

Tue. Jun 4, 2019

Room C

General Session | General Session | [GS] J-3 Data mining

[1C4-J-3] Data mining: applications to images

Chair:Masahiro Baba Reviewer:Masahiro Ito

5:20 PM - 6:00 PM Room C (4F International conference hall)

[1C4-J-3-01] Body Motion Segmentation in Non-Human Primate Based on Gaussian Process Hidden Semi-Markov Model

OKoki Mimura¹, Tomoaki Nakamura², Jumpei Matsumoto³, Hisao Nishijo³, Testuya Suhara¹, Daichi Mochihashi⁴, Takafumi Minamimoto¹ (1. National Institutes for Quantum and Radiological Science and Technology, 2. The University of Electro-Communications, 3. University of Toyama, 4. The Institute of Statistical Mathematics)

5:20 PM - 5:40 PM

[1C4-J-3-02] Proposition of Multimodal Time Series Data Analysis Framework by CNN based on Multi-Channel Image Conversion

OKomei Hiruta¹, Toshiki Hariki¹, Eichi Takaya¹, Kazuki Ito², Hiroki Aramaki², Takao Inagaki³, Norio Yamagishi⁴, Satoshi Kurihara¹ (1. Keio University, 2. Net One Systems Co., Ltd, 3. TOYOTA Production Engineering Co., Ltd., 4. TOYOTA Motor Co., Ltd.)

5:40 PM - 6:00 PM

Room D

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

[1D4-J-1] Fundamental AI, theory: bio-inspired intelligence

Chair:Hiroki Terashima Reviewer:Junpei Komihyama

5:20 PM - 6:40 PM Room D (301B Medium meeting room)

[1D4-J-1-01] A Research on Quantification of The Fear Using EEG

OShunki Kanamaru¹, Yusuke Yokota², Yasusi Naruse², Ikuko Yairi¹ (1. Sophia University, 2. NICT)

5:20 PM - 5:40 PM

[1D4-J-1-02] Evaluation of work load estimation index of somatosensory evoked potential by N-back task

OKoichi Chiba¹, Yusuke Yokota², Yasusi Naruse², Ikuko Yairi¹ (1. Sophia University, 2. NICT)

5:40 PM - 6:00 PM

[1D4-J-1-03] Area segmentation of mouse auditory cortex using complex sounds and unsupervised learning

OHiroki Terashima¹, Hiroaki Tsukano², Shigeto Furukawa¹ (1. NTT Communication Science Labs, 2. Niigata University)

6:00 PM - 6:20 PM

[1D4-J-1-04] Creating metamemory by evolving artificial neural network with neuromodulation

OYusuke Yamato¹, Reiji Suzuki¹, Takaya Arita¹ (1. Nagoya University)

6:20 PM - 6:40 PM

Room E

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

[1E4-J-12] Human interface, education aid: body and its movements

Chair:Michimasa Inaba Reviewer:Yoko Nishihara

5:20 PM - 6:40 PM Room E (301A Medium meeting room)

[1E4-J-12-01] English Word Learning System for Children to Learn by Acting Whole Body

OKensei Yamazaki¹, Kaoru Sumi¹ (1. Future University Hakodate)

5:20 PM - 5:40 PM

[1E4-J-12-02] Tennis Training Support System using HMD and Tracking Sensor

ORintaro Nishimoto¹, Masaru Okamoto¹, Yukihiro Matsubara¹, Noriyuki Iwane¹ (1. Hiroshima City University)

5:40 PM - 6:00 PM

[1E4-J-12-03] Neural Virtual Try-On System considering 3D human model

OShizuma Kubo¹, Yusuke Iwasawa¹, Masahiro Suzuki¹, Yutaka Matsuo¹ (1. The University of Tokyo)

6:00 PM - 6:20 PM

[1E4-J-12-04] Comparison and Consideration of Appearance Positions of Model Human Processor and Readiness Potential

ONanako Shimizu¹, Toshitaka Higashino², Masato Soga¹ (1. Wakayama University, 2. Osaka University)

6:20 PM - 6:40 PM

Room H

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

[1H2-J-13] AI application: image and sensitivity

Chair:Koji Morikawa Reviewer:Yoshimasa Tawatsuji

1:20 PM - 3:00 PM Room H (303+304 Small meeting rooms)

[1H2-J-13-01] Video Cartoonization based on Generative Adversarial Networks

○Hiroyuki Moriyama¹, Yachao Li¹, Eri Sato-Shimokawara¹, Toru Yamaguchi¹ (1. Tokyo Metropolitan University)

1:20 PM - 1:40 PM

[1H2-J-13-02] Evaluation and Analysis of Video Contents Using Physiological Information and VR Environment

Hayato Uraji¹, OKoki Matsumura¹, Juan Lorenzo Hagad¹, Ken-ichi Fukui¹, Masayuki Numao¹ (1. Osaka university)

1:40 PM - 2:00 PM

[1H2-J-13-03] Proposal of latent sensory estimation method for BGM recommendation using VR and EEG measurement

○Yoji Kawano¹, Kikue Sato³, Eichi Takaya¹, Satoshi Suga¹, Kazuki Yamauchi², Satoshi Kurihara¹ (1. KeioUniversity, 2. RecoChoku Co.,Ltd., 3. The University of Electro-Communications)

2:00 PM - 2:20 PM

[1H2-J-13-04] Music Composition based on the Genetic Programming with segmented VRAE

○Hironori Yamamoto¹, Naoki Mori¹ (1. Osaka Prefecture University)

2:20 PM - 2:40 PM

[1H2-J-13-05] Analysis based on Distributed Representations of Koma Images in Four-scene Comics Story Dataset

○Akira Terauchi¹, Naoki Mori¹, Miki Ueno² (1. Osaka Prefecture University, 2. Toyohashi University of Technology)

2:40 PM - 3:00 PM

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

[1H3-J-13] AI application: medicine and healthcare

Chair:Kenji Kondo Reviewer:Yoshikuni Sato

3:20 PM - 5:00 PM Room H (303+304 Small meeting rooms)

[1H3-J-13-01] Realization of behavior prediction method

using behavior log in the hospital and attribute information

○Masanori Nakagawa¹, Aoi Saito², Kazuya Murakami³, Ryu Taniguchi¹, Hiroyoshi Kuroda¹, Masahiko Ito¹, Tomomi Yajima⁴, Fumitake Hata⁴, Takafumi Nakanishi⁵ (1. Ricoh Co.,Ltd., 2. Ricoh IT Solutions Co.,Ltd., 3. Softcomm Co.,Ltd., 4. Sapporo Dohto Hospital Medical Corporation, 5. Musashino University)

3:20 PM - 3:40 PM

[1H3-J-13-02] Diagnostic Classification of Chest X-Rays Pictures with Deep Learning Using Eye Gaze Data

○Taiki Inoue¹, Nisei Kimura², Nakayama Kotaro^{2,3}, Kenya Sakka⁴, Abdul Ghani Abdul Rahman², Ai Nakajima⁵, Radkohl Patrick², Satoshi Iwai⁶, Yoshimasa Kawazoe⁶, Kazuhiko Ohe⁶ (1. Graduate School of Pharmaceutical Sciences, The University of Tokyo, 2. Graduate School of Engineering, The University of Tokyo, 3. NABLAS Inc., 4. Graduate School of Frontier Sciences, The University of Tokyo, 5. Aalto University, 6. Graduate School of Medicine, The University of Tokyo)

3:40 PM - 4:00 PM

[1H3-J-13-03] Eye-inspection Image-based Transfer Learning Rebar Expose using Semantic Segmentation

Michihiro Nakajima¹, OTakato Yasuno¹, Daisuke Nagatomi¹, Kazuhiro Noda¹, Kiyoshi Aoyanagi¹, Seiji Sekiguchi¹ (1. Yachiyo Engineering, Co.,Ltd.)

4:00 PM - 4:20 PM

[1H3-J-13-04] Cheerful status prediction using "Sleep Diary" application

○Jou Akitomi¹, Ikuo Kajiyama¹, Isa Okajima², Mineko Yamaguchi¹ (1. NEC Solution Innovators Ltd., 2. Tokyo Kasei University)

4:20 PM - 4:40 PM

[1H3-J-13-05] Prediction of the Onset of Lifestyle-related Diseases Using Health Insurance Claims Data

○Fumie Yaegashi¹, Masahiro Araki¹, Natsuki Oka¹, Motoshi Shintani², Masataka Yoshikawa³ (1. Kyoto Institute of Technology, 2. SG Holdings Group Health Insurance Association, 3.

Japan System Techniques Co., Ltd.)

4:40 PM - 5:00 PM

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

[1H4-J-13] AI application: medicine

Chair:Takeshi Imai Reviewer:Koji Kozaki

5:20 PM - 7:00 PM Room H (303+304 Small meeting rooms)

[1H4-J-13-01] Chest X-ray anomaly detection based on normal models of anatomical structures segmented by U-Net

○Kenji Kondo^{1,2}, Jun Ozawa¹, Masaki Kiyono^{2,3}, Shinichi Fujimoto³, Masato Tanaka³, Toshiki Adachi³, Harumi Ito³, Hirohiko Kimura³ (1. Advanced Industrial Science and Technology, 2. Panasonic Corporation, 3. University of Fukui)

5:20 PM - 5:40 PM

[1H4-J-13-02] Lesion Detection based on Normal Model of Vascular Pattern in Base Right Lung on Chest X-ray

○Hirokazu Nosato¹, Kenji Kondo^{1,2}, Yuta Kochi¹, Hidenori Sakanashi¹, Masahiro Murakawa¹, Jun Ozawa¹, Masaki Kiyono^{2,3}, Shinichi Fujimoto³, Masato Tanaka³, Toshiki Adachi³, Harumi Ito³, Hirohiko Kimura³ (1. National Institute of Advanced Industrial Science and Technology, 2. Panasonic Corporation, 3. University of Fukui)

5:40 PM - 6:00 PM

[1H4-J-13-03] Sleep Apnea Detection by Combining Long Short-Term Memory and Heart Rate Variability

○Ayako Iwasaki¹, Chikao Nakayama², Koichi Fujiwara^{2,3}, Yuki Yoshi Sumi⁴, Masahiro Matsuo⁴, Manabu Kano², Hiroshi Kadotani⁵ (1. Faculty of Medicine, Kyoto University, 2. Graduate School of Informatics, Kyoto University, 3. Graduate School of Engineering, Nagoya University, 4. Department of Psychiatry, Shiga University of Medical Science, 5. Department of Sleep and Behavioral Sciences, Shiga University of Medical Science)

6:00 PM - 6:20 PM

[1H4-J-13-04] Clustering Difference of the features of the by Weight Values in the Weighted PLSA using DPC data

○Kazuya Yamashita¹, Chisae Murata¹, Yuichiro Sakamoto², Eiichi Sakurai^{1,2}, Yoichi Motomura^{1,2}

(1. AI Research Center,AIST, 2. Saga University)

6:20 PM - 6:40 PM

[1H4-J-13-05] Cluster Features and Transition Patterns in the Analysis Results of Sepsis-related DPC Data with Weighted PLSA Methods

○Chisae Murata¹, Kazuya Yamashita¹, Yuichiro Sakamoto², Eiichi Sakurai^{1,2}, Yoichi Motomura^{1,2}

(1. National Institute of Advanced Industrial Science and Technology, 2. Saga University)

6:40 PM - 7:00 PM

Room I

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

[1I3-J-2] Machine learning: advances in reinforcement learning

Chair:Masahiro Yukishima Reviewer:Kohei Miyaguchi

3:20 PM - 4:20 PM Room I (306+307 Small meeting rooms)

[1I3-J-2-01] Development of Optimal Control Using AlphaZero Reinforcement Learning Algorithm

○Watabe Masaya¹, Kun Yang¹, Dinesh Malla², Katsuyoshi Sakamoto¹, Kouichi Yamaguchi¹, Tomah Sogabe^{1,3} (1. The University of Electro-Communications, 2. Grid Inc., 3. i-PERC, The University of Electro-Communications)

3:20 PM - 3:40 PM

[1I3-J-2-02] Generalized goal oriented deep reinforcement learning for robot arm training with continuous action space

○Kimura Tomoaki², Masaya Watabe², Katsuyoshi Sakamoto¹, Kouichi Yamaguchi¹, Dinesh Malla³, Tomah Sogabe^{1,3,4} (1. Advanced science and technology department, The University of Electro-Communications, 2. Mechanical department The University of Electro-Communications, 3. Grid Inc., 4. i-perc, The University of Electro-Communications)

3:40 PM - 4:00 PM

[1I3-J-2-03] Imitation learning based on entropy-regularized reinforcement learning

○Eiji Uchibe¹ (1. Advanced Telecommunications Research Institute International)

4:00 PM - 4:20 PM

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

[1I4-J-2] Machine learning: new modeling

Chair:Masayuki Okamoto Reviewer:Satoshi Oyama
5:20 PM - 7:00 PM Room I (306+307 Small meeting rooms)

[114-J-2-01] Conservation-Law Estimation from Symmetric Property of Dynamical System Extracted using DNN

○Yoh-ichi Mototake¹ (1. University of Tokyo)
5:20 PM - 5:40 PM

[114-J-2-02] Invariant Feature Learning by Pairwise Neural Net Distance

○Yusuke Iwasawa¹, Kei Akuzawa¹, Yutaka Matsuo¹
(1. The University of Tokyo)
5:40 PM - 6:00 PM

[114-J-2-03] Evaluation Method of Major Factors in Long-term Prediction with Exogenous Variables

Yuki Nakatsuka¹, ○Susumu Shirayama¹ (1. Univ. of Tokyo)
6:00 PM - 6:20 PM

[114-J-2-04] Hierarchical Neural Topic Model for Multimodal Learning

○Tatsuya Aoki¹, Masato Minamisaka¹, Takayuki Nagai^{1,2} (1. The University of Electro-Communications, 2. Osaka University)
6:20 PM - 6:40 PM

[114-J-2-05] Flexible segmentation for multi-dimensional time series data

○Maya Shigeru¹, Akihiro Yamaguchi¹, Tatsuya Inagi¹, Ken Ueno¹ (1. Toshiba Corporation)
6:40 PM - 7:00 PM

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

[112-J-5] Web Intelligence

Chair:Yuichi Miyamura Reviewer:Masahiro Ito
1:20 PM - 3:00 PM Room I (306+307 Small meeting rooms)

[112-J-5-01] An Empirical Method to Remove Reviews against the Guidelines for Restaurant Review Sites

○Yasutaka Shindoh¹, Atsunori Kanemura¹, Yusuke Miyao¹ (1. DG Lab, Digital Garage, Inc.)
1:20 PM - 1:40 PM

[112-J-5-02] Predictive Analysis on Cyber-predators Using Various Social Network Structures

○Mao Nishiguchi¹, Fujio Toriumi¹ (1. The University of Tokyo)
1:40 PM - 2:00 PM

[112-J-5-03] Proposal of Similar Area Discovery Based on Impression Extracted from Social Media

○Yasufumi Takama¹, Yosuke Sakamoto¹, Kenichiro Kobayashi², Takehiko Hashimoto² (1. Tokyo Metropolitan University, 2. GA technologies)
2:00 PM - 2:20 PM

[112-J-5-04] Analysis of readers in Online News Service

○Atom Sonoda Sonoda¹, Yoshifumi Seki², Fujio Toriumi¹ (1. The University of Tokyo, 2. Gunosy Inc.)
2:20 PM - 2:40 PM

[112-J-5-05] Analysis of user activity of politics news cluster by user attributes

○Yoshifumi Seki¹, Mitsuo Yoshida² (1. Gunosy Inc, 2. Toyohashi University of Technology)
2:40 PM - 3:00 PM

Room J

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

[1J3-J-2] Machine learning: bayesian models

Chair:Ichigaku Takigawa Reviewer:Satoshi Oyama
3:20 PM - 4:40 PM Room J (201B Medium meeting room)

[1J3-J-2-01] Bayesian Optimization with Kernels for Persistence Diagrams

○Tatsuya Shiraishi¹, Makoto Yamada^{1,2}, Hisashi Kashima^{1,2} (1. Kyoto University, 2. RIKEN Center for Advanced Intelligence Project)
3:20 PM - 3:40 PM

[1J3-J-2-02] Scalable Bayesian Optimization with Memory Retention

○Hidetaka Ito¹, Tatsushi Matsubayashi¹, Takeshi Kurashima¹, Hiroyuki Toda¹ (1. NTT Service Evolution Laboratories, NTT Corporation)
3:40 PM - 4:00 PM

[1J3-J-2-03] Bayesian Estimation for Spatial distribution using Low precision Sensors in Multi-Environment

○Masato Ota¹, Ryo Hanafusa¹, Takeshi Okadome¹ (1. Kwansai Gakuin University)
4:00 PM - 4:20 PM

[1J3-J-2-04] Sparse Bayesian Learning for Itemset Data

○Ryoichiro Yafune¹, Hiroto Saigo¹ (1. Kyushu University)
4:20 PM - 4:40 PM

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

[1J4-J-3] Data mining: social mining

Chair:Shogo Okada Reviewer:Tomoya Yoshikawa

5:20 PM - 6:20 PM Room J (201B Medium meeting room)

[1J4-J-3-01] Modelling of retention of media service users based on power-law

○Soichiro Morishita¹ (1. CyberAgent, Inc.)

5:20 PM - 5:40 PM

[1J4-J-3-02] Role discovery of the links based on the network structure

○Shumpei Kikuta¹, Fujio Toriumi¹, Mao

Nishiguchi¹ (1. The University of Tokyo)

5:40 PM - 6:00 PM

[1J4-J-3-03] Application of density Sphere graph-CNN based deep learning to congestion prediction

○Takahashi Kei¹, Katsuhisa Sakamoto¹, Kouichi

Yamaguchi¹, Takumi Numajiri², Masaru Soagbe²,

Tomah Sogabe^{1,3} (1. The University of Electro-

Communications, 2. Grid Inc., 3. i-PERC, The

University of Electro-Communications)

6:00 PM - 6:20 PM

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

[1J2-J-6] Web mining 1

Chair:Mitsuo Yoshida Reviewer:Kugatsu Sadamitsu

1:20 PM - 2:40 PM Room J (201B Medium meeting room)

[1J2-J-6-01] Recommendation System based on

Generative Adversarial Network \\with Graph Convolutional Layers

Takato Sasagawa¹, ○Shin Kawai¹, Hajime

Nobuhara¹ (1. University of Tsukuba)

1:20 PM - 1:40 PM

[1J2-J-6-02] Visualization and Analysis of the Hierarchical Correlation among Words and Documents in Hyperbolic Space

○Daiki Hashimoto¹, Hori Koichi¹ (1. University of Tokyo)

1:40 PM - 2:00 PM

[1J2-J-6-03] User Identification Across Social Media Based on Friends' Locations

○Kazufumi Kojima¹, Masahiro Tani¹ (1. NEC

Corporation)

2:00 PM - 2:20 PM

[1J2-J-6-04] Proposal of Flexible Route Recommendation Method Employing Edge Vector-Based Formulation

○Hiroki Shibata¹, Yasufumi Takama¹ (1. Tokyo

Metropolitan University)

2:20 PM - 2:40 PM

Room K

General Session | General Session | [GS] J-4 Knowledge utilization and sharing

[1K2-J-4] Knowledge utilization and sharing 1

Chair:Naoki Fukuda Reviewer:Jun Sugiura

1:20 PM - 3:00 PM Room K (201A Medium meeting room)

[1K2-J-4-01] Designing Domain Ontologies on Local

Foods and Their Stories

○Ikue Kawamura¹, Shiramatsu Shun¹ (1. Nagoya

Institute of Technology University)

1:20 PM - 1:40 PM

[1K2-J-4-02] Multi-Domain Knowledge Base Construction

System Based on Various Data Integration

○Tomoya Yamazaki¹, Takuya Makabe¹, Kentaro

Nishi¹, Chihiro Nishimoto¹, Hiroki Iwasawa¹ (1.

Yahoo Japan Corporation)

1:40 PM - 2:00 PM

[1K2-J-4-03] Constructing a better Linked Data

infrastructure in Life Sciences based on our experience

○Yasunori Yamamoto¹, Atsuko Yamaguchi¹ (1.

Database Center for Life Science)

2:00 PM - 2:20 PM

[1K2-J-4-04] Report on the First Knowledge Graph

Reasoning Challenge 2018

○Takahiro Kawamura^{1,2}, Shusaku Egami²,

Koutarou Tamura^{3,4}, Yasunori Hokazono⁴,

Takanori Ugai⁵, Yusuke Koyanagi⁵, Fumihito

Nishino⁵, Seiji Okajima⁵, Katsuhiko Murakami⁵,

Kunihiko Takamatsu⁶, Aoi Sugiura⁷, Shun

Shiramatsu⁸, Xiangyu Zhang⁸, Kouji Kozaki⁹ (1.

Japan Science and Technology Agency, 2.

University of Electro-Communications, 3. NRI

digital, Ltd., 4. Nomura Research Institute, Ltd., 5.

Fujitsu Laboratories Ltd., 6. Kobe Tokiwa

University, 7. Kobe City Nishi-Kobe Medical

Center, 8. Nagoya Institute of Technology, 9.

Osaka University)

2:20 PM - 2:40 PM

[1K2-J-4-05] Reorganizing Hierarchical Category Structure

of Wikipedia Based on the Parent-Child

Relationship Classification

○Takanori Nakagawa¹, Yoshiaki koitabashi¹,

Masaharu Yoshioka^{1,2} (1. Hokkaido University, 2.

Riken AIP)

2:40 PM - 3:00 PM

General Session | General Session | [GS] J-4 Knowledge utilization and sharing

[1K3-J-4] Knowledge utilization and sharing 2

Chair:Takahiro Kawamura Reviewer:Koji Kozaki

3:20 PM - 5:00 PM Room K (201A Medium meeting room)

[1K3-J-4-01] Knowledge-Structuring by using an Ontology and Procedural Knowledge in Guitar Performance Knowledge

○Nami Iino^{1,2,3}, Takuichi Nishimura¹, Ken Fukuda¹, Hideaki Takeda^{4,2} (1. National Institute of Advanced Industrial Science and Technology, 2. SOKENDAI (Graduate University for Advanced Studies), 3. RIKEN (Institute of Physical and Chemical Research), 4. National Institute of Informatics)

3:20 PM - 3:40 PM

[1K3-J-4-02] TurkScanner: Predicting the Hourly Wage of Previously Unseen Microtasks

○Susumu Saito¹, Chun-Wei Chiang², Saiph Savage², Teppei Nakano¹, Tetsunori Kobayashi¹, Jeffrey Bigham³ (1. Waseda University, 2. West Virginia University, 3. Carnegie Mellon University)

3:40 PM - 4:00 PM

[1K3-J-4-03] The Representation Extraction for Emerging Research Fields Using an Embedding Method for Heterogeneous Networks

○Masanao Ochi¹, Masanori Shiro², Jun'ichiro Mori¹, Kimitaka Asatani¹, Ichiro Sakata¹ (1. The University of Tokyo, 2. National Institute of Advanced Industrial Science and Technology)

4:00 PM - 4:20 PM

[1K3-J-4-04] Summarization of Discussion Document based on Abstract argumentation semantics

○Kei Nishina¹, Katsumi Nitta² (1. Tokyo Institute of Technology, 2. National Institute of Advanced Industrial Science and Technology)

4:20 PM - 4:40 PM

[1K3-J-4-05] Identifying Affiliation Impacts on Innovation Enhancement

○Takahiro Miura¹, Kimitaka Asatani¹, Ichiro Sakata¹ (1. Department of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo)

4:40 PM - 5:00 PM

Room L

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

[1L2-J-11] Robot and real worlds: cognition of objects and environment

Chair:Kugatsu Sadamitsu Reviewer:Masakazu Hirokawa

1:20 PM - 3:00 PM Room L (203+204 Small meeting rooms)

[1L2-J-11-01] Design and Evaluation Image Recognition Sub-tasks to Improve End-to-End Learning Model for Self Driving Cars

○Jing Shi¹, Hao Zhi Li², Toshiyuki Motoyoshi¹, Tadashi Onishi¹, Hiroki Mori³, Tetsuya Ogata^{1,4} (1. Department of Intermedia Art and Science, School of Fundamental Science and Engineering, Waseda University, 2. Department of Modern Mechanical Engineering, School of Creative Science and Engineering, Waseda University, 3. Future Robotics Organization, Waseda University, 4. National Institute of Advanced Industrial Science and Technology)

1:20 PM - 1:40 PM

[1L2-J-11-02] Object Perception in the Blind Spots with Mirror Based on Depth Prediction Using CNN

○Yuto Uchimi¹, Shingo Kitagawa¹, Iori Yanokura¹, Kei Okada¹, Masayuki Inaba¹ (1. The University of Tokyo)

1:40 PM - 2:00 PM

[1L2-J-11-03] Filtering of Middle Layer Outputs for Object Classification Using a Model Trained Detecting Grasping Positions

○Yasuto Yokota¹, Kanata Suzuki¹, Yuuji Kanazawa¹, Tomoyoshi Takebayashi¹ (1. Fujitsu Laboratories LTD.)

2:00 PM - 2:20 PM

[1L2-J-11-04] Observational Causal Induction with Small Samples

○Yu Takarada¹, Tatsuji Takahashi¹ (1. School of Science and Engineering, Tokyo Denki University)

2:20 PM - 2:40 PM

[1L2-J-11-05] Pixyz: a framework for developing complex deep generative models

○Masahiro Suzuki¹, Takaaki Kaneko¹, Shohei Taniguchi¹, Tatsuya Matsushima¹, Yutaka Matsuo¹ (1. The University of Tokyo)

2:40 PM - 3:00 PM

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

[1L3-J-11] Robot and real worlds: recognition and movements

Chair:Felix Jimenez Reviewer:Shinobu Hasegawa

3:20 PM - 5:00 PM Room L (203+204 Small meeting rooms)

[1L3-J-11-01] HVGH: Segmenting High Dimensional Time Series Data Using VAE and HDP-GP-HSMM

OMasatoshi Nagano¹, Tomoaki Nakamura¹, Takayuki Nagai², Daichi Mochihashi³, Ichiro Kobayashi⁴, Wataru Takano² (1. The University of Electro-Communications, 2. Osaka University, 3. Institute of Statistical Mathematics, 4. Ochanomizu University)

3:20 PM - 3:40 PM

[1L3-J-11-02] Calibration System Using Semantic-ICP for Visualization of Robot Spatial Perception Through Mixed Reality

OHitoshi Nakamura¹, Lotfi El Hafi¹, Yoshinobu Hagiwara¹, Tadahiro Taniguchi¹ (1. Ritsumeikan University)

3:40 PM - 4:00 PM

[1L3-J-11-03] Path Planning by Spatial Concept-Based Probabilistic Inference from Human Speech Instructions

OAkira Taniguchi¹, Yoshinobu Hagiwara¹, Tadahiro Taniguchi¹, Tetsunari Inamura^{2,3} (1. Ritsumeikan University, 2. National Institute of Informatics, 3. The Graduate University for Advanced Studies)

4:00 PM - 4:20 PM

[1L3-J-11-04] Self-location by a 360-degree camera mounted on a flying-robot

OGenki Ohtani¹, Yasushi Honda¹ (1. Muroran Institute of Technology)

4:20 PM - 4:40 PM

[1L3-J-11-05] Self-supervised learning base target picking system for dual-arm robot considering object instance occlusion

OShingo Kitagawa¹, Kei Okada¹, Masayuki Inaba¹ (1. the University of Tokyo)

4:40 PM - 5:00 PM

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

[1L4-J-11] Robot and real worlds: learning of robots

Chair:Yoshimasa Tawatsuji Reviewer:Masakazu Hirokawa

5:20 PM - 6:40 PM Room L (203+204 Small meeting rooms)

[1L4-J-11-01] Development of black line tracing system using deep learning for Pepper robot

OYuta Ogai¹, Masaya Kazuki¹, Shogo Suzuki¹, Daisuke Katagami¹, Takenori Obo¹, Junji Sone¹, Takahito Tomoto¹, Yoshihisa Udagawa¹ (1.

Tokyo Polytechnic University)

5:20 PM - 5:40 PM

[1L4-J-11-02] Construction of Multimodal Learning Models Based on Integrating Stochastic Models

ORyo Kuniyasu¹, Tomoaki Nakamura¹, Takayuki Nagai², Tadahiro Taniguchi³ (1. The University of Electro-Communications, 2. Osaka University, 3. Ritsumeikan University)

5:40 PM - 6:00 PM

[1L4-J-11-03] Integrated Cognitive Model for Robot Learning of Concepts, Actions, and Language

OKazuki Miyazawa¹, Tatsuya Aoki¹, Takato Horii¹, Takayuki Nagai^{1,2} (1. The University of Electro-Communications, 2. Osaka University)

6:00 PM - 6:20 PM

[1L4-J-11-04] Simultaneous Learning of Object Concepts, Language Model, and Acoustic Model Using Unsupervised Multimodal Learning

OHiroyuki Murakami¹, Ryo Ozaki¹, Akira Taniguchi¹, Tadahiro Taniguchi¹ (1. Ritsumeikan University)

6:20 PM - 6:40 PM

Room M

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

[1M4-J-13] AI application: industries and markets

Chair:Akira Tanimoto Reviewer:Shohei Higashiyama

5:20 PM - 6:40 PM Room M (Front-right room of 1F Exhibition hall)

[1M4-J-13-01] The local transactional structure based estimation of inter-firm relationships which mediates industrial modules

Kohei Kanda¹, OHajime Sasaki², Hiroko

Yamano², Ichiro Sakata¹ (1. Dept. of

Technology Management for Innovation,

Graduate School of Engineering, The University

of Tokyo, 2. Policy Alternatives Research

Institute, The University of Tokyo)

5:20 PM - 5:40 PM

- [1M4-J-13-02] Construction of a Strategy Tree in Financial Transaction using Technical Indicators
 OOhki Kato¹, Hajime Anada¹ (1. Tokyo City University)

5:40 PM - 6:00 PM

- [1M4-J-13-03] Analysis of the Impact of the Rule for Investment Diversification on Investment Performance using a Multi-Agent Simulation
 Olsao Yagi¹, Takanobu Mizuta² (1. Kanagawa Institute of Technology, 2. SPARX Asset Management Co., Ltd.)

6:00 PM - 6:20 PM

- [1M4-J-13-04] Dynamic clustering of mutual funds based on the return series
 OTohgoroh Matsui¹, Kazuki Yoneda², Koichi Moriyama², Atsuko Mutoh², Nobuhiro Inuzuka² (1. Chubu University, 2. Nagoya Institute of Technology)

6:20 PM - 6:40 PM

Room N

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

- [1N2-J-9] Natural language processing, information retrieval: dialogue

Chair: Masaaki Tsuchida Reviewer: Yuzuru Okajima

1:20 PM - 3:00 PM Room N (Front-right room of 1F Exhibition hall)

- [1N2-J-9-01] Dialogue based recommender system that flexibly mixes utterances and recommendations

ODaisuke Tsumita¹, Tomohiro Takagi¹ (1. Department of Computer Science, Meiji University)

1:20 PM - 1:40 PM

- [1N2-J-9-02] Applying a neural network model of a dialogue considering the context to Japanese ordering dialogue
 OYuri Murayama¹, Ichiro Kobayashi², Takeshi Morita³, Yukiko Nakano⁴, Takahira Yamaguchi³ (1. Ochanomizu University Graduate School, 2. Ochanomizu University, 3. Keio University, 4. Seikei University)

1:40 PM - 2:00 PM

- [1N2-J-9-03] Evaluations for personalized chatbot based on LSTM

OSohei Okui¹, Makoto Nakatsuji¹ (1. NTT Resonant, Inc)

2:00 PM - 2:20 PM

- [1N2-J-9-04] Response Dialogue-Act Prediction based on Conversational History

OKoji Tanaka¹, Junya Takayama¹, Yuki Arase¹ (1. Graduate School of Information Science and Technology, Osaka University)

2:20 PM - 2:40 PM

- [1N2-J-9-05] Empirical study of conditional interactions based on longitudinal survey data

OHiromitsu Ota¹ (1. The Open University of Japan)

2:40 PM - 3:00 PM

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

- [1N3-J-9] Natural language processing, information retrieval: understanding

Chair: Masayuki Okamoto Reviewer: Masahiro Ito

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

- [1N3-J-9-01] Extract Object of Changes from Documents using Similarities of Co-occurrence Word and its Time Distribution

OKatsuaki TANAKA¹ (1. Saitama Institute of Technology)

3:20 PM - 3:40 PM

- [1N3-J-9-02] Mention Detection method for Entity Linking

ONaotaka Kawata¹, Genichiro Kikui² (1. Okayama Prefectural University Graduate School, 2. Okayama Prefectural University)

3:40 PM - 4:00 PM

- [1N3-J-9-03] Spoken Language Understanding based on Sentence Segmentation by Language Models

OKei Wakabayashi¹, Johane Takeuchi², Makoto Hiramatsu¹, Mikio Nakano² (1. University of Tsukuba, 2. Honda Research Institute Japan Co., Ltd.)

4:00 PM - 4:20 PM

- [1N3-J-9-04] Distinguish Antonyms in Multiple Viewpoints on Distributed Word Representations

OTaku Nakamura¹, Ran Tian², Shota Sasaki¹, Kentaro Inui^{1,3} (1. Tohoku University, 2. National

Institute of Advanced Industrial Science and
Technology (AIST), 3. RIKEN Center for Advanced
Intelligence Project (AIP))
4:20 PM - 4:40 PM

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

[1N4-J-9] Natural language processing, information
retrieval: domain knowledge analysis

Chair:Tomoko Okuma Reviewer:Kugatsu Sadamitsu
5:20 PM - 6:40 PM Room N (Front-right room of 1F Exhibition
hall)

[1N4-J-9-01] Chemical Named Entity Recognition with
Self-Training

○Yiming Cui^{1,3}, Hitoshi Nishikawa^{1,3}, Takenobu
Tokunaga¹, Hiyori Yoshikawa^{2,3}, Tomoya
Iwakura^{2,3} (1. School of Computing, Tokyo
Institute of Technology, 2. Fujitsu Laboratories
Ltd., 3. RIKEN AIP-Fujitsu Collaboration Center)
5:20 PM - 5:40 PM

[1N4-J-9-02] Adding Multiple Subword Sequences to
BiLSTM-CRF Model for Compound Name
Extraction

○Hirotoshi Sekine¹, Go Urasawa¹, Takashi Inui¹,
Tomoya Iwakura² (1. Tsukuba Univ. / Riken AIP
Fujitsu center, 2. Riken AIP Fujitsu center)
5:40 PM - 6:00 PM

[1N4-J-9-03] Using Subword Sequence BiLSTM-CRF
Model for Compound Name Extraction

○Go Urasawa^{1,3}, Hirotoshi Sekine^{1,3}, Takashi Inui^{1,3},
Tomoya Iwakura^{2,3} (1. University of Tsukuba, 2.
Fujitsu Laboratories, 3. RIKEN AIP-FUJITSU
Collaboration Center)
6:00 PM - 6:20 PM

[1N4-J-9-04] Analysis of vocabulary and omitted words
in car license tests

○Seiki Matoba¹, Masaki Koga¹, Motohiro Otuka¹,
Ichirou Kobayashi², Hirotoshi Taira¹ (1. Faculty
of Information Science and Technology, Osaka
Institute of Technology, 2. Graduate School of
Humanities and Sciences, Ochanomizu
University)
6:20 PM - 6:40 PM

Room O

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

[102-J-12] Human interface, education aid:
information navigation

Chair:Yukihiro Matsubara Reviewer:Megumi Kurayama
1:20 PM - 2:40 PM Room O (Front-left room of 1F Exhibition
hall)

[102-J-12-01] Proposal and Development of the System
for private navigation by ARKit2

○Yudai Asano¹, Toshitaka Higashino², Masato
Soga¹ (1. Wakayama University, 2. Osaka
University)
1:20 PM - 1:40 PM

[102-J-12-02] Development of an Adaptive Street View
that Selects Panoramic Images Based on
User Browsing Behavior

○Riki Satogata¹, Keisuke Takiguchi¹, Yosuke
Fukuchi¹, Michita Imai¹ (1. Keio University)
1:40 PM - 2:00 PM

[102-J-12-03] The Model for the PRVAs'

Recommendation with Nonverbal
Information

○Tetsuya Matsui¹, Hidehito Honda², Seiji
Yamada^{3,4,5} (1. Seikei University, 2. Yasuda
Women's University, 3. National Institute of
Informatics, 4. SOKENDAI, 5. Tokyo Institute of
Technology)
2:00 PM - 2:20 PM

[102-J-12-04] Analyzing Factors of Beginner Friendliness
/ Visual Intelligibility for Overall
Measurement of Web Pages Explaining
Academic Concepts

○Chiharu Hirohana¹, Shintaro Okada¹, Takehito
Utsuro¹, Yasuhide Kawada², Noriko Kando³ (1.
University of Tsukuba, 2. Logworks Co., Ltd., 3.
National Institute of Informatics)
2:20 PM - 2:40 PM

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

[103-J-12] Human interface, education aid:
education and evaluation

Chair:Masato Soga Reviewer:Megumi Kurayama
3:20 PM - 4:20 PM Room O (Front-left room of 1F Exhibition
hall)

[103-J-12-01] Hidden Markov IRT model as a
generalization of Bayesian Knowledge
Tracing

○Emiko Tsutsumi¹, Shuhei Shionoya¹, Masaki

Uto¹, Maomi Ueno¹ (1. The University of Electro-Communications)

3:20 PM - 3:40 PM

[103-J-12-02] A test theory based on deep learning: Deep Response Model

ORyo Kinoshita¹, Maomi Ueno¹ (1. The University of electro-Communication)

3:40 PM - 4:00 PM

[103-J-12-03] Personalized Feedback in Case-Method Study

OKenta Sasaki¹, Kenichi Suzuki¹, Kentaro Inui² (1. Graduate School of Management, GLOBIS University, 2. Tohoku University)

4:00 PM - 4:20 PM

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

[104-J-12] Human interface, education aid: education and communication

Chair:Kazuhisa Seta Reviewer:Megumi Kurayama
5:20 PM - 7:00 PM Room O (Front-left room of 1F Exhibition hall)

[104-J-12-01] Discussion Support Robot on Educational Field

Hiroki Ono¹, OKaito Koike¹, Takeshi Morita², Takahira Yamaguchi² (1. Graduate School of Science and Technology, Keio University, 2. Faculty of Science and Technology, Keio University)

5:20 PM - 5:40 PM

[104-J-12-02] Analysis of Interaction for the Developing an Interactive Speaker for Children

OKazuhiro Mitsukuni¹, Ichikawa Jun¹, Yukari Hori², Yuta Ikeno³, Leblanc Alexandre³, Tetsukazu Kawamoto³, Natsuki Oka¹, Yukiko Nishizaki¹ (1. Kyoto Institute of Technology, 2. HAKUHODO Inc, 3. HAKUHODO i-studio Inc.)

5:40 PM - 6:00 PM

[104-J-12-03] Communication Learning Support for Pragmatic Language Disorders Using a Humanoid Robot

OKeigo Yabuki¹, Kaoru Sumi¹ (1. Future University Hakodate)

6:00 PM - 6:20 PM

[104-J-12-04] Dialogue Mood Estimation from Dialogue Voice Considering Personality Trait of Speaker

OTatsuya Hasegawa¹, Shohei Kato^{1,2} (1. Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology)

6:20 PM - 6:40 PM

[104-J-12-05] Interaction Model Promoting Language Development through Japanese Word Play

OJumpei Nishikawa¹, Junya Morita¹ (1. Shizuoka University)

6:40 PM - 7:00 PM

Room P

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

[1P4-J-10] Vision, speech: organisms and medicine

Chair:Toshihiko Yamasaki Reviewer:Akisato Kimura
5:20 PM - 6:40 PM Room P (Front-left room of 1F Exhibition hall)

[1P4-J-10-01] Construction of a Classification Model for Nodule Detection in Lung CT Images

OTaku Ri¹, Tatsuya Yamazaki¹ (1. Niigata University)

5:20 PM - 5:40 PM

[1P4-J-10-02] A novel quantification method of dense breast from mammography

OKenichi Inoue¹ (1. Shonan Memorial Hospital, Breast Cancer Center)

5:40 PM - 6:00 PM

[1P4-J-10-03] Cell Image Segmentation by Integrating Generative Adversarial Network for Each Class

OHiroki Tsuda¹, Kazuhiro Hotta¹ (1. Meijo University)

6:00 PM - 6:20 PM

[1P4-J-10-04] Proposition of Pseudo-labeling for Segmentation in Stacks of Electron Microscopy Images

OEichi Takaya¹, Yusuke Takeichi², Mamiko Ozaki², Satoshi Kurihara¹ (1. Keio University, 2. Kobe University)

6:20 PM - 6:40 PM

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

[1P2-J-13] AI application: finance and economics

Chair:Yasuo Tabei Reviewer:Tomoya Yoshikawa
1:20 PM - 3:00 PM Room P (Front-left room of 1F Exhibition hall)

- [1P2-J-13-01] Investigating the Effect of Index Investing on Stock Price Formation
Olzuru Matsuura¹, Kiyoshi Izumi¹, Hiroki Sakaji¹, Hiroyasu Matsushima¹, Takashi Shimada¹ (1. The University of Tokyo)
1:20 PM - 1:40 PM
- [1P2-J-13-02] Measuring Economic Trends based on Financial Institution Texts
OHirofumi Kondo¹, Mamoru Yogosawa¹, Michinori Naruse¹, Masakazu Mori¹ (1. The Japan Research Institute, Limited)
1:40 PM - 2:00 PM
- [1P2-J-13-03] Visualization of Inter-Regional Flows in the Virtual Currency using Machine Learning
OJoomi Jun¹, Takayuki Mizuno^{2,1} (1. SOKENDAI, 2. National Institute of Informatics)
2:00 PM - 2:20 PM
- [1P2-J-13-04] Statistical analysis aimed at assessing the economic impact of fire accidents on damaged companies
ORyoji Sato¹, Ichiro Sato¹, Takayuki Mizuno² (1. Tokio Marine & Nichido Risk Consulting Co., Ltd., 2. National Institute of Informatics)
2:20 PM - 2:40 PM
- [1P2-J-13-05] Automatic Summarization of Analyst Reports Based on Causal Relationships from News Articles
OWATARU TAKAMINE¹, Kiyoshi Izumi¹, Yasunori Sakaji¹, Hiroyasu Matsushima¹, Takashi Shimada¹, Yasuhiro Shimizu² (1. University of Tokyo, 2. Nomura Securities Co., Ltd.)
2:40 PM - 3:00 PM

Room Q

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

[1Q2-J-2] Machine learning: reinforcement learning and its advances

Chair:Koichiro Yoshino Reviewer:Kohei Miyaguchi
1:20 PM - 3:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

- [1Q2-J-2-01] Building a Human-Like Agent Based on a Hybrid of Reinforcement and Imitation Learning
ORousslan Fernand Julien Dossa¹, Xinyu Lian¹, Hirokazu Nomoto², Takashi Matsubara¹, Kuniaki Uehara¹ (1. Kobe University, 2. EQUOS

RESEARCH Co., Ltd.)

1:20 PM - 1:40 PM

- [1Q2-J-2-02] Human Sub-goal Transfer in Hierarchical Reinforcement Learning
OTakato Okudo^{1,2}, Seiji Yamada^{2,1} (1. SOKENDAI, 2. National Institute of Informatics)
1:40 PM - 2:00 PM
- [1Q2-J-2-03] Global optimization for supply chain process by deep reinforcement learning
OKazuhiro Koike¹ (1. ASKUL Corporation)
2:00 PM - 2:20 PM
- [1Q2-J-2-04] Construction of Inverse Reinforcement Dynamics Learning Framework based on Maximum Entropy Principle
OYuki Nakaguchi¹, Riki Eto¹, Itaru Nishioka¹ (1. NEC Data Science Research Laboratories)
2:20 PM - 2:40 PM
- [1Q2-J-2-05] On/off-policy Hybrid Deep Reinforcement Learning and Simulation in Control Tasks
OBonan Wang¹, Shin Kawai¹, Hajime Nobuhara¹ (1. University of Tsukuba)
2:40 PM - 3:00 PM

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

[1Q3-J-2] Machine learning: structural modeling

Chair:Koh Takeuchi Reviewer:Akisato Kimura
3:20 PM - 5:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

- [1Q3-J-2-01] L1 Regularization based Learning Method for Capsule Network
ONozomu Ohta¹, Shin Kawai¹, Hajime Nobuhara¹ (1. University of Tsukuba)
3:20 PM - 3:40 PM
- [1Q3-J-2-02] Construction of pooling layer by skip connection and analysis based on expressive power of these models
OJumpei Nagase¹, Tetsuya Ishiwata² (1. Graduate School of Engineering and Science, Shibaura Institute of Technology, 2. College of Systems Engineering and Science, Shibaura Institute of Technology)
3:40 PM - 4:00 PM
- [1Q3-J-2-03] Extracting and Exploiting Latent Knowledge Structure by Graph-based Knowledge Tracing
OHiromi Nakagawa¹, Yusuke Iwasawa¹, Yutaka Matsuo¹ (1. The University of Tokyo)

4:00 PM - 4:20 PM

[1Q3-J-2-04] Learning to Find Hard Instances of Graph Problems

○Ryoma Sato¹, Makoto Yamada^{1,2,3}, Hisashi Kashima^{1,2} (1. Kyoto University, 2. RIKEN Center for AIP, 3. JST PRESTO)

4:20 PM - 4:40 PM

[1Q3-J-2-05] A study on recommender system considering diversity in recommendation items based on LDA

○Zhiying Zhang¹, Taiju Hosaka¹, Haruka Yamashita², Masayuki Goto¹ (1. Waseda University, 2. Sophia University)

4:40 PM - 5:00 PM

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

[1Q4-J-2] Machine learning: knowledge representation and logic

Chair: Takuya Hiraoka Reviewer: Yuzuru Okajima

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

[1Q4-J-2-01] Unsupervised Grounding of Plannable First-Order Logic Representation from Images

○Masataro Asai¹ (1. IBM Research Tokyo)

5:20 PM - 5:40 PM

[1Q4-J-2-02] Learning Logic Programs from Noisy State Transition Data

○Yin Jun Phua¹, Katsumi Inoue^{1,2} (1. Tokyo Institute of Technology, 2. National Institute of Informatics)

5:40 PM - 6:00 PM

[1Q4-J-2-03] Adversarial Invariant Feature Learning with Accuracy Constraint for Domain Generalization

○Kei Akuzawa¹, Yusuke Iwasawa¹, Yutaka Matsuo¹ (1. The University of Tokyo)

6:00 PM - 6:20 PM

[1C4-J-3] Data mining: applications to images

Chair:Masahiro Baba Reviewer:Masahiro Ito

Tue. Jun 4, 2019 5:20 PM - 6:00 PM Room C (4F International conference hall)

[1C4-J-3-01] Body Motion Segmentation in Non-Human Primate Based on Gaussian Process Hidden Semi-Markov Model

○Koki Mimura¹, Tomoaki Nakamura², Jumpei Matsumoto³, Hisao Nishijo³, Testuya Suhara¹, Daichi Mochihashi⁴, Takafumi Minamimoto¹ (1. National Institutes for Quantum and Radiological Science and Technology, 2. The University of Electro-Communications, 3. University of Toyama, 4. The Institute of Statistical Mathematics)

5:20 PM - 5:40 PM

[1C4-J-3-02] Proposition of Multimodal Time Series Data Analysis Framework by CNN based on Multi-Channel Image Conversion

○Komei Hiruta¹, Toshiki Hariki¹, Eichi Takaya¹, Kazuki Ito², Hiroki Aramaki², Takao Inagaki³, Norio Yamagishi⁴, Satoshi Kurihara¹ (1. Keio University, 2. Net One Systems Co., Ltd, 3. TOYOTA Production Engineering Co., Ltd., 4. TOYOTA Motor Co., Ltd.)

5:40 PM - 6:00 PM

霊長類における身体動作時系列の分節推移構造推定

Body Motion Segmentation in Non-Human Primate Based on Gaussian Process Hidden Semi-Markov Model

三村 喬生 *1

Koki Mimura

中村 友昭 *2

Tomoaki Nakamura

松本 惇平 *3

Junpei Matsumoto

西条 寿夫 *3

Hisao Nishijo

須原 哲也 *1

Tesuya Suhara

持橋 大地 *4

Daichi Mochihashi

南本 敬史 *1

Takafumi Minamimoto

*1量子科学技術研究開発機構

National Institutes for Quantum and Radiological Science and Technology

*2電気通信大学

The University of Electro-Communications

*3富山大学

University of Toyama

*4統計数理研究所

The Institute of Statistical Mathematics

Understanding the nature of nonverbal communication (eye contacts, face expressions, body postures, hand gestures, body motions, etc...) is one of the core issue in behavioral neuroscience. In this study, we demonstrated the data-driven dynamical segmentation of the body expressions in free moving small non-human primate, common marmoset. We developed a new marker-less 3D motion tracking system optimized to marmoset. Then, we proposed unsupervised segmentation using a Gaussian process-hidden semi-Markov model (GP-HSMM). As a result, we succeeded to classify three types of marmoset feeding behavior (high position feeding, low position feeding, and low position feeding with hands) only based on body parts positions, face direction, and body angle information. This result suggested that proposing system could represent high versatility to quantify the animal nonverbal body expressions without qualitative teacher labels.

1. はじめに

「目は口ほどに物を言う」という慣用句があるが、視線・表情・姿勢・動作などの非言語表現は、意図や感情などヒトの内部状態の伝達手段として機能している [Coulson 2004]。ヒトにおいて特異的に複雑化した言語表現の進化的起源は、非ヒト霊長類など社会集団を構成する動物種においても広く観察される身体表現を用いた非言語表現に求められ [Burrows 2008, Kemp 2013]、社会的コミュニケーションの本質的要素を成していると考えられる。しかし、言語表現に紐づけて解釈が可能な例外 (手話やジェスチャーなど) を除き、非言語表現を定量的に解析する有効な手段は知られていない [Knapp 2014]、コミュニケーションダイナミクスの包括的な記述には至っていない。

小型霊長類コモン・マーモセット *Callithrix jacchus* は、他個体に対する協力性や公平性を認識するなど豊かな社会性を示す [Yasue 2018]。また、マーモセットは餌が設置される状況に応じて手や歯を使った多様な摂餌行動パターンを使い分ける事が知られ、他個体の摂餌行動を観察して模倣するなど社会的機能の基盤的動作として報告されている [Voelkl 2000]。しかし、自由な運動を妨げずに視線や身体運動情報を定量的に測定することはこれまで困難であった。

ヒトの言語表現に関する研究 (自然言語処理) においては、連続する文字列から形態素や統語構造を推定する構成論的アプローチが試みられている [Mochihashi 2009]。内部状態の伝達という機能的相同性に着目すると、非言語表現にもこれと同様の最小単位や統語的な時間構造が仮定できる。既に、自然言語処理を応用し、淀みなく連続するヒトの動作の観測情報から時系列的遷移構造を推定する試みも報告されている [Taniguchi 2011, Nakamura 2017]、非ヒト動物の動作解析では自己回帰

連絡先: 三村 喬生, 量子科学技術研究開発機構 放射線医学総合研究所, 千葉県千葉市稲毛区穴川 4-9-1, 電話番号 043-206-3251, mimura.koki@qst.go.jp

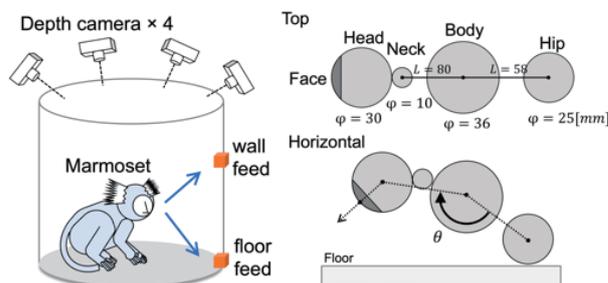


図 1: 摂餌行動の測定および骨格モデルのデザイン。

隠れマルコフモデル (AR-HMM) など単純な時系列構造推定に留まり、モデルの表現力は限定的である [Wiltshko 2015]。

一方、動物行動研究分野からは多くの動物種に対応したモーショントラック技術が報告されており [Mathis 2018]、ヒトのモーションを 2D 画像からトラッキングする技術も高精度化している [Tome 2017 など]。これらの技術によりトラッキングログ取得のハードルが低下しつつあり、集積されたデータから行動エングラム (動物固有の行動パターン) やその文脈的な意味構造に対する解析手法が求められている。

そこで本研究では、まず、マーモセットに最適化された独自の高精度モーショントラック技術を開発・実装した。深度カメラデータ解析と物体検出アルゴリズムを組み合わせることで、ボディマーカを用いずに摂餌行動時の一連の動作について身体パーツの空間配置と顔の方向ベクトルを推定することに成功した。続いて、既にヒトの身体運動パターンの解析において優れた成績を示しているガウス過程隠れセミマルコフモデル (Gaussian Process Hidden Semi-Markov Model, GP-HSMM, [Nakamura 2017]) による時系列分節構造の推定を応用し、モーショントラック情報からデータ駆動に、動作パターンに含まれる単位構造とその時系列遷移を解析した。

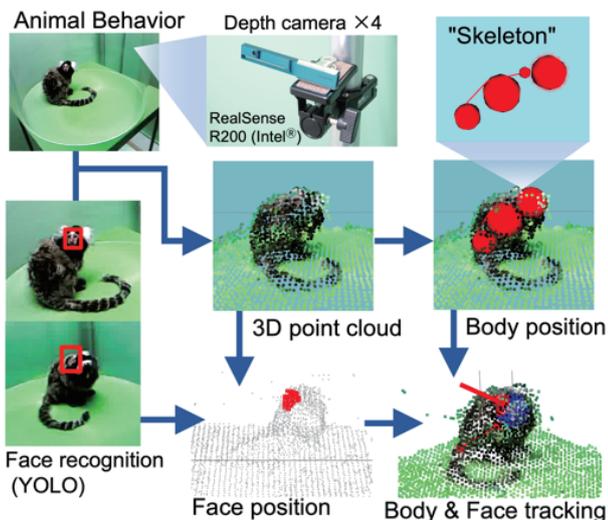


図 2: マーカーレス 3次元モーショントラッキング技術の概要。

2. 方法

2.1 行動記録

本研究では、実験環境に馴致済みのマーマセット (成体オス 1 頭, メス 3 頭) を用い、計 25 回の摂餌行動を計測した。摂餌行動は設置される餌の位置によって 2 種類の分類が含まれる (床 floor, 17 回; 壁 wall, 8 回)。実験には死角のない透明なアクリル円柱型行動試験ケージ (径 40cm; 高 50cm) を用い、動物はケージ中で自由に行動しながら壁面もしくは床に設置された餌 (約 5mm 角に成形されたタマゴ蒸しパン片) を任意のタイミングで摂餌した [図 1 左]。測定には、深度カメラ RealSense R200(Intel 社) を用いた。この R200 はパターン投射用の近赤外プロジェクタと 2 台の近赤外カメラを搭載し、視差を用いて深度距離を 1cm スケールで算出することができる (時間解像度: 30 frame/sec)。行動試験ケージを 4 方向から撮影し、ソフトウェア上で空間キャリブレーションを行い、統合することにより 3次元点集合 (point cloud) を得た [図 2]。

2.2 モーショントラッキング

測定された試験フィールドの point cloud から色相フィルタを用いてマーマセットの身体概形を抽出し、ボールとパスからなるマーマセット骨格モデルを物理シミュレーションによりフィッティングする事で、身体パーツ (頭・首・胴・腰) の空間位置を推定した。骨格モデルは球体で代表される身体パーツとそれを結ぶ骨格パスからなる。骨格パスには長さや角度の律則があり、身体パーツ間の距離と相互配置を緩く制限している [図 1 右]。また、身体パーツには、それぞれ point cloud に対して引力範囲と斥力範囲が中心からの距離 (半径) として設定されており、この釣り合いが取れる安定な空間配置に身体パーツがアトラクトされる事で推定が完了する。2D 画像における物体認識を用いた frame-by-frame のモーショントラッキング (例えば openpose や deeplabcut などの手法) に対し、本手法は frame を独立とせず、ある frame における推定結果が次の frame における推定の初期配置として用いられるため、時系列に対して自然で連続した身体運動を表現することができる。一連の計算アルゴリズムは公開されている齧歯類のトラッキング解析プログラム^{*1} [Matsumoto 2013] をマーマセット用に最適化して実装された。更に、顔の向きを検出するため frame-by-frame に 2D

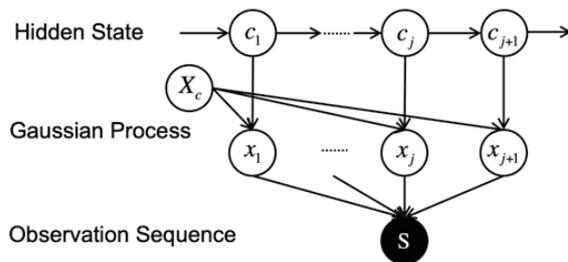
*1 <http://3dtracker.org/>

図 3: GP-HSMM のグラフィカルモデル。

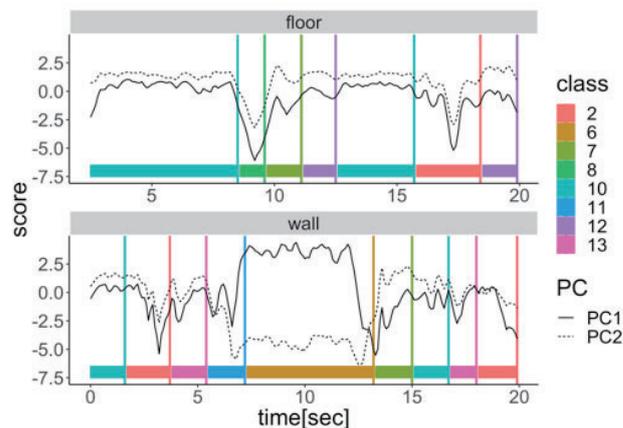


図 4: GP-HSMM を用いた分節構造推定結果の代表例。

RGB 画像上で顔の座標を推定し、point cloud に投影することで、空間座標を推定した。2D 画像における顔検出には深層学習を用いたオブジェクト検出アルゴリズム YOLO [Redmon, 2016] を用い、教師データ 2500 セットに対し学習を行った (学習率 0.1%, 積算回数 5 万回)。YOLO により検出された顔範囲に含まれる point cloud を 4 方向から抽出し、頭中心座標からの距離で抽出 ($d \leq 5 \text{ cm}$) した後、重心を算出することで空間中の顔の座標を身体マーカーを用いずに推定した [図 2]。

2.3 身体動作の分節構造推定

身体動作の分節化のために、部位 (顔・頭・胴・腰) ごとの床からの高さおよび運動速度と、骨格モデルの屈折角 [図 1 左, θ] を含めた計 9 種類の特徴量を抽出し、Loess 回帰により時間軸に対して 10 Hz に平滑化した後、主成分分析により 2次元に圧縮したデータを用いた [図 4, 6]。分節構造推定の実行は、ガウス過程セミマルコフモデル (GP-HSMM) を用いた [図 3]。当該手法は、連続量のパラメータによる時系列多次元軌道に対し、ガウス過程を用いたクラスタリングによるセグメントの分類と同時に、セミマルコフモデルによりセグメント長を推定し、さらにセグメント間の時間的推移構造をマルコフモデルにより考慮するものである。解析プログラムは公開されているもの^{*2} をカスタマイズして用いた。

学習のプロセスでは、まず全ての摂餌行動時系列をランダムに分節・分類し初期化する。今回のデータでは平均長 20 frame に設定した。次に、ある摂餌行動系列 s_n を分節化して得られた単位系列 $x_{n_j} (j = 1, 2, \dots, J_n)$ を、それらが分類されているクラス $c_{n_j} (j = 1, 2, \dots, J_n)$ から全て削除し、各クラスタのガウス過程パラメータ X_c と遷移確率 $P(c|c')$ を更新する。更新されたパラメータを用い、新たな単位時系列とそれらのクラスを推定する事で、パラメータの更新を繰り返す (Forward

*2 <https://github.com/naka-lab/GP-HSMM>

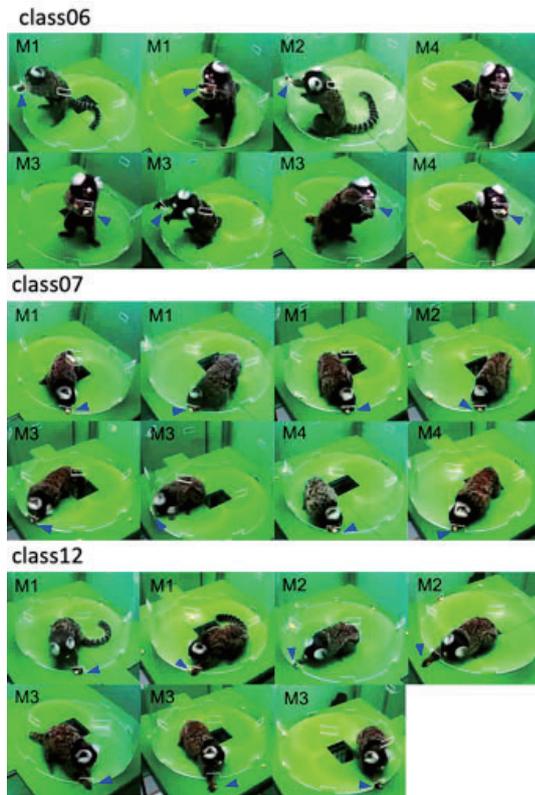


図 5: 異なるクラスに分類された摂餌行動の代表例。

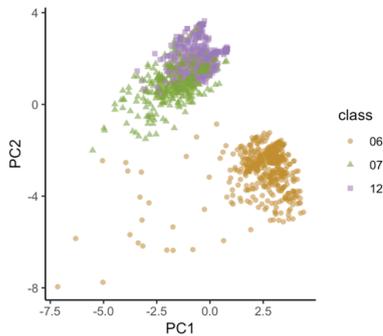


図 6: 特徴量主成分平面におけるクラスの分離。

filtering-Backward sampling)。これにより、観測系列の分節点とガウス過程のパラメータを交互に最適化する事ができる [図 3, 4, Nakamura 2017 に詳述]。

得られた餌設置条件ごとのクラス出現率を集計し、その差異パターンを階層的クラスタ解析 (完全連結法) により解析した [図 7B]。このクラスタ構造に従ってクラスの遷移確率行列を Hinton diagram により可視化した [図 7C]。

3. 結果

3.1 摂餌行動セグメント

25 セットの摂餌行動 (計 500 秒, 10fps) から抽出された 9 次元の行動特徴量の第 1, 2 主成分スコア時系列に対し、クラス数を 15 種類に設定した GP-HSMM による分節構造推定 (分節平均長 20 frame) を行った。結果 [図 4]、11 種類が採用され、4 種類のクラスは頻度 0 となった。これは最適クラス数の近似的な推定結果とみなす事ができる。

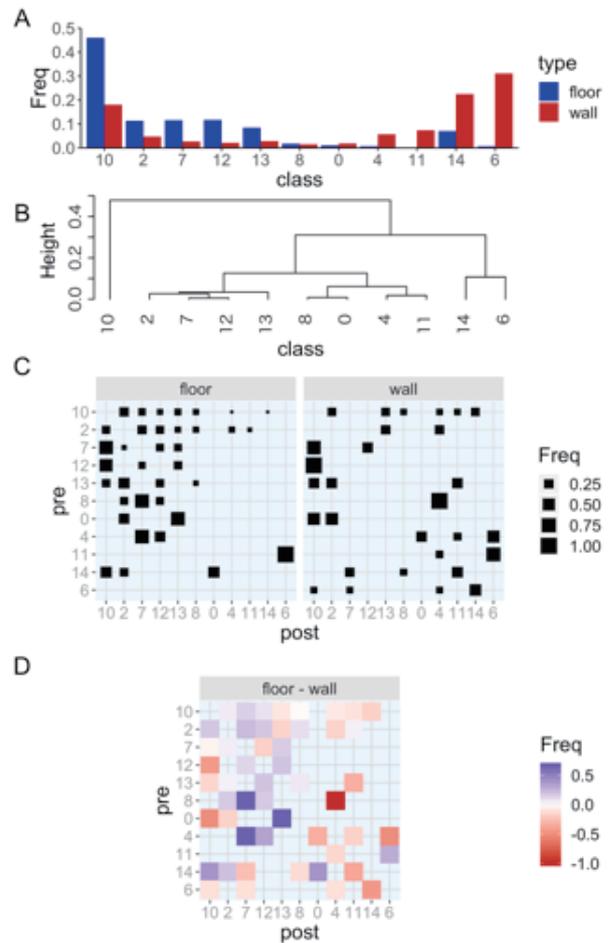


図 7: 餌の設置条件に応じた時系列遷移構造の変化。

最も多く検出されたクラス 10 は、あまり身体を動かさず顔の向きの変化のある行動が含まれていた。分節化後にビデオログから摂餌タイミングが含まれるクラスを検討したところ、大きく 3 つのクラスが得られた。それぞれ、床に置かれた餌を口を使って直接摂餌する場合の行動 [図 5 中, class07]、壁に置かれた餌を手を使って摂餌する行動 [図 5 上, class06]、および床に置かれた餌を手を使って摂餌する行動 [図 5 下, class12] を含んでいた。行動特徴量の主成分平面において、これら 3 種類の摂餌行動クラスについて分布を確認したところ、壁・床の条件差異は当該主成分得点においても認められたが、床条件における 2 種類の摂餌行動 (class07, 12) の分布は重複しており、動作クラスの分離にはパラメータの時系列構造を考慮したモデル解析が有効である事が示唆された [図 6]。

3.2 摂餌条件による遷移構造変化

検出された 11 種類の行動クラスの出現率は、餌の設置場所の条件 (壁・床) に応じて異なっていた [図 7A]。条件ごとのクラス出現率に対する完全連結法 (complete linkage method) による階層的クラスタ解析 [図 7B] に基づいた順序で遷移確率および条件間差異を可視化した [図 7CD]。結果、共通して高頻度で観測されたクラス 10 の他、床条件 (2, 7, 12, 13) と、壁条件 (0, 4, 6, 11, 14) のそれぞれにおいて相互に強く関連づけられたクラス群を検出した。分節化後にビデオログを参照したところ、それぞれの摂餌行動における特徴的な行動要素が含まれていた [表 1 に詳述]。

表1 餌設置条件に応じて特徴的に検出された行動分節

餌条件	クラス	特徴
床	2	前傾になり頭を床に近づける
床	7	摂餌行動 (床, 手を使わない)
床	12	摂餌行動 (床, 手を使う)
床	13	視線を周囲に大きく動かす
壁	0	視線を上から下に移動する
壁	4	大きく動き状態を起こす
壁	6	摂餌行動 (壁, 手を使う)
壁	11	壁にある餌にむけて立ち上がる
共通	10	大きく動かさず周囲を見渡す

4. まとめ

本研究では、非言語表現を高解像度かつ汎用的に解析する手法の開発および実装として、小型霊長類モン・マーマセットの典型的な摂餌行動のログデータを取得し、身体動作時系列の分節推移構造推定を行った。データ取得には深度カメラとオブジェクト検出器を組み合わせた新規のマーカース・3次元モーショントラック技術を開発・実装し身体部位のトラッキング情報を抽出した。分節推移構造の推定には、ガウス過程の導入により多次元連続量を取り扱える拡張を施した隠れマルコフモデル GP-HSMM を用いた。

当該手法を用い、多くの動物種において自然に観察可能な代表的な目的指向型行動 (goal-directed behavior) である摂餌行動を解析した。マーマセットの摂餌行動は、手や指を駆使した複雑な行動パターンを示す。提案手法により、手の運動情報・餌の空間配置情報・あるいはヒトの観察による教師ラベルを用いずに、身体部位 (顔・頭・胴・腰) の時系列情報のみから摂餌行動パターンの分離が得られたことは、本解析手法が高解像度な行動エソグラム分離器として機能したことを示唆している。

マーマセットでは既に遺伝子操作/改変・神経薬理操作・神経活動記録・脳イメージングなど神経科学分野の先端的研究・解析技術の適用が報告されている。提案手法による身体表現の行動エソグラム評価と組み合わせることで、精神・疾患モデル動物の表現系の評価が可能となり、ヒト臨床における言語表現に障害がある精神・神経疾患の病態評価、言語機能が未成熟な発達初期における障害リスクの早期診断など幅広い応用が見込まれる。

謝辞

本研究にあたり島谷健一郎准教授 (統計数理研究所)、谷口忠大教授 (立命館大学)、および鈴木航室長・浅場明莉研究員 (国立精神・神経医療研究センター) に多くの有益なアドバイスをいただいた。また本研究は、科研費 JP17H06040 およびAMED 課題番号 JP18dm0307007 の支援を受けて実施されたものである。ここに感謝の意を表す。

参考文献

- [Burrows 2008] Burrows, M. A.: The facial expression musculature in primates and its evolutionary significance, *BioEssays*, 30 (2008).
- [Coulson 2004] Coulson, M.: Attributing Emotion to Static Body Postures: Recognition Accuracy, Confusions, and Viewpoint Dependence, *Journal of Nonverbal Behavior*, 28 (2) (2014)

- [Kemp 2013] Kemp, C., Kaplan, G.: Facial expressions in common marmosets (*Callithrix jacchus*) and their use by conspecifics, *Animal Cognition*, 16 (2013).
- [Knapp 2014] Knapp, L. M., Hall, A. J., and Horgan, G. T.: *Nonverbal Communication in Human Interaction*, Wadsworth, Cengage Learning (2014).
- [Mathis 2018] Mathis, A., Mamidanna, P., Cury, M. K., Abe, T., Murthy, N. V., and Mathis, W., M., *DeepLabCut: markerless pose estimation of user-defined body parts with deep learning*, *Nature Neuroscience*, 21 (2018).
- [Matsumoto 2013] Matsumoto, J., Urakawa, S., Takamura, Y., Malcher-Lopes, R., Hori, E., Tomaz C., Ono T., and Nishijo, H. A 3D-video-based computerized analysis of social and sexual interactions in rats, *PLoS One*, (2013).
- [Mochihashi 2009] Mochihashi, D., Yamada, T., and Ueda, N.: Bayesian unsupervised word segmentation with nested Pitman-Yor language modeling, *Proceedings of the 47th Annual Meeting of the ACL and the 4th IJCNLP of the AFNLP*, (2009).
- [Nakamura 2017] Nakamura, T., Nagai, T., Mochihashi, D., Ichiro, K., Asoh, H., and Kaneko, M.: Segmenting Continuous Motions with Hidden Semi-markov Models and Gaussian Processes, *Frontiers in Neurorobotics* (2017).
- [Redmon 2016] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., *You Only Look Once: Unified, Real-Time Object Detection*, arXiv (2016)
- [Taniguchi 2011] Taniguchi, T., Hamahata, K., and Iwahashi, N.: Unsupervised Segmentation of Human Motion Data Using a Sticky Hierarchical Dirichlet Process-Hidden Markov Model and Minimal Description Length-Based Chunking Method for Imitation Learning, *Advanced Robotics*, 25 (2011).
- [Tome 2017] Tome, D., Russell, C., and Agapito, L., *Lifting from the Deep: Convolutional 3D Pose Estimation from a Single Image*, *CVPR*, (2017)
- [Voelkl 2000] Voelkl, B., and Huber, L., *True imitation in marmosets*, *Animal Behavior*, 60 (2000)
- [Wiltschko 2015] Wiltschko, A. B., Johnson, M. J., Iurilli, G., Peterson, R. E., Katon, J. M., Pashkovski, S. L., Abaira, V. E., Adams R. P., and Datta, S. R., *Mapping Sub-Second Structure in Mouse Behavior*, *Neuron*, 88(6) (2015)
- [Yasue 2018] Yasue, M., Nakagami, A., Nakagaki, K., Ichinohe, N., Kawai, N., *Inequity aversion is observed in common marmosets but not in marmoset models of autism induced by prenatal exposure to valproic acid*, *Behavioral Brain Research*, 343 (2018)

多変量時系列変数マルチチャネル変換画像分類における深層学習の適用

Proposition of Multimodal Time Series Data Analysis Framework by CNN based on Multi-Channel Image Conversion

蛭田 興明^{*1} 梁木 俊冴^{*1} 高屋 英知^{*1} 伊藤 千輝^{*2} 荒牧 大樹^{*2} 稲垣 隆雄^{*3}
 Komei Hiruta Toshiki Hariki Eichu Takaya Kazuki Ito Hiroki Aramaki Takao Inagaki
 山岸 典生^{*4} 栗原 聡^{*1}
 Norio Yamagishi Satoshi Kurihara

^{*1}慶應義塾大学 大学院理工学研究科
 Graduate School of Science and Technology, Keio University

^{*2}ネットワンシステムズ株式会社
 Net One Systems Co., Ltd.

^{*3}トヨタプロダクションエンジニアリング株式会社
 TOYOTA Production Engineering Co., Ltd.

^{*4}トヨタ自動車株式会社
 TOYOTA Motor Co., Ltd.

In recent years, with the development of IoT and sensor technology, various data can be acquired. In this case, it is expected to establish analytical methods capable of extracting the characteristics of relevances of each variable of multimodal data. In this study, time series variables with different dimensions on the same time axis are converted to color change images as RGB which is the three primary colors of light, and Convolution Neural Network(CNN) is applied to this. Next, we propose a method to perform more effective feature extraction by converting the image using XYZ, Lab color space reflecting the color visual stimulus with RGB as the base. We compared accuracy with existing classification method and showed the effectiveness of the proposed method. Moreover, by converting time series in various color spaces. It is suggested that higher performance feature extraction can be realized than when processing each variable as independent.

1. はじめに

近年, IoT やセンサ技術の発展により, 多様なデータをリアルタイムで得ることが可能な世の中になってきている. 実際に現時点で採取することのできるデータは, 変数の種類が単一という場合は少なく, 二種類以上のデータを対象とする場合が殆どである. このような場合の分析は, 現状は各変数の種類に対して回帰分析や異常検知を行う等, あくまで独立した変数として処理する方法が殆どである. しかし, このような多次元データが得られる場合, それぞれの変数が独立に作用している場合だけでなく, 実際はある変数が変化するとある変数が変化するというように, 互いに関連し合い, 影響を及ぼしながら変化している場合が多い. しかし未だ多次元データの関連性を新たな特徴量として抽出する研究手法は確立されていない. したがって, 複数の多次元データが得られた際に, 変数の関係を維持できるような適切な前処理を行うことで各変数の関連性を特徴抽出し, より有効性の高い分析を行う手法の確立が期待されている.

2. 関連研究

多次元データ分析に関しては今日まで産業界, 学術界を問わず幾多の手法が提案されてきた. 深層学習による高い分類精度が明らかになって以来, 深層学習に基づく多次元データ, 特に時系列データに対する分析手法が近年数多く提案されている. Zheng ら [2] は, 複数の時系列データを各チャネルに変換し, それぞれのチャネルに対し個別の Convolutional Neural Network(CNN) により処理する手法を提案している. Wang ら

[3] は Deep Neural Network を用いた時系列分類のベースライン手法を提案している.

これらの手法はいずれも, 深層学習の特徴である多次元データより特徴量を自動的に抽出しているといった点では有効性があるものの, 複数の変数の関連性より新たな特徴量を抽出するといった領域までは踏み込めていない.

3. 提案手法

本研究では, 色の持つ物理的特性を効果的に活用する特徴抽出手法の提案を行う. はじめに, 3つの異なる次元を持つ変数をそれぞれ光の三原色である赤, 緑, 青に対応させ, 正規化を行い統合させ一つの色変化画像に変換し, それに対して畳み込みニューラルネットワークを適用することで, 高性能の特徴表現学習を行う分析手法の提案を行う. 色成分は赤, 緑, 青の各独立成分の線形結合で表せるため, 3つの変数を色変換する事で, 既存手法とは異なり, 変数間の関連性も抽出することができるメリットがある. しかし, 我々人間は RGB を一つの色として認識できるが, 計算機で処理する場合は, RGB 独自に処理されてしまう. そこで, 計算機でも人のように RGB を取り扱うために, RGB を基軸にした XYZ, Lab 色空間を利用した画像変換を行うことで, より効果的な特徴抽出を行うことを目指す. XYZ は人間の視覚刺激を反映した色空間となっており, RGB 系をベースとして次のような式で表現できる.

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.576669 & 0.185558 & 0.188229 \\ 0.297345 & 0.627364 & 0.075291 \\ 0.027031 & 0.070689 & 0.991338 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (1)$$

XYZ 系の各成分は色の三原色である赤, 緑, 青の線型結合で表せるので, 各色成分に対応させた変数間の関連性を特徴抽出

連絡先: 蛭田興明, 慶應義塾大学大学院理工学研究科,
 T 223-8522 神奈川県横浜市港北区日吉 3-1-4-1,
 Email: komei1582@gmail.com

することができる。加えて、XYZ 表色系の導入により、人間が見て異なる色同士を異なる情報として扱うことが可能となる。

加えて、この XYZ 系を改良させ、より色差を正確に表現できる CIELAB 系も同時に採用した。Lab は XYZ をベースとして、次のような式で表せる。

$$f(t) = \begin{cases} t^{\frac{1}{3}} & (t > 0.008864) \\ \frac{9.66^3 t + 16}{116} & (\text{otherwise}) \end{cases} \quad (2)$$

$$L^* = 116f(Y/Y_n) - 16$$

$$a^* = [f(X/X_n) - f(Y/Y_n)]$$

$$b^* = [f(Y/Y_n) - f(Z/Z_n)]$$

(X_n, Y_n, Z_n は正規化定数)

これらの二つの色空間と通常の RGB による時系列色画像を作成し、画像分類精度の比較を行うことで色相変換による特徴表現能力の向上を試みた。

4. 時系列の折りたたみ画像作成による効果

本研究では、時系列を色相変換することで色の特性を生かした特徴抽出を行うだけでなく、時系列データを画像に置き換える際に、従来のように時系列を一行にするのではなく、時系列ウィンドウ単位で変化させたデータを横に複数並べて一つの正方形の画像とした。これによって、より広範囲の時系列パターンを表現学習することを試みた。図 5 で示すような画像変換を行うことで、隣接する時間と離れた時間の両方を畳み込むことが可能となる。これによって、多様な時系列データ変化の特徴表現学習を行うことが可能となる。

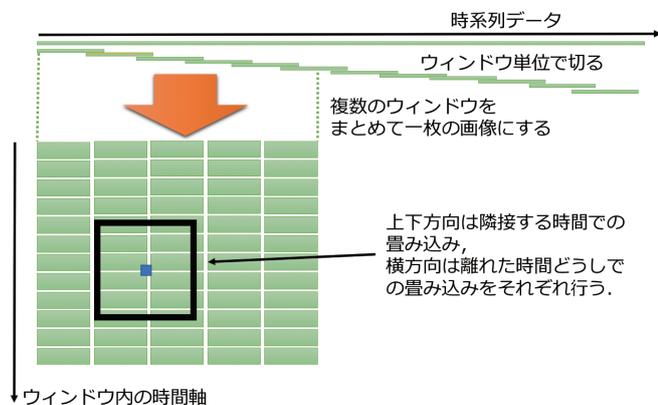


図 1: 時系列折りたたみによる作成画像イメージ

5. 実験

本研究では、上述した 2 種類の色空間によって表現される色覚刺激や色同士の差を多次元データ同士の関連性や違いに対応させることで、特徴表現能力の向上を試みた。

今回の研究で使用した CNN アーキテクチャは LeNet[8] をベースに構築した。今回の提案手法の概要を図 3, 図 4 に示す。本実験では、データセットとして UCI Machine Learning Repository の Heterogeneity Activity Recognition Data Set を用いた。これはスマートフォンの加速度センサデータであり、9 人の被験者が多様な行動をする際の x, y, z 軸の 3 方向の加速度

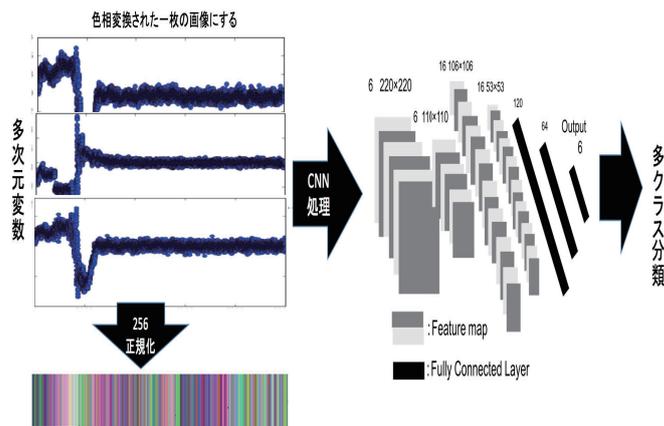


図 2: 提案手法の全体像 (1 列画像の場合)

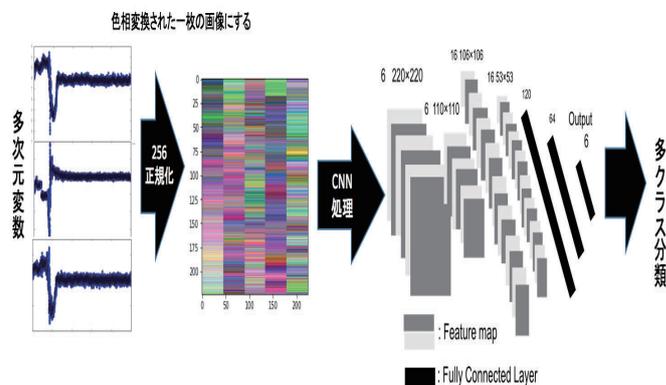


図 3: 提案手法の全体像 (折りたたみ画像の場合)

の時間変化の記録である。被験者が取り得る行動は、「立つ」、「座る」、「歩く」、「階段を登る」、「階段を下りる」、「自転車に乗る」の 6 種類である。人間の各動作の周期は約 1 秒間により、本研究では時系列ウィンドウサイズを 1250ms にし、1 ウィンドウを特定の間隔 (5ms, 10ms, 50ms, 100ms) でスライドさせ画像を作成した。これらを入力とし、行動分類モデルの学習を試みた。精度確認のため、訓練データ：バリデーションデータの比率を 8:2、バッチサイズ 70、エポック数 50 とした。

6. 結果

提案手法の評価のため、比較手法として既存の多次元データ分類手法である SVM, K-NN, RandomForest(RF), LSTM によるモデルを作成し、これと各色相空間上で画像変換した提案手法の精度 (Precision), 再現率 (Recall), F1 値 (F1-score) を求め比較した。その結果を表 1 に示す。加えて、時系列データを折りたたむことによる効果を確認するために、同一のウィンドウ間隔における精度比較を行った結果を表 2 に示す。

7. 結論および今後の方針

3次元加速度センサデータを RGB に対応させ、多様な色相空間で画像変換し、その画像の多クラス分類による行動認識を行った。表 1 より全ての比較手法より提案手法が最も高い性能

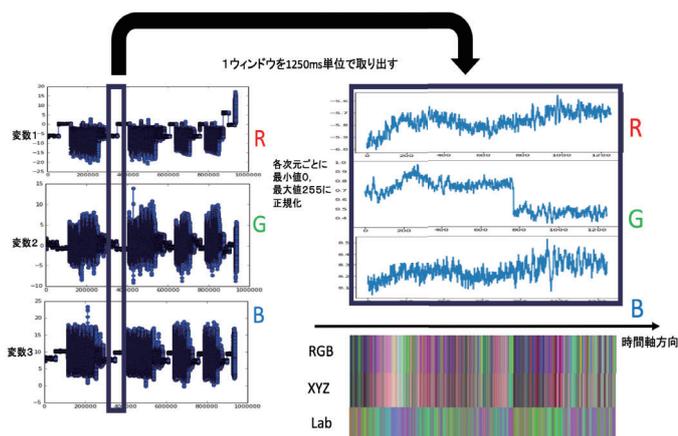


図4: 多次元データの色画像変換手順

表1: 色相効果の評価実験の結果

ウィンドウスライド 5ms における結果

手法	精度 (Precision)	再現率 (Recall)	F 値 (F-score)
SVM	85.92 %	85.89 %	85.79 %
KNN	85.50 %	85.59 %	85.49 %
RF	85.68 %	85.78 %	85.68 %
LSTM	50.29 %	90.72 %	64.63 %
RGB+CNN	92.85 %	92.57 %	92.68 %
XYZ+CNN	91.30 %	91.31 %	91.21 %
Lab + CNN	91.43 %	91.76 %	91.53 %

を示すことが確認できた。しかし、色相変換による効果が現れる場合も存在したが、色相変換によって必ずしも分類性能が向上するわけではないことが判明した。この原因として、今回の加速度データは必ずしも各成分が関連性を持って変化しているわけではないことが考えられる。加えて、時系列を一系列の画像として処理する場合と比較して、折りたたみ画像に変換することによって、わずかではあるが分類精度の向上が確認された。この結果より、時系列画像を折りたたむことで、多様な時系列変化を特徴表現学習できていることが期待される。

今後は、より多様なデータ分析手法との比較により、提案手法の有効性を示す。また、加速度データ以外にも心電図、脳波など、多様なデータに対しても性能を評価する。加えて、本手法では多次元データを直接色変換するため、現状では次元数が4以下の場合にしか対応できない。より汎用性を高めるために、次元数が5以上の場合にも色相変換により変数間の関連性を抽出できる手法の確立に努めていく。

表2: 折りたたみ画像の評価実験の結果

ウィンドウスライド 5ms における結果

色相+画像形式	精度 (Precision)	再現率 (Recall)	F 値 (F-score)
RGB+CNN 1d	92.85 %	92.57 %	92.68 %
XYZ+CNN 1d	91.30 %	91.31 %	91.21 %
Lab + CNN 1d	91.43 %	91.76 %	91.53 %
RGB+CNN 2d	92.90 %	93.06 %	92.94 %
XYZ+CNN 2d	92.20 %	92.32 %	92.26 %
Lab + CNN 2d	86.92 %	86.86 %	86.83 %

参考文献

- [1] 総務省:平成28年度情報通信白書,2016
- [2] Yi Zheng, Qi Liu, Enhong Chen, Yong Ge, J. Leon Zhao, *time series classification using multi-channels deep convolutional neural networks*, International Conference on Web-Age Information Management, 2014.
- [3] Zhiguang Wang, Weizhong Yan, Tim Oates *time series classification from scratch with deep neural networks a strong baseline*, arXiv:1611.06455, 2016.
- [4] Zhengping Che, Sanjay Purushotham, Kyunghyun Cho, David Sontag, Yan Liu *Recurrent Neural Networks for Multivariate Time Series with Missing Values*, arXiv:1611.06455, 2016.
- [5] Nijat Mehdiev, Johannes Lahanna, Andreas Emrich, David Enkeb, Peter Fettke, Peter Loosa *Time Series Classification using Deep Learning for Process Planning: A Case from the Process Industry*, Procedia Computer Science archive Volume 114 Issue C, November 2017 Pages 242-249
- [6] Nima Hatami, Yann Gavet, Johan Debayle *Classification of Time-Series Images Using Deep Convolutional Neural Networks*, arXiv:1710.00886, 2017
- [7] Fazle Karim, Somshubra Majumdar, Houshang Darabi, Samuel Harford *Multivariate LSTM-FCNs for Time Series Classification*, arXiv:1801.04503, 2018
- [8] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner *Gradient-based Learning applied to document recognition*, Proceedings of the IEEE, 86(11), 1998
- [9] 日本色相学会 カラーテクノロジー, 朝倉書店, 2008

[1D4-J-1] Fundamental AI, theory: bio-inspired intelligence

Chair:Hiroki Terashima Reviewer:Junpei Komihyama

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room D (301B Medium meeting room)

[1D4-J-1-01] A Research on Quantification of The Fear Using EEG○Shunki Kanamaru¹, Yusuke Yokota², Yasusi Naruse², Ikuko Yairi¹ (1. Sophia University, 2. NICT)

5:20 PM - 5:40 PM

[1D4-J-1-02] Evaluation of work load estimation index of somatosensory evoked potential by N-back task○Koichi Chiba¹, Yusuke Yokota², Yasusi Naruse², Ikuko Yairi¹ (1. Sophia University, 2. NICT)

5:40 PM - 6:00 PM

[1D4-J-1-03] Area segmentation of mouse auditory cortex using complex sounds and unsupervised learning○Hiroki Terashima¹, Hiroaki Tsukano², Shigeto Furukawa¹ (1. NTT Communication Science Labs, 2. Niigata University)

6:00 PM - 6:20 PM

[1D4-J-1-04] Creating metamemory by evolving artificial neural network with neuromodulation○Yusuke Yamato¹, Reiji Suzuki¹, Takaya Arita¹ (1. Nagoya University)

6:20 PM - 6:40 PM

脳波計を用いた恐怖の定量化に関する研究

A Research on Quantification of The Fear Using EEG

金丸 竣樹*¹ 横田 悠右*² 成瀬 康*² 矢入 郁子*¹
 Shunki Kanamaru Yusuke Yokota Yasusi Naruse Ikuko Yairi

*¹ 上智大学大学院 理工学研究科 理工学専攻情報学領域
 Graduate School of Science and Technology, Sophia University #1

*² 国立研究法人 情報通信研究機構
 National Institute of Information and Communications Technology #2

Recently, in the field of brain science, it has been reported that brain network related to fear sympathetic nervous activity was clarified by fMRI measurement. However, fMRI measurement under daily circumstances is difficult. If it is possible to detect fear with electroencephalograph in daily circumstances, objective fear indicators will be determined and used to control fear in the entertainment field and to reduce fear in medical services and so on. In this paper, we analyzed the characteristics of electroencephalogram data during fear and no fear by using frequency analysis from two experiments using VR horror game and experiments using horror movie with a dry electrode. As a result, there was significant difference in power spectral density between alpha wave fear and no fear.

1. はじめに

脳科学の分野では機能的核磁気共鳴画像法(functional magnetic resonance imaging : fMRI)を用い、恐怖による交感神経活動の脳内ネットワークが明らかとなった[1]。しかし、fMRIはMRI装置内で測定をするため日常的な状況下での恐怖感情の測定は困難である。脳波計を用いて簡易かつリアルタイム性高く恐怖を検出できれば、客観的な恐怖の指標を用いてエンターテインメント分野での恐怖の制御やフィードバックを得ること、医療サービスなどでの恐怖の低減といった実応用が可能となる。そこで本稿では、乾式の脳波計を用いて恐怖時の脳波の計測し、その特徴の分析を行う。

2. VR ホラーゲームを用いた実験

2.1 実験機器

“恐怖”の定義は曖昧であるため、実験における恐怖を定義する。山根氏によると恐怖対象の現れとは「不気味・異様な存在者が、余裕ないほど近すぎて在ること」と述べている[2]。そこで本実験の恐怖の提示方法として、高い没入感を得ることができるVR (Virtual Reality) を用いることを計画した。VRゲームはOculus Rift用ホラーゲーム「Dreadhalls」を用いた。当ゲームでは、ランダムに生成されるダンジョンでプレイヤーはホラーオブジェクトを避けながら進むため、前述の恐怖の定義に当てはまる状況をランダムに得られる。

脳波計測はワイヤレス生体計測装置 Polymate Mini 108 とドライ電極をOculus Rift CV1に取り付けたものを利用した。拡張10-20法[3]における前頭部電極位置1箇所(Fp2)、頭頂部電極位置3箇所(C3, Cz, C4)、後頭部電極位置3箇所(O1, Oz, O2)に電極を配置した。全てのデータはサンプリング周波数500Hzで計測した。また、脳波計測に加えてiPod Touchを加速度センサとして用い体動を計測し(加速度データ)、皮膚電気活動測定ユニットAP-U030を用い精神性発汗を計測した(EDAデータ)。

連絡先: 金丸竣樹, 上智大学理工学専攻情報学専攻,
 〒232-0072 神奈川県横浜市南区永田東 1-34-18,
 080-3729-1116, kanamaru@yairilab.net

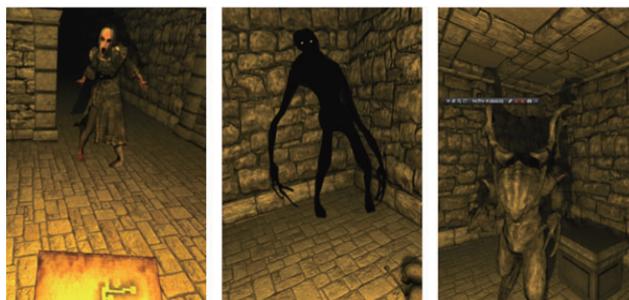


図1 Dreadhallsのホラーオブジェクト
 (左からゾンビ, 黒い影, ガーゴイル)

2.2 実験概要

実験はVRゲーム内の最初のチュートリアルで操作方法とゲーム内のアイテムに関する説明を行い、実際に「ゾンビ」と遭遇させた。その後、休憩を取り、スタートからゴールまでのランダムダンジョンプレイ中の脳波を計測した。ゲームのプレイ時間は約20分で、VR酔いで体調を崩した場合は十分な休憩をとった。

実験協力者は健康な大学生11名(男性11名, 年齢幅22-25)である。その内6名において脳波計の端子の不備・イベントデータ数の不足が確認されたため分析対象から外した。全ての協力者は、実験内容について十分に理解し、参加の同意を得た上で実験を行った。



図2 脳波測定用 Oculus Rift

2.5 考察

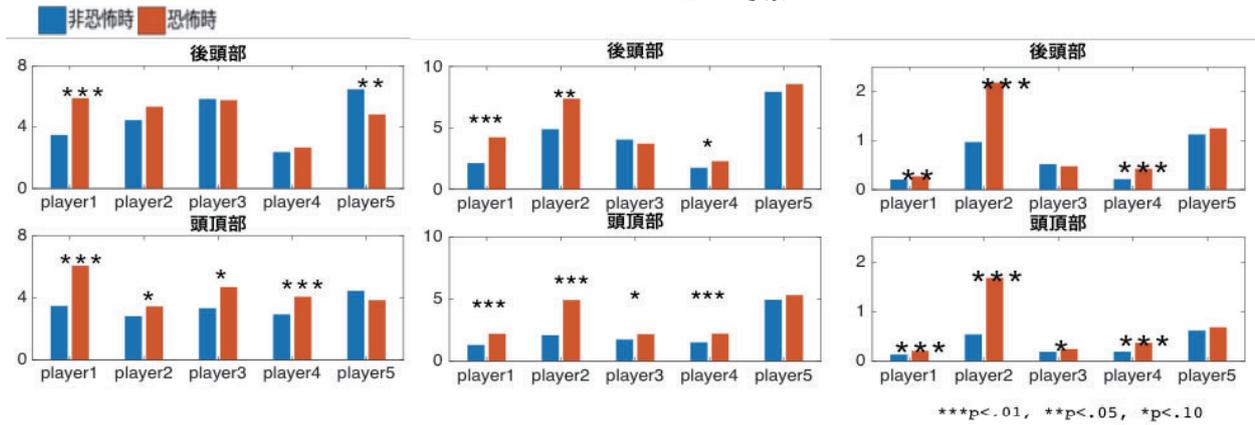


図3 脳波におけるパワースペクトル密度(左からシータ波, アルファ波, ベータ波)

2.3 解析方法

得られた脳波データに対して Matlab を用いてバンドパスフィルタ, 眼電アークファクトの除去の前処理を行い, 周波数解析によりパワースペクトル密度を算出した. VR ホラーゲームプレイ時の動画を元に, iPod Touch により得られた加速度データに閾値を設け, 体動の大きい時刻の脳波データを破棄した. 恐怖時のデータは EDA データの波形の立ち上がりからピークまでに潜伏時を加えた時間の脳波データとした[4]. 非恐怖時のデータは EDA データの変化の割合が低く値の変動が少ない場面かつ, 心拍間隔が全体の上位 10%の時間の脳波データとした. これらの恐怖・非恐怖の指標を元に, パワースペクトル密度を恐怖と非恐怖のデータに分類した. 分類されたデータに対してデータの差の有意性を確かめるため t 検定を行った.

2.4 実験結果

図 3 に全ての実験協力者における, 周波数帯域毎の恐怖時・非恐怖時のパワースペクトル密度を示す. また, 表 1~3 に周波数帯域毎の恐怖時・非恐怖時のパワースペクトル密度の差(恐怖 - 非恐怖)を示す. シータ波について, 後頭部(5名中2名), 頭頂部(5名中2名)で有意な差が確認された($p < .05$). アルファ波について, 実験協力者の後頭部(5名中2名), 頭頂部(5名中3名)において恐怖・非恐怖時の間に有意な差が見られた($p < .05$). 有意な差が見られた協力者において非恐怖時に比べ恐怖時の値が大きく出る傾向が確認された. ベータ波について, 実験協力者の後頭部(5名中3名), 頭頂部(5名中3名)において恐怖・非恐怖時の間に有意な差が見られた($p < .05$). 有意な差が見られた協力者において非恐怖時に比べ恐怖時の値が大きく出る傾向が確認された.

表1 シータ波のパワースペクトル密度の差

	player1	player2	player3	player4	player5
後頭部	2.630	0.746	-0.097	0.346	-1.465
頭頂部	2.671	0.626	1.201	1.084	-0.469

表2 アルファ波のパワースペクトル密度の差

	player1	player2	player3	player4	player5
後頭部	2.093	2.493	-0.327	0.530	0.635
頭頂部	0.910	2.839	0.433	0.704	0.371

表3 ベータ波のパワースペクトル密度の差

	player1	player2	player3	player4	player5
後頭部	0.058	1.268	-0.073	0.201	0.076
頭頂部	0.075	1.188	0.035	0.171	0.043

ベータ波の結果に関しては興奮状態や緊張状態で発生するという特徴と一致しているため, 恐怖時・非恐怖時をある程度の妥当さで分類できたと言える. 一方で, アルファ波の結果に関しては精神負荷がかかる時に活動が減少するという特徴と一致していない. これはネガティブな画像提示前にアルファ波が強く減衰するという研究と関係していることが考えられる[5]. また, 本実験の課題として次の二つのことが挙げられる.

- VR ホラーゲームのプレイ時に VR 酔いを訴える協力者がいたことにより, 視覚誘導性自己運動感覚が脳波に影響している可能性があるということ[6][7].
- 体動は閾値を超えたものに関して破棄しているため除去しきれていない細かな体動が解析データに含まれていることが考えられる,

3. ホラー映像を用いた実験

3.1 実験機器

VR ホラーゲームを用いた実験での課題点である体動ノイズと VR 酔いに関して考慮するために, 恐怖の提示方法としてホラー映像のワンシーンを VR で見せることにした. ホラー映像の選定はホラー映画評論家の添野氏の監修の元で, 観測対象の恐怖に近い2つの映像作品(貞子 VS 伽椰子, 日本の怖い夜)から3つのシーンを用いた. 映像はホラーイベントが起こるまでの時間が長く, グロテスクな表現を使っていない映像の中でも, ホラーイベントが起こるまでに何か起こりそうな「予感」を協力者に想起させるような映像とした. 実験は乾式の脳波計のみを用いて行った. 脳波計の電極位置を拡張 10-20 法における前頭部電極位置 2 箇所(Fp2, AP8), 前頭中心部電極位置 3 箇所(FC3, FCz, FC4), 後頭部電極位置(O1, O2)に変更した.

3.2 実験概要

実験は安静時の脳波を約 2 分間計測し, その後ホラー映像を3つ合わせたものを二度見もらった. 実験映像は全体で 10 分程度であり, ホラー映像の間には 30 秒間の休憩を設けた. 二度目の映像視聴前には十分な休憩を設けて計測を行った. また, 実験後に映像に対する評価と協力者の視聴状況についてアンケートを行い, 恐怖・非恐怖の分類に用いた.

実験協力者は健康な大学生 8 名(男性 8 名, 年齢幅 22-23)である. その内, 恐怖を感じていないと実験後のアンケートで申告した 2 名と脳波計端子の一つが外れていた 1 名を分析対象から外した. 全ての協力者は実験内容について十分に理解し, 参加の同意を得た上で実験を行った.

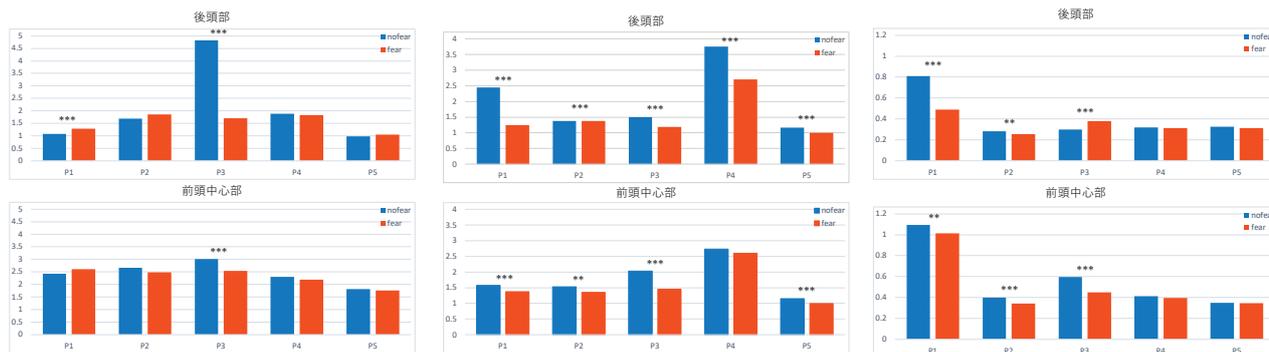


図4 脳波におけるパワースペクトル密度(左からシータ波, アルファ波, ベータ波) ***p<.01, **p<.05

3.3 解析方法

2.3 と同様に脳波データの前処理を行い, 周波数解析により各周波数帯のパワースペクトル密度を算出した. 恐怖時のデータは一度目の映像視聴時に協力者がアンケートで恐怖を感じたと答えたホラーシーンの直前の脳波データとした. 非恐怖時のデータは二度目の映像視聴時の恐怖時と同じタイミングの脳波データとした. 抜き出した脳波データに対して Smirnov-Grubbs の棄却検定を用いて外れ値を除去し, データの差の有意性を確かめるために協力者毎に t 検定を行った. また, 協力者毎に代表点求め, 3 要因(恐怖・非恐怖, 電極位置, 周波数帯域), 周波数帯域におけるシータ波を除いた各 2 水準(恐怖・非恐怖, 後頭部・前頭中心部, アルファ波・ベータ波)の分散分析を ANOVA4 on the Web を用いて行った.

3.4 実験結果

図4に各周波数帯域における各協力者(P1~P5)のパワースペクトル密度の平均値と t 検定の結果を示す. 表4~表6に各周波数帯域におけるパワースペクトル密度の差(恐怖 - 非恐怖)を示す. シータ波について後頭部(5名中2名), 前頭中心部(5名中1名)で恐怖・非恐怖の脳波データに有意な差(p<.01)が確認された. 恐怖時と非恐怖時の値の差の傾向は一致しなかった. アルファ波について実験協力者の後頭部(5名中5名, p<.01), 前頭中心部(5名中4名, p<.05)において恐怖・非恐怖の脳波データに有意な差が見られた. 有意な差が見られた協力者において非恐怖時に比べ恐怖時の値が小さくなる傾向が確認された. ベータ波についても実験協力者の後頭部(5名中3名), 頭頂部(5名中3名)において恐怖・非恐怖の脳波データに有意な差(p<.05)が確認された. P3の後頭部を除く有意な差が見られた協力者において非恐怖時に比べ恐怖時の値が小さくなる傾向が確認された.

表4 シータ波のパワースペクトル密度の差

	Participant1	Participant2	Participant3	Participant4	Participant5
後頭部	0.207	0.171	-3.120	-0.057	0.064
前頭中心部	0.181	-0.187	-0.482	-0.113	-0.058

表5 アルファ波のパワースペクトル密度の差

	Participant1	Participant2	Participant3	Participant4	Participant5
後頭部	-1.202	-0.008	-0.315	-1.042	-0.170
前頭中心部	-0.208	-0.169	-0.586	-0.139	-0.157

表6 ベータ波のパワースペクトル密度の差

	Participant1	Participant2	Participant3	Participant4	Participant5
後頭部	-0.322	-0.026	0.079	-0.008	-0.014
前頭中心部	-0.078	-0.059	-0.150	-0.019	-0.003

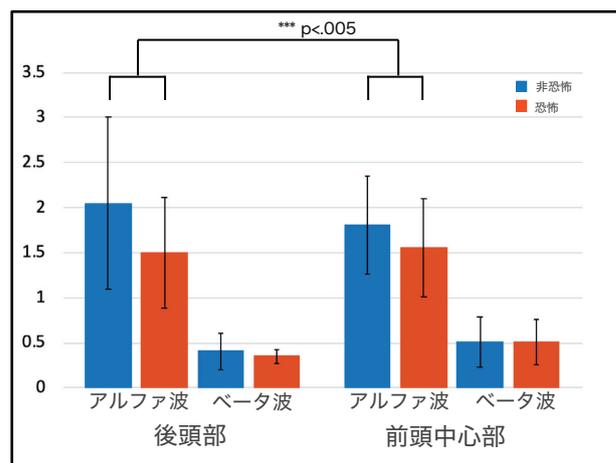


図5 分散分析の結果

図5は協力者の代表点(それぞれの水準における加算平均値)における平均と標準偏差をまとめたものである. 協力者の脳波データに対して 2(恐怖・非恐怖)×2(後頭部・前頭中心部)×2(アルファ波・ベータ波)の3 要因の ANOVA による分散分析を行ったところ, 恐怖ラベル(恐怖・非恐怖)と周波数帯域(アルファ波・ベータ波)において主効果が有意であった(F(1,4)=10.281, p<.05), F(1,4)=14.097, p<.05). また, 一次の交互作用が要因間(恐怖ラベル×周波数帯域)で認められた(F(1,4)=11.023), p<.05)が, 他の交互作用は認められなかった. 交互作用が確認された(恐怖ラベル×周波数帯域)要因において単純主効果を調べるために下位検定を行った. 恐怖・非恐怖の要因におけるアルファ波の単純主効果が有意であったが(F(1,9)=20.599, p<.005), ベータ波に関しては有意でなかった(F(1,9)=0.463, p>.10). よって, 分散分析の結果として恐怖・非恐怖においてアルファ波のパワースペクトル密度の差を見ることに意味があることがわかった.

3.5 考察

協力者毎の t 検定の結果と協力者グループ間に対する分散分析の結果から脳波測定位置による恐怖・非恐怖の影響の差は少なく, 恐怖時の脳活動はアルファ波と関連があると考えられる. 非恐怖時と比べ恐怖時のアルファ波が低いことからアルファ波の結果に関しては精神負荷がかかる時に活動が減少するという特徴があることからホラー映像視聴時にも同様の傾向が見られていると考えられる. 一方で, ベータ波の結果に関して分散分析において単純主効果は認められなかった. また, パワースペクトル密度の差の傾向として非恐怖時と比べ恐怖時は協力者3(P3)の後頭部を除いて減少傾向が見られた. 認知活動に関わ

る前頭部において非恐怖時と比べ恐怖時の脳波が低く見られることから二度目の映像視聴時(非恐怖時)に認知活動が上がっている。恐怖の脳波は興奮・緊張に関わってくるのが考えられるため、この結果は一度目の映像視聴時(恐怖時)の方がベータ波は高くなるという仮説とは逆となった。これらの結果から次のようなことが考えられる。

- ホラーイベント前を恐怖時の脳波データとして利用しているため、認知処理に関する情報を扱うベータ波では刺激に対する準備状態であることが考えられ、このベータ波の準備状態に個人差がある可能性が考えられる。
- 実験後の協力者アンケートにおいて複数の協力者(8名中3名)が実験の後半で乾式の脳波計による痛みを報告している。痛みを報告しなかった協力者も多少の痛みを感じていたことが考えられる。痛みがベータ波を増加させるという報告があることから、乾式の脳波計の痛みによっても同様の傾向が出ていたことが考えられる[8][9]。

4. 全体の考察

ホラー映像を用いた実験の分析ではVRホラーゲームを用いた実験の分析結果と比較すると全体的にパワースペクトル密度が小さくなった。これは細かな体動・眼球運動などのノイズを取り除けたということが考えられる。一方で、VRホラーゲームの没入感による恐怖刺激に比べてホラー映像の恐怖刺激が弱かった可能性も考えられるため刺激に関しても考慮していく必要がある。また、ホラー映像を用いた実験ではVR酔いを訴えた協力者がいなかったことからVRホラーゲームを用いた実験での課題点に関しては解決できた。課題を解決した上で行ったホラー映像を用いた実験から恐怖時にアルファ波が減少するという分析結果を得ることができた。アルファ波の波形を見ることで今後恐怖の定量化につなげていけるのではないかと考えられる。また、ベータ波に関しても恐怖時に減少傾向にあったが、これは脳波計の痛みに関して留意した上で慎重に調査していく必要がある。今回ホラー映像を用いた実験では他の生理指標を恐怖・非恐怖の分類に用いることができなかった。今後、他の生理指標を含めた上でより緻密に定義した恐怖指標を用い、恐怖の脳波がどの周波数帯域に出るか細かく見ていく必要がある。また、実験はまだ初期段階であり、協力者の数が少ないことから各周波数帯域でのパワースペクトル密度の傾向が一致しないこと、分散分析の結果が一人一人の協力者に左右されやすいことが考えられる。今後、より多くの協力者を得た上で分析を行うことでより確かな知見が得られると考えられる。

5. 終わりに

本稿では、恐怖時の脳活動を明らかにするために乾式の脳波計を用いて健常な協力者を対象に二つの実験の視点から恐怖時の脳波の観測を試みた。生理指標を用いたVRホラーゲームによる実験では、生理指標を元に恐怖・非恐怖の脳波データを分類し、解析することでベータ波を見ることで恐怖時の脳波を測定できる可能性を示した。しかし、恐怖以外の刺激であるVR特有の視覚誘導性自己運動感覚による酔い、VRゲームプレイ時における細かな体動ノイズの混入などが脳波データに影響を与えている可能性があり、これらの問題を解決した上で脳波データを解析する必要があった。問題を解決するために計画したホラー映像を用いた実験では、協力者がアンケートで主観的に怖さを感じたと答えた映像の一度目の映像視聴におけるホラーイベントが起こるまでの脳波を恐怖、二度目の映像視聴時における同じタイミングの脳波データを非恐怖の脳波データを分類した。分類された脳波データを解析することで、非恐怖時に

比べ恐怖時のアルファ波が減少する傾向が確認され、アルファ波での恐怖の定量化の可能性を示した。しかし、ベータ波に関しては仮説と異なる結果となり、恐怖時の脳波の特徴としては弱い結果となった。

今後、本稿における実験で得られた知見を裏付ける結果が求められる。そのために、恐怖・非恐怖の指標をより明確に、かつ、より客観的に定義した上で協力者を集め、細かい周波数帯域で広義的に分析を進めていく必要がある。また、恐怖時の脳波をより明確な特徴を得た上で、得られた恐怖時の脳波の特徴を用いて時間周波数解析や機械学習などを用いて時系列データ分析を行っていきたい。

謝辞

NICT 成瀬康博士、横田悠右博士、ホラー映画評論家の添野知世氏に感謝いたします。また、本実験に協力してくださった参加者の皆様に感謝いたします。

参考文献

- [1] [Yoshihara 2016] Yoshihara Kazufumi: Neural correlates of fear-induced sympathetic response associated with the peripheral temperature change rate., *NeuroImage*, 134, pp.522-531, 2016
- [2] [山根一郎 2007] 山根一郎: 恐怖の現象学的心理学, 関係学研究(5), pp.113-129, 2007
- [3] [Klem 1999] Klem, G., LuE'ders: The ten-twenty electrode system of the international federation, *Electroencephalogr Clin Neurophysiol*, Vol. 52, No. 3, pp. 3-6, 1999
- [4] [廣田 2003] 廣田昭久: 新たな精神生理学的虚偽検出の指標: 規準化脈波容積の適用可能性, *生理心理学と精神生理学*, Vol. 21, No. 3, pp. 217-230, 1999
- [5] [Onoda 2008] Onoda K: Anterior cingulate cortex modulates preparatory activation during certain anticipation of negative picture, *Neuropsychologia* 46.1: 102-110, 2008
- [6] [Hosoda 1994] Hosoda R: Evaluation of ride-quality and incidence of seasickness (3rd report), *Journal of the Society of Naval Architects of Japan*, Vol. 1994 No. 176, pp. 517-524, 1994
- [7] [福川 2003] 福川雅人: 乗り物酔い過程における心拍ゆらぎの解析, *関西造船協会論文集*, Vol. 2003, No. 240, pp. 237-242, 2003
- [8] [江部 1979] 江部充: 図解脳波テキスト, 36-43, 文光堂, 東京, 1979
- [9] [伊藤 1988] 伊藤正男: 最新脳の科学 (1), 425-427, 同文書院, 東京, 1988

体性感覚誘発電位の作業負荷推定指標化の N-back タスクによる評価

Evaluation of work load estimation index of somatosensory evoked potential by N-back task

千葉 晃一*¹ 横田 悠右*² 成瀬 康*² 矢入 郁子*¹
 Koichi Chiba Yusuke Yokota Yasusi Naruse Ikuko Yairi

*¹ 上智大学大学院理工学研究理工学専攻情報学領域
 Graduate School of Science and Engineering, Sophia University

*² 国立研究開発法人 情報通信研究機構
 National Institute of Information and Communications Technology

Abstract: The purpose of this study is to elucidate a method that uses somatosensory evoked potential as an estimation index of workload. Realtime estimation of the workload in the brain by AI system will enable to increase the concentration of people by keeping a moderate tension. The quality of interaction between the system and people could be largely increased by intervention of interacting when people lost the concentration. We measured and analyzed the activity of the brain during the execution of the N-back task while presenting somatosensory stimuli to 10 participants without impairment. As a result, amplitude modulation was seen with N9 which is one of somatosensory evoked potential components. In addition, a t test was performed on it, and a significant difference was observed. The Bonferroni method was used to correct the p value.

1. はじめに

急速な IT 化により、コンピュータのディスプレイなど表示機器 (VDT: Visual Display Terminals) を使用した作業が、時間、量ともに増加し、それに伴う精神的・身体的な疲労を訴える作業が増加している。VDT 作業は、長い間ディスプレイを見つめ、座ったままの姿勢で作業をするため、「拘束的」である。その上、VDT 作業負荷は、肉体労働に比べて軽微であるが、連続した作業であるため、疲労が蓄積しやすく一定の期間を経て障害が、顕在化することが多い。このように VDT 作業における疲労は、作業者の健康に影響を与えると伴に、作業効率の低下も懸念される[1]。

これまで、VDT 作業に関する実験や研究は、数多くなされており、健康管理上の対策やハード面の改善などに大きな成果が認められている。しかし、多くの課題も残されている。疲労は、概念や定義が広く、VDT 作業時の疲労もはっきり定義づけされていない[1]。

脳内の作業負荷をリアルタイムに AI システムが推定する方法を確立し、過度な疲労を検知した時点で、随時 VDT 作業者に警告を与えれば、VDT 作業者は、それに基づいて休息を得て作業効率を低下させず、さらに健康を維持できるのではないかと考えられる。そのシステムを実現させるためには、生体情報から疲労に関する信号を抽出できることが不可欠である。

近年、脳活動計測による精神作業負荷 (MWL: mental work load) の評価が注目されている[2]。MWL は、脳内の作業負荷に応じて常に変化する。脳内の作業負荷は、思考や集中といった活動状態では高く、休息状態では低くなる。リアルタイムに作業負荷を推定する手法が確立されれば、MWL を適正なレベルに維持することにより、過度な負担を避け、適度な緊張感を維持することが可能となるため、

脳内の作業負荷を推定し指標化することは重要である[3]。

従来の EEG を用いた脳内の作業負荷推定指標化の研究では、聴覚定常状態応答 (ASSR: Auditory Steady State Responses) を用いた手法が用いられてきている[4]。しかし、この手法は、発話や対話などの聴覚刺激を含む作業への適用が困難という欠点がある。そこで、私たちは発話や対話などの聴覚刺激を含む作業への適用を目指し、体性感覚刺激によって誘発される体性感覚誘発電位 (SEP: Somatosensory Evoked Potentials) を作業負荷の推定指標とする手法を提案し、その実現可能性について検討する。SEP は、皮膚表面などを物理刺激された時に現れる事象関連電位 (ERP: Event Related Potential) の成分であり、上肢 (正中、尺骨神経) あるいは下肢 (後頸骨、総腓骨神経) を電気刺激することによって得られる。その伝導路は抹消神経大径有髄繊維、脊髄後索、内側毛帯、視床、大脳皮質感覚野と考えられている[5]。

私たちは、同じ視覚刺激内の難度を調整するために N-back タスクを採用した。N-back タスクは、短期作業記憶の研究で使用されてきた作業記憶タスクである[6]。負荷係数 N を調整することにより、視覚刺激の物理的特徴を維持しつつ、認知作業負荷の程度を調節することが可能である。本研究では、負荷係数 N を調整することで、N-back タスクによって引き起こされる脳波記録 (EEG: Electroencephalogram) を用いて SEP 変調を調べた。

参加者には、一定の体性感覚刺激を与えながら、異なる作業負荷を与えると予想される 3 種類の N-back タスクである 0-back タスク、1-back タスク、2-back タスクを実施した。また、SEP を誘発するために、1Hz の電流刺激を使用した。本稿では、SEP を指標として用いることができるかどうかを、タスクの難易度を調整できる N-back タスクを行っている被験者の脳波を解析し評価した。

連絡先: 千葉晃一, 上智大学理工学専攻情報学領域,
 〒120-0001 東京都足立区大谷田 3-12-23 ライオンズプラザ
 北綾瀬 1025 号, 080-2055-3191, chiba@yairilab.net

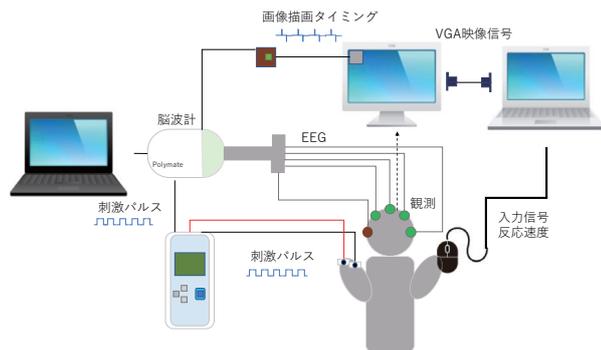


図1 実験システムの概要図

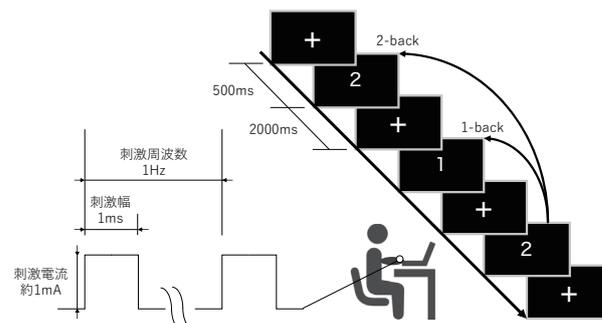


図2 視覚刺激及び触覚的な反復電流刺激の概要図

2. 実験デザイン

2.1 参加者

実験に協力した参加者は12名の健康な日本人(男性12名, 年齢20~25歳)である。すべての参加者は正常な体性感覚および正常または矯正された正常視力を有していた。参加者には、実験手順の説明をした後、書面による同意を得た。本研究は上智大学『人を対象とする研究』に関する倫理委員会の承認を受けている。2名の参加者は健康状態に異常があったため分析から除外する。

2.2 実験システム概要

実験システムの概要図を図1に示す。本研究はSEPを観測するために、実験イベント(主に刺激提示タイミング)をミリ秒(ms)単位で取得する必要がある。そのため、脳波計の外部入力端子にポータブル型の定電流刺激装置のトリガ信号を入力した。また、画像の描画タイミングを見るためにモニターの左上にフォトディレクタを設置した。実験イベントの開始と終了のタイミングを提示画像の左上の色変化で示し、それをフォトディレクタで検出した。そして、脳波計の外部入力端子に検出した画像の描画タイミングを入力した。参加者にはマウスクリックによってN-backタスクの解答を入力してもらった。

2.3 実験機器

脳波計測には、32chEEGシステム(Polymate Mini AP108)とアクティブ電極(AP-U040(A) ミュキ技研)を用いた。電極は、CP4, CP6, TP8に設置した。参加者は頭頂を計測しマークした後、Czに位置を合わせて脳波キャップ(g.GAMMAcap g.tec medical engineering)を被せCP4, CP6, TP8をマークした。その後、皮膚前処理剤(Nuprep イーストメディック)を用いて、頭皮を研磨することで皮膚インピーダンスを低下させた後、脳波・筋電図用ペースト(エレフィックス Z-181JE(チューブ入) NIHON KOHDEN)を用いてアクティブ電極を固定した。すべての信号は、左乳様突起を基準電極、右乳様突起をグラウンドとした。

体性感覚刺激には、ポータブル型定電流刺激装置(USE-00 株式会社ユニークメディカル)を用いた。当装置は、刺激幅1.0ms, 刺激周波数1.0Hz, 刺激波形位相モノフェージックの定電流刺激を提示可能である。参加者はウェットティッシュ(天然アルコール除菌 ウェットオールコーヨー化成)で左手の示指を拭き、示指に心電図電極(エールローデ SMP-300 株式会社メッツ)を付け、鱈口クリップを用いて電極とポータブル型定電流刺激装置を接続した。

視覚刺激としてのN-backタスクにはPC(MacBookPro 13-inch, 2017, Appl製), MATLAB Psychtoolbox(MathWorks製), スタンダードモニター(FlexScan L761T-C EIZO製)を用いた。視覚刺激のための画像はVideo Graphics Array映像信号により提示され、椅子に腰かけた参加者が、90~100cm離れた場所から観測した。

2.4 実験手続き

はじめに、実験参加者に対して、体性感覚刺激としての触覚的な反復電流刺激(以降、電流刺激と略記)を与える間に、視覚刺激としてのN-backタスクを実行してもらうという説明を行った。電流刺激及び視覚刺激の概要図を図2に示す。まず、参加者にCP4, CP6, TP8のEEG計測のため、頭部に電極を取り付けた。最初に参加者の頭頂(Cz)を測定計測した後、Czを基準として脳波キャップ(g.tec, g.GAMMAcap)を着用し、CP4, CP6, TP8をマークした。その後、CP4, CP6, YP8に導電性ペーストを塗りアクティブ電極を装着した。脳波データのサンプリング周波数は1kHzとした。

次に、電流刺激のため参加者の左手の示指にポータブル定電流刺激装置を取り付け、電流の強さを0.1mAから0.1mAずつ数値を上げながらそれぞれ30秒(s)間の刺激提示を繰り返し、個々の参加者の感覚閾値を探索した。参加者には以降の実験中、電流刺激を無視するよう指示した。参加者がN-backタスクを実行している間、常に1Hzの間隔で感覚閾値の3倍電流刺激を提示し、EEGを記録した。

すべてのN-backタスク実験で、我々は500ミリ秒(ms)の間、スクリーン上に「1」または「2」の文字(それぞれ50%の割合)をランダムに提示するタスクを100回ずつ試行した。各試行の間には2000ミリ秒(ms)の間、固定点(有する空白の画像)を提示した。N-backタスクは、0-back, 1-back, 2-backの順に実行した。それぞれのタスクは250秒(s)行われた。0-backタスクでは、参加者は視覚的判別を行った。具体的には、参加者は対応するボタンを押して画面に提示されている現在の番号を解答した。1-および2-backタスクでは、参加者は、現在の番号が以前のN個の番号と一致するかどうかを解答した。参加者は、右手の人差し指または中指を使用してボタンを押した。本実験は、0-back, 1-back, 2-backの順に実行された。すべての参加者は実験開始前に説明を受け、練習テストを行った。

2.5 脳波解析

データ解析ソフトとして MATLAB(MathWorks 製)を用いた。はじめに、計測された連続データに対して FIR バンドパスフィルタ(5-100Hz)をかけた。さらに、電源ノイズを除去するためにバンドストップフィルタ(50Hz)をかけた。次に刺激に対する脳電位を、加算平均法を用いて抽出した。加算平均法とは、脳波データを、事象にそろえて整列させ、データポイント毎に加算平均する方法である。データポイントとは、サンプリング周波数を用いてサンプリングしたポイントごとのデータのことである。[7]。

今回はポータブル型の定電流刺激装置からのトリガデータからオンセットタイミングを抽出した。トリガタイミングからデータの切り出しを-200 ミリ秒(ms)~1000 ミリ秒(ms)の間で行い、データポイント毎に加算平均を行った。ベースライン補正は切り出したデータの範囲の平均値で行った。

3. 結果

実験参加者はそれぞれ participant1~10 とした。各実験参加者の電流刺激の強さを表 1 に、各タスクの正答率を表 2 に、反応時間を表 3 に示す。トリガデータからトリガタイミングを抽出し、データを切り出してデータポイント毎に加算平均した全実験参加者の加算平均波形を図 3 に示す。データポイントは 1000 ポイントあり、250 秒の計測データなので、約 250 回の加算を行っている。

N9 に関する t 検定の結果を表 4-6 に示す。両側検定の p 値がそれぞれ 0-1back の t 検定では 0.0048、0-2back t 検定では 0.0005、1-2back t 検定では 0.0025 である。しかし、複数回繰り返された検定では、全体において帰無仮説が棄却される可能性である familywise error rate を補正する必要が出てくる。

私たちは、非常に保守的な familywise error rate の調整法である Bonferroni 法で補正をかけた。検定総数が 3 なので、それぞれの検定の有意水準を 5%から $5/3=1.666\dots$ に変更する。つまり、有意水準を $0.05/3 = 0.0166\dots$ に変更する。そのようにしても、両側検定の p 値がそれぞれ 0-1back の t 検定では 0.0048、0-2back の t 検定では 0.0005、1-2back の t 検定では 0.0025 であるため、すべてにおいて有意差があることを示している。

表 1 実験参加者の電流刺激の強さ

刺激強度	感覚閾値(mA)	呈示強度(mA)
Participant1	0.9	2.7
Participant2	0.8	2.4
Participant3	0.7	2.1
Participant4	1.0	3.0
Participant5	0.8	2.4
Participant6	0.6	1.8
Participant7	0.8	2.4
Participant8	0.9	2.7
Participant9	0.7	2.1
Participant10	0.8	2.4
Average	0.8	2.4

表 2 実験参加者のタスク毎の正答率

正答率	0back(%)	1back(%)	2back(%)
Participant1	100	96	85
Participant2	99	97	85
Participant3	98	93	90
Participant4	98	97	92
Participant5	97	82	73
Participant6	100	87	89
Participant7	100	94	97
Participant8	100	98	98
Participant9	100	96	91
Participant10	98	89	62
Average	99.0	92.9	86.2

表 3 実験参加者のタスク毎の反応時間

平均解答時間	0back(sec)	1back(sec)	2back(sec)
Participant1	0.409	0.642	1.165
Participant2	0.460	0.647	1.218
Participant3	0.565	0.748	1.136
Participant4	0.352	0.369	0.487
Participant5	0.486	0.853	0.999
Participant6	0.338	0.568	0.636
Participant7	0.435	0.702	0.742
Participant8	0.328	0.495	0.641
Participant9	0.434	0.666	1.043
Participant10	0.465	0.861	1.055
Average	0.427	0.655	0.912

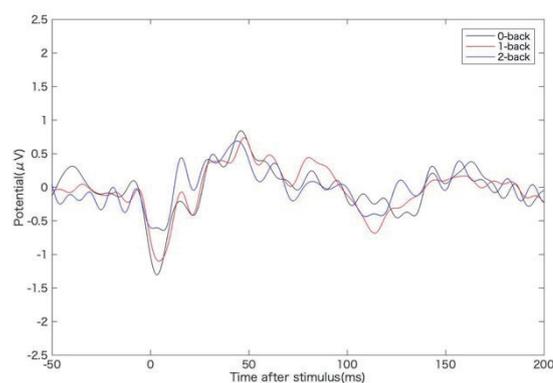


図3 全実験参加者の加算平均波形

表 4 N9 に関する 0-1back の t 検定の結果

	0-back	1-back
平均	-1.502	-1.259
分散	0.1376	0.1581
観測数	10	10
ピアソン相関	0.8574	
仮説平均との差異	0	
自由度	9	
t	-3.713	
P(T<=t) 片側	0.0024	
t 境界値 片側	1.8331	
P(T<=t) 両側	0.0048	
t 境界値 両側	2.2622	

表 5 N9 に関する 0-2back の t 検定の結果

	0-back	2-back
平均	-1.502	-0.934
分散	0.1376	0.0738
観測数	10	10
ピアソン相関	0.4911	
仮説平均との差異	0	
自由度	9	
t	-5.355	
P(T<=t) 片側	0.0002	
t 境界値 片側	1.8331	
P(T<=t) 両側	0.0005	
t 境界値 両側	2.2622	

表 6 N9 に関する 1-2back の t 検定の結果

	1-back	2-back
平均	-1.259	-0.934
分散	0.1581	0.0738
観測数	10	10
ピアソン相関	0.7874	
仮説平均との差異	0	
自由度	9	
t	-4.136	
P(T<=t) 片側	0.0013	
t 境界値 片側	1.8331	
P(T<=t) 両側	0.0025	
t 境界値 両側	2.2622	

4. 考察

全体の正答率と解答時間から 0-back, 1-back, 2-back とタスクの難易度に応じて正答率が低下し, 反応時間が増加していることがわかる. このことから, 物理的な刺激を一定に保ちながらタスクの難易度を変えることができたといえる. 全被験者の加算平均波形から本実験で注目していた体性感覚誘発電位の N9 を観測することが出来, また, 0-back, 1-back, 2-back と段階的に N9 の振幅が小さくなっていくように見られた. Bonferroni 法で補正をかけた t 検定でも, 両側検定の p 値から, すべてにおいて有意差があることが示されている.

上記のことから, 体性感覚誘発電位の N9 成分の振幅は作業の難易度と反比例することが考えられる. このことから, 体性感覚誘発電位の N9 を作業負荷の推定指標とする手法の実現可能性を示せた.

5. おわりに

本稿では, 体性感覚刺激によって誘発される体性感覚誘発電位を作業負荷の推定指標とする手法の解明のため, 12 名の健康な被験者を対象に, 体性感覚刺激としての電流刺激を呈示しつつ N-back タスク実行中の脳の活動を測定し, 10 名のデータを用いて分析を行った. その結果, 体性感覚誘発電位の成分の一つである N9 に注目した場合, 0-1back, 0-2back, 1-2back 間のすべてにおいて Bonferroni 法で補正をかけた t 検定を行い有意差が見られた. 今回の分析で, 体性感覚誘発電位を作業負荷の推定指標とする手法の実現可能性を示せた.

今後の展望として, あらかじめ作業負荷を与えたときの実験参加者ごとの加算平均波形と, 事象とは無関係に生じる背景脳波を抽出する. その後, 加算平均波形を学習データとしてモデルを作成し, 測定中の脳波データから背景脳波を取り除きつつ, 画像認識を行うことで, リアルタイムに作業負荷の推定を行っていきたいと考えている.

参考文献

- [1] 八谷百合子, et al. 独立成分分析を利用した VDT 入力作業時の疲労の評価. ITヘルスケア誌, 2008, 2.2: 66-79.
- [2] MESHKATI, N.; HANCOCK, P. A. (ed.). Human mental workload. Elsevier, 2011.
- [3] SHERIDAN, T. B.; STASSEN, H. G. Definitions, models and measures of human workload. In: Mental Workload. Springer, Boston, MA, 1979. p. 219-233.
- [4] YOKOTA, Yusuke, et al. Estimation of Human Workload from the Auditory Steady-State Response Recorded via a Wearable Electroencephalography System during Walking. Frontiers in human neuroscience, 2017, 11: 314.
- [5] 尾崎勇; 橋本勲. 体性感覚誘発電位と体性感覚誘発脳磁場の最近の進歩. 臨床神経生理学, 2012, 40.1: 19-28.
- [6] OWEN, Adrian M., et al. N-back working memory paradigm: A meta-analysis of normative functional neuroimaging studies. Human brain mapping, 2005, 25.1: 46-59.
- [7] 入戸野: 心理学のための事象関連電位ガイドブック, 北大路書房, 第1章 p10 2005.

複雑音と教師なし学習を用いたマウス大脳皮質聴覚野の領野分割

Area segmentation of mouse auditory cortex using complex sounds and unsupervised learning

寺島 裕貴 *¹ 塚野 浩明 *² 古川 茂人 *¹
Hiroki Terashima Hiroaki Tsukano Shigeto Furukawa

*¹NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, NTT Corporation

*²新潟大学 脳研究所
Brain Research Institute, Niigata University

It is controversial how to segment functional areas of the mouse auditory cortex. Previous studies had two biases: (1) they used only limited types of synthetic stimuli and (2) they selected candidate acoustic features in advance. To address the issues, we recorded cortical responses to a set of naturalistic complex sounds and analyzed them using machine learning techniques with no explicit hypothesis about acoustic features. Cortical responses obtained by calcium imaging and 165 sounds were decomposed into major five components by applying a matrix decomposition technique that was originally proposed for a human fMRI study. By comparison with classic tonotopy and regression by acoustic features, we identified functional areas that correspond to areas called AAF, A1, A2, DA, DM, and DP. Moreover, we found a new functional area outside the classical auditory cortex.

1. はじめに

わたしたちが音を聴いているとき、耳に到達した音波は神経活動に変換されて、聴覚神経系で階層的に情報処理が行われていく。その中で特に高次の情報処理は大脳皮質の聴覚野が担っており、聴覚野はさらに複数の機能的領野に分かれている。それら領野の階層的な情報処理を調べるための基盤として、聴覚野の領野構成を明らかにすることは重要な意味を持つ。

マウスは、遺伝的操作の容易さ等から近年の哺乳類における神経科学の中心的存在である。マウスの聴覚野がどのような領野から構成されているかについて、近年議論が起きている。かつては電気生理学的な単一ユニット記録を基に、周波数地図(トノトピー)がある A1, AAF の周辺に、非トノトピック領域として A2, UF, DP が定義されていた [Stiebler 97]。ところが近年になってイメージング技術が発展し、かつての定説とは異なる領野分けが提案され始めており [Guo 12, Issa 14, Tsukano 15, Tsukano 17b, Issa 17], 広い合意がない状況である [Tsukano 17a]。

従来のマウス聴覚野の領域分け研究には、2つの問題があった。第1に、脳活動を取得するための音刺激が、限られた種類の合成音(主に純音とFM音)に留まっていた。第2に、解析手法にも研究者の仮説が強く反映されており、注目する音響特徴量を事前に絞りこんでしまっていたため、重要な情報を無視している可能性があった。

これら2つの問題を解決するため、本研究では、自然音と同程度に複雑な音に対する聴覚野活動を測定し、特段の仮説を設けずに機械学習技術を用いた領域同定を試みた。複雑音セットに対する脳活動をカルシウムイメージングで広域取得し、行列分解で5つのコンポーネントに分解した。過去の研究が提案していた AAF, A1, A2, DA, DM, DP と概ね対応する領域を確認し、さらに、DAの外側に潜在的な新領域が存在する可能性も明らかになった。

2. 手法

2.1 動物と倫理的配慮

実験のプロトコールは新潟大学動物実験倫理委員会の許可を得ている。全てのデータは、Emx1-Cre driver mouse と GCaMP8-flox mouse を掛け合わせて得られたオスのマウス産仔を7~10週齢で観察したものである。

2.2 聴覚野のカルシウムイメージング

マウスをウレタン (1.7 g/kg ip; Wako, Osaka, Japan) で十分に麻酔し、実験中は体温を約 37°C としてパラフィンで頭蓋骨の透明を維持した。青色励起光 ($\lambda = 470\text{--}490\text{ nm}$) を右聴覚野に照射し、GCaMP 蛍光 ($\lambda = 500\text{--}550\text{ nm}$) を冷却 CCD カメラ (AQUACOSMOS with ORCA-R2 camera; Hamamatsu Photonics, Hamamatsu, Japan) で取得した。128 × 168 ピクセルの画像 (2.6 × 3.4 mm or 4.2 × 5.5 mm) を 9 or 10 Hz で取得した。

2.3 音刺激

自然音を含むような複雑な統計性を保った音をマウスに聴かせるために、ヒト向けに用意された自然音 165 種データセット [Norman-Haignere 15] を 250 kHz でリサンプリングし、4 オクターブ上方にピッチシフトさせた。また、過去の研究と比較するため、8種の周波数 (1.5, 2, 3, 6, 12, 24, 48, 64, 96 kHz) の純音に対して2種類の振幅変調 (20, 40 Hz) を適用した音刺激も用いた。

2.4 音刺激の呈示

2秒の刺激音を5秒間隔でランダムに呈示し、各刺激につき約 20 trial 取得した。全ての音は、マウスの 10 cm 手前に置いた同一のスピーカー (SRS-3050A; Stax, Saitama, Japan) から呈示した。周波数が 50 kHz 以上に限られる AM 純音は高周波対応のスーパーツイーター (ES105A; Murata, Kyoto, Japan) から出した。音圧はマイクロフォン (types 4135 and 2669; Brüel & Kjær, Nærum, Denmark) と音圧計 (type 2610; Brüel & Kjær) で 60–70 dB SPL に調整した。

2.5 脳活動画像の前処理

刺激音の onset 直前 1 秒間のフレーム平均蛍光量 F_0 をベースラインとし、音 onset 後 2 秒間のフレーム平均蛍光量 F のベースラインに対する相対増分 $\Delta F/F_0$ を、該当トライアルの脳活動とした。解析では全トライアル平均を用いた。

連絡先: 寺島裕貴, NTT コミュニケーション科学基礎研究所, 〒243-0198 神奈川県厚木市森の里若宮 3-1, teratti@teratti.jp

個体間の位置合わせは、165種複雑音に対する脳活動の相関が最大化するよう affine 変換を用いて行った。

2.6 教師なし学習を用いたコンポーネント分割

複雑音に対する脳活動をもとに脳領域を分割するための手法として、ヒト fMRI 向けに提案された教師なし行列分解法を用いた [Norman-Haignere 15]. 取得した脳活動は、巨大な行列 D (165種 \times 21504ピクセル) として考えることができる。この行列を、ピクセル数に比べて十分に少ない N 個のコンポーネントの重ね合わせとして近似することを考える。すなわち、 $D \sim RW$ 。ただし、ここで R, W の次元はそれぞれ、(165種 $\times N$)、($N \times 21504$ ピクセル) である。 W の各行のネグトロピー (非ガウス性) を最大化するような回転行列を求めて R, W を決定した。計算には論文著者らによる実装を用いた。

分割するコンポーネントの個数 N は、文献 [Norman-Haignere 15] 類似の方法で決定した。交差検証法のように、まず1個体を hold out した状態で行列分解を行った。Hold out しておいた個体の全トライアルをランダムに2分割し、それぞれの平均活動を学習した基底に射影したものの同士の相関が最大になるように N の値を選択した。

3. 結果

3.1 複雑音に対する脳活動の計測

まず、マウスにとって十分複雑で自然音に似た音刺激を用意した。ヒト用に構築された自然音 165種データベース [Norman-Haignere 15] を基に、マウスの可聴域に合わせるため、ピッチを上方に4オクターブシフトした複雑音を準備した。この複雑音をマウスに対して呈示し、聴覚野全体の活動をカルシウムイメージングで取得した。

3.2 脳活動の仮説フリーなコンポーネント分解

前節で得られた165種の刺激に対する応答に対して機械学習手法を適用して分割を試みた。適用した手法は、ヒト fMRI 研究で提案された行列分解法である [Norman-Haignere 15]。コンポーネント数 N は原論文に類似の指標を用いて決定し、8個体のデータから $N = 5$ を選択した。

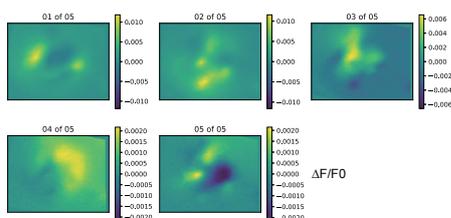


図1 コンポーネント5個の空間パターン

図1に全個体のデータを $N = 5$ 個のコンポーネントに分割した際の空間パターンを示す。空間的に局在した興奮と抑制のパターンが得られていることがわかる。

3.3 領野同定：トノトピーとの比較

前節で得られた空間的な活動パターンが過去に提案された領野分けとどのように対応するのか調べるため、振幅変調をかけた純音刺激に対する応答も調べた。図2に、各コンポーネントをトノトピーと重ね合わせた結果を示す。トノトピーの低周波領域を黒で、高周波領域を白で半透明に重畳している。

いくつかのコンポーネントは、過去に提案された領域とよく対応していた。コンポーネント1はA1, AAFの低周波領域によく対応している。コンポーネント2はA2を中心としてA1高周波, AAF高周波と対応している。コンポーネント5はA1高周波とDM高周波によく対応している [Tsukano 15]。コン

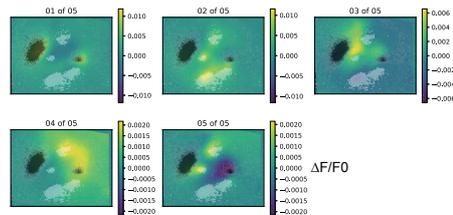


図2 コンポーネント5個とトノトピーの関係

ポーネント3は非トノトピックだが、A1, AAF, A2との相対的な位置関係から、DA, DPおよびA1の中周波領域だと考えられる。コンポーネント4は過去に単独領域としては指摘されていない新規領域と思われ、より詳細な機能の解析が待たれる。これらの結果は、自然様の複雑音に対する脳活動の仮説フリー解析が、マウス聴覚野の機能的構造の解明に貢献できることを示している。

参考文献

- [Guo 12] Guo, W., Chambers, A. R., Darrow, K. N., Hancock, K. E., Shinn-Cunningham, B. G., and Polley, D. B.: Robustness of cortical topography across fields, laminae, anesthetic states, and neurophysiological signal types, *Journal of Neuroscience*, Vol. 32, No. 27, pp. 9159–9172 (2012)
- [Issa 14] Issa, J. B., Haeffele, B. D., Agarwal, A., Bergles, D. E., Young, E. D., and Yue, D. T.: Multiscale optical Ca²⁺ imaging of tonal organization in mouse auditory cortex, *Neuron*, Vol. 83, No. 4, pp. 944–959 (2014)
- [Issa 17] Issa, J. B., Haeffele, B. D., Young, E. D., and Yue, D. T.: Multiscale mapping of frequency sweep rate in mouse auditory cortex, *Hearing research*, Vol. 344, pp. 207–222 (2017)
- [Norman-Haignere 15] Norman-Haignere, S., Kanwisher, N. G., and McDermott, J. H.: Distinct cortical pathways for music and speech revealed by hypothesis-free voxel decomposition, *Neuron*, Vol. 88, No. 6, pp. 1281–1296 (2015)
- [Stiebler 97] Stiebler, I., Neulist, R., Fichtel, I., and Ehret, G.: The auditory cortex of the house mouse: left-right differences, tonotopic organization and quantitative analysis of frequency representation, *Journal of Comparative Physiology A*, Vol. 181, No. 6, pp. 559–571 (1997)
- [Tsukano 15] Tsukano, H., Horie, M., Bo, T., Uchimura, A., Hishida, R., Kudoh, M., Takahashi, K., Takebayashi, H., and Shibuki, K.: Delineation of a frequency-organized region isolated from the mouse primary auditory cortex, *Journal of neurophysiology*, Vol. 113, No. 7, pp. 2900–2920 (2015)
- [Tsukano 17a] Tsukano, H., Horie, M., Ohga, S., Takahashi, K., Kubota, Y., Hishida, R., Takebayashi, H., and Shibuki, K.: Reconsidering tonotopic maps in the auditory cortex and lemniscal auditory thalamus in mice, *Frontiers in neural circuits*, Vol. 11, p. 14 (2017)
- [Tsukano 17b] Tsukano, H., Horie, M., Takahashi, K., Hishida, R., Takebayashi, H., and Shibuki, K.: Independent tonotopy and thalamocortical projection patterns in two adjacent parts of the classical primary auditory cortex in mice, *Neuroscience letters*, Vol. 637, pp. 26–30 (2017)

神経修飾を用いたニューラルネットワークによるメタ記憶の進化

Creating metamemory by evolving artificial neural network with neuromodulation

大和 祐介 鈴木 麗璽 有田 隆也
Yusuke Yamato Reiji Suzuki Takaya Arita

名古屋大学 大学院情報学研究科
Graduate School of Informatics, Nagoya University

Human have the ability to consciously aware of the presence or absence of their memory. This kind of the ability called metamemory plays important roles in human cognition. We aim to evolve artificial neural networks with neuromodulation, that have a metamemory function. Our constructive approach is based on the repetition of evolutionary experiments, analysis of the evolved networks and refinement of the measure, so as to reducing the gap between the functional properties of behavior and subjective reports of phenomenal experience. This paper reports on the current state of the approach based on the evolutionary experiments with a delayed matching-to-sample task.

1. 序論

本研究の目的は構成論的アプローチによってメタ記憶能力を持つニューラルネットワークを進化させることである。ヒトは自分の記憶に特定の知識が存在するか、その記憶がどれ程の確かさであるかを認知できる。このような自らの記憶に対する主観的な認知能力であるメタ記憶は、ヒト固有の特徴と見なされており [1], メタ認知の一種として広く研究されてきた。我々は、この目的のために、Evolutionary Plastic Artificial Neural Networks (EPANN) [2] を用いる。これは、可塑的なニューラルネットワークを進化によって創発させることにより、学習システムをデザインし、創り出す計算論的アプローチであり、生物の知性が進化、発達、学習の相互作用によって創発したという事実にそのアイデアの源泉がある。

本研究は認知・行動プロセスにおける必須要素として知られている神経修飾を使用する。これは修飾ニューロンによってニューロン間結合の可塑性を動的に変更するものである [3]。さらに、ある種の進化戦略 [4] を用いて、神経修飾を用いたニューラルネットワークのトポロジーと結合重みを進化させることにより、ターゲットとする認知機能、メタ記憶を自動的に生成することを狙う。すでに我々は予備的実験により、そのようなアプローチによって進化させたネットワークがサルを対象に開発された遅延見合わせ課題 (DMTS) に基づくメタ記憶の行動主義的な基準を満たすことを示している [5]。

しかし、メタ記憶はそれほど単純なものではない [6]。なぜならば、動物の行動を観察するだけで自分の記憶を監視できると結論づけることは非常に難しいからである。たとえ、ヒトを用いた被験者実験でさえも、最新の技術を用いて脳活動を計測するだけで主観的な認知能力を同定することは簡単ではない。そもそも、その難しさはメタ記憶の定義自体にも依存する。ただし、我々のアプローチのように人工的なニューラルネットワークの進化を用いる場合は、生物を扱う場合とは違い、原理的にはニューラルネットワークで起こるすべてのプロセスのメカニズムを理解することができるという強みがある。

本研究は、先行研究 [5] を出発点とし、進化させたネットワー

クを批判的に分析し、メタ記憶とは異なるようなメカニズムに基づいているネットワークが進化することを排除するようにメタ記憶の基準を改訂する。このような進化実験、進化したネットワークの分析、メタ記憶の基準の改訂を繰り返していくことにより、真のメタ記憶の実現に近づけていく。

2. 方法論

2.1 メタ記憶の尺度

Hampton は、アカゲザルを対象とした遅延見合わせ課題を考案した。動物に対するメタ記憶実験には回避応答パラダイムと情報探索パラダイムがあり、彼の実験は前者に属する。まず、サルはあるイメージを記憶する。その後、設定した遅延時間を経て、テスト (4つのイメージから記憶した1つを選択する) を受けるか回避するかを選択する。ただし、一定の確率で選択させずに強制的にテストを受けさせる。テストでは記憶したものと同一イメージを選択した場合、高品質の報酬を受け取るが、それ以外の場合は何も受け取れない。回避した場合には中程度の報酬を受け取る。メタ記憶を持つならば、選択して受けた場合と強制されて受けた場合の正解率を比較すると前者の方が高く、また、遅延時間の増加に従ってその差は大きくなるはずである。Hampton はサル1匹がこの基準を満たすことを示した [7]。

近年、動物の認知に関する研究が盛んであり、様々な議論がなされている。特にメタ記憶に関する動物実験に対する批判は記憶しているかどうかの主観的な認知をヒトを使った実験でのアンケート調査等によらずに、動物の行動のみから推測している点にある。生物の主観的な体験ではなく、メタ記憶を持っているならばするはずの行動を調べている点である。Hampton の実験においても記憶の有無に関わらず難しいイメージを固定的に回避して報酬を最大化することでクリア可能と言える [6] [8]。我々は、行動の機能と主観的な体験の間に存在するギャップを埋めるため、メタ記憶の定義、進化実験、進化したネットワークの分析、基準の改訂、…という反復に基づく構成論的アプローチにより真のメタ記憶を持つニューラルネットワークの進化を目指す。

- 行動基準

Hampton の実験パラダイムで、選択条件と強制条件のテ

連絡先: 大和祐介, 名古屋大学 大学院情報学研究科 複雑系科学専攻, 〒464-8601 名古屋市中千種区不老町, 080-2712-4721, yamato@alife.cs.is.nagoya-u.ac.jp

ストの正答率に差が生じる。

- ニューラル基準 1

行動基準を満たすが、これが入力のみに基づくものではない。

以降、この定義に基づき進化実験と分析を行う。

2.2 タスク

進化実験に用いるタスクは、Hampton の実験 [7] に基づく。まず、個体は学習フェーズで 5 桁のビットからなるパターン (00001, 00010, 00100, 01000, 10000) のうち 1 つを正解として受け取る。次に、遅延フェーズでノイズとして複数回 00000 のパターンを受け取る。その後、選択フェーズへと移行する。この時、確率 2/3 で選択条件、確率 1/3 で強制条件となる。選択条件では、個体はテストの選択を指示する入力を受けて、受けるか回避するか選択する。回避を選択すると得点 0.3 を受け取る。一方、強制条件の場合、テストフェーズへ移行する。テストフェーズでは、全パターンがランダムな順に入力される。正解と同じパターンが入力された時に解答を選択した場合、個体は得点 1.0 を得る。それ以外の場合は得点を得られない。なお、学習フェーズでは確率的に正答不能パターン (00000) を含める。これは、回避選択が最適行動である状況を作り出して回避選択能力の進化を促すためである。遅延量 N_{delay} の大きさはべき分布に従う乱数は以下の式 (1) で定める。

$$N_{delay} = \lfloor \frac{-1}{\lambda \times \ln(R)} \rfloor + 1, \quad (1)$$

ここで、 λ は分布の形状に関するパラメータ、 R は $[0, 1]$ の範囲の一様乱数である。以上のタスクを複数回行い、得点の合計値を個体の適応度とする。

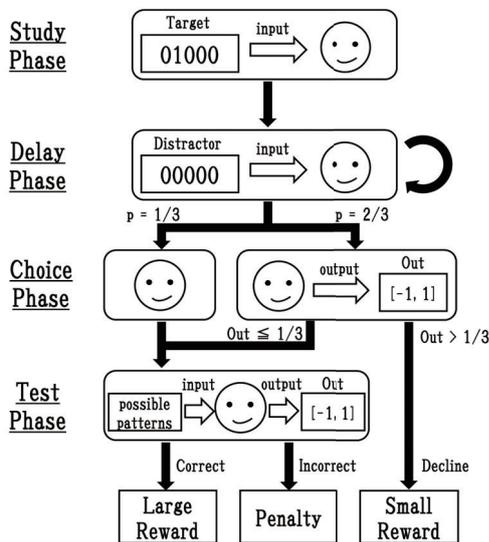


図 1: Hampton の実験パラダイムに基づくタスクの流れ。

2.3 モデル

個体は神経修飾を導入したニューラルネットワークを持つ。ニューロンとして、7つの入力ニューロン以外は、可変個数の標準ニューロン (内、3つが出力ニューロン) と修飾ニューロンである。入力、パターンの各ビット、選択条件の指示、バイアスであり、それぞれガウシアンノイズ (σ, μ) を加算した

ものが入力される。修飾ニューロンは、標準ニューロンとは異なり、ニューロンの出力値をネットワークの結合重みの更新率とすることにより、結合重みの更新の可塑性 (学習率) を動的に変更する。標準ニューロン i の活性 a_i は式 (2)、修飾ニューロン i の活性 m_i は式 (3) によって計算する。

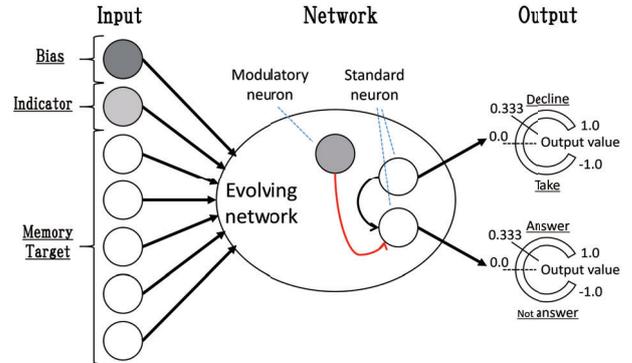


図 2: ニューラルネットワークの入力と出力。

$$a_i = \sum_{j \in Std} w_{ji} \cdot o_j \quad (2)$$

$$m_i = \sum_{j \in Mod} w_{ji} \cdot o_j, \quad (3)$$

ここで、 w はシナプス前ニューロン j とシナプス後ニューロン i の結合重み、 Std および Mod はニューロン i に結合している標準ニューロンと修飾ニューロンの集合である。 o_j はニューロン j の出力であり、 $o_j = \tanh(a_j)$ として計算される。ニューロン j と i 間の結合重みは以下の式によって更新する。

$$\Delta w_{ji} = \tanh m_i \cdot \eta \cdot (A o_j o_i + B o_j + C o_i + D), \quad (4)$$

o_j と o_i はシナプス前ニューロン j とシナプス後ニューロン i の出力である。 η, A, B, C, D は進化可能なパラメータであり、進化によって多様な更新規則を表現することができる。

ネットワークの構造や結合重みは進化戦略により進化させる。アルゴリズムは基本的に Soltoggio らの手法 [3] と同じである。遺伝子座として、ニューロン数、ニューロンの種類、2次元の結合重み行列、結合重みの更新規則に関する 5 パラメータを持つ。結合重みとパラメータ A, B, C, D は $[-1, 1]$ 、 η は $[-100, 100]$ の範囲で進化する。遺伝子型 GhV の結合重みは、式 (5) によって初期表現型の結合重み PhV に変換される。

$$PhV = \begin{cases} 0 & (|GhV^3| < 0.01) \\ 10 \cdot GhV^3 & (otherwise). \end{cases} \quad (5)$$

親個体は、空間的な局所性を考慮したトーナメント選択によって選ばれる。各個体は配列に格納され、ランダムなオフセットを伴ったサイズ 5 の連続的なセグメントに区切られる。その後、各セグメントの最大適応度個体が親として選択され、0.1 の確率で交叉、それ以外は自身のコピーを子とする。交叉は、親集団からランダムに選択される。親同士は結合重みの部分行列と対応するニューロンを交換して子を生成する (交叉点は結合重み行列の各軸上からランダムに選択)。また、更新規則パラメータに対しては一様交叉を適用する。突然変異率は

0.1 とし、結合重みと更新規則パラメータに対して $\mu = 0.0$, $\sigma = 0.3$, (η のみ $\mu = 0.0$, $\sigma = 3.0$) のガウシアンノイズを加算する。ニューロンの挿入、複製、削除はそれぞれ 0.04, 0.06, 0.02 の確率で適用される。追加されたニューロンの種類は 0.5 ずつの確率で決定され、結合重みは $[-1, 1]$ の範囲で初期化される。このようにして N 個体が 1 世代として生成され、 G 世代繰り返される。

3. 実験結果

個体数 $N = 300$, 世代数 $G = 1000$, 課題数 $T = 300$, 正答不能課題数 $U = 20$, N_{delay} のパラメータ $\lambda = 0.7$, 最大ニューロン数を 16 とする。各試行は 300 回のタスクのうち、正当不可能課題を 20 回含む。初期世代の各エージェントのパラメータはタスクの開始時に可能な範囲内でランダムな値に設定される。

この設定で進化実験を 20 試行行った結果、17 試行で行動基準を満たす個体が進化した。分析の結果、典型的な 2 種類 (タイプ A とタイプ B) の個体を発見した。タイプ B 個体は 17 試行全てで進化した。タイプ A 個体は 17 試行中 8 試行のみ進化した。図 3, 4 はそれぞれタイプ A, タイプ B の個体の遅延変化による得点の変化を表す。両タイプとも強制条件より選択条件での正答率が高い。つまり行動基準を満たす。しかし、タイプ A は遅延時間の増加に従い回避選択率が増加したのに対し、タイプ B はほとんど変化がない。

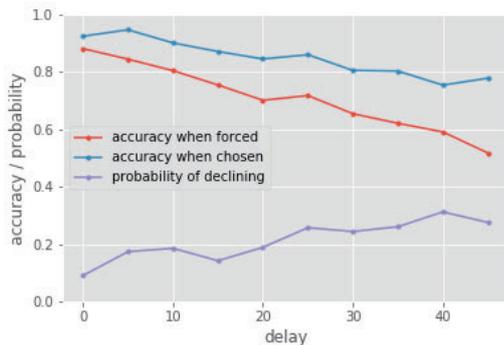


図 3: タイプ A の典型的な振る舞い (reward: 217.7).

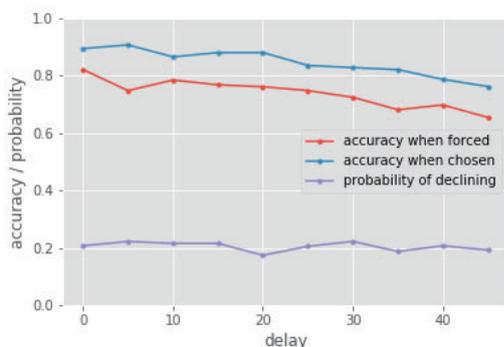


図 4: タイプ B の典型的な振る舞い (reward: 220.4).

次に、タイプ A とタイプ B の振る舞いの違いを調べた。表 1, 2 は、各パターン別の強制条件、選択条件、及び回避タスクの平均正答率を表す。回避タスクの正答率は回避したテストを

仮に解答していたとして算出した。遅延は各パターン 40 とした。タイプ A は受け取るパターンに関わらず、強制条件よりも選択条件の方が正答率が高く、回避タスクの正答率も低い。これは、正答できないテストを回避していることを表しており、ニューラル基準 1 を満たす。一方、タイプ B はパターン 01000 が入力された場合のみ回避行動を多用し、その他のパターンでは全く回避を行わなかった。これは、特定の刺激に対して回避を関連付けるような回避応答パラダイムにおいて指摘された振舞いであり、行動基準は満たすがニューラル基準 1 は満たさない個体に典型的な振る舞いである。ただし一方で、パターン 01000 についてはタイプ A と同様に記憶を忘却した課題に対して回避を選択する傾向があった。つまり個体はニューラル基準 1 を満たすものであるが、特定パターンのみに対してのみの振る舞いで満たしていると言える。

表 1: 各パターンに対するの正解率に関するデータ (タイプ A).

Bit patterns	Accuracy in forced tests	Accuracy in chosen tests (probability of taking)	Accuracy in declined tests (probability of declining)
00001	0.671	0.825 (0.756)	0.291 (0.244)
00010	0.667	0.825 (0.800)	0.172 (0.200)
00100	0.663	0.788 (0.753)	0.302 (0.247)
01000	0.689	0.809 (0.799)	0.287 (0.201)
10000	0.714	0.814 (0.787)	0.203 (0.213)

表 2: 各パターンに対するの正解率に関するデータ (タイプ B).

Bit patterns	Accuracy in forced tests	Accuracy in chosen tests (probability of taking)	Accuracy in declined tests (probability of declining)
00001	0.843	0.823 (1.0)	– (0.0)
00010	0.840	0.835 (1.0)	– (0.0)
00100	0.794	0.789 (1.0)	– (0.0)
01000	0.448	0.729 (0.436)	0.294 (0.564)
10000	0.758	0.770 (1.0)	– (0.0)

次に、タイプ A のネットワーク構造と振る舞いを分析する。図 5 で典型的なタイプ A のネットワーク構造を示す。ネット

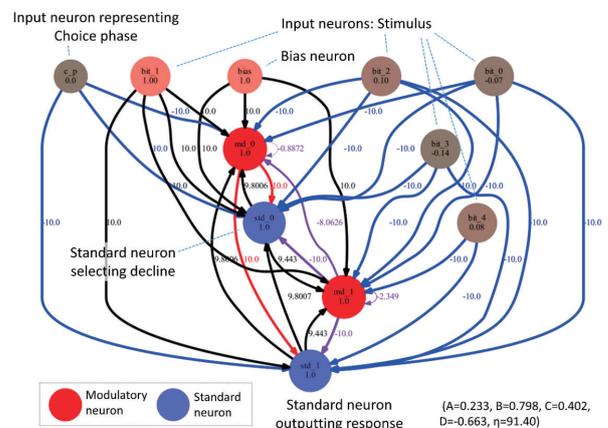


図 5: タイプ A のニューラルネットワーク.

ワークの挙動の観察により、図6のようにパターンの各ビット入力ニューロンと特定のニューロン間の結合重みでターゲットパターンの構造が保持されていることがわかった。具体的には、ターゲットパターンの1であるビットに対応する結合重みのみが正となっており、テストフェーズにおいてこの結合重みが入力に対するマスクとして働く。その結果、ターゲットパターンが入力された場合に解答を選択する。

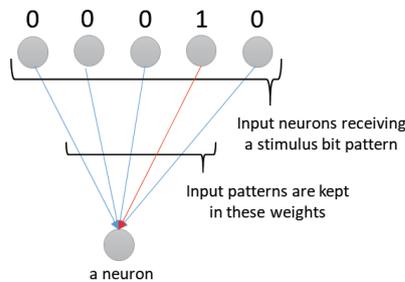


図6: ターゲットパターンの構造を反映する結合重み。

また、忘却は次のようなメカニズムによることがわかった。記憶が保たれている状態では、テスト回答ニューロンが受け取る修飾ニューロンからの出力の総和は0で、記憶を反映する結合構造は変化しない。ノイズにより修飾ニューロンの活性に変化が生じて、テスト回答ニューロンが受け取る修飾ニューロンからの出力の総和が0以外に変化すると結合重みが更新される。この更新量が大きい場合に記憶の忘却が生じる。

図7は、ネットワークの発展による時間結合重みの変化を表す。同図より、忘却が発生すると同時に周辺の結合重みも変化することで回避を選択していることがわかる。これは、修飾ニューロンによる修飾先の同時更新によるものであり、記憶の忘却原因を引き金とした受動的な性質だと考えられる。つまり、記憶のモニタのような能動的な機能として、自身の記憶を自己参照しているものではない。

4. 結論

本稿では神経修飾モデルを用いた進化実験を行ってメタ記憶の進化を調べた。我々は、メタ認知を扱う回避応答パラダイムに基づく実験の議論において指摘を受けた振る舞いを排除するために2つの基準（行動基準とニューラル基準1）を定義した。また、進化実験を行い2種類の代表的な個体を発見し、どちらもニューラル基準1を満たすことを確認した。さらに、ネットワークの構造とダイナミクスを解析し、メタ記憶の機能を獲得したネットワークの記憶の保持と忘却、記憶の忘却時にテストの回避を選択するメカニズムを明確にすることで、ニューラル基準1を満たす個体の振舞いは自身の記憶の参照に基づくものではないとわかった。

参考文献

- [1] Endel Tulving and Stephen A Madigan. Memory and verbal learning. *Annual review of psychology*, Vol. 21, No. 1, pp. 437–484, 1970.
- [2] Andrea Soltoggio, Kenneth O Stanley, and Sebastian Risi. Born to learn: The inspiration, progress, and future of evolved plastic artificial neural networks. *Neural Networks*, Vol. 108, pp. 48–67, 2018.

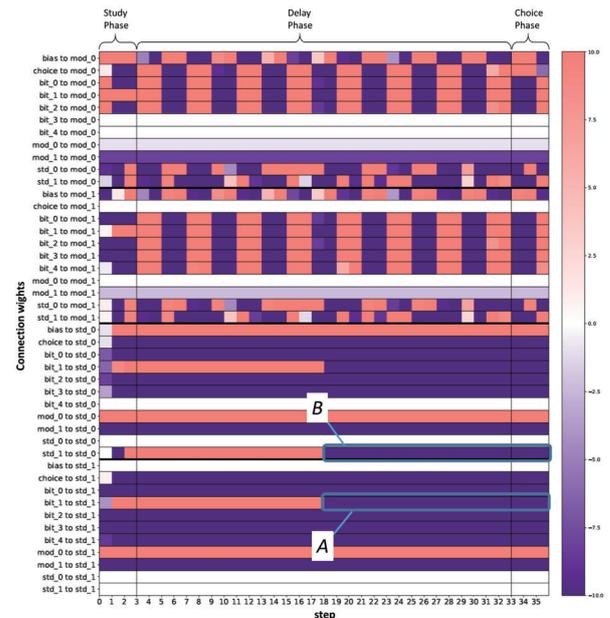


図7: ネットワークの結合重みの時間発展。ノイズにより修飾ニューロンの活性が変化しする。これにより、ビット入力ニューロンと標準ニューロンとの間の記憶を保持する結合重みが正から負へと変化(A)。これは記憶の忘却に相当。それと同時に、その他の結合重みも反転(B)。その結果、選択フェーズで回避選択を決定する標準ニューロンが活性化し回避を選択。

- [3] Andrea Soltoggio, John A Bullinaria, Claudio Mattiussi, Peter Dürr, and Dario Floreano. Evolutionary advantages of neuromodulated plasticity in dynamic, reward-based scenarios. In *Proceedings of the 11th international conference on artificial life (Alife XI)*, No. LIS-CONF-2008-012, pp. 569–576. MIT Press, 2008.
- [4] Thomas Bäck, David B Fogel, and Zbigniew Michalewicz. *Handbook of evolutionary computation*. CRC Press, 1997.
- [5] Masaru Sudo, Reiji Suzuki, and Takaya Arita. Can agents with neuromodulation know when they remember? *Proc. of the 19th International Symposium on Artificial Life and Robotics*, pp. 330–334, 2014.
- [6] Josep Call. Do apes know that they could be wrong? *Animal cognition*, Vol. 13, No. 5, pp. 689–700, 2010.
- [7] Robert R Hampton. Rhesus monkeys know when they remember. *Proceedings of the National Academy of Sciences*, Vol. 98, No. 9, pp. 5359–5362, 2001.
- [8] Jonathon D Crystal and Allison L Foote. Metacognition in animals. *Comparative cognition & behavior reviews*, Vol. 4, pp. 1–16, 2009.

[1E4-J-12] Human interface, education aid: body and its movements

Chair:Michimasa Inaba Reviewer:Yoko Nishihara

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room E (301A Medium meeting room)

[1E4-J-12-01] English Word Learning System for Children to Learn by Acting Whole Body○Kensei Yamazaki¹, Kaoru Sumi¹ (1. Future University Hakodate)

5:20 PM - 5:40 PM

[1E4-J-12-02] Tennis Training Support System using HMD and Tracking Sensor○Rintaro Nishimoto¹, Masaru Okamoto¹, Yukihiro Matsubara¹, Noriyuki Iwane¹ (1. Hiroshima City University)

5:40 PM - 6:00 PM

[1E4-J-12-03] Neural Virtual Try-On System considering 3D human model○Shizuma Kubo¹, Yusuke Iwasawa¹, Masahiro Suzuki¹, Yutaka Matsuo¹ (1. The University of Tokyo)

6:00 PM - 6:20 PM

[1E4-J-12-04] Comparison and Consideration of Appearance Positions of Model Human Processor and Readiness Potential○Nanako Shimizu¹, Toshitaka Higashino², Masato Soga¹ (1. Wakayama University, 2. Osaka University)

6:20 PM - 6:40 PM

全身で演技をすることによる英単語学習システム

English Word Learning System for Children to Learn by Acting Whole Body

山崎 健成
Kensei Yamazaki

角 薫
Kaoru Sumi

公立はこだて未来大学システム情報科学部
Future University Hakodate of System Information Science

Abstract: We developed an English verb learning system for elementary and junior high school students by acting the verb meaning on their own and showing a character's acting in the game. The students learn English verbs by listening to the pronunciation of English words, understanding the meaning, pronouncing the verb, acting on their own, and watching the character's actions that was reflected their own actions. The result shows that the system is effective for learning English verbs by conducting an experiment using elementary school sixth graders as subjects.

1. はじめに

本研究では、学習する英単語の動詞の意味を学習者が演じ、ゲーム内のキャラクタがその動作をすることで英単語を学習するシステムを開発した。

現在、世界的に共通の言語である英語の学習は子どもたちにとって必須となりつつある。日本では中学生から英語の教科が必修化されているが、文部科学省によると 2020 年には小学校で必修教科としての英語が開始される予定である。小学 3, 4 年生では英会話をし、小学 5, 6 年生では読み書きや英作文など本格的な英語学習が開始されることとなる。

しかしながら、中学生で英語学習のモチベーションを保つことができるのは約 4 割である[1]と言われている。さらに 2014 年の Benesse によるアンケート結果によると、日本の中学生の約 6 割が英語を苦手としており、苦手としている理由として約 7 割が「単語が覚えられない」とされている。

英単語を学校の授業で勉強する場合、教科書や単語帳などを用いた紙媒体テキストベースの学習方法がほとんどである。しかし、児童向け英会話塾では、実際に体を動かして英語を覚えている授業もある。英単語を覚える際には、ジェスチャを使用して説明した方が、より多く単語を覚えていることが実験で示されている[2]。このように、英単語を覚える際には、文字のみの情報より、ジェスチャやイメージを多用した方が記憶と意味を結びつけられるとされている[3][4][5][6][7][8]。

さらに、自身が動くだけではなく動きを見ることも記憶効果に影響があるとされている。固有名詞について、ジェスチャを見ながら学習するパターンとジェスチャはなく口頭のみで学習するパターンの 2 パターンで学習し、記憶成績に差があったかどうか検証した結果、ジェスチャを見ながら学習を行った方が記憶の成績が良かったが実験により示されている[9]。また、大学で教授が講義する際、身振り手振りをした場合としない場合ではどちらがより学習記憶に結び付きかを検証した結果、身振り手振りがあった方が学習結果は向上したことが実験により示されている[10]。文字のみを見たとき、絵を見たとき、ジェスチャを見たときの 3 つのパターンで、物語性のある文章を覚えた結果を比較検証した結果、文字や静止画を見た時より、ジェスチャを見た方が学習結果は向上したことが挙げられた[11]。

ジェスチャにより英語を学習するゲームとして、Leap Motion

を用いて単語を手話と共に学習し、指定された物を部屋から探し単語を学習するシステムも開発されている[12]。ここでは、主に使用するのは腕のみであり、全身を使う動きを表現できないものであった。本研究で提案システムは全身を使用して英単語を覚えるシステムである。それにより実際の単語の意味の動作を演技することができる。

本研究では、小学生や中学生を対象に、簡単に英単語を覚えられることを目的として、ジェスチャによる学習を取り入れ、学習者がその単語を学習する際に実際に演技し、演技した動きをキャラクタで再現しシステム上に提示し、それを見ながら学習するシステムを開発する。また、本システムを使用することで、学習者が英単語を覚えられるかどうかを検証する。

2. システム概要

本システムは英単語(動詞)の意味を学習者自身が演じ、演技した動きをゲーム内のキャラクタが動くことで英単語を学習できるものとなっている。

システムは全部で 3 つの画面が存在する。ランダムに英語の動詞をシステム内で表示し、意味、発音を確認する出題画面、その動詞を実際にユーザが演技し、ユーザが演技した動きが画面内のキャラクタに反映される演技画面、単語の意味を問う問題が出題される解答画面の 3 画面である。

2.1 出題画面

出題画面は、3 種類のボタンとテキストが表示される外見となっている。単語の出題方法は動詞の csv ファイルに保存された動詞をランダムに選択するものである。動詞 csv ファイルは、同じ行に左から動詞原型、意味、三人称単数形、過去形、過去分詞形、進行形となっている。選択と同時に、学習する単語の列番号を txt ファイルに保存する。3 種類のボタンはそれぞれ「意味」、「発音を聞いてみる」、「動いてみる」がある。「意味」ボタンを押すと csv ファイルからその単語の意味の部分を読み込み、発音を再生する。「動いてみる」ボタンを押すと、次のシーンへ遷移し、それと同時に Anaconda Prompt を起動させる。

2.2 演技画面

Anaconda Prompt が起動すると OpenPose と呼ばれるモーションキャプチャアプリケーションが起動する。OpenPose とは、CMU-Perceptual-Computing-Lab によって開発されたオープンソースのボーン取得システムである。動画や写真から人体を検出し、検出した人体から体の各部位の 3 次元の位置情報を出

連絡先: 山崎健成, 公立はこだて未来大学 システム情報科学部, b1015173@fun.ac.jp

力するシステムである。学校や家庭で簡単に使用できるような web カメラのみを使用してできるため OpenPose を利用した。

動きを撮り終わると図 1 のように画面にキャラクターと「勉強する」ボタンが表示される。キャラクターはユーザが直前で行った動きをするようになる。「勉強する」ボタンを押すと最後のシーンへ遷移する。



図 1 wonder(不思議に思う)を演じる学習者とキャラクター

2.3 解答画面

解答画面では画面上部に問題文、中央にはキャラクター、下部には 3 つの回答ボタンがある。問題文は「(学んだ単語)はどんな意味でしょう?」と表示されている。キャラクターは前の画面と同様にユーザから取得したモーションで動かしている。回答ボタンには正解の意味と不正解の異なる 2 つの意味の 3 つの選択肢が位置はランダムで表示されている。不正解のボタンを押すと、「残念もう一度よく思い出してね」と表示される。正解ボタンを押すと初めの画面へ遷移する。

2.4 モーションの反映

取得したユーザの動作をキャラクターに反映させる際の流れを説明する。初めに、OpenPose によってユーザの動作からボーン位置情報を含んだファイルを出力する。フレーム毎に各関節の座標が出力されている。Tensorflow を用いてそのファイルから解析データを出力する。その後、解析データを用いてモーションファイルを出力する。最後に、出力されたモーションファイルを Unity 上で動くモーションデータに変換し動作させる。

3. 実験

本研究で開発した英単語学習システムの評価を目的に地域小学校 6 年生の児童 20 人を対象として 2 週間に分けて 2 度実験を行った。実験は小学校の授業の一環として行われた。授業の流れとしては、英語の普及率など簡単な概要を学んでもらった後、アイスブレイクのため、Simon says game を行った。Simon says game とは出題者と演技者に分かれて行うゲームである。ルールとしては、出題者が「Simon says」と言ったときのみ演技者は出題者の言った動きをする。逆に「Simon says」と言わなければ演技者は出題者の言った動きをしてはいけない。Simon says game で使った単語はシステムで利用した単語とは異なるものであった。アイスブレイク終了後、実験を行った。

システム使用の流れは図 2 のように、初めに発音と意味を確認し学習者に発音をしてもらった。その後、演技をしてもらい、その動きを確認してもらった。演技を確認する際、音声や意味も一緒に提示した。最後に、クイズを解いてもらった。

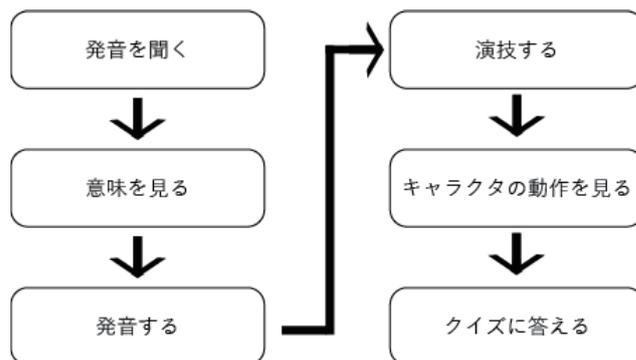


図 2 システム使用の流れ

3.1 実験 1 週目

図 3 のように験材料として、デスクトップパソコンおよびシステム、ディスプレイ 2 台、web カメラ、事前事後テスト、事後アンケートの資料を作成した。アンケートは 5 段階評価ならびに自由記述を用いて総合的に評価した。

実験手続きは、初めに事前テストを 5 分行った。次に、本システムを 20 分利用してもらった。最後に事後テストを 5 分と事後アンケートを 5 分間行ってもらった。実験は 10 人ずつ同時に行われた。これを 1 セッションとする。残りの 9 人は別室で待機してもらい、セッションが終了すると交代してもらった。初めに 10 人同時に全体の説明をし、その後、事前テストを同時に行った。次にシステムを 2 人ずつ使用してもらった。その際、操作している画面は他の 8 人も同時に見る状態になっていた。操作する 2 人は 1 人がマウス操作、もう 1 人が演技をした。これを 1 語学習する毎に交代し、1 セッション毎、3 回×5 グループで 15 回行った。最後に事後テストと事後アンケート行って実験終了とした。

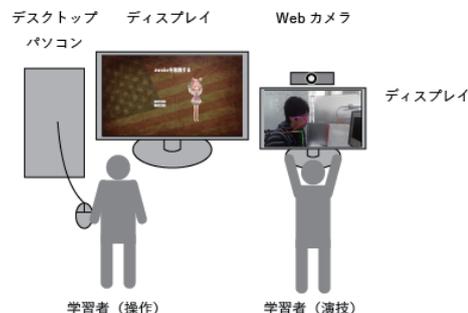


図 3 実験の様子

3.2 実験 2 週間目

実験材料は実験 1 週目と同じものを用意した。

実験手続きは、最初から本システムを 20 分(15 回)行ってもらった。最後に事後テストを 5 分と事後アンケートを 5 分間行ってもらった。実験は 10 人ずつ同時に行われた。これを 1 セッションとする。残りの 9 人は別室で待機してもらい、セッションが終了すると交代してもらった。初めに 10 人同時に全体の説明をし、

その後、事前テストを同時に行った。次にシステムを2人ずつ使用してもらった。その際、操作している画面は他の8人も同時に見る状態になっていた。操作する2人は1人がマウス操作、もう1人が演技をした。これを1語学習する毎に交代し、1セッション毎、3回×5グループで15回行った。最後に事後テストと事後アンケート行って実験終了とした。また、事後テストは1週目に使用したものの出題順を変更したものを解答してもらった。

3.3 事前事後テスト

事前事後テストは動詞の意味を語群から選択する形式の問題とした。出題する順番は位置で覚えてしまう可能性があったため毎回変更した。出題した単語は表1の通り12語とした。事前事後テストの語群は表2のように20語とした。レベルは簡単にならないよう出題した単語は中学2,3年生程度で学習する単語であり、小学6年生には少し難しい単語とした。(図4参照)

表1 出題した英単語群

Awake	climb	decide	Discuss
exercise	hurt	introduce	Realize
Shake	understand	Wonder	Worry

表2 選択肢の語群

跳ぶ	傷つける	手をたたく	座る
伸びる	蹴る	決める	実現する
歌う	目が覚める	理解する	悩ませる
紹介する	発見する	不思議に思う	話し合う
登る	わくわくする	練習する	揺すぶる

英語問題

1、英語の意味を下から選んで書いてください

(1) wonder _____

(2) shake _____

(3) introduce _____

(4) understand _____

(5) worry _____

(6) climb _____

(7) decide _____

(8) realize _____

(9) awake _____

(10) exercise _____

(11) hurt _____

(12) discuss _____

意味

跳ぶ	傷つける	手をたたく	座る
伸びる	蹴る	決める	実現する
歌う	目が覚める	理解する	話し合う
紹介する	発見する	不思議に思う	悩ませる
登る	わくわくする	練習する	揺すぶる

図4 事前事後テスト

4. 実験結果

1週間目の実験の事前事後テスト、2週間目の事後テストの結果として、テストのスコアの平均値は常に上昇していた。(図5参照) 球面性の検定より、Greenhouse-Geisserを行った結果、5%水準で有意であった。(表3参照) また、多重比較を行った結果、すべてのテスト間において5%水準で有意であった。(表4参照)

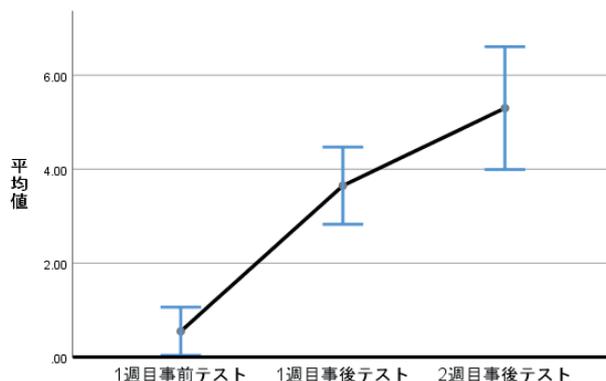


図5 平均点の推移

表3 Greenhouse-Geisser

df	MS	F	p 値	偏 η^2
1.327	175.262	51.376	0.00	0.73

表4 多重比較

	SE	p 値
1週目事前, 1週目事後間	0.261	0.00
1種目事前, 2週目事後間	0.575	0.00
1週目事後, 2週目事後間	0.53	0.017

5. 考察

本研究では英単語の意味を学習者自身が演じ、演じた動きをゲーム内のキャラクタが動く英単語学習システムを開発し、単語学習に効果があるか検証した。実際に学習者が演じて再度その動作を見る学習方法はおおむね効果があったと考えられる。

今回出題された単語は中学2,3年で学習するものであったにも関わらず、テスト結果が向上したことから本システムを使用することで英単語学習能力は向上したと考えられる。

しかし、テスト結果の上昇度合いが1週目の事前と1週目の事後の間よりも1週目の事後と2週目の事後の間の方が緩やかになっていた。また、2度の実験を行って最終的な平均点が満点である12点の半分未満という結果となった。これら結果の理由として、開発したシステムは単語毎に異なる回数出題されたためであると考えられる。1度出題されると後はランダムになるよう設計したため1単語あたりの学習結果に違いが表れてしまっていた。例えば、事前事後テストの解答を詳細にみると“wonder”、“shake”の2単語の正答率が非常に高かった。それは平均合計出現回の5回に対してこの2単語の平均合計出現回数は8.5回であったためと考えられる。(図6参照) “exercise”の出題回数が少ないにも関わらず、正答率が高い理由については日常会話で“エクササイズ”という言葉を使用することが多いため、簡単に覚えられたためであると考えた。また、今回出題した単語が難しかったこと、使用回数が2週間に分けて2回のみであったことも最終平均点数が半分未満になってしまったに影響していると考えられる。

今後の展望として、一定回数出題された単語もしくは、

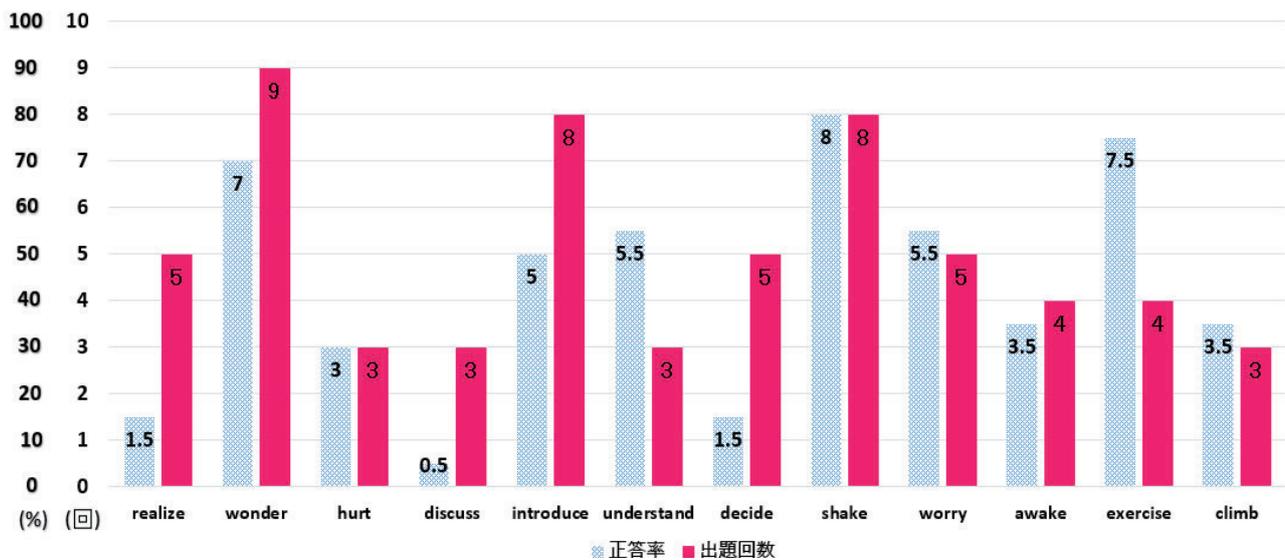


図6 正答率と出題回数

学習者が確実に覚えてしまった単語は除外するシステムを追加するべきだと考えている。また、今回使用した単語以外の単語を収録し、使用期間を多くするべきだと考えている。

6. まとめ

本研究の目的は英単語の意味を学習者自身が演じ、演じた動きをゲーム内のキャラクタが動く英単語学習システムを開発し、学習者が使用することで新しい英単語を覚えることができるかどうか検証することであった。結果として、確かに学習者は英単語を覚えることができた。しかし出題に偏りがあったため、覚えた単語に偏りがあった。よって学習者が覚えた単語は除外して出題するように改善するなどすることでより良くなると考えられる。

7. 謝辞

実験にご協力いただいた、函館市立赤川小学校の皆様には感謝申し上げます。

参考文献

- [1] 山森光陽. 中学校1年生の4月における英語学習に対する意欲はどこまで持続するのか. 教育心理学研究, 2004, 52, p.71-82
- [2] 川村義治. イメージと記憶—なぜ身体動作イメージは英単語の記憶再生に効果があるのか—. 教育メディア研究, 2006, vol. 12, no. 2, p. 31-41.
- [3] Allen, L. Q. (1995). The effects of emblematic gestures on the development and access of mental representations of French expressions. *The Modern Language Journal*, 79, 521-529.
- [4] Tellier, M. (2009). The effect of gestures on second language memorization by young children. *Gesture*, 8, 219-235
- [5] Kelly, S.D., McDevitt, T., Esch, M.: Brief training with co-speech gesture lends a hand to word learning in a foreign language. *Language and Cognitive Processes* 24, pp.313-334 (2009)
- [6] Macedonia, M., Muller, K., Friederici, A.: Neural correlates of high performance in foreign language vocabulary learning. *Mind, Brain and Education* 4(3), pp.125-134 (2010)
- [7] Macedonia, M., von Kriegstein, K.: Gestures enhance foreign language learning. *Biolinguistics* 6(3-4), pp.393-416 (2012)

- [8] Macedonia, M., Knosche, T.R.: Body in mind: How gestures empower foreign language learning. *Mind, Brain, and Education* 5, pp.196-211 (2011)
- [9] 林拓弥, 日根恭子. 形式ジェスチャーが記憶に与える影響, 日本認知心理学会第15回大会, 2017, p4-13
- [10] 長谷川大, 白川真一, 佐久田博司. Pedagogical Agent の導管メタファ・ジェスチャーが学習者の理解に与える効果, 情報処理学会論文誌とコンピュータ, 2018, p83-92
- [11] 濱本秀樹. 統語構造を反映したジェスチャー: 記憶・再生効果に関する予備的研究, 文学・芸術・文化第26巻第2号. 2015, p35-62
- [12] 増田翔, 寺本健吾, 佐々木大志, ドミニク・カスツジャ・バゲンダ, 角薫. ジェスチャーで学ぶ英語学習システム. ヒューマンインターフェースシンポジウム 2015, ヒューマンインターフェース学会, 2015

HMD とトラッキングセンサーを用いたテニス練習支援システム

Tennis Training Support System using HMD and Tracking Sensor

西本 林太郎*¹
Rintaro NISHIMOTO

岡本 勝*¹
Masaru OKAMOTO

松原 行宏*¹
Yukihiro MATSUBARA

岩根 典之*¹
Noriyuki Iwane

*¹ 広島市立大学大学院 情報科学研究科
Graduate School of Information Sciences, Hiroshima City University

In this paper, VR-based tennis training support system using HMD is proposed. In this system, user can practice the swing by shaking the racket at a virtual tennis court constructed in the virtual environment. By using a HMD and a tracking sensor attached on the real racket, the head position and the racket position can be measured. From measured information, interaction between virtual racket and virtual ball is calculated, and this calculation result are show for user as feedback in the virtual environment. Experimental results verified that using HMD is more effective than 2D video display for showing trajectory of a virtual ball.

1. はじめに

スポーツの練習において、システムを用いた練習支援が研究されている。Mishimaらは、2次元映像を出力するディスプレイを用いて熟練者の動作を模倣してテニスの練習を行うシステムを提案した[Mishima 14]。このシステムでは、熟練者の動作をモーションキャプチャーで記録し、そのデータを用いて熟練者の動作を行うボーンモデルを作成している。そして、そのボーンモデルを撮影した学習者の映像に拡張表示し、学習者はそのボーンモデルを模倣して練習を行うことができる。このシステムを用いることでテニスの構えを練習することができる。しかし、飛んでくるボールに対して適切なタイミングで構える際、2次元映像では奥行き認識が困難であると考えられる。またラケットを把持した練習は想定されていない。

3次元映像を表示する方法として、両眼視差を考慮した映像を表示することができるヘッドマウントディスプレイ(Head Mounted Display: 以下HMD)を用いることが考えられる。津田らは、HMDを用いて仮想環境内で野球のフライを捕球する練習が行えるシステムを提案した[津田 17]。HMDを用いることでユーザがボールの落下位置を判断し、落下位置までの移動を行うことができる。

本稿では、現在開発を進めている、HMDを用いて仮想環境内でテニスのスイング練習を行う手法[西本 18]のプロトタイプシステムの実装及び機能評価を行う。HMDを用いることで、2次元映像のディスプレイよりもボールの位置が把握しやすくなると考えられる。またラケットにトラッキングセンサーを装着することで、実際にラケットを振って練習を行うことができる。本システムでは、

ユーザのスイング動作に対してボールとラケットの衝突位置を確認できる機能を実装した。検証実験では、2次元映像を用いたシステムとの比較を行う。

2. システム

図1にシステムの外観を示す。図1のようにユーザはHMDを装着し、利き手にラケット、もう片方の手にコントローラを持って練習を行う。ユーザはコントローラを用いることでシステムの実行を行う。ラケットにトラッキングセンサーを装着することでラケットの正確な位置情報を取得することができる。図2に構築した仮想環境と俯瞰図を示す。図2(a)のように実際のテニスコートやラケット、ボールのサイズを考慮し、仮想環境を構築した。仮想環境内のラケットの位置は、トラッキングセンサーから取得されたデータをもとに実環境のラケットの位置が反映される。ユーザは図2(b)のユーザの位置に立ち、相手コートから飛んでくるボールに対して、実際にラケットを振ってスイングの練習を行う。

ユーザが自身のスイングを振り返るために3つの機能を用意した。1つ目の機能は、スイングした際にボールがラケットに当たった位置によって音を出力する機能である。ボールがラケットの

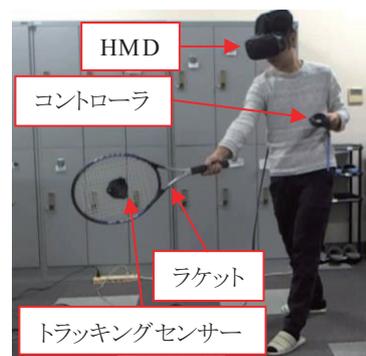


図1 システムの外観

連絡先: 西本林太郎, 広島市立大学大学院情報科学研究科,
広島県広島市安佐南区大塚東3丁目4番1号,
TEL 082-830-1674, lnishimoto@lake.info.hiroshima-cu.ac.jp

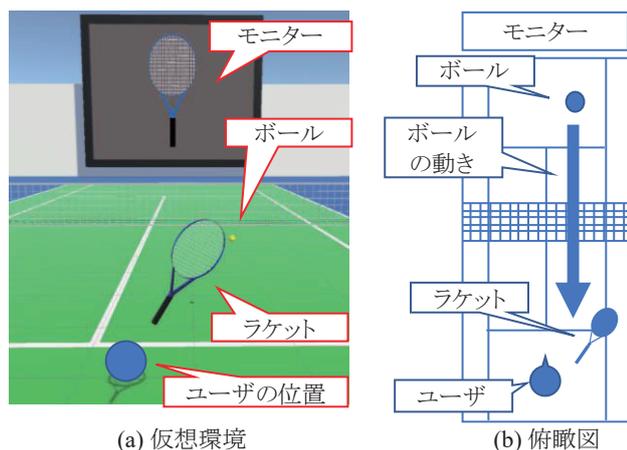


図2 構築した仮想環境と俯瞰図



図3 衝突位置を表示しているときのモニター

中心付近に当たると大きな音が、それ以外の部分に当たると小さい音がスピーカーに出力される。ユーザはこの音を聴くことによって、ボールがラケットの中心に当たったか否かを聴覚的に把握できる。2つ目の機能は、ボールがラケットに当たった位置を図2のモニターに表示する機能である。図3に衝突位置を表示しているときのモニターを示す。図3のように、ボールとラケットが衝突するとモニターにボールとラケットの位置が表示される。練習者はこのモニターを見ることで、ボールが当たった位置を視覚的に把握できる。3つ目の機能は、スイングした際のボールとラケットをリプレイで表示する機能である。本システムでは、ボールとラケットの位置をログとして保存し、スイング時の数秒間のボールとラケットの動きを再現する。ユーザが直前に行ったスイング動作時のボールとラケットの動きを同じ場所にリプレイ映像としてアニメーションで表示する。ユーザはこのリプレイ機能を用いてボールに対してどのようなスイングをしたのかをラケットの軌道を見て確認することでボールに当たった時のラケットの面の向きを把握できる。

3. 検証実験

検証実験では、2次元映像のディスプレイよりもHMDの方がボールの距離感を把握し、打つことができるか検証する。HMDを用いたシステムと2次元映像のディスプレイを用いたシステムで、ボールを打ち比較する。それぞれのシステムで練習なしで

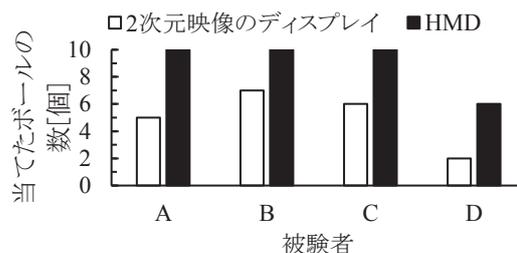


図4 2つのシステムを用いて各被験者が当たったボールの数

ボールを10球ずつ打つ。被験者は4名(A~D)で、被験者A, BはHMDのシステムの後、2次元映像のディスプレイのシステムでボールを打ち、被験者C, Dは逆の順番で表示されたボールを打つように指示した。

図4に2つのシステムを用いて各被験者が当たったボールの数を示す。図4より、すべての被験者において2次元映像のディスプレイよりもHMDのシステムの方がボールに当てることができたことが分かる。また被験者からは「2次元映像のディスプレイのシステムの方は距離感も高さもわかりづらい」、「画面が遠くなるため見づらい」といった意見があった。以上の結果より、被験者は2次元映像のディスプレイよりHMDの方がボールの距離感や高さを把握し、打つことができたといえる。

4. おわりに

本稿では、HMDとトラッキングセンサーを用いたテニス練習支援システムのプロトタイプシステムの開発及び機能評価を行った。HMDを用いることで、仮想環境内のボールの位置が把握しやすくなり、ラケットにトラッキングセンサーを用いることで、仮想環境内で実際にラケットを振って練習を行うことができる。検証実験では2次元映像のディスプレイよりもHMDの方がボールの距離感を把握し、打つことができるか検証した。

今後の課題として、飛んでくるボールに対してどのように構えスイングするかなどの教示情報をユーザにフィードバックする技術の実装があげられる。

参考文献

- [Mishima 14年] T. Mishima, M. Okamoto, and Y. Matsubara.: ARbased Skill Learning Support System with Velocity Adjustment of Virtual Instructor Movement, Proceedings of the 22nd international conference on computer in education, pp. 331-336, (2014).
- [津田 17年] 津田直彦, 井村誠孝: VR技術を用いたフライ捕球訓練システム, 情報処理学会第79回全国大会, pp. 973-974, (2017).
- [西本 18年] 西本林太郎, 岡本勝, 松原行宏, 岩根典之: トラッキングセンサーを用いたVR型テニス練習支援システム, 電子情報通信学会教育工学研究会, 信学技報, Vol. 118, No. 294, pp. 57-62, (2018).

身体の3次元構造を考慮したニューラル仮想試着

Neural Virtual Try-On System considering 3D human model

久保 静真^{*1} 岩澤 有祐^{*1} 鈴木 雅大^{*1} 松尾 豊^{*1}
Shizuma Kubo Yusuke Iwasawa Masahiro Suzuki Yutaka Matsuo

^{*1}東京大学大学院工学系研究科 松尾研究室
The University of Tokyo, Matsuo Laboratory

We propose a novel virtual try-on method based on Generative Adversarial Networks (GAN), which uses 3D surface model of body. In existing GAN-based methods (CAGAN, SwapGAN) sometimes do not work on a human image of rare posture. In our proposed method, by using DensePose to estimate a point corresponding to 3D surface model for each pixel point of 2D image, 3D surface based information is incorporated into our model. Therefore, it is possible to change clothes of people in various postures. Our proposed method uses a coarse-to-fine strategy. First, *Parts Generation Network* generates parts and they are mapped to 2D image to produce coarse dressing image. After that, *Refine Network* refines the coarse dressing image. In our experiment, we show the result of the proposed method and our method has effect on rare postures by comparison with existing methods.

1. はじめに

オンラインショッピングサイトの需要の増加に伴い、仮想試着は注目を集めている。既存の仮想試着の研究では服の模様や特徴を対象の人物の服の領域に遷移させることに注力しているが、身体の向きが変わると自然な画像が生成できないという課題がある。例えば、既存のモデルは身体が直立正面となるような姿勢ではうまくいくが、腕が身体の正面にくるような姿勢ではうまくいかないことがある。既存の研究における身体情報の利用はセグメンテーションや2次元の姿勢推定に限定されているが、身体の向きが変わっても自然な画像を生成するためには、身体構造を考慮するのに必要な新たな情報を補完する必要があると考えられる。

本研究では、様々な姿勢に対しても有効な着せ替えを行なうために、身体の3次元構造を考慮した仮想試着の手法を提案する。仮想試着では、身体の3次元構造の推定とその推定された3次元構造に服をマッピングする2つのプロセスが存在すると考えられるが、既存の手法ではこのプロセスを同時に行っている。提案手法ではこのプロセスを明示的に分離し、身体の3次元構造の推定に既存研究のDensePose[Güler 18]の出力であるIUV^{*1}データを利用することで、既存手法よりも身体構造として正確な服の着せ替え画像を生成できることを示す。提案モデルは2段階のネットワークを用いる。1段階目のネットワークでは服の画像から身体の3D表面のUV座標に対応するパーツを生成する。その生成したパーツをIUVデータに沿って、対象の人物に貼り付けることで対象の服に着せ替わった画像を生成する。生成するパーツの各ピクセルは身体の3次元構造に即してマッピングされるため、様々な姿勢であっても対応できる。このマッピングの段階では粗さが残るため、2段階目のネットワークでは精錬してより本物らしい画像を生成する。

2. 先行研究

近年では、人物画像に任意の服を着せた画像を生成する仮想試着の研究が複数行われている。画像生成において、Generative Adversarial Networks (GAN) [Goodfellow 14] がよく使われるのと同時に、仮想試着においてもGANを使った手法は提案されている。[Jetchev 17] は [Jun-Yan 17] を応用したGANによる仮想着せ替えの手法を提案した。[Kubo 18] は [Jetchev 17] の研究において、服の領域を考慮することで服の模様の遷移がうまくいくことを示した。また、その他の仮想試着の研究としては、[Han 17] や [Wang 18] がある。[Han 17] では粗い画像を生成するEncoder-Decoderのステージとその出力とthin plate spline (TPS) によって変形した服を入力に画像を精錬するステージの2段階のモデルを構築し、仮想試着を行った。[Wang 18] は [Han 17] を応用して、Geometric Matching Module (GMM) を使って服の変形を行なう機構を取り入れ、服の特徴をより生成画像に反映できることを示した。

最近では、身体の領域を検出し、各ピクセルに対して3Dサーフェスモデルに対応する点を推定する[Güler 18]を利用した研究も行われている。[Neverova 18] は[Güler 18]を姿勢推定のタスクに応用した。また、[Wu 18] は[Güler 18]を用いて2つの画像人物間の服の交換を行った。本稿では、この[Güler 18]によって得られる身体の3次元構造の情報を仮想試着のモデルに組み込むことで身体構造をより考慮した仮想試着のモデルを提案する。

3. 提案手法

提案手法では、2段階のネットワークを学習する。全体像は図1に示す通りである。1段階目のネットワークであるパーツ生成ネットワーク(Parts Generation Network)によって、着せ替え後の人物の3次元表面を表す身体各パーツを生成し、そのパーツを利用し、テクスチャマッピング(Texture Mapping)によって2次元の着せ替え画像を生成する。そして、その着せ替え画像を2段階目のネットワークである精錬ネットワーク(Refine Network)によって精錬させたものを最終的な結果とする。

連絡先: 久保静真, 東京大学工学系研究科松尾研究室,
08015475717, kubo@weblab.t.u-tokyo.ac.jp

*1 3Dモデルにテクスチャをマッピングするときに使うUV座標系に各UV座標が身体のどのパーツに属するかの情報も加えたものである。UV座標系は2次元の直交座標系で横方向をU, 縦方向をVとする。

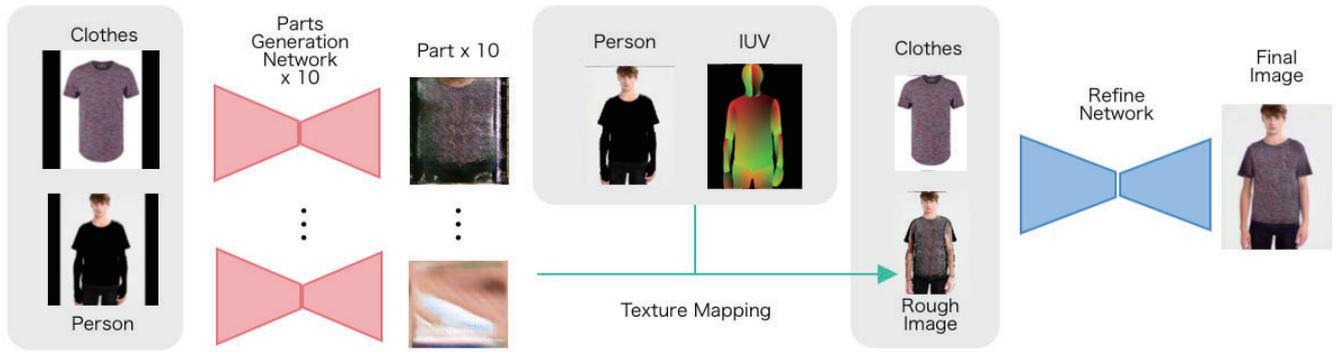


図 1: 全体像

赤のネットワークがパーツ生成ネットワーク (Parts Generation Network) を、緑の線がテクスチャマッピング (Texture Mapping) を表しており、これらによって粗い着せ替え画像 (Rough Image) が生成される。その後、図中の青で表された精錬ネットワーク (Refine Network) によってより本物らしい着せ替え画像へと精錬される。なお、入力の服の領域を切り取られた「Person」と DenseposePose の出力の「IUV」は着せ替える対象の人物画像から得られる。

3.1 パーツ生成ネットワーク

1つ目のネットワークであるパーツ生成ネットワーク (Parts Generation Network) では対象の服の画像から着せ替え後の人物の3次元表面を表す身体各パーツを生成するように学習する。本稿では既存手法と同様に、着せ替える対象を上着に限定するため、生成するパーツは上半身に含まれる合計10個のパーツとなる (ただし、両手は除く)。生成するパーツそれぞれに対してネットワークを用意する。それぞれのネットワークは服の画像と人物の服部分を切り抜いた画像の2枚の画像を入力とする。人物の服部分を切り抜いた画像を入力に含めたのは人物の肌の色のような身体情報を加味するためである。入力の画像は出力のサイズに合わせ、2枚とも正方形となるように補完し、128x128にリサイズして入力とした。10個のネットワーク全てにおいて入力は同じであり、出力の画像のサイズも128x128である。教師データとして、入力の服を着用した人物画像から Densepose[Güler 18] によって得られる IUV データを用いてパーツにしたものを用いる。この人物画像の元のサイズは1100x762または1650x1143のサイズであり、128x128のパーツの画像を教師データとして用意した。パーツの例を図2に示す。



図 2: パーツの生成例

上の段の画像が教師データとなるパーツの画像となる。下の段の画像がネットワークによって出力されるパーツの画像例である。

学習は、各パーツごとに下記の式 (1) の損失関数を最小にするように行われる。G と D はそれぞれ多層パーセプトロンからなる Generator, Discriminator の関数を表したものであり、式 (1) のように G と D の関数 $V(G, D)$ の min-max ゲームによって学習を進める。各項については以下で説明する。

$$\min_G \max_D V(D, G) = L_{GAN_{parts}}(G, D) + L_1(G) + L_{perceptual}(G). \quad (1)$$

用いるデータは、入力の服の画像を c_i 、人物の服部分を切り抜いた画像を r_i 、対応するパーツの画像を y_i 、対応する教師データのパーツの存在する領域のマスクを m_i とし、 $\{c_i, r_i, y_i, m_i\}_{i=1}^N$ のような N 組のペアの集合からなる。以下の式 (2), (3) にそれぞれ、 $L_{GAN}(G, D)$ と $L_1(G)$ を示す。Generator の出力をパーツの存在領域でマスクして学習に利用する。

$$L_{GAN_{parts}}(D, G) = E[\log D(y_i, c_i, r_i)] + E[\log(1 - D(G(c_i, r_i) \odot m_i, c_i, r_i))] \quad (2)$$

$$L_1(G) = E\|y_i - G(c_i, r_i) \odot m_i\|. \quad (3)$$

なお、 E は期待値を表している。

また、以下の式 (4) では perceptual loss と呼ばれる $L_{perceptual}(G)$ を示す。 $G(c_i, r_i) \odot m_i$ と対応するパーツ画像 y_i を一般物体認識で高い性能を示した VGG19[Simonyan 15] の学習済みモデルにそれぞれ入力して得られる各ブロックの特徴マップの差 l_ϕ の和を取ったものが perceptual loss である。 λ は各層のパラメータ数の逆数である。[Johnson 16, Han 17] に習って、perceptual loss を追加することで服の模様を考慮出来るようになることを期待している。

$$L_{perceptual}(G) = E \left[\sum_{i=1} \lambda_i l_{\phi, block_{conv2}} \right]. \quad (4)$$

3.2 テクスチャマッピング

パーツ生成ネットワークで生成したパーツを IUV データに基づいて、対象の人物の身体表面にマッピングする。対象の人物の画像は256x192のサイズで、貼り付けるパーツの部分は [Chen 15] によって得られる上半身のセグメンテーションデータを用いて取り除いた。なお、両手は IUV データにより元画像から再現した。図3に例を示す。

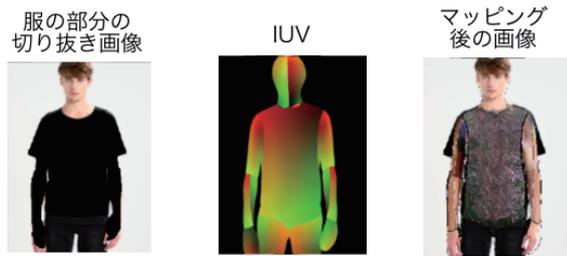


図 3: テクスチャマッピングの例
服の部分を切り抜いた画像に IUV データを元に生成したパーツを貼り付けることでマッピングを行なう。

3.3 精錬ネットワーク

テクスチャマッピング後の着せ替え画像は粗く、補完しきれない部分が残るため、精錬ネットワークにより本物らしい画像に精錬する。入力としてはテクスチャマッピング後の着せ替え画像と着せ替える服の画像を入力とする。全ての入力のサイズは 256×192 である。学習は式 (5) の損失関数を最小にするように行われる。ここでの G , D はパーツ生成ネットワークとは別のネットワークである。 $L_1(G)$, $L_{perceptual}(G)$ では着用している服と着せ替える服を同じ服にして着せ替え処理を行って、着せ替え前後の差をパーツ生成ネットワークと同様に損失とする。 $L_{GAN_{refine}}(G, D)$ については以下で説明する。

$$\min_G \max_D V(D, G) = L_{GAN_{refine}}(G, D) + L_1(G) + L_{perceptual}(G). \quad (5)$$

入力の人物の画像を h_i , 元々着用している服を c_i , 着せ替える服の画像 c_j , テクスチャマッピングによって生成された粗い着せ替え画像を r_{ij} として、以下の式 (6) に $L_{GAN_{refine}}(G, D)$ を示す。なお、この項は既存手法である CAGAN[Jetchev 17] や SwapGAN[Kubo 18] と同様の項である。

$$L_{GAN_{refine}}(D, G) = E[\log D(h_i, c_i)] + E[\log(1 - D(G(r_{ij}, c_j), c_j))] + E[\log(1 - D(h_i, c_j))]. \quad (6)$$

4. 実験

4.1 データセット

学習に使用する人物画像とその人物の着用する服の画像のペアのデータセットはファッション EC サイト Zalando (<https://www.zalando.de>) の Website から取得したものである。また、画像のサイズは 256×192 とし、1 枚に複数の服が写っているようなノイズとなる画像は取り除いた。用意したデータは合計で 9286 組であり、9000 組を学習に、286 組をテストに利用した。実装は DeepLearning のフレームワークの Pytorch を利用し、最適化手法には Adam を用いた。ネットワークは畳み込み層と逆畳み込み層を多層に積み上げており、各層はバッチ正規化を行い、ReLU または LeakyReLU を活性化関数として利用している。比較として、従来手法の CAGAN[Jetchev 17], SwapGAN[Kubo 18] も実装し比較を行ったが、公平性のため、各手法とも論文内の 128×96 のサイズの画像ではなく、本提案手法に合わせて 256×192 のサイズ

の画像で学習を行った。また、セグメンテーションの生成には [Gong 17] のデータセットで学習した [Chen 15] を利用し、また、[Güler 18] によって得られる IUV データを利用する。

4.2 生成結果

図 4, 図 5 は提案手法の生成画像を示したものである。図 4 は特に特徴の模様のある服の着せ替えを行った例である。図 5 は着用している服と着せ替える服の丈の長さの違う場合の着せ替え及び学習データに少ない正面向きの姿勢ではない人物の着せ替えの例である。

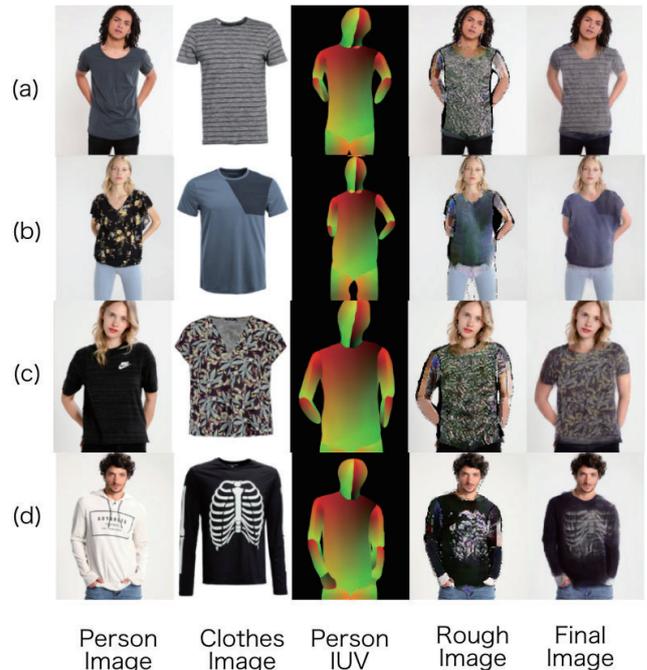


図 4: 提案手法の生成画像 1
Rough Image はテクスチャマッピング後の生成結果, Final Image は精錬ネットワークの生成結果である。

4.3 既存手法との比較

図 6 は GAN ベースの既存手法である CAGAN と SwapGAN との比較を示している。既存手法である CAGAN 及び SwapGAN は直立正面の姿勢の人物の着せ替えであれば着せ替えを行なうことができるが、図の人物のような他の姿勢の画像に対してはうまく着せ替えを行なうことが難しい。これは、学習データに多く存在する直立正面以外の姿勢までネットワークの学習が及んでいないためであると考えられる。一方、提案手法では身体の構造をネットワーク内で学習しようとするのではなく、Densepose によって得られる IUV データを使ったマッピング (パーツの貼り付け) に担わせることにより、直立正面の特定の姿勢だけではなく様々な姿勢に対応できるようになったと考えられる。

5. まとめ

本研究では、ファッション分野におけるオンラインショッピングサイトの需要増加によって利用が期待される仮想試着に関して 3 次元表面を利用した着せ替え手法の提案を行った。既存の GAN を用いた自動着せ替え手法である CAGAN, SwapGAN

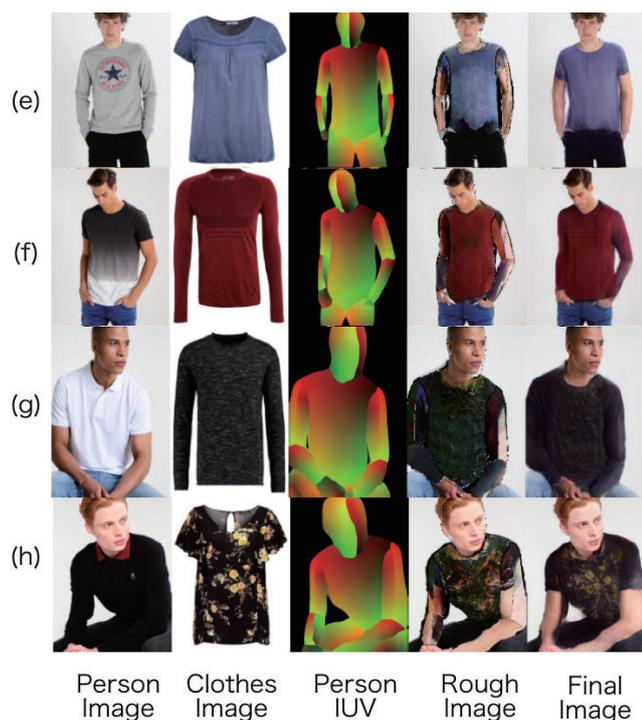


図 5: 提案手法の生成画像 2

Rough Image はテキストチャッピング後の生成結果, Final Image は精練ネットワークの生成結果である。(e), (f) はそれぞれ長袖から半袖, 半袖から長袖の服に着せ替えた例である。(g), (h) は正面向きでない姿勢の画像を着せ替えた例である。

との比較により 3 次元構造を利用した着せ替え手法の有効性を示した。今後も引き続き, 改善に取り組む予定である。

参考文献

- [Goodfellow 14] Goodfellow, Ian J. and Pouget-Abadie, Jean and Mirza, Mehdi and Xu, Bing and Warde-Farley, David and Ozair, Sherjil and Courville, Aaron and Bengio, Yoshua: Generative Adversarial Networks, in Neural Information Processing Systems (NIPS) (2014)
- [Jetchev 17] Jetchev, Nikolay and Bergmann, Urs: The Conditional Analogy GAN: Swapping Fashion Articles on People Images, in International Conference on Computer Vision (ICCV) (2017)
- [Jun-Yan 17] hu, Jun-Yan and Park, Taesung and Isola, Phillip and Efros, Alexei A.: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, in International Conference on Computer Vision (ICCV) (2017)
- [Kubo 18] Shizuma, Kubo and Yusuke, Iwasawa and Masahiro, Suzuki and Yutaka, Matsuo: SwapGAN: Cloth-Region Aware Generative Adversarial Networks toward Virtual Try-On System (2018)
- [Han 17] Han, Xintong and Wu, Zuxuan and Wu, Zhe and Yu, Ruichi and Davis, Larry S.: VITON: An Image-

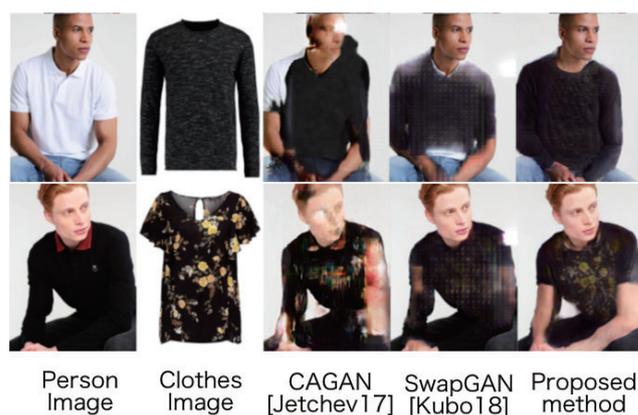


図 6: 既存手法との比較

based Virtual Try-on Network (2017), in the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (2018)

- [Wang 18] Wang, Bochao and Zheng, Huabin and Liang, Xiaodan and Chen, Yimin and Lin, Liang and Yang, Meng.: Toward characteristic-preserving image-based virtual try-on network, in European Conference on Computer Vision (ECCV) (2018)

- [Güler 18] Güler, Rıza Alp and Neverova, Natalia and Kokkinos, Iasonas: DensePose: Dense Human Pose Estimation In The Wild, in the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (2018)

- [Neverova 18] Neverova, Natalia and Alp Güler, Rıza and Kokkinos, Iasonas: Dense Pose Transfer, in European Conference on Computer Vision (ECCV) (2018)

- [Wu 18] Wu, Zhonghua and Lin, Guosheng and Tao, Qingyi and Cai, Jianfei: M2E-Try On Net: Fashion from Model to Everyone (2018)

- [Simonyan 15] Simonyan, Karen and Zisserman, Andrew: Very Deep Convolutional Networks for Large-Scale Image Recognition, in International Conference for Learning Representations (ICLR) (2015)

- [Johnson 16] Johnson, Justin and Alahi, Alexandre and Fei-Fei, Li: Perceptual losses for real-time style transfer and super-resolution, in European Conference on Computer Vision (ECCV) (2016)

- [Gong 17] Gong, Ke and Liang, Xiaodan and Zhang, Dongyu and Shen, Xiaohui and Lin, Liang: Look into Person: Self-supervised Structure-sensitive Learning and A New Benchmark for Human Parsing, in Computer Vision and Pattern Recognition (CVPR) (2017)

- [Chen 15] Chen, Liang-Chieh and Yang, Yi and Wang, Jiang and Xu, Wei and Yuille, Alan L.: Attention to Scale: Scale-aware Semantic Image Segmentation (2015)

Model Human Processor と運動準備電位の出現位置の比較と検討

Comparison and Consideration of Appearance Positions of Model Human Processor and Readiness Potential

清水 菜々子*1
Nanako Shimizu

東野 利貴*2
Toshitaka Higashino

曾我 真人*1
Masato Soga

*1 和歌山大学システム工学部

*2 大阪大学大学院情報科学研究科

Faculty of Systems Engineering, Wakayama University

Graduate School of Information Science and Technology, Osaka University

Abstract: In thinking about human-computer interface, it is important to know how human beings recognize, judge and act. Therefore, Card et al. devised a model of human cognitive processing process called Model Human Processor (MHP). However, this MHP predicts processing time from empirical rules, and is not much considered from the aspect of brain activity. In this study, we focused on readiness potential (RP), which is a characteristic brain wave, and verified MHP from the aspect of brain activity by measuring EEG when performing basic user performance. Experimental results show that MHP can be roughly explained from the aspect of RP, which is a characteristic brain activity.

1. はじめに

人間の認知処理過程をモデル化したものに、Card らの Model Human Processor (MHP) がある[Card 1987]。しかし、MHP は経験則に従い処理時間を予測したものであり、脳活動の側面からはあまり検討されていない。そこで、本研究では、脳波の中でも、運動準備電位 (Readiness Potential: RP) と呼ばれる脳波に着目し、脳波を計測・解析して、脳活動の側面から MHP の検証を行う。

2. 研究目的

MHP では、知覚に要する平均時間を 100ms, 認知に要する平均時間を 70ms, 運動に要する時間を 70ms と定めている (図 1)。

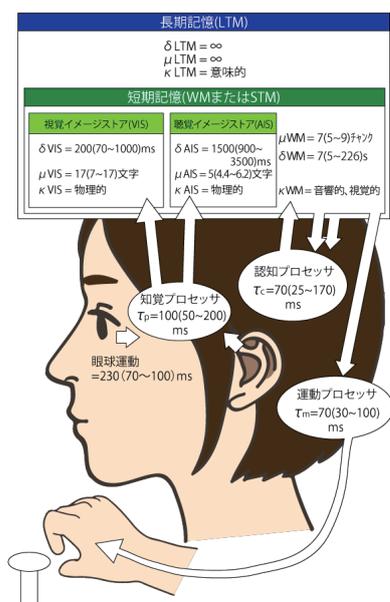


図 1 MHP のモデル

そこで、MHP を用いて、人間の 4 つの基本的ユーザ・パフォーマンスである単純反応、物理的照合反応、名称照合反応、カテゴリ照合反応における認知処理過程を表すと図 2 に示すようになる[古市 1987]。なお、単純反応は何らかの情報が呈示されたときに行う反応、物理的照合反応は呈示された情報が事前に記憶していた情報と同じときに行う反応、名称照合反応は呈示された情報が事前に記憶していた名称と同じ名称で表すことができるときに行う反応、カテゴリ照合反応は呈示された情報が事前に記憶していたカテゴリと同じカテゴリで表すことができるときに行う反応のことである。

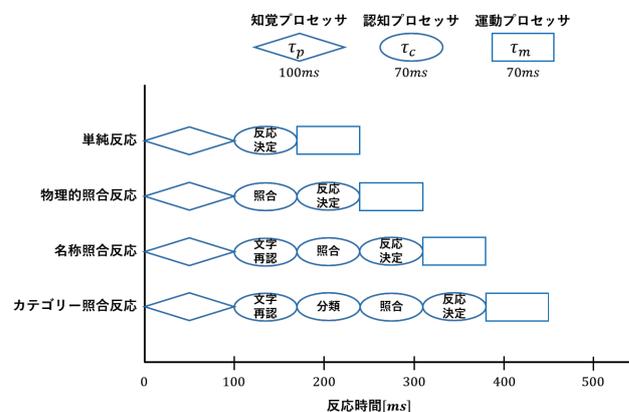


図 2 MHP における 4 つの基本的ユーザ・パフォーマンス

また、RP は Kornhuber らによって、発見された脳波である [Kornhuber 1965]。随意運動に 550ms 先立って生じる微小な電位の変化であり、電位の変化は負の方向である。随意運動に対する準備に関連する脳波であり、運動野で見られる。以上から、MHP の 4 つのモデルにおいて、RP が出現すると考えられる位置を重ね合わせて図示すると図 3 に示すとおりになる。

連絡先: 清水菜々子, 所属: 和歌山大学システム工学部,
電子メールアドレス: s206128@wakayama-u.ac.jp

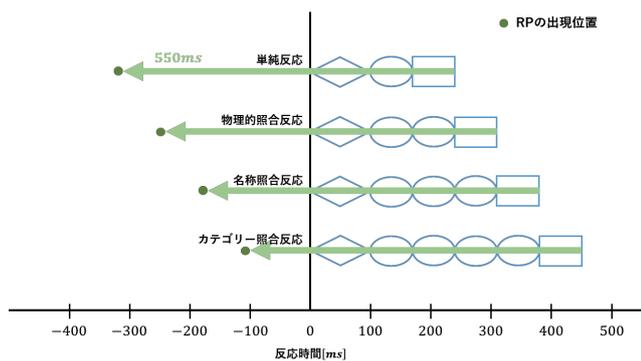


図3 RPとMHPの矛盾

(緑色の矢印はMHPにおける運動プロセッサの終了位置から550ms前の位置を示している。)

MHPにおいて、脳内で運動の準備が行われるのは、認知プロセッサの区間である。しかし、図3に示すように、RPの出現位置は知覚プロセッサよりも前になっており、これはMHPとRPが矛盾していることを示している。そこで、本研究では、4つのモデルに対応する実験を構築し、その実験中の脳波を計測して、RPの出現位置を確認することで、この矛盾点について検証を行う。

3. 実験手法

MHPに対応する4つの実験を構築し、実験中の被験者の脳波を計測した。実験は、脳波計を装着した被験者に視覚刺激を呈示し、事前に教示した視覚刺激(ターゲット刺激)が呈示されたらマウスの左クリックを、それ以外の視覚刺激が呈示されたら右クリックを行ってもらった。また、視覚刺激の呈示からマウスクリックまでの時間を反応時間(Reaction time: RT)として記録した。本実験の実験環境を図4に示す。視覚刺激を呈示するためのディスプレイは、被験者から1m離れた位置に設置した。被験者には脳波計を装着してもらい、利き手にマウスを握ってもらった。

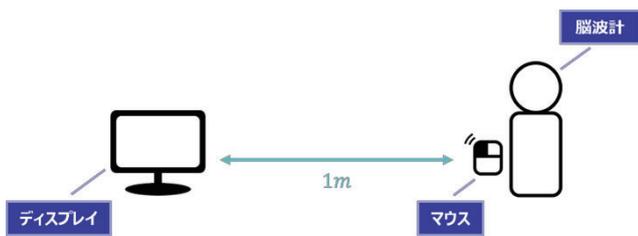


図4 実験環境

各実験における視覚刺激、ターゲット刺激を表1に示す。なお、脳波計測にはBIOSEMI Active Twoを用いた。サンプリングレートは512Hzとし、電極は国際10-20法に基づいて配置した(図5)。

表1 視覚刺激の種類

	視覚刺激	ターゲット刺激	ターゲット刺激の出現確率[%]
単純反応	●	●	100
物理的照合反応	A, B, C, a, b, c, 1, 2, 3	B	11
名称照合反応	A, B, C, D, E, a, b, c, d, e, 1, 2, 3, 4, 5	/di:/と読む記号(D, d)	13
カテゴリー照合反応	A, B, C, D, E, a, b, c, d, e, 1, 2, 3, 4, 5	子音(B, C, D, b, c, d)	40

電極の配置(10-20法)

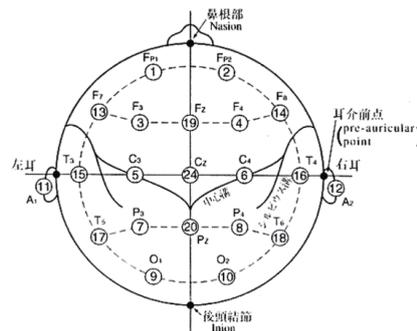


図5 国際10-20法[松田 1995]

また、視覚刺激の呈示方法は、図6に示すように、注視点(+)が呈示された画面と、視覚刺激が呈示された画面を交互に呈示した。注視点の画面の呈示時間は、1000-2000msの間でランダムにした。これは、視覚刺激が呈示されるタイミングをずらすことで、被験者が、視覚刺激が呈示されるタイミングを覚えてしまうことがないようにするためである。視覚刺激の画面は600ms間呈示した。また、各実験において、視覚刺激の提示回数、どの視覚刺激もそれぞれ30回とした。これは、脳波のデータを加算平均するためである。

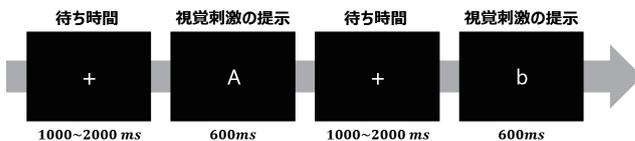


図6 視覚刺激の呈示方法

4. 解析手法

取得した脳波のデータから被験者ごとの加算平均波形を導出するまでのデータ処理の過程を図7に示す。脳波のデータから眼電位のデータを除算することで、眼球運動やまばたきによるノイズを除去し、1-30Hzのバンドパスフィルタを適用することで、脳波以外の現象によるノイズを除去した。ノイズを除去した脳波のデータを、トリガー(マウスクリックの位置)を起点に-1000msから500msの区間で分割した。分割したデータ1つ1つに対して、視覚刺激呈示の位置を起点に-700msから-500msの区間の平均電位をベースラインとして、ベースライン補正を行った。その後、RTが平均±2SD(標準偏差の±2倍)を超えるデータを外れ値として除外し、加算平均を行った。また、被験者ごとの加算平均波形をさらに加算平均することで、総加算平均波形を導出した。

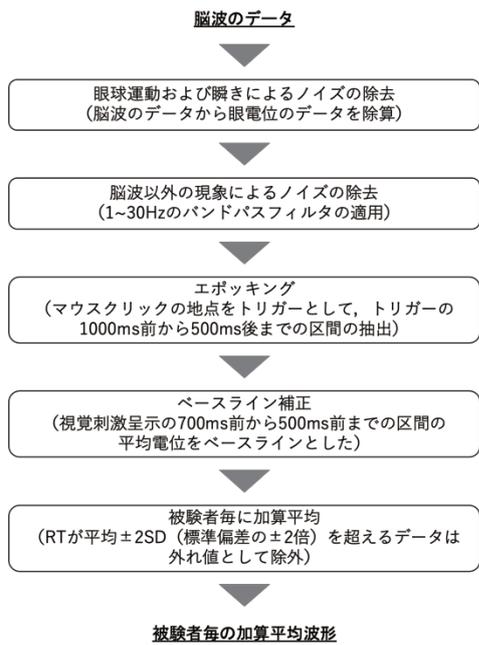


図7 脳波データ整形の過程

5. 実験結果

解析には、健康な男女 10 名の被験者の C3 電極のデータを用いた。C3 電極の位置は運動野であり、RP が検出できる。

5.1 4つのモデルにおける RT の比較

4つのモデルにおける RT の平均値, 分散を表 2 に示す。

表 2 4つのモデルにおける RT の平均値・分散

	RTの平均値[sec]	RTの分散[sec ²]
単純反応	0.2819	0.0223
物理的照合反応	0.4799	0.0488
名称照合反応	0.5253	0.0558
カテゴリー照合反応	0.6144	0.0964

4つのモデルにおける RT について、有意水準 5% で一元配置分散分析を行った。多重比較の結果、4つのモデルの RT の間には有意差があり、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に RT が有意に長くなっていることが分かった。4つのモデルにおける RT の平均値, 標準誤差, p 値を図 8 に示す。

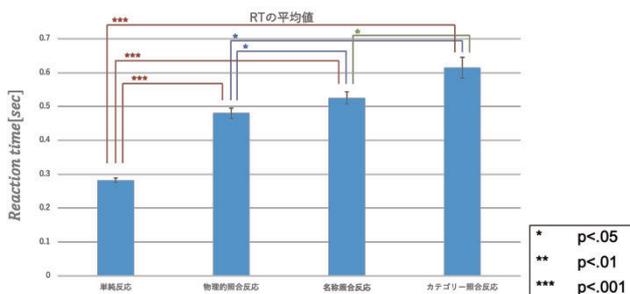


図 8 4つのモデルにおける RT の平均値, 標準誤差, p 値 (エラーバーは標準誤差を示している。)

5.2 RP の出現位置

4つのモデルにおける総加算平均波形および RP が出現し始めた位置(波形の振幅が有意に負に振れ始めた位置)を図 9 に示す。図 9 において、0ms の位置はマウスクリックの位置であり、赤線は視覚刺激呈示のタイミングを示している。縦軸は振幅 (μV), 横軸は時間(sec)である。なお、水色の区間は、帰無仮説を「平均がゼロで分散が未知の正規分布である」として、1 標本 t 検定を行い、有意水準 5% で棄却された区間である。

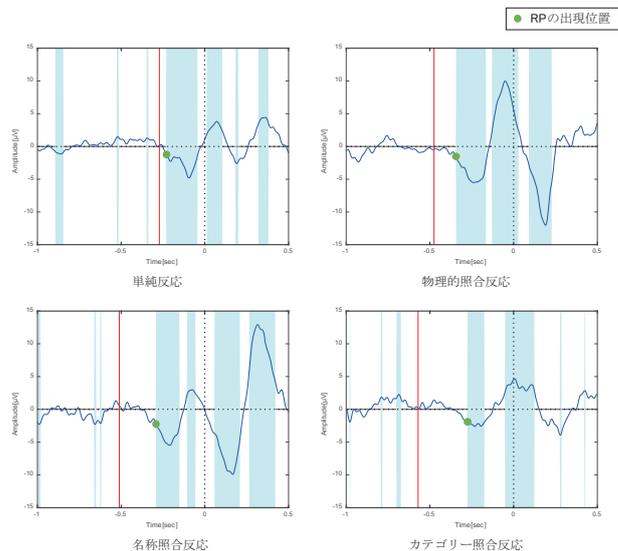


図 9 RP の出現位置 (緑色の○は RP の出現位置を示す。)

また、MHP における4つのモデルでの認知処理過程の予測、RP の出現位置、マウスクリックの位置を図 10 に示す。なお、図 10 において 0ms の位置は視覚刺激呈示のタイミングである。図 10 より、物理的照合反応、名称照合反応、カテゴリー照合反応では、RP の出現位置は認知プロセッサの区間であることが分かる。しかし、単純反応では知覚プロセッサの区間で RP が出現していた。

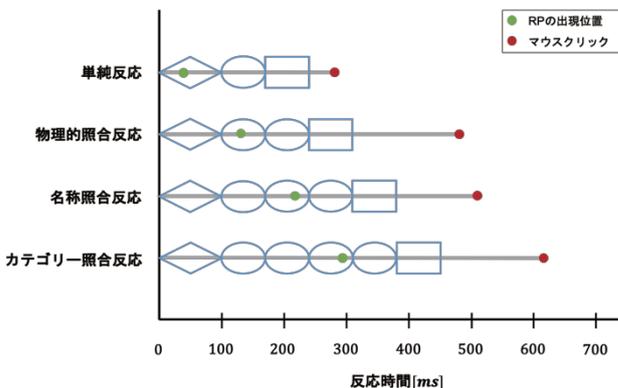


図 10 MHP における予測モデルと RP の出現位置

5.3 RP のピーク

4つのモデルにおける総加算平均波形および RP のピークの位置(RP の出現区間において波形の振幅が有意に最大になる位置)を図 11 に示す。図 11 において、0ms の位置はマウスクリ

ックの位置であり、赤線は視覚刺激呈示のタイミングを示している。

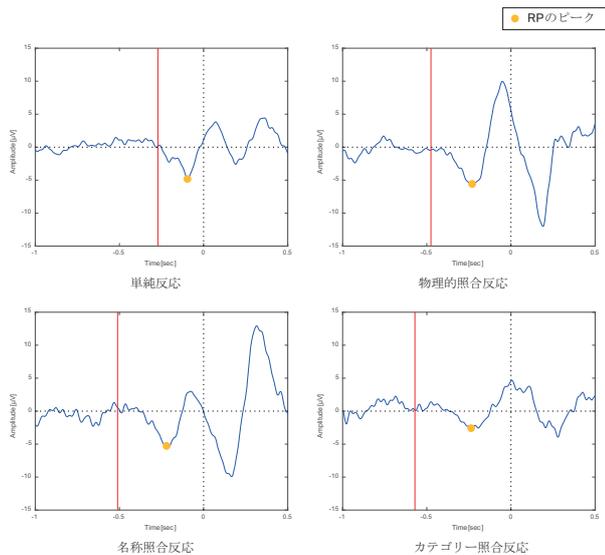


図 11 RP のピークの位置
(黄色の○は RP のピークを示す。)

また、MHP における 4 つのモデルでの認知処理過程の予測、RP のピークの位置、マウスクリックの位置を図 12 に示す。なお、図 12 において 0ms の位置は視覚刺激呈示のタイミングである。図 12 より、各反応において、視覚刺激呈示から RP のピークが出現するまでの時間が、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に伸びていることが分かる。この結果は、MHP における認知プロセッサの数が、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に増えていることと共通している。

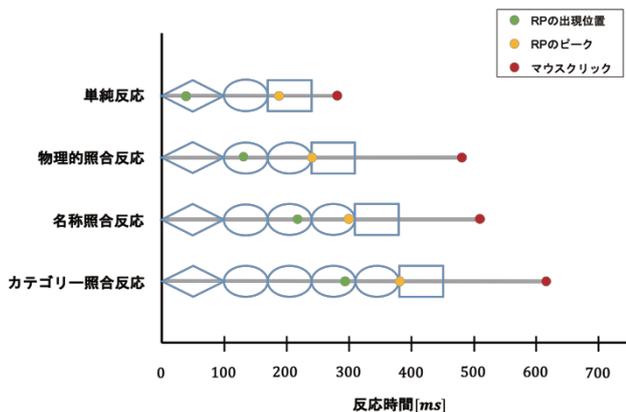


図 12 MHP における予測モデルと RP のピークの位置

6. 考察

4 つのモデルの RT は、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に有意に長くなっていた。MHP における 4 つのモデルの RT の予測は、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に長くなっている。すなわち、今回行った 4 つのモデルの実験は、MHP における RT の予測と一致した。

RP の出現位置について、物理的照合反応、名称照合反応、カテゴリー照合反応では、認知プロセッサの区間で出現した。そのため、物理的照合反応、名称照合反応、カテゴリー照合反応においては、MHP は脳活動の側面から見ても問題がないといえる。一方、単純反応では、知覚プロセッサの区間で RP が出現した。単純反応は、視覚刺激が呈示されたらマウスクリックを行うという、他の 3 つの反応と比較しても非常に簡単な反応である。そのため、実際に視覚刺激を知覚するよりも前から、マウスクリックをしようという準備状態に脳内になっていた可能性が考えられる。しかし、脳内がマウスクリックの準備状態にあったとしても、実際にマウスクリックを行うかどうかの決定を行うのは、視覚刺激を知覚した後と考えられるため、単純反応の認知処理過程を「知覚→認知(反応決定)→運動」と予測した MHP のモデルに間違いはない。

また、RP のピークの位置は、MHP における認知プロセッサの反応決定の位置が、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に遅れるのと同様に遅れている。よって、RP のピークの位置は MHP における反応決定の位置に相当すると考えられる。

以上より、MHP は特徴的な脳活動である RP の側面からも概ね説明できることが分かった。

7. まとめ

本研究では、経験則的に導かれたモデルである MHP が脳活動の側面からも正しいかどうかを検証するために、特徴的な脳波である RP に着目し、4 つの基本的ユーザ・パフォーマンスに対応する実験を構築して、その実験中の脳波を計測した。実験の結果、RT は単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に有意に長くなっており、MHP における RT の予測の傾向と一致した。RP の出現位置は、物理的照合反応、名称照合反応、カテゴリー照合反応では、認知プロセッサの区間であり、単純反応では、知覚プロセッサの区間であった。また、視覚刺激呈示から RP のピークが出現するまでの時間は、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に増加していることが分かった。これは、単純反応、物理的照合反応、名称照合反応、カテゴリー照合反応の順に MHP における認知プロセッサの数が増えていることと対応している。したがって、物理的照合反応、名称照合反応、カテゴリー照合反応では、MHP は正しいことが分かった。一方、単純反応では、RP が知覚プロセッサの区間で出現したが、単純反応が他の 3 つの反応と比べて非常に簡単な反応であるため、視覚刺激を知覚するよりも前から脳が運動の準備状態になった可能性が考えられる。そのため、単純反応においても MHP は間違っているとはいえない。以上より、MHP は特徴的な脳活動である RP の側面からも概ね説明できることが分かった。

参考文献

- [Card 1987] Stuart K. Card, Thomas P. Moran, Allen Newell, "The Psychology of Human-Computer Interaction", Crc Press, 1983
- [古市 1987] 古市康一, 溝口文雄, "インタフェースの科学(知識情報処理シリーズ 5)", 共立出版, pp49-76, 1987
- [Kornhuber 1965] Hans H. Kornhuber, Lüder Deecke, "Hirnpotentialänderungen bei Willkürbewegungen und passive Bewegungen des Menschen: Bereitschaftspotential und referente Potentiale", Pflüger's Archiv für die gesamte Physiologie des Menschen und der Tiere, 第 284 巻, pp. 1-17, 1965
- [松田 1995] 松田信義, 菅野剛史, "臨床検査技術学(7) 臨床生物学", 医学書院, 1995

[1H2-J-13] AI application: image and sensitivity

Chair:Koji Morikawa Reviewer:Yoshimasa Tawatsuji

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room H (303+304 Small meeting rooms)

[1H2-J-13-01] Video Cartoonization based on Generative Adversarial Networks○Hiroyuki Moriyama¹, Yachao Li¹, Eri Sato-Shimokawara¹, Toru Yamaguchi¹ (1. Tokyo Metropolitan University)

1:20 PM - 1:40 PM

[1H2-J-13-02] Evaluation and Analysis of Video Contents Using Physiological Information and VR EnvironmentHayato Uraji¹, ○Koki Matsumura¹, Juan Lorenzo Hagad¹, Ken-ichi Fukui¹, Masayuki Numao¹ (1. Osaka university)

1:40 PM - 2:00 PM

[1H2-J-13-03] Proposal of latent sensory estimation method for BGM recommendation using VR and EEG measurement○Yoji Kawano¹, Kikue Sato³, Eichi Takaya¹, Satoshi Suga¹, Kazuki Yamauchi², Satoshi Kurihara¹ (1. KeioUniversity, 2. RecoChoku Co.,Ltd., 3. The University of Electro-Communications)

2:00 PM - 2:20 PM

[1H2-J-13-04] Music Composition based on the Genetic Programming with segmented VRAE○Hironori Yamamoto¹, Naoki Mori¹ (1. Osaka Prefecture University)

2:20 PM - 2:40 PM

[1H2-J-13-05] Analysis based on Distributed Representations of Koma Images in Four-scene Comics Story Dataset○Akira Terauchi¹, Naoki Mori¹, Miki Ueno² (1. Osaka Prefecture University, 2. Toyohashi University of Technology)

2:40 PM - 3:00 PM

GANを利用したアニメーション生成

Video Cartoonization based on Generative Adversarial Networks

森山紘行^{*1}
Hiroyuki Moriyama

李亜超^{*1}
Yachao Li

下川原(佐藤)英理^{*1}
Eri Sato-Shimokawara

山口亨^{*1}
Toru Yamaguchi

^{*1} 首都大学東京大学院

Graduate School of System Design, Tokyo Metropolitan University

Animation has been playing an important role in the economy and culture. However, making animation is a hard work and costly. To solve the problem, we propose new solution for animation video generative model, which of baseline is Cartoon-GAN[1]. Cartoon-GAN is a kind of image to image style transfer network, and it has attained to generate cartoon style image from real-world scenes. In deep learning, there are usually two ways to process videos: 3d convolution or 2d convolution added with temporal processing. However, existing method doesn't achieve enough smoothness in the cartoon-style video making task. For our cartoon-style transfer task in video to video, our new solution is to use each two image frames and optical flow as an input for the generator. In this paper, we generated cartoon videos by adopting optical flow, which is effective to predict object motion.

1. はじめに

今や、アニメーションは社会の中で様々な価値を生み出してきている。多くのアニメーターによって作品が作られ、新しい経済効果や文化を生み出すことに貢献してきている。しかしこれまでのところ、アニメーション作成は人による作業が必要不可欠となっている。いくつかのアニメ制作会社のデータ[2]によれば、アニメの編集や作成には時間の消費量や、かかる費用が膨大であることがわかっている。そのため、もし私たちがアニメーション作成作業に関して、自動で行う手法を開発出来れば、その価値や意義は大きい。

画像から画像へのスタイル変換における最近の研究では、ほぼ良い結果を出してきている。この分野について、Cycle GAN[3]と呼ばれる手法を用いることで、機械学習時に整備された画像を用意しなくても、ある画僧から別の画像スタイルへの変換タスクにおいて一定の結果を出している。

従来の画像スタイル変換手法を応用し、ある画像を漫画風に変換する研究が行われるようになってきた。しかしこのタスクでは、a)高度なシンプル化、抽象化が必要 b)はっきりした輪郭、滑らかな色調変化、シンプルなテキストの実現が難しいという問題があった。この問題は本研究で目的としている、動画のアニメーションへのスタイル変換にも言えることである[4]。そこで我々は、2章で述べる Cartoon GAN[1]を活用することで、アニメーションらしいスタイルを出力している。

2. 関連研究

近年、画像のスタイル変換に関する研究では多くの場合、Ian Goodfellowらが2014年に提案したGANを基本として用いている[5]。本稿1節内のa), b)で説明したような、画

連絡先: 森山紘行, 首都大学東京大学院, moriyama-hiroyuki@ed.tmu.ac.jp

像の漫画風スタイル変換における問題点を解決するため、Cartoon GAN[1]では2つの新しい損失関数を活用している。一つは写真と漫画の間のスタイル変換に対応するため、VGGnetの高レベルな特徴マップの疎な正規化で定式化されている semantic content loss である。またもう一つは、鮮明なエッジの維持が目的の edge-promoting adversarial loss である。これらの工夫により、現実世界の画像から漫画風画像へのスタイル変換が成功している。

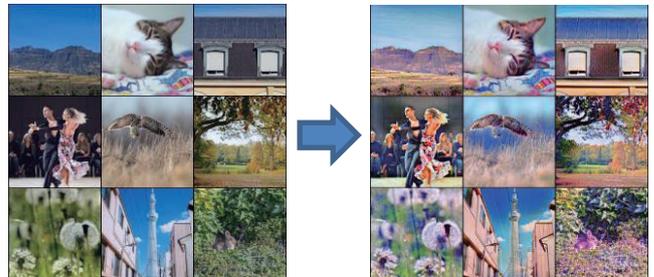


図1. Cartoon GANを用いたスタイル変換の例

また、動画から動画へのスタイル変換タスク[4]にも焦点が当てられるようになってきている。このタスクにおいては、three stream(3次元畳み込み)かtwo stream(2次元畳み込みと時間的処理の組み合わせ)が主流となっている。Three stream[4]では、3次元の畳み込みを用いた、時空間変換器を提案し、この問題への1つの解決法であるとしている。しかし、3次元の畳み込みによる手法では動画内の動作情報を的確に捉えているのが明確には示されておらず、動画生成に適用するのは困難である。また、two streamとしてはLSTMを時間的処理として用いている[6][7]のものもある。しかし、LSTMは動画全体の特徴を取れない問題があり、これも動画生成への適用は難しい。

そこで本稿では、動画内全体に対して動きの特徴を取得するため、動画のスタイル変換における新規手法を次の3章のように提案する。

3. 提案手法

動画は、連続した画像フレームによって成り立っている。そこで本手法では、Cartoon GAN[1]を各画像フレームの生成用に用いる。動画と画像の違いは、動画は空間特徴だけでなく、時間的特性をも各フレーム間に持っていることである。我々の研究目標は滑らかなアニメーション生成であるため、次の 3.1 節で述べるようなオプティカルフローを時間的特性として用い、図 2 で示すシステム構成によるアニメーション生成を行った。

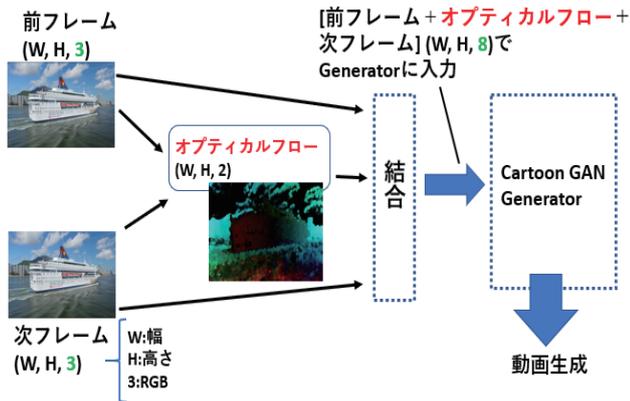


図 2. システム構成図

3.1 オプティカルフロー

近年の研究により、オプティカルフローは動画生成において効果的な手法であることが分かっている [8]。そこで我々の手法では、2 つの画像フレーム間の差分ベクトルを計算するのにこれを用いた。

オプティカルフローには、疎と密、2 つのアルゴリズムがある。疎のタイプは画像内の特定の特徴点のみを分析するときに適用され、密のタイプは画像内の全てのピクセル移動に適用される。今回、2 つの画像フレーム間における、全ての差分ベクトルを取得して用いるため、密なオプティカルフローとして Gunnar-Farneback 法を利用した。

3.2 Generator への入力

2 次元の畳み込みは、画像処理の特徴抽出における重要な技術の 1 つである。今回、Cartoon GAN に用いられている VGG や Resnet など、事前に学習済みの Imagenet を活用することで、空間特徴処理に向けた 2 次元畳み込みを利用出来る。また時間的特性に関しては、3.1 節で述べたオプティカルフローを適用している。

Cartoon GAN の generator に入力する前に、オプティカルフローによる処理を行う。動画に使われている画像フレームの中から、2 つを取り出す。画像は幅 W 、高さ H 、色の RGB からなるため、 $(W, H, 3)$ の配列を持つ。前の画像と次の画像とでオプティカルフローを計算した結果、差分ベクトルとして 2 チャンネルの配列が返ってくる。従って、 $(W, H, 2)$ の配列となる。

前と後の画像フレーム、そしてオプティカルフローの配列を結合した $(W, H, 8)$ の配列を Cartoon GAN の generator に入力し、動画生成を試みた。

4. 実験

実験に向け、我々は現実世界の動画とアニメーション動画のデータセットを用意した。これらは youtube と pixabay の中からそれぞれ人手で集めた。本稿 3 章で提案したシステムと用意したデータセットで実験を行った結果、図 3 のようなアニメーションが生成された。

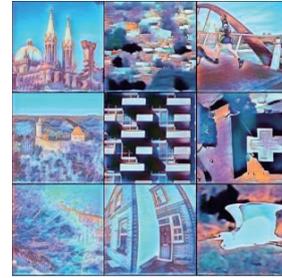


図 3. 生成されたアニメーション

5. まとめ

我々は、アニメーション生成において Cartoon GAN を利用し、generator への入力として、2 つの画像フレームとその間の差分ベクトルであるオプティカルフローを利用する手法を提案した。結果として、動画のアニメーションへのスタイル変換を行うことが出来た。

今後は、この生成結果を他のアニメーション生成手法とも比較し、動画の滑らかさについて評価を行う。

参考文献

- [1] Y. Chen, Y.-K. Lai, and Y.-J. Liu, "CartoonGAN": Generative Adversarial Networks for Photo Cartoonization," Cvpr2018, pp.9465-9474, 2017
- [2] G. Kucharska, "How much does it cost to produce animation – and why?" <https://www.studiopigeon.com/blog/how-much-does-it-cost-to-produce-animation-and-why/>, 05,01,2018.
- [3] J. Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks," Proceedings of the IEEE International Conference on Computer Vision, vol. 2017-October, pp.2242-2251, 2017.
- [4] D. Bashkurova, B. Usman, and K. Saenko, "Unsupervised Video-to-Video Translation", no. Nips, 2018.
- [5] 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, pp.2672-2680.
- [6] Mittal, Gaurav, Tanya Marwah, and Vineeth N. Balasubramanian. "Sync-Draw: Automatic Video Generation using Deep Recurrent Attentive Architectures." Proceedings of the 2017 ACM on Multimedia Conference. ACM, 2017.
- [7] Li, Yachao, and Toshihiro Komma. "Generating Videos Based on Convolutional Recurrent Generative Adversarial Networks." International Conference on Geometry and Graphics. Springer, Cham, 2018.
- [8] H. Jiang, D. Sun, V. Jampani, M.-H. Yang, E. Learned-Miller, and J. Kautz, "Super slo-mo: High quality estimation of multiple intermediate frames for video interpolation," arXiv preprint arXiv:1712.00080,2017.

VR 環境と生体情報を用いた映像コンテンツの評価及び分析

Evaluation and Analysis of Video Contents Using Physiological Information and VR Environment

浦地 勇人*¹ 松村 昂輝*¹ フアン ロレンゾ ハガド*¹ 福井 健一*² 沼尾 正行*²
 Hayato Uraji Koki Matsumura Juan Lorenzo Hagad Ken-ichi Fukui Masayuki Numao

*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 大阪大学産業科学研究所

The Institute of Scientific and Industrial Research, Osaka University

Abstract: By evaluating the effect of the video content, the content creator can know how the viewer felt his work. In this evaluation process, traditionally self-report type questionnaire data has been used. However, since this method involves participant bias, experimenter bias, or human diversity, accurate evaluation is difficult. Also, in order to eliminate these as much as possible, it is necessary to obtain an appropriate subject, which is high cost. In order to deal with these problems, this study proposes a method to complement physiological information in addition to questionnaires when evaluating emotional response to video contents. Specifically, it is a combination of subjective self-report questionnaire and heart rate variability. It is the viewer of short television commercials and news programs that are watched via the VR headset platform. Analysis was done using support vector machine and random forest. As a result, effective models and analysis results were obtained.

1. はじめに

伝統的に、テレビコマーシャル(TVCM)やその他の消費者向けの映像コンテンツの評価はアンケートを用いて実施されてきた。しかしながら、近年の研究では映像コンテンツの評価に生体情報を利用する試みが広がっている。従来のアンケートを用いる手法では、複雑な感情や考えを言葉のみを用いて表現しなければならず、その回答は言葉による短いフィードバックに限られ、必ずしも本当の感情を取得できているとは限らない。言葉のみで正しい感情を必ずしも取得できない理由として、人間は社会的な動物であるので、実験者の期待に応じようとしてしまい、回答に影響を与えてしまうことがある。人間の意志決定は言葉で表現できるほど論理的ではない。それゆえ、人間の感情と考えを言葉のみで表現するのは難しく、その正確性は限られる。これらの理由で、生体反応に基づいて感情や考えを測定する取り組みが進んでいる [5]。しかしながら、生体情報(ECG)を用いて感情を予測する研究は多くなされているが、コンテンツそのものを評価するような高次の感情を予測する研究はほとんどない。また ECG は信頼性の高い生体情報であるが、その反応性はそう良くないと考えられており、日本のテレビコマーシャル(TVCM)にあたる 15 秒間といった動画にはほとんど用いられない。さらに、多くの研究では、実験室のような管理された空間で高価な器具を用いて実験を実施するため、アンケートよりも費用や労力を必要とし、実社会での企業等の利用は困難である。

本研究では、心電図(ECG)からニュース動画の視聴者が内容をわかりやすく感じているのかどうかのモデルと、TVCM の視聴者がその動画を好きかどうかを診断する 2 つのモデルを構築した。その結果 nn50 という特徴量に着目することで、ニュースのわかりやすさという高次の感情を予測できることが示された。それに加え、15 秒間という短い動画でも信頼性の高い生体情報である ECG から感情を予測できることも示された。実験には VR ヘッドセットと安価な器具を使用し、コンテンツへの没入感を高めることで、高い学習精度を実現するデータを取得した。

連絡先: 浦地勇人 大阪大学大学院情報科学研究科
 (surname)@ai.sanken.osaka-u.ac.jp

2. 関連研究

感情を取得する方法の一つとして心電図(ECG)を用いたものがある[2]。これらの感情は自律神経によって引き起こされる変化と強い相関があり、その変化を拡張することで、人間の感情にまで広げることができる[4]。そのため、脳波計(EEG)と皮膚コンダクタンス反応(GSR)も一般的に感情分析に用いられる。

Ramzan et al.[3]は心電図(ECG)と脳波(EEG)を用いて映像コンテンツを視聴した際の感情を予測した。彼らの研究では感情価と覚醒度を教師データとして機械学習モデルを構築している。多くの先行研究と同じように、感情を引き起こす刺激として映像コンテンツを用いており、使用される動画はある感情を引き起こすのに適したものとなっている。そのため、一般的な映像コンテンツより感情を引き出すことが容易であり、生体情報にも反映されやすい。TVCM と視聴者の感情との関連を分析したものに Granero et al.[1]の研究がある。この研究では ACE スコアを参考指標として使用している。ポジティブ、ネガティブおよびそのどちらでもないという3つの感情を割り当て、これを使用して視聴者がどのように感じたのかを識別した。彼らの研究では EEG、ECG そして GSR を用いて、感情を予測するのに最も良い特徴量とアルゴリズムを発見することを目的としている。その結果、GSR と ECG から最も良い特徴量が得られることがわかった。この研究ではアメリカの TVCM を用いているため、30 秒や1分間の動画によるデータとなっており、日本で一般的に使用される 15 秒間の TVCM の動画では、ECG と GSR の反応性の低さから正確な予測に有効な特徴量とならない可能性がある。またその動画の長さの違いから日本の TVCM では物語やメッセージ性を持たせられず、印象に残りやすいよう考えられた動画構成となっているのに対し、アメリカの TVCM では物語性を持たせるなど文化的な違いもある。

3. 目的

本研究では、アンケートデータと生体情報を用いて映像コンテンツの評価を実施した。そうすることで、映像コンテンツのより良い評価と調査の利便性向上を目指す。従来のアンケートデータのみを用いた手法では、上記の制約に加え、被験者の質

を確保しなければならないという問題もある。質の高い被験者とは、実験に協力的で精力的に取り組み、実験者に極力配慮しない等の要素を持った人物である。評価実験のための被験者を集める際、こうした点に注意した上で被験者を集めるには多大なコストがかかってしまう。またデータを集めるためには、実験後等に回答を得る時間が必要となり、これも高いコストが必要となる。よって本研究では、質の高い被験者から得られたアンケートデータを用い、生体情報からモデルを構築し、映像コンテンツを評価する。そうすることで、評価の際にアンケートを実施することなく映像評価することができるようになり、被験者の質に関してもアンケートのみを用いるより注意が必要ではなくなる。それに加え、有用な特徴量を発見し、アンケートデータを用いずにモデルを構築する際の道標とすることが可能である。また生体情報による評価をするにあたり、コンテンツへの没入がより必要になる。生体情報には当然ながら評価対象のコンテンツ以外の刺激からの情報も含まれてしまい、コンテンツ以外の刺激を極力減らす必要がある。これらを踏まえ、本研究では、VR 環境下で実験を実施した。

4. 方法概要

本研究では、ニュース番組と 15 秒間の日本のテレビコマーシャルの2種類の映像コンテンツを分析した。

ニュース番組では、様々な種類のテロップを付与するかどうかで、内容のわかりやすさに影響があるのかを分析した。感情認識において最も信頼できる生体情報の一つであるので、ここでは ECG を使用する。同じニュース番組にテロップを付与した3種類の動画を比較した。1つ目はテロップをつけないもの(N)、2つ目は装飾のあるテロップ(A)、そして3つ目はシンプルなテロップ(B)のものである。全部で 24 名の被験者に対して実験を実施した。2分 15 秒間の動画を視聴したのち、複数の解答項目とともにその動画の内容がどのように理解しやすかったのかを取得した。これらの質問から、5段階のニュース動画のわかりやすさを取得した。機械学習モデルを構築し、これらのデータから学習とテストを実施し、分析に有用な特徴量が判明した。またそこからコンテンツのわかりやすさとの関連を分析した。

2つ目のデータセットはテレビコマーシャル(TVCM)から取得され、3種類の 15 秒間の短い動画を比較した。その際、テレビコマーシャルを好き、嫌いまたそのどちらでもないのかを5段階で取得した。こちらのデータセットでも短い動画のデータにも ECG のデータが有用か調査するため ECG を使用した。

5. VR ON AIR TEST

本研究では、SOOTH 社によって開発された VR OAT(VR ON AIR TEST) [6]を用いてデータを取得した。このシステムでは、VR 環境下における、動画視聴者の動作を取得できる。タッチ式のデバイスを用いて、アンケートに回答し、複数の生体センサーがそのプラットフォームに内蔵されている。VR 環境はユーザーがコンテンツに没入できるという利点がある。さらに、既存のプラットフォームと比較して、使用しているツールが安価かつ着脱も容易である。このように、実社会で企業等が実施する映像コンテンツの評価により適していると期待される。

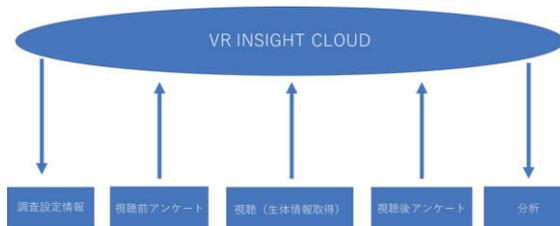


図1: VR ON AIR TEST

このように、タブレット端末から属性やアンケートな回答を取得でき、VR 上で映像コンテンツの視聴と EEG をはじめとする様々な生体情報を取得できる。そしてこれらのデータをクラウド上で管理することもできる。

6. 実験手続き

以下の項では2つの動画視聴の実験をどのように実施したかの詳細を述べる

6.1 ニュース動画

20代の男女24名の被験者が2分 15秒間のニュース番組を視聴した。アンケートは動画の視聴前と視聴後にそれぞれの動画に対して実施した。その間、ECG および EEG のデータを取得した。3種類のテロップを付与した動画を使用した。1つ目はテロップをつけないもの(N)、2つ目は装飾のあるテロップ(A)、そして3つ目はシンプルなテロップ(B)のものである。全ての被験者24名が動画 N を視聴し、その後24名を二つのグループに分割し、それぞれ A か B どちらかの動画を視聴した。全てのテロップは動画の内容について述べられたものである。

6.2 テレビコマーシャル

テレビコマーシャルの動画を20代から50代の男女 213名の被験者が視聴した。ニュース動画のようにセンサーを用いて生体情報を取得した。テレビコマーシャルは 15 秒間の動画 3 本で、同一商品について競合する 3 社によるものを用いた。アンケートも同様に、視聴前と視聴後に実施した。

7. 特徴量

7.1 ニュース動画

最初の実験のアンケートから、ニュース動画のわかりやすさを述べるため五段階の評価を得た。

- 1:非常にわかりにくい
- 2:わかりにくい
- 3:どちらでもない
- 4:わかりやすい
- 5:非常にわかりやすい

テロップなしの動画から5段階すべての評価の反応を得た。

しかしながら、テロップなしの動画からの評価はすべての評価が4以上であった。このことからテロップはニュース動画のわかりやすさを改善するのに効果的であったと考えられるが、追加の検証が必要である。それゆえ、アンケートの反応が生体反応と一致するかどうか分析した。段階1と2および段階 4 と 5 を区別することは困難であるので、1と2を「わかりにくい」、4 と 5 を「わかりやすい」に統合した。

7.2 テレビコマーシャル

TVCM から、11のシーンとそれぞれのシーンに番号を付与した。それぞれのシーンと時間は表 1 に示した。また動画の好き、嫌いに関しても同様に以下の 5 段階の評価を取得した。

- 1: 非常に嫌い
- 2: 嫌い
- 3: どちらでもない
- 4: 好き
- 5: 非常に好き

これらのアンケートに対してすべての動画において、嫌いと回答したものは非常に少なかった。そのため、「どちらでもない」及び好きの 2 段階に統合した。

7.3 ECG データ

心電図は、心臓内で発生する電気的な変化によって引き起こされる。心臓が収縮し、体表からの電位として検出されたとき、電気信号のピークは P、Q、R、S、T のように名付けられる。R は最高点を表し、R と R の間隔 (RRI) は常に一定ではなく変動する。この変動は感情との強い結びつきを持つ心理的影響も反映している。以下の図 2 にこれを示す。

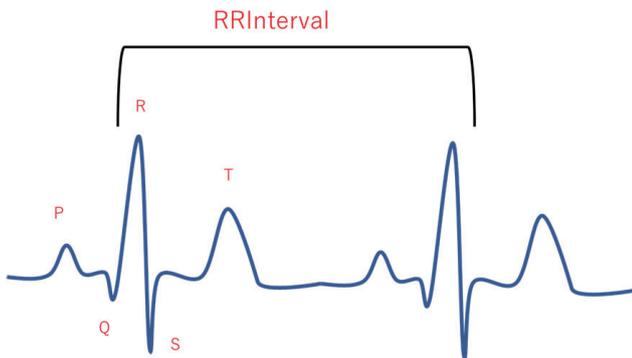


図2:心電図と RRI

ここでは、Neurosky[7]を使用して ECG データを収集し、RRI から得られる以下の特徴量を抽出した。

- RMSSD - 連続する RR 間隔の差の二乗平均平方根
- SDNN - RR 間隔の標準偏差
- NN50 - 連続する隣接 RR 間隔の差が 50 ミリ秒を超えた数の割合
- PNN50 - 連続する隣接 RR 間隔の差が 50 ミリ秒を超えたものの割合
- HF - 高周波帯域のパワー (0.15~0.4 Hz)

8. モデル

アンケートからの教師データと生体情報から機械学習モデルを構築した。使用したアルゴリズムはサポートベクターマシン (SVM) とランダムフォレスト (RF) である。実装には python の機械学習ライブラリーの scikit-learn を使用した。

8.1 ニュース動画モデル

学習は ECG から得られる様々な特徴量を用いて実施した。機械学習のモデルを用いて、データの構造を分析するため ECG のデータは 10 秒間隔毎に分割し、それぞれから特徴量を

算出した。24 名の被験者のうち、欠損等のため信頼性の高いデータが得られたのは 15 名のみであった。それゆえ 15 名のデータを用い、4 分割の交差検証を実施した。教師データにはアンケートから得られたニュース動画のわかりやすさを使用し、SVM にてこれを予測した。その際、カーネル及びハイパーパラメータはグリッドサーチにて最適化を行った。

またそれに加え、RF を用いて特徴量の重要度も算出した。モデルのパラメータは同様にグリッドサーチにて最適化され、15 名すべてのデータを使用した。

8.2 テレビコマーシャルモデル

学習はニュース動画モデルと同様に ECG から得られる特徴量を用いて実施した。TVCM でも ECG のデータは前半 10 秒間と後半 5 秒間に分割され、値を算出した。欠損等のため信頼性の高いデータが得られたのは 20 名 (好き 10 名、どちらでもない 10 名) のみであった。それゆえ 20 名のデータを用い、4 分割の交差検証を実施した。教師データにはアンケートから得られた TVCM の好みを使用し、SVM にてモデルを構築した。TVCM のモデルでも、カーネル及びハイパーパラメータはグリッドサーチにて最適化を行った。

9. 結果

9.1 ニュース動画の結果

SVM によってニュース動画 (N) のわかりやすさを識別した結果を表 1 に示す。使用したカーネルは rbf カーネル、線形カーネル (linear)、多項式カーネル (poly) で表の model に示す。特徴量 (feature) は 7.3 のものを用いた。

表 1: 動画 N によるデータセットの予測結果

model	feature	training	test	recall	f-value
rbf	nn50	100	72.9	66.7	59.4
poly	rmssd	84.3	52.1	45.8	42.2
rbf	hf	46.6	45.8	33.3	20.8
linear	sdnn	97.7	33.3	33.3	23.6
rbf	pnn50	100	45.8	45.8	36.1

これらの結果から、最も有効な特徴量は nn50 であった。

次に、動画 N のデータから学習した 4 つの交差検証のモデルを使用して、テロップを付与した動画 (A, B) の値を予測した。表 1 から nn50 が最も高い精度を示したため、ここでは nn50 を使用する。注意すべき点として、テロップを付与した動画からは「わかりやすい」の単一の教師データしか得られておらず、トレーニングセットには使用できない。このデータセットは合計 20 (A が 11、B が 9) 個からなる。識別結果は以下の表 2 に示す。

表 2: テロップあり動画の予測結果

data	model	feature	test
A	rbf	nn50	100
B	rbf	nn50	100

予測結果はアンケートの回答と完全に一致した。このことから、テロップを付与することで被験者はニュース動画をわかりやすく感じるようになったということが生体情報からも検証された。

続いて動画 N を学習データ、アンケートを教師データとしてランダムフォレストにて学習器を構築した。この学習器から特徴量の重要度を得た。これを時間順にならべ、動画と比較した。その結果を以下の図 3 に示す。

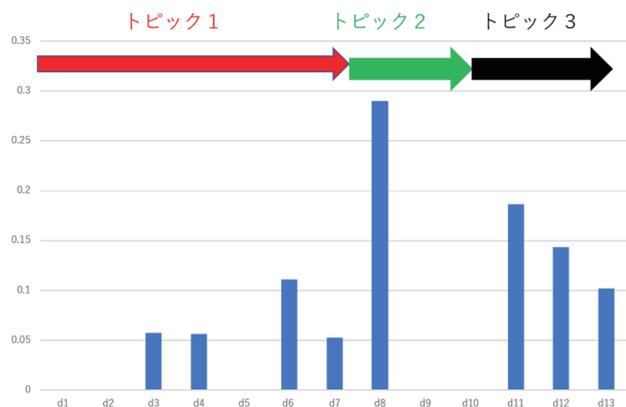


図3: 時間毎の特徴量の重要度とニュース動画の比較

横軸は動画の時間を表しており、縦軸は重要度の割合を表している。d1は動画開始時(0秒)からの10秒間を表しており、d2,d3...d13はそれぞれその後10秒間毎の値を表している。ここでは特徴量に nn50 を使用している。

この図から重要度の高い時間に注目し、動画と対応づけるとあるトピックの終盤に集中していることがわかる。このニュース動画は3つのトピックからなっており、重要度が高い時間帯はそれぞれトピックの終盤と一致している。このことから生体情報にもトピックの終盤にコンテンツのわかりやすさに対する反応が現れることがわかる

9.2 テレビコマーシャルの結果

SVM によってテレビコマーシャルを好きか、そうでないかを識別した結果を表3に示す。

表3: テレビコマーシャルの予測結果

model	feature	training	test
linear	nn50	74.8	70.8
linear	sdnn	74.6	66.7

この結果から、日本のテレビコマーシャルのように短い動画であっても、ECG から感情を予測できることがわかる。また、こちらでも nn50 が最も有効な特徴量であった。

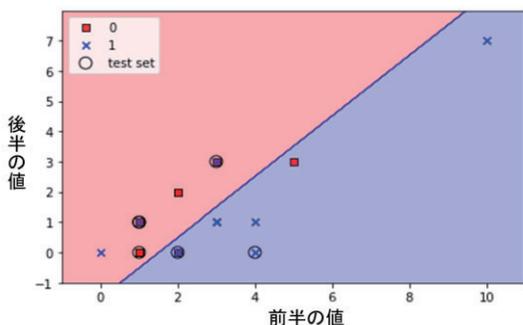


図4: TVCM モデルの nn50 決定境界

図4に nn50 を用いて得られた SVM の決定境界を示す。0が「どちらでもない」、1が「好き」を表す。このように、前半に比べ後半の nn50 値が減少すれば、好きと回答する傾向が見受けられた。

9.3 まとめ

ECG から得られる特徴量に基づき、ニュース動画のわかりやすさを識別する学習器を得た。テロップを使用した場合、全ての被験者がニュース動画を少なくともわかりやすかったと評価した。この結果が本当にそうであるのか、実験効果によるものかを検証するため、テロップ無しの動画から得られたデータセットでモデルを学習させた。その結果、検出されたニュースのわかりやすさとアンケート結果は完全に一致した。そのようにして、本研究ではアンケートの回答の信頼性をどのように検証するのかわを示した。またテロップの存在がニュース番組の理解において有効であることも判明した。さらに、ECG の特徴量の中でニュース番組のわかりやすさと最も強い相関を持つものが nn50 であることがわかった。また特徴量の重要度を算出し、その結果ニュース番組におけるそれぞれのトピックの終盤の重要度が高いことも判明した。

次に、同様に ECG を用いて TVCM から感情を推定するモデルを得た。この感情は TVCM が好きなのか、そうでないのかの2種類を使用した。その結果日本の TVCM のように短い動画でも ECG を用いて感情を推定できることが示された。

10. おわりに

本研究では、ECG から動画の視聴者の感情を診断するモデルを構築した。構築したモデルはニュース動画の内容をわかりやすく感じているのかを診断するモデルと、TVCM を好きかどうかのモデルである。その結果、ECG から取得できる nn50 という特徴量を用いることで動画の評価に関連する高次元な感情を取得できることが示された。また TVCM のような短い動画でも nn50 を用いることで感情を予測できることが示された。これらは VR ヘッドセットと安価な器具を用いて実施しており、VR 環境によって使用者の没入感を高め、高精度の感情予測に使用可能なデータを取得できることも示された。

より信頼性の高い評価を得るため、これらの自動化された映像評価を従来のアンケート結果と組み合わせることが可能である。この自動化された映像評価の精度がさらに向上すれば、アンケートを使用しない評価も可能になると考えている。

参考文献

- [1] Granero, A. C.; Fuentes-Hurtado, F.; Ornedo, V. N.; Provinciale, J. G.; Ausin J. M. and Raya, M. A. Comparison of Physiological Signal Analysis Techniques and Classifiers for Automatic Emotional Evaluation of Audiovisual Contents, *Front. Comput. Neurosci.*, 15 July 2016
- [2] Shaffer, F. and Ginsberg, J. P. An Overview of Heart Rate Variability Metrics and Norms, *Front. Public Health*, 28 September 2017
- [3] Ramzan, N.; Palke, S.; Cuntz, T.; Gibson, R. and Amira, A. Emotion Recognition by Physiological Signals, 2016 society for Imaging Science and Technology
- [4] Quintana, D. S.; Guastella, A. J.; Outhred, T.; Hickie, I. B.; Kemp, A. H. Heart rate variability is associated with emotion recognition: Direct evidence for a relationship between the autonomic nervous system and social cognition, *International Journal of Psychophysiology* 86 (2012) 168–172
- [5] 広志熊倉. ニューロマーケティングの現状、課題そして展望(特集ニューロマーケティング). *オペレーションズ・リサーチ*, Vol. 61, No. 7, pp. 421–428, jul2016
- [6] <https://www.vr-insight.com/en/oat.html>
- [7] <http://neurosky.com/>

VRと脳波計測を用いたBGM推薦のための潜在感覚推定方法の提案

Proposal of latent sensory estimation method for BGM recommendation using VR and EEG measurement

川野 陽慈^{*1}
Yoji Kawano

佐藤 季久恵^{*2}
Kikue Sato

高屋 英知^{*1}
Eichi Takaya

須賀 聖^{*1}
Satoshi Suga

山内 和樹^{*3}
Kazuki Yamauchi

栗原 聡^{*1}
Satoshi Kurihara

^{*1}慶應義塾大学 大学院理工学研究科

Graduate School of Science and Technology, Keio University

^{*2}電気通信大学 大学院情報理工学研究科

Graduate School of Informatics and Engineering, The University of Electro-Communications

^{*3}株式会社レコチョコク

RecoChoku Co.,Ltd.

The atmosphere of the place is formed by complicated combination such as visual information and auditory information. When designing the atmosphere, it is important to control visual information and auditory information. It is said that BGM has an *emotion inducing effect* and an *image guiding effect*, and it can be adjusted to the atmosphere of the place with a small effort. There are many shops where BGM is introduced to utilize those effects. However, it is difficult to select music in accordance with changing situations in the situation. In this research, we aim to construct a system that recommends BGM suitable for the atmosphere in a store. And in this paper, we proposed a method to extract impressions that people potentially hold by reading EEG. Also, by using VR, we conducted experiments in various spaces as if they were in real space.

1. はじめに

場の雰囲気というものは、人と人との間に流れる「空気」や視覚情報、聴覚情報、嗅覚情報などが複雑に絡み合うことによって形成されている。この場の雰囲気を人為的にデザインする場合、特に視覚情報（家具、調度品、壁紙）と聴覚情報（BGM）をコントロールすることが重要である。BGMには感情誘導効果やイメージ誘導効果があるとされており、小さな労力で場の雰囲気に合わせることができる。現に店舗などではそれらの効果を利用するためにBGMを導入しているところが多い。しかし、時間帯による店内の見え方や客層の変化により、店舗側はその都度雰囲気に合ったBGMを提供することが求められる。それぞれ異なる店内の雰囲気に合わせてBGM配信サービスが対応することや人手により選曲を行うことは困難である。このことから本研究では、店舗の雰囲気に適したBGMを推薦するシステムの構築を目指す。従来研究では、場の雰囲気から想起する人間の喜びや悲しみ、怒り（ストレス）、落ち着きなどの感性評価はアンケートやインタビューなどの測定方法が用いられていた。しかし、この評価方法では被験者の頭在意識に影響を受ける可能性がある。また、従来研究では、没入感のない画像を見て評価を行っており、現場にいる感覚での推薦に至らない可能性がある。そこで、本研究では人手による楽曲の印象抽出ではなく、脳波を読み取ることで人が無意識に抱く印象を抽出した。また、Virtual Reality(VR)を用いることで、あたかも現実空間にいるような環境で、あらゆる空間での実験を行った。

2. 関連研究

画像や楽曲といったコンテンツに対しユーザがタグ付けを行うことは、ソーシャルタギングと呼ばれ、これを利用した推薦や検索システムに関する研究は数多く存在する。坂井らは、室内の動画画像から店舗のラベルや時間帯、日差しの有無、都会

度合いのラベルをつけた。また、楽曲も同様にラベル付けし、それらの相関を求め店舗の雰囲気に適したBGMの推薦を行っている[坂井18]。Kaminskasらは、ユーザが関心のある場所(place of interest, POI)に即した楽曲推薦のシステムを構築している[Kaminskas11]。楽曲とPOIに双方同様の感情語を用いたタグをつけ、それらをベクトルとして扱い、類似度から適した楽曲を推薦している。タグには9項目の感情タグと13項目の物理的タグ(色や気温など)を用いている。いずれの研究も、感情語の抽出は人手でラベル付けした教師データをもとに行っており、主観的な評価をしている。また、画像や動画画像から想起する感情は、実際にその場にいる感覚が薄く、現場にいる感覚での推薦に至らない可能性がある。

3. 提案システム

本研究では、店舗の雰囲気に合わせたBGMを提供するシステムの構築を行う。場の雰囲気から想起する人間の喜びや悲しみ、怒り（ストレス）、落ち着きなどの感性は、直接測定できない場合が多い。そこで、本研究では脳波から感性をよみとり、被験者の感性の状態を定量的に把握する。また、現実の店舗での実験を行う場合、既にBGMがかけられているところが多く、他の顧客も存在することから容易に実験が行えるとは言えない。そのため、現実の空間を模したVR空間で実験を行う。VR空間では、現実の場で撮影したVR動画があれば、あらゆる場での実験が容易であり、動画画像を閲覧してBGM評価を行う実験と比べてより現実に近い環境での実験が可能である。そして、実際の店舗で流れるBGMは、イヤホンではなく、場から流れる音であることから、本研究では、イヤホンのように耳に密着させずに音楽を聞くことができる骨伝導型イヤホンでBGMを聞き、あたかも場から流れているような環境での実験を行う。実験環境として、図1のようにVR空間であらゆる空間にしながら骨伝導型イヤホンでBGMを、VRに装着しているスマートフォンでVR内での場面の音(環境音)を流し、額に装着した脳波計で脳波の計測を行う。

連絡先: 川野 陽慈, 慶應義塾大学 大学院理工学研究科,
yojimax822@keio.jp

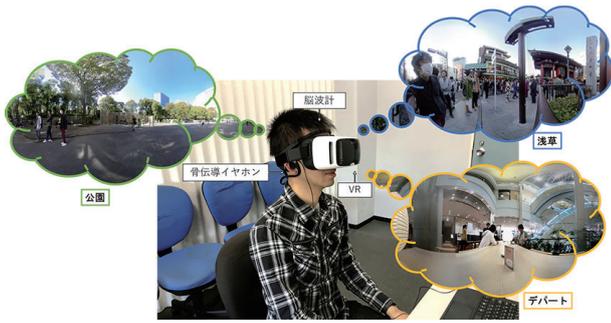
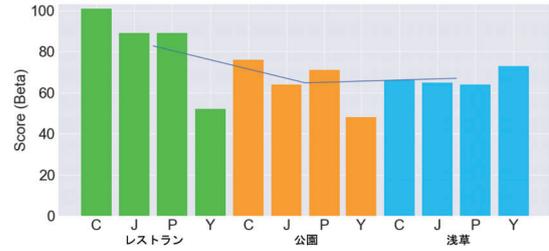


図 1: 実験環境

図 3: β 波の中央値のスコア

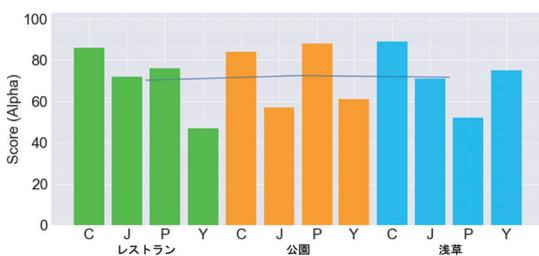
4. 実験

4.1 実験設定

実験環境としてなるべく異なる印象を想起する場としてレストラン・観光地・公園の3つをVR映像として用いた。また、音楽はBGMとして想定される楽曲をLoganら [Logan01] の手法によりクラスタリングで分類した。その結果から4つの楽曲(クラシック, ジャズ, ピアノ, 洋楽)を用い, 4曲とも音量が等しくなるよう調整した。このとき, 馴染みのある楽曲, 日本語の歌詞の流れる楽曲は, BGMとしてではなく個々の楽曲に対して意識が向いてしまうため除外した。1場面に対し4つの楽曲を1分50秒ずつ流し, 場面は, 楽曲が1巡する7分20秒後に切り替わるように設定した。被験者には, VR, 脳波計, 骨伝導型イヤホンを装着してもらった。VR内で3つの景色を眺めながら約22分間楽曲を聞く動作を21~26歳の男子学生13名に行ってもらった。

4.2 解析及び実験結果

脳波の解析の際, 加速度の大幅なずれがあるときの脳波は取り除いた。各シチュエーション(場面A, 楽曲aを流しているときを1シチュエーションとみなす)の後半30秒間のリラックスをしている時に現れる α 波 [Nitish13] と集中時に現れる β 波 [Nitish13] を記録し, その中央値を求めた。そして, シチュエーションごとの脳波の結果を見るために, ユーザごとに, α 波, β 波それぞれ中央値の値が最も高い順に, 12,11,10,...,1と得点付けを行った。得点付けした全ユーザの合計値をグラフで可視化した(図2, 図3)。図2から, 場面に限らず, クラシックはリラックス効果が高くなる傾向にあった。図3から, 場面ごとにみると, レストランのような閉鎖的な場では, 集中しやすい傾向にあった。また, レストランや公園等の落ち着いたある場では, 洋楽のような賑やかでアップテンポな曲では集中しにくい傾向がみられた。

図 2: α 波の中央値のスコア (C:クラシック J:ジャズ P:ピアノ Y:洋楽)

5. 結論

本研究では, 店舗内での雰囲気に合わせてBGMを推薦するために, 推薦するための楽曲評価を主観的なものではなく, 脳波計を用いることで, 潜在的な感覚で評価を行うシステムを提案した。また, 実験環境としてVRを装着し, 様々な場での実験を行った。その結果, 場の違いによってユーザが異なる感覚を想起する事が見られた。そして, 場と楽曲を変えたときのユーザの感覚を脳波計で抽出し, リラックス度合いや集中度合いといった, ユーザが潜在的に抱く感性をもとに楽曲の評価ができることが確認された。

今後は, この提案システムを大規模化し, 被験者実験を行う。また, 脳波以外にも心拍や血流, 発汗などの複数の生体信号を用いることでより高い精度でユーザの潜在的感覚抽出を試みる。最終的には, 実際の店舗の雰囲気を提案システムに入れ, 推薦されたBGMを提供するシステムを構築する。

参考文献

- [坂井18] 坂井栞, 高屋英知, 池田圭佑, 川野陽慈, 佐藤圭, 山内和樹, 大矢隼士, 栗原聡. 雰囲気を反映したbgm推薦システムの提案. 行動変容と社会システム vol.03, Vol. 2018, 2018.
- [Kaminskas11] Marius Kaminskas and Francesco Ricci. Location-adapted music recommendation using tags. In International Conference on User Modeling, Adaptation, and Personalization, pp.183-194. Springer, 2011.
- [Logan01] Beth Logan and Ariel Salomon. A content-based music similarity function. Cambridge Research Labs-Tech Report, 2001.
- [Nitish13] Nitish V Thakor and David L Sherman. EEG signal processing: Theory and applications. In Neural Engineering, pp. 259-303. Springer, 2013.

segmented VRAE と遺伝的プログラミングに基づく音楽の創作

Music Composition based on the Genetic Programming with segmented VRAE

山本 周典*¹ 森 直樹*¹
 Hironori Yamamoto Naoki Mori

*¹大阪府立大学工学研究科
 Graduate School of Engineering, Osaka Prefecture University

Automatic music composition is one of the most difficult and attractive challenges in the artificial intelligence (AI) field. In order to tackle this challenge, an approach using interactive evolutionary computation (IEC) is drawing attention because IEC takes human emotions into consideration. We have proposed an automatic music composition system based on IEC with a surrogate model called an evaluation model. In the previous study, the model is constructed with a Variational Recurrent Auto-Encoder (VRAE) to achieve quantitative evaluations. However, it is not easy for a simple VRAE to map tunes' features into a meaningful latent space regardless of their lengths.

This paper focuses on the way to map tunes with different length into a good latent space and the application for IEC. The evaluation model employs a hierarchical VRAE called segmented VRAE. The experiments are carried out to show the effectiveness of the proposed method.

1. はじめに

近年、計算機による楽曲の自動生成に関する研究が積極的になされており、新しい文化や産業の創造に繋がるとして多方面から強く期待されている。しかしながら、作品の評価は個人の嗜好や感性に大きく依存するため、これを定量的に評価することは非常に困難とされている。このような問題に対して、人間の評価系そのものを評価関数として最適化システムに導入した対話型進化型計算 (Interactive Evolutionary Computation: IEC)[Takagi 98] が注目をされている。

そこで我々はこれまで、適応度景観を学習し近似的に評価関数を推定する surrogate model[Jin 11] を応用した IEC による対話型楽曲自動生成システムを提案してきた。[山本 18] この従来システムでは、楽曲を表現するために音高および音価の概念を反映した木構造を用いた。また、Genetic Programming (GP) の拡張手法である Genetic Programming with Multi-Layered Population Structure (MLPS-GP)[Hasegawa 17] を楽曲の探索アルゴリズムとして用いた。surrogate model としては評価モデルと呼ばれるモデルを作成し、ユーザに代わって評価モデルに近似的に楽曲評価をさせることで IEC におけるユーザ負荷の問題を軽減した。この評価モデルにおける評価の過程では生成モデルの一種である Variational Recurrent Auto-Encoder (VRAE)[Fabius 14] を用いた。VRAE は Variational Auto-Encoder (VAE)[Kingma 13] の拡張手法で、VAE と同様に入力データが潜在的に内包している意味を反映しつつ写像した潜在空間を構築することが可能である。従来システムの楽曲評価では、潜在空間内における楽曲の潜在変数を評価の対象とすることで定量的な楽曲評価を実現した。しかしながら、単純な構造を持つ VRAE の場合、楽曲のような可変長データをその長さに関係なく適切な潜在変数に写像することは難しい。

本研究では以上の点を背景として、segmented VRAE と称す階層構造をもった VRAE に基づく対話型楽曲自動生成システムを提案する。segmented VRAE では楽曲を一定幅ごとに

潜在変数に写像し、楽曲を複数の潜在変数によって扱う。この結果、楽曲の全体の長さによって左右されることなく潜在変数を獲得することができる。得られた潜在変数をもとに適応度関数を作成することで、より入力楽曲の要素を適切に反映した楽曲生成を目指す。

2. 提案モデル

本章では VRAE の概要および本システムで用いた segmented VRAE について説明する。

2.1 Variational Recurrent Auto-Encoder

VRAE[Fabius 14] は VAE[Kingma 13] と呼ばれる生成モデルの拡張手法で、エンコード部およびデコード部で Recurrent Neural Network (RNN) を使用している。このため楽曲のような時系列データに適している。VAE および VRAE の目的関数は、潜在変数の確率分布の形状に関わる項 (latent loss) および潜在変数を事前分布として元データの復元に関わる項 (reconstruction loss) で構成される。

2.2 segmented VRAE

次に、segmented VRAE について説明する。segmented VRAE は階層的な構造を持ち、入力データを幾つかの部分列に分けて扱う。

図 1 に segmented VRAE の構造を示す。segmented VRAE ではエンコード部において入力 x を n_x 個の部分データに分解し、各部分データに対応する潜在変数の集合 $Z = \{z_x^{(i)}\}_{i=1}^{n_x}$ を得る。また、デコード部では得られた潜在変数を上層の RNN に入力し、得られた出力を下層の RNN の初期状態および入力に結合する。各部分データの入力の初期値には“EOS” タグを入力する。本研究ではエンコード部では Bi-Directional RNN を使用し、デコード部では Long Short-Term Memory (LSTM) [Schmidhuber 97] を使用した。

3. 楽曲の自動生成システムの概要

本章では進化型計算を用いた楽曲自動生成システムについて示す。

連絡先: 山本 周典, 大阪府立大学 工学研究科, 大阪府堺市市区
 学園町 1-1, 072-254-9273, h.yamamoto@ss.cs.osakafu-
 u.ac.jp

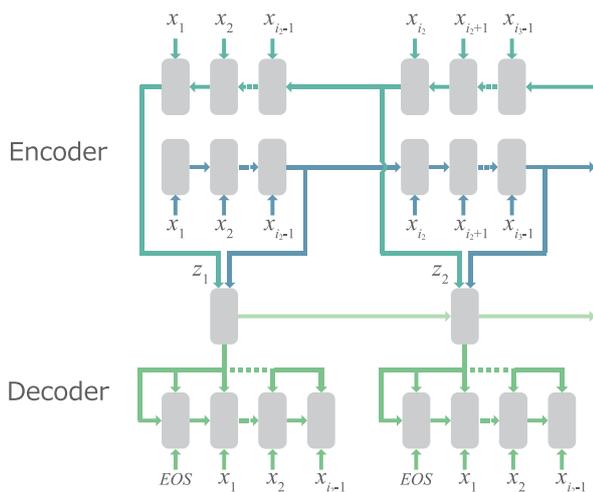


図 1: segmented VRAE の構造

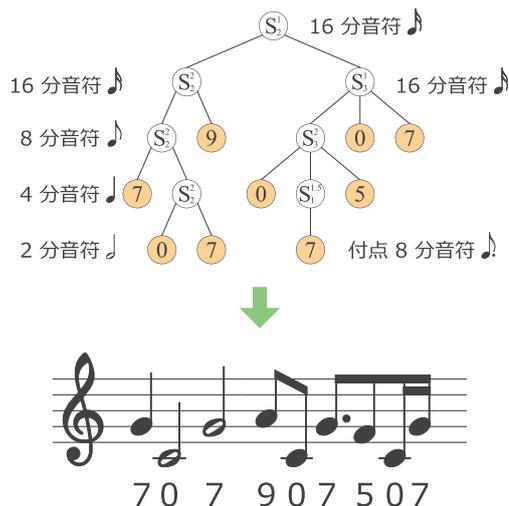


図 2: 木構造と楽譜の対応関係の例

3.1 提案システムの流れ

本システムはユーザの嗜好に沿った曲をユーザの評価に基づいて進化的に獲得することを目的としたシステムである。以下、評価モデルが楽曲の特徴量を学習するのに使用した曲を入力曲、進化型計算による探索中の個体を探索曲、探索終了後のエリート個体を進化曲と呼ぶ。

1. 入力曲に基づいて評価モデルが構築される。
2. 評価モデルによって探索曲を近似評価し、この評価に従い MLPS-GP が進化曲を生成する。
3. ユーザが進化曲を実評価する。
4. 評価モデルがユーザの実評価に基づいてユーザの嗜好を推定し、さらに IEC により評価モデルを更新し、初期個体群に進化曲を反映する。
5. ユーザが満足する曲が生成できた場合は終了する。そうでなければ 2. に戻る。

ただし、本研究では評価モデルによる近似評価に対して主眼を置くため、以下 2. までを対象として述べる。

3.2 入力曲の定義

本研究では、入力曲を一般入力曲および選好入力曲の 2 種類に大別し、評価モデルに学習させる。一般入力曲とは人が普段から耳にし聴き心地の良いと感じるような普遍的な曲のことで、これらを大量に学習することによって汎用的な楽譜情報の獲得が期待される。一方、選好入力曲とは、進化曲の特徴付けのために一般入力曲の中から抽出された曲のことで、ユーザの嗜好を獲得することが期待される。本システムでは、一般入力曲の学習によって獲得した普遍的な楽曲の特徴およびユーザに選択させた選好入力曲の特徴を組み合わせることで、ユーザの嗜好に合った進化曲の獲得を目的としている。

3.3 個体表現

本研究では GP を適用するために曲を木構造によって表現する。この木構造によって曲の音高および音価が表現可能である。図 2 に、GP における曲の個体表現と楽譜の対応関係を示す。終端ノードを音高とし、非終端ノードを子ノードへ

の音高の倍率および子ノードへの分岐数とした。 l を子ノードの音価への倍率、 m を子ノードへの分岐数として、非終端ノードを S_m^l で表す。 l, m に関しては、 $l \in \{1.0, 1.5, 2.0\}$ 、 $m \in \{1, 2, 3, 4\}$ と定めた。また本研究では、根ノードの音価を 16 分音符で固定し、終端ノードは 3 オクターブ分に対応する 36 種類を用いた。なお、 $S_m^{1.5}$ に関しては付点音価を表現することを目的としているため、ある終端ノードの音価を計算するに際して、その親ノードが $S_m^{1.5}$ の場合においてのみ音価を 1.5 倍とし、それ以外の $S_m^{1.5}$ に関しては音価を 1 倍とするように設定した。木構造表現から楽譜に変換する際は、終端ノードに関して深さ優先探索の先行順で辿ることによって変換がなされる。

3.4 適応度

ここでは MLPS-GP で最適化する際に用いる適応度について示す。適応度を計算するにあたって、事前に VRAE に対して一般入力曲を学習させる。次に、選好入力曲 $m_t (t \in \mathcal{N})$ をユーザが設定し、これらを VRAE のエンコード部によって潜在空間に写像することで、潜在変数の集合 $\mathbf{Z}_{m_t} = \{\mathbf{z}_{m_t}^{(i)}\}_{i=1}^{n_{m_t}}$ を得る。また、探索曲 x についても同様に潜在変数の集合 $\mathbf{Z}_x = \{\mathbf{z}_x^{(i)}\}_{i=1}^{n_x}$ を算出し、これらをデコードすることで \hat{x} を得る。

以上の変数を用いて、探索曲 x に対する直接的な評価指標である個体評価値 $f(x)$ を定義していく。個体評価値 $f(x)$ は以下の 2 項目によって定義される。

- ユーザ設定の選好入力曲 m_t および探索曲 x の類似度 $f_d(m_t, x)$
- 探索曲 x に対する外れ値検知項 $f_o(x, \hat{x})$

3.4.1 楽曲間距離 $f_d(m_t, x)$

ユーザ設定の選好入力曲 m_t および探索曲 x の類似度は潜在変数間の Kullback-Leibler 情報量 (KL 情報量) をもとに算出する。選好入力曲の潜在変数 $\mathbf{Z}_{m_t} = \{\mathbf{z}_{m_t}^{(i)}\}_{i=1}^{n_{m_t}}$ および探索曲の潜在変数 $\mathbf{Z}_x = \{\mathbf{z}_x^{(i)}\}_{i=1}^{n_x}$ に基づき、楽曲間距離 $f_d(m_t, x)$ を以下で定める。

$$f_d(m_t, x) = \frac{1}{n_{m_t} n_x} \sum_{v=1}^{n_{m_t}} \sum_{w=1}^{n_x} D_{\text{KL}}(\mathbf{z}_{m_t}^{(v)}, \mathbf{z}_x^{(w)}) \quad (1)$$

ただし, $D_{KL}(\cdot, \cdot)$ は KL 情報量を表す.

3.4.2 外れ値検知項 $f_o(x, \hat{x})$

外れ値検知は探索曲をデコードした際の reconstruction loss をもとに算出する. 探索曲 x および VRAE のデコードによって得られた \hat{x} を用いて, 外れ値検知項 $f_o(x, \hat{x})$ は以下で与えられる.

$$f_o(x, \hat{x}) = |g(x, \hat{x}) - \beta| \quad (2)$$

ただし, g は VRAE 学習時に reconstruction loss を算出した関数とし, β は学習済み VRAE に対してテストデータを入力した際に得られる reconstruction loss とする. このようにテストデータの reconstruction loss に基づいて, 教師無しで入力データと学習時のデータセットとの差異を測り, 外れ値を検知する研究 [Erik 15, Bontemps 16] も報告されており, 本研究でも有用であると考えられる.

3.4.3 個体評価値

(1) 式および (2) 式から, 探索曲に対する個体評価値 $f(x)$ は以下で与えられる.

$$f(x) = \left(\frac{1}{T} \sum_t f_d(m_t, x) + \alpha f_o(x, \hat{x}) \right)^{-1} \quad (3)$$

ただし, α は可調整パラメータである.

(3) 式では, 選好入力曲および探索曲の楽曲間距離 $f_d(m_t, x)$ を最小化することで探索曲を選好入力曲に近づける. また, 外れ値検知項 $f_o(x, \hat{x})$ を最小化することで学習に用いたデータに近い楽曲の生成を実現する.

3.5 適応度

ユーザの嗜好を反映する上で, 生成する曲の長さは重要な要素である. ゆえに, 本システムでは, ユーザが必要とする曲の曲長を t_d , 進化曲の曲長を t_x とし, MLPS-GP における適応度 $F(x)$ は (3) 式を用いて, 次式のように与えられる.

$$F(x) = \frac{t_d}{t_d + |t_d - t_x|^2} f(x) \quad (4)$$

4. 実験

ここでは以下に示す 2 種類の実験をする.

- segmented VRAE の精度解析
- 探索過程における適応度の解析

実験で用いたデータは Essen フォークソングデータベースコレクション [Ess] から 8472 曲を引用した. 各楽曲は 3 オクターブの範囲に規格化し, 音高および音価の組合せに対して, 楽譜と同様それぞれ固有のタグを割り振った. また, 6434 曲を訓練データ, 1609 曲をテストデータとして用いた.

4.1 segmented VRAE の精度解析

ここではネットワーク構造の違いによる影響を確認するために, 従来 VRAE および segmented VRAE の精度を比較する. ただし本実験における従来 VRAE は, エンコード部を BiDirectional RNN, デコード部を LSTM から構成され, 層状の構造を持たないものである.

表 1 に従来 VRAE および segmented VRAE 共通のパラメータを示す. segmented VRAE の場合, 入力データを複数の部分データに分割する過程が必要となる. 今回は予備実験により “5” タグずつ区切ることで部分データを作成した.

表 1: VRAE および segmented VRAE 共通のパラメータ

パラメータ名	値
batch size	512
embed units	256
hidden state	512
latent units	128
optimizer	Adam
alpha (Adam)	0.001
beta1 (Adam)	0.05
beta2 (Adam)	0.001
dropout	0.8
loss fuction	softmax cross entropy

表 2 に従来 VRAE および segmented VRAE のテストデータに対する精度を示す. ただし, epoch に関してはそれぞれテストデータに対する精度に基づき決定した. また, accuracy については高いほうが, それ以外の項目については低いほうが高い精度を示す. まず, 全体の “loss” より segmented VRAE の方が従来 VRAE よりも高い精度を示している. また, “accuracy” および “reconstruction loss” の項目より, 従来 VRAE に対して segmented VRAE の方が潜在変数からのデータ復元に関して高い精度を示すことがわかった. 一方で “latent loss” の項目から, 潜在変数に対する形状の最適化は従来 VRAE の方が高い精度を示すことがわかった. この理由として, VAE における loss は latent loss および reconstruction loss の和によって構成されており, reconstruction loss の方が全体の loss に対する影響が大きかったことが原因として考えられる. この結果, segmented VRAE は latent loss をあまり考慮せず reconstruction loss を下げる方向に最適化が進んだと考えられる.

4.2 適応度の解析

ここでは評価モデルによる探索曲の進化について解析する. 選好入力曲を “SCHOENE AUGEN SCHOENE STRAHLEN” [Ess] の 1 曲に設定し, (4) 式の適応度に基づき音楽を自動生成した. 表 3 に本実験で用いた MLPS-GP のパラメータおよび評価モデルのパラメータを示す.

表 4 に進化曲の適応度および表 5 にランダム曲の適応度を示す. ただし, 楽曲間距離 $f_d(m_t, x)$ および外れ値検知項 $f_o(x, \hat{x})$ は小さい値ほどよい結果を示しており, 一方で適応度 $F(x)$ は大きい値ほど望ましい. 表 4, 5 よりすべての項目について進化曲がより良い結果を示した. また, これらの項目に対して進化曲およびランダム曲の間で Welch の t 検定にかけたところ, 1% 水準で有意差が見られた. 図 3 に評価回数に対する進化曲の適応度の推移を示す. これにより, 評価回数を重ねるごとに適応度の上昇が確認できる. 以上の結果は MLPS-GP による進化曲に対する最適化が設定した目的関数に基づき成功していることを示している.

5. まとめと今後の課題

本論文では segmented VRAE と称す階層構造をもった VRAE に基づく進化的楽曲自動生成システムを提案した. まず, segmented VRAE を導入し, これを活用した進化的楽曲生成システムを示した. 実験では segmented VRAE の精度および生成過程における楽曲の最適化について解析した. 今後の課題としては, 深層学習に基づく手法の探索アルゴリズム,

表 2: 従来 VRAE および segmented VRAE の精度

種類	epoch	accuracy	latent loss	reconstruction loss	loss
従来 VRAE	100	0.2866	0.02724	2.542	2.569
segmented VRAE	300	0.4183	0.1664	2.081	2.248

表 3: MLPS-GP および評価モデルのパラメータ

パラメータ名	値
適応度評価回数 N_e	30000
初期化における減衰率 r_{dump}	0.8
初期の深さ制限 D_{init}	3
α (個体評価値)	1
β (外れ値検知項)	2.081
曲長 t_d [sec]	15

表 4: 進化曲の適応度

評価指標	楽曲間距離 $f_d(m_t, x)$	外れ値検知項 $f_o(x, \hat{x})$	適応度 $F(x) \times 10^{-2}$
平均	16.02	2.622	5.196
標準偏差	1.59	1.210	0.611

探索オペレータの構築およびユーザとの対話評価の導入があげられる。

謝辞

本研究は一部、日本学術振興会科学研究補助金基盤研究 (C) (課題番号 26330282) および一般財団法人カワイサウンド技術・音楽振興財団の補助を得て行われたものである。

参考文献

- [Bontemps 16] Bontemps, L., McDermott, J., Le-Khac, N.-A., et al.: Collective Anomaly Detection Based on Long Short-Term Memory Recurrent Neural Networks, in *International Conference on Future Data and Security Engineering*, pp. 141–152, Springer (2016)
- [Erik 15] Marchi, E., Vesperini, F., Eyben, F., Squartini, S., Björn Schuller: A Novel Approach for Automatic Acoustic Novelty Detection Using a Denoising Autoencoder with Bidirectional LSTM Neural Networks, in *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference On*, pp. 1996–2000, IEEE (2015)
- [Ess] *The Essen Folksong Collection* <http://www.esac-data.org/>
- [Fabius 14] Fabius, O. and van Amersfoort, J. R.: Variational Recurrent Auto-Encoders, *arXiv preprint arXiv:1412.6581* (2014)
- [Hasegawa 17] Hasegawa, T., Mori, N., and Matsumoto, K.: Genetic Programming with Multi-Layered

表 5: ランダム曲の適応度

評価指標	楽曲間距離 $f_d(m_t, x)$	外れ値検知項 $f_o(x, \hat{x})$	適応度 $F(x) \times 10^{-2}$
平均	51.96	12.71	1.489
標準偏差	9.56	2.77	0.267

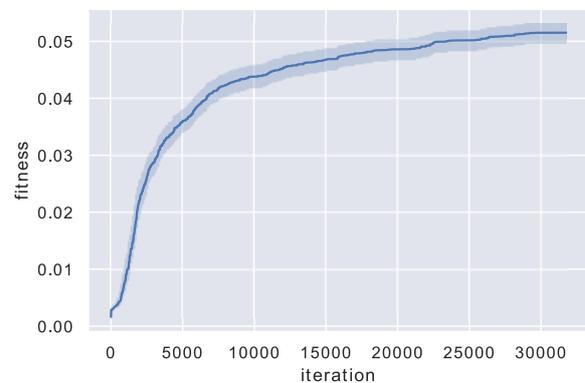


図 3: 評価回数に対する進化曲の適応度の推移。ただし、横軸は評価回数、縦軸は進化曲の適応度を示す。

Population Structure, *Proceedings of the 2017 Annual Conference on Genetic and Evolutionary Computation* (2017)

- [Jin 11] Jin, Y.: Surrogate-Assisted Evolutionary Computation: Recent Advances and Future Challenges, *Swarm and Evolutionary Computation*, Vol. 1, No. 2, pp. 61–70 (2011)
- [Kingma 13] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes., *CoRR*, Vol. abs/1312.6114, (2013)
- [Schmidhuber 97] Schmidhuber, J. and Hochreiter, S.: Long Short-Term Memory, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)
- [Takagi 98] Takagi, H.: Interactive Evolutionary Computation: Cooperation of Computational Intelligence and Human Kansei, in *Proceedings of the 5th International Conference on Soft Computing and Information/Intelligent Systems*, pp. 41–50 (1998)
- [山本 18] 山本 周典, 長谷川 拓, 森 直樹, 松本 啓之亮: 深層学習によるユーザ評価モデルを導入した遺伝的プログラミングによる音楽自動生成手法の提案, 2018 年度人工知能学会全国大会 (2018)

4 コマ漫画ストーリーデータセットにおける コマ画像の分散表現に基づく解析

Analysis based on Distributed Representations of Koma Images in Four-scene Comics Story Dataset

寺内 光^{*1} 森 直樹^{*1} 上野 未貴^{*2}
Akira Terauchi Naoki Mori Miki Ueno

^{*1}大阪府立大学 ^{*2}豊橋技術科学大学
Osaka Prefecture University Toyohashi University of Technology

Understanding the creation of human by artificial intelligence (AI) is increasing; however, those are still known as one of the most difficult tasks. In this research, we are challenging for the understanding of four-scene comics by AI. To aim at this challenge, we use a novel dataset what is called “Four-scene Comics Story Dataset”, which is the first dataset made by researchers and cartoonists to develop AI creations. We focused on illustration touches of comics which is determined by cartoonists. First, we applied autoencoder (AE) models to this dataset to get distributed representations, then applied classifiers to that and predict a touch. The prediction offers an indirect measure of the distributed representations. The effectiveness of the proposed method is confirmed by computer simulations taking data of various pattern of removing parts in koma images of the four-scene comics story dataset structure as an example.

1. はじめに

近年、深層学習をはじめとする機械学習技術の発展を背景に、人工知能による小説やイラストの自動生成など計算機による創作物理解が注目されている。しかしながら、創作は高次の知的活動であるため、現段階では表層的な模倣以上の成果は得られていない。

近年、コミック工学を中心に、人の創作物の中でも特に漫画を対象とする分野が発展している。同分野では従来研究として言語情報を用いて漫画のコマの順序を識別する手法や、画像情報を用いて登場人物の位置を推定する手法などが報告されている。しかしながら、データセットとして同一のストーリーを描いた物語は存在しないため、より創作者に近い感性に関わる表現方法やタッチの識別については十分な研究がなされていなかった。そこで本研究では、上野によって作られたデータセット [上野 18] を用いることでこの問題を解消し、より創作者に近い視点に基づく計算機による漫画の意味理解を実現するために、画像処理の分野から作者ごとのタッチ識別に焦点を当てる。

画像のタッチ識別をする単純な方法に畳み込みニューラルネットワークを用いた識別が考えられる。しかしながら、本研究では特定のタスクに依らない汎用性をもつ画像の分散表現を得ることを目的とし、その分散表現をタッチ識別タスクの識別率により評価する。画像のもつ特徴を分散表現として得るための手法は Illustration2Vec[Saito 15] や畳み込み自己符号化器などが提案されている。本研究ではこれまでにない新たな実験として、コマ画像から顔のパーツを抜いた画像に対するタッチ識別について検討した。これは従来のデータセットでは実現できない内容であるため、本研究においては創作と人工知能に関する新たな知見を得ることを目的とする。

2. 研究用漫画データ

4 コマ漫画を対象としたデータセットとしては Manga 109[Matsui 17][Ogawa 18] が知られているが、本研究では上野によって作られたデータセット (以下、4 コマ漫画ストーリーデータセットとする) を用いる。このデータセットは人工知能と創作物に関する研究発展のために研究者が一から開発に関わった世界初の研究用データセットであり、いくつかの特徴がある。まず、Manga109 のように市販の漫画を用いて作成されたデータセットとは異なり、4 コマ漫画ストーリーデータセットは本データセットのために幾人かの漫画家によって描き下ろされた 4 コマ漫画から構成されている。市販の漫画を用いた場合、著作権などの問題に加え、計算機上で扱うための著者の感性に関する情報が少なく、漫画の意味理解を目的とした研究には適さないという問題がある。例えば漫画に登場するキャラクターの感情は明示されていないため、読者によるアノテートによってラベルを付与する必要があるが、アノテートされたラベルが漫画家の意図とは異なる可能性を否定できない。また、オリジナリティの観点から同一プロットを複数の漫画家が描くことは稀有なため、漫画における表現の多様性に関する研究は困難である。4 コマ漫画ストーリーデータセットは上述の問題点を解決するために作られたデータセットであり、人工知能研究において大きな利点がある。

4 コマ漫画ストーリーデータセットは各コマがレイヤの重なりによって作成されており、レイヤ例としては目レイヤ、鼻レイヤ、口レイヤ、輪郭レイヤ、身体レイヤなどが存在する。これらのレイヤはそれぞれ別々に取り出すことができるように設計されている。これは必要な情報が容易に取り出せることを意味し、漫画の画像解析のために用いることができる情報が大量にあるという点で重要である。

また、上野は異なる作者によって描かれた 4 コマ漫画を、そのタッチを基にギャグタッチ、少女漫画タッチ、少年漫画タッチ、青年漫画タッチ、萌えタッチの 5 タッチに分類した。本研究では計算機による少年漫画タッチ、青年漫画タッチ、萌えタッチの 3 タッチを識別することを目的とする。図 1 に 3 タッチのコマ画像の例を示す。

連絡先: 寺内 光, 大阪府立大学 工学研究科, 大阪府堺市中央区 学園町 1-1, terauchi@ss.cs.osakafu-u.ac.jp



(a) 少年漫画タッチ

(b) 青年漫画タッチ



(c) 萌えタッチ

図 1: 各タッチ例

(c) 作画: 鈴木市規 (シナリオ: (株) スポマ 播村早紀/豊橋技術科学大学 上野未貴)

(c) 作画: 湯沢としひと (シナリオ: (株) スポマ 播村早紀/豊橋技術科学大学 上野未貴)

(c) 作画: 棟田ウメコ (シナリオ: (株) スポマ 播村早紀/豊橋技術科学大学 上野未貴)

3. 要素技術

3.1 自己符号化器

自己符号化器 (AutoEncoder: AE) とはニューラルネットワークの一種で、情報量を落とさずにより低次元の特徴表現を獲得するための次元圧縮手法である。AE は出力データが入力データと一致するように損失関数を定め、学習を進めるという点に特徴がある。

3.2 畳み込み自己符号化器

畳み込み自己符号化器 (Convolutional AutoEncoder: CAE) は 3.1 節で説明した AE に畳み込み層を追加したものである。CAE ではエンコーダに畳み込みと MaxPooling を用いており、デコーダに畳み込みと UpSampling を用いている。CAE は畳み込み層を有しているため、特に画像処理に対して有効である。

4. 提案手法

本研究では画像を分散表現化し、識別タスクを解くことを目的とする。しかしながらコマ画像は自然言語とは異なり、周辺のコマ画像からその特徴を抽出することが困難である。また、単語のように同じ画像が何度も出現するという事もない。そこで、本研究では他のコマの情報ではなく自身を教師ラベルのようにして学習する AE, CAE を用いて、その中間層の出力を分散表現として用いる。

本研究で使用する手法は以下の 2 通りに分かれる。

手法 1 AE を用いた分散表現による識別

手法 2 CAE を用いた分散表現による識別

本研究では AE, CAE ともに分散表現を 26626 次元から 3332 次元まで圧縮するモデルを keras を用いて構築した。

表 1: AE のモデル構造

レイヤー名	出力次元
Input	26656
Fully Connected 1	5000
BatchNormalization	5000
Fully Connected 2	3332
Dropout	3332
Fully Connected 3	5000
Fully Connected 4	26656

表 2: CAE のモデル構造

レイヤー名	出力サイズ
Input	(136, 196, 1)
Convolution 1	(136, 196, 4)
BatchNormalization	(136, 196, 4)
MaxPooling 1	(68, 98, 4)
Dropout	(68, 98, 4)
Convolution 2	(68, 98, 2)
MaxPooling 2	(34, 49, 2)
Convolution 3	(34, 49, 2)
UpSampling 1	(68, 98, 2)
Convolution 4	(68, 98, 4)
UpSampling 2	(136, 196, 4)
Convolution 5	(136, 196, 1)

4.1 AE を用いた分散表現による識別

AE を用いた分散表現による識別について説明する。表 1 に本実験で用いた AE モデルを示す。ただし、全結合層の活性化関数には最終層に sigmoid を、それ以外は ReLU を用いた。また、dropout rate は 0.5 とした。

手法 1 では Fully Connected 2 の出力を分散表現として用い、Support Vector Machine (SVM), Random Forest, および 3 層 Multi-Layer Perceptron (MLP) でコマ画像のタッチ識別をする。

4.2 CAE を用いた分散表現による識別

CAE を用いた分散表現による識別について説明する。表 2 に本実験で用いた CAE モデルを示す。ただし、畳み込み層の活性化関数には最終層に sigmoid を、それ以外は ReLU を用いた。また、dropout rate は 0.25 とした。

手法 2 では MaxPooling 2 の出力を平滑化したものを分散表現として用い、SVM, Random Forest, 3 層 MLP でコマ画像のタッチ識別をする。

5. 数値実験

本実験では、実験 1 においてはすべてのレイヤを用いて生成したコマ画像、実験 2 においては目レイヤ、口レイヤを抜いた画像を対象に、青年漫画タッチ、少年漫画タッチ、萌えタッチのいずれであるかを識別した。SVM, Random Forest での識別には、それぞれ 5 分割交差検定および grid search で得た最良のパラメータを用いた。表 3 に実験条件を示す。

本研究では AE, CAE で得た分散表現を用いてタッチ識別タスクを解く。その識別率が、得られた分散表現の性能に関する一指標になるという仮定を基に実験を進めた。

表 3: 実験で用いたパラメータ

-	AE, CAE	3層 MLP
最適化手法	Adam	Adam
学習率	0.001	0.001
エポック数	500	100
バッチサイズ	32	32
中間層	3332	500

表 4: 実験 1 識別率

識別器	AE	CAE
SVM	0.6042	0.7083
Random Forest	0.7083	0.8125
3層 MLP	0.5208	0.5833
ベースライン	0.3333	0.3333

表 5: 3 タッチ識別の精度, 再現率, F 値

タッチ	精度	再現率	F 値
少年漫画タッチ	0.790	0.938	0.857
青年漫画タッチ	0.700	0.750	0.727
萌えタッチ	1.000	0.750	0.857



図 2: AE の入力画像と出力画像



図 3: CAE の入力画像と出力画像

5.1 実験 1

手法 1, 2 について実験した. 実験には上述の 4 コマ漫画ストーリーデータセットを用いた. 画像はすべてのレイヤを用いて生成され, 1 タッチ 80 枚に対して青年漫画タッチ, 少年漫画タッチ, 萌えタッチの 3 タッチより計 240 枚を用いた. この 240 枚の画像に対して AE, CAE を用いて分散表現を獲得し, 対応するタッチを正解ラベルとして付与した. そして AE, CAE で得られた分散表現を SVM, Random Forest, および 3 層 MLP を用いてタッチ識別をした.

5.1.1 実験 1 の結果

図 2 に AE, 図 3 に CAE の入力画像と出力画像の例を示す. 図 2 より, AE においては入力画像とほぼ同一の画像が復元されていることがわかるが, 図 3 より CAE においては入力画像と出力画像を比べた時に, 出力画像が少しぼやけているのがわかる. これは MaxPooling 層によって情報の欠落が起きているため, より抽象的な特徴量が抽出できていると考察できる.

表 4 に実験 1 のテスト識別率を示す. 表 4 より, 最も識別率が高かったのは CAE と Random Forest を用いた実験であり, その識別率は 0.8125 であった. これは CAE を用いて得た特徴量を Random Forest がうまく分離できていることを示している.

表 5 に 3 タッチ識別の精度, 再現率, F 値を示す. 表 5 よ

り, 3 タッチの中で最も F 値の低かったものは青年漫画タッチであることがわかる. これは, 青年漫画タッチは萌えタッチとはトーンの使い方が似ており, 少年漫画タッチとは髪の描き方が似ていたため, 識別が他よりも難しかったからだと考えられた. また, 実験 1, 2 で誤識別した画像を調べた結果, 全体的に背景やオノマトベに黒色のべた塗りが使われている傾向があることが判明した. 図 4, 図 5 に実験 1 で得た分散表現を t-SNE により可視化したものを示す. 各軸は次元圧縮後の各要素を示している. 図 4 においては AE で得られた分散表現はおおよそのクラスが視覚的に確認できるが, 図 5 における CAE で得られた分散表現にはそのような明確なクラスは存在しない. これは CAE が AE よりも高次の複雑な多様体を分散空間上で形成しているためであると考えられる.

5.2 実験 2

コマ画像から 1 つのレイヤを抜いたデータセットに対して実験 1 で最も識別率の高かった CAE と Random Forest の組み合わせによりタッチを識別し, どのレイヤが識別タスクに大きく影響を与えているか調べた. 今回用いたレイヤ抜き設定は顔のレイヤのうち, 目レイヤを抜いた「目抜き」と口レイヤを抜いた「口抜き」の 2 種類である. これらのレイヤ抜き画像に対する分散表現を用いたタッチ識別タスクを解き, すべてのレイヤを用いた画像の識別タスクと識別率の比較を行う.

5.2.1 実験 2 の結果

表 6 に各レイヤ抜き設定に対するテスト識別率を示す. 表 6 より, 最も識別率の高かったオリジナル画像から最も識別率の下がったものは口抜きの画像で, すべてのレイヤを用いた識別率より約 25 % も低下したことがわかる. これは口というパーツがコマ画像のタッチ識別に大きく寄与していることを意味する. 漫画としては誇張されやすい目よりも口を除いた時のほうが識別率が下がったのは, 4 コマ漫画ストーリーデータセットにおいて登場人物のひとりがメガネをかけており, 目を除いた影響が比較的少なかったからだと考えられる. また, 表 7 にすべてのレイヤを用いた画像, 表 8 に目抜き画像, 表 9 に口抜き画像を用いた識別タスクの混同行列を示す. 表 7 から表 9 より, すべてのレイヤを用いた画像の識別では, 萌えタッチに対する精度が高く, 目抜き画像の識別では少年漫画タッチに対する再現率が高いことがわかる. また, 全体的に少年漫画タッチと識別した個数が多いのに対し, 口抜き画像の識別では, 青年漫画タッチと予測した個数が多かったのも特徴的な点であった. 今回の識別実験においては萌えタッチと少年漫画タッチ間の誤識別はあまり見られず, この 2 タッチは図 4 で確認できるように分散空間上で離れた位置にクラスを形成しているのではないかと考察できる.

