| Thu. Jun 6, 2019  | Shao-Hsuan Tai <sup>1</sup> , Hao-Shang Ma <sup>1</sup> , OJen-Wei  |
|---|---|
| Room B  | 3.50 PM - 4.10 PM   |
| International Session   International Session   [ES] E-2 Machine learning<br>[3B3-E-2] Machine learning: image recognition and<br>generation<br>Chair: Masakazu Ishihata (NTT)<br>1:50 PM - 3:30 PM Room B (2F Main hall B)   | [3B4-E-2-02] A Community Sensing Approach for User<br>Identity Linkage<br>OZexuan Wang <sup>1</sup> , Teruaki Hayashi <sup>1</sup> , Yukio<br>Ohsawa <sup>1</sup> (1. Department of Systems Innovation  |
| <ul> <li>[3B3-E-2-01] Design a Loss Function which Generates a<br/>Spatial configuration of Image In-<br/>betweening</li> <li>OPaulino Cristovao<sup>1</sup>, Hidemoto Nakada<sup>1,2</sup>,<br/>Yusuke Tanimura<sup>1,2</sup>, Hideki Asoh<sup>2</sup> (1. University<br/>of Tsukuba, 2. National Advanced Institute of<br/>Science and Technology of Japan (AIST))</li> <li>1:50 PM - 2:10 PM</li> <li>[3B3-E-2-02] One-shot Learning using Triplet Network<br/>with kNN classifier</li> <li>OMu Zhou<sup>1,2</sup>, Yusuke Tanimura<sup>2,1</sup>, Hidemoto<br/>Nakada<sup>2,1</sup> (1. University of Tsukuba, 2. Artifical<br/>Intelligence Research Center, National Institute of<br/>Advanced Institute of Technology)</li> <li>2:10 PM - 2:30 PM</li> <li>[3B3-E-2-03] Cycle Sketch GAN: Unpaired Sketch to<br/>Sketch Translation Based on Cycle GAN<br/>Algorithm</li> <li>OTakeshi Kojima<sup>1</sup> (1. Peach Aviation Limited)</li> </ul> | School of Engineering, The University of Tokyo)<br>4:10 PM - 4:30 PM<br>[3B4-E-2-03] Learning Sequential Behavior for Next-Item<br>Prediction<br>ONa Lu <sup>1</sup> , Yukio Ohsawa <sup>1</sup> , Teruaki Hayashi <sup>1</sup> (1.<br>The University of Tokyo)<br>4:30 PM - 4:50 PM<br>[3B4-E-2-04] Application of Unsupervised NMT<br>Technique to JapaneseChinese Machine<br>Translation<br>OYuting Zhao <sup>1</sup> , Longtu Zhang <sup>1</sup> , Mamoru<br>Komachi <sup>1</sup> (1. Tokyo Metropolitan University)<br>4:50 PM - 5:10 PM<br>[3B4-E-2-05] Synthetic and Distribution Method of<br>Japanese Synthesized Population for Real-<br>Scale Social Simulations<br>OTadahiko Murata <sup>1</sup> , Takuya Harada <sup>1</sup> (1. Kansa<br>University)<br>5:10 PM - 5:30 PM |
| 2:30 PM - 2:50 PM<br>[3B3-E-2-04] Conditional DCGAN's Challenge: Generating<br>Handwritten Character Digit, Alphabet and<br>Katakana<br>ORina Komatsu <sup>1</sup> , Tad Gonsalves <sup>1</sup> (1. Sophia<br>University)<br>2:50 PM - 3:10 PM<br>[3B3-E-2-05] Sparse Damage Per-pixel Prognosis Indices<br>via Semantic Segmentation<br>OTakato Yasuno <sup>1</sup> (1. Research Institute for<br>Infrastructure Paradigm Shift (RIIPS))<br>3:10 PM - 3:30 PM  | Room H         International Session   International Session   [ES] E-3 Agents         [3H3-E-3] Agents: safe and cooperative society         Chair: Ahmed Moustafa (Nagoya Institute of Technology),         Reviewer: Takayuki Ito (Nagoya Institute of Technology)         1:50 PM - 3:30 PM Room H (303+304 Small meeting rooms)         [3H3-E-3-01] An Autonomous Cooperative Randomization         Approach to Prevent Attacks Based on         Traffic Trends in the Communication         Destination Anonymization Problem         OKeita Sugiyama <sup>1</sup> , Naoki Fukuta <sup>1</sup> (1. Shizuoka         University)  |

1:50 PM - 2:10 PM

[3H3-E-3-02] Cooperation Model for Improving Scalability of the Multi-Blockchains System

OKeyang Liu<sup>1</sup>, Yukio Ohsawa<sup>1</sup>, Teruaki Hayashi<sup>1</sup>

(1. University of Tokyo, Graduate school of

engineer)

2:10 PM - 2:30 PM

[3B4-E-2] Machine learning: social links

Yasufumi Takama (Tokyo Metropolitan University)

3:50 PM - 5:30 PM Room B (2F Main hall B)

International Session | International Session | [ES] E-2 Machine learning

Chair: Lieu-Hen Chen (National Chi Nan University), Reviewer:

[3B4-E-2-01] Social Influence Prediction by a Community-

based Convolutional Neural Network

[3H3-E-3-03] Effect of Visible Meta-Rewards on Consumer **Generated Media** OFujio Toriumi<sup>1</sup>, Hitoshi Yamamoto<sup>2</sup>, Isamu Okada<sup>3</sup> (1. The University of Tokyo, 2. Rissho University, 3. Soka University) 2:30 PM - 2:50 PM [3H3-E-3-04] Toward machine learning-based facilitation for online discussion in crowd-scale deliberation OChunsheng Yang<sup>1</sup>, Takayuki Ito<sup>2</sup>, Wen  $GU^2$  (1. National Research Council Canada, 2. Nagoya Institute of Technology) 2:50 PM - 3:10 PM [3H3-E-3-05] An automated privacy information detection approach for protecting individual online social network users OWeihua Li<sup>1</sup>, Jiagi Wu<sup>1</sup>, Quan Bai<sup>2</sup> (1. Auckland University of Technology, 2. University of Tasmania) 3:10 PM - 3:30 PM

## Room J

International Session | International Session | [ES] E-4 Robots and real worlds

[3J3-E-4] Robots and real worlds: Human

#### Interactions

Chair: Yihsin Ho (Takushoku University), Eri Sato-Shimokawara (Tokyo Metropolitan University) 1:50 PM - 3:10 PM Room J (201B Medium meeting room)

[3J3-E-4-01] Automatic Advertisement Copy Generation

#### System from Images

OKoichi Yamagata<sup>1</sup>, Masato Konno<sup>1</sup>, Maki

Sakamoto<sup>1</sup> (1. The University of Electro-

Communications)

1:50 PM - 2:10 PM

[3J3-E-4-02] Eye-gaze in Social Robot Interactions

Koki Ijuin<sup>2</sup>, OKristiina Jokinen Jokinen<sup>1</sup>, Tsuneo Kato<sup>2</sup>, Seiichi Yamamoto<sup>2</sup> (1. AIRC, AIST Tokyo Waterfront, 2. Doshisha University)

2:10 PM - 2:30 PM

[3J3-E-4-03] A Team Negotiation Strategy that Considers

## Team Interdependencies

ODaiki Setoguchi<sup>1</sup>, Ahmed Moustafa<sup>1</sup>, Takayuki

Ito<sup>1</sup> (1. Nagoya Institute of Technology)

#### 2:30 PM - 2:50 PM

[3J3-E-4-04] Identity Verification Using Face Recognition

Hoshino<sup>1</sup>, Naoki Tokunaga<sup>1</sup>, Masami Kanda<sup>1</sup> (1. NEC Solution Innovators, Ltd.) 2:50 PM - 3:10 PM

#### JSAI2019

OTakaya Ozawa<sup>1</sup>, Ei-Ichi Osawa<sup>1</sup> (1. Future University Hakodate)

4:10 PM - 4:30 PM

 [3A4-J-13-03] Design and Preliminary Evaluations of Multi-Agent Simulation Model for Electric Power Sharing among Households OYasutaka Nishimura<sup>1</sup>, Taichi Shimura<sup>2</sup>, Kiyoshi Izumi<sup>3</sup>, Kiyohito Yoshihara<sup>1</sup> (1. KDDI Research Inc., 2. Kozo Keikaku Engineering Inc., 3. The University of Tokyo) 4:30 PM - 4:50 PM

## Room C

General Session | General Session | [GS] J-9 Natural language processing, information retrieval [3C3-J-9] Natural language processing, information

retrieval: creation and analysis of stories Chair:Hiromi Wakaki Reviewer:Masahiro Ito 1:50 PM - 2:50 PM Room C (4F International conference hall)

[3C3-J-9-01] Novel Segmentation Method based on the Distributed Representation of Sentences and Analysis Method of Story Developments OKiyohito Fukuda<sup>1</sup>, Naoki Mori<sup>1</sup>, Makoto Okada<sup>1</sup> (1. Osaka Prefecture University) 1:50 PM - 2:10 PM

[3C3-J-9-02] Analysis of Four-scene Comics Story Dataset based on natural language processing ORyo Iwasaki<sup>1</sup>, Naoki Mori<sup>1</sup>, Miki Ueno<sup>2</sup> (1. Osaka Prefecture University, 2. Toyohashi University of Technology) 2:10 PM - 2:30 PM

[3C3-J-9-03] Search for Similar Story Sentences based on Role of Characters in order to Support and Analyze Contents Creator's Ideas OTakefumi Katsui<sup>1</sup>, Miki ueno<sup>1</sup>, Hitoshi Isahara<sup>1</sup> (1. toyohashi university of technology)

2:30 PM - 2:50 PM

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

[3C4-J-9] Natural language processing, information

retrieval: correction of documents Chair:Yasutomo Kimura Reviewer:Yoko Nishihara

3:50 PM - 4:50 PM Room C (4F International conference hall)

[3C4-J-9-01] An Approach for Applying BERT to Sentence Elimination Problem in English Exam

## Room A

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

[3A3-J-13] Al application: enterprize and

## management

Chair:Kazutoshi Sasahara Reviewer:Hiroto Yoneno 1:50 PM - 3:10 PM Room A (2F Main hall A)

[3A3-J-13-01] Study on the mechanism of occurrence of

quality spoofing by "Conjecture" "air" and
"water" using business game
OHIROYASU SEITA<sup>1</sup>, Setsuya Kurahashi<sup>1</sup> (1.
Tsukuba university )
1:50 PM - 2:10 PM

[3A3-J-13-02] Detecting Technology Portfolios in the

Semiconductor Industry

OBohua Shao<sup>1</sup>, Kimitaka Asatani<sup>1</sup>, Ichiro Sakata<sup>1</sup>

(1. the University of Tokyo)

2:10 PM - 2:30 PM

[3A3-J-13-03] Relationships between mission statements

and protability in scal year 2016

(Preliminary Result)

ORyozo Kitajima<sup>1</sup>, Ryotaro Kamimura<sup>2</sup>, Hiroyuki

Sakai<sup>1</sup>, Kei Nakagawa<sup>3</sup> (1. Seikei University, 2.

IT Education Center, Tokai University, 3. Nomura

Asset Management Co., Ltd.)

2:30 PM - 2:50 PM

[3A3-J-13-04] Influences caused by faultlines on the

organizational performance.

OFumiko Kumada<sup>1</sup>, Setsuya Kurahashi<sup>1</sup> (1.

University of Tsukuba)

2:50 PM - 3:10 PM

General Session | General Session | [GS] J-13 Al application [3A4-J-13] Al application: electrical power Chair:Takashi Onoda Reviewer:Yuiko Tsunomori 3:50 PM - 4:50 PM Room A (2F Main hall A)

[3A4-J-13-01] Evaluation of power consumption estimation model based on household information OTomofumi Tahara<sup>1</sup>, Hideaki Uchida<sup>1</sup>, Hideki

Fujii<sup>1</sup>, Shinobu Yoshimura<sup>1</sup> (1. The university of Tokyo)

3:50 PM - 4:10 PM

[3A4-J-13-02] Optimization of Power Electric Supply Path in Smart Grids OHiromi Narimatsu<sup>1</sup>, Hiroaki Sugiyama<sup>1</sup>, Genichiro Kikui<sup>2</sup>, Hirotoshi Taira<sup>3</sup>, Seiki Matoba<sup>3</sup>, Ryuichiro Higashinaka<sup>1</sup> (1. NTT Communication Science Laboratories, 2. Okayama Prefectural University, 3. Osaka Institute of Technology) 3:50 PM - 4:10 PM

[3C4-J-9-02] A consideration of word sense

disambiguation of company name utilizing securities report

OHiroyuki Matsuda<sup>1</sup>, Kazuhiko Tsuda<sup>1</sup> (1.

Graduate School of Business Sciences, University of Tsukuba)

4:10 PM - 4:30 PM

[3C4-J-9-03] Misspelling Detection by using Multiple Bidirectional LSTM Networks ORyo Takahashi<sup>1</sup>, Kazuma Minoda<sup>1</sup>, Akihiro

> Masuda<sup>2</sup>, Nobuyuki Ishikawa<sup>1</sup> (1. Recruit Technologies Co.,Ltd., 2. PE-BANK, Inc) 4:30 PM - 4:50 PM

## Room H

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

[3H4-J-7] Agents: intelligence in/among robots Chair:Keisuke Otaki Reviewer:Hidekazu Oiwa 3:50 PM - 5:10 PM Room H (303+304 Small meeting rooms)

[3H4-J-7-01] Effect of Robot Anxiety on the Appearance

Tendency of Uncanny Valley Kazuhiro Ikeda<sup>1</sup>, OTomoko Koda<sup>1</sup> (1. Osaka

Institute of Technology) 3:50 PM - 4:10 PM

- [3H4-J-7-02] Strategyproof Mechanism with Agents Grouping for Multi-Agent Pathfinding OManao Machida<sup>1</sup> (1. NEC) 4:10 PM - 4:30 PM
- [3H4-J-7-03] A Fundamental Study of Region Allocation for Mobile Robots Based on Constraint Optimization and Decentralized Solution Method

OToshihiro Matsui<sup>1</sup> (1. Nagoya Institute of Technology)

4:30 PM - 4:50 PM

[3H4-J-7-04] On the design of state value functions for real-time continuous-state space multi-agent decision making

OTomoharu Nakashima<sup>1</sup>, Harukazu Igarashi<sup>2</sup>,

Hidehisa Akiyama<sup>3</sup> (1. Osaka Prefecture
University, 2. Shibaura Institute of Technology, 3.
Fukuoka University)
4:50 PM - 5:10 PM

## Room J

General Session | General Session | [GS] J-1 Fundamental AI, theory [3J4-J-1] Fundamental AI, theory: search and application Chair:Ichigaku Takigawa Reviewer:Yoichi Sasaki 3:50 PM - 5:10 PM Room J (201B Medium meeting room) [3J4-J-1-01] ACO with Pheromone Update by Negative Feedback Can Solve CSPs OTakuya Masukane<sup>1</sup>, Kazunori Mizuno<sup>1</sup> (1.

Department of Computer Science, Takushoku University)

3:50 PM - 4:10 PM

[3J4-J-1-02] An Algorithm for solving the Traveling Salesman Problem using Clustering Method OJumpei Uchida<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University)

4:10 PM - 4:30 PM

[3J4-J-1-03] Algorithm of Traveling Salesman Problem using Particle Swarm Optimization OYuki Yamada<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University)

4:30 PM - 4:50 PM

[3J4-J-1-04] League Scheduling for U12 Basketball OTenda Okimoto<sup>1</sup>, Kazuki Nishimura<sup>1</sup>, Katsutoshi Hirayama<sup>1</sup> (1. Kobe University) 4:50 PM - 5:10 PM

## Room K

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

[3K3-J-2] Machine learning: analysis and validations of models

Chair:Masahiro Suzuki Reviewer:Satoshi Oyama 1:50 PM - 3:30 PM Room K (201A Medium meeting room)

[3K3-J-2-01] Statistical Mechanical Formulation of

Learning Dynamics of Two-Layered Neural Networks with Batch Normalization

OShiro Takagi<sup>1</sup>, Yuki Yoshida<sup>1</sup>, Masato Okada<sup>1</sup>

(1. Graduate School of Frontier Sciences, The

University of Tokyo) 1:50 PM - 2:10 PM

- [3K3-J-2-02] On the trade-off between the number of nodes and the number of trees in Random
   Forest
   OSo Kumano<sup>1</sup>, Tatsuya Akutsu<sup>1</sup> (1. Kyoto University)
   2:10 PM 2:30 PM
- [3K3-J-2-03] Do the AUC and log-loss evaluate CTR prediction models properly?

OSatoshi KATAGIRI<sup>1</sup> (1. F@N Communications, Inc.)

2:30 PM - 2:50 PM

[3K3-J-2-04] Social reinforcement learning with shared global aspiration for satisficing ONoriaki Sonota<sup>1</sup>, Takumi Kamiya<sup>2</sup>, Tatsuji

Takahashi<sup>1</sup> (1. Tokyo Denki University, 2. Graduate School of Tokyo Denki University) 2:50 PM - 3:10 PM

[3K3-J-2-05] On the mathematical approach to the

``photo-likeness" of images

OYasuhiko Asao<sup>1</sup>, Ryotaro Sakamoto<sup>1</sup> (1.

Graduate School of Mathematical Science, the

- University of Tokyo)
- 3:10 PM 3:30 PM

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

[3K4-J-2] Machine learning: real world interaction Chair:Daiki Kimura Reviewer:Hikaru Kajino 3:50 PM - 5:30 PM Room K (201A Medium meeting room)

[3K4-J-2-01] Consideration on Generation of Saliency

Maps in Each Action of Deep Reinforcement Learning Agent

OKazuki Nagamine<sup>1</sup>, Satoshi Endo<sup>2</sup>, Koji Yamada<sup>2</sup>, Naruaki Toma<sup>2</sup>, Yuhei Akamine<sup>2</sup> (1. Information Engineering Course, Graduate School of Engineering and Science, University of the Ryukyus, 2. Faculty of Engineering, School of Engineering Computer Science and Intelligent Systems, University of the Ryukyus)

3:50 PM - 4:10 PM

[3K4-J-2-02] Dynamic Reward Clustering

ORyota Higa<sup>1</sup>, Junya Kato<sup>1</sup> (1. NEC Corporation)

4:10 PM - 4:30 PM

[3K4-J-2-03] A dialogue system implemented with latent parameters OWeida Li<sup>1</sup>, Chie Hieida<sup>2</sup>, Takayuki Nagai<sup>2</sup> (1. Seiko Gakuin High School, 2. The University of Electro-Communications)

- 4:30 PM 4:50 PM
- [3K4-J-2-04] Comfortable Driving by Deep Inverse Reinforcement Learning ODaiko Kishikawa<sup>1</sup>, Sachiyo Arai<sup>1</sup> (1. Chiba

University) 4:50 PM - 5:10 PM

[3K4-J-2-05] Linear function approximation of Cognitive Satiscing Function OYu Kono<sup>1,2</sup> (1. Tokyo Denki University, 2. DeNA, Co., Ltd.) 5:10 PM - 5:30 PM

## Room N

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

[3N3-J-10] Vision, speech: voice and

## communication

Chair:Masanori Tsujikawa Reviewer:Jun Sugiura 1:50 PM - 2:30 PM Room N (Front-right room of 1F Exhibition hall)

[3N3-J-10-01] Multilingual Imputation Using Transfer

Learning for Estimating Emotion from Speech

OKoichi Sakaguchi<sup>1</sup>, Shohei Kato<sup>1,2</sup> (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)

1:50 PM - 2:10 PM

[3N3-J-10-02] Development of Open-source Multi-modal Interaction Platform for Social Experiment of Conversational User Interface OAkinobu Lee<sup>1</sup> (1. Nagoya Institute of Technology, Japan) 2:10 PM - 2:30 PM

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

[3N4-J-10] Vision, speech: applications to industries Chair:Masanori Tsujikawa Reviewer:Tomoya Yoshikawa 3:50 PM - 4:50 PM Room N (Front-right room of 1F Exhibition hall)

[3N4-J-10-01] Measurement of growing situation of agricultural crops on FPGA-mounted drone using Circle SSD

|               | OTakuma Yoshimura <sup>1</sup> (1. poco-apoco                           |
|---------------|---|
|               | Networks Co.Ltd.)   |
|               | 3:50 PM - 4:10 PM   |
| [3N4-J-10-02] | Prediction of Favorability Rating on Beer-                              |
|               | Can Package Designs Using Convolution                                   |
|               | Neural Network and Visualization by Class                               |
|               | Activation Mapping.   |
|               | OHiroyuki Shinohara <sup>1</sup> , Tatsuji Ishiguro <sup>1</sup> ,      |
|               | Shunsuke Nakamura <sup>2</sup> , Toshihiko Yamasaki <sup>2</sup> (1.    |
|               | Kirin Company, Limited, 2. The University of                            |
|               | Tokyo)  |
|               | 4:10 PM - 4:30 PM   |
| [3N4-J-10-03] | Conversion of Floor Plan Images to Graph                                |
|               | Structures using Deep Learning and                                      |
|               | Application to Retrieval  |
|               | OMantaro Yamada <sup>1</sup> , Xueting Wang <sup>1</sup> , Toshihiko    |
|               | Yamasaki <sup>1</sup> , Kiyoharu Aizawa <sup>1</sup> (1. the University |
|               | of Tokyo)   |
|               | 4:30 PM - 4:50 PM   |
|               |   |

## Room P

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

[3P4-J-7] Agents: social multiagents Chair:Naoki Fukuda Reviewer:Jun Ichikawa 3:50 PM - 5:30 PM Room P (Front-left room of 1F Exhibition hall)

[3P4-J-7-01] Explainable Compromising Algorithm based

on Constraint Relaxation for Automated **Negotiating Agents** OShun Okuhara<sup>1,2</sup>, Takayuki Ito<sup>2</sup> (1. Fujita Health University, 2. Nagoya Institute of Technology) 3:50 PM - 4:10 PM

[3P4-J-7-02] An allocation strategy with deep

reinforcement learning for efficient task processing in multi agent system OGenki Matsuno<sup>1</sup>, Sho Tanaka<sup>2</sup>, Hiroki Hara<sup>2</sup>, Syunyo Kawamoto<sup>2</sup>, Syo Shimoyama<sup>2</sup>, Takashi Kawashima<sup>2</sup>, Daisuke Tsumita<sup>2</sup>, Yasushi Kido<sup>1</sup>, Osamu Hashimoto<sup>1</sup>, Tomohiro Takagi<sup>2</sup> (1. Skydisc, Inc., 2. Meiji University) 4:10 PM - 4:30 PM

[3P4-J-7-03] Omoiyari as Filling Gaps Making Collective Adaptation

> OYoshimiki Maekawa<sup>1</sup>, Fumito Uwano<sup>1</sup>, Eiki Kitajima<sup>1</sup>, Keiki Takadama<sup>1</sup> (1. The University of Electro-Communications)

4:30 PM - 4:50 PM

[3P4-J-7-04] Investigation of online simulation method of social consensus formation OYasuko Kawahata<sup>1</sup>, Akira Ishii<sup>2</sup>, Takuya Ueoka<sup>1</sup>

> (1. Gunma University, 2. Tottori University) 4:50 PM - 5:10 PM

[3P4-J-7-05] Estimation of agent's rewards with multiagent maximum discounted causal entropy inverse reinforcement learning OKeiichi Namikoshi<sup>1</sup>, Sachiyo Arai<sup>1</sup> (1. Chiba University) 5:10 PM - 5:30 PM

## Room Q

General Session | General Session | [GS] J-13 AI application [3Q3-J-13] AI application: analysis of physical behaviors in artifacts Chair: Takuya Hiraoka Reviewer: Yoichi Sasaki 1:50 PM - 3:10 PM Room Q (6F Meeting room, Bandaijima bldg.)

[3Q3-J-13-01] Construction of Dataset for Feature

Extraction Performance Evaluation using **Aerial Photographs** OHiroyuki Ohno<sup>1</sup>, Ryo Endo<sup>1</sup>, Takayuki Nakano<sup>1</sup>,

Masako Shinoda<sup>1</sup> (1. Geospatial Information

Authority of Japan)

1:50 PM - 2:10 PM

[3Q3-J-13-02] Slime detection during pile construction using machine learning OSohei Arisaka<sup>1</sup>, Yuki Tamagawa<sup>1</sup>, Kojiro Takesue<sup>1</sup> (1. Kajima Corporation)

2:10 PM - 2:30 PM

[3Q3-J-13-03] The optimization and comparison of methods for the Air foil design using Deep Reinforcement Learning.

> OHitoshi Hattori<sup>1</sup>, Kazuo Yonekura<sup>1</sup> (1. IHI Corporation)

## 2:30 PM - 2:50 PM

[3Q3-J-13-04] Application of Gradient Booting regression toward the Computational Fluid Dynamics in the Manufacturing industry

OYutaro Ogawa<sup>1</sup>, Takuya Shimizu<sup>1</sup>, Toshiaki

Yokoi<sup>1</sup> (1. INFORMATION SERVICES

INTERNATIONAL-DENTSU, LTD.)

2:50 PM - 3:10 PM

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

## [3Q4-J-13] Al application: transformation system Chair:Masahiro Tada Reviewer:Masayuki Otani 3:50 PM - 5:10 PM Room Q (6F Meeting room, Bandaijima bldg.)

| [3Q4-J-13-01] | Traffic anomaly detection using ETC2.0   |
|---------------|--|
|               | probe data   |
|               | ⊖Atsuki Masuda <sup>1</sup> , Masaki Matsudaira <sup>1</sup> (1. Oki                     |
|               | Electric Industry Co,.Ltd.)  |
|               | 3:50 PM - 4:10 PM  |
| [3Q4-J-13-02] | Design method for high efficiency drone  |
|               | highway network  |
|               | OMasatoshi Hamanaka <sup>1</sup> (1. RIKEN)  |
|               | 4:10 PM - 4:30 PM  |
| [3Q4-J-13-03] | Classification for time-sequence data  |
|               | appeared in shift control of automobile  |
|               | automatic transmission   |
|               | OYusuke Morikawa <sup>1</sup> , Yasuhiro Ishihara <sup>1</sup> ,                         |
| -             | Takanori Ide <sup>1</sup> , Eiji Moriyama <sup>1</sup> , Taku Akita <sup>1</sup> , Yasuo |
| -             | Tabei <sup>2</sup> , Takehito Utsuro <sup>3</sup> , Hiroshi Nakagawa <sup>2</sup>        |
|               | (1. Aisin AW Co., Ltd., 2. RIKEN, Center for   |
|               | Advanced Intelligence Project, 3. Fclty. Eng, Inf.                                       |
|               | &Sys, Univ. of Tsukuba)  |
|               | 4:30 PM - 4:50 PM  |
| [3Q4-J-13-04] | Likelihood distribution of Pedestrian  |
|               | Trajectories rendered by Variational   |
|               | Autoencoder  |
|               | $\bigcirc$ Yasunori Yokojima <sup>1</sup> , Tatsuhide Sakai <sup>2</sup> (1.             |
| :             | Siemens K.K., 2. Great Wall Motor)   |
|               | 4:50 PM - 5:10 PM  |
|               |  |

## Room D

Organized Session | Organized Session | [OS] OS-4

[3D3-OS-4a] 自律・創発・汎用 AIアーキテクチャ(1) 栗原 聡 (慶應義塾大学)、川村 秀憲(北海道大学)、津田一郎 (中部大学)、大倉 和博(広島大学) 1:50 PM - 3:10 PM Room D (301B Medium meeting room)

[3D3-OS-4a-01] Story Association Mediated by Individual

#### and General Concepts

OTaisuke Akimoto<sup>1</sup> (1. Kyushu Institute of Technology) 1:50 PM - 2:10 PM

[3D3-OS-4a-02] How "intelligence" is called as

## "intelligence"?

OMasayuki Yoshinobu<sup>1</sup> (1. Freelance) 2:10 PM - 2:30 PM

[3D3-OS-4a-03] Double Articulation Analyzer with Prosody for Unsupervised Word

Discovery

- OYasuaki Okuda<sup>1</sup>, Ryo Ozaki<sup>1</sup>, Tadahiro Taniguchi<sup>1</sup> (1. Ritsumeikan University) 2:30 PM - 2:50 PM
- [3D3-OS-4a-04] Generating Collective Behavior of a Robotic Swarm in a Two-landmark Navigation Task with Deep

Neuroevolution

ODaichi Morimoto<sup>1</sup>, Motoaki Hiraga<sup>1</sup>,

Kazuhiro Ohkura<sup>1</sup>, Yoshiyuki Matsumura<sup>2</sup> (1. Hiroshima University, 2. Shinsyu University)

2:50 PM - 3:10 PM

Organized Session | Organized Session | [OS] OS-4

[3D4-OS-4b] 自律・創発・汎用 AIアーキテクチャ(2) 栗原 聡 (慶應義塾大学)、川村 秀憲(北海道大学)、津田一郎 (中部大学)、大倉 和博(広島大学) 3:50 PM - 5:10 PM Room D (301B Medium meeting room)

[3D4-OS-4b-01] Introducing a Call Stack into the RGoal Hierarchical Reinforcement Learning Architecture OYuuji Ichisugi<sup>1</sup>, Naoto Takahashi<sup>1</sup>, Hidemoto Nakada<sup>1</sup>, Takashi Sano<sup>2</sup> (1. National Institute of Advanced Industrial Science and Technology (AIST), 2. Department of Computer and Information Science, Faculty of Science and Technology, Seikei University) 3:50 PM - 4:10 PM [3D4-OS-4b-02] Avoiding catastrophic forgetting in echo state networks by minimizing the connection cost
OYuji Kawai<sup>1</sup>, Yuho Ozasa<sup>1</sup>, Jihoon Park<sup>1</sup>, Minoru Asada<sup>1</sup> (1. Osaka University) 4:10 PM - 4:30 PM
[3D05-06-3] Special program 4:30 PM - 5:10 PM

#### Room E

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

[3E3-OS-12a] 画像と AI (MIRU2019プレビュー)(1) 長原 - (大阪大学)、川崎 洋(九州大学)、岡部 孝弘(九州工業 大学)

1:50 PM - 3:10 PM Room E (301A Medium meeting room)

[3E3-OS-12a-01] Convolutional Neural Network for Image

**Recognition and Visual Explanation** 

OTakayoshi Yamashita<sup>1</sup> (1. Chubu

University)

1:50 PM - 2:30 PM

[3E3-OS-12a-02] Adaptive selection of auxiliary tasks in UNREAL

OHidenori Itaya<sup>1</sup>, Tsubasa Hirakawa<sup>1</sup>,

Yamashita Takayoshi<sup>1</sup>, Fujiyoshi Hironobu<sup>1</sup>

(1. Chubu University)

2:30 PM - 2:50 PM

[3E3-OS-12a-03] ShakeDrop Regularization for ResNet

Family

OYoshihiro Yamada<sup>1</sup>, Masakazu Iwamura<sup>1</sup>, Koichi Kise<sup>1</sup> (1. Osaka Prefecture University)

2:50 PM - 3:10 PM

Organized Session | Organized Session | [OS] OS-12 [3E4-OS-12b] 画像とAI (MIRU2019プレ ビュー) (2) 長原 - (大阪大学)、川崎洋(九州大学)、岡部孝弘(九州工業 大学) 3:50 PM - 5:10 PM Room E (301A Medium meeting room)

[3E4-OS-12b-01] Neural 3D Mesh Renderer OHiroharu Kato<sup>1</sup>, Yoshitaka Ushiku<sup>1</sup>, Tatsuya Harada<sup>1</sup> (1. The University of Tokyo) 3:50 PM - 4:10 PM [3E4-OS-12b-02] Between-class Learning for Image Classification

OYuji Tokozume<sup>1</sup>, Yoshitaka Ushiku<sup>1</sup>,

©The Japanese Society for Artificial Intelligence

| Tatsuya Harada <sup>1,2</sup> (1. The University of                         | Behaviour of Other Players  |
|---|---|
| Tokyo, 2. RIKEN)  | OHinako Tamai <sup>1</sup> (1. Nara Women's                           |
| 4:10 PM - 4:30 PM   | University)   |
| [3E4-OS-12b-03] A Generative Framework for Creative                         | 3:10 PM - 3:30 PM   |
| Data Based on the Generative  |   |
| Adversarial Networks  | Organized Session   Organized Session   [OS] OS-14                    |
| ORiku Fujimoto <sup>1</sup> , Takato Horii <sup>1</sup> , Tatsuya           | [3F4-OS-14b] 人狼知能と不完全情報ゲーム(2)   |
| Aoki <sup>1</sup> , Takayuki Nagai <sup>1,2</sup> (1. The University        |   |
| of Electro-Commnications, 2. Osaka  | 3:50 PM - 5:30 PM Room F (302B Medium meeting room)                   |
| University)   |   |
| 4:30 PM - 4:50 PM   | [3F4-OS-14b-01] Development and evaluation of the                     |
| [3E4-OS-12b-04] Modeling of prejudice eves by designers                     | game agent to change confidence of                                    |
| ORvuichi Ishikawa <sup>1</sup> . Kou Izumi <sup>1</sup> . Hidekazu          | estimating in Cooperative game Hanabi                                 |
| Havashi <sup>1</sup> , Hiroyuki Fukuda <sup>2</sup> (1,                     | $\bigcirc$ Eisuke Sato <sup>1</sup> , Hirotaka Osawa <sup>1</sup> (1. |
|   | University of Tsukuba)  |
| 4:50 PM - 5:10 PM   | 3:50 PM - 4:10 PM   |
| 4.50 FIM - 5.10 FIM   | [3F4-OS-14b-02] Role estimation in Werewolf games                     |
| Boom F  | using a selective desensitization neural                              |
| Koonii F  | network   |
| Organized Session   Organized Session   [OS] OS-14                          | Masahiro Saito <sup>2</sup> , Seiryu Mishina <sup>1</sup> , OKen      |
| [3F3-OS-14a] 人狼知能と不完全情報ゲーム(1)   | Yamane <sup>1</sup> (1. Teikyo University, 2. Fujisoft                |
| 稲葉 通将(広島市立大学)、片上 大輔(東京工芸大学)、狩野  | Incorporated)   |
| 芳伸(静岡大学)、大槻 恭士(山形大学)<br>1:50 PM - 2:20 PM Poom 5 (2028 Modium mosting room) | 4:10 PM - 4:30 PM   |
|   | [3F4-OS-14b-03] Artificial Intelligence for Deducing Roles            |
| [3F3-OS-14a-01] Analyzing Gestures in Real-World                            | of Players in the Werewolf Game using                                 |
| Werewolf Game   | Information about Conversations among                                 |
| $\bigcirc$ Shutarou Takayama $^1$ , Hirotaka Osawa $^1$ (1.                 | Players   |
| University of Tsukuba)  | OMunemichi Fukuda <sup>1</sup> , Hajime Anada <sup>1</sup> (1.        |
| 1:50 PM - 2:10 PM   | Tokyo City University)  |
| [3F3-OS-14a-02] "Goodness" analysis of a Werewolf                           | 4:30 PM - 4:50 PM   |
| Game's player based on a biological   | [3F4-OS-14b-04] Extraction of Interpretable Rules for                 |
| signal  | Role and Team Estimation in Al Wolf                                   |
| OHirotaka Yamamoto <sup>1</sup> , Nagisa Munekata <sup>1</sup>              | Yuki Omura <sup>1</sup> , Wataru Sakamoto <sup>1</sup> , OT           |
| (1. Kyoto Sangyo University)  | omonobu Ozaki <sup>1</sup> (1. Nihon University)                      |
| 2:10 PM - 2:30 PM   | 4:50 PM - 5:10 PM   |
| [3F3-OS-14a-03] Simulation of Strategic Evolution in 5-                     | [3F06-09-5] Discussion / Conclusion                                   |
| player Werewolf   | 5:10 PM - 5:30 PM   |
| $\bigcirc$ Atsushi Takeda <sup>1</sup> , Fujio Toriumi <sup>1</sup> (1. The |   |
| University of Tokyo)  | Room G  |
| 2:30 PM - 2:50 PM   |   |
| [3F3-OS-14a-04] Simulation Analysis based on Behavioral                     | Organized Session   Organized Session   [OS] OS-18                    |
| Experiment of Cooperative Pattern Task                                      | [3G3-OS-18a] 感情と Al(1)  |
| $\bigcirc$ Norifiumi Watanabe <sup>1</sup> Kota Itoda <sup>2</sup> (1       | 日永田 智絵(電気通信大学)、堀井 隆斗(電気通信大学)、長井                                       |
| Mussching University 2 Keig University)                                     | 隆行(天阪大子)<br>1:50 PM - 3:30 PM Room G (302A Medium meeting room)       |
| 2.50  PM = 3.10  PM   |   |
| 2.30 FIVE - 3.10 FIVE   | [3G3-OS-18a-01] (Invited talk) Predictive coding of                   |
| by 2 Devore Considering Veting  | interoception and affective emergence                                 |
|   |   |

| OHideki                   | Dhira <sup>1</sup> (1. Nagoya University)                  |
|---------------------------|--|
| 1:50 PM                   | - 2:30 PM  |
| [3G3-OS-18a-02] Action Se | election based on Somatic                                  |
| Marker H                  | lypothsis  |
| OChie Hi                  | eida <sup>1</sup> , Takato Horii <sup>1</sup> , Takayuki   |
| Nagai <sup>1,2</sup>      | (1. The University of Electro-                             |
| Communi                   | cations, 2. Osaka University)                              |
| 2:30 PM                   | - 2:50 PM  |
| [3G3-OS-18a-03] Active pe | erception based on free-energy                             |
| minimiza                  | tion on restricted Boltzmann                               |
| machine                   | s  |
| OTakato                   | Horii <sup>1</sup> , Takayuki Nagai <sup>1,2</sup> (1. The |
| University                | of Electro-Communications, 2.                              |
| Osaka Un                  | iversity)  |
| 2:50 PM                   | - 3:10 PM  |
| [3G3-OS-18a-04] Extractio | n of Neuroscientific Findings                              |
| by Visua                  | ization of Deep Neural                                     |
| Network                   |  |
| OKazuki                   | Sakuma <sup>1</sup> , Junya Morita <sup>1</sup> , Taiki    |
| Nomura <sup>2</sup> ,     | Takatsugu Hirayama <sup>3</sup> , Yu                       |
| Enokibori                 | <sup>3</sup> , Kenji Mase <sup>3</sup> (1. Faculty of      |
| Informatio                | cs, Shizuoka University, 2. Graduate                       |
| School of                 | Information Science, Nagoya                                |
| University                | , 3. Graduate School of Informatics,                       |
| Nagoya U                  | niversity)   |
| 3:10 PM                   | - 3:30 PM  |
|                           |  |

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

[3G4-OS-18b] 感情と AI(2) 日永田 智絵(電気通信大学)、堀井 隆斗(電気通信大学)、長井 隆行 (大阪大学) 3:50 PM - 5:30 PM Room G (302A Medium meeting room)

[3G4-OS-18b-01] Automatic Detection of Insincere

## Utterances with LSTM

OKazuya Mio<sup>1</sup>, Aya Ishino<sup>2</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa<sup>1</sup> (1. Graduate School of Information Sciences, Hiroshima City University, 2. Faculty of Media Business, Hiroshima University of Economics) 3:50 PM - 4:10 PM [3G4-OS-18b-02] A Study on Concept Acquisition Method

for User Preference in Dialogue for Empathy

> OTakahisa Uchida<sup>1,2</sup>, Takashi Minato<sup>2</sup>, Yutaka Nakamura<sup>1</sup>, Yuichiro Yoshikawa<sup>1</sup>, Hiroshi Ishiguro<sup>1,2</sup> (1. Osaka University, 2.

| Advanced Telecommunications Research                          |
|---|
| Institute International)                                      |
| 4:10 PM - 4:30 PM   |
| [3G4-OS-18b-03] A personalized model to estimate              |
| emotion of individual based on                                |
| observed facial expression and                                |
| generation of robot behavior                                  |
| OKazumi Kumagai <sup>1</sup> , Ikuo Mizuuchi <sup>1</sup> (1. |
| Tokyo University of Agriculture and                           |
| Technology)   |
| 4:30 PM - 4:50 PM   |
| [3G4-OS-18b-04] Human inference system derived from           |
| emotion as a value calculation system                         |
| hypothesis  |
| OMasahiro Miyata <sup>1</sup> , Takashi Mory <sup>2</sup> (1. |
| Graduate School of Engineering, Tamagawa                      |
| University, 2. College of Engineering,                        |
| Tamagawa University)  |
| 4:50 PM - 5:10 PM   |
| [3G4-OS-18b-05] Agents which generate and estimate            |
| emotions based on logical model                               |
| OMai Tsukamoto <sup>1</sup> (1. Nara Women's                  |
| University)   |
| 5:10 PM - 5:30 PM   |

#### Room L

Organized Session | Organized Session | [OS] OS-22 [3L3-OS-22a] 創作者と人工知能が創る創作の未来(1) 上野 未貴(豊橋技術科学大学)、森 直樹(大阪府立大学)、はたな

か たいち((株)クリエイターズインパック) 1:50 PM - 3:30 PM Room L (203+204 Small meeting rooms)

[3L3-OS-22a-01] (Invited talk) The Future of Animation Industry Drawn by Creators and Artificial Intelligence OTaichi Hatanaka<sup>1</sup> (1. Creators in Pack

Inc.)

1:50 PM - 2:10 PM

[3L3-OS-22a-02] A Proposal of a Mathematical Story

Generation Method Based on Hero's Journey

Onoguchi katsuhiro<sup>1</sup> (1. comic artist) 2:10 PM - 2:30 PM

[3L3-OS-22a-03] Narrative Structure Analysis Punchlines of SF Genre within the Flash Fiction of Shinichi Hoshi

OShuuhei Toyosawa<sup>1</sup>, Hajime Murai<sup>1</sup> (1.

Future University Hakodate)

2:30 PM - 2:50 PM

[3L3-OS-22a-04] Story Creation System based on

Sentence Similarity for Supporting Contents Creation

OHaruka Takahashi<sup>1</sup>, Miki Ueno<sup>1</sup>, Hitoshi Isahara<sup>1</sup> (1. Toyohashi University of Technology)

2:50 PM - 3:10 PM

[3L3-OS-22a-05] Classification method for four-scene comics based on Creative Viewpoint ONaoki Mori<sup>1</sup> (1. Osaka Prefecture University) 3:10 PM - 3:30 PM

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

[3L4-OS-22b] 創作者と人工知能が創る創作の未来(2) 上野未貴(豊橋技術科学大学)、森 直樹(大阪府立大学) 3:50 PM - 5:30 PM Room L (203+204 Small meeting rooms)

[3L4-OS-22b-01] Autonomous Collection and Feedback of Dialogue Profile for Dialogue **Contents Circulation** Masaki Mori<sup>1</sup>, OAkinobu Lee<sup>1</sup> (1. Nagoya Institute of Technology, Japan) 3:50 PM - 4:10 PM [3L4-OS-22b-02] A Discussion about Jazz Improvisation System based on Studies with First-Person's View ODaichi Ando<sup>1</sup> (1. Tokyo Metropolitan University) 4:10 PM - 4:30 PM [3L4-OS-22b-03] Of application of artificial intelligence to fashion design OYoko Fujishima<sup>1,3</sup>, Osamu Sakura<sup>2,3</sup> (1. Graduate School of Interdisciplinary Information Studies, The University of Tokyo, 2. Interfaculty Initiative in Information Studies, The University of Tokyo, 3. RIKEN-AIP) 4:30 PM - 4:50 PM [3L4-OS-22b-04] Tone Pasting Using cGANs with Tone Feature Loss OKoki Tsubota<sup>1</sup>, Kiyoharu Aizawa<sup>1</sup> (1. The University of Tokyo) 4:50 PM - 5:10 PM [3L4-OS-22b-05] Creative Future will be Created by

Contents Creators and Artifical Intelligence OMiki Ueno<sup>1</sup> (1. Toyohashi University of Technology) 5:10 PM - 5:30 PM

## Room P

Organized Session | Organized Session | [OS] OS-20

[3P3-OS-20] 脳波から音声言語情報を抽出・識別する 新田 恒雄(早稲田大学/豊橋技術科学大学)、桂田 浩一(東京理科 大学)、入部 百合絵(愛知県立大学)、田口 亮(名古屋工業大学) 1:50 PM - 3:30 PM Room P (Front-left room of 1F Exhibition hall)

[3P3-OS-20-01] Describing Brain Activity Evoked by Speech Stimuli ORino Urushihara<sup>1</sup>, Ichiro Kobayashi<sup>1</sup>, Hiroto

Yamaguchi<sup>2,3</sup>, Tomoya Nakai<sup>2,3</sup>, Shinji

Nishimoto<sup>2,3</sup> (1. Ochanomizu University, 2.

National Institute of Information and

Communications Technology, 3. Osaka University)

1:50 PM - 2:10 PM

[3P3-OS-20-02] Development of Syllable Labelling Tool

for Electroencephalogram Data OMingchuan Fu<sup>1</sup>, Ryo Taguchi<sup>1</sup>, Kentaro

Fukai<sup>2</sup>, Kouichi Katsurada<sup>2</sup>, Tsuneo Nitta<sup>3,4</sup>

(1. Nagoya Institute of Technology, 2. Tokyo University of Science, 3. Waseda University, 4.

Toyohashi University of Technology)

2:10 PM - 2:30 PM

[3P3-OS-20-03] Word Recognition from speech-imagery EEG

> OSatoka Hirata<sup>1</sup>, Yurie Iribe<sup>1</sup>, Kentaro Fukai<sup>2</sup>, Kouichi Katsurada<sup>2</sup>, Tsuneo Nitta<sup>3,4</sup> (1. Aichi Prefectural Univ., 2. Tokyo Univ. of Science, 3. Waseda Univ., 4. Toyohashi Univ. of Tech.) 2:30 PM - 2:50 PM

[3P3-OS-20-04] Syllable recognition in speech-imagery EEG OKentaro Fukai<sup>1</sup>, Hidefumi Ohmura<sup>1</sup>, Kouichi

Katsurada<sup>1</sup>, Tsuneo Nitta<sup>2,3</sup> (1. Tokyo University of Science, 2. Waseda University, 3. Toyohashi University of Technology) 2:50 PM - 3:10 PM

[3P3-OS-20-05] BCI Studies on Extraction of Spoken Language representation from Speech Imagery EEG OTsuneo Nitta<sup>1</sup>, KENTAROU FUKAI<sup>2</sup>, KOUICHI KATSURADA<sup>2</sup>, YURIE IRIBE<sup>3</sup>, RYOU TAGUCHI<sup>4</sup>, SHUNJI SUGIMOTO<sup>5</sup>, JUNSEI HORIKAWA<sup>5</sup> (1. Waseda University, 2. Tokyo Science University, 3. Aichi Prefectural University, 4. Nagoya Institute of Technology, 5. Toyohashi University of Technology) 3:10 PM - 3:30 PM

## Thu. Jun 6, 2019 Room R [3Rin2] Interactive Session 1 10:30 AM - 12:10 PM Room R (Center area of 1F Exhibition hall) [3Rin2-01] Traffic Risk Estimation from On-vehicle Video by Region-based Spatio-temporal DNN trained using Comparative Loss OKwong Cheong Ng<sup>1</sup>, Yuki Murata<sup>1</sup>, Masayasu Atsumi<sup>1</sup> (1. Dept. of Information Systems Sci., Graduate School of Eng., Soka University) 10:30 AM - 12:10 PM [3Rin2-02] Bi-directional multimodal generation via estimating conditional distribution of latent variables obtained from pre-trained generative models OShigeaki Imakiire<sup>1</sup>, Masanao Ochi<sup>1</sup>, Junichiro Mori<sup>1</sup>, Ichiro Sakata<sup>1</sup> (1. University of Tokyo School of Engineering Department of Technology Management for Innovation) 10:30 AM - 12:10 PM [3Rin2-03] Binarized Variational Information Bottleneck OMakoto Kawano<sup>1</sup>, Yu Oya<sup>2</sup>, Satoshi Yagi<sup>2</sup>, Jin Nakazawa<sup>1</sup> (1. Keio University, 2. NTT Corporation) 10:30 AM - 12:10 PM [3Rin2-04] Semi-supervised Domain Adaptation using Prediction Models in Associated Domains OYasuhiro Sogawa<sup>1</sup>, Tomoya Sakai<sup>1</sup> (1. NEC Corporation) 10:30 AM - 12:10 PM [3Rin2-05] A study on measures in multi-armed bandit problem with hidden state. OKouhei Kudo<sup>1</sup>, Takashi Takekawa<sup>1</sup> (1. Kogakuin University) 10:30 AM - 12:10 PM [3Rin2-06] An Approach to Unseen Classs Classification with In-Service Predictors OTomoya Sakai<sup>1</sup>, Yasuhiro Sogawa<sup>1</sup> (1. NEC Corporation) 10:30 AM - 12:10 PM [3Rin2-07] Multi-armed bandit algorithm applicable to

[3Rin2-07] Multi-armed bandit algorithm applicable to stationary and non-stationary environment using self-organizing maps ONobuhito Manome<sup>1,2</sup>, Shuji Shinohara<sup>2</sup>, Kouta Suzuki<sup>1,2</sup>, Kosuke Tomonaga<sup>1,2</sup>, Shunji Mitsuyoshi<sup>2</sup> [3Rin2-08] Learning Interpretable Control Policies with Decision Trees via the Cross-Entropy Method OYukiko Tanaka<sup>1,2</sup>, Takuya Hiraoka<sup>1,2</sup>, Yoshimasa Tsuruoka<sup>2,3</sup> (1. NEC, 2. National Institute of Advanced Industrial Science and Technology, 3. The University of Tokyo)

10:30 AM - 12:10 PM

 [3Rin2-09] Development of Embedded System for Recognizing Kuzushiji by Deep Learning Masahiro Takeuchi<sup>1</sup>, OTaichi Hayasaka<sup>1</sup>, Wataru Ohno<sup>1</sup>, Yumie Kato<sup>2</sup>, Kazuaki Yamamoto<sup>3</sup>, Mamoru Ishima<sup>4</sup>, Tetsuya Ishikawa<sup>4</sup> (1. National Institute of Technology, Toyota College, 2. Tsurumi University, 3. National Institute of Japanese Literature, 4. TRC-ADEAC, Inc.)

10:30 AM - 12:10 PM

- [3Rin2-10] Stochastic Regularization for Residual Networks: Shake-ResDrop and Shake-SENet OJunya Shirahama<sup>1</sup>, Kazuhiko Kawamoto<sup>1</sup> (1. Chiba University)
   10:30 AM - 12:10 PM
- [3Rin2-11] Fairness-aware Edit of Thresholds in a Learned Decision Tree Using a Mixed Integer Programming Formulation OKentaro Kanamori<sup>1</sup>, Hiroki Arimura<sup>1</sup> (1. Hokkaido University) 10:30 AM - 12:10 PM
- [3Rin2-12] Predicting Laughters in Comedy Drama with Subtitles and Facial Expression

OYuta Kayatani<sup>1</sup>, Mayu Otani<sup>2</sup>, Chenhui Chu<sup>3</sup>, Yuta Nakashima<sup>3</sup>, Haruo Takemura<sup>1</sup> (1. Graduate School of Information Science and Technology, Osaka University, 2. CyberAgent, Inc., 3. Institute for Datability Science, Osaka University) 10:30 AM - 12:10 PM

[3Rin2-13] Application of Aspect-based Sentiment Analysis using Self-Attention Mechanism to Japanese Sentences ORyuichi Akai<sup>1</sup>, Masayasu Atsumi<sup>1</sup> (1. Graduate School of Engineering, Soka University)

10:30 AM - 12:10 PM

[3Rin2-14] Estimating Emotion Intensities in Japanese Tweets Using Emotion Intensity Lexicon OTatsuki Akahori<sup>1</sup>, Kohji Dohsaka<sup>1</sup>, Hidekatsu Ito<sup>1</sup>, Masaki Ishii<sup>1</sup> (1. Akita Prefectural University) 10:30 AM - 12:10 PM

[3Rin2-15] An Investigation of Effective Features for Toponym Resolution of Words in Newspaper Articles ORyo Seki<sup>1</sup>, Takashi Inui<sup>1</sup> (1. University of

10:30 AM - 12:10 PM

Tsukuba)

- [3Rin2-16] Cluster analysis of Twitter Data, using Interactive Data visualization Tool OShinichiro Wada<sup>1</sup> (1. Graduate School of Sociology, Rikkyo University.) 10:30 AM - 12:10 PM
- [3Rin2-17] Comparative Analysis of the Effect of Additional Training between Multiple Domains by Clustering of the Embeddings of Parsing Errors OTakuya Hara<sup>1</sup>, Takuya Matsuzaki<sup>1</sup>, Hikaru Yokono<sup>2</sup>,
  - Satoshi Sato<sup>1</sup> (1. Graduate School of Engineering, Nagoya University, 2. Fujitsu Laboratories Ltd.) 10:30 AM - 12:10 PM
- [3Rin2-18] Vending Machine Drink Recognition with Deep Learning for IoT Device.
  - OKatsuhiro Araya<sup>1</sup>, Takayuki Osa<sup>2</sup>, Shigemitsu Yamaoka<sup>2</sup>, Kazuhiko Nishi<sup>2</sup>, Masayuki Nakao<sup>2</sup> (1. Arkth Inc., 2. University of Tokyo, School of Engineering)
  - 10:30 AM 12:10 PM
- [3Rin2-19] Robust Eye Contact Detection for Multi-Party Conversational Systems OKenjiro Nogawa<sup>1</sup>, Shinya Fujie<sup>2</sup>, Tetsunori Kobayashi<sup>1</sup> (1. Waseda University, 2. Chiba Institute of Technology)

10:30 AM - 12:10 PM

- [3Rin2-20] Succesive estimation of the asteroid shape and probe motion using sequential images
   OToma Suzuki<sup>1</sup>, Takehisa Yairi<sup>1</sup>, Naoya Takeishi<sup>1</sup>, Yuichi Tsuda<sup>2</sup>, Naoko Ogawa<sup>2</sup> (1. The University of Tokyo, 2. Japan Aerospace Exploration Agency)
   10:30 AM - 12:10 PM
- [3Rin2-21] Image-to-image Translation from Apparel Item Image Placed Flat to Image Put on Using Deep Neural Networks Saki Tsumugiwa<sup>1</sup>, OYoshiaki Kurosawa<sup>1</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa<sup>1</sup> (1. Hiroshima City

University) 10:30 AM - 12:10 PM [3Rin2-22] Noise reduction of live image in scanning electron microscope OFuminori Uematsu<sup>1</sup>, Masahiko Takei<sup>1</sup>, Mitsuyoshi Yoshida<sup>1</sup> (1. JEOL Ltd.) 10:30 AM - 12:10 PM [3Rin2-23] Truthful Dynamic Pricing Mechanisms for Ondemand Mobility Services OKeiichiro Hayakawa<sup>1</sup>, Eiji Hato<sup>2</sup> (1. Toyota Central R&D Labs., Inc., 2. The University of Tokyo) 10:30 AM - 12:10 PM [3Rin2-24] Multi-agent simulation tool incorporation group evacuation behavior model ORyusei Ishida<sup>1</sup>, Masanori Akiyoshi<sup>1</sup> (1. Kanagawa University) 10:30 AM - 12:10 PM [3Rin2-25] A study of observation fluctuation reduction method for ear acoustic authentication OMasaki Yasuhara<sup>1</sup>, Takayuki Arakawa<sup>2</sup>, Takafumi Koshinaka<sup>2</sup>, Shohei Yano<sup>1</sup> (1. National Institute of Technology, Nagaoka College, 2. NEC Corporation) 10:30 AM - 12:10 PM [3Rin2-26] New similarity scale to recognize bird calls and abnormal sounds of concrete/machine OMichihiro Jinnai<sup>1</sup>, Edward James Pedersen<sup>2</sup> (1. Nagoya Women's University, 2. Central Queensland University, Australia) 10:30 AM - 12:10 PM [3Rin2-27] An Investigation of Controllable Neural Conversation Model with Dialogue Acts OSeiya Kawano<sup>1</sup>, Koichiro Yoshino<sup>1,2</sup>, Satoshi Nakamura<sup>1</sup> (1. Nara Institute of Science and Technology, 2. Japan Science and Technology

10:30 AM - 12:10 PM

Agency)

- [3Rin2-28] Improvement of Knowledge Graph Completion
   Using Label Characters for Questions to
   Acquire Knowledge in Dialog Systems
   OYuma Fujioka<sup>1</sup>, Katsuhiko Hayashi<sup>1</sup>, Mikio
   Nakano<sup>2</sup>, Kazunori Komatani<sup>1</sup> (1. The Institute of
   Scientific and Industrial Research, Osaka University,
   2. Honda Research Institute Japan Co.,Ltd.)
   10:30 AM 12:10 PM
- [3Rin2-29] Acquisition and Utilization of Trivia for Conversational News Contents Delivery

OHiroaki Takatsu<sup>1</sup>, Yoichi Matsuyama<sup>1</sup>, Hiroshi Honda<sup>2</sup>, Shinya Fujie<sup>1,3</sup>, Tetsunori Kobayashi<sup>1</sup> (1. Waseda University, 2. Honda R&D Co.,Ltd., 3. Chiba Institute of Technology) 10:30 AM - 12:10 PM

- [3Rin2-30] Generative Adversarial Networks toward
   Representation Learning for Image Captions
   OYuki Abe<sup>1</sup>, Takuma Seno<sup>1</sup>, Shoya Matsumori<sup>1</sup>,
   Michita Imai<sup>1</sup> (1. Keio University)
   10:30 AM 12:10 PM
- [3Rin2-31] Speech extraction from conversation based on image-to-image translation using deep neural networks
  - OKosuke Takaichi<sup>1</sup>, Yoshio Katagami<sup>2</sup>, Yoshiaki Kurosawa<sup>1</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa<sup>1</sup> (1. Graduate School of Information Sciences Hiroshima City University, 2. School of Information Sciences Hiroshima City University)

10:30 AM - 12:10 PM

 [3Rin2-32] An anti-noise performance comparison between acoustic features in detecting voice pathology using machine learning OKouta Suzuki<sup>1,2</sup>, Shuji Shinohara<sup>2</sup>, Nobuhito Manome<sup>1,2</sup>, Kosuke Tomonaga<sup>1,2</sup>, Shunji Mitsuyoshi<sup>2</sup> (1. SoftBank Robotics Corp., 2. Graduate School of Engineering, The University of Tokyo) 10:30 AM - 12:10 PM

[3Rin2-33] Toward proofreading support using Word2vec
 OMasato Maruyama<sup>1</sup>, Takashi Takekawa<sup>1</sup> (1.
 Kogakuin University)
 10:30 AM - 12:10 PM

[3Rin2-34] Construction of Corpus for Text Simplification by Sentential Alignment based on Decomposable Attention Model OKoichi Nagatsuka<sup>1</sup>, Masayasu Atsumi<sup>1</sup> (1. Soka University)

10:30 AM - 12:10 PM

[3Rin2-35] What's Here Like ? Analysis of Web Search Log Based on User's Location OTatsuru Higurashi<sup>1</sup>, Kouta Tsubouchi<sup>1</sup> (1. Yahoo Japan Corporation) 10:30 AM - 12:10 PM

[3Rin2-36] Relevance Analysis among Domestic Enjoyments based on News Site App Users' Interest OKota Kawaguchi<sup>2,1</sup>, Tatsukuni Inoue<sup>1</sup>, Seiya

Osada<sup>1</sup>, Tatsuo Yamashita<sup>1</sup> (1. Yahoo! JAPAN, 2. University of Tsukuba) 10:30 AM - 12:10 PM [3Rin2-37] Implementation and Evaluation of an Interpretable Fake News Detector OKazuya Yamamoto<sup>1</sup>, Satoshi Oyama<sup>1</sup>, Masahito Kurihara<sup>1</sup> (1. Hokkaido University) 10:30 AM - 12:10 PM [3Rin2-38] Automatic Evaluation for Cyberbullying Detection Method based on Statistical Scale OMasaki Arata<sup>1</sup>, Fumito Masui<sup>1</sup>, Michal Edmond Ptaszynski<sup>1</sup> (1. Kitami Institute of Technology) 10:30 AM - 12:10 PM [3Rin2-39] Automatic Impression Indexing based on Appraisal Dictionary from Tweet ORuna Yamada<sup>1</sup>, Sho Hashimoto<sup>1</sup>, Atsuhiro Yamada<sup>1</sup>, Noriko Nagata<sup>1</sup> (1. Kwansei Gakuin University) 10:30 AM - 12:10 PM [3Rin2-40] Catch Me if Yahoo Can: Hotel Recommendation for Potential Travelers using Transit App Log OMikiya Maruyama<sup>1</sup>, Kotaro Takahama<sup>1</sup>, Kota Tsubouchi<sup>1</sup>, Teruhiko Teraoka<sup>1</sup> (1. Yahoo Japan Corporation) 10:30 AM - 12:10 PM [3Rin2-41] Official document simplification using neural machine translation approach OTakumi Maruyama<sup>1</sup>, Kazuhide Yamamoto<sup>1</sup> (1. Nagaoka University of Technology) 10:30 AM - 12:10 PM [3Rin2-42] Neural Error Detection for Weather Forecast Manuscript by Pseudo Error Corpus ONaruhisa Shirai<sup>1</sup>, Masatsugu Hangyo<sup>2</sup>, Mamoru Komachi<sup>1</sup> (1. Tokyo Metropolitan University, 2. WEATHERNEWS INC.) 10:30 AM - 12:10 PM [3Rin2-43] Neural Sequence-Labelling Models for ASR **Error Correction** OTaishi Ikeda<sup>1</sup>, Hiroshi Fujimoto<sup>1</sup>, Takeshi Yoshimura<sup>1</sup>, Yoshinori Isoda<sup>1</sup> (1. NTT DOCOMO, INC.) 10:30 AM - 12:10 PM

[3Rin2-44] Construction of a Diagnosis Representation Model of Person with Dementia Based on ConceptNet for Deeper Understanding of Physical and Mental Conditions
ONaoki Kamiya<sup>1</sup>, Takumi Yoshizawa<sup>1</sup>, Shogo
Ishikawa<sup>1</sup>, Hideki Ueno<sup>2,4</sup>, Mia Kobayashi<sup>2,4</sup>, Minoru
Maeda<sup>3</sup>, Chiaki Nishiyama<sup>3</sup>, Yujun Murakami<sup>3</sup>,
Shinya Kiriyama<sup>1,4</sup>, Yoichi Takebayashi<sup>1,4</sup> (1.
Shizuoka University, 2. Chiba University Hospital, 3.
Orange Cross Foundation, 4. The Society of Citizen
Informatics for Human Cognitive Disorder)
10:30 AM - 12:10 PM

[3Rin2-45] Evaluation and Analysis of design for life environment with a high regard for selfreliance based on the representation of a self of people with dementia OMika Teramen<sup>1</sup>, Shogo Ishikawa<sup>1</sup>, Shinya

Kiriyama<sup>1</sup>, Tadasuke Kato<sup>2</sup>, Takeshi Ide<sup>2</sup>, Yoichi Takebayashi<sup>1,3</sup> (1. Shizuoka University, 2. Aoicare Co., Ltd, 3. Citizen Informatics for Human Cognitive Disorder)

10:30 AM - 12:10 PM

[3Rin2-46] Development of Electroencephalogram brainmachine interface using convolutional neural network

> OMasaki Kato<sup>1</sup>, Sotaro Shimada<sup>2</sup> (1. Meiji University Graduate School, 2. Meiji University) 10:30 AM - 12:10 PM

[3Rin2-47] Evaluation of Automatic Monitoring of Instillation Adherence Using Eye Dropper Bottle Sensor and Deep Learning in Patients with Glaucoma

> OHitoshi Tabuchi Tabuchi<sup>1,2</sup>, Kazuaki Nishimura<sup>1</sup>, Shunsuke Nakakura<sup>1</sup>, Hiroki Masumoto<sup>1</sup>, Hirotaka Tanabe<sup>1</sup>, Asuka Noguchi<sup>1</sup>, Ryota Aoki<sup>1</sup>, Yoshiaki Kiuchi<sup>2</sup> (1. Tsukazaki Hospital, 2. Hiroshima University)

10:30 AM - 12:10 PM

[3Rin2-48] Sleep/wake classification using remote PPG signals

Yawen Zhang<sup>1</sup>, OMasanori Tsujikawa<sup>2</sup>, Yoshifumi Onishi<sup>2</sup> (1. HKUST, 2. NEC)

10:30 AM - 12:10 PM

[3Rin2-49] Biomarker discovery from gene expression

data of mixed tumor samples

OKatsuhiko Murakami<sup>1</sup> (1. Fujitsu Laboratories Ltd.) 10:30 AM - 12:10 PM

## Room A

[3A1-PS-3] Explain Yourself – A Semantic Stack for Artificial Intelligence 9:00 AM - 10:10 AM Room A (2F Main hall A)

[3A1-PS-3] Explain Yourself – A Semantic Stack for Artificial Intelligence

> Randy Goebel<sup>1</sup> (1. Professor of Computing Science at the University of Alberta, Canada, and co-founder of the Alberta Machine Intelligence Institute (AMII)) 9:00 AM - 10:10 AM

#### Room I

[3I3-KS-8] 役に立つ人の心の過程のモデリング 1:50 PM - 3:30 PM Room I (306+307 Small meeting rooms)

[3I3-KS-8] 役に立つ人の心の過程のモデリング 1:50 PM - 3:30 PM

[3I4-KS-10] AIマップタスクフォースの活動一 AI初学 者・異分野研究者のための AI研究の俯瞰

3:50 PM - 5:30 PM Room I (306+307 Small meeting rooms)

[3I4-KS-10] AIマップタスクフォースの活動一 AI初学者・異 分野研究者のための AI研究の俯瞰一 3:50 PM - 5:30 PM

#### Room M

[3M4-KS-11] ヒューマンインタラクション技術による 自立共生支援 AIの研究開発と社会実装に 向けて 3:50 PM - 5:30 PM Room M (Front-right room of 1F Exhibition hall)

[3M4-KS-11] ヒューマンインタラクション技術による自立 共生支援 AIの研究開発と社会実装に向けて 3:50 PM - 5:30 PM

## Room O

[3O3-KS-9] 人工知能国際標準化への誘い 1:50 PM - 3:30 PM Room O (Front-left room of 1F Exhibition hall)

[3O3-KS-9] 人工知能国際標準化への誘い 1:50 PM - 3:30 PM

[3O4-KS-12] NEDO次世代人工知能中核技術 〜人を見 守り協働する人工知能の実現に向けて〜 3:50 PM - 5:30 PM Room O (Front-left room of 1F Exhibition hall)

[3O4-KS-12] NEDO次世代人工知能中核技術 〜人を見守り 協働する人工知能の実現に向けて〜 3:50 PM - 5:30 PM

Room M

## [3M3-IND-5] Industrial session 5

吉岡 健(富士ゼロックス株式会社) 1:50 PM - 3:30 PM Room M (Front-right room of 1F Exhibition hall)

[3M3-IND-5] Industrial session 5

1:50 PM - 3:30 PM

## Room C

[3C-LS] NEC Corporation 12:50 PM - 1:40 PM Room C (4F International conference hall)

[3C-LS] NEC Luncheon Seminar

今岡 仁<sup>1</sup>、中台 慎二<sup>1</sup> (1. NEC) 12:50 PM - 1:40 PM

## Room E

[3E-LS] HAKUHODO Inc. 12:50 PM - 1:40 PM Room E (301A Medium meeting room)

[3E-LS] Hakuhodo Luncheon Seminar

猪谷 誠一<sup>1</sup>、藤井 遼<sup>1</sup> (1. 株式会社博報堂) 12:50 PM - 1:40 PM

## Room M

## [3M-LS] Intel Corporation

12:50 PM - 1:40 PM Room M (Front-right room of 1F Exhibition hall)

[3M-LS] Intel Luncheon Seminar

志村 泰規<sup>1</sup>(1. インテル株式会社) 12:50 PM - 1:40 PM

## Room O

[3O-LS] DENTSU Inc.

12:50 PM - 1:40 PM Room O (Front-left room of 1F Exhibition hall)

[3O-LS] Dentsu Luncheon Seminar

12:50 PM - 1:40 PM

Room Y

## [3Y5-PS-5] Paricipants' networking meeting 6:00 PM - 7:30 PM Room Y (Bandaijima multi-purpose square)

[3Y5-PS-5] Participants' networking meeting

6:00 PM - 7:30 PM

International Session | International Session | [ES] E-2 Machine learning

## [3B3-E-2] Machine learning: image recognition and generation

Chair: Masakazu Ishihata (NTT)

Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room B (2F Main hall B)

| Design a Loss Function which Generates a Spatial configuration of   |
|---|
| OPaulino Cristovao <sup>1</sup> , Hidemoto Nakada <sup>1,2</sup> , Yusuke Tanimura <sup>1,2</sup> , Hideki Asoh <sup>2</sup> (1. University of Tsukuba, 2. National Advanced Institute of Science and Technology of Japan (AIST)) |
| 1:50 PM - 2:10 PM<br>One-shot Learning using Triplet Network with kNN classifier  |
| OMu Zhou <sup>1,2</sup> , Yusuke Tanimura <sup>2,1</sup> , Hidemoto Nakada <sup>2,1</sup> (1. University of Tsukuba, 2.<br>Artifical Intelligence Research Center, National Institute of Advanced Institute of                    |
| Technology)   |
| 2:10 PM - 2:30 PM   |
| Cycle Sketch GAN: Unpaired Sketch to Sketch Translation Based on  |
| Cycle GAN Algorithm   |
| OTakeshi Kojima <sup>1</sup> (1. Peach Aviation Limited)  |
| 2:30 PM - 2:50 PM   |
| Conditional DCGAN's Challenge: Generating Handwritten Character   |
| Digit, Alphabet and Katakana  |
| $\bigcirc$ Rina Komatsu $^1$ , Tad Gonsalves $^1$ (1. Sophia University)  |
| 2:50 PM - 3:10 PM   |
| Sparse Damage Per-pixel Prognosis Indices via Semantic  |
| Segmentation  |
| $\bigcirc$ Takato Yasuno <sup>1</sup> (1. Research Institute for Infrastructure Paradigm Shift (RIIPS))   |
| 3:10 PM - 3:30 PM   |
|   |

# Design a Loss Function which Generates a Spatial configuration of Image In-betweening

Paulino Crsitovao<sup>\*1</sup> Hidemoto Nakada<sup>\*2\*1</sup> Yusuke Tanimura<sup>\*2\*1</sup> Hideki Asoh<sup>\*2</sup>

\*1 University of Tsukuba

<sup>\*2</sup> National Institute of Advanced Industrial Science and Technology of Japan

Instead of generating image inbetween directly from adjacent frames, we propose a method based on inbetweening in latent space. We design a simple loss function which generates a latent space that represent the spatial configuration of image inbetween. Contrary to the frame based methods, this model can make plausible assumption about the moving objects in the image and can capture what is not seen in the images. Our model has three networks, all based on variational autoencoder, sharing same weights. We validate this model on different synthetic datasets. We show the details of our network architecture and the evaluation results.

## 1. Introduction

For machines to become more intelligent and autonomous is essential that they understand the world around them, by being able to learn and understand the semantics present in the data. One way to approach this issue is by using generative models. These models can learn the patterns present in the data and generate new similar sample. This work seeks to discover latent representations present in data also design an objective function which generates the spatial configuration of image inbetween. Image inbetween attempts to generate image interpolation from nearby frames. The generated image has to preserve the spatial configuration of the moving objects. Up to now, optical flow [Yi 15], [Mémin 98] and convolutional neural networks [Amersfoort 17] have been proposed to generate image interpolation. Both methods generate image inbetween directly from adjacent frames 1. The result is blur images and loss of contextual information, also they cannot capture what is not present in the the frames. When generating image inbetween preserving the spatial location, shape, color is relevant for some application, for this reason we design a simple model that is able to preserve the contextual representations of objects between nearby frames. This model find scope in several areas such as movie and animation industries where they have to draw each individual frame and in image inpaiting.

In section 2 we describe our proposed model to generate image interpolation, in section 3, we show the results and we present conclusion in the last section.

## 2. Proposed Method to Generate Image Inbetween

## 2.1 Model Overview

Our model is based on generative models, which have shown tremendous success in different field such as pattern recognition, image classification, natural language process and reinforcement learning. The proposed approach uses variational autoencoder to generate image inbetween.



(b) Eatent Model Interpolation

Figure 1: Comparison between existing approach and our

## 2.2 Proposed Loss Function to Generate Image Inbetween

Evaluating generative models means adjusting the internal weights of the network in order. to minimize an error measure. The error is usually given by a loss function. We optimize our network to minimize the distance between the image inbetween and ground truth in latent space. We follow a standard loss function for variational autoencoder. The model has three VAE each with its error function, we sum all errors function plus a an error function caused by the difference between the average latent space of the nearby frames and ground truth. We introduce a scalar hyper-parameter that we call coefficient  $\alpha$  (below equation). The coefficient  $\alpha$  is an adjustable parameter which express how much is relevant the difference between the Z1 and Z'. Next section we highlight the relevance of  $\alpha$ .

Contact: paulinocristovao86@gmail.com

$$\begin{split} \mathbf{l}_{(\mathbf{X}_0,\mathbf{X}_1,\mathbf{X}_2)} = \mathbf{l}_{\mathbf{VAE}}(\mathbf{X}_0) + \mathbf{l}_{\mathbf{VAE}}(\mathbf{X}_1) + \mathbf{l}_{\mathbf{VAE}}(\mathbf{X}_2) + \\ & \alpha(\mathbf{D_{\mathbf{KL}}}(\mathbf{q}_{(\mathbf{X}_1)} || \frac{\mathbf{q}_{(\mathbf{X}_0)} + \mathbf{q}_{(\mathbf{X}_2)}}{2})) \end{split}$$

#### **2.3** Effects of Coefficient $\alpha$

The adjustable hyper-parameter  $\alpha$  modifies the traditional variational autoencoder objective function. It places a restriction on the latent space. This coefficient constraint the latent representations to generate a latent space which represent the spatial configuration of inbetween objects in the image. For  $\alpha = 0$  represents the traditional VAE, no restriction is placed in the latent model, increasing the value of  $\alpha$  means increasing restrictions on the latent representations.

When evaluating images, the motion of large objects seems easy to evaluate however, evaluating small motion is more complex. We aim to be able to detect small and large changes between frames.



Figure 2: Inbetween Image: Red dots: Nearby Images; Green dot: Inbetween Image

## 3. Experiments

#### 3.1 Data Preprocessing

We used synthetic datasets. Two scenarios were tested: first where the object has one variable influencing its rotation which we name "one degree of freedom" and second having two variables "two degrees of freedom". The images were reshape into size of 32x32. For training and testing we randomly sample a triplet images by giving a certain interval among the frames.

#### 3.2 Network Implementation

The base of our model follows a variational autoencoders (VAE), the network model has three VAEs 3, all sharing same weights to reduce the number of hyper-paremeters. The encoder has four convolutional layers, first layer (128 nodes), second(256 nodes), third (512 nodes), fourth (1024 nodes), kernel size = 4 and stride 2. The decoder has four deconvolutional layers, first layer (512 nodes), second (512 nodes), third (256 nodes), fourth (64 nodes) with same kernel size and stride. We input a triplet image. For this work we ignore the output of the nearby frames 3.



Figure 3: Network implementation

#### **3.3** Reconstruction

#### The goal is to test the location accuracy

In this section, firstly we qualitatively demonstrate that our proposed model can reconstruct the input image. We tested the reconstruction object location, shape and color. Two scenarios is tested, on  $\alpha$  equal to zero and  $\alpha$  greater than zero.

#### 3.3.1 One degree of freedom

Below results are for testing. We note that after strong coefficient  $\alpha = 100$ , the reconstruction test misses some features of the input data.



(a)  $\alpha = 0$ , epochs=10000

(b)  $\alpha = 100$  ,epochs=10000

Figure 4: Teapot:1st row: Original Image, 2nd row:Reconstructed Image. Red box shows imperfect object reconstruction

#### 3.3.2 Two degrees of freedom

We increase the complexity of the data, the rotation of the object is influenced by two variables.



Figure 5: Teapot: 1st row:Reconstructed Image

row:Original Image, 2nd

#### 3.3.3 Multiple Objects

The task of reconstructing 3 objects seems complex for the model, since it has to capture the pattern of each object and make correspondent matching while interpolating.





(a)  $\alpha = 0$  , epochs=10000

(b)  $\alpha = 100$  ,epochs=10000

Figure 7: Teapot-Testing: 1st row:first image, 2nd row: ground truth, 3rd row: Inbetween Image, 4th row: second image. The red square box shows that with  $\alpha = 0$  we have imperfect inbetween, Blue box show the correct inbetween





Figure 6: Mulitple Objects:

row:Reconstructed Image

1st row:Original Image, 2nd

#### 3.4 Image Inbetween

As the model was able to reconstruct its input image, even with strong restriction placed in the latent space, next we qualitatively demonstrate the image inbetween generated by our model 7. Using two nearby images with large displacement from one image to other, with zero coefficient the image inbetween does not preserve the accurate spatial location of the object, increasing the coefficient the model is able to generate the perfect image inbetween as we will show in the next section.

#### 3.4.1 One degree of freedom

We trained the framework with images or rotating on xaxis with one degree of freedom. The testing size is 360, the test images used in training and testing are distinct. The images generated by our approach  $\alpha = 100$  presents a fair inbetween 7.

#### 3.4.2 Two and Six degrees of freedom

Previous examples we rotated the object in 360 degrees on x-axis, i.e. with one degree of freedom. It is easy to find the pattern of the data points as there are just 360 options or angles. We increased the complexity of the images by moving the object with two and six degrees of freedom. The results for two degrees are credible 8, while for six degrees (3 objects), the model does not perform well on testing phase 9.

#### 3.5 Quantitative Evaluation

The goal here is to evaluate the complexity of the dataset in terms of its degree of freedom. We evaluate the same object in one degree and two degrees of freedom. The results indicates that the two degrees of freedom is more complex. Its MSE gives higher values 10.

## 3.6 Linear Latent Space Interpolation

We sample pair of images x1 and x2 and project them into latent space z1 and z2 by sampling from the encoder,



(a)  $\alpha = 0$  ,epochs=15000

(b)  $\alpha = 100$  ,epochs=15000

Figure 8: 2D Teapot-Testing: 1st row:first image, 2nd row: ground truth, 3rd row: Inbetween Image, 4th row: second image. The red square box shows that with  $\alpha = 0$  we have imperfect inbetween, Blue box show the correct inbetween



Figure 9: Multiple Objects - Testing: 1st row:first image, 2nd row: ground truth, 3rd row: Inbetween Image, 4th row: second image

then linearly interpolate between Z1 and Z2 and pass the intermediary points through the decoder to plot the inputspace interpolations. The objective is to estimate the continuity in the latent space. Below figures show the generated smooth interpolation of two nearby points. The latent codes used to generate the nine intermediate images are equivalent to (P=0.9, to 0.1): We observe smooth transitions between pairs of examples, and intermediary images remain credible 11. This is an indicator that this model is not just restricting its probability mass exclusively around training examples, but rather has learned latent features that generalize well.

Linear latent space interpolation, indicate that there is a continuity in the latent space which allows a smooth interpolation. We show an example of 3 objects moving in random direction 12, we linearly interpolate the latent space and generate the possible trajectory between first frame and last frame. This model can predict a long-term frames and has the ability to capture their trajectory.





Figure 12: Linear Long-term interpolation of 3 objects, we see the smooth interpolation from first frame and the last frame.

## 4. Related Work

The intention of unsupervised methods is to uncover the underlying latent representation of the data. Recent works on VAE [Higgins 17][Chen 18] [Berthelot 18] focus in disentangled the latent representations. This approach finds great application in scenario where there is a need to distinguish different characteristics present in the data, for instance, skin color, head pose, facial expression. A disentangled representation can be useful for natural tasks that require knowledge of the salient attributes of the data, which include tasks such as face and object recognition.

Our prosed model does not disentangle latent representations, it simply learn the pattern present in the data.

#### 4.1 Improving Interpolation

While generating interpolation two fundamental characteristics have to be preserved: intermediate points along the interpolation are indistinguishable from real one and provide semantic and smooth morphing [Berthelot 18] The late characteristic is hard to achieve, for that reason [Berthelot 18] purpose a model based in variational autoencoder which introduce a regularizer which encourages interpolated data points to appear more indistinguishable from reconstructions of real data points. It is important to make a clear distinguish between image interpolation generated by latent model and our model. These latent model approaches cannot be used for our target application for the following reason, the dataset used by these models present some variation of the data, for instance in case of celebrity dataset mentioned earlier, it has many factors such as rotation of the head, skin color, age, gender, with or without glasses. The dataset we used does not present such characteristics in addition, we do not disentangle any specific factor of variations, we simply put a restriction on the latent model to generate an accurate image inbetween.

## 5. Conclusion

We present an alternative approach for generating an image inbetween by giving nearby frames which are nonconsecutive images using a latent model. Our approach changes the Naive VAE objective function by introducing a hyper-parameter which constraint the latent representations. This model excels at predicting the image inbetwee in addition the model generalizes well for different datasets. For future, we will test this model on more complex data such as: Complex physical models, such as linked arms. Non-image data, for instance: text and audio data video i.e. video with fast motions and more moving objects. Finding better hyper-parameters between reconstruction and image inbetween.

## Acknowledgement

This paper is based on results obtained from a project commissioned by the New Energy and Industrial Technology Development Organization (NEDO). This work was supported by JSPS KAKENHI Grant Number JP16K00116.

## References

- [Amersfoort 17] Amersfoort, V., et al.: Frame Interpolation with Multi-Scale Deep Loss Functions and Generative Adversarial Networks, arXiv preprint arXiv:1711.06045 (2017)
- [Berthelot 18] Berthelot, D., et al.: Understanding and Improving Interpolation in Autoencoders via an Adversarial Regularizer, arXiv preprint arXiv:1807.07543 (2018)
- [Chen 18] Chen, T. Q., et al.: Isolating Sources of Disentanglement in Variational Autoencoders, arXiv preprint arXiv:1802.04942 (2018)
- [Higgins 17] Higgins, I., et al.: beta-vae: Learning basic visual concepts with a constrained variational framework, in *International Conference on Learning Representations* (2017)
- [Mémin 98] Mémin, E. and Pérez, P.: Dense estimation and object-based segmentation of the optical flow with robust techniques, *IEEE Transactions on Image Processing*, Vol. 7, No. 5, pp. 703–719 (1998)
- [Yi 15] Yi, C., Liyun, C., and Chunguang, L.: Moving Target Tracking Algorithm Based on Improved Optical Flow Technology, *Open Automation and Control Systems Journal*, Vol. 7, pp. 1387–1392 (2015)

## One-shot Learning using Triplet Network with kNN classifier

Mu ZHOU<sup>\*1\*2</sup> Yus

Yusuke TANIMURA<sup>\*2\*1</sup> Hidemoto NAKADA<sup>\*2\*1</sup>

\*1筑波大学

University of Tsukuba

\*2産業技術総合研究所 人工知能研究センター

kuba Artifical Intelligence Research Center, National Institute of Advanced Institute of Technology

We propose a triplet network with a kNN classifier for the problem of one-shot learning, in which we predict the query images by given single example of each class. Our triplet network learns a mapping from sample images to the Euclidean space. Then we apply kNN classifier on the embeddings generated by the triplet network to classify the query sample. Our method can improve the performance of one-shot classification with data augmentation by processing the images. Our experiments on different datasets which are based on MNIST dataset demonstrate that our approach provides a effective way for one-shot learning problems.

## 1. Introduction

Deep learning has shown great achievement in various tasks related to artificial intelligence such as object recognition [Girshick 15], image classification [Kaiming 15], and speech recognition [Yu 14]. However, huge amounts of labelled data is necessary for these deep neural network models to train on. In contrast, humans are capable of one-shot learning, which is to learn a concept from one or only a few training example, contrary to the normal practice of using a large amount of data. This is evident in the case of learning a new thing rapidly - humans have no problem recognizing the new category with one or a few direct observation. However, it is a challenging task for machine to solve the classification and recognition problem with very few labelled training data.

## 2. Related work

Several studies have investigated few-shot learning and one-shot learning, one special type neural network is Siamese Neworks [Koch 15]. The idea of the Siamese Network is based on distance metric learning which is to learn the distance metric from the input space of training data by a contrastive loss, then keep the samples belonging the same class close to each other and separate the dissimilar samples. The similar one is Triplet Network [Hoffer 15] which is composed of 3 parameter-shared convolutional neural networks.

Inspired by Siamese Networks and Triplet Networks, we improve the Triplet Network and use a triplet loss [Schroff 15] in our work. The loss function is to minimize the distance between the data with same label and maximize the distance between the data with different label. Before we get the embeddings trained on networks, we do data augmentation on the training set with only one sample. Then we make the prediction to the embedded query points by finding the nearest embedded support point by using k-Nearest Neighbor classifier. The procedure of the whole work is shown in Figure 1.



Figure 1: Prediction procedure.

## 3. Method

### 3.1 Triplet Network

In this research, we use the triplet network to learn the distance metric from inputs of triplet images. The triplet network is a horizontal concatenation triplet with 3 identical Convolutional Neural Networks (with shared parameters), these ConvNets are trained using triplets of inputs. The input triplet  $(\vec{x_a}, \vec{x_p}, \vec{x_n})$  is composed of an anchor instance  $\vec{x_a}$ , a positive instance  $\vec{x_p}$  (same class as the anchor), and a negative instance  $\vec{x_n}$  (different class from the anchor). The network is then trained to learn an embedding function f(x) called triplet loss. The model architecture is shown in Figure 2.

#### 3.1.1 Convolutional Networks

A series of breakthroughs in image classification came with the introduction of Convolutional Neural Networks (CNNs or ConvNets), where the image is input into a nested series of functions and convolved with filters, then output as feature vector. In our method, the ConvNet has 4 convolutional layers and is used as an embedding function. The ouput is passed through a fully connected layer resulting in a 128-dimensional embedding. In addition, we use ReLU as an activation function which is a common choice, especially for convolutional networks. The architecture of this ConvNet is as following:

• 1x{5x5-conv.layer (32 filters), 5x5-conv.layer (32 filters), batch normalization, max pool(2, 2), leaky relu,



Figure 2: Triplet Network Model.



Figure 3: Triplet Loss Function.

dropout(0.25)},

- 1x{3x3-conv.layer (64 filters), 3x3-conv.layer (32 filters), batch normalization, max pool(2, 2), leaky relu, dropout(0.25)},
- 1x{fc-layer, batch normalization}.

#### 3.1.2 Triplet Loss

Although we did not compare it to other loss function, we believe that the triplet loss is more suitable for this network, and triplet loss layer could improve the accuracy of ConvNets. A triplet loss is used to learn an embedding space for the images, such that embeddings of same class are close to each other, while those of different class are far away from each other. For the distance on the embedding space d, the loss of a triplet  $(\vec{x_a}, \vec{x_p}, \vec{x_n})$  is:

$$L = max(d(x_a, x_p) - d(x_a, x_n) + \alpha, 0)$$

where  $\alpha$  is a margin that is enforced between positive and negative pairs[Schroff 15]. In our research, the triplet loss minimizes the distance between the anchor and the positive, both of which have the same identity, and maximizes the distance between the anchor and a negative of a different identity, as shown in Figure 3.

#### 3.2 kNN Classifier

The k-Nearest Neighbors algorithm is one of the simplest way to perform classification. Most kNN classifiers

use Euclidean distances (also known as L2-norm distance) to measure the similarities between the instances which are represented as vector inputs. The L2-norm distance is as following:

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2}$$

In our research, after we trained the dataset (both train and test dataset) on the Triplet Network, we obtained the embeddings of the data, each of which is a 128-dimensional feature vector. Then we used PCA (Principal component analysis) to reduce the dimension of the feature vectors. Since these vector embeddings are represented in shared vector space, we can calculate the similarity between the vectors by using the vector distance. Finally we used kNN classifier to calculate the distance between the test point and all the training points by giving the feature vector of labelled training and unlabelled test data. We gained the best choice of k and choose the corresponding classification that appears most frequently as the predictive class.

#### 3.3 Data Augmentation

Data augmentation is the most common solution for oneshot learning, since it can help to increase the amount of relevant data in the dataset and boost the performance of neural networks. In our research, we augmented the images in the training dataset. As a result, a large amount of training images was created, through different ways of processing or combination of multiple processing, such as random rotation, shifts and shear, etc.

## 4. Experiment

#### 4.1 Dataset

MNIST database (Modified National Institute of Standards and Technology database) is a large database of handwritten digits that is commonly used for training various image processing systems. The MNIST database contains 60,000 images for training and 10,000 images for testing. Figure 4 presents some of the digits from MNIST dataset.

## 4.1.1 Initial Dataset

To setup the training dataset, we chose whole digit images with label 0 to 4, while we randomly selected simple digit image with the label 5 to 9 from the MNIST dataset. This initial dataset was used for our comparison experiment. The count of each label on initial training dataset is shown in Figure 5.

#### 4.1.2 Augmented Dataset

In addition to the initial dataset, we generated another training dataset by the technique of data augmentation. In our experiment, we augmented the single image. Due to the limitation of some digit images, (i.e. digit 9 may be recognized as digit 6 after the 180-degree rotation,) we did the random rotation operation with only 30 degrees combined with random zoom and random shifts. To ensure similar appearance of the amount of each label, we enlarged the images several times with similar amount. The count of



Figure 4: Samples from MNIST dataset.



Figure 5: The initial dataset.

each label on augmented training dataset is shown in Figure 6.

## 4.2 Triplet Selection

Input triplets for Triplet Network were generated in two ways. One kind of triplets was produced by the augmented dataset, while another one was created by the initial dataset which was not augmented. For the first type, we randomly selected 1 sample (used as the anchor instance) from the dataset, then chose another one (used as the positive instance) from the same label. Then we randomly obtained the other sample (used as the negative instance) from any other label. Finally, we concatenated them as a triplet pair. However, for the other type created by initial dataset, we used the same image as the positive instance to overcome the limitation of lack of samples.

#### 4.3 Results

We evaluated the performance of our model on above two datasets - initial dataset and augmented dataset, in order to judge the effectivity of data augmentation. To estimate the performance on Triplet Network in comparison to other model, we applied the CNN model on one-shot classification with the augmented dataset, as is mentioned above.

We obtained the embeddings of training points and test



Figure 6: The augmented dataset.



Figure 7: Embedding visualization of training points.

Figure 8: Embedding visualization of test points.

points from the Triplet Network, and we did visualization using t-SNE technique, as shown in Figure 7 and Figure 8. With these training points and test points, we evaluated the accuracy with different k ranging from 1 to 30, and selected the best choice of k. Figure 9 presents the accuracy of kNN classifier for different choice of k with augmented dataset in our Triplet Network model, and we get the best k (k=11) in this experiment. We predicted the label of test points with best k, and compared with the true label. The results are shown in Table 1, which present the accuracy of the test dataset with 1-shot classes (label 5 to label 9).

In our experiment on Triplet Network, the accuracy of the test dataset is 46.8% for 1-shot classes, while the accuracy



Figure 9: Accuracy of kNN classifer for different choices of k.

| 0 -      | 977 | 0    | 2   | 1   | 0   | 0  | 0  | 0  | 0  | 0 |        |   |
|----------|-----|------|-----|-----|-----|----|----|----|----|---|--------|---|
| ч.       | 0   | 1128 | 3   | 4   |     |    |    |    |    | 0 | - 1000 | 1 |
| ~ ~      | 12  | 4    | 993 | 19  | 4   |    |    |    |    | 0 | - 90.0 |   |
| m -      |     | 1    | 18  | 991 |     |    |    |    |    | 0 | - 000  |   |
| 4 -      | 2   | 2    | 2   | 0   | 976 |    |    |    |    | 0 | - 600  |   |
| <u>ہ</u> | 40  | 19   |     |     | 81  | 65 |    |    |    | 0 |        |   |
| φ.       | 222 | 14   | 71  | 19  |     |    | 95 |    |    | 0 | - 400  |   |
| r -      | 103 | 78   | 254 | 429 | 104 |    |    | 60 |    | 0 |        |   |
| ∞ -      | 60  | 54   | 120 | 512 | 192 | 1  |    |    | 32 | 0 | - 200  |   |
| ი -      | 31  | 12   | 11  | 70  | 883 |    |    |    |    | 2 |        |   |
|          | ó   | i    | 2   | 3   | 4   | 5  | 6  | 7  | 8  | 9 | -0     |   |
|          |     |      |     |     |     |    |    |    |    |   |        |   |

Figure 10: The result on TripletNN with initial dataset.



Figure 11: The result on TripletNN with augmented dataset.

is only 9.8% in the comparison experiment. This result suggests that data augmentation make sense and can obtain better prediction result than without data augmentation. In addition, the Triplet Network gives a better performance than the CNN model in this experiment.

Figure 10 and 11 show the results between actual labels and predicted labels in both datasets using Triplet Network. With regard to the accuracy of digit 9, it gets a low score since most of digit 9 are recognized as digit 4. This result implies that most written digit 9 are significantly similar to written digit 4, and the machine may not recognize them precisely with simple sample.

| Mathad (dataset)          |     | Accuracy |     |     |     |         |  |
|---------------------------|-----|----------|-----|-----|-----|---------|--|
| Method (dataset)          | 5   | 6        | 7   | 8   | 9   | Average |  |
| TripletNN (not Agumented) | 14% | 18%      | 11% | 6%  | 0%  | 9.8%    |  |
| CNN (Augmented)           | 25% | 26%      | 16% | 24% | 13% | 20.8%   |  |
| TripletNN (Augmented)     | 42% | 56%      | 66% | 56% | 14% | 46.8%   |  |

Table 1: Results of 1-shot classes.

## 5. Conclusion

In this work, we described how a Triplet Network model, inspired by the Siamese Network based on distance metric, can be used for one-shot learning. We used the embeddings of training points trained on kNN classifier and predict the label with the embedding of testing points by the classifier. We obtain significant improvement by the effectiveness of data augmentation. Of the 3 approaches tested, we achieved best results by augmenting the initial dataset with Triplet Network model. While in the contrast experiment on CNN model, data augmentation resulted accuracy of 20.8%. However, the experiment on Triplet model with initial dataset resulted accuracy of 9.8%, where almost all the data trained with 1 sample can not be recognized. This study therefore indicates that the benefits gained from data augmentation may work well on one-shot learning problem.

Although our experiment demonstrate a great improvement, the results are subject to certain limitations. For instance, since the differences between digit 9 and digit 4 are unable to be separated, most of digit 9 are recognized as digit 4 in the experiments. In addition, due to the computational constraint, our experiments were unable to explore how our approaches work on other much larger and complex datasets. Therefore, future work should focus on how to distinguish the difference between written digit 9 and digit 4 and how to enlarge the metric distance between digit 9 and 4. Furthermore, future studies need to be carried out in order to validate whether our approach does indeed help to solve the one-shot learning on other large and complex datasets, such as Fashion MNIST, Omniglot, Mini-Imagenet and e.t.

## Acknowledgement

This paper is based on results obtained from a project commissioned by the New Energy and Industrial Technology Development Organization (NEDO). This work was supported by JSPS KAKENHI Grant Number JP16K00116.

## References

- [Girshick 15] Girshick, R.: Fast R-CNN, IEEE International Conference on Computer Vision (ICCV) 2015 (2015)
- [Hoffer 15] Hoffer, E. and Ailon, N.: Deep metric learning using triplet network, *International Workshop on Similarity-Based Pattern Recognition* (2015)
- [Kaiming 15] Kaiming, H., Xiangyu, Z., Shaoqing, R., and Jian., S.: Delving deep into rectifiers: Surpassing human- level performance on imagenet classification, arXiv preprint arXiv:1502.01852 (2015)
- [Koch 15] Koch, G., Zemel, R., and Salakhutdinov, R.: Siamese neural networks for one-shot image recognition, *ICML Deep Learning Workshop* (2015)
- [Schroff 15] Schroff, F., Kalenichenko, D., and Philbin., J.: Facenet: A unified embedding for face recognition and clustering, *Proceedings of the IEEE conference on computer vision and pattern recognition* (2015)
- [Yu 14] Yu, D. and Deng, L.: Automatic Speech Recognition: A Deep Learning Approach, Springer Publishing Company (2014)

# Cycle Sketch GAN: Unpaired Sketch to Sketch Translation Based on Cycle GAN Algorithm

## Takeshi Kojima

## Peach Aviation Limited

Unlike pixel image generation, sketch drawing generative model outputs a sequence of pen stroke information. This paper proposes Cycle Sketch GAN: the first model that learns to translate a sketch drawing from source domain to target domain in the absence of paired dataset. Based on Cycle GAN algorithm, this model uses Transformer Encoder architecture in generators. Transformer Encoder feeds the input stroke information in source domain and generates the parameters for output distribution, from which the stroke information in target domain is sampled by reparameterization trick. The negative log likelihood of the distribution is used as cycle consistency loss. This model is trained and evaluated by some QuickDraw datasets. Qualitative evaluation shows that this model can practically translate sketch drawings from source domain to target domain. Quantitative evaluation by user study showed that 42 % of the translated sketches is recognizable compared to 71 % of the human sketches.

#### 1. Introduction

Unlike pixel image generation, sketch drawing generative model outputs a sequence of pen stroke information (See section 2.1 for details). Some recent researches focused on creating sketch drawing generative model [Ha 18][Song 18] by neural network. However, the research of sketch to sketch translation, which aims to transform a sketch from source domain to target domain especially without supervised dataset, was not yet conducted.

This paper proposes Cycle Sketch GAN: the first model that learns to translate a sketch drawing from source domain to target domain in the absence of paired dataset. Specifically, this unsupervised learning model can change a sketch drawing's partial shapes characteristic to source domain into ones characteristic to target domain while keeping the common features unchanged (See an example in Fig.1). To train this model, we need to prepare 2 domain datasets, but each data in one domain does not need to have paired data in the other domain. This model is based on Cycle GAN algorithm[Zhu 17]. However, several changes are implemented to solve the following 2 problems specific to sketch drawing process.

The first problem of unsupervised sketch to sketch translation is that the sketch drawing is a process of generating a sequence of stroke vector representations. Therefore, Convolutional Neural Network(CNN), which is used in basic Cycle GAN, should not be used for this solution. Cycle Sketch GAN solves this problem by using Transformer[Vaswani 17] Encoder architecture in a generator. Transformer has self-attention mechanisms and recently succeeded in improvements of several sequential data processing tasks mainly in NLP. Note that Transformer Decoder is not used in this paper because we have no supervised data. Instead, Transformer Encoder feeds input and directly generates sequential outputs.

The second problem is that drawing sketch requires the accurate generation of strokes. Therefore, cycle consistency loss function has to be like the form of reconstruction loss as in [Ha 18], instead of L1 or L2 Norm. Cycle Sketch GAN solves this problem as follows: Transformer Encoder feeds the input stroke in source domain and generates the parameters for output distributions. Stroke





Figure 1: A visualized example of sequential stroke output process by Cycle Sketch GAN. This model can learn to translate a sketch drawing from source domain (Top: bucket) to target domain (Bottom: cup) in the absence of paired datasets. The common feature between 2 drawings (the body of bucket and cup) is unchanged.

information in target domain is sampled from the distribution by reparameterization trick to enable backpropagation for the training. The negative log likelihood of the distribution is used as cycle consistency loss to improve accuracy.

## 2. Methods

#### 2.1 Data Format

Based on [Ha 18], the data format of a sketch drawing for this model is a sequence of pen stroke actions  $s = (s1, ..., s_i, ..., s_{N_{max_s}})$ , where  $s_i = (\Delta_{x_i}, \Delta_{y_i}, p1_i, p2_i, p3_i)$ .  $\Delta_{x_i}, \Delta_{y_i}$  are the offset distance of *i*th pen movement in the direction of x axis and y axis.  $p1_i, p2_i, p3_i$  are binary one-hot vector of 3 possible states at *i*th movement<sup>\*1</sup>.  $p1_i$  is an indicator that the pen is touching the paper for the *i*th pen movement.  $p2_i$  is an indicator that the pen is lifted from the paper for the *i*th pen movement.  $p3_i$ is an indicator that the drawing has ended. In case of  $p3_i = 1, \Delta_{x_i}$ and  $\Delta_{y_i}$  are defined to be 0.

#### 2.2 Generator Architecture

This model uses Transformer[Vaswani 17] Encoder architecture as a generator to translate a sketch drawing stroke representation of domain  $S_A$  to domain  $S_B$ , and vice versa. Specifically,  $s_A \in S_A$ is fed into one generator and translated to  $\tilde{s_B} \in S_B$ . In the same way,  $s_B \in S_B$  is fed into the other generator and translated to  $\tilde{s_A} \in S_A$ . The architectures of these 2 generators are the same. This section omits the subscript A and B for simplicity.

<sup>\*1 [</sup>Ha 18] defines  $p1_i, p2_i, p3_i$  as binary one-hot vector of 3 possible states at i + 1th movement.



Figure 2: Overall image of Cycle Sketch GAN

The input s is concatenated with Positional Encoding [Vaswani 17] whose dimension size for *i*th position is  $N_{PE}^{*2}$ . The concatenated representation is fed into Transformer Encoder as input. Transformer Encoder has  $N_{TL}$  multiple stacked layers, each of which consists of  $N_{TA}$  multi-head attentions and a feed-forward network with dimension size of  $4N_{TA}$ , followed by a position-wise linear projection for the output below.

$$(\mu_x, \mu_y, \hat{\sigma_x}, \hat{\sigma_y}, \hat{\rho_{xy}}, q1, q2, q3)_1$$
  
....  $(\mu_x, \mu_y, \hat{\sigma_x}, \hat{\sigma_y}, \hat{\rho_{xy}}, q1, q2, q3)_{N_{max_s}}$   
=  $TransformerEncoder([s; PE])$  (1)

As described in [Ha 18],  $(\mu_x, \mu_y, \hat{\sigma_x}, \hat{\sigma_y}, \hat{\rho_{xy}})$  are defined as the parameters for a bivariate normal distribution to describe  $\Delta x$ and  $\Delta y$ . (q1, q2, q3) are the categorical distribution parameters to model the ground truth data (p1, p2, p3). The following nonlinear functions are required to ensure that standard deviations are nonnegative, that the correlation values are limited between -1 and 1.

$$\sigma_x = exp(\hat{\sigma_x}), \ \sigma_y = exp(\hat{\sigma_y}), \ \rho_{xy} = tanh(\hat{\rho_{xy}})$$
(2)

The reparameterization trick for bivariate normal distribution is applied using  $(\mu_x, \mu_y, \sigma_x, \sigma_y, \rho_{xy})$  to sample single value for each *i*th pen movements.

$$\begin{bmatrix} \tilde{\Delta x_i} \\ \tilde{\Delta y_i} \end{bmatrix} = \begin{bmatrix} \mu_{x_i} \\ \mu_{y_i} \end{bmatrix} + L_i \begin{bmatrix} \epsilon_{x_i} \\ \epsilon_{y_i} \end{bmatrix}$$
where  $L_i = \begin{bmatrix} \sigma_{x_i} & 0 \\ \rho_{xy_i}\sigma_{y_i} & \sqrt{1 - \rho_{xy_i}^2}\sigma_{y_i} \end{bmatrix}$ 
 $\epsilon_{x_i}, \epsilon_{y_i} \sim N(0, 1), \ \epsilon_{x_i}, \epsilon_{y_i} \in \mathbb{R}$  (3)

 $L_i$  is a lower triangular matrix after cholesky decomposition of covariance matrix of bivariate normal distribution.

Categorical reparameterization for  $(q1, q2, q3)_i = q_i$  is also applied by using Gumbel Softmax[Jang 17] with temperature  $\tau$ .

$$\tilde{q}_{i} = softmax((q_{i} + g_{i})/\tau)$$
where  $g_{i} = -\log(-\log(u_{i}))$ 
 $u_{i} \sim Uniform(0, 1), u_{i} \in \mathbb{R}^{3}$ 
(4)

In order to deceive discriminators as much as possible, generators calculate the following position-wise conditional operation before the data is fed into Discriminator.

$$\tilde{s}_i = \begin{cases} (0, 0, \tilde{q1}, \tilde{q2}, \tilde{q3})_i & if \max(\tilde{q1}_i, \tilde{q2}_i, \tilde{q3}_i) = \tilde{q3}_i \\ (\tilde{\Delta x}, \tilde{\Delta y}, \tilde{q1}, \tilde{q2}, \tilde{q3})_i & otherwise \end{cases}$$
(5)

Here, for simplification, the sequence of functions (1) and (2) can be defined as  $t = (t1, ..., t_i, ..., t_{N_{max_s}}) = G(s)$ , where  $t_i = (\mu_x, \mu_y, \sigma_x, \sigma_y, \rho_{xy}, q1, q2, q3)_i$ . The sequence of functions (3), (4) and (5) can also be defined as  $\tilde{s} = (\tilde{s}_1, \tilde{s}_2, ..., \tilde{s}_{i_1}, ..., \tilde{s}_{N_{max_s}}) = H(t)$ . By using these expressions, 2 generators can be defined as:

$$\tilde{s_B} = H_B(G_B(s_A)), \quad \tilde{s_A} = H_A(G_A(s_B)) \tag{6}$$

Note that the function  $H_A(\cdot)$ ,  $H_B(\cdot)$  does not contain any neural networks to be optimized.

#### 2.3 Discriminator Architecture

The discriminator D is a multilayer convolutional neural network with instance normalization. Specifically, the discriminator regards the input s or  $\tilde{s}$  as an image with height= $N_{max_s}$ , width=5 and depth=1. The *j*th layer of D convolves the input of the layer with kernel size ( $N_{Dk-height_j}$ ,  $N_{Dk-weight_j}$ ) and stride size =  $N_{Ds_j}$  without padding, and outputs the tensor with channel size  $N_{Dc_j}$ , followed by instance normalization and activation. As an exception, the first layer and final layer does not have instance normalization. The final layer also has no activation function due to the restriction of the architecture of the discriminator in improved Wasserstein GAN optimization process [Gulrajani 17]. 2 discriminators,  $D_A$  for data A and  $D_B$  for data B are implemented with the same architecture described above.

#### 2.4 Objective function

The objective function of this model contains adversarial losses and cycle consistency losses for both domains[Zhu 17]. As for the adversarial loss, this model uses improved Wasserstein GAN [Gulrajani 17] instead of the normal GAN [Goodfellow 14] to avoid mode collapse and to stabilize the training. The adversarial loss for data A is:

$$\mathcal{L}_{GAN}^{A}(G_{A}, D_{A}, S_{B}, S_{A})$$

$$= \mathbb{E}_{s_{B}}[D_{A}(H_{A}(G_{A}(s_{B})))] - \mathbb{E}_{\ddot{s}_{A}}[D_{A}(\ddot{s}_{A})]$$

$$+ gradient \ penalty \ for \ WGAN-GP$$

$$where \ \ddot{s}_{A} = noise(s_{A}) \tag{7}$$

noise(·) is a function that adds random noises U(-0.01, 0.01)into (p1, p2, p3), and also into  $(\Delta_{x_i}, \Delta_{y_i})$  if  $q3_i = 1$  to prevent D from concentrating too much on discrete variables. The same as true for the adversarial loss of data B,  $\mathcal{L}^B_{GAN}(G_B, D_B, S_A, S_B)$ .

As for cycle consistency loss of data A, firstly the following cycled parameters are introduced.

<sup>\*2</sup> Considering the case  $N_{PE} > 5$ , we use concatenation instead of addition.

$$(\tilde{t}_{A,1},...,\tilde{t}_{A,i},...\tilde{t}_{A,N_{max_s}}) = G_A(H_B(G_B(s_A)))$$

$$where \ \tilde{t}_{A,i} = (\tilde{\mu}_x^A, \tilde{\mu}_y^A, \tilde{\sigma}_x^A, \tilde{\sigma}_y^A, \tilde{\rho}_{xy}^A, \tilde{q}_1^A, \tilde{q}_2^A, \tilde{q}_3^A)_i \quad (8)$$
Then employee interval as for the formula of the maximum description of the

Then, cycle consistency loss for data A is expressed as follows:

$$\mathcal{L}_{cyc}^{A}(G_{A}, G_{B}, S_{A})$$

$$= \mathbb{E}_{s_{A}} \left[ -\frac{1}{N_{\max_{s}}} \sum_{i=1}^{N_{s}} \log \left( \mathcal{N}(\Delta x_{i}^{A}, \Delta y_{i}^{A} \mid \tilde{w}_{i}^{A}) \right) - \frac{1}{N_{\max_{s}}} \sum_{i=1}^{N_{\max_{s}}} \sum_{k=1}^{3} pk_{i}^{A} \log(qk_{i}^{'A}) \right]$$
where  $\tilde{w}_{i}^{A} = (\tilde{\mu}_{x}^{A}, \tilde{\mu}_{y}^{A}, \tilde{\sigma}_{x}^{A}, \tilde{\sigma}_{y}^{A}, \tilde{\rho}_{xy}^{A})_{i}$ 
 $q1_{i}^{'A}, q2_{i}^{'A}, q3_{i}^{'A} = softmax(\tilde{q}1_{i}^{A}, \tilde{q}2_{i}^{A}, \tilde{q}3_{i}^{A})$ 
(9)

 $\mathcal{N}(\Delta x_i^A, \Delta y_i^A \mid \tilde{w}_i^A)$  is the probability distribution function for a bivariate normal distribution.  $N_s$  is the point of last stroke in the sketch. This cycle consistency loss function is the same as the reconstruction loss function of [Ha 18] except that the distribution of  $(\Delta x, \Delta y)$  is not modeled as a Gaussian mixture model (GMM). It can be said that the function is a special case of GMM size = 1. The same as true for the cycle consistency loss for data B,  $\mathcal{L}_{cuc}^B(G_B, G_A, S_B)$ .

The final objective function is:

$$\mathcal{L}(G_A, G_B, D_A, D_B) = \mathcal{L}^A_{GAN}(G_A, D_A, S_B, S_A) + \mathcal{L}^B_{GAN}(G_B, D_B, S_A, S_B) + \lambda \mathcal{L}^A_{cyc}(G_A, G_B, S_A) + \lambda \mathcal{L}^B_{cyc}(G_B, G_A, S_B)$$
(10)

We aim to solve:

$$G_A^*, G_B^* = \arg\min_{G_A, G_B} \max_{D_A, D_B} \mathcal{L}(G_A, G_B, D_A, D_B)$$
(11)

## 3. Experimtents

#### 3.1 Dataset

To evaluate Cycle Sketch GAN, full size of "Sketch-RNN QuickDraw Dataset" is used. QuickDraw Dataset contains hundreds of classes of sketch drawings. Each class is a dataset of more than 70K training samples and 2.5K test samples. In this paper, the following 6 classes are picked up from QuickDraw and made pairs: (bucket, cup), (suitcase, envelope), (sock, rollerskates). Note that each data in one class does not have paired data in the other class. The data format is changed according to section 2.1.

This experiment only uses the data whose size of the stroke actions does not exceed  $N_{max_s} = 50$ . Moreover, in order to equalize the training dataset size between paired classes, training data were randomly sampled from the class whose dataset size is larger than the other.

#### **3.2 Implementation details**

As for generators, the dimension size of Positional Encoding is set to be  $N_{PE} = 251$ . Transformer layer size is  $N_{TL} =$ 12, and the multihead attention size is  $N_{TA} = 4$ . As for the Discriminator, the hyper parameter values are set as followed:  $(N_{Dk-height_1}, N_{Dk-weight_1}, N_{Ds_1}, N_{Dc_1}) = (5, 5, 1, 128)$  $(N_{Dk-height_2}, N_{Dk-weight_2}, N_{Ds_2}, N_{Dc_2}) = (10, 1, 2, 256)$  $(N_{Dk-height_3}, N_{Dk-weight_3}, N_{Ds_3}, N_{Dc_3}) = (10, 1, 2, 512)$  $(N_{Dk-height_4}, N_{Dk-weight_4}, N_{Ds_4}, N_{Dc_4}) = (5, 1, 1, 1).$ 



Figure 3: The original sketches by human (Row A, B) and the translated sketches by Cycle Sketch GAN (Row B', A').

All the activation functions in generators and discriminators are Leaky-ReLU activation. The temperature  $\tau$  of Gumbel Softmax is set to be 1.  $\lambda$  in the final objective function is also set to be 1.

While training, minibatch SGD is used and the Adam optimizer is applied for the optimization process with  $\beta_1 = 0$  and  $\beta_2 = 0.9$ [Gulrajani 17]. The learning rate is fixed with 0.00005 during the training. The minibatch size is 128 and the iteration size is 30000 for generators. Discriminators and generators are mutually trained with the number of iterations of Discriminators per iteration of generators be set 5[Gulrajani 17].

Before generators feed data, the offsets  $(\Delta x, \Delta y)$  in each classes is normalized using a single scaling factor [Ha 18] to adjust the offsets in the training set to have a standard deviation of 1. The test dataset is also normalized by that single scaling factor which is calculated by the training set of the same class.

2 types of data augmentation are applied into the training data for every iteration[Ha 18]. The first one is to stretch  $\Delta x$  and  $\Delta y$  respectively by multiplying random value drawn from U(0.85, 1.15). The second one is to drop out strokes by dropping each point within line segments with a probability of 0.1.

Residual Dropout[Vaswani 17] is applied into Transformer Encoder with dropout rate = 0.1 during the training. At inference time, the dropout rate = 0, and also  $\epsilon_x, \epsilon_y, g = 0$  in the reparameterization trick to produce the optimal translated drawings  $\tilde{s_B}^* = H_B(G_B^*(s_A))$  and  $\tilde{s_A}^* = H_A(G_A^*(s_B))$ .

#### 3.3 Results

#### 3.3.1 Qualitative Evaluation

3 Cycle Sketch GAN models are trained by using 3 dataset pairs in QuickDraw (See section 3.1). Fig. 3 shows some examples of the translated sketch drawings from test data by the trained models. A and B rows are the randomly chosen sample drawings from each class test datasets. The drawings in B' rows are respectively the translated sketch drawings from the above A drawings. The



Figure 4: The stroke order of an original sketch by human (A, B) and the translated sketch by Cycle Sketch GAN (B', A').

same is true for A' and B. It shows that the common features are unchanged between the test sample drawing and the translated drawing, but the partial shapes characteristic to source domain are successfully transformed into ones characteristic to target domain, although some samples are failed to be translated.

Fig. 4 compares the order of the strokes between some test sample data and the translated data. Each row describes the snapshots of the strokes at the point of i = 6, 12, 18, 24, 30, 36, 42, 48 from the left to right. It clearly shows that the stroke order between original sketch and translated sketch are very similar from the start until some point. After that point, the stroke becomes different to express the characteristic feature for each domains.

#### 3.3.2 Quantitative Evaluation

| Class                       | Cycle Sketch GAN | Human            |  |  |
|-----------------------------|------------------|------------------|--|--|
| bucket                      | 32.8(±30.5)      | 57.6(±25.9)      |  |  |
| cup                         | 43.0(±28.5)      | 75.2(±31.3)      |  |  |
| suitcase                    | 49.0(±30.3)      | 54.4(±27.0)      |  |  |
| envelope                    | $63.1(\pm 23.1)$ | 85.8(±18.7)      |  |  |
| sock                        | 38.4(±26.1)      | 71.8(±23.9)      |  |  |
| rollerskates                | 30.8(±14.8)      | $82.0(\pm 14.7)$ |  |  |
| Average                     | 42.9             | 71.1             |  |  |
| Table 1: User survey result |                  |                  |  |  |

User study was also conducted on Amazon Mechanical Turk (AMT) to test the quality of translated sketch drawings. For each class, the survey results were collected from 20 participants. Specifically, participants see drawings one by one, and were asked "Do you think the drawing is (class name)?". Participants clicked on "yes" or "no" for the answer. For each dataset class, 55 drawings are surveyed, which consists of 25 of real sample sketches by humans, 25 of translated sketches by Cycle Sketch GAN, and 5 of trials (apparently irrelevant class sketches to check whether the participant's response was reliable or not). The order of showing these drawings are randomized.

Table. 1 shows the survey result, which lists the average percentage (and the standard deviation) of answering "yes" for each class surveys. Overall, 42 % of the translated sketches is recognizable compared to 71 % of the human sketch. There is apparent that some easy sketches such as envelope got higher recognition rate, while some complex sketches such as rollerskates got lower rate.

## 4. Conclusion and Future Work

This paper proposed Cycle Sketch GAN, the first model that learns to translate a sketch drawing from source domain to target domain in the absence of paired dataset. Qualitative and quantitative evaluation by some QuickDraw datasets demonstrates the effectiveness of this model. As a future work, the model needs to be improved to be able to translate complicated sketch drawings with higher quality. Using GMM as output distributions, or using Encoder-Decoder architecture as generators such as Seq2Seq might be effective. Furthermore, there might be a possibility that this unsupervised learning approach can be applied into other tasks that requires sequential data generation, such as unsupervised language translation[Lample 18], even though we need quite a lot of model changes and improvements.

## References

- [Goodfellow 14] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y.: Generative Adversarial Nets, in *Advances in Neural Information Processing Systems* 27, pp. 2672–2680 (2014)
- [Gulrajani 17] Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., and Courville, A. C.: Improved Training of Wasserstein GANs, in *Advances in Neural Information Processing Systems 30*, pp. 5767–5777 (2017)
- [Ha 18] Ha, D. and Eck, D.: A Neural Representation of Sketch Drawings, in *International Conference on Learning Representations* (2018)
- [Jang 17] Jang, E., Gu, S., and Poole, B.: Categorical Reparameterization with Gumbel-Softmax (2017)
- [Lample 18] Lample, G., Ott, M., Conneau, A., Denoyer, L., and Ranzato, M.: Phrase-Based & Neural Unsupervised Machine Translation, in *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, pp. 5039–5049 (2018)
- [Song 18] Song, J., Pang, K., Song, Y., Xiang, T., and Hospedales, T. M.: Learning to Sketch With Shortcut Cycle Consistency, in 2018 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2018, pp. 801–810 (2018)
- [Vaswani 17] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. u., and Polosukhin, I.: Attention is All you Need, in *Advances in Neural Information Processing Systems 30*, pp. 5998–6008 (2017)
- [Zhu 17] Zhu, J.-Y., Park, T., Isola, P., and Efros, A. A.: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, in *Computer Vision (ICCV)*, 2017 IEEE International Conference on (2017)

## Conditional DCGAN's Challenge:

## Generating Handwritten Character Digit, Alphabet and Katakana

Rina Komatsu<sup>\*1</sup>

Tad Gonsalves<sup>\*1</sup>

## \*1 Sophia University

Developing deep learning models has a great potential in assisting human tasks involving design and creativity. This study deals with generating handwritten characters using deep learning techniques. The task is not simply generating images randomly, but generating them conditionally, making a distinction according to the UI designates. To solve this task, we constructed the Conditional DCGAN model which includes the techniques from DCGAN and Conditional GAN. We tried training the models to be able to generate conditional images by adding label information as input to the Generator. Deep learning experiments were performed using 141319 training data consisting of 96 kinds of characters including digits, Roman alphabets and Katakana. The Generator trained by inputting random noise concatenated with the 96 kinds of characters, could generate each kind of character by just adding the appropriate label information.



Figure 1. Proposed Conditional DCGAN which generates conditional handwritten characters

#### 1. Introduction

Of late, more and more Deep Learning techniques which deal with generating images are been developed and as a result realistic images are being generated. In addition to being able to generate images that are realistic, the potential of deep learning is immense, such as supplementing blank areas and learning to imitate styles of famous painters to create artistic images.

To further test the potential of deep learning, we tried generating handwritten characters by developing a model called *Conditional DCGAN* which combines DCGAN with cGAN (Conditional GAN). A conditional label is added as additional input along with the image input to the model. The target kinds of character we dealt with in this study are not only digits, but also alphabets and katakana (Japanese script) and some special characters. The goal of this study is generating handwritten characters by making a distinction among more than 90 different kinds of them.

In our experiment, we obtained results by changing the dimensions of the random noise which is part of the input for the models. It can be inferred from our results that when the number of dimensions of noise falls below the number of labels, the model cannot generate images that are likely to be characters; and on the other hand, if the number of types exceeds 90, the

Contact: Rina Komatsu, Faculty of Science & Technology, Sophia University, Tokyo, Japan, r komatsu@outlook.com model can generate the specified characters.

#### 2. Related Work

We construct the model (the architecture shows in Figure 1) based on the techniques from DCGAN and cGAN. This section introduces generating method: GAN and DCGAN, also introduce cGAN to generate conditional images.

#### 2.1 GAN & DCGAN

GAN: Generative Adversarial Net [Ian J. Goodfellow, 2014] is a generative network model that generates images by training a Generator and a Discriminator that are tied together in an adversarial relationship. The Generator plays the role of generating images from a given probability density distribution with random noise input, while the Discriminator plays the role of distinguishing the real input data from the fake data generated by the Generator. However, GAN has the weak points that the probability density distribution Generator learns is unable to indicate clearly and training Generator and Discriminator tend to unstable [Naoki Shimada et al, 2017].

DCGAN: Deep Convolutional Generative Adversarial Network [Alec Radford et al, 2015] is a generative model designed to solve this weak point by employing stable learning techniques such constructing fractional-strided convolution in Generator and strided convolution in Discriminator, in addition, instead of pooling layers, adapting batch normalization [Sergey (2)

Ioffe et al, 2015] to each layer and so on. The Generator in DCGAN extends the information through upsampling from random noise input, while the Discriminator extracts feature maps through convolutions. As a result, DCGAN succeeds in generating more realistic images than GAN.

About how to calculate Loss GAN and DCGAN utilize Discriminator's output in loss function shown in formulae (1) and (2) to update each the parameters of each model. Formula (1) is loss function for Discriminator and (2) is the one for Generator. If the Discriminator learns good work in distinguishing, then log(D(x)) increases and 1-log(G(z)) decreases on the contrary. On the other hand, if the Generator reaches a matured level that deceives the Discriminator, then log(D(z)) increases.

$$L_D(G, D) = E[\log(D(x))] + E[1 - \log(D(G(z)))]$$
(1)

$$L_G(G,D) = E[-\log(D(G(z)))]$$

where,

x is the training sample data, and

G(z) is the Generator's output from random noise z.

#### 2.2 cGAN: Conditional GAN

cGAN: Conditional GAN [Mehdi Mirza et al, 2014] is the generative model which can output designated images by adding auxiliary information (represented as one-hot vector) such as a label corresponding with the kinds or modality to Generator after finishing training in the Generator and Discriminator.

Figure 2 shows a simplified structure of Conditional Adversarial Nets dealing with the auxiliary information. Random noise z and an auxiliary information y are input to the Generator combined forward to hidden layer. These jointed data help the Generator to suggest the probability density distribution to which the training sample data belongs. Also, training sample data x or generated ones G(z|y) and y are input to Discriminator combined in same.



Figure 2. Simple Structure of Conditional Adversarial Net (adapted from Figure 1 in [Mehdi Mirza et al, 2014])

# 2.3 Conditional DCGAN (Constructed model in this study)

Figure 1 is the structure of proposed model in this study through trial and error finding stable training between Generator and Discriminator relatively quickly. In section 4 "Result" introduces the result using the Generator in this architecture.

Explaining details in this proposed model, Generator and Discriminator have the common factor that there is additional

input named the auxiliary information represented one -hot (In this study, the auxiliary information is replaced to the label information related with the kind of characters). In Generator, the random noise z which consists of the number of dimensions nz and label information c are merged and input to Liner layers, then proceeded to up-sampling as output G(z,c) by deconvolution. In Discriminator, c is transposed to channel representation c' since Discriminator's input is represented with channel like training sample data x or G(z,c), then merged them and extract feature maps by convolution. When proceeded to convolution, input in each layer is added some noise for stable learning [Martin Arionsky et al, 2017].

Generator, Discriminator Loss is obtained by using the output from Discriminator like GAN and DCGAN. Formula (3) is loss function for Discriminator and (4) is the one for Generator.

$$L_D(G, D) = E[\log(D(x, c))] + E[1 - \log(D(G(z, c), c))]$$
(3)  
$$L_G(G, D) = E[-\log(D(G(z, c), c))]$$
(4)

#### 3. Experiment

#### 3.1 Handwritten character dataset

As the target for handwritten character dataset, we used ETL-1 Character Database [Electrotechnical Laboratory, 1973-1984] from Electrotechnical Laboratory (succeeding organization: National Institute of Advanced Industrial Science and Technology).

In the ETL-1 Character Database, the handwritten character images are grayscale and have a unified size of  $64\times63$ . The dataset contains 96 different characters: 10 Arabic numerals, 26 large alphabets, 12 special characters and 48 katakana letters. These handwritten characters were collected from 1445 writers, by making each writer write one character at a time on an OCR sheet. The total number of samples collected were 141,319.

In the training process of the Generator and the Discriminator, we treated this dataset as training sample data x.

#### 3.2 Experiment Environment

The training of the Generator and Discriminator to distinguish 96 different kinds of characters is implemented in the Python programming language and Chainer deep learning library [Seiya Tokui et al, 2015]. We also used NVIDIA GeForce GTX 1080 Ti graphic boards to speed up the training as much as possible.

#### 3.3 Experiment Setup

As an initial setting, the whole training sample images are resized to  $64 \times 64$  and set the weight decay parameter  $\lambda = 0.00001$ .

The following steps count as 1 epoch. We repeated training the Generator and Discriminator for 100 epochs, every time employing a minibatch size 50.

#### <u>Step 1:</u>

This step consists in preparing the Generator's input, random noise and the label information. Random noise z is generated from uniform random distribution in the range [-1, 1], setting the number of dimensions as nz. Label information c is represented
with one-hot vector corresponding to the ID related to each type of character. The data shape of c becomes (batch size, label num, 1).

Step 2:

The z and c inputs are merged into the Generator to generate the output data G(z, c).

#### <u>Step 3:</u>

To the Discriminator, G(z,c) as fake data is input merged with c' which is represented in channel from c (The data shape of c' becomes (batch size, label num, h, w)). Next, the training sample data x is input merged with c'.

#### <u>Step 4:</u>

From the Discriminator's output, Generator and Discriminator Loss is calculated and the relevant parameters are updated in each model. As an optimization function, we employed the Adam function [Diederik P. Kingma et al, 2014]. The Adam function parameters in the Generator and Discriminator network models which assisted stable training in our study are shown in Table 1.

| Table | 1: | Adam | function | parameters |
|-------|----|------|----------|------------|
|-------|----|------|----------|------------|

| Parameters    | α      | $\beta_1$ |
|---------------|--------|-----------|
| Generator     | 0.001  | 0.5       |
| Discriminator | 0.0002 | 0.5       |

#### 4. Result

Using the Generator in our Conditional DCGAN, this section introduces the generated result changing nz =32,64,96(corresponding to the number of character kinds), 256,1024 and 4096(same to whole image size we set).

#### 4.1 Generating conditional handwritten characters

To make sure the Generator output handwritten characters designating c, we prepared 5 kinds of characters. Figure 3 shows each kind of handwritten character image picked up from training sample data.



Figure 3. The targets for generating (picked up from ETL-1 Character Database)

Figure 4 is the result generated by using Generators of varying nz values. In the images depicted in Figure 4, vertical axis means the output changing label information and horizontal axis means the output using different random noise z.

From the results in nz=32,64 and 96, we can see that there are outputs which are likely handwritten characters, but they do not reflect the label information. Most output were the handwritten character not belong to the kind in training sample data. Also, same images are generated although changing *z*.

On the other hand, in Generator with nz set to 256, 1024, 4096, it is possible to generate by reflecting the designation of target character type. Thus, there is no confusion between similar characters such as "8" and "S", " $\checkmark$ " and " $\gamma$ " which are similar in shape. Moreover, in the result of changing the random noise, it was possible to generate an image in which its peculiarity appeared rather than a similar image, such as when the character is large or small, or the thickness of the line is different.

Moreover, it was able to generate distinct characters despite the size being smaller (nz = 256; image size:  $64 \times 64$ ).



Figure 4. Conditional output from Generator changing nz

#### 4.2 Loss changes in Generator and Discriminator

The Loss specific to the Generator and Discriminator for each epoch is shown in Figure 5.



Figure 5. Loss changes from epoch 1-100.

As can be seen in Figure 5, in the model nz = 32,64,96, as the epochs progressed, the Generator Loss steadily increased, while the Discriminator loss gradually decreased near to 0. The difference in loss between Generator and Discriminator at epoch wider than the ones in conditional image generation. This result implies that gradient vanishing occurred in the Generator since Discriminator learned to distinguish between the real data and the fake data much before the Generator optimized to deceive the matured Discriminator [Ian Goodfellow, 2016].

Figure 6 shows the result of generating the whole of 96 kinds of characters as the target we set, from a larger nz=4096 to a smaller nz=256. Each Generator could output almost all kinds of handwritten images, making distinction just by changing the label information.

It can be inferred from our results that when the number of dimensions of noise falls below the number of labels, the model cannot generate images that are likely to be characters; on the other hand, if the number of types exceeds 90, the model can generate the specified characters.



5. Conclusion and Future work

In this study, to be able to generate handwritten characters distinguishing among 96 different kinds of characters by adding

UI designation, we constructed Conditional DCGAN. This model adapted DCGAN techniques using deconvolution for upsampling at the Generator and convolution for extracting feature maps, and cGAN technique that adds label information to Generator and Discriminator. Through training our Generator and Discriminator with the dimension of random noise over the kinds, Generator could output the entire set of characters as a result.

In our future work, since the data shape of label information at the Discriminator in Figure 1 is (batch size, label num, h, w), large load will be applied to the model if dealing with over thousand kinds of characters like kanji. To solve this problem, constructing more compact Discriminator so that Discriminator's label information could keep the shape same as the one generated by the Generator and compressed through linear function. We want to try generating conditional images making distinction among over thousand kinds of images with compact Conditional DCGAN as the next challenge.

- [Ian J. Goodfellow et al, 2014] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville & Yoshua Bengio: Generative Adversarial Nets, Advances in neural information processing systems, pp. 2672-2680, 2014.
- [Naoki Shimada et al, 2017] Naoki Shimada & Takeshi Ooura: INTRODUCTION TO DEEP LEARNING WITH Chainer, Gijutsu-Hyohron Co (Japan), 2017.
- [Alec Radford et al, 2015] Alec Radford, Luke Metz & Soumith Chintala: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, arXiv preprint arXiv:1511.06434, 2015.
- [Sergey Ioffe et al, 2015] Sergey Ioffe & Christian Szegedy: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, arXiv preprint arXiv:1502.03167, 2015.
- [Mehdi Mirza et al, 2014] Mehdi Mirza & Simon Osindero: Conditional Generative Adversarial Nets, arXiv preprint arXiv:1411.1784, 2014.
- [Martin Arjovsky et al, 2017] Martin Arjovsky & Léon Bottou: Towards Principled Methods for Training Generative Adversarial Networks, arXiv preprint arXiv:1701.04862, 2017.
- [Electrotechnical Laboratory, 1973-1984] Electrotechnical Laboratory: Japanese Technical Committee for Optical Character Recognition, ETL Character Database, 1973-1984.
- [Seiya Tokui et al, 2015] Seiya Tokui, Kenta Oono, Shohei Hido & Justin Clayton: Chainer: a Next-Generation Open Source Framework for Deep Learning, Proceedings of workshop on machine learning systems (LearningSys) in the twenty-ninth annual conference on neural information processing systems (NIPS). Vol. 5, pp. 1-6,2015.
- [Diederik P. Kingma, 2014] Diederik P. Kingma & Jimmy Lei Ba: Adam: A Method for Stochastic Optimization, arXiv preprint arXiv:1412.6980, 2014.
- [Ian Goodfellow, 2016] Ian Goodfellow: NIPS 2016 Tutorial: Generative Adversarial Networks, arXiv preprint arXiv:1701.00160, 2016.

# Sparse Damage Per-pixel Prognosis Indices via Semantic Segmentation

Takato Yasuno\*1

# <sup>\*1</sup> Research Institute for Infrastructure Paradigm Shift (RIIPS)

Efficient inspection and accurate prognosis are required for civil infrastructures with more than 30 years since completion. If we can detect damaged photos automatically per-pixels from the record of the inspection record and countermeasure classification of drone 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. A piece of damage photo is often sparse as long as it is not zoomed around damage, exactly the range where the detection target is photographed, is at most only one percent. In this paper, we propose three damage detection methods of transfer learning which enables semantic segmentation in an image with low pixels using damaged photos of drone inspection. Furthermore, we propose prognosis indices to make a decision repair-priority such as the counts index of pop-outs region and the per-pixel area counts index of each pop-out based on morphology image processing. In fact, we show the results applied this method using the 40 drone inspection images whose size is 6,000 x 4,000 on an infrastructure, where each image is partitioned into 400 crops, so the total number of input images is 16,000 for training deep neural network. Finally, future tasks of damage detection modeling are mentioned (211words).

# 1. Introduction

Deterioration of civil engineering structures is progressing in recent years, including a large number of concrete structures. Improving efficiency of scheduled inspections is a pressing issue, since the cost of inspections comprises a large proportion of maintenance costs for local governments, which are also experiencing manpower shortage for technical personnel. There are often opportunities to apply deep learning as a method for improving efficiency of inspections on social infrastructure and studies have been conducted on this issue. Dam general inspection is required for dam once every 30 years and as a result, images of damage have been accumulating (Ministry of Land, Infrastructure, 2013). If it were possible to utilize images of damage that are attached to inspection reports, data from scheduled inspections from past years can be input for the purpose of deterioration learning. If it could be possible to automatically calculate numerical scores for the extent of damage based on images of damage, this would be useful in deciding whether any repairs work should be performed and for setting the order of priority among candidates for repairs. There are past studies on detecting cracks in concrete on bridges, structures, plants, etc.

Especially, for dam structural health monitoring, it is important to prognosis pop-outs owing to be greater impact on the health of dam embankment. In area of low quality aggregates, as a result of the water absorption of the concrete, the soft stone having a high water absorption rate becomes saturated. When the freezing temperature is reached, pressure due to volume expansion occurs. However, the detection model for pop-out is only at its incipient stages, so it would be difficult to claim that this is an established means for concrete damage deterioration learning and prediction. This paper proposes a practical method applies semantic segmentation (segmentation) of concrete damage using images of damage from drone-base inspections. Results are shown from actually applying this method on sparse images of damage,

Contact: Takato Yasuno, RIIPS on 5-20-8, Asakusabashi, Taitoku, Tokyo, 111-8648, tk-yasuno@yachiyo-eng.co.jp focusing on images of pop-outs among images of damage to dam embankment. Finally, references will be made to issues of damage detection modeling as well.





Figure 1: Monitoring concrete structures from drone-base inspection to train segmentation networks and damage prediction for prognosis indices.

# 2. Related Studies and Damage Images

# 2.1 Damage detection studies for civil infrastructures

Since 2002, there has been an accumulation of studies (Wu, 2002) (Chun, 2015) on resolving damage detection using neural networks (ANN) for the purpose of continuous surveillance of bridges. Many instances of damage detection modeling for machine learning have been conducted over the past 15 years, including the ANN, as well as the PCA, SVM, GA and other such solution methods (Gordan, 2017). Since the potential of convolutional neural networks (CNN) to exhibit high degrees of accuracy in classifying one million images into 1,000 classes was reported in 2012 (AlexNet, 2012), there has been active reporting of studies on solution methods of the CNN, which provides solutions with greater accuracy than conventional methods for label categorization of overall images, object detection and semantic segmentation at the pixel level. There have been a number of studies conducted on damage classification of at the whole-image level for cracks and corrosion of road pavement, structures and bridges, for detection of damage to civil engineering structures (Gopalakrishnan, 2018) (Ricard, 2018), as well as damage segmentation at the pixel level (Hoskere, 2017). A report was made on a study that applied deep CNN to conduct four classes of damage segmentation, namely no damage, only separation, exposure of rebar (with and without rust), using 734 images of damage (Guillamon, 2018). The breakdown of the damage classes, however, indicated a distribution biased to the third class, for which there were 510 images, and as such, distortion in the training images cannot be denied. Dimensions of the images of damage were widely varied, being 640 x 480, 1,024 x 768, and 1,600 x 1,200. The potential for learning with the index that represents the degree of matching between prediction and reality, mIoU (class mean IoU) to the level of 0.6 to 0.8 was indicated by using some types of CNN models for fully convolutional networks (FCN) in entering images of such diverse dimensions. The use of the damage detection modeling that utilizes solution method of CNN, however, has just been started and as such, it would be difficult to claim that this is an established general-purpose method for damage detection in management of infrastructure. This paper proposes a practical method for damage segmentation with considerations for sparse characteristics of damage images from drone-base inspections. Furthermore, using the output of prediction RGB-images by the trained semantic segmentation, we propose two morphological indices such as the number of identified damages and the perpixel counts of each damage region for prognosis to make a decision repair-priority.

Table 1: Comparison of the per-pixel counts between the target pop-outs region and the background region.

| Example consisting<br>of 40 damage drone<br>inspection images | Total number<br>of pixels per<br>damage image | The number<br>of pixels<br>per image | Percentage<br>per image |
|---|---|--------------------------------------|-------------------------|
| Background  | 954,339,801                                   | 23,858,495                           | 99.4%                   |
| Damage to region<br>of interest (ROI)                         | 5,660,199                                     | 141,505                              | 0.6%                    |
| Total per image   | 960,000,000                                   | 24,000,000                           | 100.0%                  |

#### 2.2 Characteristics of Damage Images

This paper provides a practical observation on characteristics of images of damage, using 40 images of damage in which popout has been captured through drone-base inspection of dam embankment, whose size is 6,000 x 4,000. While generality cannot be guaranteed with these characteristics, they are considered to lead the way for utilizing images of damage. Characteristics of general conditions and damage for pop-out is as follows (CERI, 2016). Pop-out is a crater-like indentation generated by destruction due to the expansion of aggregate particles on the concrete surface. These are often observed in aggregates with high water absorption and in poor quality. Pop out is the meaning of "jumps out suddenly". In the case of lowquality aggregate, as a result of the water absorption of the concrete, the soft stone having a high water absorption rate becomes saturated. At this time, when the freezing temperature is reached, pressure due to volume expansion occurs, the surface portion peels off, and then a crater-like hole is formed.

Table 1 shows the summary value for the damage area (region of interest: ROI) subject to detection, as well as other regions in

the background, counted at pixel level. No advance manipulation was conducted on images to unify photographing distance and picture quality. The number of pixels per image was 24 million pixels. The proportion of these that include targeted damage was only 0.6%. The first characteristic of damage image is the sparsity of the area comprised of ROI.

# 3. Per-pixel Learning and Prognosis Indices

#### 3.1 Damage segmentation for prediction

The FCN-Alex (Long, 2015), as well as the SegNet-VGG16 (Badrinarayanan, 2016) are compared where appropriate, as a method for learning transfers of semantic segmentation. The solution method used in this paper by itself does not present any innovation but the extremely sparse proportion of detection target ROI on any given image is a characteristic and the intention was to derive a practical method that can be applied to images of damage with sparse pixel labels. The FCN-Alex is a transfer learning of AlexNet and the CNN is implemented to the deepest layer, making it a deep neural net (DNN) of 23 layers in depth. Learning is possible with relatively short calculation time and prediction output for exhaustive detection of targeted damage can be achieved. SegNet-VGG16 is a method of transfer learning used to identify objects for automatic driving and a DNN with depth of 91 layers.

This paper applies the four deep neural networks described above to images of damage to compare calculation execution time, accuracy and prediction output image. There is a problem of no improvements being evident with loss functions when the SGDM is used in the optimization method for hyper parameters, as gradients of the detection target are eliminated due to the sparse characteristic of the damage image. In order to overcome this issue, the gradient of the detection target is captured with good sensitivity and the previously updated quantities are deleted where appropriate, and the RMSProp, which has a characteristic formula for error function that eliminates the amount of change in gradients of detection targets by taking square root of the amount of change in gradient, is adopted (Hinton, 2012) (Mukkamala, 2017). The weighting factor for the updating amount was set to 0.99. The learning coefficient for the overall model was set to 1E-5 and the minibatch was set to 32.

#### 3.2 Morphological indices for prognosis

The word morphology commonly denotes a branch of biology that deals with the form and structure of animals and plants. We use the same word here in the context of mathematical morphology as a toll for extracting image components that are useful in the representation of region shape. We are interested also in morphological techniques for pre- or post-processing, such as morphological filtering, thinning, and pruning. In imageprocessing applications, dilation and erosion are used most often in various combinations (Serra 1992; Gonzalez 2008). This paper proposes some prognosis indices to make a decision repairpriority such as the counts index of pop-outs region and the perpixel area counts index of each pop-out based on morphological image processing, such as dilation and erosion operation.

On the prediction of pop-out damage segmentation, there are some extremely small size of pop-outs, so that we may overlook them. Also, the shape of pop-outs are not always like circle, but these are complex shape or partially connected with various size of pop-outs. This paper proposes two practical morphological operation, dilation and erosion, in terms of the union (or intersection) of an image with a translated shape called structuring element. At first, we translate the prediction RGBimage of pop-out segmentation into a binary mask image with pop-out foreground (1-valued pixel, white color) and with background (0-valued pixel, black color). Dilation is an operation that "grows" or "thickens" objects in the extremely small images of pop-outs. This growing is controlled by a shape referred to as a structuring element, such as linear, disk, octagon etc. This paper proposes the disk-shaped structuring element with radius r=3. Further, erosion "shrinks" or "thins" objects in a binary image like complex shape and partially connected with various size of pop-outs. This paper proposes these morphological operations applied to the masked prediction of pop-outs images. By these operation, it is possible to avoid overlooking the small pop-outs, and we can extract the complex shape or partially connected pop-outs, in order to count the number of pop-out and the each region pixel size more accurately and efficiently.

## 4. Applied Results

#### 4.1 Training results

The input data was 40 images whose size is 6,000 x 4,000 from drone-base inspections of dam embankment. In order to bring them closer with the input size of deep pre-trained network, we partitioned each original image into 25 x 16 equal 400 crops whose size was 250 x 240. The usage rate of the training and test data was set to Train: Test = 99:1. The transition of loss function in the learning process applied to the pop-out segmentation is shown in Figure 2. The calculation conditions are 490 cycles per epoch for a total of 24,500 repeated calculations in 50 epochs. The loss value of the FCN-AlexNet is transitioning at a lower level than SegNet-VGG16. This FCN models, however, have large dispersion of loss values and their disadvantage is that they make for unstable learning processes. The loss function of the SegNet-VGG16 does not offer minimum values, but up and down fluctuations remain small early on, which can be interpreted to offer superior stability for the learning process.

|  | Table 2: Con | nparison c | of indices | for pop-out | segmentation | models |
|--|--------------|------------|------------|-------------|--------------|--------|
|--|--------------|------------|------------|-------------|--------------|--------|

| DNN model    | Time calculation | Mean<br>mIoU | Weighted<br>wIoU |
|--------------|------------------|--------------|------------------|
| FCN-AlexNet  | 466min.          | 0.5811       | 0.9861           |
| SegNet-VGG16 | 832min.          | 0.5967       | 0.9856           |

Table 2 shows the calculation time, accuracy, mean-IoU and weighted-IoU index of respective segmentation model. The FCN-AlexNet offers a relatively short calculation time of 466 minutes. This net achieved the index such as mIoU = 0.5811, and wIoU = 0.9861. Meanwhile, the SegNet-VGG16 offers about two times calculation time compared with FCN-AlexNet, and indicates the score of mIoU of 0.5967 and wIoU of 0.9856. While each weighted wIoUs have almost no difference, but regarding the score of the mean mIoU the SegNet-VGG16 is superior with the FCN-AlexNet to select better pop-out predictor.

#### 4.2 Prediction results

Figure 2 shows an output RGB-image of predictions for a test image whose size is 600 x 400, using the trained SegNet-base predictor of pop-out segmentation. Here, the region of prediction are shown in green color. In contrast, the region of background are shown in magenta color. Figure 3 shows the translated binary mask with pop-out foreground (1-valued) and with background (0-valued). We operated the morphological operations applied to the masked prediction of pop-outs images. Further, we compute the centroid of each pop-out region and set the pop-out number in order to represent the counts index accurately, here the total count of pop-outs is 14. Figure 4 shows the per-pixel counts of each region based on the morphological image pre-processing. Figure 5 shows the bar chart that we can visualize the volume indices of pop-outs and it is possible to compare the largest size, middle size, and extremely small size of pop-outs in order to make a decision of repair-priority for infrastructure manager.



Figure 2: Trained SegNet-base prediction of pop-outs (RGB image) Here, green indicates prediction, magenta denotes background.



Figure 3: Counts index of identified pop-out centroid based on morphological operations with dilation and erosion.



Figure 4: Per-pixel counts of each pop-out prediction region based on morphological image processing.



Figure 5: Area pixel count index of each pop-out for prognosis measure indices to make a decision regarding repair-priority.

# 5. Conclusion

#### 5.1 Concluding remarks

This paper proposed a method for detecting pop-out by semantic segmentation, using images of damage obtained from drone-base inspections. In fact, we show the results applied this method using the 40 drone inspection images at a dam embankment, where each image is partitioned into 400 crops, so the total number of input images is 16,000 for training deep neural network. Based on transfer learning, per-pixel higher accurate prediction is possible, even to sparse damage images whose pop-out ratio per-pixel is only one percent compared with the background. The SegNet-VGG16 exhibited the better accuracy and achieved class mean mIoU index of 59.67% and weighted index wIoU of 98.56%. Furthermore, we demonstrated to compute some morphological indices, such as the counts index of identified pop-outs centroid and the per-pixel area counts index of each pop-out region for prognosis to make a decision repair-priority more accurately and efficiently.

#### 5.2 Future works

The scope of this paper was the segmentation of pop-out for prognosis, using images from drone-base inspection of dam embankment. Monitoring various damages for standard dam inspection prescribes concrete crack, scaling, pop-outs, water leak, efflorescence etc (Ministry of Land, Infrastructure, 2013). In contrast, creation of dataset for training and prediction of various segmentation models for being predictive diagnosis before occurred pop-outs, such as "crack" and "scaling" are the issue for health monitoring. Infrastructure manager administrates a lot of aging structures other than dam well. Learning of damage segmentation models using a diverse range of images for a wide variety of other infrastructures will be the issue for the future. Predictor of damage segmentation intelligence created from scratch, i.e. U-Net by data mining accumulated images is also a challenging issue. Furthermore, 3-dimension segmentation is more useful for volume counting to measure the depth of damage.

[Acknowledgments] We would like to express our gratitude to obtain practical information about Deep Learning and Image Processing Toolbox for training and prediction from Mr. Shinichi Kuramoto and Mr. Takuji Fukumoto.

- [Ministry of Land, Infrastructure 2013] Water Management Land Conservation Bureau River Environment Division : Dam General Inspection Procedure Commentary, 2013.
- [CERI 2016] Public Works Research Institute CERI : Survey and Countermeasure Guidance on the Structure Suspected of Frost Damage (draft), 2016.
- [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, Latin American Journal of Solids and Structures, pp.2373-2401.
- [AlexNet 2012] Krizhevsky, A. et al. : ImageNet Classification with Deep Convolutional Neural Networks, NIPS, 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, International Journal for Traffic and Transport Engineering, 8(1), pp.1-14, 2018.
- [Ricard 2018] Ricard, W., Silva, L. et al. : Conclete 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, 3<sup>rd</sup> Huixan International Forum on Earthquke Engineering for Young Researchers, 2017.
- [Guillanmon 2018] Guillamon, J.R. : Bridge Structural Damage Segmentation using Fully Convolutional Networks, Universitat Politecnica de Catalunya, 2018.
- [Long 2015] J. Long, E. Shelhamer, T. Darrell : Fully Convolutional Networks for Semantic Segmentation, CVPR, pp3431-3440, 2015.
- [Badrinarayanan 2016] V. Badrinarayanan, A. Kendall, et al., 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. Mukkalmala et al.: Variants of RMSProp Adagrad with Logarithmic Regret Bounds, 2017.
- [Serra 1992] Serra, J., Vincent, L.: An Overview of Morphological Filtering, Circuits, Systems and Signal Processing, 11(1), pp47-108, 1992.
- [Gonzalez 2008] Gonzalez, R.C., Woods, R.E. : Digital Image Processing, 3<sup>rd</sup> ed., Prentice Hall, 2008.
- [Yasuno 2018] T. Yasuno: Infra Machine Learning for Predictive Maintenance via Classification Models, 32th Journal of Society for Artificial Intelligence, 3Z1-04, 2018.
- [Yasuno 2019] T. Yasuno, M. Amakata, J. Fujii, Y. Shimamoto : Color-base Damage Feature Enhanced Support Vector Classifier for Monitoring Quake Image, IAPR: CCIW, 2019. (2019.Feb.15)

International Session | International Session | [ES] E-2 Machine learning

# [3B4-E-2] Machine learning: social links

Chair: Lieu-Hen Chen (National Chi Nan University), Reviewer: Yasufumi Takama (Tokyo Metropolitan University)

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room B (2F Main hall B)

| [3B4-E-2-01] | Social Influence Prediction by a Community-based Convolutional<br>Neural Network  |
|--------------|---|
|              | Shao-Hsuan Tai <sup>1</sup> , Hao-Shang Ma <sup>1</sup> , OJen-Wei Huang <sup>1</sup> (1. National Cheng Kung                               |
|              |   |
|              |   |
| [3B4-E-2-02] | A Community Sensing Approach for User Identity Linkage  |
|              | OZexuan Wang <sup>1</sup> , Teruaki Hayashi <sup>1</sup> , Yukio Ohsawa <sup>1</sup> (1. Department of Systems Innovation,                  |
|              | School of Engineering, The University of Tokyo)   |
|              | 4:10 PM - 4:30 PM   |
| [3B4-E-2-03] | Learning Sequential Behavior for Next-Item Prediction   |
|              | $\bigcirc$ Na Lu $^1$ , Yukio Ohsawa $^1$ , Teruaki Hayashi $^1$ (1. The University of Tokyo)   |
|              | 4:30 PM - 4:50 PM   |
| [3B4-E-2-04] | Application of Unsupervised NMT Technique to JapaneseChinese  |
|              | Machine Translation   |
|              | OYuting Zhao <sup>1</sup> , Longtu Zhang <sup>1</sup> , Mamoru Komachi <sup>1</sup> (1. Tokyo Metropolitan University)<br>4:50 PM - 5:10 PM |
| [3B4-E-2-05] | Synthetic and Distribution Method of Japanese Synthesized   |
| []           | Population for Real-Scale Social Simulations  |
|              | $\bigcirc$ Tadahiko Murata <sup>1</sup> Takuya Harada <sup>1</sup> (1 Kansai University)  |
|              |   |
|              | 5.10 FWI - 5.30 FWI   |

# Social Influence Prediction by a Community-based Convolutional Neural Network

Shao Hsuan Tai<sup>\*1</sup> Hao-Shang Ma<sup>\*2</sup> Jen-Wei Huang<sup>\*3</sup>

\*1\*2\*3Institute of Computer and Communication Engineer, Department of Electrical Engineering, National Cheng Kung University, Tainan, Taiwan

Learning social influence between users on social networks has been extensively studied in a decade. Many models were proposed to model the microscopic diffusion process or to directly predict the final diffusion results. However, most of them need expensive Monte Carlo simulations to estimate diffusion results and some of them just predict the size of the spread via regression techniques, where people who will adopt the information becomes unknown. In this work, we regard the prediction of final influence diffusion results in a social network as a classification problem to avoid expensive simulations with knowing the final adopters. We first address the problem on a deep neural network and utilize the diffusion traces to train the network. Furthermore, we propose a community-based convolutional neural network to capture the information of local structure with the aforementioned network. The proposed model is referred to as the Social Influence Learning on Community-based Convolutional Neural Network, SIL-CCNN shows the promising results in both synthetic and real-world datasets.

# 1. Introduction

Nowadays people tend to share their life, emotions, and opinions to others on social network websites. Two representative diffusion models, Independent Cascade, IC, model and Linear Threshold, LT, model, were reformulated by Kempe [3]. However, there are several limitations of predicting the information diffusion using diffusion models. The influence probabilities between users and the active threshold of a user should be measured or learned from many personal features such as users' preferences and different relationships. In real social networks, the features are not easy to extract since the data sometimes is not complete. In addition, to get the results of IC/LT model, we need to conduct a huge number of simulations.

Actually, the prediction of the information diffusion process and the final diffusion results models can be regarded as a classification problem. Given the information sources and the network structure, the individuals are classified into active or inactive classes in the final diffusion result. The active class is corresponding to the individuals being influenced successfully in the information diffusion process. Some related works aim to predict the size of information spreads as a classification or regression problem [1,7]. Different with diffusion models, these methods usually do not learn the individuals who are actually influenced by the information. We would like to know exactly who are influenced and who are not.

To overcome above limitations and solve the classification problem, we propose an influence prediction model based on

Contact: Jen-Wei Huang, Institute of Computer and Communication Engineer,
Department of Electrical Engineering,
National Cheng Kung University, Tainan, Taiwan.
Email: jwhuang@mail.ncku.edu.tw
Tel:(+886)-6-2757575#62347 community-based convolutional neural network. First, we consider the influence propagation process in the past to learn the influence between individuals. Then, most of the diffusion models consider the network structure, i.e., the relations between individuals, as their features. However, the information of the whole network structure may not be useful for the classification problem whereas the local network information of a single individual should be helpful. We try to embed the local structure of an individual into our model to learn the local relations. The community structure in social networks represents a cluster of individuals sharing connections that are stronger than those with individuals outside the community. The information diffusion in a community should be faster than outside the community. Therefor, we use the convolutional neural networks to mine the local relations within the community structure. The idea is that convolutional neural networks are good to extract the effects of a small group of individuals around an individual by extracting valuable relations from the structure. Finally, the influence traces and the community structure information are combined into our model as training features of the deep neural network. The proposed scheme is referred to as the Social Influence Learning on Community-based Convolutional Neural Network, SIL-CCNN.

The remainder of the paper is organized as follows. Works related to this work are outlined in Section 2. Section 3 details the proposed methodology. Experiment results and conclusions are presented in Section 4 and Section 5.

# 2. Previous Work

In this section, we will briefly introduce other related works on diffusion models and the prediction of information spread size.

#### 2.1 Diffusion Models

Diffusion models can be used to identify social influence by tracking information propagating through a social network. Nowadays, some diffusion models adopt the learning strategy to predict the activation since the technique of learning methodology has matured in these few years. Saito [6] first proposed a learning method for IC model. Wang [8] proposed a feature-enhanced approach, which considers not only temporal data in cascades but also additional features. Chou [2] proposed Multiple Factor-Aware Diffusion model, MFAD, that can consider many kinds of factors together. MFAD model adopts positive and unlabeled learning to train the classifiers for each individual.

#### 2.2 Prediction of Information Spread Size

Different from diffusion models, the cascade prediction only focuses on predicting whether the information will become popular and widely spread. The problem is usually formulated as a classification or a regression problem to understand the size of potential influence of information.

Among the classification solutions of predicting information cascade, Cheng [1] proposed to use temporal and structural features for predicting the relative growth of a cascade size. As for the regression solutions, Tsur [7] proposed a content-based prediction model to include locations, orthography, number of words, lexicality, ease of cognitive process and emotional effect on various cognitive dimensions.

Our work aims to learn the hidden influence propagation from the data instances and the network structure directly without the huge number of diffusion simulations.

## 3. Methodology

In this section, we first propose an ordinary deep neural network model, SIL-DNN, for identifying traces of social influence. Second, we adopt a convolutional neural network to extract the local structure information of a network from the communities. Then, we propose Social Influence Learning on Community-based Convolutional Neural Network, abbreviated as SIL-CCNN, which combines the SIL-DNN and a community-based convolutional neural network to predict the final influential results.

Given a social network  $\mathbb{G} = (\mathbb{V}, \mathbb{E})$ , the node set  $\mathbb{V}$  corresponds to the individuals, and  $\mathbb{E}$  is the edge set indicating the relationships between individuals. Each influence trace (u, v, x) indicates that the nodes v adopt the information x and is influenced by source nodes u, where u and v are sets of nodes in  $\mathbb{V}$ . The architecture of SIL-DNN is presented in Fig. 1. In SIL-DNN, the number of neurons in the input layer is the same as the number of individuals in the social network |V|. The same setting is used in the output layer. For every trace, we put the vector of information sources as the input data of SIL-DNN and the output are the vector of influenced nodes. The input vector and output vector could be set as follows,

$$\begin{cases} y_i = 1, \text{ if } i \in u \text{ for } (u, v, x) \\ y_i = 0, & \text{otherwise,} \end{cases}$$
(1)



Figure 1: Social Influence Learning on Deep Neural Network Architecture

where  $y_i$  represents an individual i at the input layer.  $i \in u$ for (u, v, x) indicates all traces that transmit the information x from user i. For example, an individual i provides an information x during the observation. The neuron of input layer  $y_i^0 = 1$  for the information x. On the other hand, in the output layer, the  $y_j = 1$  represents that node j is influenced by i and is classified as the active class. Otherwise, node j is classified into the inactive class.

#### 3.1 Social Influence Learning on Communitybased Convolutional Neural Network

In order to join the community structure to help us to predict the information diffusion results, we propose Social Influence Learning on Community-based Convolutional Neural Network, SIL-CCNN. The architecture of SIL-CCNN is presented in Fig. 2. First, we need to extract the community information in the network and form the relation matrix of each community. A list of relation matrix RMfor communities in COMM can be formulated. Then, we design a community-based convolutional neural network to deal with community-related information by extracting features through a convolutional layer and a pooling layer. For the input of the convolution layer, we extract the relation matrices of communities to represent the local network information of the individual. The relation matrix RM of a community is defined as follows,

$$RM = [rm_{ij}]_{d \times d}, rm_{ij} = \begin{cases} w_{ij}, (v_i, v_j) \in E\\ 0, otherwise, \end{cases}$$
(2)

where d is the number of nodes in the community. The element  $rm_{ij}$  in the relation matrix represents the weight on the edge between node  $v_i$  and node  $v_j$  in a community. In addition, in order to account for differences in the size of communities, the community information matrices are normalized to the size of the largest community and have zero-padding.

However, if we randomly assign the order of nodes in relation matrices and put the matrices into the convolutional neural network, the small extracted region in the convolution layer would be meaningless. Therefore, we design an arrangement strategy to determine the relations of nearby



Figure 2: Social Influence Learning on Community-based Convolutional Neural Network architecture

elements. The order of individuals in each relation matrix is determined by the ranking of the number of degrees. The individual having the largest degree will be arranged to the leftmost of x-axis and the topmost of y-axis. Therefore, each block in different relation matrices shares the same weight matrix in the convolutional neural network.

In the pooling layer, we use max-pooling as our pooling function. Max-pooling is particularly well suited to the separation of features that are sparse. After the pooling layer, SIL-CCNN constructs a merge layer to combine the output of the pooling layer and the input vector of SIL-DNN. Then, several hidden layers are trained in SIL-CCNN before the output layer. Finally, a few hidden layers and one full-connected output layer are connected after the merge layer.

As for the detailed setting of neural network, the kernel size of the convolutional layer is defined to  $3 \times 3$ . In addition, we define a sigmoid function in the output layer and a crossentropy objective function. In the training step, our goal is to minimize the following equation:

$$Q\left(W^{t}, W^{r}\right) = -\sum_{i}^{I} t_{i} \log y_{i}, \qquad (3)$$

where I is the number of inputs,  $W^t$  is the weight matrices of traces, and  $W^r$  represents the weight matrices of the structure relation in SIL-CCNN. The weight matrix contains the relations between the individuals and the local structure information. The equation above is shown for one individual i at output layer k ranging over all target labels. Our objective function aims to minimize the cross entropy between the target t and the prediction y. As for the optimization, we use the well-known backpropagation algorithm and Adam [4] to compute the parameters in SIL-CCNN.

# 4. Experiments

In this section, we introduce experiments aiming at evaluating predicting performance in social networks using a



Figure 3: Accuracy and MAE on the synthetic dataset of 5000 nodes



Figure 4: Accuracy and MAE on twitter dataset

synthetic dataset and a real-world dataset.

#### 4.1 Dataset descriptions

**Synthetic Data.** Using the Lancichinetti-Fortunato-Radicchi (LFR) benchmark [5], we generate the synthetic dataset with 5000 nodes (2,666,674 traces). For the generation of diffusion data, we set the transmission probability uniformly between 0.1 and 1. We then choose a node at random to function as a source node and set it to be active.

**Real Data.** We crawl data from Twitter<sup>\*1</sup> for the period between September 2011 and May 2015. We use the experts in Healthcare Pundits<sup>\*2</sup> and Security<sup>\*3</sup> as the ini-

<sup>\*1</sup> https://twitter.com

 $<sup>*2 \</sup>quad http://nursepractitionerdegree.org/top-50-health-care-$ 

pundits-worth-following-on-twitter.html \*3 http://www.marblesecurity.com/2013/11/20/100-security-

tial nodes, and crawl the followers of these experts to form a social network. The twitter data contains 20,453 users and 3,782,305 tweets. In this study, tweets were used as items, and the actions of sharing, replying, and liking are indications of the influence of a tweet.

#### 4.2 Compared Methods

We include the following methods to predict the information diffusion results.

- Logistic Regression (LR). The in-degree and outdegree are included in a classifier for individual v.
- Independent Cascade model (IC). IC is a conventional diffusion model in which the probability of transmission from individual *u* to *v* is the ratio of items individual *v* adopted items from individual *u*.
- Multiple Factor-Aware Diffusion model (MFAD). MFAD is a diffusion model that can learn the social influence by multiple features [2].
- SIL-DNN and SIL-CCNN. We evaluated the performance of SIL-DNN and SIL-CCNN using one hidden layer (*DNN\_1layer*, *CCNN\_1layer*) and two hidden layers (*DNN\_2layers*, *CCNN\_2layers*) in the following experiments.

## 4.3 Evaluated Metrics

We evaluate the performance of algorithms using the following two metrics.

- Accuracy. Accuracy is defined as the ratio of correct predicted answers over all answers in order to estimate the correctness of predictions.
- Mean Absolute Error (MAE). We computed the mean absolute error as follows:  $MAE = \frac{\sum_{i=1}^{n} |y_i x_i|}{n}$ , where  $y_i$  is the truly adopted result of individual  $i, x_i$  is the estimated adoption probability of individual i, and n is the number of individuals in the network.

#### 4.4 Results and Discussions

The comparison results on synthetic dataset is shown in Fig. 3. SIL-DNN and SIL-CCNN outperform the other three methods in the synthetic dataset. In addition, SIL-CCNN have higher accuracy and lower MAE than SIL-DNN using the same number of hidden layers. The results show that the information of the community structure actually helps the model to predict the influence results better. The proposed community-based CNN indeed extracts the local relations of individuals. Moreover, the performance of SIL-CCNN 2 layers is better than the SIL-CCNN 1 layer. Using more hidden layers also conducts a better result.

In the real twitter dataset, the results are shown in Fig. 4. SIL-DNN and SIL-CCNN still outperform the other three methods except for the  $DNN_layer$ . We have examined the propagation results in these two datasets. We found that the influenced scale of the synthetic dataset is much larger than the Twitter dataset. This indicates that the

# 5. Conclusions and Future Works

In this work, we proposed two neural network architectures, SIL-DNN and SIL-CCNN, to identify social influences based on the propagation of information in a social network. The proposed framework makes it possible to obtain the diffusion results within the community. SIL-DNN and SIL-CCNN can predict the users who are actually influenced from the information without the Monte Carlo simulation. Experimental results demonstrate that SIL-DNN and SIL-CCNN both outperform existing methods.

For further improvement, we will design a strategy to extend the depth of SIL-CCNN in the future to overcome the problem with the insufficient number of traces. We also want to revise the structure of neural network to consider more features such as the content of items.

- J. Cheng, L. Adamic, P. A. Dow, J. M. Kleinberg, and J. Leskovec. Can cascades be predicted? In *In Proceedings of WWW*, pages 925–936, 2014.
- [2] C.-K. Chou and M.-S. Chen. Multiple factors-aware diffusion in social networks. In *In Proceedings of PAKDD*, pages 70–81, 2015.
- [3] D. Kempe, J. M. Kleinberg, and E. Tardos. Maximizing the spread of influence through a social network. In In Proceedings of h ACM SIGKDD, pages 137–146, 2003.
- [4] D. Kingma and J. B. Adam. A method for stochastic optimization. In *In Proceedings of ICLR*, 2015.
- [5] A. Lancichinetti and S. Fortunato. Benchmarks for testing community detection algorithms on directed and weighted graphs with overlapping communities. *Physi*cal Review E, 80, 2009.
- [6] K. Saito, R. Nakano, and M. Kimura. Prediction of information diffusion probabilities for independent cascade model. In *In Proceedings of KES*, pages 67–75, 2008.
- [7] O. Tsur and A. Rappoport. What's in a hashtag?: content based prediction of the spread of ideas in microblogging communities. In *In Proceedings of WSDM*, pages 643–652, 2012.
- [8] L. Wang, S. Ermon, and J. E. Hopcroft. Featureenhanced probabilistic models for diffusion network inference. In *In Proceedings of ECML-PKDD*, pages 499– 514, 2012.

diffusion results in synthetic dataset should be more difficult to predict. The superiority of SIL-CCNN over SIL-DNN shows that the performance can be improved by including the community information by the proposed communitybased convolutional neural network.

experts-follow-twitter/

# A Community Sensing Approach for User Identity Linkage

Zexuan Wang Teruaki Hayashi Yukio Ohsawa

Department of Systems Innovation, School of Engineering, The University of Tokyo

User Identity Linkage aims to detect the same individual or entity across different Online Social Networks, which is a crucial step for information diffusion among isolated networks. While many pair-wise user linking methods have been proposed on this important topic, the community information naturally exists in the network is often discarded. In this paper, we proposed a novel embedding-based approach that considers both individual similarity and community similarity by jointly optimize them in a single loss function. Experiments on real dataset obtained from Foursquare and Twitter illustrate that proposed method outperforms other commonly used baselines that only consider the individual similarity.

# 1. Introduction

In recent years, Online Social Networks (OSNs) such as Twitter, Facebook and Foursquare tend to become the central platform of people's social life. Tons of contextual (e.g. tweets, photos) and network structure related (e.g. users' profiles, relations) data is created every day on these OSNs, which is an important resource for many valuable applications such as user behavior prediction, and cross-domain recommendation. All such applications require a crucial step called User Identity Linkage (UIL) [Shu 17], which aims to identify and link the same person/entity across different OSNs. These linkages are also called anchor links as they help align different networks under the common scene that users usually don't explicitly claim the ownership of their different accounts, and due to privacy protection rules, personal information is always restricted inside each isolated OSNs.

Abundant literature has been focusing on the UIL problem, and the majority of them fall into two categories: (1) Structure-based approaches: these approaches focus directly on the structural features of a social network, such as user names, following relationship and common neighbors between different users [Malhotra 12, Kong 13], while the problem of those approaches lies on the difficulty to find an optimal distance function between nodes to evaluate their similarity as networks are not presented in the Euclidean space [Zhang 18]. (2) Embedding-based approaches: network embedding is a new way of network representation that is able to encode the network in a continuous lowdimensional vector space while effectively preserving the network structure, for example, [Zhou 18] proposed a duallearning embedding paradigm to improve the linking result.

However, existing methods haven't paid enough attention to the social communities naturally formed by people in the real world. Users who have limited profile information could be evaluated easier when they are located in interest groups together with their close neighbors. To better resolve the UIL problem, we proposed a novel method called Community Sensing User Identity Linkage (CSUIL), which takes

Contact: Zexuan Wang, The University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo, Japan, wangzexuan@g.ecc.u-tokyo.ac.jp advantage of both structural and embedded features of a network by designing a jointly learning model. It aids user mapping by driving some of users to the same communities they belong to, which enhances the method's accuracy and generalization ability. Experiment results on real-world dataset show feasibility of our method.

# 2. Problem Definition

**Definition 1** Social Network Graph An unweighted and undirected network is denoted as  $G = \{V, E\}$ , where V is the set of nodes and each node represents a user, E is the set of edges reflecting connections between nodes.

**Definition 2** Node Embedding In a given network  $G = \{V, E\}$ , node embedding (a sub-task of network embedding) learns a projection function  $\psi : V \mapsto \mathbb{R}^{|V| \times d}$ , where  $d \ll |V|$ . For each node  $v_i \in V$ ,  $\psi(v_i) \in \mathbb{R}^d$  denotes its latent representation in the vector space.

**Definition 3** *n*-th order neighbors The collection of all nodes which can be reached from the given root node  $v_r \in G$ within exactly n hops, denoted as  $C_r = \{v_i | hop(v_i, v_r) = n\}$ .

**Definition 4** User Identity Linkage Given two different networks,  $G^S = \{V^S, E^S\}$  and  $G^T = \{V^T, E^T\}$ . The goal of User Identity Linkage (UIL) is to predict a pair-wise linkage between a user node  $v_s$  selected from the source network  $G^S$  and an unlabeled user node  $v_s$  in the target network  $G^T$ , which indicates the same user/entity (i.e.,  $v^s = v^t$ ).

# 3. Community Sensing User Identity Linkage

This proposed method consists of three main components: network embedding, community clustering and latent space mapping. A brief overview is shown in Figure 1, where blocks are the core elements in each phase, green lines indicate structural information flow directions and blue lines show how algorithms connect different phases.

## 3.1 Network Embedding

The quality of the latent representation of each node in both source and target network is important to the results



Figure 1: A brief overview of CSUIL

of the following clustering and mapping stages. Ideally, user nodes that have stronger connection, like sharing more common neighbors, or having shorter path between them should be closer to each other after they are projected into the latent space. To obtain the network embedding in good quality, an efficient model called DeepWalk [Perozzi 14] was adopted. DeepWalk mainly utilizes the truncated random walk and the SkipGram [Mikolov 13] model.

In particular, A random walk generator is first applied to the network, which will sample uniformly a random node  $v_i \in G$  as the root of a random walk sequence  $W_{v_i}$ , then the generator samples uniformly from the neighbors of the last node visited until the maximum sequence length(l) is reached. The generated sequences could be thought of as short sentences, while the nodes within sequences are treated as words of a special kind of language. We could then obtain the embedding of nodes as a byproduct when updating the weight matrix in the derived SkipGram model, which aims to maximize the co-occurrence probability of nodes that appear within a window size w near the center  $v_j$  in the sequence  $W_{v_i}$ , that is to maximize the following log probability:

$$\max \quad \frac{1}{l} \sum_{i=1}^{l} \sum_{j=-w, j \neq 0}^{w} \log \Pr(v_{i+j}|v_i)$$
(1)

where  $\Pr(v_{i+j}|v_i)$  is calculated with a hierarchical softmax function:

$$\Pr(v_{i+j}|v_i) = \frac{\exp(\boldsymbol{\psi}(v_{i+j})^{\mathrm{T}}\boldsymbol{\psi}(v_i))}{\sum\limits_{m=1}^{l} \exp(\boldsymbol{\psi}(v_m)^{\mathrm{T}}\boldsymbol{\psi}(v_i))}$$
(2)

where  $\psi(v_i)$  is the embedding of node  $v_i$  we want to update at each training step and finally output to the next phase.

#### 3.2 Community Clustering

In some supervised User Identity Linkage models such as PALE [Man 16], it only focuses on learning the user level, pair-wise matching patterns between source and target network. However, these methods failed to consider the social communities naturally formed by people in the real world. Some drawbacks may exist under such settings that users with very limited profile information could be hard to distinguish from others and the model may fall into over-fitting of local pair-wise features when trained with small amount of labeled data. More importantly, the knowledge contained in the structural relationship among anchor and non-anchor users in the original non-euclidean space is discarded after SkipGram is applied (shown by green lines in Figure 1) and later phases are not able to reuse such information.

Therefore, we made an assumption that compared to only considering the generated embedding or user-level similarity matching, the fact that which neighbors a user has in the original network, and which community a user belongs to could reveal more diffusible structural knowledge. Thus, we consider clustering the n - th order neighbors of an anchor user to form their social community, the users in the same community have a closer relationship and higher similarity, which could be evaluated in some metrics including: the amount of common neighbors, or the minimum walk length between each other.

To utilize all the user information in a community, we reuse the structural information in the original network and derive a new embedding to represent this community by adopting the mean value of all community member embedding generated in Section 3.1 that are non-anchor nodes. The center that represents a certain community cluster  $C_i$ is denoted as  $\mu_i$ :

$$\psi(\mu_i) = \frac{\psi(v_r) + \sum_{v' \in C_i} \psi(v')}{N+1}$$
(3)

where  $v_r$  is the root user, and N is the community size.

#### 3.3 Latent Space Mapping

Let  $\boldsymbol{z}^{\boldsymbol{s}} = \psi(v^s)$  and  $\boldsymbol{z}^{\boldsymbol{t}} = \psi(v^t)$  be the node embedding generated in Section 3.1 and the final stage of CSUIL is Latent Space Mapping. In this phase, we try to find a mapping function from the source network to the target network  $\Phi$ :  $\mathbb{R}^{|V^s| \times d} \mapsto \mathbb{R}^{|V^t| \times d}$ , that will minimize the distance between the predicted embedding  $\Phi(\boldsymbol{z}^s)$  and the true corresponding embedding  $\boldsymbol{z}^t$  of  $\boldsymbol{z}^s$  in the target network:

$$\min \quad \left\| \Phi\left( \boldsymbol{z}^{\boldsymbol{s}} \right) - \boldsymbol{z}^{\boldsymbol{t}} \right\|_{F} \tag{4}$$

We then train a novel two-inputs and two-outputs neural network model, which breaks down the whole task above into two simultaneously conducted parts: (1) minimize the distance between predicted and real user node (2) minimize the distance between predicted and real community center. The second sub-task will drive the mapping function to the direction that also exploits the relationship between community centers in both source and target networks to increase the generalization ability of the model on new unseen data. Next, the design of the loss function could be one of the most critical parts of a machine learning model, a good loss function should reflect the error during training as well as the generalization error that guides parameters to optimize the model. Therefore, for the goal of above two sub-tasks, a new community sensing loss function is proposed as:

$$loss = (1 - \gamma) \sum_{(v^s, v^t) \in \{S, T\}} \left\| \Phi(\boldsymbol{z^s}; \theta) - \boldsymbol{z^t} \right\|_F + \gamma \sum_{\boldsymbol{\mu} \in C} \left\| \Phi(\boldsymbol{\mu^s}; \theta) - \boldsymbol{\mu^t} \right\|_F$$
(5)

where  $\{S, T\}$  is the set of groundtruth anchor pairs, C is the set of community centers, F is the Frobenius norm,  $\theta$  is the collection of all parameters in the model, and  $\gamma$  is the hyper-parameter of the weight coefficient of the community loss that could be co-optimized during the learning of the mapping function.

We finally employed a Multi-Layer Perceptron (MLP) model that does not require extensive feature selection or difficult parameter tuning to learn the optimized mapping function, while this model also has the flexibility of dealing with the non-linear relationships that may exist between the source and target network.

The whole algorithm design is shown in Algorithm 1.

Algorithm 1: CSUIL

Input: network G(V, E), anchor nodes  $\{S, T\}$ , test nodes  $\{S', T'\}$ , community clustering parameter n, community loss parameter  $\gamma$ Output: mapping function  $\Phi$ , matching result list  $\mathbb{R}$ foreach node  $v_i \in G$  do | Generate the embedding of  $v_i$  as  $z_i$ end foreach anchor node pair  $\{s_i, t_i\}$  in  $\{S, T\}$  do Reuse the original network structure information, cluster the n-order neighbors of  $s_i$  and  $t_i$ Derive the community center  $\mu_i^s$  and  $\mu_i^t$ end

Train the MLP model by jointly minimize the node mapping loss  $\|\Phi(\boldsymbol{z}^s; \theta) - \Phi(\boldsymbol{z}^t)\|_F$  and community loss  $\|\Phi(\boldsymbol{\mu}^s; \theta) - \Phi(\boldsymbol{\mu}^t)\|_F$ foreach test node  $s'_i \in S'$  do | Add the predicted  $t'_i$  to result list R

end Evaluate(R, T')

# 4. Experiment

#### 4.1 Data Preparation

A real-world social network dataset collected from Twitter and Foursquare [Zhang 15] is used in this experiment, which was released in [Liu 16]. All the sensitive personal information is removed under privacy concerns to form the final training and testing data. The ground truth of anchors is obtained by crawling users' Twitter accounts from their Foursquare homepage. Table 1 lists the statistics of this dataset.

| Network    | #Users | #Relations | #Anchors |
|------------|--------|------------|----------|
| Twitter    | 5,220  | 164,919    | 1,609    |
| Foursquare | 5,315  | 76,972     |          |

| Table 1: Statistics of | f Twitter-Foursquare | Dataset |
|------------------------|----------------------|---------|
|------------------------|----------------------|---------|

#### 4.2 Evaluation Metrics

In this experiment, in a similar form to [Zhou 18], a metric called *Precision*@k was adopted, which is defined as:

$$Precision@k = \frac{\sum_{i}^{n} TOP_k(\Phi(\boldsymbol{z}_i^s))}{N}$$
(6)

where  $TOP_k(\Phi(\boldsymbol{z}_i^s))$  is a binary output function (0 or 1), for each predicted embedding  $\Phi(\boldsymbol{z}_i^s)$ , it tells whether the positive match  $\boldsymbol{z}_i^t$  exists in the top - k list or not, and N is the number of all testing nodes. In the context of UIL, as *Precision*@k is a metric of the true positive rate, it could be treated the same as *Recall*@k, and  $F_1$ @k.

#### 4.3 Comparative Methods

We compare the proposed CSUIL with several existing embedding-based methods, and take them as the baseline of this task.

- **CSUIL**: the proposed method, it could explicitly exploit the individual as well as community features of a network, by jointly optimizing mapping functions that concentrate on user-level and community-level similarity respectively.
- **IONE**: Proposed in [Liu 16] and adopted as a baseline result, Input-Output Network Embedding (IONE) is a network embedding and partial network alignment method. It takes follower-ship and followee-ship as input and output contexts and generates all three representations together with the user node.
- **INE**: INE is a simplified version of IONE, which only consider node and input representation for matching.

#### 4.4 Results

The performance results are illustrated in Table 2 and Figure 2. In the experiment, during the community clustering phase, the cluster size is set to first-order neighbors for the simplicity. Then we examine the ability of the final model (with training rate=90%) on the link prediction task. For CSUIL, we report the result in different settings of precision metrics k and community loss weight coefficient  $\gamma$ . For INE and INOE, we report the result in the original paper's default setting.

|          |        |        | F      | Precision@ | k      |        |        |        |
|----------|--------|--------|--------|------------|--------|--------|--------|--------|
| $\gamma$ | P@1    | P@5    | P@9    | P@13       | P@17   | P@21   | P@25   | P@30   |
| INE      | 0.1108 | 0.2184 | 0.2975 | 0.3291     | 0.3703 | 0.4114 | 0.4304 | 0.4494 |
| IONE     | 0.1899 | 0.3481 | 0.4494 | 0.4968     | 0.5253 | 0.5665 | 0.5854 | 0.6044 |
| 0.8      | 0.2405 | 0.5190 | 0.6203 | 0.6835     | 0.7342 | 0.7722 | 0.7975 | 0.8165 |

Table 2: Performance comparison between baselines

From the experiment results, we could conclude that:



Figure 2: Link prediction precision results. X-axis is the different value of k, for the top-k list being evaluated; Y-axis is the precision result in percentage.

- Compared to the baseline model, INE and IONE, the best performance (when  $\gamma = 0.8$ , shown in Table 2 and Figure 2(a)) of our approach has an improvement from about 6% to 21 % at most in different settings of precision metrics, which shows the feasibility of this approach.
- Figure 2(b) also illustrates that by changing the setting of community loss weight coefficient γ, the ability of the model to sense more positive matching in a larger search space (higher k setting in precision), could be enhanced, which is an important improvement because many other papers only stress their performance at the k = 30 setting. However, adding too much weight to community loss may lead to a slight reduction of the ability to narrow the target to a finer scale (lower k in precision), compared with the γ = 0 setting.

# 5. Conclusion

In this paper, we aim to study the UIL problem by reusing the discarded knowledge in the original Online Social Network after network embedding. Not limited to anchor same users across networks, we would also like the community formed by close users to have a positive match across networks. This is because some users may have limited profile and it could be hard to distinguish them from others. However, in the context of a community, users share common features, and they will be driven to the correct direction where group of users with high similarity locates, even if community members are known little. This could also help to avoid overfitting the input data and increase the generalization ability of the method.

Therefore, we break down the main task into two simultaneously learned sub-tasks: User Mapping and Community Mapping, this is achieved by jointly optimizing the user loss and community loss in a single MLP model. Based on above theories, Community Sensing User Identity Linkage (CSUIL) is proposed. Results show that our approach outperforms current baseline models, and has the flexibility to adapt hyper-parameters for different needs or data input.

## Acknowledgments

This work was funded by JSPS KAKENHI JP16H01836, JP16K12428, and industrial collaborators.

- [Kong 13] Kong, X., Zhang, J., and Yu, P. S.: Inferring anchor links across multiple heterogeneous social networks, in *Proceedings of the 22nd ACM international conference on Information & Knowledge Management*, pp. 179– 188ACM (2013)
- [Liu 16] Liu, L., Cheung, W. K., Li, X., and Liao, L.: Aligning Users across Social Networks Using Network Embedding., in *IJCAI*, pp. 1774–1780 (2016)
- [Malhotra 12] Malhotra, A., Totti, L., Meira Jr, W., Kumaraguru, P., and Almeida, V.: Studying user footprints in different online social networks, in *Proceedings* of the 2012 International Conference on Advances in Social Networks Analysis and Mining (ASONAM 2012), pp. 1065–1070IEEE Computer Society (2012)
- [Man 16] Man, T., Shen, H., Liu, S., Jin, X., and Cheng, X.: Predict Anchor Links across Social Networks via an Embedding Approach., in *IJCAI*, Vol. 16, pp. 1823–1829 (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– 710ACM (2014)
- [Shu 17] Shu, K., Wang, S., Tang, J., Zafarani, R., and Liu, H.: User identity linkage across online social networks: A review, Acm Sigkdd Explorations Newsletter, Vol. 18, No. 2, pp. 5–17 (2017)
- [Zhang 15] Zhang, J. and Philip, S. Y.: Integrated Anchor and Social Link Predictions across Social Networks., in *IJCAI*, pp. 2125–2132 (2015)
- [Zhang 18] Zhang, J.: Social Network Fusion and Mining: A Survey, CoRR, Vol. abs/1804.09874, (2018)
- [Zhou 18] Zhou, F., Liu, L., Zhang, K., Trajcevski, G., Wu, J., and Zhong, T.: DeepLink: A Deep Learning Approach for User Identity Linkage, in *IEEE INFOCOM* 2018-IEEE Conference on Computer Communications, pp. 1313–1321IEEE (2018)

# Learning Sequential Behavior for Next-Item Prediction

Na Lu Yukio Ohsawa Teruaki Hayashi

Department of System Innovation, School of Engineering, The University of Tokyo

A more precise recommendation plays an essential role in e-commerce. Representation learning has attracted many attentions in recommendation field for describing local item relationships. In this paper, we utilize the item embedding method to learn item representations and user representations. Our methods compute cosine similarity of user vector and recommended item vectors to achieve the goal of personalized ranking. Experiment on real-world dataset shows that our model outperforms baseline model especially when the number of the recommended item is relatively small.

# 1. INTRODUCTION

The sharp growth of e-commerce and the using mobile electronic device require a more precise prediction of next item that users would probably like to purchase. Data mining of users' behaviors aims at finding useful patterns from a large database. In this task, understanding users' history and features are one of the most critical parts.

To deal with this task, some models were developed based on last transaction information, which is mostly involving Markov chains[Chen 12]. This method mainly makes use of users' sequential transaction data to predict what will be the next item considering the last transaction event. The advantages of this method are that it could consider the time sequence and recommend a proper item for the next movement. Other general recommendation models would consider users' past purchase behavior as a whole to generate their overall taste (or features) [Rendle 10]. This method could generally grasp a user's interests. The most widely used method of general recommendation models is called collaborative filtering. The advantages of this method are that it could get users' interesting points. Thus, the recommendation could generate from users' whole behavior. However, this method discards subsequent information that may lack preciseness in next-item prediction.

Here a good recommendation model could consider not only the sequential information but also users' overall taste. A hierarchical representation model was proposed to combine both sequential information and user history transaction information [Wang 15]. The proposed hierarchical representation model used a two-layer model. One-layer aggregated all the sequential transactions, and in the second layer, this sequential information was aggregated with the user's overall taste. Then the combined information was used to predict item in the next transaction. This method was novel by setting different layers to combine two kinds of information. However, a better method has been proposed to learn item representations.

Contact: Na Lu, The University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8656 Japan, Department of Systems Innovation, School of Engineering, The University of Tokyo, Bldg.No.8. 507, 080-1241-0956, luna@g.ecc.u-tokyo.ac.jp For understanding sequence data, we utilize the Skip-Gram model for word representation learning in natural language process field [Mikolov 13] named as word2vec. Skip-Gram model learns word representations by predicting the context of this word. More precisely, word2vec get a word vector in a lower dimensional space compared with one-hot representation. This method was later generalized as item2vec for learning item representations [Barkan 16]. Item2vec treats users' subsequent behavior as a sentence in word2vec and creates item vectors.

By learning users' sequential data to generate item representations, we proposed a method for aggregating users' history behavior and general taste to build a recommendation system.

# 2. RELATED WORKS

A good recommendation system could improve users' decision-making process in this information overload era. The widely used recommendation methods include collaborative filtering, content-based filtering, and hybrid filtering. Despite the use of traditional methods, many approaches are proposed to improve the quality of recommendations. We first review some related work in this field.

#### 2.1 Sequential Pattern Mining

Pattern mining is an essential branch of data mining, which consists of discovering frequent itemsets, associations, sub-graphs, sequential rules, etc. [Chen 96]. The target of sequential pattern mining is to detect sequential patterns by analyzing a set of sequential data, in which occurrence frequency is one of the target [Pei 04]. Item2vec embeds items into a low-dimensional representation by accounting the item co-occurrence in user records. That is, this model could generally capture the co-occurrence patterns of items in each transaction data.

#### 2.2 Personalized Ranking

From the target of the recommendation system, it can be treated as a rating prediction problem or a personalized ranking problem [Rendle 09]. The task of personalized ranking is to provide a user with a ranked list of items, which matches a real-life scenario. An example is that an online retailer wants to give a personalized ranking item list that a user may probably buy in the recent future. Former research for personalized ranking algorithms optimized through learning users' preferences on a set of items, which include BPR [Rendle 09], CliMF [Shi 12].

#### 2.3 Item Representation Learning

The word embedding method [Mikolov 13] have attracted much attention from fields besides NLP. The recommendation is also to utilize this method for better performance, including clustering [Barkan 16] and regression. Representation learning in recommendation means getting relationships between items from a specific data set, which is called item embedding. Barkan and Koenigstein [Barkan 16] first proposed Item2Vec model which based on a neural item embedding model for collaborative filtering. In this method, item embedding is used to learn a better item representation but fail to give a personalized ranking recommendation. In this research, we propose an item embedding based method combined with users' history behaviors to provide a personalized next-item recommendation.

# 3. PROBLEM STATEMENT

In this section, we first introduce the problem formalization of recommendation based sequence behavior. We then describe the item embedding and recommendation for the next item in detail. After that, we talk about the learning and prediction procedure of this method.

#### 3.1 Formalization

Let  $U = \{u_1, u_2, ..., u_{|U|}\}$  be a set of users and  $I = \{i_1, i_2, ..., i_{|I|}\}$  be a set of items, in which |U| and |I| denote to the total number of unique users and items, respectively. For each user u, the transaction history data  $T^u$  is given by  $T^u = (T_1^u, T_2^u, T_3^u, ..., T_t^u)$ , where  $T_t^u \subseteq I$ . The purchase history of all users is denoted as  $T = \{T^1, T^2, T^3, ..., T^t\}$ . Given the transaction data of all users, our task is to predict what the user will probably buy in the next time (eg. t-th), which is denoted as  $R = \{R^1, R^2, R^3, ..., R^u\}$ . Every  $R^i$  includes k items as recommendation:  $R^i = \{R_1^i, R_2^i, ..., R_k^i,\}$ . That is, we need to generate a personalized ranking  $R^i$  for user  $u_i$  in t-th transaction.

#### 3.2 Item2Vec algorithm

Our purpose is to learn a recommendation model from a sequential transaction data which could also combine users' overall taste. In this section, we first explain Item2Vec algorithms in detail, which generate item embedding from sequential data. Then users' general taste will be concluded from one user's whole transaction data. At last, item representations and users' general taste will be combined to create a personalized ranking for a next-item recommendation.

To proposed our method for personalized ranking from a sequential user transaction data, we first need to have a look at Item2Vec specifically. Skip-gram with negative sampling (SGNS) was first introduced in word embedding by Mikolov et al. [Mikolov 13]. The neural embedding in natural language processing attempts to map words and phrases into a vector space of low-dimensional semantics and syntax. Skip-gram uses the current word to predict its context words. The item collection in Item2vec is equivalent to the sequence of words in word2vec, that is, the sentence. Commodity pairs that appear in the same collection are considered positive. For the set  $w_1, w_2, ..., w_K$  objective function:

$$\frac{1}{K}\sum_{i=1}^{K}\sum_{j\neq i}^{K}\log(w_j|w_i) \tag{1}$$

Same as word2vec, using negative sampling, define  $p(w_j|w_j)$  as:

$$p(w_j|w_j) = \sigma(u_i^T v_j) \prod \sigma(-u_i^T v_k)$$
(2)

Finally, the SGD method is used to learn the max of the objective function and to obtain the embedding representation of each item. The cosine similarity between the two items is the similarity of items.

The cosine similarity between two vectors can be formalized as:

$$\cos(v_1, v_2) = \frac{v_1 \cdot v_2}{|v_1||v_2|} \tag{3}$$

### 3.3 Proposed method

From Item2Vec method, all users' transaction data  $T = \{T^1, T^2, T^3, ..., T^t\}$  is used to learn item representations. More specifically, Item2Vec algorithm inputs a large corpus of transactions and creates a vector space, in which every unique item is transformed as a vector in this space. Based on this, we produce item representations based on users' sequential transaction data.

The advantage of our methods is that we can introduce aggregation operations in forming user representations from their history transaction data. In this work, we propose two aggregation methods to get a user representation.

The first is average pooling. This method construct one vector by taking the average value from a set of vectors. Let  $V = \{v_1, v_2, v_3, ..., v_l\}$  be a set of vectors. Average pooling of V can be formalized as:

$$f_{ave}(V) = \frac{1}{l} \sum_{i=1}^{l} v_i \tag{4}$$

Second is max pooling. This method construct one vector by taking the max value from a set of vectors. Thus, max pooling can be formalized as:

$$f_{max}(V) = \begin{bmatrix} max(v_1[1] & \dots & v_l[1]) \\ max(v_1[2] & \dots & v_l[2]) \\ \dots & \dots & \dots \\ max(v_1[n] & \dots & v_l[n]) \end{bmatrix}$$
(5)

From a user's transaction data  $T^i$ , we can get a user representation  $\vec{u_i}$  from  $f_{ave}(T^i)$  and  $f_{max}(T^i)$  as  $u_{i\vec{ave}}$ and  $u_{i\vec{max}}$ . Combine with top-K recommendation from item embedding, which is  $R^i$ , we re-rank  $R^i$  based on the weighted similarity with user  $u_i$ . The detail of re-ranking of recommendation  $R^i$  is in Algorithm 1.

In this way, we can combine  $u_i$ 's general taste  $(\vec{u_{iave}} \text{ and } \vec{u_{imax}})$  and sequential prediction  $(R^i)$  to get a overall prediction.

Algorithm 1 Combination of user representation and top-K recommendation
Input: top-K recommendation R<sup>i</sup> for u<sub>i</sub>, user vector u<sub>iave</sub> and u<sub>imax</sub>, item set I
Output: R<sup>i</sup><sub>ave</sub> and R<sup>i</sup><sub>max</sub>
1: for j ≤ top - K \* 2 do

2: if  $R_j^i \subseteq I$  then 3:  $R_{ave-j}^i = cos(R_j^i, u_{iave})$  and  $R_{max-j}^i = cos(R_j^i, u_{imax})$ 4: else

- 5:  $test_size 1$
- 6: end if
- 7: end for
- 8: sort  $R^i_{ave}$  and  $R^i_{max}$  from highest to lowest, choose top-K items from  $R^i_{ave}$  and  $R^i_{max}$
- 9: return  $R^i_{ave}$  and  $R^i_{max}$

| Dataset name  | # users | # items | # T     |
|---------------|---------|---------|---------|
| Online Retail | 90,346  | 2553    | 397,923 |

Table 1: Basic Information about Online Retail dataset

# 4. EXPERIMENT AND DISCUS-SION

In this section, we conduct empirical experiments to test the effectiveness of our method for a next-item recommendation. We first introduce the experimental data set, the baseline methods in our experiments. Then we compare our approach with the baseline model to study the effect of different aggregations. Finally, we make some analysis on the result of the experiments.

#### 4.1 Dataset

We conduct our experiment on an open data set named 'Online Retail dataset' [UCI 15]. This data set includes transaction data from 2010.12.01 to 2011.12.09. Every row includes invoice number, product number, product name, sale quantity, sale time, unit price, customer ID, and customer's country. After deleting the row that has a default value, the data set basic information is in Table 1.

#### 4.2 Evaluation and Discussion

We divided the dataset into train data and test data. Train data was used to train item2vec model to generate the item representations. Test data was used to evaluate the effectiveness of our method.

In the test data, we first remove the last transaction data from user u. So the remaining is  $T_{n-1}^{u} = \{i_1, i_2, i_3, ..., i_{t-1}\}$ . We use the learned model and remaining  $T^{u}$  to make a recommendation of top-K items located closer to each item in the learned vector space. Then these top-K items and user vector derived from  $T_{n-1}^{u}$  are combined to make the final top-K recommendation.

Here we use Recall as the prediction evaluation. The recall is formalized as below:

$$Recall(T_t^u, R_t^u) = \frac{T_t^u \bigcap R_t^u}{T_t^u}$$

| Method<br>top-K | Ave    | Max    |
|-----------------|--------|--------|
| 1               | 14.98% | 20.25% |
| 3               | 6.41%  | 8.43%  |
| 5               | 8.95%  | 7.54%  |
| 10              | 4.57%  | 6.13%  |
| 15              | 1.47%  | 7.75%  |
| 20              | 3.37%  | 3.85%  |

Table 2: Recall percentage improvement compared with baseline method

In our experiment, we set top-K=1,3,5,10,15,20 as the number of items that would be recommended to user u. In this experiment, the baseline method is the prediction derived from the item2vec method, which was not combined with a user vector. The comparison of these methods are as follows.



Figure 1: The change of recall for three methods

We can see that the average model and max model could improve over 10% of recall compared with the baseline model. That means if we recommend one item for a user, our model performed well by aggregating user's vector and item2vec prediction. However, this improvement declined with the increase in top-K, which means if we recommend a lot of items to a user at one time, our improvement is not as effective as recommending fewer items. Compared with the baseline model, the recall of the average model and max model are higher, and they get higher with the increase of top-K. If we provide more items for a user, the probability of correct prediction will be higher, just as Figure 1 shows above.

# 5. CONCLUSION

Representation learning has attracted many attentions in recommendation field for describing local item relationships. In this paper, we utilize the item embedding method to learn item representations from sequential transaction data. And we also constructed user representations to get a ranked list of items for a user. The experiment result demonstrated that our proposed method for next-item recommendation outperformed baseline model in prediction recall. Specifically, our models get 14.98% and 20.25% improvement compared with baseline model in a top-1 recommendation, which means we get a distinct improvement when the number of the recommended item is relatively small.

# 6. ACKNOWLEDGEMENT

This work was funded by JSPS KAKENHI, JP16H01836, JP16K12428, and industrial collaborators.

# References

- [Chen 12] Chen, Shuo, et al. "Playlist prediction via metric embedding." Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2012.
- [Rendle 10] Rendle, Steffen, Christoph Freudenthaler, and Lars Schmidt-Thieme. "Factorizing personalized markov chains for next-basket recommendation." Proceedings of the 19th international conference on World wide web. ACM, 2010.
- [Wang 15] Wang, Pengfei, et al. "Learning hierarchical representation model for nextbasket recommendation." Proceedings of the 38th International ACM SIGIR conference on Research and Development in Information Retrieval. ACM, 2015.
- [Mikolov 13] Mikolov, Tomas, et al. "Distributed representations of words and phrases and their compositionality." Advances in neural information processing systems. 2013.
- [Barkan 16] Barkan, Oren, and Noam Koenigstein. "Item2vec: neural item embedding for collaborative filtering." Machine Learning for Signal Processing (MLSP), 2016 IEEE 26th International Workshop on. IEEE, 2016.
- [Chen 96] Chen, Ming-Syan, Jiawei Han, and Philip S. Yu. "Data mining: an overview from a database perspective." IEEE Transactions on Knowledge and data Engineering 8.6 (1996): 866-883.
- [Pei 04] Pei J, Han J, Mortazavi-Asl B, et al. Mining sequential patterns by pattern-growth: The prefixspan approach[J]. IEEE Transactions on Knowledge & Data Engineering, 2004 (11): 1424-1440.
- [Rendle 09] Rendle, Steffen, et al. "BPR: Bayesian personalized ranking from implicit feedback." Proceedings of the twenty-fifth conference on uncertainty in artificial intelligence. AUAI Press, 2009.
- [Shi 12] Shi, Yue, et al. "CLiMF: learning to maximize reciprocal rank with collaborative less-is-more filtering." Proceedings of the sixth ACM conference on Recommender systems. ACM, 2012.

[UCI 15] https://archive.ics.uci.edu/ml/datasets/Online+Retail

# Application of Unsupervised NMT Technique to Japanese–Chinese Machine Translation

Yuting Zhao<sup>\*1</sup> Longtu Zhang<sup>\*2</sup> Mamoru Komachi<sup>\*3</sup>

Tokyo Metropolitan University

Neural machine translation (NMT) often suffers in low-resource scenarios where sufficiently large-scale parallel corpora cannot be obtained. Therefore, a recent line of unsupervised NMT models based on monolingual corpus is emerging. In this work, we perform three sets of experiments that analyze the application of unsupervised NMT model in Japanese–Chinese machine translation. We report 30.13 BLEU points for ZH–JA and 23.42 BLEU points for JA–ZH.

# 1. Introduction

Neural machine translation (NMT) has recently shown impressive results thanks to the availability of large-scale parallel corpora [Bahdanau 14]. NMT models typically fit hundreds of millions of parameters to learn distributed representations which may generalize better when data is redundant. Unfortunately, finding massive amounts of parallel data remains challenging for vast majority of language pairs, especially for low-resource languages, as it may be too costly to manually produce or nonexistent. Conversely, monolingual data is much easier to find, and many languages with limited parallel data still possess significant amounts of monolingual data.

Recently, remarkable results have been shown in training NMT systems relying solely on monolingual data in the source and target languages by using an unsupervised approach [Artetxe 18, Lample 18a]. They proposed unsupervised NMT models that are effective on English–French and English–German. Following their practice, we try to apply unsupervised NMT model to Japanese–Chinese translation.

In this work, we perform experiments from two data domains. They are divided into two types of monolingual corpus and quasi-monolingual corpus. Among them, the best BLEU score can reach 30.13 of ZH–JA and 23.42 of JA–ZH with using ASPEC-JC (Japanese Chinese language pairs) parallel corpus [Nakazawa 16] in the quasi-monolingual setting.

# 2. System Architecture

The unsupervised NMT model [Lample 18b] we used is composed of two encoder-decoder models for source and target languages and in series with back-translation models. The encoders will encode monolingual sentences into latent representations for respective decoders. One decoder is used as a translator to decode the latent representations, and the other decoder perform the denoising effect of a language model on the target side that refines the latent representation of the source sentence. Then, it jointly train two back-translation models together with the two encoder-decoder language models. In the forward translation, the model generates data which will be trained to the backward translation and in the backward translation, the model trained from the generated target to the source generates translations. The generated sentences from backtranslation are added to the regular training set in order to regularize the model.

#### 3. Experiment

#### 3.1 Datasets

We prepare three data sets from ASPEC-JC (Japanese Chinese language pairs) parallel corpus [Nakazawa 16] and Wikipedia dump  $^{*1}$ .

For quasi-monolingual data, the Japanese–Chinese portion of ASPEC-JC was used. Note that although this is a parallel corpus, we shuffled it and used it monolingually. In this paper, we call it ASPEC-Quasi. Official training/development/testing split contains totally 670,000 Chinese and Japanese sentences for training and 2,000+ sentences for evaluating and testing.

For monolingual data, the Japanese–Chinese portion of ASPEC-JC was also used. Note that we shuffled it monolingually and divided the monolingual Chinese and Japanese data into the first half and the second half. Then, they were staggered and combined to form two groups of monolingual data sets with a size of 335,000, and one group was randomly selected for experiment. In this paper, we call it ASPEC-Mono. In addition, we created a Japanese–Chinese monolingual corpus with a training size of 10 million from Wikipedia articles. As above, evaluation and test data are all official data from ASPEC-JC.

#### 3.2 Preprocessing

Firstly, we tokenize Japanese and Chinese datasets separately. We use MeCab  $^{*2}$  with dictionary IPADic for Japanese and Jieba  $^{*3}$  with its default dictionary for Chinese. Secondly, we join the source and target monolingual corpora to learn fastBPE tokens with the vocabulary size of 30,000. Finally, we apply fastText [Bojanowski 17] on the

<sup>\*1</sup> https://dumps.wikimedia.org/

<sup>\*2</sup> http://taku910.github.io/mecab/

<sup>\*3</sup> https://github.com/fxsjy/jieba

Contact: Yuting Zhao, zhao-yuting@ed.tmu.ac.jp

| Corpora                 | Amount                | JA-ZH                | ZH-JA                |
|-------------------------|-----------------------|----------------------|----------------------|
| ASPEC-Mono<br>Wikipedia | 335,000<br>10,000,000 | 8.9<br>9.74          | 10.37<br>12.51       |
| ASPEC-Quasi             | 670,000               | <b>23.42</b> (31.19) | <b>30.13</b> (39.18) |

Table 1: BLEU scores of 3 datasets. (The BLEU score of OpenNMT model is presented in parentheses)

BPE tokens. This way, we obtain cross-lingual BPE embeddings for Chinese and Japanese language pairs to initialize lookup tables. More specifically, we use the skip-gram model with ten negative samples, a context window of 5 words, and 512 dimensions.

#### 3.3 Model

In this work, our models use transformer cells as basic units in the encoders and decoders with PyTorch toolkit version 0.5. We set the number of layers of both the encoders and decoders to 4, and the hidden layers is set to 512. Adam optimizer is used with a learning rate of 0.0001 and a batch size of 25. We set a maximum length of 175 tokens per sentence for each type of dataset and a dropout rate of 0.1. We also set random blank-out rate to 0.1 and word shuffle of 3.

BLEU score is used to evaluate translation in both directions with every iteration, and training will stop when the scores from the last 3 iteration did not improve any more.

#### 4. Results and Discussions

The BLEU scores obtained by all the tested datasets are reported in Table 1.

Amount of data. Firstly, we see the results obtained from the complete monolingual datasets ASPEC-Mono and Wikipedia. As our baseline, the results of ASPEC-Mono obtained 8.9 BLEU points for JA–ZH and 10.37 BLEU points for ZH–JA. As the amount of sentences increases from 335,000 to 10,000,000, the results of Wikipedia obtained 9.74 BLEU points for JA–ZH and 12.51 BLEU points for ZH–JA. Comparing with ASPEC-Mono, scores have gone up in both directions despite of domain difference.

Quasi-monolinguality. Secondly, we see the results in the last row, which is from ASPEC-Quasi corpus. It gets 23.42 BLEU points for JA–ZH and 30.13 BLEU points for ZH–JA. This result exceeds all the previous two results. Moreover, the OpenNMT model using ASPEC-JC parallel corpus reports 31.19 BLEU points for JA–ZH and 39.18 BLEU points for ZH–JA. In contrast, the BLEU score of unsupervised NMT is lower than that of supervised NMT, but the gap is not big.

# 5. Related Work

From the work of Sennrich et al. [Sennrich 16], they proposed a straightforward approach to create synthetic parallel training data by pairing monolingual training data with an automatic back-translation. Recently, Artetxe et al. [Artetxe 18] and Lample et al. [Lample 18a] have achieved substantial improvement for fully unsupervised machine translation. They leverage strong language models through training the sequence-to-sequence system as a denoising autoencoder.

# 6. Conclusion

Based on the above analysis, it can be inferred as follows:

- For monolingual data, the larger the data, the better the translation results.
- For quasi-monolingual data, the effectiveness of unsupervised NMT model on Japanese–Chinese is quite promising, even if it uses smaller training dataset.

From the experiment, we can see unsupervised NMT is effective in Japanese–Chinese machine translation. However, it is worth considering that why there is a huge gap between the results of using monolingual corpus and quasi-monolingual corpus on Japanese–Chinese unsupervised NMT. Even though the amount of monolingual Wikipedia corpus is 15 times more than that of ASPEC-Quasi corpus, the result is much worse. We hope to start from this significant gap and continue to study the factors affecting unsupervised NMT in Japanese–Chinese machine translation.

- [Artetxe 18] Artetxe, M., Labaka, G., Agirre, E., and Cho, K.: Unsupervised Neural Machine Translation, in *Proceedings of ICLR* (2018)
- [Bahdanau 14] Bahdanau, D., Cho, K., and Bengio, Y.: Neural Machine Translation by Jointly Learning to Align and Translate, in *Proceedings of ICLR* (2014)
- [Bojanowski 17] Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T.: Enriching word vectors with subword information, in *Proceedings of TACL*, pp. 135–146 (2017)
- [Lample 18a] Lample, G., Conneau, A., Denoyer, L., and Ranzato, M.: Unsupervised Machine Translation Using Monolingual Corpora Only, in *Proceedings of ICLR* (2018)
- [Lample 18b] Lample, G., Ott, M., Conneau, A., Denoyer, L., and Ranzato, M.: Phrase-Based & Neural Unsupervised Machine Translation, in *Proceedings of EMNLP*, pp. 5039–5049 (2018)
- [Nakazawa 16] Nakazawa, T., Yaguchi, M., Uchimoto, K., Utiyama, M., Sumita, E., Kurohashi, S., and Isahara, H.: ASPEC: Asian Scientific Paper Excerpt Corpus, in *Proceedings of LREC*, pp. 2204–2208 (2016)
- [Sennrich 16] Sennrich, R., Haddow, B., and Birch, A.: Improving Neural Machine Translation Models with Monolingual Data, in *Proceedings of ACL*, pp. 86–96 (2016)

# Synthetic and Distribution Method of Japanese Synthesized Population for Real-Scale Social Simulations

Tadahiko Murata<sup>\*1</sup>

\*1 Department of Informatics, Kansai University, Japan Takuya Harada<sup>\*2</sup>

# \*2 Research Institute for Socionetwork Strategies, Kansai University, Japan

In this paper, we describe how synthesized populations are essential in real-scale social simulations (RSSS), and the current situation of the population synthesis for whole populations in Japan. RSSS is simulations using the real number of populations or households in social simulations. This paper describes how we have completed to synthesize multiple sets of populations based on the statistics of each local government in Japanese national census in 2000, 2005, 2010 and 2015. We have started to distribute those multiple sets of the synthesized populations for researchers of RSSSs in Japan. In distributing the synthesized populations, we should protect personal or private information in the synthesized populations. We show some scheme how to protect them using a cloud service or secure computations.

# 1. Introduction

In this paper, we try to develop a platform for Real-Scale Social Simulation (RSSS) by synthesizing whole households in Japan and providing the data of synthesized households for researchers who try to develop RSSS tools. RSSS is simulations using populations or households in the real scale.

Recently social simulations have attracted from many researchers to tackle with problems in our environments or communities. One of the most influential social simulations is the segregation model proposed by **Schelling (1971)**. In his model, he clearly shows how segregations happen due to the preference of residents to be a neighbor of the same race or group. His model shows that segregations can happen even if there is no hostility among races. His model is quite interesting and meaningful to give understanding of conflict and cooperation. He was awarded the 2005 Novel Memorial Prize in Economic Science.

Although Schelling's model is quite significant, interpretation is required to apply his model to real situations. If we are able to directly conduct simulations with real-scale environments and real-scale residents, it is easy to draw insight from simulation results. That is why RSSS has much attention from many researchers recently.

In order to conduct RSSS, real-scale populations are required. For example, when **Murata & Konishi (2013)** optimized the number of polling places with considering the voting rate and the number of polling places in a city using a scheme of RSSS, they should synthesize the population in the city and measure the distance of polling places from their homes. When **Murata & Du (2015a)** assessed effects of the pension program for each household in Japan, they should create and simulate demographic movement of all prefectures in Japan for 25 or over 100 years according to the statistics of Japanese census conducted in 2010.

# 2. Synthetic reconstruction methods

Since RSSS researchers should face to synthesize populations in the target area of their social simulation sooner or later, we have synthesized populations using the available statistics in each local government such as city, town and village in Japan according to the national census in 2000, 2005, 2010 and 2015. The number of cities, towns and villages in Japan is 1741 in the national census in 2015).

Methods synthesizing populations with individual attributes are known as Synthetic Reconstruction method (SR method) (Wilson, 1976). Originally an SR method employs real samples from the real statistics. That method increases the number of individuals from the samples in order to fit the real statistics. Here, we prefer using the term "synthesize" to the term "reconstruct" in this paper. Since a reconstruction method is expected to generate exactly the same attributes of each individual in the population, however, it is impossible to reconstruct the same attributes from a small number of statistics. Therefore, we can only synthesize a population that has the same statistical characteristics using SR methods. Lenormand & Deffuan (2013) compared SR methods that employ samples with a synthetic method without samples. They showed the synthetic method without samples is better than the former one.

We employ a synthetic method without samples in this paper. The basis of our method is a method proposed by **Ikeda et al.** (2010). They proposed a method for synthesizing households of nine family types according to the nine real statistics using a simulated annealing method (Davis, 1987). Fig. 1 shows the nine



Fig. 1 Nine Family Types.

Tadahiko Murata; Address: Kansai University, 2-1-1, Ryozenji, Takatsuki, Osaka 569-1095, Japan; Phone: +81-72-690-2429, FAX; +81-72-690-2491; murata@kansai-u.ac.jp.



Maps is generated using the fundamental geospatial data of the GIA, Japan

Fig. 2 Households Projection on buildings.

family types they synthesized. 95% households in Japan come from these family types. Each family member has attributes of sex, age, kinship in its household. **Murata & Masui (2014, 2015b)** modified the objective function and a transition method in their simulated annealing method. Although their method (Ikeda, 2010; Murata, 2014, 2015b) can synthesize a population that has the same statistical characteristics with the real statistics, their method tried to synthesize a reduced population with only 500 or 1,000 households. The synthesized population is too small for social simulations in a real city, town or village.

In order to cope with the problems arisen in the reduced number of populations, we tried to synthesize exactly the same number of individuals in a target area such as states, counties, and prefectures using statistics of prefectures (Murata, 2016, 2017a). We first increased the number of real statistics for each family type and modified a transition method (Age-Changing method) in their SA method by considering role in a family (2016). We then proposed another transition method (Age-Swap method) in their SA method that keeps the distribution of the initial population that is fit to the real statistics (2017a). Agechanging method has a better performance in reducing the error when the number of transitions in an SA method is relatively small. On the other hand, Age-swap method can reduce better than Age-changing method when the number of transitions in an SA method is relatively large.

When we increase other attributes such as geographical characteristics (Harada, 2017) or occupation and income (Murata, 2017b) to the synthesized population, populations by local governments such as city, town or village are required (Murata, 2018). There are finer statistics that are statistics for each "basic unit block." The number of "basic unit blocks" in Japan is around 1.9 millions. A population synthesis method using statistics of "basic unit block" is proposed by Harada & Murata (2018). We have conducted population synthesis using the above algorithms with high performance computers in Osaka University. Fig. 2 shows an example of a household projection on buildings in a map of Japan. Each figure in a circle shows the number of households residing in the corresponding building.

Table 1 Distributed Synthetic Populations.

| Organization       | Synthesized Area       | Statistics           |  |
|--------------------|------------------------|----------------------|--|
| RTI International, | All states, USA        | 2010 US Decennial    |  |
| USA                | Population: 300        | Census               |  |
|                    | million                | 2007-2011 American   |  |
|                    |                        | Community Survey     |  |
| CDRC: Consumer     | England & Wales,       | 2011 UK Census       |  |
| Data Research      | UK                     |                      |  |
| Center, UK         | Population: $(53 + 3)$ |                      |  |
|                    | million                |                      |  |
| Kansai University, | Japan                  | 2000 National Census |  |
| Japan              | Population: 120        | 2005 National Census |  |
|                    | million                | 2010 National Census |  |
|                    |                        | 2015 National Census |  |

# 3. Synthesized Population Distribution

Using the above synthetic methods, we have generated synthesized populations for whole Japan. We are trying to prepare the database of synthesized populations using database. There are only two organizations that distributes synthetic populations in the national level in the world. **Table 1** shows the distributed synthesized populations. Those organizations distribute nation-wide populations of their country.

Although they are distributing only one set of synthesized populations, we have synthesized 10 sets of populations now. Since any methods synthesizes populations based on the limited number of statistics, there is no guarantee that the synthesized population is exactly the same as the real population. Therefore, RSSS should be conducted on several sets of populations and find common outcome from the simulations, or a unique outcome among them. When we find a common result, it seems to be obtained from any populations with the same statistical characteristics of the real population. When we find some unique result, we should carefully see how the obtained result is caused. In order to conduct such multiple simulations, we distribute several sets of populations.

We are distributing synthetic populations with the following notations.

- 1) The synthetic populations do not contain any data of the real households and individuals.
- The synthetic populations contain only the same statistical characteristics of the real households and individuals.
- 3) The synthetic populations do not contain any statistical characteristics that are not used in the synthetic process.
- The synthetic population will be updated when latest statistics become available.
- Simulations or analysis using the synthetic populations should be conducted on multiple sets of populations.
- 6) Outcomes of simulations and analysis should NOT be released any personal or private information that is relating to real households or individuals.

Although synthesized populations are not real populations, residents may consider that their privacy is offended by releasing

their personal information such as their occupations, income or educational back grounds. Therefore, we require researchers to conduct their simulations or analysis using multiple sets of synthesized populations in Item 5). We also require researchers not to release outcomes of their simulations or analysis in any forms that enables others to identify or estimate a private information in a certain household.

# 4. Further Challenges for Data Protection

In order to protect the personal or private information in the synthesized populations, we are planning to employ a cloud service that enables simulations using the synthesized populations. By employing a cloud-style service, we do not have to distribute the synthesized data themselves to researchers but allow them to access the synthesized data in their RSSSs. In order to realize such an interface for accessing the synthesized populations, we should develop online programming tools for utilizing the synthetic populations in simulations or analysis.

Another way to protect personal information is to employ secure computation (Chida, 2014). The secure computation enables users to utilize sensitive data without allowing them to see exact values of them.

## 5. Conclusion

In this paper, we show the current status of population synthesis of whole populations in Japan. We have developed multiple sets of synthesized populations with the same statistical characteristics of the real populations in Japan. In synthesizing the populations, we utilized the statistics conducted in 2000, 2005, 2010, and 2015. After synthesizing the populations with sex, age, kinship in their household, we are increasing attributes of each individual such as geospatial data, occupation, and income. We hope enriching such synthesized population will help researchers who try to develop real-scale social simulations or analyze micro data to see characteristics of our communities or environments.

#### Acknowledgement

Part of this research is funded by Foundation for the Fusion of Science and Technology in 2017, JSPS KAKENHI 17K03669 in 2017, and Tateishi Science and Technology Foundation in 2018. Synthesized populations are generated using the large-scale computing systems (VCC) of Cybermedia Center, Osaka University.

## References

- [Chida, 2014] K. Chida, G. Morohashi, H. Fuji, F. Magata, A. Fujimura, K. Hamada, D. Ikarashi, R. Yamamoto, Implementation and evaluation of an efficient secure computation system using 'R' for healthcare statistics, J. of the American Medical Informatics Association, Vol. 21, Is. e2, pp. 326-331, 2014.
- [Davis, 1987] L. Davies: Genetic algorithms and simulated annealing; Research Notes in Artificial Intelligence, Los Altos, CA: Morgan Kaufumann, 1987.
- [Harada, 2017] T. Harada, T. Murata, Projecting household of synthetic population on buildings using fundamental

geospatial data, SICE Journal of Control, Measurement, and System Integration, Vol. 10, No. 6, pp. 505-512, 2017.

- [Harada, 2018] T. Harada, T. Murata, Geospatial data additional method using basic unit blocks, Proc. of SICE Symposium on Systems and Information 2018, 6 pages, 2018 (in Japanese).
- [Ikeda, 2010] K. Ikeda, H. Kita, M. Susukita, Estimation method of individual data or regional demographic simulations, Proc. of SICE 43rd Technical Com. on System Engineer, pp. 11-14, 2010 (in Japanese).
- [Lenormand, 2013] M. Lenormand, G. Deffuant, Generating a synthetic population of individuals in households: Sample free vs sample-based methods, Journal of Artificial Societies and Social Simulation, vol. 16, no. 4, pp. 1-9, 2013.
- [Murata, 2013] T. Murata, K. Konishi, Making a Practical Policy Proposal for Polling Place Assignment Using Voting Simulation Tool, SICE Journal of Control, Measurement, and System Integration, Vol. 6, No. 2, pp. 124-130, 2013.
- [Murata, 2014] T. Murata and D. Masui, "Estimating agents' attributes using simulated annealing from statistics to realize social awareness", Proc. of 2014 IEEE Int'l Conf. on System, Man & Cybernetics, pp. 717-722, 2014.
- [Murata, 2015a] T. Murata, N. Du, Comparing income replacement rate by prefecture in Japanese pension system, Advances in Social Simulation, pp. 95-108, 2015.
- [Murata, 2015b] T. Murata and D. Masui, "A two-fold simulated annealing to reconstruct household composition from statistics", Proc. of 2015 IEEE Int'l Conf. on System, Man & Cybernetics, pp. 1133-1138, 2015.
- [Murata, 2016] T. Murata, T. Harada, D. Masui, Modified SAbased household reconstruction from statistics for agentbased social simulations", Proc. of 2016 IEEE Int'l Conf. on Systems, Man, & Cybernetics, pp. 3600-3605, 2016.
- [Murata, 2017a] T. Murata, T. Harada, D. Masui, Comparing transition procedures in modified simulated-annealing-based synthetic reconstruction method without samples, SICE Journal of Control, Measurement, and System Integration, vol. 10, no. 6, pp. 513-519, 2017.
- [Murata, 2017b] T. Murata, S. Sugiura, T. Harada, Income allocation to each worker in synthetic populations using basic survey on wage structure, Proc. of 2017 IEEE Symposium Series on Computational Intelligence, pp. 471-476, 2017.
- [Murata, 2018] T. Murata, T. Harada, Synthetic method for population of a prefecture using statistics of local governments, Proc. of 2018 IEEE Int'l Conf. on Systems, Man, & Cybernetics, pp. 1171-1176, 2018.
- [Schelling, 1971] T. Schelling, "Dynamic models of segregation, Journal of Mathematical Sociology, Vol. 1, pp. 143-186, 1971.
- [Wilson, 1976] A. G. Wilson, C. E. Pownall, A new representation of the urban system for modeling and for the study of micro-level interdependence, Area, vol.8, no. 4, pp. 246-254, 1976.

International Session | International Session | [ES] E-3 Agents

# [3H3-E-3] Agents: safe and cooperative society

Chair: Ahmed Moustafa (Nagoya Institute of Technology), Reviewer: Takayuki Ito (Nagoya Institute of Technology)

Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room H (303+304 Small meeting rooms)

# [3H3-E-3-01] An Autonomous Cooperative Randomization Approach to Prevent Attacks Based on Traffic Trends in the Communication Destination Anonymization Problem

OKeita Sugiyama<sup>1</sup>, Naoki Fukuta<sup>1</sup> (1. Shizuoka University) 1:50 PM - 2:10 PM

# [3H3-E-3-02] Cooperation Model for Improving Scalability of the Multi-Blockchains System

OKeyang Liu<sup>1</sup>, Yukio Ohsawa<sup>1</sup>, Teruaki Hayashi<sup>1</sup> (1. University of Tokyo, Graduate school of engineer)

2:10 PM - 2:30 PM

# [3H3-E-3-03] Effect of Visible Meta-Rewards on Consumer Generated Media OFujio Toriumi<sup>1</sup>, Hitoshi Yamamoto<sup>2</sup>, Isamu Okada<sup>3</sup> (1. The University of Tokyo, 2. Rissho

University, 3. Soka University)

2:30 PM - 2:50 PM

[3H3-E-3-04] Toward machine learning-based facilitation for online discussion in crowd-scale deliberation

OChunsheng Yang<sup>1</sup>, Takayuki Ito<sup>2</sup>, Wen GU<sup>2</sup> (1. National Research Council Canada, 2. Nagoya Institute of Technology)

2:50 PM - 3:10 PM

# [3H3-E-3-05] An automated privacy information detection approach for protecting individual online social network users

OWeihua Li<sup>1</sup>, Jiaqi Wu<sup>1</sup>, Quan Bai<sup>2</sup> (1. Auckland University of Technology, 2. University of Tasmania)

3:10 PM - 3:30 PM

# An Autonomous Cooperative Randomization Approach to Prevent Attacks Based on Traffic Trends in the Communication Destination Anonymization Problem

Keita Sugiyama<sup>\*1</sup> Naoki Fukuta<sup>\*2</sup>

\*<sup>1</sup> Faculty of Informatics, Shizuoka University
 \*<sup>2</sup> College of Informatics, Academic Institute, Shizuoka University

The communication destination anonymization problem is one of the problems to be resolved under some trade-offs in the cyber security field. Several approaches have been proposed for the communication destination anonymization problem such as Wang's U-TRI. However, due to the trade-offs that the user cannot take too expensive costs to make the network performance improved while keeping its security level, there remains the issues to make anonymization even over a short period of time while giving a good throughput. In this paper, we present an overview of the approach to solve this issue by introducing autonomously coordinating multiple end-hosts and a simulation environment to analyze it.

# 1. Introduction

When defending facilities with the camera network or patrolling ponds for avoiding illegal disposals by drones, the networks constituting them also need to be protected at the same time in order to operate them properly. It is mentioned that the anonymity of communication destination in such network is often implemented for this purpose [Wang 17]. U-TRI [Wang 17] has been proposed by Wang et al as one of the approaches for that purpose. However, it is mentioned that U-TRI still suffers from an issue when attackers are allowed to utilize their observed traffic trends [Wang 17]. In this paper, we present an overview of the approach to solve this issue by introducing autonomously coordinating multiple end-hosts and a simulation environment to analyze it.

## 2. Background and Related Work

## 2.1 Communication Destination Anonymization

It is one of the security problems on enterprise local networks that attackers are able to gather intelligence such as which end-hosts are online and which end-hosts are important by sniffing traffic in the networks. In order to prevent this problem, identifiers appear in network traffic need to be anonymized. PHEAR [Skowyra 16] and U-TRI [Wang 17] are methods to anonymize addresses in the local network. U-TRI implement anonymity by updating identifiers representing the communication destination and source in VIRO, which is a method of efficiently routing packets using the Software Defined Network, at random intervals based on idea of Moving Target Defense [Jajodia 11].

#### 2.2 Attacks Based on Traffic Trends

As mentioned in the original Wang's U-TRI paper [Wang 17], U-TRI leaves the problem to allow attackers to attack based on traffic trends. Although the detail is not clearly mentioned there, the following cases can happen. For example, on the system where multiple clients are managed by a server, it is expected that packets whose destination address or source address is the address of the server appear frequently since multiple clients communicate with the server. In such a case, even if the address of each end-host is updated in a certain period, it is not difficult for the attacker to identify the address of the server by investigating the appearance situation of the address in a shorter period than the address-update interval. The primary factor of that is that, U-TRI implements anonymity in the medium to long term, but anonymity is not implemented in the short term. It is possible to make that hard by making the address-update interval very short for the purpose of implementing anonymity. However, shortening the addressupdate interval disorderly is not a practical solution since it is expected that the network performance will be greatly impaired by increasing the packet loss rate.

In this way, U-TRI leaves the possibility of traffic analysis utilizing the fact that it is difficult to implement shortterm communication destination anonymity and that the tendency of traffic tends to be biased due to the nature of the system. In this paper, we will proceed with the necessary discussion to propose a method to effectively implement short-term anonymity.

# 3. Overview of Proposed Approach

The aim of our proposed approach is to implement a short-term anonymity in consideration of the trade-offs with the network performance while implementing the communication destination anonymity in the medium to long term like the U-TRI does. In addition, it is also required to

Contact: Keita Sugiyama, Faculty of Informatics, Shizuoka University, 3-5-1 Johoku, Naka-ku, Hamamatsu-shi, Shizuoka 432-8011 Japan, cs15050@s.inf.shizuoka.ac.jp

|   | Address                      | The First<br>Observed<br>Time | The Last<br>Observed<br>Time |
|---|------------------------------|-------------------------------|------------------------------|
| 1 | f0:00:38:4e:8f:29            | 00:00:12                      | 00:08:12                     |
| 2 | <del>5e:11:59:50:df:30</del> | 00:00:12                      | 00:04:12                     |
| 3 | <del>ef:fe:27:b7:3d:10</del> | 00:04:12                      | 00:08:12                     |
| 4 | <del>a0:50:88:8a:5f:33</del> | 00:08:12                      | 00:12:12                     |
| 5 | bf:2c:f8:9d:db:48            | 00:08:12                      | 00:13:30                     |
| 6 | be:9a:70:5b:9f:54            | 00:12:12                      | 00:13:30                     |

Figure 1: The recently updated addresses estimated by the attacker.

change the strategy automatically and autonomously in consideration of the current traffic trends since network traffic changes over time.

Regarding the former requirement, the approach that each end-host determines the address-update frequency according to its own importance level is considered as one of the ways of satisfying the requirements.

Regarding the latter requirement, the approach that each end-host determines the address-update frequency according to its own packet transmission/reception status and packet loss is considered as one of the methods satisfying the requirements.

Therefore, it is possible for each end-host to determine its own address-update frequency in consideration of its own importance level, packet transmission/reception status, and its potential or current level of packet losses. Here, an issue is found using this approach. The issue of this approach is that the attackers are able to predict the most recently updated address, that is, the address likely to be the address pointing to the end-host whose address is being updated frequently, by excluding addresses that have not been observed for a long time and addresses that have been observed for a long time among the observed addresses. Figure 2 shows how an attacker predicts the most recently updated address from the observed addresses. Entries 1 to 4 are the addresses that have not been observed for a long period of time. Entry 5 is an address that is being observed for a long period of time. The attacker predicts that entry 6 is the address that was most recently updated.

In this way, it becomes an issue when attackers are able to gain much profit by attacking the end-host with high frequency of address-updates if the address-update frequency can be predicted by attackers. In order to solve this issue, we also require the ability that allows each end-host to cooperate with other end-hosts for giving attackers uncertainty about their own importance level.

# 4. Calculation of Attack-Success Rate by Simulator

In this work, we are preparing a prototype simulator to evaluate effectiveness our approach. The prototype of simulator has a mechanism to analyze the differences among the original U-TRI and our approach regarding their abilities to prevent an attack which utilizes its poor implementation of anonymity of communication destination (Attacker



Figure 2: Attack-success rate of each attacker against the address-update interval of the server. The number of end-hosts except for the server = 6, the address-update interval of end-host except for the server = 2000 [steps].

A) and an attack which predicts an end-host whose update frequency of the addresses is high (Attacker B).

On a situation with a network which has one server and six cameras where each camera communicates with the server, we analyze the attack-success rate of each attacker in the case where the attack-success condition is to attack the server. Figure 2 shows the results on that condition. It shows the attack-success rate when only the address-update interval of the server is changed while the address-update interval of end-hosts are fixed except for the server.

# 5. Conclusion

In this paper, we presented an overview of the approach to prevent attacks based on the traffic trends which is unavoidable in the original U-TRI, which provides the communication destination anonymization problem in the cyber security field by autonomously coordinating multiple endhosts. In addition, we presented a prototype simulator to analyze differences among the original U-TRI and our approach.

- [Jain 11] Jain, S., Chen, Y., and Zhang, Z.-L.: VIRO: A scalable, robust and namespace independent virtual Id routing for future networks, 2011 Proceedings IEEE IN-FOCOM, pp. 2381–2389 (2011)
- [Jajodia 11] Jajodia, S., Ghosh, A. K., Swarup, V., Wang, C., and Wang, X. S.: Moving Target Defense: Creating Asymmetric Uncertainty for Cyber Threats, Springer Publishing Company, Incorporated (2011)
- [Skowyra 16] Skowyra, R., Bauer, K., Dedhia, V., and Okhravi, H.: Have No PHEAR: Networks Without Identifiers, in *Proceedings of the 2016 ACM Workshop on Moving Target Defense*, pp. 3–14 (2016)
- [Wang 17] Wang, Y., Chen, Q., Yi, J., and Guo, J.: U-TRI: Unlinkability Through Random Identifier for SDN Network, in *Proceedings of the 2017 Workshop on Moving Target Defense*, pp. 3–15 (2017)

# Cooperation Model for Improving Scalability of the Multi-Blockchains System

Liu Keyang Ohsawa Yukio Teruaki Hayashi

Department of System Innovation, Graduate School of Engineering, The University of Tokyo

Scalability is an open question of the blockchain. Ongoing solutions, like Sharding and Side-chain, try to solve it within an independent blockchain system. We propose a cooperation model by constructing a system of multiple blockchains. In this model, secure cross chain operations can help to handle more requests. The gossip channel can help to refresh the states of other blockchains. Through manage interactions among blockchain systems, this model can limit their misbehaviors and improve scalability.

# 1. INTRODUCTION

Blockchain, a solution to decentralized systems, can solve problems in fields like finance[Eyal 2017], supply chain[Abeyratne 2016], crowdsourcing [Li 2018]. Currently, blockchain can provide two functions. First, a blockchain can work as a securely distributed ledger[Ren 2018]. Second, a blockchain can provide a reliable distributed calculating platform. By using smart contracts[Underwood 2016], all participants can execute functions correctly and give the same output.

Generally, a decentralized system is more robust and trusted than a centralized system. However, the scalability is its weakness. Scalability problem is the long latencies or superfluous messages caused by growing participants. Usually, it is a result of the consensus algorithm[Karame 2016]. Many solutions try to solve this problem within a blockchain system. Sidechain shifts some assets into a sidechain to realize faster responses[Back 2014]. Sharding technology tries to split participants into several shardings for parallel processing[Luu 2016]. All these works sacrifice security or consistency for the efficient responses.

This work tries to solve the scalability problem through cooperative problem-solving. In this model, each blockchain system is an independent agent. The contributions of this work are 1. A protocol for delivery versus payment(DVP) problem. 2. The framework of Blockchain's cooperation model.

# 2. RELATED WORKS

Sharding is an exciting idea that split blockchain into several shardings so they can handle requests simultaneously. This idea shares some similarity with multiple blockchains system. Elastico[Luu 2016] and Rapid chain[Zamani 2018] are some great implementations of this solution. In these systems, the randomness of each sharding limits the possibility of collusion and planned attacks. However, they give up security or consistency to some degree. To solve this problem, we propose a framework to weaken secure assumptions of each blockchain. By considering possible attack happens, this work focus on limiting the effect of attacks. Hence, our model allows more sacrificing of security on individual blockchain while providing better services.

Chen et al[Chen 2017] and Kan et al[Kan 2018] had finished some works about the communication between different blockchains. They simulate Internet stack and TCP protocol to create the Inter blockchain communication protocol. Although these methods are functional, they are also fragile to malicious attacks. Besides, they ignored the achievements of the consensus algorithm which is very useful in DVP problem. This work will consider the case that some blockchains are controlled or created by attackers. We can prove that these attacks cannot affect other blockchains.

# 3. PROBLEM MODEL

This part will clarify assumptions and notations of this model. First, N = 1, 2, ...n represents the set of agents. Each agent *i* is a distributed network that maintains one blockchain  $B_i[]$  with all terminated blocks list linearly. The participants of each agent run the consensus algorithm to maintain the blockchain and provide their services to users. Terminated block means at least  $f_i > 0.5$  participants have confirmed and stored the block.  $f_i$  is the parameter of each agent's consensus algorithm.

Second, all block contents two parts: header and body. A header contains at least the hash of the previous Block, metadata of the body, and signatures of the creator. For convenience, all blockchains' contents, like transactions or Key-Value pair, is unified under an abstracted class – log. Each agent should support two operations: verify and  $check_i$ . verify(log, h) will return the validity of one log before the  $h^{th}$  block  $B_i[h]$  according to the rule of the blockchain. Taking a Bitcoin's transaction as an example, input should be a subset of unspent transaction output (UTXO), and the sum of inputs should be larger than the sum of outputs.  $check_i(log)$  returns the position of one log in  $B_i$ . It will return -1 when it does not exist. Hence, the

Contact: Liu Keyang, University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo 113-8656 Japan, Department of Systems Innovation, School of Engineering, The University of Tokyo, Bldg.No.8. 507, 070-4336-1780, stephenkobylky@gmail.com

following property held:

- a.(Validity)  $\forall h > 0$  and  $log \in B_i[h]$ ,  $verify_i(log, T) =$ True for T < h and  $verify_i(log, T) = False$  for T > h.
- b.(Agreement) If  $check_i(log) == True$ , log can be accessed from at least  $f_i$  part of participants in agent i.

Third, we assume adding one legal log into a blockchain consume resources for all agents. Under this condition, cross chain operation becomes a DVP problem. Off-line cost's DVP problem is the job of exchanges. This work focus on the online DVP problem between two agents. Cooperation model will guarantee the payment's validity stick to the delivery of goods.

Last, we allow an agent itself can work improperly or attack some other agents. Since an agent can work independently, agents need some mechanism to control the effect of attacks. One naive way is creating a higher layer blockchain among different agents so it can be byzantine fault tolerate. This work uses another lightweight method. We create an externality of each cross-chain operation without affecting other agents. However, these externalities can prove the existence of misbehavior and punish the agent by detaching it from the network.

#### COOPERATION MODEL **4**.

This section includes the detail of the cooperation model. To begin with, we defined two extended functions for each participant of agents in our model.

#### 4.1 **Extended** operation

Define a condition log clog1 = log1||log2||j||h1||h2 represents log1 is a cross chain operation related to log2 in agent j. The expiration height for a condition log is h1and  $h_2$  in agent *i* and *j*. All participants of agents maintain a waiting list(WL) for cross chain log and condition log. WL supports a function condcheck(). When clog1 and log1 are stored together in WL, condcheck(log1) = clogand condcheck(clog1) = log1. In other cases, it returns the existence of input log in WL.

Next, we need to define the extended function  $checkEX_i(log1)$ . Let  $checkEX_i(log1) = -1$  if condcheck(log1) = True.If condcheck(log1) = clog1,  $checkEX_i(log1)$ =  $check_i(clog1).$ In other cases,  $checkEX_i(log1) = check_i(log1)$ .  $checkEX_i(clog1) =$  $check_i(clog1)$ 

Then, we define function verify Ex(log, h) in algorithm 1.

#### 4.2 Workflow

By using previous notations, the operations to WL are following:

• When the new terminated block contains a condition log *cloq1*, all participants add *cloq1* and *loq1* into their WL.

#### Algorithm 1 verifyEx Input: log1 or clog1, h Output: True or False 1: if Input is normal log then if condcheck(log1)! = clog1 then 2: **return** verify(log1, h)3: 4: else $checkEX_i(clog1)$ 5: return $\geq$ $checkEX_i(log_1) < 0 \& checkEX_i(clog_2) \geq 0$ & verify(log1, h)end if 6:

0 &

7: else if condcheck(clog)! = False then

return False 8:

9: else

10: return  $h < h_1 \& verify(log1, h)$ 

11: end if

• Expire: When  $B_i[h1]$  is terminated clog1 is removed from WL. When  $check EX_j(log 2) \geq 0$  and  $checkEX_i(log1) \ge 0$  log1 and clog1 is removed.

the workflow of cross chain operations are following:

- 1. Register: A user submits *clog1* to one participant. Participants check  $verify EX_i(clog1, h_t)$  where  $h_t$  is the current height of blockchain  $B_i$ . If it returns True, commit clog1 to next block.
- 2. Condition-commit: If the newest terminated Blocks contain *clog1*, all participants add *clog1* and *log1* to their WL.
- 3. Pre-commit: User submits log1 to one participant. The participant checks  $verify EX_i(log1, h)$ . If it is true, commit log1 to next block.
- When the height of blockchain • 4. Commit: reaches h1, participant check  $checkEX_i(log1)$  and  $checkEX_i(log2)$  to determine whether to expire clog1.

The workflow of a success cross chain operation looks like Figure 1.

Till now, we have clarified main steps of a cross chain operation. The final step is to broadcast the latest view, like the hash of last terminated block header, of both agents. One agent can use a gossip channel to notify other agents of updating. This gossip is not necessary to be received or confirmed. However, an agent can reveal a fork by identifying an unmatched view of one agent.

#### 4.3 Communication rule

In the cooperation model, each blockchain is an agent to act. Hence, verifying the status of one agent demands sufficient supports from its participants. Due to the property of agreement, secure connection with one agent i anchors to the parameter  $f_i$ . For a given possibility p, the required confirmations  $m_i$  should satisfied  $(1 - f_i)^{m_i} < p$ . Hence,  $m_i \geq \frac{p}{\ln(1-f_i)}.$ 

A secure communication requires enough participants of agent i asks for  $m_j$  confirmations from agent j independently. The communication cost is  $O(m_i * m_j)$  per time.



Figure 1: The work flow of one cross chain operation.

An efficient way is to select some proxies to do this communicate. Once selected proxies confirmed  $checkEX_j()$ , they can spread the gossip information among agent *i*. Under this method, the cost is  $O(m_i)$ . For preventing collusion, participants should randomly select proxies.

# 5. ANALYSIS AND EXPERIMENT

#### 5.1 Function analysis

To view other possible situations of this protocol, we can consider the states of WL. WL can allow three statues:1. Null,2. *clog1* and *log1*, 3. *log1*. Table 1 shows the result of VerifyEX and CheckEX, where the condition is the 3rd line in Algorithm 1. When a user submits *clog1*, only case 1 and case 3 can continue. Case 3 means new condition log is a supplement to an expired one which jumps to the final stage. When a user submits *log1* at case 3, participants can detect that it is a rejected log. As a result, on one can admit a existed cross chain operation *log1* without satisfying a condition *clog1*. This is the cost of agreement in a blockchain.

Assumes log' is conflicted with log1, which indicates the terminated blockchain can only contain one of them. The condition for committing log',  $checkEX_i(log1)$  should be less than 0. Since termination requires admissions of at least half of all participants, they can exclude the possibility of conflicts within the blockchain. Once a terminated block contains log', it is impossible to activate log1 in case 3 any more. The reason is clog1 is also conflicted with log'.

| WL<br>Func     | Null  | Clog&log                                    | log   |
|----------------|---|---|---|
| VerifyEX(clog) | Verify(Log)                                 | False                                       | Verify(Log)                                 |
| CheckEX(clog)  | $\operatorname{check}(\operatorname{clog})$ | $\operatorname{check}(\operatorname{clog})$ | $\operatorname{check}(\operatorname{clog})$ |
| VerifyEX(log)  | Verify(Log)                                 | condition                                   | Verify(Log)                                 |
| CheckEX(log)   | $\operatorname{check}(\log)$                | $\operatorname{check}(\operatorname{clog})$ | -1  |

Table 1: Result of VerifyEX(ignore h) and CheckEX

Hence, by using the property of Blockchain, this protocol can solve the DVP problem of cross chain operations.

#### 5.2 Security analysis

This part provides some brief proofs of security. Generally, there are two types of attacks: agent's misbehaviors and communication attacks. During the protocol, the only information needed about other agent is function checkEXwhich affect by WL and terminated blocks. Hence, Adjusting can detect the counterfeit WL and  $B_i$ . Once attacker Eve controls the agent j, j can reply to other agents arbitrary and support any cross-chain operations. After completing a cross chain operation, Eve can create a fork to repeal the existed log. In this case, agents that received the previous view of j will anchor to the elder branch and reject new branch inherit the identity of j. The network will wait for j recovering the former branch and continue its services. Here, the gossip channel creates an externality of an agent so that it cannot change its termination within the network. The higher rate to verify gossip, the higher termination the model can propose.

Besides, there are some network attacks like Sybil attacks and DDOS attack among agents. Sybil attack means the attacker create several agents in the model to arrange attacks. However, these bot agents need to spend enough resources to convince users of other agents for one round attack. Hence, this attack is not profitable if users can manage their risk. Another way is isolating one agent like Man in the Middle(MITM) attack to block gossips. This attack is very costly when the target is a distributed network. A fixed and reliable channels can also resolve this attack. In a word, the resilience against manufactured identities depends on the value of each agent. Lastly, DDOS attacks also worth considering. Attackers can attack waiting list by creating many useless conditional logs. The solution can be charging an additional fee for registering cross chain operation. Indeed, cross chain operations require extra payment for stronger termination and complex procedures. The most significant problem relates to the gossip channel where redundancy informs can block useful gossip. Hence, the gossip channel needs some rule for filtering. Agents can require a signature for each message, limit frequency of source agents, create some periodical routes.

#### 5.3 Experiment

This work intended to improve the scalability of one agent through cross chain operation. The experiment evaluated the average latency and gossip burden for different rates of cross chain operations in the worst case. Latency is evaluated by the number of blocks for solving same amount of requests. Gossip represents the number of message sent in gossip channel when discard rate is 0.5. The result(Figure 2) shows a linear growth of latency with inter log rate and stable average gossip message related to the number of agents. The increasing of latency relates to the size of condition logs. In the experiment, we assume condition log spending double space compare to other logs.



Figure 2: Average latency and gossip according to cross operation rate when transactions terminate immediately. The first picture shows the number of gossips is square to the system's scale. The second picture shows the system do not accumulate gossips or latency as time goes by.

# 6. CONCLUSION

This work proposes a cooperation model for improving scalability. Under the cooperation model, cross chain operation can create externality of each agent and spread it through gossip channel. The termination of one agent can partly rely on other agents and agent can pay more attention to achieve agreements. On the other hand, cross chain operation extends the ability of one agent and allow a more flexible exchange between different digital assets. We can still optimize this work in many ways. Condition log and gossip message can be compressed to reduce latency and burden of gossip channel. A gossip checking protocol can detect forks faster. The future works will focus on the consensus design under the cooperation model and optimization of gossip channel and related protocols.

# 7. ACKNOWLEDGMENT

This work was funded by JSPS KAKENHI, JP16H01836, JP16K12428, and industrial collaborators.

- [Eyal 2017] Eyal I. Blockchain technology: Transforming libertarian cryptocurrency dreams to finance and banking realities[J]. Computer, 2017, 50(9): 38-49.
- [Abeyratne 2016] Abeyratne S A, Monfared R P. Blockchain ready manufacturing supply chain using distributed ledger[J]. 2016.
- [Li 2018] Li M, Weng J, Yang A, et al. Crowdbc: A blockchain-based decentralized framework for crowdsourcing[J]. IEEE Transactions on Parallel and Distributed Systems, 2018.
- [Karame 2016] Karame G. On the security and scalability of bitcoin's blockchain[C]//Proceedings of the 2016 ACM SIGSAC Conference on Computer and Communications Security. ACM, 2016: 1861-1862.
- [Back 2014] Back A, Corallo M, Dashjr L, et al. Enabling blockchain innovations with pegged sidechains[J]. URL: http://www. opensciencereview. com/papers/123/enablingblockchain-innovationswith-pegged-sidechains, 2014.
- [Luu 2016] Luu L, Narayanan V, Zheng С, et protocol А secure sharding for al. open blockchains[C]//Proceedings of the 2016 ACM SIGSAC Conference on Computer and Communications Security. ACM, 2016: 17-30
- [Ren 2018] Ren Z, Cong K, Aerts T, et al. A scale-out blockchain for value transfer with spontaneous sharding[C]//2018 Crypto Valley Conference on Blockchain Technology (CVCBT). IEEE, 2018: 1-10.
- [Chen 2017] CHEN Z, Zhuo Y U, DUAN Z, et al. Inter-Blockchain Communication[J]. DEStech Transactions on Computer Science and Engineering, 2017 (cst).
- [Kan 2018] Kan L, Wei Y, Muhammad A H, et al. A Multiple Blockchains Architecture on Inter-Blockchain Communication[C]//2018 IEEE International Conference on Software Quality, Reliability and Security Companion (QRS-C). IEEE, 2018: 139-145.
- [Zamani 2018] Zamani M, Movahedi M, Raykova M. RapidChain: scaling blockchain via full sharding[C]//Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security. ACM, 2018: 931-948.
- [Underwood 2016] Underwood S. Blockchain beyond bitcoin[J]. Communications of the ACM, 2016, 59(11): 15-17.

# Effect of Visible Meta-Rewards on Consumer Generated Media

# Fujio Toriumi<sup>\*1</sup>Hitoshi Yamamoto<sup>\*2</sup>Isamu Okada<sup>\*3</sup>

<sup>\*1</sup>The University of Tokyo <sup>\*2</sup>Rissho University<sup>\*3</sup>Soka University

Consumer Generated Media(CGM) are useful for sharing information, but information does not come without cost. Incentives to discourage free riding (receiving information, but not providing it) are therefore offered to CGM users. The public goods game framework is a strong tool for analyzing and understanding CGM and users' information behaviors. Although it is well known that rewards are needed for maintaining cooperation in CGM, the existing models hypothesize the linkage hypothesis which is unnatural. In this study, we update the meta-reward model to identify a realistic situation through which to achieve a cooperation on CGM. Our model reveals that restricted public goods games cannot provide cooperative regimes when players are myopic and never have any strategies on their actions. Cooperative regimes emerge if players that provide first-order rewards know whether cooperative players will give second-order rewards to the first-order rewarders. In the context of CGM, active posting of articles occurs if potential commenters/responders can ascertain that the user posting the article will respond to their comments.

# 1. Introduction

Consumer generated media (CGM) are the most active information sharing platforms in which users generate contents by voluntary participation. They include information sharing sites such as Wikipedia and TripAdviser, and question/answer forums such as Yahoo Answers. CGM reflect positive traits of the Internet because, in CGM, aggregating users' voluntary participation bears values, and thus they have network externality in which the more active users are, the more the values of the CGM are.

CGM rely on user-provided information and thus fail if information is not provided. Getting users to provide information generally requires effort costs including time costs and click costs[Nakamura 14]. Therefore, CGM users are given incentives to discourage free riding, a situation in which users receive information, but do not provide it. While huge CGM never worry about freeriding, many managers of small-sized CGM pay attention to it. CGM can be regarded as a kind of public goods game–a social dilemma game in which users may refrain from paying costs (that is, free riding), although they could benefit substantially if they contributed.

To avoid the free-rider problem, many CGM adopt incentive systems for users to receive comments as appreciation for posting articles. These comments are considered rewards for contributing to the public goods game. Moreover, many real CGM systems provide Like buttons to react to comments, which can be regarded as meta-rewards. This is because comments also give psychological benefits to original article providers as well as Like buttons give psychological benefits to their receivers.

Toriumi et al. [Toriumi 16] used a public goods game model to show that meta rewards are required to maintain cooperation. A meta reward is a reward for those who gave a reward to cooperative users. Many CGMs implement a function that allows other users to express their gratitude to those who provided information, and the users who ex-

連絡先: Fujio Toriumi, tori@sys.t.u-tokyo.ac.jp

pressed their gratitude can also be given something as a reward.

However, the model has an unrealistic hypothesis which called Linkage hypothesis: Whoever performs the firstorder sanction (rewards) also performs the second-order one. This hypothesis is needed for the theoretical rationale of meta sanctions because, if the second-order sanctions are independent of the first-order sanctions, thirdorder free riders who shirk the second-order sanctions only are possible, and thus cooperation through meta sanctions collapses. Experimental studies have no consensus on this linkage hypothesis. Some experiments support the linkage between the first-order sanctions and cooperative behaviors [Horne 01, Horne 07] while others deny it [Yamagishi 12, Egloff 13]. The linkage hypothesis between the first-order and second-order sanctions is partially supported by an experiment of a one-shot public goods game [Kivonari 08].

In this paper, we will model our CGM public goods game without assuming the linkage hypothesis between the first- and second-order rewards. While a previous model [Toriumi 16] uses the same parameter,  $r_i$ , as the probabilities of giving rewards and giving meta rewards, our model separates the former probability from the latter.

# 2. Models and Methods

In this section, we develop a model that reflects real CGM by extending the CGM model proposed by Toriumi et al. [Toriumi 12]. We then define an adaptive process of players in the model to explore feasible solutions of strategies for promoting and maintaining cooperation. Third, we introduce several scenarios to provide insight for managing real CGM by comparing their performances. Finally, we set parameter values to perform our simulation.

#### 2.1 A restricted meta reward game model

We consider N agents playing a restricted meta reward game. The game is run for a discrete time and each period is referred to as a round. In each round, all agents play three sequential steps in serial order. Using the case of Agent i as an example, Agent i has its own strategy denoted by  $(b_i, r_i, rr_i)$ , which we will explain later.

In the first step, the agent provides its own token into a public pool with probability  $b_i$  and otherwise does not. In CGM, a contribution and a non-contribution are, respectively, regarded as an information-providing behavior and a non-providing behavior. If a token is provided by Agent i, i must pay a cost  $\kappa_0$ , also the other N-1 players receive a benefit,  $\rho_0$ .

In the second step, rewards for providing a public good may occur. In CGM, posting a comment to an information provider is regarded as a reward. If and only if Agent iprovides a token, the other N-1 agents consider whether or not they will give a reward to Agent i. Agent  $j \neq i$  gives a reward to Agent i with probability  $p_{r_i \rightarrow j}$  and otherwise does not. This probability is calculated as  $p_{r_i \rightarrow j} = \varepsilon \cdot r_j$ , where  $r_j$  is j's own reward parameter and  $\varepsilon$  is an expected rate of meta rewards newly introduced in this model to consider the third challenge of the above-mentioned prior studies. If a reward is given, Agent i gains a constant benefit,  $\rho_1$ , while Agent j must pay a constant cost,  $\kappa_1$ .

In the third step, meta rewards for giving rewards may occur. In our model, meta rewards from contributors are possible in the first step only to consider the second challenge of the previous studies, thus making this model a restricted game. In CGM, a reply to comments is regarded as a meta reward. If and only if Agent *i* received a reward from Agent *j*, Agent *i* can decide whether to give a meta reward to Agent *j* with probability  $rr_i$ , and otherwise not. While Toriumi et.al.[Toriumi 12] assumes that  $r_i = rr_i$ , our model assumes that these are independent of each other to consider the linkage hypothesis. If a meta reward is given, Agent *j* gains a constant benefit,  $\rho_2$ , while Agent *i* must pay a constant cost,  $\kappa_2$ .

Each agent plays the above three steps four times in each round. When all agents complete these steps, each agent's final payoff at each round is regarded as its fitness value.

#### 2.2 Simulation scenarios

In the restricted meta reward game, there is no incentive to give meta rewards, and thus players never provide meta incentives. To consider this point, we introduce players' expectations of meta rewards. We then explore how these expectations are reflected in the probability of providing rewards using the following three scenarios that are different values of expected rates of meta rewards,  $\varepsilon$ .

- 1. No reference ( $\varepsilon=1.0):$  players do not use any reference
- 2. Social reference  $(\varepsilon = \frac{1}{N} \sum_{k} rr_{k})$ : players use the average rate of meta rewards in the group
- 3. Individual reference ( $\varepsilon = rr_i$ ): players use cooperator *i*'s probability of meta rewards

Scenario 1 is a baseline. Scenario 2 describes a situation that players can get information on a providing rate of meta rewards in CGM. For instance, we suppose a system

| Table 1: Simulation Para |
|--------------------------|
|--------------------------|

| Param                             | Value |
|-----------------------------------|-------|
| N                                 | 100   |
| Simulation steps                  | 1000  |
| $\mu$ (benefit-cost ratio)        | 2.0   |
| $\delta$ (discount ratio)         | 0.8   |
| $\rho_0$ (benefit of cooperation) | 2.0   |
| $\kappa_0$ (cost of cooperation)  | 1.0   |

in which seeing all meta rewards for rewards by others is possible. Scenario 3 describes a situation that visualizes a providing rate of meta rewards for information provided in CGM. In this scenario, we assume that players can decide whether or not to provide meta rewards to a cooperator after they check the providing rate of meta rewards of the focal cooperator.

#### 2.3 Parameter setting

For simplicity, we set the values of the parameters above by installing two new intervening parameters:  $\delta$  and  $\mu$ .

$$\kappa_0 = 1.0$$
 (1)

$$\rho_n = \mu \cdot \kappa_n \tag{2}$$

$$\kappa_n = \delta \cdot \kappa_{n-1},\tag{3}$$

where n = 1, 2.

At first, we simulate the case of  $\mu = 2$  and  $\delta = 0.8$  to clarify the performances of each scenario. Then, we investigate the influences of the cost-reward ratios in Section 3.2. Table 1 shows the values of the other parameters in the simulation.

#### 3. Simulation Results

#### 3.1 Comparison of three scenarios

We simulate 100 runs with different random seeds in each scenario, and show the averages and the variances of values using error-bars in Figs.1, 2, and 3. In these figures, the vertical axes show the step numbers while the horizontal axes show the average parameter values: Cooperation indicates cooperation rates,  $b_i$ , Reward indicates reward rates,  $r_i$ , and MetaReward indicates meta reward rates,  $r_i$ .

As shown in Fig.1, the cooperation rate in Scenario 1 decreases at about 100 steps while increasing at the beginning. This is due to the decrease in reward rates. The rate gradually decreases immediately after the beginning and reaches 0.1 at 20 steps. No reward never bears cooperation.

Scenario 2 faces the same mechanism and thus neither scenario can maintain a cooperative regime.

In Scenario 3, on the other hand, the cooperation rate increases from the beginning, then the meta reward rate also increases and, finally, the reward rate increases, therefore maintaining a stable cooperative regime as shown in Fig.3.

Why does Scenario 3 promote cooperative regimes while Scenario 1 does not? This is quite surprising because parameter value  $\varepsilon$  is 1 in Scenario 3 while it is less than 1 in Scenario 1. We then analyzed the time series of cooperation rates, reward rates, and meta reward rates in Scenario 3 in comparison with Scenario 1. At the beginning of the simulation, cooperative rates increased in both scenarios. However, the next phenomena are different. In Scenario 3, the meta reward rates increased before the reward rates increased. This is because players with high meta reward rates tend to receive more rewards than those with low meta reward rates. If the number of players who give rewards is sufficiently large, the high meta reward rates bear the benefit of the rewards and are larger than the costs of meta rewards. Therefore, players with high meta reward rates benefit more than those with low meta reward rates.

The more players with high meta reward rates there are, the greater the probability of receiving meta rewards when giving rewards. Therefore, players who tend to give rewards gain more benefit than those who do not, and thus the reward rates increase. High reward rates enhance the benefit of cooperation and, therefore, cooperative players have an advantage over defective players. Cooperative regimes stay robust.

#### 3.2 Influence of cost-reward ratios

In our model, the rate of the reward benefit on the reward cost is important for promoting cooperative regimes[Toriumi 16]. Therefore, we simulated many cases with different values of  $\mu$  and  $\delta$ . Figure 4 shows the average rate of cooperation in 1000th step with in 50 runs per each case. In this figure, the x axis indicates  $\mu$ , the y axis indicates  $\delta$ , and the color bar indicates the average cooperation rates.

The scopes of  $\mu$  and  $\delta$  are, respectively,  $0.0 \leq \mu \leq 5.0$ and  $0 \leq \delta \leq 1.0$ . This figure shows that

- 1. Cooperative regimes emerge only in Scenario 3
- 2. Cooperative regimes never emerge if  $\mu < 1.4$  and
- 3. Cooperative regimes emerge if approximately  $\mu \cdot \delta > 1.0$

Among these, Result 2 is consistent with a previous study [Toriumi 12] that demonstrated that cooperative regimes require a substantially large benefit of rewards compared with their costs. Our result adds the insight that it also requires a sufficiently larger value of  $\mu$  in our model than the previous study's model. This is because the expected values of meta rewards are small if  $\mu$  is small, and thus the incentive to give rewards vanishes.

Next, we consider Result 3. As a result of our simulation, condition  $\mu \cdot \delta > 1.0$  is necessary for promoting cooperation. In terms of the relationship between rewards and meta rewards, if the benefit of meta rewards is greater than the cost of rewards, players may receive a benefit through giving rewards, and thus there are incentives to give rewards. This indicates that

$$\rho_2 > \kappa_1 \tag{4}$$

is required. If  $\kappa_1 > 0$  is satisfied, equations  $\rho_2 = \mu \cdot \kappa_2 = \mu \cdot \delta \kappa_1$  are satisfied, and thus the necessary condition of reward behaviors is

$$\mu \cdot \delta = \frac{\rho_2}{\kappa_1} > 1.0. \tag{5}$$

Strictly on this point, players do not always receive meta rewards and thus we should consider the average rate of meta rewards,  $\overline{rr_i}$ . Therefore,

$$\overline{rr_i} \cdot \mu \cdot \delta > 1.0 \tag{6}$$

is the necessary condition.

If this condition is satisfied, players who give rewards to other players at sufficiently large rates of meta rewards have an advantage. This also means that cooperative agents are given incentives from which they should receive a large amount of meta reward rates. This mechanism works and therefore players with large amounts of both reward rates and meta reward rates have survival advantages and, finally, cooperative regimes emerge.



Figure 1: Result of Scenario 1



Figure 2: Result of Scenario 2

# 4. Discussion

While our main results support the importance of meta-rewards for activating CGM, we must state the



Figure 3: Result of Scenario 3



Figure 4: Change  $\mu, \delta$  in Scenario 3

other important drivers of real posting including brand image[Kim 16], attention seeking, communication, archiving, and entertainment[Sung 16]. Moreover, we have no option but to accept the future study on the empirical data that support that the original article providers respond to other commenters replies to sustain posting on CGM.

We developed a restricted public goods games model to overcome the mismatches found between previous models and actual CGM. Our model reveals that restricted public goods games cannot provide cooperative regimes when players are myopic and never have any strategies on their actions. Cooperative regimes emerge if players that give firstorder rewards are given information that reveals whether cooperative players will give second-order rewards to the first-order rewarders. In the context of CGM, if users who post articles reply to commenters/responders, active posting of articles occurs if potential commenters/responders can ascertain that the user posting the article will respond to their comments.

This study should be extended. First, the present version of our model describes two types of players actions: cooperation as posting information and defect as non-posting. However, defect behaviors in CGM can be divided into two types: do nothing and post inadequate information. This issue should be introduced in a future version. Second, while our model assumes that all players can observe all information, this is not realistic. We are interested in the influence when the frequency of information accessibility depends on the quality of the information.

- [Egloff 13] Egloff, B., Richter, D., and Schmukle, S. C.: Need for conclusive evidence that positive and negative reciprocity are unrelated, *Proceedings of the National Academy of Sciences*, Vol. 110, No. 9, pp. E786–E786 (2013)
- [Horne 01] Horne, C.: The enforcement of norms: Group cohesion and meta-norms, *Social psychology quarterly*, pp. 253–266 (2001)
- [Horne 07] Horne, C.: Explaining norm enforcement, Rationality and Society, Vol. 19, No. 2, pp. 139–170 (2007)
- [Kim 16] Kim, A. J. and Johnson, K. K.: Power of consumers using social media: Examining the influences of brand-related user-generated content on Facebook, *Computers in Human Behavior*, Vol. 58, pp. 98–108 (2016)
- [Kiyonari 08] Kiyonari, T. and Barclay, P.: Cooperation in social dilemmas: Free riding may be thwarted by secondorder reward rather than by punishment., *Journal of per*sonality and social psychology, Vol. 95, No. 4, pp. 826–42 (2008)
- [Nakamura 14] Nakamura, H., Gao, Y., Gao, H., Zhang, H., Kiyohiro, A., and Mine, T.: Tsunenori Mine. Toward Personalized Public Transportation Recommendation System with Adaptive User Interface, 3rd International Conference on Advanced Applied Informatics (2014)
- [Sung 16] Sung, Y., Lee, J.-A., Kim, E., and Choi, S. M.: Why we post selfies: Understanding motivations for posting pictures of oneself, *Personality and Individual Differences*, Vol. 97, pp. 260–265 (2016)
- [Toriumi 12] Toriumi, F., Yamamoto, H., and Okada, I.: Why do people use Social Media? Agent-based simulation and population dynamics analysis of the evolution of cooperation in social media, in *Proceedings of the The* 2012 IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology-Volume 02, pp. 43–50 (2012)
- [Toriumi 16] Toriumi, F., Yamamoto, H., and Okada, I.: Exploring an Effective Incentive System on a Groupware, Journal of Artificial Societies and Social Simulation, Vol. 19, No. 4 (2016)
- [Yamagishi 12] Yamagishi, T., Horita, Y., Mifune, N., Hashimoto, H., Li, Y., Shinada, M., Miura, A., Inukai, K., Takagishi, H., and Simunovic, D.: Rejection of unfair offers in the ultimatum game is no evidence of strong reciprocity, *Proceedings of the National Academy* of Sciences, Vol. 109, No. 50, pp. 20364–20368 (2012)

# Toward machine learning-based facilitation for online discussion in crowdscale deliberation

Chunsheng Yang<sup>\*1</sup>, Takayuki Ito<sup>\*2</sup>, and Wen Gu<sup>\*2</sup>

<sup>\*1</sup> National Research Council Canada <sup>\*2</sup> Nagoya Institute of Technology

The objective of this paper is to develop machine learning-based facilitation agent for facilitating online discussion in collective intelligence, particularly for online discussion in deliberation. The main idea is to model facilitator's human behaviour by using machine learning technique, case-based reasoning paradigm,. After introducing the details of the proposed machine learning-based approach for facilitation of online discussion, the paper presents some preliminary results along with some outline of the on-going research tasks and future work. The results demonstrate that it is feasible and effective to develop machine learning-based agent for smoothing the discussion and achieving a consensus.

# 1. Introduction

Deliberation is defined as the activity of small group of people who make the best solution for themselves [Ito 2017]. Over centuries, such decision-making process never changed. This deliberation process is controlled by a small group of powerful people who make the policies without incorporation of public opinion from crowd, and excludes the most people's involvement during the decision-making. Such an approach is becoming inadequate because many important ideas are not properly incorporated. Today, democratically, most people or crowds have to be involved in deliberation.

With the rapid development of Internet, the Internet-based online discussion in crowd-scale deliberation [Klein 2011] or in collective intelligence has attracted many efforts from researchers in social science and computer science. Online crowd decision-making support has received an amount of research interests, and some such support systems have been developed. For instance, Climate CoLab at MIT [Introne 2011] was a pioneer project which aims at harnessing the collective intelligence of thousands of people around the world to make arguments on global climate issues. The project developed a web-based crowdsourcing platform to facilitate the online argumentation [Klein 2011, Gurkan 2010, Klein 2007] democratically. Another example is COLLAGREE developed at Nagova Institute of Technology (NiTech); it is a web-based online discussion platform [Ito, 2014], which provides a facilitator the support for managing online discussion to effectively achieve the consent through various mechanisms, including facilitation, incentives [Ito 2015], discussion-tree [Sengoku 2016], and understanding. The project team has applied the COLLAGREE to political applications such as city planning forum to collect the crowd opinion from public. For example, NiTech and Nagoya City used COLLAGREE for generating the consent for Next Generation Total City Planning. With the help of COLLAGREE, the Nagoya City gathered many opinions from public citizens. On the other hand, the people from

city can understand the importance of next generation city plan. Eventually a consent decision can be achieved democratically. Such online argumentation platforms or forums require the facilitators having systematic methodologies to efficiently guild the discussion toward to consensuses by integrating ideas and opinions and avoiding flaming.

Existing online discussion systems or collective intelligence support systems require the human facilitators to conduct facilitation in order to guide/ensure the online discussion towards consensus. However, human facilitators-based online discussion systems remain several challenging issues such as human bias, time/location restriction, and human resources constrains. To address these challenges, relieve some burden of facilitators, and reuse the prior experience and skills of the facilitators, it is desirable that more advanced techniques are available for supporting the automated facilitation to achieve the consensuses efficiently.

Fortunately, the advancement of machine learning and multiagent systems techniques provides a venue for developing facilitator agent to automate facilitations for large-scale online discussion. One of machine learning techniques available is case-based reasoning (CBR), which provides an effective reasoning paradigm for modeling the human cognition behaviors in solving real-world problems. CBR-based approach has been widely applied to many applications such as fault diagnostics [Yang 2003], recommendation systems, and judge supporting systems [Lopes 2010]. We believe in that machine learningbased facilitation, specifically, CBR-based method should be a good solution to crowd-scale deliberation or online discussion Therefore, we propose a CBR approach to facilitation. facilitating the crowd-scale online discussion in order to achieve a consensus efficiently. The main idea is to develop CBR-based facilitation actions/mechanisms, including better idea generation, smooth discussion, avoiding negative behavior and flaming, and maintaining online discussion, consensus-oriented guidance and navigation, and so on. The paper mainly discuss the basic ideas on developing machine learning-based facilitation agent and some on-going research tasks and future work.

Following this Section, the paper presents the proposed CBRbased approach for facilitating the online discussion in details;

Chunsheng Yang, National Research Council Canada, 1200 Montreal Road, Room370a@M50, Ottawa, ON, Canada, <u>Chunsheng.Yang@nrc.gc.ca</u>, Tel 1-613-993-0262
Section III discusses the on-going research tasks and future work; and the final Section concludes the paper.

## 2. Machine learning-based facilitation agent

Machine learning techniques have been widely applied to various real-world problems and have been achieved great success in developing machine learning-based modeling technologies. Today, the machine learning-based modeling technology has become a powerful tool for building models to explain, predict, and describe system or human behaviors. The main task is to develop the data-driven models from the historic data or past experience by using machine learning algorithms. The developed models have the given ability to explain, predict, and describe the system or human behaviour. For example, in the prediction applications, the machine learning-based models can forecast the system operating status, including failures or faults. With such predictions the proactive actions can be taken to maintain the system availability. In this work, we contemplate to use a case-based reasoning approach or paradigm to model facilitators' behavior or facilitation by using their experience accumulated in past.

#### 2.1 CBR-based modeling for cognition

CBR is rooted in the works of Roger Schank on dynamic memory and the central role that a reminding of earlier episodes (cases) and scripts (situation patterns) has in problem solving and learning [Schank 1983]. Today, Case-based reasoning is a paradigm for combining problem-solving and machine learning to solve real-world problems. It has become one of the most successful applied intelligences for modeling human cognition. The central tasks in CBR-based methods and systems [Amodt 1994] are: "to identify the current problem situation, find a past case similar to the new one, use that case to suggest a solution to the current problem, evaluate the proposed solution, and update the system by learning from this experience. How this is done, what part of the process that is focused, what type of problems that drives the methods, etc. varies considerably, however". A general CBR-based system or agent can be described by a reasoning cycle composed of the following four steps:

- . RETRIEVE the most similar case from existing case bases;
- REUSE the solution in the case to solve the problem such as flaming, wrong post to the issue, distraction post;
- . REVISE the proposed solution if necessary;
- RETAIN the parts of this case into a case base for future problem solving.

#### 2.2 Case composition and definition

In general a case documents relationships between problems and its solutions. CBR solves a new problem by adapting similar solutions used for a similar problem in the past. For online discussion facilitation, a case can be defined as three components (as shown as Figure 1): online discussion case description, facilitation action, and case management. Following is the brief description for each components.



Fig.1 The case composition for online discussion

*Case Description:* This component contains discussion post, issue related to discussion, topics, theme, and so on. Post could be a free text, or a group of sub posts.

*Case Management:* This component consists of necessary case management information such as case status, case life cycle, case type, case consistence, and so on.

*Case Facilitation:* This component records the facilitation actions conducted by human facilitator over the past online discussion. The main facilitation could be flaming control, topic shift, post combination, post deletion, idea promotion, and so on.

From online discussion practice such as Nagoya City Planning, we have collected the data to create cases based on the case definition. It is especially useful to create facilitation cases which documents how a facilitator guided the online discussion; what kind of facilitation was used; how a facilitation action was taken, and so on.

## 2.3 Similarity computation

Based on the case definition above, a CBR method must provide a similarity algorithm for computing the similarity between two cases. Using computed similarity, the similar cases can be retrieved from a case base. In this work, we provide a global similarity algorithm, which computes the global similarity (sim) using Equation 1.

where, *sim* is the global similarity of two problems; N is the number of features or attributes that contribute to similarity;  $\omega_i$  is the weigh coefficient of each feature; *sim*<sub>i</sub> is a local similarity;  $f_i$ ,  $f_i'$  are the *i*<sup>th</sup> features in a case and given problem description. It is computed with Nearest Neighbor *(NN)* distance algorithm *(NN* method) for regular types of the features. For a free "text" feature, we use natural language processing techniques to compute local similarity. Particularly, we used IE (Information Extraction) method to compute the text similarity by using the library provided in OpenNPL package [Weber 2001]. We used the Maximum Entropy algorithms implemented in the OpenNLP package to compute the local similarity for two text messages as expressed as Equation 2.

## 2.4 CBR-base facilitation agent framework

Once the case base is created, the CBR-based facilitation agent is ready constructed in online discussion system or platform. In general, such a facilitation agent can be implemented following the designed framework showed as in Table 1.

Table 1, the pseudocode for facilitation agent framework (Note: CB: case bases, C: case from Post, C': retrieved case from CB, E4: facilitation action from C')

| Input caseBase (plain text file, CB);            |
|--|
| Steps  |
| CB =Loadthecasebaseinmomorry (CB text file);     |
| C= GetOnlineDiscussionCase (post ,issue, theme); |
| C'= StartReasonningCycle(C) ;                    |
| $\Rightarrow$ <i>RrtriveCase(C,SIM());</i>       |
| $\Rightarrow$ SolutionAdaptation(C')             |
| $\Rightarrow$ ReviseCase(C');                    |
| ⇒ RetainCase( C');                               |
| FA = AdaptatFacilitation(C');                    |
| ExecuteFAcilication (FA);                        |
| Stop   |
|  |

As described in Table 1, the first step is to load the cases (stored in external files or database) into memory given a case composition and configuration mapping information. Once the case base is loaded into memory, a facilitation agent can execute the CBR reasoning cycles to retrieve the similar case in a case base for obtaining facilitation action give a post, issue and theme. Second step is to adapt the facilitation from the similar case for given case; the third step is to modify the case if necessary; the last step is to retain the revised case and save it back to the case base as a new case. The final step is to execute the facilitation action based on adapted facilitation action to the current post if it requires a facilitation action.

## 3. Discussion and Future Work

This paper mainly reports our ongoing research project. The objective is to present the ideas for developing machine learningbased agent for online discussion facilitation. Therefore many tasks are ongoing. Since focusing on CBR-based approach for facilitation, we only discuss the CBR related ongoing tasks. The other machine learning-based methods for automated facilitation will be reported in other papers.

### 3.1 Case structure extension and similarity algorithm

The case defined above is a basic structure. To reflect the various online discussion and complexity of facilitator's behaviour, the case structure may become complicated and complex. The similarity computation algorisms have also to be further investigated and extended from existing simple algorithm. For example, we are exploring a graph-based case structure in

order to build case from a group post instead of one individual post [Gu 2018]. On the other hand, we have to investigate new algorithms for computing similarity of graph-based online discussion cases

Cases can be created either from historic data or simulation data. In this work, we conducted an online discussion forum to collect the real data. The forum was set up as a "CBR approach to support facilitation in COLLAGREE". We created the theme for an online discussion in the laboratory. The online discussion was managed and guided by a facilitator who maintains the online discussion in three phases: divergence, convergence, and evaluation. The facilitator used the support vehicle provided to navigate the forum from divergence to convergence to evaluation. Using collected data, we created some cases which reflect the facilitator's facilitation during online discussion. However, to enrich the facilitation more data are required for case creation. One way is to conduct the simulation to generate more facilitation data for creating more cases.

## 3.2 Machine learning-based case adaptation

In CBR research area, one remaining challenge is case adaptation. It is normal that we can't retrieve a similarity case from a case base to obtain a similar facilitation action for controlling and managing online discussion in practice. Therefore, the CBR-based agent has to adapt a facilitation action. To this end, we have to build the ability for agent to learn a new facilitation action. This motivates us to investigate the machine learning-based case adaptation methods for facilitation agent.

## 3.3 Case base management

This is a vital research topic for any CBR-based applications. The existing cases are manually created from the forum data collected in COLLAGREE. This is a time-consuming task and requires rich domain knowledge to understand the contents in the post or opinion. With the increasing of the collected data, manual case creation will be a challenge. An automated case creation mechanism is expected and necessary. Therefore two necessary research topics are described as follows:

- (1) Automated case generation: As we discussed above, automated case creation is desirable to relieve the burden of manual case creation. From the viewpoint of machine learning, automated case creation is a supervised learning problem. It requests the annotated information to decide the case property or types. To do this sentiment analysis of the post contents is inevitable and vital for determining the case types: positive, natural, and negative. Another challenge is machine translation of language. During the online discussion it may encounter the multiple language. When generating cases from different language the automated machine translation is required.
- (2) Case base management: In this work, the case base management still remains a challenge. To manage the case base efficiently, case redundancy and consistence have to be investigated in order to ensure the quality and integrity

of the case bases. Another challenge is case adaptation from the existing case and case updating to existing cases.

#### 3.4 Validation and evaluation

Validation and evaluation for a CBR-based systems is always a challenge issue in developing CBR-based applications. It requires many efforts to design the procedures and methods. In this work, the following tasks will be conducted:

- (1) Continue to collect the data from online discussion forum using COLLAGREE and create more cases for evaluation;
- (2) Evaluate the performance of CBR-based systems for facilitation support by comparing the results with one from human facilities; and
- (3) Validate the scalability of cases crossing different themes, even domains.

#### 4. Conclusions

This paper reported an ongoing research project. The objective is to develop a machine learning-based facilitation agent for online discussion system to perform the automated facilitation in crowd-scale deliberation. After describing the proposed approach, we discussed some on-going research tasks and future work.

#### ACKNOWLEDGMENT

This work was supported by the JST CREST fund (Grant Number: JPMJCR15E1), Japan. We would like to thank all project members and related people for their contribution in the studies and the experiments. We are also grateful for all participants at Ito-Lab, Nagoya Institute of Technology in online discussion on CBR application to COLLAGREE.

#### References

- [Amodt, 1994] A. Aamodt and E. Plaza, "Case-based reasoning: Foundational issues, methodological variations, and system approaches", AI Communications, Vol. 7 No. i, 1994.
- [Gu, 2018] W. Gu, A. Moustafa, T. Ito, M. Zhang. and C. Yang, "A Case-based Reasoning Approach for Automated Facilitation in Online Discussion Systems", The Proceedings of The 2018 International Conference on Knowledge, Information and Creativity Support Systems (KICSS 2018), Thailand, Nov. 2018
- [Gurkan, 2010] A. Gurkan, L. Iandoli, M. Klein, and G. Zollo, "Mediating debate through on-line latrge-scale atgumentation: Evidence from the field", Information Science Vol. 180, No. 19, 2010, pp. 3686-3702
- [Ito, 2015] T. Ito, Y. Imi, M. Sato, T. K. Ito, and E. Hideshima,"Incentive Mechanism for Managing Large-Scale Internet-Based Discussions on COLLAGREE", Collective Intelligence 2015, May 31 – June 2, 2015, the Marriott Santa Clara in Santa Clara, CA (poster).
- [Ito, 2014] T. Ito, Y. Imi, T. K. Ito, and E. Hideshima, "COLLAGREE: A Faciliator-mediated Large-scale Consensus Support System", Collective Intelligence 2014, June 10-12, 2014. MIT Cambridge, USA. (poster)
- [Ito, 2017] T. Ito, T. Ostuka, S. Kawasa, A. Sengoku, S. Shiramatsu, T.K. Ito, E. Hideshima, T. Matsuo, T. Oishi, and R. Fujita, "Experimental results on large-scale cyber-physical hybird discussion support", International Jouran of Crowd Science, Vol. 1 No. 1, 2017
- [Introne, 2011] J. Introne, R. Laubachar, G. Olson, and T. Malone, "The Climate Colab: Large scale model-based collaborative planning", Proceedings of International Conference on Collaboration Technologies and Sytems (CTS 2011), 2011
- [Klein, 2011] M. Klein, "Toward crowd-scale deliberation", DOI: 10.13140/RG.2.2.12264.06401 , Massachusetts Institute of

Technology, available at https://www.researchgate.net/publication/317613473Towards\_Crowd-Scale\_Deliberation

- [Klein, 2012] M. Klein, "Enabling large-scal deliberation using attention-mediation metrics", Computer Supported Cooperative Work(CSCW), Vol. 21, No. 4/5, pp.449-473, 2012
- [Klein, 2007] M. Klein, "Achieving collective intelligence via largescale on-line argumentation", CCI working paper, 2007-001, April, 2007
- [Lopes, 2010] E. C. Lopes and U. Schiel, "Integrating Context into a Criminal Case-based Reasoning Model", the proceedings of 2nd International Conference on Information, Process, and Knowledge management, 2010
- [Schank, 1983] R. C. Schank. "Dynamic Memory", Cambridge Univ. Press, 1983.
- [Sengoku, 2016] A. Sengoku, T. Ito, K. Takahashi, S. Shiramatsu, T.K. Ito, E. Hideshima and K. Fujita, "Discussion Tree for Managing Large-Scale Internet-based Discussion", Collective Intelligence 2016, Stern School of Business New York University June 1-3, 2016
- [Weber, 2001] R. Weber, D. W. Aha, N. Sandhu, H. Mounoz-Avila, "A textual case-based reasoning framework for knowledge management applications", Proceedings of Knowledge Management by Case-Based Reasioning; Experience and Management as Resue of Knowledge (CWCBR 2001), 2001
- [Yang, 2003] C. Yang, R. Orchard, B. Farley, and M. Zaluski, Authoring Cases from Free-Text Maintenance Data, in Proceeding of IAPR International Conference on Machine Learning and Data Mining (MLDM 2003), Leipzig, Germany, July 5-7, 2003, pp.131-140

# An automated privacy information detection approach for protecting individual online social network users

Weihua Li<sup>\*1</sup>, Jiaqi Wu<sup>\*1</sup>

Quan Bai<sup>\*2</sup>

<sup>\*1</sup> Auckland University of Technology, New Zealand

\*2 University of Tasmania, Australia

Abstract: Massive private messages are posted by online social network users unconsciously every day, some users may face undesirable consequences. Thus, many studies have been dedicated to privacy leakage analysis. Whereas, there are very few studies detect privacy revealing for individual users. With this motivation, this paper aims to propose an automated privacy information detection approach to effectively detect and prevent privacy leakage for individual users. Based on the experimental results and case studies, the proposed model carries out a considerable performance.

## 1. Introduction

Online social networks (OSNs) have become ubiquitous in people's activities. The popularization of OSNs turns out to be a double-edged sword. On one hand, it provides convenience for people to communicate, collaborate, and share information. On the other hand, OSNs also come with serious privacy issues. Without given much attention by the users, a massive amount of private information can be accessed publicly through OSNs. Users may expose themselves to a wide range of "observers", which include not only relatives and close friends, but also strangers and even stalkers. This raises a serious cybersecurity issue, i.e., online privacy leak.

Online privacy leak means that an individual user shares his/her private information to people who he/she does not know well or even strangers on the Internet. This can be very dangerous for general Internet users, especially with the booming of OSNs. It is necessary to have a tool to assist general users to make better use of OSNs and protect them from leaking privacy information [Wang 11] [Hasan 13]. Hence, it is essential to detect privacy leakage in OSNs and remind individual online social network users before posting any privacy-related message. Under this motivation, in this paper, we propose a novel privacy detection framework for individual users of OSNs by using a Deep Learning approach. Twitter has been used as the source of data for training and validating our proposed framework since it is the biggest microblogging social media in the world [Mao 11]. Based on the generic definition of privacy and the characteristics of OSNs, the definition of "individual privacy" in OSNs have been formally defined. Furthermore, a deep learning-based approach has been developed and utilized to extract privacy-related entities from the messages posted by the users.

The rest of the paper is organized as follows. Section 2 reviews the existing research work regarding data leaks on OSNs. Section 3 introduces the automated privacy information detection framework. In Section 4, two experiments have been conducted to evaluate the proposed framework by using a real-world dataset collected from Twitter. Section 5 concludes this study, as well as the limitations and future work.

#### 2. Related Work

Privacy leakage detection in OSNs has attracted great attention to many researchers. A few studies have been conducted to analyze user privacy revealing on Twitter. People are very cautious about their personal information, e.g., home address, phone number, etc., but they consciously or unconsciously disclose their plans and activities through posting information in OSNs [Humphreys 10]. Publishing such messages online can possibly raise serious security issues. For example, a message saying "going out for holiday" implies that no one stays at home, which may cause robbery. Therefore, users should be reminded before delivering such event-related information. Mao, Shuai and Kapadia (2011) present a detection approach to analyzing three types of sensitive tweets, i.e., drunk, vacation and disease tweets. The research on privacy issues is not restricted to Twitter. Acquisti and Gross (2006) investigate the privacy concerns of users on Facebook. Dwyer, Hiltz, and Passerini (2007) compare the trust and privacy issues between Myspace and Facebook. Bhagat, Cormode, Srivastava, and Krishnamurthy (2010) show that privacy can be revealed by predicted social graph.

Whereas, very few studies investigate how to detect individual privacy information and protect individual OSNs users from online privacy leak. Therefore, in this study, instead of assisting the organizations, we target the individual online users and keep them away from privacy leakage. As almost all the posts by users are unstructured data, the information extraction plays a pivotal role in the proposed framework.

Named Entity Recognition (NER) is an important method for extracting domain-specific information [Nadeau 07]. Given the context of privacy detection domain, NER can assists users in identifying privacy-related entities after given sufficient training. Traditionally, Conditional Random Field (CRF) classifier has been employed for NER due to its robustness and reliability. Gomez-Hidalgoy et al. (2010) proposed a mechanism which is capable of detecting named entities, e.g., a company, brand, or person, using NER. Nowadays, Bi-directional Long Short-Term Memory with Conditional Random Field (Bi-LSTM CRF) model becomes more popular as it achieves more promising results [Lample 16]. Therefore, we utilize Bi-LSTM CRF for privacyrelated entities extraction. Privacy Information Detection.

Contact: Dr Weihua Li, Auckland University of Technology, 55 Wellesley St E, Auckland, 1010, NZ, +64 09921 9999



Fig 1 The Proposed Privacy Detection Framework

#### 3. Privacy Information Detection Framework

#### 3.1 Definition of Privacy

"Privacy" has a very broad meaning, which generally refers to the people's right to keep their personal matters and relationships secret [Gehrke 11]. In this sense, the privacy information is associated with something personal, as well as the matters of past, present, and future. Given the generic definition, in this paper, the privacy information that users tend to publish on the OSNs is defined as a sequence of words, stating or implying any individual's personal information, preferences, events that he or she involved.

Based on the definition given above, the privacy information incorporates four categories of entities, i.e., PERSON, TRAIT, PREF, and EVENT. More specifically, PERSON refers to any expression that identifies a real person; TRAIT represents the personally identifiable information, such as birth date and phone number; PREF refers to an individual's preference or hobbies; EVENT indicates the matters or activities that one involves anytime anywhere. Therefore, given a word sequence, the judgment of privacy information can be summarized as a rule as follows:

 $\exists PERSON \land (\exists TRAIT \lor \exists PREF \lor \exists EVENT) \rightarrow P(message)$ 

#### 3.2 The Automated Privacy Detection Framework

Our automated privacy information detection framework is demonstrated in Figure 1. The framework illustrates how the privacy detection model gets trained and utilized.

Users keep posting messages to the OSNs hosting in the cloud. Such raw unstructured and public data can be obtained through crawlers or APIs provided by the OSNs. For example, Twitter allows developers to search public tweets if the proposed project is approved. Given the context of privacy detection, the potential privacy-related data should be filtered and downloaded. Preprocessing is conducted based on specific rules, such as removing meaningless words and characters and parsing word sequences to tokens. The processed data are supposed to be further enriched by running through the pre-annotation if a privacy-detection NER model is available. Next, human involvements, i.e., manual annotation, are required. Specifically, according to the aforementioned definition of privacy information, it is essential to recognize the privacy-related entities, i.e., PERSON, TRAIT, PREF, and EVENT. The annotation also aims to figure out these four types of entities from the processed data. The annotated dataset is then fed into the deep learning model for training.

The privacy detection model consists of two components, i.e., a deep learning model for privacy-related entities recognition and privacy definition rules. For any posting messages by the OSN users, the proposed model is capable of judging whether the message is privacy-related or not. Moreover, as the privacy rules are properly defined, the privacy detection model can also explain the reason why the message is potentially privacy-related. Using a single deep learning model for private messages classification definitely loses the capability of justification.

#### 3.3 Privacy-Related Entities Recognition

The privacy-related entities recognition plays an important role in the entire framework. There are two major aspects affecting the performance of an NER model, i.e., the annotation approach and the algorithm.

In this study, the Bi-LSTM CRF model has been employed for privacy-related entities recognition in our model, as it is capable of achieving more promising results compared with that of other classic algorithms when being applied to NER [Lample 16]. Bi-LSTM can learn long-term dependency due to the structure of the 'cell' in the hidden layer. Moreover, it can adjust the impact of previous states on the current states through the forget gate, input gate and output gate in the 'cell' [Graves 05]. However, it lacks the feature analysis on the sentence level, which can be solved by CRF. It can consider contextual conditions to make global optimal predictions. Combining the LSTM and CRF together can label sequence effectively when ensures to extract contextual features [Huang 15]. In regards to the annotation approach, BIO encoding scheme is utilized to tag entities in NER task [Kim 04]. BIO encoding scheme is a standard method which can solve the joint segmentation problem in labelling sequence by transforming them into raw labelling problem. Specifically, 'B-' is used as a prefix of an entity, implying the beginning of an entity; prefix 'I-' tags other characters indicating the tag is inside of an entity and 'O' is used for characters which do not belong to any pre-defined entities. For example, privacy-related entities fall into BIO scheme are normally annotated as follows:

| Ι               | watch          | а       | movie   | with | Christine.      |
|-----------------|----------------|---------|---------|------|-----------------|
| <b>B-PERSON</b> | <b>B-EVENT</b> | I-EVENT | I-EVENT | 0    | <b>B-PERSON</b> |

#### 4. Experiments

Two experiments have been conducted to evaluate the proposed privacy detection framework. The first experiment aims to train a privacy-related entities recognition model using Bi-LSTM CRF model. The second experiment gives some case studies to further demonstrate the effectiveness of the proposed privacy detection model.

#### 4.1 Data description

Twitter is one of the largest OSNs, which enables users to conduct online social activities, including the distribution of any ideas or information. In Twitter, the messages that are posted and interacted by users are known as "tweets". Twitter provides APIs, allowing developers to search and store tweets. Therefore, we utilize Twitter API to collect 18k tweets by searching for some terms which potentially result in privacy leakage, such as pronouns, sensitive words, plans, etc.

#### 4.2 Experiment 1

In Experiment 1, a privacy detection model based on Bi-LSTM CRF is trained to recognize the privacy-related entities. Through which, the users can be prompted before potential privacy leakage occurs. According to the definition of privacy and BIO encoding scheme mentioned previously, nine tags have been defined, i.e., 'B-PERSON', 'I-PERSON', 'B-TRAIT', 'I-TRAIT', 'B-PERF', 'I-PERF', 'B-EVENT', 'I-EVENT' and 'O'. Around 200 tweets have been annotated manually by applying these nine tags.

In this experiment, we leverage three traditional evaluation metrics as follows:

- **Precision**: the percentage that privacy-related entities can be labelled correctly among all the entities which are labelled privately in the test dataset.
- **Recall**: the percentage that privacy-related entities can be labelled correctly among all the actual privacy entities in the test dataset.
- **F1-score**: the weighted average of precision and recall, which takes both the two measures into account.

After 50 epochs' training, the performance of the deep learning model is demonstrated in Table 1.

Table 1 Performance of Privacy-Related Entities Recognition

| Entity    | Precision | Recall | F1-score |
|-----------|-----------|--------|----------|
| PREF      | 0.99      | 0.67   | 0.8      |
| TRAIT     | 0.68      | 0.88   | 0.77     |
| PERSON    | 0.98      | 0.93   | 0.95     |
| EVENT     | 0.77      | 0.67   | 0.71     |
| Avg/Total | 0.86      | 0.83   | 0.84     |

## 4.3 Experiment 2 Case Study

In this experiment, we further demonstrate the effectiveness of the proposed privacy detection model by selecting three tweets posted recently and analyzing the results produced by the model.

#### Case 1: Adam and I are having lunch tomorrow.

Results: Adam (B-PERSON) and I (B-PERSON) are having (B-EVENT) lunch (I-EVENT) tomorrow.

Explanations: Based on the privacy rules, this tweet is privacyrelated since it mentions both PERSON and EVENT.

#### Case 2: Watching a movie is a good way to relax!

Results: Watching (B-EVENT) a (I-EVENT) movie (I-EVENT) is a good way to relax!

Explanations: This tweet is just a simple statement regarding "Watching a movie", which is not a private one.

Case 3: My son is crazy about coke.

Results: My (B-PERSON) son (I-PERSON) is crazy about coke (B-PREF).

Explanations: This tweet talks about PERSON and PREF, it is privacy-related.

## 5. Conclusion and Future Work

In this paper, we presented a privacy information detection framework for individual OSN users. The objective is to protect end users from potential privacy leakage before posting any messages. The proposed framework explains the process of data collection, processing, model training and how it works. Both privacy rules and Bi-LSTM CRF model are leveraged in the privacy detection model. Thus, the proposed model is equipped with the capability of both detection and results explanation.

This study is still very preliminary and there is huge space for further investigation and extension. In the future, we intend to utilize a larger training dataset for performance evaluation and improve the performance of the privacy-related entities recognition by fine-tuning the parameters of Bi-LSTM CRF. Moreover, different tweets are associated with different degrees of privacy leakage. How to evaluate and score the privacyleakage degree is also under our consideration.

## References

- [Wang 11] Wang, Y., Norcie, G., Komanduri, S., Acquisti, A., Leon, P. G., & Cranor, L. F. "I regretted the minute I pressed share: A qualitative study of regrets on Facebook.". *Proceedings of the seventh symposium on usable privacy and security*,pp.10 (2011).
- [Humphreys 10] Humphreys, L., Gill, P., & Krishnamurthy, B. "How much is too much? Privacy issues on Twitter." *Conference of International Communication Association* (2010).
- [Mao 11] Mao, H., Shuai, X., & Kapadia, A. "Loose tweets: an analysis of privacy leaks on Twitter." *Proceedings of the 10th* annual ACM workshop on Privacy in the electronic society. (2011).
- [Hasan 13] Hasan, O., Habegger, B., Brunie, L., Bennani, N., & Damiani, E. "A discussion of privacy challenges in user profiling with big data techniques: The excess use case." *Big Data (BigData Congress), 2013 IEEE International Congress* on. (2013).
- [Wang 17] Wang, Q., Bhandal, J., Huang, S., & Luo, B. "Classification of private tweets using tweet content." Semantic Computing (ICSC), 2017 IEEE 11th International Conference on.(2017).
- [Aborisade 18] Aborisade, O., & Anwar, M. "Classification for Authorship of Tweets by Comparing Logistic Regression and Naive Bayes Classifiers." 2018 IEEE International Conference on Information Reuse and Integration (IRI). (2018).
- [Lample 16] Lample, G., Ballesteros, M., Subramanian, S., Kawakami, K., & Dyer, C. "Neural architectures for named entity recognition." arXiv preprint arXiv:1603.01360 (2016).
- [Bengio 94] Bengio, Y., Simard, P., & Frasconi, P.. "Learning long-term dependencies with gradient descent is difficult." *IEEE transactions on neural networks* Vol.5, No.2, pp.157-166 (1994).
- [Graves 05] Graves, A., & Schmidhuber, J. "Framewise phoneme classification with bidirectional LSTM and other neural network architectures." *Neural Networks* Vol.18, No.5-6, pp. 602-610 (2005).
- [Huang 15] Huang, Z., Xu, W., & Yu, K. "Bidirectional LSTM-CRF models for sequence tagging." arXiv preprint arXiv:1508.01991 (2015).
- [Bhagat 10] Bhagat, S., Cormode, G., Srivastava, D., & Krishnamurthy, B. "Prediction Promotes Privacy in Dynamic Social Networks." WOSN. (2010)
- [Acquisti 06] Acquisti, A., & Gross, R. "Imagined communities: Awareness, information sharing, and privacy on the Facebook." *International workshop on privacy enhancing technologies.* (2006)
- [Dwyer 07] Dwyer, C., Hiltz, S., & Passerini, K. "Trust and privacy concern within social networking sites: A comparison of Facebook and MySpace." *AMCIS 2007 proceedings*, pp. 339 (2007).
- [Kim 04] Kim, J. D., Ohta, T., Tsuruoka, Y., Tateisi, Y., & Collier, N."Introduction to the bio-entity recognition task at JNLPBA." Proceedings of the international joint workshop on natural language processing in biomedicine and its applications. pp.70-75 (2004).

- [Wu 15] Wu, Y., Xu, J., Jiang, M., Zhang, Y., & Xu, H. "A study of neural word embeddings for named entity recognition in clinical text." *AMIA Annual Symposium Proceedings*, Vol. 2015, p. 1326 (2015).
- [Nadeau 07] Nadeau, D., & Sekine, S. "A survey of named entity recognition and classification." *Lingvisticae Investigationes*, Vol.30, No.1, pp.3-26. (2007).
- [Gehrke 11] Gehrke, J., Lui, E., & Pass, R. "Towards privacy for social networks: A zero-knowledge based definition of privacy." *Theory of Cryptography Conference*, pp. 432-449 (2011).
- [Gomez-Hidalgo 10] Gomez-Hidalgo, J. M., Martin-Abreu, J. M., Nieves, J., Santos, I., Brezo, F., & Bringas, P. G. (2010, August). Data leak prevention through named entity recognition. In Social Computing (SocialCom), 2010 IEEE Second International Conference on (pp. 1129-1134). IEEE.

International Session | International Session | [ES] E-4 Robots and real worlds

# [3J3-E-4] Robots and real worlds: Human Interactions

Chair: Yihsin Ho (Takushoku University), Eri Sato-Shimokawara (Tokyo Metropolitan University) Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room J (201B Medium meeting room)

# [3J3-E-4-01] Automatic Advertisement Copy Generation System from Images

OKoichi Yamagata<sup>1</sup>, Masato Konno<sup>1</sup>, Maki Sakamoto<sup>1</sup> (1. The University of Electro-Communications)

1:50 PM - 2:10 PM

# [3J3-E-4-02] Eye-gaze in Social Robot Interactions Koki Ijuin<sup>2</sup>, OKristiina Jokinen Jokinen<sup>1</sup>, Tsuneo Kato<sup>2</sup>, Seiichi Yamamoto<sup>2</sup> (1. AIRC, AIST Tokyo Waterfront, 2. Doshisha University) 2:10 PM - 2:30 PM

[3J3-E-4-03] A Team Negotiation Strategy that Considers Team Interdependencies ODaiki Setoguchi<sup>1</sup>, Ahmed Moustafa<sup>1</sup>, Takayuki Ito<sup>1</sup> (1. Nagoya Institute of Technology) 2:30 PM - 2:50 PM

# [3J3-E-4-04] Identity Verification Using Face Recognition Improved by Managing Check-in Behavior of Event Attendees OAkitoshi Okumura<sup>1</sup>, Susumu Handa<sup>1</sup>, Takamichi Hoshino<sup>1</sup>, Naoki Tokunaga<sup>1</sup>, Masami Kanda<sup>1</sup> (1. NEC Solution Innovators, Ltd.) 2:50 PM - 3:10 PM

# Automatic Advertisement Copy Generation System from Images

Koichi Yamagata<sup>\*1</sup>, Masato Konno<sup>\*1</sup>, Maki Sakamoto<sup>\*1</sup>

## <sup>\*1</sup> Graduate School of Informatics and Engineering, The University of Electro-Communications

When we want to sell something, the presence of a good advertisement copy often affects sales. In this research, we develop an automatic advertisement copy generation system. Most existing systems only enter keywords, and the potential image of the product is not necessarily reflected by keywords only. We propose a method to generate advertisement copies using images as input to convey potential messages and the world view. This method uses Word2vec and color information of ad images, and both were confirmed to be effective by evaluation experiments. In the evaluation experiments, the mean score of the proposed method was significantly larger than 4 out of 7, and most of the subjects answered positively to ad copies of our method.

## 1. Introduction

Advertisement copies describe the features of products with a short number of characters and impact sentences, which are factors that greatly contribute to building brands such as companies and promoting purchase willingness of products. In recent years, there have been many researches on the generation of Japanese sentences and advertisement copy generation. In existing researches, however, they did not focus on describing potential messages and the view of the world that the producer wanted to convey.

In this research, we propose a method to generate appropriate copies reflecting color and sensitivity of given images by using a database that maintains the relationship between color and words.

There are also several prior studies on the relationship between color and sensitivity. Iiba et al. [Iiba 13] focused on the relationship between color and word sensibility, and constructed a system that recommends appropriate colors and fonts for textual sensibility images considering the effect reminiscent of the color of words. Further, Nakamura et al. [Nakamura 12] focused on the relationship between color and lyrics and constructed a music retrieval system with color as input. In this research, we focus on the relationship between colors and words and aim to automatically generate advertisement copies with color input.

Recently, in the field of natural language processing, various methods handling words as distributed expressions are increasing. Mikolov et al. [Mikolov 13] developed Word2vec which is a new model that improves the precision of vector operation of words considering the similarity between words in sentences. In this research, we utilize Word2vec to extract synonyms from a large corpus.

Existing researches on advertising copying were mainly methods of inputting words and keywords, and they were not taken into consideration to convey the latent message or the world view that the creator wished to convey. On the other hand, in this research, we construct an automatic advertisement copy generation system using images as inputs. Color information is extracted from the input image, and a large number of advertisement copies are generated by using a database that maintains the relationship between words and colors, from which adequate copies are determined as outputs.

#### 2. Methods

The flow of the proposed method is as follows:

- 1. Color information contained in given image is extracted, and some keywords are extracted from the database storing the relationship between words and colors.
- From the lyrics database, some phrases including the keywords extracted in step 1 are searched and extracted as sentence templates.
- By using a deep neural network (dnn) based classification model that classifies words used for ad copies or not trained by ad copies corpus, word candidates are selected from the word extracted in step 1.
- 4. The noun in the template sentences extracted in step 2 are replaced by the words selected in step 3, and they are taken as copy candidate sentences.
- The ad copy candidate sentences are evaluated by the similarities given by Word2vec, and the most evaluated ad copy candidate sentence is outputted.

In step 1, we utilize the word-color database constructed by [Konno 18]. This database was constructed based on the idea of the relation between sensitivities and music/colors studied by [Nakamura 11]. In this database, among the songs released between 1968 and 2017, we defined words that were often used for lyrics as primitive words (PWs), and each PW has a 45-dimensional color information vector obtained by a psychological experiment. Figure 1 shows 45 colors to define the 45-diensional color vector space. For words other than PWs that were not psychologically tested, latent semantic analysis was performed on them, and color information vectors were given based on the similarities with PWs.

In step 3, pytorch is used as a dnn library. The input data is a bag-of-words vector of a sentence to be classified, and the output data is "copy" or "not-copy".

In step 4, we use Word2vec model which learned 100,000 songs of Japanese lyrics corpus, and which contains similarities with a poetic point of view. Using this model, we calculate the similarities between words (nouns, verbs, adjectives etc.) contained in sentences and evaluate candidate sentaQSZQences of ad copies.

Contact: Koichi Yamagata, UEC, 1-5-1, Chofugaoka, Chofu, Tokyo182-8585, Japan, koichi.yamagata@uec.ac.jp, 042-443-5535



Fig. 1: 45 colors to define the 45-dimmensional color vector space.

## 3. System Evaluation

In order to evaluate our system, we conducted an evaluation experiment with 30 subjects (7 females and 23 men, mean age = 22.63). We adopted 20 advertisement images actually used from four categories (beverage and food, travel, beauty, fashion), and we prepared five ad copies for each advertisement image by five methods:

- A) original ad copy
- B) proposed method
- C) proposed method without Word2vec
- D) proposed method without using the image
- E) RNN

For example, when input image was a picture of three can coffees against the background of the night sky, an ad copy of method B (translated into English) was "You will surely drink it tonight", method C outputted "You laugh, even the deadly midnight dropping the mountain, forever", method D outputted "Eat coffee and coffee", method E outputted "Feel coffee and go".

Subjects were asked to evaluate a total of 100 advertisement copies for the images including the original ad copies and the ad copies outputted by the proposed method. The subjects evaluated the following questionnaires on a scale from 1 to 7:

- i. Is it appropriate as an ad copy in this category?
- ii. Is it appropriate as an ad copy regardless of category?
- iii. Is the grammar of the ad copy appropriate?
- iv. Does the ad copy follow the impression of the image?

Table 1 shows the results of the questionnaires (averages and standard errors of scores). We can see that the mean score of the proposed method B is much larger than 3, and most of the subjects answered positively to our method. Comparing the methods A and B, we can see that the proposed method is slightly less than the scores of original advertisements. However, it is not so bad and the difference is small. In the food category, it is confirmed that the proposed method has smaller score differences with respect to the original advertisement. Comparing the methods B and C, we

can see that the use of Word2vec is effective. Comparing the methods B and D, we can see that the use of images is effective. Comparing the methods B and E, we can see that the proposed method is much better than the RNN method.

Table 1: Results of questionnaires to evaluate each method (averages and standard errors of scores)

| ( |                   |                   |                 |                   |  |  |  |  |  |  |
|---|-------------------|-------------------|-----------------|-------------------|--|--|--|--|--|--|
|   | i                 | ii                | iii             | iv                |  |  |  |  |  |  |
| Α | $5.29 {\pm} 0.07$ | $5.75 {\pm} 0.06$ | $6.03 \pm 0.06$ | $5.37 {\pm} 0.07$ |  |  |  |  |  |  |
| В | $4.90 \pm 0.07$   | $5.17 {\pm} 0.06$ | $5.55 \pm 0.06$ | $4.22 \pm 0.08$   |  |  |  |  |  |  |
| С | $2.82 {\pm} 0.07$ | $3.15 {\pm} 0.08$ | $3.31 \pm 0.08$ | $2.51 {\pm} 0.06$ |  |  |  |  |  |  |
| D | $4.23 \pm 0.08$   | $3.92 {\pm} 0.08$ | $3.81 \pm 0.09$ | $3.20 \pm 0.07$   |  |  |  |  |  |  |
| Е | $3.18 {\pm} 0.07$ | $2.74 \pm 0.07$   | $2.05 \pm 0.06$ | $2.75 \pm 0.07$   |  |  |  |  |  |  |

## 4. Conclusion

This study proposed a method to generate advertisement copies using images as input to convey potential messages and the world view. This method uses not only Word2vec but also color information of images, and both were confirmed to be effective by evaluation experiments. In the evaluation experiments, the mean score of the proposed method was significantly larger than 4 out of 7, and most of the subjects answered positively to our method. The proposed method was slightly less than the scores of original advertisements. However, it was not so bad and the difference was small.

#### References

- [Iiba 13] Iiba, S., Doizaki, R., and Sakamoto, M.: Color and Font Recommendations based on Mental Images of Text, Transactions of the Virtual Reality Society of Japan, 18(3), pp.217-226 (2013)
- [Nakamura 12] Nakamura, T., Utsumi, A., and Sakamoto, M.: Music Retrieval Based on the Relation between Color Association and Lyrics, Transactions of the Japanese Society for Artificial Intelligence, Volume 27, Issue 3, pp. 163-175, 2012.
- [Mikolov 13] Mikolov, T., Yih, W., Zweig, G.: Linguistic Regularities in Continuous Space Word Representations, Conference of the North American Chapter of the Association for Computational Linguistics: Human Language, Technologies (NAACL-HLT-2013) (2013)
- [Konno 18] Konno, M., Suzuki, K, and Sakamoto, M.: Sentence Generation System Using Affective Image, 2018 Joint 10th International Conference SCIS and 19th ISIS, 678-682.
- [Nakamura 11] Nakamura, T., Kawanishi, K., and Sakamoto, M.: A Possibility of Music Recommendation Based on Lyrics and Color, Transactions of the Japanese Society for Artificial Intelligence, Transactions on Fundamentals of Electronics, Communications and Computer Sciences, Volume J94-A, pp.85-94, No.2 (2011)

# Eye-gaze in Social Robot Interactions – Grounding of Information and Eye-gaze Patterns

| Koki Ijuin <sup>*1</sup> | Kristiina Jokinen <sup>*2</sup>   | Tsuneo Kato <sup>*1</sup>     | Seiichi Yamamoto*1 |
|--------------------------|-----------------------------------|-------------------------------|--------------------|
|                          | <sup>*1</sup> Doshisha University | <sup>*2</sup> AIRC, AIST Toky | vo Waterfront      |

This paper examines human-robot interactions and focuses on the use of eye-gaze patterns in evaluating the partner's understanding process. The goal of the research is to understand better how humans focus their attention when interacting with a robot and to build a model for natural gaze patters to improve the robot's engagement and interaction capabilities. The work is based on the AIST Multimodal Corpus which contains human-human and human-robot interactions on two different activities: instruction dialogues and story-telling dialogues. The preliminary experiments show that there are differences in the eye-gaze patterns given expected and non-expected responses, which affects their understanding and grounding of the presented information. The paper corroborates with the hypothesis that eye-gaze patterns can be used to predict grounding process and provide information to the speaker about how to proceed with the presentation, so as to support the partner's understanding and building of the mutual knowledge. Some consideration is given to future improvements in methodology.

## 1. Introduction

The goal of the research is to understand better how humans focus their attention when interacting with a robot and to build a model for natural gaze patters to improve the robot's engagement and interaction capabilities. The work follows from the pilot study (Jokinen 2018) in which human gaze patterns were studied when they interacted with a humanoid Nao robot using the WikiTalk application (Jokinen and Wilcock 2014) which allowed the user to navigate among Wikipedia topics, and is also related to eye-gaze in second-language learning with robots (Fujio et al. 2018).

In this paper, we focus on eye-tracking technology and its use in instruction giving and story-telling activities. The hypothesis examined in the paper is that there is a difference between the interlocutor's eye-gaze patterns depending on how their understanding proceeds, i.e. if the partner's utterance is understood, misunderstood or non-understood. By measuring eye-gaze activity in the communicative context we build a model that enables estimation of the partner's level of understanding, and consequently, modification of the presentation if the partner eye-gaze signals problems in the grounding of information. Such a model can help the humanoid robot to better tailor its presentations to the human user, i.e. to enable the use of the partner's eye-gaze signals to establish an appropriate way to continue. In particular, it will enable us to study how eye-gaze is used in grounding information and creating mutual understanding of the discussion topic.

Smooth interaction requires that the partners can easily understand each other and are able to build their conversation on mutual knowledge of what has been discussed. The process of creating such mutual knowledge is called grounding, i.e. the partners ground the semantics of their utterances in the context of their interaction and the context of their world knowledge, Clark & Wilkes-Gibbs (1986).

Earlier work shows that in social situations, humans are sensitive to another person's gaze: it constructs new shared

Contact: Kristiina Jokinen, AIRC AIST Tokyo Waterfront, Koto, Aomi, Tokyo, kristiina.jokinen@aist.go.jp

knowledge, communicates experiences, and creates social linkages (Argyle & Cook, 1976; Kendon, 1967). Visual attention is important in cognitive studies (Skarrat et al. 2012), and e.g. turn-taking is commonly coordinated by gaze (Jokinen et al., 2013). Broz et al. (2015) provides an overview of the work on eye gaze and human robot interaction.

## 2. Data collection setup

Experiments were set-up using the lab's SMI eye-tracker and the Nao robot, to collect eye-tracking data. Fig 1. Shows the setup. Each participant had two conversations, one with a human partner (HHI) and one with a humanoid robot (HRI). The conversations were about 10 minutes long. One of the experimenters played the role of the human partner but was different from the one who gave instructions to the participant.

The experiment was conducted in Japanese or English depending on the participant's preferred language. The instructions were the same for both HRI and HHI conditions. Before the experiments, the participants signed a consent form and filled in a pre-experiment questionnaire of their background



and expectations. After each interaction (HRI and HHI), they filled in another questionnaire focussing on their experience in the interaction.

Data consists of 30 participants (20 Japanese, 10 English), each having both HHI and HRI conversation. The participants (10 female) were students and researchers, age 20-60, with experience on IT, but no experience on robots. Of the participants, 14 had instruction and 16 chat dialogues.

Data analysis has started using the standard gaze frequency and duration measurements, annotations and statistical analysis, to analyse the user's gaze patterns during interaction with the robot and with a human partner. Special attention is paid to gesturing and head nodding, and conversational instances such as turn-taking, feedback, and problem cases.