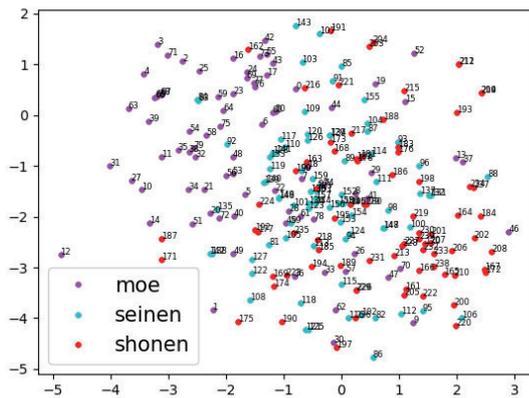


図 4: AE で得た分散表現

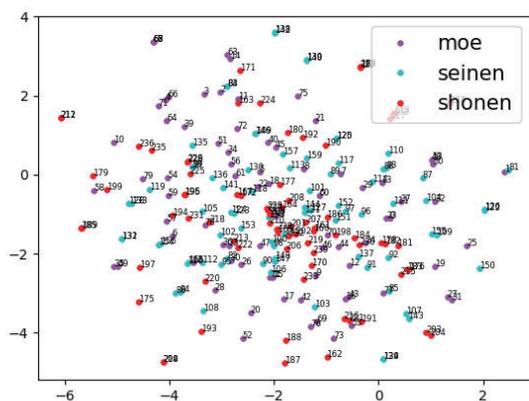


図 5: CAE で得た分散表現

表 6: 実験 2 識別率

レイヤ抜き設定	識別率
すべて使用	0.8125
目抜き	0.7917
口抜き	0.6667
ベースライン	0.3333

6. まとめと今後の課題

本研究では, AE, CAE で得た分散表現を用いて 4 コマ漫画のタッチ識別において識別率 8 割程度となる分散表現を獲得できた. また, 全体的に AE よりも CAE を用いたほうが識別率が高く, 漫画のコマ画像に対しても CAE が有効であることが確認できた. さらに, 創作視点に立つ新しいデータセットを用いることによって, これまで研究されてこなかったレイヤ抜き画像に対する識別率の変化を観察し, 顔のパーツがタッチ識別に寄与していることを確認できた. 今後の課題としては, 以下のものがあげられる.

- より効率的な分散表現の獲得
- 他のレイヤ抜き画像に対する識別率実験
- 分散表現と作者との定量的な解析

表 7: すべてのレイヤを用いた画像識別の混同行列

		予測値		
		萌え	青年	少年
真値	萌え	12	4	0
	青年	0	12	4
	少年	0	1	15

表 8: 目抜き画像識別の混同行列

		予測値		
		萌え	青年	少年
真値	萌え	12	3	1
	青年	3	10	3
	少年	0	0	16

表 9: 口抜き画像識別の混同行列

		予測値		
		萌え	青年	少年
真値	萌え	11	4	1
	青年	1	10	5
	少年	0	5	11

謝辞

本研究は一部, 日本学術振興会科学研究補助金基盤研究 (C) (課題番号 26330282) の補助を得て行われたものである.

本研究は一部, JST, ACT-I(グラント番号:JPMJPR17U4) の支援を受けたものである.

4 コマ漫画ストーリーデータセットの制作に対し, ご協力いただいた漫画家の方々, 株式会社スポマへ謝意を示す.

参考文献

- [Matsui 17] Matsui, Y., Ito, K., Aramaki, Y., Fujimoto, A., Ogawa, T., Yamasaki, T., and Aizawa, K.: Sketch-based Manga Retrieval using Manga109 Dataset, *Multimedia Tools and Applications*, Vol. 76, No. 20, pp. 21811–21838 (2017)
- [Ogawa 18] Ogawa, T., Otsubo, A., Narita, R., Matsui, Y., Yamasaki, T., and Aizawa, K.: Object Detection for Comics using Manga109 Annotations, *CoRR*, Vol. abs/1803.08670, (2018)
- [Saito 15] Saito, M. and Matsui, Y.: Illustration2Vec: a semantic vector representation of illustrations, pp. 1–4 (2015)
- [上野 18] 上野 未貴: 創作者と人工知能: 共作実現に向けた創作過程とメタデータ付与 4 コマ漫画ストーリーデータセット構築, 人工知能学会全国大会論文集, Vol. JSAI2018, pp. 4Pin116–4Pin116 (2018)

[1H3-J-13] AI application: medicine and healthcare

Chair:Kenji Kondo Reviewer:Yoshikuni Sato

Tue. Jun 4, 2019 3:20 PM - 5:00 PM Room H (303+304 Small meeting rooms)

- [1H3-J-13-01] Realization of behavior prediction method using behavior log in the hospital and attribute information**
○Masanori Nakagawa¹, Aoi Saito², Kazuya Murakami³, Ryu Taniguchi¹, Hiroyoshi Kuroda¹, Masahiko Ito¹, Tomomi Yajima⁴, Fumitake Hata⁴, Takafumi Nakanishi⁵ (1. Ricoh Co.,Ltd., 2. Ricoh IT Solutions Co.,Ltd., 3. Softcomm Co.,Ltd., 4. Sapporo Dohto Hospital Medical Corporation., 5. Musashino University)
3:20 PM - 3:40 PM
- [1H3-J-13-02] Diagnostic Classification of Chest X-Rays Pictures with Deep Learning Using Eye Gaze Data**
○Taiki Inoue¹, Nisei Kimura², Nakayama Kotaro^{2,3}, Kenya Sakka⁴, Abdul Ghani Abdul Rahman², Ai Nakajima⁵, Radkohl Patrick², Satoshi Iwai⁶, Yoshimasa Kawazoe⁶, Kazuhiko Ohe⁶ (1. Graduate School of Pharmaceutical Sciences, The University of Tokyo, 2. Graduate School of Engineering, The University of Tokyo, 3. NABLAS Inc., 4. Graduate School of Frontier Sciences, The University of Tokyo, 5. Aalto University, 6. Graduate School of Medicine, The University of Tokyo)
3:40 PM - 4:00 PM
- [1H3-J-13-03] Eye-inspection Image-based Transfer Learning Rebar Expose using Semantic Segmentation**
Michihiro Nakajima¹, OTakato Yasuno¹, Daisuke Nagatomi¹, Kazuhiro Noda¹, Kiyoshi Aoyanagi¹, Seiji Sekiguchi¹ (1. Yachiyo Engineering, Co.,Ltd.)
4:00 PM - 4:20 PM
- [1H3-J-13-04] Cheerful status prediction using "Sleep Diary" application**
○Jou Akitomi¹, Ikuo Kajiyama¹, Isa Okajima², Mineko Yamaguchi¹ (1. NEC Solution Innovators Ltd., 2. Tokyo Kasei University)
4:20 PM - 4:40 PM
- [1H3-J-13-05] Prediction of the Onset of Lifestyle-related Diseases Using Health Insurance Claims Data**
○Fumie Yaegashi¹, Masahiro Araki¹, Natsuki Oka¹, Motoshi Shintani², Masataka Yoshikawa³ (1. Kyoto Institute of Technology, 2. SG Holdings Group Health Insurance Association, 3. Japan System Techniques Co., Ltd.)
4:40 PM - 5:00 PM

病院内行動ログおよび属性情報を用いた行動予測手法の実現

Realization of behavior prediction method using behavior log in the hospital and attribute information

仲川 正則^{*1} 齊藤 葵^{*2} 村上 和哉^{*3} 谷口 竜^{*1} 黒田 裕芳^{*1}
 Masanori Nakagawa Aoi Saito Kazuya Murakami Ryu Taniguchi Hiroyoshi Kuroda
 伊藤 政彦^{*1} 矢嶋 知己^{*4} 秦 史壯^{*4} 中西 崇文^{*5}
 Masahiko Ito Tomomi Yajima Fumitake Hata Takafumi Nakanishi

^{*1}株式会社リコー ^{*2}リコーITソリューションズ株式会社 ^{*3}株式会社ソフトコム
 Ricoh Co.,Ltd. Ricoh IT Solutions Co.,Ltd. Softcomm Co.,Ltd.
^{*4}札幌道都病院 ^{*5}武蔵野大学
 Sapporo Dohto Hospital Medical Corporation. Musashino University

Abstract: In this paper, we represent a realization method of behavior prediction by using behavior log in the hospital and attribute data of each nurse. In recent years, the busyness and complexity of medical staff's work has become a social problem. It is important to realize the operational efficiency of medical staff by applying information technology. We are collecting behavior data by attaching RFID tags to medical staff and hospital patients in an actual medical field under the cooperation of Sapporo Dohto Hospital Medical Corporation. Our method realizes a behavior prediction based on behavior order by using these actual behavior data by applying Long-Short Term Memory (LSTM). We realize improving work efficiency such as optimal placement of medical staff by applying our behavior prediction method.

1. はじめに

近年、医療スタッフが健康で安心して勤務に従事できる医療現場の環境整備が注目を浴びている。特に、医療スタッフが効率的にかつ心地よく業務に従事するために、属人的に役割分担を工夫するだけでは限界があり、病院内における行動データに基づいて、より効率的な配置や役割分担をすることが重要となってきた。

我々はこれまで、札幌道都病院の院内において、医療スタッフ、および入院患者に RFID タグを身に付けてもらい、院内随所に設置した RFID アンテナおよびゲートウェイから位置情報を取得することにより、医療スタッフ、および入院患者の行動データを取得してきた。実際に札幌道都病院の院内で展開している RFID タグ、RFID アンテナを図 1 に示す。

また、これらの RFID タグ、アンテナおよび行動データを用いて、リアルタイムで院内のどこに誰がいるのかを俯瞰して可視化するリアルタイムモニタリングシステムを実現し、同病院内で展開している。図 2 に実際のリアルタイムモニタリングシステムの画面例を示す。本システムは、RFID タグをつけた医療スタッフ、入院患者、および医療器具のそれぞれの場所についてリアルタイムで確認でき、札幌道都病院では、主に各フロアのナースステーション内の大型モニタに 24 時間 365 日表示している。



図 1：RFID タグおよび RFID アンテナ

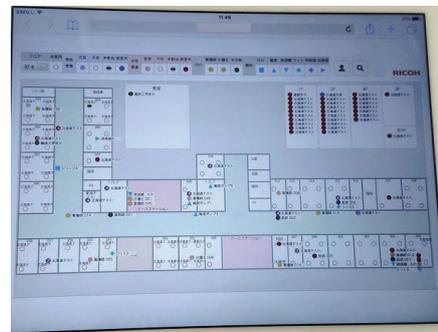


図 2：リアルタイムモニタシステム

本システムによって、院内の看護師における、患者探し、他看護師の呼び出しや支援依頼、医療機器類の検索といった問題への対応時間の軽減が実現されている。

これらのシステムを利用している医療スタッフから得られた現場の課題として以下が挙げられる。

A. 業務の効率化に関する課題

1. 必要な備品の在庫が所属フロアに無い場合、別のフロアを探し回る事象が発生している。
2. 業務終了間際に、ナースステーションにて「電子カルテ入力」「日報作成」などをまとめて行っている。
3. 看護師は担当病室により業務が異なることが多く、同じ看護師という職種でも業務内容及び煩雑さが異なる。そのため、適切な人員配置を行うことが困難である。

B. 突発的な業務発生による課題

計画外の入院についてはベテランの看護師でも 30 分から 1 時間程度、対応に時間かかる場合がある。

これらの課題から、非効率な業務や突発的な業務による生産性の低下がどのような原因でどの程度発生しているのか明らかにし、医療スタッフの担当業務見直しや人員配置などについて、取得した行動データから明らかにすることが重要である。

本稿では、医療スタッフ、特に看護師に着目し、実際の病院内のリアルタイムモニタシステムによる看護師の行動データを用いた看護師の行動予測モデルの実現について述べる。具体的には、随時記録される看護師の位置データを元にしてクラスタリングすることにより、看護師の行動パターンを把握し、それを元に Long-Short Term Memory (LSTM) [Hochreiter 97]を適用す

連絡先: 仲川 正則, 株式会社リコー, 東京都中央区築地 5-6-10, masanori.nakagawa@jp.ricoh.com

ることにより、現実の行動順序に基づいた行動予測を可能とする。看護師の行動予測を実現することにより、より効率的な配置をリアルタイムで判断する材料になりうる。本研究の特徴として、LSTM を用いた行動予測モデルを実現することにより、行動順序に基づく予測を実現した点、実際の病院内の看護師を対象とした行動データを適用した点が挙げられる。

2. 院内における行動データ

本節では、病院内で取得可能な行動データについて、特に今回対象とする看護師の行動データについて示す。

札幌道都病院の院内において、医療スタッフが RFID タグを付けており、院内随所に設置した RFID アンテナおよびゲートウェイから位置情報を 6 秒おき取得に取得している。これらのデータから、院内でアンテナをどこに設置しているかを紐付け、実際、いつ、どのエリアにいたか 24 時間 365 日検知することが可能である。具体的には、機械的につけられた測位場所のアンテナ ID を ICU, XXX 号室(部屋番号), ナースステーションなどの各定義エリアに変換しておくことができる。

本稿では、簡単化のため、医療スタッフの中でも特に看護師の行動データに着目することとする。院内では、複数のフロアが存在し、入院患者の症状によってフロアが割り当てられている。看護師は担当フロアが原則決まっているが、介護士、臨床工学士などの看護師以外の医療スタッフは全てのフロアを見回ることが多い。本稿では、このような背景から、特に病院内 4 階の看護師を対象とすることとする。

また、各看護師について、属性データがあり、上記の行動データに紐付けることが可能である。

今回対象とする看護師 RFID 行動データ、および属性データは、具体的に次の通りとなる。

A. 看護師 RFID 行動データ

- ・ 期間:2018/11/1~2018/11/30 までの一ヶ月間で夜勤帯を除く日中帯の 8:00~20:00
- ・ ID タグ数:4F フロアに所属する看護師 21 名分
- ・ データ総数:1, 527, 687 レコード

B. 属性データ

- ・ 看護師シフトデータ(2018/11/1~8)
リーダー、サブ、部屋持ち、フリー、検査という 5 つの役割があり、各々の看護師の役割は日々異なる。
- ・ 看護師の入社経過年及び資格取得経過年データ(2018/11/1 時点)
各々の看護師の当院に務めてからおよび看護師資格取得してからの経過年データである。

3. RFID 行動データを用いた院内行動予測方式

本節では、2 節で示した対象データを用いた看護師の院内行動予測方式について示す。3.1 節では、本方式の全体概要を示す。3.2 節では、看護師の行動パターンを導き出すためのクラスタリングについて示す。3.3 節では、これまでの行動順序に基づき次の行動を予測するための LSTM を用いた行動予測モデルの実現方式について示す。

3.1 院内行動予測方式全体像

本方式の全体像について図 3 に示す。図 3 中の「A. エリア変換データ」とは、RFID アンテナによって機械的につけられた測位場所のアンテナ ID を ICU, XXX 号室(部屋番号), ナースステーションなどの各定義エリアに付け直したデータである。図 3 中の「B. 日次滞在累積データ」とは、「A. エリア変換データ」を

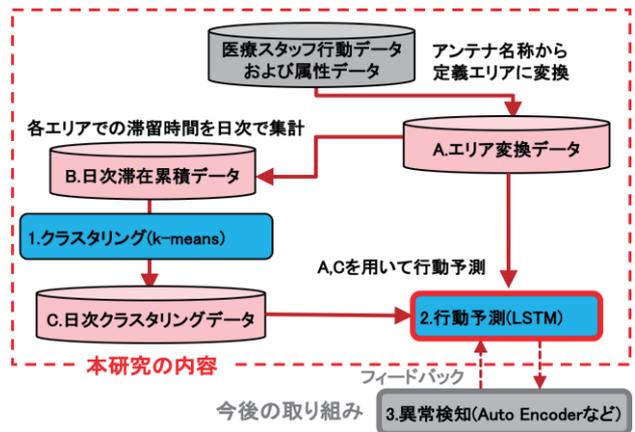


図 3: 行動予測方式の全体像

表 1: 実行パラメータ(k-means)

パラメータ	値
クラスタ数	1-20
繰り返し回数の最大値	300
初期値選択実行回数	10

用いてタグ毎に日次でエリアごとに滞在した累積時間を求め、正規化を行ったものである。

本方式は大きく、クラスタリング部と行動予測部がある。クラスタリング部は事前に、看護師の行動パターンを導出することを目的としている。行動予測部は、クラスタリング部で導出された行動パターン別に行動予測モデルを構築する。事前にクラスタリングをする理由として、看護師には予め決められた役割が振り分けられていることが多く、その役割によって行動パターンがある程度決まっていると予測される。行動パターンごとにクラスタリングし、そのクラスごとに予測モデルを構築する方が、精度の高い予測モデルを構築できると考えられるためである。クラスタリング部で導出された結果を図 3 中の「C. 日次クラスタリングデータ」として保持する。

3.2 看護師行動特性によるクラスタリング

図 3 中の「B. 日次滞在累積データ」は、RFID タグ ID ごとの日次ごとの滞在時間の累積を示している。各 ID の行動、つまり累積滞在場所の特性でクラスタリングを行う。看護師の役割は週ごと、もしくは日ごとに変換することがあるために、日次ごとに集約してクラスタリングすることにより、看護師の業務としてどのような行動パターンがあるかを導出することが可能となる。

具体的には、k-means[Lloyd 1982]を用いて、表 1 で示す実行パラメータで実装した。

これによって形成された各クラスが、看護師の行動パターンの種類とみなす。クラスごとに、つまり、行動パターンごとに行動予測モデルを構築する。例えば、業務内容によっては、ある看護師においては特異な行動でも、別の看護師では、当たり前行動である場合がある。これらの行動パターンを事前に分けておくことにより、行動予測の精度を上げられると考えられる。

3.3 LSTM を用いた看護師行動予測

ある看護師に着目し、現在 t において居た場所、その 1 ステップ前($t-1$)に居た場所と遡り、 n ステップ前($t-n$)に居た場所までを入力として、 $t+1$ の時にどこにいるかを予測するようなモデルを考える。

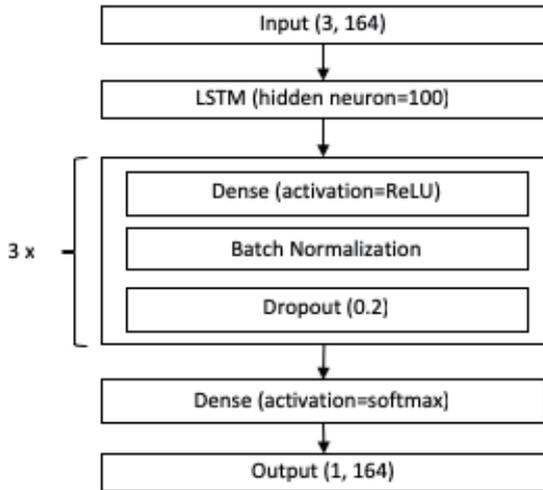


図 4 : LSTM のモデル構造

表 2 : LSTM モデルにおける実行パラメータ

パラメータ	値
ステップ数	3, 5, 10
ミニバッチサイズ	128
学習回数	25

本稿では, LSTM [Hochreiter 97]を用いて構築する. 具体的なネットワーク構成, パラメータについては, 図 4, 表 2 に示す.

なお, 中間層において活性化関数に ReLU 関数, Batch Normalization および Dropout=0.2 の 3 層構造を適用し, 出力層の直前に softmax 関数を用いた.

4. 評価実験と結果

本節では, RFID 行動データを用いた院内行動予測モデルの評価, 検証を行う. 4.1 節では, 看護師の行動パターンの種類を見出すためのクラスタリングの検証を行う. 4.2 節では, 実際の行動予測についてクラスタリングをする場合としない場合で精度比較を行った.

4.1 行動特性のためのクラスタリング結果

2~20 クラスタまでのクラスタリングを行ったうち, クラスタ内のデータの相関関係や特定エリアでの滞在傾向および看護師のシフト属性に基づいてクラスの特徴を最も捉えることができたクラスタ数 10(k=10)として定めた.

図 5 にクラスタ別の滞在時間割合累積を示す. クラスタ 2 が休憩室に置き忘れたもの, クラスタ 4 が 4 階以外での位置が取得されているものである. その他のクラスタについてもナースステーションは共通として, クラスタごとに滞在する病室がほぼ異なるようになっており, 看護師の行動パターンの種類を抽出できている.

図 6 は, 各クラスタの入社経過年の人数について示している. クラスタ 3 は正に相関, クラスタ 0,5,6,7 は負に相関しており, クラスタ 3 の行動パターンは入社経過年が大きいベテランの看護師の行動パターンとみることができる.

図 7 は, 各クラスタの看護師資格取得年の人数について示している. クラスタ 5 が正に相関している. クラスタ 5 の行動パター

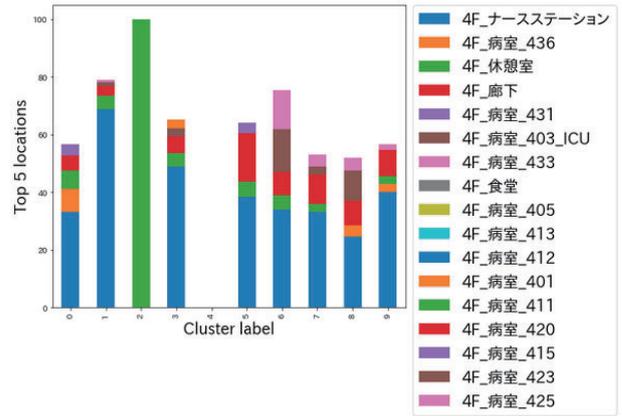


図 5 : クラスタ別滞在時間割合累積グラフ(上位 5 件)

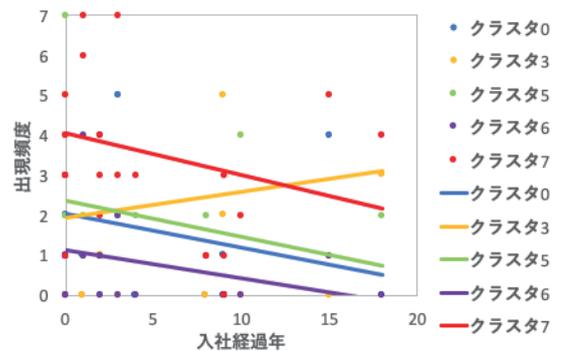


図 6 : 看護師別入社経過年と出現頻度の散布図および近似直線

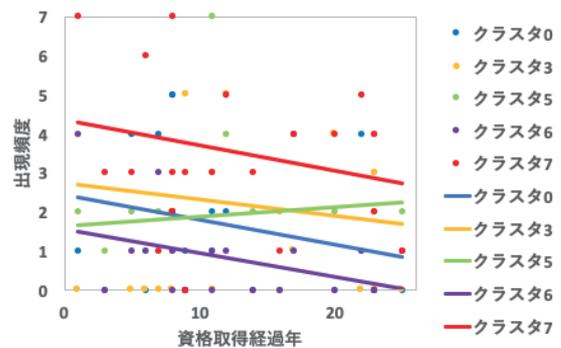


図 7 : 看護師資格取得経過年と出現頻度の散布図および近似直線

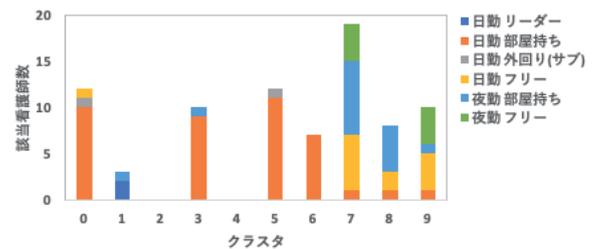


図 8 : 各クラスタにおける看護師と役割との関係

ンは、入社経過年は少ないが看護師資格を取ってから長いベテランの行動パターンであると推定される。

図 8 は、各クラスタにおける看護師の実際の役割の延べ人数を示したものである。クラスタ 0,3,5,6 は通常の部屋持ち、クラスタ 1 がリーダー格、クラスタ 7,8,9 がその他の役割を持つ看護師の行動であることが分かる。

これらのことから、各クラスタは次のように行動パターンが分かれていますとみることが出来る。

[クラスタ=0,9]

特定病室(436)の出現頻度が高い。クラスタ 0 に関して入社経過年・資格取得経過年ともに負の相関関係が現れている。

[クラスタ=1]

ナースステーションの出現頻度が非常に高い。リーダーを分担する看護師が分類されていることから、師長に近い行動を反映していると考えられる。

[クラスタ=2,4]

クラスタ 2 は 4F_休憩室、クラスタ 4 は 4F 以外(B1F_仮眠室)に 100%滞留している。タグの置忘れと考えられる。

[クラスタ=3]

特定病室(401, 403_ICU)の出現頻度が高い。入社経過年はプラス、資格取得経過年は負の相関関係が現れている。

[クラスタ=5]

特定病室(415, 420)の出現頻度が高い。入社経過年はマイナス、資格取得経過年は正の相関関係が現れている。

[クラスタ=6,7]

特定病室(423, 425)の出現頻度が高い。入社経過年・資格取得経過年ともに負の相関関係が現れている。

[クラスタ=8]

特定病室(403_ICU)の出現頻度が高い。

以上のクラスタのうち、図 8 より日勤における部屋持ちの看護師数が最も多く、看護師の日次業務のうち最も定常業務の割合が多いと考えられるクラスタ 5 が日勤業務に対する行動予測の対象として最も望ましいと考え、後述の LSTM を用いた看護師行動予測の検証のための対象データとした。

4.2 LSTM を用いた行動予測の検証

クラスタ 5 に属するデータを対象として、LSTM による行動予測モデルを構築した。比較対象として、クラスタリングをせず、全データを対象としたモデルも併せて構築した。

表 3: クラスタリングの有無とステップ毎のデータ数

クラスタリングなし	値(step=3/ 5/ 10)
学習用データ	848,242/ 847,872/ 846,948
検証用データ	282,748/ 282,624/ 282,316
推論用データ	282,748/ 282,624/ 282,316
クラスタリングあり	値(step=3/ 5/ 10)
学習用データ	127,032 / 126,983 / 126,860
検証用データ	42,344 / 42,328 / 42,287
推論用データ	42,345 / 42,328 / 42,287

表 4: クラスタリングの有無とステップ毎の検証精度

クラスタリングなし	値(step3/5/10)
val_acc	0.9094/ 0.9094/ 0.9092
クラスタリングあり	値(step3/5/10)
val_acc	0.9214/ 0.9214/ 0.9237

クラスタリングなしで全データ活用、および、クラスタリング後クラスタ 5 のデータを活用のそれぞれのデータ量については、表 3 に示す通りである。

実際の精度比較の結果は表 4 に示す。これにより、クラスタリングなしよりもクラスタリングによる分類データを用いた方が精度の向上が見られた。また、計算回数については学習回数 25 の状態で学習データ精度および検証データ精度が収束していることを確認しており、ステップ数の違いやミニバッチサイズによる明らかな精度の違いは見られなかった。これはクラスタリングを行うことにより、病室担当やフリーなどの役割分担ごとに行動データが分類されそれらの行動パターンがある程度の共通性を持っていることが考えられる。

これらの結果から、実際の病院内の看護師の RFID タグデータから、行動順序に基づく行動予測が可能になっていることを確認できた。

5. おわりに

本稿では、医療スタッフ、特に看護師に着目し、実際の病院内のリアルタイムモニタシステムによる看護師の行動データを用いた看護師の行動予測モデルの実現について示した。本モデルにより、実際の病院内における看護師の行動特性によって、看護師の実際の行動を明らかにし、その人一人一人の行動を予測することが可能になった。

現状では単一フロアにおける医療スタッフを対象としているため、今後対象範囲を院内の全従業員に拡大し、医療機関内の多様なスタッフの行動予測への適用を検討していくことが課題である。また、期間についても、1 ヶ月間のデータのみを用いているため、季節などの環境依存で行動が変化することも考えられることから、データ対象期間を 1 年以上に広げていくことも検討する。その際、日単位での行動パターンだけでなく、月、年単位での行動パターンを加味することも必要になるだろう。

今後の課題として、定常業務の中でも効率的でない業務行動や突発的な業務の頻度、ケースなどについても異常検知による非効率な業務原因の解明、および、これらの研究成果を用いた実際の院内における業務効率化に貢献が挙げられる。

謝辞

本稿について、札幌道都病院様からのご支援およびご助言を賜りました。深く感謝致します。

参考文献

- [Lloyd 1982] S. Lloyd: Least squares quantization in PCM, IEEE Trans Inform Theory, IT-28, pp. 129-137 (1982)
- [Hochreiter 9] Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, Neural Computation, Vol. 9, No. 8, pp. 1735-1780 (1997)

視線データを活用した深層学習による胸部 X 線写真の診断的分類

Diagnostic Classification of Chest X-Rays Pictures with Deep Learning Using Eye Gaze Data

井上 大輝^{*1}
Taiki Inoue

木村 仁星^{*2}
Nisei Kimura

中山 浩太郎^{*2,3}
Kotaro Nakayama

作花 健也^{*4}
Kenya Sakka

Abdul G. A. R.^{*2}
Abdul G. A. R.

中島 愛^{*5}
Ai Nakajima

Radkohl P.^{*2}
Radkohl P.

岩井 聡^{*6}
Satoshi Iwai

河添 悦昌^{*6}
Yoshimasa Kawazoe

大江 和彦^{*6}
Kazuhiko Ohe

松尾 豊^{*2}
Yutaka Matsuo

^{*1} 東京大学大学院薬学系研究科
Graduate School of Pharmaceutical 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} 東京大学大学院新領域創成科学研究科
Graduate School of Frontier Sciences,
The University of Tokyo

^{*5} Aalto University
Aalto University

^{*6} 東京大学大学院 医学系研究科
Graduate School of Medicine,
The University of Tokyo

Automatic diagnosis of chest X-ray pictures with deep learning has been extensively studied in recent years. In order to improve the accuracy, it is important how to input small localized areas which are disease specific while at the same time using the information that can be obtained by the whole picture. We considered that human eye-gaze fixations can be a biomarker that indicates areas specific to disease. In this study, we propose a deep learning model utilizing eye-gaze data. We demonstrate that the classification shows the better accuracy on using eye-gaze data of experienced doctors than eye-gaze data of non doctor or non-use of eye-gaze information.

1. はじめに

今日、肺がんを始めとした病態の診断を実施する上で胸部 X 線写真は広く利用されているが、これには専門家である放射線医による適切な読影が必要である。しかし、放射線医の人材不足は世界中で共通の問題であり、放射線医にかかる負担を軽減する技術や仕組みの開発が望まれている。このような背景ならびに近年の深層学習技術の発展に後押しされ、胸部 X 線写真の自動診断は現在盛んに研究されている。

胸部 X 線写真の深層学習による診断の先駆けとしては 2017 年に発表された CheXNet [Rajpurkar 17] が挙げられる。これは既存の深層学習ネットワークである DenseNet [Huang 16] を基盤としたモデルであり、112,120 枚の胸部 X 線写真を使用して 14 種類の病態を分類した結果、放射線医を上回る診断精度を記録した。しかし翌年には、AG-CNN [Guan 18] と呼ばれるモデルが CheXNet の診断精度を更新している。CheXNet が胸部 X 線写真全体をダウンスケールした画像を入力としているのに対し、AG-CNN は Attention 機構 [Mnih 14] を採用することで、胸部 X 線写真全体に加えて、異常と疑われる領域の局所画像を入力としている。このように、胸部 X 線写真を診断する深層学習モ

デルの精度向上には異常と疑われる局所画像を正確に抽出し、入力とすることが重要であると言える。

AG-CNN は胸部 X 線写真から得られる情報を基に異常と疑われる局所画像を抽出しているのに対し、本研究では「診断時に医師が凝視している領域を異常と疑われる局所画像として抽出できるのではないか」という仮説を立てた上で、視線データを基に抽出された局所画像を入力とする深層学習モデルを構築した。

2. 手法

2.1 データセット

本研究では、東京大学附属病院より正常 47 枚、異常 48 枚、合計 95 枚の胸部 X 線写真を提供を受けた。その 95 枚の写真を用いて、医師 5 名および医師訓練を受けていない成人男女 5 名に対して表示された胸部 X 線写真が正常・異常のいずれであるかを分類する試験を各被験者ごとに 2 回ずつ行い、その際に各被験者の視線データを収集した (Figure 1)。

正常・異常の分類は、ディスプレイ上に 95 枚の胸部 X 線画像の中から 1 枚ずつランダムに画像を表示させ、被験者がマウスの左右クリックによって正常・異常の分類を行えるソフトウェアを独自に開発し、それを利用した。

また視線データは、Leveque らによる研究 [Leveque 18] を参考に、赤外線型のアイトラッキングデバイス Tobii Eye Tracker 4C

連絡先: 井上大輝, 東京大学, 〒113-0033, 東京都文京区本郷 7-3-1, taiki-inoue45@g.ecc.u-tokyo.ac.jp

を利用して収集することとした。得られた視線データは、約 11 ミリ秒に 1 回の間隔で視線の x, y 座標が記録された時系列データである。

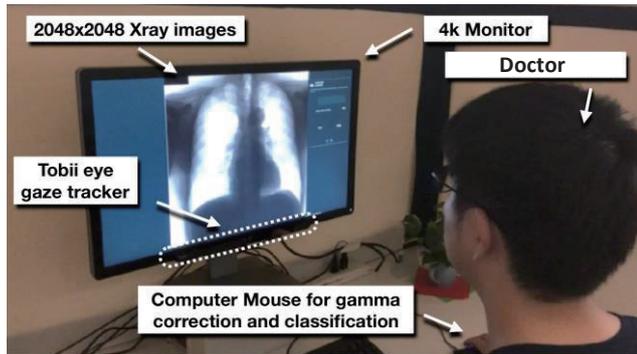


Figure 1 | 視線データ収集時の様子

2.2 胸部 X 線写真の前処理

入力データのもとになる胸部 X 線写真は、既存の深層学習モデルである CheXNet および AG-CNN を参考にして、平均を 0.485、標準偏差を 0.229 として正規化を行った。また、データ拡張と頑健性向上を目的とした、鏡映や回転・せん断変形による画像の水増し方法は、本研究では実施しなかった。これは、胸部 X 線写真は左右非対称であり、また読影では各部位の傾きなどが重要な情報になるためである。

2.3 モデルの構造

本研究で提案するモデル (Figure 2) では、まず Maximum Sampling を行うことで、胸部 X 線写真の中で視線が最も集まっている領域 (局所画像) を抽出する。そして、胸部 X 線写真を 2048×2048 から 224×224 にダウンスケールした画像 (全体画像) と、局所画像を重ねて複数チャンネルとしたものを DenseNet-121 の入力とし、正常および異常の確率を出力させた。

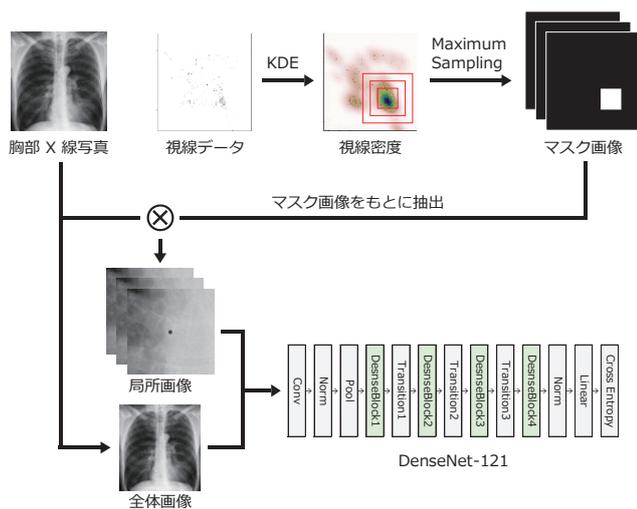


Figure 2 | 本研究で提案するモデルの構造

(1) Maximum Sampling

局所画像を抽出するため、確率変数の確率密度関数を推定するノンパラメトリック手法の 1 つである KDE (Kernel Density Estimation) を用い、視線データ (Figure 3-a) から視線密度

(Figure 3-b) を算出した。そして、視線密度が最も高い点を中心として局所画像を抽出した (Figure 3-c)。

また、人間の視野が複数階層により成り立っている [Pickrell 03] ことを考慮し (Figure 4), 最大で 4 階層とする局所画像の階層化を行った。階層 r_i の局所画像は、2048×2048 の胸部 X 線写真の中で最も視線密度が高い点を中心として、一辺が s_{r_i} の画像となるよう抽出した後、224×224 にダウンスケールすることで得られる。 s_{r_i} は以下の数式に従う。

$$s_{r_i} = 224 \div (1 - 0.25 \times (i - 1)), \quad i = \{1, 2, 3, 4\}$$

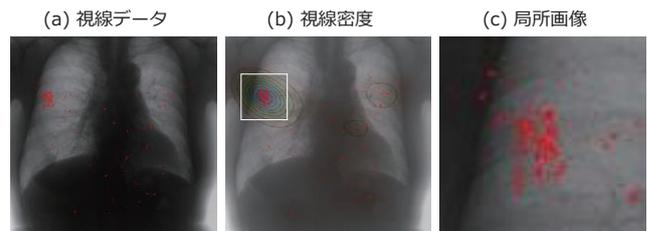


Figure 3 | Maximum Sampling の過程

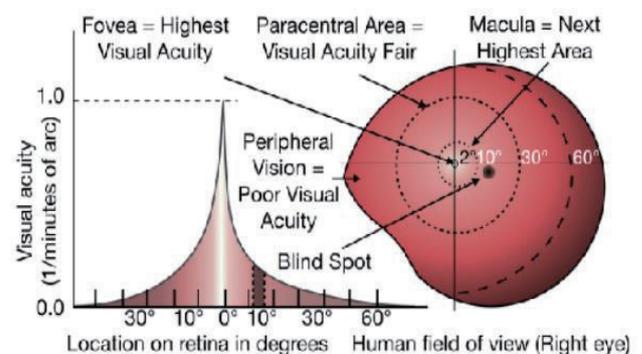


Figure 4 | 人間の視野に関するモデル

(2) 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (以下 CNN) は深層学習モデルの 1 つで、画像処理などのタスクにおいて高い性能を示している [Krizhevsky 12]. 特に CNN の派生である DenseNet [Huang 16] は、CheXNet および AG-CNN の基盤となっているネットワークであるため、本研究でも同様に DenseNet を基盤としてモデルを構築した。

なお、入力次元におけるチャンネル方向の扱い方に関しては本来の DenseNet と異なる方式を採用している。DenseNet では RGB の色情報チャンネル方向に 3 次元として組み込んでいるが、本研究において色情報はグレースケールのため 1 次元のみであり、チャンネル方向では色の代わりに視野の階層数を表している。例えば階層数が 2 の場合、入力次元は 2 となる。

出力層は Softmax (2 クラス)、活性化関数は ReLU、目的関数は CrossEntropyLoss、最適化手法は Adam ($\beta_1=0.9$, $\beta_2=0.999$, $\epsilon=10^{-8}$), 学習率は 10^{-5} , 事前学習は ImageNet, エポック数は 100 とした。

2.4 評価方法

本研究で使用したデータセットは 190 枚 (ユニークな 95 枚の胸部 X 線写真に対して $n=2$ で視線データを収集) となっており、これらを訓練データ 152 枚、テストデータ 38 枚に分割した。

その際、訓練・テストデータ間で、同一の胸部 X 線写真を出現させないようにし、正常・異常の割合を一定にしている。そして、訓練データを用いて学習させ、各エポックごとにテストデータを用いて AUROC を算出し、これを比較することでモデルの良し悪しを評価することにした。

この際、視線データの有用性を精査するため、胸部 X 線写真全体をダウンスケールした画像のみを入力とした場合の結果を Baseline として置き、本研究で提案するモデルと比較した。

また局所画像の階層化の有用性を精査するため、視線データの局所画像部分の階層数は、1 階層 (全体画像と合わせて 2 次元の入力) から 4 階層 (全体画像と合わせて 5 次元の入力) の場合までの AUROC をそれぞれ算出し、比較を行った。

3. 結果・考察

本研究におけるモデル評価の結果は Figure 5, Table 1 に示す通りである。A~E はそれぞれ医師訓練を受けていない 5 名、F~J は医師 5 名を表している。Table 1 の Actual Accuracy は各被験者が正常・異常の判定を行った結果の正答率であり、n Hierarchies は、全体画像+1~n-1 階層の局所画像を入力とした場合の AUROC を表している。

医師訓練を受けていない A~E の被験者の視線データを使用してテストを行った場合、全ての階層数において Baseline を下回る結果となった。一方で、医師である F~J の視線データを利用した場合、F および J が Baseline を上回る結果が得られた。なおこの際、2~5 Hierarchies としてテストを行ったが、各階層間で AUROC に有意な差は認められなかった。

これらの結果より、視線データはモデルの AUROC に影響を及ぼし、特に F や J のような Actual Accuracy の高い医師の視線データを採用することによって胸部 X 線写真における正常・異常の分類において効果的な作用をもたらすことが示唆された。

これはすなわち、より Actual Accuracy の高い被験者の視線データを収集・採用することによって更にモデルの精度が改善する余地があることを表している。

一方で、Actual Accuracy が最も高かった医師 G においては、モデル精度が全ての階層において Baseline を下回る結果であり、Actual Accuracy の高い視線データが必ずしもモデル精度向上に貢献しないことが分かる。この点に関しては診断における熟練度の違いが画像内の各部位への視線の滞留時間等の違いを生む可能性等も視野に入れた上で今後更なる検証が必要である。

4. 今後の展望

本研究を通じて、医師の視線データの利用が胸部 X 線写真に対する深層学習を利用した診断的分類において有効性を持つことが分かった。同時に、Actual Accuracy の高い医師の視線データを使うことが必ずしもモデルの改善を保証しないことも見た。これはすなわち本研究により開発したモデルにおいて捉え切れていない特徴の存在が示唆されているということであり、今後そうした特徴の検証を視野に入れた更なるモデル改善の余地が期待できる。

そうした特徴の一例としては、例えば視線データが持つ時系列的な情報の存在が挙げられる。今回の研究では Maximum Sampling により視線データを視線密度として取り扱ったため時系列的な情報が失われていたが、今後モデルに時系列的な情報を取り入れることにより今回の研究では表現し切れなかった情報を捉え、更なるモデルの改善に繋がる可能性が考えられるため、そうした観点を踏まえて引き続き検証を続けていきたい。

5. 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。

6. 参考文献

- [Rajpurkar 17] Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, Andrew Y. Ng: “CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning”, arXiv: 1711.05225, 2017.
- [Huang 16] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger: “Densely connected convolutional networks”, arXiv: 1608.06993, 2016.
- [Guan 18] Qingji Guan, Yaping Huang, Zhun Zhong, Zhedong Zheng, Liang Zheng, Yi Yang: “Diagnose like a Radiologist: Attention Guided Convolutional Neural Network for Thorax Disease Classification”, arXiv: 1801.09927, 2018.
- [Mnih 14] V. Mnih, N. Heess, A. Graves et al., “Recurrent Models of Visual Attention”, in Advances in neural information processing systems, 2014.
- [Leveque 18] Lucie Leveque, Hilde Bosmans, Lesley Cockmartin, Hantao Liu: “State of the Art: Eye-Tracking Studies in Medical Imaging”, IEEE Access, 2018.
- [Keane 03] Miller-Keane, Marie T. O’Toole, EdD, RN, FAAN: “Miller-Keane Encyclopedia & Dictionary of Medicine, Nursing & Allied Health”, Saunders, 2003.
- [Krizhevsky 12] A. Krizhevsky, I. Sutskever, G.E. Hinton: “ImageNet Classification with Deep Convolutional Neural Networks”, NeurIPS, 2012.

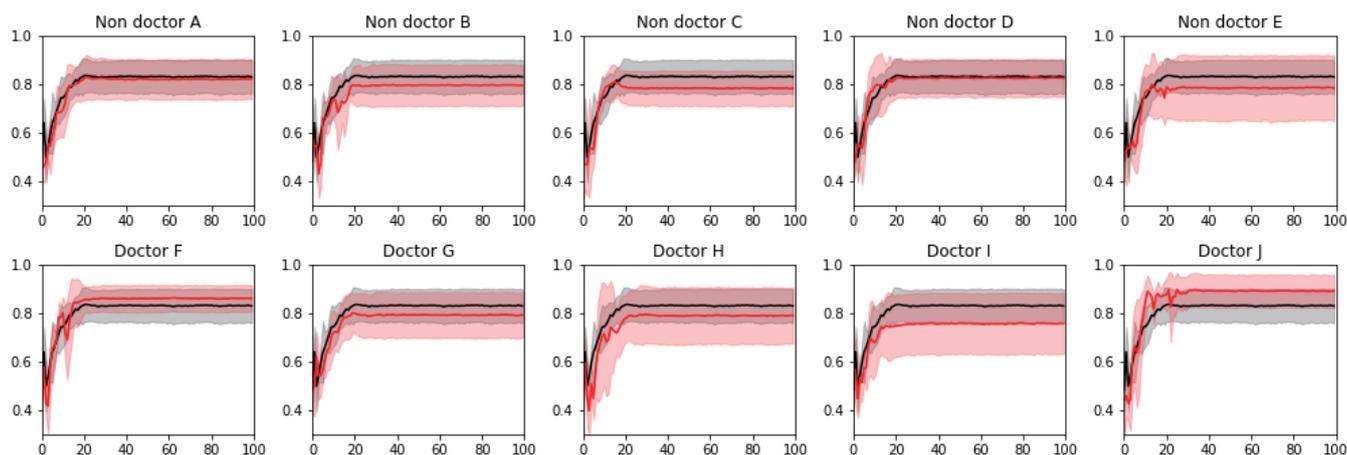


Figure 5 | 3 Hierarchies における各被験者のテストデータに対する精度の推移. 赤線:各被験者のテストデータに対する精度, 黒線: Baseline の精度, 薄い赤で囲まれた領域:各被験者のテストデータに対する精度 \pm SD, 薄い黒で囲まれた領域:Baseline の精度 \pm SD.

Table 1 | 各被験者の視線データおよびモデルごとの比較.

Model	Non doctor					Doctor				
	A	B	C	D	E	F	G	H	I	J
Actual Accuracy ^{※1}	0.770	0.750	0.530	0.620	0.540	0.830	0.860	0.740	0.780	0.850
2 Hierarchies ^{※2}	0.818	0.814	0.814	0.824	0.829	0.856	0.827	0.837	0.820	0.856
3 Hierarchies ^{※2}	0.829	0.800	0.810	0.827	0.800	0.863	0.802	0.795	0.760	0.898
4 Hierarchies ^{※2}	0.789	0.784	0.780	0.801	0.687	0.882	0.834	0.760	0.769	0.859
5 Hierarchies ^{※2}	0.770	0.751	0.758	0.832	0.658	0.866	0.798	0.789	0.776	0.870
Baseline ^{※2}	0.836									

※1:各被験者が正常・異常の判定を行った結果の正答率

※2:AUROC の値

目視点検の損傷画像による鉄筋露出セグメンテーションの転移学習 Eye-inspection Image-based Transfer Learning Rebar Expose using Semantic Segmentation

中島 道浩^{*1} 安野 貴人^{*1} 永富 大亮^{*1} 野田 一弘^{*1} 青柳 聖^{*1} 関口 齊治^{*1}

Yasuno Takato, Nakajima Michihiro, Nagatomi Daisuke, Noda Kazuhiro, Aoyanagi Kiyoshi, Sekiguchi Seiji

^{*1} 八千代エンジニアリング株式会社

Yachiyo engineering, Co., Ltd.

When civil infrastructures have been deteriorated, efficient and accurate diagnosis are required. Especially in municipalities, the shortage of technical staff and budget constraints on repair expenses have become a critical problem. If we can detect damaged photos automatically per-pixels from the record of the inspection record in addition to the 5-step judgment and countermeasure classification of eye-inspection vision, then it is possible that countermeasure information can be provided more flexibly, whether we need to repair and how large the expose of damage interest. Generally speaking, rebar exposure is frequently occurred, and there are many opportunities to judge repair measures. This paper proposes three damage detection methods of transfer learning which enables semantic segmentation in an image with low pixels using damaged photos of eye-vision inspection. In fact, we show the results applied this method using the rebar exposed images on the real bridges (143words).

1. はじめに

近年,土木構造物の劣化が進行しており,コンクリート構造物も多くを占める.特に地方自治体において,技術職員の人材不足に加え,維持管理費に占める点検費用の割合が多いことから,定期点検の効率化が喫緊の課題となっている.社会インフラの点検効率化を実現する手法として,ディープラーニングを適用する機会があり,既往研究が見られる.橋梁は,5年に1回の近接目視点検が義務付けられており,損傷画像の蓄積がある[国交省 2014].点検調査に貼り付けた損傷画像の活用ができれば,過年度の定期点検データを劣化学習の入力に用いることが可能となる.従来の定性的な5段階判定に加え,損傷画像から損傷の程度を数値のスコアとして自動算出できれば,修繕対策をすべきか,修繕候補のなかで優先順位を考える対策情報として有用である.橋梁,建築物,プラント等のコンクリートひび割れ検出については,既往の研究がある.ひび割れは発生頻度が多く,教師画像を比較的生成しやすい.一方,剥離・鉄筋露出は,放置しておくと鉄筋の腐食が進行するため,ひび割れよりも構造物の健全性に与える影響が大きいと考えられる.しかしながら,剥離・鉄筋露出の検出モデルについては緒に就いたばかりであり,劣化学習の手法として確立しているとは言いがたい.剥離は,目視点検の画質を用いることで正確な検出が困難であるものの,鉄筋露出は,目視点検の画質を用いて劣化学習モデルを構築できる可能性がある.本稿では,近接目視点検の損傷画像を用いたコンクリート損傷の

セマンティック・セグメンテーション(以下,セグメンテーションと略す)を適用する実践的な手法を提案する.実際に,橋梁の損傷画像のうち,鉄筋露出に着目し,疎な損傷画像に対して本手法を適用した結果を示す.最後に,損傷検出モデリングの課題に言及する.

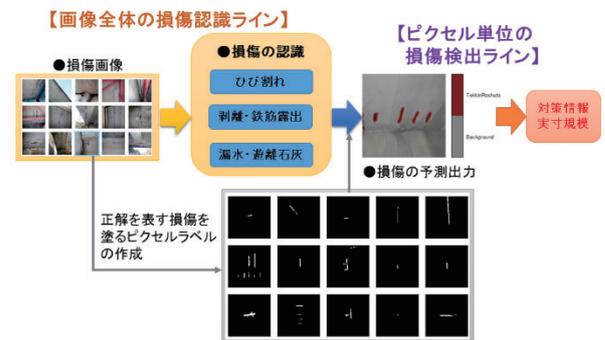


図1 目視点検の損傷画像から認識と検出までの劣化学習ライン

2. 損傷検出の既往研究

2.1 インフラの損傷検出に関する既往研究

2002年より,橋梁の継続監視のために,ニューラルネットワーク(ANN)を用いた損傷検出の解法に関する研究の蓄積がある[Wu 2002][Chun 2015].最近,15年間に,ANNをはじめ,PCA, SVM, GA等の解法を用いた機械学習の損傷検出モデリングが多数行われている[Gordan 2017].2012年に,深い層の畳み込みニューラルネットワーク(CNN)が1,000クラス100万枚の画像分類において,高い精度を発揮する可能性[AlexNet 2012]が報告されてから,CNNの解法は,画像全体のラベル分類,物体検出,ピクセル単位のセマンティッ

ク・セグメンテーションに対して、従来の解法よりも高い精度をもたらす研究が盛んになっている。土木構造物の損傷検出においても、道路舗装、建築物、橋梁のひび割れ、腐食を対象に、画像全体ラベルの損傷分類[Gopalakrishnan 2018][Ricard 2018]、損傷セグメンテーション[Hoskere 2017]の研究が見られる。734枚の損傷画像に対し、損傷なし、剥離のみ、鉄筋の露出（錆なし、錆あり）の4クラスの損傷セグメンテーションを行うため、深いCNNが適用されている[Guillamon 2018]。しかし、損傷クラスの内訳は、3つ目のクラスに510枚と偏り、訓練画像の歪みが否めない。損傷画像のサイズは、640 x 480から1,600 x 1,200まで多岐に渡る。このような様々な画像サイズの入力においても、FCNの3種類のCNNモデルを適用することにより、予測と真実の一致を表す指標 mIoU（クラス平均IoU）が、0.6~0.8の水準まで学習できることが示された。しかしながら、CNNの解法を駆使した損傷検出モデリングは、緒に就いたばかりであり、橋梁の損傷検出の汎用手法が確立されたとは言い難い。本稿では、橋梁の近接目視点検における損傷画像の特性を考慮した損傷セグメンテーションの実用的な手法を提案する。

表2 検出対象とする損傷と背景のピクセル単位の比較

208枚の鉄筋露出が映る損傷写真の例	損傷画像のピクセル総数	1枚当たり平均ピクセル数	1枚に占める割合
背景(Background)	63,683,619	306,171	98.9%
検出対象の損傷(ROI)	725,251	3,487	1.1%
1枚の合計	64,408,870	309,658	100.0%

2.2 目視点検の損傷画像の特性

本稿で対象とする橋梁の近接目視点検において鉄筋露出が映っている損傷画像208枚を通じて、損傷画像の特性を考察する。本特性に一般性は約束できないものの、損傷画像の活用の手掛かりとなると考える。ここで、剥離・鉄筋露出の一般的性状・損傷の定義は、コンクリート部材の表面が剥離している状態を「剥離」といい、剥離部で鉄筋が露出している場合を「鉄筋露出」という。5段階の評価区分は、a, b: 損傷なし, c: 剥離のみが生じている, d: 鉄筋が露出しており、鉄筋の露出は軽微である, e: 鉄筋が露出しており、鉄筋が著しく腐食又は破断している[国交省 2014]。表2に、検出対象とする損傷領域とそれ以外の背景の領域をピクセル

単位でカウントした集計値を示す。目視点検の画像は、撮影距離と画質が完全に統一できるとは限らない。1枚当たりの平均ピクセル数は、30.9万画素である。このなかに、対象とする損傷が占める割合は、高々1.1%に過ぎない。損傷画像の特性は、「損傷領域の占める割合が疎」である。

表3 対象とする損傷写真の画質分布

縦	横	1枚のピクセル総数	最小画素に対する倍率	枚数
378	504	190,512	1.00	163
540	720	388,800	2.04	12
852	1,113	948,276	4.98	33

表3に、208枚の損傷画像における画質サイズの内訳を示す。最小画素のものに対して、2~5倍のばらつきがある。縦横のサイズは、実際には13種類があり、それらを3つのグループに分けた場合の中央値で集計した。このように、損傷画像の特性は、「画像サイズの不均一性」である。現場の作業環境と使用するカメラの制約条件から、損傷との撮影距離は、厳密に一定距離が保持されるとは限らない。過年度の損傷画像を活用する場合、小さい画像サイズを含む、撮影距離が一定でない入力画像においても活用できる手法が求められる。今回、提案する転移学習の手法は、入力画像を縦横 224 x 224 にリサイズし、枚数の少なさを補強するために、+/-30度の回転をランダムに行い生成する。通常、画像分類モデルでは、検出対象が小さく遠目に移っている場合、ズームし画像の中央に位置するように切り出すことが多い。しかし、本稿で提案する損傷検出セグメンテーション・モデルは、畳み込みニューラルネットワーク（CNNと略す）の層を深く内蔵しており、畳み込み操作を繰り返すことで、検出対象が写る位置と大きさが端部に小さく映っていたとしても、損傷の特徴を柔軟に学習できることに利点がある。

3. 損傷検出モデル

3.1 損傷検出セグメンテーション・モデル

本稿では、セマンティック・セグメンテーションの転移学習手法として、FCN-Alex, FCN-VGG16[Long 2015], SegNet-VGG16[Badrinarayanan 2016]を適用比較する。本稿で用いる解法自体には新規性はないものの、1枚に占める検出対象領域の割合が疎である損傷画像に対して、適用可能な実用手法を見出すことを目的とする。FCN-Alexは、Ale

xNetの転移学習によるもので、その末尾の層までCNNを導入し、深さ23層を有する。次に、FCN-VGG16(16s)は、VGG16の転移学習によるもので、密なネットワーク構造で深さ47層を有する。SegNet-VGG16は、自動運転の物体認識に用いられる転移学習の手法で、深さ91層を有する。

本稿では、上記3つのモデルを適用し、計算実行時間、精度、予測出力を比較する。ハイパーパラメータの最適化手法は、損傷画像の疎な特性から、SGDMを用いると検出対象の勾配が消失しやすく、損失関数の改善が見られない問題が生じた。これを克服するため、RMSPropを採用した[Hinton 2012][Mukkamala 2017]。これは、疎な検出対象の勾配変化量を感度よく捉え、前回の更新量を適度に忘れて、勾配の変化量の平方根で除する誤差関数に特徴がある。数値計算では、更新量の重み係数を0.99と設定した。モデル全体の学習係数は、 $1E-5$ とし、ミニバッチを16と設定した。

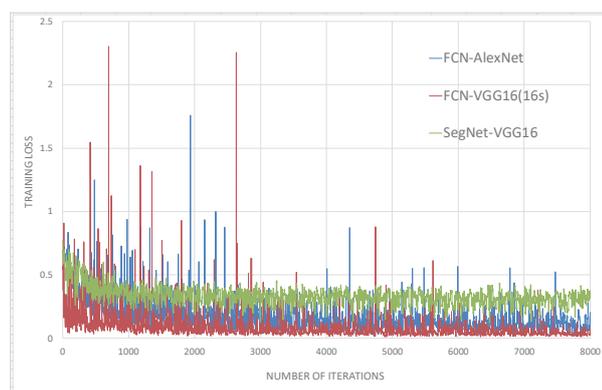


図2 鉄筋露出セグメンテーションの精度と損失関数の推移

4. 適用結果

4.1 転移学習の結果

106 橋の近接目視点検における鉄筋露出の損傷画像 208 枚を対象にし、訓練・テストデータの使用率を、Train : Test = 95 : 5 とした。図 2 に、鉄筋露出セグメンテーションの学習過程での損失関数の推移を示す。計算条件は、1 エポック当たり 832 回で、10 エポックで、計 8,320 回の反復計算を行った。FCN-VGG16 の損失関数が深堀りし、低い水準で推移している。FCN-AlexNet は、FCN-VGG16 よりも損失の値が高く推移している。しかし、2 つの FCN モデルは、損失の分散が大きく、安定性に欠ける点が短所である。SegNet-VGG16 の損失関数はやや高い水準だが、早期に上下変動が小さく推移し、学習過程の優れた安定性(Stability)が読み取れる。

表 3 に、各モデルの計算時間、精度、平均及び重み付き IoU

指標を示す。FCN-Alex は、129 分と相対的に短い計算時間で学習できるが、IoU 指標が高くはない。FCN-VGG16 は、7 時間 40 分の最長の計算時間を所要しているものの、ピクセル単位で損傷位置の真実と予測出力が一致する IoU 指標が良好な水準にある。SegNet-VGG16 は、平均 $mIoU=0.7757$ ならびに重み付き $wIoU=0.9897$ と最高水準となっている。

表3 鉄筋露出セグメンテーションのモデルの指標比較

DNN モデル	計算時間	平均 mIoU	重み付き wIoU
FCN-AlexNet	129min.	0.5291	0.9639
FCN-VGG16(16s)	460min.	0.6662	0.9775
SegNet-VGG16	230min.	0.7757	0.9897

4.2 予測出力

以下では、上記のように鉄筋露出セグメンテーションを学習したモデルを用いて、目視点検のテスト画像 10 枚の予測出力を紹介する。図 3 と図 4 に、鉄筋露出が写るテスト画像に対する各セグメンテーション・モデルの予測出力を示す。

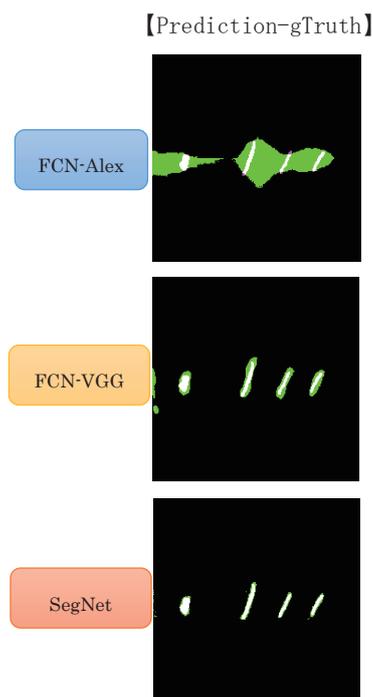


図3 学習した3つのモデルによる鉄筋露出予測 (テスト出力1) 上から3段に渡って、3つのモデルの予測出力を表す。左側は、目視点検の元の画像をベースに、背景を灰色で着色し、鉄筋露出の予測出力を茶色で着色した。右側は、予測と真実の一致するピクセルを白色で表す。予測が真実以外に誤検出したピクセルは緑色で表す。真実が予測されずに漏れたピクセルはマゼンダ色で表す。FCN-AlexNet は、漏れなく真実の鉄筋露出 (白色) を捉えており再現率が高いものの、その周り (緑色) の背景まで予測し、誤検出が増えて正解率が

低くなっている。FCN-VGG16 (16s) の予測出力は、漏れなく真実を捉える点は変わらず、その周りの誤検出が改善されている。さらに、SegNet-VGG16 の予測出力は、漏れなく真実の鉄筋露出を捉えるとともに、その周りの誤検出はほとんどなく、再現率と正解率がともに3つのモデルのなかで良質な水準を達成している。同じ計算条件のもとで、SegNet-VGG16 は、より早くより高い精度で転移学習できる。

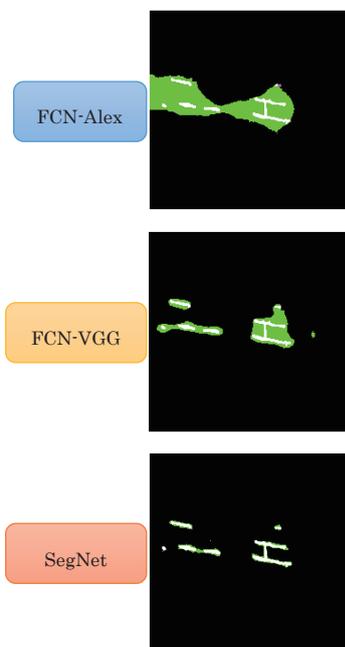


図4 学習した3つのモデルによる鉄筋露出の予測 (テスト出力2)

5. おわりに

本稿では、近接目視点検で得られる損傷画像を用いて、セグメンテーションによる鉄筋露出を検出する3つの転移学習の手法を提案し、実際に、低画質の均一でない損傷画像に適用した。鉄筋露出の教師画像を作成し、ランダムにパッチを生成する前処理を施すことで、損傷画像の数とバリエーションを増すことができた。低画質の均一でない入力画像に対しても、転移学習により迅速に高い精度の学習が可能となった。FCN-AlexNet, FCN-VGG16 は、損傷を漏れなく検出する高い再現率(recall)を發揮したが、その周りに誤検出が生じて正解率(precision)に課題が残った。SegNet-VGG16 は、迅速に高い精度を發揮し、クラス平均の指標 mIoU が 77.57%, 重み付きの指標 wIoU が 98.97%を達成した。4K画質の均一な撮影条件でなくとも、従来の近接目視点検の画像を用いて、セグメンテーションを学習できることが示された。

本稿では、橋梁の近接目視点検における損傷画像を用いて、鉄筋露出の検出に着目した。橋梁の点検項目は、26項目の基準がある[国交省 2014]。鉄筋露出の予兆となる「剥離」を

はじめ、「ひび割れ」「うき」等の損傷に関して、学習用データセット生成と損傷検出モデルの学習が課題である。これらは、鉄筋露出よりも繊細で、背景のコンクリートに埋もれ特徴が希薄である。目視点検を1次スクリーニングと位置づけ、要注意の損傷に着目した局所的な詳細調査として、高画質で撮影した損傷画像の劣化学習が課題となる。今後、バリエーション豊かに他の構造物にも、既存の蓄積した損傷画像を活用して、インフラ劣化学習の草分けに取り組みたい。

【謝辞】 数値計算で、蔵本進一氏、福本拓司氏(MathWorks Japan)に実践的な情報を提供頂いた。感謝の意を表します。

参考文献

- [国交省 2014] 国土交通省道路局: 橋梁定期点検要領, 2014.6.
- [Wu 2002] Wu, Z., Xu, B. Yokoyama, K. : Decentralized Parametric Damage Detection Based on Neural Networks, *Comput. Civ. Infrastruct. Eng.*, 17, pp.175-184, 2002.
- [Chun 2015] Chun, P., Yamashita, et al. : Bridge Damage Severity Quantification using Multipoint Acceleration Measurement and Artificial Neural Networks, 2015.
- [Gordan 2017] Gordan, M., Razak, H.A. et al. : Recent Development in Damage Identification of Structures using Data Mining, *Journal of Solids and Structures*, pp.2373-2401.
- [AlexNet 2012] Krizhevsky, A., Sutskever, I., Hinton, G.E. : ImageNet Classification with Deep Convolutional Neural Networks, in: F. Pereira, C. Burges et al.(Eds.), *Advances in Neural Information Processing Systems*, Vol.25, pp.1097-1105, Curran Associates, Inc., 2012.
- [Gopalakrishnan 2018] Gopalakrishnan, K., Gholami, H. et al. : Crack Damage Detection in Unmanned Aerial Vehicle Images of Civil Infrastructure using Pre-trained Deep Learning Model, *Int. J. for Traffic & Transport Engineering*, 8(1), pp.1-14, 2018.
- [Ricard 2018] Ricard, W., Silva, L. et al. : Concrete Cracks Detection based on Deep Learning Image Classification, *MDPI Proceedings*, 2, 489, pp.1-6, 2018.
- [Hoskere 2017] Hoskere, V., Narazaki, Y. et al : Vision-based Structural Inspection using Multiscale Deep Convolutional Neural Networks, 3rd Huixian International Forum on Earthquake Engineering for Young Researchers, 2017.
- [Guillamon 2018] Guillamon, J.R. : Bridge Structural Damage Segmentation using Fully Convolutional Networks, *Universitat Politècnica de Catalunya*, 2018.
- [Long 2015] J. Long, E. et al. : Fully Convolutional Networks for Semantic Segmentation, *CVPR*, pp.3431-3440, 2015.
- [Badrinarayanan 2016] V. Badrinarayanan, A. Kendall, R. Cipolla, SegNet: Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, *ArXiv:1511.00561v3*, 2016.
- [Hinton 2012] G. Hinton, N. Srivastava, K. Swersky : Lecture 6d – A Separate, Additive Learning Rate for Each Connection, *Slides Lecture Neural Networks for Machine Learning*, 2012.
- [Mukkamala 2017] M.C. Mukkamala et al.: Variants of RMSProp and Adagrad with Logarithmic Regret Bounds, 2017.
- [Yasuno 2018] 安野貴人: 予測メンテナンスとインフラ劣化学習モデル, 第32回人工知能学会, 3Z1-04, 2018.

(2019.2.13)

睡眠日誌アプリを利用した将来の元気度の予測

Cheerful status prediction using “Sleep Diary” application

秋富 穰^{*1}
Jou Akitomi

梶山 征央^{*1}
Ikko Kajiyama

岡島 義^{*2}
Isa Okajima

山口 美峰子^{*1}
Mineko Yamaguchi

^{*1} NEC ソリューションイノベータ株式会社
NEC Solution Innovators, Ltd.

^{*2} 東京家政大学
Tokyo Kasei University

Recently, the problem of insomnia is a social issue. To solve this problem, we develop “Sleep Diary” application depend on the theory of cognitive behavioral therapy for insomnia: CBT-I. It is suggested that users continuously use this application may improve their sleep habituation. However, the continuation of behavior change is difficult for many people. So, we consider that it is required extrinsic motivation method to continuously use the application. In this study, we focused on the cheerful status prediction function as extrinsic motivation method. As a result, our method using random forest classified cheerful status with practical accuracy. Particularly effective features were chosen from average and standard deviation of 7 days sleep data. We will confirm effectiveness of this method.

1. はじめに

睡眠の問題を抱えると、精神面や身体面の両面に悪影響を与えることが知られており、疲労感や集中力の低下による産業事故のリスクを増大させ、生産性の低下など、社会的な問題を引き起こすと言われている[厚生労働省 2014].

睡眠改善の手法の一つとしては、不眠のための認知行動療法 (Cognitive Behavioral Therapy for Insomnia: CBT-I) があり、これまでにその有効性が示されている[Okajima 2011]. 我々はこの CBT-I 技法の一部である睡眠日誌の記録と睡眠衛生についての習慣や知識を提供するためのアプリである「睡眠日誌」アプリを試作開発した。ユーザは、睡眠日誌アプリの利用により、日々の睡眠を記録し、良い睡眠習慣について学び、日々の睡眠の状態を振り返る。ユーザがこのアプリの利用を継続することができれば、ユーザの睡眠習慣が改善されることが期待される。実際に、本アプリの長期利用継続者においては、睡眠の改善効果があるだけでなく、睡眠に関係するその他の生活習慣である夜間のカフェインの摂取や飲酒などについても、摂取頻度が低下するという改善効果があることが示唆されている [石井 2018].

このようなユーザの生活習慣の改善のための行動を如何に継続させるかということ、ユーザの行動変容を考える上で最も大きな課題の一つである。この課題に対する最初のアプローチとして、我々はまず本アプリのユーザが利用継続するか否かを予測する方法の検討を行った。この検討の結果、ユーザが入力した最初の数日間の睡眠データを用いることで、数週間後にそのユーザがアプリの利用を継続しているか否かが予測可能であることが示唆された [秋富 2018]。そこで本研究では、次のステップであるユーザへのアプリ利用の動機付けの方法として、睡眠データによって将来のパフォーマンス (元気度) を予測することに注目した。この機能が実現すれば、アプリの利用の継続により睡眠のデータが蓄積されることで、そのユーザにとって将来の元気度が分かるというメリットが発生するため、アプリの利用の継続を促すための手段と成りえると期待される。

本稿では、これまでに蓄積されている睡眠日誌アプリのデータから、ユーザの翌日の元気度を予測する方法について検討を行った。

2. 元気度

睡眠日誌アプリでは、記録するデータが大きく二つに分けられる。一つは、朝起きたタイミングに記録を推奨している前日の就寝時から当日の起床時までの睡眠に関するデータ (入床時刻、離床時刻など) や、それに付随する生活習慣に関するデータ (夜にカフェインを摂取した、夜に飲酒をしたなど) である。もう一つは、日中の活動が終わった後に一日を振り返るタイミングでの記録を推奨している、その日の元気度のデータである。睡眠日誌アプリのユーザは、この二つのデータを参照することにより、日中の元気度が高くなるための良い睡眠習慣や、自分の元気度が低くなる悪い睡眠習慣について気付きを得ることが出来る。

睡眠日誌アプリでは、ユーザの主観に基づくデータの記録を重視しており、元気度については、アプリから予め用意されている5段階の中からユーザが任意の段階を手入力することで記録される。ここで元気度と呼んでいる値は、基本的には主に眠りの問題において日中の活動に支障があった程度が記録されることを想定しているが、入力内容において特に厳格なルールは定めていないため、ユーザによっては単に疲労の度合いを記録していたり、仕事の生産性のようなものを記録していたりすることがあると考えられる。本稿においては、問題を単純化するため、ユーザの意図は考慮せず、単に元気度として取り扱った。

3. 将来の元気度の予測

本研究では、機械学習の手法の一つであるランダムフォレストを用いて、睡眠データから将来の元気度の予測を試みた。具体的な問題設定としては、あるユーザが記録した一週間分の睡眠データを用いて特徴量を設計し、最後に睡眠データを記録した日の翌日の元気度を予測することとした。

連絡先: 秋富 穰, NEC ソリューションイノベータ株式会社,
東京都江東区新木場 1-18-7, 03-5534-2619,
jou-akitomi@vt.jp.nec.com

なお、睡眠日誌アプリは利用を開始する際にユーザからデータの研究利用についての同意を得ており、データは全て個人を特定できない形に処理した上で使用した。

3.1 使用したデータ

予測に用いたデータは、全て睡眠日誌アプリの入力データから抽出した。抽出したデータ項目は、大きく分類すると、個人属性に関するデータ（年代、性別、主訴の種類など）と、睡眠そのものに関するデータ（睡眠時間、入床時刻、入眠時刻、覚醒時刻、離床時刻など）と、睡眠に関係する生活習慣のデータ（夜にカフェインを摂取したか否か、夜に飲酒をしたか否かなど）と、日中の元気度のデータの四種類である。これらのデータは、全てユーザごと、日ごとに紐付いているが、データの入力には任意であるため、一定の割合で欠損データが存在する。本研究では、予測に用いるユーザの質をある程度一定に保つため、60日以上利用を継続しているユーザの中からデータの欠損が少ない737名（男性370名、女性367名）に限定し、その7日目から60日目までのデータについて抽出を行った。

3.2 実験内容

抽出したデータについて連続7日分を1セットとして扱い、各データの特定区間の平均、標準偏差などを計算することにより特徴量を設計し、最終日の翌日の元気度に基づいてBad, Normal, Goodの3種類のラベルを付加した。ラベルは、元気度1~2点をBad, 3点をNormal, 4~5点をGoodとした。その結果、ユーザの年代別の元気度のラベルの割合は以下の表1の通りであった。

表1. 年代別の元気度の割合 (%)

年代	Bad	Normal	Good
10	23.6	37.6	38.8
20	26.6	42.1	31.3
30	25.4	43.1	31.5
40	21.6	41.6	36.9
50	22.2	41.1	36.7
60	12.9	36.3	50.8
70	5.5	18.8	75.6

表1の通り、抽出された元データはどの年代においてもBadの割合が少ない不均衡データであったため、SMOTE(Synthetic Minority Over-sampling Technique)アルゴリズムによってデータ数の偏りの調整を行った後にランダムフォレストの入力データとした。入力データのうち、80%を学習データとして用い、残り20%を予測データとして用いた。

4. 結果

作成した入力データを用いて、各データセットの元気度がBad, Normal, Goodのどれであるかの予測を行った。予測結果を以下の表2に示す。

表2. 元気度の予測結果

ラベル	正解率	適合率	再現率	F値
Bad	0.887	0.880	0.771	0.822
Normal	0.864	0.778	0.859	0.817
Good	0.917	0.859	0.873	0.866

また、予測に用いられた特徴量の重要度を、ジニ係数を用いて算出した。この算出された重要度を基に、データのカテゴリ別に、どのカテゴリの特徴量の重要度が高かったかを調査した。カテゴリは、個人属性データ（個人属性）、7日間データ（7日間）、3日間データ（3日間）、2日間データ（2日間）の4カテゴリに分類した。その結果を以下の表3に示す。

表3. 特徴量の重要度順位（カテゴリ別） (%)

重要度順位	個人属性	7日間	3日間	2日間
~20	44.4	37.1	8.6	0.0
~40	0.0	20.0	20.0	17.1
~60	0.0	14.3	25.7	17.1
~80	0.0	5.7	22.9	28.6
~100	55.6	17.1	5.7	20.0
~120	0.0	5.7	17.1	17.1

5. 考察

表2によるとBadの再現率とNormalの適合率が他よりも若干低い傾向にあったが、正解率は全体的に高い傾向にあった。今回の問題設定にて予測した元気度は特に直接的に病気に係るなど深刻な健康データであるとは言えないため、今回の試みにおける予測精度は実用的には十分である可能性が高い。

また、表3によると、今回の予測結果において重要な特徴量は、個人属性データや7日間データのカテゴリに多く含まれているということが示唆された。時系列の予測問題において多くは予測するタイミングの直近のデータの重要度が高くなる傾向があるため、今回の結果はユーザの睡眠の状態とそれに関連する元気度という課題設定において特に特徴的な結果であると考えられる。ユーザの元気度により強く影響を与えるのが直近の睡眠の状態ではなく、それより前の7日間の睡眠の状態であると示唆されたことは幾つかの睡眠研究の知見と合致しており、非常に興味深い。

6. おわりに

本稿では、ユーザの健康的な生活習慣の継続支援のための介入方法の一つとして、蓄積された睡眠データを用いた将来の元気度の予測という課題に取り組んだ。将来の元気度の予測という課題に関しては、予測方法や特徴量の設計方法などに未だ改善の余地はあるが、現時点においても十分に実用的と考えられる予測精度を達成することが出来た。今後は実際に予測システムを睡眠日誌アプリに実装し、継続率が向上するか否かの評価をすることが重要であると考えられる。

また、今回取り組んだ将来の元気度の予測という課題には、ユーザの継続支援の他にも様々な応用の可能性があると考えられる。今後は予測精度の向上に取り組むと共に、元気度の予測を応用した新たな課題への取り組みを進めていきたい。

謝辞

本研究について大きな貢献をいただいた NEC ソリューションイノベータの村上紘士さんをはじめ、本研究に協力していただいた皆様に感謝をいたします。

参考文献

- [厚生労働省 2014] 厚生労働省健康局: 健康づくりのための睡眠指針 2014, 2014.
- [Okajima 2011] Isa Okajima, Yoko Kodama and Yuichi Inoue: A meta-analysis on the treatment effectiveness of cognitive behavioral therapy for primary insomnia, *Sleep and Biological Rhythms*, Japanese Society of Sleep Research, 2010.
- [石井 2018] 石井美穂, 秋富穰, 梶山征央, 岡島義, 山口美峰子: 職域での「睡眠日誌」アプリケーションの利用可能性の検討, *産業衛生学雑誌 (産業医学)* (60) 382, 2018.
- [秋富 2018] 秋富穰, 梶山征央, 石井美穂, 岡島義, 山口美峰子: 睡眠日誌アプリの開発と睡眠習慣改善行動の継続の予測, 日本人工知能学会全国大会 (32 回) 講演論文集 3Pin1-52, 2018.

レセプトデータを用いた生活習慣病の発症予測

Prediction of the Onset of Lifestyle-related Diseases Using Health Insurance Claims Data

八重樫 文絵 *¹ 荒木 雅弘 *¹ 岡 夏樹 *¹ 新谷 元司 *² 吉川 昌孝 *³
 Fumie Yaegashi Masahiro Araki Natsuki Oka Motoshi Shintani Masataka Yoshikawa

*¹京都工芸繊維大学 *²SG ホールディングスグループ健康保険組合
 Kyoto Institute of Technology SG Holdings Group Health Insurance Association

*³日本システム技術株式会社
 Japan System Techniques Co., Ltd.

This paper proposes a system which predicts the onset of lifestyle-related diseases using health insurance claims data. In the transportation industry, they try to reconsider health management to take measures against drivers' overwork these days. Previous studies used representation learning for predicting some diseases. Similarly, we regard this issue as a text classification problem in natural language processing and try to make a model which helps drivers' health management. We transformed the health insurance claims into a fixed-length vector and predicted lifestyle-related diseases with UnderSampling and Bagging. As a result, our model achieved 0.75 in the recall of positives. We're sure that the significance of applying natural language processing to health insurance claims data was shown in this study.

1. はじめに

近年、医療情報の電子化により、健康診断結果やレセプトデータを用いた疾病発症リスクの予測や、それに伴う医療費の削減が様々な業界で求められている。特に運送業界では、昨今のインターネット通販の急速な普及による宅配件数の増加に伴うドライバーの過重労働は社会的問題となっており、運転中の事故率は年々増加しつつある [国土交通省 17]。ドライバーの健康管理対策を見直すために新たな対策の考案が急務とされ、医療情報を基にした生活習慣病等の発症予測モデルの開発が期待されている。

発症予測を目的とした先行研究には、血液中の 1130 種類のタンパク質から心疾患に関連する 9 種類のタンパク質を特定し、心疾患リスクスコアの推定法を提案した研究 [Ganz 16] や、健診結果に基づいて心筋梗塞や脳梗塞の発症確率を予測する研究 [Yatsuya 16] がある。これらの研究では、血圧値や採血結果の数値データを主に使用しており、レセプトのような文字列の多いデータには適用できない。そこで、Skip-gram を利用した心不全予測の研究 [Choi 17] や、Bag-of-Words を用いた研究 [Weng 17]、NN による単語の分散表現を利用した研究 [Choi 16][Chen 17][Liu 18][Bo 18] など、医療情報を表現学習として扱っている研究のように、自然言語処理の観点から考えて、本問題を文書分類問題として捉え、可変長データを固定長ベクトル化する方法を試行できないかと考えた。そこで本研究では、特定の運送業者のレセプトデータを用いて生活習慣病に属する複数の疾病名を対象に、今後 1 年以内に発症する可能性のある人を予測することを目的とする。この問題を解決するために我々は、リカレントニューラルネットワークを用いてレセプトデータを固定長ベクトル化し、アンサンブル学習によって識別器を構成する方法を提案する。なお、対象とする疾病名及びそれぞれに対応する関連保健問題の国際統計分類 (ICD)10 は表 1 に示す通りである。

表 1: 予測対象の疾病名

疾病名	ICD10
インスリン依存型糖尿病	E10
インスリン非依存型糖尿病	E11
糖尿病	E14
狭心症	I20
急性心筋梗塞	I21, I22
心筋症	I42
不整脈・伝導障害	I44~I49
くも膜下出血	I60, I690
脳内出血	I61, I691
脳梗塞	I63, I693

2. 提案手法

本研究では、特定健康保険組合が持つ特定個人に関する全てのレセプトを時系列順に並べたものを 1 つの文章として捉え、形成したデータを固定長ベクトル化し、最後にアンサンブル学習で識別器を構成する手法を提案する。

2.1 レセプトデータの扱い

レセプトデータとは患者に対する診療行為や調剤の記録であり、この多くが文字列として保存されている。機械学習で利用するために、我々はこれらの文字列を数値化する方法を検討した。ICU 入室患者の死亡リスク予測を目的とした Nori らの研究 [Nori 17] では、医療費の発生する全ての介入行為に対する属性を 1 とすることで特徴量に加えて数値化を図っているが、これではレセプトデータの時系列性を考慮できない。そこで本研究では、特徴量に性別、年齢、“外来または入院”、摘要名を選択し、以下の例のように各人毎に時系列順にこれらを並べ、1 つの文章として解釈した。この時、摘要名中の薬名はその薬の一般名に置き換える。一般名とはその薬の主成分のことを指し、このように置換することでジェネリック医薬品に

連絡先: 〒 606-8585 京都府京都市左京区松ヶ崎橋上町 1
 京都工芸繊維大学大学院 工芸科学研究科 情報工学専攻
 インタラクティブ知能研究室, yaeg@ii.is.kit.ac.jp

移行した後の変化や、効能が同じなのに別会社の製品であるという違いを吸収できる。

例：Aさんの場合

レセプト 1:[男性, 40 歳, 外来, 初診, インフルエンザ検査, ロキソニン 100mg]

レセプト 2:[男性, 41 歳, 外来, 再診, 大塚生理食注]

↓

[男性 40 歳 外来 初診 インフルエンザ検査 ロキソプロフェン ナトリウム水和物 男性 41 歳 外来 再診 生理食塩水]

2.2 学習データ形成

以下、表 1 に示す疾病名の診断を受けたことがない人を健康者、受けたことがある人を重症者として、それぞれの学習データの形成方法を示す。

まず健康者の場合である。健康者は全員、直近 1 年間のデータを削除する。本稿執筆時点では 2018 年 5 月のデータが最新なので、健康者は 2017 年 5 月以前のデータを使用する。次に重症者の場合、重症疾病名初出から n 个月前以前のデータを使用する。n を 1 から 12 まで一様に分布させ、1 人につき 12 個のデータを作成してデータの拡張を行う。このように“発症の n 个月前までのデータを使う”ようにすることで、数少ない重症者のデータは発症直前まで捨てることなく利用し、かつ、重症者の情報が常に発症直前までのデータであるという偏りを防ぐことができる。図 1 に健康者と重症者のデータ処理方法を示す。

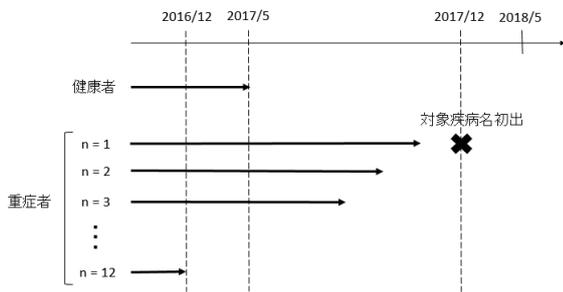


図 1: データの削除

このようにしてできた重症者のデータを図 2 に示すように 12 個に割り振る。ここで、n 個目の Pot に n 个月前以前のデータばかりが集まるのを防ぐため、人毎に機械的に n を 1 ずつずらして分割していく。

	Pot1	Pot2	Pot3	Pot4	...	Pot12
A	n=1	n=2	n=3	n=4	...	n=12
B	n=2	n=3	n=4	n=5	...	n=1
C	n=3	n=4	n=5	n=6	...	n=2
.			.			
.			.			
.			.			

図 2: データの割り振り

こうして作成された重症者のみのデータ群 12 個に対して、次は図 3 に示すように健康者のデータを付加していく。ここで圧倒的に健康者のデータが多いことに対する対策として UnderSampling を行う。重症者と同じ人数だけ健康者の中からランダムにデータを抽出し、Pot のデータ群に付加していく。さらにデータ量を増やすためにこの作業を 1 つの Pot に対して 10 回行う。これを 12 個全ての Pot に適用し、最終的に 120 個の学習データを作成する。

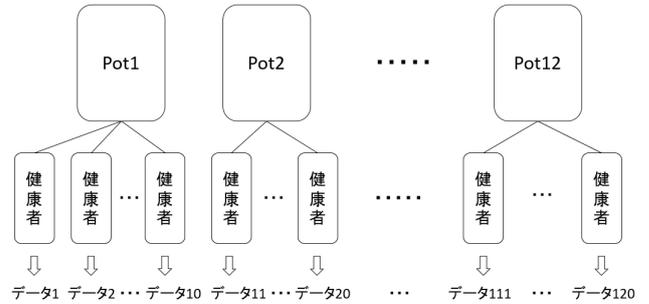


図 3: データの UnderSampling

2.3 固定長ベクトル化

レセプトデータでは、人ごとに通院回数も異なれば一回の診察で行われる診療行為や調剤の数も異なる。つまり形成されたデータは可変長である。この可変長なデータを、図 4 に示すように固定長に変換するために、文書分類問題でよく使用される TF-IDF を利用する方法と、時系列性を加味できる RNN の中間層の出力を取り出す方法を試行した。



図 4: 固定長ベクトル化

2.4 識別器の構成

最後に、固定長ベクトル化された 120 個の学習データを使用して 120 個の弱識別器を作成する。先にも述べたように、本研究で使用するデータは、全体の約 95% が健康者という不均衡なデータである。ここで、不均衡クラス分類問題において確率論的観点から有効な手法を提案した研究 [Wallace 11] では、不均衡なデータセットに対して UnderSampling と Bagging を組み合わせることで精度向上を見込めることが示されている。そこで我々は、図 3 に示したように UnderSampling したデータに対して Bagging を適用し、多数決による予測を行った。なお、Bagging を施すにあたって、それぞれの弱識別器は決定木をもって構成した。

3. 実験

3.1 データセット

データセットには、健保組合から提供された12年間のデータを用いた。予測対象となる疾病名は表1に示す通りで、重症者の教師ラベルを1、健康者は0とした。データの前処理にあたって、健康者の場合、2017年5月より前のデータがない人を削除し、重症者の場合、対象疾病初出のレセプトから1年前より過去のデータがない人及び対象疾病初出のレセプトから1年前までの間にレセプトが1つもない人を削除する。

3.2 予測設定

退職者・死亡者も含む、全77,665人のうち70%を訓練データとして抽出し、残りの30%をテスト用データとして用いた。形成された学習データらを固定長ベクトル化した後に、120個の枝刈りなしの決定木を作り、多数決によって予測結果を決定した。精度はPrecision, Recall, F1-Scoreの数値によって評価した。固定長ベクトル化にはTF-IDFによる方法とRNNの中間層の出力を取り出す方法の二つを用意し、精度比較を行った。RNNにおいては、Embedding層、Dense層、LSTM層、Dense層、Dense層の、5層のネットワークを構成し、第三層目のLSTM層から256次元の固定長ベクトル化された出力を取り出した。Embedding層への入力時、各学習データは可変長系列なので、最大系列長に合わせて入力直前にゼロパディングする。また、最後のDense層にのみ、活性化関数としてsigmoid関数を適用した。最適化法はRMSpropを、損失関数にはBinary Crossentropyを使用した。

3.3 結果

まず、比較のための従来手法を挙げる。従来手法では、健診のいくつかの項目に閾値を設定し、それらの論理和で重症者か健康者かを区分する。その閾値は、日本人間ドック学会が公式に発表している判定区分表に基づいて決定した^{*1}。設定された閾値は以下の通りである。なお血糖値に関しては、人間ドックと今回の健診の条件が異なるため、HbA1cという項目において過去のデータから参考にした値 θ を基準に判定している。

収縮期血圧: 160以上, 拡張期血圧: 100以上, クレアチニン(男性): 1.30以上, クレアチニン(女性): 1.00以上, eGFR: 44.9以下, 尿酸: 9.0以上, HDLコレステロール: 34以下, LDLコレステロール: 59以下, 180以上, 中性脂肪: 29以下, 500以上, AST: 51以上, ALT: 51以上, γ -GTP: 101以上, 血色素量(男性): 12.0以下, 18.1以上, 血色素量(女性): 11.0以下, 16.1以上, 血小板数: 9.9以下, 40.0以上, 尿蛋白: (2+)以上, HbA1c: θ

この従来手法をベースラインに、TF-IDFによる固定長ベクトル化の方法、RNNの中間層の出力を取り出す方法の精度を比較した。表2に重症者の、表3に健康者の実験結果を示す。

今回試行した固定長ベクトル化の内、どちらの方法も健康者のPrecisionは高いが、重症者の場合RNNによる方法の方が少し高い数値を記録した。またRecallについては重症者、健康者ともにRNNを利用した方が良い結果となった。どちらの方法も健康者においてはPrecision, Recall, F1-Score全ての評価で従来手法のそれに劣る結果となったが、重症者において

は、どちらの方法もRecallが従来手法を上回り、RNNを利用した方法に関してはF1-Scoreが従来手法と同等という結果となった。

表2: positive(重症者)の精度比較

	Precision	Recall	F1-Score
従来手法	0.11	0.45	0.17
TF-IDF	0.07	0.56	0.12
RNN	0.10	0.65	0.17

表3: negative(健康者)の精度比較

	Precision	Recall	F1-Score
従来手法	0.98	0.87	0.92
TF-IDF	0.96	0.59	0.73
RNN	0.97	0.64	0.77

表2, 3より、2つの提案手法の内、RNNの中間層を取り出す方法による固定長ベクトル化の方が優位であることが示されたため、この方法で更なる追加実験を行った。我々は、恒川らの研究[恒川19]によって導き出された、識別に有効な健診・問診項目の上位10項目を特徴量に加えた。健診項目からは、HbA1cの値、メタボ判定名、尿糖名、代表判定名、受診年度年齢、心電図判定名の6項目を抽出し、問診項目からは、血圧を下げる薬を飲んでいるか、インスリン注射又は血糖を下げる薬を飲んでいるか、脂質異常症を改善する薬を飲んでいるか、医師から心臓病(狭心症、脳梗塞等)にかかっているといわれたり、治療を受けたことがあるか、という4つの質問を抽出した。健診項目は、HbA1cと年齢が数値で記録され、尿糖名は5段階評価、それ以外は全て6段階評価となっている。問診項目はいずれも、はい又はいいえで回答する形となっている。実験の手順は以下の通りである。まず提案手法で述べた特徴量をRNNを使用して固定長ベクトル化する。次に、先に示した10項目を、one-hot表現として固定長ベクトルに付加する。ただしHbA1cは数値のまま加え、年齢は10代、20代のように年齢層に分割してone-hot表現に変換して加える。こうしてできた特徴ベクトルで決定木を作り、多数決を行った結果が表4である。この結果で、重症者に対するRecallは提案手法の中で最も高い数値を得た。

表4: 健診・問診項目を追加した結果

	Precision	Recall	F1-Score
positive	0.09	0.75	0.16
negative	0.97	0.56	0.71

4. 考察

表2, 3より、提案手法ではRNNによる方法の方がPrecisionの値が向上している。さらにRecallの観点からも、RNNによる方法の方がTF-IDFを利用する方法と比べて高い数値を出している。これらのことから、時系列性を加味できるRNNの中間層を取り出す方法の方が優位であることが考えられる。しかし、健康者はPrecisionもRecallも従来手法の方が良い結果となった。重症者に関しては、提案手法のRecallが従来手法を超え、F1-ScoreはRNNを使用する方法においては同等

*1 <https://www.ningen-dock.jp/wp/wp-content/uploads/2013/09/Dock-Hantei2018-20181214.pdf>

であったが、Precision はどちらも従来手法に劣る結果となった。このような結果になった原因は、データの形成の仕方にあると考える。普通、患者は自身の体調に異変を感じたり健診結果が悪かったからという理由で受診するが、本研究のように重症者において対象疾病名初出から n カ月前以前のデータを使う、というようにデータを削ると、健康者と同じような内容のデータができるのは必然的なことである。一見健康者のようなデータなのに教師信号は 1 というデータが多数あったため、健康者も重症者も従来手法の Precision に劣る結果になったと考える。しかし逆に、そのような方法でデータの预处理をしているにも関わらず、重症者の Recall は提案手法の方が大幅に高く、RNN を使用する手法では F1-Score が従来手法と同等であることも事実である。このことから、レセプトに自然言語処理を適用する形で提案手法のようにデータを処理することに、一定の有効性が認められる。

これらの結果と考察を受け、更なる精度向上を目的とした追加実験では、健診と問診の項目を加えることで重症者に対する Recall の数値を大幅に向上させることに成功した。これは、健診と問診合わせて 57 個ある項目の内から、識別に有効な上位 10 項目を選出したことが精度向上に繋がったと考える。しかし、それでもなお健康者の Recall, F1-Score は従来手法のそれと比較して大幅に低く、重症者に関しても Precision を伸ばすことはできなかった。

ここから精度を上げるためには、各疾病が何に起因して発症するのかを吟味し、それらの情報を特徴量に加えることが必要であると考えられる。例えば本研究でも対象疾病の一つに加えている“インスリン非依存型糖尿病”は、一般的に遺伝により発症するリスクが高いことが知られている。このように、遺伝性や家族の病歴、喫煙や飲酒、毎日の運動量といった生活習慣に関する情報を特徴量として加えることを、専門家も交えて考えることで精度の向上が見込めると考える。

5. おわりに

本研究ではレセプトデータを用いて複数の疾病名を対象に、今後 1 年以内に発症する可能性のある人の予測を試みた。従来手法と比較して、健康者に対する精度は劣る結果となったが、重症者の Recall には大幅な精度向上が見られた。このことから、レセプトデータに表現学習を用いる考え方は有効であると言える。今後の研究では遺伝性、飲酒や喫煙などの生活習慣に関する情報を特徴量に追加することで精度向上を目指したい。

参考文献

[国土交通省 17] 国土交通省:健康起因事故の発生状況と健康起因事故防止のための取組み <http://www.mlit.go.jp/jidosha/anzen/03safety/resource/data/kenkokiinjiko.pdf>, (参照 2019-02-08)

[Ganz 16] Ganz, P., Heidecker, B., Hveem, K., Jonasson, C., Kato, S., Segal, M. R., Sterling, D. G., and Williams, S. A. : Development and Validation of a Protein-Based Risk Score for Cardiovascular Outcomes Among Patients With Stable Coronary Heart Disease., JAMA, Vol. 315, No. 23, pp 2532–2541 (2016)

[Yatsuya 16] Yatsuya, H., Iso, H., Li, Y., Yamagishi, K., Kokubo, Y., Saito, I., Sawada, N., Inoue, M., and Tsugane, S. : Development of a Risk Equation for the Incidence of Coronary Artery Disease and Ischemic

Stroke for Middle-Aged Japanese - Japan Public Health Center-Based Prospective Study., Circulation Journal, Vol.80, No. 60, pp. 1386–1395 (2016)

[Choi 17] Choi, E., Schuetz, A., Stewart, F. W., and Sun, J. : Medical Concept Representation Learning from Electronic Health Records and its Application on Heart Failure Prediction, arXiv:1602.03686, Cornell University (2017)

[Weng 17] Weng, W.-H., Waghlikar, B. K., McCray, T.A., Szolovits, P., and Chueh, C.H. : Medical sub-domain classification of clinical notes using a machine learning-based natural language processing approach, BMC Medical Informatics and Decision Making, Vol. 17, No.1, pp.1–13 (2017)

[Choi 16] Choi, E., Bahadori, T. M., Schuetz, A., Stewart, F.W., Sun, J. : Doctor AI: Predicting Clinical Events via Recurrent Neural Networks, arXiv:1511.05942, Cornell University(2016)

[Chen 17] Chen, M., Hao, Y., Hwang, K., Wang, L.[Lu], and Wang, L.[Lin]. : Disease Prediction by Machine Learning over Big Data from Healthcare Communities, IEEE Access, Vol. 5, pp. 8869–8879 (2017)

[Liu 18] Liu, J., Zhang, Z., and Razavian, N. : Deep EHR: Chronic Disease Prediction Using Medical Notes, arXiv:1808.04928, Cornell University (2018)

[Bo 18] Bo, J., Chao, C., Zhen, L., Shulong, Z., Xiaomeng, Y., and Xiaopeng, W. : Prediction the Risk of Heart Failure With EHR Sequential Data Modeling, IEEE Access, Vol. 6, pp. 9256–9261 (2018)

[Nori 17] Nori, N., Kashima, H., Yamashita, K., Kunisawa, S., and Imanaka, Y. : Learning Implicit Tasks for Patient-Specific Risk Modeling in ICU., Thirty-First AAAI Conference on Artificial Intelligence, pp. 1481–1487 (2017)

[Wallace 11] Wallace, C. B., Small, K., Brodley, E. C., and Trikalinos, A.T. : Class Imbalance, Redux, 2011 IEEE 11th International Conference on Data Mining, DOI:10.1109/ICDM.2011.33, pp. 754–763 (2011)

[恒川 19] 恒川 充, 岡 夏樹, 荒木雅弘, 新谷元司, 吉川昌孝: 健診データを用いた生活習慣病の発症予測, JAMI & JSAI AIM 合同研究会, (2019)

[1H4-J-13] AI application: medicine

Chair:Takeshi Imai Reviewer:Koji Kozaki

Tue. Jun 4, 2019 5:20 PM - 7:00 PM Room H (303+304 Small meeting rooms)

[1H4-J-13-01] Chest X-ray anomaly detection based on normal models of anatomical structures segmented by U-Net

○Kenji Kondo^{1,2}, Jun Ozawa¹, Masaki Kiyono^{2,3}, Shinichi Fujimoto³, Masato Tanaka³, Toshiki Adachi³, Harumi Ito³, Hirohiko Kimura³ (1. Advanced Industrial Science and Technology, 2. Panasonic Corporation, 3. University of Fukui)

5:20 PM - 5:40 PM

[1H4-J-13-02] Lesion Detection based on Normal Model of Vascular Pattern in Base Right Lung on Chest X-ray

○Hirokazu Nosato¹, Kenji Kondo^{1,2}, Yuta Kochi¹, Hidenori Sakanashi¹, Masahiro Murakawa¹, Jun Ozawa¹, Masaki Kiyono^{2,3}, Shinichi Fujimoto³, Masato Tanaka³, Toshiki Adachi³, Harumi Ito³, Hirohiko Kimura³ (1. National Institute of Advanced Industrial Science and Technology, 2. Panasonic Corporation, 3. University of Fukui)

5:40 PM - 6:00 PM

[1H4-J-13-03] Sleep Apnea Detection by Combining Long Short-Term Memory and Heart Rate Variability

○Ayako Iwasaki¹, Chikao Nakayama², Koichi Fujiwara^{2,3}, Yuki Yoshi Sumi⁴, Masahiro Matsuo⁴, Manabu Kano², Hiroshi Kadotani⁵ (1. Faculty of Medicine, Kyoto University, 2. Graduate School of Informatics, Kyoto University, 3. Graduate School of Engineering, Nagoya University, 4. Department of Psychiatry, Shiga University of Medical Science, 5. Department of Sleep and Behavioral Sciences, Shiga University of Medical Science)

6:00 PM - 6:20 PM

[1H4-J-13-04] Clustering Difference of the features of the by Weight Values in the Weighted PLSA using DPC data

○Kazuya Yamashita¹, Chisae Murata¹, Yuichiro Sakamoto², Eiichi Sakurai^{1,2}, Yoichi Motomura^{1,2} (1. AI Research Center,AIST, 2. Saga University)

6:20 PM - 6:40 PM

[1H4-J-13-05] Cluster Features and Transition Patterns in the Analysis Results of Sepsis-related DPC Data with Weighted PLSA Methods

○Chisae Murata¹, Kazuya Yamashita¹, Yuichiro Sakamoto², Eiichi Sakurai^{1,2}, Yoichi Motomura^{1,2} (1. National Institute of Advanced Industrial Science and Technology, 2. Saga University)

6:40 PM - 7:00 PM

U-Net で領域抽出した解剖構造の正常モデルに基づく胸部 X 線異常検知

Chest X-ray anomaly detection based on normal models of anatomical structures segmented by U-Net

近藤 堅司^{*1,*2} 小澤 順^{*1} 清野 正樹^{*2,*3}
Kenji Kondo Jun Ozawa Masaki Kiyono

藤本 真一^{*3} 田中 雅人^{*3} 安達 登志樹^{*3} 伊藤 春海^{*3} 木村 浩彦^{*3}
Shinichi Fujimoto Masato Tanaka Toshiki Adachi Harumi Ito Hirohiko Kimura

^{*1} 産業技術総合研究所 ^{*2} パナソニック株式会社 ^{*3} 福井大学
Advanced Industrial Science and Technology Panasonic Corporation University of Fukui

We report a chest X-ray anomaly detection method based on normal models of anatomical structures, and the corresponding evaluation results. The method consists of segmentation process for anatomical structures and anomaly detection process for the segmented regions. We use U-Net for segmentation and Hotelling's theory for anomaly detection. Targets for segmentation and anomaly detection are nine structures including anatomical structures and boundary lines between anatomical structures. For experimental data assessment, 684 normal cases and 13 abnormal cases were used. Positions and sizes of segmented regions were used as indices for anomaly detection. When cutoff values for anomaly detection are decided by maximizing Youden indices, the sensitivities were all 1.0 and specificities ranged from 0.80 to 1.0 for anatomical structures.

1. はじめに

近年、医用画像を解析処理することで異常を検知し所見や疾患名の推定を行う装置/ソフトウェアが開発されている。それらを用いる診断はコンピュータ支援診断(Computer-Aided Diagnosis: CAD)と呼ばれ、医師の読影精度向上および負担軽減が期待されている。医用画像の中でも胸部X線画像は豊富な情報を含み、その撮影装置は安価で普及率も高いため、胸部X線撮影は胸部疾患診断の第一選択方法になっている。

胸部X線画像の CAD 技術としては、事前に機械学習した病変を検出するものが多く提案されている[Wang 17]。しかしながら、胸部X線画像では奥行き方向に複数の解剖学的構造物が重なって描写され、さらに病変がそれらの解剖学的構造物と重なった場合は病変検出が困難になる。また、胸部X線画像を対象とした正常モデルによる異常検知として、variational autoencoder(VAE)を用いて胸部X線画像の生成モデルを構築し、胸部X線画像の異常検知を試みた取組[上原 16] [黒滝 17]があるが、[上原 16]では定量評価が未だであり、[黒滝 17]では、胸部 X 線画像と他モダリティ画像とを識別する実験しか行っていない。

我々は、この課題に対し、局所解剖学的構造の正常モデルに基づき、解剖学的構造の疾患による変化を検出することで異常検知を行う胸部X線画像 CAD システムの開発を進めている。これまでに、本システムの実現に必要な構成要素である胸部 X 線画像からの解剖学的構造の領域抽出について、U-Net を用いて実装・評価した結果を報告済である[近藤 18][近藤 19]。

本稿では、U-Net を用いて領域抽出した解剖学的構造に対し、解剖学的構造の正常モデルと比較を行うことで異常検知を試みた結果を報告する。

2. 提案手法

提案する局所解剖学的構造の正常モデルに基づく胸部 X 線画像の異常検知手法では、予め解剖学的構造毎に、近傍の画

連絡先: 近藤堅司, 産業技術総合研究所人工知能研究センター, 〒305-8560 茨城県つくば市梅園 1-1-1 中央第 1, kondo.kenji@aist.go.jp

像パターン(見え方), 位置やサイズなどの指標の正常値の分布をモデル化しておき, 異常検知対象の胸部X線画像から抽出した解剖学的構造の指標と正常モデルとの適合度を判定することで, 異常検知を行う(図1)。

本章では, 図1における「解剖学的構造毎の異常検知」の概要を説明する。

2.1 対象とする局所解剖学的構造

胸部 X 線画像診断において見逃されやすい, 縦隔・心臓・大血管・横隔膜などに重なる領域の異常検知を想定し, 領域抽出および異常検知の対象として, 図2に示す9個の解剖学的構造を用いた。F:第一胸椎, I:気管は解剖学的構造そのものであるが, 他は, X 線吸収率が互いに異なる複数の解剖学的構造物によって胸部 X 線画像上に描出される, 解剖学的構造間の境界線である。本研究では, 境界線も含めて解剖学的構造と呼ぶ。

2.2 解剖学的構造の領域抽出

解剖学的構造の領域抽出には, encoder-decoder 型の Fully Convolutional Network (FCN) の一種である U-Net を用いた[Ronneberger 15]。また, この U-Net を, 胸部 X 線画像の肺野, 心臓, 鎖骨領域の multi-class segmentation に適用した技術[Novikov 18]を参考に U-Net の構造を決定した。

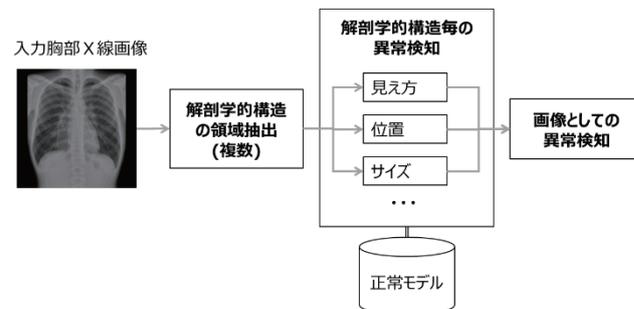


図 1 局所解剖学的構造の正常モデルに基づく胸部 X 線画像の異常検知

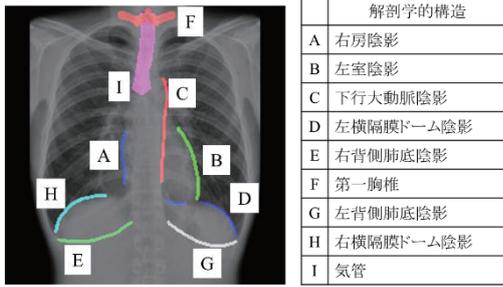


図2 対象とする局所解剖学的構造

解剖学的構造	
A	右房陰影
B	左室陰影
C	下行大動脈陰影
D	左横隔膜ドーム陰影
E	右背側肺底陰影
F	第一胸椎
G	左背側肺底陰影
H	右横隔膜ドーム陰影
I	気管

表1 異常症例13症例の異常箇所

	異常を有する解剖学的構造									疾患
	A	B	C	D	E	F	G	H	I	
異常症例1	○									不明
異常症例2	○									肺炎
異常症例3	○				○			○		肺炎
異常症例4		○								不明
異常症例5		○								不明
異常症例6			○	○						不明
異常症例7			○	○						肺炎
異常症例8			○	○			○			肺癌
異常症例9					○					肺炎
異常症例10							○			気胸
異常症例11								○		不明
異常症例12									○	甲状腺腫瘍
異常症例13									○	甲状腺腫瘍

2.3 局所解剖学的構造の正常モデルに基づく異常検知

予め用意した胸部に疾患のない(以下, 正常)胸部X線画像セットに対し, 領域抽出した解剖学的構造毎に, 予め定めた指標を算出し, 前記指標の分布を獲得しておく. 本稿では, 指標の分布を正規分布と仮定するホテリング理論を用いて, 解剖学的構造毎および指標毎の異常検知を行う. 正常胸部X線画像セットから得られた, ある1次元指標 x の分布の標本平均を $\hat{\mu}$, 標本分散を $\hat{\sigma}$ とすると, 新たな観測値 x' の異常度は, 次式で求められる. 解剖学的構造毎及び指標毎に得られた分布(即ち, 標本平均と標本分散)を正常モデルと呼ぶ.

$$a(x') = \left(\frac{x' - \hat{\mu}}{\hat{\sigma}} \right)^2$$

3. 評価実験

3.1 実験データ

福井大学病院の, 正常胸部 X 線画像 684 症例および, 胸部に疾患のある(以下, 異常)胸部 X 線画像 13 症例を用いた. 本研究は, 福井大学医学系研究倫理審査委員会の承認を得て実施している.

正常症例については, 解剖学的構造の領域検出の機械学習および定量評価のために, 診療放射線技師および読影教育を受けた作業者が, 図2の解剖学的構造について領域マスク画像(二値)を手作業で作成した. 実験で用いる胸部 X 線画像は次のように加工して用いた.

- 画像の幅と高さが異なる胸部 X 線画像(DICOM)について余白を付加して正方形状に変換後, 256×256 画素へ縮小(領域マスク画像も胸部 X 線画像と同様の方法で縮小)
- 胸部 X 線画像の輝度値に関しては, DICOM header のウィンドウ幅(WW), ウィンドウレベル(WL)を利用して正規化を行った後, float に変換

正常 684 症例を無作為に 300,300,84 個の集合に分割し, それぞれ, U-Net 学習, 正常モデル構築, 異常検知評価に用いた. 異常 13 症例については, 図2で示す解剖学的構造付近が疾患の影響で変化しているものを評価者が目視で選定した. なお, 定量評価のために, 異常症例に対して近辺に異常が生じている解剖学的構造の種類を記録した(位置やサイズなどの異常の種類は記録していない). 異常症例毎の異常箇所と疾患名を表1に示す. 今回は適切な異常症例を選定できなかった F を除く解剖学的構造毎に 2~3 個の異常症例を選定した.

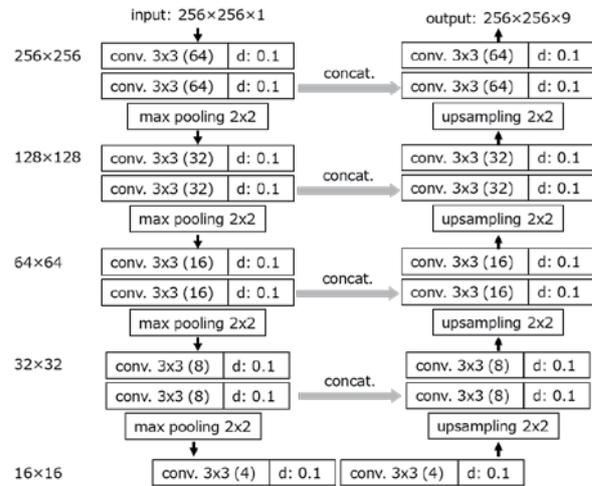


図3 実験に用いた U-Net の構造

3.2 U-Net を用いた解剖学的構造領域抽出

(1) U-Net のネットワーク構造

実験に用いた U-Net の構造を図3に示す. U-Net への入力の前節の方法で DICOM 画像を加工した胸部 X 線画像(256×256×1(float))であり, U-Net からの出力は, 図2の9つの解剖学的構造の領域をそれぞれ予測した画像(256×256×9(float))である. 以下, 図3の記載法について補足する. "conv. 3×3 (fx)"はサイズ 3×3(×前層の特徴マップ数)のフィルタを fx 個用いる convolution 層を, "d: 0.1"は確率 0.1 の dropout 層を, 左端の 256×256 等は特徴マップの画像サイズを表している. 図3の U-Net では stride および kernel size が 2×2 の max pooling を 4 回行うことで, 最も低解像度の特徴マップの幅および高さは, 入力画像の 1/16 のサイズとなる. なお, convolution 層の活性化関数として Rectified Linear Unit(ReLU)を, 最終層の活性化関数として sigmoid を用いている. 学習時の損失関数として, 領域マスク画像の教師データとネットワーク出力画像間の Dice 係数の 9 クラスに関する平均値に(-1)を掛けた値を使用した.

(2) U-Net の解剖学的構造領域抽出性能

正常胸部 X 線画像と教師画像となる領域マスク画像 9 画像の組 300 セットののうち, 無作為に抽出した 270 セット(9割)を訓練に, 残りの 30 セット(1割)を検証に用いた. 検証用データセットに対する領域抽出性能(Dice 係数)を, 表2に示す. [近藤 19]における同一ネットワーク構造での性能と比較すると, 検証データに対する平均 Dice 係数は 0.784 から 0.773 に低下している.

表 2 U-Net の領域抽出性能 (Dice 係数)

for training		for validation								
ave.	ave.	A	B	C	D	E	F	G	H	I
0.857	0.773	0.694	0.750	0.788	0.766	0.696	0.914	0.655	0.790	0.908

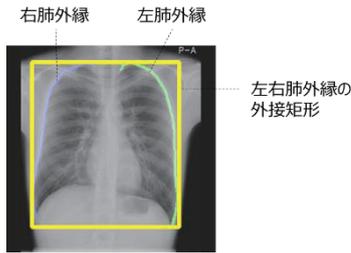


図 4 抽出した左右肺外縁とその外接矩形の例

訓練データセット数が 615 から 270 に凡そ半減した影響と考えられる。

3.3 局所解剖学的構造の正常モデルの構築

本稿では、U-Net で抽出した解剖学的構造の領域に対し、①領域重心位置(2次元座標)、②領域面積(1次元)、③細線化後線長(1次元)の3種類を異常検知の指標として利用した。特に②は F:第一胸椎や I:気管のような解剖学的構造そのもの、③はそれ以外の解剖学的構造間の境界線に対する指標として採用した。

なお、体格や撮影位置の影響をキャンセルするため、別途、U-Net で左右肺外縁の検出を行い、検出した肺外縁の外接矩形(以下、胸郭矩形)で正規化した後で各指標を用いた。左右肺外縁とその外接矩形の例を図 4 に示す。

(1) 解剖学的構造の重心位置

訓練済 U-Net を用いて、正常モデル構築用 300 症例から 9 個の解剖学的構造を抽出し、胸郭矩形で正規化後の、抽出領域の重心位置の 2 次元分布を図 5 に示す。図 5 では、分布の度数を疑似カラーで表示しており、また、縦軸と横軸は胸部 X 線画像の縦横とそれぞれ対応しており、黄色の枠は胸郭矩形に相当する。9 個それぞれの 2 次元正規分布の平均・分散を正常モデルとした。

(2) 解剖学的構造の領域面積

胸郭矩形で正規化後の、解剖学的構造(F, I)の領域面積の 1 次元分布を図 6 に示す。横軸が領域面積、縦軸は度数である。それぞれの 1 次元正規分布の平均・分散を正常モデルとした。

(3) 解剖学的構造間の境界線の線長

胸郭矩形で正規化後の、解剖学的構造間の境界線(F, I 以外)の細線化後線長の 1 次元分布を図 7 に示す。横軸が境界線長、縦軸は度数である。それぞれの 1 次元正規分布の平均・分散を正常モデルとした。

3.4 局所解剖学的構造の正常モデルに基づく異常検知

前節で構築した正常モデルを用いて、正常 84 症例および異常 13 症例の計 97 症例に対して異常検知を行った。図 5~図 7 に示す分布を正規分布と仮定し、2.3 節で説明したホテリング理論を利用した(正規分布と見做せるかどうかの検定は今回行っていない)。解剖学的構造毎に異常検知を行い、3.3 節(1)に示した指標である重心位置は全解剖学的構造に対して、(2)に示した領域面積は解剖学的構造 F, I に対して、(3)に示した線長は解剖学的構造間の境界線(F, I 以外)に対して適用した。なお、今回は(1)重心位置、(2)面積、(3)線長のいずれかの異常度

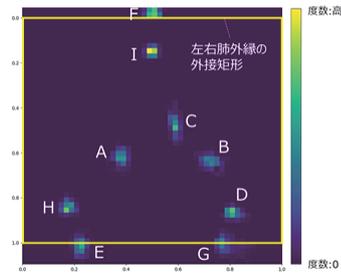


図 5 解剖学的構造重心位置の 2 次元分布

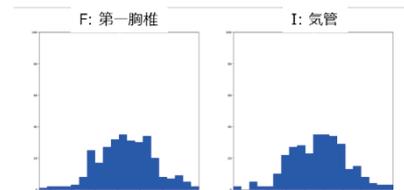


図 6 解剖学的構造面積の分布

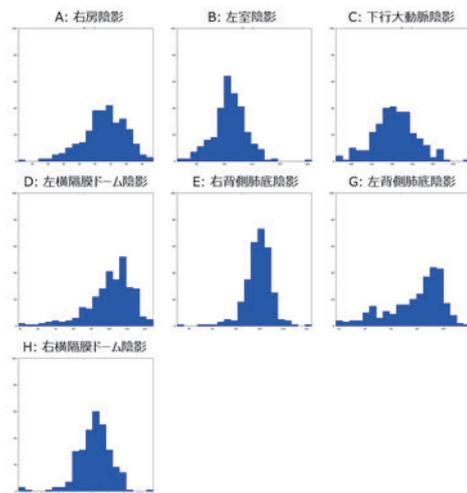


図 7 解剖学的構造間境界線長の分布

a(x)がカットオフ値以上となる場合に、その解剖学的構造を異常と判定した。

(1) 定量評価

解剖学的構造毎の異常検知性能を表 3 に示す。表 3 では、解剖学的構造毎に ROC 解析における area under the curve 値 (AUC), Youden 指数(感度+特異度-1)[Youden 50]の最大値、以下 Youden 指数最大時の、カットオフ値(異常度閾値)、感度、特異度、True Positive 数 (TP), False Negative 数 (FN), True Negative 数 (TN), False Positive 数 (FP)を記載している。異常症例のない F:第一胸椎については、Youden 指数が計算できないため評価を行っていない。結果では、いずれの解剖学的構造においても感度は 1 となった。今回は人が目視で解剖学的構造に変化のある異常症例を選定したため、結果的に異常検知が容易な異常症例が集まった可能性がある。今後、一見異常と分かりにくい異常症例に対しても評価を行う必要がある。また、A: 右房陰影について特異度が 0.80 と低くなっている。その理由は、異常症例として選定した 1 つの症例(図 8 の異常症例 1)で比較的良好に A: 右房陰影が抽出できてしまったため、カットオフ値が低く設定されたことによる。異常があっても解剖学的構造

表3 解剖学的構造毎の異常検知性能

解剖学的構造	AUC	最大 Youden 指数	カットオフ値 (異常度閾値)	感度 (陽性率)	特異度 (1-偽陽性率)	TP	FN	TN	FP
A	0.92	0.80	2.90	1	0.80	3	0	75	19
B	0.99	0.98	9.44	1	0.98	2	0	93	2
C	1.00	1.00	29.58	1	1.00	3	0	94	0
D	0.97	0.96	20.00	1	0.96	3	0	90	4
E	0.99	0.99	28.85	1	0.99	2	0	94	1
G	0.95	0.94	9.06	1	0.94	2	0	89	6
H	0.99	0.99	21.97	1	0.99	2	0	94	1
I	0.97	0.97	12.94	1	0.97	2	0	92	3

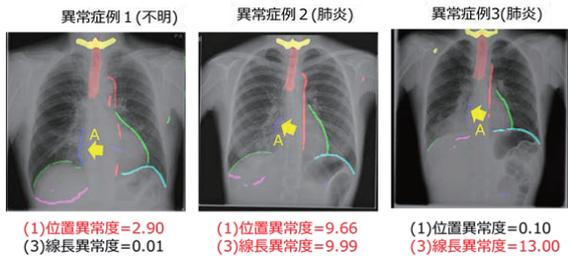


図8 A: 右房陰影付近に異常がある異常3症例

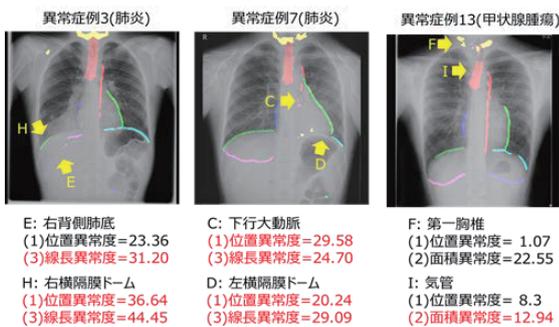


図9 異常を正しく検知した症例

が抽出できてしまう場合に対しては、解剖学的構造付近のアピランス(見え方)を利用した異常検知が必要と考える。その他の解剖学的構造については、異常度閾値が9を超え、即ち、正常症例における指標の正規分布において標準偏差の3倍を超える閾値となっており、ほぼ妥当な閾値が設定されていると考える。

(2) True positive の例

異常を正しく検知した(true positive)の例を、図9に示す。

図9左の異常症例3(図8右と同一)は、右下葉に肺炎が存在しており、その影響によりE:右背側肺底、H:右横隔膜ドーム(A:右房)に関する異常度が閾値を超え、異常を検知できている。図9中央の異常症例7は、左下葉に肺炎が存在しており、C:下行大動脈、D:左横隔膜ドームに関する異常度が閾値を超え、異常を検知できている。図9右の異常症例13は、甲状腺腫瘍により気管支が左に圧排されており、I:気管に関する異常度が閾値を超え、異常を検知できている。特に、異常症例7は心臓裏に重なる肺炎であり、異常症例13は縦郭内に存在する甲状腺腫瘍であり、双方とも病変自体は視認しづらく見逃しやすい症例であるが、正しく異常検知できていることが分かる。

4. 結び

局所的な解剖学的構造の正常状態をモデル化し、疾患による解剖学的構造の変化を検出することで異常検知を行う。胸部X線画像異常検知手法の概要と実験結果について報告した。領域抽出対象として、第一胸椎や気管のような解剖学的構造や、下行大動脈陰影などの解剖学的構造間の境界線である線構造の計9個を扱った。また、それらの位置、面積、線長を異常検知の指標とし、前記指標の分布を正規分布と仮定するホテリング理論を用いて、解剖学的構造毎および指標毎の異常検知を行った。正常84症例および異常13症例の計97症例を用いた定量評価では、Youden指数最大基準で決定したカットオフ値を用い、評価対象の異常症例が無い1個を除く8個の解剖学的構造に関して、感度1、特異度0.80~1.0を確認した。

今後は、対象とする解剖学的構造を増加させ、解剖学的構造付近のアピランスによる異常検知も追加すると共に、False positiveの削減に取り組む。

参考文献

- [Ginneken 06] B. Ginneken, M. Stegmann, and M. Loog, "Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database," *Medical Image Analysis*, vol. 10, pp. 19–40, 2006.
- [Novikov 18] A. Novikov, D. Lenis, D. Major, J. Hladuvka, M. Wimmer, and K. Buhler, "Fully Convolutional Architectures for Multi-Class Segmentation in Chest Radiographs", *IEEE Transactions on Medical Imaging* 37(8), 2018.
- [Ronneberger 15] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation". In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 234–241. Springer, 2015.
- [Wang 17] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, R. Summers, "ChestX-ray8: Hospital-scale ChestX-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases", *CVPR2017*, 2017.
- [Youden 50] W. J. Youden, "Index for rating diagnostic tests", *Cancer*, 3(1), pp 32–35, 1950.
- [上原 16] 上原雅俊, 味曾野雅史, 中山浩太郎, 山口亮平, 河添悦昌, 大江和彦, 松尾豊, "生成モデルを利用した X 線写真に対する異常検知の試行と考察", 第2回日本医療情報学会「医用知能情報学研究会」人工知能学会「医用人工知能研究会」(SIG-AIMED)合同研究会, 2016.
- [黒滝 17] 黒滝紘生, 中山浩太郎, 上原雅俊, 山口亮平, 河添悦昌, 大江和彦, 松尾豊, "深層学習による胸部X線写真からの診断補助", 第31回人工知能学会全国大会, 2017.
- [近藤 18] 近藤堅司, 小澤順, 清野正樹, 藤本真一, 田中雅人, 安達登志樹, 伊藤春海, 木村浩彦, "U-Net を用いた胸部 X 線画像からの解剖学的構造の領域抽出", 第32回人工知能学会全国大会, 2018.
- [近藤 19] 近藤堅司, 小澤順, 清野正樹, 藤本真一, 田中雅人, 安達登志樹, 伊藤春海, 木村浩彦, "深層学習を用いた胸部 X 線画像からの解剖学的構造の領域抽出", *生体医工学*, 2019(掲載予定).

胸部 X 線右肺底領域における肺血管正常モデルに基づく病変検出 Lesion Detection based on Normal Model of Vascular Pattern in Base Right Lung on Chest X-ray

野里博和*¹ 近藤堅司*^{1*2} 河内祐太*¹ 坂無英徳*¹ 村川正宏*¹ 小澤順*¹
Hirokazu Nosato Kenji Kondo Yuta Kochi Hidenori Sakanashi Masahiro Murakawa Jun Ozawa

清野正樹*^{2*3} 藤本真一*³ 田中雅人*³ 安達登志樹*³ 伊藤春海*³ 木村浩彦*³
Masaki Kiyono Shinichi Fujimoto Masato Tanaka Toshiki Adachi Harumi Ito Hirohiko Kimura

*¹ 産業技術総合研究所

Advanced Industrial Science and Technology

*² パナソニック株式会社

Panasonic Corporation

*³ 福井大学

University of Fukui

Abstract: This paper describes a lesion detection method based on normal model of vascular pattern in base right lung on chest X-ray photographs and its conducted evaluation results. The base right lung area, which is one of anatomical structures, shows clearly pulmonary blood vessels. Thus, in this area, changes of vascular pattern caused by chest lesion can be observed. Therefore, to distinguish apparent changes of vascular pattern caused by lesion, we use higher order local auto-correlation (HLAC) features to represent the geometrical information of vascular pattern in base right lung and sub-space method to form a normal model of vascular pattern without lesion. Through the experiments conducted with real clinical chest X-ray photographs, the proposed method achieves 92.9% in recall and 89.5% in specificity in anomaly detection including normal and three types of chest lesions.

1. はじめに

近年、医用画像のデジタル化の普及により、コンピュータ解析処理を用いた異常検出や疾患推定を行う装置/ソフトウェアの研究開発が進み、臨床現場への適用が進みつつある。それらを用いた診断は、コンピュータ診断支援 (Computer-Aided Detection/Diagnosis) と呼ばれ、コンピュータで定量的に解析された結果を「第 2 の意見」として利用する「医師による診断」[藤田 07]とされている。

現在の医療において用いられる医用画像には X 線、CT、MRI、内視鏡などがあるが、X 線検査が最も広く普及している。特に胸部 X 線検査は、胸部全体に X 線を照射して得られる平面的な画像に基づいて肺や心臓など我々の生命活動を支える胸部臓器の異常検出を行う検査で、健康診断などの基本的な検査にも含まれる優れた方法である。しかしながら、胸の中の立体的な構造物 (臓器、骨格、血管など) が重なり合って描写されているため、病変がこれら構造物に重なっていた場合、その病変を直接診断することが困難となる。この問題は、胸部 X 線を対象とした CAD においても共通な問題であり、事前に定義された病変画像を機械学習することを前提とした CAD システムにおいては、映っていない病変を検出することはできない。

この問題を解決するため、近藤らは胸部 X 線画像に映る解剖学的構造に基づいた病変検出アプローチを提案し、それに向けた解剖学的構造の抽出手法を提案した[近藤 18]。解剖学的構造とは、胸部の臓器などの構造物およびそれらの境界線のことで、これらは正常な胸部 X 線画像において、おおよそ決まった位置、大きさ、角度、陰影状態を示している。胸部に病変が存在した場合、これら解剖学的構造は、その病変の影響により正常な状態から変化する。この変化は、それぞれの解剖学的構造に対し医学的な根拠に基づいた変化として現れるため、この変化を検出することにより、病変自体が映ってなくても、異常の有無を検出することができる。

連絡先: 野里博和, 国立研究開発法人産業技術総合研究所
人工知能研究センター, 〒305-8560 茨城県つくば市梅園
1-1-1 中央第 1, 029-861-3842, h.nosato@aist.go.jp

そこで本稿では、解剖学的構造である右肺底領域の血管影に着目し、この領域の血管影が肺疾患により正常と異なることを利用し、正常な肺の肺血管の状態 (太さ、広がり、組織構造など) を学習して、病変を検出する異常検出手法を提案する。正常胸部 X 線画像 697 症例、異常胸部 X 線画像 14 症例を用いた実験の結果、提案手法による病変検出の有効性を確認した。

2. 胸部 X 線診断と解剖学的構造

2.1 胸部 X 線診断

胸部 X 線検査は、胸部全体に X 線を照射して平面撮影し、胸部にある臓器 (主に肺・心臓・大動脈) に異常がないかを調べるための検査で、その撮影装置は安価で普及率も高いため、一般の検診にも採用されるなど胸部疾患診断の第一選択方法となっている。胸部 X 線を対象とした CAD の研究開発は 1964 年から始まっており[田中 12]、近年では、深層学習等の機械学習を用いて、事前に病変画像を学習して検出するものが多く提案されている[Rajpurkar 17] [Wang 17]。しかしながら、胸の中で複数重なり合っている解剖学的構造物が病変と重なった場合は直接的な検出が非常に難しくなる。

2.2 解剖学的構造に基づいた病変検出

胸部 X 線画像中には、心臓、肺、大動脈、横隔膜、肋骨、鎖骨、胸椎など多くの解剖学的構造が描写されている。近藤らは、その中でも胸部 X 線画像診断において見逃されやすい、縦隔・心臓・大血管・横隔膜などに重なる領域の異常検出を想定し、評価対象の解剖学的構造として図 1 に示す 9 個を対象とした領域抽出を行っている[近藤 19]。健常者の胸部 X 線画像に描写される解剖学的構造物は、個人差はあるもののおおよその位置や形状が一定であるので、正常の解剖学的構造領域を正確に抽出できれば、それからの逸脱を測ることで病変検出が可能となる。

これら解剖学的構造のうち、H (右横隔膜ドーム) と E (右背側肺底) の境界線で囲まれた領域 (図 1 の赤い網掛け部位) には、

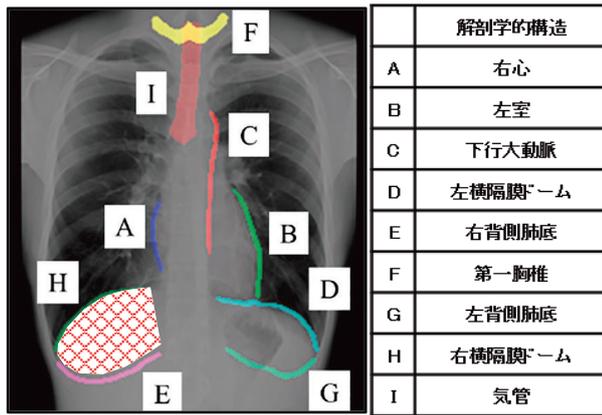


図 1 9種の解剖学的構造と右肺底領域

右肺底領域に関する情報が含まれている。この領域は、肺底部で横隔膜に沿って湾曲している領域で、肺組織の重なりが他の肺野より少なく、肺組織の情報が明確に描写されている。特に、肺組織内の血管情報(太さ、広がり、組織的構造など)が観察でき、正常状態と病変による血管像の変化を比較することで病変検出が可能になることが期待できる。そこで本稿では、この右肺底領域を対象とした、異常検出を試みる。

3. 提案手法

3.1 基本アプローチ

本研究では、胸部 X 線画像の解剖学的構造に基づいた病変検出を目的として、高次局所自己相関(Higher-order Local Auto-Correlation: HLAC)特徴[Otsu 88]を用いた、正常画像に基づく胸部 X 線画像からの異常検出手法を提案する。筆者らは、これまでに病理組織画像に対し、正常組織とがんの含まれる組織の画像を自動分類するための、画像認識による診断支援技術を提案している[Nosato 12]。この技術は、細胞や細胞核などの組織内構造物の輪郭から形態的特徴を計算する自動診断手法[Demir 05]とは異なり、対象画像全体から幾何学的特徴である HLAC 特徴量を算出する。この HLAC 特徴量には、対象領域中の全体的な組織の状態や構成する組織の特徴が統計的な数値として表現されており、これら数値の違いを多変量解析や機械学習による判別手法などを用いて分類することができる。

本稿では、解剖学的構造物である右肺底領域の X 線画像から観察できる陰影に含まれる血管像を総合的に評価するため、HLAC 特徴を用いるアプローチを適用することで、領域内の血管像を数値化し、正常状態との変化に基づいた評価を自動化し、病変の検出を行う。

3.2 右肺底画像からの特徴抽出

図 2 に本稿で特徴抽出を行う対象領域を示す。まず、胸部 X 線画像(図 2a)から赤枠の領域を、深層学習を用いた自動領域検出手法[近藤 18]により抽出した解剖学的構造の E と H を基準に右肺底領域(図 2b)として切り出す。次に、切り出した右肺底領域から HLAC 特徴量を抽出する。本稿では、この右肺底領域内部の陰影情報のみから病変検出を行うため、図 2c に示すように画素単位で内接する領域を対象として HLAC 特徴を算出する。

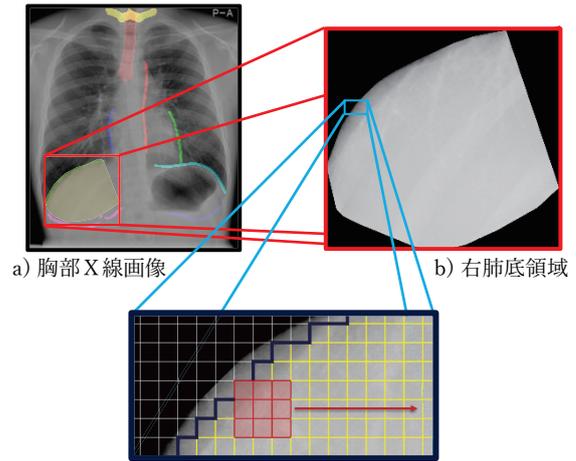


図 2 特徴抽出の対象領域

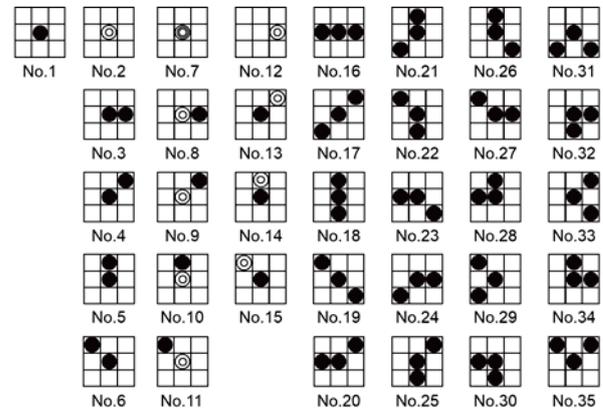


図 3 高次局所自己相関特徴のマスクパターン

対象の右肺底領域画像を $f(r)$ とすると、 N 次の自己相関関数は、変異方向 $(a_1 \dots a_N)$ に対して、

$$x_N = \int f(r) f(r + a_1) \dots f(r + a_N) dr$$

で定義される。本稿では、変異方向 a を参照点 r の周囲の 3×3 画素の領域に限定し、自己相関係数の次数 $N=2$ とした時、対象領域を走査した際に重複するパターンを除外すると、図 3 に示す 35 個の局所パターンに集約される。本稿では、これら 35 個の局所パターンから算出する 35 次元のベクトルを対象領域のピクセル数で正規化し HLAC 特徴とする。

3.3 異常度算出

本稿では、正常の胸部 X 線画像の右肺底領域から抽出した HLAC 特徴量を正常部分空間法[Nanri 05]により算出した正常部分空間(正常モデル)の規定ベクトルを基に、正常モデルからの逸脱度を算出し、異常判別の指標とする。逸脱度は、正常部分空間の直交補空間への射影成分の距離 d_{\perp} とすると、算出した正常部分空間の規定ベクトル U_K 、単位行列 I_M を用いて、以下のように算出する。

$$d_{\perp}^2 = x^T (I_M - U_K U_K^T) x$$

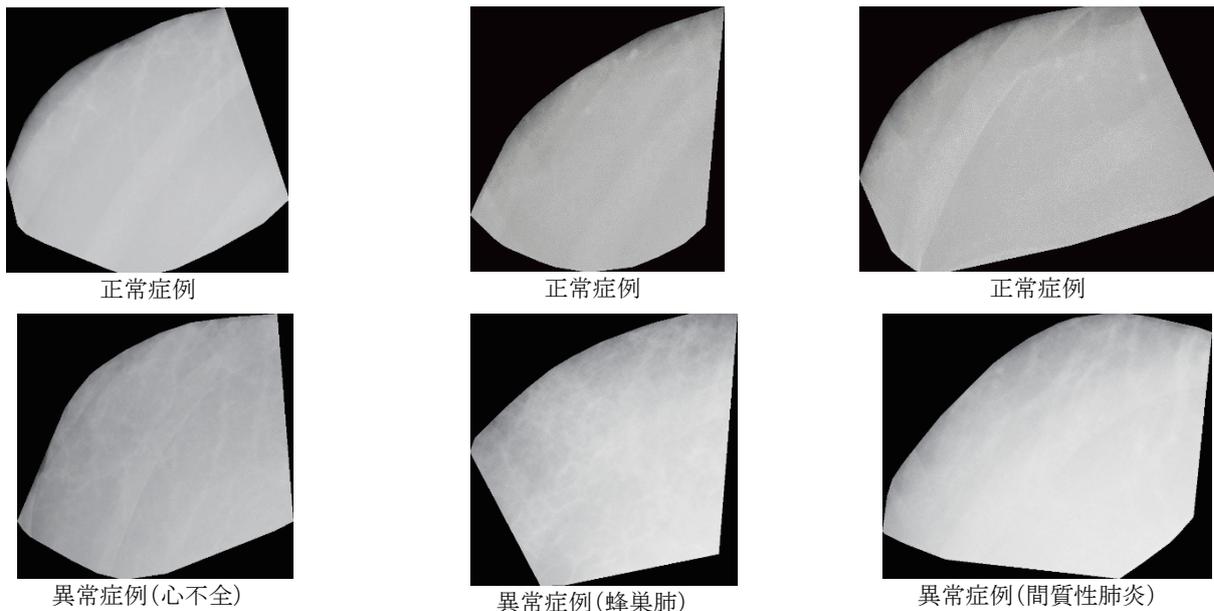


図4 実験に用いた右肺底領域画像例

4. 検証実験

4.1 実験データ

本稿では、福井大学病院の正常胸部 X 線画像 697 症例及び異常胸部 X 線画像 14 例に対し、あらかじめ深層学習を用いた胸部 X 線画像からの解剖学的構造の領域検出手法[近藤19]を用いて切り出した右肺底領域画像(図4)を用いた。本研究は、福井大学医学系研究倫理審査委員会の承認を得て実施している。なお、症例使用に関し、福井大学ホームページにて情報公開を行い、オプトアウトにおいて患者の拒否の機会を設けている。表1に本稿で用いた異常14症例の疾患名を示す。これらは予め医師により診断されたものである。

本稿では、提案する異常検出手法の有効性を検証するための実験として、5-fold 交差検定を行った。正常 697 症例のうち、8割(約 557 症例)を正常モデルの算出、残りの 2割(約 140 症例)と異常 14 症例をテストに用いる実験を、正常症例を入れ替えながら 5 試行を行い、各試行における精度を評価した。精度評価は、ROC(Receiver Operating Characteristic)曲線およびその AUC(area under the curve)値を算出し、Youden 指数(感度+特異度-1)[Youden 50]が最大となる閾値をカットオフ値とした時の感度、特異度、正確度、TP, FN, TN, FP を算出した。

表1 異常症例所見

異常症例所見	症例数
間質性肺炎	8
蜂巢肺	2
心不全	2
右肺底部肺がん	2

4.2 検証実験結果

図5に本検証実験により得られた各試行と平均の ROC 曲線と AUC 値を示す。AUC 値は平均で 0.93 と提案手法の有効性を示唆するのに十分な精度を確認できた。各試行の ROC 曲線を比較すると、過検出を押さえた場合(False Positive Rate < 0.2)、検出結果にばらつきはあるものの、False Positive Rate ≥ 0.2 での検出精度は安定していることがわかる。

表2に各試行の Youden 指数が最大となった閾値での感度、特異度、正確度、TP, FN, TN, FP を示す。Youden 指数最大(=ROC 曲線左上のポイント)での感度はいずれも 93%(異常 14 症例中 1 症例の未検出)であった。各試行における未検出症例を確認した結果、特定の 1 症例(表1の異常症例3:蜂巢肺)が未検出であった。一方、特異度は平均 90%と高い精度の結果ではあったが、76%~99%(正常約 140 症例中、1~33 症例の過検出)とばらつきが生じており、各試行の正常部分空間算出に用いた正常画像のデータセット内のバリエーションによる影響が出ていることが考えられる。

5. 結論

本稿では、胸部 X 線画像からの解剖学的構造に基づいた病変検出を目指し、解剖学的構造の 1 つである右肺底領域画像から抽出した HLAC 特徴量と正常部分空間法を用いた異常検出手法を提案した。検証実験では、正常の右肺底領域画像の特徴量のみを学習し、正常部分空間法を算出した結果、異常 14 症例に対し感度 93%を確認した。本稿で示した結果は、従来の胸部 X 線画像の CAD では難しかった、胸部 X 線画像には直接的に表れなかった病変でも、解剖学的構造の正常状態を学習し、医学的根拠に基づいた解剖学的構造に現れる変化を検出することで、病変検出を実現する可能性があることを示唆している。

機械学習や深層学習では、なぜその結果に到達したのかを論理的に説明できず、ブラックボックスのように計算結果として解が出力されるため、その結果を医師や患者が納得して受け入

表2 検証実験結果

	最大 Youden 指数	感度 Recall	特異度 Specificity	正確度 Accuracy	TP	FN	TN	FP
試行 A	0.879	0.929	0.950	0.948	13	1	133	7
試行 B	0.821	0.929	0.893	0.896	13	1	125	15
試行 C	0.806	0.929	0.878	0.882	13	1	122	17
試行 D	0.921	0.929	0.993	0.987	13	1	138	1
試行 E	0.691	0.929	0.763	0.778	13	1	106	33
平均	0.824	0.929	0.895	0.898				

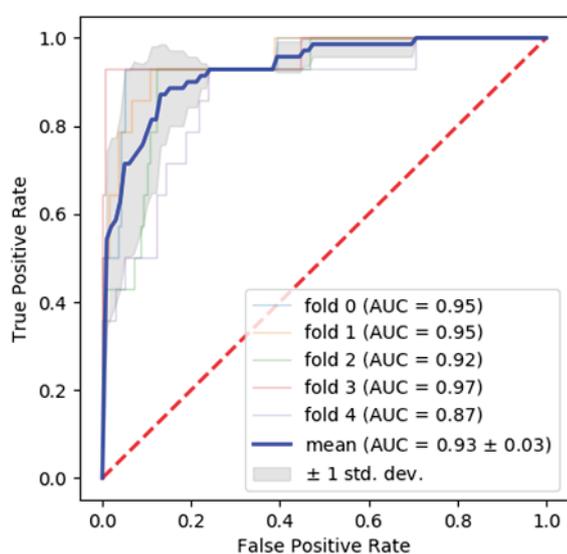


図5 ROC 曲線

れることが難しい場合がある[大江 17]。本手法は、解剖学的構造が病変による影響によって起こる変化を検出し、病変の有無を判断することが可能である。解剖学的構造の変化には、必ず医学的な根拠があり、それらに対応付けすることにより、個々の検出結果を医学的根拠に基づいて説明することが可能となる。本手法が、解剖学的構造といった医学的な知識を融合した新しいCADとして、胸部 X 線検査における診断支援のブレイクスルーとなることを期待する。

参考文献

- [Demir 05] C. Demir and B. Yener, "Automated cancer diagnosis based on histopathological images: a systematic survey", Technical Report, TR-05-09, Rensselaer Polytechnic Institute, Mar., 2005.
- [Nanri 05] T. Nanri and N. Otsu, "Unsupervised Abnormality Detection in Video Surveillance", Proc. IAPR Conf. on Machine Vision Application, pp. 574-577, 2005.
- [Nosato 11] H. Nosato, T. Kurihara et al., "An Extended Method of Higher-order Local Autocorrelation Feature Extraction for Classification of Histopathological Images", IPSJ Trans. CVA, Vol. 3, pp.211-221, 2011.

- [Nosato 17] H. Nosato, H. Sakanashi et al., "Image Retrieval Method for Multi-Scale Objects from Optical Colonoscopy Images", International Journal of Biomedical Imaging, 2017(7089213), pp.1-13, 2017
- [Otsu 88] N. Otsu and T. Kurita, "A new scheme for practical flexible and intelligent vision systems", Proc. IAPR Workshop on Computer Vision, pp. 431-435, 1988.
- [Rajpurkar 17] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, R. Ball, C. Langlotz, K. Shpanskaya, M. Lungren, A. Ng, "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning", arXiv:1711.05225v3, 2017.
- [Youden 50] W. J. Youden, "Index for rating diagnostic tests", Cancer, 3(1), pp 32-35, 1950.
- [Wang 17] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, R. Summers, "ChestX-ray8: Hospital-scale ChestX-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases", CVPR2017, 2017.
- [大江 17] 大江和彦, "これからの医療における AI の活用と課題", 医薬品情報学, 19(3), pp.N1-N3, 2017.
- [近藤 18] 近藤堅司, 小澤順, 清野正樹, 藤本真一, 田中雅人, 安達登志樹, 伊藤春海, 木村浩彦, "U-Net を用いた胸部 X 線画像からの解剖学的構造の領域抽出", 第 32 回人工知能学会全国大会 2018 予稿集, 2j4-04, 2018.
- [近藤 19] 近藤堅司, 小澤順, 清野正樹, 藤本真一, 田中雅人, 安達登志樹, 伊藤春海, 木村浩彦, "深層学習を用いた胸部 X 線画像からの解剖学的構造の領域抽出", 生体医工学, 2019 (掲載予定).
- [田中 12] 田中利恵, "6.4.1.1 胸部単純 X 線写真", 第 6 章 コンピュータ支援検出/診断, 「実践医用画像解析ハンドブック」藤田広志, 石田隆行, 桂川茂彦 監修, pp.595-605, オーム社, 2012.
- [藤田 07] 藤田広志, "医療画像のコンピュータ支援診断", システム/制御/情報, 51(10), pp.433-438, 2007.

長期短期記憶と心拍変動に基づく 睡眠時無呼吸症候群のスクリーニング

Sleep Apnea Detection by Combining Long Short-Term Memory and Heart Rate Variability

岩崎 絢子^{*1} 仲山 千佳夫^{*2} 藤原 幸一^{*2*3} 角 幸頼^{*4} 松尾 雅博^{*4} 加納 学^{*2}
Ayako Iwasaki Chikao Nakayama Koichi Fujiwara Yukiyooshi Sumi Masahiro Matsuo Manabu Kano

角谷 寛^{*5}
Hiroshi Kadotani

^{*1}京都大学医学部
Faculty of Medicine, Kyoto University

^{*2}京都大学情報学研究科
Graduate School of Informatics, Kyoto University

^{*3}名古屋大学工学研究科
Graduate School of Engineering, Nagoya University

^{*4}滋賀医科大学精神科
Department of Psychiatry, Shiga University of Medical Science

^{*5}滋賀医科大学睡眠行動医学講座
Department of Sleep and Behavioral Sciences, Shiga University of Medical Science

Sleep apnea syndrome (SAS) is a prevalent disorder which causes daytime fatigue with increased risk of cardiovascular diseases. A large number of patients are undiagnosed and untreated partly because of the difficulty in performing its gold standard test, polysomnography (PSG). In this research, we propose a simple screening method utilizing heart rate variability (HRV) and long short-term memory (LSTM) which is a kind of the neural network techniques. The result of applying this algorithm to clinical data demonstrates that it can discriminate between patients and healthy people with high sensitivity and specificity.

1. はじめに

睡眠時無呼吸症候群 (Sleep Apnea Syndrome; SAS) は睡眠中に呼吸停止または呼吸量の低下が頻回に出現する病態であり、無呼吸低呼吸指数 (Apnea Hypopnea Index; AHI) が 5-10 以上の睡眠呼吸障害に、昼間の眠気などの自覚症状を伴う状態を指す [1]. AHI は、睡眠 1 時間あたりの無呼吸および低呼吸の回数であり、SAS の重症度の診断に用いられる。なお、無呼吸は 10 秒以上換気が停止する状態、低呼吸は呼吸気流が 50% 以上低下した状態が 10 秒以上継続する状態である。

無呼吸に伴い睡眠が障害されるため熟睡感が得られず、日中の傾眠や集中力の低下を生じることがあり、交通事故の原因となる。報告によって異なるものの、SAS 患者が自動車事故を起こす可能性は健常者の 2-10 倍といわれており [2], SAS の診断および治療の社会的な影響は大きいと考えられる。さらに、SAS はほとんど自覚症状がないケースでさえ高血圧症・冠動脈疾患・脳血管障害のリスクを高めるため、SAS の治療は予後にも重要である。[3,4].

SAS のほとんどは上気道の狭窄・閉塞によるものであるため、睡眠中にマスクを装着し持続的に陽圧をかけることによって気道の閉塞を防止する持続陽圧呼吸法 (Continuous Positive Airway Pressure; CPAP) が代表的な治療法となっている。SAS は CPAP 治療により症状や生活習慣病の合併リスクが改善される [5-7] 疾患であるため、SAS の早期発見および治療は重要である。疫学調査によると、日本での SAS 有病率は男性 3.3%、女性 0.5% であり、患者数は 200 万人近いとされているが、自身が SAS であることを自覚している人は少なく、受診しているのは 12 万人に過ぎない [8,9].

SAS の確定診断には終夜睡眠ポリグラフ検査 (polysomnography; PSG) が用いられている。PSG は睡眠中の被験者の心

連絡先: 藤原幸一, 名古屋大学, fujiwara.koichi@material.nagoya-u.ac.jp

電・筋電・呼吸気流・SpO₂などを計測し、SASの有無や重症度を調べることができる検査である。しかし、PSGのデータ取得と解析に専用機器と熟練検査技師を必要とするため、限られた施設でしか実施できないのが現状である。そこで SAS の診断には、PSG の検査項目の一部を省いた SAS 簡易モニタが利用されることがある。SAS 簡易モニタは在宅で使用できるものの、適切な使用には医師による監督が必要であり、装置の装着も必ずしも容易ではない [10]. したがって、在宅で手軽に SAS 罹患をスクリーニングし、その結果に応じて適切に病院の受診を促すことができるシステムが必要である。

ところで、睡眠時に無呼吸もしくは低呼吸になると、血中酸素飽和度の低下などにより自律神経活動に変化が現れることが知られており [11], その変化を検出できれば、SAS スクリーニングを実現できると考えられる。心拍変動 (Heart Rate Variability; HRV) は自律神経活動と関係があることが知られているが、実際に SAS 患者の無呼吸時には HRV が変化するという報告がある [12-15]. HRV データの収集には、心拍データを高精度かつ簡便に測定できるウェアラブル心拍計測デバイス [16] が利用できる。これを用いることにより、睡眠時に採取した心拍データから HRV 解析を行い、SAS 罹患の可能性を在宅で簡便に判定できるようになると考えられる。

そこで、本稿では HRV データと、ニューラルネットワークの一種である長期短期記憶から SAS スクリーニングを行う手法について検討する。

2. 心拍変動解析

2.1 RR 間隔

HRV 解析では、図 1 のように心電図の最も高いピーク (R 波) の間隔 (R-R interval; RRI) を取得するのが一般的である [17]. 健康人から得られた RRI のプロットを図 2 に示す。このように、生理的な条件下でも RRI は呼吸などによる影響を受け

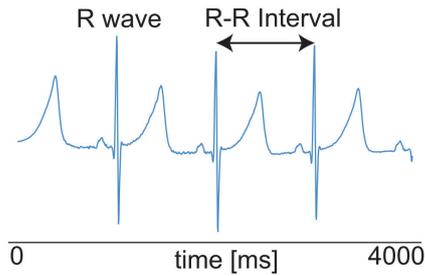


図 1: 心電図波形の例

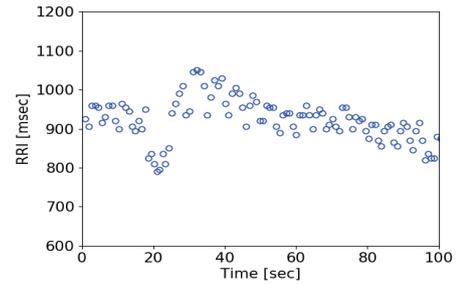


図 2: RRI データの一例

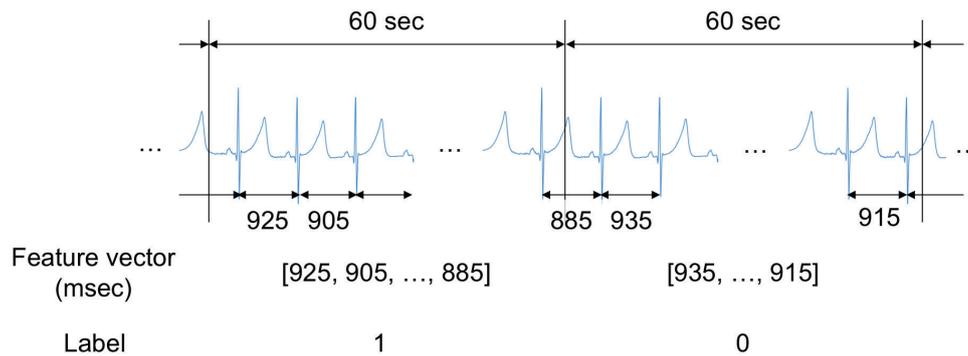


図 3: 特徴量抽出スキーム

1 拍ごとに変動している。

こうして得られた RRI を 60 秒ごとなど一定の長さの区間に分割し、区間内に含まれる RRI データから求めた平均や分散、周波数領域特徴量から得られた値などを特徴量として SAS のスクリーニングを試みている先行研究は多く存在するが [17-19], 本研究では RRI データのみを用いて SAS 患者と健常者の分類を行った。同様の試みは既に存在するものの [20] 本稿では臨床現場のニーズを踏まえ、各区間における正常呼吸か無呼吸の判別だけでなく、個々の被験者が SAS に罹患しているか否かの判別を行った。

2.2 特徴量抽出

PSG データから得られた被験者の第 II 誘導心電図から RRI [msec] を抽出した。これを図 3 のように 60 秒ごとに分割し、区間で発生した RRI を格納して特徴量ベクトルとした。なお、RRI の測定は不等間隔であるため、特徴量ベクトルの長さは可変である。さらに、技師による判読結果に基づいて、各区間が無呼吸状態を示す「1」か、正常呼吸を示す「0」かでラベリングした。

また、RRI データの個人差を除外するため、各患者ごとの RRI データを用いて平均 0、標準偏差 1 に正規化し、これらのベクトルを組み合わせる訓練用データを作成した。

2.3 モデル構築

時系列データに対して用いられる再帰ニューラルネットワーク (Recurrent Neural Network; RNN) の一種である LSTM (Long Short-Term Memory) は RNN で生じる勾配消失・爆発を解決したという点からよく用いられる。LSTM の構造を図 4 に示した。今回用いる LSTM のネットワーク構成 [21] は、通常の RNN のように前のタイムポイントでの出力を入力として受け取るだけでなく、長期的な状態を保持する記憶セルを

持ち、長期的な記憶から捨てるべきものを選択する「忘却ゲート (f)」, 入力から重要な情報を選択する「入力ゲート (i)」, 長期的な記憶から出力すべきものを選択する「出力ゲート (o)」を学習する [22]。本項では LSTM を用いて、生 RRI を格納して得られた特徴量ベクトルを入力とし、各区間が無呼吸か正常呼吸かの判別結果を出力するモデルを作成した。

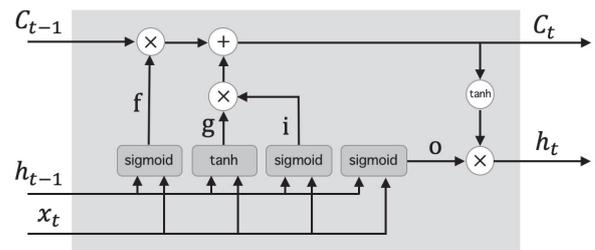


図 4: LSTM の構造 [22]

本研究では入力・LSTM 1 層 (32 units)・出力の 3 層のネットワークを用いて、学習率 0.01 の Adam optimizer により最適化を行いモデルを構築した。

2.4 SAS 患者と健常者の判定

被験者が SAS であるかを判定するために、被験者ごとに apnea/sleep (AS) ratio を算出した。

$$A = 100 t_a / t \quad [\%] \quad (1)$$

ただし、 t_a はモデルによって推定された無呼吸の期間の長さ [min], t は睡眠時間 [min] である。

A がある閾値 \bar{A} 以上の被験者を SAS, そうでない被験者を健常者と判定した。

3. 臨床データへの応用

3.1 被験者の特性

滋賀医科大学精神科にて患者 28 名分および健常者 39 名分の睡眠中 PSG データを収集した。なお、本データ収集および解析は、滋賀医科大学附属病院倫理委員会の承認の下、実施された。ECG 電極不良などにより、実際に解析可能なデータが取得できたのは患者 24 名分および健常者 35 名分であった。解析対象の 59 名の被験者の属性を表 1 にまとめた。

表 1: 被験者の特性

Age	Male			Female		
	AHI 0-14	15-29	30-	0-14	15-29	30-
18-30	7	0	0	15	0	1
31-50	7	2	5	6	0	0
51-80	0	7	7	0	1	1

3.2 結果

図 5 に (a) 訓練データ と (b) 検証データ における被験者ごとの AS ratio を示した。

SAS の診断基準である AHI 15.0 に最も近い (a) の Patient 5 (AHI: 15.3) を正常と無呼吸の境界とみなし、当該患者の AS ratio (0.168) を閾値 \bar{A} と設定したところ、感度・特異度ともに 100% で患者と健常者を分類することができた。また、検証用データにおいて、患者群の平均 AS ratio は 0.399, 健常者の平均 AS ratio は 0.058 であり、有意差が認められた ($p < 0.01$)。

4. 考察

4.1 先行研究との比較

先行研究 [17] では、RRI から抽出した HRV 指標と、機械学習手法の一つであるサポートベクターマシン (SVM) の組み合わせを用いて感度 100%, 特異度 86% で患者を判別している。一方、RRI と LSTM の組み合わせを用いた提案法はこの先行研究を上回る精度を示した。特徴量として RRI を用いることと、機械学習アルゴリズムとして LSTM を用いることとが精度向上に寄与しているのかを確認する追加実験として、先行研究で用いられたものと同じ HRV 指標と LSTM を組み合わせる精度を確認した。その結果、感度 96%, 特異度 82% となり、精度は両手法に比して低いものとなった。したがって、精度向上には特徴量として RRI を用いることが重要である可能性があり、陽に時系列データであることを考慮していない SVM では表現できていない RRI 時系列データの特徴を LSTM では表現できているなどが考えられる。

4.2 既存の簡易モニタとの比較

表 2 に従来の代表的な SAS 簡易モニタおよび提案法の感度と特異度を示す [23]。この表より、提案法は従来の SAS 簡易モニタより高い精度を示すことが分かる。さらに、利便性の観点においても提案法には SAS 簡易モニタへの優位性が存在する。事前の受診および医師による監督が必要である SAS 簡易モニタ [10] に対して、提案法は心拍データのみに基づいた手法であるためウェアラブル心拍センサを用いることで誰でも容易に測定でき、取得した心拍データの解析も自動で行える。つ

まり、提案法は従来の SAS 簡易モニタよりも、在宅での SAS スクリーニングに適していると考えられる。

表 2: 既存の簡易モニタおよび提案法の精度

Product	Sensitivity [%]	Specificity [%]
Healthdyne 202-11 Oximeter	97	80
Nellcor N-200	82	76
SageTech SNORESAT	100	63
ResMed AutoSet 3.03	97	32
Criticare 504 5 Oximeter	67	92
Konica Minolta Pulsox 7	94	62
提案法	100	100

5. まとめと今後の展望

本研究では、生 RRI データとニューラルネットワークの 1 つである LSTM を用いた SAS スクリーニング手法を提案した。提案法では、SAS 患者および健常者の睡眠時心拍データから心拍変動と長期短期記憶を用いて無呼吸・正常呼吸識別モデルを構築し、被験者の睡眠時心拍データから SAS 罹患を判定する。提案法を臨床データに適用したところ、SAS 患者を感度 100%, 健常者を特異度 100% で検出できた。これは従来の SAS 簡易モニタを上回る性能である。

今後はオープンデータを含む PSG データセットに対して本手法を適用するほか、大規模な PSG データ収集も行う。また、本研究ではモデルの構築と検証は PC 上で行ったが、将来的には提案法をスマートフォンのアプリとして実装し、ウェアラブル心拍センサと組み合わせて在宅で使用可能な SAS スクリーニングシステムを開発する。最終的に、被験者にウェアラブル心拍センサを装着させて検知精度や使用感を検証し、早期の実用化を目指す。

謝辞

本研究の一部は、科研費基盤 A #17H00872, JST さきがけ #JPMJPR1859, 科学技術振興財団, 住友から助成を受けて実施された。

参考文献

- [1] 榊原: 睡眠時無呼吸症候群診療ハンドブック, 医学書院 (2010)
- [2] C F P George: Driving and automobile crashes in patients with obstructive sleep apnoea/hypopnoea syndrome *Thorax*, 804/807 (2004)
- [3] Peppard, Paul E., et al.: Prospective Study of the Association between Sleep-Disordered Breathing and Hypertension, *NEJM*, **Vol. 342**, No. 19, pp. 1378/1384 (2000)
- [4] Reichmuth, Kevin J., et al.: Association of sleep apnea and type II diabetes: a population-based study; *Am J Respir Crit Care Med*, **Vol. 172**, No. 12, pp. 1590/1595 (2005)
- [5] Engleman, Heather M., et al.: Randomized placebo-controlled crossover trial of continuous positive airway pressure for mild sleep apnea/hypopnea syndrome; *Am J Respir Crit Care Med*, **Vol. 159**, No. 2, pp. 461/467 (1999)

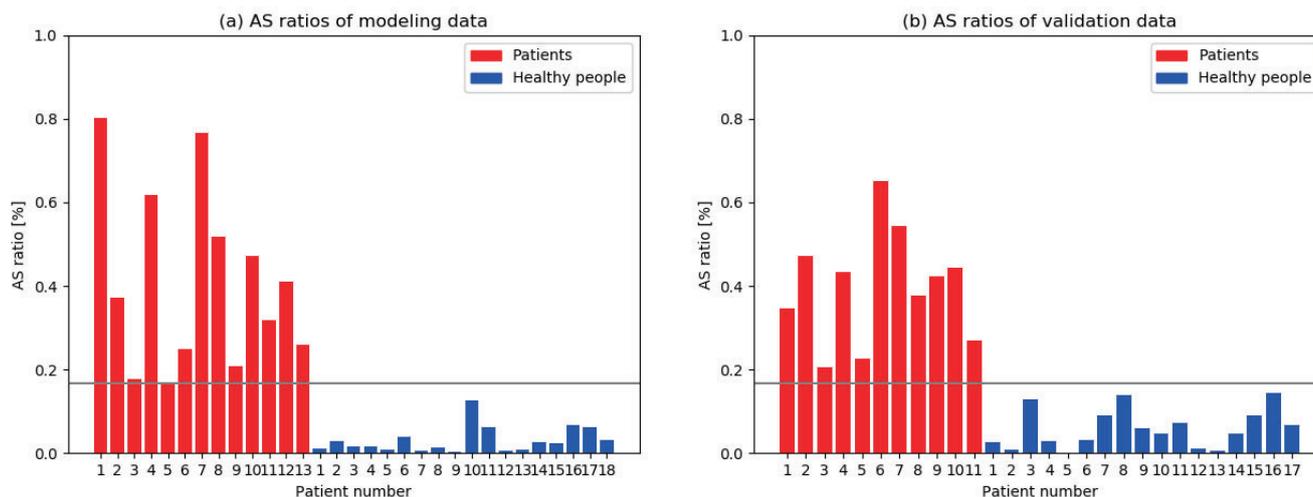


図 5: AS ratio: 訓練データ (左), 検証データ (右)

- [6] Douglas, Neil J.: Systematic review of the efficacy of nasal CPAP; Thorax, **Vol. 53**, No. 5, pp. 414/415 (1998)
- [7] Engleman, Heather M., et al.: Effect of continuous positive airway pressure treatment on daytime function in sleep apnoea/hypopnoea syndrome; The Lancet, **Vol. 343**, No. 8897, pp. 572/575 (1994)
- [8] 粥川裕平: 閉塞性睡眠時無呼吸症候群の有病率と性差, 年齢差; 治療学, **Vol. 30**, No. 2, pp. 179/182 (1996)
- [9] 厚生労働省: 平成 23 年度患者調査総患者数 傷病基本分類別; G473 (2011)
- [10] Chesson, Andrew L., et al.: Practice parameters for the use of portable monitoring devices in the investigation of suspected obstructive sleep apnea in adults; Sleep, **Vol. 26**, No. 7, pp. 907/913 (2003)
- [11] Somers, Virend K., et al.: Sympathetic neural mechanisms in obstructive sleep apnea; J Clin Invest, **Vol. 96**, No. 4, pp. 1897 (1995)
- [12] Marin, Jose M., et al.: Long-term cardiovascular outcomes in men with obstructive sleep apnoea-hypopnoea with or without treatment with continuous positive airway pressure: an observational study; The Lancet **Vol. 365**, No. 9464, pp. 1046/1053 (2005)
- [13] Dingli, K., et al.: Spectral oscillations of RR intervals in sleep apnoea/hypopnoea syndrome patients; European Respiratory Journal, **Vol. 22**, No. 6, pp. 943/950 (2003)
- [14] Keyl C., et al.: Heart rate variability in patients with obstructive sleep apnea; Clin sci, **Vol. 91**, pp. 56/57 (1996)
- [15] Shiomi, T., et al.: Augmented very low frequency component of heart rate variability during obstructive sleep apnea; Sleep, **Vol. 19**, No. 5, pp. 370/377 (1996)
- [16] Yamakawa, T., et al.: Development of a wearable HRV telemetry system to be operated by non-experts in daily life; APSIPA, 2013 Asia-Pacific. IEEE, (2013).
- [17] C. Nakayama, K. Fujiwara, M. Matsuo, M. Kano, and H. Kadotani: Development of sleep apnea syndrome screening algorithm by using heart rate variability analysis and support vector machine, *IEEE EMBC*, 8165/8168 (2015)
- [18] A. Kaguara, K. M. Nam, and S. Reddy: A deep neural network classifier for diagnosing sleep apnea from ECG data on smartphones and small embedded systems, *BA Computer Science* (2014)
- [19] D. Novak, K. Mucha and T. Al-Ani: Long short-term memory for apnea detection based on heart rate variability, *IEEE Engineering in Medicine and Biology Society* (2008)
- [20] R. K. Pathinarupothi, Vinaykumar R. , E. Rangan, Gopalakrishnan E. and Soman K. P. : Instantaneous heart rate as a robust feature for sleep apnea severity detection using deep learning, *IEEE BHI*, 293/296 (2017)
- [21] Felix A. Gers, Schmidhuber J. and Cummins S. : Learning to Forget: Continual Prediction with LSTM, *Technical Report* (1999)
- [22] 斎藤: ゼロから作るディープラーニング2 ー自然言語処理編, オライリー・ジャパン (2018)
- [23] Flemons, W., et al.: Home diagnosis of sleep apnea: a systematic review of the literature: an evidence review cosponsored by the American Academy of Sleep Medicine, the American College of Chest Physicians, and the American Thoracic Society: CHEST Journal, **Vol. 124**, No. 4, pp. 1543/1579 (2003)

重み付き PLSA と DPC データを用いた患者と診療行為等の同時クラスタリングにおける重み値によるクラスタリングの特徴の違い

Clustering Difference of the features of the by Weight Values in the Weighted PLSA using DPC data

山下 和也^{*1} 村田 知佐恵^{*1} 阪本 雄一郎^{*2} 櫻井 瑛一^{*1*2} 本村 陽一^{*1*2}
 Kazuya Yamashita Chisae Murata Yuichiro Sakamoto Eiichi Sakurai Yoichi Motomura

^{*1} 産業技術総合研究所人工知能研究センター
 Artificial Intelligence Research Center, AIST

^{*2} 佐賀大学
 Saga University

The accumulation of DPC data has progressed, and the importance of these medical big data is recognized. At present, there are few reports such as application for selection and comparison of a new treatment strategy using DPC. We used DPC data and PLSA to clarify simultaneous clustering of patients requiring intensive care and clinical practice and to extract clusters time transition patterns of patients and to evaluate feasibility of doctor's treatment strategy decision support algorithm we have verified. Furthermore, by using weighted PLSA, clustering can be performed which clearly shows the difference of attention variables by giving weight to 'attention' medical treatment, objective variables such as mortality rate, number of hospital days and medical expenses It is confirmed that it is. In this research, we treat all DPC items including variables that we have not used so far as variables, and investigate the differences in clustering features by changing the weight of each variable. As a result, it was shown that it is possible to generate clusters according to the purpose by adjusting the weight of each variable as a parameter according to the variable to be noticed.

1. はじめに

現在、著者らの研究チームは、医療ビッグデータの利活用の一環として、日常的に収集蓄積が進む Diagnosis Procedure Combination (診断群包括分類、以下 DPC) データに着目し、治療効果の検証のみでなく、治療戦略や医師の意思決定支援への応用の可能性を検討している。

これまで、診療科を問わず発症の可能性や対応の必要性がある敗血症に焦点を当て、DPC データに基づき、Probabilistic Latent Semantic Analysis (確率的潜在意味解析、以下 PLSA) 手法[Hofmann 1999]を用いた患者と診療行為の同時クラスタリング、さらにそこで得られたクラスタを状態空間とみなして同一患者が入院中にたどるクラスタ間の時間遷移パターンを解析し、治療戦略決定支援アルゴリズムの実現可能性を検証してきた[山下 2017, 山下 2018a, 山下 2018b]。その結果、DPC データを用いた診療行為のクラスタリングが可能であることのほか、患者が入院中の治療経過に伴いクラスタを遷移する確率からその後の状態遷移パターンに違いがあり、ある状態で特定の治療を行った場合の在院日数や死亡率、その後どのような経過をたどる可能性があるかなどについて、予測可能なことが明らかになった。さらに、注目している変数に重みを与える「重み付き PLSA (weighted PLSA)」を初めて適用したクラスタリングも実施し、血液浄化の種類によりクラスタ分類されることを明らかにした[山下 2019]。ただし DPC データのうち「診療行為」に特化してクラスタリングしたものであり、年齢や金額など DPC データのすべての項目を同時に変数とした解析は行っていなかった。

そこで本研究では、DPC データ全体から死亡率と関連する要因を探索的に見つけることを目指してその為に、重み付き PLSA の重み値を 0 及び正の数とすることで、これまでの解析と DPC 全体を用いた新たな解析を重み値の違いとして統一的に議論し、重み値を変化させることによるクラスタリングの特徴の違いとして整理し、重み付き PLSA の医用応用における有用性を調べた。

2. 重み付き PLSA

研究施設において平成 24 年度～平成 26 年度の期間に入院していた敗血症患者 458 名の DPC データを用いて、PLSA によるクラスタリングを実施した。

PLSA は、2 つの変数 x, y の背後に共通の特性となる潜在変数 z があると仮定し、それらの関連性について、期待尤度最大化法によって x および y が潜在変数 z に所属する確率値を推定し、所属確率が最大となる z にクラスタリングする手法である。

本研究では、変数 x を患者 ID と診療行為実施日 (入院初日から 1 日単位、在院日数と同じ) を組み合わせ「患者 ID_実施日」とし、その他の DPC データ項目を変数 y とした (表 1)。

PLSA 解析において、共起行列の特定の行の頻度に重みを付ける「重み付き PLSA (weighted PLSA)」の重みを y の変数別に各行に対して、0, 1, 20 等に変えて、変数 x 側の患者のクラスタ遷移パターンや y 側のクラスタリングの特徴が重み値を変えることによりどう変わるかを調べた。

表 1 変数 y に使用した DPC データの項目

年齢	出来高金額合計(円)
性別	薬:出来高(円)
在院日数	材料:出来高(円)
ICU日数	10診察料合計(円)
診療行為名称	20投薬料合計(円)
MDC6名称	30注射料合計(円)
診療科	40処置合計(円)
医師コード	50手術合計(円)
死亡の有無	60検査合計(円)
	70画像合計(円)
	90入院料合計(円)
	97食事合計(円)

本研究は、研究施設の倫理審査委員会で承認を取得した。また、PLSAの実行は、産業技術総合研究所の知財ソフトウェア「PLASMA」を使用した。

際にはその診療行為に高い重みを与える(山下,2019)他、見たい現状に応じて各変数の重みをパラメータとして調整することで目的に応じたクラスタを生成出来ることが可能であることが示された。



図1 診療行為名称のみに重み1他は0の生存患者のクラスタ遷移



図2 DPC各項目に重み1、死亡の有無のみ20倍の重みの生存患者のクラスタ遷移

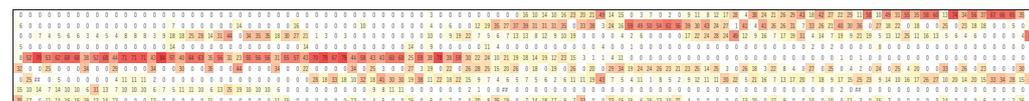


図3 診療行為名称のみ重み1他は0の死亡患者のクラスタ遷移

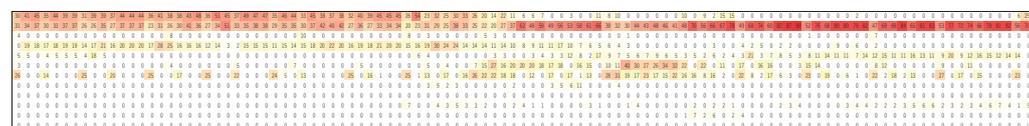


図4 DPC各項目に重み1、死亡の有無のみ20倍の重みの死亡患者のクラスタ遷移

3. 重み付き PLSA の重み値の違いによるクラスタリングの特徴

PLSA の y の変数として診療行為名称のみに重み1を与え、他の変数は0とした場合の生存したある患者のクラスタ遷移を図1に示す。図の横方向は時間軸(日)であり、左端が入院初日で右端が退院日である。縦方向は AIC 基準で最適とされた9つのクラスタをそれぞれのクラスタに属する患者の死亡率の低い順に下から並べたものである。各マス目の色(数字)は患者のその日の各クラスタへの所属確率(%)を示していて赤が濃い程確率が高い。入院初期は様々なクラスタに所属しているが、後期は下から3つ目のクラスタに集中している。このクラスタは投薬や診察、検査項目が中心のクラスタである。

次に y の変数として診療行為名称以外にも表1の各項目に重み1を与え、死亡の有無のみ重み20を与えた場合の12クラスタ(AIC最小)に対して上記と同じ生存患者の遷移を図2に示す。入院初期は下から2番目のクラスタの所属確率が高くまたこのクラスタへの所属は退院まで一貫して続いている。後半には下から3番目のクラスタへの所属確率も高まっている。この3番目のクラスタは投薬、診察、検査項目が中心のクラスタで、診療行為名称のみに重み1の場合の入院後期に所属した項目と共通の診療行為名称が多い。

死亡した患者の事例についても上記と同様に診療行為名称のみに重み1とDPC各項目も入れた場合の結果を図3、図4にそれぞれ示す。診療行為名称に重み1倍の方では日々ある程度複数のクラスタへ所属している一方、各DPC項目を入れた方では上から2番目への所属確率が高くそのクラスタへの所属は入院期間にわたって一貫している。

4. 考察

各DPC項目を入れたPLSAでは入院全期にわたって所属しているクラスタが見られ、そのようなクラスタは患者の属性が反映されていると思われる。日々の診療行為の違いにあまり左右されない総合的な患者の状態をみられるクラスタが生成されていると捉える事が出来る。特定の診療行為の効果に注目したい

謝辞

本研究にご協力くださった関係者の皆様に心より感謝申し上げます。本研究は、NEDO委託事業「人間と相互理解できる次世代人工知能技術の研究開発」の支援を受けて行いました。

参考文献

- [Hofmann 1999] Hofmann T: Probabilistic Latent Semantic Analysis, Proceedings of the Fifteenth conference on Uncertainty in artificial intelligence, Morgan Kaufmann Publishers Inc., 1999.
- [本村 2018]本村陽一;ビッグデータを活用する確率モデリング技術～社会実装の取り組みと課題～,統計数理 第66巻 第2号,(2018)
- [山下 2017] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 時間変化も考慮したpLSA手法による敗血症治療戦略への応用, 第27回人工知能学会 社会におけるAI研究会, 2017.
- [山下 2018a] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 医師の知見と経験を蓄積・伝承する判断支援システム実現に向けたPLSAによる診療クラスタの時間遷移パターンの解析, 人工知能学会全国大会, 2018.
- [山下 2018b] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 診療クラスタ遷移と医学的判断の紐づけによる敗血症治療ナビゲーションシステム実現可能性の検証, 第5回「JAMI 医用知能情報学研究会-JSAI 医用人工知能研究会」合同研究会, 2015.
- [山下 2019] 山下和也, 村田知佐恵, 阪本雄一郎, 櫻井瑛一, 本村陽一: 敗血症患者への血液浄化を含む治療戦略決定支援に向けた重み付きPLSAによる診療行為と患者のDPCデータに基づく同時クラスタリング解析, 日本急性血液浄化学会雑誌, 2019 in print.
- [本村 2019]本村陽一,山下和也,阪本雄一郎:DPC診療群分類包括評価データに対する確率的潜在意味構造モデリング,BIO Clinica 34(3),2019

重み付き PLSA を用いた敗血症患者の DPC データ分析結果における各クラスタの特徴およびクラスタ遷移パターンの検討

Cluster Features and Transition Patterns in the Analysis Results of Sepsis-related DPC Data with Weighted PLSA Methods

村田 知佐恵*¹
Chisae Murata

山下 和也*¹
Kazuya Yamashita

阪本 雄一郎*²
Yuichiro Sakamoto

櫻井 瑛一*^{1*2}
Eiichi Sakurai

本村 陽一*^{1*2}
Yoichi Motomura

*¹ 産業技術総合研究所人工知能研究センター
Artificial Intelligence Research Center, AIST

*² 佐賀大学
Saga University

This study aimed to investigate factors related to mortality in patients with sepsis by analyzing all items of their diagnosis procedure combination (DPC) data with weighted probabilistic latent semantic analysis (PLSA) methods and to clarify features and transition patterns of the clusters extracted from the analysis. The results showed that 12 clusters were optimal and among those the one with high severity and the one receiving palliative care tended to have a high mortality rate. In addition, focusing on the main cluster for each patient, five cluster transition patterns were revealed.

1. はじめに

現在、著者らの研究チームは、医療ビッグデータの利活用の一環として、日常的に収集蓄積が進む Diagnosis Procedure Combination (診断群包括分類、以下 DPC) データに着目し、治療効果の検証のみでなく、治療戦略や医師の意思決定支援への応用の可能性を検討している。

これまで、診療科を問わず発症の可能性や対応の必要性がある敗血症に焦点を当て、DPC データに基づき、Probabilistic Latent Semantic Analysis (確率的潜在意味解析、以下 PLSA) 手法 [Hofmann 1999] を用いた患者と診療行為の同時クラスタリング、さらにそこで得られたクラスタを状態空間とみなして同一患者が入院中にたどるクラスタ間の時間遷移パターンを解析し、治療戦略決定支援アルゴリズムの実現可能性を検証してきた [山下 2017, 山下 2018a, 山下 2018b]。その結果、DPC データを用いた診療行為のクラスタリングが可能であることのほか、患者が入院中の治療経過に伴いクラスタを遷移する確率から、状態遷移パターンに違いがあり、ある状態で特定の治療を行った場合の在院日数や死亡率、その後どのような経過をたどる可能性があるかなどについて、予測可能なことが明らかになった。さらに、注目している変数に重みを与える「重み付き PLSA (weighted PLSA)」を初めて適用したクラスタリングも実施し、血液浄化の種類によりクラスタ分類されることを明らかにした [山下 2019]。ただし、これらは DPC データのうち「診療行為」に特化してクラスタリングしたものであり、年齢や金額など DPC データのすべての項目を同時に変数とした解析は行っていなかった。

そこで本研究では、DPC データ全体から死亡率と関連する要因を探索的に見つけることを目的とした解析を行い、抽出されたクラスタの特徴やクラスタ遷移パターンについて検討する。

2. 方法

研究施設において平成 24 年度～平成 26 年度の期間に入院していた敗血症患者 458 名の DPC データを用いて、PLSA によるクラスタリングを実施した。

PLSA は、2 つの変数 x, y の背後に共通の特性となる潜在変数 z があると仮定し、それらの関連性について、期待尤度最大化法によって x および y が潜在変数 z に所属する確率値を推定し、所属確率が最大となる z にクラスタリングする手法である。なお、本研究では、PLSA 解析において、共起行列の特定の行の頻度に重みを付ける「重み付き PLSA」を適用した。

分類された各クラスタについては、変数 y 側からクラスタの特徴、および、変数 x 側からクラスタ遷移パターンをそれぞれ分析し、考察において臨床の観点から統合した。

本研究は、研究施設の倫理審査委員会で承認を取得した。また、PLSA による解析は、産業技術総合研究所の知財ソフトウェア「PLASMA」を使用した。

2.1 使用した変数

本研究では、変数 x を患者 ID と診療行為実施日 (入院初日から 1 日単位、在院日数と同じ) を組み合わせ「患者 ID_実施日」とし、その他の DPC データ項目を変数 y とした (表 1)。

さらに、死亡率と関連する要因を探索するため、「死亡の有無」を 20 倍、その他の変数項目はすべて 1 倍で重みを付けた。

表 1 変数 y に使用した DPC データの項目

年齢	出来高金額合計(円)
性別	薬:出来高(円)
在院日数	材料:出来高(円)
ICU日数	10診察料合計(円)
診療行為名称	20投薬料合計(円)
MDC6名称	30注射料合計(円)
診療科	40処置合計(円)
医師コード	50手術合計(円)
死亡の有無	60検査合計(円)
	70画像合計(円)
	90入院料合計(円)
	97食事合計(円)

2.2 クラスタ遷移の加工

変数 x 側からクラスタ遷移を確認するため、各患者の実施日ごとに、所属確率が 15%以上のクラスタに焦点を当て、特に 60%以上を「強」として区別し、それらのクラスタの組み合わせの特徴が、目視でも明瞭なほど大きく変化する日を遷移日とした(図 1)。

実施日	遷移日	クラスタ	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
1	1	C6,C7(強),C9	12%	0%	0%	0%	0%	0%	63%	0%	25%	0%	0%	0%
2			0%	0%	0%	0%	0%	31%	38%	0%	31%	0%	0%	0%
3			4%	0%	0%	0%	0%	26%	47%	0%	23%	0%	0%	0%
4			0%	0%	0%	0%	0%	0%	62%	0%	38%	0%	0%	0%
5			0%	0%	0%	0%	0%	0%	62%	0%	38%	0%	0%	0%
6			0%	0%	2%	0%	0%	20%	38%	0%	41%	0%	0%	0%
7			2%	0%	0%	0%	0%	0%	59%	0%	38%	0%	0%	0%
8			0%	0%	0%	0%	0%	23%	41%	0%	36%	0%	0%	0%
9			0%	0%	0%	0%	0%	0%	55%	0%	45%	0%	0%	0%
10	10	C1,C6,C7,C9	18%	0%	0%	0%	2%	18%	26%	0%	36%	0%	0%	0%
11			26%	0%	0%	0%	0%	0%	38%	0%	36%	0%	0%	0%
12			28%	0%	0%	0%	0%	0%	36%	0%	36%	0%	0%	0%
13			21%	0%	0%	0%	1%	18%	27%	0%	33%	0%	0%	0%
14			38%	0%	0%	0%	0%	0%	27%	0%	35%	0%	0%	0%

図 1 クラスタ遷移加工のプロセス

3. 結果

変数 x 「患者 ID_実施日」の総数は 19658、変数 y のうち「診療行為」の総数は 4406 となった。

重み付き PLSA によるクラスタリングの結果、AIC 最小は 12 となった。12 の各クラスタは、分析結果として出力された順に、C1, C2, C3, ..., C12 と付番した。変数 y 側から分析したクラスタの特徴、および、変数 x 側から分析したクラスタ遷移パターンを以下に示す。

3.1 各クラスタの特徴

重み付き PLSA により得られた 12 のクラスタのうち、C1 および C7 は死亡率が高く、C8, C10、および C11 は死亡率が低かった。また、所属していた変数 y の内容を分析すると、重症度、手術実施や集中治療室(Intensive Care Unit、以下 ICU)への入院の有無、年齢期などの特徴が得られた。ただし、C6 については、目立った特徴は見当たらなかった。詳細を表 2 に示す。

表 2 AIC 最小となった 12 クラスタの特徴

クラスタ名	死亡率	特徴
C1	高	・重症度が高い ・在院日数が長い
C2		・緊急入院が多い ・在院日数が短く、入院費が低い
C3		・手術が多い ・人工心肺/人工血管/人工弁/ステント関係が多い
C4		・リハビリ加算が多い
C5		・緊急入院が多い ・血液浄化や緊急手術が多い
C6		(目立った特徴は見当たらなかった)
C7	高	・緩和ケアを受けている患者が多い
C8	低	・31~45歳、61~75歳が多い ・薬剤や検査費が高い
C9		・褥瘡管理加算が高い
C10	低	・46~60歳が多い ・ICUに入院している患者が多く、入院期間は短い
C11	低	・76歳以上が多い ・ICUに入院している患者が多く、入院費が高い
C12		・小児患者が多い

3.2 クラスタ遷移パターン

患者ごとのクラスタ遷移パターンを確認すると、実施日ごとの所属クラスタにおいて、クラスタの強さの観点から 5 つの遷移パターンが見られた。また、患者の特徴に応じた遷移パターンも見られた。

(1) クラスタの強さに関する 5 つの遷移パターン

各患者の実施日ごとのクラスタリング結果において、所属が 60%以上と示されたクラスタを「強」と設定し、「主クラスタ」と定義すると、以下のような 5 つの遷移パターンが見られた。

- ・最初から最後まで 1 つのクラスタが継続して強い。
(主クラスタが変化しない)
- ・最初から最後まで複数のクラスタが現れ、強いクラスタが見られない。
(主クラスタが存在しない)
- ・最初から最後まで 1 つのクラスタが間欠的に強く現れる。
(主クラスタがときどき現れる)
- ・初期に現れた複数のクラスタのうち、1 つのクラスタが途中から強くなる(表 3)。
(主クラスタが途中から現れる)
- ・初期に強いクラスタがあるが、途中で複数クラスタに分散する(表 4)。
(主クラスタが途中で消える)

なお、初期に強いクラスタが現れ、途中で別のクラスタが強くなるパターンは 3 例のみであった。

表 3 主クラスタが途中から現れる遷移例

ID	遷移日	クラスタ	遷移日	クラスタ	遷移日	クラスタ	遷移日	クラスタ
***50	1	3,6,9,11	6	5,9,11	21	9,11(強)	82	6,11(強)
***03	1	2,3,5,6	2	2,5,6	7	2(強),10		
***98	1	5,9,11	15	9,10,11	21	4,8,9,10	28	4,8(強)

表 4 主クラスタが途中で消える遷移例

ID	遷移日	クラスタ	遷移日	クラスタ	遷移日	クラスタ	遷移日	クラスタ
***28	1	6,10(強),11	12	4,6,10,11				
***93	1	2(強),6,10	10	2,6,10	19	2,6,8,10		
***94	1	6,10(強)	8	6,10,11	17	5,6,10,11	29	6,10,11

(2) 患者の特徴に応じた遷移パターン

死亡の有無や年齢期など、患者の特徴に注目すると、以下の 7 つの遷移パターンが見られた。

- ・死亡に至った患者の場合、最終クラスタに C7 または C1 が含まれていた。
- ・死亡の有無に関わらず、初期クラスタに C2 が含まれる場合が多かった。
- ・死亡の有無に関わらず、C3 が強い実施日の場合、翌日に C5 が現れる場合が多かった(図 2)。
- ・死亡の有無に関わらず、C6 が間欠的に現れる患者が多かった。
- ・0~15 歳の小児患者は、死亡 1 例を除き、すべて最終クラスタが C12 であった。
- ・回復した 16 歳以上の患者は、最終クラスタに C8, C10, C11, C12 のいずれかを含んでいた。特に C10 および C11 の場合が多かった。

- 初期にC2が強く、その他はC6のみの場合、全員回復し、入院期間が短く(最大で32日間)、クラスタの変化もほとんど見られなかった。

ID	実施日	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12
***13	7	47%	0%	0%	4%	0%	0%	49%	0%	0%	0%	0%	0%
***13	8	20%	0%	64%	0%	3%	13%	0%	0%	0%	0%	0%	0%
***13	9	29%	0%	0%	3%	39%	21%	7%	0%	0%	0%	0%	0%
***13	10	29%	0%	0%	3%	39%	20%	9%	0%	0%	0%	0%	0%
***13	11	26%	0%	0%	0%	42%	19%	14%	0%	0%	0%	0%	0%
***13	12	27%	0%	0%	0%	43%	19%	11%	0%	0%	0%	0%	0%
***03	1	0%	7%	63%	0%	0%	16%	0%	3%	0%	11%	0%	0%
***03	2	0%	6%	2%	6%	36%	17%	0%	0%	0%	22%	10%	0%
***03	3	0%	8%	2%	8%	34%	8%	0%	0%	0%	24%	16%	0%
***03	4	0%	17%	0%	9%	27%	0%	0%	6%	0%	35%	7%	0%
***03	5	0%	10%	0%	15%	24%	20%	0%	0%	0%	24%	8%	0%
***03	6	0%	12%	3%	23%	30%	0%	0%	0%	0%	21%	11%	0%

図 2 C3からC5の遷移例

4. 考察

4.1 DPC データに基づくPLSA 分析の有用性

分析結果から、クラスタの特徴と遷移パターンを統合すると、臨床における実際の状況が推察でき、各クラスタの臨床的な意味付けが可能であることが明らかになった。

例えば、C7は、死亡率が高く、緩和ケアを受けている患者が多いクラスタであり、また遷移パターンにおいても最終クラスタとなることが多いという結果から、患者がターミナル(終末期)の状況にあると考えられる。同様に、死亡率が高く、重症度が高い状態の患者が多いC1も、遷移パターンで最終クラスタとなっており、最大限の治療を行い、他に治療の選択肢がない状況と考えられる。

敗血症以外の(入院する原因となった)疾患も含め、重症度が高く入院が長引いている状況や、緩和ケアを受ける状態にある患者において死亡率が高い傾向が見られることは、実際の臨床現場で想定される状況でもあるが、DPC データからの客観的な分析により、そのような状況が確率論として導かれたことの意味は大きい。臨床における現象をデータに反映できることの証明であり、本研究により、DPC データを活用した治療選択ナビゲーションシステムの実現可能性が高まったと考える。

一方、上記と比較して、C10やC11などICUに入院したケースでは死亡率が低い傾向を示したことも興味深い。集中治療を受けることができる、すなわち明確な治療方法がある状況下では、敗血症に罹患した場合でも、救命率が高いということが言えるかもしれない。この結果から、DPC データを活用したPLSAによる分析は、システム構築のためだけでなく、臨床で起こる現象の検証方法として、新たな視点が提供できる可能性が示唆された。

さらに、クラスタ遷移パターンにおいて、一人の患者の入院期間中には主クラスタが一つのみ存在する、もしくは存在しないという今回の分析結果から、治療選択ナビゲーションシステムの開発において、主クラスタが注目すべきポイントの一つとなり得ることがわかった。主クラスタが変わることはほとんどないため、患者単位でのカテゴリー分けなどに主クラスタという考え方が役立つと思われる。また、経過とともに遷移しやすいのは、主クラスタ以外で所属するクラスタであることがわかったため、今後、その観点からより詳細な分析を行いたい。

4.2 臨床判断につながるクラスタ分類と遷移パターン

本研究における各クラスタの特徴やその遷移パターンから、臨床判断につながるいくつかの視点が得られた。

C6は、主クラスタにはならない、付随的なクラスタであると考えられる。数日おきに現れる傾向があることから、定期的に行われる薬剤投与や処置などが含まれるクラスタではないかと推測される。また、入院期間が短い患者が多いC2が強く、その他はC6のみが所属している組み合わせが一定数見られたことから、薬剤投与などで順調に回復したケースが想定される。したがって、具体的な薬剤や処置については、今後さらなる分析・検討が必要であり、重要な視点となる可能性があることが示唆された。

C12は、小児患者が多いことから、小児特有の疾患が多いことや、薬剤の投与量が成人とは異なるなどの治療の違いが反映された結果のクラスタと考えられる。小児領域は、他領域と区別して検討する必要があることがデータから示されたと考えられる。

C3は手術を受けた患者が多く、C5は緊急入院した患者や、緊急手術、血液浄化が行われた患者が多いクラスタとして分類されていた。したがって、C3が強く現れた翌日にC5に遷移する傾向については、翌日に再手術や術後合併症への対応が行われた可能性もデータからは考えられた。今後、実際の診療記録との突合せを行い、クラスタ遷移に関連する現象を検証したい。

4.3 今後の課題

DPC データを治療戦略支援に活かす取り組みは、本研究も含め、これまでの研究によりある程度の実現可能性は示されている。しかし、臨床応用に向けては、複合疾患の状況や各疾患の治療期間など、DPC データのみでは得られない診療記録からの詳細情報も追加し、より大規模なデータベースを構築することや、多施設のデータによる分析を行い、結果の信頼性を高めていく必要があると考える。

また、今回は所属確率60%以上のクラスタを主クラスタと定義したが、妥当性を確保するためには、他の変数項目での実施や条件を変えた上での解析を重ねながら検証する必要がある。

5. 結論

DPCデータの全項目を用いて、「死亡の有無」のみに20倍の重みを付けたPLSAによるクラスタリングを行った結果、敗血症患者のうち、重症度が高く入院が長引いている患者や緩和ケアを受けている患者の場合は、死亡率が高いことが明らかになった。また、ICUに入院したケースでは死亡率が低い傾向が示された。

各患者の実施日ごとの所属クラスタのうち、所属確率が高い主クラスタに注目すると、5つの遷移パターンが得られた。また、各クラスタの特徴に注目すると、小児領域は他領域とは区別して検討するほうがよいこと、薬剤や処置について詳細な分析が必要なこと、手術とその後の処置の関係性を診療記録から把握する必要があることなどの示唆を得た。

今後は、医師の意思決定を支援する治療選択ナビゲーションシステムの開発に向けた分析・予測の高度化と、現場ニーズに即した機能開発、試作、実証へと進めていく。

謝辞

本研究にご協力くださった関係者の皆様に心より感謝申し上げます。本研究は、NEDO委託事業「人間と相互理解できる次世代人工知能技術の研究開発」の支援を受けて行いました。

参考文献

- [Hofmann 1999] Hofmann T: Probabilistic Latent Semantic Analysis, Proceedings of the Fifteenth conference on Uncertainty in artificial intelligence, Morgan Kaufmann Publishers Inc., 1999.
- [山下 2017] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 時間変化も考慮した pLSA 手法による敗血症治療戦略への応用, 第 27 回人工知能学会 社会における AI 研究会, 2017.
- [山下 2018a] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 医師の知見と経験を蓄積・伝承する判断支援システム実現に向けた pLSA による診療クラスタの時間遷移パターンの解析, 人工知能学会全国大会, 2018.
- [山下 2018b] 山下和也, 阪本雄一郎, 櫻井瑛一, 本村陽一: 診療クラスタ遷移と医学的判断の紐づけによる敗血症治療ナビゲーションシステム実現可能性の検証, 第 5 回「JAMI 医用知能情報学研究会-JSAI 医用人工知能研究会」合同研究会, 2015.
- [山下 2019] 山下和也, 村田知佐恵, 阪本雄一郎, 櫻井瑛一, 本村陽一: 敗血症患者への血液浄化を含む治療戦略決定支援に向けた重み付き PLSA による診療行為と患者の DPC データに基づく同時クラスタリング解析, 日本急性血液浄化学会雑誌, 2019, in print.

[113-J-2] Machine learning: advances in reinforcement learning

Chair:Masahiro Yukishima Reviewer:Kohei Miyaguchi

Tue. Jun 4, 2019 3:20 PM - 4:20 PM Room I (306+307 Small meeting rooms)

[113-J-2-01] Development of Optimal Control Using AlphaZero Reinforcement Learning Algorithm

○Watabe Masaya¹, Kun Yang¹, Dinesh Malla², Katsuyoshi Sakamoto¹, Kouichi Yamaguchi¹, Tomah Sogabe^{1,3} (1. The University of Electro-Communications, 2. Grid Inc., 3. i-PERC, The University of Electro-Communications)

3:20 PM - 3:40 PM

[113-J-2-02] Generalized goal oriented deep reinforcement learning for robot arm training with continuous action space

○Kimaura Tomoaki², Masaya Watabe², Katsuyoshi Sakamoto¹, Kouichi Yamaguchi¹, Dinesh Malla³, Tomah Sogabe^{1,3,4} (1. Advanced science and technology department, The University of Electro-Communications, 2. Mechanical department The University of Electro-Communications, 3. Grid Inc., 4. i-perc, The University of Electro-Communications)

3:40 PM - 4:00 PM

[113-J-2-03] Imitation learning based on entropy-regularized reinforcement learning

○Eiji Uchibe¹ (1. Advanced Telecommunications Research Institute International)

4:00 PM - 4:20 PM

アルファゼロ型強化学習アルゴリズムを用いた最適制御手法の開発

Development of Optimal Control Using AlphaZero Reinforcement Learning Algorithm

楊 坤^{*1}, 渡部 雅也^{*1}, Dinesh Bahadur Malla^{*1}, 坂本克好¹, 山口浩一¹, 曾我部東馬^{*1,2}

¹ 電気通信大学 基盤理工学専攻

² 電気通信大学 i-パワーエネルギー・システム研究センター

Deep Learning and Reinforcement Learning are developing rapidly in recent years. A lot of researches which apply deep reinforcement learning to the field such as game and robot control have generated great success. In this paper, we examine the possibility of adopting AlphaZero, an reinforcement learning algorithm demonstrates an unprecedented level of versatility for an game AI, to optimal control problems and gain insight on its ability to control the actions under noisy environment that is difficult to handle by using conventional control mechanism.

1. 序論

制御理論は 1778 年にワットの蒸気機関に適用された P(Proportional, 比例)制御から始まり、1940 年代に比例制御にオフセットを除去する I(Integral, 積分)制御と出力の先行抑制を行う D(Differential, 微分)制御を加えた PID 制御の普及により、制御理論として広く認知された。その後 20 世紀後半に線形代数を制御に応用した線形システム論が誕生し、多入力多出力システムを取扱えるようになり、状態方程式を解くことで解析的に制御の最適解が得られるようになった。

しかし、システムに非線形成分、外乱が存在する場合やシステムの詳細を知ることができないなどの場合は、システムを数式化し解析することが困難になる。そのため現在でも複雑なシステムにおいては PID 制御が用いられ、試行錯誤を通じてパラメータを調整する手法が使われている。

一方、1970 年代から、ニューラルネットワークと強化学習が急速に発展してきた。「任意関数を近似できる」ニューラルネットワークと「環境に対して事前知識を必要とせず、探索に通じて行動を最適化する」強化学習を用いて、非線形成分、外乱が含まれる複雑なシステムでも近似することができ、制御の最適化を行なえるようになった。

そして近年、強化学習分野は幾つのブレイクスルーを遂げている。2015 年に Google DeepMind 社が発表した DQN アルゴリズムがビデオゲームで超人的な高得点を叩き出し、話題となり、その後も最適制御への応用が成果を上げ、制御問題において DQN の有用性が確認された。2016 年、同じく Google DeepMind 社から AlphaGo が発表され、同年にトップ棋士イ・セドルを破り、世界を驚かせた[1]。2017 年に後続バージョンの AlphaZero が発表され、AlphaGo に 100 戦全勝という圧倒的な進化を遂げた。そのため、近年 AlphaZero の強化学習アルゴリズムを用いて、タンパク質の折りたたみなどより難解な「ゲーム」に挑戦し、別分野へ応用する試みが始まった。

本研究は Google DeepMind 社が発表した AlphaZero の論文 [1]に基づき、AlphaZero 強化学習アルゴリズムを再現し、最適制御問題に対して AlphaZero 型強化学習アルゴリズムの有効性を検証する。また、適用した結果を既存の DQN アルゴリズムとど

のような差があるかを比較する。更に外乱テストにおけるアルゴリズム予測性能のロバスト性を検証する。

2. 最適制御と強化学習

2.1 最適制御と強化学習の関係

制御は、制御対象のプラントに思い通りの出力 $r(t)$ をさせるためにコントローラからの入力 $u(t)$ を決めることである。そして、最適制御は、図 1 のように制約条件のもとで、ある評価関数 J を最小化するように制御を行うことである。

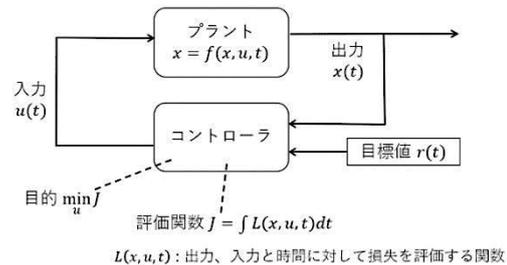


図 1 最適制御の模式図

すなわち、最適制御問題は一般的に評価関数

$$J = \int L(x, u, t) dt \quad (2.1)$$

の最小値を与える $u(t)$ を求める問題へと帰着できる。しかし、実際多くの場合では評価関数の最小値を解析的に解くことができない。

強化学習はエージェントが環境に働きかけ、働きかけによって生じる対象の変化の観測のみに通じて、ある目的を目指す最

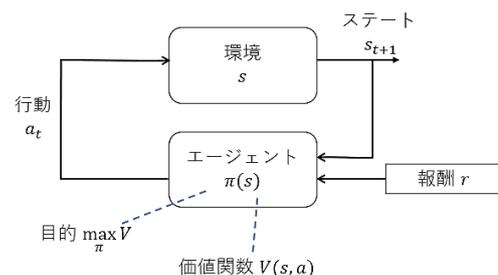


図 2 強化学習の模式図

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

適な行動を発見する枠組みである。強化学習において、目的は報酬 r を用いて表され、ある行動を取ることで将来に渡ってもらえる報酬の期待値は価値 v と表す。強化学習の目的は一般的に探索を通じて行動価値を最大化することになる。

ここで、最適制御の目標値と評価関数を強化学習の報酬に変換すれば、最適制御問題に強化学習を応用することができ、従来手法で適用できなかった複雑なプラントに対しても強化学習を用いたアプローチが可能になる。

2.2 アルファゼロの概要

アルファゼロ強化学習アルゴリズムは、DQN などのアルゴリズムと異なり[3]、探索にモンテカルロ木探索(Monte Carlo tree search, MCTS)を用い、価値(Value)と方策(Policy)をすべてニューラルネットワークに予測させ、木探索によるセルフプレイで得られた経験のみで予測を修正する構成になっている。従来のアルファ碁に比べ、価値を予測するバリューネットワークと方策を予測するポリシーネットワークが一つのニューラルネットワークに統合され、マルチタスク学習により予測精度の向上が図られた。

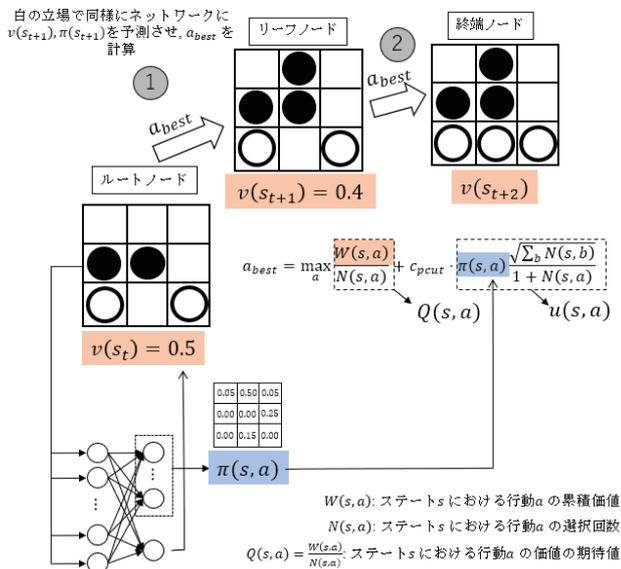


図3 三目並べにおける MCTS の選択(Selection)

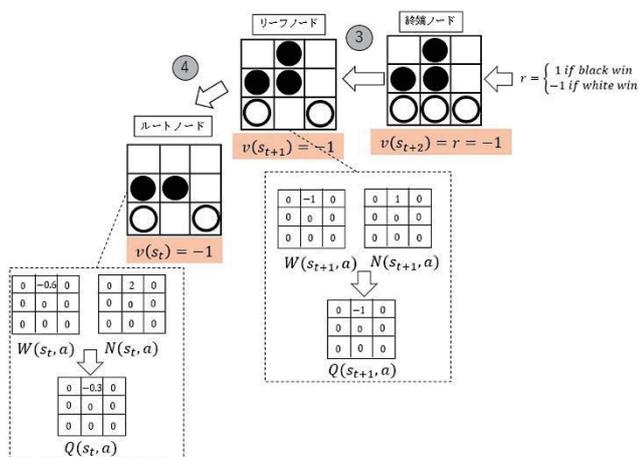


図4 三目並べにおける MCTS の更新(Backup)処理

また、ニューラルネットワークの性能向上により、木探索でのプレイアウト(報酬を貰うまで探索木を伸ばす)処理が不要となり、より高速に探索を行えるようになった。

アルファゼロのセルフプレイは、今の盤面(ステート)をルートノードとし、図3、図4のように一定回数の木探索を行う。探索中に行動の価値 $Q(s, a)$ が評価、更新され、価値の高い手は a_{best} の式によって、選択される回数も多くなる。探索が終わったあとルートノードでの各行動の選択回数に比例した確率でセルフプレイの次の一手を決め、この過程を繰り返してゲームが終わるまで進める。そして、一定回数のセルフプレイを行い、途中で経験したステート、その時に探索から得た行動方策、ゲーム最後の結果(報酬)を記録し、ニューラルネットワークに学習させる。この手順を繰り返すことで、ニューラルネットワークの予測精度が上がり、その予測結果を使った木探索の質も上がる。それによってセルフプレイでより最適な行動が取られ、蓄積される学習データの精度も上がる。この正帰還によって、アルファゼロが強くなる。

2.3 最適制御への応用

アルファゼロの入力であるボードゲームの盤面をプラントのステート、出力である次の一手の位置をコントローラの出力に対応させ、評価関数を変換して報酬とすれば、アルファゼロを最適

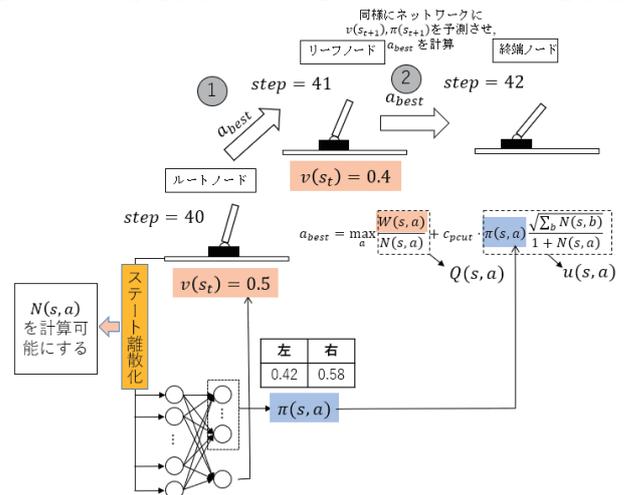


図5 CartPoleにおける MCTS の選択と展開処理

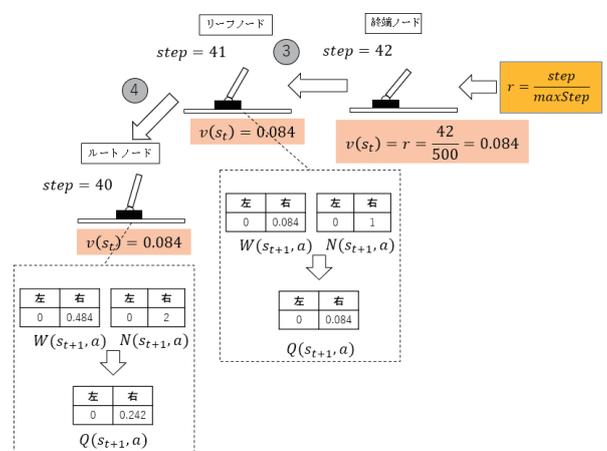


図6 CartPoleにおける MCTS の更新処理

制御に応用できる。アルファゼロの入力の盤面と出力の次の一手の位置は共に離散値であり、最適制御に応用にあたり、プラントのステートとコントローラの出力が連続値である場合、その値を離散値するか、あるいはアルファゼロの入出力を連続値に対応させる必要がある。制御問題においてプラントの状態は実際センサーなどによって測り、出力されるのでセンサーに精度があり、観測される状態は実質離散値となることを考慮し、本研究はより実装しやすい入出力の離散化を選んだ。

3. 評価実験

OpenAI Gym^[2]に公開されている典型的な制御問題である CartPole のシミュレーター(図 7)を用いて、アルファゼロの強化学習アルゴリズムを応用し、学習を試み、結果を別論文^[3]で公開されている DQN の結果と比較した。また、学習済みのモデルを用いて、50 ステップ毎にランダムに振り子を左あるいは右に 0.1~0.15 rad を倒す外乱(振り子の角度の大きさが 0.21 rad を超えたらゲーム終了となる)を加え、外乱に対するモデルの応答を実験した。

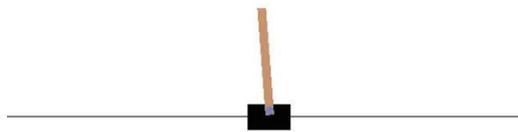


図 7 OpenAI Gym の CartPole シミュレーター

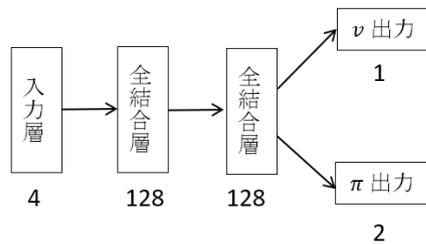


図 8 CartPole 実験におけるアルファゼロのニューラルネットワーク構成

Table 1 CartPole 実験におけるアルファゼロパラメータ設定

項目	条件
最大ステップ数	500
イテレーション回数	100
イテレーションあたりエピソード数	20
ステート丸め桁数	3
MCTS 探索回数	80
C_{puct}	1

4. 考察と展望

図 9 から、アルファゼロが 500 エピソードで振り子を最大の 500 ステップ倒立できるようになり、それ以後は最大ステップを維持できた。DQN と DQN with Target Network に比べて収束時の性能と安定性が優れている。図 10 から、最大 500 ステップの倒立の学習に対し、外乱実験で 2000 ステップを維持でき、さらに 50 ステップ毎に加えた外乱に対して、Cart の速度と Pole の角度が 0 になるように制御できた。従って最適制御においても、アルファゼロ強化学習アルゴリズムの有用性が確認できた。

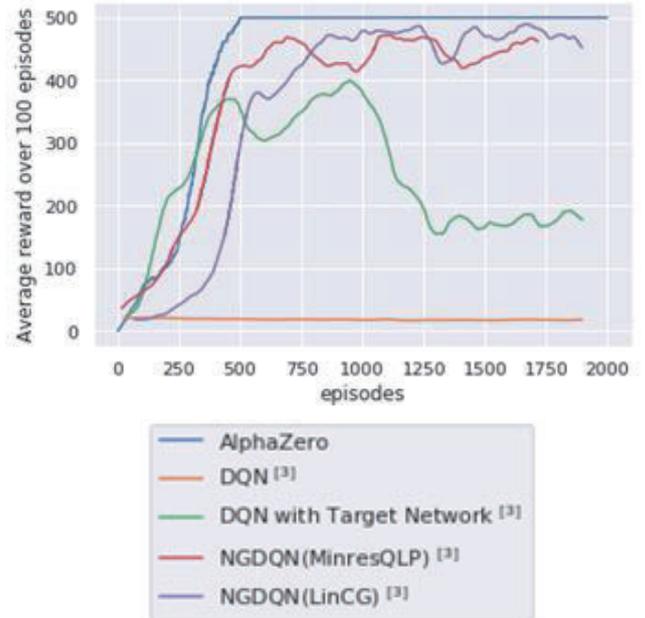


図 9 CartPole 学習結果の比較

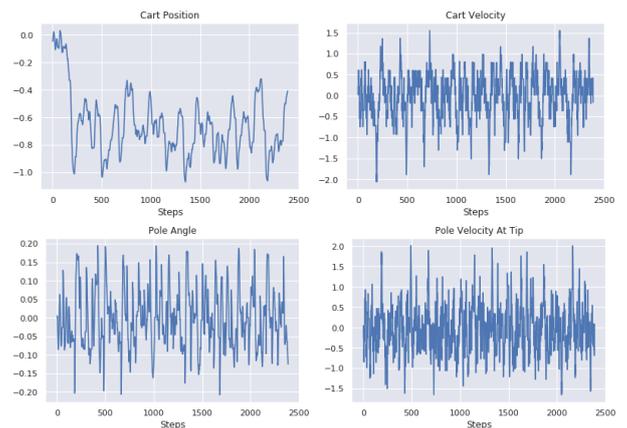


図 10 CartPole 外乱実験の結果

本研究の展望として、今回はプラントのステップ入力を離散化しアルファゼロを適用したが、連続ステート、連続出力を必要とする制御問題では、アルファゼロの MCTS を連続入力、連続出力に対応させる研究が期待される。

5. まとめ

本研究では、最適制御と強化学習の関係、強化学習アルゴリズムのアルファゼロの概要を説明し、アルファゼロを最適制御問題に応用できることを提案した。そして、アルファゼロを最適制御問題の一つである CartPole に応用し、既存の DNQ アルゴリズムと比較した。また外乱実験でアルファゼロが振り子を倒立することができ、外乱のあるプラント制御においても有用であることを確認できた。

参考文献

- [1] D Silver, J Schrittwieser, K Simonyan, I Antonoglou, A Huang, A Guez, T Hubert, L Baker, M Lai, A Bolton, Y Chen, T Lillicrap, Fan Hui, L Sifre, G van den Driessche, T Graepel,

- D Hassabis, “Mastering the game of Go without human knowledge,” *Nature*, 2016.
- [2] CartPole-v1, <https://gym.openai.com/envs/CartPole-v1/>
- [3] E Knight, O Lerner, “Natural Gradient Deep Q-learning”, arXiv:1803.07482, 2018

汎化ゴールにおける連続動作型ロボットアームの深層強化学習手法の開発

Generalized goal oriented deep reinforcement learning for robot arm training with continuous action space

木村 友彰¹, 渡部 雅也¹, 坂本 克好², 山口 浩一², Dinesh Bahadur Malla³, 曾我部 東馬^{*2,3,4}

¹ 電気通信大学 機械システムプログラム

² 電気通信大学 先進理工学科

³ 株式会社 グリッド

⁴ 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

In multigoal reinforcement learning, Universal Value Function Approximators(UVFA) that takes not only a state but also a goal for inputs is used. We designed a task by bringing the end effector of the 7DOF robot arm to the goals using UVFA based multigoal reinforcement learning. Meanwhile, we performed the equivalent task by changing the number of goals. We confirmed a superb prediction ability by mapping the goal reachability degree using UVFA.

1. はじめに

強化学習において状態だけではなくゴールも汎化するための価値関数近似として Universal Value Function Approximators(UVFA)[1] が提案され、UVFA により目標が一つではなく複数ある場合のマルチゴール強化学習が可能になった。学習時にマルチゴールをタスクとして学習したエージェントは一つのゴールをタスクとして学習するよりも簡単に学習が進むことが示されており [2]、マルチゴール強化学習の有効性が示されている。[2]では7自由度ロボットアームを用いたマルチゴール強化学習を考えていたが、エージェントの行動はエンドエフェクタに対する操作になっていた。エージェントの行動をエンドエフェクタに対する操作ではなくアームの関節角度に対する操作とすると行動が複雑になりゴールの汎化が難しくなるということが考えられる。そこで本研究では連続動作の7自由度ロボットアームに対してエージェントの行動をアームの関節角度に対する指令値としたマルチゴール強化学習タスクを考え、この場合に対してゴールを汎化することができることを示す。

2. 強化学習

本章では本研究において用いた強化学習手法の説明を行う。

● Deep Deterministic Policy Gradients(DDPG)

Deep Deterministic Policy Gradients(DDPG)[3]は Deep Q-Networks(DQN)[4]を行動空間が連続な場合に用いることができるように拡張したアルゴリズムである。行動を決めるための Actor と行動を評価するための Critic からなる Actor-Critic 法に基づいており、Actor とそのターゲットネットワーク、Critic とそのターゲットネットワークの4つのニューラルネットワークがある。それぞれのニューラルネットワークについて簡単に説明する。Actor ネットワークは方策を表し、状態に対しての行動を出力するネットワークである。Critic ネットワークは行動価値関数を表し、

状態、行動に対しての行動価値関数の値を出力するネットワークである。ターゲットネットワークは DQN と同様に学習するネットワークと構造は同じとし学習の間は固定して学習を行った後ソフトアップデートにより更新する。学習の方法に関しては Critic ネットワークは TD 誤差を最小化するように学習し、Actor ネットワークは Critic ネットワークの出力を最大化するように学習する。またエピソードを進めていくときには actor の出力に探索ノイズを付与したものを行動とする。

● Universal Value Function Approximators(UVFA)

Universal Value Function Approximators(UVFA)は通常の価値関数を目標が複数ある場合でも用いることができるように拡張したものである。まず目標が複数ある場合の強化学習つまりマルチゴールの強化学習について説明する。目標が複数あるつまりゴールが複数ありそれぞれのゴールに対して報酬関数が定義されている。エピソードの間は目指すゴールは固定されておりエピソードの最初に初期状態を決めるときに合わせて決められる。UVFA は通常の価値関数の入力に加えてゴールを入力に入れるという構造になっておりこれにより状態、行動だけではなくゴールも含めた価値を考えることが可能になる。また方策も状態だけではなくゴールも合わせて決めることになる。

3. ロボットアームへの強化学習の適用

マルチゴールの強化学習タスクとしてロボットアームのエンドエフェクタを決められた位置(ゴール)に持っていくというタスクを考えた。ここでゴールの位置は固定ではなくロボットの作業範囲の中で変えられるとする。図1がロボットアームに強化学習を適用しこのタスクを行う流れを表したものである。青い矢印がエピソードを進める流れであり、赤い矢印が学習時の流れである。強化学習エージェントとして UVFA を用いた DDPG エージェントを使い状態はアームの各関節の角度、行動は各関節への角度指令値、ゴールはゴールの座標とした。また、報酬はエンドエフェクタの位置とゴールの間の距離(cm)にマイナスをかけたものを

連絡先: 曾我部 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

用いエピソードの終了条件はこの距離が決められた範囲内に入っているかどうかとした。

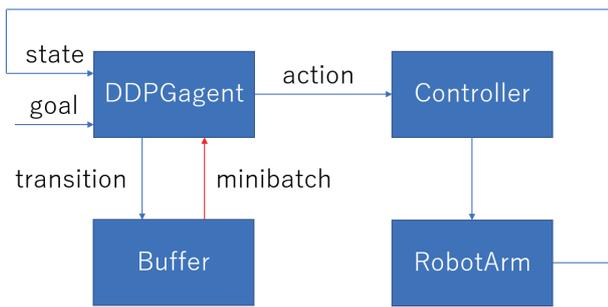


図1 ロボットアームの強化学習

エピソードの開始にエージェントはそのエピソードのゴールを受け取りエピソードが始まる。このゴールの与え方がロボットの作業範囲の中のゴールを汎化するために重要となると考えられるのでゴールの与え方を変えいくつか実験を行った。実験にあたっては Gazebo シミュレータを用いロボットのモデルには株式会社アールティの7自由度のロボットアーム CRANE-X7を用いた。

4. 実験

● ゴールを二点与える

ゴールを二つ用意し学習を行った。用意した二つのゴールの座標は(0.3, 0.2, 0.15), (0.3, -0.2, 0.15)とした。学習後の汎化性能をこれらの二つのゴールに対して x, y 方向にゴールを変更しどのくらいの距離まで近づくことができるのかによりテストした。図2より学習したゴールから離れると汎化性能は悪化していることがわかる。また、同じ距離だけ学習したゴールから離れていてもこれらの間にある方のゴールについては間もないゴールより高い汎化性能を出せていることがわかる。

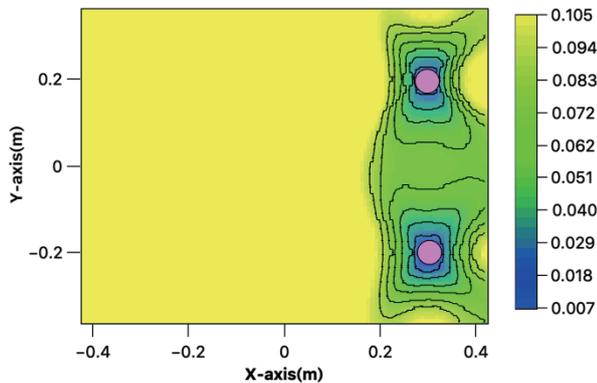


図2 ゴール二つの場合の汎化性能

● ゴールを三点与える

ゴールを三つ用意し学習を行った。用意した三つのゴールの座標は(0.3, 0.2, 0.15), (-0.2, -0.15, 0.35), (0.1, -0.4, 0.1)とした。学習後の汎化性能をこれらのゴールに対して x, y, z 方向にゴールを変更しどのくらいの距離まで近づくことができるのかによりテストした。図3において10cm近づけていることを汎化性能があるといえる限界と考えこれより離れてしまった場合汎化性能はないと考え色はグレーとした。図3よりゴール二つの場合と同じように学習したゴールから離れると汎化性能は悪化していることがわかる。また、学習したゴールの間にあるゴールに対しては離れていてもそれなりの汎化性能を出すことができている。

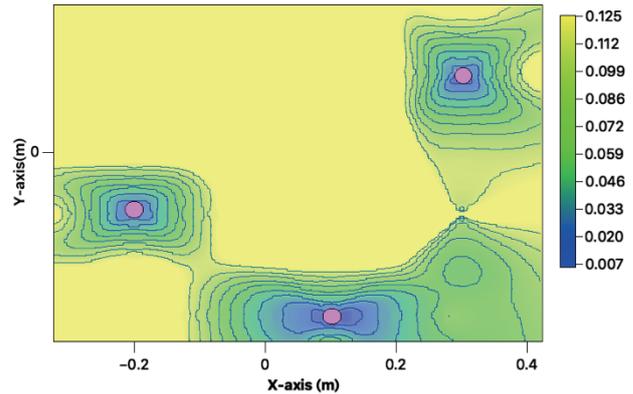


図3 ゴール三つの場合の汎化性能

5. 考察とまとめ

ゴール二つの場合、三つの場合より二つのことがわかる。一つは学習したゴールから離れると汎化性能は悪化するということともう一つは学習したゴールの間にあるゴールにはある程度の汎化性能を持たせることができるということである。これより学習するゴールをうまく設定することができればロボットの作業範囲全てに対して汎化性能を持たせることが可能であると考えられるが、このゴールの設定方法に明確な指標はない。よって今後このゴールの設定の仕方をエージェントが学習するという手法を開発しすべてのゴールに対する汎化機能を出せるようにしていきたいと考えている。

参考文献

- [1] Schaul, Tom, Horgan, Daniel, Gregor, Karol, and Silver, David *Universal value function approximators*, In International Conference on Machine Learning, 2015.
- [2] M. Andrychowicz, F. Wolski, A. Ray, J. Schneider, R. Fong, P. Welinder, B. McGrew, J. Tobin, P. Abbeel, and W. Zaremba *Hindsight Experience Replay*, arXiv preprint arXiv:1707.01495, 2018.
- [3] Timothy P. Lillicrap, Jonathan J. Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver and Daan Wierstra *CONTINUOUS CONTROL WITH DEEP REINFORCEMENT LEARNING*, arXiv preprint arXiv:1509.02971, 2016.
- [4] Mnih, Volodymyr, Kavukcuoglu, Koray, Silver, David, Rusu, Andrei A, Veness, Joel, Bellemare, Marc G, Graves, Alex, Riedmiller, Martin, Fidjeland, Andreas K, Ostrovski, Georg, et al. *Humanlevel control through deep reinforcement learning*, Nature, 518(7540):529–533, 2015.

エントロピー正則された強化学習を用いた模倣学習

Imitation learning based on entropy-regularized reinforcement learning

内部 英治 *1

Eiji Uchibe

*1国際電気通信基礎技術研究所

ATR Computational Neuroscience Labs.

This paper proposes Entropy-Regularized Imitation Learning (ERIL) that is given by a combination of forward and inverse reinforcement learning. ERIL utilizes the soft Bellman optimality equation in which the reward function is augmented by the entropy of the learning policy and the Kullback-Leibler (KL) divergence between the learning and the baseline policies. We show that inverse RL is interpreted as estimating the log-ratio between two policies and the log-ratio is efficiently solved by binary logistic regression. Forward RL is given by a variant of Dynamic Policy Programming and our algorithm is interpreted as minimization of the KL divergence between the learning policy and the estimated expert policy. Experimental results on the MuJoCo-simulated environments show that ERIL is more sample efficient than the previous methods such as GAIL and AIRL because the forward RL step of ERIL is off-policy.

1. はじめに

強化学習は最適方策（制御則）を試行錯誤によって獲得するための手法で、知能ロボットに自律的な学習能力を与えるために必要である。またヒトや動物の意思決定過程の計算モデルとして計算論的神経科学の分野で注目されている。一般に強化学習では各状態で実行した行動に対する即時評価である報酬を必要とする。しかし所望の最適方策を達成する報酬を設計するのは簡単ではない。たとえばタスクを達成した場合のみ正の報酬値を与え、それ以外は0であるような非常にスパースな報酬関数を用いた場合、原理的には最適方策を学習できるが必要とするデータ数や学習時間は非常に膨大なものとなる。学習効率を改善するために複雑な報酬関数を設計することも考えられるが、多くの場合は意図しない最適方策を学習することになる。

この問題に対処するための方法として逆強化学習がある。逆強化学習ではタスクを達成しているエキスパートの存在を仮定し、エキスパートが用いている報酬関数をエキスパートからのデータから推定する。近年、強化学習と逆強化学習の組み合わせが敵対的生成ネットワーク (Generative Adversarial Networks; GAN) として定式化できることが示された [3, 4, 6]。逆強化学習は GAN における識別器に対応し、エキスパートからのデータとロボット自身が生成したデータを区別する。強化学習は GAN における生成器に対応し、逆強化学習によって推定された報酬の期待積算を最大にするように新しい方策を学習する。Generative Adversarial Imitation Learning (GAIL) [6] や Adversarial Inverse Reinforcement Learning (AIRL) [4] は逆強化学習と強化学習を繰り返すことで単純な模倣学習である Behavior Cloning (BC) よりもエキスパート方策を精度良く復元できることを示した。GAIL や AIRL はエキスパートからのサンプル数が少ない場合でも有効であるが、その一方で生成器の改善に必要な環境とのインタラクションに関するデータ効率は低いことが知られている。一つの理由として GAIL や AIRL は方策オン型の強化学習法である Trust Region Policy Optimization (TRPO) [9] を用いていることがあげられる。重

連絡先: 内部英治, 国際電気通信基礎技術研究所 脳情報研究所
ブレインロボットインタフェース研究室, 〒619-0288 京
都府相楽郡精華町光台二丁目2番地2, uchibe@atr.jp

点サンプリング等の技術を用いない限り過去に学習方策が生成したデータを再利用できないため方策の改善には現在の学習方策が多くデータを生成する必要がある。

そこで強化学習時のデータ効率を改善するために、本研究ではエントロピー正則された模倣学習 (Entropy-Regularized Imitation Learning; ERIL) を提案する。報酬関数は学習方策のエントロピーと学習方策とベースライン方策の Kullback-Leibler (KL) ダイバージェンスによって正則化される。この定式化のもとで得られるソフトベルマン最適方程式を用いて、逆強化学習を密度比推定問題として定式化する。密度比推定はエキスパート方策からのデータと学習者自身が生成したデータを区別するロジスティック回帰によって効率的に解くことができる。識別器は報酬、状態価値関数、学習者の方策によって記述され、従来法で用いられた識別器 [4, 12] を一般化したものである。逆強化学習の結果エキスパート方策が推定されるため、KL ダイバージェンスによって新たな学習方策を更新する、これは方策オフ型の強化学習である Soft Actor-Critic [5] で用いられるものと同じで、強化学習時におけるデータ効率を期待できる。

OpenAI gym [2] で提供されているロボット制御課題を用いて ERIL と従来手法を比較する。シミュレーション結果より、エキスパートからのデータ数に関しては従来法と同程度の効率であるが、環境とのインタラクションに関するデータ効率は従来法よりも改善されたことを示す。

2. エントロピー正則化された強化学習

離散時間の無限期間マルコフ決定過程 (Markov Decision Process; MDP) を考える。MDP は $(\mathcal{X}, \mathcal{U}, p_T, r, \gamma, p_0)$ の組によって定義される。ここで \mathcal{X}, \mathcal{U} はそれぞれ状態空間、行動空間である。 $p_T(\mathbf{x}' | \mathbf{x}, \mathbf{u})$ は状態 $\mathbf{x} \in \mathcal{X}$ で行動 $\mathbf{u} \in \mathcal{U}$ を実行した時に状態 $\mathbf{x}' \in \mathcal{X}$ に遷移する確率で、モデルフリー強化学習の枠組みでは未知である。 $\tilde{r}(\mathbf{x}, \mathbf{u})$ は状態 \mathbf{x} 、行動 \mathbf{u} に対して与えられる即時報酬である。 $\gamma \in (0, 1)$ は割引率、 $p_0(\mathbf{x})$ は初期状態分布である。状態 \mathbf{x} で行動 \mathbf{u} を選択する確率を $\pi(\mathbf{u} | \mathbf{x})$ とする。強化学習の目的は期待割引積算報酬を最大にする方策を求めることである。

近年、報酬関数をエントロピによって正則化されたクラスの MDP が注目を集めている [1, 5, 7]. 具体的には報酬関数が

$$\begin{aligned} \tilde{r}(\mathbf{x}, \mathbf{u}) \triangleq & r(\mathbf{x}, \mathbf{u}) + \kappa \mathcal{H}(\pi(\cdot | \mathbf{x})) \\ & - \eta \text{KL}(\pi(\cdot | \mathbf{x}) \| b(\cdot | \mathbf{x})) \end{aligned} \quad (1)$$

のように正則化される. ここで $r(\mathbf{x}, \mathbf{u})$ は通常の意味での即時報酬関数, $\mathcal{H}(\pi(\cdot | \mathbf{x}))$ は方策 π のエントロピ, $\text{KL}(\pi(\cdot | \mathbf{x}) \| b(\cdot | \mathbf{x}))$ は π とベースライン方策 $b(\mathbf{u} | \mathbf{x})$ の間の Kullback-Leibler (KL) ダイバージェンス, κ, η は実験者の定めるメタパラメータである. このとき以下のベルマン最適性方程式

$$\begin{aligned} V(\mathbf{x}) = & \max_{\pi} \mathbb{E}_{\mathbf{u} \sim \pi(\cdot | \mathbf{x})} [r(\mathbf{x}, \mathbf{u}) - \kappa \ln \pi(\mathbf{u} | \mathbf{x}) \\ & - \eta \ln \frac{\pi(\mathbf{u} | \mathbf{x})}{b(\mathbf{u} | \mathbf{x})} + \gamma \mathbb{E}_{\mathbf{x}' \sim p_T(\cdot | \mathbf{x}, \mathbf{u})} [V(\mathbf{x}')]] \end{aligned} \quad (2)$$

が成り立つ. ここで $V(\mathbf{x})$ は状態価値関数と呼ばれる. エントロピの役割は最適方策が決定論的になることを防ぎ, 探索を促進する. KL ダイバージェンスの役割はベースライン方策 $b(\mathbf{u} | \mathbf{x})$ からあまり逸脱しないように方策改善ステップを保守的にする. エントロピ正則化の利点は式 (2) の右辺の方策に関する最大化が Lagrange の未定乗数法によって解析的に求められることである. 結果として状態価値関数 $V(\mathbf{x})$ と状態行動価値関数 (\mathbf{x}, \mathbf{u}) に対して以下の関係式

$$V(\mathbf{x}) = \beta^{-1} \ln \int \exp(\beta Q(\mathbf{x}, \mathbf{u})) d\mathbf{u}, \quad (3)$$

$$Q(\mathbf{x}, \mathbf{u}) = r(\mathbf{x}, \mathbf{u}) + \eta \ln b(\mathbf{u} | \mathbf{x}) + \gamma \mathbb{E}_{\mathbf{x}' \sim p_T(\cdot | \mathbf{x}, \mathbf{u})} [V(\mathbf{x}')] . \quad (4)$$

が成り立つ. ここで

$$\beta \triangleq \frac{1}{\kappa + \eta}$$

と定義している. 行動が離散の場合, 式 (3) の右辺は log-sum-exp 関数として知られる max 演算子を滑らかにしたものである. 最適方策は

$$\pi(\mathbf{u} | \mathbf{x}) = \exp[\beta(Q(\mathbf{x}, \mathbf{u}) - V(\mathbf{x}))], \quad (5)$$

と与えられる. $\eta = 0$ のとき Soft Q-learning や Soft Actor-Critic [5] が, $\kappa = 0$ のとき Dynamic Policy Programming (DPP) [1] が導出される.

3. エントロピ正則化された模倣学習

エントロピ正則化された強化学習は報酬関数 $r(\mathbf{x}, \mathbf{u})$ が与えられれば最適方策を求めることができる. 本節では報酬関数のかわりに最適方策から生成された状態行動データから最適方策を求める模倣学習を提案する.

3.1 密度比推定による逆強化学習

式 (1) において最適方策を $\pi(\mathbf{u} | \mathbf{x}) \equiv \pi^E(\mathbf{u} | \mathbf{x})$, ベースライン方策を $b(\mathbf{u} | \mathbf{x}) \equiv \pi^G(\mathbf{u} | \mathbf{x})$ とする. このとき式 (4), (5) より以下の関係式

$$\begin{aligned} \frac{1}{\beta} \ln \frac{\pi^E(\mathbf{u} | \mathbf{x})}{\pi^G(\mathbf{u} | \mathbf{x})} = & r(\mathbf{x}, \mathbf{u}) - \kappa \ln \pi^G(\mathbf{u} | \mathbf{x}) \\ & + \gamma \mathbb{E}_{\mathbf{x}' \sim p_T(\cdot | \mathbf{x}, \mathbf{u})} [V(\mathbf{x}')] - V(\mathbf{x}) \end{aligned} \quad (6)$$

を得る. さらに $\pi^E(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ を

$$\pi^E(\mathbf{x}, \mathbf{u}, \mathbf{x}') \triangleq p_T(\mathbf{x}' | \mathbf{x}, \mathbf{u}) \pi^E(\mathbf{u} | \mathbf{x}) \pi^E(\mathbf{x})$$

と提議し, $\pi^G(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ も同様に定義する. このとき式 (6) の左辺は

$$\ln \frac{\pi^E(\mathbf{u} | \mathbf{x})}{\pi^G(\mathbf{u} | \mathbf{x})} = \ln \frac{\pi^E(\mathbf{x}, \mathbf{u}, \mathbf{x}')}{\pi^G(\mathbf{x}, \mathbf{u}, \mathbf{x}')} - \ln \frac{\pi^E(\mathbf{x})}{\pi^G(\mathbf{x})} \quad (7)$$

と書き換えることができる. 式 (7) の右辺は二つの密度比の差であり, それぞれ π^E, π^G からのサンプルがあれば推定できる [10]. たとえば $\pi^E(\mathbf{u} | \mathbf{x})$ から収集された状態行動遷移を

$$\begin{aligned} D^E = & \{(\mathbf{x}_i, \mathbf{u}_i, \mathbf{x}'_i)\}_{i=1}^{N^E}, \\ \mathbf{u}_i \sim & \pi^E(\cdot | \mathbf{x}_i), \quad \mathbf{x}'_i \sim p_T(\cdot | \mathbf{x}_i, \mathbf{u}_i) \end{aligned}$$

とし, 同様に π^G からのサンプル D^G を収集する. 密度比推定問題を通して報酬や状態価値関数を推定することが逆強化学習に対応する.

密度比を推定する様々な手法が提案されている [10] が, ここではロジスティック回帰を用いる. そのために二値変数 $L \in \{0, 1\}$ を導入し, $L = 1$ のとき π^E からサンプル, $L = 0$ のとき π^G からサンプルする. すなわち

$$\pi^G(\mathbf{x}) = \Pr(\mathbf{x} | L = 0), \quad \pi^E(\mathbf{x}) = \Pr(\mathbf{x} | L = 1)$$

とする. このとき

$$\ln \frac{\pi^E(\mathbf{x})}{\pi^G(\mathbf{x})} = \ln \frac{D(\mathbf{x})}{1 - D(\mathbf{x})} - \ln \frac{\Pr(L = 1)}{\Pr(L = 0)}$$

と書き換えることができる. ここで $D(\mathbf{x})$ は状態 \mathbf{x} が π^E からのサンプルであるかどうかを識別する識別器 $D(\mathbf{x}) \triangleq \Pr(L = 1 | \mathbf{x})$ である. 同様に $\pi^E(\mathbf{x}, \mathbf{u}, \mathbf{x}')/\pi^G(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ も識別器 $D(\mathbf{x}, \mathbf{u}, \mathbf{x}') \triangleq \Pr(L = 1 | \mathbf{x}, \mathbf{u}, \mathbf{x}')$ によって記述できる. 以上より式 (6) を

$$\begin{aligned} \frac{1}{\beta} \ln \frac{D(\mathbf{x}, \mathbf{u}, \mathbf{x}')}{1 - D(\mathbf{x}, \mathbf{u}, \mathbf{x}')} = & \frac{1}{\beta} \ln \frac{D(\mathbf{x})}{1 - D(\mathbf{x})} \\ & + r(\mathbf{x}, \mathbf{u}) - \kappa \ln \pi^G(\mathbf{u} | \mathbf{x}) + \gamma V(\mathbf{x}') - V(\mathbf{x}) \end{aligned} \quad (8)$$

と書き換える. 対数密度比 $\ln D(\mathbf{x})/(1 - D(\mathbf{x}))$ を $g(\mathbf{x})$ とおく. このとき識別器 $D(\mathbf{x})$ は

$$D(\mathbf{x}) = \frac{1}{1 + \exp(-g(\mathbf{x}))}$$

となり, 通常の二値分類問題として $g(\mathbf{x})$ を推定できる. 同様にして $D(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ を

$$D(\mathbf{x}, \mathbf{u}, \mathbf{x}') = \frac{\exp(\beta f(\mathbf{x}, \mathbf{u}, \mathbf{x}'))}{\exp(\beta f(\mathbf{x}, \mathbf{u}, \mathbf{x}')) + \exp(\beta \kappa \ln \pi^G(\mathbf{u} | \mathbf{x}))} \quad (9)$$

と構築する. ここで

$$f(\mathbf{x}, \mathbf{u}, \mathbf{x}') \triangleq r(\mathbf{x}, \mathbf{u}) + \frac{1}{\beta} g(\mathbf{x}) + \gamma V(\mathbf{x}') - V(\mathbf{x})$$

と定義している. 式 (9) の識別器は従来の逆強化学習で用いられている識別器の拡張である. たとえば $g(\mathbf{x}) = 0$ かつ $\eta = 0$

とすれば AIRL [4] の識別器が, $\kappa = 0$ とすれば LogReg-IRL [12] の識別器と一致する.

以上をまとめると逆強化学習は次の二つのステップで構成される. まず識別器 $D(\mathbf{x})$ を学習することで $g(\mathbf{x})$ を推定する. 次に識別器 $D(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ を学習して $r(\mathbf{x}, \mathbf{u})$ と $V(\mathbf{x})$ を推定する. この際 $g(\mathbf{x})$ と $\pi^G(\mathbf{u} | \mathbf{x})$ は固定する. $D(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ は対数尤度

$$J(D) = \mathbb{E}_{(\mathbf{x}, \mathbf{u}, \mathbf{x}') \sim \mathcal{D}^E} [\ln D(\mathbf{x}, \mathbf{u}, \mathbf{x}')] + \mathbb{E}_{(\mathbf{x}, \mathbf{u}, \mathbf{x}') \sim \mathcal{D}^G} [\ln (1 - D(\mathbf{x}, \mathbf{u}, \mathbf{x}'))]$$

を最大にすることで得られる. ここで $(\mathbf{x}, \mathbf{u}, \mathbf{x}') \sim \mathcal{D}$ は \mathcal{D} からのサンプルの期待値を意味する.

3.2 ベースライン方策の更新

密度比推定による逆強化学習の結果, エキスパート方策 π^E の推定値

$$\frac{1}{\beta} \ln \hat{\pi}^E(\mathbf{u} | \mathbf{x}) \approx r(\mathbf{x}, \mathbf{u}) + \eta \ln \pi^G(\mathbf{u} | \mathbf{x}) + \gamma V(\mathbf{x}') - V(\mathbf{x})$$

が得られる. これを用いて新しいベースライン方策 π_{new}^G を KL ダイバージェンス

$$J(\pi) = \mathbb{E} [\text{KL}(\pi(\cdot | \mathbf{x}) \| \hat{\pi}^E(\cdot | \mathbf{x}))] \quad (10)$$

を最小にするように求める.

ベースライン方策の更新は Soft Actor-Critic [5] で用いられるものと同一である. Soft Actor-Critic では最適方策は以下の KL ダイバージェンス

$$J(\pi) = \mathbb{E} [\text{KL}(\pi(\cdot | \mathbf{x}) \| \exp\{\beta(Q(\mathbf{x}, \cdot) - V(\mathbf{x}))\})],$$

を最小にすることで計算される. Soft Actor-Critic では報酬 $r(\mathbf{x}, \mathbf{u})$ が与えられたとき式 (3), (4) を用いて $V(\mathbf{x})$ と $Q(\mathbf{x}, \mathbf{u})$ を計算したのちに最適方策を推定するのに対し, 提案手法ではエキスパートからのデータ \mathcal{D}^E が与えられたときに密度比推定によって最適方策を推定することになる. よって式 (10) による方策改善が強化学習ステップに相当する.

ただし式 (10) による更新では \mathcal{D}^E と現在の学習方策 π^G によって生成されたデータ \mathcal{D}^G だけから推定されたエキスパート方策を用いているため, 過去の学習方策が用いたデータを利用していない. そこで逆強化学習によって推定された報酬と対数密度を固定し, 状態価値関数と状態行動価値関数を Soft Actor-Critic にしたがって更新する. 式 (5) より, 状態価値関数を更新するための目的関数は

$$J(V) = \mathbb{E}_{\mathbf{x} \sim \mathcal{D}} \left[\frac{1}{2} (V(\mathbf{x}) - \tilde{V}(\mathbf{x}))^2 \right],$$

と与えられる. ここで

$$\tilde{V}(\mathbf{x}) = \mathbb{E}_{\mathbf{u} \sim \pi^G} [Q(\mathbf{x}, \mathbf{u}) - \beta^{-1} \ln \pi^G(\cdot | \mathbf{x})]$$

である. 状態行動価値関数を学習する目的関数は

$$J(Q) = \mathbb{E}_{(\mathbf{x}, \mathbf{u}, \mathbf{x}') \sim \mathcal{D}} \left[\frac{1}{2} \left\{ Q(\mathbf{x}, \mathbf{u}) - \tilde{Q}(\mathbf{x}, \mathbf{u}, \mathbf{x}') \right\}^2 \right],$$

となる. ここで

$$\tilde{Q}(\mathbf{x}, \mathbf{u}, \mathbf{x}') = r(\mathbf{x}, \mathbf{u}) + \eta^{-1} \ln \pi^G(\mathbf{u} | \mathbf{x}) + \gamma V(\mathbf{x}')$$

とする. \mathcal{D} はエキスパートデータも含めたすべてのデータをまとめたものである.

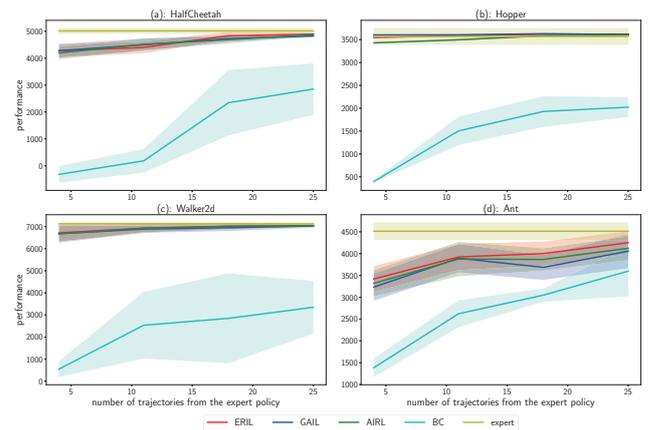


図 1: エキスパートからのデータ数についての性能比較. 横軸はエキスパート方策 π^E から与えられた軌跡の個数, 縦軸は本来の報酬のもとで評価した場合の性能を示す.

4. シミュレーション

提案手法の有効性を検証するために, OpenAI gym [2] で提供されている Half-Cheetah, Hopper, Walker, Ant という 4 種類のロボット制御課題に適用する. これらは物理エンジン MuJoCo [11] を用いている. これらのタスクの目的はできるだけ速く移動することである. まず本来設定されている報酬関数をもとに最適方策 π^E を TRPO によって学習し, そこから得られるデータを \mathcal{D}^E として用いる. 関数近似として用いるニューラルネットワークの構造は従来研究 [4, 6] を参考に構築した. 対数密度 $g(\mathbf{x})$, 報酬 $r(\mathbf{x})$, 状態価値関数 $V(\mathbf{x})$, 行動価値関数 $Q(\mathbf{x}, \mathbf{u})$ は 2 層のニューラルネットワークを用い, 活性化関数は ReLU, ユニット数はそれぞれ 400, 300 とした^{*1}. また方策 $\pi^G(\mathbf{u} | \mathbf{x})$ はガウス分布によって構成し, その平均値を同じ構成のニューラルネットワークで表現した. 初期ベースライン方策は BC によって初期化する. 1 エポックあたり学習方策 π^G によって生成される軌跡は 100 とし, 各軌跡は 50 個の状態行動遷移対を含むとする. 正則化のパラメータは $\kappa = 1, \eta = 10$ とし, 割引率は $\gamma = 0.99$ とした.

まず \mathcal{D}^E からのサンプル数を変えることで逆強化学習のデータ効率を評価する. Ho and Ermon [6] に従い, 一つの軌跡が 50 個の状態行動遷移対 $(\mathbf{x}, \mathbf{u}, \mathbf{x}')$ を含む, つまり 1 エピソードあたりのステップ数が 50 である. 逆強化学習は不良設定問題であるため, 各手法で推定された報酬は直接比較できない. そこで最終的に獲得された学習方策をシミュレータで提供される本来の報酬のもとで評価する. 図 1 に ERIL と GAIL, AIRL, BC を比較した結果を示す. ERIL, GAIL, AIRL とともに BC よりも高い制御性能を示す方策を獲得している. 一方で 3 種類の模倣学習の間にはそれほど違いは見られなかった. Fu et al. [4] は GAIL と AIRL で実質的な差はなかったことを報告しており, 本報告の結果と一致する. また前述したように対数密度 $g(\mathbf{x})$ とメタパラメータ κ, η の値によって ERIL と AIRL の識別器は一致する. 実際にこの課題では学習方策を BC によって初期化しているため, ほとんどの状態 \mathbf{x} において $g(\mathbf{x}) \approx 0$ となっていた.

次にエキスパート方策 π^E からの軌跡の数は 25 と固定し,

*1 Fu et al. [4] が指摘したように逆強化学習では報酬を状態と行動の関数として近似した場合は表現能力の高さから過剰適合しやすい. そのため報酬関数は状態のみに依存する関数として表現した.

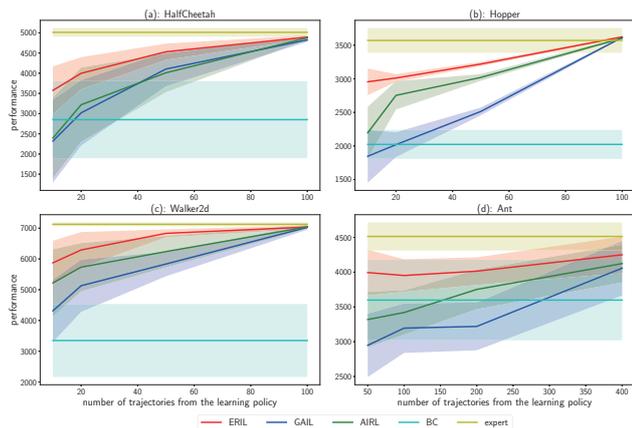


図 2: 学習方策からのデータ数についての性能比較。横軸は学習方策 π^G から各エポックで与えられた軌跡の個数、縦軸は本来の報酬のもとで評価した場合の性能を示す。

学習方策が生成する軌跡の数を変更した場合の性能を比較した。図 2 に結果を示す。軌跡の数が少ない場合、ERIL は GAIL, AIRL, BC よりも高い性能を達成する学習方策を獲得した。この理由としては ERIL は方策オフ型の強化学習を用いているのに対し、GAIL と AIRL は方策オン型である TRPO を用いているためであると考えられる。

5. おわりに

本稿ではエントロピー正則化強化学習に基づいた模倣学習 ERIL を提案した。GAN-GCL, GAIL, AIRL などの従来法と異なり、提案手法はソフトベルマン最適方程式に基づき導出されている。そのため強化学習に相当するベースラインの更新ステップは方策オフ型である。シミュレーション結果より ERIL は従来法よりもサンプル効率が良いことが示された。

ERIL には注意深く調整すべきメタパラメータがあり、強化学習の場合には式 (1) で用いている正則化のパラメータ κ, η は学習過程の安定性や関数近似誤差に影響を与えることが知られている [7]。逆強化学習時においても識別器の性能に影響を与えるが、これらのパラメータをどのように学習中に調整するかは今後の課題である。

強化学習ステップにおける ERIL と AIRL の性能差は主に Soft Actor-Critic と TRPO の違いによって説明できると考えられる。Neu et al. は DPP, TRPO など様々な強化学習アルゴリズムの性質を調査した [8] が、Soft Actor-Critic や逆強化学習を組み合わせた場合の性質ははまだ明らかではない。この研究を拡張することで ERIL と AIRL の差を考察することも今後の課題である。

謝辞 本研究の成果は、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) の委託業務および JST, 未来社会創造事業, JPMJMI18B8 の支援を受けたものである。

参考文献

[1] M. G. Azar, V. Gómez, and H. J. Kappen. Dynamic policy programming. *Journal of Machine Learning Research*, 13:3207–3245, 2012.

- [2] G. Brockman, V. Cheung, L. Pettersson, J. Schneider, J. Schulman, J. Tang, and W. Zaremba. OpenAI Gym. *arXiv preprint*, 2016.
- [3] C. Finn, P. Christiano, P. Abbeel, and S. Levine. A connection between generative adversarial networks, inverse reinforcement learning, and energy-based models. In *NIPS 2016 Workshop on Adversarial Training*, 2016.
- [4] J. Fu, K. Luo, and S. Levine. Learning robust rewards with adversarial inverse reinforcement learning. In *Proc. of the 6th International Conference on Learning Representations*, 2018.
- [5] T. Haarnoja, A. Zhou, P. Abbeel, and S. Levine. Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor. In *Proc. of the 35th International Conference on Machine Learning*, pages 1856–1865, 2018.
- [6] J. Ho and S. Ermon. Generative adversarial imitation learning. In *Advances in Neural Information Processing Systems 29*. 2016.
- [7] T. Kozuno, E. Uchibe, and K. Doya. Theoretical analysis of efficiency and robustness of softmax and gap-increasing operators in reinforcement learning. In *Proc. of the 22nd International Conference on Artificial Intelligence and Statistics*, 2019.
- [8] G. Neu, V. Gómez, and A. Jonsson. A unified view of entropy-regularized markov decision processes. *arXiv preprint*, 2017.
- [9] J. Schulman, S. Levine, P. Abbeel, M. Jordan, and P. Moritz. Trust region policy optimization. In *Proc. of the 32nd International Conference on Machine Learning*, pages 1889–1897, 2015.
- [10] M. Sugiyama, T. Suzuki, and T. Kanamori. *Density ratio estimation in machine learning*. Cambridge University Press, 2012.
- [11] E. Todorov, T. Erez, and Y. Tassa. MuJoCo: A physics engine for model-based control. In *Proc. of IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 5026–5033, 2012.
- [12] E. Uchibe. Model-free deep inverse reinforcement learning by logistic regression. *Neural Processing Letters*, 47(3):891–905, 2018.

[114-J-2] Machine learning: new modeling

Chair: Masayuki Okamoto Reviewer: Satoshi Oyama

Tue. Jun 4, 2019 5:20 PM - 7:00 PM Room I (306+307 Small meeting rooms)

[114-J-2-01] Conservation-Law Estimation from Symmetric Property of Dynamical System Extracted using DNN○Yoh-ichi Mototake¹ (1. University of Tokyo)

5:20 PM - 5:40 PM

[114-J-2-02] Invariant Feature Learning by Pairwise Neural Net Distance○Yusuke Iwasawa¹, Kei Akuzawa¹, Yutaka Matsuo¹ (1. The University of Tokyo)

5:40 PM - 6:00 PM

[114-J-2-03] Evaluation Method of Major Factors in Long-term Prediction with Exogenous VariablesYuki Nakatsuka¹, ○Susumu Shirayama¹ (1. Univ. of Tokyo)

6:00 PM - 6:20 PM

[114-J-2-04] Hierarchical Neural Topic Model for Multimodal Learning○Tatsuya Aoki¹, Masato Minamisaka¹, Takayuki Nagai^{1,2} (1. The University of Electro-Communications, 2. Osaka University)

6:20 PM - 6:40 PM

[114-J-2-05] Flexible segmentation for multi-dimensional time series data○Maya Shigeru¹, Akihiro Yamaguchi¹, Tatsuya Inagi¹, Ken Ueno¹ (1. Toshiba Corporation)

6:40 PM - 7:00 PM

DNNを用いて抽出された力学系の対称性からの保存量推定

Conservation-Law Estimation from Symmetric Property of Dynamical System Extracted using DNN

本武 陽一

Mototake Yoh-ichi

東京大学大学院新領域創成科学研究科

Graduate School of Arts and Science, The University of Tokyo

It is suggested that Deep Neural Networks (DNN), which continues to develop in recent years, has a function to extract information of data sets necessary to achieve a given task by modeling the distribution as a manifold. In addition to confirming the usefulness of DNN technology, numerous researchers and engineers are developing various DNN algorithms and tuning parameters. This situation means that enormous knowledge on the manifold structure for various data sets is being accumulated. The purpose of this research is to propose a method to extract manifold structure with complex shape extracted in an interpretable form. Specifically, we propose a method to extract the symmetry of manifold for coordinate transformation. Based on the Noether's theorem in physics, we develop the method to estimate the conservation law of the system. Applying the proposed method to the time series data of the moving object according to the central force potential, it was confirmed that symmetry according to the conservation law of angular momentum could be extracted.

1. 導入

近年発達を続ける Deep Neural Networks (以下, DNN) が, 与えられたタスクを達成するために必要なデータセットの情報を, その分布を多様体としてモデル化することで抽出する機能を持つことが示唆されている [1][2][3][4][5][6][7][8]. このような視点に立つと, DNN の写像関数は多様体を定義するものと理解される. しかしながら, この写像関数は一般に, 非常に多数のパラメータによって構成された非線形関数となるため, そこからデータセット分布の持つ情報を解釈可能な形で抽出することは困難である.

これに対して我々は, この DNN がモデル化した多様体構造についての情報を, その入力空間の連続的な変換に対する対称性として抽出する手法を提案する. これによって, 複雑な写像関数を対称性という指標でより単純に評価することが可能となる.

対称性から対象のデータセットの理解を行うためには, 対称性とデータセットの性質との間を結ぶ理論が必要となる. 物理学の分野では, この対称性と対象の性質に関する理論の構築が長年行われて来た. ネーターの定理はその代表例で, ハミルトニアンの座標変換に対する普遍性と, 系の保存量とを結びつけることが可能となる. 本研究では, 提案手法を中心力ポテンシャル系の時系列データに適用し, そこからハミルトニアンの対称性を抽出することを試みた. この結果, 角運動量に対応する対称性が抽出されることを示唆する結果が得られた.

2. 手法

2.1 DNN と多様体

多様体は, ユークリッド空間を貼り合わせることによって構成される空間である. 大まかな例としては, 地図と二次元の多様体である地球表面がある. 我々は, 地球表面を 2 次元のユークリッド空間である地図のラミネーションとして理解する. より正確には, d_m 次元微分可能多様体 M とは, 多様体上の任

意の点 x^0 で接空間 $T_{x^0}M$ と呼ばれる d 次元ユークリッド空間と同相な近傍を持つ位相空間である. 本研究では, DNN はデータセットの分布を, 多様体として近似的にモデル化すると考える. その上で, DNN はデータ多様体をそれと同じ次元のユークリッド空間に近い大域的座標系へ写像する機能を持つと考える. 本研究では, データ分布を多様体として近似した際に現れる構造をデータ多様体と呼ぶ.

微分同相写像は, d_m 次元多様体 M を d_m 次元多様体 N へ写像する微分写像関数として定義される. 逆関数定理より, 微分写像関数のうち, そのヤコビアン行列が多様体 M 上の全ての点で正則行列となるものは微分同相写像となる. つまり, ある微分写像関数のヤコビアン行列が入力空間と出力空間上の全ての点で正則行列となる場合, 入力空間と出力空間は多様体としてモデル化されているといえる. 多様体仮説で取り扱うのは, ユークリッド空間中の多様体となる. この場合, 多様体を定義する微分写像に求められる条件は, 多様体に対応する部分空間から多様体に対応する部分空間への写像に関して同相写像となることである. これは前の議論と同様に, ある微分写像が与えられた場合に, その部分空間上の全ての点に関する写像関数のヤコビアンが正則行列となることと同値となる. つまり, ある部分空間上の全ての点での写像関数のヤコビアン行列の rank が d_m となる場合, その部分空間が多様体としてモデル化されているといえる. これに基づき, 我々は DNN 写像関数がモデル化した入出力空間での多様体の接空間を以下の手続きで算出した. 今, 入力 d_{in} 次元, 出力 d_{out} 次元である, L 層 DNN を考える. この DNN の写像関数 $F(x) = (F_1(x), F_2(x), \dots, F_{d_{out}}(x))$ は,

$$\begin{aligned} F(x) &= h^L = f(w^{L-1}h^{L-1} + b^{L-1}) \\ &= f(w^{L-1}f(\dots f(w^1x + b^1)\dots) + b^{L-1}) \end{aligned} \quad (1)$$

によって与えられる. ここで, $h^l = (h_0^l, h_1^l, \dots, h_{d_l}^l)$ は, d_l

連絡先: 本武陽一, 東京大学大学院総合文化研究科,
mototake@sacral.c.u-tokyo.ac.jp

次元の第 l 層の出力とし、 $f(\cdot)$ を、

$$\mathbf{f}(\mathbf{w}^{l-1}\mathbf{h}^{l-1} + \mathbf{b}^{l-1}) = (f_1, f_2, \dots, f_{d_l})$$

$$f_j = f\left(\sum_i^{d_{l-1}} (w_{ij}^{l-1}h_i^{l-1} + b_j^{l-1})\right) \quad (2)$$

とした。 f は活性化関数と呼ばれ、良くシグモイド関数や LeRU 関数等が用いられる。従って、ある入力 \mathbf{p} が与えられた場合の DNN 写像関数のヤコビアン行列 \mathbf{J} は、

$$J_{ij}^{\text{DNN}} = \frac{\partial F_j(\mathbf{x})}{\partial x_i}$$

$$= \sum_{\langle k_{l-1}, k_{l-2}, \dots, k_1 \rangle} \frac{\partial h_j^l}{\partial h_{k_{l-1}}^{l-1}} \frac{\partial h_{k_{l-1}}^{l-1}}{\partial h_{k_{l-2}}^{l-2}} \dots \frac{\partial h_{k_1}^1}{\partial x_i} \quad (3)$$

で与えられる。また、各層間の写像関数のヤコビアンを

$$\mathbf{J}^l = \begin{pmatrix} \frac{\partial h_1^l}{\partial h_1^{l-1}} & \dots & \frac{\partial h_1^l}{\partial h_{d_{l-1}}^{l-1}} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_{d_l}^l}{\partial h_1^{l-1}} & \dots & \frac{\partial h_{d_l}^l}{\partial h_{d_{l-1}}^{l-1}} \end{pmatrix} \quad (4)$$

とした場合に、全体のヤコビアンは

$$\mathbf{J}^{\text{DNN}} = \mathbf{J}^L \mathbf{J}^{L-1} \dots \mathbf{J}^1 \quad (5)$$

で与えられる。例えば活性化関数 f としてシグモイド関数を用いた場合、

$$\mathbf{J}^l = \begin{pmatrix} h_1^{l-1}(1-h_1^l) & \dots & h_{d_{l-1}}^{l-1}(1-h_1^l) \\ \vdots & \ddots & \vdots \\ h_1^{l-1}(1-h_{d_l}^l) & \dots & h_{d_{l-1}}^{l-1}(1-h_{d_l}^l) \end{pmatrix} \quad (6)$$

となる。このように写像関数から定義された多様体上のある点 \mathbf{p} での局所近傍座標系である接空間 $T_p M$ は、点 \mathbf{p} 周りでのヤコビアン行列 \mathbf{J} の縮退していない基底空間であるユークリッド空間として与えられる。

この描像は、DNN がシグモイド関数のほぼ線形な部分をつなぎ合わせた曲がった空間上で主成分分析のようなことを行う

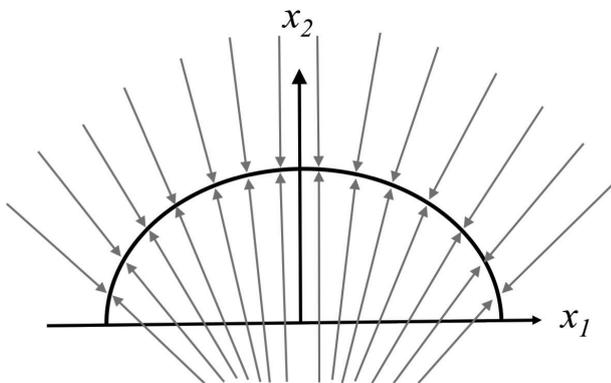


図 1: DNN におけるデータ分布の多様体への引き込みメカニズムの模式図

ものとして理解される。その際圧縮される方向は、多様体から遠く離れた点まで及ぶことに注意されたい (図 2)。また、シグモイド関数の線形部分が有限であることから、多様体から離れるほど、圧縮領域の隙間となる空間が拡大する。このような空間は、シグモイド関数の性質から、0 あるいは 1 に吸引されていくと考えられる。

2.2 DNN のモデル化した多様体からの対称性抽出手法

前節の議論より、入力空間で多様体上にないデータ点は、多様体上に吸引されるとわかる。入力空間から見た中間層でのデータ点の移動は図 2 のような模式図に従うと考えられる。中間層において一度多様体上に吸引されたデータ点は、それよりも後の層において多様体上のデータと分離されることはない。したがって、出力層 $\mathbf{F}(\mathbf{x})$ において、全てのデータは多様体上、あるいは空間の角となる 0 と 1 の組み合わせで与えられる座標点に縮退する。

これをふまえると、あるデータ多様体を学習した DNN に対して、新たに与えられたデータセット $\{\mathbf{x}_i\}_{i=1}^N$ がそのデータ多様体上にあるかは、それが出力空間に写像された際のデータ集合 $\{\mathbf{F}(\mathbf{x}_i)\}_{i=1}^N$ との間の二乗誤差

$$E(\{\mathbf{x}_i\}_{i=1}^N; \mathbf{F}(\mathbf{x})) = \sum_{i=1}^N [\mathbf{x}_i - \mathbf{F}(\mathbf{x}_i)]^2 \quad (7)$$

によって評価されるとわかる (図 2)。

なぜならば、入力空間で多様体から離れたデータほど、出力空間で多様体上に落ち込むまでに移動した距離が遠く、結果として二乗誤差が大きくなるためである。

今知りたいのは、DNN の訓練時に用いたデータ多様体分布がどのような座標変換 \mathbf{A} に対して普遍となるかということである。先ほど議論した多様体からの距離を測る指標 $E(\{\mathbf{x}_i\}_{i=1}^N; \mathbf{F}(\mathbf{x}))$ を用いると、データ多様体の分布構造を変えない座標変換は、

$$E(\{\mathbf{A}\mathbf{x}_i\}_{i=1}^N; \mathbf{F}(\mathbf{A}\mathbf{x})) = \sum_{i=1}^N [\mathbf{A}\mathbf{x}_i - \mathbf{F}(\mathbf{A}\mathbf{x}_i)]^2 \quad (8)$$

が小さな値となる \mathbf{A} を集めてくれば良いとわかる。

具体的には、行列 \mathbf{A} の $d_{in} \times d_{in}$ 個ある要素 a_{jk} についてサンプリングを行うことで、 $E(\{\mathbf{A}\mathbf{x}_i\}_{i=1}^N; \mathbf{F}(\mathbf{A}\mathbf{x}))$ がある閾値以下となる \mathbf{A} の集合が得られる。

2.3 ネーターの定理

系の対称性と保存量との関係について、ネーターによって証明された定理である [9]。ここで、 d 次元一般化座標を、 $\mathbf{q}(t)$ と $\mathbf{p}(t)$ とし、系のハミルトニアンを $H(\mathbf{q}, \mathbf{p}; t)$ とする。今、ハミルトニアン $H(\mathbf{q}, \mathbf{p}; t)$ が、ある微小な座標変換

$$t' = t + \delta t$$

$$q'_j = q_j + \delta q_j \quad (9)$$

(ただし、 $j=1 \sim d$) に対して普遍であるとする。すると、ネーターの定理より微小変換の生成子 G_δ が時間によらず普遍な量となる。つまり、保存量となる。ここで微小変換の生成子 G_δ は、

$$(\delta q_j, \delta p_j) = \left(\frac{\partial G_\delta}{\partial q_j}, \frac{\partial G_\delta}{\partial p_j} \right) \quad (10)$$

を満たすものとして定義される。

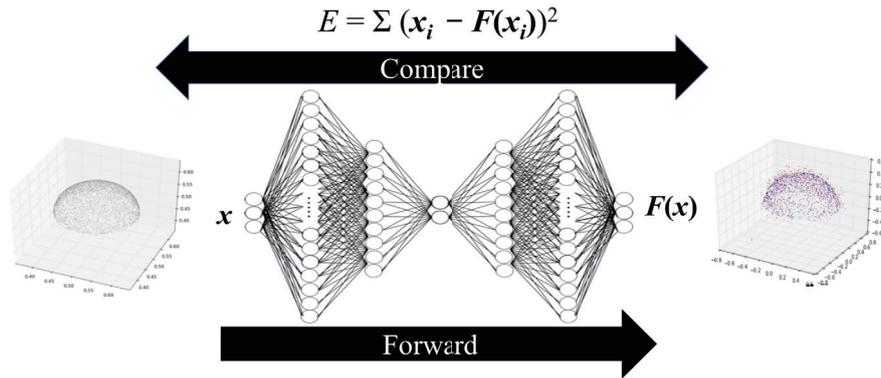


図 2: 対称性の抽出. 多様体上からの距離を, 入力データと出力データの 2 乗誤差から定量化.

2.4 時系列データの対称性とネーターの定理

次に, ネーターの定理を適用するために必要なハミルトニアン $H(q, p; t)$ の微小変換に対する普遍性を, 位相空間での時系列データ $\{\mathbf{q}^i(t), \mathbf{p}^i\}_{i=1}^N$ から得る方法について述べる. ハミルトニアン力学系において, 力学系の時間発展方程式は, \mathbf{q}, \mathbf{p} についての一階微分方程式となる. このことから, 一つの仮定を設定した. それは, 「与えられたハミルトニアン $H(q, p; t)$ の元である一定エネルギー E で運動を行う系が, $4d$ 次元空間 $(\mathbf{q}(t), \mathbf{p}(t), \mathbf{q}(t+1), \mathbf{p}(t+1))$ に取り得る全ての状態を持つ等エネルギー面 (多様体 M_E) の持つ対称性が, ハミルトニアンの対称性と関係する。」というものである. これはすなわち, あらゆる初期値から生成した同じエネルギーを持つ運動の時系列データの持つ多様体の対称性を抽出すれば, 保存量の候補が得られるという仮定となっている. この仮定によって得られた結果の妥当性は, 最終的に得られた保存量が時間普遍であることを確認することで容易に確認される. この M_E が持つ対称性を 2.2 節の方法で推定することで, 保存量推定を行うのが本提案手法の枠組みである.

2.5 変換の生成子

最後に, 2.2 節の方法で得られるハミルトニアン普遍な大域変換 \mathbf{A} から, 微小変換の生成子 G_δ を取り出す方法を, 3 次元回転の行列と $\text{SO}(3)$ の生成子を例にとって説明する.

Z 軸まわりの回転行列を書き下すと,

$$A_z = \begin{pmatrix} \cos(\theta_z) & \sin(\theta_z) & 0 \\ -\sin(\theta_z) & \cos(\theta_z) & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (11)$$

となる. 今, この回転角 θ_z が, 非常に小さい ($= \delta\theta_z$) として, この行列を θ_z についてテーラー展開し, 一次の項までをとると,

$$A_z \sim \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} + \begin{pmatrix} 0 & -\delta\theta_z & 0 \\ \delta\theta_z & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad (12)$$

となる. この右辺第二項が Z 軸周りでの回転の生成子となる. 他の軸についても同様に生成子が得られる.

実際にサンプリングして得られる \mathbf{A}_z においては, 隠れ変数である θ_z による変換行列のパラメタライズはできないため.

要素 a_{ij} の間の関係の回帰や, それらの分布の分析などから,

$$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (13)$$

周りでの微小変動の方向を見積もることで, 回転の生成子を得た.

3. 結果と考察

物理学データへの手法の適用を行う. 具体的に適用するのは, 以下のハミルトニアン

$$H(\mathbf{x}, \mathbf{p}) = \frac{\mathbf{p}^2}{2m} - \frac{k}{r} \quad (14)$$

に従う 2 次元空間中の中心力運動である. 実験では, $k = 10, m = 1$ とし, さらに, 運動を円運動に限定した上で, 系の取りうる全ての状態によってトレーニングデータを生成した.

サンプリング対象となる変換行列は, 配位空間 $\mathbf{x} = (x_1, x_2)$ を,

$$\begin{pmatrix} x'_1 \\ x'_2 \end{pmatrix} = \mathbf{A} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \quad (15)$$

と変換する. この時, 運動量空間 $\mathbf{p} = (p_1, p_2)$ は,

$$\begin{pmatrix} p'_1 \\ p'_2 \end{pmatrix} = \begin{pmatrix} m\dot{x}'_1 \\ m\dot{x}'_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \end{pmatrix} \begin{pmatrix} m\dot{x}_1 \\ m\dot{x}_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \end{pmatrix} \begin{pmatrix} p_1 \\ p_2 \end{pmatrix} \quad (16)$$

と変換される. したがって, この 4 つの変換行列の要素についてサンプリングを行う. ちなみに今回は, 時間変換に対する対称性は, 明らかであるので検討対象としなかった. ちなみに, 時間方向の対称性は, エネルギー保存則を導く.

ここではメトロポリスサンプリングを用いた. メトロポリスサンプリングでは, 全てのパラメータについて step 数は 0.2 と設定され, 分散 0.2 のガウスノイズを仮定した. その上で, 1,000step の burn in の後に 9,000step のサンプリングを実行した. この結果, 図 3 のような結果が得られた.

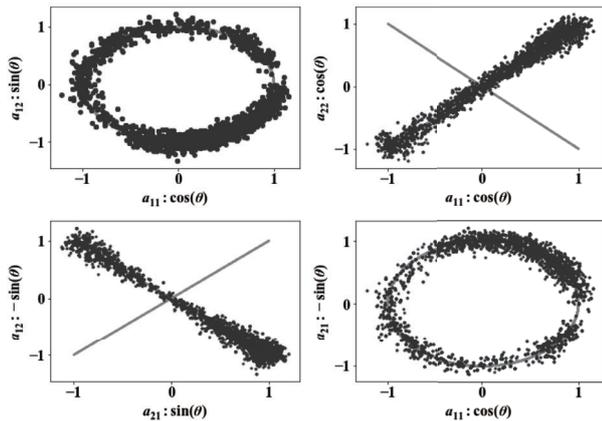


図 3: 中心力ポテンシャル中を運動する物体の時系列データセットに対して、提案手法によって得られたデータ多様体の分布を変えない対称性変換 \mathbf{A} の要素 a_{jk} の比較。 \mathbf{A} が回転行列となっている場合に得られるであろう分布構造を黒線で表した。ただし、 $a_{11}-a_{22}$ と $a_{12}-a_{21}$ の図における直線の片方は、鏡像変換の従う分布構造についてもプロットした図となっている。

得られた結果より、変換の生成子を推定する。今回得られた結果の図から変換が単位行列となる $a_{11} = a_{22} = 1$ 周りの微小変動を考察すると、 $a_{11}-a_{12}$ と $a_{11}-a_{21}$ の関係 (図 3) より、生成子の a_{11}, a_{22} 成分が 0 となり、 a_{12} と a_{21} 成分が $\pm\delta\theta_y$ 方向を持つとわかる。さらに、 $a_{21}-a_{12}$ の関係より、生成子の a_{11}, a_{22} 成分の符号が逆であることがわかる。以上より、得られた変換の生成子は、

$$\begin{pmatrix} 0 & -\delta\theta_y \\ \delta\theta_y & 0 \end{pmatrix} \quad (17)$$

となる。これはちょうど $SO(2)$ の対称性の生成子となっており、これより、角運動量が保存することがわかる。

以上のように、提案手法によって力学系の時系列データから、そのハミルトニアンに関する情報を抽出し、保存則が推定されることが確認された。

4. まとめと今後の展望

データ多様体をモデル化した DNN から、その多様体の持つ対称性に関する情報を抽出する手法を構築した。そしてその応用として、中心力ポテンシャル中を運動する力学系の時系列データの作るデータ多様体に提案手法を適用した。その結果、力学系が持つ対称性の抽出と、ネーターの定理を介した保存量の推定を実現した。

本提案手法は、さらに複雑な対称性を持つ系への適用も可能であると考えられる。具体的には、中心力ポテンシャル中の力学系が持つ配位空間とは違う空間における隠れた対称性である、 $SO(4)$ の抽出と、対応する保存量であるルンゲ-レンツベクトルの推定等の実現が期待される。

近年の DNN 技術の有用性の確認とともに、多数の研究者・技術者が各種の DNN アルゴリズムの開発やパラメータチューニングを行なっている。この状況は、各種データセットに対する多様体構造についての莫大な知見が蓄積されつつあることを意味する。本提案手法は、このような蓄積された莫大な知見を解析するための手法開発に繋がっていくことが期待される。

参考文献

- [1] Irie Bunpei and Kawato Mitsuo. Acquisition of internal representation by multi-layered perceptrons. *The Transactions of the Institute of Electronics, Information and Communication Engineers D*, Vol. 73, No. 8, pp. 1173–1178, 1990.
- [2] GE Hinton and RR Salakhutdinov. Reducing the dimensionality of data with neural networks. *Science*, 2006.
- [3] Pratik Prabhanjan Brahma, Dapeng Wu, and Yiyuan She. Why deep learning works: A manifold disentanglement perspective. *IEEE transactions on neural networks and learning systems*, Vol. 27, No. 10, pp. 1997–2008, 2016.
- [4] Ronen Basri and David Jacobs. Efficient representation of low-dimensional manifolds using deep networks. *arXiv preprint arXiv:1602.04723*, 2016.
- [5] Salah Rifai, Yann N Dauphin, Pascal Vincent, Yoshua Bengio, and Xavier Muller. The manifold tangent classifier. pp. 2294–2302, 2011.
- [6] 本武陽一, 池上高志. Deep neural networks の力学的・幾何学的解析. 人工知能学会全国大会論文集, Vol. JSAI2016, pp. 1A5OS27c1–1A5OS27c1, 2016.
- [7] Yhoichi Mototake and Takashi Ikegami. The dynamics of deep neural networks. *Proceedings of the Twentieth International Symposium on Artificial Life and Robotics*, Vol. 20, , 2015.
- [8] Y. Mototake. Geometrical structures embedded in high dimensional data sets and deep learning : Analysis and application to dynamical systems. 2016.
- [9] AE Noether. Nachr kgl ges wiss göttingen. *Math. Phys. KI II*, Vol. 235, , 1918.

ペアワイズニューラルネット距離による不変表現学習

Invariant Feature Learning by Pairwise Neural Net Distance

岩澤 有祐^{*1} 阿久澤 圭^{*1} 松尾 豊^{*1}
 Yusuke Iwasawa Kei Akuzawa Yutaka Matsuo

^{*1}東京大学工学系研究科
 The University of Tokyo

How to learn representations invariant to nuisance attribute is a universal problem among machine learning applications. This paper holds the following three contributions to this problem. First, we empirically show that adversarial training using categorical attribute classifier, which is one of the state-of-the-art approaches and called adversarial feature learning (AFL), is suffered from practical issues that significantly slow down the convergence. Second, we reformulate the optimization problem of AFL as pair-wise distribution matching and derive a new approach for learning invariant representations. Finally, we introduce parameter sharing techniques to reduce the computation difficulty of our strategy. Empirical results show the superior performance of our proposed method on both toy dataset and well-used domain generalization tasks.

1. はじめに

観測 x を観測と関連する何らかの属性 a に不変な表現 z に変換する技術は不変表現学習と呼ばれ、ドメイン汎化や公平性配慮の文脈で利用されている [Xie 17]. 本稿では、特にカテゴリカル変数 a に対して不変な表現学習を実現する新たな手法としてニューラルネット距離を利用した手法 (ペアワイズニューラルネット距離, *Pairwise Neural Net Distance*) を提案する (図 1-b, c). ニューラルネット距離とは

$$d_{\phi, \mathcal{F}_{nn}}(P, Q) = \sup_{D \in \mathcal{F}_{nn}} \left[\mathbb{E}_{x \sim P} [\phi(D(x))] + \mathbb{E}_{x \sim Q} [\phi(1 - D(x))] \right] \quad (1)$$

というような形で2つの分布 P と Q の距離を近似的に計測する方法である。目撃関数 ϕ の選び方により、Wasserstein 距離や Jensen Shannon Divergence など様々なよく知られた分布間距離を近似することができ、特に画像生成の領域でよく利用されている。

本稿ではまず、カテゴリカル変数 A に対して不変な表現 Z を学習する問題が属性 i に対応した観測 x の特徴空間上での分布 $P^i(Z)$ を他の属性すべての特徴空間上での分布 $P^j(Z)$ に近づける、ペアワイズな分布間距離の最小化問題として定式化できることを示す。この定式化により、GAN と同様様々な分布間距離尺度が利用できるという利点がある。次に、ペアワイズな分布間距離を最小化の素朴な実装では属性の数に対して計算量が指数関数的に爆発するという問題に対して、パラメータ共有を利用することでこの問題を回避できることを示す (図 1-c)。実験では、ペアワイズニューラルネット距離の具体例として近年 GAN でよく利用されている Wasserstein 距離を利用した Pairwise Wasserstein Distance (PWD) を提案し、PWD を用いた不変特徴学習とカテゴリカル分類器による敵対的学習を利用した不変表現学習の既存手法である Adversarial Feature Learning (AFL) と比較し、(1) 提案法が既存手法と比較して少ない更新回数でより不変性の高い表現を実現できること、(2) 不変表現学習の代表的な応用事例であるドメイン汎化においてより優れた性能を達成することを示す。

2. 前提知識

2.1 記法・問題設定

X, Y, A をそれぞれ観測 x , 目標 y , 観測と関連するカテゴリカルな属性 a に対応した確率変数であるとする。不変表現学習は、データセット $\mathcal{S} = \{(x_i, y_i, a_i)\}_{i=1}^n$ が与えられたもとで次の損失関数を最小化刷るようなエンコーダ E を求める問題として定式化される。

$$\mathcal{J} = \mathbb{E}_{x, y, a \in \mathcal{S}} [-L(E(x), y) + \lambda V(E(x), a)]. \quad (2)$$

ただし、 E は観測 x を何らかの特徴量 z に変換する関数であり、 $L(E(x), y)$ は特徴量 z が持つ y の情報量、 $V(E(x), a)$ は特徴量 Z と属性 A が独立であること (すなわち不変であること) を要請する何らかの指標である。理想的な指標としては、 Z と A の条件付きエントロピーが考えられる。ここで条件付きエントロピーは、 $H(A|Z) = \sum_{a \in \mathcal{A}, z \in \mathcal{Z}} -p(a, z) \log p(a|z)$ で与えられる確率変数 Z が持つ A に関する情報量の尺度である (ただし、 \mathcal{A} および \mathcal{Z} はそれぞれの確率変数の実現値の集合)。条件付きエントロピーは確率変数が独立であるときのみ最大になるという性質があるため、条件付きエントロピーを最大化するようなエンコーダ E を学習することで A に対して不変な表現が得られる。しかし一般に条件付きエントロピーは計算不可能であり、別の方法で独立性を計測する必要がある。

2.2 Adversarial Feature Learning

V を計測する方法として、近年提案された敵対的特徴学習 (*adversarial feature learning; AFL*) がある [Iwasawa 17, Xie 17]. 敵対的特徴学習では、現在の特徴表現 z が望ましくない因子 a についてどの程度の情報を持っているかを、カテゴリカル分類器 D による z から a の分類しやすさとして定量化し、分類器 D が予想しにくくなる (敵対的な) 方向に特徴表現 z を修正する (図 1-a)。より形式的には、次の最適化問題として定式化される。

$$\min_{E, M} \max_D \mathbb{E}[-\log q_M(y|z = E(x)) + \lambda \log q_D(a|z = E(x))]. \quad (3)$$

連絡先: 岩澤有祐, 東京大学工学系研究科技術経営戦略学専攻,
 iwasawa@weblab.t.u-tokyo.ac.jp

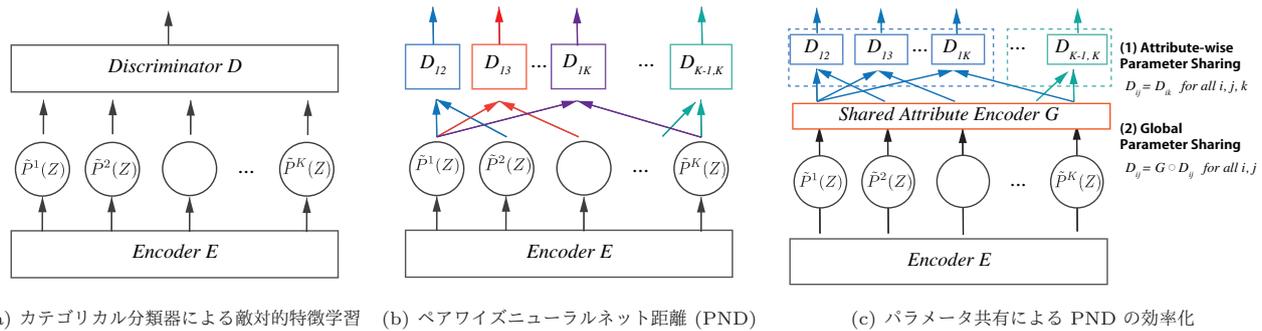


図 1: 効率的なペアワイズニューラルネットワーク距離による不変表現学習. (a) カテゴリカル分類器に基づく敵対的特徴学習の概要図. (b) ペアワイズニューラルネットワーク距離の概要図. すべての分布のペアに対する識別器 $D_{i,j}$ を利用して, ニューラルネットワーク距離の推定と最小化を行う. (c) パラメータ共有による PND の効率的な実装方法. 属性ごとに識別器を共有する Attribute-wise Parameter Sharing とすべての識別器で埋め込みを共有する Global Parameter Sharing によりパラメータ数の爆発を抑える.

ただし, q_M および q_D はそれぞれ関数 M と D でパラメータ化された条件付き分布であり, λ は制約の強さを制御するハイパーパラメータである. (1) E を固定した上で D の更新 (式 3 の第 2 項の最大化), (2) D を固定した上で式 3 全体の最小化, の 2 つのステップを交互に繰り返すことにより AFL では z が持つラベル y に関する情報量の最大化と a に関する情報量の最小化を同時に行う.

敵対的特徴学習の利点の 1 つは, 式 3 の第 2 項の最小化が条件付きエントロピーの最大化として解釈できる点である. 例えば, D が十分なキャパシティがありかつ十分に訓練されている場合, $q_D(a|z)$ は真の条件付き分布 $p(a|z)$ と一致し, 第 2 項目を最小化するように E を更新することは条件付きエントロピーを最大化することと対応する. また, 上記の min-max ゲームは条件付きエントロピーを最大化するような均衡点を持つことが Xie らによって示されている [Xie 17].

このように敵対的特徴学習は, 条件付きエントロピーの最大化という不変性を高める上で妥当な解釈が可能であり, またドメイン汎化や公平性配慮機械学習の文脈で特徴量空間での l_2 距離や Maximum Mean Discrepancy といった統計的な尺度を利用した手法群 [Zemel 13, Louizos 16, Xie 17] と比較して有効性が報告されている. しかし, Xie らの理論的な考察は全ステップで識別器を正しい条件付きエントロピーを近似するまで学習できることを前提にしており, 実際的な挙動とは乖離がある. 本稿では, 図 x に示すような単純なデータセットを利用して, (1) カテゴリカル分類器に基づく手法が実際的には不安定な挙動を示すこと, (2) この問題は条件付きエントロピーの最大化問題をペアワイズな分布間距離の最小化問題と考えることで解消できること, を実験的に示す.

3. 提案手法

本章ではまず提案手法であるペアワイズニューラルネットワーク距離について説明したのち, 提案法が AFL と同様の条件付きエントロピーの最大化問題として解釈できることを示す. 次に, 素朴なペアワイズニューラルネットワーク距離の計算はパラメータ爆発を引き起こす問題を指摘し, 効率的に計算するためにパラメータ共有を行う方法について述べる.

3.1 ペアワイズニューラルネットワーク距離

属性 i に対応したサンプルの特徴空間上での経験分布を $\tilde{P}_E^i(Z)$ と記述する. ここで E は観測を特徴空間に写像するエンコーダであり, 特徴空間の分布がエンコーダに依存してい

ることを明示的に表している. 提案手法では次のペアワイズニューラルネットワーク距離を最小化するように E を更新する.

$$\frac{1}{K^2 C_2} \sum_{i \neq j \in \mathcal{A}} d_{\phi, \mathcal{F}_{nn}}(\tilde{P}_E^i(Z), \tilde{P}_E^j(Z)). \quad (4)$$

ここで, $d_{\phi, \mathcal{F}_{nn}}$ は何らかのニューラルネットワーク距離 (式 1 参照) である.

提案手法は, AFL と同様に条件付きエントロピーを最大化していることとみなすことができる. より形式的には, $P(A)$ が離散一様分布であるとすると, 次の定理が成り立つ.

定理 1. 条件付きエントロピー $H(A|Z = E(x))$ はすべての $z \in \mathcal{Z}$ および属性のペア i, j について $P_E^i(Z) = P_E^j(Z)$ が成立するときのみ最大値をとり, またその条件付きエントロピーは $-\log \frac{1}{K}$ である.

Proof. ラグランジュの未定乗数法より,

$$L = - \sum_{a \in \mathcal{A}} p(a, z) \log p(a|z) + \lambda(1 - \sum_{a \in \mathcal{A}} p(a|z)) \quad (5)$$

の偏微分は条件付きエントロピーが最大になるときにゼロである. 連立方程式を解くと, すべての $z \in \mathcal{Z}$ について $p(a=1|z) = p(a=2|z) = \dots = p(a=K|z) = \frac{1}{K}$ が成り立つときに条件付きエントロピーは最大になり, このときの条件付きエントロピーは $-\log \frac{1}{K}$ であることが得られる. また, ベイズの法則より

$$p(z|a=i)p(a=i) = p(z|a=j)p(a=j) \quad (6)$$

がすべての $z \in \mathcal{Z}$ および属性のペア $i, j \in \mathcal{A}$ について成立する (ただし, $P(A)$ が離散一様分布という仮定を用いた). \square

この定理が意味するところは, 提案法が AFL と同様に理論的に条件付きエントロピーの最大化という理論的に妥当な解釈が可能であるということである. そのため, 理論的には AFL と提案法は同様に不変な表現を学習できる. もう 1 つの示唆は, 条件付きエントロピーは最大値がバウンドされている一方で, AFL が最適化している式 3 における第 2 項目は上限がバウンドされていないということである. このことは, AFL の最適化によって得られる近似条件付きエントロピーが実際より条件付きエントロピーを過大評価 (すなわち, 独立性を高く評価する) 傾向にあることを示唆している. 本稿では, バウンド

されていない負の対数尤度を直接最大化すると条件付きエントロピーを過大評価すること、またそのような現象が発生する場合に AFL は不安定な挙動を示すことを実験的に検証する。

AFL と比較した提案法の利点は、より優れた性質を持つさまざまな分布間距離を利用することができる点である。たとえば、AFL と同様に敵対的訓練を利用した研究の代表的な例である敵対的生成ネットワーク (generative adversarial networks, GAN) の領域では、Jensen Shannon Divergence として解釈される元論文での定式化は勾配消失を引き起こしたり、あるいは均衡点の付近で勾配がゼロにならない (すなわち安定しない) ことが知られている。この問題の解決策として、 $\phi(t) = t$ で関数の集合 \mathcal{F}_{nn} が 1 -Lipschitz 制約を満たす場合に対応する Wasserstein 距離を最小化する方法が広く利用されている。

$$d_{\mathcal{F}_{nn}}(P, Q) = \sup_{D \in \mathcal{F}_{nn}} |\mathbb{E}_{x \sim P}[D(x)] - \mathbb{E}_{x \sim Q}[D(x)]|. \quad (7)$$

本稿では特に、式 7 をニューラルネットワーク距離として利用した場合 (以降 Pairwise Wasserstein Distance, PWD と記す)、を実験で利用し、その有効性を評価する。

3.2 パラメータ共有による効率的なモデル化

提案法を素朴に実装した場合の問題点は、膨大なパラメータと計算量が必要になる点である。例えば、識別器として中間層のユニット数が M 、特徴量の次元が N 、属性 a が K 個の実現値を持つとする。この場合、式 4 を素朴に最適化しようとするすべての分布間のペアについて最適な識別器 $D_{i,j}$ を学習して最小化する必要があるため、 $(N+1) \times M \times \frac{K \times (K-1)}{2}$ 個の重みパラメータが必要になる^{*1}。これは、カテゴリカル分類器を用いた場合のパラメータが $(N+K) \times M$ であるのと比較すると大きな差である。例えば、属性 a の実現値が 5 個の場合でも、その差は 10 倍になる。ドメイン汎化において、例えばユーザを属性とみなす場合はその属性の数が 10 を越えることも珍しくなく、その場合は単に学習が難しくなるだけでなくメモリ制約により学習が行えない可能性もある。

この問題に対応する最も単純な方法として、分布間距離を測る $D_{i,j}$ 分布のペアごとにすべてに独立したパラメータを用意するのではなく何らかのパラメータ共有を行う方法が考えられる。本稿では、次の 2 つのパラメータ共有を利用する (図 1-c を参照)。(1) *Attribute-wise parameter sharing*: 属性 i と属性 j に対応する 2 つの分布の識別器 $D_{i,j}$ はすべての j について共有 (すなわち $D_{i,j} = D_{i,k \neq j} = D_i$) である。このパラメータ共有は、ある分布 i について、その他のすべての分布との距離を最大化するような関数 D_i が存在することを仮定している。(2) *Global parameter sharing*: すべての識別器 $D_{i,j}$ はすべての i, j に共有な属性エンコーダ G と i, j に固有の識別器 $H_{i,j}$ によって、 $D_{i,j} = G \circ H_{i,j}$ と分解できる。このパラメータ共有は、すべてのドメインのペアにおいてドメインを識別するような特徴は共通であることを仮定している。

この 2 つのパラメータ共有を組み合わせた場合の特殊な例として、属性ごとの識別器 H_i を線形であると仮定した場合、パラメータ数は既存の AFL と全く同じになる。より具体的には、出力層に活性化関数を用いない D (AFL ではクラス分類を使うため Softmax 関数を出力層に使う) を使って、(1) 各属性 i ごとに予測ベクトル $\mathbb{E}_{z \sim \hat{P}_E^i(z)}[\hat{a}^i = D(z)]$ を得る、(2) すべての \hat{a}^i を結合した行列 $B = [\hat{a}^1 \dots \hat{a}^K]$ を得る、(3) B のすべての非対角成分 $B_{i,j}$ について、対角成分 $B_{i,i}$ との差の絶対値を計算する (これが $P_E^i(Z)$ と $P_E^j(Z)$ について式 7 を計算

していることと同値になる。)、(4) すべての i, j について (3) の結果の平均を取る、というステップで式 4 を効率的に計算することができる。本稿では、以降この計算方法を利用する。

4. 実験・考察

4.1 実験設定

検証には (1) 本稿で新たに導入したトイデータセット、(2) 回転 MNIST (Rotation MNIST, MNISTR) [Ghifary 15]、(3) PACS [Ghifary 15] の 3 つのデータセットを利用した。トイデータセットは、図 2-a に示されるような平均が異なる 2 次元の 3 つのガウス分布により構成されたデータセットである。より具体的には、各属性 i は $[\sin(\frac{i}{3}\pi), \cos(\frac{i}{3}\pi)]$ を平均値ガウス分布から各属性ごとに 1000 サンプルずつサンプルした。この場合、各分布の平均が 0 になるように分布を動かすことができれば最大不変性を達成できることになるような単純なデータセットであるが、AFL ではこのような単純なデータセットでも不安定な挙動を起こすことを示す。トイデータセットを用いた実験では識別器 D の更新およびエンコーダ E の更新に学習率 0.1 とした SGD を利用した。

MNISTR は、[Ghifary 15] らによって導入されたドメイン汎化でよく利用されるデータセットである。具体的には、MNIST データセットから各クラス 1000 枚ずつランダムにサンプルしたものを 0 度から 75 度まで 15 度刻みに傾けたサブセットを 6 つにより構成される。MNISTR における目標はテストに利用されるサブセット以外の 5 つのサブセットから回転角度に不変な表現を学習し、未知の回転角度におけるデータセットで良い性能を発揮することである。本稿では慣例に習い、各回転角度に対応するサブセットを $M0$ といったように表記する。また、学習はバッチサイズを 128 とした最大 10k 更新を行った。学習アルゴリズムとしては学習率を 0.001 とした Adam を利用した。ネットワーク構造は [Ghifary 15] を参考に、 5×5 のフィルタを持つ畳み込みを 2 回繰り返したあと (それぞれ 32 フィルタと 48 フィルタ) 最大プーリングを行い、ユニットサイズ 100 の全結合層を 2 回繰り返す構造を利用した。PACS は [Li 17] によって導入された MNISTR と並んでドメイン汎化の検証によく利用されるデータセットである。PACS はそれぞれ 4 つの画像ドメインである Photo, Art, Cartoon, Sketch の頭文字をとったものである。[Li 17] の研究に習い、AlexNet CNN を再学習する形で学習を行い、またバッチサイズは 64 とした最大 5k 回の更新を学習率を 0.0005 とした Adam を利用して行った。

MNISTR と PACS に共通する項目として、識別器はユニットサイズ 800 の中間層を持つ MLP を利用した。また、学習はそれぞれ検証データにおけるクラス分類の損失が最小になる点の値を採用した。ハイパーパラメータ λ については MNISTR については $\{0.01, 0.1, 1.0, 2.0\}$ 、PACS については $\{0.001, 0.01, 0.1, 1.0\}$ から検証データにおける正解率が最大になるパラメータを選択した。また、MNISTR については 5 回、PACS については 3 回シードを変えた実験を行い、未知ドメインのデータに対する平均正解率および標準誤差を比較した。提案手法である PWD では、識別器 D が 1 -Lipschitz 制約を満たす必要がある。 1 -Lipschitz 制約を満たす方法はいくつかあるが、本稿では Spectral Normalization (SN) [Miyato 18] を利用した。また、比較を公平にするために、AFL を利用する場合に SN を利用する場合としない場合の双方 (SN を利用しない場合を AFL、する場合を SN と表記) を検証した。

*1 ただし、バイアス項は単純化のため計算していない

表 1: ドメイン汎化性能の比較.

(a) MNISTR				(b) PACS			
	DAN	SN	PWD		DAN	SN	PWD
M0	83.6± 0.4	87.7± 0.9	89.6± 0.6	art	53.2± 2.7	56.5± 2.0	60.4± 2.0
M15	98.4± 0.6	98.6± 0.2	98.7± 0.1	cartoon	60.2± 3.2	61.4± 1.8	65.2± 1.1
M30	97.3± 0.4	97.1± 0.3	98.2± 0.6	photo	82.5± 1.3	81.5± 1.0	84.5± 1.1
M45	91.1± 0.8	90.9± 1.0	94.4± 0.7	sketch	59.5± 2.6	59.7± 8.2	60.9± 1.7
M60	96.5± 1.0	97.9± 0.3	98.3± 0.7	Avg	63.85	64.79	67.76
M75	86.1± 2.0	89.8± 0.4	87.7± 2.1				
Avg	92.16	93.66	94.49				

4.2 実験結果

図 2 と図 3 に、トイデータを利用した場合の AFL と PWD の挙動を比較した結果を示す。具体的には、(1) ユニットサイズ 2 の中間層を 1 層持つ MLP (入力サイズも 2 なので、重み行列は 4 つの成分を持つ) を重み行列 W を対角行列に、バイアスを 0 に初期化、(2) エンコーダ E を固定して識別器 D (ユニットサイズ 100, 活性化関数 ReLU の MLP) を 100 バッチ訓練したのち、(3) 識別器 D と E (ユニットサイズ 2 の中間層を 1 層持つ MLP を各分布ごとに用意した) の更新を交互に 100 回行った。図中 (a,b,c) の上部に記載されている数値は AFL および PWD のスコアおよび D と同じ構造を持つ識別器 D_{eval} を 100 バッチ訓練した場合の負の対数尤度 (括弧の中の数字) を表している。この図から、次のような結果が得られた。(1) PWD を最小化することが実際に D_{eval} により計測される対数尤度 (\approx 真の条件付きエントロピー) を安定して低下させていた、(2) AFL は不安定な挙動を引き起こし最大エントロピーを 100 ステップ後も達成できていない (最も良い場合で 38 ステップ後の 0.684) のに対して、PWD は 16 ステップ目でほぼ最大エントロピーと一致する 1.080 を達成していた。(3) 図 2-c に示されている用に、カテゴリカル分類器 D を単に騙すだけだと理論的な最大エントロピーを上回る値をとってしまい、かつ上記のような減少が発生した場合に AFL は不安定な挙動を取る傾向にあった。表 1 に MNISTR と PACS におけるドメイン汎化性能を比較した結果を示す。(1) PWD が M75 を除く全ての場合で最も良い精度を達成している、(2) 通常の AFL の場合でも SN を入れる方が精度が改善する、という結果が得られた。ただし、ドメイン汎化性能は学習の停止時刻に大きく依存する傾向にあり、ドメイン汎化性能に対する寄与は今後の検討が必要である。

5. おわりに

本稿では観測中に含まれる特定の属性に不変な表現を学習する新たな手法としてペアワイズニューラルネットワーク距離にもとづく方法とその効率的な実装方法を提案し、(1) 提案法が不変性の素直な基準である条件付きエントロピーの最大化であるとみなせること、(2) 実験的に既存のクラス分類にもとづく敵対的学習手法より提案法が少ない更新回数で不変な表現に到達することを確認した。今後は、(a) 広範なデータセットにおける調査、(b) パラメータ共有の影響の理論的な分析を行う。

謝辞

本研究は JSPS 科研費 18K18101 の助成により行われました。

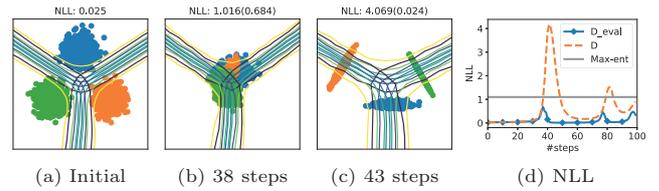


図 2: トイデータセットにおける AFL の挙動。(a,b,c) それぞれ E を更新する前、事後に学習した識別器 D_{eval} を 100 バッチ更新した場合の対数尤度 (\approx 真の条件付きエントロピー) が最大になった時点、学習に利用した識別器 D の尤度が最大になった時点における特徴空間および識別境界の可視化。(d) D_{eval} と D の対数尤度の推移および真の最大エントロピー ($= \frac{1}{3} \approx 1.067$).

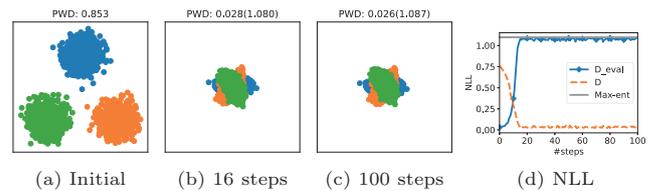


図 3: トイデータセットにおける PWD の挙動。(a,b,c) それぞれ E を更新する前、16 ステップ後 (PWD が最初に極小値をとった時点)、および 100 ステップ後の特徴空間および識別境界の可視化。(d) PWD と D_{eval} の対数尤度の推移。

参考文献

- [Ghifary 15] Ghifary, M., Bastiaan Kleijn, W., Zhang, M., and Balduzzi, D.: Domain generalization for object recognition with multi-task autoencoders, in *ICCV*, pp. 2551–2559 (2015)
- [Iwasawa 17] Iwasawa, Y., Nakayama, K., Yairi, I. E., and Matsuo, Y.: Privacy Issues Regarding the Application of DNNs to Activity-Recognition using Wearables and Its Countermeasures by Use of Adversarial Training, in *IJCAI*, pp. 1930–1936 (2017)
- [Li 17] Li, D., Yang, Y., Song, Y.-Z., and Hospedales, T. M.: Deeper, broader and artier domain generalization, in *IEEE International Conference on Computer Vision (ICCV)*, pp. 5543–5551 (2017)
- [Louizos 16] Louizos, C., Swersky, K., Li, Y., Welling, M., and Zemel, R.: The variational fair auto encoder, in *ICLR* (2016)
- [Miyato 18] Miyato, T., Kataoka, T., Koyama, M., and Yoshida, Y.: Spectral normalization for generative adversarial networks, in *ICLR* (2018)
- [Xie 17] Xie, Q., Dai, Z., Du, Y., Hovy, E., and Neubig, G.: Controllable Invariance through Adversarial Feature Learning, in *NIPS* (2017)
- [Zemel 13] Zemel, R., Wu, Y., Swersky, K., Pitassi, T., and Dwork, C.: Learning fair representations, in *Proceedings of the 30th International Conference on Machine Learning (ICML)*, pp. 325–333 (2013)

外生変数を伴う長期予測における主要因子推定法

Evaluation Method of Major Factors in Long-term Prediction with Exogenous Variables

中塚祐喜 *¹

Yuki Nakatsuka

白山晋 *¹

Susumu Shirayama

*¹ 東京大学 工学系研究科

School of Engineering, The University of Tokyo

In many fields, long-term prediction on time series data with exogenous variables has been performed. However, it is difficult to deal with some noise in input data and to qualitatively understand the obtained results. In this paper, first, we extend the DA-RNN proposed by Qin et al so that it can be used in the different time range from the original method. Also, the DA-RNN is extended to be applicable to long-term prediction. Second, we develop a new method of long term prediction based on the extended DA-RNN and the subsequence time-series clustering. An evaluation method of major factors in the exogenous variables is proposed by visualizing the weight of attention mechanism. We tested our method using dataset named SML2010. It is shown that our method has high prediction ability and robustness against noise, accountability of the results.

1. はじめに

1.1 外生変数を伴うデータに対する長期予測

多くの分野・領域において、外生変数を伴う時系列データに対する予測が行われている。その目的は様々であるが、単なる予測でなく、意思決定や政策立案に役立たせるためのものもある。例えば、気温、降水量あるいは降雪量などの予測結果は、商品の仕入れ、電力需要、自然災害対策などに影響する。

外生変数を伴うモデルは、目的変数だけではなく外生変数も参照することで目的変数に対する予測能力を高めている。こうしたモデルの一例として、注意機構を用いた 2 段階注意機構 RNN (Dual-stage Attention-based RNN; DA-RNN) モデル [Qin 17] がある。

このような予測手法は、主に 1 ステップ先の状態を予測する手法として提案されてきた。一方で、近年、時系列予測の分野における新たな課題として、長期予測が注目されている。なお、本稿では長期予測を 2 ステップ以上先までの予測とする。長期予測には、大きく分けて 5 つの予測戦略が提案されている [Taieb 12]。それらの予測戦略は、それぞれ精度の蓄積や確率的従属関係、予測の柔軟性など様々な問題を有している。また、長期予測モデルによって得られる結果は、定量的な結果を与えるものの、人間がすぐに結果を解釈して利用するのは難しく、定性的理解の面で問題がある。

1.2 予測結果の解釈性

上記のように、現状の長期予測における予測戦略は、人間がすぐに結果を解釈して利用するのは難しいという課題がある。解釈性という側面では、近年、機械学習モデルに対する研究でも問題になっている。

Ribeiro らによると、機械学習における解釈性の問題には、「なぜその予測値が得られたのかを説明する」とこと、「そのモデルがどのような性質を持っているかを説明する」とこという 2 つの観点がある [Ribeiro 16]。

本稿で扱う注意機構を利用したモデルは後者に分類することができる。注意機構は、深層学習の入力層や中間層のベクトルから予測に有用な部分を自動的に学習する方法であり、機械翻

訳の分野を中心に既存のモデルの予測能力を高めるものとして注目されている。さらに、注意機構では、注意機構の重みを可視化することで与えられた入力の中の部分が有用であったかを知ることができる。Riemer らは目的変数と外生変数からなる入力に対して、注意機構を利用した解釈性の高い時系列モデルを提案している [Riemer 16]。彼らの研究では、予測における主要因子の重要度を決定することに注意機構を利用している。

1.3 本研究の目的

以上に述べた時系列データに対する解釈性の高い注意機構モデルには、長期予測に対して提案されたものはない。一方で、応用上、長期予測モデルが必要となるケースは多く存在する。また、外生変数の時系列が部分的に目的変数と相関があるように振る舞うことがあり、既存のモデルでは目的変数と本来関係のない誤った入力変数を選択する可能性がある。

そこで、本研究の目的を外生変数を伴う時系列データに対する長期予測タスクにおける解釈性の高い注意機構モデルを提案することとし、同時に注意機構の重みをより解釈しやすい方法を提案する。加えて、部分的なノイズにも頑健なモデルを提案することを目標とする。

2. 外生変数を伴う予測モデル

本節では外生変数を伴う時系列モデルとして Dual-stage Attention-based RNN (DA-RNN) モデルを説明する。

本稿では以下の 2 通りの定式化を扱う。

$$\hat{y}_{T+1} = F(y_1, y_2, \dots, y_T, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T) \quad (1)$$

$$\hat{y}_{T+1} = F(y_1, y_2, \dots, y_T, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T, \mathbf{x}_{T+1}) \quad (2)$$

ここで、 y_t ($t = 1, 2, \dots, T$) は目的変数、 \mathbf{x}_t ($t = 1, 2, \dots, T$) は外生変数を表す。また、以下では、外生変数の数を n とし、外生変数を $\mathbf{x}^k = (x_1^k, \dots, x_{T+1}^k)$ ($k = 1, 2, \dots, n$) と表す。

2.1 DA-RNN モデル

DA-RNN モデルは入力情報・時系列情報の両方に注意機構を組み込んだモデルである。入力情報における注意機構を第 1 段階の注意機構、時系列情報における注意機構を第 2 段階の注意機構と呼ぶ。DA-RNN における Encoder と Decoder は、LSTM のユニットで構成されている。

連絡先: 中塚 祐喜, 東京大学大学院工学系研究科システム創成学専攻 白山研究室, 文京区本郷 7-3-1, nk.tsssa@gmail.com

2.1.1 第1段階の注意機構

第1段階の注意機構は、Encoderにおける注意機構である。時点 $t-1$ での Encoder の m 次元の隠れ状態ベクトル \mathbf{h}_{t-1} 、内部セルの状態ベクトル \mathbf{s}_{t-1} に対し、次時点 t 、特徴 k における関連度 e_t^k を

$$e_t^k = \mathbf{v}_e^T \tanh(\mathbf{W}_e[\mathbf{h}_{t-1}; \mathbf{s}_{t-1}] + \mathbf{U}_e \mathbf{x}^k) \quad (3)$$

と計算する。なお、 $\mathbf{v}_e \in \mathbb{R}^T$ 、 $\mathbf{W}_e \in \mathbb{R}^{T \times 2m}$ 、 $\mathbf{U}_e \in \mathbb{R}^{T \times T}$ であり、これらは学習するパラメータである。

そして、この関連度 e_t^k をソフトマックス層に通すことで、注意機構の重み α_t^k を計算する。この α_t^k を用いて $\tilde{\mathbf{x}}_t = (\alpha_t^1 x_t^1, \dots, \alpha_t^n x_t^n)$ とし、Encoderに入力することで、最終的な隠れ状態ベクトル \mathbf{h}_t を得る。

2.1.2 第2段階の注意機構

第2段階の注意機構は、Decoderにおける注意機構である。時点 $t-1$ での Decoder の m 次元の隠れ状態ベクトル \mathbf{d}_{t-1} 、内部セルの状態ベクトル \mathbf{s}'_{t-1} に対し、時点 t の第2段階の注意機構における関連度 l_t^i を

$$l_t^i = \mathbf{v}_d^T \tanh(\mathbf{W}_d[\mathbf{d}_{t-1}; \mathbf{s}'_{t-1}] + \mathbf{U}_d \mathbf{h}_i) \quad (4)$$

と計算する。ここで、 $\mathbf{v}_d \in \mathbb{R}^m$ 、 $\mathbf{W}_d \in \mathbb{R}^{m \times 2m}$ 、 $\mathbf{U}_d \in \mathbb{R}^{m \times m}$ であり、これらは学習するパラメータである。

そして、この関連度 l_t^i をソフトマックス層に通し、注意機構の重み β_t^i を得る。この β_t^i を用いて、Encoderの重み付き隠れ状態ベクトル \mathbf{c}_t を $\mathbf{c}_t = \sum_{i=1}^T \beta_t^i \mathbf{h}_i$ のように得る。こうして得た隠れ状態ベクトルを Decoderに入力する。

Decoderでは、隠れ状態ベクトル \mathbf{c}_t と過去の目的変数 y_t を入力として受け取り、隠れ状態ベクトル \mathbf{d}_t を計算する。この \mathbf{d}_t を出力層に通し、次のように予測値 \hat{y}_{T+1} を得る。

$$\hat{y}_{T+1} = \mathbf{v}_y^T (\mathbf{W}_y[\mathbf{d}_{T+1}; \mathbf{c}_{T+1}] + \mathbf{b}_w) + b_v \quad (5)$$

ただし、 $[\mathbf{d}_{T+1}; \mathbf{c}_{T+1}] \in \mathbb{R}^{2m}$ である。また、 $\mathbf{W}_y \in \mathbb{R}^m \times 2m$ 、 $\tilde{\mathbf{b}}_w \in \mathbb{R}^m$ 、 $\mathbf{v}_y \in \mathbb{R}^m$ 、 $b_v \in \mathbb{R}$ であり、これらは学習するパラメータである。

2.1.3 DA-RNN モデルの限界

DA-RNN は式 (2) の形で定式化されており、将来の時間 $t+1$ 時点での外生変数の値を一般には利用できない点が問題であると指摘されている [Tao 18]。また、この手法では、時系列が一部の区間でのみ相関があるように振る舞った場合、誤った入力変数を選択する可能性があると考えられる。

3. 提案手法

3.1 DA-RNN モデルの拡張

DA-RNN の元の定式化は、式 (2) の形式であった。そこで本稿では、Tao の指摘を踏まえて、DA-RNN を式 (1) に合わせた定式化を提案する。具体的には、式 (5) の計算を次のように変更する。

$$\hat{y}_{T+1} = \mathbf{v}_y^T (\mathbf{W}_y[\mathbf{d}_T; \mathbf{c}_T] + \mathbf{b}_w) + b_v \quad (6)$$

また、Encoder の隠れ状態ベクトルは次のように更新する。

$$\mathbf{h}_t = f_1(\mathbf{h}_{t-1}, \tilde{\mathbf{x}}_{t-1}) \quad (7)$$

この変更に合わせて、Decoder の隠れ状態ベクトルは時点 T まで計算する。本研究では、この方法を DA-RNN-Tp モデル (DA-RNN-Tp と表記) と呼ぶことにする。

3.2 長期予測モデルへの拡張

次に、長期予測への拡張法を提案する。ここで、長期予測とは τ ステップ先までの予測を指す。本稿では、予測値 \hat{y}_{T+1} を得た後、その予測値を再び Decoder に入力することで、次のステップの予測値 \hat{y}_{T+2} を計算する。この操作を τ 回繰り返すことで長期予測を行う。

この方法によって、DA-RNN-Tp を長期予測に適用できるようにする。本研究では、このモデルを DA-RNN-TpLP と記す。

3.3 部分時系列クラスタリング付きの DA-RNN-TpLP

前節までに示した DA-RNN モデルの拡張版に対し、部分時系列クラスタリングによるクラスタの情報をモデルに加えることによって、よりノイズに頑健なモデルを構築する。具体的には、前処理として訓練データにおける外生変数と目的変数の過去の値を全てを使って部分時系列クラスタリングを行う。スライディングウィンドウによって D 個の訓練データが得られた場合、つまり、 $((\mathbf{x}^1, \dots, \mathbf{x}^n, \mathbf{y}), y_{T+1})$ の組が D 個ある場合、 $(n+1) \times D$ 個の部分時系列を用いて部分時系列クラスタリングを行う。

ここでは、部分時系列クラスタリング手法として k-shape 法 [Paparrizos 15] と呼ばれる手法を利用する。

以下では、k-shape 法によって得られた $\mathbf{x}^1, \dots, \mathbf{x}^n, \mathbf{y}$ に対応するクラスタを $\mathbf{c}_1, \dots, \mathbf{c}_n, \mathbf{c}_{n+1}$ と表す。また、これらを one-hot ベクトルによって表したものを $\mathbf{c}_1, \dots, \mathbf{c}_n, \mathbf{c}_{n+1}$ とする。

このように得られたクラスタ情報を用いて外生変数のクラスタ $\mathbf{c}_1, \dots, \mathbf{c}_n$ と、目的変数のクラスタ \mathbf{c}_{n+1} を比較し、目的変数と類似したクラスタ同士の重みが大きくなるように、式 (3) の e_t^k を次のように補正する。

$$e_t'^k = e_t^k (U^k (\mathbf{c}_k - \mathbf{c}_{n+1})) \quad (8)$$

ただし、 $U^k \in \mathbb{R}^C$ であり、学習パラメータである。ここで C はクラスタの総数である。以降の計算は DA-RNN-TpLP と同様である。本稿では、この方法を提案手法と称する。

3.4 注意機構の重みによる主要因子推定法と情報支援

最後に、注意機構の重みを利用した新たな主要因子推定法を提案する。提案手法や DA-RNN では、第1段階の注意機構によって、各データに対し各特徴における注意機構の重みを計算することができる。この注意機構の重みの平均や分散によってその特徴を記述し、他の特徴と比較することも可能になる。しかしながら、平均や分散が近い値をとる場合でも、各特徴によって注意機構の重みの分布の形が異なる可能性がある。このため、注意機構の重みの分布を比較する方法が必要になる。

本稿では Bhattacharyya 距離 [Bhattacharyya 43] を利用して、特徴をクラスタリングすることを提案する。クラスタリング方法として、k-means++法を利用する。クラスタリングによって得られたあるグループに対し、得られた特徴と目的変数を同時にプロットすることで、それをユーザへの支援情報として活用することができる。その結果、そのような支援情報に基づき必要な特徴の取捨選択や特徴の追加などを考察することが可能となる。

4. 数値実験

本稿では、数値実験に SML2010 データセット [Zamora-Martínez 14] を用いる。SML2010 は室温

表 1: 短期予測における評価指標

	RMSE	MAE	MAPE
Encoder-Decoder	2.800	2.096	0.100
Attention	2.608	1.971	0.095
DA-RNN-Tp	2.572	1.886	0.091
Proposed	2.508	1.812	0.088

表 2: 長期予測における評価指標

	RMSE	MAE	MAPE
DirRec	0.252	0.186	0.009
Encoder-Decoder	0.249	0.183	0.009
Attention	0.281	0.216	0.010
DA-RNN-TpLP	0.233	0.157	0.007
Proposed	0.239	0.164	0.008

表 3: ノイズを追加した場合の長期予測における評価指標

	RMSE	MAE	MAPE
DA-RNN	0.556	0.361	0.017
Proposed	0.555	0.352	0.016

表 4: ノイズを追加した場合の短期予測における評価指標

	RMSE	MAE	MAPE
DA-RNN	0.051	0.039	0.002
Proposed	0.048	0.039	0.002

の予測に利用されるデータセットであり、屋内外に設置された温度計・湿度計などのセンサの値を収集したものである。目的変数として室温のデータを、外生変数として屋内外の湿度・風速などの $n = 20$ 個の外生変数を用いる。

これらのデータは合計約 40 日間、1 分ごとに計測されているが、15 分の区間幅で平滑化されている。本実験では、訓練データとして最初の 3,200 点、検証データとして続く 400 点、テストデータとして最後の 537 点を利用する。検証データは学習の終了エポック数の決定に利用した。入力データのウィンドウ幅 $T = 10$ 、隠れ状態ベクトルの次元数 $m = p = 128$ とし、クラスタ数 $C = 8$ とし、損失関数には平均二乗誤差 (MSE) を利用した。そして、短期予測・長期予測 2 種類のタスクにおいて手法の比較を行った。長期予測では、 $\tau = 10$ ステップ先までの予測を行った。

上記の設定の下、手法の性能比較を行うために RMSE, MAE, MAPE という 3 つの評価指標を採用した。

4.1 実験結果

短期予測においては 3 種類の従来手法とその性能を比較した。使用した従来手法は、Encoder-Decoder モデル、注意機構モデル、DA-RNN-Tp モデルである。長期予測においては上記 3 種類のモデルに加え、DirRec Strategy [Sorjamaa 06] と LSTM を組み合わせたモデルとも比較を行った。

表 1, 表 2 にテストデータに対する評価指標の値を示す。

短期予測の場合、表 1 に示すように、DA-RNN-Tp と提案手法は他の比較手法よりも優れた結果を示した。さらに、提案手法は全ての指標で DA-RNN-Tp よりも優れた予測能力を示した。これは部分時系列クラスタリングによって、効率的に注意機構の重みを計算することが可能であることを示唆している。

長期予測の場合、短期予測よりも予測区間が長くなるため、全体として予測能力が落ちているものの、2 段階の注意

機構のモデルの予測精度の高さが確認された。中でも、DA-RNN-TpLP が全ての評価指標において他の全ての手法よりも優れた予測能力を示した。

4.2 注意機構の重みの比較と特徴の分析

さらに、DA-RNN-Tp と提案手法における外生変数の注意機構の重みの平均値を計算した。SML2010 における結果を図 1 に示す。ただし、Bhattacharyya 距離 [Bhattacharyya 43] を距離関数とした際のクラスタリングによって同じクラスタに割り当てられた特徴を同じ色で示している。クラスタ数は 5 であるので、全部で 5 色に各特徴が分けられている。

図から、両者の注意機構の重みの傾向は類似しているものの、比較手法よりも提案手法の方が外生変数における注意機構の重みの大小が明確になっていることがわかる。したがって、提案手法は従来手法よりも不要な外生変数を自動的に選別して予測を行っていると考えられる。

また、各特徴に割り当てられた特徴に関して、注意機構の重みの平均が近いもの同士が同じクラスタに割り当てられている傾向にある。しかしながら、例えば「Precipitacion」という特徴と「Meteo.Exterior.Sol.Oest」という特徴は重みの平均値差は小さいにも関わらず、重みの分布が大きく異なっているため、異なったクラスタが割り当てられている。図 2 にこれらの特徴の注意機構の重みの分布を示す。図のように重みの分布に大きな差異が見られており、モデルにその特徴が大きな重要性を持つと判断される機会に違いがあることがわかる。

4.3 ノイズに対する頑健性の比較

提案手法のノイズに対する頑健性を調べるために、既存の外生変数に対し一定のノイズを加える実験と全く予測に寄与しないノイズに基づく特徴を加える実験を行った。

4.3.1 一部区間におけるノイズ

この実験では、標準化したテストデータに対し、正規分布に従うノイズを加えてその予測能力の変化を調べた。表 3 に長期予測における結果を示す。表 2 と表 3 を比較すると、ノイズがない場合には DA-RNN-TpLP が優れた結果を示していたが、ノイズを加えた場合にはその予測能力が逆転した。この実験結果は、提案手法は部分的なノイズに対してより頑健であることを示唆している。

4.3.2 入力変数におけるノイズ

この実験では、全く予測に寄与しないノイズに基づく特徴を外生変数として追加して、提案手法における予測能力や注意機構の重みの変化を調べた。

正規分布からサンプリングしたノイズに基づく特徴を 5 種類追加し、合計 25 個の外生変数で短期予測モデルを訓練し、その予測性能をテストデータで評価を行ったところ、RMSE: 0.026, MAE: 0.019, MAPE: 0.001 という結果を得た。表 1 と結果を比較すると、わずかな予測能力の劣化は見られるが、ほとんどノイズの影響を受けていないと考えられる。また、図 3 はこの時の注意機構の重みを示したものである。図より、追加したノイズに対しては一貫して低い注意機構の重みを与えていることが確認できる。

5. おわりに

本稿では、長期予測モデルに対する解釈性の高いモデルが存在しないことと既存の予測モデルは部分的なノイズに対して頑健ではないことを指摘した上で、Qin らの DA-RNN モデルを長期予測が可能になるように拡張し、部分時系列クラスタリングを加えることで、ノイズに対して頑健性を有する長期予測

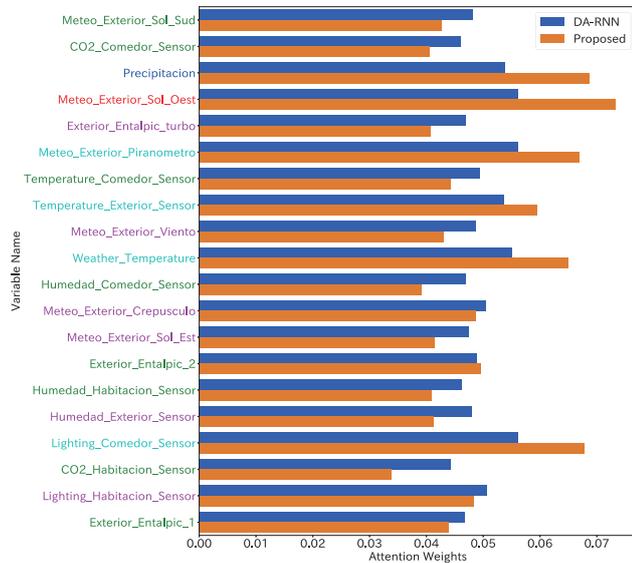


図 1: SML2010 における短期予測の場合の訓練データの注意機構の重み

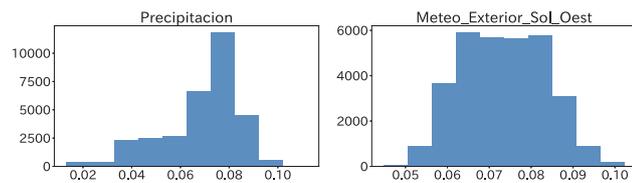


図 2: 注意機構の重みの分布の比較

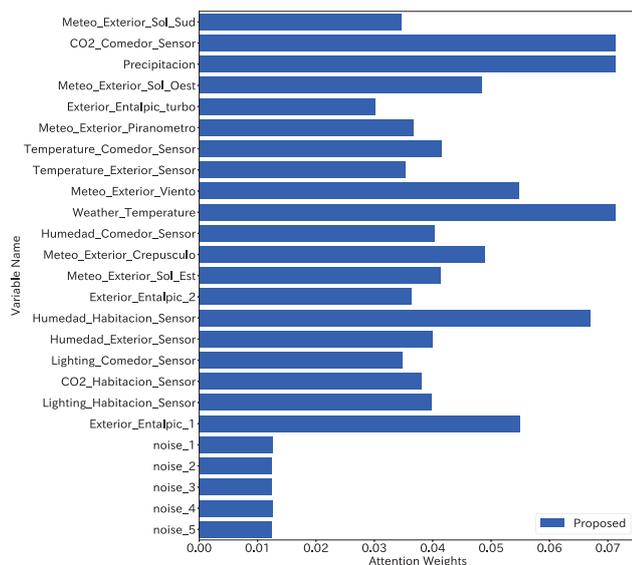


図 3: ノイズ特徴を加えた場合の注意機構の重み

手法を構築した。また、その注意機構の重みから主要因子を推定する方法を提案した。

提案手法を複数のデータセットに適用し、短期・長期予測の両方において従来手法と同等以上の予測能力があることを示した。また、ノイズを加えた場合でも高い予測能力を維持できることから、ノイズに対して頑健であることを示した。

今後の課題としては、注意機構の重みの解釈性を向上させる可視化方法の開発、部分時系列クラスタリングのクラスタ数の適切な決定方法の考案、可視化における解釈性の高いクラスタ数の決定方法の開発などが挙げられる。

参考文献

- [Bhattacharyya 43] Bhattacharyya, A.: On a measure of divergence between two statistical populations defined by their probability distributions, *Bulletin of the Calcutta Mathematical Society*, Vol. 35, pp. 99–109 (1943)
- [Paparrizos 15] Paparrizos, J. and Gravano, L.: k-Shape: Efficient and accurate clustering of time series, in *Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data*, pp. 1855–1870 (2015)
- [Qin 17] Qin, Y., Song, D., Cheng, H., Cheng, W., Jiang, G., and Cottrell, G. W.: A dual-stage attention-based recurrent neural network for time series prediction, in *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, pp. 2627–2633 (2017)
- [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 International Conference on Knowledge Discovery and Data Mining*, pp. 1135–1144 (2016)
- [Riemer 16] Riemer, M., Vempaty, A., Calmon, F., Heath, F., Hull, R., and Khabiri, E.: Correcting forecasts with multifactor neural attention, in *Proceedings of International Conference on Machine Learning*, pp. 3010–3019 (2016)
- [Sorjamaa 06] Sorjamaa, A. and Lendasse, A.: Time series prediction using DirRec strategy., in *Proceedings of the European Symposium on Artificial Neural Networks*, pp. 143–148 (2006)
- [Taieb 12] Taieb, S. B., Bontempi, G., Atiya, A. F., and Sorjamaa, A.: A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition, *Expert Systems with Applications*, Vol. 39, No. 8, pp. 7067–7083 (2012)
- [Tao 18] Tao, Y., Ma, L., Zhang, W., Liu, J., Liu, W., and Du, Q.: Hierarchical Attention-Based Recurrent Highway Networks for Time Series Prediction, *arXiv preprint arXiv:1806.00685* (2018)
- [Zamora-Martínez 14] Zamora-Martínez, F., Romeu, P., Botella-Rocamora, P., and Pardo, J.: On-line learning of indoor temperature forecasting models towards energy efficiency, *Energy and Buildings*, Vol. 83, pp. 162–172 (2014)

マルチモーダル学習のための階層ニューラルトピックモデル

Hierarchical Neural Topic Models for Multimodal Learning

青木 達哉^{*1} 南坂 雅人^{*1} 長井 隆行^{*1*2}
 Tatsuya Aoki Masato Minamisaka Takayuki Nagai

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

In this paper, we propose novel hierarchical neural topic models for learning multimodal sensory data. The first one is the neural version of multilayered multimodal LDA (mMLDA), which we call “Deep-mMLDA”. The use of the neural inference network makes the Bayesian topic model scalable and powerful. Therefore, the model can deal with very large scale multimodal sensor data in real world. The second one is further extension of the Deep-mMLDA to nonparametric Deep-mMLDA, which can infer the number of categories from the learning data. The idea behind the model is to use the recurrent stick breaking process (RSBP) that uses recurrent neural networks for implementing the stick breaking process. We conduct an experiment using multimodal data of human activities collected in a smart house environment. As the result of comparison in the performance of the proposed and baseline models, the validity of the proposed models is confirmed.

1. はじめに

近年、機械学習の性能が向上し、実社会での応用が進んでいる。機械学習の役割の1つは観測データから有益な情報を予測することである。実世界の観測情報は一般に、複数のモダリティからなるマルチモーダル情報であり、マルチモーダル情報から潜在情報を抽出することは重要な要素となる。機械学習において、データの潜在的な情報を抽出する研究は数多く行われてきた。その中でも階層ベイズに基づくトピックモデルである Latent Dirichlet Allocation (LDA) [Blei03] は文書分類から始まり、情報検索、画像分類など様々な分野へと応用されている。マルチモーダル情報処理においても、例えば中村らは画像、音、触覚といった複数のセンサ情報を同時に扱う Multimodal LDA (MLDA) を提案し、ロボットにおける有効性を示した [Nakamura11]。さらに [Attamimi16] は、MLDA を多層構造とした multilayered MLDA (mMLDA) を提案し、マルチモーダルな観測情報に関するトピック同士の関係性を、上位層としてモデル化することを可能とした。しかし MLDA や mMLDA には、大規模な入力データに対して計算コストが高いといった問題がある。特にギブスサンプリングを用いた推論には、多大な時間を要する。また、学習データに対応したトピック数を事前に設定する必要があるが、マルチモーダルな情報に対して適切なトピック数を決定するのは困難である。

一方で、近年の深層学習の発展により、確率的生成モデルを深層学習によって推論する深層生成モデルに注目が集まっている。その中の1つが、変分近似と深層学習を援用して推論を行う Variational Autoencoder (VAE) [Kingma13] である。VAE の推論手法をベースとして、様々な確率的生成モデルの推論が提案されており、先に述べたトピックモデルについても、[Srivastava17] や [Srivastava18] などの研究がある。VAE をベースとした学習法の利点として、GPU を使った並列計算による推論が挙げられ、大規模な学習データを扱いやすいという強みをもつ。

本研究ではこのような背景に基づき、両分野の先行研究の利点を兼ね備えたより効率的に大規模なマルチモーダル情報
 連絡先: 青木達哉, 電気通信大学, 東京都調布市調布ヶ丘 1-5-1,
 aoki@apple.ee.uec.ac.jp

を学習できるトピックモデルの実現を目指す。具体的には、[Srivastava18] で提案されたトピックモデルの推論手法に基づき、[Attamimi16] で提案された階層構造を持つトピックモデル mMLDA のニューラルネットワークによる推論モデルを提案する。そして、上位層のトピック数を推定できるトピックモデルへと拡張を行う。

2. mMLDA

はじめに本研究で提案するニューラルトピックモデルのベースとなる mMLDA について概要を述べる。mMLDA は、マルチモーダルデータに対する階層的な構造を持つトピックモデルである。mMLDA の下位層には、複数モダリティ情報を含む観測情報を1つのトピックに統合するモデルが複数配置され、上位層には、それらのモデルのトピックの関係を捉えるモデルが存在する。mMLDA は、 \mathbf{x}_d^{cm} データ数 D の観測データ集合 $\mathbf{X} = \{\mathbf{x}_d^{cm} | m = M^1, \dots, M^c, c = 1, \dots, C\}$ が上位トピック数 K , 下位トピック数 K^c の確率分布の混合分布から生成されたとして以下のようにモデル化する。

$$p(\mathbf{X}) = \prod_{d=1}^D \prod_{c=1}^C \prod_{m=1}^{M^c} p(\mathbf{x}_d^{cm} | \phi^{cm}, \beta^{cm}, \theta^c) p(\theta^c | \theta, \alpha^c) p(\theta | \alpha)$$

β^* , α^* , α はハイパーパラメータ, C は下位層の MLDA のモデル数, M^c は c 番目の下位層の MLDA のモデルに含まれるモダリティ数を表す。mMLDA の学習とは、観測情報 \mathbf{X} の尤度を最大とするパラメータ ϕ , θ を推定することであり、[Attamimi16] ではギブスサンプリングによって推定を行っている。

3. 提案手法

3.1 Deep-mMLDA

本研究では、前節で述べた mMLDA のように階層的なトピック構造を持つモデルをニューラルネットワークで構築し、そのパラメータの推論手法を提案する。図1が提案するモデルの構造である。このモデルを “Deep-mMLDA” と呼ぶ。図1中の Z^* のユニットは上位のノードの出力を受け、平均 μ^* , 分

散共分散行列 Σ^* を算出し、混合比 θ^* を出力するノード全体を表す。このネットワークは、全モダリティの観測情報を入力とし、全結合層を経て上位層のトピック混合比 θ 、下位層のトピック混合比 θ^c と観測情報の出力分布 $p(\mathbf{x}^{cm}|\theta^{cm})$ をニューラルネットワークの前向き計算により算出する。

$$\begin{aligned}\theta &= \text{softmax}(\mu + \epsilon \Sigma) \\ \theta^c &= \text{softmax}(\mu^c + \epsilon^c \Sigma^c) \quad (c = 1, \dots, C) \\ p(\mathbf{x}^{cm}|\theta^c) &= \text{softmax}(\theta^c \cdot \mathbf{w}^{cm}) \quad (m = 1, \dots, M^c)\end{aligned}\quad (1)$$

ただし、 C は下位層の MLDA のモデルの数、 M^c は c 番目の下位層のモデルのモダリティ数を表す。

次に、Deep-mMLDA の損失関数となる変分下限 \mathcal{L} を導出する。ここでは、 $C = 2$, $M^1 = 1$, $M^2 = 1$ の場合について述べるが、他の場合も同様に考えることができる。観測情報 $\mathbf{X} = [\mathbf{x}^{11}, \mathbf{x}^{21}]$ に対する周辺対数尤度より、 \mathcal{L} は以下になる。なお、 $q(\cdot)$ は近似分布、 $\mathbf{H} = [\alpha, \alpha^1, \alpha^2]$ はハイパーパラメータの集合、 $\Theta = [\theta, \theta^1, \theta^2]$ は混合比の集合を表す。

$$\begin{aligned}\log p(\mathbf{X}|\mathbf{H}) &= \log \int_{\Theta} q(\Theta) \frac{p(\mathbf{X}, \Theta|\mathbf{H})}{q(\Theta)} d\Theta \\ &\leq \int_{\Theta} q(\Theta) \log \frac{p(\mathbf{X}, \Theta|\mathbf{H})}{q(\Theta)} d\Theta = \mathcal{L}\end{aligned}\quad (2)$$

式 (2) の同時確率 $p(\mathbf{X}, \Theta|\mathbf{H})$ は、mMLDA の場合、

$$\begin{aligned}p(\mathbf{X}, \Theta|\mathbf{H}) &= p(\mathbf{x}^{11}|\theta^1)p(\mathbf{x}^{21}|\theta^2)p(\theta^1|\theta, \alpha^1) \\ &\quad p(\theta^2|\theta, \alpha^2)p(\theta|\alpha)\end{aligned}\quad (3)$$

である。さらに、deep-mMLDA では近似分布 q を次のように仮定する。これらのパラメータは、式 (1) のようにニューラルネットワークで計算される。

$$q(\Theta) = q(\theta|\mathbf{x}^{11}, \mathbf{x}^{21})q(\theta^1|\mathbf{x}^{11})q(\theta^2|\mathbf{x}^{21})\quad (4)$$

式 (3)、式 (4) を用いて最終的に、下限 \mathcal{L} は次のようになる。 $D_{KL}(\cdot|\cdot)$ は KL ダイバージェンスを表す。

$$\begin{aligned}\mathcal{L} &= -D_{KL}(q(\theta|\mathbf{x}^{11}, \mathbf{x}^{21})||p(\theta|\alpha)) \\ &\quad -\mathbb{E}_{\theta \sim q(\theta|\mathbf{x}^{11}, \mathbf{x}^{21})}[D_{KL}(q(\theta^1|\mathbf{x}^{11})||p(\theta^1|\alpha^1))] \\ &\quad -\mathbb{E}_{\theta \sim q(\theta|\mathbf{x}^{11}, \mathbf{x}^{21})}[D_{KL}(q(\theta^2|\mathbf{x}^{21})||p(\theta^2|\alpha^2))] \\ &\quad +\mathbb{E}_{\theta^1 \sim q(\theta^1|\mathbf{x}^{11})}[\log p(\mathbf{x}^{11}|\theta^1)] \\ &\quad +\mathbb{E}_{\theta^2 \sim q(\theta^2|\mathbf{x}^{21})}[\log p(\mathbf{x}^{21}|\theta^2)]\end{aligned}\quad (5)$$

つまり、 \mathcal{L} は上位層のトピックに対する KL ダイバージェンス、下位層のトピックに対する KL ダイバージェンス及び各モダリティ毎の観測情報に対する対数尤度の期待値の3種類の項で構成される。この式 (5) を目的関数とし、値を最大化するパラメータを決定する。

3.2 RSB-mMLDA

ここでは、Deep-mMLDA を学習データに応じて上位層のトピック数が調整可能なモデルへ拡張する。具体的には、上位層のトピックの確率分布に対し、ディリクレ過程から生成される無限次元ディリクレ分布を事前分布として導入する。本研究では Stick-Breaking Process (SBP) をニューラルネットワークで計算するための手法として、[Miao17] で提案された Recurrent Stick Breaking Process (RSBP) を利用する。

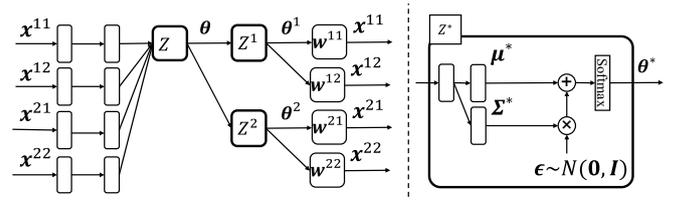


図 1: Deep-mMLDA のネットワーク構造

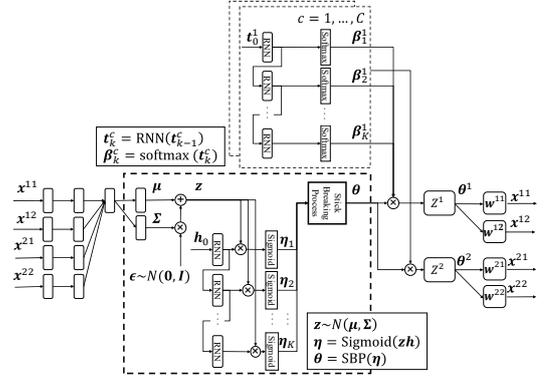


図 2: RSB-mMLDA のネットワーク構造

RSBP は、Recurrent Neural Network (RNN) の再帰的な計算により SBP を再現する手法である。

図 2 に RSBP を導入し、上位層のトピック数を可変にした Deep-mMLDA のネットワーク構造を示す。本研究では、このモデルを“RSB-mMLDA”と呼ぶ。このネットワークでは、全モダリティの観測情報を入力とし、全結合層を経て RSBP により上位層のトピックの混合比 θ を出力する。また、 t^0 を初期入力値とする RNN を用いたネットワークにより、上位層のトピックの出力分布のパラメータに相当する β^c を出力する。最終的に、 θ 及び β^c を入力とし、下位のトピック混合比 θ^c 及び観測情報の出力分布 $P(\mathbf{x}^{cm}|\theta^c)$ を算出する。これらの計算は Deep-mMLDA と同様、全てニューラルネットワークの前向き計算により実行される。

$$\begin{aligned}z &= \mu + \epsilon \Sigma, \quad \eta = \mathbf{h}z, \quad \theta = \text{SBP}(\eta) \\ \beta^c &= \text{RNN}(t^c), \quad \theta^c = \text{softmax}(\theta^c \cdot \beta^c) \quad (c = 1, \dots, C) \\ p(\mathbf{x}^{cm}|\theta^c) &= \text{softmax}(\theta^c \cdot \mathbf{w}^{cm}) \quad (m = 1, \dots, M^c)\end{aligned}\quad (6)$$

RSB-mMLDA の損失関数は Deep-mMLDA と同様であり、式 (5) を最小化するパラメータを推定する。また、パラメータの推定と同時に、トピック数を増加させるべきかを判断する。そのために、トピック数が $i-1$ の場合の損失 \mathcal{L}^{i-1} と i の場合の損失 \mathcal{L}^i を考え、トピック数を増やしたときの尤度の増加量 \mathcal{I} を算出する。

$$\mathcal{I} = \sum_d^D [\mathcal{L}_d^i - \mathcal{L}_d^{i-1}] / \sum_d^D [\mathcal{L}_d^i]\quad (7)$$

トピック数の増加しやすさを決めるハイパーパラメータを γ とし、 $\mathcal{I} > \gamma$ であればトピック数を 1 つ増加させる。

3.3 学習における工夫

提案モデルの学習を安定化させるために、2 つの工夫を学習に導入する。

1 つ目は、事前学習による下位層の重みの初期値の決定である。提案モデルでは、潜在変数の階層化などのため複雑な

ネットワーク構造になったことで、十分にパラメータが学習されない可能性がある。そこで、事前にモジュール毎に下位層の学習を行う。その後、学習された重みを Deep-mMLDA, RSB-mMLDA の下位層の重みの初期値としてネットワーク全体を学習する。

2つ目は欠損情報の予測学習である。これは観測情報のうち意図的に一部分の情報を全ての要素が0であるベクトルと置換し、他の観測情報から予測する学習を混入させる。この学習を通常の学習と合わせて行うことでモダリティ間の関係性の学習を促進する。

4. 評価実験

提案手法である Deep-mMLDA, RSB-mMLDA を用いて適切にマルチモーダルデータのトピックが学習可能であるかを評価した。また、ベースライン手法として [Attamimi16] で提案されたギブスサンプリングを用いる mMLDA (Gibbs-mMLDA) でも同様に学習を行い、性能を比較した。

4.1 実験設定

評価実験に用いたデータセットは、[Attamimi16] の実験で使用されたスマートハウス内で人が物体を操作する活動の場面を観測したマルチモーダルデータである。観測情報には、操作物体の画像情報 (Object), 被験者の関節角情報 (Motion), LRF で計測した被験者の位置情報 (Place), 画像から推定した被験者の性別情報 (Person Gender), 年齢情報 (Person Age) とそれらに対応する単語情報 (Object Word, Motion Word, Place Word, Person Word) の9種類の情報が含まれる。各情報は学習のための前処理として Bag of Features 表現への変換を行った。データの総数は446個である。

上述のマルチモーダルデータをもとに、次の2通りの情報の組み合わせに対してトピック推定を行った。

1. 4入力条件

- 使用した情報
(Object, Object Word, Motion, Motion Word)
- mMLDA の構造
 $C = 2$ (Object, Motion)
 $C1 = (\mathbf{x}^{\text{Object}}, \mathbf{x}^{\text{ObjectWord}})$
 $C2 = (\mathbf{x}^{\text{Motion}}, \mathbf{x}^{\text{MotionWord}})$

2. 9入力条件

- 使用した情報
(Object, Object Word, Motion, Motion Word, Place, Place Word, Person Gender, Person Age, Person Word)
- mMLDA の構造
 $C = 4$ (Object, Motion, Place, Person)
 $C1 = (\mathbf{x}^{\text{Object}}, \mathbf{x}^{\text{ObjectWord}})$
 $C2 = (\mathbf{x}^{\text{Motion}}, \mathbf{x}^{\text{MotionWord}})$
 $C3 = (\mathbf{x}^{\text{Place}}, \mathbf{x}^{\text{PlaceWord}})$
 $C4 = (\mathbf{x}^{\text{PersonGender}}, \mathbf{x}^{\text{PersonAge}}, \mathbf{x}^{\text{PersonWord}})$

本実験では、学習を行うにあたり3種類の手法に共通で下位層のカテゴリ数を、Object カテゴリ数=25, Motion カテゴリ数=17, Place カテゴリ数=5, Person カテゴリ数=3とした。また、上位層のカテゴリ数について、Gibbs-mMLDA と Deep-mMLDA は17とし、RSB-mMLDA は初期カテゴリ数を1, $\gamma = 0.05$ とした。

表 1: 4入力条件の学習後の対数尤度の比較

	Deep-mMLDA	RSB-mMLDA
Object	-28219	-28349
Motion	-13155	-13649

表 2: 9入力条件の学習後の対数尤度の比較

	Deep-mMLDA	RSB-mMLDA
Object	-28746	-29153
Motion	-13852	-14734
Place	-7658	-8062
Person	-7581	-7940

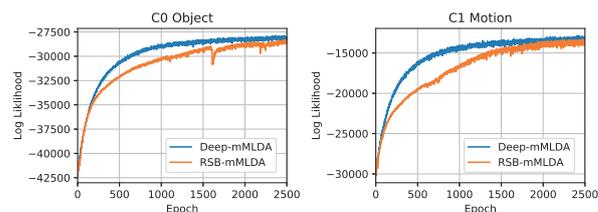


図 3: 4入力条件における学習データに対する対数尤度

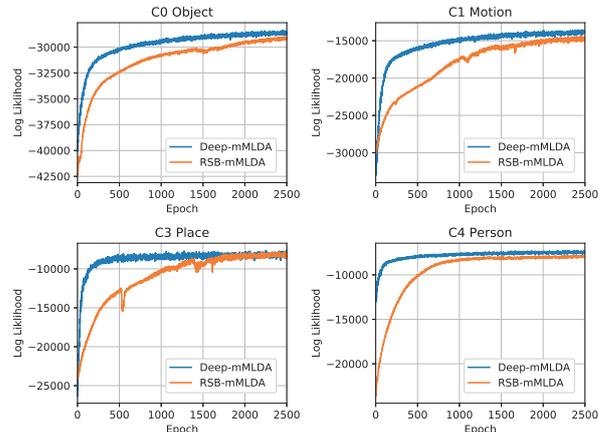


図 4: 9入力条件における学習データに対する対数尤度

4.2 結果

まず、提案手法である Deep-mMLDA 及び RSB-mMLDA の学習中の挙動を確認した。図3に4入力条件の場合の対数尤度の挙動、図4に9入力条件の場合の対数尤度の挙動を示す。どちらの条件においても、Deep-mMLDA は急激に損失を下げるように学習が進んだ。一方、RSB-mMLDA は Deep-mMLDA と比較すると多くの更新回数が必要であるが、対数尤度の変化は徐々に小さくなり、無限にトピックを増やし続けることはないことが確認できる。学習終了時の最終的な対数尤度を、表1, 表2に示す。また、各種法の学習時間の実測値を表3に示す。本実験では、Gibbs-mMLDA のサンプリング回数を2000, Deep-mMLDA 及び RSB-mMLDA のエポック数を2500と設定した。表3に示すように、大きく学習時間が削減された。この学習時間の短縮は並列計算によるパラメータ推定に起因する。

次に、それぞれのモデルが推定したトピックの構造を評価した。評価のために、人手により学習データに対して Object, Motion, Place, Person の4つの項目のラベルづけを行い、ラベルによる分類と学習結果を用いた分類の一致度を分類精度と

表 3: 各手法で学習にかかった時間

	Gibbs-mMLDA	Deep-mMLDA	RSB-mMLDA
4 入力条件 [秒]	62085	356	1091
9 入力条件 [秒]	70718	559	2141

表 4: 4 入力条件における分類精度の比較

	Gibbs-mMLDA	Deep-mMLDA	RSB-mMLDA
Object	0.484	0.748	0.647
Motion	0.562	0.600	0.567

表 5: 9 入力条件における分類精度の比較

	Gibbs-mMLDA	Deep-mMLDA	RSB-mMLDA
Object	0.443	0.576	0.457
Motion	0.502	0.674	0.504
Place	1.00	0.982	0.746
Person	0.807	0.959	0.695

定義する。表 4 に 4 入力条件, 表 5 に 9 入力条件の結果をそれぞれ示す。

まず, Deep-mMLDA についてみると, 表 4 で示すようにベースラインである Gibbs-mMLDA と比較して, 同等もしくはそれ以上の分類精度であった。また, 表 5 に示すように, 入力情報の種類を 4 から 9, 下位概念数を 2 から 4 に増加させても, Gibbs-mMLDA と同等以上の分類精度があった。これらの結果は Deep-mMLDA が Gibbs-mMLDA と同等の学習をすることができ, 入力情報の種類数や下位層のモデル数に対して拡張性を持つことを示す。

続いて, RSB-mMLDA についてみると 4 入力条件では, 表 4 で示すように, RSB-mMLDA の分類精度は Gibbs-mMLDA の値を上回っているが, 上位トピック数を固定した Deep-mMLDA には劣る。また, 9 入力条件では, 表 5 で示すように Gibbs-mMLDA よりも劣る結果となった。

最後に, 推定した上位層のトピック混合比 θ を t-SNE で 2 次元へ圧縮し, 各モデルの上位層のトピック空間を定性的に調べた。図 5 に, それぞれの上位層のトピック空間を示す。各データ点は, 学習データに付与された Motion ラベルで色付けを行った。予めカテゴリ数を与えた Gibbs-mMLDA, Deep-mMLDA と同様に, トピック数をデータに応じて推定した RSB-mMLDA の上位層のトピック空間も, Motion ラベルに応じたクラスが形成されていることが分かる。これらの結果は, 提案手法にマルチモーダル情報に対して有効な上位層のトピックを推定できることを示唆する。

5. まとめ

本稿では, より効率的に大規模なマルチモーダル情報を学習できるトピックモデルの実現を目指し, ニューラルネットワークを用いた 2 種類のマルチモーダル情報のためのトピックモデルを提案した。Deep-mMLDA は, 文書分類のために提案された階層トピックモデルをマルチモーダル情報が扱えるように拡張したモデルであり, 学習のための損失関数の導出を行った。RSB-mMLDA は, Deep-mMLDA にディリクレ過程を導入し上位層のカテゴリ数推定を可能にしたモデルである。評価実験として, 最大 9 種のモダリティ情報で構成されるマルチモーダルデータに対して, Deep-mMLDA, RSB-mMLDA で学習を行い, その分類精度を先行研究と比較した。Deep-mMLDA は全条件において, RSB-mMLDA は 4 入力条件において従来

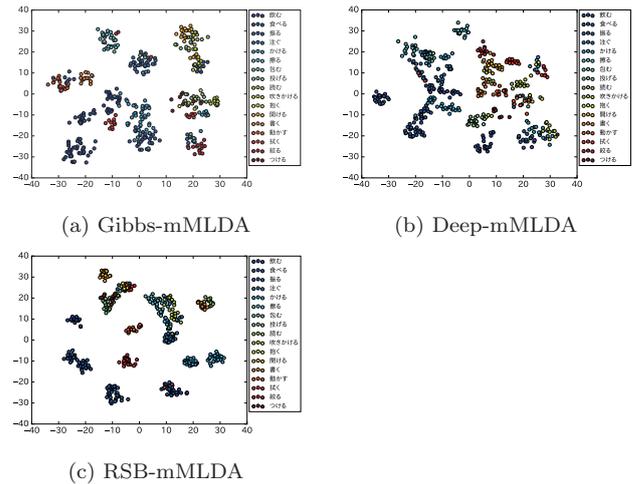


図 5: 4 入力における上位層の状態

の mMLDA と同等以上の分類精度を得る学習が可能であることが確認できた。また深層学習の並列化という特徴を生かし, 学習時間を大幅に削減した。

今後は, 本研究で提案した 2 つの提案モデルの学習結果が異なった要因を明らかにし, RSB-mMLDA においても全ての学習条件で従来の mMLDA と同等以上の学習結果が得られるようにモデルの改善を行う予定である。

謝辞

本研究は, JST CREST(JP-MJCR15E3) 及び JSPS 科研費 (17J10512) の支援を受けて実施した。

参考文献

- [Blei03] D M.Blei, A Y.Ng, M I.Jordan, “Latent Dirichlet Allocation”, Journal of Machine Learning Research 3, pp. 993-1022, 2003
- [Nakamura11] T Nakamura, T Araki, T Nagai, N Iwahashi, “Grounding of Word Meaning in Latent Dirichlet Allocation-Based Multimodal Concepts”, Advanced Robotics 25, pp. 2189-2206, 2011
- [Attamimi16] M Attamimi, Y Ando, T Nakamura, T Nagai, D Mochihashi, I Kobayashi, H Asoh, “Learning word meanings and grammar for verbalization of daily life activities using multilayered multimodal latent Dirichlet allocation and Bayesian hidden Markov models”, Advanced Robotics, pp. 806-824, 2016
- [Kingma13] D P Kingma, M Welling, “Auto-Encoding Variational Bayes”, arXiv:1312.6114, 2013
- [Srivastava17] A Srivastava, C Sutton, “Autoencoding Variational Inference For Topic Models”, ICLR, 2017
- [Srivastava18] A Srivastava, C Sutton, “Variational Inference In Pachinko Allocation Machines”, arXiv:1804.07944, 2018
- [Miao17] Y Miao, E Grefenstette, P Blunsom, “Discovering Discrete Latent Topics with Neural Variational Inference”, ICML, 2017

多変量時系列データの柔軟な分割方法の提案

Flexible segmentation for multi-dimensional time series data

真矢 滋*¹ 山口 晃広*¹ 稲木 達哉*¹ 植野 研*¹
Shigeru Maya Akihiro Yamaguchi Tatsuya Inagi Ken Ueno

*¹株式会社 東芝 研究開発センター システム技術ラボラトリー
System Engineering Laboratory, Corporate Research & Development Center, Toshiba Corporation

Along with the development of IoT technology, large amount of time series data are becoming available in recent years. To discover useful knowledge from time series data, the method of segmenting multivariate time series data into characteristic patterns has been receiving much attention. However, positions of segmentation obtained by previous methods are identical across variables, which makes difficult to capture the specific feature of each variable. To deal with this problem, we propose a new method that can obtain appropriate positions of segmentation for each variable. Moreover, we experimentally show the effectiveness of our proposed method using both artificial and real datasets.

1. はじめに

IoT 技術の普及に伴い、大量の多変量時系列データが取得可能になりつつある。そのため、これらの多変量時系列データから有用な知見を導き出す手法の研究開発が大きな注目を集めている。多変量時系列データから重要な知見を抽出する方法として近年、時系列分割方法が多く提案されている。時系列分割とは、元の多変量時系列データを性質が似ている期間ごと（以降、セグメントと呼ぶ）に分割する手法である。図 1(a) に時系列分割の例を示す。時系列分割の活用方法としてはまず、重要な時系列パターンの抽出が考えられる。一方で、分割が発生した時点では変数間の関係に何らかの変化が発生していると考えられる。そのため、故障などのイベント情報と照合することでイベントの発生原因を求めることができる。このように時系列分割は様々な場面での活用が見込まれている。

時系列分割を行う手法として、松原らは多変量時系列データを多階層連鎖モデルを用いて定式化し、MDL 原理を用いることでパラメータの設定を全自動で行う手法を提案した [Matsubara 14]。また Hallac らはネットワーク構造を用いて時系列データのモデリングを行い ADMM を用いた高速なアルゴリズムの提案を行った [Hallac 17]。これらの手法は様々な実データにも適用され、それぞれの文献で各ケースステディから有用な知見が得られた旨が報告されている。

一方で、情報伝搬をモデリングする際には、変数間のラグを考慮することが重要となる。例えば、ある商品がある地点で流行し、他の地域までその影響が及ぶのには時間がかかる場合が多い。この場合、ラグの影響をモデルに組み込むことで現象をより正しく理解することができ、様々な知識発見に役立てることができる。しかしながら、既存手法では変数に関わらず分割位置が同一でありこのような場合に対応することができなかった。そこで、提案手法では分割位置の変数間のラグを考慮した手法を提案する。提案手法による分割の概念図を図 1(b) に示す。実データにはノイズが含まれる場合も多い。そこで提案手法では、元データから正則化を用いてノイズ除去を行いつつ DTW (Dynamic Time Warping) を用いて変数間のラグを考慮した分割方法を提案する。

本研究の貢献は以下の通りである。変数間にラグがある場合

の時系列分割法を定式化し、効率的なパラメータ推定アルゴリズムを提案する。また、セグメント数などのハイパーパラメータを自動で決定する指針を示し、実データから様々な有用な知見を得られることを確認した。

2. 時系列データの分割

変数の数 (P)、各変数の時系列長 (T) からなる、時系列データを $\mathbf{x} \in \mathbb{R}^{P \times T}$ とする。本節では変数間のラグを考慮した提案手法の定式化を行う。分割するセグメント数を S とする。一方で、時系列データに周期性がある場合など同様の特徴を持つセグメントが複数出現する可能性があることが想定される。そこで、各セグメントをクラスタリングし、全クラスタ数を C とする。そして、 p 番目の変数の各セグメントの位置を $\mathbf{u}^p \in \mathbb{R}^{S+1}$ と示す。ただし、 s 番目のセグメントの位置を u_s^p とする。ま

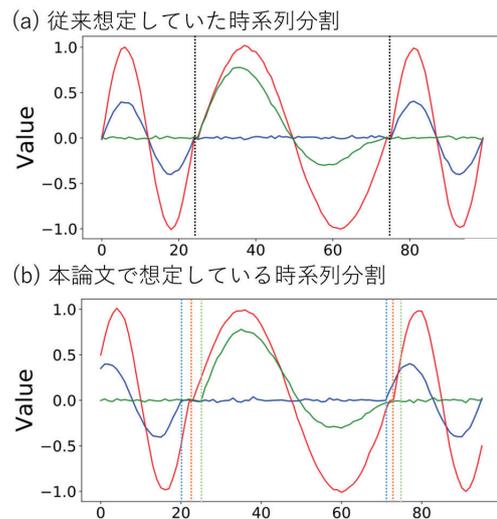


図 1: 時系列分割の例。破線が分割位置を示す。(a) 従来の時系列分割。各変数で同一箇所での分割。(b) 本論文で想定している時系列分割。変数ごとに対応する色の破線で示す箇所適切に分割。

た $u_1^p = 1$, $u_{S+1}^p = T$ とする. 本論文の目標は各変数ごとのセグメント位置を示す $u^p \in \mathbb{R}^{S+1}$ を求めることである.

2.1 ラグの扱いについて

本節では各セグメントで DTW を用いた場合のラグの表現方法について述べる. 提案手法で用いる DTW のワーピングパスを w とする. ワーピングパスの各要素はタプル (\cdot) で表し, 要素は各変数の値及び, セグメントのインデックスからなり $P+1$ 次元である. 1 から P 次元目は, 各変数の値を格納し, $P+1$ 次元目には, セグメントのインデックスとする. 図 2 に $P=2$, セグメント数 S が 2 の場合の例を示す. この例の場合は $w = [(1, 1, 1), (2, 1, 1), (3, 2, 1), (4, 3, 2), (4, 4, 2)]$ となる. そしてワーピングパスの長さを $|w|$ とする. この場合, $|w| = 5$ である. またワーピングパスのうちセグメントが s のものだけを抜き出したものを $w(s)$ とする. 例えば $w(1) = [(1, 1, 1), (2, 1, 1), (3, 2, 1)]$ である.

次に本論文では $\mathbf{x}_{i,p} \in \mathbb{R}$ を行列 \mathbf{x} の (i, p) 要素の値とする. また, $\mathbf{x}_{(a,b,c)} \in \mathbb{R}^{(b-a+1)}$ は行列 \mathbf{x} の第 a 行から第 b 行, 第 c 列を取り出した行列とする.

2.2 ノイズ除去の方法について

実際に観測される時系列データには様々な要因によりノイズが含まれている場合が多い. そこで, 時系列データを扱う場合にはノイズに対処する必要がある. 本節では, 元データ \mathbf{x} に含まれるノイズの除去の方法について述べる. 本論文ではノイズ除去後のデータを $\hat{\mathbf{x}} \in \mathbb{R}^{P \times T}$ とする. ノイズ除去後のデータに期待する条件を 2 点述べる.

1 点目はノイズ除去前のデータと除去後のデータの値が近いことである. ここで両者の差を $\mathbf{z} = \mathbf{x} - \hat{\mathbf{x}} \in \mathbb{R}^{P \times T}$ とするとこの差 \mathbf{z} はできるだけ小さくなることが望ましい.

2 点目は, 時系列データはある程度スムーズであるはずという仮定である. スムーズであるために, 本論文ではノイズ除去後のデータは隣接するデータと値がある程度近いはずという知見を盛り込む. p 番目の変数, s 番目のセグメントに関してスムーズ性を組み込んだノイズ除去の定式化を行う. $\hat{\mathbf{x}}_{(u_s^p:u_{s+1}^p-1,p)} \in \mathbb{R}^{u_{s+1}^p-u_s^p}$ を該当するデータのノイズ除去後のデータとする. この時スムーズ化を行うための目的関数は $\sum_{i=0}^{u_{s+1}^p-u_s^p-1} (\mathbf{x}_{(u_{s+i}^p,p)} - \mathbf{x}_{(u_{s+i+1}^p,p)})^2 = \hat{\mathbf{x}}_{(u_s^p:u_{s+1}^p-1,p)}^T \mathbf{G} \hat{\mathbf{x}}_{(u_s^p:u_{s+1}^p-1,p)}$ となる. ただし, $\mathbf{G} \in \{-1, 0, 1, 2\}^{u_{s+1}^p-u_s^p \times u_{s+1}^p-u_s^p}$ は三重対角行列で $(1, 1)$ 成分と $(u_{s+1}^p - u_s^p, u_{s+1}^p - u_s^p)$ の値は 1 で, それ以外の対角成分は 2 であり, 三重対角行列の非対角成分の値は -1 である.

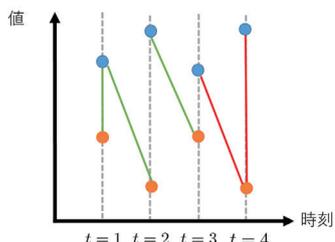


図 2: ワーピングパスの説明例. 橙が第 1 変数, 青が第 2 変数を示す. 緑の線, 赤い線はそれぞれ 1 つ目, 2 つ目のセグメントに対応するワーピングパス.

つまり

$$\mathbf{G} = \begin{pmatrix} 1 & -1 & 0 & \cdots & 0 \\ -1 & 2 & -1 & \cdots & 0 \\ 0 & -1 & 2 & \cdots & 0 \\ \vdots & & & \ddots & \\ 0 & 0 & 0 & \cdots & 1 \end{pmatrix}$$

となる.

2.3 変数間のラグを組んだセグメントについて

次に各セグメントを構成する条件について述べる. 各セグメントでは変数間に関係があることが期待される. 本論文では, 同一セグメント区間では, 各変数は他の変数で線形回帰が可能だと仮定する. つまり, 各セグメントではラグを考慮した場合に線形関係があると仮定する. この時, s 番目のセグメントが c 番目のクラスタに属している場合の回帰誤差は $\sum_{l=1}^{|w(s)|} (\mathbf{x}_{(s,l,p)} - \mathbf{x}_{(s,l,vp)} \boldsymbol{\theta}_{(c,p,:)})^2$ となる. ただし, $\mathbf{x}_{(s,l,p)} \in \mathbb{R}$ は s 番目のセグメントのワーピングパス $w(s)$ の l 番目のタプルの p 番目の変数とする. また, $\mathbf{x}_{(s,l,vp)} \in \mathbb{R}^{P-1}$ は s 番目のセグメントのワーピングパス $w(s)$ の l 番目のタプルの p 番目の変数以外の値を示す. また, $\boldsymbol{\theta} \in \mathbb{R}^{(C \times P \times (P-1))}$ は各クラスタにおける回帰係数であり, $\boldsymbol{\theta}_{(c,p,:)} \in \mathbb{R}^{P-1}$ は c 番目のクラスタにおける p 番目の変数以外を用いて p 番目の変数を回帰する際に用いる係数である. また, 実際の評価では通常の線形回帰と同様に切片の項も組込んでいるが, 簡単のため定式化では省略する.

2.4 提案手法の定式化

本節では, ノイズ除去後のデータ $\hat{\mathbf{x}}$ に変数間のラグを組んだセグメンテーションを行う提案手法の定式化を行う. この時, 最小化すべき提案手法の目的関数は

$$\begin{aligned} & \sum_{s=1}^S \sum_{p=1}^P \sum_{l=1}^{|w(s)|} (\hat{\mathbf{x}}_{(s,l,p)} - \hat{\mathbf{x}}_{(s,l,vp)} \boldsymbol{\theta}_{(\text{label}(s),p,:)})^2 \\ & + \frac{\lambda_1}{TP} \sum_{s=1}^S \sum_{p=1}^P \hat{\mathbf{x}}_{(u_s^p:u_{s+1}^p-1,p)}^T \mathbf{G} \hat{\mathbf{x}}_{(u_s^p:u_{s+1}^p-1,p)} \\ & + \frac{\lambda_2}{TP} \sum_{s=1}^S \sum_{p=1}^P \|\mathbf{z}_{(u_s^p:u_{s+1}^p,p)}\|_2^2 \\ & S.T. \mathbf{x} - \hat{\mathbf{x}} = \mathbf{z} \end{aligned} \quad (1)$$

となる. ただし, $\text{label}(s)$ は s 番目のセグメントが属すクラスタを示す. 上記の定式化には制約式を含む. このような制約式を含む最適化において, 近年 ADMM [Boyd 11] が幅広く用いられている [Zhou 17][Hallac 17].

3. パラメータの推定方法

本節では, 提案手法のパラメータ推定方法について述べる.

3.1 セグメント位置の更新方法

本節では, p 番目の変数に関するセグメント位置 u^p の求め方について述べる. 式 (1) で ADMM を用いるために拡張ラグランジュ法を適用した式に変換する. セグメント位置以外の変数を固定した際に, セグメント位置に関連する部分は $\sum_{s=1}^S \sum_{p=1}^P \sum_{l=1}^{|w(s)|} (\hat{\mathbf{x}}_{(s,l,p)} - \hat{\mathbf{x}}_{(s,l,vp)} \boldsymbol{\theta}_{(\text{label}(s),p,:)})^2$ である. そこで, この式の値をできるだけ小さくするようにセグメント位置の更新を行う.

提案手法では変数 p のワーピングパスを求める際に、 p 番目の変数以外のワーピングパスを固定し、 p 番目のワーピングパスとセグメント位置の更新を行う。ワーピングパス w の j 番目のタプルの p 番目の要素を $w_{j,p}$ とする。タイムワーピング行列 DP は

$$DP[i, j, s] = \text{Loss}(i, j, s) + \min \begin{cases} DP[i-1, j-1, s-1] \\ DP[i-1, j-1, s] \\ DP[i-1, j, s-1] \\ DP[i-1, j, s] \\ DP[i, j-1, s-1] \\ DP[i, j-1, s] \end{cases}$$

$$DP[1, 1, 1] = 0$$

$$\text{Loss}(i, j, s) = (\hat{x}_{i,p} - [\hat{x}_{w_{j,1},1}, \dots, \hat{x}_{w_{j,p-1},p-1}, \hat{x}_{w_{j,p+1},p+1}, \dots, \hat{x}_{w_{j,P},P}] \theta_{(\text{label}(s), p, :)})^2$$

$$(i = 1, 2, \dots, T; j = 1, 2, \dots, |w|; s = 1, 2, \dots, S) \quad (2)$$

となる。提案手法の場合は動的計画法において 6 通りのパスから最適なものを選択する。時系列長は T 、ワーピングパス長は $|w|$ であり、変数数が p なので上記の計算を各変数ごとに行うと計算量は $\mathcal{O}(PT|w|S)$ となる。

一方で、 $|w|$ の大きさは時系列長と同じオーダーであることが多い。そのため、実質的には計算時間は $\mathcal{O}(PT^2S)$ となり、時系列長に関して 2 乗で効くため効率的に計算することができない。この問題に対処するために、提案手法では Sakoe-Chiba Band を [Sakoe 78] 用いる。Sakoe-Chiba Band はワーピングパスを求める動的計画法において探索範囲を絞ることで計算時間の効率化を目指す方法である。現状の p 番目の変数に関するワーピングパスを抽出すると $[w_{1,p}, w_{2,p}, \dots, w_{|w|,p}]$ となる。そこで、提案手法では Sakoe-Chiba Band を用いて [Rong 17] 各回での変数 p のワーピングパスの更新の際に元のワーピングパスと最大でも m しかずれないとする。以上の手続きにより、探索範囲を絞ることで計算時間が $\mathcal{O}(mPTS)$ となり、各変数に関して線形の計算時間で計算できることが分かった。なお、本論文では $m = 10$ として実験を行った。

3.2 パラメータの決定方法

分割位置 (u^p) 以外のパラメータに関しては、目的関数全体では非凸関数だが、各パラメータに関しては凸関数である。そのため、紙面の都合上割愛するが交互最適化を用いることで局所最小解を得られる。

次に提案手法のハイパーパラメータの設定方法について述べる。単変量データからノイズを除去する方法として ASAP [Rong 17] によるとデータの尖度 (Kurtosis) をできるだけ元データの尖度と同じ値を取るように保ちながらデータの標準偏差を減少させる方法が提案されている。そこでノイズ除去の方針として、 $deg - noise = \sum_{p=1}^P ((\text{Kurt}(\mathbf{x}_{(:,p)}) - \text{Kurt}(\hat{\mathbf{x}}_{(:,p)}))^2 + \sigma(\hat{\mathbf{x}}_{(:,p)}))$ を指標とし、複数の $\lambda_1, \lambda_2, \rho, S, C$ の組合せから、この指標の値が一番小さくなる時の値を用いる。ただし、 $\text{Kurt}(\cdot)$ はデータの尖度を示す。

4. 実験

本節では人工データ、および実データを用いて提案手法の性能検証を行う。比較手法としては高階層連鎖モデルを用いた AutoPlait [Matsubara 14]、およびネットワークモデルを用いた TICC [Hallac 17] を用いる。なお、AutoPlait では MDL 原理を用いることでセグメント数を自動で決定することができる。

表 1: セグメント位置の正確性について

提案手法	AutoPlait	TICC
2	24	1224

4.1 データセットについて

まず、本節で用いるデータセットについて紹介する。

人工データの生成方法について述べる。 S, C, P をそれぞれ 5, 2, 4 と設定し、4 変数の変数名を a, b, c, d とする。2 つのクラスタを A, B とし、クラスタ A に関しては変数 a と b は正弦波に従い、変数 c と d は共に同じ直線に従う。一方、クラスタ B は変数 a, b, d 余弦波に従い、変数 c は定数値を取る。また、クラスタ A・クラスタ B で各変数で正規分布に従うノイズを加える。また、変数間のラグを表現するために、各クラスタで変数 $(a, b), (b, c), (c, d)$ 間の時間的ラグを設ける。そして、 $[A, B, A, B, A]$ とデータを連結し、セグメント数 5 クラスタ数 2 のデータを生成する。

また、実データに関しては、以下の 2 つを用いる。

- **GDP**: この実データセットは日本・ドイツ・インド・イタリア・カナダの GDP の値に関するものであり、単位は 10 億 US ドルである。データの取得期間は 1970 年から 2017 年までの 48 点である。なお本データセットは The World Bank <https://data.worldbank.org/> から取得可能である。
- **Piketty**: このデータセットはグーグルトレンドのクエリ検索により取得された実データセットである。クエリは日本・アメリカで Piketty という単語が検索数を示す。検索期間は 2004 年 1 月から 2018 年 11 月までで各月ごとに一回計測されている。そのためデータセットのタイムスタンプ数は 179 である。

4.2 考察

本節では、実験結果の考察を行う。

人工データに適用した場合の実験結果を図 3 に記す。 S, C の値は正解の値である 5, 2 を用いた。(a), (b), (c), (d) はそれぞれ提案手法、提案手法拡大図、AutoPlait, TICC の実験結果である。(a), (b) の破線は提案手法を適用した場合のセグメント位置を示す。(c), (d) の同一の色で塗られた区間は各手法で同一クラスタのセグメントを示す。セグメント位置を正しく検知できたかを判断するため指標として、正解のセグメント位置と各手法で得られたセグメント位置の中で最も近いものとの絶対値誤差を用いる。 p 番目の変数の正解のセグメント位置を u^{*p} とするとこの指標は $\sum_{p=1}^P \sum_{s=1}^S |u_s^{*p} - u_{\arg \min_s |u_s^{*p} - u_s^p|}|$ と定義される。この指標は値が小さいほど正確のセグメント位置に近いことを意味する。表 1 に結果を示す。表 1 および、図 3(a), (b) から提案手法の場合に最も正確にセグメント位置を検出できていることが分かる。提案手法では変数ごとにセグメント位置のラグを正しく表現できていることが分かる。一方、図 3(c) に示す AutoPlait では概ねセグメント位置を検出できているもののラグまでは表現することができていない。また、人工データでは各セグメントで正弦波などに従うように変数が時間発展している。図 3(d) に示す TICC ではセグメント内での時間発展をモデルに組み込めないため、正しいセグメント位置を求められなかったと考えられる。

次に実データを用いた場合の実験結果を紹介する。データセット Piketty, GDP で S, C ごとにそのほかのハイパーパ

表 2: 各データセットで (S, C) ごとの deg-noise の集計結果. deg-noise の値が最小となった (S, C) の組合せを太字で表示.

GDP	(2,2)	(3,3)	(4,4)
	4832.743	4778.887	4882.266
Piketty	(2,2)	(3,2)	(3,3)
	725.550	64.419	-

ラメータの値を変更した際に最小となった deg-noise の値を表 2 に記す. また選択された S, C とその時の deg-noise の値を太字で記す. なお, Piketty で $S = C = 3$ の場合, あるセグメントに属するタイムスタンプが存在しない結果となったため, 記入していない. 提案手法では deg-noise が最小となる場合の S, C の値を用いるので, GDP の場合は $(S,C)=(3,3)$, Piketty の場合は $(S,C)=(3,2)$ と設定した.

次に実データ GDP の結果を紹介する. このデータセットでは GDP の値がある程度似通った 5ヶ国のデータを用いる. 一方で経済発展のスピードは国や年度により大きく異なると考えられる. なお AutoPlait を適用した場合は自動決定したセグメント数が 1 となったため, 可視化からは除外した. 提案手法では S, C の値として 3, 3 が選択されその結果を図 4(a) に示す. またクラスタ数を 3 とした場合の TICC の実験結果を図 4(b) に示す. 両者を比較すると, 1 つ目のセグメント位置に関しては両者で大きな違いは見られない. 一方で, 2 つ目のセグメント位置に関しては提案手法を適用した場合に日本だけ他国よりセグメント位置が早い (1998 年) ことが分かる. 日本では 1990 年代のバブル崩壊以降の GDP が伸び悩んでおりそのような経済情勢を反映していると考えられる.

次に実データ Piketty の結果を紹介する. Piketty 氏はフランス出身の有名な経済学者であり, 世界的なベストセラーとなった “21 世紀の資本” の著者でもある. 英語の翻訳本は 2014

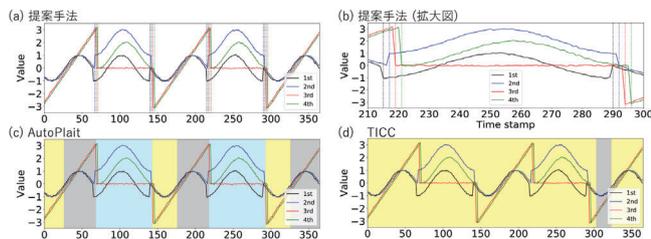


図 3: 人工データの実験結果.(a) 提案手法 (b) 提案手法 (拡大図) (c)AutoPlait (d)TICC

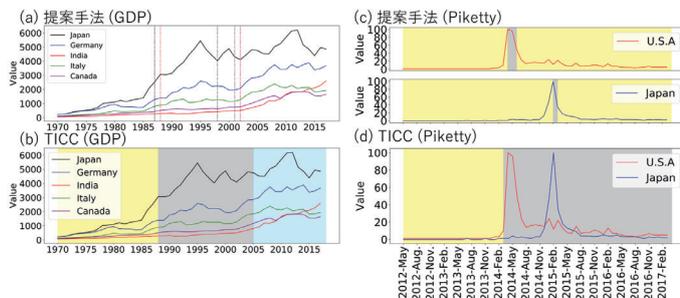


図 4: 実データの実験結果. (a) 提案手法 (GDP) (b)TICC(GDP) (c) 提案手法 (Piketty) (d)TICC(Piketty)

年 4 月に出版され, 日本語版は 2014 年 12 月に出版された. このデータセットには翻訳時期の差が反映されていると考えられる. 提案手法を適用した場合, $S = 3, C = 2$ となった. 図 4(c) からアメリカの場合, 日本の場合とも翻訳本の発売後の数か月が 2 つ目のセグメント期間に当たることが分かる. この期間は本が出版され一種のブームが起きていると考えられる. また提案手法を適用しば場合 1 つ目のセグメントと 3 つ目のセグメントは同一のクラスタである. ブームが一段落し, 3 つ目のセグメントの期間となると両者の検索数は落ち着き 1 つ目のセグメントと同じクラスタに属したと考えられる. 提案手法で選択されたクラスタ数が 2 であったため, TICC でクラスタ数を 2 にした場合の TICC の結果を図 4(d) に記す. TICC では変数間のラグが考慮できないため, アメリカでのブームは検知できるが, 日本でのブームは検知できないことが分かる. なお, AutoPlait の場合はセグメント数が 1 となり時系列データが分割されなかったため可視化からは除外した. このように, 提案手法を用いることで実データから様々な知識を発見することができた.

5. 結論

本研究では, 変数間の時間的ラグをモデルに組み込んだ多変量時系列データの分割方法のモデリングを行い, 効率的なパラメータの推定方法を提案した. また人工データから正しく変数間のラグを検知できることを確認し, 実データから有用な知見が導き出され, 提案手法の有効性を確認できた.

参考文献

- [Boyd 11] Boyd, S., Parikh, N., Chu, E., Peleato, B., Eckstein, J., et al.: Distributed optimization and statistical learning via the alternating direction method of multipliers, *Foundations and Trends® in Machine learning*, Vol. 3, No. 1, pp. 1–122 (2011)
- [Hallac 17] Hallac, D., Vare, S., Boyd, S., and Leskovec, J.: Toeplitz inverse covariance-based clustering of multivariate time series data, in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 215–223 (2017)
- [Matsubara 14] Matsubara, Y., Sakurai, Y., and Faloutsos, C.: Autoplait: Automatic mining of co-evolving time sequences, in *Proceedings of the 2014 ACM SIGMOD international conference on Management of data*, pp. 193–204 (2014)
- [Rong 17] Rong, K. and Bailis, P.: ASAP: prioritizing attention via time series smoothing, *Proceedings of the VLDB Endowment*, Vol. 10, No. 11, pp. 1358–1369 (2017)
- [Sakoe 78] Sakoe, H. and Chiba, S.: Dynamic programming algorithm optimization for spoken word recognition, *IEEE transactions on acoustics, speech, and signal processing*, Vol. 26, No. 1, pp. 43–49 (1978)
- [Zhou 17] Zhou, C. and Paffenroth, R. C.: Anomaly detection with robust deep autoencoders, in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 665–674 (2017)

[112-J-5] Web Intelligence

Chair:Yuichi Miyamura Reviewer:Masahiro Ito

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room I (306+307 Small meeting rooms)

- [112-J-5-01] An Empirical Method to Remove Reviews against the Guidelines for Restaurant Review Sites
○Yasutaka Shindoh¹, Atsunori Kanemura¹, Yusuke Miyao¹ (1. DG Lab, Digital Garage, Inc.)
1:20 PM - 1:40 PM
- [112-J-5-02] Predictive Analysis on Cyber-predators Using Various Social Network Structures
○Mao Nishiguchi¹, Fujio Toriumi¹ (1. The University of Tokyo)
1:40 PM - 2:00 PM
- [112-J-5-03] Proposal of Similar Area Discovery Based on Impression Extracted from Social Media
○Yasufumi Takama¹, Yosuke Sakamoto¹, Kenichiro Kobayashi², Takehiko Hashimoto² (1. Tokyo Metropolitan University, 2. GA technologies)
2:00 PM - 2:20 PM
- [112-J-5-04] Analysis of readers in Online News Service
○Atom Sonoda¹, Yoshifumi Seki², Fujio Toriumi¹ (1. The University of Tokyo, 2. Gunosy Inc.)
2:20 PM - 2:40 PM
- [112-J-5-05] Analysis of user activity of politics news cluster by user attributes
○Yoshifumi Seki¹, Mitsuo Yoshida² (1. Gunosy Inc, 2. Toyohashi University of Technology)
2:40 PM - 3:00 PM

ガイドラインに反するレビューを除去する レストラン・レビュー・サイト向けの実用的なフィルタリング処理

An Empirical Method to Remove Reviews against the Guidelines for Restaurant Review Sites

新堂 安孝 兼村 厚範 宮尾 祐介
Yusataka SHINDOH Atsunori KANEMURA Yusuke MIYAO

株式会社デジタルガレージ DG Lab
DG Lab, Digital Garage, Inc.

Restaurant reviews written by customers on the Web can influence many people when they decide what to eat. Offensive or irrelevant reviews are often posted to restaurant review services and they can make people displeased and ruin services' reputation. To avoid this, restaurant review service providers issue guidelines that define what are inappropriate reviews, and employ human workers to manually remove reviews violating the guidelines. Such manual operations incur high costs and automatic filtering is desirable. Unfortunately, although several filtering methods are available, their accuracy and efficiency are still not enough to work well on actual restaurant review services because of their costs, complexities, and reviews' noisiness. In this paper, we introduce a simple, accurate, and efficient method that detects whether a review violates guidelines or not, and show through experiments on real restaurant review data that the method works well under practical and difficult situations.

1. はじめに

モバイル・インターネットの普及とともにレストラン・レビュー・サイト (e.g. Yelp¹, Retty²) が広く定着し、消費者が何をどこで食べるかを考える際に強い影響を持っている [1, 2]. 一方で、同サイトには後述の例³のような攻撃的なレビューや飲食そのものとは無関係のレビュー (以降、これらのレビューをまとめて「不適切レビュー」と呼ぶ。不適切レビュー、特に飲食そのものとは無関係のレビューは、fake review [3] に包含されないことに注意) が投稿されることが多いが、これらは、レストラン経営者などからの訴訟を招いたり、ユーザーを不快にさせサイトの品質を悪化させる要因となる。

例: 攻撃的なレビュー

注文していないお酒を不正請求されました。意図的にやっていると思います。

例: 飲食そのものとは無関係のレビュー

以前より接客が雑になっている。14時30分から休憩をとるのに説明されてない。

このため同サイトを運営する企業は、悪影響が出る前に不適切レビューを削除する必要があるが、その自動化が難しいため、不適切レビューを明確にすべくガイドライン (e.g. Yelp⁴, Retty⁵) を用意した上で、作業者を雇用して同レビューを手手で除去せざるを得ない。この雇用に関するコストの高さは同サイトの運営の問題となる。

連絡先: 新堂 安孝 <shindo@dglab.com>

*1 <https://www.yelp.com/>

*2 <https://retty.me/>

*3 本論文では食べログの実レビューを適切に改変してレビュー例として記載する。

*4 <https://www.yelp.com/guidelines>

*5 <https://retty.me/announce/tos/>

そこで本研究では、実レストラン・レビュー・サイトの該当コストを削減すべく、以下の4条件を満たす不適切レビューのフィルタリング処理を logistic regression [4] と自立語の bag-of-n-gram [5] (以降、それぞれ LR および BoN と表記する) を用いて開発した。

- F1** 同処理の実システム導入に際し、追加コストを避けるため、新しい言語リソースを必要としない。
- F2** 同処理を実システムに容易に導入するため、構成がシンプルである必要がある。
- F3** レビュー (i.e. user-generated text) 特有の砕けた表現でも問題なく処理できる必要がある。
- F4** レビュー全体に対する不適切レビューの割合 (この割合はサイトに強く依存する) が低くとも問題なく処理できる必要がある。

また、食べログ⁶の実データを用いて評価し、同処理が実環境で高い性能を発揮することを示した。(補足: 本論文は、レストラン・レビューを主な対象に、国際会議 IEEE BigData 2018 に採択された論文 [6] を再構成したものである)

2. 関連研究

本研究に近い研究として、インターネット上の違法・有害情報 [7] を対象にしたコンテンツ・フィルタリングに関するもの [8, 9, 10] が知られている。これらの研究は、半自動生成した辞書の利用、大量の単語共起を用いた文書分類、係り受け情報を用いた文書分類などが特徴であるが、それぞれ、シード辞書は人手で生成する、語彙共起が大量になるため HDD や SSD などの追加ストレージが必要である、係り受け解析器は再学習なしでは砕けた表現で性能を発揮できない [11] という理由から、全て **F1-3** のいずれかを満たさない。また、節 1. の例「飲食そ

*6 <https://tabelog.com/>

のものとは無関係のレビュー」から容易に分かる通り、辞書を用いた手法では該当レビューの抽出が困難である。

3. 提案手法

我々は、BoN ベースの特徴ベクトルによる LR を用いてレビューが適切である (i.e. ガイドラインに反さない) 確率を算出するモデルを構築し、人手で不適切レビューを除去する作業の前に同モデルを導入する処理を提案する。同モデルが閾値以上の確率を与えたレビューは、人手の作業を介さずに適切なレビューであると判断する。

この処理により、人手の作業を大幅に減らすことが可能となる。また提案手法は、節 1. の 4 条件を以下の通り満たしている。(F3 および F4 については、後述の実験の結果によりその確かさが明らかになる)

- F1 使用する言語リソースは既存の形態素解析辞書のみであり、新しい言語リソースを作成する必要がない。
- F2 少数の比較的単純な技術 (e.g. LR, BoN) のみを用いており、構成はシンプルである。
- F3 くだけた表現を入力しても、処理そのものに支障が出ない技術のみを用いている。
- F4 閾値を変更する本手法は、片寄りのあるデータを適切に扱うことに向いている。

本研究では 4 種類の特徴ベクトルを比較する形で実験する。1 つのレビューに対して 1 つの特徴ベクトルを対応させ、BoN の n は「1 ($n=1$)」または「1 と 2 の両方 ($n=1,2$)」を、各要素の値は「レビュー内の各 n -gram の出現頻度 (integer)」または「レビュー内に各 n -gram が存在する/しない (boolean)」を、それぞれ考える。各組み合わせの特徴ベクトルを用いた合計 4 種類のモデルを表 1 の要領で **I1**, **I2**, **B1**, **B2** と示す。

表 1: 特徴ベクトルの種類とモデル

各要素の値	n -gram	
	$n=1$	$n=1,2$
integer	I1	I2
boolean	B1	B2

4. 実験

4.1 実装およびコーパス

本研究では、実験にあたり以下の要領で実装を選択した。

- 形態素解析環境: MeCab⁷ 0.996, UniDic⁸ 2.1.2
- LR: LIBLINEAR⁹ 2.1.0

また、実験で 2 種類のコーパスを用いた。

コーパスのうち 1 つは、2005 年から 2016 年に食べログに投稿されたレビューで、適切・不適切のフラグが付与されていない

い。内訳は表 2 の通りである。BoN で有効な n -gram は本コーパスに含まれるものとする。1-gram は本コーパスで 250 回以上出現した 40263 個を、2-gram は本コーパスで 100 回以上出現した 830353 個を、本研究ではそれぞれ用いた。この出現頻度による制限は、出現頻度の低い n -gram がモデルに悪影響を与えることを防ぐ狙いがある。

表 2: フラグなしコーパス内訳

レビュー数	単語数	1-gram 数
10^7	32×10^8	10^6

もう 1 つのコーパスは、2017 年 7 月から 2018 年 2 月に食べログに投稿されたレビューで、適切・不適切のフラグが人手により付与されている。内訳は表 3, 4 の通り¹⁰である。

表 3: フラグありコーパス内訳 (全体)

レビュー数	単語数	1-gram 数
1378273	389775791	403614

表 4: フラグありコーパス内訳 (月ごと)

収集月	レビュー数	収集月	レビュー数
2017/07	176745	2017/11	164838
2017/08	178885	2017/12	166180
2017/09	175416	2018/01	170253
2017/10	181708	2018/02	164248

4.2 実験 1

本実験では、モデル間の比較を行う。学習データとして 2017 年 7~12 月に収集したレビューを、試験データとして 2018 年 1~2 月に収集したレビューを、それぞれ用いた実験結果を図 1¹¹に示す。

同表から分かる通り、**B2** が最も性能が良く、次いで **B1** が良い。**I2** は、**I1** よりわずかに性能が悪く、全体で見ると最も性能が悪い。曲線の形としては、**I1** と **I2** が、**B1** と **B2** が、それぞれ似ている。

B2 が高い確率 (特に true positive rate で 0.8 に該当する閾値以上の確率) を与えた false positive のレビューを見てみると、その多くは目視確認する限り食べログのガイドラインを守っている。つまり、該当レビューは true positive と考えられる。ただし以下の例の通り、かつこが非常に多い、冒頭に飲食と無関係の情報が長く続いているなど、ガイドラインを守っているか否かの判断を人手で素早く実施することが困難なものが、そのほぼ全てを占める。この傾向は、人手の適切・不適切の判断にばらつきがあること、同時に **B2** が学習データのノイズに対して頑強であることを、それぞれ意味する。また **B2** は節 1. の条件 **F3**, **F4** を十分に満たしていると考えられる。

*7 <http://taku910.github.io/mecab/>

*8 <https://unidic.ninjal.ac.jp/>

*9 <https://www.csie.ntu.edu.tw/~cjlin/liblinear/>

*10 適切・不適切の内訳は食べログの機密情報のため掲載不可。

*11 本研究では全ての実験結果を ROC 曲線を用いて示す。

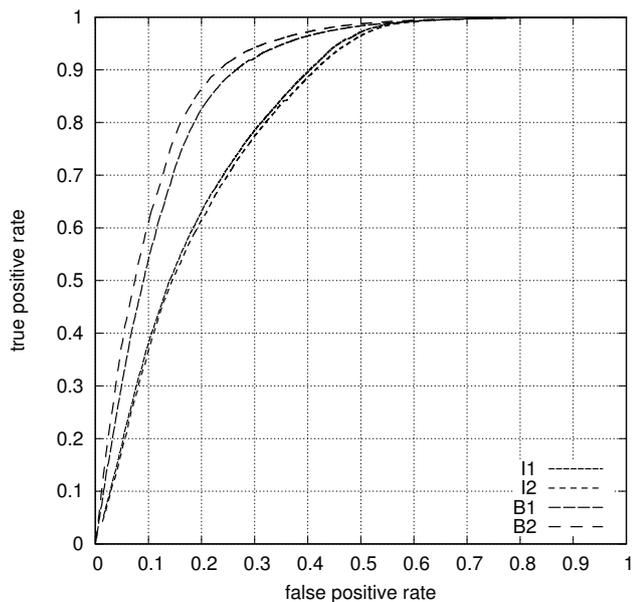


図 1: 実験 1 (各モデルの出力)

例: かつこが非常に多いレビュー

賽(さいころ)に容子(やうす)似(に)せる“黒砂糖(くろざとう)”
無農薬栽培(あやしげなるくすりぬき)の“紅茶(こふちや)”
肥後天草(ひごあまくさ)の“春子(かすご)”・“小鱈(こはだ)”

例: 冒頭に飲食と無関係の情報が続いているレビュー

福島県会津若松市出身の歴史上の要人は数多い。それは今でもよく知られているが、その偉業は忘れられている。

[skip over many sentences similar to the above sentences]

今回食べたソースかつ丼はこの店の名物だ。本当に上質の豚肉を使っていた。

[skip over many sentences that mention foods]

とてもおいしかった。再訪したい。

4.3 実験 2

本実験では、各モデルが学習データの量に対してどうふるまうかを確認する。各学習データ(以降、1mo, 2mo, 4mo, 6moと示す)として表 5 の期間に収集したレビューを、試験データとして 2018 年 1~2 月に収集したレビューを、それぞれ用いた。各モデルの実験結果を図 2-5 に示す。

表 5: 学習データ (実験 2)

収集期間	1mo	2mo	4mo	6mo
開始月	2017/12	2017/11	2017/09	2017/07
終了月	2017/12	同左	同左	同左

I2 (図 3) のみ、学習データが増えれば増えるほど性能が悪化している。これは、2-gram の総数が大きいことと各 n -gram の出現頻度がまちまちであることから、**I2** が複雑になりすぎた結果、古いレビューに強く適合する悪影響が発生した可能性が考えられる。また、食ベログのレビューが含む季節に強く依存した表現 (e.g. 蒸し暑い, 冷やしそうめん) も、悪影響を与え

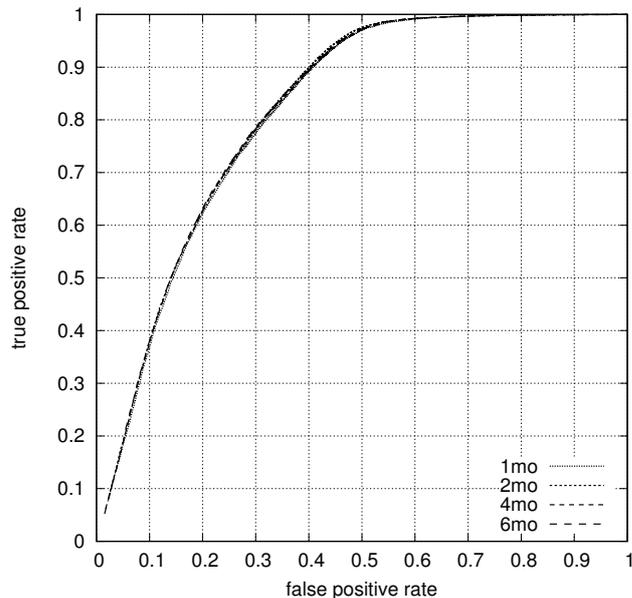


図 2: 実験 2 (I1 の出力)

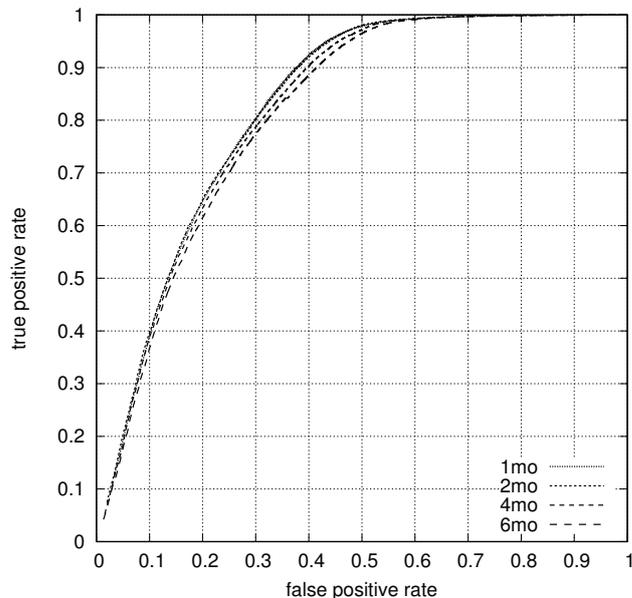


図 3: 実験 2 (I2 の出力)

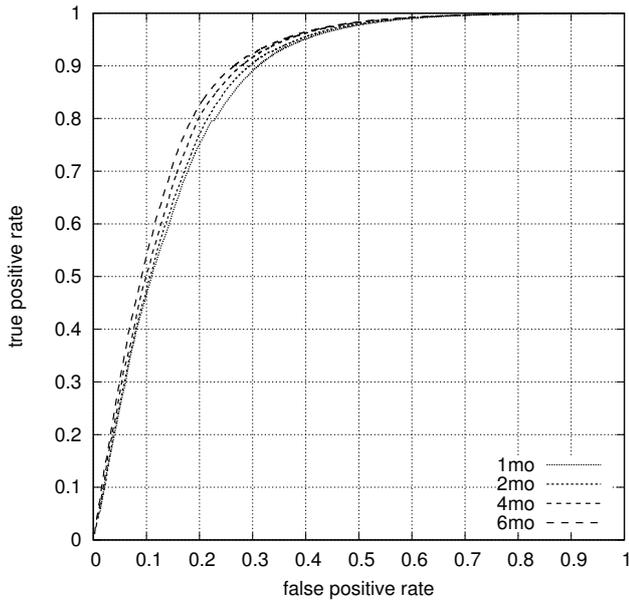


図4: 実験2 (B1 の出力)

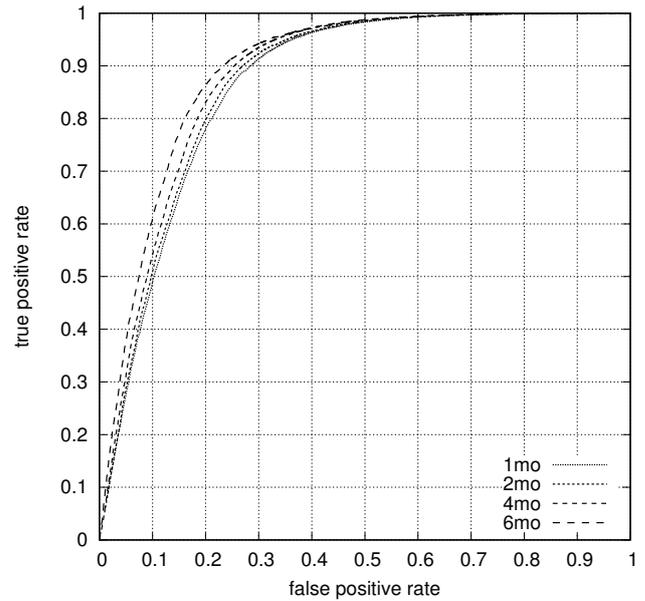


図5: 実験2 (B2 の出力)

た可能性がある。

一方で、**B1** (図4) および **B2** (図5) は、学習データが増えれば増えるほど性能が向上している。これは **B1** と **B2** の汎化性能が高いことを示していると考えられる。また **B1** と **B2** は、1ヶ月分の学習データ (1mo) を用いた結果でも、メール・フィルタリングで用いられる手法に近い **I1** より良い性能が出ている。

5. まとめ

本研究では、レストラン・レビュー・サイトに投稿される不適切レビューを人手で除去するコストを削減すべく、該当レビューを除去する実用的な手法を提案し、食ブログの実レビュー・データを用いて実験を行い以下の通りその有用性を示した。

- 実験を通し、不適切レビューを人手で除去するコストの80%程度を、最良のモデル **B2** で削減できる¹²ことが分かった。また同モデルについては、学習データが増えることで性能が向上する傾向を持つことが分かった。(節4.2および節4.3を参照のこと)
- 実システムに組み込む際に問題となる要素を考慮することで、実システム導入が容易な設計を実現できた。(節1.および節3.を参照のこと)

参考文献

- [1] MyVoice Communications, Inc. ネット上の口コミ情報に関するアンケート調査 (第4回). https://myel.myvoice.jp/products/detail.php?product_id=22515, 2017.
- [2] Japan Finance Corporation. 外食に関する消費者意識と飲食店の経営実態調査. https://www.jfc.go.jp/n/findings/pdf/seikatsu25_1218a.pdf, 2013.

- [3] Arjun Mukherjee, Bing Liu, and Natalie Glance. Spotting fake reviewer groups in consumer reviews. In *Proceedings of the 21st international conference on World Wide Web*, 2012.
- [4] David Cox. The regression analysis of binary sequences (with discussion). *Journal of the Royal Statistical Society B*, Vol. 20, pp. 215–242, 1958.
- [5] Alice Zheng and Amanda Casari. *Feature Engineering for Machine Learning*. O'Reilly Media, Inc., 2018.
- [6] Yasutaka Shindoh, Atsunori Kanemura, and Yusuke Miyao. A simple method to remove reviews against guideline for online review services. In *Proceedings of the 2018 IEEE International Conference on Big Data*, 2018.
- [7] Ministry of Internal Affairs and Communications. インターネット上の違法・有害情報に対する対応. http://www.soumu.go.jp/main_sosiki/joho-tsusin/d_syohi/ihoyugai.html, 2009.
- [8] Tatsuya Ishisaka and Kazuhide Yamamoto. Detecting nasty comments from BBS posts. In *Proceedings of The 24th Pacific Asia Conference on Language, Information and Computation*, pp. 645–652, 2010.
- [9] Kenji Nakamura, Shigenori Tanaka, Yuhei Yamamoto, and Satoshi Abiko. Method of filtering harmful information considering extraction range of word co-occurrence (in Japanese). *IPSJ Journal*, Vol. 54, No. 2, pp. 571–584, February 2013.
- [10] Kazushi Ikeda, Tadashi Yanagihara, Gen Hattori, Kazunori Matsumoto, and Yasuhiro Takishima. Hazardous document detection based on dependency relations and thesaurus. In *AI 2010: Advances in Artificial Intelligence*, pp. 455–465, 2010.
- [11] Satoshi Namba, Kenta Kadouchi, Yasuhiro Tajima, and Genichiro Kikui. マイクロブログに対する文境界推定および係り受け解析. In *Proceedings of the 21th Annual Meeting of the Association for Natural Language Processing*, 2015.

*12 ここでは不適切レビューの総数が適切レビューの総数より十分に小さいと仮定。

多様なソーシャルネットワーク構造を用いた cyber-predator 予測分析

Predictive Analysis on Cyber-predators Using Various Social Network Structures

西口 真央*¹ 鳥海 不二夫*¹

Mao Nishiguchi

Fuji Toriumi

*¹東京大学

The University of Tokyo

In this paper, we use the information of social network structures to tackle cyber-predator detection in a social networking service, and compare and analysis the explanatory power of these structures. We first create networks from various perspectives such as footprints and reactions to posts as well as conversations. By applying Large-scale Information Network Embedding (LINE) to these networks, latent representations based on each network structure are extracted. Using these latent representations as input features, we develop classification models for predicting cyber-predators. As a result of computational experiments, we confirmed that many social network structures are effective for detecting cyber-predators. In addition, we got some interesting findings, such as “the tendency of cyber-predator appears most strongly in the profile browsing history”. The findings obtained in this paper are used to suppress minors’ cybercrime damage.

1. はじめに

近年、オンラインコミュニティを介した未成年者の誘い出しやいじめなどの犯罪被害が増加傾向にある。警察庁の調査によると、特に複数人での交流が可能なソーシャルネットワーキングサービス (SNS) に起因する被害児童数が顕著に増加しており、その数は過去最多となっている [警察 17]。スマートフォンや SNS を日常的に利用する事が一般的となった現代において、サイバー犯罪の加害者、いわゆる cyber-predator を正確に検知し上記のような事犯を限りなく抑えることが、喫緊の社会的課題の 1 つとなっている。

これまでも、cyber-predator をシステム的に検知するための研究は数多く行われてきた [Nahar 13, Huang 14, F. Toriumi 15, Cardei 17, Liu 17]。cyber-predator 検知には、会話から抽出されたテキストコーパスを入力とするものが多いが、コーパスのみを用いたモデルでは予測性能に限界がみられる [Huang 18]。近年では、テキストコーパス以外にも、ユーザ属性やユーザ間の会話の有無から得られるネットワーク構造を活用する手法も盛んに提案されており、これらの入力は検知精度の向上に貢献することが実験的に示されている [Nahar 13, Huang 14, F. Toriumi 15, Cardei 17]。

しかしながら、既存研究の多くは事後的、すなわち cyber-predator との接触後に検知することを想定したものであり、接触自体を防ぐことは難しい。サイバー犯罪を抑えるためには、cyber-predator をいち早く検知し、接触を未然に防ぐ仕組み作りもまた重要である。また、近年の主要な SNS におけるユーザ同士の繋がり、会話の他にもフォローや通報、ブロックなど、様々な定義のネットワークが考えられるが、これらのネットワーク構造を活用した cyber-predator 検知に関する研究は、我々が知る限りまだ無い。

以上の背景を踏まえ、本研究では、cyber-predator 未然検知システムを構築する第 1 歩として、未成年者が多く存在する複数交流形 SNS 内に蓄積された実データを利用し、様々な種類のソーシャルネットワーク構造の有用性を比較分析する。ソーシャルネットワークは一般的に大規模かつ疎であり、ネット

ワーク構造をそのまま活用することは困難である。そこで我々は、[Tang 15] によって提案された Large-scale Information Network Embedding (LINE) により、ネットワーク構造を低次元のベクトル空間で表現することを試みる。LINE は、エッジの重みや向きも考慮可能な、大規模ネットワーク構造に適した分散表現獲得手法の 1 つである。我々はまず、各種ネットワーク構造から分散表現を独立に学習する。次に、cyber-predator を予測するための適切なクラス分類問題を設定し、それぞれの特徴量を入力としたモデルを個別に構築することで、各種ネットワーク構造の有用性を比較検証する。

次章では、cyber-predator に関連する既存研究について紹介する。続く第 3 章では、分散表現獲得手法である LINE を説明する。第 4 章では計算実験の設定及び結果について議論する。最後に、本研究で得られた知見と今後の課題について述べる。

2. 関連研究

本章では、大規模データからの cyber-predator の自動検知に関する既存研究について議論する。検知モデルの入力に最も利用されてきたデータセットは、ユーザ同士の会話内容から抽出されたテキストコーパスである。テキストコーパスは、モデルに対する強い説明力である一方、Bag of Words などの単純な特徴だけでは検知精度に限界がある [Huang 18]。そのため、近年ではコーパス以外のデータも利用する研究も盛んに行われている。

SNS に蓄積されたコーパス以外のデータセットの中で、注目されているものの 1 つが、ユーザ間の繋がりを表すソーシャルネットワークデータである。[Nahar 13] は、過去にサイバー空間上で行われたいじめの被害者と加害者を一種のソーシャルネットワークとして表現し、次に最も活発なサイバーいじめが行われるリンクを識別する手法を開発した。ユーザ間のソーシャルネットワークが、サイバー犯罪の検知に寄与することは、その他の研究でも示唆されている。[Huang 14] は、テキストコーパスに加え、[Nahar 13] と同様にサーバー空間におけるいじめの加害者-被害者ネットワークを構築し、独自に定義したネットワーク構造の分散表現などをモデルの入力として

連絡先: 西口 真央, 東京大学, 東京都文京区本郷 7-3-1, 03-5841-6991, nishiguchi@crimson.q.t.u-tokyo.ac.jp

与えることで、予測性能の改善に成功した。[F. Toriumi 15]では、ユーザ間の会話をエッジとみなした有向ネットワークを作成し、ネットワーク構造に基づくクラスタリング分析を行ったところ、誘い出しを受けるユーザの構造と誘い出す側のユーザとの間に、明確な違いがあることを確認した。

これらの既存研究は、ソーシャルネットワークが cyber-predator 検知に効果的であることを示した価値のある研究であるが、我々は大きく2つの課題が残されていると考える。1つ目は、すでに事犯が発生した後のネットワーク構造を利用している点である。犯罪被害をさらに抑えるためには、cyber-predator である可能性が高い者との接触自体を未然に防ぐことが望ましい。2つ目は、既存の研究で定義されたソーシャルネットワークが、直接的な会話の有無により定義されるものに限定されていることである。現在の主要な SNS には、ユーザ同士の会話以外に、フォローやコメント、リツイートといった機能があり、これらも1種のソーシャル関係を意味する。ネガティブなものでは通報やブロックといった繋がりも、ソーシャルネットワークとして捉えることができる。

したがって、本研究では、事犯が発生するより以前のデータのみを利用し、検知することを試みる。また、様々なソーシャルネットワーク構造を定義し、それらの構造が検知に与える影響を横断的に比較する。次章では、ネットワーク構造からの分散表現獲得手法について説明する。

3. ネットワーク構造の表現学習

近年のネットワークデータの大規模化に伴い、より低次の空間でネットワークを表現する手法が盛んに開発されている。ネットワークの持つ情報を低次元で正確に表現することができれば、クラスタリングや分類問題、推薦システムなどの様々なタスクが適用可能となる。

LINE は、大規模ネットワークからの高速かつ正確な分散表現の獲得が可能な手法の1つである [Tang 15]。LINE には、ノード間の直接的な接続に基づく局所的な構造を保存する LINE(1st) と、ノードの共有に基づく大域的な構造を保存する LINE(2nd) の2種類の手法が提案されている。どちらの手法もエッジの重みを入力可能であるが、LINE(1st) は基本的に無向ネットワークのみを対象としているのに対して、LINE(2nd) は有向ネットワークにも適用可能である。本稿で取り扱うネットワークは全て重み付き有向ネットワークであるため、今回は LINE(2nd) のみを利用する。

LINE(2nd) の学習プロセスを説明する前に、本章で扱うネットワークを定義する。ノード集合 V 、および有向エッジ集合 E が与えられたとき、有向ネットワークは $G = (V, E)$ と定義される。各エッジ $e \in E$ はノードの順序付きペア $e = (u, v)$ であり、ノード間の接続の強さを表す重み $w_{uv} > 0$ を持つ。LINE(2nd) の目的は、各ノード $v \in V$ を、ある低次元空間 R^d で表現することである。ただし、 $d \ll |V|$ である。

LINE(2nd) では、あるノードは他のノードの文脈という役割が与えられる。そして、文脈にわたり類似の分布を有するノードは類似していると仮定する。LINE(2nd) は、この仮説を経験的に表現した確率分布 $\hat{p}(\cdot|v_i)$ と、分散表現ベクトルの内積により得られる確率分布 $p(\cdot|v_i)$ との間の差を最小化するように学習する。LINE(2nd) が解く目的関数は式 (1) で定式化される。

$$O = \sum_{i \in V} \lambda_i d(\hat{p}(\cdot|v_i), p(\cdot|v_i)) \quad (1)$$

ここで、 $d(\cdot, \cdot)$ は2つの確率分布間の距離であり、相対エント

ロピーによって算出される。 λ_i はネットワーク内のあるノード i の重要度を表しており、 $\lambda_i = d_i$ 、 $d_i = \sum_{k \in N(i)} w_{ik}$ である。ここで $N(i)$ はノード v_i の出次近傍である。

経験的確率分布は式 (2)、分散表現の内積から得られる確率分布は式 (3) で定義される。

$$\hat{p}(v_j|v_i) = \frac{w_{ij}}{d_i} \quad (2)$$

$$p(v_j|v_i) = \frac{\exp(\vec{u}_j^T \cdot \vec{u}_i)}{\sum_{k=1}^{|V|} \exp(\vec{u}_k^T \cdot \vec{u}_i)} \quad (3)$$

ここで、 \vec{u} はノードの役割の時の v_i の表現であり、 \vec{u}_i' は特定の文脈として扱われる時の v_i の分散表現を意味する。 $|V|$ は文脈の数である。

LINE はまた、最適化プロセスにおいて、negative sampling およびエッジサンプリングにより、高速かつ正確な表現学習を実現している。最適化手法の詳細は [Tang 15] を参照されたい。

4. 計算機実験

以下ではまず、実験に使用するデータセットや事前パラメータ、評価方法について説明する。その後、実験結果について議論する。

4.1 cyber-predator の予測

4.1.1 データセット

本研究では、株式会社ナナムエ^{*1} が運営している「ひま部」^{*2} という複数交流形 SNS において蓄積されたデータを使用する。ひま部は、メインターゲットを学生とした SNS であり、本研究のテーマに適したデータセットを保有している。ひま部が提供する主な機能は、昨今の主要な SNS と同様に、個人間や複数人でのチャット、文書や画像の投稿、そして投稿に対する返信や絵文字などによるリアクションである。ひま部では、サイバーリスクの自己対策のために、特定のユーザをブロックする機能や、ユーザや投稿などを運営に通報するといった行動が可能である。また、誘い出しや公序良俗に反する投稿などを行なったと運営が判断した場合、アカウントが停止され、今後一切サービスの利用ができなくなる。今回の実験では、アカウントが停止されたユーザを cyber-predator と定義する。

このようなサービス特性を踏まえ、我々は以下のアクションからソーシャルネットワークを定義する。

- フォロー：お気に入りのユーザを登録する行動。フォローを行うことにより、フォローしたユーザの投稿閲覧やチャットが容易になる。フォローしたユーザからフォローされたユーザに向かって有向エッジが接続される。フォローは1度しか行われないため、エッジの重みは1のみである。
- フォロー保留：フォローの申請があつたにも関わらず、フォローを許可しない行動。これをネガティブな意思表示と捉え、フォローとは別のネットワークとして定義する。エッジの重みは1のみである。
- 足跡：他ユーザのプロフィールページの閲覧行動。プロフィールを閲覧する行為は双方向的なコミュニケーション

*1 <https://nanameue.jp/ja>

*2 <https://himabu.com/>

ンではないが、特定のユーザに対する何かしらの興味を表す行動であると考えられる。プロフィールを閲覧したユーザから閲覧されたユーザに向かって有向エッジが接続される。エッジの重みは閲覧回数とする。

- チャット：1対1でのメッセージの送受信履歴。メッセージを送信したユーザから受信したユーザに向かって有向エッジが貼られる。エッジの重みは送信回数とする。
- コメント：他ユーザの特定の投稿に対し、コメントする行動。投稿したユーザと、コメントしたユーザがエッジで結ばれる。エッジの重みはコメント回数とする。
- リアクション：他ユーザの特定の投稿に対し、絵文字によりポジティブな感情を示す行動。リアクションしたユーザから投稿したユーザへ向かって有向エッジが接続される。エッジの重みはリアクション回数とする。
- ブロック：特定のユーザからの個人チャットの受信や検索結果への表示を制限する行動。ネガティブな感情を表すネットワークである。ブロックしたユーザからブロックされたユーザに対して有向エッジが接続される。エッジの重みは全て1である。
- 通報：特定のユーザを、不適切なユーザであると運営に報告する行動。これも直接的な交流ではないが、ネガティブな感情を表すネットワークを作成可能である。通報したユーザから通報されたユーザに対して有向エッジが接続される。エッジの重みは全て1である。

各ネットワークの基本的な統計量を表1に示す。それぞれ

表1: 各ネットワークの統計量

ネットワーク	ノード数	エッジ数	平均入次数	平均出次数
フォロー	334,099	10,776,111	32.8	61.2
フォロー保留	119,776	295,895	20.3	2.7
足跡	496,393	28,429,788	60.7	92.8
チャット	146,137	1,595,801	11.3	12.3
コメント	73,163	348,562	5.2	6.1
リアクション	227,050	10,029,191	46.7	73.9
ブロック	103,422	341,814	3.6	9.1
通報	160,802	236,514	2.0	3.6

大きさは異なるが、1,000万以上のエッジを持つ比較的大規模なネットワークも対象となっている。また、ノードの数に対する入次数の数から、比較的疎なネットワークであることも確認できる。

4.1.2 評価方法

前節で定義した各ソーシャルネットワークから、LINE(2nd)によりそれぞれ分散表現を獲得する。ネットワークの作成に使用した期間は、2018年8月28日から2018年9月28日までの1ヶ月間である。各ネットワーク構造の有用性を比較するために、分散表現を入力特徴とした2クラス分類問題を設定する。対象となるユーザは、2018年9月21日までにインストールし、最終ログイン日が2018年8月28日以降のユーザ、かつ2018年9月28日までにアカウントが停止していないユーザである。対象ユーザのうち、2018年9月29日から10月31日の間にアカウント停止されたユーザを Predator クラス、それ以外のユーザを Normal クラスに分割する。

分類アルゴリズムには Random Forest [Liaw 02] を使用する。ただし、全体に占める Predator クラスの割合は1%未満と極端に不均衡なデータセットであり、Random Forest を単

に適用するだけでは良いモデルを構築することが困難である。また、各ネットワークは対象となるユーザが異なる。例えば、足跡やフォローといった行動は多くのユーザが行うが、通報を行うユーザは比較的少ない。そのため、クラス比にも違いが生じており、そのままでは正確な比較が難しい。

そこで我々は、アンダーサンプリング及び擬似データの生成によって、各ネットワークのクラス比を統一する。まず、ランダムなアンダーサンプリングにより、クラス比を1:9にする。その後、Synthetic Minority Over-sampling Technique (SMOTE) [Chawla 02] により、クラス比が3:7になるように、Predator クラスの擬似データを生成する。SMOTEは、元のデータに近い新たなインスタンスを生成することが可能であり、オーバーサンプリングによく利用される。モデルの評価には10分割交差検証法を利用し、F1値およびPrecisionとRecallにより評価する。

4.1.3 事前パラメータ

LINE(2nd)には、いくつか事前に設定するパラメータが存在する。分散表現の次元数、negative sampling数、そしてエッジサンプリング数である。次元数とnegative sampling数は、全てのネットワークでそれぞれ100と5に設定する。エッジサンプリング数は、各ネットワークの総エッジ数の約50%に設定する。

Random Forest を構成する決定木の数は50、分岐ルールにはGini係数を使用する。各決定木の最大深さは7、各葉が分岐を行うための最小インスタンス数は20に設定する。また、今回は不均衡データであるため、クラス比に応じてインスタンスの重みを調整する。

4.2 計算結果

以上の条件により、計算機実験を行なった結果を表2に記載する。全体的な評価をみると、対象とした8つのネットワー

表2: 評価値

ネットワーク	F1値	Precision	Recall
フォロー	0.571	0.620	0.530
フォロー保留	0.601	0.670	0.545
足跡	0.637	0.626	0.648
チャット	0.563	0.583	0.544
コメント	0.565	0.653	0.497
リアクション	0.505	0.522	0.502
ブロック	0.586	0.608	0.566
通報	0.560	0.631	0.504

クはある程度の説明力を有するが、極端に高い予測性能のモデルは存在しておらず、ネットワーク構造情報だけでは予測に限界があることが確認できる。

それぞれのネットワークの評価値を比較していく。最もF1値が高かったネットワークは足跡であり、これは興味深い結果である。足跡は、フォローやチャットからなる一般的なネットワークに比べ、比較的弱い繋がりであるが、その分敷居の低い接触である。この結果から、足跡には、どのようなユーザに声を掛けるべきか、獲物を見定めているパターンが隠れているのではないかと考えられる。単純な足跡をつけた回数を比較しても、Normalクラスの中央値は15回であるのに対し、Predatorクラスは183回であったことから、Predatorが多くユーザのプロフィールにアクセスしていることが分かる。Predatorクラスに顕著な足跡ネットワーク構造のパターンを明らかにすることは、今後の課題である。

足跡の次に F1 値が高いネットワークは、フォロー保留とブロックであった。これらは、ネガティブな感情を表すネットワークであるため、説明力が強いことは直感的にも理解できる。フォローとフォロー保留を分けてネットワークの構築を行うことが有用であることが明らかとなった。

逆に予測性能が相対的に低いネットワークは、リアクションと通報であった。リアクションは、足跡の次に大規模で緩いコミュニケーションであるが、Predator クラスの識別にはあまり寄与しないようである。一方の通報は、クラス定義と密接に関係しているように思われるが、今回の分類タスクが未然検知であり、既にアカウント停止されたユーザが対象外であったため、まだ通報という形で顕在化していない状態であることが原因であると考えられる。また、表 1 から分かるように、通報ネットワークは特に疎なデータであった。[Tang 15]でも議論されているが、次数の少ないノードの分散表現を得ることは一般的に困難である。今後は、[Tang 15]で行われていた前処理のように、2次近傍の接続まで考慮するなどの工夫により、ネットワークの密度も高くした上での比較実験も行なっていく。

5. おわりに

本稿では、ソーシャルネットワーク構造を利用した cyber-predator 未然予測モデルの構築を行なった。本稿の貢献は、これまであまり注目されていなかったプロフィール情報の閲覧や、フォローの保留など、様々なネットワークを定義し、公正な比較分析を行なった点である。モデルには、大規模かつ疎な重み付き有向グラフのネットワークに対して LINE(2nd) を適用し、構造を保存した分散表現を入力として与えることで、意味のあるモデルの構築に成功した。本稿で得られた知見は以下のとおりである。

- 多くのソーシャルネットワーク構造が、cyber-predator の検知に有効である
- 直接的な会話ネットワークよりも、プロフィール情報の閲覧という弱い繋がりが、cyber-predator の未然検知において強い説明力を持つ
- フォローとフォロー保留を区別することで、予測性能が向上する可能性がある
- ユーザのブロックや運営への通報により作成されたネットワーク構造は、未然検知においては説明力が比較的弱い

今後は、単に予測するだけでなく、cyber-predator 集合にはどのような構造パターンが出現しているのかを分析し、予測の妥当性を明らかにしていく。また、テキストコーパスやユーザ属性から得られる特徴も追加し、予測モデルのさらなる性能向上を図り、実サービスへの実装を通じてサイバー犯罪の抑止に貢献していく。

謝辞

本研究は RISTEX 「未成年者のネットリスクを軽減する社会システムの構築」プロジェクトの助成を受けた研究である。また、貴重なデータをご提供いただいた株式会社ナナムエの皆様にご感謝申し上げます。

参考文献

[Cardei 17] Cardei, C. and Rebedea, T.: Detecting sexual predators in chats using behavioral features and imbal-

anced learning, *Natural Language Engineering*, Vol. 23, No. 4, pp. 589–616 (2017)

[Chawla 02] Chawla, N. V., Bowyer, K. W., Hall, L. O., and Kegelmeyer, W. P.: SMOTE: synthetic minority over-sampling technique, *Journal of artificial intelligence research*, Vol. 16, pp. 321–357 (2002)

[F. Toriumi 15] F. Toriumi, M. T., T. Nakanishi and Eguchi, K.: Analysis of User Behavior on Private Chat System, in *2015 IEEE / WIC / ACM International Conference on Web Intelligence and Intelligent Agent Technology*, pp. 1–4 (2015)

[Huang 14] Huang, V. K. S., Qianjia and Atrey, P. K.: Cyber Bullying Detection Using Social and Textual Analysis, in *Proceedings of the 3rd International Workshop on Socially-Aware Multimedia*, pp. 3–6, New York, USA (2014), ACM

[Huang 18] Huang, V. K. S., Qianjia and Atrey, P. K.: On cyberbullying incidents and underlying online social relationships, *Journal of Computational Social Science*, Vol. 1, No. 2, pp. 241–260 (2018)

[Liaw 02] Liaw, A., Wiener, M., et al.: Classification and regression by randomForest, *R news*, Vol. 2, No. 3, pp. 18–22 (2002)

[Liu 17] Liu, D., Suen, C. Y., and Ormandjieva, O.: A Novel Way of Identifying Cyber Predators, *arXiv preprint arXiv:1712.03903* (2017)

[Nahar 13] Nahar, V., Li, X., and Pang, C.: An effective approach for cyberbullying detection, *Communications in Information Science and Management Engineering*, Vol. 3, No. 5, p. 238 (2013)

[Tang 15] Tang, J., Qu, M., Wang, M., Zhang, M., Yan, J., and Mei, Q.: LINE: Large-scale Information Network Embedding., in *WWWACM* (2015)

[警察 17] 警察庁：平成 29 年上半期におけるコミュニティサイト等に起因する事犯の現状と対策 (2017)

ソーシャルメディアからの印象抽出に基づく類似エリア判定手法の提案

Proposal of Similar Area Discovery Based on Impression Extracted from Social Media

高間 康史
Yasufumi Takama*1

坂元 陽亮
Yosuke Sakamoto*1

小林 賢一郎
Kenichiro Kobayashi*2

橋本 武彦
Takehiko Hashimoto*2

*1 首都大学東京大学院システムデザイン研究科
Graduate School of System Design, Tokyo Metropolitan University

*2 株式会社 GA technologies
GA Technologies

This paper proposes a method for finding similar areas in terms of impression. Nowadays, social media is one of our important resources, from which we can obtain subjective information, such as the impression of some products and places. Such information is expected to be useful when looking for the places to live. The proposed method constructs an emotional word dictionary and uses it to extract the impression of the area around a station from reviews. The similarity between stations is calculated based on the extracted impression. This paper compares the quality of dictionaries constructed with different methods and shows the accuracy of the similarity judgment.

1. はじめに

本稿では、不動産分野における印象を用いたエリア推薦を目的として、レビューから印象を抽出するための感情語辞書構築手法、及び類似エリア判定手法を提案する。ソーシャルメディアは製品や場所などに対する主観的意見が得られる貴重な情報源であり、居住地を探す際にも有益と考えられる。提案手法では、駅周辺に対して投稿されたレビューから印象を抽出し、その結果に基づき印象の類似する駅を推定する。感情表現辞典に対し、類義語やブログデータなどからブートストラップにより抽出した語を追加して感情語辞書を構築し、辞書とレビューとのマッチングによって印象を計算する。ラベル付きレビューを用いた印象抽出精度評価と、クラウドソーシングによる類似度判定精度評価を通じて、提案手法の有効性を検証する。

2. 関連研究

テキストからの感情・印象抽出は、様々な感情分類手法と抽出手法の組み合わせによる手法が提案されている。山本らは、感情表現辞典 [中村 93] の 10 感情を用いて、文章データセットにおける語の共起関係から感情語辞書を作成し、Twitter に投稿されたツイートからの辞書マッチングによる感情抽出手法を提案している [山本 14]。地域情報の利用に関して、Yao らは周辺地域の安全性が家の価値に影響を与えるとの考えに基づき、犯罪履歴などの統計データに基づく価値推定手法を提案している [Yao16]。

3. 提案手法

3.1 感情語辞書の作成

提案手法で使用する感情語辞書は、感情表現辞典 [中村 93] をベースに構築する。本書で定義されている 10 感情から「恥」を削除、「怒」「昂」を「驚」に併合して、7 感情として感情語辞書を作成する。本辞書は多くの関連研究で利用されているが、出版が 1993 年であり、現代的な文章の多いレビューで使用される語の多くが収録されていないことが想定されるため、類義語およびブログデータなどからブートストラップにより抽出した語を追加することで現代語に対処する。

表 1: 印象と感情の対応関係

印象	感情 (positive)	感情 (negative)
好感度	好	厭
安心度	安	怖
興奮度	驚	
楽しさ	喜	
哀しさ	哀	

類語辞典として日本語 WordNet と Weblio 類語辞典を用い、感情表現辞典中の感情語に対する類義語に、元の感情語と同じ感情ラベルを付与して感情語辞書に追加する。このとき、類義語抽出の精度向上のため、相互類義関係にある語句のみを感情語辞書に追加する。

ブートストラップ [Hearst92] は、少数の語をシードとして利用して、大規模な文章データから同位語などを取得するアプローチである。提案手法では、IDR で提供されている不満調査データセット *1 と芸能人のブログから抽出したブログデータから、反復回数 1 回のブートストラップにより語を抽出する。

3.2 印象抽出

エリアに関するレビューと辞書とのマッチングによって、エリアの印象を抽出する。提案手法では、感情と印象の対応を表 1 の様に定義する。ここで、「興奮度」、「楽しさ」、「哀しさ」については、対として表現することが難しいと考え、ポジティブな感情のみで定義している。

辞書マッチングでは、レビューを形態素に分割し、各感情語の重みと出現回数の積から印象別のスコア (印象値) をレビューごとに求める。感情語の印象に対する重みは、表 1 のネガティブな感情を持つ感情語は -1 、ポジティブな感情を持つ感情語は 1 を初期値とし、係り受け解析による否定形や仮定形、程度副詞の抽出によって重みを更新する。エリアに対する各印象の強さは、該当レビューの印象値の総和により求める。

3.3 エリア推薦

本稿で提案するエリア推薦システムの構成を図 1 に示す。ユーザは入力として、ユーザの好む駅 (クエリ駅) と検索範囲を入力する。入力された検索範囲内の各駅とクエリ駅間で印象ベクトルのユークリッド距離を計算し、類似度順に並べたリストをユーザに推薦する。

連絡先: 高間 康史, 首都大学東京, ytakama@tmu.ac.jp

*1 https://www.nii.ac.jp/dsc/idr/fuman/fuman_top.html

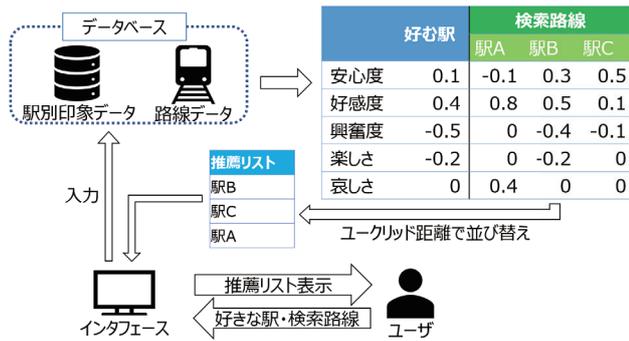


図 1: 提案システムの構成

表 2: 実験に利用した各辞書の説明

辞書名	説明
base	感情表現辞典
wd	日本語 WordNet による base の拡張
wb	Weblio 類語辞典による base の拡張
jw	感情表現辞書 [柴田 17]
+b	ブートストラップによる拡張

4. 評価実験

4.1 印象抽出精度

本実験では、駅に関するレビュー 500 件に印象ラベルを付与して正解データを作成し、提案手法による印象抽出結果と比較を行った。レビューにつき 3 名で、各印象の強さを 7 段階でラベル付けし、多数決で正解データを決定した。多数決で決まらない場合は中央値を採用した。

表 2 に示す各辞書を用いてレビューに対する印象値を計算し、その値に基づきレビューごとに印象を降順に並べた結果と、正解データにおける印象ラベルの順序からスピアマンの順位相関係数を求めた結果を表 3 に示す。

表より、各拡張手法による語彙追加によって相関を示すレビュー数が増加していることがわかる。特に、wb+b では全体の約 50% のレビューが相関を示している。この結果から、提案手法による辞書拡張は、印象抽出精度の向上に有効といえる。一方で、逆相関を示すレビューが約 30% 存在するため、否定形・仮定形の抽出部分の改善や、感情と印象の対応関係の再検討が必要と考える。

4.2 類似度判定精度

印象に基づく類似駅の判定精度を評価する実験を行った。正解データはクラウドソーシングを利用して作成した。各ターゲット駅に対し、提案手法による印象が類似する上位 10 駅と、それ以外の駅 10 駅を提示して、類似すると思う駅を任意数選択してもらった。回答は 97 人から得られた。ターゲット駅及び選択肢となる駅は、東京都内でレビュー数の多い駅、あるいは乗客数の多い駅の中から抽出し、印象抽出の結果に基づき「原宿」「新橋」「水道橋」「代々木」「目黒」「蒲田」の 6 駅をターゲット駅として採用した。また、感情語辞書は前節に示した結果が最も良好な wb+b を用いた。

表 3: 各辞書を用いた実験結果による相関別レビュー件数

辞書	base	wd	wd+b	wb	wb+b	jw	jw+b
相関	175	240	248	238	266	162	186
無相関	275	98	136	130	118	122	104
逆相関	50	107	116	132	116	216	210

表 4 に原宿・代々木・水道橋の適合率・再現率を求めた結果を示す。選択人数が N 人以上の駅を正解データ、提案手法の推薦リストは上位 L 件として評価を行っている。結果から、原宿駅では $N = 15$ の場合を除いて、 L に関わらず適合率 0.5 以上となるのがわかる。また、 $L = 10$ の時に再現率は大きくなるが、適合率はそれほど低下しないことがわかる。蒲田駅でも、同様の結果が得られた。

代々木駅では $N = 5$ の場合、 L に関わらず適合率 0.6 以上となるのがわかる。再現率を見ると、 L に関わらず、 $N = 10$ の場合に最小となっていることから、多数の人が類似するとした駅と、少数の人だけが類似するとした駅の両方を推薦できているといえる。新橋、目黒駅でも代々木駅と同様の結果が得られた。

水道橋駅では $N = 5$ の場合を除いて、適合率 0.2 以下、再現率 0.3 以下と小さい値になっている。これらの結果から、水道橋駅以外では、ある程度良い精度で推薦ができていると考える。また、選択人数が少ない駅は、実際にその駅を利用していた人のみが類似すると判断した駅である可能性が考えられる。その場合、これらの駅は推薦された人にとって、意外かつ有用な推薦になる可能性があると考えられる。

表 4: 各ターゲット駅の適合率・再現率

L	N	原宿		代々木		水道橋	
		P	R	P	R	P	R
3	5	1.00	0.21	0.67	0.12	0.33	0.06
3	10	1.00	0.43	0.33	0.11	0.00	0.00
3	15	0.33	0.25	0.33	0.20	0.00	0.00
5	5	1.00	0.36	0.80	0.24	0.60	0.18
5	10	0.60	0.43	0.20	0.11	0.00	0.00
5	15	0.20	0.25	0.20	0.20	0.00	0.00
10	5	0.90	0.64	0.90	0.53	0.80	0.47
10	10	0.50	0.71	0.30	0.33	0.20	0.25
10	15	0.30	0.75	0.20	0.40	0.00	0.00

5. おわりに

本稿では、エリアに関するレビューから印象を抽出するための感情語辞書構築手法、及び類似エリア判定手法を提案した。印象抽出精度の評価実験から、提案する各辞書拡張手法によって印象抽出精度が向上することを示した。また、類似駅判定についても、ある程度精度の良い推薦が可能であることを示した。今後は、エリアに関する統計データに基づく類似度判定との特性比較や統合を検討する予定である。

謝辞

本研究の一部は JSPS 科研費 16K1253500 の助成を受けたものです。

参考文献

- [中村 93] 中村明, 感情表現辞典, 東京堂 出版, 1993.
- [山本 14] 山本湧輝, 熊本忠彦, 灘本明代, Twitter 特有表現を考慮したツイート の多次元感情抽出手法の提案, 情報処理学会関西支部大会, G-01, 2014.
- [Yao16] Z. Yao, Y. Fu, B. Liu, H. Xiong, The Impact of Community Safety on House Ranking, SIAM Int'l Conf. on Data Mining, pp. 459-467, 2016.
- [Hearst92] M. A. Hearst, Automatic acquisition of hyponyms from large text corpora, COLING'92, Vol. 2, pp. 539-545, 1992.
- [柴田 17] 柴田大作, 若宮翔子, 伊藤藤, 荒牧英治, クラウドソーシングによる日本語感情表現辞書の構築, NLP2017, pp. 771-774, 2017.

オンラインメディア記事の読者の行動分析

Analysis of readers in Online News Service

園田 亜斗夢^{*1} 関 喜史^{*2} 鳥海 不二夫^{*1}
Atom Sonoda Yoshifumi Seki Fujio Toriumi

^{*1}東京大学 ^{*2}株式会社 Gunosy
The University of Tokyo Gunosy Inc.

Information is transmitted through websites, and the immediate reaction to various information is required. Hence, the efforts for readers to select information themselves have increased, which leads to the further improvement of recommendation services that can reduce such burdens. On the other hand, it is pointed out that filter bubbles that only provide biased information to users are generated due to the redundant recommendation. In this research, we analyzed behavioral changes and showed that behavior changes during the period as well as the existing research, and also consider the relationship between the diversity decrease and the period and the number of views.

1. はじめに

インターネットの登場により新聞社等のメディアの発信するニュースの媒体が新聞から web サイトに拡大し [1], 記事の速報性の向上や記事数の増加が進んでいる。これに伴い、ユーザが記事を選択する際に必要な時間と労力が増大している。このような状況下で、メディアを通じた情報接触において人々は何かの基準で閲覧する情報を取捨選択せざるを得なくなっていると推測される。情報接触の過程で、取捨選択の際には2つの問題があると考えられる。1つは「見たいものだけを見る」といったユーザ主体の選択的接触による問題であり、もう1つはシステム主体で行われる検索システム、レコメンデーション、ランキング等の広義の推薦システムの利用による問題である。広義の推薦システムは、記事を選択する際に必要な時間と労力といった負担を減らし、満足度を向上させるため、多くの分野で導入されている。特に、技術の発達によってユーザの選好に応じて提示情報をパーソナライズするタイプの推薦システムの導入が進んでいる。一方で、過度の推薦によってユーザに偏った情報のみを提供するフィルターバブルが発生しているとの指摘もある [2]。フィルターバブルの問題点として、得られる情報が偏ることによって、社会の分極・分断の進行が挙げられる。つまり、過度の推薦は、極端な考えを生み出し、合意形成が困難となる状態を作りかねない。正確な情報が広く社会的に共有されることは民主的な意思決定の必要条件である。しかし、「見たいものだけを見る」ことが容易な情報環境下では、異なる意見を持つ他者に対する寛容性の低下やマイノリティに対する偏見の増大、フェイクニュースの無批判な受容などによってこの必要条件を満たすことが難しくなる [3]。

本研究では既存のニュースサイト上でのユーザの行動変容について分析を行い、筆者のこれまでの研究 [4], [5] と比較する。これにより、既存の結果と比較し、多様性の減少はメディアが異なっても起きているのかを確認する。そのために、本研究では、既存研究と同様にユーザの行動を閲覧した記事の多様性によって評価し、現実のデータで時間の経過に伴う多様性の指標が変化していることを確認し、多様性の変化と期間・閲覧数の関係についても考察する。また、多様性が増加するユーザ

の存在を確認し、そのようなユーザの閲覧数の変化の条件についても確認する。

2. 分析手法

2.1 分析に用いるデータ

本研究では、2018年11月1日から12月31日までの2ヶ月間の株式会社 Gunosy が提供するニュース配信スマートフォンアプリケーションのデータを用いる。

この中で、11月1日～11月7日までの登録ユーザについて分析した。これは、既存ユーザではメディアに適合しており、短期間では変化しづらいことから、新規ユーザを扱うことで、期間の経過の影響を対象の2ヶ月間のデータで明確にするためである。また、11月15日～11月21日と12月24日～12月30日の期間それぞれで、閲覧数が一定以上のユーザを抽出した。これは分析する期間において十分な閲覧数があるユーザを対象とするためである。

閲覧記事の評価には、既存のカテゴリを用いた。既存研究では記事のクラスタリングを行い、そのクラスタによって評価していたが、本研究で扱うデータはカテゴリ数が50と分析に十分な細分化がなされていたため、既存のカテゴリを採用した。

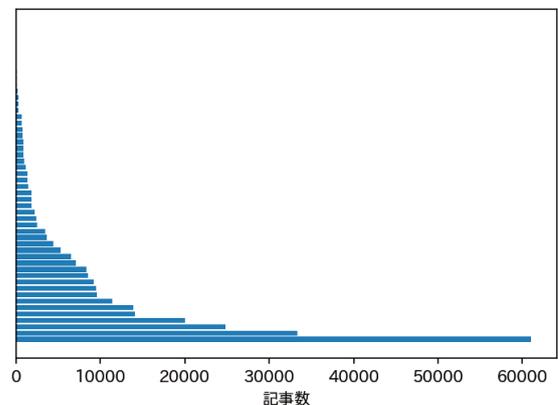


図 1: カテゴリごとの記事数の分布

ここで、図 1 に横軸に記事数を取り、記事数が多い順に並べたものを示す。ここから、カテゴリごとの記事数は異なり、一部のカテゴリに多くの記事が集中していることが分かる。

2.2 閲覧行動の多様性の評価

本研究では閲覧行動の多様性の変化を行動変容として、ある一定の期間経過後、読んだ記事の種類が変化したかどうかを分析する。つまり、読んでいる記事のカテゴリの多様性によって、ユーザの行動を評価する。カテゴリの集中度は、情報量エントロピーを用いて次のように求められる。

$$H(u) = - \sum_i p_i \cdot \log p_i$$

ただし、 p_i は各ユーザにおけるカテゴリ c_i の存在確率で、閲覧数 N のとき、 $p_i = c_i/N$ と表されるものである。カテゴリエントロピーの高いユーザは、様々なカテゴリに所属する記事を読んでいるユーザであり、カテゴリエントロピーの低いユーザは、特定のカテゴリに所属する記事を集中的に読んでいるユーザである。一般に、フィルターバブルとは推薦システムによりユーザがその人の観点に合わない情報から隔離され、ユーザ自身の興味があると判断された範囲に集約されていくことである。したがって、読んでいる記事のカテゴリの集中度でその影響を測ることができると期待される。例えば、もしフィルターバブルによって観点に合う情報のみと接するようになれば、閲覧記事は特定のクラスタに集中するため、多様性が失われ、カテゴリエントロピーは低下すると考えられる。

そこで、一定期間ごとに閲覧行動の多様性を評価し、多様性に変化が見られるか確認する。その際、期間を複数比較することで、多様性が安定するまでの期間を確認する。

3. 期間の経過によるカテゴリエントロピーの変化

3.1 分析結果

期間ごとのカテゴリエントロピーは表 1 のようになった。11 月 15-21 日と 12 月 13-19 日を比較すると、約 1ヶ月の間に有意水準 1% で有意にカテゴリエントロピーが減少していた。よって、この分析から、株式会社 Gunosy のサービスにおいても、期間の経過によって閲覧するカテゴリが集中していっていると考えられる。また、カテゴリエントロピーの減少幅は 11 月 15-21 日と 11 月 22-28 日の間が最も大きく、期間の序盤ではより閲覧するカテゴリの幅が狭まりやすいと考えられる。一方、有意な差ではないが、11 月 29-12 月 5 日と 12 月 6-12 日の間では多様性が増加し、その後、また減少に転じている。このことから、安定しつつも、カテゴリエントロピーの減少は続いていることがわかる。

また、この期間の記事全体のエントロピーは 1.26 であることから、閲覧されている記事のエントロピーはおおよそ半減しているが、これは表示記事や閲覧数の制約の影響があると推測される。

図 2 に 11 月 15-21 日と 12 月 13-19 日のカテゴリエントロピーの分布を示す。これより、カテゴリエントロピーの平均だけでなく、全体としてエントロピーが減少し、閲覧するカテゴリの幅が狭まっていることがわかる。また、図 3 に 11 月 22-28 日と 12 月 13-19 日のカテゴリエントロピーの分布を示す。図 2 と比較すると、分布の差がわかりづらくなっており、安定しはじめていることがわかる。

一方、期間 1 と期間 2 を比較すると、カテゴリエントロピーが増加しているユーザも 32% 存在し、全体の分布としては減

表 1: 期間ごとのカテゴリエントロピーの平均

期間	平均カテゴリエントロピー
11 月 15-21 日	0.727
11 月 22-28 日	0.676
11 月 29-12 月 5 日	0.673
12 月 6-12 日	0.682
12 月 13-19 日	0.643

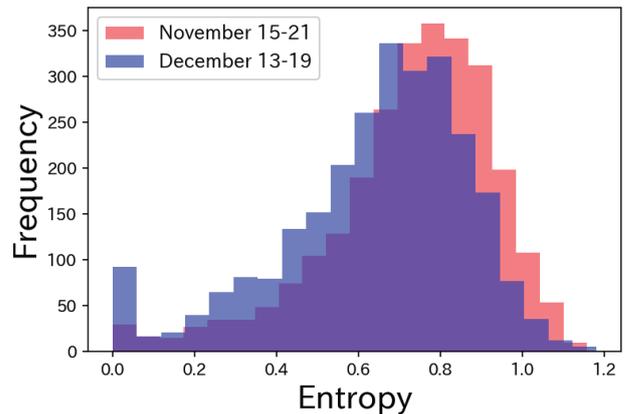


図 2: カテゴリエントロピーの分布 (11 月 15-21 日と 12 月 13-19 日)

少しているが、増加しているユーザも一定程度いることがわかった。

3.2 考察

既存研究 [4] では日本経済新聞社の提供する日経電子版において多様性が減少することを確認したが、以上の結果より株式会社 Gunosy のサービスでも多様性の指標として採用したカテゴリエントロピーが減少していることがわかった。また、複数の期間を比較することで、カテゴリエントロピーは序盤では大きく減少することがわかった。一方、期間の後半でも増加と減少が起きていることから、真に安定し出すのは、より期間が経過した後であり、より長期間での分析が必要であると考えられる。さらに、エントロピーが増加しているユーザも 32% 存在したことから、期間を経ることで、全体としてはエントロピーは減少しているが、増加するユーザも十分に存在し、ユーザごとの違いが大きくなってくると考えられる。

4. カテゴリエントロピーと閲覧数の関係

4.1 相関分析

本章では、閲覧記事数が多様性の変化に与える影響を明らかにするために、カテゴリエントロピーと閲覧数の関係を分析した。そのために、11 月 15-21 日 (期間 1) と 12 月 13-19 日 (期間 2) のカテゴリエントロピーと閲覧数を比較した。この期間中に閲覧数は 14% 減少していた。まず、エントロピーと閲覧数の相関分析を行った。表 2 にカテゴリエントロピーと閲覧数の相関係数を示す。この表から、期間 1 のエントロピーと期間 2 のエントロピーには相関があることが分かる。つまり、一定の期間の経過後もカテゴリエントロピーが高いユーザは高いままのことが多いと考えられる。また、各期間のエント

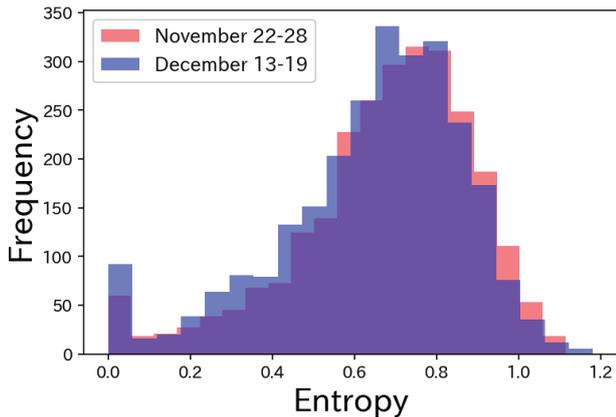


図 3: カテゴリエントロピーの分布 (11月 22-28 日と 12月 13-19 日)

表 2: カテゴリエントロピーと閲覧数の関係

比較対象	相関係数
期間 1 のエントロピーと期間 2 のエントロピー	0.609
期間 1 のエントロピーと期間 1 の閲覧数	0.273
期間 2 のエントロピーと期間 2 の閲覧数	0.345
エントロピーの変化と閲覧数の変化	0.299

ロピーと閲覧数の間にも弱い相関があることが見て取れる。さらに、エントロピーの変化と閲覧数の変化間にも弱い相関があることが分かり、読んでいる記事数の変化が多様性の変化に影響していると考えられる。つまり、新規登録後日数がたつにつれ、全体として閲覧数が減少し、カテゴリエントロピーもその影響を受けていると考えられる。

4.2 ユーザグループごとの分析

ここでは、ユーザをクリック数のしきい値で3分割し、その3分割したユーザ群の期間中での遷移を基に、エントロピーの変化を分析した。具体的には、閲覧数が平均より少ないユーザをグループ A、閲覧数が平均に近いユーザをグループ B、閲覧数が平均の2倍以上多いユーザをグループ C として分析した。期間 1 と期間 2 を比較し、これらのグループ間の移動について分析したところ、グループ A はユーザ数が 72% 増加し、グループ B は 15% 減少、グループ C は 22% 減少していた。ここから、利用初期は多くの記事を読覧するが、期間の経過に伴い安定してくることがわかる。

表 3 に、グループの移動ごとのユーザ数の割合と期間ごとのカテゴリエントロピーを示す。グループを移動しない場合 (A → A, B → B, C → C) のうち、A → A, B → B に関しては有意水準 1% で有意にカテゴリエントロピーが減少していることが分かるが、C → C では有意に減少はしていなかった。つまり、グループを移動しない場合で閲覧数が少ない場合はカテゴリエントロピーは減少するが、閲覧数が十分にある場合はカテゴリエントロピーは減少しにくいと考えられる。このことから、多様性の減少を抑制するには、閲覧数の確保が重要であると考えられる。

次に、グループを閲覧数が増加する方向に移動する場合のうち、分析に十分なユーザ数を含む A → B, B → C について分

表 3: カテゴリエントロピーとグループの遷移の関係

比較対象	ユーザ割合 [%]	期間 1 のエントロピー	期間 2 のエントロピー
A → A	11.0	0.625	0.509
A → B	7.2	0.624	0.677
A → C	0.0	0.528	0.449
B → A	20.2	0.724	0.525
B → B	48.2	0.752	0.699
B → C	3.5	0.767	0.794
C → A	0.3	0.858	0.529
C → B	5.5	0.808	0.719
C → C	4.0	0.855	0.804

析する。このうち、A → B に関しては有意水準 1% で有意にカテゴリエントロピーが増加していることが分かるが、B → C では有意に増加はしていなかった。しかしながら、閲覧数が増加する方向に移動する場合、カテゴリエントロピーも増加する傾向にあり、減少はしないことが分かる。また、平均カテゴリエントロピーと比べても高い水準であると言える。このことから、閲覧数が増えることは、カテゴリエントロピーの減少を抑制するために良い影響があると考えられる。

さらに、グループを閲覧数が減少する方向に移動する場合のうち、分析に十分なユーザ数を含む B → A, C → B について分析する。B → A, C → B どちらについても、有意水準 1% で有意にカテゴリエントロピーが減少していることが分かる。このことから、閲覧数が減ることは、カテゴリエントロピーの減少を抑制するために悪い影響があると考えられる。

以上より、カテゴリエントロピーと閲覧記事数グループの遷移を分析することで、閲覧記事数が増加することはカテゴリエントロピーの増加に貢献することがわかった。また、閲覧数に変化がない場合は、カテゴリエントロピーは減少しやすいが、閲覧数が十分にある場合はカテゴリエントロピーの減少を抑制できることがわかった。

一方、期間 2 のカテゴリエントロピーの絶対値に注目すると、期間 1 の閲覧数が多いほど期間 2 の値が大きいたことが分かる。このことから、閲覧記事数の増減はカテゴリエントロピーの変化に影響を与えるが、全体としては、前節の相関分析で見たように期間 1 のエントロピーの影響が強いことが分かる。つまり、一定の期間の経過後もカテゴリエントロピーがもともと高いユーザは比較的高い状態を維持していると考えられる。しかしながら、閲覧数がこれ以上に減少していった場合に、一定期間前の影響と閲覧数減少による影響が逆転することも考えられ、より長期での分析が今後の課題である。また、閲覧数が一定以上の場合には他のカテゴリを読覧する確率が増えると推測され、エントロピーは増えやすいはずである。また、カテゴリごとに閲覧される期待値が異なる。そこで、閲覧数とカテゴリごとの期待値を表現する指標を導入し比較することで分析がより進むと考えられ、これは今後の課題である。

5. 結論

株式会社 Gunosy が提供するニュース配信スマートフォンアプリケーションの閲覧行動について、記事のカテゴリのエントロピーの平均によりユーザの行動の多様性を評価し、複数の期間の閲覧行動を比較し、分析した。これらの結果と既存研究 [4] の比較から、メディアが変わっても、多様性の指標であ

るエントロピーの減少が起きていることが確認できた。また、複数の期間を比較することで、カテゴリエントロピーは序盤の方が大きく減少すること、新規登録後1ヶ月以上経過してもカテゴリエントロピーの減少は続いていることがわかった。一方、増加するユーザも一定数存在し、期間を経ることで、ユーザごとの差異が大きくなっていくと考えられる。

また、記事の閲覧数とカテゴリエントロピーの関係を分析したところ、閲覧数とエントロピーの間には相関があり、また、閲覧数の変化とエントロピーの変化の間にも相関が存在することがわかった。

今後の課題として、より長期間の分析を行い、多様性の減少幅が小さくなり、安定期に入るまでの期間の解明が必要である。また、初期の多様性と閲覧数の変化が一定期間経過後のエントロピーに与える影響の変化に対する分析が今後の課題である。他にも、行動変容を導く要因の分析のために、閲覧記事だけではなく、表示されたが読まれなかった記事と表示されなかった記事についても分析を進めていく必要がある。

参考文献

- [1] 総務省. 平成 28 年情報通信メディアの利用時間と情報行動に関する調査報告書. http://www.soumu.go.jp/main_content/000492877.pdf.
- [2] Eli Pariser. *The filter bubble: What the Internet is hiding from you*. Penguin UK, 2011.
- [3] 小林哲郎ほか. ソーシャルメディアと分断化する社会的リアリティ (特集 twitter とソーシャルメディア). 人工知能学会誌, Vol. 27, No. 1, pp. 51–58, 2012.
- [4] Atom Sonoda, Fujio Toriumi, Hiroto Nakajima, and Miyabi Gouji. Analysis and modeling of behavioral changes in a news service. In *2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, pp. 73–80. IEEE, 2018.
- [5] 園田亜斗夢, 鳥海不二夫, 中島寛人, 郷治雅. ネットワーク構造に基づく新聞記事の分類による読者の行動分析. 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. 3O1OS1a03–3O1OS1a03. 一般社団法人人工知能学会, 2018.

政治ニュース記事クラスタに対する属性ごとのユーザ行動の分析

Analysis of user activity of politics news cluster by user attributes

関 喜史*1
Yoshifumi Seki吉田 光男*2
Mitsuo Yoshida*1株式会社 Gunosy
Gunosy Inc.*2豊橋技術科学大学
Toyohashi University of Technology

我々はフィルターバブルやエコーチェンバーのようなユーザのニュース記事の閲覧時に発生するとされる選択的接触行動をユーザ行動ログから定量的に評価することを目指している。この目的のために、これまで、ユーザ属性ごと行動の違いについて、カテゴリとキーワードを用いて議論してきた。ニュース配信サービスにおいて、政治ニュース記事に対するユーザ属性ごと行動の違いを分析する際に、本稿ではニュース記事のクラスタに着目する。クラスタにおけるクラスタにおけるクリックと Like 行動との相関係数および比率を比較し、ニュースの内容によるユーザ行動の違いを詳細に捉えられることを実験的に示した。

1. はじめに

近年人々はウェブでの情報収集を活発に行なっているが [LINE], ウェブにおいてはフィルターバブル [Pariser 11], エコーチェンバー [Jamieson 08] という現象が指摘されている。フィルターバブルは情報がパーソナライズされてしまうことで広い視野を失ってしまうとされる現象であり、エコーチェンバーは自らが好む情報やそれを支持するコミュニティにばかりに接触してしまうあまり、偏った考えがより強化されてしまうとされる減少である。これら 2 つの現象は Brexit やトランプ大統領誕生に大きく影響したとされており、ジャーナリストを中心に問題視されているが [Hooton 16], これらの現象について定量的な分析はほとんど行われていない。このような背景から我々はニュース配信サービスのユーザ行動ログからこれらの現象についての分析をこれまで行っている。

本研究ではニュース配信サービスにおいて、政治ニュース記事に対するユーザ属性ごと行動の違いを、ニュース記事のクラスタを用いて分析する。以前の研究で我々はユーザの属性別の行動の違いについて、カテゴリとキーワードを用いて議論した [関 18, Seki 18]。若年層の投票率の低下は社会問題化しているなかで [総務], 世代間で政治への関心がどのように異なるのかといふアンケートを用いた研究や調査はあるが、実際の行動に基づく研究は多くない [鈴木 12]。本研究ではニュース記事のクラスタを用いることで、ニュースの内容によるユーザ行動の違いをより詳細に捉えることを目指す。

2. データセット

本研究では株式会社 Gunosy が提供するニュース配信サービスであるグノシー*1 における 2018 年 8 月の 1ヶ月間の政治カテゴリにおけるユーザ行動ログを用いる。

本研究ではニュース記事のクリックとニュース記事への like を扱う。図 1 にグノシーのサービス画面を示す。ニュース記事リストはタイトルとサムネイル画像からなるセルとして表示されており、ユーザはクリックすることで記事詳細画面で本文を読むことができる。記事詳細画面の下部のナビゲーションバー

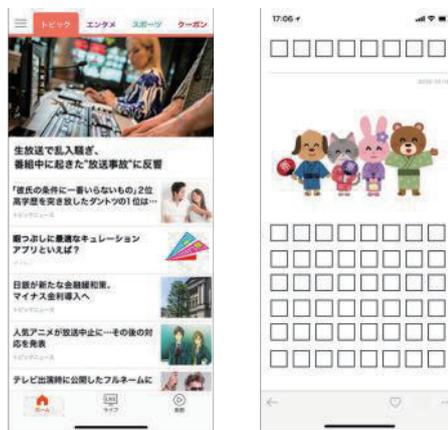


図 1: グノシーのサービス画面: 左の図はニュース記事リスト画面であり、各ニュース記事はタイトルとサムネイル画像からなるセルで構成されている。セルをクリックすると右図の詳細画面に進む。画面下部のツールバーのハート型のボタンが Like ボタンである。Like ボタンはニュース記事本文の末尾にもある。

のハート型のボタンを押すことでニュース記事に Like することができる。詳細画面末尾にも同様のボタンがある。2019 年 2 月現在、Like ボタンを押してもユーザにメリットのある機能は提供されていないが、いくらかのユーザには活発に利用されている。比較のためには一定以上の行動が必要なため、クリック数が 100 以上の記事に限定している。

本研究ではユーザ属性別の行動の違いに着目するが、ユーザ属性としては性別と年齢を用いる。ユーザはこれらの属性を利用開始時に登録することができる。性別は男性、女性、その他から選べるが、本研究では男性と女性を比較対象に用いる。年齢は 20 歳未満, 20 - 24, 25 - 29, 30 代, 40 代, 50 歳以上から選ぶことができるが、分析で 20 代以下 (Young), 30 代 (Middle), 40 代以上 (Older) の 3 カテゴリに分ける。ユーザは属性を登録せずに利用することもできるが、その場合は一定以上サービスを利用していたユーザを対象に、サービス内での行動から教師あり学習を元にユーザ属性の推定を行っている。分析はこれらの方法によって属性がわかるユーザのみに限定

連絡先: 関 喜史, 株式会社 Gunosy, 〒106-6125 東京都港区六本木 6-10-1 六本木ヒルズ森タワー 25 階, 03-6455-4562, yoshifumi.seki@gunosy.com

*1 <https://gunosy.com>

表 1: Each action ratio between demographic attributes.

			all	Politics	
number of news articles				1,333	
Click ratio	Gender	Male	58.9%	76.2%	
		Female	41.1%	23.8%	
	Age	Young	34.7%	16.4%	
		Middle	30.2%	22.1%	
Older		35.1%	61.5%		
Like ratio	Gender	Male	47.7%	78.2%	
		Female	52.3%	21.8%	
	Age	Young	25.8%	8.8%	
		Middle	25.4%	11.0%	
		Older		48.7%	80.2%

する。

分析対象となるニュース記事は、一定以上のユーザ行動が必要のためクリック数が 100 以上のものに限定する。このようにして 1,333 件のニュース記事が得られた。それぞれの属性の各行動の比率を表 1 に示す。all はサービス全体での比率を示している。サービス全体に比べて政治カテゴリは男性の年齢層の高いユーザの行動が活発であることがわかる。

3. クラスタリングによる分析

3.1 クラスタリング

記事のクラスタリングはニュース記事のタイトルを用いて行う。まずニュース記事をタイトルを用いてベクトル化する。ベクトルにあたっては Continuous Bag-of-Words (CBOW) モデルを用いた word2vec を利用する。モデルの作成には過去 2 年間グノシーで配信されたニュース記事データのタイトルを Mecab と mecab-ipadic-NEologd を用いている。同時にそのニュース記事データを用いて inverse document frequency を計算しておく。ニュース記事のベクトル \mathbf{a} は以下の式で定義される [米田 17]。

$$\mathbf{a} := \frac{\sum_{\mathbf{w}_i \in W_a} \text{idf}(\mathbf{w}_i) \mathbf{w}_i}{\left\| \sum_{\mathbf{w}_i \in W_a} \text{idf}(\mathbf{w}_i) \mathbf{w}_i \right\|} \in \mathbb{R}^d,$$

ここで W_a はニュース記事 a のタイトルの単語集合であり、 $\mathbf{w}_i \in \mathbb{R}^d$ は次元数 d で word2vec にベクトル化された単語である。idf(\mathbf{w}_i) は単語 w_i の idf 値を表す。つまりタイトルに出現した単語ベクトルの idf 値による重み付け平均ベクトルをニュース記事ベクトルとしている。

このようにして構築した記事ベクトルを k-means を用いてクラスタリングする。クラスタ数は 10 とした。^{*2} 各クラスタの概要と記事数とクリック数、Like 数の分布を表 2 に示す。記事数は総裁選に関する記事が多いクラスタ 6 の記事数が飛び抜けて多い以外は、全体として等しく分布しているが、クリック数と Like 数はバラつきが多い。クリック数、Like 数は政治ゴシップを扱うクラスタ 9 が非常に多く、ユーザから人気のあるクラスタであることがわかる。クラスタ 6 は記事数が他のクラスタの 23 倍程度あるため、それと比較するとクリック数、Like 数はそこまで多くない。クリック数と Like 数の傾向はクラスタごとに異なり、例えば沖縄に関係するニュースが多いク

^{*2} クラスタ数を 240 の範疇でエルボー法による分析を行ったが、クラスタ内誤差平方和はクラスタ数 10 以上でなだらかに下がりが続いていたため、解釈性を高めるために 10 とした。

表 2: クラスタリングの結果

	概要	記事数	記事数 比率 [%]	クリック数 比率 [%]	Like 数 比率 [%]
1	政権	88	6.6	3.0	2.8
2	選挙・政局	192	14.4	8.0	5.6
3	総裁選 (ゴシップ)	167	12.4	12.4	13.1
4	社会	97	7.3	3.7	2.2
5	事件	108	8.1	3.9	3.6
6	総裁選	283	21.2	12.8	15.1
7	コラム	103	7.7	20.5	14.2
8	沖縄関連	82	6.2	4.8	13.0
9	政治ゴシップ	140	10.5	27.8	27.7
10	外交・海外	73	5.5	2.9	2.6

ラスタ 8 はクリック数は少ないが Like 数は比較すると多い。このようにクラスタごとにクリックと Like の傾向は異なる。

3.2 各クラスタにおけるユーザ属性間の行動傾向

ここでは各クラスタのユーザ属性間の行動傾向を分析し、議論する。属性間の行動傾向の指標としてピアソンの相関係数 (以下相関係数) と、行動総数の比を用いる。相関係数が高ければ強い相関があり、クラスタ内のニュース記事において行動の属性間の比率がある程度一貫していることがわかる。そのため相関が強ければ行動総数の比から、そのクラスタの特性を議論することができる。一方で相関係数が低ければ、クラスタ内のニュース記事において属性間の行動の比率の一貫性が低いため、行動総数の比で議論することは難しい。まずは相関係数によって、それぞれのクラスタにおける属性間行動の一貫性を確認する。

表 3 にクラスタごとにクリック行動の相関係数と比率を示す。すべての属性間の相関係数は全クラスタにおいて高く、各クラスタとも属性間のクリック傾向には強い相関があることがわかる。表 4 には同様に Like 行動の相関係数と比率を示す。クリックと比較したときに相関係数は小さいが、全体としては強い相関がある。一方でクラスタ別でみると低いクラスタがいくつか存在する。特にクラスタ 4 はすべての属性間で著しく相関係数が低い。また属性ごとに傾向が違い、例えばクラスタ 6 は男女間と middle-older 間では強い相関があるが、young-middle, older-young 間では比較的相関が弱い。今回は相関係数が 0.6 以上のクラスタに絞って、行動総数の比率を議論することにする。

例として男女間のクラスタ間の傾向について議論する。政治カテゴリはもともと男性の行動のほうが多く、男性は女性の 3.2 倍のクリック、3.58 倍の Like を生み出している。クリックの中で男性比率がより高いのはクラスタ 6、次いでクラスタ 3、そしてクラスタ 10 である。クラスタ 6 とクラスタ 3 は自民党総裁選に関するものであり、クラスタ 10 は外交に関するものである。これらのクラスタはより男性の関心が強いクラスタであるといえる、一方で女性のクリック比率が男性と比較して高いのはクラスタ 8、クラスタ 7、クラスタ 9 であり、それぞれ沖縄、コラム、政治ゴシップのクラスタであり、これらのクラスタは女性の関心が強いクラスタであるといえる。Like をクリックと比較すると、男性の関心の高いクラスタでは、クラスタ 3 がクリックで高い関心の合った他の 2 つに比べて男性の比率が突出していない。またクリックにおいて女性側の関心が高かったクラスタをみると、クラスタ 9 は Like の比率で見れば男性がより Like しているクラスタになっている。一方でクラスタ 8 はクリックよりも女性側に偏っている。このようにクラスタごとにクリックと Like では行動傾向も異なること

表 3: 各クラスタのクリック行動の属性間の相関と比率

	male-female		young-middle		middle-older		older-young	
	pearson	ratio	pearson	ratio	pearson	ratio	pearson	ratio
all	0.902	3.20	0.992	0.75	0.923	0.36	0.901	3.74
1	0.895	3.60	0.981	0.98	0.949	0.34	0.906	2.98
2	0.930	3.08	0.996	0.86	0.899	0.38	0.870	3.04
3	0.869	4.84	0.913	0.79	0.948	0.28	0.787	4.54
4	0.634	3.44	0.993	0.88	0.811	0.53	0.830	2.14
5	0.880	3.76	0.978	0.75	0.899	0.38	0.864	3.52
6	0.962	5.87	0.995	0.83	0.924	0.23	0.924	5.29
7	0.859	2.61	0.987	0.65	0.929	0.41	0.924	3.70
8	0.987	1.72	1.000	0.80	0.995	0.42	0.995	2.98
9	0.953	2.70	0.999	0.69	0.947	0.40	0.940	3.66
10	0.982	4.36	0.994	0.86	0.995	0.29	0.992	4.02

表 4: 各クラスタの Like 行動の属性間の相関と比率

	male-female		young-middle		middle-older		older-young	
	pearson	ratio	pearson	ratio	pearson	ratio	pearson	ratio
all	0.747	3.58	0.909	0.81	0.845	0.14	0.786	9.09
1	0.719	3.76	0.537	1.05	0.686	0.13	0.840	7.10
2	0.698	3.06	0.767	0.71	0.728	0.19	0.574	7.39
3	0.720	4.93	0.564	0.78	0.632	0.11	0.556	11.65
4	0.263	3.93	0.362	1.2	0.454	0.20	0.359	4.13
5	0.734	3.45	0.610	0.90	0.703	0.18	0.636	6.00
6	0.925	6.51	0.519	0.72	0.909	0.10	0.571	13.90
7	0.769	2.92	0.857	0.72	0.854	0.16	0.818	8.65
8	0.935	1.33	0.975	1.01	0.999	0.22	0.973	4.53
9	0.976	4.79	0.884	0.70	0.650	0.10	0.683	13.72
10	0.945	6.45	0.713	0.76	0.881	0.17	0.796	7.94

が示唆される。

4. まとめ

本稿ではニュース配信サービスにおいて、政治ニュース記事に対するユーザ属性ごと行動の違いを、ニュース記事のクラスタを用いて分析した。我々は以前のユーザの属性別の行動の違いについて、カテゴリとキーワードを用いて議論したが、今回はニュース記事のクラスタを用いることで、ニュースの内容によるユーザ行動の違いをより詳細に捉えることを目指した。ニュース記事タイトルの分散表現を使ってクラスタリングを行い、各クラスタに対する相関係数とクリック行動と Like 行動の比率を求め比較した。クラスタごとに相関の度合いは異なるが大まかには強い相関があり、クラスタの傾向を比較することが可能であること確認し、比率の違いからユーザ属性による話題への関心の違いを議論できることを示した。キーワードベースで行った以前の手法と比較すると、クラスタの解釈については定性的な部分が必要になるが、クラスタ内のデータ量が大きくもてるため、分析が容易になる点、また全体の中でのまとまりを抽出するため、トピックを網羅的に議論できる点で優れている。

今後はユーザ側を属性ベースではなく、興味関心で分類することでユーザの関心の偏りの発見と分析に取り組みたい。また政治ニュースへの関心は社会でのイベントにより変動すると考えられるため、データ量を増やし時間経過による影響についても詳しく調査したい。

参考文献

[Hooton 16] Hooton, C.: Social media echo chambers gifted Donald Trump the presidency. the Independent (2016)

[Jamieson 08] Jamieson, K. H. and Cappella, J. N.: *Echo chamber: Rush Limbaugh and the conservative media establishment*, Oxford University Press (2008)

[LINE] LINE 株式会社: 世代間のニュースサービス利用に関する意識調査

[Pariser 11] Pariser, E.: *The Filter Bubble: What the Internet Is Hiding from You*, The Penguin Group (2011)

[Seki 18] Seki, Y. and Yoshida, M.: Analysis of Bias in Gathering Information Between User Attributes in News Application, in *IEEE BigData 2018 Workshop: The 3rd International Workshop on Application of Big Data for Computational Social Science (ABCSS2018)* (2018)

[関 18] 関 喜史: 世代による政治ニュース記事の閲覧傾向の違いの分析, 人工知能学会全国大会 (2018)

[総務] 総務省: 国政選挙の年代別投票率の推移について

[米田 17] 米田 武, 久保 光証, 関 喜史: ニュース配信システムにおけるパーソナライズ的设计と導入, 信学技報, NLC2017-28 (2017)

[鈴木 12] 鈴木万希枝: 若年層のニュース消費に関する研究: 情報源接触パターンおよびニュース情報への選択的接触の検討, 三田哲学会 (2012)

[1J3-J-2] Machine learning: bayesian models

Chair:Ichigaku Takigawa Reviewer:Satoshi Oyama

Tue. Jun 4, 2019 3:20 PM - 4:40 PM Room J (201B Medium meeting room)

[1J3-J-2-01] Bayesian Optimization with Kernels for Persistence Diagrams○Tatsuya Shiraishi¹, Makoto Yamada^{1,2}, Hisashi Kashima^{1,2} (1. Kyoto University, 2. RIKEN Center for Advanced Intelligence Project)

3:20 PM - 3:40 PM

[1J3-J-2-02] Scalable Bayesian Optimization with Memory Retention○Hidetaka Ito¹, Tatsushi Matsubayashi¹, Takeshi Kurashima¹, Hiroyuki Toda¹ (1. NTT Service Evolution Laboratories, NTT Corporation)

3:40 PM - 4:00 PM

[1J3-J-2-03] Bayesian Estimation for Spatial distribution using Low precision Sensors in Multi-Environment○Masato Ota¹, Ryo Hanafusa¹, Takeshi Okadome¹ (1. Kwasei Gakuin University)

4:00 PM - 4:20 PM

[1J3-J-2-04] Sparse Bayesian Learning for Itemset Data○Ryoichiro Yafune¹, Hiroto Saigo¹ (1. Kyushu University)

4:20 PM - 4:40 PM

パーシステント図に対するカーネルを用いたベイズ最適化

Bayesian Optimization with Kernels for Persistence Diagrams

白石 竜也 *1 山田 誠 *1*2 鹿島 久嗣 *1*2
Tatsuya Shiraiishi Makoto Yamada Hisashi Kashima

*1京都大学 *2理化学研究所 革新知能統合研究センター
Kyoto University RIKEN Center for Advanced Intelligence Project

The graph structure optimization is a fundamental task in graph structured data analysis. In the graph structure optimization, objective function is usually an expensive-to-evaluate and black-box function. Therefore, we need to optimize the unknown function with as few evaluations of the function as possible. Bayesian optimization is one of methods that can handle this difficulty. However, in order to apply Bayesian optimization to graph structured data, we need to extract proper geometric information of the structure and measure similarity between the structures. In this paper, we utilize topological data analysis (TDA), which is recently applied in machine learning, to extract robust topological information from graph structured data. Experiments show that topological information extracted by TDA contributes to efficient search of the optimal structure compared with random search baseline.

1. はじめに

近年、グラフ構造データに対する機械学習手法の研究が盛んに行われている。グラフ構造最適化は最適な性質を持つグラフ構造を探索するタスクであり、グラフ構造データ分析のなかでも基本的で重要なタスクの一つである。例えば、あるタンパク質と最も強く結合する化合物の探索や、交通量が最適となる道路ネットワークの探索などが挙げられる。

ここで最適化される目的関数、すなわち化合物の結合力や道路の交通量などといった性質は、出力の評価に長時間の実験が必要な評価コストの高い関数であり、その形が与えられないブラックボックス関数であることが多い。そのため、目的関数の評価回数を少なく抑えつつ、未知の目的関数でも最適化できる手法が望ましい。この条件を満たす手法の一つにベイズ最適化がある。しかし、ベイズ最適化に関する研究はベクトルを入力とするものが多く、グラフ構造を扱うものは少ない。ベイズ最適化でグラフ構造を扱うには、その構造の幾何学的な特徴をうまく捉えた類似度を設計する必要がある。

一方で、複雑な構造を持つデータのトポロジカルな特徴を抽出できる手法として、位相的データ解析 (topological data analysis, TDA)、特にパーシステントホモロジーと呼ばれる手法が注目されている。この手法は距離空間上の点群から特徴抽出を行うもので、その結果は図2のようなパーシステント図 (persistence diagram, PD) と呼ばれる点群で表現される。

ベイズ最適化でグラフ構造を扱うための類似度設計において、TDA を利用する方法はこれまで行われてこなかった。そこで本研究では、PD に対するカーネルを用いることで、パーシステントホモロジーによって得られる情報を利用するベイズ最適化手法を提案する。また、パーシステントホモロジーでは一つのデータから複数種類のPDを抽出できるが、これら複数のPDの情報を同時に用いる手法は提案されてこなかった。本研究ではさらに、複数のカーネルを線型結合で組み合わせることで、複数のPDの情報を扱える手法を提案する。複数のデータを用いた実験を行い、ランダムに探索する場合と比べて、提案手法によって効率的に探索が行えることを示す。

連絡先: 白石 竜也, 京都大学大学院情報学研究科知能情報学専攻, shiraiishi.t@ml.ist.i.kyoto-u.ac.jp

2. 問題設定

入力空間 \mathcal{X} から目的関数 $f: \mathcal{X} \rightarrow \mathbb{R}$ が最小となる点を探索する。本研究では \mathcal{X} としてデータ集合 $\mathcal{D} = \{\mathbf{x}_i\}_{i \in I}$ を考え、この与えられたデータ集合から目的関数を最小化する点を探索する。ここで、 \mathbf{x}_i はそれ自体が点群やグラフ構造で表されるデータである。

$$\mathbf{x}^* = \operatorname{argmin}_{\mathbf{x} \in \mathcal{D}} f(\mathbf{x})$$

目的関数として評価コストの高い関数を想定しているのので、できるだけ少ない評価回数で最適解を探索することが目標となる。ただし、目的関数値は真の値 $f(\mathbf{x}_i)$ にガウス分布に従う独立な加法性ノイズ $\epsilon_i \sim \mathcal{N}(0, \sigma^2)$ が含まれた状態でのみ観測できるものとする。

3. ベイズ最適化

ベイズ最適化は評価コストの高い目的関数の最適化によく用いられる最適化手法の一つである。ベイズ最適化は繰り返し処理で構成されており、各ステップはガウス過程による目的関数値の予測分布の計算と、獲得関数を用いた次の探索点の選択の二つのステップからなる。

3.1 ガウス過程

ガウス過程は確率過程の一つであり、スカラーやベクトルに対するガウス分布を関数に対して一般化したものである。ベイズ最適化では目的関数 $f: \mathcal{X} \rightarrow \mathbb{R}$ をガウス過程でモデル化して予測分布の計算を行う。あるステップまでに入出力データ $\mathcal{D} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_t, y_t)\}$ が得られているとする。ただし、出力 y_i として真の値 $f(\mathbf{x}_i)$ が観測されるとは限らず、ガウス分布に従う独立なノイズ $\epsilon_i \sim \mathcal{N}(0, \sigma^2)$ が含まれているとする。

$$y_i = f(\mathbf{x}_i) + \epsilon_i$$

ガウス過程の定義より、このとき $f(\mathbf{x}_1), \dots, f(\mathbf{x}_t)$ の同時確率分布はガウス分布となる。

$$(f(\mathbf{x}_1), \dots, f(\mathbf{x}_t))^T \sim \mathcal{N}(\mathbf{0}, \mathbf{K}) \quad (1)$$

ここで、 \mathbf{K} の各成分はカーネル関数を用いて $K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ と表される。 T は転置を表す記号である。このとき、データに含まれていない点 \mathbf{x}_{t+1} に対する目的関数値 $f(\mathbf{x}_{t+1})$ の予測分布が計算できる。 $f(\mathbf{x}_1), \dots, f(\mathbf{x}_t), f(\mathbf{x}_{t+1})$ の同時確率分布も式 (1) と同様の形であることと、出力にはノイズが含まれていることから、 $f(\mathbf{x}_{t+1})$ の予測分布もまたガウス分布となり、その平均 $\mu(\mathbf{x}_{t+1})$ と共分散 $\sigma^2(\mathbf{x}_{t+1})$ は以下ようになる。

$$\begin{aligned} \mu(\mathbf{x}_{t+1}) &= \mathbf{k}_{t+1}(\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{y} \\ \sigma^2(\mathbf{x}_{t+1}) &= k(\mathbf{x}_{t+1}, \mathbf{x}_{t+1}) - \mathbf{k}_{t+1}(\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{k}_{t+1}^T \end{aligned}$$

ここで、 $\mathbf{k}_{t+1} = (k(\mathbf{x}_{t+1}, \mathbf{x}_1), \dots, k(\mathbf{x}_{t+1}, \mathbf{x}_t))$ 及び $\mathbf{y} = (y_1, \dots, y_t)^T$ である。

3.2 獲得関数

ベイズ最適化では、ガウス過程を利用して計算された予測分布に基づいて、獲得関数 $acq(\mathbf{x})$ が最大となる点を次に出力を評価する点として選択する。

$$\mathbf{x}_{t+1} = \operatorname{argmax}_{\mathbf{x} \in \mathcal{X}} acq(\mathbf{x})$$

獲得関数の選択においては、既に得られている最良の値の周辺を調べる活用 (exploitation) と、不確実性の高い部分を調べる探索 (exploration) とのバランスが重要となる。ここでは、よく使われている expected improvement (EI) について述べる。EI はある時点で得られている最良の値 y_{best} と、予測される目的関数値 $f(\mathbf{x})$ との差の期待値を最大化する手法である。EI では獲得関数を以下で定義する。

$$\begin{aligned} acq_{EI}(\mathbf{x}) &= \mathbb{E}[\max\{0, y_{best} - f(\mathbf{x})\}] \\ &= \begin{cases} (y_{best} - \mu(\mathbf{x}))\Phi(Z) + \sigma(\mathbf{x})\phi(Z) & \sigma(\mathbf{x}) \neq 0 \\ 0 & \sigma(\mathbf{x}) = 0 \end{cases} \end{aligned}$$

ここで、 $Z = \frac{y_{best} - \mu(\mathbf{x}_{t+1})}{\sigma(\mathbf{x}_{t+1})}$ であり、 $\Phi(Z)$ と $\phi(Z)$ はそれぞれ標準正規分布の累積密度関数と確率密度関数である。

4. パーシステントホモロジー

位相的データ解析 (topological data analysis, TDA) ではトポロジーの観点から、点群やグラフで表現されるデータの大きな形に注目して分析を行う。トポロジーでは伸縮させて一致させられる図形同士は同じものとして扱われる。このような図形同士はホモトピー同値であるといわれ、連結成分や穴の数が同じ図形となっている。ここでは、TDA 手法の一つであるパーシステントホモロジーについて直感的な説明を行う。

距離空間 (M, d) 上の点群 $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ をパーシステントホモロジーによって分析する。このとき、各点を中心とする半径 r の領域をすべて足し合わせた領域 S_r を考える。

$$S_r = \bigcup_{i=1}^N \{\mathbf{x} \in M \mid d(\mathbf{x}, \mathbf{x}_i) \leq r\}$$

いくつかの r に対する S_r の例を図 1 に示す。 r を大きくしていくと、領域同士が繋がって大小二つのリングが現れ、やがて小さいリングが潰れて無くなっていく様子が観察できる。パーシステントホモロジーでは、このとき現れる連結成分や穴などの幾何学的な構造について、それがいつ現れ、どのくらいの期間見られるのかに注目して分析を行う。

パーシステントホモロジーによって得られるトポロジカルな特徴は、パーシステント図 (persistence diagram, PD) と呼ばれる図として表現される。PD は r を大きくしていく過程で S_r に見られる幾何学的な構造について、その構造が現れたときの半径 b と潰れて無くなったときの半径 d のペア (b, d) をプロットしたものである。このとき注目する構造によって複数の PD が考えられ、連結成分に注目した場合は 0 次の PD、リングに注目した場合は 1 次の PD などと呼ばれる。図 1 の点群に対する 0 次の PD と 1 次の PD を図 2 に示す。1 次の PD には大小のリングに対応する二つの点が見て取れる。小さい方のリングは birth と death の差が小さいことから分かるように、対角線に近い点に対応している。同様に大きい方のリングは対角線から離れた点に対応している。このことから、対角線の近くに分布している点はすぐに消えるノイズ的な構造を表しており、対角線から離れて分布している点はより重要な構造を表していると考えられる。

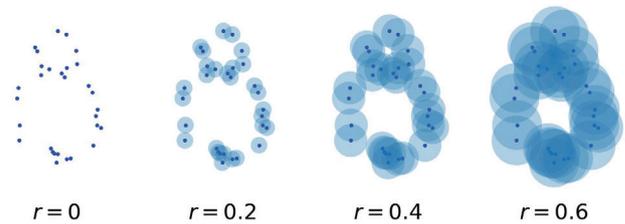


図 1: いくつかの r に対する S_r の例

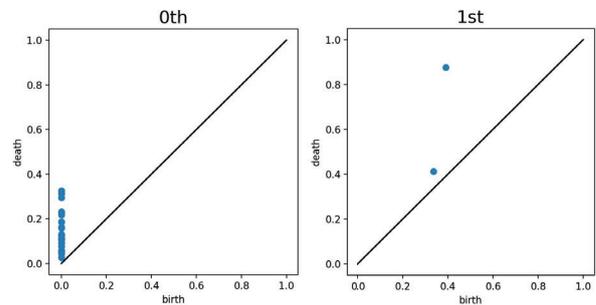


図 2: 図 1 の点群に対する 0 次の PD と 1 次の PD

5. 提案手法

本研究では、PD に対するカーネルを用いることで、パーシステントホモロジーによって得られる情報を利用したベイズ最適化を行う。また、複数のカーネルを線型結合で組み合わせることによって、一つのデータから得られる複数種類の PD の情報を同次に扱う方法を考える。

5.1 パーシステント図に対するカーネル

5.1.1 Persistence weighted Gaussian kernels

Persistence weighted Gaussian kernels (PWGK) [Kusano 16] は、PD を重み付き測度とみなしてカーネル平均埋め込みによって RKHS 上にベクトル化することで、通常の線形カーネル (PWGK-Linear) やガウスカーネル (PWGK-Gaussian) を考えられるようにする方法である。そ

それぞれは以下の式で表される。

$$k_L(D_i, D_j) = \sum_{\mathbf{x} \in D_i} \sum_{\mathbf{y} \in D_j} w(\mathbf{x})w(\mathbf{y}) \exp\left(-\frac{\|\mathbf{x}-\mathbf{y}\|^2}{2\sigma^2}\right)$$

$$k_G(D_i, D_j) = \exp\left(-\frac{d(D_i, D_j)^2}{2\tau^2}\right)$$

ここで、 $w(\mathbf{x})$ は各点を対角線からの距離に応じて重み付ける関数であり、[Kusano 16] では $w(\mathbf{x}) = \arctan(C \text{pers}(\mathbf{x})^p)$ が使用されている。pers(\mathbf{x}) は \mathbf{x} の death と birth の差である。また、 $d(D_i, D_j)^2 = k_L(D_i, D_i) + k_L(D_j, D_j) - 2k_L(D_i, D_j)$ と表される。

5.1.2 Persistence Fisher kernel

Persistence Fisher kernel (PFK) [Le 18] は、PD を平均だけが異なる正規分布の和とみなして、フィッシャー情報計量を用いて類似度を測る方法である。PFK ではパーシステント図 D_i, D_j を対角線に射影した $D_{i\Delta}, D_{j\Delta}$ を考え、 D_i と D_j を比較する代わりに $D'_i = D_i \cup D_{j\Delta}$ と $D'_j = D_j \cup D_{i\Delta}$ を比較する。まず PD の各点を中心とする正規分布の和を考える。

$$\rho_{D'_i}(\mathbf{x}) = \frac{1}{Z} \sum_{\mu \in D'_i} \mathcal{N}(\mathbf{x}; \mu, \sigma \mathbf{I})$$

ここで、 Z は正規化定数である。そしてこの分布に対するフィッシャー情報計量を考える。

$$d_{FIM}(D_i, D_j) = \arccos\left(\int \sqrt{\rho_{D'_i}(\mathbf{x})\rho_{D'_j}(\mathbf{x})} d\mathbf{x}\right)$$

最終的なカーネルは以下の式で表される。

$$k_{PF}(D_i, D_j) = \exp(-td_{FIM}(D_i, D_j))$$

5.2 複数カーネルの組み合わせ

パーシステントホモロジーで得られた複数の PD の情報を同時に扱うために、それぞれの PD から計算したカーネルを組み合わせる一つのカーネルを構成する。ここでは、0 次の PD から計算したグラム行列 \mathbf{K}_0 と 1 次の PD から計算したグラム行列 \mathbf{K}_1 を線型結合によって組み合わせる。

$$\mathbf{K} = \alpha_0 \mathbf{K}_0 + \alpha_1 \mathbf{K}_1$$

係数 $\alpha_0, \alpha_1 > 0$ の学習方法として以下の方法を考える。

5.2.1 kernel target alignment

複数のカーネルを線形結合によって組み合わせる際に、以下で定義される alignment を最大化するように係数を学習する方法が提案されている [Cortes 10]。

$$\rho(\mathbf{K}, \mathbf{Y}) = \frac{\langle \mathbf{K}_c, \mathbf{Y}_c \rangle_F}{\|\mathbf{K}_c\|_F \|\mathbf{Y}_c\|_F}$$

ここで、 $\mathbf{Y} = \mathbf{y}\mathbf{y}^T$ 及び $\mathbf{K}_c(x, y) = \mathbf{K}(x, y) - \mathbb{E}_x[\mathbf{K}(x, y)] - \mathbb{E}_y[\mathbf{K}(x, y)] + \mathbb{E}[\mathbf{K}(x, y)]$ である。alignment の最大化は二次計画問題に帰着させることができる。ベイズ最適化では各ステップで \mathbf{y} が更新されるので、各ステップにおいて新たな出力が得られたタイミングで学習を行う。

5.2.2 最尤推定

ベイズ最適化では目的関数をガウス過程によってモデル化している。このとき、あるステップまでに出力データ $\mathbf{y} = (y_1, \dots, y_t)^T$ が得られているとすると、 \mathbf{y} に対する対数尤度は以下のように計算できる。

$$\log p(\mathcal{D}|\alpha) \propto -\frac{1}{2} \mathbf{y}^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{y} - \frac{1}{2} \log |\mathbf{K} + \sigma^2 \mathbf{I}|$$

そこで係数を学習する方法として、最尤推定によってこの対数尤度を最大化する方法を考える。対数尤度の最大化は勾配に基づく最適化手法などを用いて行うことができ、こちらも新たな出力が得られたタイミングで学習を行う。

6. 評価実験

6.1 データセット

人工データと 2 つの実データを用いて実験を行う。人工データの生成には [Hertzsch 07] で提案されている方法を用いる。 $r > 0$ と初期点 $(x_0, y_0) \in [0, 1] \times [0, 1]$ から、以下の式に従って点群 $\{(x_i, y_i)\}_{i=1}^N$ を生成する。

$$x_{n+1} = x_n + r y_n (1 - y_n) \pmod{1}$$

$$y_{n+1} = y_n + r x_{n+1} (1 - x_{n+1}) \pmod{1}$$

ここでは $N = 1000$ とした。 $r = 2.0$ の場合と $r = 4.3$ の場合に生成される点群を図 3 に示す。この点群を一つのデータとし、生成に用いた r をその目的関数値とする。データセットは $r \in [2.0, 4.3]$ の範囲からランダムに 1000 個選んで生成する。

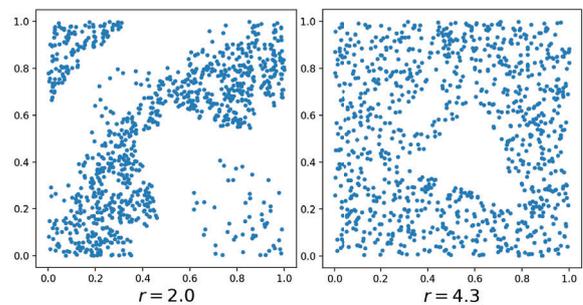


図 3: 人工データの例

実データには MoleculeNet [Wu 17] から ESOL データセットと FreeSolv データセットを使用する。どちらも比較的小さい化合物の性質に関するデータセットである。ESOL は水溶性に関するデータセットでサイズは 1128, FreeSolv は水和自由エネルギーに関するデータセットでサイズは 642 である。本研究では、化合物を構成する原子の種類や結合は考慮せずに、原子の 3 次元座標のみを用いて化合物を点群として扱う。

6.2 PD に対するカーネルによる効果

まずランダムに探索する場合と比べて、PD の情報によってどの程度効率的に探索できるようになるか検証する。ベイズ最適化では、ランダムに選んだ 10 個のデータを用いて最初の予測分布を計算する。カーネルとして PWGK-Linear, PWGK-Gaussian, PFK を用い、獲得関数として EI を用いる。これらのカーネルは人工データについては 1 次の PD を用いて計算し、実データについては 0 次の PD を用いて計算する。また、ハイパーパラメータの設定と近似計算を元論文 [Kusano 16][Le 18] に従ってそれぞれ行う。ベイズ最適化を 30 回実行したときの、各ステップで得られている最小解の平均を図 4 に示す。ランダムに探索する場合と比べて、PD に対するカーネルを用いることで効率的に探索できていることが分かる。

6.3 複数のカーネルの組み合わせ

続いて複数種類の PD の情報を組み合わせることで、一種類のみを用いる場合と比べて、どの程度効率的に探索できるようになるか検証する。0 次の PD から計算したカーネルを使用し

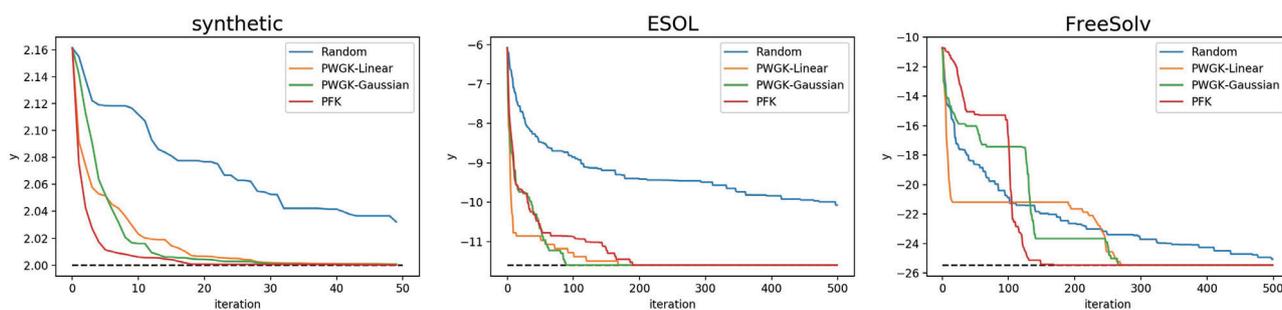


図 4: 各ステップにおいて得られている最小解の推移。黒い点線は探索対象である最適解を示している。

た場合 (0th), 1 次の PD から計算したカーネルを使用した場合 (1st), 両者を kernel target alignment によって組み合わせた場合 (align), 最尤推定によって組み合わせた場合 (MLE) とを比較する。ここでは評価指標として, 図 4 における収束曲線と黒い点線とで挟まれた部分の面積を用いる。各カーネルについて実験を行った結果を表 1 に示す。各値はランダムの場合が 1 になるようにスケールされている。多くの場合において, 最尤推定によって PD の情報を組み合わせることで, より効率的に探索できるようになることが分かる。

表 1: 複数カーネルの組み合わせによる実験結果

		Synthetic	ESOL	FreeSolv
Random		1.0000	1.0000	1.0000
PWGK -Linear	0th	0.1597	0.0571	0.6832
	1st	0.1551	0.3867	1.4169
	align	0.1664	0.3119	1.0350
	MLE	0.0898	0.1757	0.5241
PWGK -Gaussian	0th	0.1512	0.0763	0.8833
	1st	0.1509	0.4630	1.2399
	align	0.1618	0.2455	0.8862
	MLE	0.4308	0.0560	0.5867
PFK	0th	0.1172	0.1153	0.7685
	1st	0.0730	0.2544	0.6644
	align	0.0922	0.1195	0.8695
	MLE	0.2220	0.0703	0.7640

7. 関連研究

グラフ構造データに対するベイズ最適化に関する研究はいくつかあるが, 任意のグラフ構造に対するベイズ最適化のフレームワークとして, Graph Bayesian Optimization (GBO) が提案されている [Cui 18]。GBO では二つのカーネルの線形結合によってカーネルを構成している。一つはグラフの次数や各種中心性などを要素とするベクトルを用いた, ガウスカーネルなどのベクトルカーネルである。次数や中心性などの特徴量はグラフの幾何学的な特徴を表す値ではあるが, こうした明示的な特徴がそれをうまく反映できているとは限らない。そこで GBO では, ベクトルカーネルで表現されない情報を補うために, もう一つのカーネルとしてグラフカーネルを用いている。

8. むすび

本研究では, パーシステントホモロジーによって得られる複数のトポロジカルな情報を利用したベイズ最適化手法を提案し

た。PD に対するカーネルを用いた実験によって, PD の情報が効率的な探索に寄与していることと, 複数種類の PD の情報を組み合わせることでより効率的に探索できることを示した。

今後の課題として, 他の PD カーネルや獲得関数を用いた実験を試すことや, グラフカーネルを用いる GBO との比較を検討している。ベイズ最適化では, より実用的な問題設定として, 各イテレーションで一つずつデータを選択するのではなく, 複数の候補をまとめて選択することが考えられる。本研究では, 化合物のようなグラフ構造データを点群として扱ったが, グラフのノードやエッジに付加されている特徴を扱えるように拡張することが考えられる。また, 新たなグラフを生成する仕組みを追加することで, グラフを生成しながら未知のグラフ構造を探索できるようにすることも考えている。

参考文献

- [Cortes 10] Cortes, C., Mohri, M., and Rostamizadeh, A.: Two-Stage Learning Kernel Algorithms, *In Proceedings of the 27th International Conference on Machine Learning* (2010)
- [Cui 18] Cui, J. and Yang, B.: Graph Bayesian Optimization: Algorithms, Evaluations and Applications, *arXiv preprint arXiv:1805.01157* (2018)
- [Hertzsch 07] Hertzsch, J.-M., Sturman, R., and Wiggins, S.: DNA microarrays: design principles for maximizing ergodic, chaotic mixing, *Small*, Vol. 3, pp. 202–218 (2007)
- [Kusano 16] Kusano, G., Fukumizu, K., and Hiraoka, Y.: Persistence weighted Gaussian kernel for topological data analysis, *In Proceedings of the 33rd International Conference on Machine Learning*, pp. 2004–2013 (2016)
- [Le 18] Le, T. and Yamada, M.: Persistence Fisher Kernel: A Riemannian Manifold Kernel for Persistence Diagrams, *Advances in Neural Information Processing Systems*, pp. 10027–10038 (2018)
- [Wu 17] Wu, Z., Ramsundar, B., Feinberg, E. N., Gomes, J., Geniesse, C., Pappu, A. S., Leswing, K., and Pande, V.: MoleculeNet: A Benchmark for Molecular Machine Learning, *arXiv preprint arXiv:1703.00564* (2017)

過去記憶を用いたスケーラブルなベイズ最適化

Scalable Bayesian Optimization with Memory Retention

伊藤秀剛^{*1}

Hidetaka Ito

松林達史^{*1}

Tatsushi Matsubayashi

倉島健^{*1}

Takeshi Kurashima

戸田浩之^{*1}

Hiroyuki Toda

^{*1}日本電信電話株式会社 NTT サービスエボリューション研究所

NTT Service Evolution Laboratories, NTT Corporation

Bayesian optimization is a method for the global optimization of black-box functions as few evaluation as possible. It utilizes Gaussian processes to efficiently select parameters to be evaluated. However, it is not scalable because Gaussian processes scale cubically with the number of iterations. In this work, we propose a method for scalable Bayesian optimization by leveraging models used in past iterations, which we call past memory. This technique enables us to fit Gaussian processes to only input-output pairs near the previously selected input parameter. In experiments, we show our proposed method outperforms naive Bayesian optimization in terms of optimization performance with limited time budget.

1. はじめに

ベイズ最適化は探索領域内で関数値が最適となる入力パラメータ $\mathbf{x}^* = \arg \min_{\mathbf{x} \in \mathcal{X}} \mathcal{F}(\mathbf{x})$ を求める手法である [Shahriari 16]. ベイズ最適化は、ブラックボックス関数（関数の事前知識がない関数であり、関数にパラメータを入力し評価して得られる関数値のみを利用できる）の最適化に適用可能で、評価する入力パラメータと、評価そのものを交互に繰り返しながら関数を最適化する手法である。この手法はモデルとしてガウス過程を用意し、過去に評価を行った入力パラメータと関数出力値の組を学習する。そして、そのモデルの予測値を基に次に評価を行うべき入力パラメータを決定する。このことによって、関数の評価回数を可能な限り最小限に抑えることができるようにこの手法は設計されており、機械学習のハイパーパラメータの最適化などに幅広く応用されてきた。

しかし、ベイズ最適化は、評価する入力パラメータの決定と関数の評価の繰り返し回数が増えるにつれ、ガウス過程のモデルが学習すべきデータの量が増加するため、入力パラメータの決定に時間がかかるようになる。ガウス過程の計算量は学習するデータ量の3乗に比例するため、学習データ量の増加によりアルゴリズムの実行速度は大幅に低下する。そのため、一定の繰り返し回数以上では入力パラメータ決定が関数の評価より時間がかかるようになる。このことから、ベイズ最適化は繰り返し回数を増やすことが困難であり、通常数百回程度の評価回数に制限される。これの対処方法として、ガウス過程よりも計算量の低い別のモデルへの置き換えを行う手法 [Hutter 11] があるが、これらはモデルの表現力が低下する問題がある。

そこで、本論文では繰り返し回数を増やしても、所要時間の増加を抑えることができる、Bayesian Optimization with Memory Retention (BOMR) を提案する。提案手法のアイデアは、過去の繰り返しにおいて使用したモデルの予測結果、つまり過去記憶を再利用することである。図1に提案手法の概念図を示す。ある繰り返しで左から2番目の赤点（丸い黒枠で囲まれている）が新たな入力パラメータとして選択されたときを考える。ベイズ最適化は、この新たに選択された入力パラメータをデータ点として保持する。ここで、ガウス過程のモデ

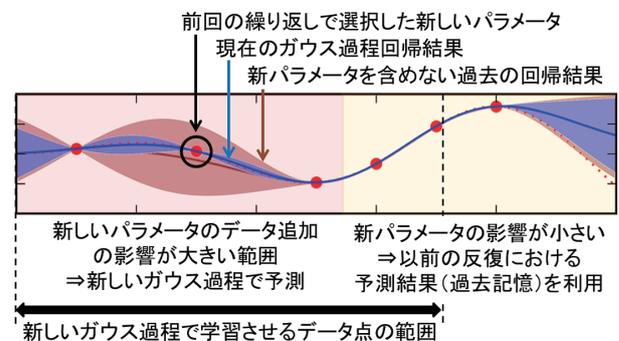


図 1: 提案手法の概要

ルが学習するデータに、新たなデータ点が含まれていないモデルと、含まれているモデルの予測結果を、それぞれ赤茶色と青色で示す。新たなデータ点が学習データに含まれたことによって、そのデータ点の周辺は予測結果が大きく変化することがわかる。一方、新たなデータ点から離れた範囲は、予測結果が似通っており、新しいデータ点を含まないモデルの予測結果を用いても、新しいデータ点を学習したモデルと変わらない十分な予測精度を持つとわかる。

このことに着目し本手法では以下の工夫を行う。まず、直前に選択された新しい入力パラメータの周辺（薄赤の範囲）のみ、この入力パラメータをデータ点として加えて新しく学習したモデルで予測を行う。また、新しく学習するモデルのデータ点は、新しい入力パラメータの周辺を十分に予測できる範囲に存在するデータ（黒矢印の範囲）に限る。このことで、繰り返しの回数の増加に対する学習データの増加を抑え、ガウス過程の計算時間を抑制する。一方、新入力パラメータの周辺以外（黄色の範囲）は、過去記憶として保存した以前の繰り返しにおける予測結果を再利用する。これらの工夫によって、ガウス過程の高い予測精度を維持しながら、繰り返し回数を増やすことが可能である。

ここで、新たに学習したモデルを用いて予測を行う範囲（薄赤の範囲）の決定方法について、本論文では2つの方法を提案する。1つ目が、新たな入力パラメータの影響度合いを表す

数値に閾値を設けて範囲を決める方法、2つ目が新たな入力パラメータの周りの点との相対的な位置関係に基づきポロノイ領域を用いて範囲を決める方法である。

本論文では、人工関数を用いた最適化実験を行う。そして、提案手法が繰り返し回数の増加に対する所要時間の増加を抑えることができ、通常のベイズ最適化より高い精度で最適化を行えることを示す。また、新たなモデルの予測範囲の決定方法は、短時間の最適化ならば1つ目の方法、長時間の最適化ならば2つ目の手法がより有効であることも示す。

2. ベイズ最適化

ベイズ最適化は、評価する入力パラメータの決定とその評価を、試行錯誤的に繰り返す手法である。ベイズ最適化のプロセス実行の前はデータ \mathcal{D}_0 の初期化を行う*1。 t 回目の繰り返しでは、下記の3つのプロセスを通して入力パラメータ \mathbf{x}_t を選択し、評価する。繰り返しは総計 T 回行われる。

1つ目のプロセスがガウス過程を用いたモデルの学習である。ガウス過程は教師あり学習の一種であり、 D 次元のベクトルの入力 $\mathbf{x} = [x_1, \dots, x_D]$ に対してスカラー値の出力 $y = \mathcal{F}(\mathbf{x})$ が対応するデータを用いて学習を行うことで、新たな D 次元のベクトルを入力として、その入力に対応するスカラー値の出力を予測するモデルである[Rasmussen 06]。ガウス過程は、平均的な予測値を決める平均値関数 $m: \mathcal{X} \rightarrow \mathbb{R}$ とデータの相関関係を決める共分散カーネル $k: \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$ によって規定される。本論文では平均値関数は定数 $m(\mathbf{x}) = m_0$ とする。また、共分散カーネルとしてガウスカーネル $k(\mathbf{x}, \mathbf{x}') = \exp(-\|\mathbf{x} - \mathbf{x}'\|_2^2 / (2h^2))$ を用いる。このカーネルは、2つの入力のユークリッド距離が近いと、それらの出力も似ていると予測する性質を持つ。 $h \in \mathbb{R}_+$ はスケールの大きさを規定するハイパーパラメータであり、最尤推定で決定可能である。ガウス過程は $t-1$ 回目までの繰り返しで得たデータ $\mathcal{D}_{t-1} = \{(\mathbf{x}_i, y_i) \mid i = 1, \dots, t-1\}$ を用いて学習を行う。このプロセスの計算量は、ガウス過程の学習のためデータ数を要素数とする正方行列の逆行列計算を行うことで $O(t^3)$ 、これを繰り返すと $O(T^4)$ である。

2つ目のプロセスが、モデルを用いた、次に評価する入力パラメータの選択である。実際の関数に入力して評価を行っていない入力パラメータ \mathbf{x} に対しても、ガウス過程を用いて関数の値の予測を行うことができる。ここで、ガウス過程の利点は予測を平均 $\mu(\mathbf{x})$ 、分散 $\sigma(\mathbf{x})$ のガウス分布の形で行うことで、予測値のみならず、その不確かさも得ることができることである。ガウスカーネルの性質から、入出力データの入力値にユークリッド距離が近い入力パラメータに対しては小さい不確かさを持って、距離が遠い入力パラメータは大きい不確かさを持って予測する。

ベイズ最適化は、このガウス過程の予測結果を用いて獲得関数 $\alpha(\mathbf{x})$ という、次に選択するべき度合いを数値化する関数を計算し、それを最大化する入力

$$\mathbf{x}_t = \arg \max_{\mathbf{x} \in \mathcal{X}} \alpha(\mathbf{x})$$

を、次に評価する入力パラメータとして選択する。本論文では期待改善量 (EI) という獲得関数を用いる [Bull 11]。EI は $\alpha(\mathbf{x}) = (\tau - \mu(\mathbf{x})) \Phi(\gamma) + \sigma(\mathbf{x}) \phi(\gamma)$ と与えられる。ここで、 τ は今まで得られた出力の最適値であり、 $\gamma = (\tau - \mu(\mathbf{x})) / \sigma(\mathbf{x})$

*1 本論文の実験ではランダムサンプリングによって $T_0 = 50$ 点の初期点、 $\mathbf{x}_1^{\text{init}}, \dots, \mathbf{x}_{T_0}^{\text{init}}$ を選択し、その評価を行い $i = 1, \dots, T_0$ に対して $y_i^{\text{init}} = \mathcal{F}(\mathbf{x}_i^{\text{init}})$ を得て、それを \mathcal{D}_0 に加える。

Algorithm 1 Bayesian Optimization with Memory Retention (BOMR)

- 1: **Input:** 目的関数 $\mathcal{F}(\mathbf{x})$, 探索範囲 \mathcal{X} , 獲得関数 $\alpha(\mathbf{x})$, 最大繰り返し回数 T
- 2: \mathcal{D}_0 のランダムサンプリングなどを用いて初期化
- 3: 過去記憶 $\mathcal{M}_0 \leftarrow \emptyset$
- 4: **for** $t = 1, 2, \dots, T$ **do**
- 5: 探索範囲 $\mathcal{X}'_t \subseteq \mathcal{X}$ の絞りこみ
- 6: 学習データ $\mathcal{D}'_t \subseteq \mathcal{D}_{t-1}$ の絞り込み
- 7: ガウス過程による \mathcal{D}_{t-1} へのフィッティング
- 8: $\mathcal{M}_t \leftarrow \{(\mathbf{x}, \mu(\mathbf{x}), \sigma(\mathbf{x})) \in \mathcal{M}_{t-1} \mid \mathbf{x} \notin \mathcal{X}'_t\}$
- 9: $\mathbf{x}_t^{\mathcal{M}} \leftarrow \arg \max_{\mathbf{x} \in \mathcal{M}_t} \alpha(\mathbf{x})$
- 10: $\mathbf{x}'_t \leftarrow \arg \max_{\mathbf{x} \in \mathcal{X}'_t} \alpha(\mathbf{x})$
- 11: $\mathbf{x}_t \leftarrow \arg \max_{\mathbf{x} \in \{\mathbf{x}_t^{\mathcal{M}}, \mathbf{x}'_t\}} \alpha(\mathbf{x})$
- 12: 評価 $y_t \leftarrow \mathcal{F}(\mathbf{x}_t)$
- 13: $\mathcal{D}_t \leftarrow \mathcal{D}_{t-1} \cup \{(\mathbf{x}_t, y_t)\}$
- 14: 10行目の最適化中に調べた点のデータを \mathcal{M}_t に追加
- 15: **Return** \mathcal{D}_T 内で最良の入力パラメータ

である。また、 $\Phi(\gamma)$ と $\phi(\gamma)$ はそれぞれ標準正規分布の累積分布関数と確率密度関数である。EI は探索と活用のバランスを取れる性質を持つ。探索とは不確かさの大きい入力パラメータを調べることであり、活用とは良い結果を得た入力パラメータに似ているものを調べることであり、探索だけではランダムな選択が増え効率が悪いが、活用だけでは局所解にトラップされ最適解にたどり着くことができないため、この2つを両立するよう EI は設計されている。本論文では獲得関数の最大化に多スタート局所探索を用いる。多スタート局所探索は、複数の点をランダムで選択し、その場所を起点として局所探索の手法を用いて局所解を探索し、得られた局所解の中から最も最適な点を選択する手法である。局所探索の手法としては L-BFGS を用いる。このプロセスは、獲得関数の計算回数を T_a とすると、ガウス過程の予測のために繰り返し1回当たり $O(T_a t^2)$ 、繰り返し全体で $O(T_a T^3)$ の計算量である。

3つ目のプロセスが選択した入力パラメータの評価である。評価後は結果をデータに追加し、 $t+1$ 回目の反復に移行する。このプロセスの計算量は繰り返し回数に依らないため、 t が小さいときに最も計算時間がかかるのはこのプロセスだが、 t が増加すると1, 2つ目のプロセスが計算時間のボトルネックとなる。

3. 提案手法

3.1 過去記憶の利用

提案手法である BOMR をアルゴリズム 1 に示す。BOMR は、過去の繰り返しで用いたガウス過程モデルによる、関数出力値の予測結果を過去記憶として保存する。そして、過去記憶で十分に予測ができる範囲については過去記憶を用いることで、それができない範囲については新たなモデルで予測を行う。探索範囲内の入力パラメータの関数評価値の予測を行い、それを基に次に探索する点を決定する。

t 回目の繰り返しにおいて、BOMR は以下のように過去記憶の利用を行う。まず、前回の繰り返しで選択された入力パラメータ \mathbf{x}_{t-1} の影響が強い範囲が、過去記憶が使えない範囲であるので、これを t 回目の探索範囲 \mathcal{X}'_t とする (5行目)。そして、その探索範囲内の予測を十分に行えるだけの学習データ \mathcal{D}'_t を、過去に評価したデータ \mathcal{D}_{t-1} の中から一部を絞り込む

ことで得て、その D'_t を使ってガウス過程を学習させる (6,7 行目). 次は、 \mathcal{X}'_t を新たに調べなおすため、過去記憶の中から \mathcal{X}'_t を除いた範囲にある入力パラメータのデータだけ保持する (8 行目). その後は獲得関数最大化のプロセスを行う. まず、過去記憶のデータで最も獲得関数の値が大きい点 \mathbf{x}_t^M を得る *2 (9 行目). 次に \mathcal{X}'_t 内で最も獲得関数の値が大きい点 \mathbf{x}'_t を得る (10 行目). そして、 \mathbf{x}_t^M と \mathcal{X}'_t を比較し、獲得関数の値が大きい方を t 回目の繰り返しで評価する入力パラメータ \mathbf{x}_t として選択する (11 行目). 後は \mathbf{x}_t を評価して関数評価値 $\mathcal{F}(\mathbf{x}_t)$ を取得し、評価済のデータに加える (12,13 行目). 最後に 10 行目の最適化の間に調べた点のデータを過去記憶 \mathcal{M}_t に追加する *3 (14 行目).

3.2 探索範囲の絞りこみ

BOMR において、毎回の繰り返しにおける探索範囲 \mathcal{X}'_t をどのように行うかが問題である. 本論文では、これらの決め方について 2 通りの方法を提案する.

3.2.1 カーネルの値の閾値を用いた方法

カーネルの値の閾値を用いた方法を述べる. ある入力パラメータ \mathbf{x} の関数評価値 $\mathcal{F}(\mathbf{x})$ を予測するとき、 \mathbf{x} と過去に選択した入力パラメータ \mathbf{x}_{t-1} とのカーネルの値 $k(\mathbf{x}, \mathbf{x}_{t-1})$ は、 \mathbf{x}_{t-1} が予測結果 $\mu(\mathbf{x}), \sigma(\mathbf{x})$ に与える影響力の強さを表す. そこで、 $k(\mathbf{x}, \mathbf{x}_{t-1})$ がある閾値を上回る範囲を、新しいモデルで予測すべき範囲とみなし、これを含んだ空間に \mathcal{X}'_t を絞り込むことを考える. ガウスカーネルなど一般的なガウス過程のカーネルを用いると、 \mathbf{x} と \mathbf{x}_{t-1} のユークリッド距離が近いときに $k(\mathbf{x}, \mathbf{x}_{t-1})$ が大きくなる. そこで、 \mathbf{x}_{t-1} に近い範囲に \mathcal{X}'_t を絞り込めばよい. そこで、スケールの大きさを規定するハイパーパラメータ h を考慮して、

$$S_c(\mathbf{x}_{t-1}) = \{\mathbf{x} \in \mathcal{X} \mid \|\mathbf{x} - \mathbf{x}_{t-1}\|_2 \leq h \cdot c\}$$

に対し、 $S_c(\mathbf{x}_{t-1}) \subseteq \mathcal{X}'_t$ なる \mathcal{X}'_t を探索範囲とする. ここで、 c はハイパーパラメータであり、 c が大きい程、広い範囲が探索範囲となる. このとき、 h を最尤推定を用いて決定している場合は、新しいガウス過程を学習する前に h の値を得ることができないが、以前の繰り返しにおける h の値で代替することができる *4.

ここで、 $S_c(\mathbf{x}_{t-1})$ は球になるが、獲得関数最大化は L-BFGS が使える立方体 $\{\mathbf{x} \in \mathcal{X} \mid \forall i = 1, \dots, D, x^L \leq x_i \leq x^U\}$ の方が行いやすい. ここで \mathbf{x} の i 番目の要素を x_i と表している. そこで、 \mathcal{X}'_t を、各軸に直交する面を持つ体積最小の立方体とする. このとき \mathcal{X}'_t は $S_c(\mathbf{x}_{t-1})$ に外接する. つまり、 $x^L = x_{(t-1,i)} - h \cdot c$ であり、 $x^U = x_{(t-1,i)} + h \cdot c$ である. ここで、 $x_{(t-1,i)}$ は \mathbf{x}_{t-1} の i 番目の要素である.

3.2.2 ボロノイ領域を用いた方法

次にボロノイ領域を用いて \mathcal{X}'_t を絞り込む方法を述べる. $k(\mathbf{x}, \mathbf{x}_{t-1})$ の観点では \mathbf{x} の関数評価値の予測値に \mathbf{x}_{t-1} が与える影響力の強さは、 $\|\mathbf{x} - \mathbf{x}_{t-1}\|_2$ に対し単調減少する. しかし、 \mathbf{x} の周りにデータ点が少ない場合は、予測値に影響を与える他の要素が少ない為、 \mathbf{x} と \mathbf{x}_{t-1} との距離がある程度遠くて

*2 このとき、獲得関数として EI を用いている場合は、過去の最良値 τ が変化していない場合、同じ平均と分散を持つ予測結果に対して、過去に計算した獲得関数の値と変化がない為、再利用して実行時間を削減することができる.

*3 このとき、有望な結果のみを記憶として保存してもよく、その場合は実行時間を削減できる. 本論文では得られた獲得関数値の局所的な最大値を取る入力パラメータのみを記憶として保存する.

*4 本論文では過去の繰り返し 100 回分の h の中央値を用いた.

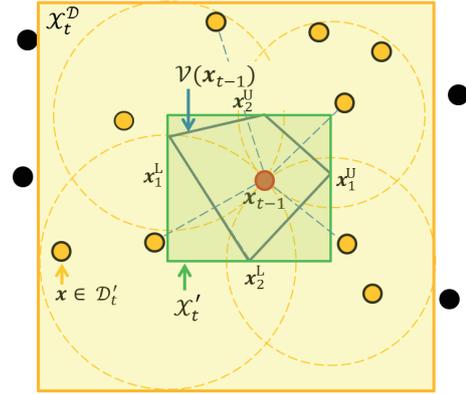


図 2: ボロノイ領域を用いた場合の探索範囲と学習データ点の絞り込み方法の図示. 赤色の点 \mathbf{x}_{t-1} 、深緑色の四角形で囲まれた範囲が $\mathcal{V}(\mathbf{x}_{t-1})$ であり、黄緑色で塗られた範囲が \mathcal{X}'_t である. そして、その外側の黄色い枠で囲まれた領域が \mathcal{D}'_t であり、黄色の点で表されたデータ点が \mathcal{D}'_t に含まれる. 黒い点で表されたデータ点は学習しないデータ点である.

も予測値へ大きな影響を与えると考えられる. 一方、 \mathbf{x} の周りにデータ点が多い場合は、 \mathbf{x}_{t-1} が与える \mathbf{x} の予測値への影響は小さくなると考えられる. よって、 \mathbf{x}_{t-1} と他のデータ点との相対的な距離関係を考慮して \mathcal{X}'_t を絞り込むべきである.

これを実現する方法としてボロノイ領域の利用がある. この方法では、 \mathbf{x} の関数評価値の予測値に影響を与えるのは、 \mathbf{x} の最近傍点であると考え *5. よって、 \mathbf{x} の最近傍点が \mathbf{x}_{t-1} であれば \mathcal{X}'_t に加える. そこで、 \mathbf{x}_{t-1} のボロノイ領域

$$\mathcal{V}(\mathbf{x}_{t-1}) = \{\mathbf{x} \in \mathcal{X} \mid \forall i = 1, \dots, t-2, \|\mathbf{x}_{t-1} - \mathbf{x}\|_2 \leq \|\mathbf{x}_i - \mathbf{x}\|_2\}$$

を用いて、 $\mathcal{V}(\mathbf{x}_{t-1}) \subseteq \mathcal{X}'_t$ なる \mathcal{X}'_t を探索範囲とする. ボロノイ領域を用いることで、繰り返し回数が増えにつれ探索範囲が狭まっていき、これに応じて学習すべきデータの増大を防げる. ここで $\mathcal{V}(\mathbf{x}_{t-1})$ は複雑な形状であり、また厳密に得るための計算量も大きい. そこで、探索領域は各軸に直交する面を持ち体積が最小となる直方体 $\mathcal{X}'_t = \{\mathbf{x} \in \mathcal{X} \mid \forall i, x_i^L \leq x_i \leq x_i^U\}$ とする. このときも \mathcal{X}'_t は $\mathcal{V}(\mathbf{x}_{t-1})$ に外接する.

\mathcal{X}'_t の計算方法について述べる. $f_i(\mathbf{x}) = x_i$ という関数を定義すると、 $x_i^L = \min_{\mathbf{x} \in \mathcal{V}(\mathbf{x}_{t-1})} f_i(\mathbf{x})$ であり $x_i^U = \max_{\mathbf{x} \in \mathcal{V}(\mathbf{x}_{t-1})} f_i(\mathbf{x})$ である. ここで、 $f_i(\mathbf{x})$ は線型関数である. また、 $\|\mathbf{x}_{t-1} - \mathbf{x}\|_2 \leq \|\mathbf{x}_i - \mathbf{x}\|_2$ という条件は、 \mathbf{x}_{t-1} と \mathbf{x}_i の垂直二等分面で \mathcal{X} を隔てた 2 つの空間のうち、 \mathbf{x}_{t-1} が存在する側に \mathbf{x} が存在する条件、つまり $(\mathbf{x}_{t-1} - \mathbf{x}_i)^\top \mathbf{x} \geq (\|\mathbf{x}_{t-1}\|_2^2 - \|\mathbf{x}_i\|_2^2)/2$ と同値であり、これは線型制約である. これらより、 x_i^L や x_i^U を求める問題は線型計画問題であり、線型計画法で求めることができる *6.

*5 実際に [Bull 11] では、 h が一定の条件にてガウス過程の予測値の不確かさが最近傍点との距離によって上から抑えることができ、これが最適化性能に影響することが示されている.

*6 線型計画法のアルゴリズムの計算量は制約条件の数に応じて増大していく. しかし、 $\mathcal{V}(\mathbf{x}_{t-1})$ の形に影響するデータ点は \mathbf{x}_{t-1} に近いデータ点のみであるので、そのようなデータ点をいくつか選び、それらに関する制約条件のみを考えることで計算量を削減できる. 一部の制約条件のみを考えて得た x_i^L (または x_i^U) が正しいことは、 $f_i(\mathbf{x}) = x_i^L$ (または $f_i(\mathbf{x}) = x_i^U$) となる \mathbf{x} の最近傍点が \mathbf{x}_{t-1} であることを調べればわかる. 最近傍探索は $O(t)$ の計算量で可能であり、kd 木などの手法を用いて高速化することもできる. x_i^L や x_i^U

3.3 学習データ点の絞りこみ

\mathcal{D}'_t の絞り込みは \mathcal{X}'_t に応じて行う。本論文では学習するデータ点の範囲 \mathcal{X}'_t を決め、 $\mathcal{D}'_t = \{(\mathbf{x}, y) \in \mathcal{D}_{t-1} \mid \mathbf{x} \in \mathcal{X}'_t\}$ とする。 \mathcal{X}'_t 内の点を十分学習できる範囲を \mathcal{X}^D_t はとる必要があるため、 $\mathcal{X}'_t \subseteq \mathcal{X}^D_t$ であることに注意する。本論文では \mathcal{X}'_t と同様に \mathcal{X}^D_t を各軸に直交する面を持つ直方体とする。

そこでポロノイ領域の考え方をを用いて \mathcal{X}'_t を決定する。任意の \mathcal{X}'_t 内の点に対し、この点の最近傍データ点が \mathcal{D}'_t に含まれるようにする。つまり、 $\{\hat{\mathbf{x}} \in \mathcal{X} \mid \exists \mathbf{x} \in \mathcal{X}'_t, \mathbf{x} \in \mathcal{V}(\hat{\mathbf{x}})\} \subseteq \mathcal{X}^D_t$ である。ここで \mathcal{X}'_t のある頂点 \mathbf{x}_c を考える。 \mathbf{x}_c にとって \mathbf{x}_{t-1} より速いデータ点は最近傍になりえないため、 \mathbf{x}_c が中心で $\|\mathbf{x}_{t-1} - \mathbf{x}_c\|_2$ を半径とする球の内側に、 \mathbf{x}_c の最近傍データ点が含まれる。よって、全ての角に対しこのような球を考え、これらの球を全て内包する最小体積の直方体を \mathcal{D}'_t とする。角のみ考えれば、その他の点に対しても条件が満たされる。図2に2次元におけるポロノイ領域を用いた場合の探索範囲と学習データ点の絞り込みの模式図を示す。

4. 実験

本章では人工関数の最適化実験を通して提案手法の有効性を実証する。最適化の目的関数として次元が $D = 3$ の Rosenbrock 関数 $\mathcal{F}(\mathbf{x}_t) = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$ を用いる。探索範囲は $\mathcal{X} \in [-5, 10]^D$ である。

提案手法として、 $c = 1$ としてカーネルの値の閾値を用いた手法 (BOMR S) と、ポロノイ領域を用いた手法 (BOMR V)、そしてこれら2つを両方使用してより狭い方の探索範囲に限定した手法 (BOMR SV) の3手法を用いる。また、ベースラインとして通常のベイズ最適化 (BO) を用いる。提案手法の最初の繰り返しにおいては過去記憶がないため、 $\mathcal{X}'_1 = \mathcal{X}$ 、 $\mathcal{D}'_1 = \mathcal{D}_0$ とする。獲得関数の計算回数は、ベースラインでは $T_a = 1000D$ 回に制限する。提案手法では \mathcal{X}'_t が狭く同じ計算回数は必要ないため、 $1000D$ 回に \mathcal{X}'_t の対角線の長さ \mathcal{X} の対角線の長さの比をかけた回数に制限する。CPU に Xeon E7-4870 を用いて計算を行い、全ての最適化は1スレッドのみを使用して実行する。乱数の影響を抑えるため、10種類のランダムシードを用いて最適化を全手法10回ずつ行い、実線が平均値であり、標準偏差の大きさだけ上下双方を塗りつぶしたグラフで結果を示す。スケールの違いに対する影響を取り除くため、平均と分散は対数をとった値に対して計算している。

図3の左に、横軸が繰り返しの回数であり、縦軸が所要時間である、両対数グラフを各手法に対して示す。横軸の値が大きい方が高速である。ベースラインのBOは 10^5 秒経過時点で繰り返し回数は 10^3 回に到達しない。一方、どの提案手法もBOよりも高速であり、 10^5 秒の時点で繰り返し回数は10倍以上の差がつく。BOMR Sは繰り返し回数が小さいときに特に高速である。しかし時間がたつとBOと近い計算量のオーダーで計算時間が増大する。これは、閾値が一定だと閾値内に存在するデータ点の数が繰り返し回数の増加に伴い増えるからである。BOMR Vは最初はBOMR Sより低速であるが、最終的にはこれより高速になる。BOMR Vは、繰り返し回数が増えるに従いポロノイ領域が縮小し、学習すべきデータ点の数を抑える効果により、計算量のオーダーがBOより小さい。BOMR SVは全ての繰り返し回数で、BOMR SとBOMR Vの高速である方と同程度である。

が正しくない場合、制約条件を増やしてもう一度線型計画問題を解き、得られた x_i^L や x_i^U が正しいことを調べなおせば良い。

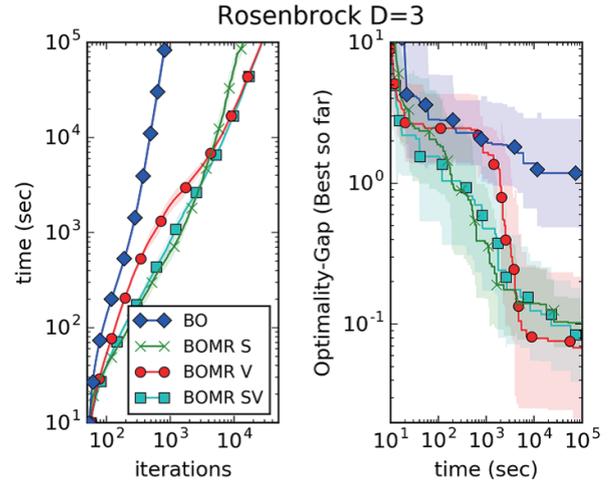


図3: 各手法の所要時間と最適化精度

図3の右に、横軸が所要時間であり、縦軸が t 回目の繰り返し終了時点で得た関数評価値のベスト値 ($\min_{t' \leq t} \mathcal{F}(\mathbf{x}_{t'})$) である、両対数グラフを示す。この関数の最適値は0であるので、関数値そのものの値が、最適値との差 (Optimality-Gap) を示す。得た入力パラメータのうち最良のものを最終的に取得することを想定するため、ベスト値を記載している。縦軸の値が小さい程、最適化の精度が高い。提案手法はどれもBOよりも高い最適化性能を示している。過去記憶の利用により、モデルの表現力を維持したまま高速化が出来ているとわかる。

5. 結論

本論文では繰り返し回数が増えるにつれ急激に低速化してしまうベイズ最適化の弱点を克服する、新しい手法BOMRを提案した。BOMRは以前の繰り返しで得たモデルの予測結果を過去記憶として保存し、それを再利用することで、繰り返し回数の増加に対してモデルの学習データ量が増加することを抑え、スケーラブルな最適化を実現した。実験では、高速化の結果で提案手法が通常のベイズ最適化より、同じ計算時間でより良い入力パラメータを発見できることを示した。

参考文献

- [Bull 11] Bull, A. D.: Convergence rates of efficient global optimization algorithms, *Journal of Machine Learning Research*, Vol. 12, pp. 2879–2904 (2011)
- [Hutter 11] Hutter, F., Hoos, H. H., and Leyton-Brown, K.: Sequential model-based optimization for general algorithm configuration, *In LION*, pp. 507–523 (2011)
- [Rasmussen 06] Rasmussen, C. E. and Williams, C. K. I.: *Gaussian processes for machine learning.*, MIT Press (2006)
- [Shahriari 16] Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., and Freitas, de N.: Taking the human out of the loop: A review of bayesian optimization, *Proceedings of the IEEE*, Vol. 104, No. 1, pp. 148–175 (2016)

多環境における低精度センサーを用いた空間分布のバイズ推定

Bayesian Estimation for Spatial distribution using Low precision Sensors in Multi-Environment

太田 真人 *1 花房 諒 *1 岡留 剛 *1
 Masato Ota Ryo Hanafusa Takeshi Okadome

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

The method proposed in this paper enables us to estimate the spatial distribution of physical quantities in multiple geographical regions, where many low-precision sensors are densely placed and a small number of (or no) high-precision sensors are positioned. For a region that has high-precision sensors, the method determines the biases of the low-precision sensors placed in the regions accurately using the values of the high-precision sensors and it corrects the values of the low-precision sensors precisely. Furthermore, the method divides the regions into the clusters using the sensor data similarity as a similarity measure. Then, for a region that has no high-precision sensor, it estimates the spatial distribution of physical quantities in the region by a novel multi-task learning that transfers the regional shared-information in the cluster which the region belongs to. Some experiments show that the method estimates the spatial distribution of physical quantities accurately.

1. はじめに

生態の環境モニタリングや農業や漁業・都市における環境センシングにおいて、コストがかかる高精度センサーは多く配置することができず配置する場所が限られる。一方、低精度センサーは誤差は大きいですが、安価で多地点に配置でき、それを用いて大量のセンサデータを入手することができる。例えば、AMeDAS を高精度センサーとみなし、Raspberry Pi を使ったセンサノードや衛星から撮ったサーモ画像を低精度センサーとみなして、ある領域の各点での温度を予測するのに用いることができる。

環境から得られるセンサデータはその総数も種類も増えてきており、多数のセンサデータを用いた空間分布の推定は多く研究されている [Xu 17]。さらに、センシングする環境の対象も増え、本研究で対象とする多環境は、複数の都市や、各地域の工場内や港、各地方の森林が挙げられる。しかし、高精度センサーがある環境は少なく、低精度センサーしかおけない環境は多くある。その場合、低精度センサーだけで高精度に環境をセンシングする必要がある。本研究では、各環境における物理量の空間分布を推定するタスクにおいてマルチタスク学習を行い、低精度センサーだけの環境においても精度高く推定することを目的とする。マルチタスク学習は、関連する複数のタスクを解く際に、タスク間で情報を共有することで推定精度を上げる学習手法である。

地理空間データにおけるマルチタスク学習として、タスク間を関係付けさせるタスク関係行列に地形などの景観類似性や、環境間の場所が近い空間的近接性をパラメータの正則化に用いた研究がされている [Atluri 18]。しかし、位置が互いに近く、景観は似ていてるが、環境周りの外的要因や遠方の影響を受けている場合があり、位置の近傍関係は正しいタスク間の関係に必ずしも反映していない。例えば、地形は似ていてるが、一方の環境では工場地区が近くにあり他方に比べて CO2 量や雲量が多い場合、または一方だけが風下の影響を受けている場合が挙げられる。本研究では、多数のセンサデータや地理情報を含む空間的補助データを用いて、各環境の観測データから多環境

連絡先: 関西学院大学, 兵庫県三田市学園 2 丁目 1 番地,
 masato190@kwansei.ac.jp

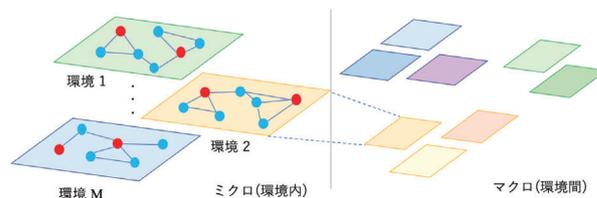


図 1: 本提案モデルの概念図。左: 環境内の少数の高精度センサーと多数の低精度センサーの観測位置における空間分布の真値を重み付きエッジで結び、無向グラフを構成する。右: 環境間は観測データと補助データの類似性からクラスタリングし、マルチタスク学習により、物理量の空間分布を推定する。

の類似性を推定しクラスタリングするマルチタスク学習を行うことにより、各環境の物理量の空間分布を精度高く推定する。

本研究は、多環境のクラスタリングに、[Iwata 13] らが提案した iWMM (infinite warped mixture model) を用いる。iWMM は、多次元の観測データに対して GPLVM (GP Latent Variable Model) による非線形な次元削減を行い、低次元空間内で iGMM (infinite Gaussian mixture model) による観測データの特徴をクラスタ化しつつ、クラス数を自動決定する手法である。iWMM は汎用性が高くクラスタリングや密度推定・多様体学習・視覚化に適応可能である。本提案手法における iWMM の位置付けを示すために、各環境内のモデルを以下で説明する。

本研究では観測データの信頼性を確率変数で表現し、教師データは高精度センサーの観測値であり、低精度センサーの観測データはドリフトを含み誤差が大きく擬似教師データとして考える。このような観測データに対して、一般的な回帰手法のニューラルネットワークやガウス過程 (GP: Gaussian Process) では推定誤差が大きくなる。提案手法は、環境内において高精度センサー値を頼りに低精度センサー値を補正するため、画像分野の [Geman 84] の画素の近傍は相関しているという考えに基づく。したがって、観測地点の空間分布はマルコフ確率場 (MRF: Markov Random Field) の構造を持つ多

次元ガウス分布に従う。また、各観測位置が等距離ではないため、ノード間のエッジに重みを与える。重みの与え方として、空間統計学の一般的なアプローチに、距離の逆数の重みづけや k 近傍法を用いた空間重み行列 [Stakhovych 09] がある。しかし提案手法では空間重み行列を用いず、補助データ間の類似度で与える。ただし、類似度は一般にわからず、類似度のパラメータを事後確率最大化からベイズ推定する。iWMM はその類似度を定めるパラメータを生成するために用いる。iWMM の性質上、同じクラスでは似たパラメータベクトルを持つように正則化が働くため、類似した環境と共同したマルチタスク学習になる。ここで提案モデルの概念図を図 1 に示す。最後に、本研究の貢献を以下に述べる。

- 環境に配置されたドリフトを含む多数の低精度センサー値と、環境内の少数の高精度センサー値に基づいて物理量の空間分布を高精度に推定。
- 多環境においてタスク間の関係性に空間近接性を用いず、観測データの類似性に基づき環境をクラスタリングし、マルチタスク学習を行うことにより、低精度センサーのみの環境においても空間分布の推定精度の向上。

2. 物理量の空間分布の推定手法

ある環境のセンサーの観測位置を含む補助データは、 $\mathbf{X}^m = (\mathbf{x}_1, \dots, \mathbf{x}_{S_m})^T$ とする。 $\mathbf{x}_i \in \mathbb{R}^{D_h}$ (D_h : 補助データの種類) とし、 $S_m = L_m + H_m$, H_m は高精度センサー、 L_m は低精度センサーの総数である。 m はある環境を表し、全環境数は M ある。低精度センサーの観測値は $y_i^{(n)} = z_i + \mu_i + \epsilon_n$, 高精度センサーのそれは $y_i^{(n)} = z_i + \eta_n$ で表される。ここで μ_i は i 個目の低精度センサーの系統誤差, ϵ_n は低精度センサーのノイズで期待値 0 で精度が α のガウス確率変数であり, η_n は高精度センサーのノイズで期待値 0 で精度が β のガウス確率変数である。ただし $\alpha < \beta$ とする。センサーを置いた位置での空間分布の真値を z_i とし、その集合を $\mathbf{z}^m = (z_1, \dots, z_{S_m})^T$ とする。環境 m の低精度と高精度センサーの観測変数集合を合わせて $\mathbf{Y}^m \in \mathbb{R}^{N_m \times S_m}$ とする。ここで、 N_m は計測回数である。全環境での観測値集合は $\mathbf{Y} = \{\mathbf{Y}^1, \dots, \mathbf{Y}^M\}$ である。

エネルギー関数を用いて環境内のマイクロなモデルの外観を説明し、次にエネルギー関数を確率分布として表す。最後に、環境間を考慮するマクロな確率モデルに拡張していく。

2.1 エネルギー関数

まず環境内のエネルギー関数は次のように定義される。

$$E_m = \sum_{j \in \mathcal{N}(i)} k(\mathbf{x}_i, \mathbf{x}_j) (z_i - z_j)^2 + \frac{\alpha}{2} \sum_{i=1}^{L_m} (y_i - z_i - \mu_i)^2 + \frac{\beta}{2} \sum_{i=L_m+1}^{S_m} (y_i - z_i)^2, (1)$$

ただし、

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{1}{2} \mathbf{w}_m^T (\mathbf{x}_i - \mathbf{x}_j)\right).$$

ここで、 $\mathbf{w}_m \in \mathbb{R}^{D_h}$ は類似度を構成するパラメータである。エネルギー関数の 1 項目は平滑化項, 2 項目は低精度センサー値に関する誤差を最小化する項, 3 項目は高精度センサーのそれに対応する項である。このエネルギー関数の最小化にお

ける特徴は 2 つある。近傍内の補助データの類似性を用いた重み $k(\mathbf{x}_i, \mathbf{x}_j)$ により、近傍内の空間分布の真値同士を近づける。 $\alpha < \beta$ により、1 項目の平滑化項から低精度センサーの観測位置での真値 z_i が高精度センサーの観測位置での z_j に影響され、ドリフト μ_i が推定される。

2.2 Spalogh (環境内確率モデル)

少数の高精度センサーと多数の低精度センサーを用い、多数の低精度センサーのドリフトと空間分布を推定する手法を Spalogh と呼ぶ。まず、式 (1) のエネルギー関数をギブス・ボルツマン分布で定義し、エネルギー関数の各項ごとに分布をガウス分布に変形させる。その後、パラメータに対して事前確率を置き、同時確率を求めていく。尤度関数は、式 (1) の 2 項と 3 項目をまとめてガウス分布を用いて以下の式で定義される。

$$p(\mathbf{Y}^m | \mathbf{z}^m, \boldsymbol{\mu}^m, \alpha, \beta) = \prod_{n=1}^{N_m} \mathcal{N}(\mathbf{y}^n | \mathbf{z}^m + \boldsymbol{\mu}^m, \mathbf{I}_{S_m}), (2)$$

ただし、 \mathbf{I}_{S_m} は対角行列でその対角要素は最初の L_m 次元は α^{-1} であり、残りの H_m 次元が β^{-1} である。系統誤差 $\boldsymbol{\mu}^m$ ベクトルは最後の高精度センサー数分の次元は 0 で与えられている。事前分布 $p(\boldsymbol{\mu}^m)$ はある品番の低精度センサーの系統誤差は母平均があると仮定し、以下の式で与えられる。

$$p(\boldsymbol{\mu}^m) = \prod_{i=1}^{L_m} \mathcal{N}(\mu_i^m | m_\mu, \sigma_\mu^2), (3)$$

m_μ には無情報事前分布を置く。 σ_μ^2 は超パラメータになる。空間分布の真値 \mathbf{z}^m の事前分布 $p(\mathbf{z}^m | \mathbf{w}_m)$ は式 (1) の 1 項目を変形すると MRF の構造を持つ多次元ガウス分布で以下のよう書き下される。

$$p(\mathbf{z}^m | \mathbf{w}_m) = \mathcal{N}(\mathbf{z}^m | \mathbf{0}, \mathbf{A}^{-1}(\mathbf{w}_m)), (4)$$

ただし、

$$[\mathbf{A}(\mathbf{w}_m)]_{ij} = \begin{cases} \sum_{k \in \mathcal{N}(i)} k(\mathbf{x}_i, \mathbf{x}_k) & (i = j) \\ -k(\mathbf{x}_i, \mathbf{x}_j) & (j \in \mathcal{N}(i)) \\ 0 & (\text{otherwise}), \end{cases}$$

ここで、 i の近傍は半径 d とした。 α, β は共役事前分布で $\alpha \sim \text{Gam}(a_{L0}, b_{L0}), \beta \sim \text{Gam}(a_{H0}, b_{H0})$ である。

2.3 Spalogh - iWMM (多環境マルチタスク学習)

環境にも類似性があると仮定し、複数のクラスが存在するとする。ただし、事前知識ではクラス数も環境間の類似度もわからない。そこで、環境内の \mathbf{z}^m を近傍で平滑化させる重み $k(\mathbf{x}_i, \mathbf{x}_j)$ がもつパラメータ $\mathbf{w}_m, m = 1, \dots, M$, をクラスタリングし、環境の類似性を表現することで、同じクラスでは似た \mathbf{w}_m を持つように正則化するマルチタスク学習を行う。このクラスタリングは、環境内の近傍の補助データ $\mathbf{x}_i^m, \mathbf{x}_j^m$ と空間分布の真値 z_i^m, z_j^m の関係性が環境間で似ていると同じクラスに属するようになる。

\mathbf{w}_m を全環境分まとめた行列 $\mathbf{W} \in \mathbb{R}^{M \times D_h}$ を GPLVM で非線形に低次元圧縮し、低次元空間内で iGMM により正則化させる (iWMM)。また、RBF カーネルを用いた GP の性質上、入力に似ると出力も似るため、環境間でパラメータ \mathbf{w}_m も似るようになる。通常、 \mathbf{w}_m は、エネルギー関数最小化を行

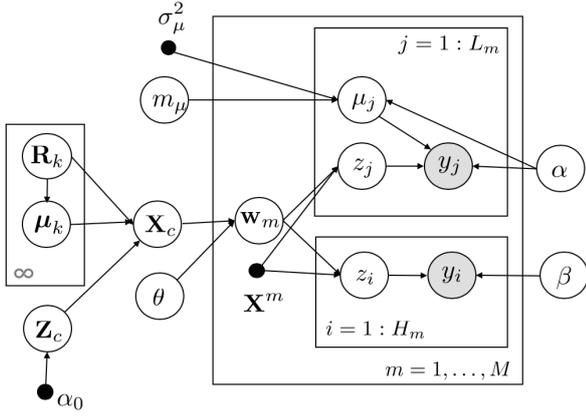


図 2: 提案モデルのベイジアンネットワーク. 大きなプレートが各環境を表し, 小さいプレートの上は低精度センサーを表し, 下のプレートは高精度センサーを表す.

うと, 大きな値をとり, 近傍で平滑化させる効果がなくなる. したがって正則化が必要である. ここでは, GPLVM の共分散行列 \mathbf{K} の各要素が小さくなるように RBF カーネルの尺度パラメータ θ_0 とスケールパラメータ σ_0 にガンマ分布を仮定し, 超パラメータをうまく設計することで, \mathbf{w}_m の正則化を実現する.

まず, $p(\mathbf{W})$ の分布として GPLVM を用いる.

$$p(\mathbf{W}|\mathbf{X}_c, \theta) = \prod_{j=1}^{D_h} \mathcal{N}(\mathbf{w}_j | \mathbf{0}, \mathbf{K}). \quad (5)$$

本研究ではパラメータ $\{\theta_0, \sigma_0, \beta_0\}$ を持つ RBF カーネルを使用した. カーネルパラメータの分布として $\theta = \{\theta_0, \sigma_0\}$ は $\theta_0, \sigma_0 \sim \text{Gam}(a_{k0}, b_{k0})$ で与える. 次に, GPLVM の入力になる確率変数 \mathbf{X}_c の分布に iGMM を用いる.

$$p(\mathbf{x}_c | \{\lambda_k, \mu_k, \mathbf{R}_k\}) = \sum_{k=1}^{\infty} \lambda_k \mathcal{N}(\mathbf{x}_c | \mu_k, \mathbf{R}_k^{-1}), \quad (6)$$

この位置 \mathbf{x}_c が潜在的なクラスを決める要因である. $\{\mu_k, \mathbf{R}_k\}$ に事前分布として超パラメータ $\{\mathbf{u}, r, \mathbf{S}, \nu\}$ を持つガウス・ウィシャート分布を使用する. クラス分割数を決める \mathbf{Z}_c に超パラメータ α_0 を持つ中華料理店過程を導入した. クラス数を決めるのに重要な α_0 は 0.1 に設定し, クラス数が少なくなるようにした. iWMM の詳細は [Iwata 13] を参照. 提案モデルのベイジアンネットワークを図 2 に示す.

式 (2) から (6) と超パラメータの分布の積により提案モデルの同時分布が以下の式で与えられる.

$$\begin{aligned} p(\mathbf{Y}, \mathbf{Z}, \boldsymbol{\mu}, \mathbf{W}, \mathbf{Z}_c, \mathbf{X}_c, \theta, \alpha, \beta, m_\mu) &= p(\mathbf{Y}|\mathbf{Z}, \boldsymbol{\mu}, \alpha, \beta) p(\boldsymbol{\mu}|m_\mu) \\ &\times p(\mathbf{Z}|\mathbf{W}) p(\mathbf{W}|\mathbf{X}_c, \theta) \\ &\times p(\mathbf{X}_c|\mathbf{Z}_c) p(\mathbf{Z}_c) \\ &\times p(\alpha) p(\beta) p(\theta) p(m_\mu). \end{aligned}$$

事後確率 $p(\mathbf{Z}, \boldsymbol{\mu}, \mathbf{W}, \mathbf{Z}_c, \mathbf{X}_c, \theta, \alpha, \beta, m_\mu | \mathbf{Y})$ をギブスサンプリングとハミルトンモンテカルロ・サンプリング (HMC) により推定する.

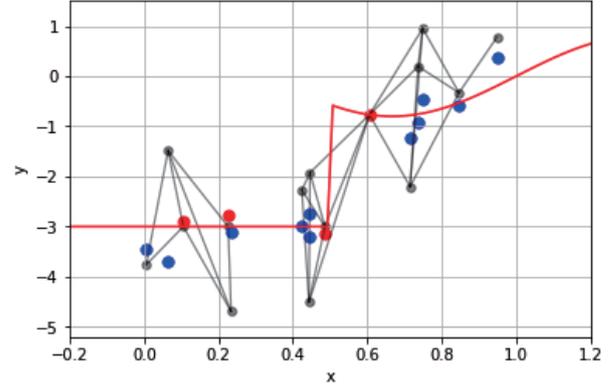


図 3: ドリフト推定による低精度センサー値の補正結果. 青丸は低精度, 赤丸は高精度センサーでの空間分布の推定値を表している. 黒丸はドリフトを含んだ観測データである. 赤線は真値, 黒線は近傍のエッジを表す. 元々のドリフトの平均絶対値誤差は 1.13, 補正後の誤差は 0.29.

3. 実験

以下 2 つを検証する.

- 1) 環境内で高精度センサーを頼りに低精度センサーが補正されるか.
- 2) マルチタスク学習により多環境ならびに低精度だけの環境も補正の推定精度が上がるのか.

3.1 データセット

本実験では, 1) 人工データ 2) アメリカの点観測の気象データ *1*2 を用いた. 1) 1次元の環境を仮定し, 真値は x 軸が 0.5 までは $y = -3$, それ以上は $y = \cos(1.5\pi x)$ の曲線である. x の生成は $x \sim \text{Uni}(0, 1)$ で 11 点は低精度としてドリフト $\mu_i \sim \text{Uni}(-2, 2)$ とノイズ $\mathcal{N}(0, 0.5)$ を真値に加えた. 高精度は 4 点でノイズ $\mathcal{N}(0, 0.1)$ を加えて用いた. 近傍の距離を $d = 0.18$ とした. 2) については環境は全 10 環境で Florida, New York, Washington, California, Texas, Indiana, Wyoming 州で, 後ろ 3 州だけ 2 環境ずつ作成した. 環境内の観測点が 15 地点で全環境同数になるように用意した. 補助データとして緯度, 経度, 標高, 雨量, 湿度など 12 種類を全環境において正規化し用いた. 目的変数は日中平均気温とする. 15 地点中 4 地点を高精度センサーとし, 11 地点を低精度センサーとする. 低精度センサーにはドリフトとして $\text{Uni}(0, 2)$ を加えて実験を行なった. 高精度センサーの位置は全体的に散らばるように選び, その観測値には人工データ同様ノイズを加えた.

3.2 比較手法

単純な Lasso 回帰と [Obozinski 07] が提案したマルチタスク学習の Group Lasso 及びグラフラプリアンによる正則化を用いた Lasso 回帰 [Xu 16], ただし, 空間的近接性に基づく距離の逆数のタスク関係行列を用いた. さらに, Spallogh- L^2 ノルムで行なった. Lasso の正則化パラメータは共通して $\lambda = 1.3$ を使用した. Spallogh- L^2 ノルムは, \mathbf{W} の事前分布に平均 0 の等方ガウス分布を用いたモデルである. 環境間で重み \mathbf{w}_m を独立にした手法になる.

*1 <https://weather.us/observations/california/total-cloud-coverage/20180201-1800z.html>

*2 <http://climod.unl.edu>

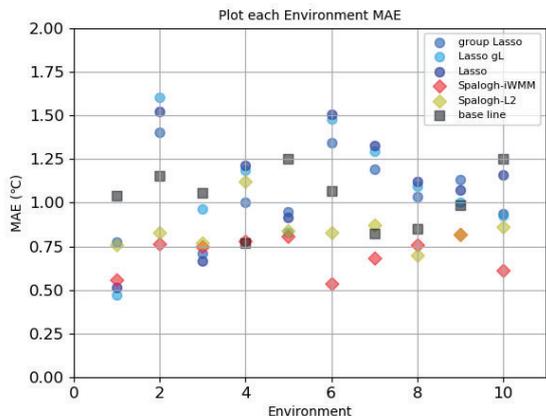


図4: 各環境で生成したドリフト量と推定したドリフト量 μ_{MAP} の MAE を比較した図。横軸は環境の番号であり、縦軸は摂氏の MAE である。10番が低精度センサーのみの環境になる。

3.3 結果・考察

1) について図3に、人工データでのドリフト推定による低精度センサー値の補正結果を示す。赤丸の高精度センサー値によって全体的に青丸の低精度センサー値が補正されていることが分かる。しかし、どの観測位置が高精度センサーになるかで推定結果が大きく異なることが分かる。一般に高精度センサーの位置は空間代表性を持っていることが望まれる。高精度センサーが空間分布の局地的な場所に配置されている場合、低精度センサーもその局地的な場所に強く影響される。

2) の実験の結果である、各環境におけるドリフトの推定誤差を図4に示した。Lasso はドリフトを表す確率変数がモデルにないため、 λ の大きさに依存して、環境によって推定結果が良い場合もあれば悪い場合もある。環境の10番目は低精度だけの環境であり、Spalogh-iWMM は比較手法より高い精度を示している。本実験では、 w_m は L^2 ノルムにあたる事前分布より多環境の影響を受けた方が精度が良いことが分かる。他の環境についても同様に推定結果が Spalogh- L^2 と同等かそれ以上の結果が示されている。各環境の潜在的なクラスと重みパラメータ \mathbf{W} を図5に示す。クラスターリングにおいて、3州だけ同じ環境が2つ ($\{4, 6\}$, $\{5, 7\}$, $\{9, 10\}$) あったが、どの2つの環境も同じクラスに属することはなかった。これは、クラスが景観類似性や、空間的近接性によって決まるのではなく、各環境の観測地点近傍の補助データの類似性と観測データに依存して決まることわかる。さらに、今回のデータセットは環境内で観測位置の間隔が広く、高精度センサーを頼りすぎ、誤差が逆に大きくなる場合があった。この問題の解決策に空間分布の真値間の差が大きい場合、不連続とみなす画像の分野で有名なラインプロセスを用いることが期待される。

4. おわりに

本稿では、観測データの信頼性をもとに、少数の高精度センサーと多数の低精度センサーを用いたセンサー値の補正と観測地点における空間分布を推定した。さらに環境をクラスターリングしつつ、マルチタスク学習を行い、比較手法より精度が高いことを示した。また、低精度だけの環境においても高い精度を示した。本手法の課題として、補助データに欠損値があってもはならない。補助データに欠損値があっても対応できるような

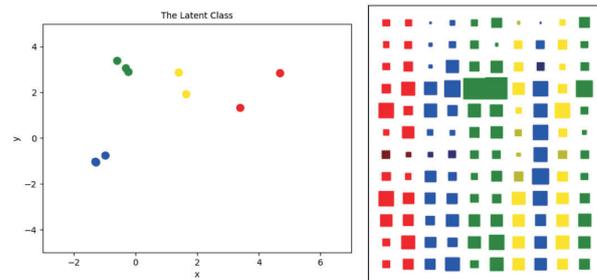


図5: [左] iWMM による各環境の潜在的な二次元空間の位置。色はクラス。[右] 各環境内のエッジの重みを決めるパラメータのヒートマップ。横に各環境が並び、縦に各環境内で補助データにかかるパラメータを表す。四角形の大きさがパラメータの大きさを示す。暗い色は負の値。特に緑色や黄色をみると、パラメータベクトルが似ていることが分かる。

テンソル分解などのモデルを検討する。さらに超パラメータの決定がヒューリスティックになってる部分をより正確に決定する方法が課題である。今後の発展として、環境内の不連続性に対応するラインプロセスの導入がある。また欠損値に強いモデルへの拡張を行う。環境モニタリングの応用を見据えた時空間データにおける長期計測に有効なモデルを構築することが挙げられる。

参考文献

- [Xu 17] Xu, J., "Multi-Task Learning and Its Application to Geospatio-Temporal Data," *Michigan State University*, 2017.
- [Atluri 18] Atluri, G., A. Karpatne, and V. Kumar, "Spatio-temporal data mining: A survey of problems and methods," *ACM Computing Surveys (CSUR)*, vol. 51, no. 4, p. 83, 2018.
- [Iwata 13] Iwata, T., Duvenaud, D., and Ghahramani, Z., "Warped mixtures for nonparametric cluster shapes," *In Uncertainty in Artificial Intelligence*, 2013.
- [Geman 84] Geman, S. and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," *IEEE Transactions on pattern analysis and machine intelligence*, 6, pp. 721-741, 1984.
- [Stakhovych 09] Stakhovych, S. and B. H. Tamm, "Specification of spatial models: A simulation study on weights matrices." *Papers in Regional Science*, 88.2, pp. 389-408, 2009.
- [Obozinski 07] Obozinski, G., B. Taskar, and M. I. Jordan, "Joint covariate selection for grouped classification," *Technical report, UC Berkeley*, 2007.
- [Xu 16] Xu, J., et al., "Gspartan: a geospatio-temporal multi-task learning framework for multi-location prediction," *Proceedings of the 2016 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics*, 2016.

アイテムセットを用いたスパースベイズ学習

Sparse Bayesian Learning for Itemset Data

矢船僚一朗 *¹ 西郷浩人 *²
Ryoichiro Yafune Hiroto Saigo

*¹*² 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

Sparse bayesian learning can learn sparse solution for linear classification / regression problem. Although it has a number of advantages over non-bayesian approach, extension of it to non-linear model is non-trivial. In this paper, we employ itemset mining, and consider building sparse bayesian model on the binary occurrence matrix of items. We propose an iterative algorithm that can efficiently extract non-linear features while avoiding the entire enumeration. In computational experiments based on simulated dataset, our approach could correctly identify non-linearity in the dataset. In experiments using HIV dataset, we demonstrate the effectiveness of bayesian approach by rejecting samples with large estimated variance.

1. はじめに

スパースモデリングとは多数の変数から特に重要なものをシステムティックに選んでモデル構築を行う手法で、過去数10年の間に計算生物学、信号処理、コンピュータビジョンなど多くの分野で成功を収めてきた。特にLASSO [Tib96]として知られるL1正則化問題は幅広く研究されている。LASSOの利点は、凸形式で定式化され高速計算ができることにある。これに対して私たちは事後分布を与える回帰モデルを構築するスパースベイズ学習 [TF03] を用いる。LASSOは点推定であるが、ベイジアンな手法を用いることでターゲット値の推定値に加えて、推定の不確かさなどの追加情報が得られる。今回対象とする問題はアイテムセットに対する回帰学習である。アイテムセットとはアイテムの組み合わせのことである。各アイテムの有無を $\{0, 1\}$ のバイナリベクトルで表すことによりアイテムセットの有無を $\{0, 1\}$ で表現する。これは化合物、ガンの遺伝子型、ウイルスの突然変異などさまざまな種類の実データの表現が可能である。単独のアイテムを用いた場合は線形モデルであるが、アイテムセットを用いることで相互作用を利用した非線形モデルが構築される。また生物のデータに対しては選ばれた変数から、どの組み合わせが反応に影響を与えているかを解釈できる。これは創薬において重要な情報である。アイテムセットの次元数は単独なアイテムの次元数と比較して膨大であるがスパースモデリングを行うことで次元数を削減できる。この論文ではアイテムセットに対してスパースベイズ学習を適用する方法とアイテムセットの探索を効率的に行う定理を紹介する。そして、人工データと実データを用いた計算機実験を行い手法の利点について説明する。

2. 準備

2.1 アイテムセットによる回帰学習

データベース上に含まれるアイテム $item_1, \dots, item_n$ の集合を E とする。アイテムとは「商品」などのものである。 E の部分集合 $z \subseteq E$ をアイテムセット (Itemset) という。トレーニングデータの各サンプルはアイテムセット $z_i \subseteq E$ とターゲット値 $t \in \mathbb{R}$ で構成される。このとき、各サンプルのアイテムセッ

ト z をトランザクションという。与えられたアイテムセットから、指定した出現数やサイズを満たすアイテムセットを出力する方法をアイテムセットマイニングという。アイテムセットマイニングのアルゴリズムはLCM (Linear time Closed itemset Mining) [UAUA03]を用いた。この論文ではテストデータのトランザクション z_{test} を入力して、ターゲット値 t_{test} の予測値 $f(z_{test})$ を出力する回帰モデルを考える。単純なモデルとしてはアイテム単体の有無に重みをつけた回帰モデルがある。

$$f(z_i) = w_1 \phi(item_1 \subseteq z_i) + \dots + w_n \phi(item_n \subseteq z_i) \quad (1)$$

ここで、 $\phi(k \subseteq z_i) = 2I(k \subseteq z_i) - 1 \in \{-1, 1\}$ である。つまり ϕ はアイテム k がトランザクション z_i に存在するときに1を、存在しないときに-1を返す指示器である。これを発展させ、次のような適当に選んだアイテムセット p_1, \dots, p_m の有無に重みをつけた回帰モデルを導入する。

$$f(z_i) = w_1 \phi(p_1 \subseteq z_i) + \dots + w_m \phi(p_m \subseteq z_i) \quad (2)$$

アイテムセットによる回帰学習の利点は非線形効果を取り入れることによってより複雑なモデルを構築できることにある。一方で、アイテムセットの数は膨大でありアイテムセット空間の全てに重みをつけることは過学習を起こす可能性がある。そのため、適切なアイテムセットにのみ重みをつけるスパースベイズ学習を使用する。

2.2 スパースベイズ学習

Tipping [TF03] によるスパースベイズ学習の概要を説明する。アイテムセット \mathbf{x}_n とターゲット値 t_n の組み合わせからなるデータセット $\{\mathbf{x}_n, t_n\}$ が与えられたとき、ターゲットベクトル $\mathbf{t} = (t_1, \dots, t_N)^T$ を近似ベクトルを $\mathbf{y} = (y(\mathbf{x}_1), \dots, y(\mathbf{x}_N))^T$ と誤差ベクトル $\boldsymbol{\epsilon} = (\epsilon_1, \dots, \epsilon_N)^T$ の和として表現する:

$$\mathbf{t} = \mathbf{y} + \boldsymbol{\epsilon} = \Phi \mathbf{w} + \boldsymbol{\epsilon} \quad (3)$$

ここで、 \mathbf{w} はパラメータベクトルである。 $\Phi = [\Phi_1, \dots, \Phi_M]$ は $N \times M$ の表現行列であり、列ベクトルは各データに対してアイテムセットの有無を示す $\{0, 1\}$ の基底ベクトルを構成する。

連絡先: 矢船僚一朗: yafune.ryoichiro.549@s.kyushu-u.ac.jp

スパースベイズモデルは、誤差が平均0、分散 σ^2 の独立したガウス分布として確率的に形作られるという仮定を行う： $p(\epsilon) = \prod_{n=1}^N N(\epsilon_n|0, \sigma^2)$ 。パラメータ σ^2 は前もって知っていれば定めることができるが一般的にはデータから推定される。したがって、誤差のモデルはターゲットベクトル \mathbf{t} に対しての多変量正規分布を意味し、これは尤度関数となる：

$$p(\mathbf{t}|\mathbf{w}, \sigma^2) = (2\pi)^{-N/2} \sigma^{-N} \exp\left\{-\frac{\|\mathbf{t} - \mathbf{y}\|^2}{2\sigma^2}\right\}. \quad (4)$$

この尤度関数はパラメータの事前確率によって補完される：

$$p(\mathbf{w}|\alpha) = (2\pi)^{-M/2} \prod_{m=1}^M \alpha_m^{1/2} \exp\left(-\frac{\alpha_m w_m^2}{2}\right). \quad (5)$$

ここでハイパーパラメータ、 $\alpha = (\alpha_1, \dots, \alpha_M)^T$ を導入した。これはそれぞれが個々に事前確率の強さを制御する。 α が与えられたとき事後確率分布はベイズの定理のもとで尤度と事前確率を結合することで与えられる：

$$p(\mathbf{w}|\mathbf{t}, \alpha, \sigma^2) = \frac{p(\mathbf{t}|\mathbf{w}, \sigma^2)p(\mathbf{w}|\alpha)}{p(\mathbf{t}|\alpha, \sigma^2)}. \quad (6)$$

これはガウス分布 $N(\boldsymbol{\mu}, \boldsymbol{\sigma})$ に従い、平均と分散は次のように表される：

$$\boldsymbol{\Sigma} = (\mathbf{A} + \sigma^{-2} \boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \quad \boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \mathbf{t}, \quad (7)$$

ここで \mathbf{A} は $\text{diag}(\alpha_1, \dots, \alpha_M)$ と定義される。タイプII最尤法を用いることで点推定 α_{MP} が得られる。すなわち、スパースベイズ学習は周辺尤度 α に関する局所的な最大化問題として定式化する。これは対数尤度 $L(\alpha)$ の最大化問題に等しい：

$$\begin{aligned} L(\alpha) &= \log p(\mathbf{t}|\alpha, \sigma^2) = \log \int_{\infty}^{\infty} p(\mathbf{t}|\mathbf{w}, \sigma^2) p(\mathbf{w}|\alpha) d\mathbf{w} \\ &= -\frac{1}{2} [N \log 2\pi + \log |\mathbf{C}| + \mathbf{t}^T \mathbf{C}^{-1} \mathbf{t}], \end{aligned} \quad (8)$$

$$\mathbf{C} = \sigma^2 \mathbf{I} + \boldsymbol{\Phi} \mathbf{A}^{-1} \boldsymbol{\Phi}^T. \quad (9)$$

$\alpha = \alpha_{MP}$ で(6)式を評価することによってパラメータに対する点推定 $\boldsymbol{\mu}_{MP}$ が得られる。これは最終的な近似値 $\mathbf{y} = \boldsymbol{\Phi} \boldsymbol{\mu}_{MP}$ を与える。

2.3 周辺尤度最大化

周辺尤度最大化のアルゴリズムを紹介する。単一のハイパーパラメータ α_i , $i \in \{1 \dots M\}$ で構成される項ができるように、 $L(\alpha)$ の \mathbf{C} を書き換える：

$$\begin{aligned} \mathbf{C} &= \sigma^2 \mathbf{I} + \sum_{m \neq i} \alpha_m^{-1} \phi_m \phi_m^T + \alpha_i^{-1} \phi_i \phi_i^T \\ &= \mathbf{C}_{-i} + \alpha_i^{-1} \phi_i \phi_i^T \end{aligned} \quad (10)$$

ここで \mathbf{C}_{-i} は \mathbf{C} から基底ベクトル i の寄与が除かれた行列である。 $L(\alpha)$ の記述のために行列式と逆行列が必要になるため下に示す：

$$|\mathbf{C}| = |\mathbf{C}_{-i}| |1 + \alpha_i^{-1} \phi_i^T \phi_i| \quad (11)$$

$$\mathbf{C}^{-1} = \mathbf{C}_{-i}^{-1} - \frac{\mathbf{C}_{-i}^{-1} \phi_i \phi_i^T \mathbf{C}_{-i}^{-1}}{\alpha_i + \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i} \quad (12)$$

これより $L(\alpha)$ を次のように書くことができる：

$$\begin{aligned} L(\alpha) &= -\frac{1}{2} [N \log(2\pi) + \log |\mathbf{C}_{-i}| + \mathbf{t}^T \mathbf{C}_{-i}^{-1} \mathbf{t} \\ &\quad - \log \alpha_i + \log(\alpha_i + \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i) - \frac{(\phi_i^T \mathbf{C}_{-i}^{-1} \mathbf{t})^2}{\alpha_i + \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i}] \quad (13) \\ &= L(\alpha_{-i}) + \frac{1}{2} [\log \alpha_i - \log(\alpha_i + s_i) + \frac{q_i^2}{\alpha_i + s_i}] \\ &= L(\alpha_{-i}) + l(\alpha_i) \end{aligned}$$

ここで s_i , q_i の値を次のように定義した：

$$s_i \triangleq \phi_i^T \mathbf{C}_{-i}^{-1} \phi_i \quad q_i \triangleq \phi_i^T \mathbf{C}_{-i}^{-1} \mathbf{t} \quad (14)$$

q_i は $q_i = \sigma^{-2} \phi_i^T (\mathbf{t} - \mathbf{y}_{-i})$ と書ける。目的関数 $L(\alpha)$ は計算のために ϕ_i の項を含まない $L(\alpha_{-i})$ と ϕ_i を含む項である $l(\alpha_i)$ に分割された。 $l(\alpha)$ を計算することで、 $L(\alpha)$ は α_i に関して次の値のときに最大値を取ることが分かった：

$$\alpha_i = \frac{s_i^2}{q_i^2 - s_i}, \quad q_i^2 > s_i \text{ のとき} \quad (15)$$

$$\alpha_i = \infty, \quad q_i^2 < s_i \text{ のとき} \quad (16)$$

全ての基底ベクトル(アイテムセット)について、 q_i と s_i を計算することは $S_i = \phi_i^T \mathbf{C}^{-1} \phi_i$, $Q_i = \phi_i^T \mathbf{C}^{-1} \mathbf{t}$ とおいたときに以下の計算式を用いることで比較的簡単にできる：

$$s_m = \frac{\alpha_m S_m}{\alpha_m - S_m}, \quad q_m = \frac{\alpha_m Q_m}{\alpha_m - S_m} \quad (17)$$

上の式(15), (16)はアルゴリズム上で次の手続きを行うことを意味している：

- ϕ_i がモデルに含まれていて($\alpha_i < \infty$)かつ $q_i^2 \leq s_i$ であるとき、 ϕ_i を消去する($\alpha_i = \infty$).
- ϕ_i がモデルに含まれていなくて($\alpha_i < \infty$)かつ $q_i^2 > s_i$ であるとき、 ϕ_i を追加する($\alpha_i = s_i^2 / (q_i^2 - s_i)$).

3. 手法

3.1 アルゴリズム

アイテムセットを使った周辺尤度最大化のアルゴリズムをAlgorithm 1に示す。アルゴリズムは全ての $\log \alpha$ が 10^{-6} 以下になり、かつすべての $\theta \leq 0$ で追加が出来ない状態で停止させている。これはモデルに追加できるアイテムセットが存在せず、かつ α の再計算でも周辺尤度があまり向上しない状態である。しかし、テストデータに適用した際にこの状態が最もよい性能を出すとは限らない。そのため後に記述する実験ではバリデーション用のデータを用いて、そのデータでの性能が最も良くなった状態のモデルをテストデータに採用した。テストデータの新しいアイテムセット \mathbf{x} に対する予測 t を出力するために、次のように定義される予測分布を評価する[Bis06].

$$p(t|\mathbf{t}, \alpha, \sigma^2) = \int p(t|\mathbf{w}, \sigma^2) p(\mathbf{w}|\mathbf{t}, \alpha, \sigma^2) d\mathbf{w} \quad (18)$$

ただし、 \mathbf{t} はトレーニングデータのターゲット値からなるベクトルである。また表記を簡単にするため、予測するターゲット値に対応する入力を右辺の条件部分から省いた。式(18)の右辺の2つの確率分布はそれぞれターゲット値の条件付き分布、重

Algorithm 1 Sparse Bayesian Learning for Itemset Data

```

1:  $\sigma^2 = \text{var}[t] \times 0.1$ 
2: for all itemsets  $\phi_i$  do
3:    $\alpha_i = \infty$ 
4:    $\delta L_i = \|\phi_i^T \mathbf{t}\|^2 / \|\phi_i\|^2$ 
5: end for
6:  $j = \text{argmax}_i |\delta L_i|$ 
7:  $\alpha_j = \frac{\|\phi_j\|^2}{\|\phi_j^T \mathbf{t}\|^2 / \|\phi_j\|^2 - \sigma^2}$ 
8: Initialize  $\Sigma, \mu$ 
9: while do
10:  Compute  $\delta L_i$  for all itemset from (13)
11:   $j = \text{argmax}_i |\delta L_i|$ 
12:   $\theta_j \triangleq q_j^2 - s_j$ 
13:  if  $\theta_j > 0$  and  $\alpha_j < \infty$  then
14:    Re-estimate  $\alpha_j$ 
15:  else if  $\theta_j > 0$  and  $\alpha_j = \infty$  then
16:    Add  $\phi_j$  to the model with updated  $\alpha_j$ 
17:  else if  $\theta_j \leq 0$  and  $\alpha_j < \infty$  then
18:    Delete  $\phi_j$  from the model and set  $\alpha_j = \infty$ 
19:  end if
20:  Update  $\sigma^2 = \|\mathbf{t} - \mathbf{y}\|^2 / (N - M + \sum_m \alpha_m \Sigma_{mm})$ 
21:  Recompute/Update  $\Sigma, \mu$ 
22:  if  $\log \alpha_i < 10^{-6}$  and  $\theta_i < 0$  for all basis then
23:    break
24:  end if
25: end while

```

みの事後分布である。ターゲット値の条件付き分布 $p(t|\mathbf{w}, \sigma^2)$ は式 (4) で与えられ、重みの事後分布 $p(\mathbf{w}|\mathbf{t}, \alpha, \sigma^2)$ は式 (6) の多次元ガウス分布で与えられる。これを使って式 (18) は次のようなガウス分布で表される。

$$p(t|\mathbf{x}, \mathbf{t}, \alpha, \sigma^2) = N(t|\mu^T \phi(\mathbf{x}), \beta(\mathbf{x})) \quad (19)$$

ただし、予測分布の分散 $\beta(\mathbf{x})$ は

$$\beta(\mathbf{x}) = \frac{1}{\sigma^2} + \phi(\mathbf{x})^T \Sigma \phi(\mathbf{x}) \quad (20)$$

で与えられる。(20) の第 1 項はデータに含まれるノイズを表し、一方第 2 項は \mathbf{w} に関する不確かさを反映している。ノイズとパラメータ μ の分布は独立なガウス分布であるからこれらの分散は加法的である。

3.2 枝刈りの定理

Algorithm 1 を適用するとき、手続き Add の候補となる全ての $\alpha_t = \infty$ のアイテムセット t について $\theta = q_t^2 - s_t$ を計算している。この節はアイテムセットの探索空間の木構造を利用した定理を紹介する。

定理 1 (枝刈りの定理) 探索木のノード t に到達したとき、もし次の条件を満たすなら以降のノードには Add の候補となるアイテムセットは存在しない。

$$4 \sum_j \sum_k \mathbf{M}_{jk} I(t \subseteq T_j) I(t \subseteq T_k) - 4 \sum_{M_j < 0} \mathbf{M}_j I(t \subseteq T_j) + \sum_j \sum_k \mathbf{M}_{jk} \leq 0 \quad (21)$$

Max pattern	number of nodes
1	21
2	211
3	1351
4	6191
5	21255
6	50605
∞	107607

表 1: 最大アイテムセット数を変化させたときのノードの総数の変化。サンプル数 200, 特徴数 20 で固定した。

ここで、 $\mathbf{M} = (\mathbf{C}^{-1} \mathbf{t} \mathbf{t}^T \mathbf{C}^{-1} - \mathbf{C}^{-1})$ であり、 \mathbf{M}_j は \mathbf{M} の j 列目を表しており、 T_j は j 番目のトランザクションを表している。

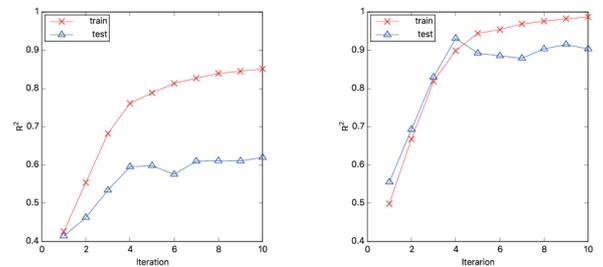
4. 人工データの実験

図 1: 単独のアイテム (左), アイテムセット (右) について、トレーニングデータとテストデータの学習がどのように変化するかを示す学習曲線を書いた。横軸はアルゴリズムの反復回数で縦軸は決定係数 R^2 を示している。

アイテムセットを用いたスパースベイズの効果を確認するために、シミュレーションデータを作成し実験を行なった。データは [TTS18] を参考に次のように作成した。まずベルヌーイ分布 ($q = 0.6$) に従う確率変数を使って $\mathbf{X} \in \{0, 1\}^{n \times p}$ の表現行列を生成した。次に表現行列からランダムに 5 個の特徴を選択し、さらに 2^5 の組み合わせの中からサイズ 2 以上の組み合わせを含むものを 5 個選択する。つまり単独のアイテム 5 個とサイズ 2 以上のアイテムセット 5 個の計 10 個を選択した。選択した特徴にそれぞれ独立な一様分布 $U_{[0,1]}$ から重み \mathbf{w} を与え、応答変数 $\mathbf{y} = \mathbf{X}\mathbf{w}$ を計算した。まず、アルゴリズムの繰り返しによる精度の変化を調査した。サンプル数 100, 特徴数 50 のデータをトレーニング用とテスト用にそれぞれ用意して、学習曲線を書いた。精度として以下の式で定義される決定係数 $R^2 = 1 - \sum_i (y_i - f_i)^2 / \sum_i (y_i - \bar{y})^2$ を用いた。図 1 は学習曲線を表している。左が最大アイテムセット数を 1 にした学習で、右が 5 にした場合である。トレーニングデータの精度は反復を繰り返すにつれてどちらも上昇しており正しく学習が出来ていることが確認された。またアイテムセットを取り入れることによって精度が向上しているのが分かる。次にデータを変化させたときの計算時間の比較を行なった。図 2 は最大アイテムセット数とトレーニングデータのサンプル数を変化させたときの計算時間の変化を表している。特徴数は $p = 20$ とした。3 つの線はアイテム単独で回帰を行なった最大アイテム数

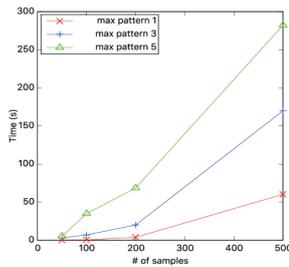


図 2: サンプル数を増やしたときの計算時間の変化. 最大アイテムセットサイズ 1, 3, 5 をそれぞれ指定したときを比較した. 特徴の数は 20 で固定した.

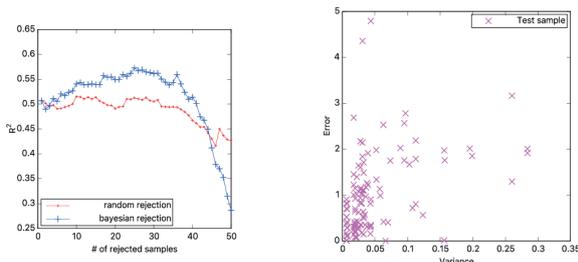


図 3: 棄却による精度の変化 (左) 分散と誤差の相関関係 (右)

1 と最大アイテムセット数 3,5 のサンプル数を変えたときの計算時間の変化である. サンプル数が増え, 最大アイテムセット数が増えるほど計算時間が伸びることが確認された. 表 1 は特徴数 20 のデータで最大アイテムセット数を変化させた時の探索空間のノードの数を示している. このときトレーニングデータのサンプル数は 200 とした. データの性質やサンプル数によっても変わるが, 最大アイテムセット数を増やすことで指数関数的にノードが増加する.

5. 実データの実験

この節では, 提案手法を HIV-1 drug dataset [RGK⁺03] に適用した結果を紹介する. このデータは市販の抗 HIV 薬に対する生体外感受性検査の結果をまとめたものであり, 各薬剤に対するウイルスの耐性が野生型のそれと比較して倍率変化 (fold-change) として記録されている. この記録は各ウイルスの薬剤耐性を表す応答値 y と野生型と異なる遺伝子型のアイテムセットからなる. 例えば, あるウイルスが参照した配列の 1 番目と 6 番目に突然変異して元のアミノ酸からアルギニンとシステインに変化しているときアイテムセットは $\{1A, 6C\}$ となる. スパースベイズによるテストデータの予測は平均と分散からなる. 分散の効果を調べるために次の実験を行なった. サンプル数 630 個のジドブジン (AZT) のデータセットをトレーニング 60%, バリデーション 20%, テスト 20% に分割した. バリデーションデータの精度が最も良い反復回数のモデルをテストデータに適用した. 適用して得られた分散が大きいものから棄却した場合 (ベイジアン棄却) とランダムに棄却した場合 (ランダムの棄却) での精度の変化を比較した. 図 3 の左はベイジアン棄却とランダムの棄却による精度の変化を 5 回の平均で表している. ランダムの棄却と比較した場合にベイジアン棄却は前半はランダムの棄却よりも精度が上がり, 後半は精度が下がっている. これよりベイジアンモデルの分散が予測の正

確さと相関関係があると考えることができる. 図 3 の右はクロスバリデーションのある 1 回の結果について分散と誤差の相関関係を示した図である. 分散は (20) の第 2 項のサンプルによって変化する部分, 誤差は予測値と正解の差の絶対値を表している. 図より一定の相関関係があり, 相関係数は 0.51332 であった.

6. おわりに

アイテムセットに対して, スパースベイズ学習を適用するアルゴリズムを説明した. スパースベイズ学習は, 与えたデータの変数の数よりもパラメータの数を少なくし, 結果がガウス分布で得られる特徴を持っている. アイテムセットを変数に持たせることで, 単独のアイテムのみを変数にするよりも複雑な非線形モデルを作ることが可能になる. また分布を推定することで推定値だけでなく, 推定の不確かさが計算でき, LASSO などの点推定よりも多くの情報を得ることができた. ベイジアン棄却の実験を行なって, 分散の高いデータを棄却させると精度が上昇することが分かった.

参考文献

- [Bis06] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, 2006.
- [RGK⁺03] Soo-Yon Rhee, Matthew J Gonzales, Rami Kantor, Bradley J Betts, Jaideep Ravela, and Robert W Shafer. Human immunodeficiency virus reverse transcriptase and protease sequence database. *Nucleic acids research*, 31(1):298–303, 2003.
- [TF03] Michael E. Tipping and Anita C. Faul. Fast marginal likelihood maximisation for sparse bayesian models. In *Proceedings of the Ninth International Workshop on Artificial Intelligence and Statistics, AISTATS 2003, Key West, Florida, USA, January 3-6, 2003*, 2003.
- [Tib96] Robert Tibshirani. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 267–288, 1996.
- [TTS18] Mirai Takayanagi, Yasuo Tabei, and Hiroto Saigo. Entire regularization path for sparse non-negative interaction model. In *2018 IEEE International Conference on Data Mining (ICDM)*, pages 1254–1259. IEEE, 2018.
- [UAUA03] Takeaki Uno, Tatsuya Asai, Yuzo Uchida, and Hiroki Arimura. LCM: an efficient algorithm for enumerating frequent closed item sets. In *FIMI '03, Frequent Itemset Mining Implementations, Proceedings of the ICDM 2003 Workshop on Frequent Itemset Mining Implementations, 19 December 2003, Melbourne, Florida, USA, 2003*.

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

[1J4-J-3] Data mining: social mining

Chair:Shogo Okada Reviewer:Tomoya Yoshikawa

Tue. Jun 4, 2019 5:20 PM - 6:20 PM Room J (201B Medium meeting room)

[1J4-J-3-01] Modelling of retention of media service users based on power-law

○Soichiro Morishita¹ (1. CyberAgent, Inc.)

5:20 PM - 5:40 PM

[1J4-J-3-02] Role discovery of the links based on the network structure

○Shumpei Kikuta¹, Fujio Toriumi¹, Mao Nishiguchi¹ (1. The University of Tokyo)

5:40 PM - 6:00 PM

[1J4-J-3-03] Application of density Sphere graph-CNN based deep learning to congestion prediction

○Takahashi Kei¹, Katsuhisa Sakamoto¹, Kouichi Yamaguchi¹, Takumi Numajiri², Masaru Soagbe², Tomah Sogabe^{1,3} (1. The University of Electro-Communications, 2. Grid Inc., 3. i-PERC, The University of Electro-Communications)

6:00 PM - 6:20 PM

メディアサービスにおけるユーザの継続の冪分布に基づくモデル化

Modelling of retention of media service users based on power-law

森下 壮一郎 *¹

Soichiro Morishita

*¹株式会社サイバーエージェント

CyberAgent, Inc.

In this paper, a model of the visitor retention in media services via the Internet such as video distribution service is shown. Visitor intervals of media services usually follow power-law. Based on the theory, we describe the modeling of visitor intervals and separate the residual into the elements of return and retention. Moreover, the result of the separation according to access log of the Internet TV station “AbemaTV” is shown as an example.

1. はじめに

本稿では、ウェブ上のメディアサービスにおけるアクティブユーザの継続数の統計的モデルについて述べる。

企業の価値を計るための概念として customer equity が提唱されている [1]. これは、将来にわたっての収益性の担保という観点の下で、優良な顧客を抱えている企業は資産を持つ企業と同様に価値があるとみなすものである。

顧客生涯価値 (LTV: lifetime value) は customer equity を計算するための考え方の一つで、顧客 1 人あたりに対する売上の将来にわたっての積算と定義される。定義上は顧客の一生涯が対象であるが、実際には目的に応じて視野に入れる期間を設定して、その区間で積算する。具体的には、1 人の顧客が時間経過に応じて一定の確率で離脱すると考えて、対象期間において顧客が継続している確率とユーザ 1 人あたりの平均売上の積とする。

なお顧客数の集計方法は業態に応じて大きく異なる。たとえば動画配信サービスなどのウェブを介したサービスでは、ユーザに対して識別子 (ID: identifier) を付与して、期間中にアクセスがあったユーザ (アクティブユーザ) を集計するのが一般的である。ユーザ登録を伴わないサービスの場合はウェブブラウザや専用アプリケーションなどのユーザエージェント (UA: user agent) に対して ID を付与して同様の集計を行う。この ID は自然人と一対一対応しないのであるが、便宜的に ID の単位をユーザとし、このように集計した ID の数をアクティブユーザ数と呼ぶ。しかしながら UA に付与した ID は端末の変更や UA の再インストールなどにより変わるので、素朴な集計では多めの値になることを見積もる必要がある。一方、継続率の計算においては、実際にはユーザが継続して利用していても UA に付与した ID は変わってしまいがちであるので、見かけの継続数は下がってしまう。

以上の理由で継続数の見積もりは困難であるが、一般にユーザを獲得した日と経過日数とのクロス集計による分析が行われており、素朴な集計よりは妥当な結果を得られる。このような分析は、継続数についての性質が同等になるような集団 (コホート) を対象に行うので、コホート分析と呼ばれる [2]. コホート分析において、ユーザ登録を伴うサービスで退会の時期が明らかである場合は生存分析が有用である。しかしユーザ登録を伴わないサービスであれば退会処理がそもそも行われな

い。したがって一定期間の利用が途絶えたユーザを便宜的に離脱ユーザと見なす。離脱の判断を適切に行うためには利用間隔のモデル化が必要である。

一般的な生存分析では生存時間のモデルとして指数分布やワイブル分布を採用し、生存数を経過時間で説明する。一方、利用が途絶えたユーザが利用を再開するきっかけはプロモーションなどの要因によるものであり、このようなイベントは経過時間が異なるユーザに対して同時に発生する。すなわち経過時間を揃えたとき、ユーザによっては異なる時間にイベントが発生する。そのために利用間隔が利用開始日と従属な関係になる。

以上のことから本稿では、メディアサービスにおける継続ユーザ数の統計モデリングを目的として、経過時間とイベント発生の従属性を考慮に入れた上でのサービスの利用間隔のモデル化を行う。具体的には来訪問隔の統計モデリングを行い、さらにその残差について特異値分解によりユーザの継続要素とイベント発生による復帰要素とに分解する手順を示す。

2. 定式化

サービス開始時点から一定の時間間隔 w おきに集計を行うこととし、間隔 w を単位としたときのサービス開始からの経過時間を t で表す。そして、期間 $[wt, w(t+1))$ の間にユーザからのアクセスがあった場合を時刻 t における来訪とする。

ところでユーザの来訪問隔を確率的に扱う場合、平均到着時間が λ の指数分布に従うものとして表現するのが一般的である。しかしながらウェブ上のメディアサービスにおいてはユーザの来訪問隔が冪分布に従う場合がある [3]. このとき、ユーザの来訪問隔 τ の確率分布は $f(\tau) = P(X = \tau)$ として $f(\tau) \sim \tau^{-\alpha}$ と表現できる。このことから、冪分布に従う値は両対数グラフで一次直線上に分布する。

図 1 にその一例を示す。これは横軸を来訪問隔 τ 、縦軸を UU (unique user) 数とした両対数グラフである。ただし、縦軸についてはグラフ中の直線の傾きが 1 となるように正規化している (このグラフの元となったデータの詳細は 4 節で述べる)。グラフ中の直線は $\tau > 1$ であるデータを対象にして単回帰モデルで回帰分析を行って得られた回帰直線である (説明変数と被説明変数の両方を対数変換した上での単回帰であるので、実際には非線形回帰である)。なお $\tau = 1$ の場合は本稿のモデル上では継続利用を意味し、来訪問隔が空いていないと見なすべきなので回帰モデルからは除外している。このグラフからユーザの来訪問隔が冪分布に従う様子が確認できる。次節

連絡先: 森下 壮一郎, 株式会社サイバーエージェント 秋葉原ラボ, morishita.soichiro@cyberagent.co.jp

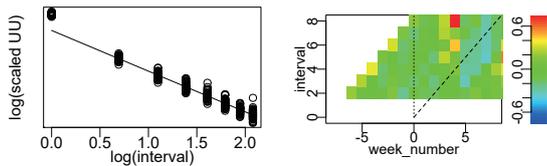


図 1: 冪分布に従う例 図 2: 残差のヒートマップ

で、この条件における残差を説明するモデルについて述べる。

3. 残差のモデリング

前節までで述べたモデルにおける残差のヒートマップの例を図 2 に示す。横軸は時刻 t 、縦軸は来訪間隔 τ である。なお τ が 0 および 1 のときは、冪分布に従うモデルに含まないので除外している。斜めの破線上の要素は時刻 t で来訪したユーザが、その後 $t+\tau$ の各時刻に来訪した数に対応している。垂直な点線上の要素は時刻 $t-\tau$ の各時刻に来訪したユーザが、時刻 t に来訪した数に対応している。例えばヒートマップにおいて右上の $(t, \tau) = (8, 8)$ の要素に着目すると、これは時刻 $t-\tau=8$ に来訪したユーザが時刻 $t=8$ に来訪した数に対応している。

ここで時刻 t に来訪したユーザの継続しやすさ（以下、継続要素） $\mathbf{p} = \{p_t\}$ と、時刻 t に発生したイベントのユーザの復帰させやすさ（以下、復帰要素） $\mathbf{q} = \{q_t\}$ とを考える。そして残差 $r_{t\tau}$ を \mathbf{p} と \mathbf{q} との線形結合で表現するために、残差を列挙したベクトル $\mathbf{r} = \{r_{t\tau}\}$ について次式が成り立つことを仮定する。

$$\mathbf{r} = A \begin{pmatrix} \mathbf{p} \\ \mathbf{q} \end{pmatrix}$$

ここで行列 A は $r_{t\tau} = p_{t-\tau} + q_t$ が成り立つように要素の値を設定した係数行列である。特異値分解で一般化逆行列 A^+ を求めることにより残差 \mathbf{r} から \mathbf{p}, \mathbf{q} をそれぞれ求められる。

4. 実証実験

以上で述べた方法の有用性を検証するために、インターネットテレビ局「AbemaTV」*1 へのアクセスログを元にして新規ユーザを含まないコホートを対象に継続の要素と復帰の要素とを分解する実験を行った。なお、このコホートは恣意的に選んだものであるため、以下に示す結果はサービス全体の継続数や離脱数を反映するものではない。

集計期間は 2018 年 1 月 1 日から 2018 年 10 月 1 日である。間隔 w は 1 週間とした。これは週単位の周期性の影響を除くためである。なお図 1 に示したグラフも、離脱判定の閾値 $n=8$ として、集計期間において 8 週目にあたる週（2018 年 2 月 26 日の週）を $t=0$ の週として、提案手法を適用した。結果を図 3 に示す。左上が継続要素 \mathbf{p} 、左下が復帰要素 \mathbf{q} 、右上がこれらを合成したもの、右下が元の値（残差）である。分解結果の合成により元の残差をよく再現できていることが分かる。

次に継続要素 \mathbf{p} と復帰要素 \mathbf{q} の散布図を図 4 に示す。時刻 $t=9$ の週はいずれも高い。これは 2018 年 4 月 30 日から始まるゴールデンウィークの週であり、特番等の施策が効を奏したのだと考えられる。また、復帰要素が同程度に高い $t=4$ の週は 2018 年 3 月 26 日から始まる週であるが、これは番組改編直後の新番組のインパクトが反映されている。なお、 $t=1$

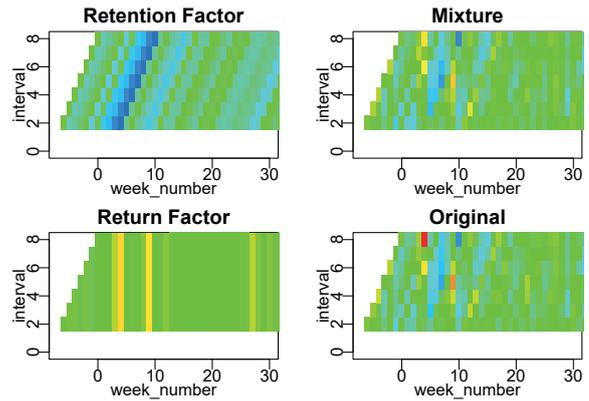


図 3: 分解結果のヒートマップ

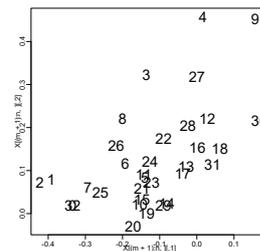


図 4: 分解結果の散布図

および $t=2$ の週で特に継続要素および復帰要素が低い。これらはいずれも番組改編の直前の時期であり、相対的に継続要素が低くなっている。

5. おわりに

本稿では、ウェブ上のメディアサービスにおける LTV 算出において見込みが難しいユーザの継続数についての統計モデリングを行った。具体的には、メディアサービスの利用間隔が冪分布に従うことを確認し、さらに統計モデルの残差をユーザの継続しやすさの要素とイベント発生による復帰させやすさの要素との線形和で説明するモデルを提案して、特異値分解によりそれぞれの要素に分解できることを示した。そしてモデルの妥当性を検証するために実環境下で得られたデータに適用して結果を示した。

今後の課題として、周期的な要素の導入や、このモデルに対応したコホートの決定手法の確立などが考えられる。

参考文献

- [1] Rust, Roland T., Lemon, Katherine N., Zeithaml, Valerie A.: Return on Marketing: Using Customer Equity to Focus Marketing Strategy, Journal of Marketing, vol.68, no.1, pp.109-127, 2004.
- [2] 川口 真一, 下村 剛士: プラットフォーム型ビジネスを支えるシステム運営, UNISYS TECHNOLOGY REVIEW 第 136 号, p.37-47, 2018.
- [3] 武内 慎, 人の音楽鑑賞行動に見られる冪分布に対する現象論的モデルの検証, 日本物理学会 2018 年秋季大会, 9aM203-3, 2018.

*1 <https://abema.tv>

構造に基づくリンクの役割発見

Role discovery of the links based on the network structure

菊田 俊平*¹ 鳥海 不二夫*¹ 西口 真央*¹
Shumpei Kikuta Fujio Toriumi Mao Nishiguchi

*¹東京大学工学系研究科

The University of Tokyo School of Engineering

This paper aims at the discovery of link roles in order to understand links on the network. This work presents a flexible, general framework including graph transformation, representation learning, role assignment, and sense making. We use Edge-dual graph to regard links as nodes and struc2vec to embed links based on roles. We show our model successfully embed the similar links into the low 2-dimensional space on visualization task. Furthermore, we assign roles to links and conclude the structure is critical for a better understanding of links. Future work includes the automatic algorithm to decide the number of clusters and apply our method to real-world datasets.

1. はじめに

ソーシャルネットワークにおいて、リンクは人と人との関係性を表し、そのリンクの性質は、「友人関係」、「上司と部下の関係」、「家族の関係」など多岐にわたる。これらのリンクの性質を理解することができれば、適切な推薦や行動を取ることが可能になるため、リンクの性質の理解は意義がある。

リンクの性質の理解には、リンクの構造が役立つと考えられる。なぜなら、二者の関係性は、二者の他の人との関係性の構造によって構築されると考えられるからである。例えば、所属企業が異なる二者 A, B が存在し、それぞれの所属する企業が頻繁に取引を行う場合、A, B はコミュニティをつなぐ役割を果たす。このとき、二者間のリンクは、コミュニティをつなぐブリッジとしての役割を持ち、二者間の関係性が「得意先の関係」などと理解できる。

ネットワークにおけるノードやリンクの構造は、役割と引き換えられ、役割発見というテーマは、ノードを主な対象として、グラフ理論や社会科学の研究コミュニティにおいて発展し、様々な手法が提案されている [Rossi 15]。また、近年のネットワークの大規模化や自然言語処理 [Mikolov 13] の利用に伴い、低次元のベクトル空間に正確に射影することを目的とする、表現学習と呼ばれる研究領域が注目を集めている [Goyal 18][Cui 18]。表現学習は、分類やリンク予測のタスクにおいて利用されており、役割発見においても利用可能と考えられる。

しかし、従来の研究対象はノードであることが多く、リンクの理解に焦点を当てた研究は少ない。また、役割発見や表現学習の領域においても、リンクに対する研究は活発に行われていない。

本研究の目的は、リンクを類似した構造を持つリンク群に分割し、リンク群に役割をラベリングすることで、リンクの性質を理解することである。手法として、リンクの役割発見を行うための汎用的なフレームワークを導入する。提案フレームワークは、リンクをノードとして扱う辺双対グラフ及び、構造に注目した表現学習である struc2vec[Ribeiro 17] を利用している。実験では、ベンチマークネットワークにおける、可視化によって、類似した構造を持つリンクは近い表現を持つことを

確認し、クラスタリングによって、類似リンクにラベリングを行うことで、リンクの性質を理解できることが示す。

本論文は以下のように構成される。第 2 章では、関連研究について述べ、第 3 章において、提案手法の詳細を述べる。第 4 章において、実験とその結果・考察を述べる。最後に第 5 章で、結論と今後の展望について述べる。

2. 関連研究

本研究における関連研究として、ネットワークにおける役割発見とネットワーク表現学習について述べる。

2.1 ネットワークにおける役割発見

ネットワークからの役割発見に関する研究は、これまでも数多く行われてきた [Rossi 15]。役割発見のアルゴリズムはグラフから直接役割を割り当てる手法と、グラフから特徴量を抽出し、その特徴量に応じて役割を割り当てる手法に大別される [Rossi 15]。前者の例として Blockmodel[White 76] は、役割グラフを作成することで、構造的に類似するノード群に分割する手法であり、多数の類似手法が提案されている。後者の例として rolx[Henderson 12] は、グラフにおける構造的な特徴量を抽出し、その特徴量に対して行列分解を行い、役割を割り当てる手法である。しかし、既存の研究において、対象はノードであり、リンクに対する手法は少ない。本研究においては、[Rossi 15] で提案されたノードの役割を割り当てるフレームワークをリンクに対して用いることができるように、拡張したフレームワークを提示する。

2.2 ネットワーク表現学習

自然言語処理 [Mikolov 13] を端緒としたネットワーク表現学習は、現在多数のアルゴリズムが提案されている [Perozzi 14][Grover 16]。ただし、多くのアルゴリズムが隣接しているノードを近くに埋め込む、homophily の性質に基づいており、ネットワークの大域的構造を保存することを目的とした手法は少ない。しかし、役割を探索する場合、ネットワーク上で距離が離れていても果たす役割が似ていれば、近くに埋め込まれる必要がある。グラフにおける役割に注目した手法として、struc2vec [Ribeiro 17] や、グラフ畳み込み手法 [Kipf 16] が提案されているが、本研究においては、属性情報やラベルがないことから、構造情報のみを利用する struc2vec を用いる。

連絡先: 菊田 俊平, 東京大学工学系研究科, kikuta@torilab.net

さらに、本研究においてはリンクの表現を得る必要があるが、リンクの表現学習の手法は少なく、既存手法 [Abu-El-Haija 17] はリンク予測に特化している。また、リンクの分散表現は、二つのノードの分散表現間の二項演算によって取得し、リンク予測などのタスクに用いられることがあるが、明示的にリンクの表現を得ておらず、有向グラフである場合、非対称な関係性を適切に埋め込むことはできない。そこで、本研究においては、ノードの手法をリンクに用いるためにグラフを変形する手法を導入する。

3. 提案手法

本章では、リンクの役割を発見するため、以下の汎用的なフレームワークを導入する。

- グラフ変形: リンクとノードの役割を反転させる
- 表現学習: ノードの分散表現を自動的に得る
- クラスタリング: 分散表現に応じてリンク群に分割する
- 役割割当: リンク群に対して適切なラベルを貼る

本フレームワークは目的や制約に応じて、柔軟に手法を入れ替えることができる性質を持つ。例えば、本研究ではクラスタリングの際にハードクラスタリングを用いるが、ソフトクラスタリングの手法も同様に用いることができる。

3.1 グラフ変形

本研究では、ノード用のネットワーク表現学習をリンクに対して用いるために、辺双対グラフを用いる。古典的なグラフ理論に起因する手法であり、脳科学 [Bogdanov 14] や、現在のグラフ理論 [Yuan 17] においても利用されている。辺双対グラフの作成方法は以下の通りである。

$$G' = (\{e' | e \in E\}, \{e'_1 e'_2 | e_1, e_2 \in E, e_1 \text{ と } e_2 \text{ は隣接する}\}) \quad (1)$$

ここで、 E は元のグラフにおけるリンクのリスト、 e_1 と e_2 が隣接するとは、ノードを共有することを示す。図 1 に、辺双対グラフの例を示す。元のグラフである [1] のリンクとノードを入れ替えた辺双対グラフが [2] である。

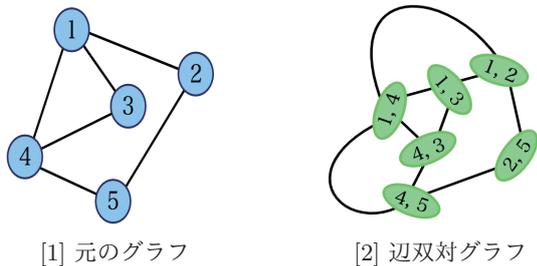


図 1: 辺双対グラフ作成過程

3.2 表現学習

本研究において、分散表現を得る手法として struc2vec [Ribeiro 17] を用いる。struc2vec は、ネットワーク上での位置に関係なく、構造的に似ている二つのノードを潜在空間上で近くに、似ていない二つのノードを遠くに埋め込む表現学習の手法である。struc2vec では、二つのノ

ド u, v の構造的類似度 $f_k(u, v)$ を計算するために、以下の式を用いる。

$$f_k(u, v) = f_{k-1}(u, v) + g(s(R_k(u)), s(R_k(v))) \quad (2)$$

$$k \geq 0, |R_k(u)|, |R_k(v)| > 0$$

ここで、 k はノードから k ホップ先を示し、 $R_k(u)$ は、ノード u の k ホップ先のノード群である。 $s(R_k(u))$ は、 $R_k(u)$ の次数集合を昇順に並び替えた配列であり、 g は、配列同士の距離を測定する関数である。struc2vec では、関数 g として、動的時間伸縮法 [Rakthanmanon 13] を用いており、以下の式で表される。

$$d(a, b) = \frac{\max(a, b)}{\min(a, b)} + 1 \quad (3)$$

ここで、 a, b は配列 A, B の要素であり、 d の和が最小となるように組み合わせる。ノード u, v は構造的距離が近いと、配列同士の類似性が大きくなるため、 $d(a, b)$ は小さくなり、 f も小さくなる。次に、 k^* 層から成る多層グラフを作成するが、ノード間の重みを以下のように定義する。

$$w_k(u, v) = e^{-f_k(u, v)} \quad (4)$$

$$k = 0, \dots, k^* - 1$$

ここで k は k 層目であることを示し、 w はリンクの重みを表す。また、同一のノードの上下の層とのリンクの重みを以下のように定義する。

$$w(u_k, u_{k+1}) = \log(\Gamma_k(u) + e)$$

$$w(u_k, u_{k-1}) = 1$$

$$\Gamma_k(u) = \sum_{v \in V} \mathbb{1}(w_k(u, v) > \bar{w}_k)$$

$$k = 0, \dots, k^* - 1 \quad (5)$$

得られた多層グラフ上をノード u を始点とするランダムウォークすることを考える。確率 q で、現在の層上を遷移し、確率 $1 - q$ で上下の層における同一ノードに遷移する。第 k 層目における遷移確率は、式 (4)(5) で得た重みを用いて、以下のように定義する。

$$p_k(u, v) = \frac{e^{-f_k(u, v)}}{Z_k(u)}$$

$$Z_k(u) = \sum_{\substack{v \in V \\ v \neq u}} e^{-f_k(u, v)} \quad (6)$$

$Z_k(u)$ は確率とするための正規化項である。

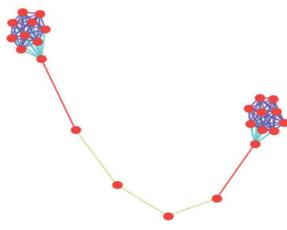
$$p(u_k, u_{k+1}) = \frac{w(u_k, u_{k+1})}{w(u_k, u_{k+1}) + w(u_k, u_{k-1})}$$

$$p(u_k, u_{k-1}) = 1 - p(u_k, u_{k+1}) \quad (7)$$

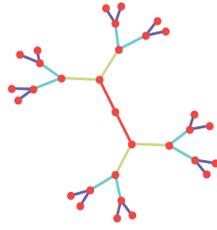
ランダムウォークによって類似する構造を持つノードに遷移しやすいため、ノード u の文脈はノード u に類似するノードによって構成される。文脈が与えられた上で、分散表現を得る際に Skip-gram [Mikolov 13] を用いる。最適手法として階層型ソフトマックスを用いる。

3.3 クラスタリング

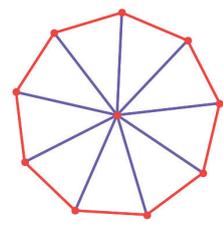
役割数 r が与えられた前提で、分散表現から類似性を持つ r 個に分ける手法として、非階層型クラスタリング手法である k -means 法 [Hartigan 79] を用いる。ここで、struc2vec の性質によって、構造的に類似しているリンクは近い表現を持つため、同じクラスターに帰属していると考えられる。



[1] Barbell graph



[2] 階層型グラフ



[3] リング・スター構造

図 2: 可視化の結果

3.4 役割割当

同様の役割を持つリンク群に分割した後、それらに役割のラベルを与える必要がある。本研究では、役割を割り当てる手法を導入する。クラスターにおける、ネットワーク指標の代表値からクラスターを特徴付ける手法であり、各クラスターに対して、双対グラフ上の次数, pagerank, 媒介中心性, 近接中心性, クラスター係数を計算し、それらに有意な差が得られれば、それをクラスターの特徴と考え、役割を割り当てる。

4. 提案手法の評価と応用

本研究における実験のスキームは以下の通りである。まず、類似した構造を持つリンクが近い表現を持つことを確認するために、可視化を行う。その結果を考察し、クラスターリングから得られる結果は有意義であることを確認した上で、役割発見のタスクを解く。

4.1 ベンチマークネットワークの可視化

本節では、(4, 10)-Barbell グラフ, 階層型グラフ, リング・スター構造グラフに対して、提案手法を適用し、類似した構造を持つリンクが近い表現を持っていることを確認する。

ここで、(n, k)-Barnell グラフとは、n 個のノードを用いて完全グラフを二つ作成し、それらが k 個のノードによって媒介されるグラフである。また、階層型グラフとして、深さ 4 の完全二分木, リング・スター構造としてスター構造の周りをリング状にリンクで囲ったグラフを用いる。階層型, リング・スター構造グラフは、4, 2 本の構造的に同等なリンクを持つため、クラスター数を 4, 2 と定めた。Barbell グラフにおいては、構造的に一致したリンクは 5 本であるが、構造的に類似しているが一致はしていないリンクが近い表現を持つことを確認するため、クラスター数を 4 に設定した。

元のグラフを構造に基づいてリンクを色分けした結果は図 2 の通りである。barbell グラフにおいて、構造的に同等なリンク群(紫, 緑, 赤)は同じクラスターに所属し、類似した構造を持つリンク群(黄)も同じクラスターに所属している。さらに、階層型グラフ, リング・スター型グラフにおいても、構造的に同等なリンク群は同じクラスターに所属していることが確認できる。したがって、可視化のタスクによって、類似した構造を持つリンクは近い表現を持つことが分かる。

4.2 リンクの役割発見

本節では、第三章で導入した手法を用いて、リンクの役割発見のタスクを行う。データセットは Zachary's Karate Club[Zachary 77]を用いる。ノードが 34 個, リンクが 78 本の重みなし無向グラフである。各ノードはクラブ内のメンバーを表し、リンクはメンバー同士の結びつきを表す。クラスターの個数は 4 に設定した。

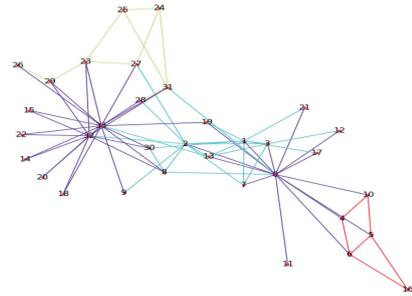


図 3: Karate Club 可視化の結果

クラスターリングを可視化した結果は図 3 の通りであり、また各クラスターのネットワーク指標の代表値は表 1 の通りである。クラスター 1 は、中心性の指標が大きく、またクラスター係数も大きいことから、コミュニティの中心からコミュニティ内の他のノードへ貼られるリンク(紫)と推測できる。また、クラスター 2 は、1 よりも媒介中心性が大きく、その他の指標が 1 よりも小さいことから、コミュニティ間のブリッジの役割を果たすリンク(水色)と推測できる。さらに、クラスター 3, 4 は、クラスター係数が小さい特徴を持ち、中心性指標は全て小さい。したがって、コミュニティ内で末端のリンクであると推測できる。さらに、リンクの構造からリンクの性質が理解できることを示す。Karate Club のデータセットは、二人の指導者によって分裂したクラブにおいて、メンバーが半分ずつ分裂したクラブに所属している。クラスター 1 は、コミュニティ内の中心的なリンクであることから、「リーダーからコミュニティ内のメンバーとの関係性」、クラスター 2 は、コミュニティ間のブリッジの役割を果たすことから、「双方のコミュニティへのつながり」、クラスター 3, 4 はリーダーとは直接かかわっておらず、媒介的でもないリンクであるといえる。すなわちグループ間をつなぐわけでも、リーダーとの関係を作るわけでもない周辺的な関係性であり、「コミュニティ内の味方同士の関係性」と解釈できる。以上より、本フレームワークによってリンクの役割をラベリングし、リンクの役割からリンクの性質が理解できる。

5. おわりに

本研究では、リンクの構造・役割に注目することで、リンクの性質を理解することを示した。また、リンクの役割発見に用いることができる柔軟なフレームワークを示し、その中で、辺双対グラフを用いることで有意義なリンクの分散表現を得られることを示した。今後取り組むこととして、データから役割の数を自動的に決定する手法がある。現時点では役割数 r を既知としているが、それを自動的に求めるアルゴリズムが求めら

表 1: Zachary's Karate Club における各クラスターのネットワーク指標の代表値

label	betweenness		closeness		clustering_coefficient		degree		pagerank	
	mean	median	mean	median	mean	median	mean	median	mean	median
1	5.1	4.5	6.6	6.6	7.6	7.9	2.2	2.2	1.5	1.5
2	6.1	5.8	5.9	5.9	6.3	5.9	1.6	1.6	1.2	1.2
3	2.2	2.3	4.0	4.4	5.3	5.2	0.8	0.9	0.8	0.8
4	1.6	1.7	3.1	3.1	5.6	5.2	0.6	0.6	0.7	0.7
scale	$\times 10^{(-2)}$		$\times 10^{(-2)}$		$\times 10^{(-1)}$		$\times 10^{(-1)}$		$\times 10^{(-2)}$	

れる。また、得られたリンクの性質からノードへの理解を深めることができると考えられる。さらに、現実世界から得られたネットワークデータに本手法を適用し、役割が得られることを示す。

参考文献

- [Abu-El-Haija 17] Abu-El-Haija, S., Perozzi, B., and Al-Rfou, R.: Learning edge representations via low-rank asymmetric projections, in *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, pp. 1787–1796 ACM (2017)
- [Bogdanov 14] Bogdanov, P., Dereli, N., Bassett, D. S., Grafton, S. T., and Singh, A. K.: Learning about Learning: Human Brain Sub-Network Biomarkers in fMRI Data, *arXiv preprint arXiv:1407.5590* (2014)
- [Cui 18] Cui, P., Wang, X., Pei, J., and Zhu, W.: A survey on network embedding, *IEEE Transactions on Knowledge and Data Engineering* (2018)
- [Goyal 18] Goyal, P. and Ferrara, E.: Graph embedding techniques, applications, and performance: A survey, *Knowledge-Based Systems*, Vol. 151, pp. 78–94 (2018)
- [Grover 16] Grover, A. and Leskovec, J.: node2vec: Scalable feature learning for networks, in *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 855–864 ACM (2016)
- [Hartigan 79] Hartigan, J. A. and Wong, M. A.: Algorithm AS 136: A k-means clustering algorithm, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 28, No. 1, pp. 100–108 (1979)
- [Henderson 12] Henderson, K., Gallagher, B., Eliassirad, T., Tong, H., Basu, S., Akoglu, L., Koutra, D., Faloutsos, C., and Li, L.: Rolx: structural role extraction & mining in large graphs, in *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 1231–1239 ACM (2012)
- [Kipf 16] Kipf, T. N. and Welling, M.: Semi-supervised classification with graph convolutional networks, *arXiv preprint arXiv:1609.02907* (2016)
- [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)
- [Perozzi 14] Perozzi, B., Al-Rfou, R., and Skiena, S.: Deepwalk: Online learning of social representations, in *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 701–710 ACM (2014)
- [Rakthanmanon 13] Rakthanmanon, T., Campana, B., Mueen, A., Batista, G., Westover, B., Zhu, Q., Zakaria, J., and Keogh, E.: Addressing big data time series: Mining trillions of time series subsequences under dynamic time warping, *ACM Transactions on Knowledge Discovery from Data (TKDD)*, Vol. 7, No. 3, p. 10 (2013)
- [Ribeiro 17] Ribeiro, L. F., Saverese, P. H., and Figueiredo, D. R.: struc2vec: Learning node representations from structural identity, in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 385–394 ACM (2017)
- [Rossi 15] Rossi, R. A. and Ahmed, N. K.: Role discovery in networks, *IEEE Transactions on Knowledge and Data Engineering*, Vol. 27, No. 4, pp. 1112–1131 (2015)
- [White 76] White, H. C., Boorman, S. A., and Breiger, R. L.: Social structure from multiple networks. I. Blockmodels of roles and positions, *American journal of sociology*, Vol. 81, No. 4, pp. 730–780 (1976)
- [Yuan 17] Yuan, W., He, K., Guan, D., and Han, G.: Edge-dual graph preserving sign prediction for signed social networks, *IEEE Access*, Vol. 5, pp. 19383–19392 (2017)
- [Zachary 77] Zachary, W. W.: An information flow model for conflict and fission in small groups, *Journal of anthropological research*, Vol. 33, No. 4, pp. 452–473 (1977)

密度球を用いた GraphCNN 深層学習手法による渋滞予測

Congestion prediction using GraphCNN depth learning method using density Sphere

高橋 慧*1, 坂本 克好*1, 山口 浩一*1, 沼尻 匠*2, 曾我部 完*2 曾我部 東馬*1*2*3

*1 電気通信大学 大学院 情報理工学研究科 *2 株式会社 GRID

*3 電気通信大学 i-パワーエネジー・システム研究センター

In this paper, we study the data clustering in a high dimensional space based on density spheres for traffic data sets with many samples and features, and predict traffic congestion by creating a distance matrix from features with Density Sphere GraphCNN. Density spheres represent the density which serves as a reference for clustering data in a high dimensional space, and it is possible to investigate the relationship of data by considering both data correlation and distance. A mechanism to realize highly accurate congestion prediction will be studied based on the result of predicting the degree of congestion by combining traffic simulation model, which reproduces congestion and compares the prediction accuracy by varying the volume of density balls

1. はじめに

近年、日本の道路交通システムは複雑な道路網や交通需要の増大、都市部への人口の過密化によって、慢性的に渋滞が発生している。そのため最近、交通需要の調整に人工知能を用いて渋滞を解消しようとする試みが行われている。スマートフォンの普及や車両の状態や道路状況などの様々なデータを取得することの出来るコネクテッドカーの登場などにより、車や人間の動きをリアルタイムで捉えられるようになってきた。そしてリアルタイムの環境や道路のデータを収集することで、機械学習による渋滞予測が可能となった。2017年には、NEXCO 東日本とNTTドコモにより東京湾アクアラインにおける AI 渋滞予知が行われ、従来より高い精度の予知が達成されている*1。今後、IoTにより様々なデバイスから取得したデータが増えれば天候や路面、車両ごとの測定が可能となり、より高精度な渋滞予測が可能になると見込まれる。

そこで本研究では、多くのサンプルと特徴量を持つ交通データセットに対して、高次元空間におけるデータの密度球(Density Sphere)に基づいたクラスタリングを行い、特徴量から距離行列を作成することで畳み込みを行う Density Sphere GraphCNN を用いて渋滞を予測する。密度球とは、高次元空間におけるデータのクラスタリングの基準となる密度を表現したものであり、データの相関と距離を両方考慮してデータの関係性を見ることが出来る。渋滞を再現した交通シミュレーションモデルと GraphCNN を組み合わせることで渋滞の度合いを予測、また密度球の違いによる予測精度の比較し、その結果に基づいて高精度な渋滞予測を実現するメカニズムを検討する。

2. Density Sphere GraphCNN

2.1 GraphCNN

CNN [Lecun 89] は古典的な多層パーセプトロンの延長にあるが、画像の局所的な特徴抽出を行う畳み込み層と、局所ごとに特徴をまとめるプーリング層を繰り返した構造になっている。従来のニューラルネットワークは中間層を増やすことで表現力が増し、表現できる関数や分類できる対象も増えるが、実際に

は過学習や勾配消失の問題から層を増やすことが容易ではない。一方、CNN は畳み込み層とプーリング層を交互に繰り返すことで層を増やし、ネットワークを深層化することが可能である。そのため CNN はディープラーニングの主力とされ、これまで画像処理、音声認識、コンピュータビジョン、言語処理など多くの分野で成功を収めてきた。しかし、CNN はそうした高い性能を持つ一方で、csv ファイルのような行と列の概念がある非構造化データに対して、適用することは困難とされてきた。

そこで最近、特徴行列の相関行列を用いて非画像データに対して畳み込みを可能とする GraphCNN[Yotam 17] という手法が報告された。GraphCNN は非画像データに対しても、CNN の長所である特徴抽出を発揮できる深層ニューラルネットワークである。先行研究ではデータマイニングコンペティションサイト Kaggle で扱われていた 2153 個の特徴と 6148 個のサンプルデータを持つ“Merck Molecular Activity Challenge” *2の分析を行い、DNN と RandomForest を用いた当時の Kaggle コンテストの優勝者のよりも優れた性能を発揮している。

2.2 既存手法の問題点

先行研究の GraphCNN では、特徴量の相関行列を用いて非画像データに対する畳み込みを行っていたが、相関係数にはデータの関係性を表すのに適切ではない場合がある [高橋ら 17]。図 1 のような 3 つのデータ点がある場合を考える。

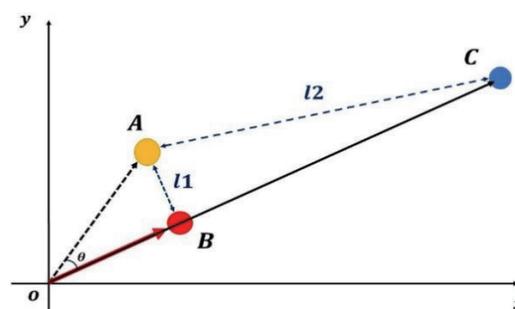


図 1 相関と距離によるクラスタリングの違い

相関係数 r は 2 つのベクトルのなす角度 θ の余弦で表されるため、 \vec{OA} と \vec{OB} の相関係数は $\cos\theta$ となり、同様に \vec{OA} と \vec{OC} の相

関係数も $\cos\theta$ となる。つまり、相関係数を基準に考えたとき、点 A, B, C は同じクラスタに分類される。一方、データ間の距離を基準に考えたとき、点 C は点 A, B から離れているため、一般的に点 A, B と同じクラスタと見なすことは出来ない。

また、図 2 のようなデータ群があったとき、点 A と点 B は同じクラスタであると考えられる。しかし、データ間の距離のみを基準に考えたとき、点 A, B の距離 $L1$ は、点 A, C の距離 $L2$ よりも離れているため、点 A と点 B が同じクラスタの場合、点 A と点 C も同じクラスタだと見なされる場合がある。

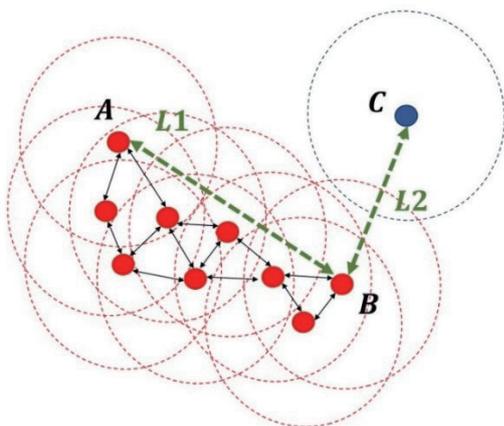


図 2 相関と距離によるクラスタリングの違い

相関係数やデータ間の距離はこうした特性があるため、それぞれを単体で用いると、データの関係性を表するのに最適とは言えない。データの相関と距離の両方を考慮に入れて、関係性を図るのが最善であり、密度球を用いることでそれら両方を考慮することが出来る。

2.3 密度球 (Density Sphere)

高次元の特徴空間において、多くの点が近接しているような領域を高密度領域といい、その領域に属する点は同じクラスタに分類されることが多い。密度球は、その特徴空間におけるデータのクラスタリングの基準となる空間密度を表したものである。図 3 に密度球のイメージモデルを示す。

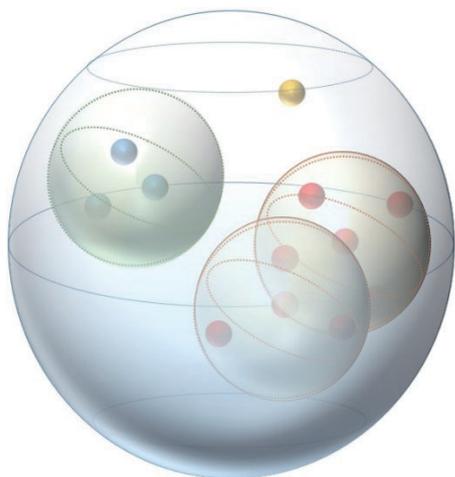


図 3 密度球のイメージモデル

あるデータ点を中心に距離 r 以内の空間に Q 個以上のデータが存在するとき、密度球が定義され、密度球がお互いに隣接するデータを同じクラスタとして扱う。距離 r 以内の空間に Q 個以上のデータが存在しない場合、密度球が定義されず、その点はどのクラスタにも属さない外れ点となる。このように密度球によるクラスタリングを行ったのちに、同クラスタの点同士の距離を求める。同じクラスタに存在するデータとの距離を取ることで、データの相関と距離を両方考慮した距離行列を作成することが出来る。図 2 の場合においても、初めにデータの密度を考慮したクラスタリングを行うことで、点 A, B と点 C が違うクラスタであると認識し、外れ点である青点を除いた点同士の距離を取ることで、データの関係性をより説明することが出来る。

3. データセットの構築と分析

3.1 交通シミュレーションモデル

本研究では、WITNESS™ という汎用シミュレーションソフトウェアを用いて、高速道路で渋滞が発生する要因を再現した簡易的なモデルを作成した。そのモデルを図 4 に示す。

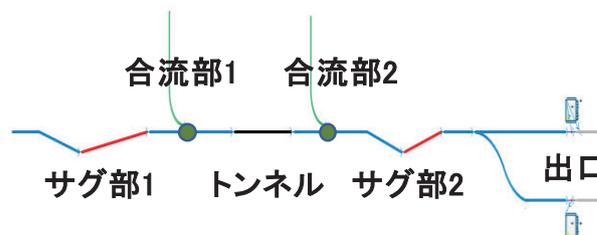


図 4 高速道路のモデル

高速道路で渋滞が発生する要因は主に 4 つあり、サグ部と呼ばれる下り坂から上り坂にさしかかる凸部、トンネル、合流部、そして出口である。渋滞の予測には通常、ある時刻にどれくらいの車が特定のエリア内にいたかという統計データと、そしてどの程度の渋滞が発生したかという道路状況を示すデータが必要になる。今回の実験では、モデルに常時数十台の車を走らせて各エリアごとの車の台数、および車ごとの走行時間を出力し、5510 サンプル 8 つの特徴量を持つデータセットを作成し、学習に用いた。

3.2 データセットの関係性

作成したデータセットの特徴量がどのような関係性を持っているかを調べる。図 5 にデータセットの関係性を表す。左上が特徴量同士の相関行列、右上がガウシアンカーネルにより求められたデータ間の距離行列、そして左下が密度球において $Q=2$ のときの距離行列、右下が $Q=4$ をにしたときの距離行列である。ガウシアンカーネルは以下のように表される式であり、データ間の距離に近いほどに値は 1 に近づく。

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right)$$

マスの色が白に近いほど特徴量はお互いの変動をよく表している。図 5 を見ると、同じデータから生成したにもかかわらず、どの行列も異なる関係性を表していることが分かる。このように用い

る手法によって、データ間の重要度が変わってくるため、学習の際に真にデータの関係性を表している行列を選択することが重要になる。

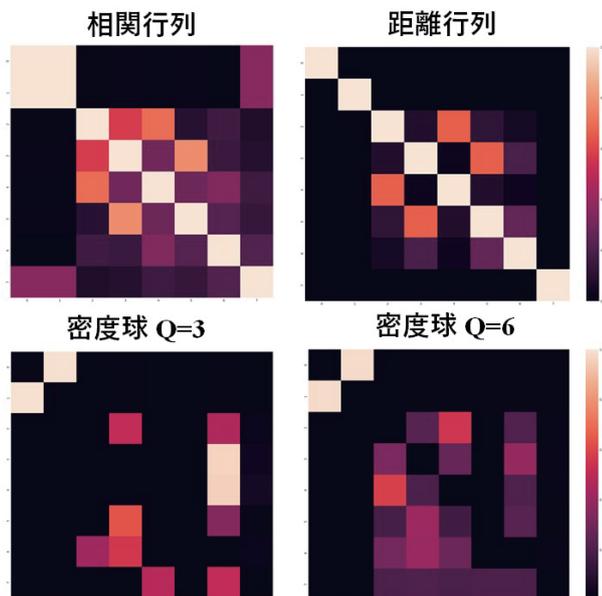


図5 データセットの関係性

4. 実験および評価

実験には、畳み込みを2回繰り返す全7層の構成を持つDensity Sphere GraphCNN(D-GCNN)を用いた。また比較のため相関行列を利用したCorrelation-GraphCNN(C-GCNN)、距離行列を利用したKernel-GraphCNN(K-GCNN)、他に回帰予測において一般的に用いられているNeural Network, RandomForest, XGBoost, LightGBMでも実験を行った。

4.1 走行時間の予測

前述の7個の手法を用いて、車の走行時間(s)の予測を行った。分析の評価にはRMSEを用いた。RMSEは

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=0}^N (f_i - y_i)^2}$$

で定義される関数であり、Yは実際の走行時間、 \hat{Y} は予測された走行時間を表し、RMSEが0に近いほど予測精度が高い。3つのGraphCNNの構成において、畳み込み1層目は15枚、2層目は20枚のフィルタ、全結合層のユニット数は64個、反復回数は300回というパラメータ設定を共通に用いた。

実験結果を図6に示す。GraphCNNを用いた3つの構成の精度は、従来のニューラルネットワークの精度を大きく上回ることが分かる。GraphCNNは他の手法よりも精度が高く、さらにD-GCNNは最も精度が良いことが分かる。次に、密度球の密度の違いによる予測精度の差を図7に示す。図7より、Q=3の時に最も良い精度を持つことが分かった。クラスタリングの際の空間密度は予測精度に影響を与え、密すぎても疎すぎても良くないことが分かる。

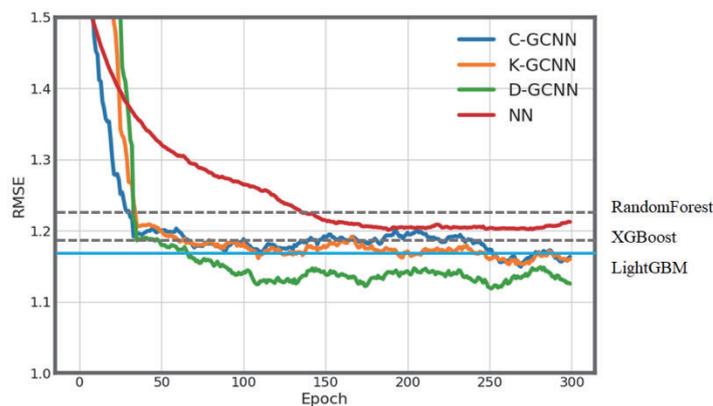


図6 走行時間の予測における各手法の精度

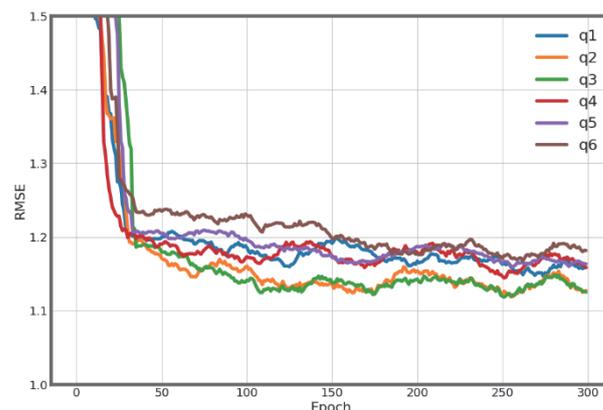


図7 密度球におけるQの値ごとの精度

4.2 渋滞の分類

次に同じデータにおいて、走行時間を「渋滞なし」「やや渋滞」「渋滞」の3クラスに分類し、渋滞の度合いを判断する分類問題を行った。その結果を表1に示す。表1よりD-GCNNがわずかに他の手法の精度を上回っていることが分かった。

表1 各手法における渋滞分類の正答率

Method	正答率 (%)
NN	71.0
RandomForest	68.4
XGBoost	73.0
LightGBM	72.9
Correlation GraphCNN	72.6
Kernel GraphCNN	72.8
Density Sphere GraphCNN	73.3

次に、密度球の密度の違いによる分類精度を表2に示す。予測と同様にQ=3の時に最も精度が良く、Q>5以上の時に分類精度が低下した。このデータセットにおいてQ>5の場合、密度球によるクラスタリングが細かく行われすぎたと考えられる。

表 2 密度球における Q の値ごとの正解率

	正答率 (%)
Q = 1	72.7
Q = 2	72.9
Q = 3	73.3
Q = 4	70.7
Q = 5	65.1
Q = 6	65.1

5. まとめ

本研究では、交通データに対する CNN の応用手法として GraphCNN に注目し、その手法の改善案として密度球を用いた Density Sphere GraphCNN を提案した。提案手法の有効性を検証するため、高速道路の渋滞を再現したミュレーションモデルから生成された交通データセットを用いて予測、分類問題の実験を行った。その結果、提案手法である Density Sphere GraphCNN は、他の GraphCNN の予測精度を上回り、密度球の有用性が証明された。また、密度球の密度条件は予測結果に影響を与える、それぞれの課題に合った値を選択する必要があると分かった。今後、データセットの特徴量が増えて関係性が複雑になったとしても、密度球を用いることで予測に必要な特徴量のみを抽出し、より高精度の予測を行えることが期待される。

参考文献

- [Lecun 89] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L.D. Jackel, “Backpropagation applied to handwritten zip code recognition”, Neural Computation, vol.1, pp.541-551, 1989.
- [Yotam 17] Yotam Hechtlinger, Purvasha Chakravarti, Jining Qin: A Generalization of Convolutional Neural Networks to Graph-Structured Data, arXiv preprint, arXiv:1704.08165 (2017)
- [高橋ら 17] 高橋慧、沼尻匠、曾我部完、坂本克好、山口浩一、横川慎二、曾我部東馬、特徴グラフを用いた汎用型 CNN 深層学習手法の開発, 2018 年度人工知能学会全国大会 (第 32 回) 論文集(2018)

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

[1J2-J-6] Web mining 1

Chair:Mitsuo Yoshida Reviewer:Kugatsu Sadamitsu

Tue. Jun 4, 2019 1:20 PM - 2:40 PM Room J (201B Medium meeting room)

[1J2-J-6-01] Recommendation System based on Generative Adversarial Network \\with Graph Convolutional Layers

Takato Sasagawa¹, OShin Kawai¹, Hajime Nobuhara¹ (1. University of Tsukuba)

1:20 PM - 1:40 PM

[1J2-J-6-02] Visualization and Analysis of the Hierarchical Correlation among Words and Documents in Hyperbolic Space

ODaiki Hashimoto¹, Hori Koichi¹ (1. University of Tokyo)

1:40 PM - 2:00 PM

[1J2-J-6-03] User Identification Across Social Media Based on Friends' Locations

OKazufumi Kojima¹, Masahiro Tani¹ (1. NEC Corporation)

2:00 PM - 2:20 PM

[1J2-J-6-04] Proposal of Flexible Route Recommendation Method Employing Edge Vector-Based Formulation

OHiroki Shibata¹, Yasufumi Takama¹ (1. Tokyo Metropolitan University)

2:20 PM - 2:40 PM

グラフ畳み込み層を有する 敵対的生成ネットワークによる推薦システムの提案

Recommendation System based on Generative Adversarial Network with Graph Convolutional Layers

笹川 天斗*¹ 河合 新*² 延原 肇*²
Takato Sasagawa Shin Kawai Hajime Nobuhara

*¹筑波大学理工学群工学システム学類

College of Engineering Systems, School of Science and Engineering, Univ. of Tsukuba

*²筑波大学大学院システム情報工学研究科知能機能システム専攻

Dept. of Intelligent Interaction Technologies, Graduate School of Systems and Information Engineering, Univ. of Tsukuba

A Graph Convolutional Generative Adversarial Network (GCGAN) is proposed to effectively recommend to new users or items. To maintain scalability, the discriminator is improved to capture latent features of users and items by using graph convolution from a minibatch size bipartite graph. Through the experiment using MovieLens dataset, it is confirmed the effectiveness of the proposed GCGAN compared with the conventional methods.

1. はじめに

近年の深層学習において、画像生成分野で注目されてきた生成モデルである GAN(Generative Adversarial Networks)[Goodfellow 14] が推薦システムにおいても有効であることが示されている [Wang 17b, Wang 17a, Chae 18]。この GAN による推薦システムは、推薦する上でユーザーの既存の購入や評価の履歴を必要としない。よって、協調フィルタリング等の履歴の類似度で推薦をするアルゴリズムが抱えるユーザーの評価が極端に少ない、あるいは無いといった状況下で推薦ができないコールドスタート問題を解消することができる。一方で、履歴の代わりに使用するユーザーおよびアイテムのドメイン情報(ユーザーの年齢やアイテムのジャンルなどの属性情報)の両方を同時かつ効果的に利用することのできるモデルは未だ存在しない。

これに対して、ソーシャルネットワーク、知識グラフ、タンパク質相互作用ネットワークなどのグラフデータのための強力なツールとして、グラフ畳み込みネットワーク [Kipf 16] が提案されている。推薦においても、ユーザーとアイテムの相互作用の構造を 2 部グラフとみなすことで応用できる。情報推薦に 2 部グラフを用いる研究では、グラフ畳み込みを用いて与えられたグラフ構造を再構成するモデルの有効性が示されている [Berg 17]。グラフ畳み込みでは、畳み込みをおこなうことでノード間の特徴量が集約していき、大局的な特徴量を学習できる。しかし、ノードが持つ特徴量をエッジにしたがって伝搬させるため、ノード数が固定されており、新規ノードを学習したモデルに追加するには、モデルを再学習する必要がある。

本研究では、ユーザーとアイテムの潜在的特徴をグラフ構造を介して学習するグラフ畳み込み敵対的生成ネットワーク (GCGAN:Graph Convolutional Generative Adversarial Network, 図 1) を提案する。GCGAN は生成器の入力ノイズにラベル情報を追加することで生成データを制御する CGAN[Mirza 14] に基づいている。ラベル情報としてユーザーの特徴量ベクトル(ドメイン情報)を入力し、ユーザーのアイテム評価・嗜好を表す 2 部グラフを生成する。このグラフで、従来のモデルではできなかったユーザーとアイテム両方のドメ

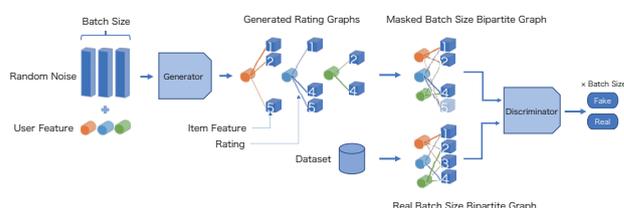


図 1: GCGAN フレームワークの全体図

イン情報を活用し、推薦性能を向上させる。またノード数において、バッチサイズごとにグラフを統合することにより、新規ノードに対しても大局的な特徴量を学習できるメリットを確保し、モデルを再構築せずとも新規ノードに対して予測が可能となる。これにより、ユーザーとアイテム両方のドメイン情報を活用し、コールドスタート問題を解消できる。

提案する GCGAN の有効性を示すために、映画評価履歴のデータセット (MovieLens100K, MovieLens1M) [Harper 16] を用いた実験を行う。比較対象として GAN ベース推薦システムである CFGAN[Chae 18] と Precision@N(Top-N の Precision)の結果を比較し、GCGAN の推薦システムにおける有効性を示す。

2. 関連研究

2.1 敵対的生成ネットワーク (GAN) を用いた推薦

GAN[Goodfellow 14] を利用し情報検索と推薦に応用した最初のモデルとして IRGAN[Wang 17b] がある。この研究では、Web 検索、アイテムの推薦、質問の回答などの情報検索タスクでその機能を実証している。同じく GraphGAN[Wang 17a] と CFGAN[Chae 18] は、GAN が推薦システムで成功する可能性を実証した先駆的な方法である。これらは生成器 G にユーザーが購入するアイテムの予測リスト(ベクトル)を生成させ、識別器 D が学習データ上の真のリストか、生成された偽物かを分類することで、生成器 G がユーザー嗜好の真の分布をとらえる手法である。GAN に基づく生成モデルによる推薦は、協調フィルタリング等の評価履歴の類似度から予測するのではなく、嗜好の分布を学習するためコンテンツベースアルゴリズム

ムの一種であるといえる。

2.2 2部グラフの推薦システム

グラフを対象とした深層学習の研究に基づき、行列補完のための自動エンコーダフレームワークを推薦に応用する研究が行われている [Berg 17]。具体的には、ユーザーとアイテムをノードとし、嗜好・評価のリンクで表した2部グラフ構造に置き換え、推薦をグラフのリンク予測問題とみなしている。そしてグラフ畳み込みネットワークにより、ユーザーとアイテムの潜在表現を学習し、再構築したグラフを用いて推薦を行う。推薦するグラフがソーシャルネットワークのようなドメイン情報を伴う場合に特に有効であり、情報推薦においては、グラフとして表現される評価値データとドメイン情報などの外部情報を組み合わせることで、評価値が少ない状態(コールドスタート)での性能向上が見込まれている。

3. 提案手法

提案法は、ユーザーとアイテムの評価(嗜好)関係を表す2部グラフを生成するネットワーク(生成器 G)を学習することで実現される。生成器に入力するのはユーザーの特徴量と正規分布に従うノイズで、出力は2部グラフである。この2部グラフをバッチサイズ個分を一つの2部グラフに統合し識別器に入力する。識別器では入力された2部グラフがデータセット上の真のグラフか、生成された偽物かを分類するように学習する。提案法の識別器では、評価値に加えてドメイン情報も扱うグラフ畳み込みを用いることで、大域的な特徴量が学習され、分類性能の向上が見込まれる。したがって、敵対的に学習される生成器についても生成性能(推薦性能)の向上が期待される。

3.1 GCGAN フレームワーク

GCGANにおける生成データはユーザーノード $u_i \in \mathcal{U}$, $i \in \{1, \dots, N_u\}$ に対応するアイテムノード $v_j \in \mathcal{V}$, $j \in \{1, \dots, N_v\}$ とのエッジの接続関係 $m_i \in \mathbb{R}^{N_v}$, $i \in \{1, \dots, N_u\}$ である。エッジは予測されるユーザーとアイテムの評価関係を表し、嗜好の度合いを示す重み値が付随する。また各ノードには F_u, F_v を次元数とする特徴量 $x_u^{(i)} \in \mathbb{R}^{F_u}$, $i \in \{1, \dots, N_u\}$, $x_v^{(j)} \in \mathbb{R}^{F_v}$, $j \in \{1, \dots, N_v\}$ が付随している。したがってGCGANはユーザーとアイテムによる2部グラフのサンプルを生成器 G で生成し、生成したグラフをもっともらしい評価関係になるよう識別器 D がデータセットを用いて識別しながら学習する。GCGANは

$$\begin{aligned} \min_G \max_D V(D, G) = \\ \mathbb{E}_{m \sim p_{data}(m)} [\log D(m \otimes (x_u, x_v))] + \\ \mathbb{E}_{z \sim p_z(z)} [\log(1 - D((G(z|x_u) \odot e) \otimes (x_u, x_v)))] \end{aligned}$$

をもとに関数 D と G を引数に取る価値関数 $V(D, G)$ によって定義され、識別器 D について最大、生成器 G について最小となるような D, G を定める。ここでの (\otimes) はグラフ畳み込みを、 (\odot) はベクトルの要素ごと積を意味している。

生成器 G は θ_G をパラメータとして、標準正規分布 p_z に従うノイズ $z \in \mathbb{R}^n$ を入力し、出力するエッジの接続関係 m の生成器上での分布 p_g を学習するため、ノイズ分布 $p_z(z)$ をデータ空間へ写像する関数

$$m = G(z|x_u; \theta_G) \in \mathbb{R}^{N_v},$$

となる。このときユーザーの特徴量 x_u をノイズ z に結合して入力することで条件付きモデルに拡張する。したがって生成器

表 1: データセット

Dataset	Users	Items	Ratings	UF	IF
ML100K	948	1,683	100,000	23	18
ML1M	6,040	3,706	1,000,000	23	18

はユーザー特徴量とノイズの分布から生成されるデータの分布を学習することが期待される。

そして識別器 D は θ_D をパラメータとして、入力 m が p_g からではなく、訓練データ上のものである確率 y を出力する関数

$$y = D(m \otimes (x_u, x_v); \theta_D) \in \mathbb{R},$$

とする。生成器から生成されたグラフは識別器 D へ入力される前に $e \in \mathbb{R}^{N_v}$ によってマスクされる。マスク e は生成器に入力されたユーザー特徴量に対応する訓練データの欠損値を、生成されたグラフにおいて再現する。識別器 D ではユーザーとアイテムの特徴量 x_u, x_v 両方を使用してグラフ畳み込みを行い、畳み込み後の特徴量と接続関係 m を結合して入力することで、条件付きモデルとして拡張する。

価値観数 V は Algorithm 1 によって最適化される。まずバッチサイズ個 b のノイズ z を $p_z(z)$ から取り出す。同様にグラフの接続関係 m を $p_{data}(m)$ から取り出す。それらをユーザー特徴量 x_u と結合する。生成器によって生成されたグラフに対応する真のグラフの欠損値をマスクする。その後 θ_D における確率的勾配が上がるように識別器 D を更新する。次にバッチサイズ個のノイズ z を取り出し、 θ_G における確率的勾配が下がるように生成器 G を更新する。これを訓練回数分だけ繰り返すことで最適化される。

3.2 識別器におけるバッチサイズ統合とグラフ畳み込み層

GCGANにおいて識別器 D が識別するのは、ユーザーとアイテムの評価・嗜好関係を表す2部グラフである。したがって識別器 D は入力された2部グラフが、データ上のものか生成されたものかを識別する。エッジの接続関係による類似ノード間の特徴量の学習のためには、複数のユーザーとアイテムのノードが必要だが、生成器 G は一人のユーザー u_i のみに関するアイテムの接続関係 m_i を出力する(図1の Generated Rating Graphs)。したがって、提案法ではバッチサイズ b 人分の2部グラフを統合し、識別器 D への入力とした。この時、識別器 D がユーザーノードが持つ特徴量 $x_u^{(i)} \in \mathbb{R}^{F_u}$, $i \in \{1, \dots, b\}$ とアイテムノードのもつ特徴量 $x_v^{(j)} \in \mathbb{R}^{F_v}$, $j \in \{1, \dots, N_v\}$ を学習するためグラフ畳み込み層を使用する。この畳み込み層は任意の数で多層化でき、特徴量が各ノードを伝搬し大域的な特徴量を学習する。識別器 D はこの畳み込んだ $h_u^{(i)}$ と隣接関係を表す $m^{(i)}$ を結合し、全結合層にてグラフが本物か偽物かを識別する。

4. 評価実験

4.1 実験環境

データセットはユーザーが映画に対して評価をしている2つのサイズの MovieLens [Harper 16] データセット(表1)を使用する。このデータセットには各ユーザーが各アイテムに行った評価の値以外に、評価を行ったユーザーとアイテムのドメイン情報が付随している。実験ではドメイン情報としてユーザーの

Algorithm 1 Minibatch stochastic gradient descent training of graph convolutional generative adversarial nets.

for number of training iterations **do**

- Sample minibatch of b noise sample $\{z^{(1)}, \dots, z^{(b)}\}$ from $p_z(z)$.
- Sample minibatch of b examples $\{m^{(1)}, \dots, m^{(b)}\}$ from data generating distribution $p_{data}(m)$.
- Sample minibatch of b user feature $\{x_u^{(1)}, \dots, x_u^{(b)}\}$.
- Sample minibatch of b mask $\{e^{(1)}, \dots, e^{(b)}\}$.
- Update the discriminator by ascending its stochastic gradient:

$$\nabla_{\theta_D} = \frac{1}{b} \sum_{i=1}^b [\log D(m^{(i)} \otimes (x_u^{(i)}, x_v)) + \log(1 - D((G(z^{(i)} | x_u^{(i)}) \odot e^{(i)}) \otimes (x_u^{(i)}, x_v)))]$$

- Sample minibatch of b noise sample $\{z^{(1)}, \dots, z^{(b)}\}$ from $p_z(z)$.
- Sample minibatch of b user feature $\{x_u^{(1)}, \dots, x_u^{(b)}\}$.
- Update the generator by ascending its stochastic gradient:

$$\nabla_{\theta_G} = \frac{1}{b} \sum_{i=1}^b [\log(1 - D((G(z^{(i)} | x_u^{(i)}) \odot e^{(i)}) \otimes (x_u^{(i)}, x_v)))]$$

end for

 The gradient-based updates can use any standard gradient-based learning rule.