## 3. Annotation and Analysis

#### 3.1 Annotation Method

Annotation for duration of utterances were done with automatic silence segmentation of ELAN. The audio files which were recorded with eye tracker were used to annotate utterances. Automatic silence segmentation was conducted two times with different thresholds of loudness for determining the silence. The one with low threshold annotates both participant's and partner's utterances, and the other one with high threshold annotates only participant's utterances. The values of those thresholds were manually set by each conversation. The segmentation of partner's utterances was calculated by subtracting those automatic segmentations.

After the segmentation, the participant's utterances in humanrobot conversations were manually classified into four types from the perspective of robot's feedback to that utterances: Correct-Understood, Miss-Understood, None-Understood, and Other. Correct-Understood (CU) were tagged to the utterance which robot recognized and gave the correct feedback, Miss-Understood (MU) were tagged to the utterance which robot recognized but gave the unexpected or wrong feedback, and None-Understood (NU) was tagged to the utterance which robot did not recognized and did not give any feedback.

To annotate the eye gaze activities of participants automatically, we created the robot detection system with OpenCV3. We used cascade classifier to detect the position of robot's face in video recorded with eye sight camera of eye tracker. The robot's face was detected as rectangle, and the rectangle of robot's body was estimated with the position of robot's face. After detecting the robot's face and body, the eye gaze activities were automatically annotated into two groups; Gaze Face and Gaze Body, by judging whether the coordinates of gaze point captured by the eye tracker were in those detected rectangles or not. Fig 2 shows the result of robot detection system and gaze point of the participant.



Figure 2 Snapshot of the result of robot detection system. Red rectangle represents the robot's face, purple rectangle represent, the estimated robot's body, and red dot represents the point of participant's gaze

## 3.2 Methodology of analyses of eye gaze activities

In order to verify how the participant uses his/her eye gaze activities, we conducted quantitative analyses of eye gaze activities during utterances, pauses just before the beginning of utterances, and pauses just after the end of utterances.

We used Gazing Ratios in order to understand how the participant uses eye gaze activities during the human-robot conversations.

Gazing Ratio is defined as:

$$\frac{1}{N} \sum_{i=1}^{N} \left( \frac{DG_{(i)}}{duration of i + v} \right)$$

where  $DG_{fi}$  represents that the duration of participant's gaze toward the robot during *i*-th window. Three types of windows were used: before utterance window, during utterance window, and after utterance window. N represents the total number of windows. Gazing Ratio was calculated for each utterance type (CU, MU, and NU).

## 4. Preliminary Results

The Gazing Ratios were calculated with the data of 19 participants. Figure (ppt p. 26) shows that the temporal change of Gazing ratio for each utterance type in human-robot conversations. The results of eye gaze activities show that the participants tend to gaze away from the robot after they finishes speaking regardless of correctness of robot's feedback. After the robot gives feedback, the participants shift their gaze to the robot again. However, when the robot does not give any feedback to the participants, the participants keep gaze away to the robot for a while, and then they gaze at the robot again.

These results suggest that after the participants answer the



Figure 3 Gazing Ratios of participant during utterances, before the beginning of utterances, and after the end of utterances

question from the robot, they gaze away from the robot during the interval that the robot starts speaking, and if the robot does not start speaking, the participants soon realize that there is something wrong with the conversation so that they gaze at the robot in order to monitor what is going on to the robot.

This quantitative difference of eye gaze activities according to the robot's reaction might be useful to predict the participant's state whether he/she is waiting for the robot's feedback or not.

## 5. Conclusions

This paper has presented preliminary studies concerning eyegaze in human-robot interaction and focused especially on the understanding of the presented information. Such grounding is important for the human-robot interaction to progress smoothly and for the robot to exhibit context-aware capability, i.e. be able to take the user's multimodal signals in the given conversation al context into account. The work is based on the AIST Multimodal Corpus which includes eye-tracking data on natural interactions between two humans and between a human and a robot.

The work continues on further analysis and annotation of the corpus and building computational models of the use of eye-gaze in signaling the interlocutors' understanding. As the corpus contains both human-human and human-robot interactions in similar conversational situations, further research is focused on studying the differences in the human gaze behaviour in the two types of conversational settings. This will deepen our knowledge of the function of gazing in interaction in general and the role of being able to detect and analyse gaze-patterns also in human-robot interactions.

#### Acknowledgement

This paper is based on results obtained from *Future AI and Robot Technology Research and Development Project* commissioned by the New Energy and Industrial Technology Development Organization (NEDO).

## References

- Argyle, M. and Cook, M. (1976). Gaze and Mutual Gaze. Cambridge University Press, Cambridge.
- Broz, F., Lehmann, H., Mutlu, B., and Nakano, Y. (Eds.) (2015). Gaze in Human-Robot Communication. John Benjamins Publishing Company.
- Clark, H. & Wilkes-Gibbs D. Referring as a collaborative process. Cognition 22:1-39, 1986
- Fujio, S., Ijuin, K., Kato, T., Yamamoto, S. (2018). Measurement of Gaze Activities of Learners with Joining-in-type RALL System, Proceedings of the 2018 IEICE General Conference, March 2018 (In Japanese)
- Jokinen, K., Furukawa, H., Nishida, M., Yamamoto, S. (2013). Gaze and Turn-taking behaviour in Casual Conversational Interactions. ACM Transactions on Interactive Intelligent Systems (TiiS) Journal, Special Section on Eye-gaze and Conversational Engagement, Vol 3, Issue 2.
- Jokinen, K. and Majaranta, P. (2013). Eye-Gaze and Facial Expressions as Feedback Signals in Educational Interactions. In D. Griol Barres, Z. Callejas Carrión, R. López-Cózar Delgado (Eds.) Technologies for Inclusive Education: Beyond Traditional Integration Approaches. Chapter 3, pp.38-58. Hershey, PA: Information Science Reference, IGI Global.

- Jokinen, K. and Wilcock, G. "Multimodal Open-domain Conversations with the Nao Robot." In Natural Interaction with Robots, Knowbots and Smartphones - Putting Spoken Dialog Systems into Practice. Springer Science+Business Media, 2014. pp. 213-224
- Kendon, A. (1967). Some functions of gaze-direction in social interaction. Acta Psychologica, 26 (1): 22–63.
- Skarratt, P.A. et al. 2012. Visual cognition during real social interaction. *Frontiers in human neuroscience*. 6, (Jan. 2012), 196

# A Team Negotiation Strategy that Considers Team Interdependencies

Daiki Setoguchi<sup>\*1</sup> Ahmed Moustafa<sup>\*1</sup> Takayuki Ito<sup>\*1</sup>

<sup>\*1</sup> Nagoya Institute of Technology

## ABSTRACT

In automated negotiation, team negotiation is poised as one of the most important negotiation techniques. A team is a group where multiple interdependent agents participate in negotiations as a negotiating party during the course of negotiations. Existing team negotiation strategies did not consider the change in decisions due to the interdependencies within the team. In this paper, we propose a team negotiation strategy that considers the interdependencies within the same team. Towards this end, in the proposed negotiation strategy, we first set the parameters that represent the interdependencies that exist within the team in both directions. Thereafter, a voting process is performed in each direction. By weighting the degree of dependency of each team member, a change in agent decision due to its dependency relationships is measured. A comparative experiment with the existing team negotiation strategies showed the efficiency of the proposed strategy.

## 1. Introduction

Numerous researches on automated negotiation agents have been done in multiagent research fields [1, 2]. Negotiation has emerged as an important social activity wherein different people with different targets seek to reach an agreement in order to satisfy each other's interests and is indispensable in the real world where various goals exist. Therefore, automated negotiation is attracting attention as it can bring the benefits of negotiation in order to solve real life problems. In this regard, it is thought that it can be applied to route change interference and scheduling system in e-commerce system and transportation system [1, 2, 3]. One of the most important automated negotiation techniques is team negotiation [4, 5]. A team is a group where multiple interdependent agents participate in negotiations as a negotiating party during negotiations. There are numerous negotiation scenarios between multiple groups in the real world such as negotiations between a couple and a real estate agent, a negotiation between a friend and a travel agency.

In these scenarios, the team in the negotiation participates in the negotiation as a single party, but cannot be regarded as one agent. This is because they may have internal conflicting preferences when making team decisions. Even if one of the team members is unlikely to accept the proposal from the negotiating partner, this proposal may be compromised and accepted when another member accepts it. In this way, since all the team members have individual preference information and are affected by the decision of other agents, linear preference information cannot be expressed as one agent. Therefore, it is important to negotiate with the dependency amongst the team members.

However, the existing team negotiation approaches did not consider interdependencies within the team during negotiation [4, 5]. As teams are interdependent by nature in team negotiations, interdependencies must be considered during these negotiations. For example, when an agent in a team accepts the opponent's proposal, the agent that depends on that agent becomes more likely to accept the same opponent's proposal by the degree of dependency. In this context, it becomes necessary to evaluate these changes in decisions due to dependencies within the team.

In this paper, we propose a team negotiation strategy that considers the dependency relationships within this team. The proposed negotiation strategy, bidirectionally sets the parameters that express these dependency relationships that exist within the team. By setting bidirectional dependencies within the team, it becomes possible to express unilateral dependencies. In each mechanism, when the voting process is performed, by weighting the dependency degree of each team member, change of agent decision according to the dependency relation is expressed.

#### Proposed Team Negotiation Strategy

First, we define interdependencies within the team as follows. Let parameter w(a, b) define Agent A 's dependency on Agent B, and each team member sets parameters to all other team members according to its dependency relationships. This is defined as the degree of dependency from agent A to agent B. When there are N team members, the dependency W(a) that Agent A receives can be defined by Equation (1).

$$W(a) = \Sigma w(i, a) \tag{1}$$

Where w(i, a) is the degree of dependency that Agent A receives from Agent i. For example, when there are three team members, their interdependencies can be represented as shown in Figure 1.



Figure 1: Dependency relationships amongst three team members

As shown in Figure 1, we can see that the dependencies between Agent A and Agent B, Agent B and Agent C, Agent A

Contact: Daiki Setoguchi, Nagoya Institute of Technology, setoguchi.daiki@itolab.nitech.ac.jp

and Agent C can be defined from both directions. By this, it can also be defined in a state that depends unilaterally.

Members with a high degree of dependency who receive it can be regarded as members with high decision and speaking rights within the team because other members are strongly influenced by their opinion. Therefore, members with high dependence are members of high importance within the team, and if the utility value of members with high importance is high, other members can easily compromise. Conversely, members with low importance depend heavily on other members, so they depend on the utility values of other members. Since the importance value in the team at this time has a difference in importance depending on the members, the weighted sum by importance rather than the sum of the utility values of simple team members is the utility value of the team. For example, utility values of members with high importance are simply added with a simple summation, but other members are influenced by the dependency within the team, and the utility value increases. Therefore, it is necessary to calculate the increment of the utility value due to the dependency relationship. Therefore, when the utility value of Agent A is assumed to be u(a), the utility value of the team can be defined by Equation (2).

$$U = \Sigma u(i) W(i) \tag{2}$$

Where u(i) is the utility value obtained by Agent i. W(i) is the importance level of Agent i and can be regarded as the decision power that Agent i has in the team. In this research, we propose a novel team negotiation strategy that maximizes the utility value U of the whole team.

## 2.1 Accept/Reject Opponents' Offer

The Accept mechanism for a team determines whether to accept the proposed bid from the negotiating partner. Towards this end, all team members need to vote regarding the proposed bid by the opponent. Let s(a) be the acceptance function employed by Agent A in order to assess the proposed bid. s(a) is a function that returns 1 when Agent A chooses acceptance, and 0 if not. Here, the acceptance function is defined by Equation (3).  $f = \Sigma s(i) W(i)$ (3)

Where s(i) represents s is a variable that returns 0 or 1 as to whether or not the Agent i accepted. W(i) is the importance level of Agent i. In other words, it is synonymous with W(i) in the team judged to be accepted when Agent i accepted. Therefore, when voting is done, it is necessary to obtain the importance degree of the accepted member as the voting right and the acceptance function as the sum of the importance degree. As a result of voting in this way, accept as a team if the acceptance function exceeds half the size of the team. Since the acceptance function is the sum of the importance of the received members in the team, when it exceeds half the size of the team, members who exceed the majority in the team accepted the other party's bid. Therefore, accept the proposal of the negotiating partner as a team's decision. Otherwise, the team starts the offer proposal mechanism.

## 2.2 Offer Proposal

The Offer mechanism decides and transmits the bid to be proposed to the negotiating partner as a team. The proposed approach employs a voting mechanism that selects widely accepted candidates such as Borda count [6]. Submit the bid that each team member wishes to propose within the team. After that, each team member evaluates all the submitted bids by using its own utility function. Let the utility value obtained when Agent A accept Agent B's proposed Bid is  $u'_{A(b)}$ . Agent A has a dependence on agent B for w(a, b), and it is necessary to weight it when evaluating it depending on the degree of dependency. The utility value  $u_{A(b)}$  for Agent B's proposed Bid for Agent A is as follows. Next, we evaluate and rank all the bids submitted within the team by Equation (4).

$$u_{A(b)} = u'_{A(b)} \{ 1.0 + w (a, b) \}$$
(4)

Where  $u'_{A(b)}$  is the utility value when accepting B's proposed. Also, w(i, a) is the degree of dependency that Agent A receives from Agent i. Assign the score from the set [0, |A| - 1] to the submitted bid along with its ranking. | A | is the total number of bids submitted. All team members make this ranking, and the highest score bid is sent to the negotiating partner as the team's proposed bid.

## Experiment And Discussion

In this experiment, we use GENIUS which is a generalpurpose negotiation platform as evaluation environment [7]. GENIUS is an open source software, aimed at negotiation simulation and the development of automated negotiation agents. Since GENIUS supports Java API that is necessary for agent development, development becomes easy with basic knowledge of Java programming. We set the experiment setting as follows. The Automated Negotiating Agents Competition (ANAC), an international competition of automated negotiation agents, employs this simulator, where several researches on automated negotiation agents are actively conducted. In addition, the negotiation problems used in the past ANAC competition have been prepared as a standard, and they support the development of an effective negotiation strategies in various negotiation problems. We set the experiment setting as follows.

- We set up 3 team members and use 3 agents of Atlas 3, Caduceus, PonPokoAgent.
- We also used Farma as a negotiating partner. All the agents used for the experiments received high ranking results at ANAC competitions.
- We used two parts, partydomain and Domain 8, implemented in GENIUS as a negotiation domain.
- Negotiating with setting the maximum time of negotiations to 180 turns, the agents negotiated 10 times for each team member's permutation. That is, 3! × 10 = 60 automated negotiations were made in one negotiation domain.
- We set the following two interdependencies in the team.

|         | Agent A | Agent B | Agent C |
|---------|---------|---------|---------|
| Agent A | 0.5     | 0.2     | 0.3     |
| Agent B | 0.3     | 0.6     | 0.1     |
| Agent C | 0.2     | 0.1     | 0.7     |

Table 1: Dependency within the team

|         | Agent A | Agent B | Agent C |
|---------|---------|---------|---------|
| Agent A | 0.6     | 0.2     | 0.2     |
| Agent B | 0.3     | 0.5     | 0.2     |
| Agent C | 0.3     | 0.3     | 0.4     |

 Table 2: Dependency within the team



Figure 2: Average negotiation result (Table1)



Figure 3: Average negotiation result (Table2)

The results of the experiment are shown in Figure 2 and Figure 3. As demonstrated in Figure 2, the results show that the score increases by about 0.05 for partydomain and about 0.14 for Domain 8. Since the number of team members is three, the increase in score per person is increased by about 1.8% for party domain and about 4.7% for Domain 8. As demonstrated in Figure 3, the results show that the score increases by about 0.04 for partydomain and about 0.11 for Domain 8. Since the number of team members is three, the increase in score per person is increased by about 0.04 for partydomain and about 0.11 for Domain 8. Since the number of team members is three, the increase in score per person is increased by about 1.3% for party domain and about 3.7% for Domain 8. Table 3 shows the results of examining the number of agreement proposal candidates in order to investigate the difference in increment by the negotiation domain.

| Domain Name | Issues | Total Bid |  |  |  |
|-------------|--------|-----------|--|--|--|
| partydomain | 6      | 3072      |  |  |  |
| Domain8     | 8      | 6561      |  |  |  |

Table 3: Comparison of size of negotiation space

From Table 3, when comparing partydomain and Domain 8, the total number of bids is larger in Domain 8. As the total number of Bids increases, the options of the proposed Bid spread, so the probability of agreeing on the same agreement decreases and the difference in the agreement proposal based on the strategy is largely reflected. From Figure 2, Figure 3 and Table 3, it can be seen that the utility value of the team is increasing as the total number of agreement proposals is larger. Therefore, as the total number of agreement proposals increases, the difference between the utility values of existing teams and the proposed method teams increases, so it can be concluded that the proposed method adapts to the utility value of the team that changes according to the dependency relationship.

## 4. Conclusions And Future Work

In this paper, we proposed a novel negotiation strategy that considers the interdependencies within the team in team negotiation scenarios. Towards this end, the proposed strategy implements appropriate considerations by setting the parameters that represent the interdependencies within the team, and then, using these parameters to weigh the relationship in each direction. A comparative experiment with the existing team negotiation strategies demonstrated the efficiency of the proposed strategy. As for future research, planned to investigate how to quantify the parameters that represent the interdependencies in actual negotiation problems. In addition, it become very difficult to simulate the actual negotiation scenarios unless there is a method to formulate appropriately from these scenarios. As another research direction, we also plan to study the change in the dependency score due to the change in the negotiating partner. As the negotiation partner changes, the result changes accordingly, so we plan to investigate how the agreement proposals change with the proposed approach.

### References

- Kanamori, R., Takahashi, J. and Ito, T. "Evaluation of Traffic Management Strategies with Anticipatory Stigmergy", Journal of Information Processing, Vol.22, No.2(2014).
- [2] Sen, S. and Durfee, E. H. "On the design of an adaptive meeting scheduler.", Artificial Intelligence for Applications, 1994., Proceedings of the Tenth Conference on. IEEE (1994).
- [3] Kraus, S. "Strategic Negotiation in Multiagent Environments", MIT press (2001).
- [4] Sánchez-Anguix, Víctor, V., Botti, V., Julián, V., & García-Fornes, A. "Analyzing intra-team strategies for agent-based negotiation teams." The 10th International Conference on Autonomous Agents and Multiagent Systems-Volume 3. International Foundation for Autonomous Agents and Multiagent Systems, 2011.
- [5] Sanchez-Anguix, V., Julian, V., Botti, V., & Garcia-Fornes, A. "Reaching unanimous agreements within agent-based negotiation teams with linear and monotonic utility functions." IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics) 42.3: 778-792, 2012.
- [6] Nurmi, Hannu. "Voting systems for social choice." Handbook of Group Decision and Negotiation. Springer, Dordrecht, 2010. 167-182.
- [7] Lin, R., Kraus, S., Baarslag, T., Tykhonov, D., Hindriks, K., & Jonker, C. M. "Genius: An integrated environment for supporting the design of generic automated negotiators." Computational Intelligence 30.1 (2014): 48-70.

# Identity Verification Using Face Recognition Improved by Managing Check-in Behavior of Event Attendees

Akitoshi Okumura<sup>\*1</sup> Susumu Handa<sup>\*1</sup> Takamichi Hoshino<sup>\*1</sup> Naoki Tokunaga<sup>\*1</sup> Masami Kanda<sup>\*1</sup>

\*1 NEC Solution Innovators, Ltd.

This paper proposes an identity-verification system using continuous face recognition improved by managing check-in behavior of event attendees such as facial directions and eye contact (eyes are open or closed). Identity-verification systems have been required to prevent illegal resale such as ticket scalping. The problem in verifying ticket holders is how to simultaneously verify identities efficiently and prevent individuals from impersonating others at a large-scale event at which tens of thousands of people participate. We previously developed Ticket ID system for identifying the purchaser and holder of a ticket. This system carries out face recognition after attendants check-in using their membership cards. The average facerecognition accuracy was 90%, and the average time for identity verification from check-in to admission was 7 seconds per person. The system was proven effective for preventing illegal resale by verifying attendees of large concerts; it has been used at more than 100 concerts. The problem with this system is regarding face-recognition accuracy. This can be mitigated by securing clear facial photos because face recognition fails when unclear facial photos are obtained, i.e., when event attendees have their eyes closed, are not looking directly forward, or have their faces covered with hair or items such as facemasks and mufflers. In this paper, we propose a system for securing facial photos of attendees directly facing a camera by leading them to scan their check-in codes on a code-reader placed close to the camera just before executing face recognition. The system also takes two photos of attendees with this one camera after an interval of about 0.5 seconds to obtain facial photos with their eyes open. The system achieved 93% face-recognition accuracy with an average time of 2.7 seconds per person for identity verification when it was used for verifying 1,547 attendees of a concert of a popular music singer. The system made it possible to complete identity verification with higher accuracy with shorter average time than Ticket ID system.

## 1. Introduction

Identity verification is required in an increasing number of situations. Let us take an example of a case in which many people are admitted to an event. It used to be that in such cases, having a document, such as a ticket or an attendance certificate, checked was sufficient to gain entry; the need for personal authentication was not seriously considered due to the limited amount of time for admitting all participants. Many events with high ticket prices had designated seating, so it was not necessary to assume that some tickets may have been counterfeit. However, the advent of Internet auctions in recent years has made it easier to buy and sell tickets at the individual level. This has resulted in an increase in illegal ticket scalping, i.e., tickets being purchased for resale purposes. Equity in ticket purchasing is required not only by ticket purchasers but also by event organizers and performers [Chapple 16]. Consequently, event organizers have had to deal with complaints about malicious acts by undesignated individuals who take advantage of fans by buying and selling tickets on the Internet. In many cases, therefore, any ticket buying and selling outside the normal sales channels is prohibited. Ticket-sales terms now often stipulate that tickets are invalid when people apply for them using a pseudonym or false name and/or false address or when they have been resold on an Internet auction or through a scalper. Illegally resold tickets have in fact been invalidated at amusement parks and concert halls [JE 15]. Verification has therefore become a more important social

issue than ever before. The problem in verifying ticket holders is how to simultaneously verify identities efficiently and prevent individuals from impersonating others at a large-scale event at which tens of thousands of people participate. To solve this problem, we previously developed Ticket ID system that identifies the purchaser and holder of a ticket by using facerecognition software [Okumura 17]. Since the system was proven effective for preventing illegal resale by verifying attendees at large concerts of popular music singers and groups, they have been used at more than 100 concerts. However, it is necessary to improve face-recognition accuracy because face recognition fails when unclear facial photos are obtained, i.e., when event attendees have their eyes closed, not looking directly forward, or have their faces covered with hair or items such as facemasks and mufflers. We propose an identity-verification system for attendees of large-scale events using continuous face recognition improved by check-in behavior of event attendees such as facial directions and eye contact (eyes are open or closed).

## 2. Ticket ID System Using Face Recognition

## 2.1 Outline of Ticket ID System

Thorough verification for preventing individuals from impersonating others is in a trade-off relationship with efficient verification. The problem in verifying ticket holders is how to simultaneously verify identities efficiently and prevent individuals from impersonating others at a large-scale event in which tens of thousands of people participate. The solution should be suitable within practical operation costs for various

Akitoshi Okumura, NEC Solution Innovators, Ltd.

<sup>2-6-1</sup> Kitamikata, Takatsu-ku, Kawasaki, Kanagawa 213-8511

sized events held in various environments including open air. As a practical solution combining efficiency, scalability, and portability for a large-scale event, we developed Ticket ID system, which consists of two sub-systems, a one-stop face recognition system (one-stop system) and a check-in system [Okumura 17]. The one-stop system uses the high-speed and high-precision commercial face recognition product NeoFace [NEC 17]. The one-stop system is implemented in a commercially available tablet terminal, and the recognition result is displayed with regard to the facial-photo information of 100,000 people within about 0.5 seconds. The check-in system supports identity verification of attendees. A venue attendant checks in by placing his/her membership card on the card reader and initiates face recognition by the taking of his/her photos. The following steps make up the ticket-verification procedure from ticket application to admission [Okumura 17]:

Step 1: Tickets to popular events are often sold on a lottery basis at fan clubs or other organizations where membership is registered. Individuals applying for tickets register their membership information as well as their facial photos. In the same way for an ordinary ID photo, the registered facial photo is a clearly visible frontal photo taken against a plain background. The face must not be obstructed by a hat, sunglasses, facemask, muffler, or long hair.

Step 2: Event organizers notify ticket winners, i.e., successful applicants that have been selected.

Step 3: On the day of the event, venue attendants receive membership cards from attendees, and use a card reader to verify that attendants entering the venue are successful applicants at the event venue, as shown in Fig. 3.

Step 4: The attendants use the one-stop system to confirm that the photo taken at the time of application and the collation photo show the same person. The attendants explain the verification through face recognition to the attendees and instruct them where to stand in front of the terminal. Then, they execute the facerecognition process using the terminal to confirm the attendees are those who applied for the tickets.

Step 5: The admission procedure is carried out in accordance with the face-authentication results.

#### 2.2 Problems with One-stop System

The average time for identity verification from check-in to entry admission was 7 seconds per person, and the average accuracy of face recognition was 90%. It is necessary to improve face-recognition accuracy by securing clear facial photos because face recognition fails when unclear facial photos are obtained, i.e., when event attendees have their eyes closed, are not looking directly forward, or have their faces covered with hair or items such as facemasks and mufflers. When face recognition fails, venue attendants have to verify attendees carefully by direct visual inspection. This increases the mental and physical burden on attendants, which makes attendees have an unreliable impression of the system. When face-recognition accuracy is 90%, two attendees are successively verified without face recognition failure with a probability of 81%. This means that 19% of attendees may experience face-recognition failure or observe it in front of them. Improving face-recognition accuracy is critical for decreasing attendants' stress and attendees' waiting time.

## 3. Continuous-Face-Recognition System

## 3.1 Managing Check-in Behavior of Attendees

We propose an identity-verification system for attendees of large-scale events using continuous face recognition improved by managing check-in behavior of the attendees. The proposed system enables attendees to check in themselves (check-in doers are not attendants, but attendees). While the previous system is equipped with a card reader, the proposed system verifies attendees with a QR code reader set up at the same position for recognizing faces of attendees standing still in front of a venue attendant, as shown in Fig. 4. Managing facial directions and eye contact are two major issues regarding facial recognition. The proposed system addresses these issues with the following methods:

#### 1) Managing facial direction

The proposed system secures facial photos of attendees directly facing a camera by leading them to scan their QR codes just before executing face recognition. We found most people spontaneously look at the code-reader, i.e., turn their faces to the reader during check-in. The face-recognition camera of the proposed system is placed at the same position as the code-reader, as shown in Fig. 4, which makes it possible to take an attendee's photo when directly facing the camera when the photo is taken just after check-in.



Fig. 3 One-stop face-recognition system



Fig. 4 Continuous face-recognition system

#### 2) Managing eye contact

The proposed system uses a continuous-face-recognition system for accepting two photos of attendees successively taken with a single camera after an interval of 0.5 seconds to obtain facial photos with their eyes open. Few people spontaneously keep their eyes closed longer than 0.5 seconds because human blink duration is on average between 0.1 and 0.4 seconds [Bentivoglio 97]. Few people spontaneously blink twice in 0.5 seconds because human blink rate is between 7 and 17 per minute [Nosch 16]. It is possible to manage eye contact of attendees when we take the first photo at the same time of them scanning a QR code and then take the second photo after an interval of 0.5 seconds with a single camera.

## 3.2 Configuration of Proposed System

Figure 5 shows a configuration of the proposed system including event-attendee control platform and continuous-facerecognition system. The configuration is almost the same as that of the previous system [Okumura 17] except for a check-in doer and a QR code reader. While check-in doers of the previous system are attendants, those of the proposed system are attendees. While the previous system uses a card reader to scan membership cards, the proposed system uses a QR-code reader to scan tickets with QR codes. When attendees check in at a location that has the proposed system installed, they scan their QR-coded tickets. The attendee-management system provides the attendees the tickets in advance of the event day. Attendees can obtain tickets with QR codes with their smartphones. The ticket has the concert name, date and time, venue, QR code containing attendee's membership information, his/her name, seat number, registered photos, and so on.



Fig. 5 Configuration of proposed system

#### 3.3 Identity-Verification Procedure

An attendee's identity is verified with the procedure shown in Fig. 6. When attendees scan their QR codes, a check-in system performs ticket-winner check as well as showing the attendants the member information of the attendees, which is retrieved from the ticket-winner database with search keys of membership numbers obtained through a QR code reader. Scanning a QR code automatically activates continuous face recognition by taking two photos of the attendee after an interval of 0.5 seconds. When either photo is verified with the registered photo of the attendee, face recognition is successful. When attendees are

ticket winners and face recognition is successful, the verification is successful. Otherwise, verification fails.



Fig. 6 Flowchart of verification

#### 3.4 Operational Steps

The proposed system has the following operational steps from ticket application before the event day to admission on the event day:

Step 1: Ticket application is the same as that of the one-stop face-recognition system described in Section 2.1.

Step 2: Event organizers notify ticket winners, i.e., successful applicants that have been selected. They can obtain attendee's tickets including their QR codes and registered facial photos.

Step 3: At the check-in site on the event day, attendees scan their QR codes with the code reader according to attendant's instruction.

Step 4: Attendants can confirm that attendees are successful applicants who applied for the tickets.

Step 5: If identity is verified, the attendee is admitted entry. Otherwise, identity is verified by an attendant with direct visual inspection of the facial photo on the ticket.

## 4. Demonstration of Proposed System

#### 4.1 Results

Six sets of the proposed system were used for a popular concert on November 17, 2018 in Tottori prefecture, Japan. Face recognition was carried out for 1,547 attendees. Face-recognition accuracy was 93%, and identity-verification time was 2.7 seconds on average in cases in which face recognition was not successful. No cases of attendees impersonating others were reported for the concert. The false reject rate (FRR) was 7% and the false accept rate (FAR) was 0%. There were two reasons for recognition failure: The first was that faces of incorrect attendees were detected when photos contained other attendees behind the correct attendee. The second was that the attendees had their faces covered with hair or items such as facemasks and mufflers. Failure was not observed due to the fact that attendees had their eyes closed or were not directly facing a camera.

#### 4.2 Discussion

Table 1 compares the results of our previous and proposed systems. The average identity-verification time was 4.3 seconds shorter than that of the previous system because of changing check-in doers and improving face-recognition accuracy. The proposed system does not require handing over a membership

card between attendants and attendees. The face-recognition accuracy of the proposed system was 3% higher than that of the previous system. This resulted in decreasing the number of direct visual inspections, which increases identity-verification time.

There was a problem with face detection in that faces of incorrect attendees were detected when photos contained other people behind an attendee. This can be solved by choosing the face with the largest face area among all the detected faces. Face recognition failed when attendees had their faces covered with hair or items. There were no cases in which attendees had their eyes closed or were not directly facing a camera in the two successive photos, i.e., in the first photo and second photo taken after 0.5 seconds. Managing facial direction and eye contact of attendees worked as expected. It is difficult to solve the problem of when the faces of attendees are covered with hair or items because there would be no differences between the first and second photos on the attendee's covered faces. The attendee's cooperation is necessary for solving this problem.

|                                 | Previous system  | Proposed system                           |  |  |
|---------------------------------|--|---|--|--|
| Identity-<br>verification time  | 7 seconds  | 2.7 seconds                               |  |  |
| Face-recognition accuracy       | 90%  | 93%                                       |  |  |
| Check-in doer                   | Attendant  | Attendee                                  |  |  |
| Reasons for recognition failure | Attendees had their eyes closed.                         |   |  |  |
|                                 | Attendees were<br>not directly<br>facing camera.         |   |  |  |
|                                 |  | Incorrect attendee's faces were detected. |  |  |
|                                 | Attendees had their faces covered w their hair or items. |   |  |  |

Table 1 Results of our previous and proposed systems

## 5. Future Issues

Faces of incorrect attendees were detected when they stood behind a correct attendee. This can be solved by choosing the face with the largest face area among all the detected faces. If this improvement does now work, we are preparing a partitioning screen to be placed behind the correct attendee to prevent incorrect attendees from being photographed.

The largest obstacle remaining to improving face-recognition accuracy is that of covered faces. This problem could be solved with attendee's cooperation. We have been developing an identity-verification system using face recognition from selfies taken by attendees with their smartphone cameras [Okumura 18]. Self-photographing is regarded as helpful for securing clear facial photos because attendees can control intrinsic parameters such as their expressions, facial hair, and facial directions. We are planning to use of this system with the proposed system for solving the problem of covered faces.

The proposed system has been widely reported in the mass media. The system is highly regarded from reviews on the Internet [Hachima 18]. It was used to carry out face recognition for more than 100,000 attendees in 2018. Though no cases of attendees impersonating others were reported for any of these events, i.e., the FAR was 0%, the FAR should be more carefully examined from the view-point of preventing impersonation. It is necessary to evaluate the robustness against impersonation with pseudo attack tests. These tests should include disguise and lookalike tests. A disguise test makes people's facial appearances as similar to each other as possible by using facial paraphernalia such as facial hair, glasses, and makeup. A lookalike test is conducted for those, such as twins or similar looking siblings, with similar facial features. A disguise test will reveal considerable disguise methods and help in creating operational manuals for venue attendants to detect these methods. A lookalike test will disclose the technical limitations of current face-recognition methods and help in establishing nextgeneration technology.

## 6. Conclusion

We proposed an identity-verification system for attendees of large-scale events using continuous face recognition improved by managing check-in behavior of the attendees. The proposed system could secure facial photos of attendees directly facing a camera by leading them to scan their QR codes on a QR-code reader placed close to the camera just before executing face recognition. The system took two photos of attendees with this one single camera after an interval of 0.5 seconds to obtain facial photos with their eyes open. The system achieved 93% facerecognition accuracy with an average identity-verification time of 2.7 seconds per person when it was used for verifying 1,547 attendees at a concert of a popular music singer. The system made it possible to complete identity verification with higher accuracy with shorter average time than the previous system. We plan to improve our system to further streamline the verification procedure.

## References

[Chapple 16] Chapple,J.: Ticket resale? NO, says Japanese music business (Aug. 23, 2016), available from < https://www.iq-mag.net/2016/08/ticket-resale-no-says-japanese-live-business-resaleno/#.W 01Jk8Un3g>.

[JE 15] JE fandom: Johnny's Tracks Illegally Sold Tickets for Arashi's Japonism Tour (Oct. 25, 2015), available from <a href="https://jnewseng.wordpress.com/2015/10/25/johnnys-tracksillegally-sold-tickets-for-arashis-japonism-tour/">https://jnewseng.wordpress.com/2015/10/25/johnnys-tracksillegally-sold-tickets-for-arashis-japonism-tour/</a>. [Okumura 17] Okumura, A., etc.: Identity Verification of Ticket

Holders at Large-scale Events Using Face Recognition, *Journal* of *Information Processing*, Vol. 25, pp. 448-458 (Jun. 2017) [NEC 17] NEC: Face Recognition, available from <

 $https://www.nec.com/en/global/solutions/safety/face\_recognition/index.html>.$ 

[Bentivoglio 97] Bentivoglio AR, etc.: Analysis of blink rate patterns in normal subjects, Mov Disord. 12(6) pp1028-1034, (Nov. 1997)

[Nosch 16] Nosch DS, etc.; Relationship between Corneal Sensation, Blinking, and Tear Film Quality, Optom Vis Sci. ,93(5) pp471-481, (May. 2016)

[Okumura 18] Okumura, A., etc: Identity Verification for Attendees of Large-scale Events Using Face Recognition of Selfies Taken with Smartphone Cameras, *Journal of Information Processing*, Vol. 26, pp. 779-788 (Nov. 2018)

[Hachima 18] Hachima: Concerts of Hikaru Utada were successfully operated, available from < http://blog.coutany.com/crabing/0218887.html>\_(Nov 20

http://blog.esuteru.com/archives/9218587.html>. (Nov.2018) (in Japanese)

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

# [3A3-J-13] AI application: enterprize and management

Chair:Kazutoshi Sasahara Reviewer:Hiroto Yoneno

Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room A (2F Main hall A)

| [3A3-J-13-01] | Study on the mechanism of occurrence of quality spoofing by<br>"Conjecture" "air" and "water" using business game            |
|---------------|--|
|               | $\bigcirc$ HIROYASU SEITA $^1$ , Setsuya Kurahashi $^1$ (1. Tsukuba university )   |
|               | 1:50 PM - 2:10 PM  |
| [3A3-J-13-02] | Detecting Technology Portfolios in the Semiconductor Industry  |
|               | $\bigcirc$ Bohua Shao <sup>1</sup> , Kimitaka Asatani <sup>1</sup> , Ichiro Sakata <sup>1</sup> (1. the University of Tokyo) |
|               | 2:10 PM - 2:30 PM  |
| [3A3-J-13-03] | Relationships between mission statements and protability in scal year  |
|               | 2016 (Preliminary Result)  |
|               | $\bigcirc$ Ryozo Kitajima $^1$ , Ryotaro Kamimura $^2$ , Hiroyuki Sakai $^1$ , Kei Nakagawa $^3$ (1. Seikei                  |
|               | University, 2. IT Education Center, Tokai University, 3. Nomura Asset Management Co.,  |
|               | Ltd.)  |
|               | 2:30 PM - 2:50 PM  |
| [3A3-J-13-04] | Influences caused by faultlines on the organizational performance.   |
|               | $\bigcirc$ Fumiko Kumada <sup>1</sup> , Setsuya Kurahashi <sup>1</sup> (1. University of Tsukuba)                            |

2:50 PM - 3:10 PM

# ビジネスゲームを用いた「忖度」「空気」と「水」による品質詐称発生 メカニズムに関する研究

Study on the mechanism of occurrence of quality spoofing by "Conjecture" "air" and "water" using business game

脊板弘康<sup>\*1</sup> Hiroyasu Seita 倉橋節也\*2 Setsuya Kurahashi

\*1 \*2 筑波大学システム情報工学研究科リスク工学専攻 University of Tsukuba Faculty of system and information Engineering Department of Risk Engineering#1 #2

## Abstract

The quality spoofing case continues in a part of Japanese companies that have been sweeping the world with its top priority on customer first principles and raising quality first principles. In these cases of misrepresentation, as seen in the Akafuku case of the food fraud, there are cases in which the conjecture to a specific target worked. Until now, each company has been absolutely quality based on quality first principle, why is it so fragile and crumbling why?

In this research, we use a business game based on the framework of the Giddens 's theory of structuring to show that "quality" is absolutely made with "Conjecture" and "air", which can be said as unique culture of Japan as Mr. Shichihei Yamamoto says, and furthermore that it is collapsed due to real problems,.

## 1. 研究の背景

## 1.1.問題意識~日本企業の品質第一主義の組織文化と企業不 祥事

生産活動においてZD運動はQC活動とともに日本の品質管 理において主要な行動規範の一つになっており、近年におい ても日本の物造り産業における生産活動やサービス産業でも重 要視され、多大な貢献があるといわれている。一方で、不良ゼロ の合言葉は品質偏重による管理コスト増大、ひいては高コスト 体質の原因になっているとの指摘もある。[脊板 .18]が行った 研究では、生産の第一線において品質や生産コスト決定の中 心的役割を担う工程エンジニアの不良発生時の問題解決行動 を分析することにより、コストが重要視されている生産現場にお いても品質がコストに比較して圧倒的に重視されていることが明 らかにされた。

しかし、近年においても神戸製鋼、東洋ゴム、タカタベルトな ど日本を代表する製造メーカーで品質詐称事件が相次いで発 生しているのはなぜであろうか。

- 2. 本研究テーマに関する既存研究
- 2.1. 詐称が起こるメカニズム

米国の組織犯罪研究者[Cressey.73]は詐称が発生メカニズムを 「不正のトライアングル理論(The Fraud Triangle)」として次の ように体系化した。

- ①「プレッシャー」(Pressure) ~ 例えば、納期や生産性に関 する過大な欲求を満たさねばならないなど心理的圧力。
- (Opportunity)~不正を行おうとすれば可能な環 境が存在する状態。

③「正当化」(Rationalization)~「従業員のコンプライアンスの意識の欠如」や会社の仕組みが脆弱で詐称を起こしても発覚しにくいといった環境や仕組みに由来するもの。

これらは、多くの詐称事例に共通して見られるものであるが、あ くまでも定性的である。各要素がどの程度の大きさになれば実 際の詐称に至るのか定量的にとらえることは具体的な原因検討 や対策において重要であるが、その定量化については検討さ れていない。

また、[リーズン.91]によれば、組織不祥事は組織の持つ潜在 的な危険性をカバーする深層防御(規則や手順書、訓練、管理 業務、資格認定といったソフトな防御と工学的な安全施設・設 備や警報、非破壊検査などのハード防御)が、組織的要因(経 営層の意識決定、予算配分、人員配置、計画、意思疎通、管理 など)、局所的な作業現場要員(過度のタイムプレッシャー、不 適切な道具や装備、訓練不足、人手不足など)によって誘発さ れる従業員たちの不安全行為によってほころびることで、潜在 的だった危険性が顕在化し、それによって組織全体ないし組織 の外部にまで損害がもたらされるとしている。

リーズンの理論は具体的な対策につなげられる要素を検出しや すいが、個人、組織、社会の相互作用や時系列的な構造の発 展過程の描写力に欠ける側面がある。

## 2.2 Giddens の再帰による組織風土醸成と間嶋の詐称不祥事 への展開

[Giddens..76]は、二元論に依拠する機能主義や解釈主義な どの社会文化論の問題点を構造化理論(社会構造(規則と資 源)を、個人行為によって創られるものである一方で、同時にそ のような社会構造を創る個人行為そのものを再帰的に作り出す 二重の性格も持つとし、この個人行為と社会構造の創り創られ る関係を述べた。しかし、個人、組織、社会の相互作用や構造 の発展過程を上手く表現できる基本的な枠組みを与えているが、 詐称問題についての言及は見られない。



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

出所 : A.Giddens,New Roules of Sociological Method, Hutchison 2<sup>nd</sup> ed.1993.

図-2.ギデンズの構造化の理論による相互行為、様相性、 構造の関係

間島[間島.07]]は A.ギデンズの構造化理論を組織不祥事に 展開し [Barley.86]の時系列での相互作用による構造変化、ミク ロ・マクロリンク(個人と社会との相互作用)を包含したモデルを 組織不祥事に適用した。その結果、個人と組織、社会の間の創 り創られていく組織文化がいつしか歪んで行き組織不祥事に発 展していく様子をモデル化した。

ギデンズの枠組みを詐称問題に適用することで詐称の過程を 個人、組織、社会の相互作用を時系列的な変化とともに上手く 描けるようになっている。しかし、具体的な原因の特定やその効 果の定量化ができておらず、具体的な対策の提供力に乏しい。 また、「忖度」など日本独特の社会風土の問題を取り込めていな い。

## 2.3 山本による忖度による「空気」の絶対化と相対化による詐称 発生メカニズム

[山本.83]によれば、実際の社会での会話や議論において、 誰もが感じ、全員がそうであると認識していながら、それを否定 することなどは許されない状況を「空気」といい、これらは根拠や 事実に基づかない架空の信念を前提にしている。この空気はし ばしばそれを象徴するシンボルとなるスローガンや偶像をともな っている。これを品質になぞらえると日本企業を支配している 「品質は絶対である(品質第一主義)、品質を悪くしたら企業は 存続できない」という信念にあたる。日本企業においてはお客 様に不良品を渡すのは悪でありタブーであるとされ顧客に過剰 な配慮、すなわち「忖度」が発生し、十分に良品であるにもかか わらず「もしかすると、大きな不良とみられ信用を失う可能性が ある」として絶対化された品質に対して過剰なコストをかけるわ けである。

ところが、これらの呪縛は何らかの現実に基づく前提、例えば コストや納期が現実の問題として提起されると絶対化されていた ものはやがて相対化されるのである。この現実に基づく仮定、例 えば「納期が守れないと顧客の信用を失う」が対立概念(これを 山本は「水」という)として現れると品質第一主義は相対化し、さ らにこの「水」が連続的に作用し続ける(これを山本は「雨」とよ ぶ)とやがて納期が品質の重要度を上回り、納期を守るために 詐称に至るという多くのケースに見られる不祥事の構図となり詐 称のメカニズムが上手く説明されるのである。

## 3. 本研究の目的~ビジネスゲームを用いた「忖度」「空気」 「水」による品質第一主義の相対化メカニズムの検証

そこで、本研究では不祥事発生のメカニズムを日本独特の文化 ともいえる顧客に対する「忖度」と「空気」により絶対化されてい た「品質」が、現実の諸問題(例えば納期遵守への要請)である 「水」を注されることによって相対化し胡散霧消していくという山本の論説を、クレッシーから Giddens から間嶋に至る組織文化 の構造化の理論を基に、ビジネスゲームを用いて再現すること を目的とする。



図-3.間嶋による構造化の理論の組織文化への応用



図-4.忖度、空気による品質の絶対化と水による相対化

## 4. ビジネスゲームのデザイン

## 4.1 ビジネスゲームの仕様

以下のシナリオとルールで設定されたビジネスゲームで複数 グループを対象として行うものとする。また、形式としては以下の 様なシナリオでの RPG(ロールプレーイングゲーム)とした。

(1)ゲームの設定

- 本ゲームは、イベントを品質不良の発生時の救済申請処理とし て、定められた救済ルールに基づき救済方法を決定し得点 を競うものである。
- ゲームマニュアルで示したシナリオ
- ▶ あなたは、品質部門担当者です。あなたは、製品の出荷判断に責任を持っています。
- ▶ 現在生産している製品は、次期主力となる期待の製品です がなかなか品質が安定せず出荷にあったっては供給先との 兼ね合いで判断を加えながらの判定が必要です。

- ▶当社では、こうした品質が安定しない製品に対して特別救済 処置が設定されています。
- ▶この特別救済処置には、顧客救済と社内救済の二種類があり品質不良の程度に応じて使い分けることが求められます。
- ➤このゲームでは、発生する不良状況に応じて社内救済か顧客救済かを判定し納入による利益(銀貨)を守りながら、顧客損失と会社損失である IFC(金貨)の損失を最小にすることで得点を競います。
- ▶ 顧客救済を行うと顧客に納入が拒否され利益はなく IFC 損 失となる場合があります。社内救済の場合はそのままペナル ティなしで納入されます。
- ▶判定は手元の1~9のカードで示してください。カードの大き さが9に近いほど社内救済とし5以上なら社内救済と判定しま す。

## 4.2 ゲームにおける「忖度」「空気」「水」と忖度の評価方法

忖度とは、日本のハイコンテクスト社会において、指示されずと も相手の気持ちを推し量り応えようとすることである。このゲーム では参加者個人が、顧客の意向をくみ取り、顧客や本来の判定 基準(マニュアルの規定)やゲームでの勝ち負けを度外視して 過剰に判定を厳しくし、社内救済とする所をわざわざリスクのあ る顧客救済とする事である。従って、このゲームにおける「忖度」 とは顧客の反応であり、「空気」は「このような品質では顧客の信 用を失うので出荷はできない」という雰囲気である。これに対す る「水」とは「納期」「救済基準となるガイドライン」「上司の命令」 など現実的な問題を指している。

忖度の大きさ(「忖度」度とする)は、本来ゲームが要請する判定結果(このゲームにおいてはルール上"9"となるはず)と実際の各個人またはグループの判定結果の差として表すことが出来る。そこで、忖度の評価方法としては、忖度度をS、ルール基準の判定値をR(=9),グループ判定値をGとする時次式で表すことが出来る。

S=R-G ..... eq.1

#### 6. 実験結果

ゲーム参加者の構成は、大学院教員1名を含む10名、男性8名、女性2名、年齢は20代後半から50代後半である。予め用意した設問の回答から「誠実な思考のAグループ」と「合理的な思考のBチーム」に分けて行いゲーム終了後ディブリーフィングを行った。。

各設問における判定要因と対応するグループ判定、ゲームから要請される合理的な判定結果を表-1.にまとめる。また、個人及びグループの判定結果を図-5.に示す。









図-5.各設問に対する個人及びグループの判定結果と「忖度」 度

#### 7.考察

グループの判定(表-1参照)を見ると、問1~4はどちらのグル ープも同様にゲームの要請からすれば社内救済となる案件も顧 客救済を選んでいる。これらは仕様項目に該当するか、少しで も疑わしいものはコストの掛かる顧客救済としている。設問 5 に おいてはゲームのルールからは責任者の了解が得られていな いので顧客救済とすべきであるが、それにも関わらず顧客の了 解が得られているため社内救済と判定しており、顧客への強い 忖度が働いていると思われる。実際、その後のディブリーフィン グでも「お客様が良いというのだから」との発言が出た。設問6で は明らかな不良ではあるが社内救済としている。これは社長承 認という大きな権力とガイドラインの要請が「水」の機能を果たし たものと考えられる。問7では要求項目ではなくかつ、納期遅延 という「水」の効果により社内救済となっている。今回質問の8に おいて A の誠実グループの全員が社内救済を選んでいるのに 対して、B の合理的なグループは顧客救済と社内救済に分か れた。ゲーム後のディブリーフィングでの当事者の発言におい て「責任の所在が自分ではなく社長にあることを明確にするた めに顧客救済とした」と述べており、集団での責任より個人の責 任を重視している。これらの行動は集団が権力に「忖度」する 「空気」に支配されて詐称に至る事に対する抑止(「水」)がゲー ム上でも表れたともと考えられる。

#### 8.結論

参加者は、ゲームであると認識しながらも品質判定に際して社 内救済にする事に強い抵抗を示しており、本来、社内救済で済 ますことのできる問題も、コストのかかる顧客救済を選んでいる。 これは、山本の言う、現実(ゲーム空間上)に存在しない顧客に 「忖度」し、ゲーム上の合理的な解を選択できない「空気」に支 配(絶対化)されている状態にあった事が本ゲームにより示され たといえる。また、山本が言うところの「水」である現実を前提とし た納期遅れや、上司の命令、マニュアルの提示があった設問で は「忖度」が相対化され、顧客救済から社内救済に変容する過 程を示しているといえよう。

これらのことをギデンズや間嶋の構造化の理論による組織文化 形成過程に置き換えるなら、会社組織を構成する個人と社会の 相互作用により再帰的に形成された「品質第一」という倫理的に も社会的にも強い拘束力を持つ組織規範が、納期遅れやそれ に伴う損失コスト、あるいは権力者の命令により変容しその絶対 性が低下することを示しているのである。

## 9.今後の課題

今回のゲームでは意図的に社内救済となる様に極端な条件 (顧客救済とすると損失リスクがある一方で社内救済は損失リス クが全くない)を設定した。これは、ゲーム時間が十分とれない ため、繰り返しが少ない中で結果を得ようとしたためであるが、 ゲームの面白さ、没入感を醸成するためには、社内選択や顧客 救済時の不正発覚リスクを導入し、より現実感を高めるゲーム設 計を行う必要がる。

更に、このような「水」の要素を多く使用した場合の挙動を観察することで詐称に至る各要素の影響を定量的に明らかにしたい。

今回質問の8において A の誠実グループの全員が社内救済 を選んでいるのに対して B の合理的なグループは顧客救済と

|    | 問題設定条件   | 仕様対象項目  | 規格外れ             | 納期           | 性能           | 他者振替 | 顧客の<br>容認 | インセン<br>ティブ | 権力 | A | в | Aの判定<br>結果 | Bの判定<br>結果 | ケームルー<br>ルによる判<br>定結果 | 正答 |
|----|--|---------|------------------|--------------|--------------|------|-----------|-------------|----|---|---|------------|------------|-----------------------|----|
| 問1 | 製品に顧客要求規格にはない項目で軽い欠陥<br>あり。納期は明日である。   | ×       | $\bigtriangleup$ | ×            | 0            |      |           |             |    | 1 | 3 | 顧客         | 顧客         | 社内                    | ×  |
| 間2 | 製品性能が規格上限なのでぎりぎり大丈夫な<br>B社に納入することにした   | 0       | 0                |              | 0            | 0    |           |             |    | 1 | 1 | 顧客         | 顧客         | 社内                    | ×  |
| 間3 | IFC目標内で品質規格は測定誤差の範囲内で<br>外れ気味。顧客は安全係数が高く問題ない。  | 0       | 0                |              | 0            |      |           |             |    | 3 | 4 | 顧客         | 顧客         | 社内                    | ×  |
| 間4 | 工程内の測定器ではNGだが、再度測定した<br>らOKとなった。   | 0       | 0                |              |              |      |           |             |    | 2 | 3 | 顧客         | 顧客         | 社内                    | ×  |
| 問5 | 規格を超えるが顧客側の品質には影響を与え<br>ない。もともと急な要求で、顧客側も多少なら<br>構わないといわれている。また、納期を守れ<br>ば顧客の信用アップで金貨もらえる。 | 0       | ×                | ×            | 0            |      | 0         | 0           |    | 7 | 8 | 社内         | 社内         | 顧客                    | ×  |
| 間6 | 明らかな規格外だが大きな商談が絡むため社<br>長決裁で救済するよう命令が出た。   | 0       | ×                |              | ×            |      |           |             | 0  | 8 | 8 | 社内         | 社内         | 社内                    | 0  |
| 問7 | 製品に顧客要求項目ではない外観不良があっ<br>た。製品性能や用途的には問題なさそうであ<br>る。明日までに納入しないと遅延になる。                        | ×       |                  | ×            | 0            |      |           |             |    | 9 | 6 | 社内         | 社内         | 社内                    | 0  |
|    |  | 〇;規格対象  | ○:規格内            | ×;納期<br>遅れにな | ○;問題<br>なし   |      |           |             |    |   |   |            |            |                       |    |
|    |  | ×;規格対象外 | △;軽度             |              | 、 照答<br>品皆に野 |      |           |             |    |   |   |            |            |                       |    |
|    |  |         | ×;重度             |              |              |      |           |             |    |   |   |            |            |                       |    |

#### 表-1.ゲームの設問とグループ回答に対する判定の評価結果

社内救済に分かれた。ゲーム後のディブリーフィングでの当事 者の発言において「責任の所在が自分ではなく社長にあること を明確にするために顧客救済としたと」述べており、集団でのこ のような多様性が詐称にどのように影響するのかについても明 らかにしたい。

## 10.参考文献

- [脊板 .18] 脊板弘康(2018)「工程エンジニアの問題解決方法選 択行動にみる品質偏重傾向に関する研究」,筑波大学大学 院修士論文,2018
- [Cressey.73] Donald R. Cressey(1973), Other People's Money (Montclair: Patterson Smith, 1973), 30.
- [リーズン.91] ジェームズ・リーズン「組織事故―起こるべくして起 こる事故からの脱出」(1991),日科技連

- [Giddens..76] Anthony Giddens(1976), New Rules of Sociological Method: A Positive Critique of Interpretative Sociologies, (Hutchinson, 1976, 2nd ed., 1993).
- [間島.07] 間島 崇(2007)「組織不祥事-組織文化論による分 析-」文真堂
- [Barley.86] Barley,S.R.,"Technology as an Occasion for Structuring: Evidence from Observations of CT Scanners and the Social Order of Radiology Department", Administrative Science Quarterly,31[1986]
- [山本.83] 山本七平(1983)「空気の研究」文春文庫
- [**榎本.17**] 榎本博明(2017)「『忖度』の構造~空気を読みすぎる 部下、責任を取らない上司」,イースト書籍
- [片田.17] 片田珠美(2017)「忖度社会ニッポン」,角川新書

# Detecting Technology Portfolios in the Semiconductor Industry

Bohua Shao<sup>\*1</sup> Kimitaka Asatani<sup>\*1</sup> Ichiro Sakata<sup>\*1</sup>

## <sup>\*1</sup> School of Engineering, the University of Tokyo

Semiconductor serves as the base for the Artificial Intelligence Society. We are interested in detecting technology trends and changes in the semiconductor industry because there are some large resource allocation and organization restructure in this industry recently. In this study, we narrowed our research boundary into the U.S. and Japan. We extracted patent information related with semiconductor and made a citation network. We used Louvain method to cluster the maximum connected component and considered several largest clusters. Results show that the technology portfolios among the two countries are different. We used "*tf-idf*" to detect keywords and features of these unbalanced clusters. In the future, we will link the applicant information in a patent database with mergers and acquisitions (M&A) information in a company database. We will compare and integrate findings from different sources, such as investment, M&A, technology features and industrial policies in order to have a comprehensive understanding.

## 1. Introduction

Semiconductor industry is considered important base for the Artificial Intelligence Society. Recently, by preparing the era of Industry 4.0, resource allocation and organization restructure were under way in the semiconductor industry. There are several influential Mergers and Acquisitions (M&A) in the semiconductor industry. For example, Avago Technologies purchased Broadcom Inc. with 37 billion U.S. dollars and Qualcomm, Inc. announced to purchase NXP Semiconductor with 44 billion U.S. dollars. These phenomena changed technology landscape in the semiconductor industry largely.

In this study, we compared semiconductor industries in the U.S. and Japan. Both two countries have been leading countries in the semiconductor industry for a long term. By comparing these two countries, it is easy to trace and detect the technology trends in the semiconductor industry.

Since technological intangible assets are difficult to measure, patent analysis is a dominant method for research in this field. [Lee 2009] Likewise, in this study, we used patent data for analyzing technology development trends in the semiconductor industry.

This paper is arranged as follows: Section 2 is Literature Review, Section 3 is Data, Section 4 is Experiment, Section 5 is Results and Section 6 is Summary.

## 2. Previous Literature

In 2009, Lee *et al.* proposed a keyword-based patent map. This map is generated through keywords of patents. These keywords in vectors are extracted by text mining. Then keyword vectors are reorganized by Principle Component Analysis. Finally, these vectors were projected onto 2-dimension surface. From the map, it is easy to detect where to invest. [Lee 2009]

In 2011, Wang *et al.* used patent co-citation information between Fortune 500 companies. According to the co-citation networks of different periods, companies are divided into different industry groups. Furthermore, companies' positions in the networks change among different periods. [Wang 2011]

Ma *et al.* proposed a comprehensive method for identifying technology-driven M&A targets. They used both qualitative and quantitative methods for analysis. They also invited policy makers and experts for evaluation. Finally, they used a company as an example to verify the effectiveness of their methods. This method provided a standard, sophisticated way for identifying M&A targets. [Ma 2017]

Shao *et al.* mainly focused on financial items of M&A in Japan. This paper deals with categorization of M&A in Japan. However, it did not take technology factors into consideration, even Japan is famous for its science, technology and trading. [Shao 2018]

## 3. Data

We used Derwent Innovation patent database and Derwent World Patent Index (DWPI) for extracting patent information. We made smart search topic being "semiconductor", Publication date (Basic) being from 1990.01.01 to 2018.01.01, Application Country/Region (Basic) being US or JP. 874005 items were retrieved. We chose this time period because large development in semiconductor industries in Korea and Taiwan happened in the 1990's. [Chiu 2014] We used "Basic" items because "Basic" records the first patent in the same DWPI patent family, which largely represents where and when the patent questioned came from. [Derwent Innovation 2019]

We extracted the following items from the database: Publication Number, Title, Title – DWPI, Publication Date, Cited Refs – Patent, Count of Cited Refs – Patent, Citing Patents, Count of Citing Patents, DWPI Family Members, DWPI Count of Family Members. We did not extract International Patent Classification (IPC) and Cooperative Patent Classification (CPC) data and we used the citation clustering method for classification. [Thurber 1918] In addition, technology trends and contents change rapidly nowadays. Hence, data merely from IPC or CPC did not assure accuracy.

Contact: Bohua Shao, School of Engineering, the University of Tokyo, shaobohua6@gmail.com

## 4. Experiment

#### 4.1 Citation Network

Based on these patent data, we constructed a patent citation network. According to citation information of the patent database, we drew links between patents. Then we grouped them by DWPI Family Member information and built a new network. We assigned weights on edges between DWPI Family Members in the new network according to previous linkage information. The weight is the quantity of all links between any two patents which belong to the two DWPI Family pairs respectively.

#### 4.2 Node Degree

We were interested in the network structure and we extracted the maximum connected component from the original citation network. We calculated the degree of each node in the maximum connected component and plotted the degree distribution in loglog scale.

## 4.3 Clustering

Louvain method [Blondel 2008] is an effective and high-speed method for dealing with large networks. We used Louvain method for clustering the maximum connected component because it is very large, with 612570 nodes.

#### 4.4 Sum of "tf-idf"

In natural language processing, a very common method called *"tf-idf*" is widely used. The *"tf-idf*" aims at filtering out important terms of a document among a corpus. The *"tf-idf*" is calculated in the following way (1):

$$tf - idf_{t,d} = tf_{t,d} \cdot idf_t \tag{1}$$

where subscript *t* means a specific word (term) and *d* means a given document in the whole corpus. In order to caluculate the importance of a word in the whole corpus, we sum up "tf- $idf_{t,d}$ " of the same term across the whole corpus, as shown in (2). We have the "tf- $idf_{t}$ " for the whole corpus.

$$tf - idf_t = \sum_d tf - idf_{t,d}$$
(2)

5. Results



Figure 1. Patent degree distribution in log-log scale

Figure 1 shows the distribution of degrees in log-log scale. We took the logarithm to base 10. The horizontal axis is the degree in log scale whereas the vertical axis is the frequency in log scale. Different from the general understanding that companies only cite their own patents, patents related with semiconductor are cited by other companies as well. The line in Figure 1 is nearly straight in the middle part and we assumed that the maximum connected component has scale-free network features for nodes with degrees in the range of 20 to 80.

By Louvain method, we finally had 333 clusters. We present the largest 21 clusters and their contents in Table 1.<sup>1</sup>

Table 1 shows the quantities of patents grouped by application countries. The "USnum" column shows the quantities of patents from the U.S. by each cluster whereas the "JPnum" column shows the quantities of patents from Japan by each cluster. The column "US/JP-ratio" shows the ratios of the values in "USnum" to those correspondences in "JPnum". Similarly, column "JP/US-ratio" shows the ratios of the values in "JPnum" to those correspondences in "USnum".

We selected two leading countries in the semiconductor industry. Intuitively, ratios across different clusters did not fluctuate too much. However, as shown in this table, ratios are quite different. We mark and underline the ratios above 2 or below 0.5 in red. These unbalanced "Cluster\_id" are 4, 14, 7, 20, 8, 16 and 23.

| Table 1 | Quantities | of Patents   | in Each  | Cluster | Grouped | by |
|---------|------------|--------------|----------|---------|---------|----|
|         | Pi         | ublication ( | Countrie | S       |         |    |

| No       | Cluster id | USnum  | IPnum  | US/JP-       | JP/US-       |
|----------|------------|--------|--------|--------------|--------------|
| 140.     | Cluster_lu | Oblium | 91 num | ratio        | ratio        |
| 1        | 6          | 33728  | 36138  | 0.933        | 1.071        |
| 2        | 1          | 24488  | 33412  | 0.733        | 1.364        |
| 3        | 5          | 18502  | 24441  | 0.757        | 1.321        |
| 4        | 12         | 19731  | 19964  | 0.988        | 1.012        |
| <b>5</b> | 3          | 18922  | 19082  | 0.992        | 1.008        |
| 6        | 4          | 29081  | 7798   | <u>3.729</u> | 0.268        |
| 7        | 14         | 22394  | 11061  | <u>2.025</u> | 0.494        |
| 8        | 15         | 16448  | 15092  | 1.090        | 0.918        |
| 9        | 7          | 22213  | 9053   | 2.454        | <u>0.408</u> |
| 10       | 2          | 16267  | 13532  | 1.202        | 0.832        |
| 11       | 0          | 15819  | 10578  | 1.495        | 0.669        |
| 12       | 9          | 13368  | 10941  | 1.222        | 0.818        |
| 13       | 19         | 15128  | 8130   | 1.861        | 0.537        |
| 14       | 20         | 3409   | 18297  | <u>0.186</u> | 5.367        |
| 15       | 17         | 12038  | 7522   | 1.600        | 0.625        |
| 16       | 10         | 7371   | 7381   | 0.999        | 1.001        |
| 17       | 13         | 5743   | 8856   | 0.648        | 1.542        |
| 18       | 8          | 2246   | 7895   | 0.284        | 3.515        |
| 19       | 16         | 7592   | 2030   | <u>3.740</u> | 0.267        |
| 20       | 22         | 5001   | 4112   | 1.216        | 0.822        |
| 21       | 23         | 6163   | 2012   | <u>3.063</u> | 0.326        |

Furthermore, patents granted from the U.S. are becoming more and more recently whereas patents from Japan are declining. From these results, investors can pay attention to the differences.

<sup>&</sup>lt;sup>1</sup> The quantity of patents of the 22nd largest cluster declines to 3836. We also conducted Louvain method several times and results are slightly different. Here is a typical example.

| Table 2 Sum of y-ug in Cluster in Deing | Table 2 Sun | n of " <i>tf-idf</i> " | in "Cluster | id" Being |
|---|-------------|------------------------|-------------|-----------|
|---|-------------|------------------------|-------------|-----------|

| word       | tfidf-sum |
|------------|-----------|
| film       | 950.1     |
| gate       | 928.9     |
| second     | 894.0     |
| layer      | 835.5     |
| region     | 758.0     |
| silicon    | 741.6     |
| dielectric | 727.7     |
| insulating | 724.3     |
| fin        | 662.7     |
| material   | 657.5     |
| oxide      | 657.0     |
| metal      | 650.5     |
| electrode  | 613.3     |
| structure  | 593.9     |
| trench     | 593.2     |

#### Table 3 Sum of "*tf-idf*" in "Cluster\_id" Being 16

| word       | tfidf-sum |
|------------|-----------|
| layer      | 262.4     |
| memory     | 247.3     |
| magnetic   | 227.7     |
| second     | 210.1     |
| material   | 185.3     |
| resistance | 181.7     |
| electrode  | 181.6     |
| change     | 177.0     |
| cell       | 166.7     |
| film       | 164.2     |
| element    | 158.9     |
| metal      | 150.3     |
| conductive | 149.9     |
| line       | 146.5     |
| phase      | 145.7     |

#### Table 4 Sum of "tf-idf" in "Cluster\_id" Being 23

| word       | tfidf-sum |
|------------|-----------|
| layer      | 208.9     |
| gate       | 198.8     |
| film       | 194.9     |
| memory     | 189.4     |
| second     | 188.8     |
| pattern    | 180.0     |
| mask       | 170.3     |
| region     | 165.7     |
| silicon    | 158.6     |
| insulating | 147.2     |
| material   | 143.4     |
| trench     | 140.6     |
| line       | 136.7     |
| conductive | 136.2     |
| forming    | 124.4     |

Let us consider several clusters marked red in Table 1. We calculated sum of "*tf-idf*" for clusters with "Cluster\_id" being 4, 16 and 23 as examples because they all hold "US/JP-ratio" over 3. The corpus of each cluster is abstracts of patents belonging to the cluster questioned. Herein, we pasted words with top 15

highest sum of "*tf-idf*" values (keywords) of each cluster in Table 2, 3 and 4.

From Table 2, we only detected general terms used for semiconductor manufacturing. From Table 3 and 4, we argue that technology in the 2 clusters is related with memory storage. In all the 3 clusters, U.S. shows dominant power. We hold a hypothesis that U.S. is now allocating resources in manufacturing new generation memory in order to prepare for the big data era.

## 6. Conclusion

In this study, we extracted patent information in the semiconductor industry. We narrowed our research boundary inside the U.S. and Japan, the two leading countries around the world. We detected that the technology portfolios are different in the two countries. We investigated the technology differences and used "tf-idf" to filter out important words among these clusters.

We investigated 3 clusters with high "US/JP-ratio" values as examples. From these examples, we found that U.S. companies have been interested in memory manufacturing recently.

In this study, we only focused on citation information, which is far from enough. There are still other columns in the database, such as Publication Date, Assignee/Applicant and Abstract-DWPI. These columns provide the understanding of patents in a detailed way.

In the future, we want to deal with these columns to catch the current trend in the semiconductor industry. We will link Assignee/Applicant information of the Derwent Innovation patent database with company names in a company database. We will also incorporate social phenomena, such as M&A, industrial policies and taxes in the semiconductor industry so as to have both private and public perspectives.

## References

- [Lee 2009] Lee, Sungjoo, Byungun Yoon, and Yongtae Park, An approach to discovering new technology opportunities: Keyword-based patent map approach, Technovation 29 (6-7): 481-97, Elsevier.
- [Wang 2011] Wang, Xianwen, Xi Zhang, and Shenmeng Xu, Patent co-citation networks of fortune 500 companies, Scientometrics 88 (3): 761-70, Springer Nature, 2011.
- [Ma 2017] Ma, Tingting, Yi Zhang, Lu Huang, Lining Shang, Kangrui Wang, Huizhu Yu, and Donghua Zhu, Text mining to gain technical intelligence for acquired target selection: A case study for china's computer numerical control machine tools industry, Technological Forecasting & Social Change 116: 162-80, Elsevier, 2017
- [Shao 2018] Shao, Bohua, Kimitaka Asatani, and Ichiro Sakata, Categorization of mergers and acquisitions in japan using corporate databases: A fundamental research for prediction. Paper presented at 2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM 2018), Bangkok, Thailand, IEEE, 2018
- [Chiu 2014] Chiu, Chien-Che, and Hsing-Ning Su, Analysis of patent portfolio and knowledge flow of the global semiconductor industry. 2014 Portland International Conference on Management of Engineering & Technology (Picmet): 3621-34, IEEE, 2014

- [Derwent Innovation 2019] Derwent Innovation, Getting started in derwent innovation. Available from http://www.derwentinnovation.com/tipinnovation/support/help/introduction.htm., Accessed: 2019. 02.06.
- [Thurber 1918] Thurber, William L., The need of a secondary patent classification based on industrial arts, Journal of the Patent Office Society 1 (3) (November 01): 106-11, Patent Office Society (U.S.), 1918
- [Blondel 2008] Blondel, Vincent D., Jean-Loup Guillaume, Renaud Lambiotte, and Etienne Lefebvre, Fast unfolding of communities in large networks. Journal of Statistical Mechanics: Theory and Experiment 2008 (10): P10008, IOP Publishing, 2008

# 2016年度決算を対象とした社是と企業業績の関係 (第一報) -東証二部上場製造業企業を対象とした解析-Relationships between mission statements and profitability in fiscal year 2016 (Preliminary

Result)

-Analysis for manufacturing companies listed on Tokyo Stock Exchange 2nd Section-

|                     | 北島 良三 *1            | 上村 龍太郎 *2                | 酒井 浩之 *1             | 中川 慧 * <sup>3</sup>        |
|---------------------|---------------------|--------------------------|----------------------|----------------------------|
|                     | Ryozo Kitajima      | Ryotaro Kamimura         | Hiroyuki Sakai       | Kei Nakagawa               |
| * <sup>1</sup> 成蹊大学 | * <sup>2</sup> 東海大学 | 情報教育センター                 | * <sup>3</sup> 野村アセッ | ットマネジメント株式会社               |
| Seikei University   | IT Education        | Center, Tokai University | <sub>Nomura</sub> A  | Asset Management Co., Ltd. |

In this paper, we try to analyze relationships between mission statements and profitability. The mission statements are very important messages for companies, because they include founders' spirits, the business policies and so on. Therefore, we consider that mission statements affect profitability. Mission statements and profitability (The Return On Asset (ROA) was used) were gathered from annual securities reports because descriptions are accurate and reports are easy to obtain. As mission statements were written in natural language and data to be analyzed becomes complicated, a neural computational method called 'potential learning' which can interpret internal representations was used. As a result, we found that a generalization performance of the model was 0.6125 (accuracy) and mission statements composed of multiple messages may affect ROA.

## 1. はじめに

本研究は社是と企業パフォーマンスの関係について解析を 試みたものである. 社是は, 経営上重要視する事項, 創業の想 い、経営方針、などが記された、企業が掲げる企業行動の最高 目標と捉えることができるメッセージである (経営理念や企業 理念など様々に称される [鳥羽 84]). 企業は日々の業務活動に より収益をあげているが,決算の際に1年分の総括が行われ, 年間パフォーマンスが発表される. この際, パフォーマンスの 高・低といった結果が出てくるが、この結果の根底に社是の作 用が存在しているのではないかと我々は考えている.よって, 社是と企業パフォーマンスの間に関係性は存在しているのか? 存在しているならばどのような関係なのか?といった事柄が 我々の関心事項である.企業のパフォーマンスについて考える と,実際には,例えば市場状況や資本金などの各社を取り巻く 様々な事柄が作用するため, 社是が企業パフォーマンスに大き く影響を与えることまでは考えられない.しかし、企業の業務 姿勢や指針が社是に表されているため企業がこれを無視して業 務活動を行うことは考えられず、社是が業績に影響を与えてい る可能性を無視することもできないと考える.

社是と企業パフォーマンスの関係はこれまでにも研究されて いるが、明確に企業パフォーマンスに影響を与えているという 結果は得られておらず、高尾は先行研究レビューを通して「経 営理念が企業の収益に寄与できる可能性は十分にあると考えら れる」と述べるに留まっている[高尾 10].また、小田らはテ キストマイニングを用いた研究より、経営理念は「従業員に対 する経営理念」,「社会貢献を訴える経営理念」,「世界視点を持 つ経営理念」の3つに内容によって分類ができること、そして この3つの分類の中で従業員に対する経営理念を持つ企業が 最も業績が高く、社会貢献を訴える経営理念を持つ企業の業績 が最も低いことを報告している[小田 10].北島らもこれまで テキストマイニングを用いて研究を実施しており、2013年10 月時点で東京証券取引所市場第二部(東証二部)上場の製造業

連絡先: 北島 良三, 成蹊大学理工学部情報科学科, 〒 180-8633 東京都武蔵野市吉祥寺北町 3-3-1, r-kitajima@st.seikei.ac.jp 企業を対象とした研究 [北島 16a] から「世の中に対して訴求 する社是を持つ企業」と「顧客に対して訴求する社是を持つ企 業」が収益性がよいことを報告している.

しかし北島らの研究では社是を人手による企業 Web サイト 巡回により収集しているため,データ収集に時間的コストを要 している.社是は頻繁に変更されるものではないものの,必要 に応じて変更されるものである.よって 2013 年時点の社是を 解析し関係性を得られたからと言って,その関係性が未来永劫 続くとは考えにくく,社是にはその時代に応じた傾向が存在し ていると考えられる.しかしこれを追跡し研究するためには長 期間の調査が必要となるが,データ収集に時間的コストを要し ていては継続した研究は困難である.

そこで本研究では社是収集源として有価証券報告書を用い ることとした.有価証券報告書を使用する利点はその入手性と 情報の正確性であり、これにより社是収集の時間的コスト圧縮 が期待される.本研究では有価証券報告書を用いて 2016 年度 決算時点の社是と収益性の関係について研究を行った.

## 2. 研究手法

2.1 研究の流れ

本研究は以下の流れで実施した.

- 1. 社是と企業パフォーマンスを収集する.
- 2. 収集された社是に対して形態素解析を実施し,解析用デー タを作成する.
- 解析用データを入力とし、知的情報処理手法を用いて、企業パフォーマンスが高い企業と低い企業に分類する分類器を作成する.
- 4. 分類器の汎化能力を調べ、分類結果を解釈する.
- 以下,上記手順に沿って詳細を述べる.

#### 2.2 社是と企業パフォーマンスの収集

本研究では社是と企業パフォーマンスデータの収集源とし て有価証券報告書(有報)を用いることとした.有価証券報告 書は金融商品取引法で定められている金融庁への提出が義務 づけられている書類である.データ収集源として有報を採用 したのは、多くの企業情報を網羅できること(提出義務のある 企業は複数定められているが、その一つに、金融商品取引所 に上場されている有価証券の発行者が定められている)、正確 な情報であること(虚偽記載は違法であり、また、重大な誤謬 が発見された場合は訂正報告書の提出が必要となる)、入手が 容易であること(金融庁の「金融商品取引法に基づく有価証券 報告書等の開示書類に関する電子開示システム」(Electronic Disclosure for Investors' NETwork (EDINET)よりダウン ロード可能である)、などが理由としてあげられる.

社是および企業パフォーマンスデータは有報以外からでも, 例えば企業Webサイトを閲覧することにより入手することも 可能である.しかし,総務省統計局発行の「日本の統計 2018」 によると,4,098,284社の企業が日本には存在しており膨大な 企業数である.また企業を証券取引所上場企業に絞ったとして も,東京証券取引所(日本最大の金融商品取引所である)には 2019年1月22日現在で3,653社の企業が上場しており,こ ちらもかなりの数である.また,Webページ上のどの部分に 記載があるのかも各企業で異なっており,捜索の必要がある. このため,1企業ずつWebサイトを巡回しデータを収集する ことは時間面で高コストである.さらに,企業Webサイトは 情報発信が未来方向に一方通行であり,例えばデータ収集日の 前日に社是が更新されている場合に収集側がそれを把握するこ とは困難であるなど,問題点が存在している.

有価証券報告書は金融庁の「金融商品取引法に基づく有価 証券報告書等の開示書類に関する電子開示システム」 (Electronic Disclosure for Investors' NETwork (EDINET)) によ り, PDF ファイル形式と XBRL ファイル形式の 2 形式で公 開されている. PDF 形式の有報は報告書としてそのまま読め るものであるが, XBRL 形式の有報は eXtensible Business Reporting Language (XBRL) というコンピュータ言語で記 述されているため, そのままの状態では可読性が低いものであ る. しかしコンピュータ言語で記述されているためコンピュー タで処理しやすく,本研究では XBRL ファイル形式の有報か ら XBRL タグを手掛かりに,社是と企業パフォーマンスデー タを得た.

有価証券報告書には「経営方針,経営環境及び対処すべき課 題等」という項目があり、ここに記載されている文を解析対象 候補として入手した.一方企業パフォーマンスであるが、これ には様々な指標が存在している.本研究では収益性に着目し、 Return On Asset (ROA)を解析対象とした.これの算出には 総資産と経常利益を用い、また、その企業単体のパフォーマン スを解析対象としたい目的より、個別決算の値を取得した.

本研究では解析対象企業として東京証券取引所市場第二部に 上場している製造業の企業を対象に解析を実施することとし, 239 社の有報を収集し「経営方針,経営環境及び対処すべき課 題等」を抽出した.そして抽出した文より目視にて社是に該当 する文を選別したところ,197 社の社是を得ることができた.

#### 2.3 解析データの作成

上記のように収集される社是であるが、これらはテキスト データであるためそのままでは解析を実施することができな い.そこで社是に対して形態素解析を実施し、その結果を基に 解析用データを作成する.形態素解析には日本語形態素解析 システムである JUMAN を用い、単語の「カテゴリ」を得た. カテゴリは JUMAN の辞書に用意されている情報である.こ れは単語がどのようなものであるのか詳細を表したもので、例 えば「飛行機」という単語は「カテゴリ:人工物-乗り物」と

| 表 | 1: 解析 | 用データの変数- | 覧 |
|---|-------|----------|---|
|   | 番号    | カテゴリ名    |   |
|   | 1     | 人        |   |
|   | 2     | 組織・団体    |   |
|   | 3     | 人工物-その他  |   |
|   | 4     | 自然物      |   |
|   | 5     | 場所-施設    |   |
|   | 6     | 場所-その他   |   |
|   | 7     | 抽象物      |   |
|   | 8     | 数量       |   |
|   | 9     | 時間       |   |
|   | 10    | 未定義語     | _ |

いう具合である.

JUMAN には 22 種類のカテゴリが用意されているが,本研 究では「未定義語」というカテゴリを新設し,合計 23 種類の カテゴリを社是から得た.未定義語のカテゴリは辞書に未登録 の単語を分類するカテゴリである.このカテゴリには未登録単 語が蓄積されるため,必要に応じてこのカテゴリの単語を辞書 に追加することも可能である.

このように得られるカテゴリであるが、これらは各カテゴリ の各社是での出現頻度 (Term Frequency, TF) を、そのカテゴ リの全社是での出現状態 (文書頻度逆数, (Inverse Document Frequency, IDF)) により重み付けした値 (TF-IDF) として記 録し解析用データとした.一方, ROA データであるがこれは ROA をそのまま解析対象としたのではなく、197 社の ROA うち第一四分位数 (2.2813) 以下の企業にターゲットフラグと して「0」を、第三四分位数 (5.8129) 以上である企業に「1」 を、それぞれ割り当てて被説明変数とした. 各フラグの内訳は、 1 が 50 社、0 が 50 社となり合計 100 社が解析対象となった.

以上の手順により入力変数が23から成る解析用データが作成されたが、データ中のほとんどの値が0である変数が散見されたため、TF-IDF値が0であるものが100社中90%以上であるものを除去し、最終的に解析用データは10変数から成るデータとなった(最終的な解析用データの変数を表1に示す). この作成された解析用データが次節で述べる手法により解析される.

#### 2.4 解析手法

本研究で解析するデータは、社是と企業パフォーマンスか ら成るデータであり、複雑なデータである.そこで、複雑な データの解析に定評のあるニューラルネットワークを解析に 用いることとした.しかしニューラルネットワークはブラック ボックスと称されるほどモデル解釈が困難である.そのためモ デル解釈が可能なニューラルネットワークである「潜在学習」 [Kamimura 17] を解析手法に採用した.潜在学習はこれまで北 島らによって解釈を要する解析に採用され(例えば、スーパー マーケットデータの解析[北島 16b])、高いモデル性能、高い 解釈性が確認されている.

この手法は図1に示されているように自己組織化マップ (Self-Organizing Maps, SOM) と多層パーセプトロン (MultiLayer Perceptron, MLP) が基となっている二段階の学習から構成さ れている.図1中の①は知識獲得段階と呼ばれる段階で,入 力ニューロンの潜在性を算出し,また,SOMに基づいて知識 の獲得 (学習)を行う.潜在性とは,ニューロンの多様な状況 に対応できる能力と定義されるもので,「潜在性の高いニュー ロン (多様な状況に対応できるニューロン) は学習で重要な役 割を果たすニューロンである」と捉えている. 潜在学習ではこ の潜在性を学習完了後に解釈することで, どの入力が学習に活 用されたのか解釈可能である. 潜在性算出にあたり入力ニュー ロンに番号 k (k = 1, 2, ..., K)を割り当てて表すと, k番目 の入力ニューロンの潜在性  $\phi_k^r$  は,

$$\phi_k^r = \left(\frac{V_k}{\max\limits_{k=1,\ldots,K} V_k}\right)^r,$$

により定義される (0  $\leq \phi_k^r \leq 1$ ). ここで  $V_k$  は k 番目の入 カニューロンの分散 (これは j 番目の出力ニューロン (j =1,2,...,J) から k 番目の入力ニューロンへ接続されている重 み  $w_{j,k}$  から求められる [北島 16b]), r は算出される潜在性を 制御するパラメータである.よってパラメータrが大きい値を 持つ場合は大きな分散を持つ入力ニューロンが大きな潜在性を 持つようになる.潜在学習はこの潜在性を求めた後,知識獲得 段階で学習を行う.知識獲得段階では SOM により学習が行わ れるが,通常の SOM と異なり,入力ニューロン (k 番目の入 力ニューロンを  $x_k$  で示す) と j 番目の出力ニューロンの距離  $d_j$  を求める際に潜在性が,

$$d_j = \sqrt{\sum_{k=1}^K \phi_k^r (x_k - w_{j,k})^2},$$

として利用される.すなわち潜在学習の知識獲得段階では入 カニューロンの潜在性で重みを付けられた距離を学習に使用す る.その他の学習ロジックは通常の自己組織化マップと同様で ある.

知識獲得段階での学習が終了すると,続いて予測段階(図1 中の②の処理)での学習が行われる.予測段階は MLP にて, そして,入力層-中間層間の重みの初期値に知識獲得段階で得 られた,重みと潜在性より算出した値(重み×潜在性)がセッ トされ学習が行われる.通常 MLP による学習結果は初期重み に左右されるが,潜在学習ではこの初期重み設定により,獲得 された知識に基づいた学習が期待できる.以上が潜在学習の概 要である.なお,潜在学習にはいくつかのバリエーションがあ り,ネットワーク構造や潜在性の算出方法などに違いがある.

次章ではこの潜在学習を用いて, 前節で作成したデータを解 析していくが、本研究で使用した潜在学習は入力ニューロンの 数を10個、知識獲得段階における出力ニューロンの数および 予測段階における中間ニューロンの数を48個,予測段階にお ける出力ニューロンの数を2個とした.また予測段階におい て,中間ニューロンの伝達関数は双曲線正接関数,出力ニュー ロンの伝達関数はソフトマックス関数とした. 中間ニューロン の数であるが、これは解析に使用したソフトウェアの標準個数 \*<sup>1</sup>である.また,パラメータrについては1から2まで0.1刻 みで変化させ、最も正解率の良いパラメータ値を探索した. さ らに、解析時にデータは全サンプル (100件)の、70%を学習 用途, 15%を過学習防止用途 (早期停止), 15%を汎化能力試 験用途,に用いた.くわえてこの分割比率はそのままで,各用 途に使用されるサンプルがランダムに異なるものを 10 パター ン作成し、これらを用いて分類器を作成した. これはすなわち 10 個のモデルを作成したことになるが、次章で述べる分類結 果などモデルパフォーマンスはこの10個の平均値を採用して いることをここで述べておく.



図 1: 潜在学習概要

## 3. 結果と考察

解析の結果,社是は正解率: 0.6125,精度: 0.6058,再現率: 0.6500 で分類ができた. この際パラメータrの値は 1.9 であっ た. 潜在学習により得られたこれら結果であるが, 比較のため に実施した、多層パーセプトロン、潜在性を使用しない潜在学 習(ネットワーク構成は潜在学習と同じであるが、学習時に潜 在性を加味しないもの),と比較すると高い結果であることを 確認した (表 2 に結果を示す). このことより, 社是と企業パ フォーマンスの関係調査には潜在学習が有効であることを確認 した.しかし著しく高いパフォーマンスと言える結果でもない ため、この結果は社是とパフォーマンスの関係は解析が難しい 問題であることを示していると言える. モデルパフォーマンス が上がらなかった原因の一つとして学習データが少ないことが 考えられる. 解析対象データのうち, 社是まで取得できたデー タは 197 社あるため、無駄なく使用できればあと 97 社のデー タを解析に使用することができる. もちろん 97 社のフラグの 内訳までも考慮しなければならないため、単純に 97 社分デー タを増加させられるわけではないが、閾値の調整により少々の 増加は期待できる.

さて分類器が作成でき,性能も明らかになったため,続いて は分類に重要な役割を果たした変数の解釈を実施する. 一般的 にニューラルネットワークはブラックボックスと称され、解析 時に活用された変数を解釈することは困難である.しかし潜 在学習は潜在性を確認することでこれを可能としている.図2 は潜在性を示したものである.この図より、第10変数の潜在 性が最大であることが確認できる. これは未定義語のカテゴリ を意味する変数である.続いて潜在性がネットワークで活用さ れた変数であるのかを重みの視点から確認する.図3にネッ トワークの入力層-中間層間の重みを示しているが、図中の四 角形は重みを表しており、図形の大きさで重みの大きさを、緑 色が正の値を,赤色が負の値を示している.比較のために実施 した多層パーセプトロンでは、重みは各ニューロンでバラバラ の重みを持っており、重要変数の判断は困難である。潜在性を 使用しない潜在学習では多層パーセプトロンの場合よりも規則 性が見えるものの、どの入力変数が重要であるかの判断は依然 困難である.一方潜在学習の重みは10番目の入力ニューロン に重みが集中していることから潜在学習が 10 番目の変数を積 極的に活用している状態が確認できた.

それでは未定義語のカテゴリのうちどのような単語が出現 しているのであろうか.続いてはそれを調査した.その結果, 形態素解析の誤りが大多数を占めていること,これを除くと 数値の出現が多いことがわかった.ただしこれはアラビア数字 ではなく,例えば①などと通常とは異なる表記の数字であっ た.なお社是はビジネスメッセージであるが,未定義語のカテ

<sup>\*1</sup> 本研究で解析に使用したソフトウェア (MATLAB の SOM Toolbox) の設定 (mapsize:normal) による.

表 2: 解析結果

| 手法              | 正解率    | 精度     | 再現率    |
|-----------------|--------|--------|--------|
| 多層パーセプトロン       | 0.5250 | 0.5411 | 0.5125 |
| 潜在性を用いない潜在学習    | 0.5438 | 0.5532 | 0.5875 |
| 潜在学習 $(r = 10)$ | 0.6125 | 0.6058 | 0.6500 |



図 2: 入力変数の潜在性 (r = 10)

ゴリにはビジネス関連用語はあまり含まれていなかった.最重 要変数であるものの,未定義語のカテゴリから特殊表記の数字 が得られたことは意外であったため,2番目に潜在性の高い第 8変数を調べたが,この変数自体が数量であることから(漢数 字の出現が多いことがわかった),本研究で解析対象とした社 是では数字が重要な要因であると判断した.

この結果より解釈を実施したが、社是中でのアラビア数字 でない数字は社是を複数発信している場合に用いられるもの であった.よって一つの社是で複数訴求メッセージがあること を示している.未定義語に分類された文字を使用して複数メッ セージを発信している企業は9社あり、うちターゲットフラグ 1に属する企業数は4社、フラグ0に属する企業数は5社で あり、フラグ0に属している企業数の方が多いという結果で あり、未定義語に限って解釈を実施すると、複数メッセージ発 信企業の方が1社だけではあるがフラグ0に属している数が 多いことがわかった.

本研究により未定義語に含まれる単語により社是がパフォー マンス別に分類可能であることが明らかになった.今後はビジ ネス関連用語を辞書に登録して未定義語のカテゴリを廃し,ま た,形態素解析の誤りにも対応し,より詳細な解析を実施して いきたい.

## 4. まとめ

本研究は社是と企業パフォーマンスの関係について調査し たものである.企業パフォーマンスには ROA を採用し,これ の算出に必要な数値と,そして解析対象である社是は有価証 券報告書より入手した.有価証券報告書をデータ源とするこ とで,信頼性の高いデータを時間的コストをかけずに入手す ることができた.また ROA は個別決算の数値を用い,これ によりグループ企業の影響を排した関係性調査を実施できた. 社是と ROA 間の関係は複雑であるため,内部表現解釈が可能 なニューラルネットワークである潜在学習を解析手法に採用し



図 3: 入力層-中間層間の重み

た. 解析の結果, 正解率 0.6125 でパフォーマンス別に企業を 分類できるモデルを作成でき, またこの分類には ① といった 特殊な表記の数値が影響を及ぼしていることがわかった. 比較 のため潜在学習の他, 多層パーセプトロン, 潜在性を使用しな い潜在学習, を用いて解析を実施したところ, 潜在学習の分類 性能が最も良い結果であり, また内部表現は潜在学習以外は明 確に解釈できず, 潜在学習が社是と ROA の解析に有効な手法 であることが確認できた. しかし分類精度は改善の余地があ り, 今後は精度向上, またビジネス用語を形態素解析の辞書に 整備するなどし, さらなる重要変数の解釈を実施していく.

## 参考文献

- [鳥羽 84] 鳥羽欽一郎, 浅野俊光: 戦後日本の経営理念とその 変化 -経営理念調査を手がかりとして- (1984), 組織科学, Vol. 18, No. 2, pp. 37-51.
- [小田 10] 小田恵美子, 三橋平: 経営理念と企業パフォーマン ス: テキスト・マイニングを用いた実証研究 (2010), 経営 哲学, Vol. 7, No. 2, pp. 22-37.
- [高尾 10] 高尾義明:経営理念は役に立つのか:経営理念と成果についての先行研究からの考察 (2010),経営哲学, Vol. 7, No. 2, pp. 38-51.
- [北島 16a] 北島良三, 上村龍太郎, 内田理: 社是に含まれる業績に影響を与える単語に関する研究 -TF-IDF と共起語を切り口にした解析- (2016), 第 32 回ファジィ システム シンポジウム講演論文集, pp. 463-468.
- [北島 16b] 北島良三, 遠藤啓太, 上村龍太郎: 入力ニューロン の潜在性に着目した小売店店舗の非継続来店顧客検知モ デルの作成 (2016), オペレーションズ・リサーチ, Vol. 61, No. 2, pp. 88-96.
- [Kamimura 17] Kamimura Ryotaro: Collective mutual information maximization to unify passive and positive approaches for improving interpretation and generalization (2017), Neural Networks, Vol. 90, pp. 56-71.

フォールトラインが組織の成果に及ぼす影響 Influences caused by faultlines on the organizational performance

> 熊田 ふみ子<sup>\*1</sup> Fumiko Kumada

倉橋 節也<sup>\*1</sup> Setsuya Kurahashi

<sup>\*1</sup>筑波大学大学院ビジネス科学研究科 University of Tsukuba Graduate School of Business Sciences #1

The diversification of employment and work styles in organizations is inevitable to ensure a stable workforce in Japan, where a labor force is shrinking due to a declining birthrate and an aging population. Using the concept of faultlines, which are hypothetical dividing lines that may split a group into subgroups of people based on their multiple attributes, this paper examines the relationship of influences of a structure of diversity: the faultline strength and the number of subgroups: and communication within an organization. It is verified by an agent-based model based on the results a survey of Japanese organizations. In conclusion, when staff in an organization interact smoothly the structure of diversity influences less on the organizational performance. However, when the interaction is not smooth, for example, the communication between similar staff, the structure of diversity influences more the performance. Therefore, it is important to manage the interaction and communication.

## 1. 目的と背景

少子高齢化が進む日本では労働力の確保は必須である。そのため、外国人労働者の受入れや「働き方改革」が進められている。また、AIや IoT 等のテクノロジーの進化で、働く人、そして働き方が多様化している。

ダイバーシティ・マネジメントの研究分野では、多様化は組織 の成果にプラスにもマイナスにも影響する諸刃の剣と言われて いる。そのため、多様化した組織を適切にマネジメントすること は、今後の日本の企業では重要な課題である。

本研究は、多様性を定量的に捉える「フォールトライン」の考 え方に着目し、「多様化した組織をどのようにマネジメントすれ ば、組織のパフォーマンスは向上するか」の解の1つを明らかに することを目的とする。

## 2. 先行研究

## 2.1 多様性研究

[Willians 1998]は、多様性が組織のパフォーマンスにどのよう に影響を与えるかについて統合モデルを提唱し、プラスにもマ イナスにも影響すると説明している。

マイナスの理論

Social categorization 理論:自分と他者を年齢等表層的特徴により分類することでコンフリクトを起こす。

Similarity-attraction 理論:類似性の高い人ほど魅力を感じ結束力を高めるが、類似性の低い人とはコンフリクトを起こす。

 プラスの理論 Information and decision-making 理論:多様性により知識 や情報の種類や量が増えるため、組織にポジティブな影 響をもたらす。

この統合モデルでは、多様性が組織の成果にプラスになるか、 マイナスになるかは、コミュニケーションが阻害されるか促進され るかがポイントの1つであることを示している。

連絡先:熊田ふみ子, 筑波大学大学院ビジネス科学研究科, 〒112-0012 東京都文京区大塚 3-29-1 Email: s1845005@s.tsukuba.ac.jp

#### 2.2 フォールトライン理論

[Lau 1998]は、フォールトライン(グループを1つ以上の属性 によってサブグループ(以下、SG)に分ける仮想の分割線。以 下、FL)という考えを提唱し、組織構成員の属性による多様性と 組織内の分断(コンフリクト)の発生の因果関係を説明した。そ の後の FL の先行研究の多くは、「FL がコンフリクトを増大させ る」という結果を報告している。

また、FL の計測方法については、先行研究で 10 種類以上 が提案されている。その中で[Suzuki 2015]は、[Meyer 2013]が 提唱したクラスター分析の評価尺度である Average of Silhouette Width(以下、ASW)が連続変数、カテゴリカル変数ともに扱え、 適切な SG に分けることができる等の長所を示している。

#### 2.3 先行研究の課題

日本の組織を対象にした FL 理論の先行研究は限られている。 そこで本研究では、日本の組織を対象に調査を実施し、その結 果をもとに、多様性を ASW によって FL の強さと SG 数で定量 化・構造化した上で、多様性とコミュニケーションの関係をエー ジェントベースモデル(以下、ABM)で検証する。

## 3. モデルの概要

本モデルは、エージェントを組織の構成員に見立て、エージ ェント同士が交流することで影響し合い、評価値を更新する。そ して、組織全体の評価値(各エージェントの評価値の和)を交流 の前後で比較して、その増減を検証する。

## 3.1 エージェントの属性

各エージェントに 6 個の遺伝子列(0,1 のビット列)を設定する。 その遺伝子列を意思決定態度属性(以下、態度属性)とみなす。 エージェント同士が交流して、各々の態度属性に影響を与えて 評価値を更新する。態度属性は、消費者行動研究における多 属性態度モデルの理論を応用している。多属性態度モデルは、 消費者が製品を評価する際、一つの属性だけではなく複数の 属性に着目し、各々の属性への評価の総和が製品の総合評価 になるという考え方である。この考えを応用して、製品を組織の 課題に置き換え、課題への取組み方の特性を複数の属性で表 し、属性の総和をその課題解決のための総合評価に見立てた。

また、エージェントに設定した 6 個の遺伝子列の初期配列を ASW で計算して、組織の FL の強さと、各エージェントが属する SG を決定する。初期の態度属性は外部からの影響を受ける前 なので、年齢や性別等の表層的属性に依拠すると仮定する。

次に、初期の態度属性によって設定された SG は、FL 理論の 基になっている Social categorization 理論の表層的属性による 似た者同士による内集団と言い換えることができる。

また、交流することで影響しあい態度属性は変化するが、所属 SG は不変である。その上で、誰と交流して影響し合うと組織 全体の態度属性の評価値が向上するかを検証する。

#### 3.2 効用関数

効用関数として、NK モデルを用いる。NK モデルは、生物が 進化する過程を示す遺伝的アルゴリズムで、[Siggelkow 2003] や[Kobayashi 2011]等,組織行動や組織学習の分野で活用さ れていることより、本モデルで用いた。

NK モデルの評価値である適応度(fitness)は、0か1の値を 取るN個の遺伝子がK個の遺伝子と関係して全体の適応度を 決定している。本研究ではエピスタシスが低いN=6,K=1でシミ ュレーションを実施した。

## 3.3 シミュレーションの設定

交流する相手と自分との類似度の程度により、以下3種類の 交流方法を設定した。1回のシミュレーションで100回の交流を 行い、設定ごとに100回のシミュレーションを実施した。

• 内集団交流

FL 理論を再現した内集団交流は、同じ SG のエージェントの交流(以下、SG 内交流)と、違う SG のエージェントの 交流(以下、SG 間交流)の割合を 0~100%で設定した。 SG 内交流とは、似た者同士(内集団内)の交流であり、その割合の大きさがコンフリクトの大きさを表す。

交流相手を決める第1ステップは、SG内交流かSG間交流かを割合に応じてランダムに決める。第2ステップは、 遺伝子列のコサイン類似度が一番高いエージェントを選 択する。実社会における似た者同士の交流を再現したも ので、多様性がマイナスに作用している状態である

• 外集団交流

情報意思決定理論に基づいた交流。遺伝子列のコサイン 類似度が低いエージェントを選択する。その相手は、SG の同異とは関係なく、トーナメントサイズに応じてランダム に選択する。トーナメントサイズが大きくなると選択圧が高 くなるため、類似度の低い相手を選択する可能性が高くな る。交流相手を決める第 1 ステップは、トーナメントサイズ に応じてランダムに選択し、第 2 ステップで、その中で一 番コサイン類似度の低いエージェントを選択する。 実社会では、自分とは違う属性の人と交流して知識や情

来社会では、日方とは運り属性の人と交流して知識や情報の種類や量を増やし、多様性を積極的に活かしている 状態を再現した。本シミュレーションでは、選択圧が一番 小さいサイズ 2、一番大きいサイズ 17、中間のサイズ 9の 3種でシミュレーションを行った。

#### ランダム交流

SGの同異に関わらず 18 のエージェントがランダムに相手 を選んで交流する方法。自由に誰とで平等に交流するた め、コンフリクトがなくスムーズに交流できている状態で、 組織の潜在的な能力と仮定した。シミュレーションの設定 を表1に記した。

表 1. シミュレーションの設定

| エージェ            | ント数         | 18           |
|-----------------|-------------|--------------|
| 款年間粉            | Ν           | 6            |
| 計Ш戌奴            | K           | 1            |
| 交流相手の選択         |             | 内集団/外集団/ランダム |
| 交流方法            |             | 一点交叉         |
| 適応度の設定          |             | (0,1)の一様乱数   |
| 1シミュレー<br>たりの交流 | ションあ<br>布回数 | 100回         |
| シミュレーションの<br>回数 |             | 100回         |

#### 3.4 評価基準

100 回の交流の前後における組織全体の適応度の増減を観察し、増加幅が交流の成果である。そのため、100 回のシミュレーションによる増加幅の最大値の Top10 の平均(外れ値を除く)を評価基準とする。これは、組織の最大可能性を意味する。

また、どのような課題に対しても安定した結果を出すことも組 織としては重要である。そのために、100回のシミュレーション結 果の標準偏差を第2指標とする。標準偏差が大きい場合、最大 値が発生する安定性は低くなる。そのため標準偏差を組織の安 定性とした。

そして、最大可能性と安定性が、FLの強さや SG 数など多様 性の構造や、交流方法により、どのように変化するか、その関係 を観察することで、組織の多様化と成果の関係を検証する

#### 3.5 モデルの妥当性検証

モデルの妥当性を検証するために、FL の強さ(強・弱)と、SG 数(2,3,6)による6セットデータを作成し、FL 理論を再現してい る内集団交流でシミュレーションを実施した。その際、コンフリク トを表現している SG 内交流の比率は 0~100%の 10%単位で パラメーターを設定した。

表2の相関係数より、SG内交流の比率が増えるとTop10の 平均が下がるため、「FL はコンフリクトを起こし組織にマイナスの 影響を与える」というFL 理論の一部をサポートしている。また、 表3では、SG数が同じ場合には、FL が強いと回帰係数が大き くなっている。この点においても「FL はコンフリクトを起こし組織 にマイナスの影響を与える」というFL 理論の一部をサポートして いる。

表 2. 評価基準と各パラメーターの相関係数

|          | FL    |     | SG数    |    | 比率     |   |
|----------|-------|-----|--------|----|--------|---|
| Top10の平均 | 0.671 | *** | -0.319 | ** | -0.260 | * |
| 標準偏差     | 0.675 | *** | -0.344 | ** | -0.255 | * |

\* p<.05, \*\* p<.01, \*\*\* p<.001

表 3. 各データセットの評価基準による回帰係数

| FLの強さ    | SG数 | Top10の<br>平均 | 標準偏差     |
|----------|-----|--------------|----------|
| 強(1.000) | 2   | -3.495 *     | -0.987 * |
| 弱(0.142) | 2   | -0.545 .     | -0.200 . |
| 強(0.723) | 3   | -1.079       | -0.404   |
| 弱(0.300) | 3   | -0.553       | -0.258   |
| 強(0.848) | 6   | -0.874       | -0.399 * |
| 弱(0.260) | 6   | -0.578       | -0.215   |

. p<0.1, \* p<0.05, \*\* p<.001, \*\*\* p<0.001

## 4. 実態調査

## 4.1 調査概要

対象は日本の企業5社14グループ(大企業1社3グループ、 中堅企業1社1グループ、ベンチャー企業3社10グループで 126名が回答)で、従業員の属性とグループ内の交流状況を調 査した。調査項目は、年齢、性別、所属年数、雇用形態の4項 目の属性データと、各所属スタッフとの業務上のコミュニケーシ ョンの頻度(5段階)である。

## 4.2 調査結果



図 1. 調査対象の組織の FL の強さと SG 数

調査結果から属性データを ASW で計算し、各組織の FL の 強さと SG 数を算出した。(図 1 を参照)。

その結果を用いて、FL の強さと SG 数、SG 内交流の割合に ついて回帰分析を行った結果、以下の関係式を導いた。

```
(SG 数)=0.6872+5.7206×(FLの強さ)式(1)※決定係数:0.522,p値<0.05</td>(SG 内交流)=0.7845+(-0.11443)×(SG 数)式(2)※決定係数:0.847,p値<0.001</td>
```

次に関係式をもとに、6 つのセットデータ(a~f)を作り、シミュ レーションを実施した。セットデータの多様性の構造(FL の強さ /SG 数)は図 2 である。実態調査の結果から SG の人数に偏りが あるグループと、ないグループが存在したため、ほぼ同じ FL の 強さで同じ SG 数だが人数に偏りがある場合とない場合(a:12,6 とb:9,9、c:9,6,3,とd:6,6,6)のセットデータを作成した。また、類似 交流における SG 内交流の比率も調査結果をもとに算出した。 各セットデータの比率は、図 2 の中に記している。



## 5. シミュレーションの結果

3 つの交流方法について、100 回のシミュレーションを実施した結果が図3である。1回のシミュレーションで100回の交流し、その100回の交流の前後における組織全体の適応度の増減のTop10の平均と標準偏差である。



※ 外集団交流の 2,9,17 はトー ) シンドリイズの入ささ じめる。 図 3. シミュレーションの結果(上段:Top10 の平均 下段:標準偏差 / 左:交流別 右:セットデータ別)

- 全体的に、Top10の平均(最大可能性)と、標準偏差(安定性)は同じ傾向を示している。そのために最大可能性が高い場合は安定性が低くなる。
- コンフリクトが起きて内集団交流は、組織の潜在的パフォーマンスと仮定するランダム交流より最大可能性が低い。
   特に、FL が弱く、SG 数が少なく、SG 内の人数が均衡の場合(bの場合)は、顕著である。これは、「規模が均一よりも偏りがある方が業績は高くなる」という[Polzer 2006]の結果を支持している。また、SG 数が2よりも3以上の方が高くなっている。この点も「SG 数が 2 よりも 3 以上の業績が高い」ことを報告している[Carton 2012]の結果を支持している。
- モデルの妥当性検証のために行ったシミュレーションの結果(表 2)と同様に、FLとSG数は逆の効果をもたらすために、FLは強いがSG数が多くなるeやfは、FLとSG数が中庸であるc,dよりも最大可能性が低くなる。
- 組織の潜在的パフォーマンスを示しているランダム交流は、
   dを除いて、その組織の最大可能性を一番高く出せる交流である。
- 外集団交流は、選択圧が高くなると最大可能性が低くなる 傾向である。異質な人との交流はパフォーマンスを上げる という仮説は、異質の程度が高すぎると逆効果になること がわかった。ただし、異質な人との交流をすると、組織の 多様性の構造の影響を受けにくいこともわかった。

## 6. 考察

本研究では、FL 理論により多様性を FL の強さと SG 数で定量化して、3 種類の交流方法(内集団、外集団、ランダム)で ABM を使ってシミュレーションを行い、組織の多様性とコミュニケーションの関係、特に「誰とコミュニケーションすると、組織の パフォーマンスが高くなるか」に焦点を絞り検証した。以下 3 点 について明らかにすることができた。

 
 ・ 似た者同士の内集団交流では、FLの強さやSG数、人数の偏りという多様性の構造が組織の成果に影響を与えることがわかった。FLの強さは最大可能性を高める点では プラスに働くが、安定性が低くなる点ではマイナスの影響
を及ぼす。SG 数は逆の作用を及ぼす。そのために、その 組織が何を優先に目標を定めるのかにより、多様性の構 造を考慮することが重要である。

- 第二に多様性を積極的に活かした外集団交流は、自分と 極端に異質な人との交流は組織の最大可能性にプラスに は影響しない。最大可能性を高くするためには、隔たりな く均等に誰とでも交流することである。
- ・多様性を活かすために重要な事として、①組織の多様性の構造を把握する事。その時に、FL理論は多様性を定量的に把握できるために活用が可能である。②組織の目標として、最大可能性(高いパフォーマンス)と安定性のどちらを優先させるのかを決め、それにマッチしたコミュニケーションをマネジメントする必要がある。例えば、ミーティングのファシリテーションや席順など。

次に、今後の課題について考える。

まず実態調査については、規模を拡大することや、業種や 職種、規模による違いなど、日本の多様性の実態より深く調 査することである。そして定量的にコミュニケーションが測れる デジタルデバイスの活用などが考えられる。次に、シミュレー ションの設定については、NK モデルの Kを1だけではなく K の値を高くしたシミュレーション、多様性の強度を細かく検証 するために、トーナメントサイズをより細かく設定するなどシミュ レーションの設定を改善することが必要である。

# 7. 結論

本研究の目的は、「多様化した組織をどのようにマネジメント すれば、組織のパフォーマンスは向上するか」であった。本研 究で得られた 1 つの解は、組織の多様性の構造を把握した上 で、コンフリクトの克服し、フラットなコミュニケーションの仕組み を作ることである。それが組織のパフォーマスを向上させるため に必要なマネジメントの1つである。

そして、本研究の学術的貢献として、FLの先行研究の結果を ABM で再現し、そのメカニズムの一部をコミュニケーションの視 点から明らかにできたことが挙げられる。また、実在する企業を 対象に FL 理論に基づき調査し、実際の現象を FL 理論、ABM の結果で説明できたことは実務的貢献である。

# 参考文献

- [Carton 2012] Carton, A. M. and Cummings, J. N.: A theory of subgroups in work teams, Academy of Management Review, 37(3), 441-470, 2012.
- [Kobayashi 2011] Tomohiro KOBAYASHI, Satoshi TAKAHASHI, Masaaki KUNIGAMI, Atsushi YOSHIKAWA, and Takao TERANO: Harnessing Organizational Deviation and Kaizen Activities through Agent-Based Modeling, Institute of Electronics, Information and Communication Engineers. Information and Systems Society 94(11), 2011.
- [Lau 1998] Lau, D. C. and Murnighan, J. K.: Demographic diversity and faultlines: The Compositional dynamics of organizational groups, Academy of Management Review 23(2), 325-340, 1998.
- [Meyer 2013] Meyer, B. and Glenz, A.: Team faultline measures: A computational comparison and a new approach to multiple subgroups, Organizational Research Methods 16(3), 393– 424, 2013.
- [Polzer 2006] Polzer, J. T., Crisp, C. B., Jarvenpaa, S. L. and Kim, J. W.: Extending the faultline model to geo-graphically

dispersed teams: How collocated subgroups can impair group functioning, Academy of Management Journal49(4), 679 692,2006.

- [Siggelkow 2003] Nicolaj Siggelkow and Daniel A. Levinthal: Temporarily Divide to Conquer: Centralized, Decentralized, and Reintegrated Organizational Approaches to Exploration and Adaptation, Organization Science; 2003; 14(6).
- [Suuzuki 2015] Suzuki, R., Matsumoto, Y., and Kitai, A.: The Concept and Analytical Techniques of Faultline, Journal of political economy211(6), 53-88, 2015
- [Willian 1998] Williams, K. Y. and O'Reilly, C. A.: Demography and diversity in organizations: A review of 40 years of research, Research in organizational behavior (8), 70– 14,1998.

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

# [3A4-J-13] AI application: electrical power

Chair:Takashi Onoda Reviewer:Yuiko Tsunomori

Thu. Jun 6, 2019 3:50 PM - 4:50 PM Room A (2F Main hall A)

# [3A4-J-13-01] Evaluation of power consumption estimation model based on household information OTomofumi Tahara<sup>1</sup>, Hideaki Uchida<sup>1</sup>, Hideki Fujii<sup>1</sup>, Shinobu Yoshimura<sup>1</sup> (1. The university of Tokyo) 3:50 PM - 4:10 PM [3A4-J-13-02] Optimization of Power Electric Supply Path in Smart Grids OTakaya Ozawa<sup>1</sup>, Ei-Ichi Osawa<sup>1</sup> (1. Future University Hakodate) 4:10 PM - 4:30 PM [3A4-J-13-03] Design and Preliminary Evaluations of Multi-Agent Simulation Model for Electric Power Sharing among Households OYasutaka Nishimura<sup>1</sup>, Taichi Shimura<sup>2</sup>, Kiyoshi Izumi<sup>3</sup>, Kiyohito Yoshihara<sup>1</sup> (1. KDDI Research Inc., 2. Kozo Keikaku Engineering Inc., 3. The University of Tokyo) 4:30 PM - 4:50 PM

# 世帯情報に基づいた電力需要量推定モデルの評価

Evaluation of power consumption estimation model based on household information

田原智史\*1 内田英明\*1 Tomofumi Tahara Hideaki Uchida

藤井秀樹 \*1 Hideki Fujii 吉村忍 \*1 Shinobu Yoshimura

\*1東京大学大学院工学系研究科

School of Engineering, The University of Tokyo

Abstract: An electric power demand estimation model based on household information is proposed in this paper. The effect of transition of electric power systems being discussed today will emerge as the change of household electricity demand. The objective of this research is to develop a model which can output area-wise electricity demand curve from the sum of household-wise demand. The proposed method is based on a multi-agent-based household transition model and a household energy consumption database. The simulated result shows rough agreement with the measured values of the monthly electricity demand.

# 1. はじめに

# 1.1 背景

日本の電力システムは大きな転換を迎えている東日本大震 災を契機に,エネルギー供給が制約され,集中型エネルギーシ ステムの脆弱性があらわになった.また,化石燃料の枯渇に対 する懸念や環境への配慮から,大規模集中型エネルギーシステ ムから分散型エネルギーシステム[1]への転換が求められるよ うになった.分散型エネルギーシステムに向けて,再生可能エ ネルギー,蓄電池,熱源機等の機材を地域の特色に合わせて活 用し,効率的なエネルギーの運用しようとする試みが見られ, 現在様々な研究が行われている.

またわが国では、再生可能エネルギーの普及促進や電力自由 化の影響から、従来需要家側であった主体がより一層発電し、 電力の授受が盛んに行われるようになることが予想される.こ のような電力体制では、電力需要構造はより一層複雑化する が、マクロな予測では、複雑化に伴うパラダイムシフトに追従 できない可能性が高いため、従来の電力需要予測では対応する ことができない恐れがある.地域の特徴、人口動態、発電方式 等、様々な情報も利用して予測できるモデルが開発されれば、 将来的に蓄電池の配置等電力システムを構築する政策決定を容 易にする手段となり得る.

### 1.2 世帯推移シミュレータ

山際らは、世帯が持つ内部住民状態をライフイベントに伴い 遷移させることで、都市の世帯数推移を再現・予測できる世帯 推移シミュレータを開発した [2]. このシミュレータは、都市 の意思決定主体を「世帯」という単位で考え、その世帯を構成 する住民状態を内部変数として持つモデルとなっており、政策 立案の検証に有用なモデルとなっている.本研究では、将来的 な EV の普及や蓄電池の配置が地域の電力需要にどのような 影響を与えるかについての検討を可能とするために、人口動態 の変化を予測することができるこのシミュレータを活用する. 本研究の位置付けを図1に示す.図1における人口動態シミュ レーションが山際らが開発した世帯推移シミュレーションにあ たる.本研究で開発するモデルは、そこから得られた世帯情報 (世帯数,世帯種割合)を入力データとして,電力需要量を推 測する片方向連成モデルとなっている.

#### 1.3 既存研究

家庭部門のエネルギー需要推定モデルにおいて,経済指標 や統計データを用いたマクロ傾向を分析するもの [3] から住民 の行動を実測調査に基づいてモデル化して時間別の電力需要を 再現するモデル [4] まで多岐にわたる.前者は,全体の電力需 要予測や政策決定の評価に有益ではあるが,個々の世帯や時間 帯別の電力需要までを予測することはできないという問題があ る.一方で後者は住民の行動まで再現することでよりミクロな 電力需要まで再現することはできるが,住民の行動を網羅的に 再現するために必要なデータが現時点で入手可能とは言えず, 未知パラメータの増大,検証の困難さが依然として課題となっ ている.今後電力システムの転換により,電力需要が個々の世 帯の影響を大きく受けることを考慮すると,電力需要を決定す る要素数を抑えつつも,個々の世帯や時間帯別の電力需要まで 予測可能なメゾスコピックモデルがより一層必要になることが 考えられる.

#### 1.4 本研究の目的

本研究では、森田らの研究 [5][6] を参考に、複雑化する将来 の電力発需要量に大きく影響すると考えられる家庭部門の電 力需要を予測できるシミュレータの構築を目的とする.このシ ミュレータは、人口動態の変化、過去の電力使用量のデータ、 平日・休日、発電方式を考慮して、それぞれの地域の特性を示 すような情報を組み込み、時間別の電力需要曲線を予測でき るモデルとなっている.また、将来的な電力需要の変動を予測 し、電力システムにおける政策決定に有用な知見を提供するこ とを目的とする.

# 2. 提案手法

#### 2.1 モデルの概要

図2に電力需要推定モデルのフローチャートを示す.本研 究では、電力需要に大きな影響与える要因を、世帯情報(世帯 数、世帯種割合)、月、平日・休日、発電方法の4種類に絞り、 これらを元に15分ごとの電力需要量を出力する.

連絡先: 田原智史,東京大学大学院工学系研究科, 113-8656 東 京 都 文 京 区 本 郷 7-3-1, 03-5841-6994, t\_tahara@save.sys.t.u-tokyo.ac.jp



図 1: 開発モデルの位置付け



図 2: 電力需要推定フローチャート

# 2.2 世帯種

世帯・住民シミュレーションモデルはマクロモデルとミクロ モデルとメゾモデルに大別される.マクロモデルは世帯や住民 を集合体として扱い、その集合体の状態分布を遷移させること で世帯動態の再現するモデルである.このモデルの特徴は、少 ないパラメータで多様な世帯動態の予測を可能にするが、行動 主体である世帯・住民への影響や個々の住民の挙動までは考慮 することができないという問題がある.一方ミクロモデルは, 各住民・世帯を個別に扱い、住民・世帯毎の状態を遷移させる ことで、マクロモデルでは考慮が難しい行動主体である世帯・ 住民への影響や微視的な個々の住民の挙動を表現することがで きる.しかしこのモデルでは、複雑な社会現象を表現するため に,未知パラメータや計算時間を増大化,パラメータ推定や妥 当性の検証が困難であるという問題を抱えている. そこで山際 らは,各住民・世帯を個別に扱いながらも世帯の状態を単純化 させることで、個々の世帯への影響を考慮可能にし、パラメー タ推定・妥当性検証が容易であるメゾモデルシミュレータを開 発した. このシミュレータでは、住民の現在状態を年齢区分毎 に集約した内部状態として世帯に持たせることで、メゾスコ ピックな世帯エージェントを定義している. これにより, 住民 に関する未知のパラメータ数を抑制しつつ、住民の遷移状態に 作用する政策の影響を反映した世帯動態の再現が可能となる. 住民状態の表現には4種類の年齢区分と3種類の状態を用い る. それぞれ以下の通りである.

- 年齡区分
  - 子供 (0~19 歳)
  - 青年 (20~39 歳)
  - 中年 (40~59 歳)
  - 老年(60歳~)
- 状態
  - 状態1:世帯に存在していない
  - 状態2:世帯に存在し、かつ未婚である
  - 状態3:世帯に存在し、かつ既婚である

以上のようにして定義した年齢区分と状態の組み合わせか ら、全ての年齢区分で状態1である場合と、子供の年齢区分 のみ状態2である場合の2通りを除いた52通りの内部状態が 以下の6種類の世帯種に対応している.

- 単身世帯
- 夫婦のみ世帯
- 夫婦とその子供世帯
- 片親とその子供世帯
- 夫婦とその親世帯
- 三世代世帯

本研究では、上述した世帯推移モデルを参考に、世帯エー ジェントを6種類の世帯種に割り振った。世帯内の住民の行動 は考慮しておらず、世帯種が電力需要の傾向を決定し、それぞ れ特徴のある電力需要比率と規格化電力需要量を内部変数とし て持たせている.また各世帯は、世帯の人数は明示的には考慮 しておらず、各世帯種が持ち得る世帯人数を満たす世帯のデー タを確率的に割り当てている.

#### 2.3 発電方式

本研究では、世帯種毎にオール電化世帯と普通世帯に振り分 けている.オール電化世帯とは、冷暖房、調理、給湯を使用す るために電気を使っている世帯のことを表す.普通世帯とは、 これらを電気以外のエネルギー源を使っている世帯のことを表 す.これは、オール電化世帯はエコキュートを設置しているこ とが多く、深夜の安価な電力を使って給湯を利用するために時 間帯別の電力需要曲線に大きな差異が見られることから、世帯 種毎に発電方式を2種類設定した.

# 2.4 電力需要量の算出方法

電力需要量は(1)式で算出される.  $E_{i,T}$ は世帯 iの期間 Tの電力需要量 [kWh], Tは区間  $t_1$ から区間  $t_n$ までの和,  $e_i$ は世帯 iの規格化電力需要量 [kWh],  $r_{i,k}$ は世帯 iの区間 kにおける電力需要比率 [ratio] である. 図 3 は(1)式,(2)式を示した簡易図である. なお,本研究ではT = 24[hour] k = 15[min], n = 96と設定している.

$$E_{i,T} = e_i \sum_{k=t_1}^{t_n} r_{i,k}$$
 (1)

$$T = t_1 + t_2 + \dots + t_{n-1} + t_n \tag{2}$$

規格化電力需要量は世帯種,月,平日・休日,発電様式別に, ある日の1時間あたりの平均電力需要量とした.本モデルで は,日ごとの平均電力需要量を出し,その集めた数値の平均と 分散に従う正規分布に基づいて規格電力需要量を出力する.

電力需要比率は,ある区間 k における電力需要量を規格化 電力需要量で割った値のことである.本研究で扱う消費電力使

# 3A4-J-13-01



| 表 1: パラメータ  |       |
|-------------|-------|
| パラメータ       | 値     |
| 単身世帯割合      | 0.310 |
| 夫婦のみ世帯割合    | 0.185 |
| 夫婦とその子供世帯割合 | 0.345 |
| 片親とその子供世帯割合 | 0.077 |
| 夫婦とその親世帯割合  | 0.052 |
| 三世代世帯割合     | 0.052 |
| オール電化普及率    | 0.042 |

用量のデータベース [7] には、15 分ごとにある世帯で使用した 電力量が記載されている.このデータベースを元に、世帯種、 月、平日・休日、発電様式別に、電力需要比率を平均値として 算出し、固定値として出力する.

# 3. 数值実験

# 3.1 実験設定

本研究では、電力事業連合会による電力需要実績 [8] に掲載 されている東京電力の電力供給量と関東圏に住んでいる世帯 を対象にシミュレーションを行った電力需要量を比較する.本 来は、世帯推移シミュレータから得られた世帯情報を利用す るが、今回は検証のために実データを利用しており、世帯数は 2000 年と 2005 年の関東圏全域における世帯数の平均値とし て、1684 万世帯を採用する [9]. またタイムステップは1日と し、1年分である 365 ステップのシミュレーションを実施した.

#### 3.2 パラメータ設定

パラメータは世帯種割合とオール電化普及率であり,表1の 通りである.オール電化普及率は2009年の関東圏における普 及率を採用した[10].本研究では,簡単のため各世帯種均等に オール電化普及率を割り振った.

#### 3.3 結果

図4は、2003年における月ごとの電力需要量における実測 値とシミュレーション結果を示したものであり、図5は、図 4におけるシミュレーション結果を世帯種別に示したものであ る.図4において、夏期と冬期における電力需要量の増加傾 向は実測値と一致しており、電力需要の特性を示しているとい える.図5においても、世帯種毎の月別電力需要量の増減に ばらつきが見られるものの、季節単位での傾向は実測値と一致 した.



図 4: 月ごとの電力需要量の比較

表 2: 月ごとの電力需要量における誤差の比較

| 月  | 誤差 [%] | 月   | 誤差 [%] |
|----|--------|-----|--------|
| 1月 | -18.1  | 7月  | -6.3   |
| 2月 | -15.0  | 8月  | -2.6   |
| 3月 | -0.4   | 9月  | -2.2   |
| 4月 | -15.9  | 10月 | -18.2  |
| 5月 | -12.5  | 11月 | 14.2   |
| 6月 | -1.4   | 12月 | 4.3    |

表2は図4の実測値とシミュレーション結果における誤差 を表したものである.全体として実測値より下方に出力され, 大きな誤差の月として,1月,4月,10月等が見られた.

このような誤差が現れた原因として,消費電力使用量のデー タベース [7] の世帯数が 20 世帯程度であり,個々の世帯の影 響を受けやすいことが考えられる.電力使用量のデータをよ り集めることでより精度の高い出力結果になることが考えられる.

# 4. まとめ

本研究では世帯数,世帯属性の特徴を考慮した電力需要推 定モデルを開発した.月,平日・休日,発電方式を考慮し,月 別の電力需要量の傾向を表す推定モデルを作成した.今後の課 題として,時間帯別消費電力需要量に与える変数を刷新した 精度の向上や時系列解析導入による精度の向上が挙げられる. また電力の使用量は価格の影響や経済状況の影響も受け,年ご とに一人当たりの電力使用量も変動するため,このようなマク ロな変動も考慮することができれば,より精度の高いモデルへ となるだろう.今後の展望としては,蓄電池,再生可能エネル ギーの普及率を考慮した電力需要推定モデルへの改良が期待さ れる.蓄電池,再生可能エネルギーの普及の仕方は人口動態と 密接に関わっており,普及の仕組みをモデル化できれば,電力 システムの変革を実行する際の意思決定に有益となるモデルへ となるだろう.



図 5: 世帯種別の月ごとの電力需要量

# 参考文献

- [1] 資源エネルギー庁, "分散型エネルギーについて", http://www.enecho.meti.go.jp/committee/ council/basic\_policy\_subcommittee/mitoshi/ 006/pdf/006\\_05.pdf
- [2] 山際康平,藤井秀樹,吉村忍,"メゾスコピックモデルを 用いたマルチエージェント世帯推移シミュレーション".
   人工知能学会論文誌, Vol. 32, No. 5, pp. 1-10. 2017.
- [3] Bentzen J, Engsted T, "A revival of the autoregressive distributed lag model in estimating energy demand relationships", Energy, Vol.26, Issue 1, pp. 45-55. 2001
- [4] J.Widén and E.Wäckelgård, "A high-resolution stochastic model of domestic activity patterns and electricity demand", Appl. Energy, Vol.87, p.1880. 2010
- [5] 森田圭, 真鍋勇介, 加藤丈佳, 舟橋俊久, 鈴置保雄, "消費 電力量と世帯属性の分類に基づく世帯群の合計消費電力量 推定に関する一検討", 電気学会論文誌, Vol.136, No.6, 2016.
- [6] 森田圭, 真鍋勇介, 加藤丈佳, 舟橋俊久, 鈴置保雄, "数百 世帯規模の家庭の平均電力需要特性の評価", エネルギー 資源学会論文誌, Vol.38, No.1, 2017
- [7] (社) 日本建築学会,住宅内のエネルギー消費量に関する調査研究委員会:住宅におけるエネルギー消費量データベース,http://www.arg.ne.jp/node/2198
- [8] 電力事業連合会,電力需要実績,http://www.fepc.or. jp/library/data/demand/2010.html
- [9] 国立社会保障・人口問題研究所、日本の世帯数の将来 推計(都道府県別推計)、http://www.ipss.go.jp/ pp-pjsetai/j/hpjp2014/gaiyo/data.asp
- [10] 富士経済, "エネルギー需要家別マーケット調査要覧 2010 住宅分野編"

# スマートグリットにおける送電経路の最適化

Optimization of Power Electric Supply Path in Smart Grids

小澤 貴也 大沢 英一 Takaya Ozawa Ei-Ichi Osawa

公立はこだて未来大学 システム情報科学部 複雑系知能学科

Department of Complex and Intelligent Systems, School of Systems Information Science, Future University Hakodate

The next generation next-generation electric grids called smart grids are attracting attention due to problems such as global power shortage and environmental load caused by power generation. One of the problems with the current power being used is that the power transmission loss is large due to the long power transmission path. From such a problem, it is possible to reduce the power shortage and reduce the power generation amount by reducing the power transmission loss. For this reason, it is required to optimize the power transmission path. In this paper, we propose to reduce the power transmission loss by minimizing the power transmission path by using the code optimization method used by the compiler by treating the power transmission path like a program. We compared power transmission loss. In addition, it shows that it can be used by measuring the execution processing time of the proposed method.

# 1. はじめに

現在,日本の電力使用量は,情報化の進展やエアコンの普及 にみられるような快適な生活へのニーズが高まり,戦後一貫し て伸びている.また,今後電気自動車などの普及が予測される ため,電力需要はさらに増加すると考えられる.このような世 界的な人口増加や電力消費量の増加に伴う電力不足や,火力発 電による CO<sub>2</sub> 排出など発電による環境負荷が問題などにより スマートグリッドという次世代型電力網が注目を集めている. スマートグリッドとは,次世代型送電網と意味であり,電気自 動車などの電力貯蔵システムや太陽光発電などの分散型電源と スマートメータという人工知能や通信機能を搭載した計測機器 等を設置して電力需給を自動的に調整,最適化を可能にする電 力網を構築するという概念で効率的な電力供給が可能になると されている [谷口 10].

また,現在の使用されている電力の問題点としては,その 送電の過程で経路が長いことから送電損失が多いという点が ある.日本では電力が家庭に届くまでに送電損失によって約 4.8%失われている.年間では約 480億 kWh 送電損失となっ ており,これは 100万 kWh 級原子力発電所の約7基分の発 電量に相当する.このような問題から送電経路の最適化を行う ことで,送電損失量を削減することが可能であり,電力不足の 改善や発電量の削減が可能であると考えられる.そこで,本研 究では,電力の送電経路をプログラム言語のように扱い,コン パイラで利用されるコード最適化の手法を用いて送電経路の最 適化を可能にして,送電損失を削減する手法を提案した.

# 2. 前提知識

本章では、本研究の内容で用いる特に必要な知識について 述べる.

#### 2.1 複雑ネットワークモデル

現実世界に存在するネットワークは多くは複雑ネットワーク の性質が存在することがわかっている.電力網もまたスモール ワールド性やスケールフリー性の性質を持っていることがわ かっているので、本研究では複雑ネットワークモデルを使用す る.

複雑ネットワークを生成するモデルとして「ワッツ・ストロ ガッツモデル(WSモデル)」と「バラバシ・アルバートモデル (BAモデル)」などが存在する.これらのモデルは単純なアル ゴリズムより複雑ネットワークを生成することが可能であり, 本研究では,送電網の形状が複雑ネットワークの特性を持つこ とからWSモデル,BAモデルを使用して送電網を構築する.

#### 2.2 クラスター係数

クラスター係数は、任意のノードに隣接するノード同士が 隣接ノードである割合で、クラスター係数が高いネットワーク は関係密度が高いというものである。ノード v<sub>i</sub> のクラスター 係数 C<sub>i</sub> は、ノード i の次数 k<sub>i</sub> を用いて以下の式で算出する.

$$C_i = rac{v_i \varepsilon$$
含む三角形の数 $rac{k_i(k_i-1)}{2}$ 

# 2.3 媒介中心性

媒介中心性は、ノードが情報を媒介することに関与している度合いを表す尺度である [Brandes 01]. ノード $v_i$ の媒介中心性 $B_i$ は、始点 $v_{i_s}$ から $v_{j_t}$ の最短経路の中で $v_i$ を通るものを $g_i^{i_s i_t}$ として、最短経路の総数を $N_{i_s i_t}$ とするとき、以下の式で算出される.

$$B_{i} = \frac{\sum_{i_{s}=1; i_{s} \neq i}^{n} \sum_{i_{t}=1; i_{t} \neq i}^{i_{s}-1} \frac{g_{i_{s}}^{i_{s}} i_{t}}{N_{i_{s}} i_{t}}}{(N-1)(N-2)/2}$$

本研究では、媒介中心性が高いノードは送電線が多く集まる ノードである.そのため、ノードの媒介中心性とそのノードか ら出ていく経路数との相関について5章で考察する.

連絡先:小澤 貴也,公立はこだて未来大学 システム情報科学 部複雑系知能学科,北海道函館市中野町 116-2,0138-34-6448,b1015112@fun.ac.jp

#### 2.4 電力に関する基本的な数式

本研究では、現在送電に使用されている導線の抵抗率から シミュレーションに必要な電力に関する数値を算出した.本章 では、研究に必要な基本的な電力に関する数式を必要な知識に ついて示す.電力とその送電による送電損失は以下の式によっ て算出される.

送電抵抗: $R = \rho \times l$ 

送電損失:  $P(W) = I^2 \times R$ 

• W:電力, I:電流, ρ:導線抵抗, R:導線の長さ

本研究では,送電損失が導線の長さに比例することから,導 線の長さつまり送電距離を最適化することで送電損失量を削減 可能と想定している.

# 3. 関連研究

# 3.1 経路探索を用いた電力損失を最小化する経路選択 手法

スマートグリッドにより電力の流れを制御することで,電力 を削減する研究がある [尾倉 14]. この研究では,ヨーロッパ の15 カ国を結ぶ実際の送電網のうち2 カ国を繋げる経路を最 短経路で電力を削減するというものである.

方法としては、エッジとノードの数を最小にするように経路 を選択することで、送電損失量が最小になるという考えから幅 優先探索により経路を決定する.また、シミュレーション環境 としては、15カ国をノードとし、送電網をエッジとする.ま た、それぞれのエッジには送電損失量を超伝導交流送電線を参 考に設定している.

実験結果から表 2.1 および表 2.2 から必ずしも最小経路が一 番電力損失が小さいわけではなく,各ノードの送電損失率も影 響していることがわかった.

| 衣 1: 供栢地 115 , ה安地 112 の場合 ( 尾居 14 | 表 1: | 供給地'n5', | 需要地'n12' | の場合 | ([尾倉 | [14] |
|------------------------------------|------|----------|----------|-----|------|------|
|------------------------------------|------|----------|----------|-----|------|------|

| $n8 \sim n14$  | 距離         | 送電損失率  |
|--|------------|--------|
| $n8 \rightarrow n4 \rightarrow n10 \rightarrow n13 \rightarrow n14$  | 2954.74km  | 35.93% |
| $n8 \to n9 \to n10 \to n13 \to n14$                                  | 2638.54 km | 36.30% |
| $n8 \rightarrow n12 \rightarrow n10 \rightarrow n13 \rightarrow n14$ | 3421.55 km | 41.14% |

表 2: 供給地'n5', 需要地'n12' の場合 ([尾倉 14])

| $n5 \sim n12$                                       | 距離         | 送電損失率  |
|---|------------|--------|
| $n5 \rightarrow n4 \rightarrow n8 \rightarrow n12$  | 1866.53 km | 23.98% |
| $n5 \rightarrow n7 \rightarrow n10 \rightarrow n12$ | 1543.51 km | 23.99% |
| $n5 \rightarrow n4 \rightarrow n9 \rightarrow n12$  | 1931.14 km | 25.79% |
| $n5 \rightarrow n4 \rightarrow n10 \rightarrow n12$ | 2558.94 km | 29.60% |

# 3.2 コード最適化手法を用いてトラック経路の効率化 を行う手法

共同物流のトラックをコンパイラで利用されるコードの最適 化を用いて,トラック経路の効率化を行い CO<sub>2</sub> を削減する研 究として佐藤による研究がある [SATOH 08].

この研究では、プログラム言語の実行フローとトラック経路 の類似性があることからトラックの経路をプログラム言語とし て扱えるようにして、プログラムのための各種技術を通じてト ラック経路を効率化を行った.経路の効率化として、コード最 適化手法として逐次化と冗長コード除去を用いることでトラッ ク輸送において同じ集配先に何度も行かないように経路を変更 した.また、並列プログラムなどでは逐次実行プログラムの並 列化とは逆に並列プログラムを逐次化(直列化)することでト ラックの数を減らすことを可能にした.

また,実際のトラック輸送経路に対して,所定の輸送条件を 満足させながら効率化した結果,10%程度の効率化できた.

本研究では、このコードの最適化手法によるトラックの経路 の最適化を元に集配先を一般家庭とし、トラックの経路では、 一つ経路最適化であったものを複数の経路による送電経路の最 適化を行った.

# 4. 提案手法

本研究では,送電損失の削減のために送電経路の最適化を 行う.最適化の方法として,佐藤の研究 [SATOH 08] を参考 に送電経路をプログラム言語として扱うことで,電力供給条件 を満足させながらコンパイラのコード最適化手法として冗長 コード除去や逐次化(直列化)を用いる.本章では,提案する 手法による経路選択方法について述べる.

### 4.1 コードの最適化

提案手法では,コンパイラで使われるコードの最適化手法 である逐次化 (直列化) および冗長コードの除去の手法を用い ている.

#### 逐次化 (直列化)

逐次化とは、2つのコードを統合することにより冗長なコー ドを削除することで最適化を行うというものである.つまり、 本手法では、図1のように送電を一括化して,経路の削減を 行う.また,高電圧で送電を行うことで送電損失は削減が可能 となる.



図 1: 電力網における逐次化 (直列化) および冗長コードの除 去の例

#### 冗長コードの除去

冗長コードの除去とは、コード内の冗長な使用されていない コードを削除することで最適化を行うというものである.電力 網の場合,構造から送電経路が同じノードへ戻ってくることが あることからノードの重複する移動を除去する.つまり、図1 のように電力要求のない経路内のエージェント削減を行う.

### 4.2 送電経路選択方法

提案手法による経路選択は以下のような流れで行う. 送電経路の選択方法:

- 1 すべての電力需要家を求めて,貯蓄設備から需要家を結 ぶ経路を作成する.
- 2 コード最適化 (冗長コード除去や逐次化 (直列化)) を行う.
- 3 距離の短い送電経路を選択

例として、図2の1のような電力網の貯蓄設備からB,Cへの供給を考える.まず2のように貯蓄設備とB,Cを結ぶ経路を作成する.次に、作成された経路に逐次化と冗長コードの除去を行うことで3のような経路が決定する.



図 2: 提案手法の使用例

# 5. 実験

本実験には、多数の需要家をエージェントとする大規模エー ジェントネットワークを構築し、提案手法とダイクストラ法の 送電経路を計測し送電損失量を比較した.

計測日数を 365 日とし,太陽光発電により発電した電力の 融通可能であると想定する.また,送電による電力の損失は, 送電線の導線抵抗のみを想定する.また,需要と供給源のマッ チングには,空間マッチングを用いて行う[山本 11].また,太 陽光発電の発電量は函館市の一年間の日射量から算出した.

本研究では、潮流などをさけるため物理的制約として、電力 は一方向にしか流れないものとする.また、配電用変電所から 家庭への送電を想定している.

## 5.1 実験パラメータ

実験にはエージェント数は 100~1000 でそれぞれ 3 回行う. その他のパラメータは,実際に使用されてるものを参考に以下 のように設定した.

- 平均電力消費量: 18.5kWh
- 発電システムの設置容量:4.5kWh と
- 送電線の許容電流:6600A
- 平均次数:k = 4

太陽光による発電可能エージェントの割合を約8%とした. エージェントの電力需要量は、用意した電力消費需要パターン の朝型, 夜型,中間型の3種類用意からランダムに設定した. シミュレーションの電力融通市場は、送電網を複雑ネットワー クモデルである WS モデルと BA モデルで生成する.電力融 通を行うエージェントは、蓄電池を持つ一般家庭と電力事業者 とした.一般家庭を想定したエージェントの約8%が、太陽光 発電が可能と設定した.送電量は、送電線の許容電流以上の電 流を流すことはできないとする.

#### 5.2 実験結果1:総経路削減率

エージェント数 500 を3回行ったときの平均削減率の結果を 表3に示す.ダイクストラ法と提案手法を比較した結果,BA モデルでは提案手法によって 4.8% 削減が可能となった.WS モデル p = 0.1の場合は 29.5% 削減が可能となった.

|         | BA モデル     | WS モデル $(p = 0.1)$ |
|---------|------------|--------------------|
| 提案手法    | 3952.8 km  | 9112.3 km          |
| ダイクストラ法 | 4153.63 km | 12926.8 km         |
| 削減率     | 4.8%       | 29.5%              |
| クラスター係数 | 0.096%     | 0.379%             |
|         |            |                    |

表 3: 削減率 1

また,レギュラーグラフに近いネットワークが生成される p = 0.05のWSモデルとランダムグラフに近いネットワーク が生成されるP = 0.5のWSモデルで実験を行った結果は表 4 である.結果からp = 0.05のWSモデルのほうが削減率が 上がった.

#### 表 4: 削減率 2

|         | WS モデル ( $p = 0.05$ ) | WS モデル $(p = 0.5)$ |
|---------|-----------------------|--------------------|
| 提案手法    | 5991.9 km             | 8931.0km           |
| ダイクストラ法 | 14726.8 km            | 11705.6km          |
| 削減率     | 59.3%                 | 23.7%              |
| クラスター係数 | 0.415%                | 0.073%             |

この結果もっともクラスター係数が高い p = 0.05 の WS モデルが一番削減率が高く,クラスター係数がもっとも低い BA モデルが一番削減率が低いことから提案手法による経路削 減率はクラスター係数が関係していることが考えられる.この ことは,最適化手法の特に逐次化が関係していると考えられ る.また,BA モデルと比べ WS モデルの削減率が著しく上 がった要因として複雑ネットワークモデルの特性であるスケー ルフリー性が関係していると推測される.BA モデルはスケー ルフリー性を持つが WS モデルは持たない.このことから最 適化手法が行われる区間が供給源から次数の高いノード特にハ ブのようなノードまでとなり削減率が下がることが考えられる.

また,エージェント数1000で3回ずつ,2017年度の北海 道電力の電力使用量から算出した北海道内の送電損失量と提 案手法による送電損失量を比較した結果,WSモデルでは約 49.8%,BAモデルでは約45.49%の削減が可能となった.こ の結果から提案手法による経路選択は送電損失量の削減が可能 であると考えられる.しかし,本研究では,送電損失は送電線 の導線抵抗のみを想定している.実際の損失にはコロナ放電な どの送電損失があるため実験結果よりも削減率は下がると考え られる.

次に,エージェント数 1000 の場合のノードの媒介中心性と 提案手法による経路選択によって,そのノードを経由する経路 の数の結果は図 3 および図 4 である.結果より,ノード媒介中 心性とそのノードを経由する経路の数には相関が示唆された.



図 3: WS モデル



図 4: BA モデル

#### 5.3 実験結果 2: 実行速度

エージェント数 100~1000 までをそれぞれ3回行いその平 均処理時間を表したグラフが図5である.結果からWSモデ ルより BAモデルの方が処理時間が短いことがわかった.ま た,平成27年の北海道内の世帯数と変電所数からひとつの変 電所あたり約6600世帯の供給を行う.実験で得られた処理時 間に最小二乗法を適用して推定した曲線から6600世帯への提 案手法による経路選択にかかる処理時間はWSモデルでは約 1.64秒で,BAモデルでは0.85秒であると推測される.よっ て,現在の送電網でも実行可能時間で提案手法を用いて送電経 路を決定することは可能であると考えられる.

# 6. おわりに

本研究では、現在の送電システムでは送電損失量が多いとい う問題に対して、コードの最適化手法を送電経路に用いること で経路の削減を行い、それにより送電損失量の削減を行った. ネットワークの生成には実際の送電網に近い構造を持つ複雑



図 5: 平均処理時間

ネットワークモデルである WS モデルと BA モデルで生成し た.送電損失の削減の評価方法としては、ダイクストラ法を用 いて送電経路を生成したものと北海道の送電損失量を算出し、 提案手法との比較を行った結果、提案手法ではダイクストラ法 による経路と北海道の送電損失量に比べ送電損失量が少ないこ とを示した.

また、ネットワークの特性と提案手法との関係を調べるため ノードの媒介中心性とそのノードを経由する経路数との関係 を調べた.実験結果から媒介中心性の高いノードには多くの 経路が集まることが示された.そして、実際に使用可能である か調べるため、提案手法の実行処理時間の計測した結果、実行 処理時間から現在の送電網でも使用可能であることを示した. よって、このことから提案手法は、送電損失量の削減が可能で あり、現在の送電網で使用可能であると考えられる.

また、本研究では、送電の全体の経路の削減を行ったがもっ とも送電損失量が少なくなる経路選択ではない.また、送電損 失量の削減の最適解を取るには多くの処理時間が必要となる. よって、処理時間は変わらずに提案手法より送電損失量の削減 方法の提案が必要となる.また、本研究では経路の削減を行っ たが、さらに需要家と供給家の組み合わせによって送電損失量 の削減をする方法を模索したい.

# 参考文献

- [谷口 10] 谷口忠大, 榊原一紀, 西川郁子:自律分散型 スマートグリッド上の電力取引に対する自然方策勾配法によるマルチエージェント強化学習の有効性検証.第22回自律分散システム・シンポジウム,2010
- [尾倉 14] 尾倉康男, 篠宮紀彦:送電網において電力損失を最 小化する経路選択手法, 電子情報通信学会技術研究報告 = IEICE technical report:信学技報, 113(427), 2014.2.6・ 7, p.63-65
- [SATOH 08] SATOH I. : A Specification Framework for Earth-friendly Logistics. Proceedings of 28th IFIP WG6.1 International Conference on Formal Techniques for Networked and Distributed Systems (FORTE ' 2008), Springer June, 251-266, 2008
- [山本 11] 山本草詩,石井大介,岡本聡,山中直明:スマートグ リッドにおける送電ロスが最小となる発電源選択法の一 検討.電子情報通信学会技術研究報告 = IEICE technical report:信学技報,2011
- [Brandes 01] Brandes U. : A faster algorithm for betweenness centrality, Journal of Mathematical Sociology, Vol.25, No.2, pp.163-177, 2001

# 電力分け合いサービスの MAS モデルの設計と基礎評価 Design and Preliminary Evaluations of Multi-Agent Simulation Model for Electric Power Sharing among Households

| 西村康孝*1                              | 志村泰知*2                                  | 和泉 潔*3               | 吉原 貴仁*1                            |
|-------------------------------------|---|----------------------|------------------------------------|
| Yasutaka Nishimura                  | Taichi Shimura                          | Kiyoshi Izum         | i Kiyohito Yoshihara               |
| *1 KDDI 総合研究所<br>KDDI Research Inc. | <sup>*2</sup> 構造計画码<br>Kozo Keikaku Eng | 千究所<br>ineering Inc. | *3 東京大学<br>The University of Tokyo |

Abstract: Electric power sharing among households based on bidding method is studied as a future service. In order to verify the feasibility of the service, we newly designed a multi-agent simulation model. We validate this model through preliminary evaluations. For example, it is confirmed that the market price in this service stably changes according to the supply and demand balance between sold bid volume and purchased bid volume. In addition to that, results of household income and contract rate of this service showed that the design for bid strategies works as intended.

# 1. はじめに

太陽光発電(以下, PV)の余剰電力買取制度(以下, FIT)で設定 された 10 年間の買取義務保証期間が終了する世帯(以下, 卒 FIT 世帯)が 2019 年から登場し始める. FIT 期間中は PV 発電量の内, 宅内消費で余った余剰電力は固定単価での買取が保証されてい た. 10 年間保証される固定単価は 2009 年開始世帯の 48 円/kWh から年々低価格に推移し, 2018 年開始世帯は 26 円/kWh であった. 卒 FIT 世帯の余剰電力の買取単価は保証されていた固定単価か ら大きく低下すると言われており, いくつかの小売電気事業者から 発表されている卒 FIT 世帯向け新買取サービスの水準は約 10 円/kWh である. このため, 卒 FIT 世帯の余剰電力の価値を高める 手段として, 蓄電池導入による自家消費の促進や, 余剰電力を他 世帯へ売電する電力分け合い[井上 11]などが検討されている.

電力分け合いでは、余剰電力を小売電気事業者の買取単価より 高く他世帯へ売電できると得をする. PV を保有していない世帯も、 宅内消費する電力を小売電気事業者からの買電単価より安く他世 帯から買電できると得をする.余剰電力の総量と宅内消費の総量は 常には一致しないため、売買相手を決定する取引方法が必要にな る.取引方法には日本卸電力取引所(以下, JEPX)で発電事業者と 小売電気事業者との売買で用いられている入札方式などがある.

電力分け合いは既存サービスがほとんどなく、世帯と小売電気事 業者の利益や市場価格の安定性、市場成立に必要なサービス加 入世帯数など、サービスの実現性検証が課題である.しかしながら、 入札を想定した電力分け合いは、世帯の入札行動が天気や季節 などの環境により変化し、他世帯の入札と相互作用する複雑系であ り検証が困難であった.このような複雑系の解析には MAS(Multi-Agent Simulation)[和泉 17]が有望である.そこで本稿では、電力分 け合いの実現性検証のための電力分け合い MAS モデルを設計し、 基礎評価を通してモデルの妥当性を確認する.

# 2. 関連研究

電力・エネルギー分野への MAS の主な応用事例として,電力市 場と送配電システムに関する新制度を,安定性や効率性,有効性 などの観点から評価検証する研究がある.電力市場に関しては,国 内外の多くの研究でエージェントシミュレーションが使われ[渡 邊 03][Ullah 13],既に米国ではエージェントベースの大規模な電 カ市場テストベッド AMES が構築されて電力市場制度の評価検証 で利用されている[Sun 07]. 送配電システムに関して,実際の宅内 消費データや発電データを用いて電力消費エージェントの挙動を 決定しスマートグリッドシステムの効率性を評価検証した研 究[Vytelingum 10]がある.また,世帯や企業,小売電気事業者が 入札方式で参加する電力市場を想定し,分散した小規模な電力市 場により電力価格と配電ネットワークを創発的に構築する新たな電 力流通システムの有効性を分析する研究[井上 11]などがある.

以上のように、入札方式による世帯間の電力売買を想定した MASの応用事例は多くは知られていない. [井上 11]の研究では想 定は類似しているが、主な目的は電力流通システムの評価検証で あった.本稿では、電力分け合いサービスの実現性検証を目的とし、 利益追求や再エネ由来の電力を使いたいエコ志向など、世帯の異 なる考え方をモデル化したり、世帯利益を評価したりするなど、サー ビス観点での評価検証を重視する MAS モデルを設計する.

# 3. 電力分け合いサービス

# 3.1 サービス概要

世帯間で入札を通して電力を売買する. PV, 定置用蓄電池, EV(Electric Vehicle)の内1つ以上保有する世帯が電力分け合いで 売り手になれる. PV 保有世帯は PV 発電量から宅内消費量を引い た余剰電力を売電できる. PV に加えて, 定置用蓄電池や EV など の蓄電池を保有する世帯は, 余剰電力を蓄電して好きなタイミング に売電することもできる. 蓄電池のみを保有する世帯は, 夜間に小 売電気事業者から買電した電力を蓄電し, 昼間に売電することがで きる.

全世帯が電力分け合いで買い手になれる. 宅内消費する電力を 他世帯から買電できる.

# 3.2 想定環境

# (1) 小売電気事業者との契約

PV 発電が無い夜間など、電力分け合いだけで各世帯の宅内消費を賄うことはできない点を考慮して、各世帯は電力分け合いサービスに加えて、従来の買電を小売電気事業者と契約していることを想定する.また、入札により全ての売電入札が約定しない点を考慮して、売り手になれる世帯は小売電気事業者の定価買取を契約していることを想定する.

連絡先: 西村 康孝, KDDI 総合研究所, 埼玉県ふじみ野市 大原 2-1-15, yu-nishimura@kddi-research.jp

#### (2) 電力分け合いに対する世帯の考え方

利益追求, エコ志向, 無関心の3 つを想定する. 利益追求は電 力分け合いを通した利益増を追求する. エコ志向は電力分け合い を通し, 小売電気事業者との定価売買と比較して損をしない範囲で, 自世帯の宅内消費電力に占める再エネ由来電力の比率向上を志 向する. 無関心は小売電気事業者との定価売買と比較して損をし ない範囲であれば満足し, 利益増や再エネ由来電力の比率の向 上に関心が低い.

## (3) 約定方式

約定方式として, JEPX のスポット市場などで用いられているブラ インド・シングルプライスオークションを想定する.

#### (4) 電力の流れ

電力分け合いの売買取引と合わせて電力も世帯間で直接流す 方法と,既存の電力の流れは変えず,売買取引のみ仮想的に世帯 間で実施する方法が考えられる.前者は既存の電力インフラに大 規模な改修が必要になるため,広範囲な電力分け合いを想定する と非現実的である.本稿では後者を想定する.

#### 3.3 取引イメージ

30分を1コマとした1日48コマについて電力分け合いの売買入 札を実施する.各コマはコマ ID(1~48)で表す.約定した世帯間で は,約定価格で電力を売買する.約定しなかった世帯は,小売電 気事業者と定価で電力を売買する.

ある日のコマ ID=20(9:30 から 10:00 のコマ)を例に、入札から約 定までの流れを図 1 に示す.売電世帯 S1, S2 と買電世帯 B1, B2 はコマ ID=20 が始まる 9:30 より前に入札価格を決定する(図 1(1)). 各世帯の入札量は 9:30 から 10:00 の PV 発電や宅内消費の実績 に基づき事後に確定する(図 1(2)).入札価格と入札量の情報を突 き合わせて約定計算する(図 1(2)).ブラインド・シングルプライスオ ークションの価格優先の原理に基づき,売電世帯 S1 の売電入 札 10kWh と買電世帯 B1 の買電入札 10kWh が約定する.残った 売電世帯 S2 の売電入札と,買電世帯 B2 の買電入札は、入札価 格が合致しないため約定しない.売電世帯 S2 の入札量 10kWh は 小売電気事業者が定価で買い取る.買電世帯 B2 の入札量 5kWh は小売電気事業者から買電単価で買電する.

# 4. 電力分け合い MAS モデルの設計

電力分け合いサービスとその取引を模擬する電力分け合い MAS モデルを設計する. モデルは世帯エージェントと小売電気事 業者エージェントから構成する.

# 4.1 世帯エージェント

世帯エージェントの属性情報として,保有設備,小売電気事業者 との契約情報,入札戦略を設定できる.

#### (1) 保有設備

PV や定置用蓄電池, EV の有無を設定する. 有りの場合は, PV の定格出力値[kW]や蓄電池の蓄電容量[kWh]などの保有設備の スペック情報を合わせて設定する.

#### (2) 小売電気事業者との契約情報

小売電気事業者からの買電単価[kWh/円]と,小売電気事業者 の買取単価[kWh/円]の情報を設定する.これらの単価はコマ毎に 設定でき,時間帯に依らず固定値としたり,日中と夜間で異なる単 価としたりすることができる.



図1:入札と約定の処理イメージ(コマ ID=20 の場合)



図2:利益追求戦略の入札価格の決定方法

#### (3) 入札戦略

電力分け合いに対する世帯の考え方に対応する入札戦略として、 利益追求, エコ志向, 無関心の中から1つを選択する. 選択した入 札戦略に応じて世帯は入札価格を決定する. 小売電気事業者から の買電単価より高い買電入札価格や, 小売電気事業者の買取単 価より安い売電入札価格は非合理的であるため, 全入札戦略に共 通して, 入札価格の上限P\_MAXは小売電気事業者からの買電単 価, 下限P\_MINは小売電気事業者の買取単価とする.

利益追求戦略は、過去の約定結果と市場価格に基づいて、適宜 入札価格を変更する. i日のコマID = j (j = 1, 2, ..., 48)において、 ある世帯の売電入札価格bid(i, j)は、前日((i - 1)日)のコマID = jにおける同世帯の売電入札価格bid(i - 1, j)と、そのコマの市場価 格MP(i - 1, j)、同世帯の約定結果の3点の情報により図2(a)の通 り算出する. 前日同コマで約定してない場合は、入札し易くなるよう 入札価格をパラメータa[円/kWh]下げる. 前日同コマで約定してい る場合、市場価格と前日同コマの入札価格の差が閾値 $\alpha$ 以下の場 合は、入札価格を上げると約定しなくなる可能性が比較的高いため 入札価格を維持する. 一方、閾値 $\alpha$ より大きい場合は、乱数p(0 - 1)を用いて $p > 閾値\beta$ の場合に確率的に入札価格をb[円/kWh]上げ て利益増加を図る. ここで、 $a, b, \alpha, \beta$ は0以上の実数のパラメータ である.

利益追求戦略の買電入札価格も同様に変更する. i日のコマID = jにおいて、ある世帯の買電入札価格ask(i,j)は前日((i-1)日)の コマID = jの同世帯の買電入札価格ask(i-1,j)と、そのコマの市 場価格MP(i-1,j)、同世帯の約定結果により図 2(b)の通り算出す る. 前日同コマで約定していない場合は、入札し易くなるよう入札価 格をパラメータa'[円/kWh]上げる. 前日同コマで約定している場合、 市場価格と前日同コマの入札価格の差が閾値a'以下の場合は、入 札価格を下げると約定しなくなる可能性が比較的高いため入札価 格を維持する. 一方、閾値a'より大きい場合は、乱数p(0~1)を用い て $p > 閾値<math>\beta'$ の場合に確率的に入札価格をb'[円/kWh]下げて利 益増加を図る. ここで、 $a',b',a',\beta'$ は 0以上の実数のパラメータで ある.

エコ志向戦略は約定率を高めるため,常に成り行き注文を実行 する.無関心戦略は常に同じ入札価格での入札を実行する.

なお,各世帯の入札価格の初期値は小売電気事業者からの買 電単価と小売電気事業者の買取単価との間の一様分布で与える.

### (4) 世帯エージェントの動作

各コマでの宅内消費量やPV発電量から売電と買電のポジション が決定する.ポジション決定後,入札戦略に基づいて入札価格を 算出して入札する.

# 4.2 事業者エージェント

事業者エージェントは世帯の売買入札を集約し,約定計算を実施して約定結果を当該世帯エージェントに通知する.市場価格の 情報は全世帯エージェントに公開する.約定結果に応じて電力分 け合いの売買と小売電気事業者との売買を集計し,買電による世 帯支出と売電による世帯収入を計算する.

# 5. 電力分け合い MAS モデルの基礎評価

# 5.1 評価方針

電力分け合いサービスの実現性検証に電力分け合い MAS モデ ルを活用することを目標に,基礎評価を通して同モデルの妥当性を 確認する.具体的には以下の2点を確認する.

- 電力分け合いの市場価格が売電入札量と買電入札量の需給バランスに応じて安定的に形成される点
- 利益追求やエコ志向, 無関心の入札戦略毎の世帯利益や約 定率が設計(4.1章(3))通りになる点

# 5.2 評価指標

市場価格推移と需給バランス,世帯利益,約定率を評価指標に 用いる.市場価格は各コマでの買電入札と売電入札を突き合わせ て約定計算により算出される.需給バランスは(売電入札 量[kWh]/買電入札量[kWh])で計算する.夜間は0になり,日中は PV発電量の増加に伴い増加する.

世帯利益については、小売電気事業者と電力売買した場合の収 支を起点とし、電力分け合いにより得した金額として集計する.これ より世帯利益は0円以上になる.電力分け合いによる売買が無い世 帯の利益は0円になる.電力分け合いにより、小売り電気事業者か らの買電単価や、買取単価と比較して得する価格で売買できると世 帯利益が0円より大きくなる.約定率は約定量[kWh]/入札量[kWh] として集計する.

#### 5.3 入力データ

宅内消費電力データの例を図3に示す.ある電気サービスの宅 内消費電力データを基に統計的に加工して作成した.平日は起床 後(コマ ID=15~17(7時~8時30分))にピークがあり,外出後(コマ ID=18(8時30分~9時)以降)に宅内消費が低下するのに対し,土 日祝日は起床時間が平日と比較して遅い点や日中も宅内消費電 力が平日と比較して高い傾向など,平日と土日祝日の宅内消費パ ターンの違いを模擬している.

PV 発電量データの例を図4に示す.PV 発電量データは東京都の7月1日~7月31日を対象とし、日の出と日の入りの時間や太陽高度の情報を用いて数値シミュレーションで作成した.PVの定格出力は一般的な水準である4kWとし、夏至の正午をピークに、その他の日や時間帯は太陽高度に応じて減少する形で作成した.PV 発電量への天候や日照量、発電ロスの反映は今後の課題である.

# 5.4 評価条件

基礎評価のための評価条件を表1に示す.シミュレーション期間 は7月1日~7月31日の1か月間で世帯数は10,000世帯とす る.小売電気事業者からの買電単価は26円/kWh,小売電気事業 者の買取単価は5円/kWhとする.これらの単価は1日48コマ共 通の固定値とする.



表1:評価条件 シミュレーション期間 世帯数 10,000

| 世帯数             | 10,000       |
|-----------------|--------------|
| 小売電気事業者からの買電単価  | 26 円/kWh     |
| 小売電気事業者の買取単価    | 5 円/kWh      |
| PV 保有率          | 2%, 10%, 20% |
| 入札戦略の比率         | 10:10:80     |
| (利益追求:エコ志向:無関心) |              |



図5:コマ毎の市場価格推移と需給バランス

入札戦略の比率は、利益追求戦略、エコ指向戦略、無関心戦略 を 10:10:80 とする. PV 保有率 2%、10%、20%の 3 通りについて、 需給バランスが異なる場合の市場価格推移や世帯利益の変化を見 る. 定置用蓄電池や EV の保有率は 0%とする.

利益追求戦略のパラメータについて, a = 1 円/kWh, b = 1 円/kWh,  $\alpha = 3$  円/kWh,  $\beta = 0.3$ . a' = 1 円/kWh, b' = 1 円/kWh,  $\alpha' = 3$  円/kWh,  $\beta' = 0.3$ とする.

# 5.5 市場価格推移と需給バランス

PV 保有率が 2%, 10%, 20%の場合の 1 か月間のコマ毎の市場 価格推移と需給バランスを図 5(a)(b)(c)にそれぞれ示す.約定しな かったコマの市場価格は便宜上-1 円/kWh としている. PV 保有率 に依らず, PV 発電が無い夜間は需給バランスが 0 で約定していな い. 一方, PV 発電が有る日の出 5 時 30 分頃から日の入り 18 時頃 の間は, 需給バランスが 0 より大きくなり,約定していることが分かる.

PV 保有率が 2%の場合(図 5(a)), 需給バランスは 0~0.19 の範 囲で売電入札量は買電入札量に対して高々1/5 と極端に少ない. 市場価格は 22.0~26.0 円/kWh と比較的高い価格帯を推移している.

PV 保有率が 10%の場合(図 5(b)), 需給バランスは 0~1.11 の範 囲であり, 売電入札量が買電入札量を上回るコマが出てくる. 市場 価格は 14.9~26.0 円/kWhと広範囲を推移している.

PV 保有率が 20%の場合(図 5(c)), 需給バランスは 0~2.48 の範囲であり, 売電入札量が買電入札量の 2.48 倍と大きく上回るコマが 有る. 市場価格は 10.0~26.0 円/kWh と PV10%の時よりも広範囲を 推移している.

続いて PV 保有率 20%の場合におけるコマ別の日毎の市場価格 推移を図 6 に示す.日の出(コマ ID=11)や日の入り(コマ ID=36)は PV 発電量と需給バランスが共に小さいため,20 円/kWh 以上の高 い市場価格で推移している.その間の時間帯(コマ ID=18,24,30) は PV 発電量と需給バランスが共に大きいため,10~15 円/kWh 程 度の市場価格で推移している.

以上のように、需給バランスが低いと市場価格は高く、需給バランスが高いと市場価格は低価格帯を推移するなど、需給バランスに応じて市場価格が形成されている.また、PV 保有率 20%の場合など、1日の中で市場価格はコマ ID に応じて10円~26円/kWhのように大きく変動するが、コマ別での日毎の市場価格は安定的に推移している.同じコマで見た場合、日毎の需給バランスは大きく変わらないことから、需給バランスにより安定的に価格形成されていると言える.

### 5.6 世帯利益

売電世帯と買電世帯の入札戦略毎の利益[円/月]の箱ひげグラフを図7,図8にそれぞれ示す. PV 保有率が2%,10%,20%の全ての場合において,利益追求の利益が最も大きくなっており設計通りの結果になっている.利益追求と無関心について,利益の最大値と最小値に差異があるが,利益追求の方が無関心と比較して差異が小さい.この点について,利益追求は入札価格を市場価格に近づける方向に毎日変更するため,全世帯近しい入札価格に推移しているためと考えられる.

売電世帯の利益について, PV 保有率が高くなる程小さくなって いる. 買電世帯の利益については PV 保有率が低くなる程大きくな っている. この点について, PV 保有率が高くなる程,市場価格が低 価格帯に推移している結果(図 5)と合致している.

### 5.7 約定率

売電世帯と買電世帯の入札戦略毎の約定率を図 9 に示す. PV 保有率 2%, 10%, 20%の全ての場合において, エコ志向の約定率 が最も大きくなっており, 設計通りの結果になっている.

売電世帯の約定率について, PV 保有率が高くなる程低くなって いる. 買電世帯の約定率については PV 保有率が低くなる程高くな っている. この点について, PV 保有率が高くなる程, 需給バランス が大きくなる点(図 5)と合致している.

## 6. まとめ

世帯の余剰電力を世帯間で入札により売買する電力分け合いサ ービスを対象とした電力分け合い MAS モデルを設計した. 基礎評 価を通して同モデルの妥当性を確認した. 具体的には, 売電入札 量と買電入札量の需給バランスに応じて市場価格が安定的に推移 していた. また, 入札戦略毎の世帯利益や約定率について, 利益 追求戦略の世帯利益が高く, エコ志向戦略の約定率が高くなるな ど, 設計通りの結果が得られる点を確認した.

今後は、入札戦略の比率を変えた場合の評価や、JEPX 市場で の価格高騰などの事例を参考に、異常状態に対する市場価格推 移の安定性などを評価する.



図 6: PV 保有率 20%の場合のコマ別日毎の市場価格推移



図7:入札戦略毎の売電世帯の利益







図9:入札戦略毎の約定率

## 参考文献

- [井上11] 井上淳,藤井康正.パケット電力取引に基づく革新的配電シス テムの提案.電気学会論文誌 B, Vol. 131, No. 2, pp. 143-150, 2011.
- [和泉 17] 和泉潔,斎藤 正也,山田 健太. マルチエージェントのための データ解析,コロナ社,2017.
- [渡邊 03] 渡邊勇,岡田健司,栗原郁夫,永田真幸.電力市場のシミュレ ーション一市場シミュレータの開発とエージェントモデルの分析.電 力中央研究所報告,R02022,2003.
- [Ullah 13] Qudrat-Ullah, H. Energy Policy Modeling in the 21st Century. Springer, 2013.
- [Sun 07] Sun, J. and Tesfatsion, L. Dynamic testing of whole-sale power market designs: An opensource agent-based framework. Computational Economics, Vol. 30, No. 3, pp. 291–327, 2007.
- [Vytelingum 10] Vytelingum, P., Voice, T. D., Ramchurn, S., Rogers, A., and Jennings, N. Agent-based Micro- Storage Management for the Smart Grid. In Proc. Autonomous agents and multiagent systems, pp. 39–46, 2010.

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

# [3C3-J-9] Natural language processing, information retrieval: creation and analysis of stories

Chair:Hiromi Wakaki Reviewer:Masahiro Ito Thu. Jun 6, 2019 1:50 PM - 2:50 PM Room C (4F International conference hall)

# [3C3-J-9-01] Novel Segmentation Method based on the Distributed Representation of Sentences and Analysis Method of Story Developments OKiyohito Fukuda<sup>1</sup>, Naoki Mori<sup>1</sup>, Makoto Okada<sup>1</sup> (1. Osaka Prefecture University) 1:50 PM - 2:10 PM

[3C3-J-9-02] Analysis of Four-scene Comics Story Dataset based on natural language processing

ORyo Iwasaki<sup>1</sup>, Naoki Mori<sup>1</sup>, Miki Ueno<sup>2</sup> (1. Osaka Prefecture University, 2. Toyohashi University of Technology)

2:10 PM - 2:30 PM

# [3C3-J-9-03] Search for Similar Story Sentences based on Role of Characters in order to Support and Analyze Contents Creator's Ideas OTakefumi Katsui<sup>1</sup>, Miki ueno<sup>1</sup>, Hitoshi Isahara<sup>1</sup> (1. toyohashi university of technology)

2:30 PM - 2:50 PM

# 文の分散表現に基づく小説の自動分割とストーリー展開の解析

Novel Segmentation Method based on the Distributed Representation of Sentences and Analysis Method of Story Developments

> 福田 清人<sup>\*1</sup> 森 直樹<sup>\*1</sup> 岡田 真<sup>\*1</sup> Kiyohito Fukuda Naoki Mori Makoto Okada

> > \*1大阪府立大学 工学研究科

Graduate School of Engineering, Osaka Prefecture University

Recently, the attempts to reproduce the mechanisms of human intellectual activities have attracted interest in artificial intelligence fields. The narrative creation is one of them. It is necessary for narrative creation and creative support by the computer to make it to understand human creations and their stories. However, there are few studies on story analysis by the computer. In this study, we propose the segmentation method of novels based on the distributed representation of sentences and the analysis method of story developments. As a result of computational experiments, we confirmed that the effectiveness of the proposed methods.

# 1. はじめに

近年,人の知的活動の仕組みを計算機上で再現する試みが人 工知能の分野で広く行われ,大きな注目を集めている.人の知 的活動の1つに物語の創作がある.人の感性に基づく創作物 である物語はストーリーと表現媒体の2つの要素から構成さ れ,それらの組合せによって小説や漫画などに枝分かれしてい く.ここで,ストーリーは物語の内容であり,表現媒体はその 内容をどのような形で表現するかという表現方法である.計算 機による物語の自動生成の研究 [Pěrez 01][Ueno 14] は数多く 報告されている.また,近年では人と機械による共同作業に関 する研究も注目を集めており,人と計算機による物語の共同創 作の研究 [上原 11] や創作支援の研究 [葛井 17] も報告されて いる.どちらの研究においても,人の創作物を計算機に理解さ せることが非常に重要となる.

物語の自動生成や創作支援を実現するためには,既存の物語 を解析し,人が物語を創作するうえで必要な知識や技術を計算 機が理解可能な形で獲得する必要がある.具体的には,機械学 習技術に基づく既存の物語に対する解析による有用な情報の抽 出は必要不可欠な技術である.しかしながら,物語の解析に関 する研究は,専門家の経験則に基づいて人手で情報を抽出する 研究[佐藤 10]が主流であり,計算機による数値的な情報抽出 や解析に関する研究はほとんど報告されていない.

なお,本研究ではストーリーに焦点を当てる.表現媒体が時 代とともに姿を大きく変えることがある一方,古くから存在す るストーリーの典型的な構造が現代でもしばしば使用されるこ とから,表現媒体と比べてストーリーの方が時間経過に対して ロバストなためである.また,本研究における解析対象には小 説を用いる.

以上を背景として、本研究ではストーリーを計算機に理解させるための第一歩として、文意を考慮した小説の自動分割手法 およびストーリー展開の解析手法を提案する.文意を考慮した 文の分散表現に基づき、小説文をストーリーが展開する部分で 自動分割する.また、自動分割された複数の小説文をシーンと みなし、各シーンのベクトルを用いてストーリー展開が類似し た部分を発見する.

# 2. 関連研究

本研究と関連のあるいくつかの研究について説明する.

### 2.1 テキストセグメンテーションに関する研究

テキストデータをトピックなどの意味的なまとまりに分割 するテキストセグメンテーションに関する代表的な手法に TextTiling[Hearst 97] がある. TextTiling はテキスト中の ある2文間を基準として、その前後の文をあらかじめ設定した 窓幅の分だけそれぞれ取得し、得られた前後の文章に対して単 語の出現頻度ベクトルの類似度を計算する. この操作を基準と なる2文を動かしながら実行し、得られた類似度の変化から文 章境界を推定する手法である. TextTiling は文章内に出現す る単語に基づいてセグメンテーションするため、短い文章を対 象とした場合には有効に機能しないことが知られている.

#### 2.2 物語の解析に関する研究

物語の解析に関する研究では, 星新一の作品を構造分析の考 えに基づき, テキストの時系列に着目して物語のパターン抽出 をする研究が報告されている [佐藤 10]. しかしながら, 物語の パターンを抽出するためにはテキストを抽象化して分類する必 要があるため, 人手によってしか解析できないという問題点が 存在する.

# 3. 提案手法

本研究では,物語の中でもストーリーという要素に着目して 小説を解析する.ここで,ストーリーをイベントや登場人物の 行動,場所移動に伴う物語中の一連の状態遷移の時系列である と定義する.小説をいくつかの文章の集合であると仮定する と,ある連続した2つの文章間の差が状態遷移であり,冒頭か ら末尾までの連続した2文章間の差の分布がストーリーであ るといえる.そこで,小説中の文章を分散表現化して文章ベク トルを得た場合,小説は文章ベクトルの時系列集合とみなすこ とができる.また連続する2つの文章ベクトルに何らかの演 算子を適用した結果がその2文章間での差であり,物語内の状 態遷移を表しているといえる.そのため,小説におけるストー リーは冒頭から末尾までの連続した2つの文章ベクトルにあ る演算子を適用した結果の時系列集合であると定義できる.

以上の観点から本研究では,文の分散表現に基づく小説文の 自動分割手法およびストーリー展開の解析手法を提案する.な

連絡先: 福田清人, 大阪府立大学 工学研究科, 大阪府堺市中区学 園町 1-1, 072-254-9273, fukuda@ss.cs.osakafu-u.ac.jp

お, 文の分散表現の獲得には, これまでに提案してきた文の分 散表現の獲得手法 [Fukuda] を改良した手法を用いる.

#### 3.1 文の分散表現を用いた小説文の自動分割

TextTiling の考え方を基にして,小説文の各文の分散表現 に対して類似度を計算し,類似度が極大となる2文を結合して いく操作を,セグメント数が任意の数となるまで繰り返すこと で小説を自動分割する手法を提案する.ここで1文単位での 類似度計算をすると,機械的な文分割により分割されてしまっ た不適切な文の前後を分割点と推測してしまう可能性がある. そこである1文に対して,その1文と前後窓幅分を含む文の 分散表現の平均を類似度計算に用いるベクトルとするスムー ジング手法を導入する.図1および図2に小説文のセグメン テーション手法の概要およびスムージング手法を示す.以下に 文の分散表現を用いた小説文のセグメンテーション手法のアル ゴリズムを示す.

- 1. 獲得したいセグメント数を  $N_{\rm s}$ ,スムージング幅を  $N_{\rm w}$  と する.ここで、本節で用いるスムージング手法では基準と なる文に対してその前後の  $N_{\rm w}$  文を含む  $2N_{\rm w}$  + 1 文を まとめてスムージングする.
- 2. 解析する小説を M 文の文集合とする.
- 3. 小説中の各文に対して, 文の分散表現の獲得手法により文 の分散表現 *s*<sub>i</sub>(*i* = 1,2,...,*M*) を獲得する.
- 4. 各セグメントに対応したセグメントベクトルを  $d_j$  ( $j = N_w + 1, N_w + 2, \cdots, M N_w$ ), セグメントベクトルの 集合を  $\mathcal{D} = \{d_{N_w+1}, d_{N_w+2}, \cdots, d_{M-N_w}\}$ とする.また,各セグメントに含まれる文数を  $b_j$ ,この文数の集合を  $\mathcal{B} = \{b_{N_w+1}, b_{N_w+2}, \cdots, b_{M-N_w}\}$ とする.ここで,

$$\boldsymbol{d}_{j} = \frac{1}{2N_{\mathrm{w}}+1} \sum_{k=j-N_{\mathrm{w}}}^{j+N_{\mathrm{w}}} \boldsymbol{s}_{k}$$
(1)

$$b_j = \begin{cases} N_{\rm w} + 1 & (j = N_{\rm w} + 1, M - N_{\rm w}) \\ 1 & (\text{otherwise}) \end{cases}$$
(2)

である.

5. セグメントベクトル集合の連続した 2 つのセグメントベ クトル d および d' の類似度  $f_{sim}(d, d')$  を以下の式に 従って計算する. ここで,  $\gamma$  は減衰率であり, セグメン トが長文になりすぎないよう制御するための可調整パラ メータである.  $\gamma$  は 0 <  $\gamma$  < 1 を満たす実数である. ま た, b および b' はそれぞれセグメントベクトルに対応し たセグメントに含まれる文数である.

$$f_{\rm sim}\left(\boldsymbol{d}, \boldsymbol{d}'\right) = \gamma^{b+b'-2} \left(1 + \frac{\boldsymbol{d} \cdot \boldsymbol{d}'}{|\boldsymbol{d}||\boldsymbol{d}'|}\right) \tag{3}$$

- 6.5 で求めた類似度が最大となった2つのセグメントベクトルを  $d_{\rm m}$  および  $d_{\rm m'}$  とし、それぞれに対応するセグメントに含まれる文数をそれぞれ  $b_{\rm m}, b_{\rm m'}$ とする.
- *d*<sub>m</sub> および *d*<sub>m'</sub> に対応するセグメントを結合し、1 つの セグメントとする. その後、以下の操作を適用することで 各値を更新する. ここで、記号 '→' は 左式を右式で更新



図 1: 小説文のセグメンテーション手法の概要



図 2: 小説文のスムージング手法の概要

する操作を表す.

$$d_m = \frac{1}{2N_{\rm w} + b_{\rm m} + b_{\rm m'}} \sum_{k=m-N}^{m'+b_{\rm m'}+N_{\rm w}-1} s_k \quad (4)$$

$$b_{\rm m} \rightarrow b_{\rm m} + b_{\rm m'}$$
 (5)

$$\mathcal{B} \to \mathcal{B} \setminus \{b_{\mathbf{m}'}\} \tag{6}$$

$$\mathcal{D} \rightarrow \mathcal{D} \setminus \{ \boldsymbol{d}_{\mathrm{m}'} \}$$
 (7)

- 8.  $|\mathcal{D}| > N_{\rm s}$  ならば, 5 に戻る.
- |D| = N<sub>s</sub>の時, D および D の各要素に対応したセグメントを獲得する.

#### 3.2 文の分散表現を用いたストーリー展開の解析

3.1 節で説明した自動分割手法により得られたセグメントと そのセグメントに対応したセグメントベクトルを用いてストー リー展開を解析する.本節では,連続したセグメントに対応し たベクトル間の差分を計算し,得られた差分ベクトルを1つの ストーリー展開とみなすことでストーリーを多次元数値空間上 で表現する.以下にストーリー展開の解析手順を示す.

- 1. 解析対象とする作品を複数用意する.
- 3.1 節の自動分割手法により作品を自動分割し、各作品の セグメントとそれに対応したセグメントベクトルを獲得 する.
- 3. 各作品ごとに, 連続した 2 つのセグメントベクトルの差 分を計算する.

表 1: 実験 1 における実験条件

| $m_{\rm max}$ | 80               |
|---------------|------------------|
|               | 太宰治 「走れメロス」      |
|               | 太宰治 「黄金風景」       |
| 使用作品          | 芥川龍之介 「蜘蛛の糸」     |
|               | 芥川龍之介 「藪の中」      |
|               | エドガー・アラン・ポー 「黒猫」 |

- 得られた差分ベクトルに対して、他作品から得られた差分 ベクトルとのコサイン類似度を計算する.
- 得られたコサイン類似度や差分ベクトルの各要素の割合 に基づいて,作品間でのストーリーの類似性や,差分ベク トルとストーリー展開の関係性などを可視化しつつ解析 する.

# 4. 実験

提案手法の有効性を確認するため、いくつかの実験をした. また,提案手法を用いていくつかのストーリーを実際に解析す ることで,得られる情報の特徴や傾向についての知見を得る. 実験1~3まで実施したが,紙面の関係上,実験1のみ示す. 実験2および実験3については発表時に述べる.

#### 4.1 実験 1

文の意味的な類似性を考慮した文の分散表現を用いて,小説 のストーリー展開を可視化することができるかを確認する.

小説の各文に対して文の分散表現を獲得し, 次元圧縮手法で ある t-distributed Stochastic Neighbor Embedding (t-SNE) を用いて 2 次元空間に写像することで可視化する.

### 4.2 実験1の実験条件

表1に実験1の実験条件を示す.実験1では青空文庫から 取得した各作品を文単位に分割し,その中から m<sub>max</sub> 単語以下 の文を用いた.

#### 4.3 実験1の結果と考察

図3~図7に各作品の t-SNE による可視化の結果を示す. ここで,各図において独立に t-SNE を適用しているため,それ ぞれの図の軸に関係性はないことに注意する.また,t-SNE は データ間の距離を確率分布で表現することで次元を圧縮する ため,次元圧縮後の各軸には意味がないことにも注意を要を要 する.

図3を見ると、各文の分散表現が2つの分布パターンに属 していることがわかる.これは、「走れメロス」という作品は 町での王様との会話シーンと、村に戻ってまた町に戻るという 移動シーンの2つに分けることができることから妥当である と考えられる.

図4および図5を見ると、すべての文の分散表現が次元圧 縮後の2次元空間において、ある直線上に分布していることが わかる.このような分布をとる原因として、「黄金風景」およ び「蜘蛛の糸」は場面転換時の風景描写などが淡白であること や、作品全体を通して使用される文体や人物の口調なども一定 であることが考えられる.

図6を見ると、「藪の中」の各文の分散表現は先頭から末尾 に向かって一定方向に展開していることがわかる.このことか ら、「藪の中」は物語の後半部分で前半部分について回想する こともなく、ストーリーが次々に展開していくと考えられる.



図 3: t-SNE による「走れメロス」の可視化結果



図 4: t-SNE による「黄金風景」の可視化結果

実際に,「藪の中」という作品はある男が殺される事件に対し て,目撃者や容疑者,被害者本人の霊などが事件について語る というストーリーであり,それぞれが自身の体験を語るだけで, 各人物が関わりあうシーンが存在しない.

図7を見ると,文の分散表現が一様に分布していることがわ かる.また,「黒猫」という作品は主人公の身の回りで起きる 事件と主人公の内面が交互に書かれている作品であり,類似し たストーリー展開を作品内で何度か繰り返す内容になってい る.これらのことから,似たストーリー展開を繰り返すことで, 時系列という観点から文の分散表現を可視化した結果,一様に 分布してしまっていると考えられる.

以上の結果から、小説のストーリーやその展開に関して、文 の分散表現を用いた多次元数値空間上で作品の種類や特徴を解 析可能であると考えられる.

# 5. むすび

本研究では,文の意味的な類似性を考慮した文の分散表現に 基づく小説の自動分割手法とストーリー展開の解析手法を提案 した.自動分割手法では TextTiling の考え方を基にして,文 の分散表現間の類似度が極大な部分を結合することで小説を シーンごとに自動分割した.ストーリー展開の解析手法では,



図 5: t-SNE による「蜘蛛の糸」の可視化結果



図 6: t-SNE による「藪の中」の可視化結果

自動分割手法で得られたセグメント間の差分をストーリー展開 とみなし,差分ベクトルの類似度からストーリー展開の類似性 を解析した.提案手法の有効性を確認するためのいくつかの実 験により,以下の知見が得られた.

- 小説文の分散表現を次元圧縮手法である t-SNE によって 可視化することで、小説のストーリーやその展開について 多次元数値空間上で解析することができる。
- 提案手法を用いることで、人手によるアノテートに頼ることなく小説文を意味を考慮したシーン単位に自動分割することができる。
- 提案手法により、ストーリー展開の類似性だけではなく、 文章構成の類似性も取得することができる。

今後の課題として提案手法の根幹となる文の分散表現の性 能向上は最重要課題である. 階層的 LSTM や Attention 機構 のような自然言語処理における有効性が示された技術を手法に 導入することで更なる性能向上が期待される. また, 自動分割 手法におけるスムージングの窓幅やシーンの分割数など解析対 象の作品ごとに異なる可調整パラメータを最適化するための手 法について検討する必要がある.



図 7: t-SNE による「黒猫」の可視化結果

# 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.

# 参考文献

- [Fukuda] Fukuda, K., Mori, N., and Matsumoto, K.: A Novel Sentence Vector Generation Method Based on Autoencoder and Bi-directional LSTM, in Prieta, de la F., Omatu, S., and Fernández-Caballero, A. eds., Distributed Computing and Artificial Intelligence, 15th International Conference, DCAI 2018, Toledo, Spain, 20-22 June 2018, Vol. 800 of Advances in Intelligent Systems and Computing, pp. 128–135
- [Hearst 97] Hearst, M. A.: TextTiling: Segmenting Text into Multi-paragraph Subtopic Passages, Comput. Linguist., Vol. 23, No. 1, pp. 33–64 (1997)
- [Pěrez 01] Pěrez, y R. P. and Sharples, M.: MEXICA: A computer model of a cognitive account of creative writing, Journal of Experimental & Theoretical Artificial Intelligence, Vol. 13, No. 2, pp. 119–139 (2001)
- [Ueno 14] Ueno, M., Mori, N., and Matsumoto, K.: 2-Scene Comic Creating System Based on the Distribution of Picture State Transition, pp. 459–467, Springer International Publishing, Cham (2014)
- [葛井 17] 葛井 健文,上野 未貴,井佐原 均:質問集合とグラフ に基づく物語全体の流れを管理可能な創作支援システムの 提案,第 31 回人工知能学会全国大会発表論文集 (2017)
- [佐藤 10] 佐藤 知恵, 村井 源, 徃住 彰文: 星新一ショートショー ト文学の物語パターン抽出, 情報知識学会誌, Vol. 20, No. 2, pp. 123–128 (2010)
- [上原 11] 上原 大輝, 出水 ちあき, 宮里 洸司, 神里 志穂子, 野口 健太郎: J-030 子どもの思考プロセス把握における物語自作システムの有効性検証 (HCS(2),J 分野:ヒューマンコミュニケーション&インタラクション), 情報科学技術フォーラム 講演論文集, Vol. 10, No. 3, pp. 597–600 (2011)

# 自然言語処理に基づく4コマ漫画ストーリーデータセットの解析

Analysis of Four-scene Comics Story Dataset based on Natural Language Processing

岩崎 凌<sup>\*1</sup> 森 直樹<sup>\*1</sup> 上野 未貴<sup>\*2</sup> Ryo Iwasaki Naoki Mori Miki Ueno

\*<sup>1</sup>大阪府立大学 \*<sup>2</sup>豊橋技術科学大学 Osaka Prefecture University Toyohashi University of Technology

Comic computing is a branch of computing dealing with comics in engineering. Although comics are multi-modal data with natural languages and pictures, numerous studies in the field focus on images in comics rather than the comic content. To make models understand the contents in comics, we should deal with natural languages in comics in the form of character words. We used a dataset which was suitable for analyzing comic contents and previously proposed two tasks: sentiment analysis and variety analysis. However, two tasks did not go well because of the number of data. We demonstrated using data augmentation and analyzed the results to determine the feasibility of computers understanding comics.

# 1. はじめに

近年,人工知能による小説や漫画,アニメ,漫画といった創 作物を対象とした研究が大きな関心を集めている.創作物理解 や自動生成といった試みは工学的興味深く意義の大きい反面, そもそも人の創作物理解は高次の知的活動であり,どういった タスクであれば計算機が創作物を理解したといえるのかを定義 することさえ現状では難しい.

人の創作物の中で,特に漫画を工学的に扱う研究分野が近 年、コミック工学を中心に発展している.漫画を対象とする研 究では自然言語と画像を持つマルチモーダルなデータを扱う ため、人工知能研究の対象として適している.この分野では、 現在でも数多くの研究が報告されているが、多くは漫画の持つ 画像を対象としており、ストーリーといった漫画の意味を自然 言語から解析しようとする研究は少ないのが現状である.その 一因としては、上で述べたような意味理解のためにどのような タスクを設定すればよいかが明確ではないという点が挙げられ る.このため、表層的な情報だけではなく、ストーリーにまで 踏み込んだ研究は十分になされていない.そのような困難にも かかわらず、創作物を理解できる人工知能の構築への情動は尽 きることがない.

このような研究を実現するためには、まずデータセットが 必要となるが、人工知能と創作に関する研究分野では著作権 などの問題からデータセットを準備することが容易ではない 場合がある.しかしながら既存のデータセットには、研究に必 要な情報などのラベルを持っていないという問題点があった. この点を解決し、創作者視点を積極的に取り入れたデータセッ トとして4コマ漫画ストーリーデータセット[Ueno 18] が提 案されている.ただし、このデータセットはまだ規模が十分で はないといった別の問題が存在する.そこで、本稿では Data Augmentation を利用することで、4コマ漫画ストーリーデー タセットのデータ数の問題点を軽減し、これまで実現できな かった新しい実験手法について検討する.

これらを踏まえ、本実験では人工知能による意味理解のために感情分析と多様度分析の2つのタスクを用意し、Data Augmentation による結果を比較する.本実験はデータ量の関

大阪府堺市中区学園町1-1, iwasaki@ss.cs.osakafu-u.ac.jp

係から十分な結果は得られていないが,今後の人工知能による 創作物理解の可能性を示すという立場で結果を解析する.2章 では,参考研究を示し,3章で本実験で扱うデータセットにつ いて説明する.4章で実験手法や条件について説明し,5章で それらの考察を述べる.

# 2. 関連研究

1章で述べたように,漫画を対象とした研究分野では画像認 識が用いられることが多い. Rigaud らの研究では漫画の吹き 出しに焦点を当て,吹き出し内のテキストを自動で抽出しよう と試みた [Rigaud 15, Rigaud 16]. 松井らの研究では,人の 描いたスケッチから似た絵を持つ漫画内の絵を自動で抽出する システムを提案した [Matsui 17].藤野らは4コマ漫画の構造 理解のために4コマ漫画の読解順序識別をした [Fujino 18]. これらのすべてが漫画内の画像のみ,あるいは絵に密接に関係 したラベルを用いた研究である.

漫画の自動生成に関する研究も報告されている [Ueno 14] [Fukuda 17]. 上述のような例と異なり,これらの研究は画像 だけでなく自然言語も対象としているが,これらの研究の目的 は漫画の解析という我々の目的とは異なっており,自然言語か ら漫画を解析しようとする我々の研究とは異なる立ち位置にあ る.現在は漫画の完全な自動生成というのは難しいことを踏ま えると,我々が試みるような解析が今後の人工知能による創作 研究の発展に非常に重要なものであることがわかる.

最後に漫画に関するデータセットについて述べる.漫画を 対象とした工学研究のためのデータセットはいくつか存在す る.日本の漫画を対象としたデータセットとしては Manga109 [Matsui 17, Ogawa 18] が挙げられる.Manga109 は 109 冊 の既存の漫画を含んでおり,漫画のテキストが文字に起こさ れていたり,漫画内のキャラクターや吹き出しについてのアノ テートがなされていたりする.工学的な漫画研究ではよく用 いられるデータセットであるが,自然言語から漫画を解析する 場合には漫画のストーリーに関するラベルが少ないことから Manga109 の持つラベルでは不十分であると考えられ,本稿 では Manga109 は用いず,4 コマ漫画ストーリーデータセッ トを用いることとする [Ueno 18].データセットの詳細は次章 で述べる.

連絡先: 岩崎 凌, 大阪府立大学 工学研究科,



図 1:4 コマ漫画ストーリーデータセットのデータの一例 (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: 浦田カズヒロ(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. 研究用データセット

漫画研究用のデータセットがいくつか存在することは2章 で述べた通りであるが,漫画をデータとして使用する際は著作 権の問題から既存のデータセットを使用した方が良い. 我々が 研究に用いる4コマ漫画ストーリーデータセットは人工知能に よる創作研究の発展のために研究者が一から開発に関わった世 界初の研究用のデータセットである.以下に我々が研究でこの データセットを使う目的およびデータセットの特徴を述べる.

特徴の一つ目として、ストーリー解析に適した情報を多く含 んでいる点にある.市販された漫画をデータとした場合,著作 権などの問題に加え,計算機上で扱うためのデータが少なく, 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.4コマストーリーデータセットでは 研究に関わっているため、そのような問題点を解決することが できる.

二つ目として、上野は4コマ漫画の構造を、

- 一般:標準的な起承転結をもつ
- 繰り返し:1,2コマ間の類似が3,4コマ間でも起きる
- 出オチ:1 コマ目におかしな絵が描かれてオチがある
- タイトルオチ:最後にタイトルを見返してオチがわかる
- 再帰:4コマ目から1コマ目に戻り話として成立する
- 参照:1つ以上前の話の続きの話となる
- 連続:連続した4コマを2話並べて8コマで話となる

と定義し、これに従ってデータセットを作成している点が挙げ られる.現在は、同一のストーリーを4コマ目がオチとなる

| - t- t | -  |    | 24     | Mil.       |
|--------|----|----|--------|------------|
| 7.     | 1. | イー | 14     | 21V        |
| Ľ.     | 1. | )  | $\sim$ | <u>4</u> X |

| 実験    | ラベル   | データ数 | 拡張後データ数 |  |  |
|-------|-------|------|---------|--|--|
| 感情分析  | 驚愕    | 18   | 2252    |  |  |
|       | その他   | 147  | 19165   |  |  |
| 多様度分析 | 多様度あり | 674  | 482062  |  |  |
|       | 多様度なし | 766  | 519826  |  |  |

ー般と出オチの2つの構造から描いたものがデータとして存 在しており、本稿では計算機でこういった構造の把握も目的と している.

最後の特徴としては、Manga109のような市販漫画によっ て構成されたデータセットとは異なり、4 コマストーリーデー タセットのデータは本データセットのために5人の漫画家に よって描き下ろされている点である. ストーリーの解析をする 際に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、そういったデータの収集に基づく研究 は困難であるため、これは非常に貴重な特徴である. なお5人 の漫画家の描く絵はそれぞれ絵のタッチが異なるため、少年漫 画タッチ, 少女漫画タッチ, 青年漫画タッチ, ギャグ漫画タッ チ, 萌え漫画タッチで描かれたデータがあると言い換えること ができる.この特徴は画像解析の方向からだけでなく、自然言 語から解析する場合にも非常に役立つものである. 作家がテキ ストから絵を起こすにあたってもとにしたテキストデータは同 一のものであるが、このテキストデータは各作家が自分の思う ようにセリフや感情ラベルを変更してもよかったため、作家ご とに差が生まれている.これによって作家ごとの考えの違いな ども把握することができる.

# 4. 実験

本実験では,感情分析と多様度分析を行う.表1に各実験 で用いるデータ数を示す.各実験で使用するラベルに関する説 明は以下で述べる.

#### 4.1 Data Augmentation について

本実験では日本語 WordNet [Bond 11] のシソーラスを用い てデータを拡張する手法を用いる.データセットに含まれる状 況文,セリフを Juman++ [Morita 15] を用いて分かち書き をし,日本語 WordNet で類似語を持つ単語を類似語に置き換 えた.文の中に類似語を持つ単語が複数あっても,類似語に置 き換える単語は同時に1つまでとした.例えば,5つの単語か ら構成される文章があり,各単語が5つの類似語を持ってい た場合,その文からは新しく25 文が生成されることとなる.

#### 4.2 感情分析

本実験で使用するデータセットは全 7 種類の感情ラベル (ニュートラル, 驚愕, 喜楽, 恐怖, 悲哀, 憤怒, 嫌悪)を持っ ているが, データ数と解析の難しさの問題から今回はニュー トラルを抜き, 感情ラベルを驚愕とそれ以外(喜楽, 恐怖, 悲 哀, 憤怒, 嫌悪)の2つとする.入力には感情ラベルが付与 されている状況文あるいはセリフー文を用い,上記の感情ラベ ルを識別する.図3に感情分析で使用する self-attention モ デル[Lin 17]を示す.

#### 4.3 多様度分析

多様度分析では、漫画家がある状況を絵に起こす際に多様度 があるかどうかを識別する.ここで多様度ラベルはデータセッ トに含まれておらず、我々が独自でアノテートしたものである



図 2: self-attention モデル

ことに注意する.本実験で使用するデータセットに含まれる 複数作家の描いた漫画を用い,2つのタッチの異なる同じエピ ソードで同じコマの絵のみを比較することでアノテートした. アノテート時には,

- 1. キャラクターの数と登場キャラクター
- 2. キャラクターの描き方
- 3. 背景の有無

#### に着目した.

1. が異なるタッチ同士は 2. や 3. の違いにかかわらず「多 様度あり」とし, 1. が等しい場合,「多様度なし」とした. そ のコマにキャラクターの頭部や手などの一部分のみしか登場し ていない場合, キャラクターとみなさなかった.

1. が等しく, 2. が異なる場合は「すこしの多様度あり」とした. キャラクターの描き方とはコマに登場するキャラクター の表現の仕方である. 漫画において, 登場人物を描く方法は 様々である. キャラクターをそのまま描くこともできれば, コ マ内の吹き出しに小さく顔を描くことで, 登場人物はコマ内に 登場していないがその吹き出しの横に小さくキャラクターを描 くことで話者を明示する手法もある. このようなキャラクター の描き方の違いが上記の 2. の一例である.

1. が等しく, 3. が異なる場合は「すこしの多様度あり」とした. ここでいう背景には,キャラクターのいる場所を表すような背景に加え,その話に関係してくるアイテム(例えば,弁当に関する話の際は弁当箱)なども含まれる.

実験時,入力には話者ラベル,感情ラベル,状況文,セリフ とタッチラベルを使用した.2つのタッチのデータを比較し, 多様度のないものか少しでも多様度のあるものかの2クラス の識別をするため,話者ラベル,感情ラベル,状況文,セリフ は各タッチごとに入力した.話者ラベルは,ラベルなし,メイ ンキャラクターA,メインキャラクターB,その他の4次元 の one-hot ベクトルであり,感情ラベルは、ラベルなしか前 述した7つの感情の8次元の one-hot ベクトルである.なお 入力に使うデータはもともとデータセットに含まれているもの である.図4に実験に使用したモデルを示す.

# 5. 実験結果

表 5. に実験結果を示す. 表 5. より, どちらの実験でも訓 練時の Accuracy が 1 に近くなっていることから, 訓練デー タにおける数の少ないラベルに対しても学習ができているこ とがわかる. 特に感情分析ではデータの偏りが大きいことか



図 3: 感情分析に用いるモデル (self-attention は図 2 参照)

ら, Data Augmentation がない状態ではデータ数の多いラ ベルだけを出力するような識別機となっていることが確認でき たが, Data Augmentation によってそういったデータに対し ても特徴を学習できるようになっていることがわかる. 多様度 識別では Data Augmentation によって結果が良くなってい ることがわかる. 一般的に, Data Augmentation はロバスト 性を高めるという目的に使用されることが多く,必ずしもモデ ルのパフォーマンスを改善するものではない. しかしながら本 実験で用いた Data Augmentation 前のデータの数は非常に 少なく,適切な特徴を学習するには心もとないデータ数であっ た. 全データを通して一度しか出てこない単語も多かったため に,各データに対して非常に過学習のしやすい状態であったの が, WordNet による Data Augmentation によって本来テス トデータにしか出現しないような単語も学習できるようにな り,性能が向上したものと考えられる.

# 6. まとめ

4 コマ漫画ストーリーデータセットを用いた実験の例として 感情分析と多様度分析の 2 つを示した. Data Augmentation を用い,感情分析と多様度分析での結果を比較した. Data Augmentation により結果の改善が見られた. 本実験ではシソーラ スを用いることでデータを拡張したが, Data Augmentation の方法は他にも考えられ,そちらも比較検討する.

# 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)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します.

# 参考文献

[Bond 11] Bond, F.: Japanese SemCor : A Sense-tagged Corpus of Japanese (2011)

[Fujino 18] Fujino, S., Mori, N., and Matsumoto, K.: Recognizing the Order of Four-Scene Comics by Evolutionary Deep Learning, in *Distributed Computing and Artificial Intelligence*, 15th International Conference, DCAI



図 4: 多様度識別に用いるモデル (self-attention は図 2 参照)

|  | 衣 2: | の結果) |
|--|------|------|
|--|------|------|

| [ | 実験    | Train Accuracy | Test Accuracy | 拡張時 Train Accuracy | 拡張時 Test Accuracy |
|---|-------|----------------|---------------|--------------------|-------------------|
|   | 感情分析  | 0.8923         | 0.8941        | 0.9999             | 0.9000            |
|   | 多様度分析 | 0.6886         | 0.5181        | 0.9873             | 0.5475            |

2018, Toledo, Spain, 20-22 June 2018., pp. 136–144 (2018)

- [Fukuda 17] Fukuda, K., Fujino, S., Mori, N., and Matsumoto, K.: Semi-automatic Picture Book Generation Based on Story Model and Agent-Based Simulation, in Leu, G., Singh, H. K., and Elsayed, S. eds., *Intelligent* and Evolutionary Systems, pp. 117–132, Cham (2017), Springer International Publishing
- [Lin 17] Lin, Z., Feng, M., Santos, dos C. N., Yu, M., Xiang, B., Zhou, B., and Bengio, Y.: A Structured Selfattentive Sentence Embedding (2017)
- [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)
- [Morita 15] Morita, H., Kawahara, D., and Kurohashi, S.: Morphological Analysis for Unsegmented Languages using Recurrent Neural Network Language Model, in *EMNLP* (2015)
- [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)

- [Rigaud 15] Rigaud, C., Thanh, N. L., Burie, J., Ogier, J., Iwata, M., Imazu, E., and Kise, K.: Speech balloon and speaker association for comics and manga understanding, in *ICDAR*, pp. 351–355, IEEE Computer Society (2015)
- [Rigaud 16] Rigaud, C., Pal, S., Burie, J.-C., and Ogier, J.-M.: Toward Speech Text Recognition for Comic Books, in *Proceedings of the 1st International Work*shop on coMics ANalysis, Processing and Understanding, MANPU '16, pp. 8:1–8:6, New York, NY, USA (2016), ACM
- [Ueno 14] Ueno, M., Mori, N., and Matsumoto, K.: 2-Scene Comic Creating System Based on the Distribution of Picture State Transition, in Omatu, S., Bersini, H., Corchado, J. M., Rodríguez, S., Pawlewski, P., and Bucciarelli, E. eds., *Distributed Computing and Artificial Intelligence, 11th International Conference*, pp. 459–467, Cham (2014), Springer International Publishing
- [Ueno 18] Ueno, M.: Four-Scene Comic Story Dataset for Softwares on Creative Process, in New Trends in Intelligent Software Methodologies, Tools and Techniques - Proceedings of the 17th International Conference SoMeT\_18, Granada, Spain, 26-28 September 2018, pp. 48–56 (2018)

# 作中役割を考慮した物語文の類似文検索による 創作者の支援と感性の解析

Search for Similar Story Sentences based on Role of Characters in order to Support and Analyze Contents Creator's Ideas

葛井健文 上野未貴 井佐原均
Takefumi Katsui Miki Ueno Hitoshi Isahara

# 豊橋技術科学大学

Toyohashi University of Technology

A process of creating stories has been studied from various aspects. Recently, it has become important topic for the field of artificial intelligence. In the field, such studies are mainly divided into two groups, automatic generation of stories and assistance for human's creative activity. From the view of assistance for human's creative activity, we propose creative support method. This paper describes two systems; Creation support system and System of Search for Similar Story Sentences based on Role of Characters. In order to confirm the effectiveness of these proposed method, three types of experiments were carried out. These results suggested that the proposed system is useful for creating story and analyzing human's idea of the perspective of similar feeling.

# 1. はじめに

近年,文章解析として分散表現を用いた文のベクトル化の 手法が数多く提案されており,機械翻訳や対話システムの応答 文選択の精度が大幅に向上している.一方,物語文章の解析に ついては作者固有の文体や作品の固有表現,セリフや回想文な どが存在し,また評価指標も多岐にわたるため,文章の物語と しての類似度の推定は困難である.そのため,物語の類似度を 推定するための取り組みはとても重要であり,工学的な物語の 自動生成と創作支援の両面において貢献できると考えられる.

本研究では、従来研究で提案された2種類のテンプレート の連携により物語のプロットを作成する創作支援システムと、 新たに提案する類似した物語のあらすじを検索するシステムの 連携により、より効率的に物語を作成できる創作支援手法を提 案する.

# 2. 従来手法

# 2.1 創作支援システム

本研究で特に重要な創作支援システムに関する従来研究を 示す.従来研究として、川越らは2種類のテンプレートを連 携した創作支援システムを提案 [kawagoe 15] し,著者らはこ の創作支援手法の2種類のテンプレート間の連携を強化する 想定感情線機能を追加した手法を提案した [葛井 17].本稿で は、上記の手法に基づく創作支援システムを従来手法と呼ぶ.

# 2.2 創作支援システムの概要

創作支援システムは3つの機能を持ち、ストーリーテンプ レートを用いて物語のあらすじを作成するストーリー作成部、 キャラクターテンプレートを用いて登場人物に関する設定を作 成するキャラクター作成部、実際に作成されたプロットを用い て本文を入力するための本文入力部によって構成される.ユー ザはこのシステムを用いることで物語のプロットを完成させる ことが出来る.

## 2.3 ストーリーテンプレート

物語のプロットを作成するための質問集合がストーリーテン プレートである.また,ストーリーテンプレート中の質問項目

連絡先: 葛井 健文, 豊橋技術科学大学, 言語情報学研究室

には三幕構成 [安藤 09] が用いられている.これにより,作成 したプロットの物語中の時系列を整理出来る.

# 2.4 キャラクターテンプレート

登場人物を作成するための質問集合がキャラクターテンプ レートである.キャラクターテンプレート内で作成した登場人 物をグレマスの行為者モデル [樋口 89] に従って 4 つの役割の うちいずれか一つに当てはめる.グレマスの行為者モデルは物 語の登場人物を 6 つの役割に整理したモデルであり,従来手 法では,このうち主体,対象,援助者,敵対者を重要な役割で あると考え,ユーザは作成したキャラクターを 4 つのうちど れか一つの役割に当てはめる.

#### 2.5 想定感情線グラフ

2種類のテンプレート間の連携を強化するため,想定感情線 グラフを導入した.想定感情線グラフは以下の機能を持つ.

- 想定感情線の手動入力
- キャラクター登場場面の表示
- 各期間の感情値の自動算出

## 2.6 従来研究の実験結果と提起

従来研究について得られた意見,課題点を以下に示す.

- 創作の参考になるアイディアをシステムから提示してほしい
- 両テンプレートともにバリエーションが少ない
- 物語の方向性が固定されやすい

本研究ではこれらの問題点を解決するため,保存機能の追加 と、システム側から類似度に基づき参考となる作品を提示する ことで,作成できる物語のバリエーションの増加を目指す.

# 3. 提案手法

本章では、2.6 で示した従来手法の問題点を解決し、より有 用な創作支援手法となるように創作支援システムをあらすじ文 章の内容から似た内容のあらすじを検索するシステム(以下、 あらすじ検索システムとする)と連携して利用する手法を提 案する.類似した物語を提示することは、創作支援システムの ユーザにとって自身の参考になり、物語のバリエーションや方 向性も新たな発想が得られると考えたためである.

| · C 查找进行科学大学 重新 | · · · · · · · · · · · · · · · · · · ·   |
|-----------------|---|
| 7747.N(D HLMI(D |   |
|                 | 入1-10-05/45/46 011-18 011-18 第二章 第二章 第二章 第三章 第三章 第三章 第三章 第三章 第三章 第三章 第三章 第三章 第三   |
|                 | 物語の構造組み立てに関する質問   |
| D               | こことでは年、王島昭都の今日のか中山についてはなします。<br>第一回は時期の1912年(1)~1~下下、前回の方面になります。<br>おなたが泉く「物助のテージ」「前山の地球人物」「主人の白田・田田」<br>「主人への白眼を上回い方」などを見たいます。   |
|                 | BLTーデニングイシージの設定(Opening Image)<br>あな上型で最初なジイム、管理法、アット、テーマを設定しての主人、<br>社営でいたジーボードになる主人はためた後に「住宅わかる」と、<br>工業のの最低など、からいご参加で最近の高になって、チャルシッチペットを守成してのことい、<br>イントム・オープングインドン・支援教育するパート  |
|                 | 主人公は王朝に行く。<br>そこで基督である殿対地の情報を聞き激怒する。  |
| $\sim$          |   |
|                 | B2703時況(Theme is B1.オープニングイメージの防定(Opening Image)<br>あない思い能かって地に<br>あない思い能かって地に<br>すってい思いようにない。<br>19705時にないたいから、相に広をする主人公の出発点(変化前の姿)と、<br>19705時にとない。<br>ま要な問題を見た、あなたが書(物語の面白さをアビールするようなイベントを作成してください。<br>イベント1.オープニングイメージを象徴するイベント |
|                 | *人公セ王朝に行く、<br>そこで鼻害である敵対者の情報を聞き激怒する。<br>あらすじ文から一文を選択  |
| 類似あら            | すじ検索 入力   |
| 277897428284    |   |
| ec.cmm.coom0180 | JANAGENDERALD 9 © SOUNT   |
| title           | section line value 類似あらすじが出力  |
| 走れメロス           | 1 1 0.5106524229 そして、その原因である人類下価のために多くの人を培用している職務ディオニス王(ディオニュシオス1社)の話を開き、激励す<br>る   |
|                 |   |

図 1: 創作支援システムに基づくあらすじ検索システムの利用

| 表 1: 実験に | .用いた PV | V-DM モデル | レの学習条件 |
|----------|---------|----------|--------|
| 文書サイズ    | 次元数     | 窓サイズ     | エポック数  |

|--|

#### 3.1 あらすじ検索システムの概要

あらすじ検索システムは、物語のあらすじについて記した 一文を入力として受け取り、類似したあらすじ文を出力するシ ステムである.図1に概要図を示す.

#### 3.2 文章のベクトル化

文章の類似度などを計算する方法として文章のベクトル化が 挙げられる.中でもニューラルネットワークによる学習による 分散表現獲得手法として Paragraph Vector [Le 14] が存在す る.Paragraph Vector は Word2Vec [Mikolov 13] から派生し た手法で,本実験では PV-DM(Distributed Memory Model of Paragraph Vectors) モデルを用いる.表1にパラメータを 示す.本稿では次に述べるコーパスを学習して PV-DM モデ ルをあらすじ文章モデルと呼ぶ.

#### 3.3 コーパス作成と前処理

用いたコーパスは,類似していると判断された作品をユー ザが読むことで創作への参考にする必要があるために,青空文 庫収録作品のうち 2018 年 10 月 4 日時点で日本語 Wikipedia [Wikipedia] に記事があり,その中に「あらすじ」節を持つ 464 作品を対象とした.また,抽出の際に注釈やリンクの情報は消 去している.本研究では,Wikipedia から抽出した各記事の文 章から,「あらすじ」節に含まれる文章のみを利用し,文章コー パスとする.コーパス内の各文章には「どの作品のあらすじ文 章か」を判別するためのラベル付けを行った.また,文書解析 の精度向上および実際に創作に役立てるための情報に用いるた め,コーパスに以下の 3 つの前処理をした.

#### 3.3.1 物語に関係しない文章の削除

取得したあらすじ節の文章の中には、その物語の中の出来 事の情報ではない、作品そのものへの解説や世界観の注釈、と いった文章が含まれていることがある.本研究では創作支援シ ステムに入力された物語のあらすじ文章とWikipediaのあら すじ文章を比較し、二つの文章の類似度から物語の類似度を推 定することが目的であるため、以下に示す内容を含む文章は 今回のコーパス作成に不向きであるとして以下の操作をした. 以下に操作内容を示す.

|  | 表 2: | 三幕構成へ | 、の分割を行・ | ったあらう | すじ文章のΡ | 勺訃 |
|--|------|-------|---------|-------|--------|----|
|--|------|-------|---------|-------|--------|----|

|            | C 13 2 / C !! | ////// | 1 2 1 2 10/1 |
|------------|---------------|--------|--------------|
| 内訳         | 第一幕           | 第二幕    | 第三幕          |
| 各幕を持つ作品数   | 462           | 427    | 357          |
| 各幕に含まれる文数  | 2542          | 4175   | 2354         |
| 各幕に含まれる単語数 | 56850         | 103612 | 50900        |

- 物語の歴史的背景や設定を補足する文章
- 複数言語での表記や、表現の違いを補足する文章
- 記事内で対象としている版以外の物語の展開へ言及している文章
- 作品の解説や制作事情など、物語の出来事以外に言及している文章

以上の操作の結果,あらすじ文が全て削除された作品が2作品が2作品あったため,対象作品の数は実質的に462作品となった.

### **3.3.2** 物語の時系列の整理

Paragraph Vector を用いた文章の分散表現を用いて文書間 の類似度を計算する際、「その文章はあらすじ文章中のどの位 置にあった文章か,物語中のどのタイミングの出来事を表し た文章か」という情報は考慮されない.しかし,物語において は「物語中で出来事が起きたタイミング」は非常に重要であ り、表記の上では同じような文章でも、そのタイミングによっ て大きく意味合いが異なり,結果的に物語的な類似度は小さく なることが予想される. そのため, コーパス中の各文章に対 し、「どの作品のあらすじか」だけでなく、その文章は「創作支 援システムのストーリーテンプレートで定義された三幕構成 のうち,作品中で第一幕から第三幕のどのタイミングの出来事 に当たる文章か」を判別するためのラベル付けをした. ラベル 付けの方法として,あらすじ文章を文書量等を基準として均等 に三分割するのではなく、各作品のあらすじ文章ごとにどのよ うに三幕構成に分割できるかを人手で判断し、分類を行った. 表 2 に各幕ごとの内訳を示す.

#### 3.3.3 登場人物名の役割名への置換

あらすじ文章には、作品ごとに固有の登場人物の名前が含 まれており、Paragraph Vector を用いて文章をベクトル化す る際、固有表現はそのベクトルに強く作用する.一方で物語に おいては、「誰」が何をしたかは非常に重要であり、例えば戦 いに勝利したのが主人公であるのか敵役であるのかは意味合 いが大きく変わる.そこで、物語的に類似した文章を検索する ために、登場人物名に関する固有表現と、その人物を表す代名 詞を、創作支援システムのキャラクターテンプレートで定義さ れた4つの役割名:主人公、対象、援助者、敵対者に置換す る.登場した人物の各役割への当てはめは人手で行った.詳し いルールを以下に示す.

- 人物名と代名詞を単純に置き換える
- 各役割に人数の制限はない
- 役割名が連続するときは重複を削除する
- 「物語としての登場人物でない」人名に関しては置き換えない

#### 3.4 あらすじ検索システムの実装

前節に示した挙動をする機能を実装した.入力文は創作支援システムにおける第一幕から第三幕の入力内容のうち一文を用い,その入力を分散表現としてあらすじ文章モデルの構築に用いた文章から類似度の高い文章を上位 n 文取り出し表示する.以降, n = 15 とする.

表 3: 実験1の質問のアンケート結果(抜粋)

|               |     |   | 各評 | 価の | 頻度 |   |
|---------------|-----|---|----|----|----|---|
| 質問内容          | 平均  | 1 | 2  | 3  | 4  | 5 |
| 第一幕で出力文と入力文章は | 4.1 | 0 | 1  | 2  | 4  | 5 |
| どれぐらい似ているか    |     |   |    |    |    |   |
| 第一幕で出力文が含まれる作 | 3.8 | 2 | 0  | 2  | 2  | 6 |
| 品の第三幕のあらすじと選択 |     |   |    |    |    |   |
| した作品の第三幕のあらすじ |     |   |    |    |    |   |
| は似ていたか        |     |   |    |    |    |   |

#### 3.5 創作支援システムとあらすじ検索システムの連携

あらすじ検索システムは、入力文として時系列とキャラク ター役割を考慮したあらすじ文章を想定している.これは創作 支援システムで作成されたあらすじ文章が満たしているもので あり、創作支援システムの利用者はプロットの作成中に好きな タイミングであらすじ検索システムを利用して作成中のあらす じ文章と物語的に類似したあらすじ文章を検索することが出来 る.創作中に参考になる作品の情報を提示することは有用であ ると考えられるため、この2つのシステムを使った創作支援 によって効率的に人間の創作活動を支援できると考えられる.

# 4. 実験

研究目的に照らして,提案システムの有用性を確かめるた め,以下の3種類の実験をした.また,実験は被験者に2種 類のシステムと実験手順書,実験協力の同意書を送付し,被験 者が各自で実験を行うという形式とした.実験にあたって,出 力される可能性のあるあらすじを三幕構成に分割したものを被 験者に提示している.

# 4.1 実験1:既存の物語に対するあらすじ文章モデル の評価実験A

あらすじ検索システムを用いて,あらすじ文書モデルによ り類似あらすじが算出される頻度およびユーザが類似すると感 じる観点を解析する.

# 4.1.1 実験条件

成人男女 12 名を対象に,以下の手順により実験を行い,ア ンケートにより結果を確認した.

# 4.1.2 実験手順

被験者は,はじめに対象作品から一つ選択し,その作品を青 空文庫から確認し創作支援システムを用いてあらすじを作成す る.その後,作成したあらすじを一文ずつあらすじ検索システ ムに入力し,出力結果を確認した後アンケートに回答する.

#### 4.1.3 対象作品

この実験で被験者があらすじを作成するために対象とした 作品は「走れメロス」「雪の女王」「ジャックと豆の木」「赤ず きん」「ヘンゼルとグレーテル」の5作品である.

#### 4.2 実験1結果

表3にアンケート中の5段階評価の各評価の回答数を示す. アンケートは1-5の5段階評価で、5が最も高いとした.第 一幕から第三幕まで、全ての入力に対して被験者が選択した作品と同一の作品のあらすじを出力した結果が多くみられる.

同一の作品が出力されなかった場合において,あらすじ文の 類似度を判断した理由として「起きた出来事が似ていた」とい う回数が多く得られていることから,ユーザは別の作品のあら すじ文を比較したとき,出来事や状況を表す文章の類似度を似 ていると感じる尺度に用いていると考えられる.入力作品と同

| 衣 4: 夫缺 2 の / ノク 一 ト 結果 ( | 表 4: | 実験 2 | のア | ンケー | ト結果 | (抜粋) |
|---------------------------|------|------|----|-----|-----|------|
|---------------------------|------|------|----|-----|-----|------|

|               |     |   | 各評 | 価の | 頻度 |   |
|---------------|-----|---|----|----|----|---|
| 質問内容          | 平均  | 1 | 2  | 3  | 4  | 5 |
| 第一幕で出力文と入力文章は | 3.4 | 0 | 0  | 3  | 2  | 0 |
| どれぐらい似ているか    |     |   |    |    |    |   |
| 第一幕で出力文が含まれる作 | 1.4 | 3 | 2  | 0  | 0  | 0 |
| 品の第三幕のあらすじと選択 |     |   |    |    |    |   |
| した作品の第三幕のあらすじ |     |   |    |    |    |   |
| は似ていたか        |     |   |    |    |    |   |

ーの作品が出力されない場合,原因は大きく分けて二つに分類 できる.

- あらすじ文章の粒度が異なるパターン
- 入力した出来事がコーパスに存在しないパターン

# 4.3 実験 2:既存の物語に対するあらすじ文章モデル の評価実験 B

あらすじ文章モデルの構築に用いた文章内にあらすじ文が 存在しない既存の物語のあらすじをあらすじ検索システムに入 力し,出力結果についてのアンケートをすることであらすじ文 書モデルにより類似あらすじが出力される頻度およびユーザが 類似すると感じる観点を解析する.とくに,実験1に比べ明 確な正解が存在しないためにユーザがどの観点から類似性を見 出すかに重点を置く.

#### 4.3.1 実験条件

成人男女5を対象に、以下の手順により実験を行い、アン ケートにより結果を確認した.

#### 4.3.2 実験手順

実験手順は,対象の作品が任意の創作物である以外は実験1 と同様である.

#### 4.4 実験2結果

表4にアンケート中の5段階評価の各評価の回答数を示す. 入力した文と似たあらすじ文自体は出力されているが,あらす じ文章のうち一文が似ているからといってその作品が想定した 作品と似ているとは限らないということが分かる.

一方で,物語中の部分的な展開や目的が似ている場合があり,その例を以下に示す.

実験2の入出力考察1-

| 入力「主人公は、対象が惨殺されたショックから禁酒に失          |
|-------------------------------------|
| 敗し、バーで泥酔して失態を犯してしまう」                |
| 出力「しかし電話で連絡してきた柳吉に、お前は来ん方           |
| がええ、来たら都合が悪いと言われ、蝶子は発作的にガ           |
| ス自殺を図った」                            |
| (出典:フリー百科事典「Wikipedia:『夫婦善哉 (小説)』」) |

以上の例の入出力に対して被験者からは「物語の全体的な展開 は大きく違うが,入力文の該当場面と出力文の該当場面で主人 公がどん底にいる描写は一致していた」という意見が得られ ている.この入力に対しては,他にも登場人物が失態を犯す描 写を表す文章が出力されており,登場人物の状態を示す文とし て,またその文が含まれる物語の一場面は類似している部分 があると考えられる.以上の事から,類似あらすじ文の検索に よって提示された2つの物語間には,物語として目的,三幕構 成における各幕,その幕内の一部分の展開,登場人物の行動と いった要素的に似ている部分が見られると考えられる.

| 質問内容          | 被験者 1 | 被験者 2 | 被験者3 |
|---------------|-------|-------|------|
| 第一幕で出力文と入力文章は | 4     | 4     | 4    |
| どれぐらい似ているか    |       |       |      |
| 第一幕で出力文が含まれる作 | 2     | 4     | 2    |
| 品あらすじと選択した作品の |       |       |      |
| あらすじは似ていたか    |       |       |      |

表 5: 実験3のアンケート結果

### 4.5 実験3:システムを用いたプロット作成実験

創作支援システムを用いた物語プロット作成中に,あらすじ 検索システムを用いてその作品のプロットと似たあらすじを持 つ作品を提示することで創作に与える影響について調べる.

### 4.6 実験条件と手順

成人男性3名を対象に、物語のあらすじ作成中に類似した 物語を提示することで自分の書きたかった物語の作成に役立っ たかどうかを調べる.実験手順を以下に示す.被験者ははじめ に創作支援システムを用いて物語のあらすじを作成する.作成 中の以下のタイミングであらすじ検索システムに作成中のあら すじを入力し、出力結果を確認する.

- 第一幕に該当する回答が全て入力された時点,第一幕への回答から一文ずつ選択
- 第二幕に該当する回答が全て入力された時点,第二幕への回答から一文ずつ選択
- 第三幕に該当する回答が全てて入力された時点,第三幕
   への回答から一文ずつ選択
- ストーリーテンプレートに被験者が考える必要な部分が 全て入力された時点,すべての回答から一文を選択

各結果を確認した後、アンケートに回答する.

#### 4.7 実験3結果

表5に5段階評価の各被験者の回答を示す.実験2と同様, あらすじ文章コーパスに用いた作品が含まれないため,入力文 と似たあらすじ文は出力されているが,そのあらすじ文をもつ 作品はあまり似ていないという結果が得られた.

出力されたあらすじを持つ作品は創作中の作品とあまり似 ていないという結果が得られた一方で,多くの箇所で自身の創 作に役立てられたという回答が得られた.

▶ 実験 3 の入出力考察 1 -

入力「自分には新しいメニューは無理だという主人公は 夢の中でラーメン仙人に出会う」 出力「大和国に住む木こりの髪長彦は、ある日森の中で 神に出会う」 (出典:フリー百科事典「Wikipedia:『犬と笛』」)

以上の例の入出力に対して被験者からは出力文を含む作品と 自身の作成している物語は似ていないという解答があった一方 で、「展開の被りが避けられた」「今後の展開の参考になった」 という解答がされている.第一幕という物語の導入部分が類似 していたが、そこから展開が異なっていくことから、創作中に ユーザのイメージしていた展開以外のアイディアを提示できて いたと考えられる.

# 5. まとめ

本研究では、創作活動支援のためのシステムとして2種類 のシステムを組み合わせた手法を提案した.提案手法につい て被験者実験をすることで、時系列と、キャラクター役割を 考慮したあらすじ文章コーパスを用いて学習した Paragraph Vector モデルにより共通した要素を持つあらすじ文を出力で きること、創作活動において、物語の創作中にその物語に共通 した要素を持つ作品情報を提示することの有用性を確認した. 今後の課題は以下の通りである.

- あらすじ文章コーパスの規模拡大,各文章の整理
- 創作支援システムの拡張によるユーザの類似あらすじ検索システムへの入力の手間の削減

# 謝辞

本研究の被験者実験に協力してくださった 12 名の方々, シス テムに様々な助言を下さった作家 山口昌志様に心より感謝しま す.本研究は、一部 JSPS 科研費 (グラント番号: JP17K17809) および JST, ACT-I(グランド番号: JPMJPR17U4) の支援に よります.

# 参考文献

- [kawagoe 15] Seiya Kawagoe and Miki Ueno and Hitoshi Isahara: A Study on the Efficiency of Creating Stories by the use of Templates, The 2015 International Conference on Advanced Informatics: Concepts, Theory and Applications (ICAICTA 2015), 978-1-4673-8142-0(2015)
- [葛井 17] 葛井 健文, 上野 未貴, 井佐原 均: 質問集合とグラ フに基づく物語全体の流れを管理可能な創作支援システム の提案,人工知能学会 2017 年度全国大会 4F1-3in2(2017)
- [安藤 09] 安藤鉱平,加藤正人 (訳),シド・フィールド (著):映 画を書くためにあなたがしなくてはならないこと シド・ フィールドの脚本術,フィルムアート社 (2009(原著 1979))
- [樋口 89] 樋口 淳: 怖がることを習いに出かけた若者の話– A.J. グレマスの意味論をめぐって, 専修人文論集 (44), p93-129(1989)
- [小林 05] 小林 のぞみ,乾 健太郎,松本 裕治,立石 健二,福島 俊一:意見抽出のための評価表現の収集,自然言語処理, Vol.12, No.3, pp.203-222(2005)
- [Wikipedia] フリー百科事典 ウィキペディア日本語版 https://ja.wikipedia.org
- [Le 14] Quoc Le, Tomas Mikolov: Distributed Representations of Sentences and Documents, Proceedings of The 31st International Conference on Machine Learning (ICML 2014), pp. 1188 - 1196(2014)
- [Mikolov 13] Tomas Mikolov, Kai Chen, Greg S. Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space, conferencePostericlr2013-workshop(2013)

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

# [3C4-J-9] Natural language processing, information retrieval: correction of documents

Chair:Yasutomo Kimura Reviewer:Yoko Nishihara Thu. Jun 6, 2019 3:50 PM - 4:50 PM Room C (4F International conference hall)

# [3C4-J-9-01] An Approach for Applying BERT to Sentence Elimination Problem in English Exam

OHiromi Narimatsu<sup>1</sup>, Hiroaki Sugiyama<sup>1</sup>, Genichiro Kikui<sup>2</sup>, Hirotoshi Taira<sup>3</sup>, Seiki Matoba<sup>3</sup>, Ryuichiro Higashinaka<sup>1</sup> (1. NTT Communication Science Laboratories, 2. Okayama Prefectural University, 3. Osaka Institute of Technology) 3:50 PM - 4:10 PM

# [3C4-J-9-02] A consideration of word sense disambiguation of company name utilizing securities report

OHiroyuki Matsuda<sup>1</sup>, Kazuhiko Tsuda<sup>1</sup> (1. Graduate School of Business Sciences, University of Tsukuba)

4:10 PM - 4:30 PM

# [3C4-J-9-03] Misspelling Detection by using Multiple Bidirectional LSTM Networks ORyo Takahashi<sup>1</sup>, Kazuma Minoda<sup>1</sup>, Akihiro Masuda<sup>2</sup>, Nobuyuki Ishikawa<sup>1</sup> (1. Recruit Technologies Co.,Ltd., 2. PE-BANK, Inc) 4:30 PM - 4:50 PM

# センター英語試験の不要文除去問題に対する BERTの適用方法の検討

An Approach for Applying BERT to Sentence Elimination Problem in English Exam

成松宏美 \*1 Hiromi Narimatsu 菊井玄一郎 \*2 Genichiro Kikui 平博順 \*<sup>3</sup> Hirotoshi Taira 的場成紀 \*<sup>3</sup> Seiki Matoba

東中竜一郎 \*1 Ryuichiro Higashinaka

\*<sup>1</sup>NTT コミュニケーション科学基礎研究所

NTT Communication Science Laboratories

杉山弘晃\*1

Hiroaki Sugiyama

\*<sup>2</sup>岡山県立大学 Okayama Prefectural University

\*2大阪工業大学

Osaka Institute of Technology

We have been working on the English problems in the "Can a Robot Get into the University of Tokyo?" project. This paper focuses on the sentence elimination problem by applying BERT, which has obtained the state-of-the-art results in a number of machine comprehension tasks. We show how we apply BERT and report the improvements made over baselines. Finally, we show our error analysis and the problems that still need to be solved.

# 1. はじめに

我々は「ロボットは東大に入れるか」プロジェクト [新井 18] において,引き続き英語(特に,センター試験の英語問題)に 取り組んでいる.本稿は,センター試験の英語問題で出題され る不要文除去問題に対して,近年多くの機械読解タスクにおい て State-of-the-art (SOTA)を達成している汎用言語表現モデ ル BERT [Devlin 18] を用いた解法について述べる.

不要文除去問題は、文章中に1つの不要な文が含まれてお り、それを取り除くことで全体のまとまりが良くなるような 文を一つ選ぶという問題である.図1に示す例では、(1)より 前の文脈により、(1)以降に良い靴選びのポイントが提示され ると推測できる.ここで、(1)(2)(4)はそのポイントが提示さ れているものの、(3)はブランドの革靴の話をしており、主題 が異なる.よって、(3)が不要文であり、これを選べば正解と なる.我々はこの問題に対して、様々な手法を検討してきた がWord2vec [Mikolov 13]を用いて選択肢間の距離を測るシ ンプルな手法がもっとも良いスコアであったことを報告した [東中 17].

不要文除去問題は、文同士の類似性だけでなく、文書として の自然さの評価が必要な点で、近年取り組まれている機械読 解タスクにはあまり見られない問題である.近年、機械読解 タスクにおいて注目を集めている OpenAI GPT [Radford 18] や BERT は、Transformer と呼ばれる自己注意機構を備えた ニューラルネットワークを大規模なテキストコーパスを用いて 事前学習し、個別の問題に対して転移学習することで、様々な タスクにおいて SOTA を達成している.転移学習により様々 なタスクに適用できるため、不要文除去問題においても精度向 上が期待できる.

本稿では,BERT を不要文除去問題に適用する方法を検討 し,Word2vecに比べ,有意に正解率が良くなったことを示す. また,エラー分析により,BERT により解けるようになった Wearing proper shoes can reduce problems with your feet. Here are some important points to think about in order to choose the right shoes. (1) Make sure the insole, the inner bottom part of the s

(1) Make sufe the inside, the inner bottom part of the s hoe, is made of material which absorbs the impact on y our foot when walking. (2) The upper part of the shoe s hould be made of breathable material such as leather or cloth. (3) Some brand-name leather shoes are famous be cause of their fashionable designs. (4) When you try on shoes, pay attention not only to their length but also to their depth and width. Wearing the right shoes lets you enjoy walking with fewer problems.

図 1: 不要文除去問題の例 (平成 29 年センター英語試験問題 より引用. 正解は (3).)

問題とそうでない問題がどういうものかを示す.

# 2. BERT による不要文除去問題の解答法

ここでは、問題解答に用いる Bidirectional Encoder Representations from Transformers (BERT) [Devlin 18] につい て説明するとともに、BERT を不要文除去問題に適用する方 法を述べる. 転移学習を行う際の、学習に用いるデータの作成 方法 (2.2) および BERT の入力形式への問題の変換方法 (2.3) と、転移学習を行わずに BERT の後続文予測モデルを用いる 解法 (2.4) を説明する.

# 2.1 Bidirectional Encoder Representations from Transformers (BERT)

BERT は, 図 2 (左) に示す Transformer モデル [Alec 18] を大規模なテキストコーパスで事前学習し, 個別の問題に対し て転移学習する手法である [Devlin 18]. Transformer は, 位 置情報 (Position embedding) 付きのテキストを入力として, 「自分と関係する周辺情報を集約する」機能を持つ自己注意機

連絡先:成松宏美,NTT コミュニケーション科学基礎研究所, 〒 619-0237 京都府相楽郡精華町光台 2-4,0774-93-5311, hiromi.narimatsu.eg@hco.ntt.co.jp



図 2: Transormer モデルの構造(右) [Alec 18] と個別タスク に対する転移学習時の入出力・モデル構造(左) [Devlin 18]

構を繰り返し適用することで、タスクに適した特徴ベクトルを 計算するモデルである.BERTではTransformerの事前学習 にアノテーションが不要である.事前学習のための汎用的なタ スクとして、双方向の言語モデルタスクと2文の結束性を判 定するタスクの2種類が採用されている.双方向言語モデル タスクは、文中のマスクされた単語を推定するタスクであり、 対象単語の前後の文脈情報を利用する言語モデルを学習するこ とができる.2文の結束性タスクは、与えられた2文が連続す る文か無関係な文かを推定するタスクである.文という、単語 よりも大きい単位でのつながりの良さを学習できると考えられ る.なお BERTでは、この2文を異なるものとして陽に表現 するため、入力情報に文のまとまりを表す segmentID および そのベクトル表現 (Segment embeddings)を追加し、直接的 に文のまとまりを与える工夫がなされている.

#### 2.2 転移学習に用いる擬似問題の作成

BERT の転移学習は、比較的少量のデータでも実行可能で はあるものの、数百では十分な量とは言えない. 著者らが保持 する不要文除去問題は 249 問であり、転移学習には不十分な 分量だと考えられる. そのため、本研究では、既存の長文テキ ストの一部に不要な文を追加することで擬似的に不要文除去問 題を作成し、転移学習に利用するデータの量を増やすことで、 解答精度の向上を試みる.

利用するテキストとして、本研究では RACE データセット [Lai 17] の本文部分を用いる. 擬似問題を1 問作成する場合, この本文から連続する7 文を抜き出して正しい文章とし、7 文 以外の本文の箇所からランダムに抜き出した1 文を不要文と する.得られた不要文を,先頭・末尾以外の箇所に挿入し,図 1 のように,不要な文を1 文含む擬似問題とする.上記の連続 する7 文を抽出するウィンドウをスライドさせていくことで, RACE データセットの1 つの問題から,おおよそ10 問程度の 擬似問題が作成できる.最終的に作成できた問題数は80 万問 程度であった.

# 2.3 4 択の不要文除去問題への適用

本研究では、ある選択肢の要否を判断する2値分類器として BERT を学習し、各選択肢について個別に推定された不要らしさを4つの選択肢間で比較し、不要らしさが最大であったものを解答として出力するというアプローチを採用する.

また,BERTへの入力形式は,選択肢を置く位置や segmentID の値,選択肢近傍の見る範囲など,数種類のパターンが考 えられる.以下に,採用した4つの入力形式を述べる. doc-opt 選択肢 (opt) を除く本文 (doc) を文頭側にまと めて並べ,セパレータを挟んで opt を文末側に配置する方法 (図 3).本文側の segmentID を 0, opt 側を 1 とする.BERT の事前学習の一つである,2 文間の結束性判定を利用したもの であり, opt が doc と無関係な文であった場合に,不要である と判断できると考えられる.



図 3: doc-opt

**3opt-opt** 4 つの選択肢のうち,対象とする選択肢以外 (3opt)をまとめて文頭に置き,対象とする選択肢 opt を文 末に配置する方法(図4).doc-opt 同様, 3opt の segmentID を 0, opt の segmentID を 1 として, 2 文間の結束性判定を 利用して解答する.doc-opt に比べて見る範囲が狭いため,判 定に情報が欠落する可能性がある一方,学習を効率的に行える 可能性がある.

| token:   | [CLS] | option <sub>j</sub> (j≠i) | option <sub>k</sub> (k≠i) | option <sub>i</sub> (I≠i) | [SEP] | option | [SEP] |
|----------|-------|---------------------------|---------------------------|---------------------------|-------|--------|-------|
| segment: | 0     | 0                         |                           |                           | 0     | 1      | 1     |

#### 図 4: 3opt-opt

**prevN-opt-nextN** 対象とする選択肢 (opt) を中心として, 前後N文ずつを抽出し,出現順通りに並べて配置する方法(図 5). opt の segmentID を 1, それ以外を 0 とする.N を無限 に大きくした場合は, doc-opt における opt の配置を文中の出 現箇所としたものに対応する.position encoding による,出 現位置の情報を利用することで,より出現位置に敏感なモデル になると考えられる.



⊠ 5: prevN-opt-nextN

**prevN-nextN** prevN-opt-nextN のうち, opt を取り除い てその前後のみを利用する方法. opt が含まれない状態で判定 するため, opt とその他の箇所との意味的な距離を判定に利用 することができず,必要な文が抜けた場合の不自然さ,および 正しく不要な文が抜けた場合の自然さ,を利用して判定する必 要がある.そのため, opt を利用する他のモデルとは解答傾向 が異なることが期待される.

# 2.4 BERT の後続文予測を用いた手法 (転移学習なし)

BERT は事前学習における目的関数として, 穴埋め (cloze test) および後続文予測 (next sentence prediciton)の正解率 を目的関数としている.事前学習は大量のコーパスを使い大き な計算コストをかけて行っていることから,特に学習データが 少ない場合に,対象とする問題を事前学習の目的関数に類似し た問題に帰着させることができれば転移学習なしである程度の 精度が得られることが期待できる.そこで本研究では,前節ま でで述べた疑似負例を用いて転移学習を行う方法に加え,事前 学習自体を活かし転移学習なしで問題を解く方法を提案する.

不要文除去問題を「各選択肢がその直前の文脈に後続しう るかどうか判定する問題」と考えると事前学習における後続文 A: <選択肢の左 k 文> [SEP] <選択肢> <選択肢の右 m 文> B: <選択肢の左 k 文> [SEP] <選択肢の右 m+1 文>

# 図 6: 後続文予測への2つの入力形式

予測のタスクと同等とみなすことができる.この考えのもと, 我々は BERT の事前学習モデルのみによる後続文予測問題と して解答を試みる.各選択肢についてそれぞれ独立にその選択 肢が直前の文に後続しうるかどうかを判別(二値分類)し,接 続しないものを除去すべき選択肢として選ぶのが最も単純な実 装であるが,この場合,選択肢が一つのみ選ばれるとは限らな い.二値分類の前提となる尤度を用いて尤度最低の(すなわち 最も後続性の低い)選択肢を選ぶ方法が考えられるが確率計算 のベースが異なるためか予備実験では精度が低かった.

我々は、各選択肢について「その選択肢を除去しない場合」 と「その選択肢を除去して次の文に遷移する場合」の 接続性 の良さの差を求め、この差を「当該選択肢を除去すべきスコ ア」と考えた.すなわち、一つの選択肢に対して図 6 のよう なA、Bという入力を BERT の後続文予測モデルに与え、出 力の尤度値 (対数 odds)の差をこの選択肢のスコアとする.な おk,m は実験的に k = 2, m = 2 と定めた.各選択について このスコアを求め、スコアが最大のものを解答とする.

# 3. 評価

#### 3.1 実験設定

2014~2019年のセンター本試験および追試験,予備校の模 試に含まれる不要文除去問題 129 問をテストセット, 独自に 作成した不要文除去問題 120 問を開発セットとして,評価に 用いる.独自に開発した問題は、平均的な英語力を持つ人の 正解率が 50% 程度になるように難易度を調整している.比較 するモデルは、9種である. ベースラインとして、3つの選 択肢と1つの選択肢の距離を Word2vec のコサイン類似度で 算出し,距離のもっとも遠い選択肢を選んだ場合を比較する. prevN-opt-nextNのNは1, 2, allとする.不要文除去問題は 約7文程度から構成されていることから, N = 3とすること は、ほぼ全文使用に等しい. また、prevN-nextN については、 文章としての自然さを評価するものであるため, segmentID を 全て0にした場合も評価する.転移学習のパラメータは、バッ チサイズ 32, 最大系列長 512, dropout は 0.1 固定, epoch 数 は 4, 学習率は 5e<sup>-6</sup> と 5e<sup>-7</sup> の 2 種類とした. 各手法におい て開発セットで最大正解率時のモデルを用いてテストセットの 正解率を評価する. 学習データ数は 670,540 で, 正例・負例の 割合は同じになるようにした.

#### 3.2 結果

各手法の正解率を表1に示す.Word2vecで0.457だったの に対して,BERTで遷移学習した場合にprevN-nextN(seg0) (選択肢を除いた前文と後文を segmentID 0 で埋め込んだ場 合)において最大の0.612のスコアが得られ,カイ二乗検定 においても有意な向上が見られた(p=0.0009).また,prevNopt-nextNにおいては,前後1文だけをみるよりも,前後2文 またそれ以上をみた方が選択肢の要否を正しく判断できること がわかった.これは,人間が問題を解く際にも前後1文から 対象の文が必要か不要かを判断することが難しいことからも, 妥当な結果であると考えられる.

また, prevN-nextN については, segmentID を切り替える よりも,全て0で固定した場合の方が高い正解率が得られた. 文章としての自然さをそのまま評価する方が適していると考え

| 圭  | 1.    | タ毛油の工鼦索  |
|----|-------|----------|
| 1X | - T ÷ | 谷子仏の正脾学, |

| 衣 1. 台子仏の止脾学.          |                       |  |  |
|------------------------|-----------------------|--|--|
| 手法                     | 正解率                   |  |  |
| (1) ベースライン (w2v)       | 0.457(59/129)         |  |  |
| (2) Doc-opt            | 0.543~(70/129)        |  |  |
| (3) 3opt-opt           | 0.558~(72/129)        |  |  |
| (4) prev1-opt-next1    | 0.372~(48/129)        |  |  |
| (5) prev2-opt-next2    | $0.550 \ (71/129)$    |  |  |
| (6) prevN-opt-nextN    | 0.535~(69/129)        |  |  |
| (7) prevN-nextN        | $0.550 \ (71/129)$    |  |  |
| (8) prevN-nextN (seg0) | <b>0.628</b> (81/129) |  |  |
| (9) 転移学習なし             | 0.512~(66/129)        |  |  |

られる.

次に、手法毎に解けている問題がどのように異なるかを検 証する. 2 つの手法の正誤関係に対し, カイ二乗検定を行い独 立性が棄却されれば、正誤の傾向に関係があることが示され る. すなわち,同様の問題に正答する傾向もしくは異なる問題 に正答する傾向が示される. さらに残差分析により異なる問 題に対しての正答している数に対して特に有意な差が見られ れば,異なる問題に正答していることが示せることを利用し て,正答の傾向が近いかどうかを見る.本手法を用いて,2種 類の比較を行う. 表 2 に Word2vec とそれと同様の特徴を学 習すると考えられる Doc-opt および 3opt-opt との比較と,表 3に BERT の転移学習を行う手法におけるトップモデル間の 比較を示す.各値はp値であり、\*印は、多重検定前の有意水 準を 0.05 としたとき、ホルム補正および残差分析を行った結 果,一方が正答している箇所有意な差が見られた場合に付与し た. Word2vec との比較においては、Doc-opt による手法は異 なる問題に正答していることがわかった. これは Doc 内での 文章の自然さおよび Doc と後続する opt との含意関係が学習 された可能性が考えられる. また, 転移学習を行う手法におけ るトップモデル間の正誤比較より、3opt-optと prevN-nextN (seg0)に有意な差が見られた. 3opt-opt は選択肢間の類似度 を, prevN-nextN (seg0) は文章としての自然さをというよう に異なる点を表現できている可能性がある. これらをうまくア ンサンブル学習することができれば、さらに正解率が向上でき る可能性があると考えられる.

表 2: W2V と類似モデル間の関係比較.

|                  | (1) | (2)      | (3)     |
|------------------|-----|----------|---------|
| (1) ベースライン (w2v) |     | *0.00793 | 0.04746 |
| (2) Doc-opt      |     |          | 1.0     |
| (3) 3opt-opt     |     |          |         |

|                        | (3) | (6) | (8)      |
|------------------------|-----|-----|----------|
| (3) 3opt-opt           |     | 1.0 | *0.02103 |
| (6) prevN-opt-nextN    |     |     | *0.02414 |
| (8) prevN-nextN (seg0) |     |     |          |

#### 3.3 分析

BERT の適用によって Word2vec からどのような問題が解け るようになり,一方で依然正答できていないかについて,問題毎 の正誤の傾向により分析する.ここでは,Word2vecとBERT の適用によって最高スコアが得られた prevN-nextN (seg0)と を比較し(表 1),BERT でのみ正答した問題,両者で誤答し た問題の例を用いて分析する.4つの選択肢のスコアのうち, Food can do more than fill our stomachs? it also satisfies feelings. If you try to satisfy those feelings with food when you are not hungry, this is known as emotional eating. There are some significant differences between emotional hunger and physical hunger. (1) Emotional and physical hunger are bo th signals of emptiness which you try to eliminate with fo od. (2) Emotional hunger comes on suddenly, while physic al hunger occurs gradually. (3) Emotional hunger feels lik e it needs to be dealt with instantly with the food you wa nt; physical hunger can wait. (4) Emotional eating can le ave behind feelings of guilt although eating due to physica l hunger does not. Emotional hunger cannot be fully satisfied with food. Although eating may feel good at that moment, the feeling that caused the hunger is still there.

図 7: Word2vec および BERT で誤った問題の例 (2016 年セン ター試験本試験より引用. 正解は (1), BERT は (2) を選択).

最大値が,他の3つの選択肢のスコアと離れているものは自 信を持って選択したと考え,そのような問題を分析対象とし て選出した.尚,Word2vecとprevN-nextN (seg0)の正誤を 比較すると両者とも正答は36問,BERTでのみ正答は45問, Word2vecでのみ正答は23問,両者とも誤答は25問であり, 2手法の組み合わせオラクルでは他の組み合わせと比較して もっとも高く,スコアは0.806 (104/129)であった.

図 8 は, word2vec で誤り, BERT で正解した問題である. 主題は缶切りの利点についてであり, (1) から (3) は共通して その主題をサポートしているものの, (4) についてはサポート していない. よって, BERT によって, 主題のすり替えによ る不自然さをうまく判断できるようになった可能性がある.

続いて,図7は,両手法で誤った問題である.(1)より前の 文にて Emotional hunger と physical hunger には重要な違い がいくつかあることが述べられているものの,後続する(1)で は,共通点が述べられている.このように,論理的なつながり の判定が必要な問題においては,現在の手法では判断できない と考えられる.

One of the most important kitchen tools is the simple handoperated can opener – the manual can opener. (1) Can open ers are needed to open some canned foods, and nowadays ma ny people have easy-to-use electric ones. (2) However, with a manual can opener, even when there is an electric power fa ilure, you can still open cans. (3)Another advantage of a m anual can opener is that it will last for years without any m aintenance. (4) Recently, even some electric can openers wit h multiple functions have been getting cheaper. In any event, it is always a good idea to have a manual can opener in your kitchen.

図 8: Word2vec で誤り BERT で正答した問題の例 (2014 年 センター試験追試験より引用.正解は (4)).

# 4. まとめと今後の課題

センター英語試験で出題される不要文除去問題に対し,近年 あらゆるタスクで SOTA を出している BERT の適用方法につ いて検討し,比較を行った.これまでの最高得点を得ることが できた.これは適用の際に用いた擬似負例が有効であったと考 えられる.また,選択肢の前のN文と選択肢の後のN文を単 純に連結した埋め込み方法がもっとも正解率が高くなる(試験 問題の正解率 0.628)ことがわかり,効果的な適用方法を明ら かにした.また,従来のWord2vec手法と比較して正誤の傾 向を分析したところ,この埋め込み方法によって文章としての 自然な流れを判断できるよう学習された可能性が高い.しかし ながら,論理的なつながりや飛躍の判定が必要な問題の場合に は,誤った選択肢を選ぶ傾向があることがわかった.今後はこ の問題を解決するため,全体としてのつながりの良さと局所的 なつながりの良さの両方を判断できるようなアンサンブル学習 を検討する.合わせて,係り受け関係などとの併用により,論 理的な構造が自然さに反映されるような工夫を検討していく.

# 謝辞

本研究を推進するにあたって,大学入試センター試験問題の データをご提供下さった独立行政法人大学入試センターおよび 株式会社ジェイシー教育研究所に感謝いたします.実験データ をご提供くださいました学校法人高宮学園,株式会社ベネッセ コーポレーションに感謝いたします.

# 参考文献

- [Alec 18] Alec, R., Karthik, N., Tim, S., and Sutskever, I.: Improving Language Understanding by Generative Pre-Training, arXiv:1802.05365 (2018)
- [Devlin 18] Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K.: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, arXiv:1810.04805 (2018)
- [Lai 17] Lai, G., Xie, Q., Liu, H., Yang, Y., and Hovy, E.: RACE: Large-scale ReAding Comprehension Dataset From Examinations, in *Proc. of EMNLP 2017*, pp. 785– 794 (2017)
- [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)
- [Radford 18] Radford, A., Narasimhan, K., Salimans, T., and Sutskever, I.: Improving language understanding by generative pre-training, URL https://s3us-west-2.amazonaws.com/openai-assets/researchcovers/languageunsupervised/language\_understanding \_paper.pdf (2018)
- [新井 18] 新井紀子, 東中竜一郎 F 人工知能プロジェクト「ロ ボットは東大に入れるか」:第三次 AI ブームの到達点と限 界 (2018)
- [東中 17] 東中 竜一郎, 杉山 弘晃, 成松 宏美, 磯崎 秀樹, 菊 井 玄一郎, 堂坂 浩二, 平 博順, 南 泰浩, 大和 淳司 F「ロ ボットは東大に入れるか」プロジェクトにおける英語科目 の到達点と今後の課題, 2017 年度人工知能学会全国大会予 稿集, pp. 2H2-1 (2017)

# 有価証券報告書を活用した企業名の語義曖昧性解消法の一考察 A consideration of word sense disambiguation of company name utilizing securities report

松田 裕之<sup>\*1</sup> Hiroyuki Matsuda 津田 和彦<sup>\*1</sup> Kazuhiko Tsuda

\*1 筑波大学大学院ビジネス科学研究科 Graduate School of Business Sciences, University of Tsukuba

Word Sense Disambiguation (WSD) is a research field that distinguishes semantics from peripheral information of the target word. This research worked on WSD of company names and aimed to acquire the same classification accuracy as supervised learning with unsupervised learning. Success of WSD of company names with unsupervised learning will enable us to extract only the information of the specific business without considering the appropriate search word, without putting enormous effort on preparing teacher data. We proposed a classification method to judge word sense from similarity of word vectors by business created using securities report and word vectors of words in classification target. With the proposed method, we achieved almost the same classification accuracy as supervised learning. It is suggested that introduction of a model for determining similarity to unknown words such as fasttext, suggests that there is room for improvement of accuracy.

# 1. はじめに

従来のテキストマイニングの課題に、文字列の表記のみが集 計・分析されていることがある。例えば、運転手を指す「ドライバ ー」と、ねじ回しを指す「ドライバー」のような多義語の課題であ る。このような多義語に対して、対象語の周辺情報などから語義 を識別する語義曖昧性解消という研究分野がある。

本研究では、対象語を企業名に絞り、教師あり学習で構築した分類器に匹敵する分類精度を、教師データの作成を行わずに達成することを目指す、分類対象の典型例として「ヤマハ」を取り上げ、①楽器メーカーとしてのヤマハ、②二輪メーカーとしてのヤマハ、③①②のいずれでもないヤマハ、の3つの語義に識別する.

本研究によって、期待される成果は2点ある.1点目は、企業 名の語義曖昧性解消ができれば、適切な検索キーワードを思 いつかずとも、特定事業の情報のみを抽出することが可能とな る点である.「ヤマハの二輪製造事業についてテキストデータか ら分析せよ」と言われれば、「ヤマハ バイク」という条件で検索 しデータを抽出する人が多いと思われるが、二輪製造事業に関 するデータで「バイク」が含まれないものは多くある.一方で、適 切な検索キーワードを1ユーザーが独力で全て羅列するのは不 可能である.そのような場合、企業名の語義曖昧性解消手段が 確立されていることは有用である.

2点目は、教師なし学習による語義曖昧性解消で、対象語の 周辺情報に加え、外部知識としてシソーラスの語釈文を活用す る手法が Chen ら[Chen 2014]より提案されている.このアルゴリ ズムを拡張し、有価証券報告書を知識抽出ソースとし、企業名 の語義曖昧性解消で外部知識を活用した点である.

# 2. 語義曖昧性解消

機械学習手法による語義曖昧性解消は、一般に教師あり学 習にて解決することが多い。例えば、単語「ドライバー」を含む 用例を適当な数集め、各々の用例に対してその用例中の「ドラ イバー」の語義を付与しておく、これを教師データに、周辺語の 情報などを対象語の素性として分類器を構築、識別タスクを実 行する手法である.

しかし,教師あり学習による分類は教師データの作成コストが 大きく,対象語が限定されてしまう問題がある.全ての単語に語 義を付与する語義曖昧性解消は all-words WSD というタスクと して研究されているが,ここでは教師あり学習によるアプローチ は非現実的であり,教師なし学習が用いられる.ただし,教師な し学習による識別精度は一般に教師あり学習よりも低い問題が ある.

教師なし学習による語義曖昧性解消において一時 state-ofthe-art の性能を示していたのが, Chen ら の手法である. Chen らは, Mikolov ら[Mikolov 2013]より提唱された Skip-gram によ り単語分散表現を得た後, シソーラス WordNet[wordnet]上の, 多義語の語釈文中の類似単語を利用して各語義の意味ベクト ルを作成, この意味ベクトルと対象語が含まれる文のコンテキス トベクトルとのコサイン類似度から, 語義を判定している.

本研究の提案手法は Chen らの手法を拡張したものである. Chen らは外部知識として WordNet の語釈文を活用したが, 企 業名について各語義を説明している情報として,本研究では有 価証券報告書を活用した.

# 3. 外部知識導入による企業名の語義曖昧性解消

語義曖昧性解消の対象とする企業には「ヤマハ」を選定した. ここでいう「ヤマハ」は、ヤマハ株式会社とヤマハ発動機株式会 社の2社を指す.

日経テレコンにて取得した日経新聞朝刊記事中の「ヤマハ」 を含む文 2109 件を分類対象データとした. さらに,有価証券報 告書上で各事業に言及する箇所を4箇所特定し, 2017 年度の ヤマハ株式会社およびヤマハ発動機株式会社の有価証券報 告書から事業別に文を抽出し,本研究で用いる外部知識デー タとした.

本研究では、本研究独自の手法に加え比較対象として、教師あり学習、教師なし学習、Chenらの研究をベースとした手法の3つ、計4手法で分類精度を比較した.

まず,教師あり学習/教師なし学習向け検証データの作成法 を簡単に述べる.分類対象データおよび有価証券報告書から tf-idf 値が一定以上の名詞を抽出し,機械学習で活用する素性 ベクトルとした.分類対象データから得たものは図 1 のようにな

連絡先:松田 裕之, 筑波大学大学院ビジネス科学研究科, 東 京都文京区大塚 3-29-1, s1740125@s.tsukuba.ac.jp

り、これを「対象語の周辺語から得た素性ベクトル」と呼ぶ. さら に、有価証券報告書から得たものを追加すると図 2 のようになり、 これを「外部知識から得た素性ベクトル」と呼ぶこととする. 図1. 対象語の周辺語から得た素性



分類方法は,教師あり学習では SVM,教師なし学習では K-means 法を実施した.

次に、Chen らの研究をベースとした手法(以下「Chen らの手 法」と呼ぶ)/本研究の手法向け検証データの作成法について 述べる.有価証券報告書の事業別の文から抽出した名詞につ いて、ヤマハの事業であれば「ヤマハ」、ヤマハ発動機の事業 であれば「ヤマハ発動機」の単語ベクトル(朝日新聞コーパス [田口 2017]にgensim ライブラリ[gensim]の word2vec 関数を適 用して取得)とのコサイン類似度を計算した.次に、コサイン類 似度の閾値tを 0 から 1 まで調整しながら、コサイン類似度がt 以上の単語のみを抽出した.最後に、抽出したコサイン類似度t 以上の単語群について単語ベクトルの平均を計算し、これを事 業別単語ベクトルとみなした.

以上の事業別単語ベクトルの作成プロセスをまとめると、図 3 のようになる.



図3. 事業別単語ベクトルの作成

分類方法について述べる. Chen らの手法では、まず、分類 対象データに現れる名詞の単語ベクトルの平均を計算した(こ れを「コンテキストベクトル」と呼ぶ). 次に、事業別単語ベクトル とコンテキストベクトルのコサイン類似度を計算した. 最後に、コ サイン類似度の閾値t<sub>c</sub>を 0 から 1 まで調整しながら、「楽器」 「二輪」事業ベクトルとのコサイン類似度がt<sub>c</sub>以上かつ最も高い ものに分類した. 複数の事業ベクトルとコサイン類似度が同値で あるか、いずれの事業ベクトルともコサイン類似度が*t*c未満である場合は、「その他」に分類した.

一方、本研究の手法では、まず、分類対象データに現れる語 について各々単語ベクトルを得た.この語群に対し、コサイン類 似度の閾値t<sub>o</sub>を 0 から 1 まで調整しながら、事業別単語ベクト ルとのコサイン類似度がt<sub>o</sub>以上の語が現れる度にスコアを+1 し た.以上の計算で、スコアが最も高いものに分類した.複数のス コアが同値か、いずれのスコアも 0 の場合、「その他」に分類し た.

# 4. 評価結果と考察

各手法で達成した正答率は表 1 の通りである.「対象語の周 辺語から得た素性ベクトル」のみを活用しているのが「外部知識 活用なし」であり、「対象語の周辺語から得た素性ベクトル」に加 え「外部知識から得た素性ベクトル」も活用しているのが「外部 知識活用あり」である.また、Chen らの手法および本研究の手 法では、コサイン類似度の閾値*t*,*t*<sub>c</sub>,*t*<sub>o</sub>を調整する中で正答率 が最高となったときの値を示している.

表1. 各手法で達成した正答率

|          | 分類手法                             | 正答率 |
|----------|----------------------------------|-----|
| 教師あり学習   | SVM(外部知識活用なし)                    | 78% |
|          | SVM(外部知識活用あり)                    | 80% |
| 教師なし学習   | K-means(外部知識活用なし)                | 45% |
|          | K-means(外部知識活用あり)                | 63% |
| Chenらの手法 | 事業別単語ベクトルとコンテキストベクトルのコサイン類似度から判定 | 71% |
| 本研究の手法   | 事業別単語ベクトルと文中の語のコサイン類似度から判定       | 76% |

分類精度としては教師あり学習に匹敵する程度が求められた が、教師あり学習による正答率は 80%であったのに対し、本研 究の手法による正答率は 76%と、教師あり学習には届かないも のの4ポイント低いのみの水準を達成しており、目的は一定達 成したと言える.

# 5. おわりに

本研究では、外部知識として有価証券報告書を活用し、事業 別単語ベクトルを作成した上で、事業別単語ベクトルと分類対 象中の語の類似度から分類を行う手法により、目標とする教師 あり学習に近い分類精度のアルゴリズムを構築することに成功 した.

今後,取り組むべき課題は主に2点挙げられる.1点目は, word2vec モデルにとっての未知語の存在が,分類精度向上の 壁の1つとなった点である.fasttext モデル[Bojanowski 2016]な どを活用し,未知語に対する類似性も判定することで分類精度 を向上させられる可能性がある.

2点目は、アルゴリズムの汎用性の担保である.本研究は分類対象を「ヤマハ」に限定し、各種パラメータの最適化を行なっているため、分類対象を変更した場合に有効なパラメータであるかは確認できていない.分類対象を複数事業に取り組む他企業に拡張し、汎用的なアルゴリズム・パラメータであるか検証する必要がある.

# 参考文献

[Chen 2014] D.Chen, C.D.Manning: A Fast and Accurate Dependency Parser using Neural Networks, Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014.

- [Mikolov 2013] T.Mikolov, I.Sutskever, K.Chen, G.Corrado, J.Dean: Distributed Representations of Words and Phrases and their Compositionality, CoRR, 2013.
- [wordnet] http://www.nltk.org/howto/wordnet.html, 最終アクセス日:2019-02-03
- [田口 2017] 田口雄哉,田森秀明,人見雄太,西鳥羽二郎,菊 田洸:同義語を考慮した日本語の単語分散表現の学習,情報処理学会研究報告,2017.
- [gensim] https://radimrehurek.com/gensim/index.html, 最終アク セス日:2019-02-03
- [Bojanowski 2016] P. Bojanowski, E. Grave, A. Joulin, T. Mikolov: Enriching Word Vectors with Subword Information, CoRR, 2016.

# Bidirectional LSTM を用いた誤字脱字検出システム Misspelling Detection by using Multiple Bidirectional LSTM Networks

| 高橋 諒*1        | 蓑田 和麻 <sup>*1</sup>      | 舛田 明寬 <sup>*2</sup>     | 石川 信行 <sup>*1</sup> |
|---------------|--------------------------|-------------------------|---------------------|
| Ryo Takahashi | Kazuma Minoda            | Akihiro Masuda          | Nobuyuki Ishikawa   |
| *1 株式会社リ      | クルートテクノロジー               | ズ <sup>*2</sup> 株式会社 Pl | E-BANK              |
| Recrui        | it Technologies Co.,Ltd. | PE-BANK                 | Inc.                |

Companies in the RECRUIT Group provide matching business between clients and customers, and create lots of manuscripts every day in order to tell the attractiveness of our clients. In this paper, we propose a method for detecting misspelling in manuscripts with machine learning. That system mainly consists of two parts. One is the multiple Bidirectional LSTM networks to estimate the probabilities of correctness in each characters. The other is the random forests algorithm to decide what sentence is correct or not by using outputs of these networks. The efficacy of our approach is demonstrated on two datasets: artificial sentences and real manuscripts created in our services.

# 1. 背景·課題

情報を提供するクライアントと情報を求めるカスタマーをマッ チングするのがリクルートのビジネスモデルである. このビジネス モデルにおいて、原稿はクライアントとカスタマーを結びつける 重要な情報伝達手段である. その原稿において, 万が一誤った 内容が記載されてしまうと,企業としての信頼に関わる問題に発 展するため、校閲業務に対しては多くのリソースが割かれている. しかし,それでも稀に不備のある原稿が発見されたり,文章とし て違和感のある原稿が掲載される事態が発生したりすることが 現状であった.その原因の1つが、1枚の原稿に対してチェック すべき規定の多さである. 通常どのサービスにおいても, それ ぞれに独自の原稿規定が存在しており、その数は各々100~200 項目に渡る.年間数十万件の規模で新規原稿が作成される中 で,それら1枚1枚に対し全項目のチェックを人手で行うのは困 難であり、熟練した校閲者でも見落としが発生していた.特に、 多くの規定の中でも, 誤字脱字についてはチェックが十分に行 われていないケースが散見されていた.

上記の課題に対し、システムによる校閲補助および自動校閲 が出来ないかの検討を行った.具体的には、NG ワードチェック のようなルールベースでの校閲に加え、誤字脱字や原稿内で の表記ゆれの検出を機械学習により行うハイブリッドな校閲シス テムを作成し、実導入を行った.本論文においては、その中で も深層学習を用いた誤字脱字検出ロジックについてのアルゴリ ズムとその実験/導入結果について記す.

誤字脱字の典型例として、"私は猫が空きです"のような漢字 の変換ミスや"私に猫がに好きです"というような助詞の間違いな どがある.このような誤字脱字は、単語の組み合わせで検出しよ うとすると、その数が膨大になり全てを定義することは困難なた め、ルールベースによる検出は難しい.そこで、本研究では文 字の系列情報を利用できる深層学習を利用したアプローチを 試みた.

# 2. 関連研究

深層学習の分野において、様々なネットワークが提案されているが、文章や音声波形などの系列データに対して有効なネットワークとして Recurrent Neural Network (RNN)[1] が存在する.

IT エンジニアリング本部データテクノロジーラボ部 高橋 諒 (ryo\_takahashi@r.recruit.co.jp) 自然言語処理という観点で、RNNを用いた事例として代表的 なものとして文章の自動生成がある[2][3]. RNNを生成モデルと して捉え、文章として成立している文字列  $(x_1, ..., x_T)$ を入力とし、 それぞれの次の文字を示す $(x_2, ..., x_{T+1})$ を正解として学習させ ることで、時刻 t+1 に出現する文字の確率 $P(x_{t+1}|x_1, ..., x_t) =$ softmax $(o_t)$ を取得する. ここで $o_t$ とは、時刻 t におけるネットワ ークの最終出力である。この確率値  $P(x_{t+1}|x_1, ..., x_t)$ が最大と なる文字を次の文字として順々に生成することで文章の生成を 行う.

本研究においては、この言語モデルとしての RNN をベース に異常検知として利用している. RNN を異常検知の文脈で利 用した研究として、例えば[4]や[5]が存在する. いずれも RNN の最終層に二値分類を行うための Dense Layer を繋ぐことで、そ の系列が正常か異常かを判定している. この形式の異常検知ア ルゴリズムを、日本語の言語処理に適用した先行研究として[6] が挙げられる. [6]ではテレビで利用されるテロップにおける誤 字脱字検出を目的とし、誤字脱字を予め 8 つのパターンに分類 し、それぞれのパターンに対して正常/異常の二値分類を行う RNN モデルの構築を行っている. [6]ではパターン毎のモデル の結果を単一文章に対して重ね掛けで検出した場合、モデル 数が増えると精度が下がる点が指摘されている.

提案手法では, RNN の中でも,長期依存性をもつ LSTM[7] を双方向に発展させた Bidirectional-LSTM (BLSTM) [8]を採用 した.更に,言語モデルと正常/異常の二値分類の BLSTM を並 列で利用し,それぞれの出力値を入力としたランダムフォレスト の結果から誤字脱字を含むか否かの判定を行った.提案手法 の特徴は下記 4 点である.

・BLSTM を利用することでターゲットとなる文字の前後双方の情報を利用できる

・言語モデルを組み合わせているため,予め考えられない誤 字脱字のパターンに対しても対応ができる

・言語モデルの出力結果を参照することで, 誤字脱字判定された文字の代替提案が可能である

・複数の BLSTM のモデルの出力の組み合わせにランダムフ オレストを利用することで、検出時の閾値設定が容易になった

3 章では用いたデータセットについて、4 章では提案手法の 詳細について述べ、5、6 章では実際のデータを用いた実験と

連絡先:株式会社リクルートテクノロジーズ
試験運用結果について紹介し,7章で今後の展望について説明を行う.

#### 3. 学習データセット

本手法では、BLSTM/ランダムフォレストモデルの学習用に 誤字脱字を含まない文(OK 文)と含む文(NG 文)のデータセッ トが必要である. リクルートには校閲済み原稿が大量に存在す るため、これを OK 文として利用する. 次に、過去の校閲内容の 分析より頻出の誤字脱字のパターン(以下、NGパターン)を表1 のように定義し、OK 文を基にして NG パターンに該当する誤字 脱 字 を 含 む NG 文 を 作 成 す る こ と に し た . 対象原稿としては後述する試験運用を見据え、リクルートが運 営するサービスの一つであるゼクシィの原稿を利用した. 用意した学習データセットを表 2 に示す. 校閲済み過去原稿 は 2015 年 1 月~2018 年 1 月に掲載された原稿であり OK 文 のみで構成される. 作成 NG 文 I / II は NG 文と、その基となっ た OK 文のペアで構成され、誤字脱字の箇所の情報も含む. な お、作成 NG 文 I は人手で作成したが、そこで不足した NG パ ターンを補うため作成 NG 文 IIを機械的に作成した.

| 名称       | 内容          | 例  |                |
|----------|-------------|----|----------------|
|          |             | 正) | 100名まで収容可能な会場。 |
| 漢字       | 漢字変換ミス      | 誤) | 100名まで収容可能な海上。 |
|          |             | 正) | ドレスのご試着は、      |
| 助詞連続     | 助詞の不自然な連続   | 誤) | ドレスのをご試着は、     |
|          |             | 正) | ご要望にお応えします。    |
| 脱字(送り仮名) | 送り仮名の脱字     | 誤) | ご要望にお応します。     |
|          |             | 正) | 写真撮影を行います。     |
| 脱字(助詞)   | 助詞の脱字       | 誤) | 写真撮影行います。      |
|          | タイプミスなどによる英 | 正) | 宜しくお願いします。     |
| 英字混入     | 字混入         | 誤) | 宜しくお願いしまs。     |

表 1: NG パターン定義

表 2: 学習データセット

|          |            |                 | 文数          | データ量 |
|----------|------------|-----------------|-------------|------|
| データセット名  | 含まれるNGパターン | NG文作成方法         | [件] ※1      | [MB] |
| 校閲済み過去原稿 | -          | -               | 428, 716    | 46   |
|          | 漢字、助詞連続、脱  | クラウドソーシングを利用し   |             |      |
| 作成NG文 I  | 字(送り仮名)    | て人手で作成          | 36, 565     | 10   |
|          | 脱字(送り仮名)、脱 | プログラムによる自動生成. 平 |             |      |
| 作成NG文Ⅱ   | 字(助詞)      | 仮名をランダムに選んで除去   | 1, 247, 690 | 291  |

# 4. アルゴリズム説明

本章では深層学習を用いた誤字脱字検出ロジックについて 説明する. 方針として,まず文字ごとの妥当性を判断する BLSTM モデルを構築し,その出力から文単位での正誤を判断 するランダムフォレストを構築する. これらを組み合わせ,最終 的には「誤字脱字箇所」,「正しい候補の文字」,「誤字脱字を含 む文」の3つを出力する.

#### 4.1 BLSTM による文字毎の OK/NG 確率モデル

本手法では、前方向からの文字の流れだけでなく、後方から の情報も捉えることができる BLSTM を採用した.文字毎の正常 /異常を求めるニューラルネットワークのアーキテクチャーを図 1 に示す.BLSTM による出力は文字毎に順方向/逆方向の 2 つ が存在するため、それらを結合し、各文字が正しいまたは誤字 脱字である確率(OK/NG 確率)の 2 次元を出力するよう設計し た.BLSTM 部分は順方向/逆方向で 2 層ずつ、計 4 層の中間 層を持つ設計とした.損失関数にはクロスエントロピーを用い、 文字毎に誤差を足しあわせた値を 1 文の誤差と定めた. 推論の 際は、上記の枠組みで学習されたモデルを用いて各文字の OK/NG 確率を出力し、この出力結果を利用して「誤字脱字箇 所」と「誤字脱字を含む文」を判定する.



#### 4.2 BLSTM による言語モデル

BLSTMによる言語モデルのアーキテクチャーを図2に示す. 入力部分は基本的に図1と同様である.異なる点は以下3つである.



#### 1. 学習に用いるデータの種類

学習に用いるデータは OK 文のみとした. 言語モデルは正し い文から正しい文字の流れを予測するためである.

#### 2. 最終層への入力を作成するロジック部分

4.1 の OK/NG 確率モデルとの違いは、最終層への入力を作成するロジック部分である.図2に示すように言語モデルの場合、 t番目の文字を予測するために、順方向LSTMのt-1番目の文字における出力値と、逆方向LSTMのt+1番目の文字における 出力値を結合し、最終層への入力とする.言語モデルの場合、 前後の文字から該当文字を予測するため、このような設計とした.

#### 3. 最終層の出力

最終層の出力は基本的な言語モデル同様,文字サイズ分の 次元を出力する設計である.

推論の際は、上記の枠組みで学習されたモデルを用いて、 文を構成している文字に対する確率を出力し、この出力結果を 利用して「誤字脱字箇所」と「誤字脱字を含む文」、「正しい候補 の文字」を判定する.この言語モデルを用いる利点は、予想で きていない誤字脱字を検出できる可能性がある点である.4.1の モデルのみでは機械的に作られた NG データを基にしているため,予想していない誤字脱字の検出力が弱くなる. それに比べ, 言語モデルでは日本語として正しい文字の流れを学習するため,予想していない誤字脱字を検出できる可能性が高くなる.

# 4.3 複数モデルのアンサンブル方法

4.1, 4.2 で作成したモデルの出力値を使用して,入力文に誤 字脱字を含むかどうかを判定する.使った変数を表3に示す.

表 3: ランダムフォレストの入力変数表

| 変数の説明                      | 次元数 |
|----------------------------|-----|
| a) BLSTMモデルの出力する確率が最低となる箇所 | 1   |
| b) a)における文字の確率             | 1   |
| c) a)における文字の種別 ※1          | 6   |

※1: {平仮名,カタカナ,漢字,英字,数字,その他}のいずれかを 示すone hot vector.

BLSTM モデル毎に上記を求め, 全モデル分統合したものを 入力とし,「誤字脱字を含む文か否か」の2値を分類するモデル を作成した. 学習器にはランダムフォレストを使用した. 推論時 はそのランダムフォレストが出力する確率値と閾値の比較により 判定する. このように複数の BLSTM モデルの出力値を用いた 学習器を使用する事で, 各々の BLSTM モデルの出力値に対 する閾値をチューニングする必要がなくなる. さらに誤字脱字と 判定する際の基準の選定の精度向上にも繋がり, 精度面/保守 面共に良いパフォーマンスとなる.

#### 4.4 誤字脱字箇所推定と候補文字の決定

入力文に対しランダムフォレストが「誤字脱字を含む文」と判 断した場合,「誤字脱字箇所の推定」と「候補文字の決定」を行 う. 誤字脱字箇所の推定は,各BLSTMモデルの文字毎の確率 が一定閾値以下となった箇所とする. 誤字脱字箇所と推定され た部分に対しては候補文字を決定する. 候補文字は誤字脱字 箇所において BLSTM 言語モデルの出力する確率が高い上位 3 文字とする. ただし,余分な文字が入っている,または脱字の ような NG 文は,誤字脱字箇所を候補文字で置き換えるだけで は文の修正ができない点に注意が必要であり,今後の課題とす る.

# 5. 実験

#### 5.1 文単位の性能評価

評価に用いるモデルを表 4 に示す. LSTM 言語モデルは前 方から後方へ向かう LSTM のみで構成した言語モデルである. BLSTM (言語, OK/NG 確率 I, II)モデルは 4.1, 4.2 で述べた モデル, アンサンブルモデルは BLSTM と 4.3 で述べたランダム フォレストで構成されるモデルを指す. BLSTM OK/NG 確率モ デルは, 学習データセットである作成 NG 文 I とII でサイズや内 容が違うため, それぞれでモデルを分けた.

評価用データとして OK 文と NG 文を同数用意し, 各モデル での NG 文に対する検出率(True Positive Rate)と OK 文に対す る誤検出率(False Positive Rate)で評価する. NG 文は表 1 に示 す NG パターンごとに 200 文ずつ作成した. ここでは, 句点等の 終端記号で区切った単位を1 文とし, NG 文1 文あたり1つの誤 字脱字を含むようにした. 各モデルは1 文ごとに誤字脱字を含 む/含まないを判定する. アンサンブル以外のモデルは文字ごと に正しさ表す確率を出力するため, 文に含まれるの全文字の確 率最低値と閾値との比較で判定する.アンサンブルモデルの出 力は文単位での確率であるため,出力値と閾値の比較で判定 する.

ROC 曲線とAUC を図 3, 表 5 に示す.表 5 より, 言語モデル 同士で LSTM と BLSTM を比較すると脱字(助詞)を除く全 NG パターンで BLSTM の方が AUC 値で上回っている. BLSTM モ デル同士(言語, OK/NG 確率 I, II)の比較では, それぞれ得 意な NG パターンが異なる. OK/NG 確率 I, IIモデルは学習 データに含まれる NG パターンに対して強く, その他の NG パタ ーンに対して弱い. 一方, 言語モデルは漢字, 英字混入に強い. 特に英字混入は OK/NG 確率 I, IIモデルの学習データに無 い NG パターンであり, 言語モデルの導入により未知の NG パタ ーンに対応できる可能性がある. アンサンブルモデルは全体, 漢字, 助詞連続, 脱字(送り仮名)について AUC が全モデル中 最高値であり, 他の NG パターンでも一定値を保っており, 3つ のモデルを統合することで相補的な効果が得られている.

#### 5.2 誤字脱字箇所推定と候補文字の評価

誤字脱字箇所推定と候補文字について評価結果を表6に示 す.また,検出文の事例を表7に示す.評価用のモデルはアン サンブルモデルを採用し,NG文検出の閾値は誤検出率=0.200 となる値を採用した.このとき検出率=0.795である.

表6より, 誤字脱字箇所推定の正解率は90.6%と高い. 候補 文字の正解率は62.5%である. BLSTM 言語モデルは注目する 箇所の前後の文字を正として利用しているため, 表7 No.2 のよ うな1 文字間違いのケースでは正解率が高いが, No.1 のような 連続する2 文字が間違うケースでは正解できないケースが多く 見られた.

#### 6. 試験運用

ゼクシィを対象に試験運用を実施した. ゼクシィ原稿の校閲 者は校閲システムを利用し PC 画面上で確認や修正を行う. ア ンサンブルモデルを用いた誤字脱字検出ロジックを校閲システ ムに組み込み,試験運用した. 試験期間中に投稿された原稿 に対して校閲前後の文とアルゴリズムの検出結果を収集し,投 稿された原稿を人手で OK 文と NG 文に振り分け, 1 文単位で の検出率/誤検出率で評価した. ただし,収集した NG 文には表 1 で定義していない NG パターンも含まれる. 試験運用は期間 を2期に分け,それぞれで評価した. 評価結果を表8に示す. ま た検出できた事例を表7に示す.

表 8 より, 第1期の検出率は 60%, 誤検出率は 11%である. 試験運用と評価用データでは NG パターンの分布に差があると 考えられるが, 第1期では図 3(e)の ROC 曲線と比較しても妥当 な結果となった. その一方で適合率(Precision)は 14%と低い. 理由として NG 文に対して OK 文は 29 倍と多いことが挙げられ る.

適合率は校閲者にとってシステムに対する心理的な信頼度 に直結するため向上のための対策が必要である. 学習用デー タセットは試験運用の半年前までに取得したものであるが, 原 稿の文章は時間経過に伴うトレンドの変化により徐々に変わっ ていくと考えられる. そこで, 直近のデータを使用すれば適合率 の向上が期待出来ると考え, 第1期で収集した原稿を学習デー タとして新たに追加し, 作成済みの BLSTM モデルをファインチ ューニングした.

表 8 に示す第2期はファインチューニング後のモデルを適用 した結果である. 第1期と比べ誤検出率が 6%まで低下し, 適合 率が 22%まで上昇することが確認できた.

# 7. まとめ

本研究では、複数の BLSTM モデルのアンサンブルによる誤 字脱字検出システムの開発および実験を行った.先行研究と比 較して、提案手法では、OK/NG 確率モデルに加え言語モデル を組み込むことで、想定していない誤字脱字パターンの検出が 可能になり、検出後の候補文字の提案まで可能となった.

実験では、リクルートが保有するサービスの実データを利用し て学習を行い,試験運用を行った.その結果,誤字脱字のない OK データが圧倒的に多数を占める状態のなかで誤検出 6%, 適合率 22%という結果を得た.

現時点での課題として, 脱字のような単純に文字置き換えで は対応できないパターンでの候補文字の提案手法の確立や検 出精度向上のためのネットワーク構造の見直しがある.また,運 用面では、実際にシステムを利用してもらうことで蓄積されるフィ ードバックデータを順次追加で学習をしていく仕組みの構築を 行う.

#### 参考文献

- [1] LWilliams, Ronald J.; Hinton, Geoffrey E.; Rumelhart, David E. Learning representations by back-propagating errors, 1986
- [2] Ilya Sutskever, James Martens, Geoffrey Hinton. Generating Text with Recurrent Neural Networks. 2011.
- [3] Tsung-Hsien Wen, Milica Gasi' c, Nikola Mrk ' si' c, 'Pei-Hao Su, David Vandyke, Steve Young Semantically Conditioned LSTM-based Natural Language Generation forSpoken Dialogue Systems. 2015.
- [4] BBenjamin J. RadfordLeonardo M. Apolonio, Antonio J. Trias, Jim A. Simpson. Network Traffic Anomaly Detection Using Recurrent Neural Networks. 2018.
- [5] Pankaj Malhotra1, Lovekesh Vig2, Gautam Shroff1, Puneet Agarwal. Long Short Term Memory Networks for Anomaly Detection in Time Series 2015
- [6] 中野 信. AI 技術を使った誤テロップ自動検出に関する技術検証. The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018.
- [7] Sepp Hochreiter and J"urgen Schmidhuber. Long short-term memory. Neural computation, Vol. 9, No. 8, pp. 1735-1780, 1997.
- [8] Mike Schuster and Kuldip K Paliwal. Bidirectional recurrent neural networks. IEEE Transactions on Signal Processing, Vol. 45, No. 11, pp. 2673-2681, 1997.

|                 | 衣 4. 計画に / //                      |              |
|-----------------|------------------------------------|--------------|
| モデル名            | 内容                                 | 使用学習データ      |
| LSTM 言語モデル      | 単方向LSTMによる言語モデル                    | 校閲済み過去原稿     |
| BLSTM 言語モデル     | Bidrectional LSTMによる言語<br>モデル      | 校閲済み過去原稿     |
| BLSTM OK確率モデル I | Bidrectional LSTMによるOK/NG<br>確率モデル | 作成NG文 I      |
| BLSTM OK確率モデルⅡ  | Bidrectional LSTMによるOK/NG<br>確率モデル | 作成NG文II      |
| アンサンブルモデル       | 上記3種類のBLSTMモデルとラ<br>ンダムフォレストで構成    | 作成NG文 I + II |

表 4· 評価モデル

#### 表 5: 文単位性能評価結果(AUC)

| モデル名               | 全体   | 漢字   | 助詞連続 | 脱字<br>(送り仮名) | 脱字<br>(助詞) | 英字混入 |
|--------------------|------|------|------|--------------|------------|------|
| LSTM 言語モデル         | 0.79 | 0.89 | 0.59 | 0.8          | 0.7        | 0.95 |
| BLSTM 言語モデル        | 0.83 | 0.96 | 0.62 | 0.88         | 0.62       | 0.99 |
| BLSTM OK/NG確率モデル I | 0.76 | 0.88 | 0.89 | 0.95         | 0.51       | 0.58 |
| BLSTM OK/NG確率モデルⅡ  | 0.77 | 0.59 | 0.62 | 0.94         | 0.87       | 0.77 |
| アンサンブルモデル          | 0.88 | 0.97 | 0.89 | 0.96         | 0.77       | 0.88 |

黄色は特定NGパターンについて他モデルと比べ高い箇所

表 6: 指摘筒所推定と候補文字評価結果

|                                      | NG文 | 誤字脱字箇所   | 誤字脱字箇所推 | 候補文字評価 | 候補文字   | 候補文字   |  |
|--------------------------------------|-----|----------|---------|--------|--------|--------|--|
| NG文数                                 | 検出数 | 推定正解数 ※1 | 定正解率 ※1 | 対象数 ※2 | 正解数 ※2 | 正解率 ※2 |  |
| 1000                                 | 795 | 720      | 0.906   | 376    | 235    | 0.625  |  |
| ※1: 推定した誤字脱字箇所中に真の誤字脱字箇所を含むとき正解とみなす. |     |          |         |        |        |        |  |

※2: 候補文字3文字中に正しい文字を含むとき正解とみなす.ただし4.4節で述べた制約があ るため、NG箇所の修正前後で文字数が等しい文のみ対象とする.

表 7: 検出成功事例

| _   |        |                      |                  |            |
|-----|--------|----------------------|------------------|------------|
| No. | 評価データ  | NG文と推定誤字脱字箇所         | OK文              | 候補文字       |
| 1   | 作成NG文  | フェアに【傘】【下】して結婚式のイ    | フェアに参加して結婚式のイメージ | [参, 面, 開], |
|     |        | メージを膨らませてみて!         | を膨らませてみて!        | [を,と,そ]    |
| 2   | 1      | この機会にシェフ渾身のお料理【w】    | この機会にシェフ渾身のお料理をご |            |
|     |        | ご堪能ください。             | 堪能ください。          | [を,で,も]    |
| 3   | 試験運用時  | より格調高いしつら【れ】に変わり、    | より格調高いしつらえに変わり、  |            |
|     | 原稿     | いっそう厳かな雰囲気になる神殿。     | いっそう厳かな雰囲気になる神殿。 | [え,い,う]    |
| 4   |        | 海外にいるかのような4【つ】       | 海外にいるかのような4つのパー  | [つ階月],     |
|     |        | 【パ】ーティ空間             | ティ空間             | [パ,ホ,の]    |
| 1   | は推定誤字勝 | 注字箇所. 候補文字は【】1つあたり3文 |                  |            |

表 8: 試験運用結果

| 試験運用 |            | 0K文  | 0K文  |       | NG文 | NG文  |       |       |
|------|------------|------|------|-------|-----|------|-------|-------|
| フェーズ | 試験運用期間     | 件数   | 検出件数 | 誤検出率  | 件数  | 検出件数 | 検出率   | 適合率   |
|      | 2018/7/23~ |      |      |       |     |      |       |       |
| 第1期  | 2018/8/20  | 1207 | 146  | 0.121 | 41  | 24   | 0.585 | 0.141 |
|      | 20180831~  |      |      |       |     |      |       |       |
| 第2期  | 20180914   | 1949 | 122  | 0.063 | 51  | 35   | 0.686 | 0.223 |



図 3: 文単位性能評価結果(ROC 曲線)

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

# [3H4-J-7] Agents: intelligence in/among robots

Chair:Keisuke Otaki Reviewer:Hidekazu Oiwa

Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room H (303+304 Small meeting rooms)

# [3H4-J-7-01] Effect of Robot Anxiety on the Appearance Tendency of Uncanny Valley

Kazuhiro Ikeda<sup>1</sup>, OTomoko Koda<sup>1</sup> (1. Osaka Institute of Technology) 3:50 PM - 4:10 PM

# [3H4-J-7-02] Strategyproof Mechanism with Agents Grouping for Multi-Agent Pathfinding

OManao Machida<sup>1</sup> (1. NEC)

4:10 PM - 4:30 PM

# [3H4-J-7-03] A Fundamental Study of Region Allocation for Mobile Robots Based on Constraint Optimization and Decentralized Solution Method OToshihiro Matsui<sup>1</sup> (1. Nagoya Institute of Technology)

4:30 PM - 4:50 PM

# [3H4-J-7-04] On the design of state value functions for real-time continuous-state space multi-agent decision making

OTomoharu Nakashima<sup>1</sup>, Harukazu Igarashi<sup>2</sup>, Hidehisa Akiyama<sup>3</sup> (1. Osaka Prefecture University, 2. Shibaura Institute of Technology, 3. Fukuoka University) 4:50 PM - 5:10 PM

# 対ロボット不安特性による不気味の谷の出現傾向の分析 Effect of Robot Anxiety on the Appearance Tendency of Uncanny Valley

池田 和広 Kazuhiro Ikeda 神田 智子 Tomoko Koda

大阪工業大学情報科学部

Department of Information Science and Technology, Osaka Institute of Technology

In this study, we analyzed the influence of robot anxiety characteristics on the appearance tendency of uncanny valley. We used crowdsourcing for the questionnaire survey of mechano-humanness score (MH score) and likeability of 80 robot face images. Then we divided the participants into two groups according to their scores of Robot Anxiety Scale (RAS). The results of t-test of the fitted curves using the MH scores and likeability scores showed that the appearance tendency of the uncanny valley is affected by users' robot anxiety scale. Those who have less anxiety toward robots showed higher affinity toward the robot faces, while those with high anxiety showed lower affinity toward the same faces.

## 1. はじめに

社会的対話ロボットが日常生活で使用され,我々の生活に浸透しつつある.日本は米国やドイツと比較すると,「ロボット=コミュニケーション可能」と認識される割合が高いことが示されている[1].産業用ロボットではロボットが顔を持つことは必要ではないが,社会的対話ロボットでは,ロボットの外見がユーザである人間に与える影響を考える事が重要である.森はロボットの外見が人間的になるほど親近感は向上するが,人間に近づくある段階で一旦親近感が下がる「不気味の谷現象」を提唱した[2]. Mathur らはアメリカ人を対象に,ロボットの顔画像 80 枚を用いて,それぞれの顔を機械的-人間的の尺度に数値化(mechano-humannes (MH) スコア)し,それぞれのロボットの顔画像に対する親近感を評価するアンケート調査を実施し,MHスコアと「不気味の谷現象」の関連を示した[3].

一方、ロボットとのインタラクションに対して不安を感じる人や 否定的な感情を抱く人が存在していることから、野村らは、実験 参加者のロボットに対する不安を評価する指標である対ロボット 不安尺度 (RAS)を提唱している [4]. RASを用いて実験参加者 を分類した我々の先行研究では、受付ロボットの外見・振る舞い を変化させ、実験参加者にロボットと対話を行ってもらった.そ の結果、ロボットとの会話に不安を感じる RAS 高群は、ロボット の外見により親近感が変化するものの、不安に感じない RAS低 群ではロボットの外見によって親近感は変化しない事を示した [5].

これらのことから、本研究では「不気味の谷現象」の出現傾向 は、実験参加者の対ロボット不安の程度により影響を受けると考 える.アメリカ人の不気味の谷を検証した[3]では実験参加者を RAS 得点により分類していない.従って、本研究では、日本人 の実験参加者を募り、ロボットに対し不安を感じる RAS 高群、不 安に感じない RAS 低群に分類し、[3] と同様の実験を行う.

予測される不気味の谷の出現傾向は、RAS 低群が RAS 高 群より外見に対する親近感が高い「上下並行移動型」, RAS 高 群が RAS 低群より MH スコアの低い段階で親近感が低下し, MH スコアの高い段階で上昇する「左右移動型」, RAS 低群は RAS 高群と比べ親近感があまり変化しない「山谷の深さ変化型」 とした.

#### 2. ロボットの顔画像の印象評価実験

#### 2.1 ロボットの顔画像の機械的-人間的尺度の評価

ロボットの顔画像の MH スコアを算出するため, Yahoo!クラウ ドソーシングを利用し, 100 人の日本人に, [3] で用いられた 80 枚のロボットの顔画像(図1)に対する MH スコアアンケート(「機 械的」 -100 ~「人間的」+100 の値)に回答してもらった. 回答 から, 1~4種類の数字のみで回答している, 負の値を使用して いない, などの不適切なデータ約 20%を除外し, 79 人分のデ ータを分析対象とした. 分析対象の参加者の属性は, 平均年齢 39.2 歳, 標準偏差 9.8, 男性 62 名, 女性 17 名であった.

回答として得られた実験参加者の MH スコアの平均を, 各ロ ボットの MH スコアとした. MH スコアは最小値 -90.63, 最大値 90.33, 中央値 -37.37, 標準偏差 53.10 であった. 同じロボットの 顔画像を用いてアメリカ人が評価した[3]では, MH スコアが最 小値 -97.21, 最大値 93.21, 中央値 -49.18, 標準偏差 61.50 で あり, 両調査とも同様の傾向を示した.

#### 2.2 ロボットの顔画像の親近感の評価

2.1 と同じ 80 枚のロボットの顔画像に対する印象評価アンケートとして、ロボットに対する「親近感」、「楽しさ」、「不気味さ」 (それぞれ、「全く感じない」-100 ~「とても感じる」+100 の値で 回答)、および実験参加者の RAS を評価するアンケート調査を、 Yahoo!クラウドソーシング上で 300 人を対象に実施した.回答から、1~4種類の数字のみで回答している、負の値を使用してい ない、などの不適切なデータ約 55%を除外し、139 人分のデー タで以下の分析を行った.分析対象の参加者の属性は、平均 年齢 41.6 歳、標準偏差 10.3、男性 93 名、女性 46 名であっ た.実験参加者を RAS 得点の平均値(41.57)により二群に分類 し、RAS 得点が平均値より高い実験参加者を RAS 高群 (n=74)、 低い実験参加者を RAS 低群 (n=65) とした.

次に、MH スコアを横軸とし、「親近感」、「楽しさ」、「不気味さ」 を縦軸とした散布図を作成し、近似曲線を得た.図2に親近感と MH スコアの近似曲線を示す.その結果、どの評価指標におい ても、[3] における結果と同じく、不気味の谷の存在を示す曲線 が得られた.

RAS 高群・低群それぞれの近似曲線全体間で,近似曲線の幅を標準偏差で定義し,各データ点における近似曲線の差の合計を算出し,Welchのt検定を行った結果,「親近感」では

連絡先:神田智子,大阪工業大学情報科学部,〒573-0196 大 阪府枚方市北山 1-79-1, tomoko.koda@oit.ac.jp

RAS 低群が RAS 高群より高い傾向にあり (p=0.056),「楽しさ」 では RAS 低群が RAS 高群より有意に高く (p<0.05),「不気味さ」 では RAS 高群が RAS 低群より有意に高い (p<0.01) ことが示さ れた.

近似曲線において, MHスコアが上がるにつれ親近感が上が り始め, 極大値に至った後下がり始める MH スコア-60~-30 間 における, RAS 両群の近似曲線の t 検定を行ったところ, RAS 低群の親近感スコアが高群より有意に高い (p<0.01) ことが示さ れた.しかしながら, 不気味の谷に落ち始めてから, 谷底に至り 親近感が上がり始める MH スコア+30~+60 の近似曲線間では, RAS 両群の親近感に有意差は見られなかった. 同様の分析を, 「不気味さ」評価で行ったところ, 極大値前後の MH スコア-60~ -30 間でも (p<0.05), 極小値前後の MH スコア+30~+60 間でも (p<0.01), RAS 高群の不気味さ評価が低群と比較して有意に高 いことが示された.

しかしながら,使用したロボット顔画像 80 枚中,MH スコアが 正の値を示す画像数が,負の値を示す画像数より少ないこと, 特に不気味の谷付近である+20~+50 の画像が少ないことから (図2参照),MHスコアの分布のばらつきを防ぐために画像数を 増やして評価実験を行う必要があると考える.

RAS 高群・低群間でロボットの顔画像の「不気味さ」に最も顕 著な有意差が出ていることから, RAS 得点はロボットに対する不 安を測る指標であるため,「親近感」より「不気味さ」の評価とより 深い関連があることを示唆していると考える.また, RAS 高群・低 群の「親近感」,同様の傾向を示す「楽しさ」, RAS 高群と低群 の評価差がより顕著に現れる「不気味さ」の近似曲線より,本実 験で使用したロボットの顔画像の実験結果に関しては,「上下 移動型」に近い傾向であることを示していると考えられる.

最後に、本実験とアメリカ人参加者による[3]の近似曲線を元 に、日米の比較を行う.本実験における日本人の親近感の極大 値+7のMHスコアは-45、極小値-20のMHスコアは28であっ た.アメリカ人による評価実験では、親近感の極大値+7のMH スコアは-66、極小値-43のMHスコアは36であったことから、 実験で用いたロボット顔画像では、アメリカ人参加者の方が日 本人参加者と比較すると、親近感が減少するMHスコア区間が 長く、不気味の谷が深い傾向がある可能性を示唆している.こ のことは、日本においてロボット=人型と認識されていることと関 連があるのではないかと考える.

# 3. おわりに

本研究では「不気味の谷現象」の出現傾向は、実験参加者 の対ロボット不安の程度により影響を受けると考え、クラウドソー シングにより日本人の実験参加者を募り、80枚の様々なロボット の顔画像を用いて親近感の評価実験を行った.また、対ロボッ ト不安尺度(RAS)を用いて、実験参加者をロボットに対して不 安を感じる RAS 高群、不安に感じない RAS 低群に分類し、親 近感の変化を比較した.その結果、不気味の谷の出現傾向は 両群で異なり、対ロボット不安により影響を受ける事が示された. RAS 高群・低群の「親近感」の近似曲線において、低群の近似 曲線が高群の近似曲線より上に位置することから、本実験の範 囲内では「上下移動型」に近い傾向を示していることが示唆され た.

今後の展望として、クラウドソーシング上で精度の高いアンケート結果を得るため一人の回答数を減少させる等の方策をとること、また、MH スコアのばらつきを防ぐ為、ロボットの顔画像を 増加させて実験を行う必要があると考える.



図 1. MH スコアおよび親近感の評価実験に使用したロボット 顔画像 80 枚 [3]



#### 謝辞

#### 本研究の一部は,科研費「基盤(C) JP17K00287」の交付を受け て実施した.

- [1] 日戸浩之,谷山大輔,稲垣仁美.ロボット・AI 技術の導入を めぐる生活者と受容性と課題~日米独 3ヵ国調査. NRI 知 的資産創造, pp. 108-125, 2016.
- [2] 森政弘. 不気味の谷」, Energy 第7巻第4号, pp. 33-35, 1970.
- [3] Maya B. Mathur, David B. Reichling. Navigating a social world with robot partners: A quantitative cartography of the Uncanny Valley. Cognition, Volume 146, pp. 22–32, 2016.
- [4] 野村竜也,神田崇行,鈴木公啓,山田幸恵,加藤謙介.
   Human-Robot Interaction (HRI)における人の態度・不安・
   行動. Fuzzy System Symposium 2010, pp. 554-559, 2010.
- [5] 中川弘也,神田智子. 受付ロボットの積極性及び外見が与え る印象のユーザ属性別分析. HAIシンポジウム2017, 2017.

# マルチエージェント経路計画のための エージェントグループ化を伴う正直申告メカニズム

Strategyproof Mechanism with Agents Grouping for Multi-Agent Pathfinding

町田 真直 Manao Machida

#### NEC

This paper proposes a computationally efficient strategyproof mechanism that solves multi-agent pathfinding (MAPF) problems with heterogeneous and self-interested agents. In MAPF, agents need to reach their goal destinations while avoiding collisions between them. MAPF solvers assign agents non-conflicting paths that minimize the global cost function (e.g., the sum of travel costs). Finding the optimal solution of a MAPF problem is an NP-hard problem. Mechanism design aims to design mechanisms in which the selfish behavior of agents leads to a socially optimal outcome. The Vickrey-Clarke-Groves (VCG) mechanism is a well known mechanism that is efficient and strategyproof. However, VCG must compute an optimal outcome to be strategyproof. In this paper, we consider heterogeneous and self-interested MAPF. Agents are heterogeneous if the costs of traversing a given path differ between agents. In particular, we assume each agent has a private linear cost function of travel time. The proposed mechanism divides agents into several groups depending on their declarations and thresholds, and then computes an optimal outcome for each group sequentially. The thresholds are parameters for adjusting computational complexity of this mechanism. We show that this mechanism has trade-off between the solution quality and run-time by numerical simulations.

#### 1. はじめに

マルチエージェント経路計画問題(MAPF)はグラフとエー ジェントからなる.各エージェントは,それぞれのスタート ノードからゴールノードまで,他のエージェントと衝突する ことなく,グラフ上を移動する必要がある.MAPFの目的は, エージェント間で衝突がなく,コスト(例えば,各エージェン トの移動コストの合計)が最小である各エージェントの経路を 解として得ることである.MAPFは,交通管制,ビデオゲー ム,配車ルートの決定等,様々な応用分野を持つ[Silver 2005, Standley 2010, Ryan 2010, Dresner 2008, Kiesel 2012].

メカニズムデザインは、エージェントの利己的な行動が社会的 に望ましい結果を生むメカニズムをデザインすることを目的とす る.特に、Vickrey-Clarke-Groves (VCG)は、耐戦略性と効率 性を満たすメカニズムとしてよく知られている [Vickrey 1961, Clarke 1971, Groves 1973].しかし、VCG では耐戦略性を満 たすために、最適な結果を算出する必要がある.

従来の MAPF では,各エージェントは協力的であること が仮定されている.近年,この協力型の MAPF に対して,利 己的なエージェント間での MAPF の研究も行なわれている [Bnaya 2013, Machida 2019, Amir 2015].利己的なエージェ ント間の MAPF では,各エージェントが自身のコストを最小 化するために行動する状況で,いかにグローバルコストを最小 化するかが問題となる.[Amir 2015]は,VCG オークション と MAPF の関係を明らかにし,競り上げ式組合せオークショ ンを用いて利己的エージェント間の MAPF を解く手法を提案 している.また,組合せオークションは,与えられた経路への コストがエージェントによって異なる,異質なエージェント間 の MAPF に対しても適用することができる.しかし,組合せ オークションにおける勝者決定問題(各エージェントへの経路 の割当問題)は,NP 困難である. [Machida 2019] では、多項式時間の正直申告メカニズム SCA\*を提案している.しかし、解の品質は、VCGと比べて 悪くなってしまうという欠点がある.

本稿では、各エージェントが移動時間に対して異なる線形 な移動コストを持つ状況において、SI-MAPFを解く計算効率 の良い正直申告メカニズムを提案する.提案メカニズムでは、 各エージェントに単位時間当たりの移動コストを宣言させる. そして、メカニズム側で設定した閾値と、エージェントの宣言 に基づいてエージェントをいくつかのグループに分け、逐次、 グループごとに最適な経路割当を決定する.ここで、閾値は、 計算量と解の品質を調整するためのパラメータである.また、 数値実験により、異なる閾値を設定した提案メカニズムを比較 し、解の品質と計算時間についてトレードオフが存在すること を示す.

#### 2. 問題設定

MAPF は, グラフ G = (V, E) とエージェントの集合  $K = \{1, ..., k\}$  からなる.エージェント  $i \in K$  はスタートノード  $s_i \in V$  とゴールノード  $g_i \in V$ を持つ.各エージェントは,1 つのタイムステップに,現在のノードに留まるか,隣接する ノードに移動することができる.エージェント i の経路を, $P_i$ で表す.ここで, $P_i$  はエージェントの存在するノードと時間 の組の集合である.ただし,時間の集合は  $T = \{0, 1, 2, ...\}$ と する.また,各エージェントは他のエージェントと衝突なく移 動する. $P_i$  の時刻 n に対応する要素を  $(p_i(n), n)$  で表す.経 路  $P_i, P_j$  が衝突するとは, $n \in T$  が存在して, $p_i(n) = p_j(n)$ または  $p_i(n) = p_j(n+1) \land p_i(n+1) = p_j(n)$  が成り立つこ とである.前者はエージェント i, j が同時刻に同じに位置に存 在すること,後者はエージェント i, j が交差することに対応す る.MAPF の解を, $P = \{P_1, ..., P_k\}$  で表す.また,解の集 合をP で表す.

本稿で扱う問題設定では、エージェントが利己的かつ、異な る時間に線形な移動コストを持つとする.エージェント*i*の単

連絡先: 町田 真直, NEC, 〒 211-8666, 神奈川県川 崎市中原区下沼部 1753, 044-435-5678, manaomachida@ap.jp.nec.com

位ステップ当たりの移動コストをタイムステップコストと呼び,  $w_i \in W$  で表す.ただし, $W = [0, \overline{w}]$ はタイムステップコスト の集合であり, $\overline{w}$ はタイムステップの最大値である.例えば, このコストを燃料費だとみれば,トラックが単位時間当たりに 消費する燃料 $w_{truck}$ が,バイクが単位時間当たりに消費する燃 料 $w_{motorcycle}$ の2倍であるならば, $w_{truck} = 2 \cdot w_{motorcycle}$ と設定すればよい [Amir 2015].

経路  $P_i$  にしたがって移動したときのエージェントの移動コストは、ゴールに到着するまでのタイムステップ数を $n(P_i)$ として、 $w_in(P_i)$  で与えられる.また、形式的には、

$$n(P_i) = \min\left\{n : \forall n' \ge n, (g_i, n') \in P_i\right\}$$

である.

さらに、本稿ではエージェントのコストは準線形であると仮 定する.つまり、経路  $P_i$ にしたがって移動するために、金銭 支払い t が必要であるとき、経路  $P_i$ にしたがうエージェント iのコストは、

 $w_i n(P_i) + t$ 

で与えられる.この金銭支払いは,例えば,経路の通行料 [Bnaya 2013] や,その経路を得るためのオークションでの支 払い [Amir 2015] に対応する.利己的なエージェントは,自身 のコストを最小化することを目的として行動する.

#### 3. 提案メカニズム

本節では、タイムステップコストの異なる利己的なエージェ ント間の MAPF を解く、エージェントグループ化を伴う正直 申告メカニズムを提案する。各エージェント  $i \in K$  は自身の タイムステップコスト  $b_i \in W$  を宣言し、メカニズムは宣言 に応じて経路割当  $P \in \mathcal{P}$  と各エージェントの支払い t を決定 する。

メカニズムを,  $f = (\beta, \tau)$  で表す. ここで,  $\beta: W^k \to \mathcal{P}$ は経路割当関数,  $\tau: W^k \to \mathbf{R}^k$  は金銭支払い関数である. 提 案メカニズムでは, タイムステップ集合の区間 [0, w] に複数の 閾値を設定し, 閾値に基づいてエージェントを分割する. そし て, 順番に, グループごとに最適な経路を計画していく. ただ し,後に決定される経路は, 既に決定された経路と衝突しない ように計画する.

MAPF における探索空間は  $O(|V|^k)$  であり,エージェント 数に対して指数的に増加する.提案メカニズムでは,この探索 をグループごとに分割することにより,探索空間の削減を行な う.グループ内のエージェント数が k' であるとき,グループ 内での探索空間は  $O(|V|^{k'})$  である.そのため,提案メカニズ ムでは,閾値の設定によってグループ内のエージェント数を減 らすことで,計算時間を削減することができる.

閾値を,  $c = (c_1, ..., c_{m+1})$ とする. cは,  $c_1 > \cdots > c_{m+1}$ かつ  $c_1 = \bar{w} \wedge c_{m+1} = 0$ を満たす. 分割されたエージェント の各グループを,  $i \in \{1, ..., m-1\}$  について  $C_i(b) = \{j \in K | b_j \in (c_{i+1}, c_i]\}$ ,  $C_m(b) = \{j \in K | b_j \in [c_{m+1}, c_m]\}$ で表 す. また, エージェントの部分集合  $K' \subseteq K$ の経路を  $P^{K'}$ ,  $\hat{\mathcal{P}}(P^{K'})$ を  $P^{K'}$ と衝突のない  $K \setminus K'$  に属するエージェント の経路集合とする.

提案メカニズムを擬似コード1に示す.1行目が各グルー プごとに順次処理していくことに対応し、2行目が処理内容で ある.各グループの経路は、既に計画された経路と衝突せず、 宣言したタイムステップコストに基づいてグループ内の総コス トが最小であるよう決定される.特に閾値 *c* = (*w*,0) である

#### Mechanism 1 提案メカニズム

1: for i = 1, ..., m do

2: plan  $\beta^{C_i(b)}(b)$  such that satisfies the following condition

$$\sum_{j \in C_i(b)} b_j n(\beta_j^{C_i(b)}(b)) = \min_{P \in \hat{\mathcal{P}}(\beta^{\cup_l < i^{C_l(b)}}(b))} \sum_{j \in C_i(b)} b_j n(P_j)$$
(1)

3: end for





とき,提案メカニズムの経路割当は VCG と一致する.また, $|\max_i C_i(b)| = 1$  であるとき,提案メカニズムの経路割当は SCA\*と一致する.

図1を用いて,提案メカニズムの処理の例を示す.提案メカ ニズムは閾値 c = (1, 0.5, 0)を持ち,図1のグラフ上に存在する エージェントがそれぞれ、タイムステップコスト $b_1 = 0.8, b_2 =$  $0.2, b_3 = 0.4, b_4 = 0.6$ を宣言するとする.このとき,エージェ ントは2つのグループ, $C_1(b) = \{1, 4\}, C_2(b) = \{2, 3\}$ に分割 される.提案メカニズムは、まず $C_1(b)$ について、最適な経路 を計画する.すなわち、

$$P_1 = \{(a,0), (a,1), (b,2), (c,3), \ldots\},\$$

$$P_4 = \{(c,0), (b,1), (d,2), (b,3), (a,4), \ldots\}$$

を計画する. その後,  $P_1, P_4$  と衝突しないうちで,  $C_2(b)$  について, 以下の最適な経路を計画する.

$$P_2 = \{(e,0), (e,1), (f,2)(d,3), (f,4), (g,5), \ldots\}$$
  
$$P_3 = \{(g,0), (g,1), (g,2), (f,3), (e,4), \ldots\}$$

 $P_2$ は, (d,2)で  $P_4$  と衝突しないよう,スタート地点でワンス テップの待機を行なう.そのため, $P_2$ は  $P_4$  よりワンステップ,  $P_3$ は  $P_1$  よりワンステップ,ゴールに到着するのが遅くなる. 各グループ iの取りうる経路集合を,

$$\hat{\mathcal{P}}^{C_i(b)}(b) = \hat{\mathcal{P}}(\beta^{\cup_{l < i} C_l(b)}(b)) \tag{2}$$

で表す.また、以下の関数を定義する.

$$M(i, b'_i, j, b) = \min_{P \in \hat{\mathcal{P}}^{C_j(b')}(b')} \sum_{l \in C_j(b) \cup \{i\}} b'_l n(P_l), \quad (3)$$

ただし, $b' = (b_1, \dots, b_{i-1}, b'_i, b_{i+1}, \dots, b_k)$ である.  $M(i, b'_i, j, b)$ は、申告 b がなされているとき、エージェ ント i が申告を b'\_i に変更したときの、集合 j に属するエー ジェントとエージェント i の移動コストの和を表している. 関数 M を用いて、支払い関数を以下で与える.

$$\tau_{i}(b) = -b_{i}n(\beta_{i}(b)) + M(i, b_{i}, c^{-}(b_{i}), b) - M(i, c_{c^{-}(b_{i})+1}, c^{-}(b_{i}), b) + \sum_{j > c^{-}(b_{i})} (M(i, c_{j}, j, b) - M(i, c_{j+1}, j, b)) \quad (4)$$

ただし,  $c^{-}(b_i)$ は,  $i \in C_{c^{-}(b_i)}(b)$ を満たす値である.式(4) は,特に閾値  $c = (\bar{w}, 0)$ であるとき,VCG における支払いと 一致する.また, $c = (\frac{l}{m})_{l \in \{0,...,m\}}$ であるとき,M > 0が存 在してm = Mのとき  $|\max_i C_i(b)| = 1$ ならば, $\lim_{m\to\infty} \tau(b)$ は SCA\*の支払いと一致する.

提案メカニズムが、以下の耐戦略性を持つことを示す.

定義 1 メカニズム  $f = (\beta, \tau)$  が耐戦略性を持つとは、任意の  $i \in K, b \in W^k$  について、以下が成り立つときをいう.

$$w_i n(\beta_i(w_i, b_{-i})) + \tau_i(w_i, b_{-i}) \le w_i n(\beta_i(b)) + \tau_i(b)$$

ただし,  $(w_i, b_{-i}) = (b_1, \dots, b_{i-1}, w_i, b_{i+1}, \dots, b_k)$  である.