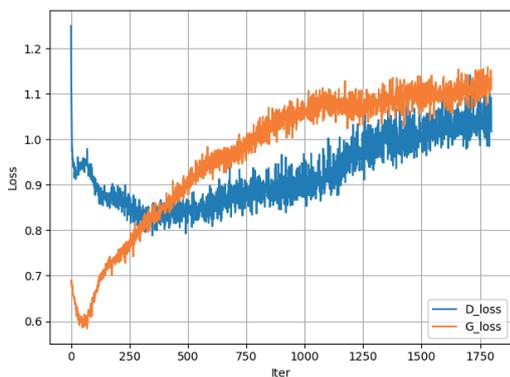


図 2: GCGAN の学習中のミニマックスゲームの推移の様子

年齢・性別・職業のデータと、アイテムのジャンルのデータを使用した。表中の UF(User Feature) と IF(Item Feature) は使用した特徴量の次元数である。MovieLens100K,1M の評価値は $r = \{\text{Null}, 1, 2, 3, 4, 5\}$ を持ち、値が大きいほど高評価をしている。データセットを (ユーザー数 $N_u \times$ アイテム数 N_v) で要素に評価値を持つ評価行列に変換し、評価なしの欠損値 (Null) は 0 とする。評価行列をユーザーの軸で 8:2 に分割し、訓練データとテストデータとした。訓練データでの学習後、生成器にテストデータ内のユーザー特徴量を入力し、生成した二部グラフのエッジ上の重み上位 N 個を推薦アイテムとする。この推薦アイテムと評価値 4 以上を嗜好ありとしたテストデータにより推薦の性能を Precision@N にて評価する。同じ GAN を用いた推薦システムであり、ユーザー特徴量を入力とした生成器と識別器を多層ニューラルネットによって構成している CFGAN を比較対象に設定する。

4.2 結果・考察

図 2 に学習における生成器と識別器の損失の推移を示す。通常の GAN [Goodfellow 14] と同様に GCGAN も生成器と識別器がシンクロして学習を進めていることが確認できる。

次に MovieLens100K と MovieLens1M での実験結果を表 2 に示す。GCGAN は MovieLens100K においてバッチサイズ 64,128 両方で比較手法を下回り、MovieLens1M においては両方のバッチサイズで比較手法を上回る結果となった。MovieLens100K で比較手法に劣り、MovieLens1M で比較手法より向上した理由として、データセットのサイズが MovieLens100K では小さく、グラフ畳み込みを行うことで識別するノードの特徴量が均一化・平滑化してしまったのではないかと考えられる。対して MovieLens1M では、十分なノード数を確保できているため、グラフ畳み込みが効果的にノードの特徴量を学習できたと考えられる。

GCGAN ではバッチサイズ個のノードを統合し、その 2 部グラフ上で畳み込みを行い特徴量を学習する。したがってバッチのサイズによってグラフ上での特徴量を学習する領域が決まり、その領域を大きくするほど大局的な特徴量を学習し、識別性能を介した推薦性能の向上が期待される。図 3 に MovieLens100K,1M においてバッチサイズを段階的に変更した結果を示す。バッチサイズを大きくすることにより性能がよくなっていることが確認できる。またある程度を超えると、そこから性能が悪化することが確認できた。これは畳み込むグラフサイズが、最終的に識別するユーザー一人に対するグラフに対して大きくなりすぎると、特徴量が平滑化し局所性が無視され識別が困難になるためであると考えられる。実際に図 3 より、アイテム数が少ない MovieLens100K では MovieLens1M よりも早い段階で性能が悪化していることが確認できる。

グラフ畳み込み層は任意の数に多層化でき、一層の畳み込みでアイテムノードの特徴量をユーザーノードへ、ユーザーノードの特徴量をアイテムノードへ伝搬する。したがって直接接続していないノードにも、多層化によりエッジを介し特徴量が伝搬される。MovieLens100K,1M においてグラフ畳み込み層の層数と評価値の推移を図 4 に示す。図より MovieLens1M においては 5 層目まで畳み込み層の層数が多くなるほど向上していることが確認できる。MovieLens100K では畳み込み層の層数による推薦性能の向上は確認できなかった。グラフが小さく、一回の畳み込みで平滑化が進んでしまったためであると考えられる。

表 2: MovieLens100K,1M での Precision@N の実験結果

Dataset	MovieLens 100K						MovieLens 1M					
	64			128			64			128		
Batch Size	P@5	P@10	P@15	P@5	P@10	P@15	P@5	P@10	P@15	P@5	P@10	P@15
CFGAN	0.610	0.678	0.684	0.667	0.768	0.808	0.578	0.735	0.759	0.662	0.732	0.757
GCGAN	0.499	0.611	0.648	0.425	0.561	0.618	0.677	0.749	0.771	0.705	0.765	0.784

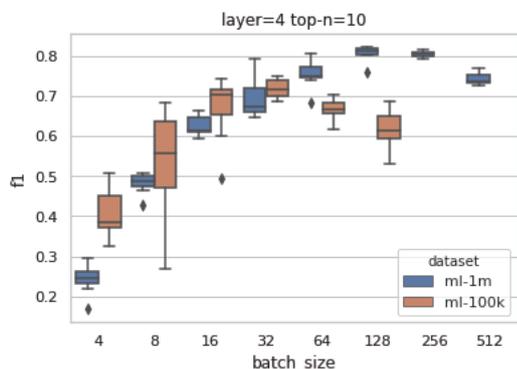


図 3: バッチサイズと f1 スコアの推移

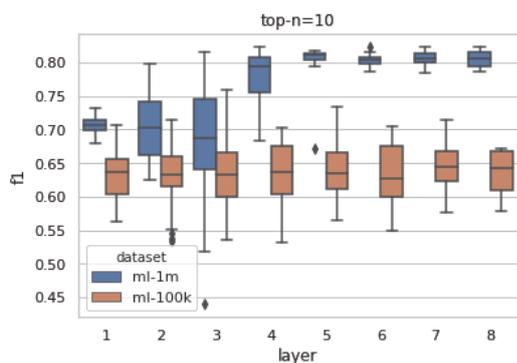


図 4: グラフ畳み込み層の層数と f1 スコアの推移

5. おわりに

本研究では推薦システムにおけるコールドスタート問題を解消するため GCGAN を提案した。GAN とグラフ畳み込みを組み合わせた GCGAN は、グラフ構造を介した特徴量の伝搬によりドメイン情報を効果的に学習でき、ユーザー特徴のみで推薦するため新規ノード (ユーザー) に対して再学習する必要がない。GCGAN は MovieLens1M のデータセットにおいて比較手法よりも推薦性能が向上した。またバッチサイズ個ごとのノードの統合と、グラフ畳み込み層の層数における推薦性能への効果を確認した。今後の課題として、MovieLens よりユーザーとアイテムの特徴より多いデータセットに GCGAN を適用すること、小さなデータセットへの対策、生成器においてもドメイン情報を考慮できるモデルを構築していく必要があると考えている。

参考文献

[Berg 17] Berg, van den R., et al.: Graph Convolutional Matrix Completion, *stat*, Vol. 1050, p. 7 (2017)

[Chae 18] Chae, D.-K., et al.: CFGAN: A Generic Collaborative Filtering Framework based on Generative Adversarial Networks, in *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, pp. 137–146 ACM (2018)

[Goodfellow 14] Goodfellow, I., et al.: Generative adversarial nets, in *Advances in neural information processing systems*, pp. 2672–2680 (2014)

[Harper 16] Harper, F. M., et al.: The movielens datasets: History and context, *Acm transactions on interactive intelligent systems (tiis)*, Vol. 5, No. 4, p. 19 (2016)

[Kipf 16] Kipf, T. N., et al.: Semi-supervised classification with graph convolutional networks, *arXiv preprint arXiv:1609.02907* (2016)

[Mirza 14] Mirza, M., et al.: Conditional generative adversarial nets, *arXiv preprint arXiv:1411.1784* (2014)

[Wang 17a] Wang, H., et al.: Graphgan: Graph representation learning with generative adversarial nets, *arXiv preprint arXiv:1711.08267* (2017)

[Wang 17b] Wang, J., et al.: Irgan: A minimax game for unifying generative and discriminative information retrieval models, in *Proceedings of the 40th International ACM SIGIR conference on Research and Development in Information Retrieval*, pp. 515–524 ACM (2017)

双曲空間上での単語および文章の意味の構造の埋め込みとその可視的な分析

Visualization and Analysis of the Hierarchical Correlation among Words and Documents in Hyperbolic Space

橋本 大輝 堀 浩一
Daiki Hashimoto Koichi Hori

東京大学工学部航空宇宙工学科
Department of Aeronautics and Astronautics, University of Tokyo

In areas such as Aerospace Engineering where many areas come together to form one complicated area of study, it could be difficult to grasp its entire structure especially for students who has just began learning it. We address this problem by visualizing the hierarchical relationship of different papers in such areas in hyperbolic space to give an overview of the area and suggest which papers to read in what kind of order according to the users interest. We also discovered ways to find new insights in relationship among different topics by using Wasserstein Metrics with the created visualization.

1. はじめに

航空宇宙工学などの技術及び学問分野は、様々な分野の成果とその複雑な関係の元成り立っている。よって特に初めてその分野を学ぶ人にとって、その全体像を把握するのが難しいことが多い。さらにその分野の中で研究をし未解決の問題に取り組もうとした場合にはその問題にかかわる要素がとてつもなく多いため、何に注目して研究を進めるべきかを判断するのは困難を極めるかもしれない。

本論文ではこういった分野の理解に役立つようにその分野に関わる論文群をその意味により Poincare Embedding に基づき双曲空間上に埋め込むことで論文の内容とその抽象度に従って木構造状に整理し可視化し、分野全体を俯瞰できるような仕組みを提案する。

さらに可視化された構造を Wasserstein Distance などを用いて分析することで、今後その分野に取り組む際にどのような点に着目するかを考える補助になる情報を視覚的に提供する仕組みを提案する。

これにより文章間の関係をだまかに捉えた可視化を作成することができ、それを分析することによりその分野に関する新たな知見を得ることに役立った。

提案手法と同様に文章のトピックを階層構造上に整理することを試みたものに Hierarchical Topic Models[1] や Pachinko Allocation Model[2] がある。特に Hierarchical Topic Model は NIPS のアブストラクトを対象にトピックの階層構造の生成を行っており、提案手法と似た題材を扱っているが、提案手法では論文からトピックを抽出しその階層構造を生成するだけでなく、各論文を一要素として扱って論文の階層構造を生成した。また提案手法では生成した階層構造を生成したあとこれを用いた分析手法について触れているという点でも異なる。

本論文の構成は以下のとおりである。2章では Poincare Embedding と Wasserstein Distance といった提案手法に用いた技術や理論についてその概要を説明する。3章では提案手法について説明し、4章では arxiv の論文のアブストラクトに対して行った実験の考察を行う。最後に、5章ではまとめと今後の課題について述べる。

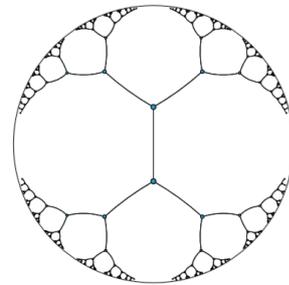


図 1: 二分木の双曲空間への埋め込み。[4] より引用

2. 関連研究及び理論

本章では提案手法に関連する Poincare Embedding と Wasserstein Distance について述べる。

2.1 Poincare Embedding

Poincare Embedding[4] では埋め込みを一般的なユークリッド空間上ではなく、負の曲率を持つ曲がった空間である双曲空間のモデルの一つであるポワンカレの円盤モデル上に行っており、これによって階層構造の埋め込みを高い精度で行っている。

双曲空間とはまっすぐなユークリッド空間と異なり負の曲率を持つ曲がった空間のことで、木構造との親和性が高い空間[3]である。木構造は双曲空間には図 1 のように中心から遠いほどより深いノード配置されるように自然な形で埋め込まれる。Poincare Embedding は入力として“哺乳類、犬”のような上位概念と下位概念のペアの集合を用い、ペアとして与えられた要素がなるべく近くに配置されるように双曲空間の一モデルであるポワンカレの円盤モデル上で最適化を行うことで双曲空間への埋め込みを行う。

より具体的には、 $\mathcal{D} = \{(u, v)\}$ を要素 u と v にみられる上位概念、下位概念の関係、 $\mathcal{N}(u) = \{v(u, v) \notin \mathcal{D}\} \cup \{u\}$ を u と上位概念、下位概念の関係がみられない要素の集合とする。このとき $d(u, v)$ を要素 u と v のポワンカレの円盤モデル上での距離

$$d(u, v) = \operatorname{arcosh} \left(1 + 2 \frac{\|u - v\|^2}{(1 - \|u\|^2)(1 - \|v\|^2)} \right) \quad (1)$$

とすると

$$\mathcal{L} = \sum_{(u,v) \in \mathcal{D}} \log \frac{e^{-d(u,v)}}{\sum_{v' \in \mathcal{N}(u)} e^{-d(u,v')}} \quad (2)$$

を最大化することで埋め込みを作成する。

2.2 Wasserstein Distance

Wasserstein Distance とは確率分布同士の距離のことで、提案手法ではこの中でも特に Earth Movers Distance と呼ばれる距離の 1 乗に関する Wasserstein Distance を用いる。

1 次の Wasserstein Distance は最適輸送問題の解と捉えることができ、理解がしやすい。

例えばある町 A に n 個の工場 A_i (ただし k は 1 から n の整数)、町 B に m 個の倉庫 B_j (ただし l は 1 から m の整数) があり、工場 A_i から倉庫 B_j までの距離が d_{ij} である中、町 A の町 B まで商品を輸送することを考える。この時工場 A_i から倉庫 B_j に運ぶ商品の数を f_{ij} とすると、輸送にかかるコストは

$$W' = \sum_{i=1}^n \sum_{j=1}^m d_{ij} f_{ij} \quad (3)$$

と定義することができる。工場 A_i には商品が w_{A_i} 個あり、工場 B_j には商品 w_{B_j} 個運ぶ必要があるという制限の中で W' を f について最小化し f^* を求め、これを f^* で平均をとると

$$W_{\infty} = \frac{\sum_{i=1}^n \sum_{j=1}^m d_{ij} f_{ij}^*}{\sum_{i=1}^n \sum_{j=1}^m f_{ij}^*} \quad (4)$$

となり、これが Wasserstein Distance となる。このように Wasserstein Distance はある集合からある集合へ要素が移動する際の最小コストととらえることができる。

Wasserstein Distance は上記のように集合同士の距離尺度として使用することができ、Word Mover's Distance[5] では文章を単語の集合とみなし word2vec と Wasserstein Distance を併用することで文章の距離を類似度として求めている。さらに Wasserstein Distance を用いた集合間の重心 (Wasserstein Barycenter) を考えることもでき、こちらも 3D モデルのモーフィングなどに用いられている [6]。

3. 提案手法

提案手法では文章集合から word2vec および doc2vec を用いてベクトルを作成し、これらを類似度をもとに双曲空間に埋め込んだ。さらに双曲空間で発見した集合に対し word2vec 及び doc2vec 空間上で Wasserstein Barycenter を求めることで双曲空間に現れる情報の補足および分析を行う。

Poincare Embedding は前述のとおり入力に上位概念下位概念のペアを用いるが、word2vec や doc2vec からこれらを求めることは難しい。よって入力に上位概念下位概念のペアではなく類似度を用いて双曲空間上への埋め込みを行っている [7] を参考に 2 において $\mathcal{D} = \{(u,v)\}$ を全ての要素、 \mathcal{N} を各 \mathcal{D} に対して v に比べ u に似ていない要素の集合として 2 のように最適化を行うことで word2vec および doc2vec 空間上での類似度から双曲空間の埋め込みを作成した。

また結果を可視化しやすいように埋め込みは 2 次元の双曲線空間上に行ったが、word2vec や doc2vec は数百次元で情報を表現しているため、2 次元の空間に埋め込みを行う際には多大な情報のロスが予測される。したがってこれを観測し、さらに補うために提案手法では Wasserstein Barycenter を用いた。

まず双曲空間内で集合をいくつか見つけ、それらの word2vec、もしくは doc2vec 空間上での Wasserstein Barycenter を求めることで全集合の重心となるような集合を計算する。するとこれは word2vec および doc2vec 空間上で各集合に関わりの深い集合を表しているはずなので、これを双曲空間で改めて可視化することで双曲空間と word2vec 及び doc2vec 空間の対応を観測する。Wasserstein Barycenter を用いた観測に関しては実験結果および考察で詳しく記す。

4. 実験と評価

プレプリントサーバ arXiv にアップロードされた論文のうち機械学習のカテゴリに類する論文の抽象トピックを対称に word2vec と doc2vec のモデルを作成し双曲空間上への埋め込みを行い、その分析を行った。

ここではまず埋め込みの結果とその分析の結果を紹介し、次に Wasserstein Barycenter を用いた結果の分析の結果を紹介する。総じて word2vec を埋め込んだ結果からは明確に階層構造を見て取ることはできなかったが、doc2vec を埋め込んだ結果からは階層構造を比較的よく見て取ることができた。ここでは紙面の都合上 doc2vec の結果のみについて述べる。

4.1 文章の埋め込み

ここでは埋め込みの対象となる文章を全文章から一様分布に従い 200 から 500 個ランダムに選択した場合の埋め込みの結果について記す。

200 個の文章に対するある埋め込みは図 2 のようになった。右下の部分を見ると、機械学習で作成した分類器の脆弱性に関する事柄である Adversarial Example や Adversarial Attack*1、また逆にこれを見つけることに関する "fake news detection" などの文章が集まっており、かつ外側を見ると "towards adversarial configurations for software product lines" など寄り具体的な適用例が集まっており、ある程度階層構造をなしている様が見取れる。したがってこのように階層構造をなしている集合に自分の気になる内容を含む論文があった場合中心に近い論文から順番に見て必要に応じて読むことで効率良くその話題の理解を進めることができる。

左端にベイズ統計をもとにした研究に関する論文、上に最適化や次元削減に関する論文が集まるなど、ある程度角度により話題の分布が見取れたが、単語の場合と同様な理由からかすべての場所で明確な階層構造を見て取れたわけではなかった。一方で単語の場合と違い、複数の分野にまたがっている論文も多いなかつ点あたりの意味が多きはっきりとしているので考察はこちらのほうが楽であった。

ある程度階層構造をなしていた脆弱性に関する話題を扱った論文群に対して考察を進める。

左下の点に "defense against the dark arts: an overview of adversarial example security research and future research directions" [9] という論文があり、これはほかの階層構造から外れている。一方でこれは IEEE Security and Privacy で行われたレクチャーのまとめであり、タイトルからもわかるように将来の研究の方向性まで含めて論じており様々な分野にまたがる内容を含んでおり抽象度が高い。またこの論文は近年の機械学習 (解くにディープニューラルネット) の進歩をまとめたページが数ページにわたりあり、他の脆弱性に関する話題の

*1 おもに深層学習により学習した分類器が正しく識別できていたデータに、人では知覚できない程のノイズを乗せることで識別を誤らせることができる分類器の脆弱性のこと [8]

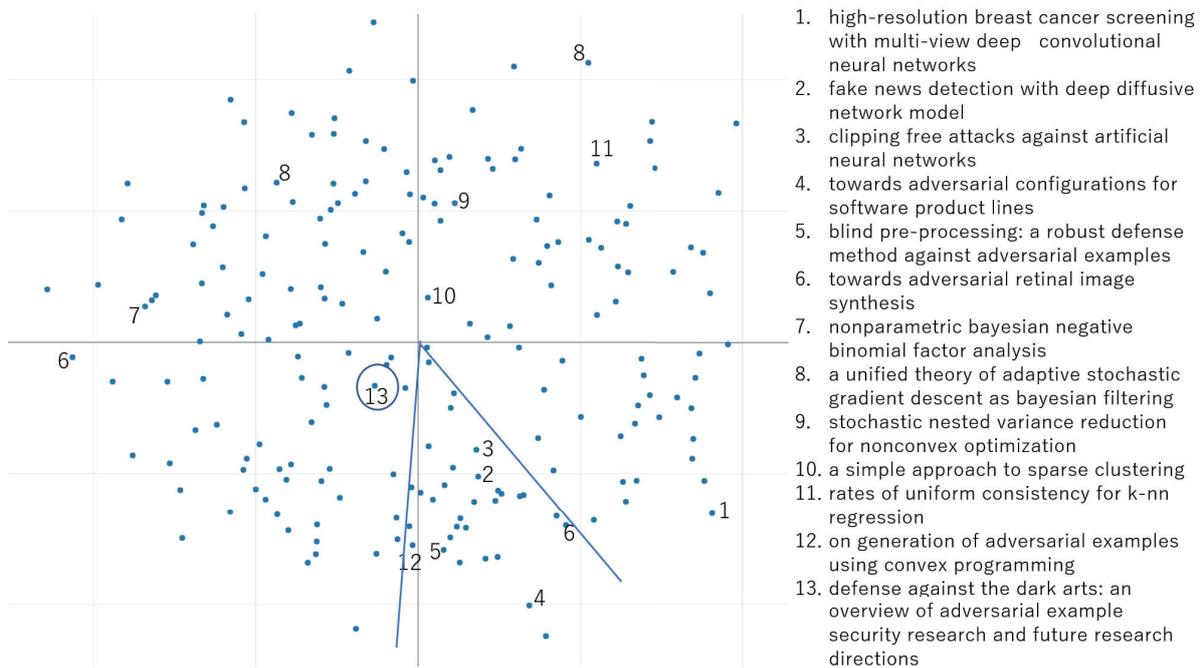


図 2: 200 個の文章に対するポワンカレの円盤モデル上での埋め込み。

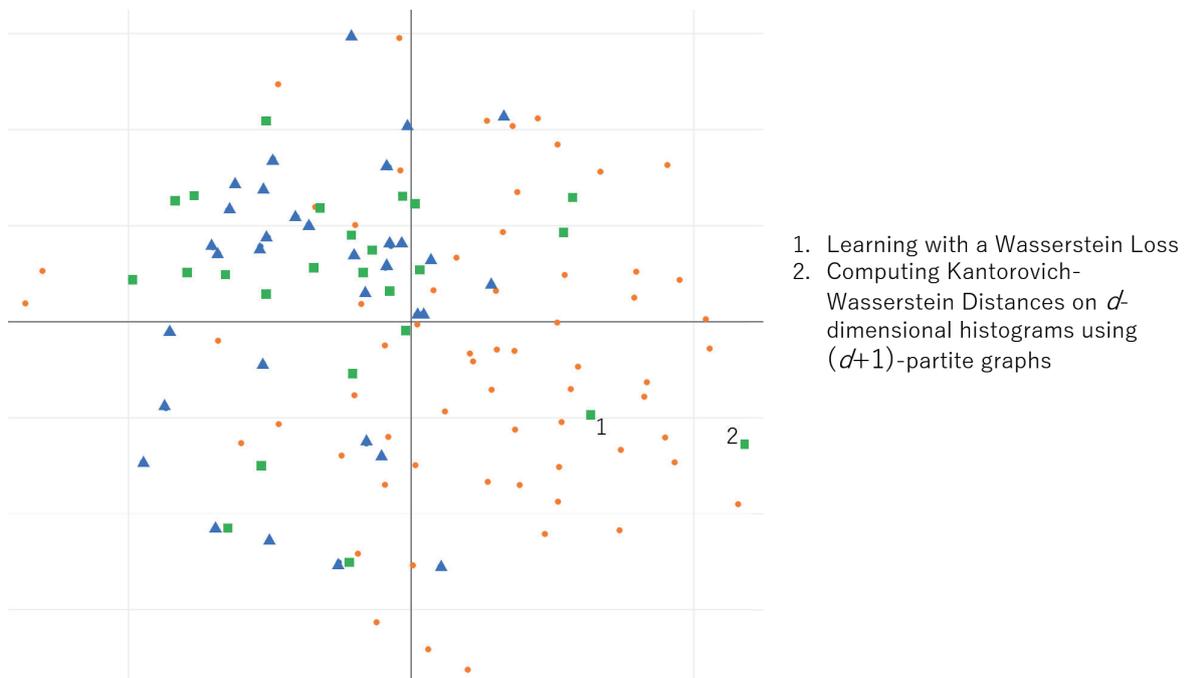


図 3: 三角が gan または generative を Abstract に含む点、丸がその他、四角が barycenter に指定された点を表す。

み扱った論文に比べ中心に来ていることも含めて点の配置は妥当だといえる。

さらにこの点の後ろに gan に関する論文が複数ある。[9] では画像を中心にセキュリティに関して言及しており、gan も効果的に adversarial example を生成する手法として近年認知されたとある。将来のセキュリティーに関する論文として gan との関連度は高いと思われ、階層構造に注目し例外を探しこれに注目することで話題同士の接点を知ることのできる良い例でもあった。

4.2 Wasserstein Barycenter を用いた分析

Wasserstein Barycenter を利用して二つの異なる場所に散布する話題の重心に当たる集合を計算することででも両方の話題と関連が深い点を探ることができ、階層構造からずれた点を探することに役立つ。

アブストラクトに wasserstein という単語が含まれている論文のみの埋め込みに対し、gan または generative という単語を Abstract に含む文章と含まない文章の集合の Wasserstein Barycenter をとった結果が図 3 である。緑の点の多くは左上または左下に集中しており、gan や generative といった話題の近くに分布している。一方で点 1 や点 2 と表される論文は gan や generative といった単語を含む点と遠いにも関わらず二つの話題に関連する Barycenter として計算されている。

これは単語での”defense against the dark arts: an overview of adversarial example security research and future research directions”と同様に階層構造の外部に位置する点を見つけたことになる。実際”learning with a wasserstein loss”[10]は Wasserstein Distance を分類器の学習の際のロスとして用いることについて書かれており、2015 年に掲載されているにもかかわらず Wasserstein GAN でのものとよく似た立ち位置で Wasserstein Distance を扱っている。”Computing Kantorovich-Wasserstein Distances on d-dimensional histograms using (d+1)-partite graphs”[11]も中心距離から離れているが multipartite graph(多部グラフ)を用いるというほかの論文ではあまり用いられない手法を用いて特定の条件下で効率よく Wasserstein Distance を計算する手法を紹介している今年の 5 月に掲載された新しい論文で、Wasserstein Distance の計算全体にかかわるものである。このように Barycenter は二つの話題の接点に当たるような点を提示しており、階層構造からずれた点を自動的に探索し話題間のつながりを見つける点を提示するなどして話題間の関係を探り、今後注目すべき話題を探る際に活用することができた。

5. おわりに

双曲空間上での埋め込みにより単語や文章の階層構造をある程度可視化し、また可視化された階層構造をもとに考察を行うことで直感的に話題間の関係などの情報を得ることができた。特に文章の埋め込みだとこれは行いやすく、adversarial examples などの例では実際にその階層構造のずれから話題間の関係を導くことができた。一方で次元の不足などから完全に何らかの基準のもとに階層構造をなしているような可視化は観察することができず、wasserstein という単語を含む文章のみを埋め込むなどして文章の話題の範囲を狭めるなどしないと双曲空間上での明確な話題の分離は見られなかった。Wasserstein Barycenter を用いた分析では話題と話題の接点となる点の探索に用いることができ、階層構造のずれをみつけそこから新たな情報を導くことができた。

提案手法の延長として、他にも w_2v や d_2v 以外の埋め込み

を双曲空間に埋め込んで同じような分析を行うことが考えられる。

参考文献

- [1] Blei, David M. and Jordan, Michael I. and Griffiths, Thomas L. and Tenenbaum, Joshua B.: Hierarchical Topic Models and the Nested Chinese Restaurant Process, *Proceedings of the 16th International Conference on Neural Information Processing Systems*, pp. 17-24 (2003)
- [2] Li, Wei and McCallum, Andrew: Pachinko allocation: DAG-structured mixture models of topic correlations *Proceedings of the 23rd International Conference on Machine Learning*, pp. 577 - 584 (2006)
- [3] Krioukov, Dmitri and Papadopoulos, Fragkiskos and Kitsak, Maksim and Vahdat, Amin and Boguñá, Marián, Hyperbolic geometry of complex networks, *Phys. Rev. E* 82, pp. 18 (2010)
- [4] Nickel, Maximillian and Kiela, Douwe: Poincaré Embeddings for Learning Hierarchical Representations, *Advances in Neural Information Processing Systems* 30, pp. 6338 - 6347 (2017)
- [5] Matt Kusner and Yu Sun and Nicholas Kolkin and Kilian Weinberger, From Word Embeddings To Document Distances, *Proceedings of the 32nd International Conference on Machine Learning*, pp. 957-966 (2015)
- [6] Justin Solomon and Fernando de Goes and Gabriel Peyré and Marco Cuturi and Adrian Butscher and Andy Nguyen and Tao Du and Leonidas J. Guibas, Convolutional wasserstein distances: efficient optimal transportation on geometric domains, *ACM Trans. Graph.* vol 34, pp. 66:1 - 66:11 (2015)
- [7] Nickel, Maximillian and Kiela, Douwe, Learning Continuous Hierarchies in the Lorentz Model of Hyperbolic Geometry, *Proceedings of Machine Learning Research* vol 80, pp. 3779 - 3788 (2018)
- [8] Ian Goodfellow, Explaining and Harnessing Adversarial Examples, *arXiv preprint arXiv:1806.04169* (2018)
- [9] Ian Goodfellow, Defense Against the Dark Arts: An overview of adversarial example security research and future research directions, *arXiv preprint arXiv:1806.04169* (2018)
- [10] Charlie Frogner and Chiyuan Zhang and Hossein Mobahi and Mauricio Araya-Polo and Tomaso A. Poggio, Learning with a Wasserstein Loss, *Advances in Neural Information Processing Systems (NIPS)* 28, (2015)
- [11] Gennaro Auricchio and Federico Bassetti and Stefano Gualandri and Marco Veneroni, Computing Kantorovich-Wasserstein Distances on d-dimensional histograms using (d+1)-partite graphs, *arXiv preprint arXiv:1805.07416* (2018)

友人の位置情報を活用したアカウント集約

User Identification Across Social Media Based on Friends' Locations

児島 一郁 谷 真宏
Kazufumi Kojima Masahiro Tani

NEC バイオメトリクス研究所
Biometrics Research Laboratories, NEC Corporation

This paper describes user identification method across social media using friends' location information. One of the conventional methods is based on the similarity of two display names. The conventional method has a problem of a decrease in the identification accuracy if a user registers different display name across social media. Our proposed method aims to address this problem utilizing friends' location information. We convert location information extracted from social media to that of administrative unit such as country and state, and calculate the weighted occurrence frequency of a location pair based on distance between the locations. This basis is that a friend list rarely includes the account pair whose locations are far distance. Finally, we identify users using the account similarity between weighted occurrence frequencies on each administrative unit. The evaluation experiment shows that the proposed method improves the performance rather than the conventional method (accuracy: 82.7% \rightarrow 90.9%).

1. はじめに

近年、様々なソーシャルメディアがそれぞれ異なった利用目的で社会に普及している。ユーザーは、例えば、芸能人や有名人が発信する情報を確認する場合と、友人と連絡を取る場合でソーシャルメディアを使い分けている。^{*1*2}

ユーザーは、異なるソーシャルメディア、異なるアカウントを用途に応じて使い分けていることから、ソーシャルメディア間で異なる情報(テキストや画像など)を投稿している場合がある。ユーザーが使い分けているソーシャルメディアのアカウントを集約できれば、多くの場合そのユーザーに関する情報が増えるため、ユーザーの属性や趣味嗜好をより詳細に分析できる。詳細な分析から得られる知見は、経済学やコミュニケーション科学、心理学、計算社会科学をはじめとする学術分野で関心が高い。また、ターゲット広告やパーソナライズド検索の高度化、ネット上のプライバシー保護や犯罪捜査等の支援に役立つ。^{*3} このため、同じユーザーが所有する異なるソーシャルメディアのアカウントを推定(ユーザーの同一性判定)する研究に対して関心が高まっている。

しかしながら、前述の通り、同一ユーザーが所有するアカウントであっても、ソーシャルメディアが異なる場合、投稿されている内容やプロフィール情報が異なるため、同一性判定したアカウント(注目アカウント)同士の投稿情報やプロフィール情報のみから判定するのは難しい。本稿では、注目アカウントの情報を用いず、注目アカウントとソーシャルメディア上でつながりのある友人アカウント群の情報、特に位置情報を用いた同一性判定手法を提案する。

2. 関連研究

多くの研究では、同一人物が所有する注目アカウントペアかどうかを判定するために、投稿されているテキストや画像、

プロフィール情報から抽出したユーザーの特徴の類似度を用いている。

Hanら [Han 17] は、投稿に添付されたGPS情報から抽出したユーザーの行動パターンの類似度に基づき同一人物が所有するアカウントかどうかを判定している。Jiangら [Jiang 16] は、投稿された画像から抽出した撮影に使用したカメラ特有のノイズパターンの類似度を用いている。Voseckyら [Vosecky 09] は、注目アカウントのプロフィールに記載されている性別や居住地などの情報の一致率を基にした、同一性判定手法を提案している。

しかしながら、多くのアカウントが投稿内容を非公開にしていたり、プロフィールとして設定できる項目が各ソーシャルメディアで異なっていたりすることから、第三者がアカウントの情報を網羅的に抽出することは難しい。そのため、Liら [Li 17] は投稿内容に比べて抽出が容易なdisplay nameの類似度に基づいた同一性判定手法を提案している。ここでのdisplay nameとは、アカウントの名前として表示されるもので、アカウントIDと異なり、同一ソーシャルメディア上で重複が許されている文字列のことを指す。Liらは、大手ソーシャルメディアプラットフォームである、Facebook、Twitter、Foursquareから収集した約120万ユーザーのdisplay nameを用いた実験を行い、高い精度を達成した。Liらはdisplay nameのペアから、共通する文字列の文字数や編集距離、Jensen-Shannon距離などを含み、14個の特徴量を抽出、Support Vector Machine(SVM)によってモデルを学習し、ユーザーの同一性判定に活用している。我々は、Liらの手法をベースラインとして実装し、提案手法と比較した。

3. 提案手法

Liらの手法では、display nameに基づいて同一性判定しているため、2つのソーシャルメディアで異なるdisplay nameを設定していた場合に同一性判定することが難しい。また、他の従来手法もアカウントの投稿内容やプロフィール情報の類似度から同一性判定しているため、ユーザーが異なる情報を各ソーシャルメディアに投稿している場合、Liらの手法同様、

*1 <https://www.valuesccg.com/knowledge/report/marketing/040/>

*2 <http://www.pewinternet.org/2018/03/01/social-media-use-in-2018/>

*3 このようなサービスを提供する場合、各国法律や各ソーシャルメディアの利用規約に従い、プライバシーに配慮する必要がある。

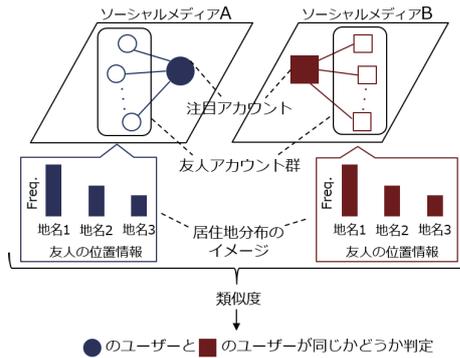


図 1: 提案手法の概略図

同一性判定することは難しいという問題がある。

本稿では、注目アカウントと交友関係にあるアカウントの情報を活用することで、注目する2つのアカウントのユーザーが同一人物かどうかを判定する手法を提案し、上記の問題を解決する。提案手法は、図1のように、注目アカウントと交友関係にあるアカウント(友人アカウント)群の情報、特に出身地や居住地といったプロフィールに記載の位置情報の類似性に基づく。また、ここでの交友関係とは、Twitterの相互フォローやFacebookのフレンドなどのようなアカウント間の関係性を指す。

提案手法では、図1のような友人アカウントの居住地分布を、居住地間の距離に基づいて重み付けすることで、ユーザー特有な地名の出現頻度分布を算出する。ユーザー特有な地名の出現頻度分布を抽出するために、国、州などの予め定めた行政区分の粒度を持つ粒度別位置情報に変換し、粒度毎に、位置情報間の距離に応じた位置情報のペアの出現頻度を重み付ける。粒度毎に重み付けられた位置情報のペアの出現頻度から、2つのアカウントの類似度を算出、粒度毎の類似度に基づき同一性を判定する。

3.1 粒度別位置情報への変換

ソーシャルメディアから抽出した友人アカウント群の位置情報は、国や州などの粒度が異なっていたり、表記ゆれなどがあるので、抽出したデータそのものから出現頻度分布を作成することは難しい。そのため、ソーシャルメディアから取得した位置情報を予め定めた粒度別の位置情報に変換する。ソーシャルメディアから取得した位置情報を粒度別位置情報に変換するために、OpenStreetMap^{*4}を活用する。OpenStreetMapでは、地名をクエリとして入力すると、地名のGPS情報と国や州などの粒度を取得でき、さらに、クエリとして入力した地名が属する、クエリの粒度より粗い行政区画や国の名称を取得することが可能である。例えば、「California」を粒度別位置情報に変換した場合、州という粒度の情報および、それを代表するGPS情報と、「California」が属する国、「US」を代表するGPS情報に変換される。変換された粒度より細かい粒度は取得できないため無視する。例えば、入力が「US」だった場合、州の粒度の位置情報は取得できないため、州の粒度は空とし、「US」のGPS情報を国の粒度の結果とする。

3.2 距離に応じた位置情報の出現頻度の重み付け

2つのアカウントの地名間の距離が遠い場合、その2つのアカウントは友人として出現し難いという仮定の下、距離が遠い地名ペアを、注目アカウント特有の地名ペアとする。例

えば、注目アカウントの友人らに「California」と「Tokyo」、「Kanagawa」を居住地に持つアカウントが取得された場合、距離が遠い「California」と「Tokyo」、「California」と「Kanagawa」のアカウントの組み合わせは、距離が近い「Tokyo」と「Kanagawa」のアカウントの組み合わせに比べて友人リストに出現し難いとして、前者2つの地名ペアの重みを大きくする。2つの地名の出現頻度を距離で重み付けしたものを、重み付け出現頻度として地名のペアのスコアとする。注目アカウントAにおける、ある粒度 u での友人の位置情報リスト $g_{u,A}$ から地名 l_i と地名 l_j のペアが選択される確率 $p(l_i, l_j | l_i, l_j \in g_{u,A})$ は式(1)のように表せる。

$$p(l_i, l_j | l_i, l_j \in g_{u,A}) = \begin{cases} \frac{n_{l_i} C_1 \times n_{l_j} C_1}{n_{l_i} C_2 \times n_{l_j} C_2} & (i \neq j) \\ \frac{n_{l_i} C_2}{N C_2} & (i = j) \end{cases} \quad (1)$$

式(1)の N は、注目アカウントAの友人の内、地名をある粒度 u の粒度別位置情報に変換できた友人数、 m_i は、 N の内、地名 l_i を持つ友人数を表している。

地名間の距離 $dist(l_i, l_j)$ を確率変数として用いて、友人の位置情報リストに地名 l_i と l_j が同時に含まれる確率 f を表した場合、地名間の距離に応じた重み w は式(2)のように書ける。

$$w(l_i, l_j) = \log \frac{1}{f(dist(l_i, l_j))} + 1 \quad (2)$$

式(1)、(2)より、 $g_{u,A}$ における地名 l_i と地名 l_j のペアの重み付き確率 $q(l_i, l_j | l_i, l_j \in g_{u,A})$ は式(3)と書ける。

$$q(l_i, l_j | l_i, l_j \in g_{u,A}) = w(l_i, l_j) p(l_i, l_j | l_i, l_j \in g_{u,A}) \quad (3)$$

3.3 各粒度におけるユーザーの同一性判定

アカウントAとA'の所有者が同一人物かどうかを粒度毎に判定するために、粒度別の類似度を式(4)のように算出する。算出した類似度と予め定めた閾値からアカウントAとA'が同一人物の所有するアカウントかどうかを判定する。

$$Sim(u, A, A') = \frac{Corr(u, A, A')}{\sqrt{Corr(u, A, A)Corr(u, A', A')}} \quad (4)$$

$$Corr(u, A, A') = \sum_{i=1}^{L_{u,A}} \sum_{j=1}^{L_{u,A'}} score(i, j | g_{u,A}, g_{u,A'})$$

$$score(i, j | g_{u,A}, g_{u,A'}) =$$

$$\begin{cases} q(l_i, l_j | g_{u,A}) q(l_i, l_j | g_{u,A'}) & l_i, l_j \in g_{u,A}, g_{u,A'} \\ 0 & other \end{cases}$$

4. 実験

4.1 実験条件

同一人物が所有するTwitterとFoursquareのそれぞれ約1,000アカウントと、その友人アカウントのプロフィール情報から、登録されている位置情報を抽出する。抽出したアカウントの内、粒度別位置情報に変換できた友人が2アカウント以上存在する注目アカウントを所有しているユーザーは292人である。この292ユーザーが所有するTwitterとFoursquareの注目アカウントと、その友人アカウントを用い、Liらの手法[Li 17]との比較実験を行う。各ソーシャルメディアにおける友人アカウント数はそれぞれ、Twitterが72,203アカウント、Foursquareが20,539アカウントである。なお、ユーザー

*4 <https://www.openstreetmap.org/>

表 1: 10 交差検証による実験結果

手法	データ数 (正例, 負例)	accuracy(%)	precision(%)	recall(%)	F-measure(%)
従来手法	584(292, 292)	82.5	87.7	75.7	81.1
従来手法 (学習用データ拡充)	584(292, 292)	82.7	97.5	67.1	79.1
提案手法 (国)	584(292, 292)	89.6	86.2	94.6	90.0
提案手法 (州)	556(277, 279)	91.0	90.8	91.3	90.9
提案手法 (州 or 国)	584(292, 292)	90.9	90.9	91.1	90.8

のプライバシーを考慮し、各ソーシャルメディアから割り振られたユーザー識別子や個人を特定し得る情報は削除し、各アカウントのページに不可逆な ID を割り振り実験を行う。

本稿において、Twitter の友人とは相互フォローの関係にあるアカウント、Foursquare の友人とはフレンドの関係にあるアカウントを意味する。州まで変換できた友人アカウント数は、国まで変換できた友人アカウント数と比べ、Foursquare, Twitter 共に約 70% 近くいたのに対し、市まで変換できた友人アカウント数は約 25% しかいなかったため、本稿では、位置情報の粒度 (u) として市より粒度が粗い国、州のみを用いる。

実験に用いる負例は、Li らの実験条件と同様、正例として用いるアカウントから異なるユーザーが所有する Twitter と Foursquare のアカウントを正例と同数だけランダムに生成する。10-交差検証により提案手法と従来手法の精度の比較実験を実施した。10 分割されたデータ内の正例と負例の割合はすべて同一 (1 : 1) とする。

従来手法の各特徴量は、アルファベットの大小文字を区別せずに算出する。提案手法で用いる友人の位置情報は、Twitter と Foursquare それぞれプロフィール内の location, homeCity に記載されている内容を抽出し、粒度別位置情報に変換する。式 (2) 中の各地点間の距離 ($dist()$) 算出には Hubeny の式を用いる。また、確率 f は、正規分布を仮定し、粒度が国の場合、地球の直径 $R(km)$ を用いて $N(x; \mu = 0, \sigma = R \times \pi/2)$ 、州の場合、約 200ヶ国の面積^{*5} から算出した直径を用いて $N(x; \mu = 0, \sigma = 460km)$ と定める。同一性判定に用いる粒度別の類似度の閾値は、学習用データセットを用いて F-measure が最大となる時の閾値を選択する。

本稿では、提案手法の精度評価実験として 3 つの実験を行う。まず、従来手法と比べて提案手法に優位性があることを確認するために、584 アカウントペア (正例 : 292, 負例 : 292) を用いて、提案手法と従来手法の精度比較を 10-交差検証で行う。比較する手法は、国の位置情報のみを用いた手法である提案手法 (国) と、州の位置情報のみを用いた手法である提案手法 (州) と、州の位置情報が得られない場合に国の位置情報を使って判定する手法である提案手法 (州 or 国) と従来手法の 4 つである。従来手法の同一性判定で用いる SVM のモデルの学習と、提案手法で用いる各粒度の類似度の閾値設定は、学習用データセットを用いて評価の都度実施する。実験に用いた注目アカウントの内、地名を州の粒度まで変換できた友人がいない注目アカウントがいくつか存在するため、提案手法 (州) の精度算出に用いたアカウントペアの数が他の手法とは異なり、精度比較ができない。提案手法 (州 or 国) は、提案手法 (州) を他の手法と比較するために、584 アカウントペアの内、地名を州の粒度まで変換できた友人がいない注目アカウントを含むアカウントペアに関してのみ国の位置情報を、残りは州の位置

情報を用いて判定した手法である。

次に、従来手法のモデルの学習に使用するデータ量を増やした場合でも、提案手法の方が優れているかどうかを確認するために、7,212 ユーザーが所有するアカウントペアの display name を基に作成した追加用データセットと、584 アカウントペアを用いた 10-交差検証を行う。学習用データセットを拡充した従来手法のモデルの学習には、10-交差検証で分割した学習用データセットに加え、追加用の学習データセットを用いる。

提案手法を実環境で用いる場合、あるアカウントペアの同一性判定に、国もしくは州のどちらの粒度を用いるか選択する必要がある。しかしながら、友人アカウントに記載されている位置情報の粒度が異なるため、どちらの粒度でアカウントペアの同一性を判定すべきかどうか分からない。本稿では、州の粒度まで変換できた友人アカウント数に応じて同一性判定に用いる粒度を切り替えた場合の精度を算出し、州の粒度まで変換できた友人アカウント数が粒度の切り替えに有用かどうかの実験を行う。

4.2 実験結果

(a) 10 交差検証による提案手法と従来手法の精度比較

提案手法である各粒度におけるユーザーの同一性判定と、従来手法との精度を比較した結果を表 1 に記す。表 1 中の accuracy, precision, recall, F-measure は 10-交差検証での各結果を平均したものである。

(b) 判定に用いる粒度の切り替えによる同一性判定

州まで変換できた友人アカウント数に応じて同一性判定に用いる粒度 (国, 州) を切り替えた場合の精度を、図 2 に示す。図 2 の (2, 5) セルが示す精度は、同一性判定したいアカウントペアの友人の内、Twitter で州まで変換できた友人アカウント数が 2 以上で、Foursquare が 5 以上の場合に州の粒度で判定し、それ以外のアカウントペアの同一性を国で判定した場合の accuracy を表している。また、図 3 の同じセル (2, 5) は国の粒度で判定したアカウントペア数を示している。ただし、584 ペアの内 28 ペア (正例 : 15, 負例 : 13) は、州まで変換できた友人が 1 人以下の注目アカウントを含んでいるため、それらのアカウントペアに関しては、条件に依らず国による判定手法を用いた。図 2, (2, 2) セルの精度は、州の粒度で判定可能なアカウントペア、556 ペアは州の粒度で、それ以外の 28 アカウントペアは国の粒度で判定した結果であるため、表 1 中の、州で計算できないアカウントのみを国で計算した場合の提案手法 (州) の accuracy と一致する。

5. 考察

表 1 から、同一性判定に用いる位置情報の粒度に依らず、提案手法の方が従来手法より accuracy が高くなることを確認できた。特に、可能な限り州の粒度でアカウントの同一性を判定した場合の精度である 90.9% は、学習用データセットを拡

*5 <https://ja.wikipedia.org/wiki/国の面積順リスト>

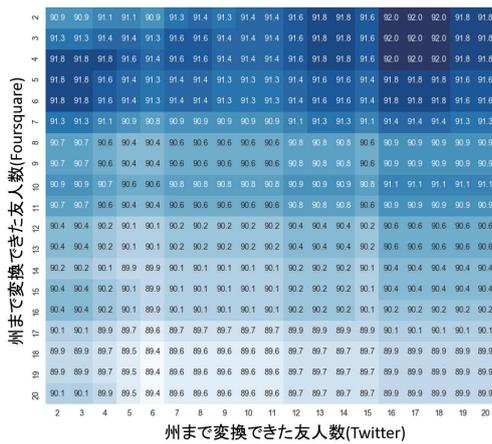


図 2: ソーシャルメディアの友人数に応じた国と州の切り替えによる判定精度

充した従来手法の精度である 82.7%から約 8 ポイント向上した。各粒度の判定結果を比較すると、提案手法(州)の方が提案手法(国)に比べて accuracy, precision, F-measure のスコアにおいて優れており、recall のみ提案手法(国)の方が提案手法(州)と比べてスコアが高かった。提案手法(国)と提案手法(州)に関し、両者共 F-measure は 90%を超えているものの、precision, recall 共に 90%を超える提案手法(州)は、precision と recall のスコアに 10 ポイント近く差がある提案手法(国)と比べて、偽陰性と疑陽性の偏りが少ない手法だと言える。これは、国の種類の方が、州の種類に比べて少ないため、同一人物が所有していないアカウント同士であっても国名が一致する可能性が高くなり、疑陽性の数が多くなるためだと考えられる。従来手法は、学習データセットを拡充したとしても大幅な精度向上(82.5%→82.7%)には繋がらないことが分かった。

図 2 から、Foursquare と Twitter で州まで変換できた友人アカウントが多い注目アカウント同士を、国の粒度で判定した場合、すべて州で判定した精度を下回ることが分かった。また、提案手法(国+州)の最高精度は 92.0%で、[(16,2), (16,3), (16,4), (17,2), (17,3), (17,4), (18,2), (18,3), (18,4)] の 9 つのセルで同じ精度であった。また、図 3 から、提案手法(国+州)の最高精度時の、州で判定したアカウントペア数と国で判定したアカウントペア数は、およそ同数であることが分かった。縦軸と横軸の値を変化させたときの精度の推移の違いから、Foursquare は州まで変換できた友人アカウントが多い場合(≥8)に、州による同一性判定を用いた方が良いが、Twitter は州まで変換できた友人アカウントが多い場合であっても国による同一性判定に切り替えた方が良いということが分かった。これは、Twitter と Foursquare のプロフィール中に記載されている位置情報の意味合いの違いに起因しているものと考えられる。Foursquare はアカウントの位置情報として home city を登録させる一方、Twitter は location を登録させるため、同一ユーザーが所有するアカウントであっても、ユーザーの解釈によって登録する地名情報が Twitter と Foursquare で変わる可能性がある。また、位置情報として homeCity より location の方がユーザーは様々な捉え方ができ、州の粒度の情報だとアカウント毎のばらつきが多くなるため、上記のような結果に繋がったと考えられる。

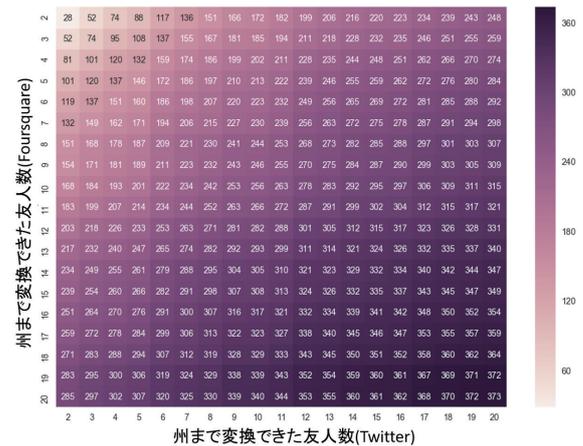


図 3: 国の粒度で判定したアカウントペア数

6. おわりに

本稿では、注目アカウントのプロフィール情報や投稿情報を用いず、友人アカウント群の位置情報から算出したユーザーの特徴量を基に類似度を計算、同一人物かどうかを判定する手法を提案した。ユーザーの特徴量として、位置情報間の距離が離れている友人アカウントのペアを定義、定式化を行った。2つのソーシャルメディア、Twitter と Foursquare から抽出した 292 アカウントのペアを用いた、従来手法との比較実験により、提案手法によって精度が向上することを示した。今後は、国と州のスコアの統合方法について研究を進める。

参考文献

- [Han 17] Han, X., Wang, L., Xu, S., Liu, G., and Zhao, D.: Linking social network accounts by modeling user spatiotemporal habits, pp. 19–24 (2017)
- [Jiang 16] Jiang, X., Wei, S., Zhao, R., Zhao, Y., and Wu, X.: Camera Fingerprint: A New Perspective for Identifying User's Identity, *CoRR*, Vol. abs/1610.07728, (2016)
- [Li 17] Li, Y., Peng, Y., Ji, W., Zhang, Z., and Xu, Q.: User Identification Based on Display Names Across Online Social Networks, *IEEE Access*, Vol. 5, pp. 17342–17353 (2017)
- [Vosecky 09] Vosecky, J., Hong, D., and Shen, V. Y.: User identification across multiple social networks, pp. 360–365 (2009)

辺ベクトルによる定式化を用いた柔軟な経路推薦手法の提案

Proposal of Flexible Route Recommendation Method Employing Edge Vector-Based Formulation

柴田祐樹 *1 高間康史 *1
Hiroki Shibata Yasufumi Takama

*1 首都大学東京
Tokyo Metropolitan University

Many studies for sightseeing route recommendation use the formulation of Selective Traveling Salesman Problem or its extension. However, this formulation uses the costs of the shortest paths between spots as the weights of edges in a graph, which means that the variety of routes between spots is ignored. Users might prefer different routes than the shortest path, such as the route along the river, forest, or sea if they have enough time. This paper proposes a method to recommend routes by considering the balance between staying time and traveling time. Extending the Edge Vector-based formulation, the proposed method utilizes inner routes in a spot to represent the staying time as the costs of those inner routes. An experiment using an artificial data set shows that the proposed method can optimize the staying time and traveling time concurrently.

1. はじめに

観光旅行をする際、ガイドブックや旅行会社が提供する観光ツアーを利用するのではなく、SNSなどのWebから入手した情報を用いて旅行者自身で観光計画を立案することも増えてきている。観光情報サイトなどでは、エリアなどの指定条件を満たす観光スポットをランキング形式で提示するサービスを提供しているが、知名度の高いスポットや宣伝に力を入れているスポットが上位に表示される傾向がある。ユーザの検索行動として、ランキング上位の件数のみしか確認しないことが一般的であるため、結果として個人の趣味嗜好に合った観光地を訪れる機会の損失を招き、一部の観光地へ旅行客が集中するなど、旅行客、観光地側双方に不利益を生じる。こういった問題を防ぐためにも、ユーザの好みに応じたスポットを選び、限られた時間で効率よく巡回する経路を提案する観光経路推薦手法は重要であり、研究が進められている [松田 04][Lim 17].

与えられた節点全てを巡回する最短経路を求める問題は Traveling Salesman Problem (TSP) [Gutin 06] として古くから研究されている。NP-Hard [Yannakakis 91] に属する TSP を解くためには近似解法が用いられ、代表的なものには 2-Optimization (2-Opt) 法 [Helsgaun 09], Simulated Annealing (SA)[Kirkpartrick 83] がある。さらに、スポットに価値を付加し、与えられた総負荷制限の中で価値の総和が最大となる経路を選ぶ問題として、Selective Traveling Salesman Problem (STSP)[Laporte 90] が定式化されている。また、STSP を拡張し、訪れた時間に依存して価値が変化するという問題を文献 [松田 04] では最適観光経路問題として定式化しており、文献 [Lim 17] では同様の定式化において、スポットの価値を Web から取得したデータを用いて推定する方法を提案している。

これらの既存研究はいずれも、節点にスポットを割り当て、節点間の辺の重みに、スポット間を結ぶ最短経路負荷 (コスト) を割り当てる、STSP の定式化を利用しているが、この定式化では特定の交通機関や道路しか用いられないことに等しい。これに対し文献 [柴田 19a] ではスポットのみでなく、途中の経路における街並みや景観等もユーザにとって重要な因子であると

し、これらを考慮可能な観光経路推薦手法 (以降 Edge Vector: EV と呼ぶ) を提案している。スポットおよび経路に関する価値や負荷すべてを辺に対する重みとして定式化することで、スポットと経路の情報を統一的に扱い、探索の過程において両者を同時に調整しながら最適経路の発見を可能としている。

本稿では EV を更に拡張し、スポット内に配置した冗長な経路を割り当てられた価値に応じて選択することによりスポットへの滞在時間をモデルする手法を提案する。提案手法により、滞在時間、途中経路を同時に決定可能となるため、柔軟な経路推薦手法が実現できる。人工データセットを用いた評価実験により、提案手法が有効に動作することを示す。

2. 辺ベクトルを用いた観光経路推薦問題の定式化と SA による近似解法

本節では EV の定式化と、同文献で用いられる近似解法について述べる。また、各用語の命名が曖昧であると考えられるものについては、対応関係を示しながら、本稿で新たに定義したものを用いて説明する。

\mathcal{N} を節点の集合、 \mathcal{E}_p を辺の全体集合とする。 \mathcal{E}_p は問題に与えられた辺 (定義辺) と後述する自己回帰辺、仮想辺 *1 を含む。辺 $e \in \mathcal{E}_p$ に対し、 $n_{st}(e)$ を e の始点、 $n_{ed}(e)$ を e の終点としたとき、これらは $\bigcup_{e \in \mathcal{E}_p} (n_{st}(e), n_{ed}(e)) = \mathcal{N}^2$ の関係を満たすものとする。

$|\mathcal{N}|$ 個の辺からなる経路を含む辺ベクトルを $\mathbf{e} := (e_i | i = 1, 2, \dots, |\mathcal{N}|)$ と定義する。 $n_{st}(e_1)$ は経路の始点、 $n_{ed}(e_{|\mathcal{N}|})$ は経路の終点であり、最適化中変化しない。辺 $e \in \mathcal{E}_p$ のうち、 $n_{st}(e) = n_{ed}(e)$ であるものを自己回帰辺と呼ぶ。辺ベクトルは自己回帰辺を含むことで、要素数を固定としながら様々な経路を表現することができる。図 1 では、定義辺を黒線で表し、輪を描いているものが自己回帰辺、青で示すものは辺ベクトルに含まれる定義辺である。この図は、節点 1, 2, 7, 8 をたどる経路の例であり、対応する辺ベクトルは $((n_{st}(e_i), n_{ed}(e_i)) | i = 1, 2, \dots, 8) = ((1, 2), (2, 7), (3, 3), (4, 4), (5, 5), (6, 6), (7, 8))$ となる。

また、この手法では、仮想辺を用いることで、2 辺の操作の

連絡先: 高間康史, 首都大学東京, 東京都日野市旭が丘 6-6,
email: ytakama@tmu.ac.jp

*1 文献 [柴田 19a] では実在辺, 自己ループ辺, 非存在辺と呼ばれる



図 1: グラフの例.

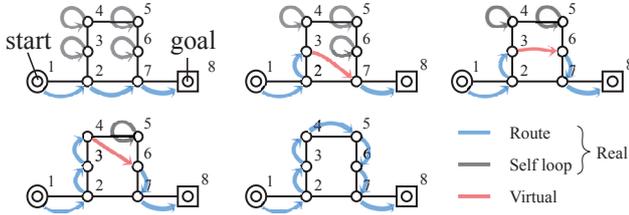


図 2: 仮想辺を用いた経路拡張の例.

みにより経路の変更をしながら探索を行う。図 2 に示す経路変更の例では、赤線により仮想辺を示している。定義辺上に乗らない仮想辺を経由することで、本来は 4 つの自己回帰辺を定義辺に変換する必要がある変化を、2 辺の置換を 4 回繰り返すことで表現している。本稿では、定義辺と自己回帰辺を合わせて実辺と呼び、その全体集合を \mathcal{E} ($\subset \mathcal{E}_p$) とする。仮想辺の集合は \mathcal{E} の補集合となる。

経路は Boltzmann 分布 [Metropolis 53] から確率的に生成されるとモデル化し、最適解を SA より近似的に求める。 \mathbf{e} の確率変数を \mathbf{e}_A 、その分布 $p(\mathbf{e}_A)$ を式 (1) により定義する。 $A = \{1, 2, \dots, |N|\}$ は辺ベクトルの各要素に対する添字の集合である。本稿において、同じ添字集合を持つ確率変数は独立同分布に従うものとする。

$$p(\mathbf{e}_A) = \frac{1}{\sum_{\mathbf{y}_A} \exp\left(-\frac{1}{kT} \phi(\mathbf{y}_A)\right)} \exp\left(-\frac{1}{kT} \phi(\mathbf{e}_A)\right) \quad (1)$$

T は温度である。また、 k は Boltzmann 定数であり、問題ごとに適切な値を設定する。 $\phi(\mathbf{e}_A)$ は目的関数であり、この値が小さくなる程、 \mathbf{e}_A の出現率が高くなり、 T が小さくなるほどこの傾向が強くなる。SA ではこの性質を用いて最適解の近似解を生成するため、目的関数の値が小さな状態が望ましい経路を表すように定式化を行う。 ϕ を式 (2) により定義する。文献 [柴田 19a] の定式化と多少異なるが、本質的には同じであり、3 節における提案手法の説明に同一の式を利用可能としている。 $\alpha_s = 0$ としたものが、EV の定式化に対応する *2。

$$\phi(\mathbf{e}_A) = F_{\text{res}} \left(\sum_{i \in A} f_c(\mathbf{e}_i) + \alpha_s \sum_{i \in A} f_s(\mathbf{e}_i) - C_c \right) - \sum_{i \in A} f_d(\mathbf{e}_i) + \alpha_a \sum_{i \in A} f_s(\mathbf{e}_i) \quad (2)$$

$f_c(e)$ は e の負荷、 $f_d(e)$ は e の価値、 $f_s(e)$ は仮想辺に対する負荷であり、式 (3) により定義される。

$$f_s(e) = f_c(e) - \sum_{s \in S(e)_{f_c}} f_c(s) \quad (3)$$

各値は辺の向きによらず、 $e \notin \mathcal{E} \Rightarrow f_c(e) = 0, f_d(e) = 0$ および $\forall e, f_d(e) < f_c(e)$ を満たすものとする。後者の条件は次

*2 文献 [柴田 19a] ではさらに f_s に対し微少な定数項を加算している等の違いがあるが、それらの影響がほぼ無いことを事前実験に確認しているため、詳細については省略する

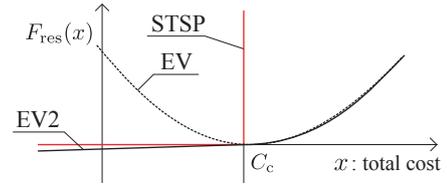


図 3: 制約関数の概形. STSP: STSP, EV: 文献 [柴田 19a], EV2: 提案手法.

の段落で説明する STSP の制約を無制限に超えた経路が生成されることを防ぐものである。 $S(e)$ ($\subset \mathcal{E}$) は辺 e の終始点を結ぶ最短経路を構成する辺の集合である。また、 $S(e) = \emptyset \Rightarrow f_s(e) = \infty$ とする。EV の定式化において、 α_a は仮想辺を消滅させるための罰則係数であり、1 以上で、仮想辺が最終的に問題なく消滅する程度に 1 に近い値を用いる。

$F_{\text{res}}: \mathbb{R} \rightarrow \mathbb{R}$ は経路負荷に対する STSP の制約を表現する関数であり、 C_c は制約値である。観光経路推薦においてこの制約値は、経路長や旅行時間に対応する。STSP, EV, 提案手法 (EV2) で用いる制約関数の概形を図 3 に示す。STSP による定式化は C_c を超える経路を認めないため、目的関数は C_c を堺に無限大の値を取る。このような目的関数を用いた最適化では、経路長が C_c 付近となる状態の近傍探索における効率が低下し、また、興味のあるスポットがあれば、多少の制約違反が許容される観光旅行において妥当なモデルとは言えない。これに対し、EV ではある程度の誤差を認め、最適化効率を向上させたいので、より現実的なモデルとしている。EV2 の持つ性質については 3 節において説明する。EV, EV2 に共通して利用する定式化を式 (4) に示す。

$$F_{\text{res}}(x) = \begin{cases} \alpha_g x + c_1 & , x < x_m \\ c_2 x^2 + c_3 x & , x_m \leq x \leq \sigma^2 \\ x + c_4 & , \sigma^2 < x \end{cases} \quad (4)$$

各設定値を、 $F'_{\text{res}}(0) = \max(\alpha_g, 0)$ 、 $c_1 = c_2 x_m^2 + c_3 x_m - \alpha_g x_m$ 、 $c_2 = (1 - c_3)/(2\sigma^2)$ 、 $c_3 = \max(\alpha_g, 0)$ 、 $x_m = (\alpha_g - c_3)/(2c_2)$ 、 $c_4 = c_2(\sigma^2)^2 + c_3\sigma^2 - \sigma^2$ と定めるとき、 $\alpha_g = -1$ において、この関数は EV のものに対応する。 σ^2 により違反の許容度合いを調節することが可能である。

SA 法において、Boltzmann 分布を近似するために Gibbs Sampling (GS) 法 [Geman 84] を用いる。経路変更を行うための最小要素は二つの辺であるため、GS 法において利用される部分空間として辺ベクトル中の 2 辺を選ぶ。この 2 辺に対する添字を i, j ($\in A$) としたとき、これら以外の添字 $A \setminus \{i, j\}$ で定義される変数により条件付けられた分布は式 (5) と書ける。

$$p(\mathbf{e}_{\{i,j\}} | \mathbf{e}_{A \setminus \{i,j\}}) = \frac{\exp\left(-\frac{1}{kT} \phi(\mathbf{e}_A)\right)}{\sum_{\mathbf{y}_{\{i,j\}}} \exp\left(-\frac{1}{kT} \phi(\mathbf{y}_{\{i,j\}}, \mathbf{e}_{A \setminus \{i,j\}})\right)} \quad (5)$$

添字 A の部分集合 M を添え字を持つ確率変数は対応する部分空間を構成し、式 (6) の性質が満たされるものとする。

$$p(\mathbf{e}_{A \setminus M}) = \sum_{\mathbf{y}_M} p(\mathbf{y}_M, \mathbf{e}_{A \setminus M}), M \subset A \quad (6)$$

ここで、 $\sum_{\mathbf{y}_M}$ は \mathbf{y}_M の状態空間についての総和を示す [Bishop 06]。この状態空間には 2-Opt 法に対応する、経路としての制約を満たすものを与える。

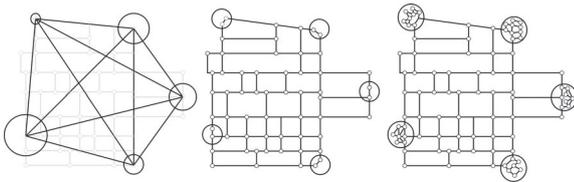


図 4: 道路ネットワークに対するモデル化. (a): STSP ベースの手法, (b): EV, (c): 提案手法のモデル化.

3. 提案手法

本稿では, EV の定式化を拡張し, スポットにおけるユーザの滞在時間と, 途中経路を同時に最適化可能な推薦手法を提案する. EV では, スポットに一つの辺を割り当て, その移動時間として滞在時間を表現しており, スポットにおける滞在時間は固定的である. しかしながらこの定式化において, 「興味のあるスポットは時間の許す限り長く滞在したい」などのような, 実際によく行われる柔軟な調整を考慮することができない. そこで本稿ではスポット内に冗長な経路を含むグラフを配置し, 辺に与える価値に応じて生成される経路を決定する手法を提案する.

図 4(a) に, STSP ベースの従来手法, (b) に EV, (c) に提案手法による定義辺配置の様子を示す. (a) のモデル化は, スポットに対応する節点への重みの一つとして固定的な滞在時間を表現する. (b) においては, スポットに対し辺を配置し, その負荷 (f_c) として滞在時間を表現している. 辺か節点かの違いはあるが, スポットに対する滞在時間が固定値となる点で (a) と同様である.

これらに対し, 経路全体を考慮して各スポットの滞在時間を柔軟に調節可能とするため, 本稿では (c) で示されるような, 冗長な経路をスポット内に配置するモデル化を提案する. スポットの滞在時間を, 「スポット内に存在する辺のうち, 経路として選択されたものが持つ負荷の総和」とみなすことで, 長い滞在時間はスポット内の冗長な経路をめぐる行動としてモデル化する. このとき, 人気のスポットや関心のあるスポット内にある辺の価値 (f_d) を高くすることで, スポット内の辺を選択されやすくなることが可能である. 滞在時間を最適化中に決定することができれば, 行きたいスポットをすべて巡っても若干の余裕がある場合に, 好きなスポットの滞在時間を長くしたり, そのほかのスポットを短時間寄り道したり, あるいは土産物店やレストランで時間を潰すといったような柔軟な経路を生成可能となる.

ここで, 提案手法で用いる目的関数 ϕ について説明する. 定式化には 2. 節でも説明したとおり式 (2) を用い, 式 (4) で定義する制約関数 F_{res} の形状には図 3 中の EV2 に該当する, $\alpha_g > 0 \wedge \alpha_g \approx 0$ と設定したものをを用いる [柴田 19b]. EV は C_c に極小値を持つ形状となっており, 訪れるべきスポットがない場合でも経路長が C_c に近づくように最適化が行われるため, 無駄な経路が生成されることから望ましい定式化ではない. これに対し EV2 は経路長に対し常に傾きが正となるため, 無駄な経路を削減するものとなっている.

α_g には, C_c 以下の経路長において, 価値がそれほど大きくないスポットを無視してしまうことがない程度に小さな値を用いる. この値は, $\min_e f_d(e)/f_d(e)$ に対し, 定義辺の与え方にのみ依存するため, 事前実験により決定することができる.

式 (2) 中のパラメータについては, 文献 [柴田 19b] に従い, $\alpha_s = 1, \alpha_a \approx 0 \wedge \alpha_a > 0$ と設定する. これにより EV に比べ

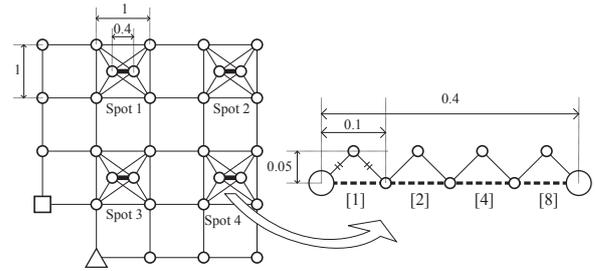


図 5: 4 つのスポットを持つ人工データセット. 太線で描かれた辺は右側のグラフに対応する. 黒破線下の [] 内の数字は各辺の f_c の値を示す. 四角は始点, 三角は終点をそれぞれ表す.

探索効率が向上し, 冗長経路の導入による問題の大規模化に対応することができる. α_a には事前実験を行い, 定義辺上を十分に探索可能である程度の微小な値を設定する.

4. 評価実験

図 5 に示す人工データセットを用い, 経路生成を行った結果を示す. このデータセットはスポット内に経路が配置され, スポット間の経路探索も含む, 提案手法が対象とするモデルに該当する. 太線で描かれた辺はスポットを示し, 図の右側にあるグラフに対応する. [] 内の数字は直上にある辺の f_c の値である. このグラフには 4 つのスポット, Spot 1, Spot 2, Spot 3, Spot 4 があり, 破線で描かれる辺 $e \in \mathcal{E}$ における f_d の値は以下のように設定する.

$$\text{Spot1: } f_d(e) = 0.8f_c(e) \quad \text{Spot2: } f_d(e) = 0.6f_c(e)$$

$$\text{Spot3: } f_d(e) = 0.4f_c(e) \quad \text{Spot4: } f_d(e) = 0.2f_c(e)$$

また, これら以外のすべての辺 e において, $f_d(e) = 0$ とし, $f_c(e)$ は図中に示す幾何学情報に基づいた距離に等しいものとする. 四角は始点, 三角は終点をそれぞれ示す. この人工データセットに対して, 制約値 (予定旅行時間) $C_c = 0.00, 0.25, 0.50, \dots, 110$ についてそれぞれ 32 回の試行を行い, 各スポットの滞在時間について平均値を求め比較する. パラメータの設定には $\alpha_s = 1, \alpha_g = 0.01, \sigma^2 = 0.1, k = 2, \alpha_a = 0.005$ を用い, 温度変化は $T(t) = 10^{-3t}$ とした. t が 10^{-5} 進むごとにサンプリングを行い, 文献 [柴田 19a] で提案されている近似的棄却サンプリングの有効範囲には $K = 16$ を用いた.

実験結果を図 6 に示す. Move はスポット間の移動時間 [-] を示す. Spot 3 が終始点に近い場所にあるため, 制約値 (予定旅行時間) C_c が小さい場合にこのスポットが優先されているが, 大きくなるにつれ, より f_d の値 (価値) の高いスポットが優先的に選択されている. また, 大きくなった C_c のあまりが生じた場合にも Spot 3 を経由する, 寄り道のような経路を生成していると言える. スポット間の移動時間は $C_c = 10, 30$ 付近など, スポットが経路に追加されるときのみ増加しており, このことから提案手法は不必要に経路を拡張しないこともわかる. これらの結果から, 提案手法では, スポット間の経路探索を行いつつ, 冗長な経路による滞在時間表現が可能であることがわかる.

5. おわりに

本稿では, 辺ベクトルによる定式化を用いた観光経路推薦手法を拡張し, スポット間の途中経路とスポットにおける滞在時

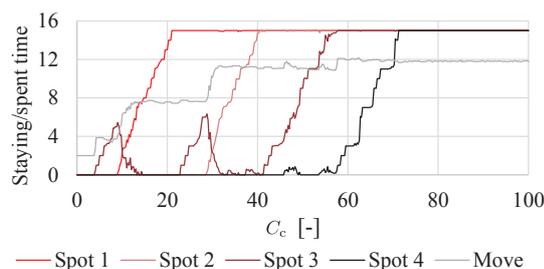


図 6: C_c の各値に対し, 人工データセットにおいて生成された経路に含まれる各スポットの滞在時間とスポット間の移動時間の総和。

間を同時に調整可能であるような, 柔軟な経路推薦手法を提案した。今後の展望として, 各スポットに対するユーザの飽きを考慮することで, 1 日程度に渡る長期間の旅行計画にも適用可能な手法に拡張することが考えられる。また, 道路ネットワークを用いた評価実験を行い, ユーザの求める旅行計画を実際に生成可能であることを検証する予定である。

謝辞

本研究は JSPS 科研費 16K12535, 15H02780 の助成および首都大学東京傾斜的研究費 (全学分) 学長裁量枠戦略的研究プロジェクト戦略的研究支援枠「ソーシャルビッグデータの分析・応用のための学術基盤の研究」によるものです。

参考文献

- [Gutin 06] Gutin, G. and Punnen, A.: The traveling salesman problem and its variations, *Springer Science & Business Media*, 2006.
- [Yannakakis 91] Yannakakis, M.: Expressing combinatorial optimization problems by linear programs, *Journal of Computer and System Sciences*, Vol. 43, No. 3, 1991.
- [柴田 19a] 柴田祐樹, 高間康史: 辺ベクトルを用いた観光経路推薦問題の定式化と焼きなまし法による解法の提案, 知能と情報, Vol. 31, No. 1, 2019.
- [Laporte 90] Laporte, G., Martello, S.: The selective travelling salesman problem, *Discrete applied mathematics*, Vol. 26, No. 2-3, pp.193-207, 1990.
- [松田 04] 松田善臣, 名嘉村盛和, 姜 東植, 宮城 隼夫: 最適観光経路問題とその解法, 電気学会論文誌 C, Vol. 124, No. 7, pp. 1507-1514, 2004.
- [Lim 17] Lim, K., Chan, J. and Karunasekera, S.: Personalized itinerary recommendation with queuing time awareness, *Proc. 40th SIGIR*, pp. 325-334, 2017.
- [Helsgaun 09] Helsgaun, K.: General k-opt submoves for the LinKernighan TSP heuristic, *Mathematical Programming Computation*, Vol. 1, No. 2-3, pp. 119-163, 2009.
- [Kirkpartrick 83] Kirkpartrick, S., Gelatte, C., Jr. and Vecchi, M.: Optimization by simulated annealing, *Science*, Vol. 220, No. 598, pp. 671-680, 1983.

[Metropolis 53] Metropolis, N., Rosenbluth, A., Rosenbluth, M. and Teller, A.: Equation of state calculations by fast computing machines, *The Journal of Chemical Physics*, Vol. 21, No. 6, pp. 1087-1092, 1953.

[Geman 84] Geman, S. and Geman, D.: Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-6, No. 6, pp. 721-741, 1984.

[Bishop 06] C. M. Bishop: Pattern recognition and machine learning, Chapter 11, *Springer*, 8th printing, 2006.

[柴田 19b] 柴田祐樹, 高間康史: 辺ベクトルを用いた経路推薦問題の解法における目的関数の改善に関する提案, 第 21 回インタラクティブ情報アクセスと可視化マイニング研究会, 2019.

[1K2-J-4] Knowledge utilization and sharing 1

Chair:Naoki Fukuda Reviewer:Jun Sugiura

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room K (201A Medium meeting room)

[1K2-J-4-01] Designing Domain Ontologies on Local Foods and Their Stories

○Ikue Kawamura¹, Shiramatsu Shun¹ (1. Nagoya Institute of Technology University)

1:20 PM - 1:40 PM

[1K2-J-4-02] Multi-Domain Knowledge Base Construction System Based on Various Data Integration

○Tomoya Yamazaki¹, Takuya Makabe¹, Kentaro Nishi¹, Chihiro Nishimoto¹, Hiroki Iwasawa¹
(1. Yahoo Japan Corporation)

1:40 PM - 2:00 PM

[1K2-J-4-03] Constructing a better Linked Data infrastructure in Life Sciences based on our experience

○Yasunori Yamamoto¹, Atsuko Yamaguchi¹ (1. Database Center for Life Science)

2:00 PM - 2:20 PM

[1K2-J-4-04] Report on the First Knowledge Graph Reasoning Challenge 2018

○Takahiro Kawamura^{1,2}, Shusaku Egami², Koutarou Tamura^{3,4}, Yasunori Hokazono⁴, Takanori Ugai⁵, Yusuke Koyanagi⁵, Fumihito Nishino⁵, Seiji Okajima⁵, Katsuhiko Murakami⁵, Kunihiro Takamatsu⁶, Aoi Sugiura⁷, Shun Shiramatsu⁸, Xiangyu Zhang⁸, Kouji Kozaki⁹ (1. Japan Science and Technology Agency, 2. University of Electro-Communications, 3. NRI digital, Ltd., 4. Nomura Research Institute, Ltd., 5. Fujitsu Laboratories Ltd., 6. Kobe Tokiwa University, 7. Kobe City Nishi-Kobe Medical Center, 8. Nagoya Institute of Technology, 9. Osaka University)

2:20 PM - 2:40 PM

[1K2-J-4-05] Reorganizing Hierarchical Category Structure of Wikipedia Based on the Parent-Child Relationship Classification

○Takanori Nakagawa¹, Yoshiaki koitabashi¹, Masaharu Yoshioka^{1,2} (1. Hokkaido University, 2. Riken AIP)

2:40 PM - 3:00 PM

郷土食とそのストーリーに関するドメインオントロジーの設計

Designing Domain Ontologies on Local Foods and Their Stories

河村郁江*¹
Ikue Kawamura

白松俊*¹
Shun Shiramatsu

*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 University

Abstract: Stories on local foods handed down is important to understand the characteristics of the regional cuisine culture. In this research, we aim to construct structured open data about detailed stories including differences of local foods in each region, and to apply it to analysis and visualization. We designed a domain ontology on local foods and that on local food stories. As a result, we found that the domain ontology on local food stories requires newly defined properties such as howToEat and produceArea. In the future, we will extend the ontology of this paper using various cases gathered in various regions, and plan to apply it to "Mochi Map" developed so far.

1. はじめに

郷土食は地域の特色を生かした食物が、それぞれの地域ごとに伝えられてきたものである。そのため、伝える人がいなくなると調理方法等の詳細が残らない場合や、似ている郷土食でも、現地の人にしかわからない微妙な差異や文脈が備わっている場合が多い。本研究では、各郷土食が伝わる地域の人の話に重要な情報が含まれると考え、郷土食の微妙な違いなどを含む、詳細な情報を保存するための郷土食オントロジーについて考察する。

2. これまでの開発

本研究では郷土食の情報を整理し、視覚化して地域理解につなげるため、「もちマップ」を開発してきた。もちマップは日本地図上にもちの位置や属性を表示することで、郷土食理解を通して地域の特性を知るためのシステムである。

2.1 もちを主題に扱う理由

本研究では、郷土食の主要な食材として、全国で食べられている「もち」を扱うこととし、今回の考察に使用した。以下に郷土食としての「もち」の特徴を述べる。

- ・ もちは郷土食の中でも全国に広く分布している
- ・ 地域ごとに様々な素材、調理法、用途がある
- ・ 歳時や年中行事に用いられてきた

このような理由から、もちは身近であり、例として分かりやすく地域や郷土食理解の一助となると考えた。

2.2 これまでの開発

【もちマップバージョン1】

もちマップバージョン1[河村16]では、もちデータを書籍[奥村03]やインターネット上の情報、および実際に人から聞いた話などを元に作成し、システムの位置や素材、および調理法などの属性を可視化することで、地域理解に役立てることを目指した。

【もちマップバージョン2】

その後、バージョン1で出た課題をふまえ、2017年に複数人によるもちデータの入力、各もちの詳細情報ページの作成を行った[河村18-1]。バージョン1ではローカルで読み込んでいたもちデータを、データベース化した。データベースの正規化を行う

際に、もちデータの語彙の検討をし、Dublin Core や Schema.org の使用を試みた。

【もちマップバージョン3】

2017年10月8,9日に開催された“実践！共通語彙基盤ワークショップ・ハッカソン”[共通語彙基盤18]において、本システムで利用しているもちデータをLinked Open Data (LOD) と呼ばれる形式のオープンデータにした[河村18-2]。

今回の郷土食オントロジーの考察はもちマップバージョン4の作成にも繋げようと考えている。

3. 人の話のオントロジー

人の話には有用な情報が多く含まれる。しかし人の話は複雑であり、これまでの研究では読むための記事としてしか利用してこなかった。そこで人に聞いた話という概念を整理し、今後データとして活用するため、話という概念と、食べ物話という視点から、プロパティを考察し、どのようなオントロジーになるかを考察した。図1は郷土食の話のオントロジー、表1はmochi:Storyクラスのプロパティ、および表2はmochi:FoodStoryクラスのプロパティである。

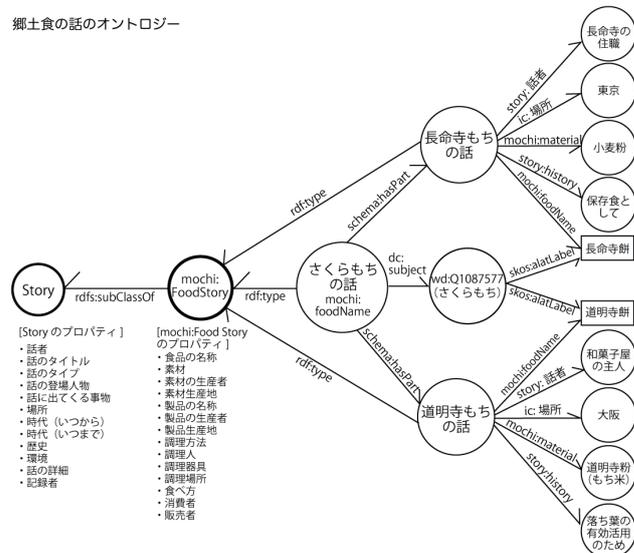


図1. 郷土食の話のオントロジー

多様なデータの統合に基づく マルチドメインナレッジベース構築システム

Multi-Domain Knowledge Base Construction System Based on Various Data Integration

山崎 朋哉*1
Tomoya Yamazaki

真壁 拓也*1
Takuya Makabe

西 賢太郎*1
Kentaro Nishi

西本 智浩*1
Chihiro Nishimoto

岩澤 宏希*1
Hiroki Iwasawa

*1 ヤフー株式会社
Yahoo Japan Corporation

Knowledge bases play crucial roles in a wide variety of information systems, such as search engines and intelligent personal assistants. For responding constantly fluctuating user information demands, we aim to construct a large-scale and well-structured multi-domain knowledge base from the world's evolving data. In this paper, we discuss enterprise-specific issues with knowledge base construction and present how to deal with these issues in our construction system. To maintain the quality of our knowledge base at the production-level, our construction system is carefully designed to incorporate various automatic and manual validation methods. We partly leverage manual validation methods to deal with business requirements and user feedback quickly since it is difficult to filter out all incorrect facts automatically in practice. Our constructed knowledge base is already utilized in real-world Japanese Web services, and the number of entities in it keeps growing steadily.

1. はじめに

近年、ナレッジベースは検索エンジンや質疑応答システムといった様々な情報システムの基盤となっている。一般的にナレッジベースには、主語 (Subject)、述語 (Predicate)、目的語 (Object) の3つ組を用いて、エンティティとそれらの関係が格納されている。本稿では、ナレッジベースに含まれる上述した3つ組のことをファクトと称する。特に商用検索エンジンでは、ユーザーのクエリに対する回答を簡潔に表示するナレッジパネル*1の表示に Google KG*2 や Satori*3 といったドメインを限定しないマルチドメインナレッジベースが活用されている。図1に「ブラックジャックによるしく」のナレッジパネルと、そのパネルの情報基となるマルチドメインナレッジベース YJKB (Yahoo! JAPAN Knowledge Base) の例を示す。YJKB は本稿で提案するシステムによって構築されたマルチドメインナレッジベースで、最も巨大な日本語のナレッジベースの1つである。ナレッジベース構築の手法は特定のドメインのナレッジベース構築システム [2] や、機械学習ベースの手法 [9] など数多く提案されており、その構築方法はナレッジベースの用途によって異なる。特に Paul ら [8] が述べているように、実サービスに使用するシステムは、継続的に高精度を保つ必要があり、アカデミックで提案されているシステムをそのまま導入することが困難であるケースが多い。

本稿では、実サービスでの品質基準を満たすマルチドメインナレッジベースの構築における課題点と、その課題点に対応したナレッジベース構築システムについて提案する。企業での品質基準を満たすナレッジベース構築の手法として、WOO [1] や Kosmix [4] が提案されている。我々の提案するシステムは、WOO や Kosmix と同じく様々な形式の巨大なデータを取り込み、1つのナレッジベースを構築することを目的としているが、以下に示す点が既存研究と比較して大きく異なる。

連絡先: 山崎朋哉, tomoyama@yahoo-corp.jp

*1 <https://support.google.com/business/answer/6331288>

*2 <https://googleblog.blogspot.com/2012/05/introducing-knowledge-graph-things-not.html>

*3 <https://blogs.bing.com/search/2013/03/21/understand-your-world-with-bing/>

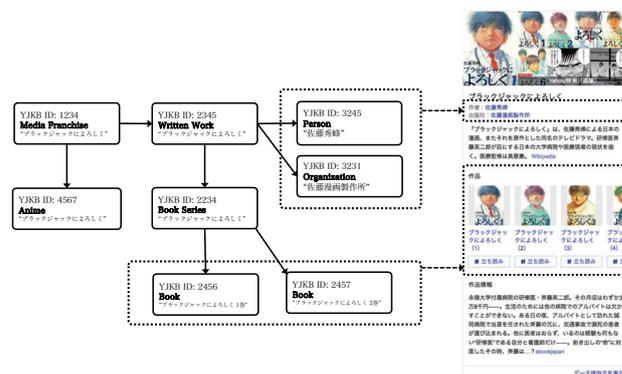


図1: 「ブラックジャックによるしく」*4 のナレッジパネルと、そのパネルを生成するためのナレッジベース (YJKB) のイメージ図

- 様々な構造化データの情報の取り込みに加えて、Web 文書といった半構造化データから情報抽出を行う機構もシステムとして取り込んでいる点
- YJKB 中の誤った情報の修正や削除のために、オントロジ等を用いた自動の方法だけでなく、人手で修正した情報を取り込む方法もシステムに取り込んでいる点

また、本稿で提案するシステムを実際に日々動作して構築した YJKB は実サービスの品質基準を満たしており、実際に日々サービスへ適用している。

本稿では、実サービスの品質基準を満たすナレッジベース構築における課題点を挙げ、その課題を解決するシステムについて提案する。また、実際に構築した YJKB の品質やインパクトについて説明する。

*4 <https://search.yahoo.co.jp/search?p=ブラックジャックによるしく> (最終閲覧日: 2019年2月8日)

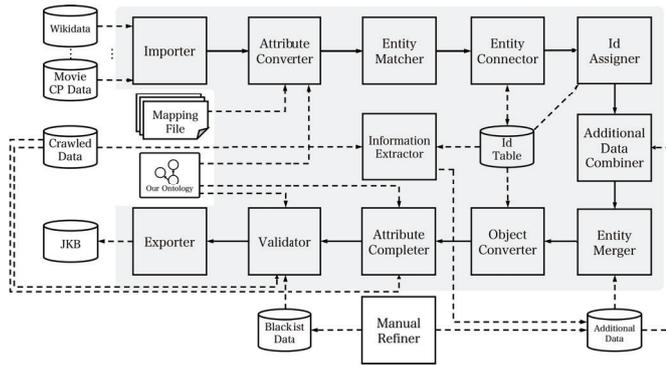


図 2: マルチドメインナレッジベース構築システム. 四角は各コンポーネントを表し, 矢印はデータの流れを表す. 点線の矢印は, システム外からのデータの移動あるいはシステム外へのデータの移動を表す.

2. マルチドメインナレッジベース構築システム

本節では, 実サービスへの品質基準を満たすシステム構築のための課題と, その課題を解決するためのナレッジベース構築システムの全体像と, 各コンポーネントの概要について説明する.

2.1 企業での品質基準を満たすための課題

ナレッジベースの構築における課題点は, 既に [1, 10] などで提案されているが, 人手の編集結果の組み込みやすさや継続的な品質維持の観点での課題点について深く言及されていない. 本稿では, 新たに 5 つの課題点を提案するとともに, 我々の提案するナレッジベース構築システムがどのようにそれらの課題点を解決しているかについて説明する.

I1: 入力データの多様性: マルチドメインのナレッジベースの構築には, 非常に多くのデータの取り込みが必要であることが知られている [3]. そのため, データフォーマットの型に依らないデータの取り込みの機構が必要である.

I2: エンティティの同一性: 同一の異なるエンティティのマッチング手法やパイプラインは [5] などで提案されている. しかし, 我々の目的は一般的な機械学習手法のように F_1 値を最大化するようなナレッジベースを構築することではなく, 精度が非常に高いことを前提とした上で, 1 エンティティの情報量を増やすことである. そのため, 高精度にエンティティをマッチングする手法が求められる.

I3: 過去のデータとの一貫性: 同じエンティティは期間を跨いで同じ ID で参照され続ける必要がある. この一貫性が保証されると, エンティティの ID を参照した編集やマッチングが可能になり, YJKB の品質向上をさらに見込むことが可能となる.

I4: 品質向上の自動化: 入力データ, 特に LOD には誤った情報が混在していることが多い. このような誤りを自動で削除や修正を行う機構や, 関連のあるエンティティ同士を自動で紐付ける機構があることで, 品質向上をスケールすることが可能となる.

I5: 人手の修正/追加情報の導入: ビジネス観点での仕様の導入や, 自動での発見が難しい誤り等を人手で修正を行うことで, YJKB を高品質に保つことが可能となる.

表 1: 入力データの比較

データソース	データ量	情報抽出の難度	更新頻度
Wikidata	30 GB	低 (JSON)	約 2 週間毎
DBpedia (日本語)	120 GB	低 (N-Triple)	約 1 年毎
Freebase	380 GB	低 (N-Triple)	2015 年 6 月 30 日に更新終了
Wikipedia (日本語)	2.6 GB	中	約 2 週間毎
社内データ	≈ 100 GB	低 (JSON, TSV, XML など)	毎日
Web からのクロールデータ	≈ 1,000 GB	高	毎日

表 2: 企業での品質基準を満たすための課題について対応を行っているコンポーネント

ナレッジベース構築の課題点	I1 多様性	I2 同一性	I3 一貫性	I4 高品質	I5 人手の導入
Importer	✓				
Entity Mather		✓		✓	
Entity Connector				✓	
ID Assigner		✓	✓		
Additional Data Combiner				✓	
Attribute Completer				✓	
Validator				✓	✓
Exporter				✓	✓
Information Extractor	✓				
Manual Refiner		✓			✓

2.2 システムの全体像

本稿で提案するナレッジベース構築システムの全体像を図 2 に示す. 複数の LOD (Wikidata, DBpedia, Freebase など) と様々なスキーマの社内データを Importer から Exporter までの 11 のコンポーネントを通じることで YJKB を構築する. また, クロールして得られた Web 文書から情報抽出を行う Information Extractor を組み込むことで, より多くのファクトを拡充する. 入力データの情報は表 1 に示す.

また, 表 2 に前節で述べた実サービスの品質基準を満たすナレッジベース構築における課題点を, どのコンポーネントで解決しているかを示す.

2.3 システムの各コンポーネントについて

Importer: 様々なスキーマのデータを YJKB のスキーマに合うようにエンティティとして取り込む. 入力データのソースやその内容に応じた信頼度を付与することで, YJKB のエンティティ中の各ファクトは信頼度を持つ.

Attribute Converter: 各入力データのクラスと YJKB で使用する我々独自のオントロジのクラスが対応付けられたマッピングファイルを入力として与えることで, 入力データのクラスを YJKB のクラスに変換する. マッピングファイルには, 例えば Wikidata の Person クラスを表す <https://www.wikidata.org/wiki/Q215627> は YJKB のオントロジ中の PERSON クラスであるという情報が記載されている. このファイルは半自動で構築することが可能である.

Entity Matcher: 同じ対象を表すエンティティをマッチングすることで, 複数のエンティティをグループ化する. 最初に, Wikipedia URL や ISBN といった ID をベースに紐付ける. このマッチングは高精度であるが, 固有の ID を持たない多くのエンティティをマッチングさせることができない問題がある. そのため, 正規化されたエンティティの名称やエンティティのクラスなどの属性値を基にマッチングを行う手法を次に適用する. エンティティの属性の種類を集합を \mathcal{A} とすると, 各エンティティは各属性毎の属性値の集合 $S = \{\{a \mid a \in A\} \mid A \in \mathcal{A}\}$ を持つ. このとき, \mathcal{A} 中の全ての属性に対して, 矛盾がないエンティティ同士をマッチングさせる. この実現のために, $S = (s_1, \dots, s_n)$ 中の各属性値集合の値の組み合わせの集合を $K = \{(k_1, \dots, k_n) \mid k_1 \in s_1, \dots, k_n \in s_n\}$ としたときに, 各

$k \in K$ が一致すればエンティティ同士を紐付ける。そうすることで、エンティティをノード、紐づけを枝とみなした時に、エンティティ同士を結ぶグラフが構成できる。このグラフの内、クリーク構造を満たすエンティティ同士をグループ化することで、ID のマッチングだけでは紐付けることのできなかった多くのエンティティのグループ化が可能となる。

Entity Connector: 異なるクラスを持ち、互いに関連するエンティティグループ同士を紐付ける。例えば、図 1 では、**Media Franchise** のエンティティと **Written Work** のエンティティが両方とも同じ「ブラックジャックによるしく」を表したエンティティであることを判別し、それらのエンティティを関連付けることで、クラスの粒度が異なるエンティティ間の関連を表すことが可能となる。

Id Assigner: 各エンティティグループに、YJKB 用の ID を紐付ける。その際過去の ID を参照するため、過去の YJKB と比較した場合でも同じエンティティは同じ ID を持つという一貫性を担保する。

Additional Data Combiner: 人手の修正結果や、後述する Information Extractor (Web 文書からの情報抽出器) から取得した情報を、YJKB の各エンティティグループに紐づける。

Entity Merger: エンティティグループに含まれるエンティティを 1 つのエンティティに統合する。その際、各エンティティの持っている信頼度が足し合わされる。この信頼度が低いエンティティは後述する Validator で除去することで、YJKB 中のエンティティの品質の高さを維持することが可能となる。

Object Converter: エンティティ中のファクトの目的語は元データソースの ID か、文字列で表記されているため、それらを YJKB 中のエンティティの ID に解決する。元データソースの ID が入っている場合は、元データソースと YJKB の ID の対応表を参照することができるが、文字列で表記されている場合は、エンティティの曖昧性を解決することで YJKB の ID に解決する。

Attribute Completer: エンティティに新たな情報を追加する。新たな情報の追加の方法として、オントロジを使用する方法を提案する。例えば、YJKB には独自のオントロジを定義しており、そのオントロジでは owl の `inverseOf`^{*5} に従った情報を追加する。これは、欠損した情報の補完を行っているため、推論に基づいた Knowledge Base Completion を行っていることに等しい。

Validator: エンティティ中の誤った情報の削除や修正を行う。例えば、オントロジを使用することで、主語と述語の組み合わせがオントロジ制約違反を起こしている場合は削除するといった自動での削除機構 [7] の他、人手で作成したブラックリストのデータに基づいて不正なデータを除去する処理を行う。また、信頼度が閾値以下の情報は削除するロジックを入れることで、YJKB の品質の高さを担保することが可能となる。

Exporter: YJKB を使用者が扱いやすいフォーマット (JSON, N-Triple) で出力する。このとき、使用するサービスに応じて、権利面などの関係から使用できない情報を削除する処理も行う。

Information Extractor: クロールされた Web 文書からの情報抽出を行い、必要な情報を YJKB に格納する。情報抽出のロジックに関する詳細は紙面の都合上省略する。

Manual Refiner: ユーザーのフィードバックや人手での品質評価によって発見した情報を基に、YJKB の品質を向上させる処理を行う。追加情報は Additional Data、削除情報は Blacklist Data としてデータベースに格納し、それらのデータを上記コンポーネントで取り入れることで、日々構築される

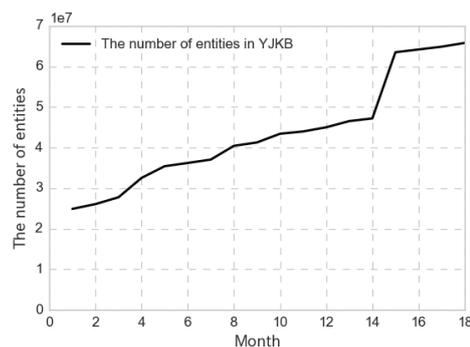


図 3: 18ヶ月間の YJKB 中のエンティティ数の推移を示すグラフ

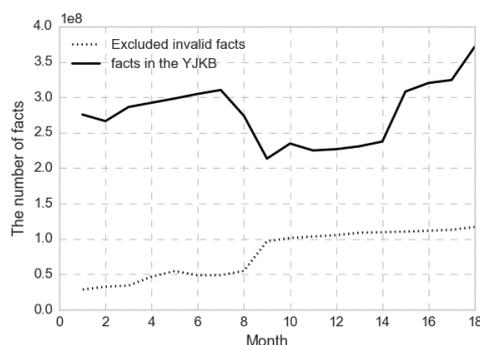


図 4: 実線は 18ヶ月間の YJKB に含まれるファクトの数、破線は Validator 等で除去されたファクトの数の推移を示すグラフ

YJKB に随時その結果を反映させることが可能となる。このコンポーネントを導入することで、I5 の課題の対応を容易にしている。

3. 実験結果

本稿で提案したシステムを Apache Spark で 18ヶ月に渡って日々実行した。その間のエンティティ数の変化は図 3 に示す。多様な入力データの増加とともに YJKB 中のエンティティ数も堅調に増加していることから、I1 で示した多様性に対応できていることが分かる。

また、エンティティ数だけでなく YJKB 中に含まれるファクトの数の推移を表 5 に示す。ファクト数がエンティティ数の増加に比例していない理由は、8ヶ月目に Validator のロジックの精度向上が行われたためである。この結果から Validator によって多くの誤りを持つファクトの自動削除が正しく行っており、I4 への対応が実現できる。具体的に削除されたファクトの主要な条件を以下に示す。

1. オントロジのクラス制約違反 (例: PERSON クラスを指す述語のファクトが、PERSON クラス以外のクラスを目的語として持つ)
2. オントロジのプロパティ制約違反 (例: ファクトの述語が Functional^{*6} の条件を満たすべきときに、その目的語がリテラル型等ではなくオブジェクト型である)

*5 <https://www.w3.org/TR/owl-ref/#inverseOf-def>

*6 <https://www.w3.org/TR/owl2-syntax/#Functional.Data.Properties>

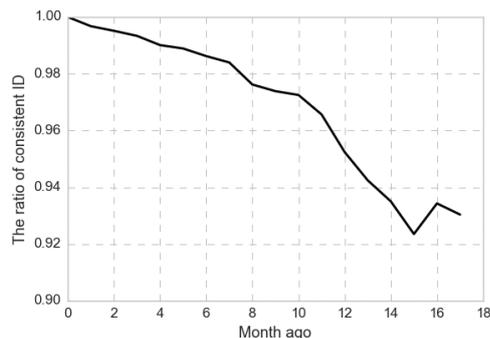


図 5: 過去データとの ID の一貫性の割合の推移を示すグラフ

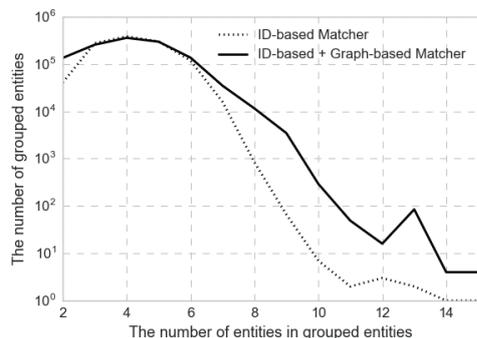


図 6: グループに含まれるエンティティの数と、そのグループの数を表す。ID の整合性によるルールベースのマッチングと、属性値を使ったグラフベースのマッチングの 2 種類の結果を示す。

3. データタイプの不整合 (例: 目的語が URL 型であるが、正しい URL 表記ではない場合や、ISBN が正しいフォーマットに則っていない場合)

上記の 3 条件はそれぞれ Validator で削除されたファクトの数の内、97.7%, 2.0%, 0.3%の割合を占める。オントロジ違反を正しく検知するためには、[6] で述べられているように網羅性のあるオントロジが必要となるため、我々が独自で定義しているオントロジが有用であることが示された。

次に、過去のデータと比較してどの程度 ID の一貫性が保たれているかを比較する。1 週間前のデータと比較したときに、YJKB の ID は 99.9996% の ID が一貫している。表 5 に、過去のデータとの YJKB の ID の一貫性の割合を比較した結果を示す。1 年間で約 5% 程度しか ID が変化しておらず、既存研究の WOO [1] が 1 週間で約 1% 弱の変化があることと比較しても ID の一貫性について頑健であることから、I3 で示した ID の一貫性の課題への対応が実現できていることを示す。

最後にエンティティのマッチング手法の結果について比較する。本稿では、2.3 章で説明した通り ID を使ったルールベースのマッチング手法と属性値を使ったグラフベースのマッチング手法を適用している。図 6 にそれぞれの手法で、同じエンティティ群に対してどの程度マッチングするエンティティ数が変わるかを示す。ルールベースだけではマッチングすることができなかったエンティティもグラフベースの手法を導入することにより、新たにマッチングしていることがわかる。また、グラフベースの手法は枝の張り方に制約を加えることで 99% 以上の

精度でのマッチングを実現する。このことから、I2 で示したエンティティの同一性の問題の対応が実現できている。

4. まとめ

本稿では、企業での品質基準を満たすマルチドメインナレッジベースの構築における課題点と、その課題点に対応するナレッジベース構築システムについて提案した。また、提案したシステムを長期間動作させて構築された YJKB の品質について調査した。

ナレッジベースの欠損情報の補完、エンティティマッチング、誤りファクトの検出の処理を機械学習等の高度な手法を企業品質基準を満たすように組み込むことが今後の課題である。

参考文献

- [1] Kedar Bellare, Carlo Curino, Ashwin Machanavajjhala, Peter Mika, Mandar Rahurkar, and Aamod Sane. WOO: A Scalable and Multi-tenant Platform for Continuous Knowledge Base Synthesis. *VLDB* 2013.
- [2] Sutanay Choudhury, Khushbu Agarwal, Sumit Purohit, Baichuan Zhang, Meg Pirrung, William Smith, and Mathew Thomas. Nous: Construction and querying of dynamic knowledge graphs. In *ICDE 2017*.
- [3] Nilesh Dalvi, Ashwin Machanavajjhala, and Bo Pang. An Analysis of Structured Data on the Web. In *VLDB 2012*.
- [4] Omkar Deshpande, Digvijay S. Lamba, Michel Tourn, Sanjib Das, Sri Subramaniam, Anand Rajaraman, Venky Hariharan, and AnHai Doan. Building, Maintaining, and Using Knowledge Bases: A Report from the Trenches. *SIGMOD* 2013.
- [5] Pradap Konda, Sanjib Das, Paul Suganthan G. C., AnHai Doan, Adel Ardalani, Jeffrey R. Ballard, Han Li, Fatemah Panahi, Haojun Zhang, Jeff Naughton, Shishir Prasad, Ganesh Krishnan, Rohit Deep, and Vijay Raghavendra. Magellan: Toward Building Entity Matching Management Systems. *VLDB* 2016.
- [6] Heiko Paulheim. Knowledge graph refinement: A survey of approaches and evaluation methods. *Semantic Web*, 8(3):489–508, 2017.
- [7] Youen Péron, Frédéric Raimbault, Gildas Ménéier, and Pierre-François Marteau. On the detection of inconsistencies in RDF data sets and their correction at ontological level. Technical report, June 2011.
- [8] G.C. Paul Suganthan, Sun Chong, K. Krishna Gayatri, Zhang Haojun, Yang Frank, Rampalli Narasimhan, Prasad Shishir, Arcaute Esteban, Krishnan Ganesh, Deep Rohit, Raghavendra Vijay, and Doan AnHai. Why Big Data Industrial Systems Need Rules and What We Can Do About It. *SIGMOD* 2015.
- [9] Sen Wu, Luke Hsiao, Xiao Cheng, Braden Hancock, Theodoros Rekatsinas, Philip Levis, and Christopher R. Foduser. Knowledge Base Construction from Richly Formatted Data. In *SIGMOD/PODS 2018*.
- [10] 市瀬 龍太郎, Kertkeidkachorn Natthawut, and 趙 麗花. 知識グラフ作成のための統合知識基盤の構築に向けて. *JSAI* 2018.

質の高い生命科学 Linked Data 利用基盤の構築に向けて

Constructing a better Linked Data infrastructure in Life Sciences based on our experience

山本泰智
Yasunori Yamamoto

山口敦子
Atsuko Yamaguchi

情報・システム研究機構
データサイエンス共同利用基盤施設
ライフサイエンス統合データベースセンター
Database Center for Life Science
Joint Support-Center for Data Science Research
Research Organization of Information and Systems

We provide Umaka-Yummy Data system to facilitate mutual understandings between Linked Data providers and consumers. Our aim is to build a better Linked Data user community in the life sciences domain. Our system monitors and evaluates each Linked Data provider in terms of six aspects by issuing a series of SPARQL queries and the other HTTP requests. Through our three-year experience of operating the system, we learned that a mutual understanding between the Linked Data providers and us is important to provide reliable monitoring results from Umaka-Yummy Data system.

1. 生命科学分野におけるデータの急増への対応

生命科学分野においては実験機器の発展や研究者の増加に伴い、得られる研究成果が大幅に増加している。これに伴い、関連情報を取りめるデータベースも増加しており、有用なデータベースを紹介する論文誌において紹介されているものだけでも1500を超えている[Rigden 2019]。このような状況において、研究者は自身の研究に関連するデータを適宜効率よく見つけることが困難な状況が発生している。関連するデータを取得するために複数のデータベースを横断的に検索する必要があることも多く、この問題に対する解決策の一つとして Resource Description Framework (RDF) を活用したデータベースが公開されつつある。RDF を採用し、生命科学分野で重要な概念である遺伝子やたんぱく質について、個々の URI を割り当てることにより、複数のデータベースから効率よく必要な情報を取得しやすくなる。また、多くの公開されている RDF データベースは当該 URI にアクセスすることで関連情報が得られるように参照解決可能としている。従って、生命科学分野における Linked Data が充実してきたといえる。また、これらのデータにアクセスできるように SPARQL エンドポイントが公開されていることも多いため、利用者は自身の開発したプログラムを利用して機械的にデータを取得することも容易になってきている。

その一方で、公開されている SPARQL エンドポイントは様々なデータ提供者が維持管理しているため、同じデータが異なる SPARQL エンドポイントから得られることもあり、一方はあまり更新がなされていなかったり、もう一方はアクセスできないことあったりなど、利用者からみて様々な原因により SPARQL エンドポイントが使いにくい状況にある。

そこで、ライフサイエンス統合データベースセンター (DBCLS) では生命科学分野において公開されている RDF データの提供サイトである SPARQL エンドポイントについて、定期的に死活確認や格納されているデータをモニターしてその結果を公開するサービス Umaka-Yummy Data を立ち上げた[Yamamoto 2018]。本サービスの目的は、RDF データを利用したい研究者が信頼

連絡先: 山本泰智, ライフサイエンス統合データベースセンター, 〒277-0871 柏市若柴 178-4-4, 04-7135-5508, yy@dbcls.rois.ac.jp

できる SPARQL エンドポイントを容易に見つけられるようにすることだけでなく、データ提供者が自身の提供するサービスの状況を確認しやすくすることであり、さらにはデータの利用者と提供者の相互理解を促し、より良い Linked Data の利用基盤を構築することにある。

Umaka-Yummy Data を正式に立ち上げてから既に3年が経ち、これまでデータの提供側からの問い合わせを受けながらシステムを改変してきた。本論文ではこれまでに得られた知見を紹介するとともに、質の高い Linked Data を提供するために必要な事項を議論することで、有益な Linked Data がより多く提供される環境の実現に貢献することを目標とする。結論としてデータ提供者側の参加が重要であり、そのために Umaka-Yummy Data が一定の役割を果たしていることが分かった。

2. Umaka-Yummy Data

Umaka-Yummy Data は毎日各 SPARQL エンドポイントに対して一連の SPARQL クエリを発行してその結果を得たり、VoID などのメタデータの有無を確認したり、CORS 対応の有無を調査したりしてそれらをデータベースに格納している。格納されたデータをもとに、各々の SPARQL エンドポイントに対する評価を 0 から 100 までの整数値で表し、Umaka Score という名前の下で公開している(図 1 参照)。Umaka Score は、6 つの評価軸のそれぞれで得られる値の平均値であり、それらの評価軸は以下の通りである。

1. 利用可能度 (Availability)
2. 新鮮度 (Freshness)
3. 利便度 (Operation)
4. 有用度 (Usefulness)
5. Linked Data 原則への対応度 (Validity)
6. 処理速度 (Performance)

これらの各評価軸の数値は以下のデータから生成している。それぞれの番号が上記の評価軸のそれに対応し、一つの評価軸の数値を得るのに複数のデータを利用している場合には、それぞれアルファベットを付けて区別している。

1. 過去 30 日間の稼働日数
2. 最終更新日



図 1 各エンドポイントのスコア一覧表示画面

3. メタデータ (SD および VoID) の提供の有無
- 4a. 広く使われているオントロジーの利用の有無
- 4b. クラス名や型指定の有無
- 4c. 他のデータセットへのリンクの有無
- 4d. コンテンツネゴシエーション利用の有無
- 5a. 参照解決な URI であるか否か
- 5b. 適切な長さの URI であるか否か
6. クエリ処理時間

現在、情報収集する対象としている SPARQL エンドポイントの数は 68 で、長時間アクセスできないエンドポイントは手動で状況を確認したうえで対象から除外している。

3. 得られた意見や改善案

これまでに Umaka-Yummy Data を運用して得られた知見に基づき、大きく分けて次の二点について議論する。すなわち、データ提供者との信頼関係の構築と、データを収集するための SPARQL クエリや HTTP リクエストの見直しである。以下、それぞれ詳細に述べる。

3.1 データ提供者からの信頼を得る

Umaka-Yummy Data は関連する SPARQL エンドポイントに対して毎日一連の SPARQL クエリやその他の HTTP リクエストを発行してデータを取得しているが、特に対象となる SPARQL エンドポイントが格納するデータの容量が大きい場合にはそれなりの負荷をかけることとなる。このため、データ提供者との信頼関係を築くことが、Umaka-Yummy Data システムが安定して有益なデータを提供し続けるために重要である。そのために以下の事項を実践している。

(1) クローラーの出自を明示する

データを取得するためのクローラーは各 SPARQL エンドポイントにアクセスするさいに、HTTP ヘッダの User-Agent の値に Umaka-Crawler という記述と、コンタクトポイントを含めている。これにより、我々のクローラーが先方のサーバーに不適切なアクセスを行っているときには、先方はアクセスログから我々を特定

し、対応できる。これは以前強い負荷をかけてしまうクエリを発行したさいに生じた一連の事案を踏まえた結果である。

(2) 得られた結果について詳細に公開する

具体的なクエリと、得られた結果を技術的に詳細に提供しているが、データ提供者側において不明と思われる現象が観測された場合に、その理由が必ずしも自明でない事例がある。このような場合には、データ提供者がシステム運用者である我々に問い合わせをし、当方にて調査する必要がある。そこで、得られた結果の再現性の有無を提供者側が確認しやすい環境を構築し、問い合わせをする前に予め問題点を把握しやすくすることが今後の課題となる。具体的には、クローラーが発行した問い合わせを再現できるようなコマンドの文字列を提示することにより、データ提供者がそれをターミナルにて貼り付けて実行可能とする仕組みを検討している。

(3) 提供者からの質問に対応する

サービスを立ち上げてからこれまでに様々な質問や意見を受けているが、当初の想定に反し、大半が筆者への個人的な問い合わせである。立ち上げ当初から我々は Linked Data の提供者と利用者との相互理解を促すことを目標としていたため、様々な形でその場を用意する計画でいた。システムのトップページから問い合わせできるフォームを設置することとどまらず、システムのソースコード一式を GitHub で公開したり、Twitter アカウントを立ち上げたりした。当初は GitHub の Issues で問い合わせがなされることもあったが、筆者との個人的な関係が構築されると、直接 Skype で問い合わせがなされるようになってきた。これは問い合わせをする側との信頼関係が築けてきた証といえるが、他により容易に質問などを行える場がないか引き続き検討する必要がある。

3.2 クエリの改善

上述の通り、Umaka-Yummy Data ではエンドポイントから取得したデータをもとに、いくつかの観点から評価し、それを分かりやすくするために数値化して Umaka Score として公開している。その中には必ずしも目的の値を取得するために最適とは言えないクエリが含まれていたため、それを見直す作業を進めている。また、評価項目の中には実際にクエリで表現する方法や得られた結果に対する解釈が明確に定義しにくいものも含まれている。そこで、引き続き本来の目的である、より良い Linked Data の利用基盤環境を実現するという見地に照らして改善していく計画である。以下に具体例を示す。

(1) クエリの最適化例

RDF データセットにおいて、クラスを示す URI が含まれている場合には、そのクラス URI に `rdfs:label` プロパティを用いた名前が付けられていると利用者が当該データセットを理解する助けとなる。このため、Umaka-Yummy Data ではそれを調査するための SPARQL クエリを発行している。

現状では、得られたクラス URI のセットに対して、FILTER と IN を用いた SPARQL クエリを発行しているが、一般的に FILTER を用いるより、VALUES を用いた方が探索範囲を狭められるため、問い合わせ内容は論理的に変わらず検索の高速化が望める。さらに、クラスの数が非常に多い場合は一つのクエリの長さが膨大になり、クエリを発行すらできない可能性もある。

そこで、クラス名を取得することと、それぞれのクラスの名前を取得することを一つのクエリに含めることでこの問題を回避する。また、予めクラス名を取得して保存しておく必要がないので、プ

ログラム全体の効率化に繋がる。具体的なクエリは以下のようになる。

```
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
SELECT DISTINCT ?class ?label
WHERE {
  GRAPH <named-graph> {
    ?class rdfs:label ?label .
    [] a ?class.
  }
}
```

(2) クエリ結果の解釈

Umaka-Yummy Data の評価項目として、コンテンツネゴシエーションへの対応の有無がある。これは次の二つの理由による。第一に、Linked Data の原則¹として、URI へのアクセスに対して、当該 URI が示す概念に関する有益な情報を返すことが望ましいとされていること、第二に、それらの情報は人にも機械にも適したものであると理想的であるから、クライアントの要求に基づき、HTML もしくは RDF (Turtle や RDF/XML など)、それぞれ別々の URL にリダイレクトさせることが望ましいとされているためである。その一方で、特にオントロジーの場合には個々の概念を表す URI には#記号を用いたハッシュ URI を用いることが多い。この場合、コンテンツネゴシエーションは行わず、RDF/XML 形式のデータが得られることが多い。

従って、コンテンツネゴシエーションに対応していることは評価軸として適切と判断できる一方、オントロジーの場合にはそれに非対応であることを理由として評価を低くすることは適当ではない。従って、アクセスする URI がハッシュ URI であるか否かで対応を変えることを検討している。

3.3 議論の場の設定

各エンドポイントについて GitHub の Issues の機能を利用した議論の場を提供しているが、これまで得られている意見や質問は、Umaka-Yummy Data への質問などと同様に、SNS を利用した筆者への個人的な連絡が多い。また、Umaka-Yummy Data のツイッターアカウントを通じた連絡も行われている。その一方で、システムを公開しているサイトにはウェブから意見や質問などを投稿できる場を提供しているが、スパムばかりで実質機能していない。

このことから、Umaka-Yummy Data システム運用者の顔の見えるコンタクトポイントが重要であり、比較的容易に、そして迅速な対応が期待できるチャンネルを用意することで、データ提供者とより良い関係を築けるといえる。

4. 結論

Umaka-Yummy Data は、各 SPARQL エンドポイントの様々な情報を定期的に取得してその結果を公開している。その目的は、データ提供者とデータ利用者との間の情報交換の場を提供することで両者の理解が深まり、より良い Linked Data 利用環境が構築できると考えているからである。現状では提供者と利用者との間の情報交換は進んでいない一方で、提供者と Umaka-Yummy Data の運用者との間の関係は深くなり、データ提供者側における問題点が比較的容易に判明する事例が増えているばかりでなく、Umaka-Yummy Data における評価方法の問題点も見つかりやすい。この状況はデータ提供者と Umaka-Yummy Data 運用者との間の Linked Data 利用環境における問題点を

共有できるという利点があるので、今後も引き続き良好な関係を保つように努めたい。そして生命科学分野における Linked Data コミュニティの発展に貢献できればと考えている。

参考文献

- [Rigden 2016] Rigden DJ, Fernández-Suárez XM: The 26th annual Nucleic Acids Research database issue and Molecular Biology Database Collection., Nucleic Acids Res., 47(D1):D1-D7, 2019.
- [Yamamoto 2018] Yamamoto Y, Yamaguchi A, Splendiani A: YummyData: providing high-quality open life science data., Database (Oxford), 2018.

¹ <https://www.w3.org/DesignIssues/LinkedData.html>

第1回ナレッジグラフ推論チャレンジ2018開催報告

～説明性のある人工知能システムを目指して～

Report on the First Knowledge Graph Reasoning Challenge 2018

- Toward the eXplainable AI System -

川村 隆浩 *1*2 Takahiro Kawamura	江上 周作 *2 Shusaku Egami	田村 光太郎 *3*4 Koutarou Tamura	外園 康智 *4 Yasunori Hokazono	鷗飼 孝典 *5 Takanori Ugai
小柳 佑介 *5 Yusuke Koyanagi	西野 文人 *5 Fumihito Nishino	岡嶋 成司 *5 Seiji Okajima	村上 勝彦 *5 Katsuhiko Murakami	高松 邦彦 *6 Kunihiko Takamatsu
杉浦 あおい *7 Aoi Sugiura	白松 俊 *8 Shun Shiramatsu	張 翔宇 *8 Shawn Zhang	古崎 晃司 *9 Kouji Kozaki	

*1 科学技術振興機構 Japan Science and Technology Agency	*2 電気通信大学 University of Electro-Communications	*3 NRI デジタル NRI digital, Ltd.
*4 野村総合研究所 Nomura Research Institute, Ltd.	*5 富士通研究所 Fujitsu Laboratories Ltd.	*6 神戸常盤大学 Kobe Tokiwa University
*7 神戸市立西神戸医療センター Kobe City Nishi-Kobe Medical Center	*8 名古屋工業大学 Nagoya Institute of Technology	*9 大阪大学 Osaka University

New challenges for knowledge graph reasoning started in Japan in 2018. Machine learning techniques have promoted applying systems containing AI to a wide variety of social systems. The explanation for the AI decision is becoming important to guarantee the security and safety of such AI systems to a certain extent. Therefore, the Special Interest Group on Semantic Web and Ontology of JSAI organized this challenge, which calls for techniques for reasoning and/or estimating criminals with a reasonable explanation based on an open knowledge graph representing a well-known novel of Sherlock Holmes. This paper describes a summary report of the first challenge, including the knowledge graph constructed for this task, approaches proposed for reasoning and/or estimating, and the evaluation metrics. Finally, we conclude this paper with the plans and issues for the next challenge in 2019.

1. チャレンジ開催の背景と目的

近い将来、さまざまな社会システムに AI 技術が組み込まれるようになることが期待される。いずれは人の手を離れてシステム自身に決定的な判断を任せられるようになるだろう。しかし、安全・安心に社会の中で AI を活用していくためには、AI によるシステムが正しく動作しているかを確認する必要がある。だが、深層学習などの機械学習技術は判断や予測のプロセスがブラックボックスであり、結論に至った理由を人間は理解できていない。そのため、AI システムが結論に至った理由を説明できる性質、説明性 (explainability) または解釈性 (interpretability) を有する AI 技術が注目されている。また、現在の AI 技術は機械学習的アプローチが主であるが、今後は帰納的な機械学習と演繹的な知識活用を融合した形の AI 技術が必要になると考えられる。しかし現状、帰納的な機械学習技術と演繹的な知識活用技術を適切に評価するためのデータセットは存在しない。推論・推定技術を用いて解釈可能な AI を実現するためのタスクに適したデータセットとしては、現実社会を反映したより複雑な、例えば時間的、因果関係的、確率的関係性を含んでいることが必要である。そこで、本会セマンティック Web とオントロジー (SWO) 研究会では、説明性、解釈性を有する AI 技術、特に帰納的な機械学習 (推定) と演繹的な知識活用 (推論) を融合した AI 技術の開発に向けたチャレンジの開催を決定した [川村 18]。本チャレンジは、(1) 推

論・推定技術共通の評価セットとして、現実の社会問題や人間関係など複雑で構造的な関係性を含んだ大規模ナレッジグラフを構築し、(2) オープンサイエンスの一環としてそれらを公開した上で、幅広く IT 技術者から推論・推定に関する手法を結集し、説明性、解釈性に関する適切な指標を設計した上で、客観的な評価、分類、体系化を行うことを目的としている。

なお、本チャレンジで構築したナレッジグラフ、応募作品、その他関連資料は公式サイト *1 に掲載されている。

2. ナレッジグラフの構築

1 回目となった 2018 年度は、シャーロック・ホームズの短編推理小説 *2 「まだらのひも」を題材とし、事件や背景、人物像を知識化したナレッジグラフで与えられる情報に基づいて事件の犯人を正しく突き止め、その理由 (証拠やトリックなど) を適切に説明するタスクとした。推理小説とした理由は、

- 現実社会の複雑な関係性を含みながら仮想的にクローズな (答えがあり、それに至る制約を制御できる) タスクを設計できる、
- タスクによっては不確実情報や証拠写真など確率的な処理や機械学習を入れないと解けなかったり、陽に書かれていない常識知識を補完しなくては解けない等、推定と推論の融合を促せる、

連絡先: 川村 隆浩, 国立研究開発法人科学技術振興機構, takahiro.kawamura(at)jst.go.jp

*1 <http://challenge.knowledge-graph.jp>

*2 <https://ja.wikipedia.org/wiki/Category:シャーロック・ホームズシリーズの短編小説>

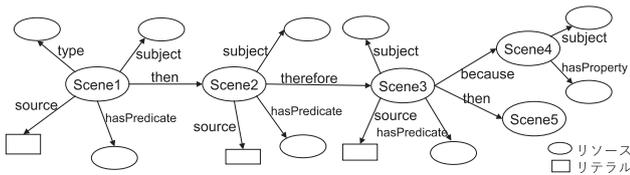


図 1: ナレツジグラフのイメージ

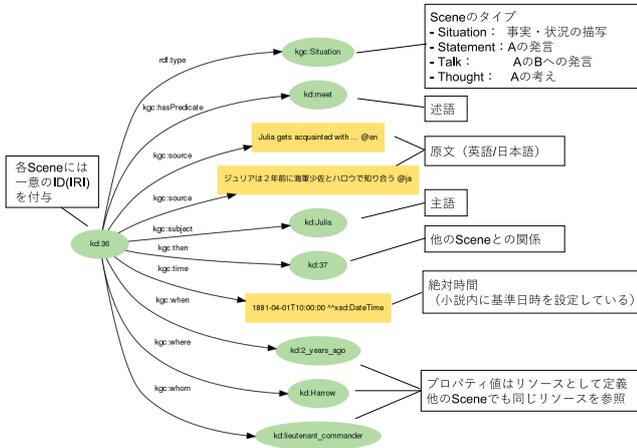


図 2: シーンの記述例

- 読者が納得しないと小説として成立しないという人間に対する説明性を有している,
- 小説が広く一般に知られており関心を引きやすい,

ことなどが挙げられる。

2.1 ナレツジグラフスキーマの詳細

ナレツジグラフのスキーマとしては一連の内容を最小単位の場面(シーン)に分割し、各シーンの記述内容、およびシーン間の関係をグラフ化する形とした。図 1 にナレツジグラフの全体イメージを示す。

また、各シーンの記述に用いる基本的なプロパティとして以下を用意した。シーンに付随する情報をまとめるため、シーン ID を主語としたプロパティとなっており、一般的な <subject, predicate, object> の形式ではないことに注意が必要である。図 2 にシーンの記述例を示す。

- subject: その場面の記述において主語となる人やもの
- hasPredicate: その場面の内容を表す述語
- hasProperty: 主語となる人やもののもつ性質
- 場面の詳細を表す目的語: whom (誰に), where (どこで), when (いつ), what (何を), how (どのように) など
- 場面間の関係: then, if, because など
- time: その場面が起こった絶対時間 (xsd:DateTime)
- source: その場面の原文 (英語/日本語のリテラル)

ナレツジグラフは、研究データのオープン化に向けて世界的に広く用いられている Resource Description Framework (RDF) で記述されており、グラフ DB に対する標準的なクエリー言語 SPARQL にて検索可能である。

3. 推論・推定技術への取り組み

この問題に対して独自性に富んだ 8 件の取り組み(実装を伴う応募が 5 件, アイデアのみの応募が 3 件)が提案された。以下、受賞作品を中心に 4 つの取り組みを簡単に紹介する。各

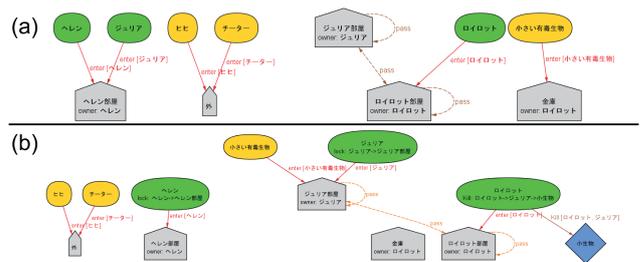


図 3: ジュリア殺害の日における整合解のうちの一つ。犯行当日の (a) 夜と (b) 深夜。小さい有毒生物が夜の段階でロイロット部屋内にいるのか、金庫内にいるのかは情報がなく特定できないため、解が一意に定まらない。

作品の詳細については、前述の公式サイトの結果発表ページを参照してほしい。

3.1 野村総合研究所の取り組み

犯行状況を数理的に記述するために、本文だけでは欠損している知識の補完を、関係性データの解析で行い、成立可能な状況の探索は SAT 問題に落とし込むことを考えた。

本手法で大きく貢献した方法については次の通りである。詳細なスクリプトや条件設定は、公式サイトの結果発表ページに掲載の資料を参照してほしい。

まず、テンソル解析による知識補完では、主語・述語・目的語の SVO 形式 (SVOO は 2 つの SVO に分解) の 3 軸とし、Tucker 分解によって補完した。補完された知識には、ジュリアに対して Animal が何らかの行為を行ったとの知識が出現した。数少ないジュリアを対象とする行動の情報として有力と判断した。

次に、所与の文章を述語論理式に書き直した。場面に共通する登場主体、殺人方法、建物/所在に関する情報を述語論理式として表し、場面「ジュリア殺害の日」、「ヘレン殺害未遂の日」における人物や状況を事実として、犯行状況の可能性を SAT 問題の解として列挙を行った (図 3)。

ジュリア殺害の日、ヘレンへの殺害未遂の日、どちらの場面でもロイロットが犯人として示される。複数の殺害方法の選択肢から、密室であり、外傷や薬物反応がないという事実から、小さい有毒生物が関与していた可能性が残った。また登場人物が、屋敷のなかをくまなく見回るが、当該生物の存在を認識していないことから犯行時や通常時の当該生物の所在は、ロイロットの部屋や金庫内であることも SAT 問題の解として導かれた。

本チャレンジでは、テンソル解析では知識補完を、SAT 問題では整合する状況の探索を試みた。すべての可能な範囲を探索することは非現実的で、人の手で注目する軸や範囲を規定しなければならないという点で、テンソルに 3 軸を与えたことや、SAT 問題でメソッドや限量子を与えたことは、本質的にはフレーム定義とフレーム選定であり、等価であると考えられる。

今回、SAT 問題のアプローチによって説明力を確保し、機械的な推論を行うことを試みた。論理式や事実にも重みをつけて解く Partial Weighted SAT 等に拡張することや、解空間を狭める探索方法を進化計算等で行うことで、論理式(法則)の補完というアルゴリズムの高度化を、SAT 問題の枠組みで行えるようにすることが今後の課題である。我々が今回 SAT 問題解法を利用したことによって、解釈性の高い人工知能・機械学習の基礎技術への探求の一助となることを期待する。

尚、今回の解析には CCG2lambda と AlloyAnalyzer が貢献した。

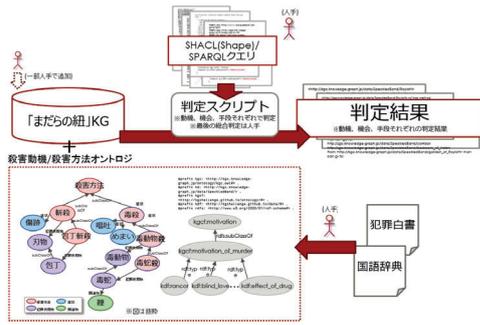


図 4: 全体構成 (上小田中 411)

3.2 富士通研究所 (上小田中 411) の取り組み

3.2.1 全体構成と作成したオントロジー

【全体構成】上小田中 411 チームは動機，機会，方法のそれぞれを持つ人物を推論することで犯人を探し出そうと考えた。

図 4 の様に殺害の動機，方法を示すオントロジーを作成し，提供されたナレッジグラフに追加し，それぞれを判定するスクリプトを適用した。それぞれの判定結果から，最後の総合判定は人手で行った。

【作成したオントロジー】犯人を推理するためには，証拠を積み重ね，犯罪に関連する知識と照らし合わせ，分析を行なう。この今回は a) 動機の分析，b) 機会の分析，c) 手段の分析の 3 つについて知識と推論規則を記述した。犯行の動機については，犯罪白書に犯罪の動機の統計があり，主にそこから列挙した。犯罪の動機の関連情報としてのエージェント間関係は，遺産相続を記述するという観点から The Agent Relationship Ontology に基づいて記述した。手段に関しては，殺人手段を国語辞典の「殺」の後方一致をベースに殺し方を列挙した。またそれぞれの殺し方に対して，国語辞典の語義をベースに手段，供用物などの属性ごとに分離して，詳細を記述した。

3.2.2 動機，機会，方法を持つ人の判定

【動機】殺人の動機を持ってもおかしくない状況かつ対象が明確であれば殺害の動機を持つとし，殺人動機が生じる状況から，該当する人物を推論する規則を作成した。処理系の実行により，1) ロイロットは金欲のためにジュリアとヘレンを 2) 村人は自己防衛のためにロイロットを 3) ヘレンは自己防衛のためにロイロットを殺す可能性がある。という結果を得た。

【機会】事件当夜，ジュリアの部屋に移動可能な場所にいた人物は機会があるとし，事件当時の各々の居場所を推論した。時間のつながりを推論する部分と，空間のつながりを推論する部分に分けた。

事件発生時の登場人物の場所は，事件発生時と同じ時刻を持つシーンの情報を取得し，事件発生以降であることが推論されるシーンを除いた。この推論により事件が起こった時，ジュリア，ヘレン，ロイロットはそれぞれの寝室にいて，ロマは庭にいたと推論された。

次に接続されている空間の繋がりを列挙し，人が通れない繋がりを記述し，差し引いて残ったものを人が移動できる繋がりと推論した。その結果，それぞれの場所からジュリアの寝室に人が通っていくことはできなかつたと推論された。

【方法】事件当夜の被害者や現場の様子から殺害方法を絞り込む部分と，絞り込まれた殺害方法を実行するために必要な条件を満たす人物を導出する部分を記述した。殺害方法を絞り込む部分により，殺害方法は毒殺であり，理由となる症状は「めまい」「青白い」「傷跡が無い」と推論された。人物を導出する部分から，ロイロットに「毒蛇殺」と「毒動物殺」が実行可能であると推論された。その両方とも理由は，鞭がロイロットの部

屋にあったことであった。

3.2.3 総合判定と今後の課題

【総合判定】前節の判定をまとめると，総合的には，本事件はロイロットが金欲のために，毒蛇を用いて，ジュリアを殺したと推論した。

【今後の課題】今回犯人探しに用いた方法は，殺人事件一般に適用可能であると考えている。ただし，オントロジーは，すべての殺害動機や殺害方法について記述したわけではないので，これを充実させることは今後の課題となる。また今回は総合判定を人手で行ったがこれを機械的に判定することも今後の課題である。

3.3 富士通研究所 (FLL-ML) の取り組み

FLL-ML チームは，検索や推論を利用した手法との比較や併用可能性の検討を目的として，機械学習を利用した犯人の予測とその理由の説明に取り組んだ。

犯人の予測のために，「まだらのひも」以外のシャーロックホームズシリーズの短編に出現する登場人物について，対応する単語ベクトルを特徴として“犯人”，“被害者”，“その他”の分類モデルを学習し，「まだらのひも」の登場人物に適用した。モデルの学習には，「まだらのひも」のナレッジグラフに加えて，青空文庫に収録されているホームズの 22 の短編から生成した 14,619 の「単語区切り文」，「登場人物の一覧」および「犯人・被害者の一覧」の 3 種類のリソースを利用した。

また，犯人と判断した理由の説明として，犯人と意味的に近い文の中から，動機・手段を示す文を提示した。動機・手段文の分類には，「まだらのひも」以外の短編に“動機”，“手段”，“その他”のタグ付けを 2,930 文行い，そのデータから学習したモデルを用いた。その際，文の特徴として，文中に出現する単語と対応する単語ベクトルの平均（文ベクトル）を利用した。犯人と文の意味的な近さは，犯人と対応する単語ベクトルと文ベクトル間の距離とした。動機・手段文出力の際には，犯人に近い文から動機・手段スコアの上位の文をそれぞれ 30 件ずつ提示し，目視によって動機・手段を示す文を判断し，ラベリングを行った。

予測の結果，犯人スコアが最も高い登場人物はロイロットとなり，次点はヘレンであった。ロイロットを犯人とした場合，被害者はジュリアと予測された。犯行の動機は，痲癩あるいは金銭問題であると推定され，犯行手段は特定できなかった。表 1 は動機を示す文として抽出されたものの一例である。

表 1: 抽出された動機文の例

動機	根拠文
痲癩	あるとき，家内で窃盗事件が立て続けに起こりまして，かんしゃくを起こし，現地で雇った執事を殴り殺してしまったそうです
金銭	ただ数エーカーの土地と，築二〇〇年にもなる屋敷だけは残りましたが，それも抵当に入っている始末でございます

犯人の予測結果は，「まだらのひも」の一般的な解釈と相違なかつた。犯行動機については，痲癩と金銭問題が抽出されているが，ロイロットの犯行は計画的なものであるため，痲癩は誤りであった。しかしながら，今回の推論チャレンジで，動機として痲癩を考慮したチームは他になく，知識として網羅することが難しい事柄を，事例を元に粗く捉えることができる点は，学習を用いる利点と言える。一方で，本手法のような単純な文の提示では，「まだらのひも」の犯行手段のような複雑な手続きは説明できないため，手続きを説明するためのデータの

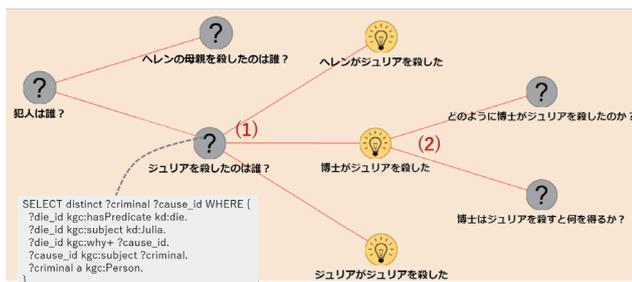


図 5: 誰が犯人か議論するための IBIS 構造

構築および予測結果との対応付けについて検討していく必要があるだろう。

3.4 名古屋工業大学の取り組み

複数のエージェントに誰が犯人か議論させ、構造化された議論のログを使って説明を出力するというアイデアを紹介する。多くの推理小説では探偵役だけでなく、誤った推理を披露する助手役（「サイドキック」等と呼ばれる）を登場させ、複数の仮説について議論する場面が入る。このような場面により、読者が事件の背景や推理の過程を解釈しやすくなる効果があると考えられる。このことから、複数の仮説について自動的に議論させることで、解釈可能性の高い推論過程が実現できると考えた。具体的には、以下のように複数の議論エージェントが意見を戦わせ、IBIS (Issue-based Information System) という構造を用いて「まだらのひも」の真相を推理するというアイデアである。

- 提供されているナレッジグラフに現れる登場人物 x ごとに「 x が犯人」という仮説を立て (図 5(1)), その仮説の説明を試みる議論エージェントを割り当てる。
- ファシリテータエージェントが各議論エージェントに仮説の詳細を質問し (図 5(2)), 各議論エージェントはその質問の答えとなる仮説を生成する。
- 生成された仮説を表す RDF トリプルは、各議論エージェントが保持するナレッジグラフを補完すべく追加される。
- ファシリテータエージェントは各議論エージェントが生成した説明の尤もらしさや整合性を評価し、最終的に評価の高かった説明が出力される。

このような着想に至った背景に、自律的ファシリテータエージェントの研究 [池田 18] がある。IBIS (Issue-based Information System) と呼ばれる議論構造で Web 上の議論を理解し、ファシリテートする研究である。この研究の新しい方向性として、議論参加者にも自律的エージェントが混ざり、人間の参加者が出した意見を補完するような仮説を生成・提示できれば、議論支援に繋がる可能性がある。その題材として、ナレッジグラフ推論チャレンジに挑戦した。なお、本アイデアは未実装であり、仮説をどのようなアルゴリズムによって生成するのは今後の課題である。

4. 評価方法

1 回目となる本チャレンジでは、基本情報の共有の後、専門家評価、一般評価の組み合わせで評価を実施した。但し、評価方法については今後も改善を続けていく予定である。今回、審査員は SWO 研究会の幹事を中心に 7 名に委託した。

専門家による評価では、以下の項目について 1 週間以上の時間を掛けて審査員に評価していただいた。いずれも 5 段階評価 (1-5) である。

- 技術性 (Significance)
- 汎用性 (Applicability)
- 発展性 (Expansibility)
- 知識・データ構築の工夫
- 知識・データ活用の工夫
- 実現可能性 (アイデアのみ)
- 論理的説明性
- 努力性
- 総合的なコメント (自由記述)

一般審査では時間的な制約から説明の心理的な側面 (納得性) に絞って評価を実施した。参加者 45 名が以下の 2 点についてアンケートに答える形で審査を行った。いずれも 5 段階評価 (1-5, 但し, 0.5 刻み) とした。

- 総合評価
- 説明性

一般審査の結果については、平均値では総合評価と説明性いずれも 1 位が 2 位を上回っているが、中央値では総合評価は上回っているが説明性では同値となり、標準偏差では総合評価と説明性いずれも 1 位のほうが大きいという結果となった。一方、専門家による評価で両者を比較すると、各指標の平均では 1 位が 2 位を上回っているが、説明性の観点では逆転した結果が得られた。

そのため、1 位と 2 位の順位付けは専門家審査員による議論に任せられる形となったが、説明性以外の観点ではいずれも 1 位は 2 位と同値、または上回っていたことから今回の結果を決定した。同時に、本チャレンジの一番の課題である説明込みで推論・推定技術の評価する点については、今後の課題となった。尚、その他に各専門家のコメント等を踏まえてベストリソース賞とアイデア賞を授与した。

5. まとめと今後の課題

本論では、説明性、解釈性を有する AI 技術の深耕を目的に開催した第 1 回ナレッジグラフ推論チャレンジ 2018 について報告した。2019 年度も推理小説を対象に、タスクの難易度や傾向を変えながら計 5 編の短編小説からなるナレッジグラフを構築し、2 回目のチャレンジを開催する。更に、推理小説以外にも現実の社会問題や研究データも対象としていきたい。具体的には、社会問題解決に関するベストプラクティス集などを検討している。培われた推論・推定技術を実際の研究課題・社会問題に関するナレッジグラフ等に適用し、説明性を有する AI 技術の社会実装に繋げたい。更に、国際イベント化し、日本初の学術的な問題設定として普及させていくことも検討している。

謝辞

本チャレンジ開催にあたりまして、これまでに開催されたワークショップ、勉強会、発表会、報告会等、各イベントへの参加者の皆様に感謝申し上げます。

参考文献

- [川村 18] 川村 隆浩, 江上 周作, 長野 伸一, 大向 一輝, 森田 武史, 山本 泰智, 古崎 晃司: 第 1 回ナレッジグラフ推論チャレンジ 2018, 第 32 回人工知能学会全国大会論文集, 1F1-01 (2018)
- [池田 18] 池田 雄斗, 白松 俊, 伊藤 孝行, 神谷 晃, 内藤 勝太, 芳野 魁, 鈴木 祥太: Web 議論の自動ファシリテーションのための事前知識を用いた質問生成手法, 人工知能学会 第 83 回言語・音声理解と対話処理研究会, SIG-SLUD-B801-05 (2018)

カテゴリの親子関係の種類に基づく Wikipedia カテゴリの再整理

Reorganizing Hierarchical Category Structure of Wikipedia Based on the Parent-Child Relationship Classification

中川嵩教^{*1} 小板橋佳晃^{*1} 吉岡真治^{*1*2}
 Takanori Nakagawa Yoshiaki Koitabashi Masaharu Yoshioka

^{*1}北海道大学 ^{*2}理研 AIP
 Hokkaido University RIKEN AIP

Wikipedia is a largest online encyclopedia that covers varieties of topics using structured documents (e.g., infobox for describing metadata, and classification using Wikipedia category). There are several efforts to extract structured knowledge, such as DBpedia, YAGO2, and Japanese Wikipedia ontology. However, there is no research that try to analyze whole Wikipedia category hierarchical structure. To tackle this problem, we have been working on the project to reorganize Wikipedia category hierarchical structure for knowledge engineers and proposed classification of parent-child relationships (e.g., class-subclass and class-instance) in the Wikipedia category hierarchy. In this paper, we discuss effectiveness of this classification results for Japanese Wikipedia category hierarchy by analyzing the characteristics of reorganized category hierarchies that are constructed by selecting (or removing) particular types of relationship.

1. はじめに

Wikipedia^{*1} は世界最大のインターネット百科事典であり、その特徴として、ページ、インフォボックス、カテゴリといった構造化がなされている。このように構造化された情報を用いて、DBpedia[Bizer 09] では、ページの情報に関するメタデータの抽出や、カテゴリ階層をオントロジーの構築に利用する YAGO2[Hoffart 13] や、日本語 Wikipedia オントロジーの研究 [玉川 10] などが行われている。しかし、確かに Wikipedia カテゴリには、概念階層としてみなせる階層が存在するものの、単純な包含関係ではない階層関係が存在し、単純に Wikipedia カテゴリの階層全てを概念階層として扱うと不都合が生じるため、既存の研究 [Hoffart 13, 玉川 10] では、アドホックに、その一部のみを利用して来た。この問題に対し、Wikipedia カテゴリを分析する研究 [Yoshioka 14, 藤原 12] から、カテゴリには概念分類を表すものだけでなく、人名や組織名といったインスタンスを表すものやその組み合わせが存在しているために、知識工学的観点から利用するためには、そのカテゴリ間の関係について検討することが必要であることが提案された [中川 18]。また、この考え方に基づき、カテゴリの種類、カテゴリの親子関係の種類を整理したデータの構築を行った [中川 19]。本稿では、この構築したデータに基づき、特定の親子関係のみを利用して (あるいは、排除して) できあがるカテゴリ階層構造の性質を議論することで、これまでに提案してきた Wikipedia カテゴリに関する分類の枠組の有用性について議論する。

2. Wikipedia カテゴリ

2.1 Wikipedia カテゴリの階層構造

Wikipedia において、カテゴリとは、膨大な記事群を様々な観点から分類するための索引であり、各記事には、それぞれに一つ以上のカテゴリが付与される。また、このカテゴリは、さ

らに詳細なカテゴリと関連付けることにより、カテゴリは階層的な構造となっている。このカテゴリ階層については、基本的には、下位カテゴリに属する記事は、上位カテゴリの性質も含むという包含関係が成立することが期待される。よってカテゴリ階層は、知識工学で用いられる概念階層と似た性質を持つことが期待されている。しかし、このカテゴリ階層の構造は、Wikipedia に登録される記事の増加に伴い、既存の階層の中に便宜上のカテゴリが作られ、それにより、必ずしも、包含関係が成り立たない形でカテゴリ階層が作られるようになっている。次小節では、包含関係に注目した際に注意すべきであるカテゴリの種類について述べていく。

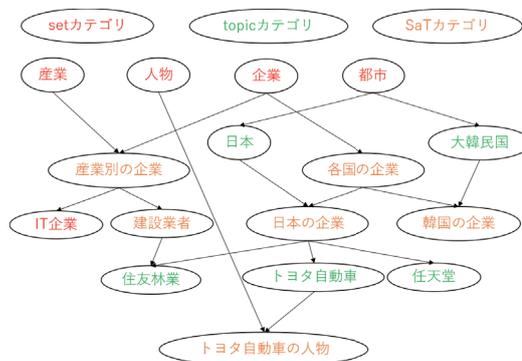


図 1: 分割のためのカテゴリによるカテゴリ分割

2.2 カテゴリの種類

Wikipedia カテゴリは、ページを分類する基準であり、「企業」、「人物」といった概念の種類を表すようなカテゴリだけでなく、「日本」「トヨタ自動車」といった具体的な事象を表すようなカテゴリが存在する。英語版 Wikipedia では、前者を set カテゴリ、後者を topic カテゴリと読んでいる。また、Wikipedia では、一つのカテゴリに大量のページが所属するとそのリストを閲覧することが困難になることから、このようなカテゴリは、様々な基準により、より詳細なカテゴリに分割することが求められている。この時できあがるカテゴリの多く

連絡先: 中川嵩教, 北海道大学工学部情報エレクトロニクス学科, 札幌市北区北 14 条西 9 丁目, 011-706-7161, f-b-hawk78@eis.hokudai.ac.jp

*1 <https://www.wikipedia.org/>

は、前述の Set と Topic の組合わせであることから、このようなカテゴリは、Set-and-Topic(SaT) カテゴリと呼ばれている。例えば、図 1 の例ではオレンジ色の「日本の企業」「産業別の企業」などが SaT カテゴリに該当する。

3. Wikipedia カテゴリと階層関係の分類

[中川 19] では、Wikipedia カテゴリを概念の種類を表すようなカテゴリを set、具体的な事象を表すようなカテゴリを topic、そして、SaT カテゴリの中で、set を構成要素として持ち、set の性質を持つ制約付き set を CS カテゴリ (ConstrainedSet カテゴリ) とし、全てのカテゴリをこの 3 種類に分類した。また、カテゴリの繋がりを包含関係の観点から以下のように分類した。

- 「制約詳細化」: CS → CS である set 部分を共通として topic が詳細化される関係である。例としては「アジアの企業」→「日本の企業」などである。制約付加と同じように set 部分は変わらないので包含関係は満たされる。
- 「クラス-サブクラス」: set 部分を見たときに、同じではないが、概念としては同じとなるような関係である。set → set 関係の「作家」→「著作家」のようなものや、CS → CS 関係の「日本の企業」→「日本の多国籍企業」のような、topic 部分がないまたは共通として、set 部分がクラス-サブクラスとなっている関係が主だが、「SF 作品」→「未来を題材とした作品」や、「日本のクラブに所属するサッカー選手」→「ベガルタ仙台の選手」のように、set 部分だけを見ると逆転が起きているが全体を見るとクラス-サブクラスとなっているような関係も一定数存在した。概念としては同じということで、この関係においても包含関係は満たされる。
- 「クラス付加」: あるカテゴリに新たな set が付け加わり CS となる関係である。多くは「トヨタ自動車」→「トヨタ自動車の人物」のように topic に set が付け加わる関係が多いが、「アニメ」→「アニメに関する企業」や「歴史の人物」→「歴史の人物を題材とした作品」のように、set 部分の後ろに新たな set が付け加わり、概念が変わってしまう set → CS 関係や CS → CS 関係も存在した。この関係においては上位カテゴリ (topic ならその上位カテゴリ) と下位カテゴリの間では概念が異なるため、包含関係は満たされない。
- 「Instance of」: 「格闘技漫画」→「北斗の拳」や「日本の国公立大学」→「北海道大学」といった、下位カテゴリが上位カテゴリの概念の具体例となるような関係である。
- 「topic 包含関係」: 「イギリス」→「イングランド」地理的な包含関係があるものが存在する他、「AKB48」→「前田敦子」のようなメンバー関係など、概念の記述はないが、topic 同士で包含関係があるような関係である。

上記に当てはまらないものは例外としてあり、例として、「日本」→「日本関連一覧」のような一覧を表示させるためのカテゴリや、「スポーツ施設」→「スポーツ施設の画像」のような画像を表示させるためのカテゴリなど、Wikipedia 特有と思えるカテゴリ名を含む関係や、歴史や二国間関係等、サブクラスやインスタンスを広く取るものが挙げられていた。

4. Wikipedia カテゴリの再整理

構築した Wikipedia カテゴリならびにカテゴリの親子関係の分類の有用性を検討するために、次の 2 つの観点からの分析を行った。

● 循環構造に関する検討

Wikipedia カテゴリの階層構造が、親子関係の包含関係 (子カテゴリに属するページは親カテゴリにも属する) を前提としているのであれば、カテゴリ階層に循環構造 (子カテゴリをたどっていくと、親カテゴリに戻る) が存在してはいけないことになるが、現実には、このような構造が Wikipedia には存在する。前節で提案した親子関係の分類には、必ずしも、包含関係が成り立たない関係が含まれていたため、包含関係が成り立つ関係に限定した際に、循環構造の数がどのように変化するかを分析する。

● クラス階層の分析

Wikipedia のカテゴリは、概念分類が同じであっても、その制約が詳細になっていくことによって、カテゴリの段数が増えていく (「日本の?」→「北海道の?」→「札幌市の?」)。しかし、これらは、本来、一つ概念分類に属するカテゴリを分割していくことでつくられたカテゴリ階層であり、概念分類という意味では、同一に扱うという考えもある。このような分割のためのカテゴリの影響を除いて、純粋にクラス-サブクラスの概念階層にのみ注目した場合に、できあがる階層について分析する。

4.1 循環構造に関する検討

循環構造は、Wikipedia カテゴリの親子関係を有向グラフとして考えたときの強連結成分として、抽出することができる。今回構築にしようとした Wikipedia カテゴリの階層構造に対して、強連結成分の抽出アルゴリズムを適用したところ、58 件の循環構造が見つかった。

このカテゴリ階層には、「ロンドン」→(クラス付加)→「ロンドンの地方自治」→(Instance of)→「グレーター・ロンドン」→(topic 包含関係)→「ロンドン」といった、必ずしも包含関係が保証されないようなクラス付加といった関係を含んでいるものや「東芝」→(その他)→「東芝グループ」のように、「その他」として分類されている分類不十分なインスタンス間の関係を含むものが存在した。

これらの問題に対し、本研究で提案している分類のうち、包含関係が成り立つと考えている「制約詳細化」、「クラス-サブクラス」に限定して再構築した Wikipedia カテゴリ階層に限定することで、多くの循環構造については、その循環がなくなり、6 件の構造のみが残った。

この 6 件に含まれているものは、「系譜学」→(クラス-サブクラス)→「系図」→(クラス-サブクラス)→「系譜学」のように関係を付け直した方が良いと思われる関係と「中国の鉄道路線」→(制約詳細化)→「中華人民共和国の鉄道路線」→(制約詳細化)→「中国の鉄道路線」のように、個別に見たときに、どちらの制約が詳細なのかがはっきりしないために、両方向ともに詳細化とつけてしまったものが存在した。後者については、2019 年 2 月 8 日現在の Wikipedia カテゴリ上では、「中華人民共和国の鉄道路線」→「中国の鉄道路線」の関係が削除されている。

4.2 クラス階層の分析

トップのカテゴリから、子カテゴリを持たないカテゴリまでの最短経路を深さとする、まず、カテゴリ階層全体を見た

際の深さは、最大で 12、平均は 4.7 となっている (表 1)。「都市」→「各国の都市」→「ヨーロッパの都市」→「イタリアの都市」→{「ナポリ」、「ローマ」、「ミラノ」、...} のような概念の分割が行われてから、最終的に topic カテゴリが 4,5 階層目で横並びになるため、平均はこのような値となっている。概念の種類 (set カテゴリと CS の set 部分) としては 17,026 種類あり、その中で、上記例の「都市」のように、制約の詳細化が多く起こったり、多種類の制約が付くことにより、複数回現れる概念 (10 件以上のもの) は 3,350 種類存在した。一番多いのは「人物」であり 45,514 件のカテゴリが存在し、Wikipedia カテゴリが、詳細化やトピックにより膨大になっており、クラス階層としては規模の大きくないことが伺える。次に、概念が同じものはひとまとまりとして数える。具体的には、包含関係が満たされない「クラス付加」「Instance of」「その他」の関係を迎らず (今回は簡易化するために「topic 包含関係」も迎らないとした)、かつ、「制約詳細化」の関係のときは深さを増やさないとし、深さを数える。上記例をとると、「都市」から「イタリアの都市」まで、全て概念「都市」の 1 階層となる。その結果、深さは最大で 9、平均で 3.5 となった。更にその中から、同じ深さにある同じ概念をまとめると深さは最大で 6、平均 2.5 となった (表 2)。「Instance of」等の関係を迎っていないため、topic カテゴリが抜けていることで全体のカテゴリ数は少なくなっている。また、上記のように、一部の概念は、「各国」→「ヨーロッパ」→「イタリア」のように、そこに付く制約の詳細化により分割され、深さが大きくなっているが、同じ概念のものをまとめ、最短経路をとると小さい階層としてまとめられることがわかる。深さが大きいものは、「リオデジャネイロオリンピック選手団」→「リオデジャネイロオリンピック日本選手団」のような CS と set の中間的なカテゴリを含む階層が含まれていた。現在これらはどちらも set となっていてクラス-サブクラスの関係に当たるが、「リオデジャネイロオリンピック (の) 日本 (の) 選手団」と考え「選手団」の階層としてひとまとまりに考えると、階層の深さは小さくなることが考えられる。

4.3 考察

分析の結果から分かるように、カテゴリの種類とその関係を整理することで、まず、殆どの循環構造が解消された。残ってしまったものの中で、「～学」のような学問に関するカテゴリは、歴史や二国間関係等と同じようにサブクラスやインスタンスを広く取るように思われたので、改めて分類する必要があると考えた。その他循環構造が残る階層関係に関しては概念階層としては使わないとするのが良いと考えている。また、Wikipedia カテゴリ階層は様々なカテゴリが複雑に繋がりがっている構造に思えるが、概念に付けられた制約が詳細化されていることにより深さが増し、トピックにより異なる概念が繋がりがっているように見えていて、クラス-サブクラスに限定してクラス階層をみると、深さの小さい概念階層のような階層が存在していることが分かった。

5. まとめ

本研究では、整理されたデータを用いて Wikipedia カテゴリの再整理を行い、循環構造に関する検討とクラス階層の分析から、これまでに提案してきた Wikipedia カテゴリに関する分類の枠組の有用性について議論した。分類について不十分な部分も見つかったが、概ね目的としていた階層を作ることができるデータができていたことが本研究により明らかとなった。分類されたデータを複数人からのチェックを受け、洗練し

ていくことで、カテゴリ階層も目的としていたものにより近づくことを期待している。

参考文献

- [Bizer 09] Bizer, C., Lehmann, J., Kobilarov, G., Auer, S., Becker, C., Cyganiak, R., and Hellmann, S.: DBpedia - A crystallization point for the Web of Data, *Web Semantics: Science, Services and Agents on the World Wide Web*, Vol. 7, No. 3, pp. 154 – 165 (2009)
- [Hoffart 13] Hoffart, J., Suchanek, F. M., Berberich, K., and Weikum, G.: YAGO2: A spatially and temporally enhanced knowledge base from Wikipedia, *Artificial Intelligence*, Vol. 194, No. 0, pp. 28 – 61 (2013)
- [Yoshioka 14] Yoshioka, M.: Analysis of Japanese Wikipedia Category for Constructing Wikipedia Ontology and Semantic Similarity Measure, in *Information Retrieval Technology 10th Asia Information Retrieval Societies Conference, AIRS 2014, Kuching, Malaysia, December 3-5, 2014 Proceedings*, pp. 470–481, Springer-Verlag GmbH (2014), LNCS8870
- [玉川 10] 玉川 奨, 桜井 慎弥, 手島 拓也, 森田 武史, 和泉 憲明, 山口 高平?F 日本語 Wikipedia からの大規模オントロジー学習, *人工知能学会論文誌*, Vol. 25, No. 5, pp. 623–636 (2010)
- [中川 18] 中川 嵩教, 吉岡 真治?F 知識工学者のための日本語 Wikipedia のカテゴリ階層構造の再整理, *人工知能学会全国大会論文集*, Vol. JSAI2018, pp. 2F402–2F402 (2018)
- [中川 19] 中川 嵩教, 小坂橋 佳晃, 吉岡 真治?FWikipedia カテゴリの構成要素に注目したカテゴリ階層の分析 (2019)
- [藤原 12] 藤原 嵩大, 吉岡 真治?FWikipedia の階層関係を分析するためのカテゴリパターンの提案, *2012 年度人工知能学会全国大会 (第 26 回) 論文集* (2012), CD-ROM 2C1-NFC2-4

表 1: カテゴリ全体での深さ

深さ	カテゴリ数	例
0	9	人間、総記、社会
1	210	宇宙、工学、地名、人名
2	25,102	音楽、人工生命、亜鉛、経済学
3	13,449	林学、医師、亜鉛の化合物、バイオテクノロジー
4	45,724	アジアの環境、日本の食品、2017年の地震、有毒植物
5	57,215	イタリアの博物学者、タイの河川、日本の海鮮料理
6	38,438	イタリア語のオペラ、協奏曲、日本の石橋、北海道の放送
7	18,812	北海道の警察署、明治大学、E-girls、王貞治
8	2,767	北海道のサッカーチーム、青森県の銀行、日本の男子プロゴルファー
9	232	イヌ科、北海道の社会人野球チーム、日本のプロ野球選手
10	55	コトドリ科、福島県ヒメオオ生息地、大森氏
11	40	オウチョウ科、ウグイス科、カラス科
12	1	ヨシキリ科

表 2: クラス階層の深さ

深さ	カテゴリ数	例
0	9	人間、総記、社会
1	351	法、教育、人物、企業
2	2,105	親族法、学校、医師、空港、サービス業
3	2,007	婚姻・離婚法、内科医、私立学校、スキー選手
4	439	婚姻法、リサーチ会社、電車、アイスダンス選手
5	49	リオデジャネイロオリンピック選手団、旧制高等学校、密閉式ドームスタジアム
6	11	リオデジャネイロオリンピック日本選手団、高等工業学校

[1K3-J-4] Knowledge utilization and sharing 2

Chair:Takahiro Kawamura Reviewer:Koji Kozaki

Tue. Jun 4, 2019 3:20 PM - 5:00 PM Room K (201A Medium meeting room)

[1K3-J-4-01] Knowledge-Structuring by using an Ontology and Procedural Knowledge in Guitar Performance Knowledge

○Nami Iino^{1,2,3}, Takuichi Nishimura¹, Ken Fukuda¹, Hideaki Takeda^{4,2} (1. National Institute of Advanced Industrial Science and Technology, 2. SOKENDAI (Graduate University for Advanced Studies), 3. RIKEN (Institute of Physical and Chemical Research), 4. National Institute of Informatics)

3:20 PM - 3:40 PM

[1K3-J-4-02] TurkScanner: Predicting the Hourly Wage of Previously Unseen Microtasks

○Susumu Saito¹, Chun-Wei Chiang², Saiph Savage², Teppei Nakano¹, Tetsunori Kobayashi¹, Jeffrey Bigham³ (1. Waseda University, 2. West Virginia University, 3. Carnegie Mellon University)

3:40 PM - 4:00 PM

[1K3-J-4-03] The Representation Extraction for Emerging Research Fields Using an Embedding Method for Heterogeneous Networks

○Masanao Ochi¹, Masanori Shiro², Jun'ichiro Mori¹, Kimitaka Asatani¹, Ichiro Sakata¹ (1. The University of Tokyo, 2. National Institute of Advanced Industrial Science and Technology)

4:00 PM - 4:20 PM

[1K3-J-4-04] Summarization of Discussion Document based on Abstract argumentation semantics

○Kei Nishina¹, Katsumi Nitta² (1. Tokyo Institute of Technology, 2. National Institute of Advanced Industrial Science and Technology)

4:20 PM - 4:40 PM

[1K3-J-4-05] Identifying Affiliation Impacts on Innovation Enhancement

○Takahiro Miura¹, Kimitaka Asatani¹, Ichiro Sakata¹ (1. Department of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo)

4:40 PM - 5:00 PM

ギター奏法知識におけるオントロジーと手続き的知識の併用による 知識の構造化

Knowledge-Structuring by using an Ontology and Procedural Knowledge in Guitar Performance Knowledge

飯野 なみ^{*1,2,3} 西村 拓一^{*1} 福田賢一郎^{*1} 武田 英明^{*2,4}
Nami Iino Takuichi Nishimura Ken Fukuda Hideaki Takeda

^{*1} 産業技術総合研究所

National Institute of Advanced Industrial Science and Technology

総合研究大学院大学

SOKENDAI (Graduate University for Advanced Studies)

理化学研究所

RIKEN (Institute of Physical and Chemical Research)

国立情報学研究所

National Institute of Informatics

This paper discusses the knowledge-structuring an ontology and procedural knowledge in guitar performance knowledge. We have attempted to collect and systematize the on-site knowledge on musical instrument performance for playing support. We focused on classical guitar which requires many techniques, and developed the Guitar Rendition Ontology. However, the knowledge is complicated, making it difficult to understand for domain experts. In this study, we designed a process for knowledge-structuring by using Guitar Rendition Ontology and procedural knowledge, and clarified the requirements and technologies look for in ontology experts and domain experts. In addition, we confirmed the usefulness of the process by questionnaire to domain experts.

1. はじめに

社会活動の多様化に伴い、専門分野の知識の適切な理解が、求められている。人工知能における知識工学の分野ではこの要請に答えるべく多くの領域オントロジーが構築されている。領域オントロジーは、分野の専門家の能力を拡張するだけでなく、横断的な利活用によって広範な知識の理解が可能となる。それは、社会活動の参画を促進し、生産性を高めることに繋がる。

しかしながら、領域オントロジーを構築するためにはいくつかの問題が存在する。まず、オントロジーを専門としない人にも理解可能な形式で提示するための方法が必要である。オントロジーの妥当性を検証するためには、分野の専門家の介入が望まれる[Andrea 17]。また、領域オントロジーはその分野の発展などによって定期的な知識の改良が必要であることから、オントロジーの専門家と分野の専門家を繋ぐためのワークフローの設計や、知識を容易に抽出し構築できる基盤作りが求められる。

我々は社会活動の一つである楽器演奏に着目し、現場の知識を収集・体系化している。中でも、奏法が多いとされるクラシックギターの知識を取り上げて知識工学的アプローチによる指導・学習支援を目指している。我々が構築した“ギター奏法オントロジー”は、クラシックギターの奏法を主とした概念体系であり、各奏法の行為を詳細に記述している[Iino 19]。しかし、この記述形式は複雑であるため分野の専門家が理解し難く、直感的に理解できる表現枠組みが必要である。

楽器演奏のような人間の活動を記述する形式として、手続き的知識がある。手続き的知識の記述には、どのように知識に基

づいて処理を行ったのかを客観的に理解することが重要である。CHARM (Convincing Human Action Rationalized Model) は、目的を明示的に記述しそのための代替方式を提示する人間行動モデルであり[Nishimura 13]、看護教育において実践的に適用された実績を持っている[西村 15]。このような分野の専門家にとって理解しやすい目的指向のモデルを活用し、領域オントロジーと連携することができれば、人間可読と機械可読の双方の向上に寄与すると考えられる。

そこで本稿では、ギター演奏に関する知識の構築におけるオントロジーと手続き的知識の併用による知識の構造化プロセスについて考察する。まず、領域オントロジーの拡張や質の向上に向けてオントロジーの専門家と分野の専門家が取り組むための要件や技術などを明確にする。そして、ギター奏法オントロジーに基づき目的指向で構造化された手続き的知識の改良を行った結果から、併用による効果や有用性について議論する。

以下、2 節ではギター奏法オントロジーの概要と問題点について述べる。3 節では知識の構造化プロセスの設計と現在の取り組みについて述べ、4 節でまとめと今後の展望について述べる。

2. ギター奏法オントロジーとその課題

2.1 ギター奏法オントロジー

領域オントロジーの“領域”や記述レベルは様々であるが、本研究ではギター奏法オントロジー¹を取り上げる。

ギター奏法オントロジーは、クラシックギターの奏法を主として、96 の概念と 18 の属性から構成されている。概念は、「ギター奏

連絡先: 飯野なみ, 産業技術総合研究所, 〒135-0064 東京都江東区青海 2-4-7 臨海副都心センター, nami-iino@aist.go.jp

¹ <https://github.com/guitar-san/Guitar-Rendition-Ontology>

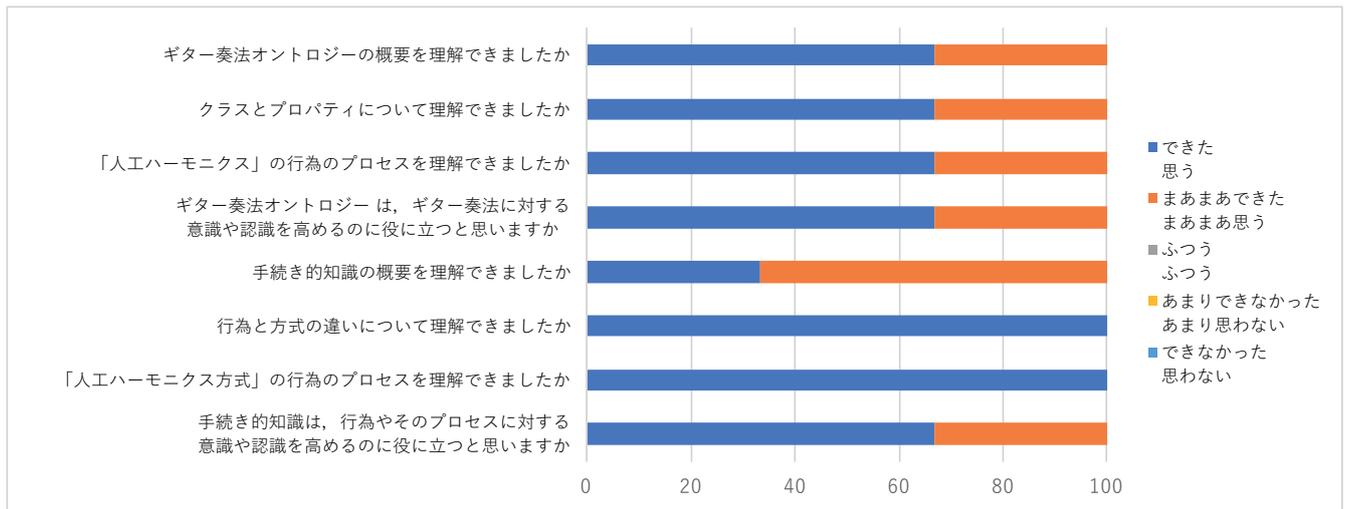


図 4 アンケート調査の結果の一部

のをギター奏法(技法)とし、ギター奏法オントロジーと対応させた。また、CHARMの基本となる構成要素は、行為に付随する凡例、実行する人、追加情報、やり方、であるが、本研究では行為以外の項目は自由に定義した。図3に構造化した手続きの知識の一部を示す。構成要素においては、様々な領域オントロジーに応じてカスタマイズできることが望ましい。また、ギター奏法オントロジーを提示するために、OWL_{Ax}を用いて可視化した。OWL_{Ax}は、オントロジー構築ツールであるProtégéのプラグインとして開発され、作成した図から公理を自動的に生成することができる[Kamruzzaman 16]。

手続きの知識を改良した結果として、多くの知識が改良された。ギター奏法オントロジーの主行為と条件行為に見られるような行為の同時性に関して、記述形式の問題点や改良方法についての知見が得られた。さらに、ギター奏法オントロジーと手続きの知識の理解度と有用性についてアンケート調査を行ったところ、全体的に好意的な回答が得られた(図4)。最も複雑な行為を必要とする人工ハーモニクス奏法に関する質問では、手続きの知識の方がギター奏法オントロジーよりも理解度の評価が高かった。アンケート調査の自由記述でも、実施者全員から手続きの知識の方が理解し易いという回答を得た。有用性については、手続きの知識とギター奏法オントロジーの詳細な記述によってギター奏法の理解が深まったことが確認された。

4. まとめ

本稿では、領域オントロジーにおける課題解決に向けて、ギター奏法オントロジーを取り上げて手続きの知識の併用による知識の構造化プロセスについて考察した。今回の取り組みにより、オントロジーの専門家と分野の専門家が取り組むための要件や技術を明確にすることができた。またギター奏法オントロジーと併用して手続きの知識を構造化することで、分野の専門家の深い理解につながったことが分かった。今後は、構築した領域オントロジーと手続きの知識の連携システムの構築に取り組む。それによって、異なる構造を持つ知識体系に対しての横断的な利用が期待できる。

謝辞

本研究の一部は JST 未来社会創造事業 JPMJMI18C9 の支援を受けたものである。

参考文献

- [Andrea 17] Andrea Westerinen and Rebecca Tauber: Ontology development by domain experts (without using the “O” word), *Applied Ontology*, 12, pp.299–311, 2017.
- [Kamruzzaman 16] Kamruzzaman, SMd, Krisnathi, A, Hitzler, P: OWL_{Ax}: A Protégé Plugin to Support Ontology Axiomatization through Diagramming, 15th International Semantic Web Conference (ISWC), 2016.
- [Iino 17] Iino, N., Nishimura, S., Fukuda, K., Watanabe, K., Kristina, J., Nishimura, T.: Development and use of an Activity Model based on Structured Knowledge – A music teaching support system –, *IEEE International Conference on Data Mining(ICDM), The 5th International Workshop on the Market of Data (MoDAT)*, 2017.
- [Iino 19] Iino, N., Nishimura, S., Nishimura, T., Fukuda, K., Takeda, H.: The Guitar Rendition Ontology for Teaching and Learning Support, *IEEE 13th International Conference on Semantic Computing (ICSC)*, 2019.
- [Nishimura 13] Nishimura, S., Kitamura, Y., Sasajima, M., Williamson, A., Kinoshita, C., Hirao, A., Hattori, K., and Mizoguchi, R.: CHARM as Activity Model to Share Knowledge and Transmit Procedural Knowledge and its Application to Nursing Guidelines Integration, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol.17, No.2, pp.208–220, 2013.
- [笹嶋 12] 笹嶋宗彦, 西村悟史, 来村徳信, ウィリアムソン彰子, 木下智香子, 服部兼敏, 溝口理一郎: 看護手順知識の習得を支援するタブレット型ツール CHARM Pad の試作, 第 27 回セマンティックウェブとオントロジー研究会, SIG-SWO-A1201-06, 2012.
- [西村 15] 西村悟史, 笹嶋宗彦, 来村徳信, 中村明美, 高橋弘枝, 平尾明美, 服部兼敏, 溝口理一郎: 目的指向の看護手順学習に向けた複数観点からの知識閲覧システム CHARM Pad と新人看護師研修への実践的活用, *人工知能学会論文誌*, Vol.30, No.1, pp.22–36, 2015.

TurkScanner: マイクロタスクの時給推定

TurkScanner: Predicting the Hourly Wage of Previously Unseen Microtasks

齋藤 奨^{*1} Chun-Wei Chiang^{*2} Saiph Savage^{*2} 中野 鐵兵^{*1} 小林 哲則^{*1}
Susumu Saito Tepppei Nakano Tetsunori KobayashiJeffrey P. Bigham^{*3}^{*1}早稲田大学 ^{*2}West Virginia University ^{*3}Carnegie Mellon University
Waseda University

In crowd markets, workers struggle to earn adequate wages by accurately gauging hourly wage of microtasks that they have not completed before. This paper explores how we might be able to predict the necessary working time (and thus hourly wage) of a previously unseen task based on data collected from prior workers completing other tasks. We collected 9,155 data records using a web browser extension, installed by 84 Amazon Mechanical Turk workers, and explore the challenge of accurately recording working time both automatically and by asking workers. Our predictive model, TurkScanner, was created using ~150 derived features and was able to predict working time with high accuracy. Future directions include observing its effects on work practices, adapting it to a requester tool for better price setting, and predicting other elements of work (*e.g.*, acceptance likelihood, worker task preference, etc.)

1. はじめに

クラウドソーシングにおけるマイクロタスクの作業時間推定による時給計算手法を設計・評価し、Amazon Mechanical Turk で収集したマイクロタスクの 84.3%において 100%以内誤差の時給予測精度を達成した。

マイクロタスク型クラウドソーシングにおいて、金銭報酬を主な動機とするクラウドワーカーの多くが十分な賃金を獲得できていないことが問題視されている [Irani 13]。主な理由の一つとして、ワーカーへ提示されるマイクロタスク情報の少なさが挙げられる。一般に、ワーカーが仕事を探す際は、公開されたマイクロタスクのリストから自身の好きなものを選ぶことができる。しかし、ここでワーカーに対し開示される情報は、短いタスク説明文やサンプル UI のみの限られた情報である場合が多い。そのため、これらを基に見積もったタスクの所要時間とリクエストが任意に定めた報酬額とを照らし合わせながら「割の良い」タスクを探して適切に選択することは、多くのワーカーにとって困難である。

こうした問題を受け、近年の研究において最適なタスクを選択する支援を行う取り組みが行われている。Amazon Mechanical Turk のワーカーの作業履歴からタスク滞在時間に基づき時給を計算し可視化する Crowd-Workers [Callison-Burch 14] や、賃金の獲得効率を最適化したタスク作業のスケジューリングを行う TurkBench [Hanrahan 15] などが提案されている。これらは「割の良い」タスク選択の支援に効果的である一方、いずれも過去行われたことのあるタスクに対してのみ有効であり、初めて投稿されたタスクに適用できないという共通点がある。

プラットフォーム上では絶えず新しいマイクロタスクが生成され続けているため、未知なタスクであっても時給が推定可能となることが重要である。経験歴の長いワーカーは、フォーラムサイトでの情報交換やプラグインの使用によって人気のリクエストのタスクを素早く選択するスキルを持っており [Kaplan & Saito 18]、明らかに優れたタスクはすぐに無くなってしまふ。そのため、未知のマイクロタスクにおける時間

的な情報をワーカーへ新たに提供し、より良いタスク選択を支援可能となることが極めて重要である。

本論文では、他のワーカーによる他のマイクロタスクの作業情報からマイクロタスクの作業時間を推定し、そこからタスク時給を計算するシステム TurkScanner を提案する。TurkScanner の構築において対処した技術課題は 2 つ存在する。一つ目は、タスク作業時間の正解データの収集である。ワーカーはタスク作業中にしばしば外部サイト閲覧や休憩などの様々な振る舞いをするため、一つ一つのタスクの実働時間を計測することは困難であることが知られている [Bederson 11]。これに対し本研究では、複数の計測方法（自動 ×2 種類、手動 ×2 種類）により収集した作業時間候補の中から、最終的なラベルの決定をワーカーに委ねる方法をとった。これにより、信頼性の保証は完全ではないものの、マイクロタスクごとに作業時間を検出することが可能となる。この手法を基にデータ収集用のウェブブラウザ拡張機能を独自に設計・実装し、それをインストールした 84 人の Amazon Mechanical Turk のワーカーが最大 10 日間で観測した合計 9,155 タスク作業レコードについて、各種タスク情報・リクエスト情報・ワーカー情報および作業時間ラベルのデータを収集した。二つ目は、収集したデータをもとにしたマイクロタスク作業時間（および時給）の推定である。Gradient Boosting Decision Tree (GBDT) [Friedman 01] により構築したタスク作業時間推定器の出力結果と報酬設定額からタスク時給の推定を行う検証実験の結果、TurkScanner は全テストデータの 69.9%において 75%以内の誤差率、84.3%において 100%以内の誤差率の推定精度を達成した。

2. 提案手法

TurkScanner では、まず機械学習によりマイクロタスクの完了に必要な時間（作業時間）を推定し、その後マイクロタスクに設定された報酬額から時給を計算する。本節では、まず最初にデータ収集における作業時間の計測アプローチについて述べ、次にデータ収集用ウェブブラウザ拡張機能の設計について述べる。その後収集データの分析結果を示したあと、最後に作業時間および時給を計算する TurkScanner の設計について述べる。

2.1 作業時間の計測

マイクロタスクの作業時間を正しく計測することは容易ではない [Bederson 11]. これはタスク作業中におけるワーカーの振る舞いの多様性に起因する。ワーカーは作業中、タスクの一環として外部サイトの閲覧や検索エンジンの利用など、ページを一時的に離れての仕事や依頼される場合がある。一方で、無関係なウェブサイトの閲覧やコンピュータを離れての休憩など作業を中断する場合や、複数の異なるタスクを並行して行うこともある。したがって、こうしたワーカーのあらゆる振る舞いを考慮し、それぞれに費やした時間を作業時間として計上するか否かを都度適切に判断しながら自動的にデータ収集を可能とする仕組みを構築する必要がある。

そこで、以下それぞれ異なる長所・短所を持つ4つのヒューリスティックな方法(自動計測1・2, 手動計測1・2)によって同時に作業時間の計測を行い、最終的にワーカー自身に最も妥当なものを選ばせることで、多様な場面において正確な作業時間をラベル付けする方法を設計した。自動計測1は、ワーカーがマイクロタスクを開始してから完了するまでの時間をプログラムにより計測する。この方法ではワーカーが何にも干渉されずにタスクを遂行した場合に最も正確な時間の計測が可能だが、途中で別タブにおける無関係な作業(他のタスクの同時作業やEメールチェックなど)が行われた場合などには正しい計測が行われない。自動計測2では、ワーカーがマイクロタスクを完了するまでにページ上にフォーカスを持っていた時間のみを計測する。これにより別タブにおける他の作業での時間の除外が可能だが、仕事の一環として外部サイトへワーカーを誘導するマイクロタスク(ウェブ検索タスクなど)も一部存在し、そうしたタスクでの正確な時間の計測が難しい。手動計測1では、作業時間計測状態のOn/Off切り替えを行うボタンをワーカーに使用させ、自ら作業時間に当たる時間を計測させる。この方法により、開発者が予期せぬいかなる例外においてもそれが作業時間に含まれるかどうかの適切な判断がワーカー自身によって可能であるが、人間であるワーカーが必ずボタン操作を行う保証をすることは極めて難しい。手動計測2では、上記3つのうちいずれもワーカーが正しくないと判断した時、自らに時間を手入力させることで作業時間を決定する。

以上の候補の中から選ばれる最終ラベルに関して、いくつかの仮説を立てた。まず、最も選ばれる候補は手動計測1であるとする。大半のワーカーは様々な理由から外部のページを閲覧したり、途中で席を一時離れたりすることを頻繁に行い、その時は自らの行動に基づいて適切に計測ボタンのOn/Offを切り替えることで正確な時間を記録できると考えた。次に、2番目に選ばれやすい候補として自動計測1を挙げた。これは、タスクを開いてからすぐに作業を開始し、かつ途中で休憩を挟まず完了したタスクにおいて、最も高信頼度な作業時間計測方法であるためである。しかし一方で、作業効率の向上を目指す一部のワーカーは、複数のタスクを複数のタブで開いた状態でそれらをつづつ行うことがあると知られており [Kaplan & Saito 18], この場合は正しい計測が行われない。よって、手動計測1よりも少ないと考える。一方、以上2つの計測方法で大半のケースはカバーできることから、自動計測2と手動計測2は数としては少ないと予想したが、ワーカーがタスクの途中でボタンクリックを忘れていたりする場合の予防線としての意味を持つため、一定数はラベルとして選ばれうることが期待された。

2.2 ウェブブラウザ拡張機能を用いたデータ収集

作業時間ラベルの付いたマイクロタスク作業データを収集するために、Amazon Mechanical Turk (AMT) のワーカー

にクローリング用のウェブブラウザ拡張機能をインストールさせ、サーバーへ作業データを送信する方法を用いた。

AMT上でデータ収集に参加するワーカーを募るマイクロタスクとして、ワーカー情報(性別、年齢、世帯収入、ワーカー経験歴、一週間のワーカー労働時間合計など)を質問した後に拡張機能のインストールを行うページへ誘導するアンケートUIを設計した。拡張機能のインストール完了とともにワーカーは最長10日間データ収集作業が可能となり、いつでもアンインストールによって終了できる(参加終了までのデータ収集分の報酬は後に支払われる)。

拡張機能インストール後、ワーカーには通常通りAMT上に存在する任意のマイクロタスク(AMTでは“HIT”と呼ばれる)を選び、行うように指示した。一つのHIT作業データを次の(a)~(c)の3ステップにより収集し、(b)と(c)の両方を正しく完了するたびに5セントのボーナスを支払った。

(a) **バックグラウンドデータスクレイピング:** ワーカーがHITのページを訪れるたびに、作業時間推定における特徴量として用いられる各種タスク関連情報をバックグラウンドで抽出した。表1に抽出した特徴量の一覧を示す。特徴量はタスク情報(HIT)、ワーカー情報(WKR)、リクエスト情報(REQ)の3つのメインカテゴリで構成される。HITは一回のHITページ訪問につき一度ずつ、合計71次元のタスクのメタデータやHTMLに関連する特徴量がページ内から抽出される。WKRに属する特徴量には、ブラウザ情報およびワーカーのダッシュボードページに対する一日に一度の非同期リクエストのレスポンス内容、および拡張機能インストール時のアンケート回答の結果が該当する。REQは、当該HITを発行したリクエストの評判情報にあたる。Turkopticon^{*1}, Turkopticon2^{*2}, TurkerView^{*3}, の3つの評判情報サイトが公開するAPIに非同期リクエストを送り、情報を取得した。

(b) **ボタンクリックによる作業時間計測:** ワーカーは、各HITでの作業中に自らの作業時間を記録するように指示される。HITのUI上部には拡張機能によって描画された記録ボタンが表示されており、ワーカーはそれをクリックすることによってOn/Offを切り替え、そのタスクにおける作業/中断状態を都度記録する。クリック忘れ防止のために2つの工夫を施した。まず、HIT開始時にはページ中央部に黒半透明スクリーンのアラートが表示され、ボタンをクリックしなければタスクを始めることができないように設計した。さらに、ワーカーが作業時間の計測を開始したHITのページには赤色の外枠を表示し、タイマーの稼働状況を把握しやすくした。なお、複数タブで開かれた複数のHITにおけるそれぞれのボタンは、同時にOnにならないように制御されている(HITの完全なマルチタスキングは可能でないことを仮定しているため)。

(c) **HIT作業後アンケート:** HIT作業レコードに作業時間をラベリングするために、ワーカーは複数の選択肢の中から最も近い作業時間を選択する。HITを完了すると同時に新しくポップアップウィンドウが開かれ、自動1(トータル)、自動2(フォーカス時)、手動1(ボタン)、手動2(直接入力)の4種類の計測作業時間のうち最も近い一つを選択するように指示される。前者の3つの選択肢のうちどれも該当するものが無いとワーカーが判断した場合、4つ目の選択肢であるTIME_CUSTOMの選択肢を選び、テキストボックスの中に作業時間を手入力する(X分X秒の形式)。回答を選択した後、“Submit”ボタンをクリックすることで回答を送信し、ポップ

*1 <https://turkopticon.ucsd.edu/>

*2 <https://turkopticon.info/>

*3 <https://turkerview.com/>

表 1: 収集データの特徴量カテゴリー一覧

HIT - タスク関連情報	
META	HIT メタデータ (報酬額, 残りタスク数など; 計 3 次元)
TMPL	HIT テンプレートの種類 (AMT 提供のもの; 11 次元の one-hot ベクトル)
URL	ページ内の URL 数 (リンク, 画像など; 計 5 次元)
INP	ページ内の INPUT タグ数 (radio, text などの type 属性ごと; 計 18 次元)
TXT	ページ内の単語数 (1 次元)
KW	タスク内容関連キーワードの有無 ("survey", "summarize" など; 計 32 次元)
WKR - ワーカー関連情報	
PRFL	事前アンケートのワーカー情報 (年齢, ワーカー経験, 自身の推定時給など; 計 16 次元)
EXT	AMT 関連拡張機能所持の有無 (CrowdWorkers, MTurk Suite など; 計 8 次元)
HIST	ワーカー作業履歴 (回答承認率, 承認 HIT 数など; 計 4 次元)
REQ - リクエスト評判情報	
TO	TurkOpticon (リクエストの報酬設定や連絡などの 5 段階評価平均; 計 6 次元)
TO2	TurkOpticon2 (タスクの報酬設定やバグ有無などの 5 段階評価平均; 計 34 次元)
TV	TurkerView (リクエストの平均設定時給やレビュー数など; 計 9 次元)

アップウィンドウは自動的に閉じられる。

2.3 収集データの分析

データ収集結果. 2018 年 10 月下旬の 10 日間でデータ収集を行った. 84 人のワーカーから全 9,155 件の HIT 作業データを収集し, 998 人のリクエストによって投稿された 1,641 種類の HIT Group (同一テンプレートの HIT のバッチ) を含んでいる. ワーカーのデータ収集参加期間は平均 6.5 日間 (SD=3.5; Median=8.1) で, 一人あたり平均 109HIT (Min=1; Max=1,958; SD=238.1; Median=34) の収集が行われた.

上記データのうち一部を除外する処理を事後的に行った. まず, いくつかの低報酬 (*i.e.*, 1~3 セント/HIT) な HIT Group が一人のワーカーにより大量に行われていることを確認した. これはデータセットのバイアスの原因となりうるため, HIT 提出数の多い上位 3 位までの HIT Group のレコードを 4 位の HIT Group の提出数 (*i.e.*, N=208) に合わせてランダムに選択し, 残りを除外した. 加えて, スпамワーカーと思われる 1 人の回答と, 不自然に長いまたは短い作業時間のタスク作業データ 210 個を無効なデータとして削除した. 以上の結果, 83 人のワーカーによる 7,608 (83.1%) HIT が残った (1,587 種類の HIT Group, 977 人のリクエスト). このデータの集合を以降の分析に用いる.

作業時間ラベリング. ラベル付けされた作業時間の平均は 277.9 秒 (SD=380.2; Median=148.3) であった. これらの作業時間ラベルと設定された報酬額から計算されたタスクの時給は, 平均で \$9.15 (SD=29.11; Median=4.23) となり, 2,270HIT (29.8%) (674 (42.4%) の HIT Group) が米国の最低賃金 (\$7.25/hour) であった.

ワーカーが最終的に作業時間として選択した候補の内訳は, 自動 1 (トータル) が 3,802HIT (50.0%), 手動 1 (ボタン) が 2,525HIT (33.2%), 自動 2 (フォーカス時) が 748HIT (9.8%), 手動 2 (直接入力) が 533HIT (7.0%) であった. 自動 2・手動 2 の総数が少ない点では仮説が支持された一方で, 自動 1 が手動 1 を 16.8 ポイント上回った点では仮説に反する結果となった.

そこで, さらなる 2 つの分析を行った. まず 1 つ目に, 手動計測 1 がうまく機能しなかった可能性を考慮し, 手動計測ボタンの使用状況を分析した. その結果, N=7,037 (92.5%) の HIT でボタンが最低 1 回はクリックされていた上, ワーカーごとのボタン使用率は平均 95.8% で, これを下回ったワーカーはわずか 16 人 (19.3%) だった. ほとんどの場合でボタンは正しく使用されているように見えたが, 一方で, そのうち 1 回タイマーが中止されたものはわずか 73HIT, 2 回は 8HIT, 3 回以上は 8HIT であり, それ以外の作業データ (N=6,948) では HIT の完了まで一度もタイマーが停止されていなかったことが分かった. 2 つ目の分析として, 作業時間ラベルとして最終的に手動 1 が選ばれた際の, 自動 1 の計測時間の秒数との差を分析した. その結果, 差がわずか 5 秒以内であるものが 72.5%, また 10 秒以内であるものは 85.1% に上った. これら 2 つの結果から, 手動 1 が最終的なラベルとして選択された場合のうちほとんどが, 自動 1 の計測時間とほぼ変わらない (*i.e.*, タスクが始まった直後にボタンをクリックし, かつ休憩を挟んでいない) 場合に選ばれていることが分かる. したがって, 今回の自動 1 と手動 1 は大部分が同じ意味を持つ結果であるといえる. なお, 今回のデータ収集では作業時間計測中にワーカーが何をしていたかをトラッキングしていないため, 手動 1 の計測結果の妥当性を検証することは出来ない. 作業時間ラベルの妥当性は今後詳細に検証していく必要がある.

2.4 TurkScanner: マイクロタスク時給の推定

TurkScanner では, *i*) タスク関連情報から作業時間を推定し, *ii*) 推定作業時間とタスクに設定された報酬額からタスク時給を計算する. タスク作業時間の推定には Gradient Boosting Decision Tree (GBDT) [Friedman 01] を用いた. なお, 今回は作業時間の出力値を対数値とすることで, 作業時間の秒数が小さいほど誤差のペナルティの重みを与えた.

手法の評価として, ワーカーオープンな 4-fold クロスバリデーションを行った. ここでのワーカーオープンとは, 学習データとテストデータをワーカー単位で分ける方針のことである. 以降の分析では, それぞれのクロスバリデーションのペアにおいて, 学習とテストを 50 回ずつ繰り返し, 得られた結果の平均をとったものを分析対象とした.

3. 実験結果と考察

タスク作業時間予測. 図 1 は, 実測の作業時間と GBDT を用いた回帰により推定した作業時間の関係を示したヒートマップである. この結果は, 多くの割合の推定された作業時間がヒートマップの対角成分もしくはその近辺に属していることを示している. 全体の推定作業時間のうち対角成分に属するのは 17.0%, 隣り合ったセルを含めたとき 47.4%, 2 つまで隣り合ったセルを含めた時 70.8% であった.

また全体の傾向として, 作業時間が短い (60 秒未満) ほど推定作業時間は実際よりも長く, また作業時間が長い (600 秒以上) ほど推定作業時間は実際よりも短くなる現象が見られた. これは, データセット内の作業時間が対数正規分布に従っていること, および作業時間を対数で推定していることが原因として挙げられる. 今回用いた GBDT は学習データ全体における予測誤差の総和を最小化するように最適化されているため, データ数の多い中程度の長さのマイクロタスクにおける作業時間推定が優先的に行われていると考えられる.

タスク時給予測. TurkScanner の最終出力であるマイクロタスク時給の予測結果について述べる. 全てのテストデータ内のタスクにおける平均の予測時給は \$5.21 (SD=4.53; Me-

Predicted working time [seconds]	Actual working time [seconds]														
	3-8 (466)	8-15 (418)	15-30 (371)	30-45 (448)	45-60 (405)	60-90 (612)	90-120 (570)	120-150 (528)	150-180 (438)	180-240 (676)	240-300 (510)	300-420 (609)	420-600 (618)	600-1200 (696)	1200- (243)
3-8	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
8-15	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
15-30	19%	33%	22%	7.1%	6.4%	3.6%	3%	1.5%	0.46%	1.5%	0.59%	0.33%	0.65%	0.14%	0%
30-45	68%	37%	15%	15%	11%	5.2%	1.2%	0.95%	0.23%	0%	0.39%	0%	0%	0%	0%
45-60	3.9%	15%	14%	10%	8.6%	5.1%	2.1%	0.76%	0%	0.59%	0%	0.33%	0.32%	0.57%	0%
60-90	1.9%	5.7%	29%	32%	27%	27%	25%	20%	15%	14%	5.3%	2.5%	0.65%	0.43%	0%
90-120	0.43%	0.96%	8.4%	27%	24%	19%	17%	14%	9.8%	7%	3.9%	2.3%	1.6%	0.29%	0.41%
120-150	0.64%	0.48%	1.9%	3.1%	10%	11%	16%	14%	16%	13%	7.5%	5.4%	2.4%	1.3%	0.41%
150-180	1.3%	1.7%	1.1%	1.3%	7.7%	19%	15%	15%	15%	10%	11%	8%	3.1%	1.9%	1.6%
180-240	2.6%	2.9%	3%	1.6%	1.2%	5.9%	15%	25%	28%	31%	33%	27%	19%	11%	5.3%
240-300	0.43%	1.9%	1.6%	0.45%	2.5%	1.3%	3.3%	5.7%	9.8%	14%	18%	20%	16%	10%	3.7%
300-420	0.64%	1.4%	2.7%	1.1%	0.49%	0.82%	0.7%	1.7%	4.6%	7.7%	15%	21%	27%	22%	15%
420-600	0.86%	0.72%	0.54%	0.89%	0.99%	1.3%	0.35%	0.76%	0.91%	1.3%	5.3%	11%	25%	37%	23%
600-1200	0.43%	0.24%	0.54%	0.45%	0%	0%	0.35%	0%	0.46%	0.15%	0.78%	1.6%	4.2%	15%	45%
1200-	0%	0%	0.27%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0.14%	5.3%

図 1: 作業時間推定結果のヒートマップ。

dian=4.20)であった。N=5,297 (全データの69.6%)において75%以内誤差、N=6,412 (全データの84.3%)において100%以内誤差をそれぞれ達成した。

また、タスクの実測作業時間に基づく時給別に結果分析を行ったところ、およそ\$15/h以下のタスクにおける予測は一定の精度で行えている一方で、それ以上の時給額のタスクでは実際よりも低めに予測されていることがわかった。ここでうまく予測が行われなかったタスクについて目視の精査を行ったところ、これらのタスクは (i) 外部の URL へ誘導するアンケートタスク、または (ii) JavaScript によって動的に描画されるコンテンツを含むタスク、であったことが確認された。これらのタスクは静的な HTML 情報を多く持たないという共通の性質を持っている。今回実装した拡張機能は動的に描画されるコンテンツ情報を取得する機能を持たなかったため、こうしたタスクではページ内にコンテンツがほぼ何も含まれないものとして扱われている。一方で、タスク時給の決定にはタスクの難易度や作業量などのタスク内に顕れる情報が大きな影響を持つと考えられる。そのため、タスク内容の特徴量成分が失われているデータに関して、特に時給予測が機能しなかった可能性がある。このことを定量的に検証するため、今後、各特徴量毎の寄与度などのさらなる詳細な分析を行っていく必要がある。

4. 結論

過去に他のワーカーが行った他のタスクの作業情報に基づきマイクロタスクの作業時間を推定する手法を提案した。本研究では2つの課題に取り組んだ。一つ目は、マイクロタスク関連情報および作業時間ラベルを取得するデータ収集方法として、4つの異なる方法により計測する作業時間のなかからワーカーに正しいものを選択させてラベリングを行うデータ収集用ウェブブラウザ拡張機能を設計した。二つ目は、GBDTによる作業時間の回帰推定およびマイクロタスクの時給計算を行う TurkScanner を設計・評価し、ワーカーがマイクロタスクを開始する前に作業内容が報酬に見合うかどうかを事前に

判断できる可能性を示した。今後は TurkScanner を AMT のワーカーに対して導入し、運用実験により実用性の検証を行っていく。

参考文献

- [Irani 13] Irani, L. C., & Silberman, M.: Turkopticon: Interrupting worker invisibility in amazon mechanical turk. *In Proc. of the SIGCHI conference on human factors in computing systems*. ACM, 611620 (2013).
- [Kaplan & Saito 18] Kaplan, T., Saito, S., Hara, K., & Bigham, J. P.: Striving to earn more: a survey of work strategies and tool use among crowd workers. *In Sixth AAAI Conference on Human Computation and Crowdsourcing*. AAAI (2018).
- [Bederson 11] Bederson, B. B., & Quinn, A. J.: Web workers unite! addressing challenges of online laborers. *In CHI'11 Extended Abstracts on Human Factors in Computing Systems*. ACM, 97-106 (2011).
- [Friedman 01] Friedman, J. H.: Greedy function approximation: a gradient boosting machine. *Annals of statistics*. 1189-1232 (2001).
- [Callison-Burch 14] Callison-Burch, C.: Crowd-workers: Aggregating information across turkers to help them find higher paying work. *In Second AAAI Conference on Human Computation and Crowdsourcing*. AAAI (2014).
- [Hanrahan 15] Hanrahan, B. V., Willamowski, J. K., Swaminathan, S., & Martin, D. B.: TurkBench: Rendering the market for Turkers. *In Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*. ACM, 1613-1616 (2015).

異種ネットワーク上のノードエンベディング法による 萌芽的研究分野特定のための分散表現抽出

The Representation Extraction for Emerging Research Fields
Using an Embedding Method for Heterogeneous Networks

大知 正直^{*1} 城 真範^{*2} 森 純一郎^{*1} 浅谷 公威^{*1} 坂田 一郎^{*1}
Masanao Ochi Masanori Shiro Jun'ichiro Mori Kimitaka Asatani Ichiro Sakata

^{*1}東京大学工学系研究科技術経営戦略学専攻

Department of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo

^{*2}産業技術総合研究所 人間情報研究部門

HIRI, National Institute of Advanced Industrial Science and Technology

It's important to identify promising research early to determine which research to invest. In addition, it's necessary to develop a technology for automatically predicting future research trends because of increasing the number of publication and the research fragmentation. There are many metrics for research performances and it depends on the objective which future trends to show. So, the problem is developing the technology to predict research trends for various metrics. Therefore, in this paper, we propose a method to extract distributed representations for automatically predicting various research metrics in the future using various heterogeneous network information with research papers. Experimental results show that prediction of the reference relation between the research papers was 95.6% F-value, and the h -index after three years from publication was 64.4% under certain conditions. The first result shows that the proposed method can sufficiently map the reference relations to a vector space. On the other hand, the prediction accuracy of the future h -index is equivalent to the comparison method, and further research needs. The results suggest that distributed representations of heterogeneous networks for scientific paper may be the basis for the automatic prediction of technology trends.

1. はじめに

研究への投資戦略策定のために、早い段階で有望な研究や研究分野を特定することは重要である。膨大な知識を俯瞰的に捉え、幅広く将来の技術開発の方向性を評価しようという試みは、技術フォアサイト、ホライズンスキヤニング、技術フォアキャスティング、インパクトアセスメント等と呼ばれる。特に最近では、このような活動を専門的に行う政府機関が多く、この国々^{*1}で設立され、政策決定の場でもこれらの試みから得られる知見を活かそうとしている。こうした試みは従来より、専門家に対するアンケートやワークショップによる T-plan 法や Delphi 法、SWOT 分析を用いたもので行われてきた。しかし、近年の論文出版数の急増及び専門知識の細分化によって、少数のメンバーによって学術研究の動向を分析することは困難となっている。また、より広い分野や、分野を横断した研究に対する需要が高まり、研究者個人に依存した技術動向予測は難しくなっている。このような中で、近年は論文や特許を直接分析し、意思決定に役立てようという試みが盛んに行われている。従来、論文や特許を直接分析する場合は、科学技術の現状を指数化することでその影響を明らかにしようとするものが多かった。論文そのものでは被引用数、出版した論文誌ではインパクトファクター (IF)、研究者個人では h -index などが挙げられる。

本稿では、出版社の持つ論文データの様々な情報をネットワーク表現し、将来の技術動向を予測するための分散表現を抽出

連絡先: 大知 正直, 〒113-8654 東京大学工学系研究科技術経営戦略学専攻, 東京都文京区本郷 7-3-1, "masanao.oochi@gmail.com"

^{*1}例えば、欧州議会科学技術選択評価委員会 (STOA) 内に設立されたユニット等 http://www.europarl.europa.eu/RegData/etudes/IDAN/2015/527415/EPRS_IDA%282015%29527415_REV1_EN.pdf

出することを目的とする。これによって、単に論文そのものが出版後どのようなインパクトを与えるかということのみならず、論文の著者や研究グループが近い将来にどのような研究に興味を持ち、どの程度のインパクトを与えるかということが定量評価できる。具体的には、ネットワークから各ノードの分散表現を抽出し、異種ネットワーク向けに改変した新たな手法を提案する。また、本研究では深層型のグラフ分散表現抽出モデルではなく、ランダムウォーク型のグラフ分散表現抽出モデルを採用した。これによって、大規模な異種ネットワークからノード分散表現を抽出することが可能になる。抽出した分散表現を用いることで、グラフデータ全体を用いずとも近傍のノードやコミュニティを検出することが可能になる。

本研究の貢献は以下の3点に要約される。

- 出版社の持つ論文データをネットワーク化し、分散表現を抽出する手法を提案をする。
- 抽出した分散表現によって、リンク予測に利用でき、グラフ構造を十分に抽出できることを示す。
- 抽出した分散表現によって、将来的な研究者の h -index の予測の可能性を示唆する。

2. 関連研究

これまでの多くの研究は、科学と技術に関する新興市場を予測し、推定するための方法を提案してきた。Fujita らは、論文の引用関係に関する複数のネットワークを作成し、クラスタリングを行い、最新の研究分野の検出の有効性を分析した [2]。Dong らは論文の出版後5年後の著者の h -index を予測した。論文のインパクトは6つの要因を用いて定義される、すなわち、著者、内容、出版社、引用、共著者、年代順である。その研究に用いられたデータはコンピュータサイエンスに関する

200 万件の論文情報である [1]. また, Sasaki らは出版直後のネットワーク的な情報のみで, その後の論文の被引用数の予測を行った [5]. このように研究分野の将来的な発展の可能性を早期に発見しようという試みは盛んに行われており, 本研究もその一つである.

一方, 2015 年からグラフを直接ベクトル空間に写像しようという試みが行われている [4, 7]. この試みは様々な発展し現在も盛んに研究されている. 深層化しようという代表的な試みは GCN [3] と呼ばれるものである. しかし, 現状ではグラフの規模も 10 万ノード程度でニューラルネットワークの階層も 2 層ほどで成果を報告しているものが多く, 大規模化, 深層化にはなお多くの課題が残されている. 本研究では, 比較的大規模化しやすいランダムウォークベースのグラフ分散表現の抽出手法を採用し, それを論文データ上で構築する異種ネットワーク向けに拡張したものを提案する. テキストデータ向けの異種ネットワーク分散表現獲得モデルがすでに報告されており [6], 本稿では, この手法を論文データ用に拡張し, 萌芽的研究分野特定に有効か評価を行う.

3. 提案手法

3.1 論文データを用いた異種ネットワーク

本稿では論文データを用いた異種ネットワークを用いる. 用いる異種ネットワークの概略を図 1 に示す. 解析対象とするネットワークは 5 つある. そして, それぞれのグラフは, 一部のノードを他のグラフと共有しており, 全く共有していないグラフは存在しない. まず, citation network で, これは論文の持つ引用関係をグラフにしたものである. 次に, paper-author network は, 論文と著者間をエッジで結んだものである. ただし, 共著者間でエッジを結ばず, 必ず論文とその著者で結ぶものとする. author-institute network は著者と著者の所属する研究機関の所属関係をエッジで結んだものである. また, 論文の特徴を表すために設定されたキーワードを論文と結んだものを paper-keyword network とする. 最後に論文が出版された雑誌と結びつけた paper-journal network を加える.

これらそれぞれのグラフのほとんどは, 論文だけ, 著者だけ, といった単一種類のノードのみで構成されたグラフではなく, 異なる種類のノード群で構成された複数の異種ネットワークである.

3.2 提案手法の概要

本節では, まず論文データから抽出した異種ネットワークの各ノードを単一のベクトル表現空間へ写像する方法について説明する. 次に, 萌芽的研究分野を特定するために有効な様々なタスクへと適用する手法を説明する. 提案手法の概要を図 2 に示す.

3.2.1 異種ネットワーク上のノードエンベディング法

本稿で用いる複数の異種ネットワーク上のノードを同一のベクトル表現空間へ写像を行う手法の説明を行う. まず, 複数の異種ネットワークの集合 \mathbf{G} を以下のように表す. ここで, G はグラフ, V はノード集合, E はエッジ集合とする.

$$\mathbf{G} := \left\{ G^l = (V^l, E^l) \mid 1 \leq l \leq |\mathbf{G}| \right\} \quad (1)$$

ここで, 各 G^l は図 1 に示した author-institute network や citation network のような複数の異種ネットワークで, $|\mathbf{G}|$ は対象とする異種ネットワークの数である. また, それぞれのグラフはノードとエッジで構成された無向グラフ $G^l := (V^l, E^l)$ とし, それぞれのグラフで共有するエッジは無いが, ノードは

表 1: 学習アルゴリズム.

学習アルゴリズム.	
1:	Input: $\mathbf{G}, T, \rho_0, K, D$.
2:	Output: \mathbf{U} .
3:	各ノードの写像ベクトル, コンテキストベクトル \mathbf{U}, \mathbf{U}' を D 次元で初期化.
4:	for $t = 1$ to T
5:	$\rho = \rho_0(1 - \frac{t}{T})$
6:	for $l = 1$ to $ \mathbf{G} $
7:	エッジ e_{ij}^l を G^l からサンプリング.
8:	ノード v_i^l, v_j^l に対応する写像ベクトル, コンテキストベクトルを \mathbf{U}, \mathbf{U}' から読み出す.
9:	写像ベクトルの更新: $\vec{u}^{t+1} = \vec{u}^t - \frac{\rho_t}{w^t} \frac{\partial O}{\partial \vec{u}}$
10:	コンテキストベクトルの更新: $\vec{u}'^{t+1} = \vec{u}'^t - \frac{\rho_t}{w^t} \frac{\partial O}{\partial \vec{u}'}$
11:	END

一部隣接するグラフと共有されているものとする. このような異種ネットワーク \mathbf{G} 上のあるノード $v_i \in \mathbf{V}$ をベクトル空間のあるベクトル $\vec{u}_i \in \mathbf{U}$ へと写像する方法を考える. ただし, \mathbf{V} は各異種ネットワーク上のノード群 V^l 全てを指す.

まず, ある特定のグラフ上で隣接するノード v_j へのエッジの重み $w_{ji} = P(v_j|v_i)$ を写像したベクトル表現で以下の式によって算出できるとする. 簡略化のため, 特定のグラフを対象にし, 添字 l を省略した.

$$\hat{P}(v_j|v_i) = \frac{\exp(\vec{u}_j^T \cdot \vec{u}_i)}{\sum_{k \in |V|} \exp(\vec{u}_k^T \cdot \vec{u}_i)} \quad (2)$$

ここで $|V|$ はグラフ上のノード数とし, \vec{u}_i をノード写像ベクトル, \vec{u}_j をノード v_i からのコンテキストベクトルとする. このコンテキストベクトルは計算上用いるのみで, 本稿ではノード写像ベクトルを求めることに興味がある. そして, この式を用いることで, 元のグラフ上でエッジの重みとの差を定式化できる. $P(\cdot|v_i)$ をノード v_i からすべてのノードへのエッジの重み (エッジが存在しないノードへは重み 0 で接続されるとする) の分布とすると, ベクトル表現から算出したエッジの重みの分布との距離の和 O を $\sum_{i=1}^{|V|} \lambda_i d(P(\cdot|v_i), \hat{P}(\cdot|v_i))$ によって計算できる. 例えば距離関数 d に KL 擬距離を採用し, 係数 $\lambda_i = \sum_{j=1}^{|V|} w_{ji}$ としたとき, 推定する $\hat{P}(\cdot|v_i)$ の変数部分のみに注目すると O は以下のように近似できる.

$$O \approx - \sum_{(i,j) \in E} w_{ji} \log \hat{P}(v_j|v_i) \quad (3)$$

この特定のグラフ G^l 内のノード集合 V^l をベクトル空間に写像したベクトル集合 $\mathbf{U}^l := \{\vec{u}_i^l \mid 1 \leq i \leq |V^l|\}$ との距離の和 O^l を異種ネットワーク \mathbf{G} 内のすべてのグラフに対して和をとる.

$$O = \sum_{l=1}^{|\mathbf{G}|} O^l \quad (4)$$

この式 4 の O を最小化する.

3.2.2 学習の手順

3.2.1 節で説明した更新式を以下のアルゴリズムによって順次更新し, ノード写像ベクトルの最適化を行う. アルゴリズム内の T は学習回数, K は負例サンプリングの回数, D は写像するベクトル空間の次元数を表す.

3.2.3 萌芽的研究分野特定の手順

本研究では, 萌芽的研究分野特定を行うことを可能にする分散表現抽出を目的とする. その初段として, 論文の将来的な被

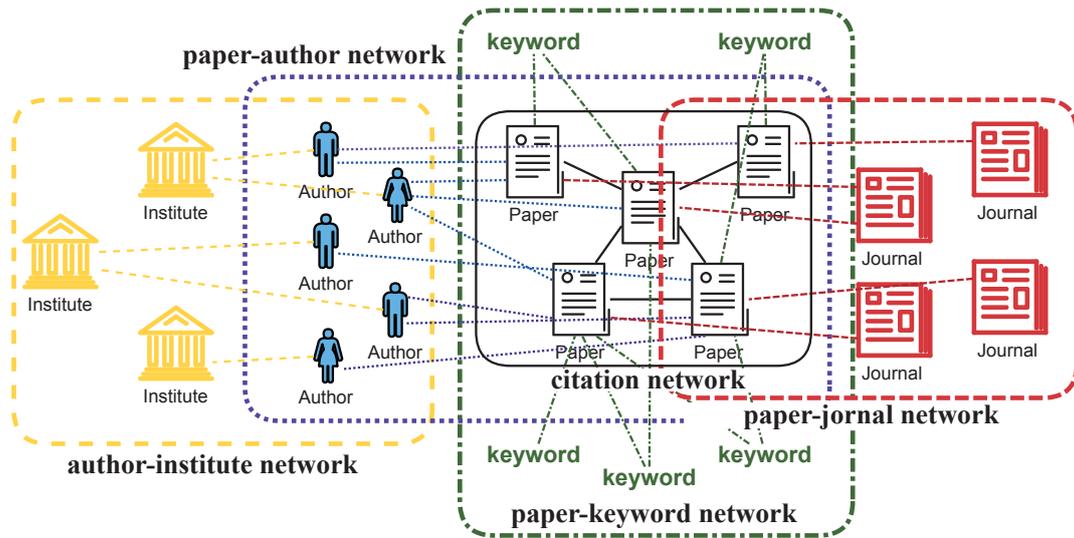
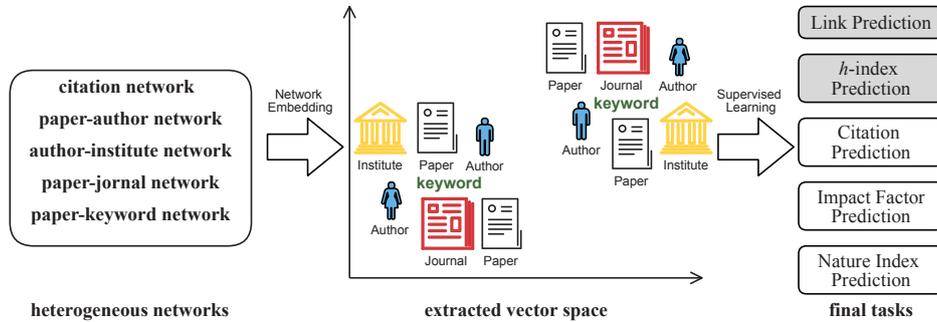


図 1: 本研究で用いる異種ネットワークの概略図.

図 2: 本稿で提案する手法の概要. final tasks 部分で色付きの Link Prediction, h -index Prediction が今回試行したタスク

引用数と研究者の将来的な h -index がトップ $x\%$ に入るか検証を行う. これによって, 異種ネットワークから抽出した分散表現が将来の研究動向の予測において, 有用であることを示す. 具体的には, ある年 (Y) から n 年後のある対象 (ID) の持つ何らかの指標 $I_{ID, Y+n}$ の予測を以下のロジスティック回帰を用いて行う.

$$\hat{I}_{ID, Y+n} = \sigma(\vec{w}^T \cdot (\mathbf{U}_s^T \cdot \vec{u}_{ID, Y})) \quad (5)$$

この式で, \vec{w} は最適化する重みベクトル, \mathbf{U}_s は適当に対象をサンプルした対象群 s のベクトルを並べた行列, $\vec{u}_{ID, Y}$ はある対象のある年の異種ネットワークで学習したベクトルである. これによって, ある対象 ID とサンプルした対象群との距離を特徴量として, その重み \vec{w} を学習することによって, 指標 I がトップ $x\%$ にはいるかどうかの予測を行う. また, \vec{w} は, Y よりも過去 (m 年前) の時点で学習しておく必要があるため, 訓練時には $Y - m$ 時点で, $Y - m + n$ 年での指標 I_{Y-m+n} の予測を行い学習する. そこで最適化を行った \vec{w} を指標 I_{Y+n} の予測に用い, 評価を行う.

4. 実験と結果

4.1 使用するデータ

使用するデータは国際的に多数の学術雑誌を発行している Elsevier より提供を受けた”(TITLE-ABS-KEY(nano AND carbon) OR TITLE-ABS-KEY(gan) OR TITLE-ABS-KEY(solar AND cell) OR TITLE-ABS-KEY(complex

表 2: データセット内の h -index の順位.

Ranking @2016	Name	h -index		
		2009	2013	2016
1	Michael Gratzel	23	72	116
2	Mohammad K.haja Nazeeruddin	13	45	80
3	Anders Hagfeldt	13	50	74
4	Shaik M.ohammed Zakeeruddin	15	47	64
5	Henry J. Snaith	7	29	63
6	Li Cheng Sun	13	44	60
7	Yong-fang Li	7	34	57
8	Christoph J. Brabec	12	33	57
9	Alan J. Heeger	8	32	55
10	Frederik Christian Krebs	12	41	55

AND networks)) AND PUBYEAR AFT 2006”というクエリに Scopus 上でヒットする文献データセットを用いる. このデータセットは, Nano Carbon, GaN, complex networks, Solar Cell に関する学術文献に関するデータで, 342,785 件の論文データを含んでいる. 論文データごとに, 著者, 研究機関, 引用文献, 雑誌名, アブストラクトの情報を持っている.

4.2 リンク予測

4.2.1 実験条件

本節では抽出した分散表現がグラフ構造を十分に学習できているか評価する. グラフ上からランダムに選択したノードのペア間にリンクが存在するかどうかを学習し, テストデータで十分に予測できるか実験する. リンクの存在の有無は $\hat{e}_{ij} = \sigma(\vec{w} \cdot \vec{u}_i^T \cdot \vec{u}_j)$ で判定を行う. $\hat{e}_{ij} \geq p$ -th の場合, その2つ

のノード間にはエッジが存在していると判定する。訓練のためにグラフから正例としてエッジのあるノードのペア、負例としてエッジの無いノードのペアを同数ずつ合計で 4358 万件サンプルする。テストデータ用に訓練データの数の 10%を同数ずつサンプルする。訓練データで最適化を行った w を用いて、テストデータのペア間のエッジの有無を予測し、その精度を評価する。比較手法として、ノード間のエッジの有無を 0.5 でランダムで選択する手法を用いる。

4.2.2 実験結果

実験結果を表 3 に示す。リンク予測に関しては総合的に見て高い精度で予測できており、本手法が十分にグラフの構造を学習できていることを示している。F1-value では p -th = 0.50 の場合に、提案手法の結果が 0.956 となっており、比較手法と比較して 0.458 ポイント高い。

4.3 h -index 指標予測

4.3.1 データセット内の h -index 指標

h -index 指数を "solar cell" というクエリで取得した *scopus* のデータセット内で計算した結果を表 2 に示す。1 位の Michael Graätzel は、色素増感型太陽電池の発明者で、2016 年時点で、色素増感太陽電池での最高記録となる 15% のエネルギー変換効率を達成しており、2019 年 1 月現在の Google Scholar 上の h -index は 253 である。その他の研究者についても概ね大きな h -index を示しており、太陽電池に関する研究者の h -index の順位は実際の順位と概ね一致している。

4.3.2 実験条件

本稿では、 $Y = 2013, n = 3, m = 4$ とし、サンプルした対象数 $|s| = 20$ とし、指標のトップ $x = 20\%$ に入るかどうかの予測を行う。つまり、2013 年の異種ネットワークを用いて、分散表現を抽出し、2016 年の著者の h -index がトップ 20% に入るかどうかの予測を行う。予測にあたって、学習には 2009 年の異種ネットワークから抽出した分散表現と 20 人サンプルした分散表現とのそれぞれの距離を特徴量として、2012 年時点での h -index の予測し、実際の値との最適化を行う。そして学習した \vec{w} を用いて 2016 年の予測を行い、結果の評価を行う。また今回は比較手法として、 Y 時点での h -index をそのまま $Y + n$ の結果として用いる。

4.3.3 実験結果

実験結果を表 4 に示す。表で、提案手法はロジスティック回帰による出力を行うので、その値のしきい値として p -th を設定している。このしきい値による違いと比較手法との差について確認する。まず、Precision は p -th = 0.80 のときに 0.992 で、比較手法の 0.704 と比較し、0.288 ポイント向上している。また、Recall は p -th = 0.06 のときに 0.717 で、比較手法の 0.652 と比較し、0.065 ポイント向上している。しかし、一方で F1-value では、提案手法は最大でも 0.644 であり、比較手法の 0.677 と比較し、0.033 ポイント下回った。

表 3: リンク予測の結果。

Method	p -th	Precision	Recall	F1-value
proposed	0.25	0.912	0.992	0.950
proposed	0.50	0.943	0.971	0.956
proposed	0.75	0.965	0.911	0.937
baseline		0.501	0.495	0.498

表 4: 将来の h -index 予測の結果。

Method	p -th	Precision	Recall	F1-value
proposed	0.06	0.585	0.717	0.644
proposed	0.80	0.992	0.0606	0.114
baseline		0.704	0.652	0.677

5. 考察

まずリンク予測については、提案したアルゴリズムによって十分にグラフ構造を学習できていることが確認できた。特にノード間のエッジの有無について 95%以上の精度で予測できており、グラフ上で隣接するノード群を十分近傍にベクトル空間上へ写像できていると考えられる。一方で、将来の h -index 予測では、個別の Precision, Recall といった指標は p -th の値を調整することで、高い値を得ることができる。しかし、両者の調和平均を取った F1-value においては最高で 0.644 を示しているものの比較手法をわずかに下回っている。パラメータを変化させることでこの精度が大きく変わることがないか今後検討する必要がある。

6. 結論

本稿では、萌芽的研究分野特定のための分散表現抽出手法を提案した。提案手法では、グラフのノード間のエッジの存在の有無を 95%以上の精度で予測でき、グラフ構造を十分にベクトル空間に写像できていることがわかった。一方で、将来の h -index 予測では precision, recall それぞれにおいては高い精度を示す結果を得ているが、F1-value においては比較手法を下回る結果であった。この結果は、抽出した分散表現によって、将来的な研究者の h -index の予測の可能性が示唆する。今後は、提案手法のパラメータの敏感性を調査したり、さまざまな指標予測を行ってみることで、本手法の限界、安定性について比較を行う予定である。

参考文献

- [1] Yuxiao Dong, Reid A. Johnson, and Nitesh V. Chawla. Will this paper increase your h -index?: Scientific impact prediction. In *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining*, WSDM '15, pages 149–158, New York, NY, USA, 2015. ACM.
- [2] Katsuhide Fujita, Yuya Kajikawa, Junichiro Mori, and Ichiro Sakata. Detecting research fronts using different types of weighted citation networks. *Journal of Engineering and Technology Management*, 32:129–146, 2014. Special Issue on Emergence of Technologies: Methods and Tools for Management.
- [3] Thomas N Kipf and Max Welling. Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*, 2016.
- [4] Bryan Perozzi, Rami Al-Rfou, and Steven Skiena. Deepwalk: Online learning of social representations. In *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 701–710. ACM, 2014.
- [5] Hajime Sasaki, T Hara, and Ichiro Sakata. Identifying emerging research related to solar cells field using a machine learning approach. *Journal of Sustainable Development of Energy, Water and Environment Systems*, 4:418–429, 12 2016.
- [6] Jian Tang, Meng Qu, and Qiaozhu Mei. Pte: Predictive text embedding through large-scale heterogeneous text networks. In *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '15, pages 1165–1174, New York, NY, USA, 2015. ACM.
- [7] Jian Tang, Meng Qu, Mingzhe Wang, Ming Zhang, Jun Yan, and Qiaozhu Mei. Line: Large-scale information network embedding. In *Proceedings of the 24th International Conference on World Wide Web*, WWW '15, pages 1067–1077, New York, NY, USA, 2015. ACM.

AF 意味論に基づく議論記録の要約手法

Summarization of Discussion Document based on Abstract Argumentation Semantics

仁科 慧*¹
Kei Nishina

新田 克己*²
Katsumi Nitta

*¹ 東京工業大学
Tokyo Institute of Technology

*² 産業技術総合研究所
National Institute of Advanced Industrial Science and Technology

Logical discussion is used in many kinds of discussions such as trial, parliamentary discussion, TV debate, and debate training, and the record of it is very important. However, it is difficult to understand the contents and the logical structure of it because it may be a very long document or difficult one. Therefore, we introduce a new method to summarize discussion documents retaining their logical structure. We used an Argumentation Framework (AF) to describe a logical structure of the document, and summarized the structure of it by compressing sub-AF which called “bunch structure” which visualized the contents of useless discussion for summarization into one argument with its reliability derived by the theory of Reliability based Argumentation Frameworks (RAF). The output of summarization is a RAF whose structure is smaller than the one of the original AF, and contents of each argument included by this RAF component of “summarized discussion document.”

1. はじめに

議論は、裁判、国会討論、討論番組、法学部での議論演習など様々な場面で行われ、その発言内容が議論記録として保存される。議論記録は一般に論理関係が複雑でしかも文章量が多いため、その内容を理解するのに時間がかかる、という問題がある。議論記録の論理構造を視覚的に表示する方法の一つに抽象議論フレームワーク (Argumentation Framework; AF) がある。これは、議論の論理構造を、論証 (ノード) と論証間の攻撃関係 (有向リンク) から成るグラフ構造で表現して、議論の論理構造を明確化し、受容性に基づく意味論を持っている。議論記録を AF で表現することにより、議論の論理構造が視覚的に理解しやすくなり、議論中のどの論証が妥当かを判別することができる。しかし、議論が複雑になると、AF のサイズが巨大になり、視覚的にも構造を把握することが困難になり、意味論計算が NP-困難となり [Dunne 09]、計算量が膨大になるため、AF の利点が失われる可能性がある。

そこで、議論の論理構造の骨格や論証の妥当性を保存しながら、AF の要約をする手法を提案することが本研究の目的である。具体的には、議論は一般的に複数の論点を持ち、それぞれの論点がサブ論点を持つことに着目する。それぞれの論点やサブ論点の議論は AF において房構造というサブグラフを構成すると仮定し、その房構造を 1 つのノードで代表させることで AF のノード数を削減し、要約を作成する。

第 2 章ではオリジナルの AF と要約した AF の関係を説明し、AF の理論を拡張した信頼度基準抽象議論フレームワークとモジュール信頼度基準抽象フレームワークを紹介し、第 3 章で AF の要約手法を説明し、第 4 章で結論を述べる。

2. 要約手法の基盤議論

2.1 抽象議論フレームワーク

本論文のベースとなる抽象議論フレームワーク AF [Dung 95]

は論証の集合 $Args$ と、論証間の攻撃関係の集合 $attacks$ の組 $(Args, attacks)$ で定義される。論証をノードと対応させ、攻撃関係を有向リンクと対応させると、AF はグラフ構造と解釈される。

AF の意味論は、 $Args$ の部分集合 S に対して論理的妥当性を定義するものである。

(1) 受理可能

$Args$ の任意の論証 a 、 a を攻撃する任意の論証 b に対して、 b を攻撃する論証 c が存在して $Args$ の部分集合 S に含まれる場合、 a は S によって受理可能であるという。

(2) 許容可能

S に含まれる任意のノード a が S によって受理可能であり、 S に含まれる論証間に攻撃関係が存在しない場合、 S は許容可能であるという。

(3) 拡張

完全拡張：許容可能な $Args$ の部分集合 S に対して、 S 外の任意の論証 a に対して、 a が S によって受理可能では無いことが成り立つ場合、 S は完全拡張である。

選好拡張、基礎拡張：完全拡張の中で、包含関係において極大な論証集合を選好拡張、極小な論証集合を基礎拡張という。

2.2 信頼度基準抽象議論フレームワーク

我々は、AF に信頼度の概念を付加した信頼度基準抽象議論フレームワーク RAF を提案した [Nishina 16]。RAF は、 $(Args, attacks, ST)$ と定義される。ST は個々の論証に対し、3 種類の信頼度のいずれかを割り当てる関数 $Ar \rightarrow \{sk, cr, def\}$ である。

ここでは、sk: 必ず信頼できる論証、cr: 信頼できる論証、def: 信頼できない論証、ということを表している。RAF においては論証集合 $Args$ の部分集合 S の受理性、許容性の定義が以下のよ

うに2つに分かれる。

(1) 楽観的受理可能

信頼度が sk か cr である $Args$ の任意の論証 a , a を攻撃する任意の論証 b に対して, 以下の 1), 2)のいずれかが成り立つ場合, a は S によって楽観的受理可能である。

- 1) b の信頼度が cr か def
- 2) b を攻撃する信頼度が sk か cr の論証 c が S の要素として含まれる。

(2) 悲観的受理可能

信頼度が sk である $Args$ の任意の論証 a , a を攻撃する任意の論証 b に対して, b を攻撃する信頼度が sk の論証 c が S の要素として含まれる場合, a は S によって悲観的受理可能である。

(3) 楽観的許容可能, 悲観的許容可能

S に含まれる論証間に攻撃関係が存在しない場合において,

- 1) S の任意のノード a が S によって楽観的受理可能である場合, S は楽観的許容可能であるという。
- 2) S の任意のノード a が S によって悲観的受理可能である場合, S は悲観的許容可能であるという。

楽観意味論, 悲観意味論における選好拡張, 基礎拡張は, 各々の完全拡張に対応して定義される。

3. AF 意味論に基づく議論記録の要約

3.1 議論記録の要約を表す RAF の導出法

まず, AF の部分グラフが房構造となっていることを以下のよう
に定義する。

房構造: ノード a を代表ノードとする房構造は, a から出発して, 向きを考慮せずにリンクを辿って, 再び a を通過することなく到達できるノードの集合と, その集合の要素間の攻撃関係からなる AF の部分集合である。

元の AF の構造全体が 1 つの房構造になる可能性があり, また, 房構造の内部に房構造が存在する可能性もある。

「RAF が AF の要約である」とは, その RAF が, 論証集合と攻撃関係に関して, AF に含まれる房構造を代表ノードで置き換えた部分グラフと一致しており, 代表ノードの信頼度は, 代表ノードの房構造における意味論評価結果から求めたものである。

議論記録の要約は, 議論を AF で表現し, その構造の要約である RAF を求め, その RAF の論証集合に対応した論証が元の議論記録の要約の内容となる。

図 1 の原発再稼働に関する議論を表す AF の例では, 論証集合 $\{3,4,5,6,7,8,9,10\}$ とその関係リンクが論証 3 を代表ノードとする房構造であり, また, 論証集合 $\{7,8,9,10\}$ とその関係リンクが論証 7 を代表ノードとする房構造である。 $\{7,8,9,10\}$ における AF において, 論証 7 は選好拡張に属するので, 7 の信頼度は cr となる。 $\{7,8,9,10\}$ を削除して論証 7 だけ信頼度 cr として残すことにより, もとの AF 情報が圧縮されたことになる。同様に, 代表ノード 3 に着目すると, $\{4,5,6,7,8,9,10\}$ を削除して, より圧縮度の高い要約を作ることができる。

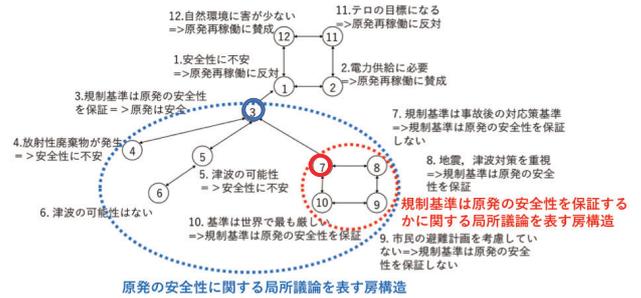


図1: 原発再稼働に関する議論の AF

3.2 議論記録の要約を表す RAF の性質

要約前のオリジナルの AF と, 代表ノード a とする房構造から a 以外を削除して得られる $Abst_RAF$ において, a は以下のような性質を持つ。

性質: $Abst_RAF$ において a が楽観完全拡張となる論証集合に属している場合, AF において a は完全拡張となる論証集合に属している。

これは, $Abst_RAF$ における a の状態から, 要約前のオリジナルの AF における a の状態が特定できることを示唆している。

4. おわりに

議論記録を AF を介して要約する手法を提案した。この要約手法は, AF の房構造を代表ノード以外の要素を全て削除し, 代わりに代表ノードの房構造における意味論上の評価結果を表す信頼度情報を残す。また, この要約手法によって得られた要約である RAF 意味論における代表ノードの評価結果から, 要約前の AF 意味論上の代表ノードの評価結果を求めることが可能である。

参考文献

- [Dung 95] P. M. Dung: On the acceptability of arguments and its fundamental role in non-monotonic reasoning, logic programming and n-person games, *Artificial Intelligence*, 77, pp.321-357. 1995.
- [Dunne 09] Paul E. Dunne and Michael Wooldridge: Complexity of abstract argumentation. In Guillermo Ricardo Simari and Iyad Rahwan (editors): *Argumentation in Artificial Intelligence*, pages 85–104. Springer, 2009.
- [Nishina 16] Kei Nishina, Yuki Katsura, Shogo Okada and Katsumi Nitta: Argumentation Support Tool with Reliability-Based Argumentation Framework, *New Frontiers in Artificial intelligence LNCS*, volume 10091, pp.265-281. 2015.

組織移動情報と研究者の学術生産性を用いた 研究組織環境の定量評価手法の提案

Identifying Affiliation Impacts on Innovation Enhancement

三浦 崇寛^{*1}
Takahiro Miura

浅谷 公威^{*1}
Kimitaka Asatani

坂田 一郎^{*1}
Ichiro Sakata

^{*1} 東京大学工学系研究科技術経営戦略学専攻

Department of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo

From the aspect of the efficient operation of a research organization, it is important to manage the research platform to promote the future publishing of scientists. However, the previous ways of organization evaluations cannot distinguish the evaluation based on scientists' community and that based on its research platform. We propose the methodology to extract scientist's movement and research productivity from bibliographic records on Computer Science between 2007 and 2018 on Scopus and make quantitative analyses about institutional impacts on scientific innovation. As a result, scientists moving to state-of-the-art institutions does not always improve scientist's productivity, rather collecting talented authors. Divided by its nationality, Chinese affiliations in low research productivity enhance the performance of scientists. Conversely, Japanese institutions give less contribution to scientists' productivity. This analysis contributes to a better understanding of scientists' incentive and what research organization can do to make scientific innovation.

1. はじめに

研究者が新しい知的発見を起こす具体的なメカニズムは未だ明らかになっていないが、研究組織が研究者の創造性に与える影響は非常に大きいことが指摘されている。適切な報奨設定や研究者同士の交流を活性化させるといった組織のインセンティブ設計によって研究者の創造性が向上することが分かっている[Verbee 2015]。特に、民間企業の参入によって近年急速に発展している Computer Science 分野では今後どの組織が成長していくかを予測することは研究者のキャリア形成のみならず、投資家や各国政府の戦略決定にも大きな影響を与えている。

しかし従来の組織評価指標である Nature Index や QS World University Rankings などの論文数や被引用数を軸とする評価は組織に所属する研究者の評価と組織環境の評価を区別していない。これは暗黙のうちに両者が相関していると考えられているためであるが、実際は両者が相関するとは限らない。例えば 1990 年代の日本の国立大学においては、優秀な研究者が劣悪な研究環境に置かれることで自身の研究能力を十分に発揮できない「頭脳の棺桶」と呼ばれる問題が古くから指摘されている[Asahi 1991]。こうした組織環境の悪化が 2000 年以降の日本の研究の国際競争力低下につながっていると考えられる[NISTEP 2017]。現状の組織環境評価手法は予算や学生の多様性などで測っているがこれらは環境の一側面に過ぎず、組織環境を定量的に評価できているものではない。

本研究では書誌情報から抽出される情報を元に組織環境を直接定量評価する手法を提案し、組織環境が研究者の学術生産性に与える影響を正しく評価できる指標となっているかを検証する。その結果、提案指標が既存の組織評価指標と比較してより研究組織環境の影響のみに焦点が当てられた指標となっていることが明らかになった。本研究によって研究者コミュニティとしての組織評価と研究プラットフォームとしての組織評価を区別

して行うことができることになることで、研究者の創造性を促す組織マネジメントを行うための意思決定補助になると考える。

2. 関連研究

研究環境に関する分析は大きく分けてチーム単位の研究者行動に着目した分析と地域単位の施策に関連づけた分析の 2 種類に分けられる。チームの研究環境に着目したものでは、各国の研究者の学術生産性が国際共著や国際間移動といった国の openness と相関関係にあることや[Wagner 2017]、論文投稿が活発で成熟した分野であるほど研究の team-size が大きいことが明らかになっている[Fortunato 2018]。また国や地域の施策と紐づけた研究では、近年科学的リーダーシップを獲得していると言われる中国が論文数やポストドクの数では欧米を上回りつつあるものの研究のインパクトはまだ追いついていないことや[Basu 2018]、アラブの春前後でアラブ諸国の研究者の論文数、被引用数ともに増加したこと[Ibrahim 2018]が計量書誌学上の研究から明らかになっている。しかし、研究環境の分析を組織評価において利用している研究は未だ行われていない。

3. 提案手法

3.1 概要

本研究では、論文数や被引用数といった観測される学術生産性指標が研究者個人の研究力と研究組織の影響力の 2 つに分けられるとする Dundar の研究結果を用いる[Dundar 1998](図 1)。

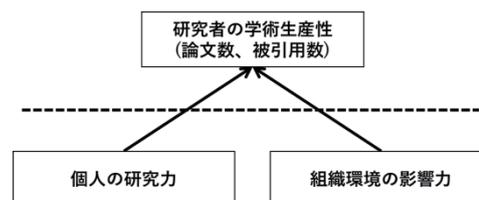


図 1. 学術生産性の捉え方

これまでの組織評価では書誌情報から直接観測できる論文数や被引用数のみを扱っていたため、その中で個人の研究力と

組織環境の影響力の占める割合が不透明であり組織環境を評価することができなかった。そこで研究者の組織移動に着目し、組織移動しても変わらない部分が研究者個人の研究力、変わる部分が組織環境の影響力であると仮定することによって本来観測することができない組織環境の影響を定量的に評価できるのではないかと考えた。提案手法の概要を図2に示す。以降で詳細を説明する。

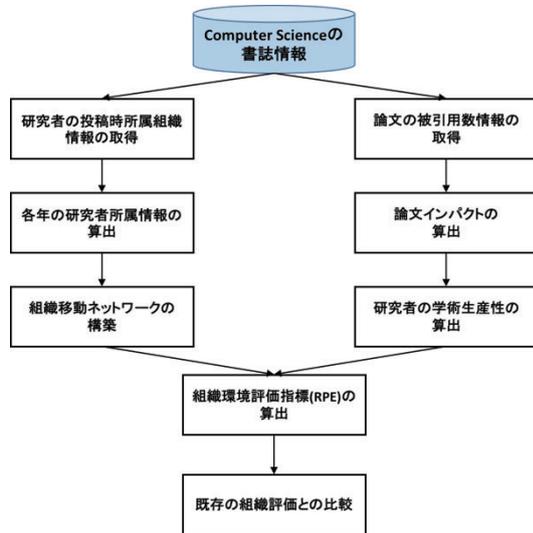


図2. 提案手法の概要

3.2 組織移動ネットワークの構築

各著者の論文投稿時における所属組織情報から著者をキーとしたスパースな所属組織辞書を作成する。次にその辞書から上山の提案した移動検出モデル[Kamiyama 2015]を用いて各著者の所属組織と流入組織を年ごとに特定する。上山はその組織で過去4年以内に投稿がなく新しく投稿された年を流入年、投稿以降4年間投稿がなかった年を流出年として研究者の所属情報を作成した。この時所属の精度を上げるために、データを通じて1回しか投稿のない組織には所属していないとする。具体例を図3に示す。例えば2010, 2011, 2013年に投稿があった場合は2010年を流入年, 2013年を流出年とする。

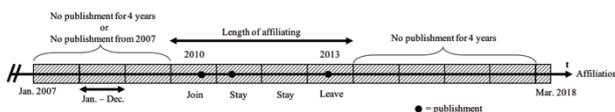


図3. 研究者の所属の検出方法

その後各年の流出流入の情報から、各研究者についてある組織を流出してから2年以内に流入している組織に対してリンクを結び、移動ネットワークを作成する。移動年は流出年と流入年の平均値をとって小数点を切り捨てる。

3.3 研究者の学術生産性の算出

本研究では、論文の2年以内の被引用数を論文のインパクトと考える。引用は多くないが優れた研究でもある sleeping beauty[Raan 2004]の存在も留意しなければならないが、Computer Science 分野では論文の投稿スパンが短いため2年内被引用数は本分野における学術生産性の一側面を示していると考えられる。各研究者の学術生産性は一般的に投稿論文の被

引用数の総和によって求められるが、より正確に研究のインパクトを測るために論文の分野と投稿年度によって標準化を行う。

分野が異なると引用構造が異なるため被引用数の比較では研究インパクトの比較ができないことが知られているが、Radicchiらによれば論文 p の被引用数 $w(p, s)$ をその分野の平均被引用数 $w_c(p, s)$ で標準化することで比較可能であることが指摘されており[Radicchi 2008], 今回はこの手法を採用する。分野の特定には、論文の引用ネットワークを Louvain 法[Tang 2016]を用いてコミュニティに分割したものを用いる。

次に投稿年度についてである。Fortunatoらによれば知的発見あたりの論文数が増加しているため[Fortunato 2018], 2007年の論文数を1とした各年の相対論文数 n_y で平均することによって論文の知的発見のみを計測することができる。また本手法では論文のインパクトを2年以内の被引用に限るため時系列情報が取得できるデータ内の論文からの被引用のみを考えるが、Computer Science は近年急速に成長した分野であり分野間引用から分野内引用へとシフトしていることが考えられるため、各年の2年内被引用数 $w_y(p, s)$ で標準化を行う。以上の2つから著者数 α_p の論文における1人あたりインパクトは、

$$i_{p,s} = \frac{w(p,s)}{(\alpha_p \times n_y \times (w_c(p,s) + w_y(p,s)))} \quad (1)$$

と求める。各年の研究者の学術生産性は $i_{p,s}$ をその研究者の投稿した論文数で足し合わせたものである。

3.4 提案指標の定義

組織移動情報と各年の研究者の学術生産性変化から今回の提案指標を算出する。今回提案する組織環境評価指標を Research Productivity Enhancement(RPE)と呼ぶ。RPEは流入した研究者の学術生産性が向上した場合、または流出した研究者の学術生産性が低下した場合に高い値をとる指標となる。提案手法と同様に、研究者の移動と学術生産性変化から各都市の傾向を分析した Verginer の計算手法[Verginer 2018]を用いて、各組織のRPEを以下のように求める。

$$RPE_{o,y} = \log \left(\frac{(\sum_{a \in A_{y,\sigma,o}} \forall \sigma \hat{I}_{a,y,s}^1) \times (\sum_{a \in A_{y,o,\tau}} \forall \tau \hat{I}_{a,y,s}^0)}{(\sum_{a \in A_{y,\sigma,o}} \forall \sigma \hat{I}_{a,y,s}^0) \times (\sum_{a \in A_{y,o,\tau}} \forall \tau \hat{I}_{a,y,s}^1)} \right) \quad (2)$$

表1. 各変数の定義

変数	定義
s	引用の判断基準(2年)
$A_{y,\sigma,\tau}$	y年に組織 σ から組織 τ に移動した著者群
$\hat{I}_{a,y,s}^0$	著者aのmax(y-4, 2007)年からy-1年までの平均インパクト
$\hat{I}_{a,y,s}^1$	著者aのy年からmin(y+3, 2017-s)年までの平均インパクト
$RPE_{o,y}$	y年の組織oのRPE

4. データ

本研究では Elsevier 社が運営する世界最大級の論文データベース Scopus から抽出した Computer Science カテゴリの論文のうち、2007年1月から2018年3月までの論文3,413,701件に絞って分析を行う。書誌情報は著者名、所属組織名、投稿年、引用文献がラベルづけされており、著者名と所属組織名はそれぞれユ

ユニークな ID で管理されている。今回は表現の揺らぎの影響を考慮して各 ID で最も頻度の多い名前と ID を紐づけた。名寄せの結果ユニークな著者数は 3,089,335 人、組織数は 237,179 件であった。各組織には所属国情報が付いており、その分布を表 2 に示す。

表 2. 各国の組織数 Top10

Chn	Usa	Ind	Fra	Jpn
37,245	37,070	16,656	13,104	12,280
Ita	Gbr	Esp	Bra	Kor
8,290	7,974	6,237	5,505	5,222

5. 結果

提案手法で移動を抽出した結果、ノード数 18,676、エッジ数 87,465 の移動ネットワークを構築した。流入は全年で観測されるが、流出は以降 4 年間の投稿情報が必要なため 2013 年までしか観測されない。そのため移動が観測されるのは 2007-2014 年の 8 年間で、各年の移動数は 2007 年と 2014 年が 5000 件弱、2008-2013 年では 10,000-15,000 件であった。

5.1 提案指標と既存指標を用いた組織評価

図 4 に主な結果を示す。横軸は既存指標で用いられる各研究組織から出た全ての論文のインパクトの総和、縦軸は今回の提案指標である RPE を各年で平均したものである。より精度を上げるために移動数が 250 回以上観測された 90 組織のみをプロットしている。点線はプロットされた組織の各平均線である。

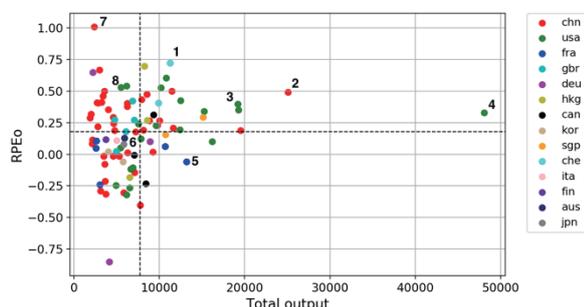


図 4. 各組織の学術生産性と RPE の関係

両者の相関係数は 0.166 程度で相関は見られず、背景で述べたように既存の組織評価指標が組織環境評価とは一致していないことがわかる。各軸の平均線によって区切られる 4 象限について特徴的な組織を挙げる。

(1) 第 1 象限

本象限は既存の組織評価でも提案指標でも高い評価を受けている組織群であり、優れた組織環境が研究者の学術生産性を高めたことで研究者コミュニティとしても活性化している正の循環の存在が推測される。OECD 内で最も 1 人あたりの教育費が高い 1: “ETH Zurich”や年間 1 兆円近い予算を有し 2016 年には科学技術の年間論文数がハーバード大を超えて世界 1 位となった 2: “Chinese Academy of Sciences”, Computer Science 分野を牽引する 3: “Microsoft Research”, 各分校が全て総和されているため既存指標で特に高い評価となっている 4: “California University”らがあった。

(2) 第 2 象限

本象限は既存指標では高い評価を受けているが、所属研究者の創造性を十分に引き出せていない「頭脳の棺桶」となっている可能性のある研究組織群である。フランスの 5: “CNRS”がこれにあたる。2000 年から CNRS の常勤研究員として勤めた小田によれば、CNRS はヨーロッパの優れた研究者がこぞって入る研究組織ではあるが政府からの資金が徐々に削られてしまい、資金を集めるために地方自治体や民間のプロジェクト用のテーマばかりにお金が割り振られてしまうため基礎研究が伸びにくい環境にあったという [Oda 2005]。また 2004 年には同組織内で研究者のストライキも発生している。この組織群は優れた研究者コミュニティを有しているがその能力を十分に活かすための組織環境に乏しく、現状優秀な研究者が集まることによって組織評価を高めているが将来の研究成果の低下が危ぶまれるともいえるべき組織群である。

(3) 第 3 象限

本象限は既存指標でも提案指標でもあまり評価されていない組織群であり、6: “University of Tokyo”があたる。東京大学は博士進学者が毎年減少してきており、研究環境の改善が叫ばれている。この象限に属する大学組織はこれから高い学術生産性を持つために組織マネジメントを見直す必要がある大学であると言える。

(4) 第 4 象限

本象限は既存指標では評価されていないが研究者の学術生産性を引き出しており今後の躍進が期待される組織群である。7: “Beijing University of Technology”, 8: “IBM Research”があたる。またこの象限に属する 24 組織のうち 15 組織が中国の大学であった。この傾向は現在の中国の社会情勢と比較しても理にかなっており、2019 年 1 月 11 日付の日本経済新聞の記事によればこれまで半導体や航空機のような戦略的製造業において技術流出を控えようとしてきたアメリカが、新たに AI やロボットを規制の対象としようとしている。この背景には今回明らかになった中国の研究機関の Computer Science における規模の拡大と実力の向上を予期したものであると考えられる。既存指標ではこれらの組織の優位性を説明できないが、RPE を用いることによって研究者の学術生産性を高めている組織環境を有していることが明らかになった。

5.2 移動数と提案指標の関係

各組織の移動数と RPE のばらつきを示したものが図 5 になる。移動数が多いほど RPE のばらつきは小さくなり、安定した値を取っていることがわかる。

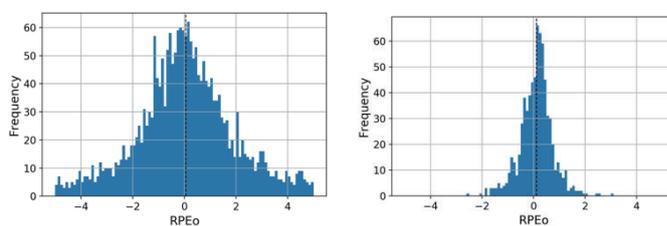


図 5. 移動数ごとの RPE の分布 (左が移動数 50 以下、右が移動数 50 以上)

提案手法では研究者個人の研究力の変動を全く考慮していなかったが、科学的発見というのはしばしば組織環境とは無関係に突発的に発生するものであり、研究キャリアの中でいつ大きな成功を収めるかは人によって様々で予測することは難しいことが分かっている [Fortunato 2018]。移動数が少ない組織では一研

研究者の学術生産性変化の影響が大きなウェイトを占めるため、突発的発見が起こった場合に組織環境が実際とは離れた値を取ってしまうことが考えられる。ある程度移動のサンプル数があれば突発的影響が平均化されより正確に組織環境のみを評価することができるため、RPE を用いた分析を行う際には一定以上のデータ数が必要であると考えられる。

6. 考察

本研究では組織環境を評価するための新しい指標とその算出方法の提案を行ったが、既存手法を用いても組織環境評価を行うことが可能であるかどうかをここで議論する。既存手法によって提案指標が代替不可能ならば、今回の提案手法が組織環境を評価する上で重要な役割を担うことができると考えられる。既存手法として、計量書誌学上で行われている移動ネットワークの構造的特徴に着目した分析を行う。例えば Life Science 分野の研究者に関しては PageRank の高い組織にインパクトの高い論文を出した研究者が移動しやすいことが明らかになっている [Verginer 2018]。

今回は抽出した移動ネットワークの各ノードの中心性と提案指標の相関係数を調べる。比較対象として各種中心性と既存指標である論文インパクトの総和との相関係数も調べる。中心性には代表的な次数中心性、近接中心性、媒介中心性、固有ベクトル中心性、PageRank [Page 1999] を用いる。PageRank は有向重みありネットワーク、それ以外は無向重みなしネットワークとして計算している。結果を表 3 に示す。

表 3. 各種中心性と既存指標、提案指標の相関係数

中心性	既存指標	提案指標
次数中心性	0.82	0.13
近接中心性	0.77	0.07
媒介中心性	0.81	0.07
固有ベクトル中心性	0.47	0.12
PageRank	0.72	0.05

ネットワークの各種中心性は既存指標と相関が強いものに対して提案指標との相関はほぼ見られないことがわかる。このことから研究者の移動は論文数や被引用数といった研究者コミュニティの評価を元に行われているものであり、組織移動に対して研究環境は大きな影響を与えていないことが示唆される。よって仮説で述べた通り既存手法である移動ネットワーク構造に着目した指標によっては今回の提案指標は代替されず、組織移動と研究者の学術生産性変化を用いた今回のアプローチは組織評価において重要な位置を占めると考えられる。

7. 結論

本研究では、書誌情報から抽出した研究者の組織移動ネットワークと学術生産性変化から研究組織環境を定量評価する指標 RPE を提案し、実際に RPE を用いた環境評価を行なった。その結果、Computer Science 分野を牽引する代表的な研究組織や既存指標ではまだ評価されていない中国の研究組織が高い RPE を保持していることが明らかになった。一方でフランスの CNRS に代表されるように、優れた研究者コミュニティを有しているが組織環境がその能力を十分に引き出せていない「頭脳の棺桶」となっている組織の存在も明らかになった。このことから RPE は研究組織が研究者の学術生産性に与える影響を表していると考えられるため、研究環境評価指標としてだけでなく研究者の将来性を推測するためにも利用できると考えられる。また既存手法である研究者の移動構造から組織の特徴を抽出する手

法によっては組織環境を表現することができず、今回の提案指標が組織環境評価に対して有意な結果を示していることが考えられる。今後の展開としては、現在の組織環境評価指標で用いられている予算や留学生数、所属研究者へのアンケートを用いた現状の組織環境評価と比べて提案手法が妥当な結果を示しているのかを調査する。

参考文献

- [Verbree 2015] Maaik Verbree, Edwin Horlings, Peter Groenewgen, Inge Vander Weijden and Peter van den Besselaar: Organizational factors influencing scholarly performance, *Scientometrics*, Vol. 102, No.1, pp.25-49, Jan, 2015
- [Asahi 1991] 朝日新聞 Weekly. 「頭脳の棺桶 国立大学」, AERA, 朝日新聞社, p9-14, 1991
- [NISTEP 2017] 村上昭義, 伊神正貴: 科学研究のベンチマーキング 2017. Technical Report, 文部科学省科学技術・学術政策研究所, August 2017.
- [Wagner 2017] Caroline S Wagner and Koen Jonkers. Open countries have strong science. *Nature News*, Vol. 550, No. 7674, p. 32, 2017.
- [Fortunato 2018] Fortunato Santo, et al.: Science of science, *Science* 359.6379: eaao0185, 2018
- [Basu 2018] A. Basu, P. Foland, G. Holdridge, and R. D. Shelton: China's rising leadership in science and technology: quantitative and qualitative indicators. *Scientometrics*, Vol. 117, No. 1, pp. 249-269, Oct 2018.
- [Ibrahim 2018] Bahaa Ibrahim. Arab spring's effect on scientific productivity and research performance in arab countries. *Scientometrics*, Vol. 117, No. 3, pp. 1555-1586, Dec 2018.
- [Dundar 1998] Halil Dundar and Darrell R Lewis: Determinants of research productivity in higher education, *Research in higher education*, Vol. 39, No. 6, pp. 607-631, 1998
- [Kamiyama 2015] 上山隆大: 研究者養成と研究のマネジメント - アメリカの経験から学ぶ. *日本労働研究雑誌*, No.660, pp.87-102, Jul 2015.
- [Raan 2004] Anthony F. J. van Raan: Sleeping beauties in science. *Scientometrics*, Vol. 59, No. 3, pp. 467-472, Mar 2004.
- [Radicchi 2008] Filippo Radicchi, Santo Fortunato, and Claudio Castellano: Universality of citation distributions: Toward an objective measure of scientific impact. *Proceedings of the National Academy of Sciences*, Vol. 105, No. 45, pp. 17268-17272, 2008.
- [Tang 2016] Jian Tang, Jingzhou Liu, Ming Zhang, and Qiaozhu Mei: Visualizing large-scale and high-dimensional data. In *Proceedings of the 25th International Conference on World Wide Web*, pp.287-297, 2016
- [Verginer 2018] Luca Verginer and Massimo Riccaboni: Brain-circulation network: The global mobility of the life scientists. Working Papers 10/2018, IMT Institute for Advanced Studies Lucca, October 2018
- [Oda 2005] 小田玲子: フランスの研究者の教育・就職状況と研究費, 2005. <http://mathsoc.jp/publication/tushin/1004/oda.pdf> (1/27 アクセス)
- [Page 1999] Page, Lawrence, et al.: The PageRank citation ranking Bringing order to the web. *Stanford InfoLab*, 1999.

[1L2-J-11] Robot and real worlds: cognition of objects and environment

Chair:Kugatsu Sadamitsu Reviewer:Masakazu Hirokawa

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room L (203+204 Small meeting rooms)

[1L2-J-11-01] Design and Evaluation Image Recognition Sub-tasks to Improve End-to-End Learning Model for Self Driving Cars

○Jing Shi¹, Hao Zhi Li², Toshiyuki Motoyoshi¹, Tadashi Onishi¹, Hiroki Mori³, Tetsuya Ogata^{1,4} (1. Department of Intermedia Art and Science, School of Fundamental Science and Engineering, Waseda University, 2. Department of Modern Mechanical Engineering, School of Creative Science and Engineering, Waseda University, 3. Future Robotics Organization, Waseda University, 4. National Institute of Advanced Industrial Science and Technology)

1:20 PM - 1:40 PM

[1L2-J-11-02] Object Perception in the Blind Spots with Mirror Based on Depth Prediction Using CNN

○Yuto Uchimi¹, Shingo Kitagawa¹, Iori Yanokura¹, Kei Okada¹, Masayuki Inaba¹ (1. The University of Tokyo)

1:40 PM - 2:00 PM

[1L2-J-11-03] Filtering of Middle Layer Outputs for Object Classification Using a Model Trained Detecting Grasping Positions

○Yasuto Yokota¹, Kanata Suzuki¹, Yuuji Kanazawa¹, Tomoyoshi Takebayashi¹ (1. Fujitsu Laboratories LTD.)

2:00 PM - 2:20 PM

[1L2-J-11-04] Observational Causal Induction with Small Samples

○Yu Takarada¹, Tatsuji Takahashi¹ (1. School of Science and Engineering, Tokyo Denki University)

2:20 PM - 2:40 PM

[1L2-J-11-05] Pixyz: a framework for developing complex deep generative models

○Masahiro Suzuki¹, Takaaki Kaneko¹, Shohei Taniguchi¹, Tatsuya Matsushima¹, Yutaka Matsuo¹ (1. The University of Tokyo)

2:40 PM - 3:00 PM

End-to-End 自動運転モデル改善のための 画像認識サブタスクの設計と評価

Design and Evaluation Image Recognition Sub-tasks to Improve End-to-End Learning Model for Self Driving Cars

石 晶^{*1} 李 志豪^{*2} 本吉 俊之^{*1} 大西 直^{*1} 森 裕紀^{*3} 尾形 哲也^{*1*4}
Jing Shi Zhihao Li Toshiyuki Motoyoshi Tadashi Onishi Hiroki Mori Tetsuya Ogata

^{*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}早稲田大学 創造理工学部 総合機械工学科

Department of Modern Mechanical Engineering, School of Creative Science and Engineering, Waseda University

^{*3}早稲田大学 次世代ロボット研究機構

Future Robotics Organization, Waseda University

^{*4}産業技術総合研究所

National Institute of Advanced Industrial Science and Technology

Sub-task training for a deep neural network can improve main task performance, for example, for self-driving cars and other tasks. However there is no theoretical design principle that how to make sub-tasks suitable for a main task. In order to improve the self-driving task, searching the optimal sub-tasks design is necessary. In this research, we compared multiple combination of sub-tasks sharing a network to generate driving command. In the research of Li et al.2018, a multi-task learning method used two modules, a perception module (extracting semantic segmentation and depth map) for recognition of surrounding circumstances and a driving module for driving operation. Their multi-task method scored higher generalization performance in unknown environment than previous end-to-end self-driving method. In this research, we conducted experiments to improve the generalization ability of their model by modifying sub-task design. As a result, generating semantic segmentation map as sub-task got the best performance for self-driving cars.

1. はじめに

現在、ビジョンベースの自動運転システムには、Mediated Perception 手法と Behavior reflex 手法の二つがある [1]. Mediated Perception 手法では、まずシーン全体を明示的に解析する。例えば、車線、交通標識、信号や車などの認識、歩行者の場合には自車への距離などを解析し、その解析した結果を用いて複雑なアルゴリズムを準備し、最終的に運転行動を生成する。Behavior reflex 手法は、RGB 画像などの知覚情報を入力として運転行動を出力とする訓練データを用意して Neural Network(NN) を学習し、運転行動を生成する手法である。このような、入力と出力に前処理をせずに制御器を学習させる手法を一般に End-to-End Learning と呼ぶ。現在自動運転において、畳み込みニューラルネットワークの End-to-End Learning を用いて、RGB カメラによって得られた画像を入力として運転行動を直接出力するという研究が行われている [2, 3]. しかし、End-to-End Learning を用いた自動運転研究にも、まだ様々な問題が存在している。例えば、RGB 画像から運転行動を直接生成し、NN で構成されるコントローラ内部の情報処理や情報表現は非明示的に処理される (Black box) ため、事故が発生した際に原因を突き止めることが困難である。また、未知の環境での汎化性能が低いという問題もある。

2. 関連研究

End-to-End Learning を用いた自動運転の従来研究はいくつか挙げられる。Codevilla et al. 2017 [3] は RGB 画像、速度と方向指示を NN に入力して運転行動を生成する手法を提案した。このモデルにより、道路に沿って適切に運転できると同時

に、十字路口など複数の進行方向がある場合に関しても、コントローラに方向を指示するだけでその方向へ進む適切な運転行動を取ることが可能になった。また Li et al. 2018[4] は、図 1 に示すような、周囲の状況の認識を担う Perception Module と、運転操作を行う Driving Module という二つのモジュールを用いたマルチタスク学習手法を提案した。Perception Module に画像認識に関するサブタスクを学習させた後に、Perception Module の画像特徴抽出部を用いて Driving Module による運転行動生成を学習させる手法である。Perception module のサブタスクは、Semantic segmentation 画像と Depth 画像の生成である。ここで、Depth 画像は車、歩行者、建物といった物体の、自車のカメラからの距離を表す。また、Semantic segmentation 画像は画面内の画素単位での一般物体認識により、画像内のすべてのオブジェクトを区分けする。

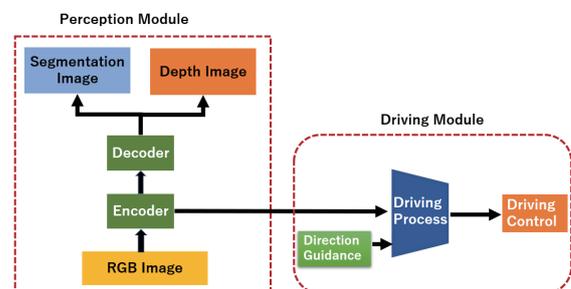


図 1: Li et al.2018 のモデル構造

Li et al. 2018 は、いくつかの運転タスク設定において、未知の環境での完走率を Codevilla et al. 2017 と比較した (図 2). 運転タスクは、1:直線路の走行, 2:一つのカーブを含むコースの走行, 3:ナビゲーションによる方向指示に従った走行, 4:ナビ

ゲーションに従い、動いている歩行者と車を含む複雑な環境での走行, の4種類である. いずれのタスクにおいても, Li et al. 2018の完走率は Codevilla et al. 2017の結果より大幅に上昇した [3, 4]. この結果から, RGB画像から運転行動を直接生成するよりも, あらかじめサブタスクを学習させた Perception moduleの特徴抽出から Driving Moduleによって運転行動を生成する方が高い運転性能になることを示した.

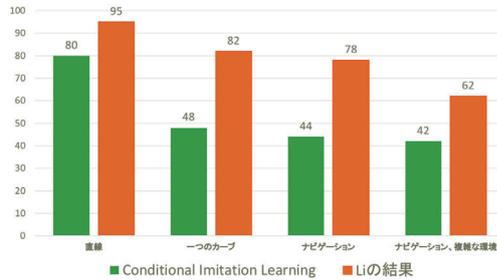


図 2: Li et al. 2018 の研究結果

しかし, Li et al. 2018 のモデルにおいても, 動的な歩行者と車が存在するタスクの完走率は 62% に留まる. 自動運転は人間の命に関わる技術なので, どんな状況に対しても正しく運転できるのが目標である.

3. 提案手法

本研究では, Li et al.2018 のマルチタスクモデルを元に, Perception Module のサブタスクデザインの改善と評価実験を行った. Li et al.2018 の研究のサブタスクは Depth と Semantic segmentation であった [4], 本研究では Semantic segmentation 画像, Depth 画像, RGB 画像から最適な組み合わせを探索する. 基本モデルは Li et al. 2018 のモデルと同様のものを用いる. 学習の手順としては, まず Perception Module にサブタスクを学習させ, 得られた重みを固定した状態で Driving Module の運転行動生成の学習を行う. 4通りのサブタスクの組み合わせで実験を行う. サブタスクの組み合わせを図3に示す. それぞれ Li et al.2018 と同じ実験環境とデータセットを使用して実験を行う.

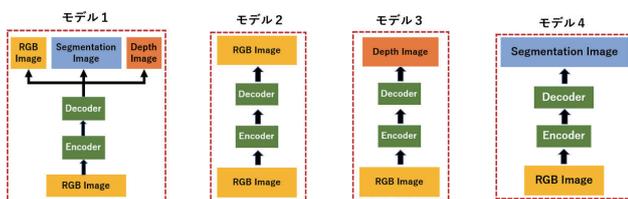


図 3: Perception Module のサブタスクの組み合わせ

4. 実験

本実験では CARLA シミュレーターを使用する [5]. CARLA シミュレーターには 2つの街が用意されており, 道路と天気の状態を 14種類から設定できる. 本実験では未知の環境での汎化性能を確かめるために, 表1の1から4の天気道路状況を用いて学習データを収集し, 5,6の天気道路状況でのテストを行った. 表1に示す天気と道路の状態でのシミュレーター画像の例を, 図4に示す.

表 1: 学習とテストに用いた天気と道路の様子

	天気	道路	時間		天気	道路	時間
1	晴	乾	昼	4	晴	乾	夕
2	晴	湿	昼	5	曇り	湿	昼
3	大雨	湿	昼	6	小雨	湿	夕



図 4: 学習とテストに用いた天気と道路の様子

またテスト時のタスクは, Li et al. 2018 と同様に, 1:直線路の走行, 2:一つのカーブを含むコースの走行, 3:ナビゲーションによる方向指示に従った走行, 4:ナビゲーションに従い, 動いている歩行者と車を含む複雑な環境での走行, とする. それぞれのタスク設定について, 2種類の天気道路の状況 (表1の5,6) で25回ずつ走行させ, 平均完走率を計算する.

5. 結果と考察

4種類のタスク設定での走行における, サブタスク設計ごとの完走率を図5に示す. 縦軸は50回(2種類の天気道路状況で25回ずつ)の走行テストでの完走率を表す. この結果より, サブタスクを Semantic segmentation のみとした場合が, 未知の環境での完走率が最も高いことが分かった.

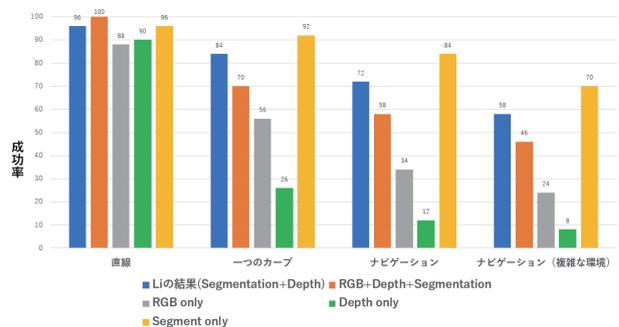


図 5: 各サブタスク設計での完走率の比較

Perception Module によるサブタスクの画像生成の例を図6に示す. Semantic segmentation のみをサブタスクとするモデルの生成結果が図6(a), Semantic segmentation および Depth をサブタスクとするモデルの生成結果がそれぞれ図6(b)(c)であ

る。Depth 情報をサブタスクに含むモデルが生成した Semantic segmentation 画像では、道路として認識されるべき部分が正しく認識されていないことが確認できる。

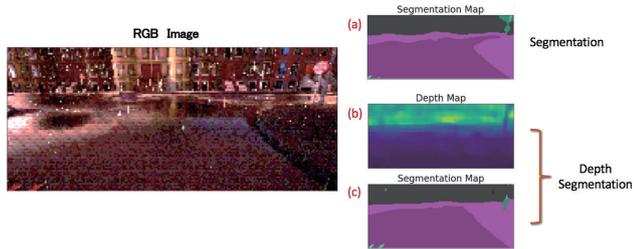


図 6: 生成した Segmentation 画像の比較

6. 現ベンチマークの課題

現状のテスト用ベンチマークは、途中で歩行者や車と衝突しても失敗ならず、試行は継続される。前述の実験においても、Depth 情報を考慮しないモデルでは、障害物に衝突しながらもゴールに到達した試行が観測された。また、試行の制限時間が設定されており、時間内にゴールに到達できなかった場合は失敗となる。Depth 情報を考慮したモデルは障害物に衝突せずに慎重な運転をしていたが、この制限時間によって失敗となるケースが多かった。以上の理由から、このベンチマークはモデルに求められる性能を正しく評価できるとは言えない。

7. 新しいベンチマークでの追加実験

以上の理由から、新しいベンチマークを用いて追加の評価実験を行った。街の様子と道路、天気の状態は以前のベンチマークと同様であるが、今回は3種類のテスト用タスクがある。いずれのタスクにおいても、ナビゲーションによる方向指示に従った走行を行う。歩行者、車、建物と衝突すると失敗となり、次の試行に移る。また、制限時間は元のベンチマークよりも長く設定した。新ベンチマークは実際の自動運転の性能のニーズに沿った評価基準であると言える。新ベンチマークについての詳細は表 2 に表す。

表 2: 新ベンチマークのセットアップ

タスク	Empty Town : 方向指示に従って走る 歩行者 : 0 人 車 : 0 台 Normal Town : 方向指示に従って走る 歩行者 : 15 人 車 : 50 台 Cluttered Town : 方向指示に従って走る 歩行者 : 70 人 車 : 150 台
評価方法	他の車や人に衝突すると失敗。次の試行に移る

8. 追加実験の結果と考察

Li et al. 2018 のモデル (Semantic segmentation と Depth をサブタスクとする) と、Semantic segmentation のみをサブタスクとするモデルで実験を行なった。図 7 に示すように、Li et al.2018 のモデルは Task1 : 56 % , Task2 : 28 % , Task3 : 14 % . Semantic segmentation のみのモデルは Task1 : 60 % , Task2 : 39 % , Task3 : 17 % となった。この結果より、新ベンチマークにおいても、Semantic segmentation のみをサブタスクとするモデルの方が高い性能となることを証明した。

%, Task2 : 39 % , Task3 : 17 % となった。この結果より、新ベンチマークにおいても、Semantic segmentation のみをサブタスクとするモデルの方が高い性能となることを証明した。

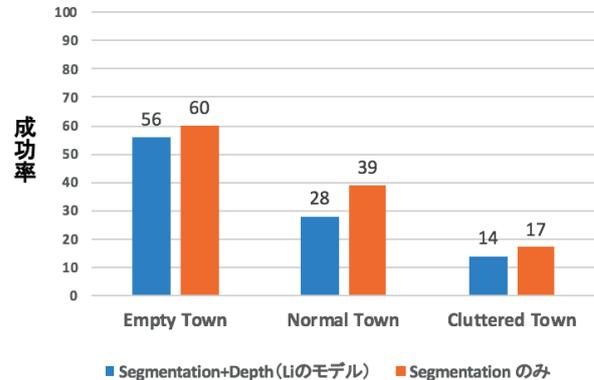


図 7: 新ベンチマークにおける結果の比較

しかし、歩行者と車が多く混雑している状況、すなわち Cluttered Town (歩行者:70 人, 車:150 台) の場合は、Semantic segmentation のみのモデルの完走率は 17 % に留まった。動的な物体に対応するための改善手法として考えられるのは、時系列情報の考慮である。一定の時間幅を持つデータを入力として用いることができると考えられる。具体的には、図 8 に示すように、Perception Module による画像特徴量および方向指示に加えて、時刻 $t-5 \sim t-1$ のステアリング、時刻 $t-5 \sim t$ のスピードを Driving module の入力として、運転行動を生成するというモデルが考えられる。

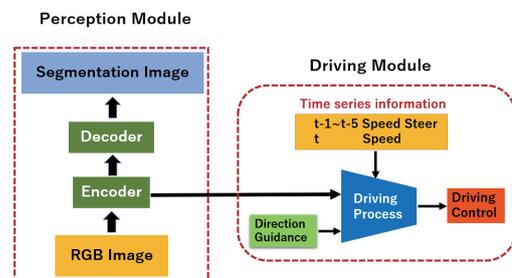


図 8: 時系列情報を考慮したモデル

9. まとめ

本研究では、自動運転において未知の環境での汎化性能を改善することを目的とし、Li et al.2018 の研究をもとに、サブタスクの内容を検討した。異なるサブタスク設計のモデルで、Li et al.2018 の研究で用いられた旧ベンチマーク、及びより実用に近い新ベンチマークで走行性能の比較を行った。結果として、どちらのベンチマークにおいても Semantic segmentation のみをサブタスクとして用いたモデルが最も完走率が高くなった。

一方で、動的な物体への対応が困難であるという課題が示された。この問題を解決するため、今後は時系列情報を使用したモデルの研究を進めていきたい。

参考文献

- [1] Chenyi Chen, Ari Seff, Alain Kornhauser, Jianxiong Xiao. DeepDriving: Learning Affordance for Direct Perception in Autonomous Driving arXiv:1505.00256 2015
- [2] Mariusz Bojarski, Davide Del Testa, Daniel Dworakowski, Bernhard Firner, Beat Flepp, Prashoon Goyal, Lawrence D. Jackel, Mathew Monfort, Urs Muller, Jiakai Zhang, Xin Zhang, Jake Zhao, Karol Zieba. End to end learning for self-driving cars, arXiv preprint arXiv:1604.07316, 2016b
- [3] Felipe Codevilla, Matthias Mller, Antonio Lopez, Vladlen Koltun, Alexey Dosovitskiy End-to-end Driving via Conditional Imitation Learning .arXiv:1710.02410, 2017
- [4] Zhihao Li, Toshiyuki Motoyoshi, Kazuma Sasaki, Tetsuya Ogata, Shigeki Sugano. Rethinking Self-driving: Multi-task Knowledge for Better Generalization and Accident Explanation Ability. arXiv:1809.11100, 2018
- [5] Alexey Dosovitskiy, German Ros, Felipe Codevilla, Antonio Lopez, Vladlen Koltun et al. CARLA: An Open Urban Driving Simulator. arXiv:1711.03938 2017

CNNによる深度予測に基づく鏡を活用した死角の物体知覚

Object Perception in the Blind Spots with Mirror Based on Depth Prediction Using CNN

内海 佑斗 北川 晋吾 矢野倉 伊織 岡田 慧 稲葉 雅幸
Yuto Uchimi Shingo Kitagawa Iori Yanokura Kei Okada Masayuki Inaba

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

Object perception in the occluded region is required for mobile robots, and it may be effective to use mirrors placed at the intersection, in the elevator and so on in order to see something in the blind spots. However, mirrors are difficult to recognize their 3D position by sensing due to high reflectivity. This paper proposes a method of predicting pixel-wise depth of mirror by using CNN. It also proposes a method of flipping object point cloud obtained from sensors along detected mirror plane, which renders virtual objects inside the mirror in real space. By using our point cloud flipping method, robots can percept a person standing at the blind corner.

1. はじめに

自律移動ロボットが建物内や道路上など様々な遮蔽物を含む環境下で活動するにあたって、遮蔽物の先の状況を把握することが重要である。特に交差点のような見通しの悪い環境にはカーブミラーが設置されている場合が多いほか、エレベータ内にも後方確認のため鏡が設置されているなど、鏡を活用した死角のカバーは有効であると考えられる。しかし鏡はその性質上反射率が1に近いためセンシングによる三次元的な位置認識が困難であり、したがって鏡を手がかりとした死角の状況予測のために鏡の位置推定が課題となっている。

近年、環境の三次元復元のために色画像を用いた多層畳み込みネットワークによる深度画像予測の手法の有効性が明らかになってきた [Wang 15] [Eigen 14]。一方でロボットには色画像のみでなく深度画像も取得可能な RGB-D カメラセンサが既に広く搭載されており、これによる深度計測が困難な鏡のような領域の深度画像のみの予測を行えばすむようになっている。これに対応して RGB-D を CNN の入力に用いる研究 [Uchimi 18] も存在するが、RGB と RGB-D の 2 種類の学習データを交互に入力に用いて、誤差逆伝播を行う層をイテレーションごとに切り替えながら学習するため、学習に長時間を要して十分に精度が上がらないという課題があった。そのため本研究ではこれを改良し、特徴量を抽出する前に入力画像を連結することで鏡面マスクと深度画像を予測するネットワークを提案する。

化粧台や姿見などの鏡は通常平面鏡である一方、道路上のカーブミラーは広視野確保のため凸面鏡が用いられていることが多い。いずれの場合もレイトレーシングにより死角の物体三次元位置の復元が可能であるが、鏡面の各点に対し法線方向を求めそれに基づいて復元を行うのは多大な計算量を要すると考えられる。したがって本研究では検出された鏡を近似的に平面鏡として扱うことにより、鏡平面に関して一括で 3 次元点群を対称移動させる手法を提案する。

本研究の提案手法の有用性を検証するため、廊下の交差点に反射鏡を設置し、ロボットの死角に存在する人間を検知する実験を行う。

連絡先: 内海佑斗, 東京大学工学部情報システム工学研究室,
113-8656 東京都文京区本郷 7-3-1 工学部 2 号館 7 階 73B2,
03-5841-7416, uchimi@jsk.imi.i.u-tokyo.ac.jp

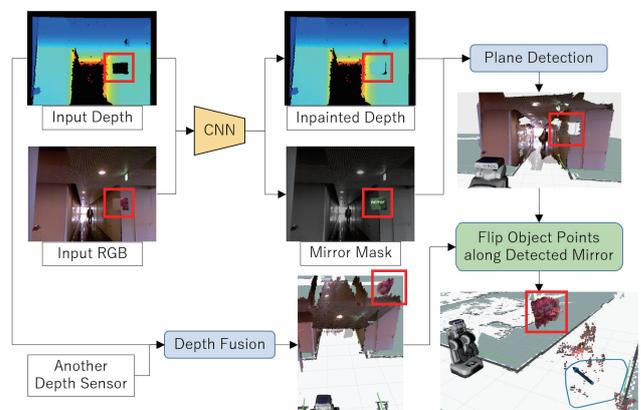


図 1: 提案システムの概観

2. 鏡面深度情報を持つ学習データセットの生成

教師あり学習による深度予測を行うために、鏡面の教師マスクおよび深度データを取得する必要がある。まずロボットが鏡のある環境を複数視点から撮影することで実環境データを収集する。続いて、収集した環境上に鏡の CAD モデルを 3 次元配置することで鏡の位置および姿勢をアノテーションし、カメラ視点での鏡のマスクおよび深度画像を生成する。なお、本研究では台座や縁などを含む物体としての鏡ではなく、光が反射する鏡面のみをマスクおよび深度情報が必要なものに留意しておく。

2.1 ロボットを用いた半自動センサデータ収集

ロボットに搭載された RGB-D カメラセンサを用いて実環境の色画像 I_{real} と深度画像 D_{real} を撮影し、さらに環境に固定された座標系で表現したカメラの位置姿勢 R_{cam}^{world} を同時に取得する。またこれらに加えて、レンダリングのためカメラ内部パラメータ K を保存しておく。

以下では鏡が環境に固定されている限り同一のシーンであると呼ぶ。このような鏡が環境に固定されている場合を仮定すれば、ロボットを用いて複数視点から自動的に環境を撮影したとしても、人間がアノテーションを行うのは各シーンに対し一

度ですむ。すなわち、同一シーンでは環境に固定された座標系で表現された鏡の位置姿勢 R_{mirror}^{world} は一定であるため、カメラ座標系で表現された鏡の位置姿勢は式 (1) により自動計算される。

$$R_{mirror}^{cam} = (R_{cam}^{world})^{-1} R_{mirror}^{world} \quad (1)$$

実環境データの収集はロボットが移動したり視線を変えたりしながら無造作に撮影する方法で構わないが、通常環境で鏡が設置されている場所はそれほど多くないため、鏡の写ったデータを十分な数だけ確保しにくいという問題が生じる。そこで本研究ではあらかじめ人が鏡の配置されている大まかな直方体領域を注目領域としてロボットに与えておき、ロボットがその周辺を重点的に自動撮影するという手法をとった。

2.2 鏡のメッシュモデルを用いた3次元空間でのアノテーション

2.1 項で収集した I_{real} , D_{real} , R_{cam}^{world} を用いれば実環境の色付き点群を3次元再構成することが可能である。この点群を参照しながらそのシーンに写っている鏡の3次元モデルをアノテーションし、各視点での鏡の位置及び姿勢を取得する。本研究では ShapeNet データセット [Chang 15] からダウンロードした物体3次元メッシュモデルの一部を必要に応じて拡大縮小することで鏡のモデルとして扱った。

アノテーションの後、各視点について鏡の位置姿勢 R_{mirror}^{cam} と実環境深度画像 D_{real} およびカメラパラメータ K を与えてレイキャスティングを行い、教師データとして用いる鏡面のマスク M_{gen} および合成深度画像 D_{gen} を生成し、データセットとする。なお、RGB-D カメラセンサによる計測可能範囲と各視点における鏡の位置を考慮して、合成深度画像 D_{gen} については深度の範囲を $[d_{min}, d_{max}]$ になるよう制限する。本研究では $d_{min} = 0.5m$, $d_{max} = 5.0m$ とした。

3. CNN による鏡面検出と深度予測

本節では多層畳み込みネットワークによる鏡面のセマンティックセグメンテーションおよび深度予測を行う。ネットワークの入力に用いるのは RGB-D カメラセンサから取得した実環境色画像 I_{real} および深度画像 D_{real} であり、教師信号として2. 節で生成した鏡面マスク M_{gen} および合成深度画像 D_{gen} を用いる。

3.1 ネットワーク構造

本研究では鏡面の検出と深度予測を画素毎に行うことが求められるため、セマンティックセグメンテーションタスクにおいて大きな成果を上げている FCN-8s at-once [Shelhamer 16] をもとにしたネットワーク (図 2) を提案する。提案するネットワークは大まかに2つのネットワークからなり、そのうち1つはセマンティックセグメンテーションを行う分類ネットワークで、もう一方は深度画像予測を行う回帰ネットワークである。分類ネットワーク、回帰ネットワークともに事前学習済みの VGG16 [Simonyan 14] モデルの fc7 層までを用いて重みを初期化しており、特に pool5 層までを特徴量抽出器として扱う。ただし回帰ネットワークの入力は3チャンネル色画像 I_{real} と、センサから取得した深度画像 D_{real} を変換した3チャンネル深度画像 D_{color} の2つを連結させた6チャンネル画像とするため、conv1.1 層のみ重みを複製して6チャンネルに対応させている。 D_{color} については3.3 項で説明する。

ネットワークの学習手順として、各イテレーションごとにまず分類ネットワークの順伝播を行う。最終層は入力画像と同じ幅、高さを持つ2チャンネル確率画像 P_{pred} を出力し、各画素

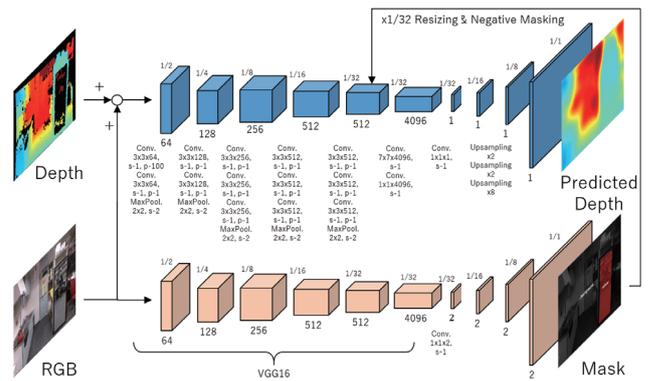


図 2: 提案ネットワークモデル. 左上: 入力深度画像 D_{color} , 左下: 入力色画像 I_{real} , 右上: 深度予測結果 D_{pred} , 右下: 予測マスク M_{pred}

について argmax をとることにより予測マスク M_{pred} を得る。続いて回帰ネットワークの特徴量抽出器の順伝播を行い、その出力 512 チャンネル画像を D_{pool5} とする。その後教師マスク M_{gen} を画像サイズ $1/32$ 倍になるようリサイズして $M_{1/32}$ とし、式 (2) に従って D_{pool5} のうち鏡領域の値を 0 にするマスキング処理を行う。

$$D_{masked} = D_{pool5} \overline{M_{1/32}} \quad (2)$$

回帰ネットワークではこれにより得られる 512 チャンネル画像 D_{masked} を fc6 層への入力とする。出力層はシグモイド関数で活性化され、これに対し予め決められた深度範囲 ($d_{min} - \epsilon$, $d_{max} + \epsilon$) になるようスケリングして予測深度画像 D_{pred} を出力する。 ϵ は教師信号が d_{min} や d_{max} を含む際に誤差逆伝播で重みの値が発散しないように設けている値で、本研究では $\epsilon = 0.1m$ とした。以上は学習時の手順であったが、推論時にはマスキング処理に教師マスク M_{gen} を用いることができないため、予測マスク M_{pred} をリサイズして用いる。

3.2 損失関数

分類ネットワークの損失関数は出力 P_{pred} に対して教師信号 M_{gen} とする Softmax Cross Entropy を採用する。

$$L_{cls} = -\frac{1}{n_{pix}} \sum_{i=0}^{n_{pix}-1} \sum_{j=0}^{n_{cls}-1} I(M_{gen}^{i,j}) \log(\text{Softmax}(P_{pred}^{i,j})) \quad (3)$$

一方、回帰ネットワークの損失関数は出力 D_{pred} と教師信号 D_{gen} の差をとり、これの双曲線余弦の対数の画素平均をとることとする。双曲線余弦の対数は極限を調べると式 (4), 式 (5) のようになっていることが計算される。 $x = 0$ 近傍で勾配が滑らかに 0 に近づき、 $|x| \rightarrow \infty$ では直線に漸近する性質を持つ関数であるため、MSE に比べ外れ値の影響を受けにくい。

$$\lim_{x \rightarrow 0} \log(\cosh(x)) \simeq \frac{1}{2} x^2 \quad (4)$$

$$\lim_{|x| \rightarrow \infty} \log(\cosh(x)) \simeq |x| - \log 2 \quad (5)$$

本研究の提案システムでは鏡と予測された領域以外についてはセンサから取得した深度をそのまま利用するため、この領域について回帰を行うことは必要ではない。しかし鏡領域のみの深度を予測するようネットワークを学習するとセグメンテーシ

ンの間違いに対して頑健でなくなってしまうため、本研究ではフェイルセーフとして画像全領域の深度についても学習させることとする。画像全領域の損失関数は式 (6) のように与えられ、また鏡領域のみの損失関数は式 (7) のように与えられる。

$$L_{reg}^{all} = \frac{1}{n_{pix}} \sum_{i=0}^{n_{pix}-1} \log(\cosh(D_{pred}^i - D_{gen}^i)) \quad (6)$$

$$L_{reg}^{mask} = \frac{1}{\sum(M_{gen}^i)} \sum_{i=0}^{n_{pix}-1} \log(\cosh(D_{pred}^i - D_{gen}^i)) M_{gen}^i \quad (7)$$

分類ネットワークと回帰ネットワークを統合させたネットワーク全体の損失関数 L_{total} は式 (8) により定義する。

$$L_{total} = L_{cls} + \lambda_1(L_{reg}^{all} + \lambda_2 L_{reg}^{mask}) \quad (8)$$

本研究では $\lambda_1 = \lambda_2 = 1$ とした。

3.3 入力データ前処理およびデータ拡張

回帰ネットワークへの入力には 3 チャンネル色画像 I_{real} および 3 チャンネル深度画像 D_{color} であった。 D_{real} から D_{color} への変換については、まず D_{real} を D_{gen} 同様に $[d_{min}, d_{max}]$ の範囲に制限し、さらに $[0, 255]$ の範囲になるようスケールリングし、このグレースケール画像を JET カラーマップで 3 チャンネル画像にすることで D_{color} を得る。

また、 I_{real} に対するデータ拡張として RGB 色空間の各色および HSV 色空間の S, V に対しランダムな値を加えたほか、ガウシアンぼかしとガウシアンノイズを適用した。 D_{color} に対しては各画素をランダムに黒色にした。幾何的なデータ拡張の多くは 3 次元情報を損なうことから本研究において適用できないが、上下左右の画像反転および回転のみ許すこととした。

以上のデータ拡張の後、ネットワークへの入力色画像 I_{real} および深度画像 D_{color} は ImageNet [Krizhevsky 12] の平均 RGB 輝度値を引いて用いることとした。

4. 検証実験

検証実験では、まず鏡面マスクと深度予測を行う提案ネットワークを学習させた際の精度を先行研究と比較する。続いて建物内の廊下の交差点において、ロボットの死角にいる人間を鏡を活用して検出する実験を行う。

4.1 鏡面検出と深度予測を行うネットワークの検証実験

本研究の提案ネットワークとの比較対象として、色画像と深度画像からそれぞれ特徴量を抽出した上で特徴量画像の連結を行う CNN [Uchimi 18] を用意する。学習データセットは訓練データとして 1440 枚、テストデータとして 360 枚を用意し、バッチサイズ 1 で 100 エポック学習させた。最適化手法として Adam [Kingma 14] を用いることとし、ハイパーパラメータの初期値 $\alpha = 10^{-5}$ とした。また重み減衰係数 0.0005 とし、1 イテレーションごとに α の値を 0.99997 倍することで学習終盤にかけて徐々に学習率が下がるようにした。

表 1 に、比較対象のネットワークと本研究で提案するネットワークそれぞれによるセマンティックセグメンテーションの Mean IoU と深度画像予測の精度を評価した実験の結果を示す。深度画像予測の精度は、単に画像全領域に関して RMSE を計算するのではなく式 (9) に示す評価指標を用いており、 M_{gen} と M_{pred} の和集合部分のうち、その積集合部分かつ深度予測誤差の絶対値が d 未満である画素の割合を計算したものである。

$$acc_{depth,d} = \frac{\sum(M_{gen} \cap M_{pred} \cap \{|D_{gen} - D_{pred}| < d\})}{\sum(M_{gen} \cup M_{pred})} \quad (9)$$

表 1: 特徴量連結ネットワークと提案ネットワークの鏡面マスクおよび深度画像予測結果

Network	mIoU	$acc_{depth,d}$		
		$d=3\text{cm}$	$d=10\text{cm}$	$d=30\text{cm}$
Concat. Features [Uchimi 18]	0.885	0.273	0.640	0.777
Ours	0.937	0.288	0.698	0.870

表 1 から、特徴量抽出後に連結を行うネットワークよりも本研究の提案ネットワークの方がマスク予測精度が高いことがわかる。また、深度予測精度 $acc_{depth,d}$ は d に関する単調増加関数であるが、 $d \in \{3\text{cm}, 10\text{cm}, 30\text{cm}\}$ のいずれについても本研究の提案ネットワークが高い精度を達成している。

4.2 鏡を用いた曲がり角の死角にいる人の位置認識実験

本項では建物内の廊下の交差点に反射鏡が設置されている環境を想定し、ロボットが交差点の先の死角にいる人間の存在を反射鏡を用いて知覚する実験を行う。本実験では鏡として平面鏡を仮定し、提案ネットワークによって予測された鏡面の深度を用いて平面検出により鏡面の法線を推定する。そして鏡に写った人間の 3 次元点群を鏡面に関して対称移動させることで実際に人間が存在する 3 次元位置を推定する。なお、鏡に写った人間はロボットから比較的遠く、RGB-D カメラセンサで距離を計測するのが困難であるため、本実験では 2 つの RGB カメラによるステレオ視で鏡に写った物体の 3 次元位置を計算するものとする。

平面の方程式が式 (10) で表されるとき、 $c \neq 0$ とすればこの平面に関する対称変換 R は式 (11)、式 (12) で求められる。

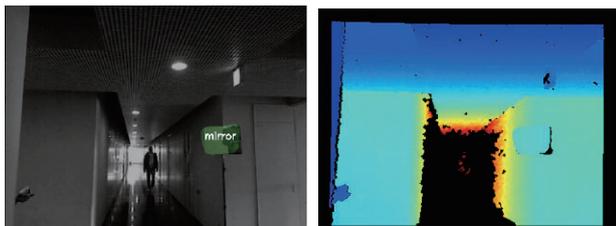
$$ax + by + cz + d = 0 \quad (10)$$

$$R = P^{-1}(I - 2\mathbf{u}\mathbf{u}^T)P \quad (11)$$

$$\mathbf{u} = \frac{1}{\sqrt{a^2 + b^2 + c^2}} \begin{pmatrix} a \\ b \\ c \\ 0 \end{pmatrix}, P = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \frac{d}{c} \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (12)$$

したがって RGB-D カメラセンサから得られた 3 次元点群のうち、鏡と推定された領域 M_{pred} に対応する点群をこの R によって移動させることで鏡面に関して反転した点群が得られる。

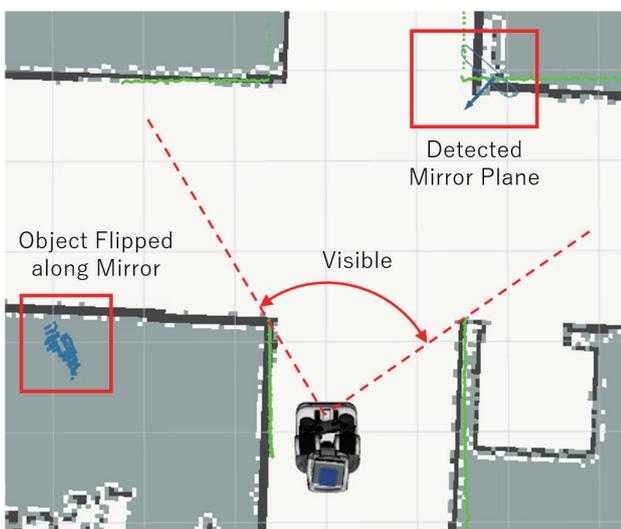
図 3 に、交差点において反射鏡の深度予測を行い、鏡に写った物体の点群を反転させた実験の様子を示す。図 3 において、交差点の角に設置された反射鏡が概ね正しく認識され、深度が予測されている様子が M_{pred} および $D_{inpaint}$ から確認できる。ここで、 $D_{inpaint}$ とは実環境深度画像 D_{real} のうち予測鏡面マスク M_{pred} の領域を予測深度画像 D_{pred} で置き換えることで修復した深度画像である。ロボットの RGB-D カメラから鏡を介さず直接確認できるのは、交差点を左折した先にいる人の手と廊下の奥にいる人である。ロボット台車部には LRF が搭載されているものの、曲がり角にいる人の脚は壁に阻まれて感知できていない。一方、ロボットカメラ視点で鏡には人



可視化された予測鏡面マスク 可視化された修復深度画像
 M_{pred} $D_{inpaint}$



第三者視点から眺めた様子



鳥瞰図による鏡平面検出結果 (紺) と LRF 計測結果 (黄緑) および反転された点群 (青) の可視化

図 3: 交差点の反射鏡を用いた死角の物体検知の様子. ロボットの RGB-D カメラによって壁際の人の手は鏡を介さず確認できるが、それ以外は死角に入っているため低位置にある台車の LRF で感知できない. 鏡に写る人間を鏡平面で反転させることで、死角の人間の点群が表現されている.

の体の一部が写っており、この点群が式 (11) によって反転され、鳥瞰図で青い点群として表現されている. この青い点群はロボットの視野外に表示されており、鏡を利用した死角の物体知覚の実現が確認できる. ところで鏡の位置は誤差約 0.2m 以内で概ね正しく予測されているものの、鏡で反転された人の点群は実際の位置 (ロボットの視野からわずかに外れた場所) から鏡と反対方向に約 1.5m 離れた位置に表示されてしまっている. これはステレオマッチングアルゴリズムにより復元された鏡の中の物体 3 次元点群の位置誤差によるものと考えられ、パラメータの調整や別の深度センサの利用により改善されると期待される.

5. 結論

本研究では、自律移動ロボットが鏡を活用して遮蔽物のある環境の死角をカバーするため、CNN を用いて鏡領域のセマンティックセグメンテーションと深度予測を同時に行い、鏡と判定された領域に写る物体 3 次元点群を鏡面に関して対称移動させることで死角の物体を知覚可能にする手法を提案した. 検証として、本研究で提案した CNN が既存の深度予測ネットワークに比べ同一データセットに対し高い予測精度を達成することを確認した. また、建物内の廊下の交差点に平面鏡が設置されている環境で、交差点を曲がった先にいる人間の点群が鏡を介して表現可能であることをロボット実機を用いて確認した.

ロボットによる死角の状況把握は、実際に移動する際に人やものとの衝突を回避する上で必要となる. 今後は本研究を応用して、死角に物体を検知した際にロボットの移動経路を再計画し、一時停止や回避ルートの実現することを目指す.

参考文献

- [Chang 15] Chang, A. X., et al.: ShapeNet: An Information-Rich 3D Model Repository, Technical Report arXiv:1512.03012 [cs.GR], Stanford University — Princeton University — Toyota Technological Institute at Chicago (2015)
- [Eigen 14] Eigen, D., et al.: Depth Map Prediction from a Single Image using a Multi-Scale Deep Network, in *Advances in Neural Information Processing Systems 27*, pp. 2366–2374, Curran Associates, Inc. (2014)
- [Kingma 14] Kingma, D. P., et al.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980, (2014)
- [Krizhevsky 12] Krizhevsky, A., et al.: ImageNet Classification with Deep Convolutional Neural Networks, in Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q. eds., *Advances in Neural Information Processing Systems 25*, pp. 1097–1105, Curran Associates, Inc. (2012)
- [Shelhamer 16] Shelhamer, E., et al.: Fully Convolutional Networks for Semantic Segmentation, *CoRR*, Vol. abs/1605.06211, (2016)
- [Simonyan 14] Simonyan, K., et al.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, Vol. abs/1409.1556, (2014)
- [Uchimi 18] Uchimi, Y., et al.: Depth Image Prediction for Transparent Objects and its Application to Home Assistant Robot Based on Automatic Training Data Generation Using Mesh Model, *Proceedings of the Annual Conference of JSAI*, Vol. JSAI2018, pp. 3L202–3L202 (2018)
- [Wang 15] Wang, P., et al.: Towards Unified Depth and Semantic Prediction From a Single Image, in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2015)

把持位置学習モデルを用いた物体形状分類のための 中間層出力の絞り込み

Filtering of Middle Layer Outputs for Object Classification
Using a Model Trained Detecting Grasping Positions

横田 泰斗*¹ 鈴木 彼方*¹ 金澤 裕治*¹ 竹林 知善*¹
Yasuto Yokota Kanata Suzuki Yuuji Kanazawa Tomoyoshi Takebayashi

*¹富士通研究所
Fujitsu Laboratories LTD.

We propose a new method to filter middle layer outputs for object classification using a model trained only detecting grasping positions. Industrial robots have to detect grasping positions and classify objects at the same time for the picking task, when objects of different shapes are mixed. One of conventional methods for learning multiple tasks is using middle layer outputs of a deep neural network. However, simple middle layer outputs can not classify objects, when there are multiple objects in the input image. As a solution to this problem, we propose a method with filtering of middle layer outputs by backpropagation. We experiment with the object classification using our method. The results of our experiment show that our proposed method can classify objects using a model trained only detecting grasping positions, even when the input image has multiple objects.

1. はじめに

製造業の分野では、生産ラインの自動化のために製品や部品の把持(ピッキングタスク)を行うロボットが広く普及している。近年、ディープニューラルネットワーク(Deep Neural Network, 以下 DNN)をピッキングタスクに適用する研究が進んでおり [Bousmalis 18], 特に、深層強化学習 [Levine 16] や、試行結果から学習データを逐次的に追加する能動学習 [Pinto 16][鈴木 18] が注目されている。一般的にピッキングタスクでは、ある特定の物体が写った入力画像に対して把持位置情報を正解ラベルとして付与した訓練データを学習させることで把持位置検出タスクを行う。そのため、これらの研究ではその他のタスク追加は考慮されていないことが多い。

しかしながら、実際の工場や倉庫におけるピッキングタスクでは複数の形状の物体が混在しているケースがあり、把持位置検出と物体形状分類のマルチタスクの実施が求められる。1つのモデルに物体把持動作と物体形状分類のマルチタスクを埋め込んで学習させる手法 [Jang 18] も考案されているが、学習に膨大な時間を要するため実用的ではない。

一方、複数タスクを別々に学習する手法では、DNN の中間層から出力される特徴量を利用する手法 [Kodirov 17] などが一般的である。ピッキングタスクに関する従来研究においては、把持位置検出タスクを学習させたモデルの中間層出力を用いることで、物体形状分類などの別の分類タスクを遂行可能であることが確認された [横田 18]。しかし、単純に取得した中間層出力では、入力画像中に複数の物体が存在するケースでは分類できない。これは、DNN には中間層が複数あり、どの層の特徴量を用いたらよいか既知ではないこと、また、複数の物体に関する特徴量が合成された状態で出力されることが原因である。

そこで、本稿では上記の課題を解決するために、把持位置検出タスクにおける推論に寄与した DNN の中間層出力を選択する手法、及び、絞り込んだ特徴量を利用した物体形状に関する分類手法を提案する。把持位置検出タスクにおいては物体形状も重要な要素のため、モデルで獲得される中間特徴量には、形状分類に適した特徴が現れていると期待される。

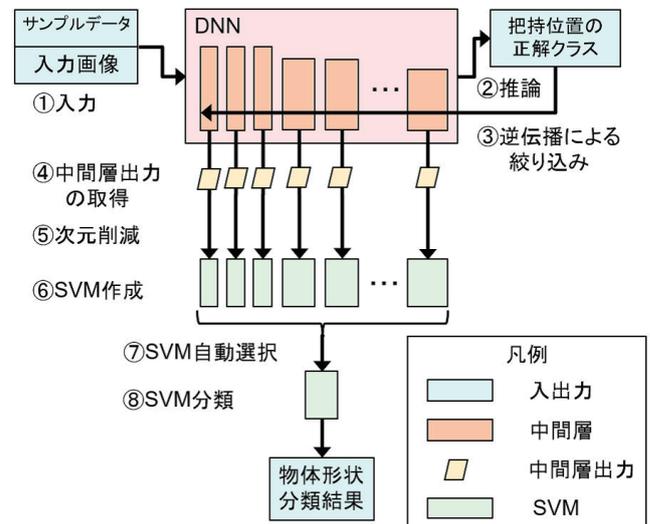


図 1: 提案手法の概要

提案手法の有用性を検証するために、入力画像中に物体が単体で存在するケース、同じ形状の物体が複数存在するケース、異なる形状の物体が複数混在するケースの 3 つの設定における評価実験を行った。

2. 提案手法

提案手法の概要を図 1 に示す。把持位置検出を行う DNN モデルには Single Shot Multibox Detector (SSD)[Liu 16] を、物体形状分類器にはサポートベクターマシン (Support Vector Machine, 以下 SVM) を用いた。SSD に把持位置検出タスクのみを学習させた後 [横田 18], 形状分類に関するタスクを解く際には、各層の中間層出力に対して、検出した把持位置ごとに逆伝播を用いて絞り込む。推論時に寄与した中間層出力だけを取得することで、複数物体が混在する入力画像でも特定の物体に関する特徴量を選択することが可能となる。その後、上記

の中間層出力の分布から分類に適した特徴量を抽出するために次元削減を行う。次元削減により得られた特徴量を、事前に上記の手順と同様に準備したサンプルデータの特徴量と比較することで物体形状分類を実施する。

次に、把持位置検出タスクを学習後の SSD における中間層出力の絞り込み手法と、SVM を用いた取得した特徴量に関する物体形状分類手法の詳細を述べる。

2.1 逆伝播を用いた中間層出力の絞り込み

先に述べたとおり、入力画像中には複数の物体や把持位置が存在するケースがあるため、検出された把持位置ごとに推論結果に寄与した中間層出力に絞り込む必要がある。推論結果に対する中間層の各ノードの寄与度を計測する方法のひとつとして、正解クラスの誤差を 1、それ以外のクラスの誤差を 0 として逆伝播を実施し、各ノードの勾配の大きさを寄与度とする方法が挙げられる。これは、正解クラスのみにも誤差を設定して逆伝播させると、正解クラスの出力に及ぼす影響が大きいノードほど損失関数の勾配も大きくなると考えられるためである。

本手法では検出された把持位置ごとに、その把持位置を唯一の正解クラスとして逆伝播を行い、各ノードの勾配の絶対値と推論時の出力値の積を中間層出力として取得する。その際、入力に近い層までノイズの少ない勾配を算出するために、各ノードの出力を伝播時に減衰させない逆伝播手法である Guided Backpropagation[Springenberg 15] を用いる。

2.2 各中間層ごとの分類器による物体形状分類

はじめに、把持位置検出タスクを学習した SSD に上記の絞り込み手法を適用することで、物体形状ごとにサンプルデータの推論を行い、中間層出力を取得して蓄積する。この時、SVM 作成時にサンプルデータの物体形状情報が必要になるため、物体形状が判別できる情報も併せて保存する。

次に、蓄積したサンプルデータを用いて各層の中間層出力の次元削減を行い、特徴量を抽出し、物体形状を分類する SVM を作成する。その際、物体形状の分類に最も適した中間層を絞り込んで自動選択するために、全ての SVM に対してサンプルデータの特徴量での分類精度を求める。

上記で作成した各 SVM にはグリッドサーチにより、サンプルデータに対して自動最適化したエラー項のパナルティパラメータを用いる。これにより、分類精度が最大となった中間層の SVM を使用して、入力画像の分類結果を出力することが可能である。また、推論時には入力画像に対して同様に上記の中間層出力の次元削減処理を行うが、この際、事前作業で蓄積した全てのサンプルデータの中間層出力も含めて次元削減処理を実施する。これは、全種類の物体形状を含むデータに対して次元削減することで、物体形状との相関が高い特徴量を多く残すためである。

3. 評価実験

3.1 実験設定

提案手法の有効性を確認するため、把持位置検出タスクのみを学習させたモデルを用いて 3 種類の実験を行い、物体形状の分類精度を確認した。把持位置学習モデルである SSD は入力画像 $300 \times 300 \times 3$ [pix] 中の物体の把持位置 (x, y, w, θ) を複数出力する。SSD の訓練データは、1 つの物体に対して複数の位置に正解ラベルを設定した画像を 2000 セットを用意し、200 エポック学習させた。最適化には Adam を用いた。

訓練データの画像は円柱、L 字、星形、T 字の 4 種類の形状の物体のいずれか 1 つがランダムな位置に配置されたもの

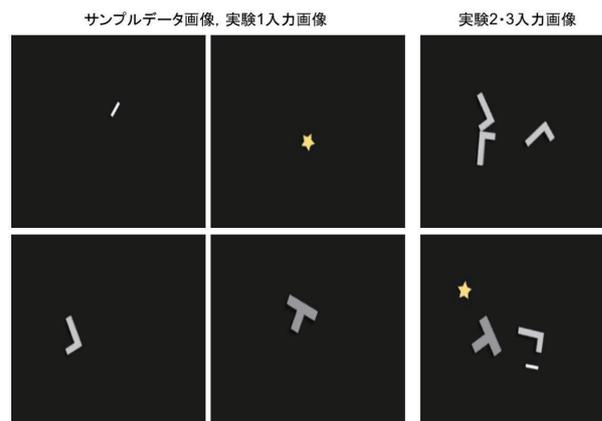


図 2: シミュレータで作成した画像例

を使用した。これらの画像は、把持位置の正解ラベルと併せてシミュレータで自動生成しており、提案手法のサンプルデータとテストデータについてもシミュレータで作成した画像 (図 2) を使用した。なお、サンプルデータの画像は、訓練データ同様、円柱、L 字、星形、T 字の 4 種類のうち 1 個の物体がランダムな位置に配置されたものを用いた。また、次元削減には主成分分析 (PCA) を用い、SVM のカーネルには RBF を用いた。対象とする中間層は、SSD の 1-1 層から 11-2 層まで全ての畳込層 (合計 23 層) とする。SSD モデルの構造上、後半の層 (5-1 層以降) を通らない出力があるため、逆伝播時に後半の層の勾配が全て 0 となるケースがある。その場合は、前半の中間層のみを対象とする。

実験 1 では、物体単体に対する分類精度を評価する。テストデータは、物体 1 個がランダムな位置に配置された画像 50 枚ずつ (合計 200 枚) とした。サンプルデータの 1 種類あたりの画像数は 5 通りのケース (5, 10, 20, 30, 40) を設定した。次元削減後の次元数についても 5 通りのケース (5, 10, 20, 30, 40) とした。

実験 2 では、複数の物体が存在するケースに対する分類精度を評価する。テストデータは、同じ形状の物体 3 個がランダムな位置に配置された画像 20 枚ずつ (合計 80 枚) とした。サンプルデータの画像数は 30 枚とし、次元削減後の次元数は 30 とした。

実験 3 では、異なる物体形状が混在するケースに対する分類精度を評価する。テストデータは、各形状の物体 1 個ずつ (合計 4 個) がランダムな位置に配置された画像 20 枚とした。サンプルデータの画像数は 30 枚とし、次元削減後の次元数は 30 とした。

3.2 結果と考察

実験 1 では、入力したテストデータの画像 200 枚に対して 226 個の把持位置を検出した。提案手法による物体形状分類の結果を表 1 に示す。行は PCA で次元削減した後の次元数、列は物体形状 1 種類あたりのサンプルデータ画像数のマトリクスで、各セルの上段は物体形状分類の正解率、下段は分類に用いた中間層を表している。

最も高い正解率は 1.000 であり、サンプルデータ画像数 40・次元数 40 の組み合わせで全ての把持位置に対して正しく物体形状を分類できた。その際、分類に用いた中間層は 2-2 層だった。一方、最も低い正解率はサンプルデータ画像数 5・次元数 5 の組み合わせの 0.593 であり、中間層は 1-2 層だった。

全体的な傾向としてサンプルデータ画像数と次元数が増えるほど正解率が高くなっているが、サンプルデータ画像数 40 では次元数 5 でも約 9 割の正解率となっており、次元数を増やすよりもサンプルデータ画像数を増やす方が正解率向上に効果的だと言える。また、正解率が 9 割以上となったケースにおける中間層は、2-1 層、2-2 層、3-1 層のいずれかであり、2-1 層から 3-1 層の間の中間層に物体形状の特徴が表れやすいことを示している。これは、本実験の DNN の最終出力が把持位置であり後半の層ほど把持位置の影響を受けやすいため、前半の中間層の方が物体形状の特徴を抽出しやすいことが要因と考えられる。全てのケースで前半の中間層が自動選択されており、物体形状分類に適した中間層の絞り込みができていけると言える。

実験 2 では、テストデータの画像 80 枚に対して 266 個の把持位置を検出した。266 個の把持位置のうち 220 個に対して正しく分類することができ、正解率は 0.962 となった。この結果により、1 つの画像中に同じ形状の物体が複数存在するケースに対しても提案手法を適用できることを確認できた。

実験 3 では、テストデータの画像 20 枚に対して 82 個の把持位置を検出した。82 個の把持位置のうち 80 個に対して正しく分類することができ、正解率は 0.975 となった。この結果により、1 つの画像中に異なる形状の物体が混在するケースに対しても提案手法を適用できることを確認できた。

サンプルデータ画像数 30・次元数 30 のケースにおける各実験の正解率 (表 2) を比較すると、ほぼ同じ正解率である。ここから、入力した画像中の物体数は分類精度に影響していないことがわかる。つまり、把持位置の推論時に寄与した出力のみに絞って中間層出力を取得できていると言える。

これらの実験結果から、提案手法によって中間層出力を絞り込むことで、物体の把持位置検出タスクのみを学習させた DNN を用いて物体形状分類タスクを遂行できることが確認できた。

表 1: 実験 1 の結果

		サンプルデータ画像数				
		5 枚	10 枚	20 枚	30 枚	40 枚
次元数	5	0.593	0.739	0.748	0.885	0.894
		1-2 層	2-1 層	1-2 層	2-1 層	1-1 層
	10	0.668	0.841	0.850	0.960	0.987
		4-1 層	2-1 層	1-2 層	3-1 層	2-2 層
	20	0.699	0.788	0.916	0.973	0.996
		2-1 層	1-2 層	2-1 層	3-1 層	2-2 層
	30	0.690	0.827	0.942	0.973	0.996
		2-1 層	1-1 層	2-1 層	3-1 層	3-1 層
	40	0.699	0.823	0.951	0.978	1.000
		2-1 層	1-1 層	2-1 層	3-1 層	2-2 層

表 2: 各実験の正解率の比較

	把持位置 検出数	正解数	正解率	分類に用いた 中間層
実験 1	226	220	0.973	3-1 層
実験 2	266	256	0.962	3-1 層
実験 3	82	80	0.975	3-1 層

4. まとめと今後の展望

本稿ではピッキングタスクにおいて、物体把持位置検出タスクのみを学習させた DNN を用いて物体形状分類タスクを実施するために、中間層出力を絞り込む手法を提案した。本手法を適用することで、入力画像中に複数の物体が存在するケースや異なる種類の物体形状が混在するケースにおいても高い精度で物体形状を分類できることを示した。今後の展望として、提案手法の物体形状以外の特徴での分類に対しての有用性を確認する。また、提案手法を拡張し、把持位置検出タスク以外の学習モデルに対して適用する。

参考文献

- [Bousmalis 18] K. Bousmalis, A. Irpan, P. Wohlhart, Y. Bai, M. Kelcey, M. Kalakrishnan, L. Downs, J. Ibarz, P. Pastor, K. Konolige, S. Levine, and V. Vanhoucke, "Using Simulation and Domain Adaptation to Improve Efficiency of Deep Robotic Grasping," in Proc. IEEE Int. Conf. Robots and Automation (ICRA), 2018.
- [Levine 16] S. Levine, P. Pastor, A. Krizhevsky, and D. Quillen, "Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection," Int. J. Robot. Res., vol.37, no.4-5, pp.421-436, 2016.
- [Pinto 16] L. Pinto, and A. Gupta, "Supersizing Self-supervision: Learning to Grasp from 50K Tries and 700 Robot Hours," in Proc. IEEE Int. Conf. Robots and Automation (ICRA), 2016.
- [鈴木 18] 鈴木 彼方, 横田 泰斗, 金澤 裕治, 竹林 知善, "物体把持位置検出における逐次学習手法の検討," 情報処理学会第 81 回全国大会発表予定, 2019.
- [Jang 18] E. Jang, C. Devin, V. Vanhoucke, and S. Levine, "Grasp2Vec: Learning Object Representations from Self-Supervised Grasping," in Conf. on Robot Learning (CoRL), 2018.
- [Kodirov 17] E. Kodirov, T. Xiang, and S. Gong, "Semantic Autoencoder for Zero-shot Learning," in Computer Vision and Pattern Recognition (CVPR), 2017.
- [横田 18] 横田 泰斗, 鈴木 彼方, 金澤 裕治, 竹林 知善, "把持位置学習における中間特徴量を用いた物体形状分類手法の検討," 情報処理学会第 81 回全国大会発表予定, 2019.
- [Liu 16] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, and A. C. Berg, "SSD: Single Shot Multi-box Detector," in European Conf. Computer Vision (ECCV), 2016.
- [Springenberg 15] J. T. Springenberg, A. Dosovitskiy, T. Brox, and M. Riedmiller, "Striving for Simplicity: The All Convolutional Net," in Proc. IEEE Int. Conf. Robots and Automation (ICRA), 2015.

少数データからの観察的因果帰納

Observational Causal Induction with Small Samples

宝田 悠*¹ 高橋 達二*¹
Takarada, Yu Takahashi, Tatsuji

*¹東京電機大学理工学部

School of Science and Engineering, Tokyo Denki University

Causal induction forms the basis for adaptation of animals. It enables diagnosis of the past, judgment in the present, and prediction for the future in uncertain environments. In AI, it is argued that efficient causal inference supports human-like quick learning and decision-making with small amount of data. The purpose of this study is to elucidate how humans judge the causal relationship when given small data. We assume that causal induction has two stages, observational and interventional, according to Hattori and Oaksford. In our experiment, we controlled a factor (symmetry between occurrence and non-occurrence of the causal events) that has been shown to manipulate the cognitive distinction between the two stages. We compared the models that correspond to the two stages, pARIs/DFH and delta-P. It was shown that pARIs, the probability of biconditionals and equivalent to Jaccard index, describes the result best in both conditions.

1. はじめに

近年の深層学習をはじめとする人工知能技術は、学習のために膨大なデータを必要とする。現実環境を前提とした人工知能には、限定された情報から即座に世界のモデルを構築し、素早い学習や判断を行う能力が不可欠であることが議論されている [Lake 17] など、因果帰納をはじめとする人間の認知のモデル化の重要性が増している。

複数の事象の共起から因果関係を推論する因果帰納は、自然環境や社会の因果関係を活用する人間にとって根本的な認知機能の 1 つであるが、現在において因果判断構造は完全には解明されていない。因果判断構造解明の先行研究の 1 つとして、因果帰納の二段階理論が存在する。人間の因果帰納プロセスが、関係のありそうな結果事象と原因候補事象のペアを観察から抽出する第一段階と、世界に対する観察主体の介入（理想的には科学実験）によって真の原因か分析する第二段階の 2 つに区別できるという理論である [Hattori 07]。第一段階のモデルとしてコサイン類似度に等しい二要因ヒューリスティクスモデル (dual-factor heuristics, DFH) が、ピアソンの相関係数の極限形として導入されている。その上で二つの段階は、後に二重過程理論に近い認知スタイル (フレーム) の違いとして議論されており [Hattori 16]、これら二つの認知フレームの切り替えを促す条件も、実験により明らかにされている [Hattori 17]。それに対して DFH より単純でありながら同等のデータ記述力を持つ、稀少と仮定される事例の比率 (proportion of assumed-to-be rare instances, pARIs) モデルが提案されている [Takahashi 10]。Takahashi et al. は pARIs について、Hattori and Oaksford のシミュレーションによる合理分析と二段階理論の双方に、オリジナルの DFH モデル以上に適合するモデルであると論じている [Takahashi_submitted]。pARIs は DFH に類似したモデルであるが Politzer と Over の提唱する双条件付確率による因果判断と一致する事や少数データに対する計算可能性の点で より高い有用性が示されている [Politzer 10, Over 09]。

連絡先: 高橋達二, 東京電機大学, 埼玉県比企郡鳩山町大字石坂, 049(296)5731-2552(ダイヤルイン), tatsujit@mail.dendai.ac.jp

2. 因果帰納

因果帰納とは、原因の候補である事象 C が、結果として着目する事象 E を引き起こす因果関係の強度を、2 事象の共起情報観測から帰納的に構築する因果判断の一種である。

2.1 因果帰納モデル

因果帰納に関するモデルの研究では 2×2 の表 1 に表される C と E の 2 事象間の観測順序を区別しない共起頻度を使用される。表 1 において、例えば C と E が両方生じた回数は a で、 C も E も生じなかった回数は d で示される。

表 1: 原因候補事象 C と結果事象 E の共起頻度

	結果生起 (E)	結果不生起 ($\neg E$)
原因生起 (C)	a	b
原因不生起 ($\neg C$)	c	d

2.1.1 ΔP

最も代表的なモデルとして ΔP がある [Ward 65]。これは、 C が生じた時の E の条件付確率と C が生じないときの E の条件付確率の差で、式 1 によって定義される。このモデルでは C と E の関係性を、抑制的である方向を含めて表すことが可能である。 ΔP が 0 より大きい値であれば C は E を生起させる性質を持ち、0 未満であれば抑制的、0 であれば E の生起に関して無関係であるとされる。このモデルは、規範的な因果帰納モデルであるとして支持されてきたが、人間の因果判断にあまり合わないことが無数の因果帰納実験により知られている。

$$\Delta P = \frac{a}{a+b} - \frac{c}{c+d} \quad (1)$$

2.1.2 DFH

人間の因果帰納時の因果強度の判断のモデルである DFH は式 2 によって定義される。

$$\text{DFH} = \frac{a}{\sqrt{(a+b)(a+c)}} \quad (2)$$

このモデルは四分点相関係数 ϕ において d を無限大まで発散させる、すなわち ϕ の $P(C)$ と $P(E)$ が 0 の極限を取るという稀少性仮定の下で導出できる。因果強度の計算対象となる

C, E の 2 事象が共に生起しないという共起情報 d は定常的に発生しているとも考えられ、時間を区切る原因に対して排中律の働く別原因を設定するなどしなければ数え上げる事が出来ない。例えば、スイッチを操作ことで明かりが点く装置を観察する時には、スイッチを操作した事象と明かりが点いた事象は確認できるが、スイッチを操作していないかつ明かりが点いていないという事象は常に発生しているといったことである。この原理的な問題からすると、 d を計算時に必要としない DFH の式の形は自然であり、有効な性質であると言える。

2.1.3 pARIs

pARIs は人間の因果帰納時の因果強度の判断のモデルで、 $P(C \wedge E)$ と $P(C \vee E)$ の比率で計算され、式 3 で定義される。

$$\text{pARIs} = \frac{P(C \wedge E)}{P(C \vee E)} = \frac{a}{a + b + c} \quad (3)$$

これは新パラダイム推論心理学における双条件文の確率と一致しており、「 C ならば E 」の条件付事象と「 E ならば C 」の条件付事象の結合で表される [Baratgin 18]。さらに、Tversky により定義された類似性の指標とも $\alpha = \beta = 1$ のとき一致し [Tversky 77]、情報工学の分野で扱われる類似度の指標である Jaccard similarity index と一致する。他にも DFH と同じく C と E が共に生起しない d を使用しない性質を有する。加えて事象 C, E が全く生起しない時を除いてゼロ除算が発生しないため、DFH を含めた他モデルより計算可能性が高い。

2.2 AB フレーム理論

AB フレーム理論は、人間の思考が性質の異なる 2 つのフレームの切り替えによって行われるとする理論である [Hattori 16]。因果帰納においては A フレームは原因と結果の関連性の検出を素早く行い、B フレームは因果の方向を含んだ正確な分析を行うとして、異なる推論モードを引き起こしているとされている。因果帰納モデルにおいては、DFH や pARIs が A フレームのモデルに、 ΔP が B フレームのモデルとして挙げられている。また、フレームの切り替えを促す要因の一つとして因果帰納における表題の形式、つまり否定が対称的か非対称的かによるものがあると述べられている。否定の形式が対称的であれば B フレーム、非対称的であれば A フレームによる推論が行われるとされている。ここでの対称とは、ある事象に対応した別の事象を否定とすることを示しており、逆にある事象が生起しないことを否定としている場合は非対称としている。例えば、花に与える肥料の影響を考える歳に肥料 A を与えたことと肥料 B を与えたことに関して差異を見るのが対称的、肥料の有無による差異を観察するのが非対称的ということである。

2.3 因果帰納モデルと対称性に関する議論

因果帰納のモデルに関して、DFH と ΔP の比較として対称及び非対称を比較した実験はあるものの [Hattori 17]、pARIs に関してはこの限りではない [Hattori 16]。また、人間が現実環境下で因果推論をする際の共起の観測数は、必ずしも十分な数を得られるとは限らず、より少ない情報から関連の検出を行う場合もあり、検証の余地がある。我々は、提示されるデータが少数の場合におけるカバーストーリーの対称および非対称によって人間の因果判断がどのような振る舞いをし、どの因果帰納モデルがどの状況で、より人間の判断を記述しているかを分析することを目的として因果帰納実験を行なった。

3. 実験

実験参加者はクラウドソーシングサイトで募集し、実験は作成した Web ページを用いて実施した。

本実験で提示した対称条件のストーリーは以下の通りである。

あなたはある魚の養殖をしていて、その魚卵を売って生活していると仮定してください。魚卵は健康にいい成分が豊富に含まれていて、他の種の魚卵よりも高く売れます。しかしながらその魚は卵を持ったまま水揚げされることが少ないことが知られています。現在までにあなたが養殖している魚を水揚げした中でも、卵を持っている確率はあまり高くありません。その国で、現在養殖している種の魚の餌を生産している会社は 2 社で、白飼料株式会社と黒飼料株式会社という会社です。あなたは黒飼料の餌を今まで使っていました。

あなたは、どこかの同業者が白飼料の餌に変えたところ魚卵の生産量が上がったという噂を聞きました。しかしその噂に関する具体的な根拠はまだなく、今まで使っていた餌から変更するにはさらなるコストがかかります。そこでこれから、両社の餌に関して魚卵生産率向上への影響を吟味することにします。

白飼料と黒飼料は、あなたの近隣の同業者の元へいくつか餌のサンプルを持ってきていました。その同業者はあなたと同じ種の魚の養殖をしていて、餌と魚卵生産率の影響を調べるべく調査をしていました。

これから、同業者の特定の魚に与えた餌の種類と、水揚げ時に魚卵を持っていたかを繰り返し提示します。注意深く観察した上で、白水産の餌を与えたことが魚卵の生産をどれだけ引き起こしたかの度合いを回答してください。

また、原因と結果各イベントに関して否定の形式を 2 種類用意しそれぞれを対称条件、非対称条件とした。非対称条件では、原因イベントをサプリメントを与えたか否か、結果イベントを卵を持っていたかとした。

今回使用した $\{a, b, c, d\}$ で構成される刺激組は、両条件共通で以下の 5 組である (表 1 も参照)：

$\{1, 0, 0, 2\}$, $\{1, 2, 2, 4\}$, $\{1, 1, 0, 2\}$, $\{5, 1, 1, 1\}$, $\{2, 1, 0, 2\}$
 実験刺激は、pARIs と ΔP の推定値間に相関がないようデザインした。

以下に実験の手順を提示する。

1. クラウドソーシングサイトで各条件につき 100 人ずつ実験参加者を募集し、実験準備ページへの遷移を指示した。
2. 実験準備ページにおいて、実験刺激の提示および説明、確認テストを行なった。
3. 確認テストを全て正解した実験参加者に対し、実験ページへの遷移を指示した。実験参加者が操作を行う実験ページは、大きく分けて 3 種類のページで構成した。
4. 最初に、提示する刺激組のカバーストーリーの説明を行うページを表示し、各条件の原因と結果を記述した文章を実験参加者へ提示した。
5. 次に、文章及び画像の提示によって実際の刺激を実験参加者に与えた。この時与える刺激組の提示例を図 1 に示す。
6. 先に示した刺激組をランダムで提示し、「次の事例へ」ボタンの押下によって次の刺激を表示した。

認知に関するテスト

魚の養殖における餌の種類の影響に関するテスト



白飼料の餌を与えたグループは、平均以上の割合で卵を持っていた

図 1: 今回の実験での刺激の提示例

7. 全ての刺激の提示が終了した時点で次の評価ページに遷移する旨をダイアログメッセージで表示した。
8. 最後に提示した刺激群に対して因果強度の推定値を入力する評価ページに遷移した。評価ページには因果強度の推定値入力を促す文章と、0 から 100 を示すゲージの表示を行い、スライダーを用いた因果強度の推定値を促した。
9. 評価の終了後、次のシナリオがある場合は「次のシナリオへ」ボタンが表示され、押下することで次のシナリオで同様の処理が、同一の実験参加者に対して繰り返し行われた。
10. 全てのシナリオの提示を終わらせた後に、回答を送信するボタンを表示した。
11. 回答の送信後、ランダム数列を記載したページへと遷移し、当該のランダム数列を実験準備ページの入力欄へ入力を促した。実験準備ページ及び実験ページのそれぞれで提示したランダム数列の組み合わせをクラウドソーシングサイトから送信することで実験終了させた。

以上が一連の実験手順である。推定値入力の際に提示した文章を以下に示す。

白飼料社製の餌を与えたこと餌を与えたことが、産卵を引き起こした因果関係の強さはどのくらいでしょうか。
0 : 全く因果関係がない
100 : 完全に因果関係がある
として、0 から 100 の値で直感で答えてください。

また、結果の分析には線形混合効果回帰モデルを用いた。分析を行うにあたり 2 つの回帰モデルを定めた。

$$M1 : \text{rating} \sim \text{Model} + (1|\text{participant}) \quad (4)$$

$$M2 : \text{rating} \sim \text{Model} + (\text{Model}||\text{participant}) \quad (5)$$

ここで変数 Model は各モデルの推定値を示す。双方のモデル共に切片を fixed effects (固定効果) と random effects (ランダム効果) を足したものとし、M1 では傾きを fixed effects のみ、M2 では fixed effects 及び random effects を足したものを利用する。各因果帰納モデルにおいて、モデル M1, M2 におけるベイズ情報量基準を算出し、より小さい値のほうのモデルを人間の判断によりフィットしているとして比較の対称とした。

3.1 結果

本実験でクラウドソーシングサイトで 200 人の実験参加者を募集し、対称条件及び非対称条件の各条件に 100 人ずつ割り振りをして実験を行なった。各条件の無効データ 1 件ずつ、計

2 件を除いたデータ 198 件を分析の対象とした。無効データは、全ての回答を初期値で行なっていた 1 件及び実験ページの回答とクラウドソーシングサイトで回答された ID が一致しなかった 1 件である。今回作成した刺激組に対して各モデルの推定値を表 2 に示す。対称条件下において実験参加者が回答した因果強度を表 3、非対称条件を表 4 に、実験参加者が回答した因果強度と各モデルとの相関係数を表 5 に示す。相関係数は、各実験参加者の回答を最小値 0, 最大値 100 として正規化したデータも用いて算出した。各モデルの適合性検証結果を、表 6 に示す。表 6 より pARIs と DFH の BIC が ΔP と比較して低い数値が出ている。また、各モデルにおいて対称条件と非対称条件それぞれの BIC を比較すると、pARIs と DFH は非対称条件の方が対称条件よりも低い数値が出ている。Hattori et al. の AB フレーム理論において本来 ΔP は B フレームのモデルされている為、pARIs や DFH よりも対称条件でより高いフィットが見られるという仮説があったが、今回の結果はその仮説に反し pARIs と DFH の方が低い BIC が出ている [Hattori 16]。

表 2: 使用する刺激組及び pARIs, DFH, ΔP における推定値

No	a	b	c	d	N	pARIs	DFH	ΔP
1	1	2	0	2	5	0.333	0.577	0.333
2	1	0	2	4	7	0.333	0.577	0.667
3	1	1	0	2	4	0.500	0.707	0.500
4	5	1	1	1	8	0.714	0.833	0.333
5	2	1	0	2	5	0.667	0.816	0.667

表 3: 実験参加者の回答の平均および分散 (対称条件)

刺激	回答_平均	回答_SD	正規化_平均	正規化_SD
1	40.152	23.998	27.148	35.734
2	47.687	25.445	43.467	37.669
3	47.717	26.782	42.809	38.480
4	67.475	24.472	81.026	30.591
5	57.030	23.924	59.619	33.373

表 4: 実験参加者の回答の平均および分散 (非対称条件)

刺激	回答_平均	回答_SD	正規化_平均	正規化_SD
1	38.566	23.967	23.045	32.724
2	40.434	25.569	25.464	32.893
3	47.727	27.789	40.175	37.584
4	68.525	19.944	78.609	31.967
5	60.000	22.216	65.423	33.650

表 5: モデル予測値とデータ平均値の相関係数

	pARIs	DFH	ΔP
対称条件_回答データ	0.907	0.883	-0.069
非対称条件_回答データ	0.982	0.967	-0.129
対称条件_正規化データ	0.894	0.869	-0.062
非対称条件_正規化データ	0.988	0.975	-0.109

3.2 考察

BIC の値が低かったことから、pARIs 及び DFH は今回の比較対称である ΔP よりも実データにフィットしたモデルであると言える。また、pARIs と DFH それぞれのモデルにおいて、非対称条件の方が対称条件よりも低い BIC が出ていることから、これらの 2 モデルは対称条件よりも非対称条件における人間の因果判断特性をより顕著に表していると言える。人間が AB フレーム理論の A フレームで推論しているという仮説のもとでこの結果は妥当であると考察する。

ΔP が対称条件下においても BIC が高く低いフィットであっ

表 6: 線形混合効果モデルによる各モデルの適合性

Model	Negation	BIC	RMSE	Estimate	Std.Error	df	t	Pr(< t)	
pARIs M1	Symmetry	4566.7	36.049	(Intercept)	24.924	3.496	492.404	7.13	<0.001
				pARIs	53.164	6.087	395	8.734	<0.001
	Non-symmetry	4443.0	34.581	(Intercept)	15.105	3.145	447.535	4.803	<0.001
				pARIs	70.547	5.068	395	13.921	<0.001
ΔP M1	Symmetry	4635.9	42.698	(Intercept)	54.194	3.924	490.224	13.81	<0.001
				ΔP	-4.364	7.155	395	-0.61	0.542
	Non-symmetry	4598.3	43.848	(Intercept)	56.043	3.776	490.683	14.843	<0.001
				ΔP	-9.985	6.643	395	-1.503	0.134
DFH M1	Symmetry	4570.0	41.404	(Intercept)	-0.566	6.427	441.794	-0.088	0.930
				DFH	74.863	8.858	395	8.451	<0.001
	Non-symmetry	4448.0	42.719	(Intercept)	-19.598	5.492	468.189	-3.569	<0.001
				DFH	100.592	7.39	395	13.612	<0.001

た理由としては主に 2 つが考えられる。1 つ目は、今回の実験が少数データである為に推定値が安定していなかったという仮説である。 ΔP の式は 2 つの項で構成されており、因果帰納の肯定的要素に関する確率と否定的要素に関する確率の比較によって表される。観察されるデータが少数であった場合、各共起回数の変動は推定値に大きく影響する。それ故に人間の因果判断と相関をあまり得られなかったということが考えられる。2 つ目としては、そもそも対称条件として行っていた実験が非対称条件として実験参加者に捉えられていた可能性があるというものである。今回の実験では、原因と結果の共起を提示する際に文章と画像を同時に表示していた。文章では、平均以上の確率で卵が収穫できたもしくは平均以下でしか収穫できなかったと提示をしていたが、使用した画像は卵が写っているか写っていないかとしており、非対称条件で使用した画像と同一であった。その為実験参加者には非対称的な印象を与えてしまい A フレームでの推論をしていたというものである。これらの仮説に対して、画像を対称的なものに変更し再度検証する必要がある。

4. おわりに

今回の実験では、人間の少数データによる因果判断を観察し、またそのデータを用いて各因果帰納モデルの比較を行なった。結果として対称条件及び非対称条件下のいずれにおいても pARIs 及び DFH に高い適合性が見られた。特に、対象条件下における AB フレームの切り替えに関して従来の理論と異なる結果が得られた。これに関しては、AB フレームの切り替えにおいて刺激数 N が関連しているという仮説が立てられる。つまり、 N が小さい値を取る時、A フレームを用いた推論を行いやすいということが考えられるということである。今後はこの仮説に関して詳しく検証を行なっていくと共に、生起不生起以外の曖昧な情報を含んだ 3×3 生起表に表される刺激についても、因果帰納モデルがどの程度フィットするか検証を行なっていく必要がある。

参考文献

- [Baratgin 18] Baratgin Jean, Guy Politzer, David E. Over, Tatsuji Takahashi, "The psychology of uncertainty and three-valued truth tables.", *Frontiers in Psychology* 9, 1479.(2018)
- [Hattori 07] Hattori, M., & Oaksford, M. (2007) "Adaptive Non-Interventional Heuristics for Covariation De-

tection in Causal Induction: Model Comparison and Rational Analysis." *Cognitive Science*, 31(5), 765-814.

- [Hattori 16] Hattori, M., Over, D., Hattori, I., Takahashi, T., & Baratgin, J. (2016) "Dual Frames in Causal Reasoning and Other Types of Thinking. In: N. Galbraith, D. Over, & E. Lucas (Eds.)" *The Thinking Mind: A Festschrift for Ken Manktelow*, Psychology Press.
- [Hattori 17] Hattori, I., Hattori, M., Over, D., Takahashi, T., & Baratgin, J. (2017) "Dual frames for causal induction: The normative and the heuristic." *Thinking and Reasoning*, 23, 3, 292317.
- [Lake 17] Lake, B., Ullman, T., Tenenbaum, J., & Gershman, S. (2017) "Building machines that learn and think like people." *Behavioral and Brain Sciences*, 40, E253.
- [Over 09] Over, D. E. (2009) "New paradigm psychology of reasoning" *Thinking & Reasoning*, 15(4), 431-438.
- [Poltzer 10] Politzer, G., Over, D. E., & Baratgin, J. (2010) "Betting on conditionals" *Thinking & Reasoning*, 16(3), 172-197.
- [Takahashi 10] Takahashi, T., Kohno Y., & Oyo, K. (2010) "Causal induction heuristics as proportion of assumed-to-be rare instances (pARIs)" *In: Proceedings of the 7th International Conference on Cognitive Science (ICCS2010)*, 361-362.
- [Takahashi_submitted] Takahashi, T., Oyo, K., & Tamatsukuri, A. (submitted) "Correlation Detection with and without the Theory of Conditionals: A model update of Hattori & Oaksford (2007)."
- [Tversky 77] Tversky, A. (1977) "Features of similarity." *Psychological Review*, 84 (4), 327352.
- [Ward 65] Ward and Jenkins(1965) "The display of information and the judgment of contingency", *Canadian journal of psychology*, 19(3),231-41.

Pixyz : 複雑な深層生成モデル開発のためのフレームワーク

Pixyz: a framework for developing complex deep generative models

鈴木 雅大^{*1} 金子 貴輝^{*1} 谷口 尚平^{*1} 松嶋 達也^{*1} 松尾 豊^{*1}
 Masahiro Suzuki Takaaki Kaneko Shohei Taniguchi Tatsuya Matsushima Yutaka Matsuo

^{*1}東京大学
 The University of Tokyo

In recent years, as researches of deep generative models (DGMs) have progressed rapidly, we need a framework which can be used to implement them in a simple and versatile manner. In this research, we focus on the following two aspects as the features of the latest complex DGMs: 1. Deep networks of them are concealed by probability distributions. 2. Their objective functions are composed of multiple loss functions. Then, in order to achieve them, we propose a new DGM library, Pixyz. We show experimentally that our library is faster than existing probabilistic modeling language in training a simple DGM, and also demonstrate that our library makes it easy and concise to implement complex DGMs which cannot be done with existing libraries.

1. はじめに

近年、深層生成モデルの研究が急速に進んでおり、画像や文書生成の他、異常検出やノイズ除去、半教師あり学習、表現学習、メタ学習など、幅広い応用先があることから注目を集めている。そうした中で、多くのコミュニティで深層生成モデルを開発し活用していくためには、簡潔かつ汎用性の高い実装ができることが求められる。

深層生成モデルは、確率モデルを構成するそれぞれの確率分布が深層ニューラルネットワーク (DNN) で表されている。一般に DNN モデルの開発には、Tensorflow や、Keras, PyTorch, Chainer といったライブラリを利用することが主流である。しかし、特に Keras のように抽象度の高いライブラリは、簡単に DNN を設計できるようになっている一方で、複雑な深層生成モデルの実装には適していないことが指摘されている^{*1}。

確率モデリング言語は、確率モデルを直感的かつ統一的に記述するための枠組みであり、最近では GPU で実行でき、DNN と確率分布を混ぜて記述できる Edward [Tran 16] や Pyro [Bingham 18] などが知られている。これらの言語は、単純な深層生成モデルや、ベイズのニューラルネットワークの実装などに使われているものの、近年数多く提案されている、複雑な深層生成モデルの実装には殆ど使われていない。その理由として、近年の深層生成モデルの次のような特徴に着目する：

確率分布によるネットワークの隠蔽 従来の確率モデルとは異なり、深層生成モデルでは、モデルを構成する確率分布がニューラルネットワークで設計される。つまり、DNN は確率分布によって隠蔽されており、それぞれが確率モデルを構成する「モジュール」のような役割を果たしている^{*2}。近年の確率モデリング言語は、上記で述べたように DNN と確率分布の両方を混ぜて書くことができるものの、確率分布によって隠蔽した書き方をすることは

困難であり、隠蔽した確率分布同士を演算する適切な枠組みもない。

複数の項 (異なるモデルの誤差関数) で構成される目的関数

近年の深層生成モデルが従来の確率モデルと大きく異なるもう一つの点は、目的関数を設定し、そのネットワークパラメータにおける勾配をとって学習・推論することである。例えば、variational autoencoder (VAE) は対数周辺尤度の下界 (ELBO)、generative adversarial network (GAN) は交差エントロピー誤差 (暗黙的なモデル分布とデータ分布の間のダイバージェンス)、そして flow-based モデルでは対数尤度を目的関数として設定している。従来の確率モデリング言語では、それぞれを異なる「モデル」として学習用のクラスを用意しているが、近年の深層生成モデルでは、これらを組み合わせたモデル、すなわち複数の項の誤差関数で定義されるモデルが提案されている。そうしたモデルについては、従来のような生成モデルの生成過程を記述する方式では実装が難しい。

したがって、現在の深層生成モデルの実装には特に決まったライブラリやフレームワークが使われることあまりなく、様々な方法で実装されているのが現状である。そのため、他人の実装を利用するためには、その実装方法を解読する必要がある、手間がかかる。また、複雑な深層生成モデルの場合、書いた本人すらわからなくなるような難解なコードになる可能性もあり、メンテナンスの点でも問題となる。

本研究では、こうした問題を解決するため、新たな深層生成モデルの実装フレームワーク Pixyz^{*3} を提案する。本ライブラリでは、上記の深層生成モデルにおける 2 つの特徴を考慮し、3 つの API (Distribution API, Loss API, Model API) による階層的な実装方法を提案する。これによって、複雑な深層生成モデルを記述できるだけでなく、設計したモデルの可読性が増し、改良や利用が容易になる。

本論文では、2 章で関連研究について説明した後、3 章で Pixyz の概要を説明する。その後 4 章で実行速度と複雑なモデ

連絡先: 鈴木雅大, 東京大学工学系研究科技術経営戦略学専攻,
 〒113-8656 東京都文京区本郷 7-3-1, masa@weblab.t.u-tokyo.ac.jp

^{*1} <https://twitter.com/dustintran/status/850394381794373634>, Dustin Tran, 2017/04/08, Twitter.

^{*2} 実際、近年の深層生成モデル論文の多くで、提案モデルがニューラルネットワークではなく確率モデルとして説明されている。

^{*3} <https://github.com/masa-su/pixyz>, なお本論文で説明する Pixyz は version 0.0.5 についてである。

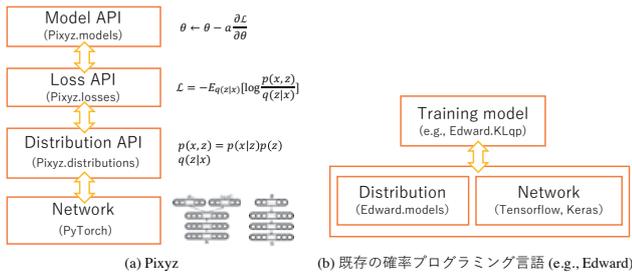


図 1: Pixyz の概要と既存ライブラリとの比較

ルの実装を検証して Pixyz の有効性について議論し、5 章でまとめと今後の展望を述べる。

2. 関連研究

既存の確率モデリング言語には、推論のための高速かつ様々なサンプリングアルゴリズムが実装されている。Stan は C++ で書かれているため高速にサンプリングできることが特徴で、モデル等を記述した Stan 形式のファイルを Python や R で読み込んで実行するインターフェースもある。最近の確率モデリング言語である Edward や Pyro は、Python を用い、TensorFlow や PyTorch 上で動作するように設計されているため、確率モデルを DNN と混ぜて実装でき、GPU 上でのサンプリングや推論、学習が可能である。こうした汎用的な確率モデリング言語は、多くの確率モデルを実装することができるが、1 章で述べた理由から、複雑な深層生成モデルを実装する上では限界がある。

一方で、本研究で提案するライブラリに最も近いのが、Probabilistic Torch (ProbTorch) [Siddharth 17] である。ProbTorch は、Pixyz 同様、深層生成モデルの実装に特化したライブラリであり、PyTorch におけるネットワークの設計の中で分布を定義する点も共通している。しかし次章で述べるように、Pixyz には、ProbTorch にはない、確率分布の積や誤差関数の演算を直感的に実装できるという特徴がある。また、ProbTorch では VAE の実装しか想定されていないが、Pixyz では VAE だけでなく、GAN や flow-based、そしてそれらを組み合わせた複雑な深層生成モデルを実装できる。

3. 提案ライブラリ : Pixyz

本章では、本研究で提案するライブラリ Pixyz の説明をする。Pixyz は Python に基づき、DNN の設計や確率分布のサンプリング及び尤度計算のために PyTorch を用いている。

先述したように、Pixyz は 3 つの API による階層的なフレームワークで構成される。大きな流れとしては、図 1(a) にあるように、1) ニューラルネットワークで確率分布を定義 (**Distribution API**)、2) 確率分布同士を計算し、誤差関数によって確率モデルを定義 (**Loss API**)、3) 定義した誤差関数を最適化するように学習 (**Model API**)、という形である。

以下、それぞれの API について順番に説明する。なお、図 2 に具体的な実装例を載せたので、各 API の説明の際、参照されたい。

3.1 Distribution API

Pixyz ではまず、確率モデルを構成する各確率分布を定義する。確率分布は、`pixyz.distributions` 以下にガウス分布 (Normal) やベルヌーイ分布 (Bernoulli) といった標準的な分布が実装されている。こうした分布クラスは、PyTorch Dis-

tribution^{*4} とほぼ同じ API であり、初期値として分布のパラメータなどを設定する。このとき、`var` で確率変数名、`name` で確率分布の名前を設定できる。条件付き分布を設計したい場合は、条件付ける確率変数名を `cond_var` の値として指定して初期化する。このようにして、分布クラスのインスタンスを生成した後に、`sample` や `log_likelihood` といったメソッドでサンプリングや与えられたサンプルの尤度を計算することができる。なお、Pixyz ではサンプルは全て辞書形式 (`dict`) で表現され、ユーザが定義した確率変数名とその実現値がそれぞれキーと値として格納されている。

次にニューラルネットワークで確率分布を定義する方法を説明する。例えば、ガウス分布を DNN で定義する場合、それらのパラメータ、つまり平均 μ と分散 σ^2 を、DNN によって $\mu = f(x; \theta)$ および $\sigma^2 = g(x; \theta)$ (θ はネットワークパラメータ) のように設定する。これを Pixyz で実現するには、用いる分布クラスを継承し、(PyTorch で通常設計するように) コンストラクタにネットワーク、`forward` に入力 (条件づける変数) から出力 (分布のパラメータ) の流れを記述する。このクラスから生成したインスタンスも、同様に `sample` や `log_likelihood` を使うことができる。つまり、一度インスタンスを生成してしまえば、分布がどのようなネットワークで定義されているかを意識せずに計算を実行できる。これは、深層生成モデルの 1 つ目の特徴 (1 章参照) と合致する。

さらに Distribution API では、分布同士の掛け算を直感的にできるという特徴がある。例えば、 $p(x|z)$ と $p(z)$ という確率分布を定義した場合、同時分布はそれらの積として $p(x, z) = p(x|z)p(z)$ となるが、Pixyz でも分布インスタンスの積として同時分布を定義することができる。この時、異なる分布クラスに同じ変数名があった場合は同じ変数として処理される。この掛け算したインスタンスもまた分布クラスなので、どのような分布で構成されているかを意識せずに、サンプリングや尤度計算ができる。

なお、このように分布インスタンスが抽象化されると、手元の分布がどのような分布・ネットワークで設計されているかを失念する可能性があるが、Distribution API では、Python の `print` メソッドで分布インスタンスの情報を確認することができる。

既存の確率モデリング言語と比べると、従来は確率モデルを生成過程によって表現していたが、Pixyz では確率モデルを同時分布によって表現する枠組みとなっている。

さらに、この API で設計するのは、確率モデルだけでなく、決定論的なニューラルネットワークや、要素の抽出・並び替えといった何らかの「処理」でも良い。その場合は `Deterministic` クラスを継承して定義し、デルタ分布 $p(x|z) = \delta(x - f(z))$ として扱われ、サンプリング結果は決定論的になる。

3.2 Loss API

サンプリングと尤度の計算によって任意の誤差関数を設計できるが、Pixyz では上位の API として、与えられた分布から誤差関数を計算する Loss API がある。Loss API には `pixyz.losses` 以下に、対数尤度、エントロピー、期待値を始め、分布間のダイバージェンスや敵対的損失などが含まれる。これらはいずれも初期化時に分布インスタンスを引数に取り、誤差関数インスタンスを生成する。

Loss API の特徴は、Distribution API と同様、誤差関数インスタンス間の演算ができるということである。例えば VAE の目的関数 (負の ELBO) は、再構成誤差と Kullback-Leibler

*4 <https://pytorch.org/docs/stable/distributions.html>

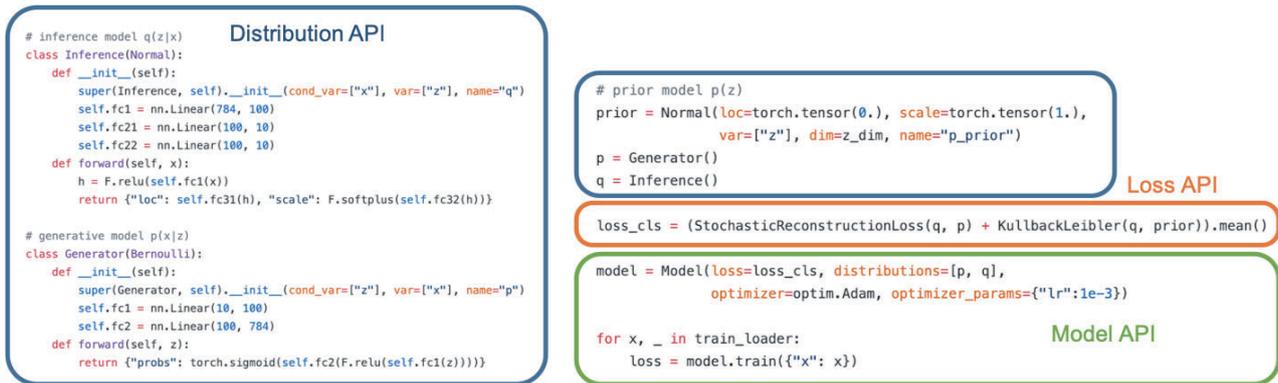


図 2: Pixyz による VAE の実装例

(KL) ダイバージェンスで構成される。したがって、それぞれの誤差関数インスタンスを生成して、それらを足し合わせることで、VAE の目的関数を定義できる。第 1 章でも述べたように、近年の複雑な深層生成モデルは、複数の項の誤差関数で定義されるが、Loss API によって、任意の深層生成モデルについて、論文の式をそのまま書くように実装することが可能になる。また、Distribution API と同様、Python の `print` メソッドによって、どのような式を定義したかを確認できる。

なお、インスタンス間の演算は目的関数の式を定義するものであり、それがどのような値をとるかは、観測変数に対応するデータを入れることで評価できる。Loss API では、`estimate` メソッドの引数にデータを入れることで、式を評価することができる。このように、先に式を定義し、その後値を評価するという方法は、define-and-run 的であるといえる。その一方で、各分布のサンプリングの流れを定義する Distribution API の内部 (`forward` メソッド) の記述方法は、これまでの PyTorch と同じなので、define-by-run である。つまり Pixyz は、各確率分布の定義については、柔軟に設計できる方式を採用しつつ、その確率分布から構成される確率モデルと誤差関数の定義については式をそのまま記述できる方式を採用しており、両方の方式の利点を採用した形となっている。

また Loss API のもう一つの利点は、誤差関数の定義と学習アルゴリズムを切り離れた点である。例えば Edward [Tran 16] のようなライブラリでは、モデル (誤差関数) と学習アルゴリズムが一体となっているため (図 1(b) を参照)、複雑な深層生成モデルに拡張することは困難である。一方、Pixyz では Loss API で任意の誤差関数を作れるため、例えば VAE と敵対的訓練を組み合わせたモデル (FactorVAE など) も実装することができる。

3.3 Model API

Model API では、モデルクラス (`pixyz.models.Model`) の初期化時に、Loss API で定義した誤差関数インスタンスや、学習する分布インスタンス、そして最適化アルゴリズムを渡し、モデルインスタンスを生成する。このインスタンスの `train` メソッドや `test` メソッドにデータを渡して実行することで、モデルの訓練やテストを行うことができる。

任意の誤差関数を Loss API で設計して誤差逆伝播を用いて学習する場合は、`pixyz.models.Model` を利用する。また、VAE や GAN などの基本的な深層生成モデルを直ぐに学習させたいユーザ向けに、誤差関数が内部で定義されているモデルクラスもある (`pixyz.models.VAE`, `pixyz.models.GAN`)。

以上が、Pixyz の実装の流れである。こうした API の階層性の最大の利点は、それぞれの API が互いに干渉しないとい

うことである。例えば、確率分布を変更したとしても誤差関数やモデルを変更する必要はないし、誤差関数を変更するときには、Loss API 内で操作が完結するため、ネットワークの構造を変える必要はない。

4. 実験と実装例の検証

本章では、まず Pixyz の実行速度を他のライブラリと比較する。VAE の実装について、PyTorch, Pyro, Pixyz で比較した。Pyro と Pixyz は PyTorch 上に実装されており、さらに確率モデリングライブラリとしての演算処理を含むため、この実装例より速度が遅くなると考えられるが、どれだけ速度を落とさずに実行できるかが複雑な深層生成モデルを実装する上で重要となる。PyTorch と Pyro の実装は Pyro ライブラリの実装例^{*5} を利用した。また全ての実装で、[Bingham 18] での実験と同様、エンコーダとデコーダに 2 層の多層パーセプトロンを利用し、バッチサイズは 128 とした。本実験では、実験環境として CPU : Intel® Core™ i5-7500T CPU @ 2.70GHz (4core), GPU : GeForce GTX 1070 (メモリ 32G) を利用した。

表 1 は 1 ステップの更新あたりにかかる時間を示したものである。[Bingham 18] での実験と同様に、10 エポックにおける平均で示しており、隠れ層の次元 $\#h$ と潜在変数の次元 $\#z$ を変えた時の結果を載せている^{*6}。

結果より、Pyro と Pixyz はいずれも PyTorch と比べると遅くなっているものの、Pixyz の方が Pyro よりも速い結果となった。なお、PyTorch の実装では VAE の正則化項 (KL ダイバージェンス) を解析的に計算しているのに対して、Pyro ではモンテカルロ近似で計算するように予め設計されている。一方、Pixyz は Loss API のおかげでどちらの目的関数でも容易に実装できるので、両方の場合の結果を載せている。モンテカルロ近似によって遅くなるものの、それでも Pyro よりも高速に学習を進められることがわかる。これは、Pixyz の方が内部の演算や操作がより簡潔であるためと思われる^{*7}。さらに [Bingham 18] では、Pyro の利点として隠れ層が増えると PyTorch との速度のギャップが小さくなることが主張されていたが、Pixyz でも同様であり、特に $h = 2000$ のときは解析

*5 https://github.com/pyro-ppl/pyro/blob/dev/examples/vae/vae_comparison.py

*6 $\#h$ と $\#z$ の設定も [Bingham 18] と同じにしているが、実行環境が異なるため、PyTorch と Pyro の速度結果も [Bingham 18] とは異なる。

*7 ただし、Pyro は Pixyz ではできないパラメータのベイズ推論やサンプリング等もサポートしているため、速度だけから一概に良し悪しを結論づけることはできないことにも注意されたい。

表 1: 各ライブラリでの VAE のステップあたりの実行時間の比較. Pixyz については, VAE の正則化項を解析的 (analytical)・モンテカルロ近似 (Monte Carlo) でそれぞれ計算した結果を載せている.

#z	#h	PyTorch (ms)	Pyro (ms)	Pixyz (analytical) (ms)	Pixyz (Monte Carlo) (ms)
10	400	2.47 ± 0.11	4.91 ± 0.12	3.61 ± 0.11	4.01 ± 0.09
30	400	2.49 ± 0.10	4.94 ± 0.13	3.58 ± 0.10	4.04 ± 0.10
10	2000	3.26 ± 0.11	4.93 ± 0.12	3.62 ± 0.09	4.14 ± 0.10
30	2000	3.28 ± 0.10	4.95 ± 0.12	3.65 ± 0.09	4.11 ± 0.10

$$\sum_{x,y \sim p_{data}(x,y)} [E_{q(z|x,y)} \log \frac{p(x,y,z)}{q(z|x,y)}] + \alpha \log q(y|x) + \sum_{x_u \sim p_{data}(x_u)} [E_{q(z|x_u,y)} \log \frac{p(x_u,y,z)}{q(z|x_u,y)q(y|x_u)}]$$

```

elbo_u = ELBO(p_joint_u, q_u)
elbo = ELBO(p_joint, q)
nll = NLL(f)
loss_cls = -(elbo - (0.1 * nll).sum()) - elbo_u.sum()
(a)

```

$$\sum_t E_{p_B(z_t|b_t)} [E_{q(z_{t-1}|z_t, b_{t-1}, b_t)} \log p(x_t|z_t) + \log p(z_t|z_{t-1}) - \log p_B(z_t|b_t)] - KL[q(z_{t-1}|z_t, b_{t-1}, b_t) || p_B(z_{t-1}|b_{t-1})]$$

```

kl = KullbackLeibler(q, p_b1)
reconst = LossExpectation(q, NLL(p_t) + NLL(p_d) - NLL(p_b2))
step_loss = LossExpectation(p_b2, reconst + kl)

_loss = IterativeLoss(step_loss, max_iter=seq_len-1,
                      series_var=["x", "b"],
                      slice_step=slice_step)
loss_cls = LossExpectation(belief_state_net, _loss).mean()
(b)

```

図 3: Pixyz による複雑な深層生成モデルの実装例. (a): M2 モデル [Kingma 14], (b): TD-VAE [Gregor 18]. Distribution API と Model API は図 2 と同様に書けるので, ここでは省略している.

的な場合において PyTorch とほぼ変わらない速度となっている. この結果から, Pixyz は速度面からも, 複雑な深層生成モデルの実装に適していると考えられる.

次に, Pixyz を使った複雑な深層生成モデルの実装例を載せる. 図 3(a) は, VAE を用いた半教師あり学習モデルである M2 モデル [Kingma 14] の式と, Pixyz による実装例である. 複数の項があるモデルでも, Loss API を用いて, 式をそのまま書くように目的関数を設計できることがわかる.

さらに複雑なモデルとして, 近年注目されている環境をそのまま深層生成モデルで学習する「世界モデル」研究の一つである, TD-VAE [Gregor 18] の式と実装例を図 3(b) に示す. TD-VAE は系列モデルであり, 近年の深層生成モデルの中でも最も複雑なものの一つであるものの, 非常に簡潔かつ可読性が高く実装できることが確認できる.

その他にも, Generative Query Network (GQN) などの世界モデルや, Deep Markov Model, Variational RNN (VRNN) といった系列情報を扱う深層生成モデルも実装することができる^{*8}.

5. まとめ

本研究では, 複雑な深層生成モデルを実装するためのライブラリとして Pixyz を提案した. Pixyz は, 近年の深層生成モデルが持つ「ネットワークが分布に隠蔽されている」「目的関数が複数の項の誤差関数で構成される」という特徴に対応できるように 3 つの API を活用している. これによって, 複雑な深層生成モデルを簡潔に実装できることを示した他, 速度面からも複雑な深層生成モデルの設計に適していることを示した.

ただし, 確率モデリング言語として Pixyz を捉えると, 実現できていないことが多い. 例えば, サンプルングについては

*8 その他の実装例については <https://github.com/masa-su/pixyzoo> を参照されたい.

確率分布からの伝承サンプリングしかサポートしておらず, またベイジックニューラルネットワークのような, パラメータにおけるベイズ推論はできない.

今後は, 確率モデリング言語としての整備をしつつ, 他のライブラリや枠組みとの組み合わせを考えていきたい. 例えば, 深層生成モデルや世界モデルは, 強化学習のアプローチから見ると, 状態表現学習の一手法である. したがって, 強化学習ライブラリと状態表現学習ライブラリとしての Pixyz を組み合わせた新たなライブラリの開発が考えられる^{*9}.

深層生成モデルや世界モデルは, 難解さや実装の困難さから, 通常の DNN に比べて活用の敷居が高い. 本ライブラリが, そうした敷居を無くす役割を少しでも果たせるように, 今後も開発を続けるつもりである.

謝辞

本研究は JSPS 科研費 18H06458 および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

- [Bingham 18] Bingham, E., Chen, J. P., Jankowiak, M., Obermeyer, F., Pradhan, N., Karaletsos, T., Singh, R., Szerlip, P., Horsfall, P., and Goodman, N. D.: Pyro: Deep universal probabilistic programming, *arXiv preprint arXiv:1810.09538* (2018)
- [Gregor 18] Gregor, K. and Besse, F.: Temporal Difference Variational Auto-Encoder, *arXiv preprint arXiv:1806.03107* (2018)
- [Kingma 14] Kingma, D. P., Mohamed, S., Rezende, D. J., and Welling, M.: Semi-supervised learning with deep generative models, in *Advances in neural information processing systems*, pp. 3581–3589 (2014)
- [Siddharth 17] Siddharth, N., Paige, B., Meent, van de J.-W., Desmaison, A., Goodman, N. D., Kohli, P., Wood, F., and Torr, P.: Learning Disentangled Representations with Semi-Supervised Deep Generative Models, 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. 5927–5937, Curran Associates, Inc. (2017)
- [Tran 16] Tran, D., Kucukelbir, A., Dieng, A. B., Rudolph, M., Liang, D., and Blei, D. M.: Edward: A library for probabilistic modeling, inference, and criticism, *arXiv preprint arXiv:1610.09787* (2016)

*9 「組み合わせる」という意味では, 既に S-RL Toolbox (<https://github.com/araffin/robotics-rl-srl>) と呼ばれる強化学習と状態表現学習のツールボックスが存在する.

[1L3-J-11] Robot and real worlds: recognition and movements

Chair:Felix Jimenez Reviewer:Shinobu Hasegawa

Tue. Jun 4, 2019 3:20 PM - 5:00 PM Room L (203+204 Small meeting rooms)

[1L3-J-11-01] HVGH: Segmenting High Dimensional Time Series Data Using VAE and HDP-GP-HSMM

○Masatoshi Nagano¹, Tomoaki Nakamura¹, Takayuki Nagai², Daichi Mochihashi³, Ichiro Kobayashi⁴, Wataru Takano² (1. The University of Electro-Communications, 2. Osaka University, 3. Institute of Statistical Mathematics, 4. Ochanomizu University)

3:20 PM - 3:40 PM

[1L3-J-11-02] Calibration System Using Semantic-ICP for Visualization of Robot Spatial Perception Through Mixed Reality

○Hitoshi Nakamura¹, Lotfi El Hafi¹, Yoshinobu Hagiwara¹, Tadahiro Taniguchi¹ (1. Ritsumeikan University)

3:40 PM - 4:00 PM

[1L3-J-11-03] Path Planning by Spatial Concept-Based Probabilistic Inference from Human Speech Instructions

○Akira Taniguchi¹, Yoshinobu Hagiwara¹, Tadahiro Taniguchi¹, Tetsunari Inamura^{2,3} (1. Ritsumeikan University, 2. National Institute of Informatics, 3. The Graduate University for Advanced Studies)

4:00 PM - 4:20 PM

[1L3-J-11-04] Self-location by a 360-degree camera mounted on a flying-robot

○Genki Ohtani¹, Yasushi Honda¹ (1. Muroran Institute of Technology)

4:20 PM - 4:40 PM

[1L3-J-11-05] Self-supervised learning base target picking system for dual-arm robot considering object instance occlusion

○Shingo Kitagawa¹, Kei Okada¹, Masayuki Inaba¹ (1. the University of Tokyo)

4:40 PM - 5:00 PM

HVGH: 高次元時系列データの深層圧縮と教師なし分節化

HVGH: Segmenting High Dimensional Time Series Data Using VAE and HDP-GP-HSMM

長野匡隼 *1
Masatoshi Nagano中村友昭 *1
Tomoaki Nakamura長井隆行 *2
Takayuki Nagai持橋大地 *3
Daichi Mochihashi小林一郎 *4
Ichiro Kobayashi高野渉 *2
Wataru Takano*1電気通信大学
The University of Electro-Communications*2大阪大学
Osaka University*3統計数理研究所
Institute of Statistical Mathematics*4お茶の水女子大学
Ochanomizu University

Humans recognize perceived continuous high dimensional information by dividing it into significant segments such as words and unit motions. We believe that such unsupervised segmentation is also an important ability for robots to learn topics such as language and motions. To this end, we have been proposed Hierarchical Dirichlet processes-Gaussian Process-Hidden Semi-Markov Model (HDP-GP-HSMM). However, it has a big drawback that the model cannot divide high dimensional time-series data, and it was required to extract low dimensional features in advance. To overcome this problem, in this paper, we propose Hierarchical Dirichlet Processes-Variational Autoencoder-Gaussian Process-Hidden Semi-Markov Model (HVGH). The parameters of HVGH are estimated by mutual learning loop of VAE and HDP-GP-HSMM. Hence, HVGH can extract features from high dimensional time-series data and, simultaneously, divide it into segments in an unsupervised manner. In the experiment, we use the various motion-capture data and show that our proposed model can estimate the correct number of classes and accurate segments compared with baseline methods.

1. Introduction

人は知覚した時系列情報を意味を持つ単位に分節・分類することで認識している。例えば、連続している音声波形を分節することで意味を持つ単位である単語を認識し、人の連続する動作を分節することで単位動作を認識することができる。人は明示的な分節点を与えられることなく自ら学習し、時系列情報を適切に分節・分類している。ロボットにおいても、言語や動作等を柔軟に学習するために、このような教師なしで分節・分類する能力は非常に重要であるといえる。そこで、我々は隠れセミマルコフモデルにおける出力をガウス過程としたノンパラメトリックベイズモデル Hierarchical Dirichlet Processes-Gaussian Process-Hidden Semi-Markov Model (HDP-GP-HSMM) [Nagano 18] を提案し、時系列データの教師なし分節化を可能とした。

しかし、HDP-GP-HSMM では、高次元データを扱うことができず、事前に特徴量抽出を行い低次元化する必要があった。分節化はこの特徴量の設計に大きく依存し、特に高次元データの場合、有効な特徴量を設計することは容易ではない。本稿では、この問題を解決するために、HDP-GP-HSMM に Variational Autoencoder [Kingma 14] を導入した Hierarchical Dirichlet Processes-Variational Autoencoder-Gaussian Process-Hidden Semi-Markov Model (HVGH) を提案する。図1が提案手法の概要である。HVGH では、VAE のエンコーダによって圧縮された潜在変数を HDP-GP-HSMM の入力として用い、さらに HDP-GP-HSMM による学習で得られるパラメータを VAE の事前分布のパラメータとして用いる。このように交互にパラメータを最適化し、VAE により単位系列を表現しやすいような潜在空間が学習される。本稿では、複数のモーションキャプチャデータを用いた実験により、他の教師なし分節化手法よりも分節化及びクラス数推定の精度が高いことを示す。

教師なし分節化では、Hidden Markov Model (HMM) が多く利用されている [Beal 01, Taniguchi 11, Fox 11, Matsubara 14]。しかし、HMM は構造が単純なために、複雑な動作を表現することが難しいと考えられる。一方、我々は Gaussian processes (GP) により時系列データを表現する。GP はノンパラメトリックな手法であり、HMM よりも複雑な動作を表現するのに適していると考えている。実際に HMM を

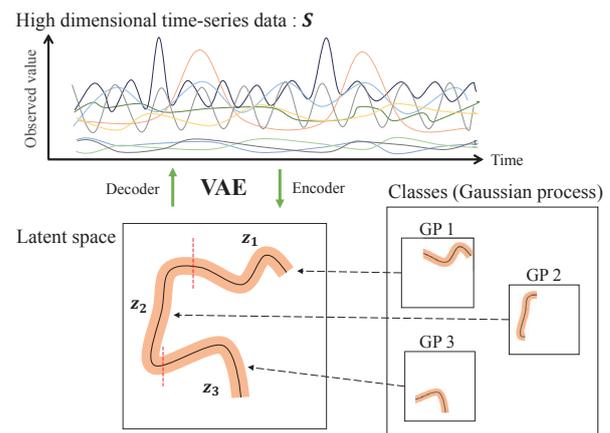


図1: Overview of the generative process of the proposed method.

ベースにした手法に比べ、GP を使った我々の手法の方が分節精度が高いことが確認できている [Nagano 18]。さらに、確率モデルに深層学習を組み合わせた研究も少ないが行われている [Johnson 17]。この研究では、VAE をクラスタリングに利用することで、複雑なデータの分類を可能としている。一方、本稿では、統計モデルである HDP-GP-HSMM と深層学習のモデルである VAE を組み合わせた高次元時系列データの分節化手法を提案する。

2. HVGH

図2に時系列データの生成モデルである提案手法 HVGH のグラフィカルモデルを示す。図において $c_j (j = 1, 2, \dots, \infty)$ は単位系列のクラスであり、無限個のクラス数を仮定している [Teh 06]。 π_c は、クラス c から各クラスへの遷移確率を表しており、 γ をパラメータとする GEM 分布 [Pitman 02] (Stick Breaking Process [Geal 08]) によって生成された β と、 α をパラメータとする Dirichlet Process (DP) から生成される。

$$\beta \sim \text{GEM}(\gamma), \quad (1)$$

$$\pi_c \sim \text{DP}(\eta, \beta). \quad (2)$$

連絡先: 長野匡隼, 電気通信大学, 東京都調布市調布ヶ丘 1-5-1, n1832072@edu.cc.uec.ac.jp

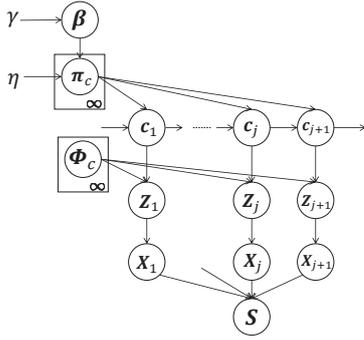


図 2: Graphical model of HVGH

j 番目のクラス c_j は, $j-1$ 番目のクラス c_{j-1} と遷移確率 π_c によって決定される. ここでは, クラスと対応した ϕ_c をパラメータとするガウス過程から単位潜在変数系列 \mathbf{Z}_j が生成されることを仮定している.

$$c_j \sim P(c|c_{j-1}, \pi_c, \alpha), \quad (3)$$

$$\mathbf{Z}_j \sim \mathcal{GP}(\mathbf{Z}|\phi_{c_j}), \quad (4)$$

ただし, ϕ_c はクラス c に分類された単位潜在変数系列の集合である. 単位系列 \mathbf{X}_j は, 単位潜在変数系列 \mathbf{Z}_j から VAE のデコーダ P_{dec} により生成される.

$$\mathbf{X}_j \sim p_{dec}(\mathbf{X}|\mathbf{Z}_j). \quad (5)$$

これらの単位系列 \mathbf{X}_j を結合することで得られる系列を観測系列 $\mathbf{s} = \mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_J$ と呼び, \mathbf{Z}_j を結合することで得られる系列を潜在変数系列 $\bar{\mathbf{s}} = \mathbf{Z}_0, \mathbf{Z}_1, \dots, \mathbf{Z}_J$ と呼ぶ. また, 以降, \mathbf{X}_j に含まれる i 番目のデータ点を \mathbf{x}_{ji} , \mathbf{Z}_j に含まれる i 番目のデータ点を \mathbf{z}_{ji} と表記し, 明らかな場合はその添字を省略する.

2.1 Gaussian Process (GP)

本稿では, 単位系列のタイムステップ i における潜在変数 z_i をガウス過程回帰で学習することで, 各クラスの単位潜在変数系列を連続的に表現する. ガウス過程では, クラス c に分類された分節の集合を ϕ_c とし, それと対応したタイムステップ i の組 (i, ϕ_c) が得られた時, タイムステップ i^{new} における z^{new} の予測分布は次式のガウス分布となる.

$$p(z^{new}|i^{new}, \phi_c, \mathbf{i}) \propto \mathcal{N}(z|\mu, \sigma^2) \quad (6)$$

$$\mu = \mathbf{k}^T \mathbf{C}^{-1} \mathbf{i} \quad (7)$$

$$\sigma^2 = c - \mathbf{k}^T \mathbf{C}^{-1} \mathbf{k} \quad (8)$$

ただし, $k(\cdot, \cdot)$ をカーネル関数として, \mathbf{C} は,

$$C(i_p, i_q) = k(i_p, i_q) + \omega^{-1} \delta_{pq}. \quad (9)$$

を要素に持つ行列である. ここで, ω はノイズを表現するハイパーパラメータを示す. また, \mathbf{k} は $k(i_p, i^{new})$ を要素に持つベクトルであり, c は $k(i^{new}, i^{new})$ である. ガウス過程では, カーネル関数を用いることで複雑に変化する時系列データを学習することが可能である. 本稿では, ガウス過程回帰に一般的に用いられる以下のようなガウスカーネルを用いる.

$$k(i_p, i_q) = \theta_0 \exp(-\frac{1}{2} \theta_1 \|i_p - i_q\|^2 + \theta_2 + \theta_3 i_p i_q), \quad (10)$$

ただし, θ_* はカーネルのパラメータである.

さらに, 観測系列が多次元のベクトルの場合は, 各次元が独立に生成されると仮定し, 時刻 i の出力値 $\mathbf{z} = (z_0, z_1, \dots)$ が

クラス c に対応するガウス過程から生成される確率 $\mathcal{GP}(\mathbf{z}|\phi_c)$ を以下のように計算する.

$$\begin{aligned} \mathcal{GP}(\mathbf{z}|\phi_c) &= p(z_0|i, \phi_{c,0}, \mathbf{i}) \\ &\quad \times p(z_1|i, \phi_{c,1}, \mathbf{i}) \\ &\quad \times p(z_2|i, \phi_{c,2}, \mathbf{i}) \cdots \\ &= \mathcal{N}(z|\mu_0, \sigma_0^2) \mathcal{N}(z|\mu_1, \sigma_1^2) \mathcal{N}(z|\mu_2, \sigma_2^2) \cdots \end{aligned} \quad (11)$$

この確率により類似する単位潜在変数系列を同じクラスへ分類することが可能となる. さらに, 各次元が独立に生成されるため, $\mathcal{GP}(\mathbf{z}_{ji}|\mathbf{Z}_c)$ の平均ベクトル $\mu_c(i)$ と分散・共分散行列 $\Sigma_c(i)$ は, 各次元の平均 $(\mu_0, \mu_1, \mu_2, \dots)$ と分散 $(\sigma_0^2, \sigma_1^2, \sigma_2^2, \dots)$ を用いて次式のようになる.

$$\mu_c(i) = (\mu_0, \mu_1, \mu_2, \dots), \quad (12)$$

$$\Sigma_c(i) = \begin{bmatrix} \sigma_1^2 & 0 & 0 \\ 0 & \sigma_2^2 & 0 \\ 0 & 0 & \ddots \end{bmatrix} \quad (13)$$

HVGH では, $\mu_c(i)$ と $\Sigma_c(i)$ をパラメータとするガウス分布を VAE の事前分布とすることで, VAE と GP が相互に影響するモデルとなる.

2.2 Variational Autoencoder (VAE)

本稿では, Variational Autoencoder (VAE) [Kingma 14] を用いることで高次元時系列データを次元圧縮し低次元の潜在変数で表現する. VAE は, 高次元データである入力 \mathbf{x} と潜在変数 \mathbf{z} の対応関係を学習するニューラルネットワークである. \mathbf{x} を入力としたエンコーダネットワークを通して平均 $\mu_{enc}(\mathbf{x})$ と分散 $\Sigma_{enc}(\mathbf{x})$ を推定する. 潜在変数は, それらをパラメータとしたガウス分布を $q_{enc}(\mathbf{z})$ に基づき確率的に決定される. さらにデコーダネットワーク p_{dec} を通して, データ \mathbf{x}' が生成される.

$$q_{enc}(\mathbf{z}) = \mathcal{N}(\mathbf{z}|\mu_{enc}(\mathbf{x}), \Sigma_{enc}(\mathbf{x})) \quad (14)$$

$$\mathbf{z} \sim q_{enc}(\mathbf{z}) \quad (15)$$

$$\mathbf{x}' \sim p_{dec}(\mathbf{x}|\mathbf{z}) \quad (16)$$

VAE では変分ベイズ法を用いて, 尤度 $p(\mathbf{x})$ が最大となるエンコーダとデコーダのパラメータを決定する. また, 通常の VAE では, 事前分布として平均をゼロベクトル $\mathbf{0}$, 分散・共分散行列を単位行列 \mathbf{e} としたガウス分布が用いられる. しかし, HVGH では, \mathbf{z}_{ji} を決定する際に, 前節で計算した \mathbf{z}_{ji} が分類されたクラス c の $\mu_c(i)$ と $\Sigma_c(i)$ をパラメータとしたガウス分布を用いる. これにより, 分節化に適した潜在空間が構成される. この VAE を用いて, 観測系列 $\mathbf{s} = \mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_J$ をエンコーダによって潜在変数へ変換し, 潜在変数系列 $\bar{\mathbf{s}} = \mathbf{Z}_0, \mathbf{Z}_1, \dots, \mathbf{Z}_J$ を得ることができる.

3. 学習

図 3 が HVGH のパラメータ推定の概要である. 観測系列 \mathbf{s} は VAE により潜在変数系列 $\bar{\mathbf{s}}$ へと変換される. HDP-GP-HSMM では, 潜在変数系列 $\bar{\mathbf{s}}$ を $\mathbf{Z}_0, \mathbf{Z}_1, \dots$ へと分節することで, \mathbf{z} の予測分布のパラメータ $\mu_c(i)$ と分散・共分散行列 $\Sigma_c(i)$ を計算する. この予測分布を, VAE の事前分布として用いることで, VAE と HDP-GP-HSMM を相互に最適化することができる.

HDP-GP-HSMM のパラメータの学習では, 潜在変数系列の分節とそのクラスを Blocked Gibbs Sampler [Jensen 95] によりサンプリングすることで推定する. まず, 全ての観測系列を圧縮することで得られる潜在変数系列をランダムに分節・分

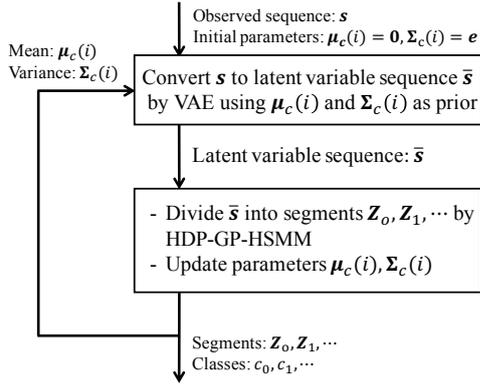


図 3: Overview of the parameter estimation of HVGH. The parameters are learned by mutual learning loop of VAE and HDP-GP-HSMM.

類することで初期化する。次に、 n 番目の潜在変数系列 \bar{s}_n の分節 $Z_{n,j} (j = 1, 2, \dots, J_n)$ を、それらが分類されているクラスからすべて削除し、各クラスのガウス過程のパラメータ ϕ_c と遷移確率 $P(c|c')$ を更新する。次に、次式に従い n 番目の潜在変数系列の分節と、そのクラスをサンプリングする。

$$(Z_{n,1}, \dots, Z_{n,J_n}), (c_{n,1}, \dots, c_{n,J_n}) \sim P((Z_0, Z_1, \dots), (c_0, c_1, \dots) | \bar{s}_n). \quad (17)$$

これらの値を用いて各クラスのガウス過程のパラメータ ϕ_c と遷移確率 $P(c|c')$ を更新する。以上の操作を全ての観測系列に対して繰り返すことで、分節とガウス過程のパラメータを交互に最適化することができる。しかし、このままでは遷移先のクラス数は無限個存在するため、各分節が各クラスに分類される確率を全て計算することは困難である。そこで、Slice Sampler [Geal 08] を用いることで、確率的にクラス数を有限個に制限し計算を可能とする。さらに、式 (17) では、あり得る分節・分類の全ての組み合わせに対して確率を与えなければならない、単純には計算できない。そこで、Forward Filtering-Backward Sampling [Uchiumi 15] を用いることでこの確率を計算し、サンプリングする。

VAE の学習では、尤度 $p(\mathbf{x})$ を最大化するエンコーダとデコーダのパラメータを決定する。一般的な VAE では、次式の変分下限を最大化するパラメータを決定する。

$$L(\mathbf{x}_{ji}, z_{ji}) = \int q_{enc}(z_{ji} | \mathbf{x}_{ji}) \log p_{dec}(\mathbf{x}_{ji} | z_{ji}) dz_{ji} - D_{KL}(q_{enc}(z_{ji} | \mathbf{x}_{ji}) || p(z_{ji} | \mathbf{0}, \mathbf{e})) \quad (18)$$

$\int q_{enc}(z_{ji} | \mathbf{x}_{ji}) \log p_{dec}(\mathbf{x}_{ji} | z_{ji}) dz_{ji}$ は復元誤差を表している。また、 $p(z_{ji} | \mathbf{0}, \mathbf{e})$ は z_{ji} の事前分布であり、平均が $\mathbf{0}$ 、分散が単位行列 \mathbf{e} となるガウス分布である。 $D_{KL}(q_{enc}(z_{ji} | \mathbf{x}_{ji}) || p(z_{ji} | \mathbf{0}, \mathbf{e}))$ はカルバック・ライブラー・ダイバージェンスであり、正則化項となっている。一方 HVGH では、HDP-GP-HSMM により推定された z_{ji} が分類されているクラス c の予測分布のパラメータである平均 $\mu_c(i)$ と分散 $\Sigma_c(i)$ を事前分布 $p(z_{ji} | \mu_c(i), \Sigma_c(i))$ のパラメータとして用いる。

$$L(\mathbf{x}_{ji}, z_{ji}) = \int q_{enc}(z_{ji} | \mathbf{x}_{ji}) \log p_{dec}(\mathbf{x}_{ji} | z_{ji}) dz_{ji} - D_{KL}(q_{enc}(z_{ji} | \mathbf{x}_{ji}) || p(z_{ji} | \mu_c(i), \Sigma_c(i))) \quad (19)$$

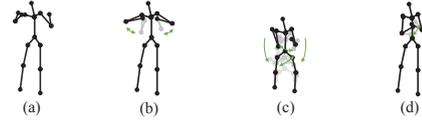


図 4: Four unit motions included in the chicken dance: (a) beaks, (b) wings, (c) tail feathers, and (d) claps.

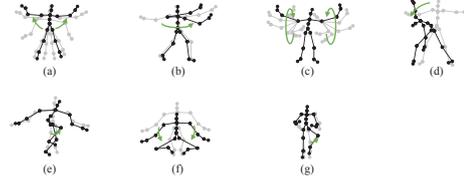


図 5: Seven unit motions included in the exercise motion1: (a) jumping jack, (b) twist, (c) arm circle, (d) bend over, (e) knee raise, (f) squatting, and (g) jogging

事前分布が $p(z_{ji} | \mathbf{0}, \mathbf{e})$ の場合、どのようなデータ点に対しても潜在変数の事前分布は $\mathcal{N}(\mathbf{0}, \mathbf{e})$ となる。一方、 $p(z_{ji} | \mu_c(i), \Sigma_c(i))$ を事前分布に用いた HVGH では、GP によって計算された平均 $\mu_c(i)$ 、分散 $\Sigma_c(i)$ をパラメータとしたガウス分布が事前分布になる。GP では時間が近いデータ点では近い値を出力するような制約が働くため、潜在変数 z_{ji} は、前後の潜在変数 $z_{j,i-1}$ や $z_{j,i+1}$ と近い値となり、時系列データの特性を表現した潜在空間が学習される。さらに、これらのパラメータはクラス毎に計算されるため、クラス毎の潜在変数の特徴が反映される。

4. 実験

提案手法 HVGH の有効性を検証するために、複数のモーションキャプチャデータに対して分節化を行ない、HDP-GP-HSMM [Nagano 18], HDP-HMM [Beal 01], HDP-HMM+NPYLM [Taniguchi 11], BP-HMM [Fox 11], Autoplaik [Matsubara 14] と比較した。評価指標は文献 [Nagano 18] と同様に、正規化ハミング距離、適合率、再現率、F 値を用いた。分節の誤差の許容範囲は観測系列の全フレーム数の $\pm 5\%$ とした。

評価には、以下の 2 つのモーションキャプチャデータを用いた。

- **チキンダンス:** CMU Graphics Lab Motion Capture Database のチキンダンスのモーションキャプチャデータを用いた*1。このダンスには、図 4 のように 4 つの単位動作が含まれている。
- **体操動作 1:** ダンス以外の動作として、CMU Graphics Lab Motion Capture Database の subject 13 の体操のモーションキャプチャデータを用いた。このデータは 3 つのシーケンスがあり、図 5 のように 7 個の単位動作が含まれている。

計算量を削減するため、全てのデータを毎秒 4 フレームにダウンサンプリングした。モーションキャプチャデータは 31 個の身体部位の方向が 3 次元のオイラー角で記述されており、各フレームは 93 次元のベクトルで構成されている。本実験では、この 93 次元をそのまま入力とした。また、HVGH ではハイパーパラメータが必要であり、経験的に決めた $\lambda = 14.0, \theta_0 = 1.0, \theta_1 = 1.0, \theta_2 = 0.0, \theta_3 = 16.0$ を用いた。VAE の学習では入力データ点の 1/4 をミニバッチとして使用し、最適化には Adam [Kingma 17] を使い、更新は 150 回繰り返した。HDP-GP-HSMM の学習では、ブロックギブスサンプラーを 10 回繰り返した。さらに、VAE と HDP-GP-HSMM のループは、VAE の変分下限が収束するまで繰り返した。

*1 <http://mocap.cs.cmu.edu/>: subject 18, trial 15

表 1: Segmentation results for the chicken dance.

	Hamming distance	Precision	Recall	F-measure	# of estimated classes
HVGH	0.23	0.86	0.86	0.86	4
VAE+HDP-GP-HSMM	0.31	1.0	0.71	0.83	4
VAE+HDP-HMM	0.74	0.15	1.0	0.26	11
VAE+HDP-HMM+NPYLM	0.48	1.0	0.86	0.92	7
VAE+BP-HMM	0.34	1.0	0.86	0.92	3
VAE+Autoplaît	0.66	0.0	0.0	0.0	1

表 2: Segmentation results for the exercise motion.

	Hamming distance	Precision	Recall	F-measure	# of estimated classes
HVGH	0.16	0.66	0.93	0.75	11
VAE+HDP-GP-HSMM	0.24	0.53	0.93	0.67	12
VAE+HDP-HMM	0.75	0.05	1.0	0.09	10
VAE+HDP-HMM+NPYLM	0.61	0.30	1.0	0.45	28
VAE+BP-HMM	0.58	0.29	0.97	0.44	7
VAE+Autoplaît	0.76	0.0	0.0	0.0	2

実際に 93 次元の時系列データをそのまま入力し分節化を行った。しかし、HVGH 以外の手法では 93 次元の高次元の時系列データそのままでは適切な分節はできなかった。そこで、HVGH とパラメータを同じにした VAE を使い、93 次元のデータを圧縮した 3 次元の潜在変数を入力として分節化を行なった。表 1, 2 にそれぞれの手法により 2 つのモーションキャプチャデータを分節した結果を示す。

VAE+HDP-GP-HSMM と VAE+BP-HMM は、chicken dance のデータを比較的高い精度で分節化できている。しかし VAE+BP-HMM の体操 1 のデータの分節化では、chicken dance のデータに比べて正規化ハミング距離の値も大きく、F 値は小さくなっている。これは、chicken dance が単純な動作の繰り返しであり、含まれる各単位動作の違いが明確であるため、HMM を用いたシンプルな手法であっても分節化が容易であったと考えられる。一方、ノンパラメトリックな手法であるガウス過程を用いている HDP-GP-HSMM と HVGH は、複雑な動作が含まれている体操を分節化することができている。さらに、HVGH ではガウス過程で学習される各タイムステップの平均と分散を VAE の事前分布とすることで、各単位動作を表現する潜在変数系列が学習できたため、VAE+HDP-GP-HSMM より精度が良くなったと考えられる。

また、提案手法では chicken dance のクラス数を正しく推定できた。しかし、体操 1 においては複雑な動作が含まれており、正解より多いクラス数が推定された。体操 1 では、正解のクラス数である 7 よりも多く推定された。これは、何もしていない静止状態を 1 つの単位動作として学習し、また左右対称に同じ動きをする動作を左側に行う場合と右側に行う場合の 2 つを単位動作として学習したためである。しかし、静止動作を 1 つの単位動作とすることは必ずしも誤りとは言えず、またモーションキャプチャデータは左側に行う動作と右側に行う動作は異なる値となるため別の動作として学習することは妥当であるといえる。さらに他の手法と比較すると、HVGH で推定されたクラス数は他の手法で推定したクラス数より正解に近く、HVGH が最も正しくクラス数を推定できていることがわかる。

以上の結果より、HVGH を用いることで、高次元の時系列データの分節化とクラス数の推定が可能であることが示された。

5. Conclusion

本稿では、VAE と HDP-GP-HSMM を相互学習することで、高次元の時系列データの分節、分類、クラス数推定を可能とした HVGH を提案した。提案手法では、VAE により単位動作の特徴を捉えた潜在変数系列が学習され、その潜在変数系列を用いることで高精度な分節化が可能となった。実際に実験により、HVGH が高次元時系列データの特徴を捉えて分節・分類が可能であることを示した。さらに、VAE と HDP-GP-HSMM をそれぞれ独立させて学習したモデルより、相互にパラメータ

を更新する HVGH の方が精度が高いことが示された。

しかし、HVGH はガウス過程を用いているため、 N 個のデータ点を学習させるのに $O(N^3)$ の計算量がかかり、さらにそれを相互学習のループで繰り返すため、計算コストが非常に高くなる。そのために、HVGH では長い時系列データを分節することが困難である。そこで今後、ガウス過程の近似法を導入することによって計算コストの削減を考えている。

謝辞

本研究は JST CREST JPMJCR15E3, JSPS 科研費 JP18H03295 の助成を受け実施したものである。

参考文献

- [Beal 01] M. J. Beal, Z. Ghahramani, and C. E. Rasmussen, "The infinite hidden Markov model," In *Advances in Neural Information Processing Systems*, pp.577–584, 2001.
- [Fox 11] E. B. Fox, E. B. Sudderth, M. I. Jordan, and A. S. Willsky, "Joint modeling of multiple related time series via the beta process," arXiv preprint arXiv:1111.4226, 2011.
- [Geal 08] J. V. Gae, Y. Saatchi, Y. W. Teh, and Z. Ghahramani, "Beam Sampling for the Infinite Hidden Markov Model," *International Conference on Machine Learning*, pp.1088–1095, 2008.
- [Jensen 95] Jensen. Claus S, Kjærulff. Uffe and Kong. Augustine, "Blocking Gibbs sampling in very large probabilistic expert systems," *International Journal of Human-Computer Studies*, vol. 42, no.6, pp.647–666, 1995.
- [Johnson 17] Matthew James Johnson, David Duvenaud, Alexander B. Wiltschko, Sandeep R. Datta, Ryan P. Adams, "Composing graphical models with neural networks for structured representations and fast inference," arXiv preprint arXiv:1603.06277v5, 2017.
- [Kingma 14] Diederik P. Kingma, Max Welling, "Auto-Encoding Variational Bayes," arXiv preprint arXiv:1312.6114, 2014.
- [Kingma 17] Diederik P. Kingma, Jimmy Lei Ba, "ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION," arXiv:1412.6980v9, 2017.
- [Matsubara 14] Y. Matsubara, Y. Sakurai, and C. Faloutsos, "Autoplaît: Automatic mining of co-evolving time sequences," *ACM SIGMOD International Conference on Management of Data*, pp.193–204, 2014.
- [Nagano 18] M. Nagano, T. Nakamura, T. Nagai, D. Mochihashi, I. Kobayashi, and M. Kaneko, "Sequence Pattern Extraction by Segmenting Time Series Data Using GP-HSMM with Hierarchical Dirichlet Process," *International Conference on Intelligent Robots and Systems*, pp. 4067–4074, 2018.
- [Pitman 02] J. Pitman, "Poisson-Dirichlet and GEM invariant distributions for split-and-merge transformations of an interval partition," *Combinatorics, Probability and Computing*, vol.11, pp.501–514, 2002.
- [Taniguchi 11] Taniguchi. T, and Nagasaka. S, "Double articulation analyzer for unsegmented human motion using Pitman-Yor language model and infinite hidden Markov model," In *IEEE/SICE International Symposium on System Integration*, pp.250–255, 2011.
- [Teh 06] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei, "Hierarchical Dirichlet processes," *Journal of the American Statistical Association*, vol.101, no.476, pp.1566–1581, 2006.
- [Uchiumi 15] K. Uchiumi, T. Hiroshi, and D. Mochihashi, "Inducing Word and Part-of-Speech with Pitman-Yor Hidden Semi-Markov Models," *Joint Conference of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*, pp.1774–1782, 2015.

複合現実によるロボットの空間認識可視化のための Semantic-ICP を用いたキャリブレーション

Calibration System Using Semantic-ICP for Visualization of Robot Spatial Perception Through Mixed Reality

中村仁
Hitoshi Nakamura

エルハフィロトフィ
Lotfi El Hafi

萩原良信
Yoshinobu Hagiwara

谷口忠大
Taniguchi Tadahiro

立命館大学
Ritsumeikan University

To achieve symbiosis between humans and robots, it is important to know what the robots recognize in their environment. Such information can be displayed using a Mixed Reality (MR) head-mounted device to provide an intuitive understanding of a robot perception. However, a robust calibration system is required because the robot and head-mounted MR device have different coordinate systems. In this paper, we develop a semantic-based calibration system for human-robot interactions in MR using Semantic-ICP. We show that the calibration system using Semantic-ICP is better than using GICP SE(3) when the accuracy of the semantic labels is high.

1. はじめに

家庭環境内で人間と共同で動作するロボットが、ヘッドマウントディスプレイを介して人間とインタラクションを行う場合、ロボットとデバイス間のキャリブレーションが必要である。近年、複合現実や拡張現実を用いたロボットの内部表現の可視化や、それらの情報を元にした追加学習を行う研究が行われている [Collett 06, Liu 18]。このような研究においてロボットとヘッドマウントディスプレイが異なる座標系を持っている場合、キャリブレーションを行わなければロボット自身の座標系に基づいた内部表現をヘッドマウントディスプレイの座標系に基づいた現実空間の該当する位置に可視化することが出来ない。

既存手法の多くでは AR マーカを用いてキャリブレーションを行う手法が用いられてきた [Liu 18]。しかし、AR マーカを用いる場合は、AR マーカが設置された範囲内ではキャリブレーションを行うことができないため、環境内に多数の AR マーカを配置する必要がある、またそれには手間がかかる。この問題を解決するためには、ロボットとヘッドマウントディスプレイのそれぞれから得られる Point Cloud を用いたキャリブレーションが利用できる。しかしながら、両デバイス間における Point Cloud の取得方法が異なっている場合、正確なキャリブレーションは困難である。

そこで本研究では、より正確な位置にロボットの内部表現を描画するために、Point Cloud に画像特徴量としてセマンティックラベルの確率分布を付加したものをキャリブレーションに用いる手法を提案する。図 1 に、2.4 節で詳しく述べる Semantic-ICP を用いたロボットとヘッドマウントディスプレイにおけるキャリブレーション手法の図を示す。

2. 関連研究

2.1 キャリブレーション手法

Liu らは、ロボットの関節上にマーカを描画する際に、ロボットの正確な位置を認識するために AR マーカを使用していた [Liu 18]。この研究では、ヘッドマウントディスプレイを装着した人間は常にロボットを見ているため、ロボットに搭載

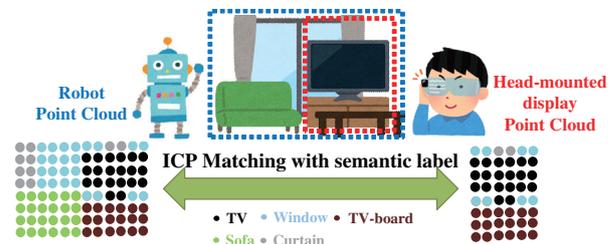


図 1: Semantic-ICP を用いたロボットとヘッドマウントディスプレイ間のキャリブレーション

されたディスプレイ上に AR マーカを表示することによってキャリブレーションを行っていた。AR マーカを用いたキャリブレーション手法ではロボットが移動したり人間が移動したりして AR マーカを捕捉できなくなった場合、キャリブレーション誤差が発生してしまう。また人間が誤差を軽減するために何度もタグを見て再キャリブレーションを行う必要があるという欠点がある。

本研究ではこれらの欠点を踏まえ、人間のキャリブレーションに関わる作業コストを削減し、誤差の少ないキャリブレーションを実現するために、互いの Point Cloud を用いた自動でキャリブレーションを行う手法を提案する。

2.2 ICP と Generalized-ICP

二つの Point Cloud をマッチングする手法として Iterative Closest Point (ICP) [Besl 92] がよく用いられる。また, Segal らは ICP を応用し, 確率的なモデルを使った Generalized-ICP (G-ICP) を提案した [Segal 09]。ICP, G-ICP は大きく分けて以下の 3 つのステップで処理が行われる。

STEP 1 X_t, X_s の対応関係 I を計算する

STEP 2 最適な変換行列 T^* を求める

STEP 3 前サイクルの最適な変換行列 T^{old} と T^* を比較し, その誤差が ϵ より小さければ終了する

ただし, $X_t = \{x_1^t, x_2^t \dots x_n^t\}$, $X_s = \{x_1^s, x_2^s \dots x_n^s\}$ を Point Cloud 集合, I を二つの Point Cloud の対応関係集合,

連絡先: 中村 仁, 立命館大学情報理工学研究所, 滋賀県草津市野路東 1-1-1, nakamura.hitoshi@em.ci.ritsumeik.ac.jp

\mathbf{T} を二つの Point Cloud 間の変換行列, ϵ を変換行列後の二つの Point Cloud 間の許容する誤差とする. まず STEP 1 において $\mathbf{X}_t, \mathbf{X}_s$ 内の点一つ一つの対応関係を計算する. 最近傍探索手法によって式 (1) を用いることによって最も近い点を探索する. 関数 d は $\mathbf{x}_i^t (\in \mathbf{x}_t)$ と一番近い距離にある点 $\mathbf{x}_i^s (\in \mathbf{x}_s)$ を取得するものである. 式 (1) によって \mathbf{x}_t と \mathbf{x}_s の全ての点の対応を求めたものの集合が \mathbf{I} である.

$$d(\mathbf{x}_i^t, \mathbf{X}_s) = \min_{\mathbf{x}_i^s \in \mathbf{x}_s} \|\mathbf{x}_i^t - \mathbf{x}_i^s\| \quad (1)$$

STEP 2 では最適な変換行列を求める計算を行う. ここでの変換行列は $\mathbf{T} = \mathbf{R}\mathbf{x}_i^t + \mathbf{p}$ と表される. ここで, \mathbf{R} はユークリッド空間での回転行列, \mathbf{p} は並進ベクトルを表している. \mathbf{x}_s を固定して \mathbf{x}_t の中から \mathbf{x}_i^t を取得し, その点 \mathbf{x}_i^t を \mathbf{R} によって回転させ, \mathbf{p} によって平行移動を行う. ICP の場合, 式 (2) を用いて最適な変換行列を求める. ここで ω_i は, $\|\mathbf{x}_i^t - \mathbf{T} \cdot \mathbf{x}_i^s\| \leq \mathbf{d}_{\max}$ を満たす時に $\omega_i = 1$ を, それ以外は $\omega_i = 0$ を取る変数である. また, \mathbf{d}_{\max} は, 計測誤差によるマッチング精度が減少するのを防ぐパラメータである. 対応付けられた 2 つの点の距離が \mathbf{d}_{\max} 以上であった場合, 計測誤差として計算対象外とするためである.

$$\mathbf{T}^* \leftarrow \operatorname{argmin}_{\mathbf{T}} \sum_i \omega_i \|\mathbf{T} \cdot \mathbf{x}_i^s - \mathbf{x}_i^t\|^2 \quad (2)$$

2.3 GICP-SE(3)

Parkison らは G-ICP を Absil らの手法 [Absil 08] を参考にして特殊ユークリッド群 (SE(3)) に適応させた GICP-SE(3) を提案した [Parkison 18]. G-ICP との違いとして最適な変換行列を求める式が f_{GICP} に変更されている. ここで C_k は $C_k \triangleq \sum_k^t + R \sum_k^s R^T$ と表される. \sum_k^t, \sum_k^s は各 Point Cloud が正規分布から得られていると仮定した際の分散である. また f_{GICP} は式 (3) である. ここで P_α 関数はコーシー損失関数であり, $P_\alpha(x) = \alpha^2 \log(1 + \frac{x^2}{\alpha^2})$ とする. また, α は損失が直線的に減少し始める場所を制御するパラメータ, n はマッチング対象の点の数である. また, 式 (3) 内の変換行列 $\mathbf{T} \in \mathbf{SE}(3)$ は式 (4) で示される.

$$\mathbf{T}^* \leftarrow \operatorname{argmax}_{\mathbf{T} \in \mathbf{SE}(3)} f_{GICP}$$

$$f_{GICP} = \sum_k p_\alpha(\|\mathbf{x}_k^t - \mathbf{T}(\mathbf{x}_k^s)\|_{C_k}^2) \quad (3)$$

$$\mathbf{T} \in \mathbf{SE}(3) = \begin{pmatrix} \mathbf{R} & \mathbf{p} \\ 0 & 1 \end{pmatrix} \quad (4)$$

2.4 Semantic-ICP

Parkison らは GICP-SE(3) にセマンティックラベルの確率分布を付加した Semantic-ICP を提案した [Parkison 18]. GICP-SE(3) と異なる点として, 式 (3) に示した関数 f_{GICP} に, 式 (5) によって得られる重み ω_k を新たなパラメータとして加えた関数 f_{SICP} を用いている点である.

$$\omega_k \triangleq \sum_{\mathbf{s}_k \in \mathbf{C}} p(\mathbf{r}_k | \mathbf{i}_k, \mathbf{x}_k^t, \mathbf{X}_k^s, \mathbf{T}^{\text{old}}) p(\mathbf{s}_k | \mathbf{i}_k, \mathbf{x}_t)$$

$$p(\mathbf{s}_k | \mathbf{i}_k, \mathbf{x}_s) p(\mathbf{i}_k | \mathbf{x}_k^t, \mathbf{x}_k^s) \quad (5)$$

式 (5) は式 (6) の式より導かれている. f_{SICP} を式 (7) のように表す. 式 (6) は二つの Point Cloud が与えられた時の

それらの対応関係, セマンティックラベル情報, 変換行列のパラメータが得られる条件付き確率はベイズ則を用いて右辺のように近似できることを示している. ここで, \mathcal{R} は \mathbf{T} の残差パラメータ, \mathbf{C} をセマンティックラベル集合, \mathbf{S} を環境内にあるセマンティックラベル集合, N をセマンティックラベルの数とする.

$$p(\mathcal{R}, \mathbf{S}, \mathbf{I} | \mathbf{X}_t, \mathbf{X}_s) \propto p(\mathcal{R} | \mathbf{I}, \mathbf{X}_t, \mathbf{X}_s) p(\mathbf{S} | \mathbf{I}, \mathbf{X}_t) p(\mathbf{S} | \mathbf{I}, \mathbf{X}_s) p(\mathbf{I} | \mathbf{X}_t, \mathbf{X}_s) \quad (6)$$

$$\mathbf{T}^* \leftarrow \operatorname{argmax}_{\mathbf{T} \in \mathbf{SE}(3)} f_{SICP}$$

$$f_{SICP} = \sum_{k=1}^{n \times N} p_\alpha(\omega_k \|\mathbf{x}_k^t - \mathbf{T}(\mathbf{x}_k^s)\|_{C_k}^2) \quad (7)$$

また, 式 (5) でのセマンティックラベルごとの Point Cloud の対応関係 \mathbf{i}_k の条件付き確率 $p(\mathbf{i}_k | \mathbf{x}_k^t, \mathbf{x}_k^s)$ は式 (8) によって示される. ここで $nn(x_k^t)$ は x_k^t の x_k^s 内にある近傍点の数を求める関数である. 本研究では図 1 に示したように, この Semantic-ICP を用いて実験を行う.

$$p(\mathbf{i}_k | \mathbf{x}_k^t, \mathbf{x}_k^s) \triangleq \begin{cases} \frac{1}{N} & \text{if } nn(\mathbf{x}_k^t) = N \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

3. 提案手法

3.1 概要

Point Cloud を用いたキャリブレーションとして, 一般的に ICP がよく用いられる. しかしながら, 本研究ではヘッドマウントディスプレイとロボットが異なるセンサーを用いて異なる手法で Point Cloud を取得している為, 一般的な ICP では良い結果が得られないと考えられる. そのため, 本研究では, ヘッドマウントディスプレイとロボットのキャリブレーションを, 互いのカメラセンサから得られる Point Cloud に画像特徴量として得られるセマンティックラベルの確率分布を付加したものをを用いてキャリブレーションする手法を提案する. セマンティックラベルとは, 画像内に含まれるオブジェクトの名前のことである. ここで, セマンティックラベルの確率分布を付加した Point Cloud を Semantic Point Cloud と定義する. Semantic Point Cloud は以下の 3 つのステップによって生成する. また提案手法では CNN として PSPNet [Zhao 17] を用いる.

STEP 1 RGB-D カメラを使用して Point Cloud, RGB 画像を取得する

STEP 2 RGB 画像を PSPNet を用いてセマンティックセグメンテーションを行いピクセルごとにセマンティックラベルの確率分布を取得する

STEP 3 STEP 1,2 で得られたピクセルごとのセマンティックラベルの確率分布から得られる最も生成確率の高いセマンティックラベルを Point Cloud を対応させ, Semantic Point Cloud を生成する

3.2 ロボット側の Semantic Point Cloud の生成手法

本手法では, ロボットは環境内全体の地図を Semantic Point Cloud として保有しているものとする. 本手法ではロボットの Semantic Point Cloud を用いた 3D の地図作成に Semantic

SLAM [Zhang 18] を改変して用いた。Semantic SLAM に用いられている RGB-D カメラの位置情報を把握するために用いられている ORB-SLAM を用いずに、ロボットの標準機能として取得できる RGB-D カメラの位置情報をそのまま用いる。ORB-SLAM よりもより精度の高い位置情報が得られるためである。また本手法では 3D 地図の作成に Octomap [Hornung 13] を用いた。Octomap で得られたボクセルマップを、Semantic Point Cloud 形式に変換することによって、環境内の Semantic Point Cloud の 3D の地図を作成することができる。ここで環境内の Semantic Point Cloud の 3D の地図のことを 3D Semantic Map と定義する。

3.3 ヘッドマウントディスプレイ側の Semantic Point Cloud の生成手法

本手法で用いるヘッドマウントディスプレイとして HoloLens を用いる。HoloLens は RGB 画像は取得できるが、Point Cloud を取得することが出来ないため、以下の 4 つのステップによって Point Cloud を取得する。

STEP 1 RGB 画像を撮影する

STEP 2 各ピクセルごとにカメラ間のベクトルを生成する

STEP 3 各ベクトルをカメラが向いている方向に延長し、Spatial Mapping に接触した場合、そのベクトルの長さをそのピクセルの深度として取得する

STEP 4 そのピクセルの座標と深度を用いて Point Cloud とする

以上の 4 ステップの後、得られた Point Cloud を 3D Semantic Map 作成に用いた同様の PSPNet のモデルを使用して最も生成確率が高いセマンティックラベルを付加した Semantic Point Cloud を生成する。

3.4 Semantic-ICP を用いたマッチング

ロボットによって得られる 3D の地図データの Semantic Point Cloud と HoloLens が現在見ている部分の Semantic Point Cloud を Semantic-ICP を使ってマッチングさせることによってキャリブレーションを行う。Semantic Point Cloud の照合によって、互いの Semantic Point Cloud 間における最適な変換行列がわかり、同時に互いの座標系間における座標系変換を推定することが可能となる。本研究では 2.2 節で示した変数 \mathbf{X}_t をロボットの 3D Semantic Map, \mathbf{X}_s をヘッドマウントディスプレイの Semantic Point Cloud, \mathbf{S} を互いの Point Cloud 内に存在するセマンティックラベルとして考える。式 (6) で示した重み ω_k の $p(\mathbf{s}_k|\mathbf{i}_k, \mathbf{x}_t)$, $p(\mathbf{s}_k|\mathbf{i}_k, \mathbf{x}_s)$ は CNN から得られるセマンティックラベルごとの生成確率を扱うが、本研究では各 Point Cloud ごとに一番生成確率が高かったラベルの確率を 1, それ以外のラベルの確率を 0 にして重み ω_k を計算する。

4. 実験

4.1 概要

本研究では、家庭環境を模した環境で、Semantic-ICP を用いたロボットとヘッドマウントディスプレイ間のキャリブレーションを行う実験を行う。



図 2: 実験で用いた環境の画像

4.2 実験条件

本実験では家庭環境を模した実環境で実験を行う。またロボットとしてトヨタ自動車株式会社の Human Support Robot (HSR), ヘッドマウントディスプレイとして Microsoft 社の HoloLens を使用する。ロボットは家庭環境内の 3D の地図データを事前に保持しているものとし、その地図データの原点がわかっているものとする。また、ヘッドマウントディスプレイは装着者が向いている方向の Point Cloud を取得することができるものとする。ロボットの座標系が右手系であり、ヘッドマウントディスプレイの座標系が左手系であることも既知とする。

4.3 本実験の目的

既存手法として、Point Cloud のマッチング手法としてよく用いられている GICP-SE(3) を用いたキャリブレーションと、提案手法である Semantic-ICP キャリブレーション同士の精度の比較を行い、提案手法の妥当性を評価する。ここでのキャリブレーションの精度とは、互いの Point Cloud をマッチングさせる際に得られた最適な変換行列 $\mathbf{T}^* \in \mathbf{SE}(3)$ の精度である。

4.4 実験方法

はじめに、実験データ作成のために、HSR を用いて家庭環境の 3D Semantic Map を作成する。その後 HoloLens を用いて家庭環境内の四箇所 (テレビ前, 作業机, 本棚前, ダイニング) で Semantic point cloud の取得を行う。図 2 に四箇所の実際の環境を示す。

これら四箇所の場所で得られた 3D Semantic Map と Semantic point cloud を用いて GICP-SE(3) と Semantic-ICP を実行し、キャリブレーション精度の比較を行う。またグラントゥールースとして、HoloLens の座標系と HSR の座標系の 3 次元距離をメジャーで測定し取得する。グラントゥールースと各キャリブレーション手法の精度の比較として、Parkison らが Semantic-ICP の評価の際に使用した変換行列 ($\mathbf{T} \in \mathbf{SE}(3)$) 誤差を用いる。ここで \mathbf{T}_{GT} はグラントゥールースの変換行列を、 d は誤差を計算する関数を表す。またこれら 3 項目の定義を式 (9) に示す。

$$d_{SE(3)}(\mathbf{T}^*; \mathbf{T}_{GT}) \triangleq \|\log(\mathbf{T}^* \mathbf{T}_{GT}^{-1})\| \quad (9)$$

4.5 実験結果

HoloLens と HSR の Semantic Point Cloud を Semantic-ICP と GICP-SE(3) でそれぞれマッチングした結果を表 1 に示す。なお、表に示された数値は全て小数第三位を四捨五入したものである。また二つの手法の結果を比較し、誤差が小さい方の数値を太字で示す。作業機とダイニングでは Semantic-ICP の方が変換行列誤差が既存手法より小さく、精度の向上が認められた。本棚前とテレビ前では、GICP-SE(3) と比較し、Semantic-ICP の方が大きな誤差が得られた。

5. 考察

精度の悪かったテレビ前と本棚前の HoloLens と HSR の Semantic Point Cloud を図 3, 図 4 に示す。図 3a と図 3b を比較すると、テレビの前のテーブルで異なったラベルが貼られていることがわかる。同様に、本棚前でも、図 4a と図 4b を比較すると本棚に異なったラベルが張られている。よって、作業機とダイニングにおいてマッチングの精度が向上し、作業機と本棚前では精度の低下したことから、HSR と HoloLens で得られたセマンティックラベルが異なっている領域が大きい時に精度が下がると考えられる。

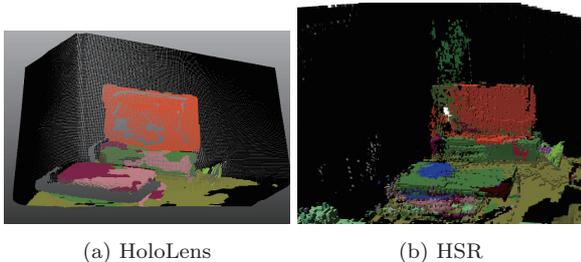


図 3: テレビ前の Semantic Point Cloud

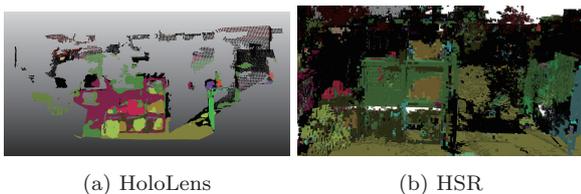


図 4: 本棚前の Semantic Point Cloud

6. おわりに

本研究では、ロボットやヘッドマウントディスプレイのキャリブレーションを、AR マーカを用いずにキャリブレーション精度を向上させる手法として Semantic-ICP を用いた。本実験

表 1: 変換行列誤差 $d_{SE(3)}$

キャリブレーション手法	テレビ前	作業機	本棚前	ダイニング
GICP-SE(3)	0.22	5.42	0.08	0.06
Semantic-ICP	8.68	0.05	0.76	0.04

では HoloLens と HSR のカメラから取得した Point Cloud に PSPNet の出力値のセマンティックラベルを付加した Semantic Point Cloud を用いてマッチングを行った。GICP-SE(3), Semantic-ICP のキャリブレーション精度の比較を行った。実験の結果、互いの Semantic Point Cloud 内の一致しているセマンティックラベルの領域が広い場合、精度が向上する傾向にあることがわかった。今後の展望としては、各ラベルの生成確率を扱う手法の改善や、セマンティックラベル以外の特徴量を用いた場合に精度の向上が見られるかの検証を行う予定である。

参考文献

- [Collett 06] T.H.J Collett and B.A MacDonald, "Augmented reality visualisation for player", In Proceedings 2006 IEEE International Conference on Robotics and Automation (ICRA), 2006, pp.3954-3959
- [Liu 18] Hangxin Liu, Yaofang Zhang, Wenwen Si, Xu Xie, Yixin Zhu, and Song-Chun Zhu, "Interactive Robot Knowledge Patching Using Augmented Reality", In Proceedings 2018 IEEE International Conference on Robotics and Automation (ICRA), 2018, pp.1947-1954
- [Besl 92] P.J. Besl and Neil D. McKay, "A method for registration of 3-D shapes", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.14, No.2, 1992, pp.239-256
- [Segal 09] Aleksandr V Segal, Dirk Haehnel, and Sebastian Thrun, "Generalized-ICP", Robotics: Science and Systems 2009, Vol.2, 2009
- [Absil 08] P.-A. Absil, R Mahony, and R Sepulchre, "Optimization Algorithms on Matrix Manifolds", Princeton University Press, Princeton, NJ, 2008
- [Parkison 18] Steven A. Parkison, Lu Gan, Maani Ghaffari Jadidi, and Ryan M. Eustice, "Semantic Iterative Closest Point through Expectation-Maximization", Proceedings of the British Machine Vision Conference, 2018, pp.1-17
- [Zhao 17] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, and Jiaya Jia, "Pyramid Scene Parsing Network", In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp.6230-6239
- [Zhang 18] Xuan Zhang, "Real-time voxel based 3d semantic mapping with a hand held rgb-d camera", <https://github.com/floatlazer/semantic slam>, Accessed:2019-01-02
- [Hornung 13] Armin Hornung, Kai M Wurm, Maren Bennewitz, Cyrill Stachniss, and Wolfram Burgard, "OctoMap: An Efficient Probabilistic 3D Mapping Framework Based on Octrees", Autonomous Robots, 2013

場所概念に基づく確率推論による音声命令からのパスプランニング

Path Planning by Spatial Concept-Based Probabilistic Inference from Human Speech Instructions

谷口 彰^{*1} 萩原 良信^{*1} 谷口 忠大^{*1} 稲邑 哲也^{*2*3}
Akira Taniguchi Yoshinobu Hagiwara Tadahiro Taniguchi Tetsunari Inamura

^{*1}立命館大学 ^{*2}国立情報学研究所 ^{*3}総合研究大学院大学
Ritsumeikan University National Institute of Informatics The Graduate University for Advanced Studies

The aim of this study is to enable a mobile robot to perform navigation tasks by probabilistic inference using spatial concepts on a probabilistic model. Specifically, path planning is performed to the target state of a spatial concept estimated through human speech instructions such as “Go to the kitchen”. In the experiment, places instructed by the speech command of the user showed high probability values, and the trajectory toward the target place was correctly estimated.

1. はじめに

人間と共存し様々な生活環境で動作するロボットは、適応的に場所に関する概念や語彙を学習するだけでなく、学習した知識をナビゲーションなどのタスクに活用することが求められる。これまで、我々は教師なし学習によりマルチモーダル情報から自律的・適応的に場所のカテゴリ知識(場所概念)を獲得する確率的生成モデル SpCoSLAM を提案している [Taniguchi 17, Taniguchi 18]。本研究では、ロボットが自らの経験に基づいて形成された概念を活用する方法について検討する。具体的には、「だいたいどこか行って」などの人の音声発話命令から、場所概念に基づき推定された目標状態へのパスプランニングを行う。

これまで、我々は Simultaneous Localization And Mapping (SLAM) [Thrun 05] と位置・音声言語・画像のマルチモーダル情報に基づくノンパラメトリックベイズ場所概念獲得モデルを統合した SpCoSLAM を提案している [Taniguchi 17]。また、地図・場所概念・語彙を同時に学習できるオンライン学習アルゴリズムの構築を行ってきた。この手法では、地図を持たない未知環境下からでも場所概念の獲得が可能であり、環境中の未探索の領域に対して追加学習が可能である。また、計算リソースに限られる実ロボットにおいて長期学習を可能とするため、データ数の増加に伴う計算コストの増加、バッチ学習と比較した場合のオンライン学習による推定精度の低下に対処した高精度かつ軽量のオンラインアルゴリズムの開発を行った [Taniguchi 18]。SpCoSLAM では、環境や語彙に関する事前知識なしに地図と場所概念および語彙を獲得することが可能である。しかし、獲得した場所概念の行動決定や意思決定への活用に関する理論的な方法についてはこれまで議論されていなかった。そこで本研究では、SpCoSLAM の確率的生成モデルの上でのロボットの行動決定問題に着目する。

本研究では、場所概念を活用したロボットと人の言語的インタラクションに基づくパスプランニングやナビゲーションを可能とすることを旨とする。本稿では、SpCoSLAM の確率的生成モデル上で行動決定に関する確率推論の手法を構築し、実際に獲得された場所概念を用いたナビゲーションタスク実験を行い、提案手法の有効性を検証する。

一般的に、ロボットにおける行動決定には強化学習が用い

られることが多い。強化学習では、マルコフ決定過程 (MDP: Markov Decision Process) に基づき試行錯誤的に行動の最適化を行う。一般的な強化学習の枠組みでは、累積報酬の最大化問題を解くが、この枠組みには確率的生成モデルとの理論的な隔たりがあった。しかし近年、強化学習を始めとする行動決定問題を確率的生成モデル上の確率推論として捉える枠組みが注目されている [Toussaint 09, Levine 18]。本研究では、行動決定問題を確率的生成モデル上の確率推論として定式化することによって、教師なし学習における推論と同じ枠組みでパスプランニングやナビゲーションを実現することができると考える。

2. 提案手法 : SpCoNavi

本章では、SpCoSLAM と同一な生成過程のグラフィカルモデル上での確率推論による、人の音声発話命令からの場所概念に基づくナビゲーション手法 SpCoNavi について説明する。

2.1 概要

本研究の問題設定は、部分観測マルコフ決定過程 (POMDP: Partially Observable Markov Decision Process) とみなせる。確率推論を行うにあたって、音声認識や自己位置推定など様々な不確実性への対処は重要である。SpCoSLAM はベイズフィルタベースの SLAM にマルチモーダルカテゴリゼーションを統合したモデルであるため、本研究の問題設定は多くの不確実性を伴ったより複雑な POMDP であると言える。本研究では、ロボットに確定的な目標地点を明示的に与えるのではなく、ロボットが人の音声命令から自らの内部知識を用いて行動目標を決定することを行う。また、全体が統合されたモデルに基づく推論であるため、確率変数の不確実性を考慮したマルチモーダル情報の相互補完的な推論が可能になる。これにより、モデル上で全体最適なパスプランニングを行うことが可能になると考える。

2.2 定式化と導出

本研究では、環境の地図、場所概念、語彙が既に獲得されているものとする。ある環境上で事前に SpCoSLAM を動作させ、最終時刻での学習結果における各モデルパラメータを固定とする。SpCoSLAM に基づいたナビゲーションのためのパスプランニングを行う際のグラフィカルモデルを Fig. 1 に示す。灰色のノードは観測済み変数および学習済みパラメータを表し、白色のノードは未観測変数を表す。このとき、地図 m ,

連絡先: 谷口 彰, 立命館大学 情報理工学部,
a.taniguchi@em.ci.ritsumei.ac.jp

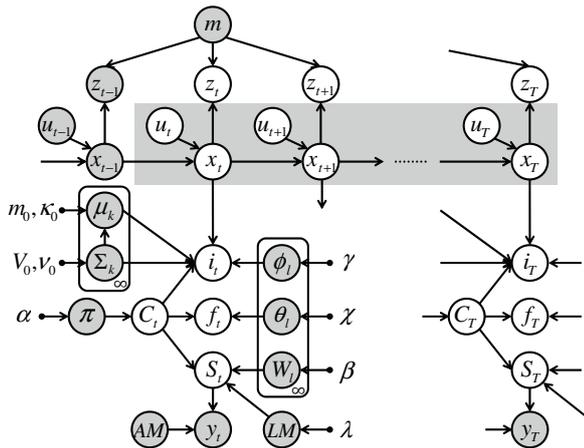


図 1: SpCoNavi のグラフィカルモデル

場所概念を表すモデルパラメータ集合 $\{\mathbf{W}, \boldsymbol{\mu}, \boldsymbol{\Sigma}, \theta, \phi, \pi\}$ および、言語モデル LM といった学習済みグローバルパラメータ集合を $\Theta_G = \{m, \mathbf{W}, \boldsymbol{\mu}, \boldsymbol{\Sigma}, \theta, \phi, \pi, LM\}$ とする。各変数の詳細については [Taniguchi 17] を参照されたい。灰色の長方形で示した箇所が提案手法で推定対象とする変数の範囲である。下添え字の T はパスプランニングの最終時刻であり、パスプランニング開始時刻を $t = 1$ としたとき、計画区間 (Planning Horizon) を表す。以降では開始時刻 $t = 1$ として数式の表記を行う。

提案手法では、人からの音声発話命令 y_t が与えられたときの動作 u_t と位置 x_t の軌道 (Trajectory) $\tau = \{u_{1:T}, x_{1:T}\}$ を表す確率分布が最大となる動作系列 $u_{1:T}$ (および、地図上のパス $x_{1:T}$) の推定を行う。目的関数となる確率分布が最大値となるときの動作系列を求める式 (1) に示す。

$$u_{1:T} = \underset{u_{1:T}}{\operatorname{argmax}} p(\tau | y_{1:T}, x_0, \Theta_G) \quad (1)$$

このとき、前時刻 $t - 1$ における自己位置 x_{t-1} は与えられるものと仮定する。実際には、事前に設定した初期位置や Monte-Carlo Localization (MCL) [Dellaert 99] のような自己位置推定により得られる推定値を利用することができる。また、音声発話命令 y_t はゴールシグナルを表す観測変数であるのみならず、現在時刻 t から時刻 T まで同様の観測が得られ続けるという仮定をおく。この仮定は、[Levine 18] における最適か否かを表すバイナリ確率変数 \mathcal{O}_t に対応する。[Levine 18] では、事後分布 $p(\tau | o_{1:T})$ における最大事後確率の推論がプランニング問題に対応することが述べられている。ここで、 $o_{1:T} = \{\mathcal{O}_t = 1\}_{t=1}^T$ である。つまり、式 (1) のように、観測 $y_{1:T}$ を条件とする事後確率分布を最大化することで、指示された場所概念によって示される位置へ移動するための最適な軌道が推定可能となる。

式 (1) を計算するためには、潜在変数 $z_{1:T}, i_{1:T}, C_{1:T}, S_{1:T}$ に関して周辺化する必要がある。このとき、 $f_{1:T}$ も未観測な変数であるが、グラフィカルモデルの依存関係より消去されるため、計算上考慮する必要はない。 $y_{1:T}$ は実際にはすべて同じ観測情報であるため、音声認識結果 $S_{1:T}$ もすべて同じとみなせる。さらに、音声認識を表す確率分布 $p(S_T | y_T, AM, LM)$ の確率値を直接求めることは困難であるため、近似として N -best 音声認識結果 $S_T^N = \{S_T^{(n)}\}_{n=1}^N$ を用いる。また、 $p(u_t)$ は一様分布を仮定する。加えて、 z_t に関する周辺化による足し合

わせについては $p(z_t | x_t, m)$ の項しか影響を受けないため、 $\sum_{z_t} p(z_t | x_t, m) = 1$ とできる。

また、地図の形状を考慮し障害物に近づかないような移動を行わせるために、式 (2) のようにマップベース動作モデル (Map-Based Motion Model) を利用する。これにより、障害物に近づくほど確率値が小さくなり、障害物のあるセルでは確率 0 になるように確率化したコストマップ^{*1} $p(x_t | m)$ を考慮した動作モデルを考えることができる。

$$p(x_t | u_t, x_{t-1}, m) \propto p(x_t | m) p(x_t | u_t, x_{t-1}) \quad (2)$$

以上より、軌道の事後確率分布は式 (3) のようになる。

$$\begin{aligned} p(\tau | y_{1:T}, x_0, \Theta_G) & \approx \prod_{t=1}^T p(x_t | u_t, x_{t-1}) \prod_{t=1}^T \left[p(x_t | m) \right. \\ & \left. \sum_{C_t} \left[\operatorname{Mult}(S_T^N | W_{C_t}) \operatorname{Mult}(C_t | \pi) \right. \right. \\ & \left. \left. \sum_{i_t} \mathcal{N}(x_t | \mu_{i_t}, \Sigma_{i_t}) \operatorname{Mult}(i_t | \phi_{C_t}) \right] \right] \quad (3) \end{aligned}$$

このとき、状態 x_t は実際には連続値であるが、占有格子地図 m の各セルごとに離散化して表現する。動作 u_t は 1 時刻につき地図上の自己位置から周囲 1 セルを移動するものとする。地図の各セルごとに確率値を計算し、動的計画法に基づく Viterbi アルゴリズムによって軌道の推定を行う。

3. 実験

本実験では、場所概念を獲得したロボットが提案手法によりパスプランニングを行うことが可能であることを示す。

3.1 実験条件

環境内にいるロボットに対し、ユーザは“** について”と発話する。** には各場所の名前が入る。実験環境は [Taniguchi 17, Taniguchi 18] で使用したもの^{*2} と同様である。また、[Taniguchi 18] において学習された Step 50 における最大尤度のパーティクルの地図、場所概念、言語モデルを用いる。音声認識には Julius dictation-kit-v4.4 (DNN-HMM decoding) を使用した。グローバルコストマップは Robot Operating System (ROS) の navigation, costmap_2d パッケージを用いて取得した。計画区間は $T = 100$, N -best 音声認識は $N = 10$ とした。ロボットの初期位置は、地図の中央に設定した。本実験においては、動作モデルは確率モデルではなく、確定的なモデルを仮定する。

3.2 実験結果

提案手法によるパスプランニングの結果の例を示す。図 2, 図 3, 図 4 に地図および、発話されたときの地図上の各セルにおける出力確率の値をカラーマップで示し、その上に推定された軌道を赤色で示す。図 2 において発話された場所は“きょうゆうせき” (右上の広い部屋), 図 3 において発話された場所は“きょうけいじょ” (上側右端の狭い部屋と上側左端の部屋), 図 4 において発話された場所は“きょういんけんきゅうしつ” (下側の右の部屋) であった。

*1 Configuration Space (C-Space) の確率的な表現と見なせる。

*2 Robotics Data Set Repository (Radish) [Howard 03] のオープンデータセット

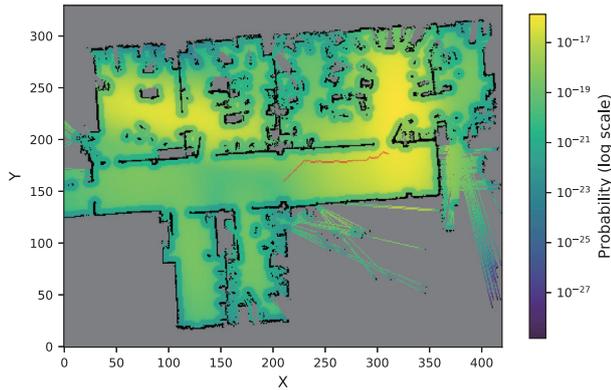


図 2: “きょうゆうせき” における出力確率と推定された軌道

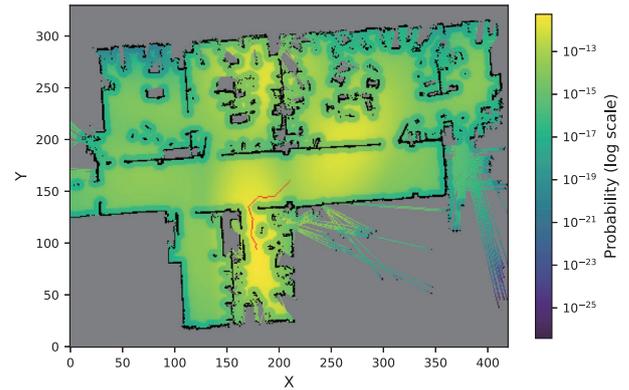


図 4: “きょういんけんきゅうしつ” における出力確率と推定された軌道

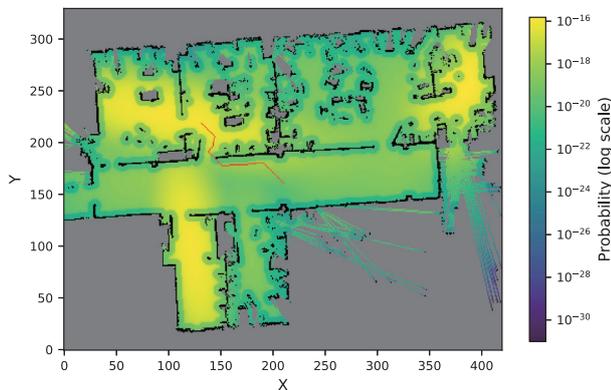


図 3: “きゅうけいじょ” における出力確率と推定された軌道

結果として、ユーザの音声命令によって指示された場所の確率値が高くなっており、指示された場所へ向かう軌道が推定されていることがわかる。地図上の確率値において、対象の場所以外の場所で確率値が高くなっている場合も見られたが、これは獲得された語彙の単語辞書に基づく音声認識結果および、場所概念の学習における誤りが原因であると考えられる。

4. おわりに

本稿では、ロボットが自律的に獲得した場所概念を用いた音声命令からのパスプランニング手法 SpCoNavi を提案した。提案手法は、従来の多くのパスプランニング手法と異なり、ゴールとして地図上の座標点を指定する必要がなく、人との音声によるインタラクションから目的地までのナビゲーションが可能となる。実験では、提案手法が音声命令により指示された場所への軌道を推定できることを示した。しかし、占有格子地図上の移動可能なセルを状態として定義したため、地図の大きさに応じて状態数が多くなり、計算量が増加する問題が見られた。

今後の課題として、A* アルゴリズムなどの従来のパスプランニング手法との定量的な比較評価や、リアルタイムなナビゲーションのための計算量の削減法の検討が挙げられる。

謝辞

本研究の一部は、JST AIP-PRISM JPMJCR18ZC, JST CREST JPMJCR15E3, JSPS 科研費 JP17J07842,

JP16H06561, JP16K12497 の助成を受けたものである。

参考文献

- [Dellaert 99] Dellaert, F., Fox, D., Burgard, W., and Thrun, S.: Monte carlo localization for mobile robots, in *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, Vol. 2, pp. 1322–1328IEEE (1999)
- [Howard 03] Howard, A. and Roy, N.: The Robotics Data Set Repository (Radish) (2003)
- [Levine 18] Levine, S.: Reinforcement Learning and Control as Probabilistic Inference: Tutorial and Review, *arXiv preprint arXiv:1805.00909* (2018)
- [Taniguchi 17] Taniguchi, A., Hagiwara, Y., Taniguchi, T., and Inamura, T.: Online Spatial Concept and Lexical Acquisition with Simultaneous Localization and Mapping, in *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 811–818 (2017)
- [Taniguchi 18] Taniguchi, A., Hagiwara, Y., Taniguchi, T., and Inamura, T.: Improved and Scalable Online Learning of Spatial Concepts and Language Models with Mapping, *arXiv preprint arXiv:1803.03481* (2018)
- [Thrun 05] Thrun, S., Burgard, W., and Fox, D.: *Probabilistic Robotics*, MIT Press (2005)
- [Toussaint 09] Toussaint, M.: Robot trajectory optimization using approximate inference, in *Proceedings of the 26th annual international conference on machine learning (ICML)*, pp. 1049–1056ACM (2009)

飛行ロボットに搭載した360度カメラによる自己位置認識

Self-location recognition by a 360-degree camera mounted on a flying-robot

大谷 元気*¹ 本田 泰*²
Genki Ohtani Yasushi Honda

*¹室蘭工業大学 工学研究科博士前期課程 情報電子工学系専攻
Muroran Institute of Technology Faculty of Engineering Division of Information and Electronic Engineering

*²室蘭工業大学 しくみ情報系領域
College of Information and Systems, Muroran Institute of Technology

In this research, we try to derive the three-dimensional coordinates and orientation of a flying robot equipped with a 360-degree camera. There are various means such as GPS, direction sensor, etc. as means for knowing the coordinates and orientation. However, it is impossible to know exact orientation and coordinates in places where indoors or magnetic fields are unstable. In this research, we aimed to acquire the direction and coordinates of the flying robot using a 360 degree camera. As a concrete method, we installed two color objects at the place we wanted to be a reference, aimed at achieving the purpose by acquiring the relative coordinates of the color object and the flying robot. Currently the average of the errors of x, y and z coordinates is less than 400 mm, but the average of the error of the direction is about 30 degrees, and in the place where the largest error is most, it is close to 120 degrees.

1. はじめに

近年、ドローンと呼ばれる無人航空機は人々の生活に馴染み深いものとなっている。写真や動画撮影に用いられるだけではなく、農薬の散布や宅配など様々な分野での活躍が期待されている。

一方で、その安全性が懸念されている。地上で動作するロボットとは違い、空中で動作するため落下による事故の危険性も高い。そして、操縦の難しさによるヒューマンエラーも少なくない。そのため、ドローンは環境の変化に適応する自律行動を取ることが求められている。

本研究で扱う飛行ロボットは4回転翼自律飛行ロボット [1](図1)である。この飛行ロボットは、知的行動の一つである反応行動 [2] によって飛行する。人間による操作は行わず自律的に飛行することから、ドローンと区別するために飛行ロボットと呼ぶ。

飛行ロボットは自律飛行するため、自分の位置や向きを把握する必要がある。ロボットの座標や向きを知る手段は様々な存在する。GPS(Global-Positioning-System:全地球測位システム)や方位センサーなどの小型で安価なものが多数市販されている。

また、複数のドローン間で直接通信を行い、衝突などの危険を回避し安全性を高める研究も行われている [3]。これらの研究に置いて、GPSなどの外部からドローンの位置情報を得ることを前提としている。

しかし、GPSを受信できないような場所や磁場の安定しないような場所では座標や向きを知ることはできない場合も存在する。そこで我々は、飛行ロボット自身に搭載したカメラによる画像情報を使い、座標と向きを取得できないかと考えた。

本研究の目的は、飛行ロボットに搭載したカメラによる色認識でカラーオブジェクトと飛行ロボットの3次元座標と相対的

な向きを取得することである。基準としたい点の床に2つのカラーオブジェクトを配置することで、飛行ロボットの座標と向きの認識を目指した。目的達成の手法として、順伝播型ニューラルネットワークの教師付き学習を用いた。

モーションキャプチャの位置情報データと比較することにより、飛行ロボット自身に搭載したカメラ情報から、自身の3次元座標と向きを認識することが可能となった。また、飛行ロボットに搭載可能なボードコンピュータを用いて、飛行に応用可能な速度でそれらを認識可能であることを示した。



図1: 実験に使用した飛行ロボット

2. 4回転翼自律飛行ロボット

本実験で使用するロボットは4回転翼自律飛行ロボット [2] である。この飛行ロボットにはボードコンピュータ RaspberryPi を2台搭載しており、1台が機体の制御、もう1台がカメラの制御を行っている。

2.1 飛行ロボットに搭載しているカメラ

本研究で使用したカメラは「Pixy CMUcam5(以下、Pixyと呼ぶ)」である。Pixyはカラーオブジェクトの2次元座標

連絡先: 大谷元気, 室蘭工業大学工学研究科博士前期課程情報電子工学系専攻, 18043011@mmm.muroran-it.ac.jp, bfb46mm@gmail.com

を Pixy 内部のプロセッサで取得することができる。Pixy は飛行ロボットの下部に下向きに搭載しており、地面に設置したカラーオブジェクトを捉えることができるようになっている。さらに、Pixy に魚眼レンズを取り付けることで画角を 75 度から 360 度に広げている。

Pixy は図 2 のように捉えたカラーオブジェクトを四角形の枠で囲い、その枠の左上角の座標と枠の幅と高さを取得する。その座標データを保存し、学習用のデータとして使用している。Pixy が取得できるデータは 1 秒間に最大 50 データとなっている。

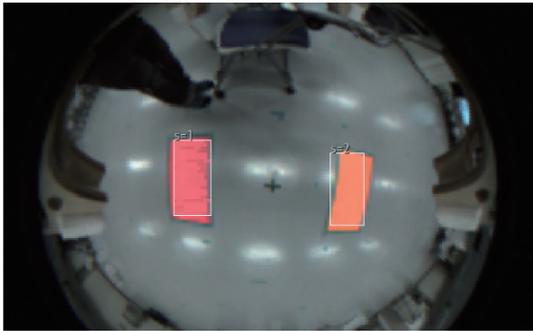


図 2: Pixy によるカラーオブジェクトの識別の様子

3. ニューラルネットワーク

本研究では順伝播型のニューラルネットワークを使用する。カメラから得られるカラーオブジェクトの 2 次元座標を入力とし、飛行ロボットの 3 次元座標と向きを出力するように学習を行う。教師データとしてモーションキャプチャで取得した飛行ロボットの 3 次元座標と向きを用いる。本研究では、python2.7.13, chainer5.1.0 を使用した。

3.1 ニューラルネットワークの入力データ

本研究では、入力データとして 2 つのカラーオブジェクトのデータを使用する。カラーオブジェクトとして、ピンク色とオレンジ色のフェルトの 2 枚を用いる。2 枚のカラーオブジェクトを使用することで、飛行ロボットの向きを表現できると考えた。そして図 3 のようにピンク色のフェルトの左上角の x 座標、y 座標、幅、高さ、そしてオレンジ色のフェルトの左上角の x 座標、y 座標、幅、高さの 8 つのデータを入力データとした。

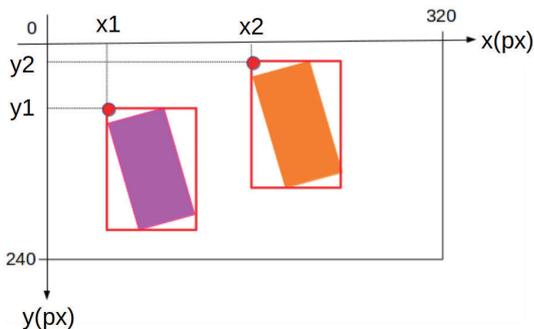


図 3: Pixy が取得する 2 次元座標

3.2 ニューラルネットワークの教師データ

学習における教師データとして、モーションキャプチャで取得した実際の飛行ロボットの 3 次元座標と向きの 4 つのデータを使用する。飛行ロボットには 5 つのマーカがついており、モーションキャプチャではそれぞれのマーカの 3 次元座標を取得することができる。この 5 つのマーカの平均を取り、その値を飛行ロボットの 3 次元座標としている。

飛行ロボットの向きは 2 つのマーカを基準として計算している。2 つのマーカの高さを除く 2 次元座標をそれぞれ (x_1, y_1) , (x_2, y_2) と置くと、

$$\text{angle} = \tan^{-1}\left(\frac{y_1 - y_2}{x_1 - x_2}\right) * \frac{180}{\pi} \quad (1)$$

となる。向きの変化を視覚的にわかりやすくするために度数法を用いた。そのため、向きの範囲は $-180 < \text{angle} < 180$ となる。

3.3 ニューラルネットワークの構成

本研究では順伝播型のニューラルネットワークを使用した。入力層は 8 ユニット、中間層は 1 層で 100 ユニット、出力層は 4 ユニットとする (図 4)。

中間層の活性化関数 σ_1 は \tanh とする。

$$\sigma_1(x) = \tanh(x) \quad (2)$$

出力層の活性化関数 σ_2 は恒等写像を用いる。

$$\sigma_2(x) = x \quad (3)$$

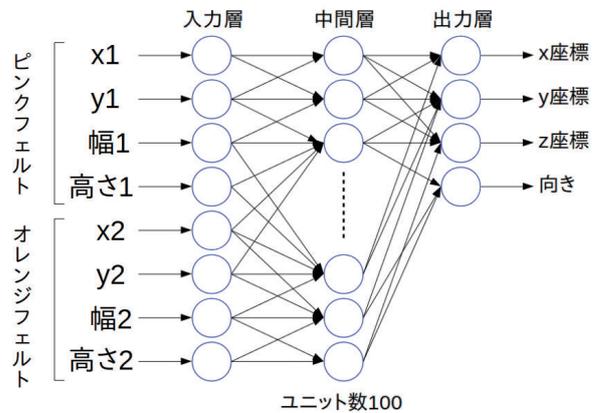


図 4: 本研究におけるニューラルネットワークの構成

4. 飛行実験

4.1 実験手法

モーションキャプチャにより原点とする位置を決める。そして地面に二枚のカラーフェルトを原点から x 軸方向に +400mm, -400mm の位置 (図 5) に貼り付ける。モーションキャプチャのレートとカメラの fps(frames-per-second) を 50 に指定し飛行ロボットを飛行させる。飛行中の飛行ロボットの 3 次元座標をモーションキャプチャで取得し、同時にカメラによりカラーフェルトの 2 次元座標を取得する。その後、飛行ロボットの 3 次元座標とカラーフェルトの 2 次元座標のデータを同期させ訓練データ及びテストデータを作成する。

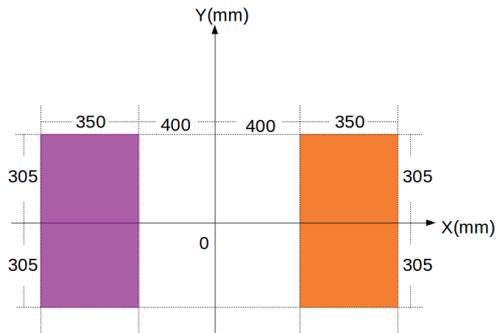


図 5: カラーオブジェクトの位置関係図

4.2 実験結果

モーションキャプチャの範囲に制限があるため、モーションキャプチャのデータ取得の範囲外に出ることがしばしば見られた。そして、同様にカメラの画角にも制限があるため、カラーオブジェクトがカメラの範囲外に出ることも起きた。このように取得できなかったデータを除き、訓練データ及びテストデータを作成した。約 100 回の飛行により、25000 ほどのデータを取得した。実際の飛行の様子を図 6 に示す。



図 6: 飛行ロボットが実際に飛行している様子

5. ニューラルネットワークによる学習

5.1 学習条件

飛行実験で入手したデータのうち約 18000 データを訓練データ、約 6000 データをテストデータとして学習を行った。過学習を防ぐため、テストデータの平均自乗誤差が最小になるところで学習をとめる。学習を行う際、すべてのデータが+1 から-1 の範囲に収まるように正規化する。

5.2 学習結果

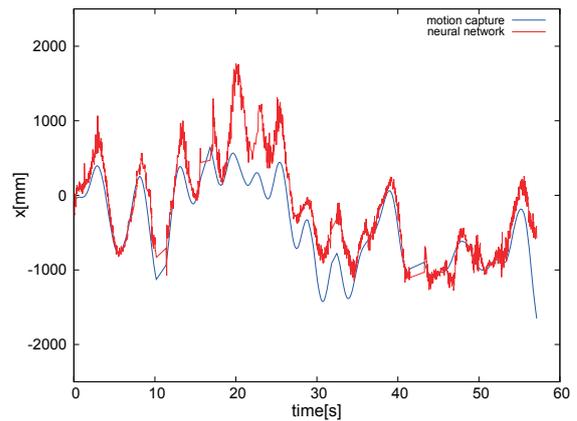
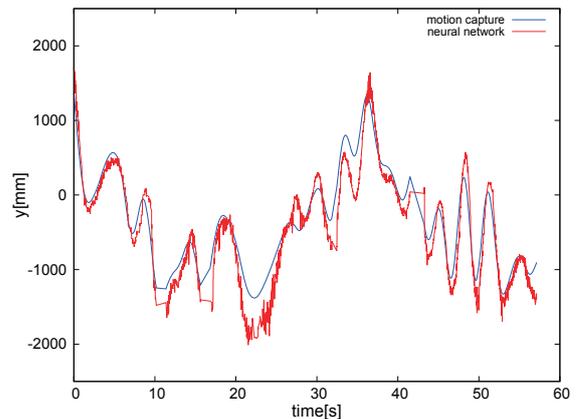
学習結果の確認として、学習に使用していない未知のデータを用意しモーションキャプチャによる飛行ロボットの 3 次元座標とニューラルネットワークを使用した飛行ロボットの 3 次元座標を比較した。そして平方平均自乗誤差 (RMSE) を計算した。ニューラルネットワークを利用して得られた x , y , z , 向き のデータを O , その教師データとなる x , y , z , 向き のデータを T , 訓練データの総数を n とすると、

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (O_k - T_k)^2} \quad (4)$$

となる。

5.3 ニューラルネットワークとモーションキャプチャの比較

テストデータを入力とした時に得られた x , y , z 座標と向きとその時の実際の飛行ロボットの x , y , z 座標と向きを比較した図を図 7, 8, 9, 10 に示す。このテストデータでの RMSE は x 座標は 356.43mm, y 座標は 245.40mm, z 座標は 129.39mm, 向きは 31.03° となった。

図 7: モーションキャプチャで取得した飛行ロボットの x 座標 (青) とニューラルネットワークを使用して得られた x 座標 (赤) の比較図 8: モーションキャプチャで取得した飛行ロボットの y 座標 (青) とニューラルネットワークを使用して得られた y 座標 (赤) の比較

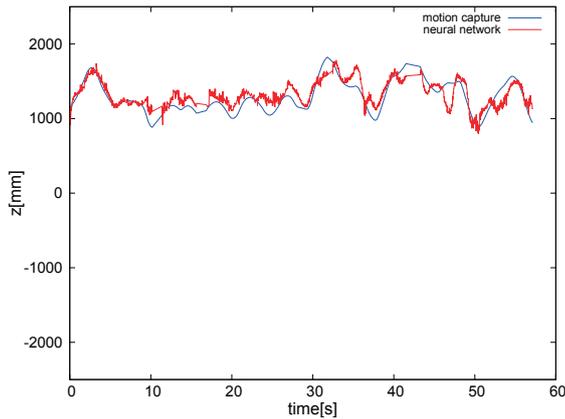


図 9: モーションキャプチャで取得した飛行ロボットの z 座標 (青) とニューラルネットワークを使用して得られた z 座標 (赤) の比較

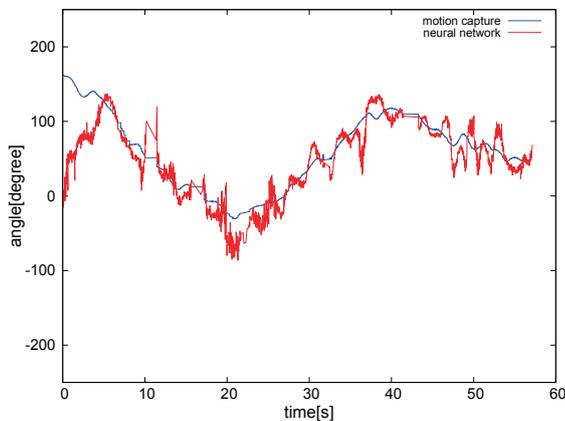


図 10: モーションキャプチャで取得した飛行ロボットの向き (青) とニューラルネットワークを使用して得られた向き (赤) の比較

5.4 考察

飛行ロボットの x, y, z 座標はモーションキャプチャに近い値を出す結果となった。中でも x 座標は誤差が大きく出ているが、これはカラーオブジェクトの形と配置が原因であると考えられる。本実験では長方形のカラーオブジェクトを2枚配置していたが、カラーオブジェクトを丸のように角度による見え方の変化が小さいものに変更したり、カラーオブジェクト間のスペースを変更することで誤差を減らすことができるのではないかと考えている。また、学習データを増やすことで全体の誤差も減らすことができると考えている。

向きの出力に関しては、大きいところで 180 度近い誤差がうまれた。本実験では、向きを -180° から $+180^\circ$ の範囲で出力するように学習を行っている。そのため、 -180° と $+180^\circ$ の付近ではニューラルネットワークの入力は近い値になるが、出力は大きく変わる事となる。これが大きな原因の一つであると考えられる。この問題は角度の出力方法を変更することで改善されると考えている。

6. RaspberryPi によるニューラルネットワークの計算

学習は外部 PC により行っているが、実際に飛行ロボットに搭載する際は RaspberryPi で処理を行う。RaspberryPi は cpu の処理能力が高くないため、実際にどのくらいの速度でニューラルネットワークの計算を行えるのか検証する必要がある。そこで RaspberryPi を使いニューラルネットワークの計算を行い、どのくらいのフレームレートが出るのかの実験を行った。Pixy のフレームレートが最大 50fps のため 50fps を 1 つの基準とする。

ニューラルネットワークに同じ値を 5000 回入力し、その時の計算時間を測定する。そして、5000 を秒数で割ることで平均の fps を算出した。

その結果、RaspberryPi でのニューラルネットワークの計算のフレームレートは約 180fps となった。

7. まとめ

ニューラルネットワークによる飛行ロボットの 3 次元座標と向きは、多少の誤差があるものの概ね出力することができた。また、RaspberryPi によるニューラルネットワークの計算時間の検証により、ニューラルネットワークの計算量を増加させられることも示された。中間層やユニット数を増やすことで誤差の減少につながると考えている。

8. 今後の課題

カラーオブジェクトの形や配置場所を見直し誤差の減少を目指す。また、角度の表し方を見直し、 -180° 、 $+180^\circ$ 付近の誤差の減少も目指す。さらに、ニューラルネットワークの中間層やそのユニット数を増やすことで、誤差がどのように変化するかの実験も必要となる。そして、今現在は飛行ロボットで取得したデータを外部 PC で計算しているため、実際に飛行ロボットに搭載して飛行実験も行っていきたい。

参考文献

- [1] 第 19 回交通流のシュミレーションシンポジウム論文集, p53-56, 2014 本田 泰
- [2] ロボットインテリジェンス, 浅田 稔, 國吉 康夫
- [3] ドローン同士の直接通信でニアミスを自動的に回避する実験に成功, <https://www.nict.go.jp/press/2019/01/24-1.html> (参照日:2019/02/07)
- [4] 第 22 回交通流のシュミレーションシンポジウム論文集, p17-20, 2016 本田 泰

物体インスタンスの重なりを考慮した 双腕ロボットによる自律学習型ターゲットピッキングシステム

Self-supervised learning base target picking system for dual-arm robot considering object instance occlusion

北川 晋吾 岡田 慧 稲葉 雅幸
Shingo Kitagawa Kei Okada Masayuki Inaba

東京大学大学院 情報理工学系研究科
the University of Tokyo, Graduate School of Information Science and Technology

Recently, robots are introduced to warehouses and factories for automation and are expected to execute dual arm manipulation as human does. We focus on target picking task in the cluttered environment and aim to realize a robot picking system which the robot selects and executes proper grasping motion from single-arm and dual-arm motion. In this paper, we propose a self-supervised learning based target picking system with selective dual-arm grasping. In our system, a robot first learns how to grasp and how to distinguish items with synthesized dataset. The robot then executes and collects grasp trial experiences in the real world and retrains grasping model with the collected trial experiences. Finally, We also propose the learning based target picking system with selective dual-arm grasping and evaluate picking task experiments in the cluttered environment such as warehouse.

1. はじめに

近年、様々な分野でロボットの社会導入が推められている。特に中小工場や倉庫などの複雑環境でマニピュレーション作業を行うロボットシステムは、Amazon Robotics Challenge [Correll 16] など盛んに研究が行われており、特に学習手法を用いたシステムが高い作業成功率を示している [Pinto 16]。これらの研究では多様な物体が重なりあう複雑環境に対応するために、大量のデータセットを用いて環境認識モデルを学習する手法が採られているが、学習手法において動作の多様化に対するデータセット生成のコスト増加が問題となる。また既存の学習手法では単腕把持動作のみがピッキングタスクに導入されているのが現状である。本研究では上記の問題を解決しながら、複雑環境での学習型ロボットピッキングシステムに双腕マニピュレーション動作を導入することを目的とする。

2. 複雑環境におけるピッキングタスク

複雑環境におけるピッキングタスクは図 1 に示すランダムピッキングとターゲットピッキングに分類される。

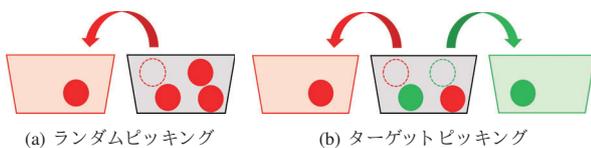


図 1: ランダムピッキングとターゲットピッキング

ランダムピッキングとは、図 1(a) に示すように環境に置かれた物品(図 1(a) 内の赤丸)を全て収納するタスクであり、これまで物品の意味ラベルに関係なく把持動作を行う研究が多く行われてきた [Pinto 16]。一方、ターゲットピッキングとは、図 1(b) に示すように環境内のターゲット物品(図 1(b) 内の赤丸)のみを収納するタスクであり、近年ランダムピッキングの学習手法の発展として研究が行われている [Wada 18]。このタ

スクはターゲット物品をいかに効率的に収納するかが課題となり、ターゲット物品を移動する妨げになる障害物物品(図 1(b) 内の緑丸)を他の場所に移動することができ、複雑環境で物品同士が重なりあった環境の中からターゲット物品を効率的に把持・収納する動作計画が必要になる。和田ら [Wada 18] は、複雑環境での物体の重なりあい(遮蔽領域)を認識しターゲット物品に重なっている物品(障害物物品)を移動することで、ターゲット物品を効率的に把持する動作計画を行う学習的認識手法を提案してされている。ランダムピッキングは、環境内の物品全てがターゲット物品というターゲットピッキングの一種であるため、本研究では拡張性の高いターゲットピッキングを対象タスクとして研究を行う。

3. 本研究の目的

本研究の目的は、複雑環境でのターゲットピッキングシステムに双腕マニピュレーション動作を導入することである。しかし、新たなマニピュレーション動作をピッキングシステムに導入する場合に主に2つの問題が存在する。1つ目の問題は、学習型ピッキングシステムに新たなマニピュレーション動作を新たに導入する場合、その動作の学習のためにより多くのデータセットが必要となる点である。またロボットのマニピュレーション動作に関しては、ロボット自身の実世界での動作試行なしで動作の評価は行えないため、ロボット実機による自律学習(Self-supervised learning)が必要となる。

2つ目の問題は、多様なマニピュレーション動作の中から状況に適した動作を評価・選択する必要がある点である。これは本研究で取り扱う単腕・双腕マニピュレーション動作それぞれの長所・短所を評価して、どちらが状況に適しているかをロボット自身が選択する必要がある。

したがって本研究では上記の2つの問題点を解決した自律学習型双腕ターゲットピッキングシステムを実現することが目的となる。本研究で提案する双腕ターゲットピッキングシステムのシステム構成図は図 2 に示し、この提案システムを、自動データセット生成と把持点予測モデルの学習、把持点予測モデルの実世界把持経験への適応、選択的雙腕把持を行うターゲットピッキングシステムの3つに分けて説明する。

連絡先: 北川 晋吾, 東京大学大学院情報理工学系研究科, 113-8656, 東京都文京区本郷 7-3-1, s-kitagawa@jsk.imi.i.u-tokyo.ac.jp

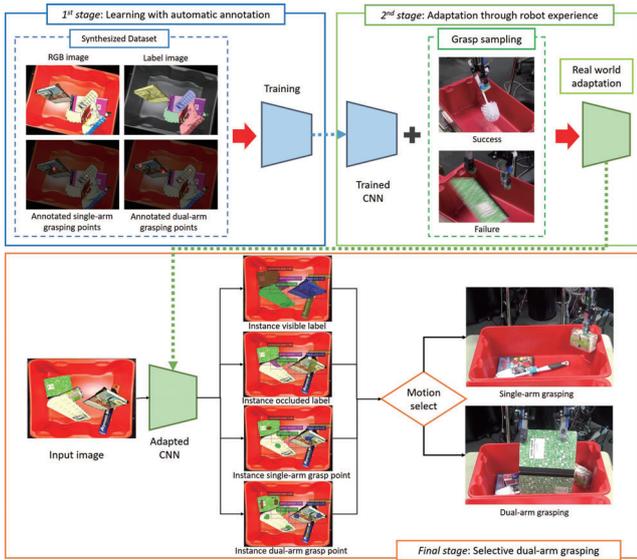
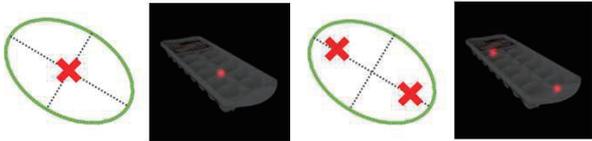


図 2: 提案する自律学習型双腕ターゲットピッキングシステム

4. 自動データセット生成と把持点予測モデルの学習

4.1 把持点予測データセットの自動生成

自動データセット生成のために本研究では物体形状に基づく把持点アノテーションアルゴリズムを設計する。本研究で提案する把持点アノテーションアルゴリズムでは、それぞれの対象物品に対して6枚以下のRGB画像を用いて、単腕・双腕把持における把持点を物体の幾何形状から図3に示すように計算する [Kitagawa 18]。



(a) 単腕把持点の自動アノテーション (b) 双腕把持点の自動アノテーション

図 3: 単腕・双腕把持のための自動把持点アノテーション

把持点データセットの自動生成は複数の対象物品インスタンスのRGB画像を変形させながら1枚の背景画像に貼り合わせることで、複数物品が重なりあい遮蔽しあう複雑環境のRGB画像を自動生成する。また画像貼りあわせによって他物品によって覆いかぶさられた領域を物体インスタンスの遮蔽領域 occ としてアノテーションする。同様にして単腕・双腕把持の把持点についてもアノテーションを行うが、他物品に対象物品領域の10%以上が覆いかぶさっている場合は物理的に対象物品が遮蔽されており把持不可能であるとみなす。

4.2 Mask-RCNNを元にした物体インスタンス可視・遮蔽領域分割を同時に行う把持点予測モデルの学習

本研究では以下に説明する把持点予測モデルと自動生成したデータセットを用いた学習手法を提案する。

この把持点予測モデルの全体構成はMask-RCNN [He 17]をベースに構成されており、RGB画像を入力として特徴量抽出器を介して得た特徴量を用いて、予測した複数の興味領域 r に対して物体領域矩形 b 、意味ラベル c_{class} 、ピクセル単位のイ

ンスタンス意味ラベル c_{inst} 、把持可能ラベル c_{grasp} の予測を行う。インスタンス意味ラベル c_{inst} とは、物体領域矩形 b 内のあるピクセルが、物体インスタンスに属しているか vis 、他物体との重なりで見えなくなっているか occ 、もしくは背景であるか bg 、を示すものである。

把持可能領域分割に関する損失 L_{single}, L_{dual} は把持戦略 s_{grasp} と興味領域 r に対して、 r 内のピクセル (x, y) における c_{grasp} に関する予測出力 $h_{s_{grasp}}(r, x, y)$ が正解データ $l_{s_{grasp}}(r, x, y)$ を予測するように学習する。 s_{grasp} と c_{grasp} についての r に関する重み $w_{s_{grasp}}(r)$ を式(1)のように計算する。式(1)において、 $N_{foreground}(r)$ は正解ラベル画像における r 内の背景ラベルではないピクセル数、 $N_{c_{grasp}}(r)$ は正解ラベル画像における r 内の把持ラベル c_{grasp} であるピクセル数、 $\alpha_{c_{grasp}}$ は c_{grasp} についての定数である。

$$w_{s_{grasp}}^{c_{grasp}}(r) = \begin{cases} \frac{N_{foreground}(r)}{\alpha_{c_{grasp}} N_{c_{grasp}}(r)} & (N_{c_{grasp}}(r) \neq 0) \\ 0 & (N_{c_{grasp}}(r) = 0) \end{cases} \quad (1)$$

本研究では把持ラベルの定数としては自動データセットに対する学習では $\alpha_{graspable}$ は1.0、 $\alpha_{ungraspable}$ は1.0に設定する。そして s_{grasp} と r における把持可能ラベルに関する損失 $L_{s_{grasp}}(r)$ は、式(1)を重みとした重み付きソフトマックス交差誤差 $WSCE$ で計算する。よって s_{grasp} における把持可能領域分割に関する損失 $L_{s_{grasp}}$ は前景フィルタ FG と $L_{s_{grasp}}(r)$ を用いて式(2)に示すように計算する。

$$L_{s_{grasp}} = \frac{\sum_{r \in R} FG(l_{class}(r)) L_{s_{grasp}}(r)}{\sum_{r \in R} FG(l_{class}(r))} \quad (2)$$

把持点予測モデルの全体損失 L_{total} は興味領域予測の損失 L_{rpn} 、物体インスタンス検出の損失 L_{det} 、物体インスタンス可視・遮蔽領域分割の損失 L_{inst} 、把持可能領域分割の損失 L_{single}, L_{dual} の和として計算する。

5. 把持点予測モデルの実世界把持経験への適応

5.1 ロボット実機による実世界把持経験収集

前項で学習したモデルの出力を用いて実世界で把持経験を収集する。把持経験の収集工程の概要については図4に示すように、学習済み把持点予測モデルの出力を用いた重み付きランダムサンプリングにより把持点を決定し実行することで、ロボットが自動的に把持経験を収集する [Kitagawa 18]。

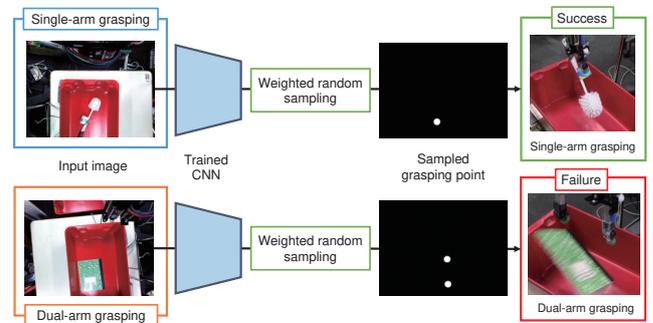


図 4: 把持点予測モデルを用いた実世界把持経験収集

5.2 再学習による実世界把持経験への適応

把持点予測モデルの予測結果における把持点の獲得と選定は、実世界での把持試行とそれによって収集されたデータセットを用いた把持点予測モデルの再学習によって実現される。再学習の際には、把持点予測モデルは意味ラベルに関しては学習済みであるとみなし、単腕・双腕把持の把持点に関する損失 L_{single} , L_{dual} の合計のみをネットワーク全体の再学習の損失 L_{total}^{adapt} として逆伝播する。

6. ターゲットピッキングのための選択的雙腕把持動作システム

6.1 選択的雙腕把持動作を行うターゲットピッキングシステムの動作フロー

本研究では選択的雙腕把持動作を行いながらターゲットピッキングタスクを実行するための動作フローを設計する。まず5.節で再学習を行った把持点予測モデルを用いて、対象物品の画像から把持すべき物品と把持点、把持戦略を選択し、その選択した物品がターゲット物品であるかどうかをチェックする。そして、把持物品がターゲット物品である場合には、予測した把持点と把持戦略を用いて把持動作ののちに収納動作を実行し、ターゲット物品でない場合には、予測した把持点と把持戦略を用いて把持動作ののちに移動動作を実行する。

6.2 Mask-RCNN を元にした把持点予測モデルを用いた雙腕把持動作選択システム

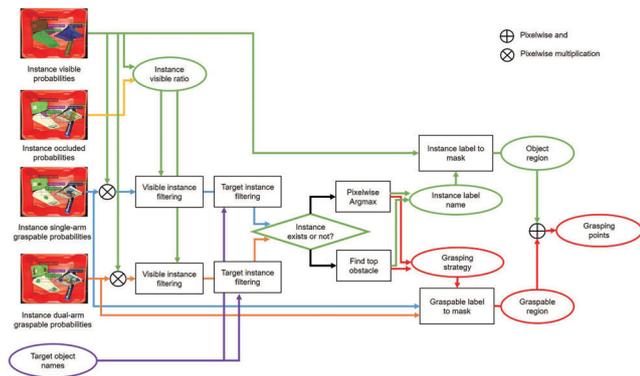


図 5: Mask-RCNN を元にした把持点予測モデルを用いた雙腕把持動作選択システム

本研究では図 5 に示すような、Mask-RCNN を元にした把持点予測モデルを用いた選択的雙腕把持動作選択システムを提案する。まず各物体インスタンスの可視・遮蔽領域分割を行うことで、各物体インスタンスの可視度 $ratio_{vis}$ を計算する。ある物体インスタンス i についての可視度 $ratio_{vis}(i)$ は物体インスタンス i の可視領域内のピクセル数 $N_{vis}(i)$ を可視・遮蔽領域内のピクセル数の合計 $N_{vis}(i) + N_{occ}(i)$ で割ることで計算される。次に物体インスタンス i の可視度 $N_{vis}(i)$ について可視度の閾値 $threshold_{vis}$ を設定することで、この閾値以上の物体インスタンスを可視物体インスタンスとして選択する。選択した可視物体インスタンスに対して、意味ラベルの確率画像と把持可能ラベルの確率画像のピクセル積算を行うことで積算結果画像を生成し、この画像の最も高い値を示すピクセルを実行する把持戦略と実行する把持点として決定する。選択した可視物体インスタンスにターゲット物品が含まれていない場合には、遮蔽されているターゲット物品を 1 つ選択し、それを遮蔽している物品インスタンスについて、可視度が

$threshold_{vis}$ を超える遮蔽物品インスタンスを探索していく。そして探索結果の遮蔽物品インスタンスを移動させる障害物インスタンスと設定し、ターゲット物品同様に、障害物物品に対する把持戦略と把持点を決定する。本研究では可視度の閾値 $threshold_{vis}$ を 0.9 と設定して動作選択を行う。

7. 検証実験

7.1 実験に用いる対象物品

本研究の検証実験で用いる対象 9 物品は Amazon Robotics Challenge [Morrison 17] においてピッキングタスク対象物品として選ばれた 40 物品の中から選んだ。この 9 物品はバインダー、ノートブック、袋入りくつした、製氷皿、アルミニウムホイル、DVD、スポンジ、テーブルクロス、トイレブラシである。この選んだ 9 物品は、雙腕把持しづらいが單腕把持では把持できる、單腕把持で把持しづらいが雙腕把持では把持できる、どちらの單腕・雙腕把持でも把持できる、の 3 つのカテゴリに分類でき、各カテゴリには表 1 に示すようにそれぞれ 2 から 4 物品が属する。

表 1: 対象 9 物品の單腕・雙腕把持に関する分類

Graspable category	Object names
Single-arm graspable	DVD, Toilet brush, Brown sponges
Dual-arm graspable	White binder, Green notebook
Both graspable	Ice cube tray, White socks, Aluminum foil, Pink table cloth

7.2 Mask-RCNN を元にした把持点予測モデルによる物体インスタンス可視・遮蔽領域分割結果

Mask-RCNN を元にした把持点予測モデルによる意味領域分割の評価として、クラス別平均適合率 mAP 、クラス別平均領域分割精度 mSQ 、クラス別平均インスタンス検出精度 mRQ 、クラス別平均インスタンス領域分割精度 mPQ の 4 指標 [Wada 18] を用いて評価を行った。人手でアノテーションした評価データセットに対して評価を行ったところ、表 2 上段に示す結果が得られ、自動生成データセットで学習したモデルでもクラス別平均領域分割精度 mSQ は 0.503 と高い値を示していることがわかる。また表 2 下段は人手でアノテーションして作成した比較用学習データセットを用いて学習したモデルの評価結果であり、自動生成データセットで学習したモデルと大差ない結果をしておりクラス別平均領域分割精度 mSQ も 0.004 だけ高い値を示すという結果が得られた。

表 2: Mask-RCNN を元にした把持点予測モデルによる物体インスタンス可視・遮蔽領域分割結果

Model	mAP	mSQ	mRQ	mPQ
Trained with synthesized dataset (Ours)	0.491	0.503	0.449	0.240
Trained with human annotated dataset	0.606	0.499	0.329	0.169

7.3 雙腕ターゲットピッキングシステムの検証実験

本実験では再学習のために 2 回の把持試行と再学習を行い、單腕把持 90 回、雙腕把持 90 回の計 180 回の把持試行経験でモデルを再学習した。

7.3.1 対象1 物品に対する選択的雙腕把持の検証

本実験では前項と同様の選択的雙腕把持の実験を行った。実験結果については表3に示す。表3に示すように再学習前と後では把持成功率が52.2%と84.4%と大きく向上した。単腕・雙腕把持の成功率についても同様に向上しており、以上の結果から把持経験収集による再学習を行うことで把持成功確率が向上することを確認した。

表3: Mask-RCNNを元にしたモデルによる把持結果

	Single-arm success	Dual-arm success	Total success
Before retraining	32 (68.1%)	15 (34.9%)	47 (52.2%)
After retraining	65 (91.5%)	11 (57.9%)	76 (84.4%)

7.3.2 対象3 物品に対するターゲットピッキングの検証

本項では対象3 物品に対するターゲットピッキングの検証実験について説明する。各物品1 つずつについてターゲットピッキングを実行する際に、他8 物品の中から2 物品を障害物としてターゲット物品の上に重ねることで複雑環境を作成した。この複雑環境を計9 シーン作成して実験を行い、各シーン2 回のタスク実行、計18 回のターゲットピッキングを行った。ターゲットピッキング結果は表4に示すように、本研究で提案するターゲットピッキングシステムは18 回中11 回成功の61.1%と高いタスク成功率を示している。

表4: 提案手法によるターゲットピッキング結果

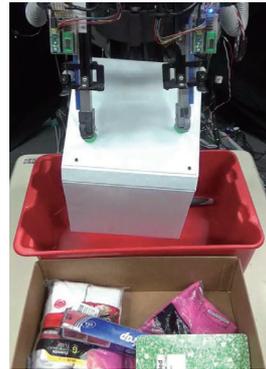
Success	Item drop	Mis- recognition	Mis- grasp	Obstacle removal failure	Total
11 (61.1%)	1 (5.6%)	2 (11.1%)	1 (5.6%)	2 (11.1%)	18

7.3.3 複雑環境におけるMask-RCNNを元にした把持点予測モデルを用いたターゲットピッキング

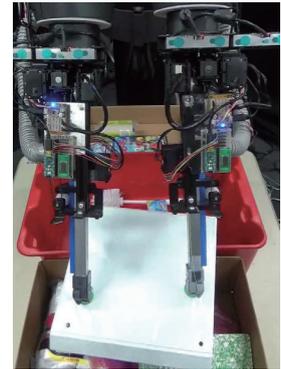
Mask-RCNNを元にした把持点予測モデルによる最終実験として、再学習した把持点予測モデルとその出力に基づく選択的雙腕把持動作を用いて、対象9 物品が重なりあう複雑環境における選択的雙腕把持動作を行うターゲットピッキングを行った。このときバインダー、ノートブック、袋入りくつした、アルミホイル、トイレブラシの5 物品をターゲット物品として、その他の物品を障害物物品として設定し、全ての物品を籠のなかにランダムに重ねて配置してターゲットピッキングを行った。またこの実験では物品の認識や把持が困難でタスク実行が終了できない場合が発生したため、その際には人が籠の中にある物品を重ねなおしてタスクを再開した。

本実験では2 シーンの複雑環境でターゲットピッキングを行った。両シーンともにテーブルクロスをターゲット物品と誤認識して収納しているが、それ以外は全てのターゲット物品を正しく収納している。また両シーンでともにバインダーとノートブックの把持の際に雙腕把持動作を選択して行い、その他の物品に対しては單腕把持動作を行った。また図6に示すように、複雑環境においてロボットはターゲット物品であるバインダーを正しくターゲット物品であると認識し、かつ安定的に把持できる雙腕把持動作とその把持点を適切に選択することで、把持・収納動作を問題なく実行した。さらに図7では、ロボットはDVDをターゲット物品を把持する際の障害物であると認

識し、かつ安定的に把持できる單腕把持動作とその把持点を適切に選択することで、把持・移動動作を問題なく実行した。



(a) バインダー(ターゲット物品)の雙腕把持動作



(b) バインダー(ターゲット物品)の雙腕収納動作

図6: 複雑環境でのターゲットピッキングにおけるターゲット物品の雙腕把持・収納動作



(a) DVD(障害物物品)の單腕把持動作



(b) DVD(障害物物品)の單腕移動動作

図7: 複雑環境でのターゲットピッキングにおける障害物物品の單腕把持・移動動作

8. 結論

本研究では、ロボットが状況に応じて選択的雙腕把持を行う自律学習型ピッキングタスクシステムを実現した。今後は収集した実世界把持経験の偏りへの対応や多様な雙腕マニピュレーション動作への拡張を行っていく。

参考文献

- [Correll 16] Correll, N., et al.: Lessons from the Amazon Picking Challenge, *CoRR*, Vol. abs/1601.05484, (2016)
- [He 17] He, K., et al.: Mask R-CNN, in *ICCV*, pp. 2980–2988 (2017)
- [Kitagawa 18] Kitagawa, S., et al.: Multi-stage Learning of Selective Dual-arm Grasping Based on Obtaining and Pruning Grasping Points Through the Robot Experience in the Real World, in *IROS*, pp. 7123–7130 (2018)
- [Morrison 17] Morrison, D., et al.: Cartman: The low-cost Cartesian Manipulator that won the Amazon Robotics Challenge, *CoRR*, Vol. abs/1709.06283, (2017)
- [Pinto 16] Pinto, L. and Gupta, A.: Supersizing self-supervision: Learning to grasp from 50K tries and 700 robot hours, in *ICRA*, pp. 3406–3413 (2016)
- [Wada 18] Wada, K., et al.: Instance Segmentation of Visible and Occluded Regions for Finding and Picking Target from a Pile of Objects, in *IROS*, pp. 2048–2055 (2018)

[1L4-J-11] Robot and real worlds: learning of robots

Chair:Yoshimasa Tawatsuji Reviewer:Masakazu Hirokawa

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room L (203+204 Small meeting rooms)

[1L4-J-11-01] Development of black line tracing system using deep learning for Pepper robot○Yuta Ogai¹, Masaya Kazuki¹, Shogo Suzuki¹, Daisuke Katagami¹, Takenori Obo¹, Junji Sone¹, Takahito Tomoto¹, Yoshihisa Udagawa¹ (1. Tokyo Polytechnic University)

5:20 PM - 5:40 PM

[1L4-J-11-02] Construction of Multimodal Learning Models Based on Integrating Stochastic Models○Ryo Kuniyasu¹, Tomoaki Nakamura¹, Takayuki Nagai², Tadahiro Taniguchi³ (1. The University of Electro-Communications, 2. Osaka University, 3. Ritsumeikan University)

5:40 PM - 6:00 PM

[1L4-J-11-03] Integrated Cognitive Model for Robot Learning of Concepts, Actions, and Language○Kazuki Miyazawa¹, Tatsuya Aoki¹, Takato Horii¹, Takayuki Nagai^{1,2} (1. The University of Electro-Communications, 2. Osaka University)

6:00 PM - 6:20 PM

[1L4-J-11-04] Simultaneous Learning of Object Concepts, Language Model, and Acoustic Model Using Unsupervised Multimodal Learning○Hiroaki Murakami¹, Ryo Ozaki¹, Akira Taniguchi¹, Tadahiro Taniguchi¹ (1. Ritsumeikan University)

6:20 PM - 6:40 PM

深層学習を使った Pepper 用黒線追従式移動システムの開発

Development of black line tracing system using deep learning for Pepper robot

大海 悠太^{*1} 香月 将也^{*1} 鈴木 省吾^{*1} 片上 大輔^{*1} 大保 武慶^{*1} 曾根 順治^{*1}
 Yuta Ogai Masaya Kazuki Shogo Suzuki Daisuke Katagami Takenori Obo Junji Sone
 東本 崇仁^{*1} 宇田川 佳久^{*1}
 Takahito Tomoto Yoshihisa Udagawa

^{*1}東京工芸大学
 Tokyo Polytechnic University

In this research, we aim to develop a pepper robot movement system that can be introduced easily. We developed a function that Pepper robot distinguishes black tapes attached to the floor in 5 directions using deep learning. I also confirmed its operation in experimental environment.

1. はじめに

サービスロボット Pepper は様々な店頭などで利用されているが、多くのものは同じ場所に固定して接客などに利用されており、移動して案内などをする用途ではあまり用いられていない。その理由として、簡便に移動させて利用するためのシステムがないことがあげられる。しかし Pepper が少し店内や教室内を巡回するだけでも、案内や教育などに活用できると考えている。これまで、Pepper の簡便な移動システムについて、テンプレートマッチングを用いたライトレース方式での移動の研究 [香月 18, 大海 18] を行ってきた。しかし、簡単なテンプレートマッチングだけでは、障害物等の処理ができないことが多い。そこで研究が進んでいる深層学習技術を用いることで、その問題がなくなるのではないかと考えている。本研究では深層学習を用いて、Pepper のライトレース型移動システムの開発を目指す。

2. 開発したシステム

図 1 に開発したプログラムの流れを示す。Pepper の口に搭載されているカメラを入力として黒線の検出を行っている。検出の際に行っている画像処理には、深層学習を使っている。ニューラルネットワークのモデルは学習済みの VGG16[Simonyan 14]を採用し、転移学習させている。

学習に用いた画像は 5 種類の黒線 (左旋回、左に修正する直線、直線、右に修正する直線、右旋回) であり、全 1830 枚を用いた (図 2)。画像は ImageDataGenerator で拡張しており、画像に [-90,90] の範囲で画素値をランダムに足している。

3. 実験と結果

学習した結果を図 3 に示す。val_acc は 8 割程度までしか上がらなかったが、間違えている画像は障害物や影が周囲にあるなど、判別が難しいものであった。

また、学習させたモデルを使い、約 2.5m × 3.5m の四角のコースで Pepper を動作させた。その結果、20 分間 9 周程度線の上を周回させることに成功した。しかし、線の周囲に障害

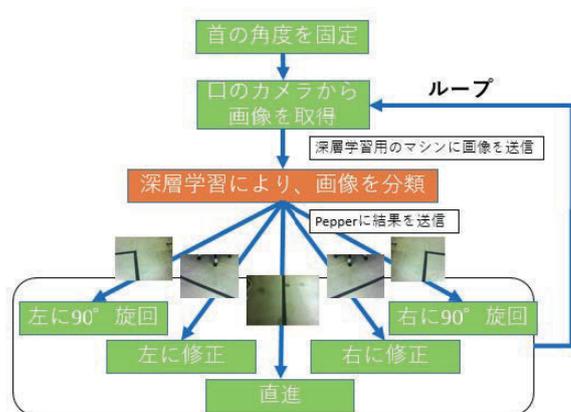


図 1: 開発したシステムの流れ。

物や影を配置すると、判別に失敗し意図しない方向へ進んでしまう現象が観察された。

4. 考察、まとめ

深層学習で黒線を判別させて、実験環境で Pepper を巡回させることに成功した。現状ではまだ難しい状況では判別に失敗してしまうことがあるため、画像データを増やすことや、黒線抽出と判別を別プロセスで分けることなど必要であると考えている。しかし、障害物をなるべく除去したり、確信度が低い場合は止まるなどの機能を付けることで、現状でもある程度運用できる可能性がある。

謝辞

本研究は、平成 28 年度「私立大学研究ブランディング事業」の「色の国際科学芸術研究センター」および、ユニバーサル未来社会推進協議会の「教育・コミュニケーションロボットの研究開発」のテーマとして、実施している。

連絡先: 大海 悠太, 東京工芸大学工学研究科電子情報工学専攻, 神奈川県厚木市飯山 1583, ogai@em.t-kougei.ac.jp

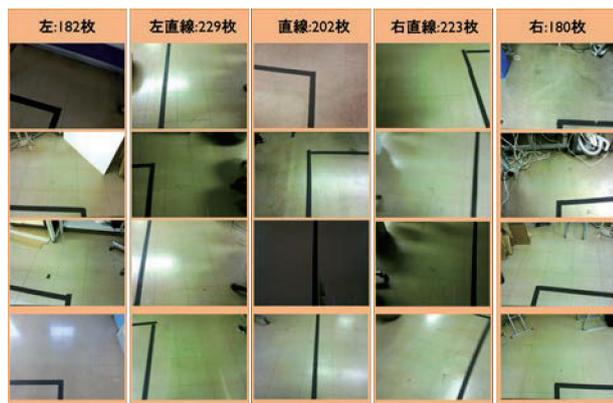


図 2: 学習に用いた画像の例。

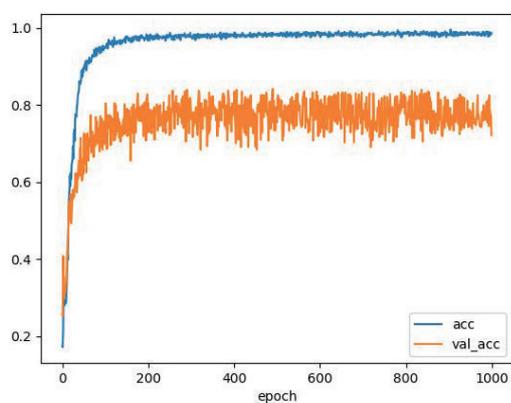


図 3: 学習結果。



図 4: Pepper がライトレースを行っている様子。

参考文献

- [Simonyan 14] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, Vol. abs/1409.1556, (2014)
- [香月 18] 香月 将也, 高橋 翼, 大海 悠太: 画像処理を用いた Pepper 用黒線追従式移動システムの開発, 第 28 回インテリジェント・システム・シンポジウム (FAN2018) (2018)
- [大海 18] 大海 悠太, 香月 将也, 鈴木 省吾, 片上 大輔, 大保 武慶, 曾根 順治, 東本 崇仁, 宇田川 佳久: 単眼カメラ画像からの挙手姿勢認識と黒線画像判別による Pepper 用教室内循環システムの開発, 第 19 回計測自動制御学会 SI 部門講演会 (SI2018) (2018)

確率モデルの統合によるマルチモーダル学習モデルの構築

Construction of Multimodal Learning Models Based on Integrating Stochastic Models

國安 瞭 *¹
Ryo Kuniyasu

中村 友昭 *¹
Tomoaki Nakamura

長井 隆行 *²
Takayuki Nagai

谷口 忠大 *³
Tadahiro Taniguchi

*¹電気通信大学
The University of Electro-Communications

*²大阪大学
Osaka University

*³立命館大学
Ritsumeikan University

In order to realize human-like intelligence artificially, large-scale models are required for robots to understand the environment using multimodal information obtained by various sensors equipped in robots. However, as the scale of models becomes large and complex, it is difficult to construct such models and to derive and implement the equations for their parameter estimation. To overcome this problem, we proposed a framework Serket that makes it easy to construct large-scale models and estimate their parameters by connecting small fundamental models hierarchically while keeping programmatic independence. In this paper, we construct the integrated models of the modules such as variational autoencoder, Gaussian mixture model, Markov model, and multimodal latent Dirichlet allocation, and then show that it is easy to construct the integrated models and their parameters are optimized by communicating between the modules by using Serket.

1. はじめに

人間のような知能を人工的に実現するためには、ロボットに搭載されている様々なセンサから得られるマルチモーダル情報から、ロボットが環境を理解するためのモデルが必要である。そこで、これまで我々は、ロボットが得たマルチモーダル情報を分類することによってロボットが言語や概念を獲得するモデルを提案してきた [Nakamura 14, Taniguchi 16]。人間のような知能を実現するためには、より複雑で大規模なモデルを構築する必要がある。しかし、そのようなモデルのパラメータ推定の式を導出し実装することは、その規模が大きくなるにつれて困難になると考えられる。そこで、我々は小規模なモデルをモジュール化し、階層的に接続することによって大規模なモデルの構築と、そのパラメータ推定を容易に行うことができるフレームワーク Serket (Symbol Emergence in Robotics tool KIT) を提案した [Nakamura 18]。本稿では、文献 [Nakamura 18, 國安 18] で実装した Variational Autoencoder (VAE) [Kingma 13], Gaussian Mixture Model (GMM), Markov Model (MM), Multimodal Latent Dirichlet Allocation (MLDA) のモジュールを Serket を用いて統合し、Serket の有効性を示す。

関連研究として、認知アーキテクチャや確率的プログラミング言語など、様々なモデルを構築するための手法が提案されている [Laird 08, Anderson 09, Patil 10, Tran 16]。しかし、これらの手法では、我々がこれまで提案してきたモデルや大規模なモデルを実装することは難しい。一方、Serket を用いることで、マルチモーダル情報から学習可能な大規模なモデルを構築することが可能となる。

なお本稿の実験で使用したプログラムは全て GitHub*¹ で公開している。

2. Serket

Serket では、小規模なモデルであるモジュールを接続することで大規模なモデルを構築し、モジュール間の通信によりパラメータの推定を行う。本章では、文献 [Nakamura 18] にて提案した Serket に関して説明する。

2.1 モジュール

図 1 に一般化されたモジュールのグラフィカルモデルを示す。各モジュールは、潜在変数 $z_{m,n}$ から生成される他のモジュールと共有される潜在変数 $z_{m-1,*}$ 、および観測 $\mathbf{o}_{m,n,*}$ を持つ。

連絡先: 國安 瞭, 電気通信大学, 東京都調布市調布ヶ丘 1-5-1, k1512051@edu.cc.uec.ac.jp

*¹ <https://github.com/naka-lab/Serket>

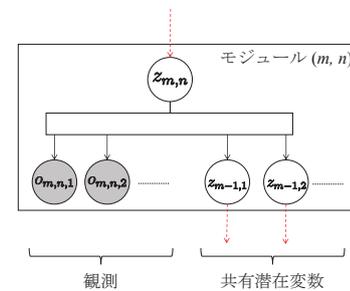


図 1: 一般化されたモジュール

ただし、共有潜在変数や観測を持たないモジュールもこの一般化されたモデルに含まれる。モジュールは以下の要件を満たすことができれば、任意の内部構造を持つことができる。

1. 各モジュールは、次の共有潜在変数が生成される確率などを計算し、潜在変数を共有するモジュールへ送ることができる。

$$P(z_{m-1,i} | z_{m,n}, \mathbf{o}_{m,n,1}, \mathbf{o}_{m,n,2}, \dots, z_{m-1}) \quad (1)$$

2. モジュール $(m+1, j)$ から送られる次の確率などを使用して潜在変数 $z_{m,n}$ を決定することができる。

$$P(z_{m,n} | z_{m+1,j}, \mathbf{o}_{m+1,j,1}, \mathbf{o}_{m+1,j,2}, \dots, z_m) \quad (2)$$

3. 末端のモジュールには共有潜在変数はなく、観測のみを持つ。

このようなモジュールを再帰的に接続することで、大規模なモデルを構築することが可能となる。

2.2 メッセージパッシング法

Serket では、モジュールが相互に影響を及ぼしあいながら共有潜在変数の値が決定される。共有潜在変数を決定する方法はいくつかあり、潜在変数が離散かつ有限である場合はメッセージパッシング (MP) 法を用いることができる。MP 法を図 2 に示す単純化されたモデルを用いて説明する。モジュール 2 では潜在変数 z_2 から共有潜在変数 z_1 が生成され、モジュール 1 では潜在変数 z_1 から観測 \mathbf{o} が生成される。 z_1 はモジュール 1 とモジュール 2 で共有されており、この値は次式のように 2 つのモジュールが相互に影響することで決定される。

$$z_1 \sim P(z_1 | \mathbf{o}, z_2) \quad (3)$$

$$\propto P(z_1 | \mathbf{o}) P(z_1 | z_2) \quad (4)$$

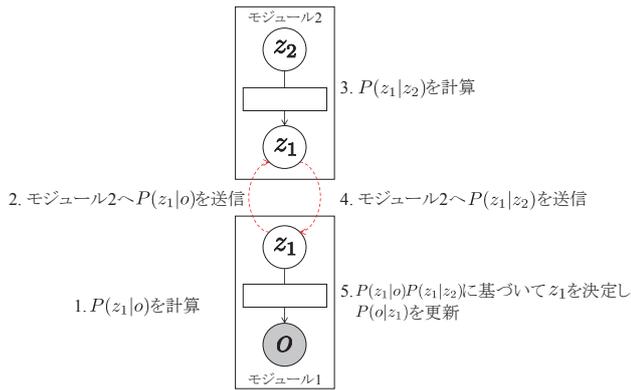


図 2: メッセージパッシング法

$P(z_1|o)$ はモジュール 1 で計算され、 $P(z_1|z_2)$ はモジュール 2 で計算される。潜在変数が離散的かつ有限の場合、 $P(z_1|z_2)$ は z_1 と同じ要素数となる多項分布であり、有限次元のパラメータで表すことができる。したがって、 $P(z_1|z_2)$ のパラメータを、モジュール 2 からモジュール 1 へ送ることができる。さらに、モジュール 1 から送られる $P(z_1|o)$ を用いてモジュール 2 で $P(z_1|z_2)$ が学習される。これらの分布のパラメータは容易に送受信でき、図 2 の手順で共有潜在変数を決定することができる。このように、メッセージのやりとりによってモデルのパラメータを最適化できるため、本稿ではこの手法を MP 法と呼ぶ。

以降の章では、Serket を用いた実装例を示す。

3. 実装例 1: VAE と GMM の統合モデル

まず、VAE と GMM を統合した次元圧縮と教師なし分類を同時に行うモデルを構築する。

3.1 Serket による実装

図 3 は、VAE と GMM を統合したモデルのグラフィカルモデルである。VAE は、観測 o をエンコーダーにあたるニューラルネットを通して任意の次元の潜在変数 z_1 に圧縮し、GMM へ送信する。GMM は、VAE から送られてきた z_1 を分類し、分類されたクラスの分布の平均 μ を VAE へ送信する。Serket では、GMM での分類の影響を受けるため、 μ を用いて VAE の変分下限を以下のように定義する。

$$\mathcal{L}(\theta, \phi; o) = -w D_{KL}(q_\phi(z_1|o) \| \mathcal{N}(\mu, I)) + \mathbb{E}_{q_\phi(z_1|o)}[\log p_\theta(o|z_1)] \quad (5)$$

ただし、 D_{KL} は KL ダイバージェンスを表しており、 w は KL ダイバージェンスの重みである。本稿では、 $w = 1$ を用いて実験を行う。これにより、GMM によって同じクラスに分類されたデータの z_1 は似た値を持つこととなり、分類に適した潜在空間が学習される。

実際に Serket を用いて実装したソースコードをソースコード 1 に示す。このように、基本的なモジュールを用意することで、容易にモデルを構築することが可能である。

3.2 実験

VAE と GMM を統合したモデルを用いて、MNIST データセットの分類を行なった。データ数は、3,000 である。VAE の潜在変数の次元数は 18 次元とした。分類結果を図 4 に、分類の定量的評価を表 1 に示す。図 4 は分類の混同行列を表しており、縦軸が正解のクラスのインデックス、横軸が分類されたクラスのインデックスである。最適化の際のメッセージのやりとりは 5 回行い、評価指標としては Adjusted Rand Index (ARI)[Hubert 85] を用いた。分類結果および ARI は、10 回の試行の平均と、そのうち最適化後の ARI が最も高かったものを併記している。さらに、VAE により圧縮された潜在変数を、主成分分析でさらに 2 次元に圧縮しプロットしたグラフ

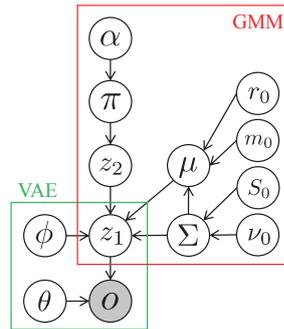


図 3: VAE+GMM のグラフィカルモデル

ソースコード 1: VAE+GMM

```

1 import serket as srk
2 import vae
3 import gmm
4 import numpy as np
5
6 # 観測と正解ラベルの読み込み
7 obs1 = srk.Observation(np.loadtxt("data.txt"))
8 category = np.loadtxt("category.txt")
9
10 # モジュールの定義
11 vae1 = vae.VAE(18, itr=200, batch_size=500)
12 gmm1 = gmm.GMM(10, category=category)
13
14 # モジュールの接続, モデルの構築
15 vae1.connect(obs1)
16 gmm1.connect(vae1)
17
18 # パラメータの更新, 最適化
19 for it in range(5):
20     vae1.update()
21     gmm1.update()

```

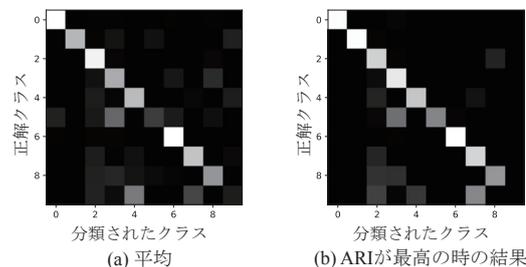


図 4: VAE+GMM の分類結果 (a)10 回の試行の平均 (b) 最適化後の ARI が最も高かった時の結果

を図 5 に示す。図 5(a) は VAE 単体で構成された潜在空間であり、図 5(b) が Serket により GMM との相互作用によって構成された潜在空間である。各点の色は、正解のクラスのインデックスを表している。

図 4 から 0,1,2,6 は誤分類が少なく高い精度で分類されているが、4,7,9 などは混同し分類精度が低いことが分かる。これは、図 5 からも確認でき、似た特徴を持つデータは潜在空間において近い位置にあるため、同じクラスに誤分類されてしまい Serket による最適化後も近い位置にまとまっている。そのため、ARI の平均値では最適化による大きな向上が見られなかったと考えられる。一方で、図 5 から最適化前では同じクラスであるデータ点が空間上に広く分布しているのに対して、Serket による最適化後ではクラスごとにまとまっている。すなわち、最適化により同じクラスに分類されるデータの潜在変数は似た値を持ち、GMM の分類に適した潜在空間が学習されていることが確認できる。

表 1: VAE+GMM の ARI

	平均値	最高値
最適化前	0.477	0.478
最適化後	0.503	0.568

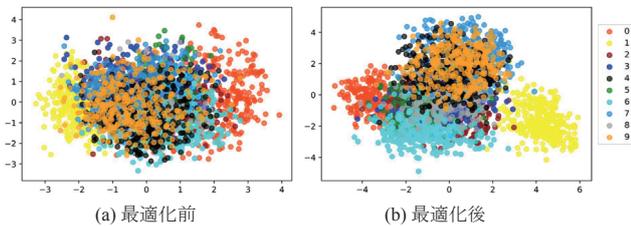


図 5: 圧縮後の潜在変数

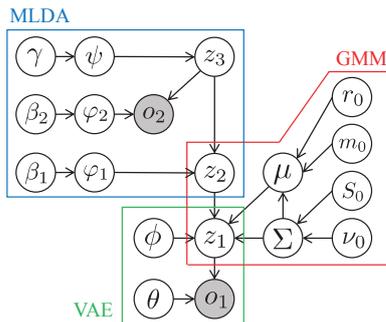


図 6: VAE+GMM+MLDA のグラフィカルモデル

4. 実装例 2: VAE, GMM, MLDA の統合モデル

次に、画像だけでなく音声も用いたマルチモーダル学習モデルを構築する。

4.1 Serket による実装

図 6 は、VAE, GMM, MLDA を統合したモデルのグラフィカルモデルである。GMM は、VAE から送られてきた潜在変数 z_1 を分類し、 t 番目のデータがクラス $z_{2,t}$ に分類される確率 $P(z_{2,t}|z_{1,t})$ を MLDA へ送信する。MLDA は、GMM から送られてきた確率を用いることで z_2 を観測として扱い、 z_2 と観測 o_2 を分類し、GMM へ確率 $P(z_{2,t}|z_{3,t}, o_{2,t})$ を送信する。GMM では、送られてきた確率も用いて再度分類を行うことで、MLDA の影響を受け z_3, o_2 を考慮した分類が行われる。

ソースコード 2 が実際に実装したソースコードである。このように、モジュールの定義、モジュール間の関係、パラメータの更新の記述を追加することで容易にモデルを拡張することが可能である。

4.2 実験

VAE, GMM, MLDA を統合したモデルを用いて、MNIST データセットおよび Spoken Arabic Digit Data Set の分類を行った。データ数は 3,000 である。Spoken Arabic Digit Data Set は数字の音声発話から MFCC 特徴量を抽出したものであり、本稿では MFCC 特徴量を HAC 特徴量 [Van.hamme 08] に変換して使用した。分類結果を図 7 に、分類の ARI を表 2 に示す。

図 7(a) から 3 章と同様に 4,7,9 が混同しており誤分類が多いが、9 の分類に関して 3 章で構築したモデルより正確に行われており、その他の数字に関しても誤分類が減少していることが確認できる。マルチモーダル情報を用いることによって誤分類が減少し、ARI が向上した。

ソースコード 2: VAE+GMM+MLDA

```

1 import serket as srk
2 import vae
3 import gmm
4 import mlada
5 import numpy as np
6
7 # 観測と正解ラベルの読み込み
8 obs1=srk.Observation(np.loadtxt("data1.txt")) # 画像
9 obs2=srk.Observation(np.loadtxt("data2.txt")) # 音声
10 category = np.loadtxt("category.txt")
11
12 # モジュールの定義
13 vae1 = vae.VAE(18, itr=200, batch_size=500)
14 gmm1 = gmm.GMM(10, category=category)
15 mlada1 = mlada.MLDA(10, category=category)
16
17 # モジュールの接続, モデルの構築
18 vae1.connect(obs1)
19 gmm1.connect(vae1)
20 mlada1.connect(obs2, gmm1)
21
22 # パラメータの更新, 最適化
23 for it in range(5):
24     vae1.update()
25     gmm1.update()
26     mlada1.update()

```

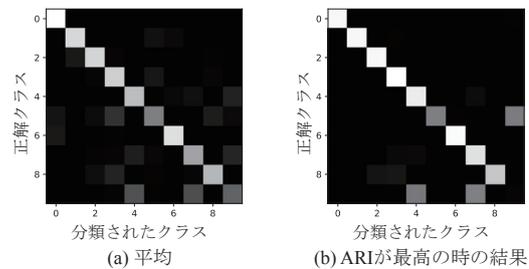


図 7: VAE+GMM+MLDA の分類結果 (a)10 回の試行の平均 (b) 最適化後の ARI が最も高かった時の結果

表 2: VAE+GMM+MLDA の ARI

	平均値	最高値
最適化前	0.604	0.638
最適化後	0.637	0.735

5. 実装例 3: VAE, GMM, MLDA, MM の統合モデル

さらに、4 章で構築したモデルに MM モジュールを接続することで、時系列データの遷移も学習可能なモデルを構築する。

5.1 Serket による実装

図 8 は、VAE, GMM, MLDA, MM を統合したモデルのグラフィカルモデルである。MLDA は、 t 番目のデータがクラス $z_{3,t}$ に分類される確率 $P(z_{3,t}|z_{2,t}, o_{2,t})$ を MM へ送信する。MM は、送られてきた確率 $P(z_{3,t}|z_{2,t}, o_{2,t})$ を用いて繰り返しサンプリングを行い、次のように遷移回数をカウントする。

$$z'_3 \sim P(z_{3,t}|z_{2,t}, o_{2,t}) \quad (6)$$

$$z_3 \sim P(z_{3,t+1}|z_{2,t+1}, o_{2,t+1}) \quad (7)$$

$$N_{z'_3, z_3} \quad (8)$$

この値から遷移確率 $P(z_3|z'_3)$ は次のように計算することができる。

$$P(z_3|z'_3) = \frac{N_{z'_3, z_3} + \lambda}{\sum_{\bar{z}_3} N_{z'_3, \bar{z}_3} + K\lambda} \quad (9)$$

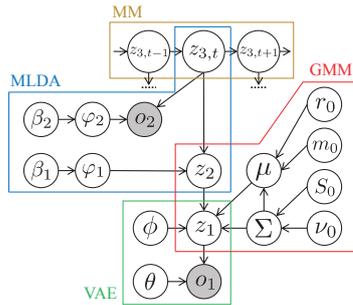


図 8: VAE+GMM+MLDA+MM のグラフィカルモデル

ソースコード 3: VAE+GMM+MLDA+MM

```

1 import serket as srk
2 import vae
3 import gmm
4 import mllda
5 import mm
6 import numpy as np
7
8 # 観測と正解ラベルの読み込み
9 obs1=srk.Observation(np.loadtxt("data1.txt")) # 画像
10 obs2=srk.Observation(np.loadtxt("data2.txt")) # 音声
11 category = np.loadtxt("category.txt")
12
13 # モジュールの定義
14 vae1 = vae.VAE(18, itr=200, batch_size=500)
15 gmm1 = gmm.GMM(10, category=category)
16 mllda1 = mllda.MLDA(10, category=category)
17 mm1 = mm.MarkovModel()
18
19 # モジュールの接続,モデルの構築
20 vae1.connect(obs1)
21 gmm1.connect(vae1)
22 mllda1.connect(obs2,gmm1)
23 mm1.connect(mllda1)
24
25 # パラメータの更新,最適化
26 for it in range(5):
27     vae1.update()
28     gmm1.update()
29     mllda1.update()
30     mm1.update()

```

ただし、 K は MLDA のクラス数である。この確率を用いて遷移を考慮したそれぞれのクラスに分類される確率を計算し、MLDA へ送信する。MLDA では、送られた確率も用いて再度分類を行うことで、データの遷移を考慮した分類が行われる。ソースコード 3 が実際に実装したソースコードである。

5.2 実験

VAE, GMM, MLDA, MM を統合したモデルを用いて、MNIST データセットおよび Spoken Arabic Digit Data Set の分類を行った。データ数は 3,000 であり、それぞれのデータは 0,1,2,3,4,5,6,7,8,9,0... のように規則的に並び替えて使用した。分類結果を図 9 に、分類の ARI を表 3 に示す。

4 章のモデルにさらに MM を接続することにより遷移を学習することで 4 章までに構築したモデルと比べて誤分類が大幅に減少し、ARI が大きく向上した。このように、Serket を用いてモジュールを接続することにより、それぞれのモジュールが影響を及ぼしあい、モデル全体のパラメータが最適化されていることが確認できる。

6. むすび

本稿では、Serket を用いて VAE, GMM, MM, MLDA を統合したモデルを構築し、Serket の有効性を示した。Serket を用いることでモジュールの定義、モジュール間の関係、パラメータの更新を記述することによって容易にモデルを構築、拡張することが可能である。MP 法によりそれぞれのモジュール

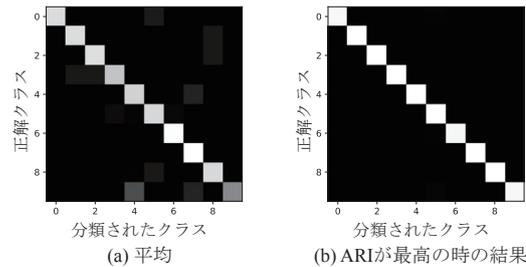


図 9: VAE+GMM+MLDA+MM の分類結果 (a)10 回の試行の平均 (b) 最適化後の ARI が最も高かった時の結果

表 3: VAE+GMM+MLDA+MM の ARI

	平均値	最高値
最適化前	0.575	0.524
最適化後	0.834	0.980

が影響を及ぼしあい、モデル全体のパラメータが最適化されることが確認できた。

実験では疑似データを用いたが、本来 Serket はロボットの様々なセンサから得られるマルチモーダル情報から学習するモデルを構築することが目的である。今後、実際にロボットのセンサから得られたマルチモーダル情報を用いた学習モデルの構築と評価や、モジュールの拡充を行っていく予定である。

謝辞

本研究は JST CREST JPMJCR15E3, JSPS 科研費 JP17K12758 の助成を受け実施したものである。

参考文献

- [Anderson 09] Anderson, J. R.: *How can the human mind occur in the physical universe?*, Oxford University Press (2009)
- [Hubert 85] Hubert, L. and Arabie, P.: Comparing partitions, *Journal of classification*, Vol. 2, No. 1, pp. 193–218 (1985)
- [Kingma 13] Kingma, D. P. and Welling, M.: Auto-encoding variational bayes, *arXiv preprint arXiv:1312.6114*, pp. 1–14 (2013)
- [Laird 08] Laird, J. E.: Extending the Soar cognitive architecture, *Frontiers in Artificial Intelligence and Applications*, Vol. 171, p. 224 (2008)
- [Nakamura 14] Nakamura, T., Nagai, T., Funakoshi, K., Nagasaka, S., Taniguchi, T., and Iwahashi, N.: Mutual learning of an object concept and language model based on MLDA and NPYLM, in *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 600–607 (2014)
- [Nakamura 18] Nakamura, T., Nagai, T., and Taniguchi, T.: SERKET: An Architecture for Connecting Stochastic Models to Realize a Large-Scale Cognitive Model, *Frontiers in Neurobotics*, Vol. 12, pp. 1–16 (2018)
- [Patil 10] Patil, A., Huard, D., and Fonnesebeck, C. J.: PyMC: Bayesian stochastic modelling in Python, *Journal of statistical software*, Vol. 35, No. 4, p. 1 (2010)
- [Taniguchi 16] Taniguchi, A., Taniguchi, T., and Inamura, T.: 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*, Vol. 8, No. 4, pp. 285–297 (2016)
- [Tran 16] Tran, D., Kucukelbir, A., Dieng, A. B., Rudolph, M., Liang, D., and Blei, D. M.: Edward: A library for probabilistic modeling, inference, and criticism, *arXiv preprint arXiv:1610.09787*, pp. 1–33 (2016)
- [Van_hamme 08] Van_hamme, H.: Hac-models: A novel approach to continuous speech recognition, in *Ninth Annual Conference of the International Speech Communication Association* (2008)
- [國安 18] 國安 瞭, 中村 友昭, 青木 達哉, 谷口 彰, 尾崎 僚, 伊志嶺 朝良, 横山 裕樹, 小椋 忠志, 長井 隆行, 谷口 忠大: 確率モデルの統合による大規模なモデルの実現—VAE, GMM, HMM, MLDA の統合モデルの実装と評価—, 情報論的学習理論ワークショップ, T-34 (2018)

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

Integrated Cognitive Model for Robot Learning of Concepts, Actions, and Language

宮澤 和貴 *¹ 青木 達哉 *¹ 堀井 隆斗 *¹ 長井 隆行 *¹*²
 Kazuki Miyazawa Tatsuya Aoki Takato Horii Takayuki Nagai

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

It is expected to realize an intelligent robot that coexists with us and supports our lives. In order to realize such a robot, it is necessary to act by understanding the surrounding environment and language in the real world. For such a complex understanding, multiple cognitive functions are required. The purpose of this study is to propose an integrated cognitive model for robots that simultaneously learn concepts, actions, and language. This can be achieved by integrating various modules. The proposed model consists of three modules: concepts formation using multimodal information, grammar learning, and reinforcement learning. We verify the potential of the proposed model through experiments using a real robot. We show that the proposed model enables robots to form concepts, make decision, and understand language.

1. はじめに

人間の生活を支援するような知的なロボットの登場が期待されている。このようなロボットは、周囲の環境や言語を理解して行動する必要がある。筆者らは、記号創発ロボティクスの視点から言語を含むロボットによる実世界の理解について検討を続けてきた [Taniguchi16]。ここで理解とは予測することであると考える、この予測を効率的に行うために概念形成を行う。概念とは様々なセンサにより取得したマルチモーダル情報をカテゴリ化した過去の経験であると考え、中村らは、文章分類で用いられる Latent Dirichlet Allocation(LDA) をマルチモーダル情報に拡張したマルチモーダル LDA(MLDA) を提案し、ロボットを用いた実験を行うことで、ロボットによる概念形成の可能性を示した [Nakamura09]。また、MLDA を拡張し他のモジュールと結合することで、簡単な言語や行動を扱うことができる [Attamimi16, Miyazawa17]。

一方で近年の深層学習技術の発展により、ロボットの様々なタスクにおける深層強化学習の有用性が示されている [Levine16, Gu16]。さらには、本研究と同様にマルチモーダルデータを用いた学習や、言語と行動の同時学習も盛んに研究されている [Arandjelovi17, Hill17]。これらのアプローチでは、知能の一部に焦点を当てモデル化することによりある機能単位の知能を獲得している。しかし実世界のような複雑な環境で動作するロボットを作るには、概念形成や言語理解、行動決定などの個々の認知機能が相互作用するような複雑な知能を考る必要がある。また、深層学習による知能獲得はシミュレーションを用いたものが多く実際のロボットを用いた研究は少ない。

そこで本稿では、複数の認知モジュールを統合した統合認知モデル(計算モデル)を構築し実際のロボットを用いて実装・評価することを目標とする。提案する統合認知モデルでは、概念・行動・言語をロボット自身の経験から同時に学習する。このように、自身の経験からボトムアップに複数の認知機能を獲得するモデルを構成することは、構成論的アプローチの観点からも、人間の学習メカニズムを解明する一助となるため有意義である。本研究では、提案モデルの有効性を検証するために、

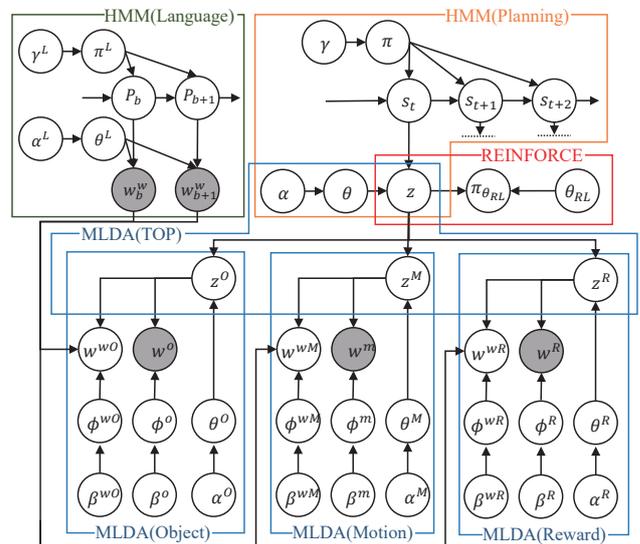


図 1: 統合認知モデルのグラフィカルモデルによる表現

実ロボットによる親子間インタラクションを模した実験を行い、マルチモーダル情報を取得することで学習と評価を行い提案モデルの有効性を検証する。

2. 統合認知モデル

本稿で提案する統合認知モデルを図 1 に示す。このモデルは、多層マルチモーダル LDA(mMLDA) による概念形成を中心に複数のモジュールを統合することで成り立っている [Fadlil13]。形成した概念を各モジュールが共有することで、複数の認知機能を統合する。各モジュールは、言語を扱う Hidden Markov Model (HMM)、即時的な行動決定を行う強化学習 (REINFORCE)、行動の時系列をモデル化し長期的な行動計画を行う Hidden Markov Model (HMM) である。提案するモデルにおいて、単語情報は mMLDA を通じて実世界の情報に接地している。この単語情報に HMM(Language) で表現された単語情報を適用することにより、提案モデルはセンサ情報に基づき文章を生成することができる。また、文章を分解して実世界

の情報を予測することで、ロボットは文章の意味を理解することができる。一方で、行動に関しては、方策に基づいた即時的な行動と、プランニングに基づいた行動を考える。即時的な行動では mMLDA が形成した概念を強化学習の状態空間・行動空間として扱うことで実現される。また、長期的な行動の計画は HMM(Planning) に表現される時系列情報を用いることで実現する。次節から各モジュールによる認知機能の実現について示し、最後にモデル全体の統合について述べる。

2.1 mMLDA による概念形成

図 1 の青枠のモジュールが mMLDA を示している。図 1 において、 z は統合概念を表すカテゴリであり、 z^O , z^M , z^R はそれぞれ下位概念に相当する、物体、動作、報酬カテゴリである。上位カテゴリ z は、下位カテゴリ間の関係性を捉えている。これにより、動作、場所、物体など各々のカテゴリ分類を行うと同時に、それらの概念間の関係を教師なしで学習することができる [Fadlil13]。 w^O , w^M , w^R , w^{w*} は観測データであり、それぞれ、物体情報、動作情報、報酬情報、言語情報である。 ϕ^* , θ^* は多項分布のパラメータであり、 β^* , α^* はディリクレ分布のパラメータである。物体情報 w^O は、物体画像から畳み込みニューラルネットワーク (CNN) により特徴抽出した 4096 次元の情報を用いた。動作情報 w^M は、ロボットの各動作を 4 次元の 1-of- k 表現としたものを用いる。報酬情報 w^R は、ロボットが行動することで得た報酬値を利用し、報酬値 r を $r < 0$, $r = 0$, $r > 0$ により場合分けして、3 次元の 1-of- k 表現としたものを用いる。言語情報 w^{w*} は、人から与えられたシーンに対応する文章の Bag of Words 表現である。

2.2 HMM(Language) による言語学習

言語学習は、Attamimi らが提案している mMLDA と HMM の相互学習により行う [Attamimi16]。このモデルにおいて、文法とは各単語の品詞と語順の情報であり、品詞は概念クラスによって表現されると考える。語順はこの概念クラスがどのような順番で並ぶことで文を構成するかを隠れマルコフモデル (HMM) で表現する。この HMM は図 1 の HMM(Language) に示す、遷移確率 π^L , 出力確率 θ^L , 単語 w_b^w の隠れ状態が P_b である HMM である。紙面の都合上詳細な説明は省略するが、HMM(Language) と mMLDA の相互学習により品詞 (概念クラスと単語の結び付け)、文法、概念を学習する。

2.3 REINFORCE による方策学習

即時的な行動の学習は強化学習による方策学習を用いて行う。強化学習には REINFORCE アルゴリズムを用いる [Williams92]。図 1 に示すように、上位概念を強化学習の状態空間・行動空間として用いる。ある時刻 t の上位概念 z_t は式 (1) に示すように観測情報 w_t^* から推定する。

$$z_t \sim P(z_t | w_t^O, w_t^M, w_t^R, w_t^w) \quad (1)$$

推定した上位概念 z_t を用いて式 (2) より次の状態の上位概念 z_{t+1} を求める。

$$\pi_{\theta_{RL}}(z_{t+1} | z_t) = \frac{\exp(\theta_{RL}^T \phi(z_{t+1}, z_t))}{\sum_{z_{t+1} \in A} \exp(\theta_{RL}^T \phi(z_{t+1}, z_t))} \quad (2)$$

ここで、 A は全行動、 θ_{RL} は方策 $\pi_{\theta_{RL}}$ のパラメータベクトル、 $\phi(\ast)$ は状態 z_t と行動 z_{t+1} のカーネル関数である。 θ_{RL} の更新は以下の式により行う。

$$\theta_{RL}^{t+1} = \theta_{RL}^t + \eta \nabla_{\theta_{RL}} J(\theta_{RL}) \quad (3)$$

$$\nabla_{\theta_{RL}} J(\theta_{RL}) \approx \sum_{e=1}^E \sum_{t=1}^T (R_t^e - \bar{b}) \nabla_{\theta_{RL}} \log \pi_{\theta_{RL}}(z_t^e | z_{t-1}^e) \quad (4)$$

ここで、 η は学習率、 R_t^e は e エピソードの t ステップ目の報酬、 \bar{b} は平均報酬である。実際の動作選択や物体選択は、推定した上位概念 z_{t+1} を用いて $w^M \sim p(w^M | z_{t+1})$, $z^O \sim p(z^O | z_{t+1})$ としてサンプリングすることで行う。

2.4 HMM(Planning) による時系列学習

長期的行動計画の学習は、図 1 上部に示すように、HMM(Planning) を用いて統合概念 z を時間方向に発展させることで行う。隠れ状態 s , 出力確率 $\theta = P(z_t | s_t, \alpha)$, 遷移確率 $\pi = P(s_t | s_{t-1}, \gamma)$ である HMM を考える。ここで α, γ はそれぞれ、ディリクレ分布のパラメータである。各パラメータ θ, π をギブスサンプリングによりサンプリングすることで学習を行う。学習を行うことで、時系列情報をモデル化できるため行動計画を行うことができる。この行動計画は、時系列的に欠損された情報を予測することで行う。欠損値は一樣分布であると考えてギブスサンプリングすることで長期的な系列を推定し、行動計画が可能になる。

2.5 モデル全体の学習

モデルの結合には中村らが提案している、SERKET のメッセージパッシングにより行う [Nakamura18]。この枠組みでは大規模なモデルの更新を各モジュールごとの更新により行い、モジュール間で情報をやり取りすることでモデル全体の学習を実現する。mMLDA は MLDA の統合により実現する。下位概念により推定した $P(z^* | w^{w*}, w^*)$ と上位概念により推定した $P(z^* | z)$ をパッシングし合い相互に更新する。mMLDA と HMM(Language) の統合による言語学習は、ある概念 C における単語 w とカテゴリ k の相互情報量 $MI(w, k | C)$ と、HMM(Language) のパラメータにより重みづけられた単語の頻度 $P(w^w | w_b^w, P_b)$ をパッシングし合い相互に更新することで実現する。REINFORCE の更新は、MLDA(TOP) により推論した状態を強化学習のモジュールにパッシングすることで実現する。HMM(Planning) の更新は MLDA(TOP) により推定した $P(z | z^O, z^M, z^R)$ と HMM(Planning) により推定した $P(z | s)$ をパッシングし合い相互に更新することで行う。このように各モジュールの更新とメッセージパッシングを繰り返すことにより全体の更新を行う。モデル全体を学習することで、モジュール内の予測のみでなくモジュール間での予測が可能になる。

3. 実験

提案手法の有効性を示すために実際のロボットを用いた実験を行った。実験の目的は、ロボットが環境に対する知識がない状態から試行錯誤的に概念・行動・言語を学習し、その結果を解析することでモデルの妥当性を検証することである。

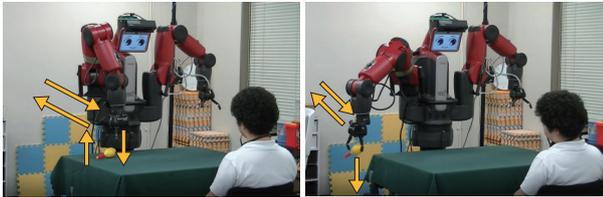
3.1 実験設定

図 2 に実験設定を示す。実験には双腕ロボット Baxter を用いた。ロボットは図 2(a) に示す物体に対して、図 2(b) に示す行動から図 2(c) に示す報酬に沿った適切な行動を選択するように学習する。物体は図 2(a) に示すように、3 つのグループに分けた。学習には学習データ 1 及び 2 を、評価には評価データを用いた。図 2(b) に示す動作は人手により事前に設計した。

図 3 に実験の流れと概要を示す。ロボットは机上から物体を一つ選択し、適切な動作を選択するように学習する。物体を

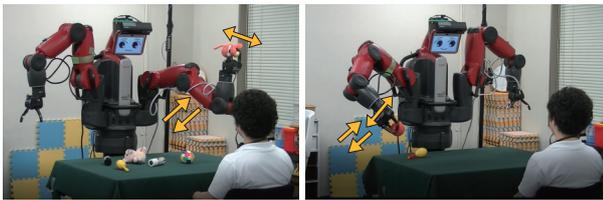
	ぬいぐるみ	ボール	マラカス	スプレー缶
学習データ1				
学習データ2				
評価データ				

(a) 実験に用いた物体



掴む

片付け



にぎる

振る

(b) 実験に用いたロボットの動作

	ぬいぐるみ	ボール	マラカス	スプレー缶
掴む	0	0	0	0
片付け	1	1	1	1
にぎる	1	1	-1	-1
振る	-1	-1	1	1

*物体把持時に「掴む」を選択、続けて同じ行動→報酬値-1
(c) 物体と動作に対応した報酬値の設定

図 2: 実験環境の設定

箱に片付けると机上の物体が一つ減る。すべての物体を片付けるともう一方の学習データの物体セットが机上に置かれる。ロボットが行動すると、親役の実験者は物体と動作に対応した言語情報と報酬情報を与えた。この環境では物体を把持し、適切な遊び(「にぎる」または「振る」)を行い、箱に片付けるという行動を繰り返すと最も高い報酬値が得られる。

次に、行動決定と情報取得の詳細について説明する。ロボットは図 3 に示すように行動決定と情報の取得を行う。ロボットの行動決定は物体を把持しているか否かにより、物体選択と動作選択の 2 通りに分かれる。物体を把持していない場合には、物体選択を行う。机上の各物体の物体概念 z_{ID}^O と方策により決定した上位概念 z から求めた $P(z^O|z)$ のコサイン

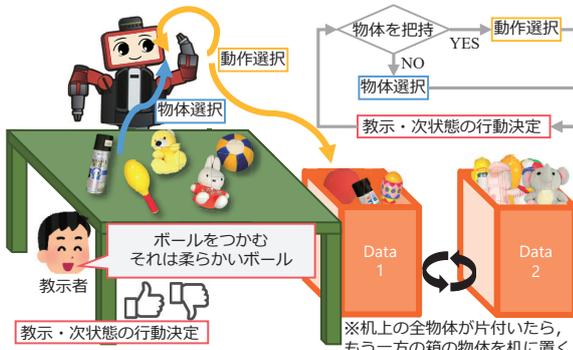


図 3: 親子間インタラクションを模した実験の概要

表 1: 下位概念のカテゴリ分類精度

	物体概念	動作概念	報酬概念
学習データ 1,2	0.81	1.00	1.00
評価データ	0.68	1.00	1.00

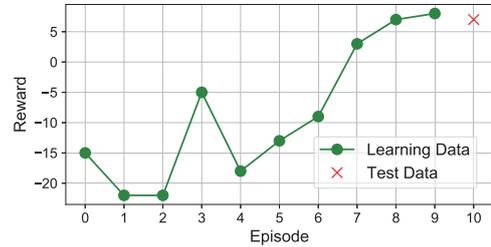


図 4: 各エピソードごとの累積報酬値

類似度を計算する。最もコサイン類似度が高い物体を把持する。ロボットが物体を把持している場合には、動作選択を行う。動作は、方策により求めた上位概念 z から動作情報 w^M を $w^M \sim P(w^M|z) = \sum_{z^M} P(w^M|z^M)P(z^M|z)$ とすることで選択する。ロボットはすでに物体を把持しているため、物体情報 w^O は 1 ステップ前の物体情報 w_{t-1}^O とした。

ロボットが上記の行動選択を行うと、教師者はロボットが行った動作と物体に対応した言語情報と報酬情報を与える。ユーザーは、ロボットがボールを握って正の報酬を得た場合には、「ボールを握るのは良いね、それは柔らかいボールだよ」などのような発話を行った。この発話に対して、音声認識による文章取得と MeCab による形態素解析を行うことで、 w^w を取得する。報酬情報は、教師者が図 2(c) に示す報酬値を直接与えた。これにより w^w, w^R を取得する。上記の行動により、ロボットはマルチモーダル情報 w^O, w^M, w^R, w^w を取得する。取得した観測情報と方策 $\pi_{\theta_{RL}}$ に基づいて、次状態の上位概念 z_{t+1} を求める。これは、式 (1)、式 (2) に基づいて行った。

上記の行動決定から次状態の行動決定までの流れを 1 ステップとして実験を行った。実験は 1 エピソード 50 ステップとし、10 エピソード、計 500 ステップを行った。1 エピソードごとに取得したマルチモーダル情報 w^* を用いて統合認知モデルのパラメータを更新した。これを繰り返すことでロボットは概念・行動・言語を学習する。また、11 エピソード目に評価データを用いて行動選択を行い、モデルの汎化性を検証した。

4. 実験結果

概念形成と行動学習、言語学習についての実験結果を示す。その後モジュールの統合による影響について述べる。行動計画に関する結果は紙面の都合上省略する。

4.1 概念形成と行動学習

まず、概念のカテゴリ分類精度について表 1 に示す。学習データと評価データに対する分類精度を各下位概念ごとに示している。これを見ると入力情報が単純な物体・報酬概念については全て分類が正しい。物体概念は分類誤りが含まれるがチャンスレベルである 0.25 と比較すると高い値となっている。次に行動学習について図 4 に示す。これは各エピソードごとの累積報酬値を示している。この図を見ると、エピソードを得るごとに累積報酬値が上昇していることが分かる。また、評価データに対しても学習データと同様の累積報酬値を得ていることから、汎化性のある行動選択が獲得できたといえる。

表 2: 文章生成における評価値

	文法	物体	動作	報酬
正しい文章数	48	24	43	50
間違えの文章数	2	26	7	0

表 3: 言語情報から実世界情報の予測精度

	物体概念	動作概念	報酬概念
モデル 1	1.00	1.00	1.00
モデル 3	0.83	0.54	1.00

4.2 言語学習

言語理解と文章生成のタスクを行い言語学習の評価を行った。まず、言語理解について示す。文章情報 w^w から w^w が接地した実世界情報 w^O, w^M, w^R を予測するタスクを行い言語理解についての評価を行った。「ぬいぐるみを振るのはいいね」というような文章情報を 24 文用意し、それを入力として w^O, w^M, w^R の予測を行い、文章が指し示す情報の予測できるかを検証した。その結果、24 文章すべての文章に対して w^O, w^M, w^R を正しく予測できた。次に文章生成について示す。これは実世界情報 w^O, w^M, w^R から文章情報 w^w を予測することで行った。評価データ 50 ステップの実世界情報 w^O, w^M, w^R を入力としてその情報を説明するような文章が生成できるかを検証した。各生成した文章に対して、文法的に正しいか、物体・動作・報酬情報それぞれについて正しく説明できているかを評価した。その結果を表 2 に示す。50 文章中ほとんどの文章は物体情報を除いて正しい説明ができています。物体情報に関して正解となる文章の生成数が少なかったのは、物体概念の分類精度が低いことに起因する物体概念に結びついた言語情報の予測性の低さが問題であると考えられる。

4.3 モジュールの統合による影響

モジュールの統合による影響を検証するために 4 種のモデルを比較した。それぞれ、モジュール欠損なし、HMM(Language) が欠損、HMM(Planning) が欠損、HMM(Language) と HMM(Planning) が共に欠損したモデルである。各モデルの学習時の対数尤度の変化について図 5 に示す。これを見ると、下位概念の対数尤度が言語モジュールを含むモデル 1, 2 では上昇していることがわかる。また、各 HMM のモジュールは更新回数が進むことで対数尤度が上昇していることがわかる。

言語理解について予測性を評価するタスクを HMM(Language) が欠損しているモデル 3 についても行う予測性の違いについて検証した。その結果を、表 3 に示す。この結果を見ると前述したようにモデル 1 はすべての文章に対して正しい予測が行えている。モデル 3 では物体、動作について予測精度の低下がみられる。つまり、言語モジュールを統合することで予測性能が向上した。これは、mMDLA に入力される言語情報 w^{w*} が HMM(Language) により正しく重みづけされたため予測性能が向上したと考えられる。

5. 結論

本研究では、概念・行動・言語を学習するための統合認知モデルを複数の確率モデルを統合することで実現した。実ロボットによる実験を行い、マルチモーダル情報を取得することで学習と評価を行い提案モデルの有効性を検証した。結果として、ロボットは自身の経験に基づいて概念・行動・言語を学習した。また、モジュールの統合により言語を含んだ予測タスクの性能が向上することを確認した。今度は、他者を考慮した文章の生成や推論などのより高次な認知活動の実現を目指す。

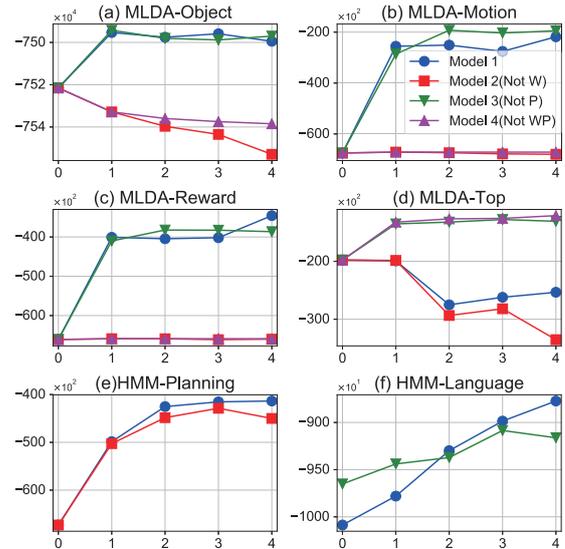


図 5: 各モジュールの対数尤度の変化。横軸はモデル全体の更新回数。縦軸は各モジュールの対数尤度。

謝辞

本研究は JST CREST (JP-MJCR15E3), 新学術領域「認知的インタラクションデザイン学」(26118001) の支援を受けたものです。

参考文献

- [Arandjelovi17] R. Arandjelovi, A. Zisserman, “Look, Listen and Learn,” arXiv 1705.08168, 2017.
- [Attamimi16] M. Attamimi, *et al.*, “Learning Word Meanings and Grammar for Verbalization of Daily Life Activities Using Multilayered Multimodal Latent Dirichlet Allocation and Bayesian Hidden Markov Models,” *Advanced Robotics* 30(11-12), pp.806–824, 2016.
- [Fadlil13] M. Fadlil, *et al.*, “Integrated Concept of Objects and Human Motions Based on Multi-layered Multimodal LDA,” in *proc. of IROS 2013*, pp. 2256–2263, 2013.
- [Gu16] S. Gu, *et al.*, “Deep Reinforcement Learning for Robotic Manipulation,” arXiv 1610.00633, 2016.
- [Hill17] F. Hill, *et al.*, “Understanding Grounded Language Learning Agents,” arXiv 1710.09867, 2017.
- [Levine16] S. Levine, *et al.*, “End-to-End Training of Deep Visuomotor Policies,” *Journal of Machine Learning Research*, Vol.17, pp.1-40, 2016.
- [Miyazawa17] K. Miyazawa, *et al.*, “Integration of Multimodal Categorization and Reinforcement Learning for Robot Decision-Making,” *IROS2017: Workshop on ML-HLCR*, 2017.
- [Nakamura09] T. Nakamura, *et al.*, “Grounding of Word Meanings in Multimodal Concepts Using LDA,” *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3943-3948, 2009.
- [Nakamura18] T. Nakamura, *et al.*, “Serket: An architecture for connecting stochastic models to realize a large-scale cognitive model.” *Frontiers in neurorobotics*, 2018.
- [Taniguchi16] T. Taniguchi, *et al.*, “Symbol Emergence in Robotics: A Survey,” *Advanced Robotics*, Vol.30, 11-12, pp.706-728, 2016.
- [Williams92] R. Williams, “Simple statistical gradient-following algorithms for connectionist reinforcement learning,” *Machine Learning*, Vol. 8, Issue 3, pp. 229-256, 1992.

教師なし学習による物体概念および 言語モデルと音響モデルの同時学習

Simultaneous Learning of Object Concepts, Language Model, and Acoustic Model using Unsupervised Multimodal Learning

村上 太亮*¹ 尾崎 僚*¹ 谷口 彰*¹ 谷口 忠大*¹
Hiroaki Murakami Ryo Ozaki Akira Taniguchi Tadahiro Taniguchi

*¹立命館大学
Ritsumeikan University

Categorization of objects plays an important role in human cognition. It is important for robots to form the object concepts for communication with humans. The purpose is to enable that robots form such object categories and acquire language. We propose the simultaneous learning of the object concepts, the language model, and the acoustic model using by combining Multimodal Latent Dirichlet Allocation (MLDA) with Nonparametric Bayesian Double Articulation Analyzer (NPB-DAA).

1. はじめに

事物のカテゴリ分類は、人間の認知機能において重要な役割を果たしている [Ashby 05]. このようなカテゴリは事前知識なしで形成され、対話などのコミュニケーションを円滑なものにしている. 本稿ではこのように形成される物体のカテゴリを物体概念と捉える. また、概念と単語が結びつくことで、人間は単語の意味を理解することができる [Smith 05]. ロボットもこのように概念の形成と言語の獲得ができることは、人間とロボットのコミュニケーションを円滑にするうえで重要であると考えられる.

教師なし学習を用いた概念獲得に関する研究として、中村らは Multimodal Latent Dirichlet Allocation (MLDA) と Nested Pitman-Yor Language Model (NPYLM) を用いて、物体概念と言語モデルの同時学習を行った [中村 15]. ここで、言語モデルは単語間のつながりを確率的に表現したものである. しかしながら、この研究では事前に学習された音響モデルを用いていた. 対して、発話音声のみから音響モデルと言語モデルを同時に学習する手法として、谷口らは Nonparametric Bayesian Double Articulation Analyzer (NPB-DAA) を提案した [Taniguchi 16].

そこで本研究では MLDA と NPB-DAA を統合することで、言語モデル・音響モデルを事前に与えることなく概念と言語の同時獲得を目指す. 本研究の概要を図 1 に示す. ロボットは物体から取得可能な視覚情報と、その物体の特徴を教示する発話から物体概念と言語モデル・音響モデルの学習を行う. これらの物体概念と、言語モデル・音響モデルは単語列を通して互いに影響を与え、より精度の高い概念や言語を獲得できることが考えられる.

本研究で提案するモデルは MLDA と NPB-DAA を統合しており、各モデルで推定されるパラメータの数も多い. ここで、大規模な構造を持つモデル同士を統合するフレームワークとして、中村らが考案した Symbol Emergence in Robotics Tool KIT (SERKET) がある [Nakamura 18]. SERKET は、プログラムの独立性を保ちながら、その構成単位である基本モデルを階層的に接続することで、大規模な生成モデルとその推論を容易に構築できるようになるフレームワークのことである. SERKET のフレームワークに従って統合モデルを構築することで、それ

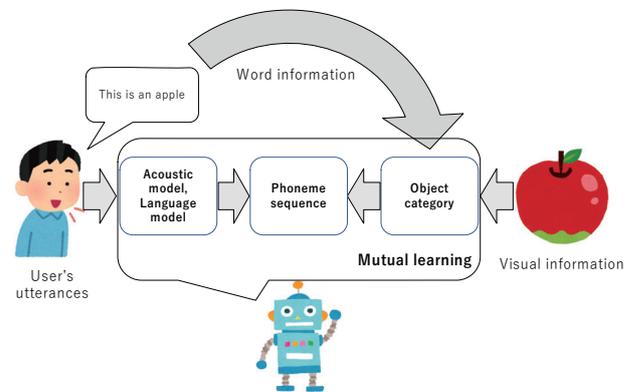


図 1: 物体概念と音響モデル、言語モデルの同時学習イメージ

ぞれの基本モデルにおいて独立に推定したパラメータを利用しても、モデル全体としてのパラメータを最適化することが可能になる.

2. 関連研究

本章では、物体概念獲得と言語モデル・音響モデルの同時学習に関連する各研究の概要について述べる.

2.1 マルチモーダル情報を用いた物体概念の形成

本節では、マルチモーダル情報を用いたカテゴリ分類を行うための手法について述べる. 中村らは、Latent Dirichlet Allocation (LDA) を、複数のモダリティから得られるマルチモーダル情報を用いることができるように、Multimodal Latent Dirichlet Allocation (MLDA) として拡張した. ここで、LDA とは文書中の潜在的なトピックを推定するトピックモデルの一種である. 中村らは、MLDA を使って複数のモダリティを用いて物体のトピックを推定することで、人間の感覚に近いカテゴリの形成が可能になることを示した [Nakamura 09].

2.2 物体概念と言語の統合モデル

中村らは、物体概念とその語意を学習する研究において、MLDA と NPYLM を用いて物体概念と言語モデルを同時学習することで、学習する単語の誤りを少なくした [中村 15]. ここで提案されたモデルは、音声認識と物体概念形成が相互に影

連絡先: 村上 太亮, 立命館大学 情報理工学研究所, 滋賀県草津市野路東 1-1-1, murakami.hiroaki@em.ci.ritsumeikan.ac.jp

響するモデルとなっており、音声認識・単語の接地・概念獲得などが統合されている。しかしながら、音響モデルについては事前に学習されたものを用いていた。詳細は [中村 15] を参考にされたい。

また、中村らの研究に関連して、谷口らはロボットの位置情報と音声認識ラティスを利用することで、場所概念と語彙を同時に獲得する手法である SpCoA++ を提案した [Taniguchi 18]。場所概念とは、ロボットが持つ位置情報や「キッチン」といった空間の名称に紐づけられる場所に関するカテゴリを指す。

2.3 言語モデルと音響モデルの教師なし学習

言語モデルだけでなく音響モデルも教師なし学習によって獲得可能な手法である NPB-DAA について述べる。NPB-DAA は、二重分節構造を持つ時系列データの生成モデルである Hierarchical Dirichlet Process Hidden Language Model (HDP-HLM) とその潜在変数の推定手法として Blocked Gibbs Sampling を組み合わせたものである。詳細は [Taniguchi 16] を参考にされたい。

3. 提案手法

本章では、教師なし学習によるマルチモーダルカテゴリゼーションと言語モデル及び音響モデルの同時学習手法について述べる。本研究は、マルチモーダル情報からカテゴリ分類と言語モデルの獲得を行う中村らのモデル (2.2 節) を拡張し、NPYLM の代わりに NPB-DAA を用いることで、音響モデルについても教師なし学習によって推定することを可能にする。

MLDA と NPB-DAA を用いたカテゴリ分類と言語モデル・音響モデルの同時学習のグラフィカルモデルを図 2 に示す。ここで、上付き文字 w, v は各モダリティを表し、それぞれが言語情報、視覚情報を指す。 $N, S_n, N_{ns}^w, N_n^v, K$ はそれぞれ物体数、 n 番目の物体に対する教示発話の回数、 s 番目の発話に含まれる単語数、 n 番目の物体の画像特徴の出現回数、カテゴリ数を表している。 θ_k^w は、カテゴリ k における言語情報の生起確率を表すパラメータであり、 β^w をハイパーパラメータとするディリクレ事前分布に従う。 θ_k^v は、 θ_k^w をパラメータとする多項分布から発生する画像特徴量であり、 θ_k^w と L をパラメータとする分布から発生する単語列と仮定する。さらに、 z_{nsj}^w, z_{ni}^v は各物体の各特徴を持つトピックを表す。 π_n は各 z_n^* の出現確率を表す多項分布のパラメータであり、 α をハイパーパラメータとするディリクレ事前分布に従う。 y_{ns} は物体に関する教示音声を表し、 l_{ns} は音素列を表す。また、 A は音響モデルを表し、 L は 2-gram 言語モデルを表し、 D は言語モデルの単語辞書を表す。

3.1 学習アルゴリズム

本節では、MLDA と NPB-DAA の統合モデルにおける、パラメータの相補的な推定方法について述べる。以下が、提案する学習アルゴリズムである。ここで、NPB-DAA に関する変数の集合として $\mathcal{H} = \{y, A, D, L\}$ と置く。

1. はじめに、NPB-DAA を用いて各教示発話 y_{ns} を単語列 \mathbf{o}_{ns}^w に分節化し、言語モデルのパラメータ L, D 、音響モデルのパラメータ A をサンプリングする。
2. 以下を一定回数繰り返す。
 - A. トピックを考慮した単語列の確率分布 $P(\mathbf{o}_{ns}^w | \theta^w, z_{ns}^w, \mathcal{H})$ から、単語列をサンプリングする。ここで、 $P(\mathbf{o}_{ns}^w | \theta^w, z_{ns}^w, \mathcal{H})$ を Unigram Rescaling 法 (UR 法) [Gildea 99] を用いて近似的に計算する。UR 法

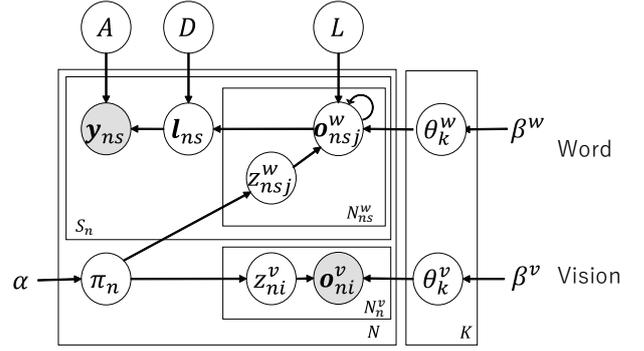


図 2: 物体概念と言語モデル・音響モデルの同時学習のグラフィカルモデル

は、トピック依存の N -gram 確率を下式のように近似的に求める手法である。

$$P(\mathbf{o}_{ns}^w | \theta^w, z_{ns}^w, \mathcal{H}) \approx \frac{P(\mathbf{o}_{ns}^w | \theta^w, z_{ns}^w)}{P(\mathbf{o}_{ns}^w)} P(\mathbf{o}_{ns}^w | \mathcal{H}) \quad (1)$$

ここで、 $P(\mathbf{o}_{ns}^w | \mathcal{H})$ はその組み合わせ種類が非常に大きく、計算困難である。そこで、Sampling Importance Re-sampling (SIR) を導入する。 $P(\mathbf{o}_{ns}^w | \mathcal{H})$ は NPB-DAA から M 個の単語列候補をサンプリングすることで近似される。

$$\mathbf{o}^{w[m]} \sim \text{NPB-DAA}(\mathcal{H}) \quad (2)$$

次に、全単語列候補 $m = 1, \dots, M$ に対して繰り返す。サンプリングで得られた単語列候補 $\mathbf{o}^{w[m]}$ を、Bag-of-Words 表現 $\bar{\mathbf{o}}^{w[m]}$ に変換する。 $\bar{\mathbf{o}}^{w[m]}$ と \mathbf{o}^v を用いて MLDA のパラメータ $\Theta^{[m]} = \{\pi^{[m]}, \theta^{s[m]}\}$ および、 $z^{s[m]}$ をサンプリングする。

$$z^{s[m]}, \Theta^{[m]} \sim \text{MLDA}(\bar{\mathbf{o}}^{w[m]}, \mathbf{o}^v) \quad (3)$$

このとき、各単語列候補の重み $\text{weight}(\mathbf{o}_{ns}^{w[m]})$ は

$$\text{weight}(\mathbf{o}_{ns}^{w[m]}) = \frac{P(\mathbf{o}_{ns}^{w[m]} | \theta^{w[m]}, z_{ns}^{w[m]})}{P(\mathbf{o}_{ns}^{w[m]})} \quad (4)$$

となり、これは UR 法における右辺第一項とみなせる。計算した重みに比例するように、 M 個の単語列から一つ選択する。以上より、NPB-DAA を用いて M 個サンプリングした単語列から、MLDA と NPB-DAA の両方の推定結果を考慮した単語列 $\hat{\mathbf{o}}_{ns}^w$ が下式のようにサンプリングされるとみなせる。

$$\hat{\mathbf{o}}_{ns}^w \sim P(\mathbf{o}_{ns}^w | \theta^w, z_{ns}^w, \mathcal{H}) \quad (5)$$

以上の手順より、 n 番目の物体に与えられた s 個目の教示発話 y_{ns} から、単語列 $\hat{\mathbf{o}}_{ns}^w$ を得る。

- B. 2-A で得られた各単語列 $\hat{\mathbf{o}}_{ns}^w$ を、Bag-of-Words 表現 $\bar{\mathbf{o}}_{ns}^w$ に変換する。 $\bar{\mathbf{o}}^w$ と \mathbf{o}^v を用いて MLDA のパラメータ $\Theta = \{\pi, \theta^s\}$ および、 z^s を更新する。
- C. 2-A で得られた単語列の集合 $\hat{\mathbf{o}}^w$ を用いて、言語モデル・音響モデルの更新を行う。NPB-DAA を用いて言語モデルのパラメータ L, D 、音響モデルのパラメータ A を再度サンプリングする。

以上のアルゴリズムで、MLDAのパラメータ Θ と、言語モデルのパラメータ L , D , 音響モデルのパラメータ A が得られ、これによって推定された物体カテゴリは、教師なし学習によって推定された単語列を用いて形成される。

4. 実験

4.1 実験 1: カテゴリ分類結果の比較

4.1.1 実験目的

本実験では、正解単語列を言語情報として用いた場合と教師なし学習によって推定された単語列を言語情報として用いた場合のカテゴリ分類結果を比較することで、教師なし学習による単語列推定がカテゴリ分類結果に及ぼす影響を調査する。

4.1.2 実験条件

本実験は中村らのデータセット [Nakamura 17]*1 から一部を抜粋し使用する。この際、物体に対する視覚情報のみを使用し、それ以外のモーダル情報については本稿では用いない。また、各物体に対する教示音声として、新たに子音を含む日本語で発話されたデータセットを作成し、これを用いた。この教示音声は、実験に用いる各物体の特徴に関する全 70 文の発話を無音響空間で収録したものである。また、これらの発話は各音素・単語の生起回数や、単語同士の遷移確率においてバランスがとれるように調整している。本実験で用いる音声特徴量は、フレーム幅を 25 [msec], フレームシフト長を 10 [msec] として変換された 12 次元の Mel-Frequency Cepstrum Coefficients (MFCC) 特徴量およびその一次微分と二次微分をそれぞれ Deep Sparse Auto Encoder (DSAE) を用いて、8 次元、5 次元、3 次元と段階的に圧縮したのち結合した、合計 9 次元の特徴量を用いる。ここで、MFCC は人間の聴覚特性を考慮した音響特徴量であり、人間の音高に関する知覚的尺度であるメル尺度を使って変換されている。

また、HDP-HLM の隠れ言語モデルにおけるハイパーパラメータは $\alpha^{LM} = 10.0$ と $\gamma^{LM} = 10.0$ とし、weak-limit 近似の単語上限数を 30 個とした。同様に、隠れ単語モデルにおけるハイパーパラメータは $\alpha^{WM} = 10.0$ と $\gamma^{WM} = 10.0$ とし、weak-limit 近似の音素上限数を 30 個とした。持続時間分布には $\alpha_0 = 200$, $\beta_0 = 10$ のポアソン分布を仮定し、MFCC の出力分布には、事前分布に $\mu_0 = 0$, Σ_0 に単位行列, $\kappa_0 = 0, 01$, $\nu_0 = (\text{dimension} + 2)$ に正規逆ウィシャート分布を持つ多変量ガウス分布を仮定した。さらに、DSAE のパラメータは $\alpha = 0.003$, $\beta = 0.7$, $\eta = 0.5$ とした。MLDA のハイパーパラメータは $\alpha = 1.0$, $\beta = 1.0$ とした。上記の条件において、ギブスサンプリング 50 イテレーションを 1 試行とし、MLDA と提案手法をそれぞれ独立に 10 回試行する。

4.1.3 実験結果

検証実験結果に関しては口頭発表にて報告する。

4.2 実験 2: 音素・単語の推定結果比較

4.2.1 実験目的

本実験では音素と単語の推定結果を、NPB-DAA が推定した単語列をもって推定する場合と、UR 法によって選択された単語列をもって推定する場合と比較し、MLDA との統合が音素と単語の推定結果に及ぼす影響を調査する。

4.2.2 実験条件

実験条件は実験 1 と同様である。ギブスサンプリング 50 イテレーションを 1 試行とし、NPB-DAA と提案手法をそれぞれ独立に 10 回試行する。

4.2.3 実験結果

検証実験結果に関しては口頭発表にて報告する。

5. まとめ

本稿では、物体の画像とその特徴を述べた教示音声から、その物体が所属するカテゴリ及び教示音声の単語列を、教師なし学習によって推定する手法を提案した。また、提案手法は UR 法によって MLDA と NPB-DAA を統合し、その同時学習アルゴリズムを SERKET アーキテクチャの考えに従い SIR を用いて構築した。

参考文献

- [Ashby 05] Ashby, F. G. and Maddox, W. T.: Human category learning, *Annu. Rev. Psychol.*, Vol. 56, pp. 149–178 (2005)
- [Gildea 99] Gildea, D. and Hofmann, T.: Topic-based language models using EM, in *Sixth European Conference on Speech Communication and Technology* (1999)
- [Nakamura 09] Nakamura, T., Nagai, T., and Iwahashi, N.: Grounding of word meanings in multimodal concepts using LDA, in *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3943–3948 IEEE (2009)
- [Nakamura 17] Nakamura, T. and Nagai, T.: Ensemble-of-Concept Models for Unsupervised Formation of Multiple Categories, *IEEE Transactions on Cognitive and Developmental Systems* (2017)
- [Nakamura 18] Nakamura, T., Nagai, T., and Taniguchi, T.: SERKET: An Architecture for Connecting Stochastic Models to Realize a Large-Scale Cognitive Model, *Frontiers in Neuro-robotics*, Vol. 12, No. Jun, pp. 1–16 (2018)
- [Smith 05] Smith, L. and Gasser, M.: The development of embodied cognition: Six lessons from babies, *Artificial life*, Vol. 11, No. 1-2, pp. 13–29 (2005)
- [Taniguchi 16] Taniguchi, T., Nagasaka, S., and Nakashima, R.: Nonparametric bayesian double articulation analyzer for direct language acquisition from continuous speech signals, *IEEE Transactions on Cognitive and Developmental Systems*, Vol. 8, No. 3, pp. 171–185 (2016)
- [Taniguchi 18] Taniguchi, A., Taniguchi, T., and Inamura, T.: Unsupervised spatial lexical acquisition by updating a language model with place clues, *Robotics and Autonomous Systems*, Vol. 99, pp. 166–180 (2018)
- [中村 15] 中村友昭, 長井隆行, 船越孝太郎, 谷口忠大, 岩橋直人, 金子正秀: マルチモーダル LDA と NPYLM を用いたロボットによる物体概念と言語モデルの相互学習, *人工知能学会論文誌*, Vol. 30, No. 3, pp. 498–509 (2015)

*1 <https://sites.google.com/site/nakatomo1018/sd/mod165>

[1M4-J-13] AI application: industries and markets

Chair: Akira Tanimoto Reviewer: Shohei Higashiyama

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room M (Front-right room of 1F Exhibition hall)

[1M4-J-13-01] The local transactional structure based estimation of inter-firm relationships which mediates industrial modulesKohei Kanda¹, Hajime Sasaki², Hiroko Yamano², Ichiro Sakata¹ (1. Dept. of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo, 2. Policy Alternatives Research Institute, The University of Tokyo)

5:20 PM - 5:40 PM

[1M4-J-13-02] Construction of a Strategy Tree in Financial Transaction using Technical IndicatorsOhki Kato¹, Hajime Anada¹ (1. Tokyo City University)

5:40 PM - 6:00 PM

[1M4-J-13-03] Analysis of the Impact of the Rule for Investment Diversification on Investment Performance using a Multi-Agent SimulationIsao Yagi¹, Takanobu Mizuta² (1. Kanagawa Institute of Technology, 2. SPARX Asset Management Co., Ltd.)

6:00 PM - 6:20 PM

[1M4-J-13-04] Dynamic clustering of mutual funds based on the return seriesTohgoroh Matsui¹, Kazuki Yoneda², Koichi Moriyama², Atsuko Mutoh², Nobuhiro Inuzuka² (1. Chubu University, 2. Nagoya Institute of Technology)

6:20 PM - 6:40 PM

産業モジュール媒介性を持つ企業間関係の 局所的取引構造に基づく推定

The local transactional structure based estimation
of inter-firm relationships which mediates industrial modules

神田 公平*¹ 佐々木 一*² 山野 泰子*² 坂田 一郎*¹
Kanda Kohei Sasaki Hajime Yamano Hiroko Sakata Ichiro

*¹東京大学大学院工学系研究科技術経営戦略学専攻

Dept. of Technology Management for Innovation, Graduate School of Engineering, The University of Tokyo

*²東京大学政策ビジョン研究センター

Policy Alternatives Research Institute, The University of Tokyo

Inter-firm relationships formed by business transactions are the resource of companies. Especially, the relationship which enables companies to produce radical and flexible innovation is important in adjusting recent rapidly changing business market. First, we identified relationships mediating industrial modules which give companies nonredundant knowledge and information through structural analysis of large transactional network. Next, we predicted these relationships by machine learning model using the feature quantities designed from the standpoint of local companies in the network. There are three suggestions in our research. First, industries which become the basis of other industries tend to have module mediating relationships. Second, the transactions with companies which have rarer attributes are likely to mediate modules. Third, the transactions between sales-oriented buyer and procurement-oriented supplier have tendency to mediate modules. These estimations are expected to be useful to choose business partners in seeking nonredundant information or opportunities to access to new market.

1. 序論

急速な技術変化や短いプロダクトサイクル、グローバル化により激化する市場環境下では、個々の企業の単独の努力では競争優位性の獲得は困難になりつつある。取引を通じて形成される企業間関係及びそれらの集合により形成されるネットワークは企業における重要なリソースの一つであり、そのリソースを通じて企業は恩恵を受けることができる。市場の変化を受けて、特に弱い紐帯の強み [Granovetter 73] を享受できるネットワーク構造が有効であるとされている。弱い紐帯の強みとは、連結としては弱いが広域的なネットワークを持つ個人や組織は全く新たに異なる情報収集に強みを持つことができるといふ強みである。日本企業は、閉じた関わりを越え外部の広域的なネットワークに存在する企業と連携することで市場の変化にいち早く対応するラジカルなイノベーションを生み出す体制は不十分であるという [若林 06, Todo 16]。

本来紐帯の強弱はその紐帯が埋め込まれるネットワーク内の構造により相対的に決まる性質であり、グローバルなネットワークを俯瞰した上で判断される性質である。企業レベルでの意思決定の局面においては、ネットワーク全体においてその企業が局所的に持ちうる情報から自身の取引の紐帯の強さを推定することが必要となる。本研究では、変化する市場環境に適応する弱い紐帯のネットワークが重要という観点に基づいた上で、弱い紐帯の特性を持つ産業モジュールを媒介する取引関係を企業の視点から推定することを目的とする。

2. 手法

本研究の分析手法は、大きく三つの部分から成る。まず企業をノード、取引関係をリンクとする取引ネットワークを構築する。次に得られたネットワークをクラスタリングし強い紐帯で結びつく企業群を産業モジュールとして定義し、弱い紐帯としてモジュール間を結ぶリンクを特定する。最後に、企業の視点を踏まえてのノードペアの特徴量およびリンクの特徴量を設計

し、上記で特定したリンクをモデルから予測し、モデルにおける特徴量の重みから評価を行う。

2.1 取引ネットワークの作成

本研究において、分析対象となる取引ネットワークの構築にあたっては、日本における大手信用調査会社である株式会社東京商工リサーチ (以下、TSR と略記) により作成された 2016 年における TSR 企業情報ファイルと TSR 企業関係ファイルを用いた。企業情報ファイル内には、固有に付与された ID を持つ各企業の財務データや従業員数を始めとする企業の基本的な情報が記載されており、企業関係ファイル内には、上記の ID に対応した企業 2 社間の仕入取引、販売取引、資本関係の情報が記載されている。

本研究では、この企業関係ファイル内のデータに基づいて各企業をノード、取引関係をリンク (本研究において資本関係の情報は扱わない) として有向ネットワークを構築する。取引関係における財・サービスの流れを、リンクの向きとして定義する。分析対象は、2016 年の中部地方を中心とする取引ネットワークである。ここで構築されるネットワークは、中部地方の県に本社を構える企業のノードを含む取引関係のリンクから構築されるネットワークを構成要素としている。

2.2 取引ネットワークのモジュール分割とモジュール間取引の特定

構築したネットワークを Louvain 法によるモジュラリティ最大化でクラスタリング [Blondel 08] することによって得られたクラスタを産業モジュールとし、弱い紐帯に相当するモジュール間取引を定義する。ネットワークのクラスタリングは、そのネットワークの構造上にて部分的に密なリンク構造を持つノードの集合を抽出することができ、クラスタリングを行うことで凝集的な取引関係が埋め込まれた部分ネットワークごとの単位にネットワークを分割できる。序論で述べた紐帯の強弱の概念に基づけば、密な部分ネットワーク内の紐帯は強い紐帯、密な部分ネットワークを結合する紐帯は弱い紐帯と捉え

ることができ、クラスタリングに基づくこのような紐帯の分類はソーシャルメディアのネットワーク分析でも用いられている [Sanz-Cruzado 18].

凝集的なネットワーク内の紐帯として議論されてきた強い紐帯は産業モジュール内部の取引関係として、冗長性のない広域的なネットワークへアクセスする紐帯として議論されてきた弱い紐帯は産業モジュール間にまたがる取引関係と読み替えることができる。

本研究においては、産業モジュール間の媒介作用を持つ取引関係については、以下の二つの視点から定義し議論を行うものとする。

1. 一次クラスタリングによって得られた産業モジュール間を結ぶ取引関係
2. 一次クラスタリングにより得られた個々の産業モジュール内にてさらにクラスタリングを行い得られたサブモジュール間を結ぶ取引関係

2.3 モジュール間取引の予測モデル

上記のクラスタリングにより得られた産業モジュール間を結ぶ橋渡しとなる取引関係を正例、それ以外のモジュール内に存在する取引関係を負例として定義し、各取引に紐づく特徴量を用いて産業モジュール間取引の予測器を作成する。予測においては、特徴量の寄与によって正例と負例の差異を明確に議論するべく、正例と負例の比が 1:1 となるように取引関係のランダムサンプリングを行い、訓練データとして全体の 70% を用い、テストデータとして残りの 30% を用いるものとする。予測に用いる分類器モデルとしてロジスティック回帰とサポートベクターマシン (以下, SVM) を用いる。これは、類似のデータセットにおいて取引先推薦を試みた先行研究 [Mori 12] でこれらの手法の有効性が確認されており、本研究への適用可能性が期待されるからである。尚、これらのモデルにおける特徴量の重みの評価を行うにあたっては、決定係数に基づく各特徴量の分散拡大要因 [Hair 14] を計算し、得られた重みの値が妥当であることを検証している。

産業モジュール間取引の予測モデルにおける特徴量の設計では、局所的な企業の視点に限定するという観点を踏まえ、取引関係のリンクが存在する 2 ノードと、それら 2 ノードの隣接ノードから構成されるサブネットワークに限定する (図 1)。

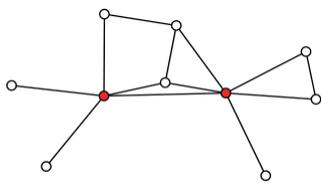


図 1: 特徴量定義に用いることのできるサブネットワーク。中心の 2 ノードと隣接ノードからなるサブネットワーク

本研究では、全 49 個の特徴量を用いて予測を行った。ネットワークのクラスタリングはネットワーク全体の構造を考慮した末に導かれるメゾスケールな視点から導き出されるネットワーク量であり [Kajikawa 12], そのためそこから定義される産業モジュール間取引はメゾスケールな量である。このメゾスケールな量を、個々の企業が持ちうる情報という点から制約をかけた特徴量で推定することが本研究の目的である。ここでは、主要な特徴量を 2 つ説明する。

一つ目は、Burt の制約指標 [Burt 92] を、本研究に合わせ再定義した特徴量である。Burt は、ネットワーク内のあるノードにおける構造的空隙を評価する際に、制約指標を導入した。これによると、ノード u の制約指標は、

$$C_u = \sum_v C_{uv} = \sum_v (p_{uv} + \sum_{w \neq u, w \neq v} p_{uw} p_{vw})^2 \quad (1)$$

であり、 p_{uv} はネットワーク内におけるノード u のすべての関わりのうち、ノード v に対する関わりが占める割合を示しており、

$$p_{uv} = \frac{z_{uv}}{\sum_w z_{uw}} \quad (2)$$

によって表される。ここで、 z_{uv} はリンク (u, v) の結びつきの強さである。今回の、取引ネットワークの定義においては、リンクに重みの情報はなため、 $p_{uv} = 1/k_u$ と定義する。これは、ノード u の他のノードへの関わりは均一であると仮定したものである。Burt の定義のように、式 (1) の和をとったノードの値としてではなく、特徴量として着目する取引関係 (u, v) に対し、 C_{uv} と C_{vu} の値を用いる。この指標は、個々のノードの次数が低くなるほど (関わる相手が固定的になるほど)、低くなる指標であり、また、共通の取引先の存在が増えることによってもその間接的な制約が伝播するとして制約が増大するように設計された指標である。

二つ目は、仕入先業種 (または都道府県) 相対割合および販売先業種 (または都道府県) 相対割合である。産業モジュール間をつなぐ役割を持つ取引関係は、一般的な取引関係と比べて希少な存在であることが期待される。ここでは、その希少さの度合いを割合によって表し、反映した特徴量を独自に設計する。仕入取引や販売取引における企業の業種ペア (あるいは都道府県のペア) の組み合わせが、その取引を行う企業の取引の総数の中でどの程度の割合を占めているかを示す指標であり、例として、企業 u の仕入先業種 l に対する相対割合 R_{ul} は、

$$R_{ul} = \frac{\text{企業 } u \text{ の業種 } l \text{ に対する仕入取引数}}{\text{企業 } u \text{ の仕入先総業種数}} \quad (3)$$

により定義される。同様の定義を、販売先業種、および仕入先都道府県、販売先都道府県について用い、特徴量とする。業種については、TSR 業種コードの業種中分類と業種細分類についてそれぞれ特徴量を計算する。

3. 結果

3.1 取引ネットワークの作成

2.1 にて述べた手法に従い 2016 年度のデータから中部地方における企業間取引ネットワークを構築した。その結果、構築されたネットワークにおける企業数と取引数を表 1 に示す。約 38 万企業、120 万取引からなるネットワークが構築された。

表 1: 中部地方取引ネットワークの概要

項目	データ数
企業数	383682
域内企業	199164
域外企業	150365
所属地域不明の企業	34153
取引数	1206671
域内企業間取引	628493
域外企業を含む企業間取引	504205
所属地域不明企業を含む企業間取引	73973

3.2 取引ネットワークのモジュール分割とモジュール間取引の特定

本研究では、この主要モジュールをさらにクラスタリングし、弱い紐帯の特性を持つ産業モジュール間取引を特定した。今回の定義のもとでは、387333 取引が正例、682844 取引が負例となった。約 36.2%の取引が弱い紐帯の特性を持つ企業間関係に相当すると言える。これは平均値であり、業種によっても弱い紐帯の持ちやすさは異なる。図 3 に取引数が 2000 以上存在した各業種の仕入取引に占める産業モジュール間仕入取引の割合が上位 20 であった業種を示す。傾向として、機械器具や工業系素材の製造に関する業種が上位にあり、36.2%よりも高い割合を示している。この傾向は、モジュール間販売取引に関しても見られ、この結果から、機械器具や工業系素材など、産業の基盤を担う業種は弱い紐帯を備えやすいことが言える。

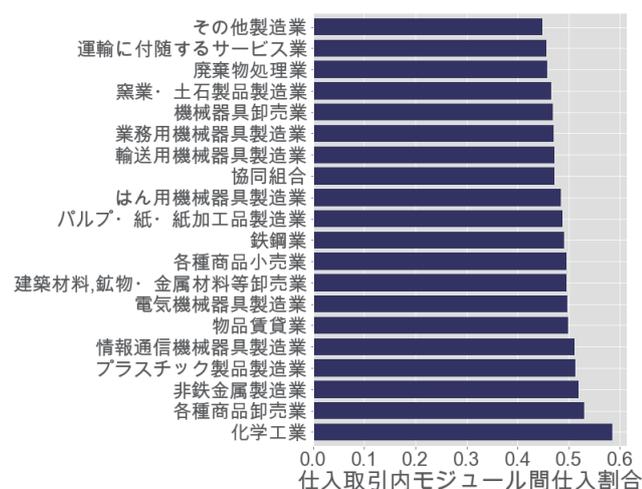


図 2: 業種毎モジュール間販売取引割合上位 20 業種

3.3 産業モジュール間取引の予測モデルによる予測

表 2 にロジスティック回帰、SVM に基づく予測モデルのモジュール間取引の精度を示す。ここでの予測は、3.2 で得られた 387333 取引の正例のうち、欠損の無いデータである 246353 取引について行っている。本来ネットワーク全体を俯瞰しなければわからないモジュール間取引を、局所的な取引構造に基づく特徴量からであっても、f 値 0.744 程度で予測ができていたことがわかる。いずれのモデルも似通った精度ではあるが、特徴量の重みは若干異なっていることが観察された。このことは、似通った精度であっても、この精度を実現する分類の実態は両者異なる可能性があることを示す。以降の考察では、両者の予測器に共通で見られた寄与の高い特徴量の特性を中心に弱い紐帯が備える特性を企業の視点から議論する。

表 2: 予測モデルの精度の評価

	ロジスティック回帰	SVM
accuracy	0.738	0.737
precision	0.726	0.724
recall	0.763	0.766
f 値	0.744	0.744

4. 考察

4.1 得られた結果を通して

産業モジュール間を媒介する取引を持ちやすい業種の傾向として、工業的素材系、機械器具系製造を中心とする製造業および卸売業が見られた。これらの業種は産業の基盤に関わる業種という特徴を持つと言える。この系統の業種が、弱い紐帯の特性を持つ取引関係を持ちやすいことの解釈としては、その業種特性として、様々な属性や形態を持つ企業と関わることのできるためと考えられる。産業における基盤的な役割を發揮し、産業における上流工程に位置するこれらの企業は、様々な属性の企業と関わるができるという点において、ネットワークの構造的には、様々な属性の企業とのやりとりを通じた冗長性のない情報が集積しやすい位置に存在しており、弱い紐帯の強みを發揮しやすい環境にあると言える。企業活動においてこれらの業種との関わりを見直すことは、冗長性のない情報の獲得において優位に立てる可能性があると言える。

次に特徴量の重みからの解釈について説明する。

まず、今回のモデルにおいては、Burt の制約指標の特徴量の寄与が負でかつその絶対値が全ての特徴量の中で最大となる結果であった。この特徴量の寄与が高いことは、取引先の絶対数が多い企業の持つ取引はモジュール間取引となりやすく、また、それらの企業が持つ取引関係のうちでも、共通の取引先が存在しない企業との取引が弱い紐帯を形成しやすいことを示している。このような取引は、産業の基盤を担うような業種の取引にも反映されていると解釈できる。機械器具系や素材系のような、産業の基盤を担う商材を扱う業種に関しては、その取引先が多岐に渡ることになる。それらの多岐に渡る多様な取引先の間には、業種の性質の隔たりが存在し、相互な取引関係は発生しにくくなるものと考えられる。

次に、仕入先（販売先）都道府県相対割合や仕入先（販売先）業種相対割合の特徴量の重みは負となったことについて説明する。これはより希少な業種や希少な地域の企業との取引がモジュール間を媒介する取引となりやすいことを示していると言える。業種については、業種細分類よりも業種中分類で定義された特徴量の方が重みの絶対値が大きくなる傾向がある。これは、類似した業種の中での希少さではなく、より大きな視点からの性質の異なる業種の中での希少さが重要であり、属性の希少さが弱い紐帯の特定に際して重要な要因であるという主張を強める結果となっている。

最後に、販売側企業の出次数密度が負、仕入側企業の出次数密度は正の重みを持っている傾向が見られたことについて説明する。販売側企業の出次数密度の重みが負であることは、販売側企業の入次数が出次数に対して高くなっており仕入志向の企業であること、仕入側企業の出次数密度の重みが正であることは、仕入側企業の出次数が入次数に対して高くなっており販売志向であることを示す。このことは、仕入志向のサプライヤーの販売する商材を仕入れる販売志向のバイヤーは、異なる産業モジュールに属す可能性が高まることを示している。実際のデータ内において産業モジュール間を媒介する仕入志向のサプライヤーと販売志向のバイヤーのペアが見られた代表的な例として、自動車の完成車メーカーとその販売を担うディーラーの取引関係が挙げられる。これらは、同じ企業グループに属しながらも、製造と販売という役割を分担して、異なる企業形態を取って一連の業務を遂行している。直観的には、同じ企業系列に属すグループは同一の産業モジュールに属すと期待されるが、これらは、ネットワークの構造的には異なるモジュールに属しやすい傾向があると言える。ネットワーク構造が知識の拡

散において機能するとする [Todo 16] ならば, 同じ企業グループ内の関係であるから冗長性の低い情報が循環していると判断するのは早計である可能性があることが示されたと言える。

4.2 専門家の評価

本研究の実験結果及び考察を, 2019年1月10日に経済産業省地域経済産業グループ地域活性化企画官(地域未来投資担当)兼地域未来投資促進チームを中心とする経済産業省職員5名に対し発表を行った。そして, 政策立案者という観点からみた本研究の有用性について評価を受けた。発表を通じて, 本研究の想定する大局的な取引ネットワーク内における企業の局所的な視点からの弱い紐帯の特定は非常に現実の経営環境に即した点において評価できるとの評価を受けた。現実の企業は, 本研究で扱うようなデータを入手することも利用することも困難な状況が多い。限られたリソースで意思決定を行わなければならない実際の企業環境を想定した局所的な視点は, 本研究のように大量のデータ分析が可能となる状況においては通常大局的な情報にのみ注力しがちになることで失われやすい視点であるという。その視点を失うことなく, 直感にも沿う納得感のある結果が出ていることが本研究の評価すべき点であるという評価を得た。また, 本研究の今後の発展について, 中部地方を超えたより広い範囲のネットワークの影響による外部性を考慮することでより普遍的な結果が得られるのではないかという指摘を得た。中部地方の取引ネットワークは製造業が主体となっており, 今回得られた機械器具系の及び工業的素材関連の業種が産業モジュール間取引を担いやすいと言う結果は製造業に偏った地域であるがゆえであるという可能性がある。ここにおいて, 他の業種が顕著な地域においては通用しない可能性があるとの指摘を得た。さらに地域間の取引ネットワーク構造の差が存在するとすれば, それらを見ることもより議論を進展させる上で重要な知見となる可能性があるということであった。

5. 結論

変化の激しい市場環境においては, 冗長性のない情報獲得を可能にし, 市場の変化への素早い対応を可能にする弱い紐帯の強みは重要である。相対的に決まるネットワークの紐帯の強弱は本来グローバルな視点からネットワークを俯瞰しなければ判断できない。企業がこれらの紐帯の強弱に関する情報を活用し競争優位性を得ていくには, 限られた局所的な視点からの情報だけで上で自身の持つ取引関係の紐帯の強弱を推定することが重要である。本研究においては, 議論が不足している個別の企業の取引関係という視点から予測モデルを構築, 推定しその特性を議論した。産業モジュールを媒介する企業間関係について大きく三つの示唆が得られた。一つ目は, 産業の基盤を担う業種の取引はモジュールを媒介する可能性が高いこと, 二つ目は, 地域や業種といった, より希少な属性を持つ相手との取引関係は産業モジュールを媒介しやすいこと, 三つ目は仕入志向のサプライヤーと販売志向のバイヤーの取引関係は産業モジュールを媒介しやすいことである。これらの特性が得られたことは, 冗長性の少ない情報の獲得や新しい市場へのアクセスを期待した取引先や買収先, 共同開発先などの選定に有用であると期待される。

本研究の今後の展望として, 二つの方向性が考えられる。一つは, 別次元のデータを用いての拡張である。企業の特許の共著関係や引用関係に関するデータなどを, 本研究での取引データと合わせて考えることで, 新たな企業属性の定義などが可能になるであろう。もう一つは, 本研究で用いた分析手法の精緻化である。本研究では, ネットワークのクラスタリングに基づ

き凝集的な取引関係内の企業の集合を産業モジュールと定義, それらを媒介する取引関係を弱い紐帯の性質を持つ取引関係であるとして分析を進めた。実際には, 紐帯の強さは連続的に変化する値である。紐帯の強さをより定量的に反映した指標による議論が必要である。さらには, 今回の取引関係のネットワークには, 取引関係の有無だけでリンクを定義しており, Granovetter[Granovetter 73]やBurt[Burt 92]のようにリンクの重みに関しては議論ができていない。実際の取引関係には取引額や取引頻度, 取引の重要度などの要素が存在し, それらを予測に合わせて利用することは, 厳密な意味での弱い紐帯を特定するにあたっては重要な議論である。

謝辞

本研究は, (株)東京商工リサーチが保有する企業情報データと企業相関データを用い実施した。ここに, 感謝の意を表する。

参考文献

- [Granovetter 73] Granovetter, M. S.: The strength of weak ties. *American Journal of Sociology*, vol. 78, no. 6, pp. 1360-1380, (1973).
- [若林 06] 若林直樹: 日本企業のネットワークと信頼企業間関係の新しい経済社会学的分析, 有斐閣, (2006).
- [Todo 16] Todo, Y., Matous, P., and Inoue, H.: The strength of long ties and the weakness of strong ties: Knowledge diffusion through supply chain networks. *Research Policy*, vol. 45, pp. 1890-1906, (2016).
- [Blondel 08] Blondel, V. D., Guillaume, J. -L., Lambiotte R., and Lefebvre, E.: Fast unfolding of communities in large networks. *J. Stat. Mech.*, P10008, (2008).
- [Sanz-Cruzado 18] Sanz-Cruzado, J., and Castells, P.: Enhancing structural diversity in social networks by recommending weak ties. In *Proceedings of the 12th ACM Conference on Recommender Systems (RecSys '18)*, pp. 233-241, (2018).
- [Mori 12] Mori, J., Kajikawa, Y., Kashima, H., and Sakata I.: Machine learning approach for finding business partners and building reciprocal relationships. *Expert Syst. Appl.*, vol. 39, no. 12, pp. 10402-10407, (2012).
- [Hair 14] Hair Jr., J. F., Black, W. C., Babin, B. J., and Anderson, R. E.: *Multivariate Data Analysis (7th ed.)*, Pearson, (2014).
- [Kajikawa 12] Kajikawa, Y., Takeda, Y., I. Sakata, and Matsushima, K.: Multiscale analysis of interfirm networks in regional clusters. *Technovation*, vol. 30, pp. 168-180, (2012).
- [Burt 92] Burt, R. S.: *Structural holes: The Structure of Competition.*, Harvard University Press, (1992).

テクニカル指標による金融取引の戦略木構築

Construction of a Strategy Tree in Financial Transaction using Technical Indicators

加藤 旺樹^{*1}
Ohki Kato

穴田 一^{*1}
Hajime Anada

^{*1} 東京都市大学大学院 総合理工学研究科
Graduate School of Integrative Science and Engineering, Tokyo City University #1

In recent years, many researchers have studied stock trading using technical analysis. However, it is necessary to have deep knowledge to use such technical analysis and it is difficult to make a profit using such techniques. Therefore, we construct an evolutionary model to create a profitable investment strategy using technical indicators. We confirmed the effectiveness of our model using historical data of the stock market.

1. はじめに

近年、テクニカル分析を用いた株式売買に関する研究が多く行われている。テクニカル分析を用いた投資では、相場のトレンドや転換点を判断するテクニカル指標を用いることで、過去の値動きのパターンから将来の値動きを予測し売買を行う。しかし、そのためには専門的な知識を必要とする上、利益を上げにくいという問題がある。

松村らは、テクニカル指標を用いた投資戦略を木構造で戦略木として表現した。そして、それぞれの個体が戦略木を持ち、その戦略木に従い株式売買を行うモデルを構築した[松村 06][松村 08]。戦略木を個体の遺伝子として遺伝的操作を用いることで、より利益が高くなるように個体を進化させ、各個体が持つ戦略木の特徴を分析した。ところが、その戦略木は上昇トレンドのみでしか稼ぐことが出来ないものとなっていた。

そこで本研究では、松村らの研究で用いられた戦略木を用いて、テクニカル指標を用いたより利益を生み出す投資戦略の構築を目的とする。

2. 提案手法

それぞれの個体が戦略木を持ち、その戦略木にしたがって取引を行う。その取引結果から個体を評価した値である適応度を求め、戦略木を個体の遺伝子として遺伝的操作を用いることでより適応度が高くなるように個体を進化させていく。

2.1 テクニカル指標

テクニカル指標は株式の売買タイミングを判断するために使われる指標で、トレンド系、オシレータ系、出来高系の 3 つがある。トレンド系は株価の推移からトレンドを判断する指標、オシレータ系は株価の推移からトレンドの転換点を判断する指標、出来高系は売買が成立した株数の推移からトレンドの転換点を判断する指標である[藤本 04][吉見 03][山中 15]。

2.2 戦略木

戦略木は、複数の非終端ノードと終端ノードからツリー状に構成される。図 1 に戦略木の例を示す。それぞれの数字がテクニカル指標や売買行動を表し、各ノードから 1 番上のノードまでのノード間を結ぶ枝の数を各ノードの深さとする。

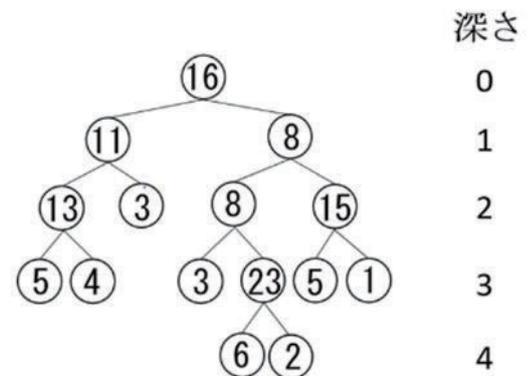


図 1 戦略木の例

各個体は戦略木を持ち、戦略木に従って当日の行動を決定する。一番上のノードからテクニカル指標に基づく判定処理により、左右どちらのノードを実行するのか決定していくことを繰り返し、到達した終端ノードの行動を実行する。判定に使用するデータは、各指標に必要な日数分の始値、高値、安値、終値、出来高の日足データである。

非終端ノードでは、テクニカル指標に基づく判定処理によって左右どちらかのノードを実行する。終端ノードでは、株式の売買行動を実行する。使用するノードは松村らの研究に用いられたノードに加え、ある程度まとめて株式を売買することが出来るようにするため終端ノードに「初期資産の 10%を使い株式を購入」という 6 番のノードと「所有株式の 10%を売却」という 7 番のノードを追加する。表 1 に終端ノードと非終端ノードを示す。

使用しているテクニカル指標を以下に示す。

・STC-slow, STC-fast (ストキャスティクス値)

一定期間の株価の最高値と最安値から株価の転換点を判断するオシレータ系の指標

・RSI

一定期間の株価の値上がり幅と値下がり幅から株価の転換点を判断するオシレータ系の指標

・%R

一定期間の株価の最高値と最安値から株価の転換点を判断するオシレータ系の指標

・VR1, VR2, WVR (ボリュームレシオ)

出来高の推移から株価の転換点を判断する出来高系の指標

表 1 終端ノードと非終端ノード

種類	番号	内容
終端ノード	1	1株購入, 資金がないときは待機
	2	1株売却, 株式がないときは待機
	3	待機
	4	所有している株式をすべて売却
	5	資金が許す限り株式を購入
	6	初期資産の10%を使い株式を購入
	7	所有株式の10%を売却
非終端ノード	8	前日の終値が前々日の終値より高ければ左のノードを実行, それ以外であれば右のノードを実行
	9	前日の出来高が前々日の出来高より高ければ左のノードを実行, それ以外であれば右のノードを実行
	10	前々日 STC-slow < STC-fast, 前日 STC-slow > STC-fast ならば左のノードを実行, それ以外であれば右のノードを実行
	11	前々日 STC-slow > STC-fast, 前日 STC-slow < STC-fast ならば左のノードを実行, それ以外であれば右のノードを実行
	12	%R を用いて0が連続して3回出た後に前日の値が20以上ならば左のノードを実行, それ以外であれば右のノードを実行
	13	%R を用いて100が連続して3回出た後に前日の値が80以上ならば左のノードを実行, それ以外であれば右のノードを実行
	14	短期移動平均と前日の終値の間に+10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	15	RSI > 70% ならば左のノードを実行, それ以外であれば右のノードを実行
	16	RSI < 30% ならば左のノードを実行, それ以外であれば右のノードを実行
	17	短期移動平均と前日の終値の間に+10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	18	短期移動平均と前日の終値の間に-10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	19	長期移動平均と前日の終値の間に+10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	20	長期移動平均と前日の終値の間に-10%以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	21	ゴールデンクロスであれば左のノードを実行, それ以外であれば右のノードを実行
	22	デッドクロスであれば左のノードを実行, それ以外であれば右のノードを実行
	23	短期移動平均との間に+2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	24	短期移動平均との間に-2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	25	長期移動平均との間に+2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	26	長期移動平均との間に-2σ以上の乖離があれば左のノードを実行, それ以外であれば右のノードを実行
	27	VR1 ≤ 70% ならば左のノードを実行, それ以外であれば右のノードを実行
	28	VR1 ≥ 45% ならば左のノードを実行, それ以外であれば右のノードを実行
	29	VR2 ≤ 30% ならば左のノードを実行, それ以外であれば右のノードを実行
	30	VR2 ≥ 70% ならば左のノードを実行, それ以外であれば右のノードを実行
	31	WVR ≤ 40% ならば左のノードを実行, それ以外であれば右のノードを実行
	31	WVR ≥ 40% ならば左のノードを実行, それ以外であれば右のノードを実行

2.3 遺伝子操作

戦略木を個体の遺伝子として, 交叉や突然変異, 淘汰の操作でより高い利益を生み出す個体を作り出していく。

2.3.1 初期個体生成

表1のノードの中から無作為に1つを選択する。そのノードが終端ノードであれば, 戦略木の生成を終了する。非終端ノードであれば, その非終端ノードの左右にノードを無作為に選択して付け加える。この作業を, 全ての非終端ノードの左右に終端ノードが付け加えられるまで繰り返す。初期個体の生成は, 初めからノード数の多い木になることを防ぐため, 深さ4には終端ノードを付け加える。初期個体は N 個体生成する。

2.3.2 評価

個体の適応度は利益の幾何平均とする。複数の期間でそれぞれ取引を行った時の利益の幾何平均を適応度とすることで, どの期間でも利益を上げている個体の適応度が高くなるようにする。さらに, 学習データを銘柄ごとに短く分割することでトレンド等の時系列の特徴を出やすくした状態で学習を行う。期間をより細かく分割し, 分割したそれぞれの期間で取引させた時の利益の幾何平均を適応度とすることで, 多くの変動パターンを学習出来ると考えたからである。しかし, 利益は負になることがあり, その場合適応度を求めることができない。そこで, 利益が負の場合, 取引の中で最も小さい利益の絶対値を全ての利益に足すことで補正する。

2.3.3 ノード削除

戦略木によって行動を決定する際に同じ数字のノードを2回目以降実行する場合, そのノードでは左右どちらのノードを実

行するのか決まっているため, 絶対に到達できないノードが生まれてしまう。例えば, 図1では, 深さ1と深さ2に8番のノードがある。深さ1にある8番で左のノードを実行する場合, 深さ2の8番も左のノードを実行することになり, その逆側の深さ3の23番のノード以下には到達できない。これらのノードは売買行動に関係なく適応度に影響を与えないが, ノード数を制限していないためこのようなノードが際限なく増えていく。これでは交叉時, 適応度に影響を与える部分が選ばれにくくなり, 進化が停滞しやすく効率的な学習が妨げられる。そこで, 戦略木がある程度大きくなってから必要ない部分を削除するために, 101世代以降では毎世代評価で使われなかったノードの削除を行う。ノードの削除を101世代以降で行うのは, 初期世代から行うと戦略木が大きくなりすぎてしまうからである。

2.3.4 交叉

現世代の全個体から適応度を用いたルーレット選択により親となる2個体を選択する。それぞれの個体から無作為に1つずつノードを選び, そのノード以下の部分木を交換することで子を2個体作り出す。これらの操作を繰り返すことで N 個体を作り出す。

2.3.5 突然変異

現世代の N 個体と交叉によって出来た N 個体について適応度の順位に基づいて突然変異を施すか決定する。個体 i の突然変異が起きる確率 P_i は次式で定義される。

$$P_i = (\text{Rank}_i - 1) \times 0.1 \quad (\%) \quad (1)$$

ここで, Rank_i は個体 i の適応度の順位である。これにより, 順位の高い個体は突然変異する確率が低くなる。突然変異を施す場合, 個体を構成する各ノードが突然変異率 p (%) に基づき

終端ノードなら他の終端ノード、非終端ノードなら他の非終端ノードに無作為に変化させる。これらの個体を次世代に残す。

2.3.6 次世代に残す個体の選択

次世代に残す個体を現世代の N 個体と、交叉と突然変異によってできた N 個体から適応度の順位を用いたルーレット選択によって選び出す。こうすることで、個体の多様性を保ちつつ順位の高い個体を次世代に残りやすくする。

2.3.7 シミュレーションの流れ

個体を N 個体用意する。個体はそれぞれ戦略木と現金残高、保有株式数の情報を持ち、1日1回売買行動する。各個体は独立して、戦略木に従い定めた期間、複数銘柄でそれぞれ取引を行う。取引は過去のデータを用いて実市場と同じ値動きを再現した市場で行い、株式の注文は注文を出した日の終値で成立させる。提案手法は以下の流れで行う。

- I)初期個体生成
 - II)初期個体の評価
 - III)交叉
 - IV)交叉によって出来た個体の評価
 - V)交叉によって出来た個体の使われないノード削除
 - VI)突然変異
 - VII)突然変異した個体の評価
 - VIII)突然変異した個体の使われないノード削除
 - IX)次世代に残す個体の選択
- III) ~ IX)を、決められた世代数まで繰り返す。

3. 結果

本研究では、取引銘柄は東京証券取引所 1 部に上場している銘柄とし、様々な変動を学習させるために 10 業種から、出来高が多く長い期間データを取ることが出来る銘柄を 1 つずつ選び出した表 2 の 10 銘柄である。

表 2 取引銘柄

業種	銘柄
製造業	キヤノン
水産・農林業	極洋
鉱業	日鉄鉱業
建設業	積水ハウス
金融保険業	野村ホールディングス
不動産業	三井不動産
運輸・情報通信業	KDDI
電気・ガス業	大阪ガス
サービス業	セコム
商業	イオン

個体数 $N=100$ 、世代数 5000、試行回数 50、 $p=0.5$ (%)とし、学習期間は 2000 年から 2005 年とした。学習期間の分割の刻みは、2 年、1 年、6 ヶ月の 3 つである。分割した期間においてそれぞれ元金 10 万円とし全銘柄で取引を行う。2 年刻みであれば、1 銘柄につき 6 年間の学習期間を 2000 年 1 月～2001 年 12 月、2002 年 1 月～2003 年 12 月、2004 年 1 月～2005 年 12 月の 3 期間に分け、10 銘柄分 30 パターンの株価変動で取引を行う。テスト期間は 2006 年から 2016 年とし 1 年ごとにテストを行った。

図 2 にその世代で適応度が最も高い個体の 1 年間に換算した学習期間での平均利益を示す。学習期間には様々な変動が存在するが、上昇トレンドが多い期間となっている。この図は、

50 試行を平均したものであり、縦軸は平均利益(万円)、横軸は世代数を表し、黒線は既存手法の平均利益、オレンジ線は 2 年刻みによる提案手法の平均利益、青線は 1 年刻みによる提案手法の平均利益、緑線は 6 ヶ月刻みによる提案手法の平均利益を表す。

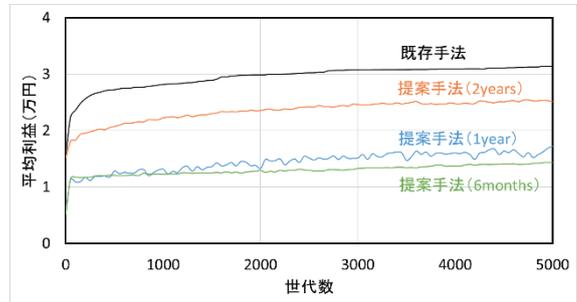


図 2 最良個体の平均利益の世代推移 (2009 年)

学習期間において既存手法が最も利益を上げることが出来ている。これは既存手法では稼ぎやすい上昇トレンドのみで利益を上げるように進化しており、提案手法では様々なパターンの変動で利益を上げようと進化しているため上昇しているところで十分に稼ぐことが出来ていないためである。短く分割し学習を行ったものほど利益を上げることが出来ていないのは、より多くのパターンで利益を上げようと進化しており、上昇トレンドで稼ぐことがより難しくなっているためである。

図 3 に 2009 年においてテストを行った結果を示す。2009 年は下降トレンド後、上昇トレンドまたは横ばいの銘柄が多い期間である。図 3 は、その世代で適応度が最も高い個体の 1 銘柄あたりの 1 年間に換算した平均利益の世代推移を表しており、50 試行の平均した結果である。縦軸は平均利益(万円)、横軸は世代数を表し、黒線は既存手法、オレンジ線は 2 年刻みによる提案手法、青線は 1 年刻みによる提案手法、緑線は 6 ヶ月刻みによる提案手法の平均利益を表す。

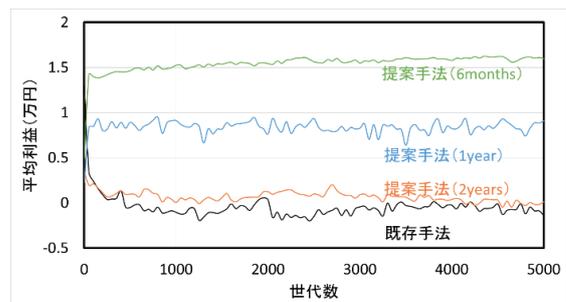


図 3 最良個体の平均利益の世代推移 (2009 年)

最終世代ではどの刻みによる提案手法も既存手法の利益を上回っており、短く分割し学習を行ったものほど利益を上げることが出来ている。既存手法は学習期間では最も利益を上げることが出来ていたが、このテスト期間では利益を上げることが出来ていない。1 年刻みと 6 ヶ月刻みによる提案手法は学習期間では既存手法より利益を上げることが出来ていなかったが、このテスト期間では利益を上げることが出来ている。これは、既存手法は上昇トレンドのみでしか稼ぐことが出来ないように進化したため、テスト期間の変動に対応できず、1 年刻みと 6 ヶ月刻みによる提案手法は様々なパターンの変動で利益を上げようと進化しているためテスト期間の変動にも対応することが出来たからだと考えられる。

他の期間でもテストを行ったところ、提案手法は上昇トレンドでは既存手法に劣るが、他の変動では上回ることが出来た。詳しい結果と考察については発表時に述べる。

4. 今後の課題

本研究では、学習期間を2年, 1年, 6ヶ月の3種類に区切り学習を行っている。より多くの変動パターンを学習させるため、さらに細かく区切ることも考えている。また本研究では、学習期間を区切る際に1月を初めとしている。そこで、学習期間を季節や年度によって区切ることも考えている。季節を考慮した区切り方であれば、春を3月～5月, 夏を6月～8月, 秋を9月～11月, 冬を12月～2月として区切り学習を行う。年度を考慮した区切り方であれば、4月を初めとして学習期間を区切り学習を行う。

参考文献

- [松村 06] 松村幸輝, 国屋美敬, 木村周平: “遺伝的プログラミング手法に基づくエージェントベーストレーダモデル” 情報処理学会論文誌, Vol.47, No9, pp.2869-2886, 2006
- [松村 08] 松村幸輝: “進化計算手法にクラスタリングを応用した株式投資の戦略最適化モデル” 情報処理学会論文誌, Vol.49, No1, pp.457-475, 2008
- [藤本 04] 藤本壱: 株価チャート分析大全, 自由国民社, 2004.
- [吉見 03] 吉見俊彦: 決定版チャート分析の真実, 日経ラジオ社, 2003.
- [山中 15] 山中康司: 相場で勝つための基本と実践 テクニカル指標の読み方・使い方, 2015.
- [Koza 92] Koza, J: Genetic Programming, MIT Press, 1992

人工市場を用いた分散投資規制が投資家の運用成績に与える影響分析

Analysis of the Impact of the Rule for Investment Diversification on Investment Performance using a Multi-Agent Simulation

八木 勲^{*1}
Isao Yagi

水田 孝信^{*2}
Takanobu Mizuta

^{*1} 神奈川工科大学
Kanagawa Institute of Technology

^{*2} スパークス・アセット・マネジメント株式会社
SPARX Asset Management Co., Ltd.

In recent years the risk of mutual funds has become difficult to assess. Therefore the rule for investment diversification for mutual funds was established to prevent assumption of unforeseen risk by investors. Some papers discussed that the rule for investment diversification affected price formation at the time of a market crash and at the time of a soaring market. However, we cannot find that it affects investment performances of investor in such situations. In this paper, we investigated that the rule for investment diversification affected investment performance of investors in financial markets where two types of investors who followed the rule and did not follow it participated at the time of stable, crashing, and soaring markets using agent-based simulations. As results, we found that the investment performances of investors who followed the rule were worse than those of investors who did not follow it in the soaring market.

1. はじめに

近年投資信託(以下、投信)の組み入れ対象となる金融商品の仕組みが複雑になるとともに、投信そのもののリスクの大きさも把握しにくくなってきた。しかし、投資家にすべてのリスク管理を求めるのは困難なため、投信運用会社側でリスクコントロールさせることを目的とした分散投資規制が設けられた[蒲谷 14, 杉田 14]。

分散投資規制は投信の各構成資産に対して保有上限を設ける規制である。これまでにいくつかの先行研究にて分散投資規制が市場に与える影響について議論されている[Yagi 17, 丸山 18]。これらは調査目的を達成するために人工市場を用いている。人工市場とは、コンピュータ上に仮想的に構築されたマルチエージェントシステムの金融市場である[Chen 12, Mizuta 14]。市場側に何らかの制約(市場安定化や効率化のための制度等)をモデル化し組み込むことで、投資家がどのように振る舞うか、さらに、彼らの振る舞いによって市場にどのような影響が現れるかを検討することが可能となる。

上述の先行研究の調査対象は市場価格形成についてであったため、本研究では、分散投資規制が投資家の運用成績に与える影響について人工市場を用いて調査した。

2. 人工市場モデル

本研究では、以下に示す丸山らが提案したモデル[丸山 18]を利用する。本モデルは 2 つのリスク資産(以下、単に「資産」と呼ぶ)のみを取引対象としている。

価格決定メカニズムは連続ダブルオークション方式(ザラバ方式)である。よって、買い(売り)注文は、その注文価格より安い(高い)売り(買い)注文が市場に既に存在すれば、その中で最も安い(高い)売り(買い)注文と即座に取引が成立する。しかし、相対する注文が市場になければ、今回の注文は市場に残す。市場に残した注文は、キャンセル時間 t_c だけ経過しても取引が成立しなかったときキャンセルされる。価格の変化幅の最小単位を δP とする。

本市場では n 体の投資家を想定したエージェントが取引に参加する。以下、エージェントの資産の注文プロセス、および、注文戦略の学習法を示す。

2.1 注文プロセス

エージェントはエージェント番号 $j = 1$ から順番に注文を出す。最後のエージェント $j = n$ が注文を出すと、次の時刻にはまた最初のエージェント $j=1$ から注文を出すことを繰り返す。時刻 t は 1 体のエージェントが注文を出すごとに 1 増える。注文をただけで取引が成立しない場合も 1 ステップ進む。

エージェント j は注文の価格と売り買いの種別を以下のように決める。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) $r_{e,j,k}^t$ は、以下の式 (1) から得られる。

$$r_{e,j,k}^t = \frac{1}{w_{1,j,k}^t + w_{2,j,k}^t + u_{j,k}} (w_{1,j,k}^t r_{e1,j,k}^t + w_{2,j,k}^t r_{e2,j,k}^t + u_{j,k} \epsilon_{j,k}^t) \quad (1)$$

ここで、 $w_{i,j,k}^t$ は時刻 t 、エージェント j 、資産 k 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。この値は後述する学習過程により変化する。 $u_{j,k}$ は、エージェント j 、資産 k の 3 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 u_{max} まで一様乱数で決められ、シミュレーション中に変化することはない。式 (1) の右辺の括弧内の第 1 項目は、ファンダメンタル価格と比較して、安ければプラスの予想リターンを、高ければマイナスの予想リターンを示すファンダメンタル投資家の成分である。ファンダメンタル価格とは、金融資産を発行する企業自身が持っている実態の価値に基づいた価格を指す。 $r_{e1,j,k}^t$ は、時刻 t におけるエージェント j の資産 k に対するファンダメンタル投資家成分だけの場合の予想リターンで $r_{e1,j,k}^t = \log(P_{f,k}/P_k^{t-1})$ である。なお、ファンダメンタル投資家は通常ファンダメンタル価値を参照して投資判断を行う投資家を指す。 $P_{f,k}$ は時間によらず一定の資産 k のファンダメンタル価格である。第 2 項目は過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す、テクニカル投資家の成分である。テクニカル投資家は過去の価格推移を参照して投資判断を行う投資家を指す。 $r_{e2,j,k}^t$ はテクニカル投資家成分だけの場合の予想リターンで、 $r_{e2,j,k}^t = \log(P_k^{t-1}/P_k^{t-1-\tau_j})$ である($k = 1, 2$)。 τ_j は 1 から τ_{max} まで一

様乱数でエージェントごとに決まる。 P_k^t は資産 k の時刻 t での取引価格 (取引されなかった時刻では一番最近に取引された価格であり、時刻 $t=0$ では $P_k^t = P_{f_k}$ とする) である。第3項目はノイズを表している。 $\epsilon_{j,k}^t$ は時刻 t , エージェント j , 資産 k の乱数項で、平均 0, 標準偏差 σ_ϵ の正規分布乱数である。予想価格 $P_{e_{j,k}}^t$ は、予想リターン $r_{e_{j,k}}^t$ に基づいて式 (2) から求められる。

$$P_{e_{j,k}}^t = P_k^{t-1} \exp(r_{e_{j,k}}^t) \quad (2)$$

注文価格 $P_{o_{j,k}}^t$ は、 $P_{e_{j,k}}^t - P_d$ (P_d は定数) から $P_{e_{j,k}}^t + P_d$ までの一様乱数で決める。注文の売り買いの種別は予想価格 $P_{e_{j,k}}^t$ と注文価格 $P_{o_{j,k}}^t$ の大小関係で式(3)のように決まる。

$$\begin{aligned} P_{e_{j,k}}^t > P_{o_{j,k}}^t & \text{ なら買い} \\ P_{e_{j,k}}^t < P_{o_{j,k}}^t & \text{ なら売り} \end{aligned} \quad (3)$$

注文数は常に 1 とする。

全てのエージェントは、注文価格や注文数を決定後、レバレッジ制約に違反していないか判定を行う。さらに分散投資規制対象エージェントは分散投資規制違反の判定も行う。

2.2 学習プロセス

本研究では、実証研究が存在を示している「投資戦略の切り替え」に焦点をあて、そのメカニズムの分析を行いやすいように比較的シンプルでパラメータの少ないモデルの構築を行った。戦略を状況に応じて切り替えるという学習プロセスを以下のようにモデル化した。すなわち、価格変化の方向を当てている戦略のウェイトを引き上げ、外れている戦略のウェイトを引き下げたようにした。また、資産 k の学習期間のリターン r_k^t をかけることにより、小さい価格変動を当てたり外したりしても大きくウェイトが増減しないようにした。学習はエージェントごとに、各エージェントが注文を出す直前に行われる。予想リターン $r_{e_{j,k}}^t$ と資産 k の学習期間のリターン $r_k^t = \log(P_k^{t-1}/P_k^{t-1-t})$ と比べ、符号の違いによって $w_{i,j,k}^t$ を式(4)のように書き換える。

$$\begin{aligned} \text{同符号なら,} & \quad w_{i,j,k}^t \leftarrow w_{i,j,k}^{t-1} + k_l |r_k^t| q_j^t (w_{i,max} - w_{i,j,k}^{t-1}) \\ \text{異符号なら,} & \quad w_{i,j,k}^t \leftarrow w_{i,j,k}^{t-1} - k_l |r_k^t| q_j^t w_{i,j,k}^{t-1} \end{aligned} \quad (4)$$

ここで、 k_l は定数、 q_j^t は時刻 t , エージェント j に与えられる 0 から 1 までの一様乱数である。上記式(4)での学習プロセスの他に、小さい確率 m で $w_{i,j,k}^t$ を再設定する。つまり、0 から $w_{i,max}$ までの一様乱数で決めなおす。これはランダム学習を意味しており、実績からの学習と組み合わせることにより、エージェントが試行錯誤的により良い戦略のウェイトを求める姿を客観的にモデル化している。

2.3 制度モデル

制度モデルは、資産の総保有量を制限するレバレッジ制約と、各資産の保有量を制限する分散投資規制から構成される。既述のようにレバレッジ制約はすべてのエージェントが対象であるが、分散投資規制は該当するエージェントのみが対象となる。本モデルにおいて、レバレッジ制約は、各エージェントの資産の取引高の総額を、純資産以下に規制するようにモデル化した。レバレッジ制約は以下の式で表される。

$$\sum_{k=1}^2 |P_k^t S_{j,k}^t| \leq NAV_i^t \quad (5)$$

ここで、 $S_{j,k}^t$ は、時刻 t におけるエージェント j の資産 k の保有量であり、 $S_{j,k}^t > 0$ なら買い保有している状態、 $S_{j,k}^t < 0$ なら空

売りしている状態を表している。なお、時刻 t におけるエージェント j のキャッシュの保有量を C_j^t とすると、エージェント j の純資産 NAV_i^t は次のように定義される。

$$NAV_i^t = \sum_{k=1}^2 P_k^t S_{j,k}^t + C_j^t \quad (6)$$

分散投資規制は次のとおり定義される。

$$\frac{|P_k^t S_{j,k}^t|}{NAV_i^t} \leq w_{dir} \quad (7)$$

w_{dir} は、分散投資規制の規制比率 (以降、規制比率と略す) であり、各エージェントの純資産に対する各資産の保有高の上限界である。何らかの理由 (例えば、 P_k^t が P_k^{t-1} より大きく上昇した等) で式 (7) が満たさなくなったとき、エージェントは式 (7) を満たすようになるまで資産 k の注文を出しつづけるようにしている。この規制違反を解消するために強制的に発注される売り注文のことを「規制違反売り注文」という。また、予めそのような事態になることを防ぐため、分散投資規制が適用されたエージェントは、注文を発注する際にその注文が規制に違反しそうな場合 (上記の式 (7) を満たさない場合) は、それをキャンセルするよう振る舞うようにした。

3. 実験とその結果

本研究では、次のようにパラメータを設定し実験を行った。

$n = 1,000$, $w_{1,max} = 1$, $w_{2,max} = 10$, $u_{max} = 1$, $\tau_{max} = 10,000$, $\sigma_\epsilon = 0.03$, $P_d = 1,000$, $t_c = 13,000$, $t_l = 10,000$, $k_l = 4$, $m = 0.01$, $\delta P = 1$. 実験の回数は、各条件において 30 回試行し、価格推移については代表的なものを、運用成績については試行開始時に対する試行終了時の純資産増減率の平均で表す。

前章で述べた人工市場を用いて、分散投資規制が導入された市場において、ファンダメンタル価格が急騰した場合と急落した場合のエージェントの運用成績を調査した。分散投資規制比率は 50% と 25% の 2 パターンとし、分散投資規制を受けるエージェント (以下、規制ありエージェント) の割合を 90%, 70%, 50%, 30%, 10% の 5 パターンとし、これらを組み合わせて検証を行う。エージェントの初期保有資産数は、分散投資規制の規制比率に対してそれぞれ 48, 24 とする。初期キャッシュ保有量はそれぞれ 40,000, 520,000 とする。

3.1 人工市場モデルの妥当性

現実の市場ではファット・テイルとボラティリティ・クラスタリングが現れる、と多くの実証研究で指摘されている [Cont 01]。よって、本モデルもこれらが再現できるようパラメータ設定を行った。ファット・テイルは、市場価格の騰落率の分布が正規分布ではなく裾が厚い、すなわち、尖度が正であることである。

表 1 規制比率 25% におけるスタイライズド・ファクト

	資産 1			資産 2		
	10%	50%	90%	10%	50%	90%
規制ありエージェントの割合						
尖度	3.94	4.14	5.11	3.80	4.20	5.26
ラグ						
価格騰落率の						
1	0.12	0.11	0.10	0.12	0.11	0.10
2	0.09	0.08	0.08	0.09	0.09	0.09
2 乗の自己						
3	0.08	0.07	0.07	0.07	0.07	0.07
相関						
4	0.06	0.06	0.05	0.06	0.06	0.06
5	0.06	0.05	0.05	0.05	0.05	0.05

また、ボラティリティ・クラスタリングは市場価格の騰落率の 2 乗が、ラグが増えても自己相関係数が有意に正であり、長期記

憶性を持つことである。調査の結果、すべてのシミュレーション条件下でスタイライズド・ファクトが再現されていることを確認した。表1にその一例を示す。

3.2 市場価格安定時の価格推移と投資家の運用成績

安定した市場を想定するため、ファンダメンタル価格は常に10,000として実験を行った。1000期毎の資産1と資産2の市場価格推移を図1に示す。ただし、両資産の市場価格はどの条件下でもほぼ同様の推移であったので、規制比率50%、規制ありエージェントの割合50%の市場価格推移のみを記載している。ファンダメンタル価格一定時には、市場価格は最初は多少下落するが、その後ファンダメンタル価格の付近で推移することが見てとれる。

次に各シミュレーション条件における規制ありエージェントと規制を受けないエージェント(以下、規制なしエージェント)の運用

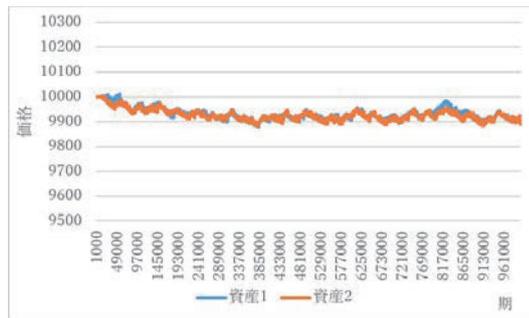


図1 ファンダメンタル価格一定時の市場価格推移

成績を表2に示す。実験の結果、安定した市場においては、どの条件においても規制ありエージェントと規制なしエージェントの最終的な運用成績に大きな差は見られなかった。よって、安定した市場においては、分散投資規制は投資家の投資活動を阻害することはないと考えられる。

表2 ファンダメンタル価格一定時の運用成績

規制比率		25%		50%	
エージェント種別		規制あり	規制なし	規制あり	規制なし
規制ありエージェントの割合	10%	0.9999	0.9999	0.9960	0.9960
	30%	0.9992	0.9993	0.9940	0.9941
	50%	0.9988	0.9989	0.9918	0.9919
	70%	0.9982	0.9983	0.9887	0.9886
	90%	0.9965	0.9966	0.9874	0.9875

3.3 市場価格急落時の価格推移と投資家の運用成績

価格急落時の市場を想定して、ファンダメンタル価格は100,000期に10,000から7,000に急落させる。規制ありエージェントの割合が50%と25%における資産1と資産2の市場価格推移を、それぞれ図2と図3に示す。ただし、資産1の市場価格は、それぞれの規制比率において、どの条件下においてもほぼ同様の推移をしたため、規制ありエージェントが50%のときの価格推移を示している。

規制比率50%の場合は、丸山ら[丸山18]の結果と同様に、資産1の市場価格の急落と連動して資産2の市場価格も下落していく傾向が見られた。規制ありエージェントの割合が増えるにつれ、資産2の市場価格の下落幅は大きくなり、収束する価格はファンダメンタル価格より低い価格になっていった。一方、規制比率25%の場合には、規制比率50%

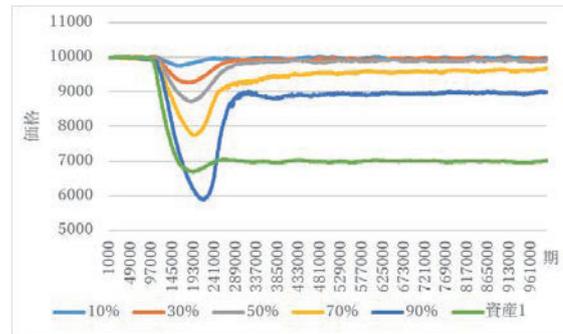


図2 ファンダメンタル価格急落時の規制ありエージェントの割合別市場価格推移(規制比率50%)

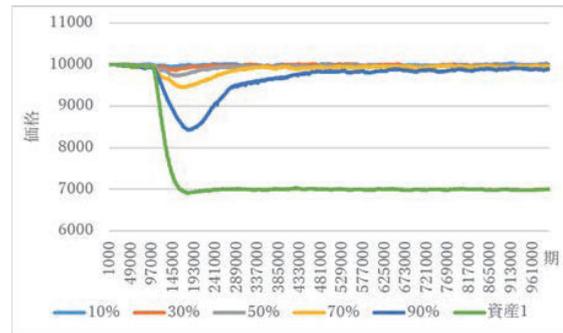


図3 ファンダメンタル価格急落時の規制ありエージェントの割合別市場価格推移(規制比率25%)

の場合に比べて下落幅が小さくなり、資産2の市場価格は、規制ありエージェントの割合が変化してもほぼファンダメンタル価格に収束した。各シミュレーション条件における規制ありエージェントと規制なしエージェントの運用成績を表3に示す。

表3 ファンダメンタル価格急落時の運用成績

規制比率		25%		50%	
エージェント種別		規制あり	規制なし	規制あり	規制なし
規制ありエージェントの割合	10%	0.9322	0.9275	0.8555	0.8545
	30%	0.9311	0.9263	0.8529	0.8538
	50%	0.9297	0.9251	0.8493	0.8521
	70%	0.9280	0.9240	0.8374	0.8411
	90%	0.9251	0.9271	0.8021	0.8008

規制比率50%のときよりも規制比率25%のときの方が運用成績は総じてよい。規制比率別に見ていくと、規制比率が50%のときは、規制ありエージェントの割合に関係なく、規制ありエージェントと規制なしエージェントの最終的な運用成績に大きな差は見られなかった。しかし、規制ありエージェントの割合が増えていくにつれ、規制ありエージェントと規制なしエージェントともに運用成績が悪化した。一方、規制比率が25%のときは、規制ありエージェントの割合が増加するにつれ、規制ありエージェントの運用成績のみ悪化した。そして、規制ありエージェントの割合が90%のとき、規制なしエージェントの方が若干ではあるが運用成績がよい結果となった。

3.4 市場価格急騰時の価格推移と投資家の運用成績

価格急騰時の市場を想定して、ファンダメンタル価格は100,000期に10,000から13,000に急騰させる。規制ありエージェントの割合が50%と25%における資産1と資産2の市場価格推移を、それぞれ図4と図5に示す。ただし、資

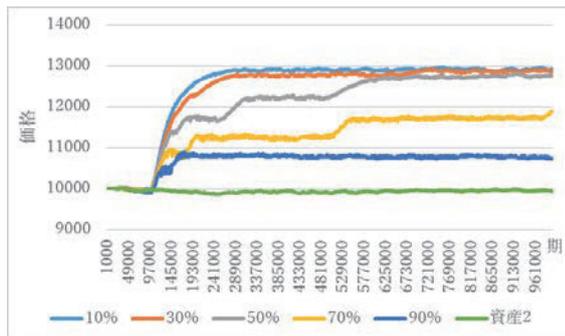


図4 ファンダメンタル価格急騰時の規制ありエージェントの割合別市場価格推移 (規制比率 50%)

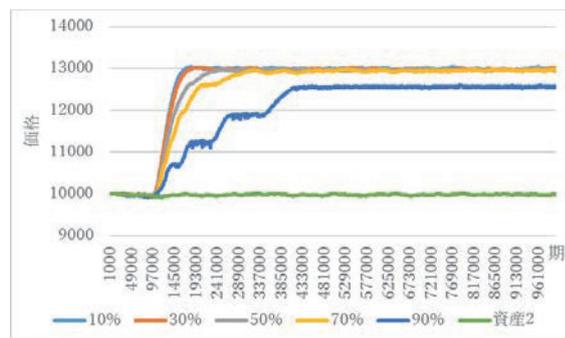


図5 ファンダメンタル価格急騰時の規制ありエージェントの割合別市場価格推移 (規制比率 25%)

産 2 の市場価格は、それぞれの規制比率において、どの条件下においてもほぼ同様の推移をしたため、規制ありエージェントが 50% のときの価格推移を示している。

規制比率 50% のときは、丸山ら[丸山 18]の結果同様、規制ありエージェントが増えるにつれ、資産 1 の市場価格が収束する値が低くなり、ファンダメンタル価格まで到達しなくなる。一方で、規制比率 25% のときは、規制ありエージェントの割合が増加しても規制ありエージェントが 90% の場合を除いて市場価格はファンダメンタル価格に収束している。各シミュレーション条件における規制ありエージェントと規制なしエージェントの運用成績を表 4 に示す。

表 4 ファンダメンタル価格急騰時の運用成績

規制比率		25%		50%	
エージェント種別		規制あり	規制なし	規制あり	規制なし
規制ありエージェントの割合	10%	1.0614	1.0731	1.1296	1.1380
	30%	1.0617	1.0758	1.1278	1.1376
	50%	1.0619	1.0801	1.1228	1.1347
	70%	1.0623	1.0888	1.0896	1.0987
	90%	1.0549	1.1055	1.0322	1.0333

規制比率 25%、50% ともにすべての条件下で規制なしエージェントの方が運用成績は良い結果となった。規制比率別に見ていくと、規制比率 25% のとき、規制ありエージェントの運用成績は規制ありエージェントの割合が増えても変化することなく維持されたが、規制なしエージェントの方は運用成績が上昇している。しかし、規制比率 50% のときは、規制ありエージェントが増えると、規制ありエージェントと規制なしエージェント共に運用成績が下降していく傾向が見られた。特に、規制ありエージェントの割合が 70% の時と 90% の時は運用成績が大きく減少している。

以上より、ファンダメンタル価格急騰時、分散投資規制はエージェントの利益獲得の機会損失を生み、エージェントの運用成績の向上を妨げてしまうと考えられる。また、規制ありエージェントが多い市場ほど、エージェント全体にマイナスの影響を与えてしまう可能性があることも示唆している。

4. まとめと今後の課題

本研究では、人工市場を用いて、1) 価格が安定した市場、2) 価格が急落した市場、3) 価格が急騰した市場において、分散投資規制が投資家の運用成績にどのような影響を与えるかを調査した。その結果、価格が安定した市場および急落した市場においては、分散投資規制の対象となる投資家とそうでない投資家の間に運用成績に大きな違いは見られなかった。しかし、価格が急騰した市場では、規制が厳しいほど投資家の利益獲得の機会損失を生み、運用成績の向上を妨げてしまう結果となった。以上より分散投資規制は、市場価格が上昇している市場においては、分散投資規制対象となる投資家たちの取引の障害になりえることが示唆された。また、規制対象となる投資家が多くなると、市場参加者全体の利益獲得を妨げてしまう可能性があることも示唆された。

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す。

謝辞

本研究は、公益財団法人日本証券奨学財団 (Japan Securities Scholarship Foundation) の助成を受けました。この場を借りてお礼申し上げます。

参考文献

- [蒲谷 14] 蒲谷 俊介:改正投信法が投信業界に与える影響, 金融 IT フォーカス, 野村総合研究所, pp.12--13 (2014)
- [杉田 14] 杉田 浩治:投資信託の 14 年改革と今後の課題, 資本市場研究会, No. 347, pp. 4--11 (2014)
- [Chen 12] S.-H. Chen, C.-L. Chang, and Y.-R. Du: Agent-based economic models and econometrics, Knowledge Engineering Review, Vol. 27, No. 2, pp. 187--219 (2012)
- [Mizuta 14] T. Mizuta, K. Izumi, I. Yagi and S. Yoshimura: Regulations' effectiveness for market turbulence by large erroneous orders using multi agent simulation, In Proceedings of IEEE Computational Intelligence for Financial Engineering and Economics 2014(CIFEr2014), pp.138--143 (2014)
- [Yagi 17] I. Yagi, A. Nozaki, and T. Mizuta: Investigation of the rule for investment diversification at the time of a market crash using an artificial market simulation, Evolutionary and Institutional Economics Review, Vol.14, No.2, pp. 451--465 (2017).
- [丸山 18]丸山隼矢, 水田孝信, 八木勲:人工市場を用いた分散投資規制が市場に与える影響分析~ファンダメンタル価格急落時と急騰時における比較~, 合同エージェントワークショップ&シンポジウム 2018 (JAWS2018) (2018).
- [Cont 01] R. Cont: Empirical properties of asset returns: stylized facts and statistical issues, Quantitative Finance, Vol. 1, pp.223--236(2001)

リターン時系列に基づく投資信託の動的クラスタリング

Dynamic clustering of mutual funds based on the return series

松井 藤五郎 *1
Tohgoroh Matsui米田 一樹 *2
Kazuki Yoneda森山 甲一 *2
Koichi Moriyama武藤 敦子 *2
Atsuko Mutoh犬塚 信博 *2
Nobuhiro Inuzuka*1中部大学
Chubu University*2名古屋工業大学
Nagoya Institute of Technology

This paper proposes a method to analyze mutual funds using dynamic clustering based on the return series. For the time series data divided into some terms, the proposed method (1) converts the original high-dimensional data to two dimensional data using t-SNE for each term, (2) applies dynamic clustering using x -means for each term, and (3) detects the cluster transitions using FBL-MONIC. This paper shows the experimental results for 29 Japanese mutual funds that track TOPIX, including four ETFs. The results indicate that there are three clusters at terms 1, 2, 3 and 4, and four clusters at term 5. We consider that the clusters are valid because one of the clusters consists of ETFs for all terms. FBL-MONIC could detect the transitions from a cluster at term 4 to a new cluster at term 5.

1. はじめに

投資信託（ファンド）は投資家から資金を預かり、ファンド・マネージャーと呼ばれる専門家が資産運用を行う金融商品である。ファンドの中には、東証株価指数（TOPIX）や日経平均株価のような株式指標（インデックス）と連動するように運用されているものがあり、これらはインデックス・ファンドと呼ばれる。

ファンドが運用の目標としている指標をベンチマークといい、同じ指標をベンチマークとしているインデックス・ファンドは同じような値動きをするはずである。しかし、実際には、同じ指標をベンチマークとしているインデックス・ファンドであっても、値動きが異なっていることがある。これは、ファンドごとに資産内容が異なるためだと考えられる。

これまで、ファンドの投資先類似度に基づくクラスタリング [1, 2] を行ってきたが、この方法は投資先がわかっていないと用いることができない。運用会社は自社が運用するファンドの投資先ならわかるが、一般的にはファンドの投資先を正確に知ることはできない。年に数回発行される運用報告書には投資先が記載されているが、ファンドごとに基準日が異なり、類似度を正確に求めることができない。

そこで本研究では、外部からでも観測可能な月次リターンの系列に基づいて、ファンドをクラスタリングする。月次リターンの系列を複数の期に分割し、期ごとにクラスタリングを行うことによって動的クラスタリングを行う。

我々は、動的クラスタリングにおいて、クラスター遷移を抽出する手法を提案している [3]。変化前のクラスターに属するデータと変化後のクラスターに属するデータの一致率を求め、変化前のクラスターを基準とした前向き分析によってクラスター遷移を検出する MONIC (MONItoring Cluster transitions) [4] という手法が提案されているが、異なる時刻に観測されたデータは同一でないと判断するために、特徴量が時間によって変化するデータに対して適用することができない。そこで我々は、ラベルの同一性に基づいてクラスター遷移を検出するよう MONIC を拡張した。これを本論文では FL-MONIC (Forward

Label-based MONIC) と呼ぶ。また、FL-MONIC に対して、変化後のクラスターを基準とした後ろ向き分析を追加した。これを本論文では FBL-MONIC (Forward-Backward Label-based MONIC) と呼ぶ。FBL-MONIC と FL-MONIC は、異なる時刻のデータであってもラベルが同じであれば一致すると判断して分析するため、特徴量が時間によって変化するデータに対して同じラベルを割り当てることによってクラスター遷移を検出することができる。

本論文では、インデックス・ファンドに対して月次リターンの系列に基づいて動的クラスタリングを行い、FBL-MONIC を用いてクラスター遷移を検出し、その結果を示す。

2. 分析手法

対象となるデータは、複数の期に分割された時系列データの集合 X_1, \dots, X_n である。ここで、 n は期の数を表す。期の長さを揃える必要はないが、同じにしておく結果を解釈しやすい。また、期が重なっていてもいいが、重複する期間が長いほどクラスタリング結果が類似しやすく、動的クラスタリングにおけるクラスターの変化が小さくなる。

まず、期ごとに、時系列データ X_t ($t = 1, \dots, n$) に対し、時系列に含まれる変数を時刻ごとに独立であると考え、t-SNE (t-distributed Stochastic Neighbor Embedding) [5] を用いて 2次元空間上のデータ集合 Y_t に変換する。

$$Y_t \leftarrow \text{t-SNE}(X_t)$$

t-SNE は、基準となる点 x から見た点 x' の近さを、 x を中心とした正規分布を考えて、 x が観測されたときに x' も観測される確率（条件付き確率）として表し、変換後の点の近さが自由度 1 の t 分布（正規分布よりも裾が重い分布）となるように変換することによって、近いデータをより近くに、遠いデータをより遠くに配置する。t-SNE を用いることによって、次元を圧縮することができ、高次元空間では最近傍であっても距離が大きくなってしまいう「次元の呪い」を解くことができる。また、2次元空間上の点に変換することによって、クラスタリング結果を可視化しやすくなる。ただし、t-SNE はデータ間の距離のみを考慮して次元圧縮を行うため、変換後の座標空間における軸の向きや大きさには意味がない。

Require: 期ごとの時系列データの集合 (X_1, \dots, X_n)

- 1: $n \leftarrow$ 期の数
- 2: **for** $t = 1$ **to** n **do**
- 3: 2次元空間上の点の集合 $Y_t \leftarrow$ t-SNE(X_t)
- 4: クラスターの集合 $\Gamma_t \leftarrow$ x-means(Y_t)
- 5: **end for**
- 6: **for** $t = 2$ **to** n **do**
- 7: クラスター遷移 $T_t \leftarrow$ FBL-MONIC(Γ_{t-1}, Γ_t)
- 8: **end for**
- 9: **return** $(\Gamma_1, \dots, \Gamma_n), (T_2, \dots, T_n)$

図1 分析手法のアルゴリズム

期ごとに、2次元空間上のデータ Y_t に対して x-means [6] を用いてクラスタリングを行い、クラスターの集合 Γ_t を得る。

$$\Gamma_t \leftarrow \text{x-means}(Y_t)$$

x-means は、非階層クラスタリングである k-means をクラスター数を自動的に決めるように拡張したものであり、クラスター数を2から1つ増やしながらか k-means を行い、BIC (Bayesian Information Criterion) を用いて最適なクラスター数を決める。x-means を用いることによって、k-means のクラスター数 k を与えなくてもよくなる。最適なクラスター数は期ごとに決められるため、本手法の動的クラスタリングにおいてはクラスター数は一定ではない。また、x-means や k-means では、クラスター割り当てをランダムに初期化するため、クラスター番号の変化には意味がない。

t-SNE と x-means の性質により、動的クラスタリングにおいて2次元空間上での位置やクラスター番号を用いて前後のクラスターを対応付けることはできない。

そこで、クラスターに属するデータのラベルに基づいたクラスター遷移検出法である FBL-MONIC [3] を用いる。クラスターの集合 $\Gamma_1, \dots, \Gamma_n$ に含まれる連続する二つのクラスター集合 Γ_{t-1} と Γ_t に対して、FBL-MONIC を用いてクラスター遷移 T_t を検出する。

$$T_t \leftarrow \text{FBL-MONIC}(\Gamma_{t-1}, \Gamma_t)$$

このアルゴリズムを図1に示す。このアルゴリズムは、複数の期に分割された時系列データの集合 X_1, \dots, X_n を入力すると、クラスターの集合 $\Gamma_1, \dots, \Gamma_n$ とクラスター遷移 T_2, \dots, T_n を返す。

3. インデックス・ファンドの分析

3.1 分析データ

Yahoo!ファイナンス内のモーニングスターのファンド検索において、「TOPIX」をキーワードとして検索し、検索されたファンドの中から東証株価指数 (TOPIX) 全体をベンチマークとしているインデックス・ファンドを取り出した*1。取り出されたファンドは29だった。その一覧を表1に示す。表中の*印はETF (上場投資信託) を表す。

これらのファンドについて、2013年11月から2018年10月までの5年分の月次リターンの時系列データを取得した。ファ

*1 例えば、野村アセットマネジメントが運用する「(NEXT FUNDS) 素材・化学上場投信」は、「TOPIX」をキーワードとした検索結果に含まれるが、対象インデックスが TOPIX ではなく TOPIX-17 素材・化学であるため除外した。

表1 分析対象の TOPIX 連動型ファンド。*印はETFを表す。

ファンド名	ラベル
トビックス・インデックス・オープン	Nomura-TIO
TOPIX 連動型上場投資信託*	Nomura-ETF
野村 インデックス F・TOPIX	Nomura-Fi
インデックスファンド TSP	Nikko-TSP
上場インデックスファンド TOPIX*	Nikko-ETF
インデックスファンド TOPIX(日本株式)	Nikko-DC
三菱 UFJ TOPIX・ファンド	MUFJ-TF
MAXIS トビックス上場投信*	MAXIS-ETF
トビックスオープン	MUKAM-TO
三菱 UFJ トビックスインデックスオープン	MUFJ-TIO
eMAXIS TOPIX インデックス	eMAXIS
三菱 UFJ トビックスオープン	MUFJ-TO
トビックス・インデックスファンド	Daiwa
ダイワ 上場投信-トビックス*	Daiwa-ETF
明治安田 TOPIX オープン	MYAM
JA TOPIX オープン	JA
ニッセイ TOPIX オープン	Nissei
MHAM トビックスファンド	MHAM-TF
DIAM 国内株式バッシブ・ファンド	DIAM
MHAM TOPIX オープン	MHAM-TO
ニュートビックスインデックス	One
東京海上 日本株 TOPIX ファンド	TMAM
りそな・TOPIX オープン	Risona
しんきん トビックスオープン	Shinkin
日本株式インデックス e	SMT-Jle
日本株式インデックスファンド	SMT-JIF
SMT TOPIX インデックス・オープン	SMT-TIO
日本株式インデックス・オープン	SMT-JIO
国内株式指数ファンド (TOPIX)	SMA

ンドの月次リターンから TOPIX の月次リターンの値を引いて TOPIX 超過リターンを求め、1年分ずつに分割してそれぞれ1つの期とした。すなわち、1つのデータは長さ12の時系列として表されている。

例として、5期 (2017年11月から2018年10月まで) の TOPIX 超過リターンの推移を図2に示す。折れ線の色は、後述するクラスタリング結果のクラスター番号を表している。1年分の折れ線グラフでは線がほとんど重なってしまうため、最初の4ヶ月分を拡大したものを図3に示す。このように、多くのファンドがかなりよく似た値動きをしている。緑色のファンドは全てETFであり、互いに非常によく似た値動きをしているが、他のファンドと比較して TOPIX 超過リターンが高い傾向にあることがわかる。

3.2 分析結果

t-SNE によって変換された2次元空間と x-means によるクラスタリング結果を図4-8に示す。データの記号と色はクラスター番号を表している。また、クラスター番号を表2に示す。

表2は、FBL-MONIC によって検出されたクラスター遷移のうち、前向き分析において生存していると判定されたクラスターを同じ色で表している*2。前向き分析だけの FL-MONIC では、 $C_{4,2}$ (4期の2番クラスター) に属するメンバーの4/7が $C_{5,4}$ にも属していることから、「 $C_{4,2}$ は $C_{5,4}$ として生存している」と判定されたが、 $C_{4,2}$ と $C_{5,2}$ の関係は検出されなかった。後ろ向き分析も行う FBL-MONIC では、 $C_{5,2}$ に属するメンバーの2/3が $C_{4,2}$ にも属していることから、「 $C_{5,2}$ は $C_{4,2}$ の影響が強い」と判定された。

*2 一致率の閾値を $\tau = 0.5$ とした。

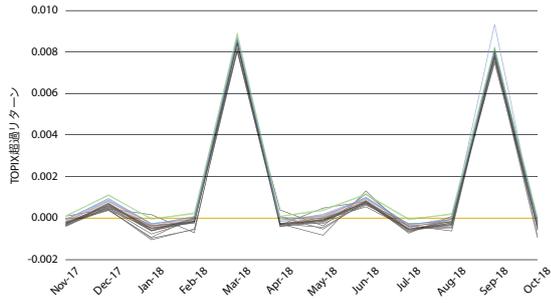


図2 29 ファンドの5期(2017年11月から2018年10月まで)のTOPIX超過リターン。色はクラスター番号を表す。

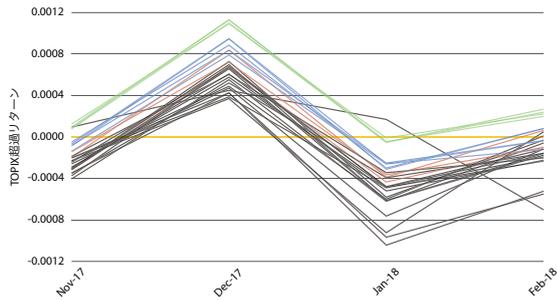


図3 29 ファンドの5期の最初の4ヶ月(2017年11月から2018年2月まで)のTOPIX超過リターンの拡大図。色はクラスター番号を表す。

表2 動的クラスタリングの結果(クラスター番号)と信託報酬。セルの色は対応するクラスターを表す。同じクラスターに属するファンドが並ぶようにソートされている。

ラベル	1期	2期	3期	4期	5期	信託報酬
Nomura-TIO	1	3	1	1	1	0.67%
Nikko-TSP	1	3	1	1	1	0.56%
Nikko-DC	1	3	1	1	1	0.67%
MUFJ-TF	1	3	1	1	1	0.68%
MUKAM-TO	1	3	1	1	1	0.67%
MUFJ-TO	1	3	1	1	1	0.65%
Daiwa	1	3	1	1	1	0.67%
MYAM	1	3	1	1	1	0.65%
JA	1	3	1	1	1	0.59%
MHAM-TO	1	3	1	1	1	0.59%
One	1	3	1	1	1	0.65%
TMAM	1	3	1	1	1	0.65%
Risona	1	3	1	1	1	0.65%
Shinkin	1	3	1	1	1	0.86%
SMT-JIF	1	3	1	1	1	0.65%
MHAM-TF	1	3	2	1	1	0.65%
DIAM	1	3	1	1	2	0.49%
SMT-JIO	3	2	1	2	1	0.65%
MUFJ-TIO	3	2	1	2	2	0.70%
Nissei	3	2	2	2	2	0.54%
Nomura-Fi	3	2	2	2	4	0.43%
eMAXIS	3	2	2	2	4	0.43%
SMT-JIe	3	2	2	2	4	0.40%
SMT-TIO	3	2	2	2	4	0.40%
SMA	3	2	2	3	4	0.43%
Nomura-ETF	2	1	3	3	3	0.12%
Nikko-ETF	2	1	3	3	3	0.10%
MAXIS-ETF	2	1	3	3	3	0.08%
Daiwa-ETF	2	1	3	3	3	0.12%

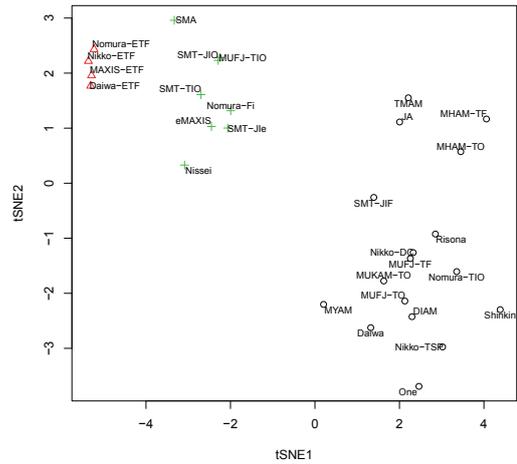


図4 1期(2013年11月から2014年10月まで)の超過リターン時系列に基づくTOPIXファンドのクラスタリング結果。

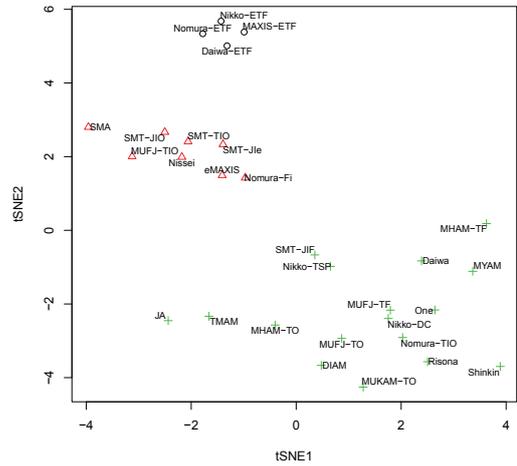


図5 2期(2014年11月から2015年10月まで)の超過リターン時系列に基づくTOPIXファンドのクラスタリング結果。

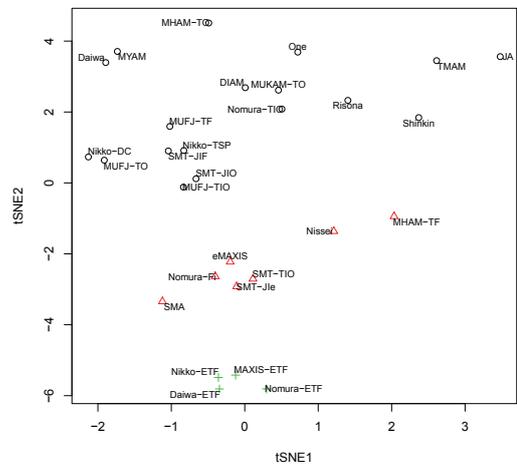


図6 3期(2015年11月から2016年10月まで)の超過リターン時系列に基づくTOPIXファンドのクラスタリング結果。

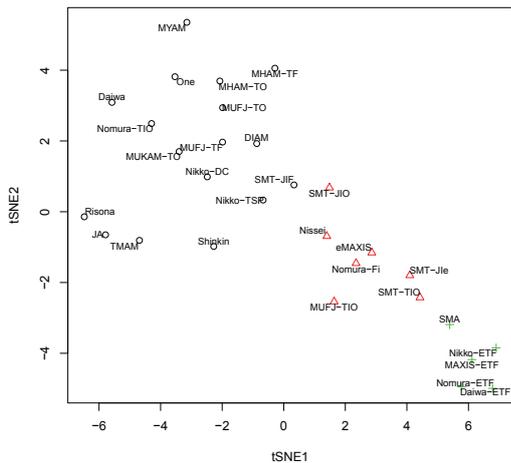


図7 4期(2016年11月から2017年10月まで)の超過リターン時系列に基づく TOPIX ファンドのクラスタリング結果。

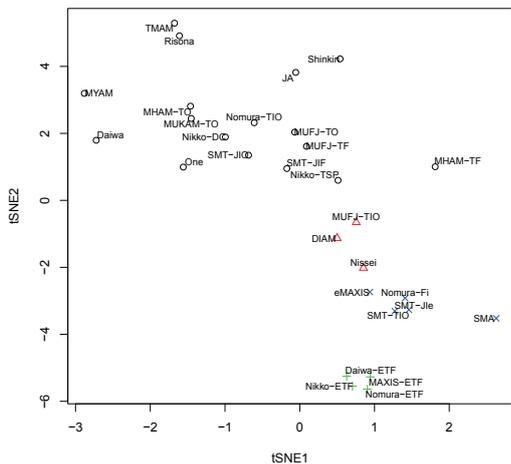


図8 5期(2017年11月から2018年10月まで)の超過リターン時系列に基づく TOPIX ファンドのクラスタリング結果。

4. 考察

今回の分析対象には、株式市場で売買されている ETF が4つ含まれている。ETF は株式市場で売買されており、証券会社や銀行などに支払う販売コストがかからないことから、信託報酬を小さくすることができる。

t-SNE を用いてリターン時系列を2次元空間に圧縮した図を見ると、全ての期において ETF は極めて近い位置に配置されている。このことから、t-SNE による次元圧縮は適切に行われていると考えられる。また、クラスタリングの結果を見ると、全ての期において ETF が同じクラスターに含まれており、かつ、そのクラスターはほぼ ETF だけで構成されていた。このことから、t-SNE によって圧縮された2次元空間上での x-means によるクラスタリングも適切に行われていると考えられる。

t-SNE と x-means の性質により、2次元空間上での位置とクラスター番号だけからでは動的クラスタリングにおけるクラスターの遷移や対応関係を求められない。提案手法では、クラス

ターに属するメンバーのラベルに基づいてクラスター遷移を検出することによって、クラスターの遷移と対応関係を求めることができる。

前向き分析だけの FL-MONIC は、5期の2番クラスター $C_{5,2}$ を4期のクラスターとは関係のない新しいクラスターと判定したが、後ろ向き分析も行う FBL-MONIC は、 $C_{5,2}$ を $C_{4,2}$ の影響が強いクラスターと判定した。実際に、 $C_{5,2}$ を構成する DIAM, MUFJ-TIO, Nissei のうち、MUFJ-TIO と Nissei は $C_{4,2}$ にも含まれるため、 $C_{5,2}$ は $C_{4,2}$ から分割された小さなクラスターに新たに DIAM が加わったものとして捉えることができる。このことから、FBL-MONIC による後ろ向き分析によって前向き分析だけでは捉えることができないクラスター遷移を検出できるようになったことがわかる。

また、全ての期において ETF クラスターに最も近いクラスターに所属していたファンドは、全て信託報酬が 0.43% 以下だった。ファンドの基準価格からは信託報酬等の間接コストが控除されており、運用が同じなら間接コストが大きい方がリターンが小さくなる。本論文では TOPIX との連動を目指すファンドだけを対象にしたためリターン時系列の違いは小さいが、信託報酬等の間接コストがリターンに影響した結果が反映されたクラスターを獲得することができたと考えられる。

5. おわりに

本論文では、複数の期に分割されたファンドのリターン時系列を対象として、(1) 期ごとに t-SNE を用いて2次元空間に圧縮し、(2) 期ごとに x-means を用いてクラスタリングを行い、(3) FBL-MONIC を用いてクラスター遷移を検出することによって、動的クラスタリングを行ってそのクラスター遷移を検出する方法を提案した。

提案手法を用いて TOPIX 連動型インデックス・ファンドを分析したところ、1期から4期は3つ、5期は4つのクラスターが得られた。全ての期において、クラスターの1つに全てのETFが含まれており、かつ、このクラスターにはETF以外のファンドがほとんど含まれていなかったことから、提案手法によって妥当な動的クラスタリングを行うことができたと考えられる。また、5期に新しく増えたクラスターは、前向き分析では4期のクラスターからの遷移として検出されなかったが、後ろ向きでは4期のクラスターの1つの影響が強いと判定され、クラスター遷移として検出することができた。

参考文献

- [1] T. Sakakibara, T. Matsui, A. Mutoh, N. Inuzuka: Clustering mutual funds based on investment similarity, *Procedia Computer Science*, 60:881–890, 2015
- [2] 米田一樹, 松井藤五郎, 武藤敦子, 犬塚信博, 森山甲一: 投資割合を考慮した投資先類似度に基づく投資信託のクラスタリング, 第31回人工知能学会全国大会, 2D1-4, 2017
- [3] 米田一樹, 松井藤五郎, 森山甲一, 武藤敦子, 犬塚信博: 動的クラスタリングにおけるクラスタの変化分析, 情報処理学会数理モデル化と問題解決研究会, 2019-MPS-122(6):1–6, 2019
- [4] M. Spiliopoulou, I. Ntoutsi, Y. Theodoridis, R. Schult: MONIC—Modeling and monitoring cluster transitions, *KDD 2006*, 706–711, 2006
- [5] L. van der Maaten, G. Hinton: Visualizing data using t-SNE, *J Mach Learn Res*, 9:2579–2605, 2008
- [6] 石岡恒憲: クラスター数を自動決定する k-means アルゴリズムの拡張について, *応用統計学*, 29(3):141–149, 2000

[1N2-J-9] Natural language processing, information retrieval: dialogue

Chair: Masaaki Tsuchida Reviewer: Yuzuru Okajima

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room N (Front-right room of 1F Exhibition hall)

[1N2-J-9-01] Dialogue based recommender system that flexibly mixes utterances and recommendations○Daisuke Tsumita¹, Tomohiro Takagi¹ (1. Department of Computer Science, Meiji University)

1:20 PM - 1:40 PM

[1N2-J-9-02] Applying a neural network model of a dialogue considering the context to Japanese ordering dialogue○Yuri Murayama¹, Ichiro Kobayashi², Takeshi Morita³, Yukiko Nakano⁴, Takahira Yamaguchi³ (1. Ochanomizu University Graduate School, 2. Ochanomizu University, 3. Keio University, 4. Seikei University)

1:40 PM - 2:00 PM

[1N2-J-9-03] Evaluations for personalized chatbot based on LSTM○Sohei Okui¹, Makoto Nakatsuji¹ (1. NTT Resonant, Inc)

2:00 PM - 2:20 PM

[1N2-J-9-04] Response Dialogue-Act Prediction based on Conversational History○Koji Tanaka¹, Junya Takayama¹, Yuki Arase¹ (1. Graduate School of Information Science and Technology, Osaka University)

2:20 PM - 2:40 PM

[1N2-J-9-05] Empirical study of conditional interactions based on longitudinal survey data○Hiromitsu Ota¹ (1. The Open University of Japan)

2:40 PM - 3:00 PM

発話と推薦を柔軟に混合させる対話型推薦システムの実現

Dialogue based recommender system that flexibly mixes utterances and recommendations

積田 大介 *¹ 高木 友博 *¹
Daisuke Tsumita Tomohiro Takagi

*¹明治大学大学院理工学研究科情報科学専攻
Department of Computer Science, Meiji University

Many of the prior research in the recommendation through dialogue were designed separating dialogue and recommendation. However, since the accuracy of the recommendation itself is not necessarily high, rarely the recommendation result meets user needs. We human, however, can guide the solutions satisfying the user, by appropriately repeating the cycle of checking mismatch reason and making another recommendation in our conversations. In this paper, we proposed a system to leverage a dialogue strategy for reinforcement learning using recommendation results based on user's utterances. We realized a dialog system to perform adaptive behavior that naturally incorporates recommendations into conversation with users.