メカニズムが耐戦略性を持つとき,各エージェントは,自身の タイムステップコストを正直に申告するときコストが最小であ り,嘘の申告する誘因を持たない.

以下の定理が成り立つ.

定理 1 提案メカニズム  $f = (\beta, \tau)$  は耐戦略性を持つ.

証明 [Archer 2001] より, 任意の  $i \in K, b \in W^k$  について,  $b_i \ge b'_i \Longrightarrow n(\beta_i(b)) \le n(\beta_i(b'_i, b_{-i}))$  が成り立ち, かつ,

$$\tau_i(b) = -b_i n(\beta_i(b)) + \int_0^{b_i} n(\beta_i(c, b_{-i}))$$
(5)

であるならば,  $f = (\beta, \tau)$  は耐戦略性を持つ.

まず,  $n \circ \beta$  が単調非増加であることを示す.  $b_i \ge b'_i$  につい て,  $C(b) = C(b'_i, b_{-i})$  が成り立つとき,明らかに $n(\beta_i(b)) \le n(\beta_i(b'_i, b_{-i}))$  が成り立つ.エージェント *i* が  $b_i$  を宣言した とき,属するグループが $C_j(b)$  であるとして, $C_j(b) \setminus \{i\} = C_j(b'_i, b_{-i})$  ならば,

$$\sum_{l \in C_j(b)} b_l n(\beta_l(b)) \le \sum_{l \in C_j(b)} b_l n(\beta_l(b'_i, b_{-i}))$$
$$\sum_{l \in C_j(b)} b_l n(\beta_l(b)) \le b_i n(\beta_i(b'_i, b_{-i})) + \sum_{l \in C_j(b'_i, b_{-i})} b_l n(\beta_l(b'_i, b_{-i}))$$

 $b_i n(\beta_i(b)) \leq b_i n(\beta_i(b'_i, b_{-i}))$ 

である.よって,任意の $i \in K$ について $n \circ \beta_i$ はW上で単調非増加である.

式 (5) から式 (4) が導出されることを示す.  $c_j > b_i \ge b'_i > c_{j+1}$  について,  $\bar{c} \in [b'_i, b_i]$  が存在して, 任意の  $c < \bar{c}$  につい て  $n(\beta_i(c, b_{-i})) = n(\beta_i(b'_i, b_{-i}))$ , かつ, 任意の  $c > \bar{c}$  につい て  $n(\beta_i(c, b_{-i})) = n(\beta_i(b))$  が成り立つとする. このとき,

$$\begin{split} \int_{b'_i}^{b_i} n(\beta_i(c, b_{-i})) &= (\bar{c} - b'_i)n(\beta_i(b'_i, b_{-i})) + (b_i - \bar{c})n(\beta_i(b)) \\ &= M(i, \bar{c}, j, b) - M(i, b'_i, j, b) \\ &+ M(i, b_i, j, b) - M(i, \bar{c}, j, b) \\ &= M(i, b_i, j, b) - M(i, b'_i, j, b) \end{split}$$

が成り立つ.よって,式(5)から式(4)が導出される.

#### 4. 数值実験

本節では、数値実験により提案メカニズムを評価する. 特に、分割するグループ数が異なる提案メカニズムの比較を行なう.  $f_s$ を、W = [0,1]をs等分にする閾値を持つメカニ



図 2: エージェントのスタート・ゴールがグリッドに隣接する, 8×8グリッドマップ

ズムとする. 例えば,  $f_2$  は閾値 (1,0.5,0) を持ち,  $f_4$  は閾値 (1,0.75,0.5,0.25,0) を持つ. また,  $f_1$  は VCG メカニズムと 一致する.

MAPFの問題設定として、以下のものを用いる.各エージェ ント $i \in K$ のタイムステップコスト $w_i$ は、[0,1]上の一様分 布に従ってランダムに与える.また、マップは8×8の4隣接 グリッドマップとし、各エージェントのスタートとゴールはグ リッドマップに属さず、1つのグリッドのみに隣接するノード とする.マップの例を図2に示す.さらに、任意の $i \in K$ に ついて、 $j \neq i$ は $s_i, g_i$ に進入禁止であるとする.各エージェ ントが他のエージェントのスタートとゴールを通過できないと いう問題設定は、各エージェントのスタートやゴールが私有地 であることに対応する。例えば、配送ドローンは、配送拠点で あるスタート地点から、配送先の住宅/ビルであるゴール地 点へ移動する.このとき、スタート・ゴールともに私有地であ り、進入の許可を得ていない他のエージェントは、これらの場 所を通過することはできない.

また,提案メカニズムで用いる最適経路計画アルゴリズム として, Conflict Base Search[Sharon 2015] を用いた.

表1は,エージェント数が5から10であるときについて, ランダムに生成した100間の,各提案メカニズムの平均の計 算時間を示している.分割するグループ数が多いメカニズムの 方が計算時間が短い.特に,エージェント数8から10にかけ て, f<sub>16</sub>の計算時間は f<sub>1</sub>(VCG)の50分の1以下である.

図 3,4 はそれぞれ,エージェント数が5 から 10 であると きについて、ランダムに生成した 100 問の、1 エージェント 当たりの平均の移動コスト、総コストを示している.ここで、 総コストは、移動コストと支払い額の合計である.図 3,4 の 両方において、分割するグループ数が少ない提案メカニズムの コストが小さい.また、 $f_1(VCG)$  とそれ以外のメカニズムを 比較すると、移動コストよりも総コストにおいてコストが大き く異なる.すなわち、 $f_1$ と比較して、 $f_s$  ( $s \ge 2$ ) は支払額も大 きい.

表1,図4より,提案メカニズムは解の品質と計算時間についてトレードオフを持ち,閾値の選択によって解の品質・計算時間のバランスの調整を行なうことができることがわかる.

表 1: 8×8グリッドマップ上, w が [0,1]<sup>k</sup> 上の一様乱数のと きの Runtime (ms)

| k  | $f_1$  | $f_2$ | $f_4$ | $f_8$ | $f_{16}$ |
|----|--------|-------|-------|-------|----------|
| 5  | 15.46  | 6.57  | 4.67  | 4.09  | 4.37     |
| 6  | 11.43  | 6.20  | 5.01  | 4.39  | 2.66     |
| 7  | 299.22 | 28.44 | 22.66 | 13.86 | 9.38     |
| 8  | 163.82 | 22.20 | 14.19 | 8.77  | 4.07     |
| 9  | 121.57 | 19.64 | 14.54 | 8.47  | 4.89     |
| 10 | 561.95 | 63.04 | 30.48 | 10.68 | 7.33     |



図 3: 8×8グリッドマップ上, w が [0,1]<sup>k</sup> 上の一様乱数のと きの, 1エージェント当たりの移動コスト

#### 5. まとめ

本稿では、各エージェントが利己的かつ移動時間に対して 線形なコストを持つ際に、MAPF を解く計算効率の良い正直 申告メカニズムを提案した.提案メカニズムでは、各エージェ ントに単位時間当たりの移動コストを申告させて、設定した 閾値によりエージェントをグループ分けし、グループごとに逐 次最適な経路割当を計算することにより、計算を高速化する. また、数値実験により閾値の異なる提案メカニズムを比較し、 閾値によって計算時間を調整できること、そして計算時間と解 の品質についてトレードオフがあることを示した.

#### 謝辞

本報告(または本研究など)には、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)からの委託を受 けて実施した「ロボット・ドローンが活躍する省エネルギー社 会の実現プロジェクト」の成果一部が含まれている.

- [Amir 2015] Amir, O., Sharon, G. and Stern, R.: Multiagent pathfinding as a combinatorial auction, in AAAI (2015)
- [Machida 2019] Machida, M.: Polynomial-Time Multi-Agent Pathfinding with Heterogeneous and Self-Interested Agents, in *AAMAS*, in press (2019)



図 4: 8×8 グリッドマップ上, w  $i^{i}$   $[0,1]^{k}$  上の一様乱数のと きの, 1 エージェント当たりの総コスト

- [Bnaya 2013] Bnaya, Z., Stern, R., Felner, A., Zivan, R., and Okamoto, S.: Multi agent path finding for self interested agents, in *Sixth Annual Symposium on Combinatorial Search* (2013).
- [Silver 2005] Silver, D.: Cooperative pathfinding, in AI-IDE, pp. 117-122 (2015).
- [Standley 2010] Standley, T.: Finding optimal solutions to cooperative pathfinding problems, in AAAI, pp. 173-178 (2010)
- [Ryan 2010] Ryan, M.: Constraint-based multi-robot path planning, in *ICRA*, pp. 922-928 (2010)
- [Dresner 2008] Dresner, K. and Stone, P.: A multiagent approach to autonomous intersection management, J. Artif. Intell. Res. (JAIR), volume 31, issume 1, pp.591–656 (2008)
- [Kiesel 2012] Kiesel, S., Burns, E., Wilt, C. M., and Ruml, W.: Integrating vehicle routing and motion planning, in *ICAPS* (2012)
- [Archer 2001] Archer, A. and Tardos, É.: Truthful Mechanisms for One-Parameter Agents; In Proceedings of the 42Nd IEEE Symposium on Foundations of Computer Science (FOCS '01), pp. 482- (2001)
- [Vickrey 1961] Vickrey, W.: COUNTERSPECULATION, AUCTIONS, AND COMPETITIVE SEALED TEN-DERS; Journal of Finance, Volume: 16, Number: 1, pp. 8-37 (1961)
- [Clarke 1971] Clarke, E.: Multipart pricing of public goods; Public Choice, Volume: 11, Number: 1, pp. 17–33 (1971)
- [Groves 1973] Groves, T.: Incentives in Teams; Econometrica, Volume: 41, Number: 4, pp. 617-31 (1973)
- [Sharon 2015] Sharon, G., Stern, R., Felner, A., and Sturtevant, N. R.: Conflict-based Search for Optimal Multi-agent Pathfinding; Artif. Intell. Volume: 219, Number: C, pp. 40-66 (2015)

# 制約最適化問題と非集中型解法による移動ロボット群への観測領域 割り当ての基礎検討

A Fundamental Study of Region Allocation for Mobile Robots Based on Constraint Optimization and Decentralized Solution Method

> 松井 俊浩 Toshihiro Matsui

### 名古屋工業大学 Nagoya Institute of Technology

Observation systems based on autonomous multiple robots including wide area surveillance, emergency response, and temporary exploration in unsafe areas have been widely studied. In general cases, there are various requirements for observation systems such as patrolling, exploration, tracking and cooperative sensing. These tasks also require the formation of robots and the allocation of observation areas. To manage complex sub-tasks simultaneously, a general approach based on constraint optimization problems and decentralized solution methods will be promising. This approach is studied as distributed constraint optimization problems in the multiagent research area. While several studies address the application of the distributed constraint optimization to sensor networks and mobile robots, there are opportunities to construct a unified model to integrate several tasks with the constraint representation and low cost decentralized solution methods. As a fundamental study, we address a simple model for patrolling problems with the allocation of observation areas to multiple robots.

# 1. はじめに

移動ロボット群による観測タスクの実現は、広域監視、災害 対応、危険性がある施設内での臨時の観測の手段として研究さ れている.自律的なロボット群による非集中型の観測タスクの 制御や観測資源割り当てには、インフラ利用が限定される状況 での利用や負荷分散の効果が期待される.一般に、観測の目的 は巡回、探査、追跡、特定の領域の集中的な観測など多様であ り、これらを支える観測領域の分担や、臨時の通信網の維持な ども含まれうる.このようなタスクを、個々のサブタスクから 必要なものを組み合わせ構成する枠組を用いることができれ ば、一定の有用性があると期待される.その一方で、非集中型 の解法によりこれらを連携させることは比較的煩雑であるた め、それらの条件を制約や目的関数として表現し、非集中型の 解法により解決する枠組の応用が検討されている.このような アプローチにマルチエージェントシステム上の基本的な最適化 問題を扱う分散制約最適化手法の研究がある [Fioretto 18].

分散制約最適化手法の動機付けとして,分散センサ網など の例題があり [Zhang 05, Béjar 05],移動ロボット群による観測 への応用も模索されている [Jain 09, Stranders 10, Zivan 15].観 測対象であるターゲットが存在する領域への注視などを複数 エージェントで分担するタスクなどが検討されているが,移動 ロボットの研究で基本的な,巡回などのタスクの上に立脚する 総合的な観測の要求に対応する複数の制約からなる問題の表現 と,実時間性を考慮する局所探索にもとづく解法の応用のため には,さらに検討の余地があると考えられる.本研究では、こ のような枠組の基礎部分の検討として,簡単な巡回観測タスク を題材としたモデルと解法の基本的な構成について検討する.

### 2. 例題

初期の検討のための簡単な例題として、グリッド世界の環境 を観測するロボットを模したエージェント群からなる系を考え る.環境は障害物と床のグリッドから構成される.各グリッド について最後に観測された論理時刻が記録される.エージェン トは4方向に移動し,周囲8グリッドの領域を観測し,観測 した時刻を更新する.各セルは十分に広く,エージェントは適 切な衝突回避により同一セルを共有できるものとする.各エー ジェントは個別にグリッド世界の地図と,関連する属性情報を 持つが,初期の検討として,各エージェントは他のエージェン トと情報を随時同期する.環境の観測時刻を更新する基本的な 巡回タスクを目的とする.エージェントは地図に基づく距離や 経路探索の計算を行い,随時移動目標を更新しつつ移動する. 未探査のセルへの移動の際に,互いに視野が重複するセルを解 消することを下位の基本的な目的とする.また,各エージェン トに自身の観測範囲を持たせ,それらを均衡するように配分す ることを上位の目的とする.ケーススタディとして,同一のセ ルから複数のエージェントが出発し,展開するシナリオについ て検討する.

# 3. 制約最適化によるタスクの協調のモデル化

各エージェントの情報を次の要素により表現する.

- エージェントの位置の二次元座標.
- エージェントの次の目的地の二次元座標.
- エージェントが担当する領域のグリッドの集合および,重 心付近の到達可能なセルの座標.これは領域を授受する 場合などの基準として用いる.
- エージェントの位置を起点とする各セルへの距離と最短 経路情報.

各エージェントは次の行動を並行する.

 次の目的地を選択し移動する.ここでは簡単に、観測を 担当する領域において、最も過去に観測し、最も遠いセ ルを優先して目的地の候補とする.指定された個数の複 数の候補の中から移動先を選ぶ.

連絡先: 松井 俊浩,名古屋工業大学,〒 466-8555 愛知県名古 屋市昭和区御器所町, matsui.t@nitech.ac.jp

- 他のエージェントとの観測領域の授受を選択し観測領域 を更新する。初期状態において一つのエージェントだけ が観測領域を持ち,他のエージェントへ観測領域を段階 的に配分する状況を考慮し,次の4種類の授受の行動の いずれかを取る。
  - 担当する観測領域を持たないエージェントが1つ
     以上ある場合に、自身の領域の半分を他に与える.
     エージェントの現在の座標から最も離れた観測領域
     のセルを膨張した領域を渡す.
  - 担当する観測領域を持たないエージェントである場合に、他のエージェントから与えられる領域をすべて受け取る。
  - 担当する観測領域を持つエージェントである場合に、 自身の領域の外周付近の領域を他に与える.ただし、 障害物に隣接する領域は除外する.
  - 担当する観測領域を持つエージェントである場合に、 自身の領域の周辺を領域を他から受け取る。

領域の授受は自身と他のエージェントの領域の大きさの差の最 大値が閾値を超えている場合に行なう.領域の授受では,受け 取る者が主導して受け取る領域を選択する.授受する領域の大 きさは,自身と他のエージェントの領域大きさの差の最大値に 応じて決める.一つのエージェントは一度に一つの領域のみを 授受する.

これらの行動の条件と評価値を複数の重み付きの制約により表現する.後者のものほど優先する階層的な重みを持つコストを与え,最小化問題とする.

- 1. 他エージェントと同一セルへの移動を抑制するためのコ スト.
- 2. 他エージェントと視野が競合するセルへの移動を抑止す るためのコスト.
- 3. 領域を受け入れるエージェントが領域を授受した結果と してなお残る領域の不均衡さのコスト. 関連するエージェ ント間の領域の大きさの差の最大値に加重する.

# 4. 非集中型の局所探索の適用

分散制約最適化問題の基本的な解法である Maximum Gain Messages (MGM) [Fioretto 18] に類似する非集中型の局所探索 を適用する.全体の解法の枠組みにおける1シミュレーション ステップは次の手順から構成される.

- 1. 各エージェントは環境を観測し,自身の現在の状況から, 問題の構成に必要な情報を計算する.
- 2. 現在の自身の情報と、自身の次の行動の初期解を提案する.
- 3. 関連するエージェントの情報を収集する.
- 4. 自身の行動の解を探索し,評価値を改善する解がある場合に,評価値の改善量を提示する.
- 5. 他のエージェントの改善量を収集する.
- 自身を含め、改善量が最も高く、識別名による優先順位 が最も高いエージェントが、解とそれに伴う情報を更新 する。

|  |   | 2 |  |  |
|--|---|---|--|--|
|  | 0 |   |  |  |
|  |   |   |  |  |
|  |   |   |  |  |
|  |   |   |  |  |
|  |   |   |  |  |
|  |   |   |  |  |
|  |   |   |  |  |

図 1:環境の例 (番号はエージェントの識別番号)

| 0 | 0                     | 0   | 0   | 0   | 0   | 2   |
|---|-----------------------|---|---|---|---|---|
| 0 | 0                     | 0   | 0   | 0   | 2   | 2   |
| 0 | 0                     | 0   | 0   | 2   | 2   | 2   |
|   |                       |   |   |   |   | 2   |
| 1 | 1                     | 1   | 1   | 2   | 2   | 2   |
| 1 | 1                     | 1   | 1   | 2   | 2   | 2   |
| 1 | 1                     | 1   | 1   | 2   | 2   | 2   |
| 1 | 1                     | 1   | 2   | 2   | 2   | 0   |
|   | 0<br>0<br>1<br>1<br>1 | 0 0<br>0 0<br>0 0<br>1 1<br>1 1<br>1 1<br>1 1 | 0       0       0         0       0       0         0       0       0         1       1       1         1       1       1         1       1       1         1       1       1 | 0       0       0       0         0       0       0       0         0       0       0       0         1       1       1       1         1       1       1       1         1       1       1       1         1       1       1       1 | 0       0       0       0       0         0       0       0       0       0       2         0       0       0       0       0       2         1       1       1       1       2         1       1       1       1       2         1       1       1       1       2         1       1       1       1       2         1       1       1       2       2 | 0       0       0       0       0       0         0       0       0       0       0       2       2         0       0       0       0       2       2         1       1       1       1       2       2         1       1       1       1       2       2         1       1       1       1       2       2         1       1       1       1       2       2         1       1       1       1       2       2         1       1       1       2       2       2 |

図 2: 観測領域の割り当て



図 3: 観測時刻の古さ

- 7. すべてのエージェントで改善量がゼロになるまで手順 3 からの処理を反復する.
- 8. 各エージェントは合意された行動を実行する.

この解法はきわめて簡素であるが、反復される毎回の交渉に リーダ選出に基づく合意を含むため、任意の段階で交渉を中断 することが容易である.実時間性を考慮する場合には、このよ うな局所探索と系の摂動を利用する準最適化のアプローチが妥 当と考えられる.

# 5. 実験

提案手法のシミュレーションを試作し,基礎的な検証を行った.10×10のグリッド世界の右上付近のセルから3つのエージェントが展開し探査する例を示す.各ステップの交渉回数の上限を20回とした.また,観測を担当する領域のサイズの差の最大値を5以下とする目標を設定した.50ステップ経過後













図 6: 最大の観測間隔

の状況の例を図 1-3 に示す.領域の演算が簡易的であるために 一部に断片が生じているが,十分に時間が経過した段階では, それぞれの担当領域のサイズは 20,18,19 程度であり,局所探 索や発見的な領域の演算による誤差はあるものの,ある程度の 均衡化がなされている.また,巡回の規則は目標地点の視野の 重複の解決以外には,周辺の観測情報が古い領域を移動目標と する貪欲的な戦略を用いたが,ある程度の間隔で更新がなさ れた.

観測を担当する領域の,大きさ,観測期間の平均と最大値の 推移を,図4-6に示す.観測領域の配分は,開始時には一つの エージェントが全体を担当する状況であり,開始後直ちに分割 された後,領域演算と局所探索の影響により停滞した場面があ るが,最終的にほぼ均衡した.観測の間隔は開始時の未探査セ ルでは100とした.全てのセルの観測後はある程度の間隔に 収まった.

### **6.** おわりに

本研究では、制約最適化問題による表現と非集中型解法を 基礎とする、移動ロボット群による観測システムの制御,資源 割り当ての枠組の基礎検討として、巡回観測タスクにおける競 合回避と観測担当領域の授受の調整を対象とした問題とモデ ルを構成し、その挙動について検証した.巡回以外のタスクを 含めた総合的な要求に対応する問題の表現と、実時間性を考慮 する局所探索にもとづく解法の応用のために、ロボット間の通 信の制限を考慮する配置の制約,注視領域への割り当てを優先 する観測などの条件の検討が今後の課題として挙げられる.ま た、より大規模な群における協調の局所性を伴う場合の評価, LiDAR による SLAM を考慮する観測と割り当てのモデルや、 動的な環境などの実際的な環境への適用の検討を進めたい.

謝辞本研究の一部は,公益財団法人立松財団一般研究助成に よる.

- [Béjar 05] Béjar, R., Domshlak, C., Fernández, C., Gomes, C., Krishnamachari, B., Selman, B., and Valls, M.: Sensor Networks and Distributed CSP: Communication, Computation and Complexity, *Artif. Intell.*, Vol. 161, No. 1-2, pp. 117–147 (2005)
- [Fioretto 18] Fioretto, F., Pontelli, E., and Yeoh, W.: Distributed Constraint Optimization Problems and Applications: A Survey, *Journal of Artificial Intelligence Research*, Vol. 61, pp. 623– 698 (2018)
- [Jain 09] Jain, M., Taylor, M. E., Tambe, M., and Yokoo, M.: DCOPs Meet the Real World: Exploring Unknown Reward Matrices with Applications to Mobile Sensor Networks, in *IJ-CAI 2009, Proceedings of the 21st International Joint Confer*ence on Artificial Intelligence, Pasadena, California, USA, July 11-17, 2009, pp. 181–186 (2009)
- [Stranders 10] Stranders, R., Fave, F. M. D., Rogers, A., and Jennings, N. R.: A Decentralised Coordination Algorithm for Mobile Sensors, in *Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence*, AAAI'10, pp. 874–880, AAAI Press (2010)
- [Zhang 05] Zhang, W., Wang, G., Xing, Z., and Wittenburg, L.: Distributed stochastic search and distributed breakout: properties, comparison and applications to constraint optimization problems in sensor networks, *Artificial Intelligence*, Vol. 161, No. 1-2, pp. 55–87 (2005)
- [Zivan 15] Zivan, R., Yedidsion, H., Okamoto, S., Glinton, R., and Sycara, K.: Distributed Constraint Optimization for Teams of Mobile Sensing Agents, *Autonomous Agents and Multi-Agent Systems*, Vol. 29, No. 3, pp. 495–536 (2015)

# 実時間連続状態空間マルチエージェント意思決定に対する 局面評価関数の設計について

On the design of state value functions for real-time continuous-state space multi-agent decision making

| 中島 智晴 *1                  | 五十嵐 治一 * <sup>2</sup>       | 秋山 英久 * <sup>3</sup>     |
|---------------------------|-----------------------------|--------------------------|
| Tomoharu Nakashima        | Harukazu Igarashi           | Hidehisa Akiyama         |
|                           |                             |                          |
| *1大阪府立大学                  | *2芝浦工業大学                    | *3福岡大学                   |
| aka Prefecture University | Shibaura Institute of Techn | ology Fukuoka University |

This paper presents an overview of value function representations and construction for RoboCup soccer simulation. Since RoboCup has several characteristic features such as multi-agent system, noisy environments, and dynamic decision making, it offers a more realistic environment for the decision making in multi-agent system research.

### 1. はじめに

ゲーム AI の研究は,計算機の性能向上や深層学習の登場に より急速な発展を見せている.その結果,囲碁や将棋をはじめ として,人間に勝利する AI プレーヤの登場が今や当たり前の ようになってきた.ゲーム AI を構築するためには,センサ情 報処理や意思決定など,社会的課題を解決するロボットや知的 情報処理に転用できるサブ課題を解決し,システム統合する必 要がある.このため,単純な課題であるトイプロブレムに比べ てゲーム AI をベンチマークとする研究は実世界への応用可能 性を広げるという意味で重要である

Os.

RoboCup サッカーシミュレーション 2D リーグは,約 20 年にわたる RoboCup の歴史の中で最も古いリーグの一つであ る.サッカーを題材とした仮想シミュレーションである一方で, 複雑なマルチエージェント問題の研究プラットフォームとして も利用することができる.表1に,RoboCup サッカーシミュ レーションと囲碁や将棋との違いをまとめる.これほどの制 約がプレイヤに課されているゲームは他にはなく,RoboCup サッカーシミュレーションを対象としたゲーム AI の研究は, より実世界応用につながるものになること考えられる.

| 表 1 | 1: Ro | oboCup | と囲碁 | い・将枝 | もとの違い |
|-----|-------|--------|-----|------|-------|
|-----|-------|--------|-----|------|-------|

| 特徴    | RoboCup    | 囲碁・将棋  |
|-------|------------|--------|
| 情報    | 不完全        | 完全     |
| 思考時間  | リアルタイム     | ターン制   |
| プレイヤ数 | 1 チーム 12 人 | 1チーム1人 |
| 状態空間  | 連続         | 離散     |
| 行動空間  | 連続         | 離散     |

RoboCup サッカーシミュレーションのゲーム AI を構築す るためには、センサ情報の処理、ボール処理の行動決定、次サ イクルのセンサ情報を得るための行動、行動実施のためのミク ロアクション決定、他エージェントを支援するための情報提供 など、幅広い情報処理と意思決定機構が必要になり、数多くの 人工知能的課題を解決しなければならない.このような複雑性 もあり、RoboCup サッカーの知見を基にした在庫管理ロボッ トや深層強化学習モデルの発展につながっている.また、将来

連絡先: 中島智晴,大阪府立大学大学院,599-8531 大阪府堺市学園町1-1,072-254-9351, tomoharu.nakashima@kis.osakafu-u.ac,jp

必要とされる集団ロボットの協調行動や自動運転における AI 部分の発展に大きく寄与すると考えられる.本論文では、その 中でも意思決定部分に焦点を当て、RoboCup サッカーシミュ レーションにおける意思決定メカニズムの研究を解説する.

# 2. RoboCup サッカーシミュレーション

RoboCup は、「2050 年までにサッカーでロボットが人間の チャンピオンチームに勝利する」という目標を掲げて立ち上 がった国際プロジェクトである. RoboCup サッカーには、い くつかのカテゴリーがある.本研究では、実機を使用せず、2 次元空間の仮想空間内で競技を行うサッカーシミュレーション 2 D リーグを対象とする.

#### 2.1 構成

RoboCup サッカーシミュレーションは、仮想サッカーフィー ルド上で競技を行う、実機ロボットを使用しないリーグである. サッカーサーバ、サッカープレイヤ(以降プレイヤ)、コーチ、 モニタから構成される.この様子を図1に示す.サッカーサー バはサッカーフィールドの全ての情報を保持しており、プレイ ヤからのアクションコマンドを受信して次サイクルのフィール ド状態を計算し、更新する.更新されたフィールドの情報を各 プレイヤに送信する.プレイヤは、サーバから受け取られた フィールド情報に基づいて状況を判断し、次サイクルのアク ションコマンドをサーバに送信する.プレイヤ間、コーチとプ レイヤ間の通信はサッカーサーバを介してのみ許可されてお り、直接通信することは許されていない.1ゲームは前後半そ れぞれ 3000 サイクルであり、1サイクルの長さは 0.1 秒であ る(したがって、1 試合の長さは延長戦がなければ 6000 サイ クル=5分).



図 1: RoboCup サッカーシミュレーションの構成

#### 2.2 プレイヤの行動決定

ここで、プレイヤの行動とアクションコマンドの違いについ て述べる.特に、ボールを持っているプレーヤの意思決定に焦 点を当てて説明する.プレイヤはフィールド状態に基づいて次 サイクルの行動を決定するが、行動の意思決定には大きく分け て二つの層がある.まず、意思決定の第1層では、パス、ドリ ブル、シュート、ホールドなどのマクロ行動を決定する.これ らの行動にはパラメータが必要である.

例えば、パスの場合は、パスを受け取るプレイヤ番号と受け 取りが、ドリブルの場合には、目標位置がパラメータとなる。 ドリブルでは、まずボールを蹴りだした後、次ボールを蹴る位 置がパラメータとなり、シュートはゴールのどの位置に向って ボールを蹴るかがパラメータとなる。また、第1層で決定され た行動に基づいて、第2層では、その行動とパラメータを達 成するためのアクションコマンド(キック、ダッシュ、ターン など5種類)とそのパラメータを計算する。これは、サーバ 内であらかじめルールによって決められているボールやプレイ ヤの物理計算を逆算することで求められる。キックのパラメー タは蹴る方向とその力、ダッシュは走る方向とその力、ターン はターンする量がパラメータとなる。プレイヤはアクションコ マンドとそのパラメータをサッカーサーバに送信する。

本論文で取り上げる行動の意思決定は、この第1層におけ る意思決定プロセスのことをいう.

#### 行動連鎖生成システム

行動連鎖システムは Akiyama ら [1] によって最初に導入さ れ,他のチームも採用している.行動連鎖生成システムの目的 は,ボールを保持しているプレーヤが次の行動を決定するため の方針を決定することである.方針が定まれば,それに沿うよ うな次の行動を決定することができる.

行動連鎖生成システムは、大きく3つに分けることができる. 探索木の生成、ノードの評価、木探索アルゴリズムである. このうち、木探索アルゴリズムはゲーム AI で広く使用されているモンテカルロ木探索や系統的探索アルゴリズムが適用できる. RoboCup サッカー(もしくはサッカー AI)固有の要素が必要なのは探索木の生成とノードの評価である. ノードの評価はサッカーフィールドがどれほどスコアにつながっているかを表すもので、局面評価とも呼ばれる.

その評価関数中のパラメータを,人間の専門家同士の棋譜を 用いて学習させる教師あり学習により,プロレベルまで棋力を 向上させることができる.現在では,階層型のニューラルネッ トワークモデルを用いて評価関数を近似し,ディープラーニン グの手法を取り入れることが主流になっている.特に,評価関 数を作成するのが難しいとされた囲碁で大成功しており,チェ スや将棋でも試みが始められている.

#### 4. 局面評価モデルの構築

局面評価の基準は、チーム戦略によって変化する.例えば、 シュートできることを目的とする戦略を考えている場合には、 シュートという目標状態に近いが同課の観点から評価値を設定 する.また、シュートまでの中間状態を目標とするチーム戦略 を立てることも可能であり、例えば、ボールを敵ペナルティエ リアに運ぶことを目的とするチーム戦略を考えている場合に は、シュートできるかどうかは考慮せず、とにかくボールを敵 ペナルティエリアに運ぶために有利な状態かどうかの観点から 評価値を割り当てることになる.

#### 4.1 特徴量の線形和による表現

RoboCup では、各プレーヤは視野範囲内にある他プレーヤ の位置や速度、自己位置を知るためのフィールド外に設置され たランドマークの位置が、数値情報として利用可能である.た だし、自分から遠くにあるオブジェクトの情報にはノイズや欠 損などの外乱が入り、不正確になる.ノイズや欠損、視野範囲 外のブレーヤやボールの情報は他プレーヤからの声かけで補完 されることもある.センサ情報にはノイズが大量に含まれてお り、プレーヤは正しくフィールド状態を把握することは非常に 困難である.このような条件下でフィールド状態を評価する.

フィールド状態を評価する最も単純な方法は、フィールド状 態を表現している特徴量をいくつか用意し、それぞれを重み 付けながら足し合わせることである.この方法は、特徴量の線 形和と呼ばれる.特徴量として、センサ情報から得られる敵プ レーヤの位置やボール、自プレーヤの位置や速度などを用い たり、「近くに敵がいる」「パス可能な味方プレーヤが近くにい る」などのような、人間がサッカーの知識を導入して作成する 特徴量も考えられたりする.後者の特徴量は特に、ヒューリス ティクスと呼ばれることもある.

特徴量の線形和でフィールド状態を評価する場合,各特徴量 に対応する重みをどのようにして決定するかという問題が残 る.単純にはランダムに決定する方法や人間の知識を利用して 決定する方法が考えられるが,限界や欠点も存在する.

#### 4.2 ニューラルネットワークモデルによる表現

前節で述べた特徴量の線形和はパーセプトロンと見なすこ とができる.この見方を発展させて,特徴量を入力,評価値を 出力とする階層型ニューラルネットを用いてフィールド状態の 評価値を求めることもできる.

局面評価値計算モデルとしてパーセプトロンやニューラル ネットワークを用いることで,機械学習の枠組みを用いた,経 験データを用いたモデルの構築が可能となる.経験データの種 類によって,評価値計算モデルを教師あり学習や強化学習によ り求めることができる.なお,教師無し学習により評価値計算 モデルを構築する研究はあまり行われておらず,研究は進んで いない.次章では,教師あり学習と強化学習を用いたフィール ド状態計算モデルの構築について述べる.

ニューラルネットワークの特徴量として,数値情報ではなく 画像情報を用いる方法も考えられる. Pomas ら [2] は,フィー ルド状態を数値情報ではなく画像で入手し,その画像からチー ムにとって有利かどうかを判断する関数を構築している.

# 5. おわりに

本稿では, RoboCup サッカーシミュレーションにおける局 面評価値計算モデルについて述べた.局面評価関数を構築する 方法について整理し,今後の研究展望を考慮するうえで重要と なる情報を与えることを目的とした.

- H.Akiyama, S.Aramaki, T.Nakashima, "Online Cooperative Behavior Planning Using a Tree Search Method in the RoboCup Soccer Simulation," *Proc. of INCoS* 2012, pp.170-177, 2012.
- [2] T.Pomas and T.Nakashima, "Evaluation of Situations in RoboCup 2D Simulations using Soccer Field Images," *Proc. of RoboCup Symposium*, 6 pages, 2018.

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

# [3J4-J-1] Fundamental AI, theory: search and application

Chair: Ichigaku Takigawa Reviewer: Yoichi Sasaki

Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room J (201B Medium meeting room)

# [3J4-J-1-01] ACO with Pheromone Update by Negative Feedback Can Solve CSPs OTakuya Masukane<sup>1</sup>, Kazunori Mizuno<sup>1</sup> (1. Department of Computer Science, Takushoku University) 3:50 PM - 4:10 PM [3J4-J-1-02] An Algorithm for solving the Traveling Salesman Problem using Clustering Method OJumpei Uchida<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University) 4:10 PM - 4:30 PM [3J4-J-1-03] Algorithm of Traveling Salesman Problem using Particle Swarm Optimization OYuki Yamada<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University) 4:30 PM - 4:50 PM [3J4-J-1-04] League Scheduling for U12 Basketball OTenda Okimoto<sup>1</sup>, Kazuki Nishimura<sup>1</sup>, Katsutoshi Hirayama<sup>1</sup> (1. Kobe University)

4:50 PM - 5:10 PM

# フェロモン更新に負のフィードバックを取り入れた ACO による 制約充足問題の解法

ACO with Pheromone Update by Negative Feedback Can Solve CSPs

增金拓弥 Takuya Masukane K

水野一徳

sukane Kazunori Mizuno

拓殖大学大学院工学研究科情報・デザイン工学専攻 Department of Computer Science, Takushoku University

To solve large-scale constraint satisfaction problems, ant colony optimization (ACO) has recently been drawing attentions. In algorithms based on ACO, candidate assignments are constructed by taking account of pheromone trails, which are updated based on a candidate assignment with the least number of constraint violations. In this paper, we propose an ACO model with dual pheromone trails: usual pheromone trails and another pheromone trails are updated based on a candidate assignment with the largest number of constraint violations. Also, usual pheromone trails are updated by considering another pheromone trails as well. We demonstrated that our model, which is applied to the cunning ant system, can be effective than other ACO-based methods for large-scale and hard graph coloring problems whose instance appears in the phase trainsiton region.

# 1. はじめに

制約充足問題 (CSP) は,離散値をとるいくつかの変数につ いて割当て可能な値の組合せのうち,与えられた全ての制約を 満たす組合せを,探索によって発見する問題である. CSP は 設計や計画問題などをはじめ,人工知能分野やパターン処理な どの広い分野にわたって応用されている基盤的技術である.

CSP を解くための探索アルゴリズムは,系統的探索アルゴ リズムと確率的探索アルゴリズムに大別される.大規模な CSP に対して,系統的探索アルゴリズムを用いて探索を行なう場 合,実用的な時間内に解を得ることが困難である場合が多い. そのため,近年では確率的探索アルゴリズムが注目されてい る.しかし,確率的探索アルゴリズムには,局所最適解に陥っ てしまう可能性があるという欠点がある.そこで,局所最適解 に陥ることを避ける,または局所最適解から効率よく抜け出す ためのメタヒューリスティクスについて研究がなされている. 蟻コロニー最適化 (ACO)は,蟻の採餌行動におけるフェロ モンコミュニケーションをモデル化したメタヒューリスティク スである [Dorigo 96, Dorigo 99]. ACO では,探索の過程で

発見された評価が高い解候補の情報を、フェロモンとして蓄積 する.このフェロモンを解候補の生成時に参考にし、フェロモ ンが多く溜まっている値の組合せほど、解候補として選択され やすくする.

従来の ACO アルゴリズムでは、フェロモン(評価が高い解 候補)と制約違反という情報を参考にして探索を行なう.本 研究ではこれらの情報に加え、"評価が低い解候補"の情報を 探索の参考にする ACO モデルを提案する.特に、評価が低 い解候補を、従来のフェロモンとは別のフェロモン(ネガティ ブフェロモンと呼ぶ)として蓄積させる ACO モデルを提案す る.更に本手法では、ネガティブフェロモンが多く溜まってい る値の組合せほど、通常のフェロモンの蓄積量を減少させる. これにより解候補が、評価が高い解候補へ誘引されつつ、評価 が低い解候補から遠ざけられ、より効率的な探索が行なわれる ことが期待される.

#### 2. 研究分野の概要

#### 2.1 グラフ彩色問題

グラフ彩色問題(COL)は制約充足問題に分類される問題 の1つである.COLは、無向グラフにおいて隣接する頂点同 士が同じ色に彩色されないような彩色パターンを探索によって 発見する問題である.特に、色数を3色とした問題は3COL と呼ばれ、アルゴリズムを評価するためのベンチマークとし てしばしば用いられる [Mizuno 11, Tayarani-N 15].ここで、 無向グラフの頂点数をn、辺数をcとした際、制約密度dをd = c/n と定義する.3COL において、 $d = 2,3 \sim 2.4$ の領域 は相転移領域と呼ばれ、難しい問題が集中していることがわ かっている [Hogg 96].

#### 2.2 蟻コロニー最適化

蟻コロニー最適化(ACO)は、蟻の採餌行動におけるフェ ロモンコミュニケーションをモデル化したメタヒューリスティ クスである [Dorigo 96, Dorigo 99]. 現実世界における蟻は餌 を見つけると、フェロモンを落としながら巣まで戻る. 蟻には このフェロモンに誘引される性質がある.フェロモンの経路は 蒸発や他の蟻による補強を繰り返し、徐々に経路の長さは短く なっていく.この過程から着想を得て、最適化問題の解法とし て提案されたものが ACO である.ACO をもとにしたアルゴ リズムは、多くの組合せ最適化問題をはじめ、3COL を含む多 くの CSP にも有効な手法であることがわかっている [Bui 08].

#### 2.3 cunning Ant System

ACO アルゴリズムの1つである cunning Ant System (cAS) [Tsutsui 06] のアルゴリズムを図1に示す. ACO アルゴリズ ムでは,1匹の蟻が1つの解候補を持つ. 複数の蟻が複数世代 にわたって解候補を生成していくことで,探索が進められてい く. 解候補生成の手順としては,まず値(COL における色) を割当てる変数(COL における無向グラフの頂点)をランダ ムに1つ選択する.次に選択された変数に対して,フェロモン と制約違反から決定される確率に基づいて,割当てる値を選択 する.以下に,解候補 A の変数  $x_j$  に割当てられる値として vが選択される確率  $p_A(< x_j, v >)$  を示す.

連絡先: 増金拓弥, 拓殖大学大学院工学研究科情報・デザイ ン工学専攻, 東京都八王子市館町 815-1, 042-665-0519, phsl.masukane@gmail.com



図 1: cAS のアルゴリズム

$$p_A(\langle x_j, v \rangle) = \frac{[\tau_A(\langle x_j, v \rangle)]^{\alpha} [\eta_A \langle x_j, v \rangle]^{\beta}}{\sum_{w \in D_j} [\tau_A(\langle x_j, w \rangle)]^{\alpha} [\eta_A(\langle x_j, w \rangle)]^{\beta}},$$
(1)

$$\tau_A(\langle x_j, v \rangle) = \sum_{\langle x_k, u \rangle \in A} \tau(\langle x_k, u \rangle, \langle x_j, v \rangle),$$
  
$$\eta_A(\langle x_j, v \rangle) = \frac{1}{1 + conf(\{\langle x_j, v \rangle\} \cup A) - conf(A)},$$

ただし,  $D_j$  は変数  $x_j$  に割当て可能な値の集合 (3COL の場 合は red, green, blue)を,  $\tau(< x_k, u >, < x_j, v >)$ は"値 uを割り当てた変数  $x_k$ "と"値 v を割り当てた変数  $x_j$ "間に溜 まっているフェロモンの量を, conf(A) は解候補 A の制約違 反数をそれぞれ表している.また,  $\alpha \ge \beta$  はそれぞれフェロ モンと制約違反を重視する重みを表している.これを,全ての 変数に値が割当てられるまで繰り返すことで,1つの解候補が 生成される.各蟻が解候補を生成した後,その集団内で最も評 価が高い解候補を用いて,フェロモングラフが更新される.以 下に $\tau(i, j)$ の更新式を示す.

$$\tau(i,j) = (1-\rho) \times \tau(i,j) + \Delta \tau$$

$$\Delta \tau = \begin{cases} \frac{1}{conf(A_{best})}, & (i,j) \in A_{best} \\ 0, & otherwise \end{cases}$$
(2)

ただし,ρはフェロモンの蒸発率,A<sub>best</sub>は集団内で最も評価 の高い解候補を表している.探索の過程で制約違反のない解候 補が発見されれば探索成功となる.逆に,指定した世代数で制 約違反のない解候補が発見できなければ探索失敗となる.

ACO アルゴリズムでは解候補を生成する際,全ての変数に 対して値を割当てるために確率を算出する.そのため,探索に 時間がかかってしまうという欠点が挙げられる.このような欠 点を改良するために提案された ACO アルゴリズムが cAS であ る. cAS では,解候補を生成する前に,前の世代の蟻(donor ant)から解候補の一部を"拝借"する蟻(cunning ant)を用 いる. 拝借された変数については確率計算が行なわれないた め, cAS は探索にかかる時間を短縮できる.

### 3. 提案手法

#### 3.1 基本方針

従来の ACO アルゴリズムは,制約違反とフェロモングラフ (評価が高い解候補の情報)をもとに探索を行なう.この2つ の情報に加え,他の情報を ACO に取り入れることで,ACO を用いた探索をより効率的なものにすることができるのでは ないかと考えた.そこで我々は,探索中に生成される"評価が 低い解候補"に着目した.解候補集団が評価が高い解候補に誘 引されるのと同時に,評価が低い解候補から遠ざかることで, 探索がより効率的に行なわれるということが期待される.

本研究では、従来の(評価が高い解候補を用いて更新され る)フェロモングラフに加えて、評価が低い解候補を用いて 更新されるフェロモングラフ(本研究ではこのフェロモングラ フを"ネガティブフェロモングラフ"と呼ぶ)を探索に用いる ACOモデルを提案する.本提案モデルの基本方針は以下の2 点である.

- 各変数に割当てる値を選択する際には、従来のACOモデルと同様に、制約違反と通常のフェロモングラフのみを参考にする。
- 通常のフェロモングラフを更新する際には、集団内で最 も評価が高い解候補だけでなく、ネガティブフェロモン グラフも参考にする。

#### 3.2 アルゴリズム

本研究では、2.3 節で述べた cAS に提案モデルを適用した アルゴリズムを提案アルゴリズムとし、ADUPT (Ant with DUal Pheromone Trails) と呼ぶ. ADUPT の手続きが図1に 示した cAS の手続きと異なる点は、"ネガティブフェロモング ラフの更新"と"通常のフェロモングラフの更新"である.

まず,ネガティブフェロモングラフの更新について説明する. 本研究で用いるネガティブフェロモングラフは,通常のフェロ モングラフと同じ構造である.また,ネガティブフェロモング ラフは集団内で最も評価が低い解候補に基づいて更新される. 以下にネガティブフェロモングラフの更新式を示す.

$$N\tau(i,j) = (1-\rho) \times N\tau(i,j) + \Delta N\tau$$
(3)  
$$\Delta N\tau = \begin{cases} conf(A_{worst}), & (i,j) \in A_{worst} \\ 0, & otherwise \end{cases}$$

ただし  $N\tau(i, j)$  は, (i, j) に溜まっているネガティブフェロモ ンの量を,  $A_{worst}$  は解候補集団内で最も評価の低い解候補を 表している.通常のフェロモングラフの更新(式2)と比較す ると,最も評価が低い解候補を用いることの他に,"フェロモ ンの蓄積量"が異なっている.従来のフェロモンの蓄積量が解 候補の制約違反数の逆数であったのに対して,ネガティブフェ ロモンの蓄積量は解候補の制約違反数そのものとする.これ は,評価が低い解候補情報を蓄積するためのネガティブフェロ モンにおいて,制約違反数が多い解候補ほど参考とする価値が 高いためである.

次に,通常のフェロモングラフの更新について説明する.従 来の ACO アルゴリズムでは,最も評価が高い解候補に含まれ る全ての値の組合せについて,フェロモンの蓄積量は一定で あった(式2).本研究では,ネガティブフェロモンが多く溜 まっている,つまり,低品質な割当てについて,通常のフェロ モンの蓄積量を小さくする.これにより,低品質な割当てが確 率的に生成されづらくなると考えられる.以下に通常のフェロ モンの更新式を示す.

$$\tau(i,j) = (1-\rho) \times \tau(i,j) + \Delta \tau$$

$$\Delta \tau = \begin{cases} \frac{1}{conf(A_{best})} \times w(i,j), & (i,j) \in A_{best} \\ 0, & otherwise \end{cases}$$
(4)

ここで, w(i, j) はネガティブフェロモン量  $N\tau(i, j)$  によって 決定される重み係数である.ただしw(i, j) の値は,対応する ネガティブフェロモンの量が上限値に近いほど0に近い値を とり,下限値に近ほど1に近い値をとるものとする.



図 2: 重み w(i, j) を決定するための関数

### 4. 評価実験

#### 4.1 実験条件

提案アルゴリズムである ADUPT の有効性を示すために, 評価実験を行なった. ここでは, ADUPT と従来手法である cAS を比較する.本実験では頂点数 n = 100 である 3COL イ ンスタンスを,制約密度  $d = 2.0 \sim 3.0$  の範囲で 0.1 毎に 11 のケースに対して,それぞれランダムに 100 問生成した.こ こで生成した問題は全て解が存在する.生成した各問題につい て,それぞれ 5 回ずつ試行を行なった.本実験のパラメータ は,蟻の数を 100,蟻の最大世代数を 2000,フェロモンの重 み  $\alpha = 5.0$ ,制約違反の重み  $\beta = 10.0$ ,フェロモンの蒸発率  $\rho = 0.01$  とした.また,w(i,j)を決定するために,図 2 に示す 4 パターンの関数を用いる.それぞれの関数を用いた ADUPT をそれぞれ,ADUPT0 ~ ADUPT3 とする.これらの手法に ついて,以下の 2 点を比較した.

- 探索成功率:全体の試行数に占める制約充足解を発見で きた試行数
- 探索コスト:制約充足解を発見するまでに生成した解候 補の数

なお,実験には PC/AT 互換機 (CPU: Intel Core i7 880 3.07GHz, RAM: 4GByte) を使用し,プログラムはすべて Java 言語で記述した.

#### 4.2 実験結果

実験の結果を図 3 と図 4 に示す. 図 3 は各手法の探索成功 率をインスタンスの制約密度ごとに示したものである. 図 3 から,提案手法である ADUPT0 の探索成功率は,従来手法 である cAS の探索成功率と比較すると,差が小さい.一方で, ADUPT1, ADUPT2, ADUPT3 の探索成功率は, cAS より も高くなっている.また,その探索成功率の差は,制約密度が 相転移領域 ( $d = 2.3 \sim 2.4$ ) に近づくにつれて大きくなってい る.特に,d = 2.3 のインスタンスについては,探索成功率の 差が約 30% であり,最大となっている.

次に,図4は全ての試行における探索コストの平均を示している.ただし,探索に失敗した(制約充足解を発見できなかった)試行については,蟻の数×世代数=200,000の解候補を生成しているため,探索コストは200,000とした.図4よ



図 3: 各制約密度における探索成功率





り, ADUPT0 の探索コストは cAS とほとんど差がない. ま た, ADUPT1, ADUPT2, ADUPT3 は, cAS よりも小さい 探索コストで解を発見できている. この探索コストの差は, 相 転移領域に近づくにつれて大きくなっている. 特に, *d* = 2.3 のインスタンスについては, ADUPT1, ADUPT2, ADUPT3 は cAS の約半分の探索コストで解を発見できている. ここで, 今回の結果では, 探索に失敗した試行における探索コストを 200,000 としたが, 実際は 200,000 のコストをかけても解を発 見できていない. つまり, 解が見つかるまで探索を続けると, 探索のコストの差は更に広がっていくと思われる.

#### 4.3 考察

4.2 節より, ADUPT1, ADUPT2, ADUPT3 の 3 つの手法 は, cAS よりも高い探索成功率を得られた. 一方で, ADUPT0 は探索成功率と探索コストのどちらについても, cAS とほと んど差がなかった.本節ではこの実験結果について考察する. 提案モデルでは, 従来の ACO アルゴリズムにおけるフェロモ ンの蓄積量に変化を与えるものである.そのため,ここでは" フェロモンの溜まり方"に着目する.

図5は,探索に成功した1つの試行について調査したもの である.縦軸はその試行で発見できた解の割当てに対応する



図 6: 解に対応するネガティブフェロモン量の割合の推移

フェロモンの量が,全ての割当てに対応するフェロモンの量に 占める割合を,横軸は世代数を表している.図5から,cAS と ADUPT0 はおよそ90世代まで,解に対応するフェロモン の割合にほとんど変化が見られない.このことから,cAS と ADUPT0 についての実験結果がほとんど同じものとなった のは,cAS と ADUPT0 のフェロモンの溜まり方が似ている ためではないかと考えられる.一方で,ADUPT1,ADUPT2, ADUPT3 は,解に対応するフェロモンの割合が徐々に増加して いることがわかる.つまり,ADUPT1,ADUPT2,ADUPT3 は,後に発見される解に近い解候補が生成されやすくなってい く.このことが,探索成功率の大きな向上につながっているの ではないかと考えられる.

図6は、図5と同じ試行について調査したものである.た だし、縦軸はその試行で発見できた解の割当てに対応する" ネガティブフェロモン"の量が、全ての割当てに対応するネガ ティブフェロモンの量に占める割合である.前述した通り、ネ ガティブフェロモンは集団内で最も評価が低い解候補に基づい て更新される.そのため、解に対応するネガティブフェロモン 量の割合が上昇しているということは、最も評価が低い解候補 が、後に発見される解に対応する割当てを多く含んでいるとい うことであると思われる. つまり,集団内の解候補全体が,解 に近づいていると考えられる. 解に対応するネガティブフェロ モン量の割合について,ADUPT0 がおよそ 90 世代までほと んど変化がないのに対して,ADUPT1,ADUPT2,ADUPT3 は徐々に上昇している. この結果から,ADUPT1,ADUPT2, ADUPT3 は集団全体が解に近づいていると思われる. 結果と して,ADUPT1,ADUPT2,ADUPT3 は解をより発見しやす くなっているのではないかと考えられる.

#### 5. おわりに

本研究では、大規模な CSP を効率よく解くための手法とし て、複数種類のフェロモンを用いる ACO モデルを提案した. 本モデルは、従来の ACO アルゴリズムで用いられるフェロモ ンを更新する際に、解候補集団内で最も評価が低い解候補に 基づいて更新される新たなフェロモンを用いるものである.提 案モデルを cAS という ACO アルゴリズムに適用し、単一の フェロモンのみを用いる cAS と実験的に比較を行なった.実 験の結果から、提案モデルの有効性を示した.今後の課題とし て、他のメタヒューリスティクスとの比較や、他の CSP への 適用が挙げられる.

- [Bui 08] Bui, T. N., Nguyen, T. H., Petal, C. M. and Phan, K. T.: An ant-based algorithm for coloring graphs, Discrete Applied Mathematics, Vol. 156, pp. 190–200 (2008).
- [Dorigo 96] Dorigo, M., et. al.: The Ant System: Optimization by a Colony of Cooperating Agents, *IEEE Transaction on Systems, Man, and Cybernetics - Part B*, Vol. 26, pp. 26–41 (1996).
- [Dorigo 99] Dorigo, M. and Di Caro, G.: The Ant Colony Optimization Meta-Heuristics, New Ideas in Optimization, pp. 11–32 (1999).
- [Hogg 96] Hogg, T., Huberman, B. A. and Williams, C. P.: Phase transition and search problem, Artificial Intelligence, Vol. 81, pp. 1–16 (1996).
- [Mizuno 11] Mizuno, K., Hayakawa, D., Sasaki, H., and Nishihara, S.: Solving Constraint Satisfaction Problems by ACO with Cunning Ants, *The 2011 Conf. on Technologies and Applications of Artificial Intelligence* (*TAAI2011*) (2011).
- [Tayarani-N 15] Tayarani-N, M. H. and Prugel-Bennett, A.: Anatomy of the fitness landscape for dense graphcolouring problem, Swarm and Evolutionary Computation, Vol. 22, pp. 47–65 (2015).
- [Tsutsui 06] Tsutsui, S.: cAS: Ant Colony Optimization with Cunning Ants, Proc. of the 9th Int. Conf. on Parallel Problem Solving from Nature (PPSN IX), pp. 162–171 (2006).

# クラスタリング手法を用いた TSP の解法 An Algorithm for solving the Traveling Salesman Problem using Clustering Method

内田 純平<sup>\*1</sup> Jumpei Uchida 穴田 一\*1 Hajime Anada

\*1 東京都市大学 Tokyo City University#1

Many economic and industrial problems lead to combinatorial optimization problems. Of these combinatorial optimization problems, the traveling salesman problem (TSP) is one of the most important problem in the field of technology and science. Therefore, we construct a new algorithm for the TSP using a new clustering method. We confirmed the effectiveness of our algorithm using several benchmark problems taken from the TSPLIB, which is a library of traveling salesman problem.

# 1. はじめに

工業や経済の問題の多くは、最も効率が良い組み合わせを 求める組み合わせ最適化問題に帰着することができる。その中 に、与えられた全ての都市を巡る最短経路を求める巡回セール スマン問題(Traveling Salesman Problem, TSP)がある。

本研究では、TSP に適した新しいクラスタリングのアルゴリズム である Clustering in clusters(以下 CIC)を提案し、CIC によって構 成したクラスタに対して NN 法と 2-opt 法、Or-opt 法を用いること により、経路生成を行うアルゴリズムを構築した。そして、TSPLIB に掲載されているベンチマーク問題を用いて提案手法の評価 実験を行い、その有効性を確認した。

# 2. 既存研究

#### 2.1 Or-opt 法

Or-opt法は巡回経路上の連続したn個のノードを切り出し,それを他の位置に挿入する改善手法である.

Or-opt 法のアルゴリズムは以下の通りである

- 都市の選択 経路上の他の位置に挿入する連続した n 個のノードを 選択する.
- ② 都市の挿入 ①で選択されたノードを他のノード間に挿入し、つなぎ 替えた時の総経路長が、元の総経路長より短くなる時に そのノードの挿入を行う。

①,②を改善が見られなくなるまで繰り返す.

#### 2.2 二次元凸包

二次元の点の集合があたえられたとき、その各点にまっすぐ 釘を打ち付け、周りに輪ゴムをかけ手を放すと、ゴムは多角形に なる.このゴムに囲われた領域がこの点集合の二次元凸包であ る.また、集合に属するすべての点は凸包の内側に存在する.

二次元凸包を求めるアルゴリズムは以下の通りである。 ① 初期点の決定

連絡先:內田純平,東京都市大学,〒158-8557 東京都世田谷区玉堤 1-28-1 二次元座標上の x 軸と, 原点から各点へのベクトルのなす 角が最も小さい点を始点とし, 原点から始点へのベクトル を基準ベクトルとする.

② 次点の決定 始点から他の点へのベクトルと基準ベクトルのなす角 を求め、なす角が最も小さい点を次の始点とし、1つ 前の始点からこの始点へのベクトルを基準ベクトルと する。

②における次点が①で決定した初期点になるまで繰り返す.

#### 3. 提案手法

#### 3.1 Clustering in Clusters (CIC)

提案手法である CIC とは、クラスタリングによって生成されたクラ スタの中で、クラスタリングをするアルゴリズムである. CIC のアル ゴリズムは以下の通りである.

- I. クラスタリング i
  - 初期設定

与えられた問題を第一象限に移動し、二次元凸包を用いて、与えられた問題の凸包を作る.原点に最も近い凸包に含まれるノードを第1初期点(以下点 a)とし、aから最も遠い凸包に含まれるノードを第2初期点(以下点 b)とする。また、与えられた問題の y 座標の最大点(以下 Max(y))を求め、座標(0,Max(y))に最も近い凸包に含まれるノードを第3初期点(以下点 c)とし、cから最も遠い凸包に含まれるノードを第4初期点(以下点 d)とする.

なお, a, b, c, d 四ヶ所の始点から独立に次の②, ③, ④を行うものとする.

- 2 初期距離の決定 始点から最も近いノードを選び次の始点とする.また、ノード間の距離を基準距離Dとする.なお、距離の計算にはユークリッド距離を用いる.
- ③ クラスタリング

始点から基準距離 D 以下の距離を持つノード全 てと始点でクラスタを生成する.なお, a, b, c, d での 1 個目のクラスタ生成が終了後, それぞれ基準距離 D の範囲内にノードが存在しないときは全クラスタの重 心を求め,最も近い重心のクラスタに入れるという手 続きを加える.

④ 始点と基準距離の更新 クラスタリングされていないノードの中で最 も始点に近いノードを次の始点とし、それらの ノード間の距離Lとする.そして、基準距離の更 新を次式で定義する.

$$D = \frac{D+L}{2} \tag{1}$$

全ノードについてクラスタリングが終わるまで③と④を繰り返す.

- II. クラスタリング ii
  - 初期設定
     各クラスタ内の最大ノード数 MN を次式で定義する.

$$MN = [AN \times 0.05] + 1$$
(2)

ここで、ANは全ノード数を表す.また、クラスタリング iで生成されたクラスタをクラスタ内のノード数の降 順に並び替え、この順番で②から行う.

- ② 始点の決定 クラスタの重心に最も近いノードを始点とする.また,重心から始点までの距離をd<sub>12</sub>とする.
- ③ 初期基準距離の決定 始点から最も近いノードを次の始点とし、その間の 距離をd<sub>2,3</sub>としてd<sub>1,2</sub>との平均を基準距離SD<sub>1</sub>とする。
   ④ 初期クラスタリング

始点から基準距離SD<sub>1</sub>以下の距離を持つノードを 選択し,選択されたノードと始点でクラスタを生成す る.基準距離SD<sub>1</sub>以下の距離を持つノードが存在し ないときは,始点だけでクラスタを生成し,その始点か ら最も近いクラスタリングされていないノードを次の 始点とする.そして新しい始点での距離をd<sub>3,4</sub>として d<sub>12</sub>, d<sub>23</sub>との平均を基準距離SD<sub>2</sub>とする.

- ⑤ クラスタリング 始点から基準距離SD<sub>i</sub>(i ≥ 2)以下の距離を持つ ノードを選択し,選択されたノードと始点でクラスタを 生成する.基準距離SD<sub>i</sub>以下の距離を持つノードが 存在しないとき、始点だけでクラスタを生成し、その始 点から最も近いクラスタリングされていないノードを 次の始点とする.この時、元の始点をi,次の始点を i+1 としたノード間の距離をd<sub>i,i+1</sub>とする.
- ⑥ 基準距離 SD の更新 初期クラスタリング後の基準距離には、次式で定 義される更新式で随時更新された基準距離SD<sub>i</sub>を使 用する。

$$SD_i = \frac{\sum_{k=1}^{i+2} d_{k,k+1}}{i+1}$$
 (3)

全ノードに対して ⑤, ⑥を繰り返す.

III. クラスタリング ⅲ

初期設定

クラスタリング ii で生成されたクラスタをクラスタ内 のノード数が2以上のクラスタのリスト(以下 clst2)とノ ード数が1つのクラスタのリスト(以下 clst1)に分ける.

- ② 並び替え clst2内のクラスタをノード数の昇順に並び替える.
   ③ 基準距離の設定
  - 基準距離の設定 clst2内のクラスタを昇順に1つ選び,選ばれたクラ スタ内でのノード間の最短距離を求める.求められた ノード間の最短距離をそのクラスタの基準距離とす る.これを clst2内のクラスタ全てに行う.
- ④ クラスタリング clst2 内のクラスタを昇順に1 つ選び, 選ばれたク ラスタ内のノードを無作為に1 つ選ぶ, そのノードと 他のクラスタのノードとの距離が基準距離以下のとき, そのノードを選ばれたクラスタに入れる. クラスタのノ ード数が最大ノード数に達するか, クラスタ内の全て のノードから探索を終えたら, まだ選ばれていない次 のノードについて同様の手続きを行う.

clst2内の全てのクラスタに対して③,④を繰り返す.

- IV. クラスタリング iv
  - 初期設定 クラスタリング iii によってクラスタリングされた clst1と clst2を用いる。
  - ② 基準距離の設定 clst2内の各クラスタの重心からクラスタ内の各ノードまでの距離を求め、平均値の1.5倍を基準距離とする.
  - ③ クラスタの分解 clst2 内のクラスタで、クラスタの重心とクラスタ内の 各ノードとの距離の平均が②で決められた基準距離 以上であるクラスタについて、そのクラスタ内で、クラス タの重心に一番近いクラスタ内のノードから一番離れ ているクラスタ内のノードをそのクラスタから外し、clst1 に入れる。
  - ④ クラスタリング
     ②を行い基準距離の再設定をする. clst1 のノードにおいて、ノードを二つ選びノード間の距離が基準距離以下であれば1つのクラスタとして clst2 に入れる. これを clst1 内の全ノードに行う.
- V. クラスタリング v
  - ① 初期設定 クラスタリング iv によってクラスタリングされた clst1と clst2 を用いる.
  - ② 基準距離の設定 clst2 内のクラスタを1つ選ぶ.また,選ばれたクラ スタ内において,そのクラスタの重心に最も近いその クラスタのノードを選び,選ばれたノードと最も離れて いるクラスタ内のノードとの距離を選ばれたクラスタの 基準距離とする.また,clst2 内のクラスタ全てに行う.
  - ③ 候補の作成 clst2 内のクラスタを1つ選び, c2とする.また, clst1 のノードを順に1つ選び, c1とする.c2 内の重心を始 点とし,重心と c1の距離が c2の基準距離の1.5 倍以 下であるならば c1をリスト stock(以下 stock)に保存す

る.1 つの c2 が選ぶ c1 の数の上限 SN を次式で定義 する.

$$SN = MN + 1 - NN \tag{4}$$

ここで、MNは最大ノード数(式(2))、NNはc2内のノード数を表か、clst1内の全ノードとの比較が終了するか、c2の選んだc1の数がSNに達したとき、clst2内のまだ選ばれていない次のクラスタをc2とする.これをclst2内で選ばれていないクラスタがなくなるまで行う.
 クラスタリング

stock 内の ノードを1つ選ぶ. 選ばれたクラスタの重 心と最も近い重心を持つ clst2 内のクラスタに選ばれ たノードを入れる. なお、この時のクラスタの最大ノード 数は(2)式の最大ノード数に 1 を加えたものであり、こ れを満たさない場合は、そのクラスタを除いた、他の clst2 内のクラスタで探す. このクラスタリングを stock 内

④が終了したとき、②を行い各クラスタの基準距離 を測定し、各クラスタの基準距離の平均に1.5倍したも のを次に使う基準距離とする.そして、clst1のノードを2 つ選び、それらのノード間の距離が基準距離以下であれ ば1つのクラスタとして clst2 に入れる.その後、②、③、④を 行い終了.

#### 3.2 解の構築方法

解構築に使用した手法は、与えられた問題を CIC によってク ラスタリングした後の各クラスタの重心で疑似的な最短経路を生 成すると、与えられた問題で生成した経路の厳密解と疑似経路 が似通う事を利用したアルゴリズムである.

本手法のアルゴリズムは以下の通りである.

のクラスタ全てに行う.

- ① クラスタリング
- CIC(3.1)を用いてクラスタリングを行う.
- ② 疑似経路作成

生成されたクラスタの重心をノードとみて,重心を結ぶ 経路を NN 法と, 20pt 法, n=1 の Or-opt 法(2.1)の順で用 いて最短経路になるように作成する.

③ 経路生成準備

クラスタを無作為に1つ選ぶ,選ばれたクラスタの重心から最も近いノードを,疑似経路上で次の経路の重心を持つクラスタ内のノードから選ぶ.これを②で生成された疑似経路をもとに一周するまで繰り返す.

④ 経路生成

③においてランダムに選ばれたクラスタを $r_n$ とすると、② の疑似経路における $r_{n-1}$ の時に③で選ばれた $r_n$ のノード を始点、 $r_n$ の時に選んだ $r_{n+1}$ のノードを終点とする。そして、 始点のノードから $r_n$ の始点以外のノードを通り終点までの 経路を NN 法、20pt 法、n=1 の Or-opt 法(2.1)の順で用い て最短経路になるように作成し、随時繋げていく。

生成された経路に対して 2opt 法, n=1 の Or-opt 法(2.1)を最 後に行い終了する.

#### 4. 結果

提案手法の有効性を確認するため、TSPLIB に掲載されている TSP のベンチマーク問題である eil51, kroa100, kroc100, kroa150を用いて評価実験を行った.

表 1:eil51 の 100 試行の結果

| eil51(最適解 426) | 提案     |  |
|----------------|--------|--|
| 平均誤差率(%)       | 2.6126 |  |
| 誤差率の標準偏差       | 0.6207 |  |
| 平均時間(秒)        | 1.28   |  |

| kroa100(最適解 21282) | 提案     |
|--------------------|--------|
| 平均誤差率(%)           | 1.8286 |
| 誤差率の標準偏差           | 0.7378 |
| 平均時間(秒)            | 5.36   |

#### 表 3:kroc100 の 100 試行の結果

| kroc100(最適解 20749) | 提案     |
|--------------------|--------|
| 平均誤差率(%)           | 1.4653 |
| 誤差率の標準偏差           | 0.6018 |
| 平均時間(秒)            | 4.10   |

表 4:kroa150 の 100 試行の結果

| kroa150(最適解 26524) | 提案     |
|--------------------|--------|
| 平均誤差率(%)           | 2.0923 |
| 誤差率の標準偏差           | 0.4178 |
| 平均時間(秒)            | 19.06  |

実験の結果,まだまだ十分な性能とは言えない.

### 5. 今後の課題

今後の課題として、クラスタリングの精度を上げることが挙げられる.提案アルゴリズムの性質上、各クラスタの重心の位置への 依存性が高く、重心による疑似経路が厳密解と大きく離れている と、厳密解と大きく離れてしまう欠点がある.また、(2)式より明らか だが、クラスタ内の最大ノード数は全ノード数に大きく依存してい るので、都市数の大きな問題をクラスタリングするとクラスタ1つ 当たりのノード数が大きくなってしまい、厳密解に似通った疑似 経路の作成が難しくなるという欠点もある.そこで、クラスタ内のノ ード数を小さくしたクラスタリングを行い、出来たクラスタ以下を新 しいノードとみてクラスタリングを行い、出来たクラスタ以下を新 しいノードとみてクラスタリングを行うことを一定のクラスタ数にな るまで再帰的に行い、解の構築(3.2)を生成されたクラスタの重 心に行うことを、クラスタリングした回数階層的に繰り返して元の 都市数に戻すことで、現在の提案手法よりも最適解に到達しや すく、より大きな都市数の問題を解けるアルゴリズムにしたいと考 えている.

# 粒子群最適化を用いた巡回セールスマン問題の解法

# An Algorithm for Solving the Traveling Salesman Problem using Particle Swarm Optimization

山田 悠希<sup>\*1</sup> 穴田 一<sup>\*1</sup> Yuki Yamada 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

Many economic and industrial problems lead to combinatorial optimization problems. Of these combinatorial optimization problems, the traveling salesman problem (TSP) is one of the most important problem in the field of technology and science. And particle swarm optimization (PSO) is a population based stochastic optimization technique inspired by social behavior of bird flocking or fish schooling. PSO has been applied to various combinatorial optimization problems belonging to nondeterministic polynomial-time hard (NP-hard) combinational problems. But applying PSO to TSP is difficult. Therefore, we construct a new algorithm which is based on PSO. We confirmed the effectiveness of our algorithm using several benchmark problems taken from the TSPLIB, which is a library of traveling salesman problem.

### 1. はじめに

工業や経済の問題の多くは、最も効率が良い組み合わせを 求める、組み合わせ最適化問題に帰着することができる。その 中に、与えられた全ての都市を巡る最短経路を求める巡回セー ルスマン問題 (Traveling Salesman Problem, TSP) がある。本庄ら は、最適化問題に用いられるアルゴリズムの一つである粒子群 最適化(Particle Swarm Optimization, PSO) [Kennedy 95]を TSP 向けに改良した挿入操作 PSO 戦略 (Insertion-based PSO strategy, IPSO) [本庄 16]を提案した。IPSO は、解空間上に配 置された各粒子がそれまでの最良解と、近傍の粒子の最良解 の情報を基に、解の更新を繰り返すことで解空間の探索を行う アルゴリズムである。しかし、この IPSO には探索が十分に行わ れないうちに、局所解に陥ってしまうという問題点がある。

そこで本研究では、既存手法で用いられた各粒子のそれま での最良解と近傍の粒子の最良解の情報に加え、解空間上で 最も遠い粒子の解の情報を現在の解に重ね合わせた解の集合 を用いて、解の更新を行うアルゴリズムを構築した.そして、 TSPLIB に掲載されているベンチマーク問題を用いて既存手法 と提案手法を比較することで、その有効性を確認した.

#### 2. 既存研究

# 2.1 粒子群最適化

粒子群最適化(Particle Swarm Optimization, PSO)とは、魚や 鳥などに見られる群れ行動を探索手法に応用した、最適化手 法の一つである. 解空間上に位置と速度を持った複数の個体 (以下、粒子と表記)をランダムに配置する. 各粒子の位置は問 題の解を表現しており、評価の高い粒子の情報を近傍の粒子 から入手し、その情報を基により良い位置に近づくように速度と 位置を更新する. PSO はこの操作を繰り返すことで解空間を探 索するアルゴリズムである. t イテレーション目における粒子 i の 位置 $x_i(t)$ と速度 $v_i(t)$ の更新式は次式で定義される.

$$x_i(t) = x_i(t-1) + v_i(t-1)$$
(1)

$$v_{i}(t) = wv_{i}(t-1) + c_{1}r_{1}(pbest_{i} - x_{i}(t)) + c_{2}r_{2}(lbest_{i} - x_{i}(t))$$
(2)

ここで, w はパラメータ,  $c_1 \ge c_2$ は[0,1]のパラメータ,  $r_1 \ge r_2$ は [0,1]の一様乱数, pbest<sub>i</sub>は粒子 i のそれまでの最良解, lbest<sub>i</sub> は粒子 i の近傍内のそれまでの最良解である. アルゴリズムの 流れの詳細は以下の通りである.

#### ①初期設定

全粒子の位置と速度をランダムに設定し、各粒子 i のpbest<sub>i</sub> を現在位置に設定する.次に、設定した近傍数 k を元に、各粒 子 i と距離が近い k 個の粒子を粒子 i の近傍に設定する.そし て、各粒子 i の近傍内で適応度が最も高い解を近傍内の最良 解lbest<sub>i</sub>と設定し、全粒子の中で適応度が最も高い解をgbest と設定する.

②位置の更新

(1), (2)式に従い, 各粒子の位置の更新を行う.

③適応度の評価

全粒子の適応度の評価を行う.適応度は問題に適した粒子 ほど高くなるよう,評価関数を事前に設定しておく.

④pbest<sub>i</sub>とgbestの更新

全粒子の pbest, lbest と gbestを更新する.

⑤速度の更新

(1), (2)式に従い, 各粒子の速度の更新を行う.

初期設定を①で行い、②から⑤までの操作を1イテレーションとし、事前に設定したイテレーション数を満たすまで繰り返すことで解空間を探索する.

連絡先:山田悠希,東京都市大学,〒158-8557 東京都世田谷区玉堤 1-28-1

#### 2.2 挿入操作 PSO 戦略

本庄らが提案した IPSOは, PSOに基づき TSP の解空間の探 索を行うアルゴリズムである.まず, 解空間上に複数の粒子を配 置する.これらの粒子は, それぞれ巡回路である解を持っており, 各粒子のそれまでの最良解と近傍の粒子の最良解から抽出し た部分経路を, 各粒子の現在の解に挿入することで解の更新を 行い, これを繰り返すことで, 解空間を探索する. アルゴリズム の流れは以下の通りである.

①初期設定

各粒子iに解 $x_i$ をランダムに設定し、各粒子のそれまでの最 良解 $pbest_i$ を現在の解 $x_i$ に設定する. 粒子iと粒子j間の距 離 $d_{ij}$ を以下のように定義し、全粒子間の距離を計算する.

| $d_{ij} = \frac{1}{S_{ij}}$                    | (3) |
|--|-----|
| $S_{ij} = \frac{\left E_i \cap E_j\right }{n}$ |     |

ここで、 $E_i$ は粒子iが持つ解 $x_i$ の経路の集合, $|E_i \cap E_j|$ は $E_i$ と $E_j$ の共通している経路の本数、nは都市数を表している。距 離 $d_{ij}$ は $x_i \ge x_j$ の共通の経路が多くなるほど短くなる。次に、 設定した近傍数kを元に、粒子iと距離が近いk個の粒子を 粒子iの近傍に設定する。各粒子iの近傍の中で総経路長が 最も短い解を近傍内の最良解 $lbest_i$ と設定し、全粒子の中で 最も総経路長が短い解を全粒子の最良解gbestと設定する。 ②解の更新

解 $x_i$ は pbest<sub>i</sub>の部分経路である pbest<sub>i</sub>'と lbest<sub>i</sub>の部分経路である lbest<sub>i</sub>'を総経路長が最も短くなるように挿入することで更新される. 粒子 i の解の更新の詳細は以下の通りである. また、9 都市の TSP の解の更新の例を図 1 に示す.図1 の例の $x_i = (1,4,7,5,6,9,8,3,2)$ は都市 1→都市 4→…→都市 3→都市 2 と都市を巡り、都市 1 に戻る巡回路を表している.

I 部分経路の作成

粒子  $i \circ pbest_i$ から, p本の連続する経路をランダムに 抜き出し, 部分経路  $pbest_i'$ とする. また, 粒子  $i \circ o$  $lbest_i$ から, l本の連続する経路をランダムに抜き出し, 部分経路  $lbest_i'$ とする.  $p \ge l$ は以下の式で表される.

| $p = [c_1 r_1 (n+1)]$ | (4) |
|-----------------------|-----|
|-----------------------|-----|

 $l = [c_2 r_2 (n+1)]$ (5)

ここで  $c_1 \ge c_2$  は [0,1] を満たすパラメータ,  $r_1 \ge r_2$  は [0,1] を満たす一様乱数, n は都市数である.  $[c_1r_1(n + 1)]$  は  $c_1r_1(n + 1)$  の整数部分を表している. 図 1 の例で は pbest<sub>i</sub>' = (5,4,8,7) と lbest<sub>i</sub>' = (8,9,6)を抜き出している.

II pbest'の再形成

pbest<sub>i</sub>'とbbest<sub>i</sub>'に共通した都市が含まれていれば, pbest<sub>i</sub>'から該当した都市を削除し,残った都市で総経路 長が最も短くなるよう部分経路を再形成する.図1の例で は都市8が共通しているため, pbest<sub>i</sub>' = (5,4,8,7)から都 市8 が共通しているため, pbest<sub>i</sub>' = (5,4,7)を再形成している.

Ⅲ *x<sub>i</sub>′*の形成

 $x_i$ から  $pbest'_i$ ,  $lbest_i'$ と共通する都市を削除し, 残った 都市で総経路長が最も短くなるよう巡回路を再形成し,  $x_i'$ とする. 図 1 の例では,  $pbest_i'$ と  $lbest_i'$ にある都市 4,5,6,7,8,9 を $x_i$ から削除し,  $x'_i = (1,3,2)$ としている. IV  $pbest_i'$ の挿入

 $pbest_i'をx_i'に総経路長が最も短くなるよう挿入する.$ 

図1の例では都市1と都市3の間に *pbest<sub>i</sub>* 'を挿入して いる.

#### V lbest<sub>i</sub>'の挿入

*lbest<sub>i</sub>*'を*x<sub>i</sub>*' に総経路長が最も短くなるよう挿入する. 図 1の例では都市5と都市3の間に*lbest<sub>i</sub>*'を挿入している. 以上の I ~V の操作を全粒子で行う.



③総経路長の計算

全粒子が持つ巡回路の総経路長の計算を行う.

④近傍の更新 全粒子間の距離を再計算し、近傍を更新する。

⑤ pbest, lbest, gbest の更新
 全粒子の pbest, lbest と gbestを更新する.

初期設定を①で行い、②から⑤までの操作を 1 イテレーショ ンとし、事前に設定したイテレーション数繰り返すことで TSP の 解空間を探索する.

### 2.3 既存手法の問題点

既存手法において、解xの更新は各粒子の今までの最良解 pbestと近傍の最良解 lbest を用いて行われる. 近傍数が 2 で ある場合, 近くにいる 2 粒子のうち良い粒子の解がlbestとなる ため, それぞれの粒子が参照できる粒子の情報が少ない. これ では, 離れた粒子との組み合わせを試さないうちに探索が終了 してしまい, 全粒子の初期解の周辺を探索する多点探索とは言 えない.

#### 3. 提案手法

提案手法における解の更新は、各粒子iのそれまでの最良 解 $pbest_i$ ,近傍の粒子の解である $lbest_i$ ,最遠の粒子の解であ る $x_i^f$ を現在の解 $x_i$ に重ね合わせた経路集合Gを用いて行わ れる. まず, ある都市 iをランダムに選択する. そして G に含まれる経路から, 次式で定義される確率 $P_{ij}$ で次の経路 ijを選択する.

$$P_{ij} = \frac{w_{ij}}{\sum_{l=1}^{n} w_{il}} \tag{6}$$

$$w_{ij} = \frac{C}{\left(d_{ij}\right)^{D}}$$

 $C = C_1 + C_2 + C_3 + C_4$ 

 $C_1 = \begin{cases} c_1 & x_i に含まれる場合 \\ 0 & otherwise \end{cases}$ 

 $C_{2} = \begin{cases} c_{2} & pbest_{i}$ に含まれる場合 0 & otherwise  $C_{3} = \begin{cases} c_{3} & lbest_{i}$ に含まれる場合

$$C_4 = \begin{cases} c_4 & x_i^f に含まれる場合 \\ 0 & otherwise \end{cases}$$

ここで、nは都市数、 $D, c_1 \sim c_4$  はパラメータを表している. (6) 式は G に含まれる経路のうち、距離が短く、複数の解に含まれ る経路を選択しやすくなるように設定している.また、この経路 集合 G のパラメータは、それぞれの粒子が自分の解の周辺を 探索するため、 $c_1$ が最も高くなるように設定している.G に選択 できる経路が存在しない場合、未訪問都市の経路の中から距 離情報を用いたルーレット選択を用いて経路を選択する.この 操作を繰り返すことで巡回路を構築していく.

# 4. 結果

提案手法の有効性を確認するため、TSPLIB に掲載されている TSP のベンチマーク問題である rd100, kroA150, pr299 を用いて評価実験を行った. 既存手法は実際にアルゴリズムを再現し、事前実験で最も結果が良かった粒子数m = 64, 近傍数 $k = 2, c_1 = 0.9, c_2 = 0.1$ というパラメータを使用した.また,提案手法における $c_1, c_2, c_3, c_4$ もまた、事前実験で最も結果が良かった $c_1 = 0.6, c_2 = 0.2, c_3 = 0.1, c_4 = 0.1$ を使用した.終了条件は rd100 と kroA150 は 30000 イテレーション, pr299 は 500000 イテレーションとした.各問題 50 試行平均の結果を表 1 ~3 に示す.また,表中で用いられている誤差率は,試行内で得られた最良解の厳密解に対する誤差の割合を表し、最終更新イテレーションは最後にgbestを更新したイテレーションを表している.

| rd100(厳密解 7910)          | 既存     | 提案       |  |  |  |  |
|--------------------------|--------|----------|--|--|--|--|
| 厳密解到達率(%)                | 88     | 98       |  |  |  |  |
| 平均誤差率(%)                 | 0.0099 | 0.0002   |  |  |  |  |
| 平均最終更新<br>イテレーション        | 3210.4 | 15565.66 |  |  |  |  |
| 素 2:kro A 150 の 50 封行の結果 |        |          |  |  |  |  |

表 1:rd100の 50 試行の結果

| 专 | 2:1 | kro/ | A150 | 0) | 50 | 試行 | 丁() | ン結 | ī果 |
|---|-----|------|------|----|----|----|-----|----|----|
|   |     |      |      |    |    |    |     |    |    |

| kroA150(厳密解 26524) | 既存     | 提案       |
|--------------------|--------|----------|
| 厳密解到達率(%)          | 10     | 20       |
| 平均誤差率(%)           | 0.25   | 0.18     |
| 平均最終更新<br>イテレーション  | 6951.2 | 27379.68 |

| 表 | 3 | : pr299    | $\mathcal{O}$ | 50  | 試行      | の結果       |
|---|---|------------|---------------|-----|---------|-----------|
|   | ~ | · pi = / / |               | ~ ~ | H. AL J | /I'H /I'S |

| <u> </u>         |          |          |
|------------------|----------|----------|
| pr299(厳密解 48191) | 既存       | 提案       |
| 厳密解到達率(%)        | 0        | 2        |
| 平均誤差率(%)         | 0.91     | 0.29     |
| 平均最終更新           | 254626.8 | 377088.3 |

実験の結果,全ての問題において,既存手法よりも提案手法の 精度が上回ったことが分かる.しかし,平均最終更新イテレーションは提案手法の方が軒並み長くなっている.これは,提案手 法の方が既存手法よりも広範囲で解を探索いるため,解の収束 が遅くなっていることが理由であると考えられる.

# 5. 今後の課題

今後の課題として,解の更新の見直しをする必要があること が挙げられる.提案手法を用いて pr299の厳密解カバー率の計 算を 50 試行行い,その平均の推移を図 2 に示す.厳密解カバ ー率とは,全粒子の経路を合わせて厳密解の経路をどれだけ 保持しているかを割合で表したものである.



図 2:提案手法における pr299 の厳密解カバー率

図2より,2000イテレーションほどで厳密解カバー率が100%に なり,その後も100%を維持していることが分かる.厳密解の経 路を全て保持しているにも関わらず,厳密解に収束しないという ことは,解の探索範囲は拡大し,全粒子が多様な経路を保持し ているものの,その組み合わせが効率よく行われていないことが 考えられる.そこで,巡回路を重ね合わせて経路を選択する際 に,様々な粒子の情報を参照するような経路の組み合わせ方 法を考案し,更なる大規模問題に挑戦していきたいと考えてい る.

- [Kennedy 95] J.Kennedy, R.C.Eberhart, : "Particle swarm optimization"IEEE International Conf. on Neural Networks, pp.1942-1948 (1995)
- [本庄 16] 本庄将也,飯塚博幸,山本雅人,古川正志,:"巡回セールスマン問題に対する粒子群最適化の提案と性能評価",日本知能情報ファジィ学会誌,vol.28,no.4,pp.744-755 (2016)

# U12バスケットボールにおけるリーグ戦スケジューリング

League Scheduling for U12 Basketball

沖本 天太<sup>\*1</sup> 西村 一輝<sup>\*2</sup> Tenda Okimoto Kazuki Nishimura 平山 勝敏 \*1 Katsutoshi Hirayama

\*1神戸大学大学院海事科学研究科 Faculty of Maritime Sciences, Kobe University \*<sup>2</sup>神戸大学海事科学部 Graduate School of Maritime Sciences, Kobe University

Sports Scheduling is one of the widely investigated application problems in Artificial Intelligence and Operations Research. This problem can be represented as a combinatorial optimization problem, in which the date and the venue of each game must be determined, subject to a given set of constraints. In 2018, Japan Basketball Association (JBA) has started to implementing the league games in the prefectures. In this paper, a formal framework for U12 Basketball League Scheduling ( $\mathsf{BLS}^{U12}$ ) problem is introduced. Furthermore, a novel solution criteria called egalitarian solution for  $\mathsf{BLS}^{U12}$  is defined. In the experiments, we use the real data of U12 basketball league games played in Hyogo prefecture in 2018 and find an optimal league scheduling which can reduce the total travel distance of teams compared to that of actually used. An egalitarian solution for the total travel distance is also provided.

# 1. はじめに

スポーツ・スケジューリング [3, 4] 問題とは、チーム、対戦 日、開催場所等の集合に対して、与えられた制約条件を満たす ように対戦表を作成する組合せ最適化問題である.スポーツ・ スケジューリングは AI や OR 分野における応用問題として広 く研究されており、応用例として、アメリカ西海岸大学対抗バ スケットボール [1] やプロサッカーリーグ [2] 等が挙げられる.

日本バスケットボール協会 (JBA)\*1 は (i) 拮抗したゲーム を多くすることで選手及び指導者の成長を促し,(ii) JBA 登 録チームに対して,一定公式試合数の確保を目的とし,都道府 県内でのリーグ戦の実施を 2018 年度より開始した.兵庫県ミ ニバスケットボール連盟 \*2 は 2018 年度,県内の男女合わせ て約 180 チームを対象に前後期リーグ戦を実施した.前期(5 月から 7 月)では,各チームは所属地区で実施された新人戦 の成績を基に,A(上位),B1,B2,B3(中位),C(下位)の 5つのリーグに分けられ,県内の各会場で 10 試合の公式戦を 行った.また後期(9 月から 12 月)では,前期の成績を基に 各リーグのチームが再編成され 10 試合の公式戦が行われた.

リーグ戦作成では,前後期各 10 試合の計 20 試合を実施しな ければならないとする総試合数に関する制約や,同じチームと 2 試合以上対戦してはならないとする重複試合の禁止等の満た さなければならない様々な制約条件が存在する.このため,す べての制約条件を満たすようなリーグ戦を作成するのは困難な 問題である.実際,兵庫県ミニバスケットボール U12 の前期 A リーグ(女子)では重複試合が 2 件発生している.さらに, 現状のリーグ戦は人手により数日かけて作成されているため, その負担を軽減する必要がある.また,各チームの総移動距離 やチーム間の移動距離の平等性等は現在考慮されていない.

本論文では,移動距離最小化問題のフレームワークを用いて, ミニバスケットボールにおけるリーグ戦作成 (U12 Basketball League Scheduling, BLS<sup>U12</sup>) 問題を定義する.実験では,2018 年度に兵庫県下で実施されたミニバス U12 の後期 A リーグ

\*2 https://hyogo-minibasket.jimdo.com

(女子)の実データを用いて、与えられた制約条件を満たし、 かつ、各チームの移動距離の総和が最小となるようなリーグ戦 及び、移動距離の最大値を最小化するようなリーグ戦をそれぞ れ作成し、実際に用いられたリーグ戦と比較評価する.

# 2. U12バスケットボールリーグ戦作成問題

ミニバスケットボール(ミニバス)におけるリーグ戦作成 (BLS<sup>U12</sup>)問題を定義する.まず BLS<sup>U12</sup>の基本用語を与える.

- T = {1,...,n}:チームの集合.
- D = {1,...,m}:日付(対戦日:休日・祝日)の集合.
- X = {x<sub>ij</sub> | i, j ∈ T (i ≠ j)}:変数の集合. x<sub>ij</sub> = k (k ∈ D) とは, チーム i と j が k 日に対戦することを表す.
- $C = \{c_1, ..., c_l\}$ :制約の集合.
- $T_s = \{q_1, ..., q_t\}$ : (各チームの) 拠点校の集合.
- *P* = {*p*<sub>1</sub>,...,*p*<sub>s</sub>}:対戦が行われる試合会場の集合.
- $\alpha: T \to T_s$ : 各チームの拠点校を返す写像.
- *β*: *D* → *P*: 日付から試合会場を返す写像.
- $dis: T_s \times P \rightarrow \mathbb{R}$ :拠点校から会場までの距離を返す関数.

以下,兵庫県ミニバス U12 で用いられた制約条件を示す.

- 制約1(総試合数の制限):各チームの対戦数は10試合とする。各チームは前期10,後期10の計20試合を行う。
- 制約2(毎試合数の制限):U12では選手の体力等を考慮して、各チーム、試合がある場合は1日に2試合行う.
- 制約3(各会場での試合数の制限):各試合会場では、その日に対戦しなければならない対戦数が決められている。
- 制約4(重複試合の禁止):同じ相手と2試合以上対戦して はならない(同じリーグ内の他の10チームと対戦する).

連絡先: 沖本 天太, 神戸大学大学院海事科学研究科, 神戸市東 灘区深江南町 5-1-1, tenda@maritime.kobe-u.ac.jp

<sup>\*1</sup> http://www.japanbasketball.jp

| チーム名     | 成徳                | 北エン   | 福田    | 香櫨園   | 塚口    | 武庫                | 浜脇                | 多田東               |
|----------|-------------------|-------|-------|-------|-------|-------------------|-------------------|-------------------|
| 提案手法     | 836km             | 608km | 636km | 888km | 944km | $876 \mathrm{km}$ | 886km             | 816km             |
| +Minimax | $878 \mathrm{km}$ | 800km | 636km | 820km | 902km | $776 \mathrm{km}$ | 828km             | $850 \mathrm{km}$ |
| チーム名     | 西宮浜               | 宝塚 BR | 川西    | 荻野    | 北淡    | 松陽                | 三田                | 氷上東               |
| 提案手法     | 842km             | 932km | 854km | 834km | 596km | 642km             | $524 \mathrm{km}$ | 270km             |
| +Minimax | 878km             | 794km | 854km | 902km | 596km | 642km             | $558 \mathrm{km}$ | 270km             |

表 1: 提案手法と+Minimax における各チームの総移動距離.

表 2: 後期 A リーグ (女子 16 チーム) における,実際のリー グ戦と提案手法で得られたリーグ戦の総移動距離と作成時間.

| 後期リーグ | 実際のリーグ戦              | 提案手法     | +Minimax          |
|-------|----------------------|----------|-------------------|
| 総移動距離 | $14,204 \mathrm{km}$ | 11,984km | $11,984 {\rm km}$ |
| 作成時間  | 数日                   | 4秒       | 173 秒             |

次に、U12におけるリーグ戦作成 (BLS<sup>U12</sup>) 問題を定義する.

定義 1 (BLS<sup>U12</sup>). ミニバスにおけるリーグ戦作成 (BLS<sup>U12</sup>) は、X を変数の集合、D を変数値の集合、C を制約の集合、  $T_s$  を拠点校の集合、P を試合会場の集合、 $\alpha$  を各チームの拠 点校を返す写像、 $\beta$  を日付から試合会場を返す写像、 $\phi$  を拠点 校から試合会場までの往復距離を計算する関数とし、

 $\mathsf{BLS}^{\mathsf{U12}} = \langle X, D, C, T_s, P, \alpha, \beta, \phi \rangle$ 

の組により定義される. 全変数への割当を A とし、関数  $\phi$  は

$$\phi(A) = \sum_{i,j,k} 2 \cdot [dis(\alpha(i), \beta(k)) + dis(\alpha(j), \beta(k))]$$

により与えられる  $(1 \le i, j \le n, i \ne j, 1 \le k \le m)$ . BLS<sup>U12</sup> を解くとは、全ての制約条件を満たし、各チームの移動距離の 総和  $\phi(A)$  が最小となるような割当 A を見つけることである.

定義 2 (BLS<sup>U12</sup> 問題).

- 入力: ミニバスにおけるリーグ戦作成 BLS<sup>U12</sup>,
- 質問: 移動距離の総和が最小となるリーグ戦をみつけよ.

リーグ戦作成 BLS<sup>U12</sup> において,各チーム i  $(1 \le i \le n)$  の 総移動距離を  $d_i$  とし、すべてのチームの総移動距離を  $\overline{d}$ ·ベク トルと呼び, $\overline{d} = (d_1, ..., d_n)$  と記述する.また 2 つの  $\overline{d}$ ·ベク トル  $\overline{d'}$  及び  $\overline{d''}$  に関して、両者の各要素の総和が等しいとき、 すなわち、 $\sum_i d'_i = \sum_i d''_i$  が成立するとき、 $\overline{d'}$  と  $\overline{d''}$  は同等で あるという.同等な  $\overline{d}$ ·ベクトルからなる集合を  $\overline{D}$  と記述する. また  $\overline{D}$  上の前順序は  $\leq_{lex}$  により与えられるものとする.す なわち、 $\forall \overline{d'}, \overline{d''} \in \overline{D}$  に関して、 $\overline{d'}$  が辞書式順序において  $\overline{d''}$ より先行している、またそのときに限り、 $\overline{d'} \leq_{lex} \overline{d'}$  と定義す る. ある  $\overline{d}$ ·ベクトル  $\overline{d'}$  が平等であるとは、 $\overline{d''} \leq_{lex} \overline{d'}$  となる ような、 $\overline{d'}$  と同等な他の  $\overline{d''}$  が存在しないことを意味する.

### 3. 評価実験

2018 年度に兵庫県下で実施されたミニバス U12 後期 A リー グ戦(女子 16 チーム)の実データを用いて BLS<sup>U12</sup> 問題を求 解した.具体的には,BLS<sup>U12</sup> 問題を 0-1 整数計画問題として 定式化し,最適化ソルバー CPLEX を用いて,各チームの移 動距離の総和が最小となるリーグ戦及び,総移動距離が最小, かつ,移動距離の最大値が最小となるリーグ戦を作成した.

実際に使用された U12 後期 A リーグ戦と提案手法によって 作成されたリーグ戦における総移動距離及び実行時間を表2に 示す(両者とも全ての制約条件1から4を満たしている).ま た,表中の+Minimaxは提案手法とミニマックス値を用いたと きの実験結果を表す.表2より,実際に使用された後期リーグ 戦での全16チームの総移動距離は14,204kmであった.これ に対し、提案手法では、全16チームの総移動距離は11,984km であり、実際に使用されたものとの差は 2.222km であった. また、実際のリーグ戦は人手により数日かけて作成されている のに対し、提案手法では最適なリーグ戦が4秒、+Minimax では最適かつ、移動距離の最大値が最小となるリーグ戦が173 秒で求解可能であった.表1は提案手法及び,+Minimax に よって得られた各チームの総移動距離を表している.提案手 法では、塚口の総移動距離が 944km(最大値)であるのに対 し、+Minimax では 902km であった. このように、+Minimax で得られた解では、総移動距離が大きい塚口や宝塚 BR の負 担を他のチームでシェアすることで軽減しているのが分かる.

# 4. おわりに

本論文では、ミニバスケットボールにおけるリーグ戦作成 (BLS<sup>U12</sup>) 問題を定義し、各チームの移動距離の総和が最小と なるような最適なリーグ戦及び、最適かつ移動距離の最大値 が最小となるようなリーグ戦を作成した.実験では、2018 年 度に兵庫県下で実施されたミニバス U12 後期 A リーグ戦(女 子)の実データを用いて、BLS<sup>U12</sup> 問題を求解し、実際に使用 されたリーグ戦と比較評価した.実験結果より、提案手法では 最適なリーグ戦が 4秒、最適かつ移動距離の最大値が最小とな るようなリーグ戦が 173 秒で作成可能であることが分かった. 今後の課題として、現場で利用可能なシステムの開発、U15 及び U18 バスケットボールにおけるリーグ戦作成、その他の スポーツ・スケジューリング問題への適用等が挙げられる.

- M. Henz. Scheduling a major college basketball conference - revisited. Operations Research, 49:163–168, 2002.
- [2] C. Ribeiro. Sports scheduling: Problems and applications. International Transactions in Operational Research, 19:201–226, 2012.
- [3] 宮代隆平 and 松井知己.スポーツスケジューリングーリングーま解決問題を中心に一.オペレーションズリサーチ, 50:119–124, 2005.
- [4] 池辺淑子. スポーツのスケジューリン グ. オペレーション ズリサーチ, 51:392–395, 2006.

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

# [3K3-J-2] Machine learning: analysis and validations of models

Chair:Masahiro Suzuki Reviewer:Satoshi Oyama

Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room K (201A Medium meeting room)

| [3K3-J-2-01] | Statistical Mechanical Formulation of Learning Dynamics of Two-<br>Layered Neural Networks with Batch Normalization          |
|--------------|--|
|              | OShiro Takagi <sup>1</sup> , Yuki Yoshida <sup>1</sup> , Masato Okada <sup>1</sup> (1. Graduate School of Frontier Sciences, |
|              | The University of Tokyo)   |
|              | 1:50 PM - 2:10 PM  |
| [3K3-J-2-02] | On the trade-off between the number of nodes and the number of   |
|              | trees in Random Forest   |
|              | OSo Kumano <sup>1</sup> , Tatsuya Akutsu <sup>1</sup> (1. Kyoto University)  |
|              | 2:10 PM - 2:30 PM  |
| [3K3-J-2-03] | Do the AUC and log-loss evaluate CTR prediction models properly?   |
|              | OSatoshi KATAGIRI <sup>1</sup> (1. F@N Communications, Inc.)   |
|              | 2:30 PM - 2:50 PM  |
| [3K3-J-2-04] | Social reinforcement learning with shared global aspiration for  |
|              | satisficing  |
|              | ONoriaki Sonota <sup>1</sup> , Takumi Kamiya <sup>2</sup> , Tatsuji Takahashi <sup>1</sup> (1. Tokyo Denki University, 2.    |
|              | Graduate School of Tokyo Denki University)   |
|              | 2:50 PM - 3:10 PM  |
| [3K3-J-2-05] | On the mathematical approach to the ``photo-likeness" of images  |
|              | OYasuhiko Asao <sup>1</sup> , Ryotaro Sakamoto <sup>1</sup> (1. Graduate School of Mathematical Science, the                 |
|              | University of Tokyo)   |
|              | 3:10 PM - 3:30 PM  |

# Batch Normalization つき3層ニューラルネットワークの学習ダイナ ミクスの統計力学的定式化

Statistical Mechanical Formulation of Learning Dynamics of Two-Layered Neural Networks with Batch Normalization

| 高木志郎         | 吉田雄紀         | 岡田真人         |
|--------------|--------------|--------------|
| Shiro Takagi | Yuki Yoshida | Masato Okada |

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

Batch Normalization is known as a method to shorten training time, stabilize training and improve the performance of neural networks. Despite its wide use, the impact of Batch Normalization on the learning dynamics of neural networks is yet to be clarified. Though some recent studies tried to tackle this problem, few of them derived the exact learning dynamics of neural networks with Batch Normalization. Because deriving the learning dynamics is helpful for understanding what Batch Normalization is doing during training, we derived an exact learning dynamics of two-layered neural networks with Batch Normalization by drawing on the previous work about a statistical mechanical method of neural network analysis. Specifically, for neural networks with Batch Normalization, we derived differential equations of order parameters, which represent a macroscopic behavior of neural networks.

# 1. はじめに

ニューラルネットワークの学習を高速化、安定化させる手 法として, Ioffe と Szegedy が提案した Batch Normalization という手法がある [Ioffe 15]. これは中間層への入力を正規化 することで学習の高速化を行う手法であるが、学習の高速化 だけではなく, 学習率や重みの初期値などのパラメータの設 定を容易にしたり,正則化の効果を持っていたりと,ニュー ラルネットワークの学習を容易にする様々な効果が経験的に 知られている.しかし, Batch Normalization がニューラル ネットワークの学習に与える影響についての理解は依然とし て不十分である. Ioffe と Szegedy は, 各層への入力がそれ以 前までの重みの変更に依存するために生じる「内的共変量シ フト」を Batch Normalization が低減できるため、学習を容 易にすると主張した [Ioffe 15]. 一方 Santurkar らは, Batch Normalization は内的共変量シフトとは関係なく,むしろ誤差 曲面を滑らかにすることで予測しやすい安定な勾配が計算で きるようにし、学習効率を向上させると主張した [Santurkar 18]. Bjorck らは, Batch Normalization が可能にする大きな 学習率が,正則化の効果を持つことによって,学習の高速化だ けでなく汎化性能の向上をもたらすことを示した [Bjorck 18]. Kohler らは, Batch Normalization は重みベクトルの最適化 を長さの最適化と方向の最適化に切り分けることによって最 適化を容易にすると主張した [Kohler 18]. また Arora らは, Batch Normalization が学習率の自動調節をもたらすことに よって最適な収束率を実現することを,滑らかな誤差関数を用 いた学習に対して示した [Arora 18]. これらはいずれも理論 的な解析により Batch Normalization の効果について示唆を 与えるものだが、ニューラルネットワークの学習中に重みや誤 差が具体的にどのように振る舞うかについては議論ができてい ない. ニューラルネットワークのパラメータや誤差のダイナミ クスを解析的に導出するのは一般に困難である.そのため,理 想化された単純な系であっても学習のダイナミクスを求めるこ とは重要である.そこで、私たちは90年代に考案された統計 力学的手法を用いて Batch Normalization を適用した3層ソ フトコミティの学習ダイナミクスを導出した. ソフトコミティ とは中間層から出力層への重みを定数に固定した場合のニュー

ラルネットワークであり,解析の簡単のため用いられることが ある.統計力学的手法とは大規模ネットワークを仮定すること で,系の大域的な挙動を記述するパラメータであるオーダーパ ラメータと訓練誤差の期待値として定義される汎化誤差のダイ ナミクスを解析的に導出する手法である [Schwarze 93, Seung 92, Saad 95, Biehl 95, Riegler 95].統計力学的手法を用いて Batch Normalization のダイナミクスを解析した研究として は、Luo らの研究がある [Luo 18].しかしこれは単層パーセ プトロンに議論を限定しており、中間層がある場合のダイナミ クスは扱っていない.我々は中間層がある3層ニューラルネッ トワークについてダイナミクスを導出した.

# Batch Normalization つき3層ニューラ ルネットワークの統計力学的定式化

#### 2.1 統計力学定式化

統計力学的定式化では一般に教師生徒型ニューラルネット ワークのオンライン学習を考える [Saad 95,Biehl 95]. ここで 教師生徒型学習とは、図1に示すように、学習器と同じ構造を 持つニューラルネットワークを教師データの生成モデルと仮定 する教師あり学習を指し、オンライン学習とは各更新毎に新し く生成されるサンプルサイズ1のデータを用いた確率的勾配 降下法による学習のことを指す. この時生成モデルを教師ネッ トワーク、学習器を生徒ネットワークと呼ぶ.

入力素子数 N, 生徒の中間素子数が K, 教師の中間素子 数が M, 出力素子数が O の 3 層ニューラルネットワークを 考える.入力  $\boldsymbol{\xi} \in \mathbb{R}^{\mathbb{N}}$  の各成分は期待値 0 分散  $\sigma^2$  の分布か ら i.i.d. にサンプリングされるとする.生徒ネットワークの 第 1 層の重み行列を  $[\mathbf{J}_1, \dots, \mathbf{J}_K]^T \in \mathbb{R}^{K \times N}$ ,第二層の重み 行列を  $[\mathbf{w}_1, \dots, \mathbf{w}_K]^T \in \mathbb{R}^{O \times K}$ ,教師ネットワークの第 1 層 の重み行列を  $[\mathbf{B}_1, \dots, \mathbf{B}_M]^T \in \mathbb{R}^{M \times N}$ ,第二層の重み 行列を  $[\mathbf{v}_1, \dots, \mathbf{v}_M]^T \in \mathbb{R}^{O \times M}$ と表記する.生徒と教師の第 1 層の重みベクトルは  $\mathbf{J}_i \in \mathbb{R}^{N \ iid} \mathcal{N}(0, 1/N)$ ,  $\mathbf{B}_n \in \mathbb{R}^{N \ iid}$  $\mathcal{N}(0, 1/N)$  と初期化をする. 今ソフトコミティを考えている ので  $\mathbf{w}_i \in \mathbb{R}^O$ ,  $\mathbf{v}_n \in \mathbb{R}^O$  は要素が定数の O 次元のベクトル で,値が不変である. ただし i, n はそれぞれ生徒と教師の中間 層の素子のインデックスである.中間層の活性化関数を  $\phi$  と し,出力層の活性化関数は恒等写像とする.このとき,生徒と 教師のネットワークの出力はそれぞれ,

$$\mathbf{s} \in \mathbb{R}^{O} = \sum_{i}^{K} \mathbf{w}_{i} \phi \left( \mathbf{J}_{i} \cdot \boldsymbol{\xi} \right), \tag{1}$$

$$\mathbf{t} \in \mathbb{R}^{O} = \sum_{n}^{M} \mathbf{v}_{n} \phi \left( \mathbf{B}_{n} \cdot \boldsymbol{\xi} \right), \qquad (2)$$

と書ける.損失関数としては二乗損失  $\varepsilon = \frac{1}{2} ||\mathbf{t} - \mathbf{s}||^2$ を用い て、 生徒ネットワークの重みを教師ネットワークの重みに近づ けていく. ここで, 系の大域的な挙動を記述するパラメータで あるオーダーパラメータを次のように定義する: $Q_{ij} = \mathbf{J}_i \cdot \mathbf{J}_j$ ,  $R_{in} = \mathbf{J}_i \cdot \mathbf{B}_n, \ T_{nm} = \mathbf{B}_n \cdot \mathbf{B}_m, \ D_{ij} = \mathbf{w}_i \cdot \mathbf{w}_j, \ E_{in} = \mathbf{w}_i \cdot \mathbf{v}_n,$  $F_{nm} = \mathbf{v}_n \cdot \mathbf{v}_m$  [Saad 95, Biehl 95, Yoshida 18]. 入力素子数 N が十分に大きい時,活性化関数によってはいくつかの理想 化のもとでこれらのパラメータの微分方程式を導出すること ができる [Saad 95, Biehl 95]. また,訓練誤差の & について の期待値として定義される汎化誤差 εg はオーダーパラメータ の関数となるので、汎化誤差のダイナミクスも導出すること ができる. Saad と Solla は3 層ソフトコミティの入力層から 中間層への重みについて, Biehl と Schwarze は一般の3層を 対象として入力層から中間層への重みについて, Yoshida ら は3層の全ての重みについて、オーダーパラメータのダイナ ミクスを導出している [Saad 95, Biehl 95, Yoshida 18]. 我々 はこのうちソフトコミティについてのダイナミクスを Batch Normalization ありの場合に拡張した.

#### 2.2 Batch Normalization の統計力学定式化

従来の統計力学的定式化ではサンプルサイズ1の学習を取 り扱っていたため、これを Batch Normalization を取り扱え るように拡張した。各更新毎に新しくb 個の入力をi.i.d. にサ ンプリングし、それを用いて学習を行うものとする。サンプル サイズbのデータの中の2つのサンプル $\xi^u$ ,  $\xi^v$  が互いに無相 関だと仮定する。すると、 $Q_{ij}$ のダイナミクスに一部修正を加 えるだけで、Batch Normalization を取り扱えるように統計力 学的手法を自然に拡張できることを確認した。

Batch Normalization では、各中間素子への入力  $x_i^u = \mathbf{J}_i \boldsymbol{\xi}^u$ それぞれに対して、ミニバッチデータについての算術平均と標 準偏差で正規化したものに学習可能パラメータ  $g_i$ をかけて  $\beta_i$ を足したものを活性化関数への入力とする.ここでは解析の簡 単のため、算術平均を引く操作と  $\beta$  を足す操作を行わず、標準 偏差は定数とする。今、入力に期待値 0 の分布を仮定している ので、サンプルサイズ b が十分大きいとき、中間層の各素子の b 個の入力についての標準偏差  $\sigma_{x_i} = \sqrt{\frac{1}{b} \sum_{u=1}^{b} (x_i^u - \mu_i)^2}$  は  $\sigma_{x_i} \approx \sqrt{\frac{b}{b-1} \langle x_i^2 \rangle} \approx \sqrt{\mathbf{J}_i^T \langle \boldsymbol{\xi}^u \boldsymbol{\xi}^{uT} \rangle \mathbf{J}_i} = \sqrt{\sigma^2 ||\mathbf{J}_i||^2} = \sigma \sqrt{Q_{ii}}$ 

となり、 $\boldsymbol{\xi}$ に依存しなくなる.ただし 〈・〉 は入力 $\boldsymbol{\xi}$ についての 期待値をとる操作である.この時、生徒の出力は、

$$\mathbf{s}^{u} = \sum_{i}^{K} \mathbf{w}_{i} \phi \left( \frac{g_{i}}{\sigma \sqrt{Q}_{ii}} \mathbf{J}_{i} \boldsymbol{\xi}^{u} \right) = \sum_{i}^{K} \mathbf{w}_{i} \phi \left( \frac{g_{i}}{\sigma \sqrt{Q}_{ii}} x_{i}^{u} \right), \quad (3)$$

となる.そして生徒の第1層の重みと学習可能パラメータ  $g_i$ の更新式はそれぞれ,

$$\Delta \mathbf{J}_i = \frac{\eta}{Nb} \sum_{u=1}^{b} \left[ (\mathbf{t}^u - \mathbf{s}^u) \cdot \mathbf{w}_i \right] \phi' \left( \frac{g_i}{\sigma \sqrt{Q_{ii}}} x_i^u \right) \frac{g_i}{\sigma \sqrt{Q_{ii}}} \boldsymbol{\xi}^u, \quad (4)$$

$$\Delta g_i = \frac{\eta}{Nb} \sum_{u=1}^{b} \left[ (\mathbf{t}^u - \mathbf{s}^u) \cdot \mathbf{w}_i \right] \phi' \left( \frac{g_i}{\sigma \sqrt{Q_{ii}}} x_i^u \right) \frac{\mathbf{J}_i \boldsymbol{\xi}^u}{\sigma \sqrt{Q_{ii}}}, \quad (5)$$



図 1: Batch Normalization ありの場合の3層ソフトコミティの教師生徒型学習の図.入力素子数がN,中間素子数がK = 2, M = 2,出力素子数がO = 1の場合.  $\xi$ を共通の入力として出力されたsとtの間の誤差を小さくするように生徒が重みを調節する.

と書ける.ただし  $\frac{\eta}{N}$  は学習率を表す. $\frac{g_i}{\sigma\sqrt{Q_{ii}}}x_i = \hat{x}_i$ と書くと、オーダーパラメータと  $g_i$ の更新式は、

$$\begin{split} \Delta Q_{ij} \\ &= \frac{\eta}{bN} \sum_{u=1}^{b} \left[ \sum_{p=1}^{M} E_{ip} \phi'(\hat{x}_{i}^{u}) \hat{x}_{j}^{u} \phi(y_{p}^{u}) - \sum_{p=1}^{K} D_{ip} \phi'(\hat{x}_{i}^{u}) \hat{x}_{j}^{u} \phi(\hat{x}_{p}^{u}) \\ &+ \sum_{p=1}^{M} E_{jp} \phi'(\hat{x}_{j}^{u}) \hat{x}_{i}^{u} \phi(y_{p}^{u}) - \sum_{p=1}^{K} D_{jp} \phi'(\hat{x}_{j}^{u}) \hat{x}_{i}^{u} \phi(\hat{x}_{p}^{u}) \right] \\ &+ \frac{\eta^{2}}{b^{2}N^{2}} \sum_{u,v}^{b,b} \boldsymbol{\xi}^{u} \boldsymbol{\xi}^{v} \left[ \sum_{p,q}^{K,K} D_{ip} D_{jq} \phi'(\hat{x}_{i}^{u}) \phi'(\hat{x}_{j}^{v}) \phi(\hat{x}_{p}^{u}) \phi(\hat{x}_{q}^{v}) \\ &+ \sum_{p,q}^{M,M} E_{ip} E_{jq} \phi'(\hat{x}_{i}^{u}) \phi'(\hat{x}_{j}^{v}) \phi(y_{p}^{u}) \phi(y_{q}^{v}) \\ &- \sum_{p,q}^{K,M} D_{ip} E_{jq} \phi'(\hat{x}_{i}^{u}) \phi'(\hat{x}_{j}^{v}) \phi(\hat{x}_{p}^{u}) \phi(\hat{x}_{q}^{v}) \right], \end{split}$$
(6) 
$$\Delta B_{in} \end{split}$$

$$= \frac{\eta}{bN} \sum_{u=1}^{b} \left[ \sum_{p=1}^{M} E_{ip} \phi'(\hat{x}_{i}^{u}) y_{n}^{u} \phi(y_{p}^{u}) - \sum_{p=1}^{K} D_{ip} \phi'(\hat{x}_{i}^{u}) y_{n}^{u} \phi(\hat{x}_{p}^{u}) \right],$$
(7)

 $\Delta g_i$ 

$$= \frac{\eta}{bNg_i} \sum_{u=1}^{b} \left[ \sum_{p=1}^{M} E_{ip} \phi'(\hat{x}_i^u) \hat{x}_i^u \phi(y_p^u) - \sum_{p=1}^{K} D_{ip} \phi'(\hat{x}_i^u) \hat{x}_i^u \phi(\hat{x}_p^u) \right],$$
(8)

と書ける.また,汎化誤差は,

$$\varepsilon_{g} = \frac{1}{2} \left[ \sum_{p,q}^{M,M} F_{pq} \phi(y_{p}^{u}) \phi(y_{q}^{u}) + \sum_{p,q}^{K,K} D_{pq} \phi(\hat{x}_{p}^{u}) \phi(\hat{x}_{q}^{u}) - 2 \sum_{p,q}^{K,M} E_{pq} \phi(\hat{x}_{p}^{u}) \phi(y_{q}^{u}) \right],$$
(9)

となる. ただし  $y_n^u = \mathbf{B}_n \boldsymbol{\xi}^u$  である. この更新式を $\boldsymbol{\xi}$  について期 待値を取ったものは,活性化関数によっては厳密に計算すること ができる [Saad 95, Biehl 95, Yoshida 18].  $\phi(x) = \operatorname{erf}(x/\sqrt{2})$ のとき,これらのオーダーパラメータと  $g_i$ ,そして汎化誤差のダイナミクスは以下のように求まる \*1:

$$N\frac{\mathrm{d}Q_{ij}}{\mathrm{d}t} = \frac{2\eta}{\pi} \left[ Q_1 - Q_2 \right] + \frac{4\eta^2 g_i g_j}{b\pi^2 \sqrt{\Lambda Q_{ii} Q_{jj}}} \left[ Q_3 + Q_4 - Q_5 - Q_6 \right], \qquad (24)$$

$$N\frac{\mathrm{d}R_{in}}{\mathrm{d}t} = \frac{2\eta}{\pi} \left[\mathcal{R}\right],\tag{25}$$

$$N\frac{\mathrm{d}g_i}{\mathrm{d}t} = \frac{2\eta}{\pi g_i} \left[\mathcal{G}\right]. \tag{26}$$

ただし dt は微小な変化量で, (l,k) = (i,j,n,p,q) について  $Q'_{lk} = \frac{\sigma^2 g_{lg_k}}{\sigma_{x_l} \sigma_{x_k}} Q_{lk}, R'_{lk} = \frac{\sigma^2 g_{l}}{\sigma_{x_l}} R_{lk}, T'_{lk} = \sigma^2 T_{lk}$ である.

$$\mathcal{G} = \sum_{p=1}^{M} \frac{E_{ip} \left( R'_{ip} (1+Q'_{ii}) - Q'_{ii} R'_{ip} \right)}{(1+Q'_{ii}) \sqrt{(1+Q'_{ii})} (1+T'_{pp}) - R'_{ip}^{\prime 2}} - \sum_{p=1}^{K} \frac{D_{ip} \left( Q'_{ip} (1+Q'_{ii}) - Q'_{ii} Q'_{ip} \right)}{(1+Q'_{ii}) \sqrt{(1+Q'_{ii})} (1+Q'_{pp}) - Q'_{ii}^{\prime 2}}$$

$$\Lambda = (1+Q'_{ii}) (1+Q'_{jj}) - (1+Q'_{ij}^{\prime 2})$$
(18)

$$\Lambda_1 = \Lambda(1 + Q'_{jp}) - Q'_{jp}^2(1 + Q'_{ii}) - Q'_{ip}^2(1 + Q'_{jj}) + 2Q'_{ij}Q'_{ip}Q'_{jp}$$
(19)

$$\begin{split} \Lambda_2 &= \Lambda (1 + Q_{qq}) - Q_{jq}^{-} (1 + Q_{ii}) - Q_{iq}^{-} (1 + Q_{jj}) + 2Q_{ij}Q_{iq}Q_{jq} & (20) \\ \Lambda_3 &= \Lambda (1 + T_{nn}') - R_{in}'^2 (1 + Q_{ii}') - R_{in}'^2 (1 + Q_{ij}') + 2Q_{ij}' R_{in}' R_{in}' & (21) \end{split}$$

$$\Lambda_4 = \Lambda(1 + T'_{qq}) - R'^2_{jq}(1 + Q'_{ii}) - R'^2_{iq}(1 + Q'_{jj}) + 2Q'_{ij}R'_{iq}R'_{jq}$$
(22)

$$\begin{split} \varepsilon_{g} &= \frac{1}{\pi} \Biggl[ \sum_{p,q}^{M,M} \operatorname{asin} \Biggl( \frac{T'_{pq}}{\sqrt{(1+T'_{pp})(1+T'_{qq})}} \Biggr) \\ &- \sum_{p,q}^{K,K} \operatorname{asin} \Biggl( \frac{Q'_{pq}}{\sqrt{(1+Q'_{pp})(1+Q'_{qq})}} \Biggr) - 2 \sum_{p,q}^{K,M} \operatorname{asin} \Biggl( \frac{R'_{pq}}{\sqrt{(1+Q'_{pp})(1+T'_{qq})}} \Biggr) \Biggr] \quad (23) \end{split}$$



図 2: (a), (c), (e), (g) が数値シミュレーションの結果で (b), (d), (f), (h) が統計力学的手法を用いて導出したダイナミクス.  $\eta = 1, N = 100, b = 100, \sigma = 1, w_i = 1, v_n = 1$ とし,総 イテレーション数は 20000 とした

#### 2.3 数値シミュレーションと統計力学的定式化により 導出したダイナミクスの一致

統計力学的手法を用いたダイナミクスの導出では近似を用 いている.そのため,統計力学的手法によって導出されたダ イナミクスと実際の重みの更新式を用いた数値シミュレーショ ンの結果が一致することを確認する必要がある.そこで K = 2, M = 2, O = 1の場合について  $Q_{ij}, R_{in}, g_i$  および  $\varepsilon_g$  の時 間発展を比較した.図2が数値シミュレーションの結果と統計 力学的手法によって導出されたダイナミクスの比較である.図 より,これらの二つの結果はよく一致しており,統計力学的手 法の近似は妥当であることがわかる.

# 3. まとめ

Saad らが発展させた統計力学的手法を用いて Batch Normalization がある場合の3層ニューラルネットワークのオー ダーパラメータおよび汎化誤差のダイナミクスを導出した.こ れを用いれば Batch Normalization がニューラルネットワー クの学習挙動にどのような影響を与えるかを解析することがで きる.

例えば、ニューラルネットワークの学習では学習初期と終期 ではデータから学習する構造が異なると考えられており、それ がニューラルネットワークが高い表現能力を持ちながら良い汎 化性能を示す原因としてあげられることがある [Saxe 18, Xu 18, Krueger 17, Rahaman 18, Arpit 18]. Batch Normalization がそれぞれの時期の学習にどのような影響を与えるのかを分析 することは Batch Normalization がなぜうまくいくのかを理 解する上で重要であり、本稿で導出したダイナミクスを解析す ることでそのような分析が可能となることが期待できる.

- [Arora 18] Arora, S., Li, Z., and Lyu, K.: Theoretical Analysis of Auto Rate-Tuning by Batch Normalization, arXiv preprint arXiv:1812.03981 (2018)
- [Arpit 18] Arpit, D., Jastrzebski, S., Ballas, N., Krueger, D., Bengio, E., Kanwal, M. S., Maharaj, T., Fischer, A., Courville, A., Bengio, Y., and Lacoste-Julien, S.: A Closer Look at Memorization in Deep Networks, *ICML* (2018)
- [Biehl 95] Biehl, M. and Schwarze, H.: Learning by on-line gradient descent, *Journal of Physics A: Mathematical* and General, Vol. 28, No. 3, p. 643 (1995)
- [Bjorck 18] Bjorck, J., Gomes, G., Selman, B., and Weinberger, K. Q.: Understanding Batch Normalization, *NeurIPS 2018* (2018)
- [Ioffe 15] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, in *ICML*, pp. 448–456 (2015)
- [Kohler 18] Kohler, J., Daneshmand, H., Lucchi, A., Zhou, M., Neymeyr, K., and Hofmann, T.: Exponential convergence rates for Batch Normalization: The power of length-direction decoupling in non-convex optimization, arXiv preprint arXiv:1805.10694 (2018)
- [Krueger 17] Krueger, D., Ballas, N., Jastrzebski, S., Arpit, D., Kanwal, M. S., Maharaj, T., Bengio, E., Fischer, A., and Courville, A.: Deep Nets Don't Learn Via Memorization, *ICLR Workshop* (2017)
- [Luo 18] Luo, P., Wang, X., Shao, W., and Peng, Z.: Towards Understanding Regularization in Batch Normalization, arXiv preprint arXiv:1809.00846 (2018)
- [Rahaman 18] Rahaman, N., Baratin, A., Arpit, D., Draxler, F., Lin, M., Hamprecht, F. A., Bengio, Y., and Courville, A.: On The Spectral Bias of Neural Networks, *NeurIPS Workshop* (2018)
- [Riegler 95] Riegler, P. and Biehl, M.: On-line backpropagation in two-layered neural networks, *Journal of Physics* A, Vol. 28, pp. L507–L513 (1995)

- [Saad 95] Saad, D. and Solla, S. A.: Exact Solution for On-Line Learning in Multilayer Neural Networks, *Physical Review Letters*, Vol. 74, No. 41, pp. 4337–4340 (1995)
- [Santurkar 18] Santurkar, S., Tsipras, D., Ilyas, A., and Mardy, A.: How Does Batch Normalization Help Optimization?, arXiv preprint arXiv:1805.11604 (2018)
- [Saxe 18] Saxe, A. M., McClelland, J. L., and Ganguli, S.: A mathematical theory of semantic development in deep neural networks, arXiv preprint arXiv:1810.1053 (2018)
- [Schwarze 93] Schwarze, H.: Learning a rule in a multilayer neural network, *Journal of Physics A*, Vol. 26, pp. 5781– 5794 (1993)
- [Seung 92] Seung, H. S., Somopolinsky, H., and Tishby, N.: Statistical mechanics of learning from examples, *Physical Review A*, Vol. 45, No. 8, pp. 6056–6091 (1992)
- [Xu 18] Xu, Z.-Q. J.: Understanding training and generalization in deep learning by Fourier analysis, arXiv preprint arXiv:1808.04295 (2018)
- [Yoshida 18] Yoshida, Y., Karakida, R., Okada, M., and Amari, S.: Statistical Mechanical Analysis of Learning Dynamics of Two-Layer Perceptron with Multiple Output Units, J. Phys. A (provisionally accepted) (2018)

# ランダムフォレストにおけるノード数と木数の関係

On the trade-off between the number of nodes and the number of trees in Random Forest

熊野 颯<sup>\*1</sup> 阿久津 達也<sup>\*2</sup> So Kumano Tatsuya Akutsu

\*1京都大学大学院情報学研究科 Grafuate School of Informatics, Kyoto University \*<sup>2</sup>京都大学化学研究所 Institute for Chemical Research, Kyoto University

Expressibility of machine learning models has been extensively studied. For example, in a Neural Network, it is proved that the efficiency concerning the number of nodes is generated from the depth. On the other hand, it is not clear whether the efficiency exists in Random Forest. Therefore, in this research, we investigate whether the efficiency exists in Random Forest. We first show that Random Forest does not have the same kind of efficiency as Neural Network, and next we show that the efficiency concerning the number of nodes can be generated from the number of trees.

# 1. はじめに

封筒上の郵便番号の識別から店舗ごとの商品の需要予測、医 療診断に到るまで幅広い分野において機械学習は活用されて いる。いずれの応用においても、まず学習のモデル(例えば、 ニューラルネットワークなら層の数やニューロンの数、ランダ ムフォレストであれば木の本数や葉の数)を決定し、次に損失 関数を最小化するパラメータを発見する。この学習モデルの決 定、すなわち学習によって最適な関数の探索を行う関数族の決 定は非常に重要である。関数族が不必要に大きい場合は過剰な 計算コストや過学習の問題を引き起こし、逆に不十分な場合に は、適切な関数を得ることはできない。課題ごとに適切な関数 族を選択しなければならないのである。

こうした関数族の選択において有効な手がかりを得るべく、学 習モデルの表現能力に関する研究が古くから行われてきた。例え ば、深さ2のニューラルネットワークで任意のボレル可測関数を 近似することができることを主張する universal aproximation theorem が知られている。また、近年ではニューラルネット ワークは層の数によって表現能力が大きく変化することが分 かってきた。例えば、深さ2のニューラルネットワーク (SNN) は任意のボレル可測関数を近似することが可能であるが、必要 となるノード数が膨大となることがある。しかし、深いネット ワーク (DNN)を用いることで、SNNよりも少ないノード数 で同じ関数を表現できる場合がある。こうした DNN が持つ、 深さによって効率良く関数を表現することが可能となる性質は depth efficiency と呼ばれている。

ニューラルネットワークに対しては、表現能力の研究が盛ん におこなわれている一方で、ランダムフォレストにおいては表 現能力に関する研究は少ない。そこで、本研究ではランダム フォレストがニューラルネットワークにおける depth efficiency と同様にノード数に関する効率性を持つかについて考察する。

# 2. 関連研究

ニューラルネットワークの表現能力は、その深さに対して指 数的に増大すると考えられている。Montúfar らは区分線形関 数を活性化関数として用いた際に、ネットワークが表現する区

連絡先: 熊野颯,京都大学大学院情報学研究科, kumano@kuicr.kyoto-u.ac.jp 分線形関数の線形領域がネットワークの幅に対しては多項式の オーダーでしか増加しないのに対し、深さに対しては指数的に 増大することを示した [1]。 また、Raghu らは、ネットワー クの出力の軌道の長さの観点から、深さに対して表現能力が指 数的に増大することを示した [2]。

DNN は SNN よりも効率的に関数を表すことが出来ること を実際に示した研究も存在する。Telgarsky は、SNN では指数 オーダーのノードが必要だが、DNN では線形オーダーのノー ドで表現できる関数族の存在を示した [3]。Symanzki らは、 DNN において depth efficiency が生じる要因の一つとして入 力の周期性が関与していることを明らかにした [4]。Bengio ら は、Sum-product Network に関して DNN では SNN よりも ノード数の観点で効率的となる関数が存在することを示した [5]。

ランダムフォレストの表現能力に関する研究においては、 Mansour が入力の次元が *d*, ノード数 N の二分決定木の VC 次元の下界が Ω(N)、上界が O(N log *d*) であることを示した [6]。また、VC 次元が *d* の識別器を T 個使用するアンサンブ ル学習の VC 次元の上界は O(*dT* log (*dT*)) である [7]。Oshiro らは、データの密度を定義し密度と最適な木の本数の関係を実 験により確かめた [8]。これらの研究から、ランダムフォレスト は木の本数に対して、表現能力が劇的に増加するといったこと はないと思われる。しかし、これらの結果は depth efficiency と類似の性質の存在を否定する訳ではない。そこで本研究で は、ランダムフォレストにおけるノード数に関する効率性につ いて考察する。

# 3. ランダムフォレストの深さ

Bengio らは、ブースト木のニューラルネットワークにおけ る深さは3であると述べている。[9]。この結果から、ランダ ムフォレストは深さ3のニューラルネットワーク以下の表現能 力しか持たず、depth efficiency と同種の効率性は存在しない と考えられる。

しかし、この結果は 選言標準形のアナロジーとして述べら れたものである。一方、近年の DNN の depth efficiency に 関する結果の多くは区分線形関数を活性化関数として用いた ニューラルネットワークについて示されている。そこで、本研 究ではまず、ランダムフォレストは区分線形関数を活性化関数 として用いた深さ3のニューラルネットワーク以下の表現能力 しか持たないことを示す。ただし、ニューラルネットワークの 出力ノードは線形関数とする。以後、本研究ではランダムフォ レストを構成する決定木として、各ノードごとに入力空間をあ る変数に対して垂直二分割(他の変数に対して軸並行に分割) する二分決定木を考え、各決定木の出力はラベルのみであると する。つまり、ランダムフォレストが出力するラベルはそのラ ベルを出力する木の本数が最も多いラベルとなる。したがって 2 値分類問題におけるランダムフォレストはすべて奇数本の決 定木から構成される。また、*c* でクラス全体を表し、*H* を

$$H(x) = \begin{cases} 1 \ (x \ge 0) \\ 0 \ (x < 0) \end{cases}$$
(1)

と定義する。また、ニューラルネットワークは出力ノードの値 が最も大きいクラスに入力を分類するものとする。

補題 1. n / -ドの決定木  $DT : \mathbb{R}^d \to c$ は Hを活性化関数に 用いた O(n) / -ド、深さ3の NN で表現することができる。

*Proof.* NN の深さ1のノードとして DT の各エッジが成立す る場合に1、それ以外は0を出力するノードを作成する。す なわち、DT のエッジが  $f_1 \ge a$  ならば  $H(f_1 - a)$  を作成し、  $f_1 > a$  ならば1 - H(a - x) を作成する。(1 はこのノードの 出力を受け取るノードのバイアスとして与えられる)

次に深さ2のノードとして DT の各葉ノードを表現するノー ドを作成する。各ノードは DT における葉ノードから根まで の枝に対応するノードの和から、DT における葉ノードの深 さ-0.5 を引いた値を活性化関数の入力として受け取る。最後 に、深さ3の出力ノードとして各クラスに対応するノードを 作成し、各クラスに属する葉ノードと対応するノードの出力を 入力として受け取る。この NN が DT を表現することは明ら かである。実際、DT において入力が到達する葉ノードに対応 する深さ2のノードのみが1を出力し、他の深さ2のノード は0を出力する(少なくとも1つの深さ1のノードの出力は0 であるため)

例えば、下図のニューラルネットワークは左図の決定木を模 倣する。



図 1: エッジの数字は重み、ノードの数字はバイアスを表す。 例えば、深さ 1 の左端のノードは *H*(*x*<sub>1</sub> - 1) を表す。

この補題を用いて、多くの区分線形間数に対し、ランダムフォレストはその関数を活性化関数として用いた深さ3のニューラルネットワーク以下の表現能力しか持たないことが示せる。以降、 $S \subset \mathbb{R}^d$ は有限集合であるとする。

定理 2. n ノードの決定木  $DT: S \rightarrow c$  は、非有界な領域に おける傾きが異なる区分線形関数  $g: R \rightarrow R$  を活性化関数と して用いた O(n) ノードの深さ3の NN で表現することがで きる。

*Proof.* S は有限集合であるから、任意の S の要素が DT の識 別境界上に存在しないと仮定してよい。f は、 $a \neq b$ を満たすあ る定数 a, b に対して、 $\lim_{x\to\infty} f(x) = a$ ,  $\lim_{x\to-\infty} f(x) = b$ を満たすとする。この時、f を用いて ( $x \neq 0$  において) H を 表現することができる。実際、

$$H(x) = \lim_{\epsilon \to 0} (f(\frac{x}{\epsilon}) - b) \frac{1}{a - b} = \frac{1}{a - b} \lim_{\epsilon \to 0} f(\frac{x}{\epsilon}) - \frac{b}{a - b}$$
(2)

である。さらに、gを非有界な領域においてax+b, a'x+b'と表される区分線形関数であるとする。この時、g(x+1) - g(x)は非有界な領域においてそれぞれ、a(x+1)+b-ax-b=a, a'となるため、gを用いて、Hを活性化関数として用いた NNを表現することができる(図 2)。したがって、補題1から非有界な領域における傾きが異なる区分線形関数を活性化関数として用いたO(n)ノード、深さ3の NN で DT を表現することができる。



図 2: g として ReLU 関数を用いた場合、活性化関数として H を用いたネットワーク (左図) は右図のネットワークで表現される

**定理 3.** n / -ドのランダムフォレスト  $RF : S \rightarrow c$  は非有界 な領域における傾きが異なる区分線形関数を活性化関数として 用いた O(n) / -ドの深さ3の NN で表現することができる。

*Proof.* ランダムフォレスト を構成するそれぞれの木に対して、 対応する NN を作成する。深さ 2 の各ノードはそれぞれ対応 する決定木の葉ノードに入力が到達したときに 1、それ以外の 場合には 0 を出力する。したがって、これらの NN の出力ノー ドを同一のノードとして見做すことで、RF に対応する NN を 得ることができる。□

これらの結果から、ランダムフォレストは深さ3のニュー ラルネットワーク以下の表現能力しか持たないこと、すなわち depth efficiency と全く同種のノードに関する効率性は存在し ないことが分かる。

#### 4. 木の本数と表現能力

#### 4.1 ノード数の下界

前節から、ランダムフォレストにおいてはニューラルネット ワークに対応する深さは固定であること、すなわち DNN と 同様の効率性は存在しないことが分かった。次に、木の本数 によって表現能力がどう変化するかの検証を行う。その為に、  $n \neq O(n)$  /ードのランダムフォレスト を T 本の木からなる ランダムフォレストで表現する際に必要となるノード数を求 める。 入力全体を X で表す。 $x \in X$  とランダムフォレストを構成 する木の各葉ノード leaf に対して、xのラベルを c(x)、leaf に割り当てられているラベルを c(leaf)、x が leaf に到達す るか否かを leaf(x) で表す。

補題 4. 次の性質を満たす集合 X を考える。この時、M = |X|とおくと X を T 本の木からなるランダムフォレストで表現するには  $\Omega(M^{\frac{2}{T+1}})$ のノードが必要である。

X を識別する任意の T 本の木からなるランダムフォレスト に対し、下記が成立する。

$$\forall x_1, x_2 \in X, c(x_1) = c(x_2) = c \rightarrow \\ |\{leaf|c(leaf) = c, leaf(x_1), leaf(x_2)\}| < \frac{T+1}{2}$$
(3)

**Proof.** 上記の性質は任意の同一ラベルを持つ異なる 2 点は、 X を認識する任意のランダムフォストにおける葉ノードのう ち半数以上に同時に正しく認識されることはないということで ある。 $L = \{leaf|c(leaf) = 1\}, l = |L|$ とする。つまり、lは ラベル 1 が割り当てられている葉の数である。同様に L'でラ ベル 0 が割り当てられている葉全体、l'でラベル 0 が割り当て られている葉の数を表す。また、 $M_1$ で  $|\{x \in X | c(x) = 1\}|$ 、  $M_0$ で  $|\{x \in X | c(x) = 0\}|$ を表す。すなわち、 $M_i$ はクラス iのデータの個数を表す。

c(x) = 1を満たす x は少なくとも  $\frac{T+1}{2}$  以上の L の要素に対して leaf(x) が成立する必要がある。一方、(3) より leaf(x) が成立する L の要素のうち、どの  $\frac{T+1}{2}$  個の葉の組み合わせも他の c(x) = 1を満たす x に対して同時に leaf(x)を満たすことはない。したがって、各  $x \in M_1$  に対し他の  $x' \in M_1$  では同時に 1 とならない  $\frac{T+1}{2}$  個の L に属する葉の組み合わせが存在するから、

$$\binom{l}{\frac{T+1}{2}} \ge M_1 \tag{4}$$

が成立する。また、ラベル0の場合も同様にして

$$\binom{l'}{\frac{T+1}{2}} \ge M_0 \tag{5}$$

が成立する。したがって、

$$l^{\frac{T+1}{2}} \ge M_1 \tag{6}$$

$$l'^{\frac{T+1}{2}} \ge M_0 \tag{7}$$

が成立する。したがって、このランダムフォレストの葉ノードの数は

$$l + l' \ge M_1 \frac{2}{T+1} + M_0 \frac{2}{T+1} \ge M \frac{2}{T+1}$$
(8)

となる。したがって、必要なノード数の下界は

$$\Omega(M^{\frac{2}{T+1}}) \tag{9}$$

この補題を用いて、 $n \pm O(n)$  ノードのランダムフォレスト を T 本の木からなるランダムフォレストで表現する際に必要 なノード数の下界を求めることができる。下界は次のように なる。 定理 5.  $n \neq O(n)$  ノードのランダムフォレスト *RF* :  $\{0,1\}^n \rightarrow \{0,1\}$ を *T*本の木からなるランダムフォレスト で表現する際に必要なノード数の下界は  $\Omega((\frac{2^n}{\sqrt{T+1}})^{\frac{2}{T+1}})$ である。

*Proof.* 任意のT (T < n) に対し、補題4の(3)の性質を満たし、 $n \neq O(n)$ ノードのランダムフォレストで識別できるXが存在することを示せばよい。各次元の要素の和が $\frac{n+1}{2}$ (ラベル1を持つ)もしくは $\frac{n+1}{2} - 1$ (ラベル0を持つ)となるn次元の0.1ベクトル全体をXと置く。

X が任意の T (T < n) に対し、(3) の性質を満たすことを 示す。X を識別する T (T < n) 本の木からなるランダムフォ レストが存在するとする。X が (3) の性質を満たさないと仮 定する。このとき、 $c(x_1) = c(x_2) = c$ を満たす、ある  $x_1, x_2$ が存在して、これらに対し  $leaf(x_1), leaf(x_2), c(leaf) = c$ を 満たす leaf が  $\frac{T+1}{2}$  個以上存在する。以降では一般性を失う ことなく c = 1 と置く。

一方、 $x_1 \neq x_2$  であるから $x_1$  で1、 $x_2$  で0となる要素が少 なくとも1つは存在し、この要素は $x_1 \ge x_2$ の両方が同じ葉 ノードに到達する木の出力に影響を与えない。したがって、 $x_1$ においてこの要素を反転させた $x_1'$ はこのランダムフォレス トにおいてラベル1と識別される。しかし、 $x_1'$ は要素の和が  $\frac{n+1}{2} - 1$  であるから、X に属し、ラベル0を持つはずである。 これは、X が T 本の木からなるランダムフォレストによって 識別されるということに矛盾する。したがって、X は (3) の 性質を満たす。

Xが $n \neq O(n)$  ノードのランダムフォレストによって識別 されるということは容易に示すことができる。それぞれの木に おいて1つの特徴量を評価し、1ならばラベル1、0ならばラ ベル0を出力すれば良い。また、

$$|X| = 2\binom{n}{\frac{n+1}{2}} \ge \frac{2^n}{\sqrt{n}} \tag{10}$$

であるから、必要なノード数の下界は

$$\Omega(\left(\frac{2^n}{\sqrt{n}}\right)^{\frac{2}{T+1}})\tag{11}$$

この定理から同じ関数を表現する際に、木の本数が n 本で あるランダムフォレストと比較して T 本の木から構成される ランダムフォレストでは多量のノードを必要とすることがある こと、すなわちランダムフォレストは木の本数に対してノード 数に関する効率性を持つことが示された。

#### 5. 結論と展望

本研究では、ランダムフォレストにおいて DNN の depth efficiency のようなノード数に関する効率性が存在するかとい うことについて考察を行った。まず、多くの区分線形関数に対 し、ランダムフォレストはその関数を活性化関数として用いた 3層のニューラルネットワーク以下の表現能力しか持たないこ とを示した。このことから、ランダムフォレストにおいては ニューラルネットワークと全く同種の効率性は存在しないこと が示された。次に、n本の木から構成されるランダムフォレス トを T 本の木から構成されるランダムフォレストで表現する 際には、T が n よりも十分に小さい場合には多くのノードが 必要となることを示した。このことから、木の本数に関しては ノード数に関する効率性が存在することが示された。今後の課

 $\square$
題としては、定理5の下界の改善、n本の木から構成されらラ ンダムフォレストをT本の木から構成されるランダムフォレ ストで表現する際に必要となるノード数の上界の導出などが考 えられる。

# 参考文献

- Guido Montufar, F., et al. "On the number of linear regions of deep neural networks." Advances in neural information processing systems. 2014. p. 2924-2932.
- [2] Maithra Raghu, et al. "On the expressive power of deep neural networks." arXiv preprint arXiv:1606.05336 (2016).
- [3] Matus Telgarsky. "Representation benefits of deep feedforward networks." arXiv preprint arXiv:1509.08101 (2015).
- [4] Lech Szymanski, and Brendan McCane. "Deep networks are effective encoders of periodicity." IEEE Transactions on Neural Networks and Learning Systems 25.10 (2014): 1816-1827.
- [5] Olivier Delalleau, and Yoshua Bengio. "Shallow vs. deep sum-product networks." Advances in Neural Information Processing Systems. 2011. p. 666-674
- [6] Yishay Mansour. "Pessimistic decision tree pruning based on tree size." In Press of Proc. 14th International Conference on Machine Learning. 1977. p.195–201.
- [7] Shalev-Shwartz, Shai, and Shai Ben-David. Understanding machine learning: From theory to algorithms. Cambridge university press, 2014. p139
- [8] Mayumi Thais Oshiro, Pedro Santoro Perez, and José Augusto Baranauskas. "How many trees in a random forest?." International Workshop on Machine Learning and Data Mining in Pattern Recognition. Springer, Berlin, Heidelberg, 2012. p. 154-168
- [9] Yoshua Bengio, Olivier Delalleau, and Clarence Simard. "Decision trees do not generalize to new variations." Computational Intelligence 26.4 (2010): 449-467.

# CTR 予測モデルの評価に AUC や log-loss は適切か?

Do the AUC and log-loss evaluate CTR prediction models properly?

片桐 智志 \*1 Satoshi Katagiri

\*<sup>1</sup>株式会社ファンコミュニケーションズ F<sup>@N</sup> Communications, Inc.

Click-through rate (CTR) prediction is one of the most important task for web advertising platform companies. However, CTR prediction is a non-standard machine learning task, so conventional metrics, for example, area under the Receiver Operating Characteristic curve (AUC), and log-loss, a.k.a. cross-entropy, and so on, can be improper. Our target is develop a new metrices for CTR prediction. In this article, we state the drawbacks of such conventional metrics and perspective of a metric based on the calibration plot approach.

## 1. はじめに

広告のリアルタイム入札システム (RTB) は、消費者が広告枠 のあるウェブページなどを閲覧するたびに、広告のリクエスト がなされ、どの広告主がページの広告枠に出稿する権利につい てオークションを自動で行い、出稿する広告を決定するシステ ムである. ここでのオークションは多くの場合, 2 番目に高い額 を提示した入札者 (広告主) が落札するという二位価格オーク ション (second-price auction) を採用している. 理論上, 二位 価格オークションでは入札者の私的価値 (private value) と一 致する価格で入札する "truth-telling 戦略" が支配戦略である [Krishna 10]. クリックに対して課金される料金体系の場合, 広 告オークションにおける私的価値とは,1回の広告表示 (インプ レッション) に対して消費者がどれくらいの確率でクリックす るかである [田頭 13]. そのため、この確率を正確に見積もるこ とは、RTB が顧客にとって有益であることに直結する. RTB プ ラットフォームを持つ多くの企業では、適切に入札のプライシン グができるように、広告表示に対する click-through 率 (CTR) を機械学習によって予測する方法を研究または導入しており、そ の先行研究だけでも枚挙に暇がない.

CTR 予測を機械学習の問題として見ると 2 値分類問題とみ なせるため、多くの研究では予測モデルの評価に area under the Receiving Operator Characteristic curve (AUC) や、対 数損失 (交差エントロピー)が用いられている.しかし、標準的 な機械学習の問題とは異なり、求められているのは予測値が正解 ラベルにどれだけ的中しているかというよりも、広告リクエス ト単位の予測確率がどれだけ適切であるか、という点である.第 2 節で詳細に述べる先行研究により、従来モデルの評価によく 用いられてきた AUC や対数損失だけでは適切に評価できない ことがわかっている.本研究では、これらを踏まえ、カリブレー ションの指標として従来から提案されている [DeGroot 83] の カリブレーションプロットや [Caruana 04] の CAL とその問 題点についても考察する.

# 連絡先: 片桐智志, 株式会社ファンコミュニケーションズ サー ビス開発部情報科学技術研究所, s katagiri@fancs.com

# 2. 先行研究のサーベイ

Microsoft の研究チームによれば [Yi 13], AUC や対数損失 などと比較して NE の性質について言及しており<sup>\*1</sup>, AUC あ るいは対数損失 (または正規化エントロピー, 以下 NE) だけで は評価指標として完全ではないとしつつも, CTR 予測精度の評 価問題に適した方法についての結論を述べていない. [He 14] で は, AUC と NE を利用しているが, NE だけではデータ全体で みたクリック率と予測値のクリック率が必ずしも近似できてい ないとして, NE に加えてデータ全体のクリック率と予測値から 計算できる期待クリック率の一致, という指標も重視している.

[Gail 05, Cook 07] では、分類モデルの出力する予測確率を 将来の病気の発病リスクとみなした場合について言及がある. 疫学分野では、ラベルに分類される確率を正しく予測すること、 正例に予測される場合のモデルの条件分布とそうでない場合の 条件分布の差別化,の3種類が要求される場合のいずれもあり えるため、[Gail 05] ではそれぞれ、accuracy、calibration (カリ ブレーション)、discrimination、と定義している. 医療を例にす ると、現時点で病気が疑われる患者を診断しすることは、予測確 率よりも陽性と陰性をどれだけはっきり区別できるかが重要な discrimination のタスクであり、一方でまだ発症していない人 が将来発症する可能性や、予後の死亡率などを知りたい(いわゆ る prognostic studies) 場合は calibration のタスクとなる. 従 来使われている AUC は discrimination に対応し、対数損失や NE は accuracy に対応する. しかし、CTR 予測について重要 となるのは、カリブレーションである.

#### 2.1 AUC の問題点

Microsoft の研究チームによれば [Yi 13], AUC は予測確率 の大きさそのものを見ないことが問題であるとしている. AUC は予測確率の絶対値ではなく,大きさでソートした際の順序を 評価していることが問題であり,実際にデータ全体のクリック 割合とクリックの予測頻度が一致しないようなモデルであって も AUC が大きくなることがある.よって,予測確率が異なる値 でも AUC は変化しない.単純な例として, $y \in \{0,1\}$ のラベ ルに対して 3 種類の予測モデルが,それぞれ予測確率  $\hat{\pi}_A$ ,  $\hat{\pi}_B$ ,  $\hat{\pi}_C$ を表1のように出力しているとする.このとき,  $\hat{\pi}_B$  は,  $\hat{\pi}_A$ 

<sup>\*1</sup> 正確には、相対情報ゲイン (RIG) についての議論だが、RIG = 1 - NE という関係が成り立つため議論内容は NE に容易に転用で きる。

| y             | 0   | 0   | 0   | 1   | 1   | 1   |
|---------------|-----|-----|-----|-----|-----|-----|
| $\hat{\pi}_A$ | 0.1 | 0.2 | 0.5 | 0.5 | 0.6 | 0.8 |
| $\hat{\pi}_B$ | 0.2 | 0.3 | 0.6 | 0.6 | 0.7 | 0.9 |
| $\hat{\pi}_C$ | 1   | 2   | 5   | 5   | 6   | 8   |
|               |     |     |     |     |     |     |

表1 AUC が変わらない例

の各値に 0.1 を足したもので,  $\hat{\pi}_C$  は  $\hat{\pi}_A$  を 10 倍にしたものだ が, それぞれの AUC は全く同じになる.

AUC はそもそも discrimination を評価する指標であり, 疾病リスクモデルの変数選択を例に, 尤度比統計量やカイニ 乗統計量と AUC とで反応の大きさの違いが指摘されている  $[Cook 07]^{*2}$ . 加えて, データの分布しだいで, AUC の事実上の 最大値が変化するという問題も, 具体例を示して指摘されてい る [Diamond 92, Gail 05].

#### 2.2 対数損失の問題点

対数損失 (交差エントロピー) も広く使われている指標である が, カリブレーションを評価するには問題がある.

たとえば, 真の確率  $\pi$  とラベル y のペアについて,  $\pi > 0.5$  ならば y = 1, そうでなければ y = 0 となる場合を考える. こ のとき,

$$(\pi_1, y_1) = (0.4, 0),$$
  
 $(\pi_2, y_2) = (0.6, 1)$ 

という 2 点だけのデータあるとする. このとき, カリブレー ションの観点からすれば, 予測モデルは真の確率に近い値を出 力するのが望ましいため,  $\hat{\pi}_1 = 0.4, \hat{\pi}_2 = 0.6$ を出力するよう なモデルが最も望ましい. このとき, 対数損失は約 0.51 となる. 一方で,  $\hat{\pi}_1 \rightarrow 0, \hat{\pi}_2 \rightarrow 1$ のときに対数損失は明らかにこれより 小さくなる. 例えば  $\hat{\pi}_1 = 0.1, \hat{\pi}_2 = 0.9$ のときに約 0.11 とな る. よって, 対数損失の小さなモデルほどカリブレーションも良 いとは限らない.

正規化エントロピー (NE) は,対数損失をデータの正例割合 に基づく対数損失で割った指標であるため,CTR 予測のよう な不均衡データに対して対数損失よりも優れているとされる [Yi 13, He 14]. しかしながら,対数損失を正規化しただけの指 標であるため,カリブレーションを評価できないという問題は NE に対してもそのまま当てはまる.

[Brier 50] による,回帰問題で使われる平均二乗誤差 (MSE) を分類問題にそのまま適用した Brier スコアもまた,同様の 問題がある.

#### 2.3 カリブレーションプロットと CAL

一方で、疫学分野では、カリブレーションの確認方法とし て、Hosmer-Lemeshow 検定が提案されている [Hosmer 89, Hosmer 80]. これはデータをいくつかのグループに分割し、そ れぞれでカイニ乗統計量を計算した和でカリブレーションがな されているかを検定する方法である.今回我々が求めているの は、AUC や対数損失に変わる相対的な指標であるので採用でき ないが、[Caruana 04] では、よく似たアイディアとして、カリブ レーションプロット [DeGroot 83] の結果に対して平均絶対誤 差 (MAE) を計算する CAL を紹介している.



図1 典型的なカリブレーション・プロットの例(左)と一律同 じ出力をする予測モデルのカリブレーションプロットの例(右)

# 3. 適切な指標はどうあるべきか

AUC や NE の問題点に対して [He 14] は, カリブレーショ ンの要件を満たすように, データのクリック頻度と予測確率に基 づく期待値とが一致しているかについても確認する方法を提案 している. しかしこれは, 膨大なデータ全体でのクリック数と予 測数の一致を見ているだけであり, 1つ1つの広告リクエストに 対する予測 CTR の精度を保証するものではない. 本研究では, 良いカリブレーションの定義として, [Gail 05] で述べられてい るものを採用する. 予測モデルが完全にカリブレーションされ ている (perfectly calibrated) とは, 特徴量 x に対して予測確 率を出力する予測関数  $\hat{f}(x)$  が, 任意の x に対して  $\pi$  の条件付 き期待値に等しい, つまり以下を満たすことを言う.

$$\hat{f}(x) := \mathbf{E}\left[\pi \mid x\right] = \int \pi dG(\pi \mid x) \tag{1}$$

ここで,  $G(\pi \mid x)$  は  $\pi$  の条件確率密度関数である. モデルが良 くカリブレーションされているかは, 実際の確率とモデルの出 力する予測確率の誤差がどれだけ小さいかで判断する. しかし, 例えば仮に平均二乗誤差 (MSE)  $N^{-1} \sum_{i=1}^{N} (\hat{f}(x_i) - \pi_i)^2$  で評 価すると, 真の確率  $\pi_i$  は観測できない. ここで  $\pi_i$  を観測可能 なラベル  $y_i$  に置き換えると, 先述の対数損失や Brier スコア の問題が発生する. この点, カリブレーションプロットや CAL は, この問題に対して, データを分割したサブグループ内での頻 度を真の確率の近似として使用していると解釈できる.

#### 4. 考察

しかしながら, CAL には次のように少なくとも 2 点の問題が 考えられる. (1) 観測点数がサブグループごとに異なるため, 相 対的に点数の多いサブグループの当てはまりが過小評価される 傾向にある, (2) 出力されるすべての予測確率が同じ値である場 合, 分位数によるサブグループによる分割ができない.

(1),(2) いずれも,分位数ではなく,観測点数が同等になるように等分割するという方法が考えられる.しかし,(2) の場合は正例の多い不均衡データにおいて一律で大きな予測確率を出力するモデリウに対しては図1のようなカリブレーションプロットを描き,CAL が良い値を示す可能性があり,NE で解消された問題が再び浮上する.

## 5. 結論と課題

本研究では、予測確率の精度を求める CTR 予測において、 AUC や 対数損失、NE だけでは評価に不十分であるというこ とを示した. 続いてカリブレーションプロットに基づく CAL について考察し、カリブレーションの指標としては問題点が残 ること示した. CAL をより適切な指標へと改善することは今後 の課題であるが、サブグループの分割方法が重要になると予想

<sup>\*2 [</sup>Cook 07] では AUC を c-統計量と呼んでいる. C は concordance の略である.

できる. 我々は CAL をに対して取り組んでいるが, 最終的な目 的は適切な評価指標の考案だけでなく, カリブレーションの良 いモデルの改良方法を開発することである.

## 参考文献

- [Brier 50] Brier, G. W.: VERIFICATION OF FORE-CASTS EXPRESSED IN TERMS OF PROBABILITY, Monthly Weather Review, Vol. 78, No. 1, pp. 1–3 (1950)
- [Caruana 04] Caruana, R. and Niculescu-Mizil, A.: Data Mining in Metric Space: An Empirical Analysis of Supervised Learning Performance Criteria, in *Proceedings* of the 2004 ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '04, pp. 69–78, Seattle, WA, USA (2004), ACM Press
- [Cook 07] Cook, N. R.: Use and Misuse of the Receiver Operating Characteristic Curve in Risk Prediction, *Circulation*, Vol. 115, No. 7, pp. 928–935 (2007)
- [DeGroot 83] DeGroot, M. H. and Fienberg, S. E.: The Comparison and Evaluation of Forecasters, *The Statistician*, Vol. 32, No. 1/2, pp. 12–22 (1983)
- [Diamond 92] Diamond, G. A.: What Price Perfection? Calibration and Discrimination of Clinical Prediction Models, *Journal of Clinical Epidemiology*, Vol. 45, No. 1, pp. 85–89 (1992)
- [Gail 05] Gail, M. H. and Pfeiffer, R. M.: On Criteria for Evaluating Models of Absolute Risk, *Biostatistics*, Vol. 6, No. 2, pp. 227–239 (2005)
- [He 14] He, X., Bowers, S., Candela, J. Q. n., Pan, J., Jin, O., Xu, T., Liu, B., Xu, T., Shi, Y., Atallah, A., and Herbrich, R.: Practical Lessons from Predicting Clicks on Ads at Facebook, in *Proceedings of 20th ACM SIGKDD Conference on Knowledge Discovery and Data Mining -ADKDD'14*, pp. 1–9, New York, NY, USA (2014), ACM Press
- [Hosmer 80] Hosmer, D. W. and Lemesbow, S.: Goodness of Fit Tests for the Multiple Logistic Regression Model, *Communications in Statistics - Theory and Meth*ods, Vol. 9, No. 10, pp. 1043–1069 (1980)
- [Hosmer 89] Hosmer, D. W. and Lemeshow, S.: Applied Logistic Regression, Wiley Series in Probability and Mathematical Statistics Applied Probability and Statistics, Wiley, New York (1989), OCLC: 19514573
- [Krishna 10] Krishna, V.: Auction Theory, Elsevier, Academic Press, Amsterdam, 2. ed edition (2010), OCLC: 845563467
- [Yi 13] Yi, J., Chen, Y., Li, J., Sett, S., and Yan, T. W.: Predictive Model Performance: Offline and Online Evaluations, in *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '13*, p. 1294, New York, New York, USA (2013), ACM Press
- [田頭 13] 田頭 幸浩,山本 浩司,小野 真吾,塚本 浩司,田島 玲: オンライン広告における CTR 予測モデルの素性評価,第 5 回データ工学と情報マネジメントに関するフォーラム (DEIM2013),郡山市,福島県 (2013)

# 補遺: 各指標の定義

#### AUC

ROC 曲線の下側の面積である.

平均自乗誤差 (MSE)・Brier スコア:

平均自乗誤差は、予測値と真値の差の2乗平均で、(2)のよう に定義される.2値分類に限定すれば、MSE と [Brier 50] によ る Brier スコアが同一のものであるのは明らかである.

Brier := 
$$MSE = \frac{1}{N} \sum_{i=1}^{N} (y_i - \hat{\pi}_i)^2$$
 (2)

対数損失 (交差エントロピー)・正規化エントロピー: 対数損失は,(3) で定義される.

$$logloss := -\frac{1}{N} \sum_{i=1} \left[ y_i \ln \hat{\pi}_i + (1 - y_i) \ln(1 - \hat{\pi}_i) \right]$$
(3)

正規化エントロピー (NE) は, 対数損失を, データ全体の正例の 割合に対する対数損失で除したものであり, (4) のように定義さ れる. ラベル数が極端に不均衡である場合, 簡単に低い対数損失 を算出できる問題があるが, NE はデータの割合で調整すること でこの問題を解消している [He 14].

$$NE := \frac{\log loss}{-(\bar{p} \ln \bar{p} + (1 - \bar{p}) \ln(1 - \bar{p}))},$$
$$\bar{p} := \frac{1}{N} \sum_{i=1}^{N} y_i$$
(4)

CAL:

予測値を十分位数を区切りに *B* 個に分割する. k 番目のビンに属する集合が  $b_k$ ,  $\sharp b_k$  はその要素数で,  $\bar{p}_k$  はそこに属する 正例ラベルの頻度とすると, CAL は, (5) のように定義される [Caruana 04].

$$CAL := \frac{1}{N} \sum_{k=1}^{B} \left| \bar{p}_k - \frac{1}{\sharp b_k} \sum_{i \in b_k} \hat{\pi}_i \right|$$
(5)

# 大局基準値共有による社会的強化学習

Social reinforcement learning with shared global aspiration for satisficing

其田憲明 \*1 Noriaki Sonota

神谷匠 \*2 Takumi Kamiya

高橋達二 \*1 Tatsuji Takahashi

\*1東京電機大学理工学部

東京電機大学大学院

School of Science and Engineering, Tokyo Denki University

Graduate School of Tokyo Denki University

When humans learn, it is not just by individual trial-and-error, but the learning is accelerated by sharing information with others. There are social learning strategies such as imitating others ' actions and emulating the high achievement of someone. As a model of social learning, sharing of state- and/or action-values are often implemented in reinforcement learning algorithms. However, sharing information of such huge amount is not realistic for a model of social learning of humans or animals. We propose an algorithm in which a mere " record " (achieved accumulated reward per episode) leads to efficient social learning. The algorithm is based on the model of satisficing integrated with different risk attitudes around the reference (aspiration level), and the conversion of the global aspiration onto each state.

# 1. はじめに

機械学習の分野の一つである強化学習では、学習を行うエー ジェントが環境との相互作用によって得られた経験から行動価 値を更新することで、収益を最大化する最適な行動系列を学習 することを目的とする.

一方で人間の学習は、ある目的水準を満たすことを目的とした場合に満足化原理[Simon 56]と呼ばれる意思決定における 損失回避の傾向がある.満足化原理とは現状の収益が基準を満 たさない場合には探索を行い、基準を満たす行動を発見した場 合にはその行動を選び続けることである.満足化原理により、 人間は効率の良い探索を行うことができると考えられている.

この満足化原理を強化学習に応用したのが Risk-sensitive Satisficing (RS) である [高橋 16]. RS は最適な基準値を与え ることで素早く最適な行動を学習し, 後悔の値を有限に抑える と証明されている [Tamatsukuri 18].

また、"keeping up with the Joneses"という慣用句が存在す るように、人間には自身を他者と社会的比較を行うことによっ て満足化の参照点が推移することが知られており、今日ではイ ンターネットの興隆などにより社会的比較の対象ははるか広範 囲に達している [Manktelow 15].

強化学習における他者との情報共有は群強化学習 [飯間 06] のように行動価値に関連したものが多い.しかし行動価値の共 有には状態行動対で情報を共有する必要があるため計算量が多 いこと,共有される情報次第では共有されたエージェントの探 索傾向に偏りが生じることで準最適解に陥る可能性があること が考えられる.このような問題に対して満足化による強化学習 を複数のエージェントで行い,状態ごとに他者のより良い成績 を自身の基準値として共有しつつ学習を行う手法が有効であ ることが示されている [其田 18].しかし,各状態ごとに行動価 値を基準値として共有していたが,現実には各状態ごとに基準 となる成績を知ることは容易ではない.一方で,100m 走のタ イムのような大局的な成績を知ることはあり,大局的な情報で あっても人間はより効果的に活用することができる [柄谷 85]. 本論文では大局的な成績から基準値の共有を行う社会的学 習を検証し,その有効性を示すことを目的とする.

# 2. 強化学習と RS 価値関数

#### 2.1 強化学習

強化学習とは学習を行うエージェントが環境との相互作用に よって、得られる報酬を最大化する行動系列の獲得を目標とす る機械学習の分野の一つである.エージェントの行動決定手法 を方策と呼び、行動価値の推定手法を価値関数と呼ぶ.強化学 習の代表的な価値推定手法である Q-learning では、時間 t に おける状態を  $s_t$ , エージェントの方策に基づいて得られる行動 を  $a_t$  としたとき、行動に対する環境からの作用として報酬  $r_t$ , 次状態  $s_{t+1}$  を観測する.行動価値  $Q(s_t, a_t)$  は学習率  $\alpha$ ,割引 率  $\gamma$  を用いることで式 1 によって更新される.

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left( r_t + \gamma \max Q(s_{t+1}) - Q(s_t, a_t) \right)$$
(1)

エージェントは行動価値 Q を利用して行動を決定する.

#### 2.2 Risk-sensitive Satisficing

Risk-sensitive Satisficing (RS) は, 状態行動対  $(s_t, a_t)$  に対 する試行量  $\tau(s_t, a_t)$  と行動価値  $Q(s_t, a_t)$ , そして状態  $s_t$  に対 して保持される満足化基準値  $\aleph(s_t)$  から, 式 2 によって RS 価 値関数が定義される.

$$RS(s_t, a_t) = \tau(s_t, a_t)(Q(s_t, a_t) - \aleph(s_t))$$
(2)

RS 方策は RS 価値関数を最大化する行動  $a_t$  を選択する方策 である.また,試行量  $\tau(s_i, a_i)$  は  $\tau_{curr}(s_t, a_t)$  と  $\tau_{port}(s_t, a_t)$ を用いて式 3 によって定義される.そして,  $\tau_{curr}(s_t, a_t)$  と  $\tau_{port}(s_t, a_t)$  は試行量割引率  $\gamma_{\tau}$ ,試行量学習率  $\alpha_{\tau}$  を用いて式 4 と式 5 によって更新される.

$$\tau(s_t, a_t) = \tau_{\text{curr}}(s_t, a_t) + \tau_{\text{post}}(s_t, a_t)$$
(3)

$$\tau_{\text{curr}}(s_t, a_t) \leftarrow \tau_{\text{curr}}(s_t, a_t) + 1$$
 (4)

$$\tau_{\text{post}}(s_t, a_t) \quad \leftarrow \quad \tau_{\text{post}}(s_t, a_t)$$

$$+ \quad \alpha_{\tau} \left( \gamma_{\tau} \tau(s_{t+1}, a_{t+1}) - \tau_{\text{post}}(s_t, a_t) \right)$$
(5)

連絡先: 高橋達二, 東京電機大学理工学部, 350-0394 埼玉県比企郡鳩山町大字石坂, 049-296-1642, tatsujit@mail.dendai.ac.jp

基準値 × に加え, 試行量 τ を用いることによって, 基準を満 たしていない非満足状態においては楽観的探索を, 基準を満た している満足状態においては悲観的活用を行う.

#### 2.3 Global Reference Conversion

強化学習に拡張された RS は各状態に基準値  $\aleph(s_i)$  を持ち, 各状態の行動価値  $Q(s_i)$  に対して適切な基準値  $\aleph(s_i)$  を与え ることで,適切に学習できることが示されている [牛田 17]. し かし,エージェントはタスク全体としての大局的な基準値を知 ることが出来たとしても,全体目標を達成するための局所的 な基準値は不明であることが多い.よって Global Reference Conversion (GRC)を用いることで,タスク全体の大局基準値  $\aleph_G$  から,式 6 によって局所的な基準値  $\aleph(s_i)$  変換を行う.

$$\delta_G = \min(E_G - \aleph_G, 0)$$
$$\max_a Q(s_i, a) - \aleph(s_i) = \zeta(s_i)\delta_G$$
$$\aleph(s_i) = \max_a Q(s_i, a) - \zeta(s_i)\delta_G \quad (6)$$

式中の $\zeta$ はスケーリングパラメータである.  $E_G$ は大局観測 期待値と呼ばれるものであり, エージェントが一定期間内に環 境から得られた累計報酬  $E_{tmp}$  と  $N_G$ を用いて式 7 で更新さ れる.

$$E_G \leftarrow \frac{E_{\rm tmp} + \gamma_G(N_G E_G)}{1 + \gamma_G N_G} \tag{7}$$

$$N_G \leftarrow 1 + \gamma_G N_G$$
 (8)

パラメータ  $\gamma_G$  は大局割引率を表し,  $0.0 \le \gamma_G \le 1.0$  の範囲 で定められる.

## 満足化基準値共有による社会的学習

[其田 18] では同一設定のタスクを複数用意し、エージェント を1体ずつ配置して並列的に学習した.エージェントN体か らなるグループのn番目のエージェントの状態 $s_i$ における最 大行動価値を $Q_n^{best}(s_i)$ とした時、式9によってグループ内で 自律的に基準値 $\aleph(s_i)$ を更新した.その結果、行動価値を直接 共有するエージェントは準最適解に陥ったが、基準値として共 有するエージェントは準最適解に陥らずに学習することに成功 した.

$$\aleph(s_i) \leftarrow \max_{n} Q_n^{best}(s_i), (\forall s) \tag{9}$$

しかし、この手法では状態  $s_i$  ごとに計算するため、状態数に 比例して情報共有に必要とする計算量が増加する問題が挙げら れる.そこで、本研究ではエージェント n 体の観測した大局観 測期待値  $E_G^n$  から式 10 のように大局基準値  $\aleph_G$  を定める.

$$\aleph_G \leftarrow \max E_G^n \tag{10}$$

この手法による,より少ない情報共有での学習の有用性を次の SuboptimaWorld タスクで評価した.

# 4. SuboptimaWorld

このタスクでは準最適解となるゴールが多数存在しており, エージェントは準最適解となるゴールを避けて,最適解となる 報酬を得られるゴールへの経路を学習することを目標とする.

#### 4.1 シミュレーション設定

図1のように縦9マス、横9マスの全81状態からなる格子 空間上で報酬が得られる経路を学習する.報酬が得られるゴー ルが8つ存在し、ゴールで得られる報酬は図1中のゴールの 数字に対応してそれぞれ1,2,...,8と得られる.またゴールを 終端状態とし、スタートからゴールにたどり着くまでを1エピ ソードとして4000エピソード行った.

提案手法である大局基準値共有を行うエージェント群を GRC グループとし、比較対象として、先行研究である 各状態の基準 値  $\aleph(s_i)$ を共有する RS グループ、最適基準を事前情報として 保持している GRC<sub>opt</sub>、そして強化学習における一般的な方策 である  $\epsilon$ -greedy を用いた.

全ての手法において学習率  $\alpha = 0.1$ ,  $\gamma = 0.9$  と設定した. 提案手法である GRC グループは大局基準値  $\aleph_G$  の初期値を 一律  $\aleph_G = 0$  とし, GRC<sub>opt</sub> の大局基準値  $\aleph_G = 8$  とした. そ して GRC グループ, GRC<sub>opt</sub> はそれぞれ  $\zeta(s_i)$  を一律 1 に,  $\alpha_{\tau} = 0.1$ ,  $\gamma_{\tau} = 0.9$ ,  $\gamma_G = 0.9$  し, エピソード単位の獲得報酬 を  $E_{tmp}$  とした. また, RS グループでの  $\tau_{\alpha} \ge \tau_{\gamma}$  は GRC グ ループと同様に設定した. そして, GRC グループと RS グルー プの基準値を共有するタイミングはどちらもグループに属する 全てのエージェントが1 エピソード終えた時点とし,基準値を共 有した後にエージェントは次のエピソードに移る.  $\epsilon$ -greedy は  $\epsilon = 1.0$  から等速度で減少させ, 2000 エピソード時点で  $\epsilon = 0$ となるように設定した.



図 1: SuboptimaWorld 概要図

# 4.2 結果

提案手法である GRC エージェントを4体とした場合の 1000 回行った平均の結果を図 2 に示す.図 2 から,最高報酬にたど り着くのが早い順から,GRC<sub>opt</sub>,GRC グループ,RS グルー プ,  $\epsilon$ -greedy となっており,  $\epsilon$ -greedy は 2000 エピソード経過 時点ではわずかに最高報酬を下回る成績であることがわかる.



そして, GRC エージェントを 1, 2, 3, 4 体とした 1000 回の 平均の結果を図 3 に示す.図 3 からエージェントが増えるごと に成績が良くなることがわかる.



図 3: 獲得平均報酬の時間発展

そして、グループで具体的にどのように学習しているかを見るための1例として、4体グループで1000エピソードを1回のみ行った場合の大局観測期待値 $E_G$ を出力したグラフを図4に示す.



図 4: 大局観測期待値 EG の時間発展

報酬7で満足していたエージェントが他者がより高い報酬 を獲得し始めた時点から再探索を行い,そして報酬8を得るこ とに成功しているのがわかる.

## 5. 考察

まずはじめに、人数が増えるごとに GRC グループの成績が 良くなることについて、非満足状態のエージェントは共有され た大局基準値 ×<sub>G</sub> 以上の報酬を得られる行動を学習するという 性質から、中には共有された大局基準値 ×<sub>G</sub> と等しい成績で満 足する場合が存在することが考えられる.しかし、グループに 属するエージェントが多いほど一度に観測される報酬のパター ンが多くなることで素早くより良い成績が得られるエージェ ントが出現する.その結果、グループの大局基準値 ×<sub>G</sub> が素早 く上昇し、グループのエージェント数が多いほど共有された大 局基準値 ×<sub>G</sub> と等しい成績に留まらず、より良い成績を発見す ることができると考えられる.

次に, 基準値の共有手法について, RS グループは行動価値か ら基準値を設定しているため, 価値更新手法の Q-learning の 行動価値の更新式の学習率の影響から満足状態のエージェント の行動価値が収束するまでの間は, 非満足状態のエージェント の行動価値は満足状態のエージェントから共有される基準値以 上の行動価値を満足状態のエージェントより少ない試行で獲得 するのが困難である.一方で GRC グループでは他者の行動価 値を直接使わずに、エピソードで得られる報酬から計算される 大局観測期待値 *E<sub>G</sub>* から基準値を更新しているため, 最適な行 動の行動価値が他の行動価値よりも高くなっていれば最適な行 動をすぐ取ることができる.したがって RS グループのように 行動価値の収束を待つ必要があるために, 基準を満たす行動系 列への収束が遅くなるということは起こりにくくなっている. しかし,準最適解で満足したエージェントのような,とある 行動系列の行動価値が他の行動価値よりも高くなってしまった 場合には,探索によって他者から共有された基準値を満たす報 酬が得られたとしても,すぐに基準を満たす行動をすることを せずに,行動価値が高い今までの準最適解への行動を選びつつ, 徐々に基準を満たす行動へと移行していることが図4から推 測できる.これはGRCが自身の最大行動価値から基準値を設 定していることと,RSグループと同様にQ-learningの行動価 値の更新式の学習率によって徐々に更新されることから生じる ものであると考えられる.したがって,価値更新手法の変更に よる,より素早い価値推定を行うことで改善が可能であると考 えられる.

## 6. おわりに

大局基準値共有を用いた社会的学習により,より限られた情報共有で学習を有効に行うことに成功した.そして,グループのエージェント数が増えることで,一定期間で探索する領域が広がり,より良い成績を素早く発見,共有することで全体での成績が向上することが判明した.今回提案した手法ではエピソード単位での獲得報酬を利用した情報を共有したため,他のアルゴリズムともグループを作ることが可能であることが考えられる.そして,今回では1エピソードごとに情報を共有していたところを,情報を共有する間隔をより疎にすることによって,さらに学習中の情報共有に必要とする計算量を減少することが可能であると考えられる.

よって今後の課題として, GRC エージェントが他のアルゴ リズムとグループを作った場合の挙動の変化の観測と, より少 ない人数での成績の向上, より疎な間隔での情報共有による学 習可能性の検証, そして今回のタスクではエージェントが確実 に報酬を得られる設計であったため, より複雑なタスクでの適 用手法を考案することが考えられる.

# 参考文献

- [Manktelow 15] Ken Manktelow : Thinking and reasoning (2012) (邦訳: 思考と推論, 服部雅史, 山祐嗣 訳: 思考と 推論 理性・判断・意思決定の心理学, 北大路書房 (2015), pp. 260-261
- [Simon 56] Simon, H.A.: Rational choice and the structure of the environment, *Psychological Review*, 63(2), 129– 138. (1956)
- [Tamatsukuri 18] Akihiro Tamatsukuri, Tatsuji Takahashi: Guaranteed satisficing and finite regret: Analysis of a cognitive satisficing value function. arXiv preprint arXiv:1812.05795, 2018.
- [飯間 06] 飯間 等 & 黒江 康明: エージェント間の情報交換に 基づく群強化学習法,計測自動制御学会論文集,42(11), 1224-1251. (2006)
- [牛田 17] 牛田有哉, 甲野佑, 高橋達二: 生存を目的とする満足 化強化学習, JSAI 2017, 4C2-2in2. (2017)
- [其田 18] 其田憲明, 神谷匠, 甲野佑, 高橋達二: 満足化基準値 共有を用いた社会的強化学習, JSAI2018 予稿集, 1N1-05. (2018)
- [高橋 16] 高橋達二,甲野佑,浦上大輔:認知的満足化 限定合 理性の強化学習における効用,人工知能学会論文誌,31(6), 1–11. (2016)
- [柄谷 85] 柄谷 行人: ブタに生れかわる話, 批評とポスト・モ ダン, pp. 257260. (1985)

# 画像の"写真らしさ"に関する数学的アプローチについて

On a mathematical approach to "photo-likeness" of images

浅尾 泰彦<sup>\*1</sup> 坂本 龍太郎<sup>\*1</sup> Yasuhiko Asao Ryotaro Sakamoto

\*1東京大学大学院数理科学研究科

Graduate School of Mathematical Science, the University of Tokyo

In image recognition, it is significant to determine the boundary between meaningful and non-meaning images. In this paper, we show a mathematical approach to this problem by defining a "quasi-photographic" image. In order to formulate the question 'What is photograph likeliness? ' mathematically, we introduce a function 'depth' that takes real values for images and analyze its asymptotic behavior. We also examine that an actual photograph is indeed a quasi-photograph. The idea of depth comes from the rank of the 0th persistent homology of a cubical complex and it can be expected that more precise classification of images can be obtained by analyzing the higher rank in the future. We also believe that it can be applied to deep learning, which is being actively utilized recently in image recognition, to selection of learning data. We would like to propose one approach of applicating pure mathematics in image recognition.

# 1. はじめに

本稿で扱う問題は、コンピュータが"内在的"にどこまで意 味のある画像とそうでないものを区別できるか? というもの である.

以下では意味のある画像のことを「写真」と呼ぶことにす る.つまり絵や数字など,我々が目にしてすぐに意味が理解で きる,もしくは意味があると判断できるもの全てを「写真」と 総称する.一方で「意味のない」画像というのは一見して意味 が理解できない,意味があると判断できないものを指す.例え ば図1右のようなモザイク画像のことを指している.

機械学習ではコンピュータに性質 A を持つ大量の類似デー タを学習させることで,新たに読み込ませたデータが性質 A を持つかどうかを判断させることができた.例えばりんごの 写真を学習させた後に図 1 右の画像を読み込ませると,コン ピュータはそれがりんごでないと判断できる.我々がここで 「内在的」と言っているのは,そのような学習の過程を経ない で,ということである.つまりりんごが何であるかを知らない 状況で,コンピュータはりんごの写真とモザイクの画像をきち んと分類することが可能であるか?また可能であれば「りん ごとモザイク」という極端な分類の他にどの程度分類が可能で あるか?

本稿では、画像の持つ数理的な性質によって特徴付けられる 「準写真」という画像のクラスを導入することで、この問題に 取り組んだ、準写真であるという性質は個々の画像に対して数 学的に有無が判別できるため上で述べた意味で内在的であり、 従ってコンピュータは学習の過程を経ずに画像を準写真とそう でないものに分類することができる.

さらに数学的に定義された準写真であるという性質は,実際の写真にもきちんと備わっていることを例で確かめることができた.

準写真は画像の「深さ」という数学的概念を定義することで 得られ,深さは近年データサイエンスの分野で広く認知されて いるパーシステントホモロジーから着想を得ている.本稿にお

坂本龍太郎: sakamoto@ms.u-tokyo.ac.jp



図 1: 右は depth が非常に大きい.

いてパーシステントホモロジーなど純粋数学で成熟した道具 を,画像認識に活用する1つのアプローチを提案したい.

## 2. 画像の深さ

#### **2.1** 画像の定式化

[0,1) で 0 以上 1 未満の実数の集合を表す. 自然数 N に対 して集合 □<sub>N</sub> を

$$\Box_N := \left\{ \frac{0}{2^N}, \frac{1}{2^N}, \dots, \frac{2^N - 1}{2^N} \right\}^2 \subseteq [0, 1) \times [0, 1).$$

で定義する.  $C = \{0, 1, ..., n-1\}$ を白黒の濃淡を表す集合 とする.  $2^N \times 2^N$  ピクセルのモノクロ画像は,写像  $\Box_N \to C$ そのものである.ここで  $2^N \times 2^N$  ピクセル画像を図 2 のよう に  $2^d \times 2^d$  分割することを考える.すなわち  $\Box_N$  の部分集合 族  $\Box_N^d$  を

$$\Box_N^d := \Big\{ \frac{1}{2^d} \Box_{N-d} + x \subseteq \Box_N \Big| x \in \Box_d \Big\}.$$

で定め非交叉和による  $2^d \times 2^d$  分割  $\Box_N = \bigsqcup_{\Box \in \Box_N^d} \Box$  を与える. 例えば、 $\Box_N^0 = \{\Box_N\}, \ \Box_N^N = \{\{x\} \mid x \in \Box_N\}$  である.

連絡先: 浅尾泰彦: asao@ms.u-tokyo.ac.jp,



図 2: 実線は□2, 点線は□2.



図 3: N = 10のキリンの画像. 左上から右下にかけて  $0 \le d \le 10$ が大きくなっていく. d = 5で初めて黒いマスが現れるので depth = 0.5 である.

#### 2.2 深さの定義

2 色モノクロ画像  $f: \Box_N \to C = \{0, 1\}$  に対して, どれくら い色の偏りがあるかを測る指標として次の関数  $\varphi_d$  を定義する.

$$\varphi_d(f) := \min_{\Box \in \Box_N^d} \left( \sum_{i,j \in \Box} |f(i) - f(j)| \right)$$

つまり  $\varphi_d$  は  $2^d \times 2^d$  分割したそれぞれのマスのうち,もっと も色が偏ったマスの偏り具合を数値として表す関数である.1 つでも「全て白(黒)」であるマスが存在すればその値は0と なる.特に  $\varphi_N = 0$  が常に成り立つ.

(2 色と限らない) 画像 f の深さを, どれくらい分割を細か くした時に ( $d \in N$  に近づけたときに) 初めて  $\varphi_d = 0$  とな るか, を測ることで定義する.

定義 1  $2^N \times 2^N$  ピクセル *n* 色画像  $f: \Box_N \to C$  に対して

$$\operatorname{depth}(f) := \frac{1}{N} \min \left\{ d \in \{0, \dots, N\} \middle| 0 = \min_{p:\operatorname{Im} f \to \{0,1\}} \varphi_d(p \circ f) \right\}$$

を f の深さという. ここで p は f の像から集合  $\{0,1\}$  への全 射全体を動く.

例えば depth(f) が 0 であることと, f が定値写像であること (つまり 1 色画像) は同値である. 逆に図 1 右のような複雑な 画像の depth は 1 となる. つまり depth は画像の複雑さを測 る指標となっている. 意味のある画像はある程度色に偏りがあ ると考えられるため depth は低いことが期待される. 図 3 は d を次第に大きくした時の  $\left(\sum_{i,j\in\square} |f(i) - f(j)|\right)_{\square \in \square_N^d}$ を色の 濃さとして表したものである. d が増加するとマスは細かくな り, 初めて真っ黒なマスが現れた時の d が depth に対応する.

## 3. 深さの漸近挙動と準写真の定義

この章では前章で定義した depth を用いて, どれくらいの 割合の画像が「とても複雑」(つまり写真らしくない)かを計 算する.それに基づいて準写真という数学的に「写真らしい」 画像のクラスを定義する.

Map( $\Box_N, C$ ) で  $\Box_N$  から C への写像全体(つまり  $2^N \times 2^N$ ピクセルモノクロ画像全体)の集合を表す.  $0 \le \alpha \le 1$ に対して depth が  $\alpha$  以下の画像全体の集合を  $\mathcal{P}_{N,C}(\alpha)$  とおく. 有限集合 X の要素の個数を #X で表すことにすれば, #Map( $\Box_N, C$ ) =  $n^{4^N}$  より, depth が  $\alpha$  以下の画像全体の割合は  $\frac{\#\mathcal{P}_{N,C}(\alpha)}{n^{4^N}}$  で ある. このとき次の計算結果を得る.

命題 1

$$\lim_{N \to +\infty} \frac{\# \mathcal{P}_{N,C}(\alpha)}{n^{4^N}} = \begin{cases} 0 & \text{if } \alpha < 1, \\ 1 & \text{if } \alpha = 1. \end{cases}$$

すなわち「ほとんど全ての画像がとても複雑」であることがわ かる.この結果は、ランダムに生成した画像が写真であること は稀有である、という我々の認識に関する直観と矛盾しない.

上の結果を # $\mathcal{P}_{N,C}(\alpha)$ の主要項の漸近挙動だと考え,第2 主要項を計算すると以下の結果を得る.

## 命題 2

$$\lim_{N \to +\infty} \frac{\# \mathcal{P}_{N,C}(1 - \alpha \frac{\log N}{N})}{n^{4^N}} = \begin{cases} 0 & \text{if } 1/\log 4 < \alpha, \\ 1 & \text{if } 0 < \alpha < 1/\log 4. \end{cases}$$

ただし log の底は 10 とする.

従って画像全体のうち depth が 1 -  $\frac{\log N}{N \log 4}$  未満であるような 「複雑すぎないもの」は非常に少ないことがわかる. 前章でも 述べたように意味のある画像は depth が低いと期待されるた め,これらを準写真と定義する.

定義 2  $2^N \times 2^N$  ピクセル n 色画像  $f: \Box_N \to C$  が

$$\operatorname{depth}(f) < 1 - \frac{\log N}{N \log 4}$$

を満たすとき, f は準写真であるという.

 $1 - \frac{\log 10}{10 \log 4} = 0.93979400086 \cdots$ より、図3のキリンの画像 (depth =  $\frac{5}{10} = 0.5$ ) は準写真である.

#### 4. 人間の認識に関する予想

図 3 では左上の真っ白な画像から始まって次第に細度が上 がっていきキリンの姿が浮かび上がり,最後には真っ黒な画像 になる.真っ黒になる 1 つ手前の画像はもうほぼ写真と変わ りないが,もう 1 つ手前までいくと写真と認識できるものの やや画質が悪いという印象を持つ.これら 11 枚の画像に真っ 白なものから順番に $\frac{0}{10}$ , $\frac{1}{10}$ ,..., $\frac{10}{10}$ と数を振ると, $\frac{s}{10} \geq \frac{9}{10}$ の 間がちょうど画質の良し悪しを判断する境目ということにな る.我々の予想はこの境目の値がおおよそ 1 -  $\frac{\log N}{N\log 4}$  に対応 するのではないかというものである.実際,前章でみたように  $1 - \frac{\log 10}{10\log 4} \sim \frac{9}{10}$  である. 予想 1 画像  $f_N = f : \Box_N \to C$  に対して画像  $f_{N-1} :$   $\Box_{N-1} \to C$ を

$$f_{N-1}(x) = \left\lfloor \frac{1}{4} \sum_{\square \in \frac{1}{2^{N-1}} \square_1 + x} f(\square) \right\rfloor \quad (x \in \square_{N-1})$$

で定義する. 帰納的に  $f_{N-i} := (f_{N-i+1})_{N-i}$  と定義する. 画像 の列  $f_N, f_{N-1}, f_{N-2}, \dots, f_0$  は次第に画質が荒くなっていくが, 画質の良し悪しの変化を認識する境目は  $\frac{k}{N} \leq 1 - \frac{\log N}{N \log 4} \leq \frac{k+1}{N}$ を満たすような  $f_k$  と  $f_{k+1}$  の間である.

# 5. パーシステントホモロジーによる高次化

パーシステントホモロジーの一般論については [H] が詳し い. depth と 0 次パーステントホモロジーとの関連を見るため に、画像  $f: \Box_N \to C$  に対して次のようなフィルター付き方 体複体  $C_d(f)$  を考える. 頂点集合は  $\Box_N$  であり、2つの相異 なる頂点 a, b はそれらがある  $\Box \in \Box_N^d$  に隣り合って含まれて いてかつ f(a) = f(b) であるときに 1 方体で結ばれていると する. 2 方体についても同様に定義する. このとき複体  $C_d(f)$ の 0 次ホモロジーの階数は d について広義単調増加関数である が、あるところから指数的に増加する. その変化の点が depth と対応する. 本研究では 0 次パーシステントホモロジーしか 考えていないが、同様にして高次の階数から画像の内在的な情 報を取り出せると期待できる.

# 6. 画像認識への応用の展望

機械学習・深層学習において,例えばコンピュータに犬と猫 の写真を分類させようとすると,必要な学習データはそれぞれ の写真 10000 枚程度とされている.10000 枚のデータを人の 手で収集し,それをコンピュータに読み込ませることはかなり のコストを費やすため近年では収集・読み込みの自動化が試み られている.一方で我々の depth を用いた方法は画像の内在 的な情報を数理的に引き出すことで画像の分類をしているた め学習データを用意する必要がない.未だ精度が荒く実用化へ の障害はあるものの,パーシステントホモロジーを始めとする 様々な数学を用いた画像認識への新たなアプローチとして期待 できると考えている.

# 7. 謝辞

本研究は数物フロンティア・リーディング大学院のプログラ ムの一つである社会数理実践研究として行われたものである. 画像認識についての解説などで尽力してくださった株式会社ニ コン研究開発本部数理科学研究所の皆様,特に深層学習との関 連や論文に対する貴重なコメントを下さった高山侑也さん,中 村ちからさんに心から感謝申し上げます.またセミナーの時間 調整や全般に関わるコメントをして頂いた東京大学数理科学研 究科特任助教(当時)の土岡俊介さんにも御礼申し上げます.

# 参考文献

[H] 平岡裕章:「タンパク質構造とトポロジー ーパーシステン トホモロジー群入門一」共立出版, 2013. General Session | General Session | [GS] J-2 Machine learning

# [3K4-J-2] Machine learning: real world interaction

Chair:Daiki Kimura Reviewer:Hikaru Kajino

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room K (201A Medium meeting room)

| [3K4-J-2-01] | Consideration on Generation of Saliency Maps in Each Action of Deep   |
|--------------|---|
|              | Reinforcement Learning Agent  |
|              | OKazuki Nagamine <sup>1</sup> , Satoshi Endo <sup>2</sup> , Koji Yamada <sup>2</sup> , Naruaki Toma <sup>2</sup> , Yuhei Akamine <sup>2</sup> (1. |
|              | Information Engineering Course, Graduate School of Engineering and Science, University of   |
|              | the Ryukyus, 2. Faculty of Engineering, School of Engineering Computer Science and  |
|              | Intelligent Systems, University of the Ryukyus)   |
|              | 3:50 PM - 4:10 PM   |
| [3K4-J-2-02] | Dynamic Reward Clustering   |
|              | ORyota Higa <sup>1</sup> , Junya Kato <sup>1</sup> (1. NEC Corporation)   |
|              | 4:10 PM - 4:30 PM   |
| [3K4-J-2-03] | A dialogue system implemented with latent parameters  |
|              | OWeida Li <sup>1</sup> , Chie Hieida <sup>2</sup> , Takayuki Nagai <sup>2</sup> (1. Seiko Gakuin High School, 2. The University                   |
|              | of Electro-Communications)  |
|              | 4:30 PM - 4:50 PM   |
| [3K4-J-2-04] | Comfortable Driving by Deep Inverse Reinforcement Learning  |
|              | ODaiko Kishikawa <sup>1</sup> , Sachiyo Arai <sup>1</sup> (1. Chiba University)   |
|              | 4:50 PM - 5:10 PM   |
| [3K4-J-2-05] | Linear function approximation of Cognitive Satiscing Function   |
|              |   |

OYu Kono<sup>1,2</sup> (1. Tokyo Denki University, 2. DeNA, Co., Ltd.) 5:10 PM - 5:30 PM

# 深層強化学習エージェントの行動別顕著性マップの生成 に関する考察

Consideration on Generation of Saliency Maps in Each Action of Deep Reinforcement Learning Agent

| 長嶺一輝*1          | 遠藤聡志*2       | 山田孝治 * <sup>2</sup> | 當間愛晃 * <sup>2</sup> | 赤嶺有平*2        |
|-----------------|--------------|---------------------|---------------------|---------------|
| Kazuki Nagamine | Satoshi Endo | Koji Yamada         | Naruaki Toma        | Yuhei Akamine |

\*1琉球大学理工学研究科情報工学専攻

Information Engineering Course, Graduate School of Engineering and Science, University of the Ryukyus

\*2琉球大学工学部工学科知能情報コース

Faculty of Engineering, School of Engineering Computer Science and Intelligent Systems, University of the Ryukyus

In recent years, deep reinforcement learning agents have surprisingly developed and achieved great results. the methods of analyzing the behaviour of agents by visualizing neural networks have been proposed. However, the methods to obtain saliency maps for each action has not been much researched. In this paper, we propose the method of generating saliency maps for each action of the agents in order to obtain deeper insight when analyzing a neural network in a deep reinforcement learning agent by visualization. We applied the proposed method to the agent which learned Atari 2600 Pong. As a result of the experiment, we obtained saliency maps which visualizes the influence of environment on each action of the agents.

# 1. はじめに

近年,深層学習の発展に伴い,強化学習に深層学習を取り 入れた深層強化学習も目覚ましい成長を見せている.一方で, 深層学習ではブラックボックス的な性質があるため、その解消 が課題となっており,深層強化学習にも同様の問題がある.例 えば、エージェントの行動のみを視認して、根拠となった画像 特徴を推測するのは困難である. これにアプローチする手法 としてニューラルネットの入出力を用いて判断根拠を可視化す る手法が提案されている [Selvaraju 17]. このような手法は深 層強化学習においてはエージェントの行動根拠の視覚化に用い られている.顕著性マップの生成は可視化手法の一つであり, エージェントが注視しているオブジェクトや学習における戦略 の変化等の分析に活用され始めている.しかし,エージェント が出力する行動価値セットに対して一つの顕著性マップを得る 手法は提案されているが、出力を行動ごとに分けて可視化す る手法は十分に研究されていない. 行動別に可視化できれば, 分析においてより深い洞察が期待できる. そこで、本研究では 既存の可視化手法を拡張して,深層強化学習エージェントの行 動ごとに顕著性マップを得る手法を提案する.また,提案した 手法を Atari 2600 の Pong を学習した深層強化学習エージェ ントに適用した結果を示し,得られた行動ごとの顕著性マップ について考察する.

# 2. 先行研究

Greydanus らは深層強化学習エージェントの行動等を分析 するために,顕著性マップを用いた可視化手法を提案してい る [Greydanus 17]. この提案手法と深層強化学習アルゴリズ ムである Asynchronous Advantage Actor-Critic (A3C) 及び Atari 2600 ゲーム環境を用いて,エージェントが注視してい る部位を可視化し,学習過程における戦略の変化等について分 析している.また,ゲームや機械学習に精通していない非エキ スパートでも,可視化結果を見ることでエージェントの行動の

連絡先: 長嶺一輝, 琉球大学理工学研究科, 〒 903-0213 沖縄 県中頭郡西原町千原 1, k188583@ie.u-ryukyu.ac.jp 解釈が容易になることを示している. Greydanus らは提案手 法を顕著性マップを生成する摂動ベースな方法と呼び,次のよ うにマップを求めている.はじめに,エージェントを十分に学 習させた後,学習を停止した状態で環境からの観測やエージェ ントが出力した行動価値等を数ステップ分保存する.次に,保 存した観測状態と次の(1)式を用いてマスク画像を作成する

$$\Phi(I_t, i, j) = I_t \odot (1 - M(i, j)) + A(I_t, \sigma_A) \odot M(i, j) \quad (1)$$

ここで、 $\Phi$ はマスク画像、 $I_t$ はステップ tにおける観測状態、 i, jはその二次元座標、 $\odot$ はアダマール積、Mはマスク、Aは ガウスフィルターでぼかした観測状態を表す。マスク画像は、 観測状態の二次元座標 i, jをマスク M の範囲でぼかしたもの で、エージェントが行動根拠とする画像特徴量を認識不可にす る効果を持つ。これと (2) 式の顕著性メトリックを用いて、画 像部位 i, jにおける顕著性スコアを計算する。顕著性スコア とは、その部位がエージェントの行動価値に及ぼす影響を数値 化したものである。

$$S(t, i, j) = \frac{1}{2} \|\pi_u(I_{1:t}) - \pi_u(I'_{1:t})\|^2$$
  
where  $I'_{1:k} = \begin{cases} \Phi(I_k, i, j) & \text{if } k = t\\ I_k & \text{otherwise} \end{cases}$  (2)

ここで, S は座標 i, j におけるスコア,  $\pi_u$  は行動価値ベクト ル,  $I_{1:t}$  は観測状態の系列を表す.このスコアを縦横数ピクセ ル間隔で求め,顕著性マップを生成する.求めたマップはリサ イズし,前処理なしの観測状態の RGB チャンネルのいずれ かと加算することで可視化する.上記の (1)(2) 式は A3C の アクターに対する顕著性スコアの計算式で,クリティックにつ いても状態価値を用いて同様に計算することができる.青がア クター,赤がクリティックの顕著性マップとして,Pong 環境 下で当手法を用いて可視化した結果を図1に示す.図1より, Pong をプレイする上で重要と考えられるブロックやパドルと いったオブジェクトをエージェントが注視していることが直感 的にわかる.

当手法がアクターの行動根拠とするオブジェクトをハイライ トしている一方で、どのオブジェクトがいずれの行動価値に貢



図 1: Greydanus らの提案手法による可視化画像

献しているかといった観察を行うことは難しい.そこで,本研 究では (2) 式の顕著性メトリックを変更して,行動別に顕著性 マップを得る手法を提案する.

# 3. 提案手法

本研究では,各行動ごとの顕著性マップを得るために,先行 研究の (2) 式の *S*(*t*,*i*,*j*) を次の (3) 式のように変更した.

$$S(a,t,i,j) = \pi_a(I_{1:t}) - \pi_a(I'_{1:t})$$
(3)

ここで、aは行動価値ベクトルのインデックス、 $\pi_a$ は行動価 値ベクトル内のaに対応する一つの行動価値を表す.この変 更により、行動別の可視化だけでなく、エージェントが注視し ている部位が行動価値に対して正負どちらの貢献をしているか 可視化することも狙った.観測状態に対する行動価値と、マス ク後の行動価値の変化及びマスク部位の行動価値に対する貢献 の関係を表1に示す.

| 表 1: 行 | 動価値と | その変化 | とマスク | P部位の貢献の | )関係 |
|--------|------|------|------|---------|-----|
| にま     | 計価店  | 行動価値 | の亦化  | 部位の香餅   |     |

| 行動価値 | 行動価値の変化 | 部位の貝厭 |
|------|---------|-------|
| 正    | 増加      | 負     |
| 正    | 減少      | 正     |
| 負    | 増加      | 負     |
| 負    | 減少      | 正     |

これは、例えば、観測状態に対する行動価値が正で、マスク後 の行動価値が増加した場合、その部位が行動価値に対して負の 影響を与ると解釈できることを表す.この表1による解釈と (3) 式を用いることでエージェントの行動別顕著性マップを生 成する手法を提案する.

## 4. 実験

本実験では提案手法により各行動ごとの顕著性マップを得る ことを目的とする.また,得られた可視化結果と図1とを比 較する.

実験設定として、本稿では学習環境に Pong を用いる. Pong には Up, Down を含む六つの行動がある. また,結果を解釈 し易くするためにオブジェクトの軌跡等の表示を追加した.

実験結果を示す.図2は、実験結果の動画から抜き出したフレームで、対戦相手が打ったボールをエージェントがパドルを 操作して打ち返そうとしている場面である.図中の茶色と白色 の部分が Pong の画像に顕著性マップを合成したもので、赤の 部位が行動価値に正の貢献を、青の部位が負の貢献をしてる.



図 2: 本研究の提案手法による可視化画像

それぞれの画像の下には行動ラベルと行動価値を,図中下部に はエージェントが取る行動とステップ数を表示している.各画 像の行動価値を見ると,Fire Down が最も高く,次に Down が高いことがわかる.反対に,Fire Up が最も低く,Up が次 に低いことがわかる.None と Fire はその中間程度の価値で ある.各画像では,None と Fire は特徴的な注視は生じてお らず,残りの四つに顕著な特徴を持った注視が生じている.一 方で,この四つは注視部位がおおよそ同じで,Fire と Down でオブジェクトの貢献が対照的になっていることがわかる.

考察を述べる.ボールの軌跡は,ボールがパドルより下に向 かっており,パドルもそれに追従するように下に向かっている. ボールはパドルから距離があり,パドルのx座標に到達するま で時間がかかることから,パドルを下に操作する Donw, Fire Down の行動価値が高いと考えられる.また,その際の顕著性 マップを見ると,ボールが正の貢献をしていることがわかる. 反対に,Up, Fire Up においてはボールが負の貢献をしてい る.これは,各オブジェクトがこの位置関係の時は,ボールが 与える貢献が行動価値に大きく影響しているためだと考えられ る.オブジェクトと各行動の関係についての洞察を得られるこ とが,提案手法の先行研究に対するアドバンテージと考える.

# 5. まとめ

本研究では,深層強化学習エージェントの行動根拠を視覚 的に分析するために,摂動ベースの顕著性マップ生成を行う既 存手法を基に,行動別の可視化を行う手法を提案した.実験で は,A3Cに提案手法を適用し,Pong環境下でのアクターの 行動別の顕著性マップを生成した.その結果,行動別に特徴的 な注視部位が生じていることを確認した.また,結果からオブ ジェクトが行動に与える影響といった,先行研究の手法では得 ることが難しい洞察を得られた.

#### 参考文献

- [Selvaraju 17] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, in Proc. of ICCV-17, pp. 618626 (2017)
- [Greydanus 17] Greydanus, S., Koul, A., Dodge, J., and Fern, A. Visualizing and Understanding Atari Agents. arXiv preprint arXiv:1711.00138 (2017)

# 動的報酬クラスタリング

# Dynamic Reward Clustering

| 比嘉  | 亮太 *1   | 加藤   | 淳也*2    |
|-----|---------|------|---------|
| Ryo | ta Higa | Juny | za Kato |

\*<sup>1</sup>NEC データサイエンス研究所 NEC Data Science Research Laboratories NEC AI ・アナリティクス事業開発本部 NEC AI Analytics Business Development Division

Real-world time series data have various patterns by the human operation. Our aim is extraction of the valuable information from the time series data with action. And we need to interpret people's policy from time series data. We propose a interpretable method for clustering the dynamic rewards from the time series data. Combining Wavelet transformation preprocessing and simple clustering methods to the human motion data and inverted pendulum simulation, our approach was successful in clustering different rewards and the interpretability of feature while maintaining the time series information.

# 1. Introduction

時間と操作を含むデータから価値のある情報を抽出するこ とは様々なサービスを提供する企業の研究として重要である。 データを取得する環境も操作する人も時間経過によって変化を する難しさがある。隣り合った時間の関係だけではなく、長期 間の関係性を抽出することも必要である。

公共施設の運用や金融など人の操作と時系列の変化は複雑 に絡まっており、直感的な判断が危険を及ぼす一方で既存の ルールベースの方法では効果的な改善が難しくなってきてい る。これはシステムの大規模化と通信の高速化による影響であ り、データに基づく自動化と支援は今後ますます必要になる。 時系列データを可視化し解釈することは、人の判断の支援に 繋がる一つの方法である。感覚的に実行してきた意思決定に 対応する方策を反映した時系列データから、数値的な指標の 一つである報酬を記述 (descriptive) する価値は計り知れない [Bazerman 06]。

操作と時間依存する観測情報を有するデータから、指標の 一つである報酬を抽出することはエージェントとシステムが相 互作用する強化学習と実社会のデータの行き来を可能にする。 環境とエージェントが相互作用する仕組の実社会システムへ の応用が広まり始めており、観測した情報から有効な状態を学 習する仕組みも報告されている [Lesort 18]。操作を含む時系 列データの問題点は、操作による非周期性がある点や系列全 体では十分なサンプルがない点である。過去のデータに基づ いて予測モデルを構築しても、別の操作が行われると全く別 のモデルになってしまう。一方で、強化学習の様にさまざまな 行動パターンを実社会で実行することは困難である。仮想環 境を構築する場合も、物理や人の心理をある程度モデル化す る必要がある。網羅的にデータが得られる場合は模倣学習に より、報酬と環境を学習するアプローチも提案されてきている [Osa 18, Baram 17, Sasaki 18] 。系列が少ない場合は仮説を 立て実験的にデータを取得して分析し解釈する必要がある。

上記の問題に取り組むために、我々は操作の影響を受けた 時系列データから報酬をクラスタリングする方法を提案する。 時系列データ全体では、同じパターンは現れないが短期的には 類似するパターンがある。研究所とデータサイエンティスト、

連絡先: 比嘉 亮太、NEC データサイエンス研究所、神奈川県 川崎市中原区下沼部 1753、email:r-higa@ct.jp.nec.com 事業部や客先との取り組みによってできた技術の一部を紹介す る。時間という物理的に素性の良い順序関係を維持しながら、 短期的なクラスタリングと非連続な時間での状態のクラスタ リングを同時に行う手法である。データ自体の意味を保持した まま、処理にも説明がつけられるシンプルな方法で構成した。 可視化することによる現象の解釈性の向上だけでなく、強化学 習の報酬設計への接続やダイナミクスの変化への遷移確率設計 にも役立つことが期待される。報酬の数値化によって行動の理 解へ繋がることも期待される。

# 2. Dynamic Reward Clustering

操作を受けた時系列データに対し系列情報を保持しながら、 報酬に対して自動クラスタリングする手法を提案する。行動や 操作は、目的を達成するための指標に基づいて行われるとす る。その指標を本論文では報酬 r として定義し、実データ分析 と強化学習の行き来が自在になるいくつかの仕組みを検討し続 けている。用語については、強化学習に従う [Sutton 18]。

#### 2.1 Background

外部からの操作の影響を受けた時系列データをs(t)とする。 時刻tにおけるi成分における観測データを $s_i(t)$ とし、全て の観測データをベクトルとしてs(t)と定める。この系列デー タは、r(s(t), a(t))に基づいて行動した方策 $\pi(a(t)|s(t))$ の影 響を受けたデータとする。方策や報酬は普遍でなく時間によっ て変化する。明示的に詳細な行動データa(t)を与えない場合 にも適用できる。

#### 2.2 Assumption

データを取得する対象となるシステムのダイナミクスは外 部からの行動によって変化する。外部への入出力の操作がない 場合は、システムのダイナミクスは変化をしないと仮定する。 例えば、波形のデータが定常である場合は外界からの操作がな く、非定常や急激な変化が生じた場合は運用の方策に変更が生 じた場合であるとする。

## 2.3 Scale-Reward Relationship

時刻依存の情報を残しながら、非周期性を考慮したスケー ルを抽出できる特徴量の設計方法を提案する。得られた特徴量 を人が読み解ける、解釈可能な指標を目指す。我々は時間方向 のラベルを維持したまま、非周期性の構造に対して有効である 手法として Wavelet 変換 (WT) を採用する [Haar 10]。時系 列データのパターンの変化が報酬や方策の変化によって生じる とし、これは波形のスケール *a* の変更と等価であるとみなす。 時刻 *t* の観測状態ベクトル *s*(*t*) の *i* 成分に対して

$$\omega_i(a,b) := \int \psi(a,b) s_i(t) \mathrm{d}t \tag{1}$$

と変換を定義する。ここで、aはスケールでありbは時刻であ り $\psi(a,b)$ は基底関数である。Scalogram 行列として

$$C := \begin{bmatrix} \boldsymbol{c}_1^{\mathrm{T}} & \boldsymbol{c}_2^{\mathrm{T}} & \cdots & \boldsymbol{c}_I^{\mathrm{T}} \end{bmatrix}$$
(2)

を定める。ただし、

$$c_i(a,b) := \left|\omega_i(a,b)\right|^2,\tag{3}$$

$$\boldsymbol{c}_{i} := \begin{bmatrix} \boldsymbol{c}_{i}(a_{1}, b_{1}) & \cdots & c_{i}(a_{1}, b_{M}) \\ \vdots & \ddots & \vdots \\ \boldsymbol{c}_{i}(a_{N}, b_{1}) & \cdots & c_{i}(a_{N}, b_{M}) \end{bmatrix}$$
(4)

と与えられる。物理学の解析で用いられるフーリエ変換 (FT) と比較した WT の利点は、非定常な変化に強く、時間情報を 保持することができる点である。静的な性質であれば FT は効 果的である。短時間フーリエ変換 (STFT) は、 $\Delta\omega\Delta t \ge 1/2$ の不確定性関係によって生じる周波数分解能と時間分解能のト レードオフがあり窓関数の幅を決められず広域な周波数間の比 較への適用は困難である。WT はスケール a により適切なト レードオフを決めることが可能になる。

#### 2.4 Dimension Reduction

高次元なデータの低次元化は、データの特徴を解釈するた めの有効な手法である。特に PCA/SVD を用いて1から3次 元といった低次元への圧縮から、報酬をどの様に抽出するの かを説明する [F.R.S. 01, Golub 13]。特異値分解 (SVD)の場 合は、

$$C = U\Lambda V^{\mathrm{T}} \tag{5}$$

と行列が分解される。時間 bを維持したまま、スケールaの 行方向に対してd次元まで削減する。 $\Lambda$ のd個までに対応す る行列  $V_d$ を元の Scalogram 行列に掛け合わせることで、

$$\tilde{C}_d = CV_d \tag{6}$$

と次元圧縮できる。スケール a 方向を2次元への圧縮すると 図1の様になる。低次元化の恩恵は、信号処理として知られ るノイズの除去に加え解釈性の向上、例えば可視化による直感 的な判断を人である分析者が行える。また、データ数に対して 表現空間が高次元になりやすい時系列データの圧縮により学習 時の次元の呪いを回避できる。

#### 2.5 Dynamic Clustering on Scale Space

データの時系列情報を保持したスケール状の空間において、 データ点のクラスタリングを行う。もっともシンプルな方法と して、k-means++に対して、上記の Scalogram による前処理 を組み合わせた手法を提案する [Arthur 07]。これは、静的な クラスタリングを時間依存を含む動的なクラスタリングへの拡 張になっている。クラスタリングを行う目的関数

$$J := \sum_{n=1}^{b_M} \sum_{k=1}^{K} \delta_{n,k} |\boldsymbol{c}_n - \boldsymbol{\mu}_k|^2$$
(7)

を最小にするクラスターにデータ点を割り当てる。ここで、 $\delta_{i,j}$ はデルタ関数であり, i = jの時 1、それ以外は 0 を与える関数 である。k-means++の場合はデータ点の順番に意味はないが、時系列データに対してはデータ点の並びと向きは重要である。 クラスタリングを行う空間に対して時系列データのスケール として与えられる空間上で行なっている。クラスター数はエル ボー法や BIC により決定できる。我々の提案手法は、操作に よってデータがどの様に分類されるのかに対する一つの解釈性 を与えることができる。詳細な内部の構造同士を比較したい場 合は、階層型クラスタリングを適用する。



図 1: 2次元のスケール空間での系列データの分類。それぞれ のクラスは異なる報酬 r<sub>1</sub>、r<sub>2</sub>によって行動したグループとし て与えられる。隣接する点だけでなく、時間的に長期の点列間 のグループ化も同時にできる。r<sub>1</sub>に含まれるデータは内部に もリング構造を持っており、より詳細な報酬関数でのクラスタ リングができることを意味している。

#### 2.6 Dynamic Reward

上記のクラスタリングにより、時系列データs(t)をスケー ル空間で分類可能になる。スケール空間が操作の影響によって 引き起こされるという仮説を用いて、クラスタリングの情報 を報酬として与える。k-means++の場合のもっとも簡単な表記 は、t = bとしてその系列データがどのセントロイド $\mu_k$ に割 り当てられるかを示せばよい。

$$r(s(t), a(t)) := f(\mu_k(\boldsymbol{s}(t))) \tag{8}$$

これは、操作の影響を受けた系列データがどのクラスに分類されるのかを表している。 $f(\mu_k(s(t)))$ は $\tilde{C}$ の固有値を返す関数とすることで、相対的な報酬間の比較ができる。例えば、クラスが $r_1 \ge r_2$ の2通りの行動を決める報酬があるとする。我々の手法は、現在の行動がどのクラスの報酬に基づいてなされたかを自動で判定することを可能にする。また、それぞれのクラスでの部分データで遷移確率を学習することもできる。過去に同じクラスに属したデータであれば、モデルを推定せずに再利用することが可能になる。Markov的な直近での分類だけでなく、時間を跨いだ長期間での系列データのグループ化も自動で可能になる。

# 2.7 Cluster and Ring

動的な報酬クラスタリングの解釈として、クラスターとリ ング構造に注目する。前者のクラスター化は類似する報酬のグ ループ化である。一方、後者のリングはある報酬のクラスター から出発して戻るという報酬間の周期性に相当するものであ る。図1はr<sub>1</sub>とr<sub>2</sub>にクラスター化され、そのクラスタ間で の時間的なループによるリング構造を示す概念図である。

#### 2.8 Joint to Dynamics model

連続性を有効活用する時系列データから常微分方程式 (ODE) [Heinonen 18, Chen 18] などの前処理として動的報酬クラス タリングを行うことでアクションの効果を含みながら有効的な サンプル数の向上とモデルの再利用性が向上する。一つの系列 として見た場合は、その場限りのモデルになるが、再生可能な ブロックでモデルを構築して組み合わせることができる。同じ 報酬に分類されるサンプルが新たに得られた場合は、モデルを 学習する必要がなくなる。また、行動によって異なるサンプル に偏るバイアスを補正する効果もある。

以下では実験において、ある時刻で変化する異なる報酬関数 によって行動するエージェントが操作したシステムの系列デー タに対して我々の提案手法の有効性を示す。

# 3. Experiment

実験の為に作成した Cart Pole データおよび、MoCap デー タ\*<sup>1</sup>を用いて提案手法の有効性を検証した。実験で用いたデー タの詳細は下記の通りであり、これらに対してアクションの自 動抽出を行った。強化学習の文脈では、時間に応じて目的が変 化するカリキュラム学習 [Sukhbaatar 17] に相当する。なお、 各データはセンサごとに平均 0、分散 1 に標準化を行った上で 使用し、k-means++のクラスター数 k は Cart Pole データに ついてはポリシーの数、MoCap データについては独自に作成 した正解ラベルの数を用いて実験を行った。また次元圧縮は PCA を使用し、圧縮後の次元数は累積寄与率が 0.95 確保さ れる数とした。

1. Cart Pole  $\vec{\tau} - \beta : t = 2000$ 

Q-learning でよく用いられる Cart Pole に対し、5 つの 異なるポリシーを学習させ各々400 エポック実行した時の Position、Velocity、Angle、Angular Velocity のデータ を繋げたデータである。

2. MoCap データ

人の動きを計測したモーションキャプチャのデータであ り、両腕と両足の4つの加速度を120フレーム/秒の間隔 で収集している。なお、今回は MoCap の中から beaks、 wings、tail feathers、claps の4つの動きからなるチキン ダンス (chicken dance: t = 1536) と、walk、run、jump、 kick、jump(left)、jump(right)、wave hands の7つの動 きからなるモーション (walks: t = 8402) の2つを使用 した。

実験の結果、chicken dance データ、walks データの各精度は、 0.700、0.860 となった。なお、精度は正解ラベル数をデータ の全体数 t で割ることで算出した。Cart Pole データについて は、各ポリシーを1 つのアクションと見做した場合の精度は 0.607 となったが、図2の使用したデータを見ればわかる通り、 実際はほぼ同じアクションをしている部分がある。その為、改 めて図2のように正解ラベルを作成し、精度を測ったところ、 0.789 という結果になった。また、Cart Pole データを2次元 スケール空間に表示し、提案手法によるクラスタリング結果に よって各点に色を付けた結果が図3 である。なお、各点の色は 図2における k-means++の結果の色と対応している。この結 果から、主要なモーションがよくまとまっている様子が確認で きた。



図 2: Cart Pole データの実験結果。上図から使用したデー タ、Position の低周波数帯の Scalogram、Velocity の低周波数 帯の Scalogram、Angle の低周波数帯の Scalogram、Angular Velocity の低周波数帯の Scalogram、正解ラベル、k-means++ の結果。

# 4. Discussion

行動の指標となる報酬と時系列データのスケールの対応関 係に基づく我々の提案手法により目的が時間に応じて変化を分 類することが確認できた。エージェントや人が学習した結果の 行動を再度データから捉え直すことに一部成功している。

アクションの変化点を抽出できていることが確認された。ま た、2次元で可視化した結果からも変化点においては点間の間 隔が広く、同じアクションをしている間は間隔が狭くまとまっ ていることから、解釈性があることも確認できた。注目すべき は図3における紫色のクラスターである。このクラスターに 該当するアクションとしては、エージェントが細かく左右に動 き、Poleの傾きをほぼ一定に保つアクションになる。然しな がら、それぞれ Poleの傾きが異なる為 Position のずれ方が異 なる状況でありながら、提案手法ではその違いを吸収しこれら を同一のアクションとして抽出できている。

<sup>\*1</sup> http://mocap.cs.cmu.edu/



図 3: Cart Pole データを 2 次元スケール空間へ圧縮した結 果。各点の色は k-means++によるクラスタリング結果に対応 し、図中の数字は時間を示す。クラスター構造の確認とその間 を行き来するリング構造が確認できる。動画として観察するこ とで、時刻変化と相対的な報酬のより明確な比較ができる。

シミュレータ上で作成されたデータだけでなく、現実の人の モーションをセンサから区別することができ、提案手法の実用 性の高さを確かめられた。

解釈性について、2次元まで次元圧縮をしたことで情報が失われてしまっている可能性も考えられる。そこで、今回使用したデータに対し PCA で2次元に圧縮した時の累積寄与率を求めたところ、Cart Pole データ、chicken dance データ、walks データの結果はそれぞれ 0.745、0.739、0.629 となった。このことからも、圧縮率が高く、また情報が失われていないことがわかる。よって、2次元に圧縮した画像を見ることで、アクションが分類された理由の解釈は十分可能である。

# 5. Conclusions

我々は操作を含む時系列データから動的に報酬をクラスタリ ングする手法を提案した。実験で紹介したデータに加え、いく つかの人の運用を含む実データに対しても我々の取り組みが有 効であることが確認できている。我々の提案手法はデータ自体 の付加価値を上げるための報酬で分割する"ハサミ"と時系列 をつなぐ"のり"に位置付けられ、DNN や HMM などの表現 力の高い学習モデルの性能をより引き出すことにも貢献でき る。また、解釈性から理解へ進める場合において、例えば物理 学で自然界を記述するハミルトニアンが重要な様に対象を記述 することが効果的であると筆者は考えている。

今後は、強化学習への実社会応用として進めている模倣学 習 [Lesort 18] を主軸とした発展を行う。また、可視化による 現状の運用比較、運用改善を利用した為替取引や HR Tech と いった応用領域を含む人やシステム間の連携がある指標を明確 化することが重要な領域へ向けて研究を継続する予定である。

# 参考文献

[Arthur 07] Arthur, D. and Vassilvitskii, S.: K-means++: The Advantages of Careful Seeding, in *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, SODA '07, pp. 1027–1035, Philadelphia, PA, USA (2007), Society for Industrial and Applied Mathematics

- [Baram 17] Baram, N., Anschel, O., Caspi, I., and Mannor, S.: End-to-End Differentiable Adversarial Imitation Learning, in Precup, D. and Teh, Y. W. eds., Proceedings of the 34th International Conference on Machine Learning, Vol. 70 of Proceedings of Machine Learning Research, pp. 390–399, International Convention Centre, Sydney, Australia (2017), PMLR
- [Bazerman 06] Bazerman, M.: Judgment in managerial decision making, J. Wiley (2006)
- [Chen 18] Chen, T. Q., Rubanova, Y., Bettencourt, J., and Duvenaud, D. K.: Neural Ordinary Differential Equations, in Bengio, S., Wallach, H., Larochelle, H., Grauman, K., Cesa-Bianchi, N., and Garnett, R. eds., Advances in Neural Information Processing Systems 31, pp. 6572–6583, Curran Associates, Inc. (2018)
- [F.R.S. 01] F.R.S., K. P.: LIII. On lines and planes of closest fit to systems of points in space, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal* of Science, Vol. 2, No. 11, pp. 559–572 (1901)
- [Golub 13] Golub, G. H. and Loan, van C. F.: Matrix Computations, JHU Press, fourth edition (2013)
- [Haar 10] Haar, A.: Zur Theorie der orthogonalen Funktionensysteme, Mathematische Annalen, Vol. 69, No. 3, pp. 331–371 (1910)
- [Heinonen 18] Heinonen, M., Yildiz, C., Mannerström, H., Intosalmi, J., and Lähdesmäki, H.: Learning unknown ODE models with Gaussian processes, in Dy, J. and Krause, A. eds., Proceedings of the 35th International Conference on Machine Learning, Vol. 80 of Proceedings of Machine Learning Research, pp. 1959–1968, Stockholmsmssan, Stockholm Sweden (2018), PMLR
- [Lesort 18] Lesort, T., Daz-Rodrguez, N., Goudou, J.-F., and Filliat, D.: State representation learning for control: An overview, *Neural Networks*, Vol. 108, pp. 379 – 392 (2018)
- [Osa 18] Osa, T., Pajarinen, J., Neumann, G., Bagnell, J., Abbeel, P., and Peters, J.: An Algorithmic Perspective on Imitation Learning, *Foundations and Trends in Robotics*, Vol. 7, No. 1-2, pp. 1–179 (2018)
- [Sasaki 18] Sasaki, F. and Kawaguchi, A.: Deterministic Policy Imitation Gradient Algorithm (2018)
- [Sukhbaatar 17] Sukhbaatar, S., Kostrikov, I., Szlam, A., and Fergus, R.: Intrinsic Motivation and Automatic Curricula via Asymmetric Self-Play, *CoRR*, Vol. abs/1703.05407, (2017)
- [Sutton 18] Sutton, R. S. and Barto, A. G.: Reinforcement Learning: An Introduction, The MIT Press, second edition (2018)

# 文章中の潜在要素を考慮した対話システム

A Dialogue System Implemented with Latent Parameters

日永田智絵\*2

Chie Hieida

李為達 \*1 Edward Li 長井隆行 \*2\*3 Takayuki Nagai

\*1聖光学院中学校高等学校 Seiko Gakuin High School \*<sup>2</sup>電気通信大学 The University of Electro-Communications

\*<sup>3</sup>大阪大学 Osaka University

When given a conversation, traditional dialogue systems mainly focus on the context that can be observed on the surface of sentences; concretely, they process and determine the output based on the grammar, visible keywords and structure of the sentence. However, the content we convey to others is affected by a multitude of latent parameters, such as emotional state, personal knowledge and personality. Therefore, we have attempted to validate the integrity of a dialogue system which takes these latent parameters into measure, and have successfully developed a dialogue system which utilizes latent parameters as input.

# 1. はじめに

近年、深層学習の発展に伴い、様々な状況における人間と の対話を目的とした対話システムの開発が進んでいる. 従来 のシステムでは、話し手が与える入力文の表層的なコンテク ストに着目し, 文章の構造やキーワードに重点を置いて出力 を生成するようなモデルが多い.一例として,二つの LSTM (Long short-term memory network) [Hochreiter97] をエン コーダーとデコーダーとしてつなげた Sequence to Sequence モデル [Sutskever14] を使用した対話システムが挙げられる [Csaky17]. Sequence to Sequence  $\forall \forall \forall h \in \mathcal{F}$ ペアを大量に学習することで片方のシーケンスからもう一方 を生成できる性質を利用して、文章の表層的なコンテキスト に着目した対話を実現することができる(図1).さらに、こ うした対話システムを応用して返答の質を上げた事例として, 2017 年にアマゾンが開催した「Alexa Prize Competition」に おいてモントリオール大学の研究室が開発した対話システム 「MILABOT」が挙げられる.これは、今までに開発されたモ デルを複数集め、各モデルの出力の中で一番質が良い返答を出 力として使用するものである [Serban17].

これらの対話システムは、入力文の表面的な要素のみに注目 しており、人同士の会話において重要な役割を果たす「感情」 などの潜在的な要素を陽に考慮していない.そのため、それら を無意識に感じる人間のように会話を行うことが難しい.そ こで本稿では、入力文から抽出できる潜在要素を陽に算出し、 それらをモデルの入力として使用した対話システムを構築し、 その有用性を検証することを目標とする.

# 2. 会話中の潜在要素

# 2.1 人間の意思決定プロセス

対話システムは人間と会話を行うためのシステムであり,人 と会話を行ったときに相手から人との区別がつかないような会 話を行うことが究極的な開発目標であると言える.対話システ ムが人間と区別がつかないようにするために必要とされる要素 は,人間が持つ要素を分析し,それらを陽にモデル化するのが 一つの方向性である.ここで,人同士で会話を行う場合に会話



図 1: Seq2Seq を使用した対話システム [Csaky17]

の進行を左右する要素として以下の4つの特徴を考える:

• 問われている返答の種類の理解

会話中に話し手が聞き手へ伝達している文章が聞き 手に何を求めているかを理解することで,聞き手はどの ような返答を行えば良いのかが理解できる.例えば,質 問を受けたときにはそれに対する答えを返すのが一般的 であるが,質問に答えずに挨拶を行うと会話としては不 適切となるため,聞き手に対する文章の,要求の分類と 検出が必要となる.

会話文中の感情の認識

話し手から同じ文を与えられても,聞き手は受けた 時の感情により返答が変化することがしばしばある.従っ て,相手と自分の感情は出力に影響を与える重要な要素 であると言うことができる.

• 会話中のキーワードに関する前提知識

人は会話内で出現するキーワードについて連想をし, 例えば話題を変えようとする時などに,それが相手への 返事に影響を与えることがある.対話システム内でもこ のプロセスを含めることで,会話を円滑に進める可能性 を残すことができる.

過去の会話文の内容の把握

人同士の会話は一文一文を単体でかけ合うというよ りも複数のやりとりから成り立つものであり, 会話中の

連絡先: 李 為達, 聖光学院中学校高等学校, 神奈川県横浜市中 区滝之上 100, liweida9@gmail.com

ある時点に至るまでのタイムステップより以前の会話の 吟味が可能でなければ、人間のような会話は実現が難し い. 会話の内容を始終まで維持するためには、この要素 が必要不可欠である.

これらの要素は単に考慮するだけでなく、総合的に考慮して 出力を考える必要がある.また、会話の経験に基づいて得た要 素に適した返答を生成する必要がある.つまり、要素をすべて 踏まえた上で、今までその人が経験してきた会話文の構造やパ ターンに基づいて返答を生成する.これらの特徴を再現するた めに、対話システムには以下の機能が必要とされると考えら れる.

• 会話文分類

人間が問われている返答を認識できるという要素を 模擬するために,入力文から問われていることを計算す る機能が必要である.

会話文中の感情検出

人間が自分の感情を認知すると共に,発現に含まれ る感情を認識しながら会話を行っているように,対話シ ステムでも同様の機能を果たすモデルが必要である.

会話に必要な前提知識

人は他人と会話を行う時に何も知識がない状態から 始まるのではなく、世間一般において常識と定義づけら れる、例えば、果物についての会話の時、「果物は食べ物 である」や、「果物は植物である」といった、ある程度の 前提知識を持っている.よって、これをシミュレートす る機能も対話システムには必要となると考えられる.

会話文貯蓄

人間が過去の会話の内容を覚えているのと同様に, 会話中のあるタイムステップに至るまでの会話の趣旨を 大まかに保存する必要がある.

• 会話文のベクトル表現

機械学習モデルが自然言語の処理を可能にするため には、文章をベクトルとして扱う必要がある.

本稿では、文章の潜在的な要素を認識するモジュールとして、上記の5つの機能に着目し、システムを構築することとした.

# 対話システムの構築

図2に、本稿で構築した対話システムのダイアグラムを示 す.タイムステップごとに入力文から返答の出力文を生成する プロセスを繰り返し、同じ会話内である限りタイムステップご との会話文を潜在空間で抽象化してできたベクトル列を保存 し、次のタイムステップで利用する.

話し手から受け取った文章を単語に分割し, GloVe[Pennington14]を用いて各単語をベクトルに変換 する.それらを集めたベクトル列を会話文のベクトル表現と して扱い,それぞれのモジュールでこのベクトル列を入力し て処理を行う.処理後に会話文から潜在要素を抽出した各モ ジュールの出力値を集め,それらを会話文を抽象化した数値 として自己組織化モジュールに入れ,出力の計算を行う.以 下,各モジュールについて説明する.



図 2: 提案するシステム

### 3.1 単語ベクトル変換モジュール

文章のままでは処理が行えないため,GloVe でワードエン ベディングを行い,ベクトル化した.本稿ではGloVe のモデ ルとして,Stanford NLP Group のウェブサイトから入手可 能な"Wikipedia 2014 + Gigaword 5"の200次元及び300 次元のバージョンを使用した.入力で受けた文章は単語と記号 をスペースで分割し,それぞれに対応したワードエンベディン グを文中の出現順にクトル化したベクトル列を構築する.構築 したベクトル列は,感情処理モジュール,文種類処理モジュー ル,会話蓄積モジュールの3つのモジュールに引き渡される.

#### **3.2** 会話文分類モジュール

ベクトル列として表現された文章の会話内における役割を, 可変長である文章を入力として受け,教師なしで潜在空間にお ける分類が可能な LSTM VAE を用いて算出する.

#### 3.3 感情検出モジュール

ベクトル列で表現された文章から算出できる相手の感情と 自分の感情を計算し,8種類の感情の中から最も近い感情を 話し手と聞き手それぞれについて出力する.モデルとしては, 可変長である文章を入力として受けることができる LSTM を 使用する.

#### 3.4 前提知識モジュール

元の英文の中でキーワードとなる単語を, Rapid Automatic Keyword Extraction algorithm [Rose10] で抽出し, それらと

関連するとされる単語の GloVe におけるベクトル表現を,最大3つまで出力する.

#### 3.5 会話蓄積モジュール

話し手と聞き手の一回のやりとりをペアとして,次のタイム ステップで使用するために保存する.これは人が会話中にキー ワードと呼ぶことができる単語を聞いた時に,無意識に連想を してしまい会話に影響を与えるような傾向があることに基づい たモジュールである.「会話の流れ」を会話蓄積モジュールの 潜在変数のベクトルを通して数値化することで,会話の進み方 を可視化するなどといった応用も可能となる.

#### 3.6 自己組織化モジュール

上記の4つのモジュールの出力を総合し、一つ一つのベクト ルが GloVe の辞書内である一つの単語に対応するようにベク トル列の形で表現された文章を出力する.モデルには、LSTM VAE を使用した.

#### 3.7 出力文潜在空間モジュール

このモジュールは、2章の中で定義される「会話の経験に基づいて、得た要素に適した返答生成」である. LSTM VAEを 用いて、あらかじめ返答文の文の構造を教師なしで学習を行う. これによって、自己組織化モジュールの出力で潜在空間が 定まれば出力文の趣旨も定まることになる.

#### 3.8 潜在空間マッパー

自己組織化モジュールで会話文中の要素をまとめたものの潜 在空間においての表現と出力文潜在空間モジュールの潜在空間 的表現の対応を学習し,新規の文の入力を受けたときに抽出さ れた要素に基づいて出力文の潜在空間的表示の生成を行う.

#### 3.9 ベクトル単語変換モジュール

単語ベクトル変換モジュールと同じように、ワードエンベ ディングのベクトルをそれらに対応した単語に変換し、組み合 わせて生成文として出力を行う.

各モジュールの学習誤差, Optimizer, ロス関数及び入力・ 出力の次元数を表1に示す.

# 4. 使用したモデルの詳細

# 4.1 LSTM

感情検出モデルに使用した LSTM は基本的に中間層を持た ず,入力は GloVe によってワードエンベディングでベクトル化 した 200 次元の単語ベクトルを可変数回受けることができる. 感情検出モデルは,感情に対応する1つの数値を出力する.

# 4.2 LSTM VAE

LSTM VAE は、一般的に使われる VAE のエンコーダーと デコーダーを LSTM で置き換えたものである.可変サイズの 入力を受けることができるエンコーダー側から出力されるベ クトル列は、入力の長さに依存せず一定の大きさの行列を出力 し、これを一般的な VAE と同様にデコーダーに入力し元の可 変長の入力を復元する.LSTM VAE の誤差は、元の潜在要素 の値の復元を行なった時の元の値と復元した値の誤差を意味す る.本稿でこれを使用した理由は、殆どの場合で可変長である 会話文を汎用的に潜在空間に変換するモデルであるためであ り、会話文分類モジュールなどに使用することができる.

# 5. 検証

#### 5.1 検証方法

モデルの会話の質を把握するための手段として,モデルの 本来の目的である人との会話を実行した. 今回は人が話し手, モデルが聞き手として人から話をかけられた時に返答を行うと いう設定のもとで検証を行なった.会話の終了の判断は,話し 手の人が不自然な会話となりつつあると感じる,または会話が 終わったことを人が自然に感じ取ることができたときとする.

#### 5.2 検証結果·考察

検証の2つの例を表2と3に示す.

一つ目の結果について,会話のやりとりを一行ずつ,2章で 触れた会話中の要素を考えながら見ていきたい.

1行目では人間は感情なしの挨拶を行ったといえる.この時, 一般的な人間は殆どの場合は同じく挨拶で返すと予想される. 人が予想する通りに,対話システムは人間の挨拶への返答を し,同じ主旨のことを聞く文を返している.2行目と3行目で は,すべて人間が返しうる返答といえるので,それぞれ適切な 出力を行ったといえる.2,3,4行目の人間が与えた文章はそ れぞれコメント,質問と賛同と概ね分類することができる.4 行目において,会話が終わってしまうような返答を人間がして いる.しかし,対話システムは話題を変えて会話を続けようと する意向が見える返答を行っている.ここでは,コメントとと もに質問を返しており,人間が会話を続けようとするときと非 常に似た形式の会話を行っているとも言える.5行目では,人 間は感情を含まない挨拶を行ってから,それに対するコメント を返しておりこれは適切な返答であると考えられる.

次に,例2について見ると,概ね例1と似た形式を取って いることがわかる.しかし,5行目において"Know you not reading?"という文法的に誤った出力を返している.この原因 として考えられるのは,学習不足である.この実験から,今回 得た対話システムはある程度の会話を実践することが可能であ り,かつ会話を継続しようとするテクニックも所持しているよ うに見受けられる.

# 6. まとめ

本稿では、人が会話中に感じると推測される潜在的要素を 陽にパラメータとした対話システムのモデルを提案した.モ デルの検証については、人が実際にインタラクションを複数回 行った時の対話システムの返答の質を特定の基準でなく、人の 感覚によって判断しているため、安定して使用できる正確な 検証方法とは言い難い.よって、今後は Conversation-turns Per Session(CPS) [Zhou18] という対話システムの会話の続行 性を測る尺度で検証を行いたいと考えている.

今回の検証から,潜在要素を意識した対話システムはある程 度人間に近いような会話を行うことができることが分かった. しかし下記の様にい,くつか疑問点が残るところがある.

• 潜在要素の影響はどれくらいあったか?

今回の対話システムでは,潜在要素をまとめる自己 組織化モジュールへの入力は受け取った入力文自体は使 用しておらず,抽出した潜在感情やキーワードなどを使 用している.しかし,使用した LSTM VAE 自体,与え られたデータへの学習の正答率は極めて高いモデルであ る.よって,今回の対話システムでも潜在要素自体が大き な意味を持ったのではなく,ただ単に使用したモデルが 与えられたデータに適応してしまった可能性がある.今 後,この点を検証する必要がある.

• 潜在要素はこれらで十分か?

今回の対話システムはある程度成功したと言うこ とができる.しかし,今回注目した潜在要素は人が意識を

| 表 1: 各モジュールの詳細          |                           |                                     |               |                       |  |
|-------------------------|---------------------------|-------------------------------------|---------------|-----------------------|--|
| Module name(Model type) | Loss                      | Loss function                       | Optimizer     | Dimentions            |  |
| 会話文分類 (LSTM VAE)        | 1.26 x 10 - 2             | KL Loss                             | RMSProp       | $300 \rightarrow 200$ |  |
| 感情検出 (LSTM)             | 1.03 x 10 - 2             | $sparce\_categorical\_crossentropy$ | AdamOptimizer | $200 \rightarrow 1$   |  |
| 自己組織化 (LSTM VAE)        | $8.7 \times 10 - 3$       | KL Loss                             | RMSProp       | $200 \rightarrow 60$  |  |
| 出力文潜在空間 (LSTM VAE)      | $4.6 \times 10 - 3$       | KL Loss                             | RMSProp       | $300 \rightarrow 200$ |  |
| 潜在空間マッパー (NN)           | $1.5918 \mathrm{x10} - 9$ | mean_squared_error                  | Adam          | $60 \rightarrow 200$  |  |

ま1.タエジョールの n =)/. //n

表 2: 人間と対話システムの会話検証: パターン1

|          | · · · · · · · · · · · · · · · · · · ·       |  |
|----------|---|--|
| Timestep | Human                                       | Dialogue System  |
| 1        | Hi, how are you today?                      | Doing great, you?  |
| 2        | I'm doing great.                            | That's nice. What do you do for work?                            |
| 3        | I code. How about you?                      | Just office work, but it is a lot.                               |
| 4        | Oh, ok. Do you enjoy your work?             | Yeah, it's quite rewarding.                                      |
| 5        | Yeah, it does pay the bills.                | When I'm not working, I play basketball. What do you do for fun? |
| 6        | I hike at the park.                         | That sounds relaxing!  |
| 7        | It keeps my mind off things. Do you travel? | Not much.  |

表 3. 人間と対話システムの会話検証・パターン2

|          | A 9. 八向と内面シバノムの云面                      |                                     |
|----------|--|-------------------------------------|
| Timestep | Human                                  | Dialogue System                     |
| 1        | Hi! How are you?                       | Hi good and you?                    |
| 2        | Great! Just ran outside.               | What do you do for a living?        |
| 3        | I am a student. How about you?         | I play basketball.                  |
| 4        | Nice! Do you love books?               | I read all the time. How about you? |
| 5        | I always liked movies more than books. | Know you not like reading?          |
| 6        | I do, but prefer the movies.           | Ok, that makes sense.               |
|          |  |                                     |

しうる要素の中の一部分であるということは容易に分か る.よって、これらの要素のみである程度の会話が可能で あるということは、人間も簡単な対話ではこの程度の要 素しか考慮していないという可能性も考えられる.この 真偽は定かでないため、今後検証の余地がある.提案モ デルは,対話文の要素を陽にモデル化しているため,対 話データの要素を解析することもできる.

対話システムの返答内容の統一性

一般的にあるデータセットを使って対話システム の学習を行うと、対話システムの返答が統一性に欠ける ことが頻繁にある.これは対話システムにおける難点の 一つであるが、今後対話システム特有の「プロフィール」 を作り、プロフィールの内容が必要とされるパターンの 検出とプロフィールに基づく返答文の生成を行う.

今後はこれらを改善する方向に研究を進めたい. また, 現時点 のモデルへ会話に影響を与えうるモジュールを加えるととも に,モデル自身のパーソナリティの固定など,より人間が持つ 特徴をモジュールの形で付け加え、さらなる検証を行うことが 今後の課題である.

# 参考文献

[Hochreiter97] S.Hochreiter, and J.Schmidhuber, "Long Short-term Memory," Neural Computation 9(8):1735-80 (1997)

- [Sutskever14] I.Sutskever, O.Vinyals, and Q.V.Le, "Sequence to Sequence Learning with Neural Networks," NIPS 2014 (2014)
- [Csaky17] R.Csaky, "Deep Learning Based Chatbot Models," Technical Report (2017)
- [Serban17] I.Serban, C.Sankar, M.Germain, S.Zhang, Z.Lin, S.Subramanian, T.Kim, M.Pieper, A.Chandar, N.Ke, S.Mudumba, A.Brebisson, J.Sotelo, D.Suhubdy, V.Michalski, A.Nguyen, J.Pineau, and Y.Bengio, "A Deep Reinforcement Learning Chatbot," CoRR2017 (2017)
- [Pennington14] J.Pennington, R.Socher, C.D.Manning, "Glove: Global Vectors for Word Representation," <https://nlp.stanford.edu/projects/glove/>, (2014)
- [Rose10] S.Rose, D.Engel, N.Cramer, and W.Cowley, "Automatic Keyword Extraction from Individual Documents," Text Mining: Applications and Theory (2010)
- [Zhou18] L.Zhou, J.Gao, D.Li, and H.Shum, "The Design and Implementation of XiaoIce, an Empathetic Social Chatbot," arXiv:1812.08989 (2018)

# 深層逆強化学習による自動運転の安心走行実現

Comfortable Driving by Deep Inverse Reinforcement Learning

岸川 大航<sup>\*1</sup> 荒井 幸代<sup>\*1</sup> Daiko Kishikawa Sachiyo Arai

\*1千葉大学大学院 融合理工学府 都市環境システム

Department of Urban Environment Systems, Graduate School of Science and Engineering, Chiba University

For the realization of automatic driving, not only safety but also comfortability of passengers is required for its application to the real society. We define it as comfortable driving. Comfortable driving is hard to define because the expectation for comfortability varies according to the designer of system. Therefore comfortable driving is difficult to code a rule-based algorithm manually. Reinforcement learning, which learns an optimal policy from trial-and-error by the agent, is an effective method to solve this problem. However it requires a reward function for the appropriate evaluation of action taken by the agent. In this paper we propose an approach to obtain comfortable driving by training with the reward function estimated from trajectories of comfortable driving, using deep inverse reinforcement learning. Experimentally we used low lateral acceleration as the condition of comfortable driving, and we were able to estimate a reward function with satisfying it.

# 1. はじめに

自動運転の実用化においては、事故を起こさず安全である ことに加えて、搭乗者にとって不快感を与えない走行が要求さ れる.これを「安心走行」と定義する.安心走行は、状況に応 じた制御を逐一記述するようなルールベース手法での実現が困 難である.これに対して、深層強化学習の導入が検討されてい る.深層強化学習は、行動を評価するスカラー値の報酬に基づ き、試行錯誤を繰り返すことで制御則を獲得する手法である. 一般的に、深層強化学習における報酬は設計者によって定義 される.しかし、安心走行の定量的な表現は困難であり、設計 者の手になる報酬では安心走行を実現できる保証はない.そこ で本論文では、深層逆強化学習によって安心走行の軌跡から推 定された報酬を用いることで、自動運転における安心走行の実 現を目的とする.

# 2. 対象問題

本論文で対象とする問題は,深層強化学習による安心走行の 学習である.深層強化学習手法には Deep Deterministic Policy Gradient (DDPG) [Lillicrap 15]を用いる. シミュレーション 環境には,オープンソースのドライビングシミュレータである TORCS (The Open Racing Car Simulator) [Wymann 00] を用いる.本論文では,TORCS に用意されている,図1の コースを用いた 600m の直進走行を扱う.



図 1: 実験で利用したコース

連絡先: 岸川大航, 荒井幸代, 千葉大学大学院 融合理工 学府 都市環境システム, 千葉市稲毛区弥生町 1-33, sachiyo@faculty.chiba-u.jp

# 3. 準備

#### 3.1 線形可解 MDP

状態  $s \in S$  の価値を V(s), 状態 s で行動  $a \in A$  を実行 して受けるコストを  $\ell(s, a)$ , 次の状態 s' への状態遷移確率を p(s'|s, a), 割引率を  $\gamma$  ( $0 < \gamma \leq 1$ ) と定義するとき, マルコ フ決定過程 (MDP) におけるベルマン方程式は式 (1) のように 表される. なお, コストは報酬の符号を反転させたものであ り, 低いほど望ましい値となる. 式 (1) は min 演算子を有す るために解析的にしか解くことができない.

$$V(s) = \min_{a} \left\{ \ell(s, a) + \sum_{s'} p(s'|s, a) \gamma V(s') \right\}$$
(1)

線形可解 MDP (LMDP) は, Todorov[Todorov 07] が提案した MDP の一種である. LMDP では, MDP における行動 *a* を実数値ベクトルである制御  $\mathbf{u} \in \mathbb{R}^{|S|}$ で定義する. 状態 *s* における  $\mathbf{u} \in \mathbf{u}_s = u(s'|s)$  とするとき, LMDP では式 (2), 式 (3) に示す二つの仮定をおく.

$$p(s'|s, \mathbf{u}_s) = \bar{p}(s'|s) \exp(\mathbf{u}_s)$$
(2)

$$\ell\left(s,\mathbf{u}_{s}\right) = q\left(s\right) + D_{\mathrm{KL}}\left(p\left(s'|s,\mathbf{u}_{s}\right) \left|\left|\bar{p}\left(s'|s\right)\right.\right)\right.$$
(3)

ここで, $\bar{p}(s'|s)$ は制御  $\mathbf{u}_s$ に依存しないsからs'への状態遷移確率,q(s)は状態依存のコスト, $D_{\mathrm{KL}}(\cdot || \cdot)$ はカルバック・ ライブラーダイバージェンスを表す.これらの仮定を式(1)に 適用し,ラグランジュの未定乗数法を用いて最小化問題を解く ことで,式(4)の線形ベルマン方程式が得られる.

$$\exp\left(-V(s)\right) = \exp\left\{-q\left(s\right)\right\} \sum_{s'} \bar{p}\left(s'|s\right) \exp\left\{-\gamma V(s')\right\}$$
(4)

このときの最適状態遷移確率  $p^*(s'|s)$  を式 (5) に示す.

$$p^{*}(s'|s) = \frac{\bar{p}(s'|s)\exp\{-\gamma V(s')\}}{\sum_{s'} \bar{p}(s'|s)\exp\{-\gamma V(s')\}}$$
(5)



図 2: LogReg-IRL による学習

#### 3.2 LogReg-IRL

Logistic Regression-Based IRL (LogReg-IRL) [Uchibe 17] は、LMDP における深層逆強化学習の一手法である.式(4) を式(5)を用いて変形すると、次の式(6)、式(7)を得る.こ こで、 $\overline{N}$ は安心走行の条件を満たさないベースライン軌跡の データ数、 $N^*$ は条件を満たすエキスパート軌跡のデータ数で ある.

$$\log \frac{p^*(s)}{\bar{p}(s)} = f(s) + \log \frac{\bar{N}}{N^*}$$
(6)

$$\log \frac{p^*(s,s')}{\bar{p}(s,s')} = f(s) - q(s) - \gamma V(s') + V(s) + \log \frac{\bar{N}}{N^*}$$
(7)

LogReg-IRL では、ロジスティック回帰 [Cox 58] を用いた密 度比推定手法である LogReg[Bickel 07] を利用して、ニューラ ルネットワークにより f(s), q(s) および V(s) を学習する.

## 4. 提案手法

本論文では、LogReg-IRLを用いて、エキスパート軌跡、及 びベースライン軌跡から報酬を推定し、深層強化学習によって 安心走行を獲得する手法を提案する.まず、LogReg-IRLを用 いて、エキスパート軌跡の集合およびベースライン軌跡の集合 から状態遷移対 (s, s')を抽出し、状態依存のコスト q(s)と状 態価値関数 V(s)を推定する.LogReg-IRLにおける学習の概 略図を図 2 に示す.

次に,学習したネットワークによって報酬を計算し,DDPG により安心走行を獲得する.推定された報酬を利用した学習の 概略図を図3に示す.報酬として,式(8)のシェーピング報酬 を用いる.LogReg-IRLではコストと状態価値関数を同時に推 定するため,シェーピング報酬の利用により学習性能が向上す ることが報告されている[Uchibe 17].

$$r(\mathbf{s}) = q(\mathbf{s}) + \gamma V(\mathbf{s}') - V(\mathbf{s}) \tag{8}$$

## 計算機実験

#### 5.1 実験設定

本実験で用いる状態入力は,TORCS に用意されている 79 次元のうち,表1に示す,運転行動に関係すると考えられる 31 次元とする.また,本実験では直進走行を扱うため,学習 による制御対象を舵角 steering の1次元とし,加速およびギ ア操作はルールベースによって制御した.

安心走行の条件は、横加速度が常に 0.3G 未満であることと する.ここで、横加速度とは、車両の進行方向を X 軸方向と



図 3: シェーピング報酬を利用した運転行動の学習

| - XI. 利用 y SIUNUS の仏窓八 | 一衣 | 衣 1: ⊼ | 判用す る | TORCS | の状態人 |
|------------------------|----|--------|-------|-------|------|
|------------------------|----|--------|-------|-------|------|

| 項目名          | 值域                      | 単位      | 説明                  |
|--------------|-------------------------|---------|---------------------|
| angle        | $[-\pi, +\pi]$          | [rad]   | 車両の角度               |
| gear         | -1, 0, 1, 2, 3, 4, 5, 6 | -       | 現在のギア               |
| rpm          | $[0, +\infty)$          | [rpm]   | エンジンの               |
|              |                         |         | 回転数                 |
| speedX       | $[-\infty, +\infty]$    | [km/h]  | X 方向速度              |
| speedY       | $[-\infty, +\infty]$    | [km/h]  | Y 方向速度              |
| speedZ       | $[-\infty, +\infty]$    | [km/h]  | Z 方向速度              |
| track1-19    | [0, 200]                | [m]     | 壁までの<br>距離<br>(図 4) |
| trackPos     | [-1+1]                  | -       | 道路中央<br>からの変位       |
| wheelSpinVel | $[0, +\infty]$          | [rad/s] | 四輪の<br>回転速度         |
| Z            | $[-\infty, +\infty]$    | [m]     | 車両重心<br>の変位         |

定義したとき,Y軸方向に発生する加速度のことである.これ は、走行中の横加速度が0.3Gを超えると,搭乗者は不快感や 恐怖心を感じるとされる [茄子川 99] ことによる.

## 5.2 エキスパート軌跡・ベースライン軌跡の生成

まず,先行研究 [北村 18] の設計報酬を用いた DDPG によ る運転行動の学習を行った.エキスパート軌跡,ベースライン 軌跡は,安心走行の条件を満たすモデルのうち最大横加速度の 小さい上位 10 モデルを利用し,各モデルの行動出力に±0.01, ±0.2 の乱数をそれぞれ加え 100 試行することで生成した.エ キスパート軌跡とベースライン軌跡における横加速度推移の一 例を図 5,図 6 に示す.横軸は総走行距離,縦軸は横加速度を 表す.なお,図中の赤線は 0.3G の基準線である.



図 4: track (19 次元)





図 6: ベースライン軌跡の横加速度推移

#### 5.3 推定された報酬による安心走行獲得

次に,生成されたエキスパート軌跡,ベースライン軌跡を用 いた LogReg-IRL の各ネットワーク f(s),q(s),V(s) の学習を 行い,LogReg-IRL により推定された報酬を用いて DDPG に よる運転行動の学習を行った.推定された報酬によって得られ たモデルの横加速度推移を図7に示す.横軸は総走行距離,縦 軸は横加速度を表す.図中の赤線は0.3Gの基準線である.得 られたモデルは走行時の最大横加速度が0.01G となり,安心 走行の条件を満たした.ゆえに,安心走行を獲得できる報酬が 推定できたといえる.

# 6. 考察

#### 6.1 LogReg-IRL における分類器の評価

まず、LogReg-IRL において、報酬・状態価値の推定に用い られる密度比推定ネットワーク f(s) がどのように学習された



図 7: 推定された報酬によるモデルの横加速度推移

| 表 2: 混回行を | 1 |  | J |
|-----------|---|--|---|
|-----------|---|--|---|

| 正解     |        | 解      | 合計     |        |
|--------|--------|--------|--------|--------|
|        |        | エキスパート | ベースライン |        |
| 予測     | エキスパート | 80131  | 444    | 80575  |
| J. 160 | ベースライン | 52474  | 141963 | 194437 |
| 合計     |        | 132605 | 142407 | 275012 |

| 表 3: 各指標の確率値 |
|--------------|
|--------------|

| 指標       | 確率     |
|----------|--------|
| 正確度      | 80.76% |
| 再現率      | 60.43% |
| 適合率      | 99.45% |
| 特異度      | 73.01% |
| F 値      | 75.18% |
| 偽ベースライン率 | 27.00% |
| 偽エキスパート率 | 0.55%  |

のかを調べた. 5.2 節の方法によって生成し, LogReg-IRL の 学習に利用しなかったエキスパート軌跡・ベースライン軌跡の データを用いて, f(s)の出力を用いたロジスティック回帰によ る分類を行った. 結果を表 2 に示す.

分類器の性能評価を,次に示す七指標を用いて行う.

- 正確度 (Accuracy) P<sub>ac</sub> · · · エキスパートをエキスパート, ベースラインをベースラインと分類できた割合
- 再現率 (Recall) P<sub>re</sub>... 実際のエキスパートをエキス パートと分類する確率
- 適合率 (Precision) P<sub>pr</sub> … エキスパートと分類した データのうち,実際にエキスパートである確率
- 特異度 (Specificity) P<sub>sp</sub> · · · ベースラインと分類した データのうち,実際にベースラインである確率
- F 値 (F-score) f · · · 再現率と適合率の調和平均
- 偽ベースライン率 P<sub>b</sub>·・・・ エキスパートをベースラインと 分類する確率
- 偽エキスパート率 P<sub>π</sub> · · · ベースラインをエキスパートと 分類する確率

正確度,再現率,適合率,特異度,F値は高いほど良く,偽 ベースライン率,偽エキスパート率は低いほど良い.表2の 混同行列を用いて計算した結果を表3に示す.

適合率と再現率はトレードオフの関係にあるが、今回の場 合再現率に比べて適合率が極めて高く、偽エキスパート率が極 めて低いため、ベースラインをエキスパートと誤って分類する ことを確実に回避するように学習しているといえる.

#### **6.2** 推定された q(s) の勾配の分析

次に,式(8)において中心となる状態依存のコストq(s)について,状態入力sの微小変化に対するq(s)の変化量である勾配 $\partial q(s)/\partial s$ を計算し,その分布を調べた.勾配の値が大きいほど,状態入力の変化に対する報酬の変化も大きくなり,報酬により強い影響を与えると考えられるためである.結果を図8に示す.

Z方向の速度である speedZ,正面方向の車両とコース端との距離である track10 には正の勾配が計算される傾向がある.

正面方向のコース端との距離は開くことが望ましく, コースア ウトの可能性を下げることができる. speedZ は, コースアウ トしたときに発生する Z 方向速度の減速を避けることでコー スアウトの可能性を下げると考えられる.

また,正面方向に対して 10 度左方向のコース端との距離 track9,正面方向に対して右側の track11~19 に負の勾配が計 算される傾向がある.これは,右側のコース端との距離から, 車両の位置による報酬を推定しているためと考えられる.実験 で利用したコースはわずかに逆 S 字状のカーブを有するコー スであり,操舵しないと 600m 区間の前半でコース左側の壁に 衝突してしまうため,コース右側に寄るような報酬が推定され ていると考えられる.

## 7. まとめ

本論文では,深層強化学習において,安心走行を獲得可能な 報酬の定義が困難であることに着目した.そこで,深層逆強化 学習で推定した報酬を用いることによって安心走行を獲得する 手法を提案した.計算機実験の結果,推定された報酬によって 安心走行を獲得することができた.

実験においては安心走行の基準を 0.3G 未満の最大横加速度 としたが、この基準は、基準を満たす軌跡を用意できるなら ば、任意に設定することができる.さらに、推定された状態依 存のコスト q(s) の勾配を分析することで、報酬の計算時に影 響を与えている状態入力を明らかにすることができる.

LogReg-IRLでは、通常の逆強化学習とは異なり、ある基準 を満たすエキスパート軌跡に加えて、基準を満たさないベース ライン軌跡が必要となるが、学習性能はベースライン軌跡に大 きく左右され、大きな課題となっている。今後の課題として、 ベースライン軌跡を必要としないような学習手法について検討 する予定である.

# 参考文献

- [Lillicrap 15] Lillicrap, T. P., et al. (2015) "Continuous control with deep reinforcement learning." arXiv preprint arXiv:1509.02971.
- [Wymann 00] Wymann, B., Espie, E., Guionneau, C., Dimitrakakis, C., Coulom, R., and Sumner, A. (2000) "TORCS, the open racing car simulator." http://torcs.sourceforge.net
- [茄子川 99] 茄子川捷久, 宮下義孝, 汐川満則. (1999)"三訂 自 動車の走行性能と試験法."山海堂, p.54.
- [Todorov 07] Todorov, E. (2007) "Linearly-solvable Markov decision problems." Advances in neural information processing systems.
- [Uchibe 17] Uchibe, E. (2017) "Model-Free Deep Inverse Reinforcement Learning by Logistic Regression." Neural Processing Letters.
- [Cox 58] Cox, D. R. (1958) "The Regression Analysis of Binary Sequences." Journal of the Royal Statistical Society. Series B (Methodological), 215-242.
- [Bickel 07] Bickel, S., Brückner, M., Scheffer, T. (2007) "Discriminative Learning for Differing Training and



図 8: 状態入力 s に対する q(s) の勾配の分布

Test Distributions." In Proceedings of the 24th international conference on Machine learning (pp. 81-88). ACM.

[北村 18] 北村清也,石川翔太,荒井幸代. (2018) "市街地の自 動運転における環境情報のフィルタリング." 2018 年度人 工知能学会全国大会.

# 認知的満足化関数の線形関数近似 - 文脈付きバンディット問題への対応 – Linear function approximation of Cognitive Satisficing Function

– To Cope with Contextual-bandit Problem –

甲野 佑\*1\*2

Kono, Yu

\*<sup>1</sup>東京電機大学理工学部 School of Science and Engineering, Tokyo Denki University \*<sup>2</sup>株式会社ディー・エヌ・エー DeNA, Co., Ltd.

Both recommendation and foraging behavior of animals are aiming to maximizing rewards through trial and error. By contrast, Maximizing reward is difficult in a complex actual world that is extremely complicated. So, The decision-making agents is considered to give priority to whether or not to achieve a specific purpose. In addition, they aim to achieve the desire level with as little information as possible. The decision-making tendency where is owned intelligent lives is called "satisficing". The RS algorithm to make choices for "satisficing" was focused in this paper, further LinRS adapted to linear approximation function was devised so that the scope of the problem is expanded to be more widely applicable. In consequence, RS became enabled to cope with the contextual-bandit problem where has application examples such as advertisement delivery. Moreover LinRS compared with familiar existing selection algorithms in simulation. The linear function approximation of LinRS realized in this study is the first step to apply a fast and efficient search algorithm by using RS that emphasizes achievement of purpose to deep reinforcement learning.

# 1. はじめに

昨今の深層学習の発展が示す通り,現代の膨大なデータを扱 う際には関数近似が必要不可欠である.しかしながら、手法に よるものの近似関数の学習には多くのデータが必要となる.機 械学習とは一般にそのようなデータからの自律的な近似関数 のパラメータの最適化と考えられているが、一方で機械学習の 中でもデータを自ら主体的に環境に働きかけて取得しなけれ ばならない強化学習も存在し,しばしば特異な存在と見なされ ている [Sutton 98]. 強化学習は報酬を最大化することを目的 に、それを達成する行動手順、方策の獲得を目的としている. つまり強化学習は様々な状態に対して適切な行動確率をエル必 要がある.そのためには様々な状態遷移を通して行動手順を試 していく必要があり、関数近似を使わないテーブル形式の学習 でさえ、膨大な繰り返しの反復試行を必要とする.一般に状態 空間は膨大で複雑であるため、その方策関数や価値関数は複雑 な関数による近似が求められる.しかしただでさえ膨大な反復 試行を必要とする上に関数近似を行うとなると, さらに"強化 学習特有の試行錯誤の回数"ד関数近似のための学習データ取 得のためのサンプリング回数"という掛け合わせにより、膨大 かつ甚大な試行時間,データ数が必要になる [Mnih 15]. 現実 の環境の複雑さを考えると, 関数近似を用いた強化学習を現実 的な時間内で行うためには、そのどちらかの高速化、軽量化が 必要となる.

近年の研究は、概ね学習やデータサンプリングを複数の計 算機に分散化することにより解決しようとしている.本研究で はそれとは対照的に、"強化学習特有の試行錯誤の回数"側を 減らすことを目的としている.人間をはじめ動物は強化学習に よって利得行動を獲得するとされている[高橋 16].しかし人 間は既存の強化学習アルゴリズムのような異常な回数の繰り 返し行動は行わない.それは知能的な構造化にも依存するが、 そもそもの意思決定傾向に違いがあると思われる.そこで本研

連絡先: 甲野 佑, 東京電機大学理工学部, 埼玉県比企郡鳩山町 大字石坂, yu.kono.02@gmail.com 究では人間の最適性より目標達成を重視した認知的満足化価値 関数 (Risk-sensitive Satisficing Value Function: RS) を用い た選択アルゴリズム (RS アルゴリズム)[高橋 16] に着目した. しかしながら RS の関数近似手法は提案されていない. そこ で本研究ではまず RS の線型近似を行い,そのアルゴリズム として LinRS (Linear RS) を考案した.また,基礎的な強化 学習課題の一つであり,広告配信などに応用される文脈付きバ ンディット問題のシミュレーションにおいて LinRS を既存ア ルゴリズムと比較し,無限の試行回数が許されていない場合で の有用性を示す.

# 特徴ベクトル上での試行錯誤: 文脈付きバンディット問題

本研究において,現在の状態(文脈)に関する特徴ベクトル が明確に与えられることを前提としたワンショットの意思決 定課題課題として, 文脈付きバンディット問題を扱う. 通常 の多腕バンディット問題ではエージェントが、未知の報酬確率  ${p_1, p_2, \ldots, p_k}$ が割り当てられた行動  ${a_1, a_2, \ldots, a_k}$ の中 から毎回一つ選択し、試行錯誤しながら得られる報酬を最大化 することを目的とした最も単純な強化学習課題である. 与えら れる報酬が1か0のベルヌーイ試行からなるものをベルヌー イバンディットと呼び、本研究ではこれを扱う.現実には選ん だ広告 (行動) がクリック (報酬) されるか否かという広告配信 などの応用例と対応づけられる.しかし広告配信の相手は常に 同じ人物とは限らない、その人物の属性(性別、年齢層、その 瞬間広告が乗るページの属性など)がわかる場合,それに応じ た配信を行うのが適切だと考えられる.この属性に応じた配信 は文脈付きバンディット問題と呼ばれる問題に相当する. 文脈 付きバンディット問題では"どの広告を配信するか"に該当す る行動集合 {a1, a2,...,ak} は通常のバンディット問題と同じ く存在する.対してその腕それぞれの行動の真の報酬関数は, その時訪れる人物 (状態 s) に応じた値として与えられる.そ の人物の属性は各次元に性別,年齢層,などの特徴量が与えら れた d 次元の特徴ベクトル x<sub>s,a</sub> によって表現される.

文脈付きバンディット問題に限らず、多数の選択肢を持つバ ンディット問題では最適な手段を知るために、現状は非最適な 行動をあえて探索的に試行する必要がある.しかし前述の通 り,高い累積報酬を得る (活用) ためにはどこかで探索を打ち 切らなければならないという速さと正確さのトレードオフを 端的に表した課題であり、探索と活用のバランシングが問題と なる.バンディット問題において、このバランシングの良し悪 しは、最適な行動が常に必ず明らかであり、それを撮り続ける 場合の累積報酬の期待値と、そのアルゴリズムの選択実績とし ての累積報酬の期待値との差分からなる regret で評価される. この regret が小さいほど, 無駄なく報酬を最大化できたこと を意味し, Upper Confidence Bound (UCB) 系のアルゴリズ ムや Thompson Sampling (TS) [Agrawal 12] などの regret をなるべく小さくすることを目的としたアルゴリズムが知ら れている. 文脈付きバンディット問題では, LinUCB[Li 10] や LinTS[Agrawal 13] など、通常のバンディット問題で扱われて いたアルゴリズムを、特徴ベクトルに対する推定をパラメー タを学習するアルゴリズムとして線形に拡張して用いられて いる.

# 3. 認知的満足化関数と RS アルゴリズム

環境への試行錯誤から良い行動手順を見つけるためには,時 にそれまでの知識を活用し,有効であるとされてきた行動の選 択肢以外の選択肢を探索してみる必要がある.無数に存在す る手順から最適なものを見つけ出すには全て試す必要があり, 組み合わせや,環境から得られる情報の不確実性からさらにそ の探索回数は増す.

それに対して、人間は必ずしも最適な行動手順を求めるわけ ではない.ある目的の達成か否か、希求水準を満たすことが重 要であり、一度見つければ基本的にはその行動を取り続ける. このような探索における意思決定における傾向を満足化と呼 ぶ.そのような希求水準を満たした・満たしていないことで価 値評価が反転する,認知的な価値関数として、満足化価値関数 (Risk-sensitive Satisficing Value Function: RS) が考案され ている [高橋 16].

$$e_a^{\rm RS} = n_a \delta_a = n_a (e_a - \aleph) \tag{1}$$

価値関数という名称だが、その性質は選択時の各行動への 評価関数である.ここで $n_a$ は行動aを試行した回数であり、  $e_a$ は行動aによって得た報酬の平均である(観測期待値).ま たその瞬間sに実行可能な行動の集合 $A_s$ の中から $e_a^{RS}$ の評 価で最大の行動aを選択する意思決定アルゴリズムをRS ア ルゴリズム(以下、断りがなければ RS は RS アルゴリズムの ことを示す)と呼ぶ、RS は非満足状況(max $_a e_a < \aleph$ )であれ ば楽観的探索を行う.すなわち試行回数 $n_a$ が少ない方が評価 が高くなることで探索を促す.一方、満足状態(max $_a e_a > \aleph$ ) は悲観的利益追求を行う、これは試行回数 $n_a$ が大きいほど評 価を高く見積もり、試行回数がポジティブフィードバック的に 増え続ける活用がなされる.

#### **3.1** 基準値と探索

基準値  $\times$  を最大の報酬確率  $p_{\text{first}}$  とその次に大きい報酬確率  $p_{\text{second}}$  の間に設定することで満足化は最適化となる。そのため、満足化基準値  $\times$  が以下のように設定された場合、最適切基準  $\aleph_{\text{opt}}$  と呼び、 $\aleph_{\text{opt}}$  を用いた RS アルゴリズムを RS-OPT アルゴリズムと呼ぶ。

$$\aleph_{\rm opt} = \frac{p_{\rm first} + p_{\rm second}}{2} \tag{2}$$

しかし, ℵ<sub>opt</sub> は報酬確率が既知のものとしているため活用 は困難である.そこで,以下のように初期値 ℵ<sub>0</sub> から基準値を 更新することで式 4 の条件を満たすことを期待する.

$$\aleph = \aleph + \alpha (e_a - \aleph) \tag{3}$$

$$p_{\text{first}} < \aleph < p_{\text{second}}$$
 (4)

式 3 によって求められる基準値  $\aleph$  は  $a_{select} = a_{first}$  である ならば  $p_{second}$  を上回るため式 4 を満たすことができる.し かし,式 3 が式 4 を満たす保証はない.

またベルヌーイバンディット問題において動的な基準値の 際適切に向けた更新式も考案されており [甲野 18],その場合 TS とほぼ互角の regret になることがシミュレーションによっ て示されている.また,同じく参考文献 [甲野 18]で,基準値  $\aleph = \infty$ である時に全ての選択肢をほぼ同配分で選択すること も知られている.すなわち  $\aleph > \max_a E$ である時は基準値  $\aleph$ は softmax 方策における温度パラメータのような役割を持ち, 高ければ高いほどランダムに近い探索を行う.

# 4. 提案アルゴリズム:LinRS

本研究では通常のバンディット問題のアルゴリズムである RS を UCB や TS と同じく線型近似関数に拡張した. LinUCB や LinTS と同じく Liner RS (LinRS) と呼ぶことにする.

# 4.1 パラメータとその更新

LinRS の計算に必要な変数として, 行動 *a* ごとに  $d \times d$  の 行列で表される  $A_a$ , d 次元のベクトルである  $b_a$ ,  $m_a$  を定義 する. ベクトル  $x_{s,a}$  は各 step で与えられる特徴ベクトル を 意味し, 変数  $r_{s,a}$  は各 step で実際に行動 *a* を選択して与え られた 0 or 1 の報酬値を表す. 変数  $u_{s,a}$  は各 step において どの選択肢を選択したかを意味し, 選択した行動 *a* に関して 1 になる.

$$\dot{A}_{a} = I + \sum_{s=1}^{t} x_{s,a} x_{s,a}^{\mathrm{T}}$$
(5)

$$b_a = \sum_{s=1}^t x_{s,a} r_{s,a} \tag{6}$$

$$m_a = \sum_{s=1}^t x_{s,a} u_{s,a}, \ u_{s,a} = \begin{cases} 1 & (a = a_{\text{select}}) \\ 0 & (otherwise) \end{cases}$$
(7)

すなわち,毎ターンインクリメントされる形で変数は更新 される.変数ベクトル  $b_a$ , $m_a$ の各次元の初期値は全て0と した.変数行列 $A_a$ の初期値は単位行列Iとした.

#### 4.2 評価関数

変数ベクトル  $b_a$ , 変数行列  $A_a$  を用いて特徴ベクトル  $x_{s,a}$  が与えられた時の報酬期待値の不偏推定量  $\hat{\theta}_a^T x_{s,a}$  が定義される.また,新たに類似度に基づいた試行回数の擬似的な量,擬 似試行回数が変数ベクトル  $m_a$ ,変数行列  $A_a$  を用いて  $\hat{\phi}_a^T x_{s,a}$  として定義する.これらの推定量と基準値  $\aleph_s$  を用いて,通常のバンディットでの評価関数である式 1 と同じ構成で,線形関数に拡張された RS の評価関数  $f_a^{RS}$  (式 10) を定義する.

$$\hat{\theta}_a = \left(\sum_{s=1}^t x_{s,a} x_{s,a}^{\mathrm{T}}\right)^{-1} \sum_{s=1}^t r_{s,a} x_{s,a}$$
$$= A_a^{-1} b_a \tag{8}$$

$$\hat{\phi}_{a} = \left(\sum_{s=1}^{i} x_{s,a} x_{s,a}^{\mathrm{T}}\right)^{-1} \sum_{s=1}^{i} n_{s,a} x_{s,a}$$
$$= A_{a}^{-1} m_{a} \tag{9}$$

$$f_a^{\rm RS} = \hat{\phi}_a^{\rm T} x_{s,a} (\hat{\theta}_a^{\rm T} x_{s,a} - \aleph_s) \tag{10}$$

LinRS では各 step において評価関数  $f_a^{RS}$  がもっとも高い 行動 a を選択する.

$$a^{\text{select}} = \arg\max_{a} \hat{\phi}_a(f_a^{\text{RS}}) \tag{11}$$

#### 4.3 3種類の基準値

LinRS も RS アルゴリズムと同じく ℵ<sub>opt</sub> の値が与えられ れば最適な選択を行うと考えられる.しかし,定常的な多本腕 バンディット問題と異なり,毎 step 異なる特徴ベクトルが与 えられた上で異なる真の報酬確率の上で選択する文脈付きバ ンディット問題では,最適な基準値が与えられることは適切で はないと考えられる.そこであらかじめ固定したパターンと, 式 3 のように更新するパターン 2 種を考案した.

### 4.3.1 固定基準値

基準値 ℵ。は特徴量, step による更新はなく, 常に固定.

#### 4.3.2 動的即時更新基準値

通常のバンディット問題の基準値の動的な更新式 3 に基づき,毎 step 意思決定毎に更新する式を以下とする.

$$\hat{\aleph}_s \leftarrow (1-\alpha)\aleph_s + \alpha \max_a \left(\hat{\theta}_a^{\mathrm{T}} x_{s,a}\right) \tag{12}$$

この基準値を用いた LinRS を本研究では Adaptive LinRS (AdaptiveLinRS) と呼ぶ.

# 4.3.3 動的な特徴ベクトルに応じた更新基準値

動的に意思決定毎に即時的に基準値を更新 (式 12) する場合,特徴ベクトル  $x_{s,a}$ の違いに対処できない.特徴ベクトル  $\phi$ での学習を行うため,  $A_a$ ,  $b_a$ を参考に, 変数行列 C と変数ベクトル d を定義し,基準値を  $\aleph$ 。を以下に定義する. パラメータ  $\alpha$  は式 12 と同じく,新規な情報に対して重み付けする更新パラメータである.通常バンディット問題における式3 や即時的な更新式3 と同じく,学習率  $\alpha$  が高ければ高いほど近視眼的な基準 (1 step 前の観測期待値)を超えるような選択肢を探すようになる.

$$C \leftarrow (1 - \alpha)C + \alpha x_{s,a} x_{s,a}^{\mathrm{T}}$$
(13)

$$d \leftarrow (1 - \alpha)d + \alpha \max_{a} \hat{\theta}_{a} \tag{14}$$

$$\hat{\aleph}_s = (C^{-1}d)^{\mathrm{T}} x_{s,a} \tag{15}$$

この基準値を用いた LinRS を本研究では Adaptive State LinRS (略記して StateLinRS) と呼ぶ.

## 5. シミュレーション設定

本研究では簡易的なシミュレーションを github にて 公開されていた python コードに追加して実験を行った [contextual bandit original source]. 毎 step 与えられる特徴 ベクトルの次元数は 16, また選択肢の数を 16 とした. シミュ レーションでは選択アルゴリズムに従い, 選択を総 step 数 と して 10,000 steps 行い, その 1,000 シミュレーション回分を 平均して regret を算出した. 選択肢の真の報酬生起確率は下 記に示される特徴ベクトルと報酬分布と毎 step サンプルし直 されるノイズ変数から決まるよう定義した.

#### 5.1 特徴ベクトルの分布と報酬関数

毎 step の特徴ベクトル *x* は step ごとに各次元が 0,1 の 一様乱数から生成されるテーブルデータとして与えられた.バ ンディットパラメータ  $\eta$  は、平均  $\mu = 0$ , 共分散は対角線の み  $\sigma = 0.01$  の対角行列として定義した.

$$\eta = \sigma \times I \tag{16}$$

それぞれの腕の報酬確率  $p_{s,s}$  はバンディットパラメータ  $\eta$ と x と,毎 step サンプリングされる平均 0 かつ 分散 0.1 の 正規分布  $\mathcal{N}(0,0.1)$  のノイズであるスカラー変数  $\epsilon$  を使い,以 下の式で定義した.

$$p_{s,a} = \text{sigmoid}(x_{s,a}^{\mathrm{T}} \eta + \epsilon) \tag{17}$$

#### 5.2 評価指標 regret

本シミュレーションの評価指標には regret (式 18) を用い た. Regret は各 step でもっとも良い選択肢を選択肢続けた 際に得られる累積報酬の期待値との差を意味する. 低ければ低 いほど無駄な探索が抑えられていることを意味し,また徐々に 対数的に収束することで,より良い選択肢を選べていることを 意味する. そのため regret が低いほど活用と探索のバランシ ングが良くできている良いアルゴリズムとされる.

$$\operatorname{regret} = \sum_{s=1}^{t} (\max p_{s,a} - p_{s,a^{\operatorname{select}}})$$
(18)

#### 5.3 比較アルゴリズム

本研究では簡易的な検証のため、LinRS と一般的な文脈付 きバンディット問題のアルゴリズムである LinUCB, LinTS と 比較を行った.また,LinRS の3種の基準値 %についても比 較を行った.

#### $\epsilon$ -greedy

確率  $\epsilon$  でランダム探索し, 確率  $1 - \epsilon$  で報酬期待値の不 偏推定量に対して最大の行動を選択 (greedy 選択) する. 本シミュレーションではパラメータ  $\epsilon = 0.1$  とする.

#### LinUCB

線形関数に拡張された UCB アルゴリズムで,分散の不 偏推定量の  $\alpha$  倍を期待値の不偏推定量に上乗せした評価 関数を用いて選択を行う.本シミュレーションではパラ メータ  $\alpha = 0.1$  とする.

#### LinTS

通常の TS を線形関数に拡張したアルゴリズムであり, TS が beta 分布から評価値をサンプリングしていたのと 異なり,多変量正規事後分布からサンプリングしている。 前述に記した LinRS, LinUCB と同じ定義の変数  $A_a$  と  $b_a$  を持つ.サンプリングに用いる多変量正規事後分布の 共分散行列,変数  $A_a$  をパラメータ  $\sigma^2$  倍したものとなっ ている.本シミュレーションではパラメータ  $\sigma = 0.1$  と する.

#### LinRS (固定基準値)

基準値 × = {0.8, 1.0, 1.2, 1.6, 2.0} でシミュレーショ ンを行った. ベルヌーイバンディットでありながら基準値 を 1.0 以上のものも用意したのは,前述した通常の RS の性質から, × >  $\max_a \hat{\theta}_a$  である場合,基準値 × が高 いほど探索が促進されるためであり,その性質を確認す るためである.

#### AdaptiveLinRS

動的な更新基準値の学習率パラメータ  $\alpha = 0.1$  とした.

#### StateLinRS

基準値推定のための変数の動的な更新のための学習率パ ラメータ α = 0.1 とした.



図 1:16 本腕,16 次元の特徴ベクトルでの regret の推移

#### 5.4 結果および考察

図 1 は regret の推移を示している. 10,000 step までい ずれの LinRS アルゴリズムは LinUCB, LinTS,  $\epsilon$ -greedy より低い regret を有している. 適当に設定した基準値  $\aleph =$ {0.8, 1.0, 1.2} においては十分に大きな回数の上で既存アル ゴリズムに比べても低い regret を有している. より長期的な step 数での regret の保証は現時点では不可能だが,現実の環 境とは常に非定常であり,特徴ベクトルからの不偏推定量では 掴みきれない変化は存在する. その時,より早く少ない regret で探索が行える性質は有用だと考えられる. しかし達成したい 目標として  $\aleph =$  {0.8, 1.0, 1.2} のいずれでも大きな差のない regret であるという範囲は通常バンディット問題での RS は曖 昧なパラメータであるとも考えられる. ただし,線型近似関数 による推定量であるがゆえ,基準値が理想基準値を有している ことが必ずしも正しいとは限らない. ゆえに max  $p_a$  より少し 高い基準値でも十分低い regret を示したのだと思われる.

また,動的な更新についてだが,AdapticeLinRSのような 即時的な基準値の更新でもLinUCBやLinTSと比べても低 い regret を示している.しかし,これは特徴ベクトルに対す る真の報酬関数にも依存するtお思われる.基準値が特徴ベク トルに依存しない以上,広告の例で言えば,まったく広告をク リックしない人間とそうでない人間が混在する状況ではあま り機能しないと思われる.そしてStateLinRSだが,LinUCB と同等よりやや低い regret に止まっている.前述の基準値が 固定な場合での考察から,高めな基準値の方が有効であると考 えられる.StateLinRSでは他の推定量と同じため,より報酬 期待値に関する推定量の上限を意識した更新式にする必要があ ると思われる.

# 6. 結論

本研究は近似関数上での一般化を目指し,RS アルゴリズム の線形近似関数に拡張した.本研究は深層強化学習などに使わ れるニューラルネットワークなどの複雑な近似関数での利用の 一時的な拡張であり,推定量に対して基準値を高めになるよう 設計する必要があるなど,有用な知見を与えた.今後の検証で より長期的な step 数,より多い行動数,より複雑な特徴ベク トルと報酬関数の関係性,より最新のアルゴリズムとの比較を 行う.その知見を通して,基準値 × の動的な更新アルゴリズ ムや,複雑な近似関数への拡張を検討していく.本研究の固定 的な基準値で低 regret を達成していることなどから,動的な 基準値でも更新アルゴリズム次第では同等の成績を有するこ とができうる可能性がある.この性質から,今後の拡張によっ て,深層強化学習上でも少ない反復回数で目的の累積報酬を達 成することが期待される.

# 参考文献

- [Sutton 98] Sutton, R. and Barto, A.: Reinforcement Learning: an Introduction, *MIT Press* (1998).
- [Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Hassabis, D., et al.: Human-level control through deep reinforcement learning, *Nature*, 518(7540), 529-533 (2015).
- [Wang 05] S. Gelly, Y. Wang., R. Munos. and O. Teytaud.: Modification of UCT with Patterns in Monte-Carlo Go, INRIA Technical Report, 6062 (2005).
- [Agrawal 12] Agrawal, S., Navin Goyal, N.: Analysis of thompson sampling for the multi-armed bandit problem, Proceedings of the 25th Annual Conference on Learning Theory (COLT) (2012).
- [高橋 16] 高橋 達二, 甲野 佑, 浦上 大輔:認知的満足化 限定合 理性の強化学習における効用, 人工知能学会論文誌, 31(6), AI30-M\_1-11. (2016)
- [甲野 13] 甲野 佑, 高橋 達二, 価値推論ヒューリスティクスと しての規準学習と忘却, Proceedings of 30 th Japanese Congnitive Science Society (JCSS), 74–79. (2013)
- [Tamatsukuri 18] Tamatsukuri, A., Takahashi, T.: Guaranteed satisficing and finite regret: Analysis of a cognitive satisficing value function, arXiv:1812.05795 (2018; manuscript under revision).
- [甲野 18] 甲野 晃弘, 高橋 達二, 満足化を通じた最適な自律的 探索, 2018 年度 人工知能学会全国大会(第 32 回)論文 集 (2018).
- [本多 16] 本多 淳也, 中村 篤祥, バンディット問題の理論とア ルゴリズム, 講談社 (2016).
- [Li 10] Li, L., Chu, W., John Langford, J., Schapire, R. E.: A contextual-bandit approach to personalized news article recommendation, *Proceedings of the 19th international conference on World wide web (WWW)*, 661– 670 (2010).
- [Agrawal 13] Agrawal, S., Goyal, N.: Thompson sampling for contextual bandits with linear payoffs, Proceedings of the 30th International Conference on Machine Learning (ICML), 127–135 (2013).
- [contextual bandit original source] Netflix も使っている! Contextual Bandit アルゴリズムを徹底解説!, https://github.com/smn-ailab/ysaito-qiita/ tree/master/multi\_armed\_bandit

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

# [3N3-J-10] Vision, speech: voice and communication

Chair:Masanori Tsujikawa Reviewer:Jun Sugiura

Thu. Jun 6, 2019 1:50 PM - 2:30 PM Room N (Front-right room of 1F Exhibition hall)

# [3N3-J-10-01] Multilingual Imputation Using Transfer Learning for Estimating Emotion from Speech

OKoichi Sakaguchi<sup>1</sup>, Shohei Kato<sup>1,2</sup> (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) 1:50 PM - 2:10 PM

# [3N3-J-10-02] Development of Open-source Multi-modal Interaction Platform for Social Experiment of Conversational User Interface OAkinobu Lee<sup>1</sup> (1. Nagoya Institute of Technology, Japan)

2:10 PM - 2:30 PM

# 音声からの感情推定における転移学習を用いた多言語補填

Multilingual Imputation Using Transfer Learning for Estimating Emotion from Speech

坂口巧一<sup>\*1</sup> 加藤昇平<sup>\*1\*2</sup> Koichi Sakaguchi 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

\*<sup>2</sup>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

Recently, vocal communication robots attract people thanks to development of AI and robot engineering. The technology of estimating emotion from speech is important to realize a smooth dialog between human and robots. This technology needs a large number of emotional speech data, but it is difficult to collect such data a lot. We investigated the effectiveness of multilingual imputation by transfer learning using 1D convolutional bidirectional LSTM. In this paper, we report the result. The result is suggested that increasing the number of languages of emotional speech learned may exceed the performance of the model learned insufficient emotional speech in single language.

# 1. はじめに

近年,ロボティクス技術とAIの発展に伴い,音声によって 人と対話するロボットが注目を集めている.人は音声対話する ときに言語情報だけでなく,声の抑揚などの非言語情報も考慮 しながら対話相手の感情を推定する.そのため,ロボットが人 と同様に音声で対話するには,そのような情報からも感情を推 定できることが望まれる.音声から感情を推定するには大量の 感情音声サンプルが必要である.しかし,感情音声を大量に集 めることは難しい.そのため,サンプル不足を補う手法が必要 と考えられる.

音声から感情を推定する研究は以前から行われている.か つては何らかの特徴抽出アルゴリズムによって複数の音声特徴 量を抽出し, Support Vector Machine (SVM) などに学習さ せて判別する手法が多かった [有本 08].近年では,ディープ ラーニングの台頭により,ニューラルネットワークに自発的に 音声特徴を学習させて判別する研究も盛んに行われるように なってきた [Dario 16] [George 16].しかし,複数の言語の音 声の感情について推定を行ったり,異言語間の感情の共通性に ついて考察している研究は少ない.

Ekman[Ekman 75] が「基本な顔表情 は文化によらず普遍 的であること」を示したことから,音声にも文化によらず共 通の特徴が存在することが期待できる.共通の特徴が存在す るならば,サンプル数の少ないある言語の感情音声データを, 別言語のデータで補填できるのではないかと考えた.本研究で は,ディープラーニングにおける多言語補完の妥当性調査を試 みた.

# 2. 提案手法

#### 2.1 音声データの前処理

音声データは、スペクトログラムに変換して1次元畳込み 双方向 Long Short Term Memory (LSTM) モデルに入力さ れる.スペクトログラムとは音声データに短時間フーリエ変 換(STFT)を行い,各周波数成分強度の時間変化を表す2次 元データである.STFTのサンプル数を882,フレーム周期を 441とし,時間長は200までとした.スペクトログラムのサイ ズはN×200とした.周波数方向をNとしたのは,次のセク ションで示す実験で周波数帯域5kHz上限と全領域(22.05kHz) の場合で比較を行うためである.5kHz上限の場合はN=101, 全領域の場合はN=442となる.これにz-score 正規化を施し たものを,1タイムステップ毎に分割して1次元畳込み双方 向LSTMモデルに入力する.なお,感情音声データは日本語, 韓国語,アメリカ英語の感情音声の5感情「怒り」「悲しみ」 「喜び」「嫌悪」「驚き」を使用した.

#### 2.2 1次元畳込み双方向 LSTM

提案モデルである転移学習モデルの事前学習,および比較 手法である単一言語の感情音声のみを学習するモデル(単一言 語モデル)には1次元畳込み双方向LSTMを用いた.

1 次元畳込み双方向 LSTM は、1 次元畳込み部と双方向 LSTM,全結合層の3つからなる.1 次元畳込み部は、1 次元 畳込み層とプーリング層の組み合わせからなる部分であり、特 徴の鋭敏化と次元圧縮を行う.LSTM は、適切な過去の入力 を保存することで、時間依存性の強いデータに対して効果を 発揮する.一般的な LSTM は過去から未来への一方向の流れ のみを考慮するが、双方向 LSTM は未来から過去への方向も 考慮する.具体的なパラメータは表1のようになる.誤差関 数は categorical crossentropy を用いた.最適化アルゴリズム には Nesterov accelerated gradient(NAG)[Nesterov 83] を用 い、学習率を 0.01 とし、epoch ごとに学習率を 1e<sup>-6</sup> ずつ減 衰し、momentum 項のパラメータを 0.9 とした.

#### 2.3 転移学習モデル

ある言語の感情音声データを別の言語の感情音声データで 補填する手法として転移学習を利用した.このモデルは,特徴 抽出部と判別部の2つからなる.

特徴抽出部には、1次元畳み込み双方向 LSTM を用いる.各 言語の感情音声で学習を行い、学習済モデル(日)、(韓)、(英) を作成する.データを 8:2 の割合で学習データとテストデータ に分け、学習データのうち 2 割を検証用データとする学習を

連絡先: 坂口巧一,名古屋工業大学,〒466-8555名古屋市昭 和区御器所町, sakaguchi@katolab.nitech.ac.jp

表 1:1 次元畳込み双方向 LSTM 詳細

| パラメータ設定    |                               |  |  |  |
|------------|-------------------------------|--|--|--|
| 入力層        | 入力サイズ:N×200 タイムステップ           |  |  |  |
|            | 上限 22.05kHz:N=442, 5kHz:N=101 |  |  |  |
| 畳み込み層 1    | フィルタ:(4,1) × 16               |  |  |  |
|            | 活性化関数:ReLu, バッチ正規化あり          |  |  |  |
| 畳み込み層 2    | 畳み込み層 1 と同様                   |  |  |  |
| 最大プーリング層1  | プールサイズ:2,ストライド 2              |  |  |  |
|            | ドロップアウト率:0.25                 |  |  |  |
| 畳み込み層 3    | 畳み込み層 1 と同様                   |  |  |  |
| 最大プーリング層 2 | プールサイズ:2,ストライド 2              |  |  |  |
| 平滑化層       | タイムステップごとに平滑化                 |  |  |  |
| 双方向 LSTM 層 | 出力次元:512×2                    |  |  |  |
|            | 隠れ層のドロップアウト:0.5 , 活性化関数:tanh  |  |  |  |
| 全結合層 1     | 出力ユニット数:100                   |  |  |  |
|            | 活性化関数:ReLU , ドロップアウト率:0.25    |  |  |  |
| 全結合層 2     | 活性化関数:softmax                 |  |  |  |
|            | 1112 正則化:(0.01,0.01)          |  |  |  |
| 出力層        | 出力サイズ:(5,1)                   |  |  |  |

#### 表 2: 判別部パラメータ詳細

| パラメータ設定 |                      |  |  |
|---------|----------------------|--|--|
| 入力層     | 入力サイズ:100 × N        |  |  |
| 全結合層 1  | 出力ユニット数:100          |  |  |
|         | 活性化関数:ReLU           |  |  |
| 全結合層 2  | 活性化関数:softmax        |  |  |
|         | 1112 正則化:(0.01,0.01) |  |  |
| 出力層     | 出力サイズ:(5,1)          |  |  |

行った.なお,学習エポック数は100回とした.学習終了後, 学習済モデルの最終層を取り除き,入力データを100次元の特 徴を抽出する特徴抽出器(日),(韓),および(英)を作成した.

作成した特徴抽出器の出力を入力として,全結合層 2 層か らなる判別部を学習する.なお,誤差関数と最適化関数につい ては 1 次元畳込み双方向 LSTM モデルと同様である.例と して,図 1 に日本語の感情音声を転移学習モデル(英韓)で学 習する場合を示す.特徴抽出器(英),(韓)に日本語感情音声 を入力して 200 次元の特徴に変換し,その特徴を入力として 学習をする.

# 3. 実験データ

実験に使用したデータ数一覧は図3のようになる.日本語, 韓国語,北アメリカ英語の3ヵ国の感情音声発話を用意し,5 感情「怒り」「悲しみ」「喜び」「嫌悪」「驚き」を実験データと して使用した.なお,サンプリング周波数は日本語と韓国語の 感情音声データは CD 規格の44.1kHz であるが,北アメリカ 英語のみ48kHz である.そのため,北アメリカ英語のデータ にサンプリング周波数変換を施し,44.1kHz に変換して使用 した.

# 3.1 日本語感情音声データ

日本語の感情音声データとして,感情評定値付きオンライ ンゲーム音声チャットコーパス (OGVC)[有本 13] を使用した. これはオンラインゲームの音声チャットの感情発話を,4名の 俳優 (男性2人,女性2人)が9感情 (受容,怒り,期待,嫌



図 1: 転移学習モデル (英韓) 概要

| 表 3: 実験データ   |      |     |     |  |  |  |
|--------------|------|-----|-----|--|--|--|
| 日本語 韓国語 北米英語 |      |     |     |  |  |  |
| 怒り           | 240  | 100 | 192 |  |  |  |
| 悲しみ          | 252  | 100 | 192 |  |  |  |
| 喜び           | 252  | 100 | 192 |  |  |  |
| 嫌悪           | 240  | 100 | 192 |  |  |  |
| 驚き           | 288  | 100 | 192 |  |  |  |
| 合計           | 1272 | 500 | 960 |  |  |  |

悪,恐れ,喜び,悲しみ,驚き,平静)で演じた音声コーパス である.

#### 3.2 韓国語感情音声データ

韓国語の感情音声データとして Cho ら [Cho 09] が用いた感 情音声データを使用した.これは,韓国の TV ドラマから韓 国人の俳優が発した感情音声フレーズを抽出し,聴取者 2 名 により 5 感情 (怒り,悲しみ,喜び,驚き,嫌悪) に分類した データである.

#### 3.3 北アメリカ感情音声データ

北 ア メ リ カ 英 語 の 感 情 音 声 コ ー パ ス と し て , RAVEDESS[RAVEDESS 18] を 使 用 し た . こ れ は 24 人の役者 (男性 12 人,女性 12 人)が発話と歌で 8 感情 (平静, 落ち着いた,喜び,悲しみ,怒り,恐怖,嫌悪,驚き)を演じ たコーパスである.今回は発話データのみを用いた.

#### 4. 周波数帯域による分類性能比較実験

別言語の学習済モデルを転移学習することによるデータ不 足の補完の予備実験として,使用する周波数帯域による分類 性能の比較実験を行った.サンプリング周波数に CD 規格の 44.1kHz を採用しため,入力として 0~22.05kHz までの周波 数のスペクトログラムを用いることができる.しかし,人の可 聴範囲は一般的に 20~20kHz といわれており,実際に感情の 特徴となる周波数成分は更に狭い範囲に分布すると予想され る.そのため,入力として周波数の上限を適切に定めることが 必要であるのではないかと考えられる. 表 4: 韓国語の分類結果 (F 値)

|     | 全帯域   | 5kHz 上限 |
|-----|-------|---------|
| 喜び  | 0.346 | 0.347   |
| 悲しみ | 0.505 | 0.498   |
| 怒り  | 0.581 | 0.571   |
| 嫌悪  | 0.508 | 0.524   |
| 驚き  | 0.367 | 0.392   |
| 平均  | 0.469 | 0.468   |

表 5: アメリカ英語の分類結果 (F 値)

|     | 全帯域   | 5kHz 上限 |
|-----|-------|---------|
| 喜び  | 0.483 | 0.501   |
| 悲しみ | 0.564 | 0.569   |
| 怒り  | 0.501 | 0.598   |
| 嫌悪  | 0.507 | 0.523   |
| 驚き  | 0.523 | 0.586   |
| 平均  | 0.517 | 0.558   |

#### 4.1 実験方法

本実験では、入力データであるスペクトログラムの周波数 帯域を 5kHz 上限にした場合と 22.05kHz(全帯域)の場合で各 言語ごとに判別性能を比較する.本実験では 2.2 の 1 次元畳 込み双方向 LSTM モデルを使用した.5 分割交差検証を行い、 各感情ごとに F 値を算出する.このとき、訓練データの 2 割 を検証データとする.なお、学習エポック数は 100 回とした.

#### 4.2 実験結果

結果を表 4,表 5,表 6 に示す.比較して高い方を太字で表 記した.

まず,韓国語の感情音声について分類した結果を比較する と(表4),「悲しみ」「怒り」については0~22.05kHzの周波数 帯域のデータを入力とした場合のがF値が良い結果になった. しかし,「喜び」「嫌悪」「驚き」については5kHz上限で区切っ たスペクトログラムを入力した場合の方が良い結果となった.

次に,アメリカ英語の感情音声について分類した結果を比較 すると(表 5),「喜び」「悲しみ」「怒り」「嫌悪」「驚き」全てに おいて 5kHz 上限で区切った場合の方が良くなった.特に「怒 り」については 0~22.05kHz の周波数帯域のデータを入力し た場合に比べて F 値が約 0.10 改善された.

最後に、日本語の感情音声について分類した結果を比較す ると(表 6),「喜び」「悲しみ」については 0~22.05kHz の周波 数帯域のデータを入力とした場合の方が良い結果となった.し かし,「怒り」「嫌悪」「驚き」については 5kHz 上限で区切った 場合の方が良い結果となった.特に「怒り」については F 値 が約 0.05 改善された.

#### 4.3 考察

全体的に、5kHz 上限でスペクトログラムを区切った場合の 方が良い結果になった.この要因として5kHz 上限で入力を区 切ったことにより、入力次元が4分の1以下まで削減されたこ とが大きいと思われる.入力データのサイズが小さいほど情報 が減ってしまうのは確かであるが、その分モデルの規模が小さ くなり、求めるべきパラメータが減少する.これにより学習に 必要となる学習データの規模が小さくなる.特に本実験のよう にデータ数が少ない場合は次元削減によるメリットが大きかっ たと考えられる.また、感情分類に深くかかわる周波数帯域を 表 6: 日本語の分類結果 (F 値)

|     | 全帯域   | 5kHz 上限 |
|-----|-------|---------|
| 喜び  | 0.444 | 0.423   |
| 悲しみ | 0.426 | 0.391   |
| 怒り  | 0.279 | 0.327   |
| 嫌悪  | 0.432 | 0.472   |
| 驚き  | 0.560 | 0.595   |
| 平均  | 0.429 | 0.443   |

削除してしまうと逆に性能が悪化することが考えられる.しかし、本実験の結果を見てみると全体的には性能の向上が見られたことから、感情分類に必要となる周波数の大部分は5kHz以内に分布すると推測される.

# 5. 転移学習による学習データ補填実験

#### 5.1 実験方法

本実験では、単一言語モデルと転移学習モデルの性能を各言 語ごとに比較する. ある言語 A の感情を推定する場合 (A 以 外の言語を B, C とする) は以下の 4 つのモデルを比較する. なお、スペクトログラムは 5kHz 上限のサイズ 101×200 のも のを使用する.

- 単一言語モデル
- 転移学習モデル (言語 B)
- 転移学習モデル (言語 C)
- 転移学習モデル (言語 BC)

5 分割交差検証を行い,各感情ごとに F 値を算出する.この とき,訓練データの2割を検証データとする.なお,学習エ ポック数は100回とした.

#### 5.2 実験結果

実験結果は表7,表8,表9のようになった.全体で最も結 果が良いものを太字,転移学習モデルの中で最も結果が良いも のを赤字で示した.

まず,韓国語の感情音声について分類した結果を比較する と(表7),全体的に韓国語の単一言語モデルが最も良い結果 となった.転移学習モデル3つについて比較すると,「悲しみ」 「怒り」「驚き」については、転移学習モデル(英日)が最も良 い結果が得られた.また,F値の平均を比較と,転移学習モデ ル(英日)が最も良い結果であった.

次にアメリカ英語の感情音声について分類した結果を比較 すると(表 8),全体的にアメリカ英語の単一言語モデルが最も 良い結果となった。特に「喜び」「悲しみ」「怒り」については 単一言語モデルと転移学習モデルの間に 0.20 以上の F 値の差 が見られた。転移学習モデル 3 つを比較すると,「喜び」「悲し み」「嫌悪」については転移学習モデル(日韓)が最も良い結果 が得られた。また,F 値の平均を比較すると,転移学習モデル (日韓)が最も良い結果であった。

最後に日本語の感情音声について分類した結果を比較すると (表 9),全体的には日本語の単一言語モデルが最も良い結果と なった.特に「怒り」については顕著であり,単一言語モデル が転移学習モデルよりも約 0.20 高い F 値となった.「喜び」に ついては転移学習モデル(英韓)が最も良い結果になった.転 移学習モデル3つについて比較すると,「喜び」「怒り」「嫌悪」

表 7: 韓国語における単一言語モデルと転移学習モデル (英), (日), (英日)の比較 (F値)

|     | 単一言語  | 転移学習モデル |       |       |
|-----|-------|---------|-------|-------|
|     | モデル   | (英)     | (日)   | (英日)  |
| 喜び  | 0.347 | 0.163   | 0.138 | 0.144 |
| 悲しみ | 0.498 | 0.344   | 0.284 | 0.380 |
| 怒り  | 0.571 | 0.484   | 0.495 | 0.540 |
| 嫌悪  | 0.524 | 0.384   | 0.354 | 0.374 |
| 驚き  | 0.392 | 0.350   | 0.374 | 0.384 |
| 平均  | 0.468 | 0.346   | 0.342 | 0.366 |

表 8: アメリカ英語における単一言語モデルと転移学習モデル (日),(韓),(日韓)の比較(F値)

|     | 単一言語  | 転移学習モデル |       |       |
|-----|-------|---------|-------|-------|
|     | モデル   | (日)     | (韓)   | (日韓)  |
| 喜び  | 0.501 | 0.296   | 0.247 | 0.301 |
| 悲しみ | 0.569 | 0.291   | 0.274 | 0.342 |
| 怒り  | 0.598 | 0.311   | 0.384 | 0.378 |
| 嫌悪  | 0.523 | 0.323   | 0.366 | 0.416 |
| 驚き  | 0.586 | 0.412   | 0.369 | 0.392 |
| 平均  | 0.558 | 0.330   | 0.332 | 0.368 |

「驚き」については,転移学習モデル (英韓) が他の転移学習モ デル以上の F 値であった.また,F 値の平均を比較すると,転 移学習モデル (英韓) が最も良い結果であった.

#### 5.3 考察

単一言語モデルと転移学習モデルの結果を比較すると,全体的に転移学習モデルの方が悪い結果になった.2言語転移学 習モデルと1言語転移学習モデルの分類結果の比較では,どの言語も5感情中3感情以上で2言語転移学習モデルの方が 良い結果が得られた.今後,学習する感情音声の言語数を増や すことで,データ数が不十分な単一言語の感情音声で学習した 判別器以上の性能が得られるのではないかと考えられる.

# 6. まとめ

本研究では、言語文化によらない共通の特徴があり、ある言 語の感情音声のデータの不足を別言語の感情音声で補完できる のではないかと考え、別の言語について学習したモデルを転移 学習で利用することを提案した.

まず,スペクトログラムの周波数帯域を適切なところで制限 した方が分類性能が向上するのではないかと考え,上限 5kHz で区切った場合と,サンプリング周波数の半分 22.05kHz まで を入力とした場合で言語ごとに学習を行い,性能の比較実験を 行った.その結果,日本語と韓国語は5感情中3感情が,ア メリカ英語は5感情全ての感情について,区切った場合の方 が高いF値が得られた.よって,5kHz までの範囲に感情に関 連する周波数が多く分布するのではないかと考えられる.

次に,ある言語の感情音声のデータ不足を別の言語の感情音 声を学習したモデルを転用することで補う方法について検討を 行った.結果としては,日本語の「喜び」以外は1から学習し たモデルが分類性能において最も良い結果であった.しかし, 1言語転移学習モデルよりも2言語転移学習モデルの方が全体 的に良い結果が得られたことから,学習する言語数を増やすこ とで,不十分なデータ量の単一言語モデルよりも高い性能が得 表 9: 日本語における単一言語モデルと転移学習モデル (英), (韓), (英韓)の比較 (F値)

|     | 単一言語  | 転移学習モデル |       |       |
|-----|-------|---------|-------|-------|
|     | モデル   | (英)     | (韓)   | (英韓)  |
| 喜び  | 0.423 | 0.412   | 0.344 | 0.437 |
| 悲しみ | 0.391 | 0.362   | 0.312 | 0.307 |
| 怒り  | 0.327 | 0.102   | 0.070 | 0.128 |
| 嫌悪  | 0.472 | 0.374   | 0.340 | 0.428 |
| 驚き  | 0.595 | 0.519   | 0.505 | 0.519 |
| 平均  | 0.443 | 0.365   | 0.334 | 0.378 |

られる可能性が示唆された.

これらの結果を踏まえ、今後は更に多くの言語の感情音声 を入手し、本実験で示された可能性について検証していく予定 である.また、言語数を増加させていくと、本手法では次元数 が増加してしまう.対策として、出力次元を減らすことや、文 化的背景が近い言語ごとに系統分けすることなどを検討してい く予定である.

# 参考文献

- [Dario 16] Dario Bertero et al, "Real-Time Speech Emotion and Sen-timent Recognition for Interactive Dialogue Systems" Proceedings of the 2016 Conference on Empirical Meth-Ods in Natural Language Processing", pp. 1042-1047
- [George 16] George Trigeorgis et al, "Adieu features? endto-end speech emotion recognition using a deep convolutional recurrent network" in Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2016, pp. 5200-5204.
- [Ekman 75] Ekman, P. and Friesen, W. V." Unmasking the Face, Prentice-Hall", 1975
- [Nesterov 83] Nesterov, Y. (1983). A method for unconstrained convex minimization problem with the rate of convergence o(1/k2). Doklady ANSSSR (translated as Soviet.Math.Docl.), vol. 269, pp. 543-547.
- [RAVEDESS 18] Livingstone SR, Russo FA (2018) The Ryerson Audio-Visual Database of Emotional Speech and Song (RAVDESS): A dynamic, multimodal set of facial and vocal expressions in North American English. PLoS ONE 13(5): e0196391. https://doi.org/10.1371/journal.pone.0196391.
- [有本 08] 有本泰子ら、"感情音声のコーパス構築と音響的特徴の分析"情報処理学会研究報告音楽情報科学 (MUS),pp.133-138,2008
- [有本 13] 有本泰子, 河津宏美, "音声チャットを利用したオン ラインゲーム感情音声コーパス", 日本音響学会 2013 年 秋季研究発表会講演論文集, 1-P-46a, pp. 385-388, 2013.
- [Cho 09] 趙章植ら," ベイジアンアプローチに基づく感情発話 音声からの感情推定における日韓感性の比較"日本感性 工学会論文誌 Vol.8No.3 pp.913-919, 2009

# オープンソースの音声言語インタラクションの社会実験基盤を

提供する MMI プラットフォームの開発

Development of Open-source Multi-modal Interaction Platform for Social Experiment of Conversational User Interface

> 李 晃伸 Akinobu Lee

# 名古屋工業大学大学院工学研究科 Nagoya Institute of Technology, Japan

A development of a multi-modal interaction platform for Social experiment of conversational user interface is proposed. In order to go over the simple spoken language interaction systems such as voice assistants, it is necessary to elucidate various factors of rich interactions quantitatively via thousands of wide variety of actual interaction data from users. The proposed system is based on a voice interaction building toolkit MMDAgent, adding some features to promote a testbed for social experiment and data collection of speech interaction system on cloud environment. It includes facilities for system distribution and management, collection of interaction log and speech data, and easy connection with cloud-based chat system. The beta version of the software is available, and it will be released as open-source software to promote wider use for various speech-based conversational user interface.

# 1. はじめに

近年,音声対話システムあるいは対話的な音声言語インタフ ェースは,情報機器・サービスと人をつなぐ次世代のモーダルと して期待が高まっている.特にここ数年,知的情報処理技術の 深化と汎化に伴って,クラウトベースの知的情報サービスと人間 を繋ぐスマートなコミュニケーションインタフェースとしての音声 対話技術が注目されている.スマートスピーカーや Web 検索等 において簡潔な発話による情報の授受やタスク達成はかなり実 現しており,今後はより自然な会話スタイルでやりとりできること が求められている.

ー方で、インタフェースとしての音声モーダルの一般的な設計論や方法論はまだ確立されているとはいえない。音声対話システムの研究事例や応用システム例はこれまでに多くあり、音声認識や音声合成の基盤技術も近年飛躍的進歩を得たが、それでもなお、現時点では音声は様々な機器やサービスに実際にアクセスするための主要なモーダルとなるに至っていない。また音声対話システムの構築には必要とされる技術が多く、CGエージェント等のインタフェースまで含めた設計・実装は多方面の多大な労力を必要とする。

音声対話を含む音声言語インタラクションが一般的なモーダ ルとして広く用いられるようになるためには、その設計や適用範 囲、他のUIとの関連性を含め、統合的に実証・実験する枠組み が必要である。音声言語の領域だけでなく、自然言語処理や対 話、ユーザインタフェースやヒューマンエージェントインタラクショ ン、あるいはデザインやコンテンツの領域を検証可能な融合的 な基盤を共有することで、多様な実際的・現実的なタスクのオー プンなシステム運用から多くの実インタラクションデータを収集し、 データドリブンなアプローチで様々な要素を量的に解明してい くことが可能となる。様々な目的のための多様なシステムが大量 に作成され実際に使われることで、多くの事例やデータを集め る環境がボトムアップに形成されると期待される。 本研究では、音声対話を含む音声言語インタラクションの多様な社会実験の実践のための基盤となるプラットフォームの実現を目標に開発された拡張版 MMDAgent について述べる.本アプリケーションは、MMDAgent で作成した音声対話・音声インタラクションシステムのネットワーク配信、ならびに利用ユーザのインタラクションログや音声データの収集を行える.これにより、音声対話システムを公開することで誰でもクラウドベースの広範囲な音声言語インタラクション実験およびデータ収集を行える.本アプリケーションはマルチプラットフォームで動作し、Android, iOS およびデスクトップ OS (Win/Mac/Linux)で同一の動作を行う.現在ベータ版が公開されており無償でダウンロード・試用が可能である.以下、ベースシステムである MMDAgent について概説したのち、提案システムについて述べる.

#### 2. MMDAgent

まずベースとなるツールである MMDAgent について述べる. MMDAgent は音声ベースのインタラクションシステムのための 構築ツールキットである[1]. 多様な音声対話システムおよび音 声インタラクションのための実験用プラットフォームとして開発が 行われている.現在, ソフトウェア全体およびサンプルの音声対 話システムがオープンソース(BSD ライセンス)で公開されてい る. 2010年に1.0が公開された. ソフトウェアの最新版は2016年 に公開されたバージョン 1.7 である.公開以来 14 万件以上ダウ ンロードされている[2].

MMDAgent 自身は音声対話システムではなく, 音声対話シ ステムを動作させるソフトウェア(ブラウザ)である. 音声対話シス テムの構成要素(辞書・ボイス・対話シナリオ・エージェントモデ ル・モーション等)は外部で定義する. MMDAgent 用のサンプ ルシステム(サンプルコンテンツ)が同じWebで公開されており, 2018年12月には従来の女性モデル・女性ボイスに加えて男性 モデル・男性ボイスを追加したバージョン1.8が公開された.ドキ ュメントはJST CREST の uDialogue プロジェクト (2011—2017) の成果物として uDialogue サイトの「MMDAgent エンサイクロペ ディア」[3]に集約されている.

連絡先: 李晃伸, 名古屋工業大学, 愛知県名古屋市昭和区御 器所町, 052-735-7550, ri@nitech.ac.jp



図1:システム全体像

MMDAgent では音声認識(Julius),音声合成(Open JTalk (日本語),Flite+HTS Engine(英語)),エージェント表示がオー ルインワンで提供されている.各部がモジュール化されていて 拡張が容易であり,言語モデルや音響モデルの拡張,ボイスモ デルの入れ替え等が容易に行える.画面表示は3D空間で,物 体とモーションの分離性や十分な表現力と自由度から, MikuMikuDanceの互換プラットフォームとしており,プリミティブ な3Dオブジェクトからヒューマノイドエージェントによるしぐさ・反 応・ジェスチャの表出まで多様なインタラクション表現が可能で ある.対話管理部はメッセージテキストを入出力とする状態遷移 機械(FST)で実装されている.

# 3. 提案システムの概要

本研究ではスマートフォンから等身大サイネージまで多様な デバイスにおいて,音声を主体とする会話的なUIを備えた音声 インタラクション・対話システムのテストベッドとして双方向の実 験および大規模データ収集を行えるよう MMDAgent を拡張し た新たなプラットフォームを構築する[4].本システムはスマート フォンマルチ OS 環境で動作し,双方向の大規模な社会実験環 境の基盤を提供する.以下,実装された新たな機構を述べる. 全体像を図1に示す.