1. はじめに

接客や相談対応をするような目的指向型の対話システムの開発は、需要の高まりとともに発達が目覚ましい研究領域である。対話システムの設計において重要なのが、ユーザの発話に対してどういった応答を返すかを決定する対話戦略の定義である。従来の目的指向型の対話システムはルールベースによる対話戦略が主流であったが、多様なユーザの発話を想定し、膨大な数のルールを定義する必要がある。そのため、機能追加やルール修正に多大な労力を伴うという問題点がある。近年、これらのルールベースな対話戦略の課題に対し、バンディットアルゴリズムや強化学習などの枠組みによるモデルベースの対話システムが注目されている。また、一般的な目的指向型の対話システムでは達成すべき目標が決まっており、ユーザの求める解を提示するだけで目標を達成することができる。一方で、ユーザ自身が、ユーザニーズを明示的に理解していない状況下では、ユーザに対して推薦を行うシステムを構築する必要がある。しかし、推薦システムそのものの精度は必ずしも高くはないため、このような対話による推薦においては、対話の当初から推薦結果がユーザニーズに適合しない事が考えられる。その場合、適合しない理由を確認、補正し、別の推薦結果を繰り返し提示していくことで、潜在的なニーズを探索しながら、ユーザが満足する解まで誘導する必要がある。また、ユーザとの対話を通じた情報収集と推薦結果の提示とを混在させ、全体的にそのやりとりの回数を減らすなどの効率化が求められる。このような、人間のように会話の中で自然に推薦を織り交ぜるような発話をするシステムの構築は難しく、先行研究の多くは通常の発話と推薦を切り離れたシステム設計になっている。本稿ではユーザの発話情報を利用した推薦システムの設計と、その推薦に基づいた強化学習による対話戦略を定義し、人間のように通常の発話と推薦とを混在させた臨機応変な振る舞いを行う対話システムの提案をする。

2. 関連研究

モデルベースの目的指向型対話システム構築の試みは、近年、数多く行われており、中でも強化学習を用いた対話に関する研究は注目を集めている。

[Xiujun 17] らは映画のチケット予約に関する対話タスクにおいて、深層強化学習による対話戦略を実現した。ここでは、ユーザの発話理解からエージェント *¹ の応答生成までを End-to-End に学習させる枠組みを提案している。しかし Xiujun らの研究では、映画予約というタスクの性質上、ユーザの目標とする映画はすでに決まっているものと仮定しており、エージェントによる推薦は行われていない。

[Yueming 18] らは対話における推薦問題に焦点を当てた研究をしている。レストラン予約のタスクに対し、深層強化学習による対話戦略に加え、ユーザの過去の行動履歴をもとに推薦をするモデルを提案し、高精度な推薦システムを用いて効率的なやりとりを行うことに成功している。しかしここでの対話戦略には、推薦システムの出力は考慮されていない。

3. 問題設定

提案するシステムの学習、評価に [Chaitanya 17] らの作成した対話データセット (以下 Personalized Dialog dataset と呼ぶ) を使用した。このデータセットはユーザとシステムのレストラン予約に関するやりとりから、次の発話を予測するというタスクに対して作成されたものである。「性別、年齢層、好みの料理、菜食主義か否か」といったユーザのプロファイル情報が与えられた状態で、予約完了までに行った会話の全記録が提供されている。また、知識ベースとして、2,400 店舗のレストラン情報が用意されており、「料理ジャンル、場所、価格帯、人数」の条件、いわゆるファセット項目でレストランを絞り込むことができる。本研究では Personalized Dialog dataset を基に、レストランを探すユーザに対して、やり取りの中でユーザが満足する店舗を予測する推薦システムと、その予測を考慮した上で発話を行う対話システムを構築する。

連絡先: 積田大介, 明治大学大学院理工学研究科情報科学専攻, 〒 214-8571 神奈川県川崎市多摩区東三田 1-1-1, tsumidai@cs.meiji.ac.jp

*¹ 本稿では提案する対話システム全体に対し、対話戦略をとるモデル自体をエージェントと呼ぶ。

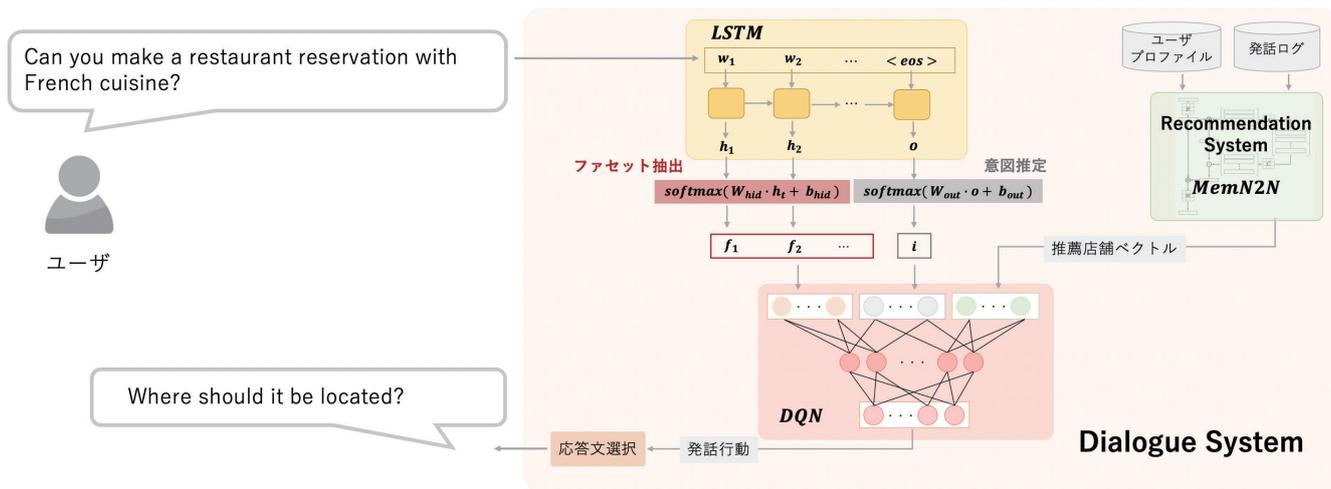


図 1: 提案システムの構成図

4. 提案システム

本研究では Xiujun らの対話システムをベースに深層強化学習の枠組みで学習を行うエージェントを設計し、その対話戦略に推薦システムによる予測を利用する。図 1 に提案システムの構成を示す。以下、本節では提案システムの各モジュールの説明を記述する。

4.1 発話意図推定とファセット抽出

推薦を行う目的指向型の対話システムにおける機能として、ユーザの発話からそのユーザがどのような意図で発言をしたかを推定することが求められる。同様に、レストラン予約に求められるファセット項目を抽出する必要がある。本研究ではユーザの発話意図推定とファセット項目抽出を同時に行うモデルとして、生成モデルや時系列予測などの分野で成果を上げている Long short-term memory (LSTM) を使用する。Personalized Dialog dataset に含まれるユーザの発話文から、数種類のユーザの発話意図パターンとファセット項目を抽出し、このモデルの学習用の教師として使用した。以下に LSTM による予測の流れを示す。

1. 発話文を単語に分割し、単語ベクトルに変換したものを、LSTM への入力とする。単語ベクトルは総単語数の次元を持ったワンホットベクトルで、単語に対応した次元位置に 1 が入る形をとる。発話文の t 番目に登場した単語を w_t とし、LSTM から得られる隠れ層の出力の内、最終出力のベクトルを o 、ベクトル o 以前の間出力のベクトルを h_1, h_2, \dots, h_n とする。また、最終セルには文の終了タグ (eos) を入れる。

$$h_1, h_2, \dots, h_n, o = LSTM(w_1, w_2, \dots, w_n, eos) \quad (1)$$

2. h_1, h_2, \dots, h_n と o にそれぞれ異なる重み付けを行い、 $softmax$ 関数に通すことで、それぞれベクトル f_1, f_2, \dots, f_n と i を得る。最終出力から得られたベクトル i がユーザの発話意図を、中間出力から得られた各ベクトル f_t が単語 w_t のファセット項目を表現するように学習させる。

$$f_t = softmax(W_{hid} \cdot h_t + b_{hid}) \quad (2)$$

$$i = softmax(W_{out} \cdot o + b_{out}) \quad (3)$$

ここで得られたユーザの発話意図とファセット項目に関するベクトルを対話戦略の入力として利用する。

4.2 推薦システム

ユーザの過去の発話とプロフィール情報を基に、ユーザの嗜好に合った店舗を予測する推薦システムについて説明する。

本研究では、質問応答の分野で提案され、対話システムの発話予測問題においても、Recurrent neural network (RNN) や LSTM といった他の深層学習のモデルを上回る精度で注目されている End-to-End Memory Networks (MemN2N) [Sainbayar 15] の枠組みによる推薦システムを利用する。

質問応答の分野で使用される MemN2N は過去の発話を知識情報として記憶し、質問を受けると、質問文を基に記憶を参照して回答を導き出す。すなわち、過去の発話情報と質問文などの外部入力から応答文を出力するモデル設計になっている。

本研究における問題設定では、質問文の代わりにユーザのプロフィール情報を使用し、特定のプロフィール情報を持つユーザに対して、発話情報を参照した店舗推薦を行うシステムを構築した。MemN2N による推薦システムの出力は総店舗数の次元を持つベクトルであり、各次元位置に該当する店舗の推薦確率を表現した形をとる。

Personalized Dialog dataset から発話ログ情報とユーザプロフィール、実際にユーザが受け入れた店舗を抽出し、推薦システムのモデル学習に使用した。学習に用いた教師は各店舗に該当する次元位置が 1 となるワンホットベクトルであり、発話ログは対話システムが推薦を行う前までのものを使用した。

推定したユーザの発話意図とファセット項目同様に、推薦システムの出力ベクトルも対話戦略の入力として使用する。

4.3 対話戦略

本研究では Xiujun らの対話システム同様に、深層強化学習による対話戦略をとるエージェントを構築する。

強化学習における問題設定では、環境を定義し、その環境下で動作するエージェントに対し、状態を与える。エージェントは受け取った状態から、自身の持つ方策を基に次にとるべき行動を決定する。環境はエージェントの行動に対し、次の状態とその行動の良し悪しを定量化した報酬を与える。以上の流れを 1 ステップと定義し、エージェントが目標を達成する、あるいは

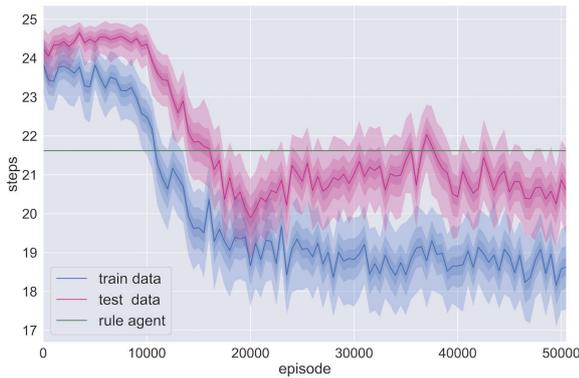


図 2: 対話システムの発話回数

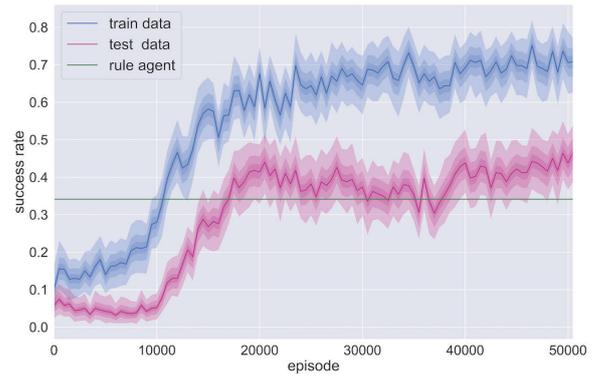


図 3: 対話成功率

は特定の条件で目標達成の失敗とみなされるまで繰り返す。このサイクルをエピソードと呼び、エージェントはエピソードを繰り返していく中で、自身の方策によって求められる行動価値を更新していく。Deep Q-Network(DQN)[Volodymyr 13]は行動価値を多層ニューラルネットワークで関数近似した深層強化学習の中でも基本的な手法である。本研究では、DQNの枠組みでの対話戦略を実現し、ユーザの発話意図とファセット項目、推薦システムの出力から次にとるべき発話の行動価値を最大化するような学習を行う。

5. 環境設計

強化学習の問題設定では、エージェントの発話行動に対して臨機応変にやりとりを行う環境が必要である。[Xiujun 16]らは映画予約に関する対話データをクラウドソーシングで収集し、ルールベースで応答文を選択するユーザシミュレータを作成した。

本研究では Xiujun らのユーザシミュレータを参考に、Personalized Dialog dataset から抽出したユーザ発話を用いてシミュレータを作成し、強化学習における環境として扱う。ユーザシミュレータの仕様を以下に示す。

- ユーザはプロフィール情報「性別、年齢層、好みの料理、菜食主義か否か」とレストランに求めるファセット項目を持ち、最終的に受け入れるレストランが必ず存在する。
- ユーザの持つファセット項目は会話の途中で移り変わる可能性がある。
- ユーザはエージェントに対して常に協力的な応答をする。(ファセット項目等の質問に対しては必ず答える)
- 一度のユーザの発話を状態、それに対するエージェントの発話を行動とし、ある状態において行動をとることを1ステップとする。
- ユーザはエージェントの行動に対し、適当な報酬を与える。
- エージェントによりユーザの満足するレストランが推薦された場合、エピソードを終了する。ステップ数が25に達しても終了する。

6. 評価実験

5.章で説明したユーザシミュレータ環境を用いて、提案システムの検証を行う。ユーザのプロフィール情報、目的とする

ファセット項目を学習用、評価用に12,000件ずつ用意し、これらを基にシミュレータが発話を行うようにした。

6.1 評価方法

エージェントの学習が経過するにつれて、提案システムの発話回数と対話の成功率がどのように変化するかを確認する。

本研究では対話システムの発話回数が短いほど、ユーザにとって必要な労力を省くことができるため、良い対話戦略と考える。対話の成功率に関しては、店舗の推薦成功率と同義であり、ユーザがシステムの推薦を受け入れた時点で対話の成功とみなす。これらの指標に関して、ファセット項目を全て聞き出してから店舗推薦を行うルールベースのエージェントによる対話システムとの比較を行う。また、学習後の対話システムによるやりとりの内容を確認し、定性的な評価も行う。

6.2 実験結果

図2に1エピソードに要した対話システムによる発話回数の推移を示す。図中、*train data*と*test data*はそれぞれ学習データと評価データに対する提案システムの発話回数を表している。また*rule agent*はルールベースの対話システムによる、評価データに対する発話回数である。ルールベースのシステムがおよそ21.6回の発話を要したのに対し、提案システムのエージェントでは、学習後の状態で、評価データに対してもおよそ20.5回(図2 *test data*のグラフ右端の時点)と効率の良いやりとりを行うことができています。

図3に示した各グラフは図2と同様の条件での対話成功率を表している。エージェントの学習を繰り返すにつれて、対話成功率は向上し、ルールベースを上回る結果になっている。

表1は学習後の提案システムによる実際のやりとりの内容である。ルールベースによる対話システムの場合、全てのファセット項目を聞き出し、店舗の推薦行動に移ることになるが、表1左側に示した提案システムの対話では、推薦の確信度に応じて必要なファセット項目のみを聞き出し、効率良く対話を成功させていることがわかる。一度目の推薦のように上手くいかない状況になると、再度ファセット項目を聞き出し、ユーザが真に求める条件を探る働きかけを行う様子が確認できる。表1右側は対話失敗とみなされた例である。序盤からファセット項目を全て聞き出しているが、最大25回可能な発話の中で推薦が成功しなかったために、対話失敗となっている。

6.3 考察

本研究では、対話システムの発話数を短くすることに成功し、対話成功率を向上させた。一方で、ユーザの目的を満足させることのできないやりとりも多く存在した。今回のタスクにおい

表 1: 学習後の提案システムによる対話例

success dialogue example	failure dialogue example
<p><u>User</u>: Can you book a table in Madrid? <u>Agent</u>: What type of cuisine would you like to eat? <u>User</u>: With Italian food. <u>Agent</u>: May I suggest this option: resto_madrid_cheap_italian_7stars_2 <u>User</u>: No I don't like that. <u>Agent</u>: Is there any change? <u>User</u>: Instead could it be with British cuisine. <u>Agent</u>: Is there any change? <u>User</u>: No. <u>Agent</u>: May I suggest this option: resto_madrid_moderate_british_7stars_1 <u>User</u>: Let 's do it.</p>	<p><u>User</u>: Can you book a table with French cuisine in Bombay? <u>Agent</u>: Would you mind telling me your price range? <u>User</u>: I am looking for a moderate restaurant. <u>Agent</u>: How many people would be in your party? <u>User</u>: I'd like to book a table for two people. <u>Agent</u>: Is there any change? <u>User</u>: Instead could it be in a cheap price range? <u>Agent</u>: Is there any change? <u>User</u>: No. <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_7stars_2 <u>User</u>: Do you have something else? <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_3stars_1 <u>User</u>: No I don't like that. <u>Agent</u>: Is there any change? <u>User</u>: No. <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_8stars_1 <u>User</u>: No I don't like that. <u>Agent</u>: Is there any change? <u>User</u>: No. <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_4stars_2 <u>User</u>: Do you have something else? <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_3stars_2 <u>User</u>: No I don't like that. <u>Agent</u>: May I suggest this option: resto_bombay_cheap_french_1stars_1 <u>User</u>: No I don't like that. ... </p>
<p>推薦に必要なファセット項目のみを聞き出し、 効率の良いやりとりを行うことに成功している。</p>	<p>何度も推薦に失敗し、最終的にユーザの満足のいく 店舗を推薦することが出来ずに終了している。</p>

て、対話の成功には推薦システムの性能が大きく関係しているため、推薦システムがユーザの嗜好をうまく汲み取れない状況において、対話の成功は非常に困難になる。また、本研究では一度の対話で行うことができる発話回数が限られている。そのため、ルールベースの対話システムのように、対話の序盤にファセット項目を全て聞き出し、その後、立て続けに推薦する対話戦略を用いたとしても、対話成功は難しいと考えられる。以上のことから、対話に失敗したエピソードが対話戦略として悪いものであるとは、一概に断定することはできない。事実、表 1 右側の失敗した対話例のように、全てのファセット項目を聞き出すことが出来ていても、推薦が原因で失敗した対話が多く存在した。この対話例は、推薦の確信度の低さや立て続けの推薦失敗という状況から、ファセット項目の修正が無いかを再度確認している点で、対話戦略としては、むしろ優れていると考えられる。

7. おわりに

本稿では、ユーザの目標が明示的でない状況での目的指向型対話を取り上げ、ユーザに対する推薦が求められる問題設定において、発話情報を利用した推薦システムの予測に基づいた対話戦略をとるシステムを提案した。さらに、ファセット項目の収集と推薦を混在させ、状況に応じて柔軟に発話をするような、人間らしい効率的なやりとりを行う対話システムの実現に成功した。一方で、本研究ではユーザ、システム共に非常に限ら

れた発話行動の中でしか検証ができていない。また、レストラン検索という限定的な問題設定下での対話システムになっている。今後はレストラン検索等の単一のタスクだけでなく、オープンドメインで多様な発話行動を想定した対話システムを構築する必要がある。

参考文献

- [Xiujun 17] Xiujun Li, Yun-Nung Chen, Lihong Li, Jianfeng Gao, Asli Celikyilmaz : End-to-End Task-Completion Neural Dialogue Systems, IJCNLP (2017)
- [Yueming 18] Yueming Sun, Yi Zhang : Conversational Recommender System, SIGIR (2018)
- [Chaitanya 17] Chaitanya K. Joshi, Fei Mi, Boi Faltings: Personalization in Goal-oriented Dialog, NIPS (2017)
- [Sainbayar 15] Sainbayar Sukhbaatar, Arthur Szlam, Jason Weston, Rob Fergus: End-To-End Memory Networks, NIPS (2015)
- [Volodymyr 13] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, Martin Riedmiller: Playing Atari with Deep-Reinforcement Learning, NIPS Deep Learning Workshop (2013)
- [Xiujun 16] Xiujun Li, Zachary C. Lipton, Bhuwan Dhingra, Lihong Li, Jianfeng Gao, Yun-Nung Chen : A User Simulator for Task-Completion Dialogues, (2016)

文脈を考慮した対話のニューラルネットワークモデルの 日本語注文対話への適用

Applying a neural network model of a dialogue considering the context
to Japanese ordering dialogue

村山 友理 *1 小林 一郎 *1 森田 武史 *2 中野 有紀子 *3 山口 高平 *2
Yuri Murayama Ichiro Kobayashi Takeshi Morita Yukiko Nakano Takahira Yamaguchi

*1お茶の水女子大学 *2慶應義塾大学 *3成蹊大学
Ochanomizu University Keio University Seikei University

There are many works on dialogue systems considering the context using a neural network. In this work, to realize a robot cafeteria, we applied a neural network model to a process of an ordering dialogue. We created a Japanese ordering dialogue dataset and conducted an experiment with it. As a result, we obtained a mean test error rate of low value.

1. はじめに

近年、文脈を考慮した対話における記憶装置付きニューラルネットワークモデルとして様々なモデルが提案されている [Graves 16, Graves 14, Weston 14, Sukhbaatar 15, Kumar 16, Vinyals 15, Yang 18]. 本研究では、ロボット喫茶店の実現を目指し、喫茶店における注文対話に取り組んでおり、注文対話の課題として、複数の人からの注文や注文の変更、注文の確認などが挙げられる。この課題を解くには客の発言の記録や、文脈を理解していることが必要であり、注文対話の処理にニューラルネットワークモデルを適用することを考えた。適用するにあたり、日本語の注文対話データセットを作成し、それについて実験を行なった。結果は、平均テスト誤り率として低い値を得ることができた。

2. 記憶装置付きニューラルネットワーク

Memory Networks [Weston 14] は、巨大メモリとメモリへの入出力操作を行う学習コンポーネントから構成されるメモリ付きニューラルネットワークである。メモリに文脈情報などを格納しておき、そこから質問に関する情報を連鎖的に読み出し利用することにより、文脈を考慮した質問応答を可能にしている。Memory Networks では、メモリに対して Hard Attention を用いており、それは微分不可能なので、学習データをアノテーションし、質問に関する情報の選択について別途学習させる必要がある。

End-To-End Memory Networks [Sukhbaatar 15] は、Memory Networks の質問に関する情報の選択において、微分可能な Soft Attention を用いたモデルである。それを用いることにより、パラメータを end-to-end に学習することができ、学習データをアノテーションする必要がなくなるため、より多様なデータを扱うことができる。

Dynamic Memory Networks [Kumar 16] は、End-To-End Memory Networks に対して入力文や質問文、メモリ内部のベクトルのエンコードに GRU を用いたモデルである。

Neural Turing Machine [Graves 14] は、読み書き可能な外部メモリを持つ LSTM である。メモリに対して Soft Attention を用いて読み出しと書き込みを行う。Differentiable Neural Computer [Graves 16] は、Neural Turing Machine のメモリ

制御に関するアクセスメカニズムをより改善したモデルであり、質問応答のタスクにおいて記憶装置付きニューラルネットワークの中で最も良い結果を達成している。本研究では、このモデルを採用し注文対話の実現を目指す。Differentiable Neural Computer について次章で詳細に説明する。

3. Differentiable Neural Computer

従来のニューラルネットワークでは、変数やデータ構造の表現や、長期間におけるデータの保存に能力の限界があると議論されてきた。Differentiable Neural Computer (DNC) は、外部メモリを用意し、それについて読み書きができるニューラルネットワークを構築することによって課題の解決を試みた。

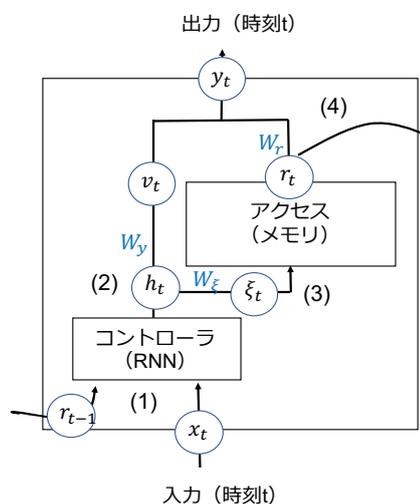


図 1: DNC の全体図

DNC の外部メモリにはヘッドがついており、書き込みヘッドによってメモリの書き換え、読み出しヘッドによってメモリの読み出しが行われる。

1. DNC 内のコントローラ (RNN) は、毎時刻につき、入力 x_t と前時刻でメモリから読み出した情報 r_{t-1} を合わせて受け取り、 h_t を出力する。

連絡先: 村山友理, お茶の水女子大学大学院人間文化創成科学研究科
理学専攻情報科学コース小林研究室, 〒 112-8610 東京都文京区大塚
2-1-1, murayama.yuri@is.ocha.ac.jp

2. h_t を線形変換し、出力 $v_t = W_y h_t$ とメモリを制御するためのベクトル $\xi_t = W_\xi h_t$ に分ける。
3. ξ_t によってメモリへの書き込みが行われ、メモリの状態が更新される。
4. メモリからの読み出しも行われ、読み出された情報 r_t は RNN の出力に $y_t = v_t + W_r r_t$ のように加算されると同時に、次時刻の RNN への入力に回される。

以上の処理を繰り返すことにより、メモリへの読み書き操作を取り込んだニューラルネットワークが実現される。これらのシステムは微分可能であるため、メモリの使い方も含めて end-to-end に学習することができる。メモリを付け加えたことにより、DNCはより複雑な情報処理を行えるようになり、文脈を踏まえた質問応答でも高い精度を実現している。また、グラフ上の最短経路探索問題やブロックパズルの問題など、様々なジャンルの問題を解くことができ、その汎用性の高さを期待させる。

DNCの質問応答タスクでは bAbI データセット [Weston 15] を用いている。bAbI データセットは、人間の行う推論を真似た学習ができるように人工的に作られたデータセットであり、タスク毎に “John is in the playground. John picked up the football. Bob went to the kitchen. Where is the football? A:playground” のようなショートストーリーとそれについての質問と答えを含んだデータが 20 種類用意されている。公開されているデータセット *1 の en-10k サブセットでは、それぞれのタスクに対して、train 10,000 個、test 1,000 個のデータが提供されている。GravesらはDNCを用いた実験で、平均テスト誤り率 3.8%を達成したと報告している。本研究では、bAbI データセットを参考に日本語注文対話データセットを作成し、DNCを用いた注文対話を行う。

4. 日本語注文対話データセットの作成

本研究では、喫茶店での注文の場面を想定し、bAbI データセットの 20 タスクの内 10 タスクを参考に日本語の注文対話データセットを作成した。表 1 に作成した注文対話データセットの例を示す。尚、例では A, B, C とアルファベット順に並んでいるが、この順番はランダムにしている。

- Single Supporting Fact (一文参照)
bAbI データセットにおいて “Mary went to the bathroom. John moved to the hallway. Mary travelled to the office. Where is Mary? A:office” のように 1 文を見れば質問に対して答えられるようなタスクとなっており、本データセットでは「～の注文は?」という質問に対して該当する客の発言 1 文を見れば答えを出せるタスクとして用意した。
- Two Supporting Facts (二文参照) と Three Supporting Facts (三文参照)
Single Supporting Fact と同様に、それぞれ 2 文、3 文を参照すれば答えられるタスクとなっている。
- Conjunction (接続詞)
bAbI データセットでは接続詞の “and” を扱っており、本データセットでもそれに対応して “と” を扱うようにした。

- Yes No Questions (イエスノー質問)
質問に対して、はい/いいえで答えるタスクである。
- Counting (数え上げ)
bAbI データセットでは “Daniel picked up the football. Daniel dropped the football. Daniel got the milk. Daniel took the apple. How many objects is Daniel holding? A: two” のように人物が物を拾ったり落したりして最終的に持っている物の数を答えるタスクだが、本研究では注文の場面を想定しているため、料理の注文数を答えるタスクとした。
- Lists (列挙)
Counting タスクのように人物が物を拾ったり落としたりし、最終的に持っている物のリストを答えるタスクであるが、本データセットでは「～の注文は?」という質問に加えて「全員の注文は?」といった質問にも答えるようにした。
- Simple Negation (否定)
否定表現を扱うタスクであり、本データセットでは注文の場面で想定される注文の変更を扱うとした。
- Basic Coreference (基本的共参照)
“Daniel was in the kitchen. Then he went to the studio. Sandra was in the office. Where is Daniel? A:studio” において代名詞 he が Daniel を指していることが分からないと答えられないようなタスクであり、注文対話においても「私もそれで」の “それ” が何を指すかを問うタスクとした。
- Compound Coreference (複合的共参照)
Basic Coreference における代名詞が複数の人物や物を意味する場合に、きちんと指し示すことができるかを試すタスクである。

本データセットでは、Counting タスク 408 個、Basic Coreference タスク 132 個、Compound Coreference タスク 264 個、他はそれぞれ 1,320 個作成し、総数 10,044 個の注文対話データセットを構築した。モデルの学習と評価にはそれらを 9 対 1 に分割して用いた。

5. 実験

5.1 実験設定

作成した注文対話データセットに対して Differentiable Neural Computer を用いて実験を行なった。表 2 に設定したハイパーパラメータの詳細を示す。7 万回学習を行ない、誤り率によってモデルを評価した。

5.2 実験結果

実験結果を図 2 に示す。

Yes No Questions タスクが最も誤り率が高かったが、学習が進むにつれて値は低くなっていった。次に誤り率が高かったのが Basic Coreference タスクであり、これも学習回数を重ねる毎に徐々に下がっていった。また、Simple Negation タスクは、1 万回学習を行なった時点での誤り率はやや高かったが、2 万回以降 0 になった。平均誤り率は 7 万回での評価において 0 になるまで緩やかに減少していった。

*1 <http://www.thespermwhale.com/jaseweston/babi/tasks-1-20.v1-2.tar.gz>

表 1: 作成した注文対話データセットの例

Single Supporting Fact (一文参照) A: ハムサンド B: クロワッサン C: カルボナーラ A の注文は？ ハムサンド B の注文は？ クロワッサン C の注文は？ カルボナーラ	Counting (数え上げ) A: グレープフルーツ ジュース B: グレープフルーツ ジュース C: レモンティー グレープフルーツ ジュース の注文数は？ 2 レモンティー の注文数は？ 1
Two Supporting Facts (二文参照) A: ハムサンド B: クロワッサン C: カルボナーラ A: アップルパイ B: パナナブレッド C: チョコレート ケーキ A の注文は？ ハムサンド, アップルパイ B の注文は？ クロワッサン, パナナブレッド C の注文は？ カルボナーラ, チョコレート ケーキ	Lists (列挙) A: ポロネーゼをシェアで A: ハムサンド B: クロワッサン C: カルボナーラ A の注文は？ ハムサンド, ポロネーゼのシェア B の注文は？ クロワッサン, ポロネーゼのシェア C の注文は？ カルボナーラ, ポロネーゼのシェア 全員の注文は？ ハムサンド, クロワッサン, カルボナーラ, ポロネーゼ
Three Supporting Facts (三文参照) A: ハムサンド B: クロワッサン C: カルボナーラ A: アップルパイ B: パナナブレッド C: チョコレート ケーキ A: アップルジュース B: グレープフルーツ ジュース C: カプチーノ A の注文は？ ハムサンド, アップルパイ, アップルジュース B の注文は？ クロワッサン, パナナブレッド, グレープフルーツ ジュース C の注文は？ カルボナーラ, チョコレート ケーキ, カプチーノ	Simple Negation (否定) A: ハムサンド B: クロワッサン C: カルボナーラ B: クロワッサンではなくてハンバーガーにします A の注文は？ ハムサンド B の注文は？ ハンバーガー C の注文は？ カルボナーラ
Conjunction (接続詞) A: ハムサンドとアップルパイとアップルジュース B: クロワッサンとグレープフルーツジュース C: カルボナーラ A の注文は？ ハムサンド, アップルパイ, アップルジュース B の注文は？ クロワッサン, グレープフルーツジュース C の注文は？ カルボナーラ	Basic Coreference (基本的共参照) A: グラタン B: 私もそれで C: ハムサンド A の注文は？ グラタン B の注文は？ グラタン C の注文は？ ハムサンド
Yes No Questions (イエスノー質問) A: アップルパイ B: パナナブレッド C: チョコレート ケーキ A の注文はアップルパイですか？ はい B の注文はチョコレートケーキですか？ いいえ C の注文はパナナブレッドですか？ いいえ	Compound Coreference (複合的共参照) A: グラタンとアイスティー B: 私もそれらで C: ハムサンドとアップルジュース A の注文は？ グラタン, アイスティー B の注文は？ グラタン, アイスティー C の注文は？ ハムサンド, アップルジュース

表 2: ハイパーパラメータの詳細

項目	仕様
LSTM のサイズ	256
バッチサイズ	1
学習率	1e-4
メモリの次元	256 × 64
読み出し回数	4
書き込み回数	1
最適化手法	RMSProp, momentum=0.9
重み初期化	~N(0, 0.1)

5.3 考察

Yes No Questions タスクは質問に対して、本データセットにおいて唯一はい/いいえのどちらかを答えるものであるが、間違えた例の全てにおいて正解が「はい」のところを「いいえ」と誤答するなど、正解とは逆のものを答えてしまっていた。Basic Coreference タスクについては、データセットの数が最も少ないタスクであり、データセット数が学習に影響したものと考えられる。Simple Negation タスクは、間違えた例

の全てが正解が“ポロネーゼ”の場合であり、誤答として“ハンバーガー”と“ミート”が多く見られ、メインの料理の中で間違えていた。今回作成したデータセットは語彙数も 72 と少なく、かなり単純なものだったため、学習の難易度は比較的低かったと思われる。

6. おわりに

本研究では、喫茶店における注文対話の処理にニューラルネットワークモデルを適用した。日本語の注文対話データセットを作成し、Differentiable Neural Computer を用いて実験を行なった結果、平均テスト誤り率として低い値を得ることができた。

今回、bAbI データセットを参考に注文対話を作成したが、今後の課題として、実際の注文対話のコーパスを収集して多様な注文対話に対応できるようにしていきたいと考えている。また、実際の喫茶店で想定される、料理に関する質問などは、文脈だけから答えることは難しいため、知識を導入することによって、より複雑な対話理解に取り組んでいきたい。

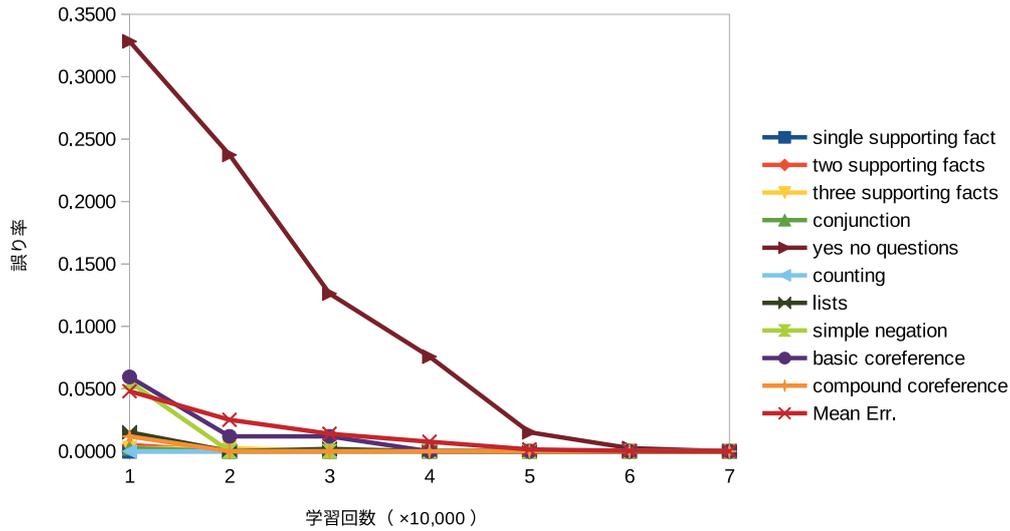


図 2: 実験結果

謝辞

本研究は、科学技術振興機構 (JST) 戦略的創造研究推進事業 (CREST) 「実践知能アプリケーション構築フレームワーク PRINTEPS の開発と社会実践」(JPMJCR14E3) の支援によって実施した。

参考文献

- [Graves 16] Alex Graves, Greg Wayne, Malcolm Reynolds, Tim Harley, Ivo Danihelka, Agnieszka Grabska-Barwińska, Sergio Gómez Colmenarejo, Edward Grefenstette, Tiago Ramalho, John Agapiou, et al. 2016. Hybrid computing using a neural network with dynamic external memory. *Nature* 538(7626):471476.
- [Graves 14] Graves, A., Wayne, G. Danihelka, I. Neural Turing machines. Preprint at <http://arxiv.org/abs/1410.5401> (2014).
- [Weston 14] Weston, J., Chopra, S. Bordes, A. Memory networks. Preprint at <http://arxiv.org/abs/1410.3916> (2014).
- [Sukhbaatar 15] Sainbayar Sukhbaatar, Jason Weston, Rob Fergus, et al. 2015. End-to-end memory networks. In *Advances in neural information processing systems*. pages 2440-2448.
- [Kumar 16] Ankit Kumar, Ozan Irsoy, Peter Ondruska, Mohit Iyyer, James Bradbury, Ishaan Gulrajani, Victor Zhong, Romain Paulus, and Richard Socher. 2016. Ask me anything: Dynamic memory networks for natural language processing. In *International Conference on Machine Learning*. pages 1378-1387.
- [Vinyals 15] Vinyals, O., Fortunato, M., Jaitly, N. Pointer networks. In *Advances in Neural Information Processing*

Systems Vol. 28 (eds Cortes, C et al.) 26922700 (Curran Associates, 2015).

- [Yang 18] Hyochang Yang, Sungzoon Cho, et al. 2018. Finding remo (related memory object): A simple neural architecture for text based reasoning. arXiv preprint arXiv:1801.08459 .
- [Weston 15] Weston, J., Bordes, A., Chopra, S. Mikolov, T. Towards AI-complete question answering: a set of prerequisite toy tasks. Preprint at <http://arxiv.org/abs/1502.05698> (2015).

PLSTMによるチャットボット対話の精度検証

Evaluations for personalized chatbot based on LSTM

奥井 颯平

Sohei OKui

中辻 真

Makoto Nakatsuji

NTT レゾナント

NTT Resonant, Inc

LSTM-based chatbot systems are now commercially accepted. Existing systems, however, do not focus on individual user's utterance history, thus it can not select a response according to the individual's characteristics. To solve this problem, we proposed a Personalized LSTM model (PLSTM) that considers the sequence of user's previous utterances as well as his/her current one and then selects the response targeted to him/her. It extracts the context vector by applying self attention mechanism in encoding user's utterances; it updates user's current utterance vector by reflecting the context vector to his/her current vector. According to the evaluations based on conversation dataset extracted from actual Q&A service, Oshiete-goo, we confirmed that PLSTM can predict the response with high accuracy by using the individual's utterance history. This method has already been implemented to the love advice chatbot, Oshiel, existed in actual AI service, Mydaiz.

1. はじめに

LSTMを用いた対話応答学習がチャットボットサービスへの応用に有用であると注目されている。例えば、ドラマキャラと会話できるチャットボット「AI家売るオンナ」^{*1}、「AIカホコ」や^{*2}、女子高生AIチャットボット「AIりんな」、恋愛相談AI「AIオシエル」^{*3}などが有名である。これらのサービスでは、インスタントメッセージサービスやQ&Aコミュニティサービス上にAIキャラクターが登場し、ユーザと雑談や恋愛相談といったコミュニケーションを行う。特に、AIカホコ等のチャットボットのように、LINE等のインスタントメッセージサービス上に登場したAIキャラクターとユーザは、その場限りではなく、日をまたがって継続的にコミュニケーションを楽しむことが多くなっている。そうした中で、各ユーザに対して、個人化されたAI応答を提供することが今後のユーザ満足度向上に繋がる可能性があると考えられる。しかし、現状のチャットボットはユーザの名前や性別などの登録されたユーザ情報や、GPSから把握される生活エリアに基づいたルールベースでの個人化しか実現できていない。つまり、ユーザの現在の発言を基にして次のAI応答を選択しているのみであり、ユーザとAIキャラクターとの過去のコミュニケーションを活かしきれていない。そのため、実際に人間の間でコミュニケーションを円滑にしたり、親しみを感じさせるために重要となる過去のやり取りから推定されるユーザ興味や性格に応じた気の利いたAI応答は実現できていない。

この問題に対し、我々は個人化されたAI応答を実現するPLSTM [奥井 18] を提案してきた。PLSTMはユーザとAIの過去のコミュニケーション履歴を現在のユーザ発言へのAI応答に用いる。特に時時刻刻と変化するユーザ興味や状況に対応するため、PLSTMはEncoder-Decoderモデルで利用されているAttentionメカニズムを応用し、ユーザの過去の発言列の中で、現在のユーザ発言と関連性の高いトピックを抽出し、現在のユーザ発言へ反映させる。このように過去の関連するトピ

クを現在の発言に反映させることで、より個人化されたユーザ満足度の高いAI応答選択を実現する。本稿では「AIオシエル」で用いた時系列情報を含むチャットボット対話データを用いてPLSTMの精度を検証する。

2. 関連研究

深層学習を用いて対話を個人化する試みは、深層学習を用いた情報推薦の研究 [Elkahky 15] に近い。深層学習ではない試みとしては、明示的な概念体系であるセマンティクスを用いて、直近のユーザ行動と興味概念が体系的に近い概念に属する過去のユーザ行動を組合せ、次のユーザへの推薦を決定する研究がある [Nakatsuji 12]。深層学習に基づく手法は、特徴量の人手調整や、言語ツール、外部リソースを取得する手順を必要としないメリットがある。例えば、長文回答構築手法 [中辻 19] では質問の背後にあるカテゴリやタイトルなどの情報を単語ベクトルに埋め込むことで質問に使用された単語の背景に合った回答を抽出し、結論を表す文と結論に対する補足を表す文の表現ベクトルを計算する。PLSTMは過去のユーザ発言を、潜在的に関連する過去のユーザ発言トピックをとって用い、外部リソースを活用せず個人の特性に応じた特徴ベクトルを学習する。QAシステムにおいてAIの応答を決定するにあたり、生成と選択のアプローチがあるが、本稿における著者らの一次検証において、応答生成は応答選択タスクに比べて性能が劣る傾向が見られた。そのため、本稿ではQA-LSTMのような応答選択型のフレームワークとPLSTMを比較する。

3. QA-LSTM

本章では、提案手法の土台となるQA-LSTM [Tan16] フレームワークについて説明する。

はじめに、LSTMについて説明するとともに、本稿における用語を定義する。入力文を $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ とする。ここで、 x_t は t 番目の単語ベクトルである。 t 番目の隠れベクトル h_t は以下の式で更新される。

連絡先: 中辻 真, nakatsuji@nttr.co.jp

*1 <https://www.ntv.co.jp/ieuru.gyakushu/AI>

*2 <http://www.ntv.co.jp/kahogo-kahoko/special/index.html>

*3 <https://oshiete.goo.ne.jp/ai>

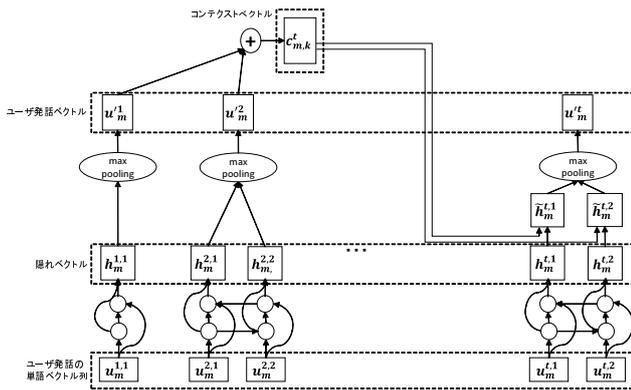


図 1: Context QA-LSTM

$$\begin{aligned}
 \mathbf{i}_t &= \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \\
 \mathbf{f}_t &= \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \\
 \mathbf{o}_t &= \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o) \\
 \tilde{\mathbf{c}}_t &= \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) \\
 \mathbf{c}_t &= \mathbf{i}_t * \tilde{\mathbf{c}}_t + \mathbf{f}_t * \mathbf{c}_{t-1} \\
 \mathbf{h}_t &= \mathbf{o}_t * \tanh(\mathbf{c}_t)
 \end{aligned}$$

LSTM ブロックは3つのゲート(入力ゲート \mathbf{i}_t , 忘却ゲート \mathbf{f}_t , 出力ゲート \mathbf{o}_t)とメモリセル \mathbf{c}_t から構成される。 σ はシグモイド関数である。 $\mathbf{W} \in R^{H \times N}$, $\mathbf{U} \in R^{H \times H}$, $\mathbf{b} \in R^{H \times 1}$ は本ネットワークにおける学習パラメータである。単方向の LSTM の場合、各トークンより以前の情報を引き継いで文脈情報を学習していく一方で、各トークンの後に現れるトークンからの文脈情報を考慮することが難しい。BiLSTM は、前後の文脈情報を双方向に処理し、2つの出力ベクトルを得る。BiLSTM ブロックの出力は、前後方向の出力2つを以下の式のように連結したものである $\overrightarrow{h}(t) = \overrightarrow{h}(t) \parallel \overleftarrow{h}(t)$ 。

QA-LSTM のフレームワークは以下の通りである。まず質問 q , 回答候補 a からなる、与えられた入力ペア (q, a) に対し、 q , a それぞれについて単語ベクトル化する。次に、それぞれ別々の BiLSTM ブロックに単語ベクトル化したシークエンスを入力として与える。BiLSTM から出力されたベクトルに対して max pooling を行い、双方向分の2つの出力ベクトルを連結することにより、 q においては \mathbf{o}_q , また a においては \mathbf{o}_a として固定長の分散表現にする。最後に、入力ペア (q, a) に対してコサイン類似度 $\cos(\mathbf{o}_q, \mathbf{o}_a)$ によってスコアリングを行う。

学習要素は以下のヒンジロス関数によって定義する。

$$\mathcal{L} = \max\{0, M - \cos(\mathbf{o}_q, \mathbf{o}_a^+) + \cos(\mathbf{o}_q, \mathbf{o}_a^-)\} \quad (1)$$

ここで \mathbf{o}_a^+ 本来の正解の回答の出力ベクトルであり、 \mathbf{o}_a^- は全回答空間からランダムに選出された不正解の回答の出力ベクトルである。また、 M は損失関数におけるマージンである。複数の正解回答を持つ質問については、その質問に紐づく各回答についてそれぞれ複数の別のペアとして扱う。

4. PLSTM

本章ではユーザの過去の発話列から、現在の発話と関係付けられるトピックをアテンションモデルを用いて抽出する PLSTM について説明する。まず、アテンションメカニズムによるユー

ザの過去の発話列を現在の発話と関係付ける方法について述べ、その次に、AI 応答の個人化により選択された応答例について述べる。

4.1 アテンションメカニズム

本稿で提案するアテンションメカニズムについて説明する。図 1 に提案するアテンションメカニズムのイメージを示す。

まず、用語を定義する。

ユーザの数を M とし、 m 番目のユーザの発話を $\mathbb{U}_m = \{\mathbf{u}_m^1, \mathbf{u}_m^2, \dots, \mathbf{u}_m^t\}$ とする。ここで、 \mathbf{u}_m^t は t 番目の発話ベクトルである。各発話は、複数の単語トークンからなる。例えば t 番目の発話列は $\{\mathbf{u}_m^{t,1}, \mathbf{u}_m^{t,2}, \dots, \mathbf{u}_m^{t,n_m^t}\}$ と表される。ここで、 n_m^t は m 番目のユーザの t 番目のユーザ発話に含まれる単語長であり、 $\mathbf{u}_m^{t,k}$ は m 番目のユーザの t 番目の発話の中の k 番目の単語ベクトルである。なお、ユーザ発話 \mathbf{u}_m^t に対応する応答は、 \mathbf{a}_m^t であり、その発話ベクトルは \mathbf{a}_m^t , 発話列は $\{\mathbf{a}_m^{t,1}, \mathbf{a}_m^{t,2}, \dots, \mathbf{a}_m^{t,n_m^{t,a}}\}$ と表される。ここで、 $n_m^{t,a}$ は m 番目のユーザの t 番目のユーザ発話への AI 応答に含まれる単語長であり、 $\mathbf{a}_m^{t,k}$ は m 番目のユーザの t 番目の発話への AI 応答の中の k 番目の単語ベクトルである。

次にアテンションを現在の発話ベクトル \mathbf{u}_m^t に反映する手順について述べる。

(1) データセットからあるユーザ m の現在の発話 \mathbf{u}_m^t を一つピックアップする。

(2) ユーザ m の過去の発話系列 $\{\mathbf{u}_m^1, \mathbf{u}_m^2, \dots, \mathbf{u}_m^{t-1}\}$ の各発話に対し、QA-LSTM と同様の方法で発話ベクトルを計算する。例えば $t-1$ 番目の発話ベクトルは、QA-LSTM と同様に、その発話内の単語列に BiLSTM を適用し、出力される n_m^{t-1} 個の隠れベクトル $\{\mathbf{h}_m^{t-1,1}, \dots, \mathbf{h}_m^{t-1,n_m^{t-1}}\}$ に対し max-pooling を適用することで、発話ベクトル \mathbf{u}_m^{t-1} を獲得する。

(3) そして、 t 番目の発話ベクトル \mathbf{u}_m^t を計算する際に、(2) で計算した過去の発話ベクトルを t 番目の現在の発話の k 番目の単語へどれだけ反映するかを決定するコンテキストベクトルを $\mathbf{c}_m^{t,k}$ を以下のように計算する。なお、 \mathbf{V}_a , \mathbf{W}_a , \mathbf{U}_a は重み行列である。

$$\begin{aligned}
 \mathbf{c}_m^{t,k} &= \sum_{j=1}^{t-1} \alpha_{k,j} \mathbf{u}_m^j, \\
 \alpha_{k,j} &= \frac{\exp(e_{k,j})}{\sum_{l=1}^{t-1} \exp(e_{k,l})}, \\
 e_{k,j} &= \mathbf{V}_a^T \tanh(\mathbf{W}_a \mathbf{h}_m^{t,k} + \mathbf{U}_a \mathbf{u}_m^j)
 \end{aligned}$$

このコンテキストベクトルの計算方法は、[Bahdanau 14]における方法を基にしているが、[Bahdanau 14]は Encoder-Decoder model にアテンションを適用している。一方、提案手法は、同一の発話ストリームの中で、現在の発話に過去の発話からアテンションを計算している点で大きく異なる。さらに、提案手法では、過去のユーザの興味は抽象的に捉えることが重要であると考えている。そのため、複数の単語ストリームからより抽象度の高いユーザ発話ベクトルを計算し、各ユーザ発話ベクトルをどの程度、現在のユーザ発話を構成する単語ストリーム内の隠れベクトルに反映するかを決定している。これは、[Bahdanau 14]のように、一連の単語ストリームの中でアテンションを計算している従来方式とは異なる。

次にコンテキストベクトル $\mathbf{c}_m^{t,k}$ を BiLSTM に以下のように反映させることで、提案手法は、過去のユーザ発話を現在の発

表 1: 実験で用いたデータセットの作成例

	質問例	回答例	ユーザ発話	AI 応答
発話文	<p>以前、合コンで知り合ったある男性とこの5ヶ月ほど毎日連絡を取り合ったり、よく2人で数回遊びに行ったりしています。相手は社会人20代で私も社会人の20代です。</p> <p>⋮</p> <p>これは、脈がもうないということなのでしょうか。</p>	<p>相手のことを意識しすぎじゃないかな？考え過ぎだと思う。脈の有無はそんなに意識しないで、まずは気楽に関係を築くようにしましょう。</p>	<p>u^1: 合コンで気になる人ができました。</p> <p>u^2: 5ヶ月間毎日連絡を取り、良く遊びに行きます。</p> <p>u^3: 私は20代の社会人です。</p> <p>u^4: 相手も20代の社会人です。</p> <p>⋮</p> <p>u^t: これは、脈がもうないということなのでしょうか。</p>	<p>a^1: そうなんですね。その後はどうでしたか？</p> <p>a^2: 相手はあなたと連絡するのが楽しいのだと思います。それから？</p> <p>a^3: そうなのですね。</p> <p>a^4: 年齢が近いのはいいですね。</p> <p>⋮</p> <p>a^t: 脈の有無はそんなに気にしなくても良いと思いますよ。</p>

表 2: 回答選択タスクにおける平均適合率の比較

	QA-LSTM	PLSTM-3	PLSTM-5
Top 1	0.05	0.09	0.04
Top 3	0.19	0.21	0.21
Top 5	0.23	0.28	0.24

話の k 番目の隠れベクトル $\mathbf{h}_m^{t,k}$ へ反映することができるようになる。

$$\begin{aligned} \mathbf{z}_k &= \sigma(\mathbf{W}_z[\mathbf{u}_m^{t,k-1}, \mathbf{T}] + \mathbf{U}_z \mathbf{h}_m^{t,k-1} + \mathbf{W}_z^a \mathbf{c}_m^{t,k} + \mathbf{b}_z) \\ \tilde{\mathbf{l}}_k &= \tanh(\mathbf{W}_l[\mathbf{u}_m^{t,k-1}, \mathbf{T}] + \mathbf{U}_l \mathbf{h}_m^{t,k-1} + \mathbf{W}_l^a \mathbf{c}_m^{t,k} + \mathbf{b}_l) \\ \mathbf{l}_k &= \mathbf{i}_k * \tilde{\mathbf{l}}_k + \mathbf{f}_k * \mathbf{l}_{k-1} \\ \mathbf{h}_m^{t,k} &= \mathbf{o}_k * \tanh(\mathbf{l}_k) \end{aligned}$$

ここで、 z は入力 i , 忘却 f , 出力 o を示すトークンであり、入力ゲート \mathbf{i}_k , 忘却ゲート \mathbf{f}_k , 出力ゲート \mathbf{o}_k に対応する。 \mathbf{l}_k はセルメモリベクトルである。 \mathbf{W}_z^a と \mathbf{W}_l^a はアテンションパラメータである。

(4) t 番目の発話ベクトル \mathbf{u}_m^t は、上記手順で更新された n_t^m 個の隠れベクトル $\{\tilde{\mathbf{h}}_m^{t,1}, \dots, \tilde{\mathbf{h}}_m^{t,n_t^m}\}$ に対し max-pooling を適用することで獲得できる。

4.2 AI 応答の個人化

チャットボットシステムにおいて、AI キャラクタに対する過去のユーザ発話が「大好きだよ」であり、現在の発話が「久しぶりだね」である場合、ユーザは AI キャラクタと親密なやり取りを行う傾向があり、結果として「会いたかった」と親密さを演出する応答を行う。一方、過去発話が「眠い今日も疲れた」であり、現在の発話が「久しぶりだね」である場合、ユーザは日常の愚痴をチャットボットにこぼす傾向があり、ユーザを心配する「元気にしてた？」を応答が期待できる。このように PLSTM ではユーザの過去発話列からアテンションメカニズムを活用し、コンテキストベクトルを抽出することで、AI 応答の個人化を実現することが期待される。

5. 評価実験

PLSTM が時系列情報を用いて個人の特徴を考慮した応答を選択することによる有効性を検証するために QA-LSTM との比較による評価実験を行った。

5.1 データセット

PLSTM の評価に日本の QA コミュニティサイト「教えて!goo」*4 において質問が複雑かつ長く、我々に知見のある「恋愛相談」カテゴリのデータセットを活用した。QA データ

をチャットボット向けの対話データに成形した例を表 1 に示す。教えて!goo!における質問文書は“二人の出会い”、“二人の関係”、“自身のこと”、“意中の相手のこと”、“具体的な悩み”などに細分化することができる。質問文書の内容を手で細分化し、ユーザ発話系列 $\{u^1, \dots, u^t\}$ として成形し、チャットボットの応答は回答文書を参考に、手で応答系列 $\{a^1, \dots, a^t\}$ を作成した。このように QA データにおける質問応答を読み解きながら、AI 応答文を割り当てることで、時系列情報を持った約 2 万 5 千件の対話応答データセットを作成した。そして、このデータセットに対してランダムに選択した 1 割を試験データセットとし、9 割を学習データセットとし、検証を実施した。また、「教えて!goo」に蓄積された「恋愛相談」、「旅行」、「ヘルステクア」等の 16 カテゴリ、約 100 万件の QA データを使用し、word2vec [Mikolov 13] により単語ベクトルを獲得した。

5.2 比較手法

本稿では以下の 3 つの手法間で精度比較を行った。

- QA-LSTM [Tan16]: LSTM により質問応答それぞれの特徴ベクトルを学習する。モデルの性質上ユーザ発話の時系列情報は学習・推論に活用されない。
- PLSTM-3:本稿が対象とする著者らの提案手法。3 ステップ前までのユーザ発話からコンテキストベクトルを学習し、ユーザ発話ベクトルを導出する。
- PLSTM-5:本稿が対象とする著者らの提案手法。5 ステップ前までのユーザ発話からコンテキストベクトルを学習し、ユーザ発話ベクトルを導出する。

5.3 評価基準

定量的な評価方法として、選択した応答が元の発話にひもづく応答と同一であれば正答とし、生成した応答を類似度順に並べ平均適合率*5 を算出した。また、定性的な評価方法として検証者が恋愛相談文書を入力し、選択される応答を考察した。

5.4 評価結果

QA-LSTM と PLSTM の定量的な評価結果、及び PLSTM における定性的な評価結果を以下に示す。

5.4.1 定量評価

各手法の平均適合率を表 2 に示す。QA-LSTM と PLSTM-5 との間に精度における差は少ない。一方、QA-LSTM に対して PLSTM-3 は精度が高い。これにより、現時刻の発話から 3 回程度前までの発話列を応答の推論に活用することで、QA-LSTM に対して高い精度で応答を選択できることが読み取れる。一方、現時刻の発話から 5 回程度前までの発話列を応答の推論に活用することの精度への寄与は少ない。よって、直近 3 回前までの発話を参照することが対話応答の精度向上に有用であると考察できる。

*4 <https://oshiete.goo.ne.jp/>

*5 [https://en.wikipedia.org/wiki/Evaluation_measures_\(information_retrieval\)](https://en.wikipedia.org/wiki/Evaluation_measures_(information_retrieval))

表 3: 定性評価の一例: コンテキストにより変化する AI 応答の例

	検証者 X	検証者 Y
過去発話	u_x^1 : 好きな人ができました u_x^2 : その人とはよく食事に行きます。 u_x^3 : とても素敵な人です。 u_x^4 : 告白しようと思うのですが, 大丈夫でしょうか	u_y^1 : 好きな人ができました。 u_y^2 : 目も合わせてくれませんか。 u_y^3 : いつも私に冷たいです。 u_y^4 : 告白しようと思うのですが, 大丈夫でしょうか
ユーザ発話	u_x^t : 脈はありますか?	u_y^t : 脈はありますか?
AI 応答	a_x^t : 脈ありでしょうね	a_y^t : 脈はないとは思いませんよ

5.4.2 定性評価

本モデルが推論時にユーザの過去発話の差により, 異なる応答を選択した例を表 3 に示す. この検証では検証者 X と検証者 Y が「恋愛相談」カテゴリにおける質問応答を想定して, 異なる過去発話と同一の現在発話をそれぞれ作成し, PLSTM における推論結果を比較した. 検証者 X, 検証者 Y の現在の発話は「脈はありますか?」と同様の発話をしているが, 過去に異なる内容の恋愛相談を発話している. 検証者 X は相手とよく食事に行くことを発話し, 検証者 Y は相手に好印象を抱かれていないことを発話しており, それぞれ異なる AI 応答が選択されている. これにより, PLSTM モデルにおいて AI 応答の個人化が実現されていることを確認した.

6. 結論

本稿では, 現在の発話に基づく AI 応答を個人毎に特化したものとするため, ユーザの過去の発話列から重要なトピックを現在のユーザ発話へ反映し, 次の AI 応答の選択に活用する PLSTM の精度を検証した. 結果として直近 3 回前までのユーザの過去発話列を考慮することで, AI 応答の選択において平均適合率の精度向上を確認した. 本手法を活用したチャットボットは株式会社 NTT ドコモ社が提供する my daiz(マイデイズ)*6 という実サービス上で提供されており, 日々ユーザの質問に回答している. 今後はアプリケーション運用により得られた知見をもとに, 以下について検証を進めることとする. ユーザ発話と AI 応答の系列において, ユーザの発話特性を考慮することができる. 例えばレスポンスの速度やユーザ発話の内容により, 対話の品質を評価できる. これらを考慮した損失関数を設計, 精度検証を行う.

参考文献

- [Bahdanau 14] Bahdanau, D., Cho, K., and Bengio, Y.: Neural Machine Translation by Jointly Learning to Align and Translate, CoRR, Vol. abs/1409.0473, (2014)
- [Elkahky 15] Elkahky, A. M., Song, Y., and He, X.: A Multi-View Deep Learning Approach for Cross Domain User Modeling in Recommendation Systems, in Proc. WWW '15, pp. 278-288 (2015)
- [Mikolov 13] Mikolov, T., M., Sutskever, I., Chen, K., Corrado, G., and Dean, J.: Distributed Representations of Words and Phrases and their Compositionality, in Proc. NIPS '13, pp. 3111-3119 (2013)
- [Nakatsuji 12] Nakatsuji, M., Fujiwara, Y., Uchiyama, T., and Toda, H.: Collaborative Filtering by Analyzing Dynamic User Interests Modeled by Taxonomy., in Proc. ISWC '12, pp. 361-377 (2012)

[Tan16] Tan, M., Santos, dos C. N., Xiang, B., and Zhou, B.: Improved Representation Learning for Question Answer Matching, in Proc. ACL '16, pp. 464-473 (2016)

[奥井 18] 奥井 颯平, 中辻 真: LSTM を用いたパーソナル対話技術, 人工知能学会第 32 回全国大会 (2018)

[中辻 19] 中辻 真, 奥井颯平, 藤田明久: LSTM を用いた Non-Factoid 型長文回答構築手法, 電子情報通信学会論文誌 Vol.J102-D, No.4 doi:10.14923/transinfj. (2019)

*6 <https://www.nttdocomo.co.jp/service/mydaiz/>

対話システムにおける履歴を考慮した応答の対話行為推定

Response Dialogue-Act Prediction based on Conversational History

田中 昂志 高山 隼矢 荒瀬 由紀
Koji Tanaka Junya Takayama Yuki Arase

大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

Sequence-to-sequence models are widely used to implement a chatbot. One of their advantages is that a chatbot can be trained in an end-to-end manner. On the other hand, its disadvantage is that a process of response generation is completely black-box. To solve this problem, interpretable response generation mechanism is desired. As a step forward in this direction, we focus on dialogue-acts and propose a method to predict a dialogue-act of the next response based on conversational history. Specifically, we consider both histories of utterances and their dialogue acts. Experiment results using the Switch Board Dialogue Act corpus show that our method achieves 8.6% and 1.2% higher F-score and accuracy on predicting responses' dialogue-acts, respectively, compared to a previous method that only considers the utterance history.

1. はじめに

深層学習による対話システムが盛んに研究されている [Vinyals 15]. 深層学習による対話システムでは、大規模な対話データを学習することで、人手による応答ルールやパターンの設計を行わずに応答を生成できるという利点がある。一方で、応答生成のメカニズムはブラックボックスであり、ある入力発話に対する応答が生成された根拠を知ることは困難である。この問題を解決するため、Zhao ら [Zhao 18] は解釈可能な応答生成モデルの重要性を主張している。本研究では、応答生成の根拠となる有効な手がかりとして対話行為に着目し、対話行為推定に取り組む。また、応答生成においては対話行為情報が有効であることが示されており [Cervone 18], 応答の対話行為を推定することは応答生成の性能向上への寄与も期待できる。

対話は一般的に発話と応答の系列であり、ある時点で生成すべき応答の対話行為の推定には過去の発話の履歴を考慮することが有効と考えられる。既存研究 [大原 18] では発話・応答の系列を用いて応答の対話行為を推定しているが、過去の対話行為の系列は考慮していない。対話行為の系列を独立に考慮することで、過去の対話行為の系列と次の応答の対話行為との関係を直接的に学習できると期待できる。例えば、「あいづち」の発話に対しては一意に「あいづち」の発話が入力された場合には、「説明」の発話に対して「あいづち」の発話が入力された場合には、「説明」の対話行為を持つ応答を続ける、「理解」の発話に対して「あいづち」の発話が入力された場合には、「質問」の対話行為を持つ応答を返すなど、対話行為の系列を用いることで高精度な応答の対話行為推定が可能となると期待できる。

そこで、本研究では応答の対話行為を対話の文脈と対話行為の系列を用いて推定する手法を提案する。提案手法では、対話の文脈を捉える Recurrent Neural Network (RNN) と対話行為の系列を捉える RNN をそれぞれ構築し、それぞれの出力を用いて次の応答の対話行為を推定する。

電話での会話を書き起こし、発話毎に対話行為がアノテートされた Switch Board Dialogue Act (SwDA) コーパス^{*1}を

連絡先: 田中 昂志, 大阪大学大学院情報科学研究科,
tanaka.koji@ist.osaka-u.ac.jp

*1 <https://catalog ldc.upenn.edu/LDC97S62>

用い、Precision, Recall, F 値のマクロ平均と全体の Accuracy を指標として評価実験を行った。その結果、大原らの手法と比較して F 値のマクロ平均においては 8.6%, 全体の Accuracy においては 1.2% 精度が向上することが示された。

2. 関連研究

対話行為推定の研究には、発話テキストからその発話の対話行為を推定する発話の対話行為推定と、発話の系列から次の応答の対話行為を推定する応答の対話行為推定が存在する。

発話の対話行為推定の研究として、Kalchbrenner ら [Kalchbrenner 13] は発話の局所的な特徴を捉えた表現を得る Convolutional Neural Network (CNN) と発話の文脈表現を得る RNN を用いた手法を提案している。SwDA コーパスを用いて実験した結果、既存の機械学習を用いた対話行為推定の手法を上回る精度を達成している。また Khanpour ら [Khanpour 16] は発話を入力とする多段の RNN を提案している。SwDA コーパスを用いて実験した結果、80.1% の精度で発話の対話行為の推定を可能にし、既存の深層学習を用いた手法を上回る精度を達成している。

応答の対話行為推定の研究として、大原ら [大原 18] は発話の表現を得る RNN と対話の文脈を得る RNN を組み合わせ、応答の対話行為を推定する。評価実験の結果、応答の対話行為推定には対話の文脈情報が有効であることを示している。また、発話を入力としその対話行為を推定する発話の対話行為推定と比べ、次の応答の対話行為を推定する応答の対話行為推定の方が困難であることが示されている。

3. 提案手法

図 1 に提案手法の概要を示す。提案手法は発話と対話の文脈情報を保持する対話テキスト Encoder, 対話行為の文脈情報を保持する対話行為 Encoder, 対話行為を推定する分類器から成る。

3.1 対話テキスト Encoder

対話テキスト Encoder は、発話をベクトル化する RNN (発話 Encoder) と文脈をベクトル化する RNN (文脈 Encoder) から構成される。入力発話を単語分割したものを発話 Encoder

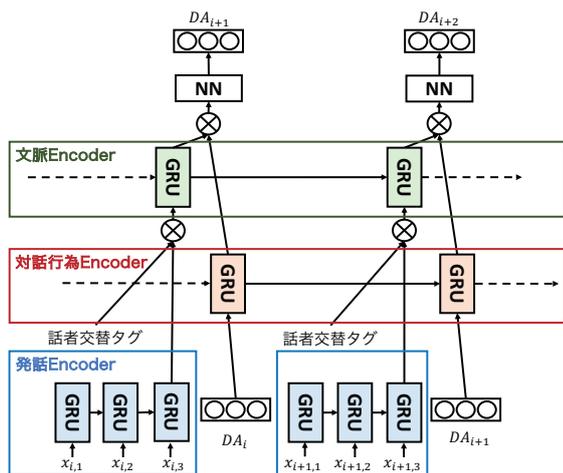


図 1: 提案手法の全体図 (⊗ はベクトルの結合操作を表す)

に逐次的に入力し、発話のベクトル表現を得る。ここで、バッチ処理をするために発話の系列長を揃えるためにパディングを行うが、パディングの情報を発話ベクトルに含めると発話の情報が欠如すると考えられる。よって、発話ベクトルはパディングを行う前の RNN の状態を用いる。そして、得られた発話ベクトルを文脈 Encoder に入力し、過去の発話ベクトルの系列を考慮した文脈ベクトルを得る。

会話は常に 1 発話毎に話者交替をするとは限らず、同じ発話者が連続で発話する場合も存在する。提案手法では、大原ら [大原 18] の手法と同様に、発話ベクトルに話者交替の有無を表す埋め込みベクトルを連結し、文脈 Encoder の入力とする。

3.2 対話行為 Encoder

対話行為 Encoder は、過去の対話行為の系列のベクトル表現を RNN によって計算する。対話行為の系列を逐次的に入力することで、過去の対話行為の履歴を表現するベクトルを得る。入力の対話行為はその時刻での発話に付与されている対話行為である。

3.3 応答の対話行為推定

提案手法では、対話行為推定を多クラス分類問題として定式化する。対話テキスト Encoder と対話行為 Encoder から得られたベクトル表現を連結し、フィードフォワードニューラルネットワークを用いて対話行為の推定を行う。

4. 評価実験

4.1 実験データ

実験データは電話での会話を書き起こし、対話行為タグを付与した SwDA コーパスを用いる。SwDA コーパスに付与されている対話行為は damsl タグ*2 に準拠しているが、付与されたタグの数が少ないものが存在し、十分に学習ができないと考えられる。そこで、簡易 damsl [磯村 09] を参考に 9 つのタグに削減したものをを用いる。SwDA コーパスに含まれる対話数は 1,155、発話数は 219,297 であり、1 対話に含まれる発話数は平均 189 である。1 つの発話に含まれる発話・応答の系列が非常に長いため、本実験では 1 対話に含まれる発話・応答系列長を 5 とし、サイズ 5 のウィンドウをスライドさせることで対話セットを抽出する。その結果、実験に用いるデータの対

*2 <https://web.stanford.edu/~jurafsky/ws97/manual.august1.html>

表 1: 実験データ内のタグの分布

タグ	タグの役割	タグ数
Statement	説明	576,005
Uninterpretable	フィラー	93,238
Understanding	理解	241,008
Agreement	同意	55,375
Directive	命令	3,685
Greeting	挨拶	6,618
Question	質問	54,498
Apology	謝罪	11,446
Other	引用, 曖昧な発話	19,882

表 2: 実験結果

	Precision	Recall	F 値	Accuracy
大原ら	30.9	25.1	23.8	68.5
提案手法	52.7	32.5	32.4	69.7
DAseq only	44.7	28.7	27.9	67.1
DAseq + Utterance	45.8	29.0	29.3	68.2
DA + Utterance seq	30.1	19.5	18.9	65.1
Utterance	24.4	21.6	21.6	66.7

話数は 212,367、発話数は 1,061,835 となった。タグの種類とデータ中のタグの分布を表 1 に示す。訓練用, 開発用, 評価用にデータセットを 80%, 10%, 10% に対話単位でランダムに分割して使用する。

4.2 実験設定

本実験では、RNN として Gated Recurrent Unit (GRU) [Cho 14] を用い、単語 Embedding の次元数は 300、発話 Encoder の GRU の次元数は 512、文脈 Encoder の GRU の次元数は 513、対話行為 Embedding の次元数は 100、対話行為 Encoder の GRU の次元数は 128 とする。また、分類器の入力層の次元数は 641、中間層の次元数は 100 とする。ロス関数に交差エントロピー誤差、最適化には Adam [Kingma 14] を使用し、学習率は 0.00005 とする。学習エポック数は 30 とし、開発用データのロスが最も低い値を示した時点の重みを用いて評価する。また、評価時にも対話行為 Encoder への入力は入力発話に付与されている正解の対話行為を用いるものとする。

表 1 から分かるとおり、各対話行為の出現数は分散が大きい。そこで評価指標として、全体の Accuracy に加え、対話行為推定の Precision, Recall, F 値のマクロ平均を用いる。

4.3 比較手法

本実験では先行研究である大原らの手法と提案手法とを比較することで、対話行為系列を考慮する有効性を検証する。また、提案手法における各コンポーネントの効果を検証するため、対話行為の文脈のみから推定を行うモデル (DAseq only)、および対話行為の文脈と直前の発話情報のみを用いて推定を行うモデル (DAseq + Utterance)、直前の対話行為と発話系列から推定を行うモデル (DA + Utterance seq)、直前の発話のみから推定を行うモデル (Utterance) を用いて精度の比較を行う。

4.4 実験結果

各モデルの評価結果を表 2 に示す。表 2 より全体の Accuracy において提案手法が最も高い値である 69.7% を示した。大原らの手法と比較して、提案手法が 1.2% 高い Accuracy を示した。このことより、対話行為系列を考慮することが応答の対

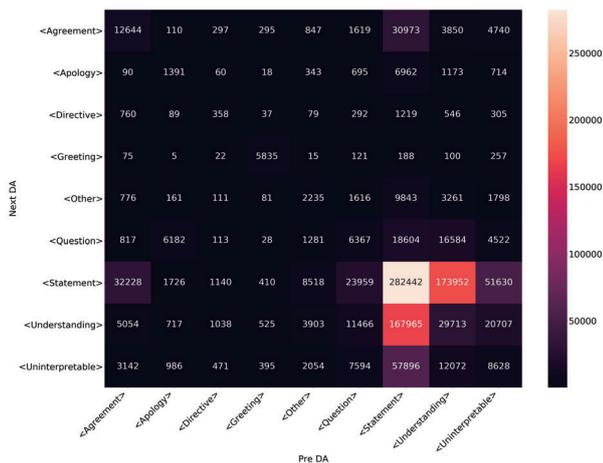


図 2: 混同行列：直前の対話行為と応答の対話行為の関係

話行為推定において有効であることが分かる。また、直前の対話行為と発話系列を用いる DA + Utterance seq と比較して、提案手法が 4.6% 高い Accuracy を示し、大原らの手法が 3.4% 高い Accuracy を示した。このことより、直前の対話行為のみを考慮する場合、推定に悪影響をもたらすことが分かる。これは、直前の対話行為と応答の対話行為の相関が薄いことが原因であると考えられる。

図 2 に直前の発話と応答の対話行為の混同行列を示す。図 2 より、対話行為として「Statement」が付与されている発話に対する応答の対話行為は「Uninterpretable」や「Statement」、「Understanding」などが続くケースが顕著に多いが、その他の対話行為の遷移については分散が大きく、対話行為遷移の目立ったパターンは観測できない。このことから、対話行為を用いる場合、系列を考慮することで推定に有益な情報を保持することが重要であることが分かる。また、対話行為の系列と直前の発話情報のみを用いる DAseq + Utterance と比較して、提案手法が 1.5% 高い Accuracy を示した。このことより、対話の系列も応答の対話行為推定において有効であることが分かる。

F 値のマクロ平均においても提案手法が最も高い値である 32.4% を示した。対話行為系列を用いているモデル全て（提案手法、DAseq only, DAseq + Utterance）において、大原らの手法と比較して高い F 値のマクロ平均を示していることから、応答の対話行為推定における対話行為の系列を考慮する有効性が明らかとなった。全体の Accuracy においては DAseq only と DAseq + Utterance は大原らの手法と比較して低いですが、大原らの手法がある特定のタグに対しては高い精度で推定が可能である一方、他のタグに対しては推定精度が低いことが原因であると考えられる。

表 3 に提案手法、大原らの手法におけるタグ別の F 値を示す。表 3 より、全ての対話行為タグにおいて提案手法が大原らの手法より高い F 値を示した。特に、低頻度なタグである「Agreement」や「Greeting」、「Question」、「Apology」においては、6.1% から 34.6% の大きな改善となった。さらに、大原らの手法では「Directive」や「Other」タグについては正しく推定できていないが、提案手法では F 値は小さいが正しく推定できるケースが存在することが分かる。これは、対話行為の系列を陽に与えることにより予測のための根拠が増えたために、出現数が少ないタグも推定できるようになったためと考

表 3: タグ別の F 値

タグ	出現数	提案手法	大原らの手法
Statement	576,005	80.8	80.4
Uninterpretable	93,238	4.7	2.6
Understanding	241,008	69.5	67.6
Agreement	55,375	23.1	15.3
Directive	3,685	2.7	0.0
Greeting	6,618	81.3	46.7
Question	54,498	8.1	2.0
Apology	11,446	22.7	11.3
Other	19,882	3.6	0.0

えられる。

表 4 に提案手法と大原らの手法を用いて対話行為推定を行った例を示す。表 4 の 1 つ目の例より、表 1 においてタグ数が比較的少ない「Agreement」タグについて大原らの手法では誤判定しているが、提案手法では正しく推定できていることが分かる。表 4 の 3 つ目は対話文脈、対話行為系列双方を考慮しても推定が困難な例である。2 つ目と 3 つ目の例では、対話行為の系列は等しく、2 つ目の例では提案手法・大原らの手法ともに正しく応答の対話行為を推定できている。しかし、3 つ目の例ではどちらの手法も推定に失敗している。3 つ目の対話における 5 つ目の発話「and it's kind of dangerous.」に対する応答の対話行為は、2 つ目の発話における「aerosol」の危険性について聞き手が理解しているか、すなわち話者の知識に依存する。この問題を解決するためには、ユーザの情報を保持する機構を用いてパーソナライズを行う必要があると考えられる。

5. まとめ

本研究では、対話文脈と対話行為の系列を考慮した応答の対話行為推定手法を提案した。

SwDA コーパスを用いて評価実験を行った結果、全体の Accuracy において 69.7%, F 値のマクロ平均において 32.4% を達成し、既存手法の性能をそれぞれ 1.2% および 8.4% 改善した。

今後の課題として、応答の対話行為推定結果を用いた応答生成を行う予定である。

参考文献

- [Cervone 18] Cervone, A., Stepanov, E., and Riccardi, G.: Coherence Models for Dialogue, in *Proceedings Interspeech 2018*, pp. 1011–1015 (2018)
- [Cho 14] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y.: Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1724–1734 (2014)
- [Kalchbrenner 13] Kalchbrenner, N. and Blunsom, P.: Recurrent Convolutional Neural Networks for Discourse Compositionality, in *Proceedings of the Workshop on Continuous Vector Space Models and their Compositionality*, pp. 119–126 (2013)

表 4: 推定結果例 (「対話行為」はその発話の対話行為を示し,「正解タグ」は応答(次の発話)の対話行為である.)

発話テキスト (対話行為)	正解タグ	提案手法	大原らの手法
1 what are they , (Uninterpretable)	Statement	Statement	Statement
2 the , (Statement)	Statement	Statement	Statement
3 I know , (Statement)	Statement	Statement	Statement
4 a Rabbit 's one , diesel (Statement)	Agreement	Understanding	Understanding
5 Uh-huh , (Agreement)	Agreement	Agreement	Statement
1 I hope so too .(Statement)	Statement	Statement	Statement
2 You know . Right now there 's a lot on the market for sale because of people having lost Yes .(Statement)	Understanding	Understanding	Understanding
3 Yes .(Understanding)	Statement	Statement	Statement
4 and everything(Statement)	Statement	Statement	Statement
5 so that 's , you know , that keeps prices down (Statement)	Understanding	Understanding	Understanding
1 It does n't seem like ,(Statement)	Statement	Statement	Statement
2 but I guess when you think of it everybody has some sort of aerosol in their home (Statement)	Understanding	Understanding	Understanding
3 Yeah .(Understanding)	Statement	Statement	Statement
4 you know ,(Statement)	Statement	Statement	Statement
5 and it 's kind of dangerous .(Statement)	Agreement	Understanding	Understanding

[Khanpour 16] Khanpour, H., Guntakandla, N., and Nielsen, R.: Dialogue Act Classification in Domain-Independent Conversations Using a Deep Recurrent Neural Network, in *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*, pp. 2012–2021 (2016)

[Kingma 14] Kingma, D. and Ba, J.: Adam: A Method for Stochastic Optimization, *International Conference on Learning Representations* (2014)

[Vinyals 15] Vinyals, O. and Le, Q. V.: A Neural Conversational Model, in *Proceedings of The 32nd International Conference on Machine Learning (ICML)* (2015)

[Zhao 18] Zhao, T., Lee, K., and Eskenazi, M.: Unsupervised Discrete Sentence Representation Learning for Interpretable Neural Dialog Generation, in *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 1098–1107 (2018)

[磯村 09] 磯村 直樹, 鳥海 不二夫, 石井 健一郎: HMM による非タスク指向型対話システムの評価, 電子情報通信学会論文誌. D, 情報・システム = The IEICE transactions on information and systems (Japanese edition), Vol. 92, No. 4, pp. 542–551 (2009)

[大原 18] 大原 康平, 佐藤 翔悦, 吉永 直樹, 豊田 正史, 喜連川 優: 階層型 RNN を用いた対話における応答の対話行為予測, 言語処理学会第 24 回年次大会 (2018)

縦断的調査データによる条件付き相互行為の実証研究

～自然発話文の語用論とポライトネスの視点から～

Empirical research on conditional interactions in longitudinal studies

～ From the Viewpoint of utterances of Natural Speech and Politeness ～

太田 博三¹

Hiromitsu Ota¹

¹放送大学 教養学部 1

¹The Open University of Japan 1

Abstract: Based on "Japanese Learner Conversation Database Profile Survey" provided by NINJAL, the same person is examined every year for the next 5 years using the characterization data of the settlement area of oral examination. The first and second utterances are regarded as pre- and posterior events, likewise up to the fifth time, and similarly maximum and fifth times are taken, and Bayesian theoretical non-verbal fillers and countermeasures, laughter, response, rephrasing, omission, repetition and repetition are politeness. From the viewpoint of mutual action of theory and ethnomethodology. We assume that these are generated from a combination of plural non-linguistic elements, not a single body, and demonstrate it. For example, it is a point that it is a reprehensible expression such as "yes yes yes." Even after the second time, to repeat the same thing repeatedly saying that I did not remember the last time, such as being rude. Here, the phraseological usage such as filler which establishes a natural conversation is inherent, and we want to be applicable to AI, robot, etc.

1. はじめに

ここ数年で、統計学は頻度主義からベイズ統計へ移行し、事前事象を踏まえて、事後事象を考えるのが当然のことになっている。その結果、音声対話システムやロボット、自動運転など人工知能（AI）の実用化につながりつつある。一方で、これまでの人工知能の歴史には冬の季節と呼ばれる時期が2回あり、この大くは人間の常識とそれに基づく推論の難しさであった。これはハードウェアと演算速度の発展により、大規模データ（ビッグデータ）で解決されつつある。しかし人間の常識の上に、様々な状況や場面、人との関わりの中で変化するのが敬語であり、語用論的にも、その含意を理解するのは人間でも難しい。コミュニケーションの難しさと言われるものである。本稿では、言葉の裏に潜む含意をフィラーや相槌、応答そして語用論の含意やポライトネス理論の見地から、時系列で、縦断的なデータを用いて、仮説検証するものである。最終的には音声応答システム等に適用可能なものになりたい。

2. 本研究の着眼点及び先行研究・方

法論・新規性・得られる成果

杉山ら（2018）は、これまでの対話システムのあり方を純粋な対話ではなかったと位置付け、発話連鎖をいくつかのパターンに分けて想定し、その上で、Wikipediaを対象とした word2vec によるベクトル化を行い、知識基盤とするとともに、対話制御を行うものである。大規模なデータによる知識習得のアプローチを捨て、人間の作る発話を先行させた。本稿では、この流れを汲み、自然な会話を、対話システムに生かすことを目的としたものである。具体的には、フィラーや笑い、相槌、応答、省略、反復・繰り返し（エコー）を取り上げる。これらは、単発で用いられているケースとフィラーと笑いとの組み合わせで、用いられているケースとがある。以下の節で、日本語を学習する非母国語話者が、そのための先行研究や方法論、新規性、そして得られる成果を次節以降に示す。

2.1 先行研究

まず、縦断データを用いた先行研究を紹介し、次に、省略の先行研究、そして最後に、フィラーや笑いなど単発の先行研究を示す。

2.1.1 縦断データの活用

国立国語研究所の提供する「日本語学習者会話データベース 縦断調査編」をもとに、同一人物を1年毎に、向こう5年間追跡調査した集住地域文字化データがある。日本語教育研究・情報センターが、ACTFL（全米外国語教育協会）の開発したOPI（Oral Proficiency Interview）テストを活用したものである。日本の各地域に定住している外国人日本語学習者（非母国語話者）の会話データを収集したもので、中・長期的な日本語学習や日本語習得、または言語生活を調査研究し、現場にフィードバックすることを目的としたものである。離散的であるが、時系列データとしてみなせるため、有用であった。



図 2.1 日本語学習者会話データベース 縦断調査編

2.1.2 縦断的調査の先行研究

野山 (2009) らは、日系ブラジル人（主に高校生）の定住する地域で、録音データをもとに、音韻的、統語的な特徴や語彙や話題の特徴、そして方略などの観点から、地域での実際の接触場面を通じて、日本語取得とその要因を研究し言語生活に帰すること

を解明したものである。「うん」を多用し最後に「はい」と相槌を打つのは母国語であるポルトガル語の影響であるとし、わかりやすい談話展開として、副助詞の「は」を用いて、効果的に主題を明示している。

また、許 (2017) は、尾崎 (1992) の聞き返しの定義を基に、同じく尾崎 (2001) の研究（在日ブラジル人）を参考に、3名の中国人日本語学習者の縦断的な調査研究を行ったものである。尾崎の聞き返しの定義は、相手の話が聞き取れない、分からないという問題に直面し、それを解消するために相手に働きかける方策であるとしている。許は、滞在期間の経過とともに、中国語の聞き返しの「あん?」が日本語としても自然な「うん?」に変化するなどが見受けられたとしている。また、聞き返しの連鎖パターンも「訂正（単純エコー型）→確認（単純エコー型）」や「確認（単純エコー型）→言い換え型」が見受けられたとしているが、日本語能力の高いほど、聞き返しの使用量が少ないとしている。つまり、日本語能力が高ければ、聞き返しを発動しなくても、問題なくコミュニケーションを維持することができる結論付けている。

2.1.3 省略の先行研究

久野 (1978) は、英語の省略現象をもとに、省略と談話法規則とに言及し、省略の順序について述べている。より新しい（重要な）インフォメーションが残され、より古いものが省略されるとしている。また談話法規則として、省略の根本原理に、省略されるべき要素は、言語的あるいは非言語的文脈から復元可能でなければならないとしている。堂下・白井・溝口・新美・田中(1998)は、音声対話システムの実装に向けて、対話における省略を、次の2つに分けている。

- 1) 対話当事者に関する省略（「私は」や「あなたに」など）、
- 2) 「共有知識に基づく省略（文脈中には言及されていないが、対話の当事者が共有している知識に基づいて、省略が行われるもの）」

この分類の上で、省略されている名詞句、修飾詞句、動詞句を省略詞区とし、この頻度を計算し、補完するものである。その省略文の前の文を0-6の範囲として、頻度を測定し、67.9%の割合で直前の文に省略詞があると結論付けている。伝 (1997) は、話し言葉の特徴を、言い淀みと言い直し、省略とし、音声対話コーパスでの統一モデルを提案し、言い淀みや言い直しなどの不適格性を適切に扱う手法について述べている。近年のディープラーニング関連では、

佐藤・乾 (2018) は、非タスク型の対話応答文生成に際して、前件と後件に分けて因果関係のデータセットを作り、因果関係知識の収集と学習を Sequence-to-Sequence(以下, Seq2Seq と省す)の処理にかけるとしている。例えば、前件が「仕事ができる」、後件が「帰りが遅い」などの因果関係の発話セットである。

2.1.4 単体での先行研究

フィルターや笑いなどの単体での研究は少なくない。太田・土屋・中川 (2009) は、フィルターを挿入する箇所を推定する「フィルター挿入モデル」と推定された箇所に挿入するべき適当なフィルターを選択する「フィルター選択モデル」を提案している。国家議事録をもとにしており、3-gram による予測精度は 17% と極めて低い。ここからも、機械による予測の限界が見受けられ、アプローチの変更が検討される。

2.2 本研究の方法論

まず、国立国語研究所の提供する「ACTFL-OPI テストとは: 日本語学習者会話データベース 縦断調査編」の中の「外国人集住地域 会話データ」の「集住地域データ」を 1 年目から 5 年目までを取り上げる。また補完的に、前述の「分散地域データ」も取り上げる。

次に、文字化されたスクリプトを形態素解析し、品詞別の頻度を概観し、省略と反復・繰り返しの語句のかたまりを取り上げ、フィルターや笑い、応答とともに共起して生成されているパターンを抽出する。

最後に、2 回目の OPI は 1 回目の何を踏まえているかを推意する。ベイズ論的には次の式になる。

$$P(2^{nd} OPI) | (1^{st} OPI)$$

2.3 本研究の新規性・得られる成果

これまで、エスノメソドロジーや会話分析では、1 つの映像データや音声データを文字に落として、それを解釈するといった 1 つのスクリプトで完結されることが少なくない。しかし実際には、同じ人物である場合は、離散的ではあるがベイズ論的に、前の事象を踏まえて、その後の事象が起きているのが現実である。本考察では、ベイズ論的な視点を取り入れ

つつ、談話の省略と反復・繰り返いを考察することで、単体ではなく、複合的で実際の対話システムへの応用にもつながると思われる。

3. 省略と反復・繰り返いの考察

3.1 反復・繰り返いの考察

JMTe001 (テスター) の「はい」の一語は返答や相槌であるが、「はい、はい、はい」と反復・繰り返になると、「突き上げ(Probes)」の役割に変わってしまう。

表 3.1 会話断片: 反復・繰り返い

T: え？
I: 死ぬとかくはいはいはいはい、そんな重い言葉を(うん)平気で言うんで(うーん)、びっくりしましたね。
T: うーん、あの、テレビの(テレビの)ね、中で、 実際でもやっぱ聞いたことありますか、中学高校で？
I: あー、そうですね、さい、中学校とかでは。

4. 条件付きポライトネス理論の展開

ポライトネス理論にベイズ理論、とりわけベイズ更新を適用してみる。

4.1 ポライトネス理論のフェイス侵害度の計算式へのベイズ定理の適用

ペネロピ・ブラウン・スティーヴン・C・レヴィンソン[(1987)以下, B&L と省略する]のポライトネス理論のフェイス侵害度の計算式 (Face Threatening Act: FTA) も、ベイズ定理を用いて、次のように表すことができる。

$Wx = D(S, H) + P(H, S) + Rx$ とおくと、 $P(Wx2 | Wx1)$ と表せる。

適用後は、社会的距離である $D(S, H)$ は $D1 \rightarrow D2$ への事後では変わらないが、相対的な力である $P(H, S)$ は $P1 \rightarrow P2$ へと縮められる可能性が考えられる。また文化的差異による負荷 (Rx) は、時間の経過とともに、軽くなると想定できる。この結果、フェイス侵害度は、ベイズ論的には、次の式のように、時間に反比例して減少するものだと考えられる。

$$Wx = D(S, H)[\rightarrow] + P(H, S)[\rightarrow] + Rx[\rightarrow]$$

4.3 ポライトネスの考察

これは、3年目の3回目の訪問（OPIテスト）では、同一場面で、直前に話したことを、省略せずに繰り返して話すと、フェイス侵害になることが見受けられる。明示的に不快感を表している。立場的にも、試験監督と受験者という関係であり、フェイス侵害度は高くなりやすい状況にある。ここから、省略と反復・繰り返しは重要な役割を担っていると考えられる。

表 4.3 会話断片：直前に話したことを繰り返すとマイナスになるケース

L: よろしくお願ひします、今回ですね、えーと、まあ未就学の、これ**の、 ... 企画を、考えていまして(はい)、で、そうですね、その、チャリティイベントで、その100時間のフットサルの試合を...
T: あー、はいはい、き、聞きました
L: はい、行かないと思って(ええ、ええ)るんですけど、まあ、前回は自分たちで色々、やってそういう、企業さんから色々と援助もらったりしてんですけど、今回はまた、県からも、協力をお願いしたいんですが
T: はい、あのね、えー、とていいのやってらっしゃいますよね、(はい)あーじゃあこちらの、にも援助ということですね？
L: はい

4.4 ベイズ更新による考察

本節では、応答詞（「はい」や「はいはいはい」と笑い(<笑>)）の出現数を1回目から5回目まで、別々にカウントし、「はい」が出て「笑い」が出ている場合を考察する。

まず、ポライトネス理論の水準を次の3つに定めて、モデル化したものである(図4.5.1を参照のこと)。

- 1) ポジティブ
- 2) ゼロ
- 3) ネガティブ

次に、尤度を算出する

その次に、事前確率を設定する。ここでは、理由不十分の原理から事前確率を等しく設定した。

「はい」と<笑>とをベイズで推定				
(1)「はいはいはい」と<笑>のモデル化				
	ポジティブ(H ₁)	ゼロ(H ₂)	ネガティブ(H ₃)	
推定子の数	3	3	3	
変数子の数	4	2	3	
(2)尤度の算出				
データ(D)	P(D H ₁)	P(D H ₂)	P(D H ₃)	
悪印象(推定子選択)	0.428	0.600	0.500	
良い印象(変数子選択)	0.571	0.400	0.500	
(3)事前確率の設定				
	確い	普通	好き	
最初の前確率	0.3	0.4	0.3	
(4)データ入力と事後確率の算出				
データ回数	データ(D)	確い(H ₁)	普通(H ₂)	好き(H ₃)
1回	良	0.300	0.400	0.300
2回	悪	0.414	0.276	0.310
3回	良	0.414	0.276	0.310
4回	良	0.527	0.176	0.297
5回	悪	0.527	0.176	0.297
6回	良	0.630	0.105	0.266
7回				
8回				
9回				
10回				

図 4.5.1 「はい」と「笑い」のポライトネス的ベイズ更新

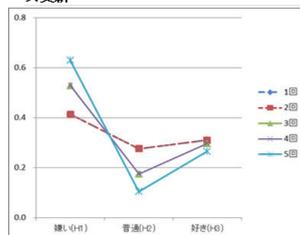


図 4.5.2 1回目から5回目までの「はい」と「笑い」のポライトネス的ベイズ更新

さらに、カウントしたデータを入力し、事後確率を計算した。

最後に、データを変えてみて、これらをグラフに図示したのが、図4.5.2である。

5 まとめ・今後の展望

本稿では、ベイズの定理を適用し、「省略」と「反復・繰り返し」の視点から、フィラーや笑い、そしてポライトネス理論をデータを用いて仮説検証したものである。

テスターによる「はいはいはい」などは一見すると、強い同意の応答句と捉えがちだが、含意されることは、決して好意的ではなく、OPI特有の「突き上げ(Probes)」になっている。この突き上げにより、非母国語話者である受験者は、「あっ、その一、えーと(笑い)」などのように、あらゆる非言語的側面が生成されている行為が読み取れた。この部分でも、何とか答えようとしながらも、フィラーや笑いなどの非言語的側面が顕著に出ている。

また、1回目より、2回目、2回目より3回目と、人間同士の接触回数が進むにつれて、非言語的側面や語用論的な側面が必要になってくると言える。

省略と反復・繰り返しは、語用論のポライトネス理論に深く関係しており、前回の接触を踏まえて生成されるものである。今後は母語話者の縦断的な調査を進め、映像データと文字化データとを用いて、仮説検証を重ね、より自然な対話の場面を見出したいと考えている。これを対話システムやロボットに応用したい。

参考文献

- 1) 杉山ら(2018)「文脈に沿った発話理解・生成を行うドメイン特化型雑談対話システムの実験的検討」, SIG-SLUD-B802-33, 人工知能学会
- 2) 国立国語研究所「日本語学習者会話データベース 縦断調査編」
https://db3.ninjal.ac.jp/judan_db/
- 3) 久野(1978)『談話の文法』大修館書店
- 4) 福田一雄(2013)「対人関係の言語学」開拓社
- 5) 松原望(2008)「入門ベイズ統計」東京書籍

[1N3-J-9] Natural language processing, information retrieval: understanding

Chair:Masayuki Okamoto Reviewer:Masahiro Ito

Tue. Jun 4, 2019 3:20 PM - 4:40 PM Room N (Front-right room of 1F Exhibition hall)

- [1N3-J-9-01] Extract Object of Changes from Documents using Similarities of Co-occurrence Word and its Time Distribution
○Katsuaki TANAKA¹ (1. Saitama Institute of Technology)
3:20 PM - 3:40 PM
- [1N3-J-9-02] Mention Detection method for Entity Linking
○Naotaka Kawata¹, Genichiro Kikui² (1. Okayama Prefectural University Graduate School, 2. Okayama Prefectural University)
3:40 PM - 4:00 PM
- [1N3-J-9-03] Spoken Language Understanding based on Sentence Segmentation by Language Models
○Kei Wakabayashi¹, Johane Takeuchi², Makoto Hiramatsu¹, Mikio Nakano² (1. University of Tsukuba, 2. Honda Research Institute Japan Co., Ltd.)
4:00 PM - 4:20 PM
- [1N3-J-9-04] Distinguish Antonyms in Multiple Viewpoints on Distributed Word Representations
○Taku Nakamura¹, Ran Tian², Shota Sasaki¹, Kentaro Inui^{1,3} (1. Tohoku University, 2. National Institute of Advanced Industrial Science and Technology (AIST), 3. RIKEN Center for Advanced Intelligence Project (AIP))
4:20 PM - 4:40 PM

共起語の類似度と時刻分布を利用した文書集合からの変化記述の対象抽出の試み

Extract Object of Changes from Documents using Similarities of Co-occurrence Word and its Time Distribution

田中 克明*1

Katsuaki TANAKA

*1 埼玉工業大学人間社会学部

Faculty of Human and Social Studies, Saitama Institute of Technology

In this paper, we proposed document sets consists of two types, a diversity description type that records actions to different objects and a change description type that recordings actions to objects that could be regarded as the same and attempted to extract objects of a change description documents. We assumed that co-occurrence words of a word indicating the object would have high similarities and words having different appearance time distributions in change description documents. As a result, we confirmed that it is possible to extract objects of a change description type documents.

1. はじめに

人間は、さまざまなことを文書として残している。文書の種類によらず、文書は「人間」が文書の記述の「対象」に何らかの「行為」（「観察」も行為とする）を行いその内容を記したものであること、また、文書数は時間の経過に沿って増えていくことが、共通する。

文書記述の例として、植物を観察して文書に記録する場合を考えると、「ツククサが咲いていた (A)」「アジサイがもうすぐ咲きそうだ (B)」「アジサイが色づいた (C)」「アジサイの花に見えるの部分は萼だ (D)」といった文書が考えられる。(A)(B)(C)(D)のうち、「ツククサ」と「アジサイ」という別々の植物について記した (A)(B) は、図1のように、異なる対象への行為を記述した文書の集合（以下、多様性記述型）である。これに対し、「アジサイ」について別の時刻に記した (B)(C) は、図2のように、同一とみなせる対象への異なる時刻の行為を記した文書の集合（以下、変化記述型）である。なお、(B)(C) に対する (D) のように、同一とみなせる対象について記述でも、時間の経過が意味をなさない場合、多様性記述型であると考えられる。

変化記述型の文書集合では、同一とみなせる対象への異なる時刻の行為を記述するため、文書集合から時間の経過を読み取ることができる。一方、多様性記述型の文書集合からは、時間の経過を読み取ることができない。すなわち、本稿で扱う「同一とみなせる対象」とは、「何かが変わったということは、なにか変化しないものがあることが必須である。」[溝口 12] とされる「なにか変化しないもの」のことである。

次に、植物を観察して記された文書集合をもとに、新たに植物を育てることにしよう。多様性記述型の文書集合からは、どのような種類の植物があるかの情報を得ることができ、育てる植物の種類を決めることに役立つ。変化記述型文書集合からは、どのように植物が育っていくかの情報を得ることができ、時間を追って植物を育てる途中で行う行動の決定に役立つ。このように、多様性記述型の文書集合と変化記述型の文書集合からは、得られる情報の性質が異なる。*1

連絡先: 田中克明, 埼玉工業大学人間社会学部情報社会学科, 〒369-0293 埼玉県深谷市普濟寺 1690, jsai2019@katsuaki-tanaka.net

*1 多様性記述型の文書集合から得られた情報を変換し、同一の対象

一般的に、文書をひとつの集合として捉えると、「(A)(B)(D) または (B)(C)」のように、同一の対象に関する記述か否かの明確な分類のもとに文書が記録されていることは少なく、図3のように多様性記述型と変化記述型が混在している。そこで本稿では、文書集合から変化記述型となっている部分集合を見つけることを目的とし、変記述型の文書集合の核となる「同一とみなせる対象」の抽出手法を提案する。

2. 関連研究

文書集合に記述されている内容を把握するための手法として、LDA[Blei 03] に代表されるトピックモデルが挙げられる。トピックモデルにより、文書に含まれる複数の特徴的な記述内容の確率分布を「トピック」として得ることができる。さらに、Dynamic Topic Models [Blei 06] などにより、文書が作成された時間の経過に沿ってトピックを抽出することが可能である。しかし、これらの手法では、トピックが、特徴が似た多様性記述型の内容を表すものか、変化記述型の内容を表すものかの判断は、トピックの内容を確認する人間が行う必要がある。

また、時間の経過に沿って文書を処理する手法として、ニュース記事や SNS などの文書集合から出来事（イベント）に関する記述を時系列に追って抽出する研究がなされている [Wanner 14]。時系列文書を扱う点において本研究と類似するが、社会性が大きい出来事の抽出を扱っており、抽出結果の利用者と対象文書の間に対応の共通理解が存在することを前提とする。

3. 提案手法

3.1 変化記述型文書集合と単語への言及の類似率

文書において同一の対象を記述する際に、変化記述型 (図2) の文書集合では、以前と同じ対象であることを認識して記述を行う。逆に文書を読む場合においても、対象についてある程度類似した表現が行われていなければ、人間が同一の対象と認識することが難しくなる。そのため、対象への言及内容にある程度の類似があると考えられる (図4)。一方、多様性記述型の文書集合 (図1) では、以前の対象と同じかを意識せずに

への行為を蓄積し変化記述型の結果を生み出すことが「知的な振る舞い」であると考えられるが、本稿では取り扱わない。

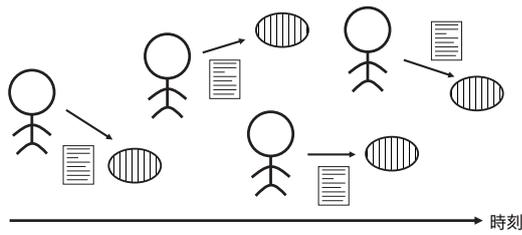


図 1: 異なる対象への記述からなる文書集合 (多様性記述型)

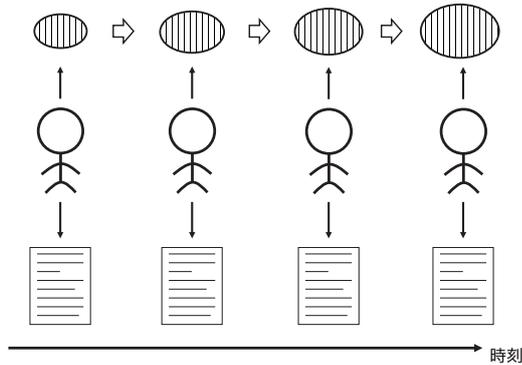


図 2: 関連する対象への記述からなる文書集合 (変化記述型)

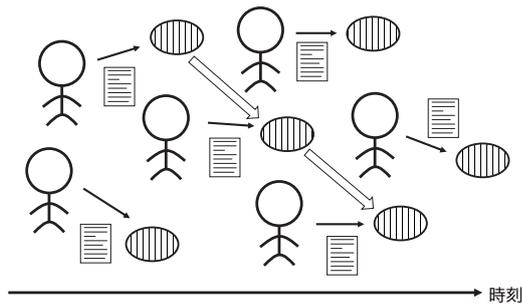


図 3: 一般的な文書集合 (多様性記述型と変化記述型が混在)

記述を行うため、同じ対象を扱う文書において、対象への言及内容が類似するか否かは、一概に判断できない。

本稿では、対象が1つの単語で表現される状態を仮定し、ある対象を表現する単語への言及は、その単語と共起する単語により行われるとする。異なる時刻に記された文書において、対象を表現する単語に対して共起する単語が類似していることが、多様性記述型の文書集合を示すとなると考え、単語への言及の類似率 (以下、言及類似率) を求める。すなわち、言及類似率が高い単語は、「同一とみなせる対象」であり、変化記述型の文書集合であるものとする。

3.2 言及類似率の計算

言及類似率は、以下のように計算した。まず、着目単語 w_a を定め、ある文書 D_i において単語 w_a と共起する単語のひとつを単語 w_b とする。次に、文書 D_i とは異なる文書 D_j において単語 w_a と共起する単語 w_c に対して、単語 w_b と類似するかの判定を行う。さらに、単語 w_b と単語 w_c が文書集合の中の異なる時刻で使われているかの判定を行う。これを繰り返し、単語 w_a と共起するすべての単語 w_b について、その他の文書で単語 w_a と共起する単語 w_c が、異なる時刻で類似する割合を、言及類似率として求める。

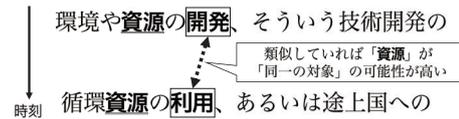


図 4: 同一の対象への記述判断例

表 1: 対象文書集合の概要

環境省中央環境審議会地球環境部会議事録	
期間	2001/2/16~2012/10/24
文書数	5910 (発言ごと)
異なり単語数	12991
「人工知能」を含むツイート	
期間	2013/12/25~2014/6/6
文書数	43862 (収集データの $\frac{1}{3}$)
異なり単語数	22251

処理対象とする文書からの単語の取得は、MeCab^{*2} による形態素解析の結果を用い、形態素解析後に名詞として得られた単語を選択することにより行った。また、単語 w_a と単語 w_b が共起するとは、形態素解析により得られた名詞の単語列において、 w_a と w_b が5単語以内あることを指すものとした。

単語が類似するかの判定は、日本語版 Wikipedia に含まれる単語を Word2vec[Mikolov 13] によりベクトル化した Wikipedia Entity Vectors^{*3} から、全単語を 300 次元のベクトルとして学習済みのモデルを用い、単語を表現するベクトルのコサイン類似度

$$\text{sim}(\vec{w}_b, \vec{w}_c) = \frac{\vec{w}_b \cdot \vec{w}_c}{|\vec{w}_b| |\vec{w}_c|} \quad (1)$$

を求め、 $\text{sim}(\vec{w}_b, \vec{w}_c) \geq 0.5$ となる単語 w_b, w_c を、類似するものとした。なお、処理対象の文書集合に存在するが、Wikipedia Entity Vectors に存在しない単語は、言及類似率の計算対象外とした。

単語 w_b と単語 w_c が異なる時刻で使われているかの判定は、単語 w_a と共起して単語 w_b が出現する時刻、同様に単語 w_a と共起して単語 w_c が出現する時刻の分布に着目し、相互の第2四分位範囲から第3四分位範囲に重なりがなければ、異なる時刻で使われているものとした。

4. 実験

4.1 対象とする文書集合

表 1 に示す 2 つの文書集合を対象とし、提案手法を適用した。1 つめは、日本の環境政策に関する諮問機関である環境省中央環境審議会のうち、地球温暖化に関する内容を中心に扱う地球環境部会の議事録である。議事録は、日時・出席者・議事次第・配布資料一覧・議事から構成され、会議 1 回ごとにほぼ同様の形式で記述されている。会議へは委員としてほぼ決まったメンバーが出席している他、外部のゲストが出席し話題の提供を行っていることが多い。会議の進行は、外部のゲストによる話題提供の後、その内容について委員が質疑と議論を行う、という形となっている。議論の内容は議事録の「議事」に記述されていたことから、「議事」部分のみを分析の対象とした。

*2 <http://taku910.github.io/mecab/>

*3 <https://github.com/singletongue/WikiEntVec>

表 2: 地球環境部会議事録 言及類似率

	単語	言及類似率	単語	出現率
1	法律	0.8638	委員	0.0101
2	事業	0.8554	環境	0.0095
3	大気	0.8511	エネルギー	0.0088
4	温室	0.8477	日本	0.0073
5	状況	0.8474	資料	0.0072
6	効率	0.8468	目標	0.0065
7	目的	0.8465	地球	0.0047
8	部分	0.8458	技術	0.0047
9	公共	0.8455	部会	0.0044
10	観点	0.8448	制度	0.0044

表 4: 上位 10 語の評価 (地球環境部会議事録)

言及類似率		出現率	
単語	対象	単語	対象
法律	○	委員	×
事業	×	環境	×
大気	○	エネルギー	×
温室	○	日本	○
状況	×	資料	×
効率	×	目標	○
目的	○	地球	○
部分	×	技術	×
公共	○	部会	×
観点	×	制度	○

表 3: 「人工知能」を含むツイート 言及類似率

	単語	言及類似率	単語	出現率
1	ロボット	0.8519	人工知能	0.0684
2	人間	0.8474	表紙	0.0375
3	自分	0.8469	人工知能学会	0.0320
4	人	0.8407	女性	0.0309
5	学会	0.8266	ロボット	0.0292
6	人類	0.8254	男	0.0225
7	機械	0.8219	家事	0.0220
8	人工知能学会	0.8177	気持ち	0.0218
9	表紙	0.8141	まとめ	0.0214
10	世界	0.8137	NAVER	0.0201

表 5: 上位 10 語の評価 (「人工知能」を含むツイート)

言及類似率		出現率	
単語	対象	単語	対象
ロボット	×	人工知能	○
人間	○	表紙	○
自分	×	人工知能学会	×
人	×	女性	×
学会	○	ロボット	×
人類	○	男	×
機械	○	家事	×
人工知能学会	×	気持ち	×
表紙	○	まとめ	×
世界	×	NAVER	×

また、議事は会議における各個人の発言として記述されており、発言ごとに趣旨が異なると考えられることから、1つの発言を1つの文書とみなし、83の議事録から得られた5910発言を異なる文書として扱った。

2つめは、Twitterより2013年12月～2014年6月に収集した「人工知能」を含むツイートである。この時期には、2014年1月刊行の人工知能学会会誌の表紙が話題となり、数多くのツイートがなされた。収集したツイートの全体の約 $\frac{1}{3}$ から、公式ツイートや、URLなどを取り除いたものを処理対象とした。なお、筆者らはこのデータを用いたトピック遷移分析システムの提案を行っている[田中14]。

4.2 計算結果

得られた言及類似率上位10語と、比較のために出現率上位10語を、表2、3に示す。なお、上位10語(表2、表3)には、言及類似率の計算により得られた結果から、文書の「対象」となる可能性が低いと考えられる、「名詞-形容動詞語幹」(「必要」など「～ない」となる単語)や「名詞-サ変接続」(「実験」「試験」など「～する」となる単語)と形態素解析器により品詞付けされた単語を除いたものを示した。

4.3 上位語の評価

表2、表3に示した言及類似率の上位10語について、各単語への言及内容について、単語とその周辺の記述を元の文書の内容を確認し、「同一とみなせる対象」であるか、評価を行った。出現頻度が高い単語では、文書集合の中で各単語が出現する箇所は数千以上のぼるため、各単語について出現する箇所をランダムに20か所選択し、確認を行った。この際、変化記述型文書集合の対象は、図3のように時間経過に沿って出現すると考えられるため、文書集合を作成時刻順に5つのグルー

プに分け、各グループから4文書ずつを選択した。評価の結果を表4、5に示す。

単語とそれに対する周辺の記述を評価するにあたり、まず、文書集合の記述自身への言及は、「同一とみなせる対象ではない」と判断した。地球環境部会議事録の「委員」「環境」「資料」「部会」「地球」「部会」が該当する。また、同一内容の文書(ツイート)により多数出現する単語も、同様に判断した。「女性」「ロボット」「男」「まとめ」などが該当する。

4.4 考察

変化記述型の文書の「対象」と考えられる単語の割合は、地球環境部会議事録、「人工知能」を含むツイートともに、言及類似率を用いたほうが文書中で「対象」である単語の割合が高く、目標とした「対象」の抽出が行えていると言えそうである。

文書における実際の記述を確認すると、単語が複数の意味に使われている場合があり、この場合は、同一の対象とはみなせないと判断した。例えば、地球環境部会議事録における「事業」は、「売電事業者」「温室効果ガスを排出する事業者」などのように、複数の種類の事業(者)を表していた。同様に、ツイートにおける「人」は、「～と発言した人」「人型」「人の意識」などさまざまな意味で用いられていた。

一方、ツイートにおける「人間」は、「人間の価値観」「人間の感情」「人間のコメント」のように、ほぼ同じ内容を表現していることから、同一の対象であると判断した。しかし、記述には時間に沿った変化は含まれておらず、「人間」を含む記述が、ツイートからなら文書集合において変化記述型の対象となっているとは言いがたい。

具体的な事物は、ほぼ対象として記述されていた。例えば、

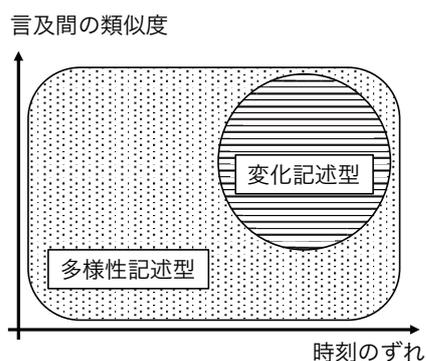


図 5: 多様性記述型・変化記述型文書集合の分布例

「法律」は「法律の施行」「法律の適用可能生」「法律大系全般」、
「学会」は「学会誌にふさわしいか悩んだ」「学会誌の表紙について公式見解」「学会誌の特集がいい返しに」など、時間経過に沿った記述が行われており、変化記述型の対象となっている。

5. 課題

本稿における研究の課題とそれらについての検討を述べる。

変化記述型の文書集合には、「異なる時刻において共起語が類似する単語が存在する」ことを仮定して実験を行った。しかし、多様性記述型の文書集合でも、別の時刻の同一の対象について以前とは無関係に記述を行うことがあることから、得られた結果は、両方の記述形式が混ざったものとなる。両形式の文書集合を、対象への言及内容の類似度と記述時刻のずれを軸として整理すると、図5のように重なる。「同一とみなせる対象」を文書集合から見つけるためには、この重なりを区別する手法が必要である。

本稿では、「対象がある単語で表される」としたが、同一の単語が異なる意味で使われることが多々ある。これに対応するために、対象単語を含む記述の全てから文書をランダムに選択して評価を行うのではなく、評価の対象とする単語への言及類似度が高い部分ごとに分割することで、変化記述型の文書集合を選択できるか、検討を行う。

また、実験結果を確認するために、言及類似率上位の単語と出現頻率が上位の単語との比較を行ったが、単語 w_a とそれぞれ異なる文書で共起する単語 w_b , w_c は、単語の共起関係をネットワークと考えた際、単語 w_a を媒介として接続されことから、今後、媒介中心性と言及類似率の比較を行いたいと考えている。

次に、提案手法における単語間の類似度の計算のために Wikipedia Entity Vectors として配布されている Wikipedia の記述内容をもとにした単語のベクトルデータを用いた。このため、実験対象の文書集合には出現するが Wikipedia Entity Vectors に含まれない単語の類似度計算は行えない。計算対象とする文書集合も含めて単語のベクトル表現を求めることにより、文書中のすべての単語について、類似度計算を行うことができる。また、類似度計算が正確に行えているかを比較、評価することも必要である。

6. おわりに

本稿では、文書集合には多様性記述型と変化記述型の2通りが考えられることを述べ、変化記述型の記述の「対象」を抽出するため、言及類似率を提案した。提案手法を2つの形式

が異なる文書集合に適用し、結果を確認した。今後、課題として述べた点を改良しつつ、性質の異なる文書集合への本手法への適用を試みる。

謝辞

本研究は JSPS 科研費 JP16K00702 の助成を受けたものである。

参考文献

- [Blei 03] Blei, D. M., Ng, A. Y., and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1002 (2003)
- [Blei 06] Blei, D. M. and Lafferty, J. D.: Dynamic Topic Models, in *Proceedings of the 23rd International Conference on Machine Learning*, pp. 113–120 (2006)
- [Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, in *Proceedings of International Conference on Learning Representations 2013* (2013)
- [Wanner 14] Wanner, F., Stoffel, A., Jckle, D., Kwon, B. C., Weiler, A., and Keim, D. A.: State-of-the-Art Report of Visual Analysis for Event Detection in Text Data Streams, in *EuroVis - STARs*, pp. 125–139 (2014)
- [溝口 12] 溝口 理一郎: オントロジー工学の理論と実践, オーム社 (2012)
- [田中 14] 田中 克明: Twitter におけるトピック遷移分析システムの提案, 第7回インタラクティブ情報アクセスと可視化マイニング研究会予稿集, pp. 22–27 (2014)

エンティティリンキングのための言及抽出手法

Mention detection method for Entity Linking

河田 尚孝*¹ 菊井 玄一郎*²

Naotaka KAWATA Genichiro KIKUI

*¹岡山県立大学大学院情報系工学研究科システム工学専攻

Graduate School of Computer Science and Systems Engineering, Okayama Prefectural University

*²岡山県立大学情報工学部情報システム工学科

Faculty of Computer Science and Systems Engineering, Okayama Prefectural University

This paper proposes a method for detecting *entity mentions* in the given text. The method consists of two sequential labelling steps. The first sequential labelling is responsible for identifying a chunk of words (morphemes) mentioning an entity. The second sequential labelling checks whether or not each chunk (or un-chunked word) is really an entity. We also investigated the relation between granularity of categories of named entities and mention detection performance. Our experimental results have shown that the second sequential labeling step for checking slightly improved recall and the eleven categories is the best granularity.

1. はじめに

エンティティリンキングとは、テキスト中の固有表現を抽出し、知識ベースのエントリー (entity) と関連付けるタスクである。知識ベースには Wikipedia や DBpedia [Auer 07] などが用いられ、特に Wikipedia のページを用いる場合は wikification と呼ばれる。エンティティリンキングを利用することで、自然言語処理の様々なタスクにおいて外部の知識ベースから得られる情報を活用することができる。また、マイクロブログなどの文章にリンクを貼ることで内容を豊かにすることができる。

エンティティリンキングは言及抽出と語義曖昧性解消の2つのフェーズに分けることができる。前者はテキスト中でエンティティについて言及 (mention) している部分を同定する処理であり、後者は同定された言及と、それが参照している事物 (entity) とを紐づける処理である。一般的に言及抽出の部分では固有表現認識 (Named Entity Recognition) のツールが利用される。しかしながら、本稿における言及抽出は言及の位置を同定するだけであり、言及のカテゴリラベル (人名, 地名など) も同時に推定する固有表現認識の一部と言える。言及抽出を用いた理由は、エンティティリンキングにおいては言及の位置のみが重要であり、カテゴリラベルの推定の重要度は低いからである。その原因は曖昧性解消においてカテゴリへの依存度が低いためである。

英語の場合、分かち書きがなされ、固有名詞が大文字から始まるなどの手がかりがあることから固有表現抽出の精度が83%であり、言及抽出はそれ以上の精度と考えられるため、語義曖昧性の解消に焦点をあてているものが多い [Mai 18]。一方、日本語における固有表現認識の精度は73%であり、英語の固有表現認識の精度と比べて十分に高いとは言えない。

日本語における言及抽出の性能を改善する上で2つのことが考えられる。1つ目は、長い言及に対する固有表現認識の精度を上げることである。南ら [南和 11] は、関根の拡張固有表現クラス [Sekine 08] がアノテートされたコーパスで固有表現認識を行った結果、イベント名や施設名を表す固有表現の認識精度が悪いことを指摘している。我々は、これらのラベルが付

与される言及は比較的長い単語で構成されるため、抽出が難しいと考える。2つ目は、固有表現認識で対象とするラベルとして適切なラベル数を選択することである。日本語では関根の拡張固有表現クラスという200種類のクラスが付与されたコーパスが存在するが、学習時間とデータスパースネス問題からこの細かい粒度のカテゴリラベルを使うことが最適とは言えない可能性がある。クラスの階層構造を利用して10~12ラベルにまとめることが多い [松田 17][Mai 18] が、適切なカテゴリ粒度を明らかにする必要がある。

以上の2つの観点から、本研究ではニューラルネットを用いた固有表現認識手法をベースとして、次の2点により言及抽出の精度向上を図る。

1. 固有表現認識を行った結果に対する再ラベリング
2. 固有表現ラベルの粒度の見直し

本稿の構成は次の通りである。2章では関連研究について、3章では提案手法、4章では実験について説明する。

2. 関連研究

固有表現認識は系列ラベリングとして考えることができる。系列ラベリングには Hidden Markov Model (HMM) [Seymore 99] や Conditional Random Field (CRF) [Lafferty 01] などのモデルが使用される。最近の研究ではニューラルネットを使用したモデルが用いられている。特に日本語の場合では、BiLSTM-CRF モデルを利用することで良い結果が得られており [Mai 18]、本研究でも BiLSTM-CRF モデルを使用する。

2.1 BiLSTM-CRF

BiLSTM-CRF は Lample ら [Lample 16] によって考案されたモデルであり固有表現認識タスクにおいて高い性能を出している。BiLSTM-CRF は3層のモデルで構築されており、character-based の BiLSTM Layer, Word-Based の BiLSTM Layer, CRF Layer の3層で構成される。モデルの構成を参考文献 [Lample 16] より図1に示す。単語の Word Embedding を入力として BiLSTM に与え双方向の出力を連結した後、連結

連絡先: 河田 尚孝, 岡山県立大学大学院, cd30013b@cse.oka-pu.ac.jp

した出力を CRF Layer に入力して各ラベルを出力する。Word Embedding については単語を文字に分割したものを BiLSTM に入力して作成している。

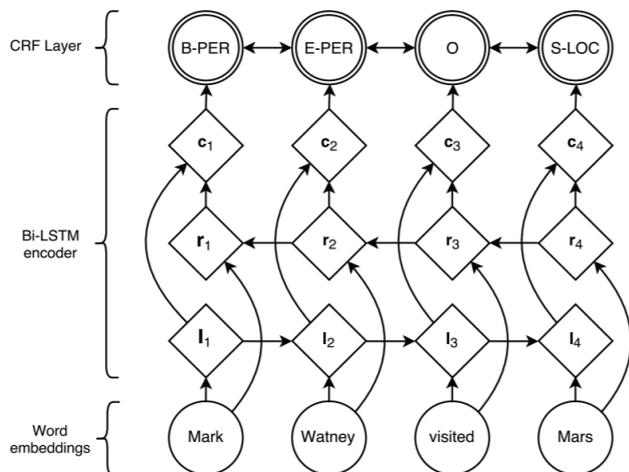


図 1: BiLSTM-CRF のモデル

現のまとめ方の例を示す。例えば「Organization_Other」や「International_Organization」は「Organization」という上位クラスにまとめることができる。「Person」のように細かいラベル分類が存在しないものについてはそのまま「Person」を使用している。ENE コーパスに含まれるラベル数は 200 ラベルであり、この階層構造を利用することで 200 ラベルを 11 ラベルにまとめることができる。さらにラベルの種類を考慮せず、全ラベルを仮に「Mention」と置き換えることでラベルの種類を 1 つにすることが可能になる。

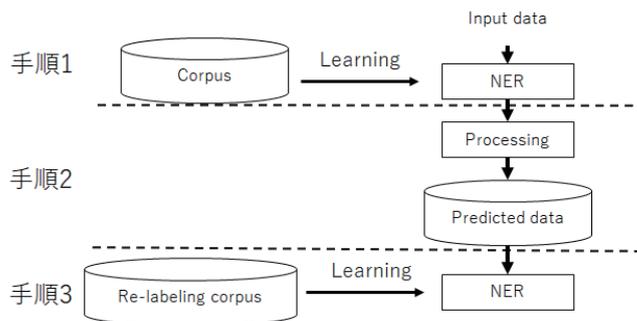


図 2: 言及抽出全体の流れ

3. 提案手法

本研究では「再ラベリング」および「固有表現カテゴリの粒度調整」の 2 点により言及抽出の精度向上を図る。以下この 2 点を順に説明する。

3.1 再ラベリング

本研究ではまず入力列（形態素列）に対して通常の固有表現認識を適用したあと、その出力に対して、別の学習データで訓練した固有表現認識を用いて再ラベリングを行う。再ラベリングの目的は最初の固有表現認識の誤りを訂正することである。言及抽出全体の流れを図 2 に示す。

手順 1 では、形態素解析された入力テキストに対して固有表現認識を適用し、得られた BIO-2 ラベルを出力とする。この時に適用する固有表現認識は、固有表現タグ付きの訓練コーパス（開発用コーパスを含む、以下、特記しない限り同様）を形態素解析して BIO-2 タグを付与したデータで訓練したものである。

手順 2 では、手順 1 の出力に対して一つの言及を構成する形態素列（すなわち、B タグの後に同一カテゴリの I タグが並んだもの）を連結して一つの形態素に変換する処理を行う。

手順 3 では、手順 2 で連結処理を行ったデータに対して次に示す訓練データで学習された固有表現認識を適用して、再ラベリングする。再ラベリング用の訓練データは手順 1 の訓練データをもとに、一つの言及を構成する形態素列を一つの形態素にまとめたものである。図 3 にこの処理を示す。

3.2 ラベルの見直し

固有表現認識において、言及の位置とラベルの種類が推定が行われるが、言及抽出においてはラベルの種類は考慮しない。そこでコーパスに与えられたラベルの種類（細かさ）を変化させて言及抽出を行う。今回はラベルの種類（総数）を変更させるために関根の拡張固有表現クラスがアノテートされた拡張固有表現タグ付きコーパス [橋本 08]（以下、ENE コーパスと表記する）の階層構造を利用する。図 4 に固有表

Mention	Label	Mention	Label
安倍	B-PER	安倍晋三	B-PER
晋三	I-PER	は	O
は	O	昨日	O
昨日	O	の	O
の	O	夜	O
夜	O		

図 3: 固有表現のまとめ方 (左:加工前, 右:加工後)

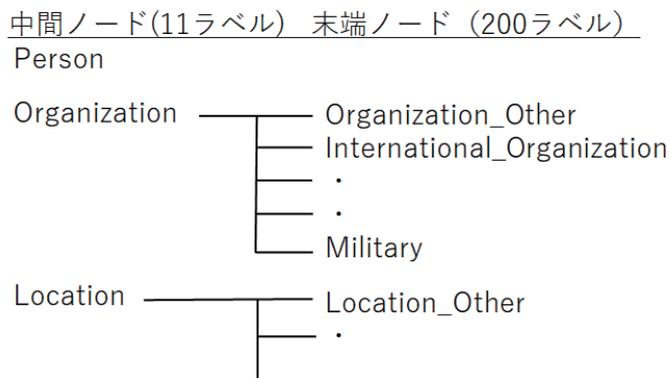


図 4: 関根の拡張固有表現ラベルの階層構造

4. 実験

本研究では再ラベリングによる固有表現認識の誤り訂正 (実験 1) とラベルの種類の総数を変化させた場合の言及抽出 (実験 2) の 2 つの実験を行った。まず、本研究で使用した系列ラベリングツールとコーパスについて説明する。

4.1 系列ラベリングツール

言及抽出の精度を測定するために系列ラベリングツールとして anaGo^{*1} と CRFsuite[Okazaki 07] を用いて実験を行った。

anaGo とは BiLSTM-CRF モデルで作成された系列ラベリングツールである。anaGo のパラメータについては参考文献 [Lample 16] をもとに設定した。使用した最適化アルゴリズムは Adam であり、パラメータは Adam の初期値を使用している。また、anaGo に対して単語ベクトルとして日本語 wikipedia エンティティベクトル [鈴木 16] を追加したものを「+word2vec」と表記している。

続いて CRFsuite を用いた実装を説明する。CRFsuite については素性として、単語の表層形、品詞細分類、文字種を対象単語およびその前後 2 単語から抽出している。

4.2 使用したコーパス

本研究では ENE コーパスと日本語 wikification コーパス [Davaajav 16] を使用した。日本語 wikification コーパスとは ENE コーパスの一部に対してエンティティ情報としてエンティティの ID (Wikipedia の記事にユニーク付与されている ID) を付与したコーパスであり、日本語エンティティリンクのコーパスとして使用することができる [松田 17]。次に使用するコーパスの内訳について説明する。トレーニングデータとして ENE コーパスに含まれる約 1600 記事、ENE コーパスと包含関係にある日本語 wikification コーパスの 340 記事を半分に分割したものをバリデーションデータ、テストデータとしてそれぞれ使用した。ENE コーパスのラベルの種類について、ENE コーパスにはおよそ 200 ラベルが付与されている。本研究では 200 ラベルから抽出が容易でかつ比較的高い F 値を達成できる時間表現・数値表現を除いた 154 ラベルと、154 ラベルを上位クラスにまとめた 11 ラベルと、ラベルの種類を無視して 1 ラベルにまとめた合計 3 種類の ENE コーパスを準備した。

4.3 実験方法

まず再ラベリングでの実験 (実験 1) を説明する。実験 1 では 11 ラベルに分類された ENE コーパスを使用した。使用した系列ラベリングツールは anaGo であり、単語ベクトルとして日本語 wikipedia エンティティベクトルを加えた。

続いてラベルの種類を変化させる実験 (実験 2) について説明する。実験 2 では ENE コーパスの階層構造を用いてラベル数を変更して 154, 11, 1 ラベルの分類に変更した計 3 種類の ENE コーパスを使用した。使用した系列ラベリングツールは anaGo と CRFsuite である。

4.4 評価尺度

最後に言及抽出の性能の評価方法について説明する。学習に用いるラベルデータはそのまま使用し、出力されるカテゴリラベルを無視することで、言及抽出の結果を測定することとする。

5. 実験結果と考察

まず固有表現を 1 単語にまとめて学習したモデルを用いて再ラベリングを行った場合の言及抽出の結果について表 1 に

示す。再ラベリングを行ったことにより再現率が 0.0526 向上、適合率は 0.0327 減少している。そして F 値は 0.011 向上している。次に再ラベリングによって新たに抽出された言及と削除された言及のうち、1 形態素のみで構成されている言及それぞれについて、ラベルの変化によって正解になった数および不正解になった数の内訳を表 2 に示す。再ラベリングによって抽出できるようになった言及は 2199 個あった。抽出できるようになった言及は「セ大阪」や「イラク戦争」など言及の 1 部に単独で固有表現となり得るものを含んだものが多かった。一方、再ラベリングによって削除された言及は 530 個あった。その中には「コメ」や「猫」などコーパス中に出現する頻度が少ない文字種であるカタカナや 1 文字で構成される言及が多かった。

この結果から固有表現を 1 単語にまとめて学習したモデルで再ラベリングを行うことで、再現率を優先した出力が得られたと言える。言及がより抽出できた原因の一つとして、固有表現を 1 単語にまとめることにより言及の前後の単語が必ず別の言及か言及以外の単語 (対象とした言及の前後の単語のラベルに B タグか O タグが付与されている) になることで、言及の前後に出現しやすい単語に注目できるようになったことが挙げられる。また言及を 1 単語にまとめることで言及の前後の単語との距離が短くなる。LSTM を用いた学習では前後の単語がより重視されるため言及の周りの単語の特徴をより学習できた可能性がある。エンティティリンクタスクにおいては、語義曖昧性解消のフェーズで言及にリンクを付与しないことが出来るため、エンティティリンクの性能向上につながると思われる。また言及を 1 単語にまとめることで言及の前後の単語との距離が短くなる。LSTM を用いた学習では前後の単語がより重視されるため言及の周りの単語の特徴をより学習できた可能性がある。エンティティリンクタスクにおいては、語義曖昧性解消のフェーズで言及にリンクを付与しないことが出来るため、エンティティリンクの性能向上につながると思われる。

続いてラベル数を変化させて言及抽出を行った結果を図 5 に示す。図 5 より、anaGo を用いた言及抽出ではラベル数が 1 の場合はラベル数 11 と 154 の場合に比べて F 値は下がっている。ラベル数 11 と 154 の場合について、F 値はほとんど変わらなかった。一方、CRFsuite を用いた場合はラベル数が多くなるほど結果が悪くなった。また word2vec の言及抽出の結果を表 3 に示す。表 3 より、anaGo に word2vec を加えることで言及抽出の性能は向上した。またラベル数が及ぼす F 値への影響は少なくなっている。これは word2vec によって追加される単語ベクトルにより言及抽出の性能が向上し、ラベル数の差が言及抽出の結果に及ぼす影響が小さくなったからだと考える。

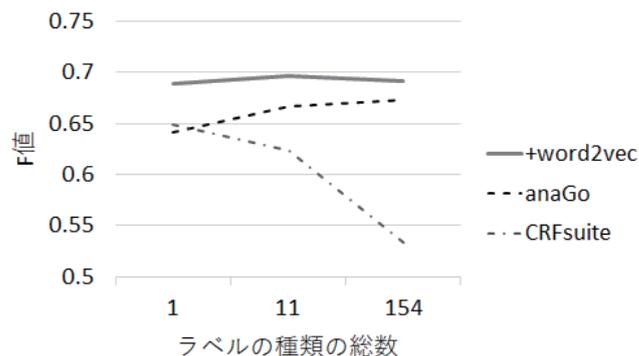


図 5: 日本語に対する言及抽出の結果

6. おわりに

本研究では言及抽出の性能を上げるために 2 つの方法を提案した。1 つ目の方法では、コーパスで分かち書きされている

*1 <https://github.com/Hironasan/anaGo>

表 1: 再ラベリングによる言及抽出の性能の変化

	再ラベリングなし	再ラベリングあり
適合率	0.7274	0.6947
再現率	0.6674	0.7200
$F_{\beta=1}$	0.6961	0.7071

表 2: 再ラベリングにより変化した 1 形態素のみで構成される言及の内訳

	言及	非言及	合計
新たに抽出された言及	1030	1169	2199
削除された言及	272	258	530

固有表現を 1 単語にまとめて学習したモデルを用いて予測ラベルの再ラベリングを行った。2 つ目の方法では、ラベルの種類を変化させて固有表現認識を行った。

1 つ目の方法を行った結果、再現率を優先した出力が得られた。適合率は下がっているが、今後エンティティリンキングタスクに応用する場合、言及抽出の次に語義曖昧性解消を行う段階で棄却することが可能であるため、F 値を下げることなく、より多くの言及を抽出できたことはエンティティリンキングの性能向上につながると考える。

2 つ目の方法を行った結果、コーパスのラベルを変化させたとき、anaGo に word2vec による単語ベクトルを加えた場合はラベル数を増やしても言及抽出の結果は変わらなかった。関根の拡張固有表現タグ付きコーパスを使う場合について 154 ラベルよりも 11 ラベルを使用することで言及抽出の性能を落とすことなく計算時間を短くすることができる。

今後の方針について、今回は言及抽出の性能に着目したが、エンティティリンキングタスクに活用することで言及抽出とエンティティリンキングの性能の関係を調べることが出来る。日本語 wikification コーパスを用いて日本語でのエンティティリンキングの性能を調査したい。

参考文献

- [Auer 07] Auer, S., Bizer, C., Koblilarov, G., Lehmann, J., Cyganiak, R., and Ives, Z.: Dbpedia: A nucleus for a web of open data, in *The semantic web*, pp. 722–735, Springer (2007)
- [Davaajav 16] Jargalsaikhan, D., 岡崎直観, 松田耕史, 乾健太郎: 日本語 Wikification コーパスの構築に向けて, 言語処理学会第 22 回年次大会, pp. 793–796 (2016)
- [Lafferty 01] Lafferty, J., McCallum, A., and Pereira, F. C.: Conditional random fields: Probabilistic models for segmenting and labeling sequence data (2001)

表 3: +word2vec の言及抽出

		適合率	再現率	$F_{\beta=1}$
ラベル数	1	0.7249	0.6567	0.6891
	11	0.7274	0.6674	0.6961
	154	0.7418	0.6483	0.6919

[Lample 16] Lample, G., Ballesteros, M., Subramanian, S., Kawakami, K., and Dyer, C.: Neural Architectures for Named Entity Recognition, in *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp. 260–270, Association for Computational Linguistics (2016)

[Mai 18] Mai, K., Pham, T.-H., Nguyen, M. T., Tuan Duc, N., Bollegala, D., Sasano, R., and Sekine, S.: An Empirical Study on Fine-Grained Named Entity Recognition, in *Proceedings of the 27th International Conference on Computational Linguistics*, pp. 711–722, Association for Computational Linguistics (2018)

[Okazaki 07] Okazaki, N.: CRFsuite: a fast implementation of Conditional Random Fields (CRFs) (2007)

[Sekine 08] Sekine, S.: Extended Named Entity Ontology with Attribute Information, in *LREC 2008* (2008)

[Seymore 99] Seymore, K., McCallum, A., and Rosenfeld, R.: Learning hidden Markov model structure for information extraction, in *AAAI-99 workshop on machine learning for information extraction*, pp. 37–42 (1999)

[橋本 08] 橋本泰一, 乾孝司, 村上浩司 他: 拡張固有表現タグ付きコーパスの構築, 情報処理学会研究報告自然言語処理 (NL), Vol. 2008, No. 113 (2008-NL-188), pp. 113–120 (2008)

[松田 17] 松田耕史, 岡崎直観, 乾健太郎: 日本語 wikification ツールキット: jawikify, 言語処理学会 第 23 回年次大会 発表論文集, pp. 250–253 (2017)

[南和 11] 南和江, 藤井康寿, 土屋雅稔, 中川聖一: 大規模コーパスを用いた固有表現抽出手法の検討, 言語処理学会 第 17 回年次大会 発表論文集, pp. 328–331 (2011)

[鈴木 16] 鈴木正敏, 松田耕史, 関根聡, 岡崎直観, 乾健太郎: Wikipedia 記事に対する拡張固有表現ラベルの多重付与 (2016)

言語モデルによる文の最適分割に基づく音声言語理解

Spoken Language Understanding based on Sentence Segmentation by Language Models

若林 啓^{*1} 竹内 誉羽^{*2} 平松 淳^{*1} 中野 幹生^{*2}
 Kei Wakabayashi Johane Takeuchi Makoto Hiramatsu Mikio Nakano

^{*1}筑波大学 ^{*2}(株)ホンダ・リサーチ・インスティテュート・ジャパン
 University of Tsukuba Honda Research Institute Japan Co., Ltd.

In this paper, we propose a new approach to solve the slot filling task for spoken language understanding by using a formulation based on the optimum segmentation of an input sentence. This formulation enables us to develop a language modeling-based method that is drastically efficient compared to the existing deep learning approach that formalizes the slot filling as a sequence labeling task. The proposed method trains the language models by a one-pass algorithm and applies a dynamic programming algorithm to find the most likely slot assignment efficiently. We empirically confirmed that the proposed method achieves a competitive accuracy compared to a deep learning method, and even works with drastically less computing resource consumption.

1. はじめに

近年、音声認識システムやチャットボットの実用化が注目を集めている。これらのシステムのインタフェースでは、ユーザは自然言語の文章でシステムに対して指示を行うため、入力された文から機能の実行に必要な情報を抽出する必要がある。例えば、「新潟の降水量を教えてください」というユーザの入力に対して、{ **Where** : 新潟, **What** : 降水量 } といった情報を抽出する。このようなタスクはスロットフィリングと呼ばれ、**Where** や **What** などの変数をスロットと呼ぶ。

スロットフィリングタスクは、系列ラベリングの問題として定式化されることが多く、深層学習を用いた手法によって高い精度で抽出できることが報告されている [Xu 13]。これらの手法では、CNN や LSTM の層によって文章の特徴量を抽出し、タグの前後関係を考慮した CRF などの層によって系列ラベルを予測する [Mesnil 15]。このアプローチは精度が高いが、モデルの学習に大きな計算資源が必要になる。

本研究では、計算資源の小さい環境でも高速に学習が可能なスロットフィリング手法を提案する。提案手法は、スロットごとに学習した言語モデルを用いて、入力文の尤度が最大になるような分割を求めることで、スロットフィリングを実現する。特に、図 1 に示すように、スロット部分の確率だけではなく、非スロット部分も言語モデルを定義して尤もらしさを評価することにより、頑強で精度の高いスロット推定が可能になることを明らかにする。深層学習よりも学習や推定にかかる時間が少ない言語モデルを用いることで、小さい計算資源で深層学習手法と同等の精度が達成できることを実験により示す。

2. 提案手法

本研究では、文のラベル付き分割を行うことでスロットフィリングを実現する。例えば、図 1 の (b) の例では、入力文を「新潟市」「の」「降水量」「を教えてください」の 4 つのセグメントに分割し、それぞれ「**Where** スロット」「**Middle** 非スロット」「**What** スロット」「**Ending** 非スロット」というラベルを付与している。形式的には、入力文をトークンの系列 $x_{1:T} = x_1, \dots, x_T$ と表

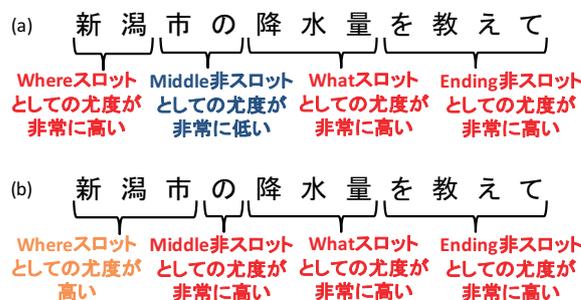


図 1: 文の最適分割に基づくスロットフィリング。提案手法は非スロット部分も含めた結合尤度をモデル化するため、(a) よりも (b) の分割を最適分割として選択する。

し^{*1}、各セグメントの最後のトークンの位置を b_1, \dots, b_K 、それぞれのセグメントに付与するラベルを y_1, \dots, y_K と表す。 k 番目のセグメントに対応する部分トークン列は $s_k = x_{b_{k-1}+1:b_k}$ と表すことができる。ただし、最後の分割位置は必ず系列の終端であるため $b_K = T$ であり、便宜的に $b_0 = 0$ とする。

スロットフィリングタスクでは、抽出を要求されるスロットの集合 \mathcal{Z} (例えば、{ **Where**, **When**, **What** }) と、学習データの集合が与えられる。学習データは、文とスロット値割り当てのペアであり、例えば図 1 の文に対して { **Where** : 新潟, **What** : 降水量 } の情報が付与されているものとする。本研究では、この学習データをラベル付き分割の形式に変換する。この変換は、以下のステップによって行われる。

- 学習データに付与されているそれぞれのスロット $z \in \mathcal{Z}$ に対応する値を、トークン列の完全マッチに基づいて文の中から見つける。文におけるマッチした箇所をセグメントとし、ラベル z を割り当てる。
- 全てのスロットについて上記の処理を行なった後に、マッチしなかった箇所のトークン列を、それぞれセグメントとする。これらのセグメントに対応するラベルは、もしセ

連絡先: 若林啓, 筑波大学図書館情報メディア系, 茨城県つくば市春日 1-2, kwakaba@slis.tsukuba.ac.jp

^{*1} 本論文の実験では、日本語の場合は文字を、英語の場合は単語を、それぞれトークンとして用いる。

グメントが文の先頭にあれば「Beginning 非スロット」、文の末尾にあれば「Ending 非スロット」、それ以外ならば「Middle 非スロット」とする。

このため、上記の3種類の非スロットラベルの集合を U とすると、ラベルの集合は $\mathcal{Y} = \mathcal{Z} \cup U$ となる。

本研究では、推論アルゴリズムの計算量を抑えるため、セグメントの前後関係については考慮しない。入力トークン列とラベル付き分割の同時確率を、以下のように定義する。

$$p(x_{1:T}, b_{1:K}, y_{1:K}) = \prod_{k=1}^K p(y_k) p(x_{b_{k-1}+1:b_k} | y_k) \quad (1)$$

$p(y_k)$ はラベルの出現確率であり、学習データ中の頻度に基づいて推定する。 $p(x_{b_{k-1}+1:b_k} | y_k)$ は、ラベル y_k に対応した言語モデルによるトークン列の確率であり、以下の節で述べる。

2.1 言語モデルの定義

それぞれのラベル $y \in \mathcal{Y}$ について、異なるパラメータを持つ言語モデル \mathcal{P}_y を仮定する。ここでは、言語モデルは、トークン列 $s = w_1, \dots, w_L$ に対して確率を割り当てる確率モデルであり、その標本空間 \mathcal{V} は以下で表される。

$$\mathcal{V} = \{w_1, \dots, w_L | w_t \in \mathcal{C}, L \leq 0\}$$

\mathcal{V} の要素であるトークン列を、フレーズと呼ぶ。スロットフィリングタスクにおいては、実際にスロットに割り当てられるフレーズの種類は少ない場合が多い。例えば、前述の例において、「Where スロット」には、ほとんどの場合は都道府県や市区町村の名前が指定されるため、同じフレーズが繰り返し出現することが予想される。この仮定に基づいて、本研究では、中華料理店過程 (CRP) を言語モデルとして用いる。CRP は、標本空間 \mathcal{V} 上の確率分布であり、特に過去に観測したことのある値に高い確率を割り当てる。CRP は、観測したことの無い値に対しても、基底分布と呼ばれる別の確率分布に基づいて確率を割り当てることから、事前にスロットが取り得る値の集合を決定することなく、特定の種類のフレーズに集中して確率を割り当てた分布を推定することができる。本研究では、CRP の基底分布として n-gram モデルを用いる。

2.1.1 n-gram モデル

n-gram モデルは、過去の n トークンに依存した離散分布に基づいて次のトークンを推定する確率モデルである。ここでは、 \mathcal{V} 上での確率の総和が 1 になる確率分布を定義するために、フレーズの長さの確率を明示的にモデル化する [Zhai 13]。フレーズ $s = w_1, \dots, w_L$ の確率は、長さが L である確率と、それぞれのトークンの n-gram 確率の積によって定義される。

$$p_{ngram}(w_1, \dots, w_L) = p(L) \prod_{t=1}^L p(w_t | w_{t-n+1:t-1})$$

$p(L)$ は、最大トークン列長を仮定した上で、離散分布によって定義する。実験では、最大トークン列長は 256 とした。

2.1.2 ディリクレ過程スロットモデル

ディリクレ過程 $DP(\alpha^0, G^0)$ は、標本空間 \mathcal{V} 上の離散確率分布を生成する確率分布であり、基底分布と呼ばれる \mathcal{V} 上の確率分布 G^0 と、生成される分布の偏りの大きさを調整するパラメータ α^0 によって定められる。ここでは、 $G^0 = p_{ngram}$ とする。フレーズがある離散確率分布 \mathcal{P} に従うとして、 \mathcal{P} の事前分布をディリクレ過程 $DP(\alpha^0, p_{ngram})$ とすると、 N 個

のフレーズの観測値 $s_{1:N} = s_1, \dots, s_N$ の次に観測されるフレーズ s_{N+1} の予測分布は、CRP と呼ばれる確率過程に従う [Teh 05]。CRP では、補助変数として、基底分布から生成される値を保持するための潜在変数 $\phi = \{\phi_1, \phi_2, \dots\}$ と、それぞれの観測値が ϕ のどの要素に対応するかを表す潜在変数 $c_{1:N} = c_1, \dots, c_N$ を考える。 c_i は、 $s_i = \phi_{c_i}$ を満たすような値しか取らないものとする。CRP による予測分布は以下で与えられる。

$$p_{crp}(s_{N+1} | c_{1:N}, \phi, \alpha^0, p_{ngram}) = \sum_{m=1}^M \frac{n_m}{N + \alpha^0} \delta(\phi_m, s_{N+1}) + \frac{\alpha^0}{N + \alpha^0} p_{ngram}(s_{N+1})$$

ただし、 n_m は $c_{1:N}$ の中で ϕ_m が出現する回数、 M は $c_{1:N}$ の中に含まれる値の種類の数、 $\delta(\phi_m, s_{N+1})$ は $\phi_m = s_{N+1}$ ならば 1、そうでなければ 0 になる指示関数である。この予測分布は、確率 $\frac{N}{N + \alpha^0}$ で過去の観測値 $s_{1:N}$ の中に出現したフレーズが現れ、確率 $\frac{\alpha^0}{N + \alpha^0}$ で n-gram 分布に従って新たに生成されるフレーズが現れると推定しており、過去に観測した値に高い確率を与える分布になっている。このモデルをディリクレ過程スロットモデル (Dirichlet Process Slot Model, DPSM) と呼ぶ。本研究では、ラベル $y \in \mathcal{Y}$ に対応する言語モデル \mathcal{P}_y はそれぞれ独立なパラメータと潜在変数をもつ DPSM とし、フレーズ $s = w_1, \dots, w_L$ の確率は p_{crp} によって計算する。

2.2 言語モデルの学習

本研究では、各ラベルの言語モデルは独立に学習を行う。学習データはラベル付き分割の形式であるが、セグメントごとに独立にフレーズを抽出して言語モデルの学習データとする。

提案手法は、学習データ全体を 1 回だけスキャンするワンパスアルゴリズムによってモデルパラメータを学習する。DPSM には、潜在変数として $c_{1:N}$ と ϕ が含まれているが、これらは事後確率分布に従ってサンプリングを行うことで、逐次的に確定させる。 N 番目の学習データ s_N が与えられたとき、対応する割り当て c_N の事後確率は、以下で与えられる。

$$p(c_N = m | s_N, c_{1:N-1}, \phi) = \begin{cases} \frac{n_m \delta(\phi_m, s_N)}{\sum_{m'} \delta(\phi_{m'}, s_N) + \alpha^0} & m \leq M \\ \frac{\alpha^0}{\sum_{m'} \delta(\phi_{m'}, s_N) + \alpha^0} & m = M + 1 \end{cases}$$

もし N 番目までに s_N と同じフレーズが一度も出現しなければ、 $m = M + 1$ となる確率が 1 になる。

この分布に従ってサンプリングを行い、もし $m = M + 1$ が選ばれたならば、遅延評価により $\phi_{M+1} = s_N$ と確定する。このとき、 s_N は基底分布である n-gram モデルの $M + 1$ 番目の観測値となるため、n-gram モデルのパラメータを更新する。n-gram モデルは、トークンの n-gram 隣接確率と、フレーズ長に関するパラメータを持つが、これらはそれぞれ n-gram 頻度とフレーズ長の数え上げを行うことで更新する。

2.3 動的計画法による最適分割発見

学習済みの言語モデルを用いて、与えられた入力文に対する最適なラベル付き分割を求める。最適なラベル付き分割とは、式 (1) で与えられる同時確率が最大になるような $b_{1:K}$ および $y_{1:K}$ である。本研究では、最適なラベル付き分割の探索を、図 2 に示すラティス上の最短経路探索問題に帰着させる。このラティスは、トークン列を左から読んでいくとき、各トークンについてセグメントを継続するか終了するかを選択する過程に基づいている。図に示している「lwhat」「3end」といった

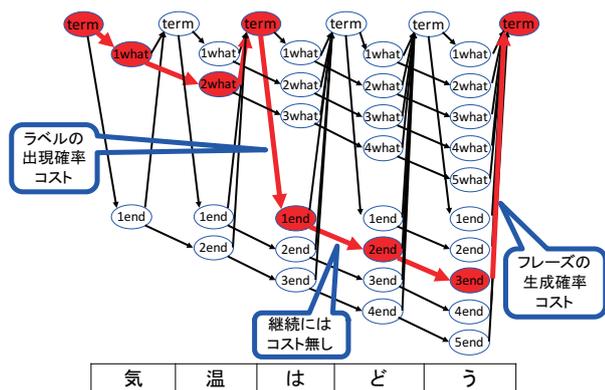


図 2: DPSM の推論を行うための動的計画法のラティス構造

ノードは、対応するトークンが、それぞれ「What スロット」ラベルの 1 単語目、「Ending 非スロット」ラベルの 3 単語目として解釈されることを表す。「term」ノードは、対応するトークン位置でセグメントが終了することを表す。

ラベル付き分割の結果は、このラティス上の経路として表現される。図で太い赤矢印で示された経路は、「気温」が「What スロット」ラベルのフレーズ、「はどう」が「Ending 非スロット」ラベルのフレーズ、と解釈する解析結果を示している。ラティス上の各エッジを通過するのにかかるコストを以下のように対応づけることで、DPSM における尤度最大の分割を行う問題は、ラティス上の最短経路を探索する問題に帰着される。

- セグメントを継続する場合には遷移コストはかからない。
- 「term」ノードへの遷移を行う際には、それまで継続中だったセグメントの確率を言語モデルで計算する。この値の負の対数をコストとする。
- 「term」ノードから別のノードに遷移を行う際には、遷移先のノードが表すラベルの確率を求める。この値の負の対数をコストとする。

これに基づいて、ダイクストラ法を用いて最短経路を求める。

3. 実験

提案手法の有効性を検証するため、実験を行なった。スロットフィリングのデータセットとして、DSTC コーパスと Weather コーパスを用いる。DSTC コーパスは、Dialog State Tracking Challenge 3 [Henderson 15] で提供された英語によるレストラン検索の対話データから、各対話の最初の発話のみを文として収集したものである。スロット情報が一つも含まれていない文は取り除き、文に現れる文字列と表記が異なるスロット値がある場合は手作業で表記を一致させて用いた。DSTC コーパスは 1,441 の文から構成され、**area, food, price range, type, children allowed** の 5 種類のスロットを含む。Weather コーパスは、日本語による天気の違いの問い合わせ発話データである。これはホンダ・リサーチ・インスティテュート・ジャパンが収集した非公開のデータであり、プロトタイプのチャット対話システムに対して社内のユーザが行なった発話の履歴のうち、天気情報について問い合わせた文を収集し、人手でスロット情報を付与したものである。Weather コーパスは 1,442 の文から構成され、**when, where, what** の 3 種類のスロットを含む。トークンの単位は、DSTC コーパスでは単語、Weather コー

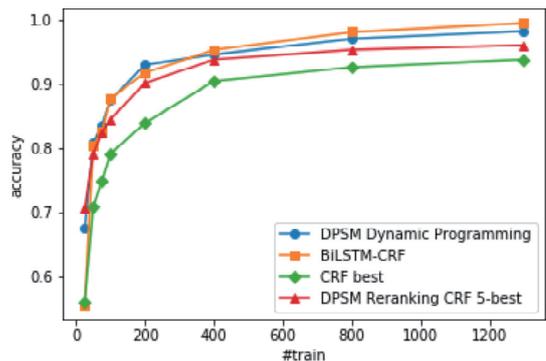
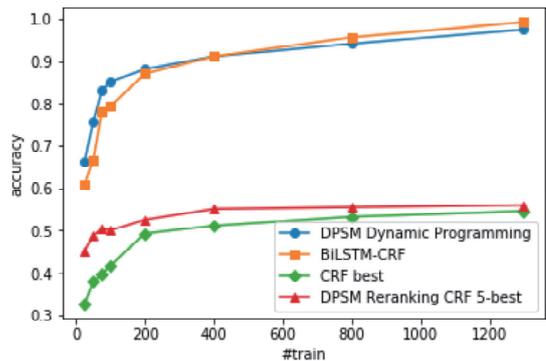


図 3: 上図が Weather コーパス (日本語), 下図が DSTC コーパス (英語) のスロット推定精度。横軸は学習データの数, 縦軸はテストデータの完全一致正解率を示している。

パスでは文字とした。これは、英語ではスペースで区切られた箇所以外でセグメントが分割されることは考えにくい、日本語の場合はそのような保証がないためである。

10 分割交差検定により、推定精度を計測した。また、交差検定におけるそれぞれの学習・テストセットにおいて、学習に用いるデータの数 (#train) を減らした時の精度の変化も計測する。比較手法として、条件付確率場 (CRF), Bidirectional LSTM に CRF を組み合わせたニューラルネットワーク (**BiLSTM-CRF**) [Reimers 17], および CRF の 5-best を DPSM によってリランキングする手法 (**DPSM Reranking CRF 5-best**) [Wakabayashi 16] を用いる。提案手法は、学習データを用いて DPSM のワンパス学習を行い、動的計画法によってスロットの推定を行う (**DPSM Dynamic Programming**)。

DPSM は Java で実装し、BiLSTM-CRF は Chainer (version 3.3) を用いて Python で実装した。実験は、Ubuntu 16.04, Xeon E5-2660 2.00GHz (14 コア) 2 基, メモリ 64GB のサーバ上で実行した。DPSM は並列計算を行わないため、1 スレッドで実行した。BiLSTM-CRF の学習は CPU で行い、物理的に並列して実行可能な 56 スレッドで実行した。

スロットの推定精度は、テストデータに含まれる文のうち、推定されたスロットが完全一致している文の数の割合として求める。図 3 に、スロット推定精度の結果を示す。横軸が学習に用いるデータの数であり、縦軸が 10 分割交差検定によって得られた推定精度の平均値である。結果を見ると、提案手法は深層学習手法とほぼ同等の精度を達成できていることが確認できる。Weather コーパスでは、学習データ数が少ない時には提案手法が最も精度が高く、学習コーパス構築の初期段階から安定した推定を行えることが示唆される。

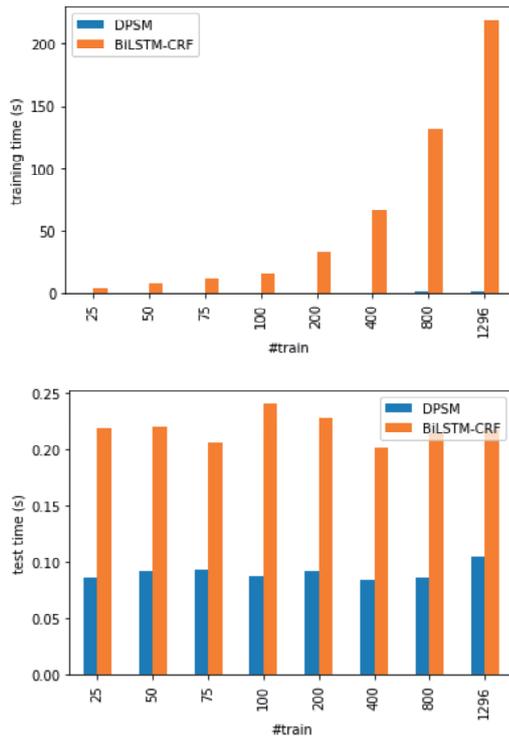


図 4: 学習時（上図）とテスト時（下図）の実行時間の比較

図 4 に、Weather コーパスにおける学習時とテスト時の実行時間の比較を示す。DSTC コーパスの結果は、Weather コーパスの結果と同様の傾向であるため、紙面の都合上割愛する。横軸は学習データの数、縦軸は 5 回の試行による実行時間の平均値である。学習時の結果を見ると、深層学習手法は学習データが増えるにつれて実行時間が非常に大きくなっているのに対して、提案手法は 1,000 件程度のデータに対しても数秒以内に学習が終了しており、高速であることが分かる。テスト時はどちらの手法も十分高速であるが、提案手法は実行時間が半分程度で済むことがわかる。

図 5 に、Weather コーパスにおける学習時とテスト時の消費メモリ量の比較を示す。実行時間と同様、DSTC コーパスの結果は傾向が同じであるため割愛する。この結果を見ると、学習時、テスト時ともに提案手法の消費メモリ量は深層学習手法と比較して圧倒的に少ないことがわかる。これは、車載端末や携帯端末での利用を考えた時には有用な特性である。

4. 結論

本研究では、言語モデルによる文の最適分割に基づくスロットフィリングのアプローチを提案した。実験により、提案手法は深層学習手法と同等の精度を達成しつつ、高速かつ省メモリであることを示した。学習データを持続的に獲得できる状況では、深層学習では再学習にかかる時間が増加していくため、モデルの更新が追いつかなくなる懸念があるが、提案手法のパラメータ学習はワンパスアルゴリズムであることから、学習データの追加に対しては追加分の計算コストしかかからない。このため、ユーザから得られる教示情報を、即時的に推定結果に反映させるような運用も可能であると考えられる。

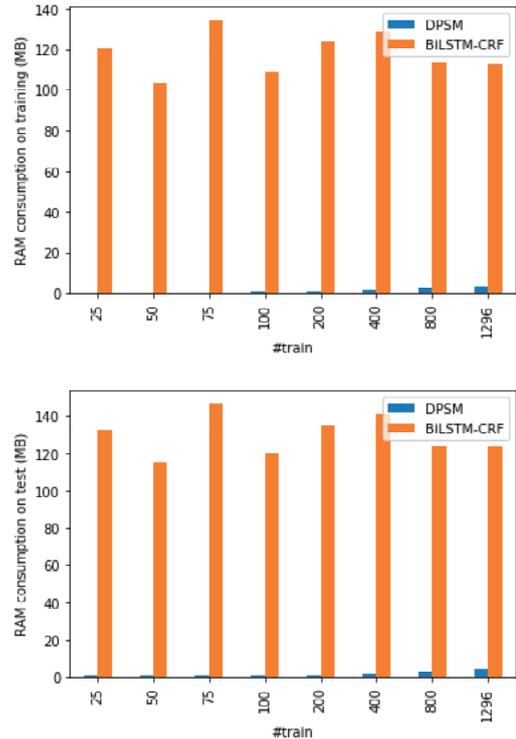


図 5: 学習時（上図）とテスト時（下図）の消費メモリの比較

参考文献

- [Henderson 15] Henderson, M. S.: *Discriminative Methods for Statistical Spoken Dialogue Systems*, PhD thesis, University of Cambridge (2015)
- [Mesnil 15] Mesnil, G., et al.: Using Recurrent Neural Networks for Slot Filling in Spoken Language Understanding, *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, Vol. 23, No. 3, pp. 530–539 (2015)
- [Reimers 17] Reimers, N. and Gurevych, I.: Reporting Score Distributions Makes a Difference: Performance Study of LSTM-networks for Sequence Tagging, in *Proc. EMNLP* (2017)
- [Teh 05] Teh, Y. W., Jordan, M. I., Beal, M. J., and Blei, D. M.: Hierarchical Dirichlet Processes, *Journal of the American Statistical Association*, Vol. 101, pp. 1566–1581 (2005)
- [Wakabayashi 16] Wakabayashi, K., Takeuchi, J., Funakoshi, K., and Nakano, M.: Nonparametric Bayesian Models for Spoken Language Understanding, in *Proc. EMNLP* (2016)
- [Xu 13] Xu, P. and Sarikaya, R.: Convolutional neural network based triangular CRF for joint intent detection and slot filling, in *Proc. IEEE Workshop on Automatic Speech Recognition and Understanding* (2013)
- [Zhai 13] Zhai, K. and Boyd-graber, J.: Online Latent Dirichlet Allocation with Infinite Vocabulary, in *Proc. ICML* (2013)

単語埋め込みにおける複数視点の対義語判定

Distinguish Antonyms in Multiple Viewpoints on Distributed Word Representations

中村 拓^{*1} 田然^{*2} 佐々木 翔大^{*1} 乾 健太郎^{*1*3}
Taku Nakamura Ran Tian Shota Sasaki Kentaro Inui

^{*1}東北大学 Tohoku University ^{*2}産業技術総合研究所 National Institute of Advanced Industrial Science and Technology (AIST)

^{*3}理化学研究所 AIP センター
RIKEN Center for Advanced Intelligence Project (AIP)

Distributed representations of words (word embeddings) are proven effective for measuring word similarity and additive compositionality. However, it is challenging to distinguish between synonyms and antonyms because their proximity in the word embedding space is generally close due to their interchangeability in the context. In this paper, we aim to build a model that can discriminate antonyms in the embedding space without affecting important properties of original word embeddings. Our method is designed to learn multiple hyperplanes for capturing antonymy relations in the embedding space in a supervised manner. Our empirical evaluation demonstrates that we can reasonably distinguish between synonyms and antonyms and reveals that several intriguing issues still remain.

1. はじめに

単語の意味をベクトル空間に埋め込む単語埋め込みは、自然言語処理の幅広いタスクに応用されている [Chen 14, Melamud 16]. 単語の周辺文脈を予測することで学習された単語埋め込みでは、似た文脈で出現する単語同士がベクトル空間内において近い位置に埋め込まれるため (図 1 中の “happy” と “glad”), 単語の類似性判定に有効であることが示されている [Hill 15]. しかしながら、対義語のように異なる極性を持つにも関わらず似た文脈で出現する単語については、従来の埋め込み手法を用いると、やはりベクトル空間内で近い位置に埋め込まれてしまい、単語間の同義・類義関係と対義関係を区別することができないという問題がある. 例えば、感情極性を持つ “happy” と “unhappy” は、どちらの単語も人の感情を言及する文脈で出現することが多く、ベクトル空間内で近い位置に埋め込まれてしまう (図 1). この問題は単語埋め込みを含意関係認識などの自然言語の意味計算に適用する上で大きな障害となってきた [Nguyen 17].

単語埋め込みにおける対義語の扱いについてはこれまで大きく 2 つのアプローチが提案されている. 1 つ目は辞書情報を教師情報として利用し、ベクトル空間内において同じ極性の単語を近づけ、異なる極性の単語を遠ざけるように単語埋め込みを学習するアプローチである [Faruqui 15, Ono 15, Pham 15, Mrksić 16]. しかし、対義語のベクトルを大きく遠ざけると、元の単語埋め込みベクトルが持っていた加法構成性などの重要な性質を損なうおそれがあり、実際にそうした副作用が報告されている.

第 2 のアプローチは、元の単語埋め込みのベクトルは変えずに、感情極性などの極性を識別する識別面を学習する手法である. この枠組みでは、元の単語埋め込みが持つ加法構成性などの重要な性質を損なうことなく “happy”-“unhappy” の

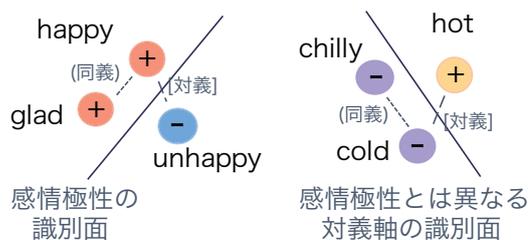


図 1: 単語埋め込みベクトル空間における複数の識別面 (対義識別面) の学習

ような対義関係を表現できる. Rothe ら [Rothe 16] は単語埋め込み空間の直交部分空間に感情極性など特定の意味的な性質を写像し、他の意味的な特徴から分離できることを示した. また、中村ら [Nakamura 18] は、単語埋め込み空間内で個々単語の感情極性を識別する線形識別器を学習することができることを実験的に示している. 中村らの方法では、例えば図 1 の “happy”, “unhappy”, “glad” のようにベクトル空間で近傍にある語の感情極性を識別する線形識別器を、一部の単語に対する感情極性ラベル付き訓練データで学習することで、感情極性が未知の単語について 90 % を超える精度で感情極性を予測している. 極性の識別面は線形識別平面であるため、この平面の法線ベクトルが埋め込み空間のどれかの基底と一致するように空間全体を回転させれば、特定の 1 次元の成分の符号を見るだけで極性を判別できる単語埋め込み空間が得られることになる.

このように中村ら [Nakamura 18] のアプローチにはいくつかの重要な利点があるが、一方でこれを感情極性以外の一般の対義関係に一般化するには、次に述べる課題を解決する必要がある. 中村らの手法では、単語埋め込み空間を感情極性がポジティブの領域とネガティブの領域に単一の線形識別平面で分離することができるという仮定をおいていた. しかしながら、一般の対義関係の中には、例えば図 1 の “hot”-“cold” の対義ベ

連絡先:

中村 拓 : tnakamura@ecei.tohoku.ac.jp
田 然 : robin.tianran@gmail.com
佐々木 翔大 : sasaki.shota@ecei.tohoku.ac.jp
乾 健太郎 : inui@ecei.tohoku.ac.jp

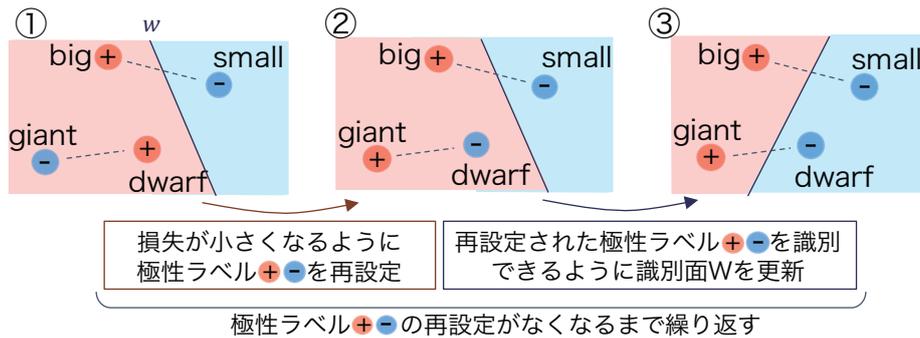


図 2: Transductive SVM を拡張した対義識別面の学習の概要。破線は対義の意味関係を表す。

アのように、感情極性では捉えられない対義軸（対義の視点）を持つものが多く存在すると予想される。そこで本稿では、図 1 のように、対義を表現する線形識別平面（以下、これらの識別面を「対義識別面」と呼ぶ）を複数用意し、

単語ベクトルが十分に似ていて、かつ対義識別面のどれかの極性が異なれば対義と判別し、全ての対義識別面で同じ極性を持たば同義と判別する単語埋め込み

を実現する前段として、その対義識別面を同義語・対義語からなる訓練事例から教師あり学習することを考える。ここで問題となるのは、様々な対義関係をどの対義識別面で表現すべきか、が訓練事例からはわからない点である。この問題に対して本稿では、学習と推論を交互に繰り返し行う **Transductive SVM** [Joachims 99] を拡張し、対義の分離軸（対義の視点）に対応する複数の対義識別面を同時に学習する手法を提案する。

2. TSVM を拡張した対義識別面の学習

本節では、WordNet[Fellbaum 98] のような資源から得られる対義・同義関係にある単語ペア集合を訓練データとして用いて、与えられた単語埋め込み空間内で対義を識別する対義識別面を学習する方法について説明する。

ただし本稿で対象とする対義極性は、感情極性におけるポジティブ・ネガティブのように単一の分離軸を設けることは難しいため、複数の分離軸に相当する複数の対義識別面を学習しながら、訓練データ中の対義語・同義語ペアに極性ラベルを設定する。本研究では、Transductive SVM (TSVM) [Joachims 99] のラベル設定及び識別面の学習方法を拡張して、学習と推論を交互に繰り返ししながら、対義語ペア・同義語ペアに対して極性ラベルを設定し、対義識別面を学習する手法を提案する。TSVM は、半教師あり学習の一つである Transductive 学習を SVM (Support Vector Machine) に適用し、ラベル付きの訓練データが少ない場合でも分類精度を向上させる手法で、学習と推論を交互に繰り返しながら、学習が収束した時点の予測を最終出力とする。

TSVM を拡張して対義識別面を学習するタスク設定は、
入力 単語ペアの意味関係ラベル（対義・同義）、
単語埋め込みベクトル集合

出力 対義識別面（識別関数の係数ベクトル）
とし、訓練データの単語ペアの意味関係ラベル（対義・同義）を用いて、単語埋め込みベクトルに極性ラベル（+ または -）を設定しながら対義識別面の学習を行う。

提案手法は、1) 極性ラベルの設定ステップと 2) 対義識別面の更新ステップの 2 つのステップを極性ラベルの再設定が生じ

なくなるまで繰り返すことで、最終的な対義識別面を得る。学習の概要を図 2 に示す

2.1 極性ラベルの設定ステップ

ここでは対義識別面の数を 1 つと仮定し、学習における極性ラベルの設定ステップ（図 2 ①→②）について説明する。はじめに、訓練データ中の対義語ペアに対して一方の単語に正（+）の極性ラベル、もう一方の単語に負（-）の極性ラベルを設定する。その時、（+，-）と（-，+）の 2 通りの仮ラベルで識別損失を計算し、損失が小さくなる極性ラベルを設定する。例えば図 2 の①で、“giant” と “dwarf” のペアについて、対義識別面 w での識別損失を計算した場合、“giant” の誤分類による損失が大きいため、より損失が小さくなる極性ラベル（“giant” が +，“dwarf” が -）を設定する。この時、対義語ペアの各単語は必ず異なる極性ラベルとなる。同様に、同義語辞書の同義語ペアに対しては、両方の単語に正または負の同じ極性ラベルを設定する。その時、（+，+）と（-，-）の 2 通りの仮ラベルで分類誤りの損失を計算し、損失が小さくなる極性ラベルを設定する。

2.2 対義識別面の更新ステップ

次に、設定された極性ラベルを用いて、対義識別面 w を更新するステップについて説明する（図 2 ②→③）。対義語・同義語の識別損失関数 J として、ヒンジ損失関数を用いる。

$$J(w) = \frac{1}{N} \sum_{j=1}^N l(p_j, w), \quad (1)$$

ただし、 N は訓練データの単語ペア数、 p_j は訓練データの単語ペア、 $l(p_j)$ は p_j の対義識別面 w に関する損失を表す。 $l(p_j)$ は以下の式で計算される。

$$l(p_j, w) = \sum_{i \in p_j, w} \max(0, 1 - y_i(w \cdot v_i - b)). \quad (2)$$

y_i は前のステップで設定した極性ラベル、 w は識別関数の係数ベクトル、 v_i は単語埋め込みベクトル、 b はバイアス項を表す。

2.3 複数の対義識別面への拡張

ここまでの学習においては、対義識別面の数を 1 つと仮定していた。次に、複数の対義識別面を学習できるように極性ラベルの設定ステップと対義識別面の更新ステップを拡張する。

複数の対義識別面に拡張する前提として、図 1 の “hot” と “cold” のようにベクトル空間で近い位置にある対義は、全て

対義識別面 1	対義識別面 2	対義識別面 3	対義識別面 4
「明確性」	「平和的か」	「金権や物」	「方向」
blunt, sharp indefinite, definite stupid, intelligent cruel, kind	timid, bold refuse, offer war, peace unlawful, lawful	poverty, wealth new, second-hand natural, artificial king, subject	onward, backward internal, external sane, crazy impatient, patient

表 1: 各対義識別面で識別された対義語ペアの例 (4 対義識別面) 及び分離基準の解釈例

の対義識別面のうちのどれか 1 つの対義識別面で分離できれば対義であるとする。一方、同義については、全ての対義識別面で分離されなければ同義であるとし、この前提をみだすような拡張を考える。

複数の対義識別面を学習する場合、極性ラベルの設定ステップ (2.1 節) において、各対義識別面ごとに極性ラベルを設定する。対義識別面の更新ステップにおいては (2.2 節)、対義については、その対義識別面における損失が最小となる単語ペアを訓練事例として用いる。同義については、全ての単語ペアを訓練事例として用いる。これは、どれか 1 つの対義識別面でも分離されたら対義とする前提から、対義については最も識別しやすい単語ペアを分離できれば十分であり、一方同義については、全ての対義識別面で分離されなければ同義とする前提から、全単語ペアを分離しない制約が必要となることに対応した設計である。\$m\$ 個の対義識別面の集合を \$\mathbf{W}\$ とした時、対義識別面 \$\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m \in \mathbf{W}\$ に対して、対義語ペアの識別損失関数 \$J_a\$ を以下に定義する。

$$J_a(\mathbf{W}) = \frac{1}{N} \sum_{j=1}^N \min[l_1(p_j), l_2(p_j), \dots, l_m(p_j)], \quad (3)$$

ただしペア \$p_j\$ に関する対義識別面 \$\mathbf{w}_k\$ の識別損失を \$l_k(p_j)\$ とした。また、対義識別面の数 \$m\$ はハイパーパラメータである。同義語ペアの識別損失関数 \$J_s\$ を以下に定義する。

$$J_s(\mathbf{W}) = \frac{1}{N} \sum_{j=1}^N \sum_{k=1}^m l_k(p_j). \quad (4)$$

最終的に、対義識別面の更新ステップは以下の最小化問題として定義する。

$$\hat{\mathbf{W}} = \arg \min_{\mathbf{W}} \{J_a(\mathbf{W}) + J_s(\mathbf{W})\} \quad (5)$$

3. 実験

3.1 対義語・同義語の判定

学習された対義識別面の有効性を測るため、対義語ペアと同義語ペアからなる評価データを用い、性能評価実験を行う。評価時は、

入力 対義語ペアまたは同義語ペアの単語ベクトル

出力 ペアの各単語の極性ラベル

とし、1 対義識別面について、評価データの単語ペアに対し、異なる極性ラベルを予測すれば対義語ペア、同じ極性ラベルを予測すれば同義語ペアと判定する。複数の対義識別面では、全ての対義識別面の内、どれか 1 つの対義識別面でも対義を予測すれば対義語ペアとみなし、全ての対義識別面で同義と予測すれば同義語ペアとみなす。

3.2 実験設定

評価データとして、[Roth 14] [Nguyen 16] で使用されている対義語・同義語ペアのデータセット*1 から、形容詞・動詞・名詞の全ペアを合わせた 2100 ペアのうち、語彙内で対義・同義の訓練データ内のペアを除く 1864 ペア (対義 966 ペア, 同義 893 ペア) を用いる。対義の訓練データには、WordNet[Fellbaum 98] 及び Roget's Thesaurus[Kipfer 09] から作成されたデータ*2 より、抽出したペア間の単語重複を除き、語彙内の 4996 ペア (9992 語) を用いる。同義の訓練データとして、WordNet [Fellbaum 98] から、対義の訓練データと単語が重複しない 3546 ペアを用いる。対義識別面学習に用いる単語埋め込みベクトルは、SGNS [Mikolov 13] モデルを用いて、英語 Wikipedia 上で訓練した 200 次元のベクトルを用いた。学習する対義識別面の数は 1 から 6 とする。

3.3 対義識別面による対義のクラスタリング

提案手法で学習された各対義識別面で識別された対義語ペアの例*3 を表 1 に示す。各対義識別面で分離された対義語ペアから、対義を分離する軸として、例えば対義識別面 1 は「明確性」、対義識別面 2 は「平和的か」、対義識別面 3 は「金権や物」、対義識別面 4 は「方向」のような基準で分けられていると解釈しうる。このように各対義識別面で識別されたペアから、どのような対義の軸が存在するか解釈の可能性があり、特徴量に用いた通常の単語ベクトルにも対義を識別する軸が存在しているのではないかと考えられる。各対義識別面において異なる性質の対義ペアが分離されることは、複数の対義識別面を学習するとき、各対義識別面において損失が最小となるペアを訓練事例に用いて対義識別面を更新するため、各対義識別面で別の分離軸が獲得されていくと考えられる。また、例えば対義識別面 4 で分けられた対義語では、「物理的な方向」と「性格的な方向」のように、対義識別面の数を増やすと、別の分離軸を獲得できる可能性がある。

3.4 対義語・同義語判定の性能

対義識別面の数と対義語・同義語の判定の正解率の関係を図 3 に示す。横軸は対義識別面の数、正解率を表す。対義識別面の数による正解率は、それぞれ対義と同義の両方の訓練データを用いて学習を行った場合 (左)、対義の訓練データのみを用いた場合 (中央) の正解率、チャンスレート (ランダムに対義または同義と出力したときの正解率) を示している。

図 3 から、対義識別面 1 つのとき、チャンスレートより正確に対義を見分けられており、TSVM を拡張した提案手法は

*1 http://www.ims.uni-stuttgart.de/forschung/ressourcen/experiment-daten/lexical_contrast_dataset.html

*2 <https://github.com/antonyms/AntonymPipeline/tree/master/data>

*3 対義の訓練データのみを用いて学習し、実験設定とは別の評価データ (対義の訓練データを取得したりポジトリ*2 の評価データ) での識別例を示している。

		予測				予測	
		対義	同義			対義	同義
正解	対義	556	410	正解	対義	805	161
	同義	298	600		同義	534	364

(a) 対義識別面の数=1

(b) 対義識別面の数=6

表 2: 対義語・同義語の判定の混同行列

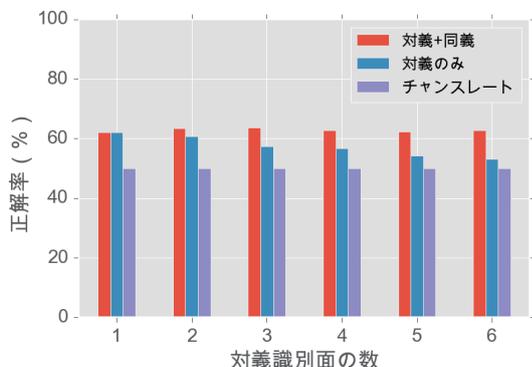


図 3: 対義識別面の数と対義語・同義語判定性能の関係

対義識別面の学習に効果があると考えられる。対義識別面の数を増やすと、対義の訓練データのみを用いて学習された対義識別面の正解率は低下した。これは、対義識別面の数の増加にともない、同義語ペアを対義識別面で分離してしまう確率が高まるのが理由としてあげられる。一方で、対義と同義の訓練データ両方を用いて学習された対義識別面の性能は、対義識別面の数に関わらず、一定を保つことができた。これは同義の訓練データを学習に用いることで、同義語を分離しない学習が行われた結果といえる。

対義と同義の訓練データ両方を用いて、1つの対義識別面、6つの対義識別面を学習したときの、対義語・同義語の判定における混同行列をそれぞれ表 2a、表 2b に示す。対義識別面の数が1つのとき、対義の正解率は低く、それに比べ同義の正解率は高かった。対義識別面の数が6つのとき、対義の正解率は高く、それに比べ同義の正解率は低くなった。そのため、図 3 のように全体としての正解率は対義識別面の数を増やしても一定となっていることがわかる。対義を分離すること、同義を分離しないことは、概ねトレードオフの関係にある結果となっている。

4. 議論：複雑な同義・対義関係の学習

今回の実験設定では、同義の訓練データは、対義の訓練データと単語の重複がないペアのみを用いた。単語の重複がある場合、例えば図 4 における対義ペア “big”-“small” の “big” に対する “large” のような「対義語の同義語」を考える。ペアごとに関係をみだす極性ラベルを設定していくと、“big” と “large” の同義ペアに異なる極性ラベルが設定され、その極性ラベルを再設定して “big” の極性ラベルが変わると、“big”-“small” の対義ペアが同じ極性ラベルになることが起こりうる。対義・同義の関係には図 4 のような複雑な依存関係があり、両方の制約をみだすラベルを探索する必要がある。全単語の対義・同義両方の関係をみだす極性ラベルの探索は簡単ではなく、実験では訓練データから除いた。しかし、正しく対義を識別するためには、同義を分離しない対義識別面を学習する必要がある、

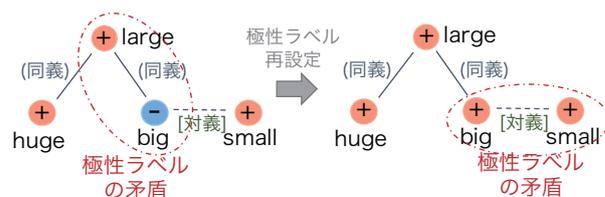


図 4: 複数の関係をもつ単語に対する極性ラベルの割り当て

対義語の同義語も同じ極性ラベルになるような考慮を要する。

5. おわりに

本論文では、単語埋め込み空間で対義の分離軸（対義の視点）に対応する複数の対義識別面を学習する手法を提案し、実際に学習した各対義識別面が異なる対義の分離軸を捉えることを示した。また、対義・同義の判定による評価から、対義と同義を正しく識別するためには、同義情報も利用した学習が有効であることを示した。一方で、より複雑な依存関係をもつ対義・同義の訓練事例を用いた対義識別面の学習における課題を論じた。

謝辞

本研究の一部は JST CREST (JPMJCR1301) および科研費 (15H01702) の支援を受けて行った。

参考文献

- [Chen 14] D. Chen, C. Manning: A fast and accurate dependency parser using neural networks, in *EMNLP*, pp. 740–750 (2014)
- [Faruqui 15] M. Faruqui *et al.*: Retrofitting Word Vectors to Semantic Lexicons, in *NAACL* (2015)
- [Fellbaum 98] C. Fellbaum: *WordNet: An Electronic Lexical Database*, Vol. 71 (1998)
- [Hill 15] F. Hill, R. Reichart, A. Korhonen: SimLex-999: Evaluating Semantic Models With (Genuine) Similarity Estimation, *Computational Linguistics*, Vol. 41, No. 4, pp. 665–695 (2015)
- [Joachims 99] T. Joachims: Transductive Inference for Text Classification using Support Vector Machines, in *ICML*, pp. 200–209 (1999)
- [Kipfer 09] B. Kipfer: *Roget's 21st Century Thesaurus*, Philip Lief Group (2009)
- [Melamud 16] O. Melamud *et al.*: The Role of Context Types and Dimensionality in Learning Word Embeddings, in *Proceedings of NAACL-HLT 2016*, pp. 1030–1040 (2016)
- [Mikolov 13] T. Mikolov *et al.*: Distributed representations of words and phrases and their compositionality, in *NIPS*, Vol. 2 (2013)
- [Mrksić 16] N. Mrksić *et al.*: Counter-fitting Word Vectors to Linguistic Constraints, in *NAACL-HLT*, pp. 142–148 (2016)
- [Nakamura 18] T. Nakamura, T. Ran, K. Inui: 単語の極性を埋め込んだ分散表現, 言語処理学会第 24 回年次大会予稿集 (2018)
- [Nguyen 16] K. A. Nguyen, S. Schulte Im Walde, N. T. Vu: Integrating Distributional Lexical Contrast into Word Embeddings for Antonym-Synonym Distinction, in *ACL*, pp. 454–459 (2016)
- [Nguyen 17] K. A. Nguyen, S. S. im Walde, N. T. Vu: Distinguishing Antonyms and Synonyms in a Pattern-based Neural Network, in *EACL*, Vol. 1, pp. 76–85 (2017)
- [Ono 15] M. Ono, M. Miwa, Y. Sasaki: Word Embedding-based Antonym Detection using Thesauri and Distributional Information, *NAACL* (2015)
- [Pham 15] N. T. Pham, A. Lazaridou, M. Baroni: A Multitask Objective to Inject Lexical Contrast into Distributional Semantics, in *ACL* (2015)
- [Roth 14] M. Roth, S. S. im Walde: Combining Word Patterns and Discourse Markers for Paradigmatic Relation Classification, in *ACL* (2014)
- [Rothe 16] S. Rothe, H. Schütze: Word Embedding Calculus in Meaningful Ultradense Subspaces, in *ACL* (2016)

[1N4-J-9] Natural language processing, information retrieval: domain knowledge analysis

Chair:Tomoko Okuma Reviewer:Kugatsu Sadamitsu

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room N (Front-right room of 1F Exhibition hall)

[1N4-J-9-01] Chemical Named Entity Recognition with Self-Training

○Yiming Cui^{1,3}, Hitoshi Nishikawa^{1,3}, Takenobu Tokunaga¹, Hiyori Yoshikawa^{2,3}, Tomoya Iwakura^{2,3} (1. School of Computing, Tokyo Institute of Technology, 2. Fujitsu Laboratories Ltd., 3. RIKEN AIP-Fujitsu Collaboration Center)

5:20 PM - 5:40 PM

[1N4-J-9-02] Adding Multiple Subword Sequences to BiLSTM-CRF Model for Compound Name Extraction

○Hiroto Sekine¹, Go Urasawa¹, Takashi Inui¹, Tomoya Iwakura² (1. Tsukuba Univ. / Riken AIP Fujitsu center, 2. Riken AIP Fujitsu center)

5:40 PM - 6:00 PM

[1N4-J-9-03] Using Subword Sequence BiLSTM-CRF Model for Compound Name Extraction

○Go Urasawa^{1,3}, Hiroto Sekine^{1,3}, Takashi Inui^{1,3}, Tomoya Iwakura^{2,3} (1. University of Tsukuba, 2. Fujitsu Laboratories, 3. RIKEN AIP-FUJITSU Collaboration Center)

6:00 PM - 6:20 PM

[1N4-J-9-04] Analysis of vocabulary and omitted words in car license tests

○Seiki Matoba¹, Masaki Koga¹, Motohiro Otuka¹, Ichirou Kobayashi², Hiroto Taira¹ (1. Faculty of Information Science and Technology, Osaka Institute of Technology, 2. Graduate School of Humanities and Sciences, Ochanomizu University)

6:20 PM - 6:40 PM

自己学習による化学文書中の専門用語抽出

Chemical Named Entity Recognition with Self-Training

崔一鳴 *1*3

Yiming Cui

西川仁 *1*3

Hitoshi Nishikawa

徳永健伸 *1

Takenobu Tokunaga

吉川和 *2*3

Hiyori Yoshikawa

岩倉友哉 *2*3

Tomoya Iwakura

*1東京工業大学 情報理工学院

School of Computing, Tokyo Institute of Technology

*2株式会社富士通研究所

Fujitsu Laboratories Ltd.

*3理研 AIP-富士通連携センター

RIKEN AIP-Fujitsu Collaboration Center

In this paper, we propose to use self-training for chemical named entity recognition. We first train a neural network-based model for chemical named entity recognition model using the CHEMDNER corpus. The trained model is used to annotate the unlabelled MEDLINE corpus to create automatically labelled training data. We then use both training data, manually labelled CHEMDNER corpus and automatically labelled MEDLINE corpus, to train our final model. The evaluation using the unlabelled MEDLINE corpus as training data showed that the effectiveness of self-training in the chemical named entity recognition task.

1. はじめに

化学分野の研究は非常に盛んであり、日々新たな発見がなされ、論文が発表されている。それらの論文の中には今まで登場したことのない、新しい化学用語が出現する。化学用語のデータベースは化学分野の研究において重要な言語資源であるが、現状ではそのデータベースは新しく出版された論文や特許を人手によって読解し、新しく出現した用語を抽出し構築されている。この作業は費用を要する作業であるだけでなく、時間的な面においても困難であり、新しい用語の登場の速度に人手による抽出によって追従することは容易ではない。さらに、化学分野に精通した人員でなければ新しい化学用語の抽出は難しい作業であるため、人員の確保そのものも容易ではない。そのため、論文からの情報抽出の自動化は急務である。

この問題を解決するため、化学文書からの化学に関する専門用語の自動抽出を試みる研究が進められている [14]。化学用語の自動抽出課題のために作られたコーパスである CHEMDNER コーパス [4] においては、10,000 件の化学分野の論文のアブストラクト (訓練データ 3,500 件, 開発データ 3,500 件, テストデータ 3,000 件) に対して、化学用語部分にラベルが付与されている。このコーパスにおいて現時点での最高精度を報告している研究は Bi-LSMT-CRF [5] に注意機構を加えたモデルであり、F 値 91.14% を達成している [6]。同じデータに対して、専門家が化学用語の抽出を行った結果の一致率は 89% であるため、それを上回る精度を達成したことになる。

本研究では、この化学用語抽出課題の精度をさらに向上させる試みとして、自己学習によって CHEMDNER 以外の大規模なデータを利用する手法を提案する。具体的には、CHEMDNER の訓練データを用いて作成したモデルを用いて、化学用語部分にラベルが付与されていない MEDLINE コーパス [11] のアブストラクトにラベルを付与し、それを新しい訓練データとして、化学用語抽出のモデルを作成する。

2. 関連研究

化学用語の抽出については数多くの研究がなされており、類似する課題である固有表現抽出 [2] と同様に、機械学習を用いる手法が数多く提案されている。近年は、ニューラルネットワークを用いる手法が活発に研究されており、CHEMDNER コーパスにおける現時点での最高の性能を報告している論文 [6] は双方向 LSTM (Bi-LSMT) と条件付き確率場 (CRF) を組み合わせた Bi-LSMT-CRF [3, 7] に基づく。先行研究に倣い、本研究でも Bi-LSMT-CRF をベースラインとして学習を行い、モデルを作成する。Luo らは Bi-LSMT-CRF に注意機構 [1] を加えたモデルを採用し、最高精度を報告している。Luo らは入力の特徴量として、MEDLINE コーパスと CHEMDNER コーパスで word2vec を用いて単語分散表現を用いている。また、品詞データや Bi-LSMT による文字分散表現 [12] も入力の特徴量として用いている。

自己学習は自然言語処理において広く用いられており、構文解析 [8] や語義曖昧性解消 [9] などに利用されている。

ニューラルネットワークを利用したモデルに自己学習を利用した先行研究として竹前らが見出し生成課題に自己学習を利用したものの [16] がある。竹前らは、正例が付与されているデータからまずモデルを作成し、それを正例が付与されていないデータに対して適用することで疑似的な正例データを作成した。その上で正例が付与されているデータと、疑似的な正例データの両者を用いて最終的なモデルを作成した。自己学習を行ったモデルと行っていないモデルを比較することによって、竹前らが見出し生成課題において自己学習を行うことによって性能が向上することを示した。

本論文は、化学用語抽出課題において、自己学習を行うことを提案する。まず化学用語ラベルが付与されているデータセットである CHEMDNER コーパスを用いてモデルを学習し、化学用語ラベルが付与されていない MEDLINE コーパスに疑似的な正解ラベルを付与する。その後、CHEMDNER コーパスと疑似的な正解ラベルが付与された MEDLINE コーパスのデータを併せて再度モデルを作成し、これを最終的なモデルとする。

連絡先:

*1{sai.m.ab@m, hitoshi@c, take@c}.titech.ac.jp

*2{y.hiyori, iwakura.tomoya}@jp.fujitsu.com

3. 提案手法

本論文の提案手法は以下のような手順になる。

1. 教師あり学習：まず、CHEMDNER の訓練データを利用して教師あり学習を行う。これをベースラインモデルとする。
2. 疑似教師データの作成：次に化学用語のラベルが付与されていない、テキストのみのデータに対して手順 1 で作成したモデルを用いて、化学用語ラベルを付与する。これを疑似訓練データとする。
3. 新規モデルの学習：手順 1 で利用した CHEMDNER の訓練データと、手順 2 で化学用語ラベルを付与した疑似訓練データの両方を用いて、新しいモデルの学習を行う。その後、CHEMDNER のテストデータを用いて、このモデルの精度の評価を行う。
4. 手順 2 と手順 3 を繰り返し、最終的なモデルを得る：手順 3 で得られたモデルの性能の評価が手順 1 で得られたモデルよりも高精度である場合、手順 3 で得られたモデルを再度用いて手順 2 と手順 3 を行う。精度向上がみられなかった場合学習を終了し、最終的なモデルを得る。

4. 実験

4.1 ベースラインモデル

ベースラインのモデルは、単語分散表現と Bi-LSMT-CRF を利用している。構成図を図 1 に示す。

4.1.1 単語分散表現

単語系列をモデルに入力する際には、word embeddings 層を通して、単語を単語分散表現に変換している。その際には gensim^{*1} による word2vec[10] を利用した。使用データは CHEMDNER コーパスの訓練データおよび単語分散表現を得る際には、スペースで区切られているものを 1 単語とし、パラメータとして次元数は 100、window size は 4、iter は 10 とした。また min count は 0 とし、学習時に登場した単語を全て分散表現の辞書に登録した。

加えて、文字の分散表現の情報も gensim ライブラリの word2vec を用いて獲得した。文字分散表現は 10 次元とし、こちらも CHEMDNER コーパスの訓練データおよび MEDLINE コーパスを利用した。

最終的には、ある単語の単語分散表現は、単語そのものの分散表現 100 次元と、単語を構成する文字の分散表現 10 次元の合計 110 次元となる。文字の分散表現は、単語に含まれている文字分散表現の平均を取った 10 次元とした。

4.1.2 Bi-LSMT-CRF

本研究におけるベースラインのモデルは Bi-LSMT-CRF によって構築されている。これは PyTorch^{*2} を用いて実装を行った。LSTM の隠れ層は 150 次元とした。また、テストの際に、分散表現辞書にない未知語が現れた際には、ランダムなベクトルを生成し、割り当てた。登場する単語が未知でも、その単語に含まれている文字情報は未知ではないことが多い。単語が未知の場合は、ランダムに生成した 100 次元のベクトルと、文字情報から得られるランダムではない 10 次元のベクトルを合成して、110 次元のベクトルとした。また、本研究で

は未知語にランダムなベクトルを割り当てる際に、同じベクトルが割り当てられるよう seed 値を固定して乱数を生成した。

4.1.3 化学用語ラベル

化学用語ラベルには固有表現抽出課題で広く利用されている IOB2[13] タグ方式を採用した。これは、化学用語を構成する最初の単語に B、最初の単語ではないが化学用語の一部である単語には I、化学用語ではない単語には O というタグを付与するというものである。

4.1.4 学習

このモデルを CHEMDNER コーパスの訓練データを用いて学習を行ったものをベースラインのモデルとした。学習の際にはミニバッチ学習を行い、ミニバッチのサイズは 100 とした。また、epoch 数は最大 20 とした。

4.2 比較手法

- ベースライン手法：CHEMDNER コーパスの訓練データを用いて、前述のモデルを用いた化学用語抽出モデルを学習し、これをベースラインの手法として利用した。
- 提案手法：ベースラインの手法によって学習が行われたモデルを用いて、化学用語ラベルが付与されていない MEDLINE コーパスのデータに化学用語ラベルを付与し、それを疑似訓練データとし、前述したように CHEMDNER の訓練データと MEDLINE 疑似訓練データの両者を利用して化学用語抽出モデルを構築する。

4.3 データ

4.3.1 CHEMDNER コーパス

CHEMDNER コーパスは化学用語抽出課題のために構築されたコーパスである [4]。コーパスの統計量を表 1 に示す。CHEMDNER コーパスは化学関連論文のアブストラクト 10,000 件からなり、化学用語の箇所に化学用語ラベルが付与されている。化学用語は、TRIVAL, SYSTEMATIC, ABBREVIATION, FORMULA, FAMILY, IDENTIFIER, MULTIPLE, NO CLASS の 8 クラスに分類されラベルが付与されているが、本実験では先行研究 [6] と同様に、これら 8 クラスを等しく化学用語であるとして、すなわち単一のクラスとして扱う。

4.3.2 MEDLINE コーパス

MEDLINE は医学を中心とする文献情報を収集したオンラインデータベースである。[15] このデータベースは医学、薬学、看護学、歯学、衛生学、獣医学、生化学、分子生物学など医学に関連する幅広い文献情報を含んでいるが、本研究では、MEDLINE コーパスの中でも、2017 年版の CHEMDNER コーパス作成時に対象としたジャーナル・会議のもののみを利用した。MEDLINE コーパスには、CHEMDNER コーパスとは異なり、化学用語ラベルは付与されておらず、テキストのみのデータのみとなっている。使用した MEDLINE コーパスに含まれるアブストラクトの文字数の合計は約 18 億字であり、これは CHEMDNER コーパスの訓練データ約 488 万字の 375 倍の量に相当する。また、単語数は約 2 億 7 千万語あり、これは CHEMDNER コーパスの訓練データ約 77 万語の約 350 倍に相当する。前述したように、本研究ではこの MEDLINE コーパスに対して CHEMDNER コーパスで訓練したモデルを利用して化学用語ラベルの付与を行い、これを疑似訓練データとして利用する。

4.4 評価

学習を終えた化学用語抽出モデルは CHEMDNER コーパスのテストデータを利用して行う。また、本研究が対象とする

*1 <https://radimrehurek.com/gensim/>

*2 <https://pytorch.org/>

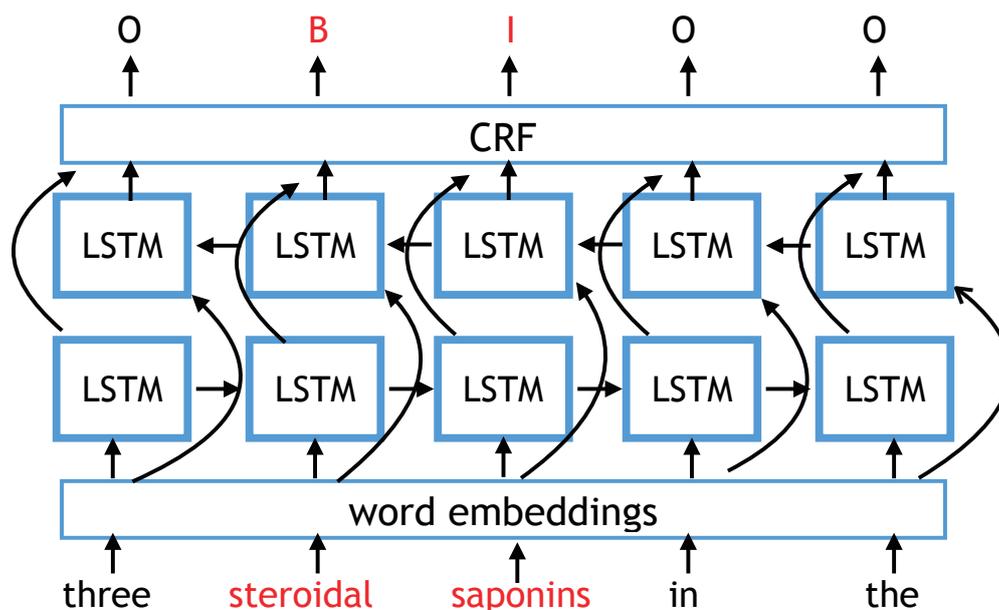


図 1: 実装したモデルの概念図

表 1: CHEMDNER コーパスの基本データ

	訓練データ	開発データ	テストデータ	合計
アブストラクト数	3,500	3,500	3,000	10,000
全文字数	4,883,753	4,864,558	4,199,068	13,947,379
全単語数	770,855	766,331	662,571	2,199,757
TRIVIAL	8,832	8,970	7,808	25,610
SYSTEMATIC	6,656	6,816	5,666	19,138
ABBREVIATION	4,538	4,521	4,059	13,118
FORMULA	4,448	4,137	3,443	12,028
FAMILY	4,090	4,223	3,622	11,935
IDENTIFIER	672	639	513	1,824
MULTIPLE	202	188	199	589
NO CLASS	40	32	41	113

表 2: 実験結果

使用データ	精度	再現率	F 値
ベースライン	0.866	0.787	0.824
自己学習 1 回	0.867	0.812	0.839
自己学習 2 回	0.857	0.826	0.841
自己学習 3 回	0.842	0.837	0.839

化学用語抽出課題と同様に線形ラベル付け問題である固有表現抽出課題においては、一般的に精度、再現率、および F 値が評価尺度として用いられるため、本研究においてもこれらの値を評価尺度として用いる。

5. 結果と考察

CHEMDNER コーパスのテストデータを用いて評価した結果を表 2 に示す。ベースラインモデルに比べて、自己学習を行うことで F 値が向上していることがわかる。特に、提案手法の手順を繰り返すことによって再現率が繰り返し向上しており、このことは訓練データの網羅性の不足が自己学習によって

補われていることを示唆している。一方で、精度は自己学習を 1 回だけ行った場合が最もよい。これは自己学習によって本来は正しくない単語列が化学用語として疑似訓練データに混入することが増えることによって、テストデータにおける精度が低下するためと思われる。結果としては自己学習を 2 回行った際の F 値が最も良好な結果を得た。

また、手順 2, 3 で用いるデータの量を変化させた際の精度の変化を表したグラフを表 3 に示す。この結果は自己学習を 1 回だけ行った際の結果である。追加データの量は、CHEMDNER の訓練データの量を 100% とした際の疑似訓練データの量を示す。すなわち、0% は自己学習を行わない場合（表 2 のベースライン）に相当する。全体的に、疑似訓練データを増やすことで、ベースラインのモデルと比較して F 値が向上することがわかる。結果として 450% において最高精度を記録しているものの、その一方で、データ量を増加させたからといって一貫して F 値が向上するという傾向は見られず、データを追加したからといって安定して性能が向上するとは言えない。そのため、自己学習に利用するデータを増加させることによって安定して性能を向上させるためには何らかの追加的な工夫が必要となるものと思われる。

表 3: データ量ごとの結果

追加データの量	精度	再現率	F 値
0 %	0.866	0.787	0.824
50 %	0.879	0.789	0.832
100 %	0.870	0.808	0.838
150 %	0.860	0.812	0.838
200 %	0.867	0.812	0.839
250 %	0.877	0.800	0.836
300 %	0.849	0.832	0.841
350 %	0.877	0.800	0.836
400 %	0.875	0.801	0.836
450 %	0.883	0.804	0.842
500 %	0.860	0.822	0.841
550 %	0.883	0.804	0.837

6. まとめ

本論文では、Bi-LSMT-CRF による化学用語抽出のモデルを学習する際に、自己学習を利用してラベルの付与されていないデータを利用することを提案した。実験により、自己学習を利用することでモデルの性能が向上したことが示された。また、自己学習を利用して得られたモデルで再度ラベルの付与を行い、それを利用して再び自己学習を行うことで、さらに性能が向上することも確認した。自己学習の際に利用するデータを増加させることによって F 値が向上することも確認できたものの、F 値の向上は一定しておらず、データ量を増加させる際には何らかの工夫が必要であると思われる。本研究は最高精度に到達していないが、現在最高精度を出しているモデルを再現し自己学習を加えることで、最高精度に到達できる見込みがあるものと思われる。

参考文献

- [1] Akash Bharadwaj, David Mortensen, Chris Dyer, and Jaime Carbonell. Phonologically aware neural model for named entity recognition in low resource transfer settings. In *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, pp. 1462–1472, 2016.
- [2] Asif Ekbal and Sivaji Bandyopadhyay. Named entity recognition using support vector machine: A language independent approach. *International Journal of Electrical, Computer, and Systems Engineering*, Vol. 4, No. 2, pp. 155–170, 2010.
- [3] Zhiheng Huang, Wei Xu, and Kai Yu. Bidirectional lstm-crf models for sequence tagging. *arXiv preprint arXiv:1508.01991*, 2015.
- [4] Martin Krallinger, Obdulia Rabal, Florian Leitner, Miguel Vazquez, David Salgado, Zhiyong Lu, Robert Leaman, Yanan Lu, Donghong Ji, Daniel M Lowe, Roger A Sayle, Riza Theresa Batista-Navarro, Rafal Rak, Torsten Huber, Tim Rocktschel, Sergio Matos, David Campos, Buzhou Tang, Hua Xu, Tsendsuren Munkhdalai, Keun Ho Ryu, SV Ramanan, Senthil Nathan, Slavko itnik, Marko Bajec, Lutz Weber, Matthias Irmer, Saber A Akhondi, Jan A Kors, Shuo Xu, Xin An, Utpal Kumar Sikdar, Asif Ekbal, Masaharu Yoshioka, Thaer M Dieb, Miji Choi, Karin Verspoor, Madian Khabza, C Lee Giles, Hongfang Liu, Komandur Elayavilli Ravikumar, Andre Lamurias, Francisco M Couto, Hong-Jie Dai, Richard Tzong-Han Tsai, Caglar Ata, Tolga Can, Anabel Usi, Rui Alves, Isabel Segura-Bedmar, Paloma Martnez, Julen Oyarzabal, and Alfonso Valencia.

The chemdner corpus of chemicals and drugs and its annotation principles. *Journal of Cheminformatics*, Vol. 7, No. Suppl 1, pp. 1–17, 2015.

- [5] Guillaume Lample, Miguel Ballesteros, Sandeep Subramanian, Kazuya Kawakami, and Chris Dyer. Neural architectures for named entity recognition. *arXiv preprint arXiv:1603.01360*, 2016.
- [6] Ling Luo, Zhihao Yang, Pei Yang, Zhang Yin, Lei Wang, Hongfei Lin, and Jian Wang. An attention-based bilstm-crf approach to document-level chemical named entity recognition. *Bioinformatics*, Vol. 34, No. 8, pp. 1381–1388, 2018.
- [7] Xuezhe Ma and Eduard Hovy. End-to-end sequence labeling via bi-directional lstm-cnns-crf. *arXiv preprint arXiv:1603.01354*, 2016.
- [8] David McClosky, Eugene Charniak, and Mark Johnson. Effective self-training for parsing. In *Proceedings of the main conference on human language technology conference of the North American Chapter of the Association of Computational Linguistics*, pp. 152–159. Association for Computational Linguistics, 2006.
- [9] Rada Mihalcea. Co-training and self-training for word sense disambiguation. In *Proceedings of the Eighth Conference on Computational Natural Language Learning (CoNLL-2004) at HLT-NAACL 2004*, 2004.
- [10] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems*, pp. 3111–3119, 2013.
- [11] U.S. National Library of Medicine. Medline. https://www.nlm.nih.gov/databases/download/pubmed_medline.html.
- [12] Marek Rei, Gamal KO Crichton, and Sampo Pyysalo. Attending to characters in neural sequence labeling models. *arXiv preprint arXiv:1611.04361*, 2016.
- [13] Erik F Sang and Jorn Veenstra. Representing text chunks. In *Proceedings of the ninth conference on European chapter of the Association for Computational Linguistics*, pp. 173–179. Association for Computational Linguistics, 1999.
- [14] Miguel Vazquez, Martin Krallinger, Florian Leitner, and Alfonso Valencia. Text mining for drugs and chemical compounds: methods, tools and applications. *Molecular Informatics*, Vol. 30, No. 6-7, pp. 506–519, 2011.
- [15] Beatriz Vincent, Maurice Vincent, and Carlos Gil Ferreira. Making pubmed searching simple: learning to retrieve medical literature through interactive problem solving. *The oncologist*, Vol. 11, No. 3, pp. 243–251, 2006.
- [16] 竹前慎太郎, 村尾一真, 谷塚太一, 小林隼人, 野口正樹, 西川仁, 徳永健伸. 自己学習を用いたニューラル見出し生成. 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. 3Pin136–3Pin136. 一般社団法人 人工知能学会, 2018.

複数サブワード系列を考慮した BiLSTM-CRF モデルを用いた文書からの化合物名抽出

関根裕人 *¹ 浦澤合 *¹ 乾孝司 *¹ 岩倉友哉 *²
Hiroto Sekine Go Urasawa Takashi Inui Tomoya Iwakura

*¹筑波大学大学院/理研 AIP-富士通連携センター

*²富士通研究所/理研 AIP-富士通連携センター

In this paper, we propose a BiLSTM-CRF model for extracting compound names from documents in chemical domain. The proposed model can be taken multiple subword sequences as input in order to obtain sufficient features for long span or unknown tokens. Subword LSTM units with contextual information are introduced in the input layer of the model. We conducted experiments based on CHEMDNER challenge to investigate the effectiveness of the model. As a result, the extraction accuracy outperformed the normal BiLSTM-CRF model, and experimental results on unknown words showed that the proposed method works better.

1. はじめに

1.1 研究背景

人間が読める言語で書かれた文書から自動的に構造化データを抽出するタスクを「情報抽出」という。近年、Bioinformatics 分野では、この情報抽出を利用した、化合物名抽出という研究分野がある。テキストから化合物名を抽出しデータを構造化することで、論文の検索性を向上させたり、データを分析し化合物間の関係について分析することができる。例えば、化合物名抽出の競争的イベントの一つに CHEMDNER[1] がある。このタスクでは PubMed という化合物関連の論文サイトの論文をアノテーションしたコーパスを作成し、コーパスとして公開している。そして、このコーパスを使用した研究活動が活発に行われている。

上記の CHEMDNER で扱われる化合物名抽出には、一般的な固有表現抽出よりも難しい点がいくつか存在する。化合物名は一つのエンティティの長さが長いものがある。例えば、“3-(4,5-dimethylthiazol-2-yl)-2,5-diphenyl tetrazolium bromide” は抽出すべき一つのエンティティであるが、このエンティティは全部で 58 文字から構成されている。次に、同一のエンティティでも複数の名前がつけられていることである。フェニルアラニンがその一例である。フェニルアラニンの他に、“L-Phenylalanine”, “Phe-OH”, “Antibiotic FN-1636” など 30 種類以上の呼び名が存在する。また、未知語が多いということも難しい点である。化合物は日々新しく作られていて、それに伴い化合物名も増加していく。未知語に対してどの程度抽出できるかという点も重要な評価の要素となる。

1.2 目的

近年、固有表現抽出の分野では Long Short Term Memory Network(LSTM) を用いて抽出されることが多い。LSTM を使用すると単語の意味や文脈の関係を考慮した計算が可能となる。本稿では LSTM をベースとして、上記の問題を解決するためにサブワードの情報をモデルに組み込む手法を提案する。サブワードとは一つの単語をより細かい単位に分ける考え方である。化合物名には極端に長い単語があるので、サブワード化により細かく区切ることで単語のみの時よりも高い抽出精度が達成できると期待できる。

1.3 本論文の構成

本稿ではまず、第 2 章で LSTM による固有表現抽出の関連研究をいくつかあげる。第 3 章ではベースラインとなる BiLSTM-CRF モデルについて説明する。第 4 章ではサブワードの分散表現の獲得手法について述べる。そして第 5 章で実験とその結果について述べる。最後に第 6 章でまとめを行う。

2. 関連研究

近年の化合物名抽出タスクでは固有表現抽出を系列ラベリング問題に落とし込み、ニューラルネットワークを用いて解く手法が中心である。その中でも Long Short Term Memory(LSTM) を用いたものが多い。

Jie[2] らは Neural Network による系列ラベリングの手法をまとめ、その抽出精度を測った。比較対象は LSTM や CNN などのモデルによる違いや、学習パラメータの違いや、文字系列の有無による違いなどをまとめている。この実験では固有表現抽出に対しては、BiLSTM-CRF に文字系列 LSTM を加えた結果が最も値がよかった。

Luo ら [3] は既存の BiLSTM-CRF に加えて、Attention 層を追加したモデルを提案した。Attention 層では、global vector という文全体の類似度を考慮することで、より幅の広い時系列の情報も取り込むことができるようになっている。

Akbik[4] らは BiLSTM-CRF モデルに加えて文字系列 LSTM を拡張した。一般的に文字系列の LSTM は一つの単語内に適用されるが、文全体の中で文字系列 LSTM を計算することによって、文脈を残しながら文字をベクトルに埋め込むことができると提案している。

このように単語および文字の情報を考慮した手法は多く提案されているが、本研究のようにサブワードを考慮した手法は提案されていない。

3. ベースライン手法

3.1 BiLSTM-CRF モデル

BiLSTM-CRF モデルについて説明する。モデルの全体構成を図 1 に示す。入力する単語系列、ラベル系列をそれぞれ $x = (x_1, x_2, \dots, x_t, \dots, x_N)$ 、 $y = (y_1, y_2, \dots, y_t, \dots, y_N)$ とする。 x_t は t 番目の単語の分散表現、 y_t はその単語に対応するラベルを表している。

連絡先: 関根裕人, 筑波大学院システム情報工学科,
sekine@mibel.cs.tsukuba.ac.jp

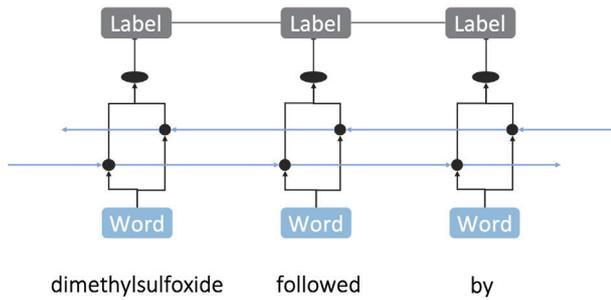


図 1: BiLSTM-CRF モデルの全体図

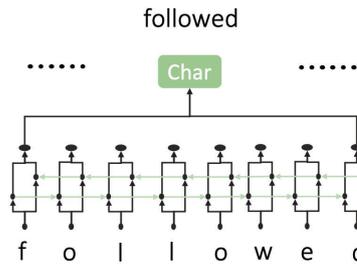


図 2: 文字 BiLSTM モデル

モデルはまず与えられた入力に対し、LSTM 層で計算を行う。LSTM とは時系列ニューラルネットワーク (RNN) の一種である。一つ前のステップの出力に加えて、時系列内で重要と考えられる情報をゲート構造を用いて保持する長期記憶と呼ばれる隠れ層を保持している。これにより一般的な RNN よりも長期的な依存関係を考慮して計算している。

$$h_t, c_t = f_{LSTM}(x_t, h_{t-1}, c_{t-1}; \theta) \quad (1)$$

BiLSTM-CRF モデルでは LSTM を前と後ろからの両方向から計算する。前向き LSTM の出力を \vec{h} 、後向き LSTM の出力を \overleftarrow{h} とする。これらの計算結果を各ステップごとにつなぎ合わせ、活性化関数の \tanh をかける。

$$out = \tanh([\vec{h} \oplus \overleftarrow{h}]) \quad (2)$$

最後に CRF 層で、それぞれのラベル列の遷移確率を考慮し、入力系列 x に対してもっともらしい y を求める。学習時は以下の $P(y|x)$ を最大にするように、パラメータを更新する。

$$P(y|x) = \text{softmax}(\text{Score}(x, y)) \quad (3)$$

この時の Score 関数は、各ラベルごとの遷移確率を $T[y_{t-1} \rightarrow y_t]$ とすると、以下の式で表すことができる。

$$\text{Score}(x, y) = \sum_{t=1}^N (\log(out_t) + \log(T[y_{t-1} \rightarrow y_t])) \quad (4)$$

3.2 Character Representation

単語系列に加えて、文字系列の分散表現を BiLSTM-CRF モデルに追加することで、抽出精度が上がる事が多い。特に未知語に対しては、単語では情報がなくなってしまう場合で

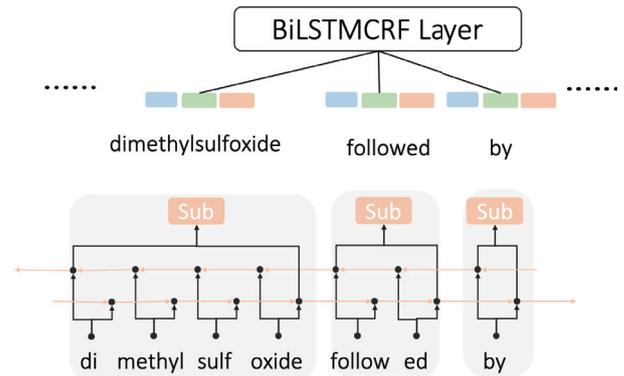


図 3: SubWord LSTM モデルの全体図

も、文字を使用することで情報を得ることができる。今回は文字系列の埋め込みを LSTM を使用して獲得する。

図 2 の部分が文字系列 LSTM の概要である。一つの単語を文字に分解し、文字単位で BiLSTM 層で計算する。前向き LSTM では一番最後の隠れ層の出力、反対に後向き LSTM では一番先頭の出力をそれぞれ連結させる。最終的に、このベクトルと単語の分散表現に連結して、BiLSTM-CRF モデルの入力として使用する。

4. Subword Representation

サブワードの分散表現の獲得方法について述べる。サブワードとは、単語をさらに分割することでより意味のある情報を得ようとする考え方である。例えば“dimethylsulfoxid”という語は“di, methyl, sulf, oxid”という分割をすると“2”を意味する“di”や、“メチル基”を表す“methyl”、“酸”を表す“oxid”などの情報を得ることができる。

4.1 Subword LSTM

サブワードの分散表現を獲得するための新しいモデルを提案する。このモデルの全体図を図 3 に示す。本手法は Akbik[4] から着想を得て、サブワードを考慮するように変形しものである。

ある単語 x_t が m 個のサブワードに分割された時、 $x_t = s_{x_t,1}, s_{x_t,2}, \dots, s_{x_t,m_t}$ と表す。このとき、入力 $x = (x_1, x_2, \dots, x_N)$ から得られるサブワード系列は $S = (s_{x_1,1}, \dots, s_{x_1,m_1}, s_{x_2,1}, \dots, s_{x_N,m_N})$ と表せる。

得られた S に対し、第 3 章で述べた BiLSTM 層と同様に計算する。今回、サブワード系列のベクトルを Word 系列に合わせる必要がある。前向き LSTM の計算結果では単語の最後のサブワード、後向き LSTM の計算結果では単語の先頭のサブワードに対応するベクトルを選択する。

ここで、前向き LSTM の出力を $\vec{h}_t = f_{LSTM}(s_t)$ とする。これを Word 系列と同じ長さにするためには、 $(s_{x_1,m_1}, s_{x_2,m_2}, \dots, s_{x_N,m_N})$ と対応する \vec{h}_t を前向き LSTM の計算結果 \vec{h}_w として使用する。

反対に、後向き LSTM を Word 系列に連結するためには、 $(s_{x_1,1}, s_{x_2,1}, \dots, s_{x_N,1})$ と対応する \overleftarrow{h}_t を後向き LSTM の計算結果 \overleftarrow{h}_w として使用する。

表 1: 実験結果

	Precision	Recall	Fscore
BaseLine(82ep)	0.9031	0.8578	0.8799
+ SW2k(93ep)	0.9047	0.8584	0.8809
+ SW4k(82ep)	0.9032	0.8589	0.8805
+ SW16k(57ep)	0.8998	0.8577	0.8783
+ SW4k,16k(86ep)	0.9006	0.8668	0.8834
+ SW2k, 4k,16k(80ep)	0.9025	0.8566	0.8790

最後に、前向き LSTM と後向き LSTM の計算結果をつなぎ合わせた $[\vec{h}_w \oplus \overleftarrow{h}_w]$ がサブワードの分散表現となる。このベクトルは、文字の分散表現と同様に、BiLSTM-CRF モデルへの入力に連結されて使用される。

このモデルは複数のサブワード系列を考慮する場合でも使用できる。その場合は、Subword LSTM をサブワード系列の数だけ用意し、一つの場合と同様に分散表現を得て、BiLSTM-CRF モデルへの入力として、サブワード系列の数だけベクトルを連結し使用する。

5. 評価実験

5.1 実験内容

提案モデルの有効性を調査する。ベースラインとして BiLSTM-CRF に文字 LSTM を加えたものを使用する。このベースラインに Subword LSTM を加えたときの抽出精度の有効性を調査する。

5.2 データ

BioCreative Challenge から出された ChEMBL コーパス [1] を実験用のデータとする。このコーパスは PubMed 中の論文の abstract を 10,000 件集め、それらに化合物と判断したエンティティを手でアノテーションしたものである。全部で 84,355 のエンティティが存在し、それらのユニークな数は 19,806 である。データ数は訓練、検証、テスト用それぞれ 3,500、3,500、3,000 件ずつ提供されている。また本研究では、BIOES スキーマに従ってラベルづけを行った。

事前学習用のコーパスとして化学系の論文を扱うサイトである PubMed から ChEMBL タスクに合うように選択された約 440 万件の abstract を使用した。単語系列、サブワード系列それぞれの埋め込み層の学習には GloVe[5] を使用した。

また、このコーパスを使用して SentencePiece[6] の学習も行った。学習にはユニグラムを使用し、語彙数は 2,000、4,000、16,000 の 3 つを使用した。

5.3 実験パラメータ

今回の実験では最適化に SGD を使用し、学習率は 0.005、減衰率は 0.0001 とした。単語系列、文字系列、サブワード系列の分散表現の次元はそれぞれ、50 次元、30 次元、50 次元とし、LSTM の隠れ層では 200 次元、50 次元、50 次元とした。

また、GPU は Tesla V100-DGXS を用いて学習した。バッチサイズが 10 で、100 エポック学習させた時に検証用データに対してもっとも値の良いモデルを使用した。

5.4 実験結果

実験結果を表 1 にまとめた。語彙数が 2000、4000 のサブワード系列をそれぞれひとつずつ加えた場合、ベースラインよりも F 値を上回った。これより、ベースラインにサブワード系列を追加した場合、抽出精度が向上することがある。

表 2: IV に対する実験結果

	Precision	Recall	Fscore
BaseLine(82ep)	0.9095	0.8941	0.9018
+ SW2k(93ep)	0.9127	0.8921	0.9020
+ SW4k(82ep)	0.9102	0.8921	0.9011
+ SW16k(57ep)	0.9089	0.8917	0.9002
+ SW4k,16k(86ep)	0.9097	0.8976	0.9036
+ SW2k, 4k,16k(80ep)	0.9090	0.8940	0.9014

表 3: OOV に対する実験結果

	Precision	Recall	Fscore
BaseLine(82ep)	0.8663	0.6871	0.7664
+ SW2k(93ep)	0.8628	0.6939	0.7692
+ SW4k(82ep)	0.8630	0.6894	0.7665
+ SW16k(57ep)	0.8619	0.6876	0.7649
+ SW4k,16k(86ep)	0.8635	0.7065	0.7771
+ SW2k, 4k,16k(80ep)	0.8507	0.6995	0.7677

今回の実験で最も良い F 値であったのは、語彙数が 4,000、16,000 のサブワード系列を同時に加えた場合であった。ベースラインと比較すると、0.003 上回っており、0.8834 であった。これは、複数のサブワード系列を同時に加えることで、抽出精度が良くなる場合があることを示している。

サブワードの有効性を調べるために未知語の単語に対する結果も調査した。抽出すべきエンティティが全て未知語だった場合のエンティティを OOV (Out of vocabulary) と呼び、反対に未知語以外の語が一つでも入っている語を IV (In vocabulary) と呼ぶ。テストデータの全エンティティ 25,308 個に対して、IV は 20,859 個で、OOV は 4,449 個であった。OOV の例としては“HANPs”, “nitriles”, “fidarestat”, “flavonolignans”, “SFN”, “CDDP”, “CYN”などがあげられる。

結果を表 2 および表 3 に示す。表から、IV に対しての結果はあまり変化がみられなかった。しかし、OOV に対してはサブワードを追加したモデルがベースラインよりも Recall が上回っていた。これは、未知語に対してサブワードの埋め込みベクトルがうまくはたっていることを示している。また OOV のときでは、SW4k,16k はベースラインよりも 0.01 以上も F 値を上回っていた。OOV において、ベースラインでは抽出できなかったが、SW4k,16k で抽出できた例としては、“HANPs”, “nitriles”, “fidarestat”, “inacotide”, “silatrane”などがあげられる。

6. まとめ

本稿ではテキストからの化合物名抽出において、サブワードの埋め込みベクトルをモデルに加えることで抽出精度が上がることを示した。

今回は語彙数が 2,000、4,000、16,000 に限定し実験を行ったが、それぞれで抽出の精度が異なっていた。サブワードの語彙数を決定することは、このモデルの重要な要素の一つでもあるため、今後は語彙数と抽出精度の関係性について深く調べる必要がある。

また、今回の実験では語彙数が 4,000 と 16,000 の二つのサブワード系列を入力した場合に最も良い精度となった。しかし、そのモデルに対し、語彙数が 2,000 のサブワード系列を

加えた場合の抽出精度は芳しくなかった。これは、単純にサブワード系列を加えていくのではなく、どのサブワード系列を使用するか判断する必要があることを示している。

今後は、加えるサブワード系列の語彙数と、どの語彙数を加えると良いスコアを得るかについてももう少し、研究していくことが必要である。

参考文献

- [1] Krallinger et al. (2015) The CHEMDNER corpus of chemicals and drugs and its annotation principles. *J Cheminform.* 2015 Jan 19;7(Suppl 1 Text mining for chemistry and the CHEMDNER track):S2. doi: 10.1186/1758-2946-7-S1-S2. eCollection 2015.
- [2] Jie Yang et al. (2018) Design Challenges and Misconceptions in Neural Sequence Labeling. 2018 13 Aug. CoRR. abs/1806.04470
- [3] Ling Luo et al. (2018). An attention-based BiLSTM-CRF approach to document-level chemical named entity recognition. *Bioinformatics*, 2018 Apr 15;34(8):1381-1388.
- [4] Alan Akbik et al. (2018) Contextual String Embeddings for Sequence Labeling. 2018 Aug. Proceedings of the 27th International Conference on Computational Linguistics, p.16381649
- [5] Jeffrey Pennington et al. (2014) GloVe: Global Vectors for Word Representation. *Empirical Methods in Natural Language Processing (EMNLP)*. p1532-1543. <https://github.com/stanfordnlp/GloVe>
- [6] Taku Kudo et al. (2018) SentencePiece: A simple and language independent subword tokenizer and detokenizer for Neural Text Processing. 2018 Aug. CoRR. abs/1808.06226. <https://github.com/google/sentencepiece>

文書からの化合物名抽出のためのサブワード有効性調査

Using Subword Sequence BiLSTM-CRF Model for Compound Name Extraction

浦澤合*¹ 関根裕人*¹ 乾孝司*¹ 岩倉友哉*²
Go Urasawa Hiroto Sekine Takashi Inui Tomoya Iwakura

*¹筑波大学大学院 /理研 AIP-富士通連携センター
University of Tsukuba/RIKEN AIP-FUJITSU Collaboration Center

*²富士通研究所/理研 AIP-富士通連携センター
Fujitsu Laboratories/RIKEN AIP-FUJITSU Collaboration Center

In this paper, we investigate of using subword sequences for compound name extraction problem. Five variety of subword sequence generators (SYMBOL, SP, BPE, BPE-DICT, and BPE-PMI) were used in the investigation. Last two of these, BPE-DICT and BPE-PMI, are originally proposed in this work. BPE-DICT is a variation of BPE which has a dictionary-based restriction. BPE-PMI introduces the PMI measure instead of word frequency count. The experimental results showed that subword sequence information improved the extraction performance. The F-measure value of BPE-DICT is 86.74 which is best score in all conditions of our experiments.

1. はじめに

人間の言葉で書かれた文書から自動的に構造化データを抽出するタスクを「情報抽出」という。抽出するデータの種類に応じてデータの特徴、文書形式などが異なる。したがって抽出データの分野により情報抽出をおこなうのに最適な抽出手法や考え方が異なるので抽出データに合わせた手法を考える必要がある。本研究では化学化合物に関する情報抽出について考える。

化学分野の研究ではさまざまな場面で化合物データベースが利用され、日本化学物質辞書 [5] や PubChem [4], ChEMBL [1] など各種データベースが提供されている。現在、これらの化合物データベースは論文や特許を手で読み解くことで作成されている。しかし化学化合物に関する論文、特許は数え切れないほどの数が存在するのでそれらから必要なデータを人手で抽出することは非常にコストの高い作業である。そこで解析技術と組み合わせたデータベース作成支援が求められている。

化合物抽出用のソフトウェアが存在するが、精度の点で実用レベルに至っているとは言い難い。化学化合物の抽出が実用レベルでないのは、化学化合物の命名規則である IUPAC 命名規則 [2] があるにも関わらず化合物の多様な表記方法があることが理由として挙げられ、略称、通称、化学式など多くの表記を持つ。例として化合物「フェニルアラニン」は「Phe-OH」, 「L-Phe-OH」, 「L-Phenylalanine」, 「(S)-2-Amino-3-phenylpropionic acid」などで表現されるが、これで全ての表記ではない。また化学の分野において新しい化合物が頻繁に報告されることも理由として挙げられる。他には複合語の存在である。複合語とはある化合物を部分的に含む化合物のことである、これらにより化合物の正確な抽出が困難となる。

上記で述べたように、化学化合物は未知語が発生しやすい分野であるため、未知語に対応する処理が重要となる。サブワードは単語と文字両者の中間的な特性を持つため単語情報を保持しつつ、未知語に対応できると考えられる。そのため本研究は様々な分割方法でサブワードを獲得し、どのようなサブワード系列が化学化合物抽出において効果が見られるか検討する。

連絡先: 浦澤合, 筑波大学大学院システム情報工学研究科,
g.u@mibel.ca.tsukuba.ac.jp

本稿の構成として、第 2 章で関連研究について述べる。第 3 章ではサブワード獲得方法について述べる。第 4 章では評価実験について述べる。最後に、第 5 章では予備調査を踏まえた考察と今後の指針を述べる。

2. 関連研究

化学分野の論文や特許から化合物を抽出する研究 [8][9][6] は盛んに行われている。機械学習を利用した手法 [8] が高精度の結果を残すものとして以前から知られていたが、近年ではニューラルネットワークを利用した手法 [9] が多く提案され化合物抽出において素晴らしい結果をもたらしている。

機械学習を利用した Lu ら [8] は文字や単語から獲得できる情報を CRF の素性として利用した。また単語のクラスタリングを素性として利用することで精度や再現性を高めようとした。次に Ling ら [9] は化合物抽出のニューラルネットワークを利用した手法によく見られる BiLSTM に attention 機能を追加した手法を提案し、CHEMDNER task [6] では現在もっとも精度の高い手法となっている。以上のように単語および文字の情報を利用した手法は数多く提案されているが、本研究のようにサブワードを利用した手法は提案されていない。

3. サブワード

3.1 固有表現抽出におけるサブワード

化合物名抽出を行う際には系列ラベリング問題として定式化することが一般的である。系列ラベリング問題として考えた場合に単語単位の系列を仮定すると、未知語が発生しやすくなり、また、抽出したい化合物と処理上の単位である単語との間で境界が一致しない問題を引き起こす。この問題への対策として、文字単位系列を用いることが考えられるが、この場合、系列長が長くなり計算量が増加する。また、単語がもっていた意味情報を利用することができないといった新たな問題が発生する。単語の使用と文字の使用はそれぞれに利点と欠点があり、両者はトレードオフの関係にあると言える。サブワードはこの両者の中間的な特性をもっており、サブワードを考慮した系列を仮定することで、単語と文字の両者の欠点を補うことができ

Algorithm 1 BPE

```

1:  $DICT \leftarrow$  辞書データ
2:  $VOCAB \leftarrow$  語彙 (初期は空)
3: テキストを文字に分割する
4: while  $VOCAB$  が指定語彙数に達するまで do
5:   隣り合う全ての文字トークンのペアに対して, それらを結合して新たな語彙候補を作成する. ( $VOCAB$  に存在するものは一文字として扱う)
6:   語彙候補の中で, 出現頻度の最も高い候補を  $VOCAB$  に追加する.
7: end while

```

Algorithm 2 BPE-DICT

```

1:  $DICT \leftarrow$  辞書データ
2:  $VOCAB \leftarrow$  語彙 (初期は空)
3: テキストを文字に分割する
4: while  $VOCAB$  が指定語彙数に達するまで do
5:   隣り合う全ての文字トークンのペアに対して, それらを結合して新たな語彙候補を作成する. ( $VOCAB$  に存在するものは一文字として扱う)
6:   結合前の左右の要素がどちらも  $DICT$  に登録されていない語彙候補の中で, 出現頻度の最も高い候補を  $VOCAB$  に追加する.
7: end while

```

ると考えられる。サブワードとは、ある単語の部分文字列のことである。例として「magnesium」という単語の場合、「ma」, 「mag」, 「magn」, 「si」, 「sium」などがサブワードになる。

3.2 サブワード獲得方法

本研究では単語から得られるサブワードとして以下 5 種類のサブワードを試みた。このうち、BPE-DICT と BPE-PMI は本研究で提案するサブワード獲得方法である。

- 記号などが存在する際にその記号で単語を分割するもの (SYMBOL),
- SentencePiece(SP),
- Byte Pair Encoding(BPE),
- 辞書制約付き Byte Pair Encoding(BPE-DICT),
- PMI による Byte Pair Encoding(BPE-PMI).

3.2.1 SYMBOL

SYMBOL は単語中に記号などが存在する際に、その記号で単語を分割するサブワード分割方法である。一般的な単語は記号を単語中に含まないので、単語は分割されず、単語そのままであることが多い。単語が組み合わせられた複合語や、長い単語には記号が含まれることが多く、分割される。

3.2.2 SP

SentencePiece[3][7] を実行することでサブワード系列を獲得する。

3.2.3 BPE

Byte Pair Encoding は Sennrich ら [10] が提案したサブワード分割方法である。BPE は原文をすべて文字に分割し、1 文字 1 語彙から始まる。隣り合う文字のペアに対して、それらを連結して新たな語彙の候補とする。この際すでに語彙に含まれているものは 1 文字として扱う。連結した際に最も出現頻度が高くなるサブワードを選び語彙に追加する。この手続きを決められた語彙数に達するまで繰り返し語彙結合ルールを学習することでサブワード分割を行う。

3.2.4 BPE-DICT

BPE-DICT は辞書制約付きの BPE である。基本的な手続きは通常の BPE と同じであるが、連結する前の左右の要素どちらも化学化合物辞書に存在しない語彙候補の中で出現頻度が最も高いものを語彙に追加する。また今回、化学化合物辞書として利用したのは PubChem データベース [4] で約 3 億個の化合物を含んでいる。

3.2.5 BPE-PMI

通常の BPE は出現頻度が高いサブワードを新たな語彙として追加するが、BPE-PMI は出現頻度ではなく Pointwise Mutual Information(PMI) が高いサブワードを新たに語彙に追加する。学習データを参照することで各サブワードについて、化合物の構成要素 (クラス 1)、構成要素でない (クラス 0) を割り当て、各サブワードとクラス 1 間の PMI を求め、出現頻度に置き換えて BPE を行う。式 (1) に PMI の定義式を示す。ここで、 $P(SW)$ はあるサブワードが出現する確率、 $P(C=1)$ はある要素が化合物の構成要素である確率、 $P(SW, C=1)$ はあるサブワードが出現した際にそれが化合物の構成要素である確率である。

$$PMI(SW, C=1) = \log_2 \frac{P(SW, C=1)}{P(SW)P(C=1)} \quad (1)$$

4. 評価実験**4.1 実験設定**

前節で述べた手法によって得たそれぞれのサブワード系列が化学化合物抽出にどの程度有効であるか観察した。データセットは CHEMDNER tsak における学習データ 3,500、開発データ 3,500、評価データ 3,000 を利用した。これは PubMed から化合物について書かれた論文の abstract を 10,000 件集め、人手でアノテーションをされたものである。合計で 84,355 の化合物エンティティが存在し、それらの重複を省くと 19,806 となる。化学化合物の固有表現抽出モデルとして Bidirectional LSTM-CRF[9] を使用し、これは単語と文字の LSTM を持つ。本研究では固有表現抽出モデルの単語 LSTM をサブワードに

表 1: サブワード別出力例: 学習データ内に存在する化合物

method \ 化学化合物	docosahexaenoic acid	nitric oxide	glutathione	superoxide
SYMBOL	docosahexaenoic acid	nitric oxide	glutathione	superoxide
SP:chem6k	docosahexaenoic acid	nitric oxide	glutathione	superoxide
BPE:32k	docosahexaenoic acid	nitric oxide	glutathione	superoxide
BPE-DICT:32k	docosahexaenoic acid	nitric oxide	glutathione	superoxide
BPE-PMI:32k	docosahexaenoic acid	nitric oxide	glutathione	superoxide

表 2: サブワード別出力例: 学習データ内に存在しない化合物

method \ 化学化合物	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides
SYMBOL	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides
SP:chem6k	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides
BPE:32k	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides
BPE-DICT:32k	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides
BPE-PMI:32k	isocorilagin	diasartemin	tetrahydropalmitine	ritanserine	polyphosphoinositides

表 3: 利用したモデルのパラメータ

epoch	200
batch size	100
単語分散表現	50
文字分散表現	30
単語 LSTM の隠れ層	100
文字 LSTM の隠れ層	50
initial rate	0.015
dropout	0.5

置き換えて用いる。また今回使用したモデルのパラメータを表 3 に示す。単語分散表現, 文字分散表現はそれぞれ 50 次元, 30 次元とし, LSTM の隠れ層では 100 次元, 50 次元とした。表中の「単語」は実際にはサブワードである。

サブワード獲得方法別の設定を述べる。SentencePiece の学習には上記と同じ学習データを利用した。学習データの全テキストを語彙数 32,000, ユニグラムで学習させたもの (SP:32k) と学習データのタグづけされた化学化合物部分のみを語彙数 6,000, ユニグラムで学習させたもの (SP:chem6k) がある。次に BPE, BPE-DICT, BPE-PMI について説明する。これら 3 つも同様に先と同じ学習データを利用したが, BPE, BPE-DICT は学習データのテキスト部分のみを語彙獲得に利用し, BPE-PMI は学習データのテキスト部分とタグ部分を語彙獲得に利用した。また 3 つそれぞれに対して 8,000, 16,000, 32,000 の語彙数で学習させた。また BPE-DICT では辞書引きを行う手続きに仮候補の文字列が 3 文字以上という制限を加えたもの (BPE-DICT-char3) と制限なしのもの (BPE-DICT) がある。この制限は制限なし BPE-DICT が獲得したサブワードを観察した際に, 多くの 1 文字サブワードが残った。その結果に対して調整を行う目的で取り入れた。

4.2 実験結果と考察

表 4 に実験結果を示す。性能を F-measure の値で比較すると, 最も良い性能であるのは語彙数 32,000 で制限なしの BPE-DICT である。この F-measure は 86.74 であり, ベースラインである単語区切りの 86.32 に 0.4 上回っている。これは通常の BPE と比較しても性能が良いことから辞書制約付きがある BPE は化合物抽出において効果があると言える。

またシンプルなサブワード分割方法である SYMBOL もベースラインの F-measure を上回っており, これはサブワードが単

表 4: サブワード別実験結果

method	Precision	Recall	F-measure
単語	86.62	86.03	86.32
SYMBOL	85.10	88.01	86.53
SP:32k	87.56	85.39	86.46
SP:chem6k	78.90	69.53	73.95
BPE:8k	87.12	84.98	86.04
BPE:16k	87.47	85.99	86.72
BPE:32k	84.38	79.38	81.80
BPE-DICT:8k	87.74	84.32	86.00
BPE-DICT:16k	87.37	85.70	86.53
BPE-DICT:32k	87.14	86.33	86.74
BPE-DICT-char3:8k	87.17	84.33	85.73
BPE-DICT-char3:16k	86.40	86.39	86.39
BPE-DICT-char3:32k	88.10	85.10	86.62
BPE-PMI:8k	85.51	82.45	83.95
BPE-PMI:16k	86.86	82.76	84.76
BPE-PMI:32k	78.69	71.03	74.66

語よりも化合物抽出で良い影響を持っていると言える。BPE-PMI の F-measure は通常の BPE と比べて低い。したがって各サブワードと化合物の構成要素クラス間との PMI をもとに BPE を行うよりも出現頻度をもとにした通常の BPE の方が今回の実験では良いサブワード分割ができていると言える。

SP:chem6k と BPE-PMI:32k の性能が他と比較すると極端に低い。SP:chem6k と BPE-PMI:32k ともにサブワード分割の特徴として化学化合物が分割されることが少なく, 残りやすいことが挙げられる。これは学習をともに学習データの化学化合物部分に集中して行うからと考えられる。化学化合物とそれ以外の違いを他のサブワード分割方法では区別できているとも言える。

表 1 と表 2 に各サブワード分割方法で得られた化学化合物のサブワード出力例をいくつか示す。表 1 の化学化合物は学習データに化合物部分としてタグ付けされているのでほとんどのサブワード分割方法が分割を行わず単語を維持している。反対に, 表 2 の化学化合物は学習データに化合物部分としてタグ付けされていないため多くのサブワード分割方法で分割が行われる。また単語や記号でサブワード分割を行うシンプルな分割方法である SYMBOL では表 2 の化合物すべてが抽出するこ

とができなかった。しかし実験結果で最も F-measure が高いサブワード分割である BPE-DICT:32k では表 2 の化合物を抽出することができた。したがって、学習データに化合物部分としてタグづけされていない化合物でもサブワードを利用することで抽出することを可能とし、DICT-BPE:32k は良いサブワード分割を行なっていると言える。

5. おわりに

今回、様々なサブワードを Bidirectional LSTM の入力系列として利用し化学化合物抽出を行い、各サブワード獲得方法別の結果を観察し、サブワードが単語よりも化学化合物抽出において効果があることを示した。

結果としては BPE-DICT が最も高い性能を残したが、各サブワード獲得方法すべてに同様のパラメータを適用したので BPE-DICT が化学化合物抽出に最も適しているとは一概にも言えない。さらに今回語彙数として 8,000, 16,000, 32,000 を使い実験を行なった、それに対して実験結果や結果の傾向が異なるものとなったが、これはサブワードを利用する上で語彙数を決定することは化学号物抽出の性能に大きな影響があると言える。今後は各サブワード獲得方法に適したパラメータの調査やサブワード分割方法とそれに適した語彙数の決定について行う必要がある。また以上のことから得られる化学化合物抽出に適したサブワードをサブワードのみの入力系列ではなく、単語系列などと組み合わせた実験などを行なっていきたい。

参考文献

- [1] ChEMBL. <https://www.ebi.ac.uk/chembl/>.
- [2] Color books-iupac international union of pure and applied chemistry. <https://iupac.org/what-we-do/books/color-books/>.
- [3] Github-google/sentencepiece: Unsupervised text tokenizer for neural network-based text generation. <https://github.com/google/sentencepiece>.
- [4] The pubchem project. <https://pubchem.ncbi.nlm.nih.gov/>.
- [5] 日本化学物質辞書 web—j-global 科学技術総合リンクセンター. <https://jglobal.jst.go.jp/info/nikkaji>.
- [6] Martin Krallinger, Florian Leitner, Obdulia Rabal, Miguel Vazquez, Julen Oyarzabal, and Alfonso Valencia. Chemdner: The drugs and chemical names extraction challenge. *Journal of cheminformatics*, Vol. 7, No. 1, p. S1, 2015.
- [7] Taku Kudo and John Richardson. Sentencepiece: A simple and language independent subword tokenizer and detokenizer for neural text processing. *arXiv preprint arXiv:1808.06226*, 2018.
- [8] Yanan Lu, Donghong Ji, Xiaoyuan Yao, Xiaomei Wei, and Xiaohui Liang. Chemdner system with mixed conditional random fields and multi-scale word clustering. *Journal of cheminformatics*, Vol. 7, No. S1, p. S4, 2015.
- [9] Ling Luo, Zhihao Yang, Pei Yang, Yin Zhang, Lei Wang, Hongfei Lin, and Jian Wang. An attention-based bilstm-crf approach to document-level chemical named entity recognition. *Bioinformatics*, Vol. 34, No. 8, pp. 1381–1388, 2017.
- [10] Rico Sennrich, Barry Haddow, and Alexandra Birch. Neural machine translation of rare words with subword units. *arXiv preprint arXiv:1508.07909*, 2015.

運転免許試験で使用される語彙と省略語句の分析

Analysis of vocabulary and omitted words in car license tests

的場 成紀 *¹ 古賀 雅樹 *¹ 大塚 基広 *¹ 小林 一郎 *² 平 博順 *¹
Seiki Matoba Masaki Koga Motohiro Otsuka Ichirou Kobayashi Hirotoshi Taira

*¹大阪工業大学大学院 情報科学研究科

Faculty of Information Science and Technology, Osaka Institute of Technology

*²お茶の水女子大学大学院 人間文化創成科学研究科

Graduate School of Humanities and Sciences, Ochanomizu University

We develop a solver for Japanese car license tests. The test consists of about a hundred of true/false questions about traffic rules, driving manners, architectures of cars and the laws of physics related to cars. While the passing score is 90%, The best score in the previous approaches is about 65%. The approach is based on the sentence similarity between the test sentence and most similar sentence with the gold-standard answer in the database in the solver. Toward the system to pass the test, we analyzed the vocabulary and writing styles of the tests. The results of the analysis showed that the vocabulary is relatively small, which is about 300 words for 100 problems, and the sentences contain a lot of zero pronouns and they cause the low accuracy of the solver. Furthermore, we tried to resolve the antecedents using a previous anaphora resolution system. The results showed that the system cannot resolve the anaphora in the tests, because each problem consists of only one sentence and the clue to resolve the pronoun is very few, and they are more difficult to resolve than ones in standard articles. The analysis has revealed that high-performance systems require the anaphora resolution which is more based on domain specific knowledge.

1. はじめに

自動車免許試験に対して自動解答するシステムの検討を行っている [平 14]. 本研究は自動車免許試験を自動解答するソルバを開発するために免許試験のコーパスの分析を行う. これまでの研究では, 問題文とソルバが持っている問題データベース中の問題文との間の単語類似度を利用して正誤判定を行う手法が提案されている [杉村 13]. この手法では, 図を使用しない自然文のみからなる模擬問題に対して, 約 6 割の正解率が得られている. また, 従来の自動車免許試験についての問題分析では, 問題のトピック, 問題の言い回し, 問題を解くために必要な技術や知識に関する検討が行われている [平 15]. 本研究では, 免許試験問題に対して自動解答する上で必要な語彙について 5W1H の観点から分析するとともに, 問題文中で頻出する省略語句について分析を行った.

2. 普通自動車免許学科試験問題の概要

普通自動車免許を取得するためには, 実際に自動車を運転し, 運転技術について評価する実技試験と交通規則やマナー等, 運転する上で必要となる知識を問う学科試験の 2 つに合格する必要がある. 後者の学科試験は, 制限時間 50 分の筆記試験である. 出題形式は正誤判定問題であり, 交通規則やマナー, 運転知識などについて述べられた問題文に対し, そこで述べられていることが正しいか誤っているかを判定する問題である. 問題は 95 問出題され, 先頭 90 問は, 問題文各 1 文を読み正誤判定を行う問題である. 自然文の問題文だけを読み解答する問題が多いが, 交通標識などのイラストの絵を参照して解答する問題も存在している. それに対し, 末尾の 5 問は, 1 問につき 1 枚の運転席から見た外の様子などのイラストが示され, 3

つの枝間の正誤判定問題を解く問題である. 先頭 90 問は各 1 点, 末尾 5 問は完答で各 2 点で, 合計 100 点満点である. 学科試験の合格基準は 90 点以上である.

3. 学科試験問題で使用されている語彙の分析

3.1 問題文中の語彙数

今回, 分析の対象とした学科試験の模擬問題は「試験によく出る普通免許 1000 題」(倉 宣昭著, 高橋書店)の第 10 回の問題の問題文 100 文とした. まず, 問題文中に含まれる内容語の語彙数について調査したところ, 319 語であった. ただし, 「原動機付自転車」などの語は「原動機」「付」「自転車」と 3 つには分けず 1 語として扱った.

3.2 問題のタイプ

3.2.1 自動解答処理の観点から見た問題分類

試験問題には異なったタイプのもが存在する. そのため, 解答する際にはどこに注目すべきなのかを理解する必要がある. まず, 試験問題は次の通り大きく 3 種に分類する事が出来ると考えた. まず 1 つ目はイラストを見て解答する問題である (以下「イラスト問題」と略す). 分析対象の 100 問中にはイラスト問題は 13 問存在した.

2 つ目は問題文で示された物理現象について, 法則に基づいて計算が必要な問題である. この問題では, 問題文が問われている法則の種類, 計算に必要な情報を特定した上で, 計算を行った上で正誤判定を行う必要がある. これは 100 問中, 2 問存在した.

3 つ目はそれ以外の問題である. この問題は, イラストはなく, 問題の自然文で記されている交通ルールやマナーなどについての記述が正しいかどうかを判定する問題である. この問題は, 100 問中, 85 問存在した.

連絡先: 的場成紀, 大阪工業大学情報科学部, 〒 573-0171 大阪府枚方市北山 1-79-1, e1b15097@st.oit.ac.jp

3.2.2 詳細な分類

以下の異なる3つの観点で、問題をより詳細に分類した。

1. 5W1Hによる分類
2. 問われ方による分類
3. 問題の内容

3.2.3 5W1Hによる分析

問題文中に出現する内容語の語彙について5W1Hの観点から分析を行った。ここで5W1Hは、時間(when)、場所(when)、ガ格(who)、ヲ格(what)、述語(how)とした。

- (1) when: 季節や天候、時間帯、災害時なども含めた時期や時間
- (2) where: 場所
- (3) who: 文中のガ格に相当する内容語
- (4) what: 文中のヲ格に相当する内容語

5W1Hの観点から内容語を分類したものを表1に示す。

まず、「時間」の中で最も多く出現した単語は「夜間」であった。これは、視界や前照灯に関する問題において、「夜間」という単語が多く用いられているためである。

「場所」に関しては単語「道路」が最も多く出現していた。また、「道路」という単語は、単独で使用されることは少なく、「一方通行の」や「車両通行帯のある」などの修飾語句を伴って使用されることが多かった。

「ガ格」については、「運転手」「自動車」などが多く出現していたが、「ブレーキ」「後車輪」などの自動車の部品に関する単語も多く見られた。また、ガ格である単語が直接的な問題の対象物ではない問題も多く見られた。例えば、

- ファン・ベルトの中央を指で押してみたら、50ミリメートルぐらいの緩みがあった

の問題では、述語「あった」に対するガ格は「緩み」であるが、問題で問われている知識は、「ファン・ベルトの緩みの大きさ」についての知識であり、問題が問っている対象の解析を難しくしていることが分かった。

3.2.4 問題の問われ方による分析

次に、問題の問われ方について分析を行った。自動車免許試験の正誤判定問題の言い回しは、ある種独特のものであり、「～は～である」といった「事実について述べている文」と「～は～した」といった「運転手や車などの「行動について述べている文」の2種類が存在し、それらの割合について分析を行った。

分析の結果、表2で示す通り、「事実について述べている文」の方が多く、出現数は84であった。それに対して、「行動について述べている文」の出現数は16であった。さらに、それらの文についての文末表現について分析したところ、「行動について述べている文」に関しては最後が「～した」で終わることが多く、「事実について述べている文」には「～である」「～できる」「～になる」「～よい」など、表現に多様性が見られた。

3.2.5 問題の内容による分析

問題の内容による分析を行う。

大きく分ける種類として4種類あり、それぞれ「運転」「準備」「知識」「心がけ」である。運転は運転に関することに対して問われている問題である。例えば「追い越し」などである。

表 1: 5W1Hの観点から分類した内容語と頻度

5W1H	単語 (頻度)
when (時間)	夜間 (6), 雨 (3) 冬 (1), 雪 (1) 災害 (1), 光化学スモッグ (1)
where (場所)	道路 (12), 交差点 (6) 高速道路/高速/高速自動車国道 (4), 坂 (4) 踏切 (3), 路側帯 (2), 踏切 (2) 曲がり角 (1), 市街地 (1), トンネル (1)
who (ガ格)	運転手 (4), 速度 (3) 自動車/車/普通自動車 (3), 者 (3) エンジン・オイル (2), 空気圧 (2) 原動機付き自転車/原動機付自転車 (2), 追い越し (1) 警察官 (1), 交通 (1) 光化学スモッグ (1), 交通公害 (1) 後車輪 (1), 視線 (1) 灯火 (1), 燃料 (1) (オイルの) 循環状態 (1), (燃料の) 消費量 (1) タイヤ・チェーン (1), トンネル (1) (排気の) 色 (1), ハンド・ブレーキ (1) 普通二輪車 (1), ブレーキ (1) 前車輪 (1), (タイヤの) 溝 (1) ミニカー (1), 路面電車 (1)
what (ヲ格)	自動車 (8), オートマチック車 (8), 車 (8) ブレーキ (3), 急ブレーキ (3) ペダル (3), ブレーキ・ペダル (3) 原動機付き自転車/原動機付自転車 (2) 人 (2), 2人 (2), 大型特殊自動車 (1) 違反 (1), 後車輪 (1) 燃料 (1), エンジン (1) ファン・ベルト (1), 速度 (1) 幼児 (1), 前照灯 (1) 急ハンドル (1), 視力 (1) チェンジ・レバー (1), 進路 (1) 通行帯 (1), 路側帯 (1) 危険 (1), 全引きしろ (1) ハイドロ・プレーニング現象 (1) 車間距離 (1) 速度超過 (1), 余地 (1) 積載超過 (1), 間隔 (1) 場所 (1), マイクロバス (1) 許可 (1), 車線 (1) 故障車 (1), 番号標 (1) 荷物 (1)

表 2: 問題の問われ方による分類の結果

問題の問われ方	頻度
事実について述べている文	84
行動について述べている文	16

表 3: 問題の内容による分類の結果

問題の内容	頻度
運転の技術	77
準備	17
知識	4
心がけ	2

準備は運転をする前に行う前の段階である。知識は運転に関する現象である。心がけは道徳的な話が含まれている。

表 3 にこれらの分類の頻度数を示す。一番多く出題されているのは「運転の技術」についてのものである。

次に多く出題されていたのは「準備」であった。「準備」に関する問題は、主に車の部品に関することや免許の種類に関する内容である。

「知識」に関する問題は、運転中におこる現象に関する内容や数式に分類される問題である。

「心がけ」は出題される問題が一番少なかった。

3.3 問題を解く上での必要な知識の分析

問題を解くために必要な知識を考察する。先の問題の分類を踏まえると

1. 運転に関する知識
2. 常識的な知識

の 2 種類が必要であると考えられる。

運転に関する知識とは「交通の方法に関する教則（昭和 53 年 10 月 30 日 国家公安委員会告示第 3 号）」に掲載されている知識について問われている。例えば

- 車の速度が 2 倍になると、制動距離はおおよそ 4 倍になる。

上記のような問題の場合、「制動距離」という単語の意味を知らなければならない。加えて、制動距離の算出の仕方も知っている必要がある。

「常識的な知識」とは運転に関する知識とは違い、明記されていない情報を想像するために必要な知識である。例を挙げると

- オートマチック車で坂を下るときは、チェンジ・レバーを 2 か 1 に入れ、エンジン・ブレーキを活用する。

上記の問題では動作主格となる単語が文中にない。しかし、人間の受験者は、問題文を見たときに「動作主格が運転手である」と容易に想像することができる。これは人が今までに培ってきた経験から推測できるためである。

3.4 問題文の省略解析

運転免許問題には省略語句が多く含まれる。問題文に対して、省略解析を行って分析を試みた。省略解析器として KNP を使用した。

表 4 に KNP による解析結果を示す。100 問の問題文中で、省略格指定が 17 個、省略解析対象指示詞が 11 個、合計 28 個の省略があった。省略格指定では主に「見える」の単語が対象となった。例えば

- 暗いトンネルから明るい場所へ出たときは、視力が急激に低下して、見えなくなることがある。

表 4: 省略解析の結果

ゼロ照応解析の結果	頻度
省略格指定	17
省略解析対象指示詞	11
合計	28

上記のような問題であった場合、「見えなくなる」の部分が省略格指定となる。また、「不特定人が」、「トンネルから」、「場所」が直接係り受け解析の格の対象となる。不特定人とは問題文の中に明記はされていないが主格の対象となるのは人であるときの対象となる。また、「とき」という単語が明記されていないが「見えなくなる」に係り受け解析の結果となっており、「見える」が何に対して指示対象としているのかを表す単語は「視力」となっている。

上記以外にも「～という」「～といえる」の単語が省略格指定の対象となった。例えば

- 運転者は、「酒を飲んだら運転しない」「乗るなら飲まない」という習慣を身につけることが大切である。
- 交通法令を守らなくても、臨機応変に運転して交通事故を起こさなければ、「安全な運転」といえる。

である。「～という」の場合、主に主格となる部分は不特定人となった。また、「～といえる」の場合は主格が不特定人となるが、上記の例では「運転と」が省略されていると特定された。

上記の KNP で省略解析を行った結果と予測していた結果と異なっていた。その原因の一つとして、免許問題が 1 文で構成されることが挙げられる。本来、KNP で省略解析を行う場合は 2 文以上あることを想定している。しかし、今回のように問題文が 1 文しかないために予想とは違った結果となったと考えられる。

4. おわりに

本稿では問題文の分析を 5W1H の観点からの使用語彙と省略語句について分析を行った。5W1H の観点で使用語彙を見た場合、「時間」は「夜間」、「場所」は「道路」、「ガ格」は「運転手」、「ヲ格」は「自動車」が一番多く頻出した。さらに省略語句について省略解析器を用いて問題文の解析を行い分析を行った。今後は、上記の結果を踏まえて自動解答システムを開発する予定である。

謝辞

本研究は JSPS 科研費 18K11452 の助成を受けたものである。

参考文献

- [杉村 13] 杉村 皓太, 佐々木 裕: 交通規則問題のための解答システムの構築, 言語処理学会第 19 回年次大会 発表論文集, pp. 790-793 (2013)
- [平 14] 平 博順, 田中 貴秋, 永田 昌明: 自動車運転免許試験 RTE コーパスの構築, 第 28 回人工知能学会全国大会予稿集, 3I4-5 (2014)
- [平 15] 平 博順: 自動車免許試験自動解答に向けた問題分析, 第 29 回人工知能学会全国大会予稿集, 1K2-2 (2015)

[102-J-12] Human interface, education aid: information navigation

Chair:Yukihiko Matsubara Reviewer:Megumi Kurayama

Tue. Jun 4, 2019 1:20 PM - 2:40 PM Room O (Front-left room of 1F Exhibition hall)

[102-J-12-01] Proposal and Development of the System for private navigation by ARKit2○Yudai Asano¹, Toshitaka Higashino², Masato Soga¹ (1. Wakayama University, 2. Osaka University)

1:20 PM - 1:40 PM

[102-J-12-02] Development of an Adaptive Street View that Selects Panoramic Images Based on User Browsing Behavior○Riki Satogata¹, Keisuke Takiguchi¹, Yosuke Fukuchi¹, Michita Imai¹ (1. Keio University)

1:40 PM - 2:00 PM

[102-J-12-03] The Model for the PRVAs' Recommendation with Nonverbal Information○Tetsuya Matsui¹, Hidehito Honda², Seiji Yamada^{3,4,5} (1. Seikei University, 2. Yasuda Women's University, 3. National Institute of Informatics, 4. SOKENDAI, 5. Tokyo Institute of Technology)

2:00 PM - 2:20 PM

[102-J-12-04] Analyzing Factors of Beginner Friendliness / Visual Intelligibility for Overall Measurement of Web Pages Explaining Academic Concepts○Chiharu Hirohana¹, Shintaro Okada¹, Takehito Utsuro¹, Yasuhide Kawada², Noriko Kando³ (1. University of Tsukuba, 2. Logworks Co., Ltd., 3. National Institute of Informatics)

2:20 PM - 2:40 PM

ARKit2 によるプライベートナビゲーションシステムの提案と構築

Proposal and Development of the System for private navigation by ARKit2

浅野 勇大*¹
Yudai Asano

東野 利貴*²
Toshitaka Higashino

曾我 真人*¹
Masato Soga

*¹ 和歌山大学システム工学部

*² 大阪大学大学院情報科学研究科

Faculty of Systems Engineering, Wakayama University Graduate School of Information Science and Technology, Osaka University

In this research, we propose a system which can freely set navigation without using GPS location information and AR marker at any location, and can be shared with multiple terminals via server. Moreover, in order to verify the usefulness of the system, a verification experiment was carried out. The verification experiment was conducted at Library in Wakayama University. We divided 20 subjects into 10 subjects for experimental group and 10 subjects for control group. The control group searched the target book using information printed by a system for book search in the Library. The experimental group searched the target book using the information and also using the developed system in this research. The result showed that this system has significant effect.

1. はじめに

モバイル端末の高機能化に伴い、スマートフォンやタブレット端末に利用されているGPSの位置情報を用いたナビゲーションシステムにAR機能に対応したものが多く登場している。しかし、屋内などGPSを測位できない場所や、プライバシーの観点からGPSの位置情報を利用しないプライベートな空間で利用できるナビゲーションシステムの需要も近年高まってきている。そこで本研究では、任意の場所において、GPSの位置情報やARマーカーを使用せずに自由にナビゲーションを設定でき、サーバーを経由することにより、複数端末で共有できるシステムを提案する。また、システムの有用性を検証するために、検証実験を行った。

2. 先行研究

ARを用いたナビゲーションシステムの先行研究は、利用場所によって大きく2つに分けられる。屋外では、Yahoo! MAP ARモード[Yahoo 18]やGoogleマップARナビゲーション機能[Google 18]といったGPS位置情報を用いたナビゲーションシステムが主流である。一方、建物の内部といった屋内では、GPS位置情報を用いることが難しいため、Wi-Fi測位、ビーコン測位、IMES測位などの方法で位置情報を取得し、ナビゲーションシステムを実現している[京極 13]。昨今では、ARToolKitの普及から専用のARマーカーを用いたナビゲーションシステムも実現している[Daniel 05]。

しかし、上述の通り、屋内で実現されているナビゲーションシステムは、ナビゲーションを行うために、センサーや、マーカーを取り付けるなど物理的な事前準備を伴う。このような準備は、実験環境であれば大きな問題にはならないが、公共施設など一般的な場所では、大きな障壁となる。

また、従来のナビゲーションシステムでは、ナビゲーション内容を設計者があらかじめ設定しておき、それを提示することでナビゲーションを行っていた。そのため、ユーザーが自由にナビゲーションを設定し、他者と共有することは難しかった。

そこで本研究では、公共施設やプライベート空間といった一般的な屋内でのナビゲーションを対象とし、物理的な事前準備

を伴わず実現できるナビゲーションシステムを提案する。また、ユーザーにより任意にナビゲーションを設定することができ、他者と共有することが可能となるシステムを提案する。

3. 提案システム

3.1 開発環境

本システムは、iPad Pro用アプリケーションとして、MacBook Proを用いて開発を行った。また、サーバーはUbuntu18.04上にWebサーバーであるApache2.4.29を環境として用意した。また、サーバープログラムはPHP7.2.10-0ubuntu0.18.04.1(cli) (built: Sep 13 2018 13:45:02) (NTS)を用いて開発を行った。

3.2 システム構成

(1) ARKit2によるARWorldMapの保存

ARKit2では、現実空間において、ユーザーのデバイスの位置を特定するために使用する、空間マッピング情報が含まれるARWorldMapという仕組みが用意されている。このARWorldMapを再設定することで、任意の空間において、AR空間を復元することが可能となる。本システムでは、この技術を利用して、デバイスが移動する物理空間に追加されたオブジェクトの情報を保存し、複数端末で共有することにより、任意の空間において、AR空間を復元することを実現した。

(2) ARWorldMapの送受信

本システムでは、ARWorldMapをHTTP通信を用いてサーバーに保存し、ダウンロードすることを可能とした。

3.3 システムの使用方法

(1) システム画面説明

システム画面は、実験用システムのため、システムの起動と同時に表示される画面だけとなっている(図1)。また、以下のような機能を搭載している。なお、番号は画像内のボタンを意味している。

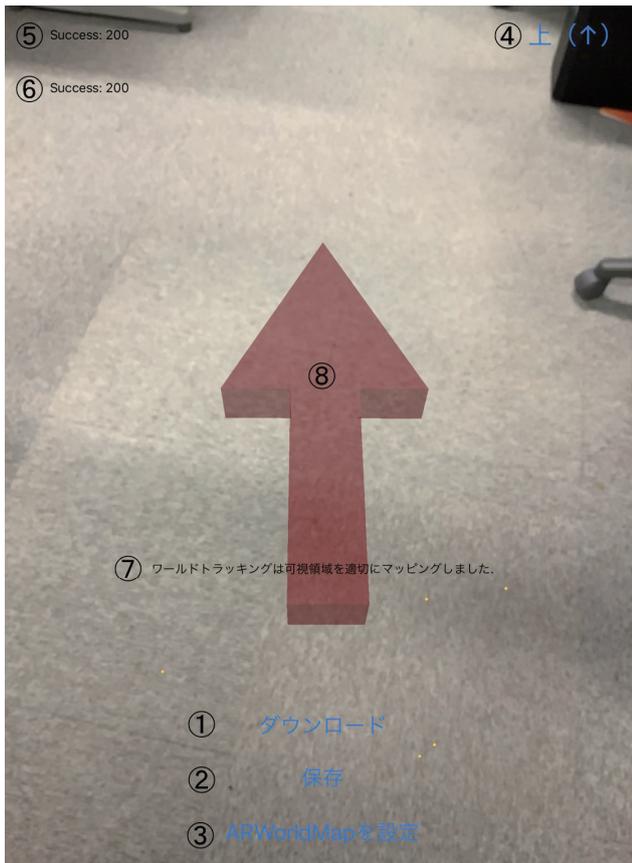


図1 システム画面

- ① ARWorldMap をサーバーからダウンロードする。
 - ② タップすると設定した ARWorldMap をローカルに保存し、その後 ARWorldMap をサーバーに送信する。
 - ③ ARWorldMap を設定ボタン、ダウンロードした ARWorldMap や、ローカルに保存した ARWorldMap を復元する。
 - ④ 空間に配置する矢印の向きを上下左右の4方向に変更するボタン。タップすることで矢印の向きの切り替えが可能。
 - ⑤ ダウンロードが成功した時に表示される。
 - ⑥ 保存が成功した時に表示される。
 - ⑦ 適切にマッピングできているかどうかを表示する。以下の4段階で表示する。
 - ワールドマップはまだ適切に利用できません。
 - ワールドトラッキングは、現在のデバイス位置の周囲の領域をまだ十分にマッピングしていません。
 - ワールドトラッキングは最近訪れた地域をマッピングしましたが、それでも現在のデバイス位置の周囲にマッピングしています。
 - ワールドトラッキングは可視領域を適切にマッピングしました。
- なお、4段階目の状態が ARWorldMap の作成・復元に対して、一番適切な状態である。
- ⑧ 平面を認識するとその特徴点を黄色くマークする。平面と認識された箇所をタップすることで矢印のオブジェクトを床に配置することができる。

(2) システムの使用手順

本システムでは、マップの新規作成と保存しているマップの復元の2つの使い方がある。それぞれを図2のフローチャートに従って説明していく。

- マップの新規作成の使用手順

マップを新規作成する際は、まずシステム画面⑦において示されるデバッグが「ワールドトラッキングは可視領域を適切にマッピングしました。」と表示されるまで、周囲をマッピングするキャリブレーションの作業を行う。その後、平面に対して、示したい方向の矢印を配置していき、マップを作成する。マップ作成終了後に、システム画面②の保存ボタンをタップし、システム画面⑤のデバッグで「Success 200」と表示されれば、保存完了である。
- マップの復元の使用手順

保存したマップを復元する際は、まずシステム画面①のダウンロードボタンをタップし、システム画面⑥のデバッグで「Success 200」と表示されれば、ダウンロード完了である。ダウンロード完了後、システム画面③のARWorldMapを設定のボタンをタップし、マップの新規作成の使用手順と同様に、システム画面⑦において示されるデバッグが「ワールドトラッキングは可視領域を適切にマッピングしました。」と表示されるまで、周囲をマッピングするキャリブレーションの作業を行うことで、マップの復元が完了する。

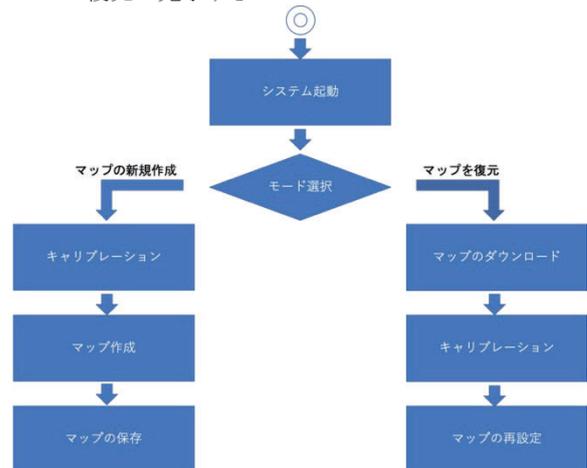


図2 ワークフロー

4. 評価実験

4.1 実験目的

本実験では、構築したシステムがナビゲーションシステムとしての有用性があるかを検証することを目的とする。

4.2 実験構成

(1) 実験環境

実験に協力した被験者は20名の大学生(男性:17名, 女性:3名)である。全ての被験者に対して、参加の同意を得た上で実験を行なった。本システムはGPSの位置情報やARマーカを使用せずに自由にナビゲーションを設定できるシステムを目的としているため、GPSが使えないかつ、ARマーカの配置が困難な和歌山大学図書館を実験場所に選定した。和歌山大学図書館では、図書分類法(日本十進分類法)に基づき、本が配置されているため、図書請求メモを用いて本を探す。図書館では、図書請求メモに記載されている配架場所、請求記号、資料番号

に従い本を探索する。そこで、本実験では、和歌山大学図書館において、本システムまたは、図書請求メモを用いて、実験者が指定した本を被験者に探索してきてもらい、探索開始から本を発見し、それを実験者の元に持ってくるまでの時間を計測した。

(2) 実験手順

本実験では、被験者は和歌山大学図書館で本を探す際に用いられる図書請求メモを用いて本を探す統制群10名と、図書請求メモと本システムを利用して本を探す実験群10名の2群に分けて実験を行なった。また、実験群で用いたシステムでは、あらかじめ実験者が本を置いてある場所までのナビゲーションを設定し、サーバーに保存してあるものをダウンロードし用いた(図3)。両群共に、実験前に図書館利用に関するアンケートを実施し、その後それぞれの実験環境に基づき、実験者が指定した本を探してきてもらい、その時間を計測した。最後に実験群のみにシステムの利用に関するアンケートを実施した。



図3 実験画面

4.3 実験結果

(1) 事前アンケートの結果

和歌山大学図書館では、図書分類法に基づき本が配置されているため、図書分類法を暗記している被験者は本システムの有無に関係なく簡単に本を見つけてしまう恐れがある。また、図書館の利用頻度により、実験結果への影響が出る恐れも考えられる。そこで、事前に、図書分類法についての習熟度、図書館の利用頻度についてのアンケートの実施した(図4, 5)。これは実験群・統制群共に同じ内容で行い、合わせて集計した。

図書分類法(日本十進分類法)について知っていますか?

20件の回答

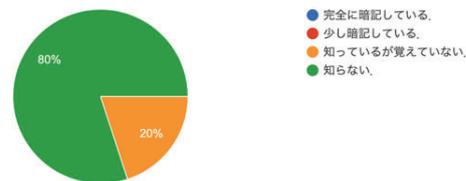


図4 図書分類法に関するアンケート結果

図書館の利用頻度を教えてください。

20件の回答

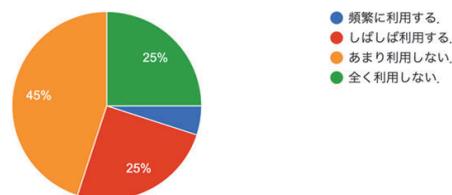


図5 図書館の利用頻度に関するアンケート

(2) 統計量

事前アンケートの結果から図書分類法を把握している被験者はいなかったため、すべての被験者のデータを採用した。被験者20名のデータから実験群(10名)・統制群(10名)ごとに本を見つけるまでの時間(探索時間)の平均値と分散値を算出した(表1, 図6)。

表1 探索時間の統計量

統計量	統制群	実験群
平均値 [s]	275.30	100.30
分散値 [s ²]	187.73	35.63

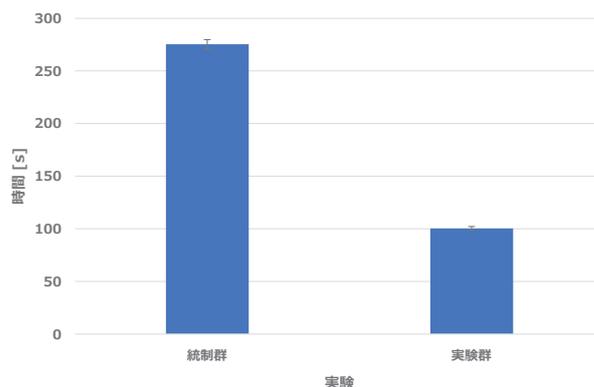


図6 平均値と標準偏差

実験群・統制群の差の検定は、ノンパラメトリック検定手法の一つである「Wilcoxonの順位和検定」を選択した。t検定を用いない理由は、データ数が少なく、データの平均値が正規分布に従うと仮定できないためである。今回、帰無仮説に「平均に差がない」、対立仮説に「平均値に差がある」と設定した片側検定を実

施した。検定の結果、 $p = 0.0036$ となった。よって有意水準 1% の場合に、帰無仮説が棄却されるため、平均値に差があることが示された。

4.4 システムに関するアンケートの結果

システムに関するアンケートには 5 段階評価のリッカート尺度を利用している。その結果を以下の表 2, 3 に示す。

表 2 アンケート質問内容

質問内容	質問番号
システムは目的地的に着くための手助けになりましたか？	1
自分がどちらに進めば良いか適切に理解できた。	2
ナビゲーションの指示はわかりやすかった。	3
図書請求メモがなくても目的地付近にたどり着くことができると思う。	4

表 3 アンケート結果

質問番号	強く同意しない	同意しない	どちらとも言えない	同意する	強く同意する
1	0	0	0	3	7
2	0	0	0	1	9
3	0	0	0	2	8
4	0	0	0	3	7

表 2, 3 のアンケート結果は、被験者数が少ないことから、データに散らばりがなく、一概に結論を述べることはできないが、比較的高い評価が得られた。

5. 考察

5.1 提案システム

本研究では、屋内でのナビゲーションシステムの問題点を解決するために、任意の場所において、GPS の位置情報や AR マーカーを使用せずに自由にナビゲーションを設定でき、設定データをサーバーを経由させることにより、複数端末で共有できるナビゲーションシステムを提案した。

本研究で使用しているマーカーレス AR の先行研究は複数見受けられるが、GPS 位置情報と AR マーカーの双方を使用しないナビゲーションシステムの研究は、あまり行われていない。

また、先行研究では、ナビゲーションシステムの設計者があらかじめ設定したナビゲーション情報を受け取ることしかできなかった。しかし、本研究では、任意の場所において、ユーザーが自由にナビゲーションを設定でき、その設定情報を複数端末(ユーザー)に共有し利用できる環境を構築した。この点については、本研究の大きな新規性であると考えられる。

5.2 図書館の利用頻度による影響

評価実験で得られたデータの信頼性の検証として、図書館の利用頻度による影響があるかについて考察する。図書館の利用頻度のアンケート結果から、探索時間と比較して考察する。以下の項目に対し、それぞれ値を割り振る。

- 頻繁に利用する ...4
- しばしば利用する ...3
- あまり利用しない ...2
- 全く利用しない ...1

この値はカテゴリデータであるが、この場合、図書館の利用頻度を表す間隔尺度とみなせるため、各被験者に対し、得られた探索時間と比較して相関係数を導出する。なお、用いる相関係

数はピアソンの積率相関係数とする。表 4 において、統制群は、図書請求メモを用いて本を探す 10 名の探索時間と利用頻度の関係、実験群は、図書請求メモと本システムを利用して本を探す 10 名の探索時間と利用頻度の関係、被験者全体は、統制群、実験群すべての被験者の探索時間と利用頻度の関係を表している。

表 4 相関係数とその p 値

	統制群	実験群	被験者全体
相関係数	0.067	0.26	-0.0035
p 値	0.85	0.47	0.99

相関係数の信頼度に関して t 検定を用いて、検定を行う。帰無仮説を「相関係数が存在しない」、対立仮説に「相関係数が存在する」とすると、p 値は表のようになる。このことから、各群において有意水準 5% で帰無仮説は棄却できず、相関係数の信頼性は担保できないため、本実験においては、図書館の利用頻度と本実験結果の相関関係を認めることはできなかった。

よって、システムの評価について、実験結果に対して、図書館の利用頻度が直接影響しているものとはいえなかったため、その影響を無視するものとする。

実験の探索時間の結果より、有意水準 1% の片側検定において、実験群の方が探索時間が有意に短いことが示された。よって、本実験により、実験群の平均値の方が低い値となっているため、システムを使った実験群の方が、より早く本を見つけることができたということが示された。また、分散値においては、実験群の方が低い値となっているため、システムを用いた場合には、被験者による探索時間の差が少ないことが示された。このことから、本システムはナビゲーションシステムとして有用であることが示された。

6. まとめ

本研究では、屋内でのナビゲーションシステムの問題点を解決するために、任意の場所において、GPS の位置情報や AR マーカーを使用せずに自由にナビゲーションを設定でき、設定データをサーバーを経由させることにより、複数端末で共有できるナビゲーションシステムを提案した。

実験を行い、検定を行った結果、実験群のほうが、統制群に比べて有意に探索時間が短くなった。よって、本研究は、ナビゲーションシステムとしても有用であることが示された。

参考文献

- [Yahoo 18] 現実世界とアプリの世界が、一つに重なった！
Yahoo!MAP の新機能「AR モード」
(最終閲覧日：2019 年 2 月 3 日)、
https://map.yahoo.co.jp/blog/archives/20180305_map_ar-mode.html
- [Google 18] Google Maps unveils its first-ever augmented reality interface (最終閲覧日：2019 年 2 月 3 日)、
<https://arstechnica.com/gadgets/2018/05/google-maps-unveils-its-first-ever-augmented-reality-interface/>
- [京極 13] 京極 海, 島村 和典: ナビゲーションのための屋内位置推定方式の研究, 高知工科大学 情報学群, 2013 年 2 月.
- [Daniel 05] Daniel Wagner, Dieter Schmalstieg: First steps towards handheld augmented reality, Vienna University of Technology, November 2005.

ユーザの閲覧行動に基づきパノラマ画像データを選択する 適応型ストリートビューの開発

Development of an Adaptive Street View
that Selects Panoramic Images Based on User Browsing Behavior

里形 理興 滝口 啓介 福地 庸介 今井 倫太
Riki SATOGATA Keisuke TAKIGUCHI Yosuke FUKUCHI Michita IMAI

慶應義塾大学大学院 理工学研究科
Keio University

By using Street View, it is possible to get landscape information that cannot be got from a planar map. However, it is problem that it is difficult for users to see where users want to see due to the coarse arrangement of the panoramic images of street. In this study, with the aim of developing an Adaptive Street View that displays panoramic image data in proportion to the degree of user's interest in the point, we propose ALPS, a method to select panoramic image data to be displayed using a spring model, based on the degree of interest estimated from the user's operation in the Street View. In the experiment, participants use the Adaptive Street View with ALPS under three tasks. As a result, it was confirmed that the panoramic image arrangement according to the user's interest was realized.

1. 序論

モバイル端末の普及に伴い地図アプリケーション [5, 3] が発展してきており、紙の地図と比較してより多様な情報をユーザに提供できる基盤が整ってきた。一方で、地図アプリケーションは地理情報の提示に主眼が置かれており、景観の情報が欠落している。ユーザが移動経路を地図アプリケーションによって確認したい場合、景観情報の欠落はデメリットになる場合がある。例えば、初めて訪れる場所での経路を地図アプリケーションで確認する場合、得られる情報が道路や建物の名称のみだと、実際に訪れた際に地図上の位置と実際の位置が同定できない可能性がある。

景観を写したパノラマ画像群を提供するサービス [6, 4] (以降、ストリートビューと呼称) を使うことで、地図に不足する景観情報を補うことができる。景観が見えるようになることで、ユーザは実際に地点を訪れているかのように経路を確認できる。またストリートビューでは、景観のパノラマ画像が連続的に提示される。結果、ユーザはどの地点をどう進んでいるのかという空間的なコンテキスト付きで地形を把握しやすくなる。しかし、パノラマ画像の配置間隔が適切でない場合、ユーザが見たい地点が見つらなくなることがある。

ユーザが見たい場所を見られない原因として、パノラマ画像の配置間隔が粗いことがある。Kolhatkar ら [7] や Zhao ら [9] は 2 枚のパノラマ画像から 2 枚の間の景観を補完するパノラマ画像を推定する手法を提案している。パノラマ画像の間を補完することで、パノラマ画像をより細かく提示できるようになり、ユーザが見たい場所を見やすくなることができる。また、車載カメラの撮影間隔の限界や通信データ量の問題を受けずに、ストリートビューで閲覧可能な景観データの量を増やすことができる。

ストリートビューからユーザが必要な情報を取り出せる可能性を上げるためには、ストリートビューに配置するパノラマ画像の枚数を増やせばよい。しかし、単にパノラマ画像の枚数を増やしてしまうと、ユーザが必要としていない位置周辺でも閲覧可能なパノラマ画像が多くなってしまい、ユーザがストリー

トビュー内を移動する際の操作量が増えてしまう。ユーザの操作量が増加することを抑えつつ各ユーザに必要な情報を提示するために、ユーザが必要としている情報を推定し、取捨選択した上で提供するユーザ適応 (パーソナライゼーション) を行う方法が考えられる。従来研究では、地図におけるパーソナライゼーションを行う手法は存在する [8, 1]。しかしながら、ストリートビューにおけるパーソナライゼーションを行う手法はまだ考えられていない。

本研究では、ストリートビュー閲覧時のユーザ操作からユーザがそれぞれの地点に抱く興味の度合 (興味度) を推定し、推定結果に基づいて選択されたパノラマ画像データを配置する手法 ALPS (Adaptive Location of Panoramic Street-images) を提案する。ALPS では、各パノラマ画像表示位置が、推定した興味度をもとに弾性力の変化するばねによって接続されるとみなす。ばねモデルで考えることにより、各パノラマ画像表示位置の疎密が連続的に容易に実現できる。ALPS によりユーザが興味のない地点ではパノラマ画像データの配置が疎になることでスムーズに進み、ユーザは操作を面倒に感じづらくなる。また、ユーザが興味のある地点の近くでパノラマ画像データの配置が密になることで、より様々な視点からの閲覧が可能になる。

2. 背景

本章では研究の背景として、ストリートビューや地図アプリケーションにおける関連研究を紹介し、ストリートビューの課題について説明する。

2.1 パノラマ画像間隔の粗さに対する提案

ストリートビューではパノラマ画像内で視点を移動しながら近隣のパノラマ画像間を遷移できるため、ユーザにとってどの場所をどのような順番で移動したのかの把握が容易であることは利点である。しかしながら、現在のストリートビューではパノラマ画像の間隔が大きく、ユーザが自分の位置を見失ってしまうこともある。Kolhatkar ら [7] や Zhao ら [9] はパノラマ画像間の実距離の大きさを撮影データ量を増やすことなく埋めるために、2 枚のパノラマ画像間を補完するパノラマ画像を生成する手法を提案した。

連絡先: 里形理興, 慶應義塾大学大学院 理工学研究科
〒 223-8522 神奈川県横浜市港北区日吉 3-14-1
E-mail: satogata@ailab.ics.keio.ac.jp

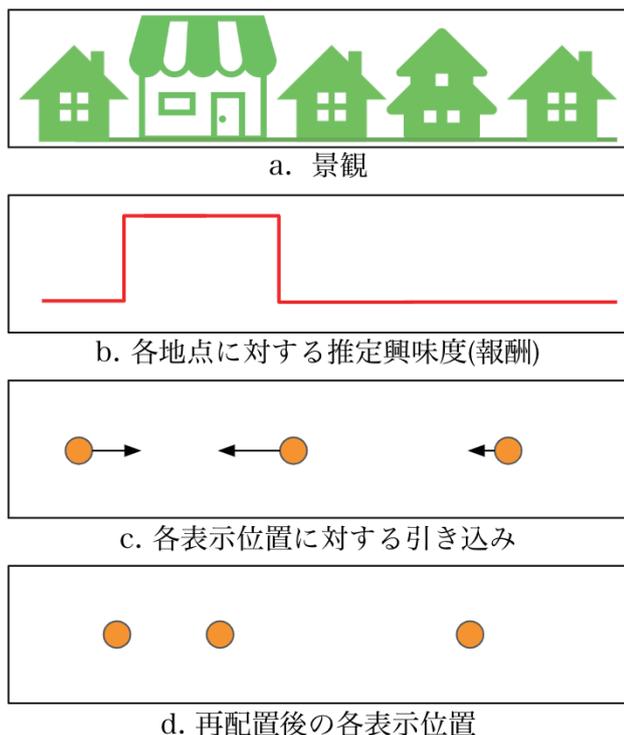


図 1: ALPS の概念図

2.2 地図パーソナライゼーション

地図上の情報過多により、ユーザが欲しい情報を得ることが困難になりうる問題を解決する方法として、地図のパーソナライゼーションが考案されている。Aoidhら [2] は、地図アプリケーションを閲覧する際のユーザのマウスの動きやクリックに基づいて地図に対するユーザの興味が測れることを示し、ユーザに必要なと思われるアプリケーションの機能を推薦する CoMPASS を作成した [1, 8]。小林ら [10] は地図上およびストリートビュー上の操作からユーザの意図を推測し、推測結果からユーザに必要なストリートビューの景観画像を統合した地図を出力するシステムを提案した。

2.3 課題

ストリートビューにおいてユーザが見たい場所を見られないという課題は、パノラマ画像の枚数を増やすことによって解決できる。しかし、多すぎるパノラマ画像はユーザの操作量を増やすことにつながり、ユーザは快適に情報を取得することが困難になる。ユーザの操作量が増加することを抑えつつ各ユーザに必要な情報を提示するために、ユーザが必要としている情報を推定し、取捨選択した上で提供するパーソナライゼーションを行う方法が考えられる。従来研究では地図アプリケーションのパーソナライゼーションは多くなされているが、ストリートビューにおいてパーソナライゼーションを行なった例はない。

3. 提案

ALPS(Adaptive Location of Panoramic Street-images) は、ユーザが興味のある地点にストリートビューのパノラマ画像配置が集中するように、パノラマ画像を再配置する手法である。興味のある地点への集中を実現する仕組みとして、経路の各地点にユーザの興味の度合いが設定されると考え、各パノラ

マ画像表示場所には興味度の高い位置へと引き込まれていくよう、その前後から興味度のより大きいほうへと移動させる(図1)。

以上のような仕組みは、各パノラマ画像表示位置が、興味度をもとにして弾性力の変わるばねで接続されているとみなすことができる。まず、自然長が0で k_A, k_B のばね定数を持つばねによって左右から接続された物体を考える。左端から右端までの長さを L とすると、物体は左端から $\frac{L \times k_B}{k_A + k_B}$ の位置でつりあう。すなわち、 k_A が大きくなるほど物体の位置は左端に寄っていく。以上の考え方を複数のばねで接続されたパノラマ画像表示位置として拡張する。更新は微小距離に区切って i 回行うものとする。はじめは各パノラマ画像表示位置の間隔が等しくなるように並んでいるとすると、 n 番目のパノラマ画像表示位置を x^n は以下の式で初期化、および更新される。

$$x_i^n = \begin{cases} I \times n & (i = 0) \\ x_i^{n-1} + \alpha(x_{i-1}^{n+1} - x_{i-1}^{n-1}) \frac{k_{i-1}^{n,n+1}}{k_{i-1}^{n-1,n} + k_{i-1}^{n,n+1}} & (i \neq 0) \end{cases} \quad (1)$$

ここで、 I は初期状態におけるパノラマ画像表示間隔を表す定数であり、 α は1より小さい定数である。 α をつりあいの位置を表現する項に乗することで微小距離を表現している。 $k^{n,n+1}$ は x^n と x^{n+1} の間にあるばねのばね定数を表している。本手法においては以下のように表現される。

$$k_i^{n,n+1} = \frac{\sum_{x \in [x_i^n, x_i^{n+1}]} r(x)}{N} \quad (2)$$

$r(x)$ は各パノラマ画像データの位置に存在する興味度を表す関数である。 N は x^n と x^{n+1} の間にあるデータ数を表す。すべてのばね定数は、ばねの両端間の興味度の平均として表現する。興味度が変わるたびにすべてのパノラマ画像表示が弾性力によるつりあいを保つように移動させる。計算を収束させるために、全てのパノラマ画像表示位置の移動量が一定の値より小さくなった時に更新を終了するものとする。

$$\forall n, |x_{i+1}^n - x_i^n| < \beta \quad (3)$$

ここで、 β は停止条件における移動量の閾値である。

ストリートビューにおいてユーザが後方に進む操作をする場合、ユーザは何か見たい対象を見落としたということが推測される。ALPS はユーザが後方に進んだ後再度前方に進む操作をもとに、操作の発生したパノラマ画像表示位置と次のパノラマ画像表示位置の区間における、ALPS の推測するユーザの興味度を増加させる。一般のストリートビューでは見落としがパノラマ画像間隔の広さに起因する時、後方に進んでもユーザは目的の対象をよく見ることができず、ユーザは再度前方へ進行することになる。ALPS によってパノラマ画像の再配置を行うことで、ユーザが再度前方へ進出した時にユーザの興味地点と推測された地点の新しいパノラマ画像が表示される。

4. 実験

実験では、ALPS を用いて実装したストリートビューを3つの異なるタスクのもとで実験参加者に使用させ、使用後に得られた推定興味度および配置の有効性を検証する。データの撮影場所は夢見ヶ崎動物公園 *1(図2)である。パノラマ画像デー

*1 〒 212-0055 神奈川県川崎市幸区南加瀬1丁目2-1



図 2: 撮影した経路は A-B 間の約 120m(地図データ ©2019 Google, ZENRIN)

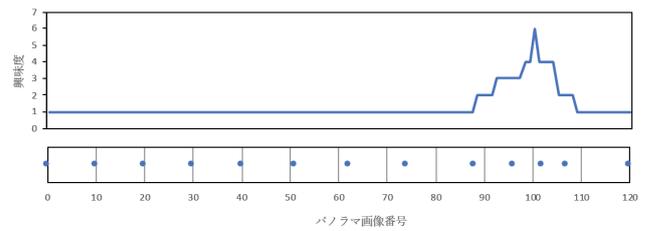
タは VIRB 360^{*2} を用いて天球動画を撮影した後、121 枚の天球画像を切り出し、画像 0 から画像 120 まで通し番号をつけたものを用いた。

3つの異なるタスクの内容は以下のようにになっている。検索タスクは、経路の中に一つだけ存在する自動販売機を探すタスクである。自動販売機は初期配置の状態から見つけることができるが、そのままでは正面から観察することは難しい。検索タスクでは、実験参加者に検索対象を指示することで、検索対象付近で推定興味度が高くなるかどうか確認する。環境把握タスクは、経路を閲覧した後、どのような経路であったかを答えるタスクである。ストリートビューを景観の全体的な印象を掴むために用いる際には、ユーザは特定の地点に注目しないため、全体を通して興味度は上下しないことが予想できる。環境把握タスクでは、実験参加者にストリートビュー内の大まかな印象を掴ませ、興味度が全体を通して上下しないかどうか確認する。計数タスクは、経路内に存在する動物を見て、動物の種類と数を答えるタスクである。計数タスクでは、実験参加者に地点に注目することが必要なタスクを課し、地点付近で興味度が高くなるかどうか確認する。1つのタスクにつき5名ずつ、合計15名の参加者にALPSによるストリートビューを用いたタスクを課した。

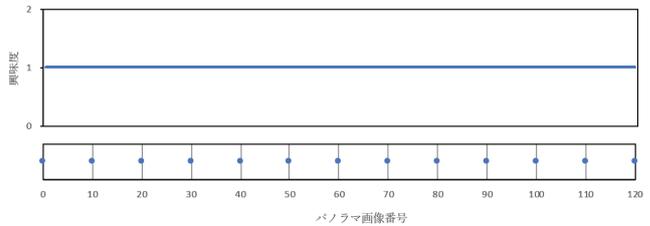
5. 結果

図3に各タスクにおいて記録された推定興味度および、記録されたパノラマ画像配置を各タスクにつき一つずつ示した。

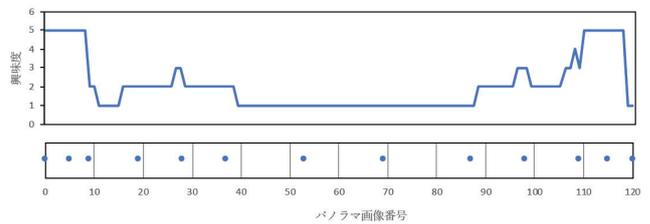
検索タスクにおいて、自動販売機は画像102地点で正面から観察できる。5名の参加者は全員が90~110付近で前後に移動し、その付近に興味があると推定された。全ての参加者がパノラマ画像配置が変化したことによって正面から自動販売機を捉えることができた。図3a 上部の興味度のグラフでは、検索対象であった自動販売機付近で興味度が高く推定されている。また、下部のパノラマ画像データの表示位置を表すグラフから、画像100付近にパノラマ画像表示位置が集中しているこ



a. 検索タスクにおける一例



b. 環境把握タスクにおける一例



c. 計数タスクにおける一例

図 3: 各タスクにおける全参加者の推定興味度と配置のうち一例

とが観察できる。

環境把握タスクにおいては、参加者に注目すべき地点を明示的に与えなかったため、各参加者間で推定興味度や配置に共通する特徴はみられなかった。図3bの一例では、参加者は一度も後退操作をしなかったため、配置は実験中常に初期配置のままであった。他の例では興味度が上昇する例もあったが、全ての参加者で共通しておらず、各々の興味にしたがって閲覧した結果だと考えられる。

計数タスクでは、程度に多少はあったが、どの参加者もタスク達成のために複数回ストリートビュー内で引き返す操作を行なった。どの参加者の興味度でも、マーコール(パノラマ画像番号30前後)付近の地点では興味度が高く推定されている。初期配置の角度からだと見づらいためにユーザが再確認するべく引き返した結果だと考えられる。他に、ラマ(画像70前後)やホンシュウジカ(画像100前後)の存在する地点でも、一部参加者の興味度が高くなっていることが確認できた。図3cの一例では、マーコールとホンシュウジカの付近で興味度が高く推定されている。他の場所でも高く推定されているのは、動物を確認することはできないが、檻があったために実験参加者が注目したためだと思われる。計数タスクは検索タスク、環境把握タスクと比較して多くの場所に注目する必要があるため、あまり注目しなくてもよい地点でパノラマ画像表示位置が疎らになる傾向も顕著に見られる例があった。例として、図3cの下部グラフでは、番号40~90でパノラマ画像の配置が疎になっている。

*2 <https://www.garmin.co.jp/products/intosports/virb-360/>

総合して、各タスクにおいて実験参加者が注目すると予想された場所で興味度が高く推定され、ALPSにおける興味度推定手法は妥当であるといえる。また、検索タスクや計数タスクのように、ストリートビュー内である物体を探したり、特定の角度から見たりする目的において、ALPSの手法は特に有効だと考えられる。

6. 今後の課題

ALPSでは、ストリートビュー閲覧時に前後する移動操作に対し、その付近の地点に興味があるとみなした。特に、前進時に後退し、再度前進を行なった地点の付近でのみ興味度を上昇させたが、前進時に後退した時点で興味度を上昇させることや、後退した地点と再度前進した地点の間のすべてで上昇させることが考えられる。また、興味度の上昇のさせ方に関して、ALPSでは1ずつ増加させたが、緩やかな上昇や急な上昇をさせた場合のパノラマ画像表示位置の挙動およびユーザの感じ方について調査したい。

興味度推定の手法に関して、ストリートビュー内での移動に基づく興味推定を用いたが、興味推定の手法は他にも考えられる。例えば、地理的特徴やユーザの注視方向、注視時間からも興味度が推定できる可能性がある。興味推定の手法については、ユーザのシステムへの印象評価も踏まえつつ検討していく必要がある。

本論文では、適応型ストリートビューのパノラマ画像の初期配置を常に等間隔としており、ユーザごとにパノラマ画像配置を変えることを想定した。実験では、各タスクに対して特徴的な興味度やパノラマ画像配置が得られた。ここで、ユーザごとに興味度を推定するのではなく、推定された興味度を地点に記録しておくことで、ある地点である目的が多く発生するような場合に有用な可能性がある。この場合、「ユーザの各地点への興味の度合い」ではなく、「各地点の興味の向けられやすさ」を推定および記録することになる。各地点の興味の向けられやすさからパノラマ画像の初期配置を決定することで、ユーザ操作に対する短期的な適応のみでなく、地域の特性に対する長期的な適応がなされ、よりユーザの操作負荷を減らすことができる。各地点の興味の向けられやすさを推定する手法に、今回用いたユーザの興味度推定手法を用いられるかどうかや、どのような手法を用いることができるか検討したい。

7. 結論

本論文では、ユーザ操作によって推測されるユーザの地点への興味度によってストリートビューのパノラマ画像の表示位置を適応的に変更する手法ALPS(Adaptive Location of Panoramic Street-images)を提案した。

ALPSでは、ストリートビュー内でのユーザ操作からユーザの地点への興味度を推定し、推定された興味度に基づいてパノラマ画像表示位置を変更する。各パノラマ画像表示位置は、推定した興味度をもとに弾性力の変化するばねによって接続されているとみなす。結果、パノラマ画像表示位置はユーザの興味度が高い地点付近に集中し、ユーザの興味度が低い地点では疎らになる。

タスクによってユーザが興味を向ける地点を操作して行なった実験の結果、ALPSでユーザの見たい地点に集中するパノラマ画像配置を実現可能なことがわかった。

今後はALPSのような適応的なインターフェースがユーザに与える影響も考慮しながらシステムを発展させていく予定である。

参考文献

- [1] E. Mac Aoidh and M. Bertolotto. Improving spatial data usability by capturing user interactions. In *The European Information Society: Lecture Notes in Geoinformation and Cartography*, pp. 389–403, 2007.
- [2] E. Mac Aoidh, M. Bertolotto, and D. C. Wilson. Analysis of implicit interest indicators for spatial data. In *Proceedings of the 15th Annual ACM International Symposium on Advances in Geographic Information Systems*, pp. 1–4, 2007.
- [3] Bing. Bing maps. <https://www.bing.com/maps>.
- [4] Bing. Streetside: Dynamic street-level imagery via bing maps. <https://www.microsoft.com/en-us/maps/streetside>.
- [5] Google. Google maps. <https://www.google.com/maps>.
- [6] Google. ストリートビュー - 絶景や世界の名所を見て回ろう. <https://www.google.co.jp/intl/ja/streetview/>.
- [7] S. Kolhatkar and R. Laganière. Real-time virtual viewpoint generation on the gpu for scene navigation. In *2010 Canadian Conference on Computer and Robot Vision*, pp. 55–62, May 2010.
- [8] J. Weakliam, M. Bertolotto, and D. C. Wilson. Implicit interaction profiling for recommending spatial content. In *Proceedings of the 13th annual ACM international workshop on Geographic information systems*, pp. 285–294, 2005.
- [9] Q. Zhao, L. Wan, W. Feng, J. Zhang, and T. Wong. Cube2video: Navigate between cubic panoramas in real-time. *IEEE Transactions on Multimedia*, Vol. 15, No. 8, pp. 1745–1754, Dec 2013.
- [10] 小林加織里, 北山大輔, 角谷和俊. オンライン地図におけるユーザ操作に基づくストリートビュー自動生成システム. In *DEIM Forum*, 2010.

顧客の非言語情報をフィードバックする 商品推薦エージェントによる推薦モデル

The Model for the PRVAs' Recommendation with Nonverbal Information

松井 哲也*1 本田 秀仁*2 山田 誠二*3*4*5
Tetsuya Matsui Hidehito Honda Seiji Yamada

*1成蹊大学
Seikei University

*2安田女子大学
Yasuda Women's University

*3国立情報学研究所
National Institute of Informatics

*4総合研究大学院大学
SOKENDAI

*5東京工業大学
Tokyo Institute of Technology

本研究では、ウェブ上で商品推薦を行うバーチャルエージェント(商品推薦エージェント, PRVA)による商品推薦効果を向上させるために、顧客の非言語情報の中でも「前傾姿勢」を認識してフィードバックするモデルを提案する。先行研究から、顧客が販売員と対話をしている際に、前傾姿勢を表出することと購買意欲の上昇との間には相関があることが示されている。また、商品推薦エージェントがポジティブな感情や専門知識を表出することにより、顧客の購買意欲を上昇させることができることも示されている。本研究では、これらの先行研究から、顧客の内部状態遷移モデルを提案する。このモデルでは、顧客の前傾姿勢を検出し、それに合わせてポジティブな感情・専門知識を表出することにより、ユーザの購買意欲を上昇させることを提案する。さらに、このモデルを検証するための実験を構想する。

1. はじめに

バーチャルエージェントやロボットなどを用いて、実店舗やウェブ上で顧客に商品を推薦したり、店舗や企業を紹介する試みは広く行われている。ウェブ上のオンラインショップなどで、顧客に商品の推薦を行うバーチャルエージェントを商品推薦エージェント(Product Recommendation Virtual Agent)と呼ぶ[Qiu -09]。このようなエージェントによる推薦の効果(顧客の購買意欲の向上など)を上げるため、エージェントの表情やジェスチャ及び商品に関する専門知識を表出する[松井・山田 17]、エージェントの語尾でパーソナリティを表現する[尹 2018]といった手法が提案されている。本研究では、旅行の推薦シナリオにおける、販売員と顧客とのインタラクションを分析した本田ら[本田 2018]の研究を参考に、顧客の非言語情報の表出を認識して推薦方法を変えることで、商品推薦エージェントの推薦効果を向上させることを目指す。

本田ら[本田 2018]は、着席して販売員の推薦を聞いている際の顧客のジェスチャに着目し、顧客の前傾姿勢の表出と購買意欲の上昇に相関があることを示した。本研究では、前傾姿勢の表出を、顧客が推薦されている商品に関心を示していることを示すサインであると捉え、その表出を認識後に推薦方法を変えることにより、顧客の感じるエージェントへの信頼感および購買意欲を向上させることを試みる。

2. 提案モデル

この実験では、図1のような顧客の内部状態遷移モデルを提案する。顧客の状態はS0とS1の2状態であり、S0は購買意欲が低く、S1は購買意欲が高い状態である。この状態は前傾姿勢の有無によって観測可能であるとする。遷移オペレータを実行することで、S0からS1への遷移を起こすことが本研究の主目的である。

遷移オペレータには、松井・山田[松井・山田 17]の研究により、顧客の購買意欲の向上に効果があることが確認されて

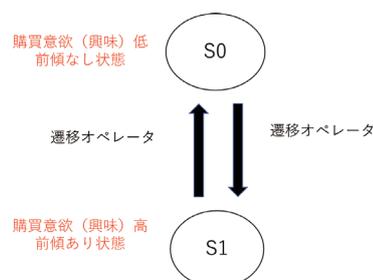


図1: 顧客の内部状態遷移モデル。

いる2種類のオペレータを用いる。1つは「感情遷移オペレータ」であり、これはエージェントの表出するポジティブな表情およびジェスチャにより構成される。もう1つは「知識量遷移オペレータ」であり、これはエージェントの表出する推薦商品についての専門知識により構成される。このモデルの有効性を示すため、以下の実験を行う。

3. 実験計画

本節では、上記のモデルを検証するために想定される実験計画について述べる。実験は、いずれの条件においても以下の共通のフォーマットで行う。商品推薦エージェントは、名古屋工業大学が公開している音声インタラクション対話システムツールキットのMMDAgent*1を用いる。推薦するのは日本国内の城への旅行パックであり、参加者の在住する東京近郊からの距離が近く、世界遺産に登録されていないという基準で10の城を選定した。1つの城の推薦動画の長さは約40秒であり、参加者は10本の動画を続けて見る。動画の一部のスナップショットを図2に示す。動画の提示順は参加者ごとにランダムにする。1つの動画を見終わる毎に、参加者はエージェントへの信頼感と購買意欲を尋ねる質問に答える。信頼感を測定するのは、個人間の信頼感を測定する尺度である interpersonal

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 <http://www.mmdagent.jp/>

solidarity scale(ISS)[Wheless 78]であり、購買意欲については以下の3つの質問を行う。



図 2: 実験動画のスナップショット

- この城への旅行に興味を持ちましたか?
- この城に行ってみたくて思いましたか?
- この城への旅行パックをみたいと思いましたか?

また、推薦動画を見ている際の参加者の姿勢の変化をマイクロソフト社の Kinect for Xbox One で計測し、参加者の前傾姿勢を検出する。このフォーマットに則り、以下の3つの実験を行う

3.1 実験 1

実験 1 では、いずれも遷移オペレータが実行されない 10 の推薦動画を参加者に見せる。

3.2 実験 2

実験 2 では、10 回の動画視聴のうち、1 番目から 5 番目までは遷移オペレータを実行せず、6 番目から 10 番目までの動画で遷移オペレータを実行する。

3.3 実験 3

実験 3 では、10 回の動画視聴のうち、Kinect で前傾姿勢を検出した動画の次の動画から遷移オペレータを実行する。

この3つの実験のうち、どの実験で最も前傾頻度およびエージェントへの信頼・購買意欲が上昇するかを比較する。我々の仮説では、実験 3 において最も購買意欲が上昇すると予想される。

4. 結論

本稿では、これまでの先行研究から、商品推薦エージェントによる推薦効果を上昇させるために、顧客の表出する非言語情報を認識して推薦方法を変える手法を用いたモデルを提案した。さらに、本モデルを検証するための実験計画を提案した。今後は実際に実験を行い、モデルの妥当性を検証したい。

参考文献

- [Qiu -09] Qiu, Lingyun and Benbasat, Izak(2009), Evaluating anthropomorphic product recommendation agents: A social relationship perspective to designing information systems, *Journal of Management Information Systems*, 25-4, pp 145-182
- [Wheless 78] Wheless, Lawrence R(1978), A follow-up study of the relationships among trust, disclosure, and interpersonal solidarity, *Human Communication Research*, 4-2, pp 143-157

[尹 2018] 尹浩, 山本景子, 倉本到, 辻野嘉宏 (2018), パーチャルエージェントに対する好意を用いた Q&A ウェブサイトにおける回答意欲向上効果ヒューマンインタフェース学会論文誌, 20-4, pp 413-416

[本田 2018] 本田秀仁, 松井哲也, 大本義正, 植田一博 (2018), 旅行相談場面の販売員-顧客間のインタラクション: 販売員のスキルの違いに見る心的状態の推定と非言語行動の分析, *電子情報通信学会論文誌 D*, 101-2, pp 275-283

[松井・山田 17] 松井哲也 and 山田誠二 (2017), ユーザの信頼を誘発する商品推薦エージェントデザイン 感情と知識量の遷移による信頼向上, *人工知能学会論文誌*, 32-2, pp.C-G92

学術用語解説ウェブページの良否評定のための 分かり易さ・見易さ因子の分析

Analyzing Factors of Beginner Friendliness / Visual Intelligibility
for Overall Measurement of Web Pages Explaining Academic Concepts

廣花 智遥 *¹ 岡田 心太郎 *¹ 宇津呂 武仁 *² 河田 容英 *³ 神門 典子 *⁴
Chiharu Hirohana Shintaro Okada Takehito Utsuro Yasuhide Kawada Noriko Kando

*¹筑波大学大学院システム情報工学研究科
Grad. Sch. Sys. & Inf. Eng. Univ. of Tsukuba

*²筑波大学システム情報系
Fclty. Eng. Inf. & Sys. Univ. of Tsukuba

*³(株) ログワークス
Logworks Co., Ltd.

*⁴国立情報学研究所
National Institute of Informatics

When we beginners study academic concepts on the Internet, the beginner friendly Web pages are often not shown by the search engine. In order to reduce the burden due to that, it is necessary to quantitatively evaluate “beginner friendliness” as well as “visual intelligibility” in Web pages explaining academic concepts. In this paper, we manually analyze and explore the cause of the lack of “beginner friendliness” as well as “visual intelligibility”. Especially, we focus on the cases where the Web page lacks either “beginner friendliness” or “visual intelligibility”, even though the Web page satisfies other one. Then, we manually analyze factors of the lack of “beginner friendliness”/“visual intelligibility” and report their statistics in detail.

1. はじめに

インターネット, さらにはパソコンやスマートフォンが普及した現在, ウェブ上には数多くのコンテンツが存在する. 平成 29 年度版総務省情報通信白書 *¹ によれば, 各世帯におけるパソコンとスマートフォンの保有率は同程度であり, 特に 13~19 歳の 8 割以上がスマートフォンを所持している. この年代は中学生から大学生に該当しており, 学習の手段としてインターネットを頻繁に利用している. 学術用語を学ぶためのコンテンツも数多く存在するため, 検索エンジンに学術用語を入力するだけで関連ページを見つけることができる. しかし, 検索上位に「分かりやすい」ウェブページが表示されるとは限らず, 一件ずつ閲覧し複数のウェブページを見比べる非効率な作業が必要となる. また, 「見づらい」ウェブページも存在するため, 比較作業を途中で諦める可能性も高い.

この現状に対する取り組みとして, [塩川 19] では, ウェブ閲覧者にとって見易く, 分かり易く, かつ, 役に立つページであるために充足すべき因子を深層学習によって機械的に特定し, 「解説型ウェブページ」の分かり易さと見易さを自動評定する仕組みを提案している. ただし, 「機械的に特定」するため, その基準が人間による直観にどの程度一致しているかを慎重に吟味することが必要となる. そこで本論文では, [塩川 19] において深層学習のための教師用事例として蓄積された学術用語解説ウェブページを対象として, 人手によって評定された学術用語解説ウェブページの「分かり易さ」・「見易さ」の詳細な因子についての分析を行う. 本論文では, 特に, 「分かり易さ」と「見易さ」のうち, 「分かり易さ」のみが充足され, 「見易さ」が充足されない場合, および, 逆に, 「見易さ」のみが充足され, 「分かり易さ」が充足されない場合に焦点を当て, それぞれ「見易さ」あるいは「分かり易さ」を損なう因子群を網羅的に分析した結果を報告する.

2. 参照学術用語ウェブページ集合の作成

2.1 対象学術分野および用語

本論文では, 文章の分かり易さ, レイアウトの見易さ, 全体評定の三つにおける評定基準が類似していると考えられる理工学術分野を対象とする. 具体的には, 統計, 線形代数, 物理, 化学, IT, プログラミング, 生物の 7 分野を対象とする. また, 各分野における学術用語の内, 主に高校 3 年生または大学レベルの学術用語 15 語 (表 2) を評価対象とする.

2.2 データセット作成手順

前節で対象とする各学術用語を検索クエリとし, ウェブ検索の検索結果上位 10 件の用語解説ウェブページを収集する. その際, 検索結果リンク先のウェブページにアクセスできない場合, 検索結果が pdf ファイルである場合, および, 複数の学術分野に横断して検索される計 5 サイト (Wikipedia *², コトバンク *³, Weblio *⁴, Yahoo!知恵袋 *⁵, goo 辞書 *⁶) は除外対象とする. 除外された分については, 検索順位 10 位より下位のページから順に補充する. 以上のウェブページ収集結果に対して, 次節の評定基準に基づき, 分かり易さ, 見易さ, および, 全体評定の各評定を行った結果を付与する.

2.3 用語解説ウェブページの手評定基準

本節では, 各々の用語解説ウェブページに対して, 人手で分かり易さ, 見易さ, および, 全体の評定を行う際の評定基準 (表 1) について述べる. 分かり易さ, および, 見易さの評定基準においては, 絶対条件と優先付け項目の二つを区別して設け, 絶対条件を満たした上で複数の優先付け項目を満たす場合に, 当該評定を満たすと評定する.

さらに, 分かり易さ, および, 見易さ両方の評定結果に基づき, ウェブページ全体の評定を行う. ここで, 特に, 分かり易さ, あるいは, 見易さのいずれかの評定のみが充足され, もう一方が充足されない場合でも, 充足されない方において,

連絡先: 廣花 智遥, 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

*¹ <http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h29/html/nc111110.html>

*² <https://ja.wikipedia.org/>

*³ <https://kotobank.jp/>

*⁴ <https://ejje.webl.io.jp/>

*⁵ <https://chiebukuro.yahoo.co.jp/>

*⁶ <https://dictionary.goo.ne.jp>

表 1: 用語解説ウェブページの分かり易さ・見易さの評定基準

(a) 分かり易さの基準

絶対条件	a	用語の定義がある	対象の学術用語に関する定義がウェブページ内に含まれている。
優先付け項目	b	文章の文字数・単語数・専門用語数	ウェブページ内に含まれる文章の、文字数・単語数・専門用語数が極端に多すぎず少なすぎない。
	c	文の長さ	ウェブページ内に含まれる1文の長さが、極端に長すぎず短すぎない。
	d	例がある	対象の学術用語に関する例題がウェブページ内に含まれている。
	e	関連用語がある	対象の学術用語に関連する用語がウェブページ内に含まれている。

(b) 見易さの基準

絶対条件	f	文字と図の比率	表や図に対し、文字が極端に多すぎず少なすぎない。
優先付け項目	g	色	黒色や原色など、文章を読む際に読みづらいと感じるような背景色を使用していない。
	h	コントラスト	白色の背景に黄色の文字等、文章を読む際に読みづらいと感じるような配色をしていない。
	i	図がある	用語解説や例示のために使用されている図が1つ以上含まれている。
	j	代表的な数式がある	一般的に数式と呼べるものを含んでいる。アルファベット1文字などは対象としない。
	k	文章と数式の比率	文に対して極端に数式が多くないかどうか。
	l	字の大きさ	文章を読む際に読みづらいと感じるほど、字が小さくない。

表 2: 学術分野ごとの対象学術用語および評定一覧

分野	対象とする学術用語 (全 15 語の用語)	評定						計
		全体		分かり易さ		見易さ		
		×	○	×	○	×	○	
統計	事後確率, 事前分布, 正規分布, F 分布, 信頼区間, 標準偏差, 主成分分析, 回帰分析, 自己回帰モデル, ポアソン分布, マルコフ連鎖モンテカルロ法, 確率密度関数, コーシー分布, 分散, パレート分析	54	96	48	102	56	94	150
線形代数	階数, 共役勾配, 行列式, クラメル公式, クロネッカーのデルタ, 三角行列, 正規直交基底, 対角化, 直交行列, 特性多項式, 二次形式, ノルム, メネラウスの定理, ヤコビ行列, 内積	99	51	88	62	88	62	150
物理	電気力線, 張力, 慣性の法則, 遠心力, 電波, 電流, 万有引力, 交流, 音波, ホイットストンブリッジ, 反発係数, 相互誘導, 正電荷, 速度, 変圧器	101	49	90	60	98	52	150
化学	イオン結合, エステル, カルボン酸, ケトン, 化学反応式, 化学平衡, 共有結合, 合成高分子, 酸化還元, 遷移元素, 典型元素, 天然高分子, 燃料電池, 物質の三態, 有機化合物	92	58	85	65	87	63	150
プログラミング	C 言語, Java, エスケープシーケンス, コマンドライン引数, スコープ, フィールド値, ポインタ, メソッド, 繰り返し処理, 構造体, 算術演算子, 条件分岐, 配列変数, 文字列, 論理演算	86	64	79	71	92	58	150
IT	API, DBMS, HTML, IP アドレス, JDBC, RDB, SDK, SQL, Unicode, URL, スコープ管理, ステークホルダー管理, タイム管理, ナレッジ管理, リスク管理	76	74	75	75	49	101	150
生物	DNA, ショウジョウバエ, 原核生物, 減数分裂, 光合成, 細胞, 葉緑体, ミトコンドリア, 遺伝子, タンパク質, マクロファージ, RNA, ヘモグロビン, ナトリウムポンプ, コケ植物	112	38	98	52	71	79	150
計	—	620	430	563	487	541	509	1,050

表 3: 「全体」・「分かり易さ」・「見易さ」の評定の組み合わせの統計

全体	評定		分野							計
	分かり易さ	見易さ	統計	線形代数	物理	化学	プログラミング	IT	生物	
×	×	×	34	57	57	55	53	33	60	349 (33.2%)
		○	10	29	32	30	26	40	36	203 (19.3%)
	○	×	10	12	12	6	6	2	7	55 (5.2%)
		○	0	1	0	1	1	1	9	13 (1.2%)
○	×	×	0	0	0	0	0	0	0	0 (0%)
		○	4	2	1	0	0	2	2	11 (1.0%)
	○	×	12	19	29	26	33	14	4	137 (13.0%)
		○	80	30	19	32	31	58	32	282 (26.9%)
計			150	150	150	150	150	150	150	1,050 (100%)

表 1(a), あるいは, 表 1(b) に示す優先付け項目のうちの一部を充足する場合には, 全体評価結果が「良」と評価されている事例が多く観測される。

2.4 データセット

作成されたデータセットにおける「全体評価」, 「分かり易さ」, 「見易さ」, の各々における良否評価分布を表 2 に示す。表 2 においては, 各学術分野における対象学術用語 (各 15 語) もあわせて示す。

3. 評価結果における見づらさ・分かりづらさ因子群の分析

3.1 評価結果の分析

表 2 において, 「全体評価」, 「分かり易さ」, 「見易さ」各々の良否二値評価結果の組み合わせ全 8 通りの分布を表 3 に示す。「分かり易さ」, 「見易さ」とともに「否」評価を覆し, 「全体評価」を「良」評価とする事例は 0 件であることから, 2.3 節の基準のうちの全体評価の基準が反映されていることが確認できる。「分かり易さ」, 「見易さ」とも「否」評価の場合は「全体評価」も「否」評価となり, 逆に, 「分かり易さ」, 「見易さ」とも「良」評価の場合は「全体評価」も「良」評価となる傾向にある。また, 「分かり易さ」が「否」評価, 「見易さ」が「良」評価の場合は「全体評価」は「否」評価 19.3%, 「良」評価 1.0% であり, 圧倒的に「否」評価となる傾向にある。逆に, 「分かり易さ」が「良」評価, 「見易さ」が「否」評価の場合は「全体評価」は「否」評価 5.2%, 「良」評価 13.0% と混在しており, 「分かり易さ」「良」評価の影響の方が強い傾向にある。

3.2 見づらさ因子群の分析

本節では, 表 3 中で「分かり易さ」が「良」評価, 「見易さ」が「否」評価の場合に「全体評価」が「否」評価となる 55 事例 (5.2%) に着目し, 表 4 に示す「見づらさの因子」19 個の分布を図 1 に示す。図 1 においては, 当該因子が「見づらさ」の原因となる主な項目である場合, 逆に, 「見づらさ」の原因としては補助的項目である場合を区別して示す。

この結果から, 因子「色コントラスト」および因子「項目間空行幅」の順に該当ページ数が多い。また, 因子「色コントラスト」においては, 補助的項目となる事例はなく, 全事例において「見づらさ」の原因となる主な項目となっている。一方, 「二段組」や「リンク過多」等は観測数が最下位相当である。

3.3 分かりづらさ因子群の分析

本節では, 表 3 中で「分かり易さ」が「否」評価, 「見易さ」が「良」評価の場合に「全体評価」が「否」評価となる 203 事例 (19.3%) のうちの 55 件に着目し, 表 5 に示す「分かりづらさの因子」12 個の分布を図 2 に示す。図 2 においては, 当該因子が「分かりづらさ」の原因となる主な項目である場合, 逆に, 「分かりづらさ」の原因としては補助的項目である場合を区別して示す。この結果から, 因子「用語解説なし」および因子「解説なしの関連用語多用」の順に該当ページ数が多い。

4. 関連研究

本論文に関連して, [春日 18, Han18] においては, 用語解説ウェブページの見易さ・分かり易さの判定を行うにあたって, 特に, HTML 構造に着目した素性を用いることにより, 見易さ・分かり易さを自動判定する手法を提案している。また, [岡田 19] においては, 「見易さ」自動判定のための深層学習を導入するとともに, その判定理由を可視化している。この可視化結

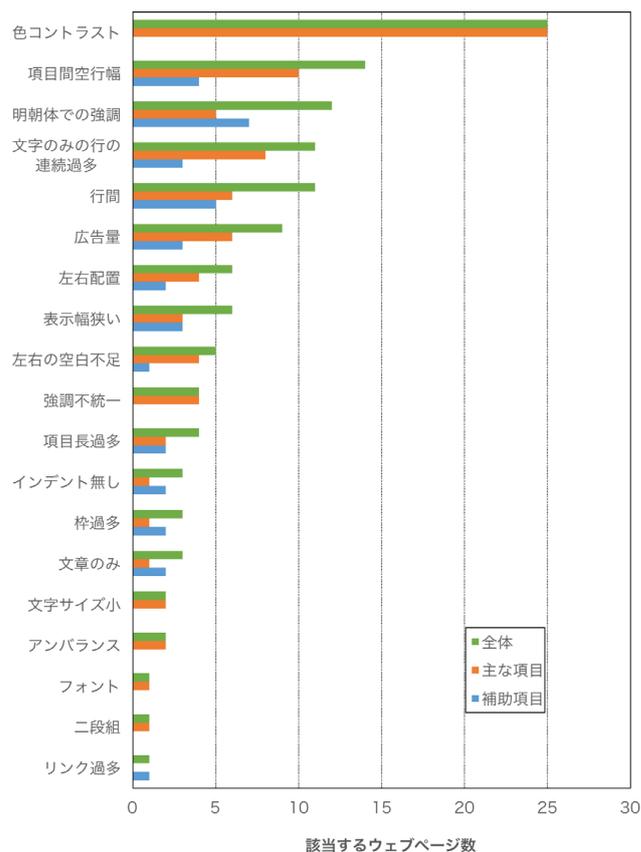


図 1: 用語解説ウェブページの見づらさの因子群の分布 (「全体評価×, 分かり易さ○, 見易さ×」である 55 例)

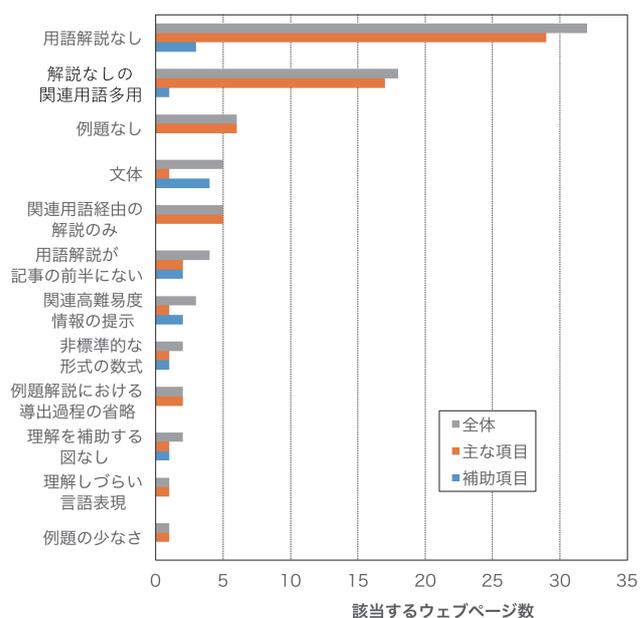


図 2: 用語解説ウェブページの分かりづらさの因子群の分布 (「全体評価×, 分かり易さ×, 見易さ○」である 55 例)

表 4: 用語解説ウェブページの見づらさの原因となる因子

	見づらさの因子	詳細
1	色コントラスト	背景色と文字色のバランスが悪い。蛍光的または刺激の強い色の枠・文字を利用。必要以上の色遣い。
2	項目間空行幅	現項目終了位置と次項目開始位置間の空行幅が不適切。
3	明朝体での強調	明朝体で強調を行なっている。
4	文字のみの行の連続過多	行数が多い、または、空行で区切られた(複数の)段落連続数が多い。
5	行間	区切り線や文章の間の行間が広い、または、狭い。
6	広告量	1ページ中に複数の広告が存在するなど、広告が多い。
7	左右配置	通例的に、横書きは左から読む。しかし、重要な内容が右に、そうでないものが左に書かれている。
8	表示幅狭い	ブラウザウィンドウに対して、ウェブページの表示幅が狭い。
9	左右の空白不足	コンテンツがブラウザウィンドウの端に寄り過ぎてている。
10	強調不統一	強調の仕方(太字、マーカーなど)が同一ページ内に複数ある。
11	項目長過多	1項目が長く、題目間の行数が多すぎる。
12	インデント無し	インデントが無く、どこからどこまでがどのコンテンツ(文章、図、数式、箇条書きなど)かが不明瞭。
13	枠過多	必要以上に枠を利用している。
14	文章のみ	文章以外のコンテンツ(一目で認識でき、明白に文字でないと判断できるもの)が無い。
15	文字サイズ小	文字サイズが小さい。
16	アンバランス	タイトルなど、内容として重要でないものの存在感が過度に大きい。
17	フォント	フォントの線の太さを使い分けておらず、一目では題目と内容の区別が困難。
18	二段組	二段組になっている。
19	リンク過多	多数のリンクが連続的に列挙されている。

表 5: 用語解説ウェブページの分かりづらさの原因となる因子

	分かりづらさの因子	詳細
1	用語解説なし	用語の応用先の紹介やプログラム実装のみなどに留まっており、用語解説が全くされていない。
2	解説なしの関連用語多用	専門的な関連用語や式が、何の説明もなく頻出。
3	例題なし	数値例を用いた具体的な例題の描写がない。
4	文体	文体が論文調で堅い。
5	関連用語経由の解説のみ	関連用語を介した解説のみであり、関連用語を用いない直接的解説が無い。
6	用語解説が記事の前半にない	用語解説箇所が記事の後半にある。
7	関連高難易度情報の提示	用語に関連する高難易度な内容も記述。
8	非標準的な形式の数式	数式の表現形式が非標準的な形式である。
9	例題解説における導出過程の省略	例題の解説において導出過程が省略されている。
10	理解を補助する図なし	文章による解説の理解を補助する図がない。
11	理解しづらい言語表現	解説部分に理解困難な言語表現を含む。
12	例題の少なさ	例題が少なさが原因で、理解が妨げられる。

果と本論文の分析結果を照らし合わせることによって、より重要性の高い属性を重視し、自動評価精度の改善が期待できる。一方、[小林05,Krug16]においては、分かり易く見やすいウェブサイトの作成方針について、詳細な考え方が述べられている。

5. おわりに

本論文では、学術用語解説ウェブページに対して、「文章の分かり易さ」および「ウェブページの見易さ」の観点から人手評価を行い、データセットを作成した。本論文では、特に、「分かり易さ」と「見易さ」のうち、いずれか片方のみが充足され、もう片方が充足されない場合に焦点を当て、「見易さ」および「分かり易さ」を損なう因子群を網羅的に分析した。そして、それらの因子群のうち、「色のコントラスト」の因子が見づらさに、「用語解説なし」および「解説なしの関連用語多用」の因子が分かりづらさに、それぞれ、大きな影響を与えていることを示した。本論文の分析をふまえ、今後は表3における各良否組(全8通りのうち、事例数0および「全体」「分かり易さ」「見易さ」全て○を除く残り4通り)を対象として、「分かり易さ」、あるいは、「見易さ」を妨げる因子の分析を行う必要がある。

参考文献

- [Han18] Han, B., Shiokawa, H., Kawaguchi, K., Utsuro, T. and Kawada, Y.: Measuring Beginner Friendliness of Chinese Web Pages explaining Academic Concepts using HTML Structures, 第32回人工知能学会全国大会論文集(2018).
- [春日18] 春日孝秀, 塩川隼人, 韓炳材, 宇津呂武仁, 河田容英: HTML構造上の特徴を利用した学術用語解説ウェブページの分かり易さの自動評価, 第10回 DEIM フォーラム論文集(2018).
- [小林05] 小林隆, 榎原直樹, 関根千佳, 遊間和子: 市民にやさしい自治体ウェブサイト: 構築から運用まで, NTT出版株式会社(2005).
- [Krug16] Krug, S.: 超明快 Web ユーザビリティ: ユーザに「考えさせない」デザインの法則, 株式会社ピー・エヌ・エヌ新社(2016).
- [岡田19] 岡田心太郎, 塩川隼人, 韓炳材, 廣花智遥, 宇津呂武仁, 河田容英: 深層学習による学術用語解説ウェブページの見易さ自動評価結果の理由提示, 第11回 DEIM フォーラム論文集(2019).
- [塩川19] 塩川隼人, 岡田心太郎, 韓炳材, 廣花智遥, 宇津呂武仁, 河田容英: 深層学習を用いた学術用語解説ウェブページの分かり易さ・見易さの自動評価, 第11回 DEIM フォーラム論文集(2019).

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

[103-J-12] Human interface, education aid: education and evaluation

Chair:Masato Soga Reviewer:Megumi Kurayama

Tue. Jun 4, 2019 3:20 PM - 4:20 PM Room O (Front-left room of 1F Exhibition hall)

[103-J-12-01] Hidden Markov IRT model as a generalization of Bayesian Knowledge Tracing

○Emiko Tsutsumi¹, Shuhei Shionoya¹, Masaki Uto¹, Maomi Ueno¹ (1. The University of Electro-Communications)

3:20 PM - 3:40 PM

[103-J-12-02] A test theory based on deep learning: Deep Response Model

○Ryo Kinoshita¹, Maomi Ueno¹ (1. The University of electro-Communication)

3:40 PM - 4:00 PM

[103-J-12-03] Personalized Feedback in Case-Method Study

○Kenta Sasaki¹, Kenichi Suzuki¹, Kentaro Inui² (1. Graduate School of Management, GLOBIS University, 2. Tohoku University)

4:00 PM - 4:20 PM

Bayesian Knowledge Tracingの一般化としての隠れマルコフIRTモデル

Hidden Markov IRT model as a generalization of Bayesian Knowledge Tracing

堤瑛美子*¹ 塩野谷周平*¹ 宇都雅輝*¹ 植野真臣*¹
Emiko Tsutsumi Shuuhei Shionoya Masaki Uto Maomi Ueno

*¹電気通信大学大学院情報理工学研究所

Graduate school of Informatics and Engineering, The University of Electro-Communications

To develop learner's ability, a teacher should grasp the learner's knowledge state accurately in a learning process. For this purpose, Bayesian Knowledge Tracing (BKT) has been proposed to infer learner's knowledge state. Although conventional BKT models learner's knowledge state as a discrete value, the learner's knowledge state must be contentious. Based on this idea, we propose a Hidden Markov IRT model as a generalization of Bayesian Knowledge Tracing. In the proposed model, learner's knowledge state takes a continuous value and change according to a Hidden Markov process in a learning process. The proposed model estimates the optimal value of the degree of learner's mastering knowledge from learning data. From some numerical experiments, we demonstrate that the proposed model improves the estimation accuracy of the learner's knowledge state.

1. はじめに

近年、コンピュータやタブレット端末の普及に伴ってeラーニング・システムを用いた学習が広まり、大量の学習データが容易に入手できるようになった。教育の現場では、学習者の発達を促すために個々の特性や理解度を把握することが課題となっている。

これまで、学習者の学習への理解度は教師の経験によって評価されていたが、過去の学習者の学習データを利用することにより、機械学習を用いた評価が可能となってきた。近年、学習過程の学習者の理解度やある知識の習得状態を推定する手法として Bayesian Knowledge Tracing (BKT) が多くの研究者によって開発されてきた [Corbett 95, MacHardy 15, David 16]。BKT は学習者が知識を理解しているか、していないかを二値で判断し、知識への理解度を確率値で表すことができる数理モデルである。Corbett ら [Corbett 95] の BKT モデルでは、学習者が知識を習得していない状態から習得した状態へ変化する際の遷移確率パラメータを持つ。しかし、遷移確率は学習者全体で共通であり、学習者ごとに最適化されていない。そこで、Yudelson ら [Yudelson 13] は学習者ごとに知識の習得度を把握するため、知識の習得状態を個人パラメータとした BKT モデルを開発している。さらに Pelánek ら [Pelánek 18] は、通常二値で表される知識の習得状態を多値で表し、習得度を表す確率がロジスティック関数に従う LogisticHMM モデルを用いることで、学習者の知識の習得度をより高精度に把握する手法を提案している。

しかし、Pelánek らの BKT モデルは、Yudelson ら [Yudelson 13] で考慮されていた知識の遷移確率パラメータの個人化が適応されておらず、学習過程での課題ごとの特性が反映されていないため、学習者の習得度の適切な評価ができない可能性がある。

また、BKT モデルでは知識の習得状態が二値または多値で表されるが、実際には知識の習得状態は連続値である。そのため、知識の習得状態を段階的に表現することで習得状態の正確な評価をすることは難しい。堤ら [堤 19] は学習過程におい

て、学習者の知識の習得状態が時系列に変化する隠れマルコフIRT (HM-IRT) モデルを開発している。IRT モデルでは、学習者の習得度が個人化されており、課題ごとの特性も考慮されているため、堤ら [堤 19] のモデルは BKT における知識の習得状態を連続値として一般化したモデルとして考えることができる。

本研究では学習者の知識の習得度の推定精度向上のために以下の2つのモデルを提案する。

1. Yudelson ら [Yudelson 13] の LogisticHMM モデルにおいて、学習者ごとに知識の習得状態の遷移確率を最適化し、さらに学習過程での課題ごとの特性を反映させた新たな BKT モデル。
2. Bayesian Knowledge Tracing の一般化としての Hidden Markov IRT モデルの提案。

提案モデルと従来の BKT を用いて、学習データから学習者の知識の習得度を推定し、推定精度の比較を行う。

2. Bayesian Knowledge Tracing

Bayesian Knowledge Tracing (BKT) [Corbett 95] は学習過程での学習者の知識の習得状態が隠れマルコフ過程に従うと仮定した数理モデルであり、学習履歴データから学習者が課題解決に必要な知識の習得度を確率で表すことができる。本章では、BKT について説明する。

はじめに、BKT で用いられる変数とパラメータについて説明する。学習者数を J 、課題数を I とするとき、学習者 j の課題 i に対する知識の習得状態 Z_{ji} を以下で表す。

$$Z_{ji} = \begin{cases} 1: & \text{学習者が課題 } i \text{ で必要な知識を習得している} \\ 0: & \text{学習者が課題 } i \text{ で必要な知識を習得していない} \end{cases}$$

また、学習者 j の課題 i に対する反応データ X_{ji} を以下で表す。

$$X_{ji} = \begin{cases} 1: & \text{学習者が課題 } i \text{ に正答} \\ 0: & \text{学習者が課題 } i \text{ に誤答} \end{cases}$$

以降本論文では、知識の習得状態を Z_{ji} 、学習者の反応データを X_{ji} とする。さらに、知識の習得状態の遷移確率パラメータとして、

$p(L_0)$: 学習者が事前に知識を習得している確率、

$p(T)$: 知識を習得していない状態から習得する確率、

$p(S)$: 知識を習得している状態で課題に誤答する確率、

$p(G)$: 知識を習得していない状態で課題に正答する確率

の4つのパラメータをもつ。ここで、知識の習得状態について、 $Z_{j,i-1} = 1$ から $Z_{j,i-1} = 0$ への遷移は起こらないものとする。BKTでは、学習者が課題 i において、ある知識を習得する確率を $p(Z_{ji} = 1) = p(L_{ji})$ とすると、 $p(L_{ji})$ は式 (1),(2) を用いて式 (3) のように表せる。

$$p(L_{ji}|X_{ji} = 1) = \frac{p(L_{ji})(1 - p(S))}{(1 - p(L_{ji}))p(G) + p(L_{ji})(1 - p(S))} \quad (1)$$

$$p(L_{ji}|X_{ji} = 0) = \frac{p(L_{ji})p(S)}{(1 - p(L_{ji}))(1 - p(G)) + p(L_{ji})p(S)} \quad (2)$$

$$p(L_{ji}) = p(L_{j,i-1}|X_{j,i-1}) + (1 - p(L_{j,i-1}|X_{j,i-1}))p(T) \quad (3)$$

ただし、 $p(L_{j1}) = p(L_0)$ とする。学習者 j が課題 i に正答する確率を次式で求める。

$$p(X_{ji} = 1) = p(L_{ji})(1 - p(S)) + (1 - p(L_{ji}))p(G) \quad (4)$$

3. 個人パラメータを導入した BKT モデル

BKT[Corbett 95]では、学習者のある知識の習得度を求めることができるが、パラメータが学習者ごとに最適化されていないために、知識の習得度の推定精度が悪いという問題点がある。この問題を解決するために、Yudelso ら [Yudelso 13] は初期確率 $p(L_0)$ と遷移確率 $p(T)$ の2つパラメータを学習者ごとに最適化した BKT モデルを開発した。この研究によって遷移確率 $p(T)$ のみを学習者ごとに最適化したパラメータとすることで推定精度が向上することが示された。この手法では、学習者 j が課題 i で知識を習得する確率 $p(L_{ji})$ を次式で求める。

$$p(L_{ji}) = p(L_{j,i-1}|X_{j,i-1}) + (1 - p(L_{j,i-1}|X_{j,i-1}))p(T)_j \quad (5)$$

4. LogisticHMM

Corbett, Yudelso ら [Corbett 95, Yudelso 13] の BKT モデルは、知識の習得状態が二値であったために、学習者の知識の習得度を正確に評価できていない可能性があった。そこで、Pelánek ら [Pelánek 18] は、学習者の知識の習得度をより高精度に把握するために、知識の習得状態 Z_{ji} を多値に変更し、予測正答確率がロジスティック関数に従うモデルを開発した。さらに、Pelánek らの BKT モデルでは、学習者

と課題の相関を表す識別力や学習全体の難易度をパラメータとして組み込んでおり、課題の特性を考慮した推定が可能となっている。LogisticHMMでは、学習者 j の知識の習得状態が $s \in \{1, \dots, S\}$ であるとき、課題 i に正答する確率を以下で表す。

$$p(X_{ji} = 1|Z_{j,i} = s) = \frac{1}{1 + \exp(-a(s/(S-1) - b))} \quad (6)$$

ここで、 S は学習者の知識状態数、 a は識別力パラメータ、 b は難易度パラメータを表す。識別力パラメータと難易度パラメータはすべての課題において共通の値を用いる。LogisticHMMでは、知識の習得状態が $Z_{j,i-1} = s-1$ から $Z_{ji} = s$ に遷移する確率を l とし、二段階以上の遷移は起こらないものとする。このとき、学習者 j が課題 i で状態 $Z_{ji} = s$ となる確率は、式 (7), (8) を用いて式 (9) のように求められる。

$$p(Z_{ji} = s|X_{ji} = 1) = \frac{p(X_{ji} = 1|Z_{ji} = s)p(Z_{ji} = s)}{\sum_{s'=0}^{S-1} p(X_{ji} = 1|Z_{ji} = s')p(Z_{ji} = s')} \quad (7)$$

$$p(Z_{ji} = s|X_{ji} = 0) = \frac{p(X_{ji} = 0|Z_{ji} = s)p(Z_{ji} = s)}{\sum_{s'=0}^{S-1} p(X_{ji} = 0|Z_{ji} = s')p(Z_{ji} = s')} \quad (8)$$

$$p(Z_{ji} = s) = \sum_{s'=1}^S p(Z_{j,i} = s|Z_{j,i-1} = s') \cdot p(Z_{j,i-1} = s') \quad (9)$$

また、学習者 i が課題 j に正答する確率を以下で表す。

$$p(X_{ji} = 1) = \sum_{s'=1}^S p(X_{ji} = 1|Z_{ji} = s')p(Z_{ji} = s') \quad (10)$$

この手法により、学習者の知識の習得度の推定精度が向上したことが示された。

5. 提案モデル

5.1 パラメータを学習者・課題ごとに最適化した LogisticHMM

Pelánek らの BKT モデルは、知識の遷移確率パラメータの個人化が適応されておらず、学習過程での課題ごとの特性が反映されていないため、学習者の習得度の適切な評価ができていない可能性がある。そのため、本研究では、学習者ごとに知識の習得状態の遷移確率を最適化し、学習過程での課題ごとの特性を反映させた新たな BKT モデルを提案する。

提案モデルでは、知識状態が s である学習者 j が課題 i に正答する確率を次式で表す。

$$p(X_{ji} = 1|Z_{ji} = s) = \frac{1}{1 + \exp(-a_i(s/(S-1) - b_i))} \quad (11)$$

ここで、 S は学習者の知識状態数、 a_i は課題 i の識別力パラメータ、 b_i は課題 i の難易度パラメータを表す。さらに、知識の習得状態が $Z_{j,i-1} = s-1$ から $Z_{ji} = s$ に遷移する確率を l_j とし、学習者ごとに最適値を推定する。本論文では、パラメータを学習者・課題ごとに最適化した LogisticHMM を提案モデル 1 とする。

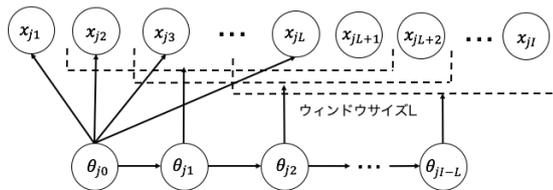


図 1: HM-IRT モデル

5.2 Bayesian Knowledge Tracing の一般化としての HM-IRT モデル

BKT モデルでは知識の習得状態が二値または多値で表されるが、実際には知識の習得状態は連続値である。そのため、知識の習得状態を段階的に表現することで正確な習得状態の評価をすることは難しい。堤ら [堤 19] は学習過程において、学習者の知識状態が時系列に変化する隠れマルコフ IRT (HM-IRT) モデルを開発している。本研究では、堤ら [堤 19] を BKT における知識の習得状態を連続値として一般化したモデルとして提案する。知識の習得状態を連続値とすることで、学習過程に対してより柔軟なモデルとなり、学習者の知識状態の推定精度の向上が期待される。HM-IRT では学習者の知識の習得状態 Z_{ji} を連続値とし、学習過程 (課題) が進むごとに、ある時点 t での学習者の知識の習得状態 Z_{jt} が直前の Z_{jt-1} に依存して確率的に変化していくモデルである。このとき、知識の習得状態 Z_{jt} の変動幅 δ をパラメータとして設定することで、 Z_{jt} の変動を制御することができる。

時点 t において学習者 j が課題 i に正答する確率を次式で表す。

$$p(X_{ji} = 1 | Z_{jt}) = \frac{1}{1 + \exp(-a_i(Z_{jt} - b_i))} \quad (12)$$

a_i は課題 i の識別力パラメータ、 b_i は課題 i の難易度パラメータを表す。ただし、

$$Z_{jt} \sim N(Z_{jt-1}, \delta), \quad Z_{j0} \sim N(0, 1) \quad (13)$$

ここで、 $N(\mu, \sigma)$ は平均 μ 、標準偏差 σ の正規分布を表す。

本研究で用いる HM-IRT のグラフィカルモデルを図 1 に示す。HM-IRT ではある時点での知識状態が継続する課題数として、ウィンドウサイズ L をパラメータとして用いている。ウィンドウサイズ L と知識の習得状態の変動幅 δ は学習データに最適な値を推定するため、様々な学習過程を表現することができる。

HM-IRT に類似したモデルとして、知識の習得状態が時系列変化する IRT モデルが複数開発されている。本論文では、通常の IRT [Lord 68] と、Martin [Martin 02] や Wang [Wang 13] で開発された知識状態の時系列変化を組み込んだ IRT モデルでも習得度の推定精度の比較を行う。

6. パラメータ推定

パラメータ推定には、MCMC の手法のうち、ブロック化ギブス・サンプリング法とメトロポリスヘイスティングス法を組み合わせた手法 [Uto 16] を用いた。紙幅の都合上、詳細は割愛する。

7. 評価実験

7.1 実験データ

実験データには、プログラミング初学者の大学生 75 人を対象にしたプログラミング学習におけるトレース問題 18 課題についての学習データを用いる [堤 19]。学習者は「変数の四則演算」「条件分岐 while ループ」「for ループ」「配列」「関数・メソッド呼び出し」の文法について各領域を学習した後、対応するトレース問題に回答している。ただし、「変数の四則演算」「条件分岐 while ループ」「for ループ」は各 4 題、「配列」「関数・メソッド呼び出し」では各 3 題が出題される。

7.2 学習者の知識の習得度についての推定精度

評価実験では、[Corbett 95][Yudelson 13][Pelánek 18] の BKT モデル、2 つの提案モデル、提案モデルに類似した IRT モデル [Ueno 17][Martin 02][Wang 13] を用いて、以下の手順で課題ごとの学習者の知識の習得度を推定し、課題への正答確率を求める。

- (1) 各モデルで求める学習者 j の課題 i での予測正答確率を P_{ji} とするとき、学習者の予測反応データ \hat{X}_{ji} を以下のように求める。

$$\hat{X}_{ji} = \begin{cases} 1, & P_{ji} \geq 0.5 \\ 0, & P_{ji} < 0.5 \end{cases}$$

- (2) 課題 2 以降について、学習者 j の課題 i における実際の学習データ X_{ji} と推定した学習者の反応データ \hat{X}_{ji} を用いて、すべての学習者、課題での一致率 c を次式で求める。

$$c = \frac{1}{J(I-1)} \sum_{i=2}^I \sum_{j=1}^J \psi(\hat{X}_{ji}, X_{ji}) \quad (14)$$

ここで、 $\psi(\hat{x}_{ji}, x_{ji})$ は \hat{X}_{ji} と X_{ji} が一致するときに 1、そうでないときに 0 をとる関数とする。

LogisticHMM と提案モデル 1 については、学習者の知識状態数 S を $S \in \{2, \dots, 9\}$ のそれぞれの場合で (1),(2) の実験を行い、どちらも $S = 2$ としたモデルが最も推定精度が高い結果となった。以降では LogisticHMM と提案モデル 1 の知識状態数は $S = 2$ とする。

また、HM-IRT について、ウィンドウサイズ $L \in \{1, 2, \dots, 17\}$ と知識の習得状態 Z_{jt} の変動幅 $\delta \in \{0.1, 0.3, 0.5, 0.7, 1.0\}$ の組み合わせを変え、それぞれのモデルで (1),(2) の実験を行ったところ、ウィンドウサイズを $L = 1$ 、変動幅を $\delta = 0.7$ にした場合が最も推定精度が高くなることがわかった。以降では HM-IRT を $L = 1, \delta = 0.7$ としたモデルとする。

表 1 に各モデルで推定した学習者の反応データの推定精度 c を示す。

表 1: 学習者の知識の習得度 推定精度 c

モデル	Corbett	Yudelson	Pelánek	提案モデル 1
予測精度	69.9%	71.4%	70.0%	68.5%
モデル	lord	Martin	Wang	HM-IRT
予測精度	72.0%	68.7%	69.8%	78.5%

表 1 より, 堤ら [堤 19] の HM-IRT モデルが最も推定精度が高くなることがわかった. HM-IRT は知識の習得状態が連続値であり, 習得状態の遷移幅をデータから最適化することができるため, より正確な知識の習得度を推定することができたと考えられる. 一方, 状態数 $S = 2$ の提案モデル 1 は, 他の BKT モデルに比べて推定精度が低い結果となった. 知識の習得度をロジスティック関数従わせる制約が本研究で用いた学習データに適応しなかったために, 推定精度が低くなったと考えられる. 提案モデル 1 が適応可能な学習過程を判断するためには, 学習データを変更して実験を行う必要がある.

8. むすび

本研究では, 学習過程で学習者の知識の習得度を推定する新たな手法として, LogisticHMM に個人パラメータと課題パラメータを拡張した手法と, BKT の一般化としての堤ら [堤 19] の HM-IRT モデルを提案した. 従来の BKT や IRT の手法を用いて, 学習者の知識の習得度の推定精度を比較したところ, HM-IRT モデルが最も推定精度が高くなることがわかった. HM-IRT モデルが BKT の知識状態を連続値とした一般化モデルとして有効であることを示した.

参考文献

- [Baker 04] Baker,B,F, and Kim,S.: Item Response Theory: Parameter Estimation Techniques, Second Edition, NY: Marcel Dekker, Inc,2004(2004)
- [Corbett 95] A.T. Corbett and J.R. Anderson, "Knowledge tracing: Modeling the acquisition of procedural knowledge," User Modeling and User-Adapted Interaction, vol. 4, no. 4, pp. 253-278(1995)
- [David 16] David,B,Y.Sega,A and Gal,Y.:Sequencing Educational Content in Classrooms using Bayesian Knowledge Tracing,the Sixth International Conference,(2016)
- [Lord 68] Lord,F and Novick,M.:Statistical theories of mental test scores, Addison-Wesley, (1968)
- [MacHardy 15] MacHardy,Z.:EECS Department University of California, Berkeley Technical Report,No. UCB/EECS-2015-98, May 14, (2015)
- [Martin 02] Martin,D,A and Quinn,Kevin.:Dynamic Ideal Point Estimation via Markov Chain Monte Carlo for the U.S.Supreme Court,1953-1999, Political Analysis,Volume 10, Issue 2,pp.134-153(2002)
- [Pelánek 18] Pelánek,R.:Conceptual Issues in Mastery Criteria: Differentiating Uncertainty and Degrees of Knowledge. Artificial Intelligence in Education,pp. 450-461 (2018).
- [Ueno 17] Ueno,M and Miyazawa,Y.:IRT-based adaptive hints to scaffold learning in programming, IEEE Transactions on Learning Technologies, Vol.14, No.8(2017)
- [Uto 16] Uto,M and Ueno.M:Item Response Theory for Peer Assessment, IEEE Transactions on Learning Technologies,Vol.9,No.2,pp.157-170(2016)
- [Wang 13] Wang Xiaojing, Berger,O,James and Burdick,Donald.:Bayesian analysis of dynamic item response models in educational testing,The Annals of Applied Statistics 2013, Vol. 7, No. 1, 126-153(2013)
- [Yudelso 13] Yudelso.M, Koedinger.K, G.J. Gordon, "Individualized Bayesian Knowledge Tracing Models," Artificial Intelligence in Education 2013, Springer, pp. 171-180,(2013)
- [堤 19] 堤 瑛美子, 宇都雅輝, 植野真臣:ダイナミックアセスメントのための隠れマルコフ IRT モデル, 電子情報通信学会論文誌 Vol.J102-D, No.2, pp.79-92, (2019)

深層学習によるテスト理論：Deep Response Model

A test theory based on deep learning: Deep Response Model

木下涼 植野真臣
Ryo Kinoshita Maomi Ueno

電気通信大学情報理工学研究所

Graduate school of Informatics and Engineering, The University of Electro-Communications.

In this article, Deep Response Model(DRM), a novel deep neural networks model for estimating student characteristic parameters and predicting student's response patterns is proposed. It consists of two independent neural networks, Student Layer and Item Layer, combines their outputs and predict student's response. Then, values of the last student layer are considered as student parameters. It can estimate student parameters and predict their responses with high accuracy even when it is difficult to calibrate item parameters.

1. まえがき

近年、Web上でテストを実施するeテストが注目されている。eテストには、適応型テストのような動的テストを実現できるなど、様々な利点があるため、様々なテスト場面において、その導入が進んでいる。

一般的に、eテストの運用では、項目反応理論(IRT)[Lord 68]をもとに、難易度や識別力などの項目パラメータが既知のテスト項目を、アイテムバンクと呼ばれるデータベースに蓄積する必要がある。eテストでは、このアイテムバンクが極めて重要な役割を果たす。

しかし、項目パラメータは、その受験者集団によって尺度が異なるため、アイテムバンクを作成する際には、全ての項目パラメータを同一尺度上に揃える等化が必要となる[Lord 80]。等化を行う際には、各テストの実施前に、受験者あるいはテスト項目の一部が共通するようにテストの設計を行うなどの等化計画を行う必要があり、eテスト導入の妨げとなっている。

また、近年、タブレット教育が学校現場などに取り入れられており、大量の学習データを獲得することが可能となっている。しかし、これらの学習データは非常にスパースであることが多く、既存の手法では、学習支援に活用することが難しい。

一方で、近年の深層学習技術の発展に伴い、教育データ解析において、深層学習の応用が盛んに行われており、高い精度が報告されている[Piech 15]。

これらを踏まえて、本研究では、綿密な等化計画を行っていない場合でも、高精度に能力パラメータを推定し、受験者の反応予測が可能な深層学習モデルであるDeep Response Model(DRM)を提案する。特に適応型テストや学習支援では、学習者の能力推定・解答予測を動的に行う必要があり、高精度に解答を予測する技術が重要であるため、提案手法が活用できる可能性が高い。

提案手法では、受験者とテスト項目を独立したニューラルネットワークの入力とし、それぞれの出力を組み合わせることで受験者の反応を予測する。本研究では、受験者を入力とするニューラルネットワークの最終層の値を能力パラメータとみなす。

提案モデルでは、反応パターンの予測誤差が小さくなるよう

に、一度に共通する重みを更新するため、IRTと異なり、受験者間・テスト項目間に依存関係があることが大きな特徴である。

シミュレーション実験により、提案手法は、等化計画が十分でない場合に、高精度に能力パラメータを推定し、受験者の反応を予測可能であることを示す。

2. 項目反応理論

本章では、まずはじめに、一般的にアイテムバンクの作成に用いられる項目反応理論とその等化手法について述べる。項目反応理論は、様々な評価場面で実用化が進められている数理モデルを用いたテスト理論の一つである[Lord 68]。

一般に項目反応理論は、正誤判定問題や多肢選択式問題など、データが正誤の2値となる反応データに適用されることが一般的である。このような2値データに適用できる項目反応モデルとして、2パラメータロジスティックモデル(2PLM)が古くから広く利用されてきた。

2.1 等化

IRTによって推定されるパラメータは、学習者集団ごとに尺度が異なるため、異なる集団のパラメータを比較する際には、パラメータを同一尺度上に変換する等化処理が必要となる。

IRTに基づいて等化を行う際には、テストを実施する前に、次の等化計画のいずれかを行う必要がある。1) 複数のテストを受験する受験者をテストに含める共通受験者計画。2) 複数のテストに共通するテスト項目を含める共通項目計画。3) 係留テストと呼ばれる共通項目群を用意し、係留テストと各尺度に共通受験者を用意する係留テスト計画。

テスト実施後、得られた反応パターンから、各パラメータを同一尺度上に変換していく。その際に用いられる手法として、等化係数推定法[Loyd 80]、同時尺度推定法[Bock 97]、固定項目パラメータ法などが知られている。

IRTを用いた等化では、パラメータを特定の集団やテスト項目に依存することなく推定できるが、実施には綿密な等化計画と莫大なコストが必要になることが多い。

3. 提案手法

本章では、提案手法について詳しく述べる。提案手法の概要図を図1に示す。提案手法では、受験者 $i \in \{1, \dots, I\}$ の項目 $j \in \{1, \dots, J\}$ に対する反応パターン $u_{ij} \in \{0, \dots, C\}$ を、以下のように予測する。

なお、提案手法は多値反応のテストデータに用いることもできるが、本研究では2値のテストデータを想定する。従って、

連絡先: 木下涼, 電気通信大学情報理工学研究所, The University of Electro-Communications, 1-5-1 Chofugaoka, Chofu-shi, 182-8585, Japan, kinoshita@ai.is.uec.ac.jp

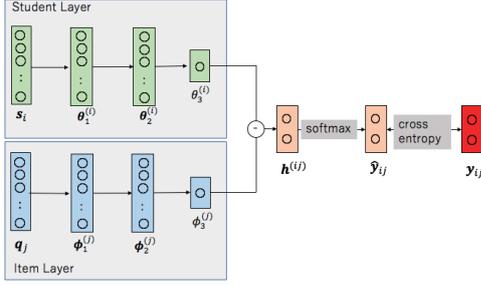


図 1: 提案手法

u_{ij} は、受験者 i が項目 j に正答の場合 1, 誤答の場合 0 をとる。

3.1 モデル定義

提案手法では、受験者の能力パラメータと項目パラメータを分離するため、受験者層 (Student Layer) と項目層 (Item Layer) の二つの独立したニューラルネットワークを組み合わせる。

受験者層では、 i 番目の要素のみが 1, 他の要素が 0 の one-hot vector である受験者ベクトル $\mathbf{s}_i \in \mathbb{R}^I$ を入力として、次のように 3 層のニューラルネットワークを計算する。

$$\theta_1^{(i)} = \tanh(\mathbf{W}^{(\theta_1)} \mathbf{s}_i + \mathbf{b}^{(\theta_1)}) \quad (1)$$

$$\theta_2^{(i)} = \tanh(\mathbf{W}^{(\theta_2)} \theta_1^{(i)} + \mathbf{b}^{(\theta_2)}) \quad (2)$$

$$\theta_3^{(i)} = \mathbf{W}^{(\theta_3)} \theta_2^{(i)} + b^{(\theta_3)} \quad (3)$$

ここで、受験者 i の隠れ層ベクトル $\theta_1^{(i)}, \theta_2^{(i)}$ の次元数は任意の値に設定することができる。

さらに、活性化関数として、以下のハイパボリックタンジエント関数を用いている。

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (4)$$

$\mathbf{W}^{(\theta_1)}, \mathbf{W}^{(\theta_2)}$ は以下のような重みパラメータ行列である。

$$\mathbf{W}^{(\theta_1)} = \begin{pmatrix} w_{11}^{(\theta_1)} & w_{12}^{(\theta_1)} & \cdots & w_{1I}^{(\theta_1)} \\ w_{21}^{(\theta_1)} & w_{22}^{(\theta_1)} & \cdots & w_{2I}^{(\theta_1)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{|\theta_1|1}^{(\theta_1)} & w_{|\theta_1|2}^{(\theta_1)} & \cdots & w_{|\theta_1|I}^{(\theta_1)} \end{pmatrix}$$

$$\mathbf{W}^{(\theta_2)} = \begin{pmatrix} w_{11}^{(\theta_2)} & w_{12}^{(\theta_2)} & \cdots & w_{1|\theta_1|}^{(\theta_2)} \\ w_{21}^{(\theta_2)} & w_{22}^{(\theta_2)} & \cdots & w_{2|\theta_1|}^{(\theta_2)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{|\theta_2|1}^{(\theta_2)} & w_{|\theta_2|2}^{(\theta_2)} & \cdots & w_{|\theta_2||\theta_1|}^{(\theta_2)} \end{pmatrix}$$

また、 $\mathbf{W}^{(\theta_3)} = (w_1^{(\theta_3)}, w_2^{(\theta_3)}, \dots, w_{|\theta_2|}^{(\theta_3)})$ は重みパラメータベクトルである。

$\mathbf{b}^{(\theta_1)} = (b_1^{(\theta_1)}, b_2^{(\theta_1)} \dots b_{|\theta_1|}^{(\theta_1)})$, $\mathbf{b}^{(\theta_2)} = (b_1^{(\theta_2)}, b_2^{(\theta_2)} \dots b_{|\theta_2|}^{(\theta_2)})$ はバイアスパラメータベクトル, $b^{(\theta_3)}$ はバイアスパラメータスカラーである。これらのパラメータは全て、反応パターンから学習される。

本研究では、受験者層の最後の隠れ層である $\theta_3^{(i)}$ を受験者 i の能力パラメータとみなす。

同様に、項目層では、 j 番目の要素のみが 1, 他の要素は 0 の one-hot vector である項目ベクトル $\mathbf{q}_j \in \mathbb{R}^J$ を入力として、次のように 3 層のニューラルネットワークを計算する。

$$\phi_1^{(j)} = \tanh(\mathbf{W}^{(\phi_1)} \mathbf{q}_j + \mathbf{b}^{(\phi_1)}) \quad (5)$$

$$\phi_2^{(j)} = \tanh(\mathbf{W}^{(\phi_2)} \phi_1^{(j)} + \mathbf{b}^{(\phi_2)}) \quad (6)$$

$$\phi_3^{(j)} = \mathbf{W}^{(\phi_3)} \phi_2^{(j)} + b^{(\phi_3)} \quad (7)$$

ここで、項目 j の隠れ層ベクトル $\phi_1^{(j)}, \phi_2^{(j)}$ の次元数は任意の値に設定することができる。

$\mathbf{W}^{(\phi_1)}, \mathbf{W}^{(\phi_2)}$ は、以下のような重みパラメータ行列である。

$$\mathbf{W}^{(\phi_1)} = \begin{pmatrix} w_{11}^{(\phi_1)} & w_{12}^{(\phi_1)} & \cdots & w_{1J}^{(\phi_1)} \\ w_{21}^{(\phi_1)} & w_{22}^{(\phi_1)} & \cdots & w_{2J}^{(\phi_1)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{|\phi_1|1}^{(\phi_1)} & w_{|\phi_1|2}^{(\phi_1)} & \cdots & w_{|\phi_1|J}^{(\phi_1)} \end{pmatrix}$$

$$\mathbf{W}^{(\phi_2)} = \begin{pmatrix} w_{11}^{(\phi_2)} & w_{12}^{(\phi_2)} & \cdots & w_{1|\phi_1|}^{(\phi_2)} \\ w_{21}^{(\phi_2)} & w_{22}^{(\phi_2)} & \cdots & w_{2|\phi_1|}^{(\phi_2)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{|\phi_2|1}^{(\phi_2)} & w_{|\phi_2|2}^{(\phi_2)} & \cdots & w_{|\phi_2||\phi_1|}^{(\phi_2)} \end{pmatrix}$$

また、 $\mathbf{W}^{(\phi_3)} = (w_1^{(\phi_3)}, w_2^{(\phi_3)}, \dots, w_{|\phi_2|}^{(\phi_3)})$ は、重みパラメータベクトルである。

$\mathbf{b}^{(\phi_1)} = (b_1^{(\phi_1)}, b_2^{(\phi_1)} \dots b_{|\phi_1|}^{(\phi_1)})$, $\mathbf{b}^{(\phi_2)} = (b_1^{(\phi_2)}, b_2^{(\phi_2)} \dots b_{|\phi_2|}^{(\phi_2)})$ はバイアスパラメータベクトル, $b^{(\phi_3)}$ はバイアスパラメータスカラーである。これらのパラメータは全て、反応パターンから学習される。

本研究では、項目層の最後の隠れ層である $\phi_3^{(j)}$ を項目 j の項目パラメータとみなす。

その後、受験者パラメータと項目パラメータの差を用いて、反応パターンの予測を行う。具体的には、以下のように、反応パターン u_{ij} に対する反応確率 $\hat{y}_{i,j} = (\hat{y}_{i,j}^{(0)}, \hat{y}_{i,j}^{(1)})$ を算出し、モデルの出力とする。

$$\mathbf{h}^{(i,j)} = (\mathbf{W}^{(y)})^T (\theta_3^{(i)} - \phi_3^{(j)}) + \mathbf{b}^{(y)} = (h_0^{(i,j)}, h_1^{(i,j)}) \quad (8)$$

$$\hat{y}_{i,j}^{(c)} = \text{softmax}(\mathbf{h}^{(i,j)}) = \frac{\exp(h_c^{(i,j)})}{\sum_c \exp(h_c^{(i,j)})} \quad (9)$$

ここで、 $\mathbf{W}^{(y)} = (w_1^{(y)}, w_2^{(y)})$, $\mathbf{b}^{(y)} = (b_1^{(y)}, b_2^{(y)})$ は、それぞれ重みパラメータベクトル, バイアスパラメータベクトルであり、反応パターンから学習される。

3.2 パラメータ学習

本節では、各パラメータの学習方法について述べる。提案手法では、反応確率 $\hat{\mathbf{y}}$ と真の反応である \mathbf{y} から、以下の分類誤差を表すクロスエントロピー Loss を算出し、損失関数とする。

$$\text{Loss} = - \sum_i \sum_j \sum_{c \in (0,1)} \mathbf{y}_{i,j}^{(c)} \log \hat{\mathbf{y}}_{i,j}^{(c)} \quad (10)$$

ここで、 $\mathbf{y}_{i,j}^{(c)}$ は、 $u_{ij} = c$ のとき 1, そうでないとき 0 をとる。

提案手法は、全ての反応パターンをもとに、Adam と呼ばれる最適化アルゴリズムに従って、損失関数が小さくなるよう、全てのパラメータを更新する。

4. 評価実験

本章では、シミュレーション実験と実データ実験で提案手法の有効性を示す。

本実験では、提案手法の実装にニューラルネットワークのフレームワークの一つである Chainer*1 を用いて、バッチ学習でパラメータを更新した。各隠れ層のノード数は 5, エポック数は 300 に固定した。また、 $\epsilon, \beta_1, \beta_2$ には、先行研究 [Kingma 14] で提案されている値を用いた。

一方、IRT のモデルには 2PLM を用いた。IRT のパラメータ推定は、マルコフ連鎖モンテカルロ法を用いた期待事後確率

*1 <https://chainer.org/>

推定法で行ない、等化には同時尺度推定法を用い、すべてのパラメータを同時に推定した。また、それぞれのパラメータの事前分布には次の分布を用いた。

$$\theta \sim N(0, 1), \quad \log a \sim N(0, 1), \quad b \sim N(1, 0.4) \quad (11)$$

ここで、 $N(\mu, \sigma)$ は平均 μ 、標準偏差 σ の正規分布を表している。

4.1 シミュレーションデータによる精度評価

等化に関する研究では、実データを収集するのに多大なコストを要することから、現実に近い条件のもと、シミュレーションにより評価を行うことが一般的である。したがって、本節では、シミュレーションデータをもとに、提案手法と IRT の等化精度を比較する。

等化精度の評価方法は様々であるが、ここでは、推定した能力パラメータと真の能力パラメータとの平均平方二乗誤差 (RMSE)、Pearson の積率相関係数と Kendall の順位相関係数について示す。ただし、RMSE を求める際には、推定したパラメータと真のパラメータを平均 0、分散 1 の分布に標準化して算出する。

4.1.1 シミュレーションデータの生成

本実験では、 J 個の項目で構成された K 個のテストを、それぞれ I 人からなる受験者集団が解答した状況を想定する。ここでは、 k 番目のテストが、 $k-1$ 番目、 $k+1$ 番目のテストとのみ共通項目を持つようにシミュレーションデータを生成する。

シミュレーションデータの生成は以下の分布に従ってパラメータを発生させ、2 PLM に従って行う。

$$\theta \sim N(0, 1), \quad \log a \sim N(0, 1), \quad b \sim N(1, 0.4) \quad (12)$$

具体的には、能力パラメータと項目パラメータを次の手法のいずれかを用いて受験者・項目に割り振る。

ランダム割り当て

式 (12) に従って、受験者数または項目数だけパラメータを発生させ、受験者または項目に無作為に割り振る。

システム割り当て

1) 式 (12) に従って、受験者数または項目数だけパラメータを発生させる。

2) 発生させたパラメータを昇順に並び替え、受験者集団数あるいはテスト数にパラメータを等分割する。

3) k 番目の受験者集団あるいはテストに、 k 番目のパラメータ分割内からパラメータを割り振る。

4.1.2 受験者の偏りとテスト受験者数による等化精度

本節では、受験者の偏りと受験者数による等化精度の変化を報告する。ここでは、受験者パラメータをシステム割り振りした場合を、受験者に偏りがある条件、ランダム割り振りした場合を受験者に偏りが無い条件とした。

本実験では、50 項目からなる 10 個のテストをそれぞれ異なる受験者が受験する状況を想定して、シミュレーションデータを発生させる。なお、識別力パラメータと困難度パラメータはランダム割り当てし、テスト間の共通項目数は 5 項目に固定した。

ここで、提案手法と IRT の等化精度を比較した結果を表 1 に示す。

表 1 より、受験者に偏りが無い場合、受験者数に関わらず、提案手法よりも IRT の精度が高いことがわかる。これは、全てのパラメータをランダム割り当てした場合、常にパラメータは等化されているとみなせるため、特別な等化処理が不要であることが原因であると考えられる。

一方で、受験者に偏りが存在する場合、いずれの受験者数で

も、提案手法の精度が IRT を大きく上回る結果となった。特に、受験者数が増えると IRT では精度が急激に低下するのに対し、提案手法では精度の差が見られなかった。

したがって、受験者集団間に能力の偏りがある状況下で、IRT は各テストの受験者数に大きく影響を受けるのに対し、提案手法は受験者数の変化に頑健な手法であることが示唆された。

等質な受験者集団を用意するには莫大なコストがかかることが多く、等化計画を行っていない場合、受験者集団間に能力の偏りがあることが一般的なため、提案手法の傾向は望ましいといえる。

4.1.3 テスト項目数による等化精度

本節では、各テストを構成する項目数を変化させた際の等化精度を比較する。ここでは、テスト間の共通項目が 5 項目である 10 個のテストをそれぞれ異なる 100 人が受験する状況を仮定して、シミュレーションデータを発生させる。また、能力パラメータのみをシステム割り当てし、項目パラメータはランダムに割り当てた。

ここで、各テストを構成する項目数を変化させて提案手法と IRT の等化精度を比較した結果を表 2 に示す。

表 2 より、各テストを構成する項目数が 10 から 50 の場合に、提案手法は IRT と比較して精度が高いことがわかる。一方で、項目数が 100 以上になると IRT の精度が上回ることが明らかとなった。従って、提案手法はテスト項目数が比較的小さい場合に有効な手法であることが示唆された。

実際のテストでは、受験者を考慮して、数百問程度の項目を解かせることは稀なため、提案手法の性質は好ましい。

4.1.4 共通項目数による等化精度

本節では、各テスト間の共通問題数を変化させた際の等化精度を比較する。ここでも、50 項目からなる 10 個のテストをそれぞれ異なる 100 人が受験する状況を仮定して、シミュレーションデータを発生させる。また、能力パラメータのみをシステム割り当てし、項目パラメータはランダムに割り当てた。

ここで、共通項目数を変化させて提案手法と IRT の等化精度を比較した結果を表 3 に示す。

表 3 より、共通項目数が多い場合は、IRT の方が精度が高いことがわかる。一方で、共通項目が 30 以下になると、提案手法がどの等化精度指標でも、IRT を大きく上回っている。従って、提案手法では、共通項目数が少ない状況下で、能力パラメータを高精度で推定できることが明らかになった。また、共通項目数が全くない場合でも、高精度であることが示された。

実際のテストで、数十問を共通項目とすることは、現実的ではないことが多いため、共通項目が少なくても影響の小さい提案手法は有効であるといえる。

4.2 実データ実験

本節では、実データを用いて、提案手法の有効性を示す。具体的には、未知の反応パターンの予測精度を検証する。

実データには、[Ueno 04] が開発した学習管理システム "Samurai" を用いて行ったテストデータ (Samurai) と、批判的思考を主題として行われたテストデータ (CT) を使用する。

Samurai データは、受験者数 169、項目数 50 からなり、欠損値がなく単一の学習者集団から得られたテストデータであるのに対し、CT データは、受験者数 1221、項目数 179 からなり、欠損が多く、等化処理が必要であることが特徴である。

4.2.1 欠損割合による予測精度の変化

次に、実データを用いて、欠損値の反応予測精度を検証する。ここでは、各受験者から得られた反応パターンから、特定の割合の反応パターンをランダムで欠損値とした反応パター

表 1: 能力パラメータの偏りとテスト受験者数による等化精度

θ	受験者数	手法	RMSE	Pearson	Kendall
50		DRM	0.317	0.950	0.882
		IRT	0.251	0.969	0.895
	100	DRM	0.312	0.953	0.882
		IRT	0.243	0.970	0.896
ランダム	150	DRM	0.270	0.964	0.890
		IRT	0.245	0.970	0.895
	200	DRM	0.294	0.957	0.891
		IRT	0.246	0.970	0.898
500	DRM	0.288	0.959	0.894	
	IRT	0.232	0.973	0.901	

表 2: テスト項目数による等化精度

項目数	手法	RMSE	Pearson	Kendall
10	DRM	0.622	0.807	0.629
	IRT	0.779	0.696	0.466
30	DRM	0.501	0.875	0.716
	IRT	0.573	0.836	0.672
50	DRM	0.411	0.916	0.785
	IRT	0.559	0.844	0.661
100	DRM	0.376	0.929	0.810
	IRT	0.325	0.947	0.827
150	DRM	0.305	0.953	0.866
	IRT	0.263	0.965	0.857

表 3: 共通項目数による等化精度

共通項目数	手法	RMSE	Pearson	Kendall
50	DRM	0.255	0.964	0.893
	IRT	0.237	0.972	0.900
40	DRM	0.248	0.969	0.89
	IRT	0.254	0.968	0.886
30	DRM	0.394	0.922	0.787
	IRT	0.360	0.935	0.805
20	DRM	0.389	0.924	0.803
	IRT	0.534	0.856	0.676
10	DRM	0.409	0.917	0.790
	IRT	0.534	0.857	0.677
5	DRM	0.411	0.916	0.785
	IRT	0.559	0.844	0.661
0	DRM	0.408	0.916	0.786
	IRT	0.612	0.812	0.532

ン行列からモデルを学習する。その後、学習したパラメータをもとに、欠損値とした項目の反応予測を行い、その正解率を提案手法と IRT で比較した。この手続きをそれぞれのデータセット、条件に対してずつ 10 回繰り返したときの平均正解率を、表 4 に示す。

ここで、各データセットと欠損割合の条件において、提案手法と IRT の予測精度に差があることを確かめるためにウィルコクソンの符号順位検定を行なった。

表 4 より、Samurai データでは、大部分を欠損値にしたとしても両者の精度に有意な差が見られないことがわかった。これは、単一の受験者集団から得られたデータであり、欠損値を多くしても等化が不要な状況であるため、IRT を用いても十分に精度が高いことが原因と考えられる。

一方で、CT データでは、多くの条件下で提案手法の方が予測精度が有意に高いことが明らかとなった。ただし、欠損をあまりに多くした場合、提案手法でも適切に予測ができないことが示された。

従って、提案手法は、複数の受験者集団が存在する欠損値の多いデータにおいて、反応の予測確率が高いことが示唆された。実際のアイテムバンクにおいて、単一の受験者集団のみが存在する状況は考えにくく、提案手法が有効な場面は多いと考えられる。

5. むすび

本研究では、深層学習を用いて、等化計画が十分でないときでも、高精度に能力パラメータの推定が可能なモデルである

表 4: 欠損値の予測精度

欠損割合	Samurai			
	DRM	IRT	DRM	IRT
1%	77.16%	76.92%	68.39%*	67.66%
10%	77.53%**	78.01%	70.01%**	69.30%
20%	77.48%	77.83%	68.72%**	68.34%
90%	71.71%	71.45%	59.89%	63.28%

* $p < .05$, ** $p < .01$

Deep Response Model を提案した。

具体的には、受験者と項目を独立したニューラルネットワークの入力とし、それぞれの出力を組み合わせることで反応パターンを予測する深層学習モデルを学習し、受験者を入力としたニューラルネットワークの出力を能力パラメータとみなした。

シミュレーション・実データ実験により、提案手法には以下の利点が存在することが明らかとなった。

- 1) 各受験者集団が等質でない場合でも、高精度に能力パラメータの推定が可能である。
- 2) 各テストの受験者数が増減しても、能力パラメータの推定精度への影響が小さい。
- 3) テスト項目数が少ない場合に、高精度に能力パラメータの推定が可能である。
- 4) 共通受験者・共通問題のいずれも存在しない場合でも高精度に能力パラメータの推定が可能である。
- 5) 複数の受験者集団が存在し、欠損値が多いデータにおいて、IRT よりも反応パターンの予測精度が高い。

提案手法は、多段階反応データや時系列解答データ、多次元データへの適応が容易であるため、モデルの拡張を行う。

参考文献

- [Bock 97] Bock, R. D. and Zimowski, M. F.: Multiple Group IRT, pp. 433–448, Springer New York, New York, NY (1997)
- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, arXiv:1412.6980 (2014)
- [Lord 68] Lord, F. and Novick, M.: Statistical Theories of Mental Test Scores, Addison-Wesley (1968)
- [Lord 80] Lord, F.: Applications of item response theory to practical testing problems, L. Erlbaum Associates Hillsdale, N.J (1980)
- [Loyd 80] Loyd, B. H. and Hoover, H. D.: Vertical Equating Using the Rasch Model, Journal of Educational Measurement, Vol. 17, No. 3, pp. 179–193 (1980)
- [Piech 15] Piech, C., Bassen, J., Huang, J., Ganguli, S., Sahami, M., Guibas, L. J., and Sohl-Dickstein, J.: Deep Knowledge Tracing, in Cortes, C., Lawrence, N. D., Lee, D. D., Sugiyama, M., and Garnett, R. eds., Advances in Neural Information Processing Systems 28, pp. 505–513, Curran Associates, Inc. (2015)
- [Ueno 04] Ueno, M.: Animated agent to maintain learner's attention in e-learning, in Nall, J. and Robson, R. eds., Proceedings of E-Learn: World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education 2004, pp. 194–201, Washington, DC, USA (2004), Association for the Advancement of Computing in Education (AACE)

ケースメソッド教育におけるフィードバックの個別化

Personalized Feedback in Case-Method Study

佐々木 健太*¹
Kenta Sasaki

鈴木 健一*¹
Kenichi Suzuki

乾 健太郎*²
Kentaro Inui

*¹ グロービス経営大学院
Graduate School of Management, Globis University

*² 東北大学
Tohoku University

The long-term goal of our research is to create a case method learning without teachers. To achieve this goal, we found that personalized feedback was effective for students in a preliminary experiment. Then, we investigated the possibility of evaluating description problem answers by machine learning. As a result, our study showed that we could score them automatically on high-accuracy utilizing LSTM with attention. The accuracy would become higher utilizing posterior probability in the network, and we found that the visualization of attention was quite moderate. Moreover, we examined the number of answers to keep the accuracy high.

1. はじめに

社会人教育, その中でも特に経営学の分野では, ケースメソッドと呼ばれる教育手法が使われることが多い [Barnes 94]. ケースメソッドとは, 実際の企業で起こった事例を題材(ケース)とし, 自分が経営者であればその事例にどのように対処するのかを受講者全員で議論するという教育手法である. 講師は自説を述べたり講義したりせずに, 議論の進行の舵を取るだけである. 与えられた題材に対して受講者が深く思考しつつ他者の考えを聞くことで, 抽象化概念力や学習意欲などの非認知能力の向上に繋がると言われている [高木 01] [佐野 13]. 一方, ケースメソッドは議論をリード・整理できる講師が必須であるため, 労働集約型, 且つ, 講師のスキルに依存するところが大きい. そのため, ケースメソッドを講師不要の形式でデジタルプラットフォーム上に実現できれば, 多くの受講者に機会を提供できるなどそのメリットは計り知れない.

本研究では, 講師を必要としないケースメソッドの実現を中長期的な目的とした中で, オンライン上で出題した問題に対する記述式回答の自動評価の可能性を調査する. もしそれが可能であれば, 図 1 に示すようにデジタルプラットフォーム上で受講生それぞれの回答に応じたフィードバックを返すことができ, ケースメソッドの受講者同士の議論の一部を擬似的に実現できるかもしれない. そして, これを実現するためには,

- 記述式問題回答の自動評価ロジックの開発
 - 回答に応じたフィードバックコンテンツの作成
- が少なくとも必要になる. 本研究では, 予備調査として回答に応じたフィードバックが受講者の満足度や有益度の向上に寄与するのかを確認した上で, 前者の記述式問題回答の自動評価ロジックの開発の可能性について述べる. 評価は, 特定の採点基準を満たすかどうかを判断することとした.

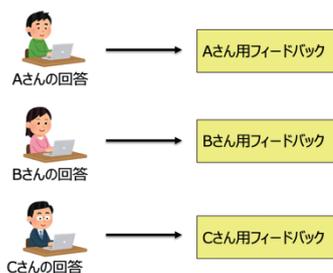


図 1 回答に応じたフィードバックの表示

2. 先行研究

先行研究には, 明確な採点基準がない長文の回答の自動採点と, 明確な採点基準がある短文の回答の自動採点の大きく 2 種類に分けられる.

前者は, エッセイの自動採点を目的とした研究で, テキスト分類の技術やテキストの複雑さを表現する特徴量などを使って, エッセイの書きぶりの良し悪しを評価するというものである [Valenti 03]. このアルゴリズムを搭載した E-rater や ETS I などのシステムは, 実際の教育現場で幅広く活用されている.

後者は, 書きぶりの良し悪しを評価するのではなく, 回答の内容を評価しようとする研究が多い [Burrows 15]. 例えば, [水本 18] らは大学入試模擬試験の 50~70 文字程度の記述式問題回答の自動採点アルゴリズムを提案した. 一つの問題に対して複数の採点項目(基準)があるので, 教師データとして少数の項目毎の点数と多数の全体点数を用意する. そして, アテンション付き LSTM を利用して, 項目毎の点数と全体点数を予測する. 結果, 問題の項目によっては RMSE (Root Mean Squared Error) が 0.1 未満となっており, 記述式問題回答の自動採点の可能性を示唆した. 本研究では, [水本 18] らと同じアテンション付き LSTM を利用し, 記述式問題回答を自動採点する.

3. データセット

教室の中で受講生同士が議論するケースメソッドはデータがデジタル化されていないため, データの作成・収集から始める必要がある. 通常のケースメソッドで使用するケースは分量が多く, ケースを読むだけでも少なくとも 30 分程度は掛かる. これをそのままパソコンやスマートフォンで読むとなると, 多くのユーザが途中で離脱する恐れがある. そのため, ケースを読んで問題に回答するまでが 30 分以内に完結するように, 通常のケースを短くした上で問題を作り直した. 作成したケース文(抜粋)と自動採点の対象とした問題, および, それぞれの問題の採点基準と回答例を載せた. ケース文の文字数は全部で 999 字あり, 5 分程度で読める分量である. 問題 1 と問題 2 ともに採点基準は 2 つ存在する. 本研究では, ライアンエアー以外にも経営戦略のケース文と問題も使用したが, 誌面の都合上ここでは詳細を取り上げない. 本研究に利用した, 各問題の採点基準毎の正解, 不正解の回答数と文字数を表 1 に載せた. クラウドサービスを利用し, ライアンエアーは問題 1, 問題 2 ともに 209 件, 経営戦

略は 156 件の回答を収集した。そして、回答がそれぞれの採点基準を満たすのかどうか 2 人で採点した。2 人の採点結果が異なる場合、別の 1 人が正解、不正解を判断した。表 2 を見て分かるように、回答が正解と不正解のどちらか一方に大きく偏っていることはなく、回答に応じてフィードバックを換えることに意味があると考えられる。

ケース文(ライアンエアー)

ライアンエアーは 1985 年に創業した。当初は低価格とフラッグキャリア並みのサービスを提供し、創業から 5 年で年間乗客数が 5,000 人から 64 万人へと急拡大したが、同時に、高コスト経営から 2,000 万ポンドの赤字を計上し、破綻寸前と報道された。経営方針の見直しを余儀なくされた 1990 年、現在も CEO(最高経営責任者)を務めるマイケル・オレアリーが経営陣に参画した。格安運賃とローコスト経営で躍進していた米国のサウスウエスト航空をモデルに、欧州初の格安航空会社としてライアンエアーは再出発した。

オレアリーが打ち出したホリデー客をターゲットとする戦略は成功した。1991 年からの湾岸戦争で業績が一時低迷したものの、1997 年以降は、地盤であったアイルランドやイギリスだけでなく、欧州各国へ次々と路線を拡大し、乗客数、営業利益ともに現在まで成長を続けている。

(中略)

米国同時多発テロ事件の直後は航空需要自体が大きく減退したものの、路線が欧州内に限られているライアンエアーへの影響は限定的であり、欧州内の旅行ぐらいいはしたい、というレジャー客を取り込むことができた。さらに、飛行機を利用せざるを得ないビジネス客も、大規模空港でのセキュリティの煩雑さを避け、より狙われにくいと思われる小空港で発着する格安航空会社を選ぶようになった。

問題 1

まず、「ホリデー客」とはどんな人たちで、普段はどんな交通手段を利用していかを考えてください。(50 文字程度)

問題 2

では、そうした「ホリデー客」をターゲットにすることで、なぜライアンエアーは、大手航空会社がひしめく航空業界でも事業成功のチャンスがあると考えたのでしょうか？(50 文字程度)

問題 1 の採点基準

1. 「低価格重視」に言及していること
2. 「普段はバスや電車などを利用」に言及していること

問題 2 の採点基準

1. 「顧客ターゲットの変更」に言及していること
2. 「競合との競争を避けたこと」に言及していること

回答例 A(問題 1) 採点基準1:○, 採点基準2:○

若者や家族連れなどの旅費を安くあげたい客で、普段はバスや電車を利用して来た。

回答例 B(問題 1) 採点基準1:×, 採点基準2:○

ホリデー客とは、休暇にまとまった期間旅行を計画する客で、普段は自動車やバスなどの交通機関を使っている。

回答例 C(問題 2) 採点基準1:○, 採点基準2:×

普段は航空機を使わない層を掘り起こすことで新規の需要を開拓できたため。

回答例 D(問題 2) 採点基準1:×, 採点基準2:×

顧客は料金が低価格であれば、ある程度サービスなどの質を下げて利用すると考えたため。

表 1 各問題の採点基準毎の正解、不正解の回答数と文字数

			回答数		文字数 (中央値)
			正	誤	
ライアン エアー	問題 1	基準 1	80	129	33
		基準 2	166	43	
	問題 2	基準 1	116	93	38
		基準 2	63	146	
経営戦略	問題 1	基準 1	76	80	51

4. 予備調査

回答に応じたフィードバックの有効性を確認するため、クラウドサービスを利用して予備調査を行った。まず、前章で述べたライアンエアーのデータセットに対し、特定のキーワードの出現有無(例:問題 1/採点基準 1 は「低価格」「安く」「安い」)だけで回答がそれぞれの採点基準を満たしているのかどうかを判定した。6.1 節の表 3 で述べるが、特定のキーワードの出現有無だけでなく一定の精度で採点することができる。次に、その採点結果に基づいて、表示するフィードバックコンテンツを換えるというものである。問題 1、問題 2 ともに採点基準は 2 つあるので、それぞれフィードバックコンテンツは 4 パターンある。そして、その効果を確認するために、

- 回答によらず総合フィードバックを表示する(126 名)
- 回答によって表示するフィードバックを換える(78 名)

の二群を用意した。章末に、問題 2 に対する総合フィードバックと個別フィードバックの例を載せた。そして、五段階評価のアンケートにより、これらの二群で満足度や有益度の差を確認した。結果(構成比)を表 2 に示す。表 2 を見て分かるように、フィードバックを個別化した方が、「大変そう思う」と答えた比率が満足度、有益度ともに 12 ポイント高くなった。これより、回答に応じたフィードバックが受講者の満足度や有益度の向上に繋がる可能性があることが分かった。但し、アプリケーションへの応用を見据えて他のケース問題への横展開を考えると、その都度キーワードを手で抽出するのは労力を要する。そこで、機械学習を使えばそのような労力を減らすことができる。さらに、採点結果の精度を高めることができれば、さらなる受講生の満足度や有益度の向上に繋がる可能性がある。そこで、本研究では、機械学習を利用して採点結果の精度が上がるのかを確認する。

フィードバック例(総合)

前の問題で見た通り、ライアンエアーは既存の航空大手とは違う市場セグメントを創出し、顧客ターゲットも変えました。なぜなら、短距離路線に特化し、普段なら電車やバスを利用するような低価格志向の旅行者にフォーカスすることで、新たなビジネスモデルを作ろうとしたからです。こうすることで、競合・顧客との関係はどう変わのでしょうか？

大手航空会社はダイレクトな競合ではなくなり、同じ航空業界にいながらにして競争から身をかわすことができます。同時に、欧州初の格安航空会社として、顧客に対して優位に立つことができるでしょう。売上にダイレクトに影響してくる顧客ターゲットの選定に加え、こうした観点も考えることができれば、大変良い回答だったと言えるでしょう。

ここでは、「5 つの力(5F)」の分析図を参考に解説していますが、ところが、必ずしもある業界が一般的に魅力的でなくても、誰に、そして、どのようなサービスを提供するのかを具体的に考えることで、全く違う魅力を提供できることがあります。5F 分析は、このように市場の魅力度を違う角度から考えて見ることに有効なツールです。

フィードバック例(個別) ※採点基準 1,2 ともに正解の場合

あなたが書かれた回答は重要な二つの観点をもろさずカバーしており、よく考えられています。

二つの観点とはすなわち以下の事を指します:

- 1) 新たな顧客層やニーズの掘り起こしといった売上に関わる観点。ライアンエアは短距離に特化し、低価格志向の層を狙うことで新たな顧客層を獲得できると考えました。なぜなら当時そうしたニーズに応える航空会社はなかったため、新たな市場セグメントを開拓できると踏んだのです。
- 2) 業界内の競争に関する点。市場セグメントを変えたことで大手航空会社が直接の競合ではなくなり、同じ航空業界にいながらして競争から身をかわすことができます。同時に、欧州初の格安航空会社として、顧客に対しても優位に立つことができるでしょう。

あなたの回答通り、この二つの観点を持つことが、分析に深みを加えます。ここでは、「5つの力(5F)」の分析図を参考に解説しましたが、こうした分析の際、市場の魅力度を違う角度から考えることを可能にする有効なツールとして働きます。

表2 アンケート結果(構成比)

	満足度(%)		有益度(%)	
	総合	個別	総合	個別
大変そう思う	10	22	16	28
そう思う	64	49	67	56
どちらでもない	17	20	11	9
そう思わない	7	8	5	6
全くそう思わない	2	1	1	1
合計	100	100	100	100

5. 手法

本研究で取り上げた問題には明確な採点基準があり、回答文字数は 30~50 文字程度である。そこで、同じような文字数の記述式問題回答を高い精度で自動採点できることが分かっている。先行研究で紹介した [水本 18] らと同じアテンション付き LSTM を利用した。本研究で採用したネットワーク構造を図 2 に示す。MeCab を使って回答を単語(形態素)に分割し、各単語の分散表現(ベクトル)をネットワークの入力とした。分散表現を獲得するためのコーパスには、Wikipedia のダンプデータに加え、グロービス経営大学院が出版している書籍のテキストデータを利用した。そして、word2vec で学習したものから、単語の分散表現を得た。なお、単語分割には MeCab を利用し、単語の分散表現は 200 次元、ウインドウサイズは 5 とした。そして、各問題の採点基準毎に正誤を判定し、leave-one-out の交差検証で精度を算出した。

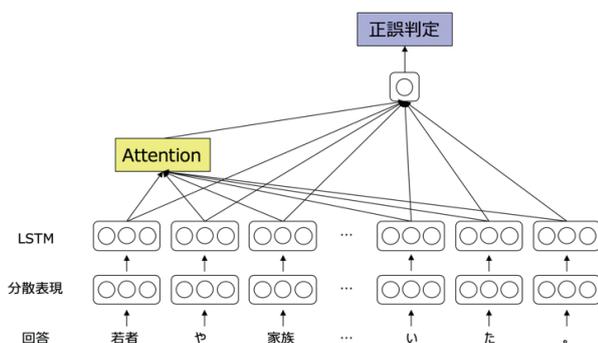


図2 ネットワーク構造

6. 結果と考察**6.1 採点結果**

アテンション付き LSTM に加えて、特定のキーワードの出現有無だけで判定した場合の採点結果の精度を表 3 に示す。表 3 を見て分かるように、特定のキーワードの出現有無だけでも 80% 程度の精度、採点基準によっては 90% 以上の精度となった。そして、アテンション付き LSTM は、それと同等、もしくはそれ以上に高い精度となった。具体的には、ライアンエアの問題 2 の採点基準 1, 2 では 80% 以上の精度、その他の問題の採点基準では 90% を超える精度となった。

表3 採点結果精度

			キーワード	LSTM
ライアン エア	問題 1	基準 1	0.900	0.923
		基準 2	0.971	0.971
	問題 2	基準 1	0.818	0.823
		基準 2	0.770	0.852
経営戦略	問題 1	基準 1	0.897	0.923

さらに、本研究で用いたアテンション付き LSTM では、正誤の判定だけでなく正解と不正解の事後確率を出力することができる。そこで、正解と不正解の事後確率がある値の範囲内に収まる場合、つまり予測の確信度が低い回答は自動採点の対象外とすることができる。その場合、我々が検討しているアプリケーションにおいては、回答に応じたフィードバックは返さずに総合フィードバックを返すという案が考えられる。正解と不正解の事後確率が 0.1 以上、且つ、0.9 以下の回答を除いた場合の採点結果の精度を表 4 に示す。この閾値は、自動採点の対象外となる回答数が多くならないように調整して決めた。表 4 を見て分かるように、確信度が低い回答を取り除くことで、数ポイント程度精度が向上することが確認できた。特に、精度が一番低かったライアンエアの問題 2 の採点基準 1 の改善幅が最も大きく、6 ポイント以上も精度が向上した。また、この確信度が低い回答は全体の 2 割以下にとどまるので、アプリケーションに応用した場合には 8 割以上の受講者には回答に応じたフィードバックを返すことができるので許容範囲であると考えられる。

表4 事後確率でフィルタリング後の採点結果精度

			全件	フィルタリング	
				精度	件数
ライアン エア	問題 1	基準 1	0.923	0.943	183/ 209 件
		基準 2	0.971	0.985	196/ 209 件
	問題 2	基準 1	0.823	0.890	172/ 209 件
		基準 2	0.852	0.874	183/ 209 件
経営戦略	問題 1	基準 1	0.923	0.950	139/ 156 件

次に、アテンションの可視化結果を図 3 と図 4 に示す。図 3 はライアンエアの問題 1 の採点基準 1、図 4 はライアンエアの問題 2 の採点基準 1 のアテンションの可視化結果である。図 2 で示したネットワーク構造はキーワード毎に重み(アテンション)を持つので、これを使えばどの単語に着目して採点したのか

分かる。そこで、重みに基づいてキーワードをハイライト表示するようにした。図3を見て分かるように、人間採点と機械採点とともに正解である場合、「費用」「抑え」「旅費」「安く」などのキーワードが色濃くハイライトされており、前述の採点基準に沿った結果になっている。図4についても、「顧客」「ターゲット」などのキーワードが色濃くハイライトされており、図3と同様に前述の採点基準に沿った結果になっている。これより、アテンション付きLSTMの精度の高さを確認できただけでなく、記述式問題回答で採点基準に触れている可能性がある箇所をハイライト表示する採点支援などの、我々が想定していないアプリケーションへの応用の可能性も確認できた。

人間採点：○，機械採点：○
回答A：費用を抑えて旅行を楽しみたいと考えていた旅行者が電車やバスを利用していった人たち
人間採点：○，機械採点：○
回答B：旅費を安くあげたい層で、普段はバスや電車を利用している
人間採点：X，機械採点：X
回答C：休日欧州内で移動する人たち。普段は電車やバスで移動していた。
人間採点：X，機械採点：X
回答D：ビジネスマンなど平日働いている人たちが電車やバス、車、徒歩などの交通手段を利用している

図3 アテンションの可視化結果(問題1/採点基準1)

人間採点：○，機械採点：○
回答A：大手と競合しない新たな顧客層の獲得が出来るから
人間採点：○，機械採点：○
回答B：低価格で旅行したい人たちのニーズに合わせ、他の大手航空会社と競合しない人をターゲットにしたから
人間採点：X，機械採点：X
回答C：他社より低価格で提供すれば、利用してもらえると考えた
人間採点：X，機械採点：X
回答D：電車やバスと比較検討できるくらい安い価格で提供できたから

図4 アテンションの可視化結果(問題2/採点基準2)

6.2 学習データの数と採点結果の精度

自動採点に必要な学習データの数を把握するため、学習データの数を減らしていくと精度がどのように変化するかを調べた。ライオンエアと経営戦略では回答数が異なるため、ライオンエアの問題の回答に限定して調査した。そして、209件の回答をleave-one-outの交差検証で評価する際、208件を学習データとして使うのではなく、それぞれ104(=208/2)件、52(=208/4)件、26(=208/8)件をランダムに抽出して学習データとして使用した。もし学習データを減らしても高い精度を維持できれば、学習データを収集する手間やコストを削減することができる。アプリケーションへの応用を見据えて他のケース問題への横展開を考えた際、大きな利点となる。結果を図5に示す。図5を見て分かるように、どの採点基準においても、学習データを104件に減らしても精度は大きく落ち込んでいないが、学習データを52件にまで減らすと精度が大きく落ち込んでいる。これより、本研究で取り上げた問題の記述式回答では、100件程度の学習データがあれば一定の精度で自動採点できることが分かった。また、学習データが104件から208件に増えると僅かではあるが精度は向上しているため、学習データを208件よりも増やすと精度はまだ上がる可能性がある。

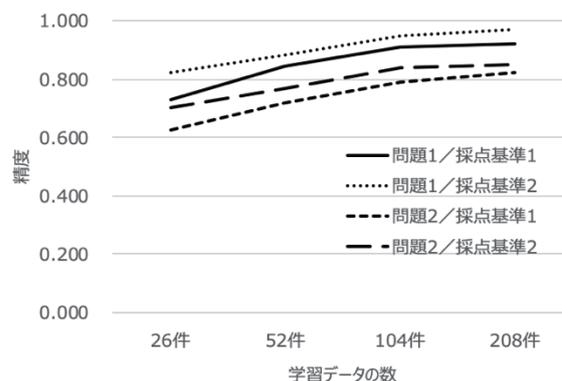


図5 学習データの数と採点結果の精度

7. 結論と今後

本研究では、講師を必要としないケースメソッドの実現を中長期的な目的とした中で、予備調査で回答に応じたフィードバックが受講者の満足度や有益度の向上に寄与する可能性があることを確認した。そして、デジタル機器上での回答を想定して作成した記述式問題回答の自動採点にアテンション付きLSTMを試した。結果、特定のキーワードの出現有無だけで判定するよりも高い精度で採点できることが分かった。正解と不正解の事後確率を利用して予測の確信度が低い回答を自動採点の対象外とすることで、精度をさらに高められることも分かった。また、アテンションの可視化結果は採点基準に沿ったものになっており、回答に応じたフィードバックの表示以外のアプリケーションの応用先も確認できた。さらに、高い精度を実現するために必要な学習データの件数も調査、把握することで、他のケース問題へ横展開する際に参考となる情報を得ることができた。

今後は、アテンション付きLSTMを利用した上で予備調査と同様の調査を他のケースでも実施し、フィードバックを個別化することで満足度や有益度がどの程度向上するかを確認したい。満足度や有益度の向上が確認できれば、アプリケーション化したものをグロービス経営大学院の教育に取り入れたい。そして、教室の中で行われるケースメソッドとの教育効果の違いなどを分析しながら、講師を必要としないケースメソッドの実現を目指す。

参考文献

- [Barnes 94] L. B. Barnes, C. R. Christensen and A. J. Hansen: Teaching and the Case Method: Text, Cases, and Readings, Harvard Business Press, (1994).
- [Burrows 15] S. Burrows, I. Gurevych and B. Stein: The Eras and Trends of Automatic Short Answer Grading, Journal of Artificial Intelligence in Education, Vol.25, pp.60-117 (2015)
- [Valenti 03] S. Valenti, F. Neri and A. Cucchiarelli: An overview of current research on automated essay grading, Journal of Information Technology Education, Vol.2, pp.319-330 (2003)
- [高木 01] 高木晴夫: ケースメソッドによる討論授業のやり方, 経営行動科学, Vol.14, No.3, pp.161-167 (2001)
- [佐野 13] 佐野享子: ケースメソッド学習の効果を高める原理, Rcus Working Paper, No.5, pp.1-22 (2013)
- [水本 18] 水本智也, 磯部順子, 関根聡, 乾健太郎: 採点項目に基づく国語記述式答案の自動採点, 言語処理学会 第24回年次大会 発表論文集, pp.552-555 (2018)

[104-J-12] Human interface, education aid: education and communication

Chair:Kazuhisa Seta Reviewer:Megumi Kurayama

Tue. Jun 4, 2019 5:20 PM - 7:00 PM Room O (Front-left room of 1F Exhibition hall)

[104-J-12-01] Discussion Support Robot on Educational Field

Hiroki Ono¹, Okaito Koike¹, Takeshi Morita², Takahira Yamaguchi² (1. Graduate School of Science and Technology, Keio University, 2. Faculty of Science and Technology, Keio University)

5:20 PM - 5:40 PM

[104-J-12-02] Analysis of Interaction for the Developing an Interactive Speaker for Children

Okazuhiro Mitsukuni¹, Ichikawa Jun¹, Yukari Hori², Yuta Ikeno³, Leblanc Alexandre³, Tetsukazu Kawamoto³, Natsuki Oka¹, Yukiko Nishizaki¹ (1. Kyoto Institute of Technology, 2. HAKUHODO Inc, 3. HAKUHODO i-studio Inc.)

5:40 PM - 6:00 PM

[104-J-12-03] Communication Learning Support for Pragmatic Language Disorders Using a Humanoid Robot

OkKeigo Yabuki¹, Kaoru Sumi¹ (1. Future University Hakodate)

6:00 PM - 6:20 PM

[104-J-12-04] Dialogue Mood Estimation from Dialogue Voice Considering Personality Trait of Speaker

OkTatsuya Hasegawa¹, Shohei Kato^{1,2} (1. Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology)

6:20 PM - 6:40 PM

[104-J-12-05] Interaction Model Promoting Language Development through Japanese Word Play

OkJumpei Nishikawa¹, Junya Morita¹ (1. Shizuoka University)

6:40 PM - 7:00 PM

教育現場における議論支援ロボット

Discussion Support Robot on Educational Field

小野 宙生
Hiroki Ono

小池 開人
Kaito Koike

森田 武史
Takeshi Morita

山口 高平
Takahira Yamaguchi

慶應義塾大学大学院
Keio University

In recent years, service robots have become widespread in various places, and robots are gradually becoming familiar to humans. It is expected that the robot market will expand further and the relationship with humans will become stronger in the future. On the other hand, in the current elementary school education, it is more required than ever that the students learn subjectively while maintaining the interests of them, and various efforts are being done in school. With is background in mind, we introduced a robot to a small group discussion lesson, and constructed a “discussion support robot” to support the discussion of children. It plays the role of proceeding with discussions with children from the two aspects of discussants and facilitators. In addition, as a case study, we conducted a discussion lesson using this system at an elementary school, and made a consideration using evaluations from children and teachers.

1. はじめに

現在、小学校教育において教師の補助役にロボットを導入した実践授業の研究を進めている[Morita 18]. 小学校教育においては児童の主体的な学習が必要になってきている。これまで行ってきた教師支援ロボットの研究は、ロボットは教師の補助役にとどまっており、児童に主体的に学習させるという教育目標を達成するには不十分であった。

以上の背景より、本研究では、議論参加者および司会進行者という2つの側面から議論の支援を行う「議論支援ロボット」を構築した。ケーススタディとして、小学校で本システムを用いたディスカッション授業を行い、児童および教師による評価を行った。

2. 関連研究

議論支援ロボットの特徴である「学習支援」と「質問応答」の関連研究について述べる。

三宅らの研究[三宅 12]では、児童 3~4 人のグループに1台のロボットを配置し、人間が遠隔操作しながら共に学習することにより、より理解を深められるロボットの振る舞いなど、ロボットと児童の関わり方を研究している。しかし、この研究では遠隔操作しているため、ロボットの自律性は低い。

Nuccioらの研究[Nuccio 17]ではオントロジーを利用した質問応答形式での研究室案内ロボットを構築している。研究室で用いられているテーマや所属メンバーなどがオントロジーに記載されており、用意したオントロジーで答えられないことは Wikipedia API を用いて応答を試みている。しかし、この研究では該当用語のアブストラクトを述べるにとどまっている。

3. 議論支援ロボット

本研究で提案する議論支援ロボットのシステム構成を図1に示す。本システムでは議論支援ロボットの持つ5つの機能に対してデータベースとオントロジーを活用しており、オントロジーや

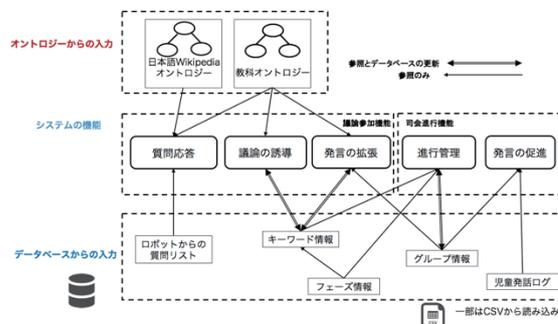


図1 システム構成

データベースを書き換えることで様々なテーマに対しても本システムを適用することが可能である。

以下、本稿では授業時間内の議論テーマごとやディスカッション以外の時間で分割したそれぞれの時間を「フェーズ」と呼ぶ。

本稿における議論支援ロボットは大きく分けて「議論参加者」と「司会進行者」の二つの機能を担う。以下ではそれぞれの役割について述べる。

3.1 議論参加

本稿の議論支援ロボットには3つの議論参加の機能があり、それぞれの機能について以下で解説する。

(1) 発言の拡張

ディスカッションの中で児童が発言すると考えられるキーワードをあらかじめ用意しており、それらのいずれかが発言された時にロボットが補足し、必要に応じて用意したビデオを見せる。図2に本機能の処理の流れを示す。生徒の発言は随時記録されているが、その中に現在のフェーズで補足するキーワードが含まれているかどうかを確認し、そのキーワードが含まれていた場合には教科オントロジーの該当するインスタンスを参照する。そのインスタンスの「説明」プロパティおよび、「補足」プロパティを取得し、適宜語尾を変化させることで、ロボットにそのキーワードについての説明をさせる。そのキーワードに関する動画が用意されていた場合、グループごとに用意されたPCにてその動画を再生する(PCで「見る」「見ない」を選択する動画も存在する)。

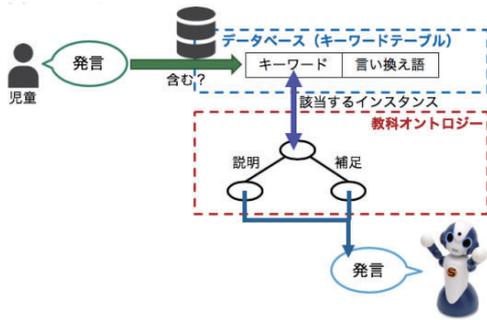


図2 「発言の拡張」機能の処理の流れ

(2) 質問応答

質問応答にはロボットから質問し児童が答えるケースと、児童からの自由な質問にロボットが答えるケースの2つがある。前者はオントロジーを用いて児童の回答が正しいかどうかを判断し、その正誤に応じてロボットが返答する。後者は児童からなされた質問に対し、オントロジーを用いてロボットが返答する。以下では、児童からロボットに質問があった時の処理の流れについて説明する。

図3に児童からロボットに質問があった時の処理の流れを示す。議論中に児童から質問されているかを判断するために、質問文の前にロボットの名前(今回の場合は「Sota」)を発言するようにルールを設定した。このことは実験前に議論参加者に対して説明している。最初に、質問文からロボット名を取り除いた上で形態素解析を行う。連続した名詞は1語として扱った上で名詞の数を取得し、以降の処理を分岐させる。

名詞が一つのみ含まれる場合は質問文を「Aについて教えて」「Aとは何?」という型の質問だと解釈する。この時は、はじめに教科オントロジーにおけるインスタンスの `rdfs:comment` プロパティを用いて回答を行う。教科オントロジーに該当するインスタンスが存在しない場合は、日本語 Wikipedia オントロジーに同様の処理を行い回答する。回答が見つからなければ、わからない旨の回答をさせる。名詞が二つある場合は二つの名詞の関係性が記述されているトリプルが見つかった時に残りの一つの名詞を回答する仕組みとなっている。二つの組み合わせが見つからない場合、最初の名詞に対して名詞が一つの質問と同様の処理を行い回答する。その回答もなければわからない旨の回答をさせる。わからない旨を伝える際にはランダムに回答を変更し、機械的な回答にならないように工夫をしている。

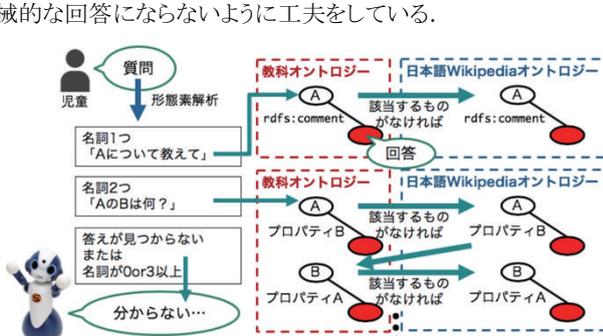


図3 児童からロボットに質問があった時の処理の流れ

(3) 議論の誘導

ディスカッションを円滑に進めるために、キーワードが一定時間児童から1つも出ない場合ロボットが解説を行うことで、未出のキーワードに関して児童に理解させるための機能である。こ

では発言の拡張と同様の方法で未出キーワードに当たるインスタンスを教科オントロジーから参照し、「説明」「補足」プロパティを用いることで解説を行い、必要に応じて動画を再生する。

そのほかにも児童から「ヒント頂戴」など、ヒントという単語が含まれた発言を検知するとロボットはヒントを求められたと判断し、キーワードごとに決められているヒントをロボットが発言する。これにより未出のキーワードに関する議論を促す効果が期待できる。

3.2 司会進行

本稿の議論支援ロボットは2つの司会進行者としての機能があり、それぞれの機能について以下で解説する。

(1) 進行管理

フェーズの移行は一定間隔のチェックによって行われる。フェーズ移行の条件としては「そのフェーズで用意したキーワードが全て発言された」もしくは「フェーズごとの規定議論時間を超過した」が用意されており、これらのいずれかを満たした場合に次のフェーズへと移る。したがってグループの状況によって移行のタイミングは異なっている。

(2) 発言の促進

(1)進行管理の部分でも述べた一定間隔のチェックの際に、前回のチェックから一度も発言していない児童がいれば「～さんはどう思うかな?」と尋ねることで全員参加型の議論の活性化を図っている。

4. オントロジー

本研究では知識源として教科オントロジーと日本語 Wikipedia オントロジー[玉川 10]の2種類のオントロジーを用意している。それぞれについて説明する。

4.1 教科オントロジー

教科オントロジーは本システムを用いる授業の範囲に特化し、人手で作成するオントロジーである。本研究のケーススタディにおいては地球環境に関するオントロジーを作成した。教科オントロジーは構築コストがかかり範囲も狭いが、正確な概念関係を構築することができる。ケーススタディで用いた教科オントロジーである、地球温暖化オントロジーにおけるクラス階層とプロパティの一部を図5に示す。教科オントロジーを利用することにより、ロボットと生徒のインタラクションを可能にしている。

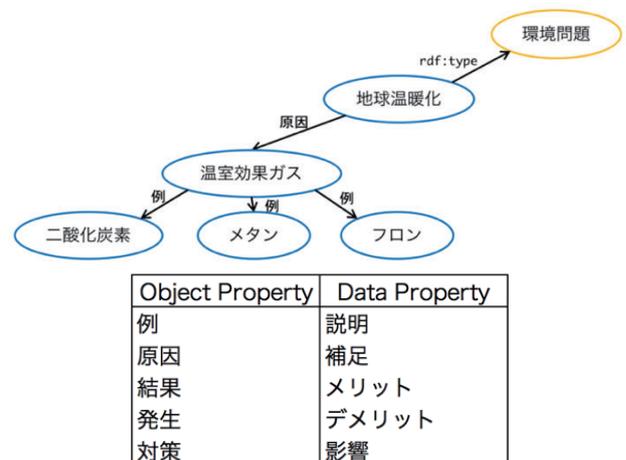


図5 地球温暖化オントロジーにおけるクラス階層とプロパティの一部

4.2 日本語 Wikipedia オントロジー

日本語 Wikipedia オントロジーとは玉川らにより構築された汎用オントロジーである。日本語 Wikipedia から半自動的に構築しており、非常に大規模なものとなっている。このオントロジーは教科に限定されない知識を持つが、教科に関する知識は十分に網羅されておらず、Wikipedia の性質上、子供向けの言葉で書かれていない。

表1に地球温暖化オントロジーと Wikipedia オントロジーの規模を示す。

	地球温暖化オントロジー	日本語 Wikipedia オントロジー
クラス数	15	160,248
インスタンス数	39	1,836,958
プロパティ数	12	24,382
トリプル数	215	12,703,202

5. ケーススタディ

議論支援ロボットを使用した授業を行う際のケーススタディとして、2018年12月13日(13:40~15:15)と12月20日(13:40~15:15)の2回、小学校5年生の総合における「地球温暖化に関する議論授業」を行なった。小学校5年生2クラス66名を対象とし、1回の実験では半数の33名が参加した。実験では33名を4~5名ずつの少人数グループ8グループに分け、さらにそれぞれを3教室に別けて実験を行なった。

5.1 実験環境

ケーススタディにおける1グループごとの実験環境を図6に示す。図6に示すようにロボットとPC、マイクを配置した。ロボットとしては発話や身振りができ、机に手軽に配置できる小型のヒューマノイドロボット Sota¹を採用した。マイクは Amivoice²を採用し、椅子に座っている議論参加者それぞれに首から下げてもらった。



図6 ケーススタディにおける1グループごとの実験環境

5.2 ロボットと児童の対話例

ケーススタディにおける Sota と児童の対話例を以下に示す。
 Sota 「それじゃあ、みんな一人一人ができる温暖化対策について話し合ってみよう。」
 児童 A 「節電すればいいんじゃないかな？」
 Sota 「今、Aくんが節電と言ったね。火力発電で電気を作る時には、大量の二酸化炭素が出ているから、電気を節約することが温暖化対策になるんだよ。使っていない明かりをこまめに消すとか、テレビをつけっぱなしにしないとか、

そういった習慣をつけることで節電ができるんだよ。」
 Sota 「それじゃあ、例えばどんな風にすれば節電ができるのか説明したビデオがあるから、見たかったらパソコンで『見る』をクリックしてね」

6. 評価

授業後の児童へのアンケート及び、教師へのインタビュー、さらに実験動画の分析を行い、それらの結果を用いて評価とした。児童に対して行ったアンケートの内容を以下に示す。

児童へのアンケート内容

- Q1. Sota の教え方はどうでしたか？
 1 よかった 2 ややよかった 3 やや悪かった 4 悪かった
- Q2. Sota に質問したときの答え方はどうでしたか？
 1 よかった 2 ややよかった 3 やや悪かった 4 悪かった
 5 Sota に質問をしていない
- Q3. Sota にヒントを聞いたときの答え方はどうでしたか？
 1 よかった 2 ややよかった 3 やや悪かった 4 悪かった
 5 Sota にヒントを聞いていない
- Q4. 授業の中で、「ここがよかった」「楽しかった」というようなことがあれば、書いてください。
- Q5. Sota や今回の授業について、「ここが悪かった」「こうした方がいいと思う」というようなことがあれば、書いてください。

「(Q1)Sota の教え方全般の評価」「(Q2)質問応答昨日の評価」「(Q3)ヒント機能の評価」では「よかった」「ややよかった」「やや悪かった」「悪かった」の4段階評価の選択肢と、Q2, Q3 では質問していない、ヒントを聞いていない場合の選択肢を用意した。「(Q4)授業のよかった点」「(Q5)授業の悪かった点」は自由記述として設定している。

6.1 児童へのアンケートからの評価

アンケート結果を表2から表4に示す。

表2 児童へのアンケート結果(Q1~Q3)

	2クラス合計			2組(12/13)			3組(12/20)		
	Q1	Q2	Q3	Q1	Q2	Q3	Q1	Q2	Q3
1 (よかった)	45	35	38	20	17	19	25	18	19
2 (ややよかった)	18	21	17	10	10	8	8	11	9
3 (やや悪かった)	0	3	0	0	2	0	0	1	0
4 (悪かった)	0	1	2	0	1	2	0	0	0
5 (質問をしていない/ヒントを聞いていない)	-	3	5	-	0	0	-	3	5
その他	0	0	1	0	0	1	0	0	0

表3 児童へのアンケート結果の一部(Q4)

記入内容	人数
Sota がビデオを見せてくれたのがよかった	20
詳しく教えてくれた	10
分かりやすかった	8
楽しかった/面白かった	8
質問にちゃんと答えてくれた	7
名前を言ってくれた	7
会話中に反応してくれた	6
ヒントを教えてくれた	4
ビデオが分かりやすかった	3
Sota が指名したのがよかった	2
考えが深まった	2
反応してくれて嬉しかった	2
先生みたいだった	2

¹ <https://www.vstone.co.jp/products/sota/>

² <https://www.advanced-media.co.jp/products/service/amivoice-front-wt01-2>

表 4 児童へのアンケート結果の一部(Q5)

記入内容	人数
声を聞き取ってもらえないことが多かった	8
Sota が答えるまでの時間が長かった	5
Sota が途中で止まった	4
質問に答えられる範囲を広くしてほしい	4
Sota の発音が悪かった	3
質問を無視された	2

表 2 はケーススタディ参加者全員の結果をまとめた「2 クラス合計」、12/13 に実施したケーススタディの結果のみをまとめた「2 組(12/13)」、12/20 に実施したケーススタディの結果のみをまとめた「3 組(12/20)」の 3 列に別れている。各クラス 33 名の児童に対して授業を行なったが、2 組のみアンケートの回収枚数が 30 枚となっており、枚数が少なくなっている。また、表 3、表 4 ではアンケートの記入内容として 2 人以上の生徒が回答したものを載せている。

これらの結果を見ると Sota への授業全体への評価は良い評価を得られている。しかし機能ごとに絞ったアンケートでは質疑応答や音声認識の部分で不満を感じていることがわかる。また質問に答えられる範囲を広くしてほしいという回答も挙がっている。

6.2 教師へのインタビューからの評価

本研究に関わってくださった 4 名の小学校教師の方に「よかった点」「悪かった点」「要望」「その他」の 4 項目についてインタビューを行った。その結果、児童が自分ごととして授業を受け、普段の授業よりも多く発言していたという部分を高く評価された。また、決まり切ったシナリオではなく、グループの発言ごとに異なる進行になる点、また児童自身の言葉にロボットが反応する心地よさがあつた点も高評価であつた。

改善点としては音声認識技術の向上が挙げられた。そのほかにも Sota が児童の呼びかけや質問に対し適切に反応できないケースも多く、呼びかけなのか質問なのかをより正確に判断する必要があるとの意見もあつた。今回は質問文の先頭に Sota とつけるルールを設けたが、児童が忘れてしまったり Sota にただ話しかけた場合でも質問と解釈してしまったりする場合もあり、本研究の研究対象ではないが、改善する必要がある部分である。

6.3 実験動画の分析からの評価

各グループの授業中の動画を検証した結果を表 5 に示す。

「発言の拡張」や「未出の解説」は共に Sota がキーワードの解説を行う機能であり何度か音声認識が原因で適切に動作していないが、児童が何度か言い直すことによって適切に動作したケースが多かった。

「質問応答」機能については児童が「Sota, ~」の形式で質問した 18 回のうち、適切に答えられたのは 2 回のみで正確性が低い結果となった。この 16 回のうち、7 回は音声認識が原因であり、残りの 9 回は「100 年後の地球の平均気温は?」のように今回のシステムでは回答できない類の質問であった。今回は質問文と解釈するために文頭に Sota とつけるルールを設けたが正確性に欠けるものであり、質問以外の発言を質問と捉えてしまう場合も 7 回あつた。

これらの結果からも、Sota の機能として質問応答機能の正確性が低いことが大きな問題点として挙げられる。しかし、音声認識や児童が質問文と認識する形式を満たさず質問することも多くあつた。これらを改善するためには質問文として児童の発言

を認識する方法や質問文の解析方法の改善、オントロジーそのものの拡張が必要だと考える。

児童を名指して発言を促す機能については、概ね動作しており、児童館の議論の活性化につながっていた。しかし、Sota からの呼びかけに答えられない子もおり、Sota からの発言の催促を苦痛に感じていた可能性があるため、呼びかけ回数に上限を設けるなどの工夫が必要と考えられる。

表 5 各機能の動作した回数の合計

	発言拡張	質問応答	未出の解説	ヒント	発言促進
適切に動作した回数	73	2	21	38	43
適切に動作しなかった回数					
音声認識が原因	9	7	-	4	-
音声認識以外が原因	0	9	0	0	2
質問でないのに質問と解釈した回数	-	7	-	-	-

7. 終わりに

本稿では、小学校における教育的効果をより高めるために、少人数のグループのディスカッション授業に導入する議論支援ロボットを提案した。ケーススタディとして小学校の授業に本システムを導入した結果、児童及び、教師の両方から高い評価を得た。今後の展望としては、音声認識技術の向上に伴い、本システムはさらに効果を発揮するようになると考えられる。また、質問応答の改善や、児童の発音がロボットへの質問なのかそうでないのかを正確に判断する方法も必要になると考えられる。

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)の支援によって実施した。

参考文献

- [Morita 18] Takeshi Morita, Shunsuke Akashiba, Chihiro Nishimoto, Naoya Takahashi, Reiji Kukihara, Misae Kuwayama, Takahira Yamaguchi: A Practical Teacher-Robot Collaboration Lesson Application Based on PRINTEPS, The Review of Socionetwork Strategies, Springer, Vol. 12, Issue 1, pp 97-126, 2018.
- [Nuccio 17] Carlo Nuccio, Agnese Augello, Salavatore Gaglio, Giovanni Pilato: Interaction Capabilities of a Robotic Receptionist, KES-IIMSS-17(Intelligent Interactive Multimedia Systems and Services 2017), pp.171-180, 2017.
- [玉川 10] 玉川奨, 桜井慎弥, 手島拓也, 森田武史, 和泉憲明, 山口高平, “日本語 Wikipedia からの大規模オントロジー学習,” 人工知能学会論文誌, vol.25 No.5, pp.623-636, 2010.
- [三宅 12] 三宅 なほみ: ロボット共生学: 実践的な学習研究にロボットを導入して, 何ができるか, 認知科学, 2012, 19 巻, 3 号, pp. 292-301, 2012.

子ども用対話型スピーカーの開発に向けた対話遊びの分析

Analysis of Interaction for the Developing an Interactive Speaker for Children

光國 和宏*¹ 市川 淳*² 堀 紫† 池野 湧太‡
Kazuhiro Mitsukuni Jun Ichikawa Yukari Hori Yuta Ikeno

アレクサンドル ルブロン‡ 河本 徹和‡ 岡 夏樹* 西崎 友規子*
Leblanc Alexandre Tetsukazu Kawamoto Natsuki Oka Yukiko Nishizaki

*京都工芸繊維大学 †株式会社 博報堂 ‡株式会社 博報堂 アイ・スタジオ
Kyoto Institute of Technology HAKUHODO Inc. HAKUHODO i-studio Inc.

The demand for interactive speaker (e.g., Amazon Echo and Google Home) is rapidly increasing especially in parenting situations. However, previous studies have focused on impression of interactive speaker or operating existing services by voice. In this study, we focused on interaction between a child and an interactive speaker for applying it to parenting situations. Children between the ages of 3 and 6 participated and did conversation play interacted with the interactive speaker. We explored relation between the participant's personality and his or her reactions. The results indicated that children who are emotionally stable, who are not nervous, or who are highly adaptive to new environment interacted with the interactive speaker better than the others. These results suggested that interaction design depending on a child's personality should be considered.

1. はじめに

現在、育児に対して不安やストレスを感じる親が増加している[厚生労働省 2015]。このような親の負担を軽減するために、育児支援に関連するヒューマンロボットインタラクションの研究が多く行われている[阿部 2013][阿部 2014][Tanaka 2007]。阿部らは、子どもとロボットとのインタラクションにおいて、性格特性や心的状態の推定が重要であると主張した。Tanaka らは当時、ロボット技術を用いて子どもたちの教育支援を行うという漠然とした目的を有していたが、具体的な場面の想定を判断をしかねていた。子どもたちの使用場面に近い状況で、ロボットと子どものインタラクションを観察するなかで、具体的な教育支援の場面や子どもを飽きさせない必要条件を探った[田中 2011]。具体的にはロボットと子どもの長期的な関係構築に向けて、6 か月の間、月齢 1~2 歳が通う教室に半自律的に操作するロボットを導入し、ビデオカメラで撮影を行った。その結果、バッテリー残量の少なくなったロボットが床の上に寝ようとする子どもたちがロボットに毛布を掛けるといった、子どもの社会的行動が見られた。このような子どもたちの世話欲をかきたてるようなロボットの振る舞いは、子どもたちの興味を長期間引き付けることが分かった。Tanaka らはこのような知見を子どもたちの学習支援などの人を支援するロボット技術開発に利用できるとした。

また、現在、Amazon Echo や Google Home といったボイスユーザーインターフェースを搭載したスマートスピーカー(以下、対話型スピーカー)が普及している[NPR 2018]。ロボットよりも気軽に家庭に導入しやすく、急速に普及して行くと考えられ、対話型スピーカーを用いた育児支援の実用性の向上が期待される。子どもに限らず、人と対話型スピーカーとのインタラクションを検討した研究がいくつか存在する[Druga 2017][Sciuto 2018]。しかし、既存のサービスの利用や対話型スピーカーの印象に関

する調査が多く、音声履歴の解析やアンケート調査に留まっており、どのようなインタラクションを行ったかを詳細に分析した研究は少ない。

このように、育児支援を目的とした対話型スピーカーは必要条件の探索段階であることから Tanaka らの研究を参考にし、半自律的に操作を行う対話型スピーカーを使用する。

本研究では、育児支援に役立つ子ども用対話型スピーカーの開発に向けた、基礎的知見を創出することを目的に、先行研究[Druga 2017][Sciuto 2018]では行われていない、子どもと対話型スピーカーの対話遊びにおけるインタラクションを観察する。そして、アンケート調査だけではなく行動分析も実施し、阿部らの研究を参考に性格特性に基づいたインタラクションの特徴を検討する。

2. 実験方法

2.1 参加者

実験参加者は幼稚園、保育園に通う 3 歳 1 か月から 6 歳 7 か月までの子ども(男児 8 名、女児 12 名、 $M=4.78$, $SD=1.15$)とその母親(20 名、31~48 歳、 $M=38.65$, $SD=4.52$)の 40 名であった。本研究は京都工芸繊維大学の倫理委員会の承認を受けた。また、子どもの実験参加については母親が代諾し、書面にて同意を得た。

2.2 環境と機材

実験は京都工芸繊維大学にて行った。幼稚園や保育園、家庭に近い環境で母子が遊ぶことが可能なように、実験を行う部屋には子どもが遊ぶための室内テントを設置した。テント内には絵本やソフトブロックなどのおもちゃを設置した。実験者や実験機材の影響を少なくするため、パーティションとホワイトボードを用いて室内を区切った。パーティション内には参加者の様子を観察するためのビデオカメラ(SONY HDR-CX670)を 2 台設置

¹ 光國和宏 京都工芸繊維大学 工芸科学部 情報工学課程

E-mail : mitsu.kz.cog@gmail.com

² 2019 年 4 月より神奈川大学に所属

した。そして、対話型スピーカーとしてペチャット(博報堂製, 直径 45mm×奥行き 21mm)を使用した。ペチャットの詳細については 2.3 節で後述する。ペチャットを操作するためにスマートフォン (Sony Xperia Z4/Z3+ Dual SOV31, Sony Xperia XZ Premium Dual G8142, GALAXY Note Edge SCL24) を用意した。ペチャットにゴムを通して、サルのみぐるみ (Jellycat: 座高 20 cm) に付けた。ペチャットを付けたぬいぐるみと実験の様子を図 1 に示す。



図 1 実験の様子と対話型スピーカー
「ペチャット」を付けたサルのみぐるみ

2.3 対話型スピーカー

本研究で使用したペチャットは市販されているボタン型スピーカーである。専用アプリを用いてスマートフォンから操作することが可能である。ぬいぐるみに付けて使用することで子どもにとっては自律的に対話しているように演出することが可能である。実験では母親がペチャットの操作を行った。ペチャットの機能のうち、通常モードとらくらくモードの2つの機能を使用した³。通常モードはテーマを選び、その中のセリフ一覧から1つずつセリフを選ぶモードである。らくらくモードはテーマを選び、3つ程度の関連したセリフから1つずつ選ぶことを6, 7回繰り返すことで一連の対話を進めるモードである。なお、テーマごとの最初のセリフは決まっている(例えば、以下で述べるテーマ「週末」の場合は「ねえねえ、お休みの日にしたいことある?」から始まる)。

本実験では日常対話のテーマとして、「はじめまして」(テーマ 1)と「お片付け」(テーマ 6)を通常モードで扱い、「あいさつ」(テーマ 2)、「くしゃみ」(テーマ 3)、「週末」(テーマ 4)、そして「頑張ったこと」(テーマ 5)をらくらくモードで扱った。操作画面の一例を図 2 に示す。

2.4 事前調査

(1) TS 式幼児・児童性格診断検査

子どもの性格特性を把握するために、TS 式幼児・児童性格診断検査 [高木 1997] を事前調査に用いた。主な養育者がそれぞれ 12~15 問から成る、11 項目の質問に「はい」か「いいえ」で回答し、「はい」の回答数を各項目の粗点とし、換算表から点数を算出する。母親が回答を行った。本研究では、特に 2.5 節で述べる対話遊びフェーズに影響があると考えられる 5 項目(神経質, 情緒不安, 社会性, 家庭適応, 学校適応)を抽出した全 63 問の回答を求めた。各項目において最低点は 1 点, 最高点は 99 点である。以下, 神経質を TS1, 情緒不安を TS2, 社会性を TS3, 家庭適応を TS4, 学校適応を TS5 と記述する。

(2) ぬいぐるみに関する調査

本研究ではぬいぐるみに対話型スピーカーを付けて実験を行ったため、普段のぬいぐるみとの関わり方についての調査を行った。「普段からぬいぐるみと遊ぶことが多いですか」という質問に対し、1 をまったくあてはまらない、6 を非常にあてはまるとし、6 件法で評定を求めた。その他、家庭で持っているぬいぐるみの種類と、ぬいぐるみと普段どのように遊ぶかについてそれぞれ自由記述で回答を求めた。



図 2 通常モード (左図) とらくらくモード
(右図: 現在開発中) の操作画面

2.5 実験手順

Web フォームにて事前調査を行った後、子どもと母親は実験室に来室し、母親は使用する対話型スピーカーの操作練習を行った。

その後、母子はテントの傍でテント内のおもちゃを用いて自由に遊んだ(以下、自由遊びフェーズ)。子どもが環境に慣れて自由遊びに飽きた、あるいは遊びに一区切りがついたと母親が判断するまで 5 分程度実施した。

自由遊びフェーズ終了後、母親は実験者からスマートフォンを受け取り、テントの傍でペチャットを操作することで、子どもはぬいぐるみと対話遊びを行った(以下、対話遊びフェーズ)。対話はテーマ 1~テーマ 5 の順に行った。遊びに一区切りがついた、あるいは子どもが遊びに飽きたと母親が判断するまで 10 分程度実施した。

対話遊びフェーズ終了後、スマートフォンを回収し、2 回目の自由遊びフェーズを行った。

その後、再び母親はスマートフォンを受け取り、テントの傍でテーマ 6 のセリフを選択することで、自由遊びフェーズで使用したおもちゃのお片付けを行うように子どもに促した(以下、お片付けフェーズ)。課題の制限時間は 5 分程度で、5 分を過ぎても子どもがお片付けを進める様子が見られない場合は、実験者が手伝った。

最後に、対話遊びフェーズやお片付けフェーズに関する質問の回答を母親と子どもそれぞれが行った。母親には 6 件法(1:まったくあてはまらない~6:非常にあてはまる)の質問紙で回答を求めた。一方で、子どもは 4 件法(1:あてはまらない~4:あてはまる)の質問紙に指さして回答した。母親や子どもに対して行った 6 件法あるいは 4 件法で回答を求めた質問項目を表 1, 2 に示す。

³ らくらくモードは現在開発中であり、リリースされているアプリに、この機能は搭載されていない。

表1 母親に対する事後質問紙

ID	質問項目
Interaction1	ぬいぐるみ遊び直前は機嫌がよさそうだった.
Interaction2	ぬいぐるみ遊び中は機嫌がよさそうだった.
Interaction3	ぬいぐるみ遊び終了時は機嫌がよさそうだった.
Interaction4	ぬいぐるみと親密な遊びができた.
Interaction5	積極的にぬいぐるみに話しかけようとしていた.
Interaction6	ぬいぐるみに興味を持っていた.
Interaction7	ぬいぐるみに好感を持っていた.
Interaction8	ぬいぐるみに親近感を持っていた.
Interaction9	普段のご家庭において1人で遊ぶ時と、行動が違っていた
Interaction10	普段のご家庭において1人で遊ぶ時と、言葉遣いが違っていた.
Clean1	普段よりも自発的にお片づけをしていた.
Clean2	普段のご家庭において1人でお片づけをする時と、行動が違っていた.
Clean3	普段のご家庭において1人でお片づけをする時と、言葉遣いが違っていた.

表2 子どもに対する事後質問紙

ID	質問項目
Child1	おしゃべりはたのしかった?
Child2	おともだちになりたい?
Child3	ほんとうのいきもののようにみえた?

2.6 分析方法

(1) 子どもの反応率

対話遊びフェーズ中の評価項目として、実験中の動画を確認し、対話型スピーカーの発話に対する子どもの反応率(以下、反応率)を求めた。対話型スピーカーの発話ごとに、子どもの発話、または頷きが観察できれば1、観察されなければ0とし、反応の有無を決定した。ペチャットの発話回数と子どもの反応数から反応率を求めた。反応の有無は2人の実験者によって決定し、相互に確認することで個人による偏りを防いだ。

(2) 子どもとぬいぐるみの接触行動

先行研究 [Tanaka 2007] のように子どもの社会的行動が見られるかを観察する指標として、対話遊びフェーズ中における、子どものぬいぐるみに対する接触行動を分析した。動画アノテーションソフトELANを用いて、子どもとぬいぐるみが接触している時間帯に注釈をつけた。接触している回数は、子どもがぬいぐるみと接触してから離すまでを1回とした。なお、上に放り投げでキャッチするといった行動は一連の接触とした。接触した回数と対話遊びフェーズの時間から1分当たりの接触行動の回数(以下、接触行動の頻度)を算出した。接触の有無は2人の実験者によって行い、相互に確認することで個人による偏りを防いだ。

同様に、子どもとぬいぐるみとの接触行動の注釈の時間を合計し、合計接触時間を算出した。合計接触時間と対話遊びフェーズの時間から接触行動の時間割合(以下、接触行動の時間割合)を算出した。

3. 結果

子どもへの事前調査(TS式幼児・児童性格診断検査, ぬいぐるみに関する調査)と事後質問紙及び行動評価(反応率, 接触行動の頻度, 接触行動の時間割合)の無相関検定と相関係数の算出を行った。

TS1と子どもに対する質問の「ほんとうのいきものようにみえた?」(以下, Child3), TS2とお片付けに関する質問紙の「普段よりも自発的にお片づけをしていた。」(以下, Clean1), TS5と子どもに対する質問の「おしゃべりはたのしかった?」(以下, Child1), TS5とChild3, ぬいぐるみに関する調査の「普段からぬいぐるみで遊ぶことが多いですか。」(以下, Doll)とお片付けに関する質問紙の「普段のご家庭において1人でお片づけをする時と行動が違っていた。」(以下, Clean2)において有意水準5%で有意な正の相関を示した。TS1と反応率, TS2と対話遊びフェーズ中の質問紙の「積極的にぬいぐるみに話しかけようとしていた。」(以下, Interaction5), TS2とChild3, TS5と接触行動の割合において有意水準10%で有意な傾向を示した。

対話遊びフェーズに関する質問紙, お片付けに関する質問紙, 子どもに対する質問, 反応率, 接触行動の頻度, 接触行動の割合それぞれと事前調査との相関係数を有意傾向や有意な相関があったもののみ表3に示す。t検定により年長児とそれ以外の間で比較を試みたが、有意な差は認められなかった。

4. 考察

表3 事前調査と事後質問紙及び行動評価との相関

ID	事前調査	質問項目あるいは行動指標	相関係数	p値
TS1	神経質	[Child3]ほんとうのいきものようにみえた?	0.47	0.037*
TS1	神経質	反応率	0.43	0.060†
TS2	情緒不安	[Interaction5]積極的にぬいぐるみに話しかけようとしていた.	0.41	0.072†
TS2	情緒不安	[Clean1]普段よりも自発的にお片づけをしていた.	0.50	0.028*
TS2	情緒不安	[Child3]ほんとうのいきものようにみえた?	0.39	0.093†
TS5	学校適応	おしゃべりはたのしかった?	0.55	0.012*
TS5	学校適応	[Child3]ほんとうのいきものようにみえた?	0.51	0.022*
TS5	学校適応	接触時間の割合	0.40	0.084†
Doll	ぬいぐるみとよく遊ぶ	[Clean2]普段のご家庭において1人でお片づけをする時と、行動が違っていた.	0.51	0.025*

4.1 事前調査と事後質問紙との関係

結果から以下のことが確認された

- 情緒が安定している傾向がある子どもは対話型スピーカーに積極的に話しかけやすい。

この結果は、子どもの情動状態は対話型スピーカーとの対話の積極性に影響を与える可能性がある。情緒が安定している子どもは、大学の実験室という普段と異なる環境、また初めて経験する、話すぬいぐるみに対しても心を開きやすいといえる。情緒が不安定な子どもに対しては、もっと現場環境に近い幼稚園や保育園、自宅で実験をすることで実験環境の影響を検証する必要がある。加えて、実験環境に慣れてもらう自由遊びフェーズの時間を増やすことで、子どもの不安を緩和できる可能性がある。また、先行研究 [阿部 2014] で行われている人見知りの子ども

に対して有効な遊びを実現可能な範囲で対話型スピーカーと行うことで不安が解消される可能性がある。

- 情緒が安定している傾向がある子どもは、対話型スピーカーにお片付けを指示されると、普段よりも自発的にお片付けを行いやすい。

大学の実験室という普段と異なる環境や、先行研究 [Tanaka 2007] のように長期間の実験ではないことが、対話型スピーカーの指示への対応に影響を与えた可能性がある。同様に、子どもの不安を解消して実験する必要があると考えられる。加えて、本研究では自分で使用したおもちゃを片付けるかという指標を用いたが、その他のしつけに繋がるような指標の検討も行っていく必要がある。お片付けに関しては他人の家に来た際の行動に対する普段のしつけが影響している可能性も考えられる。実際に「子どもに対して、普段から他人の家ではすぐに片づけるように指導しているため、片付けが早かったのかもしれない」と事後質問紙における自由記述欄に回答していた母親も見られた。

- 神経質でない傾向がある、情緒が安定している傾向がある、幼稚園や保育園に適応している傾向がある、これらの傾向を持つ子どもは、対話型スピーカーを本当の生き物であると思いやすい。
- 幼稚園や保育園に適応している傾向がある子どもは、対話型スピーカーとの対話を楽しみやすい

ある研究では子どもは4歳ごろから人工物を人として見立てるアナロジーが発達するといわれている [Piaget 1955] [Piaget 1976]。これらの結果を踏まえると、神経質ではない子どもや学校に適応している子どもは対話型スピーカーを生き物に見立てたうえで対話をしていたと考えられる。実際に、子どもに対する質問の「どうしてぬいぐるみがおはなしするようになったと思う？」という質問に対して、スマートフォンで操作しているからと回答した子どもは1名だけであった。

4.2 事前調査と行動評価との関係

- 神経質な傾向が低い子どもほど、対話型スピーカーに反応する割合が高い

この結果は神経質でない子どもの方が細かいことを気にせず、純粋に対話を行っていたためだと考えられる。神経質な子どもに対しても反応が返ってきやすいセリフやテーマを検討するために、神経質かつ、対話を楽しんでいた子どもの対話の詳細な分析などを行う必要があると考えられる。

- 幼稚園や保育園に適応している傾向がある子どもは、対話遊びフェーズ中に対話型スピーカーに触れている時間の割合が高い

幼稚園や保育園に適応している子どもは対話を楽しみやすい(4.1節)ことから対話を楽しんだ結果、ぬいぐるみに触れている時間が長かった可能性が考えられる。今回はぬいぐるみに触れている時間とぬいぐるみに触れる頻度という指標を用いたが、その他のぬいぐるみに対する社会的行動の質的な検討も検討事項の1つである。

5. 結論

本研究では子ども用対話型スピーカーの開発の知見を得るために、事前調査で得られた子どもの性格特性と母親や子どもに対して行った事後質問紙の結果や行動評価との関係を分析した。その結果以下のことが示唆された。

神経質でない、情緒が安定している、幼稚園や保育園に適応しているといった傾向がある子どもは、対話型スピーカーと良いインタラクションを行うことが出来た。

今後、育児に役立つ対話型スピーカーの開発のためには、子どもの性格特性に応じた適切な振る舞いを探っていく必要がある。そのために対話型スピーカーに対し、積極的に対話していた際によく選択されたセリフや、母親が繰り返してセリフを用いていたかを分析していく必要がある。他方で、本研究では子どもに対して、対話型スピーカーと友達になりたいかという項目では性格特性との有意な相関はなかった。人とエージェントとの良好な関係構築を目指した研究ではロボットに対する親しみが援助行動に関連すると報告されている [光國 2018]。このように親しみや親近感を子どもに与えることで、お片付けのようなしつけの効果が確認できれば育児に役立つ可能性が考えられる。加えて、Tanaka らが行っていた第三者によるインタラクションの質の主観評定などを評価項目とすることでより詳細な分析が可能になると考えられる。

利益相反

本研究は株式会社博報堂、並びに株式会社博報堂アイ・スタジオとの共同研究であるが、商業的、金銭的な利益相反の関係がなく行われた。

参考文献

- [厚生労働省 2015] 厚生労働省: 平成 27 年度 少子高齢社会等調査検討事業報告書, https://www.mhlw.go.jp/file/04-Houdouhappyou-12601000-Seisakutoukatsukan-Sanjikanshitsu_Shakaihoshoutantou/001_2.pdf, 2015.
- [阿部 2013] 阿部香澄 他: 子供と遊ぶロボット 心的状態の推定に基づいた行動決定モデルの適用, 日本ロボット学会誌, vol.31, no.3, pp. 263-274, 2013.
- [阿部 2014] 阿部香澄 他: 人見知り子どもとロボットの良好な関係構築に向けた遊び行動の分析, 情報処理学会論文誌, vol.55, no.12, pp. 2524-2536, 2014.
- [Tanaka 2007] Tanaka, F et al.: Socialization between toddlers and robots at an early childhood education center, PNAS, vol.104, no.46, pp. 17954-17958, 2007.
- [NPR 2018] National Public Radio: The Smart Audio Report, <https://www.nationalpublicmedia.com/smart-audio-report/latest-report/>, 2018.
- [Druga 2017] Druga, S. et al.: “Hey Google is it OK if I eat you?” Initial Explorations in Child-Agent Interaction, Initial Explorations in Child-Agent Interaction, Proc. IDC 2017, pp.595-600, 2017.
- [Sciuto 2018] Sciuto, A. et al.: “Hey Alexa, What’s Up?”: Studies of In-Home Conversational Agent Usage, Proc. DIS 2018, pp. 857-868, 2018.
- [田中 2011] 田中文英: 幼児教育現場におけるソーシャルロボット研究とその応用, 日本ロボット学会誌 vol.29 no.1, pp.19-22, 2011.
- [高木 1997] 高木俊一郎 他: TS 式幼児・児童性格診断検査手引, 東京: 金子書房, 1997.
- [Piaget 1955] Piaget, J.: The child's construction of reality, London: Routledge & Paul, 1955.
- [Piaget 1976] Piaget, J.: Piaget's Theory, In Piaget and his school, Springer, Berlin: Heidelberg, pp. 11-23, 1976.
- [光國 2018] 光國和宏 他: ロボットの模倣行動が印象評価と援助行動に与える影響の検討情報処理学会関西支部支部大会講演論文集, D-01, 2018.

ヒューマノイド・ロボットとの対話を利用した 語用障害をかかえる人とのコミュニケーション学習

Communication Learning Support for Pragmatic Language Disorders Using a Humanoid Robot

矢吹 溪悟*¹
Keigo Yabuki

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

In this research, we developed a communication learning support system to learn appropriate dialogue method with people with pragmatic language disorders. People with pragmatic language disorders tend to have problems with interpersonal relationships with typical development because they cannot understand the meaning of ambiguous utterances. As a solution to this problem, we proposed a communication learning support system that learns the dialogue method which is easy to be conveyed to people with pragmatic language disorders, targeting typical development. This learning support system uses a humanoid robot that mimics people with pragmatic language disorders and allows the user to experience dialogue with such a person, it is possible to learn while seeking actively transmitted utterances. Results of the evaluation experiment show that the learning effect was more remarkable than the text-based approach. It was more enjoyable as well. Therefore, this communication learning support system proved to be an effective learning means.

1. はじめに

語用障害をかかえる人(主に自閉症スペクトラム障害・社会的(語用論)コミュニケーション障害の方を指す[1][2][3][4][5])と定型発達者は会話が成立しにくい。言外の意味とは、任意の言葉に含まれる意図やニュアンスのことである[6]。この要因の一つとして、語用障害をかかえる人が曖昧な発話の言外の意味を汲み取ることが困難[7]という特徴が考えられる。具体的には、曖昧な発話の意味をつかむことができない[7]、話し手の発話意図を認識できない [8]、過剰なまでに字義通りの意味として理解する [9]、会話の文脈上の話し手の発話などに関連している情報としていない情報を区別することが難しい [10]などが挙げられる。山本、楠本は、語用障害をかかえる人は曖昧な状況及び文脈の理解が困難なため対人関係に問題が生じる[11]と解説しているため、これらの特徴は対人関係に影響を及ぼしやすい。また、言外の意味を含む発話は、会話状況や文脈によって発話の字義通りの意味に対して別の意味を包含ないし示唆する場合が多く、さらに慣用表現や指示語などのように単語自体が言外の意味を示唆する表現も存在する。

しかしながら、この問題は定型発達者の対話方法にも要因がある。田中、藤原によれば、定型発達者が発話において抽象的な表現や指示語、比喩を用いた慣用表現などを用いることなく、具体的でかつストレートな表現を用いることで語用障害をかかえる人にも伝わるようになる[12]と解説している。このことから、定型発達者に対して語用障害をかかえる人との対話方法を改善させる研究を行う必要があると考えられる。

また、語用障害をかかえる人は般化の困難さから支援が難しいという問題がある。般化が困難とは、教育の場面で学習したことを生活の場面で応用することが困難なことであり、語用障害をかかえる人が般化を行うためには、膨大な時間をかけて状況に依存しない適切な学習を行う必要がある[13]。支援事例として、コミック会話と呼ばれる曖昧な発話を視覚化する手法では般化が認められず[14]、また自閉症スペクトラム障害児 1 名に、二つ

の物体に「それとって」というような曖昧な指示に対して、自発的に明確化要求が行えるよう支援を試みた結果、般化が認められるまでに 28 ヶ月間の時間を要した研究[15]などがある。これらのことから、語用障害をかかえる人に対する支援は、負担が大きすぎるという問題点がある。

さらに、定型発達者に対しての支援事例として、矢吹、角は、自閉症者との言外の意味を含む会話を支援するシリアスゲームを開発した[16]。検証の結果、自閉症に関する専門的な知識が乏しい定型発達者に、学習効果が認められた。この研究は、知識習得に重点を置いているため、実際の会話への応用はこのシステムでは保証されていない。このため、音声対話を学習に取り入れることで、実際の会話に応用しやすい学習システムを構築できると考えられる。また、日本サード・パーティ株式会社は、応用行動分析を活用し、Kinect と NAO を用いた支援者教育システムを開発した[17]。この研究では、言外の意味の問題に対する支援は行っていないが、ヒューマノイド・ロボットを用いて支援を行っているため、定型発達者への支援にヒューマノイド・ロボットの有用性が示唆されたと考えられる。

これらを踏まえ、本研究では語用障害をかかえる人の言外の意味を汲み取れない特徴から生じる対人関係の問題を定型発達者側から改善することが目的である。そのために、ヒューマノイド・ロボットとの音声対話を用いて、定型発達者が語用障害をかかえる人に伝わりやすい発話を学習するシステムを開発する。

なお、本研究で扱う曖昧な表現は指示語とする。理由は、指示語が曖昧な表現の中で、日本語の日常会話において、一番用いられることが多い曖昧な発話だと考えられるためである。また、本研究では「重度」の語用障害をかかえる人との会話を想定する。理由は、重度の人に伝わりやすい話し方は、障害の度合いが軽い人に対しても伝わりやすい表現になるからである。

2. 学習システム

本研究で提案する学習システムは、図 1 のように語用障害をかかえる人が言外の意味を汲み取ることができなかった事例をもとに、ヒューマノイド・ロボットの Pepper に語用障害をかかえる人のふるまいを再現させる。そして、そのヒューマノイド・ロボットとの音声対話を通して、語用障害をかかえる人との会話を疑似

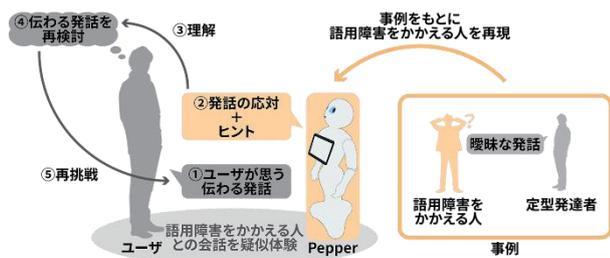


図1 学習システムの全体像

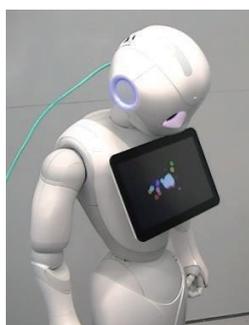


図2 「混乱」や「限定的な理解」をしたときのモーション

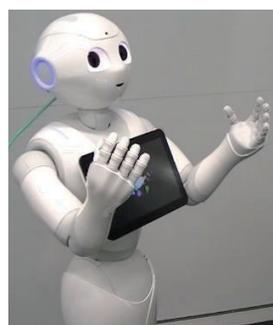


図3 「適切な対応」をしたときのモーション

体験し、ユーザの発話をベースに Pepper がヒントを与えながら、語用障害をかかえる人に伝わりやすい発話を模索しながら能動的に学習できるシステムである。

学習システムで扱った事例は、書籍[7][12]や小特集[1]に記載されている事例を参考に選出した。具体的な内容は、語用障害をかかえる人が定型発達者に本を返却しに来たとき、定型発達者が本の感想を聞くために「この本どうだった？」と発話した。このとき、「この」や「どう」の指示語を字義通りに理解してしまい、会話が成立しなくなった事例である。

全体構成として、本学習システムは「対話パート」「採点パート」「解説パート」「まとめパート」の4つから成り立っている。まず、対話パートでは、語用障害をかかえる人の振る舞いをする Pepper との対話を行うパートである。次に、採点パートでは、ユーザの発話の適切さを「○」「△」「×」で採点するパートである。そして、解説パートではユーザの発話に対して Pepper が感じたことを Pepper の心の中をのぞくという形で確認するパートである。最後に、まとめパートでは語用障害をかかえる人に伝わりやすい話し方の要点をまとめるパートである。

全体の流れは、まず「対話パート」と「採点パート」を行ったあと、採点結果から分岐が発生する。採点結果が「○」の場合は、要点の復習として「まとめパート」に行き、学習システムを終了する。一方で、採点結果が「△」や「×」の場合は、採点理由を確認するため「解説パート」に行き、ユーザの発話に対して Pepper が感じたことを確認させたのち、再度対話パートに行く流れである。なお、3回連続で採点結果が「△」や「×」の場合は、ユーザのモチベーションを考え「まとめパート」に移行する。

なお、対話パートは Pepper と会話を行うが、対話パート以外の3つパートは Pepper のタブレット上で行う。理由として、対話パートで Pepper の役割が「語用障害をかかえる人の振る舞いをする」ものであり、ユーザにアドバイスなど行う役割と差別化するために分別を行った。

また、Pepper との対話の際に、ユーザの発話に含まれる曖昧な表現の含有度合いや「本」について「誰が誰に何をどうしたのか」どの程度具体化されているかによって、Pepper の対応は大

きく分けて「混乱」「限定的な理解」「誤解・曲解」「適切な対応」の4種類に変化した。それぞれ、明確な表現がほとんどない場合は「混乱」し、明確な表現と曖昧な表現が混在している場合は、明確な表現の部分だけ理解する「限定的な理解」を示し、曖昧な表現はないものの「本」について「誰が誰に何をどうしたのか」があまり明確ではない場合は、勝手に「別の『本』」のことを聞かれていると「誤解・曲解」し対応を行い、正しい発話が行われた際に「適切な対応」を行うように設計した。

また、「混乱」「限定的な理解」のときは図2の落ち込んだモーションなどを行う。また、「適切な対応」のときは、図3の発話を理解したようなモーションなどを行う。さらに、「誤解・曲解」のときは図2と図3のモーションを組み合わせ、考え込んだあと勝手な解釈をしたことを表した。

さらに、学習者の様々な発話に対して適切な支援を行うために、公立はこだて未来大学の定型発達者13名に調査を実施し、最終的に約2800種類の発話データからなる対話コーパスを作成し、学習システムに組み込んだ。

3. 実験と結果

3.1 実験計画

実験目的は、本学習システムが、語用障害をかかえる人にも伝わりやすい発話を学習するシステムとして、有用性があるか検証することであった。検証方法として、本学習システムを用いる実験群と、臨床心理士が推薦したテキストベースの書籍[18]の抜粋資料を読む対照群の2つに群分けを行い、事前事後テストを用いて学習効果を、SD法を用いて全体の印象をそれぞれ比較実験した。実験対象は、函館市立赤川小学校に在籍する、6年生の定型発達児16名であった。また、群分けは、実験群に9名、対照群に7名とした。

実験材料として、学習効果を測定するため、事前テストおよび事後テストを作成した。これらは、語用障害をかかえる「めぐみ」と定型発達者の「ゆうき」の二人の会話状況に対して、「ゆうき」の発話が適切な対応かどうかを5択の選択肢から選ぶ形式であった。また、全3問の1問10点(30点満点)のテストであり、3問中2問が共通問題であり、非共通問題よりも難易度を上げた。また、制限時間は事前事後テストともに90秒であった。なお、問題は本学習システムで用いた事例の類似例を、語用障害をかかえる人の特徴を考慮しながら考案した。また、実験材料として、全体の印象を測定するため、SD法によるアンケートを作成した。SD法の尺度は「良い | 悪い」「重い | 軽い」「嫌いな | 好きな」「温かい | 冷たい」「楽しい | つまらない」「硬い | 柔らかい」「難しい | 易しい」「積極的な | 消極的な」「親しみやすい | よそよそしい」「暗い | 明るい」の10項目であった。また、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。集計方法は、「どちらでもない」を0点とし、左側の「非常に」「かなり」「やや」をそれぞれ-3点、-2点、-1点で、右側の「やや」「かなり」「非常に」をそれぞれ1点、2点、3点で集計した。

実験手続きとして、まず実験説明(2分)を行い、次に事前テスト(2分(説明30秒+テスト90秒))を行った。そして、実験刺激(5分程度)を用いてもらった。その後、事後テスト(2分(説明30秒+テスト90秒))とアンケートのSD法(3分程度(説明30秒+アンケート2~3分))を行った。

3.2 実験結果

事前事後テストの結果として、表1に事前事後テストの記述統計を示した。これについて、分散分析を行ったところ、交互作用

表1 事前事後テストの記述統計

テスト名	A群 (実験群)		B群 (対象群)	
	平均値	標準偏差	平均値	標準偏差
事前テスト	5.556	7.265	5.714	7.868
事後テスト	17.778	8.333	7.143	7.559

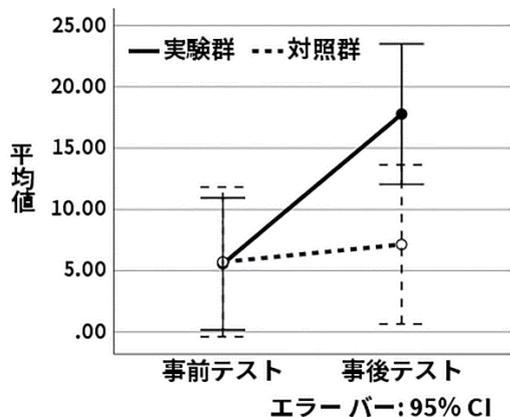


図4 分散分析を踏まえた事前事後テストの平均値の推移

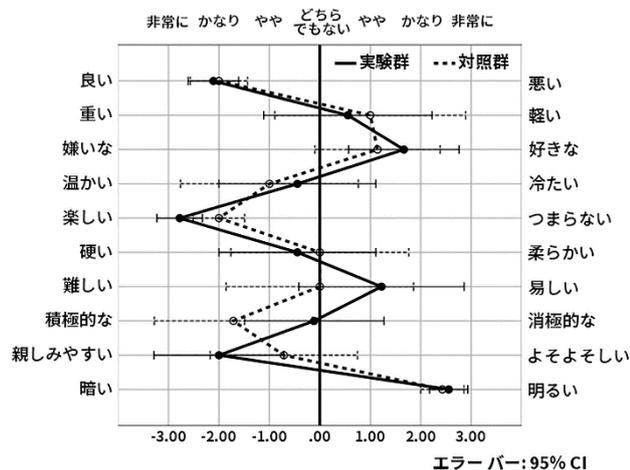


図5 セマンティック・プロフィール

表2 因子分析における因子負荷量と因子解釈

SD法の尺度 (右側)	因子				共通性
	1	2	3	4	
よそよそしい	-0.893	0.085	-0.001	-0.057	0.808
好きな	0.641	0.079	0.307	0.151	0.534
軽い	0.479	-0.210	0.410	0.405	0.606
明るい	0.335	0.181	-0.064	-0.200	0.190
消極的な	-0.230	0.937	0.092	0.294	0.999
冷たい	0.237	0.728	0.060	-0.214	0.634
柔らかない	-0.182	-0.226	-0.889	0.058	0.877
つまらない	-0.059	-0.336	0.387	0.228	0.318
易しい	0.273	-0.162	-0.160	0.779	0.733
悪い	-0.079	0.104	0.152	0.455	0.247
因子負荷量	1.776	1.699	1.267	1.231	
累積寄与率	17.759	34.750	47.424	59.735	
因子解釈	友好的	陰湿的	既存性	簡易性	

が10%水準で有意傾向(F(1, 14)=3.15, p<.1, 偏η²=0.18)であった。単純主効果の検定から、実験群の単純主効果が5%水準で有意(F(1, 14)=9.22, p<.05, 偏η²=0.40)であり、事後テストの単純主効果が5%水準で有意(F(1, 14)=6.94, p<.05, η²=0.33)

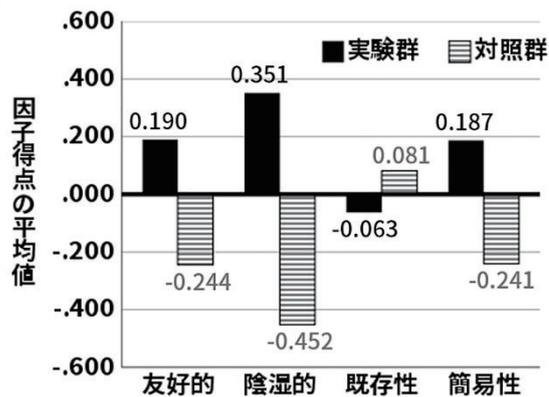


図6 各因子の因子得点の平均値

であった。なお、それ以外について有意差はなかった。また、図4に分散分析を踏まえた平均値の推移について図示した。

SD法の結果として、図5にセマンティック・プロフィールを示した。これについて、対応のないt検定を行ったところ、「楽しい|つまらない」の尺度に対して、5%水準で有意であった(t(14)=-2.45, p<.05, r=0.55)。なお、それ以外について有意差はなかった。また、因子分析の結果として、表2に因子負荷量と採用された因子の解釈を示した。なお、網掛けは「0.35」以上の値を表した。結果、「友好的」「陰湿的」「既存性」「簡易性」の4因子が採用された。また、図6に因子得点の平均値を示した。

4. 考察

事前事後テストの結果から、まず、実験群の単純主効果の結果から、本学習システムを単体でみたとき、語用障害をかかえる人にも伝わりやすい話し方を学習するシステムとして高い学習効果が認められた。このことから、母集団においても、本学習システムを用いることで高い学習効果をもたらすことが期待できると考えられた。また、事後テストの単純主効果の結果から、本学習システムはテキストベースの教材と比べ、語用障害をかかえる人にも伝わりやすい話し方を学習するシステムとして有効な学習手段であることが認められた。このことから、母集団においても、テキストベースの教材と本学習システムの学習効果を比較したとき、本学習システムを用いたほうが高い学習効果をもたらすことが期待できると考えられた。

ただし、実験群の事後テストの平均値が30点満点中17.778点であり、10点以上も伸び代があることから、現状では1回の学習にて本学習システムで学習可能な範囲を網羅することは難しいと考えられる。このような結果となった要因として、現状では3回間違えるとまとめパートに移行する仕様となっているため、学習者は最大3回までしかトレーニングする機会がなく、この回数が少ないことが要因の一つとして考えられる。また、現状では学習した知識を応用できる場が学習システム内にはないことも要因として考えられる。解決策として、まとめパートに強制的に向かうまでの間違いの回数を、モチベーションを維持できる範囲内で増やすことや、本学習システム内で獲得した知識をどれだけ応用できるか確認できるテストを加えるなど、現状よりもさらに繰り返して学習できる機能を加えることが考えられる。

また、SD法の「楽しい|つまらない」の尺度に対するt検定の結果から、本学習システムはテキストベースの教材と比べ、学習教材の楽しさという観点が顕著であった。このことから、母集団においても、テキストベースの教材と本学習システムの印象を比較したとき、本学習システムのほうが「楽しい」という観点から高い評価がなされることが考えられる。

さらに、「友好的」に対する因子得点の平均値から、本学習システムはテキストベースの教材よりも、学習者に対して友好的な印象を与えたと考えられる。このような印象を持たれた要因として、本学習システムはテキストベースの教材には存在しない、ヒューマノイド・ロボットの Pepper との会話を通して学習する形式であることから、Pepper が友好的な印象を持たれたと推察できる。

また、「簡易性」に対する因子得点の平均値から、本学習システムはテキストベースの教材よりも、学習者に対して教材の難易度が簡易な印象を与えたと考えられる。これは、教材が扱っている題材が同一にもかかわらず、本学習システムのほうが学習内容が簡単な印象を持たれたと推察できる。このような印象を持たれた要因として、本学習システムは語用障害をかかえる人との会話を疑似体験し、さらに話し方の伝わりやすさを即座にフィードバックを得られるため、テキストベースの教材よりも学習者が問題点を認識しやすく、学習中の疑問を解決する機会があったと推察できる。

しかしながら、「陰湿的」に対する因子得点の平均値から、本学習システムはテキストベースの教材よりも、学習者に対して陰湿的な印象を与えたと考えられる。また、「既存性」に対する因子得点の平均値から、本学習システムはテキストベースの教材と比べ、教材の既存的な印象にあまり大きな変化がみられなかった。これは、学習形式がまったく異なるにもかかわらず、テキストベースの教材と比べあまり斬新な教材ではなかったと推察できる。このような印象を持たれた要因として、採点・解説・まとめパートではテキストベースの教材と同様に学習者が一方的に画像を見るような形式であったことが要因として考えられる。解決策として、音声や効果音を付与するなどエンターテインメント性を追加することで、採点・解説・まとめパートに既存の教材や陰湿的なイメージを払拭する必要と考えられる。

最後に、考察のまとめとして、本学習システムはテキストベースよりも高い学習効果が認められ、学習を行いやすい環境を提示できる有効な学習手段であることがわかった。

このことから、結論として、本学習システムは、定型発達者に語用障害をかかえる人にも伝わりやすい話し方を学習するシステムとして有用性が認められ、本研究の目的を達成できる学習手段であることがわかった。

展望として、確認テストなどを追加し現状よりもさらに繰り返し学習できる機能を加えることや、音声や効果音を付与するなどエンターテインメント性を追加することで既存の教材や陰湿的なイメージを払拭することがあげられた。

5. まとめ

語用障害をかかえる人は言外の意味の理解が困難であることから対人関係に問題をかかえる傾向があり、それは定型発達者が具体的でストレートな表現で発話することが解決策であった。そして、定型発達者が語用障害をかかえる人に伝わりやすい発話を能動的に学習することができる、ヒューマノイド・ロボットとの音声対話を利用したコミュニケーション学習支援システムを開発した。検証の結果、本学習システムはテキストベースよりも高い学習効果が認められ、学習を行いやすい環境を提示できる有効な学習手段であることがわかった。結論として、本学習システムは、定型発達者に語用障害をかかえる人にも伝わりやすい話し方を学習するシステムとして有用性が認められ、本研究の目的を達成できる学習手段であることがわかった。

6. 謝辞

学習システムの評価実験における比較対象として、テキストベースの教材を推薦していただいた、社会福祉士および臨床

発達心理士の宮城大学感性デザイン学系橋本陽介助教に感謝の意を表します。さらに、実験および調査にご協力いただいた、公立ほこだて未来大学ならびに函館市立赤川小学校のみなさまに感謝の意を表します。

参考文献

- [1] 大井学:「誰かお水を運んで来てくれるといいんだけどな」:高機能広汎性発達障害へのコミュニケーション支援, 聴能言語学研究, Vol.19, No.3, pp.224-229(2002).
- [2] 大井学:高機能広汎性発達障害にともなう語用障害:特徴, 背景, 支援, コミュニケーション障害学, Vol.23, No.2, pp.87-104(2006).
- [3] Oi, M.: Interpersonal compensation for pragmatic impairments in Japanese children with Asperger syndrome or high-functioning autism, J. Multiling. Commun. Disord, Vol.3, No.3, pp.203-210(2005).
- [4] American Psychiatric Association.: Diagnostic and Statistical Manual of Mental Disorders: DSM-IV-TR, Amer Psychiatric Pub Inc (2000).
- [5] American Psychiatric Association.: Diagnostic and Statistical Manual of Mental Disorders: DSM-V, Amer Psychiatric Pub Inc (2013).
- [6] ヒューマンアカデミー:日本語教育教科書 日本語教育能力検定試験 50音順 用語集, 翔泳社(2013).
- [7] 内山登紀夫:アスペルガー症候群を知っていますか?, 東京都自閉症協会(2002).
- [8] フリス, U. : 自閉症の謎を解き明かす, 東京書籍(1991).
- [9] Mitchell, P., Saltmarsh, R. and Russell, H.: Overly literal interpretations of speech in autism: Understanding that messages arise from minds, J. Child Psychol. Psychiat, Vol.38, No.6, pp.67-691(1997).
- [10] Baltaxe, C.A.M.: Pragmatic deficits in the language of autistic adolescents, J. Pediat. Psychol, Vol.2, No.4, pp.176-180(1977).
- [11] 山本淳一, 楠本千枝子:閉症スペクトラム障害の発達と支援, Cognitive Studies, Vol.14, No.4, pp.621-639(2007).
- [12] 田中哲, 藤原里美(監修):自閉症スペクトラムのある子を理解して育てる本, 学研プラス(2016).
- [13] 日本自閉症スペクトラム学会(編):自閉症スペクトラム辞典, 教育出版(2015).
- [14] Gray, C.: Comic Strip Conversation, Future Horizons Inc. (1994).
- [15] 吉井勘人, 仲野真史, 長崎勤:自閉症児に対する会話の修復機能としての明確化要求の発達支援-明確化要求の表出タイプの出現順序, 共同行為ルーティンの役割, 明確化要求の表出と欲求意図理解との機能連関に焦点を当てて-, 特殊教育学研究, Vol.53, No.1, pp.1-13(2015).
- [16] 矢吹溪悟, 角薫:言外の意味 ZERO:定型発達者のための自閉症者との対話方法を学習するシリアスゲーム, 情報処理学会論文誌, 情報処理学会, Vol.59, No.11, pp.1934-1952(2018).
- [17] VR Inside:VR やロボットでセラピスト養成を効率化! 自閉症療育セラピスト育成プログラムで技術協力, VR/AR/MRの未来を創るビジネスニュースメディア(オンライン), 入手先 <<https://web.smartnews.com/articles/fluvVSGHJJT>>(参照日:2019-01-16).
- [18] shizu, 平岩幹男(監):発達障害の子どもを伸ばす魔法の言葉かけ, 講談社(2017).

話者の性格特性を考慮した対話音声からの対話雰囲気推定

Dialogue Mood Estimation from Dialogue Voice Considering Personality Trait of Speaker

長谷川達也 *1 加藤昇平 *1*2
Tatsuya Hasegawa Shohei Kato

*1名古屋工業大学 大学院工学研究科情報工学専攻

Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology

*2名古屋工業大学 情報科学フロンティア研究院

Frontier Research Institute for Information Science, Nagoya Institute of Technology

For natural conversation with people, dialogue system has to return an appropriate reaction depending on dialogue mood. In this study, we aim to develop a method of estimating dialogue mood for that. We conducted the experiment to collect dialogue speech data, dialogue mood evaluation, and personality traits of subjects. Dialogue speech data and dialogue mood evaluation was used for calculating intervals of utterance state. Our method estimated dialogue mood by these feature values. In this paper, we verify effectiveness of personality traits added this time and the method of dialogue mood estimation. As a result, personality traits are effective on dialogue mood estimation in a part of dialogue mood labels, and the result suggests relevance of personality features with dialogue mood.

1. はじめに

近年、人と対話システムによるコミュニケーションを目的とした研究が盛んに行われている。具体的には、コミュニケーションにおけるシステムに対するユーザの親しみやすさの向上を目的とした研究 [福田 18] や、システムとユーザとの対話がより自然に行われることを目指した研究 [小林 15][高杉 10] などがあげられる。これらの研究は、人とシステムとの一対一のコミュニケーションを目的としており、人とシステムとが対等な立場で対話することを目指しているといえる。

人とシステムが対等な立場で対話するためには、システムに対する人側からの配慮を減らす必要がある。そのための方法の一つとして、対話の雰囲気に応じた適切な反応を返すことが考えられる。適切な応答を返すには対話雰囲気を推定する機能が不可欠である。そこで、本研究では対話の雰囲気を推定するシステムの構築を目指す。

そのためにまず、人とシステムとの対話の雰囲気を推定する要素研究として、1対1対話に焦点を当てた対話雰囲気の推定を試みた。本稿では、雰囲気ラベル付き音声データセットの収集実験と、それに基づく推定手法および特徴量を検討する。

2. 関連研究

人同士のコミュニケーション時の対話雰囲気を扱う研究として、Wredeら、徳久ら、稲葉ら、豊田らなどの研究があげられる。Wredeらは、議論の盛り上がりに応じて、対話音声を4クラスに分類し、各クラスごとに韻律特徴と発話の種類を表す Dialogue Act(DA) タグによる分析を行った [Wrede1 03][Wrede2 03]。徳久らは、DA タグと修辭構造を表す Fhetorical Relation タグを用いて、それぞれのタグと対話の盛り上がりとの関係性について分析した [徳久 06]。稲葉らは、テキスト対話の単語の共起情報から対話の雰囲気推定を行った [稲葉 11]。これらの研究では、タグやテキストなどの言語情報を利用しているが、

実際の対話中にこういった情報を正確に抽出するのは難しく、本研究の目的である人とのコミュニケーションに活かす対話雰囲気推定システムの構築には利用できないと考えた。また、豊田らは、対話時の発話時間特徴に着目して、第三者視点からの対話雰囲気推定を行った [豊田 12]。発話時間特徴は言語情報や韻律情報などとは違い、抽出において高い計算コストを必要としない。また、マイクの距離や発話音量の個人差などの影響を受けない。そのため、実際の対話中に情報を抽出することを考えても、対話雰囲気推定システムを構築するうえで扱いやすい特徴量であるといえる。だが、一対一のコミュニケーションにおいてこのシステムを使用することを考えると、推定の視点が第三者であるため、システム自身が対話するうえで活用するのが困難ではないかと考えられる。

非言語情報と対話雰囲気との関連を調査した研究として Gatica-Perezら、伊藤ら、森らの研究がある。Gatica-Perezらは、会議中の動画と音声を用いて議論の盛り上がり部分の推定を行っている [Gatica-Perez 04]。伊藤らは、2者による自由対話を「盛り上がり」「盛り上がっていない」の2クラスに分類し、各クラスごとに話者の発話および動作との関係性の分析を行っている [伊藤 02]。森らは、対話を発話時と非発話時の2つの状態に場合分けを行い、状態毎の各話者の顔表情に基づいて対話雰囲気の推定を行っている [森 10]。しかし、これらの研究に用いられる動作認識や顔表情認識は高い計算コストを必要とし、人とのリアルタイムなコミュニケーションには向いていないと考えられる。

本研究では、豊田らの研究でも用いられた発話時間特徴を対話雰囲気の推定に利用する。ただ、対話への介入を想定しているわけではないため、本研究において使用する特徴量の有効性の検証および、より適切な特徴量の選定が必要である。

3. 対話雰囲気推定システム

図1に本研究で想定している対話雰囲気推定システムの概要図を示す。本システムは、話者自身の視点から見た対話雰囲気を推定するために、特徴量を入力する際に話者とその対話相手の

連絡先: 加藤昇平, 名古屋工業大学, 愛知県名古屋市昭和区御器所町, 052-735-5625, shohey@katolab.nitech.ac.jp

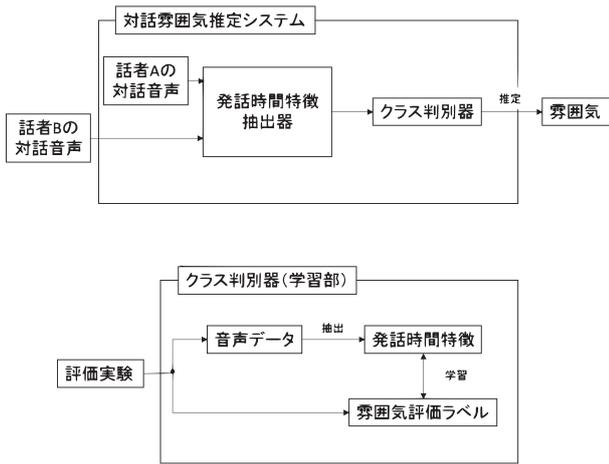


図 1: 対話雰囲気推定システム

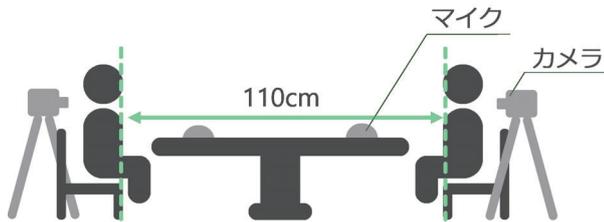


図 2: 対話実験の模式図



図 3: 対話実験の手順

音声をそれぞれ決まった形で特徴量抽出器に入力する。

具体的には、話者自身の音声（対話システムの場合は、システム発声情報）を話者 A 側、話者から見た対話の相手の音声を話者 B 側の対話音声としてそれぞれ入力する。入力後、今回使用する特徴量の 1 つである発話時間特徴を算出し、クラス判別器の入力として用いる。そして、クラス判別器から得られた出力を、入力とした対話音声における対話雰囲気の推定結果として出力する。

4. 対話雰囲気評価実験

4.1 実験概要

実験協力者は 18~24 歳の大学生 28 名（男性 13 名、女性 15 名）であり、全員がそれぞれ 1 回ずつ実験に参加した。実験の組み合わせとして、「男性 - 女性」5 組、「男性 - 男性」4 組、「女性 - 女性」5 組の計 14 組により実施した。図 2 に実験の概要図を示す。実験は、2 人 1 組で対面に着席させた状態で、対話時のそれぞれの様子を音声及び動画で計測する。図 3 に実験手順を示す。まず、推定システムの入力の 1 つである性格特徴を得るために、協力者に自信の性格評価に関するアンケートに回答させた。続いて、実験者は事前に用意した話題の中からランダムに 1 つ提供し、実験室から退室した。実験協力者には提供した話題になるべく沿う形で 5 分間の対話をさせた。対話終了後、計測した音声から音声区間抽出を行い、それぞれを実験協力者に順に聴取させる。実験協力者には区間ごとで

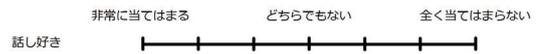


図 4: 性格評価アンケートの例

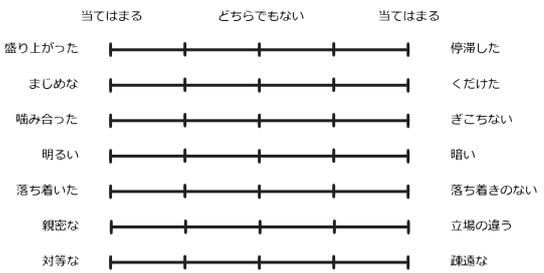


図 5: 対話雰囲気評価アンケートの構成

話雰囲気評価を行わせた。最後に、対話相手に関する評価をさせ、実験は終了した。

4.2 性格評価の方法

対話の前に、実験協力者には自身の性格評価をさせるためのアンケートに回答してもらった。アンケートは和田らの全 60 項目からなる日本語版 BigFive 尺度 [和田 96] を用いた。図 4 に、実験で用いたアンケートから 1 項目を例として示す。それぞれの項目が自分にどれだけ当てはまるかで 7 件法により回答してもらった。

4.3 音声区間抽出

音声区間の抽出は以下の手順で行った。まず、抽出する区間を選ぶ前に、計測した音声に対して発話区間検出をかける。発話区間検出は音声を有聲区間と無聲区間のそれぞれの系列に分割するために行う処理である。分割した区間のうち、無聲区間として検出されたものの開始時刻と終了時刻を記録し、それを基に評価対象の音声区間を抽出する。抽出する区間の選定基準としては、「区間の両端が 0.3 秒以上の無聲区間」、かつ「どちらの実験協力者も一度以上は発話している」とした。そして、全体の音声データからこの基準を満たす 20-40 秒の時間長をもつ区間を抽出した。また、抽出した区間に時間軸的な偏りがあると、類似したデータが集中してしまうと考えた。そのため、音声データ全体を 4 つの区間に分割し、それぞれに評価対象ができるだけ存在するように選定した。区間に選定基準を満たすものがない場合は、時間軸上でその区間のできるだけ近傍に存在できるように選定した。なお、本条件で候補区間が不足するという事象は全実験を通して観測されなかった。

4.4 対話雰囲気評価の方法

音声区間抽出後、実験開始時刻に近いものから順に、4 つの音声区間の対話雰囲気を実験協力者に評価をさせた。図 5 に、実験協力者に対して対話雰囲気の評価をさせる際に用いたアンケートの構成を示す。アンケートには対話雰囲気を表す形容詞 7 種を用いる。左側の形容詞は対話雰囲気のラベルの意味をそのまま表すような、右側の形容詞は左側の形容詞を否定するような意味を持つような形容詞をそれぞれ配置した。対話実験の後、実験者が実験時の音声から抽出した評価対象の区間を順に聴取させる。実験協力者には、それぞれの区間ごとで、対話時にどのような印象を対話に対して持っていたかを思い出させながらアンケートに回答させた。対話直後に実験協力者に直接評価させるのは、作成した音声区間に対して、対話者視点での対話雰囲気ラベルを付与するためである。

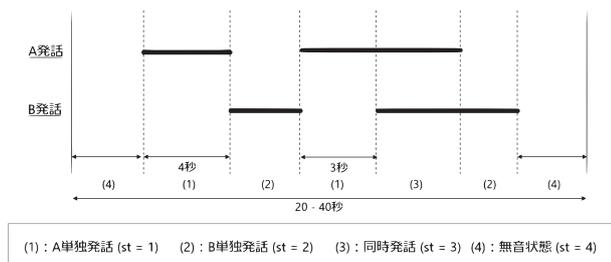


図 6: 発話状態の分割例

5. 特徴量

5.1 性格特徴

性格評価によって得られた評価データから, Big Five 尺度において個人の性格特性を表す「外向性因子」「神経症傾向因子」「開放性因子」「誠実性因子」「調和性因子」をそれぞれ算出する. 本稿では, これらすべてを性格特徴として対話雰囲気推定で使用し, それぞれに特徴番号 001-005 を割り振る. 個人の性格特徴を特徴量として用いることで, 被験者属性を考慮した推定ができるため, 対話雰囲気の捉え方における個人差を軽減できると考え, 対話雰囲気推定の特徴量として採用した.

5.2 発話時間特徴

対話者 A, B をそれぞれの実験協力者とする. 本研究では対話者 2 名の発話状態 st を次のように定義する.

$$st = \begin{cases} 1 & \text{(A 単独発話状態)} \\ 2 & \text{(B 単独発話状態)} \\ 3 & \text{(同時発話状態)} \\ 4 & \text{(無音状態)} \end{cases}$$

実験時に抽出した音声をそれぞれ上記の 4 つの状態の系列に分割し, それぞれ開始時刻と終了時刻の差をとって時間長を算出する. そして, それらを要素とする状態毎の多重集合 S_{st} を生成し, 発話時間特徴の算出に利用する. 図 6 に, 対話 d における発話状態の分割例を示す. この場合, A 単独発話 ($st = 1$) は 2 秒, 3 秒があり, 多重集合 $S_1^d = \{2, 3\}$ となる.

表 1 に発話状態集合から算出する計 95 種の発話時間特徴とその算出式例を示す. このうち, 特徴番号 006-025 の計 20 種は発話時間統計特徴である. 4.1 で定義した発話状態集合 S_{st}^d を基に以下に示す 5 種類の関数によって統計量を算出する.

$\text{mean}(S_{st}^d)$: 発話状態集合 S_{st}^d の平均
$\text{var}(S_{st}^d)$: 発話状態集合 S_{st}^d の分散
$\text{min}(S_{st}^d)$: 発話状態集合 S_{st}^d の最小値
$\text{max}(S_{st}^d)$: 発話状態集合 S_{st}^d の最大値
$\text{occupy}(S_{st}^d)$: 発話状態 st の評価区間内における占有率

また, 特徴番号 026-100 の計 75 種は話者間時間特徴であり, それぞれの発話時間統計特徴を st の各状態の発話時間統計特徴間で比較するための指標である. 表 1 における関数 $\text{stat}(S_i^d)$ は先述した 6 種の関数のうちのいずれかを適用することを表す. 発話状態間の比較は, 対話における話者間の状態を明らかにできるため, 今回用いる特徴量として有効であると考えた.

表 1: 発話時間特徴

特徴番号	特徴量	算出式例
006 - 010	A 発話に関する統計量	$\text{stat}(S_1^d)$
011 - 015	B 発話に関する統計量	$\text{stat}(S_2^d)$
016 - 020	同時発話に関する統計量	$\text{stat}(S_3^d)$
021 - 025	無音時間に関する統計量	$\text{stat}(S_4^d)$
026 - 045	A 発話と B 発話の比較	$\frac{\text{stat}(S_1^d)}{\text{stat}(S_1^d) + \text{stat}(S_2^d)}$
046 - 050	発音状態と無音状態の比較	$\frac{\text{stat}(S_4^d)}{\sum_i^3 \text{stat}(S_i^d)}$
051 - 070	全状態における各状態の割合	$\frac{\text{stat}(S_1^d)}{\sum_i \text{stat}(S_i^d)}$
071 - 085	A 発話と同時発話の比較	$\frac{\text{stat}(S_3)}{\text{stat}(S_1) + \text{stat}(S_3)}$
086 - 100	B 発話と同時発話の比較	$\frac{\text{stat}(S_3)}{\text{stat}(S_2) + \text{stat}(S_3)}$

6. 対話雰囲気推定実験

6.1 実験概要

対話実験から得られた学習サンプル 100 個による Leave-Human-Out クロスバリデーションによる性能評価を行う. 今回行った対話実験の中で, 性格評価において未入力 of 箇所があった実験協力者が 3 名いたため, 残りの 12 個は学習サンプルとして今回使用しないこととする. Leave-Human-Out クロスバリデーションとは, テストデータと同一人物のデータを学習データに含まない検証方法である.

推定における目標出力として, 評価実験で収集した対話雰囲気評価ラベルを用いる. クラス分けの方法については, どちらでもないより左側なら肯定, 右側なら否定, 真ん中を直接回答した場合のみ中間とした.

本稿では, 以前我々[長谷川 18] が提案した発話時間特徴のみを特徴量とした Random Forest による推定手法と, 性格特徴を特徴量として新たに追加した Random Forest による推定手法とを推定性能により比較し, 性格特徴の対話雰囲気推定における有効性を検討する.

6.2 実験結果

表 2 に, 比較したそれぞれの手法の推定結果から得られた F 値と正答率を示す. 「盛り上がり」「まじめさ」「囁み合い」「明るさ」の 4 つラベルにおいて, 先行研究と本実験のそれぞれの正答率に対して二項検定を行ったところ, 有意水準 5% を満たした. このことから, これらのラベルについては, 性格特徴が推定において有効であったと考えられる.

6.3 考察

今回, 性格特徴を特徴量として追加したうえで作成した推定器をラベル別に見ると, 有意差が確認されたラベルと確認されなかったラベルの両方が存在した. つまり, 本稿で使用した性格特徴における被験者属性の構成要素に, 推定において適切な要素があったラベルと, 適切な要素がなかったラベルが存在したということになる.

表 3 に, 有意差が確認されたそれぞれのラベルにおいて, 重要度が割り当てられた性格特徴の特徴番号を重要度の高い順で示す. ラベルによって性格特徴の構成要素における優劣が異なる

表 2: 異なる特徴量による Random Forest の推定結果の比較

対話雰囲気ラベル	特徴量 1		特徴量 2	
	F 値	正答率 (%)	F 値	正答率 (%)
盛り上がり	0.312	46.0	0.344	49.0
まじめさ	0.365	46.0	0.403	56.0
噛み合い	0.294	49.0	0.364	54.0
明るさ	0.285	44.0	0.364	56.0
落ち着き	0.355	46.0	0.356	46.0
親密さ	0.318	44.0	0.343	46.0
対等さ	0.279	38.0	0.318	45.0

特徴量 1: 発話時間特徴のみ

特徴量 2: 性格特徴 + 発話時間特徴

表 3: Random Forest で重要度を割り振られた性格特徴一覧

対話雰囲気ラベル	重要度が割り振られた性格特徴
盛り上がり	002, 001, 004, 005
まじめさ	001, 005, 003, 002, 004
噛み合い	001, 005, 002, 003, 004
明るさ	003, 001, 002, 005, 004

※割り振られた重要度の高い順

り、重要度が割り当てられていないものも存在していることがわかる。

これらを踏まえると、対話雰囲気ラベルごとに関係してくる被験者属性が違ってくのではないかと考えられる。ラベルごとにそれぞれ適した被験者属性による特徴量を構成することができれば、各ラベルに対する推定性能向上が期待できる。

また、被験者属性を特徴量として使用するのではなく、被験者属性によって実験協力者のクラスタリングを行い、クラスタごとで推定器を作成することで、被験者属性を考慮した推定をすることが可能である。ただし、この方法を用いる場合、各クラスタにデータが分散してしまうため、その分の各推定器に対する学習データ数の不足が課題となる。

7. おわりに

本稿では、対話雰囲気ラベル付き音声データセットの収集実験と対話雰囲気推定実験とそれを用いる特徴量についての考察を述べた。推定実験では、発話時間特徴のみを用いた Random Forest 推定器と、発話時間特徴と性格特徴を用いた Random Forest とを比較した。その結果、一部のラベルにおいて性能向上を確認し、今回における性格特徴の一部のラベルに対する対話雰囲気推定への有効性が示唆された。

また、今回使用した性格特徴は、一部のラベルにおいて有効でなかった。性格特性の特徴量としての使用方法を変更するか、他の被験者属性を導入する必要があると考えられる。他の被験者属性の具体的な例としては、実験協力者の年齢や性別などがあげられる。

今後は、各ラベルにおける有効な特徴量の検討および被験者属性を用いた学習データのクラスタリングを検討することで、より精度の高い対話雰囲気推定システムの構築を目指す。

参考文献

- [Gatica-Perez 04] Gatica-Perez, D., McCowan, I. A., Zhang, D., and Bengio, S.: Detecting Group Interest-level in Meetings, Idiap-RR-51-2004, IDIAP, Martigny, Switzerland, 2004
- [Wrede1 03] Wrede, B. and Shriberg, E: The Relationship between Dialogue Acts and Hot Spots in Meetings in PROC, IEEE Automatic Speech Recognition and Understanding Workshop(ASRU, Virgin Is-lands(2003)
- [Wrede2 03] Wrede, B. and Shriberg, E: Spotting “Hot Spots” in Meetings : Human Judgments and Prosodic Cues, in Proc. Eurospeech, pp.2805-2808(2003)
- [稲葉 11] 稲葉通将, 烏海不二夫, 石井健太郎: 語の共起情報を用いた対話における盛り上がりの自動判定, 電子情報通信学会論文誌.D, 情報・システム, Vol.94, No.1, pp59-67(2011)
- [伊藤 02] 伊藤秀樹, 重野真也, 西野卓也, 荒木雅弘, 新美康永: 対話における雰囲気分析, 情報処理学会研究報告. SLP, 音声情報処理, Vol.2002, No.10, pp.103-108(2002)
- [小林 15] 小林弘幸, 大村卓矢, 山本知仁: 音声対話システムにおける挨拶発話の適切なタイミング生成, 計測自動制御学会論文集, Vol.51, No.4, pp233-239(2015)
- [高杉 10] 高杉将司, 吉田祥平, 沖津健吾, 横山正典, 山本知仁, 三宅美博: コミュニケーションロボットとの対話における交代潜伏長と傾き先行時間長の影響評価, 計測自動制御学会論文集, Vol.46, No.1, pp.72-81(2010)
- [徳久 06] 徳久良子, 寺寫立太: 雑談における発話のやりとりと盛り上がり関連, 人工知能学会論文誌, Vol.21, pp.133-142(2006)
- [豊田 12] 豊田薫, 宮越喜浩, 山西良典, 加藤昇平: 発話時間長に着目した対話雰囲気推定, 人工知能学会論文誌 27 巻 2 号 SP-B, pp16-21(2012)
- [長谷川 18] 長谷川達也, 加藤昇平: Random Forest を用いた発話時間特徴からの対話雰囲気推定, 第 14 回日本感性工学会春季大会 (2019(to appear))
- [福田 18] 福田和彰, 加藤昇平: 親しみやすい感性対話エージェントの実現に向けた動的思考更新手法, 電気学会論文誌 C (電子・情報・システム部門誌), Vol.138, No.12, pp1485-1492(2018)
- [森 10] 森博章, 宮脇健三郎, 西口敏司, 佐野睦夫, 山下信行: グループ感情場モデルによる感情推定方式の検討, 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解, Vol.109, No.470, pp519-523(2010)
- [和田 96] 和田さゆり: 性格特性用語を用いた Big Five 尺度の作成, 心理学研究, 第 67 巻第 1 号

ことば遊びを通して言語発達を促すインタラクションモデル -認知アーキテクチャを用いた検討-

Interaction Model Promoting Language Development through Japanese Word Play
-A Study using a Cognitive Architecture-

西川 純平*¹ 森田 純哉*¹
Jumpei Nishikawa Junya Morita

*¹静岡大学情報学部
Faculty of Informatics, Shizuoka University

Children usually acquire language through interactions with others. Some researches have focused on Shiritori game, which is a popular Japanese word play, as a means of fostering language acquisition. In this research, in order to examine how the interactions with others contribute learning of languages, we constructed a model in which two agents interactively execute Shiritori game by using the cognitive architecture ACT-R. From the results of the simulation experiment, it can be seen that as the Shiritori game progresses, the similarity of knowledge structures between the two agents is increasing. In the future, by improving the model, we will closely investigate the change of knowledge through the interactive process of Shiritori game, aiming to develop a supporting method for children who have difficulties of language acquisition.

1. はじめに

人間の認知機能に関わる研究の進展によって、後天的な要因による失語症だけでなく、自閉症などの先天性の障害に由来する言語発達遅滞についても、その原因や対処が理解されるようになった。こういった背景から、近年、言語の習得を支援することに关わる研究が盛んになっている。

典型的な言語の獲得プロセスにおいて、乳幼児は養育者のふるまいを観察し、その模倣を行うことで言語を獲得していく [Tomasello 99]。このプロセスのなかで、乳幼児は、音の分節化のパターン、記号と対象の対応関係など、膨大なパラメータの値を、生得的に埋め込まれた制約に誘導されながら推定している。それに対し、言語発達遅滞者の言語習得においては、共同注視や役割交代を伴う模倣など、本来は生得的に備わる社会認知的機能を有効に活用することが困難である [Baron-Cohen 97]。

言語は本来、社会的な営み、すなわち人と他者とのインタラクションのなかで習得される。そのため、上述のような社会認知的機能に関わる障害をもつ人を支援するためには、言語の習得を促すインタラクションの条件を網羅的に探索する必要がある。そのためのツールとして、著者らは、計算機上での認知機能のモデル化とシミュレーションが有効と考える。

上記の背景から、本研究では、インタラクションを含むことば遊びをモデル化することを目的とする。ことば遊びのなかで言語習得のつまずきが解決される要因を調査し、より効果的に言語を習得するインタラクションの要素を検討する。

本研究の特徴は、ことば遊びを利用すること、認知アーキテクチャの知識やパラメータの変更によって、多様な個人間のインタラクションを検討することにある。前者のゲームとして、しりとりを扱う。後者の認知アーキテクチャには ACT-R (Adaptive Control of Thought-Rational) [Anderson 07] を用いる。

本稿の構成は次の通りである。まず、2 節にて本研究と関連する研究をレビューする。そののちに、本研究で実装を進めているプロトタイプモデルとモデルを用いたシミュレーションを

示す。最後に現状のまとめと今後の課題を示す。

2. 関連研究

2.1 しりとりの利用

しりとりは実装の容易さから、人と相互作用する様々なエージェントに組み込まれてきた。たとえば、しりとり課題中の言い淀みや間などを調整することで、ユーザがよるエージェントに感じる人間らしさの知覚を増強する研究などが行われている [大藤 17, 阪本 11]。

山本と柏原による研究 [山本 89] では、学習者の語彙モデルを構築する学習支援システムのなかで、タスクのひとつとして英単語によるしりとりを課している。

失語症の治療、あるいは自閉症の療育など、言語聴覚療法においても、しりとりは頻繁に用いられている。いくつかの論文の中で、療育中の自閉症児の検査にしりとりが利用されている [大石 94, 日山 12]。しりとりを可能にする条件は、定型発達の幼児を対象とした高橋の横断的調査によって明らかにされている [高橋 97]。この調査によれば、しりとりを遂行するためには、音を音素に分割する音韻意識や音韻による索引が付与された心的な語彙辞書が必要であること、音韻による語彙への索引付けに、かな文字の獲得が有効であることを示している。さらに、しりとりの遂行に必要な音韻意識を持たない子供であっても、ヒント提示などの大人の援助により、遊びの活動に参加可能であることも示されている。このことから高橋は「子ども達はことば遊びの活動に最初は周辺的に参加して行く中で音韻意識が高まって行き、それを支えとして文字の読みを習得する、といった過程をたどる」と考察している。

2.2 認知アーキテクチャの利用

認知アーキテクチャは、個別の課題において生起する認知プロセスをモデル化する基盤である。認知アーキテクチャを利用したモデルにより、課題の達成に関わる要因を切り分けたモデルを構築できる。様々な認知アーキテクチャが開発されるなかで、本研究では ACT-R [Anderson 07] に注目する。

ACT-R は、複数のモジュールを持つプロダクションシステムである。モジュールの動作を規定する様々なパラメータによって個人差のモデル化を容易にしている。また、外界との

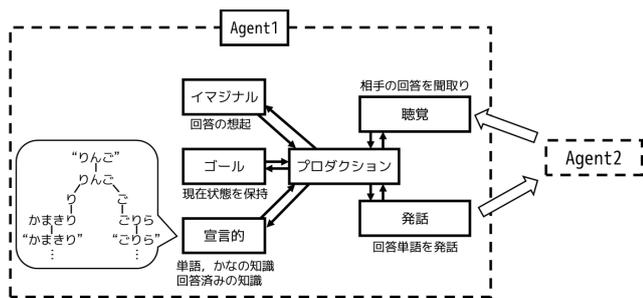


図 1: モデル概観

インタラクションを受け持つモジュールを持ち、反応時間がシミュレート可能である。各モジュールと脳部位との対応づけによって、fMRIなどの生理データとの対応も可能になっている。

ACT-R を用いた言語の獲得に関する研究は多く行われている。英語の学習における不規則動詞の獲得に関わるモデル [Taatgen 02]、幼児による名詞の学習などのモデル [Van Rij 10] が構築されている。脳機能障害に関わる検討もなされており、失語症の文理解において生じるエラーを ACT-R のパラメータによって説明した研究も存在する [Mätzig 18]。

ACT-R によるしりとりモデルとして、著者ら [西川 18] は、知識の活性値と音韻意識を対応づけるシミュレーションを行なった。その結果、音韻意識の高まりによってしり通りの継続数が増加すること、しり通りの遂行に伴って音韻意識が増強されることを示した。この結果は、先述の高橋による調査と整合的なものといえる。

2.3 従来研究の限界と本研究の目的

ここまで示したように、しりとりと言語の習得に関する研究はすでに行われている。しかし、これまでの研究では、言語習得を促すしりとりを介したインタラクションの条件は明らかになっていない。柏原と山本 [山本 89] による学習支援システムの研究では、その効果が評価されておらず、高橋の研究では、ヒントを提示することの効果を実験的に示しているものの、問いに対して1つの単語を回答するといった限定的なしりとりのみを課題とした [高橋 97]。また、著者らによるモデル化 [西川 18] についても、他者とのインタラクションを介さず、一人でしりとりをする課題のみを取り扱った。これらの限界を踏まえ、本研究では、対話的にしりとりを行う一連のプロセスをモデル化し、音韻意識の高まりなどの言語習得の過程を観察することを狙う。

3. モデルとシミュレーション

3.1 モデルの構成

本研究で構築したモデルの概観を図1に示す。このモデルには、個人に対応するエージェント（破線で囲まれた範囲）が含まれ、交互に単語を回答することでしりとりを繋げる。エージェント中のボックスは ACT-R の各モジュールに対応する。

以下に ACT-R のモジュール構造によって、しり通りのプロセスがどのように実現されるかを示す。

3.1.1 宣言的モジュール

ACT-R の宣言的モジュールを用いて、しり通りの遂行に必要な知識をモデル化する。ACT-R の宣言的モジュールにおいて、知識はチャンクと呼ばれる構成要素からなる。本研究のモデルが保持するチャンクには、単語の知識（語彙）に関する

ものと、文字の知識（かな知識）に関するものがある。前者のチャンクとして、単語の文字列情報を表す text-inf、単語の語頭文字の知識である word-heads、単語の語尾文字の知識である word-tails というタイプを用意した。以下にそれぞれのタイプに含まれるチャンクの例を示す。

```
(ringo ISA text-inf text "ringo")
```

```
(word-head-ring0 ISA word-heads
 meaning ringo
 head-char "ri")
```

```
(word-tail-ring0 ISA word-tails
 meaning ringo
 tail-char "go")
```

各チャンクは、先頭にチャンク名が示され、その後にスロット名と値の組が続く。ISA スロットの値によってチャンクの種類（チャンクタイプ）が示され、以降にチャンクタイプごとに共通のスロットを持つ。text-inf をタイプとするチャンクは、text という名前のスロットを持ち、文字列の情報（"ringo"）を保持する。word-heads タイプは、meaning スロットに単語の知識、head-char スロットに語頭文字の情報を持つ。word-tail タイプも同様に、単語の知識と語尾文字を組み合わせた情報を保持している。

本研究における ACT-R モデルは、この他に、かなに関わる知識をチャンクとして持つ。以下にその例を示す。

```
(a ISA kana string "a")
(ka ISA kana string "ka")
(sa ISA kana string "sa")
```

```
(n ISA kana string "n")
```

このチャンクは、先に示した単語に関わるチャンクの構成要素となる。つまり、本研究のモデルにおいて、word-heads あるいは word-tails タイプのチャンクに含まれる語頭、語尾文字の知識をもとにして kana タイプのチャンクを検索するということが、しりとりにおける単語から文字を切り出す音韻意識に対応すると言える。

また、本モデルはしり通りのゲーム中で既に回答された単語に関する知識を保持するためのタイプ past を持つ。このタイプは単語の知識 past-word と単語の文字列知識 past-string からなる。past タイプのチャンクは、はじめは宣言的モジュール内には存在せず、しり通りの進行に従って生成され、格納されてゆく。

3.1.2 ゴールモジュール

ゴールモジュールは、課題の状態を保持する。本モデルでは、ゴールモジュールに保持される短期記憶は回答単語を表すスロット (a-word)、回答単語の語頭文字を表すスロット (a-head)、回答単語の語尾文字を表すスロット (a-tail) とモデルの状態を表すスロット (state) によって構成される。これらのスロットの値はプロダクションモジュールによって逐次的に挿入、更新される。

3.1.3 イマジナルモジュール

イマジナルモジュールは、そこに保持された情報をチャンクとして生成する機能を持つ。本モデルの中では、相手の回答を受け取ったとき、または単語を回答するときに、回答済みの単語を表すチャンクを新たに生成し、宣言的モジュールへ格納する役割を果たす。

3.1.4 聴覚モジュール

聴覚モジュールは、耳で聞きとった音について、位置を把握し、内容を理解することに要する時間をシミュレートする。本モデルでは、聴覚的な情報の入力があるまで待機し、入力があった際には、その情報をバッファに保持したのち、宣言的知識として格納する。

3.1.5 発話モジュール

発話モジュールは、口から言葉を発することや、頭の中で言葉を思い浮かべることに要する時間をシミュレートする。本モデルでは、相手の回答した単語を思い浮かべること、自分の回答を発話することに利用される。

3.1.6 プロダクションモジュール

プロダクションモジュールは、他のモジュールが保持する情報や状態を利用しながら、ルールを選択、適用し、モジュールを操作する様々な処理を行う。本研究のモデルは、相手の回答として単語の情報を受け取ると、しりどりのルールに即して単語を検索し回答する。

モデルには、相手の回答を聞き取り自分の回答を発話する一連のプロセスの他に、自分の回答をチェックするプロセスが存在する。回答候補の想起プロセスにおいて、まず聞き取った単語の情報が聴覚モジュールから受け渡され、ゴールモジュールの a-word スロットに配置される。その後、a-word に配置された知識をもとに宣言的モジュール内の単語と語尾を結ぶ知識 (word-tails タイプのチャンク) が呼び出される。また、a-word の知識はイマジナルモジュールを利用して既に回答した単語の知識 (past チャンクタイプ) として記憶される。その後、語尾文字に注目して、ゴールモジュールの a-tail スロットに格納し、a-tail の文字を語頭に持つ単語 (word-heads タイプのチャンク) を検索する。単語が検索されると、単語知識を次のゴール (a-word スロット) にセットする。この間の単語、文字が呼び出された時点において、発話および聴覚に関わるルールが随時発火し、単語や文字の発話、聴覚情報の取得を行う。

この後、モデルは想起された回答候補が語尾に「ん」を持たないことをチェックする。想起した回答候補の語尾が「ん」でなければ、その単語を回答とする。回答候補の単語の語尾が「ん」であるとき、回答候補単語の語頭文字との関連記憶を検索し、語頭文字に着目し、語頭文字の知識を利用することで、再度かな知識から回答候補となる単語の検索をおこなう。

「ん」のチェックの後、現在ゴールに保持されている単語が、すでに自分もしくは他者によって発話されていないか判定する。モデルの宣言的モジュールは、過去に想起された単語を経験として保持している (past タイプのチャンク)。回答の前に past タイプのチャンクを検索し失敗した場合 (過去にその単語を想起した経験がない場合)、その単語を回答とする。回答候補を手掛かりとした宣言的モジュールの検索によって、過去に想起した経験が思い出された場合 (回答候補の単語が既回答だった場合)、回答候補となる単語を再検索する。

現在ゴールに保持されている単語が、既に回答された単語ではなく、語尾の文字が「ん」でもない単語が想起されたとき、その単語を回答済みの単語 (past チャンクタイプ) として記憶した上で、発話モジュールを用いて単語を回答する。以上が本モデルにおける回答の流れである。しりどりは、2つのエージェントによってこのプロセスが連鎖することで遂行される。

3.1.7 モデルのパラメータ

ACT-R のモジュールは、数値的なパラメータによって調整される。本研究において重要なパラメータは、宣言的モジュールからチャンクを検索することに関わるパラメータ (活性値)

である。活性値は学習や忘却、文脈などに対応する複数の項の加算として定義される。このうち、本研究において、学習と忘却の効果を表すベースレベルに注目する。

$$B_i = \ln \left(\sum_{j=1}^n t_j^{-d} \right) + \beta_i \quad (1)$$

上記の式 1 において、 B_i はあるチャンク i のベースレベルを表す。ベースレベルは、そのチャンクが参照された回数 n および ACT-R 内部でパラメータ (:bll) によって指定される減衰率 d と j 回目にチャンクが参照されてからの経過時間 t_j 、パラメータ (:blc) によって指定されるオフセット β_i から算出される。

ベースレベルを項として算出される活性値は、そのチャンクの想起に要する時間に影響する (活性値の高いチャンクほど素早く想起される)。さらに、活性値が一定 (パラメータ:rt によって指定される閾値) よりも低いチャンクは、長時間の検索の試行が行われた後に失敗する。つまり、シミュレーションの進行にともなう活性値の変化を観察することで、ACT-R 内部での知識の使われやすさの変化を推測することができる。

3.2 シミュレーション

シミュレーションは、簡易的なプロトタイプモデルによって行なった。このモデルには、天野と近藤による『基本語データベース：単語親密度』[天野 08] に掲載される単語の中から、20,544 語を知識として搭載した。本研究では、処理の容易さとしりどりのルールから、名詞以外の品詞、同音異義語などの重複、ろ (炉) や、わ (輪) など一音のみで構成される単語を除外してモデルの知識としている。また、単語末尾の長音記号はすべて削除した。さらに、単語をひらがなで表記した際の先頭および末尾から一文字 (拗音の場合は捨て仮名を含めた二文字) を語頭音、語尾音とし、それぞれのタイプのチャンクを定義している。このような知識を搭載した上で、しりどりのプロセスを 10,000 秒間行うシミュレーションを 1,000 回実行し、そのログデータを分析した。

図 2 と図 3 にプロトタイプモデルを実行した結果を示す。図 2 は 1 回の実行結果を事例として示している。図 2 において、一方のエージェントの回答から他方のエージェントが別の単語を回答することを 1 チェーンと数え、横軸はチェーンの回数、縦軸は 1 回のチェーンにかかる時間を示している。この図から、しりどりの進行に従って、回答にかかる時間が増加していることが読み取れる。これは、しりどりの遂行に従って回答済みの単語知識が増え、回答済みの単語が想起されて再検索を行う機会が多くなったのだと考えられる。

図 3 は、しりどりを行う 2 つのエージェントにおける、しりどり遂行中のかな知識の活性値の類似度の推移を示す。10,000 秒間のしりどりシミュレーションの間に、43 回以上のチェーンを達成した 950 組について、各チェーン後の各かな知識 (kana タイプの各チャンク) の活性値をエージェント間で比較し、コサイン類似度を算出した。図の横軸はチェーン数、縦軸はかな知識活性値の類似度の平均を表す。この図から、しりどりの進行に従って、かな知識の類似度が上昇していることが読み取れる。かな知識は、しりどりの初期には、デフォルトの値にランダムなノイズが付与された状態であるため類似度がやや低い。しりどりの遂行によって 2 エージェントで共通のかな知識が用いられることで活性値が更新され、類似度が高まったと考えることができる。

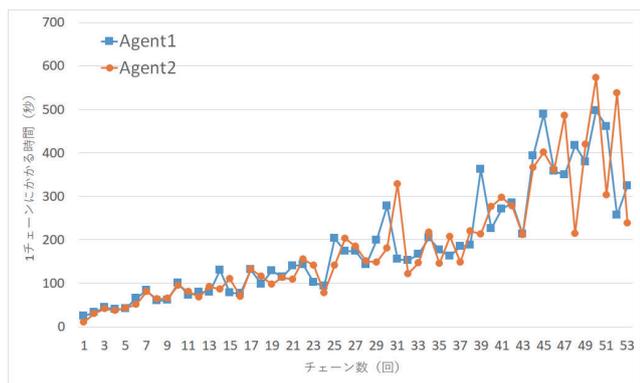


図 2: 回答に要する時間の事例

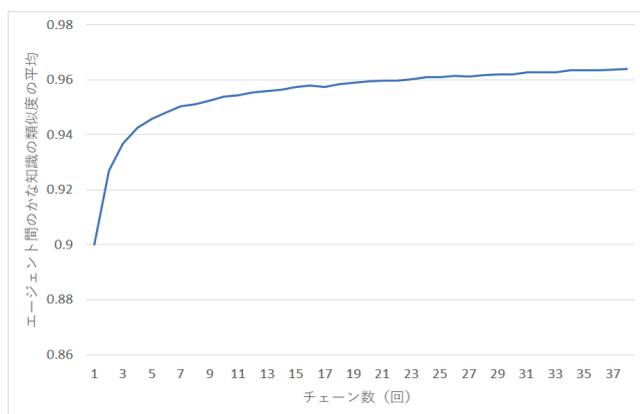


図 3: 2 者間のかな知識の類似度の推移

4. まとめ

本稿では言語発達に関わるインタラクションのモデル化に向けて、しりとりを課題としたプロトタイプモデルを作成した。プロトタイプモデルによるシミュレーションの結果、しりとり課題の遂行と2者間の音韻意識(かなの知識)の類似度の関連などを観察した。

今後、シミュレーション結果の精査と、条件の異なるシミュレーションに対する結果の比較を行っていく予定である。たとえば、word-tails タイプのチャンクにおいて、誤った語尾文字をもつ知識(単語から間違った語尾音を切り出した知識)を組み込むことで、未発達な音韻意識を持つ人のエラーをシミュレートするということが考えられる。また、将来的には、モデルを発展させることで、しりとりの成立を支えるインタラクションの条件を探っていく。

参考文献

- [Anderson 07] Anderson, J. R.: How can the human mind occur in the physical universe? (2007)
- [Baron-Cohen 97] Baron-Cohen, S.: *Mindblindness: An essay on autism and theory of mind*, MIT press (1997)
- [Mätzig 18] Mätzig, P., Vasishth, S., Engelmann, F., Caplan, D., and Burchert, F.: A computational investigation of sources of variability in sentence

comprehension difficulty in aphasia, *Topics in cognitive science*, Vol. 10, No. 1, pp. 161–174 (2018)

- [Taatgen 02] Taatgen, N. A. and Anderson, J. R.: Why do children learn to say “broke”? A model of learning the past tense without feedback, *Cognition*, Vol. 86, No. 2, pp. 123–155 (2002)

- [Tomasello 99] Tomasello, M.: *The Cultural Origins of Human Cognition* (1999)

- [Van Rij 10] Van Rij, J., Van Rijn, H., and Hendriks, P.: Cognitive architectures and language acquisition: A case study in pronoun comprehension, *Journal of Child Language*, Vol. 37, No. 3, pp. 731–766 (2010)

- [高橋 97] 高橋登: 幼児のことは遊びの発達: “しりとり” を可能にする条件の分析, *発達心理学研究*, Vol. 8, No. 1, pp. 42–52 (1997)

- [阪本 11] 阪本綾香, 林勇吾, 小川均: コミュニケーションロボット PaPeRo による人間らしさの表出, *HAI シンポジウム*, Vol. 2011, (2011)

- [山本 89] 山本米雄, 柏原昭博: 知識定着を目的とした開放型 CAI のモデル化, *電子情報通信学会論文誌 D*, Vol. 72, No. 9, pp. 1459–1471 (1989)

- [西川 18] 西川純平, 森田純哉: 認知アーキテクチャを利用したことは遊びにおける音韻意識のモデル化, *日本認知科学会第 35 回大会* (2018)

- [大石 94] 大石敬子: 学習障害における言語の問題, *聴能言語学研究*, Vol. 11, No. 2, pp. 57–63 (1994)

- [大藤 17] 大藤聖菜, 妹尾卓磨, 清丸寛一, 川崎邦将, 大澤正彦, 長田茂美, 今井倫太: 予測的認知と「間」の関係—言葉を話せないロボットによるしりとりを題材とした考察, *HAI シンポジウム*, Vol. 2011, (2017)

- [天野 08] 天野成昭, 小林哲生: 基本語データベース: 語義別単語親密度 (2008)

- [日山 12] 日山美子: 自閉症児の読み書きの発達を促すための指導: 認知特性を踏まえた音節分解の指導, *筑波大学特別支援教育研究*, Vol. 6, pp. 31–36 (2012)

[1P4-J-10] Vision, speech: organisms and medicine

Chair:Toshihiko Yamasaki Reviewer:Akisato Kimura

Tue. Jun 4, 2019 5:20 PM - 6:40 PM Room P (Front-left room of 1F Exhibition hall)

[1P4-J-10-01] Construction of a Classification Model for Nodule Detection in Lung CT Images○Taku Ri¹, Tatsuya Yamazaki¹ (1. Niigata University)

5:20 PM - 5:40 PM

[1P4-J-10-02] A novel quantification method of dense breast from mammography○Kenichi Inoue¹ (1. Shonan Memorial Hospital, Breast Cancer Center)

5:40 PM - 6:00 PM

[1P4-J-10-03] Cell Image Segmentation by Integrating Generative Adversarial Network for Each Class○Hiroki Tsuda¹, Kazuhiro Hotta¹ (1. Meijo University)

6:00 PM - 6:20 PM

[1P4-J-10-04] Proposition of Pseudo-labeling for Segmentation in Stacks of Electron Microscopy Images○Eichi Takaya¹, Yusuke Takeichi², Mamiko Ozaki², Satoshi Kurihara¹ (1. Keio University, 2. Kobe University)

6:20 PM - 6:40 PM

肺野 CT 画像における結節影検出のための分類モデルの構築

Construction of a Classification Model for Nodule Detection in Lung CT Images

李 拓宇*¹
Taku Ri

山崎 達也*¹
Tatsuya Yamazaki

*¹ 新潟大学工学部
Faculty of Engineering, Niigata University

This paper proposes a method to detect nodules with cancer possibility from lung field CT images. In the proposed method, an image trimmed from the lung field is input to a classification model constructed by CNN (Convolutional Neural Network), and if it is judged to be a nodule, a mark is labelled on the lung field CT image at trimmed position. In this paper, in order to confirm the effectiveness of the classification model in the proposed method, we construct a model to classify into three classes of solid nodules, ground-glass nodules and non-nodules, and verify classification accuracy. As a result of the verification, for ground-glass nodule images and non-nodule images, the classification accuracy is 95% more. However, the classification accuracy of solid nodule images is 81.87%, and most of misclassified them have been classified as non-nodule.

1. はじめに

日本における 2017 年のがんによる死者数は 373,334 人である [国立]. このうち、肺がんによる死者数は 74,120 人であり、部位別で第 1 位である. 肺がんは発生から約 10 年から 15 年経過すると急激に成長し、生存率が低下する [北村 17]. そのため、早期発見して治療を開始すれば生存率の向上につながるため、死者数の減少のためには肺がんの早期発見が重要である. 現在、放射線科医師は撮影した肺野 CT (Computer Tomography) 画像を目視で診断し、肺がんの可能性のある結節影の有無を判断している. ところが日本における放射線科医師数は診療科別の平均の約 28% しかなく、不足している [日本放射線科]. また、放射線科医師の中でも診断能力に個人差があり、肺野 CT 画像におけるがんの可能性のある結節影の種類によって見落とし率に差が出る場合がある.

そうした中で、近年、医療分野における診断支援に関する研究が広く行われるようになってきている. その中でも、肺野 CT 画像をはじめとした医用画像を自動診断に活用するための手法として、深層学習における畳み込みニューラルネットワーク (CNN: Convolution Neural Network) が注目されていて、CNN を用いた医用画像内の病変検出に関する研究事例もある [Havaei 17]. 肺野 CT 画像に対しても CNN を適用して、「異常あり」と診断された部分だけを放射線科医師が確認するようになれば、診断の手間を削減できるようになると考えられている.

そこで本稿では、肺野 CT 画像からがんの可能性のある結節影を検出するシステムを提案する. 提案手法では、肺野 CT 画像における断面である二次元スライス CT 画像から、小領域画像をトリミングしていく. ただし、トリミングする範囲を肺野領域内に限定する. 次に、肺野 CT 画像からトリミングしてきた小領域画像を、CNN で構築した分類モデルに入力する. そして、トリミングした部分が結節影であると判定されたら、スライス CT 画像の該当部分にラベルをつける. 本稿では、提案手法における結節影の検出の精度を検証するために、実際の肺野 CT 画像を用いて、充実性結節影画像、すりガラス状

結節影画像と非結節影画像との分類実験を行い、精度の検証を行った.

2. 提案手法

本稿では、Anthimopoulos ら [Anthimopoulos 16] が提案した CNN を用いて学習を行い、分類モデルを構築する. この CNN の構造を簡潔に表したものを図 1 に示す.

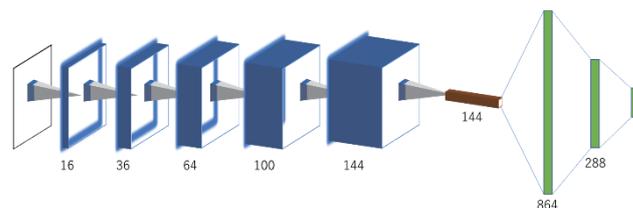


図 1 CNN の構造

以下、本稿では図 1 の CNN を AnNet という. AnNet は、最初に畳み込み層が 5 層連続した後に加えて 1 層だけプーリング層が配置され、最後に全結合層が 3 層続く構造となっている. AlexNet [Krizhevsky 12] のように、プーリング層が畳み込み層の途中にあると、医用画像における結節影の形状や境界部分などのきめ細かい特徴が失われる問題があるが、AnNet ではこの問題を解決している.

提案手法の概要を図 2 に示す. まず、肺野 CT 画像における断面である 512×512 画素の二次元スライス CT 画像を入力画像とする. 次に、肺野領域内で 32×32 画素の小領域画像をトリミングしていく. そして、トリミングした小領域画像を AnNet で構築した分類モデルに入力する. 分類モデルの出力は充実性結節影、すりガラス状結節影と非結節影の 3 クラスとする. そして、分類モデルの判定結果が充実性結節影またはすりガラス状結節影のどちらかであれば、二次元スライス CT 画像における小領域画像をトリミングした部分に矩形でラベルをつける.

本稿では、提案手法における結節影の検出の精度を確認することを目的として、実際に AnNet で分類モデルを構築し、このモデルに対する分類の精度を検証した.

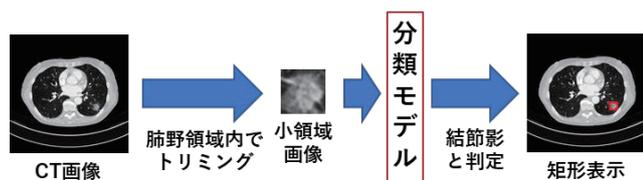


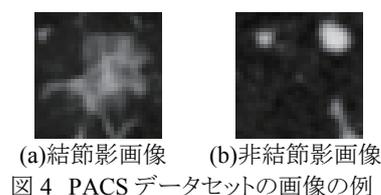
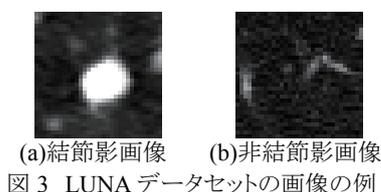
図2 提案手法の概要

3. 分類実験

3.1 使用するデータセット

本稿では、分類実験に使用する画像として、二種類のデータセットを用いる。一つ目は LUNA16 (LUng Nodule Analysis 2016) [LUNA] からダウンロードした、充実性結節影に関する CT 画像のデータセット (LUNA データセット) である。始めに、LUNA データセットにおける 512×512 画素のスライス CT 画像から、医師によるアノテーションデータが示す座標を中心とした 32×32 画素の小領域画像を、結節影画像と非結節影画像それぞれについてトリミングした。その結果、結節影画像は 1,351 枚、非結節影画像は 537,624 枚用意できた。結節影画像と非結節影画像の例を図 3 に示す。

二つ目は新潟大学医学部の PACS (Picture Archiving and Communication Systems) で収集された、すりガラス状結節影に関する CT 画像のデータセット (PACS データセット) である。結節影画像については LUNA データセットと同様に、 512×512 画素のスライス CT 画像から、アノテーションデータが示す座標を中心とした 32×32 画素の小領域画像をトリミングし、524 枚用意できた。非結節影画像についてはアノテーションデータが存在しないので、スライス CT 画像における、肺野領域内で任意の座標を中心とした 32×32 画素の小領域画像をトリミングした。結節影画像と非結節影画像の例を図 4 に示す。



3.2 分類精度の検証

本稿では、分類モデル構築のために用意したデータを 10 個のサブセットに分割して、一つずつテストデータとし、残りの 9 個のサブセットを訓練データとする 10 分割交差検証により分類精度の検証を行う。始めに、訓練データ数を合わせるために LUNA データセットに対してダウンサンプリングを行った。ダウンサンプリング後のデータは、充実性結節影画像、すりガラス状結節影画像それぞれ 524 枚である。また、結節影は向きについて無関係であることから、訓練データに対して回転及び反転によるデータ拡張を施す。非結節影画像については二つのデータセットから合わせて 524 枚を交差検証の対象にする。また、用意できた非結節影画像数は十分にあるので、この 524 枚とは別

の非結節影画像を訓練データとして追加で用いる。データ拡張後の、検証に用いる画像数をまとめたものを表 1 に示す。但し括弧内は画像数が各クラス 56 枚のサブセットをテストデータとした場合の数である。

表 1 検証に用いる画像数

	充実性 結節影画像	すりガラス状 結節影画像	非結節影 画像
訓練データ	3,776 (3,744)	3,776 (3,744)	3,776 (3,744)
テストデータ	52 (56)	52 (56)	52 (56)

表 1 に示す画像数で学習して 3 クラスに分類するモデル構築を行い、10 回分それぞれについてテストデータに対する分類を行った。

3.3 結果と考察

表 2 に分類の結果をまとめた混同行列を示す。但し、分類精度は 10 回の平均値である。また、表 2 の各項目における画像の例を表 3 に示す。表 2 より、すりガラス状結節影画像と非結節影画像については 95% 以上の高い分類精度となっており、CT 画像を基にした自動診断を正確に行える面で分類モデルの有効性が確認されている [松尾 18]。一方で、充実性結節影画像に対する分類精度は 81.87% であり、他の 2 クラスに比べて 10% 以上低くなった。さらに、正しく充実性結節影と分類できなかった画像のうち、87.37% は非結節影と分類された。このような結果になった理由として、表 3 のように、非結節影と誤分類された充実性結節影画像は、正しく充実性結節影と分類されたものに比べて結節影が小さい傾向にあることが考えられる。LUNA データセットでは、1,351 枚の結節影画像のうちの 165 枚は結節影の大きさが 3mm 以下であるとされている [LUNA]。この大きさの場合にはがんである可能性は低い、0% というわけではない。そのため、このような画像をデータセットから除外したり、優先して訓練データとしたりするかどうかについては検討すべき事項であると考えている。

表 2 分類結果

正解 \ 予測	充実性 結節影	すりガラス状 結節影	非結節影
充実性 結節影	81.87%	2.29%	15.84%
すりガラス 結節影	0.76%	98.47%	0.76%
非結節影	3.24%	1.53%	95.23%

表 3 画像の例

正解 \ 予測	充実性 結節影	すりガラス状 結節影	非結節影
充実性 結節影			
すりガラス状 結節影			
非結節影			

4. おわりに

本稿では、肺野 CT 画像からがんの可能性のある結節影を検出するシステムを提案し、そのシステムにおける分類モデルについて分類精度の検証を行った。今後は、データセットに用いる画像や CNN の層の数などについて変更した場合で分類精度の検証を行って、最適な分類モデルの条件についてさらに検討する。また、提案手法の実装を進めていく。

参考文献

- [国立] 最新がん統計,
https://ganjoho.jp/reg_stat/statistics/stat/summary.html,
国立がん研究センター, 参照 Jan.15, 2019.
- [北村 17] 北村茂三: 肺がん検診による早期発見の重要性,
医療保健学研究, No. 8, pp. 77-81, 2017.
- [日本放射線科] 放射線科医の現状と将来について,
<http://www.jcr.or.jp/kensyui/syourai/syourai.html>,
日本放射線科専門医会, 参照 Feb. 6, 2019.
- [Havaei 17] Mohammad Havaei, Axel Davy, David Warde-Farley, Antoine Biard, Aaron Courville, Yoshua Bengio, Chris Pal, Pierre-Marc Jodoin, Hugo Larochelle: Brain tumor segmentation with Deep Neural Networks, Medical Image Analysis, vol. 35, pp. 18-31, 2017.
- [Anthimopoulos 16] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, S. Mougiakakou: Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network, IEEE transactions on medical imaging, Vol. 35, No. 5, pp. 1207-1216, May 2016.
- [Krizhevsky 12] A. Krizhevsky, I. Sutskever, G. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, p. 9, 2012.
- [LUNA] LUNg Nodule Analysis 2016,
<https://luna16.grandchallenge.org>
- [松尾 18] 松尾豊: 人工知能は人間を超えるかーディープラーニングの先にあるもの, 角川書店, 2018.

マンモグラフィの dense breast の自動定量化に関する検討

A novel quantification method of dense breast from mammography

井上謙一
Kenichi Inoue湘南記念病院 乳がんセンター
Shonan Memorial Hospital, Breast Cancer Center

[Background] Evaluating dense breast from mammography is a controversial problem in breast screening. We developed a novel objective method evaluating dense breast by calculating the density within breast tissue area. [Materials and Method] Mammography images classified as category 1 taken in our institute were collected. For each mammography image, masking image was created to indicate the area of the breast tissue. A total of 197 pair images were trained and tested with U-Net algorithm. A “relative density” was calculated based on a “fat density” within a mammography. By aggregating the relative density within the breast tissue area, the “breast density” was calculated. [Result] The result showed 87.0% of DICE coefficient. Defining a dense breast as the breast density being greater than 30%, most of the images were consistent with that evaluated by human. [Conclusion] By using semantic segmentation, we developed a novel method calculating breast density and evaluating dense breast.

1. 背景

現在、乳癌検診の柱となっているマンモグラフィを読影する際に、乳房の構成も同時に読影者が判定している。現在の乳房の構成の判定方法は、アメリカの BI-RADS¹⁾を参考に、「脂肪性」、「乳腺散在」、「不均一高濃度」、「極めて高濃度」の4段階の判定方法となっており、「不均一高濃度」と「極めて高濃度」をあわせて dense breast と定義している。その扱いに関し、厚生労働省は、dense breast を含む乳房の構成を検診受診者に一律に通知することは望ましくないとしている。理由として、乳房の構成の判定結果を伝えても、それを受け入れるシステムができていないこと、マンモグラフィは無駄と誤解され得ること、判定結果が読影者によって異なり、客観性・統一性に乏しいこと、などがある。実際、読影者の読影能力やくせがあるため、乳房の構成を判定しても一致率が低いと言われている。従って現在、乳房の構成の判定結果は検診を受けた被検者には通知されていない。

しかし、“Are you dense?”運動で知られるように、自分の乳房の構成を知っておくことは乳癌検診を受けるにあたり必要な情報であると考えられる。

そこで我々は、人工知能を用いて dense breast を客観性、統一性を以って判定するために定量化する方法を検討した。

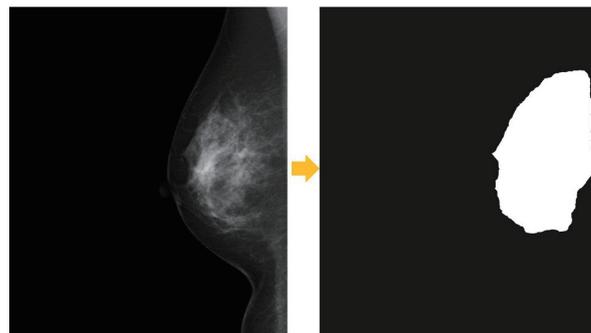
2. 対象と方法

手法としては、大きく分けて二つの手続きに分かれる。即ち、マンモグラフィ画像から乳腺組織の範囲を自動的に推定すること、もう一つは乳房内に基準となる数値を作成し、画像を相対輝度に置き換えることである。

2.1 乳腺組織の範囲を判定

当センターで撮影されたマンモグラフィ 506 枚の内、病変が描出されていない MLO 画像 197 枚を対象とした。各画像に対

し同サイズのマスクング画像を用意した。マスクングは乳腺組織の範囲を白、それ以外の皮膚、乳頭、脂肪、大胸筋、背景などは黒として塗りつぶした画像を作成した。そうすることで乳腺組織の範囲を教師データとして明示させる。



これらの画像を縦 1024×横 768 ピクセルに縮小させた上で、元画像を入力データ、マスクング画像を正解データとして semantic segmentation のアルゴリズムである U-Net²⁾に学習させた。U-Net の構造は、畳み込み層 2 層の後にプーリング層を 1 層の組み合わせを 4 回繰り返した。その後アップサンプリングとスキップコネクションを用いて入力層と出力層が同サイズになるようにした。畳み込み層では batch normalization は使用せず、活性化関数は ReLU を用いた。プーリング層は 4 ピクセルずつ縮小させた。類似度は DICE 係数を用い、Adam を用いて最小化させた。Data augmentation として左右反転画像も用いた。

ただし、これで乳腺組織の範囲を学習させても、マンモグラフィ画像は輝度を自由に調節できるため安定した結果が得られない。そこで画像の輝度を一定にするために脂肪組織の輝度を計測し、それを基準として乳腺組織の相対的な輝度を算出することとした(特許申請中)。

2.2 相対輝度を算出

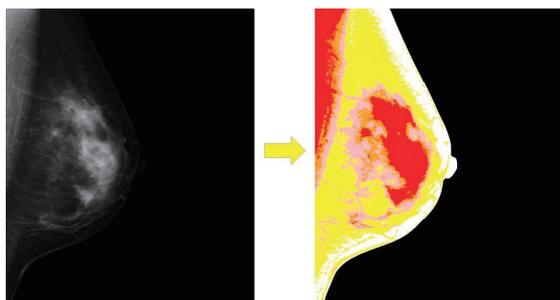
マンモグラフィ画像の内、頭側にある脂肪組織を抽出させた。具体的な測定方法としては、ある水平に引いたライン上で皮膚の位置を検出し、そこから胸壁側に向かって 50 ピクセル分移動

連絡先:

井上謙一、湘南記念病院 乳がんセンター、248-0027 鎌倉市
笛田 2-2-60、(0467)32-3456、kinoue@syonankinenhp.or.jp

し、そこから 100 ピクセル分の脂肪の輝度値を抽出し、平均を算出した。それを 5 ピクセル毎に尾側に移動しながら 20 回繰り返し、それら平均値の平均を算出し、その値をそのマンモグラフィの基準輝度とした。

マンモグラフィ画像内の全てのピクセル輝度を基準輝度で割り、基準輝度との相対的な輝度を算出し、これを相対輝度とした。それを可視化した画像がヒートマップ画像である。相対輝度毎に 1 倍未満は白、1 倍～2 倍未満は黄色、2 倍～3 倍未満はピンク、3 倍～4 倍未満はオレンジ、それ以上を赤に塗り分け、相対輝度の勾配を視覚化しやすいようにした。



2.3 乳腺濃度を算出

こうして作成したマスキング画像と、ヒートマップ画像と組み合わせることで、乳腺組織内の相対輝度を抽出した。この相対輝度を集計し、相対輝度が 3 倍以上(ヒートマップ画像で言うとオレンジと赤)の占める割合を算出することで、このマンモグラフィにおける乳腺組織の輝度の高さ、即ち乳腺組織の濃度を定量化した。これを乳腺濃度とした(特許申請中)。

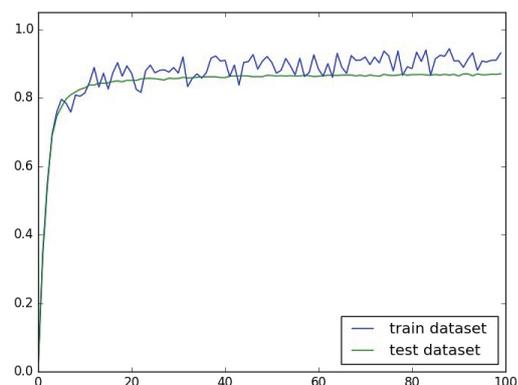
2.4 Dense breast の定義

また dense breast の定義として、乳腺濃度のカットオフ値を設定し、それ以上を dense breast とした。そうして判定した dense breast の評価を、人間が乳房の構成を判定した評価の内、不均一高濃度および極めて高濃度を dense breast とした評価と照らし合わせ、一致率を計測した。

3. 結果

3.1 学習結果

マスキング範囲の一致率は、DICE 係数で 87.0%であった。



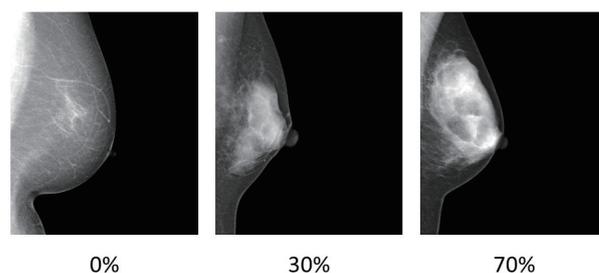
教師データとして使用していない残りのマンモグラフィ画像 309 枚をこの学習モデルに入力させたところ、ほぼ期待されるよ

うな乳腺組織の範囲をマスキングした画像を作成することができた。

同様に 309 枚のマンモグラフィ画像に対し、それぞれの基準濃度を測定した上で相対輝度を算出、ヒートマップ画像を作成した。概ねきれいに塗り分けられた。

3.2 乳腺濃度の計測

作成したマスキング画像と相対輝度を組み合わせることで、乳腺組織の範囲内の相対輝度を抽出した。これらを集計し、乳腺濃度として定量化した。いくつかの例を提示する。おおむね直感的に思った数値と大きくかけ離れてはおらず、自動化できたと考えられる。



3.3 Dense breast の定義

乳腺濃度 30%をカットオフ値とし、それ以上を dense breast と定義したところ、マンモグラフィ読影 A 判定職員による判定結果と比較し 8 割が一致した。

4. 考察

dense breast を判定するツールとして、semantic segmentation を用いて客観性をもって定量化する方法を開発した。この、手法を全国で統一して利用すれば、読影医による dense breast の評価のぶれがなくなり、検診受診者に安定した結果を通知することができると思われた

参考文献

1. E. S. Burnside, E. A. Sickles, L. W. Bassett et al., "The ACR BI-RADS c experience: learning from history," *Journal of the American College of Radiology*, vol. 6, no. 12, pp. 851-860, 2009.
2. Olaf Ronneberger, Philipp Fischer, Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351: 234-241, 2015.

クラス別敵対的ネットワークの統合による細胞画像のセグメンテーション

Cell Image Segmentation by Integrating Generative Adversarial Network for Each Class

津田 大輝*¹
Hiroki Tsuda

堀田 一弘*¹
Kazuhiro Hotta

*¹ 名城大学
Meijo University

Human experts segment cell images manually now, and the criterion for segmentation varies on each expert. As a result, subjective results are obtained. If we develop an automatic segmentation method, we can obtain objective results by the same criteria. This paper proposes a cell image segmentation method using Generative Adversarial Network (GAN) with multiple different roles. The proposed method improved the segmentation accuracy in comparison to conventional pix2pix.

1. はじめに

近年, Generative Adversarial Network (GAN) [Goodfellow 14]を用いることにより, 本物らしい画像が生成できることが注目を集めている. さらに, GAN を拡張した pix2pix [Isola 17]や Cycle GAN [Zhu 17], Star GAN [Choi 18]等は Image-to-Image の変換法として幅広いタスクで汎用性を持つことが知られている. 特に pix2pix はセマンティックセグメンテーションに対しても有効であり, 医療分野や細胞生物分野に応用されている [Havaei 17], [Ji 15]. 従来, 細胞画像のセグメンテーションは専門家の手により行われてきたため, 主観的な結果になりがちであった. そのため, 深層学習技術を用いることにより同一の基準による客観的な結果を得たいという要望が多い. そこで, 本論文では細胞画像を細胞膜, 細胞核, 背景の 3 クラスにセグメンテーションする.

従来の pix2pix は生成器と識別器が一個ずつで構成されていた. しかし, pix2pix を複数クラスのセグメンテーション問題に適用する場合, 1 つの生成器だけにより複数クラスを同時にセグメンテーションすることは困難である. 細胞膜だけをセグメンテーションする生成器と細胞核だけをセグメンテーションする生成器などのように各生成器に異なる役割を与えれば, 効率的に学習ができ, 精度が向上すると考えた. そこで本論文では, 複数の生成器と識別器に異なる役割を与える.

ここでは 2 つのセグメンテーション法を提案する. 1 つ目は Dual Different Roles GAN (DDR-GAN)という方法であり, 2 つの生成器を用いて細胞膜と細胞核をセグメンテーションする. 2 つ目の手法は Triple Different Roles GAN (TDR-GAN)という方法であり, 3 つの生成器で細胞膜, 細胞核, 背景をそれぞれセグメンテーションする.

実験では, 細胞画像から細胞膜, 細胞核, 背景の 3 クラスをセグメンテーションする問題で評価する. 評価指標として IoU (Intersection over Union)を用いる. 従来手法である 1 個ずつの生成器と識別器を用いた pix2pix の結果と比較し, 提案手法の有効性を示した. さらに, 提案手法からいくつかの識別器を削除した方法の評価も行い, 提案手法の有効性を示した.

本論文の構成は以下の通りである. まず, 2 節では関連研究について述べる. 3 節では提案手法の詳細について説明する. 4 節では細胞画像のセグメンテーションにおいて提案手法を評価する. 最後に, 5 節でまとめと今後の課題を述べる.

2. 関連研究

近年, 様々なセマンティックセグメンテーション法が提案されている [Ronneberger 15], [Long 15], [Zhao 17]. pix2pix は生成器にエンコーダ・デコーダ構造の方法を用いて入力画像から学習画像に似た変換画像を生成する. そして, 生成された画像が本物か否かを判断する識別器と生成器を互いに競わせながら学習する敵対的ネットワークである. GAN の一種である pix2pix はセグメンテーションに使用することができ, 非敵対的ネットワークよりもセグメンテーションに関して優れた結果を示している[Luc 16].

複数の GAN を用いる手法もいくつか提案されている. Mixture Generative Adversarial Nets (MGAN) [Hoang 18]は複数の生成器を用いる. K 個の生成器を用いて分布を生成し, それらを混合した分布により GAN の弱点である mode collapse 問題を回避した.他にも, Dual Discriminator Generative Adversarial nets (D2GAN) [Nguyen 17]は 2 つの識別器を用いる. この 2 つの識別器には異なる役割が与えられている. 1 つは学習画像を高得点に生成画像を低得点にするように学習を行う. もう一方の識別器は生成画像を高得点に学習画像を低得点にするよう学習し, 生成器はこれらの 2 つの識別器を騙すように学習する. これにより mode collapse 問題を回避できた. Generative Multi-Adversarial Networks (GMAN) [Durugkar 17]は複数の同じ識別器を用いる. これは最大得点を持つ識別器を選択し, それに対して学習することにより良好な解への収束が期待できる手法である.

複数の生成器または識別器を用いた従来法は存在するが, これらの手法は各々に特定の役割を与えなかった. 役割が異なる複数の GAN を用いることにより, 精度が向上すると考えられる.

3. 提案手法

本節では提案手法の詳細について述べる. 3.1 節では 2 つの提案手法に共通するネットワークの詳細について説明する. また, 3.2 節では DDR-GAN について述べ, 3.3 節では TDR-GAN について述べる.

3.1 ネットワークの詳細

従来の pix2pix は 1 つずつの生成器と識別器によりセグメンテーションを行うため, 複数のクラスのセグメンテーション問題では精度が低下してしまう. そこで, クラス毎に生成器を用意して

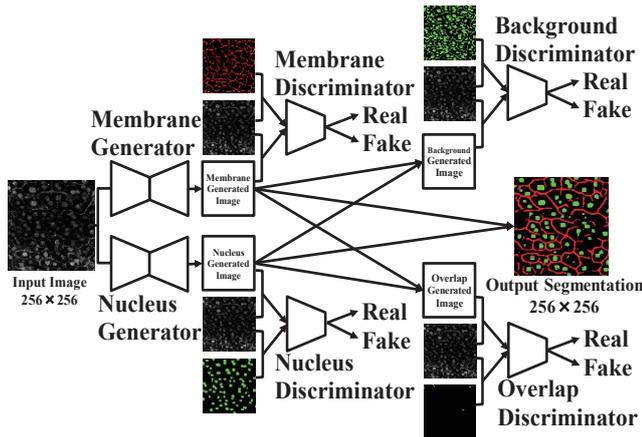


図 1. 提案手法 (a) DDR-GAN

学習を行い、その結果を統合することにより質の高いセグメンテーションを行う。また、クラス毎に識別器を用意することにより、様々な専門的観点から生成と本物か偽物か判断することができる。つまり、生成器により各クラスの確率マップを独立して生成し、それぞれの確率マップは対応する識別器に入力され、本物か偽物か判断される。また、それぞれ特徴マップからさらに判断したい部分だけを抽出することにより、該当部分だけを学習する識別器の作成も可能である。これは後述のそれぞれの提案手法にて説明する。

提案手法における生成器と識別器は従来手法とすべて同じ構造を使用する。生成器には U-Net [Ronneberger 15] を使用し、識別器として畳み込み層が 5 層の CNN を使用する。また、すべての生成器と識別器に対してフルスクラッチ学習を行う。

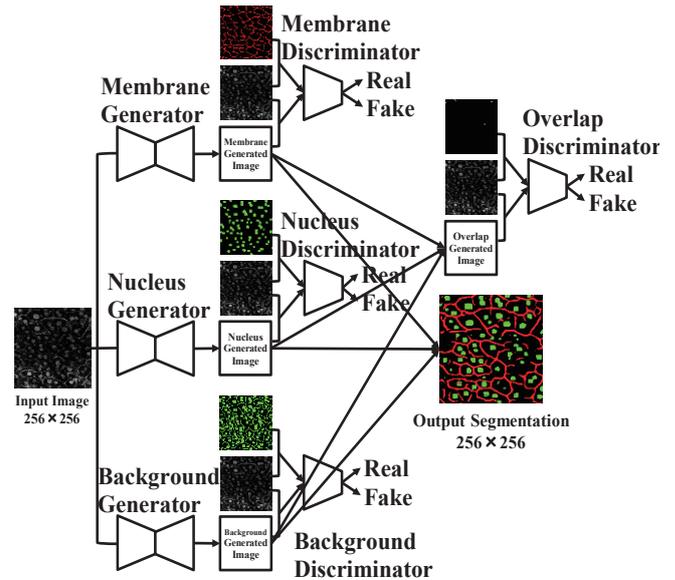
3.2 DDR-GAN

図 1(a) に DDR-GAN を示す。2 つの生成器により細胞膜と細胞核の確率マップを生成し、各クラスの結果はそれぞれの対応した識別器に入力される。また、細胞膜と細胞核のセグメンテーション結果から、細胞膜でも細胞核でもない部分を背景クラスとみなすことにより、背景のセグメンテーション結果を得ることが出来る。そして、識別器に背景クラスのセグメンテーション結果を入力する。学習に用いる正解画像は専門家が細胞膜と細胞核をそれぞれ独立して割り当てを行ったため、重複している箇所がある。この重複部分については、細胞膜を優先して学習を行うように正解画像の重複部分を細胞膜と定義し、学習画像とした。そして、それぞれの生成器により生成された画像からも同様に重複部分を抽出し、識別器により判断させる。つまり、1 つの生成器に対して 3 つの識別器から loss 関数の更新を行う。

細胞膜の生成器に対して loss 関数は以下のように学習した。

$$L_{CGAN}(G, D) = E_{x, y \sim P_{data}(x, y)} [\log D(x, y)] + E_{x, y \sim P_{data}(x), z \sim P_z(z)} [\log(1 - D(x, G(x, z)))] \quad (1)$$

$$L_{L1}(G) = E_{x, y \sim P_{data}(x, y), z \sim P_z(z)} [\|y - G(x, z)\|_1] \quad (2)$$



(b) TDR-GAN

$$G_{mem}^* = \arg \min_{G_{mem}} \max_{D_{mem}} L_{CGAN}(G_{mem}, D_{mem}) + \arg \min_{G_{back}} \max_{D_{back}} L_{CGAN}(G_{back}, D_{back}) + \arg \min_{G_{overlap}} \max_{D_{overlap}} L_{CGAN}(G_{overlap}, D_{overlap}) + \lambda \mathcal{L}_{L1}(G_{mem}) \quad (3)$$

式中の入力は 3 つあり、 x は入力画像、 y は正解画像、 z は学習ラベルを表す。 $G(\cdot)$ は生成器が出力するセグメンテーション結果、 $D(\cdot)$ は識別器が出力する本物か偽物か判断した結果を表す。 G_{mem} は細胞膜の生成器、 D_{mem} は細胞膜、 D_{back} は背景、 $D_{overlap}$ は重複部分の識別器を表す。 G_{back} と $G_{overlap}$ は細胞膜と細胞核のセグメンテーション結果から得られる背景と重複部分のセグメンテーション結果を表す。

細胞膜、背景、重複部分の識別器の式 (1) を 3 つと L1 正則化の式 (2) を組み合わせた式 (3) の loss 関数を用いて生成器の学習を行った。また、細胞核の生成器も同様の loss 関数を用いた。

3.3 TDR-GAN

図 1(b) に TDR-GAN を示す。3 つの生成器により、細胞膜、細胞核、背景の 3 つの確率マップを生成する。3 つの生成器により得られた結果はそれぞれの対応する識別器に入力される。また、DDR-GAN と同様に重複部分を抽出して識別器に入力し、判断をする。TDR-GAN では生成器 1 つに対して 2 つの識別器から loss 関数の更新を行う。

細胞膜の生成器に対して TDR-GAN では以下のように学習した。

$$G_{mem}^* = \arg \min_{G_{mem}} \max_{D_{mem}} L_{CGAN}(G_{mem}, D_{mem}) + \arg \min_{G_{overlap}} \max_{D_{overlap}} L_{CGAN}(G_{overlap}, D_{overlap}) + \lambda \mathcal{L}_{L1}(G_{mem}) \quad (4)$$

細胞膜と重複部分の識別器毎の式(1)が 2 つになった以外は DDR-GAN と loss 関数は同様である、また、細胞核、背景の生成器も同様の loss 関数を用いた。

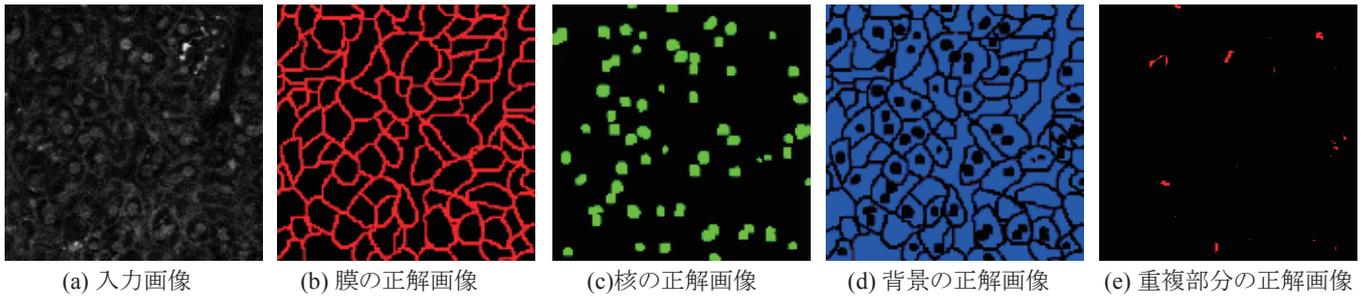


図 2. 細胞膜および細胞核に蛍光マーカーを発現するトランスジェニックマウスの肝臓の蛍光画像の一例

表 1. 提案手法の精度結果

method	Membrane[%]	Nucleus[%]	Background[%]	mIoU[%]
1. Comparison of DDR-GAN				
w/o Background & Overlap	36.61	58.74	70.54	55.30
w/o Background	37.13	59.62	70.43	55.73
w/o Overlap	36.28	61.18	70.38	55.95
Proposed method (Full model)	37.92	60.12	70.58	56.21
2. Comparison of TDR-GAN				
w/o Overlap	38.60	59.26	69.53	55.80
Proposed method (Full model)	38.83	58.77	70.06	55.89

表 2. 従来手法との精度比較

Method	Membrane[%]	Nucleus[%]	Background[%]	mIoU[%]
pix2pix	36.67	57.99	67.98	54.21
DDR-GAN	37.92	60.12	70.58	56.21
TDR-GAN	38.83	58.77	70.06	55.89

4. 評価実験

本節では提案手法の評価実験結果を示す. 4.1 節では今回の実験で使用したデータセットの詳細を述べ, 評価実験の結果を 4.2 節で述べる.

4.1 データセット

本論文では, 細胞膜および核に蛍光マーカーを発現するトランスジェニックマウスの肝臓の蛍光画像 50 枚を使用した. 画像の大きさは 256×256 画素であり, 細胞膜, 細胞核, 背景の 3 クラスからなる. ここでは 30 枚を学習用画像, 10 枚を検証用画像, 10 枚を評価用画像とした [Imanishi 18].

図 2 に細胞画像の例を示す, 図 2(a) が細胞画像であり, 図 2(b) は専門家により細胞膜のラベルが付けられた正解画像である. 図 2(c) と (d) は同様に細胞核と背景の正解画像である. 図 2(e) は細胞膜と核の重複する部分を示す.

評価指標には Intersection over Union (IoU) および Mean IoU を採用した. これらは次式のように算出される.

$$IoU = \frac{TP}{TP+FP+FN} \quad (5)$$

$$mIoU = \frac{1}{c} \sum_c \frac{TP}{TP+FP+FN} \quad (6)$$

ここで, TP は正解した画素数, FP は別クラスの画素に対して誤識別した画素数, そして FN は別クラスとして誤識別した画素数を示し, c はクラス数を示す.

4.2 実験結果

役割の異なる pix2pix の有効性を示すために, 識別器の一部用いずに精度を評価する. 実験では全ての方法で独立に 5 回データセットの画像を変更し, 学習を行う. その平均値を精度評価に用いた. 表 1 にそれぞれの精度を示す. 表 1 から分かるように, 全識別器を用いた DDR-GAN の mIoU が最も高かった.

また, 背景と重複部分の識別器を取り除いた場合が最も精度が低い. それぞれの識別器の有効性を示している. また, TDR-GAN でも同様に重複部分の識別器がない場合, 精度が低下することが分かる. これらの結果から役割の異なる複数の pix2pix の有効性を示している.

表 2 は提案手法と従来手法である pix2pix の結果を示している. 2 つの提案手法は従来手法と比べてどちらも精度が向上した. また, DDR-GAN は TDR-GAN より良い結果である. これは, TDR-GAN が 1 つの生成器に対して 2 つの識別器を使用したのに対して, DDR-GAN では 1 つの生成器に対して 3 つの識別器が使用されるためである. 複数の識別器が各生成器を学習させるのに効果的であった.

従来手法の pix2pix と表 1 の背景と重複部分の識別器を取り除いた DDR-GAN を比較すると, 元の pix2pix より優れている. これはクラス毎の生成器と識別器の有効性を示している.

表 2 より, DDR-GAN は従来の pix2pix と比較して, 細胞膜で 1.25%, 細胞核で 2.13%, 背景で 2.6%, mIoU で 2.00% 向上していることが確認できる.

図 3 はセグメンテーション結果を示す. 左から順に入力画像, 正解画像, pix2pix の結果, DDR-GAN の結果, TDR-GAN の結果を示す. 下段の画像は上段の拡大図である. 拡大画像に注目した場合, 提案手法により細胞膜のセグメンテーションがうまく識別出来ている. また, 細胞核も正確に識別出来ていることが分かる. これらの結果から異なる役割を持つ複数の pix2pix を使用する提案手法の有効性を示した.

5. まとめ

本論文では, 役割が異なる複数の pix2pix を用いたセグメンテーション法を提案した. 細胞画像の実験では, 提案手法は従来の pix2pix と比較して 2.0% 改善された.

しかし, 提案手法は細胞画像に特化しており, 多くのクラスを含む他のデータセットでは提案手法をそのまま適用することは困難である. 適用するにはクラスを生成器毎に自動で分類する必要がある. ここには Gating ネットワーク [Hiramatsu 18] を用いることができると考えられる. これは今後の課題である.

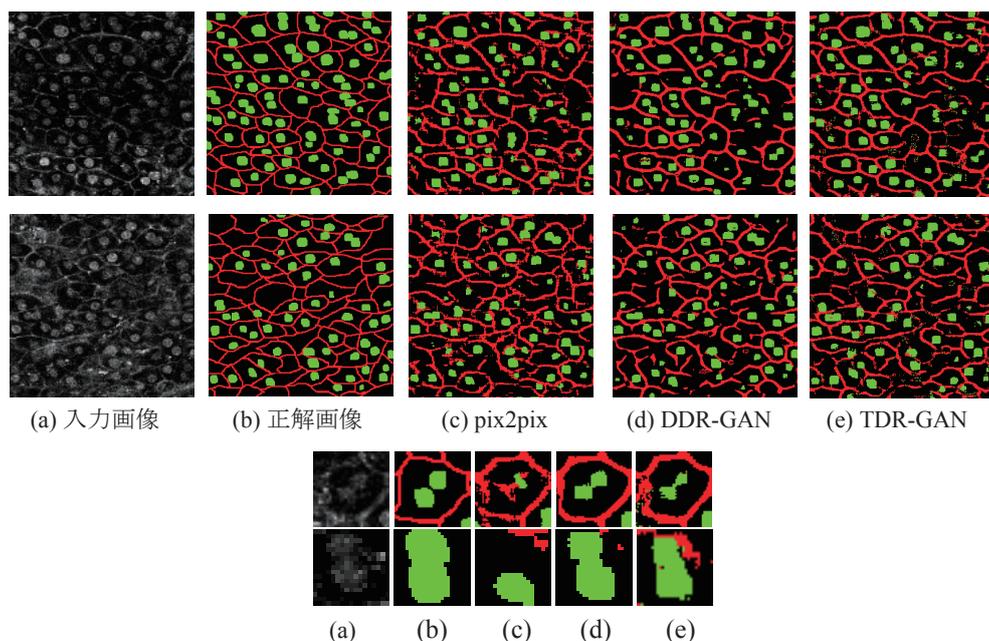


図 3. セグメンテーション結果 (a)入力画像 (b) 正解画像 (c) pix2pix [2] (d) DDR-GAN (e) TDR-GAN

謝辞

本研究の 1 部は、科学研究費新学術領域研究“レゾナンスバイオ”18H04746によるものである。

参考文献

- [Goodfellow 14] I.J. Goodfellow, J.P. Abadie, M.Mirza, B. Xu, D.W. Farley, S. Ozair, A. Courville, and Y. Bengio.s, “Generative Adversarial Nets,” *Advances in Neural Information Processing Systems*, pp. 2672-2680, Dec, 2014.
- [Isola 17] P. Isola, JY. Zhu, T. Zhou, and A.A. Efros, “Image-to-Image Translation with Conditional Adversarial Networks,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5967-5976, Jun, 2017.
- [Zhu 17] J. Zhu, T. Park, P. Isola, and A.A. Efros, “Unpaired image-to-image translation using cycle-consistent adversarial networks,” *IEEE International Conference on Computer Vision*, pp. 2223-2232, Jun, 2017.
- [Choi 18] Y. Choi, M. Choi, M. Kim, J.W. Ha, S. Kim, and J. Choo, “StarGAN: Unified Generative Adversarial Networks for Multi-Domain Image-to-Image Translation,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 8789-8797, Jun, 2018.
- [Havaei 17] M. Havaei, A. Davy, D.W. Farley, A. Biard, A. Courville, Y.Begio, C. Pal, P.M. Jodoin, and H. Larochelle, “Brain tumor segmentation with Deep Neural Networks,” *Medical Image Analysis*, vol. 35 pp. 18-31, Jan, 2017.
- [Ji 15] O.X. Ji, Y. Li, J. Cheng, Y. Yu, and M. Wang, “Cell image segmentation based on an improved watershed algorithm,” *International Congress on Image and Signal Processing*, pp. 433-437, Oct, 2015.
- [Luc 16] P. Luc, C. Couprie, S. Chintala, and J. Verbeek, “Semantic segmentation using adversarial networks,” *Advances in Neural Information Processing Systems Workshops*, Dec, 2016.
- [Ronneberger 15] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” *Medical Image Computing and Computer-Assisted Intervention*, pp. 234-241, Oct, 2015.
- [Hoang 18] Q. Hoang, T.D. Nguyen, T. Le, and D. Phung, “MGAN: Training Generative Adversarial Nets with Multiple Generators,” *International Conference on Learning Representations*, Apr, 2018.
- [Nguyen 17] T. Nguyen, T. Le, H. Vu, and D. Phung, “Dual Discriminator Generative Adversarial Nets,” *Advances in Neural Information Processing Systems*, pp. 2667-2677, Dec, 2017.
- [Durugkar 17] I. Durugkar, I. Gemp, and S. Mahadevan, “Generative Multi-Adversarial Networks,” *International Conference on Learning Representations*, Apr, 2017.
- [Long 15] J. Long, E. Shelhamer, and T. Darrell, “Fully Convolutional Networks for Semantic Segmentation,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 8789-8797, Jun, 2015.
- [Zhao 17] H. Zhao, X. Qi, X. Wang, and J. Jia, “Pyramid Scene Parsing Network,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 8789-8797, Jun, 2017.
- [Hiramatsu 18] Y. Hiramatsu, K. Hotta, A. Imanishi, M. Matsuda, and K. Terai, “Cell Image Segmentation by Integrating Multiple CNNs,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2318-2324, Jun, 2018.
- [Imanishi 18] A. Imanishi, T. Murata, M. Sato, K. Hotta, I. Imayoshi, M. Matsuda, and K. Terai, “A Novel Morphological Marker for the Analysis of Molecular Activities at the Single-cell Level,” *Cell Structure and Function*, Vol43, No.2, pp.129-140, 2018

疑似ラベリングを用いた電子顕微鏡連続切片画像セグメンテーション手法の提案

Proposition of Pseudo-labeling for Segmentation in Stacks of Electron Microscopy Images

高屋 英知^{*1} 竹市 裕介^{*2} 尾崎 まみこ^{*2} 栗原 聡^{*1}
Eichi Takaya Yusuke Takeichi Mamiko Ozaki Satoshi Kurihara

^{*1}慶應義塾大学 大学院理工学研究科 Graduate School of Science and Technology, Keio University
^{*2}神戸大学 大学院理学研究科 Graduate School of Science Kobe University

In the research field called connectomics, it is aimed to investigate the structure and connection of the neural system in the brain and sensory organ of the living things. Earlier studies have been proposed the method to help experts who suffer from labeling electron microscopy (EM) images for three-dimensional reconstruction, that is important process to observe tiny neuronal structures in detail. However, most of existing methods are based on supervised learning, that needs large amount of labeled dataset, whereas the number of labeled EM images is limited. To tackle this problem, we proposed semi-supervised learning method, that performs pseudo-labeling. This makes it possible to automatically segment neuronal regions using only a small amount of labeled data. We experimented with two kinds of dataset, and showed that our method outperformed normal supervised learning with a few labeled samples, while the accuracy was not sufficient yet.

1. はじめに

生物の脳や感覚器官における神経の微細構造を観察し、その機能性を明らかにすることは、神経生理学をはじめ様々な学問分野の発展において重要である。神経構造を観察するための手法はスケールによって様々だが、特にアリのように、小さな生物の感覚器官が対象となる場合、走査型電子顕微鏡によって得られた連続切片画像の3次元再構築が行われることが一般的である。しかし、そのためには数十から数百枚の連続切片画像に対する、専門家による神経領域のラベリング作業が必要となる。この負担を軽減するために、自動化へ向けたさまざまな取り組みがなされてきた [Kaynig 15]。近年では、ラベリングを行う上で重要な神経領域のセグメンテーションを教師あり学習の問題として定義し、深層学習を適用することが主流となっており、有効なニューラルネットワークモデルが数多く提案されている [Ciresan 12][Ronneberger 15][Chen 16]。しかし、これらのような手法のもとでも、専門家の手によるラベリング作業は不可欠である。また、観察対象となる検体の種類によっては、電子顕微鏡で撮影された画像自体が希少な場合も多い。そのようなケースにおいて専門家の負担を軽減するためには、ごく少数のラベル付きデータのみが存在していることを前提に機械学習手法を適用することが望ましいと考えられる。例えば、数百枚の連続切片画像のうち始めの数枚のみを専門家がラベル付けし、続く画像は自動的にラベリングするといった具合である。本稿では、以上のような自動化を実現するために、疑似ラベリング [Lee 13] を用いたセグメンテーション手法を提案する。

2. 疑似ラベリングによるセグメンテーション手法

提案手法の概要及び疑似アルゴリズムを図1および Algorithm1 に示す。まず、M枚の連続する連続切片画像と教師ラ

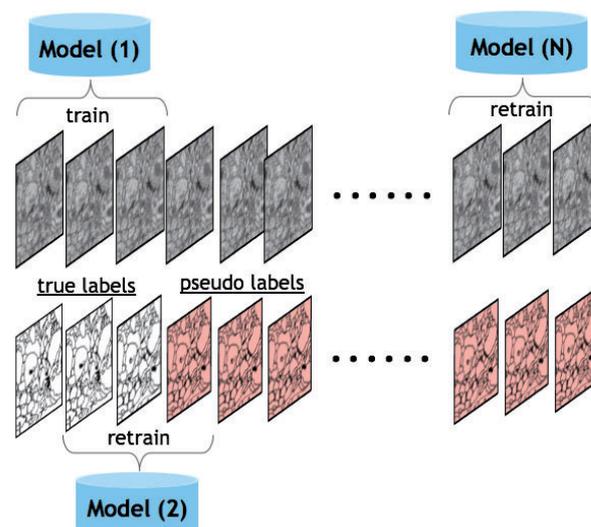


図1: 提案手法の概要. 上段は入力画像, 下段は真のラベルおよび疑似ラベルを表しており, Model(N) は, N回の再学習が行われたモデルを表している。

ベルの組 (これを初期サンプルと呼ぶ) を用いて教師あり学習を行う。次に、M+1枚目の画像に対して学習済みのモデルでセグメンテーションを行い、その結果をM+1枚目の画像に対する擬似的なラベルとする。そして、疑似ラベルを含んだM枚の画像を用いて、モデルを再学習する。これを、最後の1枚の画像に疑似ラベルが付与されるまで繰り返す。学習に用いるモデルは任意であるが、U-Net[Ronneberger 15] や Deep Contextual Network[Chen 16] のように、画像のセグメンテーションを end-to-end で学習できる深層学習モデルが望ましい。

連絡先: 高屋英知, 慶應義塾大学大学院理工学研究科,
〒223-8522 神奈川県横浜市港北区日吉3-14-1,
Email: etakaya@keio.jp

Algorithm 1 疑似ラベリングによるセグメンテーション

```

Set the number of data  $N$ , and labeled samples  $M$ 
Set the serial images  $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_N]$ 
Set the corresponding labels  $\mathbf{T} = [\mathbf{T}_1, \dots, \mathbf{T}_N]$ 
for  $i = 1$  to  $N - M$  do
  Train model with  $(\mathbf{X}_{i:i+M-1}, \mathbf{T}_{i:i+M-1})$ 
  Predict the label from  $\mathbf{X}_{i+M}$  as a pseudo label
   $\mathbf{T}_{i+M} \leftarrow$  pseudo label
end for

```

3. 実験

3.1 実験設定

提案手法の有効性を検証するため、後述する2種類のデータセットを用いて実験を行った。深層学習モデルには Deep contextual network (DCN)[Chen 16] を使用し、各イテレーションでのエポック数を200、バッチサイズを3とした。ネットワークの構成やハイパーパラメータの設定については、DCNを提案した文献[Chen 16]に則っている。評価は連続切片画像の最後の1枚における推論結果に対して行った。使用した評価指標については後述する。比較対象としては、DCNで初期サンプルによる学習(200エポックおよび600エポック)を行ったモデルによる推論結果を用いた。これは、提案手法における合計エポック数が600になるまでは学習に真のラベルが利用されている点を考慮したものである。

3.2 データセット及び評価指標

ISBI 2012 EM Segmentation Challenge dataset

かつてコンペティションで用いられた、ショウジョウバエ1齢幼虫における腹部の連続切片画像データセットで、 512×512 ピクセルの30枚の画像で構成されている。このデータセットにおける評価指標は、Rand Score Thin (V^{rand}) および Information Score Thin (V^{info})とした。これらの指標の詳細については、関連文献[Arganda-Carreras 15]を参照されたい。

クロオオアリ巣仲間識別感覚子連続切片画像データセット

神戸大学の尾崎研究室により提供されたデータセットで、 2048×2048 ピクセルの377枚の画像で構成されている。今回は、377枚の画像のうち先頭から数えた100枚を、 512×512 ピクセルにクリッピングしたものを使用した。このデータセットにおける評価指標は、画像セグメンテーションのタスクでしばしば利用される Intersection over Union(IoU)を用いた。

3.3 実験結果

それぞれのデータセットにおける実験結果を表1および表2に示す。いずれのデータセットにおいても、提案手法が、比較手法を大きく上回っていることがわかる。ただし、ISBIデータセットを最大限に活用した手法では、 V^{rand} と V^{info} のそれぞれについて90%を超える精度が達成されている*1点を考慮すると、精度面ではまだ改善の余地があるといえる。

4. まとめ及び今後の課題

本稿では、疑似ラベリングによる電子顕微鏡連続切片画像のセグメンテーション手法を提案し、深層学習モデルを用いた実験を行った。少数の学習サンプルのみが利用可能な状況にお

表1: ISBI 2012 EM Segmentation Challenge データセットにおける実験結果

Training method	V^{rand}	V^{info}
Supervised (200 epochs)	0.1620	0.1622
Supervised (600 epochs)	0.5958	0.2064
Proposed method	0.7310	0.2167

表2: クロオオアリ巣仲間識別感覚子データセットにおける実験結果

Training method	IoU
Supervised (200 epochs)	0.2725
Supervised (600 epochs)	0.4030
Proposed method	0.5451

いては、提案手法の精度が単純な教師あり学習による方法を上回った。

今後は、提案手法における初期サンプルの数と精度の関係や、疑似ラベリングの繰り返しによる精度低下の傾向などを明らかにするため、より包括的な実験を行う予定である。また、精度の改善へ向け、画像の連続性を考慮した深層学習モデルの適用可能性についても調査する予定である。

参考文献

- [Arganda-Carreras 15] Arganda-Carreras, I., Turaga, S. C., Berger, D. R., Cireşan, D., Giusti, A., Gambardella, L. M., Schmidhuber, J., Laptev, D., Dwivedi, S., Buhmann, J. M., et al.: Crowdsourcing the creation of image segmentation algorithms for connectomics, *Frontiers in neuroanatomy*, Vol. 9, (2015)
- [Chen 16] Chen, H., Qi, X., Cheng, J.-Z., Heng, P.-A., et al.: Deep Contextual Networks for Neuronal Structure Segmentation., in *AAAI*, pp. 1167–1173 (2016)
- [Ciresan 12] Ciresan, D., Giusti, A., Gambardella, L. M., and Schmidhuber, J.: Deep neural networks segment neuronal membranes in electron microscopy images, in *Advances in neural information processing systems*, pp. 2843–2851 (2012)
- [Kaynig 15] Kaynig, V., Vazquez-Reina, A., Knowles-Barley, S., Roberts, M., Jones, T. R., Kasthuri, N., Miller, E., Lichtman, J., and Pfister, H.: Large-scale automatic reconstruction of neuronal processes from electron microscopy images, *Medical image analysis*, Vol. 22, No. 1, pp. 77–88 (2015)
- [Lee 13] Lee, D.-H.: Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks, in *Workshop on Challenges in Representation Learning, ICML*, Vol. 3, p. 2 (2013)
- [Ronneberger 15] Ronneberger, O., Fischer, P., and Brox, T.: U-net: Convolutional networks for biomedical image segmentation, in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 234–241Springer (2015)

*1 http://brainiac2.mit.edu/isbi_challenge/leaders-board-new

[1P2-J-13] AI application: finance and economics

Chair: Yasuo Tabei Reviewer: Tomoya Yoshikawa

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room P (Front-left room of 1F Exhibition hall)

[1P2-J-13-01] Investigating the Effect of Index Investing on Stock Price Formation○Izuru Matsuura¹, Kiyoshi Izumi¹, Hiroki Sakaji¹, Hiroyasu Matsushima¹, Takashi Shimada¹

(1. The University of Tokyo)

1:20 PM - 1:40 PM

[1P2-J-13-02] Measuring Economic Trends based on Financial Institution Texts○Hirofumi Kondo¹, Mamoru Yogosawa¹, Michinori Naruse¹, Masakazu Mori¹ (1. The Japan Research Institute, Limited)

1:40 PM - 2:00 PM

[1P2-J-13-03] Visualization of Inter-Regional Flows in the Virtual Currency using Machine Learning○Joomi Jun¹, Takayuki Mizuno^{2,1} (1. SOKENDAI, 2. National Institute of Informatics)

2:00 PM - 2:20 PM

[1P2-J-13-04] Statistical analysis aimed at assessing the economic impact of fire accidents on damaged companies○Ryoji Sato¹, Ichiro Sato¹, Takayuki Mizuno² (1. Tokio Marine & Nichido Risk Consulting Co., Ltd., 2. National Institute of Informatics)

2:20 PM - 2:40 PM

[1P2-J-13-05] Automatic Summarization of Analyst Reports Based on Causal Relationships from News Articles○WATARU TAKAMINE¹, Kiyoshi Izumi¹, Yasunori Sakaji¹, Hiroyasu Matsushima¹, Takashi Shimada¹, Yasuhiro Shimizu² (1. University of Tokyo, 2. Nomura Securities Co., Ltd.)

2:40 PM - 3:00 PM

インデックス投資が証券市場の価格形成に与える影響の分析

Investigating the Effect of Index Investing on Stock Price Formation

松浦 出^{*1} 和泉 潔^{*1} 坂地 泰紀^{*1} 松島 裕康^{*1} 島田 尚^{*1}
 Izuru Matsuura Kiyoshi Izumi Hiroki Sakaji Hiroyasu Matsushima Takashi Shimada

^{*1}東京大学 大学院工学系研究科
 School of Engineering, the University of Tokyo

In this paper, we modeled stock markets to investigate the effect of index investing on stock price formation. We showed that index investing has little effect on stock price formation in our stock markets model by analyzing results from experiments with various market settings.

1. はじめに

インデックス投資とよばれる投資法がある。投資する資産を、すべての株式に、その時価総額の比で按分して投資するというものである。[Sharpe 64]に始まる一連の研究を理論的背景に持つこの投資法により運用される資産は、現在では投資信託の総運用資産の無視できない割合を占めるに至っている。

インデックス投資では、企業の業績を全く勘案せずに投資が行われる。そのためインデックス投資があまりに大きなシェアを占めた場合、証券市場での価格形成が適正に行われず、有望な企業に資金が集まらない、あるいは投資に値しない企業に資金が集まってしまふ可能性が考えられる。

本論文では、インデックス投資が本当にこのような価格形成の問題を引き起こすのか、また引き起こすとすれば、それはどの程度価格形成に影響を与えるのかを検証した。具体的には、証券市場に存在する証券と市場参加者、および価格決定をモデルとして設計し、いくつかのパラメータについてのシミュレーション実験を通して影響を分析した。

2. 証券市場のモデル

本節では、本研究で扱う証券市場のモデルについて述べる。

証券市場には m 種類の証券が存在し、その 1 株あたりのペイオフ $\theta = (\theta_1, \theta_2, \dots, \theta_m)^T$ は、平均 $\bar{\theta}$ 、共分散行列 Σ の正規分布 $\mathcal{N}(\bar{\theta}, \Sigma)$ に従う。また無リスク資産が存在し、その利率は 0 である。時間 $t = 0$ で、すべての証券が 1 単位だけ供給される。

証券市場には n 社のファンドが参加している。うち $n-1$ 社がインデックス投資を行わないファンド（以下ではアクティブファンドと呼ぶ）であり、1 社がインデックス投資を行うファンド（以下インデックスファンドと呼ぶ）である。

すべてのファンドは時間 $t = 0$ で投資し、 $t = 1$ に回収する。回収までにポートフォリオを組み替えることはできない。

$n-1$ 社のアクティブファンドはすべて絶対的リスク回避度一定型の効用関数を持つ。 j 番目のアクティブファンドは $t = 0$ で θ に関するシグナル $s_j = \theta + \varepsilon_j + \eta$ を受けとる。ここで、 θ は次期の証券のペイオフ、 ε_j はファンドに固有の誤差、 η はすべてのファンドに共通して入りこむ誤差を表し、 $\varepsilon_j \sim \mathcal{N}(0, \Sigma_\varepsilon)$ 、 $\eta \sim \mathcal{N}(0, \Sigma_\eta)$ 、 $(\Sigma_\varepsilon = \sigma_\varepsilon^2 \Sigma, \Sigma_\eta = \sigma_\eta^2 \Sigma)$ を仮定する。アクティブファンドは受けとったシグナルをもとに、自身の期待効用を最大化するよう行動する。

ただ 1 社存在するインデックスファンドは各証券の時価総額に応じて投資する。インデックスファンドの証券 k への投資額は、証券 k の時価総額がすべての証券の時価総額の和に占める割合に、運用総資産を掛けた額である。

2.1 アクティブファンドの行動

各アクティブファンドは、自身の期待効用を最大化するよう投資する。アクティブファンドの効用関数には絶対的リスク回避度一定型を仮定する。すなわち j 番目のアクティブファンドの効用関数 $u_j(x)$ は、 $t = 1$ での運用資産 y に対して、

$$u_j(y) = -e^{-\rho y} \quad (1)$$

と表せる。 $\rho > 0$ は絶対的リスク回避度である。 ρ はすべてのアクティブファンドに共通であると仮定する。

この状況では、シグナル s_j を得たアクティブファンド j の投資 x_j は次の最適化問題の解である。

$$\text{maximize } E \left[u_j \left(\theta^T x_j \right) \middle| s_j \right] \quad (2)$$

$$\text{subject to } p^T x_j = b_j \quad (3)$$

ただし θ' は m 種類の証券に無リスク資産を加えた $\theta' = (1, \theta_1, \dots, \theta_m)^T$ のことであり、 p は $t = 0$ での無リスク資産を含む証券の市場価格ベクトル $p = (1, p_1, \dots, p_m)^T$ 、 b_j はアクティブファンド j の運用資産である。

実はこの最適化問題は次の問題と等価である。^{*1}

$$\text{maximize } \theta_j^T x_j - \frac{\rho}{2} x_j^T \Sigma_j x_j \quad (4)$$

$$\text{subject to } p^T x_j = b_j \quad (5)$$

θ_j 、 Σ_j はそれぞれ s_j を所与とした θ' 、 Σ' の条件付き平均、条件付き分散である。この解は方程式、

$$\begin{pmatrix} \rho \Sigma_j & p \\ p^T & 0 \end{pmatrix} \begin{pmatrix} x_j \\ \lambda \end{pmatrix} = \begin{pmatrix} \theta_j \\ b_j \end{pmatrix} \quad (6)$$

を解くことで得られる。

2.2 インデックスファンドの行動

インデックスファンドはマーケットポートフォリオに投資する。すなわち、証券価格 $p = (p_1, \dots, p_m)^T$ と運用資産 b に対して、各証券に $b(p_1, \dots, p_m)^T / \sum_i p_i$ だけ投資する^{*2}。

^{*1} 証明は付録参照

^{*2} すべての証券の供給を 1 に正規化しているため、時価総額は価格と等しい。そのため時価総額の比が $(p_1, \dots, p_m)^T / \sum_i p_i$ となる

2.3 価格の決定方法

証券の価格は、すべての証券の超過需要が0となる価格で決定される。^{*3} 価格 $p \in \mathbb{R}^m$ における証券の超過需要 $D(p) \in \mathbb{R}^m$ とは、 $D_j(p) \in \mathbb{R}^m$ を、価格が p であるときの第 j ファンドの需要として、次の式で定義される量である。

$$D(p) = \sum_{j=1}^n D_j(p) - 1 \quad (7)$$

超過需要を0とする p は、 p についての方程式 $D(p) = 0$ をニュートン法で解くことで得られる。

2.4 各証券がどの程度正確に価格付けられているかの指標

インデックスファンドが存在せず、アクティブファンドが受け取るシグナルが、 $\theta + \eta$ であるとき、つまり $\sigma_\varepsilon = 0$ の場合を、最も正確な情報が反映された市場と考える。この市場で実現する価格 p_f を完全情報価格と呼ぶことにし、これをベンチマークとする。ある市場がどの程度情報を反映しているかを、その市場で実現する価格 p_p が完全情報価格からどの程度離れているかを表す指標

$$d(p_p) = \frac{\|p_p - p_f\|}{\|p_f\|} \quad (8)$$

により評価する。以下ではこの指標を完全情報価格からの乖離度と呼ぶ。

3. シミュレーション実験による検証

3.1 パラメータの決定法

本モデルでは、証券市場はファンドの数 n 、証券の種類 m 、ペイオフの期待値 $\bar{\theta}$ と共分散行列 Σ 、アクティブファンドの絶対的リスク回避度 ρ 、ファンドに固有の誤差の大きさ σ_ε 、共通の誤差の大きさ σ_η のパラメータで決定される。証券に関するパラメータ $m, \bar{\theta}, \Sigma$ は、東証第1部の1業種を1つの証券と対応させて、2010年1月から2018年9月までの業種別時価総額の月次データから定める。2010年1月から2018年9月までの業種毎の時価総額の月次成長率 μ とその共分散行列 Σ_μ をモーメント法により推定する。2018年9月の業種 $i \in \{1, 2, \dots, 33\}$ の時価総額 S_i を、すべての業種の時価総額の和 $\sum_{i=1}^{33} S_i$ で割ったものを s_i とし、 $s = (s_1, \dots, s_{33})^T$ とする。これらの値を用いて、 $\bar{\theta} = \mu * s$ 、 $\Sigma = (ss^T) * \Sigma_\mu$ (ただし $*$ は要素ごとの積) とする。

ρ の値に応じて投資行動がどのように変化するかを見るために、簡単な例を挙げる。確率0.8で賭け金が2倍に、確率0.2で0になるギャンブルを考える。パラメータ ρ の絶対的リスク回避度一定型効用を持つ人が資産 b のうち w だけをこのギャンブルに回すとする。彼のギャンブルへの投資額 w は、 X を成功確率0.8のベルヌーイ分布に従う確率変数として、

$$\mathbb{E} \left[-e^{-\rho(1-w+2wX)} \right] \quad (9)$$

を最大化するよう決定される。この関数を最大化する w は、

$$w = \frac{15}{16\rho} \quad (10)$$

^{*3} この価格決定モデルは経済学で一般均衡理論として知られるものである。詳細は [Jean- Pierre 07]1 章などを参照。

である。絶対的リスク回避度一定型の効用関数を持つ人は、その資産の多寡にかかわらずギャンブルへの投資額を決める。^{*4} $\rho = 1$ であれば15/16を、 $\rho = 15$ であれば1/16を、 $\rho = 150$ であれば1/160をギャンブルに回すわけである。実験の詳細の節で詳述する通り、本実験では各アクティブファンドの運用資産は1/160から1/16程度である。前述のギャンブルのような有利な投資案への投資額がこのようなものであることを考えると、絶対的リスク回避度 ρ は1から64程度に設定するのがよいだろう。

アクティブファンドの推定誤差の大きさ $\sigma_\varepsilon, \sigma_\eta$ については、どのような値が適切であるか見当がつかないため、 $(\sigma_\varepsilon, \sigma_\eta) \in \{1, 2, 4, 8, \dots, 64\}^2$ のすべての場合について調べ上げる。

$\sigma_\varepsilon, \sigma_\eta$ の値について、もう少し詳しく解釈しておく。まずシグナル $s_j = \theta + \varepsilon_j + \eta$ のもとでの θ の条件付き期待値と分散は、

$$\mathbb{E}[\theta | s_j] = \bar{\theta} + \Sigma(\Sigma + \Sigma_\varepsilon + \Sigma_\eta)^{-1}(s_j - \bar{\theta}) \quad (11)$$

$$= \frac{\sigma_\varepsilon^2 + \sigma_\eta^2}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} \bar{\theta} + \frac{1}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} s_j \quad (12)$$

$$\text{Var}[\theta | s_j] = \Sigma - \Sigma(\Sigma + \Sigma_\varepsilon + \Sigma_\eta)^{-1}\Sigma \quad (13)$$

$$= \frac{\sigma_\varepsilon^2 + \sigma_\eta^2}{1 + \sigma_\varepsilon^2 + \sigma_\eta^2} \Sigma \quad (14)$$

である。各アクティブファンドの受け取るシグナルがどの程度信頼できるかは $\sigma_\varepsilon^2 + \sigma_\eta^2$ のみによって決定される。 $\sigma_\varepsilon^2 + \sigma_\eta^2$ が小さければ小さいほど、ファンドは自身が受け取ったシグナルをより信頼する。 σ_ε^2 と σ_η^2 個別の値は、ファンド間のシグナルがどの程度ばらつくかにも影響する。

3.2 実験の詳細

インデックスファンドの運用資産が市場に占める割合と、完全情報価格からの乖離度の関係を調べるために、次のような実験を行った。 $m, \bar{\theta}, \Sigma$ はすべての実験で前述の、東証1部の業種別時価総額から定めた値を使う。またファンドの数は $n = 16$ を採用する。各実験では、パラメータ $\rho, \sigma_\varepsilon, \sigma_\eta$ の値を1つ選んだ。インデックスファンドの運用資産 C_i を決定し、アクティブファンドの運用資産を $(1 - C_i)/(n - 1)$ で定めた。シード値を1から20まで変化させ、それぞれのシード値について、この市場で実現する価格 p_p を計算し、同じシード値を用いて完全情報価格 p_f を計算した。結果として得られた p_p の p_f からの乖離度 $d(p_p)$ と、 C_i の値との関係性を評価した。

3.3 結果と考察

図1は、 $\rho = 16$ を固定して、 $\sigma_\varepsilon, \sigma_\eta$ ごとに横軸に C_i を、縦軸に $d(p_p)$ をプロットしたものである。インデックスファンドの運用資産 C_i の大きさにかかわらず、完全情報価格からの乖離度はほぼ一定のようである。 C_i が大きくなるにつれて完全情報価格からの乖離度が線形に増加する傾向があるようには見えないが、この原因はおそらく次のようなものである。

本実験ではアクティブファンドの効用関数に絶対的リスク回避度一定型を仮定したので、アクティブファンドの運用資産の額によらず、アクティブファンドがリスク資産に投資する額は一定である。一方インデックスファンドは運用資産のすべてを

^{*4} ファンドの効用関数に絶対的リスク回避度一定型を仮定すると、ファンドの運用資産の規模によってその性質が大きく変わってしまう。ファンドが投資家にある一定の性質を持つ金融商品を提供するものであると考えると、この特徴を持つ効用関数を採用するのはあまり適切ではない。当該仮定は計算時間を削減するための技術的なものである。

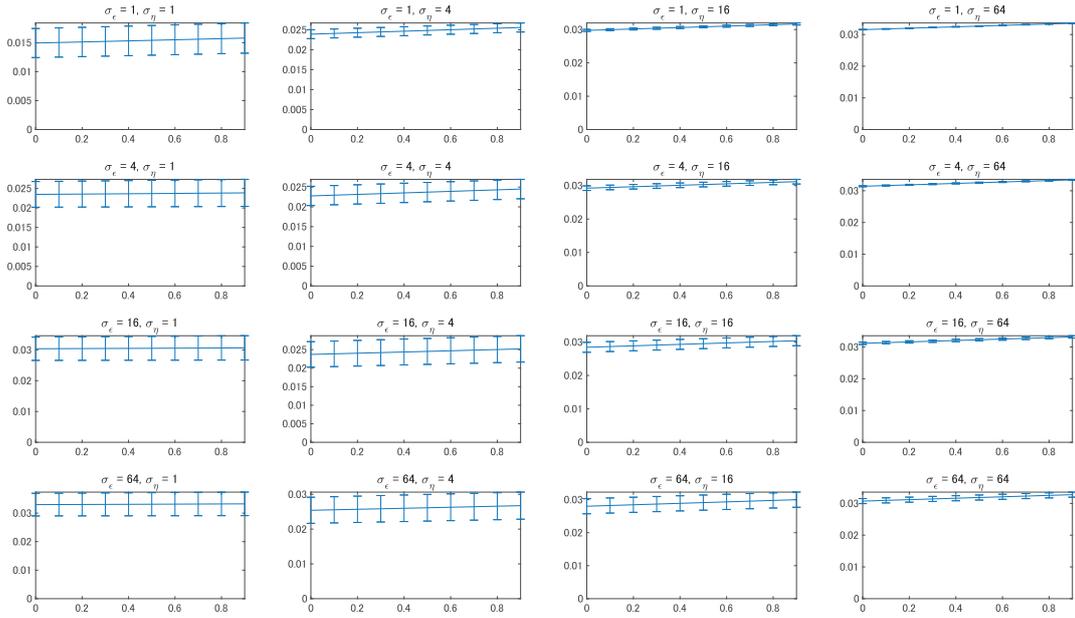


図 1: $\sigma_\epsilon^2, \sigma_\eta^2$ ごとの、インデックスファンドのシェア（横軸）と完全情報価格からの乖離度（縦軸）との関係

リスク資産に投資するので、 C_i の値に応じて市場全体でのリスク資産への投資額が線形に増加する。リスク資産に投資された額が大きいほど各リスク資産の価格は上昇して、 $C_i = 0$ の状況で計算された完全情報価格から乖離するはずである。

ρ の値を $\rho = 1, 2, 4, 8, 16, 32, 64$ と変化させて同一の分析をしたところ、 $\rho = 16$ のときと同じく、 C_i と $d(p_p)$ の間には非常に小さな線形の関係が見られた。

以上のことから、本論文で設定したモデル上では、インデックスファンドが市場の価格形成に与える影響はほとんどないと言えるだろう。

本実験の結果は、本質的に次の 2 つの仮定によるものであると考えられる。

- アクティブファンドのシグナルの正確さ、つまり σ_ϵ^2 の小ささが、ファンドの運用資産に依存せず一定であると仮定したこと
- アクティブファンドの効用関数に絶対的リスク回避度一定型を仮定したこと。

この 2 点を考慮すると結果が大きく変わりうる。インデックスファンドのシェアが大きくなったとき、前者はアクティブファンドの運用資産の減少によって、分析に使える資源が減り、受け取るシグナルが正確でなくなることを通じて、後者は正確な情報を持ったアクティブファンドがリスク資産への投資額を減少させることを通じて、市場価格と完全情報価格との乖離を大きくすると考えられる。

前者を考慮するには、 σ_ϵ^2 をアクティブファンドの総資産の大きさに反比例するように定めればよい。

後者を考慮するには、アクティブファンドの効用関数に相対的リスク回避度一定型効用関数を仮定すればよい。相対的リスク回避度一定型の効用関数を持つアクティブファンドの意思決定は、本モデルの絶対的リスク回避度一定型効用関数を持つア

クティブファンドの意思決定に比べて、計算資源を要すると考えられる。

当面の課題はこの 2 つの仮定を緩和したモデルの作成と実装である。

4. まとめ

インデックス投資が証券市場の価格形成に与える影響を見るために、証券市場のモデルを作成した。またそのモデル上での実験結果から、インデックス投資が価格形成にほとんど影響を与えていないことを示した。

今後はアクティブファンドの効用関数を相対的リスク回避度一定型に差し替え、またアクティブファンドの予測能力が運用資産に依存する構造をモデルに導入し、市場への影響の変化を分析したい。

参考文献

- [Jean- Pierre 07] Jean- Pierre Danthine, Donaldson, J. B.: 現代ファイナンス分析 資産価格理論, ときわ総合サービス (2007)
- [Sharpe 64] Sharpe, W. F.: Capital asset prices: A theory of market equilibrium under conditions of risk, *The journal of finance*, Vol. 19, No. 3, pp. 425-442 (1964)

A 付録

A1 最適化問題 (2) と最適化問題 (4) の等価性

最適化問題 (2) は、問題 (4) と等価である。これは次のようにして示せる。

$Z = \theta^T x_j$ とし、 Z の s_j の条件付き密度関数を $f_{Z|s_j}(z|s_j)$

とすると,

$$E \left[u_j \left(\theta'^T x_j \right) \middle| s_j \right] = E \left[-\exp(-\rho Z) \middle| s_j \right] \quad (15)$$

$$= - \int e^{-\rho z} f_{Z|s_j}(z|s_j) dz \quad (16)$$

である. ここで, θ', s_j の両方が正規分布に従うことから, s_j のもとでの θ' の条件付き分布は正規分布である. したがって, その期待値を θ_j , 分散を Σ_j とすると, $Z = \theta'^T x_j$ の s_j のもとでの条件付き分布は, 期待値 $\bar{z} = \theta_j^T x_j$, 分散 $\sigma^2 = x_j^T \Sigma_j x_j$ の正規分布である. これを用いると,

$$\begin{aligned} & - \int e^{-\rho z} f_{Z|s_j}(z|s_j) dz \\ &= - \int e^{-\rho z} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z-\bar{z})^2}{2\sigma^2}\right) dz \\ &= \int \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z-\bar{z}+\rho\sigma^2)^2}{2\sigma^2}\right) dz \\ & \quad \times \left(-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)\right) \end{aligned}$$

が得られる. この式の最右辺の被積分関数は, 期待値 $\bar{z} - \rho\sigma^2$, 分散 σ^2 の正規分布の密度関数であるからその積分値は 1 である. ゆえに式 (2) は $-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)$ と等しい.

以上により式 (2) の最大化は, $-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right)$ の最大化に帰着することがわかった. さらにすべての x_j と x'_j に対して,

$$-\exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right) > -\exp\left(-\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2\right) \quad (17)$$

$$\Leftrightarrow \exp\left(-\rho\bar{z} + \frac{\rho^2}{2}\sigma^2\right) < \exp\left(-\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2\right) \quad (18)$$

$$\Leftrightarrow -\rho\bar{z} + \frac{\rho^2}{2}\sigma^2 < -\rho\bar{z}' + \frac{\rho^2}{2}\sigma'^2 \quad (19)$$

$$\Leftrightarrow \bar{z} - \frac{\rho}{2}\sigma^2 > \bar{z}' - \frac{\rho}{2}\sigma'^2 \quad (20)$$

$$\Leftrightarrow \theta_j^T x_j - \frac{\rho}{2} x_j^T \Sigma_j x_j > \theta_j^T x'_j - \frac{\rho}{2} x_j'^T \Sigma_j x'_j \quad (21)$$

であるから, 最適化問題 (2) は別の最適化問題 (4) に帰着する.

金融機関のテキストデータを活用した景気センチメントの計測

Measuring Economic Trends based on Financial Institution Texts

近藤 浩史*¹
Hirofumi Kondo

與五澤 守*¹
Mamoru Yogosawa

成瀬 道紀*¹
Michinori Naruse

森 正和*¹
Masakazu Mori

*¹ 株式会社 日本総合研究所
The Japan Research Institute, Limited

Despite statistics released by the government or central banks have been used to grasp the economic trends, there is a lag in the timing of the survey and publication of the results. Therefore, there have been a lot of research to estimate them ahead of the publication. In this research, we tried to quantify the economic sentiment indicator by analyzing the huge amount of text data created and accumulated in financial institutions. As a result, it was found that our indicator had a high correlation with the Bank of Japan TANKAN, short-term economic survey of enterprises in Japan, and also had a quick reporting nature.

1. はじめに

グローバル化・IT化により経済情勢の変化速度が早まり、企業は迅速に現状の経済情勢や景気概況を把握する事が重要となっている。従来、経済情勢等を把握するには、政府や中央銀行が公表する統計を活用してきた。一方、このような統計は、調査から公表に一定時間を要するため、統計を補完し、かつ速報性のある新しい指標が必要となってきた。

新しい指標の構築に向け、[経済産業省 2017]では民間企業のデータである SNS や POS 等のビッグデータから AI 技術を活用し、速報性に優れた景気指標の開発に取り組んでいる。

他にも AI 技術を活用し、中央銀行が発行する公的な文書や SNS 等の情報から景況感を示す指数の構築や、経済指標の推定が試みられてきた[饗場 2018][大和証券株式会社 2017][余野 2018]。特に[饗場 2018]では、Twitter から「抽出 AI」を用いて景気に関するツイートを抽出し、得られたツイートに対して「評価 AI」を用いることで景況感を示すセンチメントを算出している。算出した指数は景気ウォッチャー調査*¹ 現状判断 DI(全国:原数値)と高い相関が得られたと報告されている。

本研究では、金融機関が保持するテキストデータを活用して、景況感を反映し、かつ速報性のある景気センチメント(一定期間の景況感を反映した指数)の計測を目的とする。特に本研究は、金融機関の社員が取引先企業との面談を通して作成したテキストデータ(以下、計測対象テキストと記載)を活用して景気センチメントを計測する。

金融機関は日常的に企業の経営者や担当者と接する機会があり、金融機関が作成するテキストデータには、経済活動と関連する記載を含む可能性が高い。また、SNS とは異なり、内容も一定の品質が保たれているため、景気センチメントを計測する元データとして有望と考える。

結果として、本研究で計測した景気センチメントは景況感を示す代表指標である日銀短観と高い相関を示すことが分かった。また、事前に予測できないイベント(地震等)が発生した場合の景況感について、速報性がある可能性を示唆した。

2. 景気センチメント指数の構築

先行研究[饗場 2018]を参考とした。計測対象テキストから景気に関連する文(以下、景気関連文と記載)を抽出し、各文の

景況感を数値化して景気センチメントを計測する。本節はそれぞれの実現方法を述べる。

2.1 計測対象テキストと前処理

計測対象テキストは 2006 年 1 月～2018 年 8 月に作成されたテキストである。計測対象テキストには経済環境等に触れた内容も含むが、景気とは全く関連しない内容も多数含む。

計測対象テキストは複数の文書から成り、それぞれの文書を文に分割して使用した。文を単語に分割する際には MeCab*²を使用し、辞書として mecab-ipadic-NEologd[佐藤 2017]と独自の金融用語辞書を組み合わせて使用した。

また、意味ある文を構成しないと想定される短文(動詞、名詞、形容詞の合計が 5 単語以下の文)は事前に除去した。このようにして全体で約 5,000 万件の文を得た。以下では、計測対象テキストの前処理済みの文を計測対象文と呼ぶ。

2.2 景気関連文の抽出

景気関連文の抽出では、景気ウォッチャー調査の景気判断理由集を学習データとして活用する。

景気関連文抽出モデルは入力文が景気ウォッチャー調査の景気判断理由集に含まれる文(以下、調査文と記載)か、計測対象文かを分類する文章分類モデルである(図 1)。

学習済みモデルに計測対象文を入力し、調査文と分類された文は、景気判断理由集に含まれる文に類似する文、すなわち景気関連文と見なせる。つまり、計測対象文を入力したにもかかわらず、モデルが調査文と誤判定した文を収集することで、景気関連文を抽出する。

文章分類モデルとして、以下に示す 5 つのモデルを作成・比較した。

*1: 内閣府 景気ウォッチャー調査

(https://www5.cao.go.jp/keizai3/watcher/watcher_menu.html)

*2: MeCab : Yet Another Part-of-Speech and Morphological Analyzer (<https://taku910.github.io/mecab>)

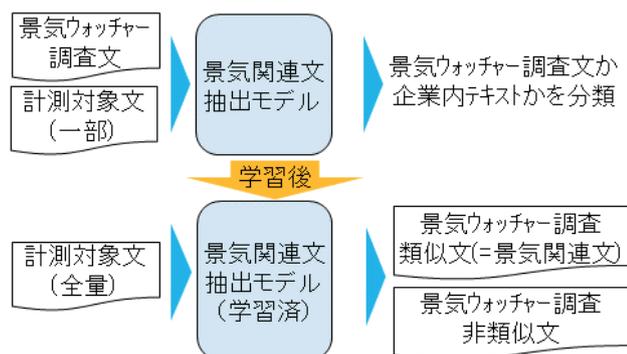


図1: 景気関連文抽出モデルの概念図

- 【TF-IDF/LR モデル】 訓練時に使用した文に含まれる単語の TF-IDF を特徴量として、ロジスティック回帰モデルで文章を分類するモデル. TF-IDF の特徴量として、単語の出現頻度が 5 以下の単語は無視した.
- 【CNN/NN モデル】 先行研究[Kim 2014]をベースとしたモデル.
- 【双方向 LSTM (BiLSTM) /NN モデル】 双方向 LSTM (以降, BiLSTM と記載) とニューラルネットワークを組み合わせたモデル.
- 【SWEM/LR モデル】 [Shen 2018] に SWEM-concat と記載されたモデル. SWEM-concat の特徴量を文の特徴量として、ロジスティック回帰で文章を分類するモデル.
- 【アンサンブルモデル】 景気関連文の抽出精度向上を目的とし、上記 4 つのモデルをアンサンブルしたモデル. 各モデルから出力された調査文らしさのスコアが、予め決めた閾値よりも大きい場合に、文を抽出する.

各モデルは調査文 (2013 年 1 月～2018 年 8 月) および計測対象文を元に学習させた. 学習ではそれぞれ 5 万文 (計 10 万文) をランダムに選択して用いた. 評価にはそれぞれ 6 千文 (計 1.2 万文) をランダムに選択して文章分類モデルの性能を評価した. 訓練済みの単語の分散表現が必要な場合は、計測対象テキストから学習させた 200 次元の word2vec (Skip-gram) モデル [Mikolov 2013] を作成・利用した.

表 1 は文章分類モデルの性能評価の結果である. どのモデルも高精度で調査文と計測対象文を分類できる.

表1: 文章分類モデルの性能

	精度	再現率	F 値
TF-IDF/LR	0.986	0.989	0.987
CNN/LR	0.990	0.993	0.992
BiLSTM/NN	0.987	0.983	0.985
SWEM/LR	0.979	0.983	0.981

2.3 文の景況感の数値化

先行研究[山本 2016]と同様に、深層学習を使用した回帰モデルを構築した. 学習済みモデルに文を入力すると、入力文が内包する景況感が数値化されて出力される. 本研究では景気ウォッチャー調査の景気判断理由集の文 (2013 年 1 月～2018 年 8 月) から学習データ (153,913 件) および評価データ (17,104 件) をランダムに選択・使用して、モデルを構築・評価した.

テストデータに対する平均二乗誤差は 0.309 となり、先行研究 [山本 2016] と同等の結果を得た. ここでも訓練済みの単語の分散表現が必要となるため、前述と同様の word2vec モデルを使用した.

表 2: 文章分類モデルごとの相関係数

モデル名	相関係数/ t 値(N=51)	四半期ごと 計測対象文数(千件)
TF-IDF/LR	0.843 / 11.0	11.0
CNN/NN	0.831 / 10.5	8.4
BiLSTM/NN	0.834 / 10.6	6.7
SWEM/LR	0.868 / 12.2	14.8
アンサンブル (閾値 2)	0.823 / 10.2	7.2

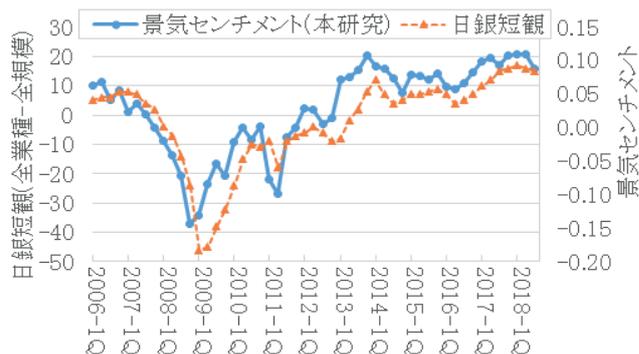


図2: 日銀短観と景気センチメント(景気関連文のみ)の時系列

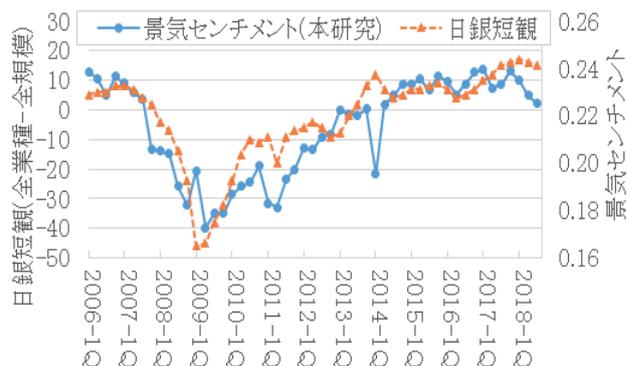


図3: 日銀短観と景気センチメント(計測対象全文)の時系列

2.4 景気センチメントの計測

各文の景況感を示す数値を一定期間ごとに集計し、景気センチメントとして計測する. 本研究では、予め決めた期間ごとに、各文に付与された景況感の数値の単純平均を計算する.

例えば、四半期単位の景気センチメントを計測する場合、3ヶ月ごと、当該期間の文につき、景況感の数値の平均を算出する.

3. 評価

3.1 日銀短観との相関分析

計測した景気センチメントが世の中の景況感を示す値であるかを検証するため、日銀短観-業況判断-最近(全産業-全規模) (以下、日銀短観と記載) との相関を分析した. なお、日銀短観の公表頻度は四半期である. また、日銀短観の第四四半期の指数は 12 月中旬に公表されるが、景気センチメントの第四四半期の計測にあたっては 12 月末までを集計範囲としている.

表 2 に景気関連文の抽出モデルを変えた場合の、景気センチメントと日銀短観の相関係数を記載した. どのモデルを使用しても、計測した景気センチメントは日銀短観と高い相関関係

(係数 0.8 以上)を示すことが分かる。特に SWEM とロジスティック回帰を使用する抽出手法が最も良かった。

景気関連文の抽出精度向上を狙って閾値を 2 とした場合のアンサンブルモデルは係数が低下する。これは、景気関連文を絞り込み過ぎると、計測対象となる文数が減少し、一部の文が示す景況感に左右されるためと考えられる。集計対象となる文数が少ない CNN/NN や BiLSTM/NN においても、同様の傾向が見られる。

今回使用した計測対象テキストに対しては、景気関連文と似ている文章を幅広く取得する手法を用いることで、良い景気センチメントを算出できる。

3.2 日銀短観と景気センチメントの時系列推移

図 2 に日銀短観と景気関連文から計測した景気センチメントの推移を図示した。なお、文の抽出モデルは SWEM/LR を使用して計測した。図 2 より、景気関連文から計測した景気センチメントは日銀短観におよそ追従することが読み取れる。特にリーマンショック(2008 年)や、東日本大震災(2011 年)のイベント時には連動している様子が顕著に読み取れる。

一方、図 3 は、景気関連文の抽出効果を示すために、計測対象文の全文から景気センチメントを計測した場合の時系列推移である。図 3 を見ると、計測対象文の全文から計測した景気センチメントも全体的な動きは日銀短観におよそ追従するが、異なる動きをしている点もある。特に 2014 年第一四半期では両者が大きく反対に動いている点が挙げられる。

図 2 と図 3 から、日銀短観との追従という観点においては、景気関連文を抽出することで、良い景気センチメントを計測できることが分かる。これは、計測対象文から景気に無関係な文、すなわち、計測のノイズとなる文を除去できたためと考える。

3.3 指数の速報性

図 2 によると計測した景気センチメントは日銀短観を先行していると読み取れる部分もある。

例として東日本大震災直後に公表された 2011 年第一四半期の指数に着目する。東日本大震災の発生により、日本の景況感悪化したはずであるが、日銀短観は震災発生の直後に悪化の方向に動いていない。これは、震災が 2011 年 3 月 11 日に発生した一方、日銀短観の企業へのヒアリング期間が 2011 年 2 月 24 日～3 月 31 日であるため、日銀短観が震災の影響を完全に反映しきれていない可能性があるためと推測できる。一方、計測対象テキストは震災発生後も作成されており、3 月 11 日以降の景況感を強く反映した値を算出できたと考える。

このように、計測した景気センチメントは震災などの事前に予測できないイベントが発生した場合の景況感として、速報性のある数値を算出している可能性がある。

参考までに、月次で公表されている景気ウォッチャー調査現状判断 DI(全国:原数値)との相関を分析すると、こちらも高い相関(係数:0.838, t 値:18.8, N=152)を示す(図 4)。景況感を示す月次数値としての活用も可能と考える。

なお、[饗庭 2018]にて算出された SNS×AI 景況感指数と景気ウォッチャー調査 DI との相関係数は 0.79 と報告されており、単純な比較はできないものの、本研究の景気センチメントのほうが高い相関を示している。

4. まとめと今後の方針

本研究では金融機関のテキストデータから景況感を示す景気センチメントを計測した。テキストデータから景気に関連する文のみを抽出し、景況感を数値化することで、日銀短観と高い

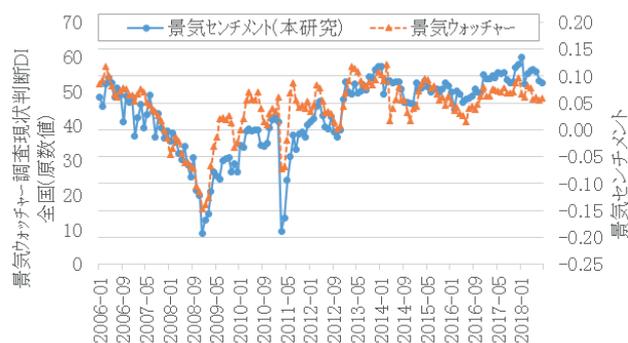


図4:景気ウォッチャー調査と景気センチメントの時系列推移

相関を持つ景気センチメントが計測できることを示した。また、震災などの予期しないイベントが発生した場合に、速報性のある景況感を計測できる可能性も示した。

今後は、他景気指標との関係を分析することや、得られた景況感の数値を用いた将来予測の可能性も検討したい。また、日銀短観との相関についても継続的に分析し、本研究の有効性をモニタリングする予定である。

5. 免責事項

本稿は著者らの見解を示すものであり、所属機関の公式見解を示すものではありません。

参考文献

- [経済産業省 2017] 経済産業省：平成 28 年度 IoT 推進のための新産業モデル創出基盤整備事業(ビッグデータを活用した新指標開発事業) 報告書, 経済産業省大臣官房調査統計グループ調査分析支援室委託調査, 2019.
- [饗庭 2018] 饗庭 行洋, 山本 裕樹：データサイエンスと新しい金融工学, 財界観測(2018 春号), 2018.
- [大和証券株式会社 2017] 大和証券株式会社：株式会社大和総研：「大和地域 AI(地域愛)インデックス」の公表について, プレスリリース, https://www.dir.co.jp/release/2017/20170713_012138.html (2018/2/4 アクセス), 2017 .
- [余野 2018] 余野 京登, 和泉 潔, 坂地 泰紀：金融レポート, およびマクロ経済指数による日銀センチメント指数の構築, 第 32 回人工知能学会全国大会, 2018.
- [山本 2016] 山本 裕樹, 松尾 豊：景気ウォッチャー調査の深層学習を用いた金融レポートの指数化, 第 30 回人工知能学会全国大会, 2016.
- [佐藤 2017] 佐藤 敏紀, 橋本 泰一, 奥村 学：単語分かち書き辞書 mecab-ipadic-NEologd の実装と情報検索における効果的な使用方法の検討, 言語処理学会第 23 回年次大会, 2017.
- [Kim 2014] Yoon Kim : Convolutional Neural Networks for Sentence Classification, EMNLP2014, 2014.
- [Shen 2018] Dinghan Shen, Guoyin Wang, Wenlin Wang, Martin Renqiang Min, Qinliang Su, Yizhe Zhang, Chunyuan Li, Ricardo Henao and Lawrence Carin : Baseline Needs More Love: On Simple Word-Embedding-Based Models and Associated Pooling Mechanisms, ACL2018, 2018.
- [Mikolov 2013] Mikolov Tomas, Sutskever Ilya, Chen Kai , Corrado Greg and Dean Jeff : Distributed Representations of Words and Phrases and their Compositionality, NIPS2013, 2013.

機械学習を用いた地域間の仮想通貨フローの可視化

Visualization of Inter-Regional Flows in the Virtual Currency using Machine Learning

全 珠美*¹
Joomi Jun

水野 貴之*^{1,*2}
Takayuki Mizuno

*¹ 総合研究大学院大学
SOKENDAI

*² 国立情報学研究所
National Institute of informatics

Human activity creates a specific pattern in 24 hours. The patterns can be influenced by the time zone they live in. Therefore, we can classify their time zone by their activity pattern. We have built a bitcoin-time zone classifier using XGBoost, a machine learning approach. We have classified the time zone of the specific bitcoin addresses used in the Ponzi event and visualized the flow.

1. はじめに

激しい価値当落やその財貨としての信頼性に疑問を挙げるにも関わらず、仮想通貨への人々の興味や投資今でも続いている。ビットコインの場合、2017年の最高値以来、値段も取引量も下がっているが、いまだ仮想通貨市場で最大の出来高を維持している[CM 19]。我々は代表的な仮想通貨であるビットコインにおける各ユーザーの取引の日中パターンを機械学習により分類することで、ユーザーの活動地域を推定し、サイバー空間で行われている仮想通貨の流れを実空間に可視化する。

ビットコインは実空間に関して強い匿名性を持っていると思われるが、ユーザーやビットコインの流れを追跡することは不可能ではない。アドレスのクラスタリングからユーザーを特定する手法[Reid 12]、ビットコインのノード間のメッセージからノードのIPを推定する手法[Kaminsky 11, Juhasz 16]などが提案されている。このようにビットコインの匿名性を解消しユーザーの空間情報を明らかにする研究は行われている。

サイバー空間でのユーザーの空間情報を推定する手法はソーシャルメディアでもよく研究されている。例えば、Twitterにおけるユーザーの投稿パターンから地域情報を推定することができる[Mahmud 14]。

本稿では、はじめに、仮想通貨コミュニティウェブサイト Bitcointalk.org で活動するビットコインユーザーの活動関連データ(活動地域、投稿履歴、取引履歴)を分類学習機の学習データとして活用し、取引の地域を分類する分類器を作成する。作成した分類器を用いて、活動地域が不明な十分に取引数があるユーザーに関して、取引パターンから実空間における活動地域を推定する。

次に、推定された活動地域を用いて、特定のビットコインの実空間における流れを分析する。我々は2015年から2016年に掛けて Bitcointalk.org に掲載され行われた特定の Ponzi イベントに注目した。ビットコイン市場の Ponzi イベントは、ユーザーがあるアドレスにビットコインを送ると、イベント主催者は集まったビットコインで投資や事業をおこない、ビットコインを送ったユーザーには何パーセントかの利益が上乘せられて返還される。一般的に、イベント参加者が増えると、初期参加者が利益を得る構造があり、乗り遅れまいと多くのユーザーが殺到する。そして、しばしば、後期参加者には、ビットコインの返還がなされない。我々は、被害者のいる Ponzi イベントにおける実空間でのビッ

トコインの流れを可視化し、どの地域で活動するユーザーが利益を、また、被害を受けているのか明らかにする。

2. データセット

ユーザーの活動パターンを分析するため二つのデータセットを用意した。一つ目はビットコインと関連して地域情報が分かるユーザーのデータである。我々は仮想通貨コミュニティウェブサイト Bitcointalk.org における2009年12月から2018年9月までの、ビットコインに関する3,251,067件の投稿記事と投稿日時、そして、その間の全891,795人の投稿者に紐づく、ユーザー名、ユーザーレベル(投稿頻度等)、ユーザーの地域情報(タイムゾーン)を収集した。本サイトの地域情報はGMTに初期設定されているため、地域情報がGMTになっているユーザーは解析から除外した。

二つ目はビットコインの取引履歴データである。公開されているビットコイン取引の情報の中から、ビットコイントランザクションID、直接やり取りしたビットコインアドレス、ビットコインの量、直前・直後のトランザクションID、そして、Bitcointalk.orgでユーザーが公開したビットコインアドレスの取引データを、www.walletexplorer.comを利用して集めた。ビットコインアドレスは、ウォレット形式にクラスタリングされている。また、主要なウォレットは、「取引所」や「マイニング」など取引種別のTAGが付けられている。

3. ビットコインユーザーの地域推定

人間は一日中必ず休みの時間が発生するが、その時間帯は地域(タイムゾーン)によって変わる。日本人とアメリカ人の日中活動をGMTに変換しパターン化すると、その形が異なる。つまり、ユーザーの活動パターンが地域(タイムゾーン)の影響を受けるため、そのパターンで地域を推定することができる。

我々はまず、Bitcointalk.orgで公開されているユーザーのビットコインアドレスデータから、サイトにおける投稿のパターンとビットコイン取引パターンに注目した。Fig. 1は投稿と取引のパターンを表しており、二つのパターンが類似していることが読み取れる。

次に、Bitcointalk.orgのユーザー投稿パターンを用いてビットコイン取引が行われる地域を推定する分類器を構築する。ユーザーの投稿パターンデータと地域情報を学習データセットとした。パターンを十分に学習させるために、学習データは、日中5時間以上の時間帯で投稿を行ったユーザーに限定した。地域の分類は、ヨーロッパEU(GMT+1~3)、アジアASIA(GMT

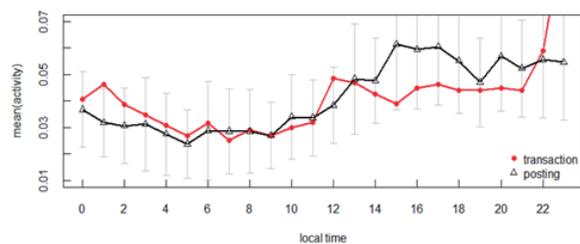


Fig. 1 : ユーザーの投稿パターンとビットコイン取引パターン

	投稿データ	取引データ
Accuracy	0.888	0.91
95% CI	(0.86, 0.912)	(0.871, 0.939)
No information rate	0.333	0.333
Kappa	0.832	0.865

Table 1 : ユーザー地域分類学習の結果

+7~9)とそれ以外の地域 OTH の三つに分類した。ヨーロッパとアジアのユーザーは今回使ったデータの 89%を占めていた。アップサンプリングをおこなうことにより、サンプルサイズの偏りをなくした。

本稿ではユーザーの活動パターンから地域を推定する分類器の構築に、機械学習の一種である XGBoost[Chen 16]を採用した。XGBoost は Random Forest アルゴリズムを基盤とし、Gradient Boosting を結合した学習法である。速度の遅い Gradient Boosting を並列処理で行っているため学習や分類の信頼性と速度が優れている。我々は、学習データをトレーニングデータセット (80%)とテストデータセット (20%) に分け、XGBoost で学習した結果が Table 1 である。地域推定を 90%に近い精度でおこなえていることが分かる。

4. イベントにおけるビットコインの地域間の流れ

構築した地域(タイムゾーン)分類器を利用し、特定の Ponzi イベントにおける地域間のビットコインの流れを分析する。はじめに、イベント主催者のウォレットを中心に、直前(送った)・直後(貰った)取引先の地域を分類する。Fig. 2 の地域別取引回数から、EU ユーザーを対象としたイベントであることが読み取れる。

次に、イベント主催者のウォレットに送る前の3取引先と、主催者のウォレットから受け取った後の3取引先を調査し、地域間の流れを観測する。Fig. 3 は、前・後三つまでの取引先の地域を分類し、各地域間におけるビットコインの出来高(BTC 量)を表している。同地域間の取引が多いことが分かる。つまり、匿名性を持つビットコイン市場であっても、物理的距離の近いユーザー同士が主に取引している。

物理的距離が近いユーザー間の取引が多い理由の一つは、ビットコイン取引ネットワークにおけるハブの存在である。取引所やサービス系会社(ATMやPayment)のウォレットがハブの役割をしており、このハブの活動パターンは、しばしば地域的特徴を強く持っている。各地域のユーザーは、その地域のこのようなハブを好んで利用する傾向があり、その結果が、地域内の取引が多い要因になっている。今回、分析を行った Ponzi イベントの前後の取引で利用された TAG 付がなされたウォレットの中でも、取引所が 24.9%、サービス系会社が 25.3%を占めていた。

5. おわりに

本研究では機械学習手法 XGBoost を利用し、ビットコインコミュニティにおけるユーザーの投稿パターンとビットコイン取引のパターンからユーザーの地域を推定する分類器を作成した。こ

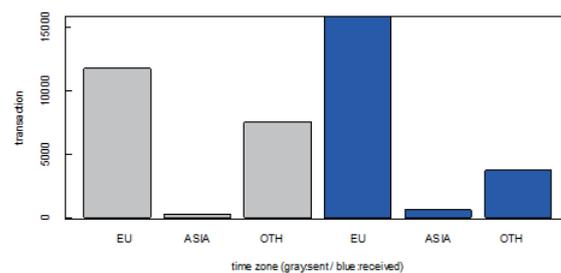
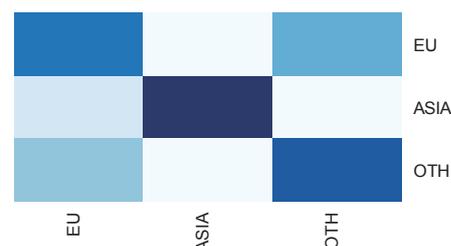
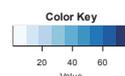


Fig. 2 : イベント参加者の地域別取引回数

Fig. 3 : 地域別ビットコインの流れ(%)
(X : Target / Y : Source)

の分類器を用いて特定の Ponzi イベントに参加したビットコインユーザーの地域を推定し、ビットコインの実空間での流れを調査した。このイベントは、EU ユーザー向けに開催されており、各地域内で主に取引されていたビットコインが、ユーザーがこのイベントに参加することで、EU に流れ込み、その後、それらのコインは EU 内で流通していることが分かった。つまり、このイベントで各国に被害者がいるとすると、被害者のビットコインは主に EU 域内で流通していると言える。

ビットコイン以来、多種多様な仮想通貨が生み出され、その利用範囲は拡大している。仮想通貨は、主にサイバー空間で取引されるが、その取引は実空間での社会生活や経済活動と密接に関係している。この関係性を理解するためには、実空間に射影した流れや利用の特徴を把握する必要がある。本研究のような、仮想通貨の流れを実空間に可視化する努力がこれからも必要になる。

参考文献

- [CM 19] <https://coinmarketcap.com/coins/>(Accessed 2019 Feb)
- [Reid 12] Reid, F.; Harrigan, M. : An Analysis of Anonymity in the Bitcoin system, Security and Privacy in Social Networks, 197-223, 2012
- [Kaminsky 11] Kaminsky D. : Black Ops of TCP/IP, Presentation, Black Hat & Chaos Communication Camp, 2011
- [Juhasz 16] Peter L. Juhasz, Jozsef Steger, Daniel Kondor, Gabor Vattay. : A Bayesian Approach to identify Bitcoin Users. PLoS ONE, 2016
- [Mahmud 14] Jalal Mahmud, Jefferey Nichols, Clemens Drews : Home Location Identification of Twitter Users, ACM Transactions on Intelligent Systems and Technology, 2014
- [Chen 16] Tianqi Chen, Carlos Guestrin. : XGBoost: A Scalable Tree Boosting System, In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016

火災事故が被災企業に及ぼす経済的影響の把握に向けた統計的分析

Statistical analysis aimed at assessing the economic impact of fire accidents on damaged companies

佐藤 遼次*¹ 佐藤 一郎*¹ 水野 貴之*²
Ryoji Sato Ichiro Sato Takayuki Mizuno

*¹ 東京海上日動リスクコンサルティング株式会社 企業財産本部
Property Risk Engineering Department, Tokio Marine & Nichido Risk Consulting Co., Ltd.

*² 国立情報学研究所
National Institute of Informatics

We aim to clarify the trends of fire impacts on corporate finance and stock markets through statistical and machine learning analysis on data sets of companies suffered from fire accident. In this paper, we confirmed that the effect on corporate finance become larger on the fire accidents having certain characteristics in the newspaper articles. We also confirmed that the trend of the impact on corporate finance can be predicted by considering the type of industries and certain characteristics in newspaper articles in a complex manner. We will also report the result of the analysis about trend of impact on stock market in this conference.

1. はじめに

企業が火災事故により被災した場合、生産設備等の資産の損失、事業継続性の損失などの直接的な影響に始まり、株価の下落という形で株式市場へも影響を及ぼし得る。実際の個々の火災事故に対する直接的な影響は、上場企業であれば、公開されている財務指標から確認することが(例えば[鈴木 2012]のように)可能である。また株価への影響についても、過去の株価データにアクセスすることで、個々の被災企業における影響を確認することは容易である。

しかしながら、企業における火災事故全体を考えた場合、企業財務や株式市場に有意に影響を及ぼしているのか、またそれはどういった特徴を持つ火災事故の場合なのか、といった疑問について明らかにしようとした研究は、著者らの知る限り存在しない。こうした疑問について明らかにすることは、防火・防災活動に取り組む当事者企業や、そうした活動を支援する様々な機関・企業にとって有益と考えられる。

そこで本研究では、過去の火災事故事例から構築したデータセットに対する統計的および機械学習を用いた分析を通じて、火災事故が企業財務や株式市場へ及ぼす経済的影響の傾向を明らかにすることを目的とする。本稿ではまず、新聞データベース及び企業情報のデータベースから、多数の火災事故事例を整理したデータセットを作成する。次に、それらの情報を企業の財務指標データベースと照合・分析することで、火災事故による直接的な被害の傾向について明らかにする。更に、その結果を株価のデータベースとも照合することで、直接的被害の傾向との対比から、株式市場への影響の傾向についても明らかにすることを目指す。

2. 手法

2.1 火災事故データセットの作成

まず、新聞データベース及び企業情報のデータベースから、企業の火災事故に関するデータセットを作成した。新聞データ

ベースとしては、(株)日本経済新聞社の記事データベースから、火災事故に関係する記事データを抽出したものを使用した。抽出したデータの諸元を表 1 に示す。

次に、各記事に付与されている株式コードを検索キーとして、火災に関する記事を企業単位で抽出した。抽出対象とした企業は、表 2 に示す 7 業種、計 657 の上場企業である。なお、企業の業種分類は、日本経済新聞の日経業種分類([日本経済新聞社])に基づいている。また、持株会社設立等により過去に株式コードが変更されている企業については、変更前の株式コードも極力検索キーに含めるよう補完して抽出を行った。結果として、計 71 の企業に対して、火災事故の発生を報じる記事を抽出した。

また、一つの企業において複数件の火災事故が報じられている場合には、それらを区別して整理することで、計 156 件の火災事故を特定した(表 2)。以上を通じて、各火災事故に関する新聞記事の情報を整理することで、火災事故及び被災企業の情報をまとめたデータセットを作成した。

2.2 財務指標データセットの準備

財務指標に関するデータベースには、トムソン・ロイターの QA Direct (1980~2016 年)を使用した。このデータベースには、企業が有価証券報告書や四半期報告書において公開している財務指標の値が纏められている。本研究ではこのデータベースから、以下に記す 2 つの財務指標を利用した。

1 つ目は、特別損失 (EXTRAORDINARY_CHARGE-PRETAX) である。有価証券報告書等における決算報告とは、企業会計原則などの各種基準に基づき作成されており、その中で、災害による損失は特別損失として計上することが定められている。そのため、火災事故により発生する固定資産の減失・損失、損壊した資産の点検費、撤去費用などを、「火災による損失」等の勘定科目で特別損失に計上することが一般的となっている。従って、特別損失の値を利用することで、火災事故による被害を定量的に捉えることができると考えた。

連絡先: 佐藤遼次, 東京海上日動リスクコンサルティング(株)
企業財産本部, 東京都千代田区大手町 1-5-1, 03-5288-
6234, roji.sato@tokiorisk.co.jp

表 1 : 抽出した新聞記事データの諸元

対象媒体	日本経済新聞, 日経産業新聞, 日経MJ, 日経地方経済面
抽出条件	テーマ分類: 火災 (# W50202) コード付与 ^{※1} , 且つ, 企業が主題の記事 ^{※2}
対象期間	1975年1月1日~2018年6月10日
抽出件数	4,865件

※1 データベース側で自動付与されるコード. 火災に関連する単語の知識辞書, 及び前後の単語との共起などから判定される.

※2 データベース側で自動付与される属性. 企業名の登場回数や登場位置などの条件を考慮して判定される.

表 2 : 抽出した火災事故の内訳

業種番号	業種名	企業数	火災が報じられている企業数	火災事故件数
1	自動車	76	12	27
2	ゴム	20	1	4
3	鉄鋼	47	12	49
4	化学	207	30	51
5	機械	234	4	8
6	繊維	49	6	10
7	パルプ・紙	24	6	7
-	合計	657	71	156

但し, ここで取り扱う特別損失の値には, 火災事故以外の災害損失, 或いは固定資産売却損, 有価証券の売却損など, 火災事故とは無関係な損失が一定程度含まれる可能性がある点に留意が必要である. また, 滅失した固定資産に火災保険が掛けられている場合には, 保険金の確定を待った上で, 保険金で賄われない分の損失だけが特別損失として計上される場合がある. 従って, 「火災による損失」等として計上されている金額は, 火災事故による損失の全てを含んでいない可能性がある点に留意が必要である.

2 つ目の財務指標は, 売上高 (NET_SALES_OR_REVENUES) である. これは, 特別損失の値を絶対値として扱うのではなく, 企業の規模の違いを考慮に入れて分析を行うために利用する.

以上 2 つの財務指標に関する決算期ごとの時系列データを, 先に抽出した火災事故の発生年月日と照合することで, 火災事故の発生前後における財務指標のデータセットを作成した.

2.3 企業財務への影響を測る指標の設定

火災事故が及ぼす企業財務への影響を評価するための指標として, 2.2 までで抽出した財務指標データより, 以下の指標を設定した.

$$\log_{10} \left(\frac{\text{loss}}{\text{sales}} \right) \quad (1)$$

ここで, *loss* は火災事故により被災した日を含む通期の特別損失 (円) を, *sales* は火災事故により被災した期の 1 つ前の期における通期の売上高を表している. そして, 特別損失を売上高で割り, 対数スケールに変換することで, 式(1)の通り指標を構築した. また, 元々の財務指標データベース側で特別損失または売上高の値が欠損しており, 指標が計算できない火災事故 35 件を除外し, 計 121 件の火災事故に対して式(1)の値を求め

た (特別損失が 0 円の場合は, 1,000,000 円に置き換えて計算した).

最後に, 式(1)に対して以下の通り規格化処理を行った. まず, 2.1 にて抽出した 71 の企業を対象に, 式(1)を財務データの全期間に適用して, 決算期別の平均値を求め, 時系列で描画したグラフを図 1 に示す. この図より, 式(1)の値は, 業種によらず, 時系列上で概ね共通した傾向を示すことが確認できる. これは即ち, 式(1)に含まれる火災事故以外の要素 (火災事故以外の特別損失) は, 個別企業ごとの経営状況などの内部環境よりも, 景気等の外部環境によって一律に受ける影響が強く作用していることを示している. そこで, 異なる時期の火災事故を適切に比較するため, 各火災事故に対する式(1)の値から, 該当の決算期における, 式(1)の値の全企業平均値 (μ) を差し引くことで, 新たに指標 式(1')を以下の通り定義した.

$$\log_{10} \left(\frac{\text{loss}}{\text{sales}} \right) - \mu \quad (1')$$

指標 式(1')は, 正または負の値をとり, 値が大きいくほど, 火災事故による企業財務への影響が大きいことを示している. この指標を用いて, 火災事故による企業財務への影響を分析することとした (以下, 「指標」とは式(1')を指すこととする).

3. 分析と考察

3.1 火災事故の有無による企業財務への影響の評価

まずは, 単純に火災事故の有無によって, 指標の値の傾向に有意な違いが現れるのかについて検討した. 即ち, “火災事故で被災した決算期の特別損失”を用いて計算した指標の値 (「火災有り指標」と呼ぶ) と, “火災事故で被災していない直近の決算期の特別損失”を用いて計算した指標の値 (「火災無し指標」と呼ぶ) を比較して, 統計的に有意な違いが見られるのかについて確認した.

火災有り指標, 火災無し指標それぞれの値を, 火災事故ごとにプロットした散布図を図 2 に示す. これらの 2 標本に対して, 対応のある/対応の無い両側 t 検定による平均値の検定, Kolmogorov-Smirnov 検定による分布の検定を実施したところ, いずれも有意な差は認められなかった (表 3).

ここで, 火災有り指標が扱っている火災事故の中には, 大小様々な規模の火災が含まれている. 従って, これらの火災事故を一律に抽出しただけでは, 火災事故が無い決算期と比べて, 企業財務への影響が有意に確認できるわけではないことが示された.

3.2 企業財務に影響を及ぼす火災事故が持つ特徴の分析

3.1 の結果を踏まえ, どのような特徴を持つ火災事故であれば, 企業財務への影響が有意に大きくなるのかについて検討した. ここで, 2.1 で整理した各火災事故に関する新聞記事から得られる情報を用いて, 以下のような特徴を設定した.