#### 3.1 システムのクラウド配信および管理機構

音声対話システムを任意の URL から任意のユーザ端末へ直 接配信可能にする. Web 上の URL で示されるディレクトリ以下 にシステムのファイルー式(対話スクリプト, 3D モデル, モーショ ン, 背景画像, ボイス定義ファイルなど)を置いておき, アプリケ ーションからその URL を開くことでシステムを自動取得できる. URL スキームに対応しており, ユーザが "mmdagent://..."のリン クを開くだけでシステムを自動ダウンロード・実行できる.

また,システム構築者からダウンロードしたユーザへの制御・ 連絡を行う仕組みを実装している.ダウンロードしたシステムに 対する更新や削除,お知らせの表示を,端末からサーバへ定 期的な更新チェックを行うことで自動的に行う仕組みになってお り,利用ユーザに対する様々な配信制御が可能である.

# 3.2 ログ・フィードバック収集機構

システム構築者が自システム利用時の動作ログを収集するた めの機構を実装する. 収集する動作ログは, MMDAgent のメッ セージキューを流れたすべてのメッセージおよびシステムログで あり, 音声認識結果, 対話管理 FST の状態遷移などのインタラ クション情報がミリ秒単位のタイムスタンプとともに保存されたも のである. また, 認識対象となった生の音声波形データも収集 できる. 端末の識別ごとにユニーク ID が自動生成され, 識別子 としてログに付与される. ログの収集スキームとして、Apache Kafka を用いたリアルタイ ムログ収集と、ローカルにファイル保存してから Web アップロー ドする方法の2種類を実装する.前者は2011年にオープンソ ース化され、LinkedIn や Twitter でも用いられている分散ストリ ーミングのプラットフォームであり、数十万以上の大量の端末に 対して高性能なリアルタイムデータストリーミングを行うことができ る.即時性が高く、コンテンツのエラー検出やロギングをリアルタ イムに行うことができる.後者のWebアップロードは、端末のロ ーカル上にログを記録・保存し、一定のタイミングでそれらを POST メソッドでWeb上のサーバへアップロードする.音声波形 データの収集は後者の場合のみ対応する.これにより、ユーザ からコンテンツ公開者へのフィードバックを実現する.

#### 3.3 クラウド型対話システムへの対応

システムが指定する Apache Kafka サーバと consumer モード で接続することで、個々の端末が Kafka サーバを通じて認識結 果や応答テキストなどのメッセージをリアルタイムにやりとりでき る. これを用いることで、対話サーバを接続して当アプリケーショ ンをフロントエンドとしたクラウド型音声対話システムを容易に実 現可能である. また接続先はシステム単位で変更できるため、 あるシステムを利用中の端末全てに発話命令を一斉送信するよ うな利用方法も可能である.

# 3.4 オープンソース開発体制

多様な音声インタラクションを対象とするためには、様々なセンサーあるいは IFTTT のようなバックエンド接続サービス等との接続のための拡張を行いやすい開発環境である必要がある. 本アプリケーションの開発においては GitHubを活用した実践的な体制を構築し、ソースコード共有によるコード主体の多様かつ迅速な開発を行う予定である.

# 4. 現行システム

本稿で提案した拡張の多くを施したアプリケーションは、既に「Pocket MMDAgent」という名称で試験公開中である[5]. サイトからは Android, iOS を含む各種 OS 用のベータ版アプリが無償 で入手可能であり、仕様もサイト上で公開されている.

#### 5. まとめ

本システムの開発進捗は現在 80%程度であり、最終的には オープンソースで公開する予定である.マルチプラットフォーム の UI 基盤としては Unity が著名であるが、本ソフトウェアはオー プンソースであり、音声言語インタラクションのデータ収集基盤と しての拡張性と可搬性を重視して作成されている.

本システムの開発と公開が,音声を含めた知的インタラクションにかかる研究テーマの統合的でデータドリブンなアプローチの土台となり,音声言語を含めた次世代インタフェースの幅広い試行錯誤と検討の一助となれば幸いである.

# 参考文献

- A. Lee, K. Oura, K. Tokuda: MMDAgent A fully opensource toolkit for voice interaction systems, IEEE ICASSP, pp. 8382-8385, 2013.
- [2] http://www.mmdagent.jp/
- [3] http://www.udialogue.org/ja/encyclopedia-ja
- [4] 李晃伸:音声対話コンテンツのネットワーク配信および大規 模ログ収集を可能にするスマートフォン版 MMDAgent の開 発,日本音響学会秋季講演論文集, 2-2-8, 2019.
- [5] Pocket MMDAgent (beta): https://mmdagent.lee-lab.org/
General Session | General Session | [GS] J-10 Vision, speech

## [3N4-J-10] Vision, speech: applications to industries

Chair:Masanori Tsujikawa Reviewer:Tomoya Yoshikawa

Thu. Jun 6, 2019 3:50 PM - 4:50 PM Room N (Front-right room of 1F Exhibition hall)

# [3N4-J-10-01] Measurement of growing situation of agricultural crops on FPGA-mounted drone using Circle SSD OTakuma Yoshimura<sup>1</sup> (1. poco-apoco Networks Co.Ltd.) 3:50 PM - 4:10 PM [3N4-J-10-02] Prediction of Favorability Rating on Beer-Can Package Designs Using Convolution Neural Network and Visualization by Class Activation Mapping. OHiroyuki Shinohara<sup>1</sup>, Tatsuji Ishiguro<sup>1</sup>, Shunsuke Nakamura<sup>2</sup>, Toshihiko Yamasaki<sup>2</sup> (1. Kirin Company, Limited, 2. The University of Tokyo) 4:10 PM - 4:30 PM [3N4-J-10-03] Conversion of Floor Plan Images to Graph Structures using Deep Learning and Application to Retrieval OMantaro Yamada<sup>1</sup>, Xueting Wang<sup>1</sup>, Toshihiko Yamasaki<sup>1</sup>, Kiyoharu Aizawa<sup>1</sup> (1. the University of Tokyo)

4:30 PM - 4:50 PM

## Circle SSD を用いた FPGA 搭載ドローンでの農作物生育状況計測 Measurement of growing situation of agricultural crops on FPGA-mounted drone using Circle SSD

吉村 拓馬<sup>\*1</sup> Takuma Yoshimura

\*1 株式会社ポコアポコネットワークス poco-apoco Networks Co. Ltd.

In this paper, we report the optimization method for the case of introducing SSD which is one of the object detection models to the drones for the purpose of measuring the growth situation of agricultural crops as viewed from a bird's eye viewpoint. We have adopted a "Separable Convolution" and introduced "Circle SSD" which uses circular shape as a detection frame as an optimization method. As a result of the optimization, the F-measure 0.67 was realized with 14770 convolution params, and the object detection could be realized with limited calculation resources on the drone.

#### 1. はじめに

本稿では,農作物の生育状況計測をドローンより上空から捉 えた鳥瞰視点で行うことを目的とし,ドローンに搭載される FPGA(Field-Programmable Gate Array)ボードに物体検出モデ ルの1つである SSD(Single Shot MultiBox Detector)[Liu 16]を 導入した事例について,物体検出モデルの小型化および円形 の検出枠の適用に関して報告する.

ドローンとは遠隔操縦または自動操縦が可能な無人航空機 の総称で、農業、設備点検、測量、警備、物資運搬など産業界 での活用が広がっている[Nonami 18].ドローンの多くは内蔵バ ッテリによって駆動するため、長時間飛行させるためには消費 電力を抑える必要がある.したがって生育状況計測のための搭 載デバイスは軽重量で消費電力の小さいことが望ましく、さらに 無線通信による電力損失を抑えることが求められる.

また本稿で採用する SSD は,統計的機械学習の数理モデル の1つで,画像認識や画像生成などに広く用いられる畳み込み ニューラルネットワーク(以降 CNN)を用いている.しかし CNN は学習時,推論時に必要となる計算量が大きく,それゆえに高 性能で消費電力の大きい CPU や GPU での運用が求められる.

本稿では、物体検出モデルの小型化を行い CPU, GPU に比 べ消費電力の小さい FPGA<sup>†</sup>に SSDを導入した.ドローンから空 撮した画像を搭載した FPGA で推論させることで、地上にあるサ ーバに文字列に比べデータ量の大きい画像を通信する必要が なく、通信量を抑えることが可能となる.全体の流れを図 1 に示 す.本稿では図中のフロー2 について述べる.





#### 2. データセット

本稿では 2018 年の 5 月から 9 月にかけて撮影されたパイナ ップル耕作地の空撮画像 2187 枚および画像に含まれる,パイ ナップルの中心位置および葉の先端への半径のリストをデータ セットとした.データセットの一部を以下の図 2 に示す.



図2パイナップル空撮画像 それぞれの株の中心部分から果実 として流通しているパイナップルが生育する.

#### 3. SSD の構成

本節では農作物の生育状況計測を実現するための,物体検 出モデルである SSD の小型化,また円形の検出枠の適用につ いて述べる.

#### 3.1 SSD の構成要素

SSD は Extractor, Coder, Suppressor の 3 つの構成からなる (図 3). Extractor は入力画像から畳み込み処理を行い物体認識 に有効な特徴量を抽出, Coder は Extractor から得られた特徴量 を各クラスの物体が存在する範囲の空間情報と確度(スコア)に 変換, Suppressor は Coder から得られた検出枠候補から重複し た確度の低い検出枠候補を除外する.



<sup>†</sup> DIGILENT 社製 Zybo Zynq-7020, USB 給電 5V, 基板サイズ 88mm×122mm, BRAM 容量 630KB

#### 3.2 FPGA のハードウェア制約

ー般に高性能な CPU や GPU が要求される CNN を FPGA に 実装するためには、記憶領域と論理ゲート数(回路規模)の制約 条件を満たす必要がある. CNN の小型化の手法としてモバイル デバイス向け小型 CNN である MobileNet ベース SSD300(パラ メータ数 6.8×10<sup>6</sup>)[Howard 17]を参考とし、制約条件を満たすた めパラメータ数を 1.5×10<sup>4</sup>までとし、Extractor の畳み込み層を 8 層まで減らす必要があった(表 1). このため CNN の構成は一 般のモデルに比べ制限される. 例えば、このパラメータ数ではフ ィルタサイズ 3 チャネル数 64 の、一般的な畳み込み層を 1 層も 構成に入れることができない(パラメータ数 3<sup>2</sup>×64<sup>2</sup> = 36864).

ただし、物体検出タスクとしての難度は先行研究に比べ低い. なぜなら先行研究のモデルは一般物体の複数クラスの認識精 度を評価指標としている(COCO dataset[Lin 14]).本稿では、対 象作物の1クラスのみであるうえに、対象の構造は水平に対し 等方的、背景は主に赤褐色から黄褐色の土で色域が限られる.

| 表 | 1 | モ  | デル   | パラ    | ラメー   | -> |
|---|---|----|------|-------|-------|----|
| 衣 | 1 | Ξ, | / /レ | ~ > > | ' ^ - | -: |

| Model        | Parameters          | Dataset   | Classes |
|--------------|---------------------|-----------|---------|
| deeplab-VGG  | $3.3 \times 10^{7}$ | COCO      | 80      |
| Inception V2 | $1.4 \times 10^{7}$ | COCO      | 80      |
| MobileNet    | $6.8 \times 10^{6}$ | COCO      | 80      |
| Ours         | $1.5 \times 10^{4}$ | Pineapple | 1       |

#### 3.3 CNN の小型化

CNN は複数の処理層で構成され,一般に多くの演算を要す る数理モデルである.1 つ目の処理層である入力層では画像に 対して空間フィルタを適用(畳み込み処理)し,特徴マップを得る. 以降の処理層では前の層で得られた特徴マップに対してさらに 畳み込み処理し特徴抽出する,またはプーリング処理によりロ バスト性を高める.こうしてより物体認識に有効な特徴量を抜き 出した特徴マップを得る.この処理において物体検出モデルで は 10<sup>9</sup>-10<sup>12</sup>スケールの積和演算回数を要する[Howard 17].

CNN の小型化・高速化において特徴抽出性能を保ちつつ, 計算量を減らす構造がいくつか考えられている. 代表的なもの として MobileNet[Howard 17]が導入した Depthwise Convolution, Pointwise Convolution, この 2 つを組み合わせた Separable Convolution がある(図 4). その他にも SqueezeNet[Iandola 16]が 導入した Fire Module, GoogLeNet[Szegedy 14]が導入した Inception Module があるが,実装上 FPGA の論理ゲート数を前 記の構造より多く消費するため用いなかった.



図 4 MobileNet における畳み込み処理 inCh:入力チャネル 数, outCh:出力チャネル数, K:フィルタサイズ, W, H:特徴マッ プの幅および高さ, params:バイアスを除くパラメータ数(出力特 徴マップ 1 座標あたりの積和演算回数に相当), なお図のストラ イド(S)は 1 である.

#### 3.4 Extractorの構成方針

CNN は層が深くなるに従い,物体検出モデルおいては一般 にチャネル数が増えていく.図4 に示すとおり Standard Convolution, Pointwise Convolution, Separable Convolutionの パラメータ数はチャネル数が支配的であるため,チャネル数が 大きい処理層にはこれらの構造は避ける.本稿では,チャネル 数が最も小さい入力層には Standard Convolution, Coder に分 岐するまでは Separable Convolution,分岐後のチャネル数が大 きい処理層には Depthwise Convolution を用いた.

#### 3.5 Coder の構成方針

Coder では Extractor で得られた特徴量を検出対象のクラスと 背景クラスの確度, 位置情報のチャネルに変換するため, チャ ネル間の畳み込み処理を要する.本稿では, 最小限の構造で ある Pointwise Convolution を 1 層のみ用いた.また, 一般的な 物体検出モデルの検出枠は矩形であるが, 植物のように水平 等方向に空間を占める物体については円形であるほうが適して いると考えた.矩形の検出枠では横位置, 縦位置, 横幅, 縦幅 の 4 パラメータの相対位置情報が必要となるが, 円形の検出枠 を適用することで, 横位置, 縦位置, 半径の 3 パラメータのみで すみ, さらに縦長横長の検出枠が不要となる.

#### 3.6 Suppressor の構成方針

Suppressor では鳥瞰視点の空撮画像,円形を検出枠とする Circle SSD に適した検出枠重複除外処理に変更した.SSD[Liu 16]で用いられていた重複度ベースの除外方法を Circle SSD に 適用すると,地表平面上に存在する検出対象の中心が重なるこ とは無いにもかかわらず,円中心が近くに存在する半径の異な る複数の検出枠が得られてしまう.そこで本稿では互いの円の 半径に対する中心への比距離が互いに 50%以下である場合, 確度の低い方の円を重複した検出枠として除外することにした (図 5).この閾値は検出対象の大きさと,近傍の検出対象との距 離の比の分布から決定した.



図 5 中心相対距離に基づく検出枠重複除外 上:一般の SSD における検出枠配置とその Intersection over Union (IoU) 下: Circle SSD における検出枠配置と半径相対中心距離

#### 3.7 Circle SSD の構成

本節をまとめると CNN の小型化をおこなった Circle SSD の構成は次頁の表 2 のようになる. 列名は図 4 を参照のこと.

#### 4. 学習時の変更点

本節では野外で運用するドローンに適したデータ拡張と、 SSD[Liu 16]に円形の検出枠を適用したことによる特徴マップの 形状の変更について述べる.

|           | Туре               | inCh | outCh | Κ | S | W   | Н   | params |
|-----------|--------------------|------|-------|---|---|-----|-----|--------|
| Extractor |                    |      |       |   |   |     |     | 11520  |
| Conv1     | StandardConv+Relu  | 3    | 8     | 5 | 1 | 512 | 288 | 608    |
| Pool1     | MaxPooling         | 8    | 8     | 2 | 2 | 512 | 288 | 0      |
| Conv2     | SeparableConv+Relu | 8    | 16    | 5 | 1 | 256 | 144 | 352    |
| Pool2     | MaxPooling         | 16   | 16    | 2 | 2 | 256 | 144 | 0      |
| Conv3     | SeparableConv+Relu | 16   | 32    | 5 | 1 | 128 | 72  | 960    |
| Pool3     | MaxPooling         | 32   | 32    | 2 | 2 | 128 | 72  | 0      |
| Conv4     | SeparableConv+Relu | 32   | 64    | 5 | 1 | 64  | 36  | 2944   |
| Conv5     | DepthwiseConv+Relu | 64   | 64    | 5 | 2 | 64  | 36  | 1664   |
| Conv6     | DepthwiseConv+Relu | 64   | 64    | 5 | 2 | 32  | 18  | 1664   |
| Conv7     | DepthwiseConv+Relu | 64   | 64    | 5 | 2 | 16  | 9   | 1664   |
| Conv8     | DepthwiseConv+Relu | 64   | 64    | 5 | 2 | 8   | 5   | 1664   |
| Coder     |                    |      |       |   |   |     |     | 3250   |
| Loc4      | PointwiseConv      | 64   | 6     | 1 | 1 | 64  | 36  | 390    |
| Conf4     | PointwiseConv      | 64   | 4     | 1 | 1 | 64  | 36  | 260    |
| Loc5      | PointwiseConv      | 64   | 6     | 1 | 1 | 32  | 18  | 390    |
| Conf5     | PointwiseConv      | 64   | 4     | 1 | 1 | 32  | 18  | 260    |
| Loc6      | PointwiseConv      | 64   | 6     | 1 | 1 | 16  | 9   | 390    |
| Conf6     | PointwiseConv      | 64   | 4     | 1 | 1 | 16  | 9   | 260    |
| Loc7      | PointwiseConv      | 64   | 6     | 1 | 1 | 8   | 5   | 390    |
| Conf7     | PointwiseConv      | 64   | 4     | 1 | 1 | 8   | 5   | 260    |
| Loc8      | PointwiseConv      | 64   | 6     | 1 | 1 | 4   | 3   | 390    |
| Conf8     | PointwiseConv      | 64   | 4     | 1 | 1 | 4   | 3   | 260    |

表 2 CNN の小型化をおこなった Circle SSD の構成

#### 4.1 データ拡張

野外での物体検出は屋内に比べ,天候や時刻による画像輝度の変動が大きいため難度が高い.ドローンのFPGAに導入する SSD の学習では画像の上下左右反転の他に,輝度の変動を考慮した以下のデータ拡張を行った.

- ガンマ値の変動(冪指数:0.5-1.25)
- RGB 輝度値の独立変動(倍率:0.82-1.00)

#### 4.2 長方形画像の扱い

SSD の矩形の検出枠には縦幅横幅のパラメータがあり,画像の縦横縮尺比を変えることで,長方形画像であっても正方形画像に変形させ扱うことができる.しかし Circle SSD の円形の検出枠の尺度は半径のみであるため,画像変形後に縦長横長となる物体範囲を正しく検出できない.そこで画像の縦横縮尺比を変えず特徴マップの横幅と縦幅を変えることで,本稿で扱う空撮画像のような長方形画像(アスペクト比 16:9)に対応させた.

#### 5. 推論時の最適化

本節では CNN を FPGA に導入するための計算量削減の手 法について述べる.

#### 5.1 固定小数点数演算

学習時に用いた浮動小数点演算器を並列動作させる GPUと は対照的に,推論時に用いた FPGA は浮動小数点演算器を持 たないまたは乏しい. そのため浮動小数点数の演算は固定小 数点数を用いたときに比べ,多くの論理ゲートを消費し回路規 模の増大につながる. そこで本稿では符号 lbit 整数 5bit 小数 10bit の 16bit ビット幅の固定小数点数で推論を行った. なお, 途中の積算は丸めず融合積和演算(FMA; fused multiply-add) とすることで誤差を小さくした.

#### 5.2 バッチ正規化

畳み込み層と直後のバッチ正規化層[Ioffe 15]は以下の式の ように、推論時に単一の等価な畳み込み層へ変換することがで き、本稿ではこの変換式を用いた.ここでxは特徴マップ, BNは バッチ正規化関数, Convは畳み込み関数, W, bは畳み込み層 の重みおよびバイアス、 $\gamma$ 、 $\beta$ はバッチ正規化が学習する尺度 および位置パラメータ、 $\sigma$ 、 $\mu$ は Conv(x)のバッチ内標準偏差 および平均の移動平均、 $\epsilon$ はゼロ除算を避けるための微小数 である.出力チャネル方向の各要素について記述している.

$$BN(Conv(\mathbf{x})) = \gamma \frac{Conv(\mathbf{x}) - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta$$
$$= \gamma \frac{(W\mathbf{x} + b) - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta \tag{1}$$

$$= \frac{\gamma W}{\sqrt{\sigma^2 + \epsilon}} x + \frac{\gamma (b - \mu)}{\sqrt{\sigma^2 + \epsilon}} + \beta .$$

$$Conv'(\mathbf{x}) = BN(Conv(\mathbf{x})) = W'\mathbf{x} + b',$$

s.t. 
$$W' = \frac{\gamma W}{\sqrt{\sigma^2 + \epsilon}}, b' = \frac{\gamma (b - \mu)}{\sqrt{\sigma^2 + \epsilon}} + \beta$$
. (2)

#### 6. 結果

対象作物を本稿の Circle SSD で検出した結果画像を次頁の 図 7 に示す. 撮影高度, 画像輝度に依らず対象作物を検出す る事ができたものの, 対象作物でない雑草への誤検出や, 高高 度の画像において対象作物の半径の誤認識が見られた.

次に Extractor の構成を表 1(パラメータ数 14770), Mobile Net like(表 1 の Depthwise Convolution を Separable Convolution に 置き換え, パラメータ数 31410), VGG like(表 1 の Depthwise Convolution, Separable Convolutionを Standard Convolution に 置き換え, パラメータ数 481026)にした Circle SSD について, 検 出確度閾値を 0.10-0.95 に変化させたときの Precision-Recall 曲 線, 最大 F 値で評価を行った. 検出枠と正解枠が一致したと判 定する基準は互いの円の半径に対する中心への比距離が 25% 以内かつ半径比が 0.8-1.25 に収まっているかとする(図 6). 適合 率(Precision)は一致枠数 / 検出枠数, 再現率(Recall)は一致枠 数 / 正解枠数, F 値は適合率と再現率の調和平均で計算される. また学習画像と検証画像は 9:1 に分け学習と検証を行った.

なお原論文のモデルは、本稿の対象作物 1 クラスのみの検 出タスクに対し CNN のパラメータ数が多すぎ、過剰適合に陥っ たため対照群としなかった.

Precision-Recall 曲線の比較, モデルサイズと最大 F 値の比 較を次頁の図 8,9 に示す.本稿のモデルの最大 F 値は 0.67 と なり,32.5 倍のパラメータ数の VGG like, 2.1 倍のパラメータ数 の MobileNet like に対し最大 F 値は 0.10,0.02 の低下に収まっ た.また同じ空撮画像に対しモデルを変更した結果を図 10 に 示す.



図6半径Rの正解枠に対して一致したとみなす検出枠の範囲



図 7 検出結果 撮影高度, 画像輝度に依らず検出できている 一方で, 雑草への誤検出, 高高度の画像での半径の誤認識が 精度を落としている. なお, 検出枠はランダムに着色している.



図8 Precision-Recall 曲線の比較 理想的な検出器は Precision = 1, Recall = 1 の点を通る. F 値はいずれも検出確度閾値 0.60 で最大となった.



図 9 モデルサイズと最大 F 値の比較 モデルサイズと検出精 度は一般的にトレードオフの関係にある. VGG like, MobileNet like のパラメータ数は本稿のモデルの 32.5 倍, 2.1 倍あり, 最大 F 値は本稿のモデルより 0.10, 002 大きい.



図10モデル変更時の検出結果の比較この画像ではVGG like と本稿のモデルは株が重なっている箇所にそれぞれ誤検出が2 箇所,1箇所あり,VGG like は隣接する株に最長の葉が被って いる株であっても検出範囲が正確である.

#### 7. まとめ

本稿では鳥瞰視点で捉えた農作物の生育状況計測を目的 に、円形の検出枠を適用した SSDとして Circle SSDを提案した. またドローンに搭載する FPGA のハードウェア制約のもと、検出 対象が1クラスのみという限られた条件付きであるものの、パラメ ータ数14770という小型 CNN 物体検出モデルを実用範囲内で 実現することができた.

改良点として、Circle SSD への損失関数の最適化に、下式の 円の類似度の採用を考えている.この類似度を用いることで株 の重複箇所への誤検出が抑えられると期待される.ここで正解 枠と Coder の各ポイントに割り振られたデフォルト枠の2円間に ついて、dは2円中心間距離、r1,r2は2円の半径である.

#### $S = \max(0, 1 - \max(d/r_1, d/r_2)) \cdot \max(0, 1 - |\log(r_1/r_2)|) \quad (3)$

課題として,矩形を検出枠とする SSD と本稿が提案した円形 を検出枠とする Circle SSD では,検出枠が正解枠と一致したと みなす基準が異なり,精度の比較ができない事が挙げられる. 両者で共通して用いることのできる評価手法について考察を深 めたい.

最後に、ハイエンドな計算機で運用される高性能の CNN だけでなく、近年では個人向け PC やモバイルデバイス、エッジデバイスで運用される中性能・小型の CNN が求められている.物体検出タスクだけでなく、単一画像超解像や領域抽出,波形認識などのタスクを実行できる小型 CNN モデルの開発に取り組んでいきたい.

#### 謝辞

本稿を作成するにあたり、ご助言を頂いた岡山県立大学の有本和民氏、大手前大学の奥村紀之氏に心より感謝致します.

#### 参考文献

- [Liu 16] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg. SSD: Single Shot MultiBox Detector, arXiv:1512.02325, 2016.
- [Nonami 18] 野波 健蔵,ドローン産業応用のすべて―開発の 基礎から活用の実際まで―, ISBN-13: 978-4274506840, 2018.
- [Howard 17] Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, Hartwig Adam, MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, arXiv:1704.04861, 2017.
- [Lin 14] Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, Piotr Dollár, Microsoft COCO: Common Objects in Context, arXiv:1405.0312, 2014.
- [Iandola 16] Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, Kurt Keutzer, SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size, arXiv:1602.07360, 2016.</p>
- [Szegedy 14] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, Going deeper with convolutions, arXiv:1409.4842, 2014.
- [Ioffe 15] Sergey Ioffe, Christian Szegedy, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, arXiv:1502.03167, 2015.

# 畳み込みニューラルネットワークを用いたビール缶パッケージの 好意度予測及び要因の可視化

Prediction of Favorability Rating on Beer-Can Package Designs Using Convolution Neural Network and Visualization by Class Activation Mapping.

篠原裕之<sup>\*1</sup> Hiroyuki Shinohara 石黒達治<sup>\*1</sup> Tatsuji Ishiguro 中村遵介<sup>\*2</sup> Shunsuke Nakamura 山崎俊彦<sup>\*2</sup> Toshihiko Yamasaki

\*1 キリン株式会社 Kirin Company, Limited \*<sup>2</sup> 東京大学 The University of Tokyo

A quantitative survey of favorability rating by multiple panels is the main method to decide package designs. However, it is expensive and there is a limitation in the number of designs that can be subjected to a single survey. Therefore, this study aims at predicting the panel evaluation from the past survey results by a convolution neural network and visualize the important features by Grad-CAM. As a result, it has been made possible to give prescreening test to package design and suggestions of important features to the designers.

#### 1. 背景と目的

最終消費者の購買行動において商品のパッケージデザイン は重要である [石井 10]. その為、企業において商品を上市す る際には、パッケージデザインに関する消費者調査を行い、良 好な結果が得られたデザインを採用する事が多い.しかし、十 分な消費者パネルを集めた調査には多額の費用が必要である、 一度の調査にかけられるパッケージデザインの数に上限がある という課題がある.

一方で、近年はディープラーニングを用いて審美性評価や 関する研究が盛んにおこなわれている [Talebi 17] [Kong 16]. これらの例から適切なディープラーニングのネットワークモデル を用いればパッケージデザインに関する消費者調査結果を予 測する事が可能であると考えられた.但し、これらの研究の多く は豊富なデータを用いてモデルを構築しており、単独の企業で 有する限られたデータのみを用いて消費者調査結果を高精度 で予測可能なモデルを構築する事は困難であることが予想され た.

そこで本研究は以下の2点を実現する事を目的とした.即ち、 未調査のパッケージデザインの中で好意度に対して好影響を 及ぼすと予測される要素と悪影響を及ぼすと予測される要素を 可視化する事、未調査のパッケージデザインを好意度調査に 供した場合の結果を予測する事である.

#### 2. 対象データ

本研究で対象としたデータはキリンビール株式会社が 2001 年から 2017 年にかけて実施した、350mL ビール缶パッケージ の好意度調査である.

調査は新規製品の上市あるいは既存製品のリニューアルに 際し、製品候補の 350mL ビール缶パッケージを非明示で 64 人から 300 人の消費者パネルに提示し、それに対する好意度 を表1に示した5段階もしくは7段階で回答を得たものである. この調査結果について、回答結果を最高10点、最低1点とな るように点数化し、全回答者の点数の平均好意度をパッケージ デザインの好意度とした.好意度のヒストグラムを図1に示す.

連絡先:篠原裕之,キリン株式会社基盤技術研究所,神奈川 県横浜市金沢区福浦 1-13-5,080-2370-9301, Hiroyuki\_Shinohara@kirin.co.jp

| 表1 回答方法及び点数化方法 |      |         |       |  |  |  |  |
|----------------|------|---------|-------|--|--|--|--|
| 7段階評価          |      | 5段階評価   |       |  |  |  |  |
| 回答             | 点数   | 回答      | 点数    |  |  |  |  |
| 非常に好き          | 10点  | 非常に好き   | 10点   |  |  |  |  |
| 好き             | 8.5点 | やや好き    | 7.75点 |  |  |  |  |
| やや好き           | 7点   | どちらでもない | 5.5点  |  |  |  |  |
| どちらでもない        | 5.5点 | やや嫌い    | 3.25点 |  |  |  |  |
| あまり好きではない      | 4点   | 非常に嫌い   | 1点    |  |  |  |  |
| 好きではない         | 2.5点 |         |       |  |  |  |  |
| 全く好きではない       | 1点   |         |       |  |  |  |  |





図2 パッケージ画像例

また、解析には調査に供した 350mL ビール缶パッケージの 正面画像を用いた(図 2).調査対象となったパッケージ画像は 509 種類であり、上位 33%(167 枚)を上位群、中位 34%(175 枚) を中位群、下位 33%(167 枚)を下位群とした. 尚、調査は非明示であるものの、当該製品が既存製品のリニ ユーアルである場合には消費者がその製品を既知である事が 好意度に影響する事が予想された.また、当該製品が季節限 定品である場合には販売する季節が好意度に影響することが 予想された.そこで、当該製品が①新規製品であるか/②既存 製品のリニューアルであるか/③春季限定製品であるか/④冬季限定商品 であるかを追加の製品属性として用いた.

#### 3. 手法

本研究の目的に従い、以下の検討を行った.本項ではそれ ぞれについて詳細を記す.

#### 3.1 上位群下位群 2 クラス分類及び要因の可視化

限られた調査結果でモデルを構築する必要がある事から、 VGG16 [Simonyan 14]をファインチューニングすることにより好 意度調査上位群及び下位群について 2 クラス分類を行った. その際に分類に寄与した特徴量を可視化する事により、パッケ ージデザインの中で好意度に対して好影響を及ぼしている要素 と悪影響を及ぼしている要素を可視化した.

具体的には、VGG16 の畳み込み層を用いて特徴量抽出を 用い、得られた特徴量について Global Average Pooling [Lin 13]を行った後に新規に構築した全結合層に入力した.季節等 の製品属性は 6 次元の配列として別途構築した全結合層に入 力した.2 つの全結合層の出力を加算し、得られた特徴量を用 いて 2 クラス分類を行った.モデル概要については図 2 に示す. また、その他解析条件詳細については表 2 に示す.

各クラス 25 枚をホールドアウト画像とし、残りの画像について 6 ラウンドのクロスバリデーションによりモデルのトレーニングを行った.学習回数は最大 250 エポックとし、その中でバリデーション画像の正答率が最も高かったエポックのモデルをそのラウンドの結果とした.

トレーニングの結果得られた 6 つのモデルを平均アンサンブ ルし最終モデルとした. 最終モデルを用いたホールドアウト画像 の分類の正答率からモデルを評価した.

寄与した特徴量の可視化については Grad-CAM [Selvaraju 17]を用いた.得られた6モデルそれぞれにGrad-CAMを適用 し、得られた画像の平均画像を特徴量の可視化結果とした.ま た、得られた可視化結果の妥当性についてはキリン株式会社 内でビール缶パッケージをデザインしている担当者の有する知 見との整合性を確認する事により評価した.

#### 3.2 好意度の予測

3.2.1 回帰モデルの性能目標値設定

パッケージデザインの平均好意度と平均的な調査パネルの 好意度との相関係数を回帰モデルの性能目標値とする事とした. しかし、好意度調査における個々のパネルの回答結果を入手 出来なかった為、回答者による回答のばらつきを定量化する為 の調査を行った.

今回の研究に用いたパッケージ画像の内 10 枚をビール事 業に直接従事した事が無いキリン株式会社従業員 23 名にラン ダムな順序で提示し、好意度について 7 段階で回答を得た.回 答結果を最高 7 点、最低 1 点となるように好意度を点数化した. また、全回答者の点数の平均値をパッケージ画像の平均好意 度とした.10 枚の画像に対する個々の従業員の好意度と平均 好意度の相関係数を求め、得られた 23 の相関係数の平均値を 回帰モデルの性能目標値とした.



|                   | 表2 2クラス分類における解析条件 | + 詳細                 |
|-------------------|-------------------|----------------------|
| 使用データ             | 入力①:画像            | 224x224x3            |
|                   | 入力②:製品属性          | 6                    |
|                   | 画像数               | 334枚 (167枚×2群)       |
|                   | ホールドアウト画像数        | 50枚(25枚x2群)          |
| Data Augmentation | 回数                | 9回                   |
|                   | 最大回転角度            | 15度                  |
|                   | 最大垂直移動距離          | 15%                  |
|                   | 最大水平移動距離          | 15%                  |
| 学習条件              | Optimizer         | Adam                 |
|                   | 損失関数              | binary cross-entropy |
|                   | エポック数             | 250エポック              |
|                   | 初期学習率             | 1.00E-06             |
|                   | 初期学習率保持エポック数      | 5エポック                |
|                   | 最終学習率             | 1.00E-09             |
|                   | 学習率変化率            | 0.97倍/エポック           |

| 表3 回帰における解析条件詳細   |              |                |  |  |  |
|-------------------|--------------|----------------|--|--|--|
| 使用データ             | 入力①:画像       | 224x224x3      |  |  |  |
|                   | 入力②:製品属性     | 6              |  |  |  |
|                   | 画像数          | 509枚           |  |  |  |
|                   | ホールドアウト画像数   | 60枚(20枚x3群)    |  |  |  |
| Data Augmentation | 回数           | 9回             |  |  |  |
|                   | 最大回転角度       | 15度            |  |  |  |
|                   | 最大垂直移動距離     | 15%            |  |  |  |
|                   | 最大水平移動距離     | 15%            |  |  |  |
| 学習条件①             | Optimizer    | Adam           |  |  |  |
|                   |              | 平均平方二乗誤差率      |  |  |  |
|                   | 損失関数         | ただし、絶対誤差率が20%を |  |  |  |
|                   |              | 下回った場合は0と見なす。  |  |  |  |
|                   | エポック数        | 50エポック         |  |  |  |
|                   | 初期学習率        | 1.00E-05       |  |  |  |
|                   | 初期学習率保持エポック数 | 5エポック          |  |  |  |
|                   | 最終学習率        | 1.00E-06       |  |  |  |
|                   | 学習率変化率       | 0.95倍/エポック     |  |  |  |
| 学習条件②             | Optimizer    | Adam           |  |  |  |
|                   | 損生開数         | 実測値と予測値の相関係数を  |  |  |  |
|                   | 设入因数         | 1から減じた値        |  |  |  |
|                   | エポック数        | 250エポック        |  |  |  |
|                   | 初期学習率        | 1.00E-06       |  |  |  |
|                   | 初期学習率保持エポック数 | 3エポック          |  |  |  |
|                   | 最終学習率        | 1.00E-08       |  |  |  |
|                   | 学習率変化率       | 0.98倍/エポック     |  |  |  |

#### 3.2.2 回帰モデルの学習条件及び評価方法

3.1 で検討したモデル構造の最終出力を変更し、回帰モデル とした.また、損失関数については平均平方二乗誤差率及び真 値と予測値のピアソンの積率相関係数(以下、相関係数とする) を1から減じた値を用いた.その他解析条件詳細については表 3に示す.

上位群、中位群、下位群各 20 枚をホールドアウト画像とし、 残りの画像について 6 ラウンドのクロスバリデーションによりモデ ルのトレーニングを行った.はじめに損失関数を平均平方二乗 誤差率とし、最大 50 エポックのトレーニングを行った.但し、平 均平方二乗誤差率算出の際に、絶対誤差率が 20%を下回った 画像の平方二乗誤差率は 0 と見なした.次に、得られたモデル について、損失関数を真値と予測値の相関係数を 1 から減じた 値に変更し、最大 250 エポックのトレーニングを行った.尚、前 半の学習についてはバリデーション画像の平均平方二乗誤差 率が最も低かったエポックのモデルを後半の学習に供した.後 半の学習についてはバリデーション画像の真値と予測値の相関 係数を 1 から減じた値が最も小さかったエポックのモデルをラウ

| 表4 2ク  | ラス分類結果   |
|--------|----------|
|        | ホールドアウト  |
|        | 画像分類の正答率 |
| 試行 1   | 82%      |
| 試行 2   | 82%      |
| 試行 3   | 82%      |
| 試行 4   | 76%      |
| 試行 5   | 76%      |
| 試行 6   | 68%      |
| 平均     | 77.7%    |
| 相対煙淮偏差 | 7.2%     |

#### 好意度に対して好影響を及ぼすと予測された領域



図3 ホールドアウト画像におけるGrad-CAMを用いた 要因可視化結果例

ンドの結果とした.得られた 6 つのモデルを平均アンサンブルし 最終モデルとした.

また、トレーニング時に用いる真値については、人間の評価 値に直線性があるか不明であった為、①好意度 ②好意度を 対数変換した値 ③好意度を 10 で除し、その値で 10 を累乗し た値 の 3 条件の換算方法を比較する為、それぞれ 3 回トレー ニングを行った.

最終モデルを用いてホールドアウト画像の好意度の予測を行い、②及び③についてはそれぞれの変換方法の逆関数を適用してから好意度との相関係数を算出しモデルを評価した.

#### 4. 結果

#### 4.1 上位群下位群 2 クラス分類及び要因の可視化

検討したモデルについて 6 回トレーニングを行った結果、ホ ールドアウト画像の分類の平均正答率は 77.7%、相対標準偏 差は 7.2%であった(表 4).また、その際の分類に寄与する領域 の可視化結果(図 3)から、「麒麟のマークは好意度に好影響を 及ぼす」「製品ロゴの英語表記は好意度に悪影響を及ぼす」と いった仮説が得られた.これらはデザイン担当者の有する知見 とも合致したことから、適切なモデルが構築できたと判断した.

#### 4.2 好意度の予測

4.2.1 回帰モデルの性能目標値設定

10 枚のパッケージ画像について個々のパネルの好意度と平 均好意度との相関係数を求めた結果(表 5)、その平均値は 0.611 であった.この数値を回帰モデルの性能目標値とする事 とした.

#### 表5 各被験者の好意度と平均好意度の相関係数

|        | 相関係数   |        | 相関係数  |
|--------|--------|--------|-------|
| 被験者 1  | -0.140 | 被験者 13 | 0.723 |
| 被験者 2  | 0.034  | 被験者 14 | 0.746 |
| 被験者 3  | 0.177  | 被験者 15 | 0.759 |
| 被験者 4  | 0.235  | 被験者 16 | 0.763 |
| 被験者 5  | 0.436  | 被験者 17 | 0.782 |
| 被験者 6  | 0.474  | 被験者 18 | 0.782 |
| 被験者 7  | 0.536  | 被験者 19 | 0.802 |
| 被験者 8  | 0.576  | 被験者 20 | 0.879 |
| 被験者 9  | 0.652  | 被験者 21 | 0.887 |
| 被験者 10 | 0.673  | 被験者 22 | 0.925 |
| 被験者 11 | 0.705  | 被験者 23 | 0.933 |
| 被験者 12 | 0.706  | 平均     | 0.611 |

|       | 表6 | 好意度の変換方法の違いによる相関係数の差 |         |              |  |  |  |
|-------|----|----------------------|---------|--------------|--|--|--|
| 百枯    |    | 杠音庫                  | 好意度を    | 好意度を10で除し    |  |  |  |
| 共唱    |    | 灯息度                  | 対数変換した値 | その値で10を累乗した値 |  |  |  |
| 試行 1  |    | 0.467                | 0.501   | 0.667        |  |  |  |
| 試行 2  |    | 0.701                | 0.520   | 0.591        |  |  |  |
| 試行 3  |    | 0.528                | 0.591   | 0.647        |  |  |  |
| 平均    |    | 0.565                | 0.537   | 0.635        |  |  |  |
| 相対標準偏 | 差  | 21%                  | 8.8%    | 6.2%         |  |  |  |

|        | 表7 好意度予測結果 |         |  |  |
|--------|------------|---------|--|--|
|        | 相関係数       | 平均絶対誤差率 |  |  |
| 試行 1   | 0.667      | 24%     |  |  |
| 試行 2   | 0.591      | 35%     |  |  |
| 試行 3   | 0.647      | 16%     |  |  |
| 試行 4   | 0.542      | 23%     |  |  |
| 試行 5   | 0.629      | 39%     |  |  |
| 試行 6   | 0.641      | 17%     |  |  |
| 平均     | 0.620      | 26%     |  |  |
| 相対標準偏差 | 7%         | 36%     |  |  |

#### 4.2.2 好意度予測モデルの学習結果

トレーニング時に用いる真値を①好意度 ②好意度を対数変換 した値 ③好意度を10で除し、その値で10を累乗した値とした 条件について各3回のトレーニングを行いその結果を比較した (表6).その結果、好意度を10で除し、その値で10を累乗した 値を用いた場合に最も良いモデルが得られた.そこで、当該条 件のみさらに3回のトレーニングを行った結果、相関係数の平 均値が0.620、相対標準偏差が7.3%であった(表7).性能目標 値が相関係数0.611であった事から、適切なモデルが構築でき たものと判断した.

尚、これらのモデルについてホールドアウト画像の好意度とその予測値の平均絶対誤差率を算出した結果、平均 26%、相対標準偏差 36%であった.

#### 5. まとめ

本研究により、限られた数のパッケージデザインの好意度調 査結果から作成したモデルを用いて、未調査のパッケージデザ インの中から好意度に対して好影響を及ぼすと予測される要素 と悪影響を及ぼすと予測される要素を可視化し、それをデザイ ナーにフィードバックする事と、複数のパッケージデザイン候補 の中から実際の調査の対象にするパッケージデザインを絞り込 むプレスクリーニングテストを行う事が可能になったと考える.一 方で、好意度そのものを高精度で予測するには予測結果の誤 差が大きく、更なる改善が必要であると考えられた.

#### 参考文献

[石井 10] 石井裕明, 恩藏直人:価値視点のパッケージ・デザイン戦略, マーケティングジャーナル 30(2), 31 - 43(2010)

- [Talebi 17] Talebi, H. Milanfar, P.: NIMA: Neural Image Assessment, arXiv preprint arXiv, 1709.05424, 2017
- [Kong 16] Kong, S. Shen, X. Lin, Z. Mech, R. Fowlkes, C.: Photo Aesthetics Ranking Network with Attributes and Content Adaptation, *arXiv preprint arXiv*, 1606.01621, 2016
- [Simonyan 14] Simonyan, K. Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv preprint arXiv, 1409.1556, 2014
- [Lin 13] Lin, M. Chen, Q. Yan, S.: Network In Network, arXiv preprint arXiv, 1312.4400, 2013
- [Selvaraju 17] Selvaraju, R. Cogswell, M. Das, A. Vedantam, R, Parikh, D. Batra,D.: Grad-cam: Visual explanations from deep networks via gradient-based localization, 2017 IEEE International Conference on Computer Vision (ICCV), 618-626, 2017

# 深層学習を用いた不動産間取り図のグラフ化と物件検索への応用

Conversion of Floor Plan Images to Graph Structures using Deep Learning and Application to Retrieval

山田 万太郎 Mantaro Yamada

汪 雪婷 <sub>Xueting</sub> Wang 山﨑 俊彦 Toshihiko Yamasaki 相澤 清晴 Kiyoharu Aizawa

東京大学

The University of Tokyo

The purpose of this research is to automatically convert real estate floor plan images into graph structures that reflect the floor plans. In order to do this, we recognize each room or door in the images with semantic segmentation using deep learning, and create graph structures based on their adjacencies. By this proposed method, it was confirmed that floor plan images could be converted to the graphs with the similarity of 81% with the ground truth graphs. Representing floor plans as structured representations–graph structures– makes it easy to compare and evaluate floor plans, and even search, and is expected to be applied to any systems that handles floor plans.



Fig. 1: 間取り図の例 [1]

#### 1. はじめに

不動産間取り図とは、不動産物件においてその間取りを表現 した図である.間取り図は、人々が物件を評価する際に非常に 有用な情報となる.しかし、間取り図はその作成者や作成方法 が様々であるため、表記ゆれが大きくなっている.その様子を Fig.1に示す.このような表記ゆれが、間取り図を直接処理 することを困難にしていると考えられる.

この問題が表れている一例として,既存の不動産物件検索 システムが挙げられる.既存の物件検索システムは,賃料や立 地,築年数などに対しては詳細な検索ができる一方,間取りに 対してはワンルームや 2LDK といった部屋のタイプでしか検 索できない.これは,例えば「10 帖以上のリビングに水回り が集中している利便性の高い配置がいい」といった間取りに対 する詳細な希望を持っているユーザーのニーズを満たしていな い.このようなニーズに沿った検索を可能にするには,間取り 図の内容をコンピュータに認識させ,その情報で検索を行う必 要がある.しかし,そのために間取り図画像を直接処理するの は、上述の理由から難しい問題であるといえる.

そこで本研究では、間取り図を表記ゆれの大きい画像という 形態から、グラフ構造という構造化された表現に変換すること を目指す.これによって、間取りの比較や評価、さらには検索 が容易になり、間取りを扱う様々な応用に繋がることが期待で きる.ここでは、深層学習による画像認識を用いて間取り図の 内容を認識することによって、間取り図を自動でグラフ化する 手法を提案する.

連絡先: 東京大学大学院情報理工学系研究科 相澤山崎研究室 〒 113-8656 東京都文京区本郷 7-3-1 TEL: 03-5841-6761 mail: yamada@hal.t.u-tokyo.ac.jp



(a) Step1: 間取り図の semantic segmentation [4]



Fig. 2: 提案手法の概要図

#### 2. 関連研究

間取り図の解析や認識を行っている研究自体は多く存在す る.代表的なものとしては例えば Liu [2] らの研究が挙げられ る.彼らは,壁の交差点や各部屋の領域と家具等の物体を深層 学習を用いて認識することにより,間取り図をベクターイメー ジへ変換することを試みている.

間取り図のグラフ構造への変換を行っている例としては, Yamasaki [3] らの研究が挙げられる.しかし,ここで作成さ れているグラフは間取り構造を正しく反映できていないという 問題がある.これは単に距離の近い部屋同士を隣接と判定して いるためであり,実際には行き来できない部屋の間にもエッジ が存在してしまう結果となっている.また,変換したグラフに ついての定量的評価も行われていない.

#### 3. 提案手法

本研究では、以下の2ステップで不動産間取り図のグラフ 変換を実現する.その概要図をFig.2に示す.

- 1. 間取り図画像の semantic segmentation を行う.
- 2. 各部屋やドアの接続関係からグラフ構造を作成する.

Table 1: クラスラベルの定義

| ラベル      | 説明              |
|----------|-----------------|
| wall     | 外壁, 内壁          |
| tatami   | 和室              |
| west     | 洋室              |
| dk       | ダイニング,キッチン,リビング |
| wc       | トイレ             |
| bath     | 浴室              |
| washing  | 洗面所,脱衣所         |
| entrance | 玄関              |
| balcony  | バルコニー,ベランダ,テラス  |
| rouka    | 廊下              |
| stairs   | 階段              |
| cl       | クローゼット,押入れ,下駄箱  |
| doors    | 開き戸,引き戸,折戸,窓    |
| unknown  | 記載のない箇所,不明箇所    |

提案手法では,まず深層学習による semantic segmentation を行い,間取り図をピクセルレベルで認識する.これによっ て,画像中のどこにどのような部屋が存在するのかがわかる. 本研究では,深層ネットワークモデル FCN-8s [4] を用いてこ れを行う.モデルの学習のためのデータセットとしては,間取 り図画像とそれに対応する独自生成の正解ラベルマスク 4,800 組を用意している.ラベルは Table 1 に示す計 14 種類とし, 間取りを構成する主要な要素が含まれている.

次に,各部屋の領域を走査して接続関係を調べ,ルールベー スでグラフの作成を行う.ノードの作成は,一定以上の面積を 持つ領域を抽出することで行う.エッジの作成は,同じドアに 隣接している部屋間,あるいは直接隣接している部屋間にのみ 行う.これにより,実際の部屋の接続関係を正しく反映したグ ラフ構造を作成することができる.

#### 4. 実験

#### 4.1 Semantic segmentation の評価

まず,提案手法の Step1 にあたる semantic segmentation の精度を評価する実験を行う.データセットを Train/Validation/Test data として 3,800/500/500 枚に分割 し, FCN-8s で間取り図画像と正解ラベルマスクの対応関係を 学習する.学習の後, Test data に対して式 (1) と式 (2) で評 価を行う.ただし,  $n_c$  はクラス数,  $t_i$  はクラス *i* に属するピ クセルの総数,  $n_{ij}$  はクラス *i* に属しクラス *j* と予測されたピ クセルの総数である.

mean accuracy = 
$$\frac{1}{n_c} \sum_{i=1}^{n_c} \frac{n_{ii}}{t_i}$$
 (1)

mean IoU = 
$$\frac{1}{n_c} \sum_{i=1}^{n_c} \frac{n_{ii}}{t_i + \sum_{i'=1}^{n_c} n_{i'i} - n_{ii}}$$
 (2)

実験の結果, Test data に対する平均の評価値は, mean accuracy が 90.6%, mean IoU が 84.0% となった. クラスごと の精度は Fig. 4 の通りである. これより, 面積が大きく文字 表記がある洋室や和室, リビングの認識精度は高く, 面積が小 さいあるいは文字表記がない領域であるドアや壁, 廊下の精度 は低くなる傾向があることがわかる.



Fig. 3: クラスごとの accuracy と IoU



Fig. 4: Semantic segmentation(中段) とグラフ化 (下段) の例

#### 4.2 グラフ化の評価

Step2 におけるルールベースでのグラフ化をし、その精度 の評価をする実験を行う. Test data に対する semantic segmentation 後にルールベースでのグラフ化を行い、その結果 作成されたグラフがどれだけ正解グラフに類似しているかを 調べる. グラフの類似度指標としては、一般的で扱いやすい ことから、MCS による類似度を用いる. グラフ $G_1$  のノード 数とエッジ数の和を  $|G_1|$  と表し、グラフ $G_1$  とグラフ $G_2$  の MCS(Maximum Common Subgraph:最大のエッジ数を持つ 共通サブグラフ)を MCS( $G_1, G_2$ ) とすると、グラフ $G_1$  とグ ラフ $G_2$  の類似度は式 (3) で計算される. MCS 類似度は 2つ のグラフが全く異なる場合は 0、全く等しい場合は 1 となり、 0~1 に正規化されている.

$$\sin(G_1, G_2) = \frac{|\mathrm{MCS}(G_1, G_2)|}{\max(|G_1|, |G_2|)} \tag{3}$$

この実験の結果,提案手法によって間取り図から変換した グラフと正解グラフとの平均の類似度は、0.810となった.ま た,その一例を Fig. 4 の下段に示す.右端の例は精度の低い 例である.この例は semantic segmentaion の精度が低く,特 に玄関付近と洋室での誤認識が目立つ.その結果,変換された グラフにも誤りが反映されており,本来の間取り図には存在し ない部屋のノードができてしまっていることがわかる.一方, 左の 2 つの例は精度が高い例であり,間取りを正しく表現し たグラフ化ができている.

#### 4.3 物件検索への応用

以上の提案した手法による間取り図のグラフ化を応用して, 間取り類似物件の検索を行う.ここでは,クエリとして任意の 間取り図画像を入力し,その間取りとの類似度が高い間取り を持つ物件の間取り図画像を出力するという実験を行う.ク エリとしては Test data を用い,検索候補としては LIFULL HOME'S データセットからさらに 25,000 件の間取り図を用 いる.この 25,000 件にはこれまでの実験で用いた 4,800 枚は 含まれていない.検索の手順は以下の通りである.

- 1. 検索候補の間取り図 25,000 件をあらかじめグラフ化する.
- 2. システムにクエリとなる間取り図画像を入力する.
- 3. 提案手法を用いてクエリ画像をグラフ化する.
- 4. クエリと検索候補のグラフとの間の類似度を計算する.
- 5. 類似度が高い順に検索結果を表示する.

このようにして類似する間取り図を検索した結果の例を Fig. 5 に示す. Fig. 5a は 2DK で和室と洋室をひとつずつ持つ間 取り図をクエリとした例である,検索結果を見るとと,クエリ と同様の間取り構造を持っていることがわかる.和室と洋室が 存在するだけではなく,その繋がり方や付随する収納の有無, 水回りへのアクセスまでもが一致していることがわかる.Fig. 5b はクエリを 2 階建ての間取り図とした例である.検索結果 も同様に 2 階建ての構造で,水回りが 1 階に,バルコニー付き の洋室が 2 階にという配置も一致していることがわかる.特 に 3 位までの間取り図はクエリによく一致している.4位と 5 位は 2 階部分の部屋がひとつ多いが,その点以外は概ね一致 しているといえる.

一方で, Fig. 5c は類似の間取り図を検索できなかった例で ある. クエリとなる間取りは, 玄関が LDK と洋室の両方に繋 がっていて, 中央に位置する洗面所を介して LDK と洋室を行 き来できるという特徴的な間取りである. しかし, 検索結果に そのような間取りを含む物件は現れなかった. この場合, クエ リとなっている間取り構造が極めてユニークであったことが原 因である可能性もある.

以上の結果から,間取りをグラフで表現しその類似度での検 索を行うことで,間取り図のスタイルやカラーリングは異なっ ていたとしても間取りの構造が類似している物件を検索できる 例があることが確認できた.

#### 5. まとめ

本研究の目的は、不動産間取り図の画像を自動でグラフ構造 に変換することである.本研究で提案した手法により、間取り 図画像をおよそ8割の精度でその間取りを反映したグラフ構 造に変換することができることを示した.さらに、それを用い ることによって任意の間取り図に対してそれと構造的に類似し ている間取りを検索する仕組みを実現できることを確認した. 本研究の成果は以下のようにまとめることができる.

- 間取りを反映したグラフへの変換手法を提案したこと
- 変換したグラフについて定量的な評価を行ったこと
- 応用として類似の間取りを検索できる例を示したこと

一方で,類似物件検索への応用については多くの課題が残さ れており,例えばその評価がひとつである.さらに,ユーザー の間取りに対する要望をシステムに伝えるためのインタフェー スをどう設計するかは重要な課題であるといえる.

#### 謝辞

本研究データの一部は, NII-IDR より提供されている LI-FULL HOME'S データセットを用いている.

#### 参考文献

- 国立情報学研究所 IDR 事務局. LIFULL HOME'S データ セット, 2010-2019.
- [2] Chen Liu, Jiajun Wu, Pushmeet Kohli, and Yasutaka Furukawa. Raster-to-Vector: Revisiting Floorplan Transformation. In *IEEE International Conference on Computer Vision*, pp. 2214–2222, 2017.
- [3] Toshihiko Yamasaki, Jin Zhang, and Yuki Takada. Apartment Structure Estimation Using Fully Convolutional Networks and Graph Model. In ACM Workshop on Multimedia for Real Estate Tech, pp. 1–6, 2018.
- [4] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully Convolutional Networks for Semantic Segmentation. In *IEEE Conference on Computer Vision and Pattern Recognition*, 2015.

## 3N4-J-10-03



(c) 失敗例

法面所 浴室

バルコニ

Fig. 5: 類似間取り図検索の例 左上が検索クエリとなる間取り図.右へ順に5位までの検索結果. General Session | General Session | [GS] J-7 Agents

## [3P4-J-7] Agents: social multiagents

Chair:Naoki Fukuda Reviewer:Jun Ichikawa

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room P (Front-left room of 1F Exhibition hall)

## [3P4-J-7-01] Explainable Compromising Algorithm based on Constraint Relaxation for Automated Negotiating Agents OShun Okuhara<sup>1,2</sup>, Takayuki Ito<sup>2</sup> (1. Fujita Health University, 2. Nagoya Institute of Technology) 3:50 PM - 4:10 PM [3P4-J-7-02] An allocation strategy with deep reinforcement learning for efficient task processing in multi agent system OGenki Matsuno<sup>1</sup>, Sho Tanaka<sup>2</sup>, Hiroki Hara<sup>2</sup>, Syunyo Kawamoto<sup>2</sup>, Syo Shimoyama<sup>2</sup>, Takashi Kawashima<sup>2</sup>, Daisuke Tsumita<sup>2</sup>, Yasushi Kido<sup>1</sup>, Osamu Hashimoto<sup>1</sup>, Tomohiro Takagi<sup>2</sup> (1. Skydisc, Inc., 2. Meiji University) 4:10 PM - 4:30 PM [3P4-J-7-03] Omoiyari as Filling Gaps Making Collective Adaptation OYoshimiki Maekawa<sup>1</sup>, Fumito Uwano<sup>1</sup>, Eiki Kitajima<sup>1</sup>, Keiki Takadama<sup>1</sup> (1. The University of Electro-Communications) 4:30 PM - 4:50 PM [3P4-J-7-04] Investigation of online simulation method of social consensus formation OYasuko Kawahata<sup>1</sup>, Akira Ishii<sup>2</sup>, Takuya Ueoka<sup>1</sup> (1. Gunma University, 2. Tottori University) 4:50 PM - 5:10 PM [3P4-J-7-05] Estimation of agent's rewards with multi-agent maximum discounted causal entropy inverse reinforcement learning OKeiichi Namikoshi<sup>1</sup>, Sachiyo Arai<sup>1</sup> (1. Chiba University) 5:10 PM - 5:30 PM

## 自動交渉エージェントのための 制約緩和を用いた説明可能な妥協アルゴリズム Explainable Compromising Algorithm based on Constraint Relaxation for Automated Negotiating Agents

奥原 俊 \*1,\*2 伊藤 孝行 \*1 Shun Okuahra Takayuki Ito

\*<sup>1</sup>名古屋工業大学大学院情報工学専攻 Dept. of Computer Science, Nagoya Institute of Technology \*<sup>2</sup> 藤田医科大学医療科学部 School of Health Sciences, Fujita Health University

This paper presents an explainable concession process based on constraint relaxation in multi-agent negotiation. Automated negotiation has been studied widely and is the promising technology for the future smart city where multiple heterogeneous agents, like driver-less cars, are conflicting and collaborating. There are a lot of studies on negotiating agents including international competitions. The problem is that most of the proposed negotiating agents employ ad-hoc conceding process, where basically they are adjusting threshold to accept their opponents offers. Because it is just adjusting a threshold, it is very difficult to show how and what the agent conceded even after agreement. In this paper, we propose an explainable concession process by using a constraint relaxation process. Here, an agent changes its belief not to believe some constraint so that he/she can accept its opponent offer. Our experimental results demonstrate that our method can work effectively.

#### 1. はじめに

自動交渉エージェント [Ito 07, Jennings 01] の重要性が高 まっており広く研究が進められている [Bai 17, Fukuta 16, Fujita 15, Marsa-Maestre 14, Ito 13, Ito 11, Ito 10, Ito 09, Ito 08]. 社会において知的な処理を自律的に行う異種のシス テム (エージェント)が現実に実現されつつある. 複数のエー ジェント間の競合が発生し,自動交渉によって合意を自動的に 得るような仕組みが現実に必要とされ得る. 自動交渉エージェ ントの研究は,マルチエージェントシステムの分野で広く行わ れており,特に 2010 年前後から国際ワークショップや国際競 技会が開催され,次世代の重要な技術である.

自動交渉エージェントの研究では、エージェントは自分の好 みを秘匿したまま、交渉プロトコルに基づき交渉し、合意を得 る.エージェントの好みは、多論点の効用関数(多属性効用関 数)で表される.交渉プロトコルは、様々なプロトコルが提案 されているが、仲介型のプロトコル、繰り返し型のプロトコ ル、提案交換型プロトコルが一般的である.

自動交渉エージェントの研究のテストベットとして,自動 交渉競技会 ANAC(Automated Negotiating Agents Competition)が 2010 年から開催されている. ANAC では多論点の 効用関数と提案交換型プロトコルが採用されており,毎年様々 なルールの拡張や修正を行い,様々な環境でのエージェントの 交渉戦略が提案されている.

課題は、妥協プロセスの説明可能性である.交渉において、 エージェントは自分の利益ばかりを考えていると合意に到達で きないため、いかに妥協するかという妥協戦略が重要である. 既存の自動交渉エージェントのほとんどが、閾値の上げ下げの みを用いたアドホックなプロセスであった.そのため、どのよ うに妥協したかという説明が難しいという課題があった.

連絡先: 奥原俊, 豊明市沓掛町田楽ヶ窪 1 番地 98 藤 田医科大学 大学 6 号館 507 室, 0562-93-2628, okuhara@itolab.nitech.ac.jp

連絡先:伊藤孝行,名古屋工業大学大学院情報工学専攻,名古屋 市昭和区御器所町名古屋工業大学4号館702,052-735-7968,ito.takayuki@nitech.ac.jp 本研究では、本課題を解決するために、妥協プロセスを制約 の緩和プロセスとして提案する。制約とは効用の基本単位を表 すものである。つまり、本研究では、エージェントの効用空間 を、論点とその論点を満たす制約の集合とする。制約は満たさ れれば価値がある。例えば、車を買うときの論点(Issue)は、 価格、色、タイプなどがある。これらの論点は制約によって結 び付けられる。つまり、タイプがスポーツカーであれば、色は 赤という制約や、タイプがセダンであれば、色は白という制約 である。制約は満たされることで価値を生み出すが、満たされ ない場合は価値を生み出さない。

また,本研究では,共有論点と個人論点を仮定する.つま り,合意は,共有論点についてエージェント同士が同じ値を持 つことである.個人論点については,ここのエージェントが なるべく自分の効用が高くなるように選択することができる. エージェントは,共有論点について相手のエージェントと同じ 値になるようにしながら,個人論点については,制約をなるべ く多く満たすように値を決めていくというトレードオフを解決 する必要がある.

このトレードオフを解決するため,エージェントは妥協プロ セスを行う.妥協プロセスにおいて,エージェントは,制約の 集合の中から,制約を一つずつ取り除いていくことで,共有論 点についての値の取れる範囲を調整する.制約を取り除くこと を制約緩和と呼ぶ.

本稿は、2章で自動交渉エージェントと交渉プロトコルにつ いて述べる、3章で、新たに提案する制約緩和に基づく妥協ア ルゴリズムについて述べる、4章で評価実験とその評価につい て述べる、5章で関連研究と本研究の違いを明らかにし、6章 で本稿をまとめる、

#### 2. 自動交渉エージェント

#### **2.1** 効用ハイパーグラフ

エージェントは複雑な効用空間を持つものとする [Ito 07]. 複雑な効用空間の表現方法は様々な方法が提案されている [Robu 05, Robu 08, Aydogan 15].本論文では,論点間の依 存関係に注目して表現するために,ハイパーグラフによる表現 [Hadfi 14b, Hadfi 14a]を用いる.ハイパーグラフとはグラフ



図 1: エージェント間の論点の共有と効用グラフ

を一般化した数学の表現で,エッジが複数のノードを連結できる.ハイパーグラフを用いた効用空間を,効用ハイパーグラフ と呼ぶ.ここでは,ノードを論点,および,エッジを制約とし て考える.

エージェント *i* の効用空間  $U_i$  は、ハイパーグラフ (*I*,*C*) で 表され、*I* は論点集合 (ノード)、*C* は制約集合 (エッジ) で ある。各論点  $I_i \in I$  は、ある決められた範囲  $D_i$  内の論点値 (Issue Value)をもつ、例えば、車を購入する場合の論点の一 つ「色」は、「赤、青、緑」という範囲のどれかの論点値をも つ、制約  $C_j \in C$  は  $(v_{C_j}, \phi_{C_j}, \delta_{C_j})$  で表される.  $v_{C_j}$  は制約  $C_j$  の価値を表す.  $\phi_{C_j}$  は制約  $C_j$  が連結している論点の集合 である、したがって、 $\phi_{C_j} \subset I$  である.  $\delta_{C_j}$  は、範囲 (range) の集合であり、 $\delta_{C_j} = \{range_{C_j}(I_i) : I_i \in \Phi_{C_j}\}$ 

ここで、制約  $C_j$  が満たされる条件は以下の通りである. 論 点  $I_i$  がとる値を  $x_{I_i}$  とする.  $C_j$  が満たされた場合,  $C_j$  を持 つエージェントはその価値  $v_{C_i}$  を得る.

$$C_{j} = \begin{cases} satisfy & if \ x_{I_{i}} \in range_{C_{j}}(I_{i}) \ \forall I_{i} \in \phi_{C_{j}} \\ unsatisfy \quad otherwise \end{cases}$$

図1にエージェントの効用グラフと論点の共有についての 例を示す.ここでは2つのエージェントが,効用グラフを持つ と同時に3つの論点を共有している.それぞれのエージェント は,各論点を結ぶ制約を持つ.論点は値をとる.制約は,結ん でいる論点の値が,制約としての範囲(range)に含まれる時 充足する.制約が充足すると,エージェントはその制約から価 値を得ることができる.

仮定 1. 制約は充足しにくい制約ほど価値が高い

仮定1に従い、本論文の実験では以下の2つを仮定している.

- より広いの値域(range<sub>Cj</sub>)を持っている制約の方が充足しやすいので,価値は低い.一方より狭い値域を持っている制約は充足しにくいので,価値は高い.
- さらに、個人制約より、相手との合意が必要な共有制約のほうが価値が高い。
- 2.2 交渉プロトコル

今回は、妥協アルゴリズムに焦点を置くため、交渉プロトコ ルは出来るだけ単純なものを採用する.本稿では繰り返し同時 提案プロトコルを提案する.すなわち、毎回、各エージェント が同時に提案を提出し、提案が互いにとって受け入れられるな ら合意する.そうでなければ、次の提案を行う.という単純な プロトコルである.

自動交渉の研究分野では交互提案プロトコル [Rubinstein 82] も採用されるが、どちらが先手で提案を出すかにより、妥協の



図 2: 制約緩和による合意の例1:初期設定



図 3: 制約緩和による合意の例2:緩和により合意

戦略が変わってしまうため,今回は単純な繰り返し同時提案プロトコルを採用した.交互提案プロトコルへの拡張は今後の課 題である.

#### 3. 制約緩和に基づく説明可能な妥協プロセス

#### 3.1 説明可能な妥協プロセス

本章では、制約緩和に基づく妥協プロセスを示す。制約緩和 とは、満たすべき制約の数を少なくすることで、自分が取り得 る効用(価値)の総和を少なくすることをいう.

既存の研究のように,アドホックに閾値を調整することで, 妥協を行う場合,なぜその値で合意したのか,を説明すること ができない.本研究では,満たすべき制約を少なくする,具体 的には,ここでは制約を考慮に入れないことにすることで,ど の制約を考慮に入れ,どの制約を考慮に入れないことで,合意 できたか,という妥協の説明が可能となる.基本的には,まず 信じている(IN)制約と信じていない(OUT)制約を分ける. 初期は全ての制約を IN としており,緩和した制約を OUT に する.

図 2 と図 3 に本論文で提案する妥協プロセスの簡単な例を 示す. 図 2 で示すように, Agent1 は Issue  $I_1$  と Issue  $I_s$  を持 つ. Issue  $I_s$  は, 共有論点である. Agent 2 は Issue  $I_2$  と Issue  $I_s$  を持つ. 各 Issue は値を 1, 2, および 3 の三つを持 つとする. Agent 1 は, 制約  $C_1$  と  $C_2$  を持つ. 両方を満たし た方が効用が高くなるため, 初期の最適解は Issue  $I_1$  につい ては 1, および  $I_s$  については 2 となる. 一方 Agent 2 は, 制 約  $C_3$ ,  $C_4$ , および  $C_5$  をもつ. 同様に最適解は Issue  $I_s$  につ いては 3,  $I_2$  については 2 となる. 図 2 の状態では,共有論 点  $I_s$  について解が異なるため,合意はできていない.

そこで、各エージェントは制約を一つ減らす(IN から OUT に変える)ことで妥協プロセスを行う.ここでは例えば、Agent 1 は制約  $C_1$  を OUT にしたとする.Agent 2 は制約  $C_5$  を OUT にしたとする.すると Agent 1 の Issue  $I_s$  の値は 2 のままで あるが、Agent 2 の Issue  $I_s$  の値も 2 に変化する(より多く の制約を満たす値の方が効用が高くなる).これにより Agent 1 と Agent 2 は合意ができる.

妥協においてどの制約を OUT にしたか(信じないようにしたか)ということがわかるため,たんに閾値を下げるのではなく,どのような制約を外したかという説明が可能となる。

#### 3.2 制約緩和アルゴリズム

様々な制約緩和が考えられるが,ここでは以下の4つの方法 を提案する.初期は全ての制約を IN としており,緩和した制 約を OUT にする.

- ランダム制約緩和: IN の制約のなかからランダムに制約 を選択し OUT にする.
- 価値に基づく制約緩和: IN の制約の中からもっとも価値の低い制約を選択し OUT にする.
- 距離に基づく制約緩和: IN の制約の中から共有論点から もっとも距離の遠い制約を選択し OUT とする.ここで 距離とは、共有論点からの連結する制約の数とする.
- 価値と距離に基づく制約緩和: IN の制約の中から共有論 点からもっとも距離の遠い制約のうち最も価値の低い制 約を選択肢 OUT とする.

#### 4. 評価実験

#### 4.1 実験設定

妥協のための制約緩和アルゴリズムの性能比較のために実 験を行う.以下に実験設定を示す.

- 参加するエージェントは2エージェントとする.
- 共有論点は1つとする..
- 各エージェントの論点の数は x とする.
- 各論点を包含する制約を1つ以上持つものとする.つまり制約のない論点はないものとする.
- 各論点を包含する制約の数は y とする.

以上の設定は,多論点かつ論点間の依存があるエージェント間 交渉の設定としては,論点がたくさんあり,それらが少ない制 約で連結しているような場合である.

#### 4.2 結果と考察

いくつかの設定で結果が得られているが,ここでは2つの 結果について図4と図5に示す.ここでは,価値に基づく制 約緩和(min),ランダム制約緩和(random),距離に基づく 制約緩和(distance),および,価値と距離に基づく制約緩和 (distance+min)について比較を行なった.

図4では、各エージェントの論点の数はx = 1とする.各 論点を包含する制約の数はy = 16とする.

図 5 では、各エージェントの論点の数は x = 2 とする. 各 論点を包含する制約の数は y = 11 とする.



図 4: 実験結果: x = 1 および y = 16



図 5: 実験結果: x = 2 および y = 11

どちらの場合もランダム制約緩和(random)に対して,価値に基づく制約緩和(min),ランダム制約緩和(random),距離に基づく制約緩和(distance),および,価値と距離に基づく制約緩和が,有意に社会的余剰を多く獲得することができている.

#### 5. 関連研究

本節では関連研究と本研究の提案の差異を示す.

妥協プロセスが提案されたのは、Klein らの論文 [Klein 03] である. 主な主張は、論点が独立な多論点効用空間を前提とした 交渉では, パレートフロントにおいて, エージェントが徐々に妥 協するのが合理的であるが, 論点が依存している場合は効用空 間が複雑になり、単純にはパレートフロントを見出せないので 単純ではないということを指摘している.一つの方法として SA による合意点探索プロトコル(暗黙に妥協を仮定している)を 提案している. さらに, Payemann ら [Faratin 98] は様々な妥 協の関数について分析している. ANAC 競技会 [Baarslag 12] は 2010 年から開催されている. 相手のオファーから統計的 に相手が受理しうる提案を推定し提案しながら、時間による 割引を考慮した閾値の調整によって提案を受け入れるという 方式が、一般的である. 例えば、AgentK [Kawaguchi 11] は、 ANAC2010の優勝エージェントである. AgentK は,相手の 提案履歴から相手の効用空間と交渉に対する姿勢を推定する. 相手が友好的であれば譲歩し、相手が敵対的であれば一定以上 は譲歩しないという, ANAC の基本的な譲歩戦略の先駆けと なった戦略である. Fawkes[Baarslag 14] は, ANAC2013 の 優勝エージェントである. Fawkes は、相手の提案履歴に基づ いて,離散ウェーブレット予測を用いて,最適な譲歩を推定す る.以上の研究では、基本的には、妥協のプロセスについて、

閾値を変化させる方法が多く、何によって妥協が実現されてい るかという説明可能性は実現できない.また,著者らが知る限 り,多論点の効用関数を仮定している自動交渉エージェントに 関する研究で,妥協の説明可能性について言及している研究は 存在しない.

マルチエージェント環境における,一貫性の分類について DTMS(Distributed Truth Maintenance System)を提案し た論文 [Bridgeland 90] で提案されている.彼らは,分散整 合性を Inconsistent, Local-Consistency, Local-and-Shared-Consistency, Global Consistency に分類している.本研究で, 合意するということは,各エージェントの中で整合しつつ,共 有する論点につても整合するということであり,Local-and-Shared-Consistency に当たる.本論文で提案する妥協の方法 は,Local-and-Shared-Consistency を得るための方法の一つ である.ただし,本論文で扱う制約グラフは効用空間を表現し ているが,DTMS では好みを表現していない.

#### 6. おわりに

本論文では,自動交渉エージェントのための説明可能な妥協 プロセスを示した.既存のほとんどの自動交渉の妥協プロセス は,閾値のアドホックな調整がほとんどだが,ここでは制約を 一つずつ削る(INからOUTにする)ことで制約緩和を行い 説明可能とした.本研究の新しい貢献は以下の点にある.(1) 制約のグラフ構造に基づく説明可能な妥協プロセスを新たに提 案した.(2)自動交渉において,共有論点と個人的論点を区 別したモデルを新たに提案した.(3)妥協プロセスにおいて, 影響と価値に基づく制約緩和プロセスを提案し,その効果を示 した.

#### 参考文献

- [Aydogan 15] Aydogan, R., Baarslag, T., Hindriks, K., Jonker, C., and Yolum, P.: Heuristics for using CPnets in utility-based negotiation without knowing utilities, *Knowledge and Information Systems*, Vol. 45, pp. 357–388 (2015)
- [Baarslag 12] Baarslag, T., Fujita, K., Gerding, E., Hindriks, K., Ito, T., Jennings, N. R., Jonker, C., Kraus, S., Lin, R., Robu, V., and Williams, C.: The First International Automated Negotiating Agents Competition, Artificial Intelligence Journal (AIJ) (2012), (to appear)
- [Baarslag 14] Baarslag, T.: What to bid and When to stop, Master's thesis, Delft University of Technology (2014)
- [Bai 17] Bai, Q., Ren, F., Fujita, K., Zhang, M., and Ito, T.: Multi-agent and Complex Systems, Springer (2017)
- [Bridgeland 90] Bridgeland, D. and Huhns, M.: Distributed Truth Maintenance, pp. 72–77 (1990)
- [Faratin 98] Faratin, P., Sierra, C., and Jennings, N. R.: Negotiation Decision Functions for Autonomous Agents, *Int. Journal of Robotics and Autonomous Systems*, Vol. 24, No. 3 - 4, pp. 159–182 (1998)
- [Fujita 15] Fujita, K., Ito, T., Zhang, M., and Robu, V.: Next Frontier in Agent-based Complex Automated Negotiation, Vol. 596, Springer (2015)
- [Fukuta 16] Fukuta, N., Ito, T., Zhang, M., Fujita, K., and Robu, V.: Recent Advances in Agent-based Complex Automated Negotiation, Vol. 638, Springer (2016)

- [Hadfi 14a] Hadfi, R. and Ito, T.: Modeling Complex Nonlinear Utility Spaces Using Utility Hyper-Graphs, in *Modeling Decisions for Artificial Intelligence*, pp. 14–25, Springer (2014)
- [Hadfi 14b] Hadfi, R. and Ito, T.: On the Complexity of Utility Hypergraphs, in Proceedings of the Seventh International Workshop on Agent-based Complex Automated Negotiations(ACAN2014) (2014)
- [Ito 07] Ito, T., Hattori, H., and Klein, M.: Multi-issue Negotiation Protocol for Agents : Exploring Nonlinear Utility Spaces, in *Proc. of 20th International Joint Conference on Artificial Intelligence (IJCAI-2007)*, pp. 1347– 1352 (2007)
- [Ito 08] Ito, T., Hattori, H., Zhang, M., and Matsuo, T.: Rational, robust, and secure negotiations in multi-agent systems, Vol. 89, Springer (2008)
- [Ito 09] Ito, T., Zhang, M., Robu, V., Fatima, S., and Matsuo, T.: Advances in agent-based complex automated negotiations, Vol. 233, Springer (2009)
- [Ito 10] Ito, T., Zhang, M., Robu, V., Fatima, S., Matsuo, T., and Yamaki, H.: *Innovations in Agent-Based Complex Automated Negotiations*, Vol. 319, Springer (2010)
- [Ito 11] Ito, T., Zhang, M., Robu, V., Fatima, S., and Matsuo, T.: New trends in agent-based complex automated negotiations, Vol. 383, Springer (2011)
- [Ito 13] Ito, T., Zhang, M., Robu, V., and Matsuo, T.: Complex automated negotiations: Theories, models, and software competitions, Springer (2013)
- [Jennings 01] Jennings, N. R., Faratin, P., Lomuscio, A. R., Parsons, S., Wooldridge, M., and Sierra, C.: Automated Negotiation: Prospects, Methods, and Challenges, *Group Decision and Negotiation*, Vol. 10, pp. 199–215 (2001)
- [Kawaguchi 11] Kawaguchi, S., Fujita, K., and Ito, T.: Compromising strategy based on estimated maximum utility for automated negotiation agents competition (ANAC-10), in *Modern Approaches in Applied Intelli*gence, pp. 501–510, Springer (2011)
- [Klein 03] Klein, M., Faratin, P., Sayama, H., and Bar-Yam, Y.: Negotiating Complex Contracts, Group Decision and Negotiation, Vol.12,No.2, pp. 58–73 (2003)
- [Marsa-Maestre 14] Marsa-Maestre, I., Lopez-Carmona, M. A., Ito, T., Zhang, M., Bai, Q., and Fujita, K.: Novel insights in agent-based complex automated negotiation, Vol. 535, Springer (2014)
- [Robu 05] Robu, V., Somefun, D. J. A., and Poutré, J. L.: Modeling complex multi-issue negotiations using utility graphs, in AAMAS '05: Proceedings of the fourth international joint conference on Autonomous agents and multiagent systems, pp. 280–287, New York, NY, USA (2005), ACM
- [Robu 08] Robu, V. and La Poutré, H.: Constructing the Structure of Utility Graphs Used in Multi-Item Negotiation through Collaborative Filtering of Aggregate Buyer Preferences, in *Rational, Robust, and Secure Negotiations* in Multi-Agent Systems, pp. 147–168, Springer (2008)
- [Rubinstein 82] Rubinstein, A.: Perfect Equilibrium In A Bargaining Model, Vol. 50, No. 1, pp. 97–109 (1982)

# マルチエージェントシステムにおける効率的タスク処理のための深 層強化学習を用いた割り当て戦略

An allocation strategy with deep reinforcement learning for efficient task processing in multi agent system

| 松野 元樹 *1<br>Genki Matsuno | 田中 翔 *2<br>Sho Tanaka       | 原 拓希 *2<br>Hiroki Hara  | 川本 峻頌 *2<br>Syunyo Kawamoto | 下山 翔 *2<br>Syo Shimoyama    | 川島 崇 *2<br>Takashi Kawashima |
|---------------------------|-----------------------------|-------------------------|-----------------------------|-----------------------------|------------------------------|
|                           | 積田 大介 *2<br>Daisuke Tsumita | 城戸 康 *1<br>Yasushi Kido | 橋本 司 *1<br>Osamu Hashimoto  | 高木 友博 *2<br>Tomohiro Takagi |                              |
|                           |                             |                         |                             |                             |                              |

\*<sup>1</sup>株式会社スカイディスク Skydisc, Inc. \*<sup>2</sup>明治大学理工学部ウェブサイエンス研究室 Meiji University, Graduate School of Science and Technology, web science lab

In this study, it was considered how to make matching between task required resource and member capability that will be applied into multi-agent systems. Supported by Reinforcement Learning strategy with deep Neural Network technique, a modern solution was conducted accompanied with standard baseline methods and evaluated from several suggestive viewpoints. According to the numerical experiments, it is elucidated that RL strategy has some advantages when targeting on both execution time duration and accuracy of combination matching.

#### 1. はじめに

近年の情報・ネットワークシステム業界においては, 各コン ポーネント・サービスをできるだけ独立細分化したのち階層的 に構造化することでシステム各部の変更容易性・疎結合性を高 めることを狙うマイクロサービスの考え方が一般的になりつ つある.細分化された多数のサービスは多様性を持つエージェ ント群 (マルチエージェント)[1]であると捉えなおすことがで きる.ここで言うエージェントとは, 我々に代わってタスクを 処理したり必要な機能を果たす端末, というくらいの意味であ る.マイクロサービス構成を採用すると個々の機能を独立して 作り込めるためシステム開発速度の加速が期待されるが, 管理 すべきエージェントの数が増えるのでシステムの制御コスト・ インフラ基盤への負担が増大するという問題がある.同様に, Internet of Things(IoT)システム [2] における各機器もまた エージェントと捉えることが可能であり, 機器の数・多様性の 増加に伴って管理コストが増える点でも同じである.

また, 負荷分散の文脈 [3, 4, 5] から考えて, マルチエージェ ントシステム内で個性を持つ各々のエージェントに適切な負荷 を持つタスクを割り振ること [6,7] はきわめて挑戦的な課題で ある.タスクとメンバーの間にありうるすべての可能な組み合 わせを試すため,あるいは可能な限りのエージェント資源を実 際のタスク処理に使うためには、タスクを振るというタスクに 従事するエージェントの数はできるだけ少ないことが望まし い.しかしながら、タスクを振るというタスクはシステム内の 1エージェントに一任するには重すぎるタスクである. なぜな らば、システムの大きさが大きくなることに伴ってタスクとメ ンバーの間にありうる組み合わせの数が指数関数的に増大する からである.また、内在するエージェントを介さずシステム外 から直接制御する中央集権的なやり方はマイクロサービスのシ ステム設計思想に反しており、制御機構も含めて考えた際のシ ステム全体を複雑化してしまう.したがって、複数のリーダー エージェントを配置しそれぞれのチームにおいてメンバーエー ジェントへの負荷分散を図るボトムアップ型の戦略を考慮する のが自然に思われる.

これは、組み合わせ最適化の言葉でいうと、組み合わせ爆発

が起こる探索不可能なほど巨大な状態空間を適当な部分空間に 分割して取り扱うことに相当する.この操作により,チームメ ンバーの再構成を行う機構を採用しない限り,ありうる組み合 わせを網羅的に探索することはできなくなるが,現実的な計算 時間で問題を解くことができるという大きな利点がある.

我々は、タスク処理を行うマルチエージェントシステムのチー ム形成に着目した論文 [8](以下ベース論文と呼ぶ)の定常状態 を対象に、深層強化学習を用いてタスク実行に必要なリソース とメンバー能力のマッチング問題の解決を試みた.詳しくは 2章に譲るが、本稿で取り扱うのはベース論文の問題設定を抽 出・簡略化したものであり、リーダーエージェントは固定メン バーを持つ1つのチーム内でどのメンバーがタスク内のどの サブタスクを担当するかを選択する (1対1対応させる)とい う課題に取り組む.また、深層強化学習を用いた提案手法の性 能を測定するため、基準として同じ問題をランダム法あるいは ソルバーによる解法を用いて解きなおし、すべての手法に共通 する有意な計量を独自に設計・計測した.

以降の章では,不足のない状態空間の設定法,深層強化学習 を用いる利点についてや効率的なメンバー能力の運用がなさ れているかを測る計量などについて議論する.2章においては, 問題設定やシステム構成,論文中で使用する数式について詳細 に説明する.3章では,実施された実験とその結果の詳細を示 し,比較手法であるランダム法あるいはソルバーによる解法と の違いについても述べる.4章では,実験の結果得られた成果 を整理し直し,今後の課題についても言及する.

#### 2. 問題設定

我々は,上記マッチング問題をシステム内エージェントの一 部が実行するべきタスクのひとつとして定義する.便宜上,マッ チング問題を扱うエージェントをリーダーエージェントと呼び, リーダーからサブタスクを与えられて働くメンバーと区別す ることにする.リーダーエージェントは複数のタスクが詰まっ たタスクキューからひとつのタスクを選び取り,自分のチーム メンバーにタスク内に含まれるサブタスクを適切に分配しなけ ればならない.タスクは複数のサブタスクから構成されており  $T = \{s_1, s_2, \dots, s_m\}, サブタスクは実行に必要なリソース値$  $を持つ <math>s_i = \{r_1^s, r_2^s, \dots, r_n^s\}$ .サブタスク実行に必要なリソー スの値  $r^{s}$  は集合  $E = \{0, 3, 4, \dots, k'\}$  から適宜選択されるが, 簡単のため 1 つの成分のみ有限の値を持ち,その他の成分は 0 とする.メンバーもまたそれぞれ自身の処理能力を表すリソー ス値を持つが  $M_{j} = \{r_{1}^{M}, r_{2}^{M}, \dots, r_{n}^{M}\},$ リソース値  $r^{M}$  は集 合  $E' = \{0, 1, \dots, k\}$  の中から設定される. リーダーエージェ ントのタスクは,チームとしてのタスク処理時間

$$t = \max_{s_i \in T, p \in n} \left\{ ceil\left(\frac{r_p^{s_i}}{r_p^{M_j}}\right) \right\}$$
(1)

が最小となるような  $s_i \ge M_j$ の組み合わせを発見することで ある.なお、タスク処理時間は整数化したのち、tick という単 位で数えることにする.さらにここで、それぞれタスク内サブ タスクの数およびチーム内メンバーの数を表す記号 #s  $\equiv m$ 、 # $M \equiv l$ を導入しておく、本研究では、変化しないパラメータ として  $n = l = k = 6, k' = 12, m \in \{2, 3, \dots, 6\}$ を採用して いる.

#### 2.1 深層強化学習 (deep Q learning)

強化学習の枠組み内において, エージェントは状態 S と行動 a が張る空間の中を即時報酬 R(S,a) を受け取り記録しながら 探索を繰り返すことで, ある状態 S においてどの行動 a を選 択すると将来に渡っての累積報酬 (以降, 価値と呼ぶ) が高く なると期待されるかを経験的に学習することができる. Q 学習 と呼ばれる学習法においては

$$Q(S,a) \leftarrow (1-\alpha)Q(S,a) + \alpha \left( R(S,a) + \gamma max_{a'}Q(S',a') \right)$$
(2)

という式に従って行動価値関数 Q(S, a) を逐次更新する. ここ で $\alpha, \gamma$  はそれぞれ学習率,割引率と呼ばれるパラメータであり, エージェントは $\alpha$ が大きいほど最新の経験を重んじる傾向を示 し, $\gamma$ が大きいほど将来の期待を重視する判断基準を習得する. 初期の Q 学習においては,価値の記録・エージェントの学習は 離散的状態行動空間を表すテーブルを利用して行われたが,深 層 Q 学習においてはテーブルの代わりに NeuralNetwork を利 用する.  $\theta$  を NeuralNetwork を特徴づけるパラメータ,  $L_{\theta}$  を TD 誤差として

$$L_{\theta} = \left(R(S,a) + \gamma max_{a'}Q^{\theta}(S',a') - Q^{\theta}(S,a)\right)^2 \qquad (3)$$

とおくと、逆誤差伝搬法によって訓練された学習済み Neural-Network  $Q^{\tilde{\theta}}(S, a)$  は状態変数が連続であっても理想的な行動 価値関数と同等の働きをすることができる.本研究では、時系 列相関の影響を緩和するため、学習に際して経験した状態・行 動・報酬をメモリに蓄積しランダムにサンプリングするミニ バッチ学習機構を採用している.

#### 2.1.1 状態行動空間と報酬の設計

状態 (入力): 状態はタスク, サブタスク割当フラグ, サブタ スク, メンバー割当フラグの4つの変数をとる. メンバーのリ ソース値は含まないことに注意が必要である.

タスク: ランダム生成され, チームで処理するように割り当 てられたタスク.

サブタスク割当フラグ: どのサブタスクがメンバーに割り当 てられているかを確認するフラグ. {0,1} のバイナリ値により 割り当てられていない状態, すでに割り当てられている状態を 識別する.

サブタスクのリソース値:サブタスク $s_i$ に該当するリソース値の組  $\{r_1^s, r_2^s, \dots, r_n^s\}$ .前述のとおり、1つの成分のみ有限の値 $r_p^s \in \{3, 4, \dots, k'\}$ を持ち、その他の成分は0である.

メンバー割当フラグ:1体のメンバーに対して1つのサブタ スクのみ割り当てることが可能なため、2つ以上のサブタスク を割り当てないようにするための変数.本来であれば別の状態 でなければならない、割り当て直前の状態が同じになってしま うという問題を回避するため、バイナリ値ではなく{0,1,...,*l*} という値をとる必要がある.

行動(出力):入力された状態に対して、どのメンバーに割り 振るべきかを行動価値として出力する.最も行動価値が高い メンバーがサブタスクを割り振るべきメンバーとして選出さ れる.

報酬:本研究では,実験の狙いに応じて以下の二つの報酬を 使い分ける.

サブタスク割り当て報酬: タスクに含まれるすべてのサブタ スクがメンバーに割り当てられたときと、それ以外の場合を識 別する固定値の報酬をリーダーエージェントに与える. 固定値 の実際の値は実験の章を参照のこと.

時間報酬: リーダーエージェントがすべてのサブタスクを実 行可能なリソースを持つメンバーに割り振ることができること を前提として、チームのタスク処理時間に応じて与えられる報 酬を時間報酬と呼ぶことにする.これには、 $t_{max}$ を問題設定上 ありうる最大のタスク処理時間として  $t_{max} - t + 1$ とすれば よい. 例えば本論文中の設定では、一番遅いメンバーのタスク 処理時間が最大 12 tick であるので、時間報酬は +1 から +12 までの値をとる.

#### 2.1.2 状態行動空間の探索方策

 $\varepsilon$ -greedy 法を採用し, 探索率は  $\varepsilon = 0.3$  とした. エージェン トの学習はタスクひとつに対してエピソード単位で進めるが, サブタスクをひとつずつメンバーに割り当てる刻みをステップ と呼び, 報酬は各ステップごとに与える. エピソード数は実験 に依存して可変とする一方で, 1 エピソードに含まれるステッ プ数は 20 で固定した.

#### 2.1.3 NeuralNetwork $\mathcal{O}$ Architecture

今回の実験で使用した NeuralNetwork は, 各層がそれぞれ 100個のノードを持つ, 4層の全結合 Network(Multi Layer Perceptron) である. 活性化関数としては leaky relu 関数, Optimizer は Adam(eps = 0.01) を使用している.



図 1: タスク, サブタスク割当フラグ, サブタスク, メンバー割 当フラグの4つの変数を入力とし, 出力としてどのメンバーに 割り当てるべきかを判定する全結合 NeuralNetwork.

#### 2.2 最小化問題としての定式化

問題をソルバーに実行可能な形式に落とし込むため,これま で述べてきた問題設定を以下のような最小化問題として再定義 する.

 $Minimize \qquad \sum_{i}^{m} \left[ max_{p \in n} \left\{ ceil\left(\frac{r_{p}^{s_{i}}}{r_{p}^{M_{j}}}\right) \right\} x(s_{i}; M_{j}) \right]$ 

Subject to 
$$x(s_i; M_j) \in \{0, 1\}$$
  

$$\sum_{j}^{l} x(s_i; M_j) = 1$$

$$\sum_{i}^{m} x(s_i; M_j) \leq 1$$

$$max_{s_i \in T, p \in n} \left\{ ceil\left(\frac{r_p^{s_i}}{r_p^{M_j}}\right) \right\}$$

$$-\sum_{i}^{m} \left[ max_{p \in n} \left\{ ceil\left(\frac{r_p^{s_i}}{r_p^{M_j}}\right) \right\} x(s_i; M_j) \right] \geq 0$$
(4)

ここで, サブタスク  $s_i$  と担当メンバー  $M_j$  の対ひとつを表す 記号  $(s_i; M_j)$  を導入した.

#### 2.3 計量の設計

この節では,複数の手法の性能を比較・測定するための計量 について議論する.計量は考慮する全ての手法に適用可能であ り,かつ,できる限り多様な観点から性能を比較できる組であ ることが望ましい.以上のことを念頭に,我々は以下に示す 4 つの計量を導入する.

割り当て成功率:現時点でのチーム構成で割り当て可能なタ スクのうち,実際に割り当てに成功したタスクの割合.

計算実行時間:同じ計算資源上で測定した,割り当てにかか る時間.強化学習を用いた手法に対しては,訓練の時間を含ま ないことに注意すること.

最適化精度:割り当てに成功したタスクが持つ処理時間とあ りうべき最適なタスク処理時間との近さ.タスク処理時間が最 短となる組み合わせをあらかじめソルバーによって求め,順位 付けを行ったのち

$$O_a = \frac{1}{N} \sum_{ii}^{N} f_{\Pi}(\pi_{ii}) \tag{5}$$

$$f_{\Pi}(\pi_{ii}) \equiv \begin{cases} 1 & (if \ \pi_{ii} = 1) \\ 1 - \frac{\pi_{ii}}{\Pi} & (otherwise) \end{cases}$$
(6)

という独自指標を導入し、百分率表示を用いて評価する. ここ で $N \equiv \#T$  は評価に使われた割当成功済タスクの数であり、  $\pi_{ii}$ はii番目のタスクに対してリーダーエージェントが提示し たサブタスクとメンバーの組み合わせの順位をソルバーの結果 と比較して決定したもの、П は着目する組み合わせ内にありう る総順位数である.

汎化性能: 訓練時に含まれないタスクについて, どれだけの 割り当て成功率あるいは最適化精度を達成できるか.

#### 3. 実験

まず始めに, もっとも簡略化された問題設定の下で提案手法 が想定通りの挙動を示すこと, すなわち, 強化学習の枠組みを 使ってリーダーエージェントが実行可能なサブタスクをメン バーに割り振り可能であることが確認された [実験 A]. 次に, 徐々に問題設定を複雑化してゆき, 提案手法 (状態・報酬設計, 探索方策)によりリーダーエージェントは得意・不得意のある 個性的なメンバーに適切なサブタスクを割り振る方法を学習で きることを実演した [実験 B]. 提案手法の性能を評価するため に割り当て成功率, 計算実行時間, 最適化精度, 汎化性能といっ た計量を導入し, ランダム法・ソルバーによる解法との比較を 行った.

#### 3.1 実験A

入力として4つの変数をとる状態空間を採用することによっ て、本当にサブタスクをメンバーに割り振れるのか確認するこ とを狙いとして、チームメンバーに割り振ることができるサブ タスクの組を有する1つのタスクを割り振る実験を行った.割 り振れているかどうかだけを確認するために、各メンバーの所 持しているリソースの成分は1つのみ1とし、量的得意不得意 の概念を排除している.サブタスクとメンバーのリソース値は 以下の通りである.

 $\begin{array}{l} \begin{array}{l} s_{1} = \{3, 0, 0, 0, 0, 0\}, s_{2} = \{0, 4, 0, 0, 0, 0\}, s_{3} = \{0, 0, 5, 0, 0, 0\} \\ (4) \quad s_{4} = \{0, 0, 0, 6, 0, 0\}, s_{5} = \{0, 0, 0, 0, 7, 0\}, s_{6} = \{0, 0, 0, 0, 0, 0, 8\} \\ M_{1} = \{1, 0, 0, 0, 0, 0\}, M_{2} = \{0, 1, 0, 0, 0, 0\}, M_{3} = \{0, 0, 1, 0, 0, 0\} \\ M_{4} = \{0, 0, 0, 1, 0, 0\}, M_{5} = \{0, 0, 0, 0, 1, 0\}, M_{6} = \{0, 0, 0, 0, 0, 1\} \end{array}$ 

また報酬はサブタスク割り当て報酬のみ +1,-1 とし, 時間報 酬は与えなかった.

結果として、図2に示すように損失がほぼ単調に減少し、図3 のようにエージェントの報酬も最適な値に収束した.なお、-4 は最短の試行ステップ -1, -1, -1, -1, +1に対応する、最 適な割り振りを行った場合の割り振り報酬であり、-20は1エ ピソード内に含まれる 20 ステップすべてで割り振りに失敗し た際の報酬である.



図 2: 損失関数の振る舞い. 安 図 3: エージェントが得た報酬.
 定して学習が進んでいる様子が 損失の低下に伴い最適な場合の
 見て取れる.
 報酬を得ていることがわかる.

#### 3.2 実験 B

メンバーが複数のリソースを持ちたくさんの種類のタスクを 処理しなければならないような状況下において, リーダーエー ジェントが汎用的な方策を学習することができるのかどうかを 確認することを目標に, 100000 エピソードかけて, ランダム生 成した 100 タスクを繰り返し与えて学習を行った. メンバーについては以下のリソース値を持つ.

 $M_1 = \{0, 2, 0, 4, 0, 1\}, M_2 = \{2, 2, 5, 6, 5, 5\}, M_3 = \{0, 6, 0, 0, 4, 6\}$  $M_4 = \{3, 2, 0, 0, 0, 0\}, M_5 = \{4, 2, 6, 4, 5, 1\}, M_6 = \{0, 4, 3, 0, 0, 6\}$ 

報酬としては、タスクを割り振れたときにはサブタスク割り 当て報酬は0で時間報酬を与え、割り振れなかったときはサブ タスク割り当て報酬のみ -0.5 を与えた.

図4に割り当て成功率,そして図5に最適化精度の実験結果 を示す.図より,学習に使用したタスクに対する割り当て成功 率(再現率:Reproducibility)はほぼ100%である一方で,始め て遭遇したタスクに対する割り当て成功率(汎用性:Versatility) は75%程度にとどまったこと、始めて遭遇したタスクのうち割 り当て可能なものに対して最適化精度80%程度を達成できる ことなどが読み取れる.また、1000000エピソードの中で、ラ ンダム生成した1000タスクを学習する仕様に変更したところ、 割り当て成功率の汎化性能は約94%へと向上し、最適化精度 の汎化性能は約85%へと上昇する改善が見られた.



図 4: 割り当て成功率の再現率 図 5: 最適化精度 (再現率:赤) (赤)と割り当て成功率の汎用性 および (汎用性:青). 学習時に (青). 学習に使うタスクの数が 遭遇したことがないタスクに対 多くないため, 汎化性能はそれ しても 80%程度の最適化精度が ほど高くない. 出ている.

#### 3.3 他の解法との比較

100000 エピソードを用い 100 種類のタスクを学習済みの エージェントによる解法, ソルバーによる解法, ランダム法の 3 つの手法を対象に, 割り当て成功率, 最適化精度, 計算実行時 間という 3 つの観点から手法の評価を試みた. それぞれ 1000 タスクを実行させた結果として表 1 が得られた. この結果か ら, 深層強化学習を用いた手法は精度と実行時間の兼ね合いが 必要とする状況下においてよい性能を発揮できるということが わかる.

表 1: 手法比較

| X 1. 1 1414 |       |       |           |
|-------------|-------|-------|-----------|
| 実験結果        | 割当成功率 | 最適化精度 | 計算実行時間    |
| ランダム        | 16 %  | 39 %  | 0.091 [s] |
| エージェント      | 74 %  | 79 %  | 8.118 [s] |
| ソルバー        | 100 % | 100 % | 17.44 [s] |

#### 4. まとめ

本研究では、強化学習の枠組みを使ってタスク・リソースマッ チング問題に取り組み、ランダム法・ソルバーによる解法といっ た対象と比較して多角的に評価を行った.その結果により、提 案手法には組み合わせ精度はそこそこでよい代わりに限られ た時間の中で次々と処理を迫られるような状況に強いという利 点がある、と結論付けた.次の研究課題として、複数チーム間 の相互作用を適切に決定して階層的なシステムを構築する、静 的なシステムを動的なものに拡張する、状態行動空間の探索方 法や NeuralNetwork の Architecture を洗練するなどの課題が ある.

#### 参考文献

- B. M. Dunin-Keplicz and R. Verbrugge, "Teamwork in Multi-Agent Systems: A Formal Approach," 1st ed. Wiley Publishing, 2010.
- [2] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari, and M. Ayyash," Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications," IEEE Communications Surveys Tutorials, vol. 17, no. 4, pp. 2347–2376, Fourthquarter 2015.
- [3] N. Amelina, A. Fradkov, Y. Jiang and D. J. Vergados, "Approximate Consensus in Stochastic Networks With Application to Load Balancing," in IEEE Transactions on Information Theory, vol. 61, no. 4, pp. 1739-1752, April 2015.
- [4] Banerjee S., Hecker J.P.," A Multi-agent System Approach to Load-Balancing and Resource Allocation for Distributed Computing," In: Bourgine P., Collet P., Parrend P. (eds) First Complex Systems Digital Campus World E-Conference 2015. Springer Proceedings in Complexity. Springer, Cham
- [5] A. Shukla, S. Kumar and H. Singh, "LOAD BAL-ANCING APPROACHES FOR WEB SERVERS: A SURVEY OF RECENT TRENDS," IJE TRANSAC-TIONS B: Applications Vol. 31, No. 2 (February 2018) 263-269
- [6] O. Sheholy and S. Kraus," Methods for task allocation via agent coalition formation," Journal of Artificial Intelligence, vol. 101, pp. 165–200, 1998.
- [7] W. Saad, Z. Han, M. Debbah, A. Hjorungnes, and T. Basar, "Coalitional game theory for communication networks," IEEE Signal Processing Magazine, vol. 26, no. 5, pp. 77–97, September 2009.
- [8] M. Hayano, N. Iijima and T. Sugawara, "Asynchronous Agent Teams for Collaborative Tasks Based on Bottom-Up Alliance Formation and Adaptive Behavioral Strategies," 2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech), Orlando, FL, 2017, pp. 589-596.

# 集団適応を導くギャップ補填に基づく「思いやり」

## **Omoivari as Filling Gaps Making Collective Adaptation**

前川佳幹1\* 上野史1 北島瑛貴1 高玉圭樹1

Fumito Uwano<sup>1</sup> Eiki Kitajima<sup>1</sup> Yoshimiki Maekawa<sup>1</sup> Keiki Takadama<sup>1</sup>

## 1 電気通信大学 <sup>1</sup> The University of Electro-Communications

**Abstract:** To make each person adapt human society and build a consensus, we focus on Japanese Omoiyari as filling psychological and numerical gaps among people. Concretely, we employed the cross-cultural game "Barnga" whose the four players have to build a consensus and determine a winner, and proposed gesture marks in the Barnga. The gesture marks are the panels which can express happy, angry, sad, and surprise. Each player can make other players recognize the gaps among players, and behave with the Omoiyari. To validate the effect of the gesture marks, we experiment on Barnga with the gesture marks and original Barnga. By analyzing the subject experiments on the Barnga, we derive that: 1) the players can recognize the gaps by the gesture marks; 2) the gesture marks contribute to make the players adapt the community and build a consensus.

#### はじめに 1

集団社会において,まとまりを持ち,意思決定を下 していくことは極めて重要である. 集団がまとまりを 持つためには、その集団に属している個人どうしでの 密なコミュニケーションが必要になる.しかし、イン ターネット上でのコミュニケーションでは考えを正し く共有することが困難であるため、自分の考えが相手 に正しく共有されずに発生する「誤解」やそれに伴う 「炎上」が頻繁に発生する.このような問題の解決の ために,人間と人工物(エージェント)との相互関係 (Human-Agent Interaction: HAI) [1] に焦点を当てた 研究がなされている [2][3].

牛田ら [4] は集団に属している個人の個性に着目し た.集団の状態はこの個性の組み合わせによって四種 類に分類でき,設計したエージェントを集団内に介入 させることで集団としてまとまりをもつ「集団適応状 態」に遷移できると述べている.しかし,牛田らは「個 人の状態」にまで言及していない.集団に属している 個人が納得しているのか否か区別がつかず、必ずしも 集団がまとまっていると判断できない. そこで私たち は、個人が納得して意思決定を下し、集団適応に遷移 するには、「思いやり」などの人間の定性的な尺度が必 要だと考える.本研究においては,「思いやり」を主観 的なギャップを補填する行動として定義した後、被験者 実験の分析により、本研究で定義する「思いやり」が 集団適応を導く上で有効的であることを示す.

#### ギャップ補填による思いやり 2

本研究では、「思いやり」をギャップを補填する行動 として表現する.「思いやり」とは単純な共感や同情と は異なる.内田ら[6]は「思いやり」には、「同情」「直 感的な理解」「向社会的な行動」の三種類の側面がある と仮定し、「思いやり」の尺度を提案、検証している. ギャップを補填するためには、相手に同情することで ギャップに気づき、相手が何を求めているのかを直感 的に理解する必要がある. 最終的に行動として現れた 際には向社会的な行動として認知される.以上の点か ら、ギャップ補填を「思いやり」として仮定し、この効 果を検証する.

本稿で考慮するギャップは大きく二種類の分類がな されている.一つ目は、数値的ギャップが発生している かどうか、二つ目は心理的ギャップが発生しているか どうかである.ここで扱う「数値的」なギャップとは, 例えば身長や体重, 収入など, 数字で表現可能なもの を指す、「心理的」なギャップとは通常目には見えない ものを指し、 例えば、 他者との 意識の 齟齬や 誤解など があげられる.以上の分類の組み合わせより、本稿で は合計4種類のギャップを考慮し、これを補填する行 動を「思いやり」になりうる行動として表現する.

<sup>\*</sup>連絡先:電気通信大学 情報理工学部 総合情報学科 〒 182-8585 東京都 調布市 調布ヶ丘 1-5-1

E-mail: maekawa.yoshimiki.1119@cas.lab.uec.ac.jp

## 3 異文化体験ゲームバルンガ

先述した「思いやり」がもたらす集団適応への効果 を検証するために,教育学で発展した異文化体験ゲー ムバルンガ[5]を採用する.バルンガは,トランプを 用いたシミュレーションゲームである.ゲームのルー ルを文化と見立て,その違いに気づいたときの驚きを カルチャーショックとして体験し,その解決方法の模 索も同時に体験することを目的としている.ゲーム中 は言語コミュニケーションが禁止されており,プレイ ヤーはジェスチャーなどを駆使して自分の意思を他の プレイヤーに共有しなくてはならない.Barngaでは, 各スートごとにAから7までの合計 28枚のカードを 使用する.

まず,プレイヤーに1人ずつゲームのルールを教え, その後プレイヤー4人で Barnga をプレイする.1人ず つ手札からカードを場に出し, 全員出し終わったのち, 一番強いカードを出したプレイヤーを勝者として指さ す. 勝者を指さしたプレイヤー全員の指差しが一致し た際にゲームの勝者が決定し、次のゲームは勝者から カードを手札から場に出していく.この手順を規定の 回数こなすことで Barnga は終了する. ゲームの最中 に手札が無くなった場合は、場に出したカードを集め、 再度プレイヤーに分配する. ここで着目したいのは, 各 プレイヤーに事前に教えていたルールが、カードの強 さの決め方について若干異なることである.教えられ ていたルールは各プレイヤーごとに異なるので、ゲー ムの開始時、プレイヤーは違和感を覚える. バルンガ において、この違和感がカルチャーショックであり、こ れを感じることを異文化体験としている.

## 4 ジェスチャー札

本研究では、バルンガ中で唯一許されている「ジェ スチャー」をより定量的に評価し、その効果を検証す るため、新たに喜び、怒り、哀しみ、驚きの四種類の 感情を表現する「ジェスチャー札」を導入した. 図1 は導入したジェスチャー札の外観であり、左から喜び、 怒り、哀しみ、驚きを表している. ジェスチャー札を Barnga 中に使用することで、自らの状態を間接的に他 者に共有でき、その結果適応的な状態を導く効果が期 待できる.

## 5 バルンガにおける場の状態の定義

本研究では、バルンガにおける場の状態を四種類定 義する.これらは、主張率と譲歩率によって決定され る.以下では、本研究で用いる主張率 *E*<sub>ind</sub> と譲歩率 *O*<sub>ind</sub> について記述する.



図 1: ジェスチャー札

#### 主張率 Eind

プレイヤーがどれだけ自分の選択に自信を持って 他のプレイヤーにみけて主張しているのか、その 度合いを指す.意見の衝突の際、再度同じ選択を した回数を $E_{self}$ ,違うプレイヤーを選択した回 数を $E_{other}$ としたとき、主張率 $E_{ind}$ は以下の式 より導出できる.

$$E_{ind} = \frac{E_{self} - E_{other}}{\max(E_{self}, E_{other})} \tag{1}$$

譲歩率 Oind

1ラウンドにおいて、どの程度自分のルール以外 で最終的な勝者を選択したのか、その割合を指す. 自分のルールに基づかない勝者を最終的に選択し た回数を Fother,現在のゲーム数を Ngame とし たとき、譲歩率 Oind は以下の式より導出できる.

$$O_{ind} = \frac{F_{other}}{N_{game}} \tag{2}$$

なお,以上の指標と各値はラウンドごとの性質を分 析可能なものとするため,ラウンドが終了するたびに 初期化するものとする.

以上の指標をプレイヤー毎に計算し,縦軸を主張率 *E*<sub>ind</sub>, 横軸を譲歩率 *O*<sub>ind</sub> としたグラフにプロットする. ここで $\theta_O$ を定義する. $\theta_O$ は各ラウンドにおけるプレ イヤーの最終的な譲歩率 Oind の平均値である.プロッ トの位置によって、プレイヤーの行動特性は以下のよ うに定義できる.  $0 < E_{ind}$  かつ  $O_{ind} < \theta_O$  にプロット されるプレイヤーは自分のルールを支持し続け、その 選択に自信を持っている「主張タイプ」.  $0 < E_{ind}$  か つ $\theta_O < O_{ind}$ にプロットされるプレイヤーは自分以外 のルールを支持し、その選択に自信を持っている「支 持タイプ」, $E_{ind} < 0$ にプロットされるプレイヤーは 自分の選択に自信がない「控え目」タイプである. 各 プレイヤーのプロットの位置関係によって場の状態を 四種類定義する. 図2は本研究で定義する四種類の場 の状態のプロットを表しており、左上が一人のプレイ ヤーの主張が他のプレイヤーを支配している「支配状 態」,右上がいずれのプレイヤーも自分の選択に自信 がない「混乱状態」,左下がぞれぞれ異なるルールを 持っている複数のプレイヤーが主張し合っている「固 執状態」,右下が同一のルールを持つプレイヤーを他 のプレイヤーが支持している「適応状態」である.



図 2: 場の四状態

思いやり度合いのほか,ギャップが発生した際にど のような行動をとったかについてもアンケートを実施 した.アンケート結果より,実際にとられた行動と場 の状態の遷移の対応を明らかにする.

#### 6.2 結果

#### 6.2.1 場の状態の遷移

ジェスチャー札なしのバルンガでは、すべてのラウ ンドにおいて固執状態であり、複数のプレイヤーが自 らのルールを主張し続ける状態に収束した.対照的に、 ジェスチャー札ありのバルンガでは、固執、支配、混 乱、適応の順に場の状態が遷移した.図3は各被験者 実験の状態遷移を縦軸で表現した線グラフである.1が 支配状態,2が混乱状態、3が固執状態、4が適応状態 を表している.



図 3: 上: ジェスチャー札なし, 下: ジェスチャー札あり

## 6 実験

#### 6.1 内容

本研究では、オリジナルのバルンガと先述したジェ スチャー札を導入したバルンガをそれぞれ被験者実験 に用い、結果の差異を分析することでジェスチャー札 の効果を示す.実験における被験者は4人とし、サン グラスとマスクを着用の上、他のプレイヤーから見て 表情が分からないようにした.実施ゲームは28ゲーム である.また、内田ら[6]が提案した思いやりの尺度を 含めたアンケートを実施することにより、思いやりの あるプレイヤーの札の使い方などを明らかにする.ア ンケートには22項目あり、それぞれに対して思いやり に対する因子負荷量が設定されている.本研究におい て、プレイヤーの思いやり度合いSを、質問項目*i*の 因子負荷量を*ai*、5段階のSD法で撮ったアンケート 結果を*wi*としたとき以下のように定義する.

$$S = \frac{\sum_{i=1}^{22} a_i w_i}{\max S} \tag{3}$$

#### **6.3** 思いやり度合い S

アンケートの結果得られたデータより思いやり度合い*S*を各プレイヤーごとに算出した.以下の表1と表2は核実験におけるプレイヤーの思いやり度合い*S*についてまとめたものである.

| 表 | 1: ジェスチャ | ー札なし | 表 2: ジェスチャ | ー札あり |
|---|----------|------|------------|------|
|   |          | S    |            | S    |
|   | プレイヤー1   | 0.76 | プレイヤー1     | 0.53 |
|   | プレイヤー2   | 0.67 | プレイヤー2     | 0.63 |
|   | プレイヤー3   | 0.53 | プレイヤー3     | 0.62 |
|   | プレイヤー4   | 0.46 | プレイヤー4     | 0.60 |

#### 6.4 適応状態時のジェスチャー札

適応状態時,心理的ギャップと数値的ギャップの両方 が発生していたときには「驚」が使用されており,数 値的ギャップのみが発生していたときには「喜」が使用 された.数値的ギャップが発生していない場面ではジェ スチャー札が使用されなかった.

## 7 分析

図3より,ジェスチャー札がある場合とない場合と の間で,場の状態の遷移に違いが出たことが分かった. このことから,ジェスチャー札を用い,自分の感情を 他のプレイヤーに共有することで,多様な状態に遷移 可能であり,結果として適応状態に遷移したことが明 らかになった.最終的な適応状態では,ギャップが発生 しているにもかかわらず「喜」が使用されていること から,各プレイヤーが結果に納得して勝者を決定して いると考えられる.

また、各状態に置いて適応状態に遷移する際に使用 された札の分布を心理的・数値的ギャップの観点から 分析することで以下の知見を得ることができた.1)喜 び札は、意見の衝突の際に自分が特定のプレイヤーの 選択を支持していることを表現でき、勝者の選択をま とめる効果を持つ.2)怒り札は、心理的ギャップと数 値的ギャップが存在する際に、プレイヤー間の優劣を 明確にし、他のプレイヤーに劣っているプレイヤーが いることの認知を促し, 適応状態を導く一つの要因と なった.3) 哀しみ札は、各プレイヤーの適応を促し、 ルールを一つにまとめる効果がある.4)驚き札は、意 見の衝突が発生した際に使用されているため、自分が 感じているギャップを他のプレイヤーに共有する際に 使用されることが分かる. さらに, 適応状態を導いた と考えられるジェスチャー札は思いやり度合いの高い プレイヤーによって多く使用されたものであり、思い やり度合いが高いプレイヤーがギャップの認知を促し, 最終的に適応状態に遷移したと考えられる.

そのほか,実施したアンケート結果より,思いやり 度合いの強いプレイヤーは心理的・数値的ギャップが存 在する際,そのギャップを埋めようとすることが明らか になった.しかし,ジェスチャー札の有無によって状 態遷移に差が生まれたことから,ギャップを埋めよう とする行動はジェスチャー札がある場合に効果的に作 用すると考えらえる.ジェスチャー札がない状況では, プレイヤーの主張は勝者選択時における指差ししかな く,その外観はいずれのプレイヤーも同じである.そ のため,ギャップを埋めようとする行動であったとして もその意図が他のプレイヤーに共有されにくく,場の 状態を遷移するまでに至らなかったと考えられる.対 して,ジェスチャー札がある状況においては,その意 図が他のプレイヤーに共有され,場の状態遷移に寄与 したと考えられる.

## 8 まとめ

本研究では、集団を適応的な状態へと遷移させるた めには「思いやり」のような人間の定性的な尺度が必 要であると考え、これを心理的・数値的ギャップを補 填する行動として定義した.思いやり行動を促進する ツールとして、自分の感情を「喜」「怒」「哀」「驚」の 4種類で表現できるジェスチャーマークを提案し、そ の有効性を異文化体験ゲームバルンガを用いて検証し た.その結果、思いやりを持つプレイヤーがギャップの 発生の際に使用したジェスチャー札は集団を多様な状 態に遷移させることが明らかとなり、その中でも特定 の使用方法によって適応状態に導けることが明らかに なった.さらに、思いやり行動の効果の発揮に寄与し たと考えらえれた.

## 謝辞

本稿を執筆するにあたって,学術新領域である「共 創言語進化」に感謝の意を表したい.

## 参考文献

- [1] 山田誠二.: 人とロボットとの < 間 > をデザイン する, 東京電機大学出版局, 2007.
- [2] Ohmura, H., Katagami, D., Mitta, K.: Design of Social Adaptive Agents in Simulation Game of cross-cultural experience, Human-Agent Interaction Symposium, 2009.
- [3] Ohmura, H., Katagami, D., Mitta, K.: Investigation Changes of Group Norm for Agents Adapting Group, *The 23rd Annual Conference of the Japanese Society for Artificial Intelligence*, 1-3, 2009.
- [4] Ushida, Y., Takadama, K.: Validation of Agent Model in Highly-dynamic Environment via Barnga Game, The Multi-Agent-Based Simulation workshop (MABS2012), 2012.
- [5] Thiagarajan, S., Steinwachs, B.: Barnga: A simulation game on cultural clashes, *Intercultural Press*, 1990.
- [6] Uchida, Y., Kitayama, S.: Development and validation of a sympathy scale, *The Japanese Jour*nal of Psychology **72**(4), 275-282, 2001.

# オンライン上における社会合意形成のシミュレーション手法の検討

## Investigation of online simulation method of social consensus formation

| 川畑 泰子*1<br>Yasuko Kawahata | 石井 晃 <sup>*2</sup><br>Akira Ishii | 上岡 拓矢*2<br>Takuya Ueoka |
|----------------------------|-----------------------------------|-------------------------|
| *1 群馬大学                    | *2 烏                              | 取大学                     |
| Gunma University           | Totto                             | ri university           |

Discrepancies and agreement formation have been studied for a long time. However, the laws and orders that are particularly reflected in society are being updated by information network changes. In particular, since 1995, as public network devices have spread all over the world due to the appearance of Microsoft Windows 95, the opportunities for making decisions and consensus formation beyond the spatiotemporal constraints have expanded enormously. From now on, quantitative research is needed on the tendency to aggregate knowledge on quantitative knowledge and trends concerning consensus formation and tendency to bring about social and economic risks. Therefore, in this research, we first examined the possibility of comparing the research on consensus building using measured data and the approach using mathematical model.

## 1. 序

意見の相違と合意形成は古くから研究されてきた[1-6].しか し, 社会でそれらが特に反映される法・秩序は, 情報網の変化 によってアップデートされている [7]. 特に, ライフログのデータ 取得が可能な基盤を保持する情報通信技術を持つネットワーク 基盤の到来は,我々の日々のデータは無意識であれ意識した ものであれ、ある種の合意形成として取り扱われている場合も発 生している[8]. 上記のような社会環境システムは,自然社会に おける森羅万象と同様に統計学的・機械学習など様々な手法 で理解する研究が進められるようになった.また,社会を支える 基盤を説明・自動化する学習モデルとして生成・著作されるケ ースも多く生まれている. 自然と同様に, 私たちの日々形成する 様々なライフログが技術を経て人々の創造活動の基盤となる機 会も増えていると言える[9]. 近年の事例であると、YouTube上 で日本における国防に関する動画のアップロードによるの検証 動画の配信が閲覧可能となっている[10]. 何らかのメディアの編 集作業がされ,国境を跨いだ世論形成に影響を及ぼす議論も オンライン上で第三者の国々から閲覧される状況にもなった. 今後,合意形成に関して定量的な知見や傾向に関する知見を 集約し、ソーシャルリスクをもたらすであろう傾向に関して定量的 な研究は必要と考えた. そこで、本研究では実測のデータを用 いた合意形成に関する研究と数理モデルを用いたアプローチ の比較の可能性に関してまず検討を行った.

#### 2. 先行研究

集団におけるある意思決定問題を解決するための AHP(Analytic Hierarchy Process)も1980年代以降,提案されて きた.このモデルにおける特徴は実際の問題に対してアプロー チができ[11],集団の合意形成過程の随所に決定に至るまでの 区間表現を用いる点にあり,集団の合意を定量的に形成する 点を持つ.上記のような合意形成に関する研究は理論ベースか ら現実の問題に対してアプローチする手法まで多様に行われて いる[12].また,合意せず意見合意に至る際の集団における不 満が発生した場合のケースに関しても,集団の一対比較値を算 出し,定量的な傾向を示唆が可能となっている.ここで構成する モデルでは,提示された区間に対し不満関数を定義し,整合性 と集団全体の不満をともに最小化する.近年は正負の決定問題 におけるモデルに対して、欠損値や大規模なケースにも対応し た研究成果も考案されている[13]. 上記のような,ある合意形成 に関わる問題解決手法も考案されてきた中, インターネット上で 様々な意見を具体的なテキストとして収集できるようになった. 社会のフレームワークを構築する上で政治に関する大衆の意 見や意志・バイアスは常にメディアの発展と活用に依存すると考 えられてきた[14].メディアは社会制度に対応すべき独自の論 理かつ独立した機関として出現した高度な近代化の象徴でもあ る. その一方で,メディアは政治,仕事,家族,宗教などの他の 機関の統合された部分であり、これらの機関の活動の多くは、 双方向・即時性をもつソーシャル・メディアとマスメディアの両方 を通じて行われつつある.即ち,社会自身がメディア化し,私た ち集団における意見の形成が常になされる時代となった[14]. 特に、アメリカ合衆国・欧米諸国では2000年代より公衆ネットワ ークにおける Web を介した選挙活動は、Web Technology の発 展と同期して Eメール・メールマガジンなどダイレクトな発信から HPなど全世界向けの発信など盛んに活用されてきた. 2012年 には ARMA モデルを採用し,諸条件やボラリティを考慮したモ デルによって傾向を予測す手法で2008年の米大統領選挙の Twitter のデータを用いて意見の時系列分布における実証分析 が行われた[15]. 意見の合意形成に関して選挙結果を集約し、 予測問題に落とし込むことによって結果がもたらした説明変数 における係数から考察を行う手法など多く登場した[16-19].

## 3. データ

#### 3-1. 選定したデータ

社会におけるメディアの発信する情報に関して人々の反応を どのデータを取得して行ったか論ずる.現在,機械学習におけ る分類手法の拡張,辞書データや学習データの元となるデータ の充実により自然言語処理に関しても多様な研究がなされてい る[16-19].つまり,自然言語処理で集めたテキストから意見の強 弱を判定できるようになったことで,社会における意見の分布を Binary opinions ではなく,ポジティブな言及からネガティブな言 及,ニュートラルな言及までの連続的な分布として測定できるようになったといえよう.本研究では,世界上における様々なメデ ィアのデータ取得の制約がある中で YouTube を選択した. 様々な OSN がリアルタイムな動画配信など可能となっている が、YouTube の場合は世界有数の TV・新聞媒体をもつニュー スメディアがニュース報道の断片を YouTube でも公開してい る.また、リアルタイムでの配信が行われているのも特徴である. また、各国におけるニュースメディアにおける配信内容・同じニ ュースの内容の報道の違い・コメントをするユーザー層の相違 における意見の分布における考察なども可能と仮説を立てた. また、今回は同じ条件下での意見の強弱を把握するため、英語 圏辞書データをベースとした ch におけるニュース動画に限定し た.

YouTube は言語性が関わるケースも存在するが、動画の内容は世界発信であり、メディア媒体別の違いに関する比較が期待されること、同じ報道内容でも報道手法によって受け取りかたが異なる部分など TV における発信と近いものがあると仮説をおいた上で解析を行った.

#### 3-2. データの取得

取得対象の ch は CNN を今回はメインとして取得した. コメン トの取得期間は, CaseA においては 2016/10/10~2018/11/29, CaseB においては, 2013/5/24~2018/11/29 までの内容とした. 本研究では,トライアルとして CNN における ch 立ち上げ以降 最も再生回数が多かった動画におけるコメントを収集し,各コメ ントごとにおける negative, positive, neutral のスコアを合算して 1 となるように処理を行った.各3つの軸におけるスコアは[-1.0, -0.75,-0.5,-0.25,0,0.25,0.5,0.75,1.0]の range で定義した.今 回は,分布を考察する際に偏ったスコアである-1,0,1 に関し ては省く処理を行っている.

入力されたデータに対し、NLTK (Natural Language Toolkit) [36] を使用している.各動画におけるコメント1つ1つにおける 特徴量抽出を行い、最終的に各動画のコメント全体における negative, positive, neutralのスコアの分布を3つの軸において 出力した.また, negative, positive, neutralの各軸のスコアを一 元的な分布で捉える際は, positive な意見のスコアに2を加算, negative な意見はスコアを負の数に変換し, neutral な意見には 加算せず-1~2のスケールに換算する手法をとった.

#### 4. 合意形成のモデル

大規模なデータベースを用いた解析が重要視されて合意形 成をもたらしたメディア・外力,世論,宗教,地域などの役割を明 確にする手法が可能となった.本研究では、こうした大規模なデ ータベースを用いた定量的な解析を、オピニオンダイナミクスに 応用する.この研究においては、定量的な解析や予測のための 理論を実測と理論計算の共同作業の可能性を模索する. 社会 の意見分布の定量的な分析は1890年以降,以降アメリカ合衆 国における新聞における掲載記事の分類を定量的にまとめ集 計した研究に始まり、1930年以降、ハロルド・ラスウェルが内容 分析として、定量的な解析の重要性を唱えてきた[20-21].しか しながら,内容分析と意見に関する研究に関しては取得可能な メディアは雑誌,新聞などマスメディアのものに限られていた. そのため、理論研究が先行する形で行われていた. 昔から数値 化しやすい意見対立の実例は選挙である. 特に米大統領選や 仏大統領選はA氏かB氏かどちらかに意見が集約されてい く. そのため, 意見をAとBの2つと仮定した理論が応用しや すい. そこで,物質内で原子の磁気の向きが2つしか取り得な い磁性物理学理論を応用する試みが古くからなされた. つまり, この種の数理モデルとしては、意見の相違を単純に0と1、ある いは1と-1とした二値モデル(Binary opinions)のモデルが磁性 物理学理論の Ising 模型の応用として提出されている[22-24].

しかし、この Ising 模型類似の研究手法では意見の分布の時間 的な発展が入れにくい.また,一方で繰り込み群の理論を応用 したモデルも Galam によって考案されている. 社会を少人数の グループに分けて、そこでの多数決でAかBかの二値の意見 のどちらかに意見が揃うと仮定したものである. それらをグルー プ分けを何回か繰り返して行うことでAとBのどちらの意見が 社会で多数派を占めるかを計算する理論である [25,26]. この 理論では少人数グループでAとBが同数だった場合,社会の 世論として優位な意見でこの少人数グループの意見が揃うとす る. 最初は少数だったグループが簡単に逆転して多数派となり うることを計算から示している. その考えで Brexit[27]や米大統 領選のトランプ当選[28]の検証も行われている.この繰り込み群 の理論では世論の動向の時間的な発展はある程度追えるが、 社会の世論でどちらの意見が優位かは理論の中にはない.外 部的な決定として境界条件として入れる必要がある.また,二値 に限る手法は米大統領選や仏大統領選の予測解析には応用 できるが、一般の社会の意見の分布は賛成の意見も反対の意 見も強弱がある. そのため, 賛成と反対の二値に限定してしまう のは単純すぎると言える.一方で連続的な意見分布を扱う数理 モデルとして Bounded Confidence Model がある[29-31]. しか し、この Bounded Confidence model は実際に大規模なデータ ベースから社会の意見を解析する上で以下の欠点がある.合 意形成の理論なので0から1までの分布しか扱わないマスメディ ア等の社会における環境における外力の影響が入っていない. この欠点を改良する形で Bounded Confidence Model を大きく 発展させた理論が最近, 石井-川畑によって提出された[32].こ の理論では意見はポジからネガまで連続的とし,個々の人同士 の相互作用は賛同・同調から反発まで様々な相互作用があると した.また、外力の影響を社会現象の数理モデル[33,34]に倣う 形で採り入れた. この理論では Bounded Confidence Model の 欠点が改良されている.また,この理論は時間発展の微分方程 式の形で提出されていて、Hegselmann-Krauseの理論と異なっ て意見の分布の時間発展が記述しやすい. ただ, この理論は 相手の意見に対する同調も反発も無限に続くと仮定している. 意見交換の初期段階は正確に記述できるが,最終段階の予測 は非現実的な無限大の正と負の意見になってしまう.この欠点 を補う理論の改良が Ishii によってなされており[35], 本研究で はこの理論を,以下に述べる社会の意見の実測を解析する理 論として用いる.

本理論の要素としては、①遠く隔たった意見には影響されない ②自分とほぼ同じ意見には影響されないという2点の修正を加 えた仮説によるモデルである.

$$\frac{dI_{i}(t)}{dt} = C_{i}A(t) + \sum_{j=1}^{N} D_{ij}\Phi(I_{j}(t), I_{i}(t))(I_{j}(t) - I_{i}(t))$$
  
$$\Phi(I_{i}, I_{i}) = \frac{1}{1 + exp(\beta|I_{i} - I_{j}| - b)} \cdot \cdot \cdot \cdot \cdot \cdot \cdot \cdot \cdot (1)$$

#### 5. シミュレーションと実測の検討

#### 5-1. シミュレーションの場合

(1)式において、 $D_{ij}$ は i 氏からi氏がどれくらい信用されてい るかをシミュレーションしている. この $D_{ij}$ に対応する係数は Hegselmann-Krause (2002)の Bounded Confidence Model で も定義されているが、我々の新しいオピニオンダイナミクス理論 ではこの係数 $D_{ij}$ が正の値なら信用していて、負の値だと不信を 抱いていると定義した. この結果、お互いに不信を抱いている と、意見交換によってお互いの意見は離れていくという計算結 果が得られる.ある程度以上意見が離れると、互いに無視する ので平行線となる. これに第三者が加わるとして、この第三者 (C氏)がA氏とB氏から強い信頼を得ている仮定して計算する と、対

立していた A 氏と B 氏が C 氏の意見にまとまるという計算結果 になる[35].



図 1:右図:300 人のお互いの係数D<sub>ij</sub>を1から-1までの乱数で 決めると設定して計算した例 左図:縦軸が意見の差で真ん中 が中立, 横軸が時間の経過である.また, 図の右側は最終的な 時間で計算で示された意見分布を示す

例として,300人のお互いの係数D<sub>ij</sub>を1から-1までの乱数で 決めると設定して計算した例を右図に示す.図の左側で縦軸が 意見の差で真ん中が中立,横軸が時間の経過である.また,図 の右側は最終的な時間で計算で示された意見分布を示す.

#### 5-1. 実測における考察

CNN の動画の再生回数上位は、国政関連の動画や面白さに 関してフォーカスをした動画にやや傾斜している.本論では、ケ ーススタディとして最も再生回数の多く、ニュース報道ではない 内容に絞った.そこで再生回数が上位の国政に関するトピック スの動画におけるコメントの意見の分布に着眼をした.





図 2:Case A におけるコメント(件)の negative, positive, neutral の 分布(取得期間: 2016/10/10~2018/11/29, 各スコア range: 0~1)



図 3:Case A におけるコメントの negative, positive, neutral を一元 化した場合の分布(スコア range:-1~2)(取得期間: 2013/5/24~2018/11/29)

Case B "Obama forgets to salute"



図 4:Case B におけるコメントの negative, positive, neutral の分布 (取得期間: 2013/5/24~2018/11/29)



図 5:Case B におけるコメントの negative, positive, neutral を一元 化した場合の分布(スコア range:-1~2)(取得期間: 2013/5/24~2018/11/29)

CaseA と CaseB は両者とも国政関連の動画であるが、CaseA は大統領選挙に関わる内容であり、ややネガティブな分布への 偏りが観測される一方、Case B に関しては面白さにフォーカスし た動画であり、ネガティブな傾向や極端に偏った分布は見受け られず比較的ポジティブな見方をされがちな傾向にあると推察 された.本研究では、コメントにおけるの自然言語処理を経たス コアにおける分布から社会の合意形成の成り立ちとシミュレーシ ョンの結果の違いとシミュレーションに関する試みを行っている. 今後この方向で研究を進めるためには、ポジ、中立、ネガのつ なぎ目の処理が課題の一つであるとも実測の結果とシミュレー ションの結果から検討される.

#### 6. 考察

本研究の大きなテーマであるマス・パーソナルにおける OSN における社会的影響についての議論は,権力に対する抵抗勢 力・ポピュリズム・危険性におけるトピックとして課題にされがち である. そのため, 5. 実測例でも取り上げたように同じ Youtube ch においてもニュースの内容や性質によって反発する意見や 合意する意見は発信源や中身によって異なる傾向も類似した 傾向も存在すると推察する. 測定した意見分布は CaseA と CaseB では報道指針は異なることからも推測するに、あるニュー ス報道や事象におけるある一定数の言及に関して比較的前向 きな傾向であるか・後ろ向きな姿勢であるかを推察が可能な傾 向として分布していることが観測できた.また,今回はニュートラ ルな意見における分布も測定を行ったため、一方軸の意見に 分裂したケースを想定した計算におけるシミュレーションの結果 とは異なる傾向を持つ. シミュレーション結果による意見分布は いくつかのクラスターに別れるケースが想定される.これは理論 の中の人同士の相互作用をさらに改良する必要があることを示 す. 実測との乖離に関しての理解を得たと共に、モデルにおけ る改良の余地を示唆される結果であった.また,現実社会にお ける傾向と相似関係もある傾向が社会学観点では推察できる要 素もあったため考慮したい.

•6 今後より一層, 世論形成における意見交流や意思決定の 場が発生しうるオンライン上において極端な世論形成や社会的 な危機に関する議論の定量的な傾向の理解を促したい.

#### 参考文献

- [1] [French J R P, 1956]French J R P (1956) A formal theory of social power., Psychological Review 63. pp. 181-194.
- [2] [Harary F, 1959]Harary F (1959)" A criterion for unanimity in French 's theory of social power ". In Cartwright D (Ed.), Stud-ies in Social Power. Institute for Social Research, Ann Arbor.
- [3] [Abelson, R P, 1964]Abelson, R P (1964)," Mathematical models of the dis-tribution of attitudes under controversy". In Frederiksen, N and Gulliksen H (Eds.), Contributions to Mathemat- ical Psychology, New York, NY: Holt, Rinehart, and Winston.
- [4] [De Groot M H, 1974]De Groot M H (1974) Reaching a consensus. J. Amer.Statist. Assoc. 69. pp. 118 - 121.
- [5] [Lehrer K, 1975]Lehrer K (1975) Social consensus and rational agnoiology. Synthese 31. pp. 141 - 160.
- [6] [Chatterjee S, 1975]Chatterjee S (1975) Reaching a consensus: Some limit theorems. Proc. Int. Statist. Inst. pp.159 -164
- [7] [Lea, John, 1984]Lea, John, and Jock Young. "What is to be Done about Law and Order?." (1984).
- [8] [Miguel, 2016]Miguel, Juan Carlos, and Miguel Ángel Casado. "GAFAnomy (Google, Amazon, Facebook and Apple): The big four and the b-ecosystem." Dynamics of Big Internet Industry Groups and Future Trends. Springer, Cham, 2016. 127-148.
- [9] Shadbolt, Nigel, and Tim Berners-Lee. "Web science emerges." Scientific American 299.4 (2008): 76-81.
- [10] France yellow vest protests
- < https://www.bbc.co.uk/news/topics/cpzg2d6re0lt/franceyellow-vest-protests>(Ref:2018/11/27)
- [11]山田善靖, 杉山学, and 八巻直一. "合意形成モデルを用い たグループ AHP." 日本オペレーションズ・リサーチ学会論 文誌 40.2 (1997): 236-244.
- [12] 八卷直一, et al. "不満関数を用いる集団区間 AHP 法." 日 本オペレーションズ・リサーチ学会論文誌 45.3 (2002): 268-284.
- [13]八巻直一, and 関谷和之. "不完全データを伴う大規模 AHP (決定理論とその関連分野)." (1998).
- [14] Hjarvard, S. (2008). The mediatization of society. Nordicom review, 29(2), 102-131.
- [15] Pak, Alexander, and Patrick Paroubek. "Twitter as a corpus for sentiment analysis and opinion mining." LREc. Vol. 10. No. 2010. 2010.
- [16] Agarwal, Apoorv, et al. "Sentiment analysis of twitter data." Proceedings of the workshop on languages in social media. Association for Computational Linguistics, 2011.
- [17] Siersdorfer, Stefan, et al. "How useful are your comments?: analyzing and predicting youtube comments and comment ratings." Proceedings of the 19th international conference on World wide web. ACM, 2010.
- [18] Wilson, T., Wiebe, J., & Hoffmann, P. (2005, October). Recognizing contextual polarity in phrase-level sentiment analysis. In Proceedings of the conference on human language technology and empirical methods in natural language processing (pp. 347-354). Association for Computational Linguistics.
- [19] 佐藤謙太, et al. "ネガポジ解析による Web データと株価変動の相関関係評価." (2015).

- [20] Lasswell, Harold D. "The measurement of public opinion." American Political Science Review 25.2 (1931): 311-326.
- [21] Lasswell, Harold D. "Why be quantitative." Language of Politics(1949): 40-52.
- [22] Galam, Physica A 238, 66 (1997).
- [23] Sznajd-Weron and J. Sznajd, Int. J. Mod. Phys. C 11,1157 (2000)
- [24] Sznajd-Weron, M. Tabiszewski, and A. M. Timpanaro, Europhys. Lett. 96, 48002
- (2011).
- [25] Galam S, "Application of statistical physics to politics" Physica A: Statistical
- Mechanics and its Applications 274, 1999, Pages 132-139
- [26] Galam S, "Real space renormalization group and totalitarian paradox of majority
- rule voting" Physica A: Statistical Mechanics and its Applications 285, Issues 1-2,
- 15 September 2000, Pages 66-76
- [27] Galam S, "Are referendums a mechanism to turn our prejudices into rational choices? An unfortunate answer from sociophysics" Chapter 19 of The Routledge Handbook to Referendums and Direct Democracy edited by Laurence Morel and Matt Qvortrup, (Taylor & Francis, London, 2017)
- [28] Galam, S, Int. J.Mod. Phys.B31 (2017) 1742015
- [29] Hegselmann R and U Krause, "Opinion Dynamics and Bounded Confidence Models, Analysis, and Simulation" Journal of Artificial Society and Social Simulation 5 (2002)
- [30] Guillaume Deffuant, David Neau, Fr'ed'eric. Amblard, and G'erard Weisbuch. Mixing Beliefs among Interacting Agents. Advances in Complex Systems, 3:87-98, 2000. 15.
- [31] G erard Weisbuch, Guillaume Deffuant, Fr ed eric Amblard, and Jean-Pierre Nadal.
- "Meet, Discuss and Segregate!" Complexity, 7(3):55-63, 2002.
- [32] Akira Ishii and Yasuko Kawahata, "Opinion Dynamics Theory for Analysis of Consensus Formation and Division of Opinion on the Internet", Proceedings of The 22nd Asia Pacific Symposium on Intelligent and Evolutionary Systems (IES2018) 71-76; arXiv:1812.11845 [physics.soc-ph]
- [33] A.Ishii, H.Arakaki, N.Matsuda, S.Umemura, T.Urushidani, N.Yamagata and N.Yoshida; The 'hit' phenomenon: a mathematical model of human dynamics interactions as s stochastic process, New Journal of Physics 14 (2012) 063018 (22pp)
- [34] A Ishii and Y Kawahata, "Sociophysics Analysis of the dynamics of peoples' interests in society" Front. Phys., 08 October 2018 | https://doi.org/10.3389/fphy.2018.00089
- [35] A. Ishii, "Opinion dynamics theory considering trust and suspicion in human relations" Submitted to Proceeding of 19th International Conference on Group Decision and Negotiation in 2019 a Joint GDN-EWG/BOR meeting,
- [36] Bird, Steven, and Edward Loper. "NLTK: the natural language toolkit." Proceedings of the ACL 2004 on Interactive poster and demonstration sessions. Association for Computational Linguistics, 2004.

## Multi-agent maximum discounted causal entropy逆強化学習による報酬推定

Estimation of agent's rewards with multi-agent maximum discounted causal entropy inverse reinforcement learning

> 浪越圭一 荒井幸代 Keiichi Namikoshi Sachiyo Arai

千葉大学大学院融合理工学府

Graduate School of Science and Engineering, Chiba University

We propose a entropy-base multi-agent inverse reinforcement learning method for constructing a multi-agent simulation. By using multi-agent inverse reinforcement learning, we can estimate the agent's behavior rule and the reward reflecting the purpose of the agent. In this paper, we extend mximum discounted causal entropy to markov game environment. Experimental results showed that the proposed method can estimate valid reward at small grid world.

#### 1. はじめに

群衆,交通流,金融など,複数の行動主体が各自の目的に 従い相互作用する現実の環境は、マルチエージェント系と呼ば れる.マルチエージェント系の振舞いを再現することで,各自 の目的を理解し,行動を予測する研究は古くから取り組まれ ており,災害誘導や交通政策の評価法として重要な研究分野で ある.

マルチエージェント系の再現法の一つにマルチエージェント シミュレーション (MAS) がある. MAS は,行動主体をエー ジェントとして扱い,エージェントの観測から行動のマッピン グを行動ルールとして記述する.そのため,エージェントの意 思決定過程や行動目的を比較的容易に解釈可能である.一方, MAS は行動ルールから全体の振舞いをボトムアップに再現す るため,行動ルールの設計に多くの試行錯誤と妥当性の説明を 要する.著者らはこの問題に対し,全体の振舞いを観測した行 動ログから,各エージェントの行動ルールを推定する枠組みを 提案してきた [Namikoshi 18].しかし,エージェントの目的 を理解するには,推定した行動ルールを解析する必要がある.

そこで、マルチエージェント逆強化学習によるエージェン トの目的推定に着目する.マルチエージェント逆強化学習は、 マルコフ決定過程をマルチエージェント系へ拡張した Markov game において、行動ログからエージェントの報酬を推定する 枠組みである.報酬は一般に状態・行動の価値を表すため、推 定報酬の高い状態・行動がエージェントの目的を表すといえ る.つまり、マルチエージェント逆強化学習により、報酬から 各エージェントのもつ目的を容易に解釈できる可能性がある.

本論文では、エントロピー最大化原理を用いた新たなマル チエージェント逆強化学習を提案する.具体的には、infinithorizonのマルコフ決定過程を対象とする Maximum discounted causal entropy 逆強化学習を Markov game へ拡張 し、その解法を示した.実験では、2人エージェントの簡易な GridWorld を対象に、決定的な Nash 均衡解の方策から生成 した行動ログから妥当な報酬が推定可能なことを示す.

#### 2. 対象問題

Markov game(MG) を <  $\mathcal{N}$ ,  $\mathcal{S}$ ,  $\{\mathcal{A}_n\}_{n \in \mathcal{N}}$ , T,  $\{R_n\}_{n \in \mathcal{N}}$  > の組で表す.  $\mathcal{N}$  はエージェント集合 ( $|\mathcal{N}| \geq 2$ ),  $\mathcal{S}$  は有限離散状態空間,  $\mathcal{A}_n$  はエージェント n の有限離散行動空間,  $T: \mathcal{S} \times \mathcal{A}_1 \times \cdots \times \mathcal{A}_{|\mathcal{N}|} \times \mathcal{S} \rightarrow [0,1]$  は状態遷移確率,  $R_n: \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$  はエージェント n の報酬をそれぞれ表す.また, エージェント n の行動は  $a_n \in \mathcal{A}_n$ , 全エージェントの結合行動は  $a \in \mathcal{A}$  と記す.全エージェントは状態  $s \in \mathcal{S}$  にアクセス可能と仮定し,不完全知覚は扱わない.

本論文では,報酬が未知の MG\{ $R_n$ }<sub>n∈N</sub> において,全 エージェントの行動ログ,すなわち可変長の軌跡集合  $\mathcal{D} =$ { $\{s_t, a_t\}_{t=0}^{t_0}$ } から報酬 { $R_n$ }<sub>n∈N</sub> を推定する.以下,行 動ログの行動主体をエキスパート, $\mathcal{D}$ をエキスパート軌跡と 記す.報酬推定時,状態遷移確率 T を直接知ることはできな いが,シミュレーション環境は利用可能とする.また,エキス パート軌跡を生成したエキスパート方策  $\pi^E$  も得られないも のとする.

#### 3. 関連研究

#### 3.1 模倣学習における逆強化学習の位置づけ

模倣学習 (Imitation Learning) とは、エキスパート軌跡か らエキスパートの振舞いを再現する枠組みである.模倣学習 は主に二つのアプローチに大別される.一つめの Behavioral Cloning は、エキスパート軌跡からエキスパートの振舞いを直 接模倣する.そのため、実装が比較的容易な反面、エキスパー ト軌跡が十分に得られない場合、軌跡に含まれない状態行動へ の汎化性能が問題となる.二つめの逆強化学習 (IRL: Inverse reinforcement learning) は、エキスパート軌跡を生成したエ キスパート方策を学習する.そのため、軌跡に含まれない状態 行動においても適切な学習が期待できる.しかし、最適な報酬 が複数存在する ill-posed 問題や、推定報酬から方策を計算す る強化学習の計算コストが高いといった課題がある.

IRL は,エキスパート報酬の推定を目的とする Reward learning と,エキスパート方策の推定を目的とする Policy learning に分けられる. Reward learning は,エキスパート方策 と他の方策とのマージンを最大化する手法 [Ng 00, Abbeel 04] や,最大エントロピー法に基づく手法 [Ziebart 10, Zhou 18] などが提案されている.一方 Policy learning は,主に敵対的 学習を用いた手法 [Ho 16] などが提案されている.

連絡先: 浪越圭一,千葉大学大学院融合理工学府都市環 境システムコース,千葉県千葉市稲毛区弥生町 1-33, acka2158@chiba-u.jp

#### 3.2 マルチエージェント逆強化学習の分類

表 1 に, マルチエージェント逆強化学習 (MAIRL: Multiagent IRL) の分類を示す. MAIRL は, 定式化の目的関数と 推定する報酬の構造によって分類できる.

| 表 1: マルチエージェント逆強化学習の? |
|-----------------------|
|-----------------------|

| Reward      | Objectives     |              |           |
|-------------|----------------|--------------|-----------|
| structure   | Max-margin     | Max-entropy  | others    |
| homogeneous |                | [Šošić 17]   |           |
| zerosum     |                |              | [Lin 18]  |
|             |                |              | [Wang 18] |
|             | [Natarajan 10] | [Ziebart 10] | [Le 17]   |
| others      | [Reddy 12]     | [Bogert 18]  |           |
|             |                | [Song 18]    |           |

[Šošić 17] は, swarm system において homogeneous なエー ジェントの報酬推定を提案している. [Lin 18, Wang 18] は, ゼ ロ和ゲームを対象とする MAIRL を提案している. しかしどち らの提案も,報酬に特殊な構造を仮定する必要があり,一般的な Markov game への適用は難しい. [Natarajan 10, Reddy 12] は [Ng 00] を拡張した MAIRL であり, [Natarajan 10] は中央 制御器, [Reddy 12] は分散制御器を仮定しそれぞれ解いている. しかし前者は状態遷移確率を陽に必要とし、後者は Inner-Loop において Nash 均衡解を求める Nash Q-learning を用いる必要 がある. [Ziebart 10, Bogert 18] は最大エントロピー法に基づ いた MAIRL である. [Ziebart 10] は状態遷移が確率的な場合 に有効な Maximum causal entropy IRL を定式化し、3 体の pursuit-evasion において有効性を示している. [Bogert 18] は エキスパート軌跡の観測に隠れ (Occlusuion) が生じる環境下 の MAIRL を提案している. しかし前者は finit-horizon を対 象とし、後者はエージェントが相互作用する状態での利得行列 を必要とすることから, 適用範囲が限られる. [Le 17, Song 18] はいずれも Policy learning を目的とした提案であり、エージェ ントの報酬を陽に推定しない.

本論文では、特徴ベクトル f と重み  $\theta$  の線形和で報酬関数 が表されると仮定し、最大エントロピー法に基づく推定法を提 案する. [Ziebart 10, Bogert 18] とは infinit-horizon を扱え る点、利得行列を必要としない点で異なる.

#### 4. 提案法

#### 4.1 定式化

マルコフ決定過程を対象とする Maximum discounted causal entropy IRL[Zhou 18](以下 MDCE IRL と記す)を, Markov game へ拡張した Multi-agent MDCE IRL(以下 M-MDCE IRL と記す)を定式化する.式(1)から式(5)に M-MDCE IRL の定義を示す.

$$\max_{\pi_{t},t\geq 0} \sum_{n\in N} H_{\pi_{t,n},\pi_{-n}^{E}}(\pi_{t,n}) \tag{1}$$

s.t. 
$$\overline{f}_{n,\pi^E} = \overline{f}_{n,\pi_{t,n},\pi^E_{-n}} \quad \forall n \in \mathcal{N}, t \ge 0$$
 (2)

 $\pi_{t,n}(a_n|s) \ge 0 \quad \forall a_n \in \mathcal{A}_n, s \in \mathcal{S}, n \in \mathcal{N}, t \ge 0$ (3)

$$\sum_{a_n \in \mathcal{A}_n} \pi_{t,n}(a_n | s) = 1 \quad \forall s \in \mathcal{S}, n \in \mathcal{N}, t \ge 0$$
(4)

$$\pi_{t,n}(a_n|s) = \pi_{t',n}(a_n|s) \quad \forall s \in \mathcal{S}, a_n \in \mathcal{A}_n, n \in \mathcal{N}, t, t' \ge 0$$
(5)

ここで,式(1)はエージェント*i*の方策に対するエントロピー であり式(6)で定義される.式(2)は式(7)の特徴期待ベクト ルを一致させる制約,式 (3) から式 (5) は方策に関する制約を 表す.また, $f_n: S \times A \rightarrow \mathbb{R}^k$  はエージェント n の特徴ベク トル, $\overline{f_n}$  は特徴期待ベクトルである.

$$H_{\pi_{t,n},\pi_{-n}^{E}}(\pi_{t,n}) = \mathbb{E}\left[\sum_{t=0}^{\infty} -\gamma^{t} \log \pi_{t,n} \left(A_{t,n} | S_{t}\right)\right]$$
(6)

$$\overline{f}_{n,\pi_n,\pi_{-n}} = \sum_{t=0}^{\infty} \gamma^t \mathbb{E}\left[f_n\left(S_t, A_t\right)\right] \tag{7}$$

$$\boldsymbol{\pi}\left(A_{t}|S_{t}\right) = \prod_{n \in \mathcal{N}} \pi_{n}\left(A_{t,n}|S_{t}\right) \tag{8}$$

#### 4.2 Single-agent 系への分解と解法

M-MDCE 問題の解法は大きく2つ考えられる.一つめは, エントロピーに基づくマルチエージェント強化学習を Inner-Loop に用いることで, M-MDCE を Multi-agent 系のまま扱 う方法である.しかし,マルチエージェント強化学習は状態行 動空間の爆発や同時学習問題を扱う必要があり,方策が適切に 学習できない可能性がある.

二つめは、各エージェントごとの目的関数へ M-MDCE を 分解し、Single-agent 系として扱う方法である. 具体的には、 以下の M-MDCE のラグランジュ緩和問題を、各エージェン トごとに解く.

$$\max_{\boldsymbol{\pi}_{t},t\geq0}\sum_{n\in\mathcal{N}}H_{\boldsymbol{\pi}_{t,n},\boldsymbol{\pi}_{-n}^{E}}(\boldsymbol{\pi}_{t,n})+\theta_{n}(\overline{f}_{n,\boldsymbol{\pi}^{E}}-\overline{f}_{n,\boldsymbol{\pi}_{n},\boldsymbol{\pi}_{-n}^{E}})$$
s.t.  $\boldsymbol{\pi}_{t,n}(a_{n}|s)\geq0\quad\forall a_{n}\in\mathcal{A}_{n},s\in\mathcal{S},n\in\mathcal{N},t\geq0$ 

$$\sum_{a_{n}\in\mathcal{A}_{n}}\boldsymbol{\pi}_{t,n}(a_{n}|s)=1\quad\forall s\in\mathcal{S},n\in\mathcal{N},t\geq0$$
 $\boldsymbol{\pi}_{t,n}(a_{n}|s)=\boldsymbol{\pi}_{t',n}(a_{n}|s)\quad\forall s\in\mathcal{S},a_{n}\in\mathcal{A}_{n},n\in\mathcal{N},t,t'\geq0$ 

Single-agent 系へ分解した場合,MDCE IRL[Zhou 18] と同 様に各エージェントごとにMDCE IRL を解けばよく,Multiagent 系における問題は生じない.しかし,対象問題の仮定か ら,報酬を推定するエージェント n 以外のエキスパート方策  $\pi_{-n}^{E}$  は得られない.

そこで本提案では、エキスパート方策  $\pi_{n}^{E_n}$ を代替方策  $\pi_{-n}$ に置き換え推定する方法を提案する. Algorithm 1 に提案法の アルゴリズムを示す.まず、各 iteration において、報酬の重 みと代替方策を更新するエージェント集合  $\tilde{N}$  を選択する.次 に、MDCE IRL により報酬の重み  $\theta_n$ を更新する.更新の打 ち切りは、特徴期待ベクトルが十分一致した場合か、打ち切り 回数に達した場合とする.最後に、Soft Q-Learning[Zhou 18] により方策  $\pi_n$ を更新したのち、 $\pi_{-n}$ を  $\pi_{-n}^{E_n}$ へ近づける「補 完」を実行する.以下では、エージェントの選択法と、代替方 策の更新及び補完法について述べる.

| Algorit | hm 1 | Multi-agent | MDCE |
|---------|------|-------------|------|
|---------|------|-------------|------|

| -                    | -  |
|----------------------|--|
| Input: N             | Markov Game $\{R_n\}_{n \in \mathcal{N}}$  |
| Input: H             | Expert trajectories $\mathcal{D}$  |
| Output:              | reward weight $\{\theta_n\}_{n \in N}$   |
| Initia               | lize policies $\{\pi_n\}_{n \in N}$ and $\{\theta_n\}_{n \in N}$                                   |
| 1: <b>for</b> it     | eration = 1, 2 do  |
| 2: $\tilde{N}$       | $\mathbf{f} \leftarrow \operatorname{Selector}(\mathcal{N})$                                       |
| 3: $\theta_r$        | $u_n \leftarrow \mathrm{MDCE}(\mathcal{D}^n, \tilde{\pi}_{-n})  \forall n \in \tilde{\mathcal{N}}$ |
| 4: $\pi_{\eta}$      | $ _{n} \leftarrow \text{SoftQ}(\theta_{n}, \tilde{\pi}_{-n})  \forall n \in \tilde{\mathcal{N}} $  |
| 5: $\tilde{\pi}_{i}$ | $\pi_n \leftarrow \text{Completation}(\pi_n, \mathcal{D})  \forall n \in \tilde{\mathcal{N}}$      |
|                      |  |

#### ■エージェントの選択法

エージェントの選択法は二種類ある. 図 1 にエージェント が 2 体の場合の更新手順と代替方策の流れを示す. 一つめの 選択法は, エージェントを 1 体ずつ選択して更新する Cyclic である. Cyclic は, 1 体ずつ報酬をエキスパートへ少しずつ近 づけていき, 更新した報酬に対する方策を代替方策として用い る. 二つめの選択法は, 全エージェントの報酬を同時に更新す る Parallel である. Parallel は, 全エージェントの報酬更新を 並列に実行しつつ, 更新した報酬に対する代替方策を定期的に 交換する.



図 1: 報酬の更新順と代替方策の流れ :  $|\mathcal{N}| = 2$ の場合. i - 1, i, i + 1 は iteration

#### ■代替方策の更新・補完法

MDCE IRL において報酬  $\theta$  に対する方策  $\pi_{\theta}$  は 式 (9),式 (10) の Soft Bellman 方程式を満たすことが 知られている [Zhou 18]. ここで softmax<sub>a∈A</sub>Q<sup>soft</sup><sub>θ</sub>(s, a) = log  $\sum_{a \in A} \exp(Q_{\theta}^{\text{soft}}(s, a))$  とする.よって代替方策の更新に は,Algorithm 2 に示す TD-base の Soft Q-Laerning を用い る.最後に、更新した代替方策に対し、エキスパート軌跡に含 まれる状態・行動を確率 1 で取るよう、代替方策を補完する. この操作は、推定中の方策とエキスパート方策の確率分布を近 づけることを意図している.

$$Q_{\theta}^{\text{soft}}(s,a) = \theta^{\top} f(s,a) + \gamma \sum_{s' \in \mathcal{S}} T(s'|s,a) V_{\theta}^{\text{soft}}(s') \qquad (9)$$

$$V_{\theta}^{\text{soft}}(s) = \text{softmax}_{a \in \mathcal{A}} Q_{\theta}^{\text{soft}}(s, a)$$
(10)

$$\pi(a|s) = \exp\left(Q_{\theta}^{\text{soft}}(s,a) - V_{\theta}^{\text{soft}}(s)\right)$$
(11)

#### Algorithm 2 Soft Q-Learning

- **Input:** reward weight  $\theta_n$ , explore policy  $\pi$ , other agent's policy  $\tilde{\pi}_{-n}$
- 1: for  $t = 0, 1, 2, \cdots$  do
- 2: Generate sample  $(s_t, a_t, s_{t+1})$  from  $\pi, \tilde{\pi}_{-n}$

3: 
$$Q_n^{\text{soft}}(s_t, a_{t,n}) \leftarrow Q_n^{\text{soft}}(s_t, a_{t,n}) + \eta_t(s_t, a_{t,n})$$
.

4: 
$$\left[\theta_n^{\top} f_n\left(s_t, a_t\right) + \gamma V_n^{\text{sort}}\left(s_{t+1}\right) - Q_n^{\text{sort}}\left(s_t, a_{t,n}\right)\right]$$

#### 計算機実験

#### 5.1 実験設定

図 2 に二つの実験環境を図示する. どちらの環境も 3 × 3 の GridWorld であり、2 体のエージェントが各自のスタート 座標  $(S_1, S_2)$  からゴール G へ最短 step で到達することを目





 (a) GW1:決定的遷移
 (b) GW2:確率的遷移
 図 2:環境とエキスパート軌跡:エージェント 1,2 に対して s<sub>1</sub>, s<sub>2</sub> は初期座標, g<sub>1</sub>, g<sub>2</sub> はゴール.太線は障壁

的とする.状態集合は全エージェントの座標の組み合わせ,各 エージェントの行動集合は $A_1 = A_2 = \{up, down, right, left\}$ であり、1step で隣接する四方向のセルに移動できる.ただし、 壁に移動する場合と、2体のエージェントが同じセルへ移動 する場合は、遷移前の座標に留まる.加えて、後者の条件は、 ゴール座標へ移動する場合を除く.GW2では、スタート座標 のセルと1つ上のセルの間に障壁があるため、 $S_1, S_2$ で up が とられた場合は1/2の確率で遷移に失敗する.いずれか、も しくは両方のエージェントがゴールへ到達した状態は吸収状態 として扱う.

各環境のエキスパート軌跡には Nash 均衡解の一つを与える. 図 2 にエキスパート方策を矢印で示す.エキスパートは,矢印 に沿った座標でそれぞれの行動を決定的にとるものとする.こ の軌跡は,ゴールに到達したエージェントに+100,同じセル に移動しようとした場合-1の報酬を与えたときの Nash 均衡 解である [Hu 03].特徴ベクトルは全状態・行動対に対するバ イナリベクトルとし,特徴期待ベクトルは最大ステップ数 50 の軌跡を 100 本サンプリングから式 (7)で求める.初期の重み は 0 ベクトル,方策は一様分布とし,各 iteration ではステッ プ幅 0.1 の最急降下法で MDCE IRL を最大 100 回更新する. また,Inner-Loop の Soft Q-Learning は 100episode 学習す る.報酬の重み更新には正則化なしの場合と L2 正則化の場合 をそれぞれ実験した.

#### 5.2 実験結果

GW1 のおける 10 試行平均および標準偏差の推移を図 3 と 図 4 に示す.図 3 はエージェントの選択が Cyclic の場合,図 4 は Parallel の場合である. 横軸は iteration,縦軸はエキスパー ト軌跡との特徴期待ベクトルの差のノルム表し,エキスパート と完全に一致するとき0となる.結果から,GW1 ではエキス パート軌跡と完全に一致する報酬が推定したことがわかる.ま た,エキスパート軌跡による補完は収束までの iteration を減 らし,Cyclic に比べ Paralell のほうが早く収束している.こ の結果の原因としては,代替方策  $\pi_n$ がエキスパート方策  $\pi_n^E$ に一致したとき分解された問題が元の M-MDCE IRL に一致 することや,補完により推定対象のエージェントがエキスパー ト軌跡上を遷移することを邪魔しなかったことが考えられる.

次に,図5にGW2にCyclicを適用した結果を示す.GW2 では,代替方策を補完しない場合,エキスパートと一致する 解が得られず,補完を用いてもエキスパートと完全に一致しな かった.この結果は,Parallelにおいても同様である.しかし, 推定報酬のうち最も値の大きな状態行動上位5組(図6)を確 認したところ,エキスパート軌跡上に大きな報酬が置かれてい ることから,結果が妥当であると確認できた.エキスパートと 完全に一致しない理由としては,環境の確率的遷移により,特 徴期待ベクトル計算のためのサンプル分布が一致しずらいこと が考えられる.



## 6. 結論と今後の課題

本論文では、MAS におけるエージェントの行動ルール設計, およびエージェントの目的理解のため、新たな MAIRL を提 案した.具体的には、infinit-horizon の Markov game におい て、最大エントロピー法に基づく MAIRL を提案した.提案 法は、決定的なエキスパート軌跡から報酬が推定できること を、3x3 の GridWorld の実験から示した.今後の課題として、 異なる環境や連続状態空間への適用、収束・最適性の考察や、 獲得する均衡解概念の特定を挙げる.

#### 参考文献

- [Abbeel 04] Abbeel, P. and Ng, A. Y.: Apprenticeship Learning via Inverse Reinforcement Learning, in *Proceedings of the Twenty-first International Conference on Machine Learning*, ICML '04, pp. 1–, New York, NY, USA (2004), ACM
- [Bogert 18] Bogert, K. and Doshi, P.: Multi-robot inverse reinforcement learning under occlusion with estimation of state transitions, *Artificial Intelligence*, Vol. 263, pp. 46–73 (2018)
- [Ho 16] Ho, J. and Ermon, S.: Generative Adversarial Imitation Learning, in Lee, D. D., Sugiyama, M., Luxburg, U. V., Guyon, I., and Garnett, R. eds., Advances in Neural Information Processing Systems 29, pp. 4565–4573, Curran Associates, Inc. (2016)
- [Hu 03] Hu, J. and Wellman, M. P.: Nash Q-learning for generalsum stochastic games, *Journal of machine learning research*, Vol. 4, No. Nov, pp. 1039–1069 (2003)
- [Le 17] Le, H. M., Yue, Y., Carr, P., and Lucey, P.: Coordinated Multi-Agent Imitation Learning, in *International Conference* on Machine Learning, pp. 1995–2003 (2017)
- [Lin 18] Lin, X., Beling, P. A., and Cogill, R.: Multiagent Inverse Reinforcement Learning for Two-Person Zero-Sum Games, *IEEE Transactions on Games*, Vol. 10, No. 1, pp. 56–68 (2018)
- [Namikoshi 18] Namikoshi, K. and Arai, S.: Estimation of the heterogeneous strategies from action log, in *Proceedings of the Genetic and Evolutionary Computation Conference*, pp. 1310–1317ACM (2018)
- [Natarajan 10] Natarajan, S., Kunapuli, G., Judah, K., Tadepalli, P., Kersting, K., and Shavlik, J.: Multi-Agent Inverse



図 6: 推定報酬値の大きな状態行動 (GW2 + Cyclic)

Reinforcement Learning, in 2010 Ninth International Conference on Machine Learning and Applications, pp. 395–400, Washington, DC, USA (2010), IEEE

- [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.
- [Reddy 12] Reddy, T. S., Gopikrishna, V., Zaruba, G., and Huber, M.: Inverse reinforcement learning for decentralized noncooperative multiagent systems, in 2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC), pp. 1930–1935, Seoul, Korea (South) (2012), IEEE
- [Song 18] Song, J., Ren, H., Sadigh, D., and Ermon, S.: Multi-Agent Generative Adversarial Imitation Learning, in Bengio, S., Wallach, H., Larochelle, H., Grauman, K., Cesa-Bianchi, N., and Garnett, R. eds., Advances in Neural Information Processing Systems 31, pp. 7471–7482, Curran Associates, Inc. (2018)
- [Šošić 17] Šošić, A., KhudaBukhsh, W. R., Zoubir, A. M., and Koeppl, H.: Inverse Reinforcement Learning in Swarm Systems, in *Proceedings of the 16th Conference on Autonomous Agents and MultiAgent Systems*, AAMAS '17, pp. 1413– 1421, Richland, SC (2017), International Foundation for Autonomous Agents and Multiagent Systems
- [Wang 18] Wang, X. and Klabjan, D.: Competitive Multi-agent Inverse Reinforcement Learning with Sub-optimal Demonstrations, in Dy, J. and Krause, A. eds., Proceedings of the 35th International Conference on Machine Learning, Vol. 80 of Proceedings of Machine Learning Research, pp. 5143–5151, Stockholmsm?ssan, Stockholm Sweden (2018), PMLR
- [Zhou 18] Zhou, Z., Bloem, M., and Bambos, N.: Infinite Time Horizon Maximum Causal Entropy Inverse Reinforcement Learning, *IEEE Transactions on Automatic Control*, Vol. 63, No. 9, pp. 2787–2802 (2018)
- [Ziebart 10] Ziebart, B. D., Bagnell, J. A., and Dey, A. K.: Modeling Interaction via the Principle of Maximum Causal Entropy, in *ICML* (2010)

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

# [3Q3-J-13] AI application: analysis of physical behaviors in artifacts

Chair:Takuya Hiraoka Reviewer:Yoichi Sasaki

Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room Q (6F Meeting room, Bandaijima bldg.)

## [3Q3-J-13-01] Construction of Dataset for Feature Extraction Performance **Evaluation using Aerial Photographs** OHiroyuki Ohno<sup>1</sup>, Ryo Endo<sup>1</sup>, Takayuki Nakano<sup>1</sup>, Masako Shinoda<sup>1</sup> (1. Geospatial Information Authority of Japan) 1:50 PM - 2:10 PM [3Q3-J-13-02] Slime detection during pile construction using machine learning OSohei Arisaka<sup>1</sup>, Yuki Tamagawa<sup>1</sup>, Kojiro Takesue<sup>1</sup> (1. Kajima Corporation) 2:10 PM - 2:30 PM [3Q3-J-13-03] The optimization and comparison of methods for the Air foil design using Deep Reinforcement Learning. OHitoshi Hattori<sup>1</sup>, Kazuo Yonekura<sup>1</sup> (1. IHI Corporation) 2:30 PM - 2:50 PM [3Q3-J-13-04] Application of Gradient Booting regression toward the Computational Fluid Dynamics in the Manufacturing industry OYutaro Ogawa<sup>1</sup>, Takuya Shimizu<sup>1</sup>, Toshiaki Yokoi<sup>1</sup> (1. INFORMATION SERVICES INTERNATIONAL-DENTSU, LTD.)

2:50 PM - 3:10 PM

## 空中写真を用いた地物抽出性能評価用データセットの構築 Construction of Dataset for Feature Extraction Performance Evaluation using Aerial Photographs

大野 裕幸\*1 Hiroyuki Ohno

遠藤 涼\*1 Ryo Endo 中埜 貴元<sup>\*1</sup> Takayuki Nakano 篠田 昌子<sup>\*1</sup> Masako Shinoda

\*1 国土地理院 Geospatial Information Authority of Japan

Several datasets are known as datasets for feature extraction. However, they are targeted to outside Japan and are not necessarily dataset with high regional diversity. Therefore, it is not suitable as an evaluation dataset for feature extraction in mapping performed as survey in Japan. So, we carried out this research with the aim of enabling the evaluation of feature extraction performance for high regional diversity and aerial photograph actually used in mapping in Japan. As a result, a dataset for evaluation was constructed using aerial photographs of 1328 regions taken in Japan since 1967. Furthermore, we compared the evaluation value of the prediction result using our dataset with that using the existing dataset using pix2pix and U-Net, and concluded that our dataset can perform sufficiently reliable evaluation.

#### 1. はじめに

地図を作成する主要な手段の一つが写真測量である.写真 測量では、空撮画像を元に、画像に写っている道路や建物等 の地物の位置や形状等を読み取って地図データを作成する. そのような空撮画像から地物の位置と範囲を特定する工程を 「判読」、判読した地物を地図上の座標を持ったデータにする 工程を「図化」というが、これらの判読、図化の作業はこれまで測 量技術者による手作業に頼らざるを得なかった.

一方で, CNN を始めとする画像認識技術が年々高度化して おり,高分解能衛星の画像を用いた道路と建物抽出用のデー タセット SpaceNet や,空撮画像を元に作成された建物抽出の ベンチマーク用データセット Inria Aerial Image Labeling Dataset [Maggiori 17](以下,「Inria データセット」という.)などが公表され, 衛星画像を用いた地物抽出(Feature Extraction)のコンテスト DeepGlobe 2018 [Demir 18]も実施されるなど,空撮画像から Feature Extraction を行う研究が盛んになりつつある. Feature Extraction は、測量の地図作成における判読及び図化の工程 に類似していることから、これを測量の工程に導入して判読及 び図化の一部でも自動化することができれば,地図作成の生産 性向上に繋がるだけでなく,災害時の被害判読等の迅速化に も応用が可能と考えられる. そこで, 筆者らは地上画素寸法 10cm~40cm の範囲で撮影された測量用の空撮画像を対象と して,我が国における測量への導入を目標とした高性能な Feature Extraction の実現に取り組んでいる.

Feature Extraction の性能は、評価用のデータセットを用いて F 値や IoU などの数値によって定量的に評価することが一般的 である.測量という実業務への導入を念頭に置いた場合、測量 で用いられているデータと同じものを評価対象として、様々な季 節、地域、気象条件の下で安定して均質な性能を発揮できるか 否かを適切に評価しなければならない.そのためには、測量用 に撮影された空撮画像から作成され、十分な多様性を有する評 価用のデータセットが必要である.しかし、既存の評価用データ セットは、日本国外の都市を対象としたものであるうえ、衛星画 像から作成されたものが多く、地域多様性の観点からも十分と は言えない.そのため、まず、我が国を対象として十分な地域 多様性を備え、測量用の空撮画像を対象とした Feature Extractionの性能評価用データセットを構築したので報告する.

連絡先:大野裕幸,国土地理院,ohno-h96bp@mlit.go.jp

#### 2. 測量に用いられる空撮画像

測量に用いる空撮画像の撮影に関する仕様は, 鳥瞰写真な どとは異なり, 要件が厳密に作業規程の準則[国土交通省 08] によって規定されている. そのため, 測量に用いる空撮画像を 一般的な空撮画像と区別して「空中写真」と記述することとし, ま ず初めに, 空中写真と, 既存の評価用データセットでよく用いら れているオルソ画像について説明する.

#### 2.1 空中写真の撮影方法

空中写真は、航空機に搭載された専用のカメラを用いて直下 に向けて撮影される.かつては 23cm 幅のフィルムを使用したア ナログカメラが用いられていたが、現在では全面的にデジタル カメラによる撮影に移行している.カメラパラメータは、焦点距離 などの内部パラメータが事前に精密に検定されているうえ、航 空機に搭載された GNSS(いわゆる GPS 等の衛星測位システ ム)と慣性計測装置(IMU)によって、外部パラメータである写真 撮影時のカメラの三次元位置とレンズ光軸の角度も極めて高精 度に計測される.さらに、撮影後に画像とカメラパラメータを用い てバンドル法等で調整計算を行うことで測量の精度を保持する ように設計されている.空中写真撮影用のデジタルカメラは主な ものだけでも10種類以上が使用されている.

#### 2.2 空中写真の特性とオルソ画像

空中写真はカメラのレンズの中心に光束が集まる中心投影で 撮影されるため、画像が写真の中心から周囲に向かって倒れ 込むように写るという特性があり、土地の起伏に伴って歪みも生 じるため、そのままでは地図とは重ならない.これに対し、中心 投影による倒れ込みと、地形の起伏による歪みを取り除く画像 処理(正射変換)を行い、画像のどこであっても真上から見たよ うな傾きの無い正しい大きさと位置に表示された画像に変換し たものをオルソ画像という(図1).オルソ画像は、地図とぴったり と重ねることができる.そのため、オルソ画像を元画像とすれば、 既往のポリゴン型の地図データを参照用のデータとして用いる ことが可能である.ただし、撮影年や撮影縮尺が異なるなど、参 照用の地図データの作成に用いられた画像とは異なる写真か ら作成されたオルソ画像を用いた場合は、地図データと元画像 に写っている内容の不一致が生じる場合がある.

一方で,空中写真では,中心投影であることを利用して左目 用の画像と右目用の画像を用意し,簡易立体視鏡や立体視に


図1.空中写真とオルソ画像の違い

対応した眼鏡と図化ソフトを用いることで立体視をすることがで きる. 元画像に対する適切な参照データが入手できない場合, 立体視によって地物を判読し,使用する画像と完全に合致する 高精度な参照データを作成することができる. 筆者らは,立体 視によって作成された参照データが評価用データセットとして 最適であると考えている.

#### 3. 多様性を持った評価用データセットの構築

空中写真から作成された既存の Feature Extraction 用データ セットとしては Inria データセットが面積の観点から最大と思われ る. Inria データセットは、地上画素寸法 30cm のオルソ画像を 使用し、アメリカ 6都市とオーストリア 4都市の合計 10都市 810 ㎢のデータが公開されており、5都市 405 ㎢分はトレーニング 用データとして参照データとセットで入手することが可能である.

しかし、日本における測量に用いることを目標とした Feature Extraction のトレーニング/評価データという観点で見ると、既存のデータセットには次のような問題点がある.

- ・すべて日本国外の都市のデータであり、日本とは地勢や地物の写り方が異なる.
- ・数~10都市程度のデータであり、地域多様性が少ない、
- ・使用されている地上画素寸法が、日本の測量で一般的に 用いられるサイズと異なる.日本では、20cm が用いられるこ とが多く、10cm も用いられ、災害時は 40cm で撮影される 場合がある.

・多くが「建物」又は「道路」カテゴリのデータのみである.

そのため、国土地理院が保有し、測量用カメラで撮影された空中写真を元に、日本における測量に適した Feature Extraction 性能評価用のデータセット(以下、「GSI データセット)という。)を構築することとした.

#### 3.1 GSI データセットの仕様

GSI データセットは、地域多様性の確保の観点から、原則として国土地理院がこれまでに測量用カメラで撮影した全ての地区から均等に範囲を抽出して構築した。過去に撮影された空中写真に対応するポリゴン型の地図データは作成されていないことから、オルソ画像ではなく、空中写真の画像データをそのまま使用し、比較的歪みが少ない各空中写真の中央を中心とする範囲を切り出して元画像とした.アナログカメラで撮影された空中写真は、1200dpi 又は 1270dpi でスキャンされた画像を使用し、「大野 17]の手法により写真中心 が画像中心となるよう補正した

画像から,同様に写真の中央を中心とする範囲を切り出して元 画像とした.

| 元画像の王な仕様は次のと   | おりである.                 |
|----------------|------------------------|
| ・地区数           | 549 地区(デジタルカメラ)        |
|                | 779地区(アナログカメラ)         |
| ・1地区あたりの切り出し枚数 | 1 1 枚                  |
| ・1枚あたりの切り出し範囲  | $572 \times 572$ pixel |
| ·地上画素寸法        | 10cm~40cm              |
| (名             | 各空中写真の撮影縮尺に基づく)        |
| ・カテゴリ分類        | 道路,建物,水域等36種類          |
|                | (表1に示す)                |

| 表 1. | GSIデ | ータセッ | トのカテ | ゴリ分類 |
|------|------|------|------|------|
|      | 001/ | / -/ |      |      |

| 番号 | RGB     | カテゴリ  | 番号  | RGB     | カテゴリ    |
|----|---------|-------|-----|---------|---------|
| 2  | #7F7F7F | 舗装道路  | 22  | #FF7F00 | 果樹園     |
| 3  | #BF7F3F | 未舗装道路 | 23  | #7F0000 | 荒れ地     |
| 4  | #5F5F5F | 駐車場   | 24  | #3F3F3F | 空地      |
| 5  | #FF007F | 分離帯   | 27  | #BFBF00 | 太陽光発電   |
|    |         |       |     |         | 設備      |
| 6  | #3F0000 | 軌道    | 28  | #BF00BF | 輸送管     |
| 7  | #0000FF | 水域    | 36  | #BF7FBF | 雪覆い等    |
| 8  | #FF0000 | 堅牢建物  | 38  | #7FBFBF | プラットホーム |
| 9  | #FF00FF | 普通建物  | 39  | #FF7FBF | タンク     |
| 10 | #FF7F7F | 無壁建物  | 44  | #FFBFBF | 防波堤     |
| 11 | #7F7F00 | 被覆    | 54  | #BFFFBF | 芝地      |
| 12 | #BFBFBF | 人工斜面  | 58  | #FFBF00 | 砂礫地     |
| 13 | #007FFF | 水制    | 61  | #BFBFFF | たたき     |
| 14 | #7FBF00 | 歩道橋   | 62  | #7F3F3F | 岩がけ     |
| 15 | #007F00 | 自然植生  | 65  | #00007F | 湿地      |
| 16 | #FFFF00 | 畑     | 66  | #BF00FF | 材料置場    |
| 17 | #00FFFF | 水田    | 67  | #7FBF7F | 園庭      |
| 18 | #007F7F | 収穫後の  | 68  | #7F7FFF | 墓地      |
|    |         | 水田    |     |         |         |
| 21 | #7FFF7F | 茶畑    | 255 | #FFFFFF | 未分類     |

各地区の写真は、写真枚数を n とした場合のファイル名順で n/2(小数部分切り捨て)番目の画像を機械的に抽出した. その ため、全域が海域や森林という画像も一定数含まれる.

カテゴリは,まず道路(舗装道路,未舗装道路を合わせて 1 カテゴリとしたもの)について全データのラベル付けを完了して おり,建物,水域,その他の順で順次追加中である.

各画像のラベル付けは、1328 枚のすべてを測量士で図化経 験がある者が目視で判読及び確認することによって実施した. ラベル付けされた画像には、性能確認用の先行整備データとし て位置付け,立体視を行わずに判読・分類したカテゴリ別画像 と、精度よく性能を確認する正式データとして位置付け、すべて 立体視により判読・分類した全カテゴリ画像の2種類がある.な お,全カテゴリ画像からあるカテゴリだけを抽出して作成したカ テゴリ別画像は正式データとして位置づけられる. 図 2 に元画 像とカテゴリのラベル付けが完了した画像の例を示す. ラベル 付けは,各カテゴリに表 1 に基づく Index 番号と塗分け色を定 義して行い, 全カテゴリ画像は, RGB と Index Color の両方で, カテゴリ別画像は RGB 画像で保存した. 道路のカテゴリ別画像 は、舗装道路と未舗装道路のカテゴリの分類色をいずれも RGB=#FF0000(赤色)としている. また,図3にデジタルカメラに よる 549 地区分の元画像抽出位置の分布を示す.赤い点が抽 出された画像の位置を示しており,北海道,秋田県,長野県,



図 2. 元画像とラベル付け画像の例 (左上:元画像,右上:全カテゴリラベル付け画像,左下: 道路のカテゴリ別画像,右下:建物のカテゴリ別画像)

岐阜県の山岳部を除き、ほぼ万遍なく抽出されていることが分かる.日本最東端の南鳥島は、デジタルカメラでの撮影が行われていない.三陸沿岸と熊本県にやや集中が見られる理由は、 災害状況把握のための空中写真撮影が実施されたためである.

### 3.2 評価値の算出方法

カテゴリ別の性能評価は, F 値により行う. 複数カテゴリの性 能評価は IoU により行うことを原則とする.

# 4. Feature Extraction と性能評価の試行

### 4.1 使用したネットワーク

表現の異なる画像の相互変換に高い性能を示している pix2pix [Isola 17]と, pix2pix の Generator 部分に使用されてい る U-Net 構造の CNN の 2 種類を用いて Feature Extraction を 実施した. いずれの入力画像, 推論結果とも 256×256pixel の 画像である. 推論では, 入力画像をいったん縦横とも 256 の倍 数になるよう線形内挿法でリサンプリングし, 256×256pixel に 分割したうえでネットワークに入力し, 推論結果は分割画像をマ ージして最近隣法で元の画像サイズにリサンプリングしている. 損失関数は, pix2pix は cGAN×0.5+L1, U-Net は L1 とした.

# 4.2 トレーニングデータ

トレーニングデータは、GSI データセット構築に用いた空中写 真をあらかじめ除外し、1967年以降にカラーフィルム及びデジ



図 3. デジタルカメラ 549 地区分の抽出位置の分布

タルカメラで撮影された空中写真約 79 万枚の中から 286×286pixel のサイズで,道路,建物 2 種類のそれぞれについて先 行整備データと同じ判読方法で作成した.トレーニング時は,ラ ンダムに 256×256pixel のデータにクリッピングされる. 作成した データ数は,道路 3100 枚,建物 1700 枚である. さらに 90 度, 180 度, 270 度に回転させた画像を追加し,合計で道路 12400 枚,建物 6800 枚のトレーニングデータとした.

なお、トレーニングデータに Inria データセットの画像は一切 使用していない.

# 4.3 性能評価の試行と考察

性能評価の試行は、GSI データセットによる性能評価値と、 既存の評価用データセットによる性能評価値の傾向を比較する ことによって実施した.既存の評価用データセットには、Inria デ ータセットでトレーニング用データセットとして提供されている 5 都市分の建物データを用いた.

Feature Extraction の推論結果を図 4 に, GSI データセットと Inria データセットで算出した建物の評価値を表 2 に, GSI デー タセットによる道路の評価値を表 3 に示す. なお, 建物に関して はデータの整備途中であるため, デジタルカメラ 314 地区, ア ナログカメラ 633 地区による評価値である. また, GSI データセ ットの建物はコンクリート等の堅牢建物, 普通建物, ビニールハ ウスやカーポートのような壁の無い無壁建物, 建物以外の 4 カ テゴリ分類としているが, 建物と建物以外の 2 カテゴリの Inria データセットと仕様を揃えるため, 堅牢建物, 普通建物, 無壁建 物の 3 カテゴリの推論結果を建物 1 カテゴリとみなして評価した.

まず, pix2pixと U-Net による性能比較であるが, [Isola 17]は セマンティックセグメンテーションでは損失関数を cGAN よりも L1 とした方が良好な結果が得られるとしているように, 本試行で

|         |           | G       | SIデータセッ | ル    |        |         | Inria デー | ・タセット   |        |      |
|---------|-----------|---------|---------|------|--------|---------|----------|---------|--------|------|
|         |           | Digital | Analog  | All  | Austin | Chicago | Kitsap   | Tyrol-W | Vienna | All  |
| Pix2pix | Precision | 82.1    | 69.7    | 74.9 | 80.2   | 78.8    | 71.6     | 68.7    | 79.2   | 77.3 |
|         | Recall    | 67.4    | 44.7    | 53.0 | 45.8   | 47.7    | 56.6     | 71.2    | 43.3   | 48.0 |
|         | F値        | 74.0    | 54.5    | 62.0 | 58.3   | 59.4    | 63.2     | 69.9    | 56.0   | 59.3 |
| U-Net   | Precision | 86.6    | 74.9    | 79.5 | 83.1   | 79.4    | 75.0     | 73.9    | 79.6   | 80.8 |
|         | Recall    | 73.8    | 49.0    | 57.2 | 48.8   | 49.0    | 59.5     | 73.4    | 51.2   | 48.3 |
|         | F值        | 79.7    | 59.2    | 66.5 | 61.5   | 60.6    | 66.3     | 73.7    | 62.3   | 60.5 |

表2. 建物抽出の評価結果

<complex-block>

 五面像
 pix2pix による推論結果
 U-Net による推論結果
 GSI データセットの正解データ

 ジングロング
 ジングロング
 ジングロング
 ジングロング

 ジングロング
 ジングロング
 ジングロング
 ジングロング

 ジングロング
 ジングロング
 ジングロング
 ジングロング

 ダングロング
 ジングロング
 ジングロング
 ジングロング

 ダングロング
 ジングロング
 ジングロング
 ジングロング

 ダングロング
 ジングロング
 ジングロング
 ジングロング

 ダングロング
 ジングロング
 ジングロング
 ジングロング

 ダング
 ダングロング
 ジングロング
 ジングロング

 ダング
 ダングロング
 ジングロング
 ジングロング

 ダング
 ダングロング
 ジングロング
 ジングロング

 ダング
 ダングロング
 ジングロング
 ジングロング

 ダング
 ダング
 ジング
 ジング

 ダング
 ダング
 ジング

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

| 表 3. 道路抽出の評価結果     |           |      |      |      |  |
|--------------------|-----------|------|------|------|--|
|                    | GSIデータセット |      |      |      |  |
| Digital Analog All |           |      |      |      |  |
| Pix2pix            | Precision | 76.0 | 71.0 | 73.7 |  |
|                    | Recall    | 67.2 | 47.9 | 57.0 |  |
|                    | F值        | 71.3 | 57.2 | 64.3 |  |
| U-Net              | Precision | 82.6 | 75.9 | 79.4 |  |
|                    | Recall    | 70.7 | 53.5 | 61.6 |  |
|                    | F值        | 76.2 | 62.7 | 69.4 |  |

もすべてのケースで U-Net の評価値が高い結果が得られた.

次に,建物の推論結果における,GSI データセット(デジタル カメラ)と Inria データセットでの評価値の比較では, GSI データ セットの方の Precision がやや高く, Recall は大きく異なるという 結果が得られた. Precision がやや高いのは、参照データに既 往の地図データを用いず, すべての画像で測量技術者が判読 してラベル付けを行ったことにより、参照データの位置ズレや不 整合の量が相対的に少ないことが要因の一つと考えられる. -方, Recall の値が大きく異なるのは, トレーニングデータに日本 国内の画像しか使用していないため,日本の都市の建物形状と 大きく異なる形態, 例えば, Vienna (ウィーン) はヨーロッパによく みられる古い石造りの街並みであるし, Austin は樹木に囲まれ た住宅が点在する街並みであるなど、を呈する都市では、適切 に推論できず,抽出されなかった建物が多いためであると推測 される.この推測は、日本の建物や土地利用と似通っている Tyrol-Wの Recall の値が GSI データセットの Recall の値と大き く違わない点からも整合的である. GSI データセットと Inria デー タセットの間での評価値の傾向は一貫しており, 面積は少ない ものの多様性を重視した GSI データセットによる評価値が一定 の信頼性を有することを証明していると考える.

なお、今後の空中写真撮影でアナログカメラが使用されること は無いことから、デジタルカメラによる評価値の重要性が高いこ とを付記する.

# 5. おわりに

測量における地図作成という実業務に Feature Extraction の 導入を目指した研究に必要となる性能評価用のデータセットを 構築し、その評価結果を既存のデータセットの評価結果と比較 することで評価結果に信頼が置けるかどうかを考察した.このデ ータセットは、今後の研究における性能評価の指標として用い る予定である.

また,道路と建物が Feature Extraction の対象地物として用い られることが多いが,地図作成のためにはその他の多くの種類 の地物の Extraction にも対応しなければならない.国家測量機 関として基盤地図情報を整備・提供している国土地理院が地図 作成能力評価のためのマルチカテゴリの性能評価用データセッ トを構築,公開することの意義は少なからずあると思われ,可及 的速やかに GSI データセットの公開につなげたいと考えている. また,データセットの対象面積も順次拡大していく予定である.

### 参考文献

- [Demir 18] Ilke Demir, Krzysztof Koperski, David Lindenbaum, Guan Pang, Jing Huang, Saikat Basu, Forest Hughes, Devis Tuia, Ramesh Raskar: DeepGlobe 2018: A Challenge to Parse the Earth through Satellite Images, arXiv:1805.06561v1, 2018
- [Isola 17] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros: Image-to-Image Translation with Conditional Adversarial Networks, CVPR2017, 2017.
- [国土交通省 08] 国土交通省:作業規程の準則,国土交通省告示第 413 号, 2008.
- [Maggiori 17] Emmanuel Maggiori, Yuliya Tarabalka, Guillaume Charpiat, Pierre Alliez: Can Semantic Labeling Methods Generalize to Any City? The Inria Aerial Image Labeling Benchmark, IEEE International Symposium on Geoscience and Remote Sensing (IGARSS),2017.
- [大野 17] 大野裕幸: 空中三角測量の全自動化によるオルソ画像作成 の効率化に関する研究, 国土地理院時報 129, 国土地理院, 2017.

機械学習による杭施工時のスライム検知 Slime detection during pile construction using machine learning

有坂 壮平<sup>\*1</sup> Sohei Arisaka 玉川 悠貴<sup>\*1</sup> Yuki Tamagawa 武居 幸次郎<sup>\*1</sup> Kojiro Takesue

\*1 鹿島建設株式会社 Kajima Corporation

During pile construction, an inspection is needed to check absence of bottom slime which leads to settlement and inclination of structures. A conventional method for slime detection is dependent on individual judgement known by a sense of a hand. Therefore, there are some problems in terms of reproducibility and quantification. In order to solve these problems, we are studying a new method for slime detection using measured tension data. In this paper, we applied machine learning to judge whether slime exists or not from the tension data. Among 6 algorithms we compared, 1-dimendional Convolutional Neural Network achieved the best performance at 93% accuracy. According to this result, we verified that machine learning is effective for the slime detection.

# 1. 背景と目的

比較的規模の大きな構造物を支える杭の施工法として,場所 打ちコンクリート杭工法が広く用いられている.本工法の施工過 程で地盤を削孔する際には,孔壁が崩れないよう孔内を安定液 (泥水)で満たした状態を維持する.削孔過程で安定液中に混 入した土粒子が杭底に沈殿したものをスライム(図1)と呼んでお り,これを除去しなければ構造物の沈下や傾斜を招く恐れがあ る.そのため,スライムが除去できているか,確実に検知する必 要がある.

スライムの検知法として, 錘をロープに吊り下げ, 錘が杭底に 当たる際のロープの張力変化を手の感触で判定する方法が一 般に採用されている(写真 1,図 2)[田中 16]. この方法は人の 手の感触に頼っているため, 再現性, 定量化という点で課題が ある. そこで, 筆者らは手の動きをアクチュエータで再現し, ロー プの張力変化をロードセルで計測する, 新たなスライム検知法 (図 3)を考案し, 開発を進めている. 本報では, この方法で得ら れた張力データからスライムの有無を判定する方法として, 機械 学習の適用性を検証した結果を示す.

# 2. 対象データ

張力データの計測には、アクチュエータの先端にロードセル を取り付け、その先に錘を吊り下げたロープを取り付けた装置を 用いた. 杭底付近に錘を一旦降ろした後、アクチュエータで錘 を降下させ、錘が着底する前後のロープにかかる張力変化をロ ードセルで計測した. 降下速度は全て表 1 に示す条件となるよ うアクチュエータで制御した.

計測は同一の杭に対して連続した 10 回の降下によって得ら れる 10 波を1 計測としており、サンプリングレートは 100Hz, 1 波 あたりのサンプル点数は 180 点である. 今回利用する張力デー タは複数の工事現場で行った 120 計測, 1199 波(欠損データを 1 件除外)とする.

錘の着底時の速度条件を同一とするため,一定速度で降下 する表 1-②の範囲で錘が着底した場合を適正に計測できたも のとした.計測結果のラベルは、スライムが無い場合の「可」,有 る場合の「不可」,正しく計測できなかった場合の「再計測」の 3

連絡先:有坂壮平, 鹿島建設株式会社, 東京都調布市飛田給 2-19-1, 042-489-8259, arisakas@kajima.com 種とした.「可」と「不可」は,適正に計測できた波を,事前に行った熟練者の手による判定から分類した.「再計測」は,適正に 計測できなかった波を機械学習用データとして意図的に再現したものである.



図2 一般的なスライム検知法 図3 考案したスライム検知法

|   | 表 1         | 降下速度の制御値 |        |
|---|-------------|----------|--------|
|   | 降下距離        | 経過時間     | 降下速度   |
|   | (mm)        | (s)      | (mm/s) |
| 1 | $0 \sim 50$ | 0.0~0.5  | 0→200  |
| 2 | 50~290      | 0.5~1.7  | 200    |
| 3 | 290~300     | 1.7~1.8  | 200→0  |

「可」,「不可」,「再計測」のデータ数は 370 波, 464 波, 365 波である.「可」と「不可」の典型的な波形の例を図 4-a, b に示 す.「可」の波形は張力が急激に低下しており,「不可」の波形 は緩やかに低下している. 図 4-c は, 錘が着底した状態から計 測開始した「再計測」の例で,最初から張力が低くなっている. 図 4-d は、「可」のうち特異な波形の波を含む例である.



#### 3. 機械学習によるスライム検知

# 3.1 方法

計測値,またはそこから計算される特徴量を入力として,1波 に対して「可」、「不可」、「再計測」のラベルを出力する機械学 習モデルを構築した. アルゴリズムはロジスティック回帰(LR), サポートベクターマシン(SVM), ランダムフォレスト(RF), 勾配 ブースティング(GB), 全結合ニューラルネットワーク(MLP), 1 次元畳み込みニューラルネットワーク(1D-CNN) [Fawaz 18]の6 つを比較した.

モデルへの入力は、1次元畳み込みニューラルネットワーク については 180 点の全計測値とした. その他のアルゴリズムに ついては計測値, 差分系列, 累積和, 各種統計量, パワースペ クトル, ヒストグラム等により 159 の特徴量を作成し, 特徴量選択 ライブラリ Boruta [Kursa 10]で候補を絞った後, 交差検証内で 使用する特徴量を決定した.1次元畳み込みニューラルネットワ ークについては、学習時にガウスノイズを付加してデータ拡張を 行った.

データセットは 8:2 に分割し, 8 割を訓練データ, 2 割をテスト データとした. 各アルゴリズムのハイパーパラメータは訓練デー タ内で10分割交差検証法によって決定し、テストデータは最終 的な性能評価にのみ用いた. 前処理, 特徴量選択, データ拡 張を含むハイパーパラメータのチューニングは、全てハイパー パラメータ最適化ライブラリ Optuna によって行った. また, デー タ分割の際にはモデルの性能を適切に評価するため,同一計 測の 10 波が分割されず、ラベルの割合も均等になるよう分割し た. モデルの評価指標は正解率(Accuracy)とした.

#### 3.2 結果

各アルゴリズムの性能を表 2 に示す. Training, Validation, Test は各交差検証で作成したモデルの訓練データ,検証デー

タ, テストデータでの正解率の平均, 表中括弧内は標準偏差で ある. Test(Ensemble)は各交差検証で作成したモデルをアンサ ンブルした場合のテストデータでの正解率である.

最も性能の良かった1次元畳み込みニューラルネットワークと, 特徴量ベースの手法で最も性能の良かったサポートベクターマ シンの混同行列を図 5-a, b に示す. 括弧内は実数である.

最適化された 1 次元畳み込みニューラルネットワークの構造 を図6に示す.活性化関数はReLU, 畳み込み層のカーネルサ イズは上から3,6,6,ドロップアウト率は0.27である.

また、特徴量ベースの手法では、交差検証によって概ね 50 前後の特徴量が選択された. ランダムフォレスト, 勾配ブーステ ィングでの特徴量重要度上位 10 個を図 7-a, b に示す.

| 表2 各アルゴリズムの性能 |          |            |         |            |  |  |
|---------------|----------|------------|---------|------------|--|--|
| Algorithm     | Training | Validation | Test    | Test       |  |  |
|               |          |            |         | (Ensemble) |  |  |
| LR            | 0.941    | 0.896      | 0.847   | 0.858      |  |  |
|               | (0.008)  | (0.078)    | (0.018) |            |  |  |
| SVM           | 0.954    | 0.892      | 0.876   | 0.879      |  |  |
|               | (0.009)  | (0.071)    | (0.023) |            |  |  |
| RF            | 0.966    | 0.909      | 0.858   | 0.875      |  |  |
|               | (0.008)  | (0.078)    | (0.016) |            |  |  |
| GB            | 0.998    | 0.884      | 0.852   | 0.871      |  |  |
|               | (0.002)  | (0.080)    | (0.026) |            |  |  |
| MLP           | 0.971    | 0.874      | 0.821   | 0.858      |  |  |
|               | (0.010)  | (0.080)    | (0.047) |            |  |  |
| 1D-CNN        | 0.944    | 0.937      | 0.892   | 0.929      |  |  |
|               | (0.029)  | (0.065)    | (0.060) |            |  |  |



図5 混同行列

b. SVM





- 2 -



#### 3.3 考察

今回の検証では1次元畳み込みニューラルネットワークが最 も性能が良く、データの特徴をよく捉えることができた.また、全 結合ニューラルネットワーク、1次元畳み込みニューラルネットワ ークとも、他のモデルに比べてアンサンブルによる性能向上が 大きくなった.これは作成されたモデルに多様性があることに起 因すると思われる.本検証では原系列のみを1チャネルで入力 したが、差分系列や累積和を合わせて入力することも有効と思 われる.

表2から,全体として訓練データと検証データのスコアに大き く差があり,モデルのバリアンスが大きいことが分かる.1次元畳 み込みニューラルネットワークでは差が小さくなっているが,これ は訓練データでのスコアがデータ拡張によるノイズ込みの性能 であること,各交差検証で検証スコアが最大となるエポックを選 択していることが理由であり,学習曲線を見るとやはり過学習の 傾向があった.このことから,同様のモデルでも学習データ数を 増やすことで性能向上が期待できる.

また,検証データとテストデータでのスコアを比べると,テスト データでは一様に性能が低下している.これは検証データとテ ストデータの分布が異なるためと思われる.また,交差検証内で も他の検証セットと比較して必ずスコアが低くなるものが存在し た.ラベルで層化分割を行っているが,同一計測が分割されな いようにしているために、データが偏りやすくなっているものと考 えられる. 適切な評価、学習のため、計測現場を考慮するなど 分割方法をさらに検討すること、より多くのデータを使用すること が必要である.

図5の混同行列を見ると、1次元畳み込みニューラルネットワークは「再計測」の再現率が高い、サポートベクターマシンは「可」の再現率が高い等、モデルによって出力の傾向が異なることが分かる。全体の正解率では1次元畳み込みニューラルネットワークの性能が最も良かったが、傾向の異なる特徴量ベースのモデルをアンサンブルすることも有効であると思われる。

特徴量ベースの手法では、図 7 から分かるようにヒストグラム に基づく特徴量がよく効いている.この特徴量はある区間に入 るデータの点数を表しており、波形の形状を反映している.スラ イムが無い場合には急激に低下し、有る場合には緩やかに低 下する張力変化の様子が捉えられているものと考えられる.

#### 4. まとめと今後の展望

考案した方法で計測した張力データからスライムの有無を判定する機械学習モデルを構築し、適用性について検証した.比較した6種のアルゴリズムでは1次元畳み込みニューラルネットワークが最も性能が良く、その正解率はテストデータで約93%であった.これにより、スライム検知における機械学習の有効性が確認できた.

今後も多くの工事現場のデータを収集することで,機械学習 モデルの精度を向上させ,スライムの有無をより高精度に判定 できる方法の開発を目指す.

### 参考文献

- [田中 16] 田中 昌史: スライム処理方法とスライム量の関係, 基 礎工 2016年3月号, 総合土木研究所, 2016.
- [Fawaz 18] Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Idoumghar, Pierre-Alain Muller: Deep learning for time series classification: a review, arXiv:1809.04356, 2018.
- [Kursa 10] Miron B. Kursa, Witold R. Rudnicki: Feature Selection with the Boruta Package Journal of Statistical Software, Vol. 36, Issue 11, 2010.

深層強化学習を用いた翼形状の最適化と手法の比較 The optimization and comparison of methods for the Air foil design using Deep Reinforcement Learning.

> 服部 均<sup>\*1</sup> Hitoshi Hattori

米倉 一男<sup>\*1</sup> Kazuo Yonekura

\*1 株式会社 IHI IHI Corporation

When designing turbomachinery such as jet engines and superchargers, CAE is indispensable technology. In order to generate high performance shapes, the optimization methods such as response surface methodology and genetic algorithm has been used for design . However, these methods require many iterative calculations. When searching for a high performance shape against multiple flow conditions, it is necessary to repeat analysis every time the flow conditions are changed, which lengthens the design time. In this paper, to shorten this design time, we propose a new design method using deep reinforcement learning and compare of methods.

# 1. 諸言

航空エンジンや車両用過給機をはじめとする機械製品を設 計する場合に, CAE (Computer Aided Engineering)は欠くことの できない技術である. 設計者は CAE を用いて, 例えば翼の周り の流体の流れを数値的に解析し、その物理現象を理解して実 際に製品を作製した時の性能等を予測する. 所望の制約条件 を満たしたうえで最も性能が良い形状を作製するため、これまで は遺伝的アルゴリズム[Kalyanmoy 2005]や応答曲面法 [Raymond 2001]などを用いた最適化が行われてきた. これらの 手法は多くの繰り返し計算が必要である. 流れの境界条件や設 計変数の増加などの仕様の変更があった場合には計算をやり 直す必要があり、設計に多くの時間を要していた.本稿では、こ の設計時間を短縮するために, 深層強化学習を用いた形状最 適化を提案し,手法の比較を行うことで設計に有用な手法を選 定する. 設計作業では, 仕様変更に合わせて, 流れの条件を 少し変えて形状を検討する作業が繰り返し行われる場合がある. このような場合、多数ある条件を包絡する条件であらかじめ多数 の数値計算を実行して学習しておき,実際の設計時は学習済 みモデルを用いて検討を行なうことで、実際の設計時間を短縮 できると期待される.

### 2. Deep Q-Network

強化学習(RL; Reinforcement Learning)では、特定の環境を 与え、得られる報酬が最大になるように行動を学習する.強化 学習については[Richard 1998]が詳しい.強化学習は図1に示 すように、報酬を与える環境と、エージェントから構成される.エ ージェントが行動を起こした結果、環境側から報酬と現在の状態が出力される.このエージェントが現在の状態に応じて、最も 多くの報酬が期待される行動をとるように学習が進む.





強化学習は一般にロボット等の制御やテレビゲームに対して 使用されており,時間変化する動的な問題に対して使用される ことが多い.一方で文献[Li 2017], [Andrychowicz 2016]ではニ ューラルネットワークのハイパーパラメータの最適化などの時間 変化しない静的な問題における最適化に適用している.本報告 で扱う問題も時間変化のない静的な問題である.行動選択の方 法について様々な手法が提案されているが,本報告ではその1 つである Deep Q-network (DQN) [Volodymyr 2013]を用いる. DQN は,次式で表す行動価値関数(Q 関数)を元に行動を決 定する.さらにこの Q 関数を深層ニューラルネットワーク(DNN) でモデル化する.

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \{r_t + \gamma \max_{a \in A} Q(s_{t+1}, a) - Q(s_t, a_t)\}$$

$$(1)$$

ここで、 $\alpha(0<\alpha\leq 1)$ は学習率、 $\gamma(0<\gamma\leq 1)$ は割引率であり、A は 取り得る行動全体を表す.式(1)は第2項が行動価値の期待値 と現在の見込みの値の差を表しており、この差分だけ現在の行 動価値を更新する.Q 関数を DNN でモデル化する利点の一 つが、状態量として画像を扱えることである.

# 3. NACA 翼の揚抗比最大化

航空機の翼型に用いられる NACA 翼を対象に揚抗比の最 大化を目的とした数値実験を行い,手法ごとに性能の比較を行 った. NACA 翼は, NACA6410 のように名称の数値が形状を一 意に決めるパラメータを表す翼型である. 図 2 に NACA4 桁系 列の一例を示す. NACA4 桁系列は翼弦長で正規化された最 大キャンバ, 最大キャンバ位置, 最大翼厚の 3 つの形状パラメ ータを持つ.ここでは翼型を固定し,膨大特性である揚抗比を 最大にするように,迎角の最適化を行った.エージェントが迎角 を増減することを図1に示す行動atとした. 迎角は0度から40 度の範囲で1度単位で変化させる.また環境は翼形状と迎角を 入力として、2 次元定常非圧縮流れの CFD (Computational Fluid Dynamics)計算を行い, 圧力コンター図と揚効比を出力 するシステムとした. エージェントは, 圧力コンター図を基に迎 角の増減を決めるため、Q 関数のモデル化には CNN [Alex 2012]を使用した. 深層強化学習の実装には ChainerRL [ChainerRL 2018]を用い、CFD の計算には OpenFOAM [OpenFOAM 2018]を使用した. 境界条件は図 3 に示すように,

流入境界(青)を流速 1 m/s, 出口境界(赤)を静圧 0 Pa, 翼面 (水色)を滑り無し境界, 解析領域の上下境界(黄)を滑り境界と し, 乱流には k- $\epsilon$ モデルを用いた. また翼弦長 1 m, 流体密度 1 kg/m<sup>3</sup>とし, 流体粘度 1.0×10-5 Pa·s とした. 学習時は初期の迎 角をランダムに決定し, エージェントが 50 回迎角を変えるまで を 1 セットとし, 400 セットの学習を行った. 与える報酬として, 迎 角を変えて揚抗比が上昇すれば報酬 r<sub>t</sub>=+1, 低下すれば r<sub>t</sub>= -1 を与えた.

図 4 にある翼型における検証時の初期解から収束解への推移を示す. θ<sub>attack</sub>は迎角であり,図 4 は迎角 37degの初期条件に対し,徐々に迎角を下げて迎角 6degに収束していることを示している.図 5 は初期解と収束解の圧力コンターである.初期解では翼の前縁部で圧力が低くなり剥離が生じているが、収束解では圧力が低い領域が減少していることが確認でき、エージェントが圧力コンター上で剥離を認識すると迎角を小さくするように行動したと考えられる.

次に強化学習の手法を変えて試行回数と得られる揚抗比の 最適値との比の比較を行った. エージェントの行動が収束した 迎角における揚抗比をエージェントの探索範囲内の揚抗比の 最適値で割った値を評価値として使用した.比較対象は DQN, DoubleDON [Hado 2016], ResidualDON, [Chainer RL 2018], Dynamic Policy Programming (DPP) [ Mohamma 2012], Advantage Learning (AL) [Marc 2016], Persistent Advantage Learning (PAL) [Marc 2016], DoublePAL [Marc 2016], SARSA [Rummery 1994]である. 学習に用いた CFD 計算の回数と各手 法の評価値を図6に示す.少ないCFDの回数で安定して高い 評価値が得られる手法が望ましい. CFD 計算の回数が 2,500 回以下の場合には AL が最も高い性能を示しているが、5.000 回付近で評価値が1ポイント低下し、学習回数によって得られる 解が変わりうることがわかる. DQN は 2,500 回以降でも高い評 価値を維持していることから本例題においては最も有用な手法 であるといえる. 一般的にレトロゲームで DQN より高性能とされ る DoubleDQN は CFD の回数が 15,000 回以下の場合には 95%以下の評価値となっていることから、DQN と同程度の精度 を得るためには 20,000 回程度の CFD 計算が必要であり,本課 題には適さないことがわかった. その理由として,本例題は1変 数の最適化であり、問題が単純であったため、シンプルな学習 手法が適していた可能性が挙げられる.したがって目的関数が 多峰性である場合や設計変数が多い場合は DON 以外の手法 が有用である可能性がある.本比較により強化学習を用いて翼 形状の最適化を行う上で,選択する手法により必要な CFD の 回数に大きな差があり、本例題においては DQN が最も適して いることを確認した.この結果は今後強化学習を用いて最適化 設計を行う上で、手法選択に役立てることができる.

# 4. 結論

深層強化学習を NACA 翼の揚抗比最大化に適用し,目的に 応じてエージェントが適切に迎角を変更できることを確認した. また手法ごとに学習に必要な CFD の回数を比較し,本課題で は DQN が最も適していた.本比較により選択する手法次第で 必要な CFD の回数に大きな差があることがわかり,今後強化学 習を用いて最適化設計を行う上で,選択するべき手法の指針が 示された.



# 参考文献

[Kalyanmoy 2005] Kalyanmoy, D.: Multi-objective Optimization using Evolutionary Algorithm, John Wiley & Sons, 2005.

[Raymond 2001] Raymond, H. M.: Response Surface Methodology: process and product optimization using designed experiments, second edition, A Wiley-Interscience publication, 2001.

[Li 2017] Li, K., Malik, J. : Learning to optimize. In: ICLR 2017 conference, 2017.

[Andrychowicz 2016] Andrychowicz, M., Denil, M., Gomez, S., Hoffman, M.W., Pfau, D., Schaul, T., Shillingford, B., de Freitas, N.: Learning to learn by gradient descent by gradient descent, arXiv preprint arXiv, 1606.04474v2, 2016.

[Richard 1998]Richard S. S. and Andrew G. B.: Reinforcement Learning: An Introduction, MIT Press, 1998.

[Volodymyr 2013]Volodymyr M., Koray K., David S., Alex G., Ioannis A., Daan W., Martin R. :Playing Atari with Deep Reinforcement Learning, NIPS Deep Learning Workshop, 2013. [Alex 2012]Alex K., Ilya S. and Geoffrey E. H.: Imagenet Classification with Deep Convolutional Neural Networks, NIPS,

pp.1097–1105, 2012. [OpenFOAM 2018] OpenFOAM, <u>http://www.openfoam.org</u>, 2018/10/30.

[Chainer RL 2018] Chainer RL,

https://github.com/chainer/chainerrl, 2018/10/30.

[Marc 2016] Marc G. B., Georg O., Arthur G., Philip S. T., Remi M.: Increasing the Action Gap: New Operators for Reinforcement Learning, Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence, 2016.

[Hado 2016] Hado V. H., Arthur G., David S.: Deep Reinforcement Learning with Double Q-learning, Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence, 2016.

[Mohamma 2012] Mohammad G. A., Vicenc G., Hilbert J. K.: Dynamic Policy Programming, Journal of Machine Learning Research 13, 2012.

[Rummery 1994] Rummery, G. A., and Niranjan, M.: On-line Qlearning using Connectionist Systems, Technical Report, Cambridge University Engineering Department, 1994.

# 勾配ブースティング回帰木を用いた製造業流体シミュレーションの高速化 手法

Application of Gradient Booting regression toward the Computational Fluid Dynamics in the Manufacturing industry

> 小川 雄太郎\*1 Yutaro Ogawa

清水 琢也<sup>\*1</sup> Takuya Shimizu 横井 俊昭<sup>\*1</sup> Toshiaki Yokoi

\*1 株式会社電通国際情報サービス INFORMATION SERVICES INTERNATIONAL-DENTSU, LTD.

Abstract: A faster calculation of MPS (Moving Particle Semi-implicit) method which is a computational fluid dynamics in the Manufacturing industry is proposed. Proposed method surrogates the semi-implicit part of MPS by the Gradient boosting regression trees using 10 original features as inputs. Finally, we confirmed that the qualitative properties of the proposed method coincide with the conventional MPS method by simulations of the dam-break problem.

#### 1. はじめに

CAE (Computer Aided Engineering) とは製造業における製品および製品部品の設計時に、コンピュータ上で設計対象の to 特性や挙動をシミュレーション (数値計算)し、最適な設計条件を明らかにする技術である. CAE の例としては、製品部品の剛性を数値計算し軽くて壊れない部品設計を実現する構造最適化、製品内を流れる流体の抵抗や翼部品が持つ揚力などを所望の性能が得られる設計するための流体シミュレーションなどが挙げられる.

これら CAE 技術が共通して抱える課題のひとつはシミュレー ション時間である. 偏微分方程式を数値計算するため,高精度 にシミュレーションするためには時間方向と空間方向に分解能 が必要となり,計算時間が増大する. CAE を用いて新たなデザ インを生み出すためにはこのシミュレーションにかかる時間を短 縮し,様々な設計条件を容易に試せる計算環境を生み出すこと が重要となる.

本研究では CAE 技術のなかでも流体シミュレーションに着 目する. 近年, 流体シミュレーションの高速化という課題に向けて 機械学習を適用する研究が進みつつある. 具体的には従来の ナビエ・ストークス方程式に従う物理モデルを, 機械学習で事前 に学習させた推論モデルに代替することで CAE の高速化を目 指すものである.

例えば Guo らは、物体の周りを流れる空気の定常状態の流 速場を求める際に、ナビエ・ストークス方程式を用いた数値計算 を行うのではなく、物体形状を CNN (Convolutional Neural Network) に入力し、物体を囲む周辺領域の各座標点での流速 を回帰するセマンティックセグメンテーションを応用した手法を 提案している [GUO 2016]. また同様のスキームにより、翼の周り の流速から翼の揚力を求める手法も提案されている [ZHANG 2018]. これらの先行研究は時間発展を伴う数値計算を省略し、 製品が持つ定常状態での特徴を、物体形状を機械学習モデル に入力して1回の推論計算で求める.

また,時間発展を伴う非定常な状態での数値時間を機械学 習で代替する事例として,Fukami らは乱流の時系列変化の計 算を機械学習で代替する手法を提案している[FUKAMI 2018].



図 1. 本研究で機械学習モデルに置き換える MPS 法の CAE および各種流体シミュレーション手法における位置づけ

Fukami らの手法は計算対象領域内の各座標点における物理 量を CNN エンコーダーで圧縮し, 圧縮した特徴量を LSTM に 入力して時系列発展したdt後の特徴量を求め, 求めた特徴量 を CNN デコーダーで復元してdt後の物理量を計算する.

しかしながら、これまで機械学習を用いた流体シミュレーション 高速化手法は種々提案されているが、製造業における重要な 流体シミュレーション手法のひとつである「MPS 法 (Moving Particle Semi-implicit Method)」について、機械学習による高速 化が実現されていないという課題が存在する.

ここで, 本研究で着目する MPS 法について図 1 を参照し解 説する. 流体シミュレーションはナビエ・ストークス方程式に基づ き物理現象を数値計算するが,大きく「格子法」と「粒子法」に 計算手法が分類される. 格子法とは対象領域を格子状にメッシ ュで分割し、その格子点上の物理量を数値計算する手法である. いわゆる差分法や有限要素法であり、乱流の再現などが得意で ある.一方で、粒子法は流体を仮想粒子の集まりとして扱い、各 粒子の時間発展に伴う移動を計算する手法である. この粒子は 仮想的な流体の塊を想定しており, 流体の分子とは異なる. 粒 子法は対象流体に対して計算用のメッシュを作る必要がないの で,大変形や自由表面を伴う系,剛体と流体の連成解析系など のシミュレーションが得意である. 例えば自動車エンジンでは, 駆動時にピストンが上下運動しており, そのピストン内の燃焼ガ スを閉じ込める目的とピストンを冷却する目的でオイルを噴出さ せている、このオイルがどのように挙動し、所望の閉じ込め・冷却 動作をしているかをシミュレーションする際などに粒子法が使用 される [越塚 2014].

連絡先:小川雄太郎,株式会社電通国際情報サービス 技術 本部開発技術部,東京都港区港南 2-17-1,03-6713-607, ogawa.yutaro@isid.co.jp

本研究で着目する MPS 法は粒子法の一種である. 粒子法の 計算アルゴリズムには MPS 法と SPH 法 (Smoothed Particle Hydrodynamics Method) が存在する. SPH 法は銀河系の衝突 など宇宙物理学におけるシミュレーションのために提案された 手法であり [LUCY 1977], 近年では流体シミュレーションにも応 用されている. ただし元来圧縮性流体(速度が早い,マッハ数 0.3 以上)を取り扱うために提案された手法であったため, 非圧 縮性流体(流速がマッハ数 0.3 以下)を想定していない. そこで 非圧縮性流体を粒子法として計算するために Koshizuka らによ って MPS 法が提案された [KOSHIZUKA 1995] [越塚 2014].

MPS 法と SPH 法は流体の非圧縮性以外にも SPH 法が陽解法 (fully explicit) で計算を行うのに対して, MPS 法は半陰的解法 (semi-implicit) で計算するという違いがある. MPS 法ではナビエ・ストークス方程式の粘性項, 重力・外力項は陽解法で, 圧力勾配項は陰解法で計算する.

MPS 法は非圧縮性流体を高精度に粒子法でシミュレーション することができ、製造業の製品設計時に広く活用されている.し かしながら MPS 法の計算時間を短縮するための機械学習手法 の提案はこれまで行われていない. SPH 法においては、ランダム フォレスト回帰木を用いた機械学習手法が提案されているが [JEONG 2015], Jeong らの手法はただちに MPS 法に流用でき るものではない.

そこで本研究では製造業の流体シミュレーションで重要な MPS 法を機械学習で高速化することを目的に研究を進める. 以 下, MPS 法の計算手法の概要を説明し, その後提案する機械 学習手法を解説する. 最後に提案手法の妥当性を流体シミュレ ーションのトイプロブレムであるダム崩壊問題で検証する.

### 2. MPS法

#### 2.1 MPS 法の概要

図 2 に MPS 法の計算アルゴリズムの概要を示す.本稿では 紙面の都合上概要の解説となるため,詳細については [越塚 2014] などを参照されたい.

はじめにナビエ・ストークス方程式の粘性項,重力・外力項を, 計算ステップkでの仮想粒子(以下,粒子と呼ぶ)の速度 $u_i^k$ ,お よび粒子の位置 $r_i^k$ を用いて計算する.添え字iは粒子番号を示 す.粘性項,重力・外力項は陽解法で解き,粒子の時刻dt後の 仮速度 $u_i^*$ と仮位置 $r_i^*$ を計算する(①,②).MPS法において粘性 項( $\nabla^2 u_i$ )<sup>k</sup>の計算は,対象とする粒子iの近傍粒子の位置や速 度に対してその相対距離に応じて重みを与える重み関数

$$w(\mathbf{r}_j - \mathbf{r}_i) = \begin{cases} \left(\frac{r_e}{|\mathbf{r}_j - \mathbf{r}_i|}\right) - 1 & (|\mathbf{r}_j - \mathbf{r}_i| < r_e) \\ 0 & (|\mathbf{r}_j - \mathbf{r}_i| \ge r_e) \end{cases}$$

を使用して

$$(\nabla^2 \boldsymbol{u}_i)^k = \frac{2d}{\lambda^0 n^0} \sum_{j \neq i} (\boldsymbol{u}_j^k - \boldsymbol{u}_i^k) w(\boldsymbol{r}_j^k - \boldsymbol{r}_i^k)$$

と計算される. ここで $r_e$ は粒子の近傍とみなす影響半径、 $\nu$ は動粘性係数, dは対象としている計算領域の次元をそれぞれ示す.  $\lambda^0$ は初期状態での1粒子の影響範囲内にある近傍粒子との距離の2乗の重み平均値を示し、次式で計算される.

$$\lambda^{0} = rac{\sum_{j \neq i} |\mathbf{r}_{j}^{0} - \mathbf{r}_{i}^{0}|^{2} w(\mathbf{r}_{j}^{0} - \mathbf{r}_{i}^{0})}{\sum_{j \neq i} w(\mathbf{r}_{j}^{0} - \mathbf{r}_{i}^{0})}$$
  
 $n^{0}$ は粒子数密度の基準値であり、以下の通りに計算さ $n^{0} = \sum_{j \neq i} w(\mathbf{r}_{j}^{0} - \mathbf{r}_{i}^{0})$ 



図2MPS 法概要および本研究で機械学習に置き換えるパート

次に粒子の仮位置において圧力 $P^{k+1}$ を,流体の非圧縮性条件から導かれる陰解法形式の式  $AP^{k+1} = b$ を解いて求める(③). A, bの各要素は粒子の仮位置から代数演算で求まり,

$$a_{ij} = \begin{cases} -\frac{1}{\rho^0} \frac{2d}{\lambda^0 n^0} w(\mathbf{r}_j^* - \mathbf{r}_i^*) & (j \neq i) \\ \frac{1}{\rho^0} \frac{2d}{\lambda^0 n^0} \sum_{j \neq i} w(\mathbf{r}_j^* - \mathbf{r}_i^*) & (j = i) \\ b_i = \frac{1}{\Delta t^2} \frac{n_i^* - n_0}{n_0} \end{cases}$$

として計算される. ここで $\rho^0$ は流体の密度を示し,  $n_i^*$ は $n_i^* = \sum_{j \neq i} w(r_j^* - r_i^*)$ で計算される粒子の仮位置での粒子密度を示す. この圧力の計算式は陰解法形式であり, 陽的に計算することができない. そのためガウスの消去法や共役勾配法など, 連立一次方程式の任意の解法で解く. なお, 粒子の周囲に粒子が密に存在しない液面や飛沫の粒子の圧力 $P_i^{k+1}$ は 0 とする.

求めた圧力**P**<sup>k+1</sup>を使用してナビエ・ストークス方程式の圧力 勾配項を以下のように計算する.

$$\nabla P_i^{k+1} = \frac{d}{n^0} \sum_{j \neq i} \frac{P_j^{k+1} - \hat{P}_i^{k+1}}{|\boldsymbol{r}_j^* - \boldsymbol{r}_i^*|^2} (\boldsymbol{r}_j^* - \boldsymbol{r}_i^*) w(\boldsymbol{r}_j^* - \boldsymbol{r}_i^*)$$

ここで $\hat{P}_{i}^{k+1}$ は粒子番号iの粒子の圧力を近傍粒子との圧力差に 負圧が生まれないように補正したものである [越塚 2014]. この 圧力勾配項による速度変化を計算し(④), 仮速度と仮位置を修 正する(⑤). 以上の①から⑤の計算を繰り返すことで, 時系列発 展を求める(⑥).

#### 2.2 MPS 法の高速化における課題

MPS 法の計算の高速化において課題となるパートは、粒子の仮位置での圧力の計算(③)である.その他のパートは陽解法であり、さらに対象粒子の近傍の情報のみを利用するため、解析領域を分割して計算機を並列させ高速化が可能である(ただし区画をまたがる粒子の移動情報はやりとりする).しかしパート③は連立1次方程式を任意の解法で解いて求める陰解法の部分であり、並列計算が困難である.そのため MPS 法の高速化の課題は圧力を求める陰解法部分にある.

れる.

# 3. 勾配ブースティング回帰木を用いた MPS 法の 改良の提案

本研究では、MPS 法において圧力**P**<sup>k+1</sup>を求める陰解法部 分を機械学習の回帰モデルに置き換え、計算機が並列状態の ままで圧力の計算を可能にし、流体シミュレーションを高速化す る手法を提案する.提案手法では粒子ごとに特徴量を計算して 回帰モデルに入力し、各粒子の圧力**P**<sup>i</sup><sup>k+1</sup>を出力する.圧力計 算以外は従来のMPS 法と同様である.

提案手法の回帰モデルに使用する特徴量について解説する. 提案手法は各粒子の影響半径内にある近傍粒子の仮位置の 情報を使用して10個の特徴量を作成する.

特徴量 1 を影響半径 $r_e$ 内に存在する粒子 $N_0$ 個との距離とする. 特徴量 1 は $N_0$ 次元のベクトルであり,各要素は昇順に配置する. 特徴量 1 の $N_0$ 個の要素 $F_{1i}^i$ は次式で定義される.

$$F_{1j}^{i} = |\mathbf{r}_{j}^{*} - \mathbf{r}_{i}^{*}| \qquad (|\mathbf{r}_{j} - \mathbf{r}_{i}| < r_{e})$$

添字iは圧力を求める対象の粒子を,jはその近傍粒子を示す.

特徴量 2-5 は圧力の計算式で使用する行列*A*, *b*の要素に関 連する特徴量であり, *N*<sub>0</sub>次元のベクトルとする. 各特徴量の*N*<sub>0</sub>個 の要素は次式で定義される.

$$F_{2j}^{i} = -\frac{1}{a_{ii}\rho^{0}} \frac{2d}{\lambda^{0}n^{0}} w(\mathbf{r}_{j}^{*} - \mathbf{r}_{i}^{*})$$

$$F_{3j}^{i} = -\frac{1}{a_{ii}\rho^{0}} \frac{2d}{\lambda^{0}n^{0}} w(\mathbf{r}_{j}^{*} - \mathbf{r}_{i}^{*})n_{j}^{*}$$

$$F_{4j}^{i} = -\frac{1}{a_{ii}\rho^{0}} \frac{2d}{\lambda^{0}n^{0}} w(\mathbf{r}_{j}^{*} - \mathbf{r}_{i}^{*})n_{j}^{**}$$

$$F_{4j}^{i} = -\frac{1}{a_{ii}\rho^{0}} \frac{2d}{\lambda^{0}n^{0}} w(\mathbf{r}_{j}^{*} - \mathbf{r}_{i}^{*})n_{j}^{**}$$

$$F_{5j}^i = \frac{1}{a_{ii}\Delta t^2} \frac{n_j - n_j}{n_0}$$

ただし $n_{j}^{**}$ は粒子番号jの粒子の仮位置 $r_{j}^{*}$ での相対粒子密度であり, $n_{j}^{**} = \frac{n_{j}^{*} - n^{0}}{n^{0}}$ として計算する. 各要素の順番は特徴量 1 で 昇順にした近傍粒子jの順番に合わせる.

特徴量6,7はNo次元のベクトルであり、次式で定義される.

$$F_{6j}^{i} = n_{j}^{*}$$
  
 $F_{7j}^{i} = n_{j}^{**}$   
特徴量 8-10 はスカラーであり、次式で定義される  
 $F_{8}^{i} = \frac{1}{a_{ii}\Delta t^{2}} \frac{n_{i}^{*} - n_{0}}{n_{0}}$   
 $F_{9}^{i} = n_{i}^{*}$   
 $F_{10}^{i} = a_{ii}$ 

以上により、特徴量ベクトルの要素数は合計で、
$$(7N_0 + 3)$$
個となる.なお各特徴量において、影響半径 $r_e$ 内に存在する粒が $N_0$ 個に満たない場合は、値0を代替として特徴量の要素とする.

提案手法の枠組みにおいて回帰手法はとくに制限されないが, 本研究では勾配ブースティング回帰木を使用し,勾配ブースティング回帰木の LightGBM [KE 2017] を使用した.

# 4. ダム崩壊問題における実験と考察

#### 4.1 流体シミュレーションの条件

提案手法の妥当性を定性的に確認するために、ダム崩壊問題を対象に MPS 法および提案手法による流体シミュレーションを実施した. シミュレーション次元は d = 2, シミュレーション範囲を囲む縦横の壁の長さは1.0 [m] および0.6 [m], 水柱の大きさは縦横0.5 [m] および0.25 [m] の範囲に含む粒子と設定し

た. 水柱の位置は右端, 左端, 中央の3条件を用意した. 粒子の 直径は $l_0 = 0.01$  [m], タイムステップはdt = 0.001 [s], シミュレ ーション時間はT = 4 [s] までとした. 粒子の影響半径 $r_e$ につい ては, 粘性項で粒子径 $l_0$ の3.1倍, その他の項で2.1倍とした.

粒子を仮位置に移動させる際に、粒子径 $l_0$ の0.5 倍以下の 距離まで近づいた場合には衝突と判定し、反発率0.2の剛体衝 突処理を行った. 流体は水を想定し、密度1000 [kg/m<sup>3</sup>]、動粘性 係数 $\nu = 1.0 \times 10^{-6}$ とした. その他本稿 MPS 法の解説で省略 したパラメータの設定は次の通りである. 自由表面粒子の判定 基準には、初期整列状態の密度 $n^0$ の0.97 倍を使用した. 数値 計算の安定性を保つために、圧力の陰解法部分において用い られる緩和係数 $\mu$ t0.2 とし、圧縮率は $\alpha = 0.45 \times 10^{-9}$ とした.

#### 4.2 機械学習モデルの学習および推論条件

提案手法の学習および推論の条件を記載する. 学習には水柱の位置が右端の条件での MPS 法のシミュレーション結果を使用した. 訓練データとして時刻 0 [s] から時刻 2 [s] までの全粒子の情報を 0.01 [s] 間隔で 200スナップショット分使用した. 特徴量は $N_0 = 28$ とする 199 要素とした. 検証データは訓練データに対して 0.005 [s] だけ後ろにずらした時刻で,同じく 200スナップショット分の全粒子のデータを使用した. LightGBM の実装には [MS LightGBM] を使用した. ハイパーパラメータの設定は、ブースティングする回帰木の最大数 n\_estimators を 30000とし、その他はデフォルト設定のままとした. LightGBM の学習時に、損失計算に二乗誤差関数を使用して検証データによる early stopping を適用した. LightGBM はブースティング手法であり、設定した最大数まで回帰木を学習して訓練データに過学習するため、検証データによる early stopping が必要となる.

提案手法の定性的な動作確認のために、水柱の位置を左端 および中央にした条件で流体シミュレーションを実施し、MPS法 による結果と提案手法の結果を比較した.

#### 4.3 結果および考察

訓練データおよび検証データの行列サイズは(238237,199), および(238214, 199) となった. 流体シミュレーション中に自由粒 子と判定された粒子は圧力が 0 となり計算には使用されないた め,訓練データおよび検証行列の行数はその分減少する. LightGBM で学習させた結果,回帰木の数は 867 本で early stopping された. 学習の結果, 圧力 $P_i^{k+1}$ の決定係数は訓練デー タが 0.70、検証データが 0.52 であった. 図 3 に水柱の位置を左 端および中央にしたシミュレーション結果を示す. それぞれにお いて, 上段が MPS 法による結果を, 下段が提案手法による結果 を示す.図3上側において時刻0[s]で左端にあった水柱が, 徐々に右方向へと崩壊し水が流れていく様子が時刻 0.3 [s] で ある. MPS 法と提案手法の挙動がほぼ一致していることが分か る. さらに時刻 0.9 [s] においては右端の壁にぶつかり水がはね 返るが、こちらも挙動が一致していることが分かる.以降、水の塊 は左右の壁にぶつかることを繰り返し,時刻 3.2 [s] での左端に ぶつかったタイミングの挙動も一致している. また水柱が中央の 場合も MPS 法と提案手法で挙動がほぼ一致している.

今回の実験において, 訓練データには水柱右端条件で時刻 が 0.0 [s] から 2.0 [s] までのデータを使用したが, 時刻 2.0 [s] 以降かつ水柱の位置が違う条件でも定性的にうまく機械学習モ デルが汎化されていることが明らかとなった. 以上により, 提案手 法をダム崩壊問題でシミュレーションして, 定性的な挙動が従来 の MPS 法の結果と一致していることを確認でき, MPS 法の陰解 法による圧力計算パートを, 勾配ブースティング回帰木を用いた 機械学習モデルに代替することが可能と確認された.



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

図3提案手法と従来手法の流体シミュレーション結果の定性的比較

本研究では MPS 法において, 論理的には高速化に貢献す る手法を提案した. 今後, 実際に高速化にどの程度寄与するの か, 粒子数を変化させながらその定量的特徴を確認していく必 要がある. MPS 法の陰解法パートの計算時間は共役勾配法を 用いた場合, 粒子数の 1.5 乗に比例する. 一方で提案手法の推 論時の計算時間は粒子数の 1.0 乗に比例するため, 高精度に 計算したい場合や大規模な計算など, 粒子数が増加するに従 い提案手法の高速化が貢献すると期待される.

また本手法の精度を向上させるためには、特徴量の吟味が必要である.現在の10個の特徴量のうち寄与度の高いもののみを残すことや、さらなる特徴量の改良が考えらえる.また LightGBMのハイパーパラメータをチューニングしていないため、 パラメータチューニングによる精度向上も期待される.

本研究では定性的な挙動の確認として,流体シミュレーション のトイプロブレムであるダム崩壊問題を使用した. 今後,実際に 製造業のエンジン設計など,実ビジネスで使用する流体シミュレ ーションの条件と規模において,提案手法がどの程度定性的お よび定量的に従来手法と一致するのか確認が必要である.

また提案手法の運用方法の検討も実ビジネスへの導入に重要となる。例えば流体が水やガソリンなど異なる条件の場合に、 機械学習モデルで違いを吸収できるようにするのか,流体の種類ごとに訓練データを用意するのか検討が必要である。さらに 訓練データの作り方も検討する必要がある。なんらかのトイプロ ブレムの結果を使用するのか,それとも実際の実験条件において1度 MPS 法を実施して訓練データを作成するのかなど、実 運用に向けた導入方法を検討する必要があると考えられる。

### 5. おわりに

本研究では製造業の流体シミュレーションで重要な MPS 法の一部を勾配ブースティング回帰木による機械学習を用いたア

ルゴリズムに代替し, 流体シミュレーションを高速化する手法を 提案した. 提案手法の定性的挙動をダム崩壊問題で確認し, 提 案手法の結果が従来手法と同様の挙動を示すことを確認した.

#### 参考文献

- [GUO 2016] GUO, Xiaoxiao; LI, Wei; IORIO, Francesco. Convolutional neural networks for steady flow approximation. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016. p. 481-490.
- [ZHANG 2018] ZHANG, Yao; SUNG, Woong Je; MAVRIS, Dimitri N. Application of Convolutional Neural Network to Predict Airfoil Lift Coefficient. In: 2018 AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference. 2018. p. 1903.
- [FUKAMI 2018] FUKAMI, Kai; KAWAI, Ken; FUKAGATA, Koji. A synthetic turbulent inflow generator using machine learning. arXiv preprint arXiv:1806.08903, 2018.
- [LUCY 1977] LUCY, Leon B. A numerical approach to the testing of the fission hypothesis. The astronomical journal, 1977, 82: 1013-1024.
- [越塚 2014] 越塚誠一;柴田和也;室谷浩平. 粒子法入門. 2014.
- [KOSHIZUKA 1995] KOSHIZUKA, Seichii. A particle method for incompressible viscous flow with fluid fragmentation. Comput. Fluid Dyn. J., 1995, 4: 29.
- [JEONG 2015] JEONG, SoHyeon, et al. Data-driven fluid simulations using regression forests. ACM Transactions on Graphics (TOG), 2015, 34.6: 199.
- [KE 2017] KE, Guolin, et al. Lightgbm: A highly efficient gradient boosting decision tree. In: Advances in Neural Information Processing Systems. 2017. p. 3146-3154.
- [MS LightGBM] https://github.com/Microsoft/LightGBM

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

# [3Q4-J-13] Al application: transformation system

Chair:Masahiro Tada Reviewer:Masayuki Otani

Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room Q (6F Meeting room, Bandaijima bldg.)

# [3Q4-J-13-01] Traffic anomaly detection using ETC2.0 probe data

OAtsuki Masuda<sup>1</sup>, Masaki Matsudaira<sup>1</sup> (1. Oki Electric Industry Co,.Ltd.) 3:50 PM - 4:10 PM

[3Q4-J-13-02] Design method for high efficiency drone highway network OMasatoshi Hamanaka<sup>1</sup> (1. RIKEN) 4:10 PM - 4:30 PM

# [3Q4-J-13-03] Classification for time-sequence data appeared in shift control of automobile automatic transmission

OYusuke Morikawa<sup>1</sup>, Yasuhiro Ishihara<sup>1</sup>, Takanori Ide<sup>1</sup>, Eiji Moriyama<sup>1</sup>, Taku Akita<sup>1</sup>, Yasuo Tabei<sup>2</sup>, Takehito Utsuro<sup>3</sup>, Hiroshi Nakagawa<sup>2</sup> (1. Aisin AW Co., Ltd., 2. RIKEN, Center for Advanced Intelligence Project, 3. Fclty. Eng, Inf. &Sys, Univ. of Tsukuba) 4:30 PM - 4:50 PM

# [3Q4-J-13-04] Likelihood distribution of Pedestrian Trajectories rendered by Variational Autoencoder

OYasunori Yokojima<sup>1</sup>, Tatsuhide Sakai<sup>2</sup> (1. Siemens K.K., 2. Great Wall Motor) 4:50 PM - 5:10 PM

# ETC2.0 プローブデータを利用した交通異常検知 Traffic anomaly detection using ETC2.0 probe data

增田 淳基 Atsuki Masuda

松平 正樹 Masaki Matsudaira

沖電気工業株式会社 経営基盤本部 研究開発センター Corporate R&D Center, Corporate Infrastructure Group, Oki Electric Industry Co., Ltd.

Abstract: Detecting traffic anomalies such as accidents and obstacles on freeways is one of serious problem for traffic management. Previous researches are almost based on vehicle detectors to get traffic velocity and quantity, and therefore not able to detect the detailed location of traffic anomaly. In this paper, we present the algorithm for detecting automatically traffic anomalies using ETC2.0 probe data. Our algorithm is based on distances from head position of traffic congestion to recovered speed position, which is calculated from velocity of probe data. The result of evaluating the algorithm is very accurate, that precision is 94.3% and recall 89.2%.

#### 1. はじめに

交通異常とは、事故や路上障害物等の交通を遮断する可能 性がある事象のことを指し、平成 29 年に高速道路における交 通事故が 8,758 件、路上障害物が 34.5 万件発生している[内閣 府 18]、[国土交通省 17]. しかし、道路管理者がそれら交通異 常を認知する方法は、パトロールカーによる発見か通報によるも のがほとんどである.高速道路内の交通異常は二次的な重大 事故につながる可能性があるため、事象が発生した後に早期に 検知可能な技術開発が急務となっている.

# 2. 関連研究

従来の交通異常検知は、道路に設置された車両感知器などの定点観測機器から得られる情報を利用するものが主流であり、 交通量や交通密度などの交通状態の時間的・空間的変化から 異常検知する手法が開発されている[Jeong 11], [成岡 14], [Chung 12]. 成岡らおよび Chung らは、車両感知器が 300~ 600m に一台設置されている首都高速道路で実証を行ない、数 百メートル単位で位置の検知が可能と報告している.また、 Jeong らは、車両検知器が多数設置されている米カリフォルニア の I-880 で実証している.一方、日本国内の地方路線では車両 感知器がインター間に1つ程度しか設置されておらず、平均間



図1 プローブデータ概念図



隔が 10km 程度であるため, 検知できてもその位置の特定が困難である.

# 3. データ特性

# 3.1 ETC2.0 プローブデータ

ETC2.0 プローブデータとは, ETC2.0 対応の車載器に走行 履歴, 挙動履歴を蓄積し, 道路上に設置したアンテナによって 収集する車両走行データである. データ内には各車両の GPS で測位した位置情報や速度,加速度等が含まれている(図 1) [瀬戸下 18]. 収集したプローブデータを縦軸に時刻,横軸に起 点からの距離(KP), プロットの色に速度を対応させて図示する と図 2のようになる. NEXCO 西日本によると,高速道路におけ る渋滞の定義は「時速 40km 以下で低速走行、あるいは停止発 進を繰り返す車列が 1km 以上かつ 15 分以上継続した状態」と あり,赤色(速度≦20km/h)およびオレンジ色(20km/h<速度≦ 40km/h)のプロットが渋滞の速度に相当する[NEXCO 西日本]. 一つの点が一つのプローブデータを表し,点を結んだ線が一 台の車両の走行軌跡を表している.

#### 3.2 イベントデータ

イベントデータは、管制センターにおいて入力された事故, 路上障害物,工事,故障車,気象,交通規制などの事象に関 するデータである.事象の分類や発生時刻,発生地点(KP)な どが記録される.ただし、実際に発生した事象から、時間遅れが



図2 プローブデータ(各車両の走行履歴)





#### 図3 自然渋滞と交通異常渋滞

生じている場合がある.

#### 3.3 自然渋滞と交通異常渋滞

自然渋滞(交通集中渋滞)は、登り坂や合流地点など速度低 下が慢性的に発生する地点において、交通容量以上の交通量 が流入することにより、車両が停滞するために発生する. 渋滞の 原因となる場所が固定され、渋滞の先頭位置は変化しないこと から、速度低下は交通量の上昇とともに徐々に進行方向に対し て後方に伝播し、渋滞が伸びることになる.

一方,交通異常渋滞は,発生要因が事故や路上障害物などの事象発生にある.事象による走行車線の封鎖もしくは,交通 規制の影響によって車線が一部遮断され,通行可能な交通量 が大きく低下する

図 3に自然渋滞と交通異常渋滞が両方発生した渋滞図を示 す. なお, 図では, 時間・空間を 100m×1 分単位のメッシュに 区切り, メッシュ内に含まれるプローブデータの平均速度を算出 したデータを可視化している. 図の上部右側が交通異常渋滞で あり, 9:02 に 477.00KP で事故, 9:18 から 10:03 まで 477.00KP から 477.80KP にかけて車線規制(追越車線)が記録されている. 一方, 図の下部中央が自然渋滞である.

### 4. モデル化と学習

自然渋滞と交通異常渋滞では、渋滞先頭の速度変化パターンに違いが見られる。また、自然渋滞においても、「サグ部」と呼ばれる登り坂、インターチェンジやジャンクションなどの合流部、トンネル入口、インターチェンジ出口において発生することが知られており、それぞれ速度変化パターンに違いがあると考えら



図5 ガンマ分布によるモデル化

れる. さらに,登り坂でも勾配や距離,大型車の混入率によって も違いがあるだろう.しかしながら,それらの違いを変数としてモ デル化・学習するには,プローブデータが充分な量とは言い難 い.したがって,今回は自然渋滞を統合してモデル化することと した.

#### 4.1 速度回復距離

速度変化パターンの指標として, 渋滞速度回復距離を利用した. これは低速車列の先頭付近において, 低速状態から高速状態になるまでに要する距離のことである. 一例として, 図 3の自然渋滞と交通異常渋滞での速度変化を図 4に示す. 距離の算出は, 100m メッシュの速度を線形補完し, 渋滞の定義速度である 40km/h の地点と速度が回復したと考えられる 55km/h の地点までの距離とした.

#### 4.2 ガンマ分布によるモデル化

交通異常を検知するため、自然渋滞における渋滞速度回復 距離を用いて、距離に応じた発生確率をモデル化する.イベン トデータが記録されておらず、同じ地点(KP)で複数の日に発 生した一連の渋滞における各時刻の渋滞速度回復距離の頻度 分布は図 5のようになる.距離が正の値をとり、分布が左右非対 称であるという特徴から、確率モデルにガンマ分布を用いた.ガ ンマ分布の確率密度関数は以下の式(1)に示す通りである.ここ で、*s*が形状パラメータ、*r*がスケールパラメータであり、ともに正 の値をとる.頻度分布から、両方のパラメータについて、最小二 乗法により最も近似する解を学習する.





$$P(x) = \frac{r^s}{\Gamma(s)} x^{s \cdot 1} e^{-rx} \qquad \cdots (1)$$

#### 4.3 交通異常検知

各時刻に取得したプローブデータに対して, 渋滞が発生して いる場合に, 過去数分の渋滞速度回復距離を算出し, 学習し た自然渋滞の分布の累積確率から, 同時生起確率を算出する. 同時生起確率が正規分布の 3 σ に相当する累積確率 (0.135%)未満の場合に, 交通異常と判定することとする. なお, なるべく遅延なく検知するため, 過去 2 分の渋滞速度回復距離 を使用する.

#### 5. 検証実験

本アルゴリズムを R 言語で実装し, ETC2.0 プローブデータと イベントデータの実データを用いて, 検証実験を行なった.

#### 5.1 実験データ

今回利用したデータは、NEXCO 西日本から提供いただいた 関西地区における複数路線のプローブデータとイベントデータ である.路線は、中国自動車道、名神高速道路、近畿自動車道 であり、2018年3月10日~3月26日、および、交通量が多い 特異日として2018年8月10日~8月15日(お盆期間)のデ ータ計48日分を検証に用いた.

#### 5.2 実験手法

検知位置については、管制センターでの入力を正解値として 異常発生位置から±500m以内の範囲を検知できるかどうかの 精度を計算することとした.精度の指標は検知技術に対して一 般的に使われている Precision/Recall を用いた. Precision は 交通異常と判定したものに対する正解率(=正解した個数/交 通異常と判定した個数),Recall は発生した交通異常の中でど れだけ検知できたかという検知率(=正解した個数/検知対象 である交通異常の個数)を表す.検知結果が上記誤差範囲内 かどうかによって Precision/Recall を算出する.

また、検知時刻については、管制センターの入力であるイベントデータと比較を行った.イベントデータは、通報やパトロールカーによる発見に基づいており、図 6のように実際に何らかの交通異常により交通状態が変化している時刻よりも遅れて入力されていることがある.これと比べて早期検知できるかどうかを検証した.

# 5.3 検証結果

検知位置に関する精度結果を表 1に示す. Precision が 94.3%, Recall が 89.2%と, ともに高水準の結果が得られた. 検知例を図 7 (a)~(c)に示す. (a)の正解例では, イベントデ



図6 イベントデータの時刻遅れ

#### 表1 異常検知精度評価

|      |        |       | 真の結果  |           |
|------|--------|-------|-------|-----------|
|      |        | 交通異常  | 非交通異常 | Precision |
|      | 交通異常   | 33    | 2     | 94.3%     |
| 予測結果 | 非検知    | 4     | —     | -         |
|      | Recall | 89.2% | —     | _         |

ータによる交通異常発生箇所の+100m を検知しており,時間 に関しても手入力よりも 1 分早く検知することができた.(b)は交 通異常に関する事象が発生しているが非検知であった 4 件の 内の一つを示している.このデータは,図では交通異常発生地 点は一か所になっているが,同じ KP,同じ時刻において故障 車と路上障害物の事象がイベントデータに含まれている.複数 の交通異常が重なり,急加速ができなく,渋滞速度回復距離が 長くなったため検知できなかったと考えられる.(c)はイベントデ ータが存在しない位置に対して交通異常判定をした例である. 検知地点付近の速度は 40km/h から 55km/h ~ 100m ほどの距 離で加速しており,交通異常と似た傾向が表れている.また,同 じ KP で他の時間帯を見ても,検知付近の交通状態が特異で ある点から,交通異常はあったがイベントデータに記録されてい ない可能性も考えられる.

検知時刻に関しては、イベントデータの入力時刻と異常検知 時刻の時間差を評価した.両者の時間差をボックスプロットで表 したものを図 8に示す.縦軸は時間差を表しており、マイナスが ETC2.0 プローブデータを利用した方式による早期検知を意味 している.結果から、中央値が0となり、半数が早期検知可能で あった.一方で、大幅に検知遅れとなる場合もいくつか存在した. これは、ETC2.0 プローブデータに異常値が含まれていたため、 渋滞速度回復距離が正しく算出できないことに起因している. 今後、データに含まれる異常値のクレンジングや手法の頑健性 も重要な課題である.

#### 5.4 まとめ

高速道路内の異常を早期発見したいという社会課題と従来 技術での高精度な位置特定が困難であるという課題に対して, ETC2.0 プローブデータを利用して渋滞先頭における渋滞速度 回復距離により交通異常を検知するアルゴリズムを開発した. 検知位置による精度評価では良好な結果を得ており,本方式 が有効であることを示した.

今後,自然渋滞の原因を含めたモデル学習・検知手法の開発や,渋滞を伴わない交通異常を検知する方式の開発に取り 組む予定である.

#### 謝辞

本研究において, NEXCO 西日本様より ETC2.0 プローブデ ータおよびイベントデータを提供いただいた. ここに感謝の意を 表す.

# 参考文献

[内閣府 18] 内閣府: 平成 30 年交通安全白書,

http://www8.cao.go.jp/koutu/taisaku/h30kou\_haku/zenbun/genkyo/h 1/h1b1s1\_2.html. [国土交通省 17] 国土交通省:高速道路会社の落下物処理件数(平成 29年度),

http://www.mlit.go.jp/road/sisaku/ijikanri/pdf/h29rakkabutu\_nexco.p df.

- [NEXCO 西日本] NEXCO 西日本: 渋滞原因解説, https://www.w-nexco.co.jp/forecast/trafficjam comment/.
- [Chung 98] Chung, E., and Kuwahara M.: Comparative study of freeway incident detection algorithms, ARRB TRANSPORT RESEARCH LTD CONFERENCE, 19TH, 1998.
- [Jeong 11] Jeong, Y.S., et al.: A wavelet-based freeway incident detection algorithm with adapting threshold parameters, Transportation Research Part C: Emerging Technologies 19.1, 2011.
- [成岡 14] 成岡尚哉, et al.: ノンパラメトリック手法による車両感知器デー タからの突発的ボトルネック検出法, 交通工学論文集 1.1, 2014.
- [瀬戸下 18] 瀬戸下伸介, et al.: ETC2.0 プローブ情報の収集と活用,国総研レポート 2018, 2018.



図8 イベントデータと検知時刻の時間差



(a) 正解例 (中国自動車道下り 2018 年 8 月 10 日)



(b) 検知漏れ例 (中国自動車道下り 2018 年 3 月 16 日)



(c) 誤検知例 (中国自動車道下り 2018 年 8 月 11 日)

図7 検知結果

高効率なドローンハイウェイ網の設計手法 Design method for high efficiency drone highway network

> 浜中 雅俊<sup>\*1</sup> Masatoshi Hamanaka

\*1 理化学研究所 RIKEN

Abstract: This paper describes the design method for drone highway network to eliminate the risk of conflict between Drones and make it fly with high efficiency. Many flight path designing methods have been proposed, however a designing method for drone highway network that raises the overall flight efficiency has not been proposed. We optimize each path using ant colony optimization and optimize the position of the terminal connecting the paths using particle swarm optimization. Experimental results show that the proposed method improves flight efficiency.

# 1. はじめに

マルチロータ型のドローンは狭いスペースを飛行・着陸できる特 長がある. 我々はマルチロータ型のドローンを山岳地帯への物 資の供給に利用することを期待している. しかし, ドローンで山 岳地帯へ物資を供給するためには以下の3つの問題がある.

#### ● GPS ロスト

従来のドローンでは GPS(グローバル・ポジショニング・システム)により位置検出が行われていたが、ビルの谷間や山岳地帯では、衛星からの GPS 信号の遮蔽や反射が生じ、正確な位置が求まらない場合があった.また、GPS 信号は微弱で、妨害で受信困難となる場合があった[Kerns 2014, Urbina 2016].

我々は、衛星 3 次元地形図を用いて、ディープラーニングに 基づき[LeCun 2015, Amari 2018], GPS 信号が受信できない 場合でもドローンの飛行エリアを推定することを可能とする手 法を提案し、群馬県昭和村で行った実証実験では 98.4%の 精度でエリア推定が可能なことを確認した [Hamanaka 2018].

#### ● 衝突リスクの増大

上空を多くのドローンが飛行するようになると、衝突の危険性 が増加し、高速で飛行させることが困難になることが予想され る. たとえば2台のドローンが空中で交差する場合には、道路 交通法と同じように交差する地点に左側から進入してくるドロ ーンが優先され、右側から進入してくるドローンはホバリングし ながら待つ必要があるが、ホバリング中もドローンはエネルギ ーを消費し続けている.

そこで我々は、ドローンハイウェイ網の提案を行ってきた [浜 中 2016].

#### ● 低いエネルギー効率

マルチロータ型ドローンは、ローター回転により自重を支える 必要がありエネルギー効率が悪い.特に山岳地帯を飛行する 場合には、山を越えるために機体を大きく上昇させる必要が あるが、上昇には非常に大きなエネルギーを必要とする。

上記のドローンハイウェイ網においては、蟻コロニー最適化法 (ACO)および粒子群最適化法(PSO)を組み合わせ、エネル ギー効率の高い経路となるよう最適設計手法を提案していた. しかし、最適化には大きな計算コストがかかるために、十分に 最適化された経路を作成することはできなかった.

本稿では、ACOの計算を GPGPU 上で実現することで大規模 なシミュレーションを実現した結果について報告する.以下,2 節では関連研究について検討し,3節では提案手法の概要に ついて述べる,そして4章では ACO5章では PSO について説 明し,6章で実験結果について述べ,7章でまとめる.

### 2. 関連研究

ドローンの飛行経路の作成法は様々提案されている. Li らは ACOを用いて 2 地点間の経路の最適化を行うことを試みた [Li 2018]. ACO は収束に時間がかかることから, Bhatt らは高速に 収束する Sniff-Dog アルゴリズムを提案した [Ashish 2018]. Shi らは、飛行経路を作成する問題を制約充足問題として定式化し, 動的グラフ上で衝突のない最短経路を求めた [Shi 2018]. これ らの研究は、出発点から到着点までの 1 つの経路を最適化しよ うとするものである [Li 2008; Bhatt 2018; Shi 2018].

一方, Balachandran らの研究[Balachandran 2018]や Galea ら の研究 [Galea 2018]は、複数のドローンを管制することを前提と している点で我々の考え方に近い. Balachandran らは、交差点 に接近する無数のドローンの中から選定された1機のドローン が周辺のすべてのドローンの運行スケジュールを計算し、その スケジュールの情報をすべてのドローンが同期する手法を提案 した.一方, Garea らはボロノイ線図を用いて経路網を作成する 方法を提案した.しかしこれらの研究では、経路網全体を効率 化するというアイディアは提案されていなかった.

我々は、ACOと PSO を組み合わせたアルゴリズムにより経路 網全体の飛行効率を向上させることを目指す.

### 3. ドローンハイウェイ網の最適化

本節では、ドローンを高速に高エネルギー効率でより遠くまで飛行させることを可能とするドローンハイウェイ網を構築するための手法の概要について述べる.

図1は京都市付近の地図で、上から下に伸びる濃い色(緑) の帯は滋賀県と京都府の県境にある山である.このときドローン ハイウェイ網として図1のような格子状のハイウェイ網を採用し た場合、様々な方向に飛行することが可能な点は優れているが、 経路が山の山頂付近を通っているため山を越えるために大きな エネルギーを必要とするため効率が悪くなるという問題が生じる.

ドローンが高速・高エネルギー効率で飛行するためには,1) 距離が短いこと,2)高度変化が少ないこと,3)直進性が高いこと が重要である.これらを同時に成立させるような経路を探索する 手法として本研究では ACO と PSO という2 つの手法を導入す る.

a)

b)

c)

d)



図1: ドローンハイウェイ網の例

# 3.1 ACO (蟻コロニー最適化)

ACOを用いて、選択した1つのターミナルに接続されている 各経路の最適化を行う. ACO は、フェロモンを使って蟻が効率 的に巣から餌場まで移動しているしくみを確率モデルで表した ものである. 蟻は、巣であるコロニーから餌を取りに出かけるが、 餌を見つけるとその一部を持ち帰るが、その際にフェロモンを出 しながら帰る. そして、餌を探しに行く蟻はフェロモンを見つける と、その先にある餌を求めてその経路を移動し、帰りにフェロモ ンを強化していく.フェロモンは、時間と共に蒸発するため、より 適した経路が選択される.

# 3.2 PSO (粒子群最適化)

PSO を用いて, 選択したターミナルの位置の最適化を行う. PSO は, 魚群において一匹が良い経路を見つけると, 残りの群 れがそれに倣うしくみをモデル化したものである. 多次元空間に おいて, 最適解を求めようとするとき, 位置と速度を持つ粒子群 が動き回る. このとき, 最も良い値となっている粒子の位置が全 体に通知され, また, ローカルなベストな位置にある粒子が近傍 に通知される.

# 3.3 ドローンハイウェイ網最適化アルゴリズム

ACOと PSO を組み合わせた手法により飛行経路網を最適化 する. アルゴリズムは以下の通りである(図 2).

- a) ドローンハイウェイ網の交点(ターミナル)を 1 つランダム で選ぶ. そのターミナルをコロニーとし,周囲のターミナ ルに餌を置く(図 2a).
- b) ACO により各コロニーから餌までの最適経路を求め, それ らの平均移動コストを算出する.
- c) 様々な位置にコロニーを置き PSO を用いて, 最も平均移 動コストが最少となるコロニー位置を求める.
- d) a から c までを 1 ステップとして、ステップを繰りかすことで ドローンハイウェイ網全体を最適化する.

# 4. ACO (蟻コロニー最適化)

ACO は、巡回セールスマン問題の最適解の近似値を効率的に 求める方法として知られている。巡回セールスマン問題は、す べての都市を1回ずつ巡回し、出発した都市に戻ってくる経路 のうち、巡回の総コスト(時間や距離)が最少のものを求める組 み合わせ最適問題であり、都市数の増加により計算量が急速 に増加する NP 困難問題である.



図 2: ドローンハイウェイ網最適化アルゴリズム

陸上において、スタート地点とゴール地点が決まっており、 その間の経路を求める問題は、多くの場合 DP マッチングが使 用できるため Viterbi アルゴリズムにより効率的に最適経路が探 索できる。しかし、マルチロータ型ドローンの三次元的な経路の 場合、飛行距離や時間だけでなく高度の変化やカーブ(曲率) によっても電費が変わってくるため、DP マッチングで解くことが 難しい問題である.そこで、ACOを用いてこの問題を解く.

ACO において蟻が,上下左右前後の 6 方向の移動のうちどちらに移動するかは, 6 方向のフェロモンの値を用いて  $\epsilon$  - greedy 法で決定する.

曲率は,現在蟻がいる地点と,5ステップ前に蟻がいた地点, 5ステップ後に蟻がいる地点で作られる三角形の外接円の半径 の逆数である.

すべての蟻がゴールに到達するか,あるいは,探索打ち切り ステップ数を超えると,蟻が通った経路にフェロモンを足し合わ せてフェロモンの更新を行う. 蟻による探索時間を短縮するた め,以下を行った.

● フェロモン初期値の設定

フェロモンの初期値は、スタート地点から垂直上昇し、最高地 点に到達したら水平移動してゴールまでのユークリッド距離が 最少となるような経路に設定した。このように設定するとフェロ モンの初期値をランダムとしたのと比べて極めて早く収束する。 最終的な収束結果はほぼ同じとなることを確認している。

#### ● 方向別のフェロモン

蟻がフェロモンを頼りにスタート地点に逆流する現象を防ぐた めに上下左右前後の 6 方向それぞれ方向別にフェロモンを 記録し反映するようにした.

● 探索打ち切り

壁が近くにあると蟻の動きに制限が加わるため、壁に沿ってフ ェロモン濃度が高くなることがある. ゴールから非常に離れた 場所を探索する蟻がいると探索に時間がかかるため、スタート からゴールまでの最短距離の二乗までで探索を打ち切ること にした.

●ゴール上空での探索打ち切り

ゴール付近には到達するが、なかなかゴールに至らない蟻が 増えると、ゴール周辺のフェロモンが増加し、ますますゴール 付近で停滞する蟻が増加するため、ゴールの上空に到達した 蟻は自動的に降下するようにした.

● GPGPUでの並列処理

ACO は, 蟻の数が少ないと収束までの試行回数が増大する. 逆に蟻の数を増やすと, 少ない試行回数で収束するが, 一回 あたりの試行時間が増大する. そこで, ACO の計算を蟻ごと に並列で GPGPU 上で行う. すると, フェロモンの更新の計算 以外は並列で行うことができるため高速化される.

# 5. PSO (粒子群最適化)

PSO は魚や鳥の群れなど,動物の群れの行動を参考にして作られた確率的最適化手法である.全探索が困難あるいは長い計算時間がかかる問題において,解の候補である粒子を解空間に多数配置し,各粒子どうしが相互作用により高精度な近似解を発見する手法である.具体的には,各粒子がそれまでに各自が発見した最も良い解候補の位置(ローカルベスト)を記憶し,かつ各粒子が持つローカルベストの中で最も良い候補の位置をグローバルベストとして全体が共有しており,粒子がその方向に移動することで最適化を行う.

PSO は進化的計算手法の 1 つに含まれるが, GA などと比べて収束性が良い.しかし, 解候補の評価を繰り返すため, 会候補の評価に時間のかかる処理の場合には高速化が難しい.

PSO の評価値は、コロニーから周囲の 6 つの餌までの ACO の コストの平均値である. ACO は収束に時間がかかるために、さ らなる高速化が必要である. 高速化のために、以下を行った.

評価値の記録

ー度ある粒子が評価値を求めた場所を別の粒子が再度評価 値を求める場合がある.コロニーを置く箇所は有限であるため, コロニー位置の探索をはじめてから最初に求めた評価値を記 録し,同じ場所にコロニーが再度来た場合には記録した評価 値を用いることで高速化する.

#### 並列計算

コロニーからは、周囲の 6 つの餌に対して経路を ACO で求める. このときこの 6 つの計算を並列で行うことで高速化する.

#### 6. 実験結果

ACO および PSO を組み合わせたドローンハイウェイ網構築手 法を用いてシミュレーション実験を行う.

#### 6.1 実験エリア

本節では,以前実験を実施した群馬県昭和村の北緯 36.6217から 36.619900まで,東経 139.1090から 139.111240 の 200メートル四方のエリア内で,スタート地点とゴール地点を ランダムで選択しその間の適切な経路を求めることとする.図 3 は,200メートル四方のエリアに LiDAR(SICK 社 LD-MRS)を 搭載したドローン(DJI 社 Matrice600)を10回飛行させ,その結 果を平均して作った 3次元地形図で,解像度は1メートルであ る.最も深いところと高いところで 90メートル程度の高度差があ り,高度を考慮して最適な経路できているか検討するのにふさ わしいエリアと考えられる.この 200メートル四方の範囲を蟻は 餌があるゴール地点を探索して進む.蟻は1ステップで上下左 右前後に1メートル進むものとする.



#### 6.2 ACO の実験結果

飛行経路の距離を x メートル,高度の差を y メートル,経路 の平均曲率を z としたとき、最少化すべきコスト関数をとして次 式を定義する. a, b, c は定数でそれぞれ、0.08, 0.8, 0.01 とした. f = ax + by + cz (1)

ACO では、多くのハイパーパラメータがあるが、本節は以下のように設定した.

- 蟻の個体数 MAX ANTS 8192
- フェロモン更新の定数 Q3

- フェロモンの依存度に関する定数 ALPHA 1.4
- フェロモン蒸発の定数 RHO 0.5
- フェロモン初期値 IP 0
- 最大探索数 MAX STEP 30,000
- 施行回数 MAX TIME 100
- 距離に対する重み a 0.08
- 高度差に対する重み b0.8
- 曲率に対する重み c 0.01

蟻の個体数 MAX\_ANTS は、多いほど並列度が高まり高速 に収束するようになるが、多すぎるとメモリ不足などにより不安定 になる場合がある。8192 は、GPU を用いた場合において我々 の環境で安定して動作する上限である。フェロモン更新の定数 Q は、スタートからゴールまでの距離に応じて変化させる必要が あるが、今回の場合 3 が適切であった。行動選択のランダム性 EPSILON は、0.05 のとき 5%の確率でランダムに行動する。

探索の結果, 最少コストは減少しており, 最適化が進んでいることが確認できた(図 4). 図 5 は, 白い x がスタート地点, 赤い x がゴール地点として ACO を行った結果である. ヒートマップはフェロモンの量, 白線が最短経路である. 試行 10 回目(図 5a)では, まだ蛇行している部分があり最適化が十分進んでいないが, 100 回目(図 5b)では最適化が進んでいる.

計算速度を比較したところ, 100 回の試行で CPU(Mac mini Corei7-8700B 3.2G/4.6GHz 6 コア 12 スレッド)で 1 時間 21 分 30 秒, GPGPU(Nvidia GTX1080)で 82.3 秒であった.





#### 6.3 PSO の実験結果

図 6 は PSO の結果求められたドローンハイウェイ網の一部で ある. 白の x がスタート地点、赤の x がゴール地点、白い線が 最適化された経路である. スタート地点とゴール地点が同じくら いの高さの場合,高低差を避けるように最適化が行われている. 実験エリアは窪地のためスタート地点とゴール地点に高低差が ある場合は,最初に高度を取って(初期フェロモンに沿った)直 線的な経路となった.

# 7. おわりに

高効率で飛行可能なドローンハイウェイ網の設計手法を提案した.今後実機を飛行させ飛行効率の検証を行う.

### 謝辞

本研究の一部は, JSPS 科研費 17K19972 の助成を受けたものです.



#### 参考文献

- [Kerns 2014] A. J. Kerns et al, "Unmanned Aircraft Capture and Control Via GPS Spoofing," Journal of Field Robotics, Vol. 31, Issue 4, pp. 617–636, 2014.
- [Urbina 2016] D. I. Urbina et al, "Limiting the Impact of Stealthy Attacks on Industrial Control Systems," Proc. of the 2016 ACM SIGSAC, pp. 1092–1105, 2016.
- [LeCun 2015] Y. LeCun et al, "Deep Learning," Nature, Vol. 521, Issue 7553, pp. 436–444, 2015.
- [Amari 2018] S. Amari et al, "Dynamics of Learning in MLP: Natural Gradient and Singularity Revisited," Neural Comput, Vol. 30, Issue 1, pp. 1–33, 2018.
- [Hamanaka 2018] M. Hamanaka, "Deep Learning-based Area Estimation for Unmanned Aircraft Systems using 3D Map," Proceedings of 2018 International Conference on Unmanned Aircraft Systems (ICUAS2018), pp. 416–423, 2018.
- [Hamanaka 2016] M. Hamanaka and H. Shiomi, "Optimum Design Method for Drone Flight Route Network, Proceedings of the 78th national convention of IPSJ, 1B-04, 2016 (in Japanese).
- [Li 2018] Z. Li et al, "Preliminary Research on Remote Planning Methods for Paths of Unmanned Aerial Vehicles in the Safe Aerial Corridor," Proc. of ICUAS2018, pp. 1288–1294, 2018.
- [Bhatt 2018] A. Bhatt et al, "Path Planning for UAV using Sniff-Dog-Algorithm," Proc. of ICUAS2018, pp. 692–701, 2018.
- [Shi 2018] Z. Shi and W. K. Ng, "A Collision-Free Path Planning Algorithm for Unmanned Aerial Vehicle Delivery," Proc. of ICUAS2018, pp. 358–362, 2018.
- [Balachandran 2018] S. Balachandran et al, "Distributed Consensus to Enable Merging and Spacing of UAS in an Urban Environment," Proc. of ICUAS2018, pp. 670–675, 2018.
- [Galea 2018] M. Galea et al, "Design of a Multi-Layer UAV Path Planner for Cluttered Environments," Proc. of ICUAS2018, pp. 914– 923, 2018.

# 自動車用自動変速機の変速制御時に現れる時系列データの分類

Classification for time-sequence data appeared in shift control of automobile automatic transmission

田部井靖生\*2 森川祐介\*1 石原靖弘\*1 井手貴節 \*1 森山英二\*1 秋田拓\*1 Eiji Moriyama Yusuke Morikawa Yasuhiro Ishihara Takanori Ide Taku Akita Yasuo Tabei 宇津呂武仁\*3 中川裕志\*2 Takehito Utsuro Hiroshi Nakagawa \*1アイシン・エィ・ダブリュ(株)

Aisin AW Co., Ltd.

\*2理化学研究所 革新知能統合研究センター RIKEN, Center for Advanced Intelligence Project

\*3筑波大学システム情報系 Fclty. Eng, Inf. & Sys, Univ. of Tsukuba

The automatic transmission is a transmission that automatically changes gear according to an optimal gear step decided based on driver's accelerator/brake operation, vehicle speed, etc. Since the quality of a changing gear of automatic transmission, we call shift feeling, has a great influence on riding comfort of the automobile, the parameters of control program are adjusted to improve the shift feeling at the development site. We call this adjustment work calibration. In the process of calibration, there is a process of identifying occurring phenomena in the time-sequence data and selecting the cause and countermeasures. Because this task takes large man-hours, it is very efficient if this task becomes automatic. Therefore, at the first step, in order to automate identification of the occurring phenomena, we built classifier of the time-sequence data using SVM. The experimental result suggests that the proposed identification system is promising directions for actually used identification system.

#### 1. はじめに

オートマチック車における自動変速機はユーザのアクセル 操作やブレーキ操作、自動車の車速などの走行状態に応じて最 適なギヤ段を決定し、自動的に変速を行う変速機である.ユー ザの操作通りに変速するマニュアル変速機では変速時の空走感 やショックは許容されるが、自動変速機はユーザの操作とは異 なるタイミングで変速するために変速時のわずかな空走感や ショックでも不快と感じる傾向がある.自動変速機の変速の質 (変速フィーリングという) は自動車の乗り心地に大きな影響 を与えており、開発現場では変速の質を高めるために自動変速 の制御プログラムのパラメータ調整に大きな工数をかけてい る. 技術者が判断した変速フィーリングが良くなるようにパラ メータを調整することを適合と呼ぶ.

適合では以下の Step 1.~Step 4. を実施している.

Step 1. 自動変速機を自動車や評価機に搭載して動作させ, 動作時の制御・物理データを時系列データとして取得する.

Step 2. 変速フィーリングに問題がある場合,時系列デー タを確認し,生じている問題の種類(=現象)を特定する.

Step 3. 特定した現象に対して想定される要因や対策の候 補をいくつか抽出する.

Step 4. Step 3. の候補の中から,発生した現象の要因と 対策を特定して制御プログラムのパラメータを調整する.

この一連の工程のうち Step 4. の要因と対策の特定には経験 が必要であり, 誤った要因と対策を選んでしまうと手戻りが発 生する. そのため自動的に熟練者の判断に近い要因と対策を提 示できれば、手戻りを未然に防止できる可能性が高くなり工数 低減が見込める.また同時に,経験の少ない技術者が熟練技術

連絡先: 森川祐介, アイシン・エィ・ダブリュ(株), 〒 444-1192 愛知県安城市藤井町高根 10, i37710\_morikawa@aisinaw.co.jp

者の知見を得ることができるため,技術者の育成に繋がること も期待できる.

要因と対策の提示のためにはまず現象の特定が必要である ため、本研究では時系列データで発生した現象の特定を現象の 分類問題として考え自動分類を行う.過去の研究 [1][2] では特 徴量ベースで時系列データの分類を行っているが、本研究では サンプリングした時系列データそのものを入力としてサポート ベクターマシン(SVM)および K 近傍法(KNN)を用いて 分類する方法を検討した.



図 1: 自動変速機からの取得データと本研究のイメージ

#### 扱う時系列データ 2.

適合時に取得した時系列データのうち,変速フィーリングに 問題があるものを対象とする. 時系列データに含まれる信号の うち回転数,加速度など7種類を用いた.時系列データは発



図 2: 前処理の流れ

生した現象のラベルを持ち,1つのデータが複数のラベルを持 つこともある.本来現象ラベルは複数の技術者により付けられ ているが,人によるばらつきを抑えるために1人の熟練技術 者が特別に再度ラベル付けを行ったデータを用いた.

データベースに保存されている時系列データは長さ2秒,値 の保存間隔は5ミリ秒,データ点数は400点である.検証の ため,アクセルを踏み込みながら高速ギヤ段に変速するアップ シフトのみを対象とする.時系列データは約300個あり,全 24 現象あるうちの数が多い順に7現象を対象とする.7現象 に該当するデータ数は平均で44.6個,最大で86個,最小で 16個である.

現象には、変速時にクラッチが勢いよく係合し、ショックが 生じる現象などが含まれる.

# 3. 現象分類システムの構成

構築した現象分類システムの構成について説明する.現象 分類システムは前処理部と分類器に分かれており,実データに 適用するためには特に前処理部が重要となる.

#### 3.1 前処理部

図2に前処理の流れを示した.時系列データの7信号それ ぞれに対し前処理を行う.各前処理を順に説明する.

Step1. 時系列データの補間を行う.時系列データは5ミ リ秒刻みで値が保存されているが,自動車の種類や開発フェー ズ,取得環境により値の更新間隔が異なり,階段状になってい ることがある.例えばあるデータでは5ミリ秒ごとに値が更 新されるが,別のデータでは50ミリ秒ごとに値が更新される. そのため値が更新された点のみを用いて線形補間でデータを 補間し,すべての時系列データを同じ時刻に比較出来るように する.

Step2. 時系列データの平滑化を行う.目的はノイズ除去 および線形補間で生じた不連続部の平滑化を行い,質の良い連 続値を生成することである.移動平均期間は15期間とした.

Step3. 2秒間の時系列データから実際に変速している区間を抽出する.変速は 0.5~1.5秒程度で終わり現象は変速中に発生するため,変速区間以外は現象の分類には必要ない情報であり,除外することで分類性能の向上が期待できる.

Step4. データのスケールを揃えるため,抽出した区間を 正規化する.正規化手法には z 正規化を用いた.時系列デー タ内の信号間で値のオーダーが数桁異なり,同じ信号でもデー タ間で 10 倍程度値のオーダーが異なるため,正規化は必須で ある.

Step5. 抽出した区間を自動変速機の内部状態に応じた変速 フェーズに分割する.変速フェーズは4つあり,順にクラッチ をストロークさせるフェーズ,回転変化が起きるまでのフェー ズ,回転が変化しているフェーズ,回転変化が終わり次のギヤ 段へ移行するフェーズである.現象は自動変速機内の物理現象 が原因で発生するため変速フェーズと関わりが深く,特定の変 速フェーズで特徴が出ることが多い.変速のたびにそれぞれの 変速フェーズの長さが異なるため,変速フェーズに分割するこ とで分類器の入力ベクトル内で現象の特徴が生じる位置を揃え ることができる.実際,変速フェーズに分割したことで分類性 能は大きく改善した.

Step6. 変速フェーズごとに時系列データをサンプリング し、時間長の異なるデータを同じ長さの入力ベクトルに変換す る.サンプリングは、各変速フェーズをN個の小区間に分け、 小区間内の最大値・最小値を抽出して行った.最大値・最小値 を抽出する理由は、現象の判定に重要なピークやボトムを見落 とさないようにするためである.今回はN=10とした.

以上の前処理により,時系列データを長さ 560 の入力ベク トルに変換した.4.1 節でそれぞれの前処理の効果を確認した.

#### 3.2 分類器

分類器には SVM および KNN を用いた. SVM のカーネル は線形カーネルおよび RBF カーネルを検討した. 分類は 1 対 他分類で行ったため,データの正例・負例に不均衡が生じる. 正例・負例それぞれで SVM の C パラメータに各クラスのデー タ数の逆数に比例する重みを掛け,不均衡データが学習に与え る影響を抑制した. SVM の学習および評価は 3-fold 交差検証 で行った. 正則化パラメータ C = 10<sup>-3</sup> ~10<sup>3</sup>, RBF カーネル パラメータ  $\gamma = 10^{-3} ~10^3$  を候補とし,交差検証の学習デー タを用い, 2-fold 交差検証で F 値が最もよくなるパラメータ を選択した. KNN は 3-fold 交差検証で評価し,近傍数 k は k = 1, 3, 5, 7, 9 を検討した.

#### 4. 結果と考察

線形カーネル SVM (SVM(線形)), RBF カーネル SVM (SVM(RBF)) 及び KNN を用いて 7 現象の分類を実施した.

#### 4.1 前処理の効果

SVM(線形), SVM(RBF), KNN の中で最も良好な性能を 示した SVM(RBF) において,各前処理の F 値の改善効果を 確認した(各分類器の性能については後述する).システム上 必要な処理を除いた,変速区間抽出,正規化,変速フェーズ分 割を除外した場合を検討した.改善効果は,すべての前処理を 実施した macro-F 値 (0.711)と前処理を除外した macro-F 値 の差として定義する.

変速区間抽出を外して2秒間の波形全体で正規化を行った 場合,macro-F値は0.613となった.変速区間抽出の効果は +0.098である.現象は変速中に発生するため変速区間以外は 現象とは関係のない無駄なデータであり,取り除くことで性能 が向上したのだと考えられる. 正規化を外した場合, macro-F 値は 0.129 となった. 正規 化の効果は +0.582 である. 現象ごとに交差検証の各 fold の 結果を見ると, すべて正例または負例と判定されており分類器 として機能していない状態であった. 3.1 節で述べた通り信号 間, データ間で値のオーダーが数桁異なるため, 今回対象とす る現象分類においては正規化は必須である.

変速フェーズ分割を外した場合, macro-F 値は 0.463 となった. 変速フェーズ分割の効果は +0.248 である. 前述した通り, 現象は自動変速機内部の物理現象と密接な関係があるため, 変速フェーズに分割することで入力ベクトル内で現象の特徴の位置が揃うようになる. そのため現象の分類に必要な入力が明確になり, 性能向上に繋がったと考えられる.

#### 4.2 KNN の結果

図3にkを変化させたときのF値の推移を表示した.macro F値はk=1がベスト性能,個別で見ても現象3,4はk=3が ベスト性能,その他現象はk=1がベスト性能となった.小さ いkがベスト性能となる理由は,データが入り組んでおり境 界面が引きづらいこと,正例の数が少ないことの2点だと考 えられる.以下で詳細に確認する.



図 3: k を変更した際の KNN の分類性能

#### 4.2.1 KNN ベスト性能

ベスト性能の現象 4 は正例数が 86 個と最も多く,また最後 の変速フェーズでピークが立つため特徴が分かりやすい. さら に現象 4 と似た特徴を持つ現象が存在せず,後述する現象 2, 3 と比較して境界面が引きやすいと考えられる.しかし特徴は 時系列データの一部にしか生じず入力ベクトルには現象の分類 に不要な入力が含まれており,特徴空間上でデータは入り組ん でいると考えられるため,大きな k では性能が出づらく k = 3 が最大となったと考えられる.

#### **4.2.2 KNN ワースト性能**

ワースト性能の現象 2 は正例数 39 個でデータ数が少ない. 特徴は 2,3 番目の変速フェーズにまたがって発生し,後述する 現象 3 と特徴が良く似ており技術者が見ても判別が難しい.特 徴が良く似た現象 2,3 でデータが入り組んでおり境界面が引 きづらく,大きな k では性能が出ないのだと考えられる.

#### 4.2.3 中間の性能

現象 3 は正例数 84 個で 7 現象中 2 番目に多いため,現象 2 より判定に使えるデータが多く性能も高くなっている.しかし k を大きくすると性能が落ちる傾向は変わらないことから,現象 2 との間でデータは入り組んでいると考えられる.現象 1 は正例数 16 個であるものの,似た現象が存在せず最初の変速フェーズにピークが出て特徴が分かりやすい.そのためk = 1.3ではデータ数のわりに分類性能が高くなっているが,

正例判定に学習データの半数が必要となる k = 5 以上では急 激に性能が落ちている.

以上のことから,データが入り組んでおり境界面が引きづらいこと,正例の数が少ないことの2点により*k* = 1,3 でベスト性能となったと考えられる.

#### 4.3 KNN と SVM の比較

表1に SVM と KNN の評価結果を示した. KNN の k は現 象ごとに最も F 値が良くなるものを選んだ.表に載せていな い現象も含め,すべての現象で SVM の F 値が KNN の F 値 を上回った.入力ベクトルには現象の分類に不要な入力も含ま れているため,すべての入力を等価に扱う KNN では重みの調 整で現象に関係する入力に注目できる SVM に性能が及ばない のだと考えられる.SVM(線形)の重みを確認すると,確かに 人間が現象の判別に使う付近の入力は大きな絶対値の重みとな り,それ以外は 0 に近い値となっていることが多かった.

| 項目          |           | SVM   | SVM   | KNN    |
|-------------|-----------|-------|-------|--------|
|             |           | (線形)  | (RBF) | IXININ |
|             | F-score   | 0.683 | 0.711 | 0.509  |
| 全体          | Precision | 0.588 | 0.661 | 0.608  |
| (macro)     | Recall    | 0.815 | 0.769 | 0.438  |
|             | AUC       | 0.869 | 0.876 | -      |
| □ 在 F       | F-score   | 0.476 | 0.525 | 0.419  |
|             | Precision | 0.374 | 0.439 | 0.493  |
| -5138 0     | Recall    | 0.667 | 0.667 | 0.389  |
|             | AUC       | 0.787 | 0.778 | -      |
|             | F-score   | 0.844 | 0.857 | 0.651  |
| <b>珀伯</b> 6 | Precision | 0.781 | 0.915 | 0.761  |
| -5138 0     | Recall    | 0.926 | 0.810 | 0.574  |
|             | AUC       | 0.977 | 0.942 | -      |
|             |           |       |       |        |

#### 表 1: 分類結果

#### 4.4 SVM(線形)とSVM(RBF)の比較

すべての現象で SVM(RBF) の F 値が SVM(線形) の F 値 を上回った. KNN で k = 1,3 がベスト性能となったことをふ まえると,特徴空間内ではデータ同士が複雑に入り組んだ構造 になっており,非線形な境界面を引ける RBF カーネルが良好 な分類性能を示したと考えられる.

#### 4.5 SVM(RBF)の結果

#### **4.5.1** 正例・負例を判別できる現象

SVM(RBF)のベスト性能である現象6について,図4に一 つの fold のテストデータの識別境界面からの距離の分布(左) と ROC 曲線(右)を示す.距離の分布から,正例(上側)と負 例(下側)の分布がほぼ完全に分離しており正確に判別できて いることがわかる. False Negative データは境界面に近い位 置で間違えており,性質の良い境界面を生成できている.

現象 6 では変速の終盤に入力回転数の変動という特徴が現 れ,他に似た現象が存在しない.同様に似た現象が存在しない 現象 1,4,7 についても F 値が 0.8 前後,AUC0.9 前後で精度 よく判別できていることから,これらの現象では特徴空間内 で現象ごとにデータが比較的まとまって分布していると考えら れる.現象 6 の Recall が 0.810 に留まったのは,データ数が 26 個しかなく学習データでテストデータの事例をカバーしき れないことが原因だと考えらるため,データ数を増やすことで 精度の向上が期待できる.



図 4: 現象 6: 境界面からの距離の分布と ROC 曲線

#### 4.5.2 正例・負例の判別が難しい現象

ワースト性能の現象5についても同様に,図5に識別境界面 からの距離の分布(左)とROC曲線(右)を示した.正例・負 例の分布が相手の分布の深い位置まで食い込んでおり,SVM が分類する条件を学習できなかった現象が存在していること がわかる.False Positive データを確認すると,距離1付近の データの約半数は現象2または現象3であった.また,距離 -3付近のFalse Negative データでも,近い順に10個のデー タを確認すると半数はやはり現象2または現象3であった.

現象5は現象2,3と同じように2,3番目の変速フェーズで 特徴が生じる.特徴も現象2,3と良く似ているため,今回分 類に用いた入力だけでは現象を説明する情報が足りず,特徴空 間内で重なって分布したのだと考えられる.



図 5: 現象 5: 境界面からの距離の分布と ROC 曲線

図6に現象3の識別境界面からの距離の分布を示す.現象5 同様,正例・負例の分布が重なっている.現象3の場合,False Positiveとなったデータの半数は現象2である.前に述べた通 り現象2,3は特徴が良く似ているため,現象を説明する情報 が足りず特徴空間内でデータの分布が重なってしまったのだと 考えられる.

現象2についても現象3,5と同様の結果となった.良く似た現象を持つ現象2,3,5の分類性能を実用レベルまで上げるためには、特徴空間内で各現象の分布を切り分ける軸を与えられる新しい入力の検討が必要であると考えられる.

# 5. まとめと今後の課題

我々は,自動車用自動変速機の開発効率向上のため,変速 フィーリングに問題がある時系列データに発生している現象の 分類を行う手法を検討した.7 現象中4現象は現時点で実用レ ベルに近いところまで来ており,本手法で現象の分類は可能で あると考える.しかし似た現象同士の分類精度は不十分である



図 6: 現象 3: 境界面からの距離の分布と ROC 曲線

ため,各現象を切り分けるための新しい入力の検討が必要で ある.

データ数と分類精度の関係について検討した結果を図7に示 す. この図は 311 個の時系列データから無作為に N 個を抽出 して RBF カーネル SVM で学習・評価する試行をデータ数 N ごとに 20 回行い, F 値の平均値を算出した結果である. デー タ数 N は N = 63, 78, 105, 155, 206, 233, 248, 311 とした. こ の図から, データ数の増加に伴い分類性能が向上する傾向が出 ることがわかった. 現象 1,4,6 については性能が飽和する傾向 が出ているが, 前述のとおりすでに十分な性能を得られてい るため問題はない. 分類が難しい現象 2,3,5 はデータ数を増や すことで性能が向上しており, データ数を増やすことでも分類 性能の改善が見込めることがわかったため, 学習に利用できる データを増やし分類器の改善を行っていく.



図 7: データ数と精度の関係

#### 参考文献

- B. D. Fulcher and N. S. Jones: Highly Comparative Feature-Based Time-Series Classification, IEEE Transactions on Knowkedge and Data Engineering, Vol.26, No.12, 2014.
- [2] A. Kampouraki, G. Manis, and C. Nikou: Heartbeat Time Series Classification With Support Vector Machine, IEEE Transactions on Information Technology in Biomedicine, Vol.13, No.4, 2009.

# Likelihood distribution of Pedestrian Trajectories rendered by Variational Autoencoder

| Yasunori Yokojima <sup>*1</sup> | Tatsuhide Sakai <sup>*2</sup> |
|---------------------------------|-------------------------------|
| <sup>*1</sup> Siemens K.K.      | *2 Great Wall Motor           |

We studied applicability of Variational Autoencoder (VAE) to capture stochastic nature of pedestrian moves in a public space without explicit labels. Movies for training the network were recorded in a public pedestrian street and an exhibition booth. These movies were converted to grayscale images representing observed pedestrian locations and occupied areas. VAE was trained on 90% of data and rest of data was kept for validation. The validation result showed satisfactory reconstruction performance of pedestrian distributions in video frames. We propose a novel method to render our expectation of finding a pedestrian in a crowd as 2-D images by utilizing the trained network. Images rendered by this method correspond to subjective images usually only captured in our mind.

#### 1. Introduction

Building reliable traffic system requires a realistic description of pedestrian behaviors. For example, one of challenges in advanced safety system developments is to find rare but important corner cases, which are likely to be traced back to a subtle but non-negligible pedestrian behavior.

Pedestrian behaviors in a public space are explained by logical relationships and stochastic factors. A logical relationship of pedestrian trajectories is studied for years and various types of models are proposed to analyze universal traffic phenomena. Those models include Social force model, Optimal velocity model, Car-following model, and Cellular Automaton (CA) based model.

The stochastic and statistic nature of pedestrian behaviors is likely to be influenced by individual experiences, subjective recognitions of regional trends, or expectations in mind. For example, there can be a trend to yield right side in a public space in a certain region when two pedestrians are passing each other. Although such stochasticity can be taken into account by assuming a probability distribution and parameters, is it possible to learn the probability distribution directly from pedestrian data?

In the meantime, we occasionally recognize certain patterns while we stare at pedestrians in a public crowd. This is a subjective process of building expectations to pedestrian moves. These expectations give intuitive motive for a pedestrian to decide behaviors in a crowd. To take this into account in a pedestrian modeling, is it possible to mimic this subjective process by unsupervised learning on pedestrian data?

For these backgrounds, our goal is twofold: firstly study applicability of unsupervised machine learning to capture stochastic aspect of pedestrian behaviors, and secondly render learned content as a representation of our expectations to find an individual in a crowd. In the following sections, we propose a method to learn pedestrian distribution in a public space using VAE [Kingma 2014].

#### 2. Learning pedestrian trajectories

#### 2.1 Data Preprocessing

Our focus is to train a network on pedestrian locations and occupied areas. For this purpose, training data is prepared in the following process.

Pedestrian movies are recorded at 30 FPS by a single eye camera mounted at a fixed location with a certain elevation angle to a floor of pedestrian traffic. Movies are recorded at two different locations by this setup: movies recorded at a public pedestrian street have approximately 90 second length (Street data, hereafter). Movies recorded at an exhibition booth have approximately 30 minutes length (Booth data, hereafter).

For each frame in these movies, we applied YOLO v3 [Redmon 2015] to detect pedestrians and selected middle points of lower bases of detected bounding boxes as approximated pedestrian positions. Pedestrian positions are transformed to positions in a 2-D rectangular area while keeping the aspect ratio same as the original area. The resulted view is corresponding to a perspective perpendicular to the floor. Based on these pedestrian positions we generate grayscale images with white circles represent areas occupied by pedestrians on a black rectangular background. These images are resized to 10% in size of the original images by using INTER\_AREA algorithm in OpenCV. Pixels in an image take value from 0 to 255. These images are fed as inputs to train the VAE network (Figure 3).

#### 2.2 VAE network

VAE network structure is shown in Figure 1. We assume the latent distribution to follow a Gaussian distribution [Doersch 2016]. A loss function is defined as the following form:

$$L(x) = -D_{KL}(q_{\phi}(z|x)||p(z)) + E_{q_{\phi}(z|x)}[\log p_{\theta}(x|z)]$$
(1)

, where first term represents a KL divergence regularization and second term represent a reconstruction error. As an explicit form of the reconstruction term, a mean-squared error function is chosen:

Contact: Yasunori Yokojima, Siemens K.K., Address, Phone number, yasunori.yokojima@siemens.com

$$MSE = \frac{1}{n} \sum (x - x')^2 \tag{2}$$

, where x is input data and x' is reconstructed data, and the summation runs over all n data points in x.

Once the network is trained properly, the reconstruction cost quantifies a distance between training data and an input fed to the trained network. When the input is not alike the training dataset, the reconstruction cost gives a high value. Using this reconstruction cost, we define a likelihood of x as follows:

$$f(x) = 1 - \left[\frac{\text{MSE} - \min(\text{MSE})}{\max(\text{MSE}) - \min(\text{MSE})}\right]$$
(3)

, where f(x) takes values from zero to one and higher value means a higher likelihood for a given x.



Figure 1 – VAE network overview: Input and Output layers have a same dimension as an input image. Two intermediate dimensions and latent dimension are 1000, 300 and 100, respectively. The rectified linear unit (ReLU) is used as the output activation.

#### 2.3 Training results

VAE was successfully trained on Street data and Booth data (Figure 2) and demonstrated satisfactory reconstruction performance (Figure 3). However, a rate of training loss vs



Figure 2 – **Example of loss change during a training**: Training loss (Orange) and validation loss (Blue) change during training on Street dataset for 700 epochs.

validation loss shows different trends for Street data and Booth data: the rate is about 20% for Street data, while it is about 5% for Booth data. This will be discussed in Section 3.1.

The trained VAE network recovers an original input from an incomplete input, in which some circles are removed from the original input as shown in Figure 3. In Figure 3, the reconstruction seems to be performing well considering 20% of gap between training and validation error for Street data. This can be interpreted as that the training on image pixel values is suitable for the current network and we are complementing the reconstructed image in our mind.



Figure 3 – Street Data Reconstruction by the trained network: a) Original input not exposed during the training, b) Reconstructed image by VAE, c) Modified input by removing three points from the original input, and d) Reconstruction of the modified input by VAE

# 3. Analysis

#### 3.1 Generalization capabilities

The difference in the rate of training loss vs validation loss represents a generalization capability of the trained network. First, Booth data have longer duration than Street data and a longer training data have an advantage for generalization. Second, pedestrians in Street data are constantly and randomly moving in the view. In contrast, people in Booth data sometimes stop and see at specific locations in the view. Thus, the Booth data have advantages over Street data in regard to generalization and this resulted in the smaller difference in the training and validation loss.

Although the network is not over-fitted (Figure 2), the cost function after training is highly sensitive to similarity of an input data to the training dataset. If a training input is slightly shifted before reconstruction by the trained network, the network tends to recover the original input by canceling out the amount of shift. In other words, the VAE network learned the pedestrian distribution specific to the training dataset and it tries to interpret any input by learned patterns.

This generalization capability will be improved by preparing larger dataset and data augmentation.



Figure 4 - Likelihood distribution over 2-D area: images are ordered in time sequence from left to right. Color shows likelihood of finding an individual in this area.

#### 3.2 Likelihood distribution on expected trajectories

When an input x is fed to the trained VAE and reconstructed, likelihood of x can be estimated by f(x). To estimate expectation to find an individual within a crowd, first one specific circle in a frame is selected and removed to create a base input  $x_0$ . Then, we put a new circle on  $x_0$  to generate a new test input  $x_1$ . By evaluating  $f(x_1)$ , one can estimate a likelihood of  $x_1$ , which is a quantified expectation to find the removed individual at the position where the new circle is placed.

By repeating this process while moving a new circle over the area of  $x_0$ , one can estimate a likelihood distribution over 2-D area. Images generated via this procedure are presented in Figure 4. These images can be seen as our expectation for a pedestrian location when other pedestrians are distributed as  $x_0$ 

By processing multiple frames in sequence, one can estimate an expected trajectory of an individual based on observations (Figure 4).

In the process described above, only one circle is removed and the likelihood distribution is estimated. The same process is applicable when removing a cluster of circles to generate  $x_0$  and putting a new area, which is not necessary to be a circle, to create  $x_1$ . In this case, the resulted 2-D likelihood distribution means our expectation to find a cluster of people around the area instead of an individual. This can be regarded as our 'softfocused' expectation over a crowd.

# 4. Conclusion

In the present study, we discussed unsupervised training of VAE on pedestrian traffic data. Since our focus was training the network only by pedestrian positions and occupied areas in a public space, movies for training are preprocessed to generate input images representing only these features. As a result, the training was made computationally less intensive and VAE network was successfully trained with relatively small amount of data.

The trained VAE captures features of a pedestrian distribution in a frame and it is utilized to render our expectation to the trajectory of an individual in a crowd. Images rendered by this method correspond to subjective images usually only captured in our mind.

Our goal is to capture stochastic aspect of pedestrian behaviors in a crowd by machine learning. In the present study, outcomes of our first attempts to embody this concept are reported. Further analysis is required to achieve an appropriate level of a generalization capability. In addition, the current method is based only on an instantaneous pedestrian distribution, and does not take into account temporal correlations. Deep neural network based models are applied to predict pedestrian trajectories, and prediction performance of various architecture is compared in a recent study [Becker 2018]. These are areas to extend the present study.

#### References

- [Yokojima 2018] Yasunori Yokojima, and Toshihiko Nakazawa, Applying deep learning to test design process in hydraulic systems design 深層学習を応用した油圧システム設計に おけるテスト設計プロセス. Journal of the Japan Fluid Power System Society 49, 71-74, 2018
- [Sakai 2019] Sakai and Yokojima, Development of Deep Learning technology for a pedestrian trajectory study without requiring explicit labeling, Annual Congress(Spring), JSAE, 2019.
- [Kingma 2014] Diederik P. Kingma and Max Welling, Auto-Encoding Variational Bayes, arXiv:1312.6114v10, 2014.
- [Doersch 2016] Carl Doersch, Tutorial on Variational Autoencoders, arXiv:1606.05908v2, 2016.
- [Mochihashi 2017] Daichi Mochihashi, "Variational Bayesian methods for Natural Language Processing", ATR SLC. 2005-6-21. http://chasen.org/~daiti-m/paper/vb-nlptutorial.pdf, accessed 2019-01-24.
- [kenmatsu4 2017] kenmatsu4, "Variational Autoencoder 徹底 説 ". Qiita, 2017-8-1, https://giita.com/kenmatsu4/items/b029d697e9995d93aa24, accessed 2019-01-24.
- [Nitta 2016] Kazuki Nitta, "Variational Autoencoder", www.SlideShare.net, 2016-11-11, https://www.slideshare.net/KazukiNitta/variationalautoencoder-68705109, accessed 2019-01-24.
- [Tatsuno 2016] Sho Tatsuno, "猫でもわかる Variational Autoencoder". www.SlideShare.net, 2016-7-29. https://www.slideshare.net/ssusere55c63/variationalautoencoder-64515581, accessed 2019-01-24.
- [Nozawa 2016] Kento NOZAWA, "Variational Auto Encoder", Green Black White. Red and 2016-12-1. https://nzw0301.github.io/notes/vae.pdf, accessed 2019-01-24.
- [fchollet 2018] fchollet, "Deep Learning for humans", GitHub, 2018-11-1, https://github.com/keras-team/keras, accessed 2019-01-24.
- [taehoonlee 2018] taehoonlee, "variational autoencoder.py", GitHub. 2018-11-1. https://github.com/kerasteam/keras/blob/master/examples/variational autoencoder.py, accessed 2019-01-24.
- [Chollet 2019] Francois Chollet, "Building Autoencoders in Keras", The Keras Blog, 2016-5-14, https://blog.keras.io/building-autoencoders-in-keras.html, accessed 2019-01-24.

- [qqwweee 2018] qqwweee, "A Keras implementation of YOLOv3 (Tensorflow backend)", GitHub, 2018-11-1, https://github.com/qqwweee/keras-yolo3, accessed 2019-01-24.
- [iss-f 2018] iss-f, "VAE を keras で実装", Qiita, 2018-2-12, https://qiita.com/iss-f/items/c43b23815fc6d15ae22e, accessed 2019-01-24.
- [Redmon 2015] Joseph Chet Redmon, "YOLO: Real-Time Object Detection", Darknet Neural Network framework, 2015, https://pjreddie.com/darknet/yolo/, accessed 2019-01-24.
- [Redmon 2013] Joseph Redmon, "Convolutional Neural Networks http://pjreddie.com/darknet/", GitHub, 2013-11-3, https://github.com/pjreddie/darknet/, accessed 2019-01-24.
- [Kathuria 2018] Ayoosh Kathuria, "A PyTorch implementation of the YOLO v3 object detection algorithm", GitHub, 2018-2-25, https://github.com/ayooshkathuria/pytorch-yolo-v3/, accessed 2019-01-24.
- [Bergstra 2012] James Bergstra: Random Search for Hyper-Parameter Optimization, Journal of Machine Learning Research 13, 2012.
- [Patterson 2017] Josh Patterson: Deep Learning A Practitioner's Approach, O'Reilly Media, p.1-403, 2017.
- [Sugomori 2017] Yusuke Sugomori: Deep Learning: Practical Neural Networks with Java, Packt Publishing, 2017.
- [Sugomori 2016] Yusuke Sugomori: Deep Learning Java programming, Packt publishing, 2016.
- [Henrik 2017] Henrik B.: Machine Learning, Impress corporation, 2017.
- [Fujita 2016] K. Fujita, A.Takahara: 実装ディープラーニング, Ohmsha, 2016.
- [Saito 2016] Y. Saito: Deep Learning–Python, O'Reilly Japan, 2016.
- [Becker 2018] Stefan Becker, Ronny Hug, Wolfgang H"ubner and Michael Arens, Notes on the TrajNet Benchmark, arXiv:1805.07663v6, 2018.
- [Newell 2002] G.F.Newell, A simplified car-following theory: a lower order model, Transportation Research Part B: Methodological, 36, 2002.
- [Sakai 2018] Tatsuhide Sakai: An Automatic Search to EV design variables using Reinforcement Learning, EVS31 Kobe Japan, 2018.

Organized Session | Organized Session | [OS] OS-4

| [3D3-OS-4a] 自律・創発・汎用 AIアーキテクチャ<br>栗原 聡 (慶應義塾大学)、川村 秀憲(北海道大学)、津田一郎(中部大<br>Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room D (301B Medium meeting   | <b>ァ (1)</b><br>学)、大倉 和博(広島大学)<br>room)  |
|---|--|
| [3D3-OS-4a-01] Story Association Mediated by Individ<br>OTaisuke Akimoto <sup>1</sup> (1. Kyushu Institute of Tech<br>1:50 PM - 2:10 PM   | lual and General Concepts  |
| [3D3-OS-4a-02] How "intelligence" is called as "intellig<br>OMasayuki Yoshinobu <sup>1</sup> (1. Freelance)<br>2:10 PM - 2:30 PM  | gence"?  |
| [3D3-OS-4a-03] Double Articulation Analyzer with Pro<br>Discovery<br>OYasuaki Okuda <sup>1</sup> , Ryo Ozaki <sup>1</sup> , Tadahiro Taniguc<br>2:30 PM - 2:50 PM   | sody for Unsupervised Word<br>hi <sup>1</sup> (1. Ritsumeikan University)                              |
| [3D3-OS-4a-04] Generating Collective Behavior of a R<br>landmark Navigation Task with Deep<br>ODaichi Morimoto <sup>1</sup> , Motoaki Hiraga <sup>1</sup> , Kazuhiro O<br>Hiroshima University, 2. Shinsyu University)<br>2:50 PM - 3:10 PM | obotic Swarm in a Two-<br>Neuroevolution<br>Dhkura <sup>1</sup> , Yoshiyuki Matsumura <sup>2</sup> (1. |

# 個別的概念と一般的概念を介したストーリーの関連付け Story Association Mediated by Individual and General Concepts

秋元 泰介 AKIMOTO Taisuke

九州工業大学大学院情報工学研究院 duata Sahaal of Commuter Saianae and Sustama Engineering Kunchu Ingtitute of Teach

Graduate School of Computer Science and Systems Engineering, Kyushu Institute of Technology

Abstract: From a cognitive system perspective, *story association* (association among stories) can be positioned as a common process underlying various cognitive activities including remembering and reusing of stories, construction of a subjective world, etc. In this paper, the author presents a basic computational theory of story association especially focusing on the role of entities, times, and places. In particular, an identical entity, time, or place appearing in multiple stories is positioned as an *individual concept*, a general level representational unit in a cognitive system. A simple implementation of story association model based on the proposed theory is also presented.

# 1. はじめに

筆者は、ストーリーを生成しながら外界と関わり合うことが人間の知能の本質であると考え、物語的な情報とその動きを中心に 据えた認知システムの研究を行っている.これまでに、世界の 表象としてのストーリーの構造や生成に関する概念レベルの理 論を提案してきた[Akimoto 18a, 18b].現在の主な課題は、それ らをもとに、計算レベルの理論・方法を作ることである.

人工知能・認知科学において、物語に関する研究には、問 題解決、状況説明、対話、コンテンツ生成、物語理解等、様々 な目的やタスクがあり得る。それに対して、認知システムの観点 から物語の認知を研究するということは、その根底をなす基本 原理を探求することを意味する。そのような立場から、本稿では、 ストーリーの「関連付け」に関する基本的な考え方とその部分的 な実装を示す。特に、個別的な存在物に対応する「個別的概念」 という要素の位置付けと働きに焦点を合わせる。

ここでストーリーの関連付けというのは、認知システムの内部 において、あるストーリーないし事物と、別のストーリーないし事 物とが結び付くことを意味する.また、それが様々な種類の情報 に基づく類似・関連性の複合的な働きによって生じることを、特 に、ストーリーの多元的関連付けと呼ぶ.認知システムにおいて、 ストーリーの関連付けは、主に以下の役割を担うと考えられる.

- あるストーリーないし事物と他のストーリーを関連付けることによって、事物の主観的な意味を形作る.
- 「今・ここ」のストーリーに、過去や未来のストーリー、あるい は別の場所のストーリーを結び付けることで、時間・空間 的な広がりのある世界を構築する。
- 新しいストーリーが生成する際に、それ以前に作られたス トーリーを、生成のための知識・素材として引き込む.
- 類似したストーリーを関連付ける仕組みは、一般的な構造 としてのスキーマを形成するための基盤になる.
- 以上を含め、様々な状況においてストーリーを想起するための基盤になる。

以下,2節で関連研究を概観した後に,3節でストーリーの多元的関連付けモデルの全体像を示し,4節で個別的概念という 要素の位置付けについて述べ,5節でそれに基づく部分的な 実装を示し,6節で今後の展望を示す.なお,本稿は[秋元 18] からの発展として位置付けられる.3節で示す全体像に大きな変更は無いが,その他の部分は新しい内容となっている.

# 2. 関連研究

ストーリーの関連付けに深く関連する問題として、人工知能・ 認知科学における記憶・想起に関する研究を概観する.

[Schank 82]は、MOP (memory organization packet)というスキ ーマ的な知識構造に基づいて、ある状況において、過去の類 似する経験(エピソード)を思い出したり、新しい経験を一般化・ 記憶したりする、発達的な記憶システムの枠組みを提示してい る. この発想は、後の事例ベース推論にもつながっている [Riesbeck 89].また、[Kolodner 83]は、[Schank 82]に示唆を得 て、E-MOP(episodic memory organization packet)という知識構 造に基づく記憶システムを実装している.

Schank らの研究が問題解決のための目的指向的な想起に 比重を置いているのに対して,想起のより一般的な性質として, 類似に基づく想起の計算モデルが提案されている.これはアナ ロジーの研究とも直接的に関連している.例えば,[Thagard 90] は,意味的類似,構造的類似,目的・用途的類似の3種類の制 約充足に基づく想起モデル ARCS を提案している.[Forbus 94] は,表面的な類似に基づく選択と,構造的な類似に基づく選択 の二段階処理による想起モデル MAC/FAC を提案している.

本研究が焦点を合わせるのは、想起そのものではなく、その 土台となる構造や仕組みであるが、上記のような研究も参考に している.まず、ストーリーの関連付けが、様々な類似の複合的 な働きから生じると考える.この点は[Thagard 90]や[Forbus 94] に近い.一方、[Thagard 90; Forbus 94]は記憶間の比較あるい は制約充足的な計算を通して記憶を選択するような仕組みにな っているが、本研究では、システム内にストーリーを組織化する 働きをする心的要素が形成され、それを通してストーリーどうし が自ずと関連付けられるという考え方をする.この点は[Schank 82]に近い.加えて、ネットワーク状の記憶組織における意味や 想起等の現象を扱う活性伝播(spreading activation)[Collins 75; Anderson 83]の考え方(ネットワーク上のある要素の活性度が近 隣の要素に減衰しながら伝播・拡散していくような仕組み)も取り 入れる.

それから,認知システムへのアプローチとして見ると,本研究 は[Kokinov 94]の DUAL に比較的近いだろう. DUAL は, [Minsky 86]の『心の社会』に示唆を得て構築された,複数の小 さな表象的かつ処理的なエージェントからなる,マルチエージェ

連絡先:秋元 泰介,九州工業大学大学院情報工学研究院知 能情報工学研究系,820-8502 福岡県飯塚市川津 680-4, akimoto@ai.kyutech.ac.jp

ントシステム型の認知アーキテクチャである. それに対して本研 究の特徴は、ストーリーを中心に据えてシステム全体の構造や 動きをモデル化しようとする点にある.

#### 3. ストーリーの多元的関連付けモデルの全体像

ストーリーの多元的関連付けの仕組みの基本的な考えは次 の通りである.個々のストーリーは、ある時、ある場所における具 体的な事象ないし事物に関する情報であるが、一般的な心的 要素を共有する形で構成される.そしてこの一般的な心的要素 を介して、自ずとストーリーどうしが関連付けられる.

#### 3.1 一般的な心的要素に基づくストーリーの構成

ストーリーを構成する一般的な心的要素の分類を表1に示す (この分類は今後も継続的に拡張・修正していく必要がある).こ れらの要素及びストーリーを,情報の複合性・具体性という観点 から,図1に示すような形で,(1)ストーリー,(2)個別的概念・スキ ーマ,(3)一般的概念・感覚情報パターンという3つの層に分け る.外側ほど複合性・具体性が高くなるようになっている.なお, これらを全体として「心的世界」と呼ぶ.

#### 3.2 活性伝播による関連付け

ストーリーの関連付けを、あるストーリーまたはその部分が活 性化した際に、一般的な心的要素を介した活性伝播によって、 他のストーリーが活性化することとする.ここでは、心的要素の 活性度という概念を、主に以下の二つの意味で用いる.

- ストーリーが活性化するということは、それが参照・想起・ 生成・変化等しやすい状態になることを意味する.
- 心的世界の活性状態は、全体として、その時に経験・注 目しているストーリーまたは事物の意味を表す.

この活性伝播の局所的な模式図を図 2 に示す.ある心的要素(ノード)の活性度が一つ以上の入力活性度に基づいて決まり、さらにそれが他の要素に伝播していくというものである.

ある心的要素 y の活性度ayの計算式の基本形を,

$$a_{\mathbf{y}} = \sum_{i}^{n} O_{\mathbf{x}_{i}} w_{i} \tag{1}$$

とする. ここでnは入力側の要素数,  $O_{x_i}$ は入力側のi番目の要素  $x_i$ の出力活性度,  $w_i$ は y と $x_i$ の間の結合強度である.  $x_i$ の出力 活性度 $O_{x_i}$ は, 当該要素の活性度 $a_{x_i}$ が閾値 $\theta_{out}$ 未満の場合に 他要素への伝播を遮断する以下の式により計算する.

$$O_{\mathbf{x}_{i}} = \begin{cases} 0, & a_{\mathbf{x}_{i}} < \theta_{out} \\ a_{\mathbf{x}_{i}}, & a_{\mathbf{x}_{i}} \ge \theta_{out} \end{cases}$$
(2)

| 表1 一般的な心的要素の種 | 頖. |
|---------------|----|
|---------------|----|

| 一般的概念 |    | 単語の意味に相当する要素(例えば「犬」「社長」).     |
|-------|----|-------------------------------|
| 個別的概念 |    | 特定の存在物に対応する,固有名詞的な要素(例        |
|       |    | えば「タマ」「太郎」). 「私」(自分自身)も, 個別的概 |
|       |    | 念の一種とする.また,個別的概念の特別な下位区       |
|       |    | 分として,「時間概念」と「場所概念」を設ける.       |
|       | 時間 | ストーリー(事象)が起きる時間に対応する,言語的      |
|       | 概念 | に分節された時間範囲(例えば「平成」「明日」).      |
|       | 場所 | ストーリー(事象)が起きる場所に対応する,言語的      |
|       | 概念 | に分節された空間範囲(例えば「新宿」「自宅」).      |
| 感覚運動的 |    | 事物の具体的な心像(イメージ)を形作り, 非言語的     |
| パターン  |    | な感覚運動情報(視覚, 聴覚, 味覚, 嗅覚, 触覚,   |
|       |    | 運動)の類似の認知のもとになる要素. 例えば, 画     |
|       |    | 像認識で用いられる特徴表現を成す要素や、イメー       |
|       |    | ジスキーマの原始的要素に相当するもの.           |
| スキ    | -7 | 以上が複合的に構造化された,複数のストーリー        |
|       |    | (の部分・要素)に通じる一般的構造.            |



図1 心的要素の組織構造(心的世界の構造).



図2 活性伝播の局所的な模式図.

# 3.3 ストーリーの関連付けの全体的な流れ

3.1 節で示した構造(図 1)と3.2 節で述べた活性伝播に基づいて,次のような流れでストーリーの関連付けが生じるものと考える—i) あるストーリーが活性化する.ii) ストーリーから個別的概念・スキーマへ,さらに一般的概念・感覚運動的パターンへと活性度が伝播する.iii) 一般的概念・感覚運動的パターンへの層や,個別的概念・スキーマの層の内部で活性度が伝播する.iv) 一般的概念・感覚運動的パターンから個別的概念・スキーマへ,さらにストーリー層へと活性度が伝播する.要するに,図 1 の構造において,外側→内側(ii),層内(iii),内側→外側(iv)という流れでストーリーどうしが関連付けられるということである.

#### 4. 個別的概念の位置付け

図 1 に示した全体像における個別的概念に焦点を合わせて, その位置付けや働きについて述べる.

まず,個別的概念が特定の存在物に対応する要素であるという考えを,例を交えて説明する.ストーリーが世界の表象であるとすると,例えば「私」や友人の「三郎」は,ストーリーの中の登場人物として位置付けられる.仮に、「二年前の三郎は,坊主頭で毎日野球の練習に打ち込んでいた」と、「最近の三郎は,金髪で毎日学校をサボって私と一緒に街を徘徊している」という二つのストーリー(記憶)があるとする.このように人柄が変わっても、これらのストーリーに現れる「三郎」を同一の人物と見なされるべきであろう.このような同一性の認識を支えるのが,個別的概念である.

ある対象を以前見たものと同一であると見なすためには、類 似の認知も必要であろう.しかし、ここで述べているのは、「同一 である」という認識そのものに対応する表象が必要であり、それ は、対象と個別的概念とを結び付けることであるということである. なお、存在物を「人」や「猪」のようにカテゴリ化することは、それ を一般的概念と結び付けることとして、個別的概念の働きとは区 別することができる.

「名前」は、個別的概念の基本要素となるだろう.しかし、個別 的概念の形成は、基本的には、「一般化」に相当するものである と考える.すなわち、ある対象(事・物・者・場所・時間)が一つ以 上のストーリーの中で現れた際に、それに伴う様々な情報(心的 要素)がその個別的概念に結び付いたり離れたりして、その基 本的な性質が形作られていくということである.このような見方を すると、個別的概念とスキーマは似ている.(なお、一般化は、 帰納的ないしボトムアップ的にだけではなく、既存の構造の再 構成等によっても生じるものと考える.一般化については検討 すべき問題が多数あるが、本稿では立ち入らないことにする.)

以上の考えに基づいて、ある個別的概念と他の心的要素と の結び付きを以下のように整理する.

- 個別的概念は、それが直接的に関与するストーリーと結び付く.
- 個別的概念には、それが持つ基本的な属性として、一般的概念及び感覚運動的パターンが結び付く.
- 個別的概念どうしは、広い意味での関連性(例えば人間 関係や時間・空間的な包含・近接)によって結び付く.

これらがストーリーの関連付けを媒介することになるが,最初 のもの(ストーリーと個別的概念の結び付き)については,特に 以下のような機能を持つと考えられる.

- 世界を構成する存在物・時間・場所等をキーとしてストーリーを参照・想起するための索引となる。
- 諸々の存在物(自己・他者・物・時間・場所)に対して,個 体の記憶(ストーリー)に基づく主観的な意味を形作る.

#### 5. 簡易的な実装

以上の考えに基づいて,個別的概念と一般的概念を介して ストーリーの関連付けを行うプログラムを簡易的に実装した.実 装言語は Scala である.なお,一般的概念の方は,単語間の意 味的な類似による関連付けに関与する.スキーマ,感覚運動的 パターン,それから生成や一般化の仕組みは実装に含まれて いない.また,ストーリーの内部構造は扱わずに,単なる一ノー ドとして表現している.

#### 5.1 入力データ

入力として、複数のストーリーと個別的概念のデータが与えられる. 一つのストーリーは、固有番号、自然言語表現、任意の数の一般的概念名及び各々の重み、任意の数の個別的概念名及び各々の重みからなる. 重みの値は $0 < w \le 1$ とする. ここに記述する一般的概念と個別的概念は、原則としてストーリーに現れるものとする. なお、自然言語表現はプログラムの動作には関与しない. 図 3 に一つのストーリーの記述例を示す. 一方、一つの個別的概念のデータは、名前(固有番号付き)、任意の数の個別的概念名及び各々の重み、任意の数の一般的概念名及び各々の重み( $0 < w \le 1$ )からなる. こちらの記述例は割

愛するが、記述形式はストーリーと概ね同じである. 以上の入力データから、図4に示すような形のネットワーク構造が作られる.ストーリー(S)、個別的概念(D)、一般的概念(G)の3層からなり、要素間の結合構造は $W^{(SD)}, W^{(SG)}, W^{(DG)}, W^{(DD)}$ の4つの行列により表現される( $0 \le w \le 1$ .結合の無い部分は0).例えば $w_{13}^{(SD)}=0.3$ は、ストーリー $s_1$ と個別的概念 d3の間の結合強度が0.3であることを意味する.

# 私は物心がついた時からずっと東京の下町にある五郎の家で暮らしている。

下町 暮らす

#1

0.3 0.3

\$1:私 \$2:五郎 \$p1:東京 \$p5:五郎の家

0.5 0.4 0.4 0.5

図3 入力のストーリーデータの記述例.





加えて、一般的概念間の類似度・関連性の表現として、単語 の意味を多次元ベクトルにより表現する word2vec [Mikolov 13] の Skip-gram モデル (300 次元、ウィンドウサイズ 10, negative sampling)を用いる. 学習には『現代日本語書き言葉均衡コー パス』[国立国語学研究所 15] (出現頻度 10 以上の単語 175801 個を対象)を用いた. これによる単語ベクトル間のコサイン類似 度を、一般的概念間の結合強度と見なす.

#### 5.2 活性伝播の流れ

初期状態として,任意の一つのストーリーの活性度を1とする. その後,以下に示す 6 つの Step を指定回数反復する.なお, Step 6 は活性度に基づく想起の簡易的な実装に相当するもの であり,本稿において重要なのは Steps 1–5 である.

**Step 1** (S 層→D 層): 下式により, 各ストーリーの出力活性度 *O<sub>s</sub>*と*W*<sup>(SD)</sup>から, 各個別的概念の活性度*a*<sub>d</sub>,を計算する.

$$a_{d_j} = \sum_{i}^{|S|} O_{s_i} w_{ij}^{(SD)}$$
(3)

Step 2 (SD 層→G 層): 下式により, 各ストーリーの出力活性 度 $O_{s_i} \geq W^{(SG)}$ , 及び各個別的概念の出力活性度 $O_{d_j} \geq W^{(DG)}$ から, 各一般的概念の活性度 $a_{g_k}$ を計算する.

$$a_{g_k} = \sum_{i}^{|S|} O_{s_i} w_{ik}^{(SG)} + \sum_{j}^{|D|} O_{d_j} w_{jk}^{(DG)}$$
(4)

Step 3 (G 層→G 層): 下式により, Step 2 終了時における各一般的概念の出力活性度 $O_{g_j}$ と一般的概念間のコサイン類似度  $(sim(g_i, g_i))$ から, 各一般的概念の活性度を計算する.

$$a_{g_i} = \sum_{j}^{|G|} O_{g_j} \operatorname{sim}(g_i, g_j)$$
(5)

ここで, コサイン類似度が閾値θ<sub>sim</sub>未満の場合は, 類似度を0と 見なして活性度が伝播しないようにしている.

Step 4 (GD 層→D 層): 下式により, 各個別的概念の出力活性度 $O_{d_i} \geq W^{(DD)}$ , 及び各一般的概念の出力活性度 $O_{g_j} \geq W^{(DG)}$ から, 各個別的概念の活性度を計算する.

$$a_{d_k} = \sum_{i}^{|\mathsf{D}|} O_{d_i} w_{ik}^{(\mathsf{DD})} + \sum_{j}^{|\mathsf{G}|} O_{g_j} w_{kj}^{(\mathsf{DG})}$$
(6)

Step 5 (GD 層→S 層): 下式により, 各一般的概念の出力活性度 $O_{g_i} \geq W^{(SG)}$ , 及び各個別的概念の出力活性度 $O_{d_j} \geq W^{(SD)}$ から, 各ストーリーの活性度を計算する.

$$a_{s_k} = \sum_{i}^{|G|} O_{g_i} w_{ki}^{(SG)} + \sum_{j}^{|D|} O_{d_j} w_{kj}^{(SD)}$$
(7)

Step 6: 焦点移動. ストーリーの活性度の大きさに応じた確率 的選択により,別のストーリーに焦点を移す(そのストーリーの活 性度を 1 にし,他のストーリーの活性度を減衰する). その後 Step 1 に戻る.

なお、上記の各 Step の計算後には、活性度の値が 0 以上 1 以下の範囲におさまるように正規化を行う. すなわち、活性度の 最大値が 1 を超える場合に、最小値を 0 とみなし、当該の層の 全要素の活性度を最大値で割った値に書き換える.

#### 5.3 動作例

このプログラムの動作例を概略的に示す.入力データとして, あるエージェントの記憶の内容を想定した 10 個のストーリーと, それらに現れる 18 個の個別的概念のデータを手作業で用意し た.一般的概念は全部で 37 個である.ストーリーの内訳は,「私」 の過去・未来に関するストーリー4 個,友人の「太郎」に関するス トーリー2 個,社会的な出来事に関するストーリー2 個,フィクシ ョン2 個である.

初期状態としてストーリー#1(図3)の活性度を1とし、活性伝 播の閾値 $\theta_{out}$ と $\theta_{sim}$ は何れも 0.3 として、 プログラムを実行した. 実際の出力は各 Step における各要素の活性度のログデータで あるが,動きを直感的に把握するための可視化プログラム (Processing で実装)も用意した.これにより表現された、1 巡目 の Step 5 終了時の活性状態を図 5 に示す. 図 1 と同じような形 で,3 つの同心円上に,一般的概念,個別的概念,ストーリーに 対応するオブジェクト(円または点)が配置されている.各要素 の活性度の大きさは円・点の色の濃度・サイズにより,活性伝播 は要素間を結ぶ線の色の濃度によりそれぞれ表現される.この 例では、ストーリー#1 から、個別的概念「\$1:私」「\$2:五郎」「\$p1: 東京」等を介して、「私」の過去や未来に関するストーリー#2-4 や,社会的な出来事に関するストーリー#7(1964 年の東京オリ ンピックに関するもの)等が活性化している. 一般的概念も複数 活性化しているが、この例では、ストーリーの活性化にはあまり 関与していないようである.



図51巡目Step5終了時の活性状態.

#### 6. おわりに

本稿では、認知システムにおけるストーリーの関連付けについて、特に個別的概念を主題として検討した.結論として、個別的概念は、ストーリーに現れる個別的な存在物の同一性を支える要素であり、その基本的な性質は、一般化を通じて、他の心的要素と結び付くような形で形成される、という考えを述べた.さらに、この考えに基づいて、個別的概念と一般的概念を介したストーリーの関連付けの簡易的な実装と動作例を示した.紙幅の都合により、十分な議論や説明ができなかった部分も多くあるため、そこは今後別稿でより詳しく扱うことにしたい.特に、時間や場所については、それぞれ特別な検討が必要であろう.また、次の課題として、視覚的情報の導入や、ストーリーの内部構造の扱いについても考えていく予定である.

#### 謝辞

本研究は JSPS 科研費 JP18K18344 の助成を受けた.

#### 参考文献

- [Akimoto 18a] Akimoto, T.: Stories as mental representations of an agent's subjective world: A structural overview. *Biologically Inspired Cognitive Architectures*, 25, 107-112 (2018)
- [Akimoto 18b] Akimoto, T.: Emergentist view on generative narrative cognition: Considering principles of the self-organization of mental stories. Advances in Human-Computer Interaction: Special Issue on Language Sense and Communication on Computer, 2018, Article ID 6780564 (2018)
- [秋元 18] 秋元 泰介: 認知システムのためのストーリーの多元的関連付 けモデルの概念と部分的実装.人工知能学会ことば工学研究会(第 60 回)資料, pp. 15-25 (2018)
- [Anderson 83] Anderson, J. R.: A spreading activation theory of memory. Journal of Verbal Learning and Verbal Behavior, 22(3), 261-295 (1983)
- [Collins 75] Collins, A. M., & Loftus, E. F.: A spreading-activation theory of semantic processing. *Psychological Review*, 82(6), 407-428 (1975)
- [Forbus 94] Forbus, K. D., Gentner, D., & Law, K.: MAC/FAC: A model of similarity-based retrieval. *Cognitive Science*, 19, 141-205 (1994)
- [Kokinov 94] Kokinov, B. N.: The DUAL cognitive architecture: A hybrid multi-agent approach. Proceedings of the 11th European Conference on Artificial Intelligence, pp. 203-207 (1994)
- [国立国語学研究所 15] 国立国語学研究所コーパス開発センター: 『現 代日本語書き言葉均衡コーパス』利用の手引き第1.1版.国立国語 学研究所 (2015)
- [Kolodner 83] Kolodner, J. K.: Maintaining organization in a dynamic long-term memory. *Cognitive Science*, 7, 243-280 (1983)
- [Mikolov 13] Mikolov, T., Sutskever, I., Chen, K., Corrado, G., & Dean, J.: Distributed representations of words and phrases and their compositionality. *Proceedings of the 26th International Conference on Neural Information Processing Systems*, pp. 3111-3119 (2013)
- [Minsky 86] Minsky, M .: The Society of Mind. Simon & Schuster (1986)
- [Riesbeck 89] Riesbeck, C. K., & Schank, R. C.: Inside Case-Based Reasoning. Lawrence Erlbaum (1989)
- [Schank 82] Schank, R. C.: Dynamic Memory: A Theory of Reminding and Learning in Computers and People. Cambridge University Press (1982)
- [Thagard 90] Thagard, P., Holyoak, K. J., Nelson, G., & Gochfeld, D.: Analog retrieval by constraint satisfaction. *Artificial Intelligence*, 46, 259-310 (1990)

# 「知能」を「知能」と言うのはどうしてか How "Intelligence" is called as "Intelligence"?

吉信真之 Masayuki Yoshinobu

This paper discusses basic issues of the structure of human intelligence. As an attempt to understand it, we set up a question "How intelligence is called as intelligence?" in stead of a question "What is intelligence?" which asks its definition. To answer this, we break it down to several sub-problems as its structure, physical background and formation processes. Overviewing them, we propose a hypothesis that there is a structure in which a human as a certain area on highly complicated layers in a complex system regards the other area as intelligence.

# 1. はじめに

汎用人工知能の研究にあたり、「知能」とは何かという問いに 出会うことは多い。そして、長い間研究と歴史が行われて来たに かかわらず、「知能」について標準的な定義は存在しないとされ るが[Legg 07b]、これは知能についての解釈が多様であるという ことだけではなく、その原理の理解もまだ充分ではないからと言 える。本稿ではその理解を困難にする要因の一つとして「知能と は何か」という定義を尋ねる問それ自体にあると仮定し、問の形 式をその原理を尋ねる形式である「『知能』を『知能』というのは どうしてか」に置き換え、それをさらに副問題に分け、俯瞰するこ とで「知能」への基礎的な理解を試みる。

# 2.「知能」の定義

心理学における定義やその定義を集めた論文[Legg 07b]を 始め、様々な定義がなされているように、「知能」についておお よその範囲、共通性を持つ理解はあるものの、それらの定義は 「知能」の原理がどのようなものかを説明したものとなってはいな い。

# 3.「知能とは何か」とは何か

このように「知能」に対する理解を困難にさせている要因の一つに「知能とは何か」という問いそれ自体を挙げても良いだろう。 「知能」について様々な定義がなされているということは、「知能」 という語とそれが指し示す対象との関係も多様であること、また それぞれの定義がなされる背景には「~とは何か」という「定義 を求める問い」[Ayer 1946]が与えられていることが考えられる。

### 3.1.言語の恣意性

ソシュールは「言語の恣意性」という概念を提起した[Saussure 1910]。聴覚イメージ(シニフィアン)とそれに結び付けられる対 象イメージおよびその範囲(シニフィエ)に自然的な必然性は無 く、非自然的、歴史的・社会的・文化的なものであることを言う [丸山 1983]。したがいこれは「知能」という語においても同様の ことが言える。

### 3.2 辞書的定義

ウェクスラーは知能を「目的的に行動し、合理的に考え、そして自分の環境に効果的に対処するための個人の総合的または 全体的な能力」[Wechsler 1944]と定義している。定義は様々な 視点から分類されるが[廣松 1998]が、一つの記号に対してこれ

連絡先:吉信真之, m.yoshinobu89vn[at]gmail.com

と同義な記号ないし記号的表現をするときこれは辞書的な定義 であり、この種の定義の問題は例えば「眼科医」に対する「目医 者」のように、任意の名辞に対する同義語を見出す方法である とエイヤーは指摘している[Ayer 1946]。ウェクスラーの定義で言 えば、「知能」に対する「行動する」「考える」「効果的に対処する」 などがこれにあたるだろう。

# 4.原理をたずねる問いの設定

知りたいことは定義では無く「知能とされる原理・構造」なのだ から、人間がどのようにしてこれを分節しているかを問えばよい。 ただし、例えば「知能の原理は何か」という問いでは目的に近づ くことが出来ないので、ここでは「『知能』を『知能』と言うのはどう してか」という問を設定する。

# 5.「『知能』を『知能』と言うのはどうしてか」

この問いに答えるため、「知能」のことを「知能」と言う構造、そ の構造を成立させる物理的背景、その構造を生成するに至った プロセスの副問題に分け、それぞれについて確認し、最後に全 体を俯瞰して「知能」の原理について考察する。本稿ではおお よその輪郭をつかむことが狙いなので、広範・詳細な事項には 触れず概観するにとどめる。



図1:副問題に分解

#### 5.1 「知能」を「知能」と言う構造

ソシュールはコミュニケーションの回路として図 2 のように示した[Saussure1910]。図の円形部分は脳に相当する。

脳は近年でも新しい機能が見つかっているので、未解明な機能もあるだろうからあまり単純に捉えることは出来ないが、聴覚から発声への処理は、生理学的には例えば一次聴覚野、聴覚連合野、感覚性言語野、補足運動野、運動性言語野、一次運動野などの神経ネットワークを介して行われていると考えられている[藤木 2007]。


図2:コミュニケーションの回路([Constantin 1910]を元に改変)

#### 5.2 生成の為の物理的背景

自然の中で複雑な構造ができるしくみとして散逸構造が知られ る。散逸構造は、平衡から遠く離れた条件下にある系内に現れ る時間的空間的構造を言う [プリゴジーヌ 1997]。代表的な例と しては、雲や太陽の表面、味噌汁などに見られるベナール対流 やベロウソフ・ジャボチンスキー反応などが知られており、地球 表面も散逸構造であると考えられている[松下 97]。

また、自然界には階層構造があり[鈴木]、システム論では上 位の階層に下の階層には無い新たな性質が出現するとき、これ を創発したと言う[伊庭 98]、

#### 5.3 生成プロセス

#### (1)発生過程

個体は受精卵より発生し、分裂・分化の過程を経て最終的 には身体構造や神経ネットワークなど機能する形態へと自己 組織化する。細胞は細胞膜を通して細胞外から栄養となる分 子等を取り込み、内部で DNA を含む各分子同士の反応を連 鎖的に繰返し、不要となった成分を外へ拡散し、細胞内の成 分を一定に保つことで恒常性を維持しているが、金子のモデ ルに拠れば、分裂により多細胞化する過程で周囲の細胞と競 合して一定の状態を維持できなくなると DNA など少数の分子 のコントロールの下、細胞内部の状態を変えることで新たな安 定状態を獲得し分化を実現するという[金子 09]。

神経組織は神経軸索を投射するターゲットとなる細胞から 分泌される誘導因子の濃度勾配によりその神経軸索を伸長、 シナプス接続を行うことで神経ネットワーク構造を形成する[御 子柴 02]。

#### (2)進化過程

各個体は、環境に適応的な個体が交配し子孫を生成する。 子孫は生殖細胞を通して親から受け継いだ遺伝情報を基に 幹細胞から発生し、遺伝型としては親とわずかに異なり、表現 型としてはその可塑性により成長の過程で環境応じて変異し た個体となる。世代交代を繰返し、遺伝型の変異を蓄積し、あ るとき元の種と子孫を残せない程度に種分化した[金子 09]。 このような過程を経て、人間の場合は原始には少数細胞の単 純な振る舞いをする生物から、現在の特に大規模で複雑なネ ットワーク構成を持つ神経組織を獲得したと考えられる。

#### (3)言語進化

岡ノ谷に拠れば、前適応とは生物のある特性はその特性に よる適応を目的として進化したのではなく、他の問題のために 進化したものが流用されたものいう。言語進化に当たっては、 脳機能の言語への前適応があり、神経構築・生物学的準備の 上に文化的過程を経て言語的構造を生成した[岡ノ谷 10]。



図3:創発の階層上にある「『知能』のことを『知能』という状態」 (イメージ)

#### 6. 世界観の導出

構造、物理的背景、生成過程のそれぞれを概観すると、地球 表面には散逸構造が現れており、これが創発を重ねて生物や それらの脳、言語、ふるまいなど複雑な構造を形成・自己組織 化していると考えても良いだろう。

すると、「『知能』を『知能』と言う構造」とは、「創発を重ねて十 分に複雑化したある領域が、また別のある領域に対して『知能』 と見做している構造」と見ることができる。言い換えると、人間は ベナール対流と同様に複雑系の只中にある存在であり、「知能」 とされる構造はそこへ論理が介在した独特な構造として地表に 奇跡的に残存しているもの、という解釈ができるのではないだろ うか。

#### 7.おわりに

本稿での検討はおおよそのものであり、構造や生成過程には 他にも多くの要因が関与しているだろうが、仮にこのような構造 が「知能」の実態であるとするならば、汎用的な AI を開発するに あたり、遠回りなようだが、前述の構造・生成過程のうち必要な 部分を抽出・利用して「人間が知能であると見なす構造」を近道 を選びつつ探索することもその手段になると考えられる。

#### 参考文献

[Legg 07b] Legg, S. and Hutter, M.: Universal intelligence: A definition of machine intelligence, Minds and Machines, Vol.17, No. 4, pp. 391-444 (2007)

[Ayer 1946] Alfred J. Ayer, Language, Truth and Logic, 1946 [Constantin 1910] 3 ème Cours de Linguistique Générale by Ferdinand de Saussure ソシュール 一般言語学講義: コンスタン タンのノート, 影浦 峡, 東京大学出版会, 2007

[丸山 1983] 丸山圭三郎, ソシュールを読む, 岩波書店, 1983 [Wechsler 1944] Wechsler, D, The measurement and appraisal of adult intelligence, Fourth edition, Williams & Wilkins, 1958 [廣松 98] 廣松渉, 岩波哲学思想・辞典, 岩波書店, 1998

[藤木 07] 藤木暢也, 内藤泰, 聴覚コミュニケーションと脳機能, 音声言語医学 48:277-283, 2007

[プリゴジーヌ 1997] プリゴジン, I, 我孫子誠也, 谷口佳津 共 訳 確実性の終焉, みすず書房, 1997)

[御子柴 02] 御子柴克彦, 清水孝雄, 脳の発生・分化・可塑性, 共立出版, 2002

[松下 97] 松下貢, 散逸構造とはなにか, 高分子 46 巻, 1997 [鈴木 93] 鈴木賢英, 自然科学ノート, 分化書房博文社, 1993 [伊庭 98] 伊庭崇, 複雑系入門, NTT 出版, 1998 [金子 09] 金子邦彦, 生命とは何か, 東京大学出版会, 2009

[岡ノ谷 10] 岡ノ谷一夫 言語起源の生物学的シナリオ,認知 神経科学 Vol.12 No.1 2010

# 韻律情報を活用した二重分節解析器による自然音声からの語彙獲得

Double Articulation Analyzer with Prosody for Unsupervised Word Discovery

奥田 恭章<sup>\*1</sup> Okuda Yasuaki 谷口 忠大 \*1 Taniguchi Tadahiro

\*1立命館大学

Ritsumeikan University

尾崎 僚\*1

Ozaki Ryo

Human infants discover words and phonemes using statistical information and prosody. For unsupervised word discovery, Taniguchi et al proposed the Nonparametric Bayesian Double Articulation Analyzer (NPB-DAA) which was able to segment speech data into word sequences. However, NPB-DAA uses only statistical information such as the mel-frequency cepstrum coefficients. In this paper, we extend NPB-DAA method using prosody, i.e., Prosodic DAA, for unsupervised word discovery. We use the second order differential of the fundamental frequency and the duration of silent as the prosody. We show in an experiment that Prosodic DAA outperforms NPB-DAA.

#### 1. はじめに

人間の幼児は月齢8ヵ月において,音声信号の分布情報や韻 律情報 (Prosody,プロソディ)から,単語の単位を見いだせ ることが知られている.本研究では,教師なし学習によりプロ ソディを含む自然音声信号から,直接音響モデルと言語モデル を同時に推定することで,語彙獲得を行う手法を提案する.

音声信号から教師なし語彙獲得を行う手法にノンパラメトリッ クベイズ二重分節解析器 (Nonparametric Bayesian Double Articulation Analyzer: NPB-DAA) がある. しかしながら, 現在の NPB-DAA ではプロソディによる音響特徴量の変化を 扱うことができない. そこで本稿では NPB-DAA にプロソディ を扱うような出力分布を新たに加えた Prosodic DAA を提案 する.

また,プロソディを強調した日本語自然発話からなる実音 声発話から教師なし語彙獲得する実験を行う.実験結果におい て,プロソディを用いて単語推定を行うことで NPB-DAA の 音素及び単語推定性能が向上することを示す.

#### 2. 先行研究

人間の語彙獲得過程において,月齢8ヵ月の幼児は音声を単 語ごとに分割することができる [Saffran 96].また,幼児は語 彙獲得の際に,音声学的性質であるプロソディを用いて音声 を単語ごとに分割していることが知られている [Jusczyk 92]. このことから,幼児は音声信号の分布,音素と単語の共起性や プロソディを用いて語彙獲得をしていると考えられる.

谷口らは、二重分節構造を持つ時系列データの生成モデルと そのパラメータの推論手法を組み合わせて、NPB-DAAを提案 した [Taniguchi 16a]. NPB-DAA は二重分節構造を持つ時系 列データの解析手法である.二重分節構造は、単独では意味を持 たない音素と、音素の組み合わせによって意味を持つ単語によ る二重の分節構造である.先行研究において、谷口らは母音のみ の音声発話データからの単語分割を実現した [Taniguchi 16a]. また、音声特徴量を Deep Sparse Autoencoder (DSAE)を用 いて、より高次の特徴量に変換することで単語分割精度が向上 することを示した [Taniguchi 16b]. 夛田らは子音を含んだ実

連絡先: 奥田 恭章, 立命館大学 情報理工学研究科, 滋賀県 草 津市 野路東 1-1-1, okuda.yasuaki@em.ci.ristumei.ac.jp



図 1:本研究の概要図.二重分節解析器にプロソディを活用 した単語分割を組み込む.ここで,Chunk は単語の継続長, Segment は音素の継続長をそれぞれ表す.

音声発話データからの単語分割を行うために動的特徴量を用いた [Tada 17]. 尾崎らは NPB-DAA にルックアップテーブル を導入することで計算量オーダを 3 次から 2 次に削減し,計 算時間を 90%削減した [Ozaki 18].

NPB-DAA では、一つの単語は同一の left-to-right の隠れ セミマルコフモデル (Hidden semi-Markov Model: HSMM) [Johnson 13] に従うとしており、プロソディによる音声波形 の変化は異なる単語として認識される. 先行研究では、音響 特徴量として、プロソディを含まない特徴量であるメル周波 数ケプストラム係数 (Mel-Frequency Cepstrum Coefficients: MFCC)を用いており、プロソディによる音声波形の変化を考 慮していない. そのため、幼児が語彙獲得過程で行うとされて いるプロソディによる単語分割を表現していない. そこで、本 研究では NPB-DAA にプロソディを用いた単語分割を組み込 むことを目的とする. 本研究の概要図を図 1 に示す.



図 2: HDP-HLM のグラフィカルモデル [Taniguchi 16a]. こ のモデルは、二重分節構造を持つ時系列データの生成モデルで ある.

#### 3. NPB-DAA

#### 3.1 階層ディリクレ過程隠れ言語モデル

階層ディリクレ過程隠れ言語モデル (Hierarchical Dirichlet Process Hidden Language Model: HDP-HLM) は二 重分節構造を持つ時系列データの生成モデルであり,これ は階層ディリクレ過程隠れセミマルコフモデル (Hierarchical Dirichlet Process Hidden semi-Markov Model: HDP-HSMM) [Johnson 13] を二重分節構造の表現ができるように 拡張したものである. 図 2 に HDP-HLM のグラフィカルモデ ルを示す. その他,生成過程などについては [Taniguchi 16a] を参照されたい.

#### 3.2 潜在単語のサンプリング

HDP-HLM の潜在単語  $z_s$  は HDP-HSMM の推論手法で 用いる backward filtering forward sampling の手続きを拡張 してサンプリングされる. HDP-HLM の潜在単語  $z_s = i$  の backward message は以下の式で求めることが出来る. ここで,  $F_t$  は潜在単語の境界かどうかを表し,  $F_t = 1$  であれば時刻 t+1 で単語が切り替わるとする.  $B_t(i)$  は潜在単語  $z_{s(t)} = i$ が時刻 t+1において,異なる潜在単語に遷移する尤度を表す.  $B_t^*(i)$  は時刻 t+1 から潜在単語が  $z_{s(t)} = i$  となる尤度を表す.

$$B_{t}(i) := p(y_{t+1:T}|z_{s(t)} = i, F_{t} = 1)$$

$$= \sum_{j} B_{t}^{*}(j)p(z_{s(t+1)} = j|z_{t} = i) \quad (1)$$

$$B_{t}^{*}(i) := p(y_{t+1:T}|z_{s(t+1)} = i, F_{t} = 1)$$

$$= \sum_{d=1}^{T-t} B_{t+d}(i)p(D_{t+1} = d|z_{s(t+1)} = i)$$

$$\cdot p(y_{t+1:t+d}|z_{s(t+1)} = i, D_{t+1} = d) \quad (2)$$

$$B_{T}(i) := 1 \quad (3)$$

潜在単語  $z_{s(t)} = i$ の潜在音素列  $w_i$ を  $w_i = (l_1, \dots, l_{L_i})$ と 置くと、 $p(y_{t+1:t+d}|z_{s(t+1)} = i, D_{t+1} = d)$ は以下の式のよう に計算できる.ここで、 $R^{(L_i,d)}$ は $L_i$ 次元で要素の和がdとなるような自然数ベクトル $\mathbf{r}$ の集合を表す.

$$p(y_{t+1:t+d}|i,d) = \sum_{r \in R^{(L_i,d)}} \prod_{k=1}^{L_i} p(r_k|l_k) \\ \cdot \prod_{m=1}^{r_k} p(y_{t+m+\sum_{k'=1}^{k-1} r_{k'}}|l_k)$$
(4)

$$R^{(L_i,d)} = \left\{ r \in \{1, 2, \ldots\}^{L_i} | \sum_{k=1}^{L_i} r_k = d \right\}$$
(5)

式4は動的計画法を用いて効率的に計算することができる.時 刻tにおいて潜在音素の遷移が発生し,その潜在音素が潜在単 語中のk番目の要素である確率をforward messageと定義し, 以下の式で再帰的に求めることができる.

$$\alpha_t(k) = \sum_{d'=1}^{t-k+1} \alpha_{t-d'}(k-1)p(d'|l_k) \prod_{t'=1}^{d'} p(y_{t-t'+1}|l_k)$$
(6)
(7)

$$\alpha_0(0) = 1 \tag{7}$$

以上により, HDP-HLM において各時刻 *t* における.  $B_t(i)$ ,  $B_t^*(i)$  が求まるため,以下の式に従い潜在単語  $z_{s(t+1)}$  とその 継続時間  $D_{s(t+1)}$ をサンプリングできる.ここで, $D_s^{\text{sum}} = \sum_{s' < s} D_{s'}$ である.

$$p(z_s = i | y_{1:T}, z_{s-1} = j, F_{D_{1:s}^{sum}} = 1) = p(i|j)\beta_{D_{1:s}^{sum}}(i)p(y_{D_{1:s}^{sum}}|i)$$
(8)

$$p(D_s = d|y_{1:T}, z_s = i, F_{D_{1:s}^{sum}} = 1) = p(y_{D_{1:s}^{sum}+1:D_{1:s}^{sum}+d}|d, i, F_{D_{1:s}^{sum}} = 1)p(d)\frac{\beta_{D_{1:s}^{sum}+d}(i)}{\beta_{D_{1:s}^{sum}(i)}^{sum}(i)}$$
(9)

#### 4. Prosodic DAA

本稿では、プロソディとして基本周波数 F<sub>0</sub>の二次微分及び 無音区間の継続長の2つを用いる.無音区間の抽出では、ある 閾値以下の音量が一定時間連続している区間を無音区間とし、 その継続長を用いる.

次に、プロソディを HDP-HLM に組み込む方法を述べる. 本稿では、プロソディはそれぞれ観測 yt と同じフレーム数を 持ち,単語の境界を表すインジケーター変数 Ft から生成され るものと仮定している.また,F<sub>0</sub>の二次微分を表す観測を y<sup>Fo</sup> とし, 無音区間長を表す観測を y<sup>sil</sup> とする. プロソディを含 む HDP-HLM のグラフィカルモデルを図3に示す.また,生 成過程は以下のようになる. ここで GEM は Stick-Breaking Process を表し, DP は Dirichlet Process を表す. LM,WM はそれぞれ言語モデルと単語モデルを表している.また, β<sup>WM</sup> は単語モデルにおける Dirichlet Process の基底測度を表し,  $\alpha^{\rm WM}$ と $\gamma^{\rm WM}$ はそれぞれ Dirichlet Process, Stick-Breaking Process のハイパーパラメータである. そして  $\pi_i^{WM}$  は潜在音 素 *i* から次の状態への遷移確率を表している.同様に β<sup>LM</sup> は言 語モデルにおける Dirichlet Process の基底測度を表し、 $\alpha^{LM}$ と $\gamma^{\text{LM}}$ はそれぞれ Dirichlet Process, Stick-Breaking Process のハイパーパラメータである. そして  $\pi_i^{\text{LM}}$  は潜在単語 i から

L

Ŀ



図 3: プロソディを含む HDP-HLM のグラフィカルモデル.潜 在単語  $z_s$  から  $z_s$ の継続長  $D_s^{sum}$  が生成される.  $D_s^{sum}$  から単 語境界を表す  $F_t$  が生成され,  $F_t$  から  $Y_t$  が生成される.

次の状態への遷移確率を表している. また,  $Y_{1:T}$  は  $y_{1:T}^{\text{F}_0}$ ,  $y_{1:T}^{sil}$ の集合を表し、 $p(Y_t)$  (t = 1:T) は  $p(y_t^{F_0}, y_t^{sil})$  である.

$$\beta^{\rm LM} \sim {\rm GEM}(\gamma^{\rm LM})$$
 (10)

$$\pi_i^{\text{LM}} \sim \text{DP}(\alpha^{\text{LM}}, \beta^{\text{LM}}) \quad (i = 1, \ldots)$$
 (11)

$$\beta^{\rm WM} \sim {\rm GEM}(\gamma^{\rm WM})$$
 (12)

$$\pi_i^{\text{WM}} \sim \text{DP}(\alpha^{\text{WM}}, \beta^{\text{WM}}) \quad (i = 1, \ldots)$$
 (13)

$$w_{ik} \sim \pi^{\text{WM}}_{w_{ik-1}}$$
  $(i = 1, ...)$   $(k = 1, ..., L_i)$  (14)

$$(\theta_j, \omega_j) \sim H \times G \quad (j = 1, \ldots)$$
 (15)

$$\phi_{qu} \sim H_{qu}^{Prosody} \quad (q = 0, 1) \quad (u = 0, 1)$$
 (16)

$$z_s \sim \pi_{z_{s-1}}^{\text{LM}} \ (s = 1, \dots, S)$$
 (17)

$$l_{sk} = w_{w_{z_sk}}$$
  $(s = 1, \dots, S)$   $(k = 1, \dots, L_{z_s})$ 
  
(18)

$$D_{sk} \sim g(\omega_{l_{sk}}) \quad (s = 1, \dots, S) \quad (k = 1, \dots, L_{z_s})$$
(19)

$$x_t = l_{sk} \quad (t = t_{sk}^1, \dots, t_{sk}^2)$$
 (20)

$$t_{sk}^{1} = \sum_{s' < s} D_{s'} + \sum_{k' < k} D_{sk'} + 1$$

$$t_{sk}^{2} = t_{sk}^{1} + D_{sk} - 1 \tag{21}$$

$$D_s^{sum} = \sum_{t=s1}^{s} D_t \tag{22}$$

$$y_t \sim h(\theta_{x_t}) \quad (t = 1, \dots, T) \tag{23}$$

$$F_t = \begin{cases} 0 & (t = t_{s1}^2 : t' - 1) \\ 1 & (t = t') \end{cases} \quad (t' = t_{sL_{z_s}}^2) \quad (24)$$

$$y_t^{r_0} \sim h^{r_0}(\phi_{F_t0}) \tag{25}$$

$$y_t^{\circ\alpha} \sim h^{\circ\alpha}(\phi_{F_t 1}) \tag{26}$$

また、プロソディによる単語分割を含む、潜在単語  $z_s = i$ の

backward message は以下の式で求められる.

$$\beta_t(i) := p(y_{t+1:T}, Y_{t+1:T} | z_{s(t)} = i, F_t = 1)$$
  
=  $\sum_j \beta_t^*(j) p(z_{s(t+1)} = j | z_t = i)$  (27)

$$\beta_t^*(i) := p(y_{t+1:T}, Y_{t+1:T} | z_{s(t+1)} = i, F_t = 1)$$

$$= \sum_{d=1}^{T-t} \beta_{t+d}(i) p(D_{t+1} = d | z_{s(t+1)} = i)$$

$$\cdot p(y_{t+1:t+d}, Y_{t+1:t+d} | i, d)$$
(28)

$$\beta_T(i) := 1 \tag{29}$$

潜在単語  $z_{s(t)} = i$ の潜在音素列  $w_i \in W_i = (l_1, \cdots, l_{L_i})$  と 置くと,  $p(y_{t+1:t+d}, Y_{t+1:t+d} | z_{s(t+1)} = i, D_{t+1} = d)$  は以下の 式のように計算できる.

$$p(y_{t+1:t+d}, Y_{t+1:t+d}|i, d) = \sum_{r \in R^{(L_i, d)}} \prod_{k=1}^{L_i} p(r_k|l_k)$$
$$\cdot \prod_{m=1}^{r_k} p(y_{t+m+\sum_{k'=1}^{k-1} r_{k'}}|l_k) p(Y_{t+m+\sum_{k'=1}^{k-1} r_{k'}}|l_k) \quad (30)$$

$$R^{(L_i,d)} = \{r \in \{1, 2, \ldots\}^{L_i} | \sum_{k=1}^{L_i} r_k = d\}$$
(31)

forward message は、以下の式で再帰的に求めることができる.

$$\alpha_t(k) = \sum_{d'=1}^{t-k+1} \alpha_{t-d'}(k-1)p(d'|l_k) \cdot \prod_{t'=1}^{d'} p(y_{t-t'+1}, Y_{t-t'+1}|l_k)$$
(32)  
$$\alpha_0(0) = 1$$
(33)

$$\alpha_0(0) = 1$$
 (33)

以上により, HDP-HLM において各時刻 t における.  $\beta_t(i)$ ,  $\beta_t^*(i)$ が求まるため、以下の式に従い潜在単語 $z_{s(t+1)}$ とその 継続時間  $D_{s(t+1)}$  をサンプリングできる.ここで, $D_{1:s}^{\text{sum}} =$  $\sum_{s' < s} D_{s'}$  である.

$$p(z_{s} = i|y_{1:T}, Y_{1:T}, z_{s-1} = j, F_{D_{1:s}^{sum}} = 1) = p(i|j)\beta_{D_{1:s}^{sum}}(i)p(y_{D_{1:s}^{sum}}, Y_{D_{1:s}^{sum}}|i) \quad (34)$$

$$p(D_s = d | y_{1:T}, Y_{1:T}, z_s = i, F_{D_{1:s}^{\text{sum}}} = 1) =$$

 $p(y_{D_{1:s}^{\text{sum}}+1:D_{1:s}^{\text{sum}}+d}, Y_{D_{1:s}^{\text{sum}}+1:D_{1:s}^{\text{sum}}+d}|d, i, F_{D_{1:s}^{\text{sum}}}=1)$ 

$$\cdot p(d) \frac{\beta_{D_{1:s}^{\text{sum}} + d}(i)}{\beta_{D_{1:s}^{\text{sum}}}^{*}(i)} \quad (35)$$

以上により, プロソディを考慮した二重分節構造の生成過程 から事後分布のサンプリング式を導出した.

#### 5. 実験

#### 実験目的 5.1

本実験では、提案手法が自然発話からの語彙獲得が可能であ るかを評価するために、プロソディを含む自然発話データセッ トを用いて, NPB-DAA と, 提案手法 (以降 Prosodic DAA と呼称する.)の音素,及び単語分割精度を比較する.

#### 5.2 実験設定

本実験では、日本語自然発話データセットを用いる.ここでは、自然発話を日常会話と相違ない発話と定義する.このデータセットは、日本語自然発話で構成された70文を1回ずつ男性の話者に発話してもらい収録した音声データセットである.本実験で用いる特徴量は、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MFCC,MFCCの一次微分、及び二次微分のそれぞれの特徴量を用いる.また、それぞれDSAEで8次元、5次元、3次元と段階的に抽出したものを結合した、合計9次元の特徴量を用いる. $F_0$ の推定には動的計画法を用いて $F_0$ を系列として推定する手法である Robust Epoch And Pitch EstimatoR<sup>\*1</sup>を用いる.

#### 5.3 実験条件

#### 5.4 実験結果

本実験の結果として、音声データの各フレームに正解ラベル を付与し、クラスタリング性能を評価する。クラスタリング性 能の定量的評価指標として、各試行で得られた最終サンプリン グ結果から、音素及び単語の調整ランド指数(Adjusted Rand Index: ARI)を算出する。ARI はクラスタリング結果が正解 ラベルと一致するとき1を取り、ランダムの場合は0をとる。 表1、及び図4に Prosodic DAA、及び NPB-DAA のそれ ぞれの音素及び単語のARIの平均を示す。表1より、2つの 手法の結果をみると、Prosodic DAA が音素 ARI、単語 ARI 共に大幅に高い値を出していることがわかる。また、Prosodic DAAと、NPB-DAA 間でt検定を行ったところ、音素 ARI と単語 ARI 共に優位水準1%で有意差が認められた。

#### 6. まとめ

本稿では、NPB-DAA によるプロソディを考慮した単語分 割を行う手法を提案した.実験では、プロソディを強調した日 本語自然発話から語彙獲得実験を行い、提案手法が既存手法と 比較して、高い精度で語彙獲得が可能であることを示した.

| 表 1: | 音素及び単語分割の精度比較. |  |
|------|----------------|--|
|------|----------------|--|

| 手法           | 音素 ARI            | 単語 ARI              |
|--------------|-------------------|---------------------|
| Prosodic DAA | $0.370{\pm}0.022$ | $0.671 {\pm} 0.054$ |
| NPB-DAA      | $0.261 \pm 0.014$ | $0.497 {\pm} 0.072$ |

\*1 REAPER: Robust Epoch And Pitch EstimatoR https://github.com/google/REAPER



図 4: 音素及び単語分割の精度比較.

今後の課題として、プロソディを強調していない、日本語自 然発話からの語彙獲得を行うことが考えられる.

#### 参考文献

- [Saffran 96] Saffran, Jenny R., Aslin, Richard N. and Newport, ElissaL.: Statistical Learning by 8-Month-Old Infants, American Association for the Advancement of Science, Vol.274, No.5294, pp.19261928, 1996
- [Jusczyk 92] Jusczyk, Peter W and Hirsh-Pasek, Kathy and Nelson, Deborah G Kemler and Kennedy, Lori J and Woodward, Amanda and Piwoz, Julie.:Perception of acoustic correlates of major phrasal units by young infants, Cognitive psychology, Vol.24, Num.2, pp.252-293, 1992
- [Taniguchi 16a] Taniguchi, Tadahiro and Nagasaka, Shogo and Nakashima, Ryo.: Nonparametric Bayesian Double Articulation Analyzer for Direct Language Acquisition From Continuous Speech Signals, IEEE Trans. Cognitive and Developmental Systems, Vol.8, Num.3, pp.171185, 2016
- [Taniguchi 16b] Taniguchi, Tadahiro and Nakashima, Ryo and Liu, Hailong and Nagasaka, Shogo.: Double articulation analyzer with deep sparse autoencoder for unsupervised word discovery from speech signals, Advanced Robotics, Vol.30, Num.11-12, pp.770783, 2016
- [Tada 17] Tada, Yuki and Hagiwara, Yoshinobu and Taniguchi, Tadahiro.: Comparative Study of Feature Extraction Methods for Direct Word Discovery with NPB-DAA from Natural Speech Signals, Joint IEEE International Conference on Development and Learning and Epigenetic Robotics, 2017
- [Ozaki 18] Ryo Ozaki and Tadahiro Taniguchi.: Accelerated Nonparametric Bayesian Double Articulation Analyzer for Unsupervised Word Discovery, The 8th Joint IEEE International Conference on Development and Learning and on Epigenetic Robotics, 2018
- [Johnson 13] Johnson, Matthew J. and Willsky, Alan S.: Bayesian Nonparametric Hidden Semi-Markov Models, Journal of Machine Learning Research, Vol.14, pp.673701, Feb.2013

# Deep Neuroevolution によるロボティックスワームの 二点間往復タスクにおける群れ行動の生成 Generating Collective Behavior of a Robotic Swarm in a Two-landmark Navigation Task with Deep Neuroevolution 森本大智\*1 平賀元彰\*1 Daichi MORIMOTO Motoaki HIRAGA Kazuhiro OHKURA Yoshiyuki MATSUMURA

\*<sup>1</sup>広島大学 \*<sup>2</sup>信州大学 Hiroshima University Shinsyu University

Deep reinforcement learning has provided outstanding results in various applications. Deep neural networks are usually trained by gradient-based methods. However, when deep reinforcement learning is applied to a robotic swarm, that is composed of many robots, it is difficult to design reward functions that lead to a desired collective behavior. In this paper, we applied deep neuroevolution, which is a technique to optimize deep neural networks with artificial evolution, to design controllers of a robotic swarm. Deep neuroevolution is expected to evolve deep neural networks to different reward/fitness landscapes because it optimizes with population-based and gradientfree methods. This paper shows that the controllers designed with deep neuroevolution give robustness to different reward settings compared to deep reinforcement learning.

#### 1. はじめに

Swarm Robotics(SR) は多数のロボットからなる集団に、ロ ボット間あるいはロボットと環境間の局所的な相互作用によっ て所望の群れ行動の生成を目指す研究分野である [Sahin 2004]. SR では群れを構成するロボットの台数が増加するに従い、設 計者が各ロボットの行動を定義して制御器を設計することが困 難となる.そのため、SR では強化学習や進化ロボティクスを 制御器設計に適用する試みがなされている [Brambilla 13].

強化学習の分野では近年,深層ニューラルネットワーク (Deep Neural Network,DNN)を組み合わせた深層強化学習 (Deep Reinforcement Learning,DRL) が様々な問題に適用され,良 好な成績を記録している [Mnih 15, Lillicrap 15]. 一般的に DRL における DNN の学習には,重みの勾配を用いた単点探 索型の勾配降下法が用いられる.そのため,多峰性の目的関数 における局所解や異なる報酬設定に対応するのが難しい.した がって,DRL をロボティックスワームに適用する場合,性能 を向上させるために適切な報酬設定が必要となる.

本稿では Deep Neuroevolution(DNE) によるロボティック スワームの制御器設計を行う. DNE は DNN を進化計算で学習 させる手法である. DNE は個体群ベースの探索によって DNN を学習させるため,報酬設定の変化に対して頑健であることが 期待される.本稿では異なる報酬条件下で,DRL および DNE によってロボティックスワームの制御器である DNN を設計し, DRL と DNE の報酬設定に対する頑健性,およびロボティッ クスワームの群れ行動の比較を行う.

#### 2. Deep Neuroevolution

Deep Neuroevolution(DNE) は進化計算によって DNN を 学習させる手法である. 一般的に DRL における DNN の学習 は,重みの勾配を用いた単点探索型の勾配降下法で行われる. そのため多峰性の目的関数における局所解や異なる報酬設定に 対応するのが難しい.対して DNE では個体群ベースの探索の ためこれらの問題に関して頑健な DNN の学習が期待される.

連絡先: 森本大智, 広島大学, morimoto@ohk.hiroshimau.ac.jp



図 1: 実験環境

DNE の先行研究として [Salimans 17, Such 17] がある. Saliman らは三層の畳み込み層と二層の全結合層からなる DNN を Natural Evolution Strategy を用いて学習させた [Salimans 17]. また Such らは同様の構造を持つ DNN を交 叉を用いず突然変異のみを用いる Genetic Algorithm によっ て学習させた [Such 17]. これらの先行研究は Atari 2600 など の DRL の問題に適用されており、本稿のロボティックスワー ムのような多数のエージェントを扱う問題には適用されてい ない.

#### 3. 計算機実験

#### 3.1 二点間往復タスク

実験には二点間往復タスクを用いる.このタスクの目的は 二つのターゲットエリア間の往復である.実験環境を図1に 示す.環境の両端に黄色とシアンのランドマークを配置する. ランドマークの中心から半径6.5mの範囲がターゲットエリア である.ロボットは目標とするターゲットエリアに到達時,目 標をもう一方のターゲットエリアに変更する.ロボットは各エ ピソード開始時に環境の中央に格子状に配置される.

#### 3.2 ロボット

図 2(a) に実験に用いた移動ロボットを示す. ロボットの直 径は 1m であり左右の二つの車輪とモータによって駆動する.





図 3: ロボットの制御器

最高移動速度は1 m/s である.本実験ではロボットが取る行動を停止, 直進, 左回転, 右回転の4 種類とする. ロボット はセンサとしてカメラ1 個と距離センサ8 個を搭載している. カメラは128×128 pixels の RGB 画像を生成する. 図 2(b) に カメラから得られる画像の例を示す.距離センサは測定範囲内 の物体までの距離を測定する.各センサの測定範囲を図 2(c) に示す.ロボットの上部に搭載された LED は後方のみ点灯し, 黄色のランドマークを目指す場合は赤色,シアンの場合は青色 を点灯する.

#### 3.3 制御器

ロボットの制御器として図3に示す DNN を用いる.制御器 は入力層,4層の畳み込み層,全結合層,出力層からなる.制 御器への入力はカメラ画像,距離センサ情報,目標ランドマー ク情報であり,それぞれ過去4タイムステップまでの情報が 入力される.畳み込みに使用するフィルタはサイズを4×4, チャネル数をそれぞれの層の入力に対応させたものを64種類 用意する.ストライドは2とし,これらフィルタに関する設定 は4層の畳み込み層で共通とする.また各畳み込み層の直前 に Batch Normalization 層を加える.

#### 3.4 実験設定

ここでは DRL と DNE における共通の実験設定について述 べる.実験の最終世代数は 500 とし,1 世代は 1000 タイムス テップとする.制御器は 24 個とし,DRL ではこれらを独立 に学習させ,DNE では進化アルゴリズムによって学習させる. またロボットに対する報酬は以下のものを用いる.

$$r_{d,i,t} = 5 \times (d_{i,t-1} - d_{i,t})$$
  
 $r_{e,i,t} = 5$  (1)  
 $r_{c,i,t} = -5$ 

ここで*i*はロボットの番号,*t*はタイムステップを表す. $r_{d,i,t}$ はロボットが目標ランドマークに近づいた距離に応じて与えられる. $d_{i,t}$ はタイムステップ*t*におけるロボット*i*の重心とランドマークの重心間の距離を示す. $r_{e,i,t}$ はターゲットエリアへの到達時に与えられる. $r_{d,i,t} \ge r_{e,i,t}$ は目標ランドマークがカメラに映っていた場合のみ適用される.また $r_{c,i,t}$ は距離センサが他のロボットや壁との接触を検知した際に与えられる.これらの報酬を組み合わせた二つの条件下で実験を行う.一つ目の条件では $r_{d,i,t}$ , $r_{e,i,t}$ , $r_{c,i,t}$ の総和によって報酬を決定する.1タイムステップにおける報酬  $R_t$ は以下の式で与え

られ,これを「報酬設定 (i)」とする.

$$R_t = \sum_{i} (r_{d,i,t} + r_{e,i,t} + r_{c,i,t})$$
(2)

二つ目の条件では $r_{e,i,t}$ のみによって報酬を決定する. 1 タイム ステップにおける報酬  $R_t$  は以下の式で与えられ,これを「報 酬設定 (ii)」とする.

$$R_t = \sum_i r_{e,i,t} \tag{3}$$

またロボットの各タイムステップにおける行動は  $\epsilon$ -greedy 法 によって決定される.第1エピソードでは $\epsilon = 1$ に設定しラ ンダムに行動を選択する.また1エピソード目は制御器の学 習を行わない.2エピソード以降は $\epsilon = 0.1$ に固定し行動を選 択しつつ,制御器の学習を行う.

#### 3.5 制御器の学習 DRL

DRL のアルゴリズムとして DQN[Mnih 15] を用いる. DQN では Experience replay によって蓄積した環境の遷移情報を再 生し毎タイムステップ制御器の重みを更新する.保有する経験 はロボット台数×1 エピソードのタイムステップサイズ分であ り、全ロボットの経験が共有される.学習時のミニバッチサイ ズは 32 とし、optimizer には RMSpropGraves[Graves 13] を 用いる.

#### DNE

DNE の場合は1エピソード間に獲得した報酬の和  $\sum_{t} R_{t} e$ 制御器の適応度とし、エピソード終了時に制御器の更新を行う.制御器の進化アルゴリズムとして文献 [Such 17] を参考と したものを用いる.各エピソード終了時にトーナメント選択 により親個体を選択する.本実験ではトーナメントサイズを2 とする.また、エリート選択により最高の適応度を記録した制 御器を一つ、遺伝的操作を行わずに次世代に引き継ぐ.選択し た親個体に対し突然変異を適用し次世代個体を生成する.突然 変異操作は以下の式で表される.

$$\boldsymbol{\theta} \leftarrow \boldsymbol{\theta} + \boldsymbol{\epsilon}\boldsymbol{\sigma} \tag{4}$$

ここで $\theta$ は DNN のパラメータベクトル,  $\epsilon$ は $\theta$ と同じ要素 数を持つノイズベクトル,  $\sigma$ は遺伝子に与える揺動のスケー リングパラメータである.  $\epsilon$ の各要素は標準正規分布よりサン プリングされる.また本実験では $\sigma$ =0.02とする.進化させる DNN のパラメータは全結合荷重値と Batch Normalization 層 のアフィン変換パラメータとする.

#### 4. 結果

#### 4.1 報酬設定(i)

学習時におけるロボットの到達回数の推移を図4に示す. グ ラフは実験3試行分のデータを示し、平均値、最大値、標準 偏差は72個の制御器のデータから算出されている. DRL で はおよそ100世代にかけて到達回数が急激に上昇しその後ほ ぼ一定の値を示す. DNE では60世代付近まで平均値がほぼ 上昇せず、その後 DRL に比べ比較的緩やかに上昇する.

次に学習中に記録された制御器を用いてロボティックスワームの群れ行動生成を行なった結果を図 6,図7に示す.DRL の場合,ロボットは他のロボット間を抜け,それぞれのロボッ トが独立にターゲットエリアを目指す振る舞いを示す.対して DNEの場合,ロボットは他のロボットを追従し環境内を輪を 描くように移動する振る舞いを示す.



(a) 1000 time steps

(b) 2000 time steps

(c) 3000 time steps





図 7:報酬設定 (i) の条件下で DNE が生成した群れ行動

(c) 3000 time steps



(a) 1000 time steps



(b) 2000 time steps



(c) 3000 time steps







(a) 1000 time steps

(b) 2000 time steps

(c) 3000 time steps

図 9: 報酬設定 (ii) の条件下で DNE が生成した群れ行動



図 5: 報酬設定 (ii) における到達回数の推移

#### 4.2 報酬設定 (ii)

報酬設定 (i) の場合と同様に到達回数の推移を表したグラフ を図 5 に示す. DRL では報酬設定 (i) と同様に到達回数の急 激な上昇が見られる.しかし,定常時の平均値,最大値は報酬 設定 (i) の場合と比べ低下している.DNE では,報酬設定 (i) で見られた 70 世代付近までの停滞が見られず,平均値は学習 初期からほぼ単調に増加している.

次に報酬設定(i)の場合と同様にロボティックスワームの群 れ行動生成を行なった結果を図8,図9に示す.DRLの場合, ロボットはターゲットエリアに侵入後ランドマークに衝突し, その後ほぼ移動を行わない.対してDNEの場合,報酬設定(i) と同様に環境内を輪を描くように移動する振る舞いを示す.

#### 5. 考察

報酬設定 (i) において DNE は、学習初期の 60 世代付近ま で到達回数の上昇が滞っている. これは報酬設定 (i) における 罰則  $r_{c,i,d}$  によるものであると考えられる. ターゲットエリア への到達報酬  $r_{e,i,t}$  が発生する頻度は  $r_{d,i,t}$ ,  $r_{c,i,t}$  よりも低い. 対して  $r_{d,i,t}$ ,  $r_{c,i,t}$  は条件を満たせば毎タイムステップ発生 する可能性がある. またロボットの最高速度を考慮すると、1 タイムステップに発生する  $r_{d,i,t}$ , の最大値は 1.0 となり、罰則  $r_{c,i,t}$  の五分の一である. このことから、学習初期において発 生する報酬は  $r_{c,i,t}$  が支配的であると考えられ、進化の過程に おいて到達回数が多い制御器よりも、衝突を回避する制御器が 有利となることで到達回数の停滞が起こると考えられる.

また,報酬設定 (ii) における DRL の到達回数は報酬設定 (i) と比較して低下している.これは与えられる報酬がスパース になるためと考えられる.上述の通り,ターゲットエリアへの 到達報酬 *r<sub>e,i,d</sub>* は発生する頻度が低い.そのため Experience Replay に用いる記憶領域において,報酬に関する情報が乏し くなることで性能が低下すると考えられる.よって,より大き い記憶領域を用い, Prioritized Experience Replay 等のアル ゴリズムを用いることで性能の向上が期待される.

また,本実験で用いた二つの報酬条件において,DNE は最 大値やロボットの振る舞いにおいて近しい性能を示したことか ら,報酬条件に対してより頑健な学習が行えると考えられる.

#### 6. おわりに

本稿では Deep Neuroevolution をロボティックスワームの 制御器設計に適用し、二点間往復タスクにおいて群れ行動の生 成を行なった. Deep Neuroevolution を適用したロボティック スワームは二つの異なる報酬条件下においてタスクの達成が可 能であることを示した.

今後の展望として,より複雑な報酬条件下でロボティックス ワームの異なる振る舞いが得られるか実験を行う.また,協調 搬送タスクや経路形成タスクに Deep Neuroevolution を適用 した場合にタスク達成が可能であるか実験を行う.

#### 参考文献

- [Sahin 2004] Erol Sahin: Swarm robotics: from sources of inspiration to domains of application, Swarm Robotics: SAB 2004 International Workshop, Vol. 3342 of Lecture Notes in Computer Science, pages 10-20. Springer, 2005.
- [Brambilla 13] Manuele Brambilla, Eliseo Ferrante, Mauro Birattari, and Marco Dorigo :Swarm robotics: a review from the swarm engineering perspective, Swarm Intelligence, Vol. 7, pages 1-41, 2013.
- [Mnih 15] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A Rusu, Joel Veness, Marc G Bellemare, Alex Graves, Martin Riedmiller, Andreas K Fidjeland, Georg Ostrovski, et al.:Human-level control through deep reinforcement learning, Nature, 518(7540):529, 2015.
- [Lillicrap 15] Timothy P Lillicrap, Jonathan J Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, Daan Wierstra :Continuous control with deep reinforcement learning, arXiv preprint arXiv:1509.02971, 2015.
- [Salimans 17] Tim Salimans, Jonathan Ho, Xi Chen, Szymon Sidor, Ilya Sutskever :Evolution strategies as a scalable alternative to reinforcement learning, arXiv preprint arXiv:1703.03864, 2017.
- [Such 17] Felipe Petroski Such, Vashisht Madhavan, Edoardo Conti, Joel Lehman, Kenneth O Stanley, Jeff Clune :Deep neuroevolution: genetic algorithms are a competitive alternative for training deep neural networks for reinforcement learning, arXiv preprint arXiv:1712.06567, 2017.
- [Graves 13] Alex Graves:Generating sequences with recurrent neural networks, arXiv preprint arXiv:1308.0850, 2013.

Organized Session | Organized Session | [OS] OS-4

[3D4-OS-4b] 自律・創発・汎用 AIアーキテクチャ(2) 栗原 聡 (慶應義塾大学)、川村 秀憲(北海道大学)、津田 一郎(中部大学)、大倉 和博(広島大学) Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room D (301B Medium meeting room) [3D4-OS-4b-01] Introducing a Call Stack into the RGoal Hierarchical Reinforcement Learning Architecture OYuuji Ichisugi<sup>1</sup>, Naoto Takahashi<sup>1</sup>, Hidemoto Nakada<sup>1</sup>, Takashi Sano<sup>2</sup> (1. National Institute of Advanced Industrial Science and Technology (AIST), 2. Department of Computer and Information Science, Faculty of Science and Technology, Seikei University) 3:50 PM - 4:10 PM [3D4-OS-4b-02] Avoiding catastrophic forgetting in echo state networks by minimizing the connection cost OYuji Kawai<sup>1</sup>, Yuho Ozasa<sup>1</sup>, Jihoon Park<sup>1</sup>, Minoru Asada<sup>1</sup> (1. Osaka University) 4:10 PM - 4:30 PM [3D05-06-3] Special program 4:30 PM - 5:10 PM

## 階層型強化学習 RGoal アーキテクチャへの 再帰呼び出し用スタックの導入

Introducing a Call Stack into the RGoal Hierarchical Reinforcement Learning Architecture

| -杉裕志 *1        | 高橋直人 *1         | 中田秀基*1          | 佐野崇 * <sup>2</sup> |
|----------------|-----------------|-----------------|--------------------|
| Yuuji Ichisugi | Naoto Takahashi | Hidemoto Nakada | Takashi Sano       |

\*<sup>1</sup>産業技術総合研究所 人工知能研究センター National Institute of Advanced Industrial Science and Technology (AIST), AIRC

\*2成蹊大学 理工学部 情報科学科

Department of Computer and Information Science, Faculty of Science and Technology, Seikei University

Humans can set suitable subgoals in order to achieve some purposes, and furthermore, can set sub-subgoals recursively if needed. It seems that the depth of the recursion is unlimited. Inspired by this behavior, we had designed a hierarchical reinforcement learning architecture, the RGoal architecture. In this paper, we introduce a call stack into the RGoal architecture to increase reusability of subgoals. We evaluate its performance using a maze with multi-task setting. The result shows that the convergence speed improves as the maximum stack size increases.



図 1: 人間が目標を達成するために、サブゴール(副目標)を 再帰的に設定する例。高いところにあるものを取る(ゴール) ために、まずはしごを取る必要がある(サブゴール)。さらに はしごを手に入れるために倉庫にいく必要がある(サブサブ ゴール)。

#### 1. はじめに

人間は何か目標を達成するために適切なサブゴール(副目 標)を設定できる。さらに必要に応じてサブサブゴールを再帰 的に設定することもでき、その再帰の深さには制約がないよう に見える(図1)。この振る舞いにヒントを得た階層型強化学 習のアーキテクチャとして、我々は RGoal アーキテクチャを 提案した[一杉 18a]。我々はこの RGoal の機能を拡張してい き、ヒトの脳の前頭前野周辺の情報処理を再現し、やがては汎 用人工知能を実現するための中核技術とすることを目指して いる。

先行研究の1つ MAXQ [Dietterich 00] は、多層(ただし 深さは固定)の階層型強化学習アーキテクチャであり、以下の 3つの特徴により学習を効率化している。

1. Subtask sharing: マルチタスク環境において、サブルー

連絡先: 一杉裕志、 茨城県つくば市梅園 1-1-1 中央第1 産業技術総合研究所、 y-ichisugi@aist.go.jp チンをタスク間で共有することで学習を速くする。

- 2. Temporal abstraction: 複雑なタスクの学習において、よ り単純なサブルーチンの組み合わせ方のみに試行錯誤を 限定することで、学習を速くする。
- State abstraction: サブルーチンごとに実行に差し支え ない程度に状態を抽象化することで、サブルーチンの学 習を速くする。

RGoal では 1. は価値関数の分解と共有 (2.2 節)、 2. は思考 モードと呼ぶ機構 (2.4 節) により実現する。 3. は現在のとこ ろ未実装だが、単一化の機構を利用したテーブル圧縮手法を検 討している [一杉 18b]。

RGoal では、エージェントによるサブゴール設定は、プロ グラミング言語におけるサブルーチン呼び出しと似た振る舞 いをする。実際、RGoal は「強化学習によるプログラム合成 システム」と見なすことができる[一杉 18b]。強化学習による プログラム合成は汎用人工知能実現に向けた有望なアプロー チの1つである。例えば、AIXI[Hutter 00] はチューリングマ シンのプログラムを、UCAI[Katayama 18] はより一般的な文 法を持った言語のプログラムを強化学習で合成する汎用人工 知能の理論である。また、このアプローチで動作するシステム として、DNC(Differentiable Neural Computers)[Graves 16] や MagicHaskeller [Katayama 08] がある。

以前提案した RGoal では、エージェントはスタックを持っ ておらず、サブゴール到達後には、それまでのコンテキストと は無関係にあらためてもともとのゴールを目指すように設計さ れていた。しかし、そのようなアーキテクチャでは、サブルー チンとして獲得された知識の再利用性が悪くなる [一杉 18b]。 脳の中に頑健に動作するスタックがあるとは考えにくいが、そ れを代替する何らかの機構があることは考えられる。そこで本 稿では、 RGoal にサブゴールを保存するスタックを導入し、 それに伴い学習則も修正する。そして、迷路課題を用いて性能 を評価する。また、 RGoal には思考モードとよぶ、演繹推論 を行うための特殊なモデルベース強化学習の機構があるが、そ の性能も以前よりも詳しく評価する。

#### 2. RGoal アーキテクチャ

#### 2.1 アーキテクチャの概要

RGoal アーキテクチャ[一杉 18a] について簡単に説明する。 エージェントは各ステップごとに、プリミティブ行動を取る かサブルーチン呼び出しを行うかのどちらかを選択する。サブ ルーチンの間に上下関係はなく、すべてのサブルーチンは対等 であり、相互再帰的に呼び出しが可能である。

ここでは**サブルーチン** *g* を、「任意の環境の状態からある1 つの状態(サブゴール) *g* に向かう方策」と定義する。また、 サブルーチン *g* を実行し続けることで、環境の状態はいつか 必ず *g* に到達すると仮定する。

Option-Critic アーキテクチャ[Bacon 17] などではサブルー チンの終了時の環境の状態は一意に決まらず、終了条件は学習 によって獲得される。一方 RGoal では、終了条件はセンサー 入力から得られる外界の特徴量の1つだと考える。つまり、終 了条件は強化学習アーキテクチャの本体によってではなく、特 徴抽出の機構によって獲得されるものと想定している。

#### 2.2 価値関数分解

行動価値関数をサブルーチンごとに分解し、サブルーチン を複数のタスク間で共有することで、学習速度を上げることが できる [Dietterich 00]。

ゴール G、環境の状態 s、サブゴール g としたとき、行動 a を取った後、方策  $\pi((s,g),a)$  に従って行動し続けたときに 得られる報酬の総和の期待値を、行動価値関数  $Q_G^{\pi}((s,g),a)$ と定義する。(報酬割引は行わないものとする。)これは以下 のように、g への到着前と到着後に分解することができる。

$$Q_G^{\pi}((s,g),a) = Q^{\pi}(s,g,a) + V_G^{\pi}(g)$$
(1)

ここで、 $Q^{\pi}(s,g,a)$  は状態 s において行動 a を取った後、方 策  $\pi$  に従って行動しサブゴール g に到着するまでの報酬の総 和の期待値である。また、 $V^{\pi}_{G}(g)$  は、サブゴール g に到着後 に方策  $\pi$  に従って行動しゴール G に到着するまでの報酬の総 和の期待値で、

$$V_G^{\pi}(g) = \Sigma_a \pi((g, G), a) Q^{\pi}(g, G, a)$$
(2)

として計算できる。

 $Q^{\pi}(s,g,a)$ はもともとのゴール Gに依存しないため、複数 のタスク間で共有することができる。

なお、行動選択の式は通常の強化学習のもの同様であり、例 えばテーブル Q のもとでグリーディーに行動を選択する場合 は以下のようにする。

$$a' = \operatorname{argmax} Q(s, g, a)$$
 (3)

#### 2.3 スタックを導入した場合の学習則

ここまでの定義はスタックがない RGoal [一杉 18a] と本質 的に違いはない(記法は一部変更した)が、学習則はスタック の導入に伴い、少し変更が必要となる。

スタックを導入した RGoal では、サブルーチン g' を呼び 出した時に現在のサブゴール g をスタックに積み、サブルー チンの実行が終了した時、すなわち状態が s から g' に変化 した時に、スタックから取り出した g をサブゴールに再設定 する。サブルーチン呼び出し前は、想定される状態の変化は  $s \rightarrow g \rightarrow G$  であるが、呼び出しによって  $s \rightarrow g' \rightarrow g \rightarrow G$  に変化する。したがって以下の式が成り立つ。

$$Q_G((s',g'),a') - Q_G((s,g),a) = (Q(s',g',a') + V_g(g') + V_G(g)) - (Q(s,g,a) + V_G(g)) = Q(s',g',a') - Q(s,g,a) + V_g(g')$$
(4)

ただし、s', a' は呼び出しの次のステップでの状態と行動であ る。この式は、行動が a がサブルーチン呼び出しに限らず、プ リミティブ行動の場合も成り立つ。したがって、Sarsa で学習 する場合の Q の更新式は以下のようになる。

$$Q(s,g,a) \leftarrow Q(s,g,a) + \alpha(r+Q(s',g',a') - Q(s,g,a) + V_g(g'))$$
(5)

この学習則には以前のもの [一杉 18a] と違い、もともとの ゴール G が現れておらず、大域的な文脈に依存しない知識が 獲得しやすくなっている。

#### 2.4 思考モード

階層型強化学習には、学習済みの簡単なタスクを組み合わ せて複雑なタスクを近似的に、しかし高速に解くという目的も ある。RGoal アーキテクチャには、そのための機構として思 考モードがある。思考モードは、学習済みの Q(s,g,a) を環境 のモデルと見なした一種のモデルベース強化学習 [Sutton 90] である。

本稿では [一杉 18a] とは違い、評価中の各エピソードの実 行の直前に、思考モードにおける実行を定数回行うように実装 を変更し、評価を行った。この振る舞いは、ヒトや動物が新た な状況に直面した時、知識を組み合わせて問題解決の行動計画 を立ててから実行する振る舞いと似たものになっている。

#### 2.5 サブルーチンの中断

以前の Roal アーキテクチャ[一杉 18a] には、実行中のサブ ルーチンを中断し、別のサブゴールに切り替える機能がある。サ ブルーチンの中断が可能であれば行動の自由度が増し、性能が 上がる可能性がある [Kaelbling 93][Sutton 99][Dietterich 00] が、今回の実装ではアーキテクチャを簡単にするため、中断の 機能を取り除いた。

#### 2.6 アルゴリズム

以上の結果をまとめた、Sarsa に基づくアルゴリズムの疑似 コードを図 2 に示す。

#### 3. 評価

今回もアルゴリズムの基本動作の確認を行うことが目的の ため、実行中の振る舞いの可視化が容易な迷路タスクを題材と して性能を評価した。

ここでは、時間をかけた厳密解への収束ではなく、準最適解 にできるだけ速やかに収束することを重視する。

マップとランドマークの集合は固定である(図 3)。ランド マークの中からエピソードごとにスタート S とゴール G がラ ンダムに選ばれる。エージェントが S から移動して G に到達 したときに与えられる報酬は 0 で、その時点でそのエピソー ドを終了し、スタートとゴールを変えて次のエピソードを始 める。上下左右の移動は -1、斜めの 4 方向いずれかへの移動 は $-\sqrt{2}$ 、壁への衝突は -1、サブルーチン呼び出しの実行は  $R^{c} = -1$ の報酬が与えられる。(前に述べたように報酬割引 はない。)ランドマークはサブゴールの候補でもあり、ランド マークの中の 1 つだけがある時点でのサブゴールになり得る。

| 1:  | <b>procedure</b> EPISODE $(S, G, \text{think-flag})$             |
|-----|--|
| 2:  | $s \leftarrow S; g \leftarrow G$                                 |
| 3:  | $stack \leftarrow empty$   |
| 4:  | Choose $a$ from $s, g$ using policy derived from $Q$             |
| 5:  | while $s \neq G$ do  |
| 6:  | # Take action.   |
| 7:  | if $a = RET$ then  |
| 8:  | $s' \leftarrow s; g' \leftarrow stack.pop(); r \leftarrow 0$     |
| 9:  | else if $a$ is $C_m$ then  |
| 10: | stack.push(g)  |
| 11: | $s' \leftarrow s; g' \leftarrow m; r \leftarrow R^{\mathcal{C}}$ |
| 12: | else   |
| 13: | if think-flag then   |
| 14: | $s' \leftarrow g; g' \leftarrow g; r \leftarrow Q(s,g,a)$        |
| 15: | else   |
| 16: | Take action $a$ , observe $r, s'$                                |
| 17: | $g' \leftarrow g$  |
| 18: | # Choose action.   |
| 19: | $\mathbf{if} \ s' = g' \ \mathbf{then}$                          |
| 20: | $a' \leftarrow RET$  |
| 21: | else   |
| 22: | Choose $a'$ from $s', g'$  |
| 23: | using policy derived from $Q$                                    |
| 24: | # Update.  |
| 25: | if $s = g$ or (think-flag and $a$ is not $C_m$ ) then            |
| 26: | # Do nothing.  |
| 27: | else   |
| 28: | $Q(s,g,a) \gets Q(s,g,a)$  |
| 29: | $+\alpha(r+Q(s',g',a')-Q(s,g,a)+V_g(g'))$                        |
| 30: | $s \leftarrow s'; g \leftarrow g'; a \leftarrow a'$              |

図 2: 1つのエピソードを実行する Sarsa に基づくアルゴリズム の疑似コード。テーブル *Q* の初期化方法については [一杉 18a] を参照。



図 3: 評価に用いた2次元格子上の迷路のマップ。20 個のラ ンドマーク (m で示した) がマップ上に配置されている。この ランドマークの中からエピソードごとにランダムにスタート S とゴール G が選択される。



図 4: 実験1:スタックのない RGoal [一杉 18a] と、スタッ クを導入した本稿のアルゴリズムとの比較。実験条件にもよる が、同程度の早さで収束している。



図 5: 実験2:スタックの深さの上限 S と性能の関係。S=0 は普通の強化学習、S=1 は2層の階層型強化学習に相当する。 上限が大きいほど収束は早くなる傾向を示している。



図 6: 実験3:各ステップの実行直前に実行する思考フェーズ の長さと性能の関係。思考フェーズの長さTは、各エピソー ドの直前に思考モードで「脳内シミュレーション」するエピ ソードの回数。思考フェーズが十分長ければ、未経験のタスク であっても、近似解がゼロショットで得られている。 テーブルの初期値は、s = g での Q(s,g,a) に対しては 0、 それ以外は-50 - n (n は小さなノイズ) に初期化した。また、 学習を効率化するため、サブルーチン呼び出しはランドマーク 上でのみ実行可能とした。

行動選択は softmax を用い、逆温度  $\beta = 1$  とした。学習率 は  $\alpha = 0.1$  である。

実験1、2、3はいずれも10回の実行結果の平均である。 横軸はステップ数である。縦軸はステップ数あたりのエピソー ド数であり、値が大きいほど、各エピソードを短いステップで 解けるということを示している。ここでステップ数とはマップ 内の移動もしくは壁への衝突の回数である。サブルーチン呼び 出し *C<sub>m</sub>*、サブルーチンからの復帰 *RET*の実行回数、思考 モードでの実行ステップは、いずれもエージェントの内部で起 こる仮想的な行動であると考え、ステップ数には含めない。

実験1(図4)はスタックがないがサブルーチン中断の機能 を持ったアルゴリズム [一杉 18a]と、スタックを導入した本 稿のアルゴリズムとの比較である。どちらも同程度の早さで 収束している。この実験条件では、スタックありの方が、サ ブルーチン中断の機能がないにもかかわらず、わずかに収束 が早くなっている。ただし、実験条件によって結果は変わり、 [一杉 18a]で用いた迷路の場合では、サブルーチン中断が起き やすく、本稿のアルゴリズムの方が収束はわずかに遅くなる。

実験2(図5)はスタックの深さの上限Sと性能の関係を 調べたものである。S=0は普通の強化学習、S=1は2層の階 層型強化学習に相当する。実験結果は、Sが大きいほど収束 が早くなる傾向を示している。(ただしS=100ではS=4より 収束が若干遅くなってる。)一方で、収束後のスコアは、サブ ルーチン呼び出しを一切行わないS=0がもっともよくなって いる。これは、サブルーチンが使える場合、ランドマークを経 由して多少遠回りする局所解にとどまってしまうためである。 なお、サブルーチンが使える場合でも、逆温度βを小さくし探 索傾向を強くして十分学習させた後、βを大きくすることで、 遠回りしないほぼ最短経路に収束することを確認している。

実験3 (図6)は各エピソードの実行直前の思考フェーズの 長さ T と性能の関係を調べたものである。ここで T は、各 エピソードの直前に、与えられた S と G のもとで思考モード で実行するエピソードの回数である。評価の前に簡単なタスク のみを用いた事前学習フェーズを 2,000,000 ステップ実行し、 そのあとの 1,000 ステップごとのスコアをプロットしている。 事前学習フェーズでは、ユークリッド距離が 8 以内にある S と G のみを選択して実行する。これは、すべてのランドマー クのペア 20x19=380 個のうちの 60 個である。短い距離にあ るランドマーク間の移動方法が 事前学習フェーズで獲得され、 長い距離の移動方法の近似解は、それをつなぐことで得られ る。思考フェーズでは、そのような近似解が、実際に行動する ことなく、脳内シミュレーションだけで「演繹的」に獲得され る。実験結果は、思考フェーズが十分に長ければ、経験したこ のない未知のタスクであっても、それまでの経験で得た知識を 組み合わせることで、近似解がゼロショットで得られることを 示している。

#### 4. まとめと今後

階層型強化学習アーキテクチャ RGoal にスタックを導入し たアルゴリズムを実装し、評価した。今後このアーキテクチャ を拡張し、状態抽象の機構を追加するなどした上で、より複雑 なタスクでの評価を行っていく。

#### 謝辞

ディー・エヌ・エー 甲野佑氏、東京電機大 高橋達二氏との 議論から研究の示唆をいただいており、深く感謝いたします。

本研究は JSPS 科研費 JP18K11488 の助成を受けたもの です。

#### 参考文献

- [一杉 18a] 一杉裕志,高橋直人,中田秀基,佐野崇, RGoal Architecture:再帰的にサブゴールを設定できる階層型強化
   学習アーキテクチャ,第9回人工知能学会汎用人工知能
   研究会 (SIG-AGI), 2018.
- [一杉 18b] 一杉裕志,高橋直人,中田秀基,佐野崇,単一化の機構を利用した階層型強化学習のテーブル圧縮手法の検討, 第 10 回 人工知能学会 汎用人工知能研究会 (SIG-AGI), 2018.
- [Dietterich 00] Thomas G. Dietterich, Hierarchical Reinforcement Learning with the MAXQ Value Function Decomposition, Journal of Artificial Intelligence Research 13, 227–303, 2000.
- [Hutter 00] Hutter, M., A theory of universal artificial intelligence based on algorithmic complexity, Technical Report: cs.AI/0004001, 2000. http://arxiv.org/abs/cs.AI/0004001
- [Katayama 08] S. Katayama, Efficient Exhaustive Generation of Functional Programs using Monte-Carlo Search with Iterative Deepening, PRICAI 2008, LNAI 5351, Springer Verlag, 199-211, 2008.
- [Graves 16] A. Graves, G. Wayne et al., Hybrid computing using a neural network with dynamic external memory, Nature 538, 471–476, 2016.
- [Katayama 18] Susumu Katayama, Computable Variants of AIXI which are More Powerful than AIXItl, 2018. https://arxiv.org/abs/1805.08592
- [Sutton 90] Sutton, R. S., Integrated architectures for learning, planning, and reacting based on approximating dynamic programming. In Proceedings of the Seventh International Conference on Machine Learning, 1990.
- [Kaelbling 93] Kaelbling, L.P.: Hierarchical Learning in Stochastic Domains: Preliminary Results. In: Proceedings of the 10th International Conference on Machine Learning, pp. 167–173, 1993.
- [Sutton 99] Sutton, R. S.; Precup, D.; and Singh, S. P., Between MDPs and semi-MDPs: A framework for temporal abstraction in reinforcement learning. Artificial Intelligence 112(1-2):181-211, 1999.
- [Bacon 17] Bacon, P.-L., Harb, J., Precup, D. The optioncritic architecture. Proceedings of AAAI, 1726–1734, 2017.

# 結合コスト最小化によるエコーステートネットワークの 破滅的忘却の回避

Avoiding catastrophic forgetting in echo state networks by minimizing the connection cost

| 河合 祐司 *1   | 小笹 悠歩 * <sup>2</sup> | 朴 志勲 *1     | 浅田 稔 *1      |
|------------|----------------------|-------------|--------------|
| Yuji Kawai | Yuho Ozasa           | Jihoon Park | Minoru Asada |

\*1大阪大学先導的学際研究機構 Institute for Open and Transdisciplinary Research Initiatives, Osaka University \*<sup>2</sup>大阪大学工学部 School of Engineering, Osaka University

Catastrophic forgetting is one of big issues in multi-task learning with neural networks. We propose that minimization of the connection cost mitigates catastrophic forgetting in echo state networks. The optimization of connections in reservoirs can yield neural modules (local sub-networks) that differentiate information flow depending on tasks. The task-specific neural activities help to consolidate knowledges of the tasks. We showed that this constraint creates neural modules consisting of negative connections and can improved the performance of multitask learning. Furthermore, we analyzed the transfer entropy of inter- and intra-modules to show task-specific functional differentiation of the modules.

#### 1. はじめに

ヒトをはじめとした生物は,新しい環境や様々なタスクへ 即時的に適応し,生涯を通じて学習し続ける.ヒトの神経ネッ トワークは異なる機能を有するモジュール構造(部分ネット ワーク)を成し,そのモジュールが動的に切り替わることに よって,柔軟な認知活動が実現されていると考えられている [Meunier 09].そのようなヒトの柔軟で適応的な学習のメカニ ズムの理解は,汎用的な人工ニューラルネットワークの設計に おいて有用となろう.

逐次的に与えられるデータをオンライン学習する枠組みは, 人工ニューラルネットワーク分野においても継続学習 (continual learning) として近年注目を集めている [Parisi 18]. し かし,複数タスクの継続学習には,破滅的忘却 (catastrophic forgetting)の問題がある [McCloskey 89]. これは,新しいタ スクの学習によって,過去に学習したタスクの情報が上書きさ れ,複数のタスクの学習を両立できないという問題である.

この破滅的忘却の回避のために、 ニューラルネットワークにモ ジュール構造を取り入れることが提案されている [Bongard 11, Ellefsen 15]. これらの研究に共通するアイデアは、複数のモ ジュールがそれぞれ異なるタスクに対応するように活動する ことで、タスク情報の上書きを防ぐことである.また、ネット ワークの結合コストの最小化によって, モジュール構造が生み 出されることが報告されている [Clune 13]. 例えば, 脳にお ける結合コストは、軸索長やシナプス強度に相当する. これに より長距離の結合が嫌われ、局所的で密なネットワークとして のモジュールが現れる. このことを利用して, Ellefsen et al. (2015)は、フィードフォワード型のニューラルネットワーク の結合コストを遺伝的アルゴリズムによって最小化すること によって, ネットワークにモジュール (タスクにより異なる処 理経路)が現れ、複数タスクの継続学習が可能になることを 示した.しかし、このモデルはフィードフォワード型であり、 静的な情報の流れのみを扱っている.実際の脳においては、リ カレント構造による動的な情報の流れの中で、モジュールの切 り替えがなされていると考えられる.また,彼らはタスクとモ ジュールの対応を定量的に評価していない.

そこで本研究は、リカレントニューラルネットワークの一 種であるエコーステートネットワーク (echo state network: ESN) に結合コスト最小化を導入するモデルを提案し、それが 複数の時系列タスクにおける継続学習の破滅的忘却を回避でき ることを示す. 一般的な ESN はランダム結合のリザバーネッ トワークに入力が与えられ、リザバーから出力への結合重みの みが誤差によって修正される.本モデルでは、リザバーネット ワークの結合を、学習性能最大化と結合コスト最小化を目的関 数とした遺伝的アルゴリズムによって最適化する.その結果、 リザバー内にモジュールが現れ、タスクに応じてモジュール内 とモジュール間の情報の流れが変化することで、出力重みの学 習における破滅的忘却が回避されることが期待される.また、 最適化されたリザバーノード間の移動エントロピーを計算し、 タスクごとの情報の流れを解析することで、モジュールの機能 分化を明らかにする.

#### 2. モデル概要

#### 2.1 エコーステートネットワークの継続学習

図1に提案モデルの概要を示す.以降では簡単のため,入 出力が一次元である場合について説明する.時刻*t*において, *N* 個のリザバーノードが入力 u(t) をベクトル  $\mathbf{W}_{in}$  で重み付 けられて受け取る.そして,リザバーノードの状態  $\mathbf{x}(t) = (x_1(t), \cdots, x_N(t))^{\top}$  は次式により更新される.

$$\mathbf{x}(t+1) = f(\mathbf{W}_{\rm in}u(t+1) + \mathbf{W}\mathbf{x}(t) + \mathbf{W}_{\rm fb}y(t)) \quad (1)$$

ここで、**W** は  $N \times N$  のサイズのリザバー重み行列, **W**<sub>in</sub> は 入力重みベクトル、**W**<sub>fb</sub> は出力 y(t) のフィードバック重みベ クトルであり、これらの重みは学習を通して不変である。今回, 関数 f として、ハイパボリックタンジェントを用いた.**W** は 行列 **W**<sub>0</sub> を次式で正規化することで得られる.

$$\mathbf{W} = \alpha \frac{\mathbf{W}_0}{\rho(\mathbf{W}_0)} \tag{2}$$

ここで、 $\rho(\mathbf{W}_0)$ は  $\mathbf{W}_0$ の固有値の絶対値の最大値(スペクト ル半径)であり、 $\alpha$ は正規化定数である. Ellefsen et al. (2015) のモデルでは、タスクによって入力ノードが異なっていたが、 本モデルでは、タスクが異なっても同じノードに入力が与えら

連絡先:河合祐司,大阪大学先導的学際研究機構,〒565-0871 大阪府吹田市山田丘 2-1, kawai@ams.eng.osaka-u.ac.jp



図 1:提案モデルの概要図.一定時間経つとタスクが別のタス クに切り替わる状況におけるエコーステートネットワークの 継続学習の問題を扱う.結合コスト最小化と誤差最小化を目 的関数とする遺伝的最適化により,リザバーネットワークにモ ジュール性が現れ,タスクの切り替えに応じてそのモジュー ルの活動も切り替わることで,複数のタスクの学習が可能に なる.

れる.明なタスク切り替え情報が与えられなくても、タスク間 の入出力の性質の違いから、リザバーの活動ダイナミクスが変 化することが期待される.

時刻 t において, 出力 y(t) を次式により得る.

$$y(t) = \mathbf{W}_{\text{out}}(t)\mathbf{x}(t) \tag{3}$$

ここで、Wout(t)は出力重みベクトルである。一般には、この 出力重みを線形回帰のバッチ学習により求めるが、今回は、次 に説明する逐次最小二乗法の継続学習により求める。

時刻 t における出力重みは次式により更新される.

$$\mathbf{W}_{\text{out}}(t+1) = \mathbf{W}_{\text{out}}(t) + \Delta \mathbf{W}(t)$$
(4)

$$\Delta \mathbf{W}(t) = \mathbf{R}(t)\mathbf{x}(t)e(t) \tag{5}$$

ここで, 誤差 e(t) は ESN の出力 y(t) と教師信号  $y_d(t)$  の差

$$e(t) = y(t) - y_{\rm d}(t) \tag{6}$$

である. R(t) は次式で与えられる.

$$\mathbf{R}(t) = \frac{1}{\mu} \left[ \mathbf{R}(t-1) - \frac{\mathbf{R}(t-1)\mathbf{x}(t)\mathbf{x}^{\top}(t)\mathbf{R}(t-1)}{\mu + \mathbf{x}(t)\mathbf{R}(t-1)\mathbf{x}^{\top}(t)} \right]$$
(7)

ここで、 $\mu$ は忘却係数とよばれるパラメータである.  $\mathbf{R}(t)$ の 初期値は $\mathbf{R}(0) = (1/\delta)\mathbf{I}$ で与えられ、 $\mathbf{I}$ は単位行列、 $\delta$ は非常 に小さい定数である.

2.2 遺伝的アルゴリズムによるリザバー重みの最適化 一般の ESN では、W<sub>0</sub> をランダムに決定するが、本モデル では、W<sub>0</sub> の個々の要素を遺伝子とする遺伝アルゴリズムによ り最適化する.その目的関数には、学習性能の最大化(誤差の 最小化)だけでなく、結合コストの最小化も含める.結合コス トを定義するために、リザバーノードを平面格子状に配置する. 二つのノード間の結合コストをその間のユークリッド距離と重 みの絶対値の乗算で表し、全体の結合コストを、全てのノード の組み合わせについての結合コストの総和で定義する.この目 的関数により、空間的に遠い結合を持つ ESN は淘汰されやすく なるため、近傍の密な結合で構成されたモジュールが創発する ことが期待される.今回、多目的の遺伝的アルゴリズムとして 代表的な,非優越ソート遺伝的アルゴリズム (non-dominated sorting genetic algorithm II: NSGA-II) [Deb 02] を用いる. 遺伝的最適化と継続学習の処理の流れを以下に記す.

- 初期世代として,異なる初期重みを持つ ESN を X 個構 成する.
- 2. 複数のタスクが切り替わる状況での継続学習により、各 ESN が Wout を更新する.
- 2. での誤差の最小化と結合コストの最小化を目的関数と する NSGA-II により、W<sub>0</sub>の異なる次世代の ESN が構 成される.
- 4. 次の世代に移り、2. と 3. を Y 回繰り返す.

#### 3. 実験

#### 3.1 実験設定

今回, リザバーノード数 N を 36 に設定し, 6×6 の平面格 子上に配置した.  $\mathbf{W}_{in}$ ,  $\mathbf{W}_{fb}$ ,  $\mathbf{W}_{out}$  の学習初期値, および,  $\mathbf{W}_0$  の進化初期値は [-1,1] の一様乱数にした.  $\mathbf{W}$  を得るた めのパラメータ  $\alpha$  は 1.0 に設定した.

以下の性質の異なる二つのタスクを用いた.

- 正弦波の短期予測:正弦波を入力とし (u(t) = sin (<sup>πt</sup>/<sub>10</sub>)),
   1時刻後の入力を教師信号とする (y<sub>d</sub>(t) = u(t + 1)).
- 3ビットパリティチェック:0か1のランダム入力に対して、現在と直近の過去二つの入力において、1が偶数個あれば教師信号は0、奇数個あれば1とする.

どちらのタスクも入出力は一次元である. 16 ステップごとに タスクを入れ替え,480 ステップまで逐次最小二乗法による継 続学習を行った.逐次最小二乗法の忘却係数  $\mu$  は 0.7 にし,初 期設定に用いる  $\delta$  は 0.1 に設定した.

NSGA-II において,一世代の個体数 X を 500,最大世代数 Y を 1000 に設定した.また,交叉率は 80%とし,80%の確率 で一世代内に 1 個体の突然変異が起きるようにした.学習性 能を 161 ステップから 480 ステップまでの平均二乗誤差で定 義し,その最小化を NSGA-II の一つの目的関数とした.結合 コストの最小化を目的関数に含めることの効果を明らかにする ために,誤差最小化のみを目的関数とする比較条件を設けた.

リザバーネットワークにモジュールが創発し、そのモジュー ルがタスクに応じて異なる機能を有していることを明らかに するために,進化最適化後のリザバーネットワークの結合のモ ジュール性と神経活動の情報の流れを評価した. ネットワーク 結合のモジュール性の評価には、Newman のモジュラリティ [Newman 06] を用いた. これはモジュール内ノード間の結合 の割合から,結合がランダムにされた場合での結合の割合を減 じた値である.この値が最も大きくなるモジュール数とノード へのモジュールの割り当てを採用する.神経活動の情報の流れ の評価には、移動エントロピー [Schreiber 00] を用いた. 今 回,あるノードの1時刻分の活動から,1時刻後の別のノード の活動への移動エントロピーを求めた. 学習後の 10,000 デー タ点に対して、全てのノード間の移動エントロピーを計算し、 モジュール間の平均移動エントロピーとモジュール内の平均移 動エントロピーを求めた. さらに、タスク期間ごとに平均移動 エントロピーを計算することで、タスク依存的な情報の流れを 可視化した.



#### 3.2 実験結果

図2に,100世代ごとの各世代における最小の平均二乗誤 差を示す.黄色と緑の線がそれぞれ,誤差と結合コストの最小 化,誤差のみの最小化の条件での結果である.この図から,結 合コストを目的関数に含めることで,学習性能が向上している ことがわかる.図3に結合コストを目的関数に入れた場合で の(a)初期世代と(b)最終世代の学習曲線の例を示す.初期 のランダムネットワークでは、タスクが切り替わるごとに再学 習を繰り返していることがわかる.一方で,最終世代では、タ スクが切り替わっても誤差が増大せず,破滅的忘却を回避して いる.

図4に,100世代ごとのモジュラリティの値の推移を示す. 正の結合と負の結合によりネットワークを分けて,それぞれの モジュラリティを解析した.図4中の実線から,結合コスト を目的関数に含めることで,負の結合ネットワークのモジュラ リティが増加したことがわかる.誤差のみを目的関数とした場 合であってもモジュラリティの増加は認められるが,結合コス トを含めた場合のものよりは大きくはない.一方,図4の正 の結合のネットワーク(破線)ではどちらの場合であっても, モジュラリティの増加はほとんどなく,ランダム結合のモジュ ラリティと同等であることがわかる.

上記のモジュラリティの解析から,最終世代の正負の結合 ネットワークのそれぞれにおいて、3つのモジュールがあるこ とがわかった.それらをモジュールA,B,Cとよび、タスクご とのモジュール間とモジュール内の平均移動エントロピーを図 5に示す(ただし、負の結合ネットワークのモジュールと正の 結合ネットワークのモジュールは対応しない).正弦波予測の ときには、移動エントロピーの値が全体的に小さい.しかし、 負のモジュール C から A への移動エントロピーが大きく、正 のモジュール B への移動エントロピーが比較的大きいことが わかる.一方で、パリティチェックのときには、負のモジュール A と B での移動エントロピーが大きい、このように、タスク に応じて異なる情報の流れが発生し、モジュールごとに異なる 情報処理がなされている可能性が示された.

#### 4. 議論と結論

本研究では、ESN のリザバーに結合コスト最適化を導入す ることで、リザバーネットワークにモジュールが現れ、継続学



図 3: 学習曲線の例. 16 ステップごとにタスクが切り替わる. 青:正弦波予測タスク,赤:パリティチェックタスク.



図 4: リザバーネットワークのモジュラリティ. 結合の正負で 分けてモジュラリティを求めた. 実線と破線はそれぞれ, 負と 正の結合が作るネットワークのモジュラリティである. 塗りつ ぶし範囲は, その世代における個体間の標準偏差を表す.

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



図 5: モジュール間とモジュール内の平均移動エントロピー. それぞれ3つのモジュールがあり,行のモジュールから列のモジュー ルへの平均移動エントロピーの大きさを色の濃さで表している.青:正弦波予測タスク,赤:パリティチェックタスク.

習における破滅的忘却が回避されることを示した. 直感的に は,結合コストによるネットワークの拘束は学習性能の改善に 直接的には寄与せず,むしろ悪化を招く可能性も考えられる. にもかかわらず,複数タスクの学習において,結合コスト最小 化を目的関数に含めることで学習性能の向上がみられたこと は興味深い(図2).また,モジュール内とモジュール間の平 均移動エントロピーの解析から,モジュールがタスクに応じて 異なる情報の流れを作ることを明らかにした(図5).これに よって,複数のタスクの学習が干渉することなく継続学習を可 能にしたと考えられる.

モジュラリティの解析から、正(興奮性)の結合はモジュー ル性を持たず、負(抑制性)の結合はモジュラーネットワーク であることを発見した(図4). それぞれのネットワークのは たらきを推測する.まず,興奮性のネットワークはおそらくラ ンダムネットワークであり,複雑な神経活動を生成する役割が あると考えられる. ランダム結合のリザバーの活動が多様なダ イナミクスを含むことによって, ESN は様々な時系列課題の 課題が可能になるとされる [Bertschinger 04]. そのため,一 般的な学習性能の向上のために結合のランダム性が必要にな る.一方,抑制性のモジュラーネットワークは、タスク特有の ダイナミクスを生成する役割があると考えられる. ヒトの脳 におけるモジュールの切り替えにおいても、不用なモジュール の活動が抑制されていることが報告されている [Fox 05]. 本 研究の結果は、ネットワークの活動が複雑であり、かつ構造を 有することが,継続学習において重要であることを示唆する. このことは、複数タスク学習におけるニューラルネットワーク の構成論だけでなく,柔軟で適応的な脳のメカニズムの理解に つながると期待される.本モデルの他のタスクへの適用や,抑 制性のモジュラーネットワークの機能のさらなる調査と体系化 が今後の課題である.

#### 謝辞

本研究は, JST, CREST, JPMJCR17A4の支援を受けた ものである.

#### 参考文献

[Bertschinger 04] Bertschinger, N. and Natschläger, T.: Real-time computation at the edge of chaos in recurrent neural networks, *Neural Comput.*, Vol. 16, No. 7, pp. 1413–1436 (2004)

- [Bongard 11] Bongard, J. C.: Spontaneous evolution of structural modularity in robot neural network controllers, in *Proc. of the 13th GECCO*, pp. 251–258 (2011)
- [Clune 13] Clune, J., Mouret, J.-B., and Lipson, H.: The evolutionary origins of modularity, *Proc. R. Soc. B*, Vol. 280, No. 1755, 20122863 (2013)
- [Deb 02] Deb, K., Pratap, A., Agarwal, S., and Meyarivan, T.: A fast and elitist multiobjective genetic algorithm: NSGA-II, *IEEE Trans. Evol. Comput.*, Vol. 6, No. 2, pp. 182–197 (2002)
- [Ellefsen 15] Ellefsen, K. O., Mouret, J.-B., and Clune, J.: Neural modularity helps organisms evolve to learn new skills without forgetting old skills, *PLoS Comput. Biol.*, Vol. 11, No. 4, e1004128 (2015)
- [Fox 05] Fox, M. D., Snyder, A. Z., Vincent, J. L., Corbetta, M., Van Essen, D. C., and Raichle, M. E.: The human brain is intrinsically organized into dynamic, anticorrelated functional networks, *Proc. Natl. Acad. Sci.*, Vol. 102, No. 27, pp. 9673–9678 (2005)
- [McCloskey 89] McCloskey, M. and Cohen, N. J.: Catastrophic interference in connectionist networks: The sequential learning problem, *Psychol. of Learn. Motiv.*, Vol. 24, pp. 109–165 (1989)
- [Meunier 09] Meunier, D., Lambiotte, R., Fornito, A., Ersche, K., and Bullmore, E. T.: Hierarchical modularity in human brain functional networks, *Front. in Neuroin*form., Vol. 3, No. 37 (2009)
- [Newman 06] Newman, M. E. J.: Modularity and community structure in networks, *Proc. Natl. Acad. Sci.*, Vol. 103, No. 23, pp. 8577–8582 (2006)
- [Parisi 18] Parisi, G. I., Kemker, R., Part, J. L., Kanan, C., and Wermter, S.: Continual lifelong learning with neural networks: a review, arXiv:1802.07569 (2018)
- [Schreiber 00] Schreiber, T.: Measuring information transfer, *Phys. Rev. Lett.*, Vol. 85, No. 2, pp. 461–464 (2000)

4:30 PM - 5:10 PM (Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room D) [3D05-06-3] Special program

Special program

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

# [3E3-OS-12a] 画像と AI (MIRU2019プレビュー)(1)

長原 一(大阪大学)、川崎 洋(九州大学)、岡部 孝弘(九州工業大学)

Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room E (301A Medium meeting room)

# [3E3-OS-12a-01] Convolutional Neural Network for Image Recognition and Visual Explanation OTakayoshi Yamashita<sup>1</sup> (1. Chubu University) 1:50 PM - 2:30 PM [3E3-OS-12a-02] Adaptive selection of auxiliary tasks in UNREAL OHidenori Itaya<sup>1</sup>, Tsubasa Hirakawa<sup>1</sup>, Yamashita Takayoshi<sup>1</sup>, Fujiyoshi Hironobu<sup>1</sup> (1. Chubu University) 2:30 PM - 2:50 PM [3E3-OS-12a-03] ShakeDrop Regularization for ResNet Family OYoshihiro Yamada<sup>1</sup>, Masakazu Iwamura<sup>1</sup>, Koichi Kise<sup>1</sup> (1. Osaka Prefecture University) 2:50 PM - 3:10 PM

# Convolutional Neural Network による画像認識と視覚的説明

Convolutional Neural Network for Image Recognition and Visual Explanation

山下隆義\*1

Takayoshi Yamashita

#### \*1中部大学

#### Chubu university

Deep learning technologies in the field of computer vision are gradually introducing into our daily life. These technologies have been achieved by introducing the methods that improve recognition performance, such as deeper models, a method of stability training of the deeper model. Moreover, to achieve the productization, the visual explanation that explains the decision making of deep learning to a user has been proposed. In this paper, we present a trend of deep learning technologies, which have been used on image recognition methods such as image classification, object detection, and visual explanation.

#### 1. はじめに

画像中に存在する物体のカテゴリや位置等を認識する画像認 識技術は, Advanced Driver Assistance System (ADAS) や 防犯システム, SNS やスマートフォンのアプリケーション等 で幅広く応用されている. ADAS では自動ブレーキシステム 等の歩行者や自動車を検出する処理で用いられ, SNS やアプ リケーション等のレジャーな分野では顔の形状を画像等から推 定して自動で編集するアプリケーション等へ応用されている.

このような, 画像認識技術が身近に取り入れられるようになっ た要因の一つとして,深層学習の発展により認識性能が向上し たことが深く関係している.画像認識分野における深層学習で は, Deep Convolutional Neural Network (CNN) [Alex 12] をベースにした手法が一般的に用いられている. CNN は,複数 のカーネルで構築される畳み込み層を主体に構築されたニュー ラルネットワークであり、学習によりカーネルを更新すること で画像認識に有効な特徴量を獲得する. CNN が画像分類で高 い性能を発揮した後、物体検出やセマンティックセグメンテー ション等の様々な画像認識タスクへ応用されるようになった. これは、CNN のモデルの発展や深いモデルを安定して学習で きる手法が数多く提案されたことが大きな貢献となっている. 一方で,CNN による性能向上のみでなく,推論時におけ る CNN の判断根拠をユーザへ伝える技術も提案されている. CNN を導入した製品が誤認識によりユーザへ何かしらの危害 を与えたとき、ユーザへなぜこのような行動を起こしたのか を説明する必要がある.そのため、これらの判断根拠を解析 する手法は CNN を用いた製品を商品化する際に重要な技術 となる. CNN の判断根拠を解析する研究は活発に取り組まれ ており、様々なアプローチが提案されている.特に、画像認識 分野では CNN が推論時に注視した領域をマップで表現した Attention map を用いることで、判断根拠を解析する視覚的 説明が用いられる.視覚的説明は、CNN が画像認識する際に 注視した領域を可視化することができるため, 直感的に CNN の判断根拠を知ることができる.

本稿では,画像認識分野で用いられる CNN の最近の動向に ついて述べる.まず,画像分類において用いられる CNN のモ デルについて述べた後,物体検出のモデルについて述べる.そして,CNNの学習時に用いられる正規化や学習方法について述べる.最後に,CNNの判断根拠を解析する視覚的説明の研究事例について述べる.

#### 2. 画像分類における CNN のモデル

物体検出法やセグメンテーション、属性認識等で用いられ る CNN ベースのモデルは、画像分類で提案されたモデル をベースにネットワークを構築している例が多い [Ren 15, Liu 16, Badrinarayanan 15, He 17]. 画像分類における CNN の初代の代表的なモデルとして、AlexNet [Alex 12] が ある. AlexNet は、大規模な画像認識コンペティションで ある ImageNet Large Scale Visual Recognition Challenge (ILSVRC) [Russakovsky 15] でトップとなったモデル である. AlexNet の構造は、5層の畳み込み層と2層の全結 合層から構築された CNN であり、Local Response Normalization (LRN) & Dropout, Rectified Linear Units (ReLU) 等の大量のデータで深いネットワークを学習するためのテク ニックが導入されている.AlexNet の提案後,より深いネット ワークを構築することで、高精度な画像分類を実現するアプ ローチが取られた.深いネットワークは、単純な特徴と複雑な 特徴を同時に学習できるため、より高い精度で認識が可能で ある. 初期におけるこのアプローチの代表的なモデルとして, VGGNet [Karen 15] や GoogLeNet [Szegedy 15] が挙げられ る. VGGNet は最大で 19 層の CNN を構築し, GoogLeNet は Inception module を導入することで 22 層の CNN を構築 している. その後, Batch Nornalization [Sergey 15] や He の 正規化 [He 15] 等, 深いネットワークの学習を安定させるため のアプローチが提案された.

2016年には、He らが Residual Learning を導入した ResNet を提案し、100層以上の CNN を構築した [He 16]. ResNet は 複数の層を繋げる際にバイパス構造を取り入れており、Residual Learning を取り入れた Residual unit を構築している. Residual Learning の導入により、大量の層で構築されたネ ットワークを安定して学習できるようになり、CNN ベース の画像分類の精度がさらに向上した. ResNet が提案された 後は、ResNet をベースにした様々なモデルが提案されてい る [Zagoruyko 16, Huang 17, Xie 17].

連絡先: 山下隆義,中部大学,愛知県春日井市 松本町 1200,0568-51-1111,0568-51-1111, takayoshi@isc.chubu.ac.jp



図 1: 物体検出の代表的なモデル

これらの画像分類モデルの進化は、物体検出や属性認識、セ グメンテーションにも大きな影響を与えている.物体検出やセ グメンテーションで用いられるネットワークは画像分類のネッ トワークモデルをベースに構築するため、画像分類の性能向上 に伴い他の認識タスクの性能も向上できる.そのため、画像分 類のモデルは他の画像認識タスクの観点からも、重要な立ち位 置に属している.

#### 3. 物体検出

CNN ベースの画像分類法の発展に伴い, CNN をベースと した物体検出法も大きく発展している.物体検出は、図??(b) のように画像中の物体の位置とそのカテゴリを推定する技術 である. CNN ベースの物体検出法は, R-CNN [Girshick 14] と Fast R-CNN [Girshick 15] をベースに進化を遂げている. R-CNN ベースの手法では、物体の候補領域を検出し、検出し た候補領域を CNN でカテゴリ分類とバウンディングボック スの修正を行う、2段階の検出構造を採用している.しかし、 R-CNN と Fast R-CNN は計算コストが高く、リアルタイム な物体検出が困難である. リアルタイムで物体検出が可能な 手法として, Faster R-CNN [Ren 15] がある. Faster R-CNN は, Region Proposal Network (RPN) を図 1(a) のように導 入しており,物体候補領域の検出と,カテゴリ分類とバウン ディングボックスの修正を1つのネットワークで End-to-End に処理できる. Faster R-CNN は、インスタンスセグメンテー ションヘも応用されている. Faster R-CNN をインスタンスセ グメンテーションへ応用した Mask R-CNN [He 17] は、検出 した物体領域のマスクを出力するブランチを追加することで, 高精度なインスタンスセグメンテーションを実現している. ま た, R-CNN のような 2 段階の検出構造を用いずに, 図 1(b) のようにネットワークの応答値から直接検出スコアを出力でき る Single Shot Multi-box Detector (SSD) [Liu 16] も提案さ れている. SSD は、物体候補領域の検出を必要としないため、 Faster R-CNN より高速に物体を検出できる.

#### 4. CNN の汎化性能を向上させる手法

大量のデータを用いて深いネットワークを安定して学習する ために,様々なテクニックが導入されている.ネットワークの



図 2: Batch Normalization の発展系の手法 (文献 [Yuxin 18] から引用)

学習時に正規化,最適化方法を導入することで,学習の収束を 早めたり,学習時における勾配の発散等を防ぐことができる.

#### 4.1 正規化

CNN はカーネルと入力画像または特徴マップの局所領域か ら内積値を求めるため、入力値にノイズが発生した場合等に応 答値のばらつきが発生し、認識性能を低下させる原因となる。 そのため、一般的には畳み込み層や全結合層の応答値を正規化 し、精度低下を抑制する。AlexNet では LRN が用いられてい たが、他の特定のネットワークに対しては精度が向上しなかっ たり、Batch Normalization [Sergey 15] が提案されたことで、 現在は一般的に用いられていない。

Batch Normalization は、特定のチャンネルをミニバッチ 単位で正規化し、平均を0と分散を1にする。図2(a)のよ うにミニバッチ単位で特定のチャンネルを正規化することで、 内部共変量シフトが大幅に変動するのを防いでいる。しかし、 Batch Normalization は内部共変量シフトを獲得するために、 ミニバッチのサイズを16以上にする必要がある。ミニバッチの サイズは大きいほど計算コストが増加するため、物体検出等の 使用メモリ量が膨大なモデルで十分な性能を発揮できない。こ の問題を解決する手法として、Group Normalization がある。 Group Normalization は、図2(b)のように数枚のチャンネル のみ用いて正規化する。これにより、Group Normalization は 少量のミニバッチサイズでも従来のBatch Normalization と 同等の精度を得ることができる。

#### 4.2 学習方法

確率的勾配降下法 (stochastic gradient descent; SGD) に よりネットワークを学習する場合,学習率 $\eta$ を学習の過程で変 化させる Learning rate schedule が一般的に導入されている. ネットワークの学習における学習率は,パラメータの更新量を 制御する係数である.学習率を大きく設定した場合は学習の収 束が早くなるが,勾配が発散しやすい.一方で,学習率を小さ く設定した場合は最適解を獲得しやすいが,学習の収束が遅く なる.この問題を解決するために,学習の過程で学習率を変更 することで,最適解を獲得しやすくしている.Learning rate schedule は,一般的には学習率を減衰させる Learning rate drop が一般的に用いられる.SGD で Learning rate drop を 用いる場合,指定した更新回数に達した際に学習率を減衰す る.学習率を特定の更新回数で下げることで,算出される学習 誤差をより下げることができ,認識率を向上できる.

一方で、学習率を下げるタイミングを手動で決定するのではなく、学習の過程で自動に決定する方法も提案されている [Zeiler 12, Tieleman 12]. Adaptive Gradient (Ada-Grad) [Duchi 11] は、ネットワークの各パラメータに対し



図 3: Attention Branch Network の構造



図 4: ABN が獲得した Attention map の例

て学習率を設計し,自動で調整しながら学習できる.Ada-Grad をベースとした学習法は,数多く提案される [Zeiler 12, Kingma 14].

#### 5. 視覚的説明

深層学習における画像認識分野では、推論時に注視した領 域をマップで表現した Attention map から判断根拠を解析す る視覚的説明の研究が取り組まれている [Zeiler 14, Zhou 16, Ramprasaath 17]. Attention map の獲得には、勾配を用い た Bottom-up の手法とネットワークの応用値を用いる Topdown の手法の2種類がある. Bottom-up の手法の例として, Guided Backpropagation と Gradient-weighted Class Activation Mapping (Grad-CAM) [Daniel 17] がある. Guided Backpropagation と Grad-CAM は, 逆伝播の特定のクラスに おける正値の勾配のみ用いることで, Attention map を獲得す る. Guided Backpropagation と Grad-CAM は特定のクラス における Attention map を様々なプレトレーニングモデルか ら獲得できるため、CNN の解析手法として広く一般的に用い られている. Grad-CAM は、特定のクラスの出力層のユニッ トから勾配を発生させ、特徴マップを獲得する.そして、順伝 播時における最後の畳み込み層の特徴マップに対して, GAP を施す. GAP により獲得した特徴ベクトルは重みとして使用 し、勾配ベースの特徴マップに対して重み付き和を求める.こ の重み付き和で求めた特徴マップに ReLU を施すことで、特



図 5: Breakout における Attention map の例

定のクラスに対する注視領域を獲得することができる.

視覚的説明における Top-down の手法は,ネットワークが 出力した応答値を用いることで Attention map を獲得できる. Top-down の手法は Attention map を獲得するためにネット ワークを再構築して再学習する必要があるが,順伝播の過程 で各クラスにおける注視領域を獲得できる. Top-down の手法 の代表的な手法である CAM [Zhou 16] は,畳み込み層の応答 値と全結合層の結合重みを用いることで,各クラスにおける Attention map を獲得できる. CAM は全結合層を畳み込み層 に入れ替える等の処理が必要なため,画像分類においては性能 低下を引き起こしやすい.

この問題を解決した Top-down な方法として, Attention Branch Network (ABN) [Fukui 18] がある. ABN は, 図 3 のように Feature extractor と Attention branch, Perception branch の3つのモジュールから構成されている. Feature extractor は、入力画像から特徴マップを抽出するモジュールであ る. Attention branch は, 畳み込み層をベースに構築されたブ ランチであり, Attention map を出力する. Feature extractor は、入力画像から特徴マップを獲得するモジュールである.抽 出した特徴マップは Attention branch へ入力され, Attention map を出力する. ABN は、画像分類をはじめとした歩行者検 出,マルチタスク学習等の様々な画像認識タスクから,図4の ように Attention map を獲得できる.また, ABN はエージェ ントの制御で用いられる深層強化学習へも応用できる. ABN を 深層強化学習へ応用した際に獲得した Attention map を,図5 に示す.図5の例は、Atari ゲームの一つである Breakout を 深層強化学習で操作している例である.図5の結果から、ボー ルを跳ね返す、ブロックの奥でボールが跳ね返る等のゲームス コアを獲得する直前のシーンにおいて, Attention map が強 く反応していることがわかる.

#### 6. おわりに

本稿では、画像認識における深層学習の動向についてまと め、紹介した.画像認識における深層学習の発展により、画像 分類をはじめとした物体検出等の性能を大幅に向上させた.ま た、性能向上だけでなく、深層学習の推論結果に対する判断根 拠を解析する研究も活発に取り組まれている.

#### 参考文献

- [Alex 12] Alex, K., Sutskever, I., and Hinton, G. E.: ImageNet Classification with Deep Convolutional Neural Networks, in *Neural Information Processing Systems*, pp. 1097–1105 (2012)
- [Badrinarayanan 15] Badrinarayanan, V., Handa, A., and Cipolla, R.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling, arXiv preprint arXiv:1505.07293 (2015)
- [Daniel 17] Daniel, S., Nikhil, T., Been, K., Fernanda, B. V., and Martin, W.: SmoothGrad: removing noise by adding noise (2017)
- [Duchi 11] Duchi, J., Hazan, E., and Singer, Y.: Adaptive Subgradient Methods for Online Learning and Stochastic Optimization, *Journal of Machine Learning Research*, Vol. 12, pp. 2121–2159 (2011)
- [Fukui 18] Fukui, H., Hirakawa, T., Yamashita, T., and Fujiyoshi, H.: Attention Branch Network: Learning of Attention Mechanism for Visual Explanation, arXiv preprint arXiv:1812.10025 (2018)
- [Girshick 14] Girshick, R., Donahue, J., Darrell, T., and Malik, J.: Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation, in *Computer Vi*sion and Pattern Recognition, pp. 580–587 (2014)
- [Girshick 15] Girshick, R.: Fast R-CNN, in International Conference on Computer Vision (2015)
- [He 15] He, K., Zhang, X., Ren, S., and Sun, J.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, in *International Conference on Computer Vision*, pp. 1026–1034 (2015)
- [He 16] He, K., Zhang, X., Ren, S., and Sun, J.: Deep Residual Learning for Image Recognition, *Computer Vision and Pattern Recognition*, pp. 770–778 (2016)
- [He 17] He, K., Gkioxari, G., Dollár, P., and Girshick, R.: Mask R-CNN, in *International Conference on Computer Vision* (2017)
- [Huang 17] Huang, G., Liu, Z., Maaten, van der L., and Weinberger, K. Q.: Densely connected convolutional networks, in *Conference on Computer Vision and Pattern Recognition* (2017)
- [Karen 15] Karen, S. and Andrew, Z.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *International Conference on Learning Representations* (2015)
- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A method for stochastic optimization, 1412.6980 (2014)
- [Liu 16] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-y., and Berg, A. C.: SSD : Single Shot MultiBox Detector, in *European Conference on Computer Vision*, pp. 1–15 (2016)

- [Ramprasaath 17] Ramprasaath, S., R., Michael, C., Abhishek, D., Ramakrishna, V., Devi, P., and Dhruv, B.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization, in *International Conference on Computer Vision*, pp. 618–626 (2017)
- [Ren 15] Ren, S., He, K., Girshick, R., and Sun, J.: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, in *Neural Information Process*ing Systems, pp. 91–99 (2015)
- [Russakovsky 15] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L.: ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, Vol. 115, No. 3, pp. 211–252 (2015)
- [Sergey 15] Sergey, I. and Christian, S.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, in *International Conference on Machine Learning*, pp. 448–456 (2015)
- [Szegedy 15] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A.: Going deeper with convolutions, in *Computer Vision and Pattern Recognition*, pp. 1–9 (2015)
- [Tieleman 12] Tieleman, T. and Hinton, G.: Lecture 6.5— RmsProp: Divide the gradient by a running average of its recent magnitude, COURSERA: Neural Networks for Machine Learning (2012)
- [Xie 17] Xie, S., Girshick, R. B., Dollár, P., Tu, Z., and He, K.: Aggregated Residual Transformations for Deep Neural Networks, *Computer Vision and Pattern Recognition*, pp. 5987–5995 (2017)
- [Yuxin 18] Yuxin, W. and Kaiming, H.: Group Normalization, in European Conference on Computer Vision, pp. 3–19 (2018)
- [Zagoruyko 16] Zagoruyko, S. and Komodakis, N.: Wide Residual Networks, in *British Machine Vision Confer*ence (2016)
- [Zeiler 12] Zeiler, M. D.: ADADELTA: An Adaptive Learning Rate Method, 1212.5701 (2012)
- [Zeiler 14] Zeiler, M. D. and Fergus, R.: Visualizing and Understanding Convolutional Networks, in *European* Conference on Computer Vision, pp. 818–833 (2014)
- [Zhou 16] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., and Torralba, A.: Learning Deep Features for Discriminative Localization, *Computer Vision and Pattern Recognition* (2016)

# UNREALにおける補助タスクの適応的選択

Adaptive selection of auxiliary tasks in UNREAL

板谷 英典 \*1 平 Hidenori Itaya Tsuba

平川 翼 \*1 Tsubasa Hirakawa

山下 隆義 \*1 Takayoshi Yamashita 藤吉 弘亘 \*1 Hironobu Fujiyoshi

#### \*1中部大学

#### Chubu University

Deep reinforcement learning has a difficulty to solve a complex problem because such problem consists of a larger state space. To solve this problem, Unsupervised Reinforcement learning and Auxiliary Learning (UNREAL) has been proposed, which uses several auxiliary tasks during training. However, all auxiliary tasks might not perform well on each problem. Although we need to carefully design these tasks for solving this problem, it requires significant cost. In this paper, we propose an additional auxiliary task, called auxiliary selection. The proposed method can adaptively select auxiliary tasks that contributes the performance improvement. Experimental results with DeepMind Lab demonstrate that the proposed method can select appropriate auxiliary tasks with respect to each game tasks and efficiently train a network.

#### 1. はじめに

強化学習とは、数値化された報酬を最大とするために、何 をすべきかを学習する問題である.また、教師あり学習のよう に、どのような行動を選択すれば良いかは教えられず、どの行 動を選択すればより良い結果に結び付くかを見つけ出す問題と なっている.

強化学習は、教師あり学習のように教師信号を用意する必要がない点などから、ロボット制御 [Gu 17] [Rajeswaran 17] やゲーム攻略 [Justesen 17] [Firoiu 17] などの様々なタスクに 応用されている.ゲーム攻略については、Silver ら [Silver 16] のコンピュータ囲碁プログラム AlphaGo がプロ囲碁棋士に 勝利し、非常に注目された.また、Atari2600 のゲーム攻略 において、深層強化学習手法の一つである Deep Q-Network (DQN) [Mnih 15] と呼ばれる手法が提案され、人間を凌駕す るスコアを達成した.DQN は Q 学習 [Watkins 92] と Deep Convolutional Neural Network (DCNN)を組み合わせた手法 であり、画像を入力とする Atari2600 のゲームのように状態 数の多い問題を扱うことを可能にしている.この DQN 以降, 強化学習手法は深層学習を組み合わせた深層強化学習が主流と なった.

強化学習における学習データは、エージェントが環境を探索し 収集する.そのため、学習に寄与するデータを獲得するために時 間を要するという問題がある.そこで、この問題を解決するため に Asynchronous Advantage Actor-Critic (A3C) [Mnih 16] が提案されている.A3Cは、学習で用いる経験の生成を並列に実 行することで高速化し、パラメータの更新を非同期的に行う手法 である.また、A3Cをベースとし、教師なし学習の補助タスクを メインタスクと並列に実行する UNspervised REinfrocsment learning and Auxiliary Learning (UNREAL) [Jaderberg 16] が提案されている.UNREALは、複数の補助タスクを導入す ることによって、ゲームタスクにおいてA3Cより高いスコア

#### 連絡先:

- 板谷 英典:itaya@mprg.cs.chubu.ac.jp
- 平川 翼:hirakawa@mprg.cs.chubu.ac.jp
- 山下 隆義: yamashita@cs.chubu.ac.jp

を達成している.しかし,UNERAL で用いられる全ての補助 タスクは、あらゆる環境において必ずしも有効であるとは限ら ない.また、補助タスクを用いることでメインタスクの学習を 妨げるという問題が存在する.そのため、補助タスクは環境に 応じて適切に設計する必要があるが、適切な補助タスクの設計 は多大な手間と時間を要する.

そこで本研究では、UNREALの補助タスクに着目し、補助タスクを環境に合わせ適応的に選択するタスク Auxiliaty Selectionを導入することで、上記の問題を解決する.最適な 補助タスクの選択には、Auxiliaty Selection により出力され た各補助タスクの重みと、各補助タスクとの損失関数の積を 取ることで実現する. DeepMind Lab [Beattie 16] の3つの ゲームを用いて、UNREAL および各補助タスクのみの場合と スコアを比較することで、本手法の有効性を示す.また、各補 助タスクの選択回数を調査することで、最適な補助タスクを選 択できているか確認する.

#### 2. 関連研究

メインタスクと補助タスクを並列に学習させることでメイン タスクの高精度化を図る手法は様々提案されている. Liebel ら [Liebel 18] は, 自動車の運転シーンにおいて, セマンティック セグメンテーションと深度推定をメインタスクとし、時刻と天 候推定の補助タスクを並列に実行することでメインタスクの精 度向上を実現している. Jaderberg ら [Jaderberg 16] は, 深 層強化学習において, ベースである A3C [Mnih 16] に加えて, 教師なし学習の補助タスクをメインタスクと並列に実行する手 法を提案している.この手法は、3つの異なる補助タスクを用 いることで、DeepMind Lab の迷路攻略タスクにおいて、高 いスコアを獲得している. 1 つ目の補助タスク Pixel Control は画像の画素が大きく変化する行動を学習するタスクである. 2 つ目の補助タスク Value Function Replay は過去の経験を シャッフルし、状態価値関数 V(s) を学習するタスクである.3 つ目の補助タスク Reward Prediction は報酬を獲得した経験 を優先して学習し、未来の報酬を予測するタスクである.

しかし,上記の手法では,メインタスクに適していない補助 タスクを用いた場合,メインタスクの学習を妨げるという問題 が存在する.そのため,補助タスクの導入にはメインタスクに

藤吉 弘亘:hf@cs.chubu.ac.jp



図 1: 提案手法のネットワーク構成

適したタスクを導入する必要がある.そこで,深層強化学習に おいて,上記の問題を解決する手法がいくつか提案されてい る. Tehら [Teh 17] は,蒸留によりタスク間に共通する行動 を捉えた方策を獲得し,学習の妨げを回避することで,学習を 安定させる手法を提案した.この手法は,共有する方策が全タ スクにおいて有効な方策から離れないような制約を導入する ことで,異なるタスク間での頑健性と安定性を獲得している. 一方,提案手法では、メインタスクの学習に有効な補助タスク を適応的に選択することで、メインタスクの学習を妨げること なく,学習の効率化を行う.

Riedmiller ら [Riedmiller 18] は、どの補助タスクの方策を 使用すれば、メインタスクを解決できるか学習する Scheduled Auxiliary Control (SAC-X)を提案している.この手法は、各 補助タスクを低レベルのタスクとして設計し、それぞれの目的 に沿った方策を学習する.そして、SAC により用いる方策を選 択することで、ロボットアームのような報酬が疎である問題を 解決している.一方、提案手法における補助タスクは方策を必 要としないため、UNREAL における Value Function Replay などが使用可能である.また、メインタスクである A3C の学 習に対して、適応的に補助タスクを選択するため、補助タスク を環境に左右されず設計が可能である.

#### 3. 提案手法

UNREAL の補助タスクは、環境によって有効性が異なるた め、メインタスクの学習を妨げるという問題がある。そのた め、環境に合わせた補助タスクの選択が求められる。本研究で は、環境に合わせて用いる補助タスクを適応的に選択するタス ク Auxiliary Selection を提案する。

#### 3.1 Auxiliary Selection

図 1 に Auxiliary Selection を導入した UNREAL のネット ワーク構成を示す. UNREAL の 3 つの補助タスクは, Pixel Control (PC), Value Function Replay (VR), Reward Prediction (RP) である. Auxiliary Selection には, Replay Buffer 内に格納された画像を入力し,状態価値関数  $V_{AS}(s)$  と方策  $\pi_{AS}$ を出力する. 方策  $\pi_{AS}$  は各補助タスクを用いるかどうかを表す 値である. 各補助タスクに対する重みを  $C_{PC} = \{0,1\}, C_{VR} = \{0,1\}, C_{RP} = \{0,1\}$ とするとき,  $\pi_{AS} = (C_{PC}, C_{VR}, C_{RP})$  となる. Auxiliary Selection のネットワークは, 畳み込み層 2層と全結合層1層から構成される.また,他の補助タスクと は異なり,A3Cのネットワークとは共有せず,独立したネッ トワークとして学習を行う.このように,環境に合わせて補助 タスクを適応的に選択することで,補助タスクを設計する際の 効率化を図る.

#### 3.2 損失関数

提案手法の損失関数 *L*<sub>proposed</sub> は, 従来の UNREAL の損失 関数をもとに設計し,式 (1) のように定義する.

$$L_{\text{proposed}} = L_{\text{A3C}} + C_{\text{VR}}L_{\text{VR}} + C_{\text{PC}}\sum_{c}L_Q^{(c)} + C_{\text{RP}}L_{\text{RP}}$$
(1)

提案手法では、Auxiliary Selection から獲得する  $C_{\rm VR}$ ,  $C_{\rm PC}$ ,  $C_{\rm RP}$  と各補助タスクの損失関数の積を取ることで、最適な補助タスクのみを用いた学習を実現する.

また,提案手法の損失関数  $L_{\text{propoped}}$  には, Auxiliary Selection から獲得する  $C_{\text{VR}}, C_{\text{PC}}, C_{\text{RP}}$ を用いている. その ため, Auxiliary Selection の学習を他の補助タスクと同 様に,  $L_{\text{proposed}}$  に基づいて行うと,各補助タスクの重み  $C_{\text{VR}}, C_{\text{PC}}, C_{\text{RP}}$ が0になるように学習されるという問題があ る. したがって, Auxiliary Selection の学習では,  $L_{\text{proposed}}$ とは異なる Auxiliary Selection の損失関数を定義し, A3C と 各補助タスクのネットワークとは独立して学習を行う.

Auxiliary Selection の損失関数は状態価値関数と方策の損 失関数で表すことができる.状態価値関数の損失関数  $L_{ASv}$  を 式 (2),方策の損失関数  $L_{ASp}$  を式 (3) に示す.ここで, $\theta^-$  は 更新前のネットワークのパラメータである.また, $H(\pi_{AS})$  は 局所的な最適解に収束しないように,探索を促進するためのエ ントロピーであり, $\beta$  はエントロピーの正則化項の強さを制御 するパラメータである.

$$L_{\rm ASv} = (r + \gamma V_{\rm AS}(s_{t+1}, \theta^-) - V_{\rm AS}(s_t, \theta))^2$$
(2)

$$L_{\rm ASp} = -\log(\pi_{\rm AS}(a|s))A(s,a) - \beta H(\pi_{\rm AS})$$
(3)

Auxiliary Selection の損失関数は,式(2)の状態価値関数 の損失関数と式(3)の方策の損失関数の和によって表される. 式(4)に Auxiliary Selection の損失関数 L<sub>AS</sub> を示す.

$$L_{\rm AS} = L_{\rm AS}v + L_{\rm AS}p \tag{4}$$



図 2: DeepMind Lab におけるステップ毎のスコア





(a) nav\_mazze\_static\_01

(b) seekavoid\_arena\_01



(c) lt\_horseshoe\_color

図 3: DeepMind Lab の各ゲーム画面

#### 4. 評価実験

#### 4.1 実験環境

本論文では,実験環境として, DeepMind Lab [Beattie 16] を用いる. DeepMind Lab は,一人称視点映像の 3D ゲー ム環境であり,大きく分けて nav\_maze\_static\_01 (maze), seekavoid\_arena\_01 (seekavoid), lt\_horseshoe\_color (horseshoe)の3つのゲームが存在する.

maze は一人称視点の迷路探索ゲームである. 道中にあるリ ンゴを獲得すると+1, ゴールに到達すると+10のスコアを獲 得することが可能であり,時間内に獲得できたスコアを競う ゲームである. エージェントが取りうる行動は,左視点移動, 右視点移動,前へ進む,後ろへ進む,左に平行移動,右に平行 移動の計 6 つである.

seekavoid はステージ内の特定の物体を集めるゲームである. リンゴを獲得すると+1,レモンを獲得すると-1のスコアを獲 得し,時間内に獲得できたスコアを競う.行動については,左 視点移動,右視点移動,前へ進む,後ろへ進む,左に平行移動, 右に平行移動の計6つである.

horseshoe は一人称視点シューティングゲームである.ス

テージ内にスポーンする敵をレーザーで攻撃し倒すと+1のス コアを獲得することが可能であり,時間内で獲得したスコアを 競う.行動については,左視点移動,右視点移動,前へ進む, 後ろへ進む,左に平行移動,右に平行移動,攻撃の計7つで ある.

#### 4.2 実験概要

前述の DeepMind Lab の 3 つのゲームにおいて, ステップ 毎のスコアを比較することで提案手法の有効性を確認する.比 較手法として,全補助タスクを用いた場合 (UNREAL), Pixel Control のみの場合 (PC), Value Function Replay のみの 場合 (VR), Reward Prediction のみの場合 (RP), 提案手法 (proposed) の 5 通りで学習を行う.学習時の各ハイパーパラ メータは変更せず, maze および seekavoid では 50,000,000 ス テップ, horseshoe では 100,000,000 ステップまで学習を行う. また, 1 エピソード内での各補助タスクの選択回数を調査する ことで,最適な補助タスクの選択が実現できているか確認す る. worker 数は 8 で行う.

#### 4.3 実験結果

#### 4.3.1 nav\_maze\_static\_01

nav\_maze\_static\_01 におけるステップ数毎のスコアを図 2 左に示す. maze においては, UNREAL と Pixel Control が 約 110 の高いスコアを獲得している. また, Value Function Replay と Reward Prediction では 0 に近く,全くスコアを獲 得できていないことが分かる. これは,壁の端の画素が大きく 変化する行動を Pixel Control によって獲得することが可能で あり,この行動が maze の迷路攻略に有効である為だと考えら れる. したがって, maze では UNREAL か Pixel Control が 最適な補助タスクの選択であると言える.

提案手法は、UNREAL と Pixel Control と同様のスコアを 獲得できることが分かる.これら2つの結果から、maze にお いて、提案手法は最適な補助タスクと同様に高いスコアを獲得 していることが確認できる.

#### 4.3.2 seekavoid\_arena\_01

seekavoid\_arena\_01 におけるステップ数毎のスコアを図2中 央に示す. seekavoid においては, UNREAL と比較し, Value Function Replay が UNREAL を約 10 スコア上回っている ことが分かる.また, maze で有効な Pixel Control は約 14 であり,高いスコアを獲得できていない.これは,ゲーム画 面の画素が大きく変化する行動がゲーム攻略とは適しておら

表 1:1 エピソードにおける補助タスクの選択回数

| 環境 \ 補助タスク | PC      | VR       | RP      |
|------------|---------|----------|---------|
| 20170      | 435.4   | 487.8    | 369.0   |
| maze       | (48.3%) | (54.1%)  | (41.0%) |
| androwoid  | 0.3     | 300.0    | 0.0     |
| Seekavoiu  | (0.1%)  | (100.0%) | (0.0%)  |
| horachaa   | 8545.1  | 14.1     | 8998.2  |
| norsesnoe  | (94.9%) | (0.1%)   | (99.9%) |

ず, 報酬が密に獲得できるゲームである為, Pixel Control と Reward Prediction が有効ではないと考えられる. したがっ て, seekavoid では Value Function Replay が最適な補助タス クの選択であると言える.

提案手法は、Value Function Replay と同様のスコアを獲得 できることが分かる.これら2つの結果から、seekavoid にお いて、提案手法は最適な補助タスクと同様に高いスコアを獲得 していることが確認できる.

#### 4.3.3 lt\_horseshoe\_color

lt\_horseshoe\_color におけるステップ数毎のスコアを図2右 に示す. horseshoe において, UNREAL が約75 で最もスコア が高く,各補助タスクのみでは Pixel Control が約50 で高いス コアを獲得している.これは,敵を倒す行動が画素を大きく変 化させる行動にあたる為,各補助タスクのみでは Pixel Control が最も有効であったと考えられる.したがって, horseshoe で は UNREAL が最適な補助タスクの選択であると言える.

提案手法は、UNREAL と同様のスコアを獲得できることが 分かる.これら2つの結果から、horseshoe において、提案手 法は最適な補助タスクと同様に高いスコアを獲得していること が確認できる.

#### 4.3.4 選択された補助タスクの解析

各ゲームの1エピソードにおける補助タスクの選択回数を表 1に示す.ここで,選択回数とは50エピソード間の平均の選択 回数であり,括弧内は1エピソード内で選択する割合を表す.1 エピソードの総ステップ数は,mazeでは900,seekavoidでは 300,horseshoeでは9,000である.seekavoidでは最適な補助 タスクである Value Function Replay,horseshoeではPixel Control と Reward Predictionを安定して選択し,mazeでは 全ての補助タスクが同等に選択されている.mazeにおいて, UNREAL と同様に全ての補助タスクを選択するため,最適な 補助タスクである UNREAL と同等のスコアを獲得したと考 えられる.したがって,UNREAL にAuxiliary Selectionを 導入することで,環境に合わせた補助タスクを選択でき,効率 的な学習を実現していると言える.

#### 5. おわりに

本研究では、学習に用いる補助タスクを適応的に選択する タスク Auxiliary Selection を提案した.提案手法では、各補 助タスクの損失関数と Auxiliary Selection により出力する重 みの積を取ることで、学習時における最適な補助タスクの選択 を実現した.これにより、環境に合わせた補助タスクを設計す る必要がなく、補助タスクを用いた学習において、効率化する ことが可能である.DeepMind Lab を用いた実験により、効 率的に学習できることを示した.今後の予定としては、異なる 環境や多様な補助タスクを導入した場合における提案手法の有 効性の調査などが挙げられる.

#### 参考文献

- [Beattie 16] Beattie, C., Leibo, J. Z., et al.: DeepMind Lab, arXiv preprint, arXiv:1612.03801 (2016)
- [Firoiu 17] Firoiu, V., Whitney, W. F., et al.: Beating the World's Best at Super Smash Bros. Melee with Deep Reinforcement Learning, arXiv preprint, arXiv:1702.06230 (2017)
- [Gu 17] Gu, S., Holly, E., et al.: Deep reinforcement learning for robotic manipulation with asynchronous off-policy updates, in *ICRA*, pp. 3389–339 (2017)
- [Jaderberg 16] Jaderberg, M., Mnih, V., et al.: Reinforcement Learning with Unsupervised Auxiliary Tasks, arXiv preprint, arXiv:1611.05397 (2016)
- [Justesen 17] Justesen, N., Bontrager, P., et al.: Deep Learning for Video Game Playing, arXiv preprint, arXiv:1708.07902 (2017)
- [Liebel 18] Liebel, L. and Körner, M.: Auxiliary Tasks in Multi-task Learning, arXiv preprint, arXiv:1805.06334 (2018)
- [Mnih 15] Mnih, V., Kavukcuoglu, K., et al.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, No. 7540, pp. 529–533 (2015)
- [Mnih 16] Mnih, V., Badia, A. P., et al.: Asynchronous Methods for Deep Reinforcement Learning, in *ICML*, pp. 1928–1937 (2016)
- [Rajeswaran 17] Rajeswaran, A., Kumar, V., et al.: Learning Complex Dexterous Manipulation with Deep Reinforcement Learning and Demonstrations, arXiv preprint, arXiv:1709.10087 (2017)
- [Riedmiller 18] Riedmiller, M., Hafner, R., et al.: Learning by Playing – Solving Sparse Reward Tasks from Scratch, in *ICML* (2018)
- [Silver 16] Silver, D., Huang, A., et al.: Mastering the game of Go with deep neural networks and tree search, Nature, Vol. 529, No. 7587, p. 484 (2016)
- [Teh 17] Teh, Y., Bapst, V., et al.: Distral: Robust multitask reinforcement learning, in NIPS, pp. 4496–4506 (2017)
- [Watkins 92] Watkins, C. J. and Dayan, P.: Q-Learning, Machine learning, Vol. 8, No. 3-4, pp. 279–292 (1992)

# ResNetsに対する正則化手法ShakeDrop

#### ShakeDrop Regularization for ResNet Family

山田 良博 \*1 Yoshihiro Yamada 岩村 雅一\*1 Masakazu Iwamura 黄瀬 浩一\*1 Koichi Kise

\*1大阪府立大学

Osaka Prefecture University

Overfitting is a crucial problem in deep neural networks, even in the latest network architectures. In this paper, so as to relieve the overfitting effect of ResNet and its improvements (i.e., PyramidNet and ResNeXt), we propose a new regularization method, named ShakeDrop regularization. ShakeDrop is inspired by Shake-Shake, which is an effective regularization method but can be applied to only ResNeXt. ShakeDrop is even more effective than Shake-Shake and can be successfully applied to not only ResNeXt but also ResNet, and PyramidNet. The important key to realize ShakeDrop is stability of training. Since effective regularization often causes unstable training, we introduce a stabilizer of training which is an unusual usage of an existing regularizer. Experiments reveals that ShakeDrop achieves comparable or superior generalization performance to conventional methods.

#### 1. はじめに

ResNet [He 16] は 100 層を超える多層の Convolutional Neural Network (CNN) を実現し、当時の一般物体認識の世界最高精度を達成した. ResNet の根幹を成す Residual Block は、入力 x に対する出力 G(x) が畳み込み処理  $F(\cdot)$  を用いて下記の式で表される.

$$G(x) = x + F(x) \tag{1}$$

ResNet 以降, Residual Block が式 (1) と同じ形で表され る Wide ResNet [Zagoruyko 16] や PyramdNet [Han 17],  $G(x) = x + F_1(x) + F_2(x) + \ldots$ で表される ResNeXt [Xie 17] (図 1(a)) といった派生手法が提案され,相次いで当時の一般 物体認識における世界最高精度を達成した.

ネットワーク構造の工夫が進む一方で、異なる形の工夫に よって認識精度を向上させた手法が Shake-Shake [Gastaldi 17] (図 1(b)) である. CNN は forward path と backward path からなる一連の学習過程によって、重みを更新する.通常は望 ましい出力に近づくように重みを更新するところを、Shake-Shake は forward path と backward path で異なる乱数を掛 ける「確率的な正則化」によって、敢えて計算を乱す. これは 常識を覆す工夫であったが、Shake-Shake はこの工夫によって 当時の一般物体認識における世界最高精度を更新した. しかし Shake-Shake は Residual Block が  $G(x) = x + F_1(x) + F_2(x)$ で表される一部の ResNeXt を前提としているため、式 (1) の 形で表される ResNet 等に導入出来ない.

本稿では、式(1)で表される ResNet 等に適用できる, Shake-Shake と同様の確率的な正則化手法を提案する.ただし、単にShake-Shake における摂動を式(1)に持ち込むだけでは、強い摂動によって学習が不安定になる.そこで、学習の安定化のために, Stochastic Depth (ResDrop) [Huang 16]で提案された正則化手法を本来の使途とは異なる形で導入する.提案手法は摂動を含む不安定な学習と通常の学習を確率的に切り替える

連絡先:

ことによって,強い摂動の恩恵を享受しつつ,安定した学習を 実現する.その際, Residual Block の F(x) に負の係数をも 乗じる強い摂動を加えることで,従来手法より認識精度を向上 させている.

#### 2. 提案手法

**2.1** Shake-Shake の考察と Single-branch Shake 従来手法 Shake-Shake の確率的な正則化は以下の式で表される.

$$G(x) = \begin{cases} x + \alpha F_1(x) + (1 - \alpha)F_2(x), & \text{in train-fwd} \\ x + \beta F_1(x) + (1 - \beta)F_2(x), & \text{in train-bwd} \\ x + 0.5F_1(x) + 0.5F_2(x), & \text{in test.} \end{cases}$$
(2)

ただし、学習時の forward path、学習時の backward path、デ スト時の forward path 計算をそれぞれ train-fwd、 train-bwd, test と表記している.  $\alpha$ ,  $\beta$  はそれぞれ  $\alpha \in [0,1]$ ,  $\beta \in [0,1]$ の一様乱数である.テスト時には  $\alpha$  及び  $1 - \alpha$ の期待値 0.5 を用いる.

式 (2)の解釈はこれまで与えられていないが, [DeVries 17] の知見に基づくと,次のように解釈できる.まず,式(2)から, Shake-Shake の foraward path では  $F_1(x) \ge F_2(x)$ の内分点 を求めている. [DeVries 17] では,2つのデータの特徴表現の 加重和を取ることで,新たなデータが生成できることが示され ている.すなわち,data augmentation である.したがって, Shake-Shake の forward path では,乱数  $\alpha$  に基づいて,学習 データに含まれないデータが特徴空間で生成されていると考え られる.一方,backward path については,[Gastaldi 17] で 実験的に検討されており, $\beta$  が  $\alpha$  と離れる程,正しく重みが更 新されないことが示されている.すなわち,Shake-Shake は, forward path では特徴空間で新たなデータを生成し,backward path では重み更新を乱していると考えられる.

この知見に基づき,式 (1) の形で表される ResNet 等に適用 可能な正則化として次式を考え, Single-branch Shake と名付

山田 良博: yamada@m.cs.osakafu-u.ac.jp

岩村 雅一: masa@cs.osakafu-u.ac.jp

黄瀬 浩一: kise@cs.osakafu-u.ac.jp



図 1: ネットワーク構造の模式図

ける (図 1(c)).

$$G(x) = \begin{cases} x + \alpha F(x), & \text{in train-fwd} \\ x + \beta F(x), & \text{in train-bwd} \\ x + 0.5F_1(x), & \text{in test.} \end{cases}$$
(3)

ただし  $\alpha$ ,  $\beta$  は Shake-Shake に習って, それぞれ  $\alpha \in [0, 1]$ ,  $\beta \in [0, 1]$ の一様乱数である.テスト時には  $\alpha$ の期待値 0.5 を 用いる.なお, [DeVries 17] では, 2つのデータの特徴表現の 内分点のみでなく, ノイズを加えることで新たなデータを生成 できることを示しており, data augmentation の観点からは, これでも十分に思える.しかし,単に  $\alpha$ , $\beta$  を適用するだけでは 学習が安定しないことが簡単な実験で確認された \*1.そのた め, Single-branch Shake では学習の安定化が必要になる.

#### 2.2 ShakeDrop

Single-branch Shake の否定的な結果は、学習を安定化させ る工夫の必要性を示唆している. そこで, ResDrop を通常とは 異なる目的で用いることを提案する.本来 ResDrop は、深い ResNet の学習時に勾配が消失する問題を解決すべく, 確率的 に選んだ一部の層を無視して学習を繰り返すという手法である. すなわち,学習時に見かけの層数を浅くすることにより,勾 配消失を防ぐ手法である.しかし、この手法は Single-branch Shake にこのまま適用しても学習の安定化にはつながらない と考えられる. 何故なら, Single-branch Shake の問題は層が 深いことでは無く, 重みの更新時に著しい摂動が加えられてい る事である. そこで本研究では、学習時に一部の層を無視する 代わりに, その部分だけ正しく重みが更新されないネットワー クと置き換える.これにより、ネットワーク全体としては正し い重み更新が行われるものの、一部では正しくない重みが更新 され, それらのバランスにより, ネットワークの学習が安定化 しながら強い摂動が加わることが期待できる.この工夫を加え て学習を安定化した手法を ShakeDrop と呼ぶことにする. 提案手法 ShakeDrop には, 確率  $p_l = 1 - \frac{l}{2L}$  のベルヌー

提案手法 ShakeDrop には、確率  $p_l = 1 - \frac{1}{2L}$  のペルメー イ分布の二値乱数  $b_l \in B(p_l)$  による制御を導入する. これは ResDrop で提案された学習安定化手法である Linear Decay Rule に基づく制御である.ただし,*L*と*l*は,入力から数えて *L* 個中*l* 番目の Residual Block を表す.提案手法 ShakeDrop (図 1(d)) は次式で与えられる.

$$G(x) = \begin{cases} x + (b_l + \alpha - b_l \alpha) F(x), & \text{in train-fwd} \\ x + (b_l + \beta - b_l \beta) F(x), & \text{in train-bwd} \\ x + E(b_l + \alpha - b_l \alpha) F(x), & \text{in test.} \end{cases}$$
(4)

ただし  $\alpha$ ,  $\beta$  はそれぞれ  $\alpha \in [-1,1]$ ,  $\beta \in [0,1]$  の一様乱数で ある.また,  $E(\cdot)$  は期待値である. $\alpha$ ,  $\beta$ ,  $b_l$  はパラメータ更新 の度に決定され,二値乱数  $b_l$  は制御に用いられる. $b_l = 1$  のと き $\alpha$ ,  $\beta$  は打ち消され,式(1) になる. $b_l = 0$  のとき,前向き と後ろ向きはそれぞれ  $G(x) = x + \alpha F(x)$ ,  $G(x) = x + \beta F(x)$ となり,式(2) と同様の摂動を含む計算となる.テスト時には 前向きの( $b_l + \alpha - b_l \alpha$ )の期待値を利用する.

予備実験の結果,提案手法 ShakeDrop は下記の条件を満た すネットワーク構造であれば機能することが分かった.

1. 加算の直前に Batch Normalization (BN) が存在する.

2. 加算の直後に ReLU が存在しない.

この2つの条件を満たすものの多くは、EraseReLUとして提 案されたネットワーク構造であり、広範な検証の中でオリジナ ルの構造のエラー率を下回る優れた構造であることが報告され ている [Dong 17].

#### 3. 実験

#### **3.1** ShakeDrop における $\alpha \ge \beta$ の影響

α 及び β について表現可能なパラメータ範囲における実 験結果を表 1 に示す. この結果から, α と β の組み合わせ の効果を確認できる. B( $\alpha = 0$ ,  $\beta = 0$ ) の PyramidDrop (PyramidNet に ResDrop を適用)を除いて, A( $\alpha = 1$ ,  $\beta =$ 1) の PyramidNet のエラー率を下回ったのは, N ( $\alpha = [-1,1]$ ,  $\beta = 0$ ) と O ( $\alpha = [-1,1]$ ,  $\beta = [0,1]$ )だけだった. これらの 中で, O が最も優れていた. この結果に基づき,以降の実験 では O を用いた.

<sup>\*1</sup> PyramidNet-110  $\alpha = 270$  に Single-branch Shake を適用した 場合, CIFAR-100 のエラー率が 77.99%だった.

表 1: CIFAR-100 における複数の  $\alpha \geq \beta$  の範囲での PyramidNet+ShakeDrop の Top-1 error 率の 4 回平均 (%). ただ し, Case A および Case B はそれぞれ PyramidNet [Han 17], PyramidDrop [Yamada 16] と呼ばれる既存手法に該当する.

| Case     | α       | β       | Error (%) |
|----------|---------|---------|-----------|
| A (既存手法) | 1       | 1       | 18.01     |
| B (既存手法) | 0       | 0       | 17.74     |
| С        | 1       | 0       | 20.87     |
| D        | 1       | [0, 1]  | 18.80     |
| Е        | 1       | [-1,1]  | 21.69     |
| F        | 0       | 1       | 99.00     |
| G        | 0       | [0, 1]  | 99.00     |
| Н        | 0       | [-1, 1] | 99.00     |
| I        | [0, 1]  | 1       | 38.48     |
| J        | [0, 1]  | 0       | 19.68     |
| К        | [0, 1]  | [0, 1]  | 18.27     |
| L        | [0, 1]  | [-1,1]  | 20.61     |
| М        | [-1,1]  | 1       | 18.68     |
| Ν        | [-1, 1] | 0       | 17.28     |
| 0        | [-1, 1] | [0, 1]  | 16.22     |
| Р        | [-1, 1] | [-1, 1] | 18.26     |

#### 3.2 従来の正則化手法との比較実験

提案手法 ShakeDrop の有効性を確認するために,一般物体 認識用データセット CIFAR-100 [Krizhevsky 09] を用いて実 験を行った.

Residual Block が式 (1) と  $G(x) = x + F_1(x) + F_2(x)$  で表 されるネットワークを用意し,正則化なし (Vanilla), ResDrop, Shake-Shake, ShakeDrop (提案手法)の認識精度を比較した.  $G(x) = x + F_1(x) + F_2(x)$  で表されるネットワークでは,確 率的な正則化の導入方法として,正則化モジュールを add モ ジュールの前と後に入れる 2 パターンが考えられる.本稿で は後に入れるものを Type-A,前に入れるものを Type-B と 呼称し,それぞれについて検証を行う.ただし実験における 一部のネットワークは、オリジナルのものではなく提案手法 ShakeDrop が適用可能な構造 (EraseReLU) に変更した.

CIFAR-100 結果を表 2 に示す. 提案手法 ShakeDrop は PyramidNet に限らず表 2 中の条件で最も多く最良値を示し ており,優れた正則化として機能していた. また,既存手法 Shake-Shake との比較において提案手法 ShakeDrop は優れた 結果を示している. Type-A と Type-B については, Type-B の方が優れた認識精度を達成する傾向が確認された.

#### 3.3 他手法との比較

最先端との手法の比較では、1800 epoch の Cosine Learning Scheduling [Gastaldi 17] と Random Erasing [Zhong 17] を 導入した PyramidNet-272 ( $\alpha = 200$ )で、提案手法 ShakeDrop が CIFAR-10/100 におけるエラー率 2.31%と 12.19%をそれ ぞれ達成し、正則化無し (Vanilla; その他の条件は同じ)のエ ラー率 3.42%と 16.66%を大幅に下回った.

#### 4. まとめ

ー般物体認識において,従来手法 Shake-Shake に代わる新 たな確率的正則化手法として ShakeDrop を提案し,ResNet 及 びその派生手法での有効性を検証した.CIFAR-100 を用いた 実験によって,提案手法 ShakeDrop による認識精度の改善を確 認した.本研究で提案した学習の安定化の方策は、ShakeDrop に適用した摂動以外でも有用な可能性があり、確率的正則化手 法を今後研究する上での基盤技術になりうると考えている.

本研究は, JST CREST #JPMJCR16E1, JSPS 科研費 #25240028 と#17H01803 補助による.

#### 参考文献

- [DeVries 17] DeVries, T. and Taylor, G. W.: Dataset Augmentation in Feature Space, in *Proc. ICLR Workshop* (2017)
- [Dong 17] Dong, X., Kang, G., Zhan, K., and Yang, Y.: EraseReLU: A Simple Way to Ease the Training of Deep Convolution Neural Networks, arXiv preprint 1709.07634 (2017)
- [Gastaldi 17] Gastaldi, X.: Shake-Shake regularization, arXiv preprint arXiv:1705.07485v2 (2017)
- [Han 17] Han, D., Kim, J., and Kim, J.: Deep Pyramidal Residual Networks, in *Proc. CVPR* (2017)
- [He 16] He, K., Zhang, X., Ren, S., and Sun, J.: Deep Residual Learning for Image Recognition, in *Proc. CVPR* (2016)
- [Huang 16] Huang, G., Sun, Y., Liu, Z., Sedra, D., and Weinberger, K.: Deep Networks with Stochastic Depth, arXiv preprint arXiv:1603.09382v3 (2016)
- [Krizhevsky 09] Krizhevsky, A.: Learning multiple layers of features from tiny images, Technical report, Univ. of Toronto (2009)
- [Xie 17] Xie, S., Girshick, R., Dollár, P., Tu, Z., and He, K.: Aggregated Residual Transformations for Deep Neural Networks, in *Proc. CVPR* (2017)
- [Yamada 16] Yamada, Y., Iwamura, M., and Kise, K.: Deep Pyramidal Residual Networks with Separated Stochastic Depth, arXiv preprint arXiv:1612.01230 (2016)
- [Zagoruyko 16] Zagoruyko, S. and Komodakis, N.: Wide Residual Networks, in *Proc. BMVC* (2016)
- [Zhong 17] Zhong, Z., Zheng, L., Kang, G., Li, S., and Yang, Y.: Random Erasing Data Augmentation, arXiv preprint arXiv:1708.04896 (2017)

表 2: CIFAR-100 における Top-1 error 率 (%). 表記がないものは 1 回の結果であり,<sup>+</sup> は 4 回の結果の平均である.\* は [Han 17] の結果である.

| Methods   | Regularization | Error (%)   |
|---|----------------|-------------|
| PegNet 110  | Vanilla        | +25.38      |
| Conv. DN Dol II Conv. DN odds   | ResDrop        | +22.86      |
| <conv-dn-relu-conv-dn-add></conv-dn-relu-conv-dn-add>   | ShakeDrop      | $^{+}21.81$ |
| ResNet 164 Bettleneck   | Vanilla        | 21.96       |
| Come DN DoL II Come DN DoL II Come DN odd   | ResDrop        | 20.35       |
| <conv-dn-relu-conv-dn-relu-conv-dn-add></conv-dn-relu-conv-dn-relu-conv-dn-add>                     | ShakeDrop      | 19.58       |
| DecNoVt 20.8 64d  | Vanilla        | 20.25       |
| Conv. DN DoLU Conv. DN DoLU Conv. DN odds   | ResDrop        | 20.28       |
| <conv-dn-relu-conv-dn-relu-conv-dn-add></conv-dn-relu-conv-dn-relu-conv-dn-add>                     | ShakeDrop      | 18.66       |
| PuramidNot 110 0270   | Vanilla        | +18.01      |
| CDN Come DN Dol II Come DN odds   | ResDrop        | $^{+}17.74$ |
| <bn-coiv-dn-relu-coiv-dn-add></bn-coiv-dn-relu-coiv-dn-add>   | ShakeDrop      | $^{+}15.78$ |
| PurpenidNet 272 Bettleneck o200   | Vanilla        | *16.35      |
| CDN Come DN D. LU Come DN D. LU Come DN a 14  | ResDrop        | 15.94       |
| <din-coily-din-relu-coily-din-relu-coily-bin-add></din-coily-din-relu-coily-din-relu-coily-bin-add> | ShakeDrop      | 14.96       |

(a) Residual Block がG(x) = x + F(x)で表される場合 (ResNet, ResNeXt, PyramidNet)

(b) Residual Block  $h^{\sharp} G(x) = x + F_1(x) + F_2(x)$  で表される場合 (ResNeXt)

| Methods  | Regularization   | Error (%) |
|--|------------------|-----------|
|  | Vanilla          | 21.75     |
|  | ResDrop Type-A   | 20.44     |
| ResNeXt-164 2-1-40d Bottleneck   | ResDrop Type-B   | 20.21     |
| <conv-bn-relu-conv-bn-relu-conv-bn-add></conv-bn-relu-conv-bn-relu-conv-bn-add>  | Shake-Shake      | 22.51     |
|  | ShakeDrop Type-A | 19.19     |
|  | ShakeDrop Type-B | 18.66     |
|  | Vanilla          | 99.00     |
|  | ResDrop Type-A   | 20.13     |
| ResNeXt-29 2-4-64d Bottleneck  | ResDrop Type-B   | 19.01     |
| $<\!\!\mathrm{Conv}\text{-}\mathrm{BN}\text{-}\mathrm{ReLU}\text{-}\mathrm{Conv}\text{-}\mathrm{BN}\text{-}\mathrm{ReLU}\text{-}\mathrm{Conv}\text{-}\mathrm{BN}\text{-}\mathrm{add}\!>$ | Shake-Shake      | 18.82     |
|  | ShakeDrop Type-A | 18.49     |
|  | ShakeDrop Type-B | 17.80     |

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

# [3E4-OS-12b] 画像と AI (MIRU2019プレビュー) (2)

長原 一(大阪大学)、川崎 洋(九州大学)、岡部 孝弘(九州工業大学)

Thu. Jun 6, 2019 3:50 PM - 5:10 PM Room E (301A Medium meeting room)

# [3E4-OS-12b-01] Neural 3D Mesh Renderer OHiroharu Kato<sup>1</sup>, Yoshitaka Ushiku<sup>1</sup>, Tatsuya Harada<sup>1</sup> (1. The University of Tokyo) 3:50 PM - 4:10 PM [3E4-OS-12b-02] Between-class Learning for Image Classification OYuji Tokozume<sup>1</sup>, Yoshitaka Ushiku<sup>1</sup>, Tatsuya Harada<sup>1,2</sup> (1. The University of Tokyo, 2. RIKEN) 4:10 PM - 4:30 PM [3E4-OS-12b-03] A Generative Framework for Creative Data Based on the Generative Adversarial Networks ORiku Fujimoto<sup>1</sup>, Takato Horii<sup>1</sup>, Tatsuya Aoki<sup>1</sup>, Takayuki Nagai<sup>1,2</sup> (1. The University of Electro-Commnications, 2. Osaka University) 4:30 PM - 4:50 PM [3E4-OS-12b-04] Modeling of prejudice eyes by designers ORyuichi Ishikawa<sup>1</sup>, Kou Izumi<sup>1</sup>, Hidekazu Hayashi<sup>1</sup>, Hiroyuki Fukuda<sup>2</sup> (1. DentsuDigital,Inc, 2. Dentsu,Inc)

4:50 PM - 5:10 PM

### Neural 3D Mesh Renderer

加藤 大晴<sup>\*1</sup> 牛久 祥孝<sup>\*2</sup> 原 Hiroharu Kato Yoshitaka Ushiku T

原田 達也 \*1\*2 Tatsuya Harada

\*<sup>1</sup>東京大学 \*<sup>2</sup>理化学研究所 The University of Tokyo RIKEN

We introduce our paper "Neural 3D Mesh Render" presented at CVPR and MIRU last year. In this work, we proposed a novel renderer that takes a 3D mesh, light, and camera setting and outputs an image. Because "back-propagation" is defined in our renderer, it can be used as a layer of deep neural networks. By using it, we can pass the gradient of a loss into a 3D space through renderer and optimize components there. In experiments, we demonstrated the effectiveness of our renderer by applying it to view-based training of single-view 3D reconstruction, 2D-to-3D style transfer, and 3D DeepDream. We also introduce some papers that use our renderer for other problems.

#### 1. はじめに

本発表は既発表論文 [Kato 18] の紹介である.

2次元画像を受け取り、その背後の3次元世界における何か を推定(最適化)することは、コンピュータビジョンにおける 本質的な課題のひとつである.画像を元に3次元構造を推定 するタスクはその直接的な例であるが、シーン理解、ポーズ認 識などの多くのタスクについても間接的に画像の3次元構造 の推定が必要とされる.

近年では,深層学習によってパイプライン全体を一気通貫 学習するアプローチが広く用いられている.ここでたとえば, 画像を受け取りそこに映る物体の3次元モデルを出力する再 構成器を,2次元画像のみを用いて訓練することを考える.目 的関数として「出力された3次元モデルが,2次元に再投影さ れたときに,正しい画像と同じように見えるか」という規準を 用いる.そのようなパイプラインを図1(上)に示す.このパ イプラインを一気通貫学習するためには,2次元画像上で定義 される目的関数の勾配が,3次元モデルを2次元へ投影するレ ンダラーを通じて3次元世界へと流れ込まなければならない. また,図1(下)に示す「3次元モデルを,2次元画像上で定義 されたスタイルの類似性を高めるように最適化する」というパ イプラインについても同様の処理が必要となる.

この「2次元画像への投影」を深層学習に組み込むことは、ボ クセルと呼ばれる 3D 表現については行われてきた [Yan 16]. しかし、ボクセルはピクセルを3次元に拡張したものであり、 メモリ使用量が解像度の3乗に比例して大きくなるという問 題がある.本研究では、3次元表現として頂点と面の集合から 成るメッシュを対象に、深層学習に組み込めるレンダラーを提 案する.通常のレンダラーには、各ピクセルごとに色をサンプ リングするラスタライズと呼ばれる過程において、ピクセル色 を頂点座標で微分すると常にゼロとなり勾配が流れないという 問題があるため、本研究ではラスタライズに疑似的な勾配を定 義することによってそれを解消する.

#### 2. 提案手法の概略

レンダラーは、3D モデル,照明情報,カメラ情報を受け取 り,画像を出力する.この処理は頂点座標の変換やラスタライ ズなどから成るが、ラスタライズを除くほとんどの処理は微分 が自然に定義されるため、勾配を特別に考える必要はない.

連絡先: {kato,ushiku,harada}@mi.t.u-tokyo.ac.jp



⊠ 1: Pipelines for single-image 3D mesh reconstruction (upper) and 2D-to-3D style transfer (lower).

図 2 (a) のように、1 枚のポリゴンのみから成るシーンを考 える. ラスタライズでは、ピクセルがポリゴンと重なるとき、 ピクセルがそのポリゴンの色で塗られる. 図 2 (b) はピクセル  $P_j$  の色  $I_j$  とポリゴンの頂点の座標  $x_i$  の関係を示している. 頂点  $x_i$  が右に動くと、ポリゴンが  $P_j$  に衝突したときにその ポリゴンの色が変わる. 図 2 (c) はこの関数の微分値を示し、 これはほぼ常にゼロであるため誤差逆伝播がうまく機能しな い. そこで本研究では、逆伝播時にのみ図 2 (b) ではなく図 2 (d) のような関係が成立しているとみなし、その傾きを勾配と する. これによって逆伝播時に「頂点がどちらに動くとピクセ ルの色がどう変わりそうか」という情報を伝えることができ、 レンダラーを含むパイプラインの一気通貫学習が可能となる.

#### 3. 実験

#### 3.1 単一画像 3 次元再構成

図3および表1は、図1(上)のパイプラインを用いて三 次元再構成器を訓練する実験の結果である.データセットは ShapeNetを使用した。メッシュの生成は、予め定義した球の 頂点を移動させることによって実現する.適切に3次元再構成 が行えていることから、2次元画像上でシルエットを比較する

# 3E4-OS-12b-01



 $\boxtimes$  2: Illustration of our method.  $v_i = \{x_i, y_i\}$  is one vertex of the face.  $I_j$  is the color of pixel  $P_j$ . The current position of  $x_i$  is  $x_0$ .  $x_1$  is the location of  $x_i$  where an edge of the face collides with the center of  $P_j$  when  $x_i$  moves to the right.  $I_j$  becomes  $I_{ij}$  when  $x_i = x_1$ .

| Retrieval [Yan 16] | Voxel [Yan 16] | Mesh (ours) |
|--------------------|----------------|-------------|
| 0.4766             | 0.5736         | 0.6016      |

表 1: Reconstruction accuracy measured by voxel IoU. Higher is better. Our mesh-based approach outperforms the voxel-based approach [Yan 16] in 10 out of 13 categories in ShapeNet.

目的関数の勾配がレンダラーを通じて適切に三次元再構成器へ と流れていることがわかる.また,我々の手法で得られるメッ シュにはノイズボクセルに表れるような粗いノイズがなく,ま た再構成の定量的な性能もボクセルを用いる場合を上回る.

#### 3.2 2 次元画像から 3 次元モデルへのスタイル転移

図4は、図1(下)のパイプラインを用いて2次元の画像の スタイルを3次元モデルへと転移する実験の結果である.ス タイルの類似性の計算には [Gatys 16] を用いた.

図からは、ウサギのテクスチャ画像にスタイル画像の色が転移していることや、ティーポットのふたの形が円形からスタイル画像のように直線的な形へと変化していることが読み取れる.これは、提案したレンダラーを用いることでスタイルに関する情報を2次元画像の空間から3次元画像の空間へと適切に流し込めることを示している.

#### 4. まとめ

本研究では深層学習に組み込むことのできるメッシュのレン ダラーを提案し、単一画像3次元再構成と、画像から3次元 モデルへのスタイル転移でその効果を検証した.

提案したレンダラーの応用可能性は本論文で示したものに 留まらない. 既に画像集合からのテクスチャ付きの3次元モ デルの再構成 [Kanazawa 18] や3次元再構成を経由した画像 の編集 [Yao 18] などへと応用されており,今後も様々なタス クへと広がってゆくことが期待される.本研究のソースコード はオンラインで公開している\*<sup>1</sup>. ⊠ 3: 3D mesh reconstruction from a single image. Results are rendered from three viewpoints. First column: input images. Second column: mesh reconstruction (proposed method). Third column: voxel reconstruction [Yan 16].



 $\boxtimes$  4: 2D-to-3D style transfer. The two left images represent initial state of a 3D model and style respectively. The style images are *Thomson No. 5 (Yellow Sunset)* (D. Coupland, 2011) and *Portrait of Pablo Picasso* (J. Gris, 1912).

#### 参考文献

- [Gatys 16] Gatys, L. A., Ecker, A. S., and Bethge, M.: Image style transfer using convolutional neural networks, in *CVPR* (2016)
- [Kanazawa 18] Kanazawa, A., Tulsiani, S., Efros, A. A., and Malik, J.: Learning Category-Specific Mesh Reconstruction from Image Collections, in *ECCV* (2018)
- [Kato 18] Kato, H., Ushiku, Y., and Harada, T.: Neural 3d mesh renderer, in CVPR (2018)
- [Yan 16] Yan, X., Yang, J., Yumer, E., Guo, Y., and Lee, H.: Perspective transformer nets: Learning singleview 3d object reconstruction without 3d supervision, in *NIPS* (2016)
- [Yao 18] Yao, S., Hsu, T. M., Zhu, J.-Y., Wu, J., Torralba, A., Freeman, B., and Tenenbaum, J.: 3D-aware scene manipulation via inverse graphics, in *NIPS* (2018)

<sup>\*1</sup> https://github.com/hiroharu-kato/neural\_renderer

## Between-class Learning for Image Classification

床爪 佑司<sup>\*1</sup> 牛久 祥孝<sup>\*1</sup> Yuji Tokozume Yoshitaka Ushiku 原田 達也 \*1\*2 Tatsuya Harada

\*<sup>1</sup>東京大学 \*<sup>2</sup>理化学研究所 The University of Tokyo RIKEN

We introduce our paper "Between-class Learning for Image Classification" presented at CVPR and MIRU last year. In this paper, we propose a novel learning method for image classification called between-class learning (BC learning). We generate between-class images by mixing two images belonging to different classes with a random ratio. We then input the mixed image to the model and train the model to output the mixing ratio. BC learning has the ability to impose constraints on the shape of the feature distributions, and thus the generalization ability is improved. As a result, we achieved 19.4% and 2.26% top-1 errors on ImageNet-1K and CIFAR-10, respectively.

#### 1. はじめに

本発表では, CVPR 2018 で発表した論文 [Tokozume 18a] について, 先駆けとして ICLR 2018 で発表した論文 [Tokozume 18b] の内容と合わせて紹介する.

音や画像の認識において,深層学習を用いた手法が高い性 能を発揮している.深層学習は,線形分離不可能なデータ空間 から線形分離可能な特徴空間への関数を学習する.限られた学 習データから出来る限り判別的な特徴空間を学習することが, 深層学習における重要な課題である.

そこで本研究では,限られた学習データから判別的な特徴空間を学習できる,深層ニューラルネットワークの新しい教師付 学習手法を提案する.新しい教師付学習手法には,ネットワー ク構造や正則化等の従来の学習技術に影響を与えないこと,限 られた学習データを効率的に使えること,判別的な特徴空間を 学習できること,の3つが求められる.

ここで、判別的な特徴空間とはどのようなものだろうか.ま ず、クラス間の Fisher's criterion [Fisher 36] が大きい特徴空 間は判別的である.Fisher's criterion とは、クラス内分散に 対するクラス間距離の比のことであり、2つのクラスがどの程 度判別的であるかを表す指標である.また、各クラスが無相関 な特徴空間は判別的である.識別タスクでは各クラスを等価に 扱う必要があるため、特徴空間において各クラスが等間隔に並 んでいることが望ましい.本研究ではこれら2つを判別的な 特徴空間の要件とする.

従来の教師付学習では、学習データセットから単一の学習 データを選択し、対応するクラスは1、それ以外は0を出力す るようにニューラルネットワークを学習していた。このような 学習手法では、特徴空間において各クラスが線形分離可能であ れば罰則が与えられないので、特徴空間が判別的になる保証は 無い.本研究ではこの問題を解決する学習手法を提案する。

#### 2. Between-class Learning

#### 2.1 概要と効果

本研究では,深層ニューラルネットワークの新しい教師付学 習手法として,between-class learning (BC learning)を提案 する. BC learning では,以下の手順でモデルを学習する.

- 異なるクラスに属する2つのデータを選択する.
- それらをランダムな比率で合成し、モデルに入力する.
- 合成比率を出力するようにモデルを学習する.



図 1: BC learning による Fisher's criterion の増大.



図 2: BC learning による各クラスの無相関化.

BC learning は、従来の学習技術に影響を与えない.また、デー タの合成によって学習データのパターン数が増えるため、限ら れた学習データを効率的に使うことができる.さらに、判別的 な特徴空間を学習できる効果がある.その理由を以下に示す.

効果 1. Fisher's criterion の増大 図1(左)のように,特 徴空間においてクラス A, B 間の Fisher's criterion が小さい 場合を考える.クラス A, B に属するデータをある比率で合成 してモデルに入力した際に,その特徴量分布(桃色)はクラス A, B のいずれかの特徴量分布と重複することが予想される. このとき,合成するデータの組み合わせによっては,合成した データがいずれかのクラスに分類されてしまい,モデルが合 成比率を出力することができない.そのため,BC learningを 行った場合の損失が大きい.一方,図1(右)のように Fisher's criterion が大きい場合,重複が発生しないため,BC learning による損失が小さい.学習は損失が小さくなる方向に進むため, BC learning によって図1(右)のような Fisher's criterion が 大きい特徴空間が学習される.
|             |                                     | 誤識別  | 率 (%)   |
|-------------|-------------------------------------|--|---|
| モデル         | 学習手法                                | CIFAR-10   | CIFAR-100   |
| 11 層 CNN    | Standard<br>BC (ours)<br>BC+ (ours) | $\begin{array}{c} 6.07 \pm 0.04 \\ 5.40 \pm 0.07 \\ \textbf{5.22} \pm \textbf{0.04} \end{array}$ | $\begin{array}{c} 26.68 \pm 0.09 \\ 24.28 \pm 0.11 \\ \textbf{23.68} \pm \textbf{0.10} \end{array}$ |
| ResNet-29   | Standard<br>BC (ours)<br>BC+ (ours) | $\begin{array}{c} 4.24 \pm 0.06 \\ 3.75 \pm 0.04 \\ \textbf{3.55} \pm \textbf{0.03} \end{array}$ | $\begin{array}{c} 20.18 \pm 0.07 \\ 19.56 \pm 0.10 \\ \textbf{19.41} \pm \textbf{0.07} \end{array}$ |
| ResNeXt-29  | Standard<br>BC (ours)<br>BC+ (ours) | $\begin{array}{c} 3.54 \pm 0.04 \\ \textbf{2.79} \pm \textbf{0.06} \\ 2.81 \pm 0.06 \end{array}$ | $\begin{array}{c} {\bf 16.99 \pm 0.06} \\ {\bf 18.21 \pm 0.12} \\ {\bf 17.93 \pm 0.09} \end{array}$ |
| DenseNet    | Standard<br>BC (ours)<br>BC+ (ours) | $\begin{array}{c} 3.61 \pm 0.10 \\ 2.68 \pm 0.03 \\ \textbf{2.57} \pm \textbf{0.06} \end{array}$ | $\begin{array}{c} 17.28 \pm 0.12 \\ 16.36 \pm 0.10 \\ \textbf{16.23} \pm \textbf{0.07} \end{array}$ |
| Shake-Shake | Standard<br>BC (ours)<br>BC+ (ours) | $\begin{array}{c} 2.86 \\ 2.38 \pm 0.04 \\ \textbf{2.26} \pm \textbf{0.01} \end{array}$          | $\begin{array}{c} \textbf{15.85} \\ 15.90 \pm 0.06 \\ 16.00 \pm 0.10 \end{array}$                   |

表 1: CIFAR-10, CIFAR-100 における実験結果.

**効果 2. 各クラスの無相関化** 図 2 (左) のように特徴空間に おいて各クラスに相関がある場合,クラス A, B の合成物がク ラス C に分類されるケースが発生するため,BC learning の損 失が大きい.一方,図 2 (右)のように各クラスに相関がない 場合,クラス A, B の合成物がクラス C に分類されないため, BC learning の損失が小さい.よって,BC learning によって 図 2 (右)のような各クラスが無相関な特徴空間が学習される.

## **2.2 環境音識別への適用**<sup>\*1</sup>

音はデータ同士を合成しても音として成り立つため,BC learning が有効であると考えられる.選択された 2 つの学習 データをそれぞれ  $\mathbf{x}_1, \mathbf{x}_2$  とし,それらの one-hot ラベルをそ れぞれ  $\mathbf{t}_1, \mathbf{t}_2$  とする.また,合成比率 r を一様分布 U(0, 1)から生成する.ラベルの合成は単純に  $r \mathbf{t}_1 + (1-r) \mathbf{t}_2$  とする. 一方,データの合成は、同様に  $r \mathbf{x}_1 + (1-r) \mathbf{x}_2$  とするのが 単純であるが, $\mathbf{x}_1, \mathbf{x}_2$  それぞれの音圧レベル  $G_1, G_2$  (dBA) の差を考慮した以下の合成式を提案する.

$$\frac{p \mathbf{x}_1 + (1-p) \mathbf{x}_2}{\sqrt{p^2 + (1-p)^2}} \quad \text{where} \quad p = \frac{1}{1 + 10^{\frac{G_1 - G_2}{20}} \cdot \frac{1-r}{r}}$$
(1)

#### 2.3 画像識別への適用

画像を合成することは直感に反するが、画像データは x 軸と y 軸に沿った波であると考えられるので、環境音と同様に BC learning が有効であると考えられる。先程と同様に  $\mathbf{x}_1, \mathbf{x}_2, \mathbf{t}_1,$   $\mathbf{t}_2, r$  を定義する。ラベルの合成は単純に  $r \mathbf{t}_1 + (1-r) \mathbf{t}_2$  と する。データの合成は、同様に  $r \mathbf{x}_1 + (1-r) \mathbf{x}_2$  とするのが 単純であるが、 $\mathbf{x}_1, \mathbf{x}_2$  からそれぞれの平均値  $\mu_1, \mu_2$  を引いて ゼロ平均にしたのちに、環境音と同様に合成することを提案す る。音圧レベルの代わりに各画像の標準偏差  $\sigma_1, \sigma_2$  を用いた 以下の合成式を提案する。前者の単純な合成方法を BC,後者 を BC+と呼ぶことにする。

$$\frac{p\left(\mathbf{x}_{1}-\mu_{1}\right)+(1-p)\left(\mathbf{x}_{2}-\mu_{2}\right)}{\sqrt{p^{2}+(1-p)^{2}}} \quad \text{where} \quad p=\frac{1}{1+\frac{\sigma_{1}}{\sigma_{2}}\cdot\frac{1-r}{r}} \quad (2)$$

## 3. 実験

一般物体画像データセット CIFAR-10, CIFAR-100, および
 ImageNet-1K を用いて学習・評価を行った.まず, CIFAR-10,
 CIFAR-100 における実験結果を表1に示す。多くの条件において、BC learning によって識別性能が向上した.また、BC+の方が BC よりも性能が高い傾向にあった。特に CIFAR-10
 において 2018 年1月現在の世界最高性能 2.26%を達成した。

\*<sup>1</sup>ICLR 2018 で発表した内容.



図 3: ImageNet-1K における実験結果. 破線は 100 epoch, 実 線は 150 epoch での実験結果.



図 4: BC learning によって学習された特徴空間の可視化.

次に, ImageNet-1K における実験結果を図 3 に示す. BC learning によって最終的な誤識別率が 20.4%から 19.4%へ約 1%向上した. BC learning は大規模なデータセットに対して も有効であることが示された.

CIFAR-10 で学習した 11 層 CNN の特徴空間(第 10 層)を PCA を用いて可視化した結果を図 4 に示す. BC learning に よって学習された特徴空間は、各クラスが球状にまとまってい ることが分かる.また、2 クラス間の Fisher's criterion の平 均値も、BC learning の方が大きかった.BC learning によっ て判別的な特徴空間が学習されたといえる.

#### 4. 結論と今後の展望

本研究では、between-class (BC) learning という深層ニュー ラルネットワークの新しい教師付学習手法を提案した.実験の 結果,BC learning によって画像の識別性能が大きく向上する ことが示された.BC learning は、音や画像以外のモダリティ のデータの識別や、識別以外のタスクにも応用が期待される、 非常に汎用性の高い技術である.また、考え方がシンプルで実 装も容易であり、実用性も高い.さらに、理論的考察の余地も あり、今後さらなる研究がなされると考えられる.

- [Tokozume 18a] Y. Tokozume, Y. Ushiku, and T. Harada. Between-class Learning for Image Classification. In CVPR, 2018.
- [Tokozume 18b] Y. Tokozume, Y. Ushiku, and T. Harada. Learning from between-class examples for deep sound recognition. In *ICLR*, 2018.
- [Fisher 36] Ronald A Fisher. The use of multiple measurements in taxonomic problems. Annals of eugenics, Vol. 7, No. 2, pp. 179–188, 1936.

# 敵対的生成ネットワークを利用した 創造的データ生成の枠組み

A Generative Framework for Creative Data Based on the Generative Adversarial Networks

| 藤元陸 *1        | 堀井隆斗 *1                | 青木達哉        | *1 長井隆行          | *1*2 |
|---------------|------------------------|-------------|------------------|------|
| Riku Fujimoto | Takato Horii           | Tatsuya Aol | i Takayuki Na    | agai |
|               | *1 康仁 汤 后 上 ど          | 4           | *2               |      |
|               | 電気通信人子                 | 2.          | 一人 恢 人 子         |      |
| The Univ      | versity of Electro-Com | mnications  | Osaka University |      |

In this research, we propose a framework to generate creative data simulating the creation process. This framework generates new and valuable high dimensional data. The characteristics of this framework are two points, a mixed generator and self-generated data learning. The mixed generator makes it possible to generate new data by loss function of regularization by Feature matching and entropy. In self-generated data learning, expressive ability to generate higher value data is acquired by using highly valued generation data as learning data. The framework for generating new and valuable data by combining these two methods is called "Deep Creative Model(DCM)". In the experiments, MNIST was used as learning data, learning a framework to set alphabet images as valuable images. As learning progresses, it was possible to gradually generate images close to the shape of the alphabet, and it was confirmed that it is possible to generate creative data with DCM.

## 1. はじめに

近 年,主 に 深 層 学 習 技 術 の 発 展 を 受 け,計 算 論 的 創 造 性 に 関 す る 研 究 が 進 展 し て い る [Elgammal 17][Mordvintsev 15][Hawthorne 17][Ha 17]. これらの研究では,人間の創造過程を計算モデルによって模 擬することで創造性に関する知見を深めたり,人間の創造性 を計算機によって拡張することを目的としている.

創造性には「新規性」と「価値」の2つの要素が重要である ことが知られている [Sternberg 99]. 我々はありふれている物 や,一度見たものには創造性を感じにくい.また初見のもので もランダムな文字の羅列のような,一般的に価値の低い物にも 創造性を感じにくい.我々が創造的だと感じるデータは,新規 性が高くかつ価値の高いデータである。例えば,スマートフォ ンは画面を触って直感的な操作が可能なため,従来のボタンで 操作する携帯電話に対して革新的である。今ではスマートフォ ンは一般的な製品であるが,発売当初はその操作方法の新規性 が高く,かつ,利便性という価値を兼ね備えていたため創造的 な製品であった。

このように、創造的なデータを生成するモデルとして、「新 規性」と「価値」の両方を兼ね備えたデータを生成すること が求められる.様々なデータを生成する手法として敵対的生 成ネットワーク (GAN)[Goodfellow 14] や Variational Auto Encoding(VAE)[Kingma 13],Glow[Kingma 18]が注目され ている.しかし、既存の生成モデルでは学習データに対して生 成データの尤度が最大になるように学習している.学習データ 外のデータ、つまり学習データにとっての新規データは、学習 時にはエラーとして扱われる.そのため既存の生成モデルに よってモデルがこれまでに学習したことのないような新規デー タを生成することは困難である.

創造的な作品の多くは、多数の失敗作の上に成り立ってい る.作品の目標を定め、制作し、評価するという工程を繰り返 すことでより創造的な作品を作り出すことができる.このよう な創造的な作品を制作する過程では、製作者本人はどのような 作品に価値があるかわからない場合もある.その場合、他人に

連絡先: 藤元陸 (rfujimoto@apple.ee.uec.ac.jp)



図 1: GAN, 混合生成器, DCM の比較.

作品の評価してもらったり、工業製品であれば実際に使用する ことで価値を判定したりする.このように、外的な評価によっ て作品の価値を算出し、その価値をもとに作品を製作すること で、作品の価値を高めることができる.

筆者らは上記の過程を模擬することで,新規データの生成 と外的な評価による価値の算出を繰り返し,創造的なデータを 生成する枠組みを提案する.本稿では生成モデルが学習データ の表現を保持しつつ新規データを生成するための手法と,価値 情報に基づいて生成モデルの表現空間を拡張する手法について 説明する.さらに提案手法において,学習データに含まれてお らず,かつ価値の高いデータを提案手法を用いて実際に生成す ることで,創造的なデータの生成が可能であることを示す.

#### 2. 関連研究

#### 2.1 敵対的生成ネットワーク

GAN は生成器と識別器で構成される.生成器の目的は画像 を生成することであり、識別器の目的は生成器の生成画像と学 習データの画像を見分けることである.学習データセットの データ分布を  $P_x$ ,生成器 に入力するノイズの分布を  $P_z$ ,生 成器の出力を G(z),生成データの分布を  $P_G$ ,識別器の出力 を D(x)とする.このとき,GAN の学習は以下のミニマック スゲームで表すことができる.

$$\min_{G} \max_{D} V(D,G) 
= (\mathbb{E}_{x \sim P_x} \log(D(x)) + \mathbb{E}_{z \sim P_z} \log(1 - D(G(z))))$$
(1)

#### 2.2 補集合分布

創造性において新規性は重要な要素であり,新規データを生 成することは創造的なデータの生成に必要不可欠である.し かし式 (5) に従って最適化された GAN では,  $P_G = P_x$  とな るため新規データを生成することはできない (図 1(a)).新規 データを生成するためには  $P_G \neq P_x$  とする必要がある.その ため, GAN が最適化されないようにモデルを設計する必要が ある.

Dai[Dai 17] らは半教師有りマルチクラス分類タスクの分類 精度上昇のために,GAN で新規データを生成する手法を提案 した.この研究では,生成器は学習データの補集合を生成する ように学習した.生成器の損失関数 L<sub>G</sub> は次式で定義される.

$$L_G = -H(G(z)) + \mathbb{E}_{x \sim P_G} \log P(x) \mathbb{I}[P(x) > \epsilon]$$
  
+  $||\mathbb{E}_{z \sim P_Z} f((G(z)) - \mathbb{E}_{x \sim P_X} f(x)||^2$  (2)

この損失関数の第三項は Feature matching[Salimans 16] によ る損失である. Feature matching は学習データと生成データ に対する識別器の中間層の期待値を一致させるため,生成デー タ分布が学習データ分布に近くなることを間接的に強いる.生 成器の損失関数を Feature matching のみで構成すると,通常 の損失関数と比べて生成データ分布と学習データ分布を一致さ せる力が小さいため,学習データ多様体上とその周囲からデー タを生成することが期待できる.つまり,学習データ分布内で は  $P_G < P_x$  となり,データ分布外では  $P_G > P_x$  となる.

しかし Feature matching では特徴の期待値を一致させてい るため、生成データが平均に偏り、モード崩壊することがある. そこで、第一項では生成データのエントロピーの最大化を行っ ている.これにより、似たデータを多く生成するとペナルティ が与えられるため、モード崩壊せず広範囲から生成されるよう になる.生成データのエントロピーの計算は、Zhao[Zhao 16] らの pull-away 項が用いられた.N をミニバッチのサイズ、  $G(z_i をミニバッチの i 番目のデータとすると、式(3) の L_{PT}$ で式(2)の第一項 -H(G(z))が近似される.

$$L_{PT} = \frac{1}{N(N-1)} \sum_{i=1}^{N} \sum_{j \neq i}^{N-1} \left( \frac{f(G(z_i))^{\top} f((G(z_j)))}{\|f((G(z_i))\| \|f((G(z_j))\|)\|} \right)^2$$
(3)

第二項は学習データの高密度領域から生成しないための項 である. I は指示関数であり、条件に合うときは 1 を、合わ ないときは 0 を返す関数である. データが学習データの分布 において存在確率がある値  $\varepsilon$  より大きいときペナルティを与 えるようにし、データ分布  $P_x$  の低密度領域から生成するよ うに強いている. さらに、学習データの分布密度  $P_x$  の推定 は PixelCNN++[Salimans 17] が利用されている. 学習デー タセットで事前学習し、生成器の学習中はネットワークの重み は固定して使用された.

まとめると,第三項が生成データ分布を学習データ分布に 近づけ,第一項が多様なデータを生成する働きをする.第二項 は学習データを生成しないようにする.これら三つの項を含む 損失関数を最小化することで,学習データ空間の周囲からデー タの生成が可能になる.





図 3: Deep Creative Modelの模式図.

#### 3. 提案手法

#### 3.1 創造的なデータ生成手法の概念

図2は提案アイディアの概念図である.本提案はデータの 生成,評価,学習の3つのフェーズに分かれる.

- 1. 学習データを学習した生成モデルでデータを生成する.
- 2. 生成したデータの価値を外部の評価器で評価する.
- 3. 評価の高いデータを学習データに追加し,生成モデルを 再学習する.

ここで、生成モデルが学習データより多様なデータを生成 可能ならば、学習データに含まれないデータを生成することが できる.そのデータを学習データに加えることで、より多様な データを生成できるようになる.同様に、学習データに含まれ ない価値の高い生成データを学習データに加えることでより 価値の高いデータが生成可能になる.そのため、生成、評価、 学習のプロセスを繰り返すことで徐々に価値の高いデータを生 成できるようになる.そこで上記のプロセスを実現するために 学習データより多様なデータを生成可能な生成モデルとして 混合生成器を提案する.さらに、混合生成器がより価値の高い データを埋成可能にする手法として価値情報を用いた自己生成 データ学習を提案する.

#### 3.2 エントロピー項を用いた混合生成器

学習データの表現を保持しつつ,新規データを生成する手法 として混合生成器を提案する.混合生成器の損失関数 *L*<sub>G</sub> には

$$L_G = -H(P_G) + ||\mathbb{E}_{x \sim P_G} f(x) - \mathbb{E}_{x \sim P_x} f(x)||^2 \qquad (4)$$

を提案する.これは,式(2)の第二項を除いたものである.式 (2)の第二項は学習データに似たデータを生成しないようにす る働きがある.そのため、学習データ分布内に価値の高いデー タがあるとき,式(2)の第二項を用いると最も価値の高いデー タを生成することができない.また後述の自己生成データ学 習の手法によって学習データが学習中に逐次変更されるため、



図 4: (a) 最も価値の高い画像 X<sub>s</sub> (b) 生成画像の中で最も価値の高い画像.

PixelCNN++を変更された学習データセットで再学習する必要があり,式(2)の第二項の計算コストが非常に高い.

式(2)の損失関数で学習した生成器は学習データ分布の高密 度領域の周囲データの生成を可能にした.一方,式(4)の損失 関数で学習した生成器は学習データ分布の高密度領域とその周 囲のデータの生成が可能である(図1(b)).

## 3.3 価値情報を用いた自己生成データ学習

混合生成器は、学習データ分布の高密度領域とその周囲の データを生成する.しかし、生成できるのは学習データの高密 度領域の周囲までであり、学習データ分布の高密度領域からよ り遠いデータを生成することはできない.混合生成器の表現空 間を拡大するためには、学習データがより多様になればよい. そこで、学習データ分布の高密度領域の周囲のデータを学習 データに加えて再学習する.

しかし,学習データ分布の高密度領域の周囲の大部分のデー タは価値の低いデータであると考えられる.そのため,混合生 成器からサンプルしたデータを全て学習データとして用いる と,学習データの大半が価値の低いデータになる.表現空間を 価値の高い方向にのみに拡大するために,学習データに加える データを価値の高い生成データに限定する.

#### 3.4 創造的データを生成するモデル

上記の提案手法である混合生成器と自己生成データ学習 を用い、創造的なデータを生成するモデル Deep Creative Model(DCM)を提案する.図3にDCMの構造を示す.DCM は GAN に混合生成器と自己生成データ学習の二つの変更を 加えたものである、通常の GAN のネットワークの損失関数を 変更し,混合生成器を学習する.外部の価値評価器で混合生成 器から生成されるデータの価値を評価する.価値の高いデー タは学習データ X<sub>V</sub> として保持する.識別器は真の学習デー タ X<sub>R</sub> と生成した価値の高いデータ X<sub>V</sub> を学習データとして 用い, True と判定するように学習する.一方, 混合生成器が 生成したデータ G(x) は False と判定するように学習する. 混 合生成器は識別器を騙すために、 $X_R$  と  $X_V$  の分布を学習す るとともに、その周囲のデータも生成できるように学習する. 学習が進むにつれて X<sub>V</sub> として保持されるデータは徐々に価 値の高いデータとなり, 混合生成器の表現空間も価値の高い方 向に拡張されることが期待できる (図 1(c)).

#### 4. 実験

#### 4.1 実験設定

手書き数字画像のデータセット MNIST を用いて DCM を 学習させた.価値は主体や環境によって異なるものであり,絶 対的な価値は存在しない.そこで、本実験での価値は計算の簡 便性の理由で、MNIST データセットにアルファベット画像を 加えた EMNIST[Cohen 17] に含まれる特定のアルファベット 画像と生成画像のピクセル間距離とした.つまり、最も価値の 高い画像を  $X_s$ ,生成した画像を X としたとき、画像 X の価 値 V(X) は

$$V(X) = -(X_s - X)^2$$
 (5)

となる. EMNIST のアルファベット画像は価値の評価にの み使い, 混合生成器の学習には使用しなかった. 自己生成デー タ学習では、100step ごとに混合生成器は 60000 枚データをラ ンダムに生成し、その中から価値の高いデータ 6000 枚を  $X_V$ として追加した.  $X_V$  に追加後、価値の高い 6000 枚以外のデー タは破棄した. 学習データは  $X_R$  と  $X_V$  が 1:1 の割合になる ようにサンプリングした.

モデルの評価は次の2つの観点で行った.

- 1. 学習初期には生成できない画像を学習後に生成できるか 定性的に評価する.
- 2. 生成画像の価値が学習によって上昇するかを定性的・定量的に評価する.

これらの評価によって, DCM の生成器が新しく価値の高い データつまり創造的なデータを生成できることを確認する.

#### 4.2 実験結果

#### 4.2.1 DCM の生成画像の定性的評価

DCM の学習結果を図 4 に示す. 図 4(a) は最も価値の高い 画像  $X_s$  であり, 図 4(b) は各  $X_s$  を価値関数に用いて DCM を 学習させたときの最も価値の高い生成画像である. (a) と (b) の画像はほぼ同じ形状になっており, DCM で MNIST データ から価値情報を用いてアルファベットの画像を生成することが できた. MNIST のデータセットに似た形状の文字が存在しな い K, N, R, W の文字も生成できており, DCM が学習デー タに含まれていないデータを生成できることが示された. こ のことから, DCM で新規データの生成が可能であることがわ かる.

図5はDCMの学習過程の各段階の最も価値の高い生成画 像である.学習初期の段階ではアルファベットとして形を成し ていない画像が生成された.しかし,学習が進むにつれて徐々 に形状が変化し最も価値の高い画像に似た画像が生成された. 学習の最初の段階では MNIST データのみで事前学習したモ デルで生成しており,このモデルでは混合生成器の表現空間内 に文字 K, N, R, W に似た形状の画像が存在していないこと がわかる.自己生成データ学習により価値の高い生成データを 混合生成器の学習データに加えることで,学習が進むにつれて 表現空間が価値の高い方向へ拡張されることがわかる.

## 4.2.2 DCM の価値の推移による定量的評価

図 6 は学習過程の特徴的な価値の推移を示した画像を対象 に図示した.価値の最大値は 0,最小値は-784 である.学習初 期の価値が最大の文字は I,最小の文字は W,収束時の最大の 文字は J,最小の文字は R であった.K,N は一般的な価値の 推移の例として図示した.学習初期と比較して収束時は全ての 文字画像の学習条件で価値が上昇した.文字 I や J は学習初期 の段階で,既に収束時に近い価値となっている.これは数字の 1 に形状が近いため,MNIST で学習させた混合生成器が生成 しやすいことが理由である.一方,数字データと形状が大きく 異なる文字 R や W は学習初期の段階では価値が低い.学習が 進むにつれて徐々に価値が上昇し,収束時には他の画像と同程 度の価値まで上昇した.これにより,DCM は生成器の表現空 間と価値の高いデータの空間が乖離している場合にも生成デー タの価値を上昇させる能力があることが定量的に示された.



図 5: 学習過程の生成データの推移.



図 6: 学習による価値の推移

以上の評価より, DCM は学習データに含まれていないデー タつまり新規テータを生成する能力があることと, 生成データ の価値を上昇させる能力があることがわかる.よって, DCM は新しく価値のあるデータつまり創造的なデータを生成する能 力がある.

## 5. まとめと今後の課題

本研究では創造的なデータを生成する枠組みを提案した.こ のモデルは、学習データに含まれておらず、かつ価値の高い データ、つまり創造的なデータの生成を行う.このモデルの特 徴は混合生成器と自己生成データ学習の2点である.混合生 成器は Feature matchingとエントロピーによる正則化の損失 関数によって、新規データの生成を可能にした.自己生成デー タ学習では、価値の高い生成データを学習データとして用いる ことで、より価値の高いデータを生成するための表現能力を獲 得した.実験では MNIST データから、アルファベット画像を 生成可能であることを確認した.

今後は絵画などの複雑なデータを用いて提案モデルの創造 的データ生成能力を検証する.また,価値の算出を分類器の分 類結果に変えるなど,より抽象的な価値関数で検証する.

## 謝辞

本研究は JST CREST(JPMJCR15E3) の支援を受けた.

- [Cohen 17] Cohen, G., Afshar, S., Tapson, J., and Schaik, van A.: EMNIST: an extension of MNIST to handwritten letters, arXiv preprint arXiv:1702.05373 (2017)
- [Dai 17] Dai, Z., Yang, Z., Yang, F., Cohen, W. W., and Salakhutdinov, R. R.: Good semi-supervised learning that requires a bad gan, in Advances in Neural Information Processing Systems, pp. 6510–6520 (2017)
- [Elgammal 17] Elgammal, A., Liu, B., Elhoseiny, M., and Mazzone, M.: CAN: Creative adversarial networks, generating" art" by learning about styles and deviating from style norms, arXiv preprint arXiv:1706.07068 (2017)
- [Goodfellow 14] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y.: Generative adversarial nets, in *Advances in neural information processing systems*, pp. 2672–2680 (2014)
- [Ha 17] Ha, D. and Eck, D.: A neural representation of sketch drawings, arXiv preprint arXiv:1704.03477 (2017)
- [Hawthorne 17] Hawthorne, C., Elsen, E., Song, J., Roberts, A., Simon, I., Raffel, C., Engel, J., Oore, S., and Eck, D.: Onsets and frames: Dual-objective piano transcription, arXiv preprint arXiv:1710.11153 (2017)
- [Kingma 13] Kingma, D. P. and Welling, M.: Auto-encoding variational bayes, arXiv preprint arXiv:1312.6114 (2013)
- [Kingma 18] Kingma, D. P. and Dhariwal, P.: Glow: Generative flow with invertible 1x1 convolutions, in Advances in Neural Information Processing Systems, pp. 10236–10245 (2018)
- [Mordvintsev 15] Mordvintsev, A., Olah, C., and Tyka, M.: Inceptionism: Going deeper into neural networks, *Google Re*search Blog. Retrieved June, Vol. 20, No. 14, p. 5 (2015)
- [Salimans 16] Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., and Chen, X.: Improved techniques for training gans, in Advances in Neural Information Processing Systems, pp. 2234–2242 (2016)
- [Salimans 17] Salimans, T., Karpathy, A., Chen, X., and Kingma, D. P.: PixelCNN++: A PixelCNN Implementation with Discretized Logistic Mixture Likelihood and Other Modifications, in *ICLR* (2017)
- [Sternberg 99] Sternberg, R. J.: Handbook of creativity, Cambridge University Press (1999)
- [Zhao 16] Zhao, J., Mathieu, M., and LeCun, Y.: Energybased generative adversarial network, arXiv preprint arXiv:1609.03126 (2016)

デザイナーが持つ審美眼のモデル化

Modeling of prejudice eyes by designers

| 石川 隆一*1          | 和泉 興*1       | 林 秀和*1           | 福田 宏幸*2         |
|------------------|--------------|------------------|-----------------|
| Ryuichi Ishikawa | Kou Izumi    | Hidekazu Hayashi | Hiroyuki Fukuda |
|                  |              |                  |                 |
| *1 株式会社電道        | <b>通デジタル</b> | *2               | 株式会社電通          |
| Dentsu Digit     | al Inc       |                  | Dentsu Inc      |

Abstract: Research based on human aesthetic sense has been done many times, but that is the theme of this research. In this study, we conducted an experiment to model the aesthetic sense of designers using convolution neural network (CNN) and gradient boost decision tree (GBDT). Moreover, in the proposed method, accuracy was improved by adding colors and character data extracted from other than CNN as new features. The effectiveness of the proposed method was verified by multiple patterns and confirmed.

## 1. はじめに

第三次人工知能ブームの最中にある現在、AIが人間の仕事 をどこまでこなす事が可能か、といった研究が盛んに行われて いる。近年では自動運転や画像生成など極めて高度なタスクも、 AIがこなせるような時代に突入しつつある。

それでも人間が持つ感性は、曖昧な情報であり数値に置き 換えることが難しい。特に絵画や小説など芸術の分野に関して 言えば、未だに人間の能力に替わる性能を持つ AI が存在する とは言い難く、現在も心理や感性に基づく予測や生成の研究は 模索が続いている。デジタル広告の世界においても、例えば無 数の画像パターンからセレクトする作業はデザイナーなど美的 感性を持つ限られた人でなければ難しいが、その煩雑な作業を 軽減するために、AI による作業の代行が今求められている。

本研究は、バナー制作におけるデザイナーの持つ審美眼の モデル化を行う事で、膨大な画像の中からAIによる分類予測を 利用し、作業の効率化を図る事である。

## 2. 関連研究

## 2.1 CNN による特徴抽出

これまでも CNN を特徴抽出器として利用する Deep Convolutional Activation Feature(DeCAF)[Donahue 13]の研究 は数多く存在する。

学習済みの VGG16 を用いた Image Captioning[Lin 14] も CNN を特徴抽出器として利用し、別の深層学習モデルに入力 することで、画像から画像の説明文を生成することを可能にした。 先行研究を踏まえ、本研究でも CNN を特徴抽出器として利用 した。

## 2.2 CNN によるテクスチャーの抽出

近年の研究によると、Convolution Neural Network(CNN)では、 入力近くの層で形状の情報を抽出しており、層を進むにつれテ クスチャーを重視して特徴を抽出している事が解明されてきて いる。[Geirhos 19] その特性を生かしたアルゴリズムとして、 Style Transfer[Li 16]が考案された。Style Transfer は ImageNet にて学習済みの VGG16[Simonyan 15]から特徴抽出をしたテク スチャーを利用し、画像を別画像のスタイルへと変換する手法 である。

先行研究によるテクスチャーを重視して特徴を抽出している ことを踏まえ、特徴抽出器から抽出される特徴以外にも有効な 情報を抽出可能だと考えた。

## 3. 提案手法

図1に提案手法の構造図を示す。本研究では ResNet50[He 16]を用いて全結合層(Global Average Pooling 層)から画像ベクトルの抽出を行った。抽出後の画像ベクトルに対し、オリジナル の画像から色彩と文字に関する情報を新たに抽出して加えるこ とで、精度の向上を試みた。またレクタングル広告をデザイナー の美的感性により、良し悪しで振り分けられた 2 分類のデータを 使用し学習・検証を行った。



図1 提案手法の構造図

#### 3.1 画像のリサイズ手法

本研究では、レクタングル広告(長方形の画像)を学習対象としているため、学習済みのCNNモデルを使用するにあたり画像を224px×224px ヘリサイズする必要があった。しかし通常の手法でリサイズを行ってしまうと引き伸ばされてしまうため、アスペクト比を維持したまま、長辺が224px になるよう縮小した。また正方形になるよう足りない部分をゼロパディングで埋めることでリサイズをおこなった。convolution層の特性を考慮し、ゼロパディングを用いて穴埋めする手法が、最もCNNの特徴抽出に悪影響を及ばさないと考えた。

## 3.2 色彩情報

図2に手法の図を示す。デザイナーが持つ美的感性はCNN により抽出することが可能な特徴やエッジ以外にも、色の配置 や色彩の情報が大きく関与すると考えた。

そのことを考慮した上で、機械学習のモデルで学習するにあたり、更なる特徴の追加を試みた。その手法として、リサイズ前

のオリジナル画像とリサイズ後の画像全体の RGB の各平均値 を算出した。またリサイズ後の画像を縦と横で3分割し、その RGB 各平均値を算出し新たな特徴として追加した。結果として 計32の特徴からなるデータを追加することで精度の向上を図っ た。



図2新たな色彩情報の取得図

## 3.3 文字に関する情報

色彩情報以外に、バナー広告におけるデザイナーの審美に は、文字の情報も重要であると考えた。Optical Character Recognition (光学的文字認識)を用いて、取得したバウンディン グボックスにより縦と横の長さから文字の占める面積を算出し、 画像に対して文字が占める面積の割合と文字数・単語数・文章 数(計4特徴)を新たな特徴として追加することで、CNN では抽 出しえない文字量やデザイン性といった情報を再現し、精度向 上を計った。

## 3.4 画像の特徴抽出

ImageNet にて学習済みの ResNet50 を用いて特徴抽出を行った。全結合層に当たる Global Average Pooling 層(2048 次元) から特徴を抽出し、抽出したデータを分類器の入力とすることで、 機械学習のモデルでも学習することを可能にした。抽出した特 徴に対し、前節で作成したデータ(計 36 特徴)を追加し、新たに 特徴量 2084 の学習データを作成した。

#### 3.5 Light GBM による分類予測

これまでの研究では画像の特徴を抽出したのちに Support Vector Machine(SVM)を用いて、分析にあたる研究が多く存在 した。しかし本研究では、機械学習競技の優勝ソリューションで 広く使用されている Light GBM を分類器として利用した。Light GBM は 2017年に Microsoft によって発表されたアルゴリズムで あり、決定木を元に考案された GBDT(Gradient Boosting Decision Tree)のモデルである。欠損やカテゴリー変数が存在し ていても学習することが可能であり、外れ値にも強く学習にかか る時間が短いことが[Ke 17]によって示されている。

## 4. 実験

## 4.1 データ

本実験では、実際にバナー制作に携わるデザイナーに協力 いただき、良し悪し(良:2172 枚・悪:2828 枚)で分けられたデータ を正解ラベルとして使用した。実験に伴い特徴追加前のデータ (5000×2048)と特徴追加後のデータ(5000×2084)を使用し、 提案手法の有効性を測った。またデータの20%を検証データに 当てた。

## 4.2 評価

評価指標として Accuracy と Receiver operating characteristic (ROC)解析を実施し, Area under curve (AUC)を算出する事で 精度を測った。ROC-AUC は最大値が1.0であり、値が1.0 に近 いほど分類モデルの性能が高いことを意味する。ROC 曲線及 び ROC-AUC の結果を図 3 に示す。



## 4.3 モデル

Light GBM 学習時のハイパーパラメーターの条件を表1に示 す。損失関数には2分類に伴い binary log loss を使用した。ま た提案手法の有効性を確認するために、ImageNet[Deng 09]に て学習済みの ResNet50を利用した。さらに CNN モデルの精度 を最大限に上げるため、転移学習を行い全結合層のみを学習 し直す事で精度の比較を実施した。

表1 Light GBM ハイパーパラメーター

| パラメーター名                 | 数値    |
|-------------------------|-------|
| learning_rate           | 0.005 |
| num_leaves              | 36    |
| min_data_in_leaf        | 5     |
| min_sum_hessian_in_leaf | 20    |
| max_depth               | 9     |
| n_estimators            | 10000 |

#### 4.4 検証結果

検証結果を表2・図4に示す。検証結果として表2から分かるように提案手法により特徴を加えることで loss・Accuracy・AUCの全てにおいて、多少の精度の向上が認められる。また Light GBM による特徴の重要性の上位15 特徴に色彩や文字数と文

字範囲の情報が反映されていることも検証結果から認められる。 さらに転移学習を用いたとしても、ResNet50単体での分類のタ スクを行うより、特徴抽出後にLight GBM にかけると精度の向上 が認められた。

| 表 2 実験結果       |       |          |      |  |  |  |
|----------------|-------|----------|------|--|--|--|
| モデル            | loss  | Accuracy | AUC  |  |  |  |
| ResNet50       | 0.548 | 0.728    | 0.79 |  |  |  |
| Light GBM      | 0.486 | 0.772    | 0.84 |  |  |  |
| Light GBM+特徴追加 | 0.478 | 0.780    | 0.85 |  |  |  |

- [Donahue 13] Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E., and Darrell, T. Decaf: A deep convolutional activation feature for generic visual recognition. CoRR, abs/1310.1531, 2013
- [Lin 14] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollar, and C. L. Zitnick. Microsoft coco: Com- 'mon objects in context. arXiv preprint arXiv:1405.0312, 2014.
- [He 16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in CVPR, 2016.
- [Ke 17] Ke, G.Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., Liu, T.Y.:
- LightGBM:A highly efficient gradient boosting decision tree. In: Advances in Neural Information Processing Systems. 2017
- [Deng 09] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei. ImageNet: A Large-Scale Hierarchical Image Database. In CVPR09, 2009



## 5. おわりに

本研究では、デザイナーによる美的感性によって振り分けられたバナー広告を使用し、新たな特徴抽出を行うことで精度の向上を試みた。実験結果として、色彩と文字データを追加することにより、多少精度が向上することが確認できた。またAccuracy 78%の精度があるモデルの再現に成功したことで、デザイナーの仕事の工数削減が期待できる。

オリジナルの画像から新たな特徴を抽出し追加する手法が 様々なタスクで有効であれば、深層学習の更なる進化につなが るのではないだろうかと考えている。今後、本研究により確認で きた画像から抽出した特徴の有効性が、デザイナーの持つ美 的感性以外のタスクにおいても有効であるか検証したいと考え る。

- [Geirhos 19] Geirhos, Robert, et al. "ImageNet-trained CNNs are biased towards texture; increasing shape bias improves accuracy and robustness." arXiv preprint arXiv:1811.12231 (2018).
- [Li 16] Li, Chuan, and Michael Wand. "Precomputed real-time texture synthesis with markovian generative adversarial networks." European Conference on Computer Vision. Springer, Cham, 2016
- [Simonyan 15] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. In ICLR, 2015.

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

[3F3-OS-14a] 人狼知能と不完全情報ゲーム(1) 稲葉通将(広島市立大学)、片上大輔(東京工芸大学)、狩野芳伸(静岡大学)、大槻恭士(山形大学) Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room F (302B Medium meeting room)

| [3F3-OS-14a-01] Analyzing Gestures in Real-World Werewolf Game  |     |
|---|-----|
| OShutarou Takayama <sup>1</sup> , Hirotaka Osawa <sup>1</sup> (1. University of Tsukuba)                |     |
| 1:50 PM - 2:10 PM   |     |
| [3F3-OS-14a-02] "Goodness" analysis of a Werewolf Game's player based on                                | ı a |
| biological signal   |     |
| $\bigcirc$ Hirotaka Yamamoto <sup>1</sup> , Nagisa Munekata <sup>1</sup> (1. Kyoto Sangyo University)   |     |
| 2:10 PM - 2:30 PM   |     |
| [3F3-OS-14a-03] Simulation of Strategic Evolution in 5-player Werewolf                                  |     |
| OAtsushi Takeda <sup>1</sup> , Fujio Toriumi <sup>1</sup> (1. The University of Tokyo)                  |     |
| 2:30 PM - 2:50 PM   |     |
| [3F3-OS-14a-04] Simulation Analysis based on Behavioral Experiment of                                   |     |
| Cooperative Pattern Task  |     |
| ONorifumi Watanabe <sup>1</sup> , Kota Itoda <sup>2</sup> (1. Musashino University, 2. Keio University) |     |
| 2:50 PM - 3:10 PM   |     |
| [3F3-OS-14a-05] Analyis of Strategies in Werewolf Game by 3 Players Considering                         | i   |
| Voting Behaviour of Other Players   |     |
| OHinako Tamai <sup>1</sup> (1. Nara Women's University)   |     |
| 3:10 PM - 3:30 PM   |     |

実世界人狼ゲームのジェスチャーの分析

Analyzing Gestures in Real-World Werewolf Game

高山 周太郎<sup>\*1</sup> Shutarou Takayama 大澤 博隆<sup>\*2</sup> Hirotaka Osawa

\*1 筑波大学 理工学群 工学システム学類

Collage of Engineering Systems, School of Science and Engineering, University of Tsukuba

# \*2 筑波大学 システム情報系

Faculty of Engineering, Information and Systems, University of Tsukuba

Nowadays, werewolf game has been studied in the context of communication games and incomplete information games. Werewolf game is expected to be used as a training method of communication because it has communication elements such as persuasion both in verbal and non-verbal aspects. However, there is little quantitative analysis for non-verbal communication factors in werewolf game which contribute for persuasion. The authors expect that it is necessary to investigate the influence of non-verbal information for clarify the mechanism of communication in werewolf game. In this study, the author gathered several human gestures and investigated the influence on the result of the game. The several parameters are arms degree, hands movement distance etc. The results suggest several persuasive non-verbal gestures in werewolf game. For example, arms degree shows how much influence on discussion in the game. It is suggested that initiative of betrayer or seer influences the result of werewolf game.

## 1. はじめに

人狼ゲームとは、プレイヤーの中から割り当てられた 「人狼」を、コミュニケーションを通じて発見するゲーム である。平和な村の中に、村人に扮した人狼が紛れ込んだ ので、人狼を見破り排除しなければならない―というスト ーリーが人狼ゲームの背景にある基本設定である。人狼を 割り当てられたプレイヤーはいかに他のプレイヤーに対し て村人だと思わせるか、他のプレイヤーはいかに人狼を見 破るか、でゲームの勝敗が決定する。

近年、人狼ゲームが研究対象として注目されており、オ ンライン上でのチャットログなどの言語情報を主な対象と して人狼ゲームを通じてより人間に近い思考のエージェン トの研究がなされている [梶尾 14]。例えば、梶原らは大澤 が作成した人狼ゲームの発話プロトコル[大澤 12]を使い、 強化学習によって人狼ゲームでの最適戦略を抽出した[梶 尾 14]。

しかし、コミュニケーションにおける非言語情報の重要 性は多くの研究で指摘されており[高木 06]、実世界での人 狼ゲームでも人間同士の非言語コミュニケーションがゲー ムの進行に関わっていると考えられる。酒井らによる、ア バターを用いた通話による人狼システムでは、プレイヤー の議論があまり盛り上がらない事がわかっている[酒井 16]。 アバターによって人の見た目が同質化され、非言語から情 報を集められなくなったためだと考えられる。人狼ゲーム 中の非言語コミュニケーションがプレイヤーにどの程度影 響を与えるのか、定量的に分析する必要があると考える。

そこで、本研究では高山による実世界人狼ゲームの非言 語情報解析システム[高山 19]により取得した姿勢情報を分 析し、役職や個人によって特徴的に見られる動作について いくつかの指標を用いて、ゲーム結果との関係性を調査し た。

## 2. 人狼ゲームについて

## 2.1 人狼ゲームのルール

人狼ゲームのルールは参加人数などによって細かい違い はあるものの、大筋のルールは共通している。本項では人 狼ゲームの一般的なルールについて記述する。

1 章で述べたとおり、人狼ゲームはコミュニケーション によってプレイヤーの中から人狼を見つけ出すゲームであ る。プレイヤーは一般的に、大きく人狼陣営と村人陣営に 分けられる。村人陣営はプレイヤーの中の人狼をすべて排 除することを目指す。人狼陣営は人間を排除して人狼と人 間の人数が同数以下になることを目指す。

ゲームは昼、投票、夜という3つのフェーズを繰り返し て進行する。昼フェーズはプレイヤー同士の自由な議論に よって人狼と思われる人物を探し出す。昼の議論には時間 制限が存在する。制限時間がきたら、投票フェーズに移る。 投票フェーズでは各プレイヤーが排除したいプレイヤーに 投票する。投票により最も多くの票を集めたプレイヤーは ゲームから除外され、その後のゲームには一切関与できな くなる。この投票によるプレイヤーの除外を処刑と呼ぶ。 夜フェーズでは各役職に与えられた特殊能力が作動する。 例えば人狼は、プレイヤーの中から襲撃する相手を一人選 び、そのプレイヤーをゲームから除外する。

## (1) 5人人狼に関して

本研究では、プレイヤーが5人の人狼ゲーム(5人人狼)を 対象とする。本研究での5人人狼の役職配分は、占い師・ 人狼・狂人・村人×2、となっている。各役職に関しては 2.2項で述べる。

5 人人狼では最長でも 2 ターン目の処刑が完了した時点 でゲームの勝敗が決定する。人狼ゲームの終了条件が「人 狼がいなくなる」または「人間と人狼が同数以下になる」 であるため、2 ターン目の処刑完了時点でプレイヤーは 2 人まで減っている。残ったプレイヤーの中に人狼がいなけ れば前者の終了条件が、人狼がいれば後者の終了条件が満 たされるためである。

5 人人狼では、最短では 1 ターン目の処刑時点で終了す る。この時点でゲームが終了した場合は、人狼陣営の敗北 となる。この場合、人狼が他のプレイヤーを騙せず、最初 の議論で見抜かれていたと言えるため、2 ターン目で負け る場合よりも大差で負けていたと言える。

#### 2.2 人狼ゲームの役職

人狼ゲームでは、固有の能力を持つ役職が各プレイヤー に与えられる。人狼ゲームでの役職は多くの種類が存在す るが、本項では、本研究での5人人狼で登場するものにつ いて述べる。

各役職の役割は以下の通りである。

- 占い師:村人陣営。夜になるとプレイヤーを一人 選び、そのプレイヤーが人狼かどうか自分だけが 知ることができる。
- 人狼:人狼陣営。夜になると一人選び、そのプレイヤーをゲームから除外する。
- 狂人:人狼陣営に所属する人間である。人狼を勝たせるために動く。占い師からは人間であると判断される。誰が人狼なのかは認識できない。
- 村人:村人陣営に所属する。特に能力を持たない。

#### 3. 解析手法

本研究では、人狼ゲーム中の非言語情報を定量的に解析 するための指標として、プレイヤーが表出する特徴的な動 作をいくつか挙げ、定式化した。動画の1フレームごとに 各指標を測定し、1ゲームごとにその平均値を取る。測定 の対象となるフレームは、各ゲームの昼の議論時間に該当 する箇所を対象とする。本研究で撮影した動画は1フレームが約0.033秒に相当する。

以下に本研究で用いた指標とその概要を示す。

#### $\cdot \text{ arms_degree}$

両腕でどの程度体を隠そうとしているのかという指標。 右手の座標から右肘の座標を引いてできるベクトルを、右 腕のベクトルlと置く。左に関しても同様に、左腕のベク トルrと置くと置く。arms\_degree の値 $\theta$ は次の(1)式で与 えられる。

$$\binom{x}{y} = \frac{1}{\|l\|} \begin{bmatrix} l_x & l_y \\ -l_y & l_x \end{bmatrix} \cdot r$$
$$\theta = \tan^{-1}\frac{y}{r} \quad (1)$$

1 ゲームごとに平均値を取り、ゲーム内でどの程度体を 隠そうとしていたのか測る。正に大きくなるほど腕を開き、 負に大きくなるほど腕を閉じていると言える。

## $\cdot directing\_upper\_the\_left\_arm$

左腕が上向きになっているかどうかの指標。左腕のベクトルが上向きならば 1、下向きならば 0 を返す。1 ゲーム ごとに足し合わせて、フレーム数で標準化することで比較 する。

#### • directing\_upper\_the\_right\_arm

directing\_upper\_the\_left\_arm を右腕に適用したもの

head\_moving

鼻の座標の前フレームからの移動距離。最初のフレーム はカウントしない。フレーム数-1で標準化する。

• left\_hand\_moving

head\_movingを鼻ではなく左手の座標に適用したもの。

right\_hand\_moving

head\_movingを鼻ではなく右手の座標に適用したもの。

## 4. プレイの計測

本研究の計測には、高山らが作成した実世界人狼の非言 語情報を取得するためのシステムを使用した[高山 19]。こ のシステムは、人狼をプレイする動画から、プレイヤーの 関節の座標情報が測定できる。このシステムから実際に習 得した情報を次の図1に示す。



図 1: 取得した関節の座標情報イメージ

2018 年 11 月、7 人の男性参加者(大学生及び大学院生) を 5 人ずつ交代でゲームを全 37 ゲーム実施した。撮影の 参加者は全員が右利きであった。本研究の撮影では、プレ イヤーの左手に発汗を測定するセンサーを付けている。プ イヤーが、心理的に左手のほうが動かしづらい可能性は考 えられる。このセンサーで取得したデータは、本研究では 使用していない。

## 5. 結果

## 5.1 ゲーム結果

全37ゲームで各陣営が勝った回数を次の表1に示す。

| ± | 1.4 | ムビ     | , 灶田 |
|---|-----|--------|------|
| 衣 | 1.  | - 王7 ' | ーム桁米 |

| 陣営        | 勝利回数 |
|-----------|------|
| 人狼        | 16   |
| 村人(合算)    | 21   |
| 村人(1ターン)  | 12   |
| 村人(2 ターン) | 9    |

5 人でプレイする人狼ゲームは通常 2 ターンで終了する が、村人陣営は人狼を処刑できればゲームに勝利できるた め、1 ターンでゲームが終了する場合もある。表 1 の「村 人(合算)」は、終了ターン数を考慮しない場合の勝利回数。 「村人(1 ターン)」「村人(2 ターン)」は、「村人(合算)」 の内それぞれ 1 ターンで終了したもの、2 ターンで終了し たものを指す。

## 5.2 解析結果

4.3 項で述べた指標のデータを役職ごとに分類し、さら にそれを2群に分けてt検定を行った。2群への分け方は

- ゲームの勝敗:勝利条件・敗北条件に分ける。ゲーム全体の議論の時間に関して値を取得する。
- ゲームのターン数:ゲームが1ターンで終了する最 短条件・2ターンで終了する最長条件に分ける。1 ターン目の議論の時間に関して値を取得する。

の2パターンを試みた。

以上のように分類したデータを、指標ごとに t 検定を行 いその結果の p 値を表 2、3 に示す。

| 表 2: | 役職ご       | とに | ゲー | ムの  | 勝敗っ | で検定() | o*<0.05, | p <sup>+</sup> <0.1) | ) |
|------|-----------|----|----|-----|-----|-------|----------|----------------------|---|
|      | P 4 174 - |    |    | - , |     |       | ,        | P/                   |   |

|                               |         |          | · •      |          |
|-------------------------------|---------|----------|----------|----------|
|                               | 人狼      | 村人       | 占い師      | 狂人       |
| arms_degree                   | 0.74830 | 0.06908+ | 0.25642  | 0.05773+ |
| directing_upper_the_left_arm  | 0.48960 | 0.81931  | 0.41968  | 0.89675  |
| directing_upper_the_right_arm | 0.51475 | 0.61446  | 0.01671* | 0.46831  |
| head_moving                   | 0.61960 | 0.00203* | 0.03788* | 0.74107  |
| left_hand_moving              | 0.14738 | 0.30183  | 0.17098  | 0.22430  |
| right_hand_moving             | 0.51583 | 0.28303  | 0.09409+ | 0.56704  |

#### 表 3: 役職ごとにゲームのターン数で検定(p\*<0.05, p+<0.1)

|                               | 人狼      | 村人       | 占い師      | 狂人       |
|-------------------------------|---------|----------|----------|----------|
| arms_degree                   | 0.70481 | 0.45325  | 0.00392* | 0.00097* |
| directing_upper_the_left_arm  | 0.75753 | 0.23767  | 0.30432  | 0.07694+ |
| directing_upper_the_right_arm | 0.59014 | 0.89732  | 0.00194* | 0.29950  |
| head_moving                   | 0.80736 | 0.03805* | 0.18326  | 0.67003  |
| left_hand_moving              | 0.14240 | 0.51271  | 0.62096  | 0.79854  |
| right_hand_moving             | 0.60686 | 0.52928  | 0.51365  | 0.66872  |

## 6. 考察

### 6.1 狂人と占い師の関係性に関する考察

本項では、狂人と占い師の arms\_degree に着目する。 Cashdan では、腕の開き具合とその場のコミュニケーショ ンでのリーダーシップとの関係性を指摘している [Cashdan 98]。arms\_degree が大きいほど、人狼ゲームの 議論の場において強い影響力を持っていると考えられる。

表3の arms\_degree から、占い師と狂人のときに着目す る。表4に、狂人・占い師の arms\_degree の、また、各群 での平均値と標準偏差を示し、図2、3に狂人、占い師そ れぞれの arms\_degree の箱ひげ図を示す。

#### 表 4:ターン数毎の arms\_degree の平均値・標準偏差

|      | 占い師    | 占い師    | 狂人     | 狂人     |
|------|--------|--------|--------|--------|
|      | 最短     | 最長     | 最短     | 最長     |
| 平均值  | -0.129 | -0.458 | -0.599 | -0.215 |
| 標準偏差 | 0.264  | 0.362  | 0.265  | 0.356  |
|      |        |        |        |        |

図 2 から、1 ターンでゲームが終了した場合、狂人の arms\_degree が有意に小さくなり、ことがわかる。ここか ら、人狼陣営である狂人が、リーダーシップを持てなかっ たため大差で負けてしまい、それが arms\_degree に表れた と考えられる。



図 2:ターン数で比較した狂人の arms\_degree



図 3:ターン数で比較した占い師の arms\_degree

反対に、図3からは1ターンで終了した時、すなわち占い師が人狼陣営に勝った時、腕を開く傾向にあることがわかる。占い師がリーダーシップを持ち、ゲームを村人陣営が有利な方へ導いたためだと考えられる。

## 6.2 占い師に関する考察

本項では、占い師の directing\_upper\_the\_right\_arm に 着目する。表 6 に勝利条件、敗北条件、最短条件、最長条 件それぞれにおける平均値と標準偏差を示す。また、図 4、 5 に勝敗を比較したとき、ターン数で比較した時それぞれ の場合の箱ひげ図を示す。

表 6: 各条件における占い師の

directing\_upper\_the\_right\_arm の平均値・標準偏差

|      | 最短    | 最長    | 勝利    | 敗北    |
|------|-------|-------|-------|-------|
| 平均值  | 0.493 | 0.206 | 0.387 | 0.167 |
| 標準偏差 | 0.230 | 0.239 | 0.265 | 0.260 |



図 4: 占い師の勝敗ごとの directing\_upper\_the\_right\_arm



directing\_upper\_the\_right\_arm

占 い 師 が ゲーム に 勝 つ 時 、 directing\_upper\_ the\_right\_arm が大きくなることがわかる。自分に注意を 引くために積極的に右腕を動かしていることが考えられる。 村人陣営が勝つには、占い師が手を挙げ、積極的に議論に 参加するのが良いとわかる。

## 7. まとめ

本研究では実世界人狼ゲームに見られるジェスチャーに 着目し、議論との関連性を調査した。本研究で提案した指 標で、1 ターン目の有利な議論の導き方や、占い師の議論 への参加の積極性を評価できることがわかった。

## 謝辞

本研究は JSPS 科研費 JP26118006, JP16H02928, JP18KT0029の助成を受けたものです。心より感謝致します。

- [Cashdan 98] Elizabeth Cashdan: "Smiles, Speech, and Body Posture: How Women and Men Display Sociometric Status and Power", Journal of Nonverbal Behavior, 1998.
- [大澤 13] 大澤博隆, "コミュニケーションゲーム「人狼」におけるエージェント同士の会話プロトコルのモデル化" HAIシンポジウム 2013, 2013.
- [梶原 14] 梶原健吾,鳥海不二夫,大橋弘忠,大澤博隆,片上大 輔,稲葉通将 and 篠田孝祐, "強化学習を用いた人狼にお ける最適戦略の抽出", 情報処理学会第 76 回全国大会講 演論文集, 2014.
- [酒井 16]酒井久志,片上大輔 and 大澤博隆"FACERIG での 人狼での無意識動作の影響", HAI シンポジウム 2016,2016.
- [高木 06] 高木幸子, "コミュニケーションにおける表情及び身体動作の役割",2006.
- [丹野 15]丹野昭宏 and 児玉健"人狼ゲーム経験による嘘の手 がかり信念の差異",パーソナリティ研究 24(1),2015.
- [高山 19]高山周太郎 and 大澤博隆 "実世界人狼ゲームの非 言語情報分析システムの設計", HAI シンポジウム 2019,2019.

# 生体信号に基づく人狼プレイヤの「強さ」分析の試み

"Goodness" analysis of a Werewolf Game's player based on a biological signal

山本 浩隆

棟方 渚

Hirotaka Yamamoto 💿 Nagisa Munekata

京都産業大学

Kyoto Sangyo Univercity

We attempted to analyse "goodness" of a game player by measuring a biological signal of each player during a five-player werewolf game. First, we focused on some periods as important game events since we observed simultaneous increase of electro dermal activities of multi players at these periods. Second, we compared electro dermal activities between high winning players and others at the important events. As a result, an unique tendency was confirmed in only electro dermal activities of the good players. This result would be expected to contribute toward designing of strategy in Werewolf AI.

## 1. はじめに

人狼ゲームは、プレイヤ同士の対話によって、属している陣 営を勝利に導いていくコミュニケーション型ゲームである.プ レイヤは自身の役職以外の情報は一切もたないため、会話が人 狼を導き出すための唯一の手がかりとなる.限られた情報の中 で早く自身の仲間を見つけ説得し、相手を欺き、情報を引き出 すことがゲームの醍醐味である.人狼ゲームは本来、対面で行 うゲームが一般的であるが、日本では古くからWeb上でBBS 人狼と呼ばれる掲示板型の人狼ゲームが存在する.2013年頃 からテレビ番組で有名人による人狼ゲームのプレイ映像が放送 されたり、動画サイトではプロ将棋棋士による人狼ゲームが放 送された.人狼ゲームを演劇として見せ、エンターテイメント として「魅せる人狼」も盛んに行われている[1].

2015年に鳥海らが立ち上げた「人狼知能プロジェクト」は「人 間と自然なコミュニケーションを取りながら人狼をプレイでき るエージェントの構築」を目標としており,実現にはエージェン ト技術や人工知能,自然言語処理,Human-AgentInteraction など様々な技術が必要とされている.人狼AI構築の一つのア プローチとして,人間の熟達者プレイヤの思考過程を分析を行 うといった試みがある[2].思考過程分析には,発話分析や自然 言語処理,生体情報を用いて行われている.本研究は,人間の 偽りのない反応を取得できる生体信号に着目し,興奮や集中, 思考の移り変わりの影響を受ける皮膚電気活動を用いて,人狼 ゲームの熟達者プレイヤの思考過程の分析を試みる.

## 2. 関連研究

#### 2.1 皮膚電気活動

皮膚電気活動は,精神性発汗を電気的にとらえたものであ る.人の手掌や足底は,緊張や動揺などの心的興奮によって発 汗を生じる.これらの発汗は,自覚できないほど微量のものか ら,手掌が湿ってしまうほど大量のものまで様々である.皮膚 電気活動は手掌に1対の電極を装着し,その電極間に微弱な電 流を流している間の発汗によって生じる測定部の抵抗値の変化 から測定できる.皮膚電気活動には複数の測定単位系があり, 人間の情動状態を評価する方法として用いられている[3,4].そ

連絡先: 棟方 渚,京都產業大学情報理工学部, munekata@cc.kyoto-su.ac.jp の中で、本研究ではSCL(Skin Conductance Level)を用いた. 本研究で用いるSCLは、緩徐な変動で観察される信号であり、 ユーザの精神的不安や安静状態の評価として用いる場合、他の 皮膚電気活動より有効であると示されている[5].

#### 2.2 皮膚電気活動と人狼ゲームの関連

精神性発汗は生体が緊急時に対処する行動,闘争-逃走反応 と密接に関連するといわれており,闘争時の手掌の発汗は道具 をしっかりと把持するという目的がある[6].人狼ゲームでは, プレイヤが勝敗を左右する重要な場面に直面した場合,闘争-逃走反応である手掌発汗があらわれ,急激な皮膚電気活動の上 昇があると考える.人狼プレイヤが重要であると考える場面を 皮膚電気活動によって判別することが可能になれば,人狼プレ イヤの「強さ」の定義や戦略の理解,それに基づいた人狼AI 構築における重み付けなどが可能となると考えられる.

#### 2.3 皮膚電気活動を用いた人狼プレイヤの分析

御手洗らは、人狼ゲームプレイヤの情動状態を対象として、 皮膚電気活動を用いた人間のコミュニケーションにおける情動 変化を解析した.プレイヤの役職や各陣営の状態がSCLに影 響をあたえるということが示唆されている.また、人狼陣営 (狂人や人狼の総称)は、村人陣営(村人や占い師の総称)よりも SCL平均値が高いことが明らかになった.この結果について、 人狼陣営は必然的に自身の役職を偽るなどの虚偽の発言が求め られるなど、精神的な負荷の高い状態がゲーム中に持続してい たことが要因の一つであると報告されている[7].

風間らは人狼のゲーム時に,誰のどのような発言がプレイヤ に影響を与え,ゲームを動かしているのかを調べるために,情 動反応のマーカとしてSCR(Skin Conductance Response)を 測定し,ゲームの展開を左右する発言の種類を分析した.ゲー ム時のSCRの上昇がみられたプレイヤの発話を抽出した結果, 人狼プレイヤは他プレイヤに疑われた際に,嘘をつくリスクを 減らす,かつ目立つことを避けるために,理由を付与するよう な反論をせずに話題を逸らそうとする発言をする傾向があると 推測した.また,村人プレイヤの思考過程とSCRの発現のタ イミングから,村人プレイヤは他プレイヤへの疑いに,人狼プ レイヤは自身への疑いに対しそれぞれ不利益を感じ,発言内容 に影響を与えていることが推測された[8].

## 3. 実験

### 3.1 人狼ゲームのルール

人狼ゲームはランダムに役職が与えられる. 役職の中には 特殊な能力を持つ役職も存在する. 今回は5人で人狼ゲームを 行うため役職は4つである.

- 占い師(預言者):他のプレイヤの役職をみる
- 人狼:他のプレイヤを殺害する
- 狂人(裏切り者):村人として数えられ、人狼に加担する村 人である
- 村人:特殊な能力は持たない

それぞれの役職の内訳は占い師1人,人狼1人,狂人1人,村人 2人とする.

ゲームは常にプレイヤ以外のゲームマスター(以下:GM)が 進行する.人狼ゲームは様々な場面が存在するが,本研究では 以下の4つに分類し,解析・議論を行う.

- 役職を確認
- 2. 夜のフェーズ(初日の殺害は不可)
- 3. 会議(4分間に固定する)
- 4. 投票

3. の会議において人狼が生き残った場合, 2. から4. をも う1度繰り返す. 村人陣営である村人, 占い師の勝利条件は人 狼の処刑であり, 人狼の勝利条件は村人の数を人狼以下にす る. 狂人は人狼の勝利が勝利条件である.

#### 3.2 実験概要

被験者に5人人狼を15試行プレイさせ、それぞれのSCLを 測定した.実験に参加した被験者は6名であり、この被験者は 普段から5人人狼をプレイしており、熟達した人間プレイヤと して位置付けることができる.被験者6名の中から5名を選出 し一部交代でゲームに参加してもらった.各被験者は15回の試 行のうち少なくとも10回は試行に参加した.連続でゲームを 行うことによる疲労の影響を考慮し、5試行ごとに約20分間の 休憩を設けた.

前述した通り,人狼は精神的な負荷の高いゲームであること から,個々のプレイヤのSCLは常に上昇と下降を繰り返してい ると考えられるが,複数のプレイヤのSCLの同期的な上昇がみ られた場合,その周辺にゲームの勝敗を左右する重要なイベン トが存在すると考えらる.そこで,全プレイヤのSCLデータに 基づき,ゲーム中の重要なイベントを抽出し,「強い」プレイ ヤと「弱い」プレイヤ間でのSCLの振る舞いを比較することと した.ここでいう「強い」プレイヤは,10から15回の試行のう ち,勝率が高いプレイヤとし,勝率の低い者を「弱い」プレイ ヤとした.

#### 3.3 本研究で使用したSCL計測システム

SCLの計測装置はAffectiva社のQ Sensorを参考に実装した ものを使用した.計測システムはPython3.5を用いて実装し, Raspberry Pi 3 ModelB上で動作させた.システムはA/D変換 器を通して,サンプリング周期20HzでSCLを取得した[7].ま た,Raspberry Pi 3 ModelB上で記録が正常に行われているの かを確認するためにPython3.6を用いて,PCとRaspberry Pi 3 ModelBの通信を同時に行った.実験では、プレイヤのジェ スチャ等の振る舞いを妨げることの無いように計測装置を配置 し、電極やリード線をプレイヤの身体に固定した.ゲームの進 行やプレイヤの言動を記録するために、各プレイヤの前方にそ れぞれマイクを配置し、顔が認識できるよう数台のビデオカメ ラを用いて実行した.

## 4. 実験結果

## 4.1 SCLによるイベント抽出

複数のプレイヤのSCLの同期的な上昇がみられた箇所に着 目し、その周辺のプロトコル分析を行なった。抽出されたイベ ントは主に各プレイヤの発話を基にタグ付けを行った。得られ た結果を表1に示す。そのイベント開始と終了に関する認識は、 各プレイヤによって多少の時間差があることを考慮し、SCLの 同期的上昇は誤差2-3秒程度とし関連づけた。

| 表 1: 抽出されたイベントとその |
|-------------------|
|-------------------|

| イベント     | 数  |
|----------|----|
| CO       | 9  |
| 疑い       | 5  |
| 殺害・投票・処刑 | 3  |
| 合計       | 17 |

全試行の分析結果から,計17箇所で複数のプレイヤのSCL の同期的な上昇がみられた.抽出された各イベント(表1)に ついて以下で説明する.

抽出されたイベント「CO」は、自身の役職を他のプレイヤ に伝えるなどのカミングアウト(以下:CO)を意味し、それに 起因するイベントが9箇所みられた.COは、あるプレイヤが 呼びかけをするなどして開始され、単数もしくは複数のプレイ ヤが役職を占い師と自称し占い結果を提示(虚偽を含む)する までをCOと定義した.つまり、COは主に占い結果に関する 会話となる.この会話の例(原文ママ)として、「A君グレー、 人間ではある(狂人の可能性がある)」、「俺はBに入れますね (投票する)、最初から黒(人狼の意味)って言ってたんで」な どの占い結果に基づくものが挙げられる.

抽出されたイベント「疑い」は,他プレイヤへの疑い(他プ レイヤからの疑い)に関する会話に基づいたイベントであり, 計5箇所みられた.この会話の例(原文ママ)として,「ないな いそれは.いや,まぁ人狼かもしれないけど(他プレイヤを指 差しながら)」,「C君人狼だからね~」など特定のプレイヤ,特 定の役職について言及したものが挙げられる.

抽出されたイベント「殺害・投票・処刑」は、GMの「Dさん が殺害されました」「では、投票してください.いっせーのー で(それぞれが他プレイヤを指差す)」などの宣言や投票を行う 場面が挙げられ、計3箇所みられた.

抽出された17箇所のイベントのうち,15箇所がゲームの初 日のフェーズに行われた.加えて,その12箇所は,初日の会議 において行われたイベントであったため,以降,初日の会議に 着目し,プレイヤの振る舞いを分析することとした.

#### 4.2 勝率による「強い」プレイヤの選定

人狼ゲームの「強さ」について定義が難しく,先行研究においても議論がなされていない.そこで,本研究では15回の試行における勝率を基に,強いプレイヤと弱いプレイヤを選定することにした.各プレイヤの勝率を以下(表2)に示す.

表 2: 各プレイヤの勝利数と試行回数

| プレイヤ | А    | В    | С   | D   | Е   | F   |
|------|------|------|-----|-----|-----|-----|
| 勝率   | 70 % | 67~% | 40% | 70% | 40% | 40% |
| 試行数  | 10   | 15   | 15  | 10  | 10  | 15  |

表2から,試行回数が多く勝率の高いプレイヤBを「強い」プ レイヤ,試行回数が多く勝率の低いプレイヤCとFを「弱い」プ レイヤとする.全15試行おける人狼陣営の勝率は33%村人勝率 の67%であった.強いプレイヤと弱いプレイヤの各陣営に属し た回数を表3に示す.

表 3: 各プレイヤの勝利数と試行回数

|     | プレイヤB | プレイヤC | プレイヤF |
|-----|-------|-------|-------|
| 占い師 | 5     | 2     | 2     |
| 村人  | 4     | 5     | 7     |
| 人狼  | 1     | 4     | 3     |
| 狂人  | 5     | 4     | 3     |

表3の結果から,強いプレイヤ(B)と弱いプレイヤ(C,F) とで,各陣営に属した回数に大きな偏りはみられなかった.

解析は、ノイズの混入(電極を触る,電極が外れる)がみ られたものは対象から除外した(有効なデータのみを使用し た).4.1章の結果から,抽出されたイベント17箇所のうち12 箇所がゲーム初日の会議で確認された.勝率で選定した強いプ レイヤ,弱いプレイヤについて,ゲーム初日の会議に着目し, 観察とSCLの分析結果から両プレイヤの振る舞いを調査する. 次章では,両プレイヤの初日の会議におけるSCLの時系列デー タの振る舞いについて分析した.

### 4.3 初日の会議のSCLの振る舞い

前章で選定した強いプレイヤ(B)と弱いプレイヤ(F)に ついて,各試行の会議(約4分間)のSCLを30秒毎に平均値を 求めた結果を図1,2に示す.各データは計10試行分となった (有効なデータのみを使用).図1,2の結果から,個人内のデー タであっても,それぞれの試行回のSCLにばらつきがあること が理解できる.ゲームは全試行同日に行われており,各試行に おいて身体状態に大きな差はみられないと考えられるが,役 職やゲーム状況によって大きな影響を受けると考えられる.次 に,より全体的な傾向を確認するため,図1,2の結果の平均を 図3,4に示す.図3,4の結果から,強いプレイヤ(B)は会議 の始まりから終わりにかけて,徐々にSCLが減少するといった 一定の傾向がみられ,弱いプレイヤ(F)のSCLは時系列的な 変化がみられなかったことが示された.もう一方の弱いプレイ ヤ(C)においても同様の結果となった.この結果をふまえ, 次章で考察を行う.

## 5. 考察

実験結果から, 熟達した強いプレイヤ(B)のSCLの振る舞 いは, 会議の始まりで相対的に高い値を示したことから, 強い プレイヤは会議開始1分程度で最も心的な興奮がみられたこと を意味する.この周辺で行われたイベントは, 主にCOであっ た.加えて, COは複数のプレイヤのSCLの同期的な上昇が最 もみられた箇所であり, 人狼ゲームにおいて最も重要なイベン トと考えることができる.そこで, COにおける強いプレイヤ



図 1: 各試行の会議中の強いプレイヤ



図 2: 各試行の会議中の弱いプレイヤ



図 3: 会議時:強いプレイヤのSCL(全試行)



図 4: 会議時:弱いプレイヤSCL(全試行)

と弱いプレイヤの言動に着目し調査した.具体的には、CO時 のプレイヤの「挙手の有無」つまり、占い師として名乗りをあ げたのかどうかを調べ(挙手有り/挙手無し)、その際のSCL の振る舞い(SCL上昇/SCL変化無)との関連について調べた. その結果を表4に示す.

表 4: CO時の挙手の有無とSCLの上昇との関連

|        | 挙手有り<br>SCL上昇 | 挙手無し<br>SCL上昇 | 挙手有り<br>SCL変化無 |
|--------|---------------|---------------|----------------|
| 強いプレイヤ | 4             | 3             | 0              |
| 弱いプレイヤ | 5             | 1             | 1              |

今回の実験では全ての試行でCOが行われており、CO時に 挙手を行なったプレイヤは、他プレイヤに向けて指差ししなが ら占い結果を提示するといった流れがみられた. このように 挙手を行なった場合には、ジェスチャや発言などプレイヤによ る明示的な行動が確認できる.一方,挙手を行わなかった場合 は、他プレイヤの様子(発言や指差し)をただ観察する様子が みられた.表3の結果から、強いプレイヤはCO時に自身が挙 手を行なった場合のみならず、挙手を行なわなかった場合にお いてもSCLの上昇がみられた.一方の弱いプレイヤでは、挙手 を行なった場合にSCLの上昇がみられたが、挙手を行わなかっ た場合には、SCLの上昇があまりみられなかった. つまり、強 いプレイヤは弱いプレイヤよりも、CO時に行われるコミュニ ケーションについて、自身の参加の有無に関わらず、戦略的に 注視していると考えられる.実際にCOでは、どのプレイヤが、 どのプレイヤに対し、どのような判定結果を示しているのか, 虚偽の有無について見極めることがその後のゲーム展開におい て大きな役割をもつため, 強いプレイヤでこのような現象がみ られたことは妥当であると考えられる.

## 6. おわりに

本研究では、複数のプレイヤのSCLの同期的な上昇から重 要であると考えられるイベントを抽出し、強いプレイヤと弱い プレイヤの初日の会議時のSCLの振る舞いと言動を分析した. その結果、強いプレイヤはいずれのゲーム、役職でも傾向が みられ、弱いプレイヤは傾向がみられないことが理解できた. COによるSCLの振る舞いについて分析した結果、強いプレイ ヤはCO時に行われるコミュニケーションを戦略的に注視して いることが示唆された.5人で行う人狼ゲームの戦略は、6人以 上で行われる人狼ゲームでは適さない場合もあるが、COの重 要性は変わらないと考える.また、本研究における強いプレイ ヤと弱いプレイヤの選定には未だ改良の余地があると思われ る.プレイヤが電極を触ることでデータにノイズの混入がみら れたことから、プレイヤが電極に触れてもノイズの混入を防ぐ 計測システムの設計が必要となる.

## 7. 謝辞

本研究はJSPS科研費16H02928の助成を受けたものです.

## 参考文献

 鳥海 不二夫,片上 大輔,大澤 博隆,稲葉 通将,篠田 孝 祐,狩野 芳伸:人狼知能 だます・見破る・説得する人工 知能,森北出版(2016)

- [2] 伊藤 毅志,高橋 克吉,猪 爪歩,加藤 英樹,村松 正和, 松原 仁:人間とコンピュータの思考の違い-囲碁の次の一 手問題による考察-,ゲームプログラミングワークショッ プ2012論文集,2012 巻,6号,pp.9 - 16(2012)
- [3] 生月 誠,原野 広太郎.山口 正二:バイオフィードバッ クにおける情動安定性の指標としての SCL の検討,バイ オフィードバック研究,13巻,pp.18-21(1986)
- [4] 梅沢 章男,黒原 彰:バイオフィードバック指標としての皮膚コンダクタンス変化と皮膚電位活動の比較,バイオフィードバック研究,21巻,pp.29-36(1994)
- [5] 新美 良純, 白藤 美隆, 皮膚電気反射-基礎と応用, 医歯 薬出版株式(1969)
- [6] 沼田 恵太郎,宮田洋,皮膚電気条件づけ-その意義と研究 動向-,関西学院大学人文学会,人文論究 61(2), pp.55-88(2011)
- [7] 御手洗 彰,水丸 和樹,本田 健悟,棟方 渚,坂本 大介, 小野 哲雄:人狼プレイヤの皮膚電気活動の解析:情動変 化を利用したソシオメータの実現へ向けて,情報処理学 会 インタラクション, pp.885-888(2018)
- [8] 風間 祥光,棟方 渚,畑 雅之,松原 仁:人狼ゲームにお けるプレイヤーの思考過程の分析,情報処理学会ゲーム 情報学研究会,2016-GI-36(19), pp.1-7 (2016)

# 5 人人狼における戦略進化のシミュレーション Simulation of Strategic Evolution in 5-player Werewolf

武田 惇史 Atsushi Takeda

鳥海 不二夫 Fujio Toriumi

## 東京大学 The University of Tokyo

In recent years, the game "Werewolf" has been drawing attention in the field of Artificial Intelligence. In this paper, we propose a method to simulate the evolution of strategy in order to investigate whether a strategy that always dominates other strategies is discovered in the 5-player werewolf regulation in future AI Wolf Competition. As a result of the simulation, we found that we can not reach a strategy that always has a dominant advantage, and eventually the strategy will continue to change periodically.

## 1. はじめに

近年, チェス, 将棋, 囲碁といった完全情報ゲームにおいて, 人工知能技術は人間の能力を上回るまでに成長している. それ に比べると, 不完全情報ゲームにおける人工知能に関する研 究はあまり行われてはいない. そこで, 人工知能研究者が次に 取り組むべき題材として,「人狼」が提案されており[篠田 14], 人 狼における人工知能技術の促進のため, 統一的なプラットフォ ームの開発, 大会の開催などを行う「人狼知能プロジェクト」が 発足している.

本研究の目的は、人狼知能大会に用いられる「5 人人狼」を 対象としたシミュレーション手法を提案し、人狼知能においてナ ッシュ均衡となるような戦略が発見されるのかを調査することで ある.

## 2. 関連研究

人狼の元となったゲーム"Mafia"というゲームを対象にし、役職として「人狼」と「村人」のみが存在する条件下で、確率的統計より最適戦略を求める研究が行われている[Braverman 08]. ここでは、話し合いをすることで、村人勝率が上がることなどが示されている.

本研究が対象とする 5 人人狼において考えられる戦略については、占い師の結果騙りが 5 人人狼において有効であるという、一般的な人狼にない、非直感的な戦略性について報告されている[片上 15].

人狼における進化的シミュレーションを行った研究[大澤 17] では、人狼、占い師、村人の3人で行う3人人狼を定義し、進 化シミュレーションを行うことで、どのような戦略があるか、どのよ うな現象がおこるかが調べられている.ここでも、占い師の結果 騙りが重要な戦略として挙げられていて、進化の中で一時的に 支配的な戦略になる、という結果が報告されている.

## 3. 5人人狼

## 3.1 ルール

人狼ゲームは、プレイヤーが「村人陣営」と「人狼陣営」に分 かれて行うチーム戦である.村人陣営は人狼を追放することで

連絡先:武田惇史,東京大学工学部システム創成学科, 113-8656 東京都文京区本郷 7-3-1 工学部 8 号館 526, TEL: 03-5841-6991, E-mail: takeda@crimson.q.t.utokyo.ac.jp

表 1:5人人狼における役職の内訳

| 役職名 | 陣営 | 人数 | 能力 |
|-----|----|----|----|
| 村人  | 村人 | 2  | なし |
| 占い師 | 村人 | 1  | 占い |
| 人狼  | 人狼 | 1  | 襲撃 |
| 狂人  | 人狼 | 1  | なし |

勝利となり, 人狼陣営は人狼が追放されないことで勝利となる. ゲームは「日」を単位として進行し, 1日はさらに「昼」と「夜」に分けられる.

本研究が対象とする5人人狼のレギュレーションにおいては, 以下のような順番でゲームは進行していく.

#### (1) 役職の割り当て

最初に、プレイヤーに対し役職がランダムに割り当てられる. 役職の内訳は表1に示す通りあらかじめ決まっている.また、役 職ごとに陣営が決まっている.プレイヤーは、自分以外のプレイ ヤーの役職を知ることができない.したがって、誰が敵で誰が味 方かわからない状態でゲームが始まる.

#### (2) 0日目:占い師の占い

占い師は、プレイヤーを一人選んでその役職が人狼であるか どうかを知ることができる.この能力を「占い」と呼ぶ.

#### (3) 1日目:話し合い,投票,追放

ここでは、プレイヤーは話し合いを行う.主に、占い師 CO(役 職を表明すること)と占い結果の報告が行われる.

その後,各プレイヤーは他プレイヤーに対して投票を行い, 最も得票数の多かったものは「追放」される.追放されたプレイ ヤーは今後ゲームに関わることができない.

#### (4) 1日目:襲撃, 占い

ここでは、人狼がプレイヤーを自由に選び、「襲撃」を行う. 襲撃されたプレイヤーは今後ゲームに関わることができない.

#### (5) 2日目:話し合い,投票,追放

この時点で残っているプレイヤーは3人である.残ったプレイ ヤーに対して、1日目と同様に話し合い、投票、追放が行われる.

#### (6) 勝利陣営の決定

人狼が追放されたら村人陣営の勝ち,最後まで人狼が生き 残れば人狼陣営の勝ちである.

| 表 3: 2017年データに対する回帰分析の結果と2018年における変化の対応 |        |         |         |         |        |         |                |         |        |
|---|--------|---------|---------|---------|--------|---------|----------------|---------|--------|
|   | 1      | 2       | 3       | 4       | 5      | 6       | $\overline{O}$ | 8       | 9      |
| 回帰係数                                    | 2.0518 | -0.3214 | -1.5614 | -2.2122 | 0.1943 | -0.4192 | 0.0384         | -0.5167 | 0.1807 |
| 標準誤差                                    | 0.0678 | 0.0384  | 0.0423  | 0.0505  | 0.0518 | 0.0231  | 0.1266         | 0.0707  | 0.0574 |
| P値                                      | 0.0000 | 0.0000  | 0.0000  | 0.0000  | 0.0002 | 0.0000  | 0.7619         | 0.0000  | 0.0017 |
| 2017年平均                                 | 0.2145 | 0.1518  | 0.3876  | 0.1381  | 0.1039 | 0.5760  | 0.0211         | 0.0709  | 0.1421 |
| 2018年平均                                 | 0.0643 | 0.0000  | 0.0721  | 0.0280  | 0.3960 | 0.6239  | 0.0264         | 0.0320  | 0.0001 |
| 回帰係数の示す増減                               | 減少     | 減少      | 減少      | 減少      | 増加     | 増加      | -              | 増加      | 減少     |
| 実際の増減                                   | 減少     | 減少      | 減少      | 減少      | 増加     | 増加      | -              | 減少      | 減少     |
| 増減の一致                                   | 0      | 0       | 0       | 0       | 0      | 0       | -              | ×       | 0      |

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

表 2: 特徴量

| 番号 | 概要                | 値          |
|----|-------------------|------------|
| 1  | 人狼占いCO            | 二值(0 or 1) |
| 2  | 占い師2ターン目CO        | 二值(0 or 1) |
| 3  | 2CO盤面における初日占い投票率  | 実数値[0,1]   |
| 4  | 2CO盤面における二日目占い投票率 | 実数値[0,1]   |
| 5  | 2CO盤面における占い結果騙り   | 二值(0 or 1) |
| 6  | 2CO盤面における裏切り者黒だし  | 二值(0 or 1) |
| 7  | 3CO盤面における占い結果騙り   | 二值(0 or 1) |
| 8  | 3CO盤面における裏切り者対抗占い | 二值(0 or 1) |
| 9  | 3CO盤面における人狼対抗占い   | 二值(0 or 1) |

## 3.2 考えられる戦略

人狼ゲームは、能力の弱い多数(村人陣営)と能力の強い少数(人狼陣営)の対戦であると解釈することができる. 追放は、 投票による多数決によって行われるため、村人陣営にとって有利であるといえる. このことが、人狼ゲームにおける「人狼陣営 が村人陣営を騙る」という構図を作り出している.

5人人狼においては、村人陣営の役職は村人または占い師 であり、人狼陣営はこのどちらかを騙ることになる、どちらを騙る かは戦略において重要な要素である.また、占い師を騙る場合 には嘘の占い結果を報告する必要がある.どのような嘘の占い 結果を報告するかも、重要な要素になる.

## 4. 戦略の進化の分析

本章では、2017年と2018年の人狼知能大会のログから、決勝に進出した強いエージェントのとる戦略がどのように遷移したのかを解析する、2018年のエージェントは、2017年において強かった戦法をとる傾向にあると予想される。

#### 4.1 特徴量

解析に使う特徴量は表2に示す通りである. 特徴量の選択においては、以下の条件を満たすものとした.

- 行動主体となる役職が存在すること. 例えば, 特徴量1は 「人狼占い CO」であり, 行動主体は人狼である.
- 行動主体の意思で値を変えられること.例えば、「村人が 人狼に投票する確率」などは本分析では特徴量になり得 ない.なぜなら、村人にとって誰が人狼であるかは非公開 の情報であり、村人が自由にこの量を変化させることがで きないからである.

## 4.2 解析手法

試合ごとの特徴量の値を説明変数として、その試合の勝敗を 2値(村人陣営が勝ちなら1,そうでなければ0)で予測するロジ スティック回帰モデルを作り、学習した.回帰係数は、正負が逆 であるという帰無仮説のもと、有意水準1パーセントで検定をお こなう.P値が 0.01を上回った特徴量は結果の考慮に入れない. 全データに対する特徴量の平均値の 2017 年から 2018 年にお ける増減と,回帰係数の正負から,2017 年に対して強い戦略が 2018 年において用いられる傾向にあるかを明らかにした.

#### 4.3 解析結果

結果を表3に示した.9個の特徴量のうち,8個でその回帰係数が有意であり,うち7個で回帰係数によって示されたエージェントにとって有利となる行動の増減と2017年から2018年における増減が一致した.このことから,2018年大会のエージェントは2017年大会に対して勝率が高くなるように作られていると考えられる.

## 5. シミュレーション

## 5.1 概要

第4章の結果に基づいて、ある年のエージェントは前年の 戦略から学習するという仮定で、戦略の進化をシミュレートする. 少ないパラメータで、行動原理に基づいた方法で妥当な結果を 得ることを目指す.

シミュレーションでは、占い師、人狼、裏切り者のとる戦略を 表す変数をそれぞれ*S*,*W*,*P*と書く.ありえるすべての状態に対 して、その発生確率はこれらの変数で表される.村人は、 *S*,*W*,*P*の値を知ることはできないが、セオリーとしてそれぞれ *S*,*W*,*P*'に等しいという考えを持つものとする.このセオリーは、 前年大会から学習したものと考える.*S*,*W*',*P*'の値と各プレイヤ ーのとった行動から、ベイズ推定的に役職を推定することができ る.プレイヤーの行動は、*S*,*W*,*P*および*S*',*W*',*P*'を用いて計算 される各プレイヤーの役職の確率分布によって決定される.起 こりうるすべての状況に対しそれが起こる確率とその時の村人 勝率の積の総和をとれば、村人勝率が分かる.すなわち、村人 勝率は*S*,*W*,*P*,*S*',*W*',*P*'の関数として表すことができる.村人勝 率を、*p*<sub>n</sub>(*S*,*W*,*P*,*S*',*W*',*P*')と書くことにする.

各役職は、ほかの役職のとる戦略が変わらないという仮定の もと、自分の陣営の勝率を最大化するような値を探索する.

## 5.2 ゲームのモデル化

5人人狼モデルでは,表 4 に示すような6つの変数を設定する.

以下に挙げるようないくつかの仮定をおいてゲームを単純化 し、決定論的なシミュレーションを可能にする.

- 占い師 CO者とその占い結果の組み合わせ以外の情報を プレイヤーが利用することはできない
- 2日目に起こることは一切考えず、1日目の時点で決着が 付くものとして考える。
- 1CO盤面になった場合、この時点で村人勝率は計算可能 であり、それ以降のシミュレーションは行わない.

モデル化された5人人狼におけるゲーム進行を図1に示す. 以下では、この図に従ってモデルの詳細を述べる.

## (1) 占い師 CO

初日の最初のターンに占い師 CO が行われる. 同時ターン制 を仮定するので,人狼,裏切り者は互いの出方を見てから占い 師を騙るかどうかを決定することができないものとする.

また, 占い師は必ず占い師 CO するものとする.

人狼, 裏切り者がそれぞれ占い師 CO をするかどうかで4通りの可能性がある. ゲームの進行上は, 占い師 CO 者の人数ごとに3通りに分岐する.

## (2) 1CO 盤面

1CO 盤面においては、村人勝率が 7/12 であることが解析的 に求められる.

#### (3) 2CO:占い師の結果出し

占い師の結果騙りは、村人を占ったとき占ったプレイヤー以外の人をランダムで選んで黒だしする、というパターンのみを考える.裏切り者、人狼に関しては、占い先としてありえるプレイヤー4通りと、占い結果(人狼か人狼でないか)の2通りで、4・2=8通りの可能性があり、その中から一様な確率でランダムに選んで行動する.

#### (4) 2CO:勝利陣営の決定

1日目の投票が終わった時点で以下のように村人勝率を定めることとし、2日目以降のシミュレーションは行わない.

- 人狼が追放された場合,村人の勝ちとなる
- 裏切り者が追放された場合,確率 1/3 で村人の勝ちとなる
- 村人が追放された場合,村人の負けとなる.

## (5) 3CO:占い師の結果出し

プレイヤー5人のうち,占い師 CO した3人以外の2人は村 人であることが全員の目線で確定する.占い師 CO した者たち の結果は、実質的に、村人に白出しするか対抗に黒出しするか のどちらかである.なぜならば、村人に黒出しすることは役職の 割り当ての組み合わせが存在せず、論理破綻を起こすためで ある.また、それぞれの占い師 CO 者の目線において対抗の一 人は裏切り者でもう一人が人狼であることはわかっているので、 対抗の一人に自出しすることは、もう一人の対抗に黒出しするこ とと等価である.

人狼は、対抗の二人を区別する情報がないため、2 人いる対抗を占う確率はそれぞれ(1/2)  $\cdot w_2$ である。裏切り者についても同様のことが言える。また、真の占い師については、もし占い先が村人であった場合には確率 $s_2$ で対抗のどちらかに 50%の確率で黒出しするものとする。

#### (6) 3CO:勝利陣営の決定

1日目の投票が終わった時点で以下のように村人勝率を定めることとし、2日目以降のシミュレーションは行わない.

- 人狼が追放された場合,村人の勝ちとなる.
- 裏切り者が追放された場合, 確率 1/2 で村人の勝ちとなる.
- 村人が追放された場合,村人の負けとなる.

### (7) 投票,追放先の決定

本モデルでは、村全体で合意の取れる人に最も投票が集ま るものと考え、追放先を決定する.この仮定は、話し合いによっ て村人同士で投票先を合わせられること、人狼は2日目のこと を考えて村人または占い師を騙らなければならず、怪しまれるよ うな投票はできないことから、この仮定は妥当であると考える.

| 表 4: | シミュレー | ション変数 |
|------|-------|-------|
|------|-------|-------|

| 変数名        | 意味                  |
|------------|---------------------|
| <b>S</b> 1 | 2CO盤面における占い師の結果騙り率  |
| <b>W</b> 1 | 3CO盤面における占い師の結果騙り率  |
| <b>p</b> 1 | 人狼の占い師CO率           |
| <b>S</b> 2 | 3CO盤面における人狼の対抗占い率   |
| W2         | 裏切り者の占い師CO率         |
| <b>p</b> 2 | 3CO盤面における裏切り者の対抗占い率 |



図 1:モデル化されたゲームのフロチャート

プレイヤーにとって、このモデルとS,W,Pの値を既知とする場合、ベイズ推定によって各プレイヤー役職を推定することができる.実際には、村人たちはS,W,Pの値を知らず、代わりに、第三者視点から、S',W',P'を用いてベイズ推定により各プレイヤーの役職の確率分布を求める.村人たちはモデル自体を共有していることを仮定するので、勝率が最も高くなるような投票先を選ぶことが可能である.具体的には、3CO 盤面の場合、(人狼確率)+(1/2)・(裏切り者確率)が最大のプレイヤーに投票し、2CO 盤面の場合、(人狼確率)+(1/3)・(裏切り者確率)が最大のプレイヤーに投票する.

#### 5.3 勝率計算

すべての変数の値を固定すれば、ゲームの考えうるすべての 展開をシミュレートすることによって、村人陣営の勝率の厳密な 計算が可能である. すなわち、起こりうるすべての盤面の状態に 対して、それが起こる確率とそのときの村人勝率の積の総和を 計算すればよい. 盤面の状態とは具体的に、3CO 盤面の場合、 3人の占い師 CO 者の結果の組み合わせのことであり、2CO 盤 面の場合、占い師を騙ったのが人狼と裏切り者どちらであるかと、 占い結果の組み合わせのことである.

各盤面の状態に対する発生確率は*S*, *W*, *P*から計算可能である. そのときに追放されるプレイヤーは*S'*, *W'*, *P'*から計算可能であり, その時点で村人勝率は確定する.

以後,村人陣営の勝率をp<sub>v</sub>(S,W,P,S',W',P')と書くことにする.

#### 5.4 シミュレーション条件

 $s_1, w_1, p_1, s_2, w_2, p_2$ はそれぞれ 0.2 と 0.8 の二値を取るものと する. ある時点における流行りの戦略が(S', W', P')とあらわされ, それに対し, 次のステップにおいて流行りの戦略が ( $S_{new}, W_{new}, P_{new}$ )になるとしたとき,

 $S_{new} = \operatorname{argmax}_{S} [p_v(S, W', P', S, W', P')]$   $W_{new} = \operatorname{argmin}_{W} [p_v(S', W, P', S', W', P')]$   $P_{new} = \operatorname{argmin}_{P} [p_v(S', W', P, S', W', P')]$ が成り立つものとする。

#### 5.5 結果と考察

シミュレーションの結果を図2に示す. ノードの書かれた数字 は上段が左から $s_1, w_1, p_1$ の値であり、下が左から $s_2, w_2, p_2$ の値 を表している.また、5.3節における(S', W', P')から ( $S_{new}, W_{new}, P_{new}$ )に向かってエッジが付与されており、エッジ を辿ることで戦略の遷移を追うことができる.

表 3から,  $s_1$ が増加,  $w_1$ が減少,  $p_1$ が高い値を維持,  $s_2, w_2, p_2$ が低い値を維持している. ここで, 2017年, 2018年そ れぞれで採用されていた戦略を見ると,赤枠で囲われた箇所に 相当していることが分かった. したがって,本シミュレーションは 2017年から 2018年の戦略の進化を内包しているといえる.

任意の状態から遷移をたどると、特定の一状態に収束はせず、図2に青枠で示したサイクルに到達することが明らかとなった.従って、2017年及び2018年のデータとの対応が見られた赤枠の部分から遷移を辿っても、安定状態には到達しない.このことから、今後の人狼知能大会における戦略の推移において、ナッシュ均衡解は発見されない可能性が示唆された.

### 6. 結論

過去の人狼知能大会のデータログから,2017年,2018年 大会においてどのような戦略が各陣営の勝利に貢献しているか を分析した.2018年のエージェントは2017年のエージェントに 対して勝率が高くなるような戦略を取る傾向にあることを回帰分 析により確認した.

また、5人人狼のゲームを現実的な時間で網羅的、決定論的 シミュレーションが行えるようにモデル化した.実際にシミュレー ションを行うことで、遷移を繰り返していっても特定の状態に収 束せず、周期的に変化し続けるようになるという結果を得た.こ のことから、今後の人狼知能大会において、ナッシュ均衡解に は辿り着かない可能性があることが明らかとなった.

本手法は、2日目を考えないなど大きな仮定を置いて、ゲー ムを単純化している.その点において、現実を正確に表せてい ないと考えられる.単純化を取り除くためには、行動原理の設定 に工夫が必要である.しかし、どのように設定するべきかは非自 明であり、より詳細なログ解析が必要である.この点に関しては 今後の課題とする.

#### 参考文献

- [篠田 14] 篠田孝祐, 鳥海不二夫, 片上大輔, 大澤博隆, 稲葉 通将:汎用人工知能の標準問題としての人狼ゲーム, 人工 知能学会全国大会 JSAI2014, 2C4-OS-22a-3, 2014.
- [Braverman 08] M.Braverman, O.Etesami, and E.Mossel. Mafia: A theoretical study of players and coalitions in a partial information environment. *The Annals of Applied Probability*, pp. 825–846, 2008.



図 2:シミュレーション結果の遷移図

- [片上 15] 片上大輔, 鳥海不二夫, 大澤博隆, 稲葉通将, 篠田 孝祐, 松原仁, 人狼知能プロジェクト, 人工知能学会論文 誌, vol.30(1), pp.65-73, 2015.
- [大澤 17] 大澤博隆, 汪博豪, 佐藤健:進化シミュレーションを用 いた3人人狼の分析, 日本ソフトウェア科学会第 34 回大会 講演論文集, 2017.

## 付録:人狼用語

## (1) CO

カミングアウトの略. 自らの役職を表明すること.

#### (2) 1CO,2CO,3CO

占い師 CO する人数が1人, 2人, 3人であるようなゲームの状態をそれぞれ 1CO,2CO,3CO と呼ぶ.

#### (3) 対抗

占い師 COしたプレイヤーに対し,他の占い師 COしたプレイ ヤーを対抗と呼ぶ.

#### (4) 白出し,黒出し

占いの結果報告が、「人狼でない」の場合白出し、「人狼であ る」の場合黒出しと呼ぶ.

# 協調パターンタスクの行動実験に基づいたシミュレーション分析

Simulation Analysis based on Behavioral Experiment of Cooperative Pattern Task

渡邊紀文\*1 Norifumi Watanabe 糸田孝太 \*2 Kota Itoda

\*1武蔵野大学 Musashino University \*<sup>2</sup>慶應義塾大学 Keio University

We have a behavior experiment using pattern task abstracting cooperative behaviors that require intention estimation and action switching to specific goals. And we have analyzed strategies to adjust cooperative intention estimations. In this research, we constructed an agent model that have three strategies of "random selection", "selfpriority selection", and "other agent's target pattern estimation". And the decision making process was verified by simulation.

## 1. はじめに

我々は他者とのコミュニケーションにおいて,他者の行動か らその意図および次に行われるであろう行動を推定し、 それに あわせる形で自己の行動を決定する. このような協調行動は1 対1のコミュニケーションにおいては、他者の行動に信頼を おいて次の行動戦略を決定することが多いが、協調すべき他者 が複数存在する場合は,着目すべき他者を選択および順位付け をし,順番に意図を推定して協調すべき他者を決定すると考え られる.具体的にはサッカーやハンドボールといったゴール型 ボールゲームにおいては、自身が敵に囲まれたときに、周囲に 存在するチームメイトの中からパスを受け取りゴールに近づ くことが出来る選手を複数選択し、それぞれのパス成功確率お よび次に行うであろう行動意図を推定する. 更にゴールに繋が るまでの協調パターンを評価し、最も得点に繋がるパターンを 選択して、そこに存在する選手にパスを出すと考えられる. こ のような協調パターンを人間がどのように評価しているのか, また人間と協調パターンを形成するエージェントにはどのよう な行動戦略モデルを構築すべきかを明らかにするため、本研究 では協調パターンタスクの行動実験に基づいたモデル構築とシ ミュレーション分析を行う.

## 2. 先行研究

他者の意図・信念状態の表現及び意図推定の深さに関しては, 誤信念課題に見られるような他者の知識としての信念表現[1]や, またより工学的な立場からは BDI(Belief-Desire-Intention) モ デルに見られるような信念 (belief), 願望 (desire), 意図 (intention) の三つの主要なパラメータによる認知過程の説明が行 われてきた [2]. 近年では確率モデルを用いて人間の意図の推定 を逆計画 (reverse planning) の問題として扱う研究 Bayesian Theory of Mind[3] や,強化学習モデルを用いた様々な深さの 意図を持つエージェントによる協調課題の研究[4] があり,意 図を扱う問題に対するエージェントベースアプローチの有効 性が示されている.意図推定の対象とすべき他者の選択では, 見えない他者への信念に関する研究 [5] なども行われている.

## 3. 協調パターンタスク

これまで我々は、協調課題パターンタスクの開発及び複数人 で実験できるシステムの構築を行い、人のみ4人で構成された 小集団における行動実験を通じて被験者の行動を分析した[6].

パターンタスクでは同時に4人が参加をし、2次元グリッド ワールドで非言語コミュニケーションのみで協調し共通の目標 を達成する事を目的とする.それぞれの被験者はグリッドワー ルド上の円形のコマを操作し、各ステップにおけるお互いの行 動をもとに他者の意図を推定し、目標となるパターンを形成す る(図1).目標とするパターンは相対位置関係で表現する図 形であり、4つのコマの内3コマで構成される.そのため各被 験者はパターン形成に関与するコマを選択して行動をする必 要がある.なおパターンは平衡移動した座標でも達成と認める が、回転や反転した座標は認めない.



図 1: 被験者が移動するグリッドワールド(左).大きい円の コマで各被験者のそれぞれの位置を示し、小さい円によって一 ステップ前に被験者がどこにいたのかを表示している.目標と なるパターン(右).

他者との意図の調整について分析をしたところ,課題中の 序盤や終盤での調整の違いによって目標パターン到達の進度が 変化するという結果を得た.また最適なステップで目標に到達 する行動を被験者が仮定することで,意図の誤推定を防止する という方策を持つことが示唆された.そこで次にパターン選択 における被験者の戦略について分析した.

連絡先: 渡邊紀文, 武蔵野大学データサイエンス学部, 東京都 西東京市新町 1-1-20, noriwata@musashino-u.ac.jp

#### 3.1 パターン選択の戦略

行動実験より,被験者が想定するパターンと他者のパターン との関係について,序盤で各被験者は新規パターンを想定して いるが,全員の意図が一致をする時には一部の被験者が自身 の目標パターンを変更し,最終的には全員一致した状態でそ れぞれのパターンを継続して推定するという結果が得られた. 具体的には被験者が選択するパターンに次の3つの関係がみ られた.

戦略 a 前ステップの自分が選択したパターンを選択

戦略 b 前ステップで他者が選択したパターンを選択

戦略 c a, b とは異なる新規のパターンを選択

これらの3つの戦略に基づいて、被験者のパターン選択過 程を分析したところ、タスク初期では戦略 c の新規のパターン を選択し、その後は被験者のうち一人が他の被験者が選択して いるパターンに合わせるという戦略の変化が見られた. このよ うな戦略の変化は試行前半で共通合意に至る場合と,後半で一 致する場合に分けられ、少ないステップ数で目的パターンを達 成できている多くの場合では、序盤に行動意図が分かるような 明示的な行動を取り、それに対して他者が合わせる事が多く見 られた. この結果より、全員が協調する事を促す本パターンタ スクにおいては、自己の行動意図をできるだけ分かりやすい形 で他者に提示し, 各状況において最も全体の到達ステップが短 くなるような目標パターンを選択する.更に選択可能なパター ンの中から多数決をとり、多くの被験者が取っているパターン を優先して選択するという行動戦略が考えられる. この結果か ら得られた集団での行動戦略を元に、エージェントモデルを構 築した.

# 4. シミュレーション分析

3章での分析結果を元に構築したエージェントモデルを,パ ラメータの違いにより複数用意し,シミュレーションを行う事 で,最も被験者の行動を説明できるモデルを検証する.エー ジェントの条件は次のように設定した.

- ランダム選択 4 体のエージェントから最短経路で到達するパ ターンに関与するエージェント 3 体をランダムに選択し, 入っていない場合はランダムな方向へ移動
- 自己優先選択 最短経路で到達するパターンの中から,自分が 含まれているパターンを優先して選択
- 他者エージェントの推定 他者エージェントの1ステップ前の 行動から目標とするパターンを推定し、それらの中から 最も多く選択されているパターンを選択

シミュレーションでは初期位置と初期目標パターンを100回 ずつランダムに用意し、それぞれの目標パターン到達ステップ 数を「ランダム選択」と「自己優先選択」行動選択と、「他者 エージェントの推定」の有無の組み合わせ条件によって比較 した.ステップ数を比較した結果を図2に示す、「ランダム選 択」および「自己優先選択」ともに、「他者エージェントの推 定」を行った場合の平均到達ステップ数(1-b および2-b)は 減少した.更に「ランダム選択(1-b)」と比較し、「自己優先選 択(2-b)」の戦略をとった場合がステップ数が少なかった.

「他者エージェントの推定」を選択した場合は,該当のエー ジェントとその行動から目標パターンを推定するため,その



図 2: 目標パターン到達のステップ数の比較. 1-a:ランダム選 択+他者エージェントの推定無, 1-b:ランダム選択+他者エー ジェントの推定有, 2-a:自己優先選択+他者エージェントの推 定無, 2-b:自己優先選択+他者エージェントの推定有.

エージェントが含まれている目標パターンを優先的に選択し, 「自己優先選択」他者にも仮定する事になる.そのため他者の 次のステップの行動選択と合致する事により,到達ステップ数 は大幅に減ると考えられたが,そのような結果は得られていな い.この原因としては,多数決の結果が複数存在した時に,そ の中からランダムに選択していたことが影響していると考えら れる.

## **5.** おわりに

本研究では協調パターンタスクの行動実験に基づき,「ラン ダム選択」「自己優先選択」「他者エージェントの推定」の3つ の戦略を持つエージェントモデルを作成した.シミュレーショ ン結果より.「自己優先選択」および「他者エージェントの推 定」の両戦略を持つエージェントが最も早く目標パターンに到 達することができ,人間の行動実験と同様の結果が得られた. ただし本結果の差異は想定していた結果よりも小さいため,今 後各ステップでの人間の行動選択との比較など詳細な分析が必 要である.

- [1] 子安増生、心の理論ー心を読む心の科学(岩波科学ライブ ラリー(73))、岩波書店、2000
- [2] G. Weiss: Multiagent Systems, second edition, MIT press, 2013
- [3] C. L. Baker, R. Saxe, J. B. Tenenbaum: Action understainding as inverse planning", Cognition, pp.329-349, 2009
- [4] 横山絢美,大森隆司:協調課題における意図推定に基づく行動決定過程のモデル的解析",電子情報通信学会論文誌, Vol. J92-A, No.11, pp.734-742, 2009
- [5] 大森隆司、ヒトの心のプロセスの計算論的理解に向けて、電子情報通信学会技術研究報告、Vol. 109, No. 460, pp.107-112, 2010
- [6] K. Itoda, N. Watanabe, Y. Takefuji: Analyzing Human Decision Making Process with Intention Estimation using Cooperative Pattern Task, Artificial General Intelligence — 10th International Conference (Springer Verlag), Vol.10414LNAI, No.10, pp.249-258, 2017

# 3者間人狼における他者の投票行動を考慮した戦略の検討

Analyis of Strategies in Werewolf Game by 3 Players Considering Voting Behaviour of Other Players

玉井 日菜子

Hinako Tamai

奈良女子大学大学院 人間文化研究科 博士前期課程 情報衣環境学専攻 Department of Computer Science and Clothing Environment,

Graduate School of Humanities and Sciences, Nara Women's University

In this research, based on the Utterance model in Werewolf Game by 3 Players of the previous research, we examined the strategy of reasonable voting behavior when anticipating the voting behavior of others. As a result, we found that a strategy which is quite different from the voting behavior which is considered reasonable when not considering the voting behavior of others is obtained. In addition, we found that the same strategy appears at regular intervals when the estimation of the voting behavior of others is repeated.

## 1. はじめに

近年、人狼ゲームに関する研究は盛んに行われている。人 狼ゲームとは、対話型のコミュニケーションによって進行する 不完全情報ゲームである。その特徴から、人工知能のための標 準問題としての可能性が検討されている [篠田 14]。従来研究 では、人狼ゲームをプレイする人工知能が挙げられ、強い人狼 エージェントも現れている。既存の人狼エージェントでは強化 学習を使用したものが多いが、論理的思考に着目したものは少 ない。一方で [大澤 14] において、人狼におけるエージェント の推論モデルとして、各エージェントの信念や意図などを明示 的に表現できる BDI モデルの利点が指摘されており、また、 BDI 論理を用い、実際の人狼ゲームで行われている複雑な推 論を記述する例が示されている。そこで、我々は BDI 論理に 基づいた論理的思考を戦略決定に用いる人狼エージェントの実 現を目指している。しかし、実際の人狼ゲームでの推論は多彩 かつ複雑であるため、エージェントに組み込める形にするには 人狼ゲームの論理的分析が必要となる。

論理的分析を行っている例として、[大澤 16] が挙げられ、人 狼ゲームの最小系である 3 人人狼において、各プレイヤーの 発言の選択肢を削減できるか検討されている。そこで、本研究 では、[大澤 16] で使用された 3 人人狼における発話のモデル を元にし、他者の投票行動を予想した上での合理的な投票行動 の戦略について検討した。その結果、互いに他者の行動を予想 しあうと安定した戦略に収束しないこと、また、[大澤 16] の 分析で合理的とされる投票行動とはかなり異なる戦略が得られ ることが分かった。

# 2. 制限を設けた人狼の戦略分析の研究

[西崎 17] では、ワンナイトではあるが 3 者間ではない人狼 の発話や投票に関する戦略分析が行われている。こちらは実際 のゲーム (100 ゲーム) の分析である。[杉本 17] では、5 人人 狼で村人に着目して投票行動の決定過程の分析が行われてい る。これも実際に行ったゲームの過程を分析している。これら に対し、我々は 3 者間で全ての可能性の分析を行っている点が 異なる。[汪 17] では、3 人人狼で、進化シミュレーションの手 法を用いて、人狼プレイヤーがどのように戦略を変化させてい くかの分析が行われている。プレイヤーが他プレイヤーの行動 を考慮した戦略決定を行っている点は本研究と同様と考えられ るが、シミュレーションによって変化の過程を調べている点が 我々と異なる。

# 3. 一般的な人狼ゲームのルール

ゲーム開始時に各プレイヤーに役職が割り当てられ、役職に 従い村人陣営と人狼陣営に分かれてプレイを行う。また、役職 に応じて特殊能力が与えられる。役職には例えば、特定のプレ イヤーが人狼であるかどうか知ることが出来る占い師などがあ る。村人陣営の勝利条件は人狼をすべて追放することであり、 人狼陣営の勝利条件は村人の数を人狼の数以下にすることであ る。ゲームは昼と夜の2つのフェーズで進行する。昼のフェー ズでは各プレイヤーが自由に対話を行い、得られた情報を元 に、投票によって誰をゲームから追放するかを決定する。夜の フェーズでは、それぞれの役職に応じた能力を行使する。人狼 は1人のプレイヤーを指定し襲撃することができる。対話にお いて、村人陣営側は人狼陣営の嘘を見破ることが重要となる。 一方人狼陣営側は役職を偽るなどの嘘をつき、議論を混乱させ 自分たちが不利にならないように誘導することが重要となる。 ゲームが進むにつれ、各プレイヤーは投票で追放されるか、人 狼に襲撃されることでゲームから除外される。そうして勝利条 件のどちらかが達成されたとき、ゲームは終了する。

## 4. 3 者間人狼の定義

当研究では、[大澤 16] の3人人狼における発話のモデルを 使用し、また、相手の投票行動を想定しない場合の合理的な行 動の分析を出発点としてを使用する。以下に概略を述べる。

## 4.1 3者間人狼の扱う範囲

3 者間人狼の場合、処刑が一回行われるとゲームが終了する ため、夜のフェーズは存在しない。同時発話 1 回のもと、投 票を行う。全員が同数投票 (3 者間人狼では各自 1 票ずつ投票) された場合引き分けとする。役職は、村人陣営である村人、占 い師、人狼陣営である人狼で構成され、各役職につき、プレイ ヤーは 1 人である。占い師にはゲーム開始前にどちらが狼で あるかの情報を与える。

連絡先:玉井 日菜子,奈良女子大学情報衣環境学専攻生活情報 通信科学コース,sah\_tamai@cc.nara-wu.ac.jp

## 4.2 プレイヤーの合理的な行動 (相手の投票行動を想 定しない場合)

[大澤 16] では、以下の投票行動を合理的であるとして採用 している。

- 村人の戦略:自身が狼と一人だけから告げられたとき、そのプレイヤーへ投票する。また、村人プレイヤーにとって自分以外を狼と指すプレイヤーが1人だけいるとき、狼と指されたプレイヤーに投票する。
- 人狼の戦略:自身が狼と一人だけから告げられた時、そのプレイヤーへの投票する。

上記以外の場合は、投票先を決定することはできない。

## 4.3 発話について

発話の種類は以下の4通りである。簡易化のため、以降村 人、人狼、占い師のプレイヤーをそれぞれ、Pv、Pw、Psと 表記する。

- To:「自身が占い師ではない」
- Tv:「自身が占い師であり、狼は Pv (村人) である」
- Tw:「自身が占い師であり、狼は Pw (人狼) である」
- Ts:「自身が占い師であり、狼は Ps (占い師) である」

ただし、自身が占い師でありながら狼は自身であると発言する ことは矛盾するため、各プレイヤー 3 通り (村人は Tv、人狼 は Tw、占い師は Ts を除く)の発話がありえる。従って、発 話の可能性は計 27 通りある。

#### 4.4 投票について

占い師は、誰が人狼であるかを知ることができるため、常に 人狼に投票することが有利であるが、村人、人狼それぞれのプ レイヤーには2通り(村人は占い師または人狼に投票、人狼は 村人もしくは占い師に投票)の行動が存在する。27通りの発 話それぞれの場合における投票行動を[表 3]([大澤 16]による) に示す。このうち、先述の合理的な行動によって行動が決まる 場合は、その行動をとるものとする。Pv, Pw, Ps は村人・人 狼・占い師の発話、Vv, Vw は村人・人狼の投票先を表し、V, W, S は村人・人狼・占い師への投票を表す。U は投票行動を 決定できない(他の2プレーヤのいずれへの投票も含んだ)状 況を表す。

## 4.5 勝敗について

[表 3] にはそれぞれの場合の勝敗も示されている。勝敗については、簡略化のため [表 1] のように記述する。村人と人狼の投票先がどちらも U の場合、どちらとも判別がつかず、村側勝利、狼側勝利、引き分けのいずれをも含んだ状況となる [表 2]。この状況を [大澤 16] では case 3.1 と表しているため、便宜上同様の表現を使用する。

| 村側勝利 | V_win    |
|------|----------|
| 狼側勝利 | W_win    |
| 引き分け | draw     |
| 表 2  | case 3.1 |

表 1: 勝敗についての表記

| 村人投票先 | 人狼投票先 | 結果   |
|-------|-------|------|
| 人狼    | 占い師   | 村側勝利 |
| 人狼    | 村人    | 村側勝利 |
| 占い師   | 占い師   | 狼側勝利 |
| 占い師   | 村人    | 引き分け |

表 2: どの結果も含む状況

| Pv            | $\mathbf{P}\mathbf{w}$ | $\mathbf{Ps}$ | Vv           | Vw           | result                 |
|---------------|------------------------|---------------|--------------|--------------|------------------------|
| То            | То                     | То            | U            | U            | case 3.1               |
| То            | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | U            | draw or W_win          |
| То            | То                     | $\mathrm{Tw}$ | W            | $\mathbf{S}$ | V_win                  |
| То            | $\mathrm{Tv}$          | То            | W            | U            | V_win                  |
| То            | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | U            | case 3.1               |
| То            | $\mathrm{Tv}$          | Tw            | W            | $\mathbf{S}$ | V_win                  |
| То            | Ts                     | То            | $\mathbf{S}$ | U            | draw or $W_{-win}$     |
| То            | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | U            | draw or $W_{-win}$     |
| То            | Ts                     | Tw            | U            | $\mathbf{S}$ | V_win or W_win         |
| Tw            | То                     | То            | U            | V            | V_win or draw          |
| Tw            | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | V            | draw                   |
| Tw            | То                     | $\mathrm{Tw}$ | W            | U            | V_win                  |
| Tw            | $\mathrm{Tv}$          | То            | W            | V            | V_win                  |
| Tw            | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | V            | V_win or draw          |
| Tw            | $\mathrm{Tv}$          | $\mathrm{Tw}$ | W            | U            | V_win                  |
| Tw            | Ts                     | То            | $\mathbf{S}$ | V            | draw                   |
| Tw            | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | V            | draw                   |
| $\mathrm{Tw}$ | Ts                     | $\mathrm{Tw}$ | U            | U            | case 3.1               |
| Ts            | То                     | То            | U            | U            | case 3.1               |
| Ts            | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | U            | draw or W_win          |
| Ts            | То                     | $\mathrm{Tw}$ | W            | $\mathbf{S}$ | V_win                  |
| Ts            | $\mathrm{Tv}$          | То            | W            | U            | V_win                  |
| Ts            | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | U            | case 3.1               |
| Ts            | $\mathrm{Tv}$          | $\mathrm{Tw}$ | W            | $\mathbf{S}$ | V_win                  |
| Ts            | Ts                     | То            | $\mathbf{S}$ | U            | draw or W_win          |
| Ts            | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | U            | draw or $W_{-win}$     |
| $\mathrm{Ts}$ | Ts                     | $\mathrm{Tw}$ | U            | $\mathbf{S}$ | $V\_win \ or \ W\_win$ |

表 3: 一回同時発話の場合の結果の分類 (Vs=W)

# 5. 他プレイヤーの戦略を推測した上での戦略 の検討

[大澤 16] では、相手の投票行動が 4.2 に述べたように仮定 され、全プレイヤーに共有された場合の、プレイヤーの合理的 な発話行動について考察されている。具体的には、各プレイ ヤーの発話の選択肢が削減できるかどうかを考えており、特定 の発話を行った場合、全ての状態において他の発話よりも自身 の勝利の可能性が増えるならば、その戦略はより強い戦略とい え、選択肢を削減できる。

本研究では、発話の削減については考慮せず、全ての発話は 等しく選択されると仮定し、その結果、どのように投票行動が 変化しうるかについて考察する。具体的には、相手の投票行動 を仮定した上でどのプレイヤーに投票するのがより強いか考察 し、戦略を決定する。さらに決定された戦略を踏まえ、こちら がその戦略をとると予想した相手プレイヤーが新たに戦略を決 定する操作を繰り返すことにより、どのような結果が得られる か検討する。表記を簡易化するため、村人が Vn の戦略を選択 すると仮定した場合の最適な狼の戦略を Wn+1、狼が Wn の 戦略を選択すると仮定した場合の村人の戦略を Vn+1 と表す (n は 0 以上の整数)。また、V0、W0 は、4.2 で述べた、相手 の投票行動を想定しない場合の戦略を指す。

#### 5.1 一人称視点での発話の分類

一人称視点での発話パターンの分類ごとの戦略を検討する。 自分視点で区別がつけられない発話パターンを1つのグループ とする。村人、人狼、いずれの場合も 15 グループに分類でき る [表 4][表 5]。例として村人視点で、二つの発話パターン Pv = To, Pw = To, Ps =Tv と、Pv = To, Pw = Tv, Ps =To について述べる。この二つの発話の違いは、占い師が自身を狼 と指したか、人狼が自身を狼と指したかである。しかし、村人 視点では、どちらの発話パターンでも片方のプレイヤーが自分 を狼と指したことしか分からない。よって、この2つの発話 パターンは同グループに分類される。しかし、村人以外のプレ イヤーの発話が上記と同じ場合でも、村人が占い師宣言した場 合、区別が可能な場合が存在する。その例として、Pv = Ts, Pw = To, Ps = Tv と、Pv = Ts, Pw = Tv, Ps = To が挙げ られる。これらは、自身を狼と指したプレイヤーを狼と指した 場合と、自身を狼と指していないプレイヤーを狼と指したとい う点で区別可能である。

| Pv | $\mathbf{P}\mathbf{w}$ | $\mathbf{Ps}$ | Pv | $\mathbf{P}\mathbf{w}$ | Ps |
|----|------------------------|---------------|----|------------------------|----|
| То | То                     | То            | То | То                     | То |
| То | То                     | $\mathrm{Tv}$ | То | То                     | Tv |
| То | $\mathrm{Tv}$          | То            | То | $\mathrm{Tv}$          | То |
| То | То                     | Tw            | То | То                     | Tw |
| То | Ts                     | То            | То | Ts                     | То |
| То | Τv                     | Τv            | То | Τv                     | Tv |
| То | Ts                     | Tw            | То | Ts                     | Tw |
| То | $\mathrm{Tv}$          | Tw            | То | Τv                     | Tw |
| То | Ts                     | $\mathrm{Tv}$ | То | Ts                     | Tv |
| Tw | То                     | То            | Tw | То                     | То |
| Ts | То                     | То            | Ts | То                     | То |
| Tw | То                     | Τv            | Tw | То                     | Tv |
| Ts | $\mathrm{Tv}$          | То            | Ts | $\mathrm{Tv}$          | То |
| Τw | То                     | Tw            | Tw | То                     | Tw |
| Ts | Ts                     | То            | Ts | Ts                     | То |
| Tw | Τv                     | То            | Tw | $\mathrm{Tv}$          | То |
| Ts | То                     | $\mathrm{Tv}$ | Ts | То                     | Tv |
| Tw | Τv                     | Τv            | Tw | Τv                     | Tv |
| Ts | $\mathrm{Tv}$          | $\mathrm{Tv}$ | Ts | $\mathrm{Tv}$          | Tv |
| Tw | Τv                     | Tw            | Tw | Τv                     | Tw |
| Ts | Ts                     | $\mathrm{Tv}$ | Ts | Ts                     | Tv |
| Tw | Ts                     | То            | Tw | Ts                     | То |
| Ts | То                     | Tw            | Ts | То                     | Tw |
| Tw | Ts                     | Tv            | Tw | Ts                     | Tv |
| Ts | Τv                     | Tw            | Ts | $\mathrm{Tv}$          | Tw |
| Tw | Ts                     | Tw            | Tw | Ts                     | Tw |
| Ts | Ts                     | Tw            | Ts | Ts                     | Tw |

表 4: 村人視点のグループ化 表 5: 狼視点のグループ化

#### 5.2 戦略の決定

最も有利となる投票先を、以下の条件のもとで決定する。

- 一番勝つ可能性が高い投票を行う。
- 勝つ可能性が同じの場合、引き分けになる確率が高い投 票先を選ぶ
- 上記の操作を行い1つに決定出来ない場合、どちらに投 票してもよいとする。

プレイヤーの区別がつき、かつ、どちらに投票しても有利度 が変わらない場合、村人の場合 WS、人狼の場合 VS と表記す る。プレイヤーの区別がつかない場合、投票先を決定できない ため、U と表記する。

#### 5.3 結果と考察

V0 を起点とした場合、V6 以降 V2~W5 をループし、W0 を起点とした場合、W6以降W2~V5をループすることが判明 した [表 6][表 7]。また、それぞれの戦略における、各勝敗の合 計と、勝率を [表 8] に記載し、それぞれの戦略と発話パターン における勝敗の詳細については、http://blackknight.ics. nara-wu.ac.jp/~u1448029/winloss.pdf に記載する。VW0 は、相手の投票行動を想定しない場合の戦略を両プレイヤーが 取った場合、つまり、[表 3] に記された勝敗の合計である。[表 8] 中の Wn は、村人が Vn-1 の戦略、人狼が Wn の戦略を選択 した場合の勝敗のことを指す (nは1以上の整数)。Vn につい ても同様である。W1 では例えば Pv=To, PW=To, Ps=Tw の場合に投票行動が V となるなど、4.2 で述べた戦略とは異 なるものが得られることも分かった。また、村人の場合、引き 分けと負けの比率は変動するが、どの戦略を選択しても勝つ 確率は変わらないことが分かった。さらに、相手プレイヤーの 投票行動が推定通りの場合、人狼は W4、村人は V4、V6 の 戦略を取ると最も有利になり、相手プレイヤーが自分の投票行 動を推測した上で投票したと仮定すると、人狼は V0、村人は W0、つまり相手の投票行動を想定しない場合の合理的な戦略 を取ると最も有利であることが分かった。

## 6. まとめ

本研究では、先行研究における3人人狼における発話のモデ ルを元にし、他者の投票行動を予想した上での合理的な投票行 動の戦略について検討した。その結果、他者の投票行動を考慮 しない場合の戦略とは、かなり異なる戦略が得られた。また、 他者の投票行動の推定を繰り返すと、一定間隔で同じ戦略が現 れ、安定した戦略に収束しないことが分かった。今後は、人数 や発話内容を増やす等のモデルの複雑化を行い、同様の研究を 行う予定である。

- [篠田 14] 篠田孝祐, 烏海不二夫, 稲葉通将, 大澤博隆, 片山大 輔, 人工知能標準問題としての人狼ゲームの提案, 第 24 回インテリジェント・システム・シンポジウム, pp.74-77, 2014.
- [大澤 14] 大澤博隆, 鳥海不二夫, 稲葉通将, 片山大輔, 梶原健 吾, 篠田孝祐, 人狼知能達成におけるエージェントの推論 モデル, 第 19 回 ゲームプログラミングワークショップ 2014, pp.157-161, 2014.
- [大澤 16] 大澤博隆,佐藤健,3 者間人狼における戦略の検討, 2016 年度人工知能学会全国大会,2F4-3,2016.

| The 33rd Annual | Conference | of the Japanese | Society for A | rtificial Intelligence, | 2019 |
|-----------------|------------|-----------------|---------------|-------------------------|------|
|                 | ./         | ./ /            | ~ ./          |                         |      |

|                | VW0  | W1   | V2   | W3   | V4   | W5   | V6   | V1   | W2   | V3   | W4   | V5   | W6   |
|----------------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| V_win          | 9    | 9    | 12   | 12   | 12   | 12   | 12   | 9    | 9    | 11   | 11   | 10   | 10   |
| V_win or draw  | 2    | 3    | 1    | 1    | 1    | 1    | 1    | 0    | 3    | 1    | 0    | 1    | 2    |
| case 3.1       | 5    | 3    | 1    | 1    | 1    | 1    | 1    | 8    | 4    | 4    | 4    | 4    | 4    |
| V_win or W_win | 2    | 3    | 1    | 1    | 1    | 1    | 1    | 1    | 2    | 0    | 1    | 2    | 1    |
| draw           | 3    | 0    | 10   | 0    | 11   | 0    | 11   | 6    | 0    | 10   | 0    | 10   | 0    |
| draw or W_win  | 6    | 1    | 2    | 1    | 1    | 1    | 1    | 3    | 0    | 1    | 1    | 0    | 0    |
| W_win          | 0    | 8    | 0    | 11   | 0    | 11   | 0    | 0    | 9    | 0    | 10   | 0    | 10   |
| 村側勝率           | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  | 0.5  |
| 狼側勝率           | 0.19 | 0.40 | 0.06 | 0.45 | 0.05 | 0.45 | 0.05 | 0.15 | 0.41 | 0.06 | 0.44 | 0.07 | 0.43 |

表 8: 戦略ごとの各プレイヤーの勝率

| Pv | $\mathbf{P}\mathbf{w}$ | $\mathbf{Ps}$ | V0           | W1           | V2           | W3           | V4           | W5           | V6           |
|----|------------------------|---------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| То | То                     | То            | U            | U            | U            | U            | U            | U            | U            |
| То | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| То | То                     | $\mathrm{Tw}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| То | $\mathrm{Tv}$          | То            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| То | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | V            | U            | $\mathbf{S}$ | U            | V            | U            |
| То | $\mathrm{Tv}$          | Tw            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| То | Ts                     | То            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| To | Ts                     | Tw            | U            | $\mathbf{S}$ | U            | V            | U            | $\mathbf{S}$ | U            |
| To | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | То                     | То            | U            | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | То                     | Tw            | W            | U            | $\mathbf{S}$ | U            | W            | U            | $\mathbf{S}$ |
| Tw | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | $\mathrm{Tv}$          | То            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Tw | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | VS           | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | $\mathrm{Tv}$          | Tw            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Tw | Ts                     | То            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Tw | Ts                     | Tw            | U            | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Ts | То                     | То            | U            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Ts | То                     | $\mathrm{Tv}$ | $\mathbf{S}$ | U            | W            | U            | $\mathbf{S}$ | U            | W            |
| Ts | То                     | Tw            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Ts | $\mathrm{Tv}$          | То            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Ts | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Ts | $\mathrm{Tv}$          | Tw            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |
| Ts | Ts                     | То            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Ts | Ts                     | $\mathrm{Tv}$ | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            |
| Ts | Ts                     | Tw            | U            | VS           | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ |

表 6: V0 を起点とした場合の戦略の変化

- [西崎 17] 西崎絵麻, 坂口早紀, 尾崎知伸, ワンナイト人狼にお ける投票行動の分析, 第 31 回人工知能学会大会論文集, 2017.
- [杉本 17] 杉本磨美, 伊藤毅志, 5 人人狼における村人の意思決 定過程の研究, 日本認知科学会第 34 回大会論文集, pp.826-832, 2017.
- [汪 17] 汪博豪, 大澤博隆, 佐藤健, 進化シミュレーションを用 いた 3 人人狼の戦略分析, HAI シンポジウム 2017 論文 集, 2017.

| $\mathbf{P}\mathbf{v}$ | $\mathbf{P}\mathbf{w}$ | $\mathbf{Ps}$ | W0           | V1           | W2           | V3           | W4           | V5           | W6           |
|------------------------|------------------------|---------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| То                     | То                     | То            | U            | U            | U            | U            | U            | U            | U            |
| То                     | То                     | $\mathrm{Tv}$ | U            | WS           | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| То                     | То                     | $\mathrm{Tw}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| То                     | $\mathrm{Tv}$          | То            | U            | WS           | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| То                     | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | U            | VS           | U            | VS           | U            | VS           |
| То                     | $\mathrm{Tv}$          | $\mathrm{Tw}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| То                     | Ts                     | То            | U            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| То                     | Ts                     | $\mathrm{Tv}$ | U            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| То                     | Ts                     | $\mathrm{Tw}$ | $\mathbf{S}$ | U            | V            | U            | $\mathbf{S}$ | U            | $\mathbf{V}$ |
| Tw                     | То                     | То            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | То                     | $\mathrm{Tv}$ | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | То                     | Tw            | U            | WS           | U            | WS           | U            | WS           | U            |
| Tw                     | $\mathrm{Tv}$          | То            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | $\mathrm{Tv}$          | $\mathrm{Tv}$ | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | $\mathrm{Tv}$          | Tw            | U            | WS           | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| Tw                     | Ts                     | То            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | Ts                     | $\mathrm{Tv}$ | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Tw                     | Ts                     | Tw            | U            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            | WS           | $\mathbf{S}$ |
| Ts                     | То                     | То            | U            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| Ts                     | То                     | $\mathrm{Tv}$ | U            | W            | U            | $\mathbf{S}$ | U            | W            | U            |
| Ts                     | То                     | Tw            | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| Ts                     | $\mathrm{Tv}$          | То            | U            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| Ts                     | $\mathrm{Tv}$          | $\mathrm{Tv}$ | U            | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | V            |
| Ts                     | $\mathrm{Tv}$          | Tw            | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | W            | $\mathbf{V}$ |
| Ts                     | Ts                     | То            | U            | WS           | VS           | WS           | VS           | WS           | VS           |
| Ts                     | $\mathrm{Ts}$          | $\mathrm{Tv}$ | U            | WS           | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ |
| Ts                     | $\mathrm{Ts}$          | $\mathrm{Tw}$ | $\mathbf{S}$ | W            | V            | $\mathbf{S}$ | $\mathbf{S}$ | WS           | $\mathbf{V}$ |

## 表 7: W0 を起点とした場合の戦略の変化

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

| [3F4-OS-14b] 人狼知能と不完全情報ゲーム(2)  |        |
|--|--------|
| 稲葉 通将(広島市立大学)、片上 大輔(東京工芸大学)、狩野 芳伸(静岡大学)、大槻 恭士                        | (山形大学) |
| Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room F (302B Medium meeting room) |        |

| [3F4-OS-14b-01] | Development and evaluation of the game agent to change confidence of estimating in Cooperative game Hanabi  |
|-----------------|---|
|                 | OEisuke Sato <sup>1</sup> , Hirotaka Osawa <sup>1</sup> (1. University of Tsukuba)<br>3:50 PM - 4:10 PM   |
| [3F4-OS-14b-02] | Role estimation in Werewolf games using a selective desensitization neural network<br>Masahiro Saito <sup>2</sup> , Seiryu Mishina <sup>1</sup> , OKen Yamane <sup>1</sup> (1. Teikyo University, 2. Fujisoft |
|                 | Incorporated)<br>4:10 PM - 4:30 PM  |
| [3F4-OS-14b-03] | Artificial Intelligence for Deducing Roles of Players in the<br>Werewolf Game using Information about Conversations among<br>Players  |
|                 | OMunemichi Fukuda <sup>1</sup> , Hajime Anada <sup>1</sup> (1. Tokyo City University)<br>4:30 PM - 4:50 PM  |
| [3F4-OS-14b-04] | Extraction of Interpretable Rules for Role and Team Estimation in AI Wolf   |
|                 | Yuki Omura <sup>1</sup> , Wataru Sakamoto <sup>1</sup> , OTomonobu Ozaki <sup>1</sup> (1. Nihon University)<br>4:50 PM - 5:10 PM  |
| [3F06-09-5]     | Discussion / Conclusion<br>5:10 PM - 5:30 PM  |
|                 |   |

# 相手の思考時間の長短によって推定の信頼度を変更する 協力ゲーム Hanabi のエージェントの開発及び評価

# Development and evaluation of the game agent to change confidence of estimating in Cooperative game Hanabi

佐藤 栄介<sup>\*1</sup> 大澤 博隆<sup>\*1</sup> Eisuke Sato Hirotaka Osawa

> \*1 筑波大学 University of Tsukuba

Abstract: AI agent for cooperation with human need to follow human thought. There are some research using cooperating game 'Hanabi' from various aspects such as self-estimation, psychology, and communication theory. In this research, we developed an agent's strategy for following human thought for guessing human understanding of AI's strategy to utilize the length of thinking time of the human player and changing the estimation reliability. As a result, we found that this agent estimated more frequently to the good player of Hanabi than the conventional agent and there is a positive correlation between some evaluation to this agent and score. However, the agent that change estimation reliability depending on opponent's thinking time didn't affect human's impression compared to the conventional agent and there was no significant difference in the score and the success rate of the estimation by changing the reliability of the estimation according to the thinking time.

## 1. 序論

現在、人間と協力するエージェントの開発のため、協力ゲーム の研究が注目されている。プログラムでゲームをプレイする分野 において、人間に勝つことを目標としたエージェントは将棋や囲 碁などで開発されており、その目標は達成されつつある。その 一方で、人間と協力して一つの課題を達成するエージェントは まだ発展途上である。このようなエージェントが、人間に勝つこと を目標としたエージェントと異なる部分は、人間側に行動の意図 を汲んでもらうために人間の思考に合わせて人間に近い行動を とらなければならないところである。よって、このようなエージェン トの開発は人工知能の人間らしさの獲得および人間の知能の 人間らしさの解明に貢献すると考えられる。

協力ゲームをプレイする AI に関する研究の一つとして協力カ ードゲーム「Hanabi」を用いた研究が挙げられる。このゲームの 大きな特徴は、相手の手札のみを見ることができて自分の手札 はわからないことと、相手への情報提供がトークンによって制限 されていることである。我々は Hanabi において他者の視点と行 動をシミュレートして、自分の状態を推測するエージェントを開 発した[1]。また、Eger らは心理学の手法とコミュニケーション理 論から、人間がエージェントに対して何か意図を持って行動し ていると感じた時、人間はそのエージェントの能力を高く評価し 好感を抱くということを示した[2]。

ただ、これらの既存の研究では人間側の思考時間という情報は Hanabi をプレイするエージェントの戦略において利用されてい ない。

本研究では Hanabi において、協力のために人間プレイヤーの 理解度を思考時間から推定するエージェントの戦略を検討する。 エージェントが協力ゲームをプレイする場合の戦略は協力相手 の思考に合わせたものであるため、人間とプレイする場合には 相手が自分のとった行動の意図を理解してくれることが前提に なっている。相手がエージェントの行動の意図を理解していな いと、お互いの行動がうまくかみ合わず、課題の失敗につなが る。相手がエージェントの戦略を理解しているならば推定の信 頼度を上げて推定を積極的に利用して行動するべきであり、逆 に相手がエージェントの戦略をあまり理解していないならばエー ジェントは推定の信頼度を下げて確定情報を重視して行動する べきである。そのため、相手の理解度の推定はエージェントが 戦略を決めるにあたって重要な問題である。

本研究ではエージェントの戦略に対するプレイヤーの理解度を プレイヤーが行動を選択するまでにかかる時間から判断するこ とを試みた。また、実際に人間にこのエージェントと Hanabiをプ レイさせることによって推定の信頼度を変更しない場合に比べ て得点および人間のエージェントに対する評価がどのように変 化するか調査した。

## 2. Hanabiの関連研究

協力ゲームをプレイするエージェントに関する研究は全体と してはまだ数が少ないが、近年では協力カードゲーム Hanabi に注目した研究が多く進められている。

我々は Hanabi において他者の視点と行動をシミュレートして、 自分の状態を推測するエージェントを開発し、この戦略を用い ることで確定情報のみに基づいて行動するエージェントより高い 得点が得られることをシミュレーションにより示した[1]。また、 Eger らは心理学の手法とコミュニケーション理論から、人間がエ ージェントに対して何か意図を持って行動していると感じた時、

<sup>&</sup>lt;sup>1</sup> 佐藤栄介,筑波大学,hailabsec@iit.tsukuba.ac.jp

人間はそのエージェントの能力を高く評価し好感を抱くというこ とを、エージェントと人間で Hanabi をプレイさせることにより示し た[2]。ただ、これらの既存の研究では人間側の思考時間という 情報は Hanabi をプレイするエージェントの戦略において利用さ れていない。思考時間は人間プレイヤーのゲーム及び相手に 対する理解度の指標として重要なものである。そのため、これを 利用することなしには人間と協力できるエージェントの開発は困 難であると考えられる。

また、Christopher らは帽子推測ゲームを応用した Hanabi に おける戦略について考察し、事前に戦略を共有することにより 75%以上の確率で最高得点をとれることを示した[3]。しかしこ れは事前に戦略を共有することを前提としており、またその内容 も複雑であることから人間と協力してプレイする戦略としては適 していない。

本研究では、事前の戦略の共有を行わずにゲーム中の相手 の思考時間を用いてエージェントの戦略に対する人間プレイヤ ーの理解度を判断し、その程度に応じて推定の信頼度を変更 するエージェントを開発し、実際に人とプレイすることによりその 評価を行う。

## 3. Hanabiのルール

本研究で用いるゲーム「Hanabi」のルールを以下に示す。

Hanabi は協力型のカードゲームであり、通常 2~5 人で行う。 今回の研究では 2 人でプレイする時のみを扱う。Hanabi は 50 枚のカードと 8 枚の情報トークンを用いて行うゲームである 50 枚のカードにはそれぞれ色と数字が設定されており、色は白、 赤、青、黄、緑の 5 色、数字は 1~5 の 5 種類である。カードは 各色 10 枚ずつ存在しその数字の内訳は 1 が 3 枚、2~4 が 2 枚、5 が 1 枚である。

このゲームの最終目的は盤面に各色のカードを 1~5 まで数 字の昇順に並べていきすべての色で 5 までカードを並べきるこ とである。ゲーム開始時、プレイヤーにはそれぞれ 5 枚のカード が手札として配られる。この時、自分の手札の情報は見ることが できず、相手の手札の情報のみが観測可能である。残りの 40 枚は裏向きにして山札として扱う。各プレイヤーは自分のターン に情報提供、カードの廃棄、カードのプレイの三つの内いずれ か一つの行動を選択して行うことができる。

情報提供では、相手プレイヤーの手札のカードの数字もしく は色を相手に教えることができる。この時、情報トークンを1 消 費する。情報トークンが1 つもない場合、情報提供を行うことは できない。また、情報を教える際には該当するものはもれなく教 えなければならない。例えば相手の手札が赤1、赤2、白1、白 2、緑1であるときに赤色を教える場合、「1番目と2番目のカー ドが赤である」というように教えることになり、どちらか一つのみの 情報を教えることはできない。

カードの廃棄では、自分の手札のうち必要ないと考えた1枚 を捨てることができる。その後、自分は山札からカードを1枚補 充する。またこの時情報トークンが7枚以下ならば情報トークン が1枚増える。廃棄したカードは両プレイヤーに公開され、その ゲーム中は使用することができなくなる。

カードのプレイでは、自分の手札の内1枚を花火につなげる ことを試みることができる。プレイしたカードが盤面の同色の花 火の数字より1大きい場合、プレイは成功となり、そのカードが 盤面の該当する色の花火に並べられて数字が1増加する。プ レイに失敗した場合、そのカードは廃棄される。成功した場合で も失敗した場合でもプレイしたカードは両プレイヤーに公開され てプレイヤーはプレイしたカードの代わりにカードを1枚山札か ら加える。 ゲームの終了条件は

・カードのプレイに3回失敗した場合

・山札が 0 枚になってから各プレイヤーが行動を一回ずつ行った場合

・すべての色の花火を5まで完成させた場合

の3 つである。盤面の花火の数の合計がそのまま得点になり、 最高得点は25 点である。

## 4. エージェントのアルゴリズム

本研究では相手プレイヤーの思考時間を戦略の指標に用い ない従来の自己推定エージェントと相手プレイヤーの思考時間 を戦略の指標に用いる新しい自己推定エージェントの2種類を 実装した。

## 4.1 従来の自己推定戦略

従来の自己推定戦略は加藤らが開発したアルゴリズムであり [4]、以下の優先順位で行動を行う。

#### (1) 数の確定情報のみに基づくカードのプレイ

色が不明だが、数字からプレイ可能カードであることが分かる カードをプレイする。例えば、ゲーム開始直後の状態の時、1の カードは色にかかわらずプレイ可能カードになる。

#### (2) プレイ可能カードの情報提示

相手がプレイ可能カードを持つことが分かり、そのカードの情報が相手にとって不完備な場合、情報提示を行う。数も色も情報が不完備な場合、教える情報をランダムに選択する。

#### (3) 自己推定に基づくプレイ可能カードのプレイ

相手の観測のシミュレーションを用いて自己の手札の推定を 行う。この時考えられる手札の可能性の集合を考え、この中に おけるカードの要素を出現数でソートし、1 番多い出現数の値 が次に多い出現数の値に対して a 倍以上のとき、このカードは 1 番多い出現数の値に等しいと推定する。この値がプレイ可能 カードの値に等しい場合にプレイする。

#### (4) 廃棄可能カードの情報提示

相手が廃棄可能カードを持つことが分かり、数または色を教 えることによって相手視点からも廃棄可能角であると断定できる 場合、その情報を提示する。

#### (5) プレイ可能カードのプレイ

自分の手札の情報と盤面の観測可能なカードからプレイ可 能カードが存在することがわかる場合、そのカードをプレイする。

#### (6) 廃棄可能カードの廃棄

自分の手札の情報と盤面の観測可能なカードから廃棄可能 カードが存在することがわかる場合、そのカードを廃棄する。

#### (7) ランダム廃棄

自分の手札の中で、最も情報量の少ないカードを廃棄する。最 も情報量の少ないカードが複数存在する場合、その中からラン ダムで廃棄する。

## 4.2 思考時間に応じて推定の信頼度を変える自己推定 戦略

本研究で開発した自己推定戦略は加藤らのアルゴリズムに 追加し、相手プレイヤーの思考時間に応じて推定の信頼度を 変更するようにした。まず、相手プレイヤーの各ターンにおける 行動選択にかかる時間を直前の5ターン分記録する。そこから 思考時間の平均と標準偏差を導き出し、次の思考時間が平均 +1標準偏差以上だったら相手は長考していると定義し、思考時間が平均-1標準偏差以下だったら相手は即決していると定義する。また、直前5ターンの思考時間の偏りによっては平均より標準偏差の方が大きくなり、即決であると定義できる時間がなくなってしまうことが起こりうる。そのため、相手プレイヤーが4.13秒以下の思考時間だった場合、平均や標準偏差にかかわらず即決であると定義する。この値は加藤が以前大学生12人を対象として行った Hanabi の実験における各プレイヤーの平均思考時間-1標準偏差の平均をとったものである[4]。この値は、各プレイヤーが即決したと判断される閾値の平均であるため、個人の直前の思考時間の平均や標準偏差にかかわらず即決であると判断できる閾値として妥当であると考えられる。

ここで思考時間の長短に対して以下の仮説を立てる。予備実験の結果、これらの妥当性は示された。

・長考している時、相手プレイヤーは自身の行動に自信がない ・即決している時、相手プレイヤーは自身の行動に自信がある。

相手が行動の選択において長考を続けるとき、相手プレイヤーは選択に自信が持てていない、すなわちエージェントの戦略があまり理解できていないと考えられる。この時にエージェントが推定を行うと、通常よりも推定に失敗する確率が高くなると考えられる。なぜならエージェントの自己推定は相手が自分のシミュレーション上の相手と同じように行動を起こすことが前提となっており、そのためには相手がエージェントの戦略をある程度理解していることが不可欠だからである。そのため、このエージェントは3.1の「3.自己推定に基づくプレイ可能カードのプレイ」で示したように推定で考えられる最も多いカードの値が次に多いカードの値のa倍以上なら推定に従うというアルゴリズムだが、相手が長考を2連続で行った場合はそのaの値を大きくすることにより推定の信頼度を下げる。

ー方相手が行動の選択において即決を続けるとき、相手プレイヤーは選択に自信を持っていると考えられるがその状況は大きく2つに分けられる。1つはエージェントの戦略を正しく理解できているときで、もう1つはエージェントの戦略を設って解釈しており、その誤った解釈に基づいて行動を進めている場合である。前者の場合、AIは推定の信頼度を上げるべきだが、後者の場合は推定の信頼度を下げるべきである。そのため、この2つの状況を判別するために相手プレイヤーのカードプレイの結果を利用した。具体的には、相手プレイヤーが即決を2連続で行った場合は推定の信頼度を上げるが、相手が即決でかつカードのプレイに失敗したときには推定の信頼度を下げるようにした。

## 5. 評価

人間・AI 間のゲームにおいて相手の思考時間の長短を推定 の信頼度の変化の指標として用いるエージェントを用いた場合 のゲームの得点に与える影響と、人間のエージェントに対して 抱く印象を評価するために実験を行った。

### 5.1 インタフェース

人間と AI 間のゲームを実現するために加藤らが開発したインタフェースを用いた[4]。これを図1に示す。 画面左下には自分の手札、画面左上には相手の手札が表示さ

れる。中央上は現在の盤面を表し、中央下の数は左から順番に 山札の枚数、情報トークンの枚数、プレイの失敗回数、得点を 示す。また、右にはプレイする、プレイに失敗する、廃棄する行 為によって観測可能になったカードが表示される。



図 1 Hanabiのインタフェース

#### 5.2 評価方法

本実験では相手のエージェントに対する印象を調べるため に、ゲームの記録と実験参加者の様子の撮影と実験後の 印象評価アンケートを行った。以下にアンケートの質問内 容を示す。

#### (1) 相手についての印象

- Q1. 意思を持っていると感じたか
- Q2. ゲームに慣れていたか
- Q3. 相手の行動の意図が分かったか
- Q4. 相手の行動に一貫性を感じたか

#### (2) ゲームについての印象

- 05. ゲームはやりやすかったか
- Q6. ゲームの結果に満足しているか
- Q7. 自由記述欄

本アンケートの設問のうち、

- Q1. 意思を持っていると感じたか
- Q2. ゲームに慣れていたか

この 2 つの項目は予備実験において有意差が表れたもので ある。また、

- Q7. 相手の行動の意図が分かったか
- Q8. 相手の行動に一貫性を感じたか

という2つの項目は人間が2種類のエージェントの差を実験 中に認識しているかを判断するために重要な役割を果たすと推 測した。よって、本実験ではこれら4間にゲームに関する質問2 問を加えた6問を設問として用いた。

Q7 の自由記述を除くすべての質問は予備実験と同様にそう思わないを1、そう思うを7とした7段階のリッカート尺度で回答する形式を用いた。

#### 5.3 実験手順

実験には20代大学生男女20人が参加した。参加者はHanabi のルールとインタフェースについて説明を受けた後、ゲームを4 回行った。従来の自己推定エージェントとのゲーム(以下 A 条 件)、相手の思考時間に応じた推定の信頼度の変化を加えた新 しい自己推定エージェントとのゲーム(以下 B 条件)の2条件の ゲームを1回ずつ行い、その後、順番を変えて1回ずつゲーム を行った。よって1人の実験参加者につき、A 条件、B 条件の サンプルの数はそれぞれ2つになる。実験に用いる山札は4 種類用意し、1人の実験参加者が4種類の山札でゲームを行う ようにした。ゲーム終了毎にアンケートを行い、最後にインタビュ ーを行って実験を終了した。

## 6. 結果

本実験では A 条件と B 条件のそれぞれでゲームを 40 回ず つ行った。よって最終的に A 条件、B 条件のデータはそれぞれ 40 個存在する。

エージェントの戦略を理解している人への本研究のエージェントが与える影響を調べるためにデータを分類した。人間側の AIの戦略に対する理解度の指標として得点を用いて、18 点以 上のものを戦略を理解しているゲーム(以下 A(h)、B(h)とする)と 定義して、A条件,B条件それぞれにおいて分類した。この閾値 は加藤の実験結果における Hanabiの平均得点 17.5 点から決 定した。結果、A(h)条件のデータは 21 個、B(h)条件のデータは 24 個になった。

A(h)条件においてカードの推定は 1 ゲームで平均 5.38 回 (SD2.79)行われ、その成功率は平均.728 (SD.196)であった。 B(h)条件においてカードの推定は 1 ゲームで平均 7.58 回 (SD4.39)行われ、その成功率は平均.744 (SD.208)であった。t 検定の結果、2 条件間で推定回数に有意差が見られた(p<.05)。

アンケートの結果を表3に示す。表3より、アンケート結果には2条件間で有意差が見られなかった。

|    | 21-1-1-1       | 1 1 1 1 1 1    |      |
|----|----------------|----------------|------|
|    | A(h)条件平均       | B(h)条件平均       | p值   |
| Q1 | 5.14 (SD 1.93) | 5.41 (SD 1.41) | .604 |
| Q2 | 5.38 (SD 1.05) | 5.08 (SD 1.44) | .439 |
| Q3 | 5.66 (SD 0.94) | 5.83 (SD 1.37) | .641 |
| Q4 | 5.19 (SD 1.10) | 5.08 (SD 1.68) | .803 |
| Q5 | 5.52 (SD 1.40) | 4.82 (SD 1.75) | .516 |
| Q6 | 5.00 (SD 1.23) | 4.79 (SD 1.55) | .627 |

表 1. アンケートの結果

アンケートの評価と得点の相関を調べた結果を下の表 4 に 示す。表 4 より、A(h)条件においては Q2 の評価と得点に正の 相関があった。また、B(h)条件においては Q2,Q3,Q4,

Q5,Q6の評価と得点に正の相関があった。(r>.4)

|    | <u> 私 4</u> , 旧内D | TV 304   |
|----|-------------------|----------|
|    | A(h)相関係数          | B(h)相関係数 |
| Q1 | .349              | 0.154    |
| Q2 | .508*             | 0.546*   |
| Q3 | .249              | 0.498*   |
| Q4 | 050               | 0.435*   |
| Q5 | .208              | 0.556*   |
| Q6 | .198              | 0.506*   |

表 2. 相関係数

# 7. 考察

本実験の得点と推定の成功率には A(h),B(h)2 条件間に有 意差は見られなかった。このことから、本研究で開発した、思考 時間を戦略の指標に取り入れたエージェントは得点においては 影響を及ぼさないといえる。

推定の回数においては B(h)条件が A(h)条件に比べて有意 に高かった。これは、エージェントの戦略を理解した実験参加者 は即決を連続で行う場面が多く、結果として推定の信頼度が上 がったゲームが多くなったからであると考えられる。また推定の 成功率は変わっていないことから、推定回数を増やしたことによ って推定の精度が変化することはなかったといえる。

両条件においてアンケート結果の有意差は見られなかった。 このことから、本研究で開発した思考時間を戦略の指標に取り 入れたエージェントは人への印象に影響を与えるかどうかはわからなかった。

両条件においてエージェントがゲームに慣れていると感じる プレイヤーは高得点を取る傾向があるといえる。これは、エージ ェントがゲームに慣れていると感じるときに、人間プレイヤーは エージェントとより協力して行動できているからであると考えられ る。また、B(h)条件においてのみ、エージェントの行動の意図を 理解した場合、エージェントの行動に一貫性を感じた場合、ゲ ームがやりやすいと感じた場合、結果に満足していると感じた場 合にも高得点を取る傾向があるといえる。これは、これらの項目 の評価が高い時、人間プレイヤーはエージェントの戦略を正し く理解しており、その結果として即決の行動が多くなり、エージェ ントの推定の信頼度が上がり、より協力できるようになったからで あると考えられる。

## 8. 結論

本研究では、協力ゲーム Hanabi において、相手の思考時間 から相手の行動選択の自信の有無を把握し、戦略における推 定の信頼度を変更する指標として用いたエージェントを開発し て、従来の自己推定戦略と比べた得点の変化、および人間に 与える印象の違いを調査した。

結果として、相手の思考時間の長短に応じて推定の信頼度 を変えるエージェントは、従来のエージェントと比較して得点と 推定の成功率に有意差は見られなかったが、推定の回数は増 加するため結果としてより多くの推定を成功させることが分かっ た。また、アンケートの結果より、相手の思考時間の長短に応じ て推定の信頼度を変えるエージェントにおいては、エージェント に対する評価やゲームに対する満足度が高いと得点も高い傾 向にあることが分かった。

今後の課題として思考時間をより適切に戦略の指標に組み 込んだエージェントの開発が考えられる。人間の思考時間に関 する仮説をより複雑にして人間の本来の思考に近いものにして、 思考時間の長短の定義の仕方をより適切なものに変更すること によりこの課題の達成が期待される。

#### 謝辞

本研究は JSPS 科研費 JP26118006, JP18KT0029 の助成を受けたものです。

- Osawa, H. (2015). "Solving Hanabi : Estimating Hands by Opponent's Actions in Cooperative Game with Incomplete Information." AAAI Workshop, Computer Poker and Imperfect Information, (pp. 37–43).
- [2] Eger, M., Martens, C., & Córdoba, M. A. (2017). "An intentional AI for Hanabi" IEEE Conference on Computational Intelligence and Games (CIG) (pp. 68-75).
- [3] Christopher Cox, Jessica De Silva, Philip Deorsey, Franklin H. J. Kenter, Troy Retter & Josh Tobin (2015) "How to Make the Perfect Fireworks Display: Two Strategies for Hanabi "Mathematics Magazine (pp. 323-336)
- [4] 加藤 拓也,大澤 博隆 "他者視点の推定を用いたエージェント評価 の向上:カードゲーム Hanabi の AI との対戦分析から"人工知能学 会全国大会論文集,第32回全国大会,4J2-01
- [5] Bartneck, C., Kulić, D., Croft, E., & Zoghbi, S. (2009). Measurement Instruments for the Anthropomorphism, Animacy, Likeability, Perceived Intelligence, and Perceived Safety of Robots. International Journal of Social Robotics, 1(1), (pp.71–81)

<sup>\*</sup> r>.4

# 選択的不感化ニューラルネットを用いた 人狼ゲームにおける役職推定

Role estimation in Werewolf games using a selective desensitization neural network

齋藤 正宏<sup>\*1</sup> 三品 晟瑠<sup>\*2</sup> 山根 健<sup>\*2</sup> Masahiro Saito Seiryu Mishina Ken Yamane <sup>\*1</sup>富士ソフト株式会社 <sup>\*2</sup>帝京大学 Fujisoft Incorporated Teikyo University

Estimating a player's role is important to win Werewolf games. As described in this paper, we propose a role estimation method incorporating a selective desensitization neural network. We evaluated its accuracy using a model constructed for 15-person games. Experimentally obtained results show that the model estimated six roles with 69% accuracy.

## 1. はじめに

人狼ゲームをプレイする人工知能(以下,人狼知能)におい て,他プレイヤの陣営や役職を推定する能力が勝敗を左右する 要素の一つであるといわれる[梶原 16,大川 17].そこで,プ レイヤの役職を推定する方法が幾つか提案されている。例え ば,サポートベクタマシン(以下,SVM)を用いて15人人狼 における推定方法が提案されている[梶原 16].また,梶原ら の特徴にさらに3つの特徴を追加して,深層学習を用いた推 定方法が比較されており.5人人狼において推定精度はよいも ので72%であった。

人狼ゲームは不完全情報ゲームであるため、確かに推定精 度 100%の実現は不可能である.しかし、さらなる精度向上が 望まれ、特に有利な能力をもつ占い師などの役職や排除するべ き人狼を精度よく推定できるとよい.また、人狼知能大会プロ トコル部門 [人狼] では 15 人で行うゲームもあり、人数や役職 が増加した場合にも対応できる必要がある.さらに、学習に膨 大なデータや時間を必要とする方法ではプレイヤの構成や戦略 が変化した場合に対応が難しく、ゲーム毎あるいはゲーム中に 学習できるような手軽な学習方法が求められる.

そこで本研究では、これらの要求を満たすような役職推定 を実現するべく、強力な類推能力をもつ選択的不感化ニューラ ルネット(以下,SDNN)[新保 10]を用いて他プレイヤの役 職を推定する方法について検討する.なお、本研究では 15人 でプレイする人狼ゲームを対象とする.また、ゲーム終了後に 他のプレイヤの役職が判明するとして、全ての情報を得ている 神のような視点ではなくプレイヤの視点で役職推定を行う.

## 2. 役職推定方法

## 2.1 人狼ゲームデータ

人狼知能プロジェクト [人狼] では,人狼知能プレ大会 GAT2018 に出場したエージェントのソースコードが公開さ れている.これらを利用して人狼ゲームをプレイさせる.な お,強さや勝率には大きなばらつきがあるが,様々な強さの エージェントが含まれるように選択する.

本研究では 15 体のエージェントを準備する. その内訳は,同 一のもの 4 体,残りの 11 体は異なるものとする. ただし,11 体中の1体は著者らが作成したもので、これを役職推定する主体とする.これは GAT2018 に参加したエージェント「neko」を、以下の点で改造してたものである.

- 村人陣営の場合、初日から最も人狼と疑われるエージェントに投票する
- ・ 霊媒師の場合,必ず2日目に霊媒した結果とともに霊媒 師告白する
- 人狼の場合,霊媒師が1人しか告白していない時にその エージェントを襲撃する

学習や性能評価には、人狼知能大会プロトコル部門で用い られているデータ形式に基づいたゲームログを用いる。110回 のゲームログから、100回分を訓練データ、10回分をテスト データとする。基本的に、全プレイヤに公開されている会話の 部分のみから特徴を抽出して入力変数として扱う。

#### **2.2** 入力変数の構成

プレイヤの役職を推定する際に役立ちそうな特徴を抽出し て入力変数とする。具体的には,梶原らが用いた(1)経過日, (2)告白した占い師の人数,(3)占い師から人間判定を受けた 回数,(4)占い師から人狼判定を受けた回数,(5)占い師告白 した順番,(6)占い師が人間判定を出した回数,(7)占い師が 人狼判定を出した回数,(8)vote 発言から投票先を変更した回 数の8変数,そして大川らが追加した(9)生死状態,(10)賛 成意見の数,(11)否定意見の数の3変数を用いる。

予備実験として,先行研究 [大川 17] と同じ 11 変数を入力 に SVM の推定器を用いて実験した結果,推定精度は 60.5%で あった.精度が 10%以上大きく低下したのは,SVM の構成方 法や最適化方法が異なるだけでなく,プレイヤの人数が増えた (役職の種類が増えた)ことやプレイヤの構成が異なっている ためだと考えられる.

そこで, さらに (12) 村人告白した順番, (13) 狩人告白した 順番, (14) 霊媒師告白した順番, (15) 狂人者告白した順番, (16) 人狼告白した順番, (17) 告白した役職, (18) 推定主体の 役職, (19) 発言回数, (20)estimate された役職, (21)estimate 発話の回数を加えた合計 21 変数を用いることにした.ただし, この中に冗長な次元が含まれていたとしても積極的に排除する ことはせずに, 役職推定器がどのように扱うのか調べる.

これらの特徴は 0~1 の値に正規化され入力変数 x として 用いる.正規化方法については改善の余地があるが,比較対象

連絡先: 山根 健, 帝京大学 理工学部 情報電子工学科, 〒 320-8551 栃木県宇都宮市豊郷台 1-1, 028-627-7224, yamane@ics.teikyo-u.ac.jp

とする SVM において精度が高いものを選択した. なお, 実際 に生成した訓練データには入力変数 x は同じであるが出力 y(役職) が異なるようなものが 30.4% 含まれ, 学習時に悪い影 響を与える可能性がある.

#### 2.3 選択的不感化ニューラルネットを用いた役職推定

本研究では, shallow な層状ニューラルネット SDNN を用い て役職推定を行う.計算など詳細については参考文献 [新保 10] を参照されたい.以下では,構成方法の概要を説明する.

入力層では、入力変数 x を成分 -1, 1 で構成される高次元 2 値パターンとして分散表現する。具体的には、ある変数  $x^i$ ( $i = 1, 2, 3, \dots, 21$ )を 100 個の素子で表現する (これを  $x^i$ の 素子群とよぶ)。従って、 $21 \times 100 = 2,100$  個の素子が並ぶ。

中間層では、2 つの素子群が表す情報を選択的不感化法を用いて分散表現のまま統合する。その結果、成分 –1,0,1 で構成される3値のパターンになる。また、素子群の組み合わせの数だけの表現が中間層に並ぶことになる。ただし、自分自身に対してはこの表現を作らないため、21 × 20 × 100 = 42,000個の素子が並ぶ。

ネットワークを動作させて得られる出力層の出力パターン と6種類の役職(村人,狩人,霊媒師,占い師,狂人,人狼) を表すコードパターンそれぞれとの方向余弦を計算して出力 パターンを解釈する.なお,出力層の素子数は100個として, それぞれの役職を表すコードパターンは成分-1,1から構成さ れる互いに無相関なパターンとする.

学習フェーズでは、ある入力変数 x に対して正しい役職を 表すパターンが出力されるように、中間層の素子から出力層の 素子への荷重 w を調整する. この調整には、簡単な学習方法 を用いることができ、以下の実験では誤り訂正学習を用いる. この時の学習回数は 10 回、学習係数 c = 0.01 とする.

## 3. 推定実験

実験は、CPU Intel Core i7-3630QM(4コア8スレッド)、 メモリ 8GB を搭載した Windows マシンを用いて実施した. また、SVM の実装には機械学習用ライブラリ [LIBSVM] を、 SDNN は自作ライブラリを利用した.

まず,SVMを用いた推定結果を表1に示す.先行研究と同様の方法(精度60.5%)と比べると精度の向上が見られるため,本研究で新たに追加した特徴(12)~(21)が有効であることがわかった.次に,SDNNの結果を表2に示す.なお,コードパターンの生成などにランダム要素が入っているため,ランダムシードを変えて10回実験し,精度が最も良い結果(best)と最も悪い結果(worst)を示している.10回の平均精度は68.6%であり,全体としてSVMより少し精度が高かった.一方で,人狼の推定ではSVMより精度が低かった.

最適化方法などを考慮すると単純な学習時間の比較が難しい. SVM については、グリッドサーチによってパラメータ探索を行うとともに、訓練データでクロスバリデーションを行なった.その結果、100 ゲームのデータに対して学習に約7時間ほどかかった.一方で、SDNN については、全く別のパターン認識タスクで用いたパラメータをそのまま利用して(パラメータ探索を行わないで)、2時間半程度であった.

さらに, 訓練データが少ない場合についての性能を調べる ため, 10 ゲームのデータで学習して, 別の 10 ゲームのデー タでテストを行なった. その結果, SVM の精度が 49.8%だっ たのに対して, SDNN の精度は 1 回学習(約 2 分)しただけ で 62.6%であった. この結果から, SDNN の方が少ない訓練 データでも効率よく学習できることがわかった.

| 表   | 1: | SVM  | を用         | りいた  | :推定  | 結 | 果   |
|-----|----|------|------------|------|------|---|-----|
| SVM | () | RBF. | $\gamma =$ | 0.5. | cost | = | 32) |

| (ndf, $\gamma$ | = 0.5, cost |  |
|----------------|-------------|--|
| 精度             | :66.6%      |  |

| 伯及 • 00.070 |       |       |
|-------------|-------|-------|
| 役職          | 適合率   | 再現率   |
| 村人          | 69.5% | 86.7% |
| 狩人          | 9.5%  | 3.0%  |
| 霊媒師         | 82.1% | 48.5% |
| 占い師         | 70.2% | 50.0% |
| 狂人          | 76.1% | 77.3% |
| 人狼          | 85.9% | 41.9% |
| 人狼          | 85.9% | 41.9% |

表 2: SDNN を用いた推定結果

|     | best     |       | worst    |       |
|-----|----------|-------|----------|-------|
|     | 精度:69.4% |       | 精度:67.6% |       |
| 役職  | 適合率      | 再現率   | 適合率      | 再現率   |
| 村人  | 66.5%    | 98.1% | 66.1%    | 96.6% |
| 狩人  | 0.0%     | 0.0%  | 0.0%     | 0.0%  |
| 霊媒師 | 97.8%    | 68.2% | 88.2%    | 68.2% |
| 占い師 | 79.0%    | 45.5% | 73.1%    | 28.8% |
| 狂人  | 74.0%    | 86.4% | 61.0%    | 92.4% |
| 人狼  | 82.2%    | 18.7% | 82.9%    | 17.2% |

## 4. まとめ

SDNNを用いて役職推定を行う方法を提案し、ゲームデータ を使って性能を検証した.その結果、SVMに比べて、SDNN の推定精度が高いことを示した.また、パラメータ探索などを 含めた学習時間についても SDNN は効率的であり、少ない訓 練データでも高い精度を示した.この結果から、SDNN を用 いて使い勝手の良い役職推定器を構築できると考えられる.

今後の課題として、人狼の推定精度を向上させる方法を検討 し、学習済みネットワークの荷重 w を分析するとともに、推 定結果に基づいて行動を決定する方法を検討する.

- [大川 17] 大川貴聖,吉仲亮,篠原歩,"深層学習を用いて役職 推定を行う人狼知能エージェントの開発,"第22回ゲーム プログラミングワークショップ論文集, pp.50–55, (2017).
- [梶原 16] 梶原健吾,鳥海不二夫,稲葉通将,大澤博隆,片山 大輔,篠田孝祐,松原仁,狩野芳伸,"人狼知能大会にお ける統計分析と SVM を用いた人狼推定を行うエージェ ントの設計,"第 30 回人工知能学会全国大会,JSAI2016 2F4-1, pp.1-4 (2016).
- [新保 10] 新保智之, 山根健, 田中文英, 森田昌彦:選択的不感化 ニューラルネットを用いた強化学習の価値関数近似, 信学 論 D, Vo.J93-D, No.6, pp.837-847 (2010).
- [人狼] 人狼知能プロジェクト, http://aiwolf.org/, 最終アク セス:2019 年 1 月 24 日.
- [LIBSVM] LIBSVM, https://www.csie.ntu.edu.tw/~cjlin/ libsvm/, 最終アクセス:2019年1月24日.

# 人狼ゲームにおける会話情報による役職推定 Artificial Intelligence for Deducing Roles of Players in the Werewolf Game using Information about Conversations among Players

福田 宗理<sup>\*1</sup> Fukuda Munemichi 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

Recently, the Artificial Intelligence based Werewolf Project has been attracting attention. Because, it is important for human-like artificial intelligence research to construct an artificial intelligence for the Werewolf Game which requires abilities to bamboozle and detect a lie. Therefore we construct an artificial intelligence for deducing roles of players in the Werewolf Game using information about conversations among players.

## 1. はじめに

近年,人工知能による将棋や囲碁などのゲームの大会が開催されている。その1つに人狼ゲームを行う人狼知能大会[1]がある。人狼ゲームで勝つためには嘘をつく能力や,情報の真偽を見極める能力が要求される。これらの能力が向上することで、人工知能がより高度な判断が可能となり,人間に近づくと考えられる。そのため、人狼知能大会が注目されている。

大川らの研究[2]では 5 人人狼で勝つために、各プレイヤの 役職を推定するニューラルネットワーク(NN)を構築した.しかし そのモデルには人狼の推定精度を向上できる余地があると考え られる.何故なら、NN に入力する特徴として、どのプレイヤを対 象にして発言したかは用いているが、発言の対象となるプレイヤ の特徴を用いていないため、上手く役職の特徴を学習できず、 推定が困難になっていると考えられるためである.

そこで本研究では,経過日数と追放投票で各プレイヤが投票 した対象,COした役職とその時の経過日数とターン数,全ての 会話情報を考慮し役職推定を行う.

# 2. 既存研究

## 2.1 人狼大会のルール

人狼ゲームは村陣営と狼陣営に分かれて、それぞれの陣営 で勝ちを競うゲームである. 村陣営は、人狼を全てゲームから 除外する(以下,追放する)ことが勝利条件であり、狼陣営は、人 間の数を人狼の数以下にすることが勝利条件である.

人狼大会では人狼ゲームを 5 人か 15 人で行い,本研究で は 5 人人狼を取り扱う. 5 人人狼の場合は各プレイヤは役職(村 人,占師,人狼,裏切り者),種族(人間,狼),陣営(村,狼)の属 性を持つ.またプレイヤの役職と種族,陣営は他のプレイヤに 非公開である.

村陣営は全て種族が人間の村人2人,占師1人である.村 人は能力を持たない.占師は1日1人のプレイヤの種族を調 べること(以下,占い)ができる.狼陣営は人狼1匹で種族は狼, 裏切り者1人で種族は人間である.人狼は1日1人のプレイヤ をゲームから除外できる(以下,襲撃).裏切り者は狼陣営が勝

連絡先:福田宗理,東京都市大学,〒158-8557 東京都世田谷区玉堤 1-28-1

#### った時に共に勝利する特殊な役職である.

人狼ゲームには、昼と夜のフェイズが存在する. 昼はプレイヤ 同士で会話し、最後に追放投票をする. 狼陣営は時折嘘の発 言をしてプレイヤを騙し、都合の良い展開に持ち込もうとする. 村陣営は狼陣営の嘘を見抜き、逆に人狼を見つけようとする. 追放投票は全員で投票を行い、最多票のプレイヤが追放され る. 夜は占師が1人を占い、人狼が1人を襲撃する. また人狼 ゲームはゲーム開始前に占師が一度占いを行い、ゲームを開 始する.

プレイヤ同士の会話はターン制である.発言は定型文で1日 に10回まで可能であり,発言をしないことも可能である.全員が 1回ずつ定型文を発言することを1ラウンドとし,これを複数ラウ ンド繰り返す.発言する順番はラウンド毎に無作為に決定する.

| 表 1: 発言の定型文   |               |  |
|---------------|---------------|--|
| 発言            | 意味            |  |
| ESTIMATE P R  | PはRだと思う       |  |
| COMINGOUT P R | PはRであると宣言する   |  |
| DIVINATION P  | Pを占いたい        |  |
| DIVINED P S   | Pの占い結果はSである   |  |
| VOTE P        | Pに投票する予定である   |  |
| AGREE T       | Tに賛成する        |  |
| DISAGREE T    | Tに反対する        |  |
| REQUEST (P)T  | (P)に T をして欲しい |  |
| SKIP          | パス            |  |
| OVER          | 今日はもう喋らない     |  |

発言に用いる定型文の種類を表1に示す.

ここで, P はプレイヤ, R は役職, S は種族, T は発言を表している.

以下の 3 つの内どれかの条件を満たすと会話が終了し,追 放投票に移行する.

● 全てのプレイヤが発言 OVER をする.

● 全てのプレイヤが発言 SKIP をするラウンドが 3 回連続する.

● 20 ラウンドが経過する.

## 2.2 大川らの役職推定モデル

人狼ゲームに強い人工知能を作る為には、プレイヤの会話 や占い結果の情報から誰が人狼かを精度よく推定する事が重 要である.大川らの研究では、以下の表 2 に示すプレイヤの特 徴から各プレイヤの役職を推定する NN を構築している. この NN ではプレイヤの役職が村人, 占師, 人狼, 裏切り者である確 率をそれぞれ出力する.

| I C CAUCAUE | 表 2.プレイヤ X の特徴          |
|-------------|-------------------------|
| 特徴          | 詳細                      |
| 経過日数        | 現在何日目か                  |
| 占師の数        | 占師 COMINGOUT(以下 CO)を    |
|             | したプレイヤの数                |
| 被占い結果       | X が人間判定された数と            |
|             | 人狼判定された数                |
| 何番目の        | (占師 COをしたプレイヤのみ)        |
| 占師          | X が何番目に占師 COをしたか        |
| 占い結果        | (占師 CO をしたプレイヤのみ)X が報告し |
|             | た人間判定の数と人狼判定の数          |
| 投票変更数       | X が発言 VOTE の発言の対象にした    |
|             | プレイヤと, X が行った投票の対象が異な   |
|             | った回数                    |
| 生死          | Xの状態が生存,追放された,          |
|             | 襲撃されたかのいずれか             |
| 肯定的意見       | X が別のプレイヤ Y に対して村陣営であ   |
| の数          | ると推定した,または Y の発言で発言     |
|             | AGREE をした数              |
| 否定的意見       | X が別のプレイヤ Y に対して狼陣営であ   |
| の数          | ると推定した,または Y の発言で発言     |
|             | DISAGREE をした数           |

## 2.3 既存手法の問題点

NN に入力するプレイヤの特徴として占い結果を用いている が、それは占い結果の数のみであり、どのプレイヤをなぜ占った のかは用いていない.さらに肯定的意見の数と否定的意見の数 は、どのプレイヤを対象にして発言したかは用いているが、その 発言の対象のプレイヤの特徴を用いていないことが、推定精度 が良くない主要な要因であると考えられる.

## 3. 提案手法

本研究では、5 人人狼で勝つために、経過日数と追放投票 で各プレイヤが投票した対象、CO した役職とその時の経過日 数とターン数、全ての会話情報を NN に入力した役職推定モデ ルを提案する.

入力の内容は6種類ある.

- 経過日数
- 追放投票で各プレイヤが投票した対象
- 各プレイヤの CO した役職とその時の経過日数, ターン数
- 推定対象者から他のプレイヤへの発言内容
- 他のプレイヤから推定対象者への発言内容
- 他のプレイヤ同士の発言内容

このモデルを自分以外の推定対象者のプレイヤ1人1人に使い、各プレイヤの役職を推定する.

提案手法の入力を以下の表3に示す.

## 4. 実験

提案手法と既存手法の役職推定モデルの精度,再現率を比較し,性能の評価をする. GAT2017人狼知能大会のログデータを用い,データの半分を学習データ,もう半分をテストデータとした.

結果と考察の詳細は発表時に述べる.

表 3:経過日数とCO状況, 会話を入れた情報

| 表 5. 座過自然とし   |  |
|---------------|--|
| 特徴            | 言 新田 二 二 二 二 二 二 二 二 二 二 二 二 二 二 二 二 二 二 |
| 経過日数          | 現在何日目か                                   |
| 追放投票で各プレイヤが   | 追放投票で各プレイヤが投票し                           |
| 投票した対象        | た対象                                      |
| 各プレイヤの CO した役 | 各プレイヤが CO した役職とその                        |
| 職とその日時        | 時の経過日数,ターン数を記録                           |
| 推定対象者から他プレイ   | 推定対象者から他プレイヤへど                           |
| ヤへの推定発言       | の役職で, 発言 ESTIMATE した                     |
|               | カゝ                                       |
| 推定対象者から他プレイ   | 推定対象者から他プレイヤへ,                           |
| ヤへの投票発言       | 発言 VOTE したか                              |
| 推定対象者が他プレイヤ   | 推定対象者から他プレイヤへ,                           |
| を占いたいと発言      | 発言 DIVINATION したか                        |
| 推定対象者が他プレイヤ   | 推定対象者から他プレイヤへ、ど                          |
| を占った結果を発言     | ういう発言 DIVINED したか                        |
| 推定対象者が他プレイヤ   | 推定対象者から他プレイヤへ,                           |
| の発言に同意する      | 発言 AGREE したか                             |
| 推定対象者が他プレイヤ   | 推定対象者から他プレイヤへ,                           |
| の発言に反対する      | 発言 DISAGREE したか                          |
| 他プレイヤから推定対象   | 他プレイヤから推定対象者へど                           |
| 者への推定発言       | の役職で、発言 ESTIMATE した                      |
|               | カ  |
| 他プレイヤから推定対象   | 他プレイヤから推定対象者へ,                           |
| 者への投票発言       | 発言 VOTE したか                              |
| 他プレイヤが推定対象者   | 他プレイヤから推定対象者へ,                           |
| を占いたいと発言      | 発言 DIVINATION したか                        |
| 他プレイヤが推定対象者   | 他プレイヤから推定対象者へ,ど                          |
| を占った結果を発言     | ういう発言 DIVINED したか                        |
| 他プレイヤが推定対象者   | 他プレイヤから推定対象者へ,                           |
| の発言に同意する      | 発言 AGREE したか                             |
| 他プレイヤが推定対象者   | 他プレイヤから推定対象者へ,                           |
| の発言に反対する      | 発言 DISAGREE したか                          |
| 他プレイヤから別の他プ   | 他プレイヤから別の他プレイヤへ                          |
| レイヤへの推定発言     | どの役職で, 発言 ESTIMATE し                     |
|               | たか                                       |
| 他プレイヤから別の他プ   | 他プレイヤから別の他プレイヤ                           |
| レイヤへの投票発言     | へ, 発言 VOTE したか                           |
| 他プレイヤが別の他プレ   | 他プレイヤから別の他プレイヤ                           |
| イヤを占いたいと発言    | へ, 発言 DIVINATION したか                     |
| 他プレイヤが別の他プレ   | 他プレイヤから別の他プレイヤ                           |
| イヤを占った結果を発言   | へ,どういう発言 DIVINED した                      |
|               | か  |
| 他プレイヤが別の他プレ   | 他プレイヤから別の他プレイヤ                           |
| イヤの発言に同意する    | へ, 発言 AGREE したか                          |
| 他プレイヤが別の他プレ   | 他プレイヤから別の他プレイヤ                           |
| イヤの発言に反対する    | へ, 発言 DISAGREE したか                       |

- [1] 人狼知能プロジェクト http://aiwolf.org/
- [2] 大川貴聖,吉仲亮,篠原歩:"深層学習を用いて役職推 定を行う人狼エージェントの開発" The22nd Game Programming Workshop 2017
# 人狼ゲームにおける明示的役職・陣営推定理由の抽出

Extraction of Interpretable Rules for Role and Team Estimation in AI Wolf

小村 友希 Yuki Omura

尾崎 知伸 Wataru Sakamoto Tomonobu Ozaki

日本大学 文理学部

坂本 航

College of Humanities and Sciences, Nihon University

The Werewolf game is a conversation-based multi-player incomplete information game. In the development of high performance AI agents for playing the werewolf games, it is important to explicitly understand the grounds and reasons for their judges and behaviors. In this paper, we report the initial results on the explicit rules extraction for the role and team estimations from agent logs, by employing an algorithm for constructing an interpretable model from tree emsambles.

#### はじめに 1.

不完全情報ゲームの一つである人狼ゲームでは、各プレイ ヤがそれぞれ役職を持ち、村人陣営と人狼陣営に分かれてゲー ムを行う.ゲームは会話を中心に行われ,他プレイヤを騙すた めの嘘をつく,他プレイヤの嘘を見抜く,他プレイヤを説得し 信頼を獲得するなど,非常に高度な行動や駆け引きと,それら を裏付けるための高次推論が重要となる.

人狼知能 [1,2], すなわち人狼をプレイする人工知能エージェ ントに関する研究は、これまで様々な方面から多様な研究が展 開されている.特にプレイヤの役職推定に関しては、勝敗を 左右する基本的な能力の一つであると認識され、精力的に研 究が行われている. 例えば文献 [3] では, 役職推定問題を制約 充足問題の枠組みで定式化している.また文献 [4] では,潜在 的ディリクレ配分法 (LDA) を用いてトピック分析を行い,ト ピックごとの単語分布を用いて役職を推定する手法を提案して いる. 文献 [5] は, 役職推定問題を機械学習問題として定式化 し、分散表現技術の一つである word2vec を用いてプレイヤの 発言をベクトル化することで訓練例を構築している. また文献 [6] では、LDA と Word2Vec を併用することによる役職推定 精度への影響を報告している. 上記の手法も含め, 役職推定研 究の多くにおいて, 積極的に機械学習手法の利用が試みられて いる [7, 8, 9, 10].

近年の深層学習・強化学習の発展にも関係し、役職推定に関 する既存研究の多くは, 推定精度の向上を主たる目的としてい る.しかし、より高度で戦略的に行動するエージェントを実現 するためには、役職推定モデルを一つのモジュールとしてエー ジェント中に組み込み、その他の機能と協調動作させることが 不可欠となる、このためには、高い推定精度はもちろんのこと、 推定の根拠や基準を明示化し, エージェントの構築に対して直 接的にフィードバックを行えることが望ましいと考えられる.

これらのことを背景に、本論文では、役職・陣営推定モデ ルの解釈を目的とした明示的推定理由の抽出を行う.具体的 には、第4回人狼知能大会決勝戦のログデータを対象とし、 決定木およびランダムフォレストによる推定モデルの構築と, inTrees[11] による解釈可能モデルの抽出を行い、これらの結 果を比較,考察する.

# 2. データセット

本研究では、第4回人狼知能大会決勝戦のログデータ\*1(15 人データのみ)を使用した.また,4日目開始時に役職・陣営 を推定することを想定し、4日目開始時点で生き残っているプ レイヤ(エージェント)に対する3日目終了時までのログデー タを利用する.

本研究では、役職・陣営推定問題を分類問題の枠組みで定式 化する. すなわち, 各ゲームにおける各エージェントを一つの 事例とみなし,クラス変数を役職(人狼,村人,占い師,霊媒 師,狩人,狂人)または陣営(人間,人狼),説明変数を(3) 日目終了時点までの)各エージェントの行動とする. 説明変 数は、当該エージェントの発話状況や占い・霊能結果、他エー ジェントへの賛否、他エージェントからの賛否、前日との差な どの観点から、合計約90種を準備した.

モデル構築及び評価に利用する事例数を表1に示す.本来 人狼ゲームでは、割り当て役職者数の違いからクラスバランス が崩れるが、今回の実験では、各クラスに属する事例数が均等 になるようにダウンサンプリングを行っている.

#### 推定モデル構築実験 3.

推定モデルの構築には、R 言語上で実装されているランダム フォレストと決定木を用いた. また inTrees<sup>\*2</sup> を用い, ランダ ムフォレストからのルール抽出を行った. ここで in Trees[11] とは、ツリーモデルアンサンブルの簡略化を通じ、解釈容易な モデルを抽出する手法である.具体的には,決定木中の根から 葉へのパス(経路)をそれぞれ一つのルールと捉え,各ルール の簡略化と貪欲アルゴリズムによるルール選択を通じ、ツリー モデルアンサンブルから決定リストを抽出する.

| 表 1     | : 事例数  |           |
|---------|--------|-----------|
|         | 役職推定   | 陣営推定      |
| 訓練例集合数  | 15,058 | 22,647    |
| テスト例集合数 | 4,589  | $5,\!661$ |

<sup>\*1</sup> http://aiwolf.org/4th-aiwolf-contest

\*2 https://cran.r-project.org/web/packages/inTrees/index.html

連絡先: 尾崎 知伸, 日本大学 文理学部 情報科学科, 〒156-8550 東京都世田谷区桜上水 3-25-40, tozaki@chs.nihon-u.ac.jp

| 役職推定タスク |     | ランダ   | ズムフォレ | スト    |       | 決定木   |       |       | inTrees |       |
|---------|-----|-------|-------|-------|-------|-------|-------|-------|---------|-------|
|         |     | 再現率   | 適合率   | F 値   | 再現率   | 適合率   | F 値   | 再現率   | 適合率     | F 値   |
| 訓練      | 占い師 | 0.993 | 0.996 | 0.995 | 0.677 | 0.165 | 0.265 | 0.969 | 0.173   | 0.293 |
|         | 霊能者 | 0.996 | 0.993 | 0.994 | 0.191 | 0.161 | 0.175 | 0.000 | 0.000   | 0.000 |
|         | 狩人  | 0.992 | 0.996 | 0.994 | 0.045 | 0.231 | 0.076 | 0.087 | 0.302   | 0.135 |
|         | 村人  | 0.999 | 0.995 | 0.997 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000   | 0.000 |
|         | 人狼  | 0.990 | 0.982 | 0.986 | 0.090 | 0.162 | 0.116 | 0.038 | 0.272   | 0.066 |
|         | 狂人  | 0.987 | 0.995 | 0.991 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000   | 0.000 |
| テスト     | 占い師 | 0.201 | 0.226 | 0.213 | 0.735 | 0.187 | 0.298 | 0.971 | 0.175   | 0.297 |
|         | 霊能者 | 0.248 | 0.246 | 0.247 | 0.337 | 0.238 | 0.279 | 0.000 | 0.000   | 0.000 |
|         | 狩人  | 0.407 | 0.260 | 0.317 | 0.089 | 0.358 | 0.142 | 0.090 | 0.308   | 0.140 |
|         | 村人  | 0.203 | 0.243 | 0.221 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000   | 0.000 |
|         | 人狼  | 0.145 | 0.193 | 0.166 | 0.102 | 0.250 | 0.145 | 0.029 | 0.176   | 0.049 |
|         | 狂人  | 0.233 | 0.245 | 0.239 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000   | 0.000 |
| 陣営推定    | タスク | ·     |       |       | ·     |       |       |       |         |       |
| 訓練      | 人間  | 0.811 | 0.709 | 0.757 | 0.905 | 0.608 | 0.727 | 0.921 | 0.599   | 0.726 |
|         | 人狼  | 0.667 | 0.779 | 0.719 | 0.417 | 0.814 | 0.551 | 0.382 | 0.829   | 0.523 |
| テスト     | 人間  | 0.786 | 0.700 | 0.740 | 0.912 | 0.607 | 0.729 | 0.928 | 0.599   | 0.728 |
|         | 人狼  | 0.663 | 0.756 | 0.707 | 0.409 | 0.823 | 0.547 | 0.379 | 0.840   | 0.522 |

| 表 | 2: | 実験結果 | : | 推定精度 |
|---|----|------|---|------|
| 1 | 4. |      | ٠ |      |



図 1:得られた決定木:役職推定(左),陣営推定(右)

### 3.1 推定精度

表2にランダムフォレストおよび決定木,inTreesによる役 職推定,陣営推定の精度を示す.役職推定に関しては,訓練例 集合に対するランダムフォレストの精度が非常に高いことが 分かる.その一方で,テスト例に対しては必ずしも十分な精度 が得られているとは言えない.また決定木は,テストデータに おける占い師・霊能者の予測精度がランダムフォレストに匹敵 する一方で,村人・狂人に対する予測ルールが導出されておら ず,役職によっては大きな偏りが確認できる.inTreesも決定 木と同様であり,いくつかの役職に対するルールが導出されて おらず,占い師以外の役職に対してはほとんど予測ができてい ない結果となった.

陣営の推定に関しては、すべての手法で人間陣営に対する F 値が 70%を超えており、高い精度での予測ができていること が確認できる.また、決定木と in Trees の性能はほぼ同じであ り、決定木は人間陣営に対する適合率と人狼陣営に対する再現 率が、in Trees は人間陣営に対する再現率と人狼陣営に対する 適合率が,それぞれ他方より僅かに優れている結果となった.

#### **3.2** 得られたモデル

図1に得られた決定木を示す.役職推定,陣営推定共に,非 常に簡単な決定木が得られていることが分かる.各決定木中の 中間ノード数は4であり,これは単純に4つの条件だけで役 職・陣営を推定していることに相当する.条件が少ないという 点で内容を把握することは容易ではあるが,精度が低いことも あり,モデルとしての妥当性には大きな疑問が残る.

表3にinTreesにより得られたルール(決定リスト)を示 す.先述した通り,inTreesはランダムフォレストに含まれる ルールを選択することで決定リストを生成する[11].従って, 各ルールは決定木における根から葉へ至るパスに相当し,結果 として複数の条件を含むものとなる.今回の実験では,(デフォ ルトルールを除き)役職推定では5つのルール,陣営推定で は4つのルールがそれぞれ抽出された.また各ルールは複数 の条件で構成されており,決定木による結果よりは複雑で豊富 な情報を含んでいることが確認できた.ただし,決定木の場合

|     | 表 3: inTrees によるルール           |
|-----|-------------------------------|
| 役職判 | 川定ルール                         |
| 狩人  | 2 日目に占い師が人間判定した回数 ≤ 1         |
|     | & 2 日目にプレイヤが賛成し高い数 > 0.5      |
|     | & 3 日目までのプレイヤの総発話数 > 4.5      |
| 霊媒師 | 2 日目のプレイヤの総発話数 > 17.5         |
|     | & 2 日目のプレイヤが否定された回数 > 0.5     |
|     | & 2 日目と 3 日目のプレイヤの発話数の差 > 3.5 |
| 占い師 | 3 日目に賛成し高い数 > 0.5             |
|     | & 3 日目のプレイヤの総発話数 > 3.5        |
| 狩人  | 1 日目のプレイヤの総発話数 ≤ 0.5          |
|     | & 3 日目に賛成された回数 > 0.5          |
| 村人  | 3 日目に疑われた回数 > 2.5             |
| 狩人  | デフォルト                         |
|     |                               |
| 陣営判 | リ定ルール                         |
| 人間  | 2 日目のプレイヤの総発話数 > 2.5          |
|     | & 3 日目に占い師 CO した順序 ≤ 0.5      |
|     | & 3 日目に賛成した回数 > 0.5           |
| 人狼  | 1日目に占い師から人狼判定を受けた回数 ≤ 0.5     |
|     | & 1 日目に占い師 CO した順番 > 0.5      |
| 人狼  | 2 日目に占い師から人狼判定を受けた回数 ≤ 0.5    |
|     | & 3 日目に占い師人狼判定を受けた回数 > 0.5    |
| 人間  | 1 日目に占い師 CO した順番 ≤ 0.5        |
|     | & 2 日目に投票発言から投票先を変更した         |
|     | & 3 日目に霊媒師 CO した順番 ≤ 0.5      |

と同様,推定できない役職が存在し,また精度面からルールの 妥当性には大きな疑問が残る結果となった.

# 4. まとめと今後の課題

デフォルト

本論文では、役職推定と陣営推定の両タスクに着目し、決定 木と inTrees を通じた解釈可能モデルの抽出を行った.予測精 度は必ずしも十分ではなかったが、決定木を用いた直接的なモ デルとの比較を通じ, inTrees を用いることで、より複雑では あるが豊富な情報を持つ解釈可能なルールの抽出が行えること が確認できた.

今後の課題として,抽出したルールを基にした各役職に特有 な知識・視点の整理や利用があげられる.また,異なる解釈可 能モデル構築アルゴリズム(例えば defragTree[12] など)の 適用や,抽出したルールを基にしたエージェントの構築などが あげられる.

### 参考文献

人間

- [1] 鳥海 不二夫,片上 大輔,大澤 博隆, 稲葉 通将, 篠田 孝 祐,狩野 芳伸:『人狼知能』,森北出版, 2016.
- [2] 狩野 芳伸,大槻 恭士,園田 亜斗夢,中田 洋平,箕輪 峻, 鳥海 不二夫(著),人狼知能プロジェクト(監修):『人狼 知能で学ぶ AI プログラミング』,マイナビ出版,2017.
- [3] 林 友超, 呉 双, 板東 勇樹, 宇津呂 武仁: 制約充足による人狼ゲームの役職絞り込み,人工知能学会第 31 回全国 大会,1N1-1in2,2017.

- [4] 荒木 大輔,鳥海 不二夫,菅原俊治:トピックモデル を用いた人狼ゲームの会話に基づく役職別のプレイヤ推定 法,情報処理学会第79回全国大会,pp.481-482,2017.
- [5] 阪本 真基, 上野敦志, 田窪朋仁: プレイヤの発言に基づ いた人狼ゲームの役職推定, 情報処理学会研究報告ゲーム 情報学 (GI), Vol.2016-GI-35, No.12, pp.1–6, 2016.
- [6] 木村 優里絵,尾崎 知伸:単語埋め込み技術を用いた人狼 BBS における役職推定,人工知能学会第 32 回全国大会, 1H2-OS13b-02, 2018.
- [7] 稲葉通将,大畠菜 央実,高橋 健一,鳥海 不二夫: 雑談 ばかりしていると殺される?人狼ゲームにおける発話行為 タグセットの提案とプレイヤの行動・勝敗の分析,情報処 理学会論文誌, Vol.57, No.11, pp.2392–2402, 2016.
- [8] 今野 伸浩,大槻 恭士:機械学習による人狼知能の陣営推 定能力向上,エンタテインメントコンピューティングシン ポジウム 2017 論文集, pp.64–69, 2017.
- [9] 大川 貴聖, 吉仲 亮, 篠原 歩: 深層学習を用いて役職推 定を行う人狼知能エージェントの開発, ゲームプログラミ ングワークショップ 2017 論文集, pp.50–55, 2017.
- [10] 木村 勇太,伊藤 毅志: 人狼 AI における機械学習を 用いた役職推定の改良,人工知能学会第 32 回全国大会, 1H2-OS13a-03, 2018.
- [11] H. Deng: Interpreting Tree Ensembles with inTrees, International Journal of Data Science and Analytics, 2018. https://doi.org/10.1007/s41060-018-0144-8
- [12] S. Hara, K. Hayashi : Making Tree Ensembles Interpretable: A Bayesian Model Selection Approach, *Proc.* of the 21th International Conference on Artificial Intelligence and Statistics, pp.77–85, 2018.

5:10 PM - 5:30 PM (Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room F) [3F06-09-5] Discussion / Conclusion

Discussion / Conclusion

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

[3G3-OS-18a] 感情と AI(1)

日永田 智絵(電気通信大学)、堀井 隆斗(電気通信大学)、長井 隆行(大阪大学) Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room G (302A Medium meeting room)

# [3G3-OS-18a-01] (Invited talk) Predictive coding of interoception and affective emergence OHideki Ohira<sup>1</sup> (1. Nagoya University) 1:50 PM - 2:30 PM [3G3-OS-18a-02] Action Selection based on Somatic Marker Hypothsis OChie Hieida<sup>1</sup>, Takato Horii<sup>1</sup>, Takayuki Nagai<sup>1,2</sup> (1. The University of Electro-Communications, 2. Osaka University) 2:30 PM - 2:50 PM [3G3-OS-18a-03] Active perception based on free-energy minimization on restricted Boltzmann machines OTakato Horii<sup>1</sup>, Takayuki Nagai<sup>1,2</sup> (1. The University of Electro-Communications, 2. Osaka University) 2:50 PM - 3:10 PM [3G3-OS-18a-04] Extraction of Neuroscientific Findings by Visualization of Deep **Neural Network** OKazuki Sakuma<sup>1</sup>, Junya Morita<sup>1</sup>, Taiki Nomura<sup>2</sup>, Takatsugu Hirayama<sup>3</sup>, Yu Enokibori<sup>3</sup> , Kenji Mase<sup>3</sup> (1. Faculty of Informatics, Shizuoka University, 2. Graduate School of Information Science, Nagoya University, 3. Graduate School of Informatics, Nagoya University) 3:10 PM - 3:30 PM

1:50 PM - 2:30 PM (Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room G)

# [3G3-OS-18a-01] (Invited talk) Predictive coding of interoception and affective emergence

OHideki Ohira<sup>1</sup> (1. Nagoya University) Keywords: Emotion, Predictive coding, Interoception

近年の感情科学では、感情は身体内部の知覚である内受容感覚からコア・アフェクトという基礎的状態が形成される過程と、コア・アフェクトを言語により解釈するカテゴリー化の過程から創発されると主張される。またコ ア・アフェクトは、脳の生成モデルによる予測に基づいた身体信号のベイズ的推論により形成されると考えられ ている。本講演では、こうした理論を紹介し、脳・身体・行動に関わる実証的知見からその妥当性を考える。

# ソマティック・マーカー仮説に基づく行動選択

Action Selection based on Somatic Marker Hypothsis

| 日永田智絵 * <sup>1</sup> | 堀井隆斗 *1      | 長井隆行 *1*2      |
|----------------------|--------------|----------------|
| Chie Hieida          | Takato Horii | Takayuki Nagai |

\*<sup>1</sup>電気通信大学 \*<sup>2</sup>大阪大学 The University of Electro-Communications Osaka University

Emotions are very important for human intelligence; however the mechanism of emotions is not yet fully clarified. The important aspect of embodiment in emotion has been claimed by Damasio's somatic marker hypothesis, which proposed that emotions evaluate external stimuli efficiently through the body. As a first step toward understanding the mechanism of emotion, we try to verify the somatic-marker hypothesis using a computer simulation. Specifically, we introduce a module that learns actions using body signals, and verify whether the agent can learn to obtain higher reward using the body signals. As the result, the simulation reveals that the model with body signals can select actions with higher reward compared to models without signals from the body.

### 1. はじめに

感情は人において重要な要素だといわれる.近年の深層学 習の発展に伴い,人工物は人を凌ぐ計算能力を有するようにな るといわれるものの,感情は人工物には有することのできない ものであるという考え方が多い.しかしながら,意識が脳の計 算の結果,生じているものだとするならば,感情も計算機上で 表現できる可能性があるのではないだろうか.

感情に関してはその重要な役割から,過去にも多く感情に 関する研究が行われてきた.その中の重要な仮説として,ソマ ティック・マーカー仮説というものが存在する.ソマティック・ マーカー仮説とは,神経科学者の Damasio が,情動を身体シ グナル,その認知を感情とし,外部の刺激によって引き起こさ れる身体シグナルが意思決定を効率化しているとした仮説であ る [Damasio 96].

本研究では、感情メカニズム解明への足掛かりとして、深層 学習を用い、ソマティック・マーカー仮説を中心とした感情の 統合的なシステムを構築し、ソマティック・マーカー仮説の検 証を行うこととした.具体的な検証方法は、意思決定の効率化 を強化学習における報酬の高い行動選択が行えるようになるこ とと解釈し、深層学習を用い、行動方策を学習するネットワー クを構築し、身体シグナルがあることによって、報酬の高い行 動の選択が行われるかを検証した.

本研究の意義は、感情の統合的なシステムを構築し、その 振る舞いを考察することによって感情メカニズム解明を目指す アプローチ(構成的アプローチ)を行う点にある.例えば生理 学的研究では、ジェームズ・ランゲ説を初めとした感情の理論 が提案されており[James 84],神経科学では、各脳部位の感 情的な働きを調査している[Koelsch 15].これらの研究では、 一部分のモデルや各部位に絞った研究となっており、感情の統 合的なメカニズムについてはまた完全には明らかになっていな い.各部位に焦点を当てる方法は、その部位を知るために重要 であるが、統合的なシステムの中で初めて現れる機能もあると 考えられる.そのため、感情の統合的なシステムを構築し、そ の振る舞いを考察することによって感情メカニズム解明を目指 すアプローチも促進されるべきである.

### 2. 実験プロトコル

仮説検証のため、まずは人の身体との対応を考慮したシン プルなタスクを設計した.本研究では、射的タスクを題材にし た(図1).タスクには水鉄砲,バケツ,風船が存在し,それ ぞれ身体反応(筋肉の動きや発汗,心拍など),体力,外的刺 激(食料)を表し、エネルギーの流れは水の移動で表現される. バケツと水鉄砲に入った水は時間が経つと蒸発してしまう.3 回に1回,風船が飛んでくるという状況で,行動として水鉄 砲を打つか,バケツの蓋を抑えるかを選択することができる. 風船を水鉄砲で打つことが出来れば,風船から水を獲得するこ とができ、バケツの水が増える.バケツの蓋を抑えると蒸発量 を減らすことができる.水鉄砲に水を増やす際にはバケツの水 を減らすこととなる. このような状況下で自身の持つ水の量を 一定に保つように行動を学習する. この設定はホメオスタシス の考え方からである.その際に身体反応と体力の情報即ち身体 シグナルが行動決定を効率化するかということを検証するこ とになる、身体シグナルを出力するモジュールを本研究では、 Somatic Marker Module (SMM) と呼ぶ. タスク内の詳細値 は以下に示す.

- 初期値は水鉄砲が 0, バケツが 80.
- 値の範囲は水鉄砲が 0-10, バケツが 0-100.
- 水鉄砲とバケツの水の総量を 80 に保つことが目標.
- 打つ行動を選択すると,水鉄砲-10.
- 但し水鉄砲が10に満たない場合は打つことができない.
- 風船を打つことができると, バケツ+30.
- 画像が変わるごとに水が蒸発.水鉄砲-2,バケツ-2.
- 但し蓋を抑える行動を選択するとバケツの水の蒸発が半減。

### 深層学習による実装

実装したネットワークを図2に示す.本研究では,強化学習 での行動選択を想定し, Deep Deterministic Policy Gradient (DDPG) [Lillicrap 15] を用いて,行動モジュールを実装し た.また,時系列情報を扱えるようにするため, convolutional LSTM (long short-term memory) [Xingjian 15] を用いて, 次の状況を予測するネットワークを追加した.本タスクにおい てはオーバースペックであるとも考えられるが,さらに複雑な

連絡先:日永田智絵,電気通信大学,東京都調布市調布ヶ丘 1-5-1,042-443-5238,hchie@apple.ee.uec.ac.jp



図 1: タスク設計概要

タスクを行うことを視野にいれ、本手法を選択した.身体シ グナルを出力する Somatic Marker Module に関してはルール ベースで作成した.

### 3.1 Somatic Marker Module (SMM)

SMM の具体的な役割は外的刺激と行動によって変化した 現在の身体シグナルを受け,身体反応を引き起こし,行動モ ジュールに身体シグナルを入力することである.外的刺激を受 け身体反応を引き起こす部分は,風船があるときには,水鉄砲 に10 用意することとした.水鉄砲に水を用意するにはバケツ から足りない分の水を移動させることとなる.その操作をした 後,次のモジュールに水鉄砲とバケツの値を入力する.

### 3.2 Convolutional LSTM

Convolutional LSTM は, Xingjian らによって提案された画 像の特徴を捉える Convolutional Neural Network と長期時系 列情報を扱うことができる LSTM とを組み合わせた方法である [Xingjian 15]. 具体的には, LSTM の重みの乗算が畳み込みで あり,構成要素はメモリセル  $C_t$ ,入力ゲート $i_t$ ,忘却ゲート $f_t$ , 出力ゲート  $o_t$  である.本稿では 2 層の Convolutional LSTM を用いており,フィルタは5×5×5 であり,誤差は平均二乗 誤差によって計算される.学習率は Adam ( $\alpha = 0.001, \beta_1 =$  $0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ )である.入力は外部刺激画像と身 体シグナル ( $65 \times 65 \times 5$ 次元)で,出力は予測画像と予測身 体シグナル ( $65 \times 65 \times 5$ 次元)である.身体シグナルは値を グレースケール画像化して入力している.

### 3.3 Deep deterministic policy gradient

Deep deterministic policy gradient (DDPG) は, Lillicrap らが提案した深層学習を用いた強化学習法であり,高次元の連 続動作空間でポリシーを学習できる深層関数近似を用いたモ デルフリー,オフポリシーの actor-critic アルゴリズムである [Lillicrap 15].入力は外部刺激画像と LSTM による予測画像, 身体シグナルと身体シグナルの初期値(65×65×12次元) で,出力は行動(1次元)である.中間層は300次元の入出力 で構成されている.報酬はホメオスタシスという考えを用い, 下記のように算出する.

$$R(t) = C - |||\boldsymbol{m}(t)|| - ||\boldsymbol{a}'(t)|||, \qquad (1)$$

R(t)は時間 t における報酬値, a(t)は時間 t における SMM の 出力, すなわち身体シグナルを表す.それに対し, a'(t)は a(t)に行動後の変化(例えば風船から水が得られたなど)を加味し たものとなる. m(t)は時間 t での保つべき基準の値となって



図 2: 実装したネットワーク

おり、本研究では初期値の値  $\boldsymbol{a}(0)$  とする. C は報酬値の補正 をする定数であり、R(t) は 0–100 の値をとる. 但し、 $\|\boldsymbol{a}'(t)\|$ が 0 のとき、R(t) も 0 とし、 $\boldsymbol{a}'(t)$  の値を初期値に戻す.

学習率は Adam (actor network:  $\alpha = 10^{-4}$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 10^{-8}$ , critic network:  $\alpha = 10^{-3}$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 10^{-8}$ ) となっており, 探索手法は Ornstein-Uhlenbeck process, ミニバッチは 200, リプレイバッファの サイズは 500 で,新しいデータが入ると古いデータは破棄される.また,本研究では batch normalization を使用した.

# 4. 結果·考察

SMM のある条件を SMM 条件とし, それに対して SMM と LSTM がない条件を DDPG 条件(図 2 の②の破線でネット ワークが切れている条件), SMM がない条件を DDPG-LSTM 条件(図 2 の①の破線でネットワークが切れている条件)と 呼ぶ. 欠損した情報は 0 で入力している. 学習時の報酬の様 子を図 3 に示す. 学習はそれぞれ 20000epochs 行った. グラ フは見やすくするために 50epochs ごとの平均値をプロットし ている. 報酬のグラフより, 全ての条件で報酬は高くなってい るが, 身体シグナルありの場合がより高い報酬が得られている ことがわかる. 総時間の報酬の平均値をとると, SMM 条件が 88.9, DDPG 条件が 83.1, DDPG-LSTM 条件が 83.2 となっ ており, 身体シグナルありが最も大きい. しかし, この結果に は学習時の行動のノイズも含まれているため, 学習済みモデル



図 3: 学習時の報酬の推移



図 4: 学習済みモデルでの報酬平均の比較

に対し、それぞれ 20episode 動かした結果を平均したものを 比較した.

結果を図4に示す.平均値はSMM条件が94.1,DDPG条件が84,LSTM条件が84.7となった.ボンフェローニ法で解析を行った結果,SMM条件とDDPG条件,DDPG-LSTM条件の間で有意差が見られた( $p = 2.94 \times 10^{-8}, 2.16 \times 10^{-7},$ ボンフェローニ法よりp < 0.01/3).DDPG条件とDDPG-LSTM条件の間は有意傾向であった(p = 0.027,ボンフェローニ法よりp < 0.1/3).よって,身体シグナルありの場合が報酬を高くする行動を選択できることがわかる.また,DDPGとDDPG-LSTMの間は有意傾向であるので,予測モジュールが報酬増加に寄与したと考えられる.

LSTM の Loss のグラフは図 5 の通りである. グラフは見や すくするために 100epochs ごとの平均値をプロットしている. 初期状態に比べ誤差が減少しており,学習が行われていること がわかる. 最終的な誤差は 3.24 と 1.32 となり, DDPG-LSTM 条件の方が小さくなる. これは,身体シグナルの予測を行って いないためであると考えられる.

次に LSTM による予測の一例を図 6 に示す. 画像の予測で は,綺麗に画像の再現ができているわけではないものの,風船 が空の色になっていたり,空が風船の色になっているなど,多 少の予測ができていることがわかる.水量の予測では,非常に 近い値ではないものの,入力された情報に対し値が増加するか 減少するかというレベルでの予測はできている.

また、身体反応のパターンを変更し、学習した結果の行動 を比較した.a群は風船がきたときのみ水鉄砲に10用意する 群で、b群は画像に関わらず常に水鉄砲に10用意するパター ンである.その結果 SMM 条件と DDPG-LSTM 条件では行 動に違いが出たが,DDPG 条件では行動に違いが出なかった. これは,DDPG 条件では風船がどのタイミングで来るか予測 できず,来た際に行動するということしかできないため,a群 とb群に違いが出なかったと考えられる.予測モジュールが あると,風船が来ないパターンの状況を細分化できるため,行 動にバリエーションが生まれる.しかしながら,詳細な身体状 況はわからないため,周期的な行動に落ち着くこととなる.身 体シグナルがあると,その時の身体状況に合わせて行動を選択 することが可能となる.

また, SMM 条件の b 群の報酬平均は 93.7 で, DDPG 条 件の報酬平均は 86, DDPG-LSTM 条件の報酬平均は 93.1 で あった. SMM 条件と DDPG-LSTM 条件の報酬があまり変わ らないのは、b群のシナリオが身体反応を一定にしたために、 身体シグナルなしでも十分に行動できたためだと思われる.し かしながら,打つ行動を選択し行動できている回数を比較する と, SMM 条件は 6 回で DDPG-LSTM 条件は 11 回となる. つまり、身体シグナルがあることにより、使用する水の量をよ り少なくより高い報酬を得ることができている. SMM 条件内 で比較すると、a群は打つことができているのが2回、b群が 6回となる. つまり, a 群の方が使用する水の量を少なくでき ており、身体反応のパターンが行動に対して制約をかけ、行動 を効率化させていることがわかる.即ち,行動選択において, 身体反応は重要であり、この部分をどのように設定するのかが 問題となる.人においては、生得的な身体反応があると考え られており, その要素がエクマンの基本感情 [Ekman 71] の考 えに繋がっていると考えられる.ただし,生得的な部分のみで は説明がつかない要素もあり、後天的に身体反応を学習するモ ジュールも必要であろう.

### 5. まとめ

本研究では、感情メカニズム解明への足掛かりとして、ソマ ティック・マーカー仮説の検証を行った。手法として、強化学習 での行動選択を想定し、Deep Deterministic Policy Gradient (DDPG) を用いて行動を強化学習するモジュールを作成し、 convolutional LSTM (long short-term memory)で作成した 予測モジュール及び身体シグナルを出力する Somatic Marker Module (SMM)の有無によって、行動選択がどのように変容 するかを検証した。学習済みモデルで行動した際の報酬の平均 を比較した結果、身体シグナルありの SMM 条件が最も報酬が 高い行動を選択できていることがわかった。また、身体反応の パターンの変化による検証では、身体反応のパターンが行動に 対して制約をかけ、行動を効率化させていることがわかった。



図 5: 学習時の LSTM の Loss の推移

表 1: 画像に対する反応を変更した際の行動例:画像0は風船なし,画像1は風船あり,行動0は蓋を抑える,行動1は打つ.

|    | 画像           |     | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 |   | 0 |
|----|--------------|-----|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 行動 | SMM 条件       | a 群 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 |
|    |              | b 群 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 | 0 | 0 |
|    | DDPG 条件      | a 群 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 |
|    |              | b 群 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 | 1 | 0 | 0 |
|    | DDPG-LSTM 条件 | a 群 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 0 | 1 | 1 | 0 | 1 | 1 | 0 | 1 | 1 | 0 | 1 |
|    |              | b 群 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 1 | 1 | 0 | 1 | 1 | 0 | 1 | 1 | 0 |



図 6: LSTM による予測の一例

これらは、身体シグナルが意思決定を効率化しているというソ マティック・マーカー仮説の主張に沿った結果となっている. 今後は SMM-LSTM-DDPG の全体のネットワークに対し、 より複雑なタスクを行い、挙動を確かめるとともに、社会的感

情など、複雑な感情がどのように表現されるのかを検証する.

# 謝辞

本研究は JSPS 科研費 JP16J04930, 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)の助成を受けたものです.

- [Damasio 96] Damasio, A. R., Everitt, B. J., and Bishop, D.: The Somatic Marker Hypothesis and the Possible Functions of the Prefrontal Cortex [and Discussion], *Philosophical Transactions of the Royal Society B*, *Biological Sciences*, Vol. 351, No. 1346, pp. 1413–1420 (1996)
- [Ekman 71] Ekman, P. and Wallace, F. V.: Constants across cultures in the face and emotion, *Journal of per*sonality and social psychology, Vol. 17, No. 2, pp. 124–129 (1971)
- [James 84] James, W.: WHAT IS AN EMOTION ?, Mind, Vol. os-IX, No. 34, pp. 188–205 (1884)
- [Koelsch 15] Koelsch, S., Jacobs, A. M., Menninghaus, W., Liebal, K., Klann-Delius, G., Scheve, von C., and Gebauer, G.: The quartet theory of human emotions: An integrative and neurofunctional model, *Physics of Life Reviews*, Vol. 13, pp. 1–27 (2015)
- [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, arXiv preprint arXiv:1509.02971 (2015)
- [Xingjian 15] Xingjian, S., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., and Woo, W.-c.: Convolutional LSTM network: A machine learning approach for precipitation nowcasting, in Advances in neural information processing systems, pp. 802–810 (2015)

# 制限ボルツマンマシンによる 自由エネルギー最小化に基づく能動的知覚

Active perception based on free-energy minimization on restricted Boltzmann machines

堀井隆斗<sup>\*1</sup> 長井隆行<sup>\*1\*2</sup> Takato Horii Takayuki Nagai

\*<sup>1</sup>電気通信大学 The University of Electro-Communications \*2大阪大学

The University of Electro-Communications Osaka University

A robot, which would like to respond quickly in the world, should select more informative signals to estimate the cause of its sensation (e.g., a state of the environment, a category of a handling object, an emotional state of interaction partner, etc.). This paper proposes an active perception framework that selects the robot's action to perceive critical sensory signals based on a free-energy minimization in an energy-based model. We employed a restricted Boltzmann machine as a fundamental component for an estimation network of the cause of sensations. Our framework demonstrated better performance for the attention control in emotional human-robot interaction than other methods.

# 1. はじめに

多様な情報にあふれる実世界で活動するロボットにとって、 環境や自身の状態を認識するために複数の感覚情報を処理する ことが重要である.Nakamura と Nagai [Nakamura 17] は、 質感や色,聴覚,触覚,単語の感覚様式に基づいて、ロボット が多感覚情報を処理することで知覚物体の関係性を構造化す る手法を提案している.また Horii ら [Horii 18] は、視覚、聴 覚、触覚の感覚様式に注目し、それらの感覚情報を統合するこ とで感情発達を再現する計算論モデルを提案している.このよ うに複数の感覚情報を統合・処理することで物体のカテゴリや 感情といった概念構造を獲得することができる.そしてこのよ うな概念構造から環境や自身の状態を推定することで,他者と の相互作用が可能となる.

概念構造を獲得したロボットは、一部の感覚情報からでも概 念情報を予測することができる.しかし、本来複数の感覚情報 を処理することで獲得された概念情報を、一部の感覚情報から 予測するとは難しい.例えば不透明なペットボトルが見えた時 にそれがゴミであるか否か、電話先の友人が大きな声を発した 時に喜んでいるのか怒っているのかを判断するためには、追加 の感覚情報が必要であることは想像にたやすい.このような 場面で概念情報(ここでは物体のカテゴリや他者の感情状態) の推定に効果的な感覚情報を選択・知覚することを能動的知覚 と呼ぶ.Taniguchi 5 [Taniguchi 18] は、ロボットのための 能動的知覚として、現在推定している概念情報と予測される未 観測感覚情報との関係性を表す相互情報量を推定し、その相互 情報量が最大となる感覚情報を選択する手法を提案している.

一方で,近年の神経科学研究において,人の能動的知覚(推 論)を説明する基本原理としての自由エネルギー原理[Friston 10]が注目されている.これは人の脳が入力される感覚信号 を予測する内部モデルを構成し,その予測と実際の信号間の 誤差を最小化するように認識や行動を実行するというもので ある.本研究ではこの自由エネルギー原理に基づいた能動的 知覚のための計算論モデルと手法を提案する.具体的には深 層学習モデルの1つである Restricted Boltzmann Machine (RBM)[Hinton 10]を用いた多感覚情報統合モデルにおいて,

連絡先: 堀井隆斗, 電気通信大学, 東京都調布ヶ丘 1-5-1, takato@uec.ac.jp



図 1: RBM による多感覚統合モデル

観測情報から概念情報を介して未観測情報を予測し,その中 で自由エネルギーが最も小さい(つまり最も予測誤差が小さ い)感覚情報を選択する.本稿では提案する能動知覚手法と Taniguchi ら [Taniguchi 18]の手法を,人とロボットの感情 コミュニケーション場面を想定した場面において評価した結果 について示す.

### 2. 提案手法

RBM [Hinton 10] による多感覚統合モデルと提案する自 由エネルギー最小化に基づく能動的知覚手法について説明す る.図1に RBM を用いた多感覚統合モデルを示す.ここで  $v_i^{m_n} \in \{0,1\}$ は n 番目の感覚様式  $m_n$  の i 番目の可視層ノー ドを,  $h_j \in \{0,1\}$ は j 番目の隠れ層ノードを示す.また  $w_{.j}$ は  $h_j$  と可視層ノードの結合加重である.このモデルは、学習 時に  $m_N$  までのすべての感覚様式情報を入力として受け取り、 入力情報と隠れ層 h を介して再構成された情報の誤差を最小 化することで、確率分布  $p(v = \{v^{m_1}, \dots, v^{m_N}\})$ を推定する. また学習によって隠れ層に何らかの特徴表現(例えば物体カテ ゴリや感情カテゴリなど)が獲得されることが期待される.

学習によって推定される周辺確率 p(v) は次式で表現される.

$$p(\boldsymbol{v}) = \sum_{\boldsymbol{h}} p(\boldsymbol{v}, \boldsymbol{h})$$
  
=  $\exp\left(\boldsymbol{c}^T \boldsymbol{v} + \sum_{j=1}^J \log(1 + \exp(b_j + \boldsymbol{W}_{\cdot j} \boldsymbol{v}))\right)$  (1)  
=  $\exp(-F(\boldsymbol{v}))/\mathcal{Z}$ 

| Algorithm    | 1 | Active | perception | based | on | free-energy | min |
|--------------|---|--------|------------|-------|----|-------------|-----|
| imization on | F | RBM    |            |       |    |             |     |

| add perceived modality $m_n$ to set $M_r$  |
|--|
| for $n = 0$ to N do  |
| $\mathbf{if} \ m_n \in \mathcal{M}_{\mathbf{r}} \ \mathbf{then}$   |
| $\boldsymbol{v}^{m_n} = v^{m_n}$   |
| else   |
| $v^{m_n}=0$  |
| end if   |
| $oldsymbol{h} \sim p(oldsymbol{h}   oldsymbol{v}^{m_1}, \cdots, oldsymbol{v}^{m_n}, \cdots, oldsymbol{v}^{m_N})$ |
| for $n = 1$ to $N$ do  |
| if $m_n \notin M_r$ then   |
| $oldsymbol{v}^{{m_n}'}\sim p(oldsymbol{v}^{{m_n}'} oldsymbol{h})$  |
| $E_n \leftarrow F(\boldsymbol{v}^{m_n'})$  |
| end if   |
| end for  |
| end for  |
| $n = \operatorname{argmin} E_n$  |
| $M_r \leftarrow M_r \cup m_n$  |
|  |

F(v)は RBM の自由エネルギーである.以上より、ある情報 vの自由エネルギーが小さいことは、vの発生確率 p(v)が高 いことと対応する.

次にある部分観測情報  $v' = \{0, \dots, v^{m_n}, \dots, 0\}$  から未観 測情報を予測することを考える. それぞれの未観測情報  $v^{m_u}$ は部分観測情報 v' から推定された h を介して再構成できるこ とから,次のように予測される.

$$\boldsymbol{h} \sim p(\boldsymbol{h} | \boldsymbol{v})$$

$$\boldsymbol{v}^{m_u} \sim p(\boldsymbol{v}^{m_u} | \boldsymbol{h})$$
(2)

ここで,提案手法は予測された未観測情報と部分観測情報から 計算される自由エネルギーが最も小さくなるものを次の知覚情 報として選択する.すなわち RBM における自由エネルギー 最小化に基づく能動的知覚は,現在の観測情報から推定される 概念情報に対して尤もらしく予測される感覚様式の情報を選択 することとなる. Algorithm1 に提案手法の詳細を示す.

# 3. 実験

提案手法の有用性を評価するために、人とロボットの感情コ ミュニケーション場面を想定した感情推定のための能動的知覚 実験を行った.実験では人の対面多感覚感情コミュニケーショ ンデータである IEMOCAP データセット [Busso 08] から表 情,音声,手の動きに関する特徴量を抽出し、それぞれを感覚 様式の情報として図 1 の多感覚統合モデルを学習した.学習 の詳細な条件に関しては [Horii 16] を参照されたい.また今 回の実験では評価値として、部分観測情報とすべての観測情報 から推定された隠れ層の発火確率の KL ダイバージェンスを 利用した.

図2に単一の感覚様式情報を部分観測情報として入力した 状態(baseline)とそれぞれ異なる能動的知覚手法で選択した 1つの感覚様式情報を付加した状態の評価値を示す.能動的知 覚を実行することで状態推定の精度が向上していることが分か る.また無作為抽出(Ramdom)とTaniguchiら[Taniguchi 18]の手法(IG.max)と比較して,提案手法(FE.min)が高 い性能を示すことが確認された.



図 2: 各能動的知覚手法による感情状態推定に対する評価値

# 4. おわりに

人の脳情報処理の基本原理だと考えられている自由エネル ギー原理に基づいた能動的知覚手法を提案した.そして,人 とロボットの感情コミュニケーションを想定した能動的知覚 の実験において情報量を最大化する Taniguchi ら [Taniguchi 18] の手法と情動推定精度を比較し,提案手法が高い性能を発 揮することを示した.

今後は提案手法と既存手法の関係性を明らかにするととも に, RBM 以外のエネルギーモデルへの適用を進める.また, ロボットの能動的知覚による状態変化の影響を踏まえた時間方 向へ拡張する.

### 謝辞

本研究は JST CREST(JPMJCR15E3, JPMJCR16E2)の 支援を受けた.また研究内容に関して議論した情報通信研究機 構長井志江主任研究員に感謝する.

- [Busso 08] Busso, C., Bulut, M., Lee, C.-C., Kazemzadeh, A., Mower, E., Kim, S., Chang, J. N., Lee, S., and Narayanan, S. S.: IEMOCAP: Interactive emotional dyadic motion capture database, *Language resources and evaluation*, Vol. 42, No. 4, pp. 335–359 (2008)
- [Friston 10] Friston, K.: The free-energy principle: a unified brain theory?, *Nature reviews neuroscience*, Vol. 11, No. 2, p. 127 (2010)
- [Hinton 10] Hinton, G. E.: A practical guide to training restricted boltzmann machines, Technical report, Department of Computer Science University of Toronto (2010)
- [Horii 16] Horii, T., Nagai, Y., and Asada, M.: Imitation of human expressions based on emotion estimation by mental simulation, *Paladyn, Journal of Behavioral Robotics*, Vol. 7, No. 1 (2016)
- [Horii 18] Horii, T., Nagai, Y., and Asada, M.: Modeling development of multimodal emotion perception guided by tactile dominance and perceptual improvement, *IEEE Transactions* on Cognitive and Developmental Systems (2018)
- [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)
- [Taniguchi 18] Taniguchi, T., Yoshino, R., and Takano, T.: Multimodal Hierarchical Dirichlet Process-Based Active Perception by a Robot, *Frontiers in neurorobotics*, Vol. 12, (2018)

# 深層学習の可視化による神経科学的知見の抽出

Extraction of Neuroscientific Findings by Visualization of Deep Neural Network

| 佐久間一輝*1       |  |
|---------------|--|
| Kazuki Sakuma |  |

森田純哉<sup>\*1</sup> 野村太輝<sup>\*2</sup> Junya Morita Taiki Nomura 平山高嗣 \*<sup>3</sup> Takatsugu Hirayama 榎堀優 \*<sup>3</sup> Yu Enokibori

間瀬健二\*3

Kenji Mase

\*1静岡大学情報学部

\*2名古屋大学大学院情報科学研究科

Faculty of Informatics, Shizuoka University

sity Graduate School of Information Science, Nagoya University

\*2名古屋大学大学院情報学研究科

Graduate School of Informatics, Nagoya University

Recently, research using deep learning has been conducted in various fields. Additionally, research on visualization methods learned by deep learning has also been actively conducted. Furthermore, the relationship between the human subjective state and electroencephalogram (EEG) has been clarified in the psychophysiological field. In this research, we apply the visualization method developed in the image field to the analysis of EEG. Using this method, we examine whether we can abstract physiologically reasonable structure of brain activity from the network visualizing EEG signals. The result of our experiment indicated the two important brain structures showing consistency with the previous neuroscience studies. We consider that our proposed method has some utilities as a tool to progress scientific understanding of human mind.

# 1. 研究背景

以前から,感情に関わる研究は生理心理学分野で脳波(EEG: Electroencephalogram)などの生体信号を用いて行われてきた. EEG は脳内部活動の情報を保持する有益なものであると考えられてきたが,EEG は複数の異なる主観的状態の情報が 集積されたものであり、ノイズも多く実利用が困難であるとされてきた.これに対し,生理心理学ではEEG を周波数帯域成分に分離し,電極位置の情報と併用して用いることで,分析対象の主観的状態との相関が検討されてきた[Sarlo 05].このようなEEG を用いた感情分析においては,熟練した高度な技能によって、ノイズ除去や結果の解釈がなされてきた.

一方で,深層ニューラルネットワーク (DNN: Deep Neural Network) は,高精度のモデルを作成することができる機械学習 の手法として盛んに研究が行われている.DNN は入力特徴にほ とんど加工することなく,特徴抽出器をボトムアップに学習可能 であるという利点がある.しかし,高精度のモデルを作成できた としてもそのモデルが内部でどのように特徴抽出を行っている のかわからない.そこでモデルがどのように特徴抽出しているの かを理解するため,DNN の特徴抽出の様子や内部状態を可視化 する研究が行われてきた [Ramprasath 16, Schirrmeister 17].しかしそのような研究は特定の入力特徴に対する特徴抽出を可 視化するものであり,特徴抽出がモデル作成者の意図するもの であるかを確認するためのものである.DNN には高度な特徴 抽出機能があるにも関わらず,そこから対象に対する新たな知 見を得ることは考慮されていない.

本研究の目的は, DNN を用いて学習したモデルから得られ る知見と,生理心理学分野での解析から得られた感情と EEG の関係の知見を比較することで,DNN から妥当性の高い知見 を得ることができるかを検討することである.この目的を達成 することで,神経科学において,扱うデータの精度の範囲内で 信頼性の高い知見を得るツールを導くことができると考える.

### 2. 関連研究

ここでは本研究のターゲットとなる領域(EEG と感情)と, 手法(DNN)に関する先行研究について述べる.

### 2.1 EEG と主観的状態との関係

EEG は生理心理学の分野で脳活動と人間の主観的状態と の関係性を調査するために利用されてきた.その中で,被験 者の主観的状態と脳の部位や $\delta$ 波, $\theta$ 波, $\alpha$ 波, $\beta$ 波, $\gamma$ 波 などの周波数帯域別の活動に関連があることが報告されてき た.例えば,左前頭部の $\theta$ 波と $\alpha$ 波が快感情と,右前頭部 の $\theta$ 波と $\alpha$ 波が不快感情と関連していることがわかっている [Davidson 03, Sarlo 05].

神経科学の分野でも、感情と脳活動の関連を科学的に解明 する試みが行われている.その中で、前頭葉の背外側前頭前 野(DLPFC)は高次認知活動に関与しており、また、感情を 抑制する機能を持つと考えられている.Beauregardらは、被 験者に悲しくなるようなビデオや性的な写真を見せ、意識的に 悲しみや性的な感情を抑制させるようにすると DLPFC の活 動が上昇することを報告した [Beauregard 01].

### 2.2 DNN を用いた研究

また,近年機械学習の発展に伴い,EEG の認識にDNN を 用いる研究が行われている.Schirrmeister らは未加工のEEG から右手,左手,足,安静の4つの運動に関係した主観的状 態の識別にCNN (Convolutional Neural Network)を適用し, CNN は未加工のEEG から周波数帯域成分を学習可能である ことを示した [Schirrmeister 17].

上記の研究は、EEG 解析に DNN を用いるアプローチの有用 性を示唆しているが、学習したモデルがどのようにして脳活動 のパターンを識別するのかを説明することが困難である.この 問題に対して、学習した DNN の可視化を行う研究が行われて いる [Ramprasaath 16]. Ramprasaath らは CNN の可視化に Gradient-weighted Class Activation Mapping (Grad-CAM) を適用した [Ramprasaath 16].彼らはさらに詳細な可視化を行 うために、Grad-CAM と Guided Backpropagation(Guided BP) を組み合わせた Guided Grad-CAM(GGC) を示した.し

連絡先: 佐久間一輝,静岡大学情報学部情報科学科, 静岡県浜松市中区城北3丁目5-1,053-478-1452, sakuma.kazuki.15@shizuoka.ac.jp



表 1: Parameters of CNN

| Type           | Structure  |
|----------------|--|
| Input          | $Depth \times Height(N_f * N_c) \times Width(Times)$                                       |
| Frequency Conv | Kernel:16 × $N_f$ × 1, Stride: $N_f$ × 1, pad=0, elu                                       |
| Spacial Conv   | Kernel:16 $\times$ N <sub>c</sub> $\times$ 1, Stride:N <sub>c</sub> $\times$ 1, pad=0, elu |
| Batch Norm 1   | Dimensions:16  |
| Dropout 1      | Wight Decay:0.5  |
| Time Conv 1    | Kernel:16 $\times$ 1 $\times$ 12, Stride:1 $\times$ 3, pad=0, elu                          |
| Time Conv 2    | Kernel:16 $\times$ 1 $\times$ 12, Stride:1 $\times$ 3, pad=0, elu                          |
| Time Conv 3    | Kernel: $32 \times 1 \times 12$ , Stride: $1 \times 3$ , pad=0, elu                        |
| Time Pool      | Kernel:1 $\times$ 3,Stride:1 $\times$ 3, pad=0, Max  |
| Batch Norm 2   | Dimensions:32  |
| Dropout 2      | Wight Decay:0.5  |
| FC 1           | 96, elu, Dropout:0.5   |
| EC 2           | Classes Softmar  |

かしながら, EEG による感情認識にこれらの技術を適用する 研究は行われていない.

# 3. 提案手法

本提案手法では、CNN と GGC を用いて脳活動の抽象化を 行い、神経科学や生理心理学の知見の抽出を行う.

#### 3.1 学習フェイズ

#### 3.1.1 入力特徵

前処理では、EEGのデータセットに対して高周波成分を除 去するために [1-50Hz] の FIR フィルタを適用する.次に,外 れ値除去として [-500 $\mu$ V,500 $\mu$ V] の範囲を超える電位を含む データを除外する.最後に,ウェーブレット変換により, $\theta$ 波 (4-7Hz), $\alpha$ 波 (8-13Hz), $\beta$ 波 (14-30Hz) 及び $\gamma$ 波 (31-50Hz) として各周波数帯域成分を算出する.

全電極位置とその全周波数帯域成分を2次元の画像に変換 し、その各行は、各電極位置の周波数帯域成分の一連の信号入 力を表す(図1の上部を参照).

### 3.1.2 モデル

学習に用いた CNN のモデルの概要を図1の下部に示す.中間層では,周波数帯域軸,電極軸,時間軸の順で独立した畳み込みを行うような Kernel を設計し,出力層は快,中立,不快を示す3クラス分類となっている.その他のモデルの構造に関わるパラメータを表1に示す.

### 3.2 中間層の可視化と集約フェーズ

EEG と GGC を用いた中間層の可視化と集約の概要を図 2 に示す.本フェーズは三段階に分かれている.



### 3.2.1 入力

学習済みモデルに,正しく分類を行うことのできた EEG の 信号(2次元の画像)を入力する.

### 3.2.2 可視化

出力層における,可視化したいクラスの値を1としパラメー タを更新せずに Backpropergation を行う. Guided BP は,以 上の操作を行った後の入力層の勾配の値である. Grad-CAM は CNN 内の全結合層の直前の畳み込み層が出力した特徴マッ プを用いて出力する.各特徴マップの勾配の平均値と,各特徴 マップの weight を掛け合わせたものに ReLU 関数を適用する. 作成した Guided BP と Grad-CAM の積が GGC となる.

### 3.2.3 集約

クラス毎に,作成した GGC を平均した画像を作成する.こ れにより,被験者間の差や試行間の差を跨いだクラスの特徴が 抽象化される.抽象化された平均画像を比較することで,神経 科学や生理心理学における知見の抽出を試みる.

### 4. 評価実験

本実験は,提案手法を用いて感情に関連する特徴的な脳活 動を抽出できるかどうかを検討することを目的としている.

### 4.1 データセット

EEG と感情に関するデータセットの作成にあたり,32人の 被験者に日常生活を記録した写真を提示した後に,感情(快不 快と覚醒度)と記憶の主観的評定を行わせた.写真が被験者に 提示されている間,簡易脳波計である EMOTIV EPOC を用 いて14 チャンネル(図1の左上部参照)サンプリング周波数 128 Hz で EEG の記録を行った.

写真は,画面中央に注視点が表示されてから4秒間表示さ れ,その後被験者はSAM (Self Assessment Maskin) に従っ て主観的状態の評価を行った [Bradley 94]. この手順の結果, 写真を閲覧する試行に対応する4,536 個の EEG データが得ら れた [野村 17].

#### 4.2 実験条件

DNN の学習に用いるデータセットは、写真提示の各試行の始 めから3 秒間の EEG データを抽出し、前節で示した前処理を適 用した.その結果、表1に示されるパラメータは Width=384 (128Hz × 3sec), Height=56 (4 周波数帯域 × 14 チャンネ ル)となる.これらに対して平滑化、ノイズ付与、及び Time Cropping を Data Augumentation として採用し、元の学習 データを 45 倍に水増しした [Schirrmeister 17].これらのデー タのうち、訓練用データとして 4/5 (学習データとして 3/4、 検証データとして 1/4),およびテストデータとして 1/5 を用いて 5 分割交差検証を行った.

### 5. 結果

### 5.1 識別性能

学習したモデルの識別精度は5つの fold の平均で 46.31%で あった.全3クラス分類問題のチャンスレートである 33.33%を 上回っていることから, EEG の時間周波数成分から快-不快に 関わる主観的状態を学習可能であることが分かった.

### **5.2 GGC**を用いた可視化

5つの fold において最高の精度であった GGC によって得 られたヒートマップを図3に示す.これらの画像は,快,平常, 不快のそれぞれのラベルが付与された EEG について,GGC によって特徴を抽象化したものである.図3より,快の場合 にはおよそ下半分(右半球に相当するチャンネルが配置),不 快の場合にはおよそ上半分(左半球に相当するチャンネルが配 置)が高い値になっている.

図3のヒートマップについて,時間軸の値を平均 すること で,頭皮上での注目強度を示す topomap[Gramfort 14] を作 成した(図4).図に示されるように,本研究において学習さ れた DNN は快と不快とラベルづけされた脳波に対し,左右 で異なる部位に注目していることがわかる.



### **5.3 Raw** データの可視化画像

上記の結果は、DNN が快と不快を区別する脳波の特徴と して、「左右半球の差分」を学習したことを示す.この結果が、 DNN による学習の結果であることを確認するため、RAW デー タを図3と同様の形式で 平均化した画像(図5)、およびその topomap(図6)を作成した.これらより、単純な平均画像に おいては、快と不快を区別する明確な特徴が示されないことが 確認される.

5.4 神経科学的に合理的な構造の抽出(局所度の比較) 神経科学の分野では,前頭葉の一部である DLPFC に不快 感情を抑制する機能があることが知られている.それに対し て快感情の生起に関わる局所的な脳部位は明らかでない.本 実験においても画像を提示され不快感を抱いているときには, DLPFC などの局所的な部位が活性化している可能性がある.



そこで,各 fold における快不快の GGC 同士で局所度の比較を行った.この分析では,GGC の局所度を,GGC 画像の各セルを活性度によってソートした配列に対して得られる回帰 直線の傾きとして定義する.配列の index に対して対数を取る ことで片対数グラフとし,それに対して回帰分析を行った.実際に得られるグラフの例を図7に示す.図7において青線は 不快時,緑線は快時の GGC の活性値と回帰直線に対応する.

図 8 は各 fold における全被験者から求められた快不快それ ぞれの局所度の平均である. fold02 と fold05 の間には快不快 間で局所度の差に有意差がみられた (fold01: t (32) = -2.03, p = 0.06, fold02: t (32) = -3.97, p < 0.01, fold03: t (32) = -1.55, p = 0.13, fold04: t (32) = -2.83, p = 0.01, fold05: t (32) = -4.57, p < 0.01).





⊠ 8: The average of the localities of each fold

☑ 7: Rank regression obtained from a participant

### **5.5** 信頼性の検証

前項までの結果は,提案手法により神経科学的な知見の抽 出が可能であることを示唆する.しかし,今回の実験における モデルの識別精度は高いものではなく,得られた知見が本当に 神経学的な構造を反映しているのか疑問が残る.ただし,脳波 と感情という対象の特質から完全な分類は困難である.そのた め,本研究では結果の一貫性を評価することで信頼性を検証 する.

各 fold における快不快の GGC の類似性を比較検討した.こ

の検証を行うため、2つの GGC によって生成された2つのベクトルを比較するコサイン類似度と、2つのハッシュ行列間の 距離を計算する *perceptual hash*の2種類の類似度を使用した [Zauner 10].

図 9 と 10 は、2 つの類似度の結果を示している. 各行列 の行と列は,各 fold (*fold01 … fold05*) に対して取得された 快と不快の GGC に対応し,行列のセルは類似性の値となって いる.行列全体に対して,同じ感情としてラベル付けされた GGC の間に高い類似性がみられ,前項で得られた GGC の特 徴に fold 間に高い一貫性があることが示されている.



 9:
 Cosine similarity

 between
 Guided

 Grad-CAM
 in

 fold
 Grad-CAM

☑ 10: Difference in hash value of Guided Grad-CAM in each fold

# 6. 考察

快不快の主観的状態を識別する DNN を作成し,学習した モデルがどのような特徴抽出を行っているのか検討を行った. GGC の平均を用いることで,学習したモデルが EEG の左右 差を用いて,快不快のクラス分類を行っていることがわかった. これは生理心理学分野で得られている知見とも一致する.この ことから,提案手法を用いることで学習済み DNN から感情に 関わる特徴的な脳活動を抽出し,妥当性の高い知見を得ること ができたと考えられる.

しかし,生理心理学分野の知見では快感情のときに左前頭 部,不快感情のときに右前頭部が活性化するとされているにも 関わらず,GGCの平均においては逆の部分に注目している. これは DNN が EEG のどの部分が活性化していないのかに注 目してクラス分類を行っているからであると考えられる (図 4c と図 6c 参照).本実験で用いた DNN の識別精度は 46.31%で あり高くない.これは,脳波と感情という扱いや分析が難しい 対象を扱っていることと,DNN が注目する箇所が最も妥当と は言えないものであったことが原因であると考えられる.

GGC における注目箇所の局所性についての検証も行い, 全 ての fold で不快時の局所性が快時より大きく, 特に fold02 と fold05 では有意差が見られた. このことから DNN は不快の 識別においてより明確な構造を持っていると考えられる. この 結果は,不快感情は局所的な部位が活性化し,快感情が前頭葉 の広範な部位が活性化する構造を反映していると考えられる. しかし今回の検証において局所性は GGC 全体に対して求め たものであった. そのため,空間と時間で分離した局所性を求 めることが今後の課題として挙げられる.

また,得られた知見には異なるデータ間で学習したモデル 間で一貫性があった.しかし学習したモデルの識別精度は決し て高い値ではなかった.一見矛盾しているようだが,精度と一 貫性は異なる指標であると考える.識別精度はあらゆる状況に 当てはまる普遍性,一貫性は得られた傾向の信頼性を表す.神 経科学における研究では,あらゆる状況に対する普遍性を求め るのではなく,揺らぎのある特定の状況における傾向の信頼性 を求める.そのため、本研究は神経科学において、扱うデータの精度の範囲内で信頼性の高い知見を得るツールのひとつになり得ると考える.

# 7. 結論

本研究の目的は、DNN を用いて神経科学的知見を得る方法 を提案することであった.そのために、EEG によって快不快 感情を認識する DNN を設計し、学習したモデルから感情に関 連する特徴的な脳活動の抽出を試みた.結果、快不快感情間の 脳活動の左右差と、不快感情における脳活動の局所性という、 これまでの神経科学の研究と一貫性を示す二つの重要な脳構造 を示した.これらの結果から、提案手法は人間の心の科学的理 解を深めるためのツールとして有用性があると考えられる.

- [Beauregard 01] Beauregard, M., Lévesque, J., and Bourgouin, P.: Neural correlates of conscious self-regulation of emotion., *The Journal of neuroscience* (2001)
- [Bradley 94] Bradley, M. M. and Lang, P. J.: Measuring emotion: the self-assessment manikin and the semantic differential, *Journal of behavior therapy and experimental psychiatry*, Vol. 25, No. 1, pp. 49–59 (1994)
- [Davidson 03] Davidson, R. J.: Affective neuroscience and psychophysiology: Toward a synthesis, *Psychophysiology*, Vol. 40, No. 5, pp. 655–665 (2003)
- [Gramfort 14] Gramfort, A., Luessi, M., Larson, E., D., E., Strohmeier, C., Brodbeck, D., and Parkkonen, M., L.and Hamalainen: MNE software for processing MEG and EEG data, *Neuroimage*, Vol. 86, No. 1, pp. 440–460 (2014)
- [Ramprasaath 16] Ramprasaath, R., Abhishek, D., Ramakrishna, V., Michael, C., Devi, P., and Dhruv, B.: Grad-cam: Why did you say that? visual explanations from deep networks via gradient-based localization, *CVPR 2016* (2016)
- [Sarlo 05] Sarlo, M., Buodo, G., Poli, S., and Palomba, D.: Changes in EEG alpha power to different disgust elicitors: the specificity of mutilations, *Neuroscience letters*, Vol. 382, No. 3, pp. 291–296 (2005)
- [Schirrmeister 17] Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W., and Ball, T.: Deep learning with convolutional neural networks for EEG decoding and visualization, *Human brain mapping*, Vol. 38, No. 11, pp. 5391–5420 (2017)
- [Zauner 10] Zauner, C.: Implementation and benchmarking of perceptual image hash functions (2010)
- [野村 17] 野村太輝ら FCNN を用いた感情認識における生理 心理的制約の効果, JSAI (2017)

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

# [3G4-OS-18b] 感情と AI(2)

日永田 智絵(電気通信大学)、堀井 隆斗(電気通信大学)、長井 隆行(大阪大学) Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room G (302A Medium meeting room)

# [3G4-OS-18b-01] Automatic Detection of Insincere Utterances with LSTM

OKazuya Mio<sup>1</sup>, Aya Ishino<sup>2</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa<sup>1</sup> (1. Graduate School of Information Sciences, Hiroshima City University, 2. Faculty of Media Business, Hiroshima University of Economics)
 3:50 PM - 4:10 PM

# [3G4-OS-18b-02] A Study on Concept Acquisition Method for User Preference in Dialogue for Empathy

OTakahisa Uchida<sup>1,2</sup>, Takashi Minato<sup>2</sup>, Yutaka Nakamura<sup>1</sup>, Yuichiro Yoshikawa<sup>1</sup>, Hiroshi Ishiguro<sup>1,2</sup> (1. Osaka University, 2. Advanced Telecommunications Research Institute International)

4:10 PM - 4:30 PM

# [3G4-OS-18b-03] A personalized model to estimate emotion of individual based on observed facial expression and generation of robot behavior OKazumi Kumagai<sup>1</sup>, Ikuo Mizuuchi<sup>1</sup> (1. Tokyo University of Agriculture and Technology) 4:30 PM - 4:50 PM

[3G4-OS-18b-04] Human inference system derived from emotion as a value calculation system hypothesis

OMasahiro Miyata<sup>1</sup>, Takashi Mory<sup>2</sup> (1. Graduate School of Engineering, Tamagawa University, 2. College of Engineering, Tamagawa University) 4:50 PM - 5:10 PM

# [3G4-OS-18b-05] Agents which generate and estimate emotions based on logical model

OMai Tsukamoto<sup>1</sup> (1. Nara Women's University) 5:10 PM - 5:30 PM

# LSTM を用いた本心でない発話の自動検出

## Automatic Detection of Insincere Utterances with LSTM

| 見尾 和哉*1    | 石野 亜耶*2    | 目良 和也*1     | 竹澤 寿幸*1            |
|------------|------------|-------------|--------------------|
| Kazuya MIO | Aya ISHINO | Kazuya MERA | Toshiyuki TAKEZAWA |

\*1 広島市立大学大学院情報科学研究科

\*2 広島経済大学メディアビジネス学部

Graduate School of Information Sciences, Hiroshima City University

Faculty of Media Business, Hiroshima University of Economics

We propose a method of automatic detection of insincere utterances from voice and facial expression. Proposed method utilizes Long short-term memory (LSTM) to consider time series variation of the voice and the facial expression instead of support vector machine (SVM). The experimental results indicated that proposed method could improve recall (0.73) and Fmeasure (0.65) from SVM baseline.

# 1. はじめに

近年,人間とコミュニケーションを行う対話システムが盛んに サービス化している. 対話システムがユーザとより円滑なコミュニ ケーションを行うためには、ユーザの感情を理解する必要があ る.しかし、表出された感情が常に本心であるとは限らないため、 発話が本心か否かというような抑圧された感情まで推定する技 術が必要である.

そこで、本研究では、抑圧された感情まで推定するシステム の構築を目的に、本心でない発話を自動検出する手法を提案 する. 提案手法では, 機械学習には LSTM (Long short-term memory)を使用し,特徴量として発話中の音声や表情の情報を 利用する.

## 2. 先行研究

本研究の先行研究として, Uemura ら[Uemura 2017]の研究が ある. Uemura らは, 発話中の音声や表情から得られる特徴量を 使用して、本心でない発話を自動検出する手法を提案している. 音声特徴量としては,音声の時系列データから, openSMILE[Eyben 2010]により算出された音量の最大値や最 小値などの 384 個の特徴を利用している.表情特徴量としては, 発話が終わった瞬間の静止顔画像から,オムロンの OKAO Vision[オムロン]を用いて算出された5感情(無,喜,驚,怒,悲) の推定感情の尤度を利用している. このように, Uemura らの手 法では, 音声, 表情ともに事前に定義された特徴量を使用して, SVM によって本心でない発話を検出している. 本研究では, よ り細かい音声や表情の時系列での変化を把握するため,機械 学習にLSTMを用いた手法を提案する.

## 3. LSTMを用いた本心でない発話の検出手法

本研究では, 音声と表情の時系列での変化を考慮し, 本心 でない発話の検出を行うため、LSTM を用いた手法を提案する. LSTM とは, RNN(Recurrent Neural Network)を改良した時系 列データを扱うことができるモデルである.

LSTM を用いた本心でない発話の自動検出手法のイメージ 図を図1に示す.図1の縦長の長方形は、LSTMの入出力とな る特徴ベクトルを模式的に表したものである.



図1 本心でない発話の自動検出手法のイメージ図

LSTM に与える特徴量について説明する.まず,音声特徴量 について説明する.発話中にマイクにより録音したデータから, openSMILEを使って、25msecの窓に対して「音圧」、「基本周波 数(F0)」,「自己相関関数から算出される声らしさ」の値を算出 する. この窓を 10msec ごとにシフトさせ時系列の音声特徴量を 得る.

次に,表情特徴量について説明する.発話中にビデオカメラ により撮影された動画から, OKAO Vision により顔部位の特徴 点(左目頭, 左目尻, 右目頭, 右目尻, 鼻左, 鼻右, 口上, 口元 左, 口元右)を検出し、その座標を時系列に並べたデータを表 情特徴量として使用する. 表情特徴量として, OKAO Vision に より推定された感情を利用せず, 顔部位の特徴点の座標を利 用するのは, Ekman [Ekman 2009]の squelched expression (抑圧 された表情)のように、顔の部位ごとの感情表出やその程度を 考慮するためである.

提案手法では、音声特徴量 $v_{voice,1}$ と表情特徴量 $v_{face,1}$ を、 それぞれ時系列に並べて LSTM 関数に入力し, 100 次元のベ クトルに変換し, 次元ごとに MAX 関数を適用しvvoice,2, vface,2 を得る. vvoice,2とvface,2を連結後,線形関数を適用し,2次元の ベクトルv<sub>voice+face</sub>へ変換する. 最後に, v<sub>voice+face</sub>の中で最 も値の大きい次元に対応するラベルを予測ラベルとする.

また, LSTM を双方向に拡張した BiLSTM (Bidirectional LSTM)を用いた手法でも同様の実験を行う.

連絡先:目良和也,広島市立大学大学院情報科学研究科, mera@hiroshima-cu.ac.jp

### 4. 実験

### 4.1 実験に使用したデータ

実験には、Uemura らの研究で使用したデータを利用した. Uemura らのデータ収集手順を説明する.まず、大学生 10人に、 図 2 に示すような、本心を誘発するであろう画像と、本心を誘発 しないであろう画像各 20 枚を、1 枚ずつ見せた.





本心を誘発する画像

本心を誘発しない画像

図2 データ収集に用いた画像

画像を見て、例え本意でなくても必ず褒めてもらい、その際 に音声をマイクで録音、表情をビデオカメラで撮影しておき、後 に特徴量として機械学習に使用した。そして発話した直後に、 本心であるか否かを回答させた。これを、褒め台詞を指定する 「台詞固定」と、自由な言葉で褒めてもらう「台詞自由」の2パタ ーンでデータを収集し、実験に使用した.実験に使用したデー タを表1に示す。

表1 実験に使用したデータ

| パターン | 本心でない発話<br>(正例) | 本心である発話<br>(負例) | 合計  |
|------|-----------------|-----------------|-----|
| 台詞固定 | 201             | 166             | 367 |
| 台詞自由 | 167             | 202             | 369 |

### 4.2 比較手法

提案手法の有効性を確認するため,以下に示す手法で実験 を行った.

- SVM 手法(比較手法): Uemura らと同様に SVM を利用 した手法
- LSTM 手法(提案手法): LSTM を利用した手法
- BiLSTM 手法(提案手法): BiLSTM を利用した手法

LSTM 手法と BiLSTM 手法のモデルパラメータの最適化手 法には Adamを使用した. 隠れ層の数は2, バッチサイズは50, エポック数は 100 とした. 評価尺度には, 精度, 再現率, F 値を 使用し, 5 分割交差検定を行った.

### 4.3 実験結果

実験結果を表2に示す.まず,台詞固定のパターンについて 考察する.比較手法である SVM 手法より,提案手法である LSTM 手法は、精度は 0.02 ポイント、再現率は 0.12 ポイント、F 値は 0.07 ポイント改善することができた.また、提案手法である BiLSTM 手法では、LSMT 手法よりもさらに再現率を 0.03 ポイ ント改善することができた.精度の向上はわずかであったが、再 現率は大幅に向上させることができた.これは、比較手法である SVM 手法では、音声、表情ともに事前に定義された特徴量を 使用していたが、提案手法では、LSTM を利用することで、より 細かい音声や表情の時系列での変化を把握することができた ためであると考えらえる.BiLSTM では、双方向の変化を把握 することができるため、より再現率が向上したと考えられる.よっ て、台詞固定のパターンでは、提案手法の有効性が確認できた.

次に、台詞自由のパターンについて考察する.比較手法である SVM 手法より,提案手法である LSTM 手法や BiLSTM 手法 では、精度、再現率、F 値ともに低下してしまった.台詞自由の パターンでは、様々な台詞が混在しているため、音声や表情の 時系列での変化を細かく把握する手法は、有効でないと考えら れる.台詞自由のパターンに対応させるためには、まずは似た 特徴を持つ発話をクラスタリングし、そのクラスタごとに提案手法 を適用する必要がある.

### 5. まとめ

本研究では、機械学習として LSTM を使用することで、本心 でない発話を自動検出する手法を提案した.実験の結果、台詞 固定のパターンにおいては、SVM を用いた比較手法と比較し、 提案手法では再現率を0.12ポイント向上させることができた.台 詞自由のパターンにおける精度の改善が今後の課題である.

### 謝辞

本研究は国立研究開発法人科学技術振興機構(JST)の研究成果展開事業「センター・オブ・イノベーション(COI)プログラム」の助成を受けたものです.

- [Uemura 2017] Joji Uemura, Kazuya Mera, Yoshiaki Kurosawa, and Toshiyuki Takezawa: Suppressed Negative-Emotion-Detecting Method by using Transitions in Facial Expressions and Acoustic Features, Proc. Emotions, Decisions and Opinions 2017, pp. 122-127, 2017.
- [Eyben 2010] Florian Eyben, Martin Wöllmer, and Björn Schuller: openSMILE – The Munich Versatile and Fast Open-Source Audio Feature Extractor, Proc. ACM Multimedia Conference – MM, pp.1459-1462, 2010.
- [オムロン] OMRON Japan, OKAO Vision | オムロン人画像セン シングサイト, https://plus-sensing.omron.co.jp/technology, (2019年2月8日アクセス).
- [Ekman 2009] Paul Ekman: Telling Lies: Clues to Deceit in the Marketplace, Politics, and Marriage, W.W. Norton, 2009.

| 手法              | 台詞固定 |      |      | 台詞自由 |      |      |
|-----------------|------|------|------|------|------|------|
|                 | 精度   | 再現率  | F值   | 精度   | 再現率  | F值   |
| SVM 手法(比較手法)    | 0.57 | 0.58 | 0.57 | 0.54 | 0.53 | 0.53 |
| LSTM 手法(提案手法)   | 0.59 | 0.70 | 0.64 | 0.52 | 0.38 | 0.44 |
| BiLSTM 手法(提案手法) | 0.59 | 0.73 | 0.65 | 0.43 | 0.43 | 0.43 |

表 2 実験結果

# 共感を目的とした対話における ユーザの選好に対する概念獲得手法に関する検討

A Study on Concept Acquisition Method for User Preference in Dialogue for Empathy

| 内田貴久 *1*2       | 港隆史*1          | 中村泰*2           | 吉川雄一郎 *2           | 石黒浩 *1*2         |
|-----------------|----------------|-----------------|--------------------|------------------|
| Takahisa Uchida | Takashi Minato | Yutaka Nakamura | Yuichiro Yoshikawa | Hiroshi Ishiguro |

\*1株式会社 国際電気通信基礎技術研究所 Advanced Telecommunications Research Institute International \*<sup>2</sup>大阪大学大学院基礎工学研究科 Graduate School of Engineering Science, Osaka University

The purpose of this research is to promote users' motivation to talk with robots. In order to improve the users' motivation in dialogue, it is necessary not only to generate empathic utterances of the robots but to show that the robots understand about target items. In this paper, we explore the method to acquire the concept of the users' preferences (likes and dislikes). In the proposed method, data on preference and similarity for items are prepared for each attribute of preference. In addition, we also organize the rules for estimating preferences and similarity with fewer observed data. As future work, it is necessary to verify whether or not the dialog robots with the proposed method can improve the users' satisfaction for the robots' empathic utterances and the users' dialogue motivation.

# 1. はじめに

本研究の目的は、ロボットがユーザと共感を目的とした対 話を行うことによって、ユーザの対話意欲を喚起することであ る.ここで共感とは、同じ感情や意見を持っていることを示す 行為であると定義する.対話システムがユーザに共感する頻度 を増やすことで、親近感やユーザ満足度が向上すると報告され ている [東中 09] ことから、共感はユーザの対話意欲を向上さ せる要因の1つであると言える.ユーザの対話意欲を向上さき るロボットは、例えば、高齢者の対話相手などのコミュニケー ション支援への応用が期待される [横山 10].また、共感とい う対話における感情の一致に関して構成論的にアプローチする ことによって、知的活動である対話と感情の関係を考察できる と考えられる.

ユーザに共感することを目的とした対話システムの1つとし て、傾聴システムが挙げられる([下岡 17] など).傾聴とは話 し手の話に共感を示しつつ,話し手がより多く話せるように手 助けをして話を聴くことである[楡木 89].対話システムが傾 聴を行うことにより,高齢者の話し相手となること[山本 09] や、ユーザの話したい,話を聞いてもらいたいといった欲求を 満たすこと[目黒 12]が期待されている.一方,ロボットがあ る対象(話題に上がっていること・もの)に関して理解能力 を持ちうると感じなければ,その対象に関して対話する意欲が 減退することが報告されている[内田 19].従って,対話にお いてユーザの満足度を向上させるためには,話題の対象に関 する意見や感想に対して共感的な発話を生成するだけでなく, ロボットがその対象に関して理解していることを示す必要があ ると考えられる.

そのための1つの方法として、対象に関する概念を有して いることを示すことを考える.概念とは、アイテム同士がある 観点において近い関係にあるかどうかを表すものであり、ここ では情報のクラスタリングによって形成されたカテゴリの集合 と定義する.例えば、ユーザはAが好きであることを認識し た場合、ロボットがある観点からAに近いBも好きなのでは ないかと提示する. さらに, A や B は X という観点から似て いないか, X なものが好きなのかといった発話を生成するこ とも考えられる. このように,対話ロボットが推定したユーザ の選好に関する概念をもとに発話を生成することによって,対 象に関する理解能力(抽象化能力や類推能力)を示せば,そ の後の共感的発話に対する満足感を高めることができると考え られる. そこで本稿では,あるアイテムに関するユーザの選好 (好き嫌い)に着目し,ユーザの選好に関する概念を,対話を 通して獲得する手法について検討を行う.

### 2. 関連研究

対話においてユーザの選好を推定する研究として,ユーザ の選好を考慮して対話を行うシステム [小林 16] がある.この システムは構文や表層格,深層格の解析結果を用いて,ユーザ の発話の極性を推定するなどして,ユーザの選好を推定してい る.提案されている手法により,現在対象となるアイテムに関 する選好を推定することができる.一方,その他のアイテムに 関する選好を推定することはできていないため,ユーザの選好 に対する概念を獲得していることにはならない.

対話においてユーザの選好をモデル化する研究として,個人の概念空間を利用した興味の推定による情報提供システム [Sumi 00] がある.ユーザとは別の複数人の概念空間を事前に 取得し,それらをもとにユーザの概念空間を推定している.し かし,選好には様々な観点が存在することが考慮されていな い.例えば、レストランAはコストパフォーマンスが良いか ら好きであり、レストランBは味が良いから好きというよう に、同じ選好でも観点が異なる場合がある.そのようなアイテ ムを同じ類似性を持つとしてしまうことによって,ユーザの選 好モデルを正しく推定できない場合がある.そこで本稿では、 選好の観点ごとに類似性データを持ち、複数の観点に基づいて 選好に関する対話を行うシステムに関する検討を行う.

### 3. 提案手法

本稿の目的は、複数の観点を考慮して、対話においてロボットがユーザの選好(好き嫌い)に関する概念を取得することで ある.そこで、選好に関するデータと選好の観点ごとに類似性

連絡先: 内田貴久, 大阪大学大学院基礎工学研究科, 大阪府 豊中市待兼山町1番3号, 06-6850-6360, uchida.takahisa@irl.sys.es.osaka-u.ac.jp

に関するデータを用意し、ユーザの選好に対する概念を獲得す る.また、ユーザの選好に関する概念を獲得する上で、対話と して自然さを保つことが課題となる.ユーザの選好について一 問一答のように次々と質問しているだけでは、対話意欲が減退 することが考えられる.そこで、少ないデータで選好や類似性 に関して推定する手法が必要になる.以下、選好と類似性の表 現と推定ルール、そして対話システムへの統合を想定した発話 生成ルールに関して説明する.

### 3.1 選好と類似性のデータ表現

選好に関するデータは表によって扱う. ここで,選好の観点 は表において各アイテムの属性として表現する.選好表は図 1 のようにアイテム数を *M*,属性数 *N* とすると *M*×*N* の行列 である.選好に関するデータは,好きであることを 1,嫌いで あることを-1,好きでも嫌いでもないことを 0 としてデータ が格納されている.データがない場合は空白になっている.図 1の例では,レストラン A をメニューの観点からは好んでい るが,店の雰囲気の観点からは嫌いであることを表している. *M*と *N* の値は対話を通して増加していく.



図 1: 選好表

類似性に関するデータも表によって扱う.類似表は図2の ようにアイテム数をMとするとM×Mの行列である.類似 性に関するデータは、関連があることを1、関連がないことを 0としてデータが格納されている.データがない場合は空白に なっている.類似表に関しては属性ごとに類似表を用意するた め、N個の表を用意する.



図 2: 類似表

本研究で対象とする対話では、ユーザとの発話から得られる データ(観測値)とユーザとのこれまでの対話から推定される データ(推定値)がある.観測値に関するデータ操作を更新、 推定値に関するデータ操作を補完と称する.これら選好表と類 似表が選好に関する概念となる.

### 3.2 表の補完ルール

ここで,観測値から推定値を補完するルールに関して説明す る.表は選好表と類似表の2種類あるため,選好表から選好表 の補完,選好表から類似表の補完,類似表から選好表の補完, 類似表から類似表の補完の4通りが考えられる.以下,それぞ れの補完ルールに関して説明する.ここで,今回はシステム (自分)とユーザ(相手)それぞれの選好・類似表があること を仮定する.また,推定値はユーザへのデータ確認発話によっ て肯定されれば以後,観測値として扱うことにする.そして, 各ルール内で補完データ間の整合性が取れない場合(例えば, あるアイテムとの類似性データによる選好表の補完では好きで あると補完される一方,別のアイテムとの類似性データによる 選好表の補完では嫌いであると補完される)は補完を行わない ことにする.以下の図における <> 付きの数値は補完された 推定値を表す.

#### 3.2.1 選好表から選好表の補完

ある属性について自他の選好の観測値がいくつかのアイテムについて一致していた場合,その属性に関する選好は他のアイテムについても自他で一致するだろうという推測である.具体的には図3のように,ある属性の選好データに関して観測値の類似度が閾値以上の場合,対象属性の一方の選好データと同じ値を他方の推定値として補完する.選好表のある属性における類似度Sは、アイテム数をM、比較する二つの表で一致する選好データの数をsとすると、S = s/Mで表される.



図 3: 選好表から選好表の補完

#### 3.2.2 選好表から類似表の補完

ある属性について2つのアイテム間で選好が一致している 場合に、それらのアイテムがその属性について類似していると 推定する.具体的には、図4のように、ある属性に関して、選 好に関する観測値がアイテム間で一致している場合はそのア イテム間の類似度を1,一致していない場合は0を推定値と して類似表を補完する.ここで、選好が一致するものは、同じ 類似性をもつことを仮定している.この補完が自身の表で生じ る場合というのは、対話を通して自身があるアイテムをある観 点で好き(嫌い)になった時に、アイテム間が類似しているこ とに気づくという現象である.



図 4: 選好表から類似表の補完

#### 3.2.3 類似表から選好表の補完

3.2.2 節と逆の場合で,ある属性について2つのアイテムが 類似している場合に,それらのアイテムのその属性についての 選好が一致していると推定する.具体的には,図5のように, ある属性の類似表にある2つのアイテム間の観測値が存在し ていれば,その属性に関して一方のアイテムの選好の観測値 と同じ値を推定値として他方のアイテムの選好を補完する.こ こで,ある属性に関して類似するものは,同じ選好をもつこ とを仮定している.この補完が自身の表で生じる場合というの は,現時点でアイテムAを好き(嫌い)であり,さらに対話 を通してアイテムAとアイテムBが似ていると知ったときに, アイテムBも好き(嫌い)になるだろうと思う現象である.



図 5: 類似表から選好表の補完

#### 3.2.4 類似表から類似表の補完

自身(相手)が似ていると思っているものは,相手(自身) も似ていると思うだろうという推定である.具体的には,図6 のように,自他の同じ属性の類似表に関して,一方の類似表の 観測値を他方の類似表にそのまま推定値として補完する.これ は片方が知らないアイテムに関して行われる補完ルールであ る.相手の表から自身の表を補完する場合というのは,ある属 性についてアイテム A と B が似ているかどうか知らないとき に,相手が似ていると発言したら,自分もそのように思い込む 現象である.



図 6: 類似表から類似表の補完

### 3.3 発話生成ルール

対話を通して選好の概念を獲得するために、システムが行 う発話には、2種類の発話を想定する.1つは表のセルを埋め る発話で、もう1つは表のセルを増やす発話である。表のセ ルを埋める発話には、表1のように、選好と類似性ごとに表 のセルを埋めるための発話と補完したセルを確認するための発 話がある.

また、表のセルを増やす発話には、アイテムを追加する発話 (例:「好きな飲食店はどこですか?」)と、属性を追加する発

表 1: 表のセルを埋める発話の分類

|     | データ取得発話      | データ確認発話        |
|-----|--------------|----------------|
| 選好  | 例)「A のメニューは  | 例) 「それじゃあ, A の |
|     | 好きですか?」      | メニューは好きですよ     |
|     |              | ね?」            |
| 類似性 | 例)「A の雰囲気は B | 例)「それじゃあ, A と  |
|     | に似てますか?」     | B の雰囲気は似てます    |
|     |              | よね?」           |

話(例:「なぜ A が好きなんですか?」)がある.

システムはユーザと対話を行いながら,効率的に選好表を 埋めることが望まれる.各種の発話を行うタイミングは,補完 が行われるごとに情報確認発話を行い,これ以上補完できない 場合は情報取得発話を行う.

### 3.4 対話例

ここで、上述の4つの補完ルールを用いて対話を行うこと を考える.これらの補完ルールを用いることによって、シス テムが既知のアイテムに関する選好概念を獲得できるだけでな く、対話を通して新規に知ったアイテムに関する選好概念の獲 得も可能になる.対話例を以下に記す.

| System: メニューが好きなレストランはどこですか?      |  |  |  |
|-----------------------------------|--|--|--|
| User: レストラン A です. 【レストラン A は新規のアイ |  |  |  |
| テムとする】                            |  |  |  |
| System: レストラン A のメニューはレストラン B に似  |  |  |  |
| てる?                               |  |  |  |
| User: いいえ, 似ていません.                |  |  |  |
| System: それじゃあ,レストランBのメニューは嫌いな     |  |  |  |
| のでは?【類似表から選好表の補完:既存のアイテムに関        |  |  |  |
| する選好に対する概念を獲得】                    |  |  |  |
| User: 好きでも嫌いでもないですね.              |  |  |  |
| System: そうなんですね. レストランBとメニューが似    |  |  |  |
| てないんだったら【類似表から類似表の補完】,それなら        |  |  |  |
| 私も好きかもしれないです!【類似表から選好表の補完:        |  |  |  |
| 新しいアイテムに関する選好に対する概念の獲得】           |  |  |  |
| User: そうなんですね.                    |  |  |  |
| System: レストラン Aってレストラン C とメニュー似て  |  |  |  |
| るんじゃない?【選好表から類似表の補完】              |  |  |  |
|                                   |  |  |  |

### 4. 考察

本稿では、共感を目的とした対話において、ユーザの選好 概念を獲得するための手法に関して検討を行った.提案手法を 用いることにより、観点ごとにユーザが何を好むのかについて 理解を示すことが可能となる.また、システムが既知のアイテ ムに関する選好概念が獲得できるだけでなく、対話を通して新 たに知ったアイテムに関する選好概念の獲得が可能になると 考えられる.新たな概念を獲得するシステムは、ユーザがす ぐにインタラクションに飽きてしまうという、現在のコミュニ ケーショ ンロボットが抱える問題を解決する手法として期待 されている [内田 08].今後は、ロボット提案手法によって選 好概念を推定しながら共感対話を行った場合に、その共感に対 する満足度を高めることができるかどうか、ユーザの対話意 欲を喚起するかどうかを検証することが課題となる.

今回の検討では,選好や類似性に関するデータはシステム

とユーザのものに限って考察した.一方,第三者のデータを導 入することによって、より精度の高いユーザの選好概念を獲得 できると考えられる. その場合, 例えば, 協調フィルタリング [Shardanand 95] の手法を適用することができる.協調フィル タリングは、多数のユーザの情報をもとに対象ユーザがどの ユーザに近いのかを計算するものである.これにより, 選好表 から選好表の補完ルールや選好表から類似表の補完ルールを置 き換えることが可能であると考えられる.しかし,多くの情報 フィルタリング手法では、ユーザのプロファイルが有効になる のに膨大な情報・時間を必要とする [土方 04] ことが指摘され ていることから, どの程度のデータサイズであれば有効に機能 するのかを検証する必要がある.また、類似表から選好表の補 完は、例えば、ガウス過程回帰 [Williams 06]、類似表から類 似表の補完は無限関係モデル [Kemp 06] の枠組みを適用でき ると考えられる. データのサイズと適用可能な手法の関係を調 査することも今後の課題となる.

### 謝辞

本研究は JST ERATO 石黒共生ヒューマンロボットインタラ クションプロジェクト(グラント番号:JPMJER1401)の一 環として行われたものです.

- [Kemp 06] Kemp, C., Tenenbaum, J. B., Griffiths, T. L., Yamada, T., and Ueda, N.: Learning systems of concepts with an infinite relational model, in AAAI, Vol. 3, p. 5 (2006)
- [Shardanand 95] Shardanand, U. and Maes, P.: Social information filtering: algorithms for automating "word of mouth", in *Proceedings of the SIGCHI conference on Human factors in computing systems*, pp. 210–217ACM Press/Addison-Wesley Publishing Co. (1995)
- [Sumi 00] Sumi, K., Sumi, Y., Mase, K., Nakasuka, S.i., and Hori, K.: Information presentation by inferring user's interests based on individual conceptual spaces, *Systems and Computers in Japan*, Vol. 31, No. 10, pp. 41–55 (2000)

- [Williams 06] Williams, C. K. and Rasmussen, C. E.: Gaussian processes for machine learning, the MIT Press, Vol. 2, No. 3, p. 4 (2006)
- [横山 10] 横山祥恵、山本大介、小林優佳、土井美和子 他:高 齢者向け対話インタフェース-雑談継続を目的とした話題提 示・傾聴の切替式対話法、研究報告音声言語情報処理 (SLP), Vol. 2010, No. 4, pp. 1−6 (2010)
- [下岡 17] 下岡和也,徳久良子,吉村貴克,星野博之,渡部生聖: 音声対話ロボットのための傾聴システムの開発,自然言語処 理, Vol. 24, No. 1, pp. 3–47 (2017)
- [山本 09] 山本大介,小林優佳,横山祥恵,土井美和子:高齢者 対話インタフェース:『話し相手』となって,お年寄りの生活 を豊かに,電子情報通信学会技術研究報告. HCS, ヒューマ ンコミュニケーション基礎, Vol. 109, No. 224, pp. 47–51 (2009)
- [小林 16] 小林峻也,萩原将文:ユーザの嗜好や人間関係を考 慮する非タスク指向型対話システム,人工知能学会論文誌, Vol. 31, No. 1, pp. DSF-A\_1 (2016)
- [土方 04] 土方嘉徳 他:情報推薦・情報フィルタリングのため のユーザプロファイリング技術、人工知能学会誌、Vol. 19, No. 3, pp. 365–372 (2004)
- [東中 09] 東中竜一郎, 堂坂浩二, 磯崎秀樹: 対話システムにお ける共感と自己開示の効果, 言語処理学会第 15 回年次大会 発表論文集, pp. 446-449 (2009)
- [内田 08] 内田ゆず, 荒木健治: 画像に対する発話を対象とした 名詞概念獲得システム SINCA, 知能と情報, Vol. 20, No. 5, pp. 685–695 (2008)
- [内田 19] 内田貴久, 港隆史, 石黒浩: 対話アンドロイドに対す る主観的意見の帰属と対話意欲の関係, 人工知能学会論文誌, Vol. 34, No. 1, pp. B–I62.1 (2019)
- [目黒 12] 目黒豊美, 東中竜一郎, 堂坂浩二, 南泰浩 他: 聞き 役対話の分析および分析に基づいた対話制御部の構築, 情報 処理学会論文誌, Vol. 53, No. 12, pp. 2787–2801 (2012)
- [楡木 89] 楡木満生:積極的傾聴法, 医学教育, Vol. 20, No. 5, pp. 341-346 (1989)

# 経験に基づく個人の感情推定モデル構築方法 及びロボット行動生成への利用

A personalized model to estimate emotion of individual based on observed facial expression and generation of robot behavior

> 熊谷和実<sup>\*1</sup> 水内郁夫<sup>\*1</sup> Kazumi Kumagai Ikuo Mizuuchi

> > \*1東京農工大学

Tokyo University of Agriculture and Technology

We aim to construct a system which allows robot to learn/generate a behavior favorable to an individual through interaction. The core idea is estimating emotion based on facial expression observed during a robot behavior to self-evaluate how the behavior is favorable to the individual. Based on the self-evaluated data gathered in the past interaction experiences, when the robot does some behaviors, our method is expected to help the robot to predict emotion of the individual gradually and properly. In this paper, we show the user studies to evaluate the proposed method. The study resulted that a robot changed its behavior to get better reaction. As future works, we discuss how robot should use observed data or knowledge to personalize robots behavior.

# 1. 個人に気に入られるロボット

本研究の目的は、人とのインタラクションを繰り返す中で個人が気に入る行動を学習してゆくロボット行動生成手法の構築である。本研究では、特定の個人とロボットとのインタラクション [Dautenhahn 04] を研究対象とする。

感情を推定する技術 [Picard 01] をロボット行動生成手法に 適用し、社会的にロボットが振る舞い [Breazeal 03] それを人 に気に入ってもらい長期に渡るインタラクションを実現する [Leite 14] ためにはシステムがどのような情報の処理をするべ きか研究を進めてきた。著者は、ドラえもんを参考にオリジナ ルのロボットをつくり、表1にまとめた様々なインタラクショ ン状況を想定し、実験を行なった。

# 2. 関連研究

2.1 感情推定を利用したコミュニケーションロボット 音声・画像などを用いた感情推定について多く研究されて きている [Zeng 09][Sariyanidi 15]。コミュニケーションロボッ トの多くは、感情推定結果をロボット行動開始のトリガや、行 動前の状況判断に用いる。そのようなロボットの戦略の多く は比較的大多数に受け入れられる行動パターンとなっている。 公共の場で不特定多数を相手にコミュニケーションするロボッ トには、この手法は有用である。しかし、家庭内やチューター ロボットなどのようにロボットが特定の個人とインタラクショ ンする場合、個人により好き嫌いが別れる行動の万人受けデザ インは難しく、特に、嫌いなものよりも好きなもののほうが好 みが分かれる。ロボットがした行動も好みによってはを相手の ひとが気に入らない可能性があるという問題点がある。

### 2.2 個人に合わせた行動をするロボット

子供と一緒に学習するチューターロボットに関する研究で は、子供の振る舞いに合わせてロボットが行動することの良い 効果が多く報告されている [Leyzberg 14]。多くの実験におい て、遠隔操作によって人間が子供の反応を観察した結果に応じ てロボットの行動が選ばれる。子供の性格や反応に応じてロ



図 1: 実際の観測表情を利用した感情推定結果に基づくロボット行動の個人適合手法

ボット行動を変えてゆくシステムを自動化する手法については 発展段階である。

Gordon らによる研究では、タブレットを用いたゲームによ る子供とのインタラクションを通してロボットの振る舞い(声 掛けの種類など)を子供の反応(表情とゲームの戦局)に応じ て決定する [Gordon 16]。しかしこの手法では、行動をどの方 向に修正するかが分からないという課題がある。ロボット行動 の表現方法、子供の過去の反応に基づきロボット行動を修正す る方法をいかに実現するかが課題となっている。

# 感情推定結果に基づく ロボット行動の個人適合手法

人がなにかされたときに見せた表情や返事など、外部に表 出された感情は、行動に対する評価系として扱うことができる と考えられる。本研究では従来の手法とは逆の方向性で感情推 定結果をロボット行動に利用する。すなわち、ロボットが行動 を開始してから後に人間がみせた反応(表情や返事など)を観 測し、次にインタラクションをする際の行動生成に利用する。 図1にメインフローの概要を示す。例えばポジティブな感情で あれば、してもよい行動とラベル付をし、次回以降に行動生成 する際に、しても良い行動を選択する頻度を高める。

連絡先: 熊谷和実, 東京農工大学, 東京都小金井市中町 2-24-16, 042-388-7206, kumagai@mizuuchi.lab.tuat.ac.jp

| インタラクション状況          | 感情推定手法                 | ロボット行動・表現方法    | 他の因子                 | 参考文献         |
|---------------------|------------------------|----------------|----------------------|--------------|
| 家庭内                 | 表情(ロボット動作中の<br>平均)     | 声かけ(自然言語)・単純動作 | 曜日・時間帯・天気・<br>忙しさ・体勢 | [Kumagai 14] |
| インタラクティブ<br>メディアアート | 表情(ロボット動作中の<br>平均・変化量) | 動作の大きさ・速さ等     | 人の動作と表情              | [Kumagai 18] |
| クイズゲーム              | 表情                     | 声かけ(自然言語)・単純動作 | クイズ戦局                | [Kumagai 16] |

表 1: 過去に実施した実験において想定したインタラクション状況・感情推定手法・ロボット行動

### 3.1 ロボット行動開始後の感情予測器の構築

感情予測器は、ある入力に対する出力の関係を学習する。本 研究であつかう予測器の入力が意味するものは、個人の心的状 態の変化や感情を引き起こす因子(ロボット行動を含む)とす る。人の感情を引き起こす因子の候補のうちのひとつにロボッ ト行動が含まれるという想定である。

どのような因子を設定するかは、ロボットが置かれた状況に よって適切に決められるものとする。出力の意味は、ロボット がした行動の後に観測した表情などから推定された個人の心的 状態変化や感情とする。また、因子の表現方法(数値化など) の設計が学習収束までのプロセスにおけるロボット行動戦略の 挙動に影響を与える。

### 3.2 感情推定部

感情は表情や声のトーン、姿勢、心拍数など様々な生理指標 に基づき推定するツールが多く出回っている。これで得られた 感情推定結果を感情予測器の出力として利用する。

まず考慮すべき点は、感情の表現方法である。感情の表 現方法については多く議論されてきているが [Plutchik 84], [Schlosberg 54], [Russell 80] 本手法では、扱いたい感情をター ゲットとし、連続値で表現することを想定する。本研究にお いては表情の種類(喜び表情・悲しみ表情など)を複数種類想 定し、各種類の表情強度をある値からある値までの連続値で 表現している。表情には直接現れないが心の中に生じている 感情が異なると、同じ種類の表情でも変化の仕方(立ち上が り、立ち下がりなど)が異なる研究がよく知られているように [Ekman 82]、どのタイミングの感情推定結果を利用するかに 応じて、良いとされる行動が変わる可能性がある。

また、学習のための使いやすさの点において、各指標ごとに 特徴があることを考慮する。例えば、声は出すときと出さない ときがある。一方で、表情は信頼度低め(ロボット行動に対す る表情ではない可能性が高いこともある)ではあるが、何かし らの結果を得ることができるという特徴がある。

また、個人の性格に応じて、どの指標に基づく感情推定結果 がもっともらしいかということが異なる。その点も学習プロセ スに影響することを考慮する必要がある。

# 4. 表情を感情予測に利用した行動生成実験

### 4.1 プロトタイプとしての行動選択実験

実験のシチュエーションは、家庭内で行われることを想定した場でのコミュニケーションとした。時間、曜日などの環境的 因子と、忙しいか否か、などの人間自身の因子の組み合わせを 状況として設定し、ロボットは状況に応じて発話と動作のセッ トを選択した。動作はシンボル的意味を連想しにくいもの(く ねくねする)を5パターン用意した。発話は10パターン用 意した。それぞれの発話は「おかえりなさい」「がんばってね」 など、相手に何かしら感情を持たせる意図をもたせた。

感情推定部分では、ロボット行動中に観測した表情点数を



図 2: 実験システムと実験参加者とのインタラクションの様子。 手を近づけると動作を開始する。[Kumagai 18]

利用し、それらの平均値を感情推定結果として感情予測部分 の入出力関係を学習した。ロボットの動作中に観測した表情点 数の重み付き和を評価点とした。各表情の種類毎にヒューリス ティックに決められた重み係数は、ポジティブな表情は正の値 の係数とした。実験では状況表示された PC の前に実験参加 者が座り、PC 画面に表示されたロボット動作中の表情は PC に取り付けたカメラで認識した。

大学院生1名に対して行なった実験では、インタラクション の回数増加に伴い、次第に感情推定結果の点数が向上している 様子が見られ、後半に点数が減少する様子が見られた。

### 4.2 連続値表現された動作生成実験

有限パターンの行動からの選択では実現困難な任意の動作 を生成する。ロボット行動を任意の軸で張られた空間上の点と して表現する。より高い評価点を得るよう修正する方向をシス テムに分からせることができると考えられる。

図 2 に示す白い枝のようなエージェント (LAS=Living Architecture System[Gorbet 15]) と人間がインタラクションす る実験を行なった。

動作時に観察した人間の表情に基づいて、動作パラメタと 人間の表情との関係を学習し、状況に応じた適切な動作パラメ タへと修正した。動作パラメタは、動作速度・動作の大きさ・ 動作が隣のエージェントへ遷移してゆく方向の3つとした。

実験は大学生・大学院生の男女14名に対し実施した。実験 前半において良い表情が見られた動作パラメタに近いパラメ タを後半で選ぶ様子がみられた。また、提案手法により生成し た動作とランダムに生成した動作に対するそれぞれの評価点 を比較した。提案手法により生成した動作に対する評価点が高 い実験参加者は表情に感情が表出する度合いが高い傾向にあっ た。ただし、パラメタ空間が膨大だと、十分な学習収束までに 多くのインタラクション回数を要する。そのため、学習が収束 する前に人が飽きたり、好みが変わるなど評価系が変わると、 適切な動作を生成することが困難という制限もある。



図 3: 情動・表情・心的状態・因子の関係図 [Ekman 75][Zajonc 89][Ekman 99][Forgas 92][Ekman 71]

# 5. 外部から直接観測困難な心的状態の推定

### 5.1 心的状態を因子に含む感情予測モデル

実験において、飽きなどが原因で行動に対する評価系が変 化したと考えられる。本研究の手法は、逐次学習の形をとるた め、評価系の遷移に追従するためにロボットは複数回ほどのイ ンタラクション回数を要する。飽きて退屈になっているような 心の状態(以下「心的状態」と呼ぶこととする。)を「状況(因 子)」に含める形でロボットが把握し、感情予測システムの更 新が心的状態の変化による評価系の変遷に追いつくまでのイン タラクション回数を減らすことを目指す。

飽きや気分など、持続時間が比較的長い心的状態と 情動とを区別し、情動発生に影響を与える因子の一 つとして心的状態を扱うようなモデルをロボットに持 たせるフレームワークを考える [Forgas 92]。図 3 は [Ekman 75][Zajonc 89][Ekman 99][Forgas 92][Ekman 71] などの知見をまとめ、心的状態・情動・因子(ロボット行動含 む)・外部への情動表出(表情など)の関係をブロック線図で 示したものである。各ブロックの関数f(),g(),h()はそれぞれ 心的状態変化モデル・情動発生モデル・表情表出モデルと呼 ぶことにする。観測データや既存の知識に基づき心的状態の 変化・発生する情動・表出する表情を予測するモデルをイン タラクションを通してロボットが構築してゆく手法を考える。

### 5.2 因子の観測可能性の高い場での心的状態推定

感情の変化を尤もらしく予測するために因子も尤もらしく 推定したい。決定論的モデルを用いて心的状態はどれほど推定 可能であるか検討するため、心的状態変化を引き起こす因子の 多くを観測データから推定可能な場で実験を行なった。実験の 状況は、プレイヤーに瞬発的な反応や集中力を求めるもぐら叩 きとした。

実験は参加者1名に対して行なった。ゲーム1回につき制限 時間約10秒間に全7匹のもぐらを穴から弾き出すルールであ る。実験ではゲームを100回実施し、各ゲーム終了毎に、心的 状態量として現在の気分のよさを-10点から10点で評価した。

本実験では、もぐら叩きゲームの戦局と1ゲーム前の気分 の良さを状況因子(入力)、ゲーム前後の気分の良さの変化量 を推定対象(出力)とし、入出力関係を3層のニューラルネッ トワークで学習した。Leave-One-Out 法を用いた交差検定を 行い、アンケート結果に基づき算出した気分変化量と、学習 結果に基づく気分変化量の計算結果との差分(以下、誤差と呼 ぶ)について検証した。実験の結果は、過去に似た経験をした ときほど気分変化予測結果の誤差が小さく、また予測変化量が 大きいほど誤差が大きくなる傾向であった。



図 4: 非線形関数の重み付和による心的状態推定モデルの個人 適合 [Kumagai 16]

# 心的状態推定モデルの個人適合手法と 行動生成への利用

### 6.1 因子・表情・心的状態の関係を表す非線形関数の 重み付き和によるモデル

本手法では、個人に合わせた心的状態推定のために、既存の 心的状態推定モデルの重み付和により因子毎の影響度合いを調 節し個人に合わせた心的状態推定モデルを構築する。既存の心 的状態推定モデルとは、ある因子と心的状態と表情との関係性 を表すものとする。

人とロボットによる協調作業など状況が限られている場合 は、人の心的状態の変化に共通パターンが見られることが多い ため、推定時に考慮する他の因子の影響が一般的なものに設定 されている。しかし、好みの分かれそうなロボット行動を含め た因子により引き起こされた心的状態の変化や情動発生など は、影響因子が個人に応じて異なると考えられる。

観測した表情と因子の関係から特徴量を抽出し、寄与率が 高いと考えられるモデルの重みを大きくする (図 4)。ニューラ ルネットワークの構造の高次の層を既存の関数に置き換えたこ とにほぼ相当すると考えられる。すでに確立された心的状態推 定モデルがあれば、それらの組み合わせを使って個人に合わせ た推定モデルを構築する。一方で、様々な因子に関する心的状 態推定モデルを複数持つ方が良く、適切なものが無い場合は用 意する必要がある。

### 6.2 クイズゲームにおける行動選択実験

クイズゲーム中の実験参加者に対しロボットが動作・発話を する実験を行なった。ロボットはクイズの戦局に応じて実験参 加者を応援するような発話をした (クイズは PC 画面に表示)。

推定モデルの構築に用いた非線形関数はクイズ状況を想定し ヒューリスティックに設計した。心的状態量は気分とした。実 験の前後に、実験結果の評価のための気分評価アンケートを実 施した。(アンケートの回答内容は行動選択には用いられてい ない。)実験は大学生・大学院生男女8名を対象に実施した。 今回の実験の結果においては、表情観測結果のみよりも心的状 態を考慮した場合の結果が良い気分ポイントがより高い参加者 の方が多い結果となった。また、表情変化が比較的少ない実験 参加者の実験結果は低い傾向であった。

### 7. 議論

### 7.1 表情認識の性能に依存する行動生成システムの性能

本研究のポイントは、表情を用いることである。(多くの実 験では OKAOVision[OMRON] という表情認識を利用した。) ロボット行動時に観測した表情に個人の感情が表れていたと き、表情予測結果に基づく行動は相手に喜ばれる可能性が高 かった。一方、表情が通常あまり変化しない実験参加者に関し ては点数が向上しない傾向が見られた。今後は、複数生理指標 を用いた感情推定手法を利用して個人の感情表出方法に合わせ たモデル構築手法を目指す。

### 7.2 ロボット行動の特徴に応じた表情処理

表情の扱い方はロボット行動の意味的特徴や動作的特徴に影響を受けると考えられる。行動に対する評価が表情等に現れる までの時間を考慮したり、ロボット動作の速度等で相対化し表 情変化を捉えるなどの対応が考えられる。

# 8. まとめ

本稿では著者らがこれまでに行ってきた研究について紹介し た。我々の研究手法のコアアイデアは、ロボットが行動したと きに個人が見せた表情を用いてロボット行動の気に入られる度 合を評価することと、行動の気に入られる度合いを予測する予 測器を過去の経験に基づいて更新してゆくことである。

提案手法について紹介し、関連研究・実験について述べた。 表情予測結果に基づく行動生成実験では、インタラクション回 数の増加に伴い個人からの評価点が増加したり、良い評価点を 得る期待値の高い方向へとパラメタを変えた動作を行う結果が 一部の実験参加者において見られた。感情が表情など外部に表 出される過程で内部状態量が働くと想定した心的状態変化モデ ルを行動選択に用いた実験では、表情のみから動作の評価を学 習するときよりも心的状態を考慮し学習したときの方が実験前 後の心的状態変化が良い結果となるケースが多かった。

ロボット行動戦略を更新し生成された行動をしたときに、よ り高い評価点を得る結果が見られた一方で、表情の変化が少な い実験参加者や、感情と表情の相関が低い実験参加者の結果は 向上しない傾向であった。評価関数の構築における感情推定結 果の利用方法(表情認識結果の平均を取るか変化量を取るか など)に課題があると考えられる。今後は、ロボット行動の特 徴(意味的特徴のような抽象度の高い特徴から動作の物理量な ど)に応じた感情推定結果の利用方法について調査しロボット 行動手法に応用する。

- [Breazeal 03] Breazeal, C.: Emotion and sociable humanoid robots, International Journal of Human-Computer Studies, Vol. 59, No. 1-2, pp. 119–155 (2003)
- [Dautenhahn 04] Dautenhahn, K.: Robots we like to live with?!a developmental perspective on a personalized, life-long robot companion, pp. 17–22IEEE (2004)
- [Ekman 71] Ekman, P.: Universals and cultural differences in facial expressions of emotion., in *Nebraska symposium on motivation*University of Nebraska Press (1971)
- [Ekman 75] Ekman, P. and Friesen, W. V.: Unmasking the Face: A Guide to Recognizing Emotions From Facial Expressions, Englewood Cliffs, N.J.: Prentice-Hall (1975)
- [Ekman 82] Ekman, P. and Friesen, W. V.: Felt, false, and miserable smiles, *Journal of nonverbal behavior*, Vol. 6, No. 4, pp. 238–252 (1982)
- [Ekman 99] Ekman, P.: Basic Emotions, in T., D. and M., P. eds., *Handbook of Cognition and Emotion*, pp. 45–60, John Wiley and Sons Ltd (1999)

- [Forgas 92] Forgas, J. P.: Affect in social judgments and decisions: A multiprocess model, in Advances in experimental social psychology, Vol. 25, pp. 227–275, Elsevier (1992)
- [Gorbet 15] Gorbet, R., Memarian, M., Chan, M., Kulic, D., and Beesley, P.: Evolving Systems within Immersive Architectural Environments: New Research by the Living Architecture Systems Group, Next Generation Building, Vol. 2, No. 1, pp. 31–56 (2015)
- [Gordon 16] Gordon, G., Spaulding, S., Westlund, J. K., Lee, J. J., Plummer, L., Martinez, M., Das, M., and Breazeal, C.: Affective Personalization of a Social Robot Tutor for Children's Second Language Skills., in AAAI, pp. 3951– 3957 (2016)
- [Kumagai 14] Kumagai, K., Baek, J., and Mizuuchi, I.: A Situation-Aware Actino Selection based on Individual Preference using Emotion Estimation, in *Proceedings of the 2014 IEEE International Conference on Robotic and Biomimetics*, pp. 356–361 (2014)
- [Kumagai 16] Kumagai, K., Hayashi, K., and Mizuuchi, I.: Estimating mood by determining weights of pre-defined basis functions based on observed facial expressions and situations, in 2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN), pp. 964–965 (2016)
- [Kumagai 18] Kumagai, K., Lin, D., Men, L., Blidaru, A., Beesley, P., Kulić, D., and Mizuuchi, I.: Towards individualized affective human-machine interaction, in 2018 27th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN), pp. 678–685 (2018)
- [Leite 14] Leite, I., Castellano, G., Pereira, A., Martinho, C., and Paiva, A.: Empathic robots for long-term interaction, *International Journal of Social Robotics*, Vol. 5, No. 3, pp. 329–341 (2014)
- [Leyzberg 14] Leyzberg, D., Spaulding, S., and Scassellati, B.: Personalizing robot tutors to individuals' learning differences, pp. 423–430ACM (2014)
- [OMRON] OMRON, : OMRON's Image Sensing Technology, https://plus-sensing.omron.com/technology/
- [Picard 01] Picard, R. W., Vyzas, E., and Healey, J.: Toward machine emotional intelligence: Analysis of affective physiological state, *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, Vol. 23, No. 10, pp. 1175–1191 (2001)
- [Plutchik 84] Plutchik, R.: Emotions: A general psychoevolutionary theory, Approaches to emotion, Vol. 1984, pp. 197–219 (1984)
- [Russell 80] Russell, J. A.: A circumplex model of affect., Journal of personality and social psychology, Vol. 39, No. 6, p. 1161 (1980)
- [Sariyanidi 15] Sariyanidi, E., Gunes, H., and Cavallaro, A.: Automatic Analysis of Facial Affect: A Survey of Registration, Representation, and Recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 37, No. 6, pp. 1113–1133 (2015)
- [Schlosberg 54] Schlosberg, H.: Three dimensions of emotion., Psychological review, Vol. 61, No. 2, p. 81 (1954)
- [Zajonc 89] Zajonc, R. B., Murphy, S., and Inglehart, M.: Feeling and facial efference: Implications of the vascular theory of emotion, *Psychological Revies*, Vol. 96, pp. 395–416 (1989)
- [Zeng 09] Zeng, Z., Pantic, M., Roisman, G. I., and Huang, T. S.: A survey of affect recognition methods: Audio, visual, and spontaneous expressions, *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, Vol. 31, No. 1, pp. 39–58 (2009)

感情の価値計算システム仮説にもとづく人の推論システムの提案

Human inference system derived from emotion as a value calculation system hypothesis

宮田 真宏<sup>\*1</sup> Masahiro Miyata 大森 隆司<sup>\*2</sup> Takashi Omori

\*1 玉川大学大学院 工学研究科 \*2 玉川大学 工学部 Graduate School of Engineering, Tamagawa University College of Engineering, Tamagawa University

There were many modeling studies about the emotion. But most of them were phenomenological and don't approach to the brain and/or cognitive mechanism. In this study, we consider a possibility of its computational modeling based on an idea that an emotion in wider sense is a value calculation system for an action decision. However, conventional inference methods could not explain human intuitive inference and logical inference. In previous study, we propose an integrated model in which the intuitive inference is represented as a search process of in a continuous and distributed associative memory, and is switched to a symbolic inference mode that biases an associative gain when it found values during the intuitive inference search. In this study, we show a merit of emotion based action decision that combines inference, reinforcement learning and reflex.

# 1. はじめに

近年の人工知能(AI)技術の発展は目覚ましく、今後生み出される製品には多様な AI 技術が用いられ、さらにその製品にはより人間的な知的機能が求められると予想される. その典型例に対人インタラクションがある. 対人インタラクションとは、基本的に人を対象とした広義のコミュニケーションを指す. それを実現するエージェントには、コミュニケーションする相手の感情や意図、要望などを理解し、それに応じた自身の意思決定を行う機能が求められよう. つまり相手の行動の原因を知り、その原因に応える自分の行動を決めることが質の高いコミュニケーションにつながる. さらに、人の意思決定には感情(価値)が関与し、その評価によりに行動することが知られている[ヴィンター 2017]. そのため、相手との円滑なコミュニケーションのためには、相手の意図や目的の背後にある人の価値観の理解もまた必要であろう. その意味で、人の価値計算の理解は高度な対人インタラクション AIの実現には欠かせないと考える.

また,人は価値と同様に感情によっても意思決定を行う.感 情が介入することは時として不合理なこともある.しかし,感情に よる意思決定は私たちの日々の生活の多くの場面において,合 理的な価値計算と同等の意思決定の結果をすばやく得ている [ヴィンター 2017].このように考えると,意思決定に対する感情 の役割は価値計算と同様と考えられる.以降,本稿では感情と 情動はその内容の複雑性については区別するが,機能的な意 味においては基本的には同一であると考えて議論する[信原 2017].

従来,感情に関しては多くのモデルが提案されてきた[Ekman 1997][Russell 1980].しかし,その多くは現象として観察される 感情を記述したモデルであり,認知や脳内処理のメカニズム,さ らにその計算論的な意味に迫るものではない[Chernavskaya 2015] [Samsonovich 2013].

また戸田は、人の複雑な感情から行動決定に至るまでの心 的過程に対して定性的な説明理論を構築した[戸田 1992].そ こで戸田は人の感情とは、自らの置かれている状態に価値を割 り振り意思決定に至るまでの計算過程であるとしている.しかし、 ここでも感情の具体的な処理過程については述べていない.

一方で[Koelsch 2015]は、人間の広義の情動を生存・安全・ 愛着・経済的価値の4つの要素に分解し、これらを個別の脳部 位に対応付けることでそれぞれの役割について説明を試みて いる. この研究では, 情動に経済的価値も含まれており, 眼窩 前頭葉がその機能を司るとしている. それではこれらの感情に 関するモデルの背後にある脳機能を考慮した計算的なメカニズ ム, さらにその役割はどのようなものであろうか. 本研究ではこれ までに, 感情とは動物が行動する際, 意思決定に用いる価値計 算システムの表出結果の一つであると仮定し, その計算モデル 化の可能性を議論してきた[Miyata 2017]. そこでは, 従来提案 されてきた手法の組み合わせにより, 実現できると考えていた.

しかし、従来行われてきた人のシンボル的な処理を Tree 探索 で実現する従来の推論手法は、人の脳内処理を考慮すると違 和感がある.人は複雑な推論過程を脳内の約 1000 億個あると される神経細胞の発火の連鎖により実現している.その処理が 直接的に Tree 探索のようなシンボル的な処理をしているかと考 えると疑問である.この問題に対して本研究ではこれまでに、価 値に駆動された連想記憶モデルを用いることで、従来言われて きた早く、確率的かつ並列的に探索する直観的推論を相互想 起により、意識的かつ時間のかかる論理的推論を自己想起の モデルによりそれぞれ実現できることを示してきた[宮田 2018]. 神経回路による連想記憶は 1970 年代から知られていたが [Nakano 1972]、最近では注目されていない.しかし脳全体は 大規模な連想記憶とも考えられ、推論との関係での記憶や知識 の利用法は検討に値しよう.

本研究にて考える推論の役割は、予測状態空間における、 価値を最大化する意思決定のための価値へ到達する状態空間 中の経路の探索であると考える.こう考えると、従来より多く研究 されてきた強化学習は、期待報酬予測という形で状態空間中に 価値に到達する経路のマーカーを付けていくアルゴリズムと解 釈できる[Sutton 1990].また進化の過程にて埋め込まれている と考えられている反射行動は、自身の不利益な事態を避ける行 動を生成すると考えると価値計算が含まれていると言えよう.こ のように考えた際、従来研究されてきた多様な意思決定アルゴ リズムは価値の最大化という意味で共通の基盤を持っている.

そこで本稿ではまず、本研究にて考えている価値計算システム仮説の概要について説明する.その後、本仮説の検証を考えた際にキーとなる推論について従来言われてきた推論手法との違い、および推論システムに求められる機能、および連想記憶によるその実現方法について説明する.そして最後に、推論、強化学習および反射とを組み合わせることによる意思決定システムの全体像について議論する.



### 2. 感情=価値計算システム仮説

### 2.1 感情と価値計算システムとの関係

我々の感情は意思決定に大きく影響を及ぼす.また自分自 身の感情の表出は他者にも伝達され,さらには他者の意思決 定にまで影響する.現在,行動経済学や脳科学では人の意思 決定は報酬(価値)の計算に基づくとされている[大竹 2012] [信原 2017].これより我々は,人などの動物の持つ感情とは自 身の置かれている内的・外的な状態を処理した結果,見出され た価値を含めて何らかの計算をし,その結果の表出されたもの であると考えた.さらに感情の背後には脳の神経細胞の発火の 連鎖による処理結果としての価値計算システムがあると想定す る.本研究では,価値と感情表出の対応はおおよそ固定であり, その結果として感情が価値評価の伝達システムとして的確に機 能すると考える.さらに感情のメカニズムの理解には,むしろ脳 内処理としての価値計算システムの理解が先に必要であろう.

それに対して従来の AI では知能の要素, および処理手順を 開発してきた.まず初めに視覚や聴覚などを処理する感覚情報 処理.次いで感覚情報処理の結果を用いた予測や意思決定な どの知的情報処理.そして最後にこれらの結果を出力する行動 生成の処理,という順である.それに対して本研究では,中段の 知的情報処理の背後にある報酬系,すなわち価値について考 える.本稿で考える価値計算システムでは,新皮質の知的情報 処理系に感覚情報が入力され,その認識結果は直ちに脳の多 様な価値を計算する処理系に伝達されると想定する.なお, 我々の考える感情の価値には Koelschの提案した「生存」「安全」 「愛着」「経済的価値」の4種を想定する.しかし,これらに対応 する脳部位(脳幹・辺縁系・海馬系・前頭葉系)は彼らの考える 脳部位よりも広範囲であると考える.本研究にて考える脳部位を 統合すると,大脳皮質下の脳部位の大半が対象になる(図 1).

### 2.2 価値計算システムにおける推論の立ち位置

本稿で考える推論とは、過去に例の無い新奇の場面での意 思決定のための価値に向かう経路探索とする.先述の通り、強 化学習や反射行動もまた時間的に長いスケールで価値計算を 含んでいると言える.すなわち、多様な意思決定アルゴリズム、 すくなくとも反射・強化学習・推論は価値の最大化という意味で 共通の基盤を持っている.

この世界で行動エージェントが出会う全ての状況を図 2 の大 きな円で表している. そのうちの一部は進化の過程で進化の過 程で先天的に反射として埋め込まれており,また他の一部は過



図2 推論による価値探索の位置づけ

去の経験から強化学習などによりその場に応じた行動が学習済 みであると考えられる.これらの状況では,個々の場面に応じた 行動あるいは価値が割り振られており,エージェントは探索をせ ずとも意思決定ができる.しかし残りの未経験領域は価値が割り 振られていない新奇の状況であり,エージェントは推論などによ り,現在状態から価値の割り振られた状況までの行動経路を発 見することで,未経験の現在状態における行動の価値を計算し 行動することが求められる.このように状況空間における価値を 基準に学習アルゴリズムを配置すると,少なくとも反射,強化学 習,推論は一続きとなり,それらの間の関係が明らかとなる.

# 3. 人の推論

認知科学では、人の推論には直観的推論(システム 1)と論理 的推論(システム 2)の二種類ある[Evans 2009]とされ、それぞれ を別のシステムとしてモデル化してきた(表1). 推論の制御は、 まずシステム1にてヒューリスティックな過程が行われ、必要に応 じて分析的過程であるシステム2が実行されることで意思決定が なされるという二重過程モデルが議論されてきた[服部 2015].

それに対して、従来の AI における推論の基本モデルには Tree 探索があげられる. Tree 探索は個々の離散状態の予測, およびその評価を行う意識的かつシンボル的な方式である [Russel 2008]. また、我々はシンボル的推論とは別に、何かを 知覚するとその影響の予測と評価を素早く行う直観的な推論過 程も持っている. これは、感覚刺激からの自動的な連想による 無意識的な予測と評価によると考えられる. これを踏まえると、 予測は局所的で多方向に並列的に進み、それを価値計算シス テムが部分的に評価したものが、直観と呼ばれていると考える [大森 2017]. 課題は、行動的には異なるこの二つのシステム がどうやって脳で実現されていか、である. これまで論理的推論 の脳部位というものは見つかっておらず、また論理的推論は確 実に意識とも関連があり、そのメカニズムは謎のままである.

表1 推論の二重過程と二重システム仮説

| 直観的推論         | 論理的推論        |
|---------------|--------------|
| 作業記憶は不要       | 作業記憶が必要      |
| 無意識的,自律的      | 意識的,         |
|               | メンタルシミュレーション |
| 推論が速い         | 推論が遅い        |
| バイアスに影響されやすい  | 規範的,公平       |
| 文脈依存          | 抽象的          |
| 確率的,分散的       | 論理的,シンボル的    |
| 暗黙知(経験的確率)を利用 | 明示的な知識を利用    |
| 推論が浅い         | 深い推論が可能      |
| 進化的に古い        | 進化的に新しい      |



### 4. 連想記憶モデル

### 4.1 連想記憶による推論

連想記憶とは、記憶パターンを貯蔵し、部分的な記憶情報を基に必要な記憶を読み出す機能である.神経回路による分散型の連想記憶モデルとしては、記憶事項を一つのベクトルで表したアソシアトロン[Nakano 1972]や時間的な連想を含んだモデル[Sompolinsky 1986]、さらには連想記憶にシーケンシャルな制御を加えた PATON[Omori 1999]などがある.これらのモデルでは、複数個の記憶事項の記銘はそれらの相関行列の和(記憶行列)で表し、想起用の入力ベクトルと記憶行列の積の計算で想起を再現できる.本稿ではこの相関行列型の連想記憶モデルを用いて、人の二種類の推論のモデル化およびその検証を行う.

### 4.2 推論システムの全体像

本研究で目指す推論の型を図3に示す Tree 構造とする.記 憶パターンは Tree の各ノードに対応し,探索は初期状態 $S_0$ から 開始することとし,状態遷移は初期状態 $S_0$ から2分木が3階層 だけ継続するとした.シミュレーションは,推論の連鎖の結果, 正の価値のあるノード $V_1$ ,または負の価値のあるノード $V_2$ の周辺 領域に到達し,価値を見出すことができた場合に意思決定がで きるとした.なお,一般的な探索問題の研究ではより深い複雑な 課題を扱うことが多いが,本研究ではまず連想記憶モデルをベ ースにした推論行動の創発を示すことが目的であるため,単純 なトイ問題を対象とする.

図 4 は本研究で想定する連想ベースの推論システムの全体 像である.入力層 $x_t$ の情報を相互想起または自己想起の連想 行列にかけ合わせることで想起パターン $x_{t+1}$ が得られ, $x_{t+1}$ は さらに価値認識層に送られ,そこに含まれる成分についての評 価と意思決定処理が行われる.

直観的推論では、x<sub>t</sub>は相互想起行列 W<sup>e</sup>にかけ合わせること で次の時刻の状態x<sub>t+1</sub>を得て、それはそのまま次の時刻の入 力になるという連想の直線的な連鎖を想定する。一つの状態か ら連想する際にその連想関係が分岐することがある(実際は多 い)ため、複数の記憶パターンが混在した想起パターンが得ら れる.さらに次の計算では複数の記憶パターンが混在した状態 を基に次の連想をするため、さらに分岐が広がるという並列的な 想起が起こり、結果として並列的で幅広い探索が実現される。こ の計算は処理が単純であるため、無意識的すなわち自動的な 過程で実現可能と考えられるが、処理を繰り返すと多くの記憶 の混合パターンが想起されることで個々の記憶パターンのゲイ ンが小さくなるため、深い推論は実現できない。

それに対して論理的推論では,直観的推論にて複数の記憶 パターンの混合パターンが想起された後,そのうちの一つの記



憶パターンを選択的に想起する自己想起過程を追加することで, 記憶パターンの混合を回避する.そのため,混合記憶パターン が一つの記憶パターンに収束するまでに時間がかかるが,想起 パターンのゲインの減衰のない深い推論が実現できる.なお, 本研究で想定する相互想起過程と自己想起過程の切り替えは, モデル的には単純なパラメータの切り替えで実現でき,その動 的なスイッチングが一見して複雑な確率的処理と論理的処理の 混合した過程を実現することとなる.

### 4.3 直観的推論と論理的推論の実現

人の推論に直観的推論と論理的推論の二種類があるとする と、状況に応じてどちらかを選択して推論を制御する上位システ ムが必要となろう.しかし、そのような上位システムは知られてお らず、そもそも論理的推論の脳部位も知られていない.その解 釈として本研究では、これら2つの推論は1つの処理システム の別の姿であり、その動作モードのスイッチングにより振る舞い が変わると考えた.その過程を連想記憶モデルの連想と仮定し て表現すると、その計算式は以下になる.

### $x_{t+1} = \alpha \left( \sum_{q} \Pr\left(x_{t+1}^{q} | x_{t}^{p}\right) W_{pq}^{e} \right) x_{t}^{c} + (1-\alpha) \sum_{q} W_{pq}^{S} x_{t}^{c} \quad \cdots (1)$

(1)式右辺の第一項は、直観的推論を実現する相互想起の 項である.ここでは過去の経験を表現する記憶ベクトルからイベ ントごとの連想行列(W<sup>e</sup><sub>pq</sub>)を作成し、入力ベクトル(x<sup>e</sup><sub>b</sub>)から想起さ れる記憶ベクトルを連想的に探索する.なお、記憶ベクトル群は 直交していると想定する.これより想起ベクトルは、入力ベクトル に関係があるほど連想行列から強い強度で想起される.そして 想起されたベクトルは過去の経験頻度を表す条件付き確率に 基づき強さが決まる.この計算の反復により、短時間で広い範 囲に対する連想的な探索が可能となる.そして探索中に価値の ある部分を発見した際には、その価値に従い意思決定する.

(1)式右辺の第二項は、第一項で見出された価値に焦点を当 て、その価値を最大化させる記憶想起の反復計算を表す. すな わち、入力ベクトル中の価値のある成分を強化して、想起によっ て特定の価値に対応する記憶パターンのみが支配的になるま で自己想起型の連想計算を反復し、その記憶パターンに対応 する行動を選択する(図 4) [宮田 2018].

### 5. 計算機シミュレーション

これまで本研究では、シミュレーション環境を作りこんだ迷路 タスクを題材に、連想記憶を用いた推論システムが人の推論シ



図5 連想記憶を用いた2つの推論の違い

ステムの統合的な説明が可能であることを示してきた.これにより,図2の価値を中心とすることで反射,強化学習,推論を組み 合わせたシミュレーションの実行を試みる.そのため本稿では, 価値計算システム仮説の検証のために迷路課題を用意した.

この課題の想定では、エージェントははじめ、迷路の経路情報を知らず、ランダムウォークにより地図を経験して経路を記銘する.そして、報酬が目の前に現れた際には反射行動により目の前にある報酬を得て、報酬地点の近傍のみに強化学習により価値を割り振っていく.そして、推論による価値探索を行う.

報酬を得た際には、エージェントは地図内のランダムな位置 に再配置されるため、すぐに推論による探索が可能になるとは 限らない.しかし、何度も経験を重ね、かつ強化学習により地図 空間中に価値の伝播が広がることで、地図空間中の様々な位 置からの推論が可能になる.そしてシミュレーションの結果、反 射・強化学習・推論という三種の行動決定方式を組み合わせた 課題において、本研究にて提案した推論システムは問題なく動 作する結果を得た.

## 6. まとめ

これまでに本研究にて考える感情の価値計算システム仮説 の概要,および連想記憶と価値の導入により実現される論理 的・直観的の二種類の推論の実現方法を示してきた.さらに, 本研究にて提案した価値駆動の推論システムと,反射行動およ び強化学習とを組み合わせ,迷路タスクにおいて効果的な行動 決定が可能であることを示した.

今後は、まず図2にて示した環境をより実世界に近い環境に したうえでのモデルの評価を行う必要がある。例えば物理法則 と捕食者や仲間を含んだ仮想環境などを用いることにより、推 論・強化学習・反射、さらにはエピソード記憶も統合したシステム の有用性を検証する。その後、必要に応じて3要素の手法を切 り替えることで、その場の状況に応じた柔軟な行動を示すエー ジェントを作成する。これを実現することは、人のような感情の効 用と発生メカニズムの解明に寄与することを期待する。本研究 は文部科学省科研費15H01622の助成を受けた。支援に感謝 する。



組み合わせたシミュレーションの結果

- [ヴィンター 2017] エヤル・ヴィンター:愛と怒りの行動経済学 賢 い人は感情で決める, 早川書房, 2017
- [信原 2017] 信原幸弘: 情動の哲学入門 価値・道徳・生きる 意味, 勁草書房, 2017
- [Ekman 1997] P. Ekman et al: What the face reveals: Basic and applied studies of spontaneous expression using the Facial Action Coding System (FACS), Series in Affective Science, Oxford University Press, 1997.
- [Russell 1980] J. A. Russell: A circumplex model of affect, Journal of Personality and Social Psychology, vol.39, pp.1161-1178, 1980.
- [Chernavskaya 2015] Chernavskaya, : An architecture of the cognitive system with account for emotional component. Biologically Inspired Cognitive Architectures., BICA Journal, 2015, doi:http://dx.doi.org/10.1016/j.bica.2015.04.009
- [Samsonovich, 2013] Samsonovich : Emotional biologically inspired cognitive architecture. Biologically Inspired Cognitive Architectures. , BICA Journal, 2013. doi:http://dx.doi.org/10.1016/j.bica.2013.07.009
- [戸田 1992] 戸田正直:感情,東京大学出版, 1992.
- [Koelsch 2015] S. Koelsch et al: The quartet theory of human emotions: An integrative and neurofunctional model, Physics of Life Reviews, Vol. 13, pp. 1-27, 2015.
- [Miyata 2017] Masahiro Miyata, Takashi Omori : Modeling emotion and inference as a value calculation system, BICA2017, Vol. 123, pp. 295-301, 2017
- [宮田 2018] 宮田真宏, 大森隆司:価値に駆動された連想記 憶に基づく人の推論過程の統合, 第 34 回 ファジィシステム シンポジウム, 2018
- [Nakano 1972] Kaoru Nakano : Associatron-A Model of Associative Memory, IEEE, 1972
- [Sutton 1990] Richard Sutton: Integrated Architectures for Learning, Planning, and Reacting Based on Approximating Dynamic Programming, Appeared in Proceedings of the Seventh Int. Conf. on Machine Learning, pp. 216-224, 1990
- [大竹 2012] 大竹文雄ら: 脳の中の経済学, ディスカヴァー携 書, 2012
- [Evans 2009] Jonathan St. B. T. Evans et al.: How many dualprocess theories do we need? One, two, or many?, Oxford Scholarship Online, 2009
- [服部 2015] 服部雅史: 思考と推論: 理性・判断・意思決定の 心理学, 北大路書房, 2015
- [Russel 2008] Russel, Norvig 他:エージェントアプローチ人工 知能第2版, 共立出版, 2008
- [大森 2017] 大森隆司, 宮田真宏: 粒子モデルと価値評価系 による直観的推論の計算アーキテクチャ, p.55-56,日本神経 回路学会全国大会講演論文集, 2017
- [Sompolinsky 1986] Haim Sompolinsky: Temporal Association in Asymmetric Neural Networks , Physical review letters, The American Physical Society, 1986
- [Omori 1999] Takashi Omori et al: Emergence of symbolic behavior from brain like memory with dynamic attention, Neural Networks Vol. 12, No. 7-8, pp. 1157-1172, 1999
- [宮田 2018] 宮田真宏, 大森隆司: 連想記憶モデルに基づく 人のシンボル的推論のモデル化, 第8回人工知能学会汎 用人工知能研究会, 2018

# 論理モデルに基づく感情生起と感情推測を行うエージェント

Agents Which Generate and Estimate Emotions Based on Logical Model

### 塚本 麻衣

Mai Tsukamoto

奈良女子大学大学院 人間文化研究科 博士前期課程 情報衣環境学専攻 Department of Computer Science and Clothing Environment,

Graduate School of Humanities and Sciences, Nara Women's University

Recently, research studies on robots that have emotions and can have dialogues with humans are progressing. By making it possible to guess the emotions of others, it is possible to generate more kind of human emotions corresponding to the guessed emotions. In addition, it is desirable that the generation of one's own emotions and the estimation of others' emotions can be performed under the same condition, but such research is not seen in the past. Therefore, in addition to our previous implementation based on the combination of OCC theory and BDI model, we have made it possible to estimate others' emotions using the same definitions as those we have used so far. Furthermore, whereas we had to give inputs from the environments to our system in the form of logical formulas, we aim to implement robots that generate emotions based on the beliefs extracted from the sentences such as conversation.

# 1. はじめに

近年、ロボットに人間らしい感情を持たせる研究が進んでい る。特に行動選択において、ロボットが抱いた感情を反映でき れば、より人間らしい行動がとれると考えられる。そのために は、行動選択と感情の生起が共通の機構で表現、および実現で きることが望ましい。

自律エージェントのモデルである BDI モデルとの相性のい い、OCC theory[OCC 88] と Adam らの研究 [Adam 09] に よる感情の定義を用いることによって、BDI logic で行動選択 と感情生起の両方を実現することが可能となる。従来、我々は Adam の論文による形式化を基に、感情を生起するロボット の実装と複数の感情の同時生起、感情の度合いの実現、時間 経過による度合い減少と感情の削除などの拡張を行っている [今井 18][浅井 18]。しかし、感情生起の条件となる信念を論理 式の形で入力する必要があった。また、生起される感情やその 妥当性を調べる手段がなかった。

そこで、本研究では与えられた日本語文を構文解析するこ とで信念を取り出し、それを用いて感情生起を行うよう実装を 行っている。現段階では、構文解析に適した形に手直しした文 からの感情生起が可能となっている。これにより、物語文をサ ンプルとしての感情生起の妥当性の検証が可能となる。また、 音声認識と組み合わせることで会話からの感情生起など、環境 からの自然な入力による感情生起への応用も期待できる。

さらに、従来の実装では他者の感情の推測を行っておらず、 そのため他者の感情を生起条件に含む自身の感情の生起につい ても実装が不十分であったため、他者の感情推測を行うように 実装を拡張した。他者の感情の推測についても自身の感情生起 と同一の条件に基づいて行えることが、自然な感情生起のため には望ましいため、両者で条件として同一の論理式を用いる形 で実装の拡張を行っている。

# 2. 関連研究

感情に関する研究には、機械学習を用いたものもみられる。 [堀宮 12] では、他者反応を含めた文章に感情ラベルを付加し、 学習させることによって、感情を示す言葉や、直接的な感情表 現のない文章に対しても、その後に続く他者からの反応によっ て感情の推定を可能としている。しかし、機械学習を用いた研 究では、感情の生起理由の説明が困難である。それに対し本 研究では、感情生起を OCC theory の形式化による論理式で 行っているため、生起した感情に対し、その理由を明確にでき る利点がある。また機械学習にはより精度を上げるために多量 の教示データが必要となるが、多量のデータを実験で得ること が難しいなどの問題があるため、我々は採用していない。

ロボットに感情を持たせるにあたり、『ポチは散歩した事を 喜んだ』のように、どの事柄に対して感情を生起しているのか 正しく表現することは、感情が生起した理由説明に用いること ができるなどの理由で望ましく、感情に関する既存研究におい てそのような研究もみられる [遠藤 06]。これは、「うれしい」 「かなしい」等の感情表現となる語句の係り元となる2文節を 抽出し、末尾に「のが」「ことが」を含むものを感情生起表現 (感情が向けられる事象)として得ることを可能としている。 しかし、感情表現となる語句が存在しない文が与えられた場合 は感情の推定が困難であり、感情生起表現が存在しない文が与 えられた場合は、生起した感情を向ける事象を明確にするこ とが困難であると考えられる。本研究では、4章で述べるよう に、一つの文から人物、事象、信念の種類と度合いを得ること によって信念を生成し、特定の信念を得たとき感情生起を行う ため、文中に感情表現となる語句が存在しない場合も信念生 成、感情生起を行うことを可能としている。また、動詞、また は動名詞を感情を向ける事象として抽出するため、主語述語が 明記された文であれば、感情生起表現が存在しない文であって も感情を向ける事象を明確にすることを可能としている。

推定した他者の感情からの行動選択を行う研究や他者の行動から自身の感情生起を行う研究も多くみられる。例えば [Tang, 14] では、話者の発話による音響的特徴によっての感情推定を可能としており、推定した感情に合わせた対話の実

連絡先: 塚本 麻衣, 奈良女子大学人間文化研究科博士 前期課程情報衣環境学専攻生活情報通信科学コース, sam\_tsukamoto@cc.nara-wu.ac.jp

現を目指しているが、自身の感情生起は行っていない。また、 [石川 18]では、他者の説得に対する受託状況によって自身の 感情状態を遷移させ、感情状態に合わせた対話を試みている が、他者の感情の推測は行っていない。人間らしさのある自然 な行動を選択するにあたり、他者の感情の推測と自身の感情生 起の両方を行い、生起、推測した感情に沿って行動を選択する よう実装を行うことが望ましいと考えられる。またその際、自 身の感情生起と他者の感情推測を同一の条件に基づいて行うこ とが妥当である。本研究では自身の感情生起と他者の感情推測 を同一の条件に基づいて行うよう実装の拡張を行った。

### 3. 他者の感情の推測

従来の研究 [今井 18][浅井 18] では、他者の信念を得ること で生起する感情が存在するが、他者の感情の推測については行 われていなかった。しかし、より人間らしいエージェントの実 装を目指すにあたり、他者の感情の推測を行い、推測した感情 に対応した自身の感情の生起を行うことが望ましいと考えら れる。推測には、自身の感情生起と同一の条件に基づくことが 妥当といえるため、感情の生起条件となる信念を感情推測の対 象が持っていると信じた時、対象の感情の推測を行うよう実装 した。

以下に、同じ感情に対する自身の感情生起の条件と他者の 感情推測の条件の例を挙げる。

感情 Joy (喜び)の生起は以下の形式的定義によって行われる。

$$Joy_{f(d)}^{i}\phi := Des_{d}^{i}\phi \wedge Bel^{i}\phi \qquad (1)$$

これは「エージェント*i*にとってイベント $\phi$ の成立が*d*程度望 ましく、エージェント*i*がイベント $\phi$ の成立を信じた時、エー ジェント*i*はイベント $\phi$ の成立に対する*f*(*d*)程度の感情 *Joy* を生起する」という意味である。ここで、*Des<sup>i</sup><sub>d</sub>* $\phi$ は「エージェ ント*i*にとってイベント $\phi$ の成立は*d*程度望ましい」、*Bet<sup>i</sup>* $\phi$ は「エージェント*i*がイベント $\phi$ の成立を信じている」という 意味である。イベントの成立に対する望ましさの度合い*d*の 値が大きいほど、感情 *Joy*の程度も大きくなると考えられる ため、感情 *Joy*の度合いを計算する関数 *f*(*d*) は増加関数と定 義している。

次に他者の感情 Joy (喜び)の推測は以下の形式的定義に よって行われる。

$$Guess\_Joy^{i,j}_{f(d)}\phi := Bel^i Des^j_d \phi \wedge Bel^i Bel^j \phi \qquad (2)$$

これは「エージェント*j*にとってイベント $\phi$ の成立が*d*程度 望ましいとエージェント*i*が信じ、エージェント*j*がイベント  $\phi$ の成立を信じているとエージェント*i*が信じた時、エージェ ント*i*はエージェント*j*のイベント $\phi$ に対する*f*(*d*)程度の感 情 *Joy*を推測する」という意味である。ここで、*Bet<sup>i</sup> Des<sup>j</sup><sub>d</sub>* $\phi$ は「エージェント*j*にとってイベント $\phi$ の成立が*d*程度望まし いとエージェント*i*が信じている」、*Bet<sup>i</sup> Bet<sup>j</sup>* $\phi$ は「エージェ ント*j*がイベント $\phi$ の成立を信じているとエージェント*i*が 信じている」という意味であり、以下の等価関係が成り立つ。

$$Guess\_Joy_{f(d)}^{i,j} \phi \equiv Bel^i(Des_d^j \phi \wedge Bel^j \phi) \tag{3}$$

これは「『エージェント j にとってイベント  $\phi$  の成立が d程度望ましく、エージェント j がイベント  $\phi$  の成立を信じて いる』ことをエージェン i が信じている時、エージェント i は エージェント j のイベント  $\phi$  に対する f(d) 程度の感情 Joy を 推測する」という意味である。 この式の Bel<sup>i</sup> の中身は式 (1)の右辺と同じ形をしており、他 者の Joy の発生の推定を自身の Joy の生起と同じ条件で行っ ている事を示す。他の感情の推測に関しても同様に、推測対象 が感情の生起条件の信念を持っていることを信じた時、対象の 感情を推測を行う。これにより、同一の条件に基づいた感情生 起と他者の感情の推測を可能とした。

# 4. 構文解析

従来の研究 [今井 18][浅井 18] では、事例として物語文から の感情生起を扱っていたが、感情生起の条件となる信念を、与 えられた物語文から人間が解釈して抽出し、実装に用いている エージェント記述プラットフォームである Jason[Jason 07] で の表記によって手動で与えることで感情生起を行う必要があっ た。しかし、これでは環境からの自然な入力から感情生起する ことができない。したがって、エージェント自身が文の中から 必要な信念を取り出し、感情生起を行うことが望ましい。そこ で、本研究では与えられた文を構文解析することで信念を論理 式として取り出し、感情生起を行うよう実装した。

例えば「ポチは散歩したい」という文が与えられると、 『ポチ (名詞) は (助詞) 散歩し (動詞「する」の連用) たい (助動詞「希望」』

のように解析でき、図1のように名詞から感情生起の主体で ある『ポチ』、動詞または動名詞から信念が発生するイベント 『散歩』、助動詞から信念の種類『des(願望)』を取り出す。そ して、Jasonの記法で

信念 des(pochi,sanpo)[degOfCert(0.5)]

(ポチは散歩が度合い 0.5 ほど望ましい) を生成し、我々のシステムに入力として与え、エージェント『ポ チ』の信念に追加する。信念の第一引数はイベントの主体となる エージェント名、第二引数はイベント名、degOfCert()は信念 の度合い (0~1)を表す。この時、従来研究 [今井 18][浅井 18] で述べられている所定の感情生起の条件を満たしていれば、感



図 1: 構文木および生成される信念

感情を表す信念は、

『感情 (イベントの主体となる人物, イベント) [度合い]』 または

『感情 (感情を向ける対象)[度合い]』

という形で表現しており、相手に向ける感情を表す際に後者の 形式をとる。感情の生起条件は、

- 主体となる人物
- イベント
- 信念の種類: bel(事象の成立を信じる)、des(事象の成立 を望む)、prob(事象の成立を予期する)、effort(事象の成 立のために努力する)、deserve(事象の成立が相応しい)、 praise(事象の成立は賞賛される)、appealing(相手に魅力 を感じる)、unappealing(相手に魅力を感じない)、familiar(相手に親しみを感じる)等
- 信念の度合い

などを用いた論理式で表現している。

与えられた文から信念を抽出する際、「~を探す」といっ たイベントの場合、自身が探し物をしていることを認識して いると共に、探し物を見つけることを望んでいると考えられ る。そのため、エージェントは探していることを信じる信念 bel(pochi,search)を持つと共に、「見つける」ことを望む信 念 des(pochi,find)[degOfCert(D)] を持つ必要がある。これに より、探し物を見つけた際に感情 Joy (喜び)を生起させる ことができる。「~ を頼む」という動詞についても同様に、 相手に頼み事をしていることを認識していると共に、相手が 頼み事を達成する事を望んでいると考えられる。そのため、 頼むことを信じる信念の他に、他者が~ に入るイベントを 発生させることを望む信念を持つ必要がある。例えば『お使 いを頼む』であれば、相手がお使いをすることを望む信念 des(pochi,bel(mike,otsukai))[degOfCert(D)] が生成される。 これにより、相手が頼み事を達成した際に感情 Joy を生起さ せることができる。このように同じ動詞であってもイベント構 成の一部となるもの(~で遊ぶ)、別のイベントに対する信念 を呼び出すもの (~を探す)、信念となる感情を生成するもの (~を頼む)が存在する。助動詞についても、信念となる感情 生成に使用するため、種類や順番を考慮して正しい信念を生成 する必要がある。

これらのことから、単語一つ一つに必要な要素を持たせ、構 文解析中に必要であれば追加、削除を行い、適切な形の信念に 変換する必要があった。これらの実現のために、本研究では形 態素解析・構文解析プログラムとして既存のものを採用せず、 信念の抽出に適した構文解析プログラムを新たに作成した。た だし、現段階では、物語文を解析に適した形に編集してから入 力することで信念を抽出する。

信念生成の際、イベントを主語と動詞句のみからなる文から 生成することも可能であり、例えば『ポチは遊んだ』という文 からは、遊んだことを信じる信念 bel(pochi,play) が生成され る。しかし、より正確な感情を生成するのであれば、動詞のみ でなく主体になり得ない名詞 (場所、物、など) をイベント名 に組み込むことで、何に対してその感情を生起したのかを細か く表現する必要がある。そうすることで、『ポチは公園で遊ん だ』と言う文から感情 Joy (喜び)が生起した際、「『ポチ』が 『公園で遊んだ』事に対して『喜び』と言う感情を生起した」 ことが分かるようになることが期待される。このように、今後 はイベントの細分化についても実装の改良を目指す。

### 5. 実験

本章では、本研究で新たに実装した他者の感情の推測の妥 当性と、構文解析プログラムが期待通りの信念を抽出するか どうかの検証を行う。生起した感情の妥当性を調べる手段とし て、本来は人間を対象とした調査が望ましいが、大人数を必要 とする心理実験は難しいため、現段階では文学作品を入力とし て用い、生成される感情が人間の読み取ったものと一致するか を見ることで検証を行う。シナリオは『はじめてのおつかい』 [筒井 77] から一部抜粋して使用した。シナリオは以下の通り である。

『お母さんからお使いを頼まれ家を出たみいちゃんは、坂で転 んでしまい、その拍子に持っていたお金を落とした。落ちたお 金を無事見つけたみいちゃんは元気に坂を登って行った。無事 にお使いを済ませたみいちゃんをお母さんが迎えにきた。』

このシナリオを、現段階の構文解析プログラムで信念抽出 可能な形に変えて入力する。

本実験で、生成されることが期待される、みいちゃんの信念 は以下のようなものである。それぞれ、上段に Jason での表 記、下段にその内容を示す。

bel(haha,des(michan,otsukai)[degOfCert(0.5)]) (みいちゃんは「お母さんがお使いすることを望んでいる」 ことを信じる) bel(michan,korobu) (みいちゃんは転んだことを信じる) des(michan, not korobu)[degOfCert(0.5)](みいちゃんは転ばないことを望む) bel(michan,otosu) (みいちゃんは落し物をしたことを信じる) des(michan, not otosu)[degOfCert(0.5)](みいちゃんは落し物をすることを望まない) bel(michan, sadasu) (みいちゃんはお金を探した) des(michan, find)[degOfCert(0.5)](みいちゃんはお金を見つけたい) bel(michan,find) (みいちゃんはお金を見つけた) bel(haha,bel(michan,otsukai)) (みいちゃんは「お母さんがお使いできたことを信じている」

ことを信じる)

また、これらの信念からは、お金を落としたことに対する感情 Distress(嘆き)、落としたお金を見つけることができたこと に対する感情 Joy(喜び)の生起、お使いを済ませた事に対する 母の Joy の感情推測が起こることが期待される。

本実験では、入力としては物語を以下の様に編集して与える。

- みいちゃんはお母さんにお使いを頼まれた
- みいちゃんは転んでしまった
- みいちゃんはお金を落としてしまった
- みいちゃんはお金を探した
- みいちゃんはお金を見つけた
- みいちゃんはお母さんにお使いを伝えた

このように、現段階では、主語が明確な形の文を入力すること で信念を抽出する。 実験の結果を以下に示す。まず、入力の各文からは以下の信 念が抽出された。 みいちゃんはお母さんにお使いを頼まれた  $\rightarrow$  bel(haha,des(michan,otsukai)[degOfCert(0.5)]) みいちゃんは転んでしまった  $\rightarrow$  bel(michan,korobu) des(michan, not korobu)[degOfCert(0.5)]みいちゃんはお金を落としてしまった  $\rightarrow$  bel(michan,otosu) des(michan, not otosu)[degOfCert(0.5)]みいちゃんはお金を探した  $\rightarrow$  bel(michan, sagasu) des(michan, find)[degOfCert(0.5)]みいちゃんはお金を見つけた  $\rightarrow$  bel(michan, find) みいちゃんはお母さんにお使いを伝えた  $\rightarrow$  bel(haha, bel(michan, otsukai)) このように、みいちゃんが望んでいなかったと考えられる「転 ぶ」、「お金を落とす」というイベントの発生を望まない信念 を、「お金を探す」というイベントに対して「お金を見つける」 というイベントの発生を望む信念を抽出できるなど、期待通り の信念が抽出されている。また、それらの信念が入力された結 果、生起した、あるいは他者に対して推測した感情は以下の様 になった。 イベント:転ぶ → Distress(嘆き)を生起(度合い 0.5) イベント:お金を落とした → Distress(嘆き)を生起(度合い 0.5) イベント:探していたお金を見つけた → Joy(喜び) を生起(度合い 0.5) イベント:お使いを済ませた →母の Joy (喜び)を推測(度合い 0.5)

このように、期待された感情が生起している他、母がイベン ト「お使い」に対して、感情 Joy の生起条件である信念 des、 bel を持っていることを信じたとき、母の感情 Joy を推測して おり、自身の感情生起と同一の条件に基づいて他者の推測を行 えている。

# 6. まとめ

本章では、今後の課題について述べる。

本研究では、他者の感情の推測の実装を行った。また、外部 から与えられた文から、感情を生起する人物、イベントの主体 となる人物、イベント、信念となる感情を抽出し、感情生成、 推測の部分に与える信念として構成する構文解析プログラムの 実装を行った。

構文解析プログラムによる信念の抽出については、長期的に は、人間による入力文の調整を必要としない方向を目指すこと が必要であるが、それ以外の課題を述べる。まず、現段階では 『ポチは~した』といった、主語の存在する文でのみの信念生 成となっているが、今後、より人間らしい感情を生起するため に、会話を取り入れた感情生起を目指す必要があると考えられ る。そのため、主語なしの文において主語を補った信念の生成 を行うよう実装を改良することが課題である。また、信念の中 でも、イベント発生のために努力する、イベントが発生するこ とが賞賛される、などの文の中からの抽出が困難である特定の 信念については、エージェント自身が初期信念として所持する ことで対処しているが、初期信念として所持するだけでなく、 イベント発生や環境の変化により、新たに生成することも可能 であるべきであると考えられる。しかし、現段階ではこれらの 信念の生成は行われていないため、今後はそれらの信念を文 脈から判断、抽出するよう実装を改良することも課題である。 これらに加え、4章で述べた通り、より明確な感情生起を行う ために細分化した事象の抽出を行うことも目指す。

- [Adam 09] Carole Adam and Andreas Herzig, Dominique Longin: A logical formalization of OCC theory of emotions, Synthese, Vol.168, No.2, pp.201-248 (2009).
- [OCC 88] A. Ortony, G. L. Clore, A. Collins: The Congnitive Structure of Emotions, Cambridge University Press (1988).
- [BDI 99] Anand S. Rao, Munindar P. Singh, Michael P. Georgeff: Formal Methods in DAI: Logic-Based Representation and Reasoning, Massachusetts Institute of Technology (1999).
- [Jason 07] Rafael H. Bordini, Jomi Fred Hübner, Michael Wooldridge: Programming MultiAgent Systems in AgentSpeak using Jason, John Wiley & Sons (2007).
- [今井 18] 今井那緒: OCC theory に基づく感情表現と時間経 過に関する論理モデル, 2017 年度修士論文, 奈良女子大 学大学院人間文化研究科情報科学専攻 (2018).
- [浅井 18] 浅井沙良:エージェントの感情生起について-新た な感情の追加-,2017 年度卒業論文,奈良女子大学生活環 境学部情報衣環境学科生活情報通信科学コース (2018).
- [堀宮 12] 堀宮ありさ, 坂野遼平, 佐藤晴彦, 小山聡, 栗原正仁, 沼澤政信: Twitter における発話者へのリプライを用いた ユーザ感情推定手法, Proceedings of DEIM 2012 (2012).
- [遠藤 06] 遠藤大介, 齋藤真実, 山本和英:係り受け関係を利用 した感情生起表現の抽出, 言語処理学会第 12 回年次大会 発表論文集, pp.947-950, (2006).
- [Tang 14] Tang Ba Nhat, 目良和也 黒澤義明 竹澤寿幸: 音声 に含まれる感情を考慮した自然言語対話システム, Proceedings of Human-Agent Interaction Symposium 2014 (2014).
- [石川 18] 石川葉子,水上雅博,吉野幸一郎, Sakti Sakriani,鈴 木優,中村哲:感情表現を用いた説得対話システム,人工 知能学会論文誌, Vol. 33, No. 1, pp. DSH-B\_1-9 (2018).
- [筒井 77] 筒井依子 (作), 林明子 (絵): はじめてのおつかい, こ どものとも傑作集, 福音館書店 (1977).

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

[3L3-OS-22a] 創作者と人工知能が創る創作の未来(1) 上野 未貴(豊橋技術科学大学)、森 直樹(大阪府立大学)、はたなか たいち((株)クリエイターズインパック) Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room L (203+204 Small meeting rooms) [3L3-OS-22a-01] (Invited talk) The Future of Animation Industry Drawn by Creators and Artificial Intelligence OTaichi Hatanaka<sup>1</sup> (1. Creators in Pack Inc.) 1:50 PM - 2:10 PM [3L3-OS-22a-02] A Proposal of a Mathematical Story Generation Method Based on Hero's Journey Onoguchi katsuhiro<sup>1</sup> (1. comic artist) 2:10 PM - 2:30 PM [3L3-OS-22a-03] Narrative Structure Analysis Punchlines of SF Genre within the Flash Fiction of Shinichi Hoshi OShuuhei Toyosawa<sup>1</sup>, Hajime Murai<sup>1</sup> (1. Future University Hakodate) 2:30 PM - 2:50 PM [3L3-OS-22a-04] Story Creation System based on Sentence Similarity for Supporting Contents Creation OHaruka Takahashi<sup>1</sup>, Miki Ueno<sup>1</sup>, Hitoshi Isahara<sup>1</sup> (1. Toyohashi University of Technology) 2:50 PM - 3:10 PM [3L3-OS-22a-05] Classification method for four-scene comics based on Creative Viewpoint ONaoki Mori<sup>1</sup> (1. Osaka Prefecture University) 3:10 PM - 3:30 PM
# 創作者と人工知能が描くアニメ業界の未来

The Future of Animation Industry Drawn by Creators and Artificial Intelligence

はたなか たいち Hatanaka Taichi

クリエイターズインパック Creators in Pack Inc.

Recently, the researches of artificial intelligence(AI) have been developed remarkably using the deep learning. In those fields, the anime is one of the most interesting and difficult research target. On the other hand, from the viewpoint of the animation industry, AI is strongly expected to help and improve the situation of creating animation. In this lecture, I show the current problems of the animation industry and the possibility of artificial intelligence in animation studio with looking to the future of the animation.

# 1. はじめに

近年のアニメブームにより,日本国内だけでも年間 100 本 以上のアニメが制作されている.それにより,アニメのクオリ ティーは進歩を遂げており,1本あたりにかかる制作費や制作 時間も上昇傾向にある.一方で,アニメを作る際の出資額がそ れに伴っておらず,制作会社の金銭的負担が増加している.そ のため,制作会社が経営破綻を起こすことや,アニメに携わる 人間の低賃金化が問題になっている.

一方,近年,ディープラーニングの飛躍的な発展を背景とし て,人工知能 (Artificial Intelligence: AI) が社会を変える基 盤技術として注目を集めている.しかしながら,アニメや漫画 など高度な創作現場への AI の適用はそれほど容易ではない. これは,一つにはやはり AI が最先端の現場で活躍する創作者 に比べると『創作』という観点ではまだ及ばないこと,使いこ なせば優れたツールなのだが初期学習コストが大きいことなど が挙げられる.

そこで、本発表では人工知能をどのようにアニメ業界に導入していくのか、その際に問題となることはどのようなことなのか、また、創作と人工知能という視点からアニメ業界を俯瞰し、アニメの未来について述べる予定である.

# 2. 日本におけるアニメ業界の現状

近年,TVアニメは人気を増しており,年間100本以上のタ イトルのアニメが「せいさく」されている.アニメには,出資 を集めるための「製作」と,実際の作業をする「制作」の2種 類「せいさく」が混在している.出資を集めるための製作を行 う組織のことを製作委員会と呼ばれている.アニメに求められ るクオリティーは年々増しており,制作にかかるコストも増し ている.しかし,製作委員会の出資額にはほとんど変化がなく, 制作現場は低賃金でのアニメ制作を余儀なくされている.そ れにより,アニメ現場の低賃金問題は社会問題となっている. しかし,アニメ現場にも問題は多くある.アニメの現場では, 古くから続く,アナログの手法にとらわれている部分が多く, 効率化が行い切れていない.アニメの制作工程には大きく分け て,絵コンテ,原画,演出,作画監督,動画,仕上げ,撮影と いう工程が存在する.この工程の中で,アニメーターが担当す

連絡先: はたなか たいち, クリエイターズインパック, t.hatanaka@creatorsinpack.com る,絵コンテ,原画,演出,作画監督,動画という工程では紙 を使ったアナログ作業が主流となっている.アナログでの作業 の場合,完成した素材のやり取りなどを郵送,もしくは制作進 行が車で運ぶ,などの作業が発生し,コストのロスが多く発生 している.それぞれの工程を効率化していくために,様々な見 地が必要と思われるが,著作権などの問題もあり,まだまだ課 題が多いのが現状である.

# 3. アニメ制作のデジタル化

アニメ制作の多くは、アナログの紙に対する作業によって行 われいるが、近年、ツールやソフトの発達により、デジタルで のアニメ制作が進んでいる.液晶タブレットや、イラストソフ トの多機能化により、アナログ作業に近づいた感覚での作業を 実現化し始めている.しかし、デジタル化にはいくつか問題が ある.まずは、アニメーターがアナログ作業に慣れてしまって いることである.アニメーターの多くは、アナログで絵を描く ということになれてしまっており, デジタルに対しての抵抗感 が大きい. それ以外にもコストの問題がある. ツールとソフト の両方を用意するためには、最低でも1セットあたり20万円 ほどのコストがかかってしまうため、制作現場への負担が大き い. 上記で記載した以外の問題も多くあるが、もちろんデジタ ル化にはメリットも存在する.アナログでかかっていた際の, 輸送やスキャンなどでかかっていた人的コストを減らすことが 出来たり, 描き直しが用意になることで, アニメーターが描く 絵の精度が上がったりなどのメリットがある.他にも,近年の アニメでは 3DCG と手書きアニメの融合なども多くなってお り、デジタルでの作業によって、3DCGとの親和性が上がり、 より緻密なアニメ作りを行うことが出来る. そのため, デジタ ル化には多くの問題があるが、その問題を解決しながら、導入 を進める現場が増え始めている.しかし,業界全体の普及率を 考えた際には、まだ20%ほどかと思われる.

# 4. アニメにおける絵コンテ

アニメにおける絵コンテとは、シナリオを元に作成するアニ メの設計図である。絵コンテにはカメラがどのように動くか、 どのキャラクターがどのような動きをするか、どのような会話 が発生するか、などの画面を構成する情報が多く入っている。 そのため、アニメの制作作業に入る前に絵コンテを解析し、物 量を事前に把握することで、より効率的に作業を進めることが 出来ると考えられる.また,絵コンテの解析を進めることで, V コンテと呼ばれる絵コンテから生成される映像の自動生成 を最終的な目的とする.V コンテはアニメに音をつけるアフレ コ工程で使用する重要な中間生成物でありながらその生成には 多大な手間がかかる.この部分を自動化できればアニメ制作に 掛かる費用の大幅な削減が可能となる.現在,このアニメにお ける絵コンテ部分が人工知能技術の応用が一番望まれている.

# 5. まとめ

本稿では、創作者と人工知能が描くアニメ業界の未来についてアニメ業界の現状を踏まえながら示した。人工知能の発展が、アニメ業界をどのように変えていくのかを予想するのは極めて困難であるが、少なくとも多くの人工知能技術がアニメ業界に導入され、アニメの創作に大きなパラダイムシフトが訪れることは確実であるように思われる。アニメの創作者、人工知能研究者、そしてコンテンツを楽しむユーザすべてにとって実りある未来が訪れることを願ってやまない。

ヒーローズ・ジャーニーに基づいた関数による物語生成手法の提案 A Proposal of a Mathematical Story Generation Method Based on Hero's Journey

> 野口 克洋<sup>\*1</sup> Katsuhiro Noguchi

> > <sup>\*1</sup> 漫画家 Comic Artist

中矢 誠<sup>\*2</sup> Makoto Nakaya <sup>\*2</sup>株式会社アキュトラス

Agutras Inc.

We propose a story generation method that is able to run on machine. It is based on Monomyth known as Hero's Journey by mythologist Joseph Campbell. We reveal event effect and strength at specific timing on the story mathematically by trigonometric function. We confirmed indication of a part of archetype on Monomyth and considered examination of effectiveness of our method.

# 1. はじめに

コンピュータコンテンツの成立以後,エンターテイメント分野 ではインタラクティブコンテンツの需要が増大し続けており,長 年,物語の機械的生成が試みられてきた.古来より物語は,エ ンターテイメント分野以外にも,マーケティングなどの実用分野 においても用いられており,物語を個人や時々に合わせて動的 に生成する技術の確立は,広い応用領域をもつ研究分野と言 える.物語の機械的生成においては,小説等を学習データとし た機械学習による生成手法や,類型化したイベントを条件分岐 などで制御していく手法などが知られている.しかし,物語は長 大化しやすい性質と形態の多様性を持ち,データセットや出力 が離散的である.そのため,既存手法では全体の構成を踏まえ ての実用レベルでの生成が困難である場合が少なくない.

先行研究として福田らは、Multi-Agent System による物語生 成を提案している[1].物語上のイベント発生をきっかけとして仮 想的なフィールドとランダムウォークを用いることで、イベント発 生のタイミングを決定している.これにより、情報密度の偏りを担 保し、読者がある程度の恣意性を感じうる物語の生成に成功し ている.しかし、この手法では、イベントが起きるタイミングが、物 語全体の構成からみて適切であるかや、起きたイベントの影響 が適切な強度であるかが考慮されていない.動的な物語の機 械生成の実現には、物語中でのイベントが、物語の構成に対し てどう作用しているのかや、その強度を数理的に扱う手法が必 要となる.その解決策として、物語創作に広く用いられているジ ョーゼフ・キャンベルのヒーローズ・ジャーニーに着目した.

#### 2. 物語の構造

神話学者ジョーゼフ・キャンベルは、世界中の多くの民話や 神話に、共通の構造があることを発見し、単一神話論と名付け た[2]. この構造をジョーゼフ・キャンベルは図 1 のように示して いる.単一神話論は、主人公が日常から何らかの非日常に遷 移し、再び日常へ帰還する通過儀礼の構造をもつ.通過儀礼 の構造は、長い物語の中で挿話などの形でも現れ、結果として 単一神話論の物語構造は、一種のフラクタル構造をなす場合 がある.また、日常と非日常は、物理的空間の移動のみならず、 同一地点での状況変化や心理状態の変化として表現されること もあり、実際の物語では様々な概念の重合わせ構造を持つこと が多い.

連絡先:野口克洋,漫画家,uo\_kanazuhi@hotmail.com

これは,映画スターウォーズの脚本の元となり,映画の成功を 経て,ヒーローズ・ジャーニーとして広まった[3]. 今日では,ハリ ウッド映画の脚本創作論など,多くの創作者にとっての物語創 作の基礎となっている. 単一神話論に頻出のイベントやキャラク タについては,神話論や創作論,心理学の研究者達による類 型化が行われている.

# 3. 提案手法

本研究では、単一神話論に基づく物語創作を、計算機上で 再現する手法を提案する.単一神話論は、図 1 で示したとおり、 円環状の図をもって、周期運動として説明されるため、物語中 でのイベントの作用や強度を、三角関数を用いて数理的に扱っ た.実際の物語構造では、多層的に構造が重なりあっている[4] が、本論では、単一神話論に基づき、1 つの主要な構造を物語 として扱う.

# 3.1 主人公の遷移関数と状況関数

物語上での主人公の位置を, 遷移関数P(t)とし, 式 1 で表 す. tは, 物語上の時間軸上のある点を表す. Pの値によって, 単一神話論における日常と非日常を式 2 で定義する. 物語上 の時間 t でおきているイベントによって, 主人公が受ける影響の 強さと方向はPを微分して得られるP'で求まる(式 3). 遷移と状 況の様子を図 2 に示す.

$$P = -\cos(t) \quad (1)$$

$$P' = \sin(t) \quad (3)$$

#### 3.2 提案手法の有効性の検討

ジョーゼフ・キャンベルの作図が数理的に正しいかどうかは証明が困難であるため、提案手法においても、単一神話論における物語の類型や特徴が表出するかどうかを確認し、有効性を検討した.

通常,物語創作者は,執筆中の物語のあるシーンにおいて, その前後の流れをある程度把握した上で物語を創作している. このため,物語中のイベント上でアドリブなどにより,物語に乱れ が生じた場合でも,前後の流れから大きく逸れていないと創作 者が考える場合には、その乱れを許容しうる. 逆に、物語の流 れから大きく逸脱せず、状況が許容範囲内にあるとき、創作者 は物語上の大きなイベントを必要としないとも言える.

提案手法に基づき,状況P'をt軸方向に±σだけ平行移動した値の差を許容値P'allowとする.許容範囲を図3で図示した. 主人公のP'が許容値から逸脱した場合,物語上のイベントを発生させてP'を補正し,主人公が遷移関数をなぞるよう実装する. このとき, P = 0のとき,つまり日常と非日常の境界線上において,  $P'_{allow}$ は最小値になる.  $P, P' E'_{allow}$ の関係を図4に示す.この結果, P = 0を目前として表出するイベントは,発生頻度が高く,主人公に与える影響の少ないものとなる.これは,単一神話論におけるゲートキーパーというキャラクタ類型の特徴に符合する.

# 4. まとめと今後の課題

本研究では、神話学者ジョーゼフ・キャンベルのヒーローズ・ ジャーニーとして知られる単一神話論に基づく物語創作を、計 算機上で再現する手法を提案した.物語中での任意の地点に おけるイベントの作用や強度を、三角関数を用いて数理的に求 めた.単一神話論における物語の類型の一部について表出を 確認し、提案手法の有効性の検討を行った.

現時点では、提案手法と単一神話論に致命的な齟齬は見つ かっていないが、ゲートキーパー以外の類型が表出する条件を 検証できていない.他のキャラクタやイベントの類型が、必ずし も数学的性質を持っているかは定かではないものの、今後の研 究ではキャンベルら神話学者や物語の捜索にかかわる研究を 深く理解し、その背景にある数学的性質をより明らかにしていく ことを目指す.また、物語コンテンツから任意のベクトル量の変 化を時系列順に抽出することができる場合、提案手法の応用で、 物語の状況分析や構造解析が定量的に行える発展可能性が あると考える.そうした発展的研究と共に、今後は文章などの形 で物語生成が行える実装と、手法としての性能評価実験の実施 を目指す.



図1 ヒーローズジャーニーの概念図



図2 主人公の遷移関数と状況関数



図3 状況P'の許容範囲



図4 . P, P'とP'allowの関係

- [1] 福田 清人,森 直樹,松本 啓之亮: 既存小説に依存しない創発 的なストーリーの自動生成に関する考察,第 29 回人工知 能学会 全国大会,301-6in
- [2] ジョーゼフ・キャンベル, 倉田真木, 斎藤静代, 関根光宏: 千の顔 をもつ英雄, ハヤカワ・ノンフィクション文庫, 2015.
- [3] ジョーゼフ・キャンベル,ビル・モイヤーズ,飛田茂雄:神話の力,ハ ヤカワ・ノンフィクション文庫, 2010.
- [4] Yu.ロトマン, 磯谷孝: 文学と文化記号論, 岩波現代選書, 1979.

星新一のショートショートにおける SF ジャンルのオチ構造分析 Narrative Structure Analysis Punchlines of SF Genre within the Flash Fiction of Shinichi Hoshi

> 豊澤修平\*1 Shuuhei Toyosawa

村井源\*1 Murai Hajime

\*1 公立はこだて未来大学 システム情報科学部 Faculty of Systems Information Science, Future University Hakodate

Abstract: This paper aims to analyze the narrative structure leading to punchlines of genre SF within the flash fiction of Shinichi Hoshi, based on classical plot analysis method. This is a process to create plots, and then to write texts for automatic generation of stories. There is a feasibility to generate automatically more natural stories by analyzing narrative structure leading to punchlines. This paper focuses on the categories of "space", "medicine", "automatic device, invention, computer" and "robot" stories from science fiction genre, which is a representative genre of Shinichi. By utilizing the result of unification and abstraction of the patterns of the theme and conditions / precondition, it would be possible to generate automatically a more natural story like Hoshi.

# 1. はじめに

近年,人工知能分野では物語の自動生成が一つの目標とし て挙げられており,例えば松原仁らが星新一賞の一次選考を通 過したことなどが注目を浴びた[松原 2013].この「きまぐれ人工 知能プロジェクト作家ですのよ」では星新一のショートショートの ようなユーモアのきいたオチのある短い物語を自動生成する人 工知能の作成を目標としている.この目標を達成するためには 物語の基本となるプロットの作成を行い,そのプロットをもとに文 章化をする必要がある.しかし,意味のつながる文章の自動生 成をするだけではなく,星らしい人間の無知や努力を皮肉る世 界観を表現する必要もある.このためには星新一のショートショ ートのプロットの作成段階で独特の世界観を表すオチが生成さ れなければならない.

以上の問題を解決するためには、物語論の方法を用いた計量的な分析が有効であると考える.文学作品を計量的に分析 することで、主観性の強い評論に対して、客観的な知見を得る 試みが行われてきている.例えば、工藤彰らは村上春樹の作品 について統計的分析をもとに作風の変化を把握することに成功 した[工藤 2011].

また,文章の自動生成については松山諒平らによるテーマに 基づいた短編の自動生成[松山 2013]や,豊澤らによる推理小 説プロットを自動生成し映像化する統合的インタラクティブシス テムの開発と評価[2018 豊澤 A]などが挙げられる.

これらの自動生成を行う上では良質なプロットやオチのデー タを用意する必要があるが、星新一の多くの作品では短い物語 の中に逆転のオチを付けることで現代まで読者を惹きつけてお り、自動生成の基礎データとして活用可能な良質で分析容易な 作品群と言える.また、一人の作家が 1000 を超える作品を書き 上げているため物語のプロットやオチの抽出を計量的に行いや すいという点からも科学的な分析に適していると考えられる.星 新一のショートショートに関しては計量的な物語構造の分析[佐 藤 2009],落語の類型である4分類による分類分析[永田 1993], 星新一の物語の基本パターンの抽出[村井 2011]がすでになさ れている.

しかし, 各ジャンルにおける固有の詳細な物語パターンの抽

出とオチに至るメカニズムは現在のところ分析がされていない. しかし、物語の精度良い自動生成を実現するためにはより詳細 で網羅的な物語パターンの分析・収集は不可欠である.

本研究では古典的なプロット分析[プロップ 1987]を用い、ショ ートショート SF ジャンルにおけるシンプルな物語のオチの構造 のパターン化、及び必要条件と前提条件の発見を目的とする.

基本的な物語のミクロパターンを収集し、それらの種類や物 語要素の交換可能条件などを特定することで、より自然な物語 の自動生成が可能になると期待される.また、これらのオチのパ ターンを結合することまで可能になればショートショートのような 短編だけではなく、長編のような物語の自動生成も視野に入る と考えられる.

#### 2. 対象

分析に用いる星新一のショートショート作品には,新潮社の 星新一全集収録を用いる[星 1998].1000編以上存在するが大 さく三部に分けられる[村井 2011].第一期は多くの読者が想定 する星新一らしい逆転オチの作品群であるが,第二期は多重 オチの込み入った構造になっており,第三期は民話を志向した 別方向の物語となっている.

星新一の作品において特徴的なジャンルとして SF が挙げられる. 星の SF 作品は「宇宙」や「薬」、「ロボット」、「自動装置・発明・コンピュータ」の4種類のテーマに大別できる. また、SF ジャンルとは別に代表的なテーマとして「悪魔・魔人」も存在する. 加えて計量的な物語構造の分析[村井 2011]において自動分類された作品中で最も話数が多い「強盗・泥棒・詐欺・囚人」も挙げられるであろう.

本研究ではテーマの自動分類の結果を手動で修正・拡張した ものを利用し,上記の 4 つのテーマの条件の元で分類された SF ジャンルの 304 作品(表 1)が分析対象である.

| 表1 | 対象テーマと作品数 |
|----|-----------|
|----|-----------|

|     | テーマ         | 作品数 |
|-----|-------------|-----|
|     | 宇宙          | 124 |
|     | 薬           | 55  |
| 自動装 | 置・発明・コンピュータ | 76  |
|     | ロボット        | 49  |

連絡先:豊澤修平,公立はこだて未来大学システム情報科学 部,b1015124@fun.ac.jp.

# 3. 手法

主要 SF4 テーマにおける各作品にプロット分析の手法を用いて作品からプロットを抜き出した.その後、一度プロットを類義語でグループ化し抽象化を行った.その上で物語のオチにつながる要素を選定した.この際に現れるオチの構造に着目し、類似する作品が3作品以上あるものを物語パターンとして抽出した.また、明確なパターンとして現れないが部分的に類似する箇所が複数存在する場合もパターンとして抽出を行った.

加えて、物語パターン抽出に加えてオチに関する必要条件と 前提条件を抽出した.本論文における必要条件とはオチを成 立させているテキスト中に記述されていない暗黙的な常識的な 知識である.また、前提条件はオチを成立させている動作の主 体が行わなければならない行為や、作中における世界の常識 である.必要条件と前提条件を特定することによって、それらの 条件を満たす別の要素とオチを交換可能となる条件を明示化 することを目的としている.このようなオチの必要条件を特定し てデータとして記述しておくことによって、本研究の成果に合わ せて一般的なオチのデータを別に準備することで異なるオチの 物語の生成が可能になると考えられる.

### 4. 結果

図 1~図 14 中において、パターン化した際の要素を左から 順に物語における時系列順に並べ、縦にそのパターンにおけ る分岐の可能性を並列で表している.また、灰色のボックスが要 素内の変更可能部分であり、それ以外の要素は固定化された 要素になっている.

「宇宙」124 作品のうち 100 作品は以下の 6 パターンに分類 された.

- 遭遇, 59 個 (図 1)
- ・ 贈り物、17個(図2)
- 沈黙・遭難,8個(図3)
- 間抜けオチ,7個(図4)
- 惑星,7個(図5)
- カニバリズム,4個(図6)

ただし個数は 1 つの作品に対して複数のパターンが存在す る場合含まれるため,実際の作品数より多くなる.

遭遇パターン(図 1)は人間と宇宙人が遭遇することでオチが 発生するパターンである.テーマが「宇宙」の中で最も多くの作 品が該当する.遭遇パターンでは人間視点と宇宙人視点に分 類することが可能である.人間視点では宇宙人と遭遇するタイミ ングでオチが変化する.可変事項の前に遭遇する場合では非 視覚的事実が発覚し、後の場合では視覚的なものがオチにつ ながる.宇宙人視点であった場合では人間以外(例えば貧乏神 や幽霊などと)と遭遇することでオチが変化する.どちらの場合 でも宇宙人の常識や認知的なずれがオチとなることが多い.

贈り物パターン(図 2)では贈与物の内容でオチが変化する. 贈与物が兵器などの悪いものであった場合は多くが与えられた ものが起動するのがオチとなる.また贈与物がテクノロジーなど の良いものであったとしても,何らかの理由で獲得できなくなる, 破壊するなどしてしまう.まれに贈与物が良いものであるときに は獲得することもある.

沈黙・遭難パターン(図 3)は大まかには遭難者視点と救出者 視点の 2 つに分けることができる.また,遭難者視点において オチの一部として惑星に不時着できずに死亡のオチになるもの が入る.

間抜けオチパターン(図 4)は古典落語におけるオチの一つ であり、深刻そうな出来事が起きるが深刻ではないことで終わる のがオチとなるパターンである.このパターンにおいては深刻そ うな出来事という曖昧な要素が引き金である.

惑星パターン(図 5)では惑星自体がオチにつながっているものである.また, 亜種パターンとして都市自体がオチにつながるものも部分的に類似する作品としてパターンに含めている.

カニバリズムパターン(図 6)では初期状態には具体的に決まった状態が存在せず、オチにおいては人間を肉として認識または捕食する暗示で終わる. 宇宙物語では宇宙人は人間とは認識が異なるため人肉食をタブーとしない存在として描かれる.

「薬」55作品うち38作品は以下の2パターンに分類された.

- 薬効果明示, 30 個 (図 7)
- 薬効果不明, 12 個 (図 8)

薬効果明示パターン(図 7)は多くが薬を使用した結果により オチが発生する.多くは薬の効果が発揮されることで別の事実 が発覚し、それがオチにつながる.または期待していた薬の効 果とは別の新たな効果が発揮されることでオチにつながる場合 に分けられる.加えて薬が誤用される場合にはそれが原因で混 乱が拡大されてオチにつながる.

薬効果不明パターン(図 8)は薬の効果が不明で効果が発揮 されることでオチにつながるパターンである.効果が明確なパタ ーンと異なり初期条件として強盗が挙げられるのが特徴的であ る.薬の効果がわからない状態にすることで効果の発覚と効果 による状態の悪化がオチにつながっている[豊澤 2018B].

「自動装置・発明・コンピュータ」76 作品のうち 66 作品が 3 パ ターンに分類された.

- 装置効果明示, 33 個 (図 9)
- 装置効果不明, 14 個 (図 10)
- 自動装置,11 個(図11)
- コンピュータ,7個(図12)

装置効果明示パターン(図 9)は装置を利用した結果に よりオチが発生する.多くは装置を利用したために失敗す るか,別の効果や目的が発覚することがオチにつながる.

装置効果不明パターン(図10)は効果不明で効果が発覚 することか,発覚した効果によりオチが発生する.

自動装置パターンでは自動装置は生活に欠かせないもの として存在する.従って装置が停止することによる不幸か 快適すぎるために退屈になるオチになる.

コンピュータパターン(図12)では、コンピュータはミ スをすることがなく支配または管理しているものとして存 在する.そして人、間側が支配管理されていることに対し て肯定的であればその管理された世界で幸福になるという. 「ロボット」49 作品のうち 41 作品が 3 パターンに分類された.

- 正体ロボット, 14 個 (図 13)
- ロボットの効果, 12 個 (図 14)
- 他テーマのパターン,22個

「ロボット」においては他テーマのパターンが多くみられた.こ れは「自動装置・発明・コンピュータ」と「宇宙」における既存の パターンが適用できたためである.主体としての役割も併せ持 つ装置としてロボットが存在していると思われる.また,ロボットの 効果というのはロボットにおける効果や能力といったものを暗黙 的に利用したパターンである.ショートショートにおけるロボットと は命や感情が存在せず仕事をする存在として描かれており、オ チとしてこれらの前提を崩したものがパターンとし現れた.

また「ロボット」には、他のテーマのパターンが適用可能な作品がいくつか見られた.

また,各テーマのパターン適用の必要条件と前提条件を 304 作品から同様に抽出した.すべての作品に対して複数個の条 件が発見されたため,本論文では「ロボット」における必要条件 と前提条件の結果の一部のみを表[1, 2]に示す.



図5惑星パターン

·調査

·惑星発見





図 14 ロボット効果

表2「ロボット」における必要条件

|    | -          |
|----|------------|
| 必  | 要条件        |
| 口7 | ボットは命がない   |
| 口7 | ボットは痛覚がない  |
| 口7 | ボットは複製可能   |
| 口7 | ボットは生物ではない |
| 口7 | ボットは合理的    |

表3「ロボット」における前提条件

| 前提条件           |  |
|----------------|--|
| 人と見分けがつかないロボット |  |
| 社会に普及しているロボット  |  |
| 頑丈なロボット        |  |
| 多機能ロボット        |  |
| 隔離された場所        |  |

# 5. 考察

各テーマにおいて特定のパターンを抽出することが可能であった.加えてパターンにおいて変更可能な箇所が存在し、変更可能な箇所への要素を代入可能であると考えらえる.これらの 各要素の組み合わせによって固定のオチやパターンの分岐が 生じることが示唆される.

「宇宙」の「遭遇」、「薬」の「薬効果明示」と「薬効果不明」パタ ーン、「装置」の「装置効果明示」と「装置効果不明」パターン、 「ロボット」の「正体ロボット」パターンには共通性があると考えら れる.これらは基本的に効果が判明しているか不明かの2つの パターンに分類することができる.効果が明示の場合では他の 効果が判明するか、判明している効果のせいで不幸になるかに 大別できる.また、効果が不明である場合では効果がわかること か、わかったことによる結果で不幸につながっている.いずれの パターンにおいてもオチは人間の無力さ無知さによって努力が 無駄になることを皮肉る星新一らしい形になっている.

また,あるテーマの主要なパターンが他のテーマの作品のパ ターンとしても利用されるものがいくつか見られた.これは世界 観としてテーマが利用されているが,オチにはそのテーマが関 与しない場合であると考えられる.加えて,「宇宙」における「贈 り物」,「間抜けオチ」,「カニバリズム」のような宇宙という世界観 を利用しなくても利用できるようなパターンについては,その世 界観を取り入れることで起こりうるオチの条件を変えるための舞 台設定として利用されていると考えられる.これらに加えて「ロボ ット」にあるようなものは上位概念として特殊な装置があり,それ の要素として主体性のある装置としてロボットという条件が加えら れたために他のテーマのパターンと共通性が高いと考えられる.

# 6. おわりに

星新一のショートショートにおける 4 つ SF ジャンル 304 作品 についてオチの構造の分析を行った.「宇宙」は 124 作品中 100 作品を 6 種類にパターン化可能であった.「薬」は 55 作品 うち 38 作品を 2 種類のパターンに分類することができた.「自 動装置・発明・コンピュータ」76 作品のうち 66 作品を 3 種類の パターンに分類することができた. また今回分析対象テーマを SF ジャンルに限定した.しかし 物語の自動生成においては汎用的な物語パターンが必要であ るため,今回分析を行った以外のジャンル分析も行う必要があ る.従って,作品数が最も多い「強盗・泥棒・詐欺・囚人」の分 析も行う必要があると考える.

本研究で抽出した必要条件と前提条件は自然言語で書かれ ておりまだ統一的な記述にはなっていない. 今後これらにオチ のパターンと同様に用語の統一と抽象化を行う必要がある. 加 えて, 各テーマにおける条件を他のテーマパターンに適用可能 かまでデータ化することができればより網羅的で多種多様な物 語プロットの自動生成が可能になると考えられる.

本論文では物語の抽象化及びオチのパターン化などを単独 分析者で行っており客観性が保証されていない.従って,統計 的な手法にのっとり第三者によるパターン化の一致度の検証を していきたいと考える.

これらの作品分析とパターン化及び必要条件と前提条件の 抽出ができれば、より星新一らしい物語プロットの自動生成が可 能になると考えられる.

- [工藤 2011] 工藤彰,村井源, 徃住彰文:"計量分析による村 上春樹長篇の関係性と歴史的変遷",情報知識学会誌, Vol21, No1, pp18-36, 2011.
- [佐藤 2009] 佐藤知恵,村井源,徃住彰文:"文学作品群の特 徴的語彙と概念カテゴリーの抽出-星新一のショートショート の計量分析-",情報知識学会誌, Vol.19, No.2, 2009.
- [松原 2013] 松原仁, 佐藤理史, 赤石美奈, 角薫, 迎山和司, 中 島秀之, 瀬名秀明, 村井源, 大塚裕子: "コンピュータに星 新一のようなショートショートを創作させる試み", The 27th Annul Conference of Japanese Society for Artificial Intelligence, 2013, 2D1-1.
- [松山 2018] 松山諒平,佐藤理史,松崎拓也: "テーマに基づ く短編小説自動生成システム",言語処理学会 第24回年 次大会発表論文集(2018年3月)
- [村井 2011] 村井 源,松本 斉子,佐藤 知恵,徃住 彰文: "物語 構造の計量分析に向けて-星新一のショートショートの物語 構造の特徴-",情報知識学会誌, Vol.21, No.1, pp.6-17, 2011.
- [豊澤 2018A] 豊澤修平, 工藤はるか, 石田晃大遠, 藤史央里, 川瀬稜人, 菊池亮太, 工藤健太郎, 栗原将風, 櫻井健太郎, 佐藤好高, 玉置秀基, 根本裕基, 原科充快, 久野露羽, 平 田郁織, 村井源, 椿本弥生, 角薫, 松原 仁"推理小説プロ ットを自動生成し映像化する統合的インタラクティブシステム の開発と評価", 研究報告人文科学とコンピュータ, Vol.13, pp1-5, 2018-01-20.
- [豊澤 2018B] 豊澤修平,村井源:"星新一のショートショートの オチの構造分析",情報処理学会シンポジウムシリーズ, Vol.2018. No.1, pp. 75-82. 2018.
- [長田 1993] 長田貴誉子:"星新一の作品分類と分析試論 -- ○○一編ショート・ショート群を考える", 国文学会誌, Vol.22, pp. 76-115,1993.
- [星 1998] 星新一:「星新一ショートショート 1001」, 新潮社, 1998.
- [プロップ 1987] ウラジーミル・プロップ(北岡誠司,福田 美智代 訳):「昔話の形態学」,水声社,1987.

# 創作支援を目的とした類似度調節による ストーリー生成システムの構築

Story Creation System based on Sentence Similarity for Supporting Contents Creation

高橋 遼\*1 Haruka Takahashi

井佐原 均 上野 未貴 Isahara Hitoshi

\*1豊橋技術科学大学

Toyohashi University of Technology

Miki Ueno

In recent years, there are lots of researches to generate creations such as comics and novels by computing methods. Especially, the orders of sentences is very important for the quality of stories. Thus, the aim of the research is to construct story creation system in order to consider the flow of the story based on the sentence similarity.

#### 1. はじめに

近年,計算機の性能の向上によるニューラルネットワークを 用いた学習が盛んである. その一つとして, 漫画や小説, アニ メーションといった人間の創作物を計算機によって理解したり 生成する研究が広がりつつある [1]. これらの研究から、人間 が創作活動を行う際の補助を行うことも可能であると考えら れる.

創作者はテキスト、画像や音声などの情報を工夫して組合せ てストーリーを表現する [2]. ストーリーは創作物の根幹であ り、カテゴリ、評価や独自性に大きく影響する. そのため、ス トーリーを作成する過程を計算機上で処理することは挑戦的な 課題である.

本研究では、読者が違和感を感じにくいストーリー構成の 分析や, 文の順序を変更して新しい作品の生成へ応用できるか 調べるため、物語のストーリー自動生成システムを構築する.

#### 2. 先行研究

#### ストーリー創作支援 2.1

ストーリー創作支援の従来研究としては、質問集合とグラフ に基づく物語全体の流れを管理可能な創作支援システムの提案 [3] がある.この研究では、創作支援システムを作成し、創作 支援システムへの入力から創作過程の解析と創作支援をする. あらかじめ準備されたカテゴリから創作者が今回考案するス トーリーに適したものを選び、フォームを埋める形式でストー リープロットを作成することができる.しかし,ストーリーの 生成は創作者によるもので,計算機が自動生成はしていない.

#### 2.2 文自動生成

文の自動生成の従来の研究としては、単語の分散表現を用 いた意味予測に基づく雑談応答生成 [4] がある. この研究では Recurrent Neural Network(RNN) を用いて, Twitter 上の会 話文を学習させ、ある会話文の入力に対して、適切な応答文の 作成を行っている. 従来の One-hot 表現を用いた方法と違い, 単語の分散表現を入力としている. 従来の方法よりも多様性の 面では向上したが、適切性に関しては大きく向上しなかった. また, 文法的な誤りがある文も生成された.

この研究は、1 文に対して1 文を返す対話文を対象とした ものであり、ストーリーといった複数文の出力には対応してい ない.

# 3. ストーリー生成システム

本研究では分散表現を利用し, 文間の類似度に基づくストー リー生成システムを構築する.

#### 3.1 コーパスの作成

コーパスには、3つのデータを用いる.用いたデータを以下 に示す.

- 1. Manga109 の 4 コマ漫画のセリフデータ (5145 文)
- 2. 青空文庫のあらすじ(7439文)
- 3. インターネット上の小説投稿サイトから集めた文章 (383494 文)

本稿ではこの中でも最もデータ数が多く、結果が良かった小説 投稿サイトの文章を利用する.「インターネット上の小説投稿 サイト」のデータはインターネットからクローリングして収集 した.これらを句点で分割し、1 文区切りにしたものを文集合 として利用する.

# 3.2 Paragraph Veector のモデル作成

Paragraph Vector[5] のモデルを作成する. Paragraph Vector とは文を分散表現に変換する技術である.分散表現に変換 することで、コサイン類似度などを用いて、文同士の類似度を 計算できるようになる.

Paragraph Vector の学習に使用する文から単語を抽出する. 文に単純な分かち書きしたものを学習に使用すると, 文の意味 への影響が小さい助詞や助動詞, 記号等も学習に使用される. そこで、形態素解析をし、文の意味に関連しにくいと考えられ る品詞の単語を除去する. 形態素解析には MeCab を用いた. また, MeCab の辞書には NAIST Japanese Dictionary<sup>\*1</sup> を 用いる. 今回学習に使用する品詞は名詞, 動詞, 形容詞, 副詞, 連 体詞である.

連絡先: 高橋 遼, 豊橋技術科学大学, 〒 441-8580 愛知県豊 橋市天伯町雲雀ケ丘1-1, takahashi@lang.cs.tut.ac.jp

<sup>\*1</sup> NAIST Japanese Dictionary, http://naist-jdic.osdn.jp/

| The 33rd Annual | Conference | of the Japanese | Society for Ar | tificial Intelligence, | 2019 |
|-----------------|------------|-----------------|----------------|------------------------|------|
|                 | ./         | ./ /            | ~ ./           |                        |      |

| 表 1: Doc2Vec のパラメータ |       |           |       |  |
|---------------------|-------|-----------|-------|--|
| 手法                  | 次元サイズ | 単語の最小登場回数 | エポック数 |  |
| DM-PV               | 100   | 1         | 100   |  |

DM-PV: Distributed Memory Paragraph Vector[6]

#### Route-Creator

Navigate to "/" Navigate to "/draw 技科大生が暇な土曜日を迎える 0.9 0.8 0.7 0.6 0.5 0.4 0.3 0.2 0.2 0.1 0.9 0.8 0.7 0.6 0.5 0.5 0.4 0.3 0.2 0.2 0.9
0.8
0.7
0.6
0.5
0.4
0.3
0.2
0.1 から ドキドキして落ち着かない までの物語 SUBMIT near \*260\* ゴールに対する類似度 0.8 0.6 特點大生が孵な土壤日を迎える 0.4 付き合っていないと、恋していないと、善ち着か だが、嫌なドキドキではな ドキドキしながらソファから立ち上が 0.2 8 75011832 5 ドキドキして蒸ち着 9 図 1: ストーリー生成システムのユーザインタフェース

Paragraph Vector を用いるためには Python 製のソフト ウェアである Gensim<sup>\*2</sup> を用いる. Gensim の中の Paragraph Vector を用いることができるライブラリである Doc2Vec を 用いる. 表1に Doc2Vec のパラメータを示す.

#### 3.3 ルート作成

上述の通り作成したモデルを用いて、ストーリーを作成する. システムの入力はストーリーの「スタートの文 $r_s$ 」と「ゴール の文 $r_g$ 」であり、スタートからゴールに対して、類似度が高 くなるようにストーリーの遷移経路を以下の手順で作成する.

- 1) 空のキュー  $\mathbf{R}_{s}$ を用意する. ゴールの文に最も近い位置に モデル内で存在する文を仮のゴールの文  $r'_{g}$ とする.  $\mathbf{R}_{s}$ に  $r_{s}$ を追加する.
- **R**<sub>s</sub>の末尾の文に対し近傍 n の文を取得し, r'<sub>g</sub> との類似 度の高い順にソートした配列 **A**<sub>s</sub> = {a<sub>1</sub>, a<sub>2</sub>, ..., a<sub>n</sub>} を 作成する.
- 3)  $\mathbf{R}_{s}$  に既存でないという条件を満たす、 $\mathbf{A}_{s}$  のインデック ス番号が最も小さい文 $a_{i}$ を  $\mathbf{R}_{s}$  に追加する.
- A<sub>s</sub> に r'<sub>g</sub> が存在すれば, r'<sub>g</sub> と r<sub>g</sub> を R<sub>s</sub> に追加しルート 作成は終了する.終了しない場合, 2) に戻って処理を繰 り返す.

作成された R<sub>s</sub> がストーリーとなる.

#### 3.4 ユーザインタフェースの実装

本研究は創作支援を目的としており,将来的にユーザが使 用することを想定し,WEBアプリケーションにてストーリー 生成システムの実装を行った.今回,開発に使用した言語は Pythonであり,用いたWEBアプリケーション開発用ライブ ラリは Dash by plotly \*<sup>3</sup>である.図1に作成したシステムの ユーザインタフェースを示す.図1の左上が入力するためのテ キストボックスである.右上の類似度調節機能でストーリー内 の類似度の遷移を決定する.作成されたストーリーは右下に表 示される.左下にはストーリーの類似度の遷移の軌跡がグラフ として表示される.

| 表 2: | 生成されたス | トーリー | -の例 | 1 |
|------|--------|------|-----|---|
|------|--------|------|-----|---|

|   |                  | -     |
|---|------------------|-------|
|   | 文                | 類似度   |
| 0 | 技科大生が暇な土曜日を迎える   | 0.206 |
| 1 | 立ち止まっている暇などない    | 0.316 |
| 2 | 付き合っていないと、恋していない | 0.505 |
|   | と、落ち着かない         |       |
| 3 | だが、嫌なドキドキではない    | 0.537 |
| 4 | ドキドキしながらソファから立ち上 | 0.780 |
|   | がる               |       |
| 5 | ドキドキして落ち着かない     | 1.00  |

表 3: 実験 1 のアンケート結果

|    |     | 10. 5 | へ両穴 エッノノ |     | 而不  |     |
|----|-----|-------|----------|-----|-----|-----|
| 入力 | 近傍  | 文数    | 自然に      | ほとん | やや不 | 不自然 |
|    |     |       | 感じた      | ど自然 | 自然に | に感じ |
|    |     |       |          | に感じ | 感じた | た   |
|    |     |       |          | た   |     |     |
|    | 50  | 9     | 0        | 1   | 2   | 1   |
| 1  | 100 | 7     | 0        | 1   | 2   | 1   |
|    | 300 | 7     | 0        | 2   | 2   | 0   |
|    | 50  | 29    | 0        | 0   | 1   | 3   |
| 2  | 100 | 9     | 0        | 1   | 2   | 1   |
|    | 300 | 11    | 0        | 0   | 4   | 0   |
|    | 50  | 7     | 0        | 0   | 3   | 1   |
| 3  | 100 | 6     | 1        | 1   | 2   | 0   |
|    | 300 | 6     | 0        | 0   | 2   | 2   |
|    | 50  | 7     | 1        | 2   | 1   | 0   |
| 4  | 100 | 9     | 1        | 2   | 1   | 0   |
|    | 300 | 4     | 2        | 1   | 1   | 0   |

#### 3.5 生成結果

表2に生成されたストーリーの例を示す.

生成結果は、文数をスタートとゴールの文を含めた6文に 固定し、類似度を図1の右上のスライダーのように調節した.

# 4. 実験1

# 4.1 アンケート評価

本システムの評価を行うためにまず,アンケートをした.文 数を固定せず,類似度の調節無しとした.スタートからゴール に到達するまでに要した遷移回数が文数となる.スタートと ゴールのペアが異なる 4 パターンの入力に対し,それぞれ近 傍数を 3 種類: 50,100,300 に変化させ,ストーリーを生成 した.そして,それらのストーリーに対し,4人のユーザに4 段階:自然に感じた,ほとんど自然に感じた,やや不自然に感 じた,不自然に感じたのいずれかを回答して評価をしてもらっ た.表3にアンケートの結果として各入力に対する回答数を 示す.

#### 4.2 ランダムとの比較評価

次に、ランダム生成したストーリーとシステムを用いて作 成したストーリー対8パターンを4人のユーザに比較をして もらった.方法は、各入力パターンに対し、スタートの文か らゴールの文までをつなぐ5文と10文をそれぞれシステム を用いる方法とコーパスから無作為に抽出する方法で決定し、 スタートの文とゴールの文と合わせてストーリーとする.生 成されたストーリーを比較し、どちらがより自然に見えるス トーリーかをユーザに選んでもらう.比較は、文数が同じもの 同士とした.4.1のアンケート評価により、最も不自然と感じ るユーザが少なかった近傍数を300に固定した.また、図2、 図3はシステムの5文と10文の場合の類似度調節機能のス

<sup>\*2</sup> Gensim, https://radimrehurek.com/gensim/

<sup>\*3</sup> Dash by plotly, https://plot.ly/products/dash/

|   |       |         | (   |       |     | 0   | 0   |        |        |      |        |     | . J | o ( |   |
|---|-------|---------|-----|-------|-----|-----|-----|--------|--------|------|--------|-----|-----|-----|---|
|   | 0.9   | 0.9     | 0.9 | 0.9   | 0.9 | 0.9 | 0.9 | 0.9    | 0.9    | 0.9  | 0.9    | 0.9 | 0.9 | 0.9 | a |
|   | 0.8   | 0.8     | 0.8 | 0.8   | 0.8 | 0.8 | 0.8 | 0.8    | 0.8    | 0.8  | 0.8    | 0.8 | 0.8 | 0.8 | 0 |
| - | 0.7   | 0.7     | 0.7 | 0.7   | 0.7 | 0.7 | 0.7 | 0.7    | 0.7    | 0.7  | 0.7    | 0.7 | 0.7 | 0.7 | 0 |
|   | 0.6   | 0.6     | 0.6 | 0.6   | 0.6 | 0.6 | 0.6 | 0.6    | 0.6    | 0.6  | 0.6    | 0.6 | 0.6 | 0.6 | 0 |
| - | 0.5   | 0.5     | 0.5 | 0.5   | 0.5 | 0.5 | 0.5 | 0.5    | 0.5    | 0.5  | 0.5    | 0.5 | 0.5 | 0.5 | 0 |
|   | 0.4 ( | 0.4     | 0.4 | 0.4   | 0.4 | 0.4 | 0.4 | 0.4    | 0.4    | 0.4  | 0.4    | 0.4 | 0.4 | 0.4 | 0 |
|   | 0.3   | 0.3     | 0.3 | 0.3   | 0.3 | 0.3 | 0.3 | 0.3    | 0.3    | 0.3  | 0.3    | 0.3 | 0.3 | 0.3 | 0 |
| 4 | 0.2   | 0.2     | 0.2 | 0.2   | 0.2 | 0.2 | 0.2 | 0.2    | 0.2    | 0.2  | 0.2    | 0.2 | 0.2 | 0.2 | 0 |
|   | 0.1   | 0.1     | 0.1 | 0.1   | 0.1 | 0.1 | 0.1 | 0.1    | 0.1    | 0.1  | 0.1    | 0.1 | 0.1 | 0.1 | 0 |
|   | , I   | 1 I     | 5 8 | ι,    | ,   | 8   | ۶.  | 8      | 6      |      | 5      | 6   | 1   | 11  | 5 |
|   |       | stand f |     |       | ,   |     |     |        | Areast |      |        |     |     | ,   |   |
|   | 図 2   | :類化     | 以度調 | 制節 5  | 5 文 |     | 义   | 3:     | 類(     | 以月   | 丟請     | 節   | 10  | 文   |   |
|   | –     |         |     |       |     |     | . – |        |        | ,    | - 10 - |     |     |     |   |
|   |       |         | _   | ь.    |     |     |     |        |        |      |        |     |     |     |   |
|   |       |         |     | E. A. | - 1 | 7 1 |     | /) \ L | ・レ 山元  | ZXT: | H      |     |     |     |   |

|         | 衣4: ノンダムとの比較結果 |      |      |      |  |  |  |  |
|---------|----------------|------|------|------|--|--|--|--|
| 18 A 14 | 5              | 文    | 10 文 |      |  |  |  |  |
|         | システム           | ランダム | システム | ランダム |  |  |  |  |
| 1       | 3              | 1    | 4    | 0    |  |  |  |  |
| 2       | 3              | 1    | 3    | 1    |  |  |  |  |
| 3       | 4              | 0    | 4    | 0    |  |  |  |  |
| 4       | 4              | 0    | 3    | 1    |  |  |  |  |
| 5       | 3              | 1    | 4    | 0    |  |  |  |  |
| 6       | 3              | 1    | 4    | 0    |  |  |  |  |
| 7       | 4              | 0    | 4    | 0    |  |  |  |  |
| 8       | 2              | 2    | 4    | 0    |  |  |  |  |

ライダーの設定である.類似度調節機能のスライダーはストー リーに意図的なアクセントが発生しないようにした.

表4に比較結果を示す.表4内の各パターンに対する行の 数字は、4人中何人が選択したかを示している.

#### 4.3 考察

アンケートによる評価では、システムによって出力されるス トーリーでは取得する近傍の文数を大きくすることで、不自然 と感じる人が減少することがわかった.

ランダムとの比較では、5 文と 10 文のどちらの場合におい ても、システムは優位性を示すことができた.しかし、ランダ ムなストーリー生成であっても 5 文からなるストーリーでは 自然と感じられる場合が見られた.一方で、10 文の場合では 4 人のユーザがほとんどの入力パターンにおいてシステムの方 が自然であると回答した.本システムでは、文の類似度が近い 文がつながるため、文の数が増加しても全体の名詞種数が多く なりにくく、システムを用いることで、5 文以上の文数では自 然なストーリーが生成されやすくなると考えられる.

ストーリーが自然と感じられなかった原因としては,文の 数や長文の影響が考えられる.文の数や長文が含まれると,ス トーリー全体に含まれる固有名詞の数が増える.これが,ス トーリー内での場面や時代,世界観に矛盾を生み出す原因とな る.対策としては,固有名詞等を代名詞に変換することや,文 数を少なく固定して生成すること,文長を制限し,長文の登場 を防ぐことで改善できると考えられる.また,コーパスサイズ により取得される類似文の類似度の平均が大きく変わることが 考えられるため,コーパスサイズに応じた適切な近傍の値を用 意することで改善が期待できる.

また,文によっては同じ意味の文が複数出現し,それらがモ デル内に多数存在し密集することで,類似文があまりに似通っ た文しか取れないという問題がある.これは,ストーリーの遷 移ができず,同じような文ばかりが連続する原因となる.対策 としては,極度な類似文はモデル作成時に数を減らすことや近 傍 n を一時的に大きくすることが考えられる.

# 5. コーパスの前処理の変更

実験1では、分散表現より類似文を取得する際に、長い文 は取得した文との類似度が高くなく、実際に読んでも類似して いるとは言い難い文も取得されていた.

そこで,実験1で用いた文の処理方法とは異なる方法で文

| 表 | 5:    | 前処理の変更点 |
|---|-------|---------|
|   | · · · |         |

| 変更前   | 変更後                        |  |  |  |  |  |
|-------|----------------------------|--|--|--|--|--|
| 削除    | 文の終端として,そこで文章              |  |  |  |  |  |
|       | を分割                        |  |  |  |  |  |
| 読点に置換 | 文の終端として、そこで文章              |  |  |  |  |  |
|       | を分割                        |  |  |  |  |  |
| 処理なし  | 感嘆符 (!),疑問符 (?),           |  |  |  |  |  |
|       | 二重鉤括弧 (『』) 以外を削除           |  |  |  |  |  |
|       | 変更前<br>削除<br>読点に置換<br>処理なし |  |  |  |  |  |

を処理し、コーパスを作成した.表5に変更点を示す.3.1で 準備したインターネット上の小説投稿サイトの作品は文体が自 由に書かれており、全角記号の出現数が多い.また、文末と思 われる点でも句点が用いられていない場合があり、その場合空 白や改行を文の終端として用いている場合がみられた.以前の コーパスでは、鉤括弧の前後をつなげて一文としていた.しか し、鉤括弧内の文を独立して抜き出すために、分割することに した.

学習データ量は,前処理の変更により,383494 文から 663066 文に増加した.

# 6. 実験 2

実験1の結果から、文の長さが長いと違和感を覚えやすい という結果があり、これらを改善することで、生成されるス トーリーの自然さに改善がみられないかを4.1のアンケート評 価で比較実験を行う、ランダムとの比較は、4.2の時点で既に 優位性がみられたため取り組まない.

#### 6.1 実験方法

5. で変更したコーパスを用いたストーリー生成の実験をす る. 3.5 と同様のパラメータで,前処理変更後のモデルに対し てもストーリーを生成させた.また,実験1と同様に文数を 固定せず,類似度の調節無しで行った結果を用いる.入力文も 同様のものを用いる.

#### 6.2 結果と考察

表6に生成されたストーリーの例を示す.表7にアンケートの結果を示す.

前処理を変更したコーパスを用いた実験では、「やや不自然 に感じた」、「不自然に感じた」と答える人がわずかに減少した. これは実験1で述べた長文が自然さに影響するという点にお いて、コーパスの文がより細かく分割されたことにより、長文 の割合が減ったため改善されたと考えられる.また、1文が 短くなったことにより、Paragraph Vector によって、文の分 散表現を獲得し、類似度の計算を行う際に、文の長さが極端に 違うものが減少しているため、より正確に類似度を測ることが できるようになったと考えられる.

しかし,表7の入力4に関しては,表3の結果よりも変更 後のコーパスの方が「自然に感じた」と回答したユーザが少な くなった.表3の入力4の結果では文が長いものも含まれて いたが,固有名詞が少なく,また「俺」や「彼女」といった代 名詞の使用が多い.これをユーザーがうまく補完して,話のつ ながりを自然と捉えられたと考えられる.対して,表7の結果 では,文数が増えたこともしくは類似度の計算が改善して類似 文を集めやすくなったことの影響からか,同じ表現を何度も繰 り返すようなストーリーとなってしまった.類似文上位 n件 を取得する現在の方法では,新しいコーパスを用いると4.3で 述べた同じ意味の文が複数出現する問題に関しては悪化させる 可能性がわかった.

|   |                   | 4      |
|---|-------------------|--------|
|   | 文                 | 類似度    |
| 0 | 技科大生が暇な土曜日を迎える    | -0.013 |
| 1 | 立ち止まっている暇などない     | 0.338  |
| 2 | 落ち着かないか、[キャラクター名] | 0.541  |
| 3 | 心の中が落ち着かない        | 0.568  |
| 4 | なんだろう、落ち着かない      | 0.618  |
| 5 | ドキドキして落ち着かない      | 1.00   |

表 6. 生成されたストーリーの例 9

|    |     | 2010 |            | • /        | 114 215           |                 |
|----|-----|------|------------|------------|-------------------|-----------------|
| 入力 | 近傍  | 文数   | 自然に<br>感じた | ほとん<br>ど自然 | やや不<br>自然に<br>感じた | 不自然<br>に感じ<br>た |
|    |     |      |            | た          | 感した               | /2              |
|    | 50  | 7    | 0          | 2          | 2                 | 0               |
| 1  | 100 | 6    | 0          | 3          | 1                 | 0               |
|    | 300 | 5    | 0          | 0          | 3                 | 1               |
|    | 50  | 10   | 0          | 0          | 2                 | 2               |
| 2  | 100 | 10   | 0          | 3          | 1                 | 0               |
|    | 300 | 7    | 2          | 1          | 1                 | 0               |
|    | 50  | 10   | 0          | 1          | 1                 | 2               |
| 3  | 100 | 6    | 0          | 2          | 2                 | 0               |
|    | 300 | 6    | 1          | 1          | 2                 | 0               |
|    | 50  | 10   | 0          | 0          | 2                 | 2               |
| 4  | 100 | 10   | 0          | 0          | 2                 | 2               |
|    | 300 | 5    | 0          | 2          | 1                 | 1               |

表 7: 実験 2 のアンケート結果

上記のことを踏まえ、今後は付近の文との距離や数に影響 されにくくするために、従来のストーリーが場面に応じてどの 程度のベクトル変化量があるかを解析し、文を選択していくよ う改良する必要があると考えられる.

表2と表6に示されるように、前後の文に同様の単語が出現 する.これは4.3に問題点として挙げた同じ意味の文が複数出 現するという問題にも近いが、用いている Paragraph Vector が単語に影響を受けやすいことが影響している.「~ない」と いった反意的な表現は学習時に直接的には考慮されないため、 肯定文と否定文であっても出現する単語が似ている場合に連 続する文として選択される場合がある.「~する」と「~しな い」といった単語はモデル学習時には距離が遠くなるような学 習を行う必要があると考えられる.そこで、反意を重視して特 徴量の調整をしたり、例えば編集距離といった他の手法と組み 合わせて文の類似度を算出することが有効ではないかと考えら れる.

# 7. 創作支援への展望

本研究では,異なる2つの入力文に対して,それらを繋ぐ ストーリーを作成した.表2,表6の「暇」と「落ち着かない」 のようにほとんど対極とも取れる状態を結び,その間を補完す るストーリーが作成できる.また,この入力が人間の目から見 て明らかに繋がりにかける文であったとしても,少々強引にな るかもしれないが,類似度調節を利用して段階的に結ぶことが 可能である.よって,これまでの人の創作者の発想では思いつ かなかった作品が生まれるきっかけになり得ると考えられる.

また,創作者の過去の十分な量の複数作品を学習すること で,作者の過去に用いた文を参考に新たなストーリーを生み 出すことが可能である.小説から小説でなくとも,小説作品の データから,歌詞や短編の作品といった違う分野に活用するこ とも考えられる.

また本研究を応用することで、作品のあらすじとして複数

文を入力して文間の類似度の変化を得て,ストーリーのスター トからゴールまでの変化をパターンに分類し解析することも視 野に入れている.

従って、本研究は創作支援に貢献できると考えられる.

# 8. まとめ

本研究では、創作支援を目的としてストーリー生成システムを構築した.文を類似度に基づいて順序変更することで人が 違和感を覚えないストーリーを生成できる可能性を示した.また、以下のことがわかった.

- ・ 文数が増えたり長文が含まれると、文中に含まれる固有 名詞等の出現回数が増え、ストーリーの自然さが損なわ れる
- 文中の固有名詞を代名詞に変換する等の対策を取り、改善する必要がある
- 記号の除去や文を分割する箇所を変更することで生成されるストーリーの結果が改善する

特にストーリーという観点で同じ単語を含まないが同様の意味 の文は距離が近く、文に登場する単語は似ていても意味が反す る文は遠くに置かれるモデルの作成が望まれる.また、コーパ スに含まれる類似文の数がモデル内の距離の変化量に大きく 影響するため一定距離での変化が可能なように改良が必要で ある.

#### 謝辞

本研究は、一部 JSPS 科研費 (グラント番号:JP17K17809) および JST, ACT-I(グランド番号:JPMJPR17U4) の支援に よる.

- [1] 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,4Pin1-16 (2018)
- [2] 福田 清人, 上野 未貴, 藤野 紗耶, 森 直樹, 松本 啓之亮, " ストーリーの自動生成を目的としたストーリーモデルの 提案", 言語処理学会 P6-1 (2016)
- [3] 葛井 健文, 上野 未貴, 井佐原 均, "質問集合とグラフに基づく物語全体の流れを管理可能な創作支援システムの提案", 人工知能学会, 2E2-04, (2017)
- [4] 古舞 千暁,滝口 哲也,有木 康雄,"単語の分散表現を 用いた意味予測に基づく雑談応答生成",日本音響学会, ROMBUNNO.2-Q-12, (2018)
- [5] Quoc Le, Tomas Mikolov, "Distributed Representations of Sentences and Documents", Google Inc, 1600 Amphitheatre Parkway, Mountain View, CA 94043, (2014)
- [6] Andrew M. Dai, Christopher Olah, Quoc V. Le, "Document Embedding with Paragraph Vectors", arXiv:1507.07998, (2015)
- [7] Y.Matsui, K.Ito, Y.Aramaki, A.Fujimoto, T.Ogawa, T.Yamasaki, K.Aizawa, "Sketch-based Manga Retrieval using Manga109 Dataset", Multimedia Tools and Applications, Springer, (2017)

# 創作視点に基づく4コマ漫画におけるストーリー分類手法の提案

Classification method for Four-scene Comics based on Creative Viewpoint

森 直樹

Naoki Mori

# 大阪府立大学工学研究科

Graduate School of Engineering, Osaka Prefecture University

Can the computer create an interesting story? This question is one of the ultimate purpose of artificial intelligence. The comic analysis has become an attractive research topic in artificial intelligence fields as comic engineering to tackle that problem, t. Although there are lots of attractive and useful topics and many researchers have been reported, creating a story by computer is still difficult. One of the most critical reason is that there are no useful comic datasets for artificial intelligence fields. In this study, I focus on the classification method for four-scene comics based on creative viewpoint.

# 1. はじめに

計算機は面白いストーリーを創作することが可能なのか? こ の問いに答えることは非常に難しい. Yes であれば, これは人 工知能における究極的な目的, 人間のように思考するシステム の構築に成功したことになる. さすがに最新の人工知能でもこ の問いに Yes と答えるだけの成果はまだ得られていないよう にみえる. 一方で, No と容易に断ずることが難しいほど, 近 年の人工知能の技術発展は急速であり, 月並みだが,「今の段 階で Yes と答えるのは難しいが近い将来確実に面白いストー リーを創作する人工知能は登場するだろう」と答えるしかない のかもしれない. 人工知能によるストーリー生成については多 くの研究がなされているが, 本稿では, 特に 4 コマ漫画に焦 点を当てる. これは, 4 コマ漫画はしっかりとしたストーリー 構造を持ち, 各ストーリーの長さが決まっているため, 定量的 な解析に向いているためである.

4 コマ漫画の研究は,漫画を工学的に解析しようと試みるコ ミック工学 [松下 13] の分野で積極的になされてきた.同分野 では多様な研究可能性が示唆されており,特に人工知能研究の ためのデータセット [Matsui 15] に関する研究が注目され始め ている.特に,人工知能研究を対象とした世界初の独自 4 コ マ漫画データセットも提案されており,今後データセットの独 自構築が活発化していく可能性が高い.既存の漫画ではなく独 自にデータセットを構築する場合,商用の漫画では困難である 表現も可能であるという利点がある反面,自由度が高いため データの何に着眼しているかが見えにくくなるという問題点 も顕在化している.そこで本稿では,機械学習を前提とした4 コマ漫画データセットの表現方法および着眼すべき特徴につい て可能な限り定量的にまとめ,同時に創作視点に基づく具体例 を示すことで創作と人工知能に関する分野の発展に寄与するこ とを目的とする.

# 2. 従来研究および本研究の位置付け

#### 2.1 コミック工学に関する研究

これまでのコミック工学は、いわゆる「漫画」を対象とし ており、漫画を工学的に扱うためのデータセットに関する研究 [Matsui 15] や既存の画像認識手法をキャラクタ識別や吹き出

連絡先:森 直樹,大阪府立大学,mori@cs.osakafu-u.ac.jp

し識別に代表される漫画内のパーツを識別する研究を中心に発展してきた.これらの研究は、コミック工学という分野を広げるために大きく貢献している.また、ユーザの視点に立った検索システム [山下 17] や読書意欲の増進に関する研究 [佐藤 18] についても積極的な研究がされている.

一方で,狭義の漫画に収まらない対象についても研究の展開が始まっている。例えば,厳密には漫画には分類されないアニメの絵コンテや絵本に関する研究 [Fujino 17] やストーリー 生成系の研究 [Fukuda 17] などがその範疇に当てはまる。

#### 2.2 4 コマ漫画に関する研究

4 コマ漫画は日本における代表的な漫画形式のひとつであ り、4 つの コマ (齣) によって完結した短い話を表現する.人間がストーリーを感じることができる最小の表現形式として、 古くから新聞や雑誌の一部に掲載されてきた.現在では、4 コ マ漫画だけを扱う専門誌も数多く存在している.

4 コマ漫画の基本的なストーリー展開は,各コマを最初から 順に起承転結に対応させ,結に相当する最終コマをオチとする 場合が多い.それ以外にも3 コマを序破急に対応させる場合 や,2 段オチ,オチを必ずしも必要としないストーリー4 コマ などが存在する.

4 コマ漫画に関する研究としては、4 コマにおける感情識別に関する研究[上野 16] やストーリー理解過程の解析研究 [上野 17],4 コマ漫画ではないが既存漫画のデータを利用した 2 コマ漫画の生成に関する研究[迎山 18] が報告されている. また4 コマ漫画の自動生成に関する研究[Ueno 16a] や遺伝 的アルゴリズムに基づく感性解析に4 コマ漫画を用いた研究 [野村 17] もなされている.

また,ストーリーに関しては4コマ漫画の内容に踏み込んだ 研究として,コマの順序識別に関する研究 [Ueno 16b,藤野 18] が報告されている.

### 2.3 漫画データセットに関する研究

4 コマ漫画を対象としたデータセットとしては Manga 109[Matsui 15] が知られている.これは著作権の切れた 109 冊の漫画の画像および台詞をデータ化したもので,その有用 性から高く評価されている.一方で,上野によって作られた4 コマ漫画ストーリーデータセット [Ueno 18, 上野 18] も特徴 的である.このデータセットは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,著作権の問 題がなく創作者自身による感情アノテートがされている,同じ 内容の話が複数の創作者により作られているなど人工知能研究 において極めて大きな利点を持つ.一方で,現段階では4コ マ漫画ストーリーデータセットはデータ数が少ないという致 命的な欠陥を持つ.そこで,今回はコミック工学の枠にとらわ れることなく創作視点の研究が可能な4コマ漫画ストーリー データセットにおいて効率的に新しいストーリーを生成するた めの4コマ漫画におけるストーリーの特徴および分類手法に ついて示す.

# 4 コマ漫画で着眼すべき特徴

以下に今回提案する 4 コマ漫画で着眼すべき特徴について 定義し,可能であれば台詞例を示す.以下では,4 コマ漫画の 各コマを始めから順に 1,2,3,4 の番号で表すが,n コマ漫画 の場合にも同様に表現することが可能である.

#### 3.1 コマの可換

ある特定のコマ同士が交換可能であるとき,それらのコマ は可換 (commutative) であると定義し, com:[n,m] で表す.

台詞例:

com:[1,2]

(1 コマ) 学生 A「今日こそ,あのバグのことを先生に正直に 言わないと…」

(2 コマ) 学生 A「おはようございます」

(3 コマ) 教員 B「おはよう」

(4 コマ) 学生 A「すいません,あの結果はバグでした!」

ただし,同一のコマ内容であっても,他のコマとの関係で可換 性を失う場合もあることに注意を要する.例えば,以下の例で は 2,3 コマは可換ではない.

#### 台詞例:

(1 コマ) 学生 A「今日こそ先生よりも先に挨拶してやる!」
(2 コマ) 学生 A「おはようございます」
(3 コマ) 教員 B「おはよう」
(4 コマ) 教員 B「…あら,なんで嬉しそうなの?」 学生 A「いえ,別に!」

3個のコマが可換な場合もある.

台詞例: com:[1,2,3] (1 コマ) 学生 A「眠い」 (2 コマ) 学生 B「意識飛びそう」 (3 コマ) 学生 C「寝たい」 (4 コマ) 教員 D「…皆早く寝ろよ そうすりゃ帰れるのに!」

また,可換な部分が 2 つある場合もある.その場合は, com:[*n*,*m*][*s*,*t*] と表す.

#### 台詞例:

com:[1,2][3,4]

(1 コマ) イケメン A「彼女と女友達は別なんだよな!」 (2 コマ) イケメン B「彼女の相談をする女友達は必要!」 (3 コマ) 非モテ C「彼女さえできたら人生終わってもいい…」 (4 コマ) 非モテ D「せめて一人だけでも女友達が欲しい…」

#### 3.2 コマの圧縮分解

複数のコマを一つのコマにできることをコマが圧縮 (summarize) 可能である,逆に一つのコマを複数のコマにできる ことをコマが分解 (separate) 可能であると定義し,それぞれ sum:[*n*,*m*] および sep:[*n*] と表す.一般に可換なコマ同士は圧 縮可能だが逆は成り立たない.例えば,以下の2コマは圧縮 可能だが可換ではない.

台詞例: sum:[*n*,*n* + 1] (*n* コマ) A「ゴメンなさい」 (*n* + 1 コマ) B「いや俺も言い過ぎた」

複数人の会話は分解可能な場合がほとんどである.ただし, 4 コマ漫画の場合には事象の粒度よりも台詞の量によって複数 のコマで表現せざるを得ない場合があり,意味だけでは圧縮性 を判定できないことに注意を要する.

## 台詞例:

sep:[n]

(n コマ) A「ゴメンなさい」 B「いや俺も言い過ぎた」

以下の台詞は上述の内容と本質的には同じ内容だが,台詞 の分量に関する制約で圧縮できない可能性がある.

#### 台詞例:

sum:[*n*,*n* + 1] (分量的に圧縮不可?)

(n コマ) A「ゴメンなさい 私の言い方も良くなかったわ 私に は昔からそういう素直じゃない部分があるの 自分でもそれが 嫌なのだけれど感情的になると抑えることができなくて…」 (n+1 コマ) B「いや俺も言い過ぎた そちらの今後を考える とどうしてもわかって欲しかったのだけれど… でもいくら正 しいと信じていても言い方が少しキツかった もう少し柔らか い表現を使うべきだったよ」

#### 3.3 同值関係

2 つの 4 コマ漫画 A, B について,何らかの要素が共通で ある場合, A と B はその要素に関して同値関係 (equivalence relation) であると定義し,  $A \sim B$  で表す. この場合,以下の 同値律を満たすものとする. また,  $A \sim B$  のとき A と B は 同値 (equivalence) であると呼ぶ.

#### 反射律: $A \sim A$

対称律:  $A \sim B$  ならば  $B \sim A$ 

推移律:  $A \sim B$  かつ  $B \sim C$  ならば  $C \sim A$ 

例えば、「プロットに関して同値」、「作者に関して同値」、「オ チのパターンに関して同値」などがあり得る.

# 4. 特定のコマに関して同値なストーリー群

ー般的に、既存の4コマ漫画の場合、作者やテーマ以外の部 分で同値なストーリー群を集めることは容易ではない、一方、 4コマ漫画ストーリーデータセットのように研究者が創作に関 わることが可能な場合は既存の4コマ漫画では困難な要素に 着目し、同値なストーリー群の作成できるという利点がある. その中で、機械学習への応用を考える場合、一部コマを共通と し、残りを可変としたデータ集合、つまり特定のコマに関して 同値なストーリー群が有用であると考えられる.以下では、共 通となるコマの部分を集合論における共通部分 (intersection) と考え,特定のコマに関して同値なストーリー群 S<sub>i</sub> における 共通部分を

$$\bigcap S_i$$
 (1)

と表現する.このとき各ストーリーは以下で表現できる.

$$S_i = \{s_{i,1}, s_{i,2}, s_{i,3}, s_{i,4}\}$$
(2)

ここで  $s_{i,j}$  はストーリー  $S_i$  の j 番目のコマ情報である.以下では、このストーリー群のパターンについて考察する.

#### 4.1 分岐型

1 コマから連続する最初の部分が共通部分となる場合を分岐 型と呼ぶ. 例えば 1~3 コマを共通部分として 4 コマ目のオ チだけを変える, 4 コマ目のポジネガだけを変えるなどの場合 に用いられる. 1 コマ目のみが共通部分の場合には自由度が一 番高く,多くのストーリーを作りやすい.

#### 分岐型の例

(1 コマ) A「神様, 周りのみんなだけは幸せにして下さい」 (2 コマ) 神「それでお前は幸せなのか?」 (3 コマ) A「はい. 周りが幸せなら僕も幸せです」

(4 コマ) 神「困ったなぁ… お前の不幸がみんなの幸せなのよ」

(1 コマ) A「神様,周りのみんなだけは幸せにして下さい」
(2 コマ) B「私,A 君のためならなんでもする」
(3 コマ) C「A 君の笑顔がない世界なんて考えられないよね」
(4 コマ) D「A 君の幸せが私たちの一番の幸せだってわかっているのかしら?」

#### 4.2 収束型

4 コマ目から遡って連続する最後の部分が共通部分となる場 合を収束型と呼ぶ。例えば 4 コマ目のオチだけ示しそこに至 る過程を 1~3 コマで自由に作る場合に用いられる。4 コマ目 の内容がインパクトの強い場合は自由度が非常に低くなる可能 性がある。一方,4 コマ目を日常的な内容とした場合には平坦 なストーリーになりやすい。

#### 収束型の例

(1 コマ) B「月が綺麗= I love you って意味なんだ!」
(2 コマ) A「B さん,ちょっと外に行きませんか?」
(3 コマ) B「A さん! いいですよ …あら,綺麗な満月」
(4 コマ) A「月が綺麗ですね」

(1コマ) A「今日は満月!距離は?輝度は?これはスゴイぞ!」
 (2コマ) B「天文部の A 君は私をどう思っているのかしら…」
 (3コマ) A「B さん,報告会に備えて月を見ませんか?」
 (4コマ) A「月が綺麗ですね」

#### 4.3 砂時計型

2,3 コマ目をいずれか,または両方を共通部分とした場合 を砂時計型と呼ぶ.これは一番ストーリーの作成が難しい.

### 2 コマ目が共通部分の場合の例

(1 コマ) A「よし,実験終わった!結果もバッチリ!」
(2 コマ) B「ああ,僕も頑張らないと」
(3 コマ) A「え?まだこれだけ?マジで?これ無理じゃない?」
(4 コマ) B「……それでも…頑張らないと」

(1 コマ) A「C 君の結果は素晴らしいね」
(2 コマ) B「ああ,僕も頑張らないと」
(3 コマ) A「B 君のテーマだって素晴らしい 焦ってはいけないよ 結果は必ず出るから」
(4 コマ) B「はい,焦らず頑張ります!」

#### 3 コマ目が共通部分の場合の例

(1 コマ) A「X って教授にも意見するし超自信家だよな」

(2 コマ) B「あいつこの前ヤンキーと乱闘したらしいぜ」

(3 コマ) 猫「ニャーン」

(4 コマ) X「ひゃっ!……でも猫だけは苦手なんだ」

(1 コマ) A「仕事また失敗した 貯金ももうない」

(2 コマ) A「人間関係も最悪 頼る友達も彼女もいない 孤 独だ…」

(3 コマ)猫「ニャーン」

(4 コマ) A「なんだか元気出た! もう少しだけ頑張ってみ るか!」

#### 2,3 コマ目が共通部分の場合の例

(1 コマ) A「研究費厳しいけれどなんとか学生を学会に行か せてやりたいな」

 $(2 \ \exists \ \forall)$  B「うちの研究室っていつもエコノミーと安宿だ よね」

(3 コマ) C「うん 高級ホテルじゃなきゃ学会なんて行きたく ないよな」

(4 コマ) A「自分の分は自腹を切って学生分の旅費だけはなんとかしてやるか」

(1 コマ) A「あいつらの成果のおかげで使い切れないほどの 研究費が!」

(2 コマ) B「うちの研究室っていつもエコノミーと安宿だ よね」

(3 コマ) C「うん 高級ホテルじゃなきゃ学会なんて行きたく ないよな」

(4 コマ) A「次の学会も俺だけ高級ホテルで旨いものでも喰 うとするか! 」

#### 4.3.1 複雑な収束型

ー般に収束型は結果が同一になる場合が多いが,出オチの場 合は結果に自由度がある.しかしながら,これは本来は4コ マ目にあるべきオチが倒置していると考えられるので,収束型 でありながら結論が異なるわけではない.一方で,4コマ目が 同一であっても1~3コマ目の内容によって結論のポジネガ極 性が反転したりまったく別の意味になる場合がある.これは, コマ単独で内容を理解することができないことを示しており, 機械学習を用いる場合はLSTMのような時系列性を扱える手 法か1~4コマの内容を一度に入力する手法を用いなければな らないことを示している.以下に複雑な収束型の例を示す.

#### 複雑な収束型の例

(1 コマ) A「アイツに研究報告しに行ったら嫌味言われた」

(2 コマ) B「髪型や服装にまでケチ付けるし最低な先生」

(3 コマ) C「私なんて彼氏の悪口言われたたんだけど,なんなのよ?」

(4 コマ) **D**「あの先生,本当に私たちが嫌がることを進んで するよね」 (1コマ) A「この前,先生が一人で散らかった研究室の掃除をしてた」

(2 コマ) B「絶望的に理解力がないアイツの面倒も夜遅くま で見るし」

(3 コマ) C「私たちの飲み会とか学会に行く段取りまで自分 でしてくれる」

(4 コマ) **D**「あの先生,本当に私たちが嫌がることを進んで するよね」

これは自然言語に基づく分岐の例であるが,台詞はなく画 像だけでもこのような例を作ることも可能である.

#### 複雑な収束型の例 (画像のみ)

(1 コマ) A が真夜中に研究室を動き回っている

(2 コマ) B「あれ? 機械学習のライブラリが最新版になって いる!」

(3 コマ) C「調子が悪かったコンピュータも直ってる なんで?」

(4 コマ) A が自分の机で寝ている

(1 コマ) B「GUI の部分終わったよ!アルゴリズム担当の A は?」

(2 コマ) C「プレゼンのパワポ作ったぜ アルゴリズム担当 の A は?」

(3 コマ) D「やっとデータセットができた アルゴリズム担当 の A は?」

(4 コマ) A が自分の机で寝ている

この違いを理解することはかなり高度な読解能力が必要で あり、ストーリーの創作も容易ではないが、そこまで踏み込ん だストーリー群を作ることは人工知能研究において極めて有用 であり検討していく必要がある.

# 5. まとめ

本稿では、創作視点に基づく4コマ漫画におけるストーリー 分類手法を提案し、記号的な表現方法と具体的な台詞例につい て述べた.既存漫画のアノテートと創作視点に基づくパターン に応じたデータセットの構築は、創作者と人工知能研究のため に必須の内容であり、今回の内容に基づく具体的なデータセッ トの構築および数値実験について進める必要がある.また、創 作者の方々のご意見を聞くとともに、クラウドソーシング等を 利用した今回のパターン分けに基づく大規模創作実験も重要な 今後の課題である.

- [Fujino 17] Fujino, S., Hatanaka, T., Mori, N., and Matsumoto, K.: The Evolutionary Deep Learning based on Deep Convolutional Neural Network for the Anime Storyboard Recognition, in Distributed Computing and Artificial Intelligence, 14th International Conference, DCAI 2017, Porto, Portugal, 21-23 June, 2017, pp. 278–285 (2017)
- [Fukuda 17] Fukuda, K., Fujino, S., Mori, N., and Matsumoto, K.: Semi-automatic Picture Book Generation Based on Story Model and Agent-Based Simulation, pp. 117–132, Springer International Publishing, Cham (2017)

- [Matsui 15] Matsui, Y., Ito, K., Aramaki, Y., Yamasaki, T., and Aizawa, K.: Sketch-based Manga Retrieval using Manga109 Dataset, *CoRR*, Vol. abs/1510.04389, (2015)
- [Ueno 16a] Ueno, M.: Computational Interpretation of Comic Scenes, in Advances in Intelligent Systems and Computing, Vol. 474, pp. 387–393 (2016)
- [Ueno 16b] Ueno, M., Mori, N., Suenaga, T., and Isahara, H.: Estimation of structure of four-scene comics by convolutional neural networks, in *Proceedings of the 1st International Workshop on coMics ANalysis, Processing* and Understanding, p. 9ACM (2016)
- [Ueno 18] Ueno, M.: Four-Scene Comic Story Dataset for Softwares on Creative Process, in New Trends in Intelligent Software Methodologies, Tools and Techniques - Proceedings of the 17th International Conference SoMeT\_18, Granada, Spain, 26-28 September 2018, pp. 48–56 (2018)
- [迎山 18] 迎山 和司:既存の漫画に基づいた2コマ漫画の自律 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.1K1OS2a02-1K1OS2a02
   一般社団法人人工知能学会(2018)
- [佐藤 18] 佐藤 剣太,牧 良樹,中村 聡史:コミックの読書意 欲を増進させる要素に関する分析,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. 1K1OS2a01-1K1OS2a01 一般社団法人人工知能学会 (2018)
- [山下 17] 山下 諒, 朴 炳宣, 松下 光範:コミックの内容情報 に基づいた探索的な情報アクセスの支援, 人工知能学会論文 誌, Vol. 32, No. 1, pp. WII-D\_1-11 (2017)
- [松下 13] 松下 光範:コミック工学:マンガを計算可能にする 試み、日本知能情報ファジィ学会ファジィ システム シンポ ジウム 講演論文集, Vol. 29, pp. 199–199 (2013)
- [上野 16] 上野 未貴, 森 直樹, 松本 啓之亮:漫画内の特徴的 要素が与えるストーリーの印象についての検討, 第 30 回 人工知能学会全国大会発表論文集, pp. 2J5-OS-08b-4in2 (2016)
- [上野 17] 上野 未貴, 末長 寿規, 井佐 原均: 漫画中の表現獲得 方法に基づくストーリー理解過程の解析, 第 31 回人工知能 学会全国大会発表論文集, pp. 4F1-5in2 (2017)
- [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 2018 年度人工知能学 会全国大会 (第 32 回) 論文集, pp. 4Pin116-4Pin116 一般 社団法人人工知能学会 (2018)
- [藤野 18] 藤野 紗耶,森 直樹,松本 啓之亮:3 分岐型畳み込み ニューラルネットワークによる 4 コマ漫画の順序識別,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. 1K1OS2a05-1K1OS2a05 一般社 団法人 人工知能学会 (2018)
- [野村 17] 野村 俊太, 荒井 幸代:進化計算を用いた人間の感性 理解のための遺伝子解析法, 第 31 回人工知能学会全国大会 発表論文集, pp. 3H2–OS–04b–2 (2017)

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

| [3L4-OS-22b] 創作者と人工知能が創る創作の未来(2)<br>上野 未貴(豊橋技術科学大学)、森 直樹(大阪府立大学)<br>Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room L (203+204 Small meeting rooms)   |  |  |  |  |
|---|--|--|--|--|
| [3L4-OS-22b-01] Autonomous Collection and Feedback of Dialogue Profile for<br>Dialogue Contents Circulation   |  |  |  |  |
| Masaki Mori <sup>1</sup> , OAkinobu Lee <sup>1</sup> (1. Nagoya Institute of Technology, Japan)<br>3:50 PM - 4:10 PM  |  |  |  |  |
| [3L4-OS-22b-02] A Discussion about Jazz Improvisation System based on Studies<br>with First-Person's View   |  |  |  |  |
| ODaichi Ando <sup>1</sup> (1. Tokyo Metropolitan University)  |  |  |  |  |
| [3L4-OS-22b-03] Of application of artificial intelligence to fashion design<br>OYoko Fujishima <sup>1,3</sup> , Osamu Sakura <sup>2,3</sup> (1. Graduate School of Interdisciplinary<br>Information Studies, The University of Tokyo, 2. Interfaculty Initiative in Information<br>Studies, The University of Tokyo, 3. RIKEN-AIP)<br>4:30 PM - 4:50 PM |  |  |  |  |
| [3L4-OS-22b-04] Tone Pasting Using cGANs with Tone Feature Loss<br>OKoki Tsubota <sup>1</sup> , Kiyoharu Aizawa <sup>1</sup> (1. The University of Tokyo)<br>4:50 PM - 5:10 PM  |  |  |  |  |
| [3L4-OS-22b-05] Creative Future will be Created by Contents Creators and Artifical<br>Intelligence<br>OMiki Ueno <sup>1</sup> (1. Toyohashi University of Technology)<br>5:10 PM - 5:30 PM  |  |  |  |  |

# 音声対話コンテンツ循環環境を実現するための対話シナリオの プロファイル自動収集およびフィードバック

Autonomous Collection and Feedback of Dialogue Profile for Dialogue Contents Circulation

森雅希 李晃伸 Masaki Mori Akinobu Lee

名古屋工業大学大学院工学研究科 Nagoya Institute of Tehchnology, Japan

In this research, we regard a spoken dialogue systems as "dialogue media content" from user's view, and tries to realize dialogue media content circulation between creators and users. Focusing on the feedback from users to the creator of the content, an autonomous collection of dialogue profile and its effective feedback scheme is proposed. Experimental results showed that among the automatically collected feedback information, displaying recognition word list and occupation time at each state helps creators for content refinement and updates. Further interview with a professional creator after a long free-creation run also indicates that this sheme can motivate ones to create the content.

# 1. はじめに

近年,音声認識や音声合成,自然言語処理技術の発展に伴い 音声対話システムが注目されており,様々な音声対話システム や音声言語インタフェースが実用化されつつある.

個々に異なる音声対話システムが社会に溢れるとき、ユーザ にとって音声対話システムは対話という体験を提供する一種の コンテンツとして捉えると考えられる。映像メディアや画像メ ディアのように、音声対話システムもその構成要素(辞書・ボ イス・対話シナリオ・エージェントモデル・モーション等)か らなるコンテンツとして考えることができる。音声対話がコン テンツとして認知され,対話が消費・模倣・創造される環境が 実現されれば,多様な対話システムの創造や、データドリブン で実践的な対話システムの知見の蓄積が期待される.筆者らは 音声インタラクション構築ツールキット MMDAgent を用い た音声対話コンテンツの研究を行っている [1][2].

本研究では、音声対話コンテンツがメディアとして循環する ための要件の一つとして、ユーザからシステム構築者(クリエ イタ)へのフィードバックに着目し、利用したユーザの体験や 動向をクリエイタへ積極的かつ有効にフィードバックする仕組 みを提案する.以下、対話シナリオ動作時のユーザごとのプロ ファイルを自動収集し、それをクリエイタに有益な形でフィー ドバックするための仕組みを提案し、実験を行った結果を示す.

# 2. 音声対話コンテンツの循環系

コンテンツが流通する背景にはコンテンツ循環が存在する [3]. 音声対話においては、図1のようなコンテンツ、ユーザ、 クリエイタが主体となった循環系を成すと考えられる.コンテ ンツがこれら主体の間を循環していくことで、多彩かつ魅力の あるコンテンツがユーザから生み出される.

音声対話のコンテンツ循環系については、これまでに、ユー ザがキャラクターとの対話を登録・編集できるコンテンツ作成 システム [1] や、ユーザ層ごとのインセンティブ設計と誘引の 分析 [2] などが試みられているが、実際に音声対話コンテンツ のポジティブループを回すには至っていない.

連絡先: 李 晃伸, 名古屋工業大学, 愛知県名古屋市昭和区御器 所町, 052-735-7550, ri@nitech.ac.jp



図 1: 音声対話コンテンツの循環系



図 2: 対話シナリオ利用統計からのフィードバック

音声対話は、動画や画像と異なり、体験を提供するインタラ クティブなメディアである.このため、音声対話コンテンツを 一方向に提供するだけでなく、ユーザの話した内容や受け答え への反応などの動向をクリエイタへ強くフィードバックする仕 組みが重要であると考える.フィードバックによって、想定と 実際が噛み合ったより質の高いコンテンツへと発展することが 容易になることが期待される.また、ユーザの反応が積極的に クリエイターへフィードバックされることは、クリエイターへ 満足度等のインセンティブ付与や、新たなコンテンツへのアイ デアを供する効果も期待される.

# 3. 対話プロファイルの自動収集およびフィー ドバックの実現

コンテンツをユーザが利用した際の利用情報(対話プロファ イル)を自動収集し、コンテンツ作成者へフィードバックする システムを提案する.



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

図 3: 提案システムの全体像

#### 3.1 対話プロファイルからのフィードバック

図2に,対話プロファイルから得られるフィードバックの例 を示す.図の左側は対話コンテンツにおける対話シナリオ(状 態遷移モデル)である.ユーザが実際に辿った対話の状態遷移 と各状態における発話内容,滞在時間を記録し,その情報を収 集することで,状態ごとの利用率やユーザ離脱率,応答できな かった発話リストが得られる.これにより,シナリオ上で定義 したが実際には利用されない対話パターンの検出や,ユーザが ある状況で頻繁に発話するが対話シナリオで対応できていない パターンの抽出,ユーザの嗜好などが把握できる.

#### 3.2 対話プロファイルの自動収集

提案システムの全体像を図3に示す.音声対話コンテンツ の構築環境として,編集中の対話シナリオの対話状態遷移をグ ラフィカルに表示可能な MMDAgent 用の対話シナリオ編集 環境 HELEN\*1を用いる.コンテンツ再生アプリは,ログ記 録・収集機能を持つ Pocket MMDAgent[4]を用いる.Pocket MMDAgent は,コンテンツ利用時のログをサーバへ自動アッ プロードする.アップロードされたログからサーバ上でプロ ファイル情報を集計・抽出し,コンテンツ開発元のクリエイ ターへ提供する.HELENでは提供されたプロファイル情報か ら対話シナリオの状態遷移図(図3右部)上に利用率を色分 け表示するとともに,利用率,離脱率,平均滞在時間および認 識単語リストを状態ごとにポップアップ表示する.これによっ て,フィードバックを確認しながら編集を行える.

# 4. 評価実験

まずフィードバックがコンテンツ構築に与える効果について 検証した.10名の学生を対象に,既存の作成済み音声対話コ ンテンツ(自己紹介・10対話)を与え,エディタを用いて自由 に対話内容を追加してもらう実験を行った.まずプロファイル なしの状態で課題を行い,次に事前実験で収集したプロファイ ルに基づいたフィードバック情報を表示した状態で課題を行っ た.利用後にアンケートによる主観評価を行った結果を表1に 示す.フィードバック情報は音声対話コンテンツの制作・更新 の際に有用な情報となり,認識単語リストおよび利用率表示が 有用であることが示唆された.一方,離脱率表示はあまり有 用でなく,複雑なコンテンツの制作にも大きくは寄与しなかっ た.コンテンツの修正や簡易な追加といった小規模の修正には 有用であるが「新たな対話内容を発想する」という創作に近い 行為への敷居を下げる効果は小さかったといえる.

| 表 1: 実験結果          |         |  |  |  |
|--------------------|---------|--|--|--|
| 質問内容               | 評価(5段階) |  |  |  |
| コンテンツ制作に役立ったか      | 4.0     |  |  |  |
| 編集が楽になったか          | 4.0     |  |  |  |
| コンテンツ制作の敷居を下げると思うか | 3.2     |  |  |  |
| 思い通りにコンテンツを制作できたか  | 4.0     |  |  |  |
| 今後もツールを利用してみたいか    | 3.7     |  |  |  |
| 認識単語リストは有用だったか     | 4.5     |  |  |  |
| 離脱率表示は有用だったか       | 2.7     |  |  |  |
| 利用率表示は有用だったか       | 3.9     |  |  |  |
| コンテンツ制作を手助けするか     | 3.8     |  |  |  |
| 複雑なコンテンツを制作できたか    | 3.1     |  |  |  |
| 簡単にコンテンツを制作できたか    | 4.0     |  |  |  |
| コンテンツ制作の励みになったか    | 4.1     |  |  |  |

プロファイル情報の創作行為への効果をさらに調べるため, 実際にクリエイターとして活発に活動しているアマチュア創 作者(対話システムは構築未経験)に本システムを利用しても らう実験を行った.システムを口頭説明し、3Dモデルなど素 材を提供したのち、3週間の期限で自由にコンテンツを創作し てもらい,実験後にインタビューを行った.作成は期間を前半 と後半に分け, 前半で作成したシステムを数人のユーザに利用 してもらい,そのフィードバックを与え,後半の作成を行うよ うにした.結果として、クリエイターが構築したコンテンツ は、早口言葉を認識するゲーム(150状態・200遷移)であっ た.インタビューの結果,利用率や認識単語リストがユーザ動 向の把握に重要な手がかりとなり、コンテンツ制作における有 効な指標となり、コンテンツ創作のモチベーションとなること が示唆された.一方で,開発当初に想定した内容以上のものが フィードバックによって新たに生まれることはなかった. モチ ベーションの維持には、今回のようなパッシブな情報だけでな く、ユーザからのコメントや要望といったアクティブなフィー ドバックも必要であると考えられる.

#### 5. おわりに

音声対話コンテンツにおいて対話プロファイルの自動収集と フィードバックがコンテンツ循環の一助となることを示した. 今後の展開としては,音声対話コンテンツ配信の仕組みやユー ザ間の体験の共有方法,アクティブなフィードバック,大規模 実験等が挙げられる.

- [1] 宮木京介,飯塚遼,李晃伸,"利用者による履歴付き対話の共同構築・拡張が可能なユーザ生成型音声対話システム",日本音響学会秋季研究発表会講演論文集,3-Q-22,2015.
- [2] 飯塚遼, 李晃伸, "ユーザ生成型音声対話システムにおけるクリエ イターとユーザの相互刺激によるインセンティブ向上の検討", 研 究報告 自然言語処理(NL) 2014-NL-216(6), 1-6, 2014.
- [3] 関亜紀子, 亀山渉, "コンテンツ循環における権利詠唱の自動化", 情報処理学会論文誌, Vol.48, No.5, p.1952-1964, 2007.
- [4] 李晃伸,"音声対話コンテンツのネットワーク配信および大規模ロ グ収集を可能にするスマートフォン版 MMDAgent の開発",日 本音響学会秋季研究発表会講演論文集, 2-2-8, 2019.

<sup>\*1</sup> 近日中に GitHub にて公開予定

# 2-5-1フレーズ練習記録の一人称研究を例にした ジャズ即興演奏生成システムのための検討

A Discussion about Jazz Improvisation System based on Studies with First-Person's View

# 安藤大地<sup>\*1</sup> Daichi Ando

\*<sup>1</sup>首都大学東京システムデザイン学部 Faculty of System Design, Tokyo Metropolitan University

In this paper, the author shows an example of jazz improvisation acquisition process record based on the author's own first-person view research. The example is about practice and cognition of 2-5-1 harmony progresses and phrases. The record indicates that musician's cognition of internalize process can be clearly described in such a way as to rule . Then the author discusses possibilities of that it is effective to adopt musician's knowledge into the art creative machine learning system.

# 1. はじめに

本稿では、ジャズ即興演奏生成システムの構築を目的とし、 著者自身の一人称研究的記録の中の 2-5-1 フレーズの部分を例 に事例と問題点を示し、それを元にジャズ即興演奏生成システ ムに人間と共通の音楽的知識を取り込むことの有効性について 議論する

著者は、人間と音楽知識を共有する作曲システム・即興演 奏システムの実現のために、主に遺伝的プログラミング (Genetic Programming, GP) と対話型進化論的計算 (Interactive Evolutionary Computation) へ人間の音楽知識への取り込み を進めている [安藤 05, 安藤 12, 安藤 17, 安藤 18a].

近年のトレンドである DNN を用いた音楽生成では Google Magenta の例があるが,実際に Google Magenta をクラシック 音楽の作曲家が用いた例では,少なくともクラシック音楽に適用 した場合には十分な表現力がないという意見がある [大久保 17]. また, Cope は LISP のプログラムが,作曲家が作曲を行う過 程のような音楽の高レベルでの表現に有効であると述べてい る [Cope 05]. OpenMusic という最も成功した作曲支援ソフ トウェアも LISP である.

LISP が音楽家にとってベストな音楽生成記述言語であるか の議論は難しいが、少なくとも DNN 的表現による音楽生成よ りは音楽家にとって理解しやすい・記述しやすいということが できる. Cope は、この理由は音楽的知識を音楽的知識のまま 入れ込むことができるからであるとしている.

よく知られている一番最初の機械学習的なジャズ即興演奏 (ジャズアドリブソロ) 生成システムは遺伝的アルゴリズムを 用いた GenJam [Biles 94] である. GenJam の染色体コーディ ングに音楽的知識はほぼ入っていない. Google Magenta の DNN 表現は LSTM と同様の表現ノードにより極短期的な時 系列的な表現が可能になっているという意味では GenJam に 比べ発展しているが,その時系列表現が音楽としては極短期出 来であること,音楽表現に特化したノードではないことから, 音楽表現力が低いのではないかと著者は考えている.

さらに DNN 表現を用いた機械学習では、データ収集も含め 学習に非常に大きなコストがかかることを考えれば、DNN 表 現ではなく、「人間の音楽家が定めた(音楽的に破綻せず、そ れになりのものが生成できることが担保されている,さらに 人間の音楽家の個性が反映されている)ルールを元にし,その 組み合わせを学習する」といった方針の方が,より良い結果を 生むのではないかと,著者は考えた.この「人間の音楽家が定 めたルールの組み合わせ」は前述の通りLISPで表現すること が容易であり,多くの音楽家が理解し,自ら記述することがで きる.

また「音楽的知識」だけでは音楽の生成は不可能もしくは不 十分なのではないかという議論もある.例えば即興演奏におい て,五線譜上に表現できる音楽知識ではなく,楽器と身体の関 係性で感覚で演奏が行われていることは,Sudnow[Sudnow 79] をはじめとしてジャズピアノのトレーニング等では一般的に知 られている.

本稿ではジャズのアドリブソロの単旋律の生成にターゲット を絞り,既存の研究の例を挙げ,さらに著者自身が一人称的に 記録してきたジャズアドリブソロ生成の練習メモに対する考察 を行う.

# 2. ジャズ即興演奏の「音楽的知識」と「音楽 以外の知識

Sudnow は,自身のジャズピアノの習得過程の記録 [Sudnow 79]の中で,音名等の音楽情報ではなく鍵盤に対する 指の動きという身体性のみで記述を行った.鍵盤楽器は五線譜 に一番マッピングしやすい楽器であるが,Sudnowの五線譜な しで指がどのように動くかのみでの即興演奏の習得過程の記述 により,鍵盤楽器と指の身体性が少なくとも一部のジャズピア ニストには五線譜よりも重要であることを示している.

著者は、ジャズ即興演奏生成に機械学習を適用するにあた り、断続的に人間の演奏家への聞き取り調査とそれを元にした 生成ルールの構築[安藤 15]を行なった.

聞き取り調査では、アマチュアベーシスト初学者を対象とし て、どのようにアドリブを生成しているかのインタビューを元 にベースライン生成のルールベースのモデル化を行ったが、人 間の生成モデルは、抽象化された五線譜上のような音楽的情報 のルールの組み合わせで表現できるわけではなく、身体性と楽 器構造が生成されるフレーズに大きな影響を与えていることが わかった.具体的には、初学者であればあるほど、ベースライ ンの構成音を「音」「音名」「階名」「コードの中の度数」など の音楽的情報としてではなく、「指のポジション」として把握し

連絡先: 東京都日野市旭ヶ丘 6-6, TEL:042-585-8074, dandou@tmu.ac.jp

ており、リードシートからのコードネームの視覚的入力が音楽 情報ではなく身体動作に結び付けられていたことがわかった.

Sudnow の記述と著者のインタビュー結果から,鍵盤楽器・ 弦楽器など「楽器中の特定の箇所・ポイント」に音高が割り当 てられ,手指がそのポイントを移動することによって音高を選 択する楽器では,少なくとも初学者の間は音楽情報よりも身体 性が重要であることが示唆されている.

これらの事例から、Google Magenta のような音楽的情報要 素のみから構成される汎用的なモデルを用いた音楽表現には限 界がある、もしくは学習コストが非常に大きくなってしまい、 実用レベルで人工知能を用いた音楽生成を行うためには、ジャ ンル・楽器ごとの音楽知識や、楽器ごとに身体性のみならず楽 器特有の音楽認知を適切に取り込んだ知識が必要である、と著 者は考えた.

# 2-5-1フレーズ即興演奏練習の一人称的記 録と考察

そこで著者は、自身を被験者としてジャズサックスの即興演 奏を習得する過程を一人称研究的に記録することを行ってきた [安藤 18b].前述のベース、ギターの例や Sudnow のピアノの 身体性が強く反映する例とは異なり、手の位置が基本的に動か ない管楽器の場合、音名でフレーズを認知する必要があり、弦 楽器や鍵盤楽器とはその習得過程における認知の仕方が異なる ことが予想される.

被験者でもある著者は、音楽大学の声楽学科の在籍経験を 持ちクラシック演奏のフレージングの基礎能力を有している. また作曲を行なっておりジャズの理論を理解するのに苦労する ことはないという特徴を持っている.

この記録の過程では、ジャズサックス演奏者に指導を仰ぎ練 習法の指導を受けるだけではなく、自身で考えた練習法を試し て、「どのような練習をしている段階で、どのような獲得感が 得られたか」を詳細に文章と五線譜に表記したフレーズにより 記録した.

本稿では、そのなかの 2-5-1 フレーズに関する記録を抜き出 てまとめて提示し、議論を行う.

2-5-1, または 1-2-5-1 とは「トニック (1) - サブドミナント (2) - ドミナント (5) - トニック (1)」という,「安定 - 緊張」 を行き来することにより「解決」感覚を表現する典型的な和 声進行の典型例の一つである. ハ長調 C-Major スケールでは 「CM7 - Dm7 - G7 - CM7」という進行になる. クラシックや ジャズなど多くの西洋音楽はこの繰り返しによって成り立って いる. その最初のトニック (1) を外したものが一般的に 2-5-1 と呼ばれる.

ジャズではこの 2-5-1 進行を用いた部分転調がドッペルドミ ナント等により頻繁に行われ,曲全体の調・キーからこの部分 のコードを切り離す必要があるため,この部分のみの進行を内 在化する練習を行う必要があるとされる.

# 3.1 和声感覚の習得過程の記録と考察

#### 3.1.1 指示された練習

まず、コードトーンのアルペジオで 2-5-1 の音高の音名を把 握する練習法を指示された. 図1に、練習フレーズの C-major での例を示す.実際の練習では、このような五線譜上に記譜さ れた音符を見てではなく、コードネームを見ながら根音からの 音程を度数を頭に思い浮かべながら音名に変換して行なった. (図1の例の3小節目の前半ならば、練習時に頭に浮かべるの は「Dm7,7531」であり、「Dm7:7 →ド、5 → ラ、3 → ファ、1 →レ」と逐次認識していく)



図 1: 練習用として指示された,または著者自身が考えた 2-5-1 のコードトーンアルペジオフレーズ.





図 2: 著者の中でのクラシックとジャズの調性の把握感覚の違い. クラシックの和声進行は調・キーに内包されているのに対して, ジャズ即興演奏の場合はコード進行の中の属七 (図中「V7」)が部分転調の調・キーを生成しているイメージ. クラシックとジャズでは五線譜上での表現に差がないのに, 演奏時の著者の「認識」もしくは「認知」は明らかに異なっている.

#### 3.1.2 和声感覚把握時点での著者の問題点と考察

一般的にアヴェイラブルノートスケールに基づきジャズの即 興演奏を行う場合,本来2の和音(図1中Dm7の部分)のス タート時点で5-1(図1中のG7→CM7の部分)に到るまでの 調号を把握している必要があるが,著者は図1に示したフレーズの練習を始めてから2年以上経っても5の和音(クラシック 和声で属七と呼ばれる和音)のアルペジオに到るまで,全体の 調号を把握する,つまり調性を感覚的に明確に把握することが できなかった.「頭と指ではわかっているのに,聴取感覚がつい てこない」とも言える.音楽の原理的には属七のみが調・キー を決定するのはクラシック・ジャズ双方で自然なことであり, 五線譜上に表現してしまえばどちらにも差がないのだが,著者 は自身の「認識」もしくは「認知」の感覚の違いに注目した. 図2に著者のクラシックとジャズの2-5-1の和声進行の感じ 方の違いを,記述したメモを元に表した模式図で示す.

クラシックの演奏やルールベースの音楽生成システムを考 えた場合,調・キーは主旋律から導き出され,演奏を始める前 に既知であることが前提であり,コード進行も調の中に内包さ れている範囲に限定される.このような著者の様な「調がわからない」感覚は発生しないと考えられる.転調の際も「ディアトニック転調」と呼ばれる手法では移動する先の調・キーがわかっていることが一般的である.

それに対して、ジャズの即興演奏の時はコード進行のみが提示されており、調整を決定づけるような主旋律の提示は行われない.この状態では「それまでに演奏された旋律」が調性のガイド足り得ないため、5のコード「属七」が出てくることのみが、その部分の調整が決定する要因となっている.

しかしながらクラシック経験者の著者がこの練習をする時に 感じた「属七」が出るまでわからなってしまう感覚は、ジャズ 特有のごく短短いスパンでの部分転調の極端な多さや、アウト 感を演出するために別のコードとも捉えられるテンションノー トを中心とした音使いをする場合には、適切な認知なのではな いかと考えた.

著者の場合のクラシック的な感じ方はトップダウン的な音楽 知識に基づくのに対して,ジャズ的な感じ方は「生成的」であ る,とも言える.

前述の通り五線譜に記述,つまり五線譜上の音楽表現になっ てしまえばクラシックとジャズのアドリブソロは全く同じルー ルで表現可能なのだが,そのバックグラウンドの和声進行の感 じ方には,このように大きく違いがあることがわかった.

# 3.2 曲中での 2-5-1 フレーズ演奏の習得方法

次に実際の曲での 2-5-1 フレーズの使用についての練習の記録について述べる.

# **3.2.1** 一般的な習得方法

曲中で 2-5-1 を即興演奏する一般的な習得方法としては,

- 1. 多くの演奏家が残している 2-5-1 フレーズ (リック) をコ ピーする.
- 2. そのフレーズを主要キーに移調できるようにする
- 3. ターゲットとなる曲の進行中に 2-5-1 を探して, コピー してきたフレーズを当てはめる

という手順が推奨されている.実際に著者もそのような指 導を受けた.ここで1.の「多くの演奏家が残している2-5-1 フレーズ」とは、ジャズ特有のアウト感を出すための非コー ドトーン(オルタードスケールやコンビネーションオブディミ ニッシュスケールに含まれている音高)が多く含まれており、 演奏家がフレーズのストックを増やして使うことで自然にアウ ト感を出せるようになっている.

#### **3.2.2** 著者の問題点と解決法

しかしながら著者の場合,「あらかじめ覚えたフレーズを演奏し出すと,コードトーンが頭の中で鳴らなくなってしまう. 認識できなくなってしまう」という問題が発生した.この現象 はクラシック演奏経験者で即興演奏を習得しようとする人間に は頻繁に見られる傾向のようで,音楽大学でピアノ即興演奏を 教授している指導者から同じような状況が多く見られることを 伝えられたことから,いわゆるフレーズを認識し演奏するとい うクラシックの練習経験やフレージングの発想が,コードトー ン認知の邪魔をしているのではないかと考えた.今後聞き取り 調査も含め詳細な研究が必要である.

そこで著者は、コピーをしないでコードトーンと9度13度 の音を使って「生成的に」演奏をする方向に練習切り替えた. いわばこれは「与えられたフレーズをそのまま覚えるのでは なく、与えられたフレーズをマルコフ過程的に一度分析してそ の生成モデルを獲得する」と言える.アウト感を出すためには チャーリー・パーカーが取り込んだとされるドビュッシーやラ ヴェルの考え方をそのまま用い [Amy 86],「より解決感を強く 出すための基本の属七からズラす」と捉えることとした結果, アウト感を持つ 2-5-1 フレーズを即興演奏で生成ができるよう になった.

フレーズの場合も和声感覚の時と同じく、フレーズを覚える トップダウン的な知識に基づくのに対して、実際に著者が自然 と感じた方法は生成的とも言える手法であると言える.

#### 4. 考察

ここまで即興演奏習得に関する既存研究と,著者の2-5-1フ レーズの即興演奏習得について一人称的記録をまとめた.

既存研究の調査では、即興演奏には楽器によって身体知が大 きく影響している可能性があり、単なる五線譜ベースの音楽知 識の表現だけでは即興演奏の表現そのものが難しいのではない かと推測した.

また,即興演奏習得過程の記録のまとめから,クラシック音楽の演奏者としての経験があり,かつ理論的には一般の学習者よりも高いレベルにある著者の場合,1.和声進行把握がクラシックとジャズで異なっている,2.クラシック音楽演奏経験のフレーズ把握認知が邪魔をしジャズの一般的なリックを習得する練習法では効率が悪い,と推測した.

このように一言にジャズの即興演奏生成モデルと言っても, 演奏する人間の音楽的バックグランドによりその認知の仕方, 感じ方も様々であり,それが演奏者の個性のような演奏の違い を生んでいると言うことができると著者は考えている.個性が 多く反映されることが「創作において評価されるクリエイティ ビティ」だとするするならば,創作に機械学習を用いる時に音 楽の良さ・演奏の個性に絶対的な評価ができなくなってしまい, 機械学習を行うためのモデル化の際に特定のモデルを「いいモ デル」であると決定することは難しくなる.

また,著者が行ってきたように,訓練された音楽家は,自身 の感じ方の分析やとった解決法などを明確に記述できることが わかった.和声感覚の認知では自らの感じ方を元にクラシック とジャズの和声感覚の違いを図示することができた.曲中での 2-5-1 フレーズの演奏習得では,既存のフレーズを使わずに分 析することでその生成モデルを獲得することが自身にとって自 然であることを「コードトーンが頭の中で鳴らなくなる」とい う問題と共に考察することができた.

Google Magenta では、ジャンルを問わず同一のモデルによ り学習を行う.しかしこのようにクラシックとジャズ即興演奏, または楽器,演奏家のバックグラウンドにより認識・認知が大 きく異なることからも、よりジャンルや楽器に特化したモデ ルを用意する必要があるのではないか、と著者は考えている. さらに、このように明確に記述された内容が表す音楽的知識に 基づく認知・生成モデルは、Google Magenta のような DNN での音楽表現モデルよりも高レベルでの認識・認知であり、同 様に音楽認知科学でのモデルよりも高レベルであると言える. また、Google Magenta のモデルは音楽家からみれば非常に非 合理な表現をされているということもでき、音楽家の認知を取 り込む、すなわち人間の音楽家と知識を共有できるモデルを導 入すれば、機械学習の効率は大きく上がると著者は予想して いる.

# 5. おわりに

本稿では,ジャズ即興演奏習得に音楽知識以外の身体性を 考慮する必要性があること,著者自身の一人称研究に基づく ジャズ即興演奏習得過程記録の例を挙げ,習得過程の認知が人 によって大きく異なり,単に五線譜上で表現できる音楽知識だ けではジャズ即興演奏を表現し切れない可能性,の2つを示 した.

今後は、楽器ごとに聞き取り調査などを進め、人間が把握し ている演奏生成モデルの実例の様々なパターンを作成し、人間 と音楽知識を共有する機械学習のための高レベルなモデルへの 応用を目指す.

- [Amy 86] Dommel-Diny, A., 笠羽 映子:ドビュッシー, 演奏 家のための和声分析と演奏解釈 / アミ・ドメル・ディエニー 著, シンフォニア (1986)
- [Biles 94] Biles, J.: GenJam: A genetic algorithm for genrating jazz solos, in *Proceedings of 1994 International Computer Music Conference*, Arhus (1994), ICMA
- [Cope 05] Cope, D.: Computer Models of Musical Creativity, MIT Press, Cambridge (2005)
- [Sudnow 79] Sudnow, D.: Ways of the Hand The Organization of Improvised Conduct, MIT Press (1979)
- [安藤 05] 安藤 大地, Dahlstedt, P., Nordahl, M. G., 伊庭 斉 志:対話型 GP を用いたクラシック音楽のための作曲支援シ ステム, 芸術科学会論文誌, Vol. 4, No. 2, pp. 77–86 (2005)
- [安藤 12] 安藤大地: クラブ系ループ音楽パフォーマンスのためのリアルタイムに音楽を Breeding するシステム, 情報処理学会論文誌, Vol. 53, No. 3, pp. 1030–1040 (2012)
- [安藤 15] 安藤 大地:ジャズ即興演奏における 4 ビートベース ラインの 2 段階対話型遺伝的プログラミングによる生成,情 報処理学会インタラクション 2015 シンポジウム (2015)
- [安藤 17] 安藤 大地:対話型遺伝的プログラミングを用いた無 調性音高配列からの和声進行の生成,情報処理学会インタラ クション 2017 シンポジウム (2017)
- [安藤 18a] 安藤 大地: CPPN 表現と Neuro-Evoluation を用 いたエレクトロニカのためのノイズ音素材生成, 情報処理学 会インタラクション 2018 シンポジウム (2018)
- [安藤 18b] 安藤 大地: クラシック演奏家のジャズ即興演奏習 得過程の記録と考察, 日本音楽即興学会第10回大会 (2018)
- [大久保 17] 大久保 雅基:携帯音楽プレイヤーを使用した遠隔 演奏同期システムの考案,先端芸術音楽創作学会会報,第9 巻 (2017)

# 人工知能のファッションデザインへの適用可能性: ファッションの文化的背景からの考察

Of application of artificial intelligence to fashion design: based on the analysis of cultural background of fashion

藤嶋陽子\*1\*3 Yoko Fujishima 佐倉統\*2\*3 Osamu Sakura

\*1 東京大学大学院学際情報学府 Graduate School of Interdisciplinary Information Studies, The University of Tokyo \*2 東京大学大学院情報学環 Interfaculty Initiative in Information Studies, The University of Tokyo

\*3 理化学研究所革新知能統合研究センター RIKEN-AIP

Abstract: We argue that how AI can be applied to the field of fashion design. Historically, fashion inherent peculiar negative attitude toward technology, related to the traditional thought against artistic object and mass production. This philosophical background would be significant for the evaluation of an impact of AI upon fashion design. Moreover, based on the analysis of the current technological character of AI and several experimental trial which AI designs fashion, AI has affinity with the design process in fashion. However, the current technological mechanism of AI corresponds with only primary research process in the inclusive flow of fashion design. The value system of fashion strongly depends on the sensibility of the fashion designer, and it closely linked with the inclusive process, rather than each step. Therefore, AI requires the symbiosis with human designers to create value in the context of fashion design.

# 1. はじめに

あらゆる分野でそうであるように、今日のファッション業界にお いても人工知能の導入というのは大きな注目を集めている.この 革新的なテクノロジーの導入をめぐって,どういった行為者がイ ニシアチブをとるのか、どのように普及するのか、これは未来の ファッションのゲームセッターを決めるのと同義かもしれない. そ れゆえ,巨大な資本を導入した大型プロジェクトがすでに遂行 されている. その最たる例が, アメリカの amazon 社による人工知 能デザイナーの開発企画であろう.これは画像からトレンドやス タイルの学習を試み、類似するデザインを作成、製品化するア ルゴリズムの開発を目指すものである. また, IBM とトミー・ヒル フィガー,そしてニューヨーク州立ファッション工科大学(FIT) Infor Design Tech の共同プロジェクトでは、トミー・ヒルフィガー の製品やコレクションの画像,模様や型紙などを学習させ,デザ インのインスピレーション源として用いた. さらにはデータ分析の 世界的カンファレンスである Knowledge Discovery and Data Mining (KDD) においても AI for Fashion というワークショップが 開催されており,特に技術開発の方面から人工知能のファッシ ョン分野における適用可能性が問われている.

このように既に多様なプロジェクトが進められているわけだが, 現在の開発方向性は主に,トレンドや消費者の購買データを利 用した生産や流通の最適化などである. EC 販売が拡大してい る今日,購買履歴や消費傾向といったデータの収集は容易に なっており,こういった顧客データとブランドの販売実績やトレン ドリサーチを結びつけた確かなデータを活用していくことは,社

連絡先:藤嶋陽子,東京大学学際情報学府/理研 AIP,東京 都文京区本郷 7-3-1, yokofujishima@g.ecc.u-tokyo.ac.jp 会問題として着目されつつある在庫廃棄の問題を考えるうえで も重要となっている. 生産, 流通のサイクルが非常に短くなり, 消費者のニーズも多様化している今日のファッション産業にお いて,人工知能を活用した商品制作への期待がさらに高まって いくのは間違いないだろう.

しかし、ファッションには芸術としての側面もある. 芸術品と商 品というふたつの性質は、有名デザイナーによるいわゆるハイフ アッションと大量生産されるマスファッションという区別とも重なり あう. それは、作品と製品という括り方の差でもあるかもしれない. こういった作品としての価値は、デザイナーの文化的背景、時 代感覚,既成概念に囚われない批判的な視点,そういった要素 がオーディエンスと共鳴することで生み出され,芸術や歴史的 な文脈から評価される.人工知能による創造活動の可能性を めぐっては,芸術分野は既に直接的に回答が試みられ,技 術的な可能性を問うだけではなく、アーティストとの協働 関係や美術マーケットにおける評価などを考察するうえで 重要な知見を提示する. 例えば 2018 年には、イギリスで は AI の描いた裸婦画が世界的な芸術賞であるルーメン賞 で金賞を受賞したり、アメリカでは AI の描いた肖像画が クリスティーズのオークションにおいて 43万 2500 ドルで 落札されたりといったニュースが注目を集めた. こういっ た芸術分野での取り組みに対し、ファッションにおいても 同様に人工知能によるデザインを創造性という観点から評 価し得るのだろうか.この問いに解答するためには、ファ ッションという対象の性質―単純に芸術作品,製品のどちら かではない、この曖昧さがファッションの固有性でもあり、捉えが たさでもある[Choi 18] —を考慮し, ファッションに固有のテクノロ ジー観や、デザイナーという仕事の役割や制作プロセスと人工 知能の技術的特性を重ね合わせて検討していく必要があるだ

ろう.

こうした視座のもと本研究では、ファッションとテクノ ロジーの関係を歴史的な文脈を踏まえつつ、デザインプロ セスと人工知能の技術的特性の親和性について検討を行う. そのうえで、ファッションデザインとの親和性と将来的な 課題を明らかにし、ファッションとテクノロジーの関係性 を批判的再考して更新することを試みる.

# 2. ファッションにおけるテクノロジー観

2016 年のニューヨーク,メトロポリタン美術館ファッション部門の企画展であった"MANUS×MACHINA"は, Apple 社がスポンサーとなり,ファッションにおける機械 技術の位置付けを問い直す挑戦的なプロジェクトだ.そし て,ファッションの歴史のなかでのテクノロジーの位置付 けに対し,極めて重要な示唆を与えるものとなった.

この展覧会の序文のなかでキュレーターのアンドリュ ー・ボルトンは、人間-対-機械という構図がいかにファッ ションの制度のなかに定着し、その価値と結びついている かを語っている[Bolton 16]. ボルトンによると, 19世紀中 盤にオートクチュールという制度が確立してから、ファッ ションでは手仕事と機械が対立関係に置かれ、この構図が 規定されてきた.ファッションの歴史のなかで、もっとも 影響を与えたテクノロジーはミシンである. ミシンの登場 は衣服の生産のスピードを大幅に早め、大量生産とそれに よる低価格化を実現させた、それ以降、テクノロジーは大 量生産と結びつけられ,機械で作られたものは手仕事より も価値の劣るものと捉える価値観が定着した. そしてこの ハンドメイドとマシーンメイドを対立させる構図は思想的 なレベルだけではなく、オートクチュールの組合であるサ ンディカ協会への参入条件に手仕事が必須とされるという 公式の制度として具現化しており, 注文服であるオートク チュールと既製服のプレタポルテの区分とも重なり合って いる.この大量生産との結びつきや複製される既製服に対 するまなざしは、展覧会の副題が "Fashion in an Age of Technology"であることからも示唆されるように、ヴァル ター・ベンヤミンの提起した機械的な複製と芸術をめぐる 議論のもとにある[Benjamin 08]. 唯一無二のオリジナル であること、それが芸術作品の要件とされるような伝統的 思想のなかで、複数作られるということは芸術的価値を否 定する論理となる. それゆえ, 機械で作られたものはどこ か無機質で、規格化されたものは平板なものであるような 印象となるのだ.

そのうえでボルトンは、オートクチュールも実際のところはミシンや標準パターンといった大量生産の技術とされるものに支えられて発展したと述べている.実際、オートクチュールの"父"と言われるチャールズ・フレデリック・ワースのクチュールハウスは、ミシンによる生産に依拠して事業を国際的な規模のものに発展させた.そして現代の最先端技術、例えば3Dプリンターや超音波圧着、レーザープリンターといったものは、オートクチュールとプレタポルテの両方に用いられ、デザイナーの創作を支えている.それゆえ、この展覧会での最終的な主張は、こういったオートクチュール・対・プレタポルテ、ハンドメイド(人間)・対・マシーンメイド(機械)という二項対立の構図を再考する必要があるということであった.

大量に生産されて大量に販売され利益を拡大させること, 生産数を制限してプレミアムな価値を守ること,ファッションは常にこの両義的な志向性を有する.ミシン以降,フ アッションに関わるテクノロジーの進化は、従来は不可能 であった創造的な表現を実現可能とする一方で、表現を容 易とすることはやはり生産を容易にすることであり、複製 性からも逃れることはできない.ファッションにおけるテ クノロジーは、生産の拡大と豊かな創造の実現—この相反 するふたつの可能性を有するものなのだ.

# 3. ファッションの制作プロセスの親和性

こういったファッションデザインに内在するテクノロジ ーへの否定的価値観に対し、人工知能はそれを変える―も しくは強化するものなのだろうか.また、そのうえでファ ッションデザイナーたちにどのように活用されていくと考 えられるのだろうか.ファッションデザインにおいて人工 知能が受容される可能性を議論するためには、その技術的 特性を確認し、ファッションデザインの制作プロセスとの 親和性を考察する必要がある.

現在の人工知能技術の中核は machine learning, すなわち, コンピュータ・プログラムが新たな課題 task や外的環境の変化を学習し, 適切な解 solution を見つけることを可能にする技術である. とくに,入出力のノード nodes が複数 (4 層以上) の階層 layer から成る—人の脳により近い—neural network の学習 (deep learning, or deep neural network) 技術が実現したことにより, 複雑な学習が可能になった.

deep learning 技術の進歩はとても急速なので、近い将来 人工知能/ロボットの知的能力が人類のそれを上回り,人 工知能/ロボットが人類の制御がきかない状態で暴走した り、さらには人類を支配する可能性があると予測する人た ちもいる[e.g., Kurzweil 05; Bostrom 14]. 現にデザインの 領域においても、既にウェブデザインやロゴのデザインの 自動生成サービスなどが登場しており、人間が行わないと 難しいと考えられていたクリエイティブ領域にも着実に進 出してきている.人工知能/ロボット技術の特徴のひとつ は、高度に自律的 autonomous であることだ. 自律的シス テム autonomous system, or "AS" が人間の知能の少なく とも一部を凌駕することで、多くの仕事がこれらの AS で 代行されるだろうし,人間にしかできない作業は何なのか, 再検討がなされていくだろう. すなわち, 人と機械がどの ように(共存 co-existing ではなく) 共生(sybiosis) するの かを再検討する必要に私たちは迫られている [Tegmark 17]. この点で、ファッション・デザインという、非常に 「人間的」なセンスが重きをなしている領域で,人工知能 と人の共生系がどのような状態になるのかを考察すること は,ファッション研究だけでなく,人工知能の研究・技術 開発にとっても有意義な作業である.

冒頭でも触れた人工知能による絵画作品やファッションデザインの試みで主に用いられているのが、敵対的生成ネットワーク Generative Adversarial Network (GAN)である.これは大量の画像を読み込ませることで人工知能が自ら共通する構造や法則を発見し、それを反映した画像の生成が可能となる技術である. 最近の事例でいうと、2018年7月にAIアーティストのロビー・バラットが、ファッションブランドであるバレンシアガの広告、ランウェイショー、広告に基づいて仮想のコレクションを生成し、話題を集めた.この例ではまだ、テキスタイルの質感が現実的ではないなどの課題があったが、2018年11月にMicrosoftが発表したチャットボット"Xiaoice"はさらにこの課題を乗り越え、生

地感までも学習し、調和を図ることを実現した.さらにこの Xiaoiceは、単語やテーマに基づいてデザイン提案することが



図1 ファッションデザインのリサーチ段階において 作成されるムードボードの例

可能であり、上記のバレンシアガ風のコレクション生成のように 特定のデザイナーの作風を模倣したものではない、新たなデザ イン提案が可能である.

つまり,現在の人工知能によるデザインは単なる複製や模倣 ではなく、新たなデザインの提案も可能な状況にある. Xiaoice も何らかの教師データに基づいてデザイン生成を行っているわ けで、それも模倣に過ぎないと考えられるかもしれない.しかし それは、人間が行うデザインプロセスにも同様の側面がある.フ アッションデザインのコレクションプロセスにおいては、コンセプト やデザインの第一段階に、リサーチの段階がある. それは、自 社や場合によっては他社の過去のコレクションやアート作品や 映画など、多様なリソースからイメージをかき集めてムードボード を作成し、コンセプトイメージを精緻化していく作業である. デザ イナー自身や,ブランドの規模によってはアシスタントが協力し てこれらの作業を行い、そこにブランドらしさやデザイナー独自 感性を加えてコレクションが作られていく. つまり, 人工知能が 行っているデザイン生成のプロセスは、ファッションデザイナー たちが通常行っている制作プロセスの流れと非常に類似性が高 いのだ.

人工知能とファッションデザイナーの制作プロセスの親和性は、 人工知能を人間のデザイナーを代替する脅威として受け止めら れるかもしれない.しかしながら、制作プロセスの親和性が高い がゆえに、既存のプロセスを簡易化するような補完的な使用もし やすいという考え方も可能である.また、既存の制作プロセスに おいては、過去のコレクションからのデザイン生成はあくまでリサ ーチ段階であり、そこからデザイナーの感性によって取捨選択 して改善し、クチュリエの技術によって具現化していく段階が必 要となる.ファッションにおける作品の評価は、作品そのものが 持つ審美性だけではなく、デザイナーのカリスマ性やブランドイ メージ、コンセプトの社会的インパクトといった作品に付随する 文脈によって規定される部分が大きい.ファッションショーでコレ クションの発表を行うようないわゆるハイブランドの制作を考える と、デザイナーはコンセプトを決め、全体の統一を図っていくデ ィレクターのような役割になる.1体1体の作品ももちろん重要で はあるが、実際のデザインの素案やデザイン案から具現化して いく作業は、アシスタントやパタンナー、クチュリエなどに委ねら れている場合が多い.それゆえ、ファッションデザインの価値の 核となるデザイナーの感性という要素は、リサーチの段階よりも むしろ、そこからのブラッシュアップしていく際のひとつひとつの 選択や、一連の制作の包括的なプロセスにおいて見出されるも のであると考えられる.

人工知能の生成するデザインは、デザインを行うという意味で は完結しているのかもしれない.しかしながら、その創作物とし ての価値を高めるのは、デザイナーという固有の人格のフィルタ ーが必要である.そこまでがファッションにおける一連の制作プ ロセスであるとすると、人工知能だけでの自動的な制作というの はそれだけでは価値を生み出すことはできず、そこにデザイナ ーの感性という別の価値を付け加えることで初めて、作品として 成立しうると考えられる.これはあくまでテクノロジーをツールとし て利用していくような志向性で、人工知能という技術の考え方に そぐわないものであるかもしれないが、ファッションという領域の 価値システムにおいては属人的な要素が大きいことを考えると、 人間との協働が必ず必要になってくるのではないだろうか.

#### 4. 今後の課題と展望

こういった人工知能を、実際にファッション産業やファ ッションデザイナーたちはどのように活用し、意義付けて いくのだろうか. この答えを出すにはまだ時間が必要であ るかもしれないが、既にデザイナーが自らのコレクション 制作に導入した事例もある.例えば,2016 年に IBM Watson が Cognitive Fashion として推進するプロジェク トの一環として、オーストラリアのデザイナーであるジェ イソン・グレッチと協力して 12 体のドレスを制作し、メ ルボルンファッションウィークで発表したものは、先駆的 な事例のひとつであろう. こういった取り組みは、デザイ ナーと共同した時に人工知能における創作がどこまで実現 可能かを考えるうえで示唆的なものである.しかしながら, 従来の人力のみで制作されたものとの差異や、 "ファッシ ョン"という社会的,歴史的な枠組みのもとでいかに評価 し、受容されうるのかを検討するためには、最終的な成果 物よりもむしろ、作品の制作プロセスに着目していく必要 があるだろう.

現段階では一般的なファッションデザインの制作プロセ スから類推して分析することが限界であったが,現在,理



図2 ファッションデザインにおける一般的な制作プロセス

化学研究所革新知能統合研究センターにおけるファッショ ンと人工知能のプロジェクトが遂行されている.これは, 人工知能の感性表現学習の可能性を検討するもので,オー トクチュールを専門に手がけるファッションデザイナーの エマ・理永と共同し,人工知能とファッションデザイナー の共生関係の構築の可能性と課題の検討を行っている.今 後はこのプロジェクトの題材として,より実証的なレベル からファッションデザイナーと人工知能の創作における協 働関係について検討していく予定である.

- [Benjamin 08] Benjamin, W.: The Work of Art in the Age of its Technological Reproducibility. In: Jennings M.W. et al., eds., The Work of Art in the Age of Its Technical Reproducibility and Other Writings on Media, Belknap of Harvard University Press, Cambridge, MA. (2008) [野村修訳: 複製技術時代の芸術作品. 所収: 多木浩 二: ベンヤミン「複製技術時代の芸術作品」精読. 岩波現代文 庫, 岩波書店 (2000)
- [Bolton 16] Bolton, A.: Manus x Machina: Fashion in an Age of Technology. Metropolitan Museum of Art, New York, NY. (2016)
- [Bostrom 14] Bostrom, N.: Superintelligence. Oxford University Press, Oxford. (2014)
- [Choi 18] Choi, K. and Lewis, V. D.: An Inclusive System for Fashion Criticism. International of Journal of Fashion Design, Technology and Education, 11(1): 12-21 (2018)
- [Kurzweil 05] Kurzweil, R.: The Singularity Is Near. Viking, New York, NY. (2005)
- [Tegmark 17] Tegmark, M.: Life 3.0: Being Human in the Age of Artificial Intelligence. Knopf, London. (2017)

# トーン特徴量を損失関数に用いたcGANでのトーン貼り

# Tone Pasting Using cGANs with Tone Feature Loss

坪田亘記 Koki Tsubota Kir

相澤清晴 Kiyoharu Aizawa

東京大学

The University of Tokyo

Tone pasting is one of the processes of manga creation and there is a demand for automatic tone pasting. In this study, we tackle a task of automatic tone pasting of manga characters. Tone pasting is difficult because tones have characteristic patterns. It is hard to learn tone patterns for usual conditional generative adversarial networks (cGANs) which are combined with  $L_1$  loss or perceptual loss. To train pasting tones in a tone pattern aware manner, we introduce *tone feature loss* to cGANs. *Tone feature loss* is the distance between tone features of target images and those of generated images. We performed experiments on two characters in Manga109 and showed our results are equal to or more visually appealing than those by a baseline method.



図 1: トーンの例. トーンには特有のパターンが存在する.

# 1. はじめに

漫画の制作において,トーン貼りは欠かせない工程である. 漫画の制作の現場では,人手によってトーン貼られている.トーンの貼り方にはアナログの方法とデジタルの方法がある.前者は,トーンを貼りたい領域の形に切り貼りするために人手が必要となる.また後者についても,領域を手動で選択する必要があり人手が必要となる.トーン貼りの自動化は,このような人手のコストを削減するため需要がある.

本稿では、キャラクターの線画に対してトーンを貼ること を目的とする.トーンは、自然画像やイラストとは異なり、特 有のパターンが存在する(図1).自然画像の生成や線画の着 色に用いられるような手法 [Isola 17, Ci 18] では、ベタに近い トーンは生成することはできるが、粗い縞模様といったパター ンは生成することが難しい.これは既存手法がトーンのパター ンを考慮していないためである.

我々は、トーン貼りの学習において、トーンのパターンを考 慮した学習を行う手法を提案する.一般的な画像から画像へ の生成の学習に用いられる conditinal generative adversarial network (cGAN)の枠組みを利用し、その学習時に、損失関 数として目標の画像と生成画像のトーン特徴量間の距離を用い る.トーン特徴量としては、同じトーン領域内では同じ特徴量 を示すものを利用する.実験により、我々の提案手法がトーン のパターンを学習しやすい手法になっていることを確認する.

連絡先:東京大学 情報理工学系研究科
 〒 113-8656 東京都文京区本郷 7-3-1
 TEL: 03-5841-6761
 Email: tsubota@hal.t.u-tokyo.ac.jp

#### 2. 関連研究

#### **2.1** 線画・漫画の着色

線画の着色は、キャラクターの線画に対するトーン貼りと、 線画内の領域を選択して色を置くという点で近いタスクであ る.pix2pix [Isola 17] では、cGAN を用いて自然画像のエッ ジから自然画像を生成している.また、cGAN は漫画の着 色 [Hensman 17, Furusawa 17] やイラストの着色 [Ci 18] でも 用いられる.本研究でも既存の線画の着色手法に倣い、cGAN を用いてトーン貼りを行う.

#### 2.2 cGAN を用いた画像生成

cGAN では、損失関数として生成画像を本物の画像に近づ けるような学習をするための adversarial loss と、タスク依存 の損失関数を組み合わせて用いる。タスク依存の損失関数とし て、 $L_1$  loss を用いる手法 [Isola 17] や、 $L_2$  loss を用いる手法 [Pathak 16]、perceptual loss [Ci 18] を用いる手法がある。

これらの手法は、トーンのパターンを考慮した損失関数とは なっていない.  $L_1$  loss や $L_2$  loss はトーンの貼り方が 1 ピク セルずれただけでも損失が発生してしまう. また perceptual loss は自然画像で学習した畳み込みニューラルネットワーク から得られる特徴量間の距離を損失関数としており、特徴量が トーンのパターンを考慮してない.本研究ではトーンのパター ンを考慮するために、タスク依存の損失関数として、トーン特 徴量の距離に基づく損失関数を用いる.

# 3. 手法

トーンのパターンを考慮するために, cGAN で用いられる タスク依存の損失関数としてトーン特徴量間の距離とする手法 を提案する.手法の概要を図2に示す.まず, cGAN を用い たベースライン手法と言える pix2pix [Isola 17] を説明した上 で,提案手法の説明を行う.

以降で数式を用いて説明するために文字を定める. x が入力 画像(線画)であり, y が x に対応したトーン付きの画像であ る.また cGAN における G が生成器であり, D が識別器で ある.



図 2: 手法概要. ⓒやまだ 浩一

# 3.1 pix2pix

pix2pix [Isola 17] は、ペアの学習データを用いて画像から 画像への変換を行う手法である.生成画像を本物の画像に近づ けるような学習を行うための adversarial loss

$$\mathcal{L}_{adv}(G, D) = \mathbb{E}_{x,y} \left[ \log D(x, y) \right] + \mathbb{E}_{x,y} \left[ \log \left( 1 - D(x, G(x)) \right) \right], \qquad (1)$$

を導入している. また, タスク依存の損失関数としては *L*<sub>1</sub> loss を用いている. *L*<sub>1</sub> loss は以下の式で定められる.

$$\mathcal{L}_1(G) = \mathbb{E}_{x,y} \left[ ||y - G(x)||_1 \right].$$
 (2)

全体の損失関数としては、この両式を組み合わせた、

$$\mathcal{L}(G,D) = \mathcal{L}_{adv}(G,D) + \lambda \mathcal{L}_1(G), \qquad (3)$$

で定められる.この損失関数を用いて,以下の式に基づき *G*の学習を行う.

$$G^* = \arg\min_{G} \max_{D} L(G, D).$$
(4)

しかし,前述したように,タスク依存の損失関数として *L*<sub>1</sub> を 用いた場合は,トーンのパターンの学習が難しい.

#### 3.2 トーン特徴量を用いた損失関数

提案手法は, cGAN におけるタスク依存の損失関数として, トーンのパターンが学習しやすいようにトーン特徴量間の距離 を用いる手法である.トーンの特徴抽出器を F と定めると,

$$\mathcal{L}_{tone}(G) = \mathbb{E}_{x,y}\left[||F(y) - F(G(x))||_1\right],\tag{5}$$

と損失関数は表される.本研究では *F* として,Gabor フィル タを用いた特徴量 [Qu 06] を利用する.この *F* は微分可能で あることに注意が必要である.

タスク依存の損失関数として *L*<sub>tone</sub> を導入した場合,全体の損失関数は以下の式で表される.

$$\mathcal{L}(G,D) = \mathcal{L}_{adv}(G,D) + \lambda_{tone}\mathcal{L}_{tone}(G).$$
(6)

この損失関数を,式4を用いて最適化する.

# 4. 実験

#### 4.1 実験設定

トーン付きの画像データセットとして、漫画画像データセットの Manga109 [Matsui 16, Ogawa 18] の漫画を用いた.デー



タセットに付与されている, "body"のアノテーションのバウ ンディングボックスに従って画像の切り出しを行い, 単一キャ ラクターについて実験を行った.対象としたキャラクターは, "平成爺メン"に登場する"留"と"タップ君の探偵室"に登場 する"篠原かもき"である.画像の例を図3に示す. "留"は トーンが粗く, "篠原かもき"はトーンが細かいことが特徴で ある.

"留"の画像は 151 枚あり, また"篠原かもき"の画像は 239 枚あった. "留"の画像は, 学習用データを 104 枚, 検証用デー タを 14 枚, テストデータを 33 枚と無作為に分割した. "篠原 かもき"の画像は, 学習用データを 168 枚, 検証用データを 20 枚, テストデータを 51 枚と無作為に分割した.

トーン付き画像と対応した線画データセットは存在しない ため、トーン除去の手法を漫画に適用した後、2 値化すること で、線画とトーン付き画像のペアを作成した.トーン除去の手 法としては [Li 17] を用いた.

ネットワークは, Isola ら [Isola 17] と同様のものを 利用した.すなわち, cGAN における生成器として Unet [Ronneberger 15] に基づいたネットワークを用い, 識別器 として PatchGAN を用いた.学習時の係数は,  $\lambda_{tone} = 100$ とした.

入力画像については,最短の辺の長さが 256 になるように アスペクト比を変更せずにリサイズした後,学習時は 256x256 にランダムクロップを行い,テスト時はセンタークロップを 行った.

#### 4.2 実験結果

実験結果を図4及び図5に示す. ベースライン手法は pix2pix である. 図4から,提案手法はベースライン手法と比較してトーンのパターンを生成できていることが分かる.また,pix2pix における  $\lambda$  が小さい場合は,トーンのパターンを生成できている部分もあるが,一方で  $\mathcal{L}_1$  の重み  $\lambda$  が小さくなることで塗るべき領域の学習が難しくなっている.図5のようにトーンが細かい場合は,提案手法・ベースライン手法いずれの場合でも十分学習できている.

# 5. 結論

本稿では、キャラクターの線画に対するトーン貼りに取り組 んだ.パターンを考慮するために、cGAN でのタスク依存の 損失関数として、目標の画像と生成画像とのトーン特徴量間の 距離を損失関数として用いた.実験により、提案手法がベース ライン手法である pix2pix と比較して、有効な場合があること を示した.

今後の展望として,2つ考えている.1つは,学習データに 存在しないキャラクターへのトーン貼りである.線画の着色の 研究のように,複数キャラクターを用いて学習することで実現 できると考えている.

もう1つは、テストデータとして純粋な線画を用いた場合 の実験である.本稿では、テストデータとして漫画から抽出し



図 5: "篠原かもき"での実験結果. ①ふくやま けいこ

た線画を用いて実験を行っている.そのため,得られた線画に は元々貼ってあったトーンの情報が残っている可能性がある.

- [Ci 18] Ci, Y., Ma, X., Wang, Z., Li, H., and Luo, Z.: User-Guided Deep Anime Line Art Colorization with Conditional Adversarial Networks, in *Proceedings of the 26th* ACM International Conference on Multimedia, pp. 1536– 1544 (2018)
- [Furusawa 17] Furusawa, C., Hiroshiba, K., Ogaki, K., and Odagiri, Y.: Comicolorization: Semi-automatic Manga Colorization, in SIGGRAPH Asia Technical Briefs (2017)
- [Hensman 17] Hensman, P. and Aizawa, K.: cGAN-Based Manga Colorization Using a Single Training Image, in 2nd International Workshop on coMics Analysis, Processing, and Understanding, 14th IAPR International Conference on Document Analysis and Recognition, pp. 72-77 (2017)

- [Isola 17] Isola, P., Zhu, J.-Y., Zhou, T., and Efros, A. A.: Image-to-Image Translation with Conditional Adversarial Networks, in *Proceedings of the IEEE Conference on CVPR*, pp. 5967–5976 (2017)
- [Li 17] Li, C., Liu, X., and Wong, T.-T.: Deep Extraction of Manga Structural Lines, ACM Transactions on Graphics, Vol. 36, No. 4, pp. 117:1–117:12 (2017)
- [Matsui 16] Matsui, Y., Ito, K., Aramaki, Y., Fujimoto, A., Ogawa, T., Yamasaki, T., and Aizawa, K.: Sketch-based manga retrieval using manga109 dataset, *Multimedia Tools and Applications* (2016)
- [Ogawa 18] Ogawa, T., Otsubo, A., Narita, R., Matsui, Y., Yamasaki, T., and Aizawa, K.: Object Detection for Comics using Manga109 Annotations, arXiv preprint arXiv:1803.08670 (2018)
- [Pathak 16] Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T., and Efros, A. A.: Context encoders: Feature

learning by inpainting, in *Proceedings of the IEEE Con*ference on CVPR, pp. 2536–2544 (2016)

- [Qu 06] Qu, Y., Wong, T.-T., and Heng, P.-A.: Manga Colorization, ACM Transactions on Graphics, Vol. 25, No. 3, pp. 1214–1220 (2006)
- [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. 234–241 (2015)

# 創作者と人工知能が創る創作の未来

# Creative Future will be Created by Contents Creators and Artificial Intelligence

# 上野 未貴 \*1 Miki Ueno

\*1豊橋技術科学大学, 情報メディア基盤センター Toyohashi University of Technology, Information and Media Center

Contents creators well consider their thoughts and feelings to represent original contents. Recently, there have been proposed lots of researches for creative contents from the several aspects in artificial intelligence field. I discuss the possibility of collaborative methods and novel representation for contents creators and artificial Intelligence.

# 1. はじめに

創作者は表現したいものをいかに伝えるかに想いを巡らせ, 創作物を創っている. その過程には、対象とするテーマだけで はなく,創作者個人の感性や体験,表現材料や技法の工夫など, 多くの要素が関わっている. 昨今, データの増加や深層学習の 台頭により,人工知能が創作物を自動生成する,解析する,ま た創作活動の支援をする、という立場の研究が増加している. しかしながら, 創作過程のすべてを担うような技術は未だ表れ ていない. 技術発展の目覚ましさから, 自動生成に関わる研究 はこれまでの創作分野を脅かすもののように見られることもあ るが、創作者と人工知能は既に協調して物を創っているともみ なせる. 例えば、画像に関しては、画像処理・描画ソフトウェ ア,ペンタブレット,などの性能向上には人工知能分野の手法 が関わっている. さらに、創作現場には、情報技術の進化が密 接に関わっている.辞書やシソーラスなどの資料の入手の易 化、オンラインでの創作者同士の交流の発展などにより、新た な表現技法が生まれ,個人の創作がより身近になったことで, 創ることのできる作品の幅が広がっている. その上で, 分野が 発展したことで生まれる新たな研究が人が創る過程にどう関わ る可能性があるのか、未来の表現がどう変容するのか、本稿で は表題のセッションに関わる研究とその展望について述べる.

# 2. 分野動向

本章では、分野を俯瞰するため創作の種類別に研究を紹介 する.創作物に関する研究は、静画、映像、音楽、俳句、刺繍 など、数多く存在するが、本稿では、言語と画像による表現を 複数組合せることで現実世界の事象や人物に限定せずストー リーを描くことが多い創作物を中心的に取り上げる.

漫画 漫画の工学的研究はコミック工学 [1] において広がり、オ ブジェクト識別 [2],漫読書意欲に関する調査 [3],メタ データの構築 [4],コマ画像生成の試み [5],など、多数の 研究 [6] がある.また分野発展に寄与するデータセットと して、日本の絶版漫画 109 冊に対しアノテーションをした Manga109[2][7],100ページの漫画に台詞やレイアウト などの情報をアノテーションした eBDtheque[8] がある.

- 小説 ショートショートの創作に関わる研究 [9],小説の自動 生成方法の研究 [10],共創による物語生成システム [11], 小説の文生成手法の研究 [12] がある.
- 絵本 子どもが ICT に触れて創造活動をするためのインタラ クティブ絵本システム [13] や、絵本の自動生成に関する [14][15] 研究が知られる.
- アニメ 中間生成物の絵コンテの作品識別 [16] などがある\*1.

# 3. 創作過程における研究の利用

以下に特に創作者が本分野の研究手法やソフトウェアを利用 できる可能性が高い観点を整理する.

#### 3.1 資料検索

創作中に必要な資料を検索するために必要となる時間は多い.特定のキャラクタを探したり,特定のシーンを探す場合である.例えば漫画に関する研究では作品の内容情報探索[17]や,ネームを検索する支援[18]がある.

#### 3.2 発想支援

用意した辞書情報から人物名やアイテム名などの名前の生 成をするツールはインターネット上の個人サイトに多数存在す る.近年のニューラルネットワークを利用した小説の自動生成 手法で全文の自動生成をすることは未だ困難だが,類似文を探 したり,部分的に自動生成された会話文やあらすじ,要約結果 を提示することで,ストーリーの発想に役立つ可能性がある.

#### 3.3 線画・着色の支援

ペイント・ドローソフトのペンの入り抜きやベジェ曲線など のアルゴリズムは長年創作に役立っている.画像処理ソフトで フィルタを適用して全体的な色彩を調整する種類や性能も向上 している.近年の技術として深層学習を利用した対話的なラ フスケッチのペン入れ手法 [19] による創作作業時間の短縮や, 深層学習を利用した自動彩色として PaintsChainer[20] がある.

# 3.4 作画·構図支援

漫画の創作支援に関する市販ソフト Comipo![21] は 3D モデ ルを配置し,関節を動かし 2D の漫画を手軽に描くなどの機能 を有する. Live2D[22] ではあらかじめパーツを分けて用意し てメッシュを適用することで自然な可変画像を作成できる.ア ニメキャラクタの正面から横へ向くなど,始点と終点のある短

連絡先: 上野 未貴, 豊橋技術科学大学, 情報メディア基盤セン ター, 〒 441-8580 愛知県豊橋市天伯町雲雀ヶ丘 1-1, E-mail: ueno@imc.tut.ac.jp

<sup>\*1 《</sup>JST 共催》人工知能はアニメを生み出せるか?-「情報ひろばサイエンスカフェ」で研究者と市民が語り合う: https:// scienceportal.jst.go.jp/reports/other/20181128\_01.html

い動作の間に必要な複数枚の画像を中割と呼び,中割を自動生成 [23] するツールが市販されている.アニメ表現で重要な髪の毛のモーションを自動生成する手法 [24] などが知られる.

#### 3.5 設定管理

ジャンルやストーリーの長さによって,人物や舞台の詳細, 伏線,起伏などを管理することが望ましい場合がある.一般的 に,創作者は紙やテキストエディタを利用し自由なフォーマッ トで個人的にメモを取ることが多い.一方で,分業が中心で工 程が多いアニメの場合には,各人物の複数の角度,感情的な表 情を描いた設定資料に加え,絵コンテ,原画などの中間媒体を 複数人で情報を共有する必要がある.設定集などの形で一部の 資料が抜粋して整理されない限り,公になることは少なく,創 作者の要望を聞き取り技術的に支援する余地がある.

# 4. 創作者との共同研究

本章では,筆者が関わる創作者と共に進める研究 [25] を,特 に漫画と小説に分けて紹介する.要素技術としては,解析・生 成両面から広いタスクを想定するものの,創作過程を工学的に 体系立て,計算機が心情や個性を考慮したストーリーの創作過 程を理解し,創作者を支援することを大きな目的としている.

#### 4.1 漫画

#### 4.1.1 データセット

筆者は創作過程を保持した4コマ漫画ストーリーデータセット [26] の構築を進めている.創作の初期からプロの漫画家と 研究者が共作した4コマ漫画のデータセットは分野初である. 既存漫画では難しかった以下の3つの観点から創作の醍醐味 であるストーリー,表現,読解の多様性を考慮している.

- オチの位置の構造を変えた同プロット別シナリオ、複数 作者による同シナリオ別表現の漫画を作成
- プロットなどの創作過程とパーツ別に詳細に分けたレイ ヤ情報を有する
- 機械学習に役立つ読者・作者双方のアノテーションを付与

#### 4.1.2 フレームワーク

4コマ漫画ストーリー理解のフレームワークを識別タスクの 組合せとして定義した.現在提案済みの識別タスクの概要を 述べる.図1に4コマ漫画ストーリーデータセットおよびフ レームワークの概要を,図2に5作者の漫画を示す.

#### 感情識別:

漫画のコマに関わる感情は大きく2種類に大別される.コ マを見たときの読者の感情およびコマ内のキャラクタの 感情である.画像情報を用いて読者がコマ全体から受け る印象として感情を識別する研究[27],自然言語情報を 用いた多層ニューラルネットワークによるコマ内のキャ ラクタの感情識別[28]に取り組んだ.4コマ漫画ストー リーデータセットは作者がキャラクタの感情を7種:基 本6感情およびニュートラルの中のいずれかから選択し てアノテートしている.

#### 順序·構造識別:

ストーリーを追うには事象の順序が重要である.計算機 が順序を識別できることは、ストーリーを理解すること につながると考え、コマの順序を識別するタスクを定義 した. Convolutional Neural Network(CNN)を用いて画像 情報から識別することに取組んだ [29].また特に4コマ 漫画ではオチの位置に基づくストーリー類型[30]が複数 あることが一般的に知られている.機械学習用に7種類 の構造として再定義し,データセットとしてその中の2 構造:4コマ目にオチがある一般(起承転結)型と1コマ 目にオチがある出オチ型の話を持つ.特定の順のコマを 対象とし,2種の構造の識別タスク[31]を定義した.

#### 多様度識別:

同じ状況を表す場合でも、絵を描く際の描き方は作者に よって異なる. 前後のコマの描き方, ジャンルに適した表 現技法、作者の個性などから、多様な描き方ができるこ とは,創作の魅力である.一方で,読者の習慣や理解力を 考慮して状況を明確に伝えるためにコマによっては一定 の好ましい描き方が存在する場合がある. 双方のバラン スの考慮は、従来、作者自身に委ねられているが、分業 制の創作でコスト面を考慮して作者に状況を説明して描 くことを依頼する立場にある者や、作者が独自性が入れ やすいコマか読者に受け入れられやすい典型的な描き方 があるかを調べたいときに、指標があれば、依頼者や作 者に役立つ創作支援ができると考えた.漫画雑誌の投稿 コーナーには、技術力向上を目指して、短い同じストー リーを異なるプロ作者が描いて紹介する解説記事も存在 するが、一般的に流通する漫画で、同話で異なる描き方 がされた作品は古典小説の漫画化などを除いてほとんど ない. そのため、多様性に関わるタスクの定義は困難だっ たが、4コマ漫画ストーリーデータセットでは、同じ自然 言語で表されたシナリオに基づいて異なる5 作者が漫画 を描いていることから、コマの多様度識別 [28] のタスク を定義した.

上記に既発表の識別タスクを紹介したが、人が自然に描き 読む漫画を人工知能のタスクから見ると他にも多数のタスク を解く必要があることがわかる。特に4コマ漫画の描き方に 関わりが強い感情、順序・構造、多様度をまず対象としたが、 ストーリーの面白さを描き理解するには文化的背景や背景知識 も必要となり、漫画以外の媒体を対象とした研究も、画像情報 と自然言語情報を有するマルチモーダルな媒体である漫画に適 用できる可能性が高い.

#### 4.2 小説

小説の創作方法は、工学として体系立てる前に、現場での 知識や物語論に基づいて、学際融合的に醸成していることを 考慮する必要がある.小説の書き方は作者によって異なるが、 アイデアや設定をラフにメモをしたり、場合によっては時代考 証や、参考となる人物や舞台の資料を用意した上で骨子となる プロットを書き、その後、文表現方法を工夫して実際に文章を 書き、校正を重ねることが多い.筆者らの研究グループではス トーリーの構成とキャラクターの設定を連携して見やすく可視 化するための質問集合を定義した創作支援システム [32] を開 発しており、実際にプロの創作者がシステム用いて小説を発表 している \*<sup>2</sup>.

システムはプロットを作成する前段階で用いることを想定し ているが、本文を記述する間に参照したり編集することも可能 であり、システムのいずれの質問や機能が、創作のどの時点で 役立ったかというアンケート評価に基づきシステムの改良を進 めている.また、システムへのユーザ入力文に基づき既存作品 の情報を参照する機能の開発を進めている.

<sup>\*2</sup> 創作者と人工知能分野研究者のコラボレーション: https://www. tut.ac.jp/docs/PR180222.pdf







図 2:4 コマ漫画ストーリーデータセット第1,2話,2構造,5作者の漫画

#### 4.3 創作者の視点

以下に、本分野に対する創作者視点の疑問や課題を述べる.

- 創作へ役立てようと保持するあらゆる資料や記憶を見渡して、自らの内側の一部を晒して物を創り上げる。創作過程の中の大事な段階を本当に人工知能分野の研究は実現できるのか。計算機上の作業だけが創作物に関わるわけではないため、個人の感性や文化的背景を計算機上で解析することは極めて難しいのではないか。
- 人同士が創作物を見せ合い,批評し合って発展してきた 創作文化ではあるが,そこに人工知能が関わるというこ とに抵抗を感じたり,著作権や二次創作物の扱いに関す る課題が存在するのではないか.

人工知能分野の手法そのものも人が生み出した創作物,と もみなせる.筆者自身,絵や小説を描くため,手法を使うか否 かを決めるのは人である,という立場を取る.創作中に人に意 見を求めるのは今後も続く創作文化だが,自分の過去作品や人 が調べるには時間がかかる世の作品を解析して情報提示するた めに人工知能分野の手法を用いて共に創作する未来の可能性を 上記課題を踏まえて議論したい.

#### 4.4 創作者と人工知能の共創への展望

4.1.2 で示した手法は未だ要素技術として手法実装と一部作品への適用に留まり、多数の作品での識別率の向上や他の高次のタスクを要するため、現場応用へは距離があることをことわった上で図1右側に示す共創を想定し研究を進める.

# 5. ストーリーに関わる創作の未来

現在筆者が,特に人工知能分野と相性が良く興味深いと考 えることを,ストーリーに踏み込んだ創作の未来を考える材料 として示す.

作品を読んだ際,2つの話の一部分が類似すると感じること がある.独創性の追求として類似が忌避される一方,オマー ジュとして敢えて類似が用いられることもあり,作者が類似 作品を探すことはいずれの場合も役立つ.読者にとってはレ ビューサイトなどを参考にして,自らの嗜好に基づき類似した 作品を読みたい場合に考慮する.ジャンル,ストーリーの構造, 時代・舞台背景,登場人物の設定,伏線の張り方,文体・描画 方法,読後感,など,類似には多様な観点がある.例えば,類 似した文を探す方法として,近年,分散表現の台頭により,辞 書に頼らなくとも表記の揺れを吸収し,文の類似を調べられる 可能性が高まったが,最終成果物のみを対象とした場合に話の 粒度の問題は依然として残り,ネームやプロットなどの創作過 程に着目した粒度別の情報があることが研究発展に望ましい.

# **6.** まとめ

本稿では、創作者と人工知能が創る創作の未来に寄せ、創作 に役立つ可能性という観点で人工知能分野の研究を紹介した. 広く見るとさらに多くの要素技術がシーズとして役立つ可能性 があり、現在進んでいる研究の目的を適切に伝え、創作者側の ニーズを聞き取りながら、新たな創作物、創作手法を生み出す 未来の可能性を共に探りたい.

# 謝辞

表題の研究で関わった方々,特に本稿の4.章の研究に関わっ ていただいた創作者の方々に各原稿の謝辞に重ね,本稿でも謝 意を表す.本研究は,JST,ACT-I(グランド番号:JPMJPR17U4) の支援を受けた.本研究は一部,JSPS 科研費 (グラント番 号:JP17K17809) および大幸財団の支援による.

# 参考文献

- [1] 松下光範. コミック工学の可能性. 第2回 ARG WEB イン テリジェンスとインタラクション研究会, pp. 63-68, 2013
- [2] Toru Ogawa, Atsushi Otsubo, Rei Narita, Yusuke Matsui, Toshihiko Yamasaki, Kiyoharu Aizawa, Object Detection for Comics using Manga109 Annotations, arXiv:1803.08670
- [3] 佐藤 剣太, 牧 良樹, 中村 聡史, コミックの読書意欲を増進さ せる要素に関する分析, 人工知能学会, 1K1-OS-2a-01, 2018
- [4] 三原 鉄也, 永森 光晴, 杉本 重雄, マンガメタデータフレー ムワークに基づくディジタルマンガのアクセスと制作の 支援ーディジタル環境におけるマンガのメタデータの有効 性の考察一, 電子情報通信学会論文誌 A, Vol.J98-A, No.1, pp.29-40, 2015
- [5] 保住純,松尾豊,深層敵対的生成ネットワークを用いたマン ガイラスト自動生成の試み,人工知能学会,1K2-OS-2b-03, 2018
- [6] 松下 光範,山西 良典,松井 勇佑,岩田 基,上野 未貴,西原 陽子,中村 聡史."私のブックマーク「コミック工学」".人 工知能, Vol. 32, 2017
- [7] Yusuke Matsui, Kota Ito, Yuji Aramaki, Azuma Fujimoto, Toru Ogawa, Toshihiko Yamasaki, Kiyoharu Aizawa, Sketchbased Manga Retrieval using Manga109 Dataset, Multimedia Tools and Applications, Springer, 2017
- [8] Clément Guérin, Christophe Rigaud, Antoine Mercier, Farid Ammar-Boudjelal, Karell Bertet, Alain Bouju, Jean-Christophe Burie, Georges Louis, Jean-Marc Ogier, and Arnaud Revel. "ebdtheque: a representative database of comics". In Proceedings of the 12th International Conference on Document Analysis and Recognition (ICDAR), 2013
- [9] 松原仁, 佐藤理史, 赤石美奈, 角薫, 迎山和司, 中島秀之, 瀬 名秀明, 村井源, 大塚裕子: コンピュータに星新一のような ショートショートを創作させる試み, 第27回人工知能学会 全国大会, 2D1-1, 2013
- [10] 緒方健人, 佐藤理史, 駒谷和範: 模倣と置換に基づく超短 編小説の自動生成, 第 28 回人工知能学会全国大会, 1C3-OS-14b-2, 2014
- [11] 秋元 泰介,小方 孝,共創物語生成システムに向けて,人工 知能学会論文誌,vol.31, no.6, AI30-O\_1-8, 2016
- [12] Kiyohito Fukuda, Naoki Mori, and Keinosuke Matsumoto, A novel sentence vector generation method based on autoencoder and bi-directional LSTM, Vol. 800 of Advances in Intelligent Systems and Computing, pp. 128-135, 2018
- [13] 朝倉民枝, おはなしづくりソフトの開発?子どもたちの心の中に安全基地を育てたい?, 情報処理学会, デジタルプラクティス, vol.2, no.2, pp.103-116, 2011
- [14] Kiyohita Fukuda, Saya Fujino, Naoki Mori, Keinosuke Matsumoto, "Semi-automatic Picture Book Generation Based on Story Model and Agent-Based Simulation., Intelligent and

Evolutionary Systems. Proceedings in Adaptation, Learning and Optimization, vol 8. Springer, Cham, 2016

- [15] Saya Fujino, Naoki Mori, Maria Navarro Caceres, Sara Rodriguez Gonzalez, Juan Manuel Corchado, The automatic objects placement for a picture book by machine learning, 24th International Symposium on Artificial Life and Robotics, 2019
- [16] Saya Fujino, Taichi Hatanaka, Naoki Mori, Keinosuke Matsumoto, The Evolutionary Deep Learning based on Deep Convolutional Neural Network for the Anime Storyboard Recognition, in Distributed Computing and Artificial Intelligence, pp. 278?285, 2017
- [17] 山下 諒, 朴 炳宣, 松下 光範: コミックの内容情報に基づいた探索的な情報アクセスの支援, 人工知能学会論文誌 32(1), WII-D\_1-11, 2017
- [18] Tetsuya Mihara, Akira Hagiwara, Mitsuharu Nagamori, Shigeo Sugimoto, "A Manga Creator Support Tool Based on a Manga Production Process Model ? Improving Productivity by Metadata", In iConference 2014 Proceedings, pp. 959-963, 2014
- [19] Edgar Simo-Serra, Satoshi Iizuka, Hiroshi Ishikawa, "Real-Time Data-Driven Interactive Rough Sketch Inking", ACM Transactions on Graphics (SIGGRAPH), 2018
- [20] PaintsChainer: https://paintschainer.preferred.tech/
- [21]  $\exists \exists Po!: https://www.comipo.com/$
- [22] Live2D: https://www.live2d.com/
- [23] CACANi: https://cacani.sg/
- [24] 古川 健次, 仲田 晋: 3 次元キャラクタにおけるアニメ風髪 モーションの自動生成, 人工知能学会, 1K2-OS-2b-02, 2018
- [25] Miki Ueno, Kiyohito Fukuda and Naoki Mori, "Can Computers Create Comics and Animations?", Computational and Cognitive Approaches to Narratology, pp. 164–190, 2016.
- [26] 上野 未貴, "創作者と人工知能: 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, 4Pin1-16, 2018
- [27] 上野 未貴, 井佐原 均. "漫画内の特徴的要素が与えるストーリーの印象についての検討". 人工知能学会, No. 2J5-OS-08b-4in2, 2016
- [28] Ryo Iwasaki, Koichi Sato, Miki Ueno, Naoki Mori, Makoto Okada, Novel deep learning method for understanding Japanese comics, 24th International Symposium on Artificial Life and Robotics, 2019
- [29] Miki Ueno, Naoki Mori, Toshinori Suenaga, and Hitoshi Isahara. "Estimation of structure of four-scene comics by convolutional neural networks". In Proceedings of the 1st International Workshop on coMics ANalysis, Processing and Understanding, MANPU@ICPR 2016, pp. 9:1–9:6, 2016
- [30] Neil Cohn, "You' re a good structure, Charlie Brown: The distribution of narrative categories in comic strips", *Cognitive Science*, Vol. 38, No. 7, pp. 1317-1359, 2014
- [31] Miki Ueno, Structure Analysis on Common Plot in Four-Scene Comic Story Dataset, 25th International Conference on MultiMedia Modeling, 2019
- [32] 葛井健文, 上野未貴, 井佐原均, "質問集合とグラフに基づ く物語全体の流れを管理可能な創作支援システムの提案", 人工知能学会, 2E2-04, 2017

Organized Session | Organized Session | [OS] OS-20

# [3P3-OS-20] 脳波から音声言語情報を抽出・識別する 新田 恒雄(早稲田大学/豊橋技術科学大学)、桂田 浩一(東京理科大学)、入部 百合絵(愛知県立大学)、田口 亮(名古屋工業大学) Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room P (Front-left room of 1F Exhibition hall) [3P3-OS-20-01] Describing Brain Activity Evoked by Speech Stimuli ORino Urushihara<sup>1</sup>, Ichiro Kobayashi<sup>1</sup>, Hiroto Yamaguchi<sup>2,3</sup>, Tomoya Nakai<sup>2,3</sup>, Shinji Nishimoto<sup>2,3</sup> (1. Ochanomizu University, 2. National Institute of Information and Communications Technology, 3. Osaka University) 1:50 PM - 2:10 PM [3P3-OS-20-02] Development of Syllable Labelling Tool for Electroencephalogram Data OMingchuan Fu<sup>1</sup>, Ryo Taguchi<sup>1</sup>, Kentaro Fukai<sup>2</sup>, Kouichi Katsurada<sup>2</sup>, Tsuneo Nitta<sup>3,4</sup> (1. Nagoya Institute of Technology, 2. Tokyo University of Science, 3. Waseda University, 4. Toyohashi University of Technology) 2:10 PM - 2:30 PM [3P3-OS-20-03] Word Recognition from speech-imagery EEG OSatoka Hirata<sup>1</sup>, Yurie Iribe<sup>1</sup>, Kentaro Fukai<sup>2</sup>, Kouichi Katsurada<sup>2</sup>, Tsuneo Nitta<sup>3,4</sup> (1. Aichi Prefectural Univ., 2. Tokyo Univ. of Science, 3. Waseda Univ., 4. Toyohashi Univ. of Tech.) 2:30 PM - 2:50 PM [3P3-OS-20-04] Syllable recognition in speech-imagery EEG OKentaro Fukai<sup>1</sup>, Hidefumi Ohmura<sup>1</sup>, Kouichi Katsurada<sup>1</sup>, Tsuneo Nitta<sup>2,3</sup> (1. Tokyo University of Science, 2. Waseda University, 3. Toyohashi University of Technology) 2:50 PM - 3:10 PM [3P3-OS-20-05] BCI Studies on Extraction of Spoken Language representation from Speech Imagery EEG OTsuneo Nitta<sup>1</sup>, KENTAROU FUKAI<sup>2</sup>, KOUICHI KATSURADA<sup>2</sup>, YURIE IRIBE<sup>3</sup>, RYOU TAGUCHI<sup>4</sup>, SHUNJI SUGIMOTO<sup>5</sup>, JUNSEI HORIKAWA<sup>5</sup> (1. Waseda University, 2. Tokyo Science University, 3. Aichi Prefectural University, 4. Nagoya Institute of Technology, 5. Toyohashi University of Technology) 3:10 PM - 3:30 PM
# 音声刺激による脳活動の言語解読への取り組み

Describing Brain Activity Evoked by Speech Stimuli

| 漆原 理乃*1               | 小林一郎*1           | 山口 裕人 *2*3              | 中井 智也 *2*3           | 西本 伸志 *2*3              |    |
|-----------------------|------------------|-------------------------|----------------------|-------------------------|----|
| Rino Urushihara       | Ichiro Kobayashi | Hiroto Yamaguchi        | Tomoya Nakai         | Shinji Nishimoto        |    |
| *1お茶の水女子大学            | * *2情報通信         | 研究機構 脳情報:               | 通信融合研究セン             | ·ター * <sup>3</sup> 大阪大学 |    |
| Ochanomizu University | National Insti-  | tute of Information and | Communications Techn | nology Osaka Universi   | ty |

The analysis of semantic activities in the human brain is an area of active field of study. In this paper, we propose a deep learning method to describe text for semantic representations evoked by speech stimuli from Functional Magnetic Resonance Imaging (fMRI) brain data. Thereby, our study aims to decode higher order perception which a person recalled in the brain by speech stimuli. However, collecting a large-scale brain activity dataset is difficult because observing brain activity data with fMRI is expensive, although a method with deep learning requires a large-scale dataset. We therefore use an automatic speech recognition method and utilize a small amounts of fMRI data efficiently for machine learning. Through experiments, we have conformed high correlation between the predicted features from fMRI data and the speech features.

# 1. はじめに

近年, 脳神経活動の意味表象を捉える研究が盛んになって いる.本研究では, Functional Magnetic Resonance Imaging (fMRI) で観測した音声刺激下の脳活動データから,人が脳内 に想起した高次意味表象を言語として解読することを目指し, 深層学習を用いて,音声刺激による脳活動データからその意味 表象をテキストとして生成する手法を構築する.しかし,fMRI により観測する脳活動データは取得のためのコストが大きく, 大量の学習データを要する深層学習を十分に行うための大規 模なデータ収集は困難である.そのため,学習済みの自動音声 認識を行う深層学習モデルの中間層に脳活動データを回帰す ることで,直接 fMRI データを用いてモデル全体を学習せず, 少量の fMRI データを効率的に活用し,脳活動データからキャ プションを生成する手法を提案する.

# 2. 関連研究

近年, 脳神経活動の多点計測技術の発展と機械学習技術の高 度化により, ヒト脳内情報表現の定量理解や解読を目指す研究 が盛んになっている [Huth 12, Stansbury 13]. しかし, これ らは動画像もしくは静止画像視聴下における脳神経活動を対象 としており, 音声 (言語)を刺激とした脳神経活動を対象とし た研究は少ない [Huth 16]. そのため, 本研究では, 音声刺激を 対象とした脳神経活動を解読することを目的とする. 解読手法 構築にあたって, 深層学習を援用することで, 動画像視聴下に おける脳活動から認知内容の解読が実現できることが示されて いる [Matsuo 18]. 本研究では, このような背景から深層学習 を用いるが, その際, Matsuo ら [Matsuo 18] の手法の少量の 脳活動データの効率的な利活用方法を参考にし, 自動音声認識 手法を援用することで, 音声刺激下の脳活動データから, その 刺激となっていた音声のテキストを生成する手法を構築し, 脳 内意味表象の解読を目指す.

# 3. 提案手法

本提案手法は,深層学習を用いて,音声刺激を受けた脳活動 データを入力として,その時に刺激となっていた音声のテキス トを生成し,人が頭の中で想起した言葉に対応する意味表象を 言葉として解読することを目指す.しかし,fMRIにより観測 する脳活動データは取得のためのコストが大きく,大量の学習 データを要する深層学習を十分に行うための大規模なデータ収 集は困難である.そのため,Encoder-Decoder Network に基 づく自動音声認識手法を援用することで少量データを効率的 に活用する.具体的には自動音声認識のEncoder から得られ る中間表現に,脳活動データを回帰させ,その結果を自動音声 認識のDecoder に入力することで,テキスト生成を行う.図1 に本提案手法の概要図,3.1 節に提案手法の処理の流れを示す.



図 1: 本研究の概要図

## 3.1 提案手法の処理の流れ

実行時の処理は以下のようになる.

step 1. 自動音声認識

step 1-1. Encoder: 音声中間表現の抽出 自動音声認識の Encoder を用いて, 音声から音声中間表 現を抽出.

連絡先:漆原理乃,お茶の水女子大学理学部情報科学科小林研究室, 〒112-8610 東京都文京区大塚 2-1-1,g1420509@is.ocha.ac.jp

step 1-2. Decoder: テキスト生成

step1-1. において抽出された音声中間表現を, 自動音声 認識の Decoder に入力し, テキストを生成.

step 2. 脳活動データの特徴量推定

脳活動データとその刺激である音声の中間表現 (step1-1 の出力) との対応関係を学習した Ridge 回帰により, 脳活 動データから対応する中間表現を推定.

step 3. 脳活動データの特徴量からテキスト生成

step1-2. で学習済みの自動音声認識の Decoder を用い て, step2. で計算された脳活動データの特徴量を入力と して, テキストを生成.

#### 3.2 自動音声認識

本手法の基盤として, Encoder-Decoder Network を用いた自 動音声認識モデル, Listen, Attend and Spell (LAS) [Chan 16] を用いる. LAS は Encoder として, ピラミッド型の双方向 Recurrent Neural Network (RNN)を用い,入力音声を中間 表現に変換する. Decoder としては, Attention 付きの単方向 RNN を用い, Encoder で得た中間表現を Attention として入 力し,通常の言語モデル同様に次にくるであろう単語,もしく は文字を1つずつ生成する. Decoder で Attention を用いる ことで,中間表現の系列と出力系列との対応関係も学習できる.

#### 3.3 脳活動データの特徴量推定

音声刺激を受けた被験者の脳活動データを入力とし,その時 の刺激となっている音声の LAS の Encoder によって抽出され た中間表現を予測するために, Ridge 回帰を用いる. 学習には 脳活動データと被験者がその時に聴いている音声を用いる. ま た, fMRI は脳活動を記録する際にタイムラグがある. 今回は それを (1)4 秒のみ, (2)4,5,6 秒の複数時点としたものをそれぞ れ説明変数とする, Ridge 回帰のモデルを構築する.

## 4. 実験

3.1 節に示す提案手法の処理の流れに沿って行った3つの実 験を以下に示す.

#### 4.1 実験1:自動音声認識

#### 4.1.1 実験設定

システムの実装は、深層学習のフレームワーク TensorFlow を用いたコード<sup>\*1</sup>を使用した.学習のためのデータセットとし て、「日本語話し言葉コーパス」(CSJ)中の3,254本の講演デー タを使用した. CSJ で設定されている評価セット1から3と 脳活動データの刺激として使用された音声は除外した.音声の 前処理として、転記基本単位(IPU)で分割し、フレームサイズ 25ms、フレームシフト10msでフレームごとに MFCC 特徴量 を取得し入力とした.出力は発音形(PhoneticTranscription) を用い、発音されている文字にstart-of-sentence (sos)とendof-sentence (eos)、バッチサイズ中の系列長に合わせるための padding(pad)を追加し、84次元とした.学習に関する詳細設 定は表1に示す.評価は CSJ の評価セット1の10本の講演 データを用いて行った.

#### 4.1.2 実験結果

epoch ごとに学習用データの Loss を記録し、その減少によ り学習の進度を確認し、収束するまで学習を行った.図2に は、先行研究 [Chan 16] と同様に取得した Decoder における

Speech\_Recognition\_with\_Tensorflow

Attention の値の可視化結果を示す.また,評価セット1で評価を行い,生成したテキストの一部と,生成テキストと正解テキストとをそれぞれ比較し編集距離のマクロ平均を計算したものを表2に示す.



図 2: 実験 1 attention の可視化

#### 4.1.3 考察

図2より, Attention がうまく機能している, つまり中間表 現の各要素が, 出力系列のどの部分に対応するかを学習するこ とができていることがわかる.しかし, 表2より, 短いテキス トは生成に成功しているが, 長いテキストは正確な生成が困難 であるといえる.

# 4.2 実験2:脳活動データの特徴量推定4.2.1 実験設定

脳活動と音声特徴量の対応関係を学習するためのデータセッ トとして、日本語話し言葉コーパス (CSJ) の16本を1人の被験 者に聴かせた時の血中酸素濃度依存性信号 (BOLD 信号;Blood Oxygenation Level Dependent Signal) を fMRI を用いて 1 秒ごとに記録した脳活動データ,および fMRI のデータ収集と 同期させた CSJ の音声を使用する. 立体撮像 96 × 96 × 72 ボクセルのうち皮質に相当する 62,552 次元分のデータ列を用 い, その時聴いている音声から LAS の Encoder であるピラ ミッド型の双方向 RNN から出力される 900 次元の音声中間表 現との対応と, 1800 次元の RNN の隠れ層 (Long short-term memory(LSTM)の隠れ層, 1,2 層目のセル c,h で共に 450 次 元により合計 1800 次元. Decoder では、この隠れ層を初期値 として予測を開始する)との対応を学習した. 脳活動データは, 1秒ごとに取得されているため,系列長を音声中間表現の系列 数に合わせるように線形補間を行い,最大値1,最小値0に正 規化を行ったものを入力として使用した. train 用データは 14 本, test 用データは2本の講演データを聴いた脳活動データと した. 学習には Ridge 回帰を用い, その詳細設定は表1に示す.

#### 4.2.2 実験結果

test 用データの脳活動データから Ridge 回帰を行い,その刺激となっていた音声の中間表現を予測した結果とその音声の中間表現との相関係数を計算したものを表3に示す.

#### 4.2.3 考察

表3より, Encoder の出力に関して, 説明変数となるタイム ラグを4秒のみとした時よりも, 4,5,6秒とした時の方が相関 係数が低いことが言える.これに関しては, 脳活動データを音 声中間表現の系列数に合わせるように線形補間を行い, それを

<sup>\*1</sup> https://github.com/thomasschmied/

|                 | 自動音声認識                            | 脳活動データの特徴量抽出                               |
|-----------------|-----------------------------------|--|
| train データ       | 日本語話し言葉コーパス (CSJ)                 | 音声刺激による脳活動データ                              |
| 学習量             | 919,118 sample $\times$ 70 epochs | 100,938 sample<br>(9,841sample を元に線形補間し増強) |
| アルゴリズム          | Adam                              | Ridge 回帰                                   |
| 学習に関する<br>パラメータ | 学習率: 0.00001                      | L2 正則化項: 1.0                               |
|                 | 入力: 494 次元                        | Attention となる中間表現:                         |
|                 | Encoder 2 層 : 全て 450 次元           | 62,552 次元 - 900 次元                         |
| 隠れ層次元           | Decoder 2 層 : 全て 450 次元           |  |
|                 | Embedding: 10次元                   | RNN の隠れ層:                                  |
|                 | 出力:84次元                           | 62,552 次元 - 1800 次元                        |
| 誤差関数            | 交差エントロピー                          |  |
|                 | Cyclic Learning Rate              |  |
| その他             | Max 学習率: 0.00003                  |  |
|                 | Step size: 700                    |  |

| 表 1: | 各パラ   | メータ設定 | (詳細)   |
|------|-------|-------|--------|
| 1 1. | 11/1/ |       | 、山王小田ノ |

表 2: 評価セット1における音声認識実験結果

| 正解テキスト       | 生成テキスト            |
|--------------|-------------------|
| コンカイノ        | コンカイノ             |
| トユーブンデハ      | トユユブブンンワワ         |
| コノヨーニ        | コノヨーニニ            |
| マチガウカノーセーガ   | チチーカカノノーー         |
| アリマスノデ       | ガガアリママスデデ         |
| 編集距離のマクロ平均:1 | 1.3 (平均文字数: 21.8) |

表 3: 実験 2 の ridge 回帰結果 (相関係数)

| タイムラグ         | (1)4 秒 | (2)4,5,6 秒 |
|---------------|--------|------------|
| Ecoder の出力    | 0.32   | 0.11       |
| LSTM の隠れ層 (c) | 0.78   | 0.78       |
| LSTM の隠れ層 (h) | 0.42   | 0.42       |

ridge 回帰の入力に使用しているため, 説明変数にノイズが多 く含まれてしまっていることが考えられる. そのため, 今後は 線形補間を用いないで予測するモデルを考案していきたい.

#### 4.3 実験3: 脳活動からのテキスト生成

実験1で学習した自動音声認識モデルLASのDecoderを 使用して,実験2(1)(2)ぞれぞれで取得した脳活動データの特 徴量を入力として,テキスト生成を行う.

#### 4.3.1 実験設定

実験2の学習において未使用のtest用の2本の講演データを 聴いた脳活動データを用いて,Ridge回帰を行い,900次元の中 間表現とRNNの隠れ層1800次元を取得し,LASのDecoder に前者の中間表現はAttentionとして入力し,後者はRNNの 隠れ層の初期値として使用した.

#### 4.3.2 実験結果

脳活動データから生成したテキストと音声から生成したテ キスト, 正解テキストをそれぞれ比較し編集距離のマクロ平均 を計算したものを表4に示す.また,生成したテキストの一部 を表5に示す.

## 4.3.3 考察

表4より脳活動データから生成したテキストの編集距離の マクロ平均が、タイムラグを4秒とした時よりも4,5,6秒とし た時の方が低くなっている.その原因としては、4.2節の実験 表 4: テキスト生成実験結果 (編集距離のマクロ平均)

| 脳活動からの生成 (タイムラグ 4 秒)     | 6.0  |
|--------------------------|------|
| 脳活動からの生成 (タイムラグ 4,5,6 秒) | 12.7 |
| 音声からの生成                  | 3.1  |
| 平均文字数                    | 6.6  |

表 5: テキスト生成実験結果 (生成例)

| 正解   | 脳活動から生成<br>(4 秒) | 脳活動から生成<br>(4,5,6 秒) | 音声から生成 |
|------|------------------|----------------------|--------|
| テーマワ | エーーー             | ウーカカカカ               | テーマワ   |
| アルト  | デテ               | デデンン                 | アルト    |
| マダ   | イイ               | ネネ                   | マダ     |
| ヤッパリ | ))               | エエ                   | ヤッパリ   |

における,表3の相関係数が後者の方が低いためといえる.表5より,タイムラグを4秒,4,5,6秒とした時の両方とも,実際の生成テキスト例も正解もしくは音声から生成したテキストと一致しておらず,生成がうまくいっていないことがわかる.4.2節の実験における,脳活動データの特徴量の推定値の誤差が影響していると考えられる.

# 5. おわりに

本稿では、自動音声認識モデル LAS を援用し、音声刺激を 受けた被験者の脳活動データから聴いている音声をテキストと して出力する手法を提案した. 今後の課題として、実験2の脳 活動データから特徴量を推定する手法を見直し、実験結果のさ らなる評価・分析を実施し、生成するテキストの精度を向上さ せていきたい.

# 謝辞

本研究を進めるにあたっては,その一部を科研費新学術領域 研究(課題番号:18H05118)の支援を受けた.

## 参考文献

[Chan 16] Chan, W., Jaitly, N., Le, Q., and Vinyals, O. Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. In Acoustics, Speech and Signal Processing (ICASSP), 2016 IEEE International Conference on (pp. 4960-4964). IEEE (2016).

- [Huth 12] Huth, A. G., Nishimoto, S., Vu, A. T., Gallant, J. L.: A continuous semantic space describes the representation of thousands of object and action categories across the human brain, Neuron, 76(6):1210-1224 (2012).
- [Huth 16] Huth, A. G., de Heer, W. A., Griffiths, T. L., Theunissen, F. E., and Gallant, J. L. Natural speech reveals the semantic maps that tile human cerebral cortex. Nature, 532(7600), 453. (2016)
- [Matsuo 18] Matsuo, E., Kobayashi, I., Nishimoto, S., Nishida, S., and Asoh, H. Describing Semantic Representations of Brain Activity Evoked by Visual Stimuli. In arXiv preprint arXiv:1802.02210 (2018).
- [Stansbury 13] Stansbury, D. E., Naselaris, T., Gallant, J. L.: Natural Scene Statistics Account for the Representation of Scene Categories in Human Visual Cortex, Neuron 79, pp.1025-1034, September 4, 2013, Elsevier Inc (2013).

脳波データ用音節ラベリングツールの開発 Development of Syllable Labelling Tool for Electroencephalogram Data

| 付 明川*1                         | 田口 亮*1           | 深井 健大郎            | ß <sup>*2</sup> 桂田浩一 <sup>*2</sup> | 新田 恒雄*3,4                          |
|--------------------------------|------------------|-------------------|------------------------------------|------------------------------------|
| Mingchua Fu                    | Ryo Taguchi      | Kentaro Fukai     | Kouichi Katsurada                  | Tsuneo Nitta                       |
| *1 名古屋工業大学                     | <sup>*2</sup> 東京 | 理科大学              | *3 早稲田大学                           | *4 豊橋技術科学大学                        |
| Nagoya Institute of Technology | Tokyo Unive      | ersity of Science | Waseda University                  | Toyohashi University of Technology |

EEG (Electroencephalogram) is an electrical signal representing activity of the brain and have been used for healthcare and brain-machine interface. Recently, research to estimate imagined linguistic information from EEG signals was launched. The research needs labeled EEG dataset that are given boundaries of imagined syllables. In this paper, we propose the syllable labeling tool for research on EEG. Labelers can adjust boundaries of each syllable using a mouse or a keyboard while observing features extracted from EEG signals. They can also easily reuse analytical methods developed by themselves because this tool runs on MATLAB. Moreover, in this paper, we describe a semi-automatic labeling method to improve operating efficiency.

# 1. はじめに

脳波(Electroencephalogram: EEG)は、非侵襲で比較的安価 に計測可能な脳信号であり、医療での臨床検査やリハビリテー ションなどで利用されている[1].また、集中度や快不快などの 感情の推定が可能であり、ブレイン・マシン・インターフェース (BCI)への応用が進められている.さらに近年では、想起した 言語情報を脳波からデュードする研究が始まっている[2].この 研究が実現すると、頭の中で想起した内容を機械が読み取るこ とができ、従来の BCI よりも利用範囲が大きく広がる.

音声認識では,発話した言語内容と音響信号との対応を統計的に学習することで実現している.同様に,脳波から言語情報をデュードするには,想起した音節系列と脳波の特徴系列間の対応をコンピュータに学習させる必要がある.音声認識技術の発展には,(1)音響モデルを学習するための音素ラベル付の音声データベースと,(2)言語モデルを学習するためのテキストコーパスの二つが大きく貢献した.音声想起時の脳波による音節認識では,(2)の言語モデルはそのまま利用可能であるが,(1)については音節ラベル付の脳波データベースは存在しないため,人手で作成する必要がある.しかし,脳波データから音節をラベリング可能なツールは現在,存在しない.

本報告は、言語想起に基づく脳波研究のための音節ラベリン グツール開発を目指している。脳波からの音声言語デコーディ ングは、まだ始まったばかりであり、特徴抽出器や識別器を設 計するためのノウハウ蓄積もこれからという段階である。従って、 (1)特徴抽出および識別手法の検討、(2)EEGデータに対する 音節ラベリング、(3)認識シミュレーション実験による検証、とい う三つの工程を繰り返しながら、より良い手法を模索していく必 要がある。本ツールは、この試行錯誤を効率化することを目的と している。ツール開発にあたっては、脳波研究者の間で広く利 用される MATLAB 上での動作を前提とした。以下では、 Hidden Markov Model (HMM)の音節アライメントを用いた半自 動ラベリングの実現可能性についても検討する。

# 2. ラベリングツールの概要

#### 2.1 開発環境

本ラベリングツールは MATLAB の GUI 開発環境である GUIDEを用いて開発している. MATLAB は, MathWorks 社が 提供する数値解析ソフトウェアである.開発した脳波の解析や 可視化が可能な EEGLAB や,信号処理,機械学習などの







toolbox が豊富に揃っていることから,音声研究者や脳波研究 者の間で広く用いられている. MATLAB上で動作するラベリン グツールを開発することにより,各研究者がこれまでに開発した 特徴抽出・機械学習の手法をシームレスに利用することができ, 研究開発が効率化すると考えている.

#### 2.2 基本機能

図1を用いてツール利用の流れを説明する.まず,収集した 脳波データから,音節ラベリングの際に用いる特徴量を抽出す る.特徴量としては、ノイズ除去後の波形や,信号強度,周波数 スペクトルなどが考えられるが,本ツールでは、「脳波中の言語 表象は tone-burst 波すなわち線スペクトル群として現れる」との 仮説に基づき,線スペクトル特徴と音節尤度ベクトル系列を用 いる[3,4].線スペクトル特徴は、音節想起時に現れる周波数成 分を元に、言語表象と成り得る特徴として抽出されたものである. 音節尤度ベクトルは、目視で音節ラベリングしたデータから学習 した音節認識器を用いて,音声想起時の脳波を認識した際の 音節毎のスコアである.音節尤度ベクトルは線スペクトルと異な り,音節らしさを直接表現する特徴量であるため,ラベリングの 大きな助けになると考えられる.しかし,ラベリングデータが全く 無い状態では使用することができない.そのため,最初は線ス ペクトル特徴に基づいてラベリングを行い,ある程度データを集 積した段階で,音節尤度を利用するという工程を想定している. 後述する HMM を用いた半自動ラベリングも同様のコンセプトで あるが,HMM は音節区間を推定出来る点が異なる.線スペクト ルと音節尤度の計算方法については[4]を参照されたい.

図 2 に開発したラベリングツールの実行画面を示す. 画面上 部にデータのファイル名や収録日, 想起内容が表示される. ま た横に示すボタンでデータの切り替えを行う. その下に, ラベリ ングする音節の区間が表示される. 画面中央に線スペクトル, 下部に音節尤度のグラフが表示され, 各グラフの内部に音節境 界と現在のカーソル位置を表すラインが表示される. データ読 み込み時に, ラベルデータが存在する場合, それが初期の境 界となる. 音節境界は, マウスまたはキーボードを用いて位置を 微調整する. ラベリング結果は, データの切り替え時に自動保 存される. 保存形式は, MATLAB で容易に利用可能な mat 形 式の他, Hidden Markov Model Toolkit (HTK)[5]のラベル形式 でも保存できる. HTK は音声認識に用いられる HMM の学習, 認識ができるソフトウェアである. HMM は時系列データの統計 モデルであり, 脳波の解析にも有効であると考えられる.

#### 2.3 HMM を用いた半自動ラベリング

EEG 信号は音声と異なり、「自分の耳で聞いて、(想起)音節 区間を判断する」ことができない. そのため、ラベリング作業者 は EEG 信号の周波数スペクトル情報を目視で観察し、習得した 各音節が共通に持つ特徴に着目してラベリングすることになる. この作業を効率化するため、我々は HMM による音節アライメントを用いた半自動ラベリング機能を開発している.

学習済みの音節 HMM を用いると, 脳波データと音節系列情報のみが与えられ, 個々の音節境界が不明な場合にも, 音節境界を推定することができる. 推定された音節境界をラベリング ツール上に初期境界として表示することで, 作業効率化を図る.また, 確認済のラベリングデータと HMM による音節境界を重ねて比較表示することにより, ラベリングの妥当性を検証できる.

HMMの特徴量には、先の線スペクトルや音節尤度の時系列 データを利用する. 今回の実験では、連続想起の10数字(1-9, 0)のを10サンプル用い、音節 HMMを5状態3ループ,混合 数3、音節以外の区間(以下、ノイズ区間)の HMMを3状態1 ループ,混合数9で学習した. 特徴量には線スペクトル28次元 を用いた. 学習に用いていないデータの音節境界を推定した結 果の一例を図3に示す. 図3の青い線が人手で設定した境界 位置、緑の線が HMM により推定された結果である. この結果 は、想起データに現れる最初の音節の始端と、最後の音節の 終端を人手で与えており、期待する性能はまだ得られていない. 今後はノイズ区間のモデル化手法を検討することで、性能の向 上を目指すと共に、半自動ラベリングに必要なデータ数につい ても調査していく予定である.

# 3. 今後の展望

本稿で紹介したラベリングツールは、1画面で1つのデータし か扱うことができない.実際のラベリングの作業では、紙に大きく 印刷したスペクトログラムを机にならべ、データ間で相互に見比 べることで、共通の特徴を探すことが行われる.このような、他の データとの比較を容易にする機能をラベリングツールに追加し ていきたいと考えている.

また,収集した脳波データが増えるにつれ,その管理が問題 となる.そこで,収録情報をデータに付与するための機能や,実 験条件に合わせて学習・評価用のデータを切り出し,ラベルデ ータと共に保存,管理,検索する機能を追加する.

### 4. まとめ

本稿では、脳波から言語情報をデコードする研究に必要な 音節ラベリングツールの開発状況を報告した. ラベリングやその 後の検証作業を容易にするため、ツールは MATLAB で開発 すると共に、HMM の音節アライメントを用いた半自動ラベリング の検討を行った. 現在は、想起データに現れる最初の音節の始 端と、最後の音節の終端を人手で与えており、期待する性能は まだ得られていないため、今後、アライメント精度を向上していく 必要がある. また、データ間の比較や、データの管理機能につ いても充実させていく予定である. 本ラベリングツールは、特徴 抽出手法および半自動ラベリング手法が完成した後、公開する 予定である.

# 参考文献

- Shindo, et al: Effects of neurofeedback training with an electroencephalogram-based brain-computer interface for hand paralysis in patients with chronic stroke: a preliminary case series study. J Rehabil Med., 43, pp. 951--957, 2011.
- [2] 神崎,他:発話時と想起時の脳波による日本語短音節認識の比較,日本音響学会2017年春季研究発表会,2017.
- [3] 新田,他:音声想起時脳波からの音声言語表象抽出に基づくBCI研究,第33回人工知能学会全国大会,2019.
- [4] 深井,他:音声想起時脳波中の音節識別について,第33回人工知能学会全国大会,2019.
- [5] http://htk.eng.cam.ac.uk/



図3 HMM の推定結果と人手によるラベルデータの比較

# 音声想起時脳波からの単語認識 Word Recognition from speech-imagery EEG

平田 里佳\*1 入部 百合絵\*1 深井 健大郎\*2 桂田 浩一\*2 新田 恒雄\*3,4 Satoka Hirata Yurie Iribe Kentaro Fukai Kouichi Katsurada Tsuneo Nitta Aichi Prefectual Univ. #1 Tokyo Univ. of Science #2 Waseda Univ.#3 Toyohashi Univ. of Tech.#4

Previous research suggests that humans manipulate the machine using their electroencephalogram called BCI (Brain Computer Interface). However, there are not existed effective methods for speech imagery recognition. In this report, we propose the word recognition method using line spectra extracted from EEG signal of continuously speech imagery. The word recognition can be achieved based on syllable-HMM model constructed by line spectra of fourteen syllables(/i/,/chi/, /ni/,/sa/,/N/,/yo/,/go/,/ro/,/ku/,/na/,/ha/,/kyu/,/u/,/ze/). The word recognition of ten numbers was conducted in our experiment.

# 1. はじめに

近年,脳波を用いて機械を操作する BCI (Brain Computer Interface)の研究が盛んに行われ,主に医療,介護現場等での活用が期待されている.

先行研究では、発話時の ECoG (Electro Cortico Graphy)の 観測から感覚運動野の音節による活性部位の違いが指摘され ている[1]. 同じく発話時 ECoG で、側頭葉の領野により周波数 パターンは大きく異なるという観測結果が報告されている[1]. 一 方,発話時は上側頭回での言語プランニング結果をブローカ野 が取次ぎ、運動野で調音指令が出て発音運動に繋がる[3]. こ れらの研究は、頭蓋内で皮質から直接信号を取得するため、身 体への負担が大きく、BCI での利用は現実的でない.

本報告では、利用者への負担が少ない非侵襲的な方法で、 頭皮から脳波(Electro-encephalogram; EEG)信号を取得し、脳 活動を分析する.また分析結果をもとに、音声想起(speech imagery)時の脳波から単語を認識することを目指す.

脳波からの単語認識研究は、現状非常に少なく、対象単語 数も2・3単語と少ない報告例が多い[4].以下では、1名分の脳 波を用いた10数字単語想起に対する実験結果を報告する.

# 2. 脳波信号の収録

成人男性 1 名(右利き) が 10 数字を想起した際の脳波を採 取した. 電極は, 左脳ブローカ野周辺に 9 電極を配置した. 図 1 に拡張 10-20 法で示した使用電極を示した(赤い四角で囲っ た電極).

10 数字は連続して想起した(ichi→ni→saN→yoN→go→roku →nana→hachi→ kyuu→zero). 収録プロトコルを図 2 に示す. 被験者は純音が鳴ってから,約 2 秒後に想起を開始し,約 3 秒 間内で 10 数字を連続想起する. 質の良い脳波信号を取得する ため,このプロセスを 23 回続けて繰り返した. 以下の実験では, 孤立単語認識としての評価を行うため,個々の数字の単語境界







を目視で与えた試料を 10 サンプル用意して使用した(孤立単 語としては 10×10 個).

# 3. 音声想起単語認識システム

提案する想起単語認識システムのブロック図を図3に示す.

#### 3.1 前処理

収録脳波データに含まれる電源ノイズや余分なアーチファクトを取り除くため、ノイズサブトラクション処理を行う.この処理では、最初に想起時以外の区間の脳波を振幅スペクトルに変換した後、8フレームを平均してノイズ区間平均振幅スペクトラムとする(N(k)).続いて、電極ごとに想起時脳波の振幅スペクトルX(k)からN(k)を引き去る.これにより、高調波成分を含む電源周波数成分、および定常的に発生するノイズを除去する.

また,音声言語に関する ECoG の研究[2]を参考に, High-γ 帯の脳波信号, すなわち 70-200Hz の Band-pass filter (BPF)を 通した成分を対象とする.開閉眼や唾呑み込みなどの筋活動 や体動によるアーチファクトの多くは BPF により除くことができた が,歯ぎしり等は想起時脳波への無視できないノイズとして残る.

#### 3.2 特徵抽出

我々の音声想起に関する研究では、「脳波中の言語表象は tone-burst 波すなわち線スペクトル群として現れる」と考えている [5]. この仮説に沿って線スペクトル群を抽出するため、 LPA(Linear Predictive Analysis;線形予測分析)を用いて、振 幅スペクトルを求めた後、正弦波に相当する線スペクトルを求め る[6].線スペクトル抽出では、周波数のゆらぎが観測されたた め,まず周波数ごとに前後3フレームの計7フレームに対して median filterを掛けて中央値を計算した後,Gaussian filter で平 滑処理を行い,周波数ゆらぎを除去した.続いて,9 電極の出 力を集約する pooling 処理を施した.これは,音節情報を観測 する度に,情報の出現する電極が異なる現象が観られた,ブロ ーカ野周辺の電極群を集約して安定に音節情報を抽出する解 決策として考案した.具体的には,9 電極のスペクトラムの要素 毎に,40msの範囲で4-normを計算した.最後に,集約したス ペクトル包絡から微分演算により複数のピーク周波数を抽出し て線スペクトル成分とする.

音節尤度ベクトルを抽出して用いた.このため,まず 10 数字 を連続して想起した脳波データの線スペクトル系列から,目視 により音節ラベリングを行い,含まれる音節区間を切り出した.ラ ベリングの例を図4に示す.次に,切り出した短音節区間28ch. ×9 フレームに対して音節毎に固有ベクトルを計算する.なお, 同時に音節と音節の間の区間をノイズ区間として,全てのノイズ 区間データから固有ベクトルを計算した.音節尤度ベクトル系 列は,10数字連続想起データに対して部分空間法により16短 音節およびノイズの17 クラスに対する音節尤度を計算し,これ を尤度ベクトル系列とする.

#### 3.3 単語認識

音節 HMM (Hidden Markov Model)を構築し, 10 数字の単 語認識を行う. HMM でモデル化する音節は 10 数字に出現す る 14 音節 (/i/, /chi/, /ni/, /sa/, /N/, /yo/, /go/, /ro/, /ku/, /na/, /ha/, /kyu/, /u/, /ze/)を対象とする. これに加えて, 短音節間に出現す るノイズについても HMM 学習する. 学習に使用する特徴量は 線スペクトル, 音節尤度ベクトルである. これらの特徴としての比 較評価を行うため, 線スペクトルと音節尤度ベクトルを組み合わ せたものに加え, 線スペクトルと音節尤度ベクトルのみによ る計 3 種類の特徴パターンを用いた実験を行った. 予備実験 の結果より, 構築した HMM は 5 状態 3 ループの left-to-right 型, 混合数は 3 混合とした. ただし, 音節間に現れるノイズ部分 に関しては, 3 状態 1 ループの left-to-right 型, 10 混合とした.

#### 4. 評価実験

音節 HMM を用いた 10 数字の単語認識を leave-one-out で 評価した.

## 4.1 実験試料

収録した脳波から線スペクトルを抽出し、線スペクトルパター ンをもとに人手で音節単位のラベリングを行った.連続数字想 起の 23 サンプルのうち、実際に音節ラベリングの作業を行った 10 サンプルに対して、10 数字単語区間を抽出し、10 単語×10 サンプルの 100 データを用いて、単語認識のための学習・評価 を行う. leave-one-out による交差検証では、10 サンプルの 1 つ を評価として除き、他の 9 サンプル中の 10×9 単語データを学 習データとする. これを 10 回繰り返して評価結果をまとめた.



図4線スペクトルパターンによるラベリング

#### 4.2 実験結果

音節 HMM を用いた 10 数字の単語認識結果を表 1 に示す. 抽出した線スペクトルをそのまま特徴量として用いた場合,線ス ペクトルのみでは 1best, 2best, 3best で正解率がそれぞれ 15.0%, 21.0%, 33.0%であり,線スペクトルと音節尤度ベクトルを 組み合わせたものでは,正解率がそれぞれ 16.0%, 23.0%, 28.0%であった.そこで,線スペクトルのスパース性を考慮し,フ レーム方向には 3 フレーム平滑を行い,周波数方向には 3 つ の周波数帯域の平均を 1 つの周波数帯域にまとめた.この処 理を行った結果が表 1 の線スペクトルと線スペクトルと音節尤度 ベクトルを組み合わせたものの結果である.ただし,線スペクト ルの結果についてのみ, leave-one-out による交差検証の際に, 特徴量の次元数が少ないために HMM が構築できない場合が あった.

表 1 10 数字の単語認識結果

| 胜加日里。                   | 正解率(%) |       |       |  |
|-------------------------|--------|-------|-------|--|
| 行似重                     | 1best  | 2best | 3best |  |
| 線スペクトル                  | 15.0   | 23.8  | 30.0  |  |
| 音節尤度ベクトル                | 54.0   | 69.0  | 80.0  |  |
| 線スペクトル<br>+<br>音節尤度ベクトル | 40.0   | 56.0  | 68.0  |  |

表1より,音節尤度ベクトルを用いた場合の3bestの正解率が80.0%と最も高かった.この結果から,想起時脳波信号を用いた単語認識には,特徴量として音節尤度ベクトルを用いることが効果的であることが示された.しかし,本研究では被験者1 名分の脳波信号のみを用いているため,今後は被験者を増やし,より多くの脳波信号を用いた認識実験を行う必要がある.

# 5. おわりに

想起時脳波信号を用いた音節 HMM による 10 数字単語認 識を行った. 脳波収録では男性 1 名が 10 数字を連続して想起 した際の脳波を取得した.

特徴抽出の前に収録した脳波データに含まれるノイズの除去 を行った. その後, LPA によって振幅スペクトルを求め, 周波数 ゆらぎの除去, 電極群の pooling を行い, 線スペクトルを抽出し た. 最後に, 音節尤度ベクトルを抽出した.

音節 HMM を構築し,10 数字の単語認識を行った.線スペクトルと音節尤度ベクトルを組み合わせたものに加え,線スペクトルのみ、音節尤度ベクトルのみによる特徴パターンを用いた実験を行った.認識結果から,音節尤度ベクトルを特徴量として用いた場合が最も正解率が高かった.今後は被験者を増やし,より多くの脳波データを用いて認識実験を行う.

#### 参考文献

- [1]Bouchard, K.E. et al.: Functional organization of human sensorimotor cortex for speech articulation., Nature; 497(7441): pp.327-332, 2013.
- [2]Flinker et al.: Redefining the role of Broca's area in speech, PNAS vol.112 no.9 pp.2871-2875, 2015.
- [3]Indefrey, P.et al., The spatial and temporal signatures of word production components, Cognition 92, 101-144, 2004.
- [4]伊東崇:サイレントシーズ BCI-HMM の性能評価-, 信学技報 MBE2014-130, NC2014-81, pp.81-84, 2015.
- [5]新田ほか: 音声想起時脳波からの音声言語表象抽出に基づく BCI 研究,人工知能学会全国大会,2019.
- [6]深井ほか, 音声想起時脳波中の音節識別について, 人工知能学会 全国大会, 2019.

# 音声想起時脳波中の音節識別について Syllable recognition in speech-imagery EEG

深井 健大郎<sup>\*1</sup> 大村 英史<sup>\*1</sup> 桂田 浩一<sup>\*1</sup> 新田 恒雄<sup>\*2, 3</sup> Kentaro Fukai Hidefumi Ohmura Kouichi Katsurada Tsuneo Nitta Tokyo Univ. of Science#1 Waseda Univ.#2 Toyohashi Univ. of Tech.#3

Fundamental research on speech-imagery recognition for BCI is one of the challenging technologies, however, the effective method to break through various difficulties in this area does not exist now. In this report, we propose the feature extraction of line spectra from EEG signal that represent linguistic information. Sixteen syllables in ten digits that are extracted from continuously-imagined-speech by hand-labelling are evaluated. Experimental results for syllable recognition based on subspace method are described.

# 1. はじめに

様々な領域に亘る Brain Computer Interface (BCI)の研究が 盛んである. BCI 研究では、主に運動野で観測した情報を解析 し、機器を操作するものが主であったが[1][2]、近年、音声言語 を抽出して識別することにより、BCI の応用を拡げる試みが始ま っている.発話時の脳波に係る研究では、脳皮質上で観察した ECoG 信号を解析するものが先行している[3][4].他方、頭皮上 で観測した脳波(EEG)を用いる研究も、実用化できると応用が 格段に広がるため、意欲的に進められている.

EEG 信号を用いる音声言語の識別研究は, 発話時の脳波を 対象にするものと, 音声想起(speech imagery)時の脳波を用いる ものがある(サイレント音声).発話時脳波は音声データを同期 に利用できるため, 言語情報の抽出が比較的容易である. 一方, 音声想起時脳波は想起タイミングを同定することが困難なため, 言語情報の抽出が難しい. 発話時脳波との相関を求め, 想起 区間を抽出する手法が試みられているが[5], 決定的な手法と は言い難い.

本報告では、音声想起時の言語表象は tone-burst 波群,す なわち線スペクトル群であるという仮説を基に、線形予測分析 (LPA)を適用して、線スペクトル特徴時系列を抽出する. 続い て、時系列中の音節セグメントを目視でラベリングしたデータを 対象に[6], leave-one-out 法による識別実験を行う. 識別器に は、小規模コーパスで比較的高い精度が得られる部分空間法 (Subspace Method; SM)を用いた[7].

# 2. 提案手法

図1に提案手法のブロック図を示す.

## 2.1 ノイズの除去

音声想起 EEG 信号は、 α 波などの定常雑音、脳波収録時の 電源ノイズ等、想起対象からみて多くのノイズを含む. そこでま ず各電極出力から、単位時間毎に全電極の平均値を引き去る. 全電極の平均値を参照値とすることで、全電極に亘るバイアス を除くことができる. 続いて各電極信号に対して、高次認知機能







#### 図 2 ノイズ除去前後の振幅スペクトル比較 (/a/)

に係る High-γ帯の周波数成分を取り出すため, 70Hz-180Hz の帯域通過フィルタ(BPF)を掛ける. 最後に, 予め想起前後の 定常時脳波振幅スペクトル成分を計算しておき, この周波数成 分をフレーム毎の振幅スペクトル成分から引き去ることで, ノイズ を低減する(noise subtraction). 以上の処理により, 想起対象信 号以外の様々な成分を除去することができた. 図 2 に処理前 (左)と処理後(右)の振幅スペクトルの違いを示す.

#### 2.2 線形予測分析(LPA)による脳波スペクトルの計算

音声想起時の言語表象を線スペクトル群であるとした仮説に 沿って、スペクトルピークの抽出に適した線形予測分析(Linear Predictive Analysis; LPA)を適用して、線スペクトル特徴時系列 を抽出する.線スペクトル群は、比較的少数の成分からなって いることが予備実験からも分かっているため、分析次数は 6 程 度(3 個の周波数ピーク相当)で十分と考えられるが、ノイズを考 慮して 8 次とした(自己相関法のハニング窓長=24msec, 4msec シフト(サンプリング周期 Ts = 2msec)).

LPA は、人間の音声生成過程をモデル化する手法の一つとして開発された方式である.この合成による分析(Analysis-by-Synthesis)手法を脳波に適用すると、脳波信号s(n)はランダムノイズを入力信号f<sub>M</sub>(m)とし、音声想起の脳波を生成する合成フィルタ係数をa<sub>M</sub>(m)として次式の畳み込み演算で表現できる.

 $s(n) = -\sum_{m=1}^{M} a_M(m)s(n-m) + f_M(n)$  (1) ここでMは線形予測の次数を表す. LPA では合成フィルタ係数  $a_M(m)$ をレビンソン・ダービン法から計算して求め, 逆フィルタ 特性として脳波を入力信号とする分析フィルタを構成してスペク トル包絡を求める.

#### 2.3 非線形フィルタによる周波数揺らぎの除去

LPAを用いたスペクトル包絡情報には、5~10 Hz 程度の周 波数揺らぎが存在する.周波数揺らぎはスペクトル包絡の極大 値や変曲点を変化させるため,揺らぎを極力消す必要がある. 本報告では,時間方向に対して非線形フィルタリングすることに より、この揺らぎを低減する.非線形フィルタとしては中間値フィ ルタ(Median filter)を使用し、出力を Gaussian fileter で平滑する. Median filter は算出した振幅スペクトル包絡のうち,同一周波数 帯の前後 3 フレーム(計 7 フレーム)から中央値を出力し, Gaussian filter は 1 フレームシフトで, 前後 3 フレームに対して (1/4, 1/2, 1/4)の重み加算することで、隣接フレーム間の 変動を低減し,時間方向を平滑化する(8msec).

#### 2.4 Pooling による電極出力の統合

想起 EEG 信号は、ブローカ野周辺の 9 電極で観測している が,音声想起時脳波の周波数パターンを観察した結果,ブロー カ野周辺の9 電極で言語情報が観察できることが分かった.し かし,想起内容により活性度の高い電極が異なる現象が観察さ れた. そこで 9 電極に対して, 振幅スペクトルの要素毎に pnorm (p = 4) 演算を適用し,時間フレーム毎に電極情報の集約 を行う. pooling 処理により, 複数電極に亘って観測される音節 の出現情報を1 電極情報として統合表現することができる.

## 2.5 線スペクトルの抽出

電極毎の LPA 分析の後, pooling 処理で統合した振幅スペク トル包絡から線スペクトルを抽出する.線スペクトル計算では、ス ペクトル包絡に対して1階微分ム=0となる極大値,及び,2階 微分ΔΔ=0となる変曲点の双方を求め、それぞれについて最大 3 個を線スペクトルとして検出する. 変曲点を加えたのは、本来 出現すべきスペクトルピークが余り顕著ではない場合にも,線ス ペクトルとして抽出すべき例が少なくなかったためである. なお ΔΔ=0 となる変曲点を線スペクトルとして採用する際には、次の 条件を設けている.

**Δ>0**かつ **ΔΔ**が + から-に変化

 $\Delta < 0$ かつ  $\Delta \Delta$ が – から+に変化 (2)図3に線スペクトルパターンの例を示す.

#### 2.6 音節識別

音節識別には部分空間法(Subspace Method; SM)を用いる. SM は,同一クラスに属するパターンが,低次元部分空間に偏 在することが多いことに着目して考案された手法である. 学習デ ータから各クラスを表現する低次元部分空間を用意し,評価デ ータを部分空間上に射影した際に,最も大きな類似度を与えた 部分空間を評価データの属するクラスとする. 学習データの部 分空間は主成分分析を用いて算出する. k 個のクラスに対して 未知データxを分類する際は、次式の類似度 $s_k(x)$ を算出す る.

$$s_k(x) = \sum_{m=1}^{M} (x \cdot \varphi_{km})^2 \tag{3}$$

ここで,  $\varphi_{km}$  はクラス k の第 m 番目の固有ベクトルであり, m = 1,..., M は部分空間の番号を示す. 部分空間法では, 通 常,入力パターンを正準化(平均値バイアスの除去)すると共に, ノルムで正規化する. 識別の特徴量には上述の線スペクトルと, 周波数間の関連性を表現した Bi-linear 構造(Bi-Spectrum)を フレーム毎に抽出した場合の2通りの検証を行う.また、識別の 際,評価データ毎に求める学習データとの類似度は,音節尤度 ベクトルとして単語識別の特徴量に用いる[8].



# 3. 評価実験

部分空間法を用いた短音節認識を leave-one-out で評価する.

#### 3.1 実験資料

成人男性1名分のブローカ野周辺の9 電極で収録した音声 想起時脳波を用いる. 識別対象の音節は/zero/, /ichi/, /ni/, /san/, /yon/, /go/, /roku/, /nana/, /hachi/, /kyu/の10数字中に含 まれる音節とし,音節セグメント毎に目視ラベリングしたデータを 用いる. 識別対象の音節は以下の 16 音節である.

/i/, /chi/, /ni/, /sa/, /a/, /yo/, /go/, /o/, /ro/, /ku/, /na/, /ha/, /kyu/, /u/, /ze/, /e/

音節識別は母音音節グループ(/a/, /i/, /u/, /e/, /o/), 有声子 音音節グループ(/ni/, /yo/, /go/, /ro/, /na/, /ze/), 無声子音音 節グループ(/chi/, /sa/, /ku/, /ha/, /kyu/)に分けて行う. ただし, 有声子音音節, 無声子音音節は 10 数字を連続で音声想起し たデータからラベリング済みの 11 サンプルを採用し,母音音節 は別に5母音を連続して3回音声想起したデータからラベリン グした 11 サンプルを用いる. また, 子音グループでは/na/と/ni/ など、後続母音の違いは母音認識を別に行うことを考えており、 以下では統合して扱う.

## 3.2 実験結果

部分空間法を用いた各音節グループの音節認識結果を表 1 に示す. 線スペクトルはスパースな表現となっているため, 3 つ の周波数帯域を1つの周波数帯域として平滑し、3フレームを1 フレームに平滑することで正解率が向上した.

| 14 1 14     | 4日,17户日,带 | 「一日母の記頭」 | <b>伯木</b> 正胜平(%) |
|-------------|-----------|----------|------------------|
|             | 母音音節      | 有声子音音節   | 無声子音音節           |
| 線スペクトル      | 43.8      | 43.6     | 38.1             |
| Bi-Spectrum | 51.2      | 40.0     | 36.3             |

主 1 囚卒 方吉卒 毎吉卒伝の詞神姓用

表 1 から,母音音節,有声子音音節,無声子音音節それぞ れのグループについて, チャンスレート(20.0%)を 2 倍程度上 回る結果を得ることができた.

## 4. おわりに

本報告では, 音声想起時脳波から線スペクトル特徴量を抽出 し,音節セグメントを目視でラベリングしたデータに対して,音節 認識を行なった.

実験では成人男性1名が10数字を連続で音声想起した際の 脳波と、5 母音を連続で3回音声想起した脳波を用いた.特徴 抽出時には、定常ノイズの除去、LPA による振幅スペクトル包絡 の算出,非線形フィルタリングによる周波数揺らぎの除去, pooling による電極群の結合を行い、線スペクトルを抽出した.

最後に,部分空間法による母音音節,有声子音音節,無声子 音音節 各グループの音節識別を行なった. 結果はチャンスレ ートを2倍程度上回る結果を得ることができた.実験結果から, 音声想起時脳波に対する線スペクトル特徴量と,目視ラベリン グを行うことの有効性を示すことができたが、今後、被験者を増 やして統計データ処理を行える環境を整え,音声想起の認識 性能向上を図りたい.

# 参考文献

[1] Hochberg L.R. et al: Neuronal ensemble control of prosthetic devices by a human with tetraplegia, Nature, Vol.442, 164-171, 2006.

[2] Velliste M. et al: Cortical control of prosthetic arm for self-feeding, Vol.453, 1098-1101, 2008.

[3] K. E. Bouchard et al: Functional organization of human sensorimotor cortex for speech articulation, Nature 495, 327–332, 2013.

[4] Flinker et al: Redefining the role of Broca's area in speech, PNAS, vol.112, no.9, 2871-2875, 2015.

[5] 神崎卓丸ほか:発話時と想起時の脳波による日本語短音節の比較,日本音響学会春季研究発表会,2017

[6] 新田恒雄ほか: 音声想起時脳波からの音声言語表象抽出 に基づくBCI研究,人工知能学会全国大会,2019

[7] T. Nitta et al: Feature extraction for speech recognition based on orthog-onal acoustic-feature planes and LDA, ICASSP '99, 421-424, 1999.

[8] 平田里佳ほか: 音声想起時脳波からの単語認識, 人工知能 学会全国大会, 2019 音声想起時脳波からの音声言語表象抽出に基づくBCI研究 BCI Research framework based on the extraction of language-representation in speech-imagery EEG

新田 恒雄<sup>\*1,2</sup> 深井 健大郎<sup>\*3</sup> 桂田 浩一<sup>\*3</sup> 入部 百合絵<sup>\*4</sup> 田口 亮<sup>\*5</sup> 杉本 俊二<sup>\*2</sup> 堀川 順正<sup>\*2</sup> Tsuneo Nitta Kentaro Fukai Kouichi Katsurada Yurie Iribe Ryo Taguchi Shunji Sugimoto Junsei Horikawa Waseda Univ.#1 Toyohashi Univ. of Tech.#2 Tokyo Univ. of Science#3 Aichi Prefectual Univ.#4 Nagoya Institute of Tech.#5

Speech imagery, or silent speech, recognition from *Electroencephalogram (EEG)* is one of the challenging technologies for non-invasive brain-computer-interface (BCI). In this report we regard the representation of language as the difference of line spectra of syllables observed at Broker area and develop the method for extracting line spectra in EEG signal. The BCI research framework based on the extraction of language-representation, as well as several examples of syllable investigated using nine electrodes around Broker area, are presented.

# 1. はじめに

近年,fMRI,PET などによる脳観察から,概念→言語表現プ ランニング→ 音節・単 語・文表現→ 発話運動神経系に至る音 声言語活動に関与する部位についての知見が蓄積されつつあ る[1], [2]. これらの知見を受け, 脳波観測から言語活動を推定 する研究が活発である.音声言語に関する脳波研究では,脳 皮質上のセンサーから発話時の脳波(electrocorticogram: ECoG)を検出する研究が先行しているが[3], 頭皮上で観測し た脳波(electroencephalogram: EEG)信号を用いる研究は,実 現されると応用が格段に広がるため意欲的に進められている. これまでの研究では、"音声言語情報が EEG 信号の中で具体 的にどのように表現されているのか"という言語表象に関する解 明は未着手であった.本報告では、言語表象は線スペクトル群 から成っていると仮定し、これらの抽出法を開発することにより、 異なる想起音節では対応する線スペクトルが異なることを示す. また,線スペクトルに基づく BCI 研究で必要となるフレームワー クについても述べる.

# 2. 脳波に現れる言語表象

音声言語は, 左中側頭回(MTG)での概念準備の後, 言語と してのプランニングが左上側頭回(STG)にかけて行われるとされ ている[1]. この後左下前頭回(IFG; ブローカ野)において音節 化(syllabication)が行われ, 音声発話の場合は左中心前回(PG; 運動野)で調音(構音)が行われる[2]. 音声想起(speech imagery)のように発話を伴わない音声言語に対するデコーディ ングも, ブローカ野に到達する言語表象を捉えることができるな ら可能になる.

# 2.1 言語表象観測へのアプローチ

脳波では低周波から順に、 $\theta$ 波(4-8Hz)、 $\alpha$ 波(8-14Hz)、 $\beta$ 波(14-38Hz)、 $\gamma$ 波(26-70Hz)が知られており、認知状態との関 連が古くから研究されてきた.一方近年に入ると、言語が関わる 高次認知活動を $\gamma$ 波より上の帯域(70Hz~)で観測・解析する 研究が盛んである.

我々は脳波解析に先立ち,「言語表象は低周波の定常的信号と同様の正弦波で,かつ言語の性格から極短時間だけ現れる」と考えた.こうした信号は tone-burst と呼ばれ,古くから過渡的信号の解析に用いられてきた.また正弦波の継続長は,反転音声(reverse speech [4])に関する実験から,反転の単位を 100



#### 音声想起脳波合成モデル



図 2 脳波の合成による分析モデル

msec 以下になると音声を明瞭に確認できることが知られており、 この事実から tone-burst 信号の継続長を 32-128msec と推測した.

図1に周波数の異なる tone-burst 信号とそのスペクトル形状 を示す. tone-burst 波は,時間窓の内部では正弦波であるが, 過渡的信号の性格から図のようにスペクトル分布に広がりを持 つ. このため,元々の線スペクトル成分を抽出するための信号 処理が必要になる.以下では線形予測分析(Linear Predictive Analysis; LPA)と線スペクトル抽出方法について説明する.

#### 2.2 線形予測分析(LPA)法に基づく脳波の分析[5]

線形予測分析(Linear predictive analysis; LPA)を図2から説 明する.図は音声想起脳波を念頭においた脳波合成モデルと 脳波から言語表象を含むスペクトル情報抽出のための分析モ

連絡先:新田恒雄,早稲田大学/豊橋技術科学大, nitta@cs.tut.ac.jp

デルを示している. 合成モデルでは, 信号源としてのランダム波 w(n)を入力とし, 言語情報を生成する神経系のインパルス応答 s(n) との畳み込み演算により, 規則性を付与された脳波として tone-burst 群から成る x(n) が出力される. 図には周波数領域で の表現 {W(k), S(k), X(k)}も示した. インパルス応答 s(n) は線 形予測係数 {a0, a1, ...ap}から計算することができる.

電極で観測される脳波 x(n)に対する分析モデルでは,合成モデルで与えられた線形予測係数から,脳波の持つ言語表象を計算する(Analysis-by-Synthesis; AbS).通常の計算アルゴリズムでは,まず脳波の自己相関係数から Durbin 法を適用して線形予測係数を求め,逆フィルターを構成して脳波のスペクトルを分析する.この時,線形予測係数(ここでは 8 次) に 0-padding を施すことで,任意の周波数分析精度を得ることができる.図3にFFT分析と比較したLPAの分析例を示す.

### 3. 脳波測定と言語表象の抽出

ブローカ野を中心に9個(3×3)の電極を配置した.10-20 法での電極位置は{(F3, F5, F7), (FC3, FC5, FT7), (C3, C5, T7)}で,g-tec 社の脳波計を使用して EEG 信号を採取 した.データ収集に関する詳細は,文献[7]に同じである. 電極毎に LPA 分析した後,周波数揺らぎに対して中間値フ ィルターとガウス平滑フィルターによる揺らぎ除去を行っ た.続いて,9電極の振幅スペクトルの各要素について, p-norm (p=4) による pooling 処理を行った.この処理後 は,単一チャンネルの振幅スペクトル系列信号に対して, 周波数方向の1階微分(極大値抽出),および2階微分(変曲 点抽出)を計算して,線スペクトルを抽出する[6].

音声想起/a-i-u-e-o/と10数字連続音声想起のデータから目 視で音節をラベリングした./a-i-u-e-o/については三回連続して 音声を想起することで,熟練した研究者は線スペクトルパターン の変化から音節を特定することができる.10数字音声想起では, 別に採取した101単音節データの標準パターンを参照してラベ リングの精度を上げる工夫をした.

図4に幾つかの音節の線スペクトルパターンを示す. 周波数 は 70Hz ~176Hz の範囲に分布している. 線スペクトルは 2~5 個程度が観察されるが、これらの意味解明は今後の課題である. 図の左側には5母音音節の線スペクトルを示した、この中では /u/の線スペクトルが低周波に集中することが顕著である.ここに 示した例から,母音同士の分離は可能と思われるが,今後,統 計的に調査したい. 図の右側には, 連続数字 "0-1-2-...-9-0"を 想起した際の脳波から採取したオ段の4つの音節を示した.音 節想起パターンでは、母音の影響が顕著であるが、後続母音が 同じ音節でも線スペクトルパターン上には違いが観られ,分離 が可能と思われる、音声学/音韻論では、音素と音節の意義が 長らく討議されているが、脳波に観られる言語表象としては、音 節に軍配が上がりそうである. ただし, これも今後, 定量的な調 査が必要である. 線スペクトルパターンは所謂スパースな特徴 である.このため、認識エンジンの中で線スペクトルを扱うには、 今後工夫が必要になると思われる[6], [7].

音声想起信号中の言語情報を線スペクトル群から抽出する ことの有効性を示すデータとして、図 5 に連続数字を想起した データに対して手動ラベリングを行ったものを示す. 図は音節 尤度を部分空間法から計算してパターン化したものを示してい る. この図から比較的容易に音節ラベリングが可能になることが 理解できよう. ただし部分空間法での辞書は学習データ内の音 節パターンを用いており, 将来, 非学習データに対して, 同様 の性能を得ることが目標となる.



図 3 FFT 分析と LPA 分析のパターン比較 (/a/)

周波数 Hz



図 4 音節の線スペクトルパターンの例



図6 言語表象に基づく BCI 研究フレームワーク

# 4. 言語表象に基づく BCI 研究フレームワーク

言語表象に基づくBCI研究はALS患者など医用だけでなく, 次世代 AI speaker 等波及効果が大きい. そのためここ数年は, 図6に示すようなセンサーデバイス,認識エンジンの開発と共に, 音声想起 DB,言語表象 DB,音節ラベリングツール[8]を整備す る必要がある.

# 5. おわりに

音声想起時の脳波から,言語表象としての線スペクトル群を 抽出する方法を開発し,想起音節間で線スペクトル特徴が分離 できることを示した.今後,被検者数を増やすと共に,ラベリング ツールの整備と言語特徴の抽出精度向上を図りたい.

# 参考文献

 Indefrey, P et al., The spatial and temporal signatures of word production components, Cognition 92, 101-144 (2004).

[2] Bouchard K.E. et al., Functional organization of human sensorimotor cortex for speech articulation, Nature 495, 327-332 (2013).

[3] Heger D. et al., Continuous Speech Recognition from ECoG, Interspeech2015, 1131-1135 (2015).

- [4] https://en.wikipedia.org/wiki/Reverse speech
- [5] 板倉,斎藤,最尤スペクトル推定法を用いた音声情報圧縮, 音声日本音響学会誌, 27-9, 17-26 (1971).
- [6] 深井ほか, 音声想起時脳波中の音節識別について, 人工 知能学会全国大会(2019).
- [7] 平田ほか, 音声想起時脳波からの単語認識, 人工知能学会 全国大会(2019).
- [8] 傅ほか, 音声想起時脳波からの音節ラベリングツール, 人工 知能学会全国大会(2019).



## 図5 連続数字音声想起データに対する手動音節ラベリング

(図の右端に音節名を示し,図は濃淡で音節尤度を示した.)

Interactive Session

# [3Rin2] Interactive Session 1

Thu. Jun 6, 2019 10:30 AM - 12:10 PM Room R (Center area of 1F Exhibition hall)

| [3Rin2-01] | Traffic Risk Estimation from On-vehicle Video by Region-based Spatio-<br>temporal DNN trained using Comparative Loss  |
|------------|---|
|            | OKwong Cheong Ng <sup>1</sup> , Yuki Murata <sup>1</sup> , Masayasu Atsumi <sup>1</sup> (1. Dept. of Information Systems Sci.,<br>Graduate School of Eng., Soka University)   |
| [3Rin2-02] | Bi-directional multimodal generation via estimating conditional   |
|            | distribution of latent variables obtained from pre-trained generative models  |
|            | OShigeaki Imakiire <sup>1</sup> , Masanao Ochi <sup>1</sup> , Junichiro Mori <sup>1</sup> , Ichiro Sakata <sup>1</sup> (1. University of Tokyo<br>School of Engineering Department of Technology Management for Innovation) |
|            | 10:30 AM - 12:10 PM   |
| [3Rin2-03] | Binarized Variational Information Bottleneck  |
| [          | $\bigcirc$ Makoto Kawano <sup>1</sup> , Yu Oya <sup>2</sup> , Satoshi Yagi <sup>2</sup> , Jin Nakazawa <sup>1</sup> (1. Keio University, 2. NTT   |
|            | Corporation)  |
|            | 10:30 AM - 12:10 PM   |
| [3Rin2-04] | Semi-supervised Domain Adaptation using Prediction Models in  |
|            | Associated Domains  |
|            | $\bigcirc$ Yasuhiro Sogawa <sup>1</sup> , Tomoya Sakai <sup>1</sup> (1. NEC Corporation)  |
|            | 10:30 AM - 12:10 PM   |
| [3Rin2-05] | A study on measures in multi-armed bandit problem with hidden state.  |
|            | OKouhei Kudo', Takashi Takekawa' (1. Kogakuin University)   |
|            | 10:30 AM - 12:10 PM   |
| [3RIN2-06] | An Approach to Unseen Classs Classification with In-Service Predictors  |
|            | O Tomoya Sakai", Yasuhiro Sogawa" (T. NEC Corporation)  |
| [2Pin2_07] | 10:30 AM - 12:10 PM<br>Multi-armod bandit algorithm applicable to stationary and non-   |
|            | stationary environment using self-organizing mans   |
|            | $\Omega$ Nohuhito Manoma <sup>1,2</sup> Shuji Shinohara <sup>2</sup> Kouta Suzuki <sup>1,2</sup> Kosuka Tomonaga <sup>1,2</sup> Shunii  |
|            | Mitsuvoshi <sup>2</sup> (1 SoftBank Robotics Corp. 2 Graduate School of Engineering The University  |
|            | of Tokyo)   |
|            | 10:30 AM - 12:10 PM   |
| [3Rin2-08] | Learning Interpretable Control Policies with Decision Trees via the   |
|            | Cross-Entropy Method  |
|            | OYukiko Tanaka <sup>1,2</sup> , Takuya Hiraoka <sup>1,2</sup> , Yoshimasa Tsuruoka <sup>2,3</sup> (1. NEC, 2. National Institute of   |
|            | Advanced Industrial Science and Technology, 3. The University of Tokyo)   |
|            | 10:30 AM - 12:10 PM   |
| [3Rin2-09] | Development of Embedded System for Recognizing Kuzushiji by Deep  |
|            | Learning  |
|            | Masahiro Takeuchi', OTaichi Hayasaka', Wataru Ohno', Yumie Kato <sup>2</sup> , Kazuaki Yamamoto <sup>3</sup> ,  |
|            | Mamoru Ishima <sup>+</sup> , Tetsuya Ishikawa <sup>+</sup> (1. National Institute of Technology, Toyota College, 2.   |
|            | Isurumi University, 3. National Institute of Japanese Literature, 4. TRC-ADEAC, Inc.)   |

|            | 10:30 AM - 12:10 PM  |
|------------|--|
| [3Rin2-10] | Stochastic Regularization for Residual Networks: Shake-ResDrop and Shake-SENet   |
|            | OJunya Shirahama <sup>1</sup> , Kazuhiko Kawamoto <sup>1</sup> (1. Chiba University)<br>10:30 AM - 12:10 PM  |
| [3Rin2-11] | Fairness-aware Edit of Thresholds in a Learned Decision Tree Using a Mixed Integer Programming Formulation   |
|            | OKentaro Kanamori <sup>1</sup> , Hiroki Arimura <sup>1</sup> (1. Hokkaido University)<br>10:30 AM - 12:10 PM   |
| [3Rin2-12] | Predicting Laughters in Comedy Drama with Subtitles and Facial<br>Expression   |
|            | OYuta Kayatani <sup>1</sup> , Mayu Otani <sup>2</sup> , Chenhui Chu <sup>3</sup> , Yuta Nakashima <sup>3</sup> , Haruo Takemura <sup>1</sup> (1.<br>Graduate School of Information Science and Technology, Osaka University, 2. CyberAgent,<br>Inc., 3. Institute for Datability Science, Osaka University)<br>10:30 AM - 12:10 PM   |
| [3Rin2-13] | Application of Aspect-based Sentiment Analysis using Self-Attention<br>Mechanism to Japanese Sentences   |
|            | ORyuichi Akai <sup>1</sup> , Masayasu Atsumi <sup>1</sup> (1. Graduate School of Engineering, Soka University)<br>10:30 AM - 12:10 PM  |
| [3Rin2-14] | Estimating Emotion Intensities in Japanese Tweets Using Emotion<br>Intensity Lexicon   |
|            | OTatsuki Akahori <sup>1</sup> , Kohji Dohsaka <sup>1</sup> , Hidekatsu Ito <sup>1</sup> , Masaki Ishii <sup>1</sup> (1. Akita Prefectural<br>University)   |
| [3Rin2-15] | An Investigation of Effective Features for Toponym Resolution of Words<br>in Newspaper Articles  |
|            | ORyo Seki <sup>1</sup> , Takashi Inui <sup>1</sup> (1. University of Tsukuba)<br>10:30 AM - 12:10 PM   |
| [3Rin2-16] | Cluster analysis of Twitter Data, using Interactive Data visualization Tool<br>OShinichiro Wada <sup>1</sup> (1. Graduate School of Sociology, Rikkyo University.)<br>10:30 AM = 12:10 PM  |
| [3Rin2-17] | Comparative Analysis of the Effect of Additional Training between<br>Multiple Domains by Clustering of the Embeddings of Parsing Errors<br>OTakuya Hara <sup>1</sup> , Takuya Matsuzaki <sup>1</sup> , Hikaru Yokono <sup>2</sup> , Satoshi Sato <sup>1</sup> (1. Graduate School of<br>Engineering, Nagoya University, 2. Fujitsu Laboratories Ltd.)<br>10:30 AM - 12:10 PM |
| [3Rin2-18] | Vending Machine Drink Recognition with Deep Learning for IoT Device.<br>OKatsuhiro Araya <sup>1</sup> , Takayuki Osa <sup>2</sup> , Shigemitsu Yamaoka <sup>2</sup> , Kazuhiko Nishi <sup>2</sup> , Masayuki Nakao <sup>2</sup><br>(1. Arkth Inc., 2. University of Tokyo, School of Engineering)<br>10:30 AM - 12:10 PM   |
| [3Rin2-19] | Robust Eye Contact Detection for Multi-Party Conversational Systems<br>OKenjiro Nogawa <sup>1</sup> , Shinya Fujie <sup>2</sup> , Tetsunori Kobayashi <sup>1</sup> (1. Waseda University, 2. Chiba<br>Institute of Technology)<br>10:30 AM - 12:10 PM  |
|            |  |

[3Rin2-20] Succesive estimation of the asteroid shape and probe motion using sequential images

OToma Suzuki<sup>1</sup>, Takehisa Yairi<sup>1</sup>, Naoya Takeishi<sup>1</sup>, Yuichi Tsuda<sup>2</sup>, Naoko Ogawa<sup>2</sup> (1. The University of Tokyo, 2. Japan Aerospace Exploration Agency) 10:30 AM - 12:10 PM

[3Rin2-21] Image-to-image Translation from Apparel Item Image Placed Flat to Image Put on Using Deep Neural Networks

Saki Tsumugiwa<sup>1</sup>, OYoshiaki Kurosawa<sup>1</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa<sup>1</sup> (1. Hiroshima City University)

10:30 AM - 12:10 PM

- [3Rin2-22] Noise reduction of live image in scanning electron microscope OFuminori Uematsu<sup>1</sup>, Masahiko Takei<sup>1</sup>, Mitsuyoshi Yoshida<sup>1</sup> (1. JEOL Ltd.) 10:30 AM - 12:10 PM
- [3Rin2-23] Truthful Dynamic Pricing Mechanisms for On-demand Mobility Services OKeiichiro Hayakawa<sup>1</sup>, Eiji Hato<sup>2</sup> (1. Toyota Central R&D Labs., Inc., 2. The University of Tokyo)

10:30 AM - 12:10 PM

[3Rin2-24] Multi-agent simulation tool incorporation group evacuation behavior model

ORyusei Ishida<sup>1</sup>, Masanori Akiyoshi<sup>1</sup> (1. Kanagawa University)

10:30 AM - 12:10 PM

[3Rin2-25] A study of observation fluctuation reduction method for ear acoustic authentication

OMasaki Yasuhara<sup>1</sup>, Takayuki Arakawa<sup>2</sup>, Takafumi Koshinaka<sup>2</sup>, Shohei Yano<sup>1</sup> (1. National Institute of Technology, Nagaoka College, 2. NEC Corporation) 10:30 AM - 12:10 PM

[3Rin2-26] New similarity scale to recognize bird calls and abnormal sounds of concrete/machine

OMichihiro Jinnai<sup>1</sup>, Edward James Pedersen<sup>2</sup> (1. Nagoya Women's University, 2. Central Queensland University, Australia)

10:30 AM - 12:10 PM

[3Rin2-27] An Investigation of Controllable Neural Conversation Model with Dialogue Acts

> OSeiya Kawano<sup>1</sup>, Koichiro Yoshino<sup>1,2</sup>, Satoshi Nakamura<sup>1</sup> (1. Nara Institute of Science and Technology, 2. Japan Science and Technology Agency) 10:30 AM - 12:10 PM

# [3Rin2-28] Improvement of Knowledge Graph Completion Using Label Characters for Questions to Acquire Knowledge in Dialog Systems

OYuma Fujioka<sup>1</sup>, Katsuhiko Hayashi<sup>1</sup>, Mikio Nakano<sup>2</sup>, Kazunori Komatani<sup>1</sup> (1. The Institute of Scientific and Industrial Research, Osaka University, 2. Honda Research Institute Japan Co.,Ltd.)

10:30 AM - 12:10 PM

# [3Rin2-29] Acquisition and Utilization of Trivia for Conversational News Contents Delivery

OHiroaki Takatsu<sup>1</sup>, Yoichi Matsuyama<sup>1</sup>, Hiroshi Honda<sup>2</sup>, Shinya Fujie<sup>1,3</sup>, Tetsunori Kobayashi<sup>1</sup>

(1. Waseda University, 2. Honda R&D Co.,Ltd., 3. Chiba Institute of Technology) 10:30 AM - 12:10 PM

[3Rin2-30] Generative Adversarial Networks toward Representation Learning for Image Captions

OYuki Abe<sup>1</sup>, Takuma Seno<sup>1</sup>, Shoya Matsumori<sup>1</sup>, Michita Imai<sup>1</sup> (1. Keio University) 10:30 AM - 12:10 PM

# [3Rin2-31] Speech extraction from conversation based on image-to-image translation using deep neural networks

OKosuke Takaichi<sup>1</sup>, Yoshio Katagami<sup>2</sup>, Yoshiaki Kurosawa<sup>1</sup>, Kazuya Mera<sup>1</sup>, Toshiyuki Takezawa <sup>1</sup> (1. Graduate School of Information Sciences Hiroshima City University, 2. School of Information Sciences Hiroshima City University)

10:30 AM - 12:10 PM

- [3Rin2-32] An anti-noise performance comparison between acoustic features in detecting voice pathology using machine learning
  - OKouta Suzuki<sup>1,2</sup>, Shuji Shinohara<sup>2</sup>, Nobuhito Manome<sup>1,2</sup>, Kosuke Tomonaga<sup>1,2</sup>, Shunji Mitsuyoshi<sup>2</sup> (1. SoftBank Robotics Corp., 2. Graduate School of Engineering, The University of Tokyo)

10:30 AM - 12:10 PM

# [3Rin2-33] Toward proofreading support using Word2vec OMasato Maruyama<sup>1</sup>, Takashi Takekawa<sup>1</sup> (1. Kogakuin University)

- 10:30 AM 12:10 PM
- [3Rin2-34] Construction of Corpus for Text Simplification by Sentential Alignment based on Decomposable Attention Model

OKoichi Nagatsuka<sup>1</sup>, Masayasu Atsumi<sup>1</sup> (1. Soka University) 10:30 AM - 12:10 PM

# [3Rin2-35] What's Here Like? Analysis of Web Search Log Based on User's Location

OTatsuru Higurashi<sup>1</sup>, Kouta Tsubouchi<sup>1</sup> (1. Yahoo Japan Corporation) 10:30 AM - 12:10 PM

# [3Rin2-36] Relevance Analysis among Domestic Enjoyments based on News Site App Users' Interest

OKota Kawaguchi<sup>2,1</sup>, Tatsukuni Inoue<sup>1</sup>, Seiya Osada<sup>1</sup>, Tatsuo Yamashita<sup>1</sup> (1. Yahoo! JAPAN, 2. University of Tsukuba)

10:30 AM - 12:10 PM

[3Rin2-37] Implementation and Evaluation of an Interpretable Fake News Detector OKazuya Yamamoto<sup>1</sup>, Satoshi Oyama<sup>1</sup>, Masahito Kurihara<sup>1</sup> (1. Hokkaido University) 10:30 AM - 12:10 PM

# [3Rin2-38] Automatic Evaluation for Cyberbullying Detection Method based on Statistical Scale

OMasaki Arata<sup>1</sup>, Fumito Masui<sup>1</sup>, Michal Edmond Ptaszynski<sup>1</sup> (1. Kitami Institute of Technology)

10:30 AM - 12:10 PM

# [3Rin2-39] Automatic Impression Indexing based on Appraisal Dictionary from Tweet

ORuna Yamada<sup>1</sup>, Sho Hashimoto<sup>1</sup>, Atsuhiro Yamada<sup>1</sup>, Noriko Nagata<sup>1</sup> (1. Kwansei Gakuin

University)

10:30 AM - 12:10 PM

[3Rin2-40] Catch Me if Yahoo Can: Hotel Recommendation for Potential Travelers using Transit App Log

OMikiya Maruyama<sup>1</sup>, Kotaro Takahama<sup>1</sup>, Kota Tsubouchi<sup>1</sup>, Teruhiko Teraoka<sup>1</sup> (1. Yahoo Japan Corporation)

10:30 AM - 12:10 PM

# [3Rin2-41] Official document simplification using neural machine translation approach

OTakumi Maruyama<sup>1</sup>, Kazuhide Yamamoto<sup>1</sup> (1. Nagaoka University of Technology) 10:30 AM - 12:10 PM

# [3Rin2-42] Neural Error Detection for Weather Forecast Manuscript by Pseudo Error Corpus

ONaruhisa Shirai<sup>1</sup>, Masatsugu Hangyo<sup>2</sup>, Mamoru Komachi<sup>1</sup> (1. Tokyo Metropolitan University, 2. WEATHERNEWS INC.) 10:30 AM - 12:10 PM

# [3Rin2-43] Neural Sequence-Labelling Models for ASR Error Correction

OTaishi Ikeda<sup>1</sup>, Hiroshi Fujimoto<sup>1</sup>, Takeshi Yoshimura<sup>1</sup>, Yoshinori Isoda<sup>1</sup> (1. NTT DOCOMO, INC.)

10:30 AM - 12:10 PM

# [3Rin2-44] Construction of a Diagnosis Representation Model of Person with Dementia Based on ConceptNet for Deeper Understanding of Physical and Mental Conditions

ONaoki Kamiya<sup>1</sup>, Takumi Yoshizawa<sup>1</sup>, Shogo Ishikawa<sup>1</sup>, Hideki Ueno<sup>2,4</sup>, Mia Kobayashi<sup>2,4</sup>, Minoru Maeda<sup>3</sup>, Chiaki Nishiyama<sup>3</sup>, Yujun Murakami<sup>3</sup>, Shinya Kiriyama<sup>1,4</sup>, Yoichi Takebayashi <sup>1,4</sup> (1. Shizuoka University, 2. Chiba University Hospital, 3. Orange Cross Foundation, 4. The Society of Citizen Informatics for Human Cognitive Disorder) 10:30 AM - 12:10 PM

# [3Rin2-45] Evaluation and Analysis of design for life environment with a high regard for self- reliance based on the representation of a self of people with dementia

OMika Teramen<sup>1</sup>, Shogo Ishikawa<sup>1</sup>, Shinya Kiriyama<sup>1</sup>, Tadasuke Kato<sup>2</sup>, Takeshi Ide<sup>2</sup>, Yoichi Takebayashi<sup>1,3</sup> (1. Shizuoka University, 2. Aoicare Co., Ltd, 3. Citizen Informatics for Human Cognitive Disorder)

10:30 AM - 12:10 PM

# [3Rin2-46] Development of Electroencephalogram brain-machine interface using convolutional neural network

OMasaki Kato<sup>1</sup>, Sotaro Shimada<sup>2</sup> (1. Meiji University Graduate School, 2. Meiji University) 10:30 AM - 12:10 PM

# [3Rin2-47] Evaluation of Automatic Monitoring of Instillation Adherence Using Eye Dropper Bottle Sensor and Deep Learning in Patients with Glaucoma OHitoshi Tabuchi Tabuchi<sup>1,2</sup>, Kazuaki Nishimura<sup>1</sup>, Shunsuke Nakakura<sup>1</sup>, Hiroki Masumoto<sup>1</sup>, Hirotaka Tanabe<sup>1</sup>, Asuka Noguchi<sup>1</sup>, Ryota Aoki<sup>1</sup>, Yoshiaki Kiuchi<sup>2</sup> (1. Tsukazaki Hospital, 2. Hiroshima University) 10:30 AM - 12:10 PM

# [3Rin2-48] Sleep/wake classification using remote PPG signals Yawen Zhang<sup>1</sup>, OMasanori Tsujikawa<sup>2</sup>, Yoshifumi Onishi<sup>2</sup> (1. HKUST, 2. NEC) 10:30 AM - 12:10 PM

# [3Rin2-49] Biomarker discovery from gene expression data of mixed tumor samples OKatsuhiko Murakami<sup>1</sup> (1. Fujitsu Laboratories Ltd.) 10:30 AM - 12:10 PM

# Traffic Risk Estimation from On-vehicle Video by Region-based Spatio-temporal DNN trained using Comparative Loss

Kwong Cheong Ng Yuki Murata Masayasu Atsumi

Dept. of Information Systems Sci., Graduate School of Eng., Soka University

Abstract: We propose a method to estimate the traffic risk during road navigation based on the region-based spatiotemporal deep neural network (DNN) trained by the comparative loss function. In this method, moving object regions are extracted using the object detector YOLO and their features are clipped out from the middle layer of the detector. Then, these feature sequence is used to estimate the traffic risk by the spatio-temporal DNN followed by the risk estimation network. Experiments were conducted using the KITTI and Dashcam Accident dataset images and we have shown that it is possible to estimate a dangerous traffic situation using the proposed risk estimation network.

## 1. Introduction

In the research of advanced driver-assistance systems (ADAS) and autonomous driving, numerous studies have been conducted to estimate the risk of traffic situation from images of driver's viewpoints [1, 2, 7]. In this paper, we propose a traffic risk estimation method based on the region-based spatio-temporal deep neural network (DNN) trained using the comparative loss function. In this method, first, moving object regions are detected using the object detector YOLO [4, 5] from each frame of a video and their features are extracted from a middle layer of the detector. Then, these object feature sequence is input into the spatio-temporal pattern encoding network which consists of a convolutional neural network (CNN) and a long short-term memory (LSTM) and the risk is estimated by the risk estimation network trained by the comparative loss function. The accuracy of the risk estimation is evaluated using a dataset of on-vehicle cameras.

## 2. Related Work

#### 2.1 Traffic Risk Estimation

Several studies have been proposed in the research of estimating upcoming traffic incidents. Chan et al. [1] proposed a dynamic-spatial-attention Recurrent Neural Network (RNN) that could anticipates accidents before they occur. Suzuki et al. [2] extended the work of Chan by introducing an Adaptive Loss for Early Anticipation (AdaLEA) method which allows a model to learn earlier incident anticipation as training progresses. In addition, a quasi-recurrent neural network (QRNN) is adopted in the base model to enable stable output from temporal convolution on sequential data such as videos. However, these methods are specialized in anticipating traffic accidents, while our proposed method takes into account learning risk estimation of any traffic situation including accidents, risky incidents, congestion and so on through the comparative loss function. On the other hand, Mark et al. [6] suggested a Deep Predictive Model that can learn its own, task-specific filters which improves prediction performance. The model uses a Bayesian

Contact: Kwong Cheong Ng, e18m5252@soka-u.jp

convolutional long short-term memory (ConvLSTM) method to process spatio-temporal visual data, proprioceptive data and steering commands to identify potential impending collisions. In addition, Ernest Cheung *et al* [8] proposed another approach called Trajectory to Driver Behavior Mapping (TDBM) that accounts the driving behavior of neighboring vehicles to perform risk assessment.

#### 2.2 Traffic Datasets for Risk Estimation

Several datasets are available for studies of the traffic risk estimation. In [1], the Dashcam video dataset is proposed to evaluate the proposed method in which 678 dashcam videos captured across six cities in Taiwan are used. This dataset is also used in this paper to estimate risk for traffic accidents. To focus on near-miss traffic incidents, Suzuki et al [7] introduced a Large Scale Near-Miss Traffic Incident database (NIDB) that comprises over 6.2K videos and 1.3M frames, many of which are incident scenes and are classified into seven classes, including low/high risk for bicycles, pedestrians, and vehicles, as well as a background class. However, as the NIDB dataset is not opensource, it is not used in this paper. Mark et al. [6] uses a robotic simulation platform proposed in [9] to simulate experiment data, whereby the training dataset is generated using a series of dynamic street scenes involving two vehicles in a sparsed simulated environment. Due to the dataset is not generated from a real environment, the approach is not used in this paper.

# 3. Risk Estimation Method

#### 3.1 Overview

As shown in Figure 1, the proposed network consists of the object detector YOLOv2, a moving objects' spatial pattern encoding CNN, a moving objects' spatio-temporal pattern encoding LSTM, and a risk estimation network. First, moving object regions are detected using the YOLO object detector from on-vehicle camera images and their features are extracted from its middle layer. Then, by inputting the feature sequence of these moving object regions into the spatio-temporal pattern encoding network which consists of a CNN and a LSTM, spatio-temporal feature of moving objects are extracted, and the traffic risk is estimated based on the risk estimation network. The risk estimation network is trained by the comparative loss function



Figure 1: Overview of proposed network

using a set of pairs of images with different relative risk levels.

#### 3.2 Object Feature Extraction

To estimate the risk level on an on-vehicle camera images, it is necessary to detect objects which are involved in traffic risk. Although it is necessary to attend various objects during driving, the important attention targets are moving objects. Therefore, in this research, a pre-trained YOLO using the COCO dataset is further trained using the KITTI dataset [3] and the Dashcam Accident dataset [1], which are on-vehicle camera datasets, to detect moving objects. The target objects to be detected are classified into the following seven categories – car, truck, person, tram, bicycle, motorbike and bus. These categories were unified between the two datasets.

After detecting the moving objects, their features are extracted using the coordinates of them from middle convolutional layers of the YOLO. The 21<sup>st</sup> layer is used as the middle layer for YOLOv2.

#### 3.3 Moving Objects' Spatio-temporal Feature

The moving objects' spatio-temporal feature is extracted by applying the spatio-temporal pattern encoding network to a composite feature map in which only the convolutional features of moving object regions are clipped from a feature map of the middle layer of YOLO (Figure 1). The network consists of the spatial pattern encoding CNN followed by a spatial pyramid pooling layer and the spatio-temporal pattern encoding LSTM. Figure 2 shows the detailed configuration of the network. In the figure, the (2, 2) of the max pooling layer represents the kernel size and the stride. The (512, 3, 1, 1) of the convolutional layer represents the number of output channels, the kernel size, and the padding width. The (3) in the spatial pyramid pooling layer is the number of pyramid levels.

#### 3.4 Risk Estimation and Comparative Loss Function

In general, it is difficult to evaluate traffic risk by objective numerical values. On the other hand, it is easier to evaluate which is dangerous between a situation where an accident is likely to occur and a situation where no accident occurs or which is dangerous between a congested situation and a non-congested situation. Therefore, we introduce the comparative loss function that learns a correct risk estimation function through relative



Figure 2: Spatio-temporal pattern encoding network of moving objects

comparison of the risk level between pairs of two spatiotemporal patterns of moving objects. In training, each estimated risk is tuned according to a supervised signal that gives which is more dangerous. Let two camera images be labelled as  $v_1, v_2$ , their relative risk be labelled as  $R(v_1, v_2)$ , and  $r_1, r_2$  be estimated risks by a sigmoid activation function of the risk estimation network (a perception) respectively. The  $R(v_1, v_2)$  is a supervised signal which takes a value of 1 when  $v_1$  is more dangerous than  $v_2$ , -1 when  $v_1$  is safer than  $v_2$ , and 0 when both are comparatively equal. Then, the comparative loss function is defined by the following equation:

$$L(r_1, r_2, R(v_1, v_2)) =$$

$$\begin{cases} \max(r_2 - r_1 + m, 0) & \dots R(v_1, v_2) = 1 \\ |r_2 - r_1| & \dots R(v_1, v_2) = 0 \\ \max(r_1 - r_2 + m, 0) & \dots R(v_1, v_2) = -1 \end{cases}$$
(1)

Here, *m* is a parameter that provides a margin of relative comparison.

In risk estimation, the degree of risk is computed by the risk estimation network from the moving objects' spatio-temporal pattern in each frame interval of a video.

#### 4. Dataset

In experiments, both the KITTI dataset [3] and Dashcam Accident dataset [1] were used for training the object detection network YOLO, and the Dashcam Accident dataset was used for risk estimation experiments. The Dashcam Accident dataset contains videos with accidents and videos without accidents, and only videos with accidents were used in experiments. Each video consists of 100 frames and accidents occur in the last 10 frames. Therefore, in risk prediction experiments, each video was divided into a non-accident part of the former 50 frames and an accident part of the latter 50 frames. The dataset used for the risk estimation is configured as shown in Table 1.

Table 1. Configuration of a dataset. Videos with accidents (positive) samples and videos without accidents (negative) samples. Numerical values in each cell represent the number of videos/ the number of frames

|          | Training  | Test     |
|----------|-----------|----------|
| positive | 455/22750 | 164/8200 |
| negative | 455/22750 | 164/8200 |

# 5. Experiments

#### 5.1 Outline of Experiments

The evaluation of risk estimation was performed for two cases: one was performed between videos with accidents and videos without accidents, and the other was performed between two videos without accidents. In the former, the comparative loss function specifies the relative comparison in which videos with accidents are more dangerous. Here, the relative comparison margin was set to 0.5. In the latter, the comparative loss function specifies relative comparison in which videos with more moving objects are more dangerous. Here in this case, the relative comparison margin was set to 0.1.

### 5.2 Results

The detection performance of moving objects using YOLOv2 was evaluated by the mean average precision (mAP) and the intersection over union (IOU). As a result, the mAP was 0.2902 and IOU was 0.5996. Since the result of detection performance was not so accurate, we evaluated the risk prediction performance by extracting moving object features from YOLOv2 using ground truth object region boxes.

Table 2 shows the result of risk estimation between videos with accidents and videos without accidents.

In table 2, BG\_ZERO and BG\_GN represent that the region other than moving objects is filled with zero (for BG\_ZERO) and filled with Gaussian noise (for BG\_GN) respectively. In addition, 'DO' represents that a dropout is applied to the output of the fully connected layer in Figure 2.

Table 3 shows the result of risk estimation between two videos without accidents but with the different numbers of moving objects.

| Table 2. Accuracy of risk estimation between videos | with |
|---|------|
| accidents and videos without accidents              |      |

|         | Training (%) |        |        | Test (%) |
|---------|--------------|--------|--------|----------|
|         | w/ DO        | w/o DO | w/ DO  | w/o DO   |
| BG_ZERO | 99.771       | 97.706 | 69.565 | 62.733   |
| BG_GN   | 97.706       | 94.839 | 70.807 | 72.050   |

Table 3. Accuracy of risk estimation between videos without accidents but with the different number of moving objects

|         | Training w/o DO (%) | Test w/o DO (%) |
|---------|---------------------|-----------------|
| BG_ZERO | 93.349              | 86.957          |

Based on the results of these experiments, we found that the proposed method achieved a better result when BG\_GN was used. This means that the Gaussian noise is useful to achieve robust training for risk estimation. In addition, we found that the proposed method was able to estimate dangerous situation not only caused by accidents but also triggered by congestion.

# 6. Conclusion

In this paper, we have proposed a traffic risk estimation DNN which is trained by the comparative loss function. This network encodes a spatio-temporal pattern of moving objects based on YOLO and the spatio temporal network and estimates traffic risk using the risk estimation network. Then, in the experiments, we have shown that it is possible to estimate traffic risk by the proposed network. As a future work, we are going to improve the accuracy of preliminary risk prediction by extending the risk estimation network. To improve the efficiency of the feature extraction, we are going to study the latest object detector YOLOv3 in hope of replacing YOLOv2 for better performance. In addition, we hope to study the effect of detecting traffic signs in traffic risk estimation and add them as a new object detection category.

# References

[1] Chan, F-H., et al., Anticipating Accidents in Dashcam Videos, ACCV, 2016

[2] Suzuki, T., et al., Anticipating Traffic Accidents with Adaptive Loss and Large-scale Incident DB, CVPR, 2018

[3] Geiger, A., et al, Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite, CVPR, 2012

[4] Redmon, Joseph., Divvala, Santosh., et al., You Only Look Once: Unified, Real-Time Object Detection, 2016

[5] Redmon, Joseph., Farhadi, Ali., YOLO9000: Better, Faster, Stronger, 2018

[6] Strickland, Mark., Fainekos, Georgios., et al., Deep Predictive Models for Collision Risk Assessment in Autonomous Driving, 2017

[7] Suzuki, T., et al, Drive Video Analysis for the Detection of Traffic Near-Miss Incidents, 2018

[8] Cheung, Ernest., Bera, Aniket., et al., Efficient and Safe Vehicle Navigation Based on Driver Behavior Classification, CVPR, 2018

[9] Rohmer, Eric., Singh, Surya P. N., et al., V-REP: a Versatile and Scalable Robot Simulation Framework, 2013

# 訓練済み深層生成モデルの潜在変数間相互条件付きサンプリングに よるマルチモーダル双方向生成モデル

Bi-directional multimodal generation via estimating conditional distribution of latent variables obtained from pre-trained generative models

| 今給黎 成彬            | 大知 正直        | 森 純一郎          | 坂田 一郎         |
|-------------------|--------------|----------------|---------------|
| Shigeaki Imakiire | Masanao Ochi | Junichiro Mori | Ichiro Sakata |

東京大学大学院工学系研究科技術経営戦略学専攻

University of Tokyo School of Engineering Department of Technology Management for Innovation

In recent years, research on multimodal generation that mutually converts between different data such as images and sentences has attracted attention from the viewpoint of applicability to real service such as automatic annotation of images and subtitles of audio.

Meanwhile, in the field of machine learning research, reusable trained models trained using large-scale data sets are being opened to the public, and the number is expected to increase in the future.

Therefore, in this research, we aim to realize multimodal generation with small data by utilizing this trained model. In this paper, we propose a multimodal generation method using a trained generation model in which latent variables of individual modality can be inferred and a small amount of data set. We realized multimodal generation by estimating the conditional distribution of latent variables obtained from trained models using small number of train data.

# 1. はじめに

近年,画像や文章などの異なるデータ間を相互に変換するマ ルチモーダル生成の研究が実サービスへの応用可能性の観点か ら注目されている.マルチモーダル生成は,画像の自動注釈, 音声の字幕生成,など最近でも大きな成果を得ており産業応用 上重要な技術である一方で,大規模なデータセットが必要であ るという課題がある.

一方で,機械学習研究分野は,大規模なデータセットを用い て訓練した再利用可能な訓練済みモデルを一般に公開するよう になってきており,その数は今後増加すると見込まれる.

そこで本研究では、この訓練済みモデルを活用することで、 小規模なデータでマルチモーダル生成を実現することを目的と する.本稿では、個別モダリティの潜在変数が推論可能な訓練 済み生成モデルと少量のデータセットによってマルチモーダル 生成を行う手法を提案する.

本稿では画像とラベルからなるマルチモーダルデータに提 案手法を適用する実験を行い、与えられた訓練済み生成モデル が十分訓練されていれば提案手法によって少数の訓練データで それらのモデルと同等程度の精度でマルチモーダル双方向生成 が可能なことを示した.

#### 2. 関連研究

#### 2.1 前提となる代表的な深層生成モデル

Kingma らによる Variational Autoencoders[1](以下, VAE) は代表的な深層生成モデルである. VAE は入力デー タから潜在変数を推論する Encoder と潜在変数から入力デー タを復原する Decoder という 2 つのニューラルネットワーク を組み合わせた深層生成モデルである. VAE の対象とするデー タ構造は画像だけでなく,テキスト [2] や音声 [3] などに対す るモデルも派生的に提案されている.

Genereative Adversarial Networks[4](以下, GAN)は,潜 在変数からデータを生成する Generator とその生成データの真 偽を判定する Discriminator を互いに学習させることで,現実

連絡先: 今給黎 成彬 imakiire@utac.u-tokyo.ac.jp

のデータに近いデータ生成を可能にする深層生成モデルである. Goodfellow らが提案した元の GAN には入力データから潜在 変数の分布を推論する過程は備わっていないが, Dumoulin ら による ALI[5] などそれを可能にするモデルが提案されている.

#### 2.2 単方向のマルチモーダル生成モデル

単方向のマルチモーダル生成モデルが扱う問題は画像から テキストの生成 [6],テキストから画像の生成 [7],テキストか ら音声の生成 [8] など多岐に渡っている.単方向のマルチモー ダル生成の主要なアプローチは、一方のモダリティのデータの 特徴を抽出する Encoder と抽出された特徴を入力として対応 モダリティを出力する Decoder を構築するという方法である. 特徴抽出とそのデコードをいかに行うかが重要であるため、モ デルが複雑化し、一般的には大規模なデータセットが必要と なる.

#### 2.3 双方向のマルチモーダル生成モデル

双方向のマルチモーダル生成モデルは単方向のマルチモー ダル生成モデルよりも学習のコストが低いという点で優れてい る.双方向マルチモーダル生成モデルの主なアプローチは異な るモダリティの共有表現を獲得する方法である.共有表現の獲 得の方法としては Deep Boltzman Machine を用いるモデル [9] や AutoEncoders を用いるモデル [10], VAE を用いるモデ ル [11] などが存在する.

#### 2.4 本研究の位置づけ

本研究ではマルチモーダルデータについて各モダリティにつ いて潜在変数の推論が可能な生成モデルの訓練済みモデルが 与えられた時に、それらの潜在変数の相互の条件付きサンプリ ングを通じてマルチモーダル双方向生成を行うモデルを提案 する.

# 3. 提案手法

本節では、各モダリティ毎に潜在変数の推論が可能な訓練済 み生成モデルが所与であるものとし、一方のモダリティの潜在 変数で条件付けた異なるモダリティの潜在変数の分布を推定 し、その推定分布からサンプリングされた潜在変数と所与のモ デルの生成過程によって異なるモダリティデータの生成を行う 手法を提案する.

(x, y) という複数のモダリティを持つデータセット  $D = \{(x_1, y_1), ..., (x_N, y_N)\}$ が存在し、それぞれのモダリティについて潜在変数  $z_x, z_y$ が推論可能な訓練済みの生成モデルが所与であるとする.本研究では、xのみが観測された時に対応するyを獲得する問題とyのみが観測された時に対応するxを獲得する問題の2つの問題を考える.本稿では、この問題に 潜在変数  $z_x, z_y$ の相互の条件付き分布のモデリングするというアプローチを提案する.

#### 3.1 訓練済み生成モデルの潜在変数間の条件付き分布 推定によるマルチモーダル生成

 $x \ge y$ は対称性があるため、まずはxを観測した下でyを 獲得する問題を考える.

yの生成過程を考慮すれば, xが与えられた下での $z_y$ の分 布 $p(z_y|x)$ を考えればよいが, xは低次元の $z_x$ により生成さ れたものであるため $z_x$ を $z_y$ に対応付ける方が複雑さが小さ い.したがって $z_x$ が与えられた下での $z_y$ の分布 $p(z_y|z_x)$ を 考える.すると,以下の手順でモダリティxのあるデータ $x_i$ が観測された時に以下の手順で対応する $y_i$ を生成できる.

- 1. 観測した  $x_i$  で条件付けた  $z_x$  の分布  $p(z_x|x_i)$  から  $z_{x_i}$  を サンプリングする
- 2. サンプリングした  $z_{x_i}$  で条件付けた  $p(z_y|z_{x_i})$  から  $z_{y_i}$  を サンプリングする
- 3. サンプリングした  $z_{y_i}$  で条件付けた  $p(y|z_{y_i})$  から  $y_i$  をサ ンプリングする

 $p(z_x|x)$  は潜在変数  $z_x$  の推論過程,  $p(y|z_y)$  は y の生成過程 であり、それぞれ所与の訓練済みモデルで十分よく近似され ているとする.よって本稿で取り扱うのは  $p(z_y|z_x)$  の推定で ある.

より具体的に  $p(z_y|z_x)$  をモデル化する方法として,  $q_{\psi_x}(z_y|z_x)$  を真の  $p(z_y|z_x)$  の近似分布として,  $z_x$  を入力と して q の分布パラメータを出力する関数  $h_{\psi_x}$  を考える. ただ し, q は所与のモデルにて  $z_y$  の事後分布に仮定されている分 布と同一形状の分布とする. すなわち,例えば  $p(z_y|y)$  に多変 量正規分布が仮定されているならば,  $q_{\psi_x}(z_y|z_x)$  も多変量正 規分布を仮定する. ここで,その分布パラメータを  $\gamma_y$  とする と  $q_{\psi_x}(z_y|z_x)$  は以下のように書き表すことができる.

$$q_{\psi}(z_y|z_x) = Dist_y(z_y|\gamma_y = h_{\psi_x}(z_x;\psi_x)) \tag{1}$$

hのパラメータ  $\psi_x$ を最適化すれば所与の訓練済みモデルと 組み合わせて xを観測した下で対応する yの生成が可能にな る. 同様に yを観測した下で対応する xを獲得したい場合は,  $z_y$ を入力として  $z_x$ が従う分布のパラメータを出力する関数  $h_{\psi_y}$ を考える.

## 3.2 最適化問題

まずは  $h_{\psi_x}$  の最適化を考える.  $(x_i, y_i)$  というペアのデータ のうち  $x_i$  のみが観測された場合に,関数  $h_{\psi_x}$  がどのような性 質を満たせば  $y_i$  を生成できるかを考える. 3.1 節で記した通り,  $y_i$  を生成するならば,分布  $p(z_y|y_i)$  からサンプリングされた潜 在変数  $z_{y_i}$  が必要である.よって, $x_i$  によって  $z_{x_i}$  が推論され た下で  $z_{y_i}$  を獲得するためには, $q_{\psi_x}(z_y|z_{x_i}) \geq p(z_y|y_i)$  を一 致させればよい.すなわち, $h_{\psi_x}$  は  $z_{x_i}$  を入力として  $p(z_y|y_i)$ に近い分布のパラメータを出力する関数であればよい. D[p||q]を確率分布  $p \ge q$  の間に定義され,分布間の距離を 評価できるダイバージェンス関数とすると,パラメータ  $\psi_x$  は そのダイバージェンス関数を最小化するような値であればい い.これは以下の式を満たすことと等しい.

$$\min_{\psi_x} D[q_{\psi_x}(z_y|z_{x_i})||p(z_y|y_i)]$$
(2)  
$$tz tz U, \ z_{x_i} \sim p(z_x|x_i)$$

 $D[q_{\psi_x}(z_y|z_{x_i})||p(z_y|y_i)]$ は $x_i, y_i, \psi_x$ の関数として表せるた めこれを $L_i(\psi_x, x_i, y_i)$ とする.ここで,目的は特定の $x_i$ だけ でなく,データセット { $(x_1, y_1), ..., (x_N, y_N)$ }の各点において  $\psi_x$ が式2を満たすことである.よって, $L_i(\psi_x, x_i, y_i)$ の期待 値の最小化を考える.

$$\min_{\psi_x} \mathbb{E}_{(x_i, y_i) \sim p_{data}} \left[ L_i(\psi_x, x_i, y_i) \right]$$
(3)

式 3 の期待値は  $X = \{x_1, x_2, ..., x_N\}, Y = \{y_1, y_2, ..., y_N\}, \psi_x$  の関数として表されるためこれを  $L(\psi_x; X, Y)$ とする. Nが十分に大きいとLの計算はメモリ 効率上困難となるため, バッチ学習を提案する. すなわち, データセット  $\{(x_1, y_1), ..., (x_N, y_N)\}$ からランダムな M 個 のサンプル  $X^M, Y^M$ を抽出し,以下の関数  $L^M$  で L を近似 する.

$$L(\psi_x, X, Y) \simeq L^M(\psi_x, X^M, Y^M)$$
  
=  $\frac{N}{M} \sum_{i=1}^M L_i(\psi_x, x_i, y_i)$  (4)

ダイバージェンス関数やモデルパラメータの最適化には様々 な選択が考えられるが、本稿においてはダイバージェンス関数 には KL ダイバージェンスを選択し、モデルパラメータの最適 化には勾配降下法を用いる.

#### 4. 実験の概要

本実験では,第3.節のモデルを画像とラベルからなるデー タセットに適用してそれらの相互生成を行った.本実験の目的 は提案手法の有効性を検証するために以下の3点を確認する ことである.

- 提案手法によって異なるモダリティの潜在変数間の条件 付き分布が正しく推定され,所与の訓練済み生成モデル と組み合わせてマルチモーダル双方向生成が可能となる こと
- 2. 提案手法においてモデルパラメータの最適化が少数のデー タセットでも可能であること
- 3. 双方向の生成が与えられた訓練済み生成モデルと同程度 の精度で行われること

#### 4.1 データセット

使用したデータは MNIST データセットである. MNIST は 70,000 件の手書き数字画像データとその画像に書かれた数字 を表すラベルデータからなるデータセットである本実験では 全データセットのうち 60,000 件を各モダリティの生成モデル の訓練に利用し, N 件を提案モデルの訓練に利用し,残りの (10,000 – N) 件を評価で利用した.

#### 4.2 訓練済み生成モデル

本実験では事前に各モダリティの VAE の訓練を行い,その 後に各モダリティの潜在変数間の条件付き分布の推定を行う提 案モデルを訓練した.

どちらのモダリティについても潜在変数の分布は正規分布 とし,潜在変数の次元は画像は 64 次元, ラベルは 2 次元とし た. どちらのモデルも十分に学習させた.

#### 4.3 提案モデルの訓練詳細

提案モデルに用いた構造は、2層の BatchNormalization 及 び LeakyReLU 活性化関数付きの線形全結合層と潜在変数の 事後分布パラメータを出力する全結合層からなる多層パーセプ トロンである.隠れ層の出力ユニット数は順に 64, 128 とし、 最終層の出力ユニット数はターゲットのモダリティの潜在変数 の次元数とした.また、LeakyReLU 関数の negative slope は 0.2 とした

モデルのパラメータ最適化に必要なデータ数を確認するために訓練データ数  $N = \{256, 1024, 8192\}$ で訓練を行った.

#### 5. 結果と考察

#### 5.1 学習の進展

図1は提案モデルを訓練中の目的関数の値の推移である.



図 1: 目的関数の値の推移

目的関数の値は学習が進むにつれて減少していることから異 なるモダリティの潜在変数間の条件付き分布が推定されている ことが分かる.また,学習の速度と最終的な収束値は訓練デー タ数によって変わっていないことから訓練データ数の増減が提 案モデルの学習に及ぼす影響は小さいと考えられる.

### 5.2 ラベルデータから画像データの生成

0~9のラベルデータから画像データを生成した結果と訓練 済み画像 VAE による生成をまとめたものが図 2 である.



図 2: ラベルから生成した画像と訓練済み画像 VAE によって 生成した画像 どの訓練データ数においても入力ラベルに合致した画像が 生成され,生成された画像の質も訓練済み VAE によるものと 同等精度であることが分かる.

次に,画像データ x の対数尤度 logp(x) の推定値による生 成精度の定量評価を行う.本実験の目的は提案手法によるデー タの生成が所与の訓練済みモデルと同程度であることの確認で あるため,対数尤度の比較は所与の訓練済みモデルによる生成 と提案手法の生成の間で行う.表1はその結果である.

表 1: 提案手法と訓練済み画像 VAE による対数尤度の比較

| モデル        | logp(x) |
|------------|---------|
| N = 256    | -351.52 |
| N = 1024   | -354.59 |
| N = 8192   | -355.56 |
| 訓練済み画像 VAE | -89.99  |

どの訓練データ数においても提案手法は元の訓練済みモデ ルよりも低い対数尤度となった一方で,訓練データ数による大 きな差は見られない.

#### 5.3 画像データからラベルデータの生成

潜在変数の分布が正しく推定されているかを検証するため に,画像データの潜在変数からラベルデータの潜在変数を二 次元平面上に可視化した結果を確認する.図3はその結果で ある.



図 3: 画像から推定したラベルの潜在変数と訓練済みラベル VAE で推定した潜在変数のプロット

どのデータ数においても訓練済み VAE と同様のプロットとなっていることが分かる.

次に, ラベルデータ y の対数尤度 logp(y) の推定値による 生成精度の定量評価を行う. 結果は表 2 である. 対数尤度には 推定値を用いているため, 値の大小関係が変動しうることに注 意されたい.

表 2: 提案手法と訓練済みラベル VAE による対数尤度の比較

| モデル         | logp(y) |
|-------------|---------|
| N = 256     | -0.0456 |
| N = 1024    | -0.0456 |
| N = 8192    | -0.0457 |
| 訓練済みラベル VAE | -0.0456 |

訓練データ数間での差はなく,かつ訓練済みモデルと同等精 度であることが分かる.

#### 5.4 所与の訓練済みモデルの学習が不十分な場合

双方向生成が所与の訓練済みモデルと同等精度で行われる ことを確認するために、画像データの VAE に 3 エポックの みしか訓練していない学習途中の重みを使って提案手法を学 習した.目的は双方向生成が所与の訓練済みモデルと同等精 度で行われるかの確認なので、訓練データ数の比較は行わず N = 1024のみで実験を行った.

図4はラベルデータから画像データを生成した結果である. ラベルと対応した画像が生成されているが.生成の質は画像 VAEよりもわずかに劣っている.



図 4: 学習途中の画像 VAE を用いた場合の生成結果

図5は画像データからラベルデータの潜在変数を推定した 結果である.十分に訓練した場合である図3と比較すると異 なるラベルの潜在変数が重なりあっていることが分かる.



図 5: 提案手法によって推定した潜在変数のプロット

#### 5.5 考察

以上の実験結果に対する考察を行う. 5.2 節においてラベル データから対応する画像データが生成されたこと, 5.3 節にお いて多くの画像から対応するラベルデータが正しく生成され たこと, 5.3 節において提案手法によって画像データから推定 したラベルデータの潜在変数が訓練済みラベル VAE によって 推定した潜在変数と同様の分布をしたこと, これら三点によっ て提案手法によってモダリティの潜在変数間の条件付き分布 の推定を介してマルチモーダル生成が可能になったことが分 かった.

5.1 節における学習の進展速度と目的関数の収束値にデータ 数による違いがないこと, 5.2 節と 5.3 節における定性及び定 量評価にデータ数による差が見られなかったこと, これらに よって提案手法は少数の訓練データで学習が可能なことが分 かった.

5.2 節において提案手法によってラベルから生成した画像が 質の面で訓練済み画像 VAE による生成画像と同等程度であっ たこと,5.3 節において提案手法の尤度評価が訓練済み VAE と同等程度なこと,5.4 節において与えられたモデルが未学習 ならば生成の質が落ちること,これら三点からは所与の訓練済 み生成モデルの潜在変数の推論過程が十分パラメータ化されて いれば提案手法による生成は与えられたモデルによる生成と同 等程度の精度で行われることが分かった.

#### 6. 結論

様々なモダリティについて個別に高精度な生成モデルが提案 され、かつ訓練済みモデルの公開が一般的となりつつある現状 に着目して、訓練済み生成モデルと小規模なデータセットを組 み合わせることで十分に高精度なマルチモーダル双方向生成を 達成することが本研究の目的であった.

まず複数モダリティについてそれぞれ訓練済みの生成モデル を所与として、その潜在変数間の相互の条件付き分布を推定し その分布からのサンプリングによって得られた潜在変数と所与 のモデルの生成過程を用いることによってマルチモーダル生成 を行うモデルを提案した。そして、特に所与の訓練済み生成モ デルが Variational Autoencoders である場合に、潜在変数間 の相互の条件付き分布を多層パーセプトロンによって推定する ことでたしかにマルチモーダル生成が可能であることを実験に よって示した。また、従来手法とは異なり潜在変数間の条件付 き分布を推定するのみなので、モデルを簡略化することによっ てパラメータ数を減らし小規模なデータセットによってモデル パラメータの最適化が可能であることを確認した。さらに、所 与の訓練済み生成モデルが十分に訓練されているならばそれと 同等程度の生成が可能なことを確認した。

以上より,本研究はマルチモーダルデータについての訓練済 み生成モデルが得られた一方で対応する訓練データセットは少 数しか得られない場合に十分よく双方向生成を達成する手法を 提案し,その有効性を示した.

#### 参考文献

- Diederik P Kingma and Max Welling. Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114, 2013.
- [2] Zhiting Hu, Zichao Yang, Xiaodan Liang, Ruslan Salakhutdinov, and Eric P Xing. Toward controlled generation of text. arXiv preprint arXiv:1703.00955, 2017.
- [3] Wei-Ning Hsu, et al. Learning latent representations for speech generation and transformation. In *Inter*speech, pp. 1273–1277, 2017.
- [4] Ian J. Goodfellow, et al. Generative adversarial nets. In Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2, NIPS'14, pp. 2672–2680, Cambridge, MA, USA, 2014. MIT Press.
- [5] Vincent Dumoulin, et al. Adversarially learned inference. CoRR, Vol. abs/1606.00704, 2016.
- [6] Quanzeng You, et al. Image captioning with semantic attention. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 4651– 4659, 2016.
- [7] Elman Mansimov, et al. Generating images from captions with attention. In *ICLR*, 2016.
- [8] Aäron van den Oord, et al. Wavenet: A generative model for raw audio. In SSW, 2016.
- [9] Nitish Srivastava, et al. Multimodal learning with deep boltzmann machines. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, Advances in Neural Information Processing Systems 25, pp. 2222– 2230. Curran Associates, Inc., 2012.
- [10] Jiquan Ngiam, et al. Multimodal deep learning. In Proceedings of the 28th International Conference on International Conference on Machine Learning, ICML'11, pp. 689–696, USA, 2011. Omnipress.
- [11] Masahiro Suzuki, et al. Improving bi-directional generation between different modalities with variational autoencoders. arXiv preprint arXiv:1801.08702, 2018.

# 二値化ニューラルネットワークへの 変分情報ボトルネックによる正則化

Binarized Variational Information Bottleneck

| 河野 慎* <sup>1</sup> | 大屋 優 * <sup>2</sup> | 八木 哲志 * <sup>2</sup> | 中澤 仁 *1      |
|--------------------|---------------------|----------------------|--------------|
| Makoto Kawano      | Yu Oya              | Satoshi Yagi         | Jin Nakazawa |
|                    |                     |                      |              |

\*<sup>1</sup>慶應義塾大学大学院政策・メディア研究科 Graduate School of Media and Governance, Keio University \*2NTT ソフトウェアイノベーションセンタ NTT Software Innovation Center

Deep neural networks are utilized in various applications in real worlds, thanks to their capabilities. One of the fashions of it is their deployment on edge devices. With edge devices, deep neural networks can be used in the context of IoT. However, the specification of those edge devices is often poor so that deep neural networks cannot be deployed. Binary neural networks, whose weights and activations are binarized, is one of the solutions. There is a well-known issue, the drastic drop in accuracy compared to its full precision networks. We consider that this is because the binary neural networks can only represent a subset of discrete functions so that they become sensitive to the input perturbation: the lack of robustness for inputs. In this paper, we propose a regularization approach that helps to alleviate the over-fitting problem by introducing variational information bottleneck. We show ablation studies on CIFAR-10 that reduce loss value the though accuracy is maintained on AlexNet-like networks with different binary activation functions.

# 1. はじめに

深層学習は、その性能の高さから様々な分野で応用されてい る.特に画像認識の分野の発展は著しく、大量の GPU/TPU と数千~数億枚の画像を学習に用いることで、近年は画像分 類タスクだけではなく、高品質・高画質な画像生成 [Brock 18] が可能となっている.一方で、道路の損傷点検 [Kawano 17] のように、高性能計算機ではなく RaspberryPi3 や NVIDIA JetsonTX2 などエッジデバイスでの実行を想定した研究が注 目されている.エッジデバイスで深層学習を実行する場合、そ の性能の低さゆえに深層学習モデルを小さくする必要がある.

深層学習モデルを圧縮することで,エッジデバイスのような 低性能計算機でも実行可能にする技術が研究されている.本 研究では,圧縮技術の一つである量子化に注目する.量子化 は,32 ビットの単精度浮動小数点数で表現されている深層学 習モデルのパラメータを 16 ビットや 8 ビットなど低演算精 度で表現するものである.特に,重みパラメータと層間の信 号\*<sup>1</sup>を1ビットで表現された binary neural networks (BNNs) [Courbariaux 16] や XNOR-Net[Rastegari 16] は,メモリを 最大で 1/32 の節約と速度の向上が期待される.さらに,BNNs は FPGA 上での実行において,その優位性が発揮される.

一方で、BNNs には、単精度浮動小数点数で表現された深 層学習モデルと比べて、一段と精度が下がってしまう問題があ る.これは、学習の逆伝播時にパラメータの表現力が不足して いることが主な原因とされている [Lin 17].つまり、重みパラ メータの量子化(二値化)は情報量の欠落による表現力の低下 を引き起こし、重みパラメータ値の急激な変動(+1  $\rightarrow$  -1 や -1  $\rightarrow$  +1)によって、入力の摂動に対する頑健性が失われて おり、過学習しやすくなってしまっている.

過学習を抑制する手法として,重みパラメータへの制約としてL1正則化やL2正則化が挙げられるが,BNNsにおいて重みは+1もしくは-1になっているため,その効果を受けるこ

とができない.そこで本研究では,確率的にニューラルネット ワークを扱う変分情報ボトルネックを BNNs に導入し, BNNs の過学習抑制を試みる.

# 2. 二値化変分情報ボトルネック

# 2.1 二値化ニューラルネットワーク

BNNs は、重みおよび信号を +1 もしくは -1 のいずれかの 値に制約することで、モデルのサイズも小さくなり、また推論 時に論理演算で行うことが可能となる.重みもしくは信号  $x^b$ の二値化は

$$x^{b} = \operatorname{Sign}(x) = \begin{cases} +1 & x \ge 0\\ -1 & \operatorname{otherwise} \end{cases}$$
(1)

である.ただし, xは,実数値を表しており,Sign は符号関数 を表している.BNNsの順伝播時,式(1)によって二値化され た重みパラメータ $W^b$ を用いて計算される.層間の活性化関 数にも符号関数が用いられ,二値の信号が出力される.しかし ながら,符号関数の勾配はほとんど至るところで0であるた め,逆伝播時に勾配が消失してしまい,学習ができない.この 問題を解決するため,BNNsでは,Hintonの講義(2012)で 紹介された straight through estimator (STE):

$$\frac{\partial \operatorname{Sign}}{\partial x} = 1_{|x| \le 1}$$

が用いられることが多い. なお, STE は hard tanh とみなす ことも可能であることが報告されている [Courbariaux 16]. ま た,符号関数を滑らかな関数として近似した SignSwish:

 $SS_{\beta}(x) = 2\sigma(\beta x)[1 + \beta x\{1 - \sigma(\beta x)\}] - 1$ 

関数を用いることで,より学習が安定して行われることが報告 されている [Darabi 18]. なお, σ はシグモイド関数を表す.

STE により BNNs の学習が可能になる一方で,依 然として過学習が起きやすい.この原因として,BNNs

連絡先: 河野 慎, 慶應義塾大学, 神奈川県藤沢市遠藤 5322, makora9143@gmail.com

<sup>\*1</sup> 活性化信号.層から出力され,次の層の入力になるもの.



図 1: 入力にノルム γ の摂動を与えた時の出力の誤差.

は摂動に対して弱い問題が挙げられる.摂動に弱い様 子を図 1 に示す.学習前の 3 種類のモデル (AlexNet, AlexNet+BatchNormalization[Ioffe 15], BNN) に MNIST の同一データにノルム  $\gamma$  の摂動を追加した時の追加前との誤 差を示している. 32 ビット浮動小数点数で表現されている深 層学習モデルに比べ, BNN は摂動の大きさに関係なく誤差が 生じてしまっている.そこで本研究では、この摂動に対してロ バスト性を向上するための正則化項を提案する.正則化項の 技術として、変分情報ボトルネック (variational information bottleneck, VIB)を導入する.

#### 2.2 変分情報ボトルネック

変分情報ボトルネック(VIB)[Alemi 16] は,情報ボトル ネック [Tishby 15] の変分下界を学習する手法である.情報ボ トルネックでは,教師あり学習を表現学習としてみなす.すな わち,入力データ X をラベル Y の予測に利用可能な潜在表現 Z への確率的な写像関数を求める.

二つの確率変数 *Z*, *Y* 間における相互情報量を *I*(*Z*; *Y*) とすると,情報ボトルネックは,次のように表現される:

$$\max I(Z; Y)$$
 subject to  $I(Z; X) \le R.$  (2)

ただし, Rは, ボトルネック(=定数)である, 式(2)を非制 約ラグランジュ最適化問題として書き直すと,

$$\max I(Z;Y) - \eta I(Z;X)$$

となる. 情報ボトルネックは一般的に計算困難で知られている ため, Alemi ら [Alemi 16] は変分法を適用し,

$$\max_{\theta,\phi,\psi} \mathbb{E}_{p(x,y)e_{\theta}(z|x)} \left[ \log q_{\psi}(y|z) - \eta \log \frac{e_{\theta}(z|x)}{m_{\phi}(z)} \right]$$
(3)

とすることで、変分下界を導出している.ただし、qは分類時 の尤度、 $\frac{e}{m}$ は任意の潜在表現空間 m に関連した潜在表現 e の 長さを罰則するレートを表している.また、 $e_{\theta}(z|x)$ は、入力 Xを潜在表現 Z に変換する確率的なエンコーダを表している. さらに、 $q_{\psi}(y|z)$ は、潜在表現 Z からラベル Y を予測する変 分分類器(もしくはデコーダ)であり、 $m_{\phi}(z)$ は、変分近似 分布を示している.変分情報ボトルネックを導入することで、 ニューラルネットワークが敵対的事例 [Goodfellow 15] を含め た摂動に対し、頑健になることが報告されている [Alemi 18].

#### 2.3 BNN への変分情報ボトルネックの導入

本研究では、BNN の最終層手前の層を、変分オートエンコー ダ [Kingma 13] のようにガウス分布  $\mathcal{N}$  の平均  $\mu$  と分散  $\sigma^2$  を

| Activation   | $-\log q_{\phi}(y z)\downarrow$   | Accuracy $\uparrow$   |
|--|---|---|
| BNN(HT)<br>BVIB(HT)  | $\begin{aligned} 1.199 \pm 3.93 \times 10^{-3} \\ 1.186 \pm 9.15 \times \mathbf{10^{-3}} \end{aligned}$ | $\begin{array}{c} 61.592 \pm 0.267 \\ \textbf{61.646} \pm \textbf{0.178} \end{array}$ |
| $\frac{\text{BNN}(\text{SS}_{\beta=5})}{\text{BVIB}(\text{SS}_{\beta=5})}$ | $\begin{array}{c} 1.302\pm5.40\times10^{-3}\\ 1.290\pm10.82\times\mathbf{10^{-3}}\end{array}$           | $\begin{array}{c} {\bf 61.270 \pm 0.410} \\ {\bf 61.134 \pm 0.475} \end{array}$       |

表 1: CIFAR10 の実験結果. 矢印は,高いスコア/低いスコア のどちらが良いのかを示している. 表中の HT は HardTanh, SS は SignSwish を表す.

$$q_{\phi}(y|z) = \mathbb{E}_{z \sim e_{\theta}(z|x)}[\operatorname{softmax}(W_{1}z + b_{1})]$$
$$\log e_{\theta}(z|x) = \log \mathcal{N}(z; \mu, \sigma^{2}I)$$
where  $\mu = W_{2}h + b_{2}$ 
$$\sigma = \operatorname{softplus}(W_{3}h + b_{3})$$
$$h = \operatorname{NN}(x)$$
(4)

ただし,  $I \in \mathbb{R}^{zdim \times zdim}$  は単位行列,  $W_1, b_1$  は, ソフトマッ クス層の全結合層,  $W_2, b_2 \geq W_3, b_3$  はそれぞれ, 平均と分散 を出力する全結合層のパラメータを示し, NN(·) は最終層から 2 層手前までのニューラルネットワークを表す.

### 3. 実験

提案手法の有効性を検証するため、本実験では、CIFAR10を 用いた損失関数の値および精度の比較を行う.まず、CIFAR10 のデータセットに対して本研究では、正規化のみを行った.こ れは、CIFAR10において、左右反転やランダムクロップなど のデータ拡張処理は、精度に非常に大きな影響があることが報 告されているため [Graham 14]、本研究では平均 0、分散 1 へ の正規化のみを行った.

本実験では,深層学習モデルの基本的な構造として AlexNet[Krizhevsky 12]を用いる.ただし,AlexNet の畳み 込み層部を式 (4)の NN とし,全結合層は 3 層ではなく 2 層とし, $\mu,\sigma \in \mathbb{R}^{256}$ とする.さらに BatchNormalizationを畳み込み層の直後に導入する.また活性化関数 (Hard-Tanh/SignSwish) については,Rastegari 6 [Rastegari 16] が 指摘するように Max プーリング層の直前に入れてしまうと出 力される値がほとんど+1 になってしまうことが懸念されるた め,畳み込み層の直前に挿入した.SignSwish のハイパーパ ラメータは, [Darabi 18] で固定値の中で最も精度が高かった  $\beta = 5$ とした.バッチサイズは 128 とし,オプティマイザには Adam[Kingma 14] を採用,学習率を 10<sup>-3</sup>,エポック数を 50 とし,10 エポックごとに 0.1 倍にした.本実験の結果を表 1 に示す.なお,異なるランダムシードを5 種類用い,その平均 と標準偏差を載せた.

## 4. 考察・まとめ

本研究では,BNNs が入力の摂動に対して敏感であるため に過学習が起きてしまう問題に対し,変分情報ボトルネックを 導入することで,正則化を試みた.

表 1 に示す通り,変分情報ボトルネックを入れることで, HardTanh と SignSwish いずれの活性化関数においても,目 的関数であった負の対数尤度は下回っている.精度においては



図 2: 任意の画像を入力した時の出力結果の違い. それぞれ,入力画像,BNN,BVIBの各出力結果となっている.BVIB は変分 情報ボトルネックの性質によりサンプリングが可能であるため,出力は箱ひげ図(サンプリング数 1000)となっている.

HardTanhを用いた場合は上回っている一方で,SignSwishを 用いた場合は下回ってしまった.目的関数と精度が一致してい ない理由として,分類結果の出力の仕方があげられる.一般的 に,分類結果の出力は,最終層のソフトマックス層出力で最も 大きい値を出力している次元のラベルとみなされる.したがっ て,モデルの学習がより上手く行っているとしても,つまり目 的関数がより小さい値になったとしても,最終的に最も大きい 値を出力するラベルが変わらなければ精度は変わらない.

BNN と BVIB 共に不正解であった CIFAR10 データおよ びモデルの出力の一例を図 2 に示す. BVIB の出力は  $y \sim p(y|z)p(z|x)$ であるため、サンプリング数を 1000 とし、結果 には箱ひげ図を用いた.図 2(a) において、入力画像の正解ラ ベルが「馬」なのに対し、BNN の出力は「鹿」が最大となっ ており、またそのほかのラベルの値はほぼ0 になっている.一 方で、BVIB では BNN と同様に「鹿」が最大となっているが、 「馬」のラベルが次に高い値を示しており、依然として不正解 ではあるが、BNN よりも正しく認識できていると言える.ま た、図 2(b) において、入力画像の正解ラベルが「猫」に対し て、BNN と BVIB 共に一番大きい値となったラベルは「犬」 であり、二番目に大きい値となったラベルは「猫」となってい る.しかし、BNN に比べると BVIB の方が「猫」ラベルの値 は大きく、より正しく認識できている.

以上のことから, BNN に変分情報ボトルネックの枠組みを 取り入れることで,正則化され,過学習が抑えられていること が確認できた.一方で,32 ビット浮動小数点数で表現された ニューラルネットワークに比べると依然として精度は低い.過 学習を抑えつつ,精度を高めていくことが今後の課題である.

#### 参考文献

- [Alemi 16] Alemi, A. A., Fischer, I., Dillon, J. V., and Murphy, K.: Deep Variational Information Bottleneck (2016)
- [Alemi 18] Alemi, A. A., Fischer, I., and Dillon, J. V.: Uncertainty in the variational information bottleneck, arXiv preprint arXiv:1807.00906 (2018)
- [Brock 18] Brock, A., Donahue, J., and Simonyan, K.: Large scale gan training for high fidelity natural image synthesis, arXiv preprint arXiv:1809.11096 (2018)
- [Courbariaux 16] Courbariaux, M., Hubara, I., Soudry, D., El-Yaniv, R., and Bengio, Y.: Binarized neural networks: Training deep neural networks with weights and activations constrained to+ 1 or-1, arXiv preprint arXiv:1602.02830 (2016)

- [Darabi 18] Darabi, S., Belbahri, M., Courbariaux, M., and Nia, V. P.: BNN+: Improved binary network training, arXiv preprint arXiv:1812.11800 (2018)
- [Goodfellow 15] Goodfellow, I., Shlens, J., and Szegedy, C.: Explaining and Harnessing Adversarial Examples, in International Conference on Learning Representations (2015)
- [Graham 14] Graham, B.: Spatially-sparse convolutional neural networks, arXiv preprint arXiv:1409.6070 (2014)
- [Ioffe 15] Ioffe, S. and Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift, arXiv preprint arXiv:1502.03167 (2015)
- [Kawano 17] Kawano, M., Mikami, K., Yokoyama, S., Yonezawa, T., and Nakazawa, J.: Road marking blur detection with drive recorder, in *Big Data (Big Data)*, 2017 *IEEE International Conference on*, pp. 4092–4097IEEE (2017)
- [Kingma 13] Kingma, D. P. and Welling, M.: Auto-encoding variational bayes, arXiv preprint arXiv:1312.6114 (2013)
- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980 (2014)
- [Krizhevsky 12] Krizhevsky, A., Sutskever, I., and Hinton, G. E.: Imagenet classification with deep convolutional neural networks, in Advances in neural information processing systems, pp. 1097–1105 (2012)
- [Lin 17] Lin, X., Zhao, C., and Pan, W.: Towards accurate binary convolutional neural network, in Advances in Neural Information Processing Systems, pp. 345–353 (2017)
- [Rastegari 16] Rastegari, M., Ordonez, V., Redmon, J., and Farhadi, A.: Xnor-net: Imagenet classification using binary convolutional neural networks, in *European Confer*ence on Computer Vision, pp. 525–542Springer (2016)
- [Tishby 15] Tishby, N. and Zaslavsky, N.: Deep learning and the information bottleneck principle, in *Informa*tion Theory Workshop (ITW), 2015 IEEE, pp. 1–5IEEE (2015)

# 関連ドメインの予測モデルを活用した半教師付きドメイン適合

Semi-supervised Domain Adaptation using Prediction Models in Associated Domains

十河泰弘 坂井智哉 Yasuhiro Sogawa Tomoya Sakai

NEC データサイエンス研究所 NEC Corporation

Semi-supervised domain adaptation which trains a prediction model so that it adapts to novel domains from a few labeled and relatively large unlabeled observations. In this talk, we consider semi-supervised domain adaptation and propose a model embedding method. Unlike the conventional semi-supervised domain adaptation, our work utilizes prediction models in source domains. Moreover, our method can generate a pseudo label to unlabeled data without any special assumption on data distribution. Through experiments, we confirm the effectiveness of our proposed model embedding approach.

# 1. はじめに

人はわずかな事例を観測するだけで,自身が保有する知識 や過去の経験から次に何が起こるかを予測することができる. このような特性を機械学習の分野において実現するために,近 年ではドメイン適合と呼ばれる手法の研究が盛んに行われてい る [3,5,6]. ドメイン適合は,潤沢なラベル付きサンプルが存 在するドメイン (元ドメイン) から得られた知識をラベル付き サンプルが限られたドメイン (目標ドメイン) に適用すること で少数サンプルからでも精度が高く予測が可能なモデルを学習 することを目的としており,さらにその発展として,目標ド メインでラベル付きサンプルに加えてラベル無しサンプルが存 在する場合に,それを活用する半教師付きドメイン適合と呼ば れる手法が提案されている [4].

本研究では、モデル埋め込みと呼ばれるアプローチに基づ いた半教師付きドメイン適合による予測モデルの学習法を提案 する.従来のドメイン適合が、元ドメインのデータや元ドメイ ンのモデルパラメータが必要なのに対し、提案法は元ドメイン で学習済みのモデルを用い、そのモデルの特性を表すモデル属 性を抽出することでドメイン適合を実現する.また、提案法で ラベル無しサンプルへの近似ラベル付与をデータクラスタ性等 の仮定なしに実現し、半教師付き学習による予測モデル推定を 可能とする.

#### 問題設定

### 2.1 半教師付きドメイン適合

まず,入力となる d 次元の特徴ベクトルを  $\mathbf{x} \in \mathbb{R}^d$  とし,それ に対応する出力を  $\mathbf{y} \in \mathcal{R}$  とする.元ドメインの数を T とし,予 測モデルを構築したい対象ドメインの数を T' と表す.本研究で は目標ドメインの  $t' \in \{T+1, T+2, \ldots, T+T'\}$  に対し,それぞ れ  $N_{t'}$  個のラベル付きサンプル  $\{(\mathbf{x}_i^{(t')}, y_i^{(t')}))|i = 1, \cdots, N_{t'}\}$ が与えられるとする.さらに,これらのラベル付きサンプルに 加え,目標ドメインそれぞれについて, $N'_{t'}$  個のラベル無しサ ンプル  $\{\mathbf{x}_j | j = 1, \cdots, N'\}$  が与えられているとする.一般的 な半教師付きドメイン学習では,T 個の元ドメインで得られ るデータまたはモデルのパラメータを基に,T' 個の目標ドメ

連絡先: 十河 泰弘, NEC, 神奈川県川崎市中原区下沼部 1753, 044-431-7659, y-sogawa@ah.jp.nec.com

インにおける予測モデル  $\{f_{t'}\}_{t'=T+1}^{T+T'}$ を構築することである.

#### 2.2 関連ドメインの予測モデル活用

本研究では、従来のドメイン適合と異なり、元ドメインに おいてデータから入出力関係を学習した T 個の予測モデル  $\{h_t(\mathbf{x})|t=1,\cdots,T\}$ が得られていることを仮定する.ここで T は元ドメインの数を、t は各タスクのインデックスを表し、  $h_t: \mathbb{R}^d \to \mathbb{R}$ である.これらの予測モデルは任意の学習アル ゴリズムによって得られたもので実運用に資するものであり、 ある程度の予測精度が保証されているものとする.

本研究での目的は、元ドメインで構築された任意の予 測モデル { $h_t(\mathbf{x})|t = 1, \cdots, T$ } と目標ドメインのデータ { $(\mathbf{x}_i^{(t')}, y_i^{(t')}))|i = 1, \cdots, N_{t'}$ } および { $\mathbf{x}_j | j = 1, \cdots, N'$ } を 用いて、目標ドメインにおける予測モデル { $f_{t'}$ } $_{t'=T+1}^{T+T'}$ を構築 することである.

## 3. 提案手法

本節では、学習済みモデルを活用した半教師付きドメイン 学習を実現するための、モデル埋め込み法を提案する.

#### 3.1 モデル属性とモデル間共通入力表現の獲得

本研究において鍵となるアイディアは、各ドメインでの学 習済みモデルの性質を表すモデル属性とそれらに対応するサ ンプルの変換,モデル間共通入力表現を獲得した上で、目標ド メインにおける予測モデルを構築することである.すなわち, 各学習済みモデルを

$$g(\mathbf{z}_i, \mathbf{a}_t) \approx h_t(\mathbf{x}_i)$$

という形で近似することを考える.ここで,g:  $\mathbb{R}^p \times \mathbb{R}^p \to \mathbb{R}$ ,  $\mathbf{z}_i \in \mathbb{R}^p$ は, $\mathbf{x}_i$ に対応する p次元の共通入力表現であり, $\mathbf{a}_t \in \mathbb{R}^p$ はモデル  $h_t$ の特性を表す p次元のモデル属性ベクトルである.各ドメインに起因した特性は、モデル属性によって表現され、共通入力表現は、モデル属性と合わせて予測を実現するのに用いられる.つまり、ドメイン間で共通した情報は、この共通入力表現が保持する.

まずモデル属性と共通入力表現を推定するために, ラベル 付きサンプルとラベル無しサンプルを用いて g と h の近似誤 差を

$$L(\mathbf{Z}, \mathcal{Z}', \mathbf{A}) := L_{\mathrm{U}}(\mathbf{Z}, \mathbf{A}) + \sum_{t'=T+1}^{T+T'} L_{\mathrm{L}}^{(t')}(\mathcal{Z}', \mathbf{A})$$

と定義する. ここで,

$$L_{\rm U}(\mathbf{Z}, \mathbf{A}) = \sum_{j=1}^{N'} \sum_{t=1}^{T} \ell(h_t(\mathbf{x}_j), g(\mathbf{z}_j, \mathbf{a}_t)),$$
$$L_{\rm L}^{(t')}(\mathcal{Z}', \mathbf{A}) = \sum_{i=1}^{N_{t'}} \sum_{t=1}^{T} \ell(h_t(\mathbf{x}_i^{(t')}), g(\mathbf{z}_i^{(t')}, \mathbf{a}_t))$$

であり,  $\ell$ :  $\mathbb{R} \times \mathbb{R} \to \mathbb{R}_{\geq 0}$  は $\ell_{\mathbf{S}}(s,t) = (s-t)^2$ のような任意の損 失関数を表し,  $\mathbf{Z} := (\mathbf{z}_1, \dots, \mathbf{z}_{N'})$ ,  $\mathcal{Z}' := (\mathbf{Z}_{T+1}, \dots, \mathbf{Z}_{T+T'})$ ,  $\mathbf{Z}_t := (\mathbf{z}_1, \dots, \mathbf{z}_{N_{t'}})$ ,  $\mathbf{A} := (\mathbf{a}_1, \dots, \mathbf{a}_T)$ . このモデル近似誤 差を  $\mathbf{z} \ge \mathbf{a}$  について最小化することで,モデル属性と共通入 力表現を推定することができる.また,目標ドメイン t' のモ デル属性については,それぞれ上記で得られた共通入力表現を 用いて

$$\widehat{\mathbf{a}}_{t'} = \arg\min_{\mathbf{a}_{t'}} \sum_{i=1}^{N_{t'}} \left( y_i^{(t')} - g(\widehat{\mathbf{z}}_i^{(t')}, \mathbf{a}_{t'}) \right)^2$$

として求めることができる.

上記の具体例として, gを下記のモデル属性と共通入力表現の内積で表すことを考える. すなわち,

$$g(\mathbf{z}, \mathbf{a}) = \mathbf{z}^{\top} \mathbf{a} \tag{1}$$

としたとき,前述のモデル属性及び共通入力表現は,辞書学 習[7]と同様にして推定することができる.

#### 3.2 モデル属性を用いた半教師付きドメイン適合

本節で,推定したモデル属性と共通入力表現を用いた半教 師付きドメイン適合による目標ドメインの予測モデル $f_{t'}$ の推 定法について述べる. ラベル付きサンプルのみから学習する場 合,目標ドメインの予測モデル $f_{t'}$ は、 $f_{t'}$ のモデルパラメー タについて下記の経験損失を最小化することで得られる.

$$R_{\rm L}^{(t')}(f_{t'}) := \sum_{i=1}^{N_{t'}} \ell(y_i^{(t')}, f_{t'}(\mathbf{x}_i^{(t')}))$$

しかしながら、ドメイン適合の問題設定においてはラベル付き サンプルの数が限定されており、正確な予測モデルの学習が難 しい.そこで、ラベル無しサンプルの活用を考える.一般的な 半教師付き学習 [2] ではラベルなしサンプルへのラベル付与に データのクラスタ構造等の仮定を導入する必要があるが、本研 究では前節で推定したモデル属性を用いてラベル無しサンプル に対し疑似的なラベルを付与することが可能である.結果とし て、下記の経験損失を最小化することで、目標ドメイン t'の 予測モデルを推定することができる.

$$R^{(t')}(f_{t'}) := (1 - \gamma) R_{\mathrm{L}}^{(t')}(f_{t'}) + \gamma R_{\mathrm{U}}(f_{t'}).$$

ここで,

$$R_{\mathrm{U}}(f_{t'}) := \sum_{j=1}^{N'} \left( g(\widehat{\mathbf{z}}_j, \widehat{\mathbf{a}}_{t'}) - f_{t'}(\mathbf{x}_j) \right)^2$$

であり、 $g(\hat{\mathbf{z}}_{j}, \hat{\mathbf{a}}_{t'})$ がラベル無しサンプルに対する疑似ラベル である.また、 $\gamma$ はラベルありサンプルとラベル無しサンプル のトレードオフパラメータである.

表 1:100 回試行の平均予測誤差(二乗誤差). ここで Linear はタスク数 T に依存しないため,各 T に対し共通の値である.

|      | 提案法   | Stack | Linear |
|------|-------|-------|--------|
| T=10 | 18.57 | 19.54 |        |
| T=20 | 17.50 | 19.67 | 19.33  |
| T=40 | 17.45 | 21.43 |        |

# 4. 評価実験

マルチタスク学習 [1] の評価に倣って人工データを生成し, 提案手法の評価を行った.本実験では各ドメインのデータ生 成に用いる線形モデルの 10 次元重みベクトルを  $N(\mathbf{0}_{10}, \Sigma)$ ,  $\Sigma := Diag\{1, 0.25, 0.1, 0.5, 2.0, 1, 0.25, 0.1, 0.5, 2.0\}$  の 10 次 元正規分布から, 15 次元の入力特徴ベクトルを U(-2.5, 2.5)の一様分布からランダムに生成した. 15 次元の入力特徴ベク トルのうち,ドメイン間で共通の 10 次元が重みベクトルと 結びついて出力を与える.比較手法には,リッジ回帰 (Linear) 及びスタッキング (Stack)を用意した.スタッキングのモデル は,minw  $\sum_{i=1}^{N_{t}} (y_i - \sum_{t=1}^{T} w_t h_t(\mathbf{x}_i))^2$ を解くことで得られる,  $\sum_{t=1}^{T} w_t h_t(\mathbf{x}_i)$  である.本実験において提案法のパラメータ はそれぞれ p = 5,  $\gamma = 0.1$  とし,モデルの近似に (1)を用い た.また,提案法のモデルおよび元ドメインのモデルにはリッ ジ回帰モデルを用いた.最終的に 6 個のラベル付きサンプル, 200 個のラベル無しサンプルを用いて,学習を行った.

表1に1000個のテストサンプルに対する各手法の予測誤差 を示す. Linear に比べ,提案法がより高精度な予測モデルを学 習できていることや,タスク数増加に伴って提案法の精度が改 善することがわかる.これらは複数の元ドメインからうまくモ デル属性と共通入力表現を獲得して,目標ドメインの学習を行 えているためと考えられる.

# 5. おわりに

本研究では、学習済みモデルを用いたドメイン適合法の提 案を行った.提案法により、元ドメインのモデルからモデル属 性を抽出することで、半教師付きドメイン適合が可能となり、 この有用性を人工データ実験よって確認した.

#### 参考文献

- Andreas Argyriou, Theodoros Evgeniou, and Massimiliano Pontil. Convex multi-task feature learning. *Machine Learning*, Vol. 73, No. 3, pp. 243–272, 2008.
- [2] Olivier Chapelle, Bernhard Schölkopf, and Alexander Zien. Semi-Supervised Learning. The MIT Press, 2006.
- [3] Hal Daume III. Frustratingly easy domain adaptation. In Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics, pp. 256–263, 2007.
- [4] Hal Daumé III, Abhishek Kumar, and Avishek Saha. Frustratingly easy semi-supervised domain adaptation. In *Proceedings of the 2010 Workshop* on Domain Adaptation for Natural Language Processing, pp. 53–59. Association for Computational Linguistics, 2010.
- [5] Chelsea Finn, Pieter Abbeel, and Sergey Levine. Model-agnostic metalearning for fast adaptation of deep networks. In *International Conference* on Machine Learning, pp. 1126–1135, 2017.
- [6] Raghuraman Gopalan, Ruonan Li, and Rama Chellappa. Domain adaptation for object recognition: An unsupervised approach. In *Computer Vi*sion (ICCV), 2011 IEEE International Conference on, pp. 999–1006. IEEE, 2011.
- [7] Julien Mairal, Francis Bach, and Jean Ponce. Task-driven dictionary learning. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 34, No. 4, pp. 791–804, 2012.

# 隠れ状態を持つ多腕バンディット問題における方策の検討 A study on measures in multi-armed bandit problem with hidden state

工藤亘平<sup>\*1</sup> Kouhei Kudo 竹川高志<sup>\*1</sup> Takasi Takekawa

\*1 工学院大学情報学部 Faculty of Informatics Kogakuin University

Abstract: The Bandit problem is a matter of maximizing the current reward by selecting one out of the options and acquiring the reward, while limiting it to one state. Reinforcement learning is a problem of maximizing rewards earned in the future by performing various actions from options, in the presence of multiple states. The difference between the two is that state information is known, and multiple states are taken into account. In this simulation, we consider a model in which the current state and state transition information is unknown, maintaining one state for a certain period of time and then transitioning to another state. Regarding this model, we compare the general Bandit problem policy and reinforcement learning policy by cumulative reward. As a result, the cumulative reward was higher for the reinforcement learning policy than for the Bandit problem policy.

# 1. はじめに

近年はインターネットの普及によってインターネットショッピン グやニュースの利用や、インターネット広告を目にする機会が増 えている.総務省の調べによるインターネットショッピングの個人 利用率は全年代平均で約7割を超える結果[1]となっていること から、老若男女に関係なく多くの人が利用していることがわかる. このため企業側も利益を最大化する目的で個人ごとの購買意 欲などを高めるためにパーソナライズを行っている.パーソナラ イズは、ユーザーが過去に選択したコンテンツの利用履歴や年 齢や性別などの個人情報に合わせてシステムが推薦するコン テンツを最適化する手法である.

パーソナライズに用いる手法としてバンディット問題があり、バ ンディット問題によるニュースのパーソナライズ化 [2]による個人 の趣味嗜好にあったニュースの推薦などバンディット問題を活 用したパーソナライズ化の方法が多く考えられている. バンディ ット問題は探索と知識利用のトレードオフを解決する問題であり、 1 つの状態に限定した中で、選択肢の集合から 1 つを選びその 選択肢から報酬を獲得してその報酬から次の選択を決定するこ とで、現在獲得できる報酬を最大化する問題である. 一般的に バンディット問題では選択肢をアーム、アームを選択する戦略を 方策と呼ぶ[3].

またバンディット問題に似た問題設定を持つ手法として強化 学習がある.強化学習は複数の状態が存在し全ての状態を知っている中で,選択肢の集合から様々な試行を繰り返していくこ とで,未来で獲得する報酬を最大化する問題である.バンディッ ト問題と強化学習の違いは,状態の情報が既知で複数の状態 を考慮しているかである.

バンディット問題でパーソナライズを行う場合はユーザー情報 や過去の評価などによってコンテンツを推薦する.しかし人は気 分や状況など状態の変化によって異なる行動を起こすため,同 様のコンテンツを推薦していても良い評価を得られない場合が ある.本論文ではこのような人の行動を現在の状態や状態遷移 の情報が未知の設定で,一定時間は1つの状態を維持して, その後他の状態に遷移する対人行動モデルとして考える.この モデルに対してバンディット問題の方策と強化学習の方策を用いてシミュレーションを行い、一般的なバンディット問題の設定と比較をした.

# 2. シミュレーション設定

# 2.1 モデル作成

人の感情や状況で行動が変化する性質を各状態で高い確率のアームが異なる設定で、毎回各状態の推移確率によって状態遷移を繰り返すが一定の時間は1つの状態を維持しその後他の状態に遷移することでアームの確率が変化するモデルとして作成する.本モデルは現在いる状態や状態数などの情報については方策側に提示せずに獲得した報酬によって方策に状態を推定させる.そして遷移確率は「初期状態」「確率分配」「状態遷移」の3つの状況がある.

「初期状態」は複数の状態が存在する中でいずれか1つの 状態の推移確率が100%となる状況である.「確率分配」が起こ るまでの一定時間はこの状況が続く.

「確率分配」は一定時間経過後に毎回獲得する報酬の結果 によって各状態の推移確率を増減させる状況である.この状況 は「状態遷移」が起こるまで続く.

「状態遷移」は増減した推移確率で他の状態へ遷移した場合の行動である. 遷移した状態の推移確率を 100%, 他の状態の 推移確率を 0%にして「初期状態」を行う.

## 2.2 方策

今回のシミュレーションで用いる方策のバンディット問題の  $\varepsilon$  - グリーディ法, UCB 方策, Thompson Sampling と強化学習の Q 学習と Q-Network について説明する.

ε-グリーディ法は、パラメータεによって定められた回数で最 適なアームを探索し、残りの回数で探索された最適なアームを 選択する.

UCB 方策は,毎回各アームで報酬の平均とアームの選択回数を用いた補正項を合わせた UCB スコアを計算して,そのスコアが最も高いアームを選択する[4].

Thompson Sampling は、各アームの報酬の当たりとはずれの 回数によって事後分布を作成し、その分布より生成される乱数 が最大となるアームを選択する[5].

連絡先:竹川高志,工学院大学情報学部,163-8677 東京都 新 宿 区 西 新 宿 1-24-2 , 033340-0103 , takekawa@cc.kogakuin.ac.jp

Q 学習は各アームに行動価値関数 Q 値を設定して獲得した 報酬で Q 値を最適化していく方法である. 各 Q 値とソフトマック ス関数を用いて確率的にアームを選択する.

Q-Network は、Q 学習とニューラルネットワークを合わせた学 習法である. ニューラルネットワークでは行動の履歴と報酬を入 力とし、各アームの報酬の期待値を出力として Q 値を教師デー タとして学習を行う方策である. またアームの選択はソフトマック ス関数を用いて確率的に選択する.

#### 2.3 設定

本シミュレーション用いるバンディット問題の設定としてアーム に用いる分布をベルヌーイ分布,報酬は当たりで1,はずれで0 とする.また1回の試行回数を10000回,1つの方策で試行を 繰り返す回数 500回とする.アーム数を3本とし、各アームの当 たりの確率は、(0.2,0.2,0.75)と設定する.このときの試行回数 10000回での最大累積報酬は7500となる.モデルに用いる設 定として状態数は3として各状態で高い確率のアームが異なる 設定を持ち、1つの状態を維持する時間を100~1000回の範 囲で乱数を用いてランダムに設定する.方策のパラメータは $\varepsilon$ -グリーディ法の $\varepsilon$ を0.2,Q学習の割引率 $\gamma$ を0.1,温度 $\beta$ を 10.0,Q-Networkの履歴数を1,学習率 $\alpha$ を0.8,温度 $\beta$ を100.0, 割引率 $\gamma$ を0.8とする.

# 3. シミュレーション結果

#### 3.1 各方策の累積報酬

図1は UCB 方策の各アームの UCB スコアとQ 学習の各ア ームのQ値とモデルの状態推移である.これよりバンディット問題と強化学習の方策でスコアの減少に差があることがわかる.図 2は今回の方策に一般的なバンディット問題の設定とモデルを 用いた場合での累積報酬の結果である.結果,左の一般的な場 合には Thompson Samplingと UCB 方策が約 7500 と最も報酬 を獲得し,Q学習とQ-Network が約 7400 と報酬を獲得した.右 のモデルを適用した場合にはQ学習とQ-Network が約 7200 と最も報酬を獲得し,UCB 方策が約 7000 と報酬を獲得した.





# 3.2 状態遷移回数の増加による累積報酬

今回のモデルは1つの状態を維持する時間が100~1000 回と長く設定されている.この範囲を限定して状態遷移の回数を 増加させた場合の各方策の累積報酬の変化をシミュレーション した.図3は待機する時間を変化させた場合の各方策の累積 報酬である.横軸は維持する時間の最大値であり,左側ほど状 態遷移回数が多い.結果,1つの状態を維持する時間の最大が 300回以下でどの方策も累積報酬が大きく減少した.





## 4. まとめ

ー般的な設定とモデル適用時を比較すると Thompson Sampling に大きな差があった. これは Thompson Sampling が 当たりの回数など報酬の履歴に影響してアームを選択している ため,変化が起こるとその対応に大幅な時間がかかるためだと 考えられる. その他にモデル適用時にはバンディット問題の方 策よりも強化学習の方策の累積報酬が高い結果となった. これ はアームの確率が変更し報酬が受け取りにくくなった場合に,Q 学習の更新式によるQ値の減少率が高く,またソフトマックス関 数によって確率的にアームを選択することで他のアームを選択 しやすくなるためだと考える. また待機時間を減少さていくとす べての方策で累積報酬が大きく減少した. 状態遷移の回数が増 加することで累積報酬の高かった方策であっても状態を推定し きれなくなっていると考えられる.

今後の課題として、状態が連続で変化していく待機時間が短 い場合には高い累積報酬を獲得した方策がなかった.そのため このような場合でも高い累積報酬が獲得できるような方策を考え る必要がある.また今回のモデルは状態数や次に遷移する状態 などの設定を限定した中で状態遷移を行っている.しかし、日常 的な問題には様々なシチュエーションや状態が存在する.よっ て様々な問題設定のモデルで各方策の累積報酬を明らかにし ていく必要がある.以上の2つにおいてシミュレーションしていく.

# 5. 参考文献

- [1] 総務省. (2015). インターネットショッピングの利用状況. 参照先: 総務省 | 平成 27 年版 情報通信白書: <u>http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h27/html/nc12</u> 2400.html
- [2] Lihong Li, Wei Chu, John Langford, Robert E.Schapire. (2012). A Contextual-Bandit Approach to Personalized News Article Recommendation.
- [3] 本多淳也, 中村篤祥. (2016). バンディット問題の理論とアルゴリズム. 講談社.
- [4] Peter Auer, Nicolò Cesa-Bianchi, Paul Fischer. (2002). Finite-time Analysis of the Multiarmed Bandit Problem. Machine Learning.
- [5] Olivier Chapelle, Lihong Li. (2011). An Empirical Evaluation of Thompson Sampling

# 運用中の予測器を使って未知のクラスを分類する方法

An Approach to Unseen Classs Classification with In-Service Predictors

坂井智哉 十河 泰弘 Tomoya Sakai Yasuhiro Sogawa

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

The goal of zero-shot learning is to recognize a novel class that did not appear in training. In this talk, we introduce a novel approach to zero-shot learning. Our approach reuses in-service predictors which are often available in practice. Unlike most of the existing methods, our method does not require to replace in-service predictors with new predictors specifically designed for zero-shot learning.

# 1. はじめに

機械学習技術が一般的になるにつれ,様々なデータ分析ツー ルが利用可能になっている.これにより,従来の課題の多くが 容易に解決されるようになりつつあるが,一方で,これまでの 機械学習手法を単純に適用するだけでは解けない問題も認識さ れるようになった.その一つの例として,訓練データには存在 しない未知のクラスがテスト時に現れるゼロショット学習 [1] が挙げられる.

ゼロショット学習では、既知と未知のクラスにまたがる属性と 呼ばれる共通の意味情報が与えられると仮定することで、未知 クラスを含めた分類を行う [1]. これまでに様々なゼロショッ ト学習法が提案され、その有用性が示されてきた [2-6].

一方で,従来のゼロショット学習法の多くが,ゼロショット 学習を導入する以前に既知クラスに対する予測器が運用されて いる状況を考慮していなかった.そのため従来の方法を利用す ると,既に運用中の予測器をゼロショット学習のための新しい 予測器と置き換えることになり,多くの費用と時間がかかるこ とになる.また,運用中の予測器に依存した他のシステムがあ れば,その更新費用も必要となる.

本研究では、モデル再利用法に基づいたゼロショット学習法 を提案する.提案法により、運用中の予測器を置き換えること なく、クラス属性を準備するだけで未知クラスを含む予測が可 能となる.計算機実験により、提案法はゼロショット学習専用 の予測器を一から構築しないにも関わらず、既存のゼロショッ ト学習手法の性能に匹敵する性能が得られることを示した.

#### 2. 予備知識

#### 2.1 問題設定

入力を d 次元の特徴ベクトル  $x \in \mathbb{R}^d$ ,対応するクラ スラベルを  $y \in \mathcal{Y}$  とする. クラス t に対する予測器を  $f^{(t)}: \mathbb{R}^d \to \mathbb{R}$  とし,テストデータ点 x' に対する予測ラベ ルを  $\hat{y} = \operatorname{argmax}_{t' \in \mathcal{Y}} f^{(t')}(x')$ で得る.

訓練およびテスト時におけるクラスラベルのドメインを、そ れぞれ  $\mathcal{Y}_{S} = \{1, \ldots, k_{S}\}$  および  $\mathcal{Y}_{U} = \{k_{S} + 1, \ldots, k_{S} + k_{U}\}$ とする.ここで、 $k_{S}$  と  $k_{U}$  は、それぞれ既知および未知クラ スのクラス数であり、 $\mathcal{Y}_{S} \cup \mathcal{Y}_{U} = \mathcal{Y}$  および  $\mathcal{Y}_{S} \cap \mathcal{Y}_{U} = \emptyset$ であ る.ゼロショット学習の目標は、訓練時にあたえられる既知ク ラスの教師情報から、テストデータ点が既知クラスと未知クラ

連絡先: {t-sakai,y-sogawa}@ah.jp.nec.com

スを含むクラスのうち,どのクラスに属するかを予測すること である.したがって,如何にして未知クラスに対する予測器の 出力を得るかが鍵となる.

#### 2.2 属性を用いた予測

ゼロショット学習を可能にする一つの方法が,属性と呼ばれる既知および未知クラスすべてに共通する意味情報を用いることである [1].

クラス*t*における属性を*m*次元の属性ベクトル*a*<sup>(t)</sup>  $\in \mathbb{R}^m$ で表す. 既知クラスおよび未知クラスに対する属性ベクトルの 集合を,それぞれ*A*<sub>S</sub> :=  $\{a^{(t)}\}_{t=1}^{k_S} \geq A_U := \{a^{(t')}\}_{t'=k_S+1}^{k_S+k_U}$ で表す.

従来のゼロショット学習のほとんどは、特徴および属性ベクトルを入力とする予測器  $G(x, a): \mathbb{R}^d \times \mathbb{R}^m \to \mathbb{R}$ を、属性ベクトルと既知クラスに関するラベル付きデータを用いて訓練する。予測器 G に入力する属性ベクトル  $a^{(t)}$  を固定すれば、 $g_{a^{(t)}}(x) := G(x, a^{(t)})$  はクラス t に対する予測器

$$f^{(t)}(\boldsymbol{x}) \approx g_{\boldsymbol{a}^{(t)}}(\boldsymbol{x})$$

とみなせる.ここで、g<sub>a</sub>(t) を属性固定予測モデルと呼ぶ. 未知クラスの属性を用いることで、未知クラスに対する予 測器の出力が得られるため、未知クラスを含めた分類が

$$\widehat{y} = \underset{t' \in \mathcal{Y}_0 \cup \mathcal{Y}_u}{\operatorname{argmax}} g_{a^{(t')}}(\boldsymbol{x}')$$

により可能となる.

#### **2.3** 運用中の予測器

本論文では,従来のゼロショット学習法と異なり,既知クラ スに対する予測器

$$\{h^{(t)}: \mathbb{R}^d \to \mathbb{R}\}_{t=1}^{\kappa_{\mathrm{S}}}$$

が得られることを仮定する.

運用中の予測器が利用可能という仮定は現実においてしば しば満たされる.例えば、データ分析者が教師付き学習を用い て用意した予測器が運用されていることが十分考えられる.こ れらの運用中の予測器を新たなゼロショット学習用の予測器に 置き換えるには、関連するシステムの更新費用や時間など多く のコストがかかるため、置き換えなしに未知クラスを含めた予 測ができることが望ましい.本研究の目的は、この運用中の予 測器 { $h^{(t)}$ }<sup>ks</sup><sub>t=1</sub> を再利用しながらゼロショット学習法を構築す ることである.

#### 3. 提案手法

#### 3.1 特徴固定予測モデル

$$\widehat{y}_j = \operatorname*{argmax}_{t' \in \mathcal{Y}_{\mathrm{S}} \cup \mathcal{Y}_{\mathrm{U}}} \eta_{\boldsymbol{x}_j'}(\boldsymbol{a}^{(t')})$$

により得られる.

#### **3.2** モデル再利用予測

次に特徴固定予測モデルの推定法について説明する.テス トデータ点には様々なパターンがあり得るため,あり得るすべ てのテストデータ点に対して特徴固定予測モデルを準備するこ とは現実的ではない.そこで,提案法は特定のテスト点に対す る予測モデルをテスト時に学習する.

まず,テストデータ点  $x'_{j}$ に対する運用中の予測器の出力  $s_{j}^{(t)} = h^{(t)}(x'_{j})$ を得る.鍵となるアイデアは,特徴固定予測モ デル $\eta_{x'_{j}}(a^{(t)})$ を,その出力が運用中の予測器の出力に近くな るように訓練することである:

$$s_j^{(t)} \approx \eta_{\boldsymbol{x}_j'}(\boldsymbol{a}^{(t)}).$$

そのような  $\eta_{x'_j}(a^{(t)})$  は,  $\{(a^{(t)}, s^{(t)}_j)\}_{t=1}^{k_{\rm S}}$  を訓練データとし て既製の回帰用ソフト(例えばリッジ回帰を行う関数)を利 用することで容易に得られる.得られた予測器  $\hat{\eta}_{x'_j}$  を用いる ことで,予測ラベル  $\hat{y}_j = \operatorname{argmax}_{t' \in \mathcal{Y}_{\rm S} \cup \mathcal{Y}_{\rm U}} \hat{\eta}_{x'_j}(a^{(t')})$ が得られる.

#### 4. 評価実験

# 4.1 人工データ

人工データを [3] に従い生成し,提案法の性能を評価した. 我々の実験では,  $d = 10, m = 20, n^{(t)} = 50, k_{\rm U} = 100 とした.$ 

運用中の予測器として、ロジスティック回帰(LR)とサポートベクトル分類器(SVC)を検討し、予測器の違いによる提 案法の性能への影響も調査した.提案法における、特徴固定予 測モデルの推定には ℓ<sub>2</sub>-正則化最小二乗法を利用した.

既知クラス数  $k_{\rm S}$  を変化したときの提案法の分類精度の変化 を図 1 に示す.  $k_{\rm S} < 50$  では、既知クラス数の増加に伴い分 類精度が増加し、 $k_{\rm S} \ge 50$  であれば、分類精度に大きな変化は 見られなかった.運用中の予測器に用いられる予測モデルに関 しては、LR を利用する方が平均的に少し高い分類精度が得ら れた.

#### 4.2 ベンチマークデータ

次に、4 つのベンチマークデータを用いて提案手法の性能 を評価した.ベンチマークデータとして、Attribute Pascal and Yahoo (aPY) [7], Animals with Attributes (AWA) [1], Caltech-UCSD-Birds 200-2011 (CUB) [8], SUN [9] を利用し た.画像特徴量として、101 層の ResNet [10] から得られた 2048 次元ベクトル [6] を利用した.

表1に平均 Top-1 分類精度を示す.提案法はゼロショット 学習に特化した分類器を一から構築しないにも関わらず,従来 のゼロショット学習専用の分類器の分類精度に匹敵する精度が 得られた.



図 1: 既知クラス数 k<sub>S</sub> を変化させたときの平均精度と標準誤 差(試行回数 5 回).

表 1: 平均 Top-1 分類精度. 既存手法の結果は, 既存研究 [6] より結果を引用した.

| 手法           | aPY  | AWA  | SUN  | CUB  |
|--------------|------|------|------|------|
| ALE $[2]$    | 39.7 | 59.9 | 58.1 | 54.9 |
| ESZSL $[3]$  | 38.3 | 58.2 | 54.5 | 53.9 |
| SynC $[4]$   | 23.9 | 54.0 | 56.3 | 55.6 |
| Lat $Em [5]$ | 35.2 | 55.1 | 55.3 | 49.3 |
| 提案法          | 38.7 | 54.5 | 55.4 | 53.4 |

# 5. おわりに

本研究では、モデル再利用に基づいたゼロショット学習法を 提案した.多くの従来法と異なり、提案法は運用中の予測器を 活用して未知クラスを含めた予測ができる.実験により、提案 法はゼロショット学習に特化した分類器を一から構築しないに も関わらず、従来法に匹敵する性能が得られることを確認した.

#### 謝辞

原稿にコメントをくれた大坂直人さんに感謝します.

#### 参考文献

- Christoph H Lampert, Hannes Nickisch, and Stefan Harmeling. Learning to detect unseen object classes by between-class attribute transfer. In CVPR, 2009.
- [2] Zeynep Akata, Florent Perronnin, Zaid Harchaoui, and Cordelia Schmid. Label-embedding for attribute-based classification. In *CVPR*, 2013.
- [3] Bernardino Romera-Paredes and Philip Torr. An embarrassingly simple approach to zero-shot learning. In *ICML*, 2015.
- [4] Soravit Changpinyo, Wei-Lun Chao, Boqing Gong, and Fei Sha. Synthesized classifiers for zero-shot learning. In CVPR, 2016.
- [5] Yongqin Xian, Zeynep Akata, Gaurav Sharma, Quynh Nguyen, Matthias Hein, and Bernt Schiele. Latent embeddings for zeroshot classification. In CVPR, 2016.
- [6] Yongqin Xian, Bernt Schiele, and Zeynep Akata. Zero-shot learning - the good, the bad and the ugly. In CVPR, 2017.
- [7] Ali Farhadi, Ian Endres, Derek Hoiem, and David Forsyth. Describing objects by their attributes. In CVPR, 2009.
- [8] P. Welinder, S. Branson, T. Mita, C. Wah, F. Schroff, S. Belongie, and P. Perona. Caltech-UCSD Birds 200. Technical report, California Institute of Technology, 2010.
- [9] Genevieve Patterson and James Hays. SUN attribute database: Discovering, annotating, and recognizing scene attributes. In *CVPR*, 2012.
- [10] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In CVPR, 2016.
# 自己組織化マップを用いた 定常・非定常環境に適応可能な多腕バンディットアルゴリズム Multi-armed bandit algorithm applicable to stationary and non-stationary environment using selforganizing maps

馬目 信人<sup>\*1\*2</sup> 篠原 修二<sup>\*2</sup> 鈴木 康大<sup>\*1\*2</sup> 朝長 康介<sup>\*1\*2</sup> 光吉 俊二<sup>\*2</sup> Nobuhito Manome Shuji Shinohara Kouta Suzuki Kosuke Tomonaga Shunji Mitsuyoshi <sup>\*1</sup> ソフトバンクロボティクス株式会社 <sup>\*2</sup> 東京大学大学院工学系研究科 SoftBank Robotics Corp. Graduate School of Engineering, The University of Tokyo

A communication robots aiming to satisfy the users facing them needs to take appropriate behavior more rapidly. However, user requests often change while these robots are determining the most appropriate behavior for these users. Therefore, it is difficult for robots to derive an appropriate behavior. Such problems are formulated as a multi-armed bandit problem. To solve this problem, we proposed a multi-armed bandit algorithm capable of adaptation to stationary and non-stationary environments using self-organizing map. In this study, numerous experiments were conducted considering a stochastic multi-armed bandit problem in both stationary and non-stationary environments. Consequently, the proposed algorithm demonstrated equivalent or improved effectiveness in stationary environments with numerous arms and consistently strong capability in non-stationary environments regardless of the number of arms in contrast with existing UCB1, UCB1-Tuned, and Thompson Sampling algorithms.

# 1. はじめに

対面するユーザを満足させることを目的とするコミュニケーションロボットは、ロボットの持つ多くの行動選択肢から、より早くそのユーザに適した行動を出力する必要がある.しかし現実には、ロボットがそのユーザに適した行動を模索してる最中にユーザの求めるものが変化してしまうことが多々ある.そのため、ロボットの最適な行動出力は難しい.

このような問題は、多腕バンディット問題[Robbins 1952]として 定式化される.多腕バンディット問題とは、ある確率で報酬が得 られる腕が複数ある環境下において、逐次的に腕を選択し、得 られる報酬を最大化させることを目的とする問題である.この問 題は、報酬確率の高い腕を見つける探索と報酬確率が高いと 確信する腕を引く知識利用のトレードオフを内在するモデルで あり、強化学習の最も基本的な問題とされている[Sutton 1998].

多腕バンディット問題における代表的なアルゴリズムとしては, ε-greedy [Sutton 1998], Softmax policy [Sutton 1998], Upper-Confidence Bound (UCB) policies [Auer 2002]などが存在する. これらのアルゴリズムは,定常環境下においては良い性能を示 す.しかし,非定常環境下においては良い性能を示さないこと から,動的な環境に特化したアルゴリズムも提案されている [Kocsis 2006][Garivier 2011].このように定常環境下において 優れた性能を出すアルゴリズムが,非定常環境下においても優 れた性能を出すとは限らず,どちらの環境下においても有用な アルゴリズムの開発は容易でない.

我々は、以前 Kohonen の自己組織化マップ (Self-Organizing Map: SOM) [Kohonen 1995]を用いた多腕バンディット問題のための新しいアルゴリズム (SOM-based Algorithm)を提案している [馬目 2019].本稿では、定常環境下,非定常環境下両者における提案アルゴリズムの性能をみるために、多腕バンディット問題の中でも腕の報酬が腕ごとに関連付けられた確率分布に従

連絡先:馬目信人,ソフトバンクロボティクス株式会社/東京大 学大学院工学系研究科, manome@bioeng.t.u-tokyo.ac.jp い与えられる確率的バンディット問題を対象として,数値実験を 行い,アルゴリズムの性能を検証する.

# 2. 多腕バンディットアルゴリズム

本稿では、提案アルゴリズムと ε-greedy や Softmax policy より 良い性能を示すことが知られている UCB1 [Auer 2002], UCB1-Tuned [Auer 2002], Thompson Sampling [Thompson 1933]との 性能比較を行う. そこで、本章ではこの 3 つの比較アルゴリズム と提案アルゴリズムについて述べる.

#### 2.1 UCB1

多腕バンディット問題において、得られる報酬を最大化するためには、報酬確率が高い腕を見つける探索と報酬確率が高い と確信する腕を引く知識利用のバランスが重要である. UCB1 は、 この探索と知識利用のバランスが優れており、確率的バンディット問題における標準的なアルゴリズムとされている.

このアルゴリズムでは、最初に全ての腕を1回ずつ選択し、その後は式(1)で定義される評価値が最も高い腕jを選択していく.

$$j = \operatorname{argmax}_{i} \left( \bar{X}_{i} + \sqrt{\frac{2 \log n}{T_{i}(n)}} \right)$$
(1)

このとき,  $\bar{X}_i$ は腕iの期待値, nは全ての腕の選択回数,  $T_i(n)$ は腕iの選択回数である.

#### 2.2 UCB1-Tuned

UCB1-Tunedは, UCB1の改良モデルである.

このアルゴリズムでは、UCB1 同様最初に全ての腕を 1 回ず つ選択し、その後は式(2)で定義される評価値が最も高い腕jを 選択していく.

$$j = \operatorname{argmax}_{i}\left(\overline{X}_{i} + \sqrt{\frac{\log n}{T_{i}(n)}\min\left\{\frac{1}{4}, V_{i}(T_{i}(n)\right)\right\}}\right) \quad (2)$$

このとき, $\bar{X}_i$ は腕iの期待値,nは全ての腕の選択回数, $T_i(n)$ は腕iの選択回数であり, $V_i$ は式(3)で定義される.

$$V_i(s) = \left(\frac{1}{s}\sum_{\gamma=1}^s X_{i,\gamma}^2\right) - \bar{X}_{i,s}^2 + \sqrt{\frac{2\log n}{s}}$$
(3)

このとき,  $X_{i,\gamma}$ は $\gamma$ 時点での腕iの報酬である.

### 2.3 Thompson Sampling

Thompson Sampling は, 腕の報酬パラメータ $\mu_i$ が何らかの確 率分布に従い生成されると仮定して考える確率一致法の一つ である. また, 大抵の場合 UCB policies に比べ有限の試行回数 内で良い結果を出せることが知られている[Kaufmann 2012].

このアルゴリズムは,各腕について,ある確率分布に従って 生成される乱数 $\tilde{\mu}_i$ をサンプリングし,この値が最も高い腕を選択 していく.

本稿では,各腕の報酬パラメータµiがベータ分布に従うとして 実装した.アルゴリズムを次に示す.

Algorithm 1: Thompson Sampling

For each arm i = 1, ..., N set  $n_i = 0, m_i = 0$ .

foreach t = 1, 2, ..., do

For each arm i = 1, ..., N, sample  $\tilde{\mu}_i$  from the Beta $(1 + n_i, 1 + m_i)$  distribution.

Play arm  $i = \operatorname{argmax}_{i \in \{1, \dots, N\}} \tilde{\mu}_i$  and observe reward  $r_t$ .

If  $r_t = 1$ , then  $n_i = n_i + 1$ , else  $m_i = m_i + 1$ .

### 2.4 提案アルゴリズム

本節では、はじめに Kohonen の最も基本的な SOM について 説明する. 次に SOM を用いた多腕バンディット問題のためのア ルゴリズムについて説明する.

#### (1) SOM

End

SOM は、Kohonen により発明された教師なし学習を行う人工 ニューラルネットワークであり、主にデータマイニングの分野でよ く用いられる[Li 2018][Belkhiri 2018]. SOM のアーキテクチャと 学習アルゴリズムの概要を図1に示す.

SOM は入力層と競合層の2層で構成される. SOM の目的は, 高次元の観測データセットを競合層の低次元空間へ写像する ことである. SOM の競合層は,正方格子状に分割され,それぞ れにノードが配置される.また,各ノードは重みと呼ばれる観測 データの次元数と同じ大きさのベクトルを持っている. SOM の学 習アルゴリズムを次に示す.

**Step 1**. 各ノードの重みに初期値**y**<sub>k</sub>(0)を与える. そして, 学習 回数*t* = 1とする.

**Step 2**. 観測データセットから一つのデータ**x**を入力ベクトルとして選択する.

Step 3. 入力ベクトルxに対して,最も近い重みを持つ勝者/ ードcを式(4)により決定する.

$$c = \operatorname{argmin}_{k} \|\mathbf{x} - \mathbf{y}_{k}(t-1)\|^{2}$$
(4)

Step 4. 各ノードの重みを式(5)により更新する.

$$\mathbf{y}_{k}(t) = \mathbf{y}_{k}(t-1) + \alpha(t)h_{ck}(t)\{\mathbf{x} - \mathbf{y}_{k}(t-1)\}$$
(5)

Step 1. Initialize each node's weight. Step 2. Choose an input vector from data set. Step 3. Calculate the Best Matching Unit.

Step 4. Modify the weights of nodes.



図 1. SOM のアーキテクチャと学習アルゴリズムの概要

このとき, αは学習率, h<sub>ck</sub>は近傍関数であり, それぞれ式(6) - (8)により定義される.

$$\alpha(t) = \alpha_0 \left( 1 - \frac{t}{T} \right) \tag{6}$$

$$h_{ck}(t) = \exp\left(-\frac{d_{ck}^2}{2\sigma(t)^2}\right)$$
(7)

$$\sigma(t) = \max\left\{\sigma_0 \exp\left(-\frac{t}{\tau}\right), \sigma_{min}\right\}$$
(8)

このとき、 $\alpha_0$ は学習率の初期値、Tは学習率の縮小スピードを決める時定数、 $d_{ck}$ は勝者ノードcと近傍ノードkのユークリッド距離である.また、 $\sigma$ は近傍半径であり、 $\sigma_0$ は近傍半径の初期値、 $\sigma_{min}$ は近傍半径の最小値、 $\tau$ は近傍半径の縮小スピードを決める時定数である。そして、学習回数t = t + 1として Step 2 に戻り処理を繰り返す。

#### (2) SOM-based Algorithm

提案アルゴリズムは、腕iを選択したときの報酬を腕iに対応するSOM<sup>i</sup>の入力とすることで腕の報酬確率を推定し、選択する腕を逐次的に決定していくものである.アルゴリズムを次に示す.

**Step 1**. 腕*i*に対応するSOM<sup>*i*</sup>を腕の数分用意する. この際, SOM<sup>*i*</sup>の各ノードの重みの初期値 $y_k^i(0)$ は,全て1次元ベクトル で $y_k^i(0) = (1)$ とする. そして,時刻t = 1とする.

Step 2. 式(9)で定義される評価値が最も高い腕jを選択する.

$$j = \operatorname{argmax}_{i} \frac{1}{N^{i}} \sum_{k=1}^{N^{i}} \left\| \mathbf{y}_{k}^{i}(t-1) \right\|$$
(9)

このとき, N<sup>i</sup>はSOM<sup>i</sup>のノード数である.また,評価値が最大となる腕が複数あった場合,その中で腕番号iが最も小さい腕を選択する.

**Step 3**. 腕*j*を選択したときの報酬を確認する. 得られた報酬 が1の場合 $\mathbf{x} = (1)$ ,報酬が0の場合 $\mathbf{x} = (0)$ とする.

Step 4. 選択した腕jに対応するSOM<sup>j</sup>について, xに対する勝 者ノードcを式(10)により決定する.

$$c = \operatorname{argmin}_{k} \left\| \mathbf{x} - \mathbf{y}_{k}^{j}(t-1) \right\|^{2}$$
(10)

このとき,勝者ノードとなる候補が複数あった場合,その中でノード番号kが最も小さいノードを選択する.

**Step 5**. SOM<sup>*j*</sup>について, 各ノードの重みを式(11)により更新 する.



図 2. 定常環境下における UCB1, UCB1-Tuned, Thompson Sampling, 提案アルゴリズムの regret の比較結果. 左から順に腕の本数 2, 10, 100 の場合における regret の 10,000 回の平均値を示す.



図 3. 非定常環境下における UCB1, UCB1-Tuned, Thompson Sampling, 提案アルゴリズムの regret の比較結果. 左から順に腕の 本数 2, 10, 100 の場合における regret の 10,000 回の平均値を示す.

$$\mathbf{y}_{k}^{j}(t) = \mathbf{y}_{k}^{j}(t-1) + \alpha(t^{j})h_{ck}(t^{j})\{\mathbf{x} - \mathbf{y}_{k}^{j}(t-1)\}$$
(11)

このとき、 $t^{j}$ は腕jの選択回数であり、 $\alpha$ および $h_{ck}$ は式(6) – (8) より計算する. 選択されなかった腕 $i(i \neq j)$ については $y_{k}^{i}(t) = y_{k}^{i}(t-1)$ とする. そして、時刻t = t + 1として Step 2 に戻り処理 を繰り返す.

### 3. 数値実験

本稿では,確率的バンディット問題を対象として,定常・非定 常環境下それぞれについて数値実験を行った.

腕の報酬は、腕iごとに設定された報酬確率 $P_i$ に基づいて決定される. プレイヤーは腕iを選択すると確率 $P_i$ で報酬1.0, 確率1- $P_i$ で報酬0.0を得ることができる. このとき、腕を選択する回数を step と呼び、プレイヤーが1 step で選択できる腕は1本のみである. 定常環境下における各腕の報酬確率 $P_i$ は、試行ごとに[0,1]区間の一様乱数によって決定した. また、非定常環境下における各腕の報酬確率 $P_i$ は、試行ごとに[0,1]区間の一様乱数によって決定した. また、非定常環境下における各腕の報酬確率 $P_i$ は、試行ごとに[0,1]区間の一様乱数によって再編した.

アルゴリズムの性能評価には、多腕バンディット問題における 代表的な評価指標である regret を用いた. regret とは、全ての step において報酬確率が最も高い腕を選択した場合と実際に 選択した腕の報酬期待値の差であり、この値が小さいほど良い アルゴリズムと考える. 本実験では、アルゴリズムの性能評価のために、腕の本数 2, 10,100の場合について、それぞれ 10,000 step のシミュレーショ ンを 10,000 回試行し、各 step における regret の平均値を算出し た.また、提案アルゴリズムにおける SOM の競合層は、全て大 きさ10×10、非トーラス型の正方格子とし、 $\alpha_0 = 0.1$ 、T = 10,000、 $\sigma_0 = 10$ 、 $\sigma_{min} = 5$ 、 $\tau = 50$ とした.

# 4. 結果

腕の本数 2, 10, 100 の場合について, 定常環境下における regret の結果を図 2 に, 非定常環境下における regret の結果を 図 3 に示す.

図2より定常環境下において, 腕の本数2の場合については UCB1-TunedとThompson Samplingの regret が同じ程度で最も 小さい値となった. 腕の本数 10 の場合については Thompson Samplingの regret が最も小さい値となった. 腕の本数 100 の場 合については, Thompson Samplingと提案アルゴリズムの regret が同じ程度で最も小さい値となった.

図 3 より非定常環境下においては, 腕の本数 2, 10, 100 全て の場合について提案アルゴリズムの regret が, 環境が変化する 500 step 目以降最も小さい値となった.

### 5. 考察

結果から、提案アルゴリズムは定常環境下において、UCB1, UCB1-Tuned, Thompson Sampling と比べ、腕の本数が多い場 合について同等以上の性能をあげることが読み取れる.また、



図 4. 提案アルゴリズムにおける SOM の可視化結果. 左の図は報酬 0.0, 1.0 が得られる確率がそれぞれ 0.8, 0.2 の腕を, 中央の 図は報酬 0.0, 1.0 が得られる確率がそれぞれ 0.2, 0.8 の腕を, 右の図は報酬 0.0, 0.5, 1.0 が得られる確率がそれぞれ 0.2, 0.6, 0.2 の腕を 1,000 回選択した後の SOM の可視化結果を示す. 格子上の色はノードの重みを表す.

非定常環境下においては、UCB1、UCB1-Tuned、Thompson Sampling と比べ、腕の本数に関わらず常に報酬確率の高い腕 を選択できることが読み取れる.

本稿では、提案アルゴリズムについて Kohonen の SOM をそのまま用いた.このメリットとデメリットについて述べる.

提案アルゴリズムにおけるメリットは、SOM の学習率,近傍半 径を縮小させることで有限の時間内に腕の報酬確率を効率よく 推定できる点にある.本来 SOM を用いる際は,観測対象のデ ータが変動しないことを前提としている.そのため,観測対象の データが時々刻々と変化する場合には,学習率,近傍半径を 縮小させない方が良い.一方で,提案アルゴリズムの式(11)の 2項目から分かるように,現時点のSOMのノードの重み(腕の評 価値に該当する)と実際に得られた報酬に差があればあるほど, 大きく値を更新するため,定常環境下のみならず非定常環境下 でも優れた性能を出せたと考えられる.

また, データマイニングの観点におけるメリットも存在する. SOM はデータの特徴を可視化することに優れている. そのため, SOM を可視化することで, どの報酬がどの程度の割合で出現 するかという腕の情報を分かりやすく捉えることができる. SOM の可視化結果の一例を図4に示す. 図4は,報酬が0.0, 1.0の 2 値を出力する腕と報酬が0.0, 0.5, 1.0の3 値を出力する腕を 1,000 回選択した後の SOM の可視化結果である. 図4に示す いずれの SOM においても, 直感的に, どの報酬がどの程度の 割合で出現するかという腕の特徴が見て分かる.

提案アルゴリズムにおけるデメリットとしては、腕の数と同じ数分の SOM を用意しなければならない点がある. そのため、問題における腕の本数が100の場合、SOM の数も100 用意する必要があり、メモリの消費量が多くなる. したがって、多腕バンディット問題をスマートに解くことだけを考えると SOM の計算式のみを用いた単純なモデルを考えた方が良い. ただし、計算速度については、1 step につき1つの SOM のノードの重みを更新するのみなので、さほど遅くはならない. また、決めなければならないパラメータが多い点も課題である.

# 6. まとめ

本稿では,確率的バンディット問題を対象として,定常・非定 常環境下それぞれについて数値実験を行った.その結果,提 案アルゴリズムは既存アルゴリズム UCB1, UCB1-Tuned, Thompson Sampling と比べ,定常環境下においては腕の本数 が多い場合について同等以上の性能を,非定常環境下におい ては腕の本数に関わらず常に良い性能をあげることを示した. 今後は、SOMのパラメータを変えた際の分析とSOMの計算 式をベースとしたより洗練されたアルゴリズムの開発に取り組む.

# 参考文献

- [Auer 2002] P. Auer, N. Cesa-Bianchi, and P. Fischer, "Finitetime analysis of the multiarmed bandit problem," *Machine Learning*, vol. 47, no. 2-3, pp. 235–256, 2002.
- [Belkhiri 2018] L. Belkhiri, L. Mouni, A. Tiri, T. S. Narany, and R. Nouibet, "Spatial analysis of groundwater quality using self-organizing maps," *Groundwater for Sustainable Development*, vol. 7, pp. 121-132, 2018.
- [Garivier 2011] A. Garivier, and E. Moulines, "On UpperConfidence Bound Policies for Non-stationary Bandit Problems," *Algorithmic Learning Theory*, pp. 174-188, 2011.
- [Kaufmann 2012] E. Kaufmann, N. Korda, and R. Munos, "Thompson Sampling: An Asymptotically Optimal Finite-Time Analysis," *Algorithmic Learning Theory*, pp. 199-213, 2012.
- [Kocsis 2006] L. Kocsis, and C. Szepesvári, "Discounted UCB," In: 2nd PASCAL Challenges Workshop, 2006.
- [Kohonen 1995] T. Kohonen, "Self-organizing Maps," Springer, 1995.
- [Li 2018] T. Li, G. Sun, C. Yang, K. Liang, S. Ma, and L. Huang, "Using self-organizing map for coastal water quality classification: Towards a better understanding of patterns and processes," *Science of The Total Environment*, vol. 628-629, no. 1, pp. 1446-1459, 2018.
- [Robbins 1952] H. Robbins, "Some aspects of the sequential design of experiments," *Bulletin of the American Mathematical Society*, vol. 58, no. 5, pp. 527–535, 1952.
- [Sutton 1998] R. S. Sutton, and A. G. Barto, "Introduction to Reinforcement Learning," *MIT Press*, 1998.
- [Thompson 1933] W. R. Thompson, "On the Likelihood that One Unknown Probability Exceeds Another in View of the Evidence of Two Samples," *Biometrika*, vol. 25, pp. 285-294, 1933.
- [馬目 2019] 馬目 信人, 篠原 修二, 鈴木 康大, 朝長 康介, 光吉 俊二: SOM に基づく多腕バンディットアルゴリズム, in Proceedings of the 81st National Convention of IPSJ, 2019.

# 決定木とCross-Entropy法を用いた解釈可能な制御方策の学習

Learning Interpretable Control Policies with Decision Trees via the Cross-Entropy Method

友紀子\*1\*2 亚岡 拓也\*1\*2 田中 鶴岡 Yoshimasa TSURUOKA Yukiko TANAKA Takuya HIRAOKA

\*<sup>1</sup>NEC セキュリティ研究所

NEC Security Research Laboratories

\*²産業技術総合研究所 人工知能研究センター National Institute of Advanced Industrial Science and Technology, Artificial Intelligence Research Center

\*3東京大学

The University of Tokyo

Learning interpretable policies for control problems is important for industrial requirements for safety and maintenance. A common approach to acquiring interpretable policies is to learn a decision tree that imitates a black-box (e.g., neural network-based) policy trained to maximize the expected reward in a given environment. However, such approximated decision tree policies are suboptimal in the sense that they do not necessarily maximize the expected reward. In this paper, we propose a method for learning a decision tree policy that directly maximizes the reward using the cross-entropy method. Our experimental results show that our method can acquire interpretable decision tree policies that perform better than baseline policies learned by the imitation approach.

#### はじめに 1.

解釈性のある制御方策 (以降、方策と呼ぶ) を学習すること は、産業応用における安全性やメンテンナンス容易性の観点 で重要である [Lipton 18]。人間が方策を解釈することができ れば、実際に方策に従って操作を実行する前に、操作の安全性 を確かめることができる。また、操作の過程で問題が起きた場 合でも、解釈性のある方策は人の手によって修正することがで きる。

深層強化学習が多くの制御タスクで人間を介さずに 高い性能の方策を獲得することに成功した [Silver 17, Andrychowicz 18] 一方で、これらの方策はニューラルネット ワークに基づいているため、一般に解釈性が低い。そのような 問題に対して、方策の学習に決定木のような解釈性の高いモデ ルを使う方法が存在する。Sammut らは、熟練操作員の操作 ログから、教師あり学習を用いて決定木に基づく方策を構築 している [Sammut 92]。Verma らは、ニューラルネットワー クでモデル化した方策を模倣するように解釈性のある方策を 学習している [Verma 18]。Liu らは、Q-Learning で得られた ブラックボックスの Q 関数を近似することで、決定木でモデ ル化された Q 関数を構築している [Liu 18]。これらの模倣に 基づく手法における主要な問題点のひとつに、学習済みのブ ラックボックス方策やQ関数を近似するように学習した決定 木方策は、モデルの複雑度の差によって、元のブラックボック ス方策やQ関数よりも性能が低下することが挙げられる。他 方、Hein らは解釈性のある木構造の方策を、ブラックボック ス方策の模倣を介さずに、遺伝プログラミングを用い期待報酬 を直接最大化して学習している [Hein 18] が、このアプローチ では方策パラメータを離散化して扱う必要があり、そのことが 学習で得た方策の性能低下を引き起こす可能性がある。

本研究では、Cross-Entropy 法 (CEM) [Szita 06] を用い、

連絡先: 田中 友紀子, NEC セキュリティ研究所, ytanaka@jz.jp.nec.com



**慶雅**\*2\*3

図 1: 決定木方策の学習

環境から与えられる期待報酬を直接最大化することで、解釈性 のある決定木方策を獲得する手法を提案する(図1)。本論文 では、まず CEM により決定木方策が直接最適化できるよう、 決定木方策のパラメータ表現を定義する。そして、我々の手法 を評価するため、複数の制御タスクで実験をする。実験の結果 より、ニューラルネットワークに基づく方策のふるまいを模倣 することで決定木方策を構築するベースライン手法よりも我々 の手法がよい性能となることを示す。さらに、我々の手法で獲 得した方策について考察し、それらがどのような解釈性をもつ かを示す。

#### 2. 検証準備

#### 2.1強化学習

強化学習の目標は、期待累積報酬を最大化するエージェン トの方策を学習することである [Sutton 98] 。一般に、エー ジェントが臨む問題は、マルコフ決定過程 (Markov Decision Processes; MDPs) で表される。MDPs では、各時間ステップ において、エージェントが環境から状態  $s_t \in S$  を観測し、環 境に行動  $a_t \in A$  を返す。ここで、S は状態空間で、A は行 動空間である。次に環境が次の  $s_{t+1}$  に遷移し、エージェント が報酬  $r_{t+1} \in \mathbb{R}$  を受け取る。エージェントは方策  $\pi$  に従い、  $s_{t+1}$  における  $a_{t+1}$  を決定する。本問題の目的は、エピソー ド周期 T における期待累積報酬  $R(\pi^*) = E_{\pi^*} \left[ \sum_{t=1}^T r_t \right]$ を最大化する最適な方策  $\pi^*$  を獲得することである。なお、本論 文では、feature 関数  $\phi(s)$  を用い、状態 s は F 次元ベクト ル表現  $\left[ \phi^{(1)}(s), ..., \phi^{(F)}(s) \right]$  に変換されると仮定する。

#### 2.2 Cross-Entropy法

本研究では、最適方策の獲得に CEM を用いる。具体的に は、パラメータ  $\boldsymbol{\theta} \in \mathbb{R}^d$  で方策  $\pi$  をパラメータ化し(パラメ タライズされた方策は  $\pi_{\boldsymbol{\theta}}$  と表記)、  $\boldsymbol{\theta}^* = \arg \max_{\boldsymbol{\theta}} R(\pi_{\boldsymbol{\theta}})$  と

なる最適パラメータ値  $\theta^*$ をみつけるために CEM を使う。 CEM では、1) パラメータサンプル生成、2) パラメータサン プル評価、3) パラメータ生成確率分布更新、を繰り返すことで  $\theta^*$ を探索する。ステップ1 では、b 個のパラメータサンプル  $\theta_1, ..., \theta_b$  が確率分布から生成される。本研究では、確率分布と して、平均ベクトル  $\mu$  と対角共分散行列  $\Sigma$  をもつ多変量ガウ ス分布  $N(\mu, \Sigma)$  を用いる。ここで、 $\sigma^{(i,i)}$ を、 $\Sigma$ の *i* 番目の対 角成分と定義する。ステップ2 では、 $\theta_1, ..., \theta_b$  がそれぞれに従 う方策を実行することで得られる累積報酬  $R(\pi_{\theta_1}), ..., R(\pi_{\theta_b})$ に基づいて評価される。そして、高い累積報酬を得た上位 *m* 個のサンプルが  $\theta_1, ..., \theta_b$  から選択される。これらの選ばれた サンプル集合を *M* と定義する。ステップ3 では、サンプル生 成用の確率分布が *M* によって更新される。本研究では、前記 多変量ガウス分布の平均ベクトルは次のように更新される。

$$\boldsymbol{\mu} = \frac{1}{m} \sum_{\boldsymbol{\theta}' \in M} \boldsymbol{\theta}'. \tag{1}$$

また、 Σの i 番目の対角成分は次のように更新される \*1。

$$\sigma^{(i,i)} = \frac{1}{m} \sum_{\theta' \in M} (\theta^{(i)'} - \mu^{(i)})^2 + \epsilon,$$
(2)

ここで、 $\theta^{(i)'}$ は $\theta'$ の*i*番目の要素であり、 $\mu^{(i)}$ は $\mu$ の*i*番目の要素である。また、 $\epsilon$ は学習早期における収束を防ぐための探索ノイズの定数である。このような手順を通し、CEM は $\theta^*$ を探索する。

# 3. 決定木方策の学習

この章では、決定木方策の学習手法について述べる。始めに 決定木方策のパラメータ表現について説明し、次に CEM を用 いたパラメータ更新手順について示す。

#### 3.1 パラメータ表現

この節では、決定木方策のパラメータ表現について定義す る。本研究では、図2の右側に示すような二分木構造をもつ 決定木を方策の表現として用いることとする。この方策におい て、非終端ノードは条件を表し、葉ノードは選択される行動を 表す。また、ノード間のリンクは条件の評価結果を表す。この



図 2: 決定木方策のパラメータ化

方策は、ある状態が与えられたとき、木の根ノードから葉ノードまでを辿ってひとつの行動を選択する。ここで、n を非終端 ノードのインデックス番号として表記し、非終端ノードの数を l、決定木の最大の深さを D と表記する \*<sup>2</sup>。

我々は、図 2 の左側に示すように、 $\theta_{\phi}$ 、 $\theta_{v}$ 、 $\theta_{u}$  で決定木 方策をパラメータ化する。 $\theta_{\phi}$  は各非終端ノードで評価される  $\phi(s)$  の要素を決定するために用いられる。 $\theta_{\phi}$  は  $(2^{D}-1) \times F$ 行列として表現される:

$$\boldsymbol{\theta}_{\phi} = \begin{bmatrix} \theta_{\phi}^{(1,1)} & \cdots & \theta_{\phi}^{(1,f)} & \cdots & \theta_{\phi}^{(1,F)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \theta_{\phi}^{(n,1)} & \cdots & \theta_{\phi}^{(n,f)} & \cdots & \theta_{\phi}^{(n,F)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \theta_{\phi}^{(2^{D}-1,1)} & \cdots & \theta_{\phi}^{(2^{D}-1,f)} & \cdots & \theta_{\phi}^{(2^{D}-1,F)} \end{bmatrix}, \quad (3)$$

ここで、 $\theta_{\phi}^{(n,f)}$  は n 番目の非終端ノードでの評価における状 態ベクトル  $\phi(s)$  の f 番目の要素に対応する値である。n 番目 の非終端ノードにおいて、評価に用いられる状態ベクトルの要 素  $\eta^{(n)}$  は、 $\theta_{\phi}$  を用いて次のように決定される:始めに、 $\theta_{\phi}$ の n 番目の行にある全ての要素を取り出す (これらの要素を  $\{\theta_{\phi}^{(n,1)}, \dots, \theta_{\phi}^{(n,F)}\}$ とする)。次に、 $\{\theta_{\phi}^{(n,1)}, \dots, \theta_{\phi}^{(n,F)}\}$ の中で 最も値が高い要素を選択し、対応する feature の要素を  $\eta^{(n)}$ として用いる。例えば、 $\{\theta_{\phi}^{(n,1)}, \dots, \theta_{\phi}^{(n,F)}\}$ から  $\theta_{\phi}^{(n,f')}$ が選 択された場合、 $\eta^{(n)}$  は  $\eta^{(n)} := \phi^{(f')}$ と決定される。

 $\boldsymbol{\theta}_v$  は各非終端ノードにおける閾値を決定するために用いられる。 $\boldsymbol{\theta}_v$  は (2<sup>D</sup> - 1) 次元ベクトルで表現される:

$$\boldsymbol{\theta}_{v} = \left[\theta_{v}^{(1)}, \cdots, \theta_{v}^{(n)}, \cdots, \theta_{v}^{(2^{D}-1)}\right], \qquad (4)$$

ここで $\theta_v^{(n)}$ は n 番目の非終端ノードにおける閾値  $v^{(n)}$  を表 す。 $v^{(n)}$ は  $v^{(n)} = (v_{max}^{(n)} - v_{min}^{(n)})g(\theta_v^{(n)}) + v_{min}^{(n)}$ で算出され る。ここで、 $v_{max}^{(n)}$ と  $v_{min}^{(n)}$ は、 $v^{(n)}$ の上限値と下限値である。 また、gはクリッピングを行うための関数であり、本研究では sigmoid 関数を用いる。

 $\boldsymbol{\theta}_u$ は葉ノードにおける行動を決定するために用いられる。 我々は、離散行動問題と連続行動問題それぞれのための $\boldsymbol{\theta}_u$ の 表現を提案する。

離散行動問題を想定した場合、 $\theta_u$ は  $2^D \times |A|$  行列として

 <sup>\*1</sup> ただし、ステップ3において、Σのすべての対角成分は式(2)
 で更新される

<sup>\*2</sup> つまり、非終端ノードの総数は (2<sup>D</sup> – 1) 、葉ノードの総数は 2<sup>D</sup> である

表される:

$$\boldsymbol{\theta}_{u} = \begin{bmatrix} \theta_{u}^{(1,1)} & \cdots & \theta_{u}^{(1,k)} & \cdots & \theta_{u}^{(1,|A|)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \theta_{u}^{(l,1)} & \cdots & \theta_{u}^{(l,k)} & \cdots & \theta_{u}^{(l,|A|)} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \theta_{u}^{(2^{D},1)} & \cdots & \theta_{u}^{(2^{D},k)} & \cdots & \theta_{u}^{(2^{D},|A|)} \end{bmatrix}, \quad (5)$$

ここで  $\theta_u^{(l,k)}$  は l 番目の葉ノードにおける k 番目の行動 候補  $a^{(k)} \in A$  に対応する値を表す。方策実行時において、  $\{\theta_u^{(l,1)}, \dots, \theta_u^{(l,|A|)}\}$ のうち最も値の大きい要素に対応する行動 候補が l 番目の葉ノードにおける行動  $u^{(l)}$  として選ばれる。

連続行動問題を想定した場合、 $\theta_u$ は 2<sup>D</sup> 次元ベクトルで表 される:

$$\boldsymbol{\theta}_{u} = \left[\theta_{u}^{(1)}, \cdots, \theta_{u}^{(l)}, \cdots, \theta_{u}^{(2^{D})}\right], \tag{6}$$

ここで  $\theta_u^{(l)}$  は *l* 番目の葉ノードにおける行動  $u^{(l)} \in \mathbb{R}$  に対応 する値を表す。 $u^{(l)}$  は  $u^{(l)} = \alpha h(\theta_u^{(l)})$  で算出される。ここで 関数 *h* はクリッピングを行うための関数であり、本研究では tanh 関数を用いる。また、  $\alpha$  は  $u^{(l)}$  を適切な範囲に収める ための係数である。

#### 3.2 パラメータ更新

前節で説明した決定木方策のパラメータ (すなわち、 $\theta_{\phi}, \theta_{v}$ 、 $\theta_{u}$ )を報酬を最大化するように更新する。パラメータの更新 手順を、Algorithm 1 に示す。ここでは、 $\theta_{\phi}, \theta_{v}, \theta_{u}$ のす べての要素を結合して  $\theta$  として扱い、CEM を適用する。

#### Algorithm 1 Cross-Entropy 法による決定木方策の学習

**Require:** initial mean vector  $\mu_0$ , initial diagonal covariance matrix  $\Sigma_0$ , number of elite *m*, constant exploration noise  $\epsilon$ 

1:  $\mu \leftarrow \mu_0$ 

2:  $\Sigma \leftarrow \Sigma_0$ 

- 3: for each update do
- 4: Generate *b* parameter samples  $\theta_1, \theta_2, ..., \theta_b$  from  $N(\mu, \Sigma)$
- 5: Evaluate each parameter samples using  $R(\pi_{\theta_1}), ..., R(\pi_{\theta_b})$
- 6: Select m parameter samples with the highest evaluations.
- 7: Update  $\mu$  by Equation (1)
- 8: Update all diagonal elements in Σ by Equation (2)
  9: end for

# 4. 実験

#### 4.1 タスク

今回、2つの制御タスクにて手法を評価する。タスク設定の サマリを表1に示す。

**CartPole:** ポールが倒れないよう、台車をコントロール するタスクである。今回、OpenAI Gym [Brockman 16] の 「CartPole-v0」環境を用いる。状態空間は連続で4次元、行 動空間は2つの離散行動 (台車に加える力の方向)である。

**Pendulum:** トルクをコントロールし、振り子を倒立状態 に維持するタスクである。今回、OpenAI Gym の「Pendulumv0」環境を用いる。状態空間は連続で 3 次元、行動空間は 1 次元の連続値 (トルク) である。

| 表 1:     | タン | スク設定 |                    |
|----------|----|------|--------------------|
| タスク      | F  | 行動   |                    |
| CartPole | 4  | 離散、  | A  = 2             |
| Pendulum | 3  | 連続、  | $a \in \mathbb{R}$ |

| タスク          | D | ベースライン   | 提案      |
|--------------|---|----------|---------|
| CartPole     | 2 | 13.2     | 200.0   |
| (NN: 200.0)  | 3 | 24.4     | 200.0   |
|              | 4 | 10.55    | 200.0   |
| Pendulum     | 2 | -1091.4  | -848.96 |
| (NN: -342.5) | 3 | -1331.1  | -290.98 |
|              | 4 | -1219.94 | -542.57 |

CartPole、Pendulum の両タスクにおいて、各エピソード の初期状態はランダムに初期化される。

#### 4.2 実験設定

ベースライン手法としてブラックボックス方策のふるまい を模倣する決定木を用いる [Sammut 92, Verma 18, Liu 18] 。まず始めに、ニューラルネットワークに基づく方策 (ブラッ クボックス方策) を PPO [Schulman 17] を用いて学習する。 次に、ニューラルネットワークに基づく方策を用いて 20 エピ ソード分の試行をし、訓練用のサンプル (状態と行動のペア) を集める。最後に、訓練用のサンプルを用いて、教師あり学 習で決定木方策を構築する。なお、ニューラルネットワークは 64 ノードの隠れ層 2 層を用いる。また、PPO は 環境との相 互作用を 10<sup>6</sup> 回通して学習される。

また、提案手法として Algorithm 1 を用いて決定木を構築 する。ハイパーパラメータには、 $b = 20, m = 4, \epsilon = 0.0001$ を用いる。

# 5. 評価

表 2 に定量的な評価結果を示す。今回、20 エピソードの平 均累積報酬に基づいて前記手法を評価した。ベースライン手 法は、5 つの乱数シードを用いた試行のうち、学習終了時の方 策の成績 (平均累積報酬) がもっともよい方策を用い、決定木 を構築した。提案手法は、5 つの乱数シードを用いた試行のう ち、学習時における方策の成績 (平均累積報酬) がもっともよ い更新回の方策を評価に用いた。なお、表 2 に示す評価値は、 学習時とは異なる新たな 20 エピソード分の試行を用いて算出 したものである。表 2 内の D は決定木の最大の深さである。 また、表 2 の各タスク名の下に「NN」として記載している手 法は、PPO で学習したニューラルネットワークに基づく方策 を用いたものである。表 2 の結果より、我々の手法はベース ライン手法の成績を上回っていることがわかる。

決定木方策の解釈性についての定性的な評価をする。図3 に、Pendulum タスクで学習した決定木方策の可視化例を示 す。方策がある状態を環境から受け取った場合、図3に示さ れるような決定木方策の各非終端ノードでの条件分岐結果に従 い、次の時間ステップで取るべき行動を選択する。非終端ノー ドでの条件文は、振り子の位置や速度のような物理量を用いた 表現で構成されており、タスクを達成する方法(どのように振 り子を倒立した状態に維持するか)が人間からみて理解しやす い形式となっている。また、図4にCartPole タスクで学習し た決定木方策の例を可視化した図を示す。図4では、2番目の



図 3: Pendulum タスクにおける Cross-Entropy 法を用いた 決定木方策 *D* = 3.



図 4: CartPole タスクにおける Cross-Entropy 法を用いた決 定木方策 *D* = 2.

深さの右に位置する非終端ノードの条件「cart\_v < 4.589」の 分岐結果はいずれも「push left」となっている。このような結 果は、図 5 のようなより簡潔な表現にすることができる。図 5 の例も、図 3 と同様に車の速度やポールの傾き角のような物 理量を用いて方策が表現されており、人間からみて理解しやす い形で可視化されている。本研究では、Pendulum、CartPole の両タスクで図 3、図 5 のような比較的浅い木構造で学習結 果を確認することができた。このような決定木方策は、数百の ノードを含むニューラルネットワークに基づく方策と比較し、 学習で得られた方策の確認に要する時間や労力が軽減される。

# 6. まとめ

今回、CEM を用いて報酬を直接最大化する、解釈性のある 決定木方策の獲得手法を提案した。2つの単純な制御タスクに おける実験結果から、ニューラルネットワークに基づく方策を 模倣するベースライン手法より我々の手法がよい性能となるこ とが分かった。将来的には、よい性能を出すためにより深い木 構造が必要となるような、より複雑なタスクでの検証をするこ とが望ましい。深い決定木において、最適な方策パラメータを 求めることは難しいことが予期される。今後は、解釈性を保ち つつ複雑なタスクに適用できる手法に拡張する必要がある。



# 参考文献

- [Andrychowicz 18] Andrychowicz, O. M., Baker, B., Chociej, M., Józefowicz, R., McGrew, B., Pachocki, J. W., Petron, A., Plappert, M., Powell, G., Ray, A., Schneider, J., Sidor, S., Tobin, J., Welinder, P., Weng, L., and Zaremba, W.: Learning Dexterous In-Hand Manipulation, Vol. arXiv:1808.00177, (2018)
- [Brockman 16] Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., and Zaremba, W.: OpenAI Gym, Vol. arXiv:1606.01540, (2016)
- [Hein 18] Hein, D., Udluft, S., and Runkler, T. A.: Interpretable Policies for Reinforcement Learning by Genetic Programming, *Engineering Applications of Artificial In*telligence, Vol. 76, pp. 158–169 (2018)
- [Lipton 18] Lipton, Z. C.: The Mythos of Model Interpretability, Queue, Vol. 16, No. 3, pp. 30:31–30:57 (2018)
- [Liu 18] Liu, G., Schulte, O., Zhu, W., and Li, Q.: Toward Interpretable Deep Reinforcement Learning with Linear Model U-Trees, in *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pp. 414–429, Springer (2018)
- [Sammut 92] Sammut, C., Hurst, S., Kedzier, D., and Michie, D.: Learning to fly, in *Machine Learning Pro*ceedings 1992, pp. 385–393, Elsevier (1992)
- [Schulman 17] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O.: Proximal Policy Optimization Algorithms, Vol. arXiv:1707.06347, (2017)
- [Silver 17] Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., Hubert, T., Baker, L., Lai, M., Bolton, A., et al.: Mastering the game of Go without human knowledge, *Nature*, Vol. 550, No. 7676, p. 354 (2017)
- [Sutton 98] Sutton, R. S. and Barto, A. G.: Introduction to Reinforcement Learning, MIT Press, Cambridge, MA, USA, 1st edition (1998)
- [Szita 06] Szita, I. and Lörincz, A.: Learning Tetris using the noisy cross-entropy method, *Neural computation*, Vol. 18, No. 12, pp. 2936–2941 (2006)
- [Verma 18] Verma, A., Murali, V., Singh, R., Kohli, P., and Chaudhuri, S.: Programmatically Interpretable Reinforcement Learning, in *Proceedings of the 35th International Conference on Machine Learning*, Vol. 80 of *PMLR*, pp. 5045–5054, Stockholmsmssan, Stockholm Sweden (2018)

図 5: 簡潔な表現にした決定木方策

# ディープラーニングによるくずし字認識組み込みシステムの開発 Development of Embedded System for Recognizing *Kuzushiji* by Deep Learning

竹内正広<sup>\*1</sup> 早坂太一<sup>\*1</sup> 大野亙<sup>\*1</sup> 加藤弓枝<sup>\*2</sup> 山本和明<sup>\*3</sup> 石間衛<sup>\*4</sup> 石川徹也<sup>\*4</sup> Masahiro Takeuchi, Taichi Hayasaka, Wataru Ohone, Yumie Kato, Kazuaki Yamamoto, Mamoru Ishima, and Tetsuya Ishikawa

\*1 豊田工業高等専門学校 \*2 鶴見大学 \*3 国文学研究資料館 \*4 TRC-ADEAC 株式会社 National Institute of Technology, Toyota College, Tsurumi University, National Institute of Japanese Literature, and TRC-ADEAC, Inc.

Abstract: Effective utilization of "Pre-modern Japanese book database" constructed by the project supervised by Center for Collaborative Research on Pre-Modern Texts, National Institute of Japanese Literature, will push forward the development of the inter-field study. It may become an obstacle for the researchers with a little knowledge of classical literature, however, because historical Japanese texts have been written by *Kuzushiji (Hentaigana* and cursive kanji). In this article, we report an attempt of recognizing *Kuzushiji* by deep learning. Using Raspberry Pi which is the low-cost small single board computer, we developed the embedded system with enough recognizing rate and speed. In addition, manifold images of *Kuzushiji* written in a text image of the spread can be extracted. Our system will be effective for school children or elderly people not possessing mobile devices who want to come in touch with *Kuzushiji*.

# 1. はじめに

国文学研究資料館により平成 26 年度より開始された「日本 語の歴史的典籍の国際共同研究ネットワーク構築計画」[1]では、 研究基盤整備として約 30 万点の歴史的典籍を画像データ化し、 既存の書誌情報データと統合させたデータベースの構築を行 っている.これを有効活用できれば、人文科学のみならず、自 然科学系分野を融合させた研究の展開も期待される.しかしな がら多くの研究者にとっては、それらに書かれている文字が「く ずし字」であることが障壁となる.

本研究では、ディープラーニングを用いたくずし字の自動翻 刻の試みを行っている.本稿では、既に WWW アプリケーショ ンとして実装されている学習モデル[2]を応用し、小型で比較的 安価なシングルボードコンピュータ Raspberry Pi を用いて開発 されたくずし字認識組み込みシステムについて報告する.

# 2. システム概要

図 1 に本研究で開発したシステムの概要を示す. Raspberry Pi 用カメラモジュール Picamera から対象の古典籍画像を撮影 する.本研究で用いるディープラーニングにより学習されたモデ ルは、くずし字1文字に対して認識を行うため、Python3 および



図1 システムの概要図



OpenCV3を用いて認識する文字の選択,画像処理などを行う. 認識は機械学習用ライブラリ TensorFlow Lite を用いて行われ, 結果は7インチのタッチディスプレイに表示される.

# 2.1 くずし字領域の検出

古典籍画像に対する前処理を OpenCV3 によって行う. 1文 字の選択は、タッチスクリーンに指を触れてから離すまでの x-y 座標を取得し、文字領域を 62×62 ピクセルにリサイズし、2値 化を行った後に、学習モデルに入力する. しかしながら、1文字 ずつ選択して認識する方法では、時間と手間がかかるため、 OpenCV3 のモルフォロジ処理によって、古典籍画像から自動で 1文字ずつの領域を検出することを試みた.

まず入力画像に対して、図 2(a)に示すように縦方向に対して 膨張処理を行い、上下の字をつなげることで、1行ごとの集まり を作成し、領域検出を行う.次に、検出した領域範囲を用いて、 図 2(b)に示すように元の入力画像を横方向に膨張処理を行い、 1行の中から1文字の領域を検出する.図 2(c)に検出例を示す.



図2 文字領域の検出過程と結果例

# 2.2 くずし字認識モデル[2]

本研究では、ディープラーニングで学習したくずし字認識モデルを用いる.このモデルは、4層の畳み込み層と3層の全結合層から構成される畳み込みニューラルネットワークである.このモデルに対して、ディープラーニング用ライブラリ Caffe を用

いて学習を行った. 学習には 3,985 種類の 418,831 文字(平均 105 文字/種類)のくずし字画像データ[3]を用いた. そのうち, 変体仮名(48 文字+濁点・半濁点)は 75 種類の 262,547 文字(平均 3,501 文字/種類), その他の漢字・カタカナ・記号などは 3,910 種類の 156,284 文字(平均 40 文字/種類)である. このモデルは, テストデータの源氏物語絵巻「桐壺」[4]11,286 文字(変体仮名 10,026 文字, その他 1,260 文字)に対して, 正解率 92.4%(変体仮名 95.2%, その他 70.1%)を得ている.

# 2.3 モデルの量子化

本研究では当初, Raspberry Pi で学習モデルを実行させるた めに, 代表的な機械学習ライブラリである TensorFlow を使用し た[5]. しかしながら, 学習モデルのサイズは 298.2MB, 認識時 間は約 3.0 秒と, モデルの読み込みおよび認識にある程度の時 間がかかった. そこで, モバイル端末や組み込み機器向けの TensorFlow Lite を使用した. TensorFlow Lite では, 学習済み モデルの重みなどを浮動小数点形式から固定小数点形式に量 子化し, モデルサイズを小さくすることで, 能力がやや劣る機器 での演算の高速化, および読み込みにかかる時間を短縮する ことができる. 本研究では, 入力のみ 32bit の浮動小数点形式と し, 他のパラメータは 8bit の固定小数点形式に量子化した. そ の結果, 先行研究と同精度のまま, モデルサイズは 78.4MB に 軽量化され, 1文字あたりの認識にかかる時間は約 0.4 秒と, TensorFlow による認識時間から約 1/8 に短縮することができた.

# 3. 実行例

開発したくずし字認識システムの表示画面を図3および図4 に示す.開発したシステムでは、GUIアプリケーションから、カメ ラ撮影、ファイル読み込み、文字検出、切り取り、自動認識のそ れぞれのボタンを操作することで処理を行うことができる.



図3 開発したシステムの実行例

ディスプレイの背面に設置した Raspberry Pi 用カメラモ ジュールは,焦点距離を約 30cm とし、3 秒間のプレビュ 一後に古典籍画像を撮影するよう設定した.既に保存済み の古典籍画像データ,もしくは保存を行った過去の画像デ ータのどちらかを選択して,ファイル読み込みを行うこと もできる.認識後は図 4 に示すように結果を表示し,認識 結果の保存と元画像のくずし字を認識結果に置き換えるこ とができる.その後,認識した文字を再びタッチすること で結果を何度でも参照することが可能であり,利用者が候 補となる5文字の中から認識結果を選択することが可能で ある.認識結果はテキストデータとして保存され、画像と 同時に読み込むことで、いつでも認識結果を参照すること ができる.



図4 認識結果の表示例

また、ディスプレイを2本指でタッチすることで、図3に示すように、認識を行った文字は緑色枠で、文字検出を行った結果の 領域は青色枠で囲まれて表示される.検出した領域をタッチす ることで認識が行われ、結果が表示される.任意の領域の切り 取りを行いたい場合は、ディスプレイからタッチおよびドラッグに より選択し、その後に表示される認識ボタンを押すと認識を行う ことができる.ボタンにより再度選択を行うことも可能である.

### 4. おわりに

本研究では、Raspberry Piを用い、カメラで撮影した画像など からくずし字の認識を可能とするシステムを開発した。量子化ニ ューラルネットワークを用いたところ、1文字を認識するのにかか る時間や精度は先行研究とほぼ変わらず、高性能なコンピュー タを用いなくても、Raspberry Pi のようなシングルボードコンピュ ータで問題なく動作することを示すことができた。

スマートフォンを持ち込むことができない小・中学校や, 普段 モバイル機器を持ち歩かない高齢者の方々でも、くずし字に触 れたいという場面に遭遇することは少なくないと考えられる. ネッ トワーク環境のない場所も含めて, そうした現場で支援ツールと して活躍することができるよう、本システムの操作性や認識精度 をより高めることが今後の課題である.

#### 謝辞

本研究は JSPS 科研費 JP16K02433 および TRC-ADEAC 株 式会社からの助成を受けたものです.

# 参考文献

- 国文学研究資料館:歴史的典籍に関する大型プロジェ クト, https://www.nijl.ac.jp/pages/cijproject/, 2015 年10月14日参照.
- [2] 早坂太一 他: 2017 年度人工知能学会全国大会(第 31 回)論文集, 3Q1-2in1, 2017.
- [3] 人文学オープンデータ共同利用センター:日本古典 籍字形データセット(国文研所蔵・CODH 加工), http://codh.rois.ac.jp/char-shape/, 2016年12月8日 参照.
- [4] 人文学オープンデータ共同利用センター:日本古典籍 データセット(国文研所蔵),源氏物語, http://codh. rois.ac.jp/pmjt/book/200003803/, 2017 年 2 月 15 日 参照.
- [5] 竹内正広他:第17回情報科学技術フォーラム講演論 文集, vol.4, pp.293-294, 2018.

# Residual Networks に対する確率的正則化の提案: Shake-ResDrop と Shake-SENet

Stochastic Regularization for Residual Networks: Shake-ResDrop and Shake-SENet

白濱 淳也 川本 一彦 Junya Shirahama Kazuhiko Kamoto

千葉大学

Chiba University

Recently, residual networks (ResNets) and their improvements, such as stochastic regularization, have proven to be able to reduce overfitting during training processes. In this paper, we propose two stochastic models which combines stochastic regularization and attention mechanism. The two models are based on ShakeDrop, combining either SENet or Stochastic Depth with ShakeDrop itself. Both of our methods were able to improve existing ShakeDrop results on CIFAR-100.

# 1. はじめに

深層学習を用いた画像認識タスクでは,畳み込みニュー ラルネットワーク (CNN) が主流となっている. Residual networks (ResNet) [He et al. 2016] は、ショートカット接 続をもつ CNN で, 2015 年に 150 層以上という大幅な深 層化を実現した. ResNet は深層化に欠かせないため,現 在でも広く利用されている. 最近では, ResNet の汎化能 力を向上させるために確率的な正則化が提案されている. Dropout[Srivastava et al 2014] のようにニューロンではなく, ResNet の層を確率的に落とす Stochastic Depth (ResDrop) [Haung et al. 2016] や,外乱を加えデータ拡張効果をもたら す Shake-Shake [Gastaldi et al. 2017] などの確率的手法が提 案されている. さらに, ResDrop のように層を落とすのでは なく Shake-Shake のように外乱を加えるか加えないか確率的 に変化させ、ShakeDrop[Yamada et al. 2018] も提案されて いる. ShakeDrop は CIFAR-100 を用いた画像分類で当時の 最高精度を記録した. さらに, ResNet にアテンション機構を 導入した SENet[Hu et al. 2018] も提案されている.

本研究では、このようなアテンション機構や確率的正則化の モデルを組み合わせてより高性能な確率的正則化を提案する.

# 2. 提案手法

既存の確率的正則化手法である ShakeDrop を軸に ResDrop と SENet を組み合わせたアーキテクチャを提案する.

#### 2.1 ShakeDrop ≿ ResDrop

ShakeDrop と ResDrop を組み合わせる. ShakeDrop に層 を落とす機構を加えるため、図 1 のように、residual モジュー ル、ショートカット接続 (出力に 0 をかけるため),出力に乱 数  $\alpha \in [-1,1]$  をかける ShakeDrop モジュール,の3つの構 造が学習中に現れることになる. その結果,ShakeDrop より も強いアンサンブル学習の効果を得ることが期待できる. さ らに、ショートカット接続が加わることにより、パラメータ を減らすこともでき、学習時間を短縮することもできる.ま た、ResDrop や ShakeDrop と同様に層が深くなるにつれて、 residual モジュールが現れる確率を低くし、残りの2つの確率

連絡先: 川本一彦, 千葉大学大学院工学研究院, 千葉市稲毛区 弥生町 1-33, kawa@faculty.chiba-u.jp



図 1: ShakeDrop と ResDrop 組み合わせて現れる3つの構造

が高くなるようにする.この確率の変化は、ネットワークが5 層のとき図2に示すようになる.

#### 2.2 ShakeDrop $\succeq$ SENet

この2つを組み合わせる方法としては図3に示すようになり, ShakeDropさせた後にSE Blockを入れるか(図3左),前に入れるかとなる(図3右).

ShakeDrop の後に加えた場合は ShakeDrop の特徴空間で のデータ拡張と SENet のアテンション機構を組み合わせるこ とができる.この組み合わせでは、図3左に示すように、畳 み込み層の出力に  $\alpha \in [-1,1]$ をかけるため符号反転も起こる うり、学習を乱しすぎることになると考えられる.乱数をかけ ない場合(residual モジュールになる)は SENet の本来のア テンション機構を生み出すことができるため、後に加えた場合 も精度向上が見込まれる.

ShakeDrop の前に加えた場合は ShakeDrop のでのデータ 拡張に SENet のアテンション機構を組み合わせることができ る. ShakeDrop の乱数と同時に, 畳み込み層からの出力を SE Block の重みでスケーリングするため, チャンネルのアテン ションを含むデータ拡張を行うことができる. 乱数が負を含む ことによってチャンネルのアテンションの符号反転を入れるこ ともできるため, 負の値での強い摂動を更に与えれると考えら れる [Yamada et al. 2018]. また前に加える場合後に加えた場 合と同様に, 乱数をかけないときは SENet を本来の形で与え られる.



図 2:5 層である場合の3種類の現れ方



図 3: 左: ShakeDrop の後 右: ShakeDrop の前

### 実験結果と考察

ー般画像認識データセットの CIFAR-100 を用いて誤識別率 で比較する. CIFAR-100 は 100 クラス各 600 枚, 合計 60000 枚の画像を抽出したデータセットで, 各クラス 500 枚を学習 用データ, 100 枚を評価用データとする. 実験の設定を表 1 に 記す.

表2に実験結果を示す.表2より,ShakeDrop単独の手法よ りも、3つの提案手法で誤識別率は低くなっている.ResDrop と組み合わせでは、アンサンブル学習の効果を強めることがで き性能向上できたと考えている.さらに、パラメータ数を減ら すことができるため学習時間の減少も確認できる.ShakeDrop の前にSENetを組み込む手法が最も低い誤識別率を達成してい る.このことは、チャンネルのアテンションを含むデータ拡張を することが性能向上に貢献することを示している.ShakeDrop の後にSENetを組み込む手法も、ShakeDrop単独に比べて誤 識別率は低くなっており、アテンション機構を単純に確率的正 則化に組み合わせても有効であることを示している.

# 4. おわりに

本研究では、確率的正則化手法の ShakeDrop に、確率的正 則化手法の ResDrop やアテンション機構の SENet を組み合 わせることの有効性を従来手法と比較することにより実証し た.今後は検証した確率的正則化方法とアテンション機構を同 時に組み合わせることを検討している.

# 謝辞

本研究は JSPS 科研費 JP16K00231 の助成を受けたもの です.

| 表 1: 実験設 | 定 |
|----------|---|
|----------|---|

| バッチサイズ | 128                       |
|--------|---------------------------|
| エポック数  | 1800                      |
| データ扩張  | Random Erasing            |
|        | [Zoung et al. 2016]       |
| 学習率    | 0.2                       |
| 重み減衰   | 0.0001                    |
| 最適化関数  | SGD with momentum         |
| 損失関数   | クロスエントロピー誤差               |
| 受羽計面   | Cosine Learnig Scheduling |
| 十日山回   | [Loshchilov et al. 2017]  |

表 2: CIFAR-100 に対する実験結果

| 手法                     | 誤識別率 (%) | 学習時間 (h) |
|------------------------|----------|----------|
| ShakeDrop              | 13.16    | 66.8     |
| ShakeDrop and ResDrop  | 12.76    | 63.0     |
| ShakeDrop after SENet  | 12.42    | 77.9     |
| ShakeDrop before SENet | 12.83    | 76.8     |

# 参考文献

- [He et al. 2016] K.He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," Proc. CVPR, pp.770-778, 2016.
- [Srivastava et al 2014] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," J. of Machine Learning, vol.15, pp.1929-1958, 2014.
- [Haung et al. 2016] G. Huang, Y. Sun, Z. Liu, D. Sedra, and K. Weinberger, "Deep networks with stochastic depth," arXiv preprint arXiv:1603.09382v3, 2016.
- [Gastaldi et al. 2017] X. Gastaldi, "Shake-shake regularization," arXivpreprint arXiv:1705.07485v2, 2017.
- [Yamada et al. 2018] Y. Yamada, M. Iwamura, and K Kise. "Shakedrop regularization," arXiv preprint arXiv:1802.02375, 2018.
- [Hu et al. 2018] J. Hu, L. Shen, S. Albanie, G. Sun and E. Wu. "Squeeze-and-excitation networks," Proc. CVPR, pp.7132-7141, 2018.
- [Zoung et al. 2016] Z. Zhong, L. Zheng, G. Kang, S. Li, and Y. Yang, "Random erasing data augmentation," arXiv preprint arXiv:1708.04896, 2017.
- [Loshchilov et al. 2017] I. Loshchilov , F. Hutter. "stochastic gradient descent with restarts." arXiv preprint arXiv:1608.03983, 2016.

# Fairness-aware Edit of Thresholds in a Learned Decision Tree Using a Mixed Integer Programming Formulation

Kentaro Kanamori Hiroki Arimura

Graduate School of Infomation Science and Technology, Hokkaido University

Fairness in machine learning is an emerging topic in recent years. In this paper, we propose a post-processing method for editing a given decision tree to be fair according to a specified discrimination criterion by modifying its branching thresholds in internal nodes. We propose a mixed integer linear programming (MIP) formulation for the problem, which can deal with several other constraints flexibly and can be solved efficiently by any existing solver. By experiments, we confirm the effectiveness of our approach by comparing existing post-processing methods.

# 1. Introduction

**Background and Motivation** In the application of machine learning models to the actual decision making, problems other than their prediction accuracy, such as *interpretability* [10] and *fairness* [7], attract increasing attention. If their prediction results are unexplainable or discriminative, they are no longer usable in the actual decision making, even if they achieve high accuracy.

In this paper, we focus on *decision tree models* [4], and study a post-processing method [7] for decision trees. More specifically, we consider a problem of editing a decision tree by modifying its branching thresholds in internal nodes so as to satisfy fairness constraints w.r.t. a sensitive attribute such as gender and race, named *re-thresholding problem*. We formulate it as a *mixed integer linear programming (MIP)* problem, which we can obtain an optimal solution by powerful off-the-shelf solvers such as CPLEX<sup>\*1</sup> and Gurobi<sup>\*2</sup>. Our approach has the following advantages:

- Interpretability: Decision tree models are known as one of the interpretable machine learning models since their predictions are based on a set of rules that human can understand easily [10, 11].
- Adaptivity: Post-processing methods can deal with the situation that a sensitive attribute or fairness criterion is given after learning [6, 7, 9]. In the actual decision making, they are not always given in advance.
- Flexibility: Our MIP formulation can deal with additional constraints defined by users without implementing designated algorithms, if these constraints can be expressed as linear equations or inequalities [2,3,11].

#### **Contribution** Our contributions are as follows:

1. We formulate a post-processing problem of editing a given decision tree so as to satisfy fairness constraints by modifying its branching thresholds, named *re-thresholding problem*, as an MIP problem.

- 2. We formulate an edit distance [12] of a decision tree to measure dissimilarity between given and modified decision trees as edit limitation constraints.
- 3. By experiments on real datasets, we confirm the effectiveness of our proposed method by comparing other existing post-processing methods.

# 2. Preliminary

#### 2.1 Notation

For  $n \in \mathbb{N}$ , we denote by  $[n] = \{1, \ldots, n\}$ . For a proposition  $\psi$ ,  $\mathbb{I}[\psi]$  denotes the indicator of  $\psi$ , i.e.,  $\mathbb{I}[\psi] = 1$  if  $\psi$  is true, and  $\mathbb{I}[\psi] = 0$  if  $\psi$  is false.

In this paper, we consider a binary classification problem, and assume its input space is normalized to  $[0,1]^D$  without loss of generality. Let a pair of an input and an output  $(x,y) \in [0,1]^D \times \{0,1\}$  be an *example*, and  $S = \{(x^{(j)}, y^{(j)})\}_{j=1}^N$  be a *dataset* with N examples. For a prediction model  $h : [0,1]^D \to \{0,1\}$ , the empirical loss on S is defined by  $L(h \mid S) := \frac{1}{N} \sum_{j=1}^N \mathbb{I}\left[h(x^{(j)}) \neq y^{(j)}\right]$ .

In addition, we consider a sensitive attribute  $z \in \{0, 1\}$ , such as gender and race. Let  $z^{(j)}$  be the sensitive attribute value w.r.t. *j*-th example  $(x^{(j)}, y^{(j)}) \in S$ , and  $Z = \{z^{(j)}\}_{j=1}^N$  be the set of its values w.r.t. *S*.

#### 2.2 Decision trees

The decision tree [4] is a prediction model that consists of a set of prediction rules expressed by the full binary ordered tree structure. It makes the prediction according to the label of the leaf node that the input x reaches, and the corresponding leaf node is determined by traversing the tree from the root. Each internal node has a pair of parameters  $(d,b) \in [D] \times [0,1]$ , where d is a branching feature and b is a branching threshold, and the input  $x = (x_1, \ldots, x_D)$  is directed to one of two child nodes depending on whether the statement  $x_d \leq b$  is true or not.

Then, the decision tree can be expressed as follows:

$$h(x) = \sum_{k=1}^{K} l_k \prod_{m \in a_k^{(\mathrm{L})}} \mathbb{I}\left[x_{d_m} \le b_m\right] \prod_{m \in a_k^{(\mathrm{R})}} \mathbb{I}\left[x_{d_m} > b_m\right],$$

Contact: kanamori@ist.hokudai.ac.jp

<sup>\*1</sup> https://www.ibm.com/analytics/cplex-optimizer

<sup>\*2</sup> http://www.gurobi.com/



Figure 1: An illustration of a decision tree. For 2-nd leaf node,  $a_2^{(L)} = \{1,3\}, a_2^{(R)} = \{2\}$ , and its corresponding region  $r_2 = (-\infty, 0.8] \times (0.4, 0.7]$ .

where  $K \in \mathbb{N}$  is the total number of leaf nodes,  $l_k \in \{0, 1\}$ is a predictive label of k-th leaf node,  $(d_m, b_m) \in [D] \times [0, 1]$ is a branching rule in m-th internal node, and  $a_k^{(L)}(a_k^{(R)}) \subseteq [K-1]$  is a set of left(right)-branching internal node indexes on the pass from the root node to k-th leaf node. Note that a decision tree with K leaf nodes has K-1 internal nodes since it is expressed as the full binary ordered tree structure. We denote a region corresponding to k-th leaf node by  $r_k \subseteq [0,1]^D$ . Then, a set of the regions  $\{r_k\}_{k=1}^K$ expresses a partition of the input space. Figure 1 illustrates an example of a decision tree.

We denote a set of all possible decision trees by  $\mathcal{H}$ . In this paper, since we consider the problem of modifying branching thresholds  $B := (b_1, \ldots, b_{K-1}) \in [0, 1]^{K-1}$  of a given decision tree, we denote a decision tree with B by  $h_B \in \mathcal{H}$ .

#### 2.3 Discrimination scores

We use two major criteria named demographic parity(DP) [5] and equal opportunity(EO) [8] to evaluate the discrimination of the model. We denote an empirical probability on a dataset S and sensitive attribute Z by  $\hat{P}$ .

**Definition 1 (DP score)** *DP score of a model* h *on a dataset* S *w.r.t. a sensitive attribute* Z *is defined by* 

$$\delta_{\rm DP}(h \mid S, Z) := |P(h(x) = 1 \mid z = 1) - \hat{P}(h(x) = 1 \mid z = 0)|.$$

**Definition 2 (EO score)** EO score of a model h on a dataset S w.r.t. a sensitive attribute Z is defined by

$$\delta_{\rm EO}(h \mid S, Z) := |\hat{P}(h(x) = 1 \mid y = 1, z = 1) - \hat{P}(h(x) = 1 \mid y = 1, z = 0)|.$$

In this paper, we call DP and EO scores discrimination score together. These values approach 1 as the model htends to make the predictions unfairly for z, while they approach 0 if the model makes the predictions fairly.

#### 2.4 Problem formulation

Here, we define our problem named *re-thresholding problem*. We assume that a decision tree  $h_B$  with branching thresholds B is already given, and the goal is to reduce the discrimination score on a given dataset S by modifying branching thresholds in B without changing the given decision tree significantly.

**Problem 1 (Re-thresholding)** Given a dataset S, sensitive attribute Z, decision tree  $h_B$  with branching thresholds  $B = (b_1, \ldots, b_{K-1})$ , discrimination score disc  $\in \{\text{DP}, \text{EO}\}$ , discrimination threshold  $t \in [0, 1]$ , dissimilarity measure of decision trees  $\Delta : \mathcal{H} \times \mathcal{H} \to \mathbb{R}_{\geq 0}$ , and parameters  $\lambda \geq 0$  and  $N_{\text{minsup}} \in [|S|]$ , re-thresholding problem is defined as follows:

$$\begin{array}{ll} \underset{\boldsymbol{\theta} \in [0,1]^{K-1}}{\text{minimize}} & L(h_{\boldsymbol{\theta}} \mid S) + \lambda \cdot \Delta(h_B, h_{\boldsymbol{\theta}}) \\ \text{subject to} & \delta_{disc}(h_{\boldsymbol{\theta}} \mid S, Z) \leq t \\ & \forall k \in [K] : |\{(x, y) \in S \mid x \in r_k\}| \geq N_{\text{minsup}} \end{array}$$

Note that we modify only branching thresholds, and do not modify branching features and predictive labels in leaf nodes. As a dissimilarity measure of decision trees  $\Delta$  in Problem 1, we propose an *edit distance of a decision tree*  $\Delta_{\rm ED}$ , which will be defined in the next section.

# 3. Proposed Method

Our formulation is based on OCT, the MIP framework for learning optimal classification trees proposed by Bertsimas and Dunn [3]. In order to adapt it to our editing problem for decision trees, we formulate an edit distance of decision trees and fairness constraints.

#### 3.1 Program variables

For  $m \in [K-1]$ ,  $j \in [N]$ ,  $k \in [K]$ , we introduce some variables for formulating Problem 1 as follows:

- $\theta_m \in [0, 1]$  is a modified branching threshold in *m*-th internal node.
- $\phi_{j,k} \in \{0,1\}$  indicates whether *j*-th input  $x^{(j)}$  reaches *k*-th leaf node, i.e.,  $\phi_{j,k} = \mathbb{I}\left[x^{(j)} \in r_k\right]$ .
- $\psi_k \in \{0, 1\}$  indicates whether some example reaches *k*-th leaf node, i.e.,  $\psi_k = \mathbb{I} \left[ \exists j \in [N] : x^{(j)} \in r_k \right].$
- $\epsilon_m^{(L)}(\epsilon_m^{(R)}) \in \{0,1\}$  indicates whether no example reaches leaf nodes in the left (right) subtree of *m*-th internal node  $c_m^{(L)}(c_m^{(R)}) \subseteq [K]$ , i.e.,  $\epsilon_m^{(L)} = \mathbb{I}\left[\forall k \in c_m^{(L)} : \psi_k = 0\right]\left(\epsilon_m^{(R)} = \mathbb{I}\left[\forall k \in c_m^{(R)} : \psi_k = 0\right]\right)$ .
- $\xi_m \in [0,2]$  expresses the cost corresponding to edit operations for *m*-th internal node.

 $\phi_{j,k}, \psi_k, \epsilon_m^{(L)}, \epsilon_m^{(R)}$  and  $\xi_m$  are auxiliary variables. The total number of the variables is  $\mathcal{O}(NK)$ .

#### 3.2 Edit distance of decision trees

We define an *edit distance of a decision tree* based on the standard tree edit distance [12]. For two ordered trees T and T', the tree edit distance between them is defined as the minimal length of the sequence of editing operations to transform T into T'. Available edit operations are insertion, deletion, and relabeling.

In our problem, an explicit edit operation is relabeling threshold values in internal nodes. We define  $|b_m - \theta_m| \in$ 



Figure 2: An example of deleting and relabeling operations. If no example reaches leaf nodes in the right subtree of *m*-th internal node ( $\epsilon_m^{(R)} = 1$ ), *m*-th internal node and its right subtree are deleted from the tree, and the total number of these edit operations are measured as an edit distance. Otherwise ( $\epsilon_m^{(R)} = 0$ ),  $|b_m - \theta_m|$  occurs as a cost for the relabeling operation.

[0, 1] as the cost of the relabeling operation for *m*-th internal node. However, when a modified branching threshold exceeds a specific value, no examples in *S* reaches its child leaf node, which is denoted by  $\psi_k = 0$ . By deletion of all leaf nodes with  $\psi_k = 0$  and their parent internal nodes in the decision tree  $h_{\theta}$ , we can obtain a unique tree structure whose prediction results on *S* are equivalent to  $h_{\theta}$ .

Then, we define our edit distance  $\Delta_{\text{ED}}$  between  $h_{\theta}$  and  $h_B$ by the total number of these delete operations and relabeling costs. For *m*-th internal node, if no example reaches leaf nodes in its left or right subtree, i.e.,  $\epsilon_m^{(\text{L})} = 1$  or  $\epsilon_m^{(\text{R})} = 1$ , the editing cost  $\xi_m$  is 2 because *m*-th internal node and its subtree are deleted. Note that if  $\epsilon_m^{(\text{L})} = 1$  ( $\epsilon_m^{(\text{R})} = 1$ ),  $\xi_{m'} = 2$  holds for any *m'*-th internal nodes included in left (right) subtree of *m*-th internal node because  $\psi_k = 0$  for any  $k \in c_{m'}^{(\text{L})}$  ( $c_{m'}^{(\text{R})}$ ) and  $\epsilon_{m'}^{(\text{L})} = 1$  or  $\epsilon_{m'}^{(\text{R})} = 1$  hold, and sum of these  $\xi_{m'}$  is equivalent to the cost of delete operations for the subtree. It can be expressed as follows:

$$\Delta_{\rm ED}(h_B, h_{\theta}) = \sum_{m=1}^{K-1} \max\{|b_m - \theta_m|, 2\epsilon_m^{\rm (L)}, 2\epsilon_m^{\rm (R)}\}.$$

Figure 2 shows an example of edit operations in our problem. By using  $\xi_m$ ,  $\psi_m$ ,  $\epsilon_m^{(L)}$ , and  $\epsilon_m^{(R)}$ , it can be expressed as a linear function and constraints.

#### 3.3 Fairness constraints

We can express both DP and EO scores by using variables  $\phi_{j,k}$  as follows:

$$\delta_{disc}(h_{\boldsymbol{\theta}} \mid S, Z) = \sum_{k=1}^{K} l_k \sum_{j=1}^{N} d_{j,k}^{(disc)} \phi_{j,k}.$$

 $d_{j,k}^{(disc)}$  is a constant value determined automatically when S and Z are given such that

$$d_{j,k}^{(disc)} = \begin{cases} \frac{z^{(j)}}{|S_1^{(DP)}|} - \frac{1-z^{(j)}}{|S_0^{(DP)}|} & (disc = DP), \\ \frac{y^{(j)}z^{(j)}}{|S_1^{(EO)}|} - \frac{y^{(j)}(1-z^{(j)})}{|S_0^{(EO)}|} & (disc = EO), \end{cases}$$

where  $S_z^{(DP)} := \{ (x^{(j)}, y^{(j)}) \in S \mid z^{(j)} = z \}$  and  $S_z^{(EO)} := \{ (x^{(j)}, y^{(j)}) \in S \mid y^{(j)} = 1 \land z^{(j)} = z \}$  for  $z \in \{0, 1\}$ .

#### 3.4 Overall formulation

Now, we can formulate Problem 1 as the following MIP problem:

minimize 
$$\frac{1}{N} \sum_{k=1}^{K} \sum_{j=1}^{N} c_{j,k} \phi_{j,k} + \lambda \sum_{m=1}^{K-1} \xi_m$$
 (1)

subject to 
$$\sum_{k=1}^{K} \phi_{j,k} = 1, \forall j \in [N]$$
(2)

$$\phi_{j,k} \le \psi_k, \forall k \in [K], j \in [N]$$
(3)

$$\sum_{j=1}^{N} \phi_{j,k} \ge N_{\text{minsup}} \cdot \psi_k, \forall k \in [K]$$
(4)

$$\substack{j \\ m} \leq \theta_m + (1 - \phi_{j,k}),$$

$$\forall k \in [K] \ i \in [N] \ m \in a^{(L)}$$

$$(5)$$

$$-e_m > \theta_m - (1 + e_{\max})(1 - \phi_{i,k}),$$
(6)

$$\forall k \in [K], j \in [N], m \in a_k^{(\mathrm{R})}$$
 (6)

$$-\xi_m \le b_m - \theta_m, \forall m \in [K-1]$$
(7)

$$b_m - \theta_m \le \xi_m, \forall m \in [K-1]$$
(8)

$$\xi_m \ge 2\epsilon_m^{(\mathrm{L})}, \forall m \in [K-1]$$
(9)

$$\xi_m \ge 2\epsilon_m^{(\mathrm{R})}, \forall m \in [K-1]$$
(10)

$$1 - \epsilon_m^{(\mathrm{L})} \le \sum_{k \in c_m^{(\mathrm{L})}} \psi_k, \forall m \in [K - 1]$$
(11)

$$\sum_{k \in c_m^{(\mathrm{L})}} \psi_k \le (1 - \epsilon_m^{(\mathrm{L})}) |c_m^{(\mathrm{L})}|, \forall m \in [K - 1] \quad (12)$$

$$1 - \epsilon_m^{(\mathbf{R})} \le \sum_{k \in c_m^{(\mathbf{R})}} \psi_k, \forall m \in [K-1]$$
(13)

$$\sum_{k \in c_m^{(\mathbf{R})}} \psi_k \le (1 - \epsilon_m^{(\mathbf{R})}) |c_m^{(\mathbf{R})}|, \forall m \in [K - 1]$$
(14)

$$\sum_{k=1}^{K} l_k \sum_{j=1}^{N} d_{j,k}^{(disc)} \phi_{j,k} \le t$$
(15)

$$-\sum_{k=1}^{K} l_k \sum_{j=1}^{N} d_{j,k}^{(disc)} \phi_{j,k} \le t$$
(16)

where  $e_m = \min\{|x_{d_m}^{(i)} - x_{d_m}^{(j)}| \mid i, j \in [N], x_{d_m}^{(i)} \neq x_{d_m}^{(j)}\}, e_{\max} = \max\{e_m\}_{m=1}^{K-1}$ , and  $c_{j,k} := l_k(1 - y^{(j)}) + (1 - l_k)y^{(j)}$ . We can express  $L(h_{\theta} \mid S)$  and  $\Delta_{\text{ED}}(h_B, h_{\theta})$  by  $\sum_{k=1}^{K} \sum_{j=1}^{N} c_{j,k} \phi_{j,k}$  and  $\sum_{m=1}^{K-1} \xi_m$ , respectively. Equation (2) and inequalities (3-6) are the same constraints with OCT [3]. Inequalities (7-15) and (16,17) are constraints for expressing our edit distance  $\Delta_{\text{ED}}(h_B, h_{\theta})$  and fairness constraint  $\delta_{disc}(h_{\theta} \mid S, Z) \leq t$ .

#### 4. Experiments

**Experimental setup** We used the **COMPAS** dataset [1]. It has N = 6172 examples and the total number of features is D = 9. Its output label  $y^{(j)} \in \{0, 1\}$  indicates whether *j*-th person recidivates within two years. We use the attribute "African-American" as its sensitive attribute  $z^{(j)} \in \{0, 1\}$ .

|                | Training          |       | Test              |       |                        |
|----------------|-------------------|-------|-------------------|-------|------------------------|
| method         | Loss              | DP    | Loss              | DP    | time[s]                |
| NB-Modified    | $0.387 \pm 0.022$ | 0.103 | $0.384 \pm 0.005$ | 0.118 | 2.028                  |
| Relabeling     | $0.412 \pm 0.018$ | 0.044 | $0.412 \pm 0.028$ | 0.063 | $0.704 \times 10^{-4}$ |
| MIP (proposed) | $0.396 \pm 0.011$ | 0.095 | $0.389 \pm 0.012$ | 0.112 | 316.72                 |

Table 1: Experimental results averaged over 5 trials. "Loss" and "DP" denote the average empirical loss with its standard deviation and DP score for training and test datasets. "time" denotes the average running times.

We compared our method (**MIP**) with the existing two post-processing methods: (1) modifying naive Bayes (**NB-Modified**) [6], and (2) relabeling for decision trees (**Relabeling**) [9]. In our experiments, we randomly split the dataset into training (50%) and test (50%) datasets, and report the average statistics over 5 trials. We obtained initial prediction models and applied each methods by using training datasets. Decision trees were learned by CART [4] with the constraint on these height less than 3. We used the threshold value of the fairness constraint t = 0.1 for all methods, and  $\lambda = 0.1$  and  $N_{\text{minsup}} = 100$  for Problem 1. All codes were implemented in Python 3.6 with scikit-learn<sup>\*3</sup> and IBM ILOG CPLEX Optimization Studio v12.8. All experiments were conducted on 64-bit macOS Sierra 10.12.6 with Intel Core i5 2.90GHz CPU and 8GB Memory.

**Experimental results** Table 1 shows the experimental results for DP scores. The DP scores of naive Bayes and decision trees before modification were 0.462 and 0.226, respectively. Our method maintained slightly lower loss than the relabeling method for decision trees on both training and test datasets, and comparable accuracy with the modifying naive Bayes method. We note that the average DP score attained by the modifying naive Bayes method exceeds t = 0.1 since it sometimes failed to obtain a model satisfying the fairness constraint. On the other hands, the running time of our method was longer than other two methods. This result implies that we need to improve our formulation, e.g., reducing program variables and constraints.

# 5. Conclusion and Discussion

We studied a fairness-aware post-processing method for decision trees, and proposed an MIP formulation of the rethresholding problem, which makes a given decision tree fair by modifying their branching thresholds. Also, we formulate an edit distance of a decision tree so as to avoid that a learned model is changed significantly. By experiments on real datasets, we confirmed the effectiveness of our methods by comparing with the existing post-processing methods.

As future work, we will try to extend our framework so as to modify branching features, and deal with user-defined constraints more flexibly. It is important that maintaining user's prior knowledge contained in the model, e.g., order of branching features on a pass from its root node to a leaf node, while improving fairness by editing operations.

Acknowledgements This work was partially supported by JSPS KAKENHI(S) 15H05711 and JSPS KAKENHI(A)

16H01743.

# References

- J. Adebayo. FairML: Auditing black-box predictive models. https://github.com/adebayoj/fairml, 2018.
- [2] S. Aghaei, M. J. Azizi, and P. Vayanos. Learning optimal and fair decision trees for non-discriminative decision-making. In *Proc. AAAI 2019, Hawaii*, 2019 (to appear).
- [3] D. Bertsimas and J. Dunn. Optimal classification trees. Mach. Learn., pages 1039–1082, 2017.
- [4] L. Breiman, J. Friedman, C. J. Stone, and R. A. Olshen. *Classification and regression trees.* CRC press, 1984.
- [5] T. Calders, F. Kamiran, and M. Pechenizkiy. Building classifiers with independency constraints. In *IEEE ICDM 2009 Workshops*, pages 13–18, Dec 2009.
- [6] T. Calders and S. Verwer. Three naive bayes approaches for discrimination-free classification. *Data Min. Knowl. Discov.*, pages 277–292, 2010.
- [7] S. Hajian, F. Bonchi, and C. Castillo. Algorithmic bias: From discrimination discovery to fairness-aware data mining. In *Proc. ACM KDD 2016, San Francisco*, pages 2125–2126, 2016.
- [8] M. Hardt, E. Price, and N. Srebro. Equality of opportunity in supervised learning. In NIPS 2016, Barcelona, pages 3315–3323.
- [9] F. Kamiran, T. Calders, and M. Pechenizkiy. Discrimination aware decision tree learning. In *IEEE ICDM* 2010, pages 869–874, 2010.
- [10] M. T. Ribeiro, S. Singh, and C. Guestrin. "Why should I trust you?": Explaining the predictions of any classifier. In *Proc. ACM KDD 2016, San Francisco*, pages 1135–1144, 2016.
- [11] C. Rudin and Ş. Ertekin. Learning customized and optimized lists of rules with mathematical programming. *Mathematical Programming Computation*, 10(4):659– 702, Dec 2018.
- [12] K. Zhang and D. Shasha. Simple fast algorithms for the editing distance between trees and related problems. *SIAM Journal on Computing*, 18(6):1245–1262, 1989.

<sup>\*3</sup> https://scikit-learn.org/

# コメディドラマにおける字幕と表情を用いた笑い予測

Predicting Laughters in Comedy Drama with Subtitles and Facial Expression

Chenhui Chu\*<sup>3</sup>

萓谷 勇太 \*1 Yuta KAYATANI 大谷 まゆ \*2 <sub>Mayu</sub> OTANI 中島 悠太 \*<sup>3</sup> Yuta NAKASHIMA 竹村 治雄 \*1 Haruo TAKEMURA

\*1大阪大学大学院情報科学研究科

Graduate School of Information Science and Technology, Osaka University

\*<sup>2</sup>株式会社サイバーエージェント CyberAgent, Inc.

\*<sup>3</sup>大阪大学 データビリティフロンティア機構 Institute for Datability Science, Osaka University

In this paper, we propose a model to predict whether an utterance leads to laughter in a comedy TV show. And we counts for facial expression that actors/presenters make. The model with subtitles and facial expression constructed as input was able to obtain accuracy, precision, recall, f-score more than model which input subtitle only or model which input only facial expression.

# 1. はじめに

笑いは、コミュニケーションにおいて非常に重要な役割を持つ. その笑いを引き起こすジョークは、プレゼンテーションにおいても聴講者の関心を示し、引き込むことができる. それだけでなく、ジョークは普段の会話においても会話を盛り上げ、その場を和ませることができる. 実際に、これらのジョークによる笑いが生み出す効果は、暗黙的に周知されており、人々は会話の中で笑いを誘発しようとしている.

現在、機械による笑いの予測に向けた研究も進められてい おり, 例えば Bertero ら [1] の研究が挙げられる. Bertero ら は、笑いが起こる発話はその発話以前の発話が起因となってい ると仮定し、時系列情報を扱うことを得意とする LSTM を使 用したモデルを構築した. この Bertero らの手法は字幕のみを 入力としており,登場人物の表情などの視覚情報について考慮 されていない.しかし,我々は笑いを引き起こすことにおいて 視覚情報は重要な手がかりであると考えた. 例えば、図1は登 場人物の発言が終了した時点の表情の変化によって笑いを誘発 している. そこで, 我々は Bertero らと同様に, 笑いを予測す ることができるモデルを考案し,Bertero らが複数の発話を入 力していることに対して、1つの発話のみを用い、その上で、 字幕だけでなく、視覚情報である発話者の表情の特徴量である Action Unit[2] を使用し、それが笑い予測において重要である ことを示す. 結果として, 字幕だけでなく, 視覚情報である表 情も組み合わせることで、最も高い精度を得ることができた.

# 2. 提案手法

提案手法として、モデルへの入力を表情・字幕とし、その二 つの入力に対するモデルの出力によって、笑いが起こった確率 を得る.

#### 2.1 表情の取得

本研究では、表情を取得する手法として、OpenFace[3] を用 いる. OpenFace では、目・鼻・口などの顔のパーツの形状や 位置、頭の向き、視線の向き、顔の表情(Action Unit)などを 検出することができる. Action Unit とは、顔面筋肉の解剖学



図 1: 表情の例 (The BIg Bang Theory, Season 3, Espode 12 (CBS) より.)

| 表 1: Action Unit |          |        |            |  |
|------------------|----------|--------|------------|--|
| AU No.           | 内容       | AU No. | 内容         |  |
| 1                | 眉の内側を上げる | 14     | えくぼを作る     |  |
| 2                | 眉の外側を上げる | 15     | 唇両端を下げる    |  |
| 4                | 眉を下げる    | 17     | オトガイを上げる   |  |
| 5                | 上まぶたを上げる | 20     | 唇両端を横に引く   |  |
| 6                | 頬を上げる    | 23     | 唇を固く閉じる    |  |
| 7                | 瞼を緊張させる  | 25     | 顎を下げずに唇を開く |  |
| 9                | 鼻にシワを寄せる | 26     | 顎を下げて唇を開く  |  |
| 10               | 上唇を上げる   | 45     | 瞬く         |  |
| 12               | 唇両端を上げる  |        |            |  |

的知見を基礎とした,44の動作単位の事を指し,例えば,笑顔 を表す時,Action Unit は 6 + 12 となる. OpenFace では 17 種類の Action Unit の強度 (0 - 5) が取得できる. OpenFace で得られる Action Unit は表 1 の通りである.

#### 2.2 ネットワーク構成

本研究におけるネットワークモデルを図2に示す.二つの 入力における詳細は以下の通りである.

字幕

字幕に関しては、単語分散表現である GloVe[4] を使用する.この時,発話ごとに単語のベクトル値の平均値を計算したものを使用し、また入力の発話は1つのみとする.

連絡先: 萓谷 勇太, 大阪大学 大学院 情報科学研究科, yuta.kayatani@lab.ime.cmc.osaka-u.ac.jp



図 2: ネットワークモデル図

| 表 2: データ( | の内訳   |
|-----------|-------|
| エピソード数    | 159   |
| 発話数       | 84191 |
| 笑いの割合     | 43.2% |
| 非笑いの割合    | 56.8% |

# 表情

表情に関しては OpenFace を用いて出力された Action Unit の強度情報を使用する. この時,発話終了時点の時 間のフレームだけでなく,「発話終了時点の時間 + 3 秒内 のフレーム」,「発話終了時点の時間 – 3 秒内のフレーム」 を入力としたモデルをそれぞれ構築した. それぞれは,時 系列方向へのマックスプーリングを行うことで 1 次元に 圧縮しこれを使用する. この時,発話者の Action Unit ではなく,その発話の時間において OpenFace により出 力される,信頼度の最も高い登場人物の Action Unit に おいて,マックスプーリングを行う.

#### 3. 実験

#### 3.1 実験設定

本研究では、笑いを予測するタスクのデータセットとして海 外コメディドラマである The Big Bang Theory を使用した. データにおける笑い・非笑いのラベリング方法としては発 話が終わった時間から 1 秒以内の効果音から笑いが検出され た時、笑いが起こった(ラベルを 1)とした.また、データに おける 80%をトレーニングセット、10%をバリデーションセッ ト)、10%をテストセットとした.データの内訳を表 2 に示す. また、モデルのパラメータ設定として、エポック数を 80、 バッチサイズを 32、最適化手法を AdaDelta とした.

#### 3.2 実験結果

字幕のみ・表情のみ・字幕と表情を使用した場合の実験結果 を表3に示す.字幕のみ・表情のみを用いた結果に比べて,字 幕と表情の両方を用いた場合,-3秒,+3秒両方において性

| 表:             | 3: 実験約 | 結果   |      |      |
|----------------|--------|------|------|------|
| 手法             | Acc    | Pre  | Rec  | F    |
| 字幕のみ           | 63.5   | 61.6 | 63.5 | 61.5 |
| 表情のみ           | 62.2   | 55.9 | 62.2 | 51.3 |
| 字幕 + 表情 (-3 秒) | 65.7   | 63.9 | 65.7 | 62.0 |
| 字幕 + 表情 (+3 秒) | 66.1   | 64.5 | 66.2 | 63.1 |

能が向上し,+3秒の時が最も高い性能を達成することができた.この結果から,笑い予測のタスクにおいて字幕だけでなく 表情も組み合わせることは精度の向上において有効であることが確認できた.

#### 3.3 考察

字幕と表情を用いた場合において,+3秒・-3秒の両方について評価を行ったが,+3秒時点の方がモデルの精度が高かったことから,笑い予測のタスクにおいては発話が終了した後の表情が重要であることが認識できる.しかし,予測という観点において,笑いが起こった後の情報を学習に使用することは適切ではないと考えられる.だが,-3秒でのモデルでも性能が向上していることから,表情の組み合わせは有効であり,適切なモデルを選定することでさらなる精度の向上が見込まれる.

# 4. 結論と今後の課題

本論文では,笑い予測のために字幕だけでなく表情を用い たモデルの提案を行った.結果としては字幕だけ,表情だけを 用いたモデルよりも両方を用いたモデルのほうが全ての評価指 標において高い数値を得ることができることを示した.今後の 課題としては,本論文では字幕に付与する情報として表情のみ を扱っているが,他にも発話者の骨格情報や姿勢の情報も使用 することなどが考えられる.

本研究の一部は科研費 No. 18H03264 による。

# 参考文献

- Dario Bertero and Pascale Fung. A long short-term memory framework for predicting humor in dialogues. In NAACL-HLT, pp. 130–135, 2016.
- [2] Paul Ekman. Pictures of facial affect. Consulting Psychologists Press, 1976.
- [3] Tadas Baltrušaitis, Peter Robinson, and Louis-Philippe Morency. Openface: an open source facial behavior analysis toolkit. In WACV, pp. 1–10. IEEE, 2016.
- [4] Jeffrey Pennington, Richard Socher, and Christopher Manning. Glove: Global vectors for word representation. In *EMNLP*, pp. 1532–1543, 2014.

# 自己注意機構を利用したアスペクトベースの感情分析の

日本語文への適用

Application of Aspect-based Sentiment Analysis using Self-Attention Mechanism to Japanese Sentences

> 赤井 龍一<sup>\*1</sup> Ryuichi Akai

渥美 雅保<sup>\*1</sup> Masayasu Atsumi

\*1 創価大学大学院工学研究科情報システム工学専攻 Information Systems Science, Graduate School of Engineering, Soka University

Sentiment analysis is a task to estimate emotions from information such as sentences. As SNSs such as LINE and Twitter which communicate mainly using sentences have developed, technology to estimate emotion from sentence information is increasingly important. In recent years, a method using aspect information has attracted attention as a sentiment analysis method using context information. The aspect-based sentiment analysis is realized in three stages. It categorizes sentences at the first stage, estimates word position which is a concrete description of aspect at the second stage, and outputs the polarity at the last stage. In this research, a neural network-based method using the self-attention mechanism for performing the aspect-based sentiment analysis is applied to Japanese sentences to evaluate its performance in comparison with English sentences.

# 1. はじめに

感情分析は文章などの情報から感情を読み取ろうとするタス クである. LINE や Twitter に代表される,主に文を使ってコミ ュニケーションを行う SNS が発達してきているため,文情報から 感情を読み取る技術が重要性を増している.近年,文脈情報を 利用した感情分析手法として,アスペクト情報を利用した手法が 注目されている[Pontiki 2015]. これら研究では,アスペクトベー スの感情分析は3つのステージに分けて実現されている.最初 のステージで文をアスペクトカテゴリーに分類し,二番目のステ ージで文中のその文のアスペクトを規定する単語の位置の推定 を行い,最後のステージで極性を出力する.本研究では,自己 注意機構を利用して文のアスペクト情報に注意を向けて感情分 析を行うニューラルネットワークベースの手法[Lin 2017]を日本 語文に適用する.そして,日本語文への適用の精度を英語文 に対する適用の精度と比較する.

# 2. 関連研究

# 2.1 アスペクトベースの感情分析

アスペクトベースの感情分析とはアスペクト情報を利用した感 情分析のことである.アスペクト情報とはその文のカテゴリに当 たるものであり,例えば,製品とその属性の組み合わせ等,エン ティティタイプと属性タイプの組み合わせによって定義される. [Pontiki 2015]では 3 つのステージに分けてアスペクトベースの 感情分析を行っている.初めに,あらかじめ設定しておいたアス ペクトのカテゴリに文を分類する(図 1).次に,文とカテゴリ情報 を入力データにしてアスペクトの具体的な記述である単語の位 置を出力する(図 2).最後に,文,カテゴリ,単語の位置を入力 値として極性の値を得る(図 3).この手法を日本語[Kubo 2018] に適用すると 2 番目のステージの精度が他のステージと比べて 低い点が問題である(表 1).そこで本研究では,日本語文の感 情分析に2番目のステージの精度をあげることが期待される [Lin 2017]の手法を適用することによって、3番目の極性の出力 の精度を向上させることを目指す.

表1 アスペクトベースの感情分析のステージごとのF値

|       | 英語   | 日本語  |
|-------|------|------|
| ステージ1 | 0.73 | 0.46 |
| ステージ2 | 0.72 | 0.19 |
| ステージ3 | 0.88 | 0.74 |



図3 極性の出力

連絡先:赤井 龍一, 創価大学大学院工学研究科, 〒192-8577 東京都八王子市丹木町 1-236, Tel: 042-691-2211

# 2.2 自己注意機構

注意機構はエンコーダデコーダモデルでよく使われる手法で ある. 一般的なエンコーダデコーダの注意は,エンコーダの隠 れ層を Source,デコーダの隠れ層を Target として次式によって 表される.

#### attention(Target, Source)

= Softmax(Target ·Source<sup>T</sup>) ·Source これは, Targetを query とみなし, Source を Keyと Value に分 離すると, 次のように表される.

# attention(query, Key, Value)

# = Softmax(query $\cdot$ Key<sup>T</sup>) $\cdot$ Value

このとき、注意は、queryに対して各 keyと各 value が1対1対 応するペアの配列、すなわち辞書オブジェクトから value を取り 出す操作とみなせる.自己注意は、query、key、value がすべて 同じ層から来る場合の注意を指す.

# 3. 日本語文の感情分析実験

### 3.1 実験概要

自己注意機構を使ったニューラルネットワークによる英語文の感情分析の先行研究[Lin 2017]では、文中の単語間の依存 関係を得るために、bidirectional LSTM で文を変換し、各単語 に対応する隠れ層 Hを入力として、その単語に注目 すべき(自 己注意)確率を次式により計算する.

# $a = softmax(w_{s2} tanh(W_{s1}H^T))$

得られる重みベクトル a は文の特定の単語やフレーズに焦点 を当てるものである.そのため,アスペクト情報を与える文脈情 報の抽出が期待できる.文中に複数の構成要素がある場合,特 に長い文の場合は文の異なる部分に焦点を合わせた複数の注 意重みベクトルが必要となる.このとき出力される注意が異なる ように,ペナルティ項を導入して注意の多様性を促進する.最 後に,注意の重み付きで各単語に対応する隠れ層の出力を足 し合わせたものを入力として,全結合層と Softmax 層で文の極 性ラベルの予測を行う.この自己注意機構を用いた感情分析モ デルを日本語文へ適用し,日本語文の感情分析を行った.

#### 3.2 データセット

今回の実験で使用する日本語のデータセットは KNB コーパ ス[橋本 2011]のうち評判情報の感情タグが付いた 492 文である. 学習用データセットとして 392 文, テスト用データセットとして 100 文を使用する.まず文を形態素解析して単語に分解し,単語の 出現頻度順に上位の単語からインデックスを付ける.文頭を表 すインデックスを 1 とした.また,助詞などの付属語のインデック スを 2 とした.そして,その他の単語につけるインデックスは 3 か らとした(表 2).このインデックスを用いて単語を one-hot ベクトル により表現する.ポジティブとネガティブをそれぞれ 1,0として二 値分類を行った.

比較のための英語のデータセットは IMDB という映画レビュ ーサイトのデータセット<sup>1</sup>を使用する. このデータセットは単語の 出現頻度順にインデックスが3から付けられている. 文の初めに インデックス1が付けられ,出現頻度が上位1000位未満の単語 のインデックスには2が付けられている(表 3). そして,日本語の データセットと同じようにポジティブとネガティブが1,0でラベル 付けされている.

表2日本語データセットのインデックス

| インデックス |                    |
|--------|--------------------|
| 0      | Padding            |
| 1      | 文の開始位置             |
| 2      | 助詞などの付属語           |
| 3以降    | インデックスを2にした単語以外の単語 |

#### 表3 IMDB データセットのインデックス

| インデックス |               |
|--------|---------------|
| 0      | Padding       |
| 1      | 文の開始位置        |
| 2      | 出現頻度順が1000位未満 |
| 3以降    | 出現頻度順が1000位以上 |

# 3.3 実験結果と考察

日本語と英語の実験結果として、感情分析の正確度を示す (表4).日本語も英語と同程度の精度を達成している.英語のデ ータセットは学習用とテスト用それぞれ 25000 文ずつあるので、 英語と日本語の差は学習用データセットの量の差であると考え られる.

| 表4感情 | 分析の正確度 |
|------|--------|
| 英語   | 91%    |
| 日本語  | 85%    |

英語文の場合,文にポジティブとネガティブな意味が含まれ る単語が入っているとその単語に注目して正解している.皮肉 やあまり使われない用法で使われた単語が含まれている文は 間違ってしまうことが多かった.日本語文の場合,データセット の量が少ないため出現頻度の少ない単語に注目がいく傾向が あった.

# 4. むすび

本論文では、アスペクトベースの感情分析手法の中のステージ2の精度の向上をはかることを目的に、自己注意機構を利用したニューラルネットワークモデルの日本語文のセンチメント分析への適用について述べた。今後は注意がアスペクト情報にいかに向けられているか確かめて、ネットワークモデルを改良していく、また一文に対しての感情分析だけでなく、1つのレビューなどの文章に対しての感情分析も行いたい。

#### 参考文献

[Pontiki 2015] Maria Pontiki et al: Semeval-2015 Task12: Aspect Based Sentiment Analysis, Semval, 2015.

- [Kubo 2018] Kubo T. and Nakayama H.: chABSA: Aspect Based Sentiment Analysis dataset in Japanese, https://github.com/chakki-works/chABSA-dataset, TIS ,2018.
- [Lin 2017] Zhouhan Lin, et al: A Structured Self-attentive Sentence Embedding, ICLR, 2017.
- [橋本 2011] 橋本 力, et al: 構文・照応・評判情報つきブログコ ーパスの構築, 自然言語処理 Vol.18, pp175-201, 2011

<sup>&</sup>lt;sup>1</sup>: https://www.imdb.com/interfaces/

# 感情強度辞書を利用した日本語ツイートの感情強度の推定 Estimating Emotion Intensities in Japanese Tweets Using Emotion Intensity Lexicon

赤堀 立樹<sup>\*1</sup> Tatsuki Akahori

Kohji Dohsaka

\*1 秋田県立大学 大学院

Graduate School, Akita Prefectural University

堂坂 浩二\*2

伊東 嗣功<sup>\*2</sup> 石井 雅樹<sup>\*2</sup> Hidekatsu Ito Masaki Ishii <sup>\*2</sup> 秋田県立大学

Akita Prefectural University

This paper presents a method for estimating emotion intensities in Japanese tweets using emotion intensity lexicon. We intend to utilize this method to create dialogue systems that can regulate user's emotion. Such dialogue systems can be expected to be useful for maintaining the good mental condition and interpersonal relationships of the users. We first created a crowdsourced emotion intensity lexicon for eight categories of emotion (joy, sadness, anger, fear, trust, disgust, anticipation, surprise), which captures word–emotion intensities using best-worst scaling. To the best of our knowledge, there is no previous works to construct emotion intensity lexicon in Japanese. Then we carried out an experiment to evaluate the effect of the emotion intensity lexicon in the estimation of emotion intensities in Japanese tweets. The experimental results show that the emotion intensity lexicon can improve the accuracy of estimating emotion intensities in tweets.

# 1. はじめに

対話システムには、ユーザとの対話を通して道案内や予約な ど特定のタスクを遂行するタスク指向型対話システムと、雑談な どコミュニケーション自身を目的とする非タスク指向型対話シス テム(雑談対話システムとも呼ぶ)があり [中野 2015]、近年は雑 談対話システムの研究が盛んに行われている.人間同士の雑 談において、対話参加者は相手の感情を考慮し、相手の感情 を調整(促進・維持・抑制)しながら対話に従事する.例えば、悲 しんでいる人に対して慰める発話をすることにより、相手の「悲し み」を和らげたり、「喜び」の感情をもっている人に対して賞賛や 共感するような発話をすることにより、相手の「喜び」を促進する. 雑談対話システムにおいても、ユーザの感情を考慮し、ユーザ の感情を調節することができれば、ユーザの良好な心身状態や 対人関係の維持、また感情調節困難な方の支援に貢献できる ことが期待される.

ユーザの感情を調節する対話システムを構築するためには, ユーザの感情強度やその変化を測定することが必要である.感 情強度の推定に関する研究は盛んになりつつあり, WASSA-2017 [Mohammad 2017]や SemEval 2018:Task 1 Affect in Tweets [Mohammad 2018a] では, 4 感情 (anger, sadness, fear, joy) を対象として, Twitter における英語ツイートの感情強度を 推定するタスクが設定されており, 様々な手法が提案されている. これらの研究は英語の感情強度推定が目的であるが, その一 方, 佐藤らは日本語ツイートの感情強度を推定する手法を提案 している [佐藤 2018].

ツイートの感情強度推定のためには、感情辞書が重要な役割を果たす.英語の感情強度推定の場合、英語の言語表現に対して感情強度を付与した感情強度辞書 [Mohammad 2018b] が利用されている.日本語の感情辞書としては、日本語表現を10種類の感情に分類した感情表現辞典 [中村 1993] や単語に感情極性 (positive・negative) の値を実数値 [-1.0, 1.0]で付与した単語感情極性対応表 [高村 2006] などがあるが、管見の限りでは日本語の感情強度辞書は構築されてこなかった.

そこで,本研究では,日本語の感情強度辞書を構築し,感情

表 1. 感情分類

| Plutchik の 8 感情分類 | 中村の10感情分類           |
|-------------------|---------------------|
| 喜び                | 喜                   |
| 受容                | 好·安                 |
| 嫌悪                | 厭                   |
| 悲しみ               | 哀                   |
| 怒り                | 怒                   |
| 恐れ                | 怖                   |
| 予期                | NRC-Emotion-Lexicon |
| 驚き                | 驁                   |

強度辞書を用いた日本語ツイートの感情強度の推定法を評価 することを目的とする.以下において,第2節で日本語感情辞 書の構築について説明する.第3節で感情強度辞書を使った 日本語ツイートの感情強度推定の評価実験について述べ,第 4節で実験結果について考察する.

# 2. 日本語感情強度辞書の構築

本研究では,まず,感情強度辞書に登録する感情表現を収 集する.その感情表現の強度を数値化し,感情強度辞書を構 築する.

# 2.1 感情表現の収集

本研究では、中村の「感情表現辞典」[中村 1993]から感情 カテゴリ(喜,好,安,厭,哀,怒,怖,驚,恥,昂)ごとに感情表現を収集 し、中村の10分類をPlutchik [Plutchik 2001]の8分類(喜び、 受容,嫌悪,悲しみ,怒り,恐れ,予期,驚き)に再分類した.再分 類は他研究との比較や応用しやすくするためである.表1に再 分類の振り分けを示す.ここで、中村の感情分類の「好」と「昂」 は、他の複数の感情に分類できるため、適宜分類した.例えば、 「昂」の「飛び上がる」や「踊る」などは「喜び」に分類し、「熱り立 つ」や「怒り狂う」は「怒り」に分類した.また、Plutchikの感情分 類の「予期」は中村の感情分類には該当する感情がないため、 Plutchikの感情分類に対応する言語表現を人手により収集した

連絡先:堂坂浩二,秋田県立大学 システム科学技術学部 情報工学科, dohsaka@akita-pu.ac.jp

| The 33rd Annual Confe | erence of the Japane | ese Society for Artificia | l Intelligence, 2019 |
|-----------------------|----------------------|---------------------------|----------------------|
|-----------------------|----------------------|---------------------------|----------------------|

| 衣 2. 感情衣現 BWS 結果(喜い, 文谷, 嫌悪, 悲し | レみ | .) |
|---------------------------------|----|----|
|---------------------------------|----|----|

| 喜                | び     | 受        | 容     | 嫌          | 悪     | 悲し              | み     |
|------------------|-------|----------|-------|------------|-------|-----------------|-------|
| 嬉し泣<br>き         | 0.979 | 信頼<br>する | 0.944 | 反吐が<br>出る  | 0.924 | 悲痛な<br>叫び       | 1.000 |
| 歓喜               | 0.974 | 敬愛<br>する | 0.875 | 目障り        | 0.905 | 咽び<br>泣き        | 0.984 |
| 天にも<br>上る気<br>持ち | 0.974 | 相思<br>相愛 | 0.854 | 生理的<br>に無理 | 0.896 | 泣き崩<br>れる       | 0.923 |
| 大喜<br>び          | 0.970 | 信仰<br>する | 0.854 | 殺意を<br>抱く  | 0.894 | 泣き叫<br>ぶ        | 0.875 |
| 狂喜               | 0.917 | 尊ぶ       | 0.852 | 吐き気<br>がする | 0.875 | 見るの<br>もつら<br>い | 0.875 |
| :                | :     | :        | :     | :          | : 2   | :               | :     |
| おかし<br>い         | 0.119 | ゆるゆ<br>る | 0.143 | 羨まし<br>い   | 0.167 | しける             | 0.109 |
| 笑                | 0.119 | のどか      | 0.119 | 困惑         | 0.146 | くすん<br>くすん      | 0.078 |
| 気軽               | 0.095 | 無事       | 0.111 | 残念に<br>思う  | 0.125 | デメリ<br>ット       | 0.047 |
| 吉                | 0.083 | ふかふ<br>か | 0.104 | 無念         | 0.095 | 苦手              | 0.042 |
| クスク<br>ス         | 0.083 | ゆった<br>り | 0.097 | 可哀想        | 0.000 | ガーン             | 0.000 |

NRC-Emotion-Lexicon [Mohammad 2013] を日本語に翻訳した 表現集を使った.

次に、多様な表現を収集するために、収集した感情表現の類 語を収集した.すべての感情表現の類語を収集するのは、コストがかかるため、Twitter APIを使って2017年3月から2018年 9月までの間に収集した約2000万ツイートの上で出現回数を 調べ、感情カテゴリごとに出現回数上位30語程度の感情表現 の類語を収集することとした.類語の収集にはWeblio類語辞 典<sup>1</sup>を使用した.類語の収集の際には、明らかに感情表現と意味合いが異なる類語は除外した(例:「怒り」の感情表現「雷」から 稲妻・電光などの類語は収集しない).類語を持たない語(例:爆発する)も除いた.類似した類語(例:激怒,憤怒,憤慨)は1つを 残して除いた.最後に、類語を含めた感情表現の出現回数を 再度調べ、出現回数1回以上の語を抽出した.

2.2 節で説明するように、本研究では、Best-Worst Scaling (BWS) [Louviere 1991]を用いて、感情表現に感情強度を付与 する. BWS は相対評価法であるため、感情強度に極端な偏り があると適切に算出できない. そのため、抽出した感情表現の 強さを手動で 3 段階に分類し、収集した感情表現の強度に極端な偏りがないことを確認した. 感情強度の 3 段階の分類は、 筆者の一人が各表現に対して 0~100の実数値を付与すること によって行った. 3 段階は大(68~100)、中(34~67)、小(0~33) とした. 以上の結果、1051 語の感情表現を収集した.

# 2.2 感情表現の強度の数値化

2.1 で収集した各感情表現に対して BWS によって感情強度 を数値化した. BWS は Mohammad らの手法 [Mohammad

| 表 3. 感情表現 BWS 結果(怒り, 怂 | れ,于期,驚る | Ĕ) |
|------------------------|---------|----|
|------------------------|---------|----|

| -          |       |                         |       |            |       |                 |       |
|------------|-------|-------------------------|-------|------------|-------|-----------------|-------|
| 怒り         |       | 恐れ                      |       | 予期         |       | 驚き              |       |
| ぶっ殺<br>す   | 1.000 | 戦慄                      | 0.938 | 予兆         | 0.938 | 言葉が<br>出ない      | 0.929 |
| 殺す         | 0.984 | 叫喚                      | 0.938 | 予測<br>する   | 0.917 | 言葉を<br>失った      | 0.881 |
| 殺意         | 0.911 | 阿鼻<br>叫喚                | 0.913 | 兆候         | 0.917 | 想像を<br>絶する      | 0.871 |
| 怒鳴り<br>散らす | 0.909 | 生きた<br>心地が<br>しなか<br>った | 0.859 | 兆し         | 0.905 | 夢にも<br>思わな<br>い | 0.854 |
| 怒り狂<br>う   | 0.900 | 畏怖                      | 0.859 | 予想<br>する   | 0.833 | <b>驚愕す</b><br>る | 0.833 |
| :          | ÷     | :                       | ÷     | ÷          | ÷     | ÷               | ÷     |
| 頬を膨<br>らます | 0.141 | 渋る                      | 0.125 | 宿命         | 0.208 | ビクビク            | 0.185 |
| くしやく<br>しや | 0.141 | 決めか<br>ねる               | 0.113 | 釈然と<br>しない | 0.208 | 認めら<br>れない      | 0.167 |
| つまら<br>ん   | 0.125 | 期待で<br>きない              | 0.094 | 理想         | 0.200 | たまたま            | 0.042 |
| ふくれ<br>っ面  | 0.089 | 気遣い                     | 0.094 | 大志         | 0.167 | うっとり            | 0.042 |
| つまら<br>ない  | 0.075 | 堂々<br>巡り                | 0.094 | ドリー<br>ム   | 0.167 | はわわ             | 0.024 |

2018b] を参考に行った. 感情カテゴリごとに 4 人の作業者に 2 ×N(N は感情表現数)の質問に回答してもらった. 各質問では, 特定の感情カテゴリに属する 4 つの感情表現が与え, 最も感情を強く感じる感情表現 (Best) と最も感情を弱く感じる感情表現 (Worst) の 2 つを回答することを求めた. このとき, Best と Worst は異なる感情表現を選択してもらった. 各感情表現は 2×N の 質問中に異なる質問で 8 回出現し, 同一の選択肢の質問は現 れないようにした. 感情表現 e の感情強度の値は次の式によっ て計算する.

$$\frac{P_{Best}(e) - P_{Worst}(e) + 1}{2}$$

このとき, *P<sub>Best</sub>(e)*, *P<sub>Worst</sub>(e)*は感情表現 e がそれぞれ Best, Worst に選択された確率である. *P<sub>Best</sub>(e)*, *P<sub>Worst</sub>(e)*の値域は [0, 1] であり, *P<sub>Best</sub>(e)* ー*P<sub>Worst</sub>(e)*の値域は [-1, 1] となる. 本研究で は値域を [0, 1] とするために線形変換を行う. 感情強度は値が 1 に近いほど強い感情を示し, 0 に近いほど弱い感情を示す.

BWS はクラウドソーシング Lancers を使って実施した. 作業の 質を確保するために全質問の 5%の質問を回答が明らかに一 意に定まる質問 (gold question) として設定し, gold question の 正解率が 70%未満の作業者の回答は使用しなかった. gold question は, BWS の作業者とは別の 2 名の作業者に感情強度 「大」「小」からそれぞれ1つと「中」から2 つから成る質問に対し て BWS と同様に回答してもらい, 2 人の回答が一致した回答の 中から作成した.

BWS は単一の質問で複数の項目間の順序関係を得られる ため, 簡便かつ有効な評価方法であると考えられる.表2,3 に 各感情の感情強度の値が上位と下位それぞれ5つずつの結 果を示す.

<sup>&</sup>lt;sup>1</sup> https://thesaurus.weblio.jp

# 2.3 感情強度辞書に関する考察

2.2節の方法によりで、1051 語からなる感情強度辞書の作成 を行った.感情強度の値は概ね直感と一致する結果となったが、 予期の感情では一部直感とは異なる結果が見られた.

予期の感情では、感情強度が高いと考えられる「期待」、「宿 命」、「理想」といったの表現が強度 0.67 以下の中・下位に入っ た.一方、感情強度が低いと考えられる「知らせ」や「見込み」な どの表現が、感情強度 0.67 以上の高位に入った.このようにな った要因として、作業者が「予期」の感情の意味を限定的に捉 えた可能性がある.予期の感情には「予想」、「知らせ」、「見込 み」といった未来の予見や未知の情報を表す表現の他に、「宿 命」といった決まった未来を表す表現や、「期待」、「理想」といっ た希望・意図を表す表現がある.作業者は予期の感情について、 未来の予想や未知の情報を表す意味に限定して考えたため、 その他の意味を表す表現の強度が相対的に低くなった可能性 がある.

# 3. ツイートの感情強度の推定と評価

#### 3.1 感情強度辞書を使った感情強度推定方法

本研究では、感情強度辞書を使ったツイートの感情強度推 定法の開発の第一歩として、簡易な方法により感情強度の推定 を行い、感情表現辞書の効果について考察する.

前提として、ツイートの感情分類が成されているものとした.また、感情強度辞書に登録された感情表現を含むツイートを対象 とした.ツイート中に含まれる否定や仮定、強調表現(!!、オオオ オオオなど)は考慮しなかった.

ツイートの感情強度の推定は、感情強度辞書を用いて、ツイートに含まれる感情表現を手がかりとして行う.ツイートには複数の感情表現が含まれる場合もあるため、以下に示す、First、Last, Averageの3つの方法と、ランダムに感情強度値を生成する方法の計4つの手法により推定を行う.各推定方法について以下に示す.

- First:ツイート中で最初に現れた感情表現の感情強度値 をツイートの感情強度値とする
- Last: ツイート中で最後に現れた感情表現の感情強度値 をツイートの感情強度値とする
- Average: ツイート中の感情表現の感情強度値の平均をツ イートの感情強度値とする
- Random: ランダムに感情強度値を生成し、ツイートの感情 強度値とする

#### 3.2 評価実験

感情強度辞書を使ったツイートの感情強度推定の評価実験 を行った. 評価の対象となるツイートは「喜び」と「悲しみ」の感情 に事前に分類された各 50 ツイートとした. ツイートの感情強度 値の正解データを作成する作業者の負担を考慮して, ツイート は 20~50 文字程度のツイートのみを使用した.

ツイートの感情強度値の正解データ(測定値)を作成するため、事前に 3.1 節と同様の手順によりツイートの感情強度値を BWS により測定した. gold question の正解率が 70%の作業者のBWSの結果を使用し、正解データを作成した.

評価は,各方法により推定された感情強度値を大(0.67~1),中(0.33~0.67),小(0~0.33)の3段階への分類した際の正解率を使って行った.

表 4,5 にツイートの感情強度推定の評価結果を示す.「喜び」の感情では、最初の感情表現の感情強度をツイートの感情

表 4. ツイートの感情強度推定評価結果(「喜び」)

|            | 小   | 中   | 大   | 全体  |
|------------|-----|-----|-----|-----|
| a) First   | 60% | 59% | 69% | 62% |
| b) Last    | 56% | 50% | 56% | 54% |
| c) Average | 60% | 55% | 60% | 58% |
| d) Random  | 27% | 48% | 26% | 34% |

表 5. ツイートの感情強度推定評価結果(「悲しみ」)

|            | 小   | 中   | 大   | 全体  |
|------------|-----|-----|-----|-----|
| a) First   | 37% | 56% | 54% | 48% |
| b) Last    | 44% | 56% | 50% | 50% |
| c) Average | 44% | 57% | 54% | 52% |
| d) Random  | 30% | 47% | 29% | 35% |

強度にする手法が正解率 62%で最も高い結果となった.また「悲しみ」の感情では、ツイート中の感情表現の感情強度の平均をツイートの感情強度とする手法が正解率 52%で最も高い結果となった.感情で評価結果を比較すると、「喜び」の感情のほうが全体的に高い正解率となった.

#### 4. 考察

「喜び」の感情強度推定は 60%程度,「悲しみ」の感情強度 推定は 50%程度の正解率となった. Random との比較ではある が,感情強度辞書は一定の効果があると言える.「喜び」の感情 の方が全体的に高い正解率となったが,作業者の感想から, 「喜び」の感情に比べて「悲しみ」の感情は,感情表現の感情強 度よりも,ツイート内容や顔文字の種類に影響されやすいことが 考えられる. そのためツイートに含まれる感情表現のみを手が かりとする推定方法では「喜び」の感情の正解率が高くなったこ とが考えられる

表 6,7 にそれぞれ「喜び」と「悲しみ」の感情強度推定が不 正解となった場合の特徴的な例を示す.測定値とは,3.2 節で 述べたように,事前に作業者の BWS により測定した感情強度 の正解値である.推定値とは,感情強度辞書を使ってツイート の感情強度を推定した値である.「喜び」の場合は方法 First, 「悲しみ」の場合は方法 Average による推定値である.

まず,表 6の「喜び」の場合,特徴的な例として,文中に否定 を含む場合,辞書に含まれない感情を表す表現を含む場合, 強調表現を多用している場合があった.まず,文中に否定を含 む例として,表 6のツイート番号 13 では,釣りに行ったが釣れ なかったという否定内容が含まれていた.否定的な表現の影響

表 6. 感情強度推定の不正解例(喜び)

| ツイ<br>ート<br>番号 | ツイート内容   | 測定<br>値 | 推定<br>値 |
|----------------|--|---------|---------|
| 13             | 初めてうなぎつりやった てか、<br>昨晩は鯉つり w ミナミの釣り堀<br>~ 釣れんかったけど w 久々に<br>糸垂らして恍惚としてたよ                  | 0.271   | 0.771   |
| 18             | デザフェス当選した!!ヤッタ<br>ー!!!!!   | 0.875   | 0.667   |
| 26             | 念願の!!!チュロス(。・・・。)♡こ<br>のベリーソース神ってる!! 店員<br>のお姉さんと、少しお話もして、<br>充実した朝時間になりましたヾ<br>(●´▽`●)/ | 0.833   | 0.563   |

により、感情強度の測定値の方が、否定を考慮せずに推定された推定値よりも低くなったと考えられる.

ツイート番号 26 は、感情強度辞書に含まれていない感情表 現を含む例である.「念願」や「神ってる」は辞書に含まれていな いため、測定値の方が推定値よりも高くなったと考えられる.

ツイート番号 18 は強調表現「!!」を多用している例である.また,ツイート自体が短いため,強調表現による影響を受けやすい可能性がある.そのため,測定値の方が推定値よりも高い結果となったと考えられる.

表 7 に示す「悲しみ」の場合,不正解となった要因としては, 顔文字の使用,ツイート内容,辞書に含まれない感情表現によ る影響が考えられる.まず,顔文字とツイート内容について考察 する.表 7 のツイート番号 1 では感情強度の強い感情表現「咽 び泣く」を使用しているが,ツイート内容または顔文字の影響に より,悲しみの感情が弱く感じられたため,測定値が推定値より 小さくなったと考えられる.一方,ツイート番号 12,28,32 では, 測定値が推定値よりも高くなっており,顔文字が感情強度を高 めている可能性がある.また,ツイート番号 36,42,45 でも,測 定値が推定値よりも 0.2 程度高くなっているが,これらのツイート は,ツイートの内容の影響を受け,含まれる感情表現の感情強 度値より高い測定値になった可能性がある.

次に、感情強度辞書に含まれない感情表現による影響について考察する. その例として表 17 のツイート番号 15,47 がある. 特にツイート番号 15 では、「阪神淡路大震災」がツイートに含まれている. 現在作成した感情強度辞書は主に形容詞と動詞によって構成されている. 今後は、感情強度値を付与した名詞を 増やすことで推定性能が向上する可能性がある.

# 5. おわりに

本研究では、中村の「感情表現辞典」を基に類語の収集を行 い、BWSにより感情強度を測定し、1051 語からなる感情強度辞 書を作成した. 概ね直感と一致する辞書の作成を行うことができ たが、予期の感情では一部直観と異なる結果となった. 例として、 予期の感情では、未来の予見や未知の情報を表す表現が上位 の感情強度となり、決まった未来や希望・意図を表す表現が中・ 下位の感情強度となった. 要因としては、作業者が予期の感情 を未来の予想や未知の情報に限定して捉えたため、その他の 意味をもつ表現の強度が相対的に低くなったと考えられる. 感 情強度辞書を使ったツイートの感情強度推定では喜び、悲しみ ともに 50~60%の正解率となった. 感情強度辞書は一定の効 果があることが示唆された.

今後の課題としては、感情強度値付きの大量のツイートから の学習による感情強度推定の性能向上、感情表現を含まない ツイートの感情強度の推定が考えられる.また、名詞への感情 強度値の付与や、否定や強調表現などを考慮した感情強度推 定を行うことを検討する.

# 謝辞

本研究は科研費(16K00355)の助成を受けたものである.

# 参考文献

[Louviere 1991] Jordan J. Louviere: Best-worst scaling: A model for the largest difference judgments, Working Paper, 1991. [Mohammad 2013] Saif M. Mohammad and Peter Turney: Crowdsourcing a Word-Emotion Association Lexicon, Computational Intelligence, Vol.29, No.3, pp.436-465, 2013. [Mohammad 2017] Saif M. Mohammad and Felipe Bravo-Marquez: WASSA-2017 shared task on emotion intensity. In:

表 7. 感情強度推定の不正解例(悲しみ)

| ツ イ<br>ー ト<br>番号 | ツイート内容   | 測定<br>値 | 推定<br>値 |
|------------------|--|---------|---------|
| 1                | なによりあのぱっちりお目目と<br>色白の肌とすっとんとんの髪が<br>手に入るかと思うと色黒一重天<br>然パーマな私は咽び泣きま<br>すヽ(;▽;)ノ                   | 0.396   | 0.984   |
| 12               | まじっすか(´・ω・III)寂しい<br>ですやっぱ心痛みます<br>…(´;ω;`)  | 0.708   | 0.589   |
| 15               | 阪神淡路大震災から 23 年。<br>被害に遭われた方々へ 哀悼<br>の意を表します。この日を決し<br>て忘れません                                     | 0.771   | 0.672   |
| 28               | 災害よりもモリ・カケ、ですか。<br>情けない・ <sup>°</sup> ・(ノ Д <sup>`</sup> )・ <sup>°</sup> ・                       | 0.646   | 0.516   |
| 32               | ミク、コヒメが卒業発表するシー<br>ンでコヒメから貰い泣きしてしも<br>た(;_;)無理いいい(;_;)   | 0.625   | 0.406   |
| 36               | 家で珈琲を入れるときにフレン<br>チプレスってのでいれてるんで<br>すけど、うっかりフィルターの紙<br>を入れるの忘れてた時があっ<br>て、朝からがっくりしたことなら<br>あります… | 0.500   | 0.328   |
| 42               | 昔絡んでた方々は見えないとこ<br>ろに行ってしまったよ(しんみり)   | 0.542   | 0.313   |
| 45               | 職場の人で「自分がやられて嫌<br>なことを、自分は他の人にする<br>派」がいてしょげる  | 0.500   | 0.268   |
| 47               | 自分の無知さを恥じる   | 0.583   | 0.234   |

Proc. the Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis, 2017.

[Mohammad 2018a] Saif M. Mohammad, Felipe Bravo-Marquez, Mohammad Salameh and Svetlana Kiritchenko: SemEval-2018 Task 1: Affect in Tweets, In: Proc. the 12th International Workshop on Semantic Evaluation, pp.1-17, 2018.

[Mohammad 2018b] Saif M. Mohammad: Word Affect Intensities, In Proc. LREC-2018, 2018.

[中村 1993] 中村明:感情表現辞典,東京堂出版,1993.

[中野 2015] 中野幹生, 駒谷和範, 船越孝太郎, 中野有紀子, 奥 村学 (監修): 対話システム, コロナ社, 2015.

[Plutchik 2001] Robert Plutchik: The nature of emotions, American Scientist, Vol.89, No.4, pp.344-350, 2001.

[佐藤 2018] 佐藤一輝, 尾崎知伸: 複数の表現学習手法を用いた日本語ツイートの感情強度推定, 人工知能学会研究会資料, SIG-KBS-B802-02, 2018.

[高村 2006] 高村大也, 乾孝司, 奥村学: スピンモデルによる単 語の感情極性抽出, 情報処理学会論文誌ジャーナル, Vol.47, No.2, pp. 627-637, 2006.

# 新聞記事中の地名に対する地理的位置推定における 有効な素性の調査

An Investigation of Effective Features for Toponym Resolution of Words in Newspaper Articles

| 関 龍 * <sup>1</sup> | 乾 孝司 *1      |
|--------------------|--------------|
| Ryo Seki           | Takashi Inui |

\*<sup>1</sup>筑波大学大学院システム情報工学研究科 Graduate School of System and Information Engineering, University of Tsukuba

In this paper, we investigate which features are efficient on toponym resolution of words in newspaper articles. Speriosu's TRIPDL algorithm are used in the investigation, and an extension version of TRIPLD is also used to diminish data sparseness problem. We focus on nouns and four types of named entity classes (ORGANIZATION, PERSON, LOCATION, and ARTIFACT), which are used in standard named entity recognition task. Through the experiments, it turns out that using only LOCATION words achieves better performance in terms of both accuracy and computational complexity.

# 1. はじめに

近年, SNS などの様々なサービスが普及し,人々が気軽に 情報を発信できる時代になってきている.これら発信された文 書内にある,場所を示す表現と実世界上での地理的位置を結 びつけたいというニーズが存在する.SNSの代表とも言える Twitter では投稿時の位置情報をつぶやきに付与することが可 能であるが,Middletonら[1]によればこの機能を利用してい るものは全体の1%にも及ばない.文書内の表現に対して実世 界上でのその地理的位置が同定できれば,特定区画に対象を限 定したテキストベースの社会分析などがこれまで以上に高精 度・高被覆で実現できるようになる.

文書内の場所を示す単語と実世界での地理的位置を結びつ けるには様々な問題があるが、その中でも場所を示す単語の曖 昧性の問題がある [2].曖昧性とは例えば、「中央区」という単 語があった場合に、日本に数ある中央区のうちのどの位置を実 際に参照しているのかわからない状況のことである.実際に日 本には数多くの中央区が存在するが、簡単のため「大阪市中央 区」と「東京都中央区」に絞った例を図1に示す.この地理的 位置推定の研究は以前から行われており、どのように場所を示 す単語の曖昧性を解消するかの方法には様々な手法が提案され てきた.文書レベルでの地理的位置推定や単語レベルでの地理 的位置推定、教師データの有無などによって手法は異なるが、 本研究では単語レベルかつ教師データを用いる地理的位置推定 について検討する.

ー般にこの地理的位置推定のタスクではデータに SNS デー タが用いられることが多い. Lianhua ら [3] はデータに Twitter を用い,地理的位置推定には地名やハッシュタグ,メンション の情報が有効であることを示した.本研究ではデータに新聞記 事を利用するときに,どのような素性,特にどの固有表現が地 理的位置推定に有効なのか調査する.

本論文では文書中に表れる実世界上の地理的位置を指す単 語を「地名」と呼び,その地名に対応する可能性のある実世界 上の住所を「候補地」あるいは単に「候補」と呼ぶ.

# 2. 関連研究

文書中の地名と実世界上の位置を関連付ける研究は数多く行われてきたが、問題設定の違いにより場合分けを行うことができる.まず、文書中に出現する「地名」つまり単語を位置と結



図 1: 中央区に対する曖昧性

びつけるタスクを toponym resolution と呼ぶ.次に「文書」の 記述内容を位置と結びつけるタスクを document geolocation と呼ぶ.また,ある「ユーザ」と関連付けられた文書集合と位 置を結びつけるタスクを user geolocation と呼ぶ.この分類 に従うと、本研究は toponym resolution に該当する.

Speriosu は TRIPDL[4] を提案した. この手法は実世界を セルで区分けし,それらと文書との対応付けを行っている.入 力文書の単語確率分布と学習済みのセルの単語確率分布間の KL ダイバージェンスを測り,より近いセルを出力とする方法 である.本研究ではベース手法として TRIPDL を採用する. 手法の詳細については 5.章で述べる.

オリジナルの TRIPDL の問題設定は document geolocation であり,実世界上の位置にはセル(地理的位置を格子状に区 切った領域)を採用している.セルを採用している理由として は入手が簡単,扱いもしやすいという点が挙げられる.まず, 場所に対する経度緯度情報さえあれば場所とそれに対応する セルがすぐに関連付けできるから入手が簡単であるといえる. また,セルとは地図を正規化したものであるとも言え,複雑な 地形などもすべて格子状に落とし込むことができるため扱いや すいといえる.しかし,本研究ではセルは使用せず,行政地区 を使用する.行政地区を使用するメリットとしては非常に出力 が直感的で他の用途に使いやすい点が挙げられる.例えばラベ ル付けを考えた場合,ある曖昧性のある地名に対して出力がセ ルだとなんの情報かわかりにくいが,出力が行政地区の場合は ラベル付けもしやすく,見る側にとってもわかりやすい.

| 11. 4  | LT.L.D.W. | 171-P -          |                 |                  |
|--------|-----------|------------------|-----------------|------------------|
| 地名     | 候俌奴       | 候補 1             | 候補 2            | •••              |
| 松屋町    | 8         | 岐阜県_岐阜市_松屋町      | 京都府_京都市_下京区_松屋町 | 京都府_京都市_上京区_松屋町  |
|        |           | 京都府_京都市_中京区_松屋町  | 京都府_京都市_伏見区_松屋町 | 大阪府_寝屋川市_松屋町     |
|        |           | 大阪府_大阪市_中央区_松屋町  | 香川県_丸亀市_松屋町     |                  |
| 本田     | 7 7       | <br>  山形県_鶴岡市_本田 | 埼玉県_深谷市_本田      | 「埼玉県」南埼玉郡」宮代町」本田 |
|        |           | 新潟県_新発田市_本田      | 富山県_射水市_本田      | 岐阜県_瑞穂市_本田       |
|        |           | 大阪府_大阪市_西区_本田    |                 |                  |
| <br>亀田 | 3         | 福島県_郡山市_亀田       |                 | 新潟県_新潟市_江南区_亀田   |
|        | 2         | 神奈川県_横浜市_旭区      | 大阪府_大阪市_旭区      |                  |
| 「パルプ町」 | 1         | -北海道_旭川市_パルプ町    |                 |                  |
| <br>芝浦 | 1         | 東京都_港区_芝浦        |                 |                  |

#### 表 1: 住所 DB の形式

# 3. コーパス

本研究で使用するコーパスは拡張固有表現タグ付きコーパス ス[5]の毎日新聞ジャンルである.このコーパスには固有表現 として様々なタグが付与されているが、本論文では地名を扱う ためタグは City タグのみを利用する.このコーパスに存在す る事例数,つまり曖昧性を解決すべき地名の数はのべ1723,異 なりで373 である.また異なりで曖昧性を解決すべき地名の 平均候補数は10 である.曖昧性の定義は4.章で説明する.

# 4. 住所データベース

本研究では候補の情報を得るために住所データベース(以降,住所DB)を参照する.住所DBとは日本中全ての住所を 含んだデータベースであり,実世界上の住所と一致していなく てはならない.しかし,住所は市区町村の合併などにより流動 性をもったものであるから必ずしも住所DBと実際の住所が 合致しているとは限らない.本論文では住所DBのおおもと のデータとして国土交通省の発行している「街区レベル位置参 照情報」\*1を利用した.今回使用するこのデータのサンプリン グは 2016 年である.

本論文では一つの地名 t に対してどのような候補が存在し ているのかを知りたいため、上記データに前処理を施し、表 1 の形式のデータを得た.例えば、地名「パルプ町」の場合、こ の名前をもつ地理的位置は北海道に 1 地点存在するだけである ので曖昧性がない.一方、「旭区」は 2 地点存在するため曖昧 性の解消が必要である.なお、候補は都道府県名からの住所を 含んでいるため候補間に曖昧性はない.住所 DB のエントリ 数は 152,937 である.この内、候補数が 2 以上になる(曖昧 性がある)エントリの割合は約 5%であり、これらエントリに おける平均候補数は 4.49 である.

#### 5. TRIPDL

本研究のベース手法である TRIPDL について述べる.まず 文書  $d_k$  中にあらわれる単語  $w_j$  の生起確率  $\tilde{\theta}_{d_{kj}}$  を計算する. 式 (1) が求める式である.

$$\tilde{\theta}_{d_{kj}} = \frac{\#(w_j, d_k)}{\sum\limits_{w_l \in V} \#(w_l, d_k)} \tag{1}$$

 $\hat{\theta}_{d_{kj}}$  は実際に訓練データから計算する単語の生起確率だが 訓練データが少ない場合に、この値だけでは多くの単語の生 起確率が 0 となってしまうためスムージングを施した  $\theta_{d_{kj}}$  を 考える.このスムージングは good-turing 推定の考え方に基 づく.まず、係数となる  $\alpha_{d_k}$  を求めるために式 (2) を計算する.これは文書  $d_k$ 中に一度だけ出現した単語  $w_j$ の生起確率である.

$$\alpha_{d_k} = \frac{|w_j \in Vs.t.\#(w_j, d_k) = 1|}{\sum_{w_j \in V} \#(w_j, d_k)}$$
(2)

次に単語の生起確率  $\tilde{\theta}_{d_{kj}}$  が 0 のときに使用する値  $\theta_{D_j}^{(-d_k)}$  で ある. その式が式 (3) である. なお,式 (3) で使用している  $\theta_{D_j}$  は使用する全ての文書集合 D における単語  $w_j$  の生起確 率である.

$$\theta_{D_j}^{(-d_k)} = \frac{\theta_{D_j}}{1 - \sum_{w_l \in d_k} \theta_{D_l}} \tag{3}$$

最後に式 (2) と式 (3) を用いて求めた  $\theta_{d_{ki}}$  である.

$$\theta_{d_{kj}} = \begin{cases} \alpha_{d_k} \theta_{D_j}^{(-d_k)}, & \text{if } \tilde{\theta}_{d_{kj}} = 0\\ (1 - \alpha_{d_k}) \tilde{\theta}_{d_{kj}}, \text{ o.w.} \end{cases}$$
(4)

セル  $c_i$  中にあらわれる単語  $w_j$  の生起確率  $\theta_{c_{ij}}$  について求 める.まず以下の式 (5) を計算し,訓練データにおけるセル中 にあらわれる単語の生起確率  $\tilde{\theta}_{c_{ij}}$  を求める.

$$\tilde{\theta}_{c_{ij}} = \frac{\sum_{d_k \in c_i} \#(w_j, d_k)}{\sum_{d_k \in c_i} \sum_{w_l \in V} \#(w_l, d_k)}$$
(5)

この後の処理は式 (2) から (4) と同様に行う.それが式 (6) から式 (8) である.

$$\alpha_{c_i} = \frac{|w_j \in Vs.t.\#(w_j, c_i) = 1|}{\sum_{w_j \in V} \#(w_j, c_i)}$$
(6)

$$\theta_{C_j}^{(-c_i)} = \frac{\theta_{C_j}}{1 - \sum_{w_l \in c_i} \theta_{C_l}} \tag{7}$$

$$\theta_{c_{ij}} = \begin{cases} \alpha_{c_i} \theta_{C_j}^{(-c_i)}, & \text{if } \tilde{\theta}_{c_{ij}} = 0\\ (1 - \alpha_{c_i}) \tilde{\theta}_{c_{ij}}, \text{o.w.} \end{cases}$$
(8)

式 (4) と式 (8) から文書中とセル中における単語の生起確率 が求められたので、最後に入力文書  $d_k$  がどの候補セル  $c_i$  と 最も KL 距離が近いかを求めそのセルが出力  $\hat{c}$  となる. つま り式 (9) となる.

<sup>\*1</sup> http://nlftp.mlit.go.jp/isj/index.html

$$\hat{c} = \arg\min_{c_i \in C_{d_k}} KL(\theta_{dk} || \theta_{ci})$$
(9)

$$= \arg\min_{c_i \in C_{d_k}} \sum_{w_j \in V_{dk}} \theta_{dkj} log \frac{\theta_{dkj}}{\theta_{cij}}$$
(10)

候補 *c*<sub>i</sub> は住所 DB のエントリ数だけあり,その数は非常に 多い.そのため,疎データの状態に陥りやすい.

# 6. 拡張手法

5. 章に示した TRIPDL を 2. 章で述べたようにセルでなく 行政地区を用いて実装する場合,ある 1 文書に対応する可能 性のある候補は 4. 章より,いくつかの候補住所に一意に決ま る. TRIPDL ではこれらの候補住所(セル)の単語確率分布 は教師がある限り必ず 1 つはあるが,今回の設定では「いく つかの」候補住所に絞られているので,どの候補住所も単語確 率分布を持たない可能性がある.その場合は候補間の確率分布 がない,つまり等距離の状態となり出力なしとなってしまう. これを解決するために,1 文書に対して複数の候補を学習させ る方法を考える.

TRIPDL では式 (5) の学習の際, 1 文書  $d_k$  に対して 1 セル  $c_i$  を学習させる. その部分を 1 セルではなく複数のセルに拡 げたのが拡張手法である. つまり式 (5) を書き換えると式 (11) になる. ここで, Widen\_city() とは 1 セルを与えたときにそ のセルを拡げた, 複数のセルを返す関数である.

先に述べたように今回の設定ではセルではなく行政地区なの でWiden\_city()には大字レベルまたは市区町村レベルの住所 が入力される.その場合はその住所の属する市区町村に属する 全ての住所候補が返される.例えば「茨城県つくば市天久保」 という大字レベルの住所が入力された場合,「茨城県つくば市」 に属する住所候補(「茨城県つくば市」,「茨城県つくば市天久保」 保」,「茨城県つくば市桜」など)が全て返される.

また,式 (12) については関数部分のみが違うだけで Widen\_city()がWiden\_pref()に替わっている.Widen\_pref() とは市区町村でなく入力候補の都道府県に属する住所候補全て を返す関数である.拡張手法では式 (5)の替わりに式 (11)あ るいは式 (12)を用いる.つまり,市区町村レベルや都道府県 レベルまで正解の解釈を拡げて学習するのが拡張手法である.

$$\tilde{\theta}_{c_{ij}} = \frac{\sum\limits_{c_m \in Widen\_city(c_i)} \sum\limits_{d_k \in c_m} \#(w_j, d_k)}{\sum\limits_{c_m \in Widen\_city(c_i)} \sum\limits_{d_k \in c_m} \sum\limits_{w_l \in V} \#(w_l, d_k)}$$
(11)

$$\tilde{\theta}_{c_{ij}} = \frac{\sum\limits_{c_m \in Widen\_pref(c_i)} \sum\limits_{d_k \in c_m} \#(w_j, d_k)}{\sum\limits_{c_m \in Widen\_pref(c_i)} \sum\limits_{d_k \in c_m} \sum\limits_{w_l \in V} \#(w_l, d_k)}$$
(12)

## 7. 評価実験

7.1 実験の設定

#### 7.1.1 実験条件

教師なし学習の先行手法である POPULATION[4] と文脈参 照法 [6] と MENTION\_COUNT[6],教師あり学習の先行手法 である TRIPDL,拡張手法の市区町村レベル,拡張手法の都道 府県レベルについて正解率・拡大正解率を測定する実験を行っ た. また TRIPDL と拡張手法では、以下のように素性に使う 単語を変えてもそれぞれ実験を行った.数詞を除く名詞全てを 使った場合,固有表現 ORGANIZATION (O) のみを使った 場合,固有表現 PERSON (P)のみを使った場合,固有表現 LOCATION(L)のみを使った場合,固有表現 ARTIFACT (A)のみを使った場合,固有表現 O,P,L,A(OPLA)のみを使っ た場合について実験を行った. 文脈参照法において参照する文 字数 k を指定する必要がある. 今回はコーパスの1 記事あた りの平均文書長 L = 1,657 のとき,前方文脈を k1,後方文脈 を $k_2$ とすると $k_1 = k_2 = \frac{L}{2} = 829$ とした. 今回の設定では コーパス内にあるターゲットは入力として与えられる.また TRIPDL は本来 document geolocation の手法であるが、本 研究では toponym resolution を扱うため,その間の違いを吸 収しなくてはならない. そのため,入力の toponym に対して その前後829文字(文脈参照法の k と同様)を結合した文字 列を擬似 document とし, TRIPDL で解いた.

#### 7.1.2 データセット

評価を行なうコーパスは 3. 章に示したものを使用する. 候 補データ生成に用いる住所データベースは 4. 章に示したもの を利用する. POPULATION に用いる人口 DB は政府が発行 している人口統計データ「e-stat 統計で見る日本」\*<sup>2</sup>の調査 年 2015 年のデータを用いる. MENTION\_COUNT で用いる 言及回数 DB を作成する際に使用する生コーパスには毎日新 聞社のコーパス [7]1 年分を用いる.

正解データは人手で作成した.拡張固有表現タグ付きコーパ スに付与された City タグが付く地名のうち,住所 DB を参照 して複数の候補が得られるものについて,その近隣文脈を読む ことで正解候補を選択した.今回は毎日新聞ジャンルのみの実 験であるため,毎日新聞ジャンル中の候補が複数ある City タ グ全 1732 個について正解を付与した.また,作業は基本的に 一人で行ったが,アグリーメントのため全 City タグのうちラ ンダムに抽出した 200 個をもう一人も作業を行い,どの程度 二人のアノテーション結果が一致するかも検証した.その結果 一致しなかったタグは全 200 個中 3 個であり,このアノテー ションは一般性を確保できていると考えられる.

#### 7.1.3 評価尺度

評価尺度には正解率と拡大正解率を用いる. 正解率とは手 法により選択した候補と正解ファイル中の候補とを比較し, 一 致していた場合に正解, そうでない場合に不正解としたときの 候補が複数ある全 City のうちの正解の割合である. 拡大正解 率とは手法により選択した候補が属する都道府県と正解ファイ ル中の候補が属する都道府県とを比較し, 一致していた場合に 正解, そうでない場合に不正解としたときの候補が複数ある全 City のうちの正解の割合である.

#### 7.2 実験結果

実験の結果を表2に示す.ここで,不正解を誤選択,正解 なし,出力なしの3つに分けた.誤選択とは正解と出力がどち らも存在するが一致しない場合であり,使用した手法によって 正しい候補を選ぶことができなかったことをあらわす.正解な しとは候補中に正解が存在しない場合である.これは合併など による原因が考えられる.出力なしとは候補があるにも関わら ず,使用した手法で出力を出せなかった場合である.また正解 なしの場合は出力の有無はドント・ケアであり,出力がなくて も出力なしにはカウントされない.

表 2 より,まず POPULATION と文脈参照法と TRIPDL(名詞) を比較すると,教師なし学習である

<sup>\*2</sup> https://www.e-stat.go.jp/regional-statistics/ssdsview

| 表 2: 実験結果                     |       |      |       |       |      |      |
|-------------------------------|-------|------|-------|-------|------|------|
| 手法                            | 拡大正解率 | 正解率  | 正解    | 誤選択   | 出力なし | 正解なし |
| POPULATION                    | 57.0  | 56.9 | 985   | 207   | 388  | 152  |
| 文脈参照法                         | 63.5  | 56.2 | 974   | 279   | 327  | 152  |
| TRIPDL(名詞)                    | 67.4  | 67.0 | 1,161 | 124   | 295  | 152  |
| TRIPDL(O)                     | 62.1  | 61.8 | 1,071 | 190   | 319  | 152  |
| $\mathrm{TRIPDL}(\mathrm{P})$ | 60.1  | 59.8 | 1,035 | 233   | 312  | 152  |
| TRIPDL(L)                     | 68.9  | 68.6 | 1,188 | 97    | 295  | 152  |
| TRIPDL(A)                     | 55.4  | 55.2 | 956   | 205   | 419  | 152  |
| TRIPDL(OPLA)                  | 68.0  | 67.6 | 1,171 | 114   | 295  | 152  |
| 拡張手法 市区町村 (名詞)                | 59.4  | 57.2 | 991   | 505   | 84   | 152  |
| 拡張手法 市区町村 (O)                 | 44.8  | 43.0 | 745   | 735   | 100  | 152  |
| 拡張手法 市区町村 (P)                 | 32.5  | 30.5 | 528   | 956   | 96   | 152  |
| 拡張手法 市区町村 (L)                 | 59.9  | 58.0 | 1,004 | 492   | 84   | 152  |
| 拡張手法 市区町村 (A)                 | 32.6  | 31.3 | 542   | 847   | 191  | 152  |
| 拡張手法 市区町村 (OPLA)              | 59.8  | 57.5 | 996   | 500   | 84   | 152  |
| 拡張手法 都道府県 (名詞)                | 61.8  | 53.7 | 930   | 650   | 0    | 152  |
| 拡張手法 都道府県 (O)                 | 43.7  | 38.3 | 664   | 916   | 0    | 152  |
| 拡張手法 都道府県 (P)                 | 30.8  | 25.6 | 443   | 1,137 | 0    | 152  |
| 拡張手法 都道府県 (L)                 | 64.0  | 56.3 | 975   | 605   | 0    | 152  |
| 拡張手法 都道府県 (A)                 | 22.2  | 17.8 | 309   | 1,261 | 10   | 152  |
| 拡張手法 都道府県 (OPLA)              | 64.2  | 56.8 | 983   | 597   | 0    | 152  |
| MENTION_COUNT                 | 72.1  | 66.7 | 1,156 | 364   | 60   | 152  |

POPULATION, 文脈参照法に比べ教師あり学習である TRIPDL (名詞) は正解率が高いことがわかる.

次に、同じ TRIPDL でも使用する素性が違う場合をそれぞ れ比べる.L が一番正解率が高いことがわかる.これは固有 表現の中で一番 LOCATION が地理的位置推定に有効だとい うことを示しており、直感通りの結果となった.ここで、それ ぞれの素性の数は、名詞:271011、O:5736、P:7933、L:16302、 A:1593 である.名詞の数は他の素性に比べてかなり多くある にもかかわらず L に正解率で及んでいないのは全ての名詞を 利用するよりも固有表現 LOCATION のみを使ったほうがよ り小さい計算量で正解率が向上することを示していると考えら れる.

次に TRIPDL と拡張手法を比較すると, TRIPDL が一番 正解率がよく, 市区町村, 都道府県と範囲を拡げる毎に正解率 が悪くなっていることがわかる.不正解の内訳から, 出力なし の数は範囲を拡げる毎に確実に減っており, 候補間が等距離に なる問題は解決されていることがわかる.しかしそれと同時に 正解は減り誤選択は増えている.

最後に一番正解率が高かった TRIPDL(L) と MEN-TION\_COUNT を比較する. MENTION\_COUNT は教師な し学習にもかかわらず,教師あり学習の TRIPDL と同じ程度 の正解率をだしており,非常に興味深い結果となった. これは MENTION\_COUNT では大量の教師なしデータを考慮できる 点が性能へ反映されたからと考えられる.

# 8. おわりに

本論文では新聞記事の地理的位置推定のタスクにおける地名 の曖昧性問題について,曖昧性解消に有効な素性の調査を行っ た.実験より,固有表現の中ではLOCATIONが一番有効な 素性であり,全名詞も同じくらい有効ではあるが,計算量を考 えると全名詞よりもLOCATIONのほうが良いという結果が 得られた.今後の課題と検討として,次のものが挙げられる.

拡張手法によって正解率が下がってしまったがその原因の追求

 MENTION\_COUNT と TRIPDL(L) とのアルゴリズム の突き合わせを行い,結合方法を検討する

### 謝辞

本研究の一部は科研費(18K11982)の助成を受けて実施さ れました.

# 参考文献

- [1] Stuart Middleton,Lee Middleton,and Stefano Modafferi.Real-time crisis mapping of natural disasters using social media.2014.
- [2] 北本 朝展.G 空間 オープンな地名情報システム GeoNLP.THE JOURNAL OF SURVEY 測量,pp6-10,2014.
- [3] Lianhua Chi,Kwan Hui Lim,Nebula Alam and Christopher J. Butler.Geolocation Prediction in Twitter Using Location Indicative Words and Textual Features.The 2nd Workshop on Noisy User-generated Text.2016.
- [4] Michael Adrian Speriosu.Methods and Applications of Text-Driven Toponym Resolution with Indirect Supervision.THE UNIVERSITY OF TEXAS AT AUSTIN.2013.
- [5] 橋本 泰一,乾 孝司,村上 浩司. 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,pp113-120,2008.
- [6] 関 龍,乾 孝司.局所文脈と関連文書を用いた地名に対す る地理的位置の同定.人工知能学会,2018.
- [7] 毎日新聞社.CD-毎日新聞 2004 データ集.

インタラクティヴなデータ・ヴィジュアライゼーション・ツールを用いた Twitter データのクラスタ分析

Cluster analysis of Twitter Data, using Interactive Data visualization Tool.

和田 伸一郎<sup>\*1</sup> WADA, Shinichiro 立教大学大学院社会学研究科 Graduate School of Sociology, Rikkyo University.

Abstract: This study attempts cluster analysis of Twitter data posted on Tokyo Governor's Election held in 2016, using Python (July 13 - August 1, 2016, 4.8 million tweets, 170 million words). For cluster analysis, words were vectorized using gensim version word2vec algorithm which is a library of Python, and attempt to visualize clusters in three dimensions using t-SNE (t-distributed Stochastic Neighbor Embedding) which is dimensionality reduction algorithm. In particular, in this research, we used the data visualization tool Embedding Projector for clustering. By using this tool, we attempted to visually identify clusters by moving the three-dimensional space interactively while visualizing the dynamic learning process in the three-dimensional space. As a result, we could identify multiple clusters with high accuracy. This made it possible to clarify what in this election Twitter users were interested in.

# 1. はじめに

本研究では、2016 年 7 月に行われた東京都知事選挙に関 する Twitter データのうち、選挙期間中(とその前後一日ずつを 含む)に投稿されたものを全数収集し、クラスタ分析を行うことに よって、選挙に関する、どのような投稿がなされたのかを分析し た.

# 2. データと前処理について

# 2.1 収集した Twitter データについて

Twitter データは、ユーザーローカル社(東京都港区)の特別 な協力を得て、2016年7月13日~8月1日の間の以下の検索 ワードを含む全数データを収集することができた.検索ワードは 次のとおりである.「小池 OR 増田 OR 鳥越 OR 百合子 OR 寛 也 OR 俊太郎 OR 都知事選 OR 都知事選挙 OR 知事選挙 OR 知事選」.その結果、表1のようなデータを csv ファイルにて収集 することができた. RT は公式リツイートのみの数、OT はオリジナ ルツイートを指す.

#### 表1

|     | 総ツイート数    | 語彙数     |
|-----|-----------|---------|
| ALL | 4,825,560 | 199,287 |
| RT  | 3,588,302 | 123,192 |
| ОТ  | 1,237,258 | 187,394 |

なお ALL データ(RT データと OT データを足したすべての データ)の単語数は, 177,439,525 語となった.

この表からも分かるように、このデータのうち、約 74%がリツイ ートからなっていた. 語彙数(単語の種類)でみても、RT の語彙 数が OT よりも少ないのは、同じツイートが数多くリツイートされて いるためである. したがって、Twitter データの場合、しばしばテ キストマイニングで行われる、単語の出現回数を出しても、あまり 意味がない. 多くリツイートされた文章に含まれる単語の出現回 数が多くなってしまうためである.

そこで、単語の類似度(意味の近さ)を計算する、Pythonのライブラリ gensim に実装されている word2vec を使って、単語のべ

クトル化を行い、どのような類似する単語群、つまりクラスタがある かを調べることにした.なお、単語ベクトル化をする際に設定した word2vecのオプションの値は以下の通りである.sg=1,size=300, min\_count=5, window=10, hs=0, negative=5, iter=10, sample=0.001(オプションについての詳しい説明については、 GitHub で公開されている Python ライブラリ gensim のソースコ ード(word2vec.py)に記載されている).

# 2.2 データの前処理(形態素解析)

その前に、これらのデータをそれぞれ形態素解析する必要が ある.日本語の形態素分析エンジンとして、最も有名なのは Mecab である(Kudo(2013)).またそれとセットにしばしば使わ れる辞書が、Mecab-ipadic 辞書である.ここで問題になるのは、と りわけ SNS テキストデータには、それぞれの SNS プラットフォー ムに固有のスラングや、多岐にわたるトピックごとに多種多様な 語彙群が存在することである.なぜ問題なのかといえば、ipadic は、標準的な辞書レベルの語彙を十分網羅的に含んでいるが、 特殊な語彙を欠いているからである.これを解決するために本 研究では、Sato(2015)によって、いまもなお定期的に更新され 続けている、こうしたネット上のスラングなどを多く含む Mecabipadic-NEologd 辞書を用いた.

とりわけ、ipadic 辞書が SNS データ分析にとって致命的なの は、氏名を一つの単語として認識しないことである. 都知事選の 場合でいえば、「小池」とカウントされた単語が「小池百合子」な のか共産党議員の「小池晃」なのかが分からない. つまり、「小 池」と「百合子」、「晃」が分解されて学習されてしまう. さらには、 「桜井」とカウントされた単語が、候補者の1人であった元在特会 会長の「桜井誠」なのか、一時期候補すると噂された「桜井俊」 (アイドルグループ嵐のメンバーの櫻井翔の父親)なのか,保守 派論客である「櫻井よしこ」なのか,が分からないということが起き る(これらの氏名はすべて分解されてしまう). こういったことがク ラスタリングで大きな欠陥となりうる理由は、それらの氏名が、相 当異なる文脈に出現する可能性が高い以上、氏名が分解され てしまうと、それぞれの文脈の差異が学習不能になってしまうか らである. これだと、いくら word2vec、t-SNE などのアルゴリズムの 精度が高くても、学習結果が混乱したものになる可能性が高くな ってしまう.

連絡先:和田伸一郎 立教大学大学院社会学研究科,東京都 豊島区西池袋3-34-1

# 3. word2vecとEmbedding Projectorによる可視化

約 20 万もある語彙の分布のどこにクラスタがあるのかを調べることは、単語ごとに類似する単語をリスト化してくれる word2vec の Python スクリプトを実行するだけでは難しい. 例えば、約 20 万もの単語すべてに類似単語リストをつくることは、現実的に難しい.

そこで、コーパス全体を可視化した上で、その全体の中に、ど のようなクラスタが現れているかを視覚的に把握するツールとし て、Google 社がオープンソースで提供しているディープラーニ ングフレームワークである TensorFlow のパワフルな可視化ツー ル、TensorBoard のスタンドアローン版 WebUI である Embedding Projector を用いることにした.

word2vec を使って 300 次元で単語ベクトル化したコーパスを, Embedding Projector 上で,次元圧縮アルゴリズムである, PCA, t-SNEを用いて,選定した特徴語とそれに類似する 1000 語から なる,三次元のローカル空間を可視化し,クラスタを出すことを試 みた.特徴語として,選挙期間中に大きな争点となっていた「待 機児童」,「介護」,また,全国的に注目されていた「オリンピック /パラリンピック」などを選定した.なお,「待機児童」,「介護」, 「オリンピック/パラリンピック」を含んだツイートは,それぞれ, 43,794, 26.955, 78,006 存在した.

図1は、「待機児童」をターゲット単語として設定し、2000回学 習した結果、収束した、その単語と意味の近い 1000 語からなる 三次元のローカル空間である.



図1.「待機児童」ローカル空間

Embedding Projector では、学習中であってもインタラクティヴ に三次元空間を左右上下自由に回転させることができ、また、ズ ームイン、ズームアウトすることによって、どの辺りにクラスタが出 現しつつあるかを、直感的に目視で判断することができる。この ツールの大きなメリットとして挙げることができるのは、機械学習 や深層学習の欠点としてしばしば指摘される、学習の「ブラック ボックス」性を、このツールが一定程度、取り除いてくれることであ る.

# 4. 分析結果と課題

いくつか特徴語を選定し、学習を行った結果、日本語でも高 い精度でクラスタを確認することができた.この精度の高さは、ま ずは word2vec, PCA、t-SNEのアルゴリズムの精度の高さにより もたらされたものであるが、加えて、NEologd 辞書が、例えば、候 補者や有識者などの名前や政党名、政治団体名、イベント名、 地名、市民会館などの建物の名前といった固有名詞を一語で 拾ってくれたことからもたらされたものでもあることが分かった.

他にも、Instagramのテキストデータを学習させ、高い精度でクラスタが出ることも確認できた。

課題としては、今回、word2vec に用意されているオプションの 値を変えて、それぞれのデータで、最も精度が高い学習結果を 比較する余裕がなかったことを挙げることができる。これについ ては、今後検討したい.

#### 参考文献

[Smilkov 16] Google Developers (Smilkov, Daniel, Viégas, Fernanda, Wattenberg, Martin.). : A.I. Experiments: Visualizing High-Dimensional Space. https://www.youtube.com/watch?v=wvsE8jm1GzE&feature=youtu.be (2016)

- [木田 17] 木田勇輔.: ソーシャルメディアとポピュリストの動員 —2016 年東京都 知事選挙における Twitter データの分析から—,文化情報学部紀要,椙山 女学園大学,第17巻, pp.83—92 (2017)
- [Kudo 13] Kudo Taku. : McCab:Yet Another Part-of-Speech and Morphological Analyzer, <u>http://taku910.github.io/mecab/</u> (2013)
- [Maaten 08] Maaten, Laurens van der, and Hinton, Geoffrey. : Visualizing data using t-SNE. Journal of Machine Learning Research, Vol 9(Nov), pp. 2579— 2605. (2008)
- [Mikolov 13a] Mikolov, Tomas, Chen, Kai, Corrado, Greg, Dean, Jeffrey. : Efficient estimation of word representations in vector space". CoRR, abs/1301.3781. (2013)
- [Mikolov 13b] Mikolov, Tomas, Sutskever, Ilya, Chen, Kai, Corrado, Gregory S., Dean, Jeffrey. : Distributed representations of words and phrases and their compositionality. In Advances in Neural Information Processing Systems 26: 27th Annual Conference on Neural Information Processing Systems 2013. Proceedings of a meeting held December 5-8, 2013, Lake Tahoe, Nevada, United States, pages 3111–3119 (2013)
- [Sato 15] Sato Toshinori. : Neologism dictionary based on the language resources on the Web for mecab-ipadic", <u>https://github.com/neologd/mecab-ipadic-neologd/</u> (2015)
- [Smilkov 16] Smilkov, Daniel, Thora, Nikhilt, Nicholson, Charles, Reif, Emily, Viégas, Fernanda, Wattenberg, Martin. : Embedding Projector: Interactive Visualization and Interpretation of Embeddings. 30th Conference on Neural Information Processing Systems (NIPS 2016), Barcelona, Spain (2016)
- [山縣 18] 山縣史哉, 梅原英一:平成 28 年度東京都知事選挙の Twitter 分析, 信学技報, 電子情報通信学会 (2018)

# 係り受け誤り埋め込み表現のクラスタリングによる 複数のドメイン間での追加訓練の効果の比較分析

Comparative Analysis of the Effect of Additional Training between Multiple Domains by Clustering of the Embeddings of Parsing Errors

| 原 拓也 *1              | 松崎 拓也 *1                | 横野 光       | *2               | 上藤 理史 *1         |    |
|----------------------|-------------------------|------------|------------------|------------------|----|
| Takuya Hara          | Takuya Matsuzaki        | Hikaru Yok | ono              | Satoshi Sato     |    |
|                      |                         |            |                  |                  |    |
| *1名古屋                | 大学工学研究科                 | *          | <sup>2</sup> (株) | 富士通研究            | 所  |
| Graduate School of F | Engineering, Nagoya Uni | iversity   | Fujitsu l        | Laboratories Ltd | l. |

We propose a method for studying the effect of additional training of Japanese dependency parsers across multiple domains from a bird's-eye view. We collected the parsing errors of a parser before and after additional training using target domain data. We then conducted cluster analysis of the parsing errors represented as dense real vectors, which are obtained from the internal states of the parser. Through quantitative and qualitative analysis of the clusters, we could grasp the types and the numbers of the parsing errors across multiple target domains.

# 1. はじめに

機械学習における課題の一つにドメイン適応問題がある。多 くの場合、訓練に用いたデータのドメイン(以下、訓練ドメイ ン)と、適用の対象となるデータのドメイン(以下、評価ドメ イン)が異なるとタスクの精度が低下する。精度の低下の原因 は訓練ドメインと評価ドメインに含まれている文の構造や単 語、あるいは正解の分布が異なっているからである。この精度 の低下を防ぐという課題をドメイン適応問題という。

本研究では、ドメイン適応問題の対象となるタスクとして 係り受け解析を取り上げる。係り受け解析とは文を構成してい る文節同士の係り受け関係(修飾・被修飾)を解析するタスク である。係り受け解析の例を図1に示す。図の中の四角が文節 を表しており、矢印が係り受け関係を表している。それぞれの 矢印は係り文節(修飾文節)から受け文節(被修飾文節)へと 伸びている。

ドメイン適応問題は、評価ドメインデータを用いて追加訓 練を行うことである程度解決できることが多い。評価ドメイン データの量は多くの場合限られており、それらを効率的に用い るための方法に関する研究は、多数存在する。例えば Daumé III と Marcu [Daumé III 06] は、追加訓練を行う際の評価ドメ インデータへの適切な重み付け方法を提案した。また Daumé III [Daumé III 07] はドメイン固有の情報とドメインに依存し ない情報を分けて訓練を行えるように素性を設計した。他に も、効率的な学習を行うために、次にアノテーションすべき データを逐次的に見つける方法(アクティブラーニング)に関 する研究も多数ある。

上で述べた研究では、適用する評価ドメインそれぞれに対 し、追加訓練用データを用意する必要がある。しかし、評価ド メインのデータを多数のドメインについて用意することはコ ストの点から現実的でない。一方、追加訓練がなぜ有効なのか は、追加訓練によって解消された誤りや、解消されなかった誤 りを一つ一つ見ていてもよくわからないことが多い。これに対 し、追加訓練の効果を俯瞰的に分析することで、より少ないア ノテーションで、効果的に適応を行うための知見が得られると 期待できる。そこで、本研究では係り受け解析器のドメイン適 応を対象に、追加訓練の効果を俯瞰的に分析するための手法と して、係り受け誤りのクラスタリングを提案する。

|    |    |     | 4    |
|----|----|-----|------|
| 私は | 甘い | ものが | 好きだ。 |

図 1: 係り受け解析の例

クラスタリングを行うためには係り受け誤りの間の類似性 を数量的に捉える必要がある。そのため、本研究では係り受け 解析器の内部状態を用いて係り受け誤りを埋め込み表現(密ベ クトル表現)に変換する。

本論文では特に、複数の評価ドメインの間での追加訓練の 効果の違いについて分析する。この分析は、評価ドメインデー タを用いた追加訓練の前後における係り受け誤りを埋め込み 表現に変換し、それらに対しクラスタリングを行い、得られた 結果を複数ドメイン間で比較することで行われる。本論文では 訓練ドメインとして新聞記事、評価ドメインとして中学校理科 教科書及び特許文書を用いてクラスタリングを行った。クラス タに含まれる誤りの数の分布や、クラスタごとの誤りの性質を 調べることで、ドメインごとの特徴を比較・分析することがで きた。

以下、2節で提案手法について説明する。3節では実際の データを用いた分析を行う。

# 2. 係り受け誤りのクラスタリング

#### 2.1 係り受け解析器

本研究では、LSTM に基づく係り受け解析器の誤りを分析 する。また、誤りの埋め込み表現を得るために、この解析器の 内部状態を用いる。本研究で用いる解析器は松野ら [松野 18] のものをベースにした。松野らのモデルは大きく分けて、(i) 単語層 LSTM による単語表現の獲得、(ii) 文節層 LSTM によ る文節表現の獲得、(iii) 多層パーセプトロンによる次元圧縮、 (iv)Biaffine 変換による係り受け関係スコアの計算の4段階に 分けられる。本研究では (i) 及び (ii) はそのままで、(iii) 及び (iv) の代わりに多層パーセプトロンによる係り受け関係スコア の計算を行う。

具体的には以下のモデルを用いる。最初に文の各単語の品 詞(4レベル)・活用形・活用タイプ・基本形をそれぞれ埋め込 み層に通し、それらを結合させることで単語分散表現とする。 文の各単語の単語分散表現をまとめて系列にしたものを*x<sup>word</sup>* 

連絡先: hara.takuya@h.mbox.nagoya-u.ac.jp

として単語層 LSTM に入力する。この時 (i) の操作は以下の 式のように行われる。

$$(\overleftarrow{\boldsymbol{y}}_{i}^{word}, \overrightarrow{\boldsymbol{y}}_{i}^{word}) = \text{BiLSTM}^{word}(\boldsymbol{x}_{i}^{word})$$
 (1)

*t* 番目の文節が *i* 番目から *j* 番目の単語で構成されている時、 文節層 LSTM への入力 *x<sup>chunk</sup>* は以下のように計算される。

$$\overleftarrow{\boldsymbol{x}}_{t}^{chunk} = \overleftarrow{\boldsymbol{y}}_{i}^{word} - \overleftarrow{\boldsymbol{y}}_{j+1}^{word}$$

$$\tag{2}$$

$$\overrightarrow{\boldsymbol{x}}_{t}^{chunk} = \overrightarrow{\boldsymbol{y}}_{i-1}^{word} - \overrightarrow{\boldsymbol{y}}_{j}^{word} \tag{3}$$

$$\boldsymbol{x}_{t}^{chunk} = \overleftarrow{\boldsymbol{x}}_{t}^{chunk} \oplus \overrightarrow{\boldsymbol{x}}_{t}^{chunk} \tag{4}$$

t番目の文節に対応した文節表現を $y_t^{chunk}$ とする。このとき (ii)の操作は以下の式のように計算される。

$$(\overleftarrow{\boldsymbol{y}}_{t}^{chunk}, \overrightarrow{\boldsymbol{y}}_{t}^{chunk}) = \text{BiLSTM}^{chunk}(\boldsymbol{x}_{t}^{chunk})$$
 (5)

$$\boldsymbol{y}_{t}^{chunk} = \overleftarrow{\boldsymbol{y}}_{t}^{chunk} \oplus \overrightarrow{\boldsymbol{y}}_{t}^{chunk} \tag{6}$$

t番目の文節がu番目の文節に係る際 (t < u)の係り受け関係スコア $s_{t,u}$ は、以下のように定義される。

$$s_{t,u} = \mathrm{MLP}(\boldsymbol{y}_t^{chunk} \oplus \boldsymbol{y}_u^{chunk} \oplus \boldsymbol{d}(t,u))$$
(7)

$$d(t, u) = [u - t = 1] \oplus [u - t \le 5]$$
(8)

ただし[·] は内部の条件が真ならば要素が1のベクトルを、偽 ならば要素が0のベクトルを表す。

この係り受け関係スコアモデルを用いて内元ら [内元 99] の アルゴリズムで訓練・解析を行う。内元らのアルゴリズムで は、後方の文節から順に係り先を決定する。その際、ある係り 文節に対し、候補となる受け文節の集合の中から1つの文節を 選択する必要がある。訓練時は、係り文節と正しい受け文節の ペアの係り受け関係スコアが、係り文節とその他の受け文節の 候補のペアの係り受け関係スコアよりも高くなるように訓練 する。具体的には、ある係り文節 tに対し、正しい受け文節を u、候補文節集合を  $C_t$  とするとき、損失関数を以下のように 定義する。

$$loss = -\sum_{u' \in \mathcal{C}_t} \log \frac{\exp(s_{t,u})}{\exp(s_{t,u}) + \exp(s_{t,u'})} \tag{9}$$

解析時は、それぞれの係り文節に対する受け文節候補集合のうち、係り受け関係スコアが最も高くなるものを選択する。

#### 2.2 係り受け誤りの収集法

本研究では評価ドメインデータによる追加訓練を行う前後 で、解析結果の誤り方がどのように変化するかを観察する。こ の目的のため、以下のように訓練データ及び解析対象のデータ が異なる3タイプの誤り例を収集した。

(1) 訓練ドメイン誤りの収集 最初に、訓練ドメインのデータ の半分を用いてベースモデルを作る。訓練ドメインのデータの 残り半分をベースモデルで解析した時の誤りを収集する。

(2) 追加訓練前の評価ドメイン誤りの収集 評価ドメインデー タの全てをベースモデルで解析した時の誤りを収集する。

(3) 追加訓練後の評価ドメイン誤りの収集 評価ドメインデー タに対し4分割交差検証を行う。ただし、ベースモデルの多層 パーセプトロン(式(7))の部分のみを、ベースモデルのパラ メータ値を初期値として、評価ドメインデータを用いて訓練す る(その結果を以降では追加訓練済みモデルと呼ぶ)。その結 果得られた誤りを収集する。 追加訓練において多層パーセプトロンのみを訓練すること で、すべてのモデルについて文節の埋め込み表現は共通とな る。これにより係り受け誤りの埋め込み結果(2.3.1項)を比 較することができる。なお、本研究では追加訓練済みモデルで 訓練ドメインデータを解析した際の誤りは用いない。理由は本 研究の目的が追加訓練による評価ドメイン誤りの変化の観察で あり、訓練ドメイン誤りの変化には興味がないためである。

#### 2.3 係り受け誤りの分析

係り受け誤りを俯瞰的に観察するための手法としてクラス タリングを行いたい。クラスタリングを行うためには、誤りの 間に距離を定義する必要がある。そこで最初に係り受け誤りを 埋め込み表現(ベクトル)に変換し、ユークリッド距離を誤り 間の距離とする。

#### 2.3.1 係り受け誤り埋め込み表現

係り受け誤り埋め込み表現(以降、係り受け誤り表現)は係 り受け誤りの3要素である係り文節・正しい受け文節・誤った 受け文節とそれらの間の距離素性を埋め込んだものである。

2.1 項で述べた係り受け解析器には、中間層として文節表現 ((6) 式の  $y_t^{chunk}$ ) がある。文節表現は文節及び周辺文脈から、 係り受け解析に必要な情報を抽出したものだと考えることがで きる。そこで係り文節・正しい受け文節・誤った受け文節に対 応する文節表現を結合し、さらに距離素性を結合したものは係 り受け誤り全体の特徴を表現するものと考えることができる。 係り文節を t, 正しい受け文節を u, 誤った受け文節を  $\tilde{u}$  とし て、係り受け誤り表現  $e_{t,u,\tilde{u}}$  は以下のように作成する。

 $e_{t,u,\tilde{u}} =$ 

$$\begin{cases} \boldsymbol{y}_{t}^{chunk} \oplus \boldsymbol{y}_{u}^{chunk} \oplus \boldsymbol{y}_{\tilde{u}}^{chunk} \oplus \boldsymbol{d}(t, u) \oplus \boldsymbol{d}(t, \tilde{u}) & (u < \tilde{u}) \\ \boldsymbol{y}_{t}^{chunk} \oplus \boldsymbol{y}_{\tilde{u}}^{chunk} \oplus \boldsymbol{y}_{u}^{chunk} \oplus \boldsymbol{d}(t, \tilde{u}) \oplus \boldsymbol{d}(t, u) & (u > \tilde{u}) \end{cases}$$

上式は、二つの受け文節候補 u と ũ のうち、正解がどちらで あるかとは無関係に、文中での出現順に従って埋め込み表現を 構成することを表す。これにより、係り受けアノテーションさ れていないデータについても、例えば係り受け関係スコア1位 と2位のペアを用いて、同様に埋め込み表現を作成できる。

#### 2.3.2 クラスタリング

本研究では、係り受け誤り表現を以下の手順で分析する。

- 1. 訓練ドメイン誤りの埋め込み表現を k-means 法でクラス タリングする。
- 評価ドメイン誤りそれぞれの埋め込み表現 e について、
   で得られたクラスタのうち、e からクラスタ重心までの距離が最も近いものに e を割り当てる。

この手順は数の多い訓練ドメイン誤りを類型ごとにグループ化 した後、評価ドメイン誤りのそれぞれを、近い類型をもつクラ スタへと分類することを意図している。

#### 3. 実験

この節では最初に実験に用いたデータの統計について述べ、 次に係り受け誤りの収集に関する詳細を述べる。最後にクラス タリングの結果とその分析について述べる。

#### 3.1 利用データ

訓練ドメインデータとして新聞記事(京都大学テキストコー パス[黒橋 97])を用いた。また、評価ドメインデータとして 理科教科書及び特許文書を用いた。理科教科書データは東京 書籍「新編新しい科学(中学1年生、中学2年生)」のテキス

| 1 | 专 1 | l: 7 | デー | タ( | の統 | 計 |
|---|-----|------|----|----|----|---|
|   |     |      |    |    |    |   |

| データ   | 文数     | 文節数     | 文節数/文 |
|-------|--------|---------|-------|
| 新聞記事  | 38,400 | 372,130 | 9.7   |
| 理科教科書 | 2,460  | 22,923  | 9.3   |
| 特許文書  | 953    | 11,157  | 11.7  |

表 2: 係り受け誤りの収集結果

| 対象            | モデル        | 誤り文節数  | 精度    |
|---------------|------------|--------|-------|
| 新聞記事          | ベースモデル     | 13,878 | 91.39 |
| <b>田利</b> 教利書 | ベースモデル     | 2,429  | 88.13 |
| 理科教科書         | 教科書訓練済みモデル | 1,671  | 91.83 |
| 供款支書          | ベースモデル     | 1,465  | 85.64 |
| 付訂入盲          | 特許訓練済みモデル  | 1,143  | 88.80 |

ト、特許文書は高分子化合物に関する特許の実施例の箇所にそ れぞれ係り受け情報を付与したものである。それぞれのデータ の統計値を表1に示す。表に示すように、本論文における実験 では、理科教科書及び特許文書の量は新聞記事の10分の1未 満と少量である。

#### 3.2 係り受け誤りの収集

2.1 項で述べた係り受け解析器の訓練は以下のように行った。 新聞記事の全体の 50 %をベースモデルの訓練データ、残りの 50 %を開発データ兼評価データとして用いた。学習データの 中で出現数が 1 回だった単語は UNK トークンに置き換えた。 単語の品詞(4レベル)、活用形、活用タイプはそれぞれ 20次 元に、単語の基本形は 200 次元に埋め込んだ。単語層・文節層 LSTM は隠れ層 1 層(300 次元)のものを用いた。多層パー セプトロンは隠れ層 1 層(300 次元)のものを用いた。訓練 アルゴリズムは学習係数 0.01 の AdaGrad で、ミニバッチサ イズは 32 文、重み減衰係数は 0.00001、勾配の大きさは5に 制限して訓練を行った。またエポック数は最大 32 エポックだ が、開発データに対する損失が最も少ないものを最終結果とし た。実装には Chainer [Tokui 15] を用いた。追加訓練は理科 教科書・特許文書それぞれについて 4 分割交差検証の要領で 行った。\*1

次に2.2項で述べた方法で係り受け誤りを収集した。その結 果を表2に示す。ベースモデルによる新聞記事に対する解析 精度は、松野ら[松野 18]と同程度であった。適応先ドメイン データによる追加訓練を行うことで精度が向上していることが わかる。ベースモデルによる解析精度が理科教科書と特許文書 で2.5ポイントほどの差があるので、特許文書は理科教科書よ り解析が難しい(新聞記事との違いが大きい)と考えられる。

### 3.3 クラスタリング結果と分析

2.3 項で述べた方法で新聞記事、理科教科書、特許文書それ ぞれの係り受け誤りを埋め込み表現に変換した。またクラスタ 数を30としてクラスタリングを行った。さらに追加訓練前後 における誤りの傾向の変化を調べるため、各クラスタに含まれ ていた追加訓練前の誤りの数・追加訓練後の誤りの数・追加訓 練によって解消できた誤りの数を調べた。その結果を図2(理 科教科書)、図3(特許文書)に示す。グラフの縦軸は各クラ スタに含まれる新聞記事誤りの数に対する評価ドメインデー 夕誤りの比(百分率)を表している。つまり、この比が相対的 表 3: 評価データにおける「…/係り文節/…/名詞+と/用言」 という文型を含む文の数(出現数)と正しい係り先

| - ± | 200000 | с (шелья |      | (1) (1) (1) (1) (1) (1) (1) (1) (1) (1) |
|-----|--------|----------|------|---|
|     | データ    | 山租粉      | 正しい係 | り文節                                     |
|     |        | ЩИСТ     | 名詞+と | 用言                                      |
|     | 新聞記事   | 594      | 378  | 216                                     |
|     | 理科教科書  | 274      | 36   | 238                                     |
|     | 特許文書   | 12       | 5    | 7                                       |

に高い値になるクラスタは、評価ドメインに特有の誤りの類型 に対応すると考えられる。グラフから、ほぼ全てのクラスタに おいて、追加訓練によって誤りの数が減少していることがわか る。またクラスタ間で誤りの分布は一様ではなく偏っており、 ドメインごとに固有の分布になっていることもわかる。本論文 では、クラスタ内の誤りの傾向が分かりやすかったクラスタ 13 とクラスタ 24 についてその特徴を述べる。以降では係り受 け誤りの例を表す時、係り文節を下線、正しい受け文節を ○ のついた波線、誤った受け文節を × のついた波線で表す。ま た誤り例の通し番号の最初の文字が「N」ならば新聞記事を、 「T」ならば理科教科書を、「P」ならば特許文書を表す。

**クラスタ 13** クラスタ 13 に属する典型的な新聞記事誤りと 理科教科書誤りを以下に示す。

N-13:

立証負担が/軽く、/証拠も/そろえやすい/ことから/東京 地検は/「製造の/企て」に/○ 絞り込んだと/×聞く。 T-13: ドルトンは,/19世紀の/初めごろ,/物質は/そ

れ以上/分割する/ことの/できない/小さな/粒子 で/×できていると/〇考えた。

クラスタ13に属する誤りは、正しい受け文節と誤った受け文 節のいずれか一方が引用を表す助詞「と」を含み、他方が直後 の動詞であるパターンが多かった。理科教科書ではその中でも 誤った受け文節が助詞「と」を含んでおり、正しい受け文節が その直後であるパターンの方が多かった。評価データにおけ る、この文型の出現数を表3に示す。表から、新聞記事では 「名詞+と」の文節にかかる割合がその直後の文節に係る割合 の2倍程度だが、理科教科書では用言文節にはるかに大きく 偏っていることがわかる。これは理科教科書では説明文(「… を/…と/いう」)が非常に多いからである(238個中 213個)。 ここから、図2に見られるようにクラスタ13に属する多数の 理科教科書誤りのうち、多くが追加訓練で解消されたのは、頻 出する説明文の構文を学習したからだと考えられる。またクラ スタ13に属する特許文書誤りの数が少なかったのは、この文 型の出現回数の少なさが原因であることがわかる。

**クラスタ 24** クラスタ 24 に属する典型的な新聞記事誤り、理 科教科書誤り及び特許文書誤りを以下に示す。

N-24:

ところが/阪神大震災では/一番/重要な/情報収集が /遅れ、/自衛隊の/初動問題に/×代表されるように/首相 官邸だけでなく/政府全体の/対応が/後手に/〇回った。 T-24:

図1のように, /光源から/出た/光は/四方八方に/<u>広がり,</u>/ 私たちの/目に/直接/×<u>届くか</u>,/何かに/当たって/はね返 って/私たちの/目に/<u>Q</u>届く。

#### P-24:

次いで、/圧力を/常圧から/13.3kPaに/し、/加熱槽 温度を/190℃まで/1時間で/Q上昇させながら、/発 生する/フェノールを/反応容器外へ/×抜き出した。

<sup>\*1</sup> 新聞記事・理科教科書は文単位で分割し、訓練に用いたが、特許 文書は文書単位で分割した。その理由は特許文書には同じ文書内で は似た文が連続するという特徴があり、それらが訓練データと評価 データに分かれると、汎化性能を正しく評価できないからである。



図 3: 追加訓練による、各クラスタに含まれる特許文書誤りの割合の変化

表 4: クラスタ 24 に属する係り受け誤りにおける誤った係り 先の位置の分布

| データ   | ベースモデル |     | 追加訓練済み |    |
|-------|--------|-----|--------|----|
|       | 前      | 後   | 前      | 後  |
| 新聞記事  | 280    | 398 |        |    |
| 理科教科書 | 83     | 2   | 5      | 37 |
| 特許文書  | 13     | 59  | 12     | 7  |

クラスタ 24 に属する誤りは係り文節と正しい受け文節、誤っ た受け文節がすべて用言文節(節の末尾)であるパターンが多 かった。3つの節 A, B, C がこの順番で並んでいる時、意味的 な構造は ((A B) C) と (A (B C)) の 2 パターン存在する \*2。 この2つの構造のうち、どちらが正しいか判定するためには、 本来は節間の関係性を認識する必要があり、難しい判断を必要 とする場合も多いと考えられる。しかし、図2と図3から、追 加訓練によって、いずれのドメインでも比較的多くの誤りが解 消されていることがわかる。その理由は、ドメインごとに出現 しやすい構造に偏りがあるからだと考えられる。実際にそれ ぞれのドメインでクラスタ 24 に属する誤りについて、正しい 受け文節と誤った受け文節のどちらが前方にあるかを調べた。 結果を表4に示す。理科教科書データの解析では、追加訓練前 のモデルは正しい受け文節よりも前方に存在する文節を選択す る傾向があったが、追加訓練によりその傾向が改善されたこと がわかる。また特許文書は理科教科書と対照的な結果である。 ここから、理科教科書は T-24 のような (A (B C)) という形 の階層的な並列関係を取る場合が多く、節Aはより遠くの文 節 C に係ることが多いと考えられる。一方、特許文書は P-24 のような手続きを表す文を多数含み、3つ以上の節が単純に並 列された構文が多いと考えられる。

# 4. おわりに

本研究では係り受け解析器の内部状態を用いて係り受け誤り を埋め込み、クラスタリングすることで、追加訓練の効果を、 複数のドメインに渡って俯瞰的に分析した。結果として追加訓 練によって解消される誤りのタイプをいくつか特定でき、さら に、解析が難しい文の特徴のドメインごとの差を比較すること ができた。今後の課題としては、解消されない誤りのタイプと その原因の特定、重心から誤りへの距離と誤りの性質の関係の 調査、ドメイン適応技術への応用などがあげられる。

# 謝辞

本研究では、JSPS 科研費 16H01819 で開発された教科書ア ノテーションデータの提供を受けた。ここに記して謝意を表す る。また本研究は名古屋大学と富士通研究所の共同研究の成果 である。

# 参考文献

- [Daumé III 06] Daumé III, H. and Marcu, D.: Domain adaptation for statistical classifiers, <u>Journal of Artificial</u> Intelligence Research, Vol. 26, pp. 101–126 (2006)
- [Daumé III 07] Daumé III, H.: Frustratingly Easy Domain Adaptation, in <u>Proc. of ACL</u>, pp. 256–263, Association for Computational Linguistics (2007)
- [Tokui 15] Tokui, S., Oono, K., Hido, S., and Clayton, J.: Chainer: a next-generation open source framework for deep learning, in <u>Proceedings of workshop on machine</u> <u>learning systems (LearningSys) in NIPS 29</u>, Vol. 5, pp. 1–6 (2015)
- [黒橋 97] 黒橋禎夫, 長尾眞:京都大学テキストコーパス・プロ ジェクト,人工知能学会第 11 回全国大会論文集, pp. 58-61 (1997)
- [松野 18] 松野智紀, 能地宏, 松本裕治:ニューラルグラフ型係 り受け解析器のための文節ベクトル表現, 言語処理学会第 24 回年次大会発表論文集 (2018)
- [内元 99] 内元清貴, 関根聡, 井佐原均 他:最大エントロピー 法に基づくモデルを用いた日本語係り受け解析, 情報処理学 会論文誌, Vol. 40, No. 9, pp. 3397–3407 (1999)

<sup>\*2</sup> T-24 では「図1のように,…広がり,」、「私たちの目に直接届く か,」、「何かに…目に届く。」という3つの節に分けられるが、最初 の節は後ろの2つの両方に意味的に係るので、(A (B C))のパター ン。P-24 は節が順番に接続しているので、((A B) C)のパターン。

# IoT デバイスのための深層学習を用いた自動販売機の購入商品の識別 Vending Machine Drink Recognition with Deep Learning for IoT Device.

| 新屋勝啓 <sup>*1</sup> | 長隆之 <sup>*2</sup> | 山岡成光 <sup>*2</sup> | 西和彦 <sup>*2</sup> | 中尾政之 *2        |
|--------------------|-------------------|--------------------|-------------------|----------------|
| Katsuhiro Araya    | Takayuki Osa      | Shigemitsu Yamaoka | Kazuhiko Nishi    | Masayuki Nakao |
| *1 44-5-0 41       |                   | *2 ++              |                   |                |

\*1 株式会社 Arkth Arkth, Inc. <sup>2</sup> 東京大学大学院工学系研究科 University of Tokyo, School of Engineering

In recent years, Internet of Things (IoT) with deep learning is used for various purposes. The balance of edge computing, data traffic, cloud computing and data volume is important for IoT. In this study, we present a framework that automatically recognizes bottles purchased from a vending machine in camera images with a convolutional neural network (CNN).

# 1. はじめに

近年 IoT と深層学習の連携が様々な用途や分野で活用され 始めている.しかし現状ではデバイス,ネットワーク,深層学習 による認識率など様々な面で課題があり、多くの研究者によっ て多岐にわたり研究されている. 例えば一般的に IoT デバイス は大量に利用されるため、なるべく安価に構築する必要がある. しかし、安価なデバイスではスペックが低くなるため、計算量の 大きい分析については制限がかかってしまう. そのため, 深層 学習による計算量を削減するための前処理やアルゴリズムの調 整, ハードウェアの構成の改善などを行う必要がある. さらに, IoT デバイスが増えるとネットワークへの負荷も高くなるため、な るべく少ない通信コストで動作させる必要がある. サーバーに蓄 積するデータも IoT デバイスの量に比例して増加するためデバ イス側でデータ圧縮や分析を行いたい. このように IoT と深層 学習の連携では, エッジ AI コンピューティング, ネットワークの 転送量, クラウドでのデータ蓄積と分析の強調を, 認識率やデ バイスの価格などとの兼ね合いを鑑みてどのように設定するか が重要である.

IoT と深層学習を連携したシステムの中でも、本研究では近 年増加している自動販売機での購入者や購入商品の分析に着 目してシステムを構築する.

現状の自動券売機の購入動向の分析システムでは店舗や機器に改修を加えたり入れ替えたりする必要があるため、導入コストが高い課題がある。本研究で構築するシステムは既存の機器の内部に改修を加えること無く、安価で外付けできることを特徴として開発を進めている。

本稿ではそのシステムの中でも特にエッジ AI コンピューティングによる飲料の分類に着目し、安価で低スペックなデバイスと 深層学習を用いて飲料自動販売機に設置したカメラから撮影された動画像中の購入商品を認識することを目的としている.

# 2. 本システムの全容

本システムでは購入者の年齢・性別と購入商品を認識すると 共に、気象センサによる気象情報を取得してクラウドに保存する. ネットワークには LoRaWAN を利用することを前提としているた め、通信するデータは飲料 ID や年齢、性別フラグ、気温など 最低限となるようにエッジで分類を行う.

また、本システムでは購入者にリアルタイムに広告表示など のインタラクションを行うため、ディスプレイや表示用のデバイス

連絡先:新屋勝啓,株式会社Arkth, info@arkth.co.jp

を設置し、クラウドから最新のデータを取得できるようにする. 図1に本システムのシステム構成を示す.



図1システム全容の構成図

# 3. 飲料の認識

#### 3.1 デバイスについて

図 1 左側のセンサー情報の取得や,飲料の分類,サーバー へのデータ転送には Raspberry Pi 3 Model B+を利用した.気 象センサに BME280 を利用し,温度・湿度・気温の3つの環境 情報を取得できる.カメラは購入者の撮影と飲料の撮影用にそ れぞれ設置し,購入者撮影用には広角に撮影できるカメラを利 用した.

### 3.2 飲料の認識

本研究では、深層学習を用いた物体検出技術を用いる。 ニ ューラルネットワークは Single Shot Multibox Detector (SSD) を 採用し[Liu 16]、深層学習のフレームワークとして TensorFlow を利用した. SSD はニューラルネットワークの構造に VGG16 [Simonyan 14]を用いた手法であり、入力画像が小さくても高い 精度の物体検出が可能である.

#### 3.3 認識の前処理

自動販売機の取り出し口に向けて設置したカメラから SSD に よって飲料を認識する際に,背景を飲料に誤認識するフレーム が多く発生した(図 2).

そこで本手法では、認識範囲のトリミングを行うと共に、背景 差分によって取り出し動作の検出を行った.

具体的には 320x240 の画像を用いた場合,取り出し口付近 の背景差分を用いて取得した動きのあったピクセル数が一定の しきい値を超えた場合に飲料の認識を行うようにした.これによ り認識を軽減すると共に,認識を行うフレーム数を削減できる.

背景差分を取得する範囲も図2に矩形で示す.

# 3.4 学習データのデータオーギュメンテーション

自動販売機に設置したカメラから取得される画像は,設置場所や時間,気象条件によって明るさが様々に変化する(図 3). そこで,学習データに対してデータ拡張を行った.データの拡張はノイズ追加,コントラスト調整,ガンマ変換による明るさ調整,



図2背景の誤認識と背景差分取得範囲

#### 4. 実験

### 4.1 自動販売機とカメラの設置

本実験に利用する自動販売機は、大学構内の屋根のある屋



外に設置した. 飲料認識用のカメラ は図 3 のように, 自動販売機前面に 取り出し口付近を撮影するように設 置した. カメラは Raspberry Pi 用のカ メラモジュールを用いた.

動画撮影時のフレームレートは設 定やプログラム上では 20FPS と設定 しているが、デバイスのスペックによ る制限によって実際は 7~8FPS とな った.

図3飲料認識用カメラの設置

# 4.2 学習データの取得

19種類の飲料を対象に自動販売機の取り出し口に向けたカメラから、手に持った飲料の画像を収集した.

背景による影響を考慮し、過学習を避けるために屋内の白い 背景で取得した学習データも追加し学習を行った.



学習データは各飲料で 100 枚ずつ程度取得した. その後データオーギュメンテーションを用いて各画像を 13 枚変換し合計 26600 枚を学習データとして利用した.

図4学習データ例

# 4.3 実験結果

飲料が写っている画像を19種類の飲料ごとに100枚ずつ検 証に利用した.その結果を下の表にまとめる.

| 合計画像数 | 正認識数      | 誤認識数    | 未検出数    |
|-------|-----------|---------|---------|
| 1900  | 1651(87%) | 137(7%) | 112(6%) |

飲料ごとの認識率では、緑茶や烏龍茶などのお茶系の認識 率が低く、一方で缶コーヒーなどの缶飲料の認識率が高い傾向 があった.これはお茶系の飲料は外観の色味が似ている物が 多いのに対し、缶コーヒーなどはパッケージの色彩などの差異 が大きいためと考えられる.

また、1枚の画像から飲料を認識するのに、Raspberry Pi 3B+ では 10 秒程度を要した.

# 5. 結果の考察

上記の通り本実験では 85%を超える認識率を達成した.しかし、本システムの狙いは様々な環境や種類の自動販売機に設置して、エッジ AI コンピューティングにより分析を行うことである.

本実験では1箇所に設置した自動販売機で同じ季節に撮影 したデータが多いため、様々な環境に設置した自動販売機で 認識を行った場合よりも高い認識率が出ていると予想される.

また,自動販売機の飲料は無数に存在すると共に,商品ラインナップの入れ替えや商品ラベルの変更も数多く発生するため 環境の変化だけでなく商品の多様性にも対応する必要がある. 本実験は深層学習やデバイスの実装に加え,学習データの取 得に多くの手間がかかった点も今後の課題である.

市販されている飲料はメーカーにラベルやボトルのデータが あるため, 今後は Zero shot Learning や Few Shot Learning[Sachin 17]の模索も重要となる.

# 6. まとめ

本稿では IoT デバイスによる飲料認識の手法を提案し,実験 を行った.その結果,限定的な環境であれば安価なエッジデバ イスで高い認識率を実現できた.今後,更に多くの環境や飲料 で検証を進めると共に学習データを集め,ハイパーパラメータ のチューニングや本手法で用いた以外のデータオーギュメンテ ーション, Few Shot Learning などの学習手法の研究を進める.

また,深層学習による画像認識は顔や動物などの認識についての先行研究が多く,飲料に特化した文献はあまり見られなかった.しかし,今後の IoT の拡大につれてあらゆるものやことを認識する需要が増えてくると予想できるため,様々な物体検出に応用できる手法を目指していく.

### 謝辞

本研究に利用した自動販売機は株式会社伊藤園の協力に より設置いただきました. 心より感謝申し上げます.

### 参考文献

[Simonyan 14] Karen Simonyan and Andrew Zisserman: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.

[Liu 16] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., and Berg, A. C.: Ssd: Single shot multibox detector, in European conference on computer vision, pp. 21-37Springer (2016)
# 多人数会話システムのための 話者の状態変化に頑健な注視状態検出

Robust Eye Contact Detection for Multi-Party Conversational Systems

野川賢二郎<sup>\*1</sup> 藤江真也<sup>\*2</sup> 小林哲則<sup>\*1</sup> Kenjiro Nogawa Shinya Fujie Tetsunori Kobayashi

\*<sup>1</sup>早稲田大学 \*<sup>2</sup>千葉工業大学 Waseda University Chiba Institute of Technology

Eye contact detection method for multi-party conversational systems is proposed. Detecting eye contact is an important function for multi-party conversational systems because eye concatact is an essential cue for deciding whether system should respond to a user utterance or not. Accuracy of a conventional eye contact detector given a single frame decreases because of various noises (e.g. blink, facial expression change, etc.) occured in real-time environment. The eye contact detection method that utilizes multiple frames is proposed for solving this problem. The system extract the feature for detecting eye concact by CNN from the image contains both eyes of a target user. Then, the feature is given to LSTM with attention mechanism as an input. The result of the experiment conducted using the gaze data in multi-party conversation shows effectiveness of the proposed method.

# 1. はじめに

多人数会話システムにおいてユーザのシステムに対する注 視状態を検出する手法について検討する.

近年,スマートスピーカや会話ロボットなどの対話システム が普及している. これらのシステムは主に一対一の対話を扱う ものであるのに対し, 複数人が会話に参与するような環境で動 作する多人数会話システムの研究が行われている.多人数会 話システムにおいて、視線はシステムがユーザの振る舞いを 理解する上で重要な情報を与える.多人数会話システムでは, ユーザの発話がシステムに向けたものか、そうでないかを識 別する必要があり,会話システムの分野で応答義務推定(受話 者推定)という問題として研究が行われている.応答義務推定 において, ユーザがシステムのことを注視しているか(注視状 態かどうか)という情報が精度の向上に寄与することが報告 されている. Turnhout らは応答義務推定において, ユーザが システムのことを注視しているか(注視状態かどうか)を人手 でアノテーションして特徴量として用いることで精度が向上 すると報告した [Van Turnhout 05]. 実際の会話システムを動 かすためには注視状態を自動検出が必要となる.視線の代用 として比較的推定が簡単なユーザの顔向きが用いられてきた [Shriberg 12, Tsai 15, 馬場 13, 杉山 16]. しかし, 多人数会 話において、ユーザの顔向きを視線の近似として用いることは 不十分であると報告されている [Vrzakova 16]. 以上のことか ら,多人数会話システムにおいて注視状態を自動で検出する技 術は重要である.

画像処理の分野において、アイコンタクト検出に関する研究 が行われてきた.アイコンタクト検出では、ノイズのない単一 の画像から虹彩が対象物体に向けられているかどうかを識別す る.Fujie らは会話ロボットでの利用を目的に対象者の目画像 を入力とするアイコンタクト検出器を PCA や LDA などの次 元圧縮法と Gaussian Mixture Model の組み合わせにより構 築した [Fujie 06].また、Smith らはアイコンタクト検出タス

連絡先:野川賢二郎,早稲田大学 理工学術院 知覚情報システム研究室,〒162-0042 東京都新宿区早稲田町 27, nogawa@pcl.cs.waseda.ac.jp
 (所属先は執筆・投稿時 2019 年 2 月のもの)

クのためのデータセット (Columbia Gaze Data Set)を公開 し PCA と MDA による次元圧縮と線形 SVM による手法を提 案した [Smith 13].また,Parekh らは Convolutional Neural Network (CNN)を用いた手法を提案した [Parekh 17].ア イコンタクト検出では、ノイズのない単一の画像から虹彩が対 象物体に向けられているかどうかを識別する.一方、会話シス テムの利用時には、前処理の段階で生じるノイズ (顔検出の失 敗,顔特徴点推定の誤差)や話者の状態変化によるノイズ (ま ばたき、表情の変化、動きによるブレ)が生じるため、単一の 画像を入力とする手法では注視状態を検出するのは難しい.

そこで本研究では、多人数会話システムにおいて注視状態 を高精度に検出することを目的とし、過去の入力画像を利用す ることでノイズに対して頑健に注視状態を検出する手法を検討 する.

本稿では,2.で提案手法である画像系列を入力とする注視 状態検出手法を説明する.3.では会話中の視線データの収集 方法とデータの詳細を述べる.4.では収集したデータを用い た注視状態検出の実験結果を報告する.最後に,5.で本研究 のまとめを述べる.

# 2. 画像系列を入力とする注視状態検出器

時々刻々と入力される画像を逐次処理し,その都度過去の履 歴を考慮してユーザの注視状態を検出するシステムを構築し た.まず,入力された全方位画像から前処理を経て人の目元の 画像を抽出する.次に,得られた目元の画像を Convolutional Neural Network (CNN) に入力し,その中間層にある画像特徴 量を Long-Short Term Memory (LSTM) に入力する.LSTM の現在の中間状態から,過去の状態に対する注意重みを計算 し,中間状態と注意重みの重み付き和で得られたベクトルから 注視状態を検出する.システムの全体像を図1に示す.以下, 前処理 (図 1.a) と注視状態検出 (図 1.c) ついて説明する.

### 2.1 前処理

まず全方位カメラによって撮影された全方位画像を極座標変 換によりパノラマ展開する.得られたパノラマ画像から人物領 域を切り出す.次に,人物領域から顔領域の検出を行い,領域 を元に 68 点の顔特徴点の検出を行う.顔領域と顔特徴点の検



図 1: 画像系列を入力とする注視状態検出器のシステム概要図.入力画像に対して前処理を行い (a), CNN の入力とする. CNN の全結合層 (fc2) で出力された値を LSTM に入力する (b). LSTM の中間層から履歴に対する注意重みを計算した後, 履歴と注 意重みによる重み付き和を全結合層の入力とし,注視状態検出結果を出力する (c).

出には機械学習ライブラリである dlib<sup>\*1</sup> を利用した. 推定さ れた顔特徴点の両目尻と鼻の先端の3点を元に顔領域画像に 対してアフィン変換を適用する. アフィン変換された顔画像か ら両目部分の画像領域を切り出す. 切り出した両目領域画像に 対してグレースケール化とヒストグラム平坦化を行う. 以上の 方法により得られた両目領域画像を CNN の入力とする.

# 2.2 識別器

識別器として注意機構を持ったLSTMを用いる.会話中に 生じるノイズに対して頑健に注視状態を検出するためには,ノ イズらしきものが入力された場合は,入力による状態の更新 をせずに過去の状態を引き継ぎ,ノイズでないものが入力さ れた場合は,状態を更新するといった処理が必要だと考えられ る.LSTM は忘却ゲートと入力ゲートを持つため,入力と状 態に応じた状態の更新を学習することに適している.そのた め,LSTM を用いることでノイズに対して頑健に注視状態を 検出することができると考えられる.また,会話中に生じるノ イズは,種類ごとに継続する長さが異なる.例として,まばた きは平均で100-150 ミリ秒なのに対し,表情の変化は数秒継 続する.そこで,LSTM に注意機構を持たせ,現在の状態に 応じた過去の状態利用方法を明示的に学習させることにより, 多様なノイズに頑健に注視状態を検出することを期待する.

# 3. 視線データ収集

本研究では,複数人のユーザがダイニングテーブルに設置 されたスピーカ型会話システムを含めて会話を行い,意思決定 を行う状況を想定してデータ収集を行った.

今回は、会話システムとして Amazon 社製の Amazon Echo\*<sup>2</sup>を用いた. Amazon Echo の上部に全方位カメラを設 置して会話中のユーザの様子を撮影した. 会話参加者に対し て,他の会話参加者と Amazon Echo と会話しながら指定さ れたタスクを遂行するようにあらかじめ指示した. タスクとし

\*1 http://dlib.net/

て、会話参加者同士で観に行く映画を決定するタスクと外食に 行く先の飲食店を決定するタスクの2種類を用意した.1タス クにつき、少なくとも2回はスピーカに対する質問を行うよ うに指示を行った. 会話が滞ることを防ぐために, 各タスクご とに Amazon Echo への質問例を会話参加者に対してあらか じめ提示した.また、ファシリテータが会話に参加した.ファ シリテータは会話が滞った場合に会話参加者に対して質問を行 うなど、円滑にタスクが進むように行動を行った. それ以外の 場合は他の会話参加者と同様にタスクに取り組んだ.ファシリ テータの振る舞いは他の対話参加者と異なるため注視状態の検 出対象から除外した.研究室の学生13人を5グループに分割 し, それぞれのグループにつき2つのタスクに取り組んでも らい合計 42 分のデータを収集した.1人のアノテータが,撮 影した動画データに対し, 各会話参加者が会話システムを注視 しているかどうかのアノテーションを行った. アノテーション の際に、以下の点を注意してラベルを付与した. 会話参加者が システムを注視している状態でまばたきをして、まばたきのあ とも注視している場合はまばたきの区間を含めて注視状態とし た.これは、まばたきはあくまでも一時的に目を閉じているの であり,会話参加者の注意はシステムに向けられているためで ある.一方,会話参加者がシステムを注視している状態でまば たきをして、まばたきのあとはシステムを注視していない場合 は瞬きの前までを注視状態とした.

会話視線データセットに加え,単一画像を入力とする注視検 出器を事前学習するための視線データセットを収集した.視線 データセットは,多様な顔形状,顔向き,注視点を含むデータ セットである.会話視線データセットと同一の環境に,複数の 注視点を設置し,収集対象者が注視点を注視しながら顔を動か している様子を,Amazon Echo上部に設置された全方位カメ ラで動画撮影をし,収集を行った.カメラのレンズを注視して いる動画とスピーカに設置された注視点を注視している動画を 正例,その他の注視点を注視している動画を負例とした.研究 室の学生17人を対象にデータを収集し,正例画像が4955枚, 負例画像が9479枚となった.

両データセット共に Kodak 社製の全方位カメラである PIX-

<sup>\*2</sup> https://www.amazon.co.jp/dp/B071ZF5KCM/

PRO SP360 4K <sup>\*3</sup> を用い,フレームレート 30fps, 解像度は 2880 × 2880 で撮影を行った.

# 4. 会話視線データセットにおける注視状態検 出実験

提案手法の有効性を調査するため,以下の4種類の手法で 比較を行った.評価指標としてF値とAUC (Area Under the Curve)を用いた.

- CNN: 視線データセットを用いて学習した CNN. 過去の フレームの情報は利用しない.
- CNN Average: 視線データセットを用いて学習した CNN を利用し,過去の xフレーム分の結果の平均を出力とする.
- CNN-LSTM: 視線データセットを用いて学習した CNN の全結合層のベクトルを入力とする LSTM を会話視線 データセットを用いて学習する.
- CNN-Attention LSTM: 視線データセットを用いて学習した CNN の全結合層のベクトルを入力とする注意機構付き LSTM を会話視線データセットを用いて学習する.現在のフレームを入力したときの LSTM の中間層のベクトルから過去 w フレームに対する注意重みを決定する.

### 4.1 実験条件

4つの全ての手法において,視線データセットを用いて CNN の学習を行った. 全 17 人分の視線データセットの 14 人分を 学習,1 人分を検証,2 人分をテストに用いた. CNN-LSTM と CNN-Attention LSTM において,全5 グループ分の会話 視線データセットの3 グループ分を学習,1 グループ分を検 証,1 グループ分をテストに用いた.会話視線データセットの テストデータ中に含まれる人は,視線データセットの学習デー タと検証データには含まれていない.CNN-LSTM と CNN-Attention LSTM の学習時は CNN の重みは固定した.また, CNN Averageのxは会話視線データセットの学習データと検証 データでもっとも AUC が高い3を採用した.CNN-Attention LSTM のwは会話視線データセットの検証データでもっとも AUC が高い32 を採用した.

### 4.2 実験結果

各手法のテストデータでのスコアを表1に示す.詳細な分 析を行うために,会話中に生じうるノイズである,瞬き,表情 の変化,顔検出の失敗が生じている時間付近に対する各手法の 推定結果と,平常時と,各ノイズ発生時の注意重みを可視化し たものをそれぞれ図2,図3,図4に示す.

画像系列を入力とする全ての手法 (CNN Average, CNN-LSTM, CNN-Attention LSTM) が、単一画像を入力とする手法 (CNN)の精度を上回っていることから、画像系列を入力と することの有効性が示された.

表1より, CNN-LSTM が CNN Average のスコアを上回っ ている. 図2より, CNN-LSTM が CNN Average に比べて ノイズである瞬きの画像が入力された場合でもうまく推定でき ていることがわかる.また図3より,表情が変化している入力 が比較的長期に渡って入力された場合でも CNN-LSTM がう まく推定できていることがわかる.以上より, LSTM によっ 表 1: 会話視線データセットにおける各手法の正しい例の F1 スコアと AUC

| 手法                        | F1 値  | AUC   |
|---------------------------|-------|-------|
| CNN                       | 0.831 | 0.923 |
| CNN Average               | 0.847 | 0.938 |
| CNN-LSTM                  | 0.880 | 0.958 |
| <b>CNN-Attention LSTM</b> | 0.880 | 0.960 |

て状態を保持し,過去の入力の情報を利用することによりノイズに頑健な注視推定が行えることが確認できた.

表1より,AUCにおいて CNN-Attention LSTM の精度 が CNN-LSTM の精度を上回っている.図3より,ユーザの 表情が変化している区間において,CNN-Attention LSTM が CNN-LSTM に比べてうまく推定できていることがわかる.ま た,図4より,顔検出が失敗している区間において,CNN-Attention LSTM が他の手法に比べてうまく推定できている ことがわかる.どの時点での履歴を利用するかを明示的に扱う 注意機構の有効性が確認できた.

CNN-Attention LSTM と CNN-LSTM の精度差が小さい 原因として,状態の推定に必要な履歴情報が LSTM のゲート 機構によってうまく保持できていることが考えられる.図 2, 3 の注意重みの可視化結果を見ると平常時とノイズ発生時の両 者の現在の状態に対する重みが高い.対して,図 4 の注意重 みの可視化結果を見るとノイズ発生時の現在の状態に対する重 みが低くなり,過去の状態に対する重みが上昇している.以上 のことから多くの場合において LSTM のゲート機構によって 状態の推定に必要な履歴情報が保持できるが,顔検出の失敗な どの特殊な場合において注意機構が有効に作用すると考えら れる.

# 5. まとめ

本研究では、多人数会話システムにおいて注視状態を高精 度に検出することを目的とし、過去の入力画像の情報を利用す ることでノイズに対して頑健に注視状態を検出する手法を検討 した.提案手法の有効性を検証するために、会話中のユーザの 視線データを収集し、収集したデータを用いて実験を行った. 評価実験の結果、画像系列を入力とする手法が、単一画像を入 力とする場合に比べて精度が向上した.LSTMを利用した手 法と Attention LSTM を利用した手法は、過去の画像の注視 状態検出結果の平均を出力とするベースライン手法よりも良い 結果となった.また、LSTM に注意機構を持たせ、入力に応 じた履歴の利用方法を明示的に学習させることにより、精度が 向上することが確認できた.詳細な分析の結果、会話中に生じ るノイズである、瞬き、表情の変化、顔検出の失敗が生じた場 合において、提案手法がベースライン手法に比べて頑健に注視 状態を検出できることがわかった.

<sup>\*3</sup> https://kodakpixpro.com/AsiaOceania/ jp/cameras/vrcamera/sp3604k/



図 2: ユーザが瞬きをしている時間付近における各手法の注視 状態検出結果.灰色部分がユーザが瞬きをしている時間. 下部は①,②時点での過去 32 状態に対する注意重みを可視化 したもの.



図 3: ユーザの表情が変化している時間付近における各手法の 注視状態検出結果.灰色部分がユーザの表情が変化している時 間.下部は①,②時点での過去 32 状態に対する注意重みを可 視化したもの.



図 4: 顔検出に失敗している時間付近における各手法の注視状 態検出結果.灰色部分が顔検出に失敗している箇所.下部は①, ② 時点での過去 32 状態に対する注意重みを可視化したもの.

# 参考文献

- [Fujie 06] Fujie, S., Yamahata, T., and Kobayashi, T.: Conversation Robot with the Function of Gaze Recognition, in 2006 6th IEEE-RAS International Conference on Humanoid Robots, Genova, Italy, December 4-6, 2006, pp. 364–369 (2006)
- [Parekh 17] Parekh, V., Subramanian, R., and Jawahar, C. V.: Eye Contact Detection via Deep Neural Networks, in HCI International 2017 - Posters' Extended Abstracts - 19th International Conference, HCI International 2017, Vancouver, BC, Canada, July 9-14, 2017, Proceedings, Part I, pp. 366–374 (2017)
- [Shriberg 12] Shriberg, E., Stolcke, A., Hakkani-Tür, D. Z., and Heck, L. P.: Learning When to Listen: Detecting System-Addressed Speech in Human-Human-Computer Dialog, in *INTERSPEECH 2012, 13th Annual Confer*ence of the International Speech Communication Association, Portland, Oregon, USA, September 9-13, 2012, pp. 334–337 (2012)
- [Smith 13] Smith, B. A., Yin, Q., Feiner, S. K., and Nayar, S. K.: Gaze locking: passive eye contact detection for human-object interaction, in *The 26th Annual ACM* Symposium on User Interface Software and Technology, UIST'13, St. Andrews, United Kingdom, October 8-11, 2013, pp. 271–280 (2013)
- [Tsai 15] Tsai, T. J., Stolcke, A., and Slaney, M.: A Study of Multimodal Addressee Detection in Human-Human-Computer Interaction, *IEEE Trans. Multimedia*, Vol. 17, No. 9, pp. 1550–1561 (2015)
- [Van Turnhout 05] Van Turnhout, K., Terken, J., Bakx, I., and Eggen, B.: Identifying the intended addressee in mixed human-human and human-computer interaction from non-verbal features, in *Proceedings of the 7th international conference on Multimodal interfaces*, pp. 175– 182ACM (2005)
- [Vrzakova 16] Vrzakova, H., Bednarik, R., Nakano, Y. I., and Nihei, F.: Speakers' head and gaze dynamics weakly correlate in group conversation, in *Proceedings of the Ninth Biennial ACM Symposium on Eye Tracking Research & Applications*, pp. 77–84ACM (2016)
- [杉山 16] 杉山貴昭, 船越孝太郎, 中野幹生, 駒谷和範:多人数 対話におけるユーザの状態に着目したロボットの応答義務の 推定,人工知能学会論文誌, Vol. 31, No. 3, pp. C-FB2\_1-9 (2016)
- [馬場 13] 馬場直哉, 黄宏軒, 中野有紀子: 人対会話エージェ ントとの多人数会話における頭部方向と音声情報を用いた 受話者推定機構, 人工知能学会論文誌, Vol. 28, No. 2, pp. 149–159 (2013)

# 画像列を用いた小惑星形状・探査機相対運動の逐次推定

Succesive estimation of the asteroid shape and probe motion using sequential images

鈴木 透馬<sup>\*1</sup> 矢 Toma Suzuki 7

矢入 健久 \*1 <sub>Takehisa</sub> Yairi 武石 直也<sup>\*1</sup> 津田 雄一<sup>\*2</sup> Naoya Takeishi Yuichi Tsuda 尾川 順子 \*2 Naoko Ogawa

\*<sup>1</sup>東京大学 The University of Tokyo \*2宇宙航空研究開発機構

Japan Aerospace Exploration Agency(JAXA)

In order for a probe to safely land on an asteroid, it is necessary to select the landing point and navigate the probe based on information of the asteroid shape and the probe motion. The procedures for extracting such information from images taken by the probe is called global mapping. In the Hayabusa project of JAXA, the global mapping was conducted with much manual manipulation. As the manual global mapping is too costly, automating the procedures is strongly desired in the future projects. In this paper, we propose a new approach for the automation of global mapping by using the technique of image recognition and robotics. Throughout the experiment using the dataset provided by JAXA, we checked the validity of the method which we proposed.

# 1. はじめに

太陽系には小惑星と呼ばれる小さな天体が無数に存在して いる.小惑星は太陽系初期の情報を持っている「始原天体」と され、太陽系の誕生や進化、そして我々生命がどのようにして 生まれてきたのかを知る大事な手がかりの一つとされている.

小惑星探査ミッションでは探査機を精密に誘導したり,安全 に小惑星に着陸させるために小惑星の詳細な形状と運動を把握 するグローバルマッピングと呼ばれる作業が不可欠である.し かし,それらの情報はミッション開始段階では未知なことがほ とんどであり,宇宙航空研究開発機構による「はやぶさ」,「は やぶさ2」プロジェクトでは探査機が小惑星付近に到着して から人間が手動で小惑星画像を解析し Ground Control Point と呼ばれる地点を多数設定することで小惑星の形状や探査機 の姿勢の推定を行った [Shirakawa 06].この作業は多大な人的 資源及び時間を消費するものであるため,この作業の自動化は 今後の小惑星探査ミッションを円滑に行う一助となり得ると考 える.

本研究ではグローバルマッピングの自動化に関する新たな アプローチを提案することを目的としている.提案手法では 探査機の位置姿勢及び小惑星の相対運動パラメタについては Extend Kalman Filter(EKF)を用いて確率的に推定し,小惑 星形状を Point Cloudを用いて確定的に表現し,小惑星形状に よる制約を用いて Adaptive Moment Estimation(Adam)に よる逐次最適化を行うことで過去に提案された手法と比較し て精度を多少落としながらも高速に大規模な点群を推定する. 提案手法の有効性を示すために小惑星探査機「はやぶさ2」が 撮影した小惑星「リュウグウ」の複数の画像列を用いて実験を 行った.実験の結果,本手法のアプローチが有効であることを 確認した.

# 2. 問題設定

2.1 グローバルマッピングの流れ

グローバルマッピング全体の大まかな流れとしては以下のようになる.

連絡先: 鈴木透馬,東京大学 知能工学研究室,tomaaerospace@g.ecc.u-tokyo.ac.jp

- 小惑星全体を俯瞰出来るような位置に探査機を誘導し、画像を多数枚撮影することで小惑星全体が含まれるような 画像列を得る.
- 2. 画像に対して何らかの特徴量を考えることで、画像間の 点と点の対応付を考える.
- カメラの観測モデルや小惑星及び探査機のダイナミクス について検討することで、小惑星の形状及び探査機の相 対運動を推定する。

本論文では1の工程は満足されているとし、2,3の工程に ついて検討する.2の工程については高速かつ高精度な Scale-Invariant Feature Transform (SIFT) 特徴量 [Lowe 04] を考 えることで行う.グローバルマッピング作業全体を効率化する ためには3の工程の効率化が特に重要である.小惑星形状及 び探査機相対位置が未知である場合,両者はカメラを介した非 線形な観測を通して相互に依存するため、全体を最適化するこ とは大規模な非線形最適化問題となっている.

### 2.2 本研究における問題設定

上記を踏まえ,本研究では以下の入出力を行うアルゴリズ ムの作成を問題とする.

表 1: 提案アルゴリズムの入出力関係

| Input:  | 一定間隔で撮影された小惑星の画像列     |
|---------|-----------------------|
| Outrati | 各時刻の探査機の相対位置姿勢、小惑星形状、 |
| Output: | 小惑星のスピン軸,小惑星の相対角速度    |

なお,小惑星形状についてはポイントクラウドを用いて表 現する.

さらに、本研究では推定対象に関する制約条件として以下 の3点を設けるものとする.

- 1. 探査機は小惑星赤道上空一定高度を小惑星に対して一定 の姿勢を保ち周回するように制御されている.
- 2. 小惑星は球形に近い形状である.



図 1: 本問題のモデル

3. 小惑星は非タンブリングである.

仮定1については探査機が小惑星全体を初期観測する際に 全域を最も効率良く観測することが出来る条件であり,妥当な 仮定であると考えられる.仮定2については実際に存在する 小惑星の中でもそのような条件を満たすものは数多く存在し, ここではそのような制約を置いても大きな問題にはならないと 考える.仮定3については本手法は画像列のみを入力とする推 定を考えているが,仮定1の制約を満たして撮影された画像列 のみからでは小惑星がタンブリングしているかを判断すること は難しく,本研究では小惑星がシングルスピンであるという仮 定を置くこととする.

# 3. 提案手法

本研究では従来手法に比べ高速かつ一定の精度を保ち推定を行うアルゴリズムとして「Adaptive Moment Estimation(Adam)[Kingma 14]による小惑星形状の局所最適化とExtended Kalman Filter(EKF)による推定を用いた小惑星形状及び探査機の相対運動の逐次推定」を提案する.

### **3.1** 提案手法の流れ

提案手法全体の流れは以下の通りである.

- 1. Adam による観測の最適化.
- 2. EKF による小惑星形状パラメタを除く状態変数の推定.
- 3. 三次元形状の再復元.
- 4. 剛体制約による形状の最適化.
- 5.1から4を時系列入力に対して繰り返し適用する.

以下では、手順1から4についての概要を述べる.なお、世 界座標系は初期時刻におけるカメラ座標系と一致させた.すな わち、初期時刻の観測の画像座標系の x 軸、 y 軸を世界座標 系の x 軸、 y 軸とし、その時のカメラの光軸方向に z 軸を取 るような系を考えるものとした.今回の問題においては小惑星 は世界座標系の一点に固定されており、探査機が世界座標系に おいて小惑星周囲を円運動するようなモデルを考えることに なる. 3.2 各ステップの概要

#### **3.2.1** Adam による観測の最適化

まず,時系列に沿って画像が入力されるごとに SIFT 特徴 量を用いた画像特徴点のマッチングを行う. 観測モデルにピン ホールカメラを採用することでエピポーラ幾何を利用してカメ ラの位置関係及び各カメラ座標系における画像特徴点の三次 元位置が復元される.しかし,この観測には SIFT 特徴量の誤 マッチング等に起因する誤差が含まれていると考えられるので 以下の方法によって観測値を補正する.



図 2: 連続する観測から復元された小惑星の部分形状

観測について i 番目の観測と i+1 番目の観測による復元 (復 元 i) と, i+1 番目の観測と i+2 番目の観測による復元 (復 元 i+1) を考える. それぞれの三次元復元についてスケール は任意であるから,復元 i と復元 i+1 スケール比を表す変数 を  $s_i$  とする.また,世界座標系におけるある点 z の i 番目の カメラ座標系における表示を  $z_i$  と書くことにし,観測より得 られる 2 つのカメラ座標系の変換を  $R_i$ ,  $t_i$  とすると理想的に は次の関係式が成立する.

$$s_i \boldsymbol{z}_{i+1} = R_i^T (\boldsymbol{z}_i - \boldsymbol{t}_i) \tag{1}$$

そこで、連続する観測の両方で検出された点全体について以下 の誤差関数を最小化する観測値 $R_i$ ,  $t_i$  及び $s_i$ を考えること で観測値を補正する.このように最適化する対象を各座標系の 変換のみに絞り、各復元内の点の相対関係は固定することで計 算量を削減している.

$$I_{1} = \frac{1}{2} \sum \|s_{i} \boldsymbol{z}_{i+1} - R_{i}^{T} (\boldsymbol{z}_{i} - \boldsymbol{t}_{i})\|_{2}$$
(2)

最適化には Adam を用いる.

上記のようにして補正された値を探査機の変位及び小惑星 形状の観測値とする.また,仮定2より補正された点群がある 球面付近に位置していると考え以下の誤差関数を最小とする座 標を考えることで小惑星の重心 *c*<sub>i</sub> を観測するものとする.

$$I_{center} = \frac{1}{N} \sum (r_{ave} - \left| \boldsymbol{Z}_i - \boldsymbol{c}_i \right|)^2$$
(3)

$$r_{ave} = \frac{1}{N} \sum \left| \mathbf{Z}_i - \mathbf{c}_i \right| \tag{4}$$

小惑星の相対角速度 ω<sub>i</sub> については探査機が各時刻において局 所的に小惑星重心に対して円運動していると考えることで以下 の式より観測するものとする.

$$\boldsymbol{v}_i = \boldsymbol{t}_i - \boldsymbol{c}_i \tag{5}$$

$$\omega_i = \frac{\boldsymbol{v}_i \cdot \boldsymbol{t}_i}{|\boldsymbol{v}_i||\boldsymbol{t}_i|} \tag{6}$$

なお (2), (3), (4) における総和は連続する観測の両方で検 出された点に関する総和を意味し, N はそのような点の個数 である.

## 3.2.2 EKFによる小惑星形状パラメタを除く状態変数の推定

ここでは拡張カルマンフィルタを用いて状態量の更新を行う. 観測方程式としては上述の式を用いることとする. 姿勢表 現に関しては簡単のため R をオイラー各表現 α, β, γ (順 に y, x, z 軸周りの回転)に分解して考える.本問題では問 題設定で述べた制約条件より探査機の取りうる姿勢は大まかに 限定されているのでオイラー角による表現を用いても姿勢表現 に問題はない.

状態遷移方程式としては、同様に制約条件より探査機は各時刻で小惑星重心に対して等速円運動しようとしているとモデ ル化出来るため、次のものを用いる.状態の表現は全て世界座 標系における表現である.r は各時刻における円軌道の半径の 推定値、Δy は探査機が軌道面から遠ざからないための位置に 関する制御を仮想的にモデル化したものである.

 $x_{i+1} = x_i - r_i \sin \omega_i + w_{x,i} \tag{7}$ 

$$y_{i+1} = y_i + \Delta y_i + w_{y,i} \tag{8}$$

$$z_{i+1} = z_i - r_i (1 - \cos \omega_i) + w_{z,i} \tag{9}$$

$$\boldsymbol{c}_{i+1} = \boldsymbol{c}_i \tag{10}$$

$$\alpha_{i+1} = \alpha_i + \omega_i + w_{\alpha,i} \tag{11}$$

$$\beta_{i+1} = \beta_i + w_{\beta,i} \tag{12}$$

 $\gamma_{i+1} = \gamma_i + w_{\gamma,i} \tag{13}$ 

$$\omega_{i+1} = \omega_i \tag{14}$$

wは状態遷移ノイズを表す.

上記の状態遷移モデルは本来の物理モデルを正確に反映し ているものであるとは言えないが、今回は等時間間隔で撮影さ れる画像の観測と探査機は小惑星赤道面を小惑星重心を中心と する等速円運動をするように制御されるという事前情報だけが 得られ、太陽系における探査機の位置やその他センサの情報は 観測として得られないと仮定しているため、実際に起こるダイ ナミクスを単純かつ矛盾無く反映するような上記のモデルを採 用した.

上記のモデルによる拡張カルマンフィルタにより観測値を フィルタリングすることで、その時刻の状態の推定値を得る.

#### **3.3** 三次元形状の再復元

カルマンフィルタによって推定された探査機の変位を用いて *i* 番目のカメラ座標系から見たカメラ行列 *P*<sub>*i*+1</sub> を復元し,そ れを用いて再び時刻 *i* のカメラ座標系における三次元形状を再 復元する.復元されたカメラ行列は始めに観測されたカメラ行 列よりも尤もらしいものとなっていると考えられる.

世界座標系と i 番目のカメラ座標系への変換は推定されてい るため、その変換を用いて再復元された形状を世界座標系での 表示に変換することが出来る.各時刻における形状の世界座標 系表現を順次足し合わせていくことで、小惑星の形状がポイン トクラウドとして復元されていく.

しかし,本手法では時刻 *i* と時刻 *i*+1の関係性のみを議論 して推定を行っているので,このままでは復元して重ね合わせ た小惑星形状等に誤差が蓄積していくと考えられる.よって, 手順 4 では復元した形状について順次スムージングを行うこ とでその問題を解決する.

### 3.4 剛体制約による形状の最適化

ここでは小惑星のある点とある点の相対的位置関係は時不 変である、すなわち小惑星は剛体であるという制約を用いて誤 差を減少させる.観測の最適化と EKF による推定による推定 が誤差無く行われていた場合、世界座標系から観測*i*における カメラ座標系への変換を $R_{w,i}$ ,  $t_{w,i}$ とすると以下の等式が成 立する.

$$R_{\mathrm{w},i+1}\boldsymbol{z}_{i+1} + \boldsymbol{t}_{\mathrm{w},i+1} = R_{\mathrm{w},i}\boldsymbol{z}_i + \boldsymbol{t}_{\mathrm{w},i}$$
(15)

しかし,実際には残留誤差のためにこの等式は成立しない. そこで,EKFにより推定された *R<sub>i</sub>*, *t<sub>i</sub>* 及び *s<sub>i</sub>* に対して微小 な変化を許し以下の誤差関数を考える.

$$I_{2} = \frac{1}{2} \sum w \|s_{i} \boldsymbol{z}_{i+1} - R_{i}^{T} (\boldsymbol{z}_{i} - \boldsymbol{t}_{i})\|_{2}$$
(16)

w は復元された三次元点の位置に関する尤度であり、本手法で はカメラによる写像の歪みを考慮して画像上に投影された小惑 星上で中心に近い点は大きい尤度を与え、外側の点には低い尤 度を与えるようにした.最適化は Adam を用いて行い、求め たパラメタを EKF の推定に伝播させて補正することで誤差の 蓄積を防ぐ.

# 4. 実験及び評価

実験に用いる画像列としては「はやぶさ 2」が実際に小惑星「リュウグウ」の赤道上空を周回しながら撮影した 2 種類の画 像列 (2018 年 6 月 30 日撮影分,同年 7 月 10 日撮影分)を用 いた.なお,推定の際の全体のスケールに関しては,初期時刻 の観測における小惑星表面から測った探査機の高度が 1000 に なるようにスケールを正規化した.

推定の際のハイパーパラメタ等は以下の通りである.

表 2: ハイパーパラメタ等

| 名称   | 意味                 | 値          |
|--|--------------------|------------|
| f  | 焦点距離               | 9348.1[px] |
| С  | 光軸中心               | 512[px]    |
| $r_{th}$   | SIFT マッチングのための距離比  | 0.4        |
| $v_{x,i}, v_{y,i}, v_{z,i}$                      | 位置の観測に関するノイズの分散    | 5.0        |
| $v_{lpha,i}, v_{eta,i}, v_{\gamma,i}$            | 姿勢の観測に関するノイズの分散    | 0.5[deg]   |
| $v_{c_{\tau},i}, v_{c_{\eta},i}, v_{c_{\tau},i}$ | 小惑星重心の観測に関するノイズの分散 | 10.0       |
| $v_{\omega,i}$                                   | 相対角速度の観測に関するノイズの分散 | 0.3[deg]   |
| $w_{x,i}, w_{y,i}, w_{z,i}$                      | 位置の状態遷移に関するノイズの分散  | 2.0        |
| $w_{\alpha,i}, w_{\beta,i}, w_{\gamma,i}$        | 姿勢の状態遷移に関するノイズの分散  | 0.1[deg]   |
| $ \Delta y_i $                                   | y 軸方向の微小な制御        | 0.5        |

どちらの画像列についてもほぼ同じ結果が得られたため本稿には 2018 年 6 月 30 日撮影分の画像列で撮影した結果を付する.

### 4.1 実験結果



図 3: 各パラメタの推定結果



図 4: 全体の俯瞰図 1 図 5: 全体の俯瞰図 2



図 6: 小惑星形状 1

図 7: 小惑星形状 2



図 8: 再投影結果 (30 ス 図 9: 再投影結果 (60 ス テップ目) テップ目)

得られたポイントクラウドを構成する点の数は計 118778 個 であり、ここでは図が煩雑になるのを避けるため適当に 5000 個を選び表示させている.

## 4.2 評価

各種の値について今回のデータセットより期待されている値 を概ね満足な精度で推定出来ているように思われる.小惑星の 形状については正解データが無いため定量的な比較は出来ない ものの,使用したデータセットから想像されるような形状を推 定出来ており,本手法を用いることで小惑星形状及び探査機の 相対運動が推定出来ていることが確認された.また,推定結果 を用いて形状を画像上に再投影することで視覚的に推定誤差 を大まかに計り知ることが可能である.再投影した画像を確認 してみると,図9のように再投影が大体一致しているものも あれば,図8のように再投影が大きくずれているものもあり, 精度の改善の余地があることが分かった.

# 5. 結論と今後の展望

## 5.1 本研究のまとめ

本研究では、ある条件下で運動する探査機が撮影した画像 列に基づき、小惑星の形状及び探査機の相対運動を推定する新 たな手法の構築を目的としていたが、それに関してはある程度 達成された.

### 5.2 今後の展望

今回の研究でさらに検討すべき点は以下の2点が主に考えられる.

- 1. 最適化アルゴリズムの精査.
- 2. 誤差関数の精査.

1について、本手法では最適化のアルゴリズムとして十分に 高速かつ安定的に良好な解を得られることが多かった Adam を選択したが最適化のアルゴリズムは他にも多く存在するの で、それらについても検討してみるべきである.最適化の速度 や大域的最適解への収束性を向上させることはオンライン推定 に実用的な段階への大きな一歩になると思われる.

2について、本手法では最適化の際の指標として空間内で の点のユークリッド距離を考えたが精推定法である Bundle Adjustment[Triggs 00] のように再投影誤差についての評価を 誤差関数として用いることで精度が向上するのではないかと考 えられる.

# 参考文献

- [Shirakawa 06] K. Shirakawa et al. Accurate landmark tracking for navigating Hayabusa prior to final descent. In Advances in the Astronautical Sciences, volume 124, pages 1817–1826, 2006.
- [Lowe 04] David G. Lowe. Distinctive image features from scale-invariant keypoints. International Journal of Computer Vision, Vol. 60, No. 2, pp. 91–110, Nov 2004.
- [Kingma 14] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- [Triggs 00] Bill Triggs, Philip F. McLauchlan, Richard I. Hartley, and Andrew W. Fitzgibbon. Bundle adjustment — a modern synthesis. In Bill Triggs, Andrew Zisserman, and Richard Szeliski, editors, Vision Algorithms: Theory and Practice, Springer, Berlin, 2000, pp. 298–375.

# 深層学習を用いたアパレルアイテム平置き画像から着装状態への変換 Image-to-image Translation from Apparel Item Image Placed Flat to Image Put on Using Deep Neural Networks

| 積際 早紀*1        | 黒澤 義明*2           | 目良 和也 <sup>*2</sup> | 竹澤 寿幸*2            |
|----------------|-------------------|---------------------|--------------------|
| Saki Tsumugiwa | Yoshiaki Kurosawa | Kazuya Mera         | Toshiyuki Takezawa |

\*1 広島市立大学 情報科学部 School of Information Sciences Hiroshima City University \*2 広島市立大学大学院 情報科学研究科 Graduate School of Information Sciences Hiroshima City University

This paper deals with image-to-image translation of apparel items. The images are difficult to be translated because the items are variously set, when they are took photos: being placed flat, being put on the mannequin and so on. We try to investigate and improve the previous work also known as 'pix2pix' based on deep neural networks, especially deep convolutional generative adversarial network (DCGAN). We propose a new two-stage procedure. Some experimentation revealed that our proposed method was superior to the previous work, evaluated using structural similarity index. Moreover, we confirmed it generated item details (zipper, button) and patterns (dot) as the result of visual confirmation. This knowledge is very important because the fault image of the item without buttons should be completely different from the original item image.

# 1. はじめに

インターネットの発展に伴い,各種通販サイトが開設されてきた.アパレル分野も例外ではなく,各メーカー/ブランドのサイトに加え,ZOZOTOWN,MAGASEEK等の大規模複合サイトが開設され,今に至っている.

これら複合サイトの利点は、様々なブランドの商品を一度に 閲覧し、また購入できることである。その一方で、ブランド毎に用 意される画像が統一しておらず、ユーザのイメージ想起を困難 にすることがある。

例えば、サーキュラースカート(図 1(a))のように広がりが大き いスカートは、着装した時に「フレア感」と呼ばれる印象を形成 する. この点、図 1(a)左よりも図 1(a)右の方が印象を伝えやす い.しかし、短いサイクルでデザインから縫製、販売まで手掛け る現代のファストファッションでは、写真撮影に時間を割いてば かりもいられない.このため、『基本的な写真(例えば、平置き画 像)からの、自動的なバリエーション画像(例えば、着用画像)変 換』が望ましいと考えられる.

そこで本研究は、このような異なるバリエーション画像を、深 層学習を用いて自動で変換し、ユーザの印象形成を容易にす ることを目的とする.特に、図 1(a)のように変形の大きい対象に ついても変換できる手法の確立を目指す.



連絡先:黒澤 義明,広島市立大学大学院 情報科学研究科, 広島市安佐南区大塚東 3-4-1,082-830-1500(代), kurosawa@hiroshima-cu.ac.jp

## 2. 関連研究

本研究はアパレルアイテム画像から、様々なバリエーション画像の変換生成を目的とする. 深層学習を用いた画像変換の研究として、いわゆる pix2pix が挙げられる[Isola 17].

本研究はこの pix2pix を利用して,大きな変形を伴う画像変換を実現する.そこで,まず本研究にとって重要な pix2pix の特徴と検討項目を挙げた上で,関連研究を2つ挙げる.

# 2.1 pix2pix

pix2pixは conditional Generative Adversarial Networks (GAN)の一種に基づく画像変換器である[Isola 17]. 線画への 着色やセグメンテーション等,様々な対象に利用されている. 次に pix2pix の特徴を2つ挙げる.

## (1) Generative Adversarial Networks (GAN)

第一の特徴は、2 つの畳み込みニューラルネットワーク(生成 器 G(Generator)と判別器 D(Discriminator))を使用する点である. まず生成器 G は、訓練画像に似た画像(fake)を生成するよう に訓練される. 次に判別器 D は、D に入力された画像が訓練画 像か、G が生成した fake かを判定する. そして、G は D を騙す ように訓練され、D は G に騙されないように訓練される. このよう に、G と D が互いに争い合うことで画像の変換精度を高める.

## (2) U-Net

次の特徴は, 畳み込みネットワークに U-Net を使用している 点である. このネットワークは, 医療分野での画像セグメンテー ション(細胞の着色 etc)を目的として開発された[Ronneberger 15]. 重要な点は, U-Netという名前が示す構造にある(図 2).

U 字の左右をつなぐ結合(skip connection)がある(右向き車 線矢印). この結合により, U 字の右側では下層から出力された 特徴マップに, 左側の対応する層からの特徴マップが加わる. これがお手本のようになり, 結合のない単なる Encoder-Decoder モデルよりも, 速く正確に学習する. 一般的に, GAN による画像 生成は細部が破綻することも多く, U-Net を使う利点は大きい.

## 2.2 pix2pix における要検討項目

[Isola 17]は車や人のセグメンテーション,線画に対する着色 等,様々な変換事例を紹介している.しかし,pixel 同士の対応 を前提としており,変形を伴う対象を検討していない.よく似た CycleGAN [Zhu 17]では,変形の問題が指摘されているため, 吟味する必要があると言える.

本研究が対象とするアパレルアイテムは、図1(a)に挙げたよう な変形を含む.こうしたアイテムの変形が可能であれば、背景からのアイテム抽出や、アイテムの変形加工等の複数の処理を、 モデルを変えるだけで実行できるという利点がある.

以上の観点から, pix2pix が変形に対応可能かどうか議論す ることを本研究の課題の1つとする.問題があるとすればどのよ うな点か,そしてどのように解決するかに検討する.

次に,アパレルアイテムに関する関連研究について,以下に 補足しておく.

# 2.3 Pixel Level Domain Transfer

pix2pix 以外にも変換を試みる研究がある. [Yoo 16]は、本研究同様、アパレルアイテム画像の様態変換を行っている. この研究も GAN を利用している.

異なる点は、U-Net ではなく単純な Encoder-Decoder モデル を使用していること、GとDに加えて、Domain 判別用の別のネ ットワークが用意されている点、の2点である. 先に述べたように、 Encoder-Decoder モデルより U-Net が優れる.

# 2.4 Detailed Garment Recovery

単なる着用画像の変換だけではなく、動画化を試みた研究も ある[Yang 16]. フレアスカートのフレアを揺らすことができる等, ユーザのイメージ想起に有効に働く手法である.

ただ,彼らの手法の問題は,型紙から衣服を作るかのような 詳細なアイテム記述が必要なことであり、コストがかかる点である. 短いサイクルで様々なアイテムが発売されるファストファッション の場合には、このようなコストをかけることは困難である.したが って、シンプルな画像変換による方法の方が、コストが少なく、よ り有効であると考えられる.

# 3. 提案手法

本研究の提案は, pix2pix を用いた変形を伴う画像変換に対 する解決法である.以下に, その手法について述べる.

先述の通り, pix2pixの手法は, 画像間のピクセルについて対応が取れているとき, または対応のずれが小さいときには有効である.一方で, 変形が大きく, 対応のずれが大きくなると, 学習が困難になると考えられる.

この理由としては, pix2pix の利点となっている skip connection に原因がある. すなわち, お手本として振る舞うべき であるのに, 対応のずれが災いする. つまり, オリジナルの画像 情報が反映されない学習結果となるわけである.

そこで本研究は、お手本となるべき入力を新たに導入するため、2 段階の処理を採用し、つなぎ目に処理を加える方法を提案する(図 3).



本研究の手法はシンプルであり,2つの pix2pix をつなげ,そ のつなぎ目で,1つめの pix2pix の出力と,最初の入力(白抜き 矢印)を重ね合わせて(concat),2つめの pix2pix への入力とす る.これにより,オリジナル画像の情報を有した6次元の画像に よる学習が可能となる.これにより,変形への対応を目指す.

# 4. 実験と考察

本節では、pix2pix の変形にの可否に関する調査を行い、その問題点を解消する実験について報告する.

## 4.1 本研究で使用するデータ

本稿では対象をスカート,また,平置き画像(図 1(a, b)左)から着装状態(図 1(a, b)右)への変換に限定する. に限定した理由は,変形量が大きく,検証に有効と考えたからである. 図 1(a)が変形の大きい例,(b)が小さいタイトスカートの例である.

以下に、本研究で使用したデータの詳細について述べる.

### (1) 撮影

1 枚のスカートに付き, 平置き画像(床に広げ, 上方から撮影) と着装状態画像(マネキンに着用)の2枚ずつを撮影した. その 後, それぞれ背景を削除した. アイテム数は283 であった.

### (2) Data Augmentation

上記アイテム数は、深層学習に十分な量とは言えないため、 data augmentationを行った.以下の表1の命令からランダムに4 種類を選び、色等を変更する.なお、オプションランダムに選ぶ.

上の手続きを1枚のアイテムにつき21回行った上で,さらに 左右反転を行った.これにより,オリジナルの画像も含め,22 (21+1) x 2(反転)倍の画像となった(283x44=12,452画像).

## (3) 画像サイズ調整

平置きと着装状態は別々に撮影しているため、サイズの調整 を行う. それぞれ、輪郭抽出を行った後、外接四角形を決定す る. そして、着装画像の縦サイズに合わせ、縦横比を維持したま ま、平置き画像を縮小/拡大し、縦横 256 pixel の画像を得た.

## 4.2 実験1~基礎的な変形に関する検討~

本研究は pix2pix の実装として, 原著者らが公開している実 装を用いた. なお, 特に断らない限り, デフォルトのパラメータを 使用する. GPUは GeforceGTX 1080Ti を使用した.

まず基本的にな変形に関する情報収集のため,判別器 D の 層数を 5 に変更(デフォルト:3)し,バッチサイズを 10 で 1,000 epoch(同:200)繰り返す実験を行った.学習時の loss の推移を 図 5 に示す.学習開始直後の L1 の値が大きく見づらいため, 補正した図になっている.

| 表1 | data augmentation | に使用した命令とオプション | / |
|----|-------------------|---------------|---|
|----|-------------------|---------------|---|

| 命令          | オプション   |   |   |  |  |
|-------------|---|---|---|--|--|
| 画像の伸縮       | [0.9], [1.05], [1.1]  |   |   |  |  |
| 回転          | [3], [5], [7](度)  |   |   |  |  |
| 透視変換        | [0.015](画像幅 x0.01   | 5), [0.03], [0.                                     | 05], [0.07],                                    |  |  |
| 色交換         | $[0, 2, 1, 3]$ (BGR $\rightarrow$ BF<br>[1, 0, 2, 3], [1, 2, 0, 3], | RG),<br>[2, 0, 1, 3], [2,                           | 1, 0, 3]  |  |  |
| 色軽減         | [0.95] (Bx0.95, Gx0   | .95, Rx0.95)  | , [0.9]   |  |  |
| 特定色軽減       | [0, 0.95] (Bx0.95) , [1, 0.95], [2, 0.95]                           |   |   |  |  |
| 色除去/半減      | [0,0] (Bx0) , $[0,0.5]$ , $[1,0]$ , $[1,0.5]$ , $[2,0]$ , $[2,0.5]$ |   |   |  |  |
| HSV 円環上     | [-40], [-30], [-20], [-10], [10], [20], [30], [40]                  |   |   |  |  |
| の移動         |   |   |   |  |  |
|             | [0], [1], [2]   |   |   |  |  |
| 平滑化/<br>先鋭化 | [0]:<br>Gaussian Filter<br>Kernel Size(11x11)                       | [1]:<br>[-1, -1, -1]<br>[-1, 9, -1]<br>[-1, -1, -1] | [2]:<br>[0, -1, 0]<br>[-1, 5, -1]<br>[0, -1, 0] |  |  |

ここで、「G\_GAN」は『生成器 G が判別器 D を騙せているか』 についての指標、「G\_L1」は『生成器 G が生成した fake(predict) と正解(ground truth)との L1 距離』に関する指標である. 今回の 学習では収束条件が L1 となっている. また、「D\_real」は『正解 に対する、判別器 Dの判定』、「D\_fake」は『fake に対する、判別 器 Dの判定』について表している.



losss when learning

図 5 loss の推移(補正後)

G\_L1, G\_GAN 共に変動が大きいことがわかる. また, L1 が横 這いである点も学習が不十分である可能性を示唆している. こ のため今回の検討は,以下の実験を含め,全てクローズドテスト で行うこととする. 学習時のアイテムをモデルに入力し,生成し た画像を挙げる(図 6~図 8).

変形の必要なサーキュラースカート(図 6)やフレアスカート(図 7)では、アイテム領域の内外に破綻が見られる(ex. 600 epoch). ただ、変形はおおむね成功しているように見える.また、シンプ ルなタイトスカート(図 8)でも変形はできていても、テクスチャー の変換には成功していない.仮説としては、ネットワークの重み 学習が変形を中心に行われて、余裕がなかったのではないか、 つまり学習資源に関するパラメータ設定が必要と考えられる.

### 4.3 実験 2~パラメータ変更~

前項の仮説を確認するため、生成器 G が持つカーネルの数 を増加させる. デフォルトが 512 の層 1024 にする等、各層 2 倍 にする<sup>1</sup>. また、性能向上のため、判別器 D の性能向上を目指し カーネルの大きさを1 にした実験を行う<sup>2</sup>. アイテムを学習モデル に入力した例を、次の図 9~図 11 に示す.

実験 1 では成功していなかったストライプ(図 6)の復元に成 功している(図 9). また図 10 では、フレアスカートのフレア感も 再現している. 一方で、ドット柄の再現については不十分であり、 さらに図 11 からわかるように、ディテール(ボタンやジッパー)が どの epoch でも再現されていない.

つまり,重み学習のためにパラメータの変更~特に,カーネル数等の増加~を行うことは重要である.しかし,それでも細かい模様やディテールを再現できないという問題が残る.

## 4.4 実験3 提案手法~2段階処理への拡張~

3 節に述べた提案手法に基づく実験を行う. 第一段階には前 節で学習した中で, 200 epoch のモデルを選んだ. 200 はデフォ ルトの値である.

このモデルにより得られた変換画像を 6 次元に合成した上で, 2 段階目の学習を行った.結果を図に示す(図 12, 図 13).

図 10 に比べた図 12 では、細かいドット柄を表現できていることがわかる.また、図 11 で不十分だったディテールが、図 13 では表現できていることもわかる.



図4 3実験比較を目的とした SSIM 値の推移

# 4.5 考察

変換がどの程度向上したか,以下の Structural Similarity (SSIM)を用いて評価する. 画素中の小領域の平均・分散・共分散を用いて,局所的な破綻に敏感であり,最良値は1である.

SSIM = 
$$\frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

撮影画像 283 枚それぞれについて, 50 epoch ごとに平置き-着装間の平均 SSIM を求めた(図 4).

実験1と比べ,実験2と実験3(提案手法)との値が高くなっていることがわかる.また実験3が優れていることも明らかである.

ただ,実験 2 との差はあまりなく,pix2pix のパラメータを変更 しただけであるので,「提案手法のようなコストをかけなくてもよ いのでは」という指摘もあろう.しかし,前節で述べたように,見 た目の変化は大きい(図 10 vs.図 12,図 11 vs.図 13).特に, ボタン等のディテールが再現できなければ,全く別のデザイン になることは指摘しておきたい.その意味で,数値以上に提案 手法が優れていると言える.

# 5. おわりに

アパレルアイテム画像の様態変換を目的に, pix2pix を利用 した2段階の学習方法を提案した.

実験の結果, SSIM による数値による比較で,本提案が優れ ていることが明らかになった. pix2pix は細かい模様やディテー ルを再現できない一方,提案手法では再現できたからである.

今後の課題としては、アイテム数を増やした上で、さらなる検 討を試みることが挙げられる. また SSIM 値は、ディテールの有 無等を反映していないこともわかった. さらなる改善のため、適 切な指標を検討することも必要であろう.

### 謝辞

この研究の一部は,国立研究開発法人科学技術振興機構(JST)の研究成果展 開事業「センター・オブ・イノベーション(COI)プログラム」.広島市立大学特定研究 費(先端学術研究費 H27~29,30 年度科研費獲得支援費)の補助を得ている.

## 参考文献

- [Isola 17] P. Isola, J.-Y. Zhu, T. Zhou, A. A. Efros : Image-to-Image Translation with Conditional Adversarial Networks, In IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [Ronneberger 15] O. Ronneberger, P. Fischer, T. Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation, arXiv:1505.04597, 2015.

のサイズを変更した複数の実験がある.ページの都合により今回 は割愛する.

<sup>&</sup>lt;sup>1</sup> 関数 UnetGenerator の ngf を 64 から 128 に変更した.

<sup>&</sup>lt;sup>2</sup> 関数 PixelDiscriminator. なお,実験1と2の間にはカーネル

- [Yang 16] S. Yang, T. Ambert, Z. Pan, K. Wang, L. Yu, T. Berg, M. C. Lin: Detailed Garment Recovery from a Single-View Image, arXiv:1608.01250v4, 2016.
- [Yoo 16] D. Yoo, N. Kim, S. Park, A. S. Paek, I. S. Kweon: Pixel-Level Domain Transfer, arXiv:1603.07442, 2016.
- [Zhu 17] J.-Y. Zhu, T. Park, P. Isola, A. A. Efros.: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, In IEEE International Conference on Computer Vision, 2017.



図 13 実験 3 item 200: epoch 毎生成画像(左から 50, 100, 200, 500, 550, 600, 800 epoch, ground truth)

走査電子顕微鏡におけるライブ像のノイズ低減 Noise reduction of live image in scanning electron microscope

植松 文徳<sup>\*1</sup> Fuminori Uematsu 武井 雅彦<sup>\*1</sup> Masahiko Takei 吉田 光良<sup>\*1</sup> Mitsuyoshi Yoshida

# \*1 日本電子株式会社 JEOL Ltd.

A real time display called a live image is used to search for a region to be observed, when observing a sample with a scanning electron microscope (SEM). This live image is usually an image with high noise and poor visibility. This makes it difficult to find an appropriate observation area. Therefore, in this research, a noise reduction model by deep neural network was created with the aim of improving the visibility of live images. We incorporated this model into the SEM and succeeded in obtaining a live image with less noise. This makes it possible to efficiently search for the observation region.

# 1. 背景と動機

走査電子顕微鏡(SEM)で試料を観察する際には, 試料の観察したい領域が電子顕微鏡の表示領域(視野)に含まれるようユ ーザーが装置を操作する必要がある.これを視野探しと呼び, 具体的には試料ステージの移動や観察倍率の変更などを行う. 視野の画像がリアルタイムで表示されるので, 視野探しで表示 される像をライブ像と呼ぶ.

ライブ像では視野探しの操作に対して十分な応答性が得られるよう,高いフレームレートを使用するのが一般的である. すなわち,電子ビームの走査が速く,検出器で観測される時間当たりの電子が少ない.そのため検出信号にノイズが発生しやすい.また,応答性が落ちるという理由から,ライブ像では複数フレームの積算によるノイズ除去を無効にすることも多い.その結果,ライブ像はノイズの多い画像となるのが常態である.

SEM の熟練ユーザーが扱い慣れた試料を観察する場合で あれば、ノイズの多いライブ像であっても、ノイズの無い状態を ある程度推測しながら視野探しを行える.しかし、そのような推 測は経験の浅いユーザーにとって困難であり、視野探しに長い 時間を要したり、観察したい対象物を見落としたりする可能性が ある.

ライブ像のノイズを低減できれば、視野探しをより効率的に見 落としなく行うことが可能となり、高い有用性が期待できる.本研 究ではライブ像のノイズ低減にディープラーニングを用いること を提案する.

# 2. 提案手法

# 2.1 モデル設計

ノイズの多い SEM の観察像をノイズの少ない観察像に変換 するモデル(ノイズ低減モデル)を作成し、それを SEM に組み込 んでライブ像のノイズを低減させる. SEM でノイズの少ない観察 像を得るには、電子ビームの走査を遅くし、さらに複数フレーム の積算によるノイズ除去を用いれば良い. これは静止画を保存 するときの観察条件であり、このようにして得られる像をフォト像 と呼ぶ. 従って本研究ではライブ像からフォト像への変換を学習 させることで、ノイズ低減モデルを作成する.

ライブ像はフォト像の一部がノイズによって隠された状態と見

なせるため、ライブ像をノイズ除去した結果は一意に定まらない. そのため Encoder-Decoder モデルを二乗誤差で学習させてノイ ズ低減モデルを作成しても、ライブ像から推定されうる多数のフ オト像を平均したような、不明瞭な像が得られると予想される.そ こで本研究ではノイズ低減モデルを学習させる手法として、 Conditional GAN を採用した.この手法ではライブ像をフォト像 に変換する生成器と、フォト像が生成された物か本物かを識別 する識別器の二つのモデルを相互に競わせて学習する.すな わち、生成器は自身が変換した画像が本物であると識別器に 誤認させようとする.一方、識別器は与えられたフォト像を正確 に識別しようとする.その際、生成したフォト像が不明瞭であると 本物ではないことが容易に判別できてしまうので、明瞭な画像 を生成するように生成器の学習が進むと期待できる.

モデル設計には pix2pixHD[Wang 17]で提案されている手法 を取り入れた.これは高品質で高解像度の画像が生成可能な Conditional GAN の手法であり, 次のような特徴を有している.

- 階層化された生成器
- マルチスケールに対応した識別器
- 複数の誤差関数の組み合わせ

pix2pixHD ではセマンティックラベルマップから写真のように リアルな画像を生成しているが、本研究は同様のモデルを SEM 観察像のノイズ除去に適用した.

## (1) 生成器のアーキテクチャ

本研究では pix2pixHD と同様に粗い解像度の生成器 (Global Generator)と密な解像度の生成器(Local Enhancer)を階 層的に結合した生成器を用いた.ここでは Johnson ら[Johnson 16]や CycleGAN[Zhu 17]や pix2pixHD で用いられる表記の慣 習に従って次のように表現する.

- フィルター数 k でストライド 1 の 7×7 畳み込み層-InstanceNorm[Ulyanov 16]層-ReLU 層を c7s1-kと表現する
- フィルター数 k でストライド 2 の 3×3 畳み込み層-InstanceNorm 層-ReLU層を dk と表現する
- フィルター数 k の 3×3 畳み込み層を二つ含む Residual ブロックを Rk と表現する
- フィルター数 k でストライド 1/2 の 3×3 転置畳み込み層-InstanceNorm 層-ReLU 層を uk と表現する

連絡先:植松文徳,日本電子株式会社,東京都昭島市武蔵野 3-1-2, fuematsu@jeol.co.jp

生成器のアーキテクチャは, Global Generator を c7s1-32, d64, d128, d256, d512, R512, u256, u128, u64, u32, c7s1-1とし, Local Enhancer を c7s1-16, d32, R32, R32, R32, u16, c7s1-1とした.

# (2) 識別器のアーキテクチャ

識別器においても pix2pixHD と同様に画像サイズの異なる 複数の識別器を結合して用いた. 識別器の個数は, Global Generator の学習では 2 個, Local Enhancer を結合した学習 では 3 個とした. ここで次のように表現する.

 フィルター数 k でストライド 2 の 4×4 畳み込み層-InstanceNorm 層-LeakyReLU層をCkと表現する

いずれの識別器も C32-C64-C128-C256 とし, その後にフィル ター数 1 でストライド 1 の 4×4 畳み込み層を繋げたアーキテク チャとした. ただし, C32 の InstanceNorm 層は省略した.

# 2.2 教師データ

教師データには同一視野を観察したライブ像とフォト像のペ アが必要となるが、これを大量に取得するには長時間の SEM 操作が必要となり、容易ではない.そこで本研究ではフォト像の みを取得し、それに人工的なノイズを付加することによって、疑 似ライブ像を作成して用いた.本手法であれば既に所有してい るフォト像を教師データとして活用できる利点がある.SEM の二 次電子像において支配的なノイズは、検出器で観測される電子 がポアソン分布に従っていることに由来するショットノイズである. そこでフォト像にこのようなショットノイズを付加して疑似ライブ像 を作成した.また教師データの数を増やすため、フォト像に拡 縮・回転・並進・反転といった画像変換を行ってデータ拡張した 後に疑似ライブ像を作成した.

# 3. 実験

# 3.1 学習

対象とする画像の解像度は、日本電子製の SEM である JSM-7900Fのフォト像と同じ 1280×960 ピクセルとした. 教師デ ータとして疑似ライブ像とフォト像のペアを約 2 万データ作成し、 GeForce GTX 1080(NVIDIA 社製)を1 基搭載した Ubuntu サ ーバーで学習を行った. Global Generator を 40 エポック学習し た後、Local Enhancer を結合して 20 エポック学習した. フレー ムワークには Microsoft Cognitive Toolkit を使用した.

# 3.2 評価

学習を行って作成したノイズ低減モデルを JSM-7900F に組 み込み,ノイズ低減されたライブ像を観察して効果を評価した. 視野探しに必要な応答性を確保するため,SEM の制御用 PC に GeForce GTX 1080 を 1 基搭載し,画像辺りの変換時間が 100ms以下となるようにした.

同一視野のライブ像(変換前), ライブ像(変換後), フォト像を 図1に示す. ライブ像のノイズが低減され, フォト像と比較しても 自然な画像となっており, 視認性が向上していることがわかる. 一方で,本手法ではライブ像をフレーム単位で変換しているた め,各フレームのノイズの偏りが変換後の画像に僅かに影響を 与える.これによって, リアルタイム表示したときに試料表面が波 打って見えるなどの違和感を生じる場合があった.

# 4. 結論と今後の課題

本研究ではディープラーニングを用いることで走査電子顕微 鏡におけるライブ像のノイズ低減が可能であることを確認し、効 率的な視野探しへの寄与が期待できる結果が得られた.

今回は効果の測定を目視による主観に頼ったが、今後は非 参照メトリックなどを用いた定量的な知覚品質の測定に取り組む 必要がある.また、vid2vid[Wang 18]で行われているように、変 換結果に時系列での一貫性を持たせるなどして、試料表面が 波打って見える現象を解消することが今後の課題となる.



図 1 SEM ライブ像の変換例.上段:ライブ像(変換前),中段: ライブ像(変換後),下段:フォト像

# 参考文献

[Wang 17] Ting-Chun Wang, Ming-Yu Liu, Jun-Yan Zhu, Andrew Tao, Jan Kautz and Bryan Catanzaro: High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs, arXiv:1711.11585, 2017.

- [Johnson 16] Justin Johnson, Alexandre Alahi and Li Fei-Fei: Perceptual losses for real-time style transfer and superresolution, arXiv:1603.08155, 2016.
- [Zhu 17] Jun-Yan Zhu, Taesung Park, Phillip Isola and Alexei A. Efros: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, arXiv:1703.10593, 2017.
- [Ulyanov 16] Dmitry Ulyanov, Andrea Vedaldi and Victor Lempitsky: Instance Normalization: The Missing Ingredient for Fast Stylization, arXiv:1607.08022, 2016.
- [Wang 18] Ting-Chun Wang, Ming-Yu Liu, Jun-Yan Zhu, Guilin Liu, Andrew Tao, Jan Kautz and Bryan Catanzaro: Video-to-Video Synthesis, arXiv:1808.06601, 2018.

# 交通サービスのための耐戦略性を有する動的課金メカニズム

Truthful Dynamic Pricing Mechanisms for On-demand Mobility Services

早川 敬一郎 \*1 羽藤 英二 \*2 Keiichiro Hayakawa Eiji Hato \*1豊田中央研究所 \*2東京大学大学院 Toyota Central R&D Labs., Inc. The University of Tokyo

Transportation services under which multiple traffic mode services are provided by a service operator through mobile apps are often called Mobility as a Service (MaaS). Commonly, the mobile app has the function of activity loggers, which represents the heterogeneity of each user. Thus, the traffic allocations and pricing algorithms that properly handle this heterogeneity of users is required. In this paper, we present a conceptual framework for the pricing mechanisms for such dynamic on-demand traffic services.

Specifically, we aim to establish Bayesian-Nash incentive compatible mechanisms, by which the dynamic system optimal state is achieved by the best response strategy of selfish agents. We introduce two common mechanisms to our MaaS settings, one which guarantees non-negative *ex-post* revenue and the other non-negative *ex-post* utility of agents. In the numerical study, we show that these two mechanisms have a trade-off between the revenue of the service operator and the benefit of customers.

# 1. はじめに

近年,複数の交通モードを統合した移動をサービスとして 提供する MaaS(Mobility as a Service)の取り組みに注目が集 まっている. MaaSの多くは顧客に対してケータイアプリを提 供し,顧客はアプリを通して交通資源(例えば,列車の指定席 やライドシェアへの相乗りなど)を予約する.一方でケータイ アプリは顧客の日々の行動を記録するロガーとしても活用され ており,顧客の多様性を考慮した有効な交通資源配分が実現可 能である.人々の多様な選好と制約の下で,有限の交通資源を 上手く配分するアルゴリズムの確立が求められる.

このような問題に対して、[Hayakawa 18b] は、Activitybased model [Kitamura 96] を用いて利用者のトリップ チェーンを考え,利用者の持つ時間と場所に関する制約 [Hägerstrand 70] を考慮した交通サービス設計の考え方を示 している.具体的には、受け入れた全ての利用者の時空間制約 と交通容量制約を将来にわたって守ることを保証する交通資源 割り当てメカニズムを、*RC(Resource-Customer)-feasible* ア ルゴリズムと定義し、その中でも特に、各時刻の割引総社会効 用 [Rust 94] を最大化するアルゴリズムを*RC-optimal* アルゴ リズムと定義している。

本研究では、顧客の利己的な行動選択を前提として、利用者 および交通事業者双方の多くの制約の下での最適状態が導かれ るような課金制度を検討する.具体的には、オークション理論 の分野で知られる Dynamic pivot メカニズム [Bergemann 10] と、Online VCG メカニズム [Parkes 04] の二つのメカニズム を導入し、その特性を評価する.

# 2. オンデマンド型交通サービスモデル

本研究で想定する交通サービスを示す。まず,複数の交通資源(列車,バス,タクシーなど)を有するサービスオペレータ は、利用者に対してケータイアプリを提供する.利用者は、交 通サービスを利用する際に、ケータイアプリ上の予約入力画面

連絡先: 早川 敬一郎, 豊田中央研究所, 愛知県長久手市横道 41-1, kei-hayakawa@mosk.tytlabs.co.jp から,自身の希望(「選好」と「制約」)を入力する.ケータ イアプリ上に実装された User Agent は,入力された情報と, 日々の行動観測から得られた利用者の嗜好の情報などを踏ま えて,トリッププランの候補を複数生成し,オペレータに送信 する.オペレータは,まずその利用者を受け入れるか否かを判 断し,受け入れた全ての利用者に対してトリッププランを提示 し,保有する交通資源を動的に割り当てる.さらに,割り当て られた交通資源に応じて,利用者にサービス利用料金を課金 する.

本研究では,既往研究 [Hayakawa 18b, 早川 18] と同様に, 離散時間 t ∈ T = {0,1,..., T̄} を考える.交通ネットワ-クは、ノードの集合 N とエッジの集合 E からなる片方向グ ラフ $\mathcal{G} = (\mathcal{N}, \mathcal{E})$ で表されるものとする.このグラフ上では, 同一地点間を結ぶ異なる交通モードは異なるエッジで表され る [Sheffi 85]. エージェントの集合を I とし, エージェント のモデルとしては、[Hayakawa 18b] と同様の状態遷移モデル を用いる. すなわち、エージェントのタイプは、報酬関数は,  $R_i: S_i \times A_i \times T \to \mathbb{R}$  と、実行可能なトリッププランの集合  $L_i$ を用いて、 $\theta_i = \{R_i, L_i\}$ で表される. ここで、エージェン トのトリッププラン  $l_i \in L_i$  は、活動時間帯  $T_i = [t_i^B, t_i^E]$  に おける一連の状態とアクションの遷移として表されるものとす る。ただし、状態 s<sub>i,t</sub> は位置や交通モードなどを含む多次元変 数であり、アクション a<sub>i.t</sub> は移動もしくは滞在を表すものとす る.エージェントは、出発時刻 t<sup>B</sup> 以降の任意の時刻に、サー ビスオペレータに対して自らのタイプを申告し、オペレーター は、当該時刻までに得られた申告に基づいて、各時刻ごとに交 通リソースの割り当てと課金額を決定するものととする。

# 3. メカニズム

本研究では、前章に示した交通サービスに対して, Dynamic pivot [Bergemann 10] と Online VCG [Parkes 04] の二つの メカニズムを適用する.これらのメカニズムは、共に、各時刻 の割引総社会効用 [Rust 94] を最大化する資源割り当てメカニ ズムを用いるが、課金方法が異なる。Dynamic pivot メカニ ズムは、各時刻に各エージェントが社会に与える外部性の期待 値に相当する額を課金する。一方、Online VCG は申し込み 時点で計算された外部性の期待値に相当する額を基本として その後の割り当てに応じて課金額が調整される仕組みとなって いる。

### 3.1 効率的な交通資源の割り当て

まず,交通資源の割り当て方法について考える.この方法 は、二つのメカニズムに共通であり、割引総社会効用を最大化 することが求められる.その割り当て方法は、以下の式で表さ れる.

$$\boldsymbol{\pi}_{t} = \operatorname*{argmax}_{\boldsymbol{\pi}'_{t} \in A(\boldsymbol{s}_{t})} \boldsymbol{E} \left[ \sum_{t \in \bar{T}} \beta^{t'-t} R(\boldsymbol{s}_{t}, \boldsymbol{\pi}'_{t}) \right].$$
(1)

ベルマンの最適性原理により、この式は以下のように書き換え られる.

$$\boldsymbol{\pi}_{t} = \operatorname*{argmax}_{\boldsymbol{\pi}'_{t} \in A(\boldsymbol{s}_{t})} [R(\boldsymbol{s}_{t}, \boldsymbol{\pi}'_{t}) + \beta \cdot V(\mathcal{T}(\boldsymbol{s}_{t}, \boldsymbol{\pi}'_{t}))], \quad (2)$$

ただし, V(s<sub>t</sub>)は、以下の式で与えられる価値関数である.

$$V(\boldsymbol{s}_t) = \mathbb{E}\left[\sum_{t'=t}^{\bar{T}} \beta^{t'-t} R(\boldsymbol{s}_{t'}, \boldsymbol{\pi}_{t'})\right],$$
(3)

既往研究 [Hayakawa 18b, 早川 18] で示したように,この計算 は ZDD [Minato 93] を用いて効率的に実行できる.

### 3.2 Dynamic pivot mechanism の課金方法

Dynamic pivot mechanism [Bergemann 10] の課金方法は, 以下の式で与えられる.

$$\begin{aligned} x_{i,t} &= -R_{-i}(\boldsymbol{a}_t) - \beta \cdot \boldsymbol{E} \big[ V_{-i}(\boldsymbol{s}', \boldsymbol{\pi}^*_{\theta_{-i}}) | \boldsymbol{s}' = \mathcal{T}(\boldsymbol{s}_t, \boldsymbol{a}_t) \big] \\ &+ V_{-i}(\boldsymbol{s}_t, \boldsymbol{\pi}^*_{\theta_{-i}}), \end{aligned}$$
(4)

ここで  $\pi^*$  は前節で示した効率的な交通資源割り当てを,  $R_{-i}$ はエージェント i を除く全エージェントの報酬の合計を,  $V_{-i}$ はエージェント i を除く全エージェントの価値関数を示す. こ の式はすなわち,「各エージェントは各時刻に社会に与えた迷 惑料を支払う」, ということを表している.

このメカニズムは、Bayesian-Nash incentive compatible か つ *ex-post* budget balanced である.各エージェントのが利己 的にベストレスポンス戦略を実行するという仮定の下で、割引 総社会効用が最大化される.また、メカニズムに参加する(交 通プランをリクエストする)ことによって負の効用が生じない ことは、確率的に保証される.ただし、条件によっては、エー ジェントはメカニズムに参加することで負の効用を得る(損を する)可能性がある.

### 3.3 Online VCG mechanism の課金方法

Online VCG mechanism [Parkes 04] の課金方法は,以下の式で与えられる.

$$x_{i,t} = \begin{cases} R_i(a_{i,t}) - V(\boldsymbol{s}_t, \pi_\theta^*) + V_{-i}(\boldsymbol{s}_t, \pi_{\theta_{-i}}^*) & (t = t_i^B) \\ R_i(a_{i,t}) & (otherwise). \end{cases}$$
(5)

この式はすなわち,「各エージェントは,最初の申告の時点で 社会に与える迷惑料を支払った上で、実際に発生した事象に応 じて支払額を調整する」ということを表している.

このメカニズムは, Bayesian-Nash incentive compatible か つ ex-post individual rational である. 各エージェントのが利



 $\boxtimes$  1: Sample network

己的にベストレスポンス戦略を実行するという仮定の下で,割 引総社会効用が最大化される点は,Dynamic pivot mechanism と同じであるが,メカニズムに参加する(交通プランをリクエ ストする)ことによって負の効用が生じないことが確定的に保 証されている.

# 4. 数值実験

#### 4.1 実験条件

今回の実験では、制御対象時刻は $T = \{0, 1, \dots, 8\}$ の8タイムステップとし、時間割引率は $\beta = 1$ とした.以下に、交通ネットワークおよびエージェントに関する実験条件を示す.

## 4.1.1 交通ネットワーク

実験では、図 1 に示すネットワークを考えた. このネット ワークは、 $N = \{A, B, C, D\}$ の4ノードと、10本の片方向リ ンクを有している.図 1(a) にリンク旅行時間を、図 1(b) に リンク容量を示す.実験においては、ノード A を住居エリア、 ノード D をオフィスエリアと考え、ノード B およびノード C は娯楽エリアと考えた. さらにノード B に位置する娯楽施設 の営業時間は  $b_B = \{3, 4, 5\}$ とした.なお、ノード B 以外の 施設については営業時間を限定せず、 $\forall n \in N \setminus B; b_n = T$  と した.

### 4.1.2 エージェントの条件設定

エージェント $i \in I$ の報酬関数については、以下のように設定した.

$$\forall a_{i,t} \in A_i^M : R_i(\boldsymbol{s}_t, a_{i,t}) = 0 \tag{6}$$

$$\forall a_{i,t} \in A_i^S : R_i(\boldsymbol{s}_t, a_{i,t}) = \begin{cases} v_i^n & (t \in b_n) \\ 0, & (otherwise) \end{cases}$$
(7)

つまり,各エージェントiは「移動」行動においては報酬を得ず,各ノード $n \in N$ 上の施設の営業時間内に当該ノードに滞在したときに報酬 $v_i^n$ を得るものとした.

今回の実験ではエージェントとして、滞在型エージェント  $I_C$  と通過型エージェント  $I_P$  を考えた.ただし、 $I_C \cup I_P = I$ である.観光トリップを想定した滞在型エージェントの目的は、 エリア内を周遊し各地点における滞在を楽しむことである. 方で、通勤トリップを想定する通過型エージェントは、出発地 と目的地の間を短い時間で移動することを目的としている.

以下,それぞれについて,今回の数値実験で設定したパラ メータを示す.

滞在型エージェント:滞在型エージェントはノード A を出発 してノード A に戻る周遊トリップを行うものとする. これは, ノード A に宿泊する観光客の観光行動を想定した設定である. 滞在型エージェントの主目的は, ノード B に位置する施設を 訪問することとする. すなわち,全ての滞在型エージェント は,トリップがキャンセルされた場合を除き,ノード B の施 設の営業時間  $b_B = \{3,4,5\}$ の間に1時間ステップ以上ノード B に滞在する必要がある. 滞在型エージェントについては,各ノードで得る報酬を以下 の正規分布に従って設定した.

| $\hat{v}_i^A \sim \mathcal{N}(50, 50),$   | $\hat{v}_i^B \sim \mathcal{N}(200, 200),$ |     |
|---|---|-----|
| $\hat{v}_i^C \sim \mathcal{N}(100, 100),$ | $\hat{v}_i^D \sim \mathcal{N}(50, 50)$    | (8) |

ただし,  $\mathcal{N}(\mu, \sigma^2)$ は, 平均  $\mu$ , 分散  $\sigma^2$  の正規分布を表してい る. この報酬関数によると,滞在型エージェントは, ノード B およびノード C に滞在することで, ノード A やノード D に 滞在するよりも大きな報酬を得ることができる.また,滞在型 エージェント  $i \in I_C$  の活動可能時間帯  $T_i = \{t_i^B, \ldots, t_i^E\}$  に ついては,活動開始時刻  $t_i^B$  が一様分布  $\{0, 1, 2\}$  に従い,活動 終了時刻  $t_{i_d}^E$  については,  $\forall i \in I_C; t_i^E = t_i^B + 6$  と設定した. 通過型エージェント:通過型エージェントについては, ノード A を出発してノード D に向かうエージェントについては, ノード D を出発してノード A に向かうエージェントの二通りを考え た. それぞれのエージェントの集合を  $I_P^{D}$  および  $I_P^{DA}$  で表 す. ただし,  $I_P^{D} \cup I_P^{DA} = I_P$  である. ノード A からノード D へ向かうエージェント  $i \in I_P^{D}$  については, 各ノードで得 る報酬を,以下の正規分布に従って設定した.

$$\hat{v}_{i}^{A} \sim \mathcal{N}(200, 200), \qquad \hat{v}_{i}^{B} = 0, 
\hat{v}_{i}^{C} = 0, \qquad \hat{v}_{i}^{D} \sim \mathcal{N}(500, 500) \qquad (9)$$

また, 逆にノード D からノード A へ向かうエージェント *i* ∈ *I*<sup>*DA*</sup> については, 各ノードで得る報酬を, 以下の正規分布に 従って設定した.

$$\hat{v}_{i}^{A} \sim \mathcal{N}(500, 500), \qquad \hat{v}_{i}^{B} = 0, 
\hat{v}_{i}^{C} = 0, \qquad \hat{v}_{i}^{D} \sim \mathcal{N}(200, 0) \quad (10)$$

すなわち,通過型エージェントは早い時刻に目的地に到着する ことで大きな報酬を得る.通過型エージェント*i*  $\in$  *I*<sub>P</sub> の活動 可能時間帯 *T<sub>i</sub>* = { $t_i^B$ ,..., $t_i^E$ } については,ノード D へ向かう エージェント *i*  $\in$  *I*<sub>P</sub><sup>D</sup> の活動開始時刻  $t_i^B$  は一様分布 {0,1,2} に,また,ノード A へ向かうエージェント *i*  $\in$  *I*<sub>P</sub><sup>DA</sup> の活動開 始時刻  $t_i^B$  は一様分布 {2,3,4} に従うものとし,活動終了時刻  $t_i^E$  については,  $\forall i \in$  *I*<sub>P</sub>;  $t_i^E = t_i^B + 4$  と設定した.

なお,今回の実験においては,全てのエージェントについ て,同一リンクの同方向への移動は活動時間帯の間に一度しか 実行しないものとした.

**エージェント間の干渉と交通管制**:上述した設定では,滞在 型エージェントは,ノードAから出発するときとノードAへ 戻ってくるときに,それぞれノードAからノードDへ向かう 通過型エージェントおよびノードDからノードAへ向かう通 過型エージェントとの間で交通リソースの競合が発生するた め,適切な交通管制が必要となる.本実験では,交通管理者 は,本節に示したエージェントの需要に関する統計モデルを事 前情報として有しているものとした.ただし,各エージェント の出発時刻および報酬に関する確定値については,通知を受け るまで未知とする.

### 4.2 実験結果

本研究で示した二つのメカニズムは、共に、逐次的に総社 会効用を最大化する割り当てを実現する.その効率について は、既往研究 [Hayakawa 18b, 早川 18] の通りである.本研究 では、二つの課金メカニズムによって実現する収益の違いに着 目して、実験を行った.実験では、通過型エージェントの数を



⊠ 2: Revenue achieved by two pricing algorithms

2とし,滞在型エージェントの数を1から10まで変化させた. 乱数を変化させながら,各条件における計算時間に応じて10 回から100回試行した.

まず,二つのメカニズムの収益を図 2 に示す.図の縦軸は, 交通資源配分の効率性を表し,将来の全エージェントの情報 が既知であった場合の最適交通資源配分で得られる総社会効 用を 1.0 として正規化された値である.図の赤実線は,両メカ ニズムで得られる総社会効用を示している.一方で,緑点線 および青破線は,Dynamic pivot mechanism および Online VCG mechanism で得られるサービスオペレータの収益を表 している.全利用者の効用の合計は,総社会効用とサービス オペレータの収益の差としてみることができる.この図によ ると,Dynamic pivot メカニズムでは,利用者の干渉が大き い時に利用者の効用の合計値が負の値となっている.一方で, Online VCG mechanism は,利用者の干渉が比較的少ない一 定条件下において,サービスオペレータの収益が負となってい ることが分かる.

## 5. まとめ

オンデマンド型の交通サービスを想定し,利用者の希望の 異質性を活用してより良い交通資源配分を実現する割り当てお よび課金のメカニズムを提案した.今後は,事業者利益とサー ビスクオリティを両立させるメカニズム [Hayakawa 18a] の確 立を目指す.

## 参考文献

- [Bergemann 10] Bergemann, D. and Välimäki, J.: The dynamic pivot mechanism, *Econometrica*, Vol. 78, No. 2, pp. 771–789 (2010)
- [Hägerstrand 70] Hägerstrand, T.: What about people in regional science?, *Papers in regional science*, Vol. 24, No. 1, pp. 7–24 (1970)
- [Hayakawa 18a] Hayakawa, K., Gerding, E. H., Stein, S., and Shiga, T.: Price-based Online Mechanisms for Settings with Uncertain Future Procurement Costs and

Multi-Unit Demand, in *Proceedings of the 17th International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*, pp. 309–317 (2018)

- [Hayakawa 18b] Hayakawa, K. and Hato, E.: Dynamic traffic resources allocation under elastic demand of users with space-time prism constraints, arXiv preprint arXiv:1806.10719 (2018)
- [Kitamura 96] Kitamura, R., Pas, E. I., Lula, C. V., Lawton, T. K., and Benson, P. E.: The sequenced activity mobility simulator (SAMS): an integrated approach to modeling transportation, land use and air quality, *Transportation*, Vol. 23, No. 3, pp. 267–291 (1996)
- [Minato 93] Minato, S.-i.: Zero-suppressed BDDs for set manipulation in combinatorial problems, in *Proceedings* of the 30th international Design Automation Conference, pp. 272–277ACM (1993)
- [Parkes 04] Parkes, D. C. and Singh, S. P.: An MDP-Based Approach to Online Mechanism Design, in Advances in Neural Information Processing Systems 16 (NIPS), pp. 791–798 (2004)
- [Rust 94] Rust, J.: Structural estimation of Markov decision processes, *Handbook of econometrics*, Vol. 4, pp. 3081–3143 (1994)
- [Sheffi 85] Sheffi, Y.: Urban transportation networks: equilibrium analysis with mathematical programming methods, *Traffic engineering control. Prentice-Hall, ISBN 0-*13-93-972 (1985)
- [早川 18] 早川敬一郎, 羽藤英二: グラフ列挙手法により容量 制約付き総社会効用最大配分を実現する動的アルゴリズム, 土木計画学研究・講演集, Vol. 57, (2018)

# 集団避難行動モデルを組み込んだ マルチエージェントシミュレーションツール

Multi-agent simulation tool incorporating group evacuation behavior model

石田龍星 秋吉政徳 Ryusei Ishida Masanori Akiyoshi

神奈川大学工学部情報システム創成学科 Department of Information Systems Creation, Faculty of Engineering, Kanagawa University

Evacuation simulation by multi agent model is used to make plans for reducing damages at disaster. In this research, we specially focused on emergent phenomena that aims to provide notices for unexpected evacuation behaviors by expressing embedded individual behavior rules concerning interactions in groups. To construct such simulation tool, we introduced three models as follows; 2-dimensional continuous planes as spacial model, evaluation agents with eyesight and individual behavior rules, and potential models as deciding moving target positions based on mutual behaviors. In the experimental studies, we set two types of agents, that is, agents with notice of evacuation exits and agents without it. Simulation results shows significance of agents with notice of evacuation exits and effects of group sizes as to evacuation behaviors.

# 1. はじめに

災害時には迅速かつ安全に避難をすることが重要であり,避 難安全計画や建物設計の支援のために,避難シミュレーション が用いられる [山下 2014].避難シミュレーションでは,エー ジェント・ベース・シミュレーションが主流となっており,マ ルチエージェントは簡単なルールからミクロ・マクロのループ により明示されていなかった新たな行動や現象が起こる創発現 象を発生させることができる.

本稿では,避難者間の相互作用によって創発される避難群 衆行動の発生を目的とし,シミュレータ使用者にとって予期し なかった避難行動への気づきを与える集団避難行動シミュレー ションモデルを提案する.

# 2. 提案モデル

# 2.1 空間モデル

避難シミュレーション空間を構築する空間モデルにはネット ワークモデルやセル空間モデルなどが考えられるが,避難エー ジェントの行動空間は,行動をより精緻に表現するために2次 元連続平面での空間としている.ただし,障害物となる壁や建 物は,複雑な形状であっても避難エージェントとの距離を計算 するために2次元のグリッド状の形状で構成している.

## 2.2 避難者モデル

避難者モデルには、エージェント・ベース・モデリングとし て、マルチエージェントモデルを基本とする.エージェントの 行動には、外部の環境を認識し、意思決定行動ルールにより行 動を行うとした.環境認識には視野を実装し、障害物や出口, 他の避難者を認識する.次の動作を決定する意思決定行動ルー ルは、if-then 形式により表現する.そして、避難行動として 他の避難者を避けたり、移動経路上の障害物を迂回するような 行動を表現するためにポテンシャルモデルを用いる.

### 2.2.1 視野の設計

避難エージェントが,他の避難者や出口を認識するために視 野を実装する.本シミュレーションで実装した避難エージェン

連絡先:石田龍星,神奈川大学,神奈川県横浜市神奈川区六角橋3丁目 27-1,045-481-5661,r201504099sb@jindai.jp



図 1: 避難エージェントの視野

表 1: 避難エージェントの意思決定行動ルール

| 避難者の種類      | 避難行動ルール        |
|-------------|----------------|
| 出口を知っている避難者 | 1. 出口を発見したら向かう |
|             | 2. 知っている出口に向かう |
| 出口を知らない避難者  | 1. 出口を発見したら向かう |
|             | 2. 集団を追従       |
|             | 3. 集団を一時的に追従   |
|             | 4. ランダムに移動     |

トの視野機能を図1に示す.視野角と視野の最大距離により 視野機能を構成し,避難エージェントは視野内に入ったものを 認識することができる.

### 2.2.2 意思決定行動ルールの設計

避難エージェントとしては、出口を知っている避難エージェ ントと出口を知らない避難エージェントより構成する. 避難 エージェントの行動ルールを表1に示す.

出口を知っている避難エージェントは、避難空間における脱 出口を知っているため、その出口方向に移動する.しかし、移 動中に他の出口を発見した場合には、その出口に移動すると いった行動をとるルールとした.出口を知らない避難エージェ ントは、基本としていかなるルールにより行動していたとし ても出口を発見することがあれば、出口を知っている避難エー ジェントと同様にその出口を向かう行動をとることとした.現 実の避難者の行動は予め定まっていないことから,その他の行 動ルールは時間ステップごとにランダムに発火することとし た.集団を追従するルールでは集団を視野内におけるエージェ ント数がk人以上であることと定義し,追従ルールを発火させ ることとした.集団を発見した場合,視野内における避難エー ジェントの一人を追従し,集団を発見することができなかった 場合には,ランダム行動をとる.なお,集団に追従するルール が発火後は,追従先の避難エージェントが視野内から外れるこ とがない限り,時間ステップごとにランダムに発火せず,ルー ルを固定する.

### 2.3 ポテンシャルモデル

避難シミュレーションの行動モデルや,移動ロボットの障害 物回避モデルとしてポテンシャルモデルがある.他の行動モ デルとして,目標点までの引力と障害物への斥力とした運動 方程式で局所的な働きを表現する Helbing らの Social Force Model などが考えられる [Helbing 1995].しかし,目標地点 までの経路上に障害物がある場合に,障害物の形によっては移 動中に立ち往生する問題がある.空間モデルをネットワークモ デルとし,エージェント行動に制約を与えることや,柳沢らの 提案する移動経路にサブゴールの経由点を決めることにより この問題を解決できるが,エージェントの行動ルールが複雑に なってしまう可能性がある [柳沢 2006].

そこで、ポテンシャルモデルはサブゴールを設定すること なく、目標地点まで経路設計を行うことができるため、ポテン シャルモデルを用いる。目黒らはポテンシャル場から避難エー ジェントの進行方向を決定する避難行動シミュレーション手法 を提案しているが、シミュレーション空間はグリッド上のセル 空間によって構成されており、進行方向はムーア近傍の8方 向にしか移動することができない[目黒 1995].本シミュレー ションモデルでは、避難行動をより精緻に扱うため空間モデ ルを二次元連続平面での空間で構成しているため、ポテンシャ ル関数の最急降下法によって求められるポテンシャルベクトル と、避難エージェントの移動ベクトルを合成することにより進 行方向を決める.



図 2: ポテンシャルモデルによる進行方向の変更

ポテンシャル関数には島倉らを参考に D.H.Kim らによって 提案されたポテンシャル関数を用いる [島倉 2009][Kim 2006]. 斥力ポテンシャル U<sub>o</sub> は次式により定義される.

$$U_o(x,y) = \sum_{i=1}^{n} c_o exp\{-\frac{(x+x_{oi})^2 + (y+y_{oi})^2}{lo^2}\}$$
(1)

ここで, *x<sub>oi</sub>*, *y<sub>oi</sub>* は, 斥力となる障害物の座標, *c<sub>o</sub>* はポテン シャル関数の影響度, *l<sub>o</sub>* はポテンシャルの山の大きさを調整す るパラメータとして用いる. ポテンシャルベクトルには, 最急 降下法をも用いることによって,避難エージェントの移動方向 ベクトルと合成する斥力ベクトルを決める.最急降下法*d*は, 次式によって定義される.

$$d = -gradU_o \tag{2}$$

## 3. 群衆移動実験

# **3.1** 群衆実験の条件

閉鎖空間内で1つの出口に向かう群衆実験Aと,2つの出 口に同時に向かう群衆実験Bを行った.シミュレーションを 行う空間は以下の図3に示すように縦幅15m,横幅10mの空 間に幅1mの出口を二つとした.実験は群衆実験A,群衆実験 Bともに避難エージェント数を30人,40人,50人の条件で 行う.

群衆実験 A はすべての避難エージェントが右の出口を知っ ている状態で行動をする.群衆実験 B は避難エージェントの 半分が左の出口を知っており,残る半分が右の出口を知ってい る状態で行動を開始する.群衆実験は両実験ともにエージェン トの初期位置が上部 3m 以内に収まる範囲でランダムに配置し ている.また,避難エージェントの視野角は 60 度,視野の最 大距離を 4m とし,歩行スピードは 1.5m/s としている.



図 3: シミュレーション空間

## 3.2 群衆実験Aの結果

群衆実験Aにおける避難エージェントが脱出した出口につい て以下の表3に示す.エージェント数30人ではすべてのエー ジェントが自分の知っている出口へ脱出しているが,エージェ ント数40人,エージェント数50人では,複数のエージェン トが自らの知ってる出口ではない出口で脱出している.この行 動は出口を知っているエージェントの意思決定行動ルールにお ける出口が視野に入った場合はその出口に向かうルールが発火 しているためだと考えられる.

避難エージェントが移動した軌跡を図4に示す.エージェン ト数 30 人ではポテンシャルモデルにおける斥力ポテンシャル の影響が少なく,左の出口が視野に入ることは無かったが,初 期位置が比較的に左の位置で移動を開始した避難エージェント は左の出口を発見している.このように,エージェント数によ りポテンシャルの影響が異なり,他の脱出口を発見する創発現 象を軌跡で確認することができる.

## 3.3 群衆実験 B の結果

群衆実験 B の実験結果を表 3 に示す. 3 つのすべてのシミュ レーションで,他のゴールで脱出する避難エージェントが多 くいることがわかる.エージェント数が 30 人,50 人のシミュ レーションでは,3 割程度が他のゴールで脱出している.



図 4: エージェントの行動軌跡

群衆実験 B における避難エージェントの移動軌跡を図 5 に 示す.群衆実験 A の移動軌跡と比べると,移動途中で出口を発 見し,その出口へ向かったような軌跡ではないことがわかる. 異なる出口を目指すエージェント集団に囲まれていた場合は, そのまま集団の流れにより,他の出口で脱出している.

#### **3.4** 群衆実験の考察

群衆実験 A・Bより,初期位置によって群衆の流れに逆らう ような動きをすることができず,結果として自らの知らない出 口を発見したり,他の避難群衆に導かれるようにして他の出口 を発見するような創発現象を確認することができた.この結果 について,現実でも人の過度な密集状態での移動では,自分の 思う方向に進むことが難しいことが表現できている.通勤ラッ シュ時の駅のホームのような狭い通路などで人が密集している 状態では,群衆として一方向へ移動の流れができている場合, 逆方向への移動はできずその流れに巻き込まれてしまうことが ような現象を本実験においても確認することができた.

# 4. 集団行動ルールを組み込んだ避難行動実験

## 4.1 シミュレーション条件

図6に示すような単純な長方形の空間を用意し、シミュレー ションを行う.シミュレーション条件として、出口を知らない 避難者が30人の条件と、出口を知っている避難者が10人、出 口を知らない避難エージェントが20人の合計30人の避難エー ジェントを空間に配置する.初期位置としてランダム分布(R)、 または中央分布(C)に分ける.空間は出口が空間の角に1つ (A)、または2つ(B)としてシミュレーションを行う.なお、 60stepで1秒としており、全てのエージェントが脱出できな くても60秒(3600step)でシミュレーションを終了することと

表 3: 実験結果 B

| エージェント数 | 知っている出口で脱出 | 他の出口で脱出 |
|---------|------------|---------|
| 30      | 20         | 10      |
| 40      | 32         | 8       |
| 50      | 35         | 15      |



図 5: エージェント数 50 人の移動軌跡

した.また,避難エージェントの視野角は 60 度,視野の最大 距離を 4m とし,歩行スピードは 1.5m/s としている.



図 6: シミュレーション空間

### 4.2 シミュレーション結果

条件ごとに避難シミュレーションを 10 回行った. 同じ条件 で 10 回のシミュレーションを行ったが, ランダム行動という ルールが避難エージェントに実装されているため, 揺らぎの影 響により, 避難エージェントの脱出人数がシミュレーションご とに大きく変わることもあった. それぞれのシミュレーション 条件で脱出人数が最大だったシミュレーションのステップ数に おける脱出人数のグラフを図 7 に示す.

出口を知っている避難エージェントが10人のシミュレーショ ン条件では500stepから1500stepまでの間で多くの避難エー ジェントが出口から脱出していることがわかる.このステップ 間で20人以上の避難エージェントが脱出していることから, 出口を知っている避難者は全員脱出し,出口を知らない避難 エージェントも10人以上が脱出していることがわかる.全て の避難エージェントが出口を知らない条件でのシミュレーショ ン結果は,出口数が2つのBC0とBR0の合計脱出人数が15 人,14人となっていることから,避難エージェントの初期位 置で脱出人数の変化はあまりなかったと言える.また,出口を 知っている避難者のいる条件に比べ,段階的に脱出しているこ とがわかる.また,AC0とAR0における脱出人数は3人と 5人の避難エージェントしか脱出することができていない.10 回のシミュレーションの中でも全てのエージェントが脱出でき ていない場合も何度かあった.

シミュレーション中で追従ルールが発火している避難エー ジェント数と全体の集団数を表すグラフを図 8, 図 9 に示す. 出口を知っている避難エージェントのいる条件では, 1step 目



図 7: 脱出人数

から 10 人近くの出口を知らない避難エージェントの追従ルー ルが発火し,600step あたりから減少しているため,出口を 知っている避難エージェントを追従することで出口から脱出し ていることがわかる.AC0 のシミュレーションでは 20 人近く の多数の追従が発生しているが,追従先の避難エージェントが ランダム行動で出口を見つけることができなかったため,ほ とんどが脱出することができなかった.集団サイズは,AR0 のシミュレーションでは集団サイズが9つになっている.追従 ルールでは,5 人以上の避難エージェントを視野内で見たとき に追従するルール設計をしているため,視野内における避難 エージェントが集団でないことがあるため,AR0 のような多 く追従集団が形成された.



図 8: 追従人数

# 4.3 考察

出口を知らないエージェントが出口を知るエージェントに 追従し,群れが形成されることによって,追従者が増加し,脱 出人数も増加するが,出口を知らない避難者を追従してしまっ た場合には,多くの避難エージェントが脱出することができな い場合があることがわかる.現在の追従ルールでは,視野から 追従先の避難エージェントが外れない限り,追従をやめること のないルール設計とし,集団サイズの制限はしていないため, 追従先が出口の知らない避難者であったとしても追従を続けて いるためほとんどの避難エージェントが出口から脱出できない ような結果になった.このことは,避難行動における出口に向 かう避難行動者の重要性や,適切な集団サイズを促す必要性を 示唆している.



図 9: 集団サイズ

# 5. まとめ

本稿では、マルチエージェントモデルを用いて、避難者行動 の創発現象を表現することで、シミュレータ使用者に気づきを 与える集団避難行動シミュレーションモデルを提案した.ポテ ンシャルモデルによるシミュレーション実験により、創発現象 を確認することができた.また、集団行動ルールを組み込んだ 避難エージェントがいるシミュレーション実験では、避難エー ジェントの追従ルールによる群れが形成されるが、追従先の避 難エージェントが出口を知っているか否かにより、脱出人数が 変化した.今後は、障害物のある空間でのシミュレーションや エージェント内部のダイナミクスの変化を起こす機能を持った エージェントモデルを構築し、創発現象の発生条件について研 究を進める予定である.

# 参考文献

- [山下 2014] 山下倫央,野田五十樹, "避難シミュレーションの 実社会への応用",情報処理, pp 572-578, 2014
- [Helbing 1995] Helbing, D. and Molnar, "Social force model for pedestrian dynamics", Physical Review E, Vol. 51, pp. 4282-4286, 1995
- [柳沢 2006] 柳沢豊, 山田辰美, 平田圭二, 佐藤哲司, "視線に基 づくサブゴール決定過程を取り入れた歩行者モデル", 情 報処理学会論文誌 47(7), pp. 2160-2167, 2006
- [目黒 1995] 横山秀史, 目黒公郎, 片山恒雄, "避難行動解析への ポテンシャルモデルの応用", 土木学会論文集 1995(513), pp. 225-232, 1995
- [島倉 2009] 島倉諭, 項警宇, 稲垣仲吉, 鈴木達也, "ポテンシャ ルを組み込んだパーティクルコントロールによる自律移 動ロボットの障害物回避制御", ロボティクス・メカトロ ニクス講演会講演概要集 2009(0), pp. 2A1-G05, 2009
- [Kim 2006] D. H. Kim, S. Shin, "Local path planning using a new artificial potential function configuration and its analytical design guidelines", Advanced Robotics 20, pp. 111-135, 2006

# 耳音響認証における観測ゆらぎ軽減手法の一検討

A study of observation fluctuation reduction method for ear acoustic authentication

安原 雅貴 \*1 Masaki Yasuhara

貢 \*1 荒川 隆行 \*2 nara Takayuki Arakawa 越仲 孝文 \*2 Takafumi Koshinaka

矢野 昌平<sup>\*1</sup> Shohei Yano

\*1長岡工業高等専門学校 NIT, Nagaoka College \*<sup>2</sup>日本電気株式会社 NEC Corporation

Ear acoustic authentication is a type of biometric authentication that uses the acoustic characteristics of the ear canal. A special earphone which has a driver and a microphone is used in this system. The measurement data has error due to the attaching and detaching of earphone each time. In our previous study, we proposed a special earphone which has a driver and two microphones. And multiple features are concatenated. However, the accuracy didn't improve. It's conceivable that the concatenation method is not good. In this study, we conceive that multiple features obtained by multiple microphones in one measurement complement observation fluctuation. As a result, the accuracy was improved. By analyzation of variance, we can say that the features were interpolated, and the learning data increased by using multiple microphones. We conclude that the method using the earphone which has multiple microphones is effective.

# 1. はじめに

指紋や顔による生体認証は普及が進んでいる.多くの場合, 認証はサービス開始時に行われる. そのため途中でユーザが入 替わる「なりすまし検知」が困難である.我々は、新たな生体 情報として耳穴(外耳道)に着目し,耳音響認証を提案した. 耳音響認証はマイクロホン内蔵イヤホンにより外耳道の音響伝 達特性を取得し、特徴量として用いる. イヤホンの装着具合等 により特徴量に差異を生じる.これを観測ゆらぎと呼ぶ.我々 は過去に、2つのマイクロホンを 90 deg に配置したイヤホン を作成し、角度の異なるマイクロホンからの特徴量を利用する ことで、特徴量の角度データを補間し、観測ゆらぎ等に対して 強靭な認証になると考え検討を行った.しかし, 画期的な精度 向上は得られなかった.特徴量の扱い方と角度の補間に問題が あると考えられる.本研究では、さらに角度データを補間する ため, 90 deg ずつに 4 つのマイクロホンを内蔵したイヤホン を作成し、各マイクロホンからの特徴量の取り扱い方法と補間 方法とを検討することで,観測ゆらぎ軽減により精度向上の可 能性を実験的に検討する.また,観測ゆらぎの要因について, 特徴量の分散の観点から考察を行う.

# 2. 実験方法

耳音響特性は図 1(a) に示す測定システムを用いて,MLS イ ンパルス応答測定法により測定する.実験は 10~40 歳代の男女 38 人に対し,左耳測定,4 ch,10 回/人,毎回着脱をして測定 を行う.90 deg ずつにマイクロホンを配置できるように図 1(b) のように設計し,3D プリンタで筐体を出力する.測定した耳 音響特性に対し,最小位相系を用いてインパルス応答が先頭に なるように処理する.このとき,信号長は 16384 次元 (0.3715 秒)を先頭から 256 次元で切り出す次元削減処理をしたもの を特徴量として用いる.特徴量に対して,SVM(linear karnel,  $C = 100, \gamma = 0.001$ )を用いて識別精度を算出する.識別性能 指標として等誤り率 (equal error rate : EER)を用いる.EER は,誤って他人を本人と識別した確率 (fail acceptance rate

連絡先:長岡高専電気電子システム工学科音響工学研究室 E-mail: syano@nagaoka-ct.ac.jp : FAR)と誤って本人を他人と識別した確率 (fail recognition rate : FRR) とが等しくなる値であり低いほど良い性能であることを示す.



図 1: 耳音響特性の測定システム

本研究では、4 ch 分の特徴量の取り扱いとして次の4手法 を用いる.手法①として各 ch を個別に用いる手法.手法②と して 4 ch 分の特徴量を時間軸で連結し用いる手法. さらに, 本報告において提案する手法③および手法④で EER を算出し 比較検討する.手法①においては、図2のようにデータセット を分けて EER を算出する. 図 2 では, Sub0 を本人, Sub1 を 学習しない他人、その他を学習する他人として分ける場合を示 している. 各ユーザ 10 個の耳音響特性のうち,本人データと して5個を学習,残り5個をテストとして用いる.手法②で は 4ch 分の特徴量を時間軸で連結させたものを特徴量を用い る. 手法③では図3のようにデータセットを分け, 4 ch 分の 特徴量を同一のラベルとして取扱う.図3において、テスト のデータ数は4 ch 分を同一ラベルとして取扱うため Sub0 で 20個, Sub1 で 40個の合計 60個となる. 手法①とデータ数を 合わせるため, Sub0 より5個, Sub1 より5個を無作為に抽 出し EER を算出する. Sub0~Sub37 を変更した全組合せで EER を算出しその平均 EER を導出する.手法④では, ch 間 のデータを足し合わせ2で割る補間処理により補間データを作 成する.補間処理は 45 deg 毎に設置された 8 個のマイクロホ ンからの耳音響特性を得ることを模擬している.補間処理で得 られたデータは学習に用い、テストデータには用いない.他手

法と同様に EER を算出し平均 EER を導出する.手法①~④ において学習データとテストデータとには重複はない.それ以 外の特徴量は提案手法①と同様に学習させ,テストデータに は本人5個,他人5個で無作為に抽出を行ったものを用いる.

さらに手法①,③,④において,特徴量の周波数振幅特性 から,周波数に対するクラス内分散*V*<sub>W</sub> とクラス間分散*V*<sub>B</sub> を 導出し,耳道音響特性に含まれる観測ゆらぎの要因について検 討を行った.

|            | Sub0                  | Sub1 | Sub2 | Sub37 |
|------------|-----------------------|------|------|-------|
| 1ch 5<br>5 | Train<br>[∵:Test : :) | Test |      | Train |

図 2: 手法①の学習データとテストデータの分割

|            | Sub0           | Sub1  | Sub2 | Sub37 |
|------------|----------------|-------|------|-------|
| 1ch 5<br>5 | Train<br>XTest | XTest |      |       |
| :          |                | Use 5 |      | Train |
| 4ch        | Train<br>XTest | data) |      |       |

図 3: 提案手法③の学習データとテストデータの分割

# 3. 実験結果

図4に、手法①~④の平均 EER を示す.本報告での提案手 法である手法③, ④が, 他手法の EER より 2~3%ほど低下し 精度が向上している.また,両耳の特徴量を用いた際に識別精 度向上に有効であった手法②よりも、精度が向上している.こ れより提案した手法③,④は有効であると考えられる.図5, 6 に手法①, ③, ④の各 ch 特徴量のクラス内分散, クラス間 分散と周波数との関係を示す.図5,6において、手法④は手 法③の特徴量の線形的な拡張であり同じ分散を示す. クラス間 分散は複数のチャンネルを同一ラベルとして扱っても各チャン ネルと同じ分散を示している. クラス内分散は提案手法のとき に大きくなっており、各チャンネルで得られる特徴量に差異が あることがわかった.この結果より、マイクロホンの角度を変 えたことで得られる特徴量が変化することが明らかになった. クラス内分散が手法③,④では悪くなっていることから,この 手法では SVM への学習の質が悪くなっているといえる.しか し、識別精度は向上している.これは、角度データが多くなっ たことで観測ゆらぎを補間したことによるものと, 各チャンネ ルで特徴量を扱うよりも手法③,④の方が学習データが多いこ とによるものと2つが考えられる.提案した手法③と手法④ を比較すると、手法④の方が精度が向上しているが、0.2%ほ どである.このことから、角度データが多くなったことで観測 ゆらぎを補間できることが示唆される.また、今回の実験で手 法③,④の精度が向上したのは、学習データ数が多くなった ことに大きく寄与していると考えられる.また、図5より、マ イクロホンの違いによる周波数特性の違いは低周波に現れるこ とがわかった.

# 4. まとめ

耳音響認証における測定時の観測ゆらぎの軽減手法を検討 した.90 deg ずつに配置したマイクロホンを4つ内蔵したイ



図 6: 周波数軸上の特徴量のクラス間分散

ヤホンを用いることで、異なる特徴量を得られることがわかっ た. 異なる特徴量を同一に学習させると、精度が悪くなりそ うだが、今回の実験では精度は良くなった. 角度データが多く なったことで観測ゆらぎを補間したことによるものと、各チャ ンネルで特徴量を扱う手法①よりも提案した手法③、④の方 が学習データが多いことによるものとが考えられる. 複数のマ イクロホンを内蔵したイヤホンを用いる手法は有効であること がわかった. 加えて、既成品のイヤホンにマイクを1つ取り付 けた場合の EER は 2%なので、イヤホンの設計が重要である ことがわかった. 4 ch イヤホンを作成した小林毅範氏に感謝 する. 本研究は JSPS 科研費 JP16K00182 の助成を受けたも のです.

# 参考文献

- [Yano 17] 矢野昌平,荒川隆行,越仲孝文,今岡仁,入澤英毅, "誤差の周波数拡散と加算平均処理による耳音紋認証の精 度向上,"信学論(A), Vol.J-100A, no.4, pp.161-168, Apr.2017.
- [Kobayashi 17] 小林毅範, 矢野昌平, 荒川隆行, 越仲孝文, "複数マイクロホンを用いた耳音響認証の認証精度向上の 検討", 信学技報, P.164, 2017.
- [Yasuhara 18] 安原雅貴, 矢野昌平, 荒川隆行, 越仲孝文, "両耳での耳音響認証の特徴量設計", 信学技報, P.77, 2018.

# New similarity scale to recognize bird calls and abnormal sounds of concrete/machine Development of pattern matching software using multi-CPU

# Michihiro Jinnai<sup>\*1</sup>

# Edward James Pedersen \*2

<sup>\*1</sup> Nagoya Women's University

\*2 Central Queensland University, Australia

A new similarity scale called the Geometric Distance, that numerically evaluates the degree of likeness between the standard pattern and the input pattern is proposed. Traditionally, the similarity scales known as the Euclidean distance and cosine similarity have been widely used to measure likeness. Traditional methods do not perform well in the presence of noise or pattern distortions. In this paper, a mathematical model for similarity is proposed to overcome these limitations of the earlier models, and a new algorithm based on a one-to-many point mapping is proposed to realize the mathematical model. Using the new similarity scale, experiments in bird call recognition were carried out in noisy environments. Furthermore, experiments in abnormal sound recognition of concrete structure were carried out. In all cases a significant improvement in recognition accuracy is demonstrated.

## 1. Introduction

Human beings, dogs, cats, and other such mammals exhibit a "sense of similarity" in their perception of sounds and sighted objects. To emulate this sense of similarity algorithmically in a "similarity scale" is an important objective for developing computer intelligence.

In an acoustic similarity scale, the degree of likeness between an acoustic standard pattern (control) and an undetermined input pattern is evaluated as a "distance" between the two patterns. This process arbitrarily emulates a human perceiving a sound and comparing that autonomously with 'templated' or remembered sounds. Ostensibly, a software-based similarity scale would return a short 'distance' for two patterns that humans would consider as similar to, or the same as each other, and a long 'distance' for two patterns that humans would consider as dissimilar.

Euclidean distance and cosine similarity are widely used to measure likeness. Conventional similarity scales compare patterns using one-to-one mapping. The result of one-to-one mapping is that the distance metric is highly sensitive to noise, and the distance metric changes in a staircase pattern when a difference occurs between peaks of the standard and input patterns. As an improvement, we have developed a new similarity scale called "Geometric Distance (GD)" [1]. GD is more accurate than the conventional similarity scales in noisy environments.

The GD similarity scale and allied detection software have proven applicable in a broad range of dynamics: from automated call detection of endangered species [2] from within 'big' environmental data sets; to real-time fault detection in concrete structures and operating machinery [3]. In this paper, we describe the underlying mathematical model for similarity; the GD algorithm; and we introduce automatic recognition software for bird vocalisations that uses the GD algorithm.

# 2. The LPC spectrogram of bird sounds

The lower diagram of Fig. 1 shows the waveform of a Noisy Miner Chur call (Paul G. McDonald; University of New England, Australia 2012, *Cooperative bird differentiates between the calls* 

Contact: Michihiro Jinnai, mjinnai@nagoya-wu.ac.jp

of different individuals, even when vocalisations were from completely unfamiliar individuals. Biology Letters 8: 365-368).



Fig. 1 Spectrogram of bird vocalisation



Fig. 2 Processing procedure in recognition system

The upper diagram of Fig. 1 shows a spectrogram (timefrequency-power) of the exact same signal. In Fig. 1, the waveform has been segmented with 18.8msec frame width and 0.31msec frame period, and the LPC spectrum has been calculated for each frame. Next, the spectrogram has been coloured according to logarithmic power of the LPC spectrum. We have set the software analysis parameters for this bird vocalisation recorded at 16kHz sampling frequency, 16bit quantization, to an LPC order of 12; restricted the spectral frequency range to 0Hz to 8000Hz, with an 11.5Hz frequency resolution; and set a dB threshold filter of 0dB to -60dB logarithmic power spectrum. To analyze transient signals such as bird vocalisations, we set a fractional frame width (with respect to total signal period) as shown at the bottom of Fig. 1. LPC spectrum analysis is suitable for spectral modeling of transient signals.

# 3. Automatic recognition procedure

Fig. 2 shows the software procedural stages for automated signal detection and recognition. First, the software differentiates potential signals from background noise (segmentation). Second, the software extracts the segmented signals and establishes the segmented signal's spectral characteristics (time-frequency-power) using LPC spectral analysis. Third, the software compares the spectral characteristics of the extracted signal (the input pattern) with a previously registered standard pattern of the focal signal (the signal to be automatically detected). Comparison is effected using the GD similarity scale. To expedite the process, the software executes parallel processing using multiple CPUs [4][5].

# 4. Mathematical model for similarity

For a functional similarity scale, we need first to develop a mathematical model for similarity, that can perform numerical processing by computation. In the GD process, a mathematical model incorporating the following two characteristics is used:

< 1 > A distance metric which shows good immunity to noise.

< 2 > A distance metric which increases monotonically when a difference increases between peaks of the standard and input patterns.

Figs. 3 and 4 graphically demonstrate the underlying computational and algorithmetric processes. The upper diagram of Fig. 3 shows an example of the "difference" where the standard pattern has two peaks in the spectrogram, and input patterns 1, 2, and 3 have a different position on the first peak. Note that both the standard and input patterns have the same volume. Fig. 4 shows an example of a "wobble" where the standard pattern has a flat spectrogram. Input patterns 4 and 5 have a "wobble" on the flat spectrogram, and input pattern 6 has a single peak. Each pattern however, is assumed to have variable  $\alpha$  in the relationship shown in Fig. 4. Therefore, the standard and input patterns always have the same volume.

Bar graphs at the bottom right of Figs. 3 and 4 express the characteristics < 1 > and < 2 > of the mathematical model diagrammatically.

## 5. New algorithm for similarity scale

A new algorithm based on one-to-many point mapping is proposed to realize the mathematical model. In the GD algorithm, when a "difference" occurs between peaks of the standard and input patterns with a "wobble" due to noise, the "wobble" is



Fig. 3 Typical example of "difference"



Fig. 4 Typical example of "wobble"

absorbed and the distance metric increases monotonically according to the increase of the "difference".

In statistical analysis, a normal distribution is usually used as a model for a phenomenon. Then, a "kurtosis" and a "skewness" are used to verify whether the phenomenon obeys the normal distribution or not. Here, the kurtosis 'a' and the skewness 'b' are statistics, and we explain them using Figs. 5 and 6. If a probability distribution of the phenomenon follows the normal distribution, then a = 3 (Fig. 5(b)). If it has flatness relative to the normal distribution, then a < 3 (Fig. 5(a)). Conversely, if it has peakedness relative to the normal distribution of the phenomenon is symmetrical about the mean  $\mu$ , then b = 0 (Fig. 6(b)). If the tail on the left side of the probability distribution is longer than the right side, then b < 0 (Fig. 6(a)). Conversely, if the tail on the left side of the probability distribution is longer than the right side of the probability distribution is longer than the left side of the probability distribution is longer than the left side of the probability distribution is longer than the left side.

In this section, we explain the GD algorithm using Figs. 7 and 8. Fig. 7 shows the spectra (frequency-power) extracted from a Macleay's Fig Parrot (*Cyclopsitta diophthalma macleayana*) vocalisation. Fig. 7 shows standard and input patterns that have been created using the momentary power spectrum (frequency-power) of standard and input sounds. Figs. 8(a)-(e) respectively show typical examples of the standard and input patterns. Note that the power spectrum is generated from the output of a filter bank with *m* frequency bands. The *i*-th power spectrum values (where, i = 1, 2, ..., m) of the standard and input sounds are divided by their total energy, so that normalized power spectra  $s_i$  and  $x_i$  have been calculated, respectively. At this moment, the standard and input patterns have the same area size. Moreover, Figs. 8(a)-(e) respectively show reference patterns that have the initial shape  $r_i$  of a normal distribution.

With the GD algorithm, a difference in shapes between standard and input patterns is replaced by the shape change of the reference pattern using the following equation.

$$r_i \leftarrow r_i + (x_i - s_i) \qquad (i = 1, 2, 3, \cdots, m) \qquad (1)$$

Next, we explain Eq. (1) using Figs. 8(a)-(e).

• Fig. 8(a) gives an example of the case where the standard and input patterns have the same shape. Because values  $r_i$  of Eq. (1) do not change during this time, the reference pattern shown in Fig. 8(a) does not change in the shape from the normal distribution.

• Figs. 8(b)-(d) respectively show examples exhibiting a small, medium, and large "difference" of peaks between the standard and input patterns. If Eq. (1) is represented by the shapes, as shown in Figs. 8(b)-(d), value  $r_i$  decreases at peak position i of each standard pattern. At the same time, value  $r_i$  increases at peak position i of each position i of each input pattern.

• Fig. 8(e) typically shows the standard pattern having a flat shape and the input pattern where a "wobble" occurs in the flat shape. Because values  $r_i$  increase and decrease alternatively in Eq. (1)



Fig. 5 Shape change and kurtosis value 'a'



Fig. 6 Shape change and skewness value 'b'



Fig. 7 Standard and input patterns

Fig. 8 Shape change of reference patterns

during this time, the reference pattern shown in Fig. 8(e) has a small shape change from the normal distribution.

With the GD algorithm, we replace the mean  $\mu$  shown in Figs. 5 and 6 with the centre axis of the normal distribution (reference pattern) shown in Fig. 8(a). Then, we replace the kurtosis 'a' and the skewness 'b' with a kurtosis 'A' and a skewness 'B' shown in the following equations.

$$A = \frac{\left\{\sum_{i=1}^{m} r_{i}\right\} \cdot \left\{\sum_{i=1}^{m} (L_{i})^{4} \cdot r_{i}\right\}}{\left\{\sum_{i=1}^{m} (L_{i})^{2} \cdot r_{i}\right\}^{2}} \quad B = \frac{\left\{\sqrt{\sum_{i=1}^{m} r_{i}}\right\} \cdot \left\{\sum_{i=1}^{m} (L_{i})^{3} \cdot r_{i}\right\}}{\left\{\sum_{i=1}^{m} (L_{i})^{2} \cdot r_{i}\right\}^{\frac{3}{2}}} \quad (2)$$

Where,  $L_i$  (i = 1, 2, ..., m) is a deviation from the centre axis of the normal distribution as shown in the reference pattern of Fig. 8(a). Then, numerical experiments were carried out to study the relationships between the kurtosis 'a' and the kurtosis 'A' or between the skewness 'b' and the skewness 'B'. As a result of the experiments, we have confirmed that they have the same characteristics [1][3].

For the reference pattern whose shape has changed by Eq. (1), the magnitude of shape change is numerically evaluated as the variable of kurtosis A and skewness B. The kurtosis and the skewness of the reference pattern can be calculated using Eq. (2). Figs. 8(a)-(e) show how A and B vary with  $r_i$ .

• In Fig. 8(a), the values  $r_i$  do not change. The kurtosis becomes A = 3 and the skewness becomes B = 0.

• In Fig. 8(b), the position *i* of the decreased  $r_i$  and that of the increased  $r_i$  are close. Because the effect of an increase and a decrease is cancelled out, the kurtosis becomes  $A \approx 3$  and the skewness becomes  $B \approx 0$ .

• In Fig. 8(d), because the shape of the reference pattern is flattened relative to the normal distribution and the shape of the reference pattern has a long tail to the right side, the kurtosis becomes  $A \ll 3$  and the skewness becomes  $B \gg 0$ .

• In Fig. 8(c), because the shape of the reference pattern is an intermediate state between (b) and (d), the kurtosis becomes A < 3 and the skewness becomes B > 0.

• In Fig. 8(e), the reference pattern has a small shape change from the normal distribution, and the kurtosis becomes  $A \approx 3$  and the skewness becomes  $B \approx 0$ .

From Figs. 8(a)-(d), we can understand that the values |A| and

|B| respectively increase monotonically according to the increase of the "difference" between peaks of the standard and input patterns. Also, from Fig. 8(e), it is clear that  $A \approx 3$  and  $B \approx 0$  for the "wobble". In this method, when a "difference" occurs between peaks of the standard and input patterns with a "wobble" due to noise, the "wobble" is absorbed and the distance metric increases monotonically purely in accord with the increase of the "difference". On this basis, we verify that the GD algorithm matches the characteristics <1> and <2> of the mathematical model. GD is defined using both the kurtosis A and the skewness B [3]. We have both one-dimensional GD and two-dimensional GD. In addition, we have a fast calculation GD algorithm [1][3].

# 6. Evaluation experiments

To authenticate the effectiveness of the GD algorithm described in Section 5, we performed evaluation experiments for the vocalisations of Macleay's Fig-Parrot. Fig. 9 shows that, using the GD algorithm, pattern matching even in a noisy environment is accurate. The same GD algorithm has been successfully used to locate cavities in concrete structures by comparing the acoustic response to controlled surface tapping above integral concrete and concrete compromised by erosion cavities. Recognition accuracy comparing taps arising from integral and cavity-compromised concrete is 17/20 [5]. These applied experiments verify the effectiveness of the GD algorithm.

# 7. Conclusions and future work

We have described the GD algorithm and introduced associated automatic recognition software for bird vocalisations. The software executes parallel processing using multiple CPUs. In our future work, we will continue to improve the recognition software.

## References

- [1] M. Jinnai, S. Tsuge, S. Kuroiwa and M. Fukumi, "A New Geometric Distance Method to Remove Pseudo Difference in Shapes", *International Journal of Advanced Intelligence*, Volume 2, Number 1, pp. 119-144 (2010) <u>http://aia-i.com/ijai/index.html</u>
- [2] M. Jinnai, N. Boucher, M. Fukumi and H. Taylor, "A new optimization method of the geometric distance in an automatic recognition system for bird vocalisations", *International Congress on Acoustics*, 105, (April 2012, Nantes, France) <u>http://www.soundid.net/</u>
- [3] M. Jinnai, Y. Akashi, K. Hashimoto and S. Hayashi, "Method for detecting abnormal sound and method for judging abnormality in structure by use of detected value thereof", *Patent No.* US9552831(2017), AU2016200487(2017), CA2918533(2018), JP5956624(2016)
- [4] M. Jinnai, "A new segmentation method of bird vocalisations recorded in the distance", 2018 Autumn Meeting, Acoustical Society of Japan, 3-1-5

[5] M. Jinnai, K. Hashimoto, S. Hayashi and E. J. Pedersen, "Recognition of abnormal vibrational responses of concrete structures", 2019 Spring Meeting, Acoustical Society of Japan, 1-6-15



Fig. 9 Result of pattern matching for bird call recognition in a noisy environment

# 対話行為を用いた制御可能なニューラル対話モデルの検討

An Investigation of Controllable Neural Conversation Model with Dialogue Acts

河野 誠也 \*1 Seiya Kawano 吉野 幸一郎 \*1\*2 中村 哲 \*1 Koichiro Yoshino Satoshi Nakamura

\*1 奈良先端科学技術大学院大学 Nara Institute of Science and Technology \*<sup>2</sup> 科学技術振興機構 Japan Science and Technology Agency

Dialogue act is known as an essential component of the dialogue system, which captures the user's intention and produces the appropriate response. In this paper, we propose a controllable response generation model given dialogue acts. Recent neural conversation models are based on the end-to-end approach that learns a mapping a mapping between dialogue histories and response utterances. However, it was difficult to control the contents of the response generated by the model. Several models tackled the problem of generating responses under the specified dialogue acts as a condition; however, these models still have problems on conditioned generations. In this paper, we introduced an extended framework of the generative adversarial network that optimizes both conditioned generator and discriminator which explicitly classifies dialogue act classes. Experimental results showed that our conditional response generation model improved both the response quality and controllability of neural conversation generation.

# 1. はじめに

対話行為とは、話者が発話において持つ何かしらの「意図」 あるいは発話における「機能」であり、その意図や機能の種類 として対話行為タグが定義される [Boyer 10, 河野 18]. 対話 行為は、対話モデルにおける基本単位の一つとして利用され てきており,特に近年,対話における発話間の相互作用をモデ ル化する上で有用であることが知られている [Yoshino 15]. し かし,近年広く用いられているニューラル対話モデル (Neural Conversation Model; NCM) では、こうした対話行為によっ てシステム発話を明示的に操作することが困難である. そこで 本研究では、システム応答が持つ対話行為の情報を条件として 用いた敵対的生成学習の枠組みを NCM に導入する.具体的に は、与えられた対話行為に基づいて応答を生成する Generator と, Generator が生成した応答が指定した対話行為に基づいた 適切なものであるかを判別する Discriminator を構築し、これ らの2つのモデルを交互に敵対的に訓練する.このような学 習の枠組みの導入により, NCM が任意の対話行為に基づいた 適切な応答を生成することが可能かどうかの評価を行った.

# 2. 関連研究

対話行為の情報を用いて発話生成を行った研究として,Wen や Zhao らの研究がある [Wen 15, Zhao 17].Wen らは, レストラン案内対話のドメインにおいて,任意の対話行為 (e.g. Inform)とそのスロット情報 (e.g. food=Chinese, name=Seven\_Days)を用いて発話生成 (e.g. "Seven Days serves Chinese.")を行うニューラル言語モデル (Semantically Conditioned LSTM; SC-LSTM)を提案している.SC-LSTM では,LSTM 言語モデルに「読み込みゲート」と呼ばれるゲー ティング機構を新たに導入することで,単語の生成時に,指定 した対話行為とスロット情報のうちどの情報を使うかの制御を 行う.しかしながら,SC-LSTM は限られたドメインのタスク 達成を対象としているため,取り扱う発話の範囲が膨大なオー プンドメインの非タスク志向対話システムにおいて適用しよう とした場合,対話行為とそのスロット情報の両方をフレームと して保持することは現実的ではない.

また, Zhao らは NCM が過度に一般化された応答を返すと いう問題 [Li 16a] に対して,対話行為の情報を用いることで より多様かつ高品質な応答生成を行う KgCVAE (Knowledgeguided Conditional Variational Autoencoder)を提案してい る. KgCVAE では, Encoder の出力結果から応答の対話行為 を予測し,これを Decoder への条件として使用している.また, 同様のアプローチとして,NCM における Decoder に感情ラベ ルや話者ラベルを条件として利用し,NCM における応答内容を 制御しようとするモデルも提案されている [Zhou 18, Li 16b]. これらの NCM は,SCE (Softmax Cross Entropy Loss) に 基づいて Decoder の各単語生成ステップにおける単語予測の 最適化を行う.しかしこれらのモデルは必ずしも生成された応 答が指定したラベルに基づいた適切な応答であることを保証し ない.この傾向は特に,低頻度のラベルで顕著である.これは, 訓練データにおけるラベルの分布の偏りに起因する [Zhou 18].

一方で、NCM に敵対的生成ネットワーク (Generative Adversarial Net; GAN)を導入することで、より多様かつ高品質 な応答生成モデルの構築が検討されている [Li 17a].具体的に は、応答発話を生成する Generator と、与えられた応答が学 習データか Generator のどちらに由来するものかを識別する Discriminatorを構築する.これらの2つのモデルを交互に敵 対的に訓練することで、より自然な発話を生成しようとする試 みである.このような、学習の枠組みが従来の NCM と比較 して高品質かつ多様な応答を生成したことが報告されている. 本研究はこうした GAN に基づく学習の枠組みを、指定した対 話行為らしい応答を生成することを目的として導入する.

## 3. 提案手法

本研究では,前節で述べた NCM における GAN に基づく発 話生成の枠組みを拡張し,応答の対話行為を条件として用いる NCM (条件付き NCM) に応用する.具体的には,与えられた 対話行為に基づいて応答を生成する Generator (G) と,G が

連絡先:河野誠也,奈良先端科学技術大学院大学,〒630-0101,奈良 県生駒市高山町 8916 番地の5, kawano.seiya.kjo@is.naist.jp

生成した応答が指定した対話行為に基づいた適切なものである かを識別する Discriminator (D) を構築し,これらの2つの モデルを交互に敵対的に訓練する.本手法は,Gによる応答 生成とDによる応答発話の評価の枠組みに,応答の対話行為 の情報を明示的に導入している点で従来手法 [Li 17a] と異な る.本研究では,このような応答の対話行為の情報を利用した GAN の枠組みの導入により,NCM が任意の対話行為に基づ いた適切な応答を生成することが可能かどうかの評価を行う.

### **3.1** 対話行為による条件付き NCM

対話行為による条件付き応答生成では、対話履歴  $M = \{M_{i-1}, M_{i-2}, \ldots, M_{i-n}\}$ と応答の対話行為  $d_i$ を用いて、応 答発話  $R_i = \{w_1, w_2, \cdots, w_I\}$ を生成する. ここで、n は対話 長、J は発話長である.本研究では、最も素朴な NCM の拡張 として図 1 のように、階層的な Encoder-decoder モデルに基 づく NCM[Tian 17] に対して、発話のデコード時に明示的に 対話行為の情報を与えるモデルを構築した.

通常の Encoder-Decoder モデルでは、Decoder における各 単語出力ステップ t において、直前の隠れ状態  $h_{t-1}$  と現在の 単語  $w_t$  のベクトル表現  $x_t$  が入力として使用される。一方で、 本モデルでは、直前の隠れ状態  $h_{t-1}$  に加えて、対話行為  $d_i$  の ベクトル表現  $e \ge x_t$  の連結ベクトル  $v_t = e \oplus x_t$  を入力とし て使用することで、指定した対話行為に基づいた応答を NCM が生成することを期待する \*1.

RNN には、LSTM や GRU と比較して高速で訓練が可能 であることが知られている SRU (Simple Recurrent Unit) [Lei 17] を用いた.評価実験では、Encoder 及び Decoder で 使用する SRU の層数は 2、中間層の次元は 1024、単語埋め込 みベクトルの次元は 256、対話行為埋め込みベクトルの次元は 100 とした.また、Encoder における最大対話長 n は 5 に設 定した.モデルの訓練は SCE により行い、開発セットにおけ る Perplexity が最も下がったモデルを評価に使用する.



図 1: 対話行為による条件付き NCM の概要

3.2 対話行為による条件付き敵対的生成ネットワーク 本研究では、敵対的生成学習(GAN)の手法として SeqGAN (Sequence Generative Adversarial Net) [Yu 17, Li 17a]の 枠組みを採用し、対話行為による条件付き応答生成へ応用す る.発話のような離散系列データの生成に GAN を適用する 場合, Generator の出力は単語の離散値の系列を前提とするた め、Disciriminator から Generator への勾配の更新を行うこ とが難しい.この問題に対して、SeqGAN では、強化学習に よるアプローチを Generator の更新に用いることで、離散的 な系列データに GAN を適用できることを示している.以下に GAN が持つ Generator, Discriminator の構成を示す.

### 3.2.1 Generator (G)

Generator では、応答生成における単語選択のプロセスをマ ルコフ決定過程とみなし、各ステップにおける単語生成がある 政策に基づいて選択された行動によって決定されると考える. SeqGAN では、Discriminator によって推定された応答文の妥 当性についてのスコア Q(M, R, d) を Generator の報酬として 利用し、この期待報酬を最大化するように Generator を方策 勾配法により更新する [Williams 92]. 本研究における対話行 為による条件付き応答生成においては、その目的関数 J と勾 配を次式で定義する \*<sup>2</sup>. ここで、 $\pi$  は応答 R の生成確率であ る.本研究では、前節で述べた対話行為による条件付き NCM を Generator として用いる.

$$J(\theta) = \mathbb{E}_{R \sim p(R|M,d)}(Q(M,R,d)|\theta)$$
(1)

$$\nabla J(\theta) \approx Q(M, R, d) \nabla \log \pi(R|M, d)$$
 (2)

$$= Q(M, R, d) \nabla \sum_{t} \log \pi(w_t | M, d, w_{1:t-1})$$
 (3)

### 3.2.2 Discriminator

本研究では,以下の2種類の Discriminator について検討 を行う.

- Implicit-Discriminator; 対話履歴 M, 応答発話 R, 対話行為 dを入力として, 与えられた R が本物 (学習データ由来のもの) か偽物 (Generator 由来のもの) であるかの 2 クラス分類を行う. Generator によって生成された R が本物であると推定され る確率を Q(M, R, d) として利用する. これは, 対話行為タグを 素朴に Discriminator の入力として用い, 生成結果が制御され ることを期待するものである.
- Explicit-Discriminator; 対話履歴 M, 対話行為 d に対応する 応答発話 R を入力として, R が Generator 由来のものである とき偽物, 学習データ由来のものであるときその対話行為を分類 するように Discriminator を訓練する. つまり, 対話行為の種 類数を N としたとき, N+1クラスの多クラス分類を行う. こ こで, Q(M, R, d) は, Generator によって生成された R が学 習データ由来の対話行為 d であると推定される確率である. 生 成文が各対話行為の特徴を反映しているかを Discriminator が 明示的に予測することにより, 各対話行為の特徴が生成文に反 映されることを期待する.

Discriminator には、図2に示すような Utterance Encoder と Dialogue Encoder で構成される階層型 RNN を Discriminator として用いる.また,Generator の場合と同様に,RNN には SRU を Discriminator の訓練の高速化のために採用する. 評価実験においては,SRUの層数は1,中間層の次元は1024, 単語埋め込みベクトルの次元は256,対話行為埋め込みベクト ルの次元は100,全結合層における中間層の次元は512 に設定 した.また,Discriminator の更新における損失関数には SCE を用いる.

# 4. 評価実験

## 4.1 データセット

対話行為による条件付き NCM の訓練と評価には DailyDialog Corpus[Li 17b] を用いた.本コーパスには,13,118 対話 における発話に, Inform (4,6532 発話), Questions (29,428 発話), Directives (17,29 発話), Commisive (9,724 発話)の

<sup>\*1</sup> 入力単語 wt 及び対話行為 d は埋め込み層を用いて密ベクトル表 現 xt, e へと変換される.

<sup>\*2</sup> 本研究では簡単化のために文全体で単一の報酬を使用している点 に留意されたい.

| 及1. 月前11為による米什竹されCM の計画         |            |         |        |         |            |            |          |
|---------------------------------|------------|---------|--------|---------|------------|------------|----------|
| モデル                             | Perplexity | Average | Greedy | Extreme | Distinct-1 | Distinct-2 | Accuracy |
| 条件付き NCM (greedy)               | 36.6614    | 0.7912  | 5.5075 | 0.5298  | 0.0336     | 0.0160     | 0.8644   |
| Adversarial-Implicit (greedy)   | 39.2864    | 0.7882  | 5.6239 | 0.5394  | 0.0297     | 0.0069     | 0.8585   |
| Adversarial-Explicit (greedy)   | 39.6993    | 0.7867  | 5.6661 | 0.5395  | 0.0311     | 0.0010     | 0.8843   |
| 条件付き NCM (sampling)             | 36.6614    | 0.7917  | 5.1785 | 0.4905  | 0.0767     | 0.2650     | 0.8176   |
| Adversarial-Implicit (sampling) | 39.2864    | 0.7870  | 5.2566 | 0.5035  | 0.0594     | 0.2093     | 0.8062   |
| Adversarial-Explicit (sampling) | 39.6993    | 0.7865  | 5.2782 | 0.5041  | 0.0583     | 0.1186     | 0.8573   |
| 条件付き NCM (beam)                 | 36.6614    | 0.7847  | 5.5680 | 0.5381  | 0.0325     | 0.0006     | 0.8707   |
| Adversarial-Implicit (beam)     | 39.2864    | 0.7793  | 5.6668 | 0.5411  | 0.0267     | 0.0031     | 0.8615   |
| Adversarial-Explicit (beam)     | 39.6993    | 0.7796  | 5.7167 | 0.5431  | 0.0274     | 0.0017     | 0.8865   |





図 2: Implicit-Discriminator, Explicit-Discriminatorの概要

4 つの対話行為タグがアノテーションされている.本研究で は、このコーパスを訓練(11,118対話),開発(1,000対話), 評価用データ(1,000対話)に分割し,対話行為による条件付 き NCM の訓練と評価に用いた.語彙サイズは2,5000に設定 し、未知語は特殊記号"UNK"に置き換えたうえで訓練を行 う.対話行為による条件付き敵対的生成ネットワークの訓練方 法については、Li らの手法[Li 17a]を参考に以下の手順で行 う.D-step, G-stepにおけるステップ数はそれぞれ、4,20に 設定し、batch size は 32 とした.また、Disciriminatoの更新 には SGD (学習率 1e-3), Generator の更新には Adam (学習 率 1e-5)を用いた\*<sup>3</sup>.

| Algorithm | 1 | 条件付き敵対的生成ネ | ッ | $\mathbb{P}$ | ワー | ク | の訓練 |
|-----------|---|------------|---|--------------|----|---|-----|
|-----------|---|------------|---|--------------|----|---|-----|

| 1:  | for number of iteration do                       |
|-----|--|
| 2:  | for number of D-step do                          |
| 3:  | sample $(M, R, d)$ from training data            |
| 4:  | generate response $\hat{R}$ using G on $(M, d)$  |
| 5:  | update D using $(M, \hat{R}, d)$ and $(M, R, d)$ |
| 6:  | for number of G-step do                          |
| 7:  | sample $(M, R, d)$ from training data            |
| 8:  | generate response $\hat{R}$ using G on $(M, d)$  |
| 9:  | compute reward r for $(M, \hat{R}, d)$ using D   |
| 10: | update $G$ on $(M, \hat{R}, d)$ using $r$        |
|     |  |

# 4.2 対話行為による条件付き応答生成の自動評価

対話行為による条件付き応答生成の評価については,関連性 (Relevance),多様性 (Diversity),制御性 (Contorollability) の3つの観点から多面的に評価を行う.

関連性 (Relevance); 生成された応答発話とレファレンスの応答発話における単語分散表現の類似度により評価を行う. 類似度の算出方法には Embedding Average, Greedy Matching, Vector Extreme の三つの評価指標 [Liu 16] を採用した\*<sup>4</sup>.

- 多様性 (Diversity); 対話システムの分野で広く採用されている Distinct-1 及び Distinct-2 により評価を行う. Distinct-1 (Distinct-2) は、テストデータに対して生成された応答発話集合におけるユニークな unigram (bigram)の数を、生成されたすべての unigram (bigram)の数でスケーリングした指標である [Li 16a].
- 制御性 (Contorollability); 入力として使用した対話行為と,実際に生成された応答文における対話行為の推定結果の一致率 (Accuracy, Precision, Recall, F1)に基づいて評価する.応答文の対話行為については,事前訓練した対話行為分類器\*5による推定結果(評価用データにおける推定精度は,0.8303)を正解として用いる.

## 5. 実験結果

表1に対話行為による条件付き NCM の自動評価結果に ついて示す.ここで,条件付き NCM は SCE により訓練さ れたモデルであり,Adversarial-Implict モデル,Adversarial-Explicit モデルはそれぞれ,Implicit-Discriminator, Explicit-Discriminator を使用した GAN により訓練されたモデルであ る.応答文の生成においては,貧欲的に出力単語を選択する 場合 (greedy) と多項分布に基づいてサンプリングを行う場合 (sampling), beam search (ビーム幅5)を行う場合 (beam)の 3 通りを試した.

### 5.1 応答生成結果の評価

GAN を導入した Adversarial-Implicit モデルでは、いずれ の decoding 手法を用いた場合においても、GAN を用いない 条件付き NCM と比較して、関連性尺度の Vector Extreme が 向上していることが確認できる. 一方で、多様性・制御性につ いては改善が確認できなかった. また、sampling を使用する 場合では、greedy に応答を生成する場合と比較して、多様性 は改善する一方で、制御性は 0.0523 ポイントもの低下が確認 できた. しかしながら、Adversarial-Explicit モデルでは、い ずれの deocding 手法を用いた場合でも、GAN を用いない条 件付き NCM と比較して関連性 (Greedy Matching & Vector Extreme) と制御性が一貫して改善している. 特に、制御性に おいては、greedy に応答を生成する場合は 0.0199 ポイント、 sampling を使用する場合では 0.0396 ポイント、beam search を使用する場合では 0.0157 ポイントもの改善が確認でき、本 モデルの有効性が示唆される結果となった.

Adversarial-Explicit モデルでは、応答文が Generator か学 習データのどちらに由来するものかを判別すると同時に、明示 的に対話行為の推定を行っている.これに対して、Adversarial-Implicit モデルでは、生成された応答の対話行為を明示的に

<sup>\*3 800</sup> iteration 実行した後のモデルを評価に使用した

<sup>\*4</sup> これらの詳細については原論文 [Liu 16] を参照されたい.本研究

では, wikiepedia データで訓練された fastText による単語分散表 現 (300 次元) を用いた.

<sup>\*5</sup> Explicit-Discriminator と同様のアーキテクチャを採用した.

推定しておらず制御性のスコア改善につながらなかったと考 えられる.また,GANを導入した2つのモデルでは,GAN を用いない条件付き NCM と比較して Perplexity の改善が確 認できなかった.GAN によるテキスト生成モデルが必ずしも Peprlexity を改善しないことは先行研究 [Tevet 18] において も指摘されている.これは,敵対的生成学習は単語予測の最適 化を目的としないためである.

### 5.2 各対話行為タグ毎における制御性の評価

表2,表3はそれぞれ Adversarial-Explicit モデルにおいて, beam search と sampling を使用して応答生成を行った場合に おける,各対話行為タグ毎の制御性の評価結果について示し ている.括弧内は,GANを用いない条件付き NCM における スコアとの差分である.ここで,テストセットにおける各対 話行為タグの出現数は,Inform は 2639, Questions は 1679, Directives は 938, Commisive は 484 である.

|--|

| 対話行為タグ       | Precision | Recall | F1               |
|--------------|-----------|--------|------------------|
| Inform       | 0.8855    | 0.9231 | 0.9039 (+0.0125) |
| Questions    | 0.9699    | 0.9976 | 0.9836 (+0.0060) |
| Directives   | 0.9263    | 0.6695 | 0.7772 (+0.0622) |
| Commisive    | 0.5976    | 0.7211 | 0.6536 (+0.0187) |
| Macro Avg    | 0.8448    | 0.8278 | 0.8296 (+0.0249) |
| Weighted Avg | 0.8926    | 0.8864 | 0.8854 (+0.0111) |

表 3: 各対話行為タグ毎における制御性 (sampling)

| 対話行為タグ       | Precision | Recall | F1               |
|--------------|-----------|--------|------------------|
| Inform       | 0.8766    | 0.9075 | 0.8918 (+0.0256) |
| Questions    | 0.9086    | 0.9774 | 0.9418 (+0.0214) |
| Directives   | 0.7963    | 0.6375 | 0.7081 (+0.1126) |
| Commisive    | 0.6364    | 0.5930 | 0.6139 (+0.0587) |
| Macro Avg    | 0.8045    | 0.7789 | 0.7889 (+0.0546) |
| Weighted Avg | 0.8526    | 0.8573 | 0.8530 (+0.0293) |

表 2, 表 3 よ 9, GAN を用いない条件付き NCM と比較し て, Adversarial-Explicit モデルでは、すべての対話行為タグ で F 値が改善していることが確認できた.また,各対話行為タ グにおける F 値のマクロ平均,加重平均も同様に改善してい ることが確認できた.特に, sampling を使用した場合におい ては、各指標のより顕著な改善が確認できる.しかしながら、 Quenstions タグにおいては、各対話行為タグの中で最も小さ な F 値の改善にとどまった. これは、Questions タグが疑問符 や 5W1H のような単語を用いたある程度パターン化された文 構造を持つため、問題が簡単 (既にベースラインが比較的高い 制御性を実現している) であることが原因だと推察される. 一 方で, Directives タグについては, beam search を使用する場 合では 0.0622 ポイント, sampling を使用する場合では 0.1126 ポイントの F 値の顕著な改善が確認できる. Commisive タグ においても同様に, beam search を使用する場合では 0.0187 ポイント, sampling を使用する場合では 0.0587 ポイントの F 値の改善が確認できた.

# 6. おわりに

本研究では、任意の対話行為に基づいて応答発話の生成を行 う条件付き敵対的生成ネットワークを提案し、その評価を行っ た.その結果、提案モデルはベースラインモデルと比較して、 関連性、制御性における客観評価尺度が改善されることを示し た.しかしながら、本研究では客観評価指標による提案手法の 評価のみにとどまり,生成文の品質についてより厳密に評価す るためには人手による評価を行うことが必要であると考えら れる.さらに,Generatorの更新の際に使用する報酬値の計算 に多様性や発話長などの情報を導入することなど,敵対的生成 ネットワークの訓練方法そのものの改善を行うことも重要であ ると考えられる.また,今後は提案手法の他タスク(感情やペ ルソナを考慮した応答生成など)における有効性の検討も進め る予定である.

# 謝辞

本研究は, JST さきがけ (JPMJPR165B) および JST CREST (JPMJCR1513) の支援を受けた.

## 参考文献

- [Boyer 10] Boyer, K. E., Ha, E. Y., Phillips, R., Wallis, M. D., Vouk, M. A., and Lester, J. C.: Dialogue act modeling in a complex task-oriented domain, in *Proc. of SIGDIAL*, pp. 297– 305Association for Computational Linguistics (2010)
- [Lei 17] Lei, T., Zhang, Y., and Artzi, Y.: Training rnns as fast as cnns, arXiv preprint arXiv:1709.02755 (2017)
- [Li 16a] Li, J., Galley, M., Brockett, C., Gao, J., and Dolan, B.: A Diversity-Promoting Objective Function for Neural Conversation Models, in *Proc. of NAACL-HLT*, pp. 110–119 (2016)
- [Li 16b] Li, J., Galley, M., Brockett, C., Spithourakis, G. P., Gao, J., and Dolan, W. B.: A Persona-Based Neural Conversation Model, *CoRR*, Vol. abs/1603.06155, (2016)
- [Li 17a] Li, J., Monroe, W., Shi, T., Jean, S., Ritter, A., and Jurafsky, D.: Adversarial Learning for Neural Dialogue Generation, in *Proc. of EMNLP*, pp. 2157–2169 (2017)
- [Li 17b] Li, Y., Su, H., Shen, X., Li, W., Cao, Z., and Niu, S.: Daily-Dialog: A Manually Labelled Multi-turn Dialogue Dataset, arXiv preprint arXiv:1710.03957 (2017)
- [Liu 16] Liu, C.-W., Lowe, R., Serban, I., Noseworthy, M., Charlin, L., and Pineau, J.: How NOT To Evaluate Your Dialogue System: An Empirical Study of Unsupervised Evaluation Metrics for Dialogue Response Generation, in *Proc. of EMNLP*, pp. 2122–2132 (2016)
- [Tevet 18] Tevet, G., Habib, G., Shwartz, V., and Berant, J.: Evaluating Text GANs as Language Models, arXiv preprint arXiv:1810.12686 (2018)
- [Tian 17] Tian, Z., Yan, R., Mou, L., Song, Y., Feng, Y., and Zhao, D.: How to make context more useful? an empirical study on context-aware neural conversational models, in *Proc. of ACL*, Vol. 2, pp. 231–236 (2017)
- [Wen 15] Wen, T.-H., Gasic, M., Mrksic, N., Su, P.-H., Vandyke, D., and Young, S.: Semantically conditioned lstm-based natural language generation for spoken dialogue systems, arXiv preprint arXiv:1508.01745 (2015)
- [Williams 92] Williams, R. J.: Simple statistical gradient-following algorithms for connectionist reinforcement learning, *Machine learning*, Vol. 8, No. 3-4, pp. 229–256 (1992)
- [Yoshino 15] Yoshino, K. and Kawahara, T.: Conversational system for information navigation based on POMDP with user focus tracking, *Computer Speech & Language*, Vol. 34, No. 1, pp. 275–291 (2015)
- [Yu 17] Yu, L., Zhang, W., Wang, J., and Yu, Y.: SeqGAN: Sequence Generative Adversarial Nets with Policy Gradient., in AAAI, pp. 2852–2858 (2017)
- [Zhao 17] Zhao, T., Zhao, R., and Eskenazi, M.: Learning Discourselevel Diversity for Neural Dialog Models using Conditional Variational Autoencoders, in *Proc. of ACL*, Vol. 1, pp. 654–664 (2017)
- [Zhou 18] Zhou, H., Huang, M., Zhang, T., Zhu, X., and Liu, B.: Emotional chatting machine: Emotional conversation generation with internal and external memory, in *Thirty-Second AAAI Con*ference on Artificial Intelligence (2018)
- [河野 18] 河野誠也,吉野幸一郎,中村哲:条件付き敵対的生成ネットワークを 用いたデータ拡張による対話行為分類法の検討,情報処理学会研究報告音声 言語情報処理 (SLP), No. 9 (2018-SLP-125), pp. 1–6 (2018)

# 対話システムにおける知識獲得質問のための ラベル文字列を用いた知識グラフ補完性能の向上 Improvement of Knowledge Graph Completion Using Label Characters

for Questions to Acquire Knowledge in Dialog Systems

| 藤岡 勇真 *1     | 林 克彦 *1           | 中野 幹生 *2     | 駒谷 和範 *1          |
|--------------|-------------------|--------------|-------------------|
| Yuma Fujioka | Katsuhiko Hayashi | Mikio Nakano | Kazunori Komatani |

\*1大阪大学 產業科学研究所

The Institute of Scientific and Industrial Research, Osaka University

\*<sup>2</sup>(株) ホンダ・リサーチ・インスティチュート・ジャパン Honda Research Institute Japan Co., Ltd.

Dialogue systems cannot respond about information that is not explicitly described in their knowledge bases. Constructing a perfect knowledge base is practically impossible; that is, filling all the values in databases is quite labor-intensive. We are trying to construct a system that can acquire information that is not explicitly described in the knowledge base by inferring latent information from knowledge graphs. In particular, we complement the links in a knowledge graph by using an embedding into latent space. We use partial character sequences of labels (i.e. entity names) to improve of knowledge graph completion. We also show examples of queries generated using the latent information in our target knowledge graph.

# 1. はじめに

データベースを参照して応答を行うタイプの対話システム は、データベースに明示的に記述されていない情報について上 手く応答できない.想定する応答に必要な情報が網羅したデー タベースが構築できれば良いが、人手で構築することは不可能 な場合が多い.

そこで我々は、データベースにない情報を自ら獲得出来る 対話システムを構築することでこの問題の解決を試みている。 そのようなシステムはユーザに質問して情報を聞き出そうとす るが、この時に明らかに間違っている質問をしてしまうとユー ザの対話意欲を削いでしまうという課題がある。

我々は、グラフ構造を持つデータベースである知識グラフ にある潜在的な情報を利用して、できるだけ間違った内容の質 問を避けることができる対話システムの構築を目指している [藤岡 18].知識グラフはデータ間の様々な関係を表現するのに 長けた知識モデルであり [Angles 08]、近年様々なシステムや サービスで用いられている..知識グラフに対する代表的な解 析手法として、潜在空間への埋め込みがある [Kadlec 17]. 埋 め込み表現を用いることで知識グラフのリンクの補完が行える が、この補完されたリンクの確信度に基づきユーザへの質問を 生成する.

本稿では、知識獲得で利用する知識グラフ補完の精度を向上 させるため、ラベルの文字列を用いた知識グラフ埋め込み手法 を提案する.ここでラベルとは、知識グラフ上のエンティティ が持つ、自身を識別する名称である.このラベルの文字列を部 分文字列に分解し利用することで、類似したラベルを持つエン ティティ間に関連性を持たせ、補完精度の改善を図る.この手 法の効果を、実際の対話システムでの利用を目的として作成さ れた知識グラフを用いて検証し、どのような質問が行えるかを 例示する.

連絡先: 藤岡 勇真,大阪大学 産業科学研究所, 大阪府茨木市美穂ヶ丘 8-1,Tel:06-6879-8416, E-mail:fujioka@ei.sanken.osaka-u.ac.jp

# 2. 知識獲得を行う対話システムの枠組み

## 2.1 知識グラフ埋め込みを利用した知識獲得

本研究では、対話システムが知識グラフをバックエンドデー タベースとして持っていることを仮定する.一般に知識グラフ はラベル付き有向グラフとして表される.有向グラフ上のエッ ジにはリレーションを表すラベルが付与されており、ノードは エンティティに相当する.知識グラフ上のエンティティの集合 を  $\mathcal{E}$ 、リレーションの集合を  $\mathcal{R}$ とする. $e_i, e_k \in \mathcal{E}, w_j \in \mathcal{R}$ に対して三つ組 (i, j, k)をトリプルと呼ぶ.この時i, j, kをそ れぞれ主語、述語、目的語と呼ぶ.トリプルは2つのエンティ ティ間の関係を表現する知識グラフの基本的な要素である.知 識グラフ  $\mathcal{G}$  はトリプルを要素とする集合として表せる.

図1にユーザから知識獲得を行う対話システムの枠組みを 示す.知識グラフ上にない知識,すなわちトリプルをユーザか ら獲得するために質問リストを生成する(図1①).知識グラ フ上にないトリプルの存在をユーザに質問することで知識獲 得を試みる.図の例では(もみじ丼,料理種,?)と目的語を穴 埋めするように質問リストを生成している.本稿で生成する質 問リストはこの例のように,目的語を穴埋めするような形式で 生成されるものとする.この時、対話の文脈や話題に関連する 質問リストを生成するようにし、急な話題転換を避けるように する.そして既知の知識グラフから埋め込み表現を学習し(図 1②),埋め込み表現から質問リスト内のトリプルに対し存在 尤度を表すスコアを計算し確信度として付与する(図1③). 付与した確信度に基づき質問リストをソートし,最も高い確信 度かつその確信度がしきい値以上のトリプルの有無をユーザに 質問し知識獲得を試みる(図1④).確信度による順位だけで なく,確信度の絶対値もしきい値によって考慮する.これは, 確信度が低い、すなわち推定結果に自信がない場合にもユーザ に問いかけてしまうことを防ぎ、明らかに間違っているような 質問でユーザの対話意欲を削がないようにするのが狙いであ る.システムの設計指針は、質問する内容をなるべく正しいも のとすることである.知識グラフ埋め込みによる補完精度の向 上は質問内容の正しさに直結するため、ラベル文字列を用いた 知識グラフ埋め込みによる補完精度向上を3章で提案する.



図 1: 知識獲得を行う対話システムの枠組み

# 2.2 知識グラフ埋め込みと ComplEx

2章で述べた枠組みでは、トリプルの存在尤度を計算する必要がある。その計算に知識グラフの埋め込み表現を利用する。 知識グラフ埋め込みは、知識グラフに対する代表的な解析手法として知られている。低次元線形空間に知識グラフを埋め込み 汎化させることで、グラフ上の欠損したリンクの有無を推論し 補完する。知識グラフは、 $|\mathcal{E}| \times |\mathcal{R}| \times |\mathcal{E}|$ の3階テンソル *X* として表現することができ、*X*の(i, j, k)要素  $x_{i, j, k}$ は以下の ように表される。

$$x_{i,j,k} = \begin{cases} 1, & (i,j,k) \in \mathcal{G}; \\ -1, & otherwise. \end{cases}$$

この表現を用いて、知識グラフ埋め込みではトリプル (i, j, k)が知識グラフ上に存在する確率  $P(x_{i,j,k} = 1)$ を、モデルに対応したスコア関数  $\phi$ を用いて以下のように表す.

$$P(x_{i,j,k} = 1) = \sigma(\phi(i, j, k; \Theta))$$

 $\sigma(\cdot)$ はシグモイド関数, $\Theta$ は各モデルにおけるパラメータを 表す.

ComplEx[Trouillon 16] は知識グラフ埋め込みモデルの一種 である. ComplEx は複素数表現とエルミート内積を利用した モデルとして知られる. ComplEx におけるスコア関数  $\phi_{Comp}$ は、 $\mathbb{C}^n$  を複素 *n*-次元空間,  $e_i, e_k \in \mathbb{C}^D$ ,  $w_j \in \mathbb{C}^D$  をそれぞ れエンティティ・リレーションに関する *D* 次元の埋め込みベ クトルとし, Re(x) を *x* の実部とすると,

 $\phi_{Comp}(i, j, k; \Theta) = Re(\langle \boldsymbol{w}_j, \boldsymbol{e}_i, \overline{\boldsymbol{e}}_k \rangle)$ 

と書ける. ここでベクトル v の l 番目の要素を  $v_l$  とした時, < a, b, c >:=  $\sum_k a_k b_k c_k$  と定義する.  $\overline{v}$  は v の複素共役ベ クトルである.

## 3. ラベル文字列を用いた知識グラフ埋め込み

本章では、エンティティの持つラベル文字列を知識グラフの 埋め込み学習に用いる手法を提案する.2.2節で述べたモデル はエンティティ同士がどのようにリンクしているかを元に埋め 込み表現を学習するが、すべてのエンティティが持つラベル文 字列に関する情報は学習に組み込まれていない.そこで、知 識グラフ上のエンティティのラベル文字列を部分文字列に分解 し、先頭もしくは末尾の数文字を擬似エンティティとして作成 することでラベル文字列を組み込む.似た部分文字列を持つエ ンティティ同士は似た性質を持つ可能性が高いという仮定のも



図 2: 「もみじ丼」と「親子丼」に対する N = 2 での展開例

とで、このようなエンティティ同士の関連性が強くなり補完精 度の向上に結びつくことを期待する.

N 文字以下の先頭もしくは末尾の部分文字列で擬似的にエ ンティティを作成し新たにトリプルを構成することを,N文 字で展開すると記述する.図2にN=2,すなわち2文字で 展開を行った例を示す.展開の対象となっている「もみじ丼」 と「親子丼」の先頭・末尾1,2文字が抽出され,部分文字列 であることを示す subs\_を先頭に付けたラベルを持つエンティ ティが作成される.そして展開元のエンティティから作成した 疑似エンティティに向けて prefix\_N もしくは suffix\_N という リレーションでトリプルを構成する.図2の例では,2つの料 理が「subs\_丼」という疑似エンティティを経由して繋がって いることがわかる.

# 4. ラベル文字列を用いた知識グラフ埋め込み による補完精度

ラベル文字列を用いた知識グラフ埋め込みによる補完の精 度を検証し,その効果を調査する.

## 4.1 使用データ

本実験で使用する知識グラフは、対話システムでの運用を 目的として、料理に関する表形式のデータベースを元に作成さ れたものである.詳述すると、料理やその材料、料理種、味、 食べられる場所などが格納されている.このデータベースは人 手で作成されたものであり、部分的にしか情報がないため、現 在も継続して情報が追加され続けている.このデータベースか ら作成される知識グラフに対し、2.1節で述べた知識獲得の枠 組みを適用して情報の拡充を行うという設定の下で議論する.

この知識グラフはエンティティ数  $|\mathcal{E}| = 7289$ , リレーショ ン数  $|\mathcal{R}| = 14$  であり, そのトリプル数は 22321 である.エン ティティに付与されたラベルの長さの平均は 5.88 (文字),標 準偏差は 3.18 (文字) である.

表 1: 各設定における精度指標及び学習データの詳細

|          | Hits@ |       |       |       |       | 学習トリブル数 | エンティティ数 | リレーション数 |
|----------|-------|-------|-------|-------|-------|---------|---------|---------|
| 設定       | 1     | 3     | 5     | 10    | MRR   |         |         |         |
| Baseline | 0.140 | 0.205 | 0.272 | 0.406 | 0.215 | 17857   | 6898    | 14      |
| N = 1    | 0.187 | 0.306 | 0.394 | 0.521 | 0.286 | 31681   | 7865    | 16      |
| N = 2    | 0.237 | 0.384 | 0.473 | 0.580 | 0.345 | 45361   | 12147   | 18      |
| N = 3    | 0.257 | 0.436 | 0.524 | 0.621 | 0.377 | 57893   | 18534   | 20      |
| N = 4    | 0.246 | 0.441 | 0.523 | 0.626 | 0.373 | 68477   | 25035   | 22      |
| N = 5    | 0.241 | 0.448 | 0.532 | 0.627 | 0.373 | 76837   | 30970   | 24      |
| N = 6    | 0.227 | 0.452 | 0.537 | 0.629 | 0.368 | 83271   | 35791   | 26      |
| N = 7    | 0.221 | 0.472 | 0.550 | 0.641 | 0.373 | 87975   | 39381   | 28      |

表 2: リレーション毎の Hits@K. N = 3 とした場合を示している(括弧内の数値は Baseline での結果との差を表す).

|              |       |                        |       | Hits          | 0     |          |       |          |     |
|--------------|-------|------------------------|-------|---------------|-------|----------|-------|----------|-----|
| リレーション名      | 1     |                        | 3     |               | 5     |          | 10    |          | 出現数 |
| is_a         | 0.157 | (+0.140)               | 0.284 | (+0.216)      | 0.331 | (+0.240) | 0.389 | (+0.243) | 795 |
| 材料           | 0.056 | (+0.047)               | 0.108 | (+0.075)      | 0.158 | (+0.107) | 0.238 | (+0.115) | 702 |
| popularity   | 0.119 | (+0.108)               | 0.377 | (+0.238)      | 0.565 | (+0.308) | 0.736 | (+0.169) | 639 |
| 別名           | 0.828 | $(\mathbf{V} - 0.108)$ | 0.980 | (+0.010)      | 0.982 | (+0.008) | 0.986 | (+0.012) | 501 |
| meal_type    | 0.578 | (+0.516)               | 0.878 | (+0.609)      | 0.916 | (+0.477) | 0.950 | (+0.235) | 417 |
| 料理種          | 0.130 | (+0.115)               | 0.367 | (+0.315)      | 0.536 | (+0.382) | 0.682 | (+0.279) | 330 |
| 温度           | 0.297 | (+0.246)               | 0.572 | (+0.381)      | 0.674 | (+0.347) | 0.801 | (+0.220) | 236 |
| restaurant   | 0.385 | (+0.261)               | 0.578 | (+0.280)      | 0.646 | (+0.211) | 0.714 | (+0.180) | 161 |
| 味            | 0.239 | (+0.159)               | 0.487 | (+0.336)      | 0.522 | (+0.301) | 0.611 | (+0.310) | 113 |
| 場所           | 0.000 | $(\pm 0.000)$          | 0.030 | $(\pm 0.000)$ | 0.061 | (+0.030) | 0.091 | (+0.030) | 33  |
| typical_side | 0.056 | (+0.056)               | 0.111 | (+0.111)      | 0.222 | (+0.167) | 0.278 | (+0.222) | 18  |
| 代表料理         | 0.000 | $(\pm 0.000)$          | 0.000 | $(\pm 0.000)$ | 0.063 | (+0.063) | 0.063 | (+0.063) | 16  |
| 機会           | 0.000 | $(\pm 0.000)$          | 0.067 | (+0.067)      | 0.133 | (+0.067) | 0.133 | (+0.067) | 15  |
| 時間           | 0.182 | (+0.091)               | 0.364 | (+0.273)      | 0.455 | (+0.273) | 0.455 | (+0.182) | 11  |

## 4.2 実験方法

精度検証のため 4.1 節で述べた知識グラフを無作為に5分割 し,その内4つをトレーニングデータ*G*',1つをテストデータ *H*'とする5分割交差検証を行った.トレーニングデータを埋め 込み,その埋め込み表現と*H*'から知識グラフ補完で一般に用い られる精度指標である Hits@*K* と MRR を算出した.Hits@*K* は $(i', j', k') \in \mathcal{H}'$ の内k'を全エンティティと入れ替えてスコ アを計算し,得られるランキング中で $\phi_{Comp}(i', j', k'; \Theta)$ が 上位*K*位に入る割合を指す.MRR は平均逆順位とも呼ばれ, 前述のランキングにおける $\phi_{Comp}(i', j', k'; \Theta)$ の順位の逆数 の平均として表される.

ラベル文字列を用いた知識グラフ埋め込みの効果を検証する ため、展開文字数 N = 1, 2,..., 7 としてトレーニングデータ を展開した場合に加え、ベースラインとして展開を行わない場 合の Hits@K, MRR を算出した. 展開時のトレーニングデー タに関する詳細を表 1 の右部に示す. テストデータ数は 4464 個である.全ての場合で共通して ComplEx による埋め込みを 適用し、埋め込み次元は複素 200 次元としてロジスティック 回帰による学習を行った.学習率調整は [Trouillon 16] に倣い Adagrad を利用し、イテレーション数は 1000、負例サンプリ ング数は 5 とした.指標算出時のランキングについて、展開 して得られた部分文字列エンティティを含むトリプルはランキ ングの対象外とした.同様に、既にテストデータに含まれるト リプルに関してもランキングの対象外とした.

## 4.3 知識グラフ埋め込みによる補完精度

表1の左部に5分割交差検証の結果を示す. 展開文字数 Nに関わらず,ベースラインに対して全ての指標が上昇してい ることわかった. Hits@3,5,10については,Nに比例して 上昇していた. 一方で Hits@1 は,N = 3の時に最大値をと り,N = 4,5,... と増加するにつれ減少する傾向が見られた. MRR に関しても同様にN = 3の時が最大であった.

この分割したデータで補完された実例を示す. 例えば (たら こ茶漬け, is\_a, お茶漬け) といった部分文字列がそのまま結 びついた単純な補完例があり, 2987 位から1位に改善されて いた.また (ホットケーキ,味,甘い) といったように,部分 文字列で結びついたエンティティの情報から改善されたと考え られる例もあり,8位から1位に改善されていた.

### 4.4 リレーション毎の補完精度

リレーション毎の精度を調査した.ある分割データに対し, 4.2節で述べた方法に従って算出された Hits@Kをリレーション 毎に分類して算出した結果を表2に示す.表1の結果(Hits@1) を考慮し, N = 3の場合とベースライン設定の2設定の比較 として示す.Hits@3, 5, 10の精度が悪化しているリレーショ ンは無く,全体としてはベースライン以上の精度を保持してい ることがわかった.『is\_a』や『料理種』といったような,階 層構造やタイプ等を表しているリレーションは、ベースライン に対し精度が大きく上昇していた.またそれ以外にも、『味』や 『温度』といったリレーションに関しても同等の精度上昇が確 認できた.

一方で、ベースラインに対して大きな改善がされていない リレーションもあった. 出現数が少ないリレーション(100以 下)では精度が改善されていないものがほとんどである.また 『別名』というリレーションでは、Hits@3, 5, 10 はベースラ インと同程度の精度であるものの,Hits@1の値が大幅に減少 するという結果になった.本質的にラベル文字列を取り扱うリ レーションである『別名』にとって、部分文字列のリンク情報 がノイズとなってしまった可能性が考えられる.しかし精度の 絶対値自体は他のリレーションに比べ比較的良好である.これ はデータの特性に起因したものであり,使用データ上で基本的 に別名というリレーションがエンティティ間に双方向に張られ る様に取り扱っており、補完が容易になっているためと考えて いる. 出現数も多く重要なリレーションである『材料』の精度 も大きな改善はされておらず、精度の絶対値も低いことがわか る. 材料のように1対多の関係を表すリレーションは、1対1 の関係を表すリレーションに比べて、ランキング上位に正しい トリプルが来るよう学習するのが容易ではないためだと考えら れる.


図 3: Baseline 設定でのスコア(確信度)の分布

# 5. 質問の精度と実例

### 5.1 スコア分布としきい値

2.1 節で述べた知識獲得を行う対話システムの枠組みにおけ る, ラベル文字列を用いた知識グラフ埋め込みの効果性を検証 する調査を行った.

推測がうまくいく場合,すなわちランキング上で1位に順 位付けられるトリプルがテストデータ中に存在する場合のスコ ア(信頼度)の分布を調査する.つまり,テストデータ中に存 在するトリプルは正例のみであるため,これが1位に順位付 けられた場合,補完結果は正解であったとみなせる.4.4節と 同様に,知識グラフのある分割データを用いて,H'中のトリ プルに関して順位を算出し,1位のトリプルがテストデータに あるかどうかで分類して各々のスコア分布を確認した.

図 3, 4 に順位が1位だったトリプルのスコアで作成した ヒストグラムを示す.このヒストグラムは,1位と判定された トリプルがテストデータ中に存在するかどうかで振り分けて度 数を計測している.図3はベースライン設定,図4はN=3 で展開した設定での結果である.テストデータに存在したトリ プルが,部分文字列の展開によって増加していることが見てと れる.また,増加したトリプルは-2付近を中心としたスコア を持っていることがわかる.スコアが4~7付近のトリプルは そのほとんどはリレーションが『別名』である.4.4節でも述 べたが,『別名』はエンティティ間に双方向に張られているリ レーションであり,補完が容易なためスコアが比較的高くなっ たと考えられる.

表3に、適合率としきい値の関係を示す.ここでの適合率と は、1位に順位付けられたトリプルの中でテストデータ ℋ中に 存在し、しきい値以上のスコアを付与されたものの割合を表す もので,表の3,4列目には割合ではなくその個数を示している. 全データ数は 4464 個である.この適合率は, $(i', j', k') \in \mathcal{H}'$ に対応する (i', j',?) を質問リストとして知識獲得を試みた時 に、行う質問が正しい割合として捉えることができる. またし きい値以上かつテストデータ中にあるトリプル数は,2.1節で 述べた知識獲得の枠組みを通して獲得できるトリプルの数と 擬似的に捉えられる.適合率が高いほど正確に,表3中のト リプル数が多いほどより多くのトリプル(知識)の獲得が期待 ができる.同じ適合率の下でそのトリプル数を見ると,適合率 が 0.8 の場合は Baseline がやや上回っており,他の適合率設 定では N = 3 が上回っている. 高い適合率の下でこのトリブ ル数を増加させることに対し、ラベル文字列を用いる大きな効 果は見られず、出来るだけ間違った質問をせず多くの知識を獲 得するという目標に対しては課題が残る.

### 5.2 質問例

提案手法で生成できる質問例について述べる. 学習方法は 4.2 節と同様であるが,知識グラフを分割せず,すべてを学習



図 4: N = 3 としたの時のスコア(確信度)の分布

表 3: 適合率としきい値の関係. BL は Baseline を表す.

|           | しきい値   | 以上かつ |         |        |
|-----------|--------|------|---------|--------|
|           | ℋ 中にある |      | 適合率を    |        |
|           | トリプル数  |      | 満たすしきい値 |        |
| 適合率が x 以上 | N=3    | BL   | N=3     | BL     |
| 0.8       | 453    | 468  | 2.034   | 0.210  |
| 0.7       | 472    | 469  | 0.906   | -0.333 |
| 0.6       | 497    | 472  | 0.160   | -0.710 |
| 0.5       | 550    | 477  | -0.592  | -1.066 |
| 0.4       | 619    | 480  | -1.280  | -1.451 |

に用いた. ベースラインと N = 3 で展開した場合の 2 設定を 取り上げる.

例えば(月見団子,味,甘い)という事実について,質問リ ストを(月見団子,味,?)として順位とそのスコアを算出し た結果,ベースライン設定では5位,-4.00で,N = 3とし た場合は1位,-1.68であった.「月見団子」と「甘い」が部 分文字列の展開によって結びついたわけではないが,"団子" を末尾に持つ他のエンティティの味に関する情報を元に順位 とスコアが改善されたものと考えられる.また(五目炊き込み ご飯,温度,あたたかい)という事実に関しても同様に順位と スコアを算出すると,ベースライン設定では7位,-4.13で, N = 3とした場合は1位,-1.66であった.この例も、"ご 飯"を末尾に持つ料理との関連性が上がったことが改善の理由 だと推察出来る.

### 6. まとめ

本稿では、知識グラフの埋め込み表現を用いた対話システム における知識獲得のための質問生成の枠組みについて述べた. またラベル文字列を用いた知識グラフ埋め込みの補完精度の改 善を提案し検証した.リレーション毎の補完精度,しきい値設 定に関しても言及した.

今後の課題は、ランキング評価におけるルールの記述や対 話内容からの質問リスト作成の枠組み設計,能動学習の導入な どが挙げられる.

- [Angles 08] Angles, R. and Gutierrez, C.: Survey of Graph Database Models, ACM Comput. Surv., Vol. 40, No. 1, pp. 1:1–1:39 (2008)
- [Kadlec 17] Kadlec, R., Bajgar, O., and Kleindienst, J.: Knowledge Base Completion: Baselines Strike Back, in *Proceedings of the* 2nd Workshop on Representation Learning for NLP, pp. 69–74 (2017)
- [Trouillon 16] Trouillon, T., Welbl, J., Riedel, S., Gaussier, E., and Bouchard, G.: Complex Embeddings for Simple Link Prediction, in Proceedings of the 33rd International Conference on International Conference on Machine Learning, pp. 2071–2080 (2016)
- [藤岡 18] 藤岡 勇真,林 克彦,中野 幹生,駒谷 和範:対話システムにおける知 識グラフの埋め込み表現を用いた応答生成の試み, SIG-SLUD, Vol. B5, No. 02, pp. 88-89 (2018)

# 会話によるニュース記事伝達のためのトリビアの獲得と活用

Acquisition and Utilization of Trivia for Conversational News Contents Delivery

| 高津 弘明 *1        | 松山 洋一 <sup>*</sup>  | <sup>41</sup> 本田 裕 *2 | 藤江 真也 *1*3          | 小林 哲則 *1            |
|-----------------|---------------------|-----------------------|---------------------|---------------------|
| Hiroaki Takatsu | Yoichi Matsuyam     | a Hiroshi Honda       | Shinya Fujie        | Tetsunori Kobayashi |
| *1早利            | 稻田大学 * <sup>2</sup> | 本田技術研究所               | * <sup>3</sup> 千葉工美 | 業大学                 |
| Wased           | a University        | Honda R&D Co.,Ltd.    | Chiba Institute     | of Technology       |

Trivia has characteristics that draw people's interests and has been used as a strategy for attracting interests in contents in various conversational applications, such as entertainment and educational sites. In this paper, we propose a model that distinguishes trivia based on the surface representation of sentences. We incorporated the trivia presentation function into the spoken dialogue system we are developing and assessed the effect of presenting trivia in the introduction part of the topics in the news transmission task. As a result of the experiment, we confirmed that it is effective for enhancing users' interests in topics and promoting the feeling of rapport with system although we were not able to find significant improvements in the number of users' feedback and the Efficiency of Information Transfer (EoIT).

#### 1. はじめに

文の表層表現に基づいてトリビアを識別するモデルを提案す る. また, ニュースを伝える会話システムにおいて, 話題の導 入部分でトリビアを提示することの効果を検証する.

我々はニュース記事のようなまとまった量の情報を効率的に 伝達する会話システムの開発を行っている [高津 18]. ここで 「効率的」とは、伝達対象となる記事の中から、ユーザにとって 不要な情報を除き,必要な情報だけを伝えることを意味する. 我々のシステムの特徴は、あらかじめ主計画、副計画と呼ぶ複数 のシナリオを用意しておき、このシナリオに沿って会話を進め ることで、リズムの良い会話を実現するうえで必須となる迅速 な応答を可能としたところにある. 主計画に沿って記事の要点 となる情報を提示する傍らで随時ユーザからのフィードバック を理解し,必要に応じて副計画に遷移して補足情報を提示する. このようにユーザの興味や理解状態に応じて提示する情報を柔 軟に切り替えながら会話を進めていく仕組みを持つ.一方で, 高い情報伝達効率 (EoIT; Efficiency of Information Transfer) を実現するにはユーザからのフィードバックが必要不可欠であ る. 本研究ではフィードバックに寄与する要素としてユーザの コンテンツに対する興味とシステムに対する親密感に着目する.

トリビアには人の興味を引く性質があり、従来よりコン テンツに対する興味を誘引する戦略として、会話主体のエ ンターテイメント(ゲーム,クイズショーなど)や教育現場 などでトリビアが利用されてきた [Brown 84, Palincsar 84, ProMarketing Wizard 13, Voices Heard Media 13].

人の興味を引くということに関して、落語の世界では聴衆を 「話を聞かせる」状況に置くために、話の「マクラ」を導入部分 に持ってくることが多い [広瀬 10]. ここでマクラは, 次に来る 話題への説明的な導入の機能を果たし、話し手と聴衆の間の親 密感 (ラポール)の構築に寄与していると考えられる.

本研究では、話題の導入部分でのトリビアの提示がコンテン ツに対する興味の誘引だけでなく、システムに対する親密感(ラ ポール)の増進にも効果があると仮定する.興味や親密感が改 善されることで、ユーザのフィードバックが増加し、情報伝達 効率や継続利用可能性の向上が見込めるか、実験を通して検証 する.

連絡先: 早稲田大学 理工学術院 知覚情報システム研究室 〒162-0042 東京都新宿区早稲田町 27 E-mail: takatsu@pcl.cs.waseda.ac.jp

#### 2. 関連研究

#### トリビアの自動獲得 2.1

トリビアには、人の興味を引く性質があり、ゲームな どのエンターテイメントや教育現場などで利用されて きた [Brown 84, Palincsar 84, ProMarketing Wizard 13, Voices Heard Media 13]. 例えば, Brown と Palincsar らは, 読解力の指導においてトリビアは学生の注意をコンテンツに向 けさせる効果があると指摘している [Brown 84, Palincsar 84].

トリビアを自動で獲得する手法に関する研究やトリビアを対 話システムの発話生成に応用した研究がある.新名らは,ユー ザを対話に引き込む効果を期待し,料理についての雑学を発話 する対話システムを開発した [新名 17]. また,トリビアを含む 文を「ある物事についての瑣末な知識であり、かつ人の興味を 引くような内容を含む文」と定義し、主語の IDF や分散表現、 主語と文中の名詞との類似度などを素性として文のトリビア度 合いを回帰やランキング学習によって推定する手法を提案した [新名 18]. 太田らは、対話を盛り上げるような発話の生成を目 的として、Wikipediaの各文をTF-IDF, 語の共起, 文の長さに よってスコア付けし、意外性のある文の抽出を行った [大田 09]. Prakash らは、固有表現の種類や Superlative Words などを素 性として Rank SVM を学習し、トリビアらしさのランキングを 行った [Prakash 15]. Tsurel らは、トリビア度を人物とカテゴ リの類似度の低さから計算される surprise とカテゴリに含まれ る全ページ間の平均類似度の高さから計算される cohesiveness の積で定義し、人物の Wikipedia ページに付与されたカテゴリ からトリビア度を計算する手法を提案した [Tsurel 17]. Fatma らは, (entity, predicate, object)の三つ組からなるデータを入 カとして, CNN でトリビアかどうかを識別する手法を提案し た [Fatma 17]. また、人手で設計した特徴量と組み合わせるこ とでより高い精度でトリビアを識別できることを示した.

本研究でも、従来トリビアと呼ばれてきたものと同様、トリ ビアを「ある物事についての瑣末な知識であり, 興味をそそるも の」と定義する.また、Fatmaらと同様にトリビアか否かを識 別する2値分類問題として定式化するが、本研究では、文の単 語系列そのものを入力として,双方向 LSTM と self-attention [Lin 17] からなるモデルによって識別を行う. そして, ニュー ス伝達タスクにおいて、トリビアの提示がユーザのコンテンツ に対する興味を誘引する効果があると仮定し検証する.

### 2.2 会話のマクラと話し手一聞き手間のラポール形成

人間同士のインタラクションを円滑にし、協働的なタスクの 達成率を向上させるためには、対話相手同士の繋がりや親密さの 感覚「ラポール(rapport)」が十分に形成されていることが重要 であると、社会心理学や人工知能などの分野で指摘されてきた. Spencer-Oatey はラポールを対話の調和度合いと円滑さである と定義した [Spencer-Oatey 05].特に、交渉 [Zhao 18]、カウン セリング [Kang 12],教育 [Zhao 14] など、相互の親密度が特定 のタスクの達成に貢献するようなドメインでラポールの効果が 報告されている.近年、ラポールの機能を部分的に実装した会 話エージェントが提案されている.Pecune らは、情報推薦型の バーチャルアシスタントにラポール機能を導入し、ラポールの 度合いと情報の受諾率などについて検討している [Pecune 18].

ところで、「聴衆に話を聞かせるメディア」であるところの落 語は、伝統的に「マクラ」、「本題」、「落ち」を基本構造として 持つ.一般的に、落語家はいきなり落語の演目に突入すること はほとんどなく、聴衆に語りかける雰囲気をつくるために、ま ずマクラとして、挨拶をしたり、世間話をしたり、軽い小咄を 披露したりしてから本題に入っていく.マクラは本題への導入 部であり、話し手と聴衆の心理的距離感を縮め、本題に関連す る話題で聴衆の意識を物語の現場に引きつけるような効果があ るとされている[広瀬 10].このように、効果的に「話を聞かせ る」状況をつくるために、マクラは話し手と聴衆の間のラポー ルの構築に寄与していると考えられる.

以上のことから,本研究では冒頭でのトリビアの提示がユー ザのシステムに対する親密感を増進する効果があると仮定し検 証する.

### 3. トリビアの識別

双方向 LSTM と self-attention [Lin 17] からなるモデルに よってトリビアか否かを識別する手法を提案する.モデルの全 体像を図1に示す.

### 3.1 トリビア識別モデル

識別対象の文がn 個の単語系列 ( $x_1, x_2, ..., x_n$ ) から構成され ているとする.  $x_i$  は i 番目の単語の one-hot ベクトルである. まず,各単語を埋め込み層で d 次元に圧縮し,得られた単語の 埋め込み表現を双方向 LSTM に入力する.ここで,LSTM の 隠れ層の次元をuとする.

$$\boldsymbol{e}_i = W_{xe} \cdot \boldsymbol{x}_i \tag{1}$$

$$\overline{\mathbf{h}}_{i} = \operatorname{LSTM}\left(\overline{W}_{eh} \cdot \mathbf{e}_{i} + \overline{W}_{hh} \cdot \overline{\mathbf{h}}_{i-1}\right)$$
(2)

$$\overleftarrow{\boldsymbol{h}}_{i} = \text{LSTM}\left(\overleftarrow{W}_{eh} \cdot \boldsymbol{e}_{i} + \overleftarrow{W}_{hh} \cdot \overleftarrow{\boldsymbol{h}}_{i+1}\right)$$
(3)

順方向 LSTM の出力と逆方向 LSTM の出力を連結し,それら を n 単語分並べて得られる行列を H とする.

$$\boldsymbol{h}_{i} = \left[ \overrightarrow{\boldsymbol{h}}_{i} || \overleftarrow{\boldsymbol{h}}_{i} \right]$$

$$\tag{4}$$

$$H = (\boldsymbol{h}_1, \boldsymbol{h}_2, ..., \boldsymbol{h}_n)$$
 (5)

この行列 *H* に対して attention を計算するが,長い文において 複数箇所 (r箇所) に注目できるように  $r \times d_a$  次元の行列  $W_{s2}$ を掛ける ( $d_a$  はハイパーパラメータ).

$$A = \operatorname{softmax}\left(W_{s2} \operatorname{tanh}\left(W_{s1}H^{\mathrm{T}}\right)\right) \tag{6}$$

得られた attention 行列 A を入力文の隠れ層の行列 H と掛け あわせて文の埋め込み行列 S を得る. この  $r \times 2u$  次元の行列 S を 2ru 次元のベクトル s に変換し,文の埋め込みベクトルを 得る.



図 1: トリビア識別モデル

表 1: トリビアデータセットの統計

|    | 訓練セット | 開発セット | テストセット |
|----|-------|-------|--------|
| 正例 | 2500  | 100   | 126    |
| 負例 | 2500  | 100   | 126    |

表 2: トリビアと非トリビアの例

| トリビア           | 非トリビア          |
|----------------|----------------|
| 1 / 2 /        | 311707         |
| 童話「ウサギとカメ」で2匹が | 最初は馬の姿で現れるが、命じ |
| 競争した距離は280m33c | られれば人間の姿になる    |
| m未満            |                |
| アルゼンチンには、昔の丸の内 | また、自動車関連メーカーには |
| 線が走っている        | より安全な自動車の開発を促す |
| ミツユビナマケモノは首を最大 | ネオジム塩を成分とする鉱物の |
| 270度回転させられる    | 記事も含みます        |

$$S = AH \tag{7}$$

$$s = [S[1]||S[2]||\cdots||S[r]]$$
 (8)

最後にこのベクトルをシグモイド関数を活性化関数とする出力 層に与え、トリビアである確率を計算する.

$$y = \sigma \left( W_{sy} \boldsymbol{s} + b \right) \tag{9}$$

### 3.2 評価実験

Webから収集したトリビアを正例,Wikipediaからランダムに抽出してきた文を負例としてデータセットを作成し、トリビア識別モデルの性能を評価する.

### 3.2.1 実験設定

Webから収集したトリビアを正例,Wikipediaからランダム に抽出してきた文を負例(非トリビア)とする.負例を抽出す るにあたり,トリビアらしい文が含まれないように負例は次の 3つの条件を満たす文の中からランダムに抽出した.(1)最初の 段落でない,(2)段落の先頭の文でない,(3)記事タイトルを含 まない.作成したトリビアデータセットの統計を表1に示す. また,トリビアおよび非トリビアの例を表2に示す.

モデルのネットワーク構造として、埋め込み層の次元  $d \in 100$ , LSTM の隠れ層の次元  $u \in 100$ , attention の次元  $d_a \in 100$ , attention の数  $r \in 5$  に設定した. 訓練セットにおいて頻度が 2 以下の単語は特殊記号 (unk) に置き換え、入力の語彙サイズを 4790 に制限した.

表 3: トリビアと非トリビアの識別精度(%)

| A        | 「トリビア」 | 「非トリビア」 |  |
|----------|--------|---------|--|
| Accuracy | 識別精度   | 識別精度    |  |
| 97.2     | 97.6   | 96.8    |  |



図 2: テストセットにおけるトリビアと非トリビアの埋め込み 表現 *s*の分布を多次元尺度構成法で次元圧縮し可視化した結果

### 3.2.2 実験結果

テストセットにおけるトリビアと非トリビアの識別精度を3 に示す.この結果から,提案モデルによって97%と高い精度で トリビアか否かを識別できることがわかった.

テストセットにおけるトリビアと非トリビアの埋め込み表現 *s*の分布を多次元尺度構成法で次元圧縮し可視化した結果を図 2に示す.この結果から、トリビアと非トリビアの境界がある 程度明確に分かれるように学習できていることがわかった.

### **3.3** Wikipedia からのトリビアの獲得

学習した識別モデルを Wikipedia の記事に適用しトリビアを 獲得する.ここでは、文脈依存性の高い文を回避するために以 下の条件を満たす文に対して識別を行った.(1)最初の段落で ある、(2)段落の先頭の文である、(3)記事タイトル+「は」を 含む文である.Wikipedia の約 100万記事に適用し、約 10万 文のトリビアを獲得した.

### 4. トリビアの会話システムへの導入効果の検証

ニュースを伝える会話システム [高津 18] においてトリビア を提示する効果を検証する.話題の導入部分でその話題に関連 したトリビアを提示することで、ユーザのコンテンツに対する 興味やシステムに対する親密感が向上すると仮定する.さらに、 それによって、ユーザのフィードバックが増加し、情報伝達効 率や継続利用可能性が向上するか、実験を通して検証する.

### 4.1 仮説

- 以下の仮説について検証を行う.
- 仮説 1: トリビアがトピックへの興味の増進に寄与する
- 仮説 2: トリビアがラポール形成に寄与する
- 仮説 3: トリビアがフィードバック数の増加に寄与する
- 仮説 4: トリビアが情報伝達効率の向上に寄与する
- 仮説 5: トリビアが継続利用可能性の向上に寄与する

表 4: 冒頭でのトリビア提示の例

| 発話タイプ | 発話内容   |
|-------|--|
| トリビア  | そういえば、天気予報の177って、昔は大隈重信<br>の自宅の電話番号だったらしいよ   |
| 話題遷移  | それで、その天気予報に関するニュースなんだけど                      |
|       | 6月から天気予報が大きく変わるみたいだよ                         |
| 主計画   | 気象庁が計算能力を約10倍に高めたスーパーコン<br>ピューターを新たに導入するんだって |
|       |  |

表 5: アンケート項目

| ID | 質問内容                                     |
|----|--|
| I1 | ~の話について、対話しているうちに興味が強まった                 |
| C1 | 自分とシステムが同調していたと感じた                       |
| C2 | システムと対話しているとき,あまり心地よくなく言いた<br>いことが言えなかった |
| C3 | 対話の間,フラストレーションがたまった                      |
| M1 | 対話システムが自分の言っていることに注意を向けてると<br>感じた        |
| M2 | 対話システムがユーザに対して敬意を払っていると感じた               |
| Ρ1 | 対話システムがフレンドリーと感じた                        |
| P2 | 対話システムに温かみを感じた                           |
| P3 | 対話システムは自分を気遣ってくれていると感じた                  |
| R1 | このシステムをまた使用したい                           |
|    |  |

### 4.2 比較条件

以下の2つの条件を比較する.

- 条件 1: ベースライン(主計画+副計画)
- 条件 2: 条件 1 + トリビア提示機能

条件2における会話冒頭のトリビア提示の例を表4に示す. なお,条件1では冒頭の2行がなく主計画から会話が始まる.

### 4.3 実験設定

各条件ごとに、本システムを始めて利用する大学生8人ずつ、 3つのニューストピック(平均33.7文,主計画サイズ9文)に ついて本システムと会話させ、会話終了後にアンケート調査を 行った.

アンケート項目を表5に示す. I1 は各トピックについての興味に関する評価項目である. R1 は継続利用可能性に関する評価項目である. 残りがラポールに関する評価項目である.

ラポールに関しては、Tickle-Degnen らが分類した同調性(Coordination),相互注意(Mutual Attentiveness),ポジティブ性(Positivity)という3つの要素に従いアンケート項目を作成した [Tickle-Degnen 90]. ここで,C1,C2,C3が同調性,M1,M2が 相互注意,P1,P2,P3がポジティブ性に関する評価項目である.

各評価項目について5段階で評価させた(5点:そう思う,4 点:どちらかと言えばそう思う,3点:どちらでもない,2点: どちらかと言えばそう思わない,1点:そう思わない).

また,被験者には,会話終了後にニュース記事を読ませ,各 文について会話で伝えて欲しかったかどうかを5段階で評価さ せた(5点:伝えてほしい,4点:どちらかと言えば伝えてほし い,3点:どちらでもよい,2点:どちらかと言えばいらない, 1点:いらない).会話で提示できた4点以上の文の被覆率と会 話で提示しなかった2点以下の文の除外率の調和平均から情報 伝達効率を被験者ごとに計算した.



### 4.4 実験結果

各条件について平均値を計算し, t 検定による仮説検定を行っ た. 被験者一人あたりの平均フィードバック数を図3に示す. 被験者一人あたりの平均情報伝達効率を図4に示す.興味増進 効果(I1)と継続利用可能性(R1)に関するアンケートの平均 点を図5,図6に示す.ラポールに関する各評価項目の平均点 を図7に示す.なお,C2とC3は同調的でないことを質問して いるため,図は同調的であるほど値が高くなるように6から引 いた値を示している.

フィードバック数と情報伝達効率,継続利用可能性について は有意な差が得られず,仮説3と仮説4,仮説5の正しさは示 されなかった.一方,興味増進効果とラポール形成効果(特に, 同調性)については有意な差が得られ,仮説1と仮説2の正し さが示された.

### 5. おわりに

トリビアか否かを識別するモデルを提案し,97%と高い精度 で識別できることを確認した.本研究では,文の表層表現のみ を入力としてトリビアの識別を行ったが,先行研究で検討され ているようなトリビアらしさを表現する特徴量も加えることで さらなる性能向上が見込めると考えられる.

検証実験の結果,情報伝達を目的とした会話システムにおい て,トリビアを話のマクラとして冒頭で伝えることにより,ユー ザのトピックに対する興味とシステムに対する同調感が増進さ れうることがわかった.すなわち「話を聞かせる会話メディア」 という新しいジャンルにおいて、トリビアの戦略的な使用が聞 き手を効果的に「聞くモード」に置かせる方法として有効であ ることが示唆された.

しかしながら、本来の目的であった、高い情報伝達効率(EoIT; Efficiency of Information Transfer)を実現するためのフィー ドバックの促進効果については確認されなかった.

ユーザを「聞くモード」にしたうえで,他にどのような因子 が直接的にフィードバックの促進に寄与するのかは,未だ解っ ていない.今回の検証実験の自由記述アンケートでは,そもそ も期待した質問応答が得られなかった,音声合成の質が良くな いと感じられる,間(ま)が悪いなどの,システム性能に対す る信頼を疑う意見も散見された.今後の研究では、システム性 能やラポール現象の網羅的な測定と分析を通してフィードバッ クを促進させるメカニズムをより系統的に明らかにしていく.

- [Brown 84] Brown, A.L., Palincsar, A.S., and Armbruster, B.B.: Instructing comprehension-fostering activities in interactive learning situations, *Learning and Comprehension of Text*, pp. 255-286 (1984)
- [Fatma 17] Fatma, N., Chinnakotla, M.K., and Shrivastava, M.: The unusual suspects: Deep learning based mining of interesting entity trivia from knowledge graphs, in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, pp. 1107-1113 (2017)
- [広瀬 10] 広瀬和生:現代落語の基礎知識,集英社, ISBN 978-4-08-771365-7 (2010)
- [Kang 12] Kang, S.-H., Gratch, J., Sidner, C., Artstein, R., Huang, L., and Morency, L.-P.: Towards building a virtual counselor: Modeling nonverbal behavior during intimate self-disclosure, in *Proceedings of the* 11th International Conference on Autonomous Agents and Multiagent Systems, pp. 63-70 (2012)
- [Lin 17] Lin, Z., Feng, M., Santos, C.N., Yu, M., Xiang, B., Zhou, B., and Bengio, Y.: A structured self-attentive sentence embedding, in Proceedings of the 5th International Conference on Learning Representations, pp. 1-15 (2017)
- [新名 17] 新名和也,嶋田和孝: シズルワードから想起される料理の雑学を話す対話シ ステム,電子情報通信学会信学技報, Vol. 117, No. 367, NLC2017-42, pp. 77-82 (2017)
- [新名 18] 新名和也,嶋田和孝:トリビア文抽出のためのトリビア度合いの推定,電子 情報通信学会信学技報, Vol. 118, No. 122, NLC2018-7, pp. 69-74 (2018)
- [大田 09] 太田知宏,鳥海不二夫,石井健一郎:発話生成を目的とした Wikipedia からの文抽出,第 23 回人工知能学会全国大会論文集,2G1-NFC5-11, pp. 1-4 (2009)
- [Palincsar 84] Palincsar, A.S. and Brown, A.L.: Reciprocal teaching of comprehension-fostering and comprehension-monitoring activities, *Cognition and Instruction 1*, No. 2, pp. 117-175 (1984)
- [Pecune 18] Pecune, F., Chen, J., Matsuyama, Y., and Cassell, J.: Field trial analysis of socially aware robot assistant, in *Proceedings of the* 17th International Conference on Autonomous Agents and MultiAgent Systems, pp. 1241-1249 (2018)
- [Prakash 15] Prakash, A., Chinnakotla, M.K., Patel, D., and Garg, P.: Did you know? - Mining interesting trivia for entities from wikipedia, in Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence, pp. 3164-3170 (2015)
- [ProMarketing Wizard 13] ProMarketing Wizard: Trivia game on facebook, http://bit.ly/1HUhlRx (2013)
- [Spencer-Oatey 05] Spencer-Oatey, H.: (Im)politeness, face and perceptions of rapport : Unpackaging their bases and interrelationships, *Journal of Politeness Research. Language, Behaviour, Culture*, Vol. 1, No. 1, pp. 95-119 (2005)
- [高津 18] 高津弘明,福岡維新,藤江真也,林良彦,小林哲則: 意図性の異なる多様な 情報行動を可能とする音声対話システム,人工知能学会論文誌, Vol. 33, No. 1 (2018)
- [Tickle-Degnen 90] Tickle-Degnen, L. and Rosenthal, R.: The nature of rapport and its nonverbal correlates, *Psychological Inquiry*, Vol. 1, No. 4, pp. 285-293 (1990)
- [Tsurel 17] Tsurel, D., Pelleg, D., Guy, I., and Shahaf, D.: Fun facts: Automatic trivia fact extraction from wikipedia, in *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, pp. 345-354 (2017)
- [Voices Heard Media 13] Voices Heard Media: Using trivia and quiz products to engage your customer, http://bit.ly/1Htiv5V (2013)
- [Zhao 14] Zhao, R., Papangelis, A., and Cassell, J.: Towards a dyadic computational model of rapport management for human-virtual agent interaction, in *Proceedings of the International Conference on Intelligent* Virtual Agents, pp. 514-527 (2014)
- [Zhao 18] Zhao, R., Romero, O.J., and Rudnicky, A.: SOGO: A social intelligent negotiation dialogue system, in *Proceedings of the 18th International Conference on Intelligent Virtual Agents*, pp. 239-246 (2018)

# 画像キャプションに対する表現学習に向けた 敵対的生成ネットワーク

Generative Adversarial Networks toward Representation Learning for Image Captions

| 阿部 佑樹    | 妹尾 卓磨       | 松森 匠哉           | 今井 倫太        |
|----------|-------------|-----------------|--------------|
| Yuki Abe | Takuma Seno | Shoya Matsumori | Michita Imai |

慶應義塾大学 理工学部

Department of Science and Engineering, Keio University

Captions generated from a single image are possibly different from each others as for representations (e.g. attention points or sentence expressions). However, a vast amount of image captioning datasets in the world have few or no annotations of latent variables. Learning latent variables of captions with no supervision is an important from perspectives of scalability and interpretability of conditional image captioning models. In this research, we propose a deep generative model to learn and leverage latent variables of image captions. In experiments, we used the task of image classification with several MNIST images and ground truth labels as down-scaled setting of image captioning, and we show that our proposed model acquired latent variables which represent sub-groups of labels.

# 1. はじめに

画像に対する適切な説明文(キャプション)を自動で生成す ることは画像キャプショニングと呼ばれる.ひとつの画像に対 するキャプションは,注目箇所の偏りや文章表現の違いによ り複数通り存在することが考えられる.別の言い方をすると, キャプションは,画像および画像と独立したキャプションを特 徴付ける要素(潜在変数)によって生成されると考えることが できる.潜在変数の利用や獲得は,コンテキストの考慮や分析 といった実用上の有用性から,画像キャプショニングにおける 重要な課題のひとつとして位置付けられる.

これまでに、画像、キャプション、および潜在変数を用いた 教師あり学習により、潜在変数の値に応じて生成するキャプ ションの特徴を変化させる手法が提案されてきている [1]. し かしながら、世の中に存在する画像キャプションのデータセッ トは、潜在変数がアノテーションされておらず未知であること が多い.

アノテーションのない訓練データから潜在変数を学習によ り獲得することは一般的に表現学習と呼ばれ,深層生成モデル を用いた手法が提案されてきている [2].深層生成モデルを用 いた画像キャプションに対する表現学習は,潜在変数による選 択的な画像キャプショニングの拡張性の向上に繋がる.また, 画像のみからキャプションを生成する方法 [3] と比較して,意 味的な潜在変数を用いて生成するキャプションを制御できるこ とは,モデルの解釈性の観点から重要である.

本研究は、画像キャプションに対する表現学習に向けた、深 層生成モデルのアーキテクチャの検討を行う.本提案モデルは テキスト生成モデル LaTextGAN[4]の拡張として表現される. 画像キャプショニングを画像で条件づけたテキスト生成として 捉えることにより、conditional GAN[5]を参考にLaTextGAN を画像で条件付けする.また、InfoGAN[2]を参考に相互情報 量に関する制約項を目的関数に加えることで、キャプションに 対する潜在変数をアノテーションのない訓練データから獲得 する.

キャプションの潜在変数の種類や区分は曖昧であるため、キャ

プションの特徴を捉えた潜在変数の定量的評価や定性的評価は 困難である.本提案モデルの評価には画像キャプショニングを 直接扱わず,ある画像に対して複数の正解ラベルが存在する画 像分類問題を,本提案モデルの有用性を示す検証課題として 扱う.

# 2. 関連研究

### 2.1 Generative Adversarial Networks

Generative Adversarial Networks (GAN) は Goodfellow et al. [6] によって提案された深層生成モデルの学習フレーム ワークである. GAN は対立する 2 つのネットワークを利用す る. 生成ネットワーク G はノイズ変数  $z \sim p_z(z)$  をデータ G(z) に変換する. 識別ネットワーク D はデータが訓練データ  $x \sim p_{data}(x)$  か G によって生成されたデータ G(z) かを識別 する. G と D の学習は次式に示すミニマックスゲームによっ て行う.

$$\min_{G} \max_{D} \mathcal{L}_{adv}(G, D) = \mathbb{E}_{\boldsymbol{x} \sim p_{data}(\boldsymbol{x})}[\log D(\boldsymbol{x})] \\ + \mathbb{E}_{\boldsymbol{z} \sim p_{\boldsymbol{z}}(\boldsymbol{z})}[\log (1 - D(G(\boldsymbol{z})))] \quad (1)$$

### 2.2 LaTextGAN

LaTextGAN[4]はGANをテキスト生成に応用した深層生成 モデルである.LaTextGANはEncoder-Decoderモジュール とGANモジュールの2つのモジュールを利用する.Encoder-Decoderモジュールはテキストとテキストを表現する文章ベク トルの相互変換に利用される.Encoder-Decoderモジュールは オートエンコーダ[7]で構成され、学習はテキストの再構成誤差 の最小化により行われる.GANモジュールは文章ベクトルの生 成に利用される.GANモジュールは通常のGANの枠組みで学 習が行われる.訓練データにはテキストを直接用いるのではな く、事前学習済みのEncoder-Decoderモジュールから得られる 文章ベクトルが用いられる.最終的なLaTextGANの出力は、 GANモジュールの出力する文章ベクトルをEncoder-Decoder モジュールによりテキストに復号することにより得る.

### 2.3 conditional GAN

conditional GAN[5] は GAN を条件付き生成モデルに拡張 したモデルである.ここで X を任意の種類の補足情報とする.

連絡先: 阿部佑樹,慶應義塾大学理工学部,〒 223-8522 神奈川県横浜市港北区日吉 3-14-1, E-mail: abe@ailab.ics.keio.ac.jp



図 1: 本提案モデルの GAN モジュールの概要図.

補足情報には例えばクラスラベルやモダリティの異なる他の データなどが挙げられる.条件付けは*G*および*D*の両方に追 加の入力として *X*を与えることで行われる.

### 2.4 InfoGAN

InfoGAN[2] は GAN を表現学習に応用した深層生成モデル である。潜在変数を $c \sim p_c(c)$ とする。 $p_c(c)$ は任意の分布を 用いる。Gはノイズ変数 zと潜在変数 cをデータG(z,c)に変 換する。InfoGAN の目的関数は、式1で示される通常の GAN の目的関数に、潜在変数を再構成するネットワーク Q(G(z,c))を用いた相互情報量制約項 $\mathcal{L}_I$ を加えた形で表現される。

$$\min_{G,Q} \max_{D} \mathcal{L}(G, D, Q) = \mathcal{L}_{adv}(G, D) + \lambda_I \mathcal{L}_I(G, Q)$$
(2)

$$\mathcal{L}_{I} = -\mathbb{E}_{\boldsymbol{z} \sim p_{\boldsymbol{z}}(\boldsymbol{z}), \boldsymbol{c} \sim p_{\boldsymbol{c}}(\boldsymbol{c})}[\log Q(G(\boldsymbol{z}, \boldsymbol{c}))] \qquad (3)$$

ここで  $\lambda_I$  はハイパーパラメータである。制約項  $\mathcal{L}_I$  の最小 化は潜在変数 c とデータ G(z, c) の間の相互情報量の変分下界 の最大化に等しいため、訓練データを特徴付ける表現を潜在変 数 c として獲得することが促される。

### 2.5 Variational AutoEncoder

Variational AutoEncoder (VAE)[8] はオートエンコーダの 拡張モデルである. VAE のエンコーダは入力 x で条件づけら れた事後分布 q(z|x) で表される. すなわち VAE は入力 x の 表現 z を分布で表現するモデルである. VAE では q(z|x) が 事前分布 p(z) に近づくような制約が加えられる. VAE の目 的関数は次式で表される.

$$\mathcal{L}_{VAE} = -\mathbb{E}_{q_{\theta}(\boldsymbol{z}|\boldsymbol{x})}[\log p_{\theta}(\boldsymbol{x}|\boldsymbol{z})] + D_{KL}(q_{\theta}(\boldsymbol{z}|\boldsymbol{x})||p(\boldsymbol{z})) \quad (4)$$

ここで $\theta$ は VAE のパラメータ,  $D_{KL}$ はカルバックライブ ラー情報量である.第1項が再構成誤差に対応し,第2項が 事後分布に対する制約に対応する.

### 3. 提案

本提案モデルは La TextGAN を元に, Encoder-Decoder モ ジュールでの VAE の利用,および GAN モジュールの画像キャ プショニング及び表現学習への拡張で表現される.

### 3.1 Encoder-Decoder $\forall \exists -h$

本提案モデルはテキストと文章ベクトルの相互変換に VAE を用いる.しかしながら、式4で表させる通常の VAE の目的 関数は事後分布に対する制約が強すぎるため、テキストの再 構成誤差が大きくなり相互変換に適さない.そこで制約係数  $0 < \lambda_{KL} < 1$ を用いて VAE の学習を行う.目的関数を次に 示す.

$$\mathcal{L}_{VAE} = -\mathbb{E}_{q_{\theta}(\boldsymbol{s}|\boldsymbol{S})}[\log p_{\theta}(\boldsymbol{S}|\boldsymbol{s})] + \lambda_{KL}D_{KL}(q_{\theta}(\boldsymbol{s}|\boldsymbol{S})||p(\boldsymbol{s}))$$
(5)



図 2: GridMNIST のサンプルの一例.



図 3: ネットワーク構成の概要図. BN はバッチ正規化, LReLU は LeakyReLU を示す.

ここで S はテキスト, s は文章ベクトルである.事後分布  $q_{\theta}(s|S)$  には対角ガウス分布を用い,事前分布 p(s) には標準 正規分布を用いる. $\lambda_{KL} = 0$  のときオートエンコーダの目的 関数と一致し, $\lambda_{KL} = 1$  のとき式 4 で示す VAE の目的関数 と一致する.小さい $\lambda_{KL}$ では再構成誤差の最小化が重要視さ れる.

VAE の学習した文章ベクトル *s* を利用すると GAN モジュー ルの学習が安定する.文章ベクトル *s* は対角ガウス分布に従う ノイズを含む.識別ネットワーク Dの入力にノイズを加えるこ とで GAN の学習を安定化する手法 [9] と同様に,訓練データ の分布とモデル分布のサポートの重なりが増加する.また,生 成ネットワーク *G* に対する近似誤差の緩和の効果が得られる.

### 3.2 GAN モジュール

図1 に本提案モデルの GAN モジュールの概要図を示す. GAN モジュールは生成ネットワークG, 識別ネットワークD, 及び復号ネットワークQから構成される.全てのネットワー クは画像 X を入力に受ける.G は画像 X と潜在変数 c から 文章ベクトル ŝを生成する.D は画像 X に対する文章ベクト ルが訓練データ s か生成データ ŝ かを識別する.Q は画像 X と文章ベクトル ŝ を入力に受けG に入力された潜在変数 c を 予測する.目的関数を次に示す.

 $\min_{G, Q, D} \mathcal{L}(G, D, Q) = \mathcal{L}_{adv}(G, D) + \lambda_I \mathcal{L}_I(G, Q)$ (6)

 $\mathcal{L}_{adv} = \mathbb