- 特徴 1: 決算への影響に関する単語の有無
…決算や株価に関する単語が新聞記事中に登場すること
- 特徴 2: 操業への影響に関する単語の有無
…操業や生産に関する単語が新聞記事中に登場すること
- 特徴 3: 記事本文の総文字数
…ある火災事故に関する一連の新聞記事における, 記事本文の総文字数が一定以上であること

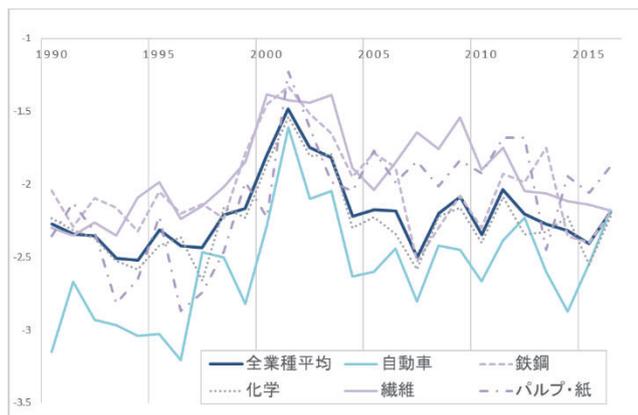


図 1：指標式(1)の年別平均値

※ 1990 年以前は値の欠損が多いため、また、業種「ゴム」「機械」は企業数自体が少ないため、図から省略。

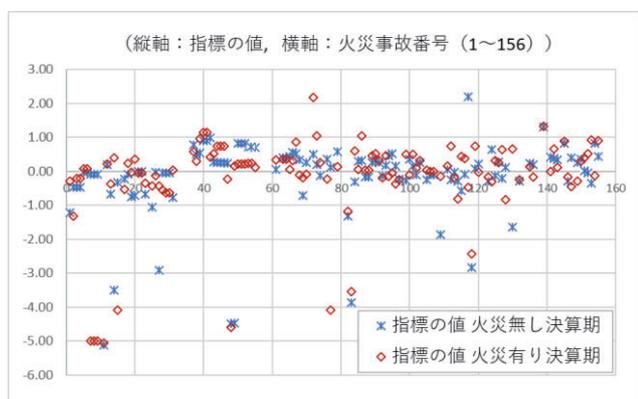


図 2：火災事故の有無に応じた指標式(1)の値の分布

表 3：火災事故の有り・無しにおける指標式(1)の平均と分布の検定

	N	平均	SD	t 値*	D
火災無し_全件	121	-0.14	1.09	0.26	0.058
火災有り_全件	121	-0.17	1.30	(n.s.)	(n.s.)

n.s. 有意差なし, *p < .05, **p < .01

(※t 値は対応のある t 検定における値)

以上の 1~3 の特徴に該当する火災事故を判定するため、以下の要領で具体的な基準を設定した。

まず、特徴 1・特徴 2 に関する判定を行うために、日経新聞社によって各記事に自動付与されている「keyword」という情報を利用することとした。この keyword には、記事の文中から切り出した単語、またはその単語を正式名称に変換したものが格納されている。次に、企業財務への影響が大きい火災事故にはどのような keyword が格納されているのかを把握するため、Web 上で閲覧できる範囲の有価証券報告書から、“実際に火災による損失が特別損失に計上されている火災事故”を 25 件まで特定した上で、それらの火災に関する新聞記事に含まれている keyword を抽出・整理することで、特徴 1・特徴 2 を定義付ける単語リストを作成した(表 3)。また、特徴 3 については、1 つ 1 つの新聞記事の本文に書かれている文章の文字数を、火災事故ごとに合算することで、総文字数を求めた。その上で、“総文字数 1,500 文字以上”を閾値として設定した。

表 3：特徴 1・特徴 2 を定義する単語リスト

単語リスト_特徴 1 (決算への影響に関するもの)	連結決算 / 収益見通し / 純利益 / 決算 / 売上高 / 営業利益 / 減益 / 損失 / 連結 / 特別損失 / 経常利益 / 経常益 / 企業業績 / 株主総会 / 経常増益 / 配当 / 収益 / 利益 / 業績 / 株価 / 連結営業利益 / 連結売上高 / 経常減益 / 予想 / 営業減益
単語リスト_特徴 2 (操業への影響に関するもの)	再開 / 操業再開 / 復旧 / 操業停止 / 減産 / 稼働 / 生産 / 停止 / 操業 / 生産計画 / 生産ライン / 生産動向 / 生産調整 / 生産量 / 生産中止 / 見通し / 回復 / 生産見通し / 生産拠点 / 生産能力 / 委託生産 / 再稼働 / 要請 / 委託 / 生産委託 / 供給停止 / 生産体制 / 工場再開 / 生産開始 / 操業開始 / 設備復旧 / 代替生産 / 長期化 / 生産再開 / 資材調達

以上の通り定義した特徴 1~3 に該当する/該当しない火災事故ごとに指標式(1)の値を分け、対応の無い片側 t 検定、Kolmogorov-Smirnov 検定をそれぞれ実施した。結果、有意水準 5%とした場合、いずれの特徴についても、平均値が有意に大きくなること、分布についても有意に異なることが確認された(表 4)。

以上より、企業財務に影響を及ぼす火災事故であるかどうかを判定するためには、記事中に決算や操業に影響することを表す単語が登場しているか、長い文章の記事で繰り返し報道されているか、といった特徴が有効であることが確認された。

3.3 機械学習を用いた企業財務への影響の傾向分析

3.2 より、新聞記事から得られる特定の特徴に着目することで、企業財務に影響を及ぼす火災事故を一定程度予測できる可能性が示唆された。そこで、こうした特徴を説明変数に、2.3 で設定した指標の値を被説明変数として回帰分析を行うことで、企業財務への影響を定量的に予測することを試みた。

回帰分析の手法にはランダムフォレストを用い、実装には Python のモジュールの 1 つである scikit-learn を用いた [Pedregosa 2011]。説明変数には、3.2 で述べた特徴 1~3 に加え、各企業が属する業種(7分類)を設定した。モデルの作成に当たっては、まず訓練データ:テストデータ=7:3 に分割した上で、訓練データに対して 3 分割交差検証によるグリッドサーチを行い、パラメータ(決定木の深さ、バギングに用いる決定木の個数)を決定した。ここで、精度の評価には本来テストデータのみを用いるべきであるが、本研究ではデータ数が限られることから、訓練データ・テストデータを合わせた全データに対してモデルを適用した結果で精度を評価することとした。

モデルを適用した予測結果を図 3 に示す。実データで外れ値と言える極端に大きな値についてはフィットしないものの、一定程度値の傾向を再現できていることがわかる。この精度を評価するため、実データ及び予測値に対してスピアマンの順位相関係数を求めたところ、相関係数=0.44 となり、有意水準 5%, 1% でそれぞれ有意であることを確認した。即ち、本モデルにより、実データとの順位相関を棄却することなく、指標(1)の値を予測できていることが確認された。

また、この予測モデルにおける特徴量の重要度を可視化した結果を図 4 に示す。この図から言えることとして、まず特徴 1~3 については、特徴 2(操業への影響に関する単語)、特徴 1(決算への影響に関する単語)、といった説明変数が予測に貢献

表 4: 特徴 1~3 における指標 式(1)の値の検定結果

	N	平均	SD	t 値	D
特徴 1	22	0.32	0.43	3.60**	0.78**
特徴 2	50	0.05	0.94	1.72*	0.31**
特徴 3	22	0.16	0.44	2.42**	0.78**

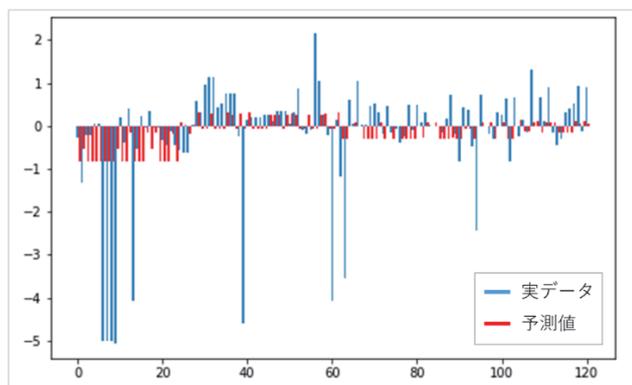
n.s. 有意差なし, * $p < 0.05$, ** $p < 0.01$ 

図 3: 指標 式(1)の実データと予測値の対比

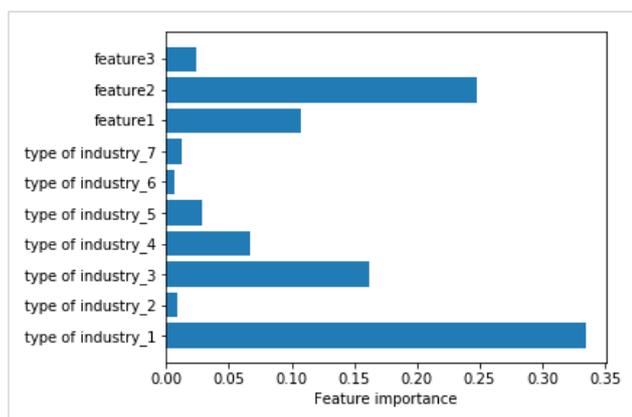


図 4: 予測モデルにおける特徴量の重要度 (type of industry の対応については表 2 を参照)

していることがわかる。3.2 の表 4 では、特徴 2 は最も平均値が低かったものの、該当するデータ数が 50 件と多いことから、他の特徴に比べて、決定木の分離に多く活用されたものと考えられる。また業種について見ると、業種 1 (自動車) の重要度が特に高くなっている。ここで、2.3 の図 1 を改めて見ると、自動車は他の業種に比べて指標の値が全体的に小さくなっており、この特徴によって被説明変数を効果的に分離できたものと考えられる。実際に、業種ごとの売上高としては自動車業が最も大きくなっており、火災で被災したとしても、売上高対比で見た影響は大きくなりにくい、という特徴が予測に貢献していると言える。

最後に、以上 3.1~3.3 の結果の総括として、各特徴を用いて火災事故を絞込んだ場合、およびランダムフォレストによる予測結果の上位に絞り込んだ場合における、指標値の分布を図 5 に示す。この図より、各特徴によって企業財務への影響が大きい火災事故を一定程度絞り込めること、また、それらの特徴を業種と併せて機械学習に供することで、影響の大きい火災事故をより精度良く予測できていることがわかる。これは言い換えれば、新聞記事による報道の特徴や、被災企業の業種といった属性を複合的に考慮することが、火災事故による企業財務への影響を予測する上で重要であることを示している。

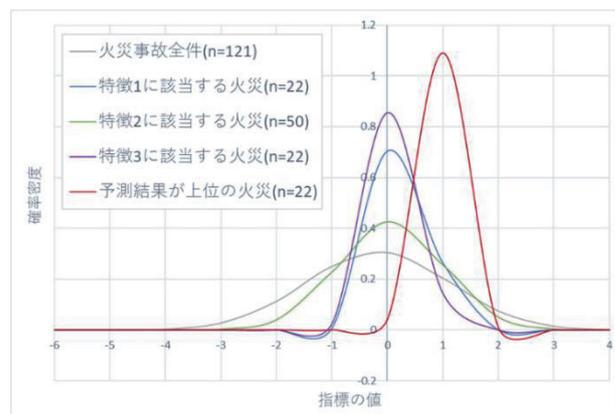


図 5: 特徴 1~3 に該当する火災事故、および、機械学習で予測した指標値の上位 22 件における指標値の分布

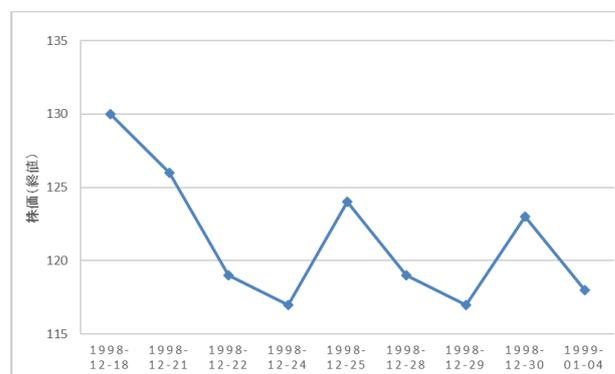


図 6: 某企業の火災事故前後における株価 (終値) の推移 (火災発生日: 1998-12-27)

4. 結論と今後の展望

本研究では、新聞記事データから特定した過去の火災事故事例を用いて、火災による企業財務への影響について分析した。結果として、単純な火災事故の有無だけでは有意な傾向の違いは確認できないものの、新聞記事での報道に一定の特徴を持つ火災に限定した場合、企業財務への影響が有意に大きくなることを確認した。また、業種や新聞記事に関する特徴を複合的に考慮することにより、企業財務への影響の傾向を一定程度予測可能であることを確認した。

今後は、火災事故による株式市場への影響についても分析を行う。今回特定した火災事故事例のうち、財務への影響が大きい火災を 1 つ取り上げ、火災前後における株価 (終値) の推移をプロットしたものを図 6 に示す。実際に、火災発生直後の取引日における株価の下落が確認できる。こうした傾向について、企業財務への影響の大きさととの比較を交えて分析を行い、結果を報告する予定である。

参考文献

- [鈴木 2012] 鈴木 拓人: 化学工場の爆発火災事故の増加とその影響について, NKSJ-RM レポート, 2012.
- [日本経済新聞社] 日経業種分類 (2018-11-30 閲覧)
<https://www.nikkei.com/markets/company/search/gyoshu/>
- [Pedregosa 2011] Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research*, 12:2825–2830, 2011.

新聞記事からの因果関係を考慮した アナリストレポートの自動要約文生成

Automatic Summarization of Analyst Reports Based on Causal Relationships from News Articles

高嶺 航^{*1}
Wataru Takamine

和泉 潔^{*1}
Kiyoshi Izumi

坂地 泰紀^{*1}
Hiroki Sakaji

松島 裕康^{*1}
Hiroyasu Matsushima

島田尚^{*1}
Takashi Shimada

清水 康弘^{*2}
Yasuhiro Shimizu

^{*1}東京大学大学院工学系研究科
School of Engineering, The University of Tokyo

^{*2}野村證券株式会社
Nomura Securities Co., Ltd.

In this paper, we focused on the causal relationships in both of news articles and analyst reports. We proposed a novel approach for summarizing analyst reports automatically based on the causal relationships extracted from both text data. As a first step toward summarization of analyst reports adequately, we analyzed the validity of the method in extracting causal relationships which can be evaluated from the analyst reports. As a result, the proposed method could extract basis information of analyst's opinions from analyst reports with some accuracy, and we could confirm the styles of analysts in expression of opinions and bases.

1. はじめに

近年、投資家に対する投資判断の支援を行う技術の必要性が高まってきており、投資判断材料の一つであるアナリストレポートの活用に注目が集まっている。アナリストレポートには、証券市場調査・分析の専門家である証券アナリストが企業の経営状態や収益力などを調査した結果がまとめられており、企業の業績や株価に対する証券アナリストの予想と根拠が示されている。記述されている予想の根拠としては、その企業の取り組む事業の近況・財務状況（企業のファンダメンタルズ）、事業に影響を与える経済・政治・社会状況（マクロ経済のファンダメンタルズ）などの外部要因についても言及されている。このように、高度な専門知識をもつアナリストによる詳細なレポートは、株価の変動要因にもなりうる [1] ため、彼らの企業の業績や株価に対する予想やその裏付けとなる根拠を投資判断の材料として活用することは有用性が高いと思われる。

しかしながら、アナリストレポートの発行の多くは決算発表の時期に集中し、膨大なレポートの全てを熟読するのは難しく、レポートの内容を十分に把握できない可能性がある。

この問題に対して、近年、自然言語処理やテキストマイニング技術の進展により、膨大な量のアナリストレポートから重要な要点のみを自動で抽出・要約する技術のニーズが高まっており、研究事例も報告されている [2][3]。このように、投資判断材料に必要な情報を要約することができれば、レポートを読む負担が減り、時間の制約がある中でもレポートの内容の要点を把握することができる。しかしながら、これら [2][3] の要約技術は、テキストに記述されている事象の背景にある因果関係を考慮していない。そのため、生成された要約文に、投資判断材料となりうる証券アナリストの予想の根拠が盛り込まれていない場合が想定される。これに対して、[4] では文の因果関係の構造に注目し、原因表現を取り出す手法を提案している。

このように、アナリストレポートの活用として自動的に重要な箇所を要約・抽出、あるいは検索する技術が研究されている。しかしながら、2つの異なる媒体（つまり、アナリストレポートとそれ以外のテキスト情報）から一つの要約文を生成する手法はまだ確立されていない。この手法の確立により、アナ

リストレポート中で業績・株価予想の根拠として言及される情報の特徴を捉えるだけではなく、新聞記事などの媒体からその根拠の背景についての情報を補うことで、より説明できる情報を含んだ要約文の生成が期待できる。さらに、これが可能になれば、要約の過程で抽出する証券アナリストの株価・業績予想につながる根拠や背景としての経済情報を検索できるようになり、証券アナリストのレポート作成支援としても期待できる。

そこで本研究では、因果関係を考慮しながら別の媒体から補填的に情報を抽出し、要約文を自動生成する手法を提案し、その評価を行う。本稿では、その提案手法実現のために、アナリストレポートから根拠情報を抽出する手法の妥当性について実験を行った。

2. 提案手法

本章では、テキストデータから因果関係表現を抽出し、要約文を自動生成する手法について述べる。2.1 節では本手法の概観、2.2 節ではアナリストレポートおよび新聞記事からの因果関係表現抽出の概要、そして 2.3 節では、要約文における根拠の背景情報の獲得に用いた表現類似度計算手法の概要を述べる。

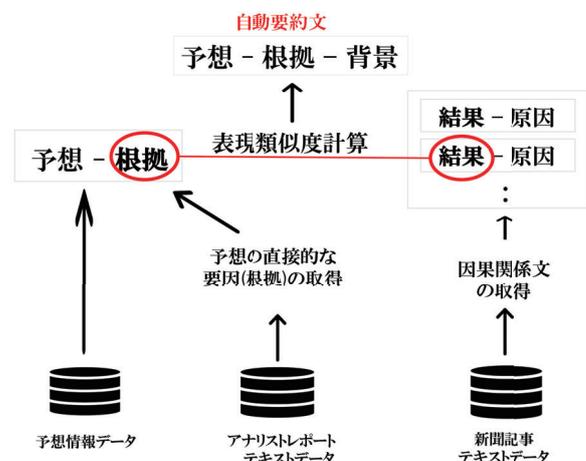


図 1: 提案手法の概説

連絡先: 高嶺航, 東京大学大学院工学系研究科技術経営戦略学専攻, 113-8656 東京都文京区本郷 7-3-1 工学部 8 号館 530 室, m2018wtakamine@socsim.org

2.1 要約文生成手法の概説

本節では要約文生成手法の概要を述べる。全体の流れを図1に示す。まず、各アナリストレポートにおける証券アナリストの企業業績・株価の予想の情報を獲得する。次に、アナリストレポート本文中に出現する因果関係の構造を抽出し、その中でも結果表現に株価・業績予想が含まれる因果関係を獲得する。獲得した因果関係の原因表現を証券アナリストによる企業業績・株価の予想の根拠情報として獲得する。ただし、この時、証券アナリストの予想情報とその予想の根拠情報は同文章内に出現するものと仮定している。つまり本手法では図2のように文章横断的に出現する因果関係表現は抽出しないこととする。また同様に、新聞記事からも因果関係の構造を抽出し、因果関係の結果表現のうち、獲得した証券アナリストの予想の根拠情報と表現が類似する文章を探索する。そして、類似性の高い因果関係における原因表現を根拠情報の背景情報として獲得する。このようにして獲得した、(1)証券アナリストの企業業績・株価予想、(2)予想の根拠(直接的な要因)、(3)根拠の背景をまとめ、アナリストレポートの要約文を自動生成する。

本自動要約手法の実装例として、Webサーバー上のシステムとして実装したものの動作画面を図3に示す。銘柄、期間を入力すると、すでに生成済みの要約文のうちから入力情報に合致する要約文を出力する。要約文の構成は、一文目に証券アナリストレポートの業績・株価予想、二文目に証券アナリストの予想の根拠、三文目にその根拠の背景を想定している。

文書1:業績予想を下方修正(結果表現)
文書2:〇〇を織り込んだ。(原因表現)

図2:文章横断的に出現する根拠情報の例

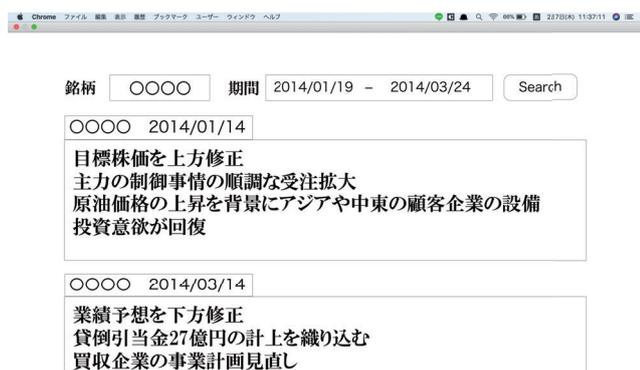


図3:想定している提案手法を用いたシステムの動作画面

2.2 因果関係抽出手法

アナリストレポート・日経新聞記事から酒井ら[4]の手法を用いて因果関係表現を抽出する。この手法では、因果関係表現を特徴付ける手がかり表現と、手がかり表現に係る節の中で共通して頻繁に出現する共通頻出表現を定義する。最初に少数の手がかり表現と共通頻出表現を与えることで、互いに係り受け関係にある新たな共通頻出表現と手がかり表現が連鎖的に獲得

される。この手法を用いる場合、アナリストレポートにおいては特にアナリストの予想を示す文の部分と、その予想の根拠を示す文の部分とを分離して抽出する。前者を予想部、後者を根拠部と呼ぶ。

アナリストレポート中から抽出した予想部と根拠部の例を図4に示す。この文章の場合、「主力の制御事業の順調な拡大を」を根拠部、「主因に」が手がかり表現、「目標株価を上方修正」が予想部となる。酒井ら[1]は、アナリストレポートからアナリストの予想と根拠情報の抽出を行なっているが、アナリスト予想根拠文の抽出方法として、共通頻出表現の数を用いてアナリストの予想根拠文かどうかを判定している。本手法では、予想の直接的な要因を根拠情報と定義しており、結果表現に業績予想が含まれる因果関係の原因表現を証券アナリストによる企業業績・株価予想の根拠情報として抽出する。

主力の制御事業の順調な受注拡大を
(根拠部)

主因に、目標株価を上方修正

(手がかり表現) (予想部)

図4:アナリストレポートから抽出した予想部と根拠部の例

2.3 表現類似計算手法

本節では、アナリストレポートの根拠の背景情報を新聞記事から獲得するために用いた、二つの文章の表現類似度を計算する手法について述べる。本研究では、表現類似度 s を以下の式のように話題性 t 、文の表層 w 、極性の一致度 p 、文脈の類似性 c の4つの構成要素として捉える。

$$s = t \cdot w \cdot p \cdot c \quad (1)$$

- 話題性:トピックモデル(LDA[5])による単語の分散表現を用いた文章の話題の類似度を算出
- 文の表層:Word2vec(Skip-gram[6][7])による単語の分散表現を用いた文章の表層的な類似度を算出
- 極性の一致度:金融極性辞書[8]を用いた単語の極性を計算し、文章間の極性がどれだけ一致するかを判定
- 文脈の類似性:アナリストレポートの根拠情報と新聞記事の結果表現の類似度を算出するだけではなく、新聞記事の原因表現との類似度も算出。より根拠情報の文意に沿った文章を抽出する。

LDAとWord2vecを用いて算出された二つのベクトル表現を用いることで、比較する二つの文書の話題性と表層的な類似度を算出する。ベクトル間類似度はコサイン類似度を用いた。 A, B はそれぞれ文章 \vec{A}, \vec{B} は、それぞれ文書 A, B 内にある名詞・動詞・形容詞の分散表現の相加平均を求めて算出した文書ベクトルである。

$$\text{cosine similarity} = \cos \theta = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \|\vec{B}\|} \quad (2)$$

表 1: 実験に用いた手がかり表現の概要

手がかり表現の数	手がかり表現の例
109	織り込んで, 見込んで, をきっかけに, 背景に, 考慮し, 踏まえ など

3. 実験

提案手法では, おおよそ同一文章内で因果関係表現が出現し, 予想とその根拠情報が獲得できるという仮説に基づいて, 酒井ら [4] の因果関係抽出手法を使用している. 本実験では, 対象としているアナリストレポートにおいて, 同一文章内で予想の根拠情報が獲得できた件数の割合を示し, 根拠情報抽出をする手法の妥当性を検証する. 実験には, 表 1 に示す手がかり表現を用いた.

実験データには, 2011 年から 2016 年までの間に発行された 7927 件のアナリストレポートのうち文章内で因果関係表現が抽出できた 7716 件を用いた. アナリストレポートから抽出した因果表現を含む文章の中から結果表現の部分に「目標株価」および「業績予想」に関する記述がある場合, その原因表現を予想の根拠情報として抽出している. なお, 因果関係を抽出するにあたって, 本実験では形態素解析器としては Mecab を用い, 係り受け解析器としては Cabocha[9] を用いた.

4. 実験結果と考察

評価方法に関しては, 文章内で因果関係抽出ができたレポートの件数に対する証券アナリストの予想の根拠情報の抽出ができたレポートの件数の割合を Precision(精度) とした. 目標株価に対する根拠情報, 業績予想に対する根拠情報, そしてどちらか一方に対する根拠情報が抽出できた割合の 3 項目を算出した.

実験結果を表 2 に示す. 検証した全項目で 5 割を下回る精度となり, 因果関係ができた抽出した文のうち, 結果表現にて目標株価と業績予想のいずれかに言及しているアナリストレポートの件数は, 4 割程度であった. 必ずしも予想に対して直接的な表現を使用している訳ではないことが分かる. この要因として次の 3 点が挙げられる.

1. 証券アナリストの予想に表記揺れがある (例: 野村予想を上方修正, 利益予想を引き上げる)
2. 明確な根拠表現を回避する
3. 文章横断的な根拠表現が抽出できない

このうち, 1 の予想情報の表記揺れについて検討する. 具体的には結果表現に含まれる記述として「目標株価」, 「業績予想」に加え, 「利益予想」, 「野村予想」, 「収益」, 「売上高」等, 計 13 個のフレーズがある場合, 予想の根拠情報として抽出を行なった. 目標株価および業績予想の根拠情報の抽出割合における表記揺れの考慮の結果を表 2 に示す.

表記揺れを考慮することによって 8 割程度まで精度を向上することができた. 予想情報の言及に関して, 証券アナリストは複数の言い回しをしており, その表記揺れを考慮に入れて根拠情報を抽出する必要があることが分かった. 本結果より, 今回実験を行なったアナリストレポートの 8 割程度が予想の根拠情報を同一文章内にて言及しており, 本手法における因果関係表現抽出手法の有用性が示すことができた.

表 2: 各予想に対する精度 (Precision)

	Precision
目標株価のみ	0.20
業績予想のみ	0.33
目標株価あるいは業績予想	0.44

表 3: 表記揺れを考慮に入れた結果 (Precision)

	Precision
表記揺れを考慮しない場合	0.44
表記揺れを考慮した場合	0.83

5. まとめ

本研究では, 新聞記事からの情報を活用し, 文章内に出現する因果関係表現と文章間の表現類似性に着目したアナリストレポートの自動要約手法を提案した. その提案手法実現のために, アナリストレポートから根拠情報を抽出する手法の妥当性について実験を行った. 表記揺れを考慮することによって, 8 割程度のアナリストレポートで同一文章内に証券アナリストの予想とその根拠情報が出現していることが分かり, 本論文において用いた因果関係抽出手法の有用性が示された. また, 実験結果を通じて証券アナリストのレポート内の書きぶりに関しても考察を行った. 今後の課題として, 要約文の評価データセットの作成, 2 節で紹介した表現類似度計算の精度向上に関する手法の考案, 因果関係抽出の精度向上に寄与する手がかり表現の語義曖昧性解消手法の考案などが考えられる.

参考文献

- [1] 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. 人工知能学会第 17 回金融情報学研究会, pp. 25–30, 2016.
- [2] Jahna Otterbacher, Güneş Erkan, and Dragomir R Radev. Using random walks for question-focused sentence retrieval. In *Proceedings of the conference on Human Language Technology and Empirical Methods in Natural Language Processing*, pp. 915–922. Association for Computational Linguistics, 2005.
- [3] Katja Filippova, Mihai Surdeanu, Massimiliano Ciaramita, and Hugo Zaragoza. Company-oriented extractive summarization of financial news. In *Proceedings of the 12th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 246–254. Association for Computational Linguistics, 2009.
- [4] Hiroyuki SAKAI and Shigeru MASUYAMA. Cause information extraction from financial articles concerning business performance. *IEICE Transactions on Information and Systems*, Vol. E91.D, No. 4, pp. 959–968, 2008.
- [5] David M Blei, Andrew Y Ng, and Michael I Jordan. Latent dirichlet allocation. *Journal of machine Learning research*, Vol. 3, No. Jan, pp. 993–1022, 2003.

- [6] Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013.
- [7] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems*, pp. 3111–3119, 2013.
- [8] 伊藤友貴, 坪内孝太, 山下達雄, 和泉潔. テキスト情報から生成された極性辞書を用いた市場動向分析. 人工知能学会全国大会論文集 2017 年度人工知能学会全国大会 (第 31 回) 論文集, pp. 2D21–2D21. 一般社団法人 人工知能学会, 2017.
- [9] 工藤拓, 松本裕治ほか. 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.

[1Q2-J-2] Machine learning: reinforcement learning and its advances

Chair:Koichiro Yoshino Reviewer:Kohei Miyaguchi

Tue. Jun 4, 2019 1:20 PM - 3:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[1Q2-J-2-01] Building a Human-Like Agent Based on a Hybrid of Reinforcement and Imitation Learning○Rousslan Fernand Julien Dossa¹, Xinyu Lian¹, Hirokazu Nomoto², Takashi Matsubara¹, Kuniaki Uehara¹ (1. Kobe University, 2. EQUOS RESEARCH Co., Ltd.)

1:20 PM - 1:40 PM

[1Q2-J-2-02] Human Sub-goal Transfer in Hierarchical Reinforcement Learning○Takato Okudo^{1,2}, Seiji Yamada^{2,1} (1. SOKENDAI, 2. National Institute of Informatics)

1:40 PM - 2:00 PM

[1Q2-J-2-03] Global optimization for supply chain process by deep reinforcement learning○Kazuhiro Koike¹ (1. ASKUL Corporation)

2:00 PM - 2:20 PM

[1Q2-J-2-04] Construction of Inverse Reinforcement Dynamics Learning Framework based on Maximum Entropy Principle○Yuki Nakaguchi¹, Riki Eto¹, Itaru Nishioka¹ (1. NEC Data Science Research Laboratories)

2:20 PM - 2:40 PM

[1Q2-J-2-05] On/off-policy Hybrid Deep Reinforcement Learning and Simulation in Control Tasks○Bonan Wang¹, Shin Kawai¹, Hajime Nobuhara¹ (1. University of Tsukuba)

2:40 PM - 3:00 PM

強化学習と模倣学習の融合による人間らしいエージェント

Building a Human-Like Agent Based on a Hybrid of Reinforcement and Imitation Learning

ドッサルスラン フェルナン ジュリアン*¹

Rousslan Fernand Julien Dossa

連 欣瑜*¹

Xinyu Lian

野本 洋一*²

Hirokazu Nomoto

松原 崇*¹

Takashi Matsubara

上原 邦昭*¹

Kuniaki Uehara

*¹神戸大学システム情報学研究科

Graduate School of System Informatics, Kobe University

*²株式会社エクオス・リサーチ

EQUOS RESEARCH Co., Ltd.

Reinforcement learning (RL) builds an effective agent that handles tasks in complex and uncertain environments by maximizing future reward. However, the efficiency is insufficient for practical use such as game AI and autonomous driving. An effective but selfish agent conflicts with other humans, and hence the demand of a human-like behavior arises. Imitation learning (IL) has been employed to train an agent to mimic the actions of expert behaviors provided as training data. However, IL tends to build an agent limited in performance by the expert skill, and even worse, the agent exhibits an inconsistent behavior since IL is not goal-oriented. In this paper, we propose a training scheme by mixing RL and IL for both discrete and continuous action space problems. The proposed scheme builds an agent that achieves a performance higher than an agent trained by only IL and exhibits a more human-like behavior than agents trained by RL or IL, validated by human sensitivity.

1. 序論

強化学習によるエージェントは、環境と対話しているうちに試行錯誤を重ねて学習し、様々な課題が解決できる。例えば、囲碁 [Silver 17] や自動運転 [Sallab 17, Shalev-Shwartz 16, Isele 18, Vikas 17], テレビゲーム [Mnih 15, Mnih 16] などがあげられる。しかしながら、強化学習エージェントは収益を最大化するように訓練されるため高い性能を示すが、実用化するには、このような性能指標以外のことも考慮する必要がある。例えば、テレビゲームにおける NPC を強化学習エージェントにすると、そのエージェントが強すぎるため、プレイヤーがゲームをあまり楽しむことができない可能性がある。また、自動運転に応用するには、高い性能を目指して訓練された強化学習エージェントは、激しく加減速したり急に曲がったりして、隣接する車や歩行者などに不安を与える恐れがある。そこで、人間らしいエージェントを設計する必要がある。一方で、模倣学習では、人間エキスパートに提供されるデータ上でエージェントにそのエキスパートの方策を学習させるため、人間らしい態度が期待できる。ただし、学習される方策は提供されたデータに制限され、模倣学習エージェントの性能はエキスパートの性能を越えることができない。

本論文では、強化学習の高い性能を保ったまま人間らしいエージェントを設計するため、強化学習と模倣学習の融合モデルを提案する。提案した融合モデルは強化学習の高い性能と人間のような振舞を示した。実験として、離散行動空間のケースとして Atari ゲームに適用した。さらに、自動運転のような実社会にも応用可能であることを実証するために、連続行動空間の Torcs [Wymann 15] という運転シミュレータで実験を行った。評価のため、性能評価と感性試験を行い、提案モデルが人間の模倣エージェントより高い性能を示し、強化学習エージェントより人間らしく振る舞うことを実証した。

2. 関連研究

2.1 強化学習と Deep Q-Networks

強化学習 (RL) をマルコフ決定過程 (MDP) の枠組みを通じて定義する。マルコフ決定過程は 5 つの要素 $\langle S, \mathcal{A}, P_a, R_a, \gamma \rangle$ からなっている。ここで S は状態空間であり、 \mathcal{A} は取りうる行動の空間である。また、 $P_a(s, s') = P_r(s_{t+1} = s' | s_t = s, a_t = a)$ はあるタイムステップ t に状態 s で行動 a を取った時、状態 s' に遷移する確率であり、 $R_a(s, s')$ は状態 s で行動 a を取って状態 s' に遷移すると与えられる報酬である。さらに、 γ ($0 < \gamma \leq 1$) は割引率と呼ばれ、短期報酬もしくは長期報酬のどちらを優先するかを γ で決定する。学習時、毎タイムステップ t , 強化学習エージェントは S から状態 s を観測し、それを考慮して行動 a を取る。その結果、エージェントは環境から行動に相当する状態 s_{t+1} と報酬 r_t が与えられる。

離散行動空間の場合、Deep Q-Networks (DQN) [Mnih 15] は、様々な課題に適用され、人間より高い性能を示すことで、有効なツールであることを実証された。あるタイムステップ t , 任意の状態 s からもらえる収益 $R_t = \sum_{t'=t}^T \gamma^{t'-t} r_{t'}$ を予測するように訓練される (T は最後のタイムステップである)。そこで、エージェントは R_t を最大化する行動 a を取る。最適な状態行動価値関数 $Q^*(s_t, a_t) = \max_{\pi} \mathbb{E}[R_t | s = s_t, a = a_t, \pi]$ はベルマン方程式より以下のように求められる。

$$Q^*(s_t, a_t) = \mathbb{E}_{s_{t+1} \sim \mathcal{E}} [r_t + \gamma \max_{a_t} Q^*(s_{t+1}, a_{t+1}) | s_t, a_t]$$

学習時、エージェントは収益 R_t を状態行動価値関数 $Q(\phi(s), a)$ で近似するように繰り返し更新していく。最終的に $i \rightarrow \infty$ の時、 Q_i は最適な Q^* に収束する [Sutton 98]。

2.2 Deep Deterministic Policy Gradient

行動空間を連続空間 $\mathcal{A} \subset \mathbb{R}^N$ とし (N は行動の次元), 目標を初期分布 $J = \mathbb{E}_{r_i, s_i \sim \mathcal{E}, a_i \sim \pi} [R_1]$ の期待収益の最大化とする。DQN は高次元の状態空間上で良い性能を得られるが、低次元の行動空間に限られる。Deep Deterministic Policy Gradient (DDPG) [Lillicrap 15] は Deterministic Policy Gradient (DPG) [Silver 14] に基づく手法である。DDPG では、強化学習エージェントの方策を θ^μ でパラメータ化される actor 関

数 $\mu(s|\theta^\mu)$ とする. この関数は任意の状態 s_t から行動 a_t に写像する関数である. また, $\text{critic}Q(s_t, a_t)$ を状態と行動のペア (s_t, a_t) を近似する関数と定義する. また, actor の更新を David Silver ら [Silver 14]. に提案された通り, 方策勾配により行われる.

ただし, 非線形推測の critic 関数 $Q(s, a|\theta^Q)$ を導入したため, 更新が発散する可能性がある. 対処法として, DDPG にソフトターゲットによる更新を導入する. 元々の actor と critic それぞれのパラメータ $\mu(s|\theta^\mu)$ と $Q(s, a|\theta^Q)$ を $\mu'(s|\theta^{\mu'})$ と $Q'(s, a|\theta^{Q'})$ に複製し, ターゲットネットワークと呼ぶ. そのターゲットネットワークを学習と共に $\theta' \leftarrow \tau\theta + (1-\tau)\theta'$, $\tau \ll 1$ により徐々に更新していくので, 学習が安定化する.

さらに, 行動空間が高次元であるため, 探索空間が膨大になるので, それを促進するように探索方策 $\mu'(s_t) = \mu(s_t|\theta_t^{\mu'}) + \mathcal{N}$ を用いる [Plappert 17]. その方策には扱う課題によって異なるノイズ関数からサンプリングされるノイズを追加する.

2.3 模倣学習

模倣学習においては, エキスパートプレイヤーが従っている方策を最適な方策 π^* であると仮定し, エージェントの方策 π が π^* に近づくように学習が行われる. 人間エキスパートに最適な方策 π^* により (状態, 行動) ペアの系列という形で提供された上で, エージェントの方策を観測される状態からエキスパートに取れそうな行動を推測するように訓練されるので, 人間エキスパートを模倣することが可能となる.

2.4 Generative Adversarial Imitation Learning

Generative Adversarial Imitation Learning (GAIL) [Ho 16] は逆強化学習と古典的な強化学習に基づく手法である. まず, 逆強化学習でエキスパート方策 π_E に少ないコストを与え, 他の異なる方策 π に高いコストを与えるコスト関数 c を学習する. Π は \mathcal{S} から \mathcal{A} に写像する方策 π の集合とし, $H(\pi) \triangleq \mathbb{E}_\pi[-\log\pi(a|s)]$ を方策 π の γ で割り引かれた causal entropy [Ho 16] とする. さらに, 強化学習の手法を用い, 逆強化学習で求められたコスト関数 c を最小化する方策を導く.

この二段階手法の計算コストが膨大であるため, 逆強化学習を用いないように J. Ho らはある方策 π の occupancy measure ρ_π を導入した [Ho 16]. ρ_π は, エージェントが方策 π に従って探索を行う際に通る (状態, 行動) ペアの密度分布である. また, 識別器 $D_w: \mathcal{S} \times \mathcal{A} \rightarrow (0, 1)$ を用い, エージェントとエキスパートそれぞれの方策に相当する ρ_π と ρ_{π_E} を見分ける. そのために, エージェントとエキスパートに生成される軌道による期待値の和を最小化する

$$\mathbb{E}_\pi[\log(D_w(s, a))] + \mathbb{E}_{\pi_E}[\log(1 - D_w(s, a))] - \lambda H(\pi), \lambda \geq 0$$

識別器 D_w がエージェントの方策とエキスパートの方策を見分けられなくなると, 後者は前者に模倣されたと言える. GAIL の手続き全体はアルゴリズム 1 ようになる.

2.5 知識の蒸留

蒸留とは教師モデルの基で生徒モデルを訓練する手法である. 教師あり学習に用いられるハードターゲット (one-hot label) の代わりに, 教師モデルに出力させるソフトターゲット [Hinton 15] を使用する. ハードターゲットと比べて, ソフトターゲットの各要素が学習に役に立つ情報を含んでいる. 例えば, 猫の画像を入力すると, “猫である” 確率が一番高く, “犬である” 確率は “人参である” 確率より高いと期待される. なぜならば, 犬は人参よりは猫に似ていると考えられるからであ

Algorithm 1 Generative Adversarial Imitation Learning

- 1: **Input:** Expert trajectories $\tau_E \sim \pi_E$, initial policy and Discriminator parameters θ_0, w_0
- 2: **for** $i = 0, 1, 2, \dots$ **do**
- 3: Sample trajectories $\tau_i \sim \pi_{\theta_i}$
- 4: Update Discriminator parameters from w_i to w_{i+1} with the gradient
- 5: $\hat{\mathbb{E}}_{\tau_i}[\nabla_w \log(D_w(s, a))] + \hat{\mathbb{E}}_{\tau_E}[\nabla_w \log(1 - D_w(s, a))]$
- 6: Take a policy step from θ_i to θ_{i+1} , using the TRPO rule with cost function $\log(D_{w_{i+1}}(s, a))$.
- 7: Specifically, take a KL-constrained natural gradient step with
- 8: $\hat{\mathbb{E}}_{\tau_i}[\nabla_\theta \log \pi_\theta(a|s) Q(s, a)] - \lambda \nabla_\theta H(\pi_\theta)$,
- 9: where $Q(\bar{s}, \bar{a}) = \hat{\mathbb{E}}_{\tau_i}[\log(D_{w_{i+1}}(s, a)) | s_0 = \bar{s}, a_0 = \bar{a}]$
- 10: **end for**

る. データが少量であっても良い性能が出せるだけではなく, 大きなモデルを圧縮する際にも有効な手法である. 蒸留が強化学習に拡張され [Rusu 15], 教師モデルから方策を導出し, より良い性能を示すということが実証されている. さらに, 異なる課題に対して学習された複数のエキスパートの基で蒸留を行い, マルチタスク課題にも適用可能であることが示された.

3. 提案手法

強化学習モデルの高い性能を保ったまま人間らしいエージェントを学習するというタスクは, (1) 人間の性能に近いエージェントを学習するサブタスクと (2) 人間のように行動を選択するエージェントを学習するサブタスクの 2 つに分割することができる. 各サブタスクはそれぞれの強化学習と模倣学習の課題として取り組みられており, 本論文で提案する手法はマルチタスク課題である. そこで, 提案する強化学習と模倣学習の融合化手法は, 離散行動空間の場合方策の蒸留に基づき, 連続行動空間の場合は敵対模倣学習に基づく方法である.

また, π^* を強化学習モデルによる最適な方策, π_{HE} を人間エキスパートの方策とする. この 2 つの方策の比率を決めるパラメータを $\alpha \in (0, 1)$ とし, 提案する目的関数は以下になる

$$\mathcal{L}_{mix}(\pi) = \alpha \mathcal{L}_{\pi_{RL}}(\pi) + (1 - \alpha) \mathcal{L}_{\pi_{HE}}(\pi)$$

離散行動空間の場合, 模倣学習の目的関数を, 模倣学習の既存研究 [Hinton 15, Rusu 15] に従って以下の交差エントロピー損失として定義する.

$$\mathcal{L}_{\pi^*}(\pi) = \mathbb{E}_s \left[- \sum_a \pi^*(a|s) \log \pi(a|s) \right]$$

人間エキスパートの方策 π_{HE} は数理モデルとして定義するのが難しく, 実験的にサンプリングされたデータの上で学習を行う. π_{HE} からソフトターゲットが得られないにも関わらず, 方策の蒸留にはハードターゲットとソフトターゲットの重付き平均を計算することでより良い性能が得られる [Rusu 15]. 従って, 人間エキスパートに提供されるデータをハードターゲットとし, 学習済み DQN モデル [Mnih 15] の方策 $\pi_{RL}^{(T)}$ の出力を熱度 T で調整したものをソフトターゲットとする. 最終的に, 損失関数は以下ようになる.

$$\begin{aligned} \mathcal{L}_{mix}(\pi) = & \alpha \mathbb{E}_{\pi_{RL}} \left[- \sum_a \pi_{RL}^{(T)}(a|s) \log \pi(a|s) \right] \\ & + (1 - \alpha) \mathbb{E}_{\pi_{HE}} \left[- \sum_a \pi_{HE}(a|s) \log \pi(a|s) \right] \end{aligned}$$

連続行動空間の場合、模倣学習法として 2.4 節で紹介された GAIL を用いる。GAIL 法は教師モデル π からサンプリングされた軌道 $\tau \sim \pi$ を必要とする。GAIL における識別器 D_w に最大化される目的関数と生徒モデルに最小化される目的関数は

$$\mathcal{L}_{\pi^*}(\pi) = \mathbb{E}_{\tau \sim \pi}[\log(D_w(s, a))] + \mathbb{E}_{\tau^* \sim \pi^*}[\log(1 - D_w(s, a))]$$

となる。ここで τ は生徒モデルからサンプリングされた軌道 $\tau \sim \pi$ である。

融合化するには、教師モデルを人間エキスパートと強化学習モデルにするので、それぞれのエキスパートから軌道 $\tau_{HE} \sim \pi_{HE}$ と $\tau_{RL} \sim \pi_{RL}$ をサンプリングする。さらに、融合の損失関数を

$$\begin{aligned} \mathcal{L}_{mix}(\pi) = & \mathbb{E}_{\tau \sim \pi}[\log(D_w(s, a))] \\ & + \alpha \mathbb{E}_{\tau_{RL} \sim \pi_{RL}}[\log(1 - D_w(s, a))] \\ & + (1 - \alpha) \mathbb{E}_{\tau_{HE} \sim \pi_{HE}}[\log(1 - D_w(s, a))] \end{aligned} \quad (1)$$

に置き換えることができる。直感的には、識別器 D_w は人間エキスパートと強化学習モデルの方策間の融合方策を認めるように学習され、この識別器を騙せるように訓練される生徒モデル π が融合方策に近づき、両方のエキスパートの長所を模倣すると期待される。

4. 実験

4.1 Atari 2600 Game: Gopher

提案手法をまず離散行動空間の Gopher という Atari 2600 システムのゲームに適用した。このゲームの目標は、農夫として地下から地上に出てくるねずみ (Gopher) が人參が取れないように、左右に動いたり穴を埋めたりすることである。人間エキスパートと訓練済みの DQN モデルがそれぞれ 55,000 のフレームを提供した上、訓練セットを 50,000、テストセットを 5,000 として学習を行った。特に、生徒モデルを訓練するために学習率 10^{-4} の Adam optimizer [Kingma 14] と Dropout 率 0.5 を利用した。蒸留の熱度を $T = 0.1$ 、トレードオフ係数を $\alpha = 0.93$ として実験を行った。

4.2 Torcs

Torcs [Wymann 15] は自動運転の研究で最もよく利用されるシミュレータの一つである [Lau 16] [You]。実験は、Gym Torcs 環境 [Yoshida 16] をベースにした。エージェントの観測空間は車から端までの距離、敵の車までの距離、現在の速度や加速度など、全体で 65 の連続値からなっている。行動空間は二つの要素「左右」と「加減速」からなっており、取りうる値は $[-1.0, 1.0]$ の範囲に限られる。報酬関数は走った距離にし、強化学習モデルを OpenAI Baselines [Dhariwal 17] の DDPG を基に訓練した。さらに、人間らしさが見分けられる状況が現れるように、Torcs シミュレータに停車ボットをした上、人間エキスパートに 60 秒の 220 エピソードをプレイさせ、そのデータを収集した。単なる模倣学習エージェントを、人間エキスパートのデータ上で、強化学習モデルの訓練と同じく、OpenAI [Dhariwal 17] の GAIL を用いて訓練を行った。最後に、GAIL の識別器更新を Eq. 1 で提案された通り実施し、両方のエキスパートの影響を等しくするためにトレードオフ係数 $\alpha = 0.5$ にして提案した融合モデルの学習を行った。

4.3 人間らしさの感性試験

各モデルの評価以外は、モデルの人間らしさを評価するためにダブル・ブラインドで感性試験を実施した。その試験は男性 23 人、女性 3 人の計 26 人の審査員を対象にした。年齢は 27 から 59 歳、平均年齢は 44 歳であり、株式会社エクス・リサーチの従業員である。全員、本調査以前に本研究の内容と資料には接触がなかった。初めに、審査員に各ゲームのルールを説明し、人間に期待できる振る舞いを理解して頂けるように各ゲームの体験会を実施した。調査の内容は、各審査員、ゲーム毎に 2 本の動画 (Gopher の場合 15 秒、Torcs の場合 30 秒) を提供し、人間か AI かの判断とその理由を依頼した。

5. 結果と考察

5.1 Atari 2600 Game: Gopher

性能に関して、点数の高い順にまず、強化学習モデル (DQN)、次に提案した融合モデル、最後に人間エキスパートとその模倣となった。融合モデルは、強化学習モデルに提供されたターゲットを $\alpha = 0.8$ で優先したにも関わらず、スコアの向上が 3 点しかなく、単体の強化学習モデルの点数との差が大きい。感性試験に関して、強化学習モデルはやはりあまり人間らしくないと判断されたが、提案した融合モデルは点数だけではなく人間らしさでも人間とその模倣より高いスコアを示した。そこで、融合モデルは強化学習の目標に向かった学習傾向と人間エキスパートの振る舞いを学習できた。意外にも、融合モデルは人間エキスパートより人間らしいと判断された。その理由を解明するために、審査員のコメント分析によってよく現れた感想は、“無駄な動きが少ない”、“動きが細かい、プログラム感が動きにある”また、“穴を順番に埋めようとする”であった。従って、人間のエキスパートは、特にゲームをあまりしない審査員に高い性能が期待されていなかったと考えられる。詳細は Table 1 に記載する。

5.2 Torcs

性能の評価に関して、まず、それぞれの人間エキスパート、GAIL による人間の模倣、強化学習の DDPG と融合モデルの点数を比較した。詳細は Table 2 に記載する。実験より、GAIL は訓練済みの強化学習モデルや決定論的なボットの模倣に優れているが、人間エキスパートの模倣の効率は意外に低いことが観測された。それは、人間エキスパートの方策は複雑で、基本的なニューラルネットワークでの扱いが困難だと推定される。

一方で、提案した融合モデルは例えば、強化学習モデルの高速度や人間エキスパートの曲がり方という特徴の模倣に成功した。さらに、人間エキスパートと強化学習モデルのように全体のトラックを走れるようになった。

人間であると判断された割合が低い順に、まず、強化学習モデル (DDPG) は“走るのが速すぎる”や“高速で角を曲がる”という理由で、あまり人間らしくないと判断された。意外に、人間エキスパートは人間らしくないと判断された。同じ動画に対して、審査員のコメントが多様であるが、より低い性能を示した人間の模倣エージェントが人間エキスパートより人間らしいと判断されたため、Gopher と同じく、人間エキスパートに示された性能は高いといえる。最後に、融合モデルは最も人間らしいと判断された上、強化学習モデルに近い性能を示した。

6. 結論

本論文では強化学習モデルに示される高性能をある程度保ったまま、人間エキスパートのように人間らしく動く融合モデル

Table 1: *Gopher* の結果

エージェント	点数		調査
	平均	偏差	判断率 (%)
人間	23.87	19.81	<u>55.70</u>
強化学習 (DQN)	40.30	36.81	32.69
模倣学習	23.91	23.79	59.62
提案手法 (RL+IL)	<u>26.05</u>	24.31	59.62

1位と2位をそれぞれ太字と下線で示す

Table 2: *Torcs* の結果

エージェント	点数 ($\times 10^3$)		調査
	平均	偏差	判断率 (%)
人間	40.17	3.63	50.00
強化学習 (DDPG)	40.45	0.43	30.77
模倣学習	23.99	1.16	<u>51.92</u>
提案手法 (RL+IL)	<u>36.63</u>	1.32	61.54

1位と2位をそれぞれ太字と下線で示す

を提案した。強化学習と模倣学習の最先端手法に基づいたモデル設計し、離散行動空間のタスクである Atari 2600 ゲームと連続行動空間のタスクである Torcs シミュレータに適用した。性能を評価した上、感性試験で提案モデルの人間らしさを評価した。提案モデルは、強化学習モデルによる性能向上と人間エキスパートの振る舞いの模倣に成功した。

7. 謝辞

本研究は、JST、未来社会創造事業、JPMJMI18B4の支援を受けたものである。感性試験にご協力を頂きました株式会社エクス・リサーチに深く感謝致します。本論文の校正を行ってくれた河村和紀さんに感謝致します。

参考文献

- [Dhariwal 17] Dhariwal, P. e. a.: OpenAI Baselines (2017)
- [Hinton 15] Hinton, G., Vinyals, O., and Dean, J.: Distilling the knowledge in a neural network, *arXiv preprint arXiv:1503.02531* (2015)
- [Ho 16] Ho, J. and Ermon, S.: Generative Adversarial Imitation Learning, *CoRR*, Vol. abs/1606.03476, (2016)
- [Isele 18] Isele, D. e. a.: Navigating occluded intersections with autonomous vehicles using deep reinforcement learning, in *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2034–2039 IEEE (2018)
- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR* (2014)
- [Lau 16] Lau, B.: Using Keras and Deep Deterministic Policy Gradient to play TORCS (2016)
- [Lillicrap 15] Lillicrap, T. P. e. a.: Continuous control with deep reinforcement learning, *CoRR*, Vol. abs/1509.02971, (2015)
- [Mnih 15] Mnih, V. e. a.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, No. 7540, p. 529 (2015)
- [Mnih 16] Mnih, V. e. a.: Asynchronous methods for deep reinforcement learning, in *International conference on machine learning*, pp. 1928–1937 (2016)
- [Ortega 13] Ortega, J. e. a.: Imitating human playing styles in super mario bros, *Entertainment Computing*, Vol. 4, No. 2, pp. 93–104 (2013)
- [Plappert 17] Plappert, M. e. a.: Parameter Space Noise for Exploration, *CoRR*, Vol. abs/1706.01905, (2017)
- [Ross 11] Ross, S., Gordon, G., and Bagnell, D.: A reduction of imitation learning and structured prediction to no-regret online learning, in *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, pp. 627–635 (2011)
- [Rusu 15] Rusu, A. A. e. a.: Policy Distillation, *CoRR*, Vol. abs/1511.06295, (2015)
- [Sallab 17] Sallab, A. E. e. a.: Deep reinforcement learning framework for autonomous driving, *Electronic Imaging*, Vol. 2017, No. 19, pp. 70–76 (2017)
- [Shalev-Shwartz 16] Shalev-Shwartz, S., Shammah, S., and Shashua, A.: Safe, multi-agent, reinforcement learning for autonomous driving, *arXiv preprint arXiv:1610.03295* (2016)
- [Silver 14] Silver, D. e. a.: Deterministic Policy Gradient Algorithms, in *Proceedings of the 31st International Conference on International Conference on Machine Learning - Volume 32, ICML'14*, pp. I-387–I-395, JMLR.org (2014)
- [Silver 17] Silver, D. e. a.: Mastering the game of Go without human knowledge, *Nature*, Vol. 550, No. 7676, p. 354 (2017)
- [Srivastava 14] Srivastava, N. e. a.: Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research* (2014)
- [Sutton 98] Sutton, R. S. and Barto, A. G. e. a.: *Reinforcement learning: An introduction*, MIT press (1998)
- [Vikas 17] Vikas, B.: Deep Reinforcement Learning approach to Autonomous Navigation (2017)
- [Wymann 15] Wymann, B. e. a.: TORCS: The open racing car simulator (2015)
- [Yoshida 16] Yoshida, N. Y.: Gym TORCS (2016)
- [You] You, Y.: TORCS for Reinforcement Learning

階層型強化学習における人間のサブゴール知識転移

Human Sub-goal Transfer in Hierarchical Reinforcement Learning

奥戸 嵩登 *1*2

Takato Okudo

山田 誠二 *2*1

Seiji Yamada

*1総合研究大学院大学
SOKENDAI*2国立情報学研究所
National Institute of Informatics

Hierarchical reinforcement learning, especially which learn policy with option discovery simultaneously, needs a lot of iterations. This paper investigates how human sub-goal transfer affect to learning speed and performance. we proposes the way to transfer human sub-goals in hierarchical reinforcement learning. To acquire human sub-goal knowledge, we use the problem in interactive machine learning. Supervised learning transforms human sub-goals into initial parameters before learning on hierarchical reinforcement learning. Two experiments, participant experiment and evaluation experiment, are conducted. The participant experiment is to acquire sub-goals of participants. The human sub-goal transfer is evaluated on learning speed and performance after learning in evaluation experiment. The future work is to conduct two experiments and analyze the results.

1. はじめに

近年、深層学習の発達に伴い強化学習の応用範囲も広がり、様々な分野で強化学習が用いられるようになった。特にゲームやシミュレーター環境といったバーチャル環境での利用例が多くなってきている。バーチャル環境で強化学習が用いられる背景として、強化学習は学習初期に危険を顧みない挙動をしたり、膨大な試行錯誤が必要となるというような性質を持つことが挙げられる。また、強化学習は学習したタスクの性質が少しでも変化すると一から学習をし直さなければならないという汎化性能の低さという問題も抱えている。

そこで、状態や方策を階層化する階層型強化学習が提案された。階層型強化学習では、プリミティブな行動をまとめて、マクロ行動の獲得やメタレベルの行動選択により状態空間の探索の効率化が図れる。階層型強化学習ではマクロ行動を自動で得ることが難しく、良いマクロ行動とは何か、自動で獲得するための方法論が研究されていた。Option-Critic アーキテクチャはマクロな行動の数をあらかじめ指定するだけでマクロな行動を自動的に獲得する手法である。しかしながら、マクロ行動の獲得と選択方法、プリミティブな行動選択を同時学習するため学習に要する試行回数が膨大に必要である。そこで、本研究では人のサブゴール知識を転移することで Option-Critic アーキテクチャの試行回数を減らせることができるかを検証する。

また、人のサブゴール知識取得の方法をインタラクティブ機械学習の枠組みの中で提案する。インタラクティブ機械学習は計算機に関する知識がない人でも学習アルゴリズムにドメインの知識を転移することができる枠組みである。学習エージェントの学習プロセス中に人がサブゴールと考える状態でフィードバックを与えてもらうことでサブゴール知識を抽出する。サブゴール知識を Option-Critic アーキテクチャに適した形に変換し、学習前の初期値として用いる方法を提案する。

2. 関連研究

本節では、本研究に関連する研究としてインタラクティブ機械学習とインタラクティブシェイピング問題、強化学習にお

連絡先: 奥戸 嵩登, 総合研究大学院大学, 神奈川県三浦郡葉山町湘南国際村, okudo@nii.ac.jp

る人の知識転移について説明する。

2.1 インタラクティブ機械学習

インタラクティブ機械学習とは、機械学習の学習プロセスに人が介入することができるような枠組みのことである。インタラクティブ機械学習はドメイン知識を有した人が機械学習の専門家を介さずに直接、機械学習アルゴリズムに知識を転移できるようにすることを目的としている [Amershi 14]。これまで、人がインタラクティブに学習プロセスに介入することを考慮したアルゴリズム [Settles 09] や、人が機械学習アルゴリズムとインタラクションしやすいインターフェース [山田 14] が研究されてきた。次節では、強化学習をインタラクティブ機械学習の枠組みに拡張したインタラクティブシェイピング問題について説明する。

2.2 インタラクティブシェイピング問題

インタラクティブシェイピング問題は、逐次意思決定問題において人から生成された一定の正負の報酬を用いて、そのタスクにおける最適方策を学習する問題である。人は訓練者としてエージェントと環境のインタラクションを観察し、任意のタイミングでエージェントの意思決定に対して評価を与えることができる [Knox 12]。代表的な手法として TAMER や TAMER + RL がある [Knox 12]。インタラクティブシェイピング問題において人のサブゴール知識を転移することを本研究は目指している。

2.3 強化学習における人の知識転移

強化学習における人の知識転移は学習エージェントに行動選択や価値関数にバイアスを与えることで学習速度を向上させることが示されている [Taylor 18]。人の知識転移の方法としては大きく3種類挙げられる。第一にデモンストレーションを与える方法である。代表的な手法としてはエキスパートの軌跡から報酬関数を生成する逆強化学習 [Ng 00] やエキスパートの方策をエージェントの行動決定に確率的に組み込んだ Human-agent Transfer [Taylor 11] がある。第二にオンラインで評価を与える方法である。先述した TAMER や、正負の評価だけでなく、評価しないこともフィードバックに含めた SABL [Loftin 16] が挙げられる。第三に学習エージェントが学習するタスクのカリキュラムを与える方法である。主に、タ

表 1: オプションの構成要素

記号	名称	説明
I	開始集合	オプションを開始できる状態集合
π	方策	行動決定を行う方策
β	終了条件	ある状態でのオプションの終了確率

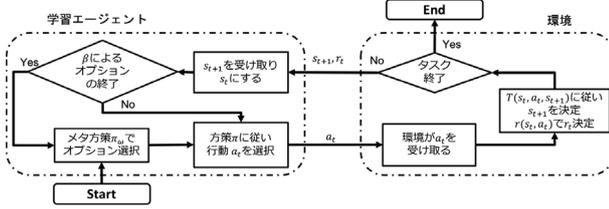


図 1: call-and-return 実行構成

スクのドメイン知識が豊富な設計者がカリキュラムの設計を行う [Taylor 18]. 本研究はオンラインで評価を与えることでカリキュラムに関する知識も転移することを目指している.

3. 人のサブゴール知識の転移

本節では人のサブゴール知識を Option-Critic アーキテクチャに転移する手法を提案する. 人のサブゴール知識の転移は2つのステップを踏む. 第一に人のサブゴール知識を取得すること, 第二にサブゴール知識の終了条件への変換である. その後, 転移された終了条件を初期値として Option-Critic アーキテクチャで学習を行う. はじめに Option-Critic アーキテクチャについて説明を記述し, 次にサブゴール知識の取得について記述する. 最後にサブゴール知識の終了条件への変換について提案する.

3.1 Option-Critic アーキテクチャ

Option-Critic アーキテクチャはタスクのサブゴールへの分割と方策の学習, メタ方策の学習を一括して学習する手法である. オプション集合とそれらの中から1つの方策を選ぶメタな方策という構造を持つオプションフレームワークを踏襲している. 1つのオプションは $\langle I, \pi, \beta \rangle$ のように定式化される. [Sutton 99] にオプションの構成要素についてまとめた表を表1に示す.

Option-Critic アーキテクチャでは実行に call-and-return を採用している. 実行の流れを図1に示す.

図1より, 始めに学習エージェントはメタ方策 π_ω でオプションを選択する. 選択したオプションが持つ方策 π で行動 a_t を選択する. 環境は行動 a_t を受け取り状態 s_t から状態 s_{t+1} へ遷移させ, 報酬 r_t を決定する. 報酬 r_t と遷移した状態 s_{t+1} を学習エージェントは受け取り, 終了条件 β で現在のオプションを終了するかどうかを決定する. 終了する場合は, メタ方策 π_ω で次のオプションを選択する. 終了しない場合は現在のオプションを継続する. 上記の流れを繰り返す.

Option-Critic アーキテクチャの学習則について説明する. Option-Critic アーキテクチャはメタ方策 π_ω , 方策 π と終了条件 β を試行錯誤によって学習する. メタ方策は価値反復により方策を更新し, 方策と終了条件は方策勾配に基づいて方策を更新する. メタ方策の学習則には intra-option Q ラーニング [Sutton 98] を用いる. Option-Critic アーキテクチャは初期状態 s_0 , 初期オプション ω_0 で始めた時の全軌跡の元で期

待割引収益

$$\rho(\Omega, \theta, \vartheta, s_0, \omega_0) = \mathbb{E}_{\Omega, \theta, \omega} \left[\sum_{t=0}^{\infty} \gamma^t r_{t+1} | s_0, \omega_0 \right]$$

の最大化を図るアルゴリズムである [Bacon 17]. ここで, θ, ϑ はそれぞれ方策のパラメータ, 終了条件のパラメータである. Ω はオプション集合である. 方程式の操作により, 下記のように表すことができる.

$$Q_\Omega(s, \omega) = \sum_{a \in A} \pi_\theta(s, \omega) \left[r(s, a) + \sum_{s'} p_{ss'}^a U(s', \omega) \right] \quad (1)$$

$$U(s, \omega) = (1 - \beta_\vartheta(s)) Q_\Omega(s, \omega) + \beta_\vartheta(s) \max_{\omega' \in \Omega} Q_\Omega(s, \omega') \quad (2)$$

ここで $r(s, a) = \mathbb{E} \{ r_{t+1} | s_t = s, a_t = a \}$, $p_{ss'}^a = Pr \{ s_{t+1} = s' | s_t = s, a_t = a \}$ を表している. メタ方策の更新則は

$$Q_\Omega(s_t, \omega) \leftarrow Q_\Omega(s_t, \omega) + \alpha [(r_{t+1} + \gamma U(s_{t+1}, \omega)) - Q_\Omega(s_t, \omega)]$$

となる. 次に, 目的関数を $Q_\Omega(s, \omega)$ とし, 方策のパラメータ θ , 終了条件のパラメータ ϑ でそれぞれ勾配を算出し, その勾配を用いてパラメータを更新する. 方策パラメータの更新則は

$$\theta \leftarrow \theta + \sum_{s, \omega} \mu_\Omega(s, \omega | s_0, \omega_0) \sum_{a \in A} \frac{\partial \pi_\theta(a|s)}{\partial \theta} Q_U(s, \omega, a) \quad (3)$$

$$\mu_\Omega(s, \omega | s_0, \omega_0) = \sum_{t=0}^{\infty} \gamma^t P(s_t = s, \omega_t = \omega | s_0, \omega_0) \quad (4)$$

となる. $\mu_\Omega(s, \omega | s_0, \omega_0)$ は (s_0, ω_0) から始まる軌跡に沿って割引かれる重み付けである. 終了条件の更新則は

$$\vartheta \leftarrow \vartheta - \sum_{\omega, s'} \mu_\Omega(s', \omega | s_1, \omega_0) \frac{\partial \beta_{\omega, \vartheta}(s')}{\partial \vartheta} A_\Omega(s', \omega) \quad (5)$$

$$A_\Omega(s', \omega) = Q_\Omega(s', \omega) - V_\Omega(s') \quad (6)$$

となる. Option-Critic アーキテクチャでは開始集合を, 終了状態を除いたタスクの状態集合と同じとして扱っている. 終了条件 β はメタ方策の切り替えタイミングを提供するので, サブゴールを定義していると解釈できる.

3.2 サブゴール知識の取得

サブゴール知識の取得には, 人が訓練者としてエージェントと環境のインタラクションを観察し, 任意のタイミングで学習エージェントの意思決定に対してフィードバックを与えることができる枠組みを利用する. 人は学習エージェントの学習中の任意のタイミングでサブゴールを指定することができる. 人が指定したタイミングで学習エージェントが訪問している状態 s_t をサブゴール状態 s_g として記録する. 記録されたサブゴール状態の集合を S_g で表す.

3.3 サブゴール知識の終了条件への変換

サブゴール状態 s_g における終了確率が1に近づくように終了条件の関数のパラメータを更新することでサブゴール知識を転移する. 人が設定したサブゴール状態 s_g でオプションの切替えを起こすためにサブゴール状態 s_g における全オプションの終了確率を1に漸近させる. 確率1を教師データとして誤差関数

$$L(s) = \frac{1}{2} (1 - \beta_\vartheta(s))^2$$

を最小化するように勾配法を用いて $\beta_{\vartheta}(s)$ のパラメータ ϑ を更新する. 全てのオプションの終了条件 $\beta_{\vartheta}(s)$ に対して同様の処理を行う. 更新されたパラメータを初期値として Option-Critic アーキテクチャの学習を開始する. サブゴール知識の取得とサブゴール知識の終了条件への変換の擬似コードを Algorithm1 に示す.

Algorithm 1 Human sub-goal transfer

Ensure: $\beta_{\vartheta,*}(s)$

repeat

$s \leftarrow s_0$

Choose ω according to π_{ω}

repeat

Choose a according to π in ω

Take a in s , observe s', r

Receive s_g from human trainer

$S_g \leftarrow S_g \cup s_g$

Update $Q_{\omega}, \pi_{\theta}, \beta_{\vartheta}$

if $\beta_{\omega,\vartheta}$ terminates in s' **then**

Choose ω according to π_{ω}

end if

$s \leftarrow s'$

until termination

until predefined number of iterations

while $\omega \in \Omega$ **do**

while $s_g \in S_g$ **do**

$\vartheta \leftarrow \vartheta - \alpha_g (1 - \beta_{\omega,\vartheta}(s_g)) \frac{\partial \beta_{\omega,\vartheta}(s_g)}{\partial \vartheta}$

end while

end while

4. 実験

本実験の目的は人のサブゴール知識の転移が Option-Critic アーキテクチャの学習スピードと学習後の性能を向上させるかどうかを検証すること. 本実験は2つのフェーズに別れる. 始めに参加者実験を行ないサブゴール知識の抽出を行う. 次にサブゴール知識を転移し, 学習アルゴリズムの性能の評価実験を行う.

4.1 参加者実験

参加者実験では, タスクにおける参加者のサブゴール知識抽出が目的である. タスクは2種類, Fourroom タスクと Pinball Domain タスクを用いる. タスク選定の基準としては, 状態空間の表現 (離散/連続) の違いである. 参加者は始めにタスク理解のために, タスクの説明を読み, 制限時間 (5分) の中でタスクをプレイする. 次に, 学習エージェントの学習中のプレイを観察し, 任意のタイミングでそのプレイに対して正負の評価を与える. 実験後, アンケートを実施する.

評価の与え方のインストラクションでは, 学習エージェントが目標達成のために良い行動をしたと思う時に正の評価を悪い行動をしたと思う時に負の評価を与えるように伝える. 学習エージェントには Option-Critic アーキテクチャを採用する. 学習エージェントはプレイを参加者へ表示している間も学習を続ける. 参加者に表示されているプレイが終了した時の最新のプレイを次のプレイを参加者へ表示する.

4.2 評価実験

評価実験では, 3つの手法を比較することで学習スピードと学習後の性能を比較することが目的である. 3つの手法の基盤

となる手法として Option-Critic アーキテクチャを用いる. それぞれ学習前の終了条件の初期パラメータの与え方が異なる. 以下にそれぞれの初期化に用いる情報を示す.

4.2.1 ベースライン

終了条件に人の知識転移を行わないベースラインとなる手法である. [Bacon 17] に従った設定を行う.

4.2.2 ランダムランドマーク

ランダムな状態をサブゴール集合として選択し, 終了条件の初期パラメータとする手法である. 状態の選択方法は Option-Critic の学習エージェントを用いて学習している間に 30% の確率でサブゴールとして訪問している状態をサブゴール集合に追加する.

4.2.3 人のサブゴール知識転移

本論文で提案する手法である. 参加者実験で得たサブゴールを用いて終了条件を初期化する.

5. 結論

本論文では, 階層型強化学習においてサブゴール知識の転移の方法と実験方法の提案を行った. 今後の課題は提案した実験方法で実験を行い, 実験結果の分析を行うことである. さらに, Atari ゲームのような高次元の観測が必要なタスクにおいてサブゴールの知識転移の検証とインタラクティブ機械学習の枠組みでサブゴール知識をオンラインで転移できるアルゴリズムの設計が挙げられる. さらに, 人間の相互適応を利用し訓練者も学習エージェントと共に学習する枠組みを設計することを旨とする.

参考文献

- [Amershi 14] Amershi, S., Cakmak, M., Knox, W. B., and Kulesza, T.: Power to the People: The Role of Humans in Interactive Machine Learning, *AI Magazine*, Vol. 35, No. 4, p. 105 (2014)
- [Bacon 17] Bacon, P.-L., Harb, J., and Precup, D.: The Option-Critic Architecture, in *AAAI* (2017)
- [Knox 12] Knox, W. B.: *Learning from Human-Generated Reward*, PhD thesis (2012), Dissertation page: <http://web.media.mit.edu/~bradknox/Dissertation.html>
- [Loftin 16] Loftin, R., Peng, B., MacGlashan, J., Littman, M. L., Taylor, M. E., Huang, J., and Roberts, D. L.: Learning behaviors via human-delivered discrete feedback: modeling implicit feedback strategies to speed up learning, *Autonomous Agents and Multi-Agent Systems*, Vol. 30, No. 1, pp. 30–59 (2016)
- [Ng 00] Ng, A. Y. and Russell, S. J.: Algorithms for Inverse Reinforcement Learning, in *Proceedings of the Seventeenth International Conference on Machine Learning*, ICML '00, pp. 663–670, San Francisco, CA, USA (2000), Morgan Kaufmann Publishers Inc.
- [Settles 09] Settles, B.: Active Learning Literature Survey, Computer Sciences Technical Report 1648, University of Wisconsin–Madison (2009)

- [Sutton 98] Sutton, R. S., Precup, D., and Singh, S. P.: Intra-Option Learning about Temporally Abstract Actions, in *Proceedings of the Fifteenth International Conference on Machine Learning (ICML 1998)*, Madison, Wisconsin, USA, July 24-27, 1998, pp. 556–564 (1998)
- [Sutton 99] Sutton, R. S., Precup, D., and Singh, S.: Between MDPs and semi-MDPs: A Framework for Temporal Abstraction in Reinforcement Learning, *Artificial Intelligence*, Vol. 112, No. 1-2, pp. 181–211 (1999)
- [Taylor 11] Taylor, M. E., Suay, H. B., and Chernova, S.: Integrating reinforcement learning with human demonstrations of varying ability, in *AAMAS* (2011)
- [Taylor 18] Taylor, M. E.: Improving Reinforcement Learning with Human Input, in *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence (IJCAI-18)*, pp. 5724–5728 (2018)
- [山田 14] 山田 誠二, 水上 淳貴, 岡部 正幸, インタラクティブ制約付きクラスタリングにおける制約選択を支援するインタラクシオンデザイン, *人工知能学会論文誌*, Vol. 29, No. 2, pp. 259–267 (2014)

深層強化学習による物流プロセスの全体最適化

Global optimization for supply chain process by deep reinforcement learning

小池和弘 *1

Kazuhiro Koike

*1 アスクル株式会社

ASKUL Corporation

The *bullwhip effect* is known as one of the problems in the supply chain. As a result of demand forecasting and decision-making, demand propagates from downstream to upstream while amplifying. This phenomenon is well reproduced by the Beer Game invented in the 1960's. On the other hand, in online shopping, there is a gap between the information-flow in cyberspace and the object-flow in physical space. This gap can be a factor to promote the *bullwhip effect*, but it is difficult to reproduce with the original Beer Game. Therefore, we set up the new game called "Netshop Game" which extended the rules and the environment. On the new game, by using deep reinforcement learning, we are able to reproduce the local optimum that can occur in net shopping supply chain, and confirmed that it is effective for discovering a global optimum by introducing a meta viewpoint.

1. はじめに

一般的にサプライチェーンで起きうる問題の一つとして *Bullwhip effect* (以下 BE) が知られている。これはサプライチェーンの下流における需要予測と意思決定の結果、需要が拡大しながら下流から上流に向かって伝搬していく現象であり、最初に認識されたのは 1958 年である [Forrester]。この現象は過剰在庫や欠品に繋がるため、発生メカニズムと抑制手法は長年に渡り研究対象となっている [Lee04]。Lee らは BE の要因として、価格表、発注頻度、返品方針、価格販売施策の頻度と深さ、情報共有の程度、需要予測方法、欠品時の配分ルールなどを挙げている [Lee97]。

BE が発生する様子は Beer Game (以下 BG) によってうまく再現される。BG は 1960 年代に MIT で考案されたシミュレーションゲームであり、直列に繋がったビールのサプライチェーンで、4 人の player が Retailer, Wholesaler, Distributor, Manufacturer となって、決められた期間内でのコスト最小化を競う (図 1)。

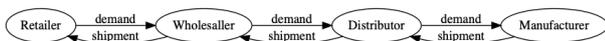


図 1: Beer Game

ネット通販においては、サイバー空間での情報の流れとフィジカル空間での物の流れの効率の差が顕著になってきており、このズレが BE の新たな要因となる可能性がある。例えば、EC サイトでの高度に効率化された販売施策によって需要の変動が増幅された結果、配送遅延や欠品、過剰在庫などが発生する場合が考えられる。販売施策が BE の要因であることは、前述の通り Lee らによって既に指摘されているが、ネット通販では意図的に過剰に強気な販売施策を取らなくても、構造的に組み込まれていると考えられる。実体と重量を持った Atom の移動は Bit のように容易ではないからである。

このサイバーとフィジカルのズレはオリジナルの BG では再現できないため、本研究ではルールを拡張した Netshop Game

を新たに設定し (図 2)、ネット通販の物流プロセスにおける諸問題の再現と全体最適化に深層強化学習を用いる方法について検討と評価を行った。

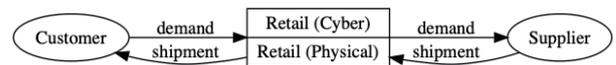


図 2: Netshop Game

2. 関連研究

BG の過程は MDP (*Markov Decision Process*) として知られており、かつ観測できる情報は、隣り合う player との注文と商品のやり取りと自身の在庫レベルのみであるため、POMDP (*Partially Observable Markov Decision Process*) である。各 player は観測可能な部分情報からコストを最小化する行動を選択するのだが、Observation 空間と Action 空間は大きく、非定常な時系列を扱うため複雑な問題である。Mnih らによって提案された DQN (deep Q-network) [Mnih] は、このような複雑な問題を克服する方法として有望である。BG の深層強化学習によるアプローチは、例えば [Oroojlooyjadid] や [Fuji] があり、効果が報告されている。

3. 提案手法

ネット通販の物流プロセス問題を扱う場合、BG そのままでは適用しにくい。ネット通販では、EC サイトやネットによる取引などサイバー空間で完結するプロセスと、物流倉庫や配送センターなどフィジカル空間で行われるプロセスでは特性の違いがある。例えばサイバー空間では商品 100 個はあくまでも数値データ (Bit) であり、100 個を強気な販売施策によって 10 倍にすることについて物理的な制約を受けにくい。一方でフィジカル空間では商品 100 個は体積と重量を持つ実体 (Atom) であり倉庫のキャパシティや出荷能力など物理制約の影響を大きく受ける。また BG では上流 player への注文のリードタイムも設定できるが、ネットによる取引では無視できる。

BG では、直列に連結された Retailer, Wholesaler, Dis-

tributor, Manufacturer の 4 player がゲームに参加するのだが、上記のネット通販特有の問題にフォーカスするため、player を Retailer のみとし、上流の 3 player, すなわち Wholesaler, Distributor, Manufacturer は Supplier として一括りで考えることにする。そして Retailer の中はサイバー空間のプロセスを管理する Cyber player と、フィジカル空間を管理する Physical player に分ける。ゲームのゴールは、Cyber は Customer からの需要に対してどれだけ欠品なくデリバリーできたかを示す *fill rate* (以下 FR) が設定した閾値より大きくなること、Physical は *bullwhip effect index* (以下 BEI) の値が設定した閾値より小さくなることとした。

これを Netshop Game と名付け、この環境を OpenAI Gym で実装し、Cyber player, Physical player それぞれの最適な行動を DQN によって学習し評価する。2 つの player にはそれぞれ偏った報酬の与え方とゴールを設定し、あえて個別最適化行動するようにして、どのような結果になるかを観察する。両者の報酬の与え方とゴール設定はいわば Netshop Game におけるジレンマである。ここに全体最適化のため、ジレンマを抱えながらバランスをとることを目指す高次元な視点を持った Meta player を加えた。

4. player 定義

Netshop Game の player は次の 3 タイプとする。

- CYBER : サイバー空間で主に報酬最大化を狙いとする player である。EC サイト上でセール、ポイント n 倍、などのセールスプロモーションを積極的に行う。在庫レベルの上昇によって生じるコストは無視し、欠品による機会損失を最小化するように行動する。
- PHYSICAL : フィジカル空間で主に物流コスト最小化を狙いとする player である。欠品による機会損失については無視し、倉庫や配送のコストを最小化すべく在庫レベルを低く抑え、BE を抑制するように行動する。
- META : CYBER と PHYSICAL それぞれの報酬とゴール条件のジレンマを抱えてバランスをとるように行動する。

5. 環境設計

5.1 状態変数

タイムステップ t における観測可能な状態変数 o_t を式 1 で定義する。

$$o_t = [IL_t, OO_t, d_t, RS_t, SS_t, a_t] \quad (1)$$

$$ho_t = [o_1, \dots, o_t] \quad (2)$$

IL_t は t における在庫数、 OO_t は supplier に対して発注したはまだ入荷していない商品数、 d_t は customer からの需要、 a_t は t における action すなわち supplier への発注数、 RS_t は supplier から入荷した商品数、 SS_t は customer に対して出荷した商品数である。

ho_t は 1 エピソードの全タイムステップの状態変数を historical observation として記憶する (式 2)。

状態変数については [Oroojlooyjadid] の定義を参考にし、ゴール条件の BEI と FR に関与する SS_t を追加した。

5.2 Action 空間

Netshop Game における action は、supplier に対する商品の発注数であり Action 空間の自由度をどこまで許容するかは慎重に決める必要がある。ここでは大きすぎる空間はメモリ効率と処理時間に悪影響があると考え、player が選択可能な Action 空間は 0 から 20 の離散値集合 $[0, 1, 2, \dots, 20]$ としたが、上限について特に強い根拠はない。

5.3 報酬

BG では式 3 に示す通り、在庫レベルによって報酬が決まる。在庫数が正の場合は在庫数分の在庫コスト c_h を、負の場合は欠品による機会損失 c_p をコストとする [Oroojlooyjadid]。なお右側の Σ は 4 player の総計を求めるためである。

$$\sum_{t=1}^T \sum_{i=1}^4 c_h^i (IL_t^i)^+ + c_p^i (IL_t^i)^- \quad (3)$$

$$(x)^+ : \max(0, x)$$

$$(x)^- : \max(0, -x)$$

Netshop Game では売値、仕入れ値、販売促進費、配送費を追加した。 s_p は売値、 c_r は仕入れ値、 c_s は販売促進費、 c_d は配送費とする。なおこれらの値は環境の中に隠され、各 player からは観測できない。式 4, 式 5, 式 6 はそれぞれ CYBER, PHYSICAL, META の報酬である。

$$\sum_{t=1}^T s_p SS_t - c_r RS_t - c_p (IL_t)^- - c_s (a_t - d_t)^+ \quad (4)$$

$$\sum_{t=1}^T s_p SS_t - c_r RS_t - c_h (IL_t)^+ - c_d SS_t \quad (5)$$

$$\sum_{t=1}^T s_p SS_t - c_r RS_t - c_p (IL_t)^- - c_h (IL_t)^+ - c_s (a_t - d_t)^+ - c_d SS_t \quad (6)$$

CYBER は欠品の機会損失コストに加え supplier への発注量が需要より大きければその差分を販売促進費として加算する。PHYSICAL は在庫数分の在庫コストと customer への出荷数分の配送コストを加算する。CYBER は過剰在庫を気にせず、PHYSICAL は欠品を気にしないという偏った報酬の設定は、局所最適に陥る状況を意図的に発生させるためである。META はコストを全て加算するが、これはバランスをとったグローバルな解を求めるためである。

5.4 ゴール条件

BG の場合は決められたタイムステップ期間の総報酬で競うのであるが Netshop Game では二つの指標をゴール条件として設定する。ゴール条件を満たしたら episode 終了となる。指標の一つは *bullwhip effect index* (BEI) 式 7 であり、もう一つは *fill rate* (FR) 式 8 である。なお、demand は t における需要数の直近 p 期間分の配列、shipped は t における出荷数の直近 p 期間分の配列、 $Var(x)$ は x の分散、 $Mean(x)$ は x の平均である。式 9 は PHYSICAL のゴール条件、式 10 は CYBER のゴール条件、META はその AND である。

$$BEI = Var(shipped)/Var(demand) \quad (7)$$

$$FR = Mean(shipped/demand) \quad (8)$$

$$BEI \text{ threshold} > BEI \quad (9)$$

$$FR \text{ threshold} < FR \quad (10)$$

5.5 需要生成

t における需要 D_t は直近 p 期間の平均に変動分として正規分布に従う確率変数 x を加えて生成される。なお初期値は 1 から 10 までの自然数からランダムに選択する。

$$D_t = \frac{\sum_{j=t-p+1}^t d_j}{p} + x \quad x \sim \mathcal{N}(\mu, \sigma^2) \quad (11)$$

5.6 アルゴリズム

Action の結果から得られた経験の蓄積と活用のトレードオフバランスをとる方法として ϵ -greedy algorithm を採用し、状態評価には DNN を採用した。

Listing 1: Netshop Game Algorithm

```

1 procedure DQN
2   for episode = 1 : n do
3     reset environment
4     for t = 1 : T do
5
6        $a_t = \begin{cases} \text{take random action prob. } \epsilon \\ \arg \min_a Q(s_t, a, \theta) \text{ (otherwise)} \end{cases}$ 
7       observe reward  $r_t$  and state  $s_{t+1}$ 
8       mini-batch  $(s_j, a_j, r_j, s_{j+1})$ 
9
10       $y_j = \begin{cases} r_j & (\text{goal}) \\ r_j + \min(Q(s, a, \theta)) & (\text{otherwise}) \end{cases}$ 
11      loss function  $(y_j - Q(s_j, a_j, \theta))^2$ 
12    end for
13  end for
14 end procedure

```

6. 学習

CYBER, PHYSICAL, META それぞれの player について 50,000 steps を上限として学習を行った。図 3 は META player agent の学習が進むにつれて報酬が上昇していく様子を示したものである。

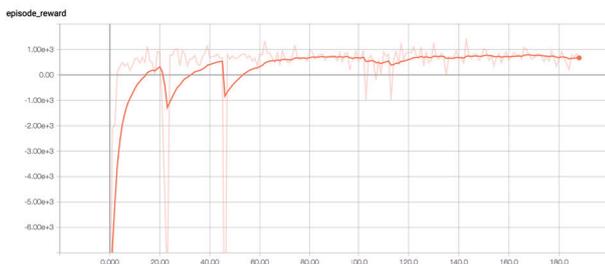


図 3: episode-rewards of META player Agent

7. テスト

学習済みの CYBER, PHYSICAL, META 各 player agent モデルを使ってそれぞれ 100 episodes のテストを行った。1 episode のタイムステップは上限を 1,000 とし、ゴール条件に達していなくても打ち切ることとした。ゴール条件は学習時と同じである。それぞれ最初の 9 episodes の最後の 100 steps

について、demand, action, stock の推移グラフを示す。それぞれ CYBER:図 4, PHYSICAL: 図 5, META:図 6 である。また、図 7 は各 player の獲得報酬のヒストグラムである。

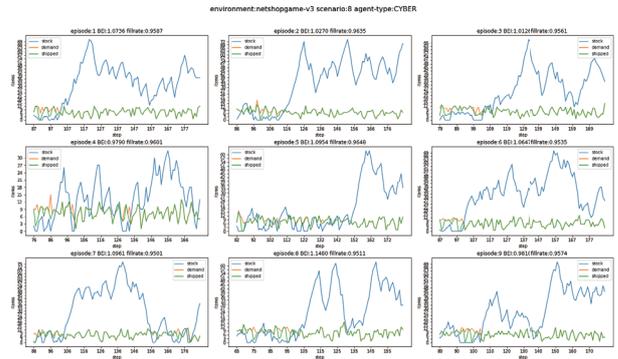


図 4: CYBER player agent

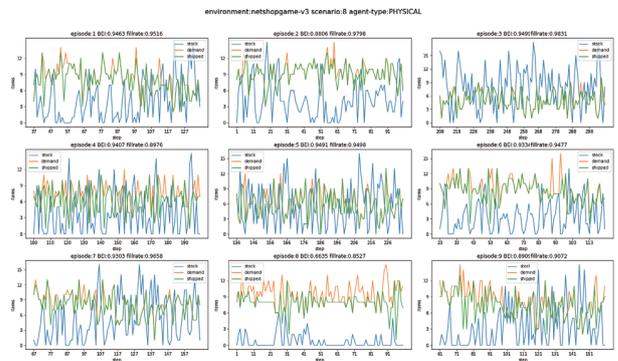


図 5: PHYSICAL player agent

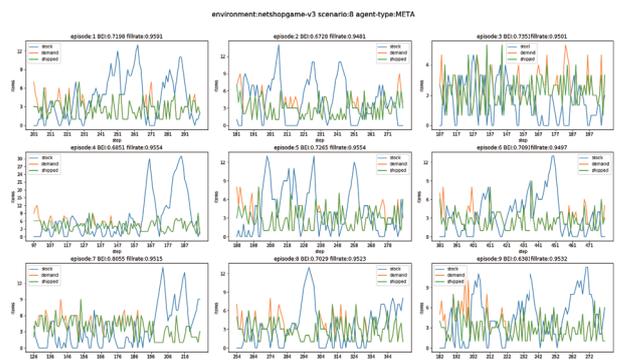


図 6: META player agent

8. 考察

表 1 はテスト結果である。steps はゴールに至るまでにかかった step 数であり、小さいほど良い。BEI は 1.0 より小さければ BE が抑制されたと考えられる。FR は customer からの需要に対して出荷できた割合を示しており 1.0 に近いほど良い。rewards は episode で得た報酬合計である。

報酬の最大化が目的であれば CYBER が一番良いが、CYBER player の episode の推移を見ると、全体的に在庫が高い

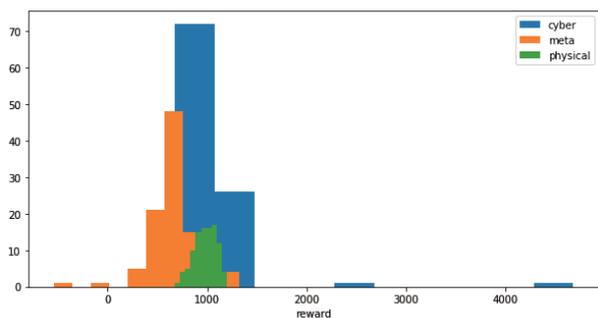


図 7: reward histogram

レベルであり続けるという現象が起きている (図 4 参照). これは過剰在庫に対して抑制する要素を与えていないため当然予想された結果であるが, 在庫レベルが抑制されている episode 4 が興味深い. BEI をゴール条件に入れていないにも関わらず他の episode に比べて低い値になった. 発注数 a と需要 d の差によって生じる販売促進費の抑制効果が働いていると考えられる.

PHYSICAL player は全体的に低い在庫レベルを維持し BEI も低い水準であるが, episode 8, 9 のようにしばしば欠品することがあり, 結果として FR も低い値になっている (図 5 参照). これも報酬とゴール設定から予想通りの結果である.

META player の BEI と FR は良い成績であるが獲得報酬が低く, ゴール達成までに他の Agent に比べて倍以上の steps がかかっている. バランスを見出すことが簡単では無いことがわかる. episode 2, 5 のように一部であるが周期と高さが一定の波形になっている部分があり, 在庫を安定させるための適正な数量管理を学習する可能性を示した. (図 6 参照)

表 1: テスト結果 (100 episodes の平均値)

player	steps	BEI	FR	rewards
CYBER	182.5200	1.0658	0.9562	1051.5985
PHYSICAL	171.4000	0.8388	0.9083	982.1282
META	369.4100	0.7025	0.9471	649.0225

9. 結論

本研究ではネット通販における物流プロセスを抽象化して Netshop Game という形をとったが, その目的は次の通りであった.

1. player 間で共有できない情報を環境の中に隠した POMDP においても解がみつかることを確認する.
2. player に偏った報酬の与え方とゴール条件設定をすることで局所最適に陥る様子を再現する.
3. 報酬とゴール条件設定のジレンマに対して, メタな視点を導入することでバランスの良い解が得られるかどうか確認する.

目的 1 については, BE の抑制に player 間の情報共有が有効であることが分かっている [Lee97]. ビジネス的に共有でき

ない仕入れ値などの情報を隠しても解は見つけられることが確認できた. 目的 2 についてはほぼ予想通りの結果が再現でき, 報酬とゴール設計の重要性を確認できた. 目的 3 のジレンマとは, BEI と FR のことであり, BEI を低くするには FR を下げないとならないという関係になっている. 逆も同様であり FR を上げて 1.0 に近づけるためには BEI が高くなる. META player が目指したのはこのトレードオフのバランスであるが, バランスは取れたものの獲得報酬は低いことが課題である.

10. おわりに

BG が考案された 1960 年代とネット通販隆盛の現在の違いは, サプライチェーンの情報の流れが著しく進化し効率化された点である. 情流に比べると物流については比較的進化の速度は緩やかであるため, EC サイトやネット取引などのサイバー空間ではデジタル化と AI によるデータ活用が進み, 倉庫や配送などフィジカル空間との間で効率化においてズレが起きていると考えられる. そのような状況においては, 例えば過度に強気な販売施策が極めて効率的に行われた場合, 通常起こりうる需要の変動以上の変動が発生し, BE の影響は更に大きくなると考えられる.

サイバー側の player とフィジカル側の player が個別に指標を定めて最大化を追求するということは, 機能ごとに分かれた組織においては合理的にみえるので, 個別最適な状況は構造的に起こりうる. しかしそれでは全体として利益は期待できないため, 全体最適化には高次元な, つまりメタな視点が必要なのである.

物流問題においては教師データが無い問題が多く, player 間で共有しづらい情報やそもそも観測が困難な情報がある. 物理的な設備の変更はコストが掛かるため様々な施策を試すことは容易では無い. そのため仮想的な環境内で相互作用から学習することができる深層強化学習が有効であると考えている. 本研究ではその有効性を示すことができたと考えている.

参考文献

- [Forrester] J. W. Forrester. Industrial dynamics: A major breakthrough for decision makers. *Harvard Bus. Rev.* (July/August 1958) 36 3766.
- [Fuji] Taiki Fuji et al. Deep Multi-Agent Reinforcement Learning using DNN-Weight Evolution to Optimize Supply Chain Performance. doi 10.24251/HICSS.2018.157 (2018)
- [Lee97] H. L. Lee et al. Information distortion in a supply chain: The bullwhip effect. *Management Science*, 43(4):546-558, (1997).
- [Lee04] H. L. Lee et al. Comments on "Information Distortion in a Supply Chain: The Bullwhip Effect". *Management Science* 50 (12 supplement). 1887-1893 (2004).
- [Mnih] V. Mnih et al. Human-level control through deep reinforcement learning, doi 10.1038/nature14236 (2015).
- [Oroojlooyjadid] Afshin Oroojlooyjadid et al. A Deep Q-Network for the Beer Game: A Reinforcement Learning Algorithm to Solve Inventory Optimization Problems, arXiv:1708.05924v2 (2018).

最大エントロピー原理に基づく逆強化ダイナミクス学習 フレームワークの構築

Construction of Inverse Reinforcement Dynamics Learning Framework based on Maximum Entropy Principle

中口 悠輝 江藤 力 西岡 到
Yuki Nakaguchi Riki Eto Itaru Nishioka

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

Recently, reinforcement learning (RL) has been showing an increasingly high performance in a variety of complex tasks of decision making and control, but RL requires quite careful engineering of reward functions to solve real tasks. Inverse reinforcement learning (IRL) is a framework to construct reward functions by learning from demonstration, but most of IRL algorithms require many accesses to the dynamics, though our access to and knowledge about the dynamics is often limited. To deal with this uncertainty of the dynamics, we propose a novel mathematical framework for constructing reward and dynamics by extending the celebrated maximum entropy framework of IRL.

1. はじめに

近年、意思決定や制御の手法を学習するフレームワークである強化学習の研究が著しく進展し、計算機の性能向上も相まって、ロボットの制御やビデオゲームの攻略、囲碁や将棋といった複雑な意思決定や制御の問題において幅広く高い性能を示すようになった。しかし、より幅広い実問題に適用するにあたっては、適切な報酬関数を指定するのが困難でしばしば意図しない振る舞いが生じてしまうのが大きな問題となっている [1]。いかに強化学習のアルゴリズムが適切に働いていても、良いパフォーマンスを得るためには緻密な報酬関数設計が必要となってしまう。

逆強化学習 (Inverse Reinforcement Learning; IRL) [2] は、強化学習の逆問題を解くことでこの人手による緻密な報酬関数設計を回避する *1。即ち、強化学習では与えられた報酬関数のもとで意思決定主体が良い振る舞いを模索するが、逆強化学習では、その強化学習問題のエキスパートの振る舞いのデモンストレーションを与え、それを生成した報酬関数を推測する。しかし、殆どの逆強化学習の定式化はダイナミクス (状態がいかに遷移していくか) へ幾らでもアクセスできることを仮定している一方で、現実にはしばしばダイナミクスへのアクセスは限られており、不確実な知識しか持ち合わせていない。

そこで本研究では、ダイナミクスに対する知識の不確実さに対処するため、逆強化学習にて最も主流の最大エントロピー法をダイナミクスの推測を含む形へ拡張することで、報酬関数とダイナミクスを同時に構成するフレームワークを提案する。また、逆強化学習および最大エントロピー法を簡潔にレビューする。

2. 逆強化学習

2.1 強化学習の定式化

強化学習は通常、Markov 決定過程 (Markov Decision Process; MDP) と呼ばれる、各時刻にて意思決定を行う主体 (エージェント、agent) を導入することで Markov 過程を一般化した数理モデルとして定式化される。Markov 過程において状態 (state) $s \in \mathcal{S}$ の時系列 $S_t = (s_1, \dots, s_t)$ を生成していく Markov 的ダイナミクス $p_t(s_{t+1}|s_t)$ は現在の状態 s_t にし

か依らなかつたが、Markov 決定過程におけるダイナミクス $p_t(s_{t+1}, r_{t+1}|s_t, a_t)$ では、現在の状態 s_t においてエージェントが取った行動 $a_t \in \mathcal{A}$ にも依存する上、次の時刻の状態 s_{t+1} のみならず報酬 (reward) と呼ばれる実数値 $r_{t+1} \in \mathbb{R}$ を確率的に返す *2。通常、関数形が時刻 t に依らない斉時的 (time homogeneous) な Markov 的ダイナミクス $p = p_t$ を用いる。

強化学習の問題は、各時刻 t において今までの状態の時系列 S_t と行動の時系列 $A_{t-1} = (a_1, \dots, a_{t-1})$ の実現値に基づいて行動 a_t を選択する確率分布 (方策、policy) $\pi(a_t|S_t, A_{t-1})$ のうち、報酬の時間総和 $R \equiv \sum_{t'} \gamma^{t'} r_{t'+1}$ (利得、return) の期待値を最大化する最適方策を求める問題として定式化される。ここで、割引因子 (discount factor) $\gamma \in [0, 1]$ は将来の報酬の価値を現在価値に割り引く係数である。利得 R の期待値は報酬の期待値である報酬関数 (reward function) $r(s, a) \equiv E_p[r|s, a]$ にしか依らないため、通常は報酬の分布は考えずに報酬関数のみ取り扱う。その場合、次の時刻の状態 s' に対する周辺分布 $p(s'|s, a) = \int p(s', r|s, a) dr$ を単にダイナミクスという。斉時 Markov 的なダイナミクス $p(s'|s, a)$ に対しては最適斉時 Markov 的な方策 $\pi(a|s)$ が存在するため、通常は斉時 Markov 的な方策のみ考える *3。結局、エージェントの軌跡 (trajectory) $\zeta = (S, A)$ はダイナミクス $p(s'|s, a)$ と方策 $\pi(a|s)$ の 2 つの斉時 Markov 的分布に従って生成される。

2.2 逆強化学習の定式化とその流派

前述のとおり、逆強化学習においては、強化学習問題のエキスパートの軌跡のサンプル (デモンストレーション、demonstration) $D = \{\zeta_n\}_n$ を与え、この D を生成した報酬関数 $r(s, a)$ を推測するという逆問題を解く。しかし、一般に一つのデモンストレーションは無限に多くの報酬関数によって説明されうるため、逆強化学習はこのままでは不良設定問題である。どのように不良設定問題として定式化するかに応じて、逆強化学習は主に 3 つの流派、最大マージン法 [4-6]、最大エントロピー法 [7-9]、Bayes 的アプローチ [10, 11] に分かれる。

歴史的に最も初期のアプローチである最大マージン法では、

*2 状態集合 \mathcal{S} および行動集合 \mathcal{A} は離散でも連続でも良いが、時間はふつう離散時間 $t = 1, 2, \dots$ を考える。

*3 Markov 的ダイナミクス $p_t(s_{t+1}|s_t, a_t)$ に対しては最適な Markov 方策 $\pi_t(a_t|s_t)$ が存在するが、一般のダイナミクス $p(s_{t+1}|S_t, A_t)$ では Markov 方策が最適となるとは限らない。

連絡先: y-nakaguchi@cj.jp.nec.com

*1 最適制御問題における損失関数の推定に用いるという文脈では、逆最適制御 (Inverse Optimal Control; IOC) とも呼ばれる [3]。

報酬関数に対する何らかの目的関数（その報酬関数のもとのエキスパートと非エキスパートとの利得の差など）を設定し、それを最大化する報酬関数を選び出す。しかし、最大マージン法はデモンストレーションの乱雑さに対して頑健ではないという欠点がある。現実にはエキスパートといえども唯一の最適な行動を取っておらず最適に近い行動を取っており、行動は乱雑に揺らいでいる。あるいは仮にエキスパートが常に最適な行動を取っていたとしても、エキスパートが意思決定に用いている特徴量の全てを我々が観測できるわけではない場合、その軌跡は我々には乱雑に見えることとなる。

第3章で後述する最大エントロピー法では、最大エントロピー原理 [12] に基づいてエキスパートの乱雑な行動を確率的にモデル化する。Bayes 的アプローチでは、エキスパートを確率的にモデル化するのみならず、さらに報酬関数に対する事前分布を設定し、エキスパートの確率モデルから従う尤度関数によって Bayes 更新することで報酬関数に対する事後分布を得て、その事後平均 (posterior mean) や最大事後確率 (MAP) 推定を報酬関数の推定値とする。しかし、関数に対する分布の自由度が巨大なためそのままでは適切な更新に大きなサンプルが必要であること、事前分布や方策のモデルの任意性、Markov 連鎖モンテカルロなどのコストが高い計算が必要となるなどの欠点がある。MAP 推定値を取る定式化の場合、最大エントロピー法を特殊なケースとして含むと解釈できる [13]。

2.3 逆強化学習の諸課題

一方で、逆強化学習は幅広い現実の問題に適用するにあたって種々の課題を抱えている。

適切な報酬関数のクラスの設定

多くの研究では報酬関数が特徴量 $\phi(s, a)$ に関して線形な形 $r(s, a) = \theta^T \phi(s, a)$ に限っており、真の報酬関数が非線形の場合に表現できない。Gauss 過程を用いた Gauss 過程逆強化学習 (GP IRL) [14] や深層学習を用いた逆強化学習 [15, 16] などのように、表現力が高い関数近似器を用いれば真の報酬関数をよく近似できるようになるものの、バイアス-バリエーションのトレードオフによってより大きなサンプルが必要となる。また、仮に線形関数でよく近似できるとしても、特徴量 $\phi(s, a)$ をどう設計すべきかという問題が残る。Feature construction for IRL (FIRL) [17] のように特徴量設計を取り扱う手法は数少ない。

計算複雑性

典型的な逆強化学習のアルゴリズムでは、報酬関数を収束するまで逐次的に更新し、その更新において毎回、現在の報酬関数のもとで非常に計算複雑性が高い（計算量が大きい）何らかの計画問題（強化学習、動的計画法、モデル予測制御など）を解く。相対エントロピー逆強化学習 (Relative Entropy IRL; RE IRL) [18] では軌跡のサンプリングを活用し計画問題を回避するが、そのぶん多数のサンプルを必要とする。線形可解 Markov 過程 (Linearly solvable MDP; LMDP) に基づく逆最適制御 [19] では、計画問題が解析的に解けるような巧妙な問題設定に制限することで計算複雑性を回避している。誘導コスト学習 (Guided Cost Learning; GCL) [16] では、報酬関数の更新において計画問題を完全には解かず、報酬関数と同時に方策も保持して方策の小さな更新に留めることで計算複雑性を減らしている。

未知のダイナミクスとサンプル複雑性

報酬の更新における計画問題においては、ダイナミクスが既知の場合はそれを用いた動的計画法やモデル予測制御などを解けばよいが、ダイナミクスが未知の場合は強化学習などダイナミクスからのサンプリングが必要となり、デモンストレーションのみならずそのダイナミクスからのサンプル複雑性（学習に

必要なサンプルのサイズ）も問題となる。RE IRL では報酬関数の更新においてはサンプリングを必要としないが、そのぶんはじめに十分なサンプルを用意する必要がある。GCL では計画問題を解ききらずに現在の方策によるサンプリングに留めることで、ダイナミクスからのサンプル複雑性も下げている。

現実には、ダイナミクスについての限られた知識や推測しか無く、ダイナミクスからのサンプリングもできない場合も考えられる [20]。そのような場合、デモンストレーションを持つダイナミクスの情報をうまく活用する技術が必要である。本研究では、ダイナミクスについての限られた知識や推測を活用しながらデモンストレーションが含むダイナミクスの情報をうまく活用する定式化として、最大エントロピー法のフレームワークを拡張し、報酬関数とダイナミクスを同時に構築する新しいフレームワークを提案する。

3. 最大エントロピー逆強化学習

3.1 最大エントロピー原理

最大エントロピー原理は、確率変数 x について何らかの特徴量ベクトル $\phi(x)$ の期待値 $E_p[\phi(x)] \equiv \sum_x p(x)\phi(x)$ の値のみ $\langle \phi \rangle$ であると観測できているがその分布 $p(x)$ 自体が未知である状況において、分布 $p(x)$ を構成する標準的な方法を与える。即ち、特徴量 $\phi(x)$ の期待値 $E_p[\phi(x)]$ を観測値 $\langle \phi \rangle$ に固定する拘束条件のもと、エントロピー $H[p] \equiv E_p[-\log p(x)] = -\sum_x p(x) \log p(x)$ を最大にする分布

$$p^* = \arg \max_{p \in \Delta} H[p] \quad \text{s.t.} \quad E_p[\phi(x)] = \langle \phi \rangle$$

を選ぶ。ここで、 $\Delta \equiv \{p \mid p(x) \geq 0, \sum_x p(x) = 1\}$ は規格化を満たす確率分布全体（確率単体）である。エントロピー $H[p]$ が凹関数で実行可能領域も凸集合なため、この問題は凸最適化問題である。よって、緩い条件下で強双対性が成り立ち、その解は Lagrange 関数 $L[p, \theta, \lambda]$ を

$$L \equiv H[p] + \theta^T (E_p[\phi(x)] - \langle \phi \rangle) + \lambda \left(\sum_x p(x) - 1 \right) \quad (1)$$

とする Lagrange 双対問題 $\min_{\theta, \lambda} \max_p L[p, \theta, \lambda]$ を解くことにより、指数型分布

$$p_\theta(x) = \frac{e^{\theta^T \phi(x)}}{Z_\theta} \quad (2)$$

として得られる。 $H[p]$ が狭義凹関数なので解は一意的である。規格化因子 $Z_\theta = \sum_x e^{\theta^T \phi(x)}$ は Bayes 統計と同様、統計力学の用語を流用して分配関数 (partition function) と呼ばれる。

Lagrange 未定乗数 θ はエントロピー $H[p_\theta] = E_{p_\theta}[-\theta^T \phi(x) + \log Z_\theta] = -\log(e^{\theta^T \langle \phi \rangle} / Z_\theta)$ を最小にするように、特徴量の期待値のマッチング

$$0 = -\frac{\partial H[p_\theta]}{\partial \theta} = \langle \phi \rangle - E_{p_\theta}[\phi(x)] \quad (3)$$

により定まる。ここで、指数型分布の恒等式 $E_{p_\theta}[\phi(x)] = -\frac{\partial}{\partial \theta} \log Z_\theta$ を用いた。とくに、観測値 $\langle \phi \rangle$ が何らかの観測サンプル X のサンプル平均 $\langle \phi \rangle = \frac{1}{|X|} \sum_{x \in X} \phi(x)$ として与えられている場合には、エントロピー $H[p_\theta]$ は単に負の対数尤度 $-\log p(X|\theta)$ であるため、この特徴量マッチングによる θ の決定は指数型分布 (2) に対する最尤法と解釈できる。

直感的には、エントロピーはその変数のもつ不確かさ、その変数の値に対する我々の無知の度合いを表すと解釈できるため、既知の知識と整合する確率分布のうち、未知の部分に対しては最も謙虚な、最も無情報で“無難”な分布を選ぶということであ

る。事実、最大エントロピー分布は、最悪時予測対数誤差

$$\max_{\tilde{p} \in \Delta} \left[- \sum_x \tilde{p}(x) \log p(x) \right] \quad \text{s.t.} \quad E_{\tilde{p}}[\phi(x)] = \langle \phi \rangle$$

を最小化するという点で最も“無難”である [21]。

3.2 ダイナミクスが決定論的な場合

Ziebart はエキスパートの行動の確率モデルの構築においてこの最大エントロピー原理を適用し、最大エントロピー逆強化学習 (Maximum Entropy IRL; ME IRL) を提案した。最初の論文 [7] では、ダイナミクスが決定論的な場合、即ち、次の時刻の状態 s' が現在の状態 s と現在の行動 a の関数として表せる場合 $s' = f(s, a)$ を取り扱っている。その場合、軌跡 $\zeta = (S, A)$ は行動の系列 $A = A_T = (a_1, \dots, a_T)$ によって一意的に ζ_A と定めることができるので、取り扱われるべき確率変数は本質的に行動の系列 A のみである。

軌跡に対する特徴量 $\phi(\zeta)$ の期待値がデモンストレーション D のサンプル平均 $\langle \phi \rangle \equiv \frac{1}{|D|} \sum_{\zeta \in D} \phi(\zeta)$ と一致するという拘束条件を取り、最大エントロピー原理に基づいてエントロピー $H[\pi] = - \sum_A \pi(A) \log \pi(A)$ を最大化する分布

$$\pi^* = \arg \max_{\pi \in \Delta} H[\pi] \quad \text{s.t.} \quad E_{\pi}[\phi(\zeta_A)] = \langle \phi \rangle$$

を採用することで、指数型分布 $\pi_{\theta}(A) = e^{\theta^T \phi(\zeta_A)} / Z_{\theta}$ を得る。さらに Ziebart は、指数 $r_{\theta}(\zeta) \equiv \theta^T \phi(\zeta)$ をこの軌跡 ζ に対する利得 $\sum_t r(s_t, a_t)$ と解釈することを提案した。実際、この解釈のもとで、この分布による利得の期待値 $E_{\pi_{\theta}}[r_{\theta}]$ は観測値 $\langle r_{\theta} \rangle = \theta^T \langle \phi \rangle$ に一致する。この提案の数理的な正当性については、後に [22] で与えられた。

3.3 非線形な報酬関数への一般化

未定乗数としてパラメータ θ を導入するこの手法では線形な報酬関数しか構成できないが、拘束条件を取り込んだ Lagrange 関数 (1) $L[\pi, \theta] = H[\pi] + E_{\pi}[r_{\theta}(\zeta_A)] - \langle r_{\theta} \rangle$ から出発することで、報酬関数 r_{θ} をパラメータ θ に関して非線形の関数へと一般化できる [15, 16]。解は全く同様に $\pi_{\theta}(A) = e^{r_{\theta}(\zeta_A)} / Z_{\theta}$ として得られ、パラメータ θ はエントロピー $H[\pi_{\theta}] = - \log(e^{r_{\theta}} / Z_{\theta})$ (あるいは負の対数尤度) を最小化するように

$$0 = - \frac{\partial H[\pi_{\theta}]}{\partial \theta} = \frac{\partial \langle r_{\theta} \rangle}{\partial \theta} - E_{\pi_{\theta}} \left[\frac{\partial r_{\theta}(\zeta_A)}{\partial \theta} \right] \quad (4)$$

により定まる。これは特徴量マッチング (3) の一般化である。

3.4 一般のダイナミクスの場合

より一般の確率的なダイナミクスへと最大エントロピー法を一般化するためには、行動の系列 A のみならず状態の系列 S も確率変数として扱う必要があるが⁴、エントロピーの定義をどう一般化するかは非自明である。いま、ダイナミクスによる状態の系列 S の確率モデルは構築しないため、両者の不確かさである同時エントロピー (joint entropy) $H[S, A] \equiv - \sum_{S, A} p(S, A) \log p(S, A)$ を最大化するのは不自然である。状態の系列 S のエントロピーは適切に除外し、行動の系列 A のエントロピーのみ用いたい。

しかし、同時分布の分解 $p(S, A) = p(A|S)p(S)$ から従うエントロピーの分解 $H[S, A] = H[A|S] + H[S]$ において、第一項の条件付エントロピー $H[A|S] \equiv - \sum_{S, A} p(S, A) \log p(A|S)$ のみ用いると、条件付分布 $p(A|S) = \prod_t p(a_t|S, A_{t-1})$ では行動 a_t の分布が未来の状態にも条件付けられており因果律と整合せず、条件付エントロピー $H[A|S] = \sum_t H[a_t|S, A_{t-1}]$ も因果律と整合せず不適切である。

一般に、ある時系列 A を別の時系列 S によって時々刻々と条

件付けたい場合、因果律と整合するように条件付けた因果的条件付分布 (causally conditioned probability)

$$p(A|S) \equiv \prod_t p(a_t|S_t, A_{t-1})$$

を用いるのが適切である。このとき同時分布は $p(S, A) = p(A|S)p(S|A_{T-1})$ と2つの因果的条件付分布の積に分解でき、それに応じて同時エントロピーは2つの因果的エントロピー (causal entropy)

$$H[A|S] \equiv - \sum_{S, A} p(S, A) \log p(A|S) = \sum_t H[a_t|S_t, A_{t-1}]$$

の和 $H[S, A] = H[A|S] + H[S|A_{T-1}]$ に分解できる。Ziebart はこの因果的エントロピーを採用することで、ダイナミクスが確率的な場合へ最大エントロピー逆強化学習を一般化した [8, 9]。

因果的エントロピー $H[A|S]$ を最大化する因果的条件付分布 $\pi(A|S)$ は、その自由度を時間に関して分解 $\pi(A|S) = \prod_t \pi(a_t|S_t, A_{t-1})$ し、各 $\pi(a_t|S_t, A_{t-1})$ について最大化することで求めることができる。Lagrange 関数 (1)

$$L[\pi, \theta] = H[A|S] + E_{\pi}[r_{\theta}(S, A)] - \langle r_{\theta} \rangle \quad (5)$$

を変分し解は $\pi_{\theta}(a_t|S_t, A_{t-1}) \propto e^{q_{\theta}^{(t)}(S_t, A_t)}$ と求まる。指数 $q_{\theta}^{(t)}(S_t, A_t) \equiv E_{\pi} [r_{\theta}(S, A) - \log p(A_{t+1:T}|S_{t+1:T}) | S_t, A_t]$ は初項 $q_{\theta}^{(T)}(S, A) = r_{\theta}(S, A)$ および漸化式 $q_{\theta}^{(t)}(S_t, A_t) = E_{s_{t+1}} [\log \sum_{a_{t+1}} e^{q_{\theta}^{(t+1)}(S_{t+1}, A_{t+1})}]$ によって再帰的に求まり、パラメータ θ は因果的エントロピー $H[A|S] = - \log(e^{r_{\theta}} / e^{q_{\theta}^{(0)}})$ を最小化するように再び特徴量マッチング (4) によって定まる。この特徴量マッチングによる θ の決定は因果的尤度 (causal likelihood)

$$\sum_{S, A} \pi_e(A|S) p(S|A_{T-1}) \log \pi_{\theta}(A|S) \simeq \sum_{\zeta \in D} \log \pi_{\theta}(A|S)$$

の最大化と解釈できる。ここで、 $\pi_e(A|S)$ はエキスパートのデモンストレーション D を生成した真の方策である。

さらに、利得が報酬の時間和で書けること $r(S, A) = \sum_t r(s_t, a_t)$ およびダイナミクスの斉時 Markov 性を仮定すると、 $Q^{(t)}(S_T, A_T) \equiv q^{(t)}(S_T, A_T) - \sum_{t' < t} r(s_{t'}, a_{t'})$ が (s_t, a_t) のみにしか依存しないことを帰納的に示すことができ、その結果として方策も斉時 Markov 的 $\pi(a_t|s_t) \propto e^{Q(s_t, a_t)}$ であると分かる。規格化 $V_{\theta}(s) \equiv \log \sum_a e^{Q_{\theta}(s, a)}$ も導入すると、解は

$$\pi_{\theta}(a|s) = \frac{e^{Q_{\theta}(s, a)}}{e^{V_{\theta}(s)}} \quad (6)$$

と書ける。 $q^{(t)}$ の漸化式は Q に対するソフト Bellman 方程式

$$Q_{\theta}(s, a) = r_{\theta}(s, a) + \gamma E_p[V_{\theta}(s') | s, a] \quad (7)$$

となる。これは、強化学習における価値関数 Q, V に対する最適 Bellman 方程式の max を softmax にしたものである^{4*5}。事実、目的関数 (5) の方策 π での最適化は、エントロピー正則化つきの利得の期待値 $E_{\pi}[r_{\theta}(S, A)] + H[A|S]$ を最大化する計画問題と解釈できる。このように利得にエントロピー正則化項を入れて一般化した強化学習の定式化は最大エントロピー強化学習

⁴ 割引因子 γ の導入は、因果的エントロピーを一般化した割引因果的エントロピー $H_{\gamma}[A|S] \equiv \sum_t \gamma^t H[a_t|S_t, A_{t-1}]$ および割引利得 $r(S, A) = \sum_t \gamma^t r(s_t, a_t)$ を用いることで実現できる [23]。

⁵ Bellman 方程式と同様に、一様ノルム $\|Q\|_{\infty} = \sup_{s, a} Q(s, a)$ に関して有界な Q 関数全体がなす Banach 空間において、ソフト Bellman 演算子 $T : Q(s, a) \mapsto r(s, a) + \gamma E_{s'} [\log \sum_a e^{Q(s', a)}] | s, a]$ も γ 縮小写像であり、Banach の不動点定理により任意の Q に対し $T^n Q$ は唯一存在する不動点 $Q_* = TQ_*$ へ指数的に収束する [23]。

といい、従来の強化学習に比べ様々な利点があることが知られ [24]、また価値関数ベースの学習と方策ベースの学習を統一するという点で理論的にも注目を集めている [25, 26]。報酬関数のスケールリング $r \rightarrow r/\alpha$ によりエントロピー正則化項の効果は α 倍でき、ゼロ温度 $\alpha \rightarrow 0$ で消去できる。このとき softmax は max に帰着し、漸化式 (7) は最適 Bellman 方程式に帰着する。方策も決定論的な最適方策 $\pi(a|s) = \delta(a - \arg \max_a Q(s, a))$ となり、従来の強化学習に帰着する。

4. 最大エントロピー逆強化ダイナミクス学習

本研究では、限られた知識のもとで方策 $\pi(A|S)$ とダイナミクス $p(S|A_{T-1})$ の両者に関して同時エントロピー $H[S, A] = H[A|S] + H[S|A_{T-1}]$ を最大化することで報酬とダイナミクスを同時推定するフレームワークを提案する。即ち、

$$\pi^*, p^* = \arg \max_{\pi, p \in \Delta} H[S, A] \quad \text{s.t.} \quad E_{\pi, p}[\phi(S, A)] = \langle \phi \rangle$$

を解く。紙面の都合上、導出の詳細は割愛する。ダイナミクスの推定では、現在の変数のみに依る“即時”特徴量 $\phi(s_t, a_t)$ のみならず、次の時刻の状態にも依る“遷移”特徴量 $\phi(s_t, a_t, s_{t+1})$ も用いる必要がある。軌跡の特徴量は両者の時間平均

$$\langle \phi(S, A) \rangle = \sum_t \left(\begin{array}{c} \phi(s_t, a_t) \\ \phi(s_t, a_t, s_{t+1}) \end{array} \right)$$

とし、それぞれに対する未定乗数を θ, λ とする。両者への分解は一意では無いが、結果は分解の仕方に依らない。

方策 $\pi(a|s)$ の解の形は (6) のままだが、ソフト Bellman 方程式にエントロピーボーナスが導入される：

$$Q(s, a) = r(s, a) + E_p[V(s')|s, a] + H[s'|s, a]$$

この表式は [8] の (6.21) と同じだが、報酬関数において“遷移”特徴量が期待値で見れる点が異なる：

$$r_{\theta, \lambda}(s, a) = \theta^T \phi(s, a) + \lambda^T E_{s'}[\phi(s, a, s')|s, a]$$

即ち、この定式化では報酬関数の特徴量はダイナミクスに応じて構成されることになる。ダイナミクスの解も同様の分布

$$p(s'|s, a) = \frac{e^{-E(s, a, s')}}{e^{-F(s, a)}}$$

を取る。ここで E および $F(s, a) = \log \sum_{s'} e^{-E(s, a, s')}$ はそれぞれ Q, V の対応物であり、ダイナミクス推定だけの [27] とは異なってエントロピーボーナス付きのソフト Bellman 方程式

$$E(s, a, s') = e_\lambda(s, a, s') + E_{a'}[F(s', a')|s'] + H[a'|s']$$

をみだす。ここで、報酬関数の対応物である $e_\lambda(s, a, s') \equiv \lambda^T \phi(s, a, s')$ は“即時”特徴量に依らず、“遷移”特徴量のみで定まる。エントロピーボーナス項は、お互いの関数を用いて

$$H[s'|s, a] = E_{s'}[E(s, a, s')|s, a] - F(s, a)$$

$$H[a'|s'] = -E_{a'}[Q(s', a')|s'] + V(s')$$

と書くことができる。

この定式化によって、方策とダイナミクスを同時に構成することができ、真のダイナミクスへアクセスせずに推定中のダイナミクスを用いて報酬を推定できる。ダイナミクスの推定が改善していくことで報酬の推定が改善し、報酬の推定が改善していくことでダイナミクスの推定が改善するという定式化となっており、別々に推定するよりも良い性能が期待される。

5. 今後の展望

このフレームワークに基づいてデモンストレーションの持つダイナミクスの情報を活用するアルゴリズムを構成し、最大エン

トロピー法に基づかないダイナミクス推定による既存手法 [20] と比較を行う。また、現実にはしばしばダイナミクスの推定モデルが手元にあるため、その事前知識を Bayes 的に取り入れてダイナミクスの推定モデルを更新する枠組みへの拡張を目指す。

参考文献

- [1] Dario Amodei, Chris Olah, Jacob Steinhardt, Paul F. Christiano, John Schulman, and Dan Mané. Concrete problems in AI safety, arxiv:1606.06565. 2016.
- [2] Stuart J. Russell. Learning agents for uncertain environments (extended abstract). In *COLT*, pages 101–103, 1998.
- [3] Rudolf Emil Kalman. When is a linear control system optimal? *Journal of Basic Engineering*, 86(1):51–60, 1964.
- [4] Andrew Y. Ng and Stuart J. Russell. Algorithms for inverse reinforcement learning. In *ICML*, pages 663–670, 2000.
- [5] Pieter Abbeel and Andrew Y. Ng. Apprenticeship learning via inverse reinforcement learning. In *ICML*, 2004.
- [6] Nathan D. Ratliff, J. Andrew Bagnell, and Martin Zinkevich. Maximum margin planning. In *ICML*, pages 729–736, 2006.
- [7] Brian D. Ziebart, Andrew L. Maas, J. Andrew Bagnell, and Anind K. Dey. Maximum entropy inverse reinforcement learning. In *AAAI*, pages 1433–1438, 2008.
- [8] Brian D Ziebart. *Modeling purposeful adaptive behavior with the principle of maximum causal entropy*. PhD thesis, 2010.
- [9] Brian D. Ziebart, J. Andrew Bagnell, and Anind K. Dey. Modeling interaction via the principle of maximum causal entropy. In *ICML*, pages 1255–1262, 2010.
- [10] Deepak Ramachandran and Eyal Amir. Bayesian inverse reinforcement learning. In *IJCAI*, pages 2586–2591, 2007.
- [11] Manuel Lopes, Francisco S. Melo, and Luis Montesano. Active learning for reward estimation in inverse reinforcement learning. In *ECML PKDD*, pages 31–46, 2009.
- [12] Edwin T Jaynes. Information theory and statistical mechanics. *Physical review*, 106(4):620, 1957.
- [13] Jaedeug Choi and Kee-Eung Kim. MAP inference for bayesian inverse reinforcement learning. In *NIPS*, pages 1989–1997, 2011.
- [14] Sergey Levine, Zoran Popovic, and Vladlen Koltun. Nonlinear inverse reinforcement learning with gaussian processes. In *NIPS*, pages 19–27, 2011.
- [15] Markus Wulfmeier, Peter Ondruska, and Ingmar Posner. Maximum entropy deep inverse reinforcement learning, arxiv:1507.04888. 2015.
- [16] Chelsea Finn, Sergey Levine, and Pieter Abbeel. Guided cost learning: Deep inverse optimal control via policy optimization. In *ICML*, pages 49–58, 2016.
- [17] Sergey Levine, Zoran Popovic, and Vladlen Koltun. Feature construction for inverse reinforcement learning. In *NIPS*, pages 1342–1350, 2010.
- [18] Abdeslam Boularias, Jens Kober, and Jan Peters. Relative entropy inverse reinforcement learning. In *AISTATS*, pages 182–189, 2011.
- [19] Krishnamurthy Dvijotham and Emanuel Todorov. Inverse optimal control with linearly-solvable mdps. In *ICML*, pages 335–342, 2010.
- [20] Michael Herman, Tobias Gindele, Jörg Wagner, Felix Schmitt, and Wolfram Burgard. Inverse reinforcement learning with simultaneous estimation of rewards and dynamics. In *AISTATS*, pages 102–110, 2016.
- [21] Peter D Grünwald, A Philip Dawid, et al. Game theory, maximum entropy, minimum discrepancy and robust bayesian decision theory. *the Annals of Statistics*, 32(4):1367–1433, 2004.
- [22] Jonathan Ho and Stefano Ermon. Generative adversarial imitation learning. In *NIPS*, pages 4565–4573, 2016.
- [23] Zhengyuan Zhou, Michael Bloem, and Nicholas Bambos. Infinite time horizon maximum causal entropy inverse reinforcement learning. *IEEE Trans. Automat. Contr.*, 63(9):2787–2802, 2018.
- [24] Tuomas Haarnoja, Haoran Tang, Pieter Abbeel, and Sergey Levine. Reinforcement learning with deep energy-based policies. In *ICML*, pages 1352–1361, 2017.
- [25] John Schulman, Pieter Abbeel, and Xi Chen. Equivalence between policy gradients and soft Q-learning, arxiv:1704.06440. 2017.
- [26] Ofir Nachum, Mohammad Norouzi, Kelvin Xu, and Dale Schuurmans. Bridging the gap between value and policy based reinforcement learning. In *NIPS*, pages 2772–2782, 2017.
- [27] Xiangli Chen and Brian D Ziebart. System identification via the principle of maximum causal entropy. *ICML Workshop on Machine Learning For System Identification*, 2013.

On/off-policy のハイブリッド深層強化学習とシミュレーション環境での制御問題への応用

On/off-policy Hybrid Deep Reinforcement Learning and Simulation in Control Tasks

王 伯楠^{*1} 河合 新^{*1} 延原 肇^{*1}
Bonan Wang Shin Kawai Hajime Nobuhara

^{*1}筑波大学大学院システム情報工学研究科知能機能システム専攻

Intelligent Interaction Technologies, Graduate School of Systems and Information Engineering, University of Tsukuba

Recently, deep reinforcement learning with neural network shows great performance in tasks such as game AI and robotics control tasks. However, on-policy and off-policy reinforcement learning methods proposed in related works have problems such as slow exploration speed. To solve these problems, we propose a hybrid deep reinforcement learning method which combines on-policy and off-policy reinforcement learning in this paper. The comparison experiment shows that the proposed method outperforms classic DDPG and DPPO method with an obvious advantage.

1. はじめに

近年、ニューラルネットワークを用いた深層強化学習は様々な分野で成果を出している [Lillicrap 15]。特にゲーム AI や Robotics コントロール問題では素晴らしい性能を示している [OpenAI 18b]。ニューラルネットワークは高い汎用性を持つ近似器として幅広い、かつ、複雑な問題に適用される。

強化学習アルゴリズムは主に on-policy と off-policy の二種類に分けられる。On-policy のアルゴリズムでは探索するエージェントと訓練するエージェントが同一である一方、off-policy のアルゴリズムではそれらは異なっている。On-policy のアルゴリズムは off-policy のアルゴリズムと比べて訓練が速く、安定性も高い。一方で、on-policy アルゴリズムは訓練が進むと、学習と探索の速度が遅くなる。Off-policy のアルゴリズムは過去の経験から学習するため、この問題を緩和できる。しかし off-policy のアルゴリズムは on-policy のアルゴリズムと比べて安定性が悪い。

本稿では、従来の on-policy と off-policy の深層強化学習の問題を解消するため、1) ハイブリッドなエージェントと 2) 訓練アルゴリズムを提案する。具体的には、1) ハイブリッドなエージェントとして、汎用性と効率的な学習のため、Actor-Critic 型エージェントを採用する。さらに、2) その訓練アルゴリズムとして、長期経験と短期経験の両方を活用するため、データを複数の短い時系列になるよう分割して、エージェントを学習させる。また、この時系列での訓練アルゴリズムに対応するために、ネットワークとして LSTM(Long Short-Term Memory) を用いる。提案手法では、目的関数に DDPG の価値関数と DPPO(Distribute Proximal Policy Optimization)[Schulman 17] の価値関数の両方を用いる。

本稿は次のように構成される。第 2 章では関連する従来研究を紹介する。第 3 章では提案手法を説明する。第 4 章では評価実験をその結果を示す。最後に第 5 章で結論を述べる。

2. 関連研究

この章では、主に関連研究の DDPG と DPPO アルゴリズムを説明する。

連絡先: 王 伯楠, 筑波大学大学院システム情報工学研究科知能機能システム専攻, wang@cmu.iit.tsukuba.ac.jp

2.1 DDPG(Deep Deterministic Policy Gradient)

DDPG アルゴリズム [Lillicrap 15] は典型的な off-policy の Actor-Critic アルゴリズムである。DDPG エージェントは行動を決めるネットワーク π と評価ネットワーク Q で構成されている。 π は状態の観測値 $s \in \mathbb{R}^m$ を入力とし、行動 $a \in \mathbb{R}^n$ あるいは行動の分布を出力する。 m, n はそれぞれ状態空間と行動空間の次元数である。 Q ネットワークは状態 s と対応する行動 a を評価し、評価値 $q \in \mathbb{R}$ を出力する。

訓練する時、まず Q を更新する。 Q を訓練した後、それを教師とし、 π を訓練する。 π は q を最大化するように θ^π を更新する。DDPG は Replay Buffer から経験データをランダムでサンプリングして訓練する。よって、DDPG アルゴリズムは自由に探索できるが、動作の変化が激しかったり、収束が遅かったりするなどの問題がある。

2.2 DPPO(Distribute Proximal Policy Optimization)

DPPO アルゴリズム [Schulman 17] は典型的な on-policy のアルゴリズムである。DPPO エージェントは行動ネットワーク π と価値ネットワーク V で構成されている。 π ネットワークは状態の観測値 s を入力とし、行動の確率分布 N^n を出力する。 V ネットワークは状態の観測値ベクトル s を入力とし、価値の予測値 $v \in \mathbb{R}$ を出力する。

DPPO アルゴリズムは最近の経験データしか使えない。よって、DPPO アルゴリズムは常に新しいデータが必要である。DPPO アルゴリズムは学習がはやく、かつ安定性も高い。しかし、DPPO は訓練が進むと探索が遅くなる。

3. 提案手法

3.1 ネットワーク構造

従来法の問題を解消するため、本論文は短期経験と長期経験の両方を活用した on/off-policy のハイブリッドエージェントと強化学習アルゴリズムを提案する。提案手法では Actor-Critic 型エージェントを採用する。短期と長期経験の特徴に対応して、行動策略部分の Actor は LSTM ネットワークを採用する。 π は一連の状態の観測値 $s_t, s_{t-1}, \dots, s_{t-K+1}$ 、LSTM 初期細胞状態 c_{init} と初期出力 h_{init} を入力とし、行動の確率分布を出力する。ただし $t \in \{1, 2, \dots, T\}$ は時刻あるいはステップ

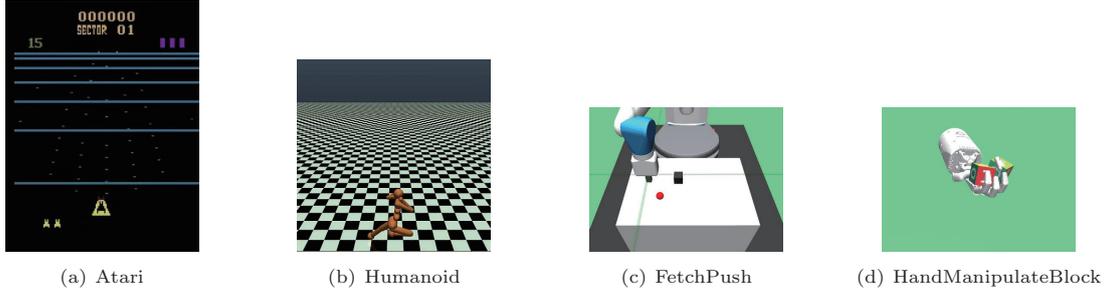
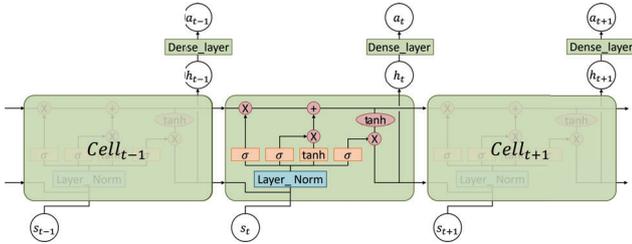


図 1: Environments Example

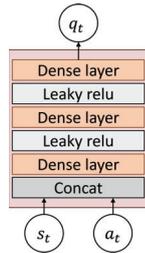
数を表し、下添え字 t はステップ t における値を表すこととする。また、 T は最後のステップを表す。 $k \in \{1, 2, \dots, K\}$ は LSTM セルの順番数を表し、 K は LSTM のセル数を表す。

$$\pi_t(s_t, s_{t-1}, \dots, s_{t-K+1}, c_{init}, h_{init}) \sim N^n. \quad (1)$$

LSTM の各ゲートの活性化関数の前に Layer Normalization を用いる。各セルの出力に全結合層をつけて最後の出力にする。

図 2: π ネットワーク構造

価値関数部分の Critic ネットワークは MLP を採用し、 Q とする。DDPG の Critic ネットワークと同じく s と a を入力とし、価値の予測値を出力する。負数の報酬値に対応するため、活性化関数は Leaky Relu を用いる。

図 3: Q ネットワーク構造

安定性のため、ネットワークは main ネットワークと target ネットワークで構成されている。main ネットワークは学習によって更新され、target ネットワークは main ネットワークのパラメーターを用いて更新される。

3.2 目的関数

長期経験と短期経験の両方を活用するため、それぞれ Q と π の目的関数を設計した。短期経験を使う on-policy 的な目的関数は $L^{vf}(\theta^Q)$ と $L^{pg}(\theta^\pi)$ があり、長期経験を使う off-policy 的な目的関数は $L^Q(\theta^Q)$ と $L^\pi(\theta^\pi)$ がある。ただし、 θ^π, θ^Q はそれぞれのネットワークの重みなどのパラメーターを表している。アルゴリズムはこの 4 つの目的関数を最適化する。

on-policy の価値目的関数 $L^{vf}(\theta^Q)$:

$$L^{vf}(\theta^Q) = \mathbb{E}(Q(s_t, a_t) - Q'_t)^2 \quad (2)$$

$$\text{where} \quad (3)$$

$$Q'_t = \sum_{i=t}^T (\gamma^{i-t} r_i) + Q(s_{T+1}, \pi(s_{T+1})). \quad (4)$$

on-policy の行動目的関数 $L^{pg}(\theta^\pi)$:

$$L^{pg}(\theta^\pi) = \mathbb{E} \left(\frac{\pi(a_t | s_t)}{\pi'(a_t | s_t)} * \hat{A}_t \right), \quad (5)$$

$$\hat{A}_t = \delta_t + \gamma \lambda \delta_{t+1} + \dots + (\gamma \lambda)^{T-t} \delta_T, \quad (6)$$

$$\delta_t = r_t + \gamma * Q_{t+1} - Q_t. \quad (7)$$

ただし、 π' は target ネットワークの π を表す。off-policy の価値目的関数 $L^Q(\theta^Q)$:

$$L^Q(\theta^Q) = \mathbb{E}(Q(s_t, a_t) - c_1 * Q'_1 - c_2 * Q'_2)^2, \quad (8)$$

$$Q'_1 = r_t + \gamma * Q(s_{t+1}, \pi(s_{t+1})), \quad (9)$$

$$Q'_2 = r_k + \gamma * r_{k+1} + \dots + \gamma^{K-k} * r_K + \quad (10)$$

$$\gamma^{K-k+1} * Q(s_{K+1}, \pi(s_{K+1})). \quad (11)$$

ただし、 c_1 と c_2 は重み引数である。

off-policy の行動目的関数 $L^\pi(\theta^\pi)$:

$$L^\pi(\theta^\pi) = \mathbb{E}(Q(s_t, \pi(s_t))). \quad (12)$$

$L^Q(\theta^Q)$ と $L^{vf}(\theta^Q)$ を最小化し、 $L^\pi(\theta^\pi)$ と $L^{pg}(\theta^\pi)$ を最大化する。

3.3 訓練アルゴリズム

訓練する時、先ず複数のエージェントを使って探索し、データを収集する。各エージェントは環境の中で一定のステップ数 T を実行し、これを一つの iteration とする。収集したデータ $(s_t, a_t, r_t, s_{t+1}, c_t, h_t)$ を Replay Buffer \mathcal{M} に保存する。探索が効率よく進むため、各エージェントは探索の途中、小さい確率 ϵ でランダムな行動を取る。 ϵ はエージェントによって違う。安定のため、target ネットワークを用いて探索を進め、main ネットワークを更新する。

4. 評価実験

4.1 実験条件

評価実験は深層強化学習においてベンチマーク的なタスク Humanoid タスクを用いる。Humanoid タスクの目的はシミュ

Algorithm 1 on/off-policy algorithm

```

1: initialize Replay Buffer  $\mathcal{M}$ ;
2: initialize Network  $\pi_{main}, \pi_{target}, Q_{main}, Q_{target}$ ;
3: for  $i$  in  $Max\_Iterations$  do
4:   for  $w$  in  $N\_Workers$  do
5:     reset Iteration Buffer  $\mathcal{I}$ ;
6:     for  $t$  in  $T$  do
7:        $a_t, c_t, h_t \leftarrow \pi_{target}(s_t)$ ;
8:        $a_t \leftarrow \text{Random Action with } \epsilon$ ;
9:        $s_{t+1}, r_t \leftarrow \text{Environment}(a_t)$ ;
10:      store  $(s_t, a_t, r_t, s_{t+1}, c_t, h_t)$  in  $\mathcal{I}$ ;
11:    end for
12:    store  $\mathcal{I}$  in  $\mathcal{M}$ ;
13:    update  $\theta_{main}^Q$  with  $L^{vf}(\theta^Q)$ ;
14:    update  $\theta_{main}^\pi$  with  $L^{pg}(\theta^\pi)$ ;
15:     $\theta_{target}^Q \leftarrow (1 - \tau) * \theta_{target}^Q + \tau * \theta_{main}^Q$ ;
16:     $\theta_{target}^\pi \leftarrow (1 - \tau) * \theta_{target}^\pi + \tau * \theta_{main}^\pi$ ;
17:  end for
18:  sample random transition  $Batch$ ;
19:  update  $\theta_{main}^Q$  with  $L^Q(\theta^Q)$ ;
20:  update  $\theta_{main}^\pi$  with  $L^\pi(\theta^\pi)$ ;
21:   $\theta_{target}^Q \leftarrow (1 - \tau) * \theta_{target}^Q + \tau * \theta_{main}^Q$ ;
22:   $\theta_{target}^\pi \leftarrow (1 - \tau) * \theta_{target}^\pi + \tau * \theta_{main}^\pi$ ;
23: end for

```

レーション環境の中の人間を前進することを学習させることである。エージェントは人間の各関節の動作を決める。

表 1: 実験条件

Deep Learning Library	Tensorflow 1.9.0
Simulation Library	openAI gym
Env	Humanoid-v2

訓練する時、Worker ごとに on-policy の目的関数を用いてエージェントを更新する、五つの Worker ごとに off-policy の目的関数を用いてエージェントを更新する。

表 2: Hyper Parameters

T	1024
N_Worker	5
π learning rate	0.00004-0.000001
Q learning rate	0.00008-0.000002
batch_size	32
epoch	5
sample_size	640
τ	0.2

4.2 実験結果

本研究はベンチマークタスク Humanoid 環境を用いて、従来の DDPG、DPPO と提案手法に対して比較実験を行いました。実験の結果は図 4 に示す。DDPG アルゴリズムはランダムな短い経験だけ用いるため、長い時系列の中の行動の関連性を無視している。よって、エージェントは最初から行動が固定し、前に進まない。DPPO アルゴリズムは学習ができるが、学習の速度が遅い。

提案手法では、安定かつ高速な学習を実現している。提案手法の on-policy 部分は安定な学習を実現し、off-policy 部分はその上探索を進ませ、学習を加速させたと思われる。

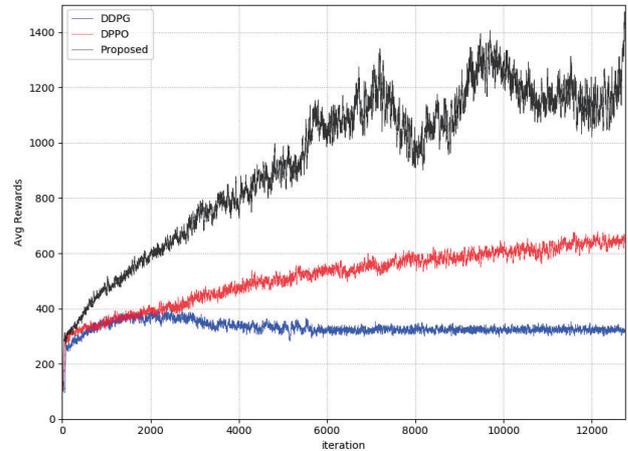


図 4: Performance Comparison of DDPG, DPPO and Proposed Method on benchmark task Humanoid

5. おわりに

本研究は従来の深層強化学習アルゴリズムの問題点を解決するため、短期経験と長期経験の両方を活用する on/off-policy のハイブリッド深層強化学習アルゴリズムを提案した。Humanoid タスクにおいて、提案手法は従来手法より優れた性能を示した。

Humanoid タスクのような、状態空間と行動空間は連続で、報酬値も丁寧に設計されているタスクに対して、提案手法は有効であると思われる。しかし現実の問題において、報酬値は二進値のタスクは多数存在している。エージェントの汎用性を向上させるため、これからは HER[Andrychowicz 17] 手法の投入と Robotics タスク [OpenAI 18a] への実装を検討している。

参考文献

- [Andrychowicz 17] Andrychowicz, M., Wolski, F., Ray, A., Schneider, J., Fong, R., Welinder, P., McGrew, B., Tobin, J., Abbeel, P., and Zaremba, W.: Hindsight Experience Replay, *CoRR*, Vol. abs/1707.01495, (2017)
- [Lillicrap 15] Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., and Wierstra, D.: Continuous control with deep reinforcement learning, *CoRR*, Vol. abs/1509.02971, (2015)
- [OpenAI 18a] OpenAI, : Ingredients for Robotics Research (2018)
- [OpenAI 18b] OpenAI, : Learning Dexterous In-Hand Manipulation, *CoRR*, Vol. abs/1808.00177, (2018)
- [Schulman 17] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O.: Proximal Policy Optimization Algorithms, *CoRR*, Vol. abs/1707.06347, (2017)

[1Q3-J-2] Machine learning: structural modeling

Chair:Koh Takeuchi Reviewer:Akisato Kimura

Tue. Jun 4, 2019 3:20 PM - 5:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[1Q3-J-2-01] L1 Regularization based Learning Method for Capsule Network

○Nozomu Ohta¹, Shin Kawai¹, Hajime Nobuhara¹ (1. University of Tsukuba)

3:20 PM - 3:40 PM

[1Q3-J-2-02] Construction of pooling layer by skip connection and analysis based on expressive power of these models

○Jumpei Nagase¹, Tetsuya Ishiwata² (1. Graduate School of Engineering and Science, Shibaura Institute of Technology, 2. College of Systems Engineering and Science, Shibaura Institute of Technology)

3:40 PM - 4:00 PM

[1Q3-J-2-03] Extracting and Exploiting Latent Knowledge Structure by Graph-based Knowledge Tracing

○Hiromi Nakagawa¹, Yusuke Iwasawa¹, Yutaka Matsuo¹ (1. The University of Tokyo)

4:00 PM - 4:20 PM

[1Q3-J-2-04] Learning to Find Hard Instances of Graph Problems

○Ryoma Sato¹, Makoto Yamada^{1,2,3}, Hisashi Kashima^{1,2} (1. Kyoto University, 2. RIKEN Center for AIP, 3. JST PRESTO)

4:20 PM - 4:40 PM

[1Q3-J-2-05] A study on recommender system considering diversity in recommendation items based on LDA

○Zhiying Zhang¹, Taiju Hosaka¹, Haruka Yamashita², Masayuki Goto¹ (1. Waseda University, 2. Sophia University)

4:40 PM - 5:00 PM

L1 正則化を用いた Capsule Network の学習法の一提案

L1 Regularization based Learning Method for Capsule Network

太田 望*¹ 河合 新*¹ 延原 肇*¹
 Nozomu Ohta Shin Kawai Hajime Nobuhara

*¹筑波大学大学院システム情報工学研究科知能機能システム専攻

Intelligent Interaction Technologies, Graduate School of Systems and Information Engineering, University of Tsukuba

Capsule Network is a new neural network proposed to overcome the shortcomings of CNN. However, the Capsule Network has many learnable parameters and is prone to over-fitting. In this research, we aim to improve generalization ability by reducing parameters using L1 regularization. We evaluate our method by comparing the accuracy and the reconstructed image with the conventional method.

1. はじめに

畳み込みニューラルネットワーク (Convolutional Neural Network, 以下 CNN) は画像認識の分野で一般的な手法として認識されている。このネットワークでは、特徴検出を行う畳み込み層とシフト不変性のためのプーリング層を繰り返す構造によって線の傾き、太さや色などの低レベルの特徴から、顔画像などにおける目や口などの高レベルの特徴を認識している。CNN の問題点として、プーリング層が抽出した特徴間の位相構造を保存しないため、同じオブジェクトであっても姿勢が異なると全く異なる内部表現になり、大規模なデータ拡張と非常に深いネットワークが必要になることが挙げられる。

本研究では、この CNN の問題を解決するために、Google Brain のチームによって提案されている Capsule Network (以下 CapsNet) に着目する。[Hinton 11, Sabour 17]。通常の CNN の各層は、特徴の存在確率をスカラーとして出力するのに対し、CapsNet はオブジェクトの存在と特徴をベクトルとして表現する。下位のカプセルはオブジェクトの一部の特徴をベクトルとして保持し、複数の下位カプセルからオブジェクト全体の特徴と存在を表現する上位カプセルを計算する。

CapsNet に関して拡張の余地がある点としては、CNN はプーリング層によってパラメータが減るのに対し CapsNet はパラメータが増えるため、ネットワークの大規模化が難しく過学習に陥りやすいことが挙げられる。特に大きな画像を入力した場合や分類クラスを増やした場合、カプセルが増加し学習が困難になる。本論文では CapsNet のパラメータを L1 正則化によって縮小した後、閾値以下の値を 0 とすることでスパース化をはかり、より単純で過学習に強いモデルを学習することを目指す。

提案手法と元の CapsNet を MNIST、fashion MNIST、SVHN データセットを用いて学習させ、テストデータの正答率を比較することで評価を行う。

2. CapsNet

CapsNet は入力を画像とし、分類クラスの確率ベクトルと再構成画像を出力する。CapsNet の概要図を図 1 に示す。

CapsNet の計算手順を以下に示す。

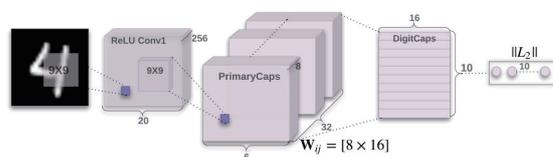


図 1: CapsNet の概要図

1. 入力画像を 2 層の畳み込み層によって 256 チャンネル、 6×6 の特徴マップへ変換する。図 1 の入力画像と Conv1 間、Conv1 と PrimaryCaps 間の変換に相当する。
2. 特徴マップを画素ごと、256 チャンネルを 8 チャンネルごとに分割する。すなわち $6 \times 6 \times 32$ 個の 8 次元ベクトルができる。 i 番目のベクトルを下位カプセル \mathbf{u}_i と定義する。図 1 の PrimaryCaps に相当する。
3. \mathbf{u}_i と重み行列 $W_{ij} \in R^{8 \times 16}$ の積を $\hat{\mathbf{u}}_{j|i}$ とする。この W_{ij} は誤差逆伝播法により学習される。

$$\hat{\mathbf{u}}_{j|i} = W_{ij} \mathbf{u}_i \quad (1)$$

4. $\hat{\mathbf{u}}_{j|i}$ と $c_{ij} \in R$ の重み付き和を計算する。 c_{ij} は後述する Dynamic Routing によって計算する。

$$\mathbf{s}_j = \sum_i c_{ij} \hat{\mathbf{u}}_{j|i} \quad (2)$$

5. 以下の squash 関数によって上位カプセル $\mathbf{v}_j = \text{squash}(\mathbf{s}_j)$ を計算する。squash 関数はベクトルの向きを保持したままノルムを $[0, 1]$ の範囲に変換する活性化関数である。上位カプセルは図 1 の DigitCaps に対応する。

$$\text{squash}(\mathbf{s}) = \frac{\|\mathbf{s}\|^2 \mathbf{s}}{1 + \|\mathbf{s}\|^2 \|\mathbf{s}\|} \quad (3)$$

6. 3-5 の手順を繰り返し 16 次元の上位カプセルを 10 個構成する。

Dynamic Routing のアルゴリズムを Algorithm 1 に示す。 r はルーティング回数、 l はレイヤー数を表す。先行研究 [Sabour 17] では $r = 3$, $l = 1$ で固定している。Dynamic

連絡先: 太田望, 筑波大学大学院システム情報工学研究科知能機能システム専攻, ohta@cmu.iit.tsukuba.ac.jp

Routing によって下位カプセルから一度上位カプセルを計算し、計算された上位カプセルに似た下位カプセルを内積によって抽出し、抽出された下位カプセルを使用してサイド上位カプセルを計算する。このように、EM アルゴリズムのように上位カプセルの推定と下位カプセルの選択を同時に行う。上位カプセルは分類対象の各クラスに対応し、画像の分類と再構成に使われる。全体の損失関数は以下に説明する分類誤差と再構成誤差の和である。

各上位カプセルのノルムを対応するオブジェクトの存在確率とする。分類の損失関数に以下の margin loss 関数を使用する。

$$L_{class} = \sum_k (T_k \max(0, m^+ - \|\mathbf{v}_k\|)^2 + \lambda(1 - T_k) \max(0, \|\mathbf{v}_k\| - m^-)^2) \quad (4)$$

k は分類クラス番号であり、 T_k は真のクラスの場合 1、それ以外の場合は 0 をとる。 m^+ は真のクラスの誤差に対する閾値、 m^- は誤ったクラスの誤差に対する閾値である。先行研究 [Sabour 17] では $m^+ = 0.9$ と $m^- = 0.1$ と $\lambda = 0.5$ である。

各上位カプセルに対し全結合層を 3 層結合し入力画像を再構成する。先行研究 [Sabour 17] はカプセルの要素は対応するオブジェクトがどのような姿勢やスケールであるかを表現していると主張している。その根拠としてカプセルの各要素を少しずつ増減させた場合に再構成されたオブジェクトの変化が要素ごとに異なることを示している。

3. L1 正則化に基づく CapsNet 学習法の提案

CapsNet では下位カプセルと 重み行列 W_{ij} の積によって上位カプセルが計算されるが、下位カプセルの全特徴が上位カプセルの全特徴の予測の役に立つわけではない。顔の識別の例で考えると、目の傾きの情報は顔の大きさとは無関係である。したがって W_{ij} の要素の大半は 0 であると考えられる。そこで先行研究 [Han 15] を参考に重み行列 W_{ij} のスパース化を図る。

CapsNet を通常の方法で 50epoch 学習した後、L1 正則化を使って 50epoch 学習する。L1 正則化とは誤差関数にパラメータの絶対値の総和に係数をかけたものである正則化項を加えることでパラメータの値を縮小する手法である。最初から L1 正則化項を誤差関数に加えた場合、係数をどれだけ小さくしても正則化項が大きくなり、学習がうまく進まなかった。設定された閾値以下の重み行列 W_{ij} のパラメータの値を 0 とする。閾値は今回は 10^{-4} とした。

従来手法である CapsNet に対して通常のテストデータと微小変形したテストデータの分類精度によって提案手法を評価する。また、 W のパラメータのうち、何%が 0 になったのか、再構成された画像が妥当なものかを評価する。

4. 実験

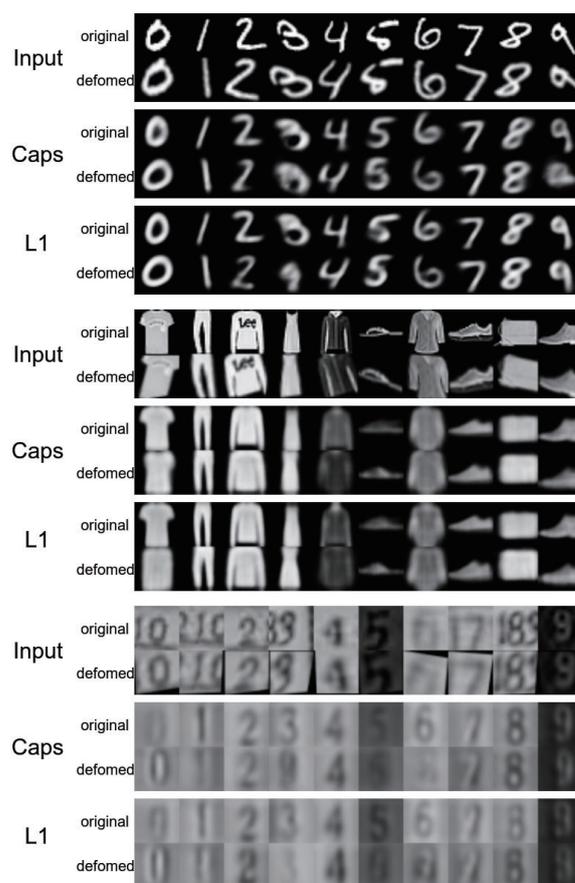


図 2: MNIST の再構成画像

参考文献 [Nair 18] に従い、MNIST、fashion MNIST、SVHN データセットとその微小変形したデータを使用して提案手法の評価を行う。MNIST は 0 から 9 の手書き数字 28×28 白黒画像のデータセットであり画像認識の評価に使用される。fashion MNIST は洋服や靴などの 10 クラスの 28×28 白黒画像のデータセットである。SVHN は google street view に写った家の表札の数字を切り抜いた 32×32 の画像データセットである。それぞれの学習データのうち 15% をバリデーションデータとして使用した。

データの微小変形は以下の手順で行う。

1. 画像を 1.2 倍に拡大
2. 画像中心を回転中心として $[-20, 20]$ 度から一様ランダムに回転
3. x 軸、 y 軸方向に $[-0.2, 0.2]$ の範囲でせん断変形

実装には Python3 と Keras を使用し、計算には Geforce GTX 1080 Ti を使用した。最適化アルゴリズムは Adam を使用した。L1 正則化はモデル中の全てのパラメータに対して適用した。

表 1 に実験結果を示す。ここで、Deformed は、テストデータに微小変形を加えた場合、Original は微小変化を加えていない場合を表す。いずれのデータセットでも微小変形の有無にかかわらず提案手法によって正答率が改善されていることが

Algorithm 1 Routing algorithm

```

procedure ROUTING( $\hat{\mathbf{u}}_{j|i}, r, l$ )
  for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l+1)$ :  $b_{ij} \leftarrow 0$ 
  for  $r$  iterations do
    for all capsule  $i$  in layer  $l$ :  $\mathbf{c}_i \leftarrow \text{softmax}(\mathbf{b}_i)$ 
    for all capsule  $j$  in layer  $(l+1)$ :  $\mathbf{s}_j \leftarrow c_{ij} \hat{\mathbf{u}}_{j|i}$ 
    for all capsule  $i$  in layer  $(l+1)$ :  $\mathbf{v}_j \leftarrow \text{squash}(\mathbf{s}_j)$ 
    for all capsule  $i$  in layer  $l$  and capsule  $j$  in layer  $(l+1)$ :  $b_{ij} \leftarrow b_{ij} + \hat{\mathbf{u}}_{j|i} \cdot \mathbf{v}_j$ 
  end for
  return  $\mathbf{v}_j$ 
end procedure

```

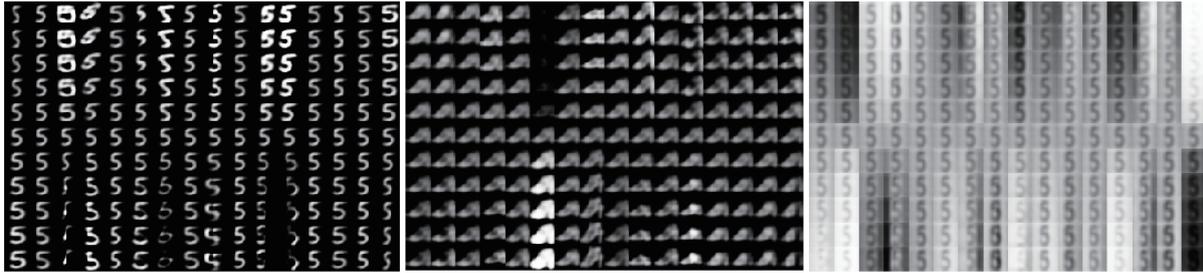


図 3: カプセルの 16 次元の要素の変化させた結果: MNIST (左)、fashion MNIST (中央)、SVHN (右)

表 1: 従来手法 (CapsNet) と提案手法 (L1) の正答率の比較

Dataset Network	Original		Deformed	
	CapsNet	L1	CapsNet	L1
MNIST	99.13	99.30	91.37	93.10
fashion MNIST	88.29	90.49	61.57	62.27
SVHN	91.91	93.29	70.86	74.17

表 2: パラメータのスパース性

	Sparsity[%]
MNIST	68.57
fashion MNIST	62.90
SVHN	68.01

ら、提案手法の有効性が確認できる。 W のパラメータのうち 0 になったものの割合を表 2 に示す。どのデータセットでも 6 割以上のパラメータが 0 になっており、先行研究 [Han 15] と同様にネットワークのスパース化に成功している。また、各データセット、各クラスの入力画像と再構成画像を図 2 に示す。MNIST データセットでは従来手法、提案手法によらず、変形されたデータに対応して再構成された画像が変化していることが確認できる。提案手法の方が再構成画像が少し明確になっている。他のデータセットでは従来手法と提案手法の違いは見られない。図 3 はカプセルの 16 次元の要素のうち、一つを選んで変動させ、他の 15 個を 0 に固定した場合の再構成画像である。ここで横軸がカプセルの次元、縦軸は変動量を表す。MNIST データセットでは選んだ要素によって数字の位置や形、大きさなどが変化している様子が確認できる。SVHN データセットでは数字の変化より背景の変化に大きく影響されていることがわかる。

5. おわりに

従来手法に比べ提案手法ではテストデータの微小変形の有無に関わらず精度が向上した。これは提案手法によって過学習が抑えられ、CapsNet の汎化性能が向上したためだと考えられる。今後の課題としては、テストデータをオブジェクトを様々な角度から撮影したものに代えて CapsNet がオブジェクトの姿勢の変化に対応する能力をテストすること、他のスパース化手法を試すことなどが挙げられる。

参考文献

- [Han 15] Han, S., Pool, J., Tran, J., and Dally, W.: Learning both Weights and Connections for Efficient Neural Network, in Cortes, C., Lawrence, N. D., Lee, D. D., Sugiyama, M., and Garnett, R. eds., *Advances in Neural Information Processing Systems 28*, pp. 1135–1143, Curran Associates, Inc. (2015)
- [Hinton 11] Hinton, G. E., Krizhevsky, A., and Wang, S. D.: Transforming Auto-Encoders, in Honkela, T., Duch, W., Girolami, M., and Kaski, S. eds., *Artificial Neural Networks and Machine Learning – ICANN 2011*, pp. 44–51, Berlin, Heidelberg (2011), Springer Berlin Heidelberg
- [Nair 18] Nair, , Prem, , Doshi, R., and Keselj, S.: Pushing the limits of capsule networks (2018), Technical note
- [Sabour 17] Sabour, S., Frosst, N., and Hinton, G. E.: Dynamic Routing Between Capsules, 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. 3856–3866, Curran Associates, Inc. (2017)

スキップ接続によるプーリング層の構成および表現力に基づくそれらのモデルの解析

Construction of pooling layer by skip connection and analysis based on expressive power of these models

長瀬 准平 *1 石渡 哲哉 *2
Jumpei Nagase Tetsuya Ishiwata

*1 芝浦工業大学大学院 理工学研究科
Graduate School of Engineering and Science, Shibaura Institute of Technology

*2 芝浦工業大学 システム理工学部
College of Systems Engineering and Science, Shibaura Institute of Technology

In this research, we consider structures such as pooling layer and skip connection from the viewpoint of expressive power in order to organize design of neural networks models. We showed that widely used these structures can be understood as a composition of affine functions and concatenated activation functions. Moreover, we show the followings: (i) the pooling layer explicitly decreases expressive power, (ii) there is no deference in expressive power between addition and concatenation as skip connection for fully connected neural networks, and (iii) the single activation block has superior expressive power compared to the multiple activation block. These results propose one guideline for design of neural networks models.

1. はじめに

深層学習で用いられるニューラルネットワークモデルの設計は、いくつかのレイヤー（ベクトル関数）を階層的に積み上げることで行われる。ここで、「どのようにレイヤーを積み上げるか」「どのようなレイヤーを積み上げるか」が重要な研究課題である。画像認識の分野では、畳み込み層とプーリング層を積み重ねた畳み込みニューラルネットワーク（Convolution Neural Networks; CNN）と呼ばれるモデルを用いて画像の特徴を効果的に抽出できるとされており、2012年頃から活発に研究が行われている。モデルの構造に関する近年の大きな成果の一つとしてはスキップ接続が挙げられる。スキップ接続はILSVRC2015の優勝モデルであるResNet[?]で用いられたことで注目され、それ以降提案されているモデルの多くにスキップ接続の構造が用いられている。一方で、これらの提案モデルの多くは経験則によるものであり、モデル設計に関する体系的な理論が存在しないことが問題である。

本研究では、ニューラルネットワークモデルの設計を体系化することを目的として、表現力の観点からプーリング層やスキップ接続などの構造について考察する。結果として、広く用いられているこれらの構造は単純なニューラルネットワークモデルに結合のスキップ接続を導入することで構成できることを数学的に示した。表現力に関する解析としては、プーリング層は陽に表現力を低下させること、加算と結合のスキップ接続は全結合ニューラルネットワークにおいて表現力に差異を与えないこと、そして、現在有効とされているsingle activationブロック構造が、multi activationブロック構造と比較して表現力の意味で優位性を持つことが示された。以上の結果より、表現力の観点からモデル設計における一つの指針を与えることができる。

2. ニューラルネットワークモデル

ニューラルネットワークモデルはレイヤーと呼ばれる関数を繰り返し合成することにより設計される。**多層パーセプトロン**

連絡先: 長瀬准平, 芝浦工業大学大学院理工学研究科, mf18061@shibaura-it.ac.jp

ンは**全結合層**と**活性化層**が繰り返し合成されているモデルであり、最も単純なニューラルネットワークモデルの一つとして知られている。画像認識の分野で用いられている**畳み込みニューラルネットワーク**は、特徴的な構造として**畳み込み層**と**プーリング層**をもつ。また、近年では**スキップ接続**と呼ばれる複数のレイヤーをまたぐ接続が導入されることが多く、優れた性能を与えることが知られている。スキップ接続と同様の構造は、入力を複数のレイヤーへ分岐させる場合や、複数の出力を併合させて用いる場合にも扱うことがある。

2.1 多層パーセプトロン

多層パーセプトロンは1970年代頃に神経回路網の数理モデルとして提案されたものが起源となり、現代の深層学習で用いられているニューラルネットワークモデルの基本となっている。その特徴として、全結合層と活性化層と呼ばれる関数の合成で表されることが挙げられる。

定義 1 (L 層多層パーセプトロン) L 層多層パーセプトロンMLPは全結合層 $w_i: \mathbb{R}^{d_i} \rightarrow \mathbb{R}^{d_{i+1}}$ と活性化層 $f: \mathbb{R}^{d_i} \rightarrow \mathbb{R}^{d_i}$ の合成によって定義される。

$$\text{MLP}_L(f) = w_L \circ f \circ w_{L-1} \circ \dots \circ f \circ w_0.$$

特に、本稿では活性化層としてReLU関数を用いている多層パーセプトロンを**ReLUパーセプトロン**と呼ぶことにする。ReLU関数などについての詳細は以下で述べる。

2.1.1 全結合層

全結合層は入力 \mathbf{x} に対して重み行列 W とバイアスベクトル \mathbf{b} を用いて出力 $y = W\mathbf{x} + \mathbf{b}$ を返すレイヤーである。入力の成分 x_i と出力の成分 y_j が全て重み付けられて結合していることから全結合層や重み層と呼ばれる。あるいは、結合が密であることからDense Layer、重み層による変換が数学的にはAffine関数として理解されることからAffine Layerなどとも呼ばれる。本稿では、しばしば重み層とAffine関数を同一視して説明する。ニューラルネットワークモデルの学習では、重み層がもつパラメータが最適値に近づくように更新することが目的となる。

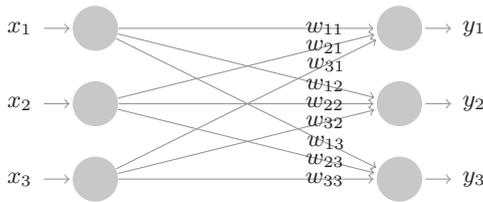


図 1: 全結合層の模式図. 入力 x_i と出力 y_j がパラメータ w_{ij} によって重み付けており, それぞれの出力は入力の線形結合によって表される.

2.1.2 活性化層

活性化層は入力 \mathbf{x} に対して非線形変換を行うレイヤーである. 神経素子のモデルとして神経の発火現象を模倣するために導入されたことから活性化層と呼ばれる. 本稿では成分ごとに同じ変換を行うもの, すなわち出力を $\mathbf{y} = (y_1, \dots, y_d)^T$ として

$$\mathbf{y} = (y_1, \dots, y_d)^T = (f(x_1), \dots, f(x_d))^T =: \mathbf{f}(\mathbf{x})$$

のような変換を行うレイヤーを活性化層として扱い, f を用いた活性化層 f などと呼ぶことにする^{*1}. 活性化層で用いられる変換の例として次のものが挙げられる.

- ReLU

$$\text{ReLU}(x) = \max(x, 0)$$

- シグモイド^{*}

$$\sigma(x) = (1 + e^{-x})^{-1}$$



図 2: 活性化層の模式図. 入力の各成分が $f: \mathbb{R} \rightarrow \mathbb{R}$ によって変換される.

2.2 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは主に画像認識の分野で発展したモデルであり, 畳み込み層と呼ばれる局所的な特徴抽出のための重み層と, 特徴量の圧縮のためのプーリング層が用いられることが特徴である. そのモデルの多くは活性化層や全結合層も併用して設計される.

2.2.1 畳み込み層

畳み込み層は入力 \mathbf{x} に対してフィルター処理と呼ばれる操作によって出力 \mathbf{y} を得るレイヤーである. 畳み込み層は学習可能なフィルター処理として考えることができる. 実用上は, RGB 画像などの多チャンネルデータに対して異なるフィルターを多数用いて特徴抽出を行うため, 入力として多次元配列が考えられることが多いが, 本研究では単純な 1 チャンネルの 2 次元画像データを想定して解析を行なっている^{*2}.

^{*1} 成分ごとに異なる変換を行うソフトマックス層などのレイヤーも存在するが, 出力層としてのみ用いられることが多いために本研究では扱わない.

^{*2} 本研究の結果は多チャンネルの場合にも単純に拡張できる.

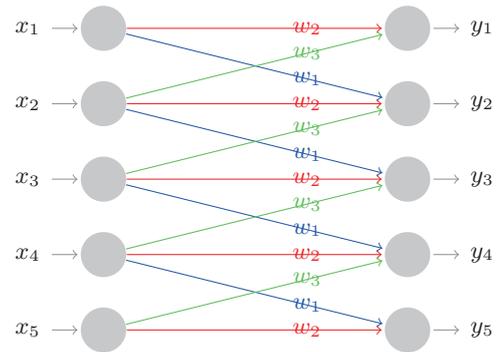


図 3: サイズ 3, 移動幅 1 の 1 次元畳み込み層の模式図. 同一の重み w_1, w_2, w_3 のみを用いてスパースな線形結合が行われる.

2.2.2 プーリング層

プーリング層は畳み込み層の後に用いられることが多く, 入力 (特に画像データ) を圧縮するための変換をもつ. 本稿では入力データのサイズを $1/n$ に圧縮するプーリング層をサイズ n のプーリング層と呼ぶことにする. 平均値を取る平均値プーリングと, 最大値を取る最大値プーリングが一般に用いられている.

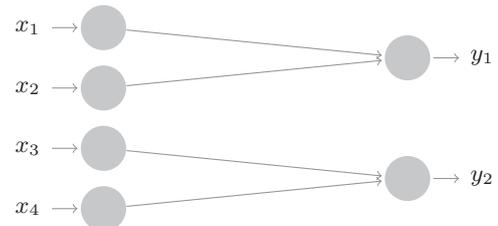


図 4: サイズ 2 の 1 次元プーリング層の模式図. $(x_1, x_2), (x_3, x_4)$ をそれぞれ圧縮したものが y_1, y_2 として出力される.

2.3 スキップ接続

スキップ接続はある層をまたぐ接続として導入される. 広く用いられているスキップ接続は加算と結合の二種類であり, スキップ接続によりバイパスされるいくつかの層をまとめてブロックと呼ぶ. ブロックの変換を $B(\mathbf{x})$ と表すと, 加算と結合のスキップ接続はそれぞれ次のように定義される.

- 加算

$$\mathbf{y} = B(\mathbf{x}) + \mathbf{x}$$

- 結合

$$\mathbf{y} = \begin{pmatrix} B(\mathbf{x}) \\ \mathbf{x} \end{pmatrix}$$

ただし, $(,)$ はベクトルの結合を表す.

その他の接続に関しては, 各成分ごとの差, 積, 最大値, 平均値を取るものや, 入力 \mathbf{x} に線形変換などを施してから接続するものなどがある. また, 二種類の層 L_1 と L_2 への分岐や併合としても加算や結合を考えることができ,

$$L_1(\mathbf{x}) + L_2(\mathbf{x})$$

のような層の併合もスキップ接続と同様に自然に導入される.

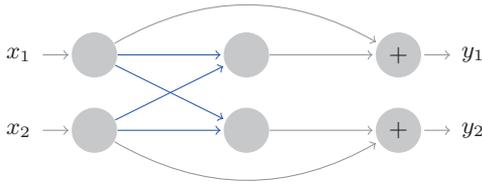


図 5: 加算のスキップ接続の模式図. 青色の変換はバイパスされるレイヤーやブロックを表している.

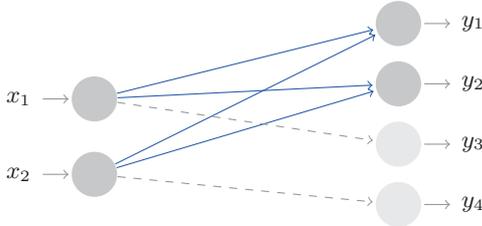


図 6: 結合のスキップ接続の模式図. 青色の変換はバイパスされるレイヤーやブロックを表している.

3. 本論

重み層 (Affine 関数) と活性化層の合成により単純なニューラルネットワークモデルである多層パーセプトロンが設計される. 本研究では, 多層パーセプトロンに結合のスキップ接続を導入したモデルを用いて一般的なプーリング層やスキップ接続を具体的に構成できることを示す. さらに, 活性化関数の種類を追加することで積のスキップ接続も具体的に構成することができる. これらの結果に関連して, プーリング層やスキップ接続の表現力に基づいた解析を行い, いくつかのモデルの解析結果を述べる.

3.1 プーリング層の構成と表現力

平均値プーリングは入力ベクトルに対して部分的に平均値を取る変換であるため, 低ランクの線形変換により実現できる. また, 最大値関数に関する性質

$$\max(x, y) = \text{ReLU}(x - y, 0) + y$$

より, 任意のサイズのベクトルの最大値関数が ReLU 関数と線形変換の合成により実現される. したがって, 入力ベクトルに対して部分的に最大値を取る変換である最大値プーリングも実現することができる. 例として, (a_1, a_2) の最大値プーリングは次のように表せる.

$$\left(f \circ \begin{pmatrix} 1 & -1 \\ 0 & 1 \end{pmatrix} + \begin{pmatrix} 0 & 1 \end{pmatrix} \right) \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \quad \left(= \max(a_1, a_2) \right),$$

ただし, f は ReLU 関数を用いた活性化層である. 以上より, 次の結果を得る.

定理 1 (プーリング層の表現力) サイズ n の平均値プーリングは線形パーセプトロン (0 層の多層パーセプトロン) により表現することができる. サイズ n の最大値プーリングは, スキップ接続をもつ m 層の ReLU パーセプトロンにより表現することができる. ただし, m は $\log_2(n) \leq m$ をみたす.

3.2 スキップ接続の構成と表現力

スキップ接続やレイヤー併合として用いられる演算の多くは線形演算であるため, 併合したい入力をあらかじめ結合させておくことで実現できる. また, 各成分ごとの最大値を取る場合には, 最大値プーリングと同様の方法により実現することができる. 例として, $\mathbf{x} = (x_1, x_2)^T \in \mathbb{R}^2$ と $\mathbf{y} = (y_1, y_2)^T \in \mathbb{R}^2$ の成分ごとの平均値, 最大値を返すスキップ接続はそれぞれ

$$\begin{pmatrix} \frac{1}{2} \mathbf{I} & \frac{1}{2} \mathbf{I} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ y_1 \\ y_2 \end{pmatrix} \quad \left(= \begin{pmatrix} \text{mean}(x_1, y_1) \\ \text{mean}(x_2, y_2) \end{pmatrix} \right),$$

$$\left(\sigma \circ \begin{pmatrix} \mathbf{I} & -\mathbf{I} \\ \mathbf{O} & \mathbf{I} \end{pmatrix} + \begin{pmatrix} \mathbf{O} & \mathbf{I} \end{pmatrix} \right) \begin{pmatrix} x_1 \\ x_2 \\ y_1 \\ y_2 \end{pmatrix} \quad \left(= \begin{pmatrix} \max(x_1, y_1) \\ \max(x_2, y_2) \end{pmatrix} \right),$$

として表すことができる. ただし, \mathbf{O}, \mathbf{I} はそれぞれ 2×2 の零行列と恒等行列, σ は ReLU 関数の活性化層である. したがって, 基本的なスキップ接続は結合スキップ接続に対する線形変換と活性化層の合成で表現可能である. また, \log と \exp に関して性質

$$\exp(\log(x) + \log(y)) = xy$$

が成り立つことから, 新たな活性化層として \log と \exp を用いることで成分ごとの積を返すスキップ接続を表現することができる. すなわち, σ_1, σ_2 をそれぞれ \log と \exp を用いた活性化層として, \mathbf{I} を 2×2 の恒等行列とすると,

$$\sigma_2 \circ \begin{pmatrix} \mathbf{I} & \mathbf{I} \end{pmatrix} \circ \sigma_1 \begin{pmatrix} x_1 \\ x_2 \\ y_1 \\ y_2 \end{pmatrix} \quad \left(= \begin{pmatrix} x_1 y_1 \\ x_2 y_2 \end{pmatrix} \right),$$

と表すことができる. 以上より, 次の結果を得る.

定理 2 (スキップ接続の表現力) 加算, 除算, 平均値のスキップ接続はいずれも結合のスキップ接続と線形変換の合成で表現することができる. 最大値のスキップ接続は加算のスキップ接続をもつ 2 層の ReLU パーセプトロンで表現できる. 積のスキップ接続は \log と \exp の二種類の活性化関数をもつ 2 層のパーセプトロンで表現できる.

また, 結合と加算のスキップ接続について次の対応がある.

命題 1 (結合と加算のスキップ接続の対応) w を全結合層とし, 二つの層 L_1, L_2 との合成を考える. このとき, 次の条件をみたす全結合層 u, v が存在する.

$$w \circ \begin{pmatrix} L_1 \\ L_2 \end{pmatrix} = u \circ L_1 + v \circ L_2.$$

ただし, u と v の出力次元は w と等しく, 入力次元は L_1 と L_2 の出力次元とそれぞれ等しい. また, 入力次元の和は w の入力次元と等しい.

この性質から、適切な次元の全結合層を用いることで加算と結合のスキップ接続に対応関係を与えることができ、スキップ接続の種類が表現力に差異を与えないことがわかる。

定理 3 (全結合層におけるスキップ接続の表現力) w_1, w_2, w' を全結合層, σ_1, σ_2 を活性化層とすると, 次の二つのモデルは表現力が等しい.

$$M_a = w_1 \circ \sigma_1 + w_2 \circ \sigma_2, \quad (1)$$

$$M_b = w' \circ \begin{pmatrix} \sigma_1 \\ \sigma_2 \end{pmatrix}. \quad (2)$$

ただし, w' は w_1, w_2 を合わせたサイズをもつ.

多層化した場合も同様の結果が得られる.

3.3 Single activation ブロックの表現力

w を重み層, σ を活性化層として, 次のようなニューラルネットワークモデルを考える.

$$M_1 = w_2 \circ \begin{pmatrix} \sigma \circ w_1 & \\ & \text{id} \end{pmatrix} \circ \begin{pmatrix} \sigma \circ w_0 & \\ & \text{id} \end{pmatrix},$$

$$M_2 = w'_2 \circ \begin{pmatrix} \sigma \circ w'_1 \circ \sigma \circ w'_0 & \\ & \text{id} \end{pmatrix}.$$

M_1 は single activation block 構造, M_2 は double activation block 構造である. このとき, 任意の w'_0, w'_1, w'_2 に対して,

$$w_0 = w'_0,$$

$$w_1 = \begin{pmatrix} w'_1 & \mathbf{0} \\ \mathbf{0} & w'_0 \end{pmatrix},$$

$$w_2 = \begin{pmatrix} w'_2 & a & -a & w'_2 \end{pmatrix}$$

とすることで $M_1 = M_2$ となる. ただし, a は任意の Affine 関数とし, $*^3 w'_2 = \begin{pmatrix} w'_2 & v'_2 \end{pmatrix}$ とおいた. 同様の考察は, 活性化層が L 個含まれるモデルについても行うことができ, 以上より, 次の結果を得る.

定理 4 (single activation block の優位性) 単層パーセプトロンに結合のスキップ接続を加えて L 回合成したモデルは, L 層の多層パーセプトロンモデルに結合のスキップ接続を加えたモデルよりも表現力が大きい.

また, 加算のスキップ接続を用いたモデルに関しても, 加算と結合の対応規則 (命題 1) を用いて同様の結果が得られる.

4. 先行研究におけるモデル構造

本稿で取り扱ったプーリング層とスキップ接続の種類はディープラーニングライブラリの一つである「keras」に実装されて

*3 合成等が定義される適切な次元の, 任意の Affine 関数とする.

いるものを参考にした. ResNet[?] では加算のスキップ接続が *residual skip connection* として提案され, DenseNet[?] では結合のスキップ接続が提案された. 結合のスキップ接続はベクトルの次元と同時に計算量やパラメータも増加させる働きがあり, 学習を高速化させるための多数の工夫が DenseNet では取り入れられていた. その他のスキップ接続としては, 平均値スキップ接続が FractalNet[?], 多段階スキップ接続が RoR[?] で用いられている. また, single ReLU ブロック構造は PyramidialResNet[?] や DenseNet などから良い成果が報告されている.

5. 結論・まとめ

本研究では, 結合のスキップ接続を導入した ReLU パーセプトロンや, 活性化層の種類を増やしたモデルを用いることでプーリング層やスキップ接続の一般的な構造が構成できることを示し, これらの構造を表現力の観点で解析した. 結果として, 最大値プーリングが多層の非線形性を持つこと, プーリング層や (結合以外の) スキップ接続が表現力に関して有意性がないこと, そして, single activation ブロックが multi activation ブロックよりも高い表現力を持つことが数学的に導かれた. 以上の結果は, スキップ接続やプーリング層といった構造を用いる場合に, 大きな表現力をもつモデルの設計方法を示していることから, ニューラルネットワークモデルの設計における一つのガイドラインを与えることができたと考えられる. 一方で, 学習に関する効果については触れておらず, 今後, 表現力と学習の両面からモデル設計の理論が構築されていくべきであると考える.

参考文献

- [Han 17] Han, D., Kim, J., and Kim, J.: Deep pyramidal residual networks, in *Computer Vision and Pattern Recognition (CVPR), 2017 IEEE Conference on*, pp. 6307–6315 (2017)
- [He 16] He, K., Zhang, X., Ren, S., and Sun, J.: Deep residual learning for image recognition, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778 (2016)
- [Huang 17] Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q.: Densely connected convolutional networks, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4700–4708 (2017)
- [Larsson 16] Larsson, G., Maire, M., and Shakhnarovich, G.: Fractalnet: Ultra-deep neural networks without residuals, *arXiv preprint arXiv:1605.07648* (2016)
- [Zhang 18] Zhang, K., Sun, M., Han, T. X., Yuan, X., Guo, L., and Liu, T.: Residual networks of residual networks: Multilevel residual networks, *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 28, No. 6, pp. 1303–1314 (2018)

グラフ表現を用いた知識獲得予測による潜在知識構造の抽出と活用

Extracting and Exploiting Latent Knowledge Structure by Graph-based Knowledge Tracing

中川 大海 *¹ 岩澤 有祐 *¹ 松尾 豊 *¹
Hiromi Nakagawa Yusuke Iwasawa Yutaka Matsuo

*¹東京大学工学系研究科
The University of Tokyo

Recent advancements in computer-assisted learning systems have increased research in the area of *knowledge tracing*, which estimates student proficiency based on their past performance. In this context, deep learning-based methods, such as Deep Knowledge Tracing (DKT), show remarkable performance; however, existing methods do not consider latent knowledge structure. This limits not only the prediction performance but also the interpretability and validity of models' prediction, which prevents the application to real educational environments. In this paper, we propose a graph-based knowledge tracing model, Graph Knowledge Tracing (GKT). Representing the knowledge structure as a graph, we model students' time-series mastery to each skill using Graph Neural Networks. We consider two problem settings, one is to exploit the pre-defined graph structure and the other is to learn the implicit graph structure from data, and provided two models to deal with them. Using two open datasets, we empirically validated that our method shows higher prediction performance and more interpretable and valid prediction compared to the previous methods. These results show the potential of our proposed method to enhance the performance and the application to real educational environments of knowledge tracing, which could help improve the learning experience of students in more diverse environments.

1. はじめに

近年、教育と情報技術の融合が進む中で、学習体験の効率化に関する研究が注目を集めている。中でも知識獲得予測 (*knowledge tracing*) [Corbett 94] の研究は、過去の生徒の学習行動を元に個々の生徒の習熟度を予測するものであり、個人に最適化された学習内容を提供する上で核となる技術である。歴史的に様々な分析手法が考案されてきたが、特に深層学習の活用により、人手での複雑な特徴量設計なしに従来の手法より高い精度での予測が可能になった [Piech 15]。

一方、深層学習を用いた知識獲得予測に関する既存の研究では、いずれも知識の構造を十分に考慮したモデルが設計されていない。本研究では、知識獲得予測の文脈に倣い、「知識」をある学問を抽象的な個別の概念に分割したもの、「知識構造」を各知識が相互の影響関係のもと一つの体系をなしている状態として定義する。知識構造の設計は学習や指導において重要な役割を担い、知識獲得の効率にも影響を与えることが知られており、こうした知識構造を明示的に考慮しない既存研究は、二つの課題を生んでいる。一つは、機械学習のモデル設計において重要な、帰納バイアスと呼ばれる、データの性質に対する知識に基づく最適なモデルの設計ができていないため、学習の効率や未知データへの汎化が妨げられている可能性が高いことである。もう一つは、知識ごとに異なる習熟の変化や、知識間の関係性などが学習に明示的に反映されないため、モデルが知識ごとの習熟度合いをどのように判断しているかという予測の解釈性が低下したり、カリキュラムを設計した側が意図しない挙動をモデルが学習し予測の妥当性が低下するなど、実際の教育現場における知識獲得予測の実用を妨げていることである。

本研究では、知識間の潜在構造をグラフ表現を用いて定式化し、近年発展が進む、深層学習を用いてグラフを扱う Graph Neural Network を拡張したモデルによって、これらの問題の

解決を図る。実験では、提案手法が既存手法に比べて、高精度かつ解釈性と妥当性の高い予測を行えることを、オープンデータを用いて実証的に検証し、またデータから学習されたグラフ構造を分析することで、効率的な知識構造の設計に関して考察する。また、実験結果を踏まえ、グラフの活用を含めた今後の知識獲得予測の研究が考慮すべき方向性を整理することで、知識獲得予測研究の発展に向けて有益な示唆をもたらす。

2. 関連研究

2.1 Deep Knowledge Tracing

Deep Knowledge Tracing [Piech 15] (DKT) は RNN を利用して知識獲得予測を行う手法である。モデルの入力は、ある生徒のある時刻における問題と正誤の組み合わせを符号化した one-hot ベクトルであり、問題の数を M とすれば、長さは $2M$ となる。訓練時に用いられる目的関数は、モデルの予測の、生徒の解答行動の観測系列に対する負の対数尤度である。

2.2 Graph Neural Network

グラフは、データを物体 (ノード) とそれらの関係性 (エッジ) から表現するデータの表現方法であり、Graph Neural Network (GNN) は深層学習を用いてグラフを扱う手法の総称である。画像認識において飛躍的な成果を發揮した CNN は、画像データに特有の局所性や位置不変性などを考慮したモデル構造によってパラメータ数を大幅に節約しながら高い表現力を獲得したことが知られているが、GNN は同様の機構を画像以外のものでできる [Battaglia 18]。

3. 提案手法

本研究では、知識構造をグラフ表現を用いて定義し、GNN を拡張した機構によって知識獲得予測を行う Graph Knowledge Tracing (GKT) のモデルを提案する。

連絡先: 中川大海, 東京大学工学系研究科技術経営戦略学専攻,
nakagawa@weblab.t.u-tokyo.ac.jp

3.1 GKT の定式化

1. で述べた定義に倣うと、知識構造は、各知識をノード、知識間の関係性をエッジとした重み付き有向グラフと見なすことが出来る。GKT では、ノード v_i に対応する知識 i に対する生徒固有の習熟状態を表す隠れ状態 \mathbf{h}_i を定義し、各時刻で生徒の解答正誤が観測される際には、解答ノード v_i に加え、隣接ノード $v_j \in \mathcal{N}_i$ の隠れ状態も更新する。ここで、 \mathcal{N}_i はノード i に隣接するノードの集合を表す。モデルは、DKT 同様、生徒の時刻 T までの解答正誤系列 $\mathbf{x}^{t \leq T}$ を入力として、次の時刻 $T+1$ の解答正誤予測 $y^{t=T}$ を出力し、DKT と同様に観測系列に対する負の対数尤度を最小化するように学習する。以下ではモデルの処理を三つの段階に分けて説明する。

まず、生徒の時刻 t における解答 \mathbf{x}^t が観測されたときに、隠れ状態の更新に利用する特徴の集約を行う。解答ノード $i = \{i_0, \dots, i_{a_t}\}$ と隣接ノード $j \in \mathcal{N}_i$ に対応する隠れ状態を抽出し、該当スキルのインデックスおよび解答正誤の埋め込み表現と連結する。

$$\begin{aligned} \mathbf{x}_{emb}^t &= \mathbf{x}^t \mathbf{E}_x \\ \mathbf{h}_i^t &= [\mathbf{h}_i^t, \mathbf{x}_{emb}^t] \\ \mathbf{h}_j^t &= [\mathbf{h}_j^t, \mathbf{E}_q(j)] \end{aligned}$$

ここで、 a_t は、時刻 t において同時に解答したスキルの数を表しており、 \mathbf{x}^t は、解答されたスキルのインデックスと解答正誤を示す長さ $2M$ の one-hot ベクトルであり、 $\mathbf{E}_q \in \mathbb{R}^{M \times e}$ はスキルの埋め込み行列であり、 $\mathbf{E}_x \in \mathbb{R}^{2M \times e}$ はスキルに対する解答正誤の埋め込み行列であり、 e は埋め込みの次元数である。

次に、集約された特徴を元に、生徒の隠れ状態を更新する。

$$\begin{aligned} \mathbf{m}_k^{t+1} &= \begin{cases} f_{self}(\mathbf{h}_i^t) & (k=i) \\ f_{neighbor}(\mathbf{h}_i^t, \mathbf{h}_j^t, \theta) & (k \neq i) \end{cases} \quad (1) \\ \tilde{\mathbf{h}}^{t+1} &= \tanh \left(\frac{1}{a_t} \sum_{i_{a_t} \in i} \mathcal{G}_{ea}(\mathbf{m}_{i_{a_t}}^{t+1}) \right) \\ \mathbf{h}^{t+1} &= \mathcal{G}_{gru}(\tilde{\mathbf{h}}^{t+1}, \mathbf{h}^t) \end{aligned}$$

ここで、 $f_{self}, f_{neighbor}$ は任意の関数であり、本研究では f_{self} には二層の多層パーセプトロンを用いる。 θ は任意のパラメータであり、 \mathcal{G}_{ea} は [Zhang 16] で用いられた Erase-Add ゲートからバイアス項を除いたものであり、 \mathcal{G}_{gru} は GRU [Cho 14] からバイアス項を除いたものである。

最後に、次の時刻における解答正誤予測 y^t を出力する。

$$y^t = \mathbf{W}_{o2} \mathbf{W}_{o1} \mathbf{h}^{t+1} + \mathbf{b}_o^T$$

ここで、 $\mathbf{W}_{o1}, \mathbf{W}_{o2}$ はノード共通で用いられる重み行列であり、 \mathbf{b}_o はノードごとに独立した値を持つバイアス項である。

3.2 GKT の性質

GKT の性質を既存手法との比較から考察する。まず、DKT [Piech 15] は、単純な RNN を元にしたモデルであり、隠れ状態をスキルごとに区別して定義できないため、スキル間の関係性を学習に明示的に反映したり、長期系列において過去の回答の習熟情報を維持することが困難であった。また、この課題を解決するためにメモリ行列を導入した DKVMN [Zhang 16] も、メモリの各スロットは入力空間のスキルとは明示的に対応しない低次元表現であり、スキルとの関係も単純な内積でしか

表現できなかった。一方、GKT は、知識構造をグラフとして明示的に学習に反映することが可能な上、スキルごとの隠れ状態を区別して定義した上で、スキル間の関係性を複数のエッジや多層のニューラルネットワークによる非線形変換を用いて複雑に定義可能である。このような性質から、従来の手法に比べてより高い精度での予測が可能になり、また予測の解釈性や妥当性が向上することが期待される。

3.3 GKT におけるグラフの定義

GKT は知識構造をグラフとして定式化して知識獲得予測を行うモデルだが、モデルの学習時には、既知のグラフを明示的 (*explicit*) に仮定することも、グラフを明示的に仮定せず (*implicit*) にモデルの学習の過程で同時に学習することも可能である。本研究では、前者を Explicit Graph Knowledge Tracing (EGKT)、後者を Implicit Graph Knowledge Tracing (IGKT) として区別し、以下でそれぞれの実装を説明する。

3.3.1 Explicit Graph Knowledge Tracing (EGKT)

EGKT では、隣接ノードの隠れ状態の更新の際に、集約した特徴をエッジの向きごとに別々の関数を用いて変換した後、仮定した既知の隣接行列 \mathbf{A} の値を元に加重和を計算する。このとき、式 1 における $\mathbf{m}_{k \neq i}^{t+1}$ は以下の式で定義される。

$$\mathbf{m}_{k \neq i}^{t+1} = \mathbf{A}_{i,k}^T \odot f_o([\mathbf{h}_i^t, \mathbf{h}_k^t]) + \mathbf{A}_{k,i} \odot f_i([\mathbf{h}_i^t, \mathbf{h}_k^t])$$

ここで、 f_i, f_o は任意の関数であり、本研究では二層の多層パーセプトロンを用いる。EGKT は、任意の方法で定義した隣接行列を利用出来るが、本研究では学習済みの DKT のモデルから [Piech 15] の手法に基づいて抽出した「DKT グラフ」、遷移確率を元に定義した「遷移グラフ」、自己以外の全ノードと等しい重みで接続する「全結合グラフ」を定義して検証を行う。

3.3.2 Implicit Graph Knowledge Tracing (IGKT)

IGKT は、知識獲得の予測と同時にグラフ構造をデータから学習するモデルであり、本研究では、グラフ構造を学習する方法として三つのモデルを提案する。一つ目は、EGKT と同様のモデル構造において隣接行列 \mathbf{A} をパラメータと見なして最適化する、Parametric Adjacency Matrix (PAM) である。二つ目は、複数ヘッ드의注意機構 [Vaswani 17] を用いて、各ノードの特徴を元に、 K 個のヘッドを用いて 2 ノード間の K 通りのエッジの重みを計算することでグラフ構造を推定する、Multi-Head Attention (MHA) である。本研究では生徒共通の静的なグラフ構造を学習するため、注意係数の計算にはスキルのインデックスや解答正誤の埋め込みを入力として用いる。三つ目は、各エッジの種類を定義する離散のカテゴリを表す潜在変数 \mathbf{z} の存在を定義し、VAE を用いて \mathbf{z} を推定することでグラフ構造を推定する、Variational AutoEncoder (VAE) である。[Kipf 18] に着想を得たモデルであり、予測の負の対数尤度に加え、潜在変数 \mathbf{z} の予測分布 $q(\mathbf{z}|\mathbf{x})$ と事前分布 $p(\mathbf{z})$ のカルバック・ライブラー情報量を最小化するように学習させることで、グラフ構造に対するスパース性などを仮定することができる。

4. 実験

4.1 実験設定

実験には、オンライン教育サービスの ASSISTments*1 における生徒の数学の問題解答ログの「skill_builder」*2 から

*1 <https://www.assistments.org/>

*2 <https://sites.google.com/site/assistmentsdata/home/assistent-2009-2010-data/skill-builder-data-2009-2010>

表 1: 各データセットの統計量

データセット	生徒数	スキルタグ数	ログ数
ASSISTments	1,000	101	62,955
KDDCup	1,000	211	98,200

表 2: 各手法のモデルの予測精度の比較

手法	AUC	
	ASSISTments	KDDCup
ベースライン	DKT	0.709
	DKVMN	0.710
EGKT	DKT グラフ	0.723
	遷移グラフ	0.721
	全結合グラフ	0.722
IGKT	PAM	0.719
	MHA	0.723
	VAE	0.722

なるデータセット（以下、ASSISTments）と、KDDCup の Educational Data Mining Challenge で使用された「Bridge to Algebra 2006-2007」[Stamper 10] のデータセット（以下、KDDCup）を用いる。各データセットでは各問題に人間の専門家が定義した「スキルタグ」が紐付けられており、本研究ではこの各スキルタグを「知識」の定義とする。各データセットより、同時解答を意味する重複ログを一つにまとめ、名前が割り当てられておりダミーでないスキルの解答ログを抽出し、最低 10 回以上解答されているスキルの解答ログを抽出した後、各ユーザ 100 回目までのログを抽出し、ランダムに 1000 ユーザを抽出した。以上の条件から抽出されたデータセットの統計量を表 1 に示す。

4.2 実験 1: モデルの予測の精度の比較

まず、提案手法が既存手法より高い精度で生徒の知識獲得を予測できるかを検証するために、DKT [Piech 15] と DKVMN [Zhang 16] をベースラインとして予測の AUC を比較し、表 2 に示した。各データセットで最高精度のものを太字で記載した。

表より、いずれのデータセットにおいても、提案手法が最も高い精度を示した。このことから、知識の潜在的な構造をグラフを用いて定式化し、GNN を拡張してグラフ表現上で生徒の知識獲得をモデリングをする提案手法が、知識獲得の予測において有効であることが示された。

4.3 実験 2: モデルの予測の解釈性と妥当性の比較

次に、提案手法が既存の深層学習を用いた手法と比較して、解釈性と妥当性の高い予測が行えるかを検証した。まず、ある生徒の時刻 T までの解答ログを抽出して学習済みモデルに入力し、出力からバイアス項を除いて正規化した値を蓄積することで、学習済みのモデルによる、生徒の各スキルに対する時系列の習熟度予測を分析可能な行列を作成した。この行列を基に、学習済みモデルの予測について、各時刻において関連する知識の習熟度のみ更新しているかによって解釈性を評価し、仮定したグラフ構造と連動して生徒の習熟を予測しているかによって妥当性を評価した。

ASSISTments における DKT と GKT の出力から作成した行列から、一部のスキル集合に関する値のみを抽出したものを図 1 に示した。各時刻において正答・誤答したスキルに対応する要素に、それぞれ「○」と「×」を記載した。各項目にお

けるヒートマップは、各行が各スキルを、各列が左から右に進む時刻を表しており、各要素の色は習熟度の変化を可視化したもので、赤色に近づくほど習熟度合いが減少し、緑色に近づくほど習熟度合いが増加したと見なすことができる。

まず、生徒が頻繁に解答したスキル集合に関する値のみ抽出して可視化したものを図 1a に示した。図より、DKT では解答の観測と予測される習熟度との関係性が小さく、全ての値が常に値が小さく変動している一方、GKT では各スキルに対する習熟度とそのスキルの解答が観測された時刻で明確に更新されていることがわかる。この結果より、提案手法が既存手法に比べ解釈性の高い予測を行えていることが検証された。

次に、グラフ上で隣接するスキル集合に関する値のみ抽出して可視化したものを図 1b に示した。図の右側は、ネットワーク図における対応する部分を抽出して可視化したものである。図より、GKT において、スキル 29 (Effect of Changing Dimensions of a Shape Proportionally) の解答が観測されていないものの習熟度予測が大きく変化した 2 箇所において、グラフ上で接続するスキル 4 (Addition and Subtraction Positive Decimals) の正答が観測されており、モデルがグラフ上の接続関係に基づいた予測を行っている様子が確認された。一方、該当のグラフを抽出した元の DKT の出力では、そのような性質は確認できなかった。この結果より、提案手法が既存手法に比べ妥当性の高い予測を行えていることが検証された。

4.4 実験 3: 学習された知識構造の分析

最後に、学習後の IGKT のモデルから学習されたグラフ構造を抽出してネットワーク図として可視化し、分析した。IGKT は自身が学習するグラフ構造を用いて生徒の知識獲得を予測するため、高い精度で予測が可能な IGKT のモデルから抽出したグラフからは、効率的な知識構造の設計について有益な知見を得られる可能性がある。各手法のモデルから作成したネットワーク図を図 2 に示す。各スキルが解答ログ内で解答される平均順序を計算し、値が大きくなるに連れて青色から黄色、赤色と変化するように対応するノードを着色した。比較のために DKT から抽出したグラフ [Piech 15] は、色の近いノード間に多くエッジが張られており、クラスタを形成している様子が確認できた。DKT は全てのスキルに関する習熟状態を同一の隠れ状態扱おうなど、長期の系列のモデリングを行いにくいモデル機構であるため、解答順序の近いノード間の依存関係を学習しやすかった可能性が考えられる。PAM から作成したグラフは、他の MHA や VAE と比較すると比較的 DKT に近い、色の近いノードを主に結びながら、クラスタを形成している様子が確認できた。局所的な接続に注目した図 3a からは、12 (Area Rectangle) や 20 (Complementary and Supplementary Angles) などの図形に関するスキル同士の接続が確認された。MHA から作成したグラフは、特定のノードから多くのエッジが流出している様子が見て取れる。他の手法が学習しなかった特殊な依存関係を学習している可能性が高いが、偏った予測をする可能性があり、スキルごとの予測精度の影響を検証する必要がある。VAE から作成したグラフは、他のグラフに比べ、特定のノードにエッジが集中せず多くのノードが繋がった密なグラフとなった。人間には直感的には解釈しにくいものの、一部、図 3b に示したように、46 (Mode), 38 (Histogram as Table or Graph), 78 (Scatter Plot) といった統計に関連するスキルが直列的に接続している部分などもあり、従来の手法では発見しにくい、意味的な関係性が深いと考えられるエッジも確認された。

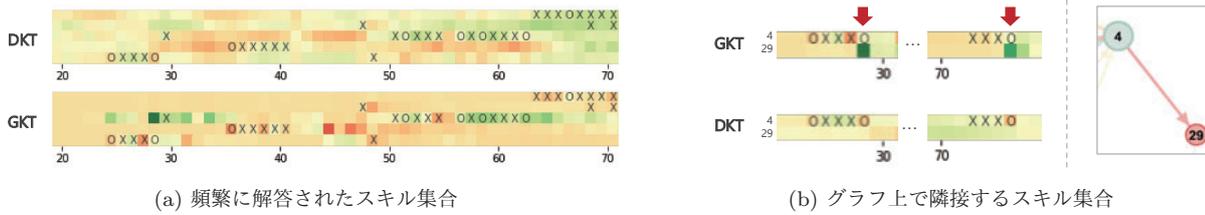


図 1: 一部のスキル集合に関する生徒の習熟予測の変遷の可視化

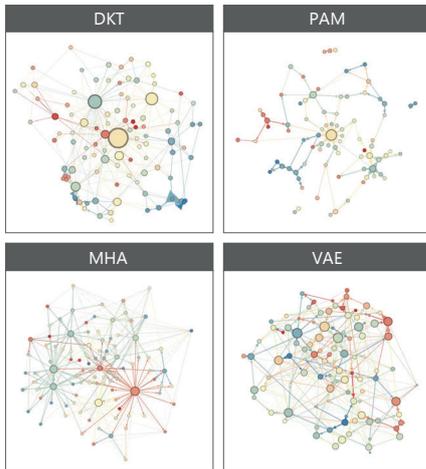


図 2: 学習済みモデルから作成したネットワーク図

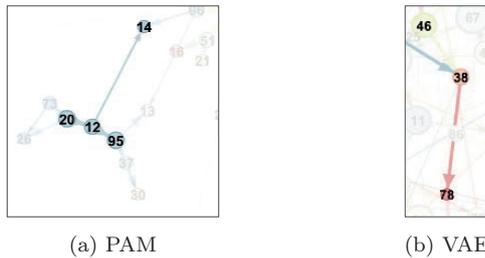


図 3: IGKT から作成したネットワーク図の局所的な可視化

5. 結論

本研究では、既存の深層学習を用いた知識獲得予測の研究が、知識構造を明示的に考慮したモデル構造を用いていないことにより生じている、二つの課題に着目し、知識構造をグラフ表現を用いて定式化し、GNNを拡張した機構で知識獲得予測を行うGKTのモデルを提案した。実験結果から、提案手法は既存手法に比べて高精度かつ解釈性・妥当性の高い予測が行えることが示され、知識獲得予測の教育現場での活用を促進する上で有益なものであることが確認された。提案手法は特殊なデータを必要としない汎用性の高い拡張であるため、多様なデータセットへの適用が期待でき、さらに知識獲得予測やGNNの近年の研究における多様な拡張と組み合わせることで、より予測の精度や解釈性などを高めることが期待できる。また、提案手法によってデータから学習した知識構造は、従来の人間の設計とは異なる構造を有することから、良い知識構造の定義は何かという根本的な問題を問いかけるものでもあり、タグ付け自体をデータから学習する [Nakagawa 18] の研究と組み合わせることで、より有益な示唆を得られる可能性がある。本研究では数学に関する二つのデータセットを用いたが、

より網羅的なデータセットを用いて検証することで、手法の汎用性の検証や、効率的な知識構造に関する新たな知見の獲得が期待でき、今後の研究課題である。本研究が、今後の知識獲得予測研究が考慮すべき重要な方向性を示し、知識獲得予測の研究や実用を加速させ、多様な環境における生徒の学習効率の向上に寄与するものとなると信じている。

参考文献

- [Battaglia 18] Battaglia Peter W, Hamrick Jessica B, Bapst Victor, Sanchez-Gonzalez Alvaro, Zambaldi Vinicius, Malinowski Mateusz, Tacchetti Andrea, Raposo David, Santoro Adam, Faulkner Ryan and others. Relational inductive biases, deep learning, and graph networks. arXiv preprint arXiv:1806.01261 (2018).
- [Cho 14] Kyunghyun Cho, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078 (2014).
- [Corbett 94] Albert T Corbett and John R Anderson: Knowledge tracing: Modeling the acquisition of procedural knowledge, User modeling and user-adapted interaction 4, 4 (1994), 253278.
- [Hochreiter 97] Sepp Hochreiter and Jurgen Schmidhuber: Long short-term memory, Neural computation 9, 8 (1997), 17351780.
- [Kipf 18] Thomas Kipf, Ethan Fetaya, Kuan-Chieh Wang, Max Welling and Richard Zemel. Neural relational inference for interacting systems. arXiv preprint arXiv:1802.04687 (2018).
- [Nakagawa 18] Hiromi Nakagawa, Yusuke Iwasawa and Yutaka Matsuo. End-to-End Deep Knowledge Tracing by Learning Binary Question Embedding, In 2018 IEEE International Conference on Data Mining Workshops (ICDMW). (2018).
- [Piech 15] Chris Piech, Jonathan Bassen, Jonathan Huang, Surya Ganguli, Mehran Sahami, Leonidas J Guibas, and Jascha Sohl-Dickstein: Deep Knowledge Tracing, In Advances in Neural Information Processing Systems. 505513 (2015).
- [Stamper 10] J. Stamper, A. Niculescu-Mizil, S. Ritter, G.J. Gordon, and K.R. Koedinger. Bridge to Algebra 2006-2007, Development data set from KDD Cup 2010 Educational Data Mining Challenge, <http://pslcdatashop.web.cmu.edu/KDDCup/downloads.jsp>. (2010).
- [Vaswani 17] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser and Illia Polosukhin. Attention is all you need, In Advances in Neural Information Processing Systems. 5998–6008 (2017).
- [Zhang 16] Jiani Zhang, Xingjian Shi, Irwin King and Dit-Yan Yeung. Dynamic Key-Value Memory Network for Knowledge Tracing, arXiv preprint arXiv:1611.08108 (2016).

グラフ上の問題に対する難しいインスタンスの自動生成

Learning to Find Hard Instances of Graph Problems

佐藤 竜馬^{*1} 山田 誠^{*1*2*3} 鹿島 久嗣^{*1*2}
 Ryoma Sato Makoto Yamada Hisashi Kashima

^{*1}京都大学 Kyoto University ^{*2}理化学研究所 革新知能統合研究センター RIKEN Center for AIP ^{*3}JST さきがけ JST PRESTO

Finding *hard instances*, which needs a long time to solve, of graph problems is important for building a good benchmark for evaluating the performance of algorithms and analyzing algorithms to accelerate algorithms. In this paper, We aim at automatically generating hard instances of graph problems. We formulate finding hard instances of graph problems as an optimization problem and propose a method to automatically find hard instances by solving the optimization problem. The advantage of the proposed algorithm is that it does not require any task-specific knowledge. To the best of our knowledge, it is the first non-trivial method in the literature to automatically find hard instances by using optimization. Through experiments on various problems, we show that our proposed method can generate a few to several orders of magnitude harder instances than the random based approach in many settings, and especially our method outperforms rule-based algorithms in the 3-coloring problem.

1. はじめに

組合せ問題のアルゴリズムを与えられたとき、どのようにしてそのアルゴリズムが解くのに時間がかかるインスタンスを自動で見つけることができるだろうか？ある与えられたアルゴリズムにとって解決に長い時間がかかるインスタンスのことを難しいインスタンスと呼ぶ。難しいインスタンスを見つけることは、次の点で重要である。

理由 1 アルゴリズムの分析と高速化に役立つ。

理由 2 ベンチマークとして使うことができる。難しいインスタンスを含むベンチマークを生成することは、アルゴリズムを評価することによって重要である。

難しいインスタンスを見つけるための最も単純な方法は、ランダムに多数のインスタンスを生成し、それらを評価し、それらのうち最も難しいインスタンスを出力することである。この手法は多くの問題について適用でき、また単純であるが、多くのアルゴリズム (e.g., クイックソート) は最悪計算量を実現するインスタンスに比べて、ランダムなインスタンスをはるかに速く処理できるので、この方法によって難しいインスタンスを発見するのは効率的ではない。難しいインスタンスを効率的に見つけるためには、問題の構造をとらえることができる方法を開発する必要がある。本研究ではグラフ問題に焦点をあて、グラフ問題の難しいインスタンスを自動でかつ効率よく生成するアルゴリズムの開発を目指す。グラフ問題は、彩色問題、最小頂点被覆問題、最大クリーク問題など、理論上、応用上共に重要な問題を数多く含むため、自動的にグラフ問題の難しいインスタンスを生成できるアルゴリズムの提案は大きな貢献となる。本研究では、グラフ問題の難しいインスタンスを見つける問題を最適化問題とし、それを解決するために山登り法、疑似焼きなまし法、そしてニューラルネットワークと強化学習を使用することを提案する。本研究における提案手法は広範囲の問題に適用可能であり、一様ランダムグラフモデルに比べてはるかに難しいインスタンスを生成することができる。

本研究の主な貢献は以下のようにまとめられる。

連絡先: 佐藤竜馬, 京都大学, r.sato@ml.ist.i.kyoto-u.ac.jp

1. 定式化 グラフ問題の難しいインスタンスを見つける問題を最適化問題として定式化する。
2. 新手法の提案 最適化問題を解くことによって困難なインスタンスを見つけるための一般的で効果的な方法を提案する。
3. 有効性 4つの問題と6つのアルゴリズムを用いた実験を通して、本手法の有効性を示す。

2. 提案手法

本章では、まず問題設定を定義する。次に、難しいインスタンスを生成する問題を最適化問題として定式化することを提案し、ニューラルネットワークと強化学習に基づく難しいインスタンス生成アルゴリズムを提案する。

2.1 問題設定

本節では、本研究で取り組むグラフ問題の難しいインスタンスを見つける問題を定義する。本研究では、グラフ彩色問題、最小頂点被覆問題、最大クリーク問題などの多くの重要な問題を含む、無向・重みなし・単純グラフを取り扱う。グラフ彩色問題、最小頂点被覆問題、最大クリーク問題はスケジューリング問題やコンパイラのレジスタ割り当て問題やコミュニティ検出など、多くの応用上の問題に登場するため、ランダムなインスタンスを含む多くのインスタンスを現実的な時間内に処理することができる様々なアルゴリズムが提案されている。一方で、これらの問題は NP 困難問題であるので、そのような効率的なアルゴリズムも最悪ケースでの計算量は指数的に増加するはずである。そのようなケースを見つけることは、第1章で述べたように、アルゴリズムを解析し、高速化することによって重要である。

本研究の目標は、グラフ問題に対するアルゴリズムが与えられたとき、そのアルゴリズムが解くために多くのステップを必要とするインスタンス (i.e., 難しいインスタンス) を自動で発見することである。特に、問題固有の特性や専門家による洞察を用いず、各インスタンスの難しさの値のみを使用して難しいインスタンスを生成する。インスタンスの難しさの定義は任

意であるが、そのインスタンスに対して実際にアルゴリズムを実行することによって計算できるものとする。例えば、実験では、三彩色問題のインスタンスの難しさの値は、Brélez のアルゴリズムの再帰呼び出しの数によって定義され、グラフ同型判定問題のインスタンス難しさは、Nauty [McKay 14] が問題を解決するのに必要な時間によって定義される。このように定義することで、インスタンスの難しさを定量的に評価できるようになると共に、最適化問題としての定式化が可能となる。アルゴリズム L を用いたときのインスタンス x の難しさの値を $\text{hardness}(x, L)$ として表記する。

仮定 1 (小さいインスタンス): 単に頂点の数を増やすことでインスタンスを任意に難しくすることができるが、このようにして生成されたインスタンスは自明であり、このような手法は実用的ではない。また、小さなインスタンスは可視化することができ、解釈や分析が容易である。本研究では、出力するインスタンスのサイズを小さな値で固定し、そのサイズの中で難しいインスタンスを生成することを目指す。

仮定 2 (サンプル効率): 難しさの評価は一般にアルゴリズムをシミュレートする必要があるため時間がかかり、インスタンスが難しい場合は特に時間がかかる。したがって、あまりにも多くのインスタンスを評価することは現実的ではないため、難しいインスタンスをより効率的に見つけることが重要である。本研究では、評価回数の上限を B に設定する。この制約により、あまりにも多くの目的関数を評価する方法 (e.g., brute-force search, 遺伝的アルゴリズム) は使用できない。

2.2 最適化問題としての定式化

本研究では、難しいインスタンスを見つけるタスクを最適化問題として定式化し、直接最適化することを提案する。難しいインスタンスを見つけるタスクを単純に定式化すると次のように書くことができる。

Problem 1

$$\begin{aligned} & \underset{x}{\text{maximize}} && \text{hardness}(x, L) \\ & \text{subject to} && x \text{ is an instance of } Q. \end{aligned}$$

ここで Q は問題で、 L は与えられたアルゴリズムである。 x が Q のインスタンスであるという条件は一般には Q に依存し、書き下すことはできないが、本研究では無向・重みなし・単純グラフ上の問題を考えているため、 x が Q のインスタンスであるときかつそのときのみ、隣接行列 $A \in \{0, 1\}^{n(n-1)/2}$ として表すことができる。したがって、Problem 1 は以下のように具体的に制約を書き直すことができる。

Problem 2

$$\begin{aligned} & \underset{A}{\text{maximize}} && \text{hardness}(A, L) \\ & \text{subject to} && A \in \{0, 1\}^{n(n-1)/2}. \end{aligned}$$

本研究でははじめに、山登り法と疑似焼きなまし法を使用して問題 2 を解くことを考える。山登り法と疑似焼きなまし法はよく知られたメタヒューリスティック探索アルゴリズムである。1 つのグラフ A を状態とし、 A から 1 つの辺を削除するか、1 つの辺を追加することで、近傍解を生成する。近傍の数が多いため、それらすべての難しさを計算することはサンプル効率の観点から効率的ではない。例えば、頂点数が $n = 50$

の場合、グラフの近傍数は $n(n-1)/2 = 1225$ となる。この問題に対処するために、本研究では乱択アルゴリズムを採用する。まず、最初に現在のグラフ A の近傍 N を無作為に選び、その難しさの値を評価する。 N の難しさが A よりも高い場合は、 N を次の状態として遷移し、そうでなければ現在の状態 A に留まる。

以上の手法により、Problem 2 を解くことができるが、 A は離散変数であるため、Problem 2 を最適化するのは困難である。そこで、本研究では最適値を変えずにこの問題を連続空間上の問題に変換することを提案する。

Problem 3

$$\begin{aligned} & \underset{P}{\text{maximize}} && \mathbb{E}_{A \sim \text{Bernoulli}(P)}[\text{hardness}(A, L)] \\ & \text{subject to} && P \in [0, 1]^{n(n-1)/2} \end{aligned}$$

ここで、 $A \sim \text{Bernoulli}(P)$ は、各 A_i が $\text{Bernoulli}(P_i)$ (ベルヌーイ分布) から独立してサンプリングされることを表す。この変換によって最適値が変わることはない。このことを次に示す。

Theorem 1. 問題 2 と 問題 3 の最適値は同じである。

Proof. M を問題 2 の最適値とし、 $\text{hardness}(A^*, L) = M$ とする。 M' を問題 3 の最適値とする。 M は問題 2 の最適値であるので、任意のグラフ A について $\text{hardness}(A, L) \leq M$ が成り立つ。したがって、任意の P に対して、 $\mathbb{E}_{A \sim \text{Bernoulli}(P)}[\text{hardness}(A, L)] \leq M$ となる。よって $M' \leq M$ 。一方、 $M' \geq \mathbb{E}_{A \sim \text{Bernoulli}(A^*)}[\text{hardness}(A, L)] = \text{hardness}(A^*, L) = M$ となる。したがって、 $M = M'$ が成り立つ。□

Theorem 2. 問題 3 の目的関数

$$f(P) = \mathbb{E}_{A \sim \text{Bernoulli}(P)}[\text{hardness}(A, L)]$$

は解析的関数である。特に、 C^∞ 級関数である。

Proof.

$$\begin{aligned} f(P) &= \mathbb{E}_{A \sim \text{Bernoulli}(P)}[\text{hardness}(A, L)] \\ &= \sum_A \prod_{i=1}^{n(n-1)/2} (P_i^{A_i} (1 - P_i)^{1 - A_i}) \cdot \text{hardness}(A, L) \end{aligned}$$

である。ここで A は $A \in \{0, 1\}^{n(n-1)/2}$ をわたる。 $f(P)$ は P の要素についての多項式であるので、 $f(P)$ は C^∞ 級関数であり、解析的関数である。□

Theorem 2 より、問題 3 の目的関数が滑らかであるため、連続空間で効率的に探索ができることが分かる。

2.3 確率的グラフモデル

本研究では、確率グラフ生成モデルと即時強化学習を使用した機械学習的なアプローチを使用して、問題 3 を解くことを提案する。他のモデルの選択肢としては、ノードやエッジを 1 つずつ出力する逐次モデルが考えられるが、特にグラフが大きい場合、そのようなモデルは訓練するのが難しい [Ma 18] ため、この方法は採用しない。即時強化学習の枠組みでは、エージェントの行動は難しいと予想されるインスタンス A に対応し、そのアクションの報酬 r はアルゴリズムを A に対して実

行してたときのコストである (*i.e.*, $r = \text{hardness}(A, L)$)。報酬 r は、報酬の予測精度を向上させるために使用される。環境からの入力には存在しないため、入力としてノイズ z を使用する。エピソードに含まれるアクションは 1 つだけなので、各アクションは独立である。

行動を決定するために、ニューラルネットワークモデルは、各辺 i に対して辺 i が現れる確率 P_i を出力する ($i = 1, 2, \dots, n(n-1)/2$)。そして、確率 P_i に従って各辺を独立にサンプリングし、グラフ A を構築する (*i.e.*, アクション)。次に、報酬を得るために $\text{hardness}(A, L)$ を評価する。最後に、REINFORCE アルゴリズム [Williams 92] を使ってニューラルネットワークモデル w_i の重みを更新する：

$$w_i = w_i + \alpha r \frac{\partial}{\partial w_i} \sum_{i=1}^{n(n-1)/2} (\log P_i^{A_i} + \log(1 - P_i)^{(1-A_i)})$$

ここで α は学習率である。 P が観測されている場合、 A_i と A_j ($i \neq j$) は独立しているが、条件が無い場合は P は独立していないため A_i と A_j ($i \neq j$) は独立ではなく、提案手法はエッジ間の非線形な関係もモデル化できる。

3. 拡張

本研究での提案手法では、難しさの値の選択は任意である。したがって、提案手法は、解決するのに長い時間を必要とするインスタンスだけでなく、他の意味で難しいインスタンスも見つけることができる。本章では応用上重要な二つの拡張について述べる。

3.1 近似度の推定

L を近似アルゴリズム、 A を問題のインスタンス、 $L(A)$ を L が A に対して出力する値、 $\text{OPT}(A)$ を A の最適値とする。 $\text{OPT}(A)$ は厳密アルゴリズムに A を入力することで計算できる。 L の近似度は、最小化問題においては

$$r(L) = \max_{A \text{ is an instance}} \frac{L(A)}{\text{OPT}(A)}$$

および最大化問題においては

$$r(L) = \max_{A \text{ is an instance}} \frac{\text{OPT}(A)}{L(A)}$$

で定義される。近似度の推定は、近似アルゴリズムの性能を調べるために重要である。しかし、 $\frac{L(A)}{\text{OPT}(A)}$ および $\frac{\text{OPT}(A)}{L(A)}$ を最大化するインスタンスを発見することは一般に難しい。そこで、インスタンス A の難しさの値として $\frac{L(A)}{\text{OPT}(A)}$ および $\frac{\text{OPT}(A)}{L(A)}$ を使用することで提案手法を用いて最大値に近い値をもつインスタンスを発見することができる。

3.2 列挙アルゴリズムの計算量

列挙アルゴリズムはある特性を満たすすべての要素を出力するアルゴリズムである。列挙アルゴリズムの計算効率を評価するときは、全ての要素の列挙にかかった合計時間だけでなく、アルゴリズムが各要素を出力する最大遅延時間 (maximum delay) やならし計算時間 (amortized time) がしばしば使用される。合計時間の代わりに最大遅延時間やならし計算時間をインスタンスの難しさの値として使用することで本研究における提案方法は最大遅延時間やならし計算時間の意味で難しいインスタンスを生成することもできる。

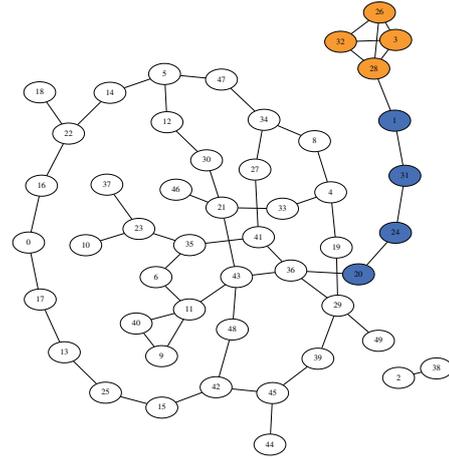


図 1: ニューラルネットワークモデルが生成した三彩色問題のインスタンスの例。バックトラッキング探索アルゴリズムは、このインスタンスを処理するために十億回以上の再帰呼び出しを必要とする。ノード 3, 26, 28, および 32 で構成される部分グラフ (図中右上端, オレンジ色) は 4 クリークを形成するため、このインスタンスは三彩色可能ではない。この 4 クリークがパス (図中青色) で大きな連結成分に接続していることが、このインスタンスを難しくしている原因である。

4. 実験

ニューラルネットワークモデルとしては 4 層の多層パーセプトロンを用いる。Adam [Kingma 14] を用いて学習を行い、学習率を 0.001, β_1 を 0.9, β_2 を 0.999 に設定する。自明なベースラインとして一様ランダムグラフモデル (Erdős-Rényi モデル) による生成と評価を繰り返す手法を用い、強力なベースラインとして三彩色問題およびグラフ同型問題でいくつかのルールベースアルゴリズムを用いる。これらのベースラインでは、アルゴリズムを使用して B (*i.e.*, 評価数の上限) 個のグラフが生成され、その中で最も難しいインスタンスが出力される。 $B = 100000$ に設定し、いずれの手法も 3 日以上経過すると強制的に停止させる。問題に応じて、出力グラフのノード数は基本的に $n = 50$ ノードに固定するが、 $n = 50$ ノードを用いたときに多くの手法が非常に難しいインスタンスを生成して比較が困難になる場合に $n = 32$ ノードに固定する。対象となる問題とアルゴリズム以下のものを用いる。

三彩色問題 (3-coloring): アルゴリズムとしては、Bréaz のヒューリスティックアルゴリズム [Bréaz 79] に基づくバックトラッキング探索 (Bréaz) を使用し、難しさの値は再帰回数とする。頂点数は $n = 50$ とする。この問題では、ベースラインとしてルールベースのアルゴリズムも使用する。

最小頂点被覆問題 (Vertex Cover): アルゴリズムとしては、極大マッチングによる上限を用いて、制約の数をより早く減らすことができる頂点を探索する分枝限定法 (B&B) を使用し、難しさの値は再帰回数とする。頂点数は $n = 50$ とする。

最大クリーク問題 (Clique): アルゴリズムとしては、Bron-Kerbosch のアルゴリズム (BK), ピボットを用いない Bron-Kerbosch のアルゴリズム (BKNP), Fast Max-Cliquer [Pattabiraman 13] (FMC) を使用し、難しさの値はそれぞれ再帰回数, 再帰回数, CPU 時間 (10^{-6} 秒) とする。頂点数は $n = 32$ とする。

表 1: 実験結果: 各値は, 5 回の試行を行い, それぞれの試行で生成した最も難しいインスタンスの難しさを平均したものである。

問題	3-coloring	Vertex Cover	Clique			Isomorphism
			BK	BKNP	FMC	
アルゴリズム	Brélaz	B&B				Nauty
ニューラルネットワーク	1151770980.6	12771.8	74499.6	4706426.4	5882966.0	9400.0
山登り法	212276998.8	46659.8	160091.8	2615672.0	195117.4	120.6
焼きなまし法	602.2	8003.2	12024.0	2518357.4	147054.4	68.4
Erdős-Rényi $p = 0.1$	937.4	761.0	86.8	105.8	27966.0	122.2
Erdős-Rényi $p = 0.5$	2.0	635.6	562.4	1503.6	36657.6	32.6
Erdős-Rényi $p = 0.9$	2.0	489.8	9365.4	327251.4	107445.0	118.0
[Cheeseman 91]	1567.6	N/A	N/A	N/A	N/A	N/A
[Hogg 94]	31708.2	N/A	N/A	N/A	N/A	N/A
[Vlasie 95]	85353.6	N/A	N/A	N/A	N/A	N/A
[Mizuno 08]	219342.2	N/A	N/A	N/A	N/A	N/A
$R(B(G_n, \sigma))$ [Neuen 17]	N/A	N/A	N/A	N/A	N/A	2700.0
$R^*(B^*(G_n, \sigma))$ [Neuen 17]	N/A	N/A	N/A	N/A	N/A	2182.0

グラフ同型問題 (**Isomorphism**): アルゴリズムとしては, Nauty [McKay 14] を使用し, 難しさの値は CPU 時間 (10^{-7} 秒) とする。頂点数は $n = 50$ とする。この問題では, ベースラインとしてルールベースのアルゴリズムも使用する。

実験結果を表 1 に示す。どのアルゴリズムに対しても, ニューラルネットワークモデルと山登り法が一貫して Erdős-Rényi モデルよりも難しいインスタンスを生成できている。特に, 三彩色問題においては, ルールベースの難しいインスタンス生成アルゴリズムに比べてもはるかに難しいインスタンスを生成できている。ニューラルネットワークモデルが生成した難しいインスタンスの例を 1 に示す。

5. 結論

本論文では, グラフ問題の難しいインスタンスを最適化問題として定式化した (問題 2, 3)。そして, これらの問題を解決するために, 山登り法, 疑似焼きなまし法, ニューラルネットワークと強化学習という三つの方法を提案した。実験では, さまざまな問題とアルゴリズムを用い, ニューラルネットワークと強化学習による手法が多くの設定において Erdős-Rényi モデルより一桁から数桁難しいインスタンスを見つけることができることを示した。特に三彩色問題では, 提案手法はルールベースのアルゴリズムよりも難しいインスタンスを発見することができた (表 1)。

謝辞

本研究は JSPS 科研費 15H01704 および JST PRESTO JPMJPR165A の助成を受けた。また, 提案手法の拡張についての実りある議論を交わして頂いた京都大学の小林靖明助教と NII の Alessio Conte 特任研究員に深く感謝の意を表す。

参考文献

- [Brélaz 79] Brélaz, D.: New Methods to Color Vertices of a Graph, *Commun. ACM*, Vol. 22, No. 4, pp. 251–256 (1979)
- [Cheeseman 91] Cheeseman, P. C., Kanefsky, B., and Taylor, W. M.: Where the Really Hard Problems Are, in *IJCAI*, pp. 331–340 (1991)

- [Hogg 94] Hogg, T. and Williams, C. P.: The Hardest Constraint Problems: A Double Phase Transition, *Artif. Intell.*, Vol. 69, No. 1-2, pp. 359–377 (1994)

- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980, (2014)

- [Ma 18] Ma, T., Chen, J., and Xiao, C.: Constrained Generation of Semantically Valid Graphs via Regularizing Variational Autoencoders, in *NeurIPS*, pp. 7113–7124 (2018)

- [McKay 14] McKay, B. D. and Piperno, A.: Practical graph isomorphism, II, *Journal of Symbolic Computation*, Vol. 60, No. 0, pp. 94 – 112 (2014)

- [Mizuno 08] Mizuno, K. and Nishihara, S.: Constructive generation of very hard 3-colorability instances, *Discrete Applied Mathematics*, Vol. 156, No. 2, pp. 218–229 (2008)

- [Neuen 17] Neuen, D. and Schweitzer, P.: Benchmark Graphs for Practical Graph Isomorphism, in *ESA*, pp. 60:1–60:14 (2017)

- [Pattabiraman 13] Pattabiraman, B., Patwary, M. M. A., Gebremedhin, A. H., Liao, W., and Choudhary, A. N.: Fast Algorithms for the Maximum Clique Problem on Massive Sparse Graphs, in *Algorithms and Models for the Web Graph*, WAW, pp. 156–169 (2013)

- [Vlasie 95] Vlasie, R. D.: Systematic generation of very hard cases for graph 3-colorability, in *ICTAI*, pp. 114–119 (1995)

- [Williams 92] Williams, R. J.: Simple Statistical Gradient-Following Algorithms for Connectionist Reinforcement Learning, *Mach. Learn.*, Vol. 8, No. 3-4, pp. 229–256 (1992)

LDA を用いた多様性を考慮する推薦システムに関する一考察

A study on recommender system considering diversity in recommendation items based on LDA

張 志穎 *1
Zhiying Zhang保坂 大樹 *1
Taiju Hosaka山下 遥 *2
Haruka Yamashita後藤 正幸 *1
Masayuki Goto*1早稲田大学
Waseda University*2上智大学
Sophia University

With the development of information technology, a huge amount of users' action history data has been accumulated on web sites. On such background, recommender system making use of these rich data has become important tool for searching contents or products. Diversifying the recommendation lists in recommender systems could potentially satisfy users' needs. In a previous research, the diversity is raised by the topic diversification method using Latent Dirichlet Allocation, but since the items belonging to the same topic are not diversified, there is a high possibility that they are similar. Therefore, this research proposes a recommendation method considering item diversification. Experimental results on MovieLens datasets demonstrate that our approach keeps accuracy produces more diversified results.

1. 研究背景と目的

近年、情報技術の発展に伴い、EC サイト等では膨大な量の購買履歴データや商品（以下、アイテム）に対する評価値データが蓄積されるようになった。このようなデータを分析することで、各ユーザの嗜好を考慮し、推定購買確率が高いアイテムを推薦するシステムが利用されている。

近年、ユーザ満足度の観点から、購買確率以外の尺度も考慮して推薦するアイテムを決定する必要性が指摘されている [McNee 06]。その尺度の一つに「多様性」がある。精度を重視した推薦では、類似したアイテム群が推薦される傾向にある。一方、多様性を考慮した推薦では、ユーザが今まで認知していなかったようなアイテムを推薦することができる可能性があるため、ユーザ満足度を向上させると考えられる [Ziegler 05]。

多様性を考慮した推薦アルゴリズムに関する研究はこれまで多く行われており、Ashkan らは、貪欲法に基づく推薦リストの構築手法をフレームワークとして定義した [Ashkan 15]。このフレームワークにおいて、学習の目的関数は、各アイテムをユーザに推薦することで得られる効用と、推薦リストとアイテムの組み合わせから計算される多様性に分割され、目的関数を最大化するアイテムを逐次的に推薦リストに追加する。

また、Xing らは、Latent Dirichlet Allocation(LDA) [Blei 03] に基づいてアイテムのトピックを抽出し、推薦リストに含まれるアイテムのトピックが多様化されるような推薦リストの構築アルゴリズムを提案した [Xing 17]。この手法は、推薦リスト全体でトピックを多様化している一方で、個々のアイテムの非類似性を保証していない。この特徴が与える影響は、ユーザが複数のトピックを好む場合により顕著に現れる。例えば、映画の推薦システムにおいて、“SF” と “ホラー” の両方のジャンルを好むユーザに 2 つの映画を推薦する場合、このユーザの嗜好に適した推薦として以下の 2 種類が考えられる。

- (a). “SF” と “ホラー” の要素を持つ映画を 2 つ推薦する
- (b). “SF” の要素を持つ映画と “ホラー” の要素を持つ映画を 1 つずつ推薦する

(a) と (b) はどちらもユーザの複数の嗜好を考慮した推薦であるが、個々のアイテムの多様性という観点からは (b) の推薦が望ましいと考えられる。

そこで本研究では、推薦リスト内のアイテム同士の類似度の増加方向に制約を加えた推薦リストの構築アルゴリズムを提案する。これにより、推薦されるアイテムのトピックの多様性だけでなく、個々のアイテムの多様性も高い推薦が可能になる。すなわち、同程度の推薦精度のもとで、より多様性の高い推薦アイテムリストを構成できると期待される。本研究では、ベンチマークデータに提案手法を適用し、精度と多様性の観点から従来手法との比較を行い、その有効性を示す。

2. 準備

2.1 Latent Dirichlet Allocation(LDA)

LDA は代表的なトピックモデルの一つであり、自然言語処理分野だけでなく、マーケティングデータにも応用がなされている。一般に、多様なユーザの購買履歴データや評価履歴データは、嗜好が全く異なるユーザによる行動履歴の集まりと仮定することが自然であり、学習データは統計的性質の異なるグループから成り立っていると考えられる。LDA などのトピックモデルでは、これらの統計的性質が異なるグループを一つのトピックとして表現する。LDA を購買履歴データへ適用すると、各ユーザにトピックの出現確率の分布、各トピックにアイテムの出現確率の分布が仮定される。ユーザによるアイテムの購買を、潜在変数であるトピックを介して表現することで、購買・被購買の関係のないユーザとアイテムの組み合わせについてもその関係性を推定することが可能となる。

M 人のユーザ集合を $\mathcal{U} = \{u_1, \dots, u_M\}$ 、 N 個のアイテム集合を $\mathcal{V} = \{v_1, \dots, v_N\}$ 、 K 個のトピック集合を $\mathcal{Z} = \{z_1, \dots, z_K\}$ をそれぞれ仮定する。また、顧客 $u_m \in \mathcal{U}$ のもとでトピック $z_k \in \mathcal{Z}$ が出現する確率を $\theta_{m,k}$ とし、そのトピック分布を $\boldsymbol{\theta}_m = (\theta_{m,1}, \dots, \theta_{m,K})^\top$ と表記する。また、トピック z_k のもとでアイテム $v_n \in \mathcal{V}$ が出現する確率を $\phi_{k,n}$ とし、そのアイテム分布を $\boldsymbol{\phi}_k = (\phi_{k,1}, \dots, \phi_{k,N})^\top$ と表記する。 $\boldsymbol{\theta}_m$ 、 $\boldsymbol{\phi}_k$ に対して、それぞれ $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_K)^\top$ 、 $\boldsymbol{\beta} = (\beta_1, \dots, \beta_N)^\top$ をパラメータとするディリクレ事前分布を仮定する。このとき、ユーザ u_m がアイテム v_n を購買する確率 $P(v_n|u_m)$ は式

連絡先: 張 志穎, 早稲田大学, 東京都新宿区 169-8555,
zhangzhiyingwsd@gmail.com

(1) で表現される。

$$P(v_n|u_m) = \sum_{k=1}^K \int \int \theta_{m,k} P(\theta_{m,k}|\alpha) \phi_{k,n} P(\phi_{k,n}|\beta) d\theta_{m,k} d\phi_{k,n} \quad (1)$$

2.2 Xing らの研究

通常の LDA に基づく推薦では、ユーザ u_m に対して推定購買確率が高くなるようなアイテムを推薦する。ここで、アイテム v_n のもとでトピック z_k が出現する確率を $\pi_{n,k}$ 、そのトピック分布を $\pi_n = (\pi_{n,1}, \dots, \pi_{n,K})^\top$ と表記すると、LDA に基づく推薦は、 $\theta_m^\top \pi_n$ を最大化するようなアイテムを逐次的に推薦リストに追加していると解釈することができる。このとき、推薦されるアイテムはユーザの好むトピックに依存して決定され、それぞれ類似したトピック分布を持つ傾向がある。

このような推薦は、ユーザの好みのトピックに応じたアイテムを推薦できているが、ユーザがまだ認知していないトピックの存在を考慮すれば、推薦リストのトピックを多様にするによって、ユーザにとってさらに魅力的なアイテムを推薦できる可能性がある。

これに対し、Xing らは、LDA に基づく推薦リストの構築アルゴリズムを拡張し、推薦の精度をある程度維持しながら多様なトピックのアイテムを推薦する手法を提案した。この手法では、既に推薦されたアイテムのトピックに対して効用を相対的に減少させる項を、推定購買確率に加算することで、ユーザの嗜好を考慮したうえで推薦リストの多様化を実現している。

各ユーザに推薦するアイテムの数を L 、ユーザ u_m が購買していないアイテム集合を \mathcal{I}_m 、ユーザ u_m に推薦するアイテム集合を \mathcal{S}_m とする ($\mathcal{S}_m \subseteq \mathcal{I}_m$)。このとき、推薦アイテム集合 \mathcal{S}_m にアイテム v_n を加えた場合の推薦の良さ $f(v_n|\mathcal{S}_m)$ は以下の式 (2) で計算される。

$$f(v_n|\mathcal{S}_m) = P(v_n|u_m) + \lambda \sum_{k=1}^K \theta_{m,k} \pi_{n,k} \prod_{v_s \in \mathcal{S}_m} (1 - \pi_{s,k}) \quad (2)$$

ただし、 λ は多様化の度合いを決定するパラメータである。また、 u_m に対する推薦リストの構築アルゴリズムを以下に示す。

Step1) $l = 1$, $\mathcal{S}_m = \left\{ \arg \max_{v \in \mathcal{I}_m} P(v|u_m) \right\}$ とする。

Step2) 式 (3) を計算して、推薦の良さを最大化するアイテム v^* を求める。

$$v^* = \arg \max_{v \in \mathcal{I}_m \setminus \mathcal{S}_m} f(v|\mathcal{S}_m) \quad (3)$$

Step3) $l \leftarrow l + 1$, $\mathcal{S}_m \leftarrow \mathcal{S}_m \cup \{v^*\}$ とする。

Step4) $l < L$ ならば Step2 へ。 $l = L$ ならば終了。

Xing らの研究では、多様性の指標も定義している。多様性は以下の式 (4) で計算される。

$$\text{diversity} = \frac{1}{M} \sum_{m=1}^M \left(1 - \frac{\sum_{v_i \in \mathcal{S}_m} \sum_{v_j \in \mathcal{S}_m \setminus \{v_i\}} \text{sim}(v_i, v_j)}{L(L-1)} \right) \quad (4)$$

ただし、 $\text{sim}(v_i, v_j)$ は π_i, π_j 間のコサイン類似度とする。

Xing らが提案したアルゴリズムによる推薦では、LDA による推薦と比較して精度が落ちる。一方で、多様性については LDA による推薦よりも優れた結果が得られる。Xing らの研究では、評価実験を通じて、精度と多様性のトレードオフの関係が示されている。推薦アルゴリズムのユーザは、多少の推薦精度の劣化を許容することで、推薦アイテムリストの多様性を高めることができる。

3. 提案手法

3.1 概要

Xing らの研究では、多様なトピックの推薦が可能となっている一方で、個々のアイテム間の非類似性は保証されていない。例えば、多くのトピックのもとで出現する複数個のアイテムを推薦した場合、推薦リストに含まれるトピックは多様であるが、推薦されるアイテム間の類似度が高くなり、ユーザの観点からの多様性が失われてしまう可能性がある。例えば、二つのトピック A とトピック B を併せ持つアイテムが複数推薦されたとしても、ユーザには類似のアイテムが推薦されているように見えてしまう。これに対し、トピック A を持つアイテムとトピック B を持つアイテムが推薦されれば、これらはユーザからもトピックの異なるアイテムが推薦されていると認識されるため、推薦アイテムリストの多様性が高いと見なされるはずである。

そこで本研究では、個々のアイテムの非類似性を考慮し、より多様な推薦リストを構築するためのアルゴリズムを提案する。提案手法では、貪欲法に基づく従来手法のフレームワークを用いて、推薦リストに含まれるアイテムとの非類似度が高くなるようなアイテムを逐次的に推薦リストに追加する。提案手法において、推薦アイテム集合 \mathcal{S}_m にアイテム v_n を加えた場合の推薦の良さ $g(v_n|\mathcal{S}_m)$ は以下の式 (5) で計算される。ただし、 γ は多様化の度合いを決定するパラメータである。

$$g(v_n|\mathcal{S}_m) = P(v_n|u_m) + \gamma \min_{v_s \in \mathcal{S}_m} (1 - \text{sim}(v_n, v_s)) \quad (5)$$

これは、Xing らの手法の式 (2) におけるトピック多様性を考慮するための右辺第 2 項を、リスト内のアイテム多様性で置き換えた式となっている。アイテム間の類似度 $\text{sim}(v_n, v_s)$ はトピック分布のコサイン類似度となっているため、トピック多様性を考慮した推薦リストを作成できると期待される。すなわち、提案手法により構築された推薦リストは、トピックに関して多様化されているだけでなく、アイテムに関しても多様化されていると考えられる。

3.2 提案アルゴリズム

Step1) $l = 1$, $\mathcal{S}_m = \left\{ \arg \max_{v \in \mathcal{I}_m} P(v|u_m) \right\}$ とする。

Step2) 式 (6) を計算して、推薦の良さを最大化するアイテム v^* を求める。

$$v^* = \arg \max_{v \in \mathcal{I}_m \setminus \mathcal{S}_m} g(v | \mathcal{S}_m) \quad (6)$$

Step3) $l \leftarrow l + 1$, $\mathcal{S}_m \leftarrow \mathcal{S}_m \cup \{v^*\}$ とする.

Step4) $l < L$ ならば Step2 へ. $l = L$ ならば終了.

4. 評価実験

提案手法の有効性を示すために、ベンチマークデータセットを用いた実験を行う。

4.1 実験概要

データセットとして、映画の評価履歴データとして公開されている MovieLens データセットを用いる。対象データのユーザ数は $M = 6,040$ 、映画数は $N = 3,706$ であり、総評価件数は 1,000,209 である。学習データとテストデータの構築およびモデルの評価は 5 分割交差検証法に基づき、ユーザごとにランダムにデータを 5 分割した。また、交差検証の各学習を行う前に、学習データ内の各ユーザの平均評価値未満のアイテムを学習データおよびテストデータから除外する。これにより、各ユーザが比較的高い平均評価値を付与するアイテム、すなわち、各ユーザの満足度が高いアイテムを推薦できるかどうかという問題設定になる。

LDA で抽出するトピック数を $K = 10$ とし、ディリクレ分布のパラメータをそれぞれ $\alpha_k = 1/K$ ($1 \leq k \leq K$), $\beta_n = 1/N$ ($1 \leq n \leq N$) とした。また、パラメータの学習は変分ベイズ法 [Beal 03] に基づいて行った。

LDA のみによる推薦 (提案手法で $\gamma = 0$ とすることに相当)、Xing らの手法による推薦と比較して提案手法の有効性を検討する。

4.2 評価指標

本研究では、Xing らの研究に準じて、二つの評価指標を用いる。まず、推薦システムに重要な評価指標として精度を評価指標とする。テストデータ内でユーザ u_m が評価を行っているアイテム集合を \mathcal{T}_m とすると、推薦の精度は以下の式 (7) で計算される。

$$\text{precision} = \frac{1}{M} \sum_{m=1}^M \frac{|\mathcal{S}_m \cap \mathcal{T}_m|}{N} \quad (7)$$

また、どれだけ多様なアイテムを推薦できているかを測る指標として、式 (4) に示した多様性指標を併せて、評価指標として用いる。

5. 実験結果

5.1 各手法における精度と多様性の関係

$L = 10$ としたときの、各手法における精度と多様性の関係を図 1 に示す。ただし、提案手法では $1.0 \times 10^{-4} \leq \gamma \leq 1.0$ 、Xing らの手法では $1.0 \times 10^{-3} \leq \lambda \leq 1.0$ を満たす複数のパラメータで実験を行い、その結果を全てプロットした。

図 1 を見ると、LDA による推薦が最も高い精度を示していることがわかる。一方、提案手法と Xing らの手法では、パラメータを変化させることで、多様性を考慮した推薦リストを得ることができる。すなわち、パラメータの設定によって、多様性を向上させると、精度的には劣化するため、図の左側に移動

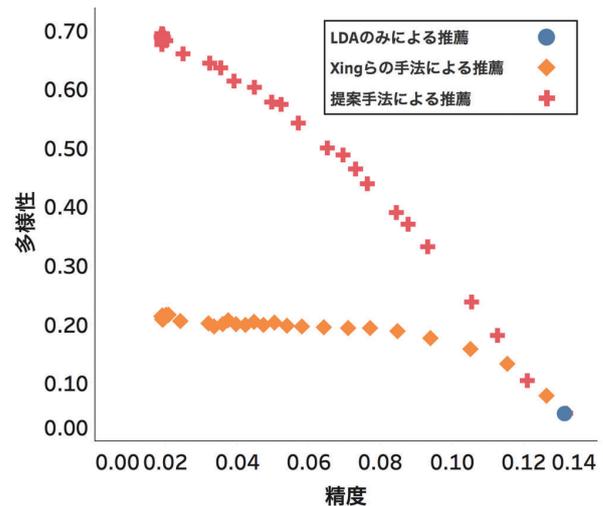


図 1: 各手法における精度と多様性の関係

すると共に、多様性が向上し、点が左上に移動する。 λ や γ の値が小さいときは、多様化の効果も小さく、LDA による推薦と同程度の結果を示しているが、これらのパラメータの値が大きくなるにつれて、推薦の精度が低下し、多様性が増加する傾向が見られた。

ここで、同じ精度では提案手法が Xing らの手法よりも高い多様性を示していることが読み取れる。提案手法は、精度の劣化に対して、多様性が向上するのが Xing らの手法よりも早く、全体として右上側のゾーンに位置している。すなわち、提案手法では Xing らの手法と同等の推薦精度を保ちながら、より多様性の高いアイテムリストをユーザに推薦することができると解釈できる。

5.2 推薦アイテム数と精度・多様性の関係

$\lambda = 0.0040$, $\gamma = 0.0004$ としたときの、各手法における推薦アイテム数 L に対する精度の変化を図 2、多様性の変化を図 3 に示す。

図 2 を見ると、推薦アイテム数 L が増加したとき、全ての手法で精度が悪化していることがわかる。これは、テストデータ数は固定であるため、推薦するアイテム数が増えると、推薦リスト中で、ユーザが評価しているアイテム数が頭打ちとなり、必然的に精度が低下するためである。特に提案手法では、推薦アイテム数の増加に対する精度の低下率が他手法と比較して大きい。これは、提案手法は推薦リストの多様性を求めるため、リストのサイズが大きくなってくると、リスト内に様々なトピックの異なるアイテムが入ってくるようになり、ユーザの嗜好から外れていくためである。

また、図 3 を見ると、比較手法では、推薦アイテム数の増加に伴う多様性の変動が小さいことがわかる。対して、提案手法では、推薦アイテム数の増加に伴って多様性が増加することを確認した。提案手法では、推薦アイテムリスト内の多様性を維持するようなアルゴリズムになっているため、リストサイズが大きくなると、それに併せて多様性も向上していく性質がある。

以上の結果から、提案手法は推薦アイテム数の変化に伴って精度と多様性が大きく変動するといえる。これは、提案手法が個々のアイテムの類似度に対して制約を設けているため、推薦アイテム数を増加させた場合に、制約が過度に強くなってしまいうことに起因する。すなわち、推薦リスト内の多様性をあまり

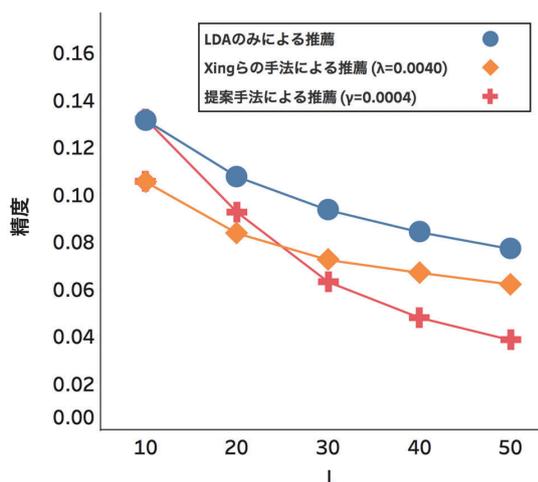


図 2: 推薦アイテム数と精度の関係

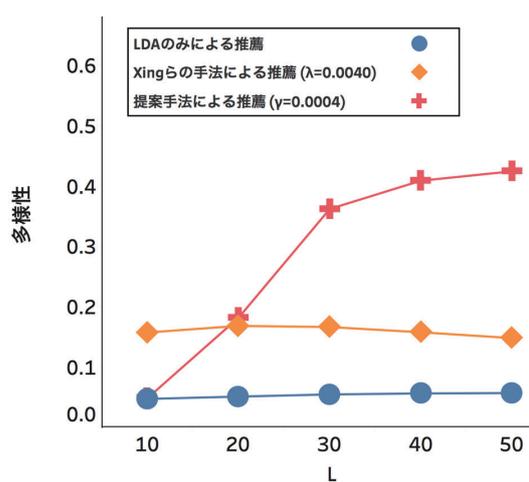


図 3: 推薦アイテム数と多様性の関係

大きくし過ぎることなく、推薦アイテム数を増加させたい場合には、 γ の値を小さくとり、提案手法の制約を緩和させる必要がある。

6. 結論と今後の課題

本研究では、個々のアイテムの非類似性を考慮することで、精度を保ちながら多様性のある推薦を行うための推薦リスト構築アルゴリズムを提案した。また、ベンチマークデータに提案手法を適用し、その有効性を示した。

MovieLens データセットを用いた評価実験では、従来手法と比較して、提案手法が同程度の精度でより高い多様性を示した。すなわち、提案手法を用いることで、推薦精度を維持しつつ、推薦リストの多様性を高めることができ、ユーザ満足度のさらなる向上を見込むことができる。しかしながら、提案手法は、推薦アイテム数の変化に対して精度および多様性が大きく変動し、その性能が不安定であることも確認した。そのため、実際に提案手法を用いる際には推薦アイテム数に応じてパラメータを調整する必要があるといえる。今後は、パラメータを調整するためのコストを考慮した評価を行うことが課題として挙げられる。

また、今後の課題として、実際の推薦システムに提案手法を組み込んで、AB テストなどの手法を用いてその効果を定量的に評価することが必要である。精度のみではなく、多様性を考慮した提案手法では、実際の推薦によるモデルの評価は特に重要である。さらに、被評価回数のないアイテムに関して、購買確率や類似度を精度よく推定することも必要である。例えば、映画のテキスト情報を、LDA や Doc2vec[Le 14] といった手法により解析することで、新規の映画に対してもその類似度を精度良く推定することができる可能性がある。

7. 謝辞

本研究を進めるに当たり、早稲田大学 創造理工学部 経営システム工学科教授後藤正幸先生からは多大な助言を賜りました。厚く感謝を申し上げます。また、本論文を作成するにあたり、ご指導いただきました上智大学理工学部 情報理工学科助教山下遥先生にも心より御礼申し上げます。更に、様々な議論やサポートをしていただいた早稲田大学 創造理工研究科 修士課程 張笑エン氏、保坂大樹氏、大堀祐一氏には丁寧かつ熱心

なご指導を賜りました。ここに深く感謝の意を表します。

参考文献

- [Ashkan 15] Ashkan, A., Kveton, B., Berkovsky, S. and Wen, Z.: Optimal Greedy Diversity for Recommendation, *In Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence*, pp.1742-1748 (2015).
- [Blei 03] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol.3, pp.993-1022 (2003).
- [McNee 06] McNee, S. M., Riedl, J. and Konstan, J. A.: Being accurate is not enough: how accuracy metrics have hurt recommender systems, *In Proceedings of International Conference on Human Factors in Computing Systems*, pp.1097-1101 (2006).
- [Le 14] Le, Q. and Mikolov, T.: Distributed Representations of Sentences and Documents, *In Proceedings of Thirty-First International Conference on Machine Learning*, pp.1188-1196 (2014).
- [Xing 17] Xing, X., Sha, C. and Niu, J.: Improving Topic Diversity in Recommendation Lists: Marginally or Proportionally?, *In Proceedings of APWeb-WAIM 2017*, pp.142-150 (2017).
- [Ziegler 05] Ziegler, C. N., McNee, S. M., Konstan, J. A. and Lausen, G.: Improving recommendation lists through topic diversification, *In Proceedings of Association for Computing Machinery on World Wide Web*, pp. 22-32 (2005).
- [Beal 03] Beal, M. J.: Variational Algorithms for Approximate Bayesian Inference, PhD thesis, Gatsby Unit, University College London (2003).

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

[1Q4-J-2] Machine learning: knowledge representation and logic

Chair:Takuya Hiraoka Reviewer:Yuzuru Okajima

Tue. Jun 4, 2019 5:20 PM - 6:20 PM Room Q (6F Meeting room, Bandaijima bldg.)

[1Q4-J-2-01] Unsupervised Grounding of Plannable First-Order Logic Representation from Images

○Masataro Asai¹ (1. IBM Research Tokyo)

5:20 PM - 5:40 PM

[1Q4-J-2-02] Learning Logic Programs from Noisy State Transition Data

○Yin Jun Phua¹, Katsumi Inoue^{1,2} (1. Tokyo Institute of Technology, 2. National Institute of Informatics)

5:40 PM - 6:00 PM

[1Q4-J-2-03] Adversarial Invariant Feature Learning with Accuracy Constraint for Domain Generalization

○Kei Akuzawa¹, Yusuke Iwasawa¹, Yutaka Matsuo¹ (1. The University of Tokyo)

6:00 PM - 6:20 PM

Unsupervised Grounding of Plannable First-Order Logic Representation from Images

Masataro Asai

IBM Research

Recently, there is an increasing interest in obtaining the relational structures of the environment in the Reinforcement Learning community. However, the resulting “relations” are not the discrete, logical predicates compatible to the symbolic reasoning such as classical planning or goal recognition. Meanwhile, Latplan [Asai 18] bridged the gap between deep-learning perceptual systems and symbolic classical planners. One key component of the system is a Neural Network called State AutoEncoder (SAE), which encodes an image-based input into a propositional representation compatible to classical planning. To get the best of both worlds, we propose First-Order State AutoEncoder, an unsupervised architecture for grounding the first-order logic predicates. Each predicate models a relationship between objects by taking the interpretable arguments and returning a propositional value. In the experiment using 8-Puzzle and a photo-realistic Blocksworld environment, we show that (1) the resulting predicates capture the interpretable relations (e.g. spatial), (2) they help obtaining the compact, abstract model of the environment, and finally, (3) the resulting model is compatible to symbolic classical planning. **This paper is an extended abstract of a paper accepted in International Conference on Automated Planning and Scheduling, Planning and Learning Track (2019). We cut out most of the details to meet the space requirement. For details/citations please refer to the original material.**

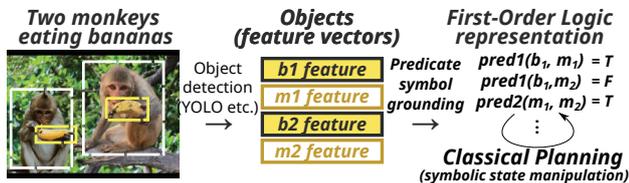


Fig. 1: Predicate symbol grounding (PSG) process for identifying the predicates and obtaining the First Order Logic (FOL) representation of the environment for symbolic reasoning. In this example, an anonymous binary predicate $pred_1$ can be interpreted by humans as something like *eating(object, subject)*.

1. Introduction

Recent success in the latent space classical planning [Asai 18, Latplan] shows a promising direction for connecting the neural perceptual systems and the symbolic AI systems. Latplan is a straightforward system built upon a state-of-the-art Neural Network (NN) framework (Keras, Tensorflow) and Fast Downward classical planner [Helmert 04]. It builds a set of propositional state representation from the raw observations (e.g. images) of the environment, which can be used for classical planning as well as goal recognition [Amado 18]. However, Latplan still contains many rooms for improvements in terms of the interpretability and the scalability which are trivially available in the symbolic systems. An instance of such limitations of Latplan is that the reasoning is performed on a propositional level, missing the ontological commitment of the First-Order Logic (FOL) that *the world comprises objects and their relations* [Russell 95].

FOL is a *structured* representation, which offers some extent of interpretability compared to the *factored* representation of propositional logic formula [Russell 95]. Even if the predicate symbols discovered by a *Predicate Symbol Grounding* system (Fig. 1) are machine-generated anonymous symbols (not the human-originated symbols assigned by manual tagging), the structures help humans interpret the meaning of the relations from the several instances of the argument list (objects) that make the predicate true. For example, when two propositions $pred(0,1)$ and

$pred(1,2)$ are true, we can guess the meaning of $pred$ as $+1$, or given $pred(monkey, banana)$ being true, the meaning of $pred$ would be something like *eating* or *holding*. This is impossible in a propositional representation where only the variable indices and the truth values are known.

In this paper, we propose First-Order State AutoEncoder (FOSAE, Fig. 2), a NN architecture which, given the feature vectors of the objects in the environment, automatically learns to identify a set of predicates (relations) as well as to select the appropriate objects as the arguments for the predicates. The resulting representation is compatible to classical planning. We do not address the object recognition problem, whose task is to extract the object entities from a raw observation. We rather assume that they are already extracted by an external system and converted into the feature vectors, given the recent success of object detection methods like YOLO [Redmon 16] in image processing. While FOSAE is in principle data-format (e.g. images, text) independent, we focus on the image-based input in this paper.

FOSAE provides a higher-level generalization and the more compact model by adding a constraint that the extracted relations are common to multiple tuples of objects. Ideally, predicates model the commonalities between the multiple instantiations of its arguments, rather than rote learning some unrelated combinations. In order to discover such predicates, our framework ensures that a single predicate is applied to the different arguments *within* the same observation. Otherwise, the network may choose to apply them to the same or the very narrow combinations of arguments in every observations, resulting in an inflexible predicate that just remembers some combinations. Since the weights used to model the predicates are utilized multiple times, this also reduces the number of weight parameters required to model the environment.

2. Related Work

Recently, there are increasing interest in the effectiveness of finding “relations” in Deep Reinforcement Learning [Mnih 15, Zambaldi 18, Battaglia 18, DRL] community. In this paper, we address the following issues in these work:

Human Supervision. Providing a relational dataset as an input (as in [Battaglia 18] and neural theorem proving), or a probabilistic

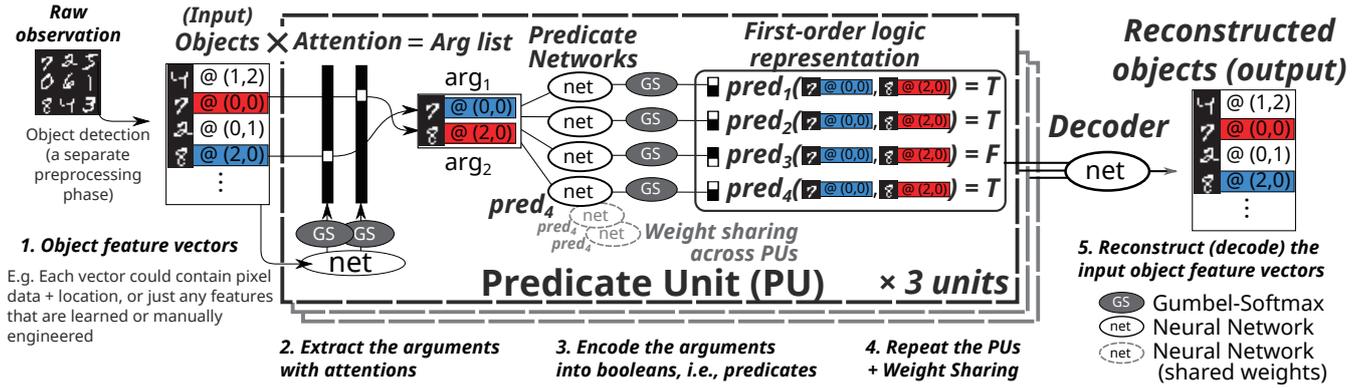


Fig. 2: A First-Order State AutoEncoder (FOSAE) with $P = 4$ predicates, arity $A = 2$, and $U = 3$ Predicate Units. In this example, a feature vector consists of the pixel values and the (x, y) location of an 8-Puzzle tile.

logic program containing predicate symbols which defines a network, exhibits the knowledge acquisition bottleneck as the predicates are grounded by humans and thus the system relies on human knowledge.

Compatibility to the symbolic systems. Relational structures in existing work do not return explicit boolean values even when the environment is deterministic, fully observable and discrete in nature. This makes them incompatible to symbolic systems such as classical planners or goal recognition. Ideally, systems should guarantee that a discrete environment is represented in a discrete form, and numeric variables (such as those handled by numeric planner) should be introduced only when necessary.

Interpretability. Some networks use real-valued soft attentions (probability) to model the objects that take part in a relation, which are similar to the predicate arguments. However, the relations resulted from soft attentions are hard to interpret due to the ambiguity, e.g. “Bob has-a ‘50% dog and 50% cat’” in a “has-a” relation. Continuous outputs of the relational structures are also difficult to interpret.

Scalability for higher arities. Some work assumes the binary relations and enumerates $O(N^2)$ pairs for N objects. The explicit structure is impractical for larger arities A because the network size $O(N^A)$ increases exponentially.

3. High-Level Overview

In order to find a first-order logic representation of the environment from raw data, we perform the following processes (Fig. 1): (1) *Object detection* identifies and extracts a set of regions from the raw data that contain objects. (2) *Predicate symbol grounding* (PSG) finds the boolean functions that take several object feature vectors as the arguments.

While both processes are nontrivial, there are significant advances in (1) recently. Object recognition in computer vision e.g. [Redmon 16, YOLO], or named entity (noun / “objects”) recognition [Nadeau 07, Mohit 14] in Natural Language Processing, are both becoming increasingly successful. In this paper, therefore, we do not address (1) and use a dataset that is already segmented into image patches and bounding boxes. In principle, we could extract the object vectors with these external systems.

Next, PSG identifies a finite set of boolean functions (predicates) from the feature input, by learning to select the argument

list from the input and detecting the common patterns between the objects that define a relation. As a result, we obtain the first-order logic representation of the input as a list of FOL statements such as $pred_2(obj_1, obj_2)=true$, where the system automatically learns to extract the arguments from the inputs, and also decides the semantics of the predicates by itself, in an unsupervised manner.

We now introduce the core contribution of this paper, First-Order State AutoEncoder (FOSAE, Fig. 2), a neural architecture which performs PSG and obtains a representation compatible to symbolic reasoning systems such as classical planners.

(Fig. 2, 1) Overall, the system follows the autoencoder architecture that takes feature vectors of multiple objects in the environment as the input and reconstructs them as the output. The form of the feature vector for each object is entirely problem/environment dependent: It could be a hand-crafted feature vector, a flattened vector of the raw pixel values for the object, or a latent space vector automatically generated from the image array by an additional feature learning system (such as an autoencoder).

FOSAE consists of multiple instances of *Predicate Unit*, a unit that (1) learns to extract an argument list from the input and (2) computes the boolean values of the predicates given the extracted argument list. The number of units U , the arity of predicates A and the number of predicates P are hyperparameters which should be sufficiently large so that the network can encode enough information into a boolean vector and then reconstruct the input. If the network does not converge into a sufficiently low reconstruction loss, we can increase these parameters until it does. How to run this iteration efficiently is a hyperparameter tuning problem which is out of the scope of this paper.

(Fig. 2, 2) In order to extract the arguments of the predicates, we use multiple attention networks. The use of attention avoids enumerating $O(N^A)$ object tuples for N objects as was done in the previous work. There are A attentions in each PU, thus each PU extracts A objects from the N objects in the input. With U PUs, there are $U \times A$ attentions.

An attention network is implemented as a 2 fully-connected networks ending with a Gumbel-Softmax activation. Unlike previous work which uses a Softmax in the output, where the attention vectors take the continuous probability values produced by Softmax, we instead use Gumbel-Softmax which converges to a discrete one-hot vector so that the meaning of the extracted objects are

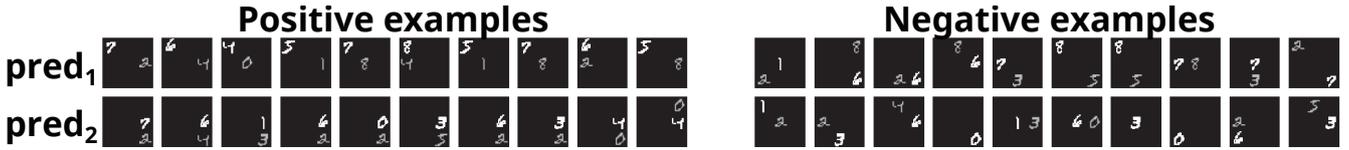


Fig. 3: The positive/negative examples of the arguments for the first 6 predicates of $(U, A, P) = (25, 2, 50)$. The first/second argument is visualized in white / gray.

clear. For example, if an attention vector for an argument takes a value $(0, 1, 0)$, it is clearly extracting the 2nd object in 3 objects, while if it were $(0, 0.5, 0.5)$, it is unclear what was selected.

(Fig. 2, 3) Next, in each u -th PU, a set of NNs called *Predicate Network* (PN) using Gumbel-Softmax takes the arguments $\mathbf{g}_u = (\mathbf{g}_{u1} \dots \mathbf{g}_{uA})$ and outputs a discrete 1-hot vector of 2 categories, which means true if the first cell is 1, and false otherwise. There are P PNs where each PN $pred_p$ ($1 \leq p \leq P$) returns a single boolean value and models a first order predicate $pred_p(\mathbf{g}_{u1} \dots \mathbf{g}_{uA}) \in \{0, 1\}$. The boolean values have the same role as the representation discovered by the propositional SAE.

(Fig. 2, 4) Attentions and PNs form a single PU. We repeat such PUs U times, which results in $U \times P$ total propositions. While the weights in the attention functions (att_{ua}) are specific to each PU, the PN weights for $pred_p$ are shared across PUs (hence it lacks the subscript u here). This makes the boolean function $pred_p$ in different PUs identical to each other, and force them to learn a common relations among the different arguments because PNs take different arguments in each PU.

(Fig. 2, 5) Finally, the input object vectors are reconstructed from the propositional representation by concatenating the boolean outputs from all PUs and feeding them to the decoder.

4. Modeling 8-Puzzle Instances

In order to evaluate FOSAE, we created a toy environment of 8-puzzle states using the feature vectors shown in Fig. 5. Each feature vector as an object consists of 15 features, 9 of which represent the tile number (object ID) and the remaining 6 represent the coordinates. Each data point has 9 such vectors, corresponding to the 9 objects in a single tile configuration. We generated 20000 transition inputs (state pairs) which are divided into 18000 (training set) and 2000 transitions (test set).

Previous work on relational structures have not yet provided evidence that they actually help modeling the environment and extract the abstract knowledge. For example, it is possible that even if a relational structure like RN [Santoro 17] extracts multiple arguments, the succeeding layers may ignore some arguments by assigning zero weights, essentially modeling just unary predicates (i.e. attributes) rather than the structural relationships.

We made the contour plots (Fig. 6) of the reconstruction errors for the test set with various U, P, A , and compared their Pareto fronts. For the same (U, P) pair, the size of the bottleneck layer (propositional vector) is $U \times P$ regardless of A , which makes the direct comparison between different A feasible. We see that the arity plays a critical role in finding the more compact information, demonstrating that structural relations contribute to building an abstract representation.

We also compared the number of trainable parameters (weights)

A	U	P	Propositions	Trainable parameters
1	18	5	90	287343
2	9	6	54	268273
3	9	7	63	303302
9	1	171	171	811828
SAE (Asai 2018)			18	3404467

表 1: Configurations $(U, P) \in [1, 20]^2$ for each A that achieved the reconstruction error ≤ 0.1 with the smallest trainable parameters.

in the network because for the same (U, P) , the larger arity means the larger number of parameters in the networks which may help the training. Table 1 shows the models with the fewest parameters among those achieved the reconstruction error ≤ 0.1 for each A .

Next, we show how the hard attentions make the predicates interpretable through visualization. In principle, we can visualize the objects in the images selected by the attentions (e.g. monkeys, bananas in Fig. 1) using a decoder function that reconstructs the regions from feature vectors. Fig. 3 shows the visualizations of the arguments given to the predicate networks. Each subfigure is a visualization of an argument list vector $\mathbf{g}_u = (\mathbf{g}_{u1}, \mathbf{g}_{u2})$ randomly sampled from the dataset. We humans could recognize the patterns that are shared on the left hand side (positive examples) of each row, which is not available in the propositional representation.

5. Evaluating Classical Planning Capability

We show that the FOL representation generated by FOSAE is a feasible and sound representation for classical planning.

We tested the FOSAE-generated representation with AMA₁ PDDL generator [Asai 18] and the Fast Downward [Helmert 04] classical planner.

5.1 8 Puzzle

Omitted due to space.

5.2 Photo-Realistic Blocksworld

The dataset generator produces a 300x200 RGB image and a state description which contains the bounding boxes (bbox) of the objects. Extracting these bboxes is an object recognition task we do not address in this paper, and ideally, should be performed by a system like YOLO [Redmon 16]. We resized the extracted image patches in the bboxes to 32x32 RGB, flattened it into a 3072-D vector, and concatenated it with the bbox vector. The bbox vector is 200-dimensional and is generated by discretizing (x_1, y_1, x_2, y_2) by 5 pixels and encoding it as a 1-hot vector (60/40 categories for each x/y -axis), resulting in 3072+200=3272 features per object.

We then solved 30 planning instances with 3 blocks, generated by taking a random initial state and choosing the goal states by the



Figure 4: (middle) The initial/goal state of a Blocksworld instance. (right) The solution to this problem reconstructed from the latent vector. It unpolishes the red cube, then moves the cylinder, the red cube, the yellow cube and then polishes the yellow cube.

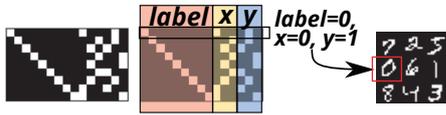


Figure 5: A single 8-puzzle state as a 9×15 matrix, representing 9 objects of 15 features. The first 9 features are the tile numbers and the other 6 features are the 1-hot x/y -coordinates.

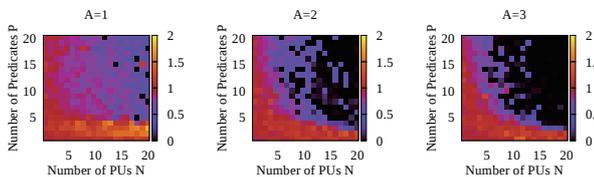


Figure 6: Contour plots of the reconstruction error of the test set for $A=1,2,3$, $(U, P) \in [1..20]^2$. It shows that the larger arity helps learning the compact representation.

3, 7, or 14 steps random walks (10 instances each). The system correctly solved all instances, where the correctness of the plans are checked manually. Fig. 4 shows an example solution generated from the intermediate states of the plan.

6. Discussion and Conclusion

We proposed First-Order State AutoEncoder, a neural architecture which grounds/extracts first order logical predicates from the environment without human supervision. Unlike any existing work to our knowledge, the training is fully automated (no manual tagging / no predefined reinforcement signals) and the resulting representation is interpretable, verifiable and compatible to symbolic systems such as classical planners.

We do not claim that we fully solved the FOL generalization because the learned FOL statements are quantifier-free, grounded



Figure 7: An example Blocksworld transition. Each state has a perturbation from the jitter in the light positions and the ray-tracing noise. Other objects may intrude the extracted regions. Objects have the different sizes, colors, shapes (cube or cylinder) and surface materials (metal or rubber).

representation that is essentially equivalent to the propositional statements. However, this work is an important step toward the full FOL generalization including quantification because quantifying a FOL formula requires a set of predicate symbols in the first place.

参考文献

- [Amado 18] Amado, L., Pereira, R. F., Aires, J., Magnaguagno, M., Granada, R., and Meneguzzi, F.: Goal Recognition in Latent Space (2018)
- [Asai 18] Asai, M. and Fukunaga, A.: Classical Planning in Deep Latent Space: Bridging the Subsymbolic-Symbolic Boundary, in *Proceedings of AAAI Conference on Artificial Intelligence* (2018)
- [Battaglia 18] Battaglia, P. W., Hamrick, J. B., Bapst, V., Sanchez-Gonzalez, A., Zambaldi, V., Malinowski, M., Tacchetti, A., Raposo, D., Santoro, A., Faulkner, R., et al.: Relational inductive biases, deep learning, and graph networks, *arXiv preprint arXiv:1806.01261* (2018)
- [Helmert 04] Helmert, M.: A Planning Heuristic Based on Causal Graph Analysis, in *Proceedings of the International Conference on Automated Planning and Scheduling (ICAPS)*, pp. 161–170 (2004)
- [Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., et al.: Human-Level Control through Deep Reinforcement Learning, *Nature*, Vol. 518, No. 7540, pp. 529–533 (2015)
- [Mohit 14] Mohit, B.: Named Entity Recognition, in *Natural language processing of semitic languages*, pp. 221–245, Springer (2014)
- [Nadeau 07] Nadeau, D. and Sekine, S.: A Survey of Named Entity Recognition and Classification, *Linguisticae Investigationes*, Vol. 30, No. 1, pp. 3–26 (2007)
- [Redmon 16] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A.: You Only Look Once: Unified, Real-Time Object Detection, in *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779–788 (2016)
- [Russell 95] Russell, S. J., Norvig, P., Canny, J. F., Malik, J. M., and Edwards, D. D.: *Artificial Intelligence: A Modern Approach*, Vol. 2, Prentice hall Englewood Cliffs (1995)
- [Santoro 17] Santoro, A., Raposo, D., Barrett, D. G., Malinowski, M., Pascanu, R., Battaglia, P., and Lillicrap, T.: A simple neural network module for relational reasoning, in *Advances in neural information processing systems*, pp. 4967–4976 (2017)
- [Zambaldi 18] Zambaldi, V., Raposo, D., Santoro, A., Bapst, V., Li, Y., Babuschkin, I., Tuyls, K., Reichert, D., Lillicrap, T., Lockhart, E., et al.: Relational Deep Reinforcement Learning, *arXiv preprint arXiv:1806.01830* (2018)

ノイズを含む遷移データからの論理プログラム学習

Learning Logic Programs from Noisy State Transition Data

ポア インジュン^{*1} 井上 克巳^{*1*2}

Yin Jun Phua

Katsumi Inoue

^{*1}東京工業大学

Tokyo Institute of Technology

^{*2}国立情報学研究所

National Institute of Informatics

Real world data are often noisy and fuzzy. Most traditional logical machine learning methods require the data to be first discretized or pre-processed before being able to produce useful output. Such short-coming often limits their application to real world data. On the other hand, neural networks are generally known to be robust against noisy data. However, a fully trained neural network does not provide easily understandable rules that can be used to understand the underlying model. In this thesis, we propose a Differentiable Learning from Interpretation Transition (δ -LFIT) algorithm, that can simultaneously output logic programs fully explaining the state transitions, and also learn from data containing noise and error.

1. はじめに

解釈遷移からの学習 (Learning from Interpretation Transition; **LFIT**) はダイナミックなシステムから解釈可能なルールを学習するアルゴリズムである。ダイナミックなシステムから観測した状態遷移を入力とし、LFIT アルゴリズムはその状態遷移を満たす論理プログラム (normal logic program; **NLP**) を出力する。得られた NLP より、システム内の各コンポーネントの関係性が明らかになる。その関係性を利用し、システムの将来的な状態の予測や、ある理想の状態への制御が可能となる。ロボット工学の分野では、周りの環境をモデル化することによりプランニングなどが可能となる [5]。生物の分野では、遺伝子間の関係性が新しい治療の発見などにつながる [7]。

LFIT アルゴリズムは主にシンボリック手法 [6] とニューラルネットワーク手法 [3] の二つの手法で実装されている。シンボリック手法では論理演算などを用いて NLP を学習する。入力の状態遷移はすべて正例および負例として捉え、各遷移ごとに学習した NLP がすべての例を満たすように論理演算を行う。これにより得られた NLP はすべての遷移に対して一貫であることが保証される。しかし、この手法にはいくつかの問題点があり、その一つとしてノイズが含まんだ入力に対して頑健でない。

一方、統計的機械学習がノイズに対して頑健であるとされている [8, 9]。従って、ニューラルネットワーク手法ではノイズへの頑健性が期待されている。先行研究ではニューラルネットワークを用いて LFIT アルゴリズムを実装する可能性を示した [3]。しかし [3] では、ノイズへの頑健性が調べられていない。

一般的に統計的機械学習およびニューラルネットワークの機械学習手法が近年普遍化している。その理由の一つとして、実応用での有効性が普遍化を促していると考えられる。しかし多くの分野に応用されていくに連れ、いくつかの弱点が明らかとなった。学習を終えて得られたモデルが人間によって解釈不可能であることが医療分野などでの応用の大きな妨げとなっている。ニューラルネットワークは一般的にどの程度学習データ以外のものまで一般化できるか、なにを学習できたか調べるのが困難である。従って、データに隠れたバイアスが存在したときに、その問題を発見するのがとても困難である。

本研究では、微分可能な LFIT アルゴリズム (δ -LFIT) を提

案する。 δ -LFIT はエンドツーエンドで微分可能なアルゴリズムである。シンボリック手法でのノイズの頑健性のなさ、および統計的機械学習での解釈不能なモデルしか得られない問題を、 δ -LFIT を通して解決する。 δ -LFIT でのノイズに対する頑健性、さらに少量のデータから学習が可能であること、そして出力が人間にとって解釈可能であることを示す。

本論文ではまず、論理プログラムおよび LFIT に関する必要な知識について述べる。次に、提案手法の δ -LFIT のアルゴリズムを説明する。そして本研究で行われた実験をいくつか示し、最後に考察および関連研究について述べる。

2. 背景

ここでは本研究を理解する上で必要な論理プログラムおよび LFIT に関する背景知識について述べる。

2.1 論理プログラム

NLP は

$$A \leftarrow A_1 \wedge \dots \wedge A_m \wedge \neg A_{m+1} \wedge \dots \wedge \neg A_n \quad (1)$$

の形式をとったルールの集合である。ここで A 及び A_i はアトムである ($n \geq m \geq 0$)。任意の (1) の形式をとるルール R において、 A は R のヘッドであり $h(R)$ で表す。そして、 \leftarrow の右辺の連言は R のボディであり R のボディで現れるリテラルの集合を $b(R) = \{A_1, \dots, A_m, \neg A_{m+1}, \dots, \neg A_n\}$ で表し、 R のボディで正リテラルとして現れるアトムを $b^+(R) = \{A_1, \dots, A_m\}$ 、負リテラルを $b^-(R) = \{A_{m+1}, \dots, A_n\}$ と表す。

NLP に出現する全てのアトムの集合をエルブラン基底 \mathcal{B} と表す。エルブラン解釈 I はエルブラン基底 \mathcal{B} の部分集合であり、各アトムへの真偽値の割り当てである。ルール R および解釈 I が与えられ、 $b^+(R) \subseteq I$ および $b^-(R) \cap I = \emptyset$ が $h(R) \in I$ を含意する時、解釈 I はルール R を満足するという。無矛盾な解釈 I が P の全てのルールを満足する時、 I は P のモデルである。論理プログラム P 及びエルブラン解釈 I を考える時、 T_P オペレータは $T_P : 2^{\mathcal{B}} \rightarrow 2^{\mathcal{B}}$ の対応である。この時 T_P オペレータは

$$T_P(I) = \{h(R) \mid R \in P, b^+(R) \subseteq I, b^-(R) \cap I = \emptyset\} \quad (2)$$

と定義する。

状態が同期的に変化していくシステムを表現するには、(1)を

$$A^{t+1} \leftarrow A_1^t \wedge \dots \wedge A_m^t \wedge \neg A_{m+1}^t \wedge \dots \wedge \neg A_n^t \quad (3)$$

のようにダイナミックな形式にできる。ここで、 t は時間ステップであり、 $t+1$ は次の時間ステップとして考える。つまり、(3)では、時間 t で A_1, \dots, A_m が真、そして A_{m+1}, \dots, A_n が偽である時、時間 $t+1$ で A が真となることを表している。

2.2 LFIT

解釈遷移の集合 E が与えられた時、その全ての遷移 $(I, J) \in E$ について $J = T_P(I)$ を満たす論理プログラム P を学習するアルゴリズムをLFITと呼ぶ[4]。いくつかのLFITアルゴリズムが提案されている[3, 6]。LFITの主な目的は対象システムのダイナミクスを説明するNLPを自動的に学習すること。

LFITは、状態の遷移に注目している。解釈 I があるシステムの t 時点での状態を表している時、同システムの $t+1$ 時点での状態 J もまた解釈である。この場合、 (I, J) がLFITで注目している解釈遷移となり、システムが I から J へ遷移していることを表す。

ルール R および解釈遷移 (I, J) が与えられ、 $b^+(R) \subseteq I$ and $b^-(R) \cap I = \emptyset$ が $h(R) \in J$ を含意する時かつその時に限り R は遷移 (I, J) と一貫であるという。 R が得られた全ての解釈遷移 $I \in E$ と一貫している時、 R が E と一貫であるという。また、 P のすべてのルール R が E と一貫である時、 P が E と一貫であるという。

論理演算を用いたLFITアルゴリズムの実装はいくつかある。ボトムアップ手法では最も特殊なルール、つまり最初はどんな解釈遷移とも一貫とならないようなルールから開始し、一般かを用いながら条件を弱めていく。トップダウン手法では最も一般的なルール、つまり最初からどんな解釈遷移にも適応できてしまうようなルールから開始し、反例を見つけながら特殊化を繰り返し最小のNLPを学習する手法である。

3. δ -LFIT

ここでは本研究での提案手法 δ -LFITについて説明する。 δ -LFITは簡単に言うとルール分類器として見なすことが可能。与えられた入力の解釈遷移の中に、あるルールが存在するか存在しないかを見分けることにより、結果的にNLPを学習することが可能となる。LFIT問題を分類問題と見立て、 δ -LFITの損失関数が実際に解釈遷移内に存在するルールとモデルが予測したルールとの交差エントロピーとなる。その損失関数を勾配降下法を用いてモデルを学習させることが可能となる。

3.1 ルールの分類

ルールを分類するには、まずあるあらゆるルールを列挙しなければならない。エルブラン基底 B が与えられた時、式3の形をとるルールは制限なしでは無限にある。

まず、ルールを簡略化する演算を定義する。

定義 1 (ルールの簡略化) ルールは以下の演算で簡略化可能:

- $a \wedge a$ は a に簡略化する
- $\neg a \wedge \neg a$ は $\neg a$ に簡略化する
- $a \wedge \neg a$ および $\neg a \wedge a$ は \perp に簡略化する

ここで a はアトムである。

\perp はルールに空のボディと同等である $a \leftarrow$ 。

以上の定義を利用し、最小ルールを定義する。

定義 2 (最小ルール) 最小ルールとはこれ以上簡略化できないルールである。

これらの定義ではアトムの順番は無視できるものとしている。 $a \wedge b$ も $b \wedge a$ もどちらも最小ルールである。

最小ルールのみ考慮することで、分類する対象のルールの数が有限となった。特に、同じアトムが2回以上出現することがないので、ルールの長さが最長 $\|B\|$ となる。これにより、すべてのルールを列挙することが可能となった。

すべてのエルブラン基底 B について、すべてのルールを含む有限順序集合 $\tau(B)$ を定義する。分類問題では、各クラスがどのルールに対応しているかがとても重要である。従って、ルールから自然数への写像を定義する。

その定義の前、まずいくつかの予備定義を説明する。

定義 3 (ルール長) ルール $R \in \tau(B)$ の長さは $\|b(R)\|$ として定義する。

定義 4 (順序集合の要素のインデックス) 順序集合 S が与えられた時、要素 $e \in S$ のインデックスは $\sigma_S(e) = \|S_{<e}\|$ として定義され、 $\sigma_S: S \mapsto \mathbb{N}$ そして $S_{<e} = \{x \mid x < e, x \in S\}$ である。

定義 5 (順序エルブラン基底) 順序エルブラン基底 B_o は B と同じ要素を含む、ただし順序エルブラン基底では $<$ の関係が成り立つ。

B_o の $<$ 関係は適当に決めてよい。しかし本論文では便宜上主に辞書順とします。ルールの集合 $\tau(B_o) = \{R \mid \|b(R)\| \leq l, R \in \tau(B_o)\} \subseteq \tau(B_o)$ として定義し、ルール長 l 以下の全てのルールを含んでいる。そのルールの集合の大きさは以下の式によって得られる:

$$\|\tau_l(B_o)\| = \begin{cases} 1 & l = 0, \\ \|\tau_{l-1}(B_o)\| + \binom{n}{l} \times 2^l & l > 0. \end{cases}$$

ここで $n = \|B_o\|$ はエルブラン基底の要素数であり $\binom{n}{k}$ は二項係数である。

また、ルール長がちょうど l の全てのルールを含む順序集合 $\tilde{\tau}_l(B_o) = \{R \mid \|b(R)\| = l, R \in \tau(B_o)\}$ を考えたとき、この集合内の順序関係はまず負アトムの位置によって決まる。負アトムを1で表し、正アトムを0として表した時、その順序は表された2進数の大小関係によって決まる。例として、 $\{a, b, \neg c\}$ は $(0, 0, 1)$ になり、左が最下位ビットとして捉えた時に 100_2 として表すことができる。この関係性では、 $\{a, b\} < \{a, c\} < \{\neg a, b\} < \{\neg b, c\} < \{\neg a, \neg c\}$ の順序が成り立つ。

次に、ルールのインデックス $\sigma_{\tau(B_o)}(R)$ について説明する。ルール R のインデックスは以下の式によって得られる:

$$\sigma_{\tau(B_o)}(R) = \|\tau_{l-1}(B_o)\| + \sigma_{\tilde{\tau}_l(B_o)}(R)$$

ここで $l = \|b(R)\|$ ルール R の長さである。

あるエルブラン基底における全てのルールのインデックスを表1に表す。

ひとつのルールにて、あるアトムは正か負として現れる、またはそのルールに現れないという3つの可能性を考えた時、 n 変数のシステムは 3^n 個のルールがあるといえる。つまり δ -LFITの分類クラスの数は $3^n \times n$ 個である。

	$l=1$	$l=2$	$l=3$
$\tau(\mathcal{B}_0)$	$0 \rightarrow \{\}$	$7 \rightarrow \{a, b\}$	
	$1 \rightarrow \{a\}$	$8 \rightarrow \{a, c\}$	$19 \rightarrow \{a, b, c\}$
	$2 \rightarrow \{b\}$	$9 \rightarrow \{b, c\}$	$20 \rightarrow \{\neg a, b, c\}$
	$3 \rightarrow \{c\}$	$10 \rightarrow \{\neg a, b\}$	$21 \rightarrow \{a, \neg b, c\}$
	$4 \rightarrow \{\neg a\}$	$11 \rightarrow \{\neg a, c\}$	$22 \rightarrow \{\neg a, \neg b, c\}$
	$5 \rightarrow \{\neg b\}$	$12 \rightarrow \{\neg b, c\}$	$23 \rightarrow \{a, b, \neg c\}$
	$6 \rightarrow \{\neg c\}$	$13 \rightarrow \{a, \neg b\}$	$24 \rightarrow \{\neg a, b, \neg c\}$
		$14 \rightarrow \{a, \neg c\}$	$25 \rightarrow \{a, \neg b, \neg c\}$
		$15 \rightarrow \{b, \neg c\}$	$26 \rightarrow \{\neg a, \neg b, \neg c\}$
		$16 \rightarrow \{\neg a, \neg b\}$	
		$17 \rightarrow \{\neg a, \neg c\}$	
		$18 \rightarrow \{\neg b, \neg c\}$	

表 1: エルプラン基底 $\mathcal{B}_0 = \{a, b, c\}$ のルールのインデックス

3.2 NLP 行列

δ -LFIT の出力は行列だが、ここではその行列を NLP に変換する手法について説明する。

エルプラン基底 $\mathcal{B} = \{a, b\}$ および下記の NLP が与えられた時、

$$a(t+1) \leftarrow a(t) \wedge b(t)$$

$$a(t+1) \leftarrow \neg b(t)$$

$$b(t+1) \leftarrow \neg a(t)$$

これは下記の行列として表すことができる：

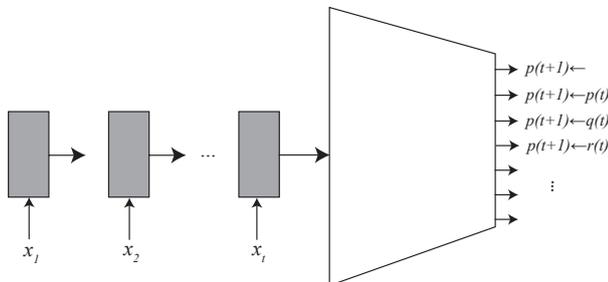
$$\begin{array}{c} \{a\} \quad \{b\} \quad \{\neg a\} \quad \{\neg b\} \quad \{a, b\} \quad \{\neg a, b\} \quad \{a, \neg b\} \quad \{\neg a, \neg b\} \\ a \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \\ b \end{array}$$

ヘッドに複数のルールが存在する時は論理和を取る意味であり、その時はヘッドの行で複数の 1 をマークすることとなる。

3.3 モデル

ここでは提案手法のモデルについて述べる。ニューラルネットワークのパターン認識を最大限に引き出すために、ニューラルネットワークの構造自体は変更なしで実装した。

主に、モデルに解釈遷移列を与え、その遷移列内に存在するルールを分類し識別したい。従って、本研究では LSTM を用いて解釈遷移列のパターン認識を行い、その後フィードフォワードニューラルネットワークを用いて分類した。そのアーキテクチャを図 1 で表す。

図 1: δ -LFIT アーキテクチャ

すべてのルール R に対して、ある遷移列 T が与えられた時、 δ -LFIT は下記の確率を出力する：

$$p(R|T)$$

遷移列 T と一貫する論理プログラム P があるとし、 δ -LFIT は P に存在するすべてのルール R について $p(R|T) = 1$ を出力し、存在しないルールについて $p(R|T) = 0$ を出力する。つまり、すべてのデータ Λ からサンプリングした時、 (R, T) が実のラベル R と一致することを期待したい。従って、下記の負の対数尤度を最小化することが学習目的である：

$$\text{LFIT 損失} = -\mathbb{E}_{(R,T) \sim \Lambda} (R \times \log p(R|T) + (1-R) \times \log(1-p(R|T)))$$

上記した損失に加え、 δ -LFIT にルール間の包含関係を学習させたいので、下記という包含損失を加える：

$$\text{包含損失}_S = -\sum_{R \in S} (R \times \log p(R|T) + (1-R) \times \log(1-p(R|T)))$$

簡単に言えば、互いに包含するようなルールはできる限り一つしか $p(R|T) = 1$ とならないように設定している損失。

正則化などを加え、全体的な損失関数は下記の通りとなる：

$$\text{loss} = \text{LFIT 損失} + \lambda_1 \sum_{S \in \mathcal{S}} \text{包含損失}_S + \lambda_2 \|\theta\|^2$$

ここで λ_1 および λ_2 はハイパーパラメータであり各損失の重みを制御している。 $\|\theta\|^2$ はすべてのパラメータに対する L_2 -正則化である。

3.4 学習データの生成

良質な学習データを入手するのは、特に統計的機械学習においてかなり重要視されている [11]。 δ -LFIT においては、分類をしているので、各クラスでの学習データが必要である。しかし各クラスはそれぞれルールに対応しているので、全てのルールにおいてそれなりの学習データが必要ということになる。現実的にそのような学習データを得るのは困難なため、本研究で用いる学習データは全て人工的に生成したものである。ここではその学習データの生成方法について説明する。

全てのルール $R \in \tau(\mathcal{B})$ について学習データを生成する。モデルの入出力に従い、学習データは (T, P) のペアであり、 T は解釈遷移列として P は R を含む最小の NLP である。学習データを生成するには、まず R を含む適当な P_0 を生成する。この P_0 からあらゆる初期値を与え解釈遷移列 T を作る。次にシンボリック手法の LFIT を用いて T から P_1 を学習する。もし P_1 の中に R が存在するなら、この (T, P_1) のペアは学習データとして加える。

4. 実験

まず提案手法が与えられた解釈遷移列からルールを分類できるか確認し、そして解釈遷移列にノイズを加え提案手法の有効性を確認する。本研究は Tensorflow [1] で実装し実験を行った。 δ -LFIT を [10] から得られたそのうち 4 つのプリアンネットワークにて有効性を確認した。4 つのプリアンネットワークのうち、3 つが 3 変数のものであり 1 つが 5 変数である。

まず、各ネットワークについて、あらゆる初期値から生成される解釈遷移列をノイズなしに δ -LFIT に与え、 δ -LFIT から予測で得られた NLP から、再びその元の解釈遷移列の復元を試みた。その復元した解釈遷移列と元の解釈遷移列との平均二乗誤差をとり評価した。

次に、元の解釈遷移列で 0 だったものを $[0, 0.5]$ の値へマッピングし、1 だったものを $[0.5, 1]$ の値へマッピングした。こ

のマッピングは正規分布に従いランダムに行った。0.5が0および1両方からマッピングされることに注意したい、これによってモデルの曖昧さへの頑健性を調べる。また、本研究ではモデルをノイズに適応させるためにノイズの含む学習データで再学習させていない。

すべての実験結果を表2で表す。多くの場合ではノイズを含んだ入力では精度が落ちている。ただし唯一の例外が Raf のネットワーク。このネットワークでは安定状態が多く、ノイズなしではニューラルネットワークにとってパターン認識するのが困難であり、ノイズを加えたことで認識がうまくいったと考えられる。

ネットワーク	MSE (ノイズなし)	MSE (ノイズあり)
3-node (a)	0.095	0.137
3-node (b)	0.054	0.057
Raf	0.253	0.217
5-node	0.142	0.147

表 2: 予測した論理プログラムの平均二乗誤差

4.1 考察

本研究での主な目的はノイズを含むデータからその遷移列を説明できる NLP を学習することである。結果を見る限り、ノイズが含まれた時精度が落ちていたことからこの目標は果たしていない。しかし、学習データにノイズを入れ、学習時にもノイズへの対応を含ませることで精度が上がると考えられる。

そして、5変数以上のネットワークには対応できなかった。主な原因として5変数以上のシステムの学習データを生成するには現実的な時間内では不可能だった。計算能力の向上を期待するとともに、マルチラベルマルチクラスの分類問題の分野におけるなにかの新展開も δ -LFIT の性能の向上につながると考えられる。

さらに、すべての実験において、解釈遷移列が安定状態である時、つまりすべての状態が同一の状態となっているとき、 δ -LFIT は正しい NLP を予測することができなかった。特に Raf では安定状態が5つあり、性能の悪さが一目瞭然である。しかしノイズを加えることで、入力データに分散が出て、 δ -LFIT にとって認識しやすくなったと考えられる。

5. 関連研究

関連研究として、Gentet らが提案した NN-LFIT 手法 [3] がある。この手法ではニューラルネットワークを学習したい対象のシステムをモデル化し、その後ルールをニューラルネットワークから抽出している。[3] では少量の学習データからでも精度の高い学習が可能であることを示したが、ノイズに対する頑健性は調べられていない。また、学習したいシステムがあるごとにニューラルネットワークを学習させる必要があるため、学習時間が無駄になるともいえる。

他に、Evans らによって提案された δ -ILP [2] がある。 δ -ILP と本研究での提案手法の主な違いは、 δ -ILP は微分可能な手法で ILP 問題を解くと同時に論理プログラムを出力することを目的としている。一方、本研究では LFIT 問題を微分可能手法で解かず、出力は論理プログラムのみである。

6. おわりに

本研究ではノイズの含んだ遷移列データから論理プログラムを学習するモデル δ -LFIT を提案した。LFIT をルールの分

類問題に見立てたことより、学習は予測したルールと本当に存在するルールとの交差エントロピーを最小化することで実現した。特に、 δ -LFIT では通常のニューラルネットワークモデルをただ用いて、変更なしに実装を行った。従って、今後ニューラルネットワーク技術について新たな進展があった時に、そのまま δ -LFIT の性能の向上につながると考えられる。そして、本研究でいくつか実験を行いその有効性を示した。ノイズを含んだ解釈遷移列についても δ -LFIT では論理プログラムの学習が可能であることを示した。今後の展開として、変数の数へのスケールアップできるアーキテクチャについて調べる。また、ノイズにさらに頑健とさせるため、学習データにあらかじめノイズを含ませて学習させその性能について調べる。

参考文献

- [1] M. Abadi, A. Agarwal, P. Barham, et al. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org.
- [2] R. Evans and E. Grefenstette. Learning explanatory rules from noisy data. *CoRR*, abs/1711.04574, 2017.
- [3] E. Gentet, S. Tourret, and K. Inoue. Learning from interpretation transition using feed-forward neural network. In *Proceedings of ILP 2016, CEUR Proc. 1865*, pages 27–33, 2016.
- [4] K. Inoue, T. Ribeiro, and C. Sakama. Learning from interpretation transition. *Machine Learning*, 94(1):51–79, 2014.
- [5] D. Martínez, G. Alenyà, T. Ribeiro, K. Inoue, and C. Torras. Relational reinforcement learning for planning with exogenous effects. *Journal of Machine Learning Research*, 18(78):1–44, 2017.
- [6] T. Ribeiro and K. Inoue. Learning prime implicant conditions from interpretation transition. In *ILP 2015*, pages 108–125. Springer, 2015.
- [7] T. Ribeiro, M. Magnin, K. Inoue, and C. Sakama. Learning multi-valued biological models with delayed influence from time-series observations. In *2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*, pages 25–31, Dec 2015.
- [8] D. Rolnick, A. Veit, S. Belongie, and N. Shavit. Deep learning is robust to massive label noise, 2018.
- [9] M. L. Seltzer, D. Yu, and Y. Wang. An investigation of deep neural networks for noise robust speech recognition. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, pages 7398–7402. IEEE, 2013.
- [10] A. Streck, H. Siebert, and H. Klarner. PyBoolNet: a python package for the generation, analysis and visualization of boolean networks. *Bioinformatics*, 33(5):770–772, 12 2016.
- [11] C. Sun, A. Shrivastava, S. Singh, and A. Gupta. Revisiting unreasonable effectiveness of data in deep learning era. *CoRR*, abs/1707.02968, 2017.

分類性能による制約を考慮した 敵対的不変表現学習によるドメイン汎化

Adversarial Invariant Feature Learning with Accuracy Constraint for Domain Generalization

阿久澤 圭^{*1} 岩澤 有祐^{*1} 松尾 豊^{*1}
Kei Akuzawa Yusuke Iwasawa Yutaka Matsuo

^{*1} 東京大学大学院工学系研究科
Graduate School of Engineering, The University of Tokyo

Learning domain-invariant representation is a dominant approach for domain generalization, where we need to build a classifier that is robust toward domain shifts. However, previous methods based on domain invariance overlooked the underlying dependency of classes on domains, which is responsible for the trade-off between classification accuracy and domain invariance. This study proposes a novel method *adversarial feature learning under accuracy constraint (AFLAC)*, which maximizes domain invariance within a range that does not interfere with classification accuracy. The reason for the constraint is that the primary purpose of domain generalization is to classify unseen domains rather than the invariance itself, and improving the invariance can negatively affect that performance. Empirical validations show that the performance of AFLAC is superior to that of baseline methods, supporting the importance of considering the dependency and the efficacy of the proposed method to overcome the problem.

1. はじめに

教師あり学習では典型的にデータが訓練時・テスト時で i.i.d. であるという仮定を置いているが、これが成り立たないとき機械学習モデルのテストデータに対する予測精度が著しく低下する [Torralla 11]. ドメイン汎化は、このような状況を想定した研究領域の一つであり、複数のソースドメインからラベルつき訓練データが得られるという設定のもと、それらの訓練データを利用してターゲットドメインから得られるテストデータへの予測を行う。ドメイン汎化は手書き文字認識 [Shankar 18], そしてユーザーにロバスタな加速度センサーからの行動認識 [Erfani 16] など、様々な応用先を持つ技術である。

本研究では、ドメイン d とクラスラベル y が何かしらの共通要因 z によって統計的に従属する状況下 (図 1-(c)) でドメイン汎化に取り組む。そのような状況の例に WISDM Activity Prediction データセット ([Kwapisz 11], 以降 WISDM) がある。WISDM では人間がドメイン、人間の行動がクラスに該当するが、いくつかの行動 (ジョギング, 階段を上る) が激しい運動を必要とするため、そうした運動を敬遠するユーザーの存在によって従属性が生じる。また別のいくつかの行動 (座る, 立つ) がデータセット収集作業の途中から付け加えられたために、あるユーザーらについてはそれらの行動に関するデータを全く得ることができない。このような状況は現実のデータセットに一般的でありドメイン適応では取り組まれている [Zhang 13] にも関わらずドメイン汎化では無視されてきた。

ドメイン汎化に取り組むために、多くの手法が不変表現学習を利用している [Muandet 13, Erfani 16, Xie 17]. 不変表現学習では、入力データ x を特徴量 h に写像したとき、 h がドメイン d に関する情報を持たなくなる、あるいは複数のドメインの分布を特徴量空間で近づけるような制約を置く。このようにして得た h から y への予測を行うことで、予測が特定の d に対して過剰適合しなくなり、テスト時に現れるターゲットドメインに対しても正しい予測を行えることが期待できる (図

1-(b)). しかし、ドメインとクラスが従属する時、単にドメインに不変な表現を学習しようとするとき分類性能を妨げてしまう危険性がある。直感的に言えば、ドメインとクラスが従属するとき y は d に関する情報を持っているので、 h が d に関する情報を持つことは y に対する予測精度の向上につながる。しかし、不変表現学習は h が d に関する情報を全く持たなくなるような制約をかけるので、不変性と分類性能のトレードオフが生じる。このトレードオフは (訓練時にはソースドメインのみを用いるため) ソースドメインに対して生じるが、ターゲットドメインに対する分類性能を損なう危険性も抱えている。例えばもしターゲットドメインがソースドメインに似ている時、あるいは極端な場合ターゲットドメインとあるソースドメインが全く同じ性質を持つとき、ソースドメインに対する分類性能を損なうことは明らかにターゲットドメインに対する分類性能を損なうことにつながる (図 1-(d)).

本研究では、不変性を優先することはドメイン汎化性能を損なう危険があることから、分類性能を損なわない範囲内で不変性を最大化することを提案する。提案手法 AFLAC (Adversarial Feature Learning under Accuracy Constraint) は、既存の敵対的不変表現学習手法の Domain Adversarial Networks (DAN, [Ganin 16, Xie 17]) の改善手法であり、分類性能による制約付きドメイン不変性を達成するように意図されている。分類性能による制約付きドメイン不変性は分類性能を妨げない範囲内で達成できる $H(d|h)$ (H はエントロピーを指す) の最大値であり $H(d|y)$ に等しい。実験では AFLAC がベースライン手法に比べて高いドメイン汎化性能を持つことを示し、ドメインとクラスの従属関係を考慮することの重要性、および AFLAC がその従属性が引き起こすトレードオフの問題に対処する能力を持つことを示す。

2. 関連研究

不変表現学習のドメイン汎化に対する有効性は [Muandet 13] によって初めて示された。DAN は敵対的学習に基づいて End-to-End に不変表現学習を行う手法であり、本研究の提案手法 AFLAC の基盤となっている。DAN は当初ドメイン適応のために提案された [Ganin 16] が、[Xie 17] によってドメイン汎

連絡先: 阿久澤 圭, 東京大学大学院工学系研究科技術経営戦略学専攻, 〒113-8656 東京都文京区本郷 7-3-1, akuzawa-kei@weblab.t.u-tokyo.ac.jp

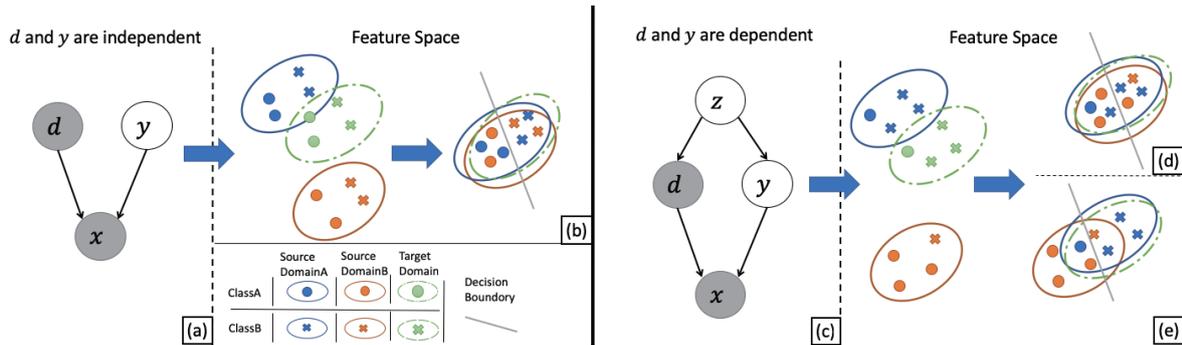


図 1: ドメインとクラスの従属性が引き起こす分類性能と不変性のトレードオフの概要. (a) ドメインとクラスが独立なとき, (b) 完全なドメイン不変性と最適な分類性能は同時に達成することができる. (c) ドメインとクラスが従属するとき, ドメイン不変性と分類性能の間にトレードオフが存在する. すなわち, (d) 完全なドメイン不変性が達成されているときは最適な分類性能を達成することができず, また (e) 逆も同じである.

化における有効性が示されている. [Xie 17] はまた, 本研究が取り組む分類性能と不変性のトレードオフについて指摘しているが, その問題への対処法については十分に議論していない.

不変表現学習を用いずにドメイン汎化に取り組む研究もいくつか存在する. 例えば [Li 18] は Semantic Alignment と呼ばれるアプローチでドメイン汎化に取り組んでいる. Semantic Alignment では, クラスで条件づけた潜在表現が全てのソースドメインで同じになるような制約をかけるが, トレードオフの問題に対処できるかは明らかではない. CrossGrad [Shankar 18] は近年 state-of-the-art の性能を示したドメイン汎化手法の一つであり, 敵対的例を生成することでデータ拡張を行う. しかしこの手法は y と d が統計的に独立であることを仮定しているため, 本研究の設定にそのまま適用可能ではない.

ドメイン適応においては [Zhang 13] が $p(y)$ がソース, ターゲットドメインで変化するような設定に取り組んでいる. [Zhang 13] は $p(y)$ の変化を推定し, ソースドメインに対する分類精度を犠牲にすることでその分布の変化を矯正し, ターゲットドメインに対する分類精度を高めている. しかしそのような手法はドメイン汎化には適用可能でない, または適用する必要がない. なぜなら, ドメイン汎化においてはターゲットドメインのデータは全く得ることができないためソースとターゲットの分布の違いには対処しようがなく, また本研究が対象としているのは複数あるソースドメイン間の分布の変化である. 代わりに本研究では複数あるソースドメインに対する不変性を高めつつ分類性能を最大化する手法を提案する.

3. モデル

3.1 既存手法: DAN

本節では, 提案モデルの基盤となる DAN に関する説明を行う. DAN は敵対的学習に基づいて不変表現学習を行う手法であり, エンコーダーが出力した潜在表現からドメインを識別しようとするドメイン識別器を持つ. ドメイン識別器がドメインを予測しようとする一方で, エンコーダーがその識別器を騙すように学習することで, 潜在表現は「ドメイン識別器が正しく識別を行うことができないような表現」, すなわちドメインに関する情報を全く持たないような表現になる.

$f_E(x)$, $q_M(y|h)$, $q_D(d|h)$ (E, M, D はパラメータ) をそれぞれエンコーダー, クラスラベルの分類器 (以降分類器), ドメインラベルの識別器 (以降識別器) とする. DAN の目的関数

は以下のように書ける.

$$\begin{aligned} \min_{E, M} \max_D J(E, M, D) &= \mathbb{E}_{x, d, y \sim p(x, d, y)} [-\gamma L_d + L_y] \\ &= \mathbb{E}_{x, d, y \sim p(x, d, y)} [\gamma \log q_D(d|h = f_E(x)) \\ &\quad - \log q_M(y|h = f_E(x))] \end{aligned} \quad (1)$$

ここで, 式 1 の L_y と L_d の最小化は通常の分類問題と同様, 単に分類器と識別器の分類誤差を最小化しているだけである. ただし, 第一項はエンコーダーと識別器の間のミニマックスゲームに相当し, 識別器は潜在表現 h から d を当てようとするのに対して, エンコーダーは識別器を騙そうとしている. DAN の訓練の様子は図 2-(a) に示されている.

3.2 提案手法: AFLAC

本研究では DAN の改善手法 AFLAC を提案する. DAN の正則化項は完全なドメイン不変性, すなわち $H(d|h) = H(d)$ を達成するような正則化を持つ [Xie 17] が, それに対して AFLAC は分類性能による制約付きドメイン不変性 $H(d|h) = H(d|y)$ を達成するような正則化を持つ. $H(d|h) = H(d|y)$ は学習された表現 h がクラスラベル y と同じだけドメイン d に関する情報を含むことを意味するが, そのような表現は分類性能を損なうことがないと考えられる.

AFLAC は DAN と同様にエンコーダー, 分類器, 識別器を持つ. そして以下の二つの最適化問題を, 交互に勾配法によるパラメータの更新を行うことによって解く.

$$\begin{aligned} \min_{E, M} V(E, M) &= \mathbb{E}_{x, d, y \sim p(x, d, y)} [\gamma L_{DKL} + L_y] \\ &= \mathbb{E}_{x, d, y \sim p(x, d, y)} [\gamma D_{KL}[p(d|y)|q_D(d|h = f_E(x))] \\ &\quad - \log q_M(y|h = f_E(x))] \end{aligned} \quad (2)$$

$$\begin{aligned} \min_D W(E, D) &= \mathbb{E}_{x, d \sim p(x, d)} [L_d] \\ &= \mathbb{E}_{x, d \sim p(x, d)} [-\log q_D(d|h = f_E(x))] \end{aligned} \quad (3)$$

DAN と同様に, 式 2 の第二項は q_M , 式 3 は q_D の尤度最大化を表している. 一方式 2 の第一項は DAN と異なり, Kullback-Leibler divergence (KLD) の最小化を通してすべての確率が 0 ではない y と h のペアに関して $q_D(d|h) = p(d|y)$ を成立させるような働きを持つ. ここで $q_D(d|h)$ は L_d の最小化によって $p(d|h)$ を近似するように学習するが, その近似が十分に行われているとき, $D_{KL}[p(d|y)|q_D(d|h)]$ の最小化は $H(d|h) = H(d|y)$ を達成する.

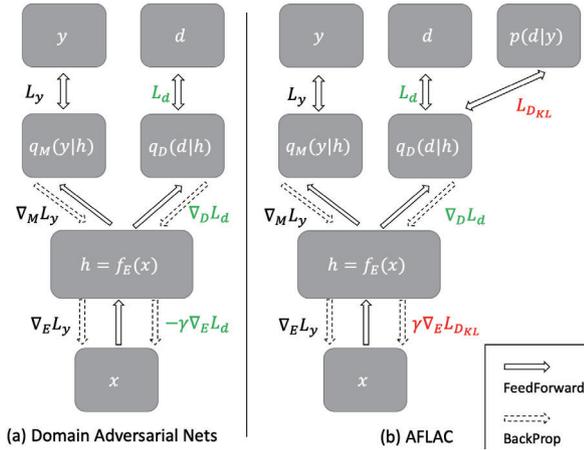


図 2: (a)DAN と (b)AFLAC の比較. (a) 分類器と識別器は L_y と L_d を最小化するように、エンコーダーは L_y を最小化、 L_d を最大化するように学習する. (b) 識別器は L_d の最小化によって $p(d|h)$ を近似するように、エンコーダーは L_{DKL} の最小化によって $p(d|h)$ と $p(d|y)$ を近づけるように学習する.

実際の訓練時には真の $p(d|y)$ を手に入れることはできないが、その最尤推定量や MAP 推定量を用いることができる。また、式 2 の $D_{KL}[p(d|y)|q_D(d|h)]$ に関しては他の分布間距離、例えば L1 距離や $D_{KL}[q_D(d|h)|p(d|y)]$ も考えられるが、大きな精度の改善が見られなかったため本研究では考えないこととする。AFLAC の訓練の概要は、図 2-(b) に示されている。

4. 実験

4.1 データセット

BMNISTR Biased Rotated MNIST (以降 BMNISTR) はドメイン汎化のための標準的なデータセットである MNISTR[Ghifary 15] を元に、本研究がドメインとクラスが従属するようにサンプルサイズに修正を加えたものである。MNISTR や BMNISTR では、それぞれのクラスは 0 から 9 のアラビア数字に対応し、それぞれのドメインは画像の傾き (0, 15, 30, 45, 60, 75 度) に対応する。またそれぞれの傾きは M0, M75 のように表記する。それぞれの画像は [Ghifary 15] の実験設定と同様に 16×16 の大きさを持つ。本研究は BMNISTR-1 から BMNISTR-4 までの、それぞれ異なるドメインとクラスの従属性を持つ 4 つのデータセットを作り出した。表 1 が示すように、BMNISTR-1, -2, -3 は似たような傾向の従属性を持つがその強さが異なっている。一方で、BMNISTR-4 はその他のデータセットとは異なる傾向の従属性を持っている。訓練では、一つのドメインをテストドメインとして、残り全てのドメインを訓練データとする設定で行った。また BMNISTR に対しては、エンコーダーを二層の畳み込み層と二層の全結合層、クラス分類機を三層の全結合層、ドメイン識別器を二層の全結合層からなるディープニューラルネットワークとした。

WISDM WISDM データセットは 36 人のユーザーによる 6 つの行動 (walking, jogging, upstairs, downstairs, sitting, and standing) を加速度計によって計測したセンサーデータによって構成される。このデータセットではユーザーがドメイン、行動がクラスに相当し、ユーザーに対して頑健な予測を行うことが目標となる。WISDM は 1. 章で述べた理由からドメインとクラスの従属性を持つ。WISDM では、ランダムに選択した $\langle 10 / 26 \rangle$, $\langle 26 / 10 \rangle$ 人のユーザーを \langle ソース/ター

表 1: BMNISTR における各ドメイン・クラスに対するサンプルサイズ。クラス 0 から 4 に対するサンプルサイズはドメインによって異なる一方で、クラス 5 から 9 に対するサンプルサイズは全てのドメインで同一となっている。

Dataset	Class	M0	M15	M30	M45	M60	M75
BMNISTR-1	0~4	100	85	70	55	40	25
	5~9	100	100	100	100	100	100
BMNISTR-2	0~4	100	80	60	40	20	0
	5~9	100	100	100	100	100	100
BMNISTR-3	0~4	100	90	80	70	60	50
	5~9	100	100	100	100	100	100
BMNISTR-4	0~4	100	25	100	25	100	25
	5~9	100	100	100	100	100	100

表 2: BMNISTR でターゲットドメインを M0 としたときのクラス 0 から 4 と 5 から 9 に対する平均の F 値。RI は AFLAC-Abl から AFLAC の相対改善率を表す。

Dataset	Class	CNN	DAN	CIDDG	AFLAC-Abl	AFLAC	RI
BMNISTR-1	0~4	83.86	84.54	87.50	87.46	90.62	3.6%
	5~9	83.90	85.24	87.46	86.46	88.10	1.9%
BMNISTR-2	0~4	84.76	86.20	88.52	86.42	89.58	3.7%
	5~9	83.36	85.22	87.02	85.62	86.86	1.4%
BMNISTR-3	0~4	82.54	85.30	87.64	88.60	89.64	1.2%
	5~9	82.18	85.80	86.74	87.60	89.04	1.6%
BMNISTR-4	0~4	71.26	79.22	76.76	76.56	80.02	4.5%
	5~9	78.62	83.14	82.64	82.94	82.80	-0.2%

ゲット > ユーザーとして用いた。データの前処理として、60 フレーム (3 秒間に相当) を一つのサンプルとしてデータセットを構築したところ、合計で 18210 サンプルとなった。モデル構造はエンコーダーを三層の畳み込み層と一層の全結合層、クラス分類器を一層の全結合層、ドメイン識別器を二層の全結合層とした。

4.2 ベースライン

提案手法の有効性を示すために、本研究では以下の手法との比較実験を行う。(1) **CNN** は通常の畳み込み層で形成されたディープネットワークである。(2) **DAN** [Xie 17] は 3.1 節で説明した、敵対的学習による不変表現学習を利用したドメイン汎化手法である。(3) **CIDDG** は [Li 18] の提案モデルを我々が再現実装したものであり、Semantic Alignment を利用している。(4) **AFLAC-Abl** は ablation study のために用意した AFLAC の変種である。AFLAC-Abl は AFLAC の目的関数である式 2 の $D_{KL}[p(d|y)|q_D(d|h)]$ を $D_{KL}[p(d)|q_D(d|h)]$ によって置き換えたモデルであり、DAN と同様に完全にドメイン不変な表現を得る、すなわち $H(d|h) = H(d)$ を成立させるような正則化項を持つ。AFLAC と AFLAC-Abl を比べることで、ドメインとクラスの従属性が引き起こすトレードオフの問題を考慮することがドメイン汎化性能に与える影響を観察することができる。AFLAC と AFLAC-Abl の訓練では、2 式の KLD の計算に必要な真の $p(d|y)$ と $p(d)$ を得ることができないため、それらの最尤推定量を代わりに用いた。

4.3 様々な種類の従属の下での比較

本節ではドメインとクラスの従属性が、ドメイン不変性を利用したドメイン汎化手法の性能に与える影響について確認する。表 2 は BMNISTR でターゲットドメインを M0 とした際の、クラス 0 から 4 と 5 から 9 のそれぞれに対する F 値の平均を示している。ここで、クラス 0 から 4 のサンプルサイズはドメインごとに異なるが、クラス 5 から 9 は全てのドメインで同じであることに注意する (表 1)。表 2 が示すよ

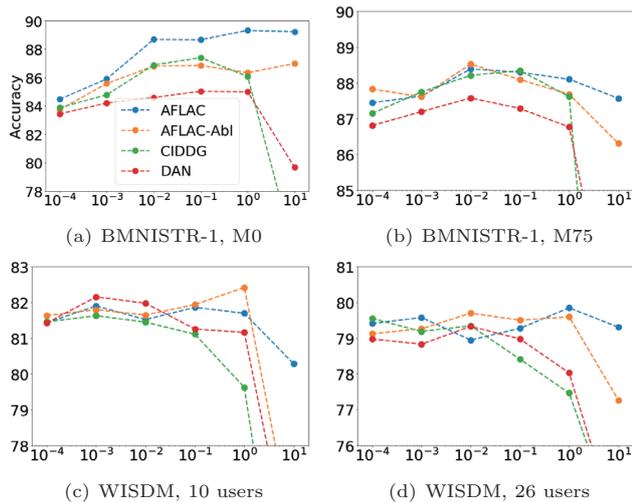


図 3: 様々な γ の値の下での正解率の比較. 各キャプションはデータセットの名前とターゲットドメインを表している.

うに, AFLAC の性能はベースライン手法の性能をほとんどのデータセットおよびクラスについて上回っているが, これはドメイン不変性を利用した DAN や AFLAC-Abl といった手法の性能がドメインとクラスの従属性によって損なわれること, そして AFLAC がその問題を緩和できることを示唆している. また AFLAC の AFLAC-Abl に対する相対改善率を見ると, BMNISTR-1, -2, -4 ではクラス 0 から 4 に対する相対改善率の方がクラス 5 から 9 に対するものよりも大きい, これは AFLAC がドメインとクラスの従属性が発生しているクラスについてより正確に予測を行えることを示唆している. また, BMNISTR-1 の相対改善率は BMNISTR-3 の相対改善率よりも大きい, これはドメインとクラスの従属性が強くなるほど, DAN や AFLAC といったドメイン不変性に基づいた手法の性能が損なわれることを示唆している. 最後に, BMNISTR-1 と BMNISTR-4 は異なる傾向のドメインとクラスの従属性を持つが, AFLAC はそのどちらのデータセットに対しても F 値を改善させている.

4.4 ハイパーパラメータに対する頑健性

次に本節では, 正則化の強さとドメイン汎化性能の関係について調べる. 図 3 は DAN, CIDDG, AFLAC-Abl, AFLAC を様々なハイパーパラメータ γ を用いて訓練した際の, y に対する正解率を示している. これらの画像から, 以下のことが示唆される. (1) 正則化項の重みを強くしたときに, AFLAC の訓練は DAN や CIDDG の訓練より安定する傾向がある. 図 3-(a, b, c, d) からは, γ の値を 1 や 10 にした時に AFLAC や AFLAC-Abl が DAN よりも高い性能を示す傾向があることが読み取れる. その理由はおそらく, AFLAC や AFLAC-Abl の制約項が KLD であり 0 によって下から抑えられているため, DAN の制約項のように重みを大きくした時に発散する心配がなく, 訓練が安定するからだと考えられる. (2) AFLAC は, 正則化を強めても分類精度が損なわれず, したがってハイパーパラメータ選択に頑健な傾向にある. 図 3-(b, c, d) は, γ を 10 のような大きな値にした時に AFLAC-Abl の y に対する正解率が大きく低下する一方で AFLAC のものはそれほど大きく低下しないことを示しているが, これは AFLAC の正則化が分類精度を損なわない範囲でドメイン不変性を最大化するように意図されているからであると考えられる.

5. 結論

本研究では, 既存研究が検討してこなかった「ドメインとクラスが統計的に従属する」という状況下でドメイン汎化を行うため, 分類性能を妨げることのない範囲でドメイン不変性を最大化する新しい手法 AFLAC を提案した. 実験では AFLAC がベースライン手法よりも優れた性能を発揮することを確認し, ドメインとクラスの従属性が引き起こすトレードオフを考慮することのドメイン汎化にける重要性, およびその問題に対する AFLAC の有効性を確認した.

参考文献

- [Erfani 16] Erfani, S., Baktashmotlagh, M., Moshtaghi, M., Nguyen, V., Leckie, C., Bailey, J., and Kotagiri, R.: Robust domain generalisation by enforcing distribution invariance, in *25th International Joint Conference on Artificial Intelligence* (2016)
- [Ganin 16] Ganin, Y., Ustinova, E., Ajakan, H., Germain, P., Larochelle, H., Laviolette, F., Marchand, M., and Lempitsky, V.: Domain-adversarial Training of Neural Networks, *J. Mach. Learn. Res.* (2016)
- [Ghifary 15] Ghifary, M., Bastiaan Kleijn, W., Zhang, M., and Balduzzi, D.: Domain Generalization for Object Recognition With Multi-Task Autoencoders, in *Proc. of the IEEE International Conference on Computer Vision (ICCV)* (2015)
- [Kwapisz 11] Kwapisz, J. R., Weiss, G. M., and Moore, S. A.: Activity Recognition Using Cell Phone Accelerometers, *SIGKDD Explor. Newsl.* (2011)
- [Li 18] Li, Y., Tian, X., Gong, M., Liu, Y., Liu, T., Zhang, K., and Tao, D.: Deep Domain Generalization via Conditional Invariant Adversarial Networks, in *The European Conference on Computer Vision (ECCV)* (2018)
- [Muandet 13] Muandet, K., Balduzzi, D., and Schölkopf, B.: Domain Generalization via Invariant Feature Representation, in *Proc. of the 30th International Conference on Machine Learning* (2013)
- [Shankar 18] Shankar, S., Piratla, V., Chakrabarti, S., Chaudhuri, S., Jyothi, P., and Sarawagi, S.: Generalizing Across Domains via Cross-Gradient Training, in *Proc. International Conference on Learning Representations* (2018)
- [Torralba 11] Torralba, A. and Efros, A. A.: Unbiased Look at Dataset Bias, in *Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition* (2011)
- [Xie 17] Xie, Q., Dai, Z., Du, Y., Hovy, E., and Neubig, G.: Controllable Invariance through Adversarial Feature Learning, in *Proc. of the 30th International Conference on Neural Information Processing Systems* (2017)
- [Zhang 13] Zhang, K., Schölkopf, B., Muandet, K., and Wang, Z.: Domain Adaptation under Target and Conditional Shift, in *Proc. of the 30th International Conference on Machine Learning* (2013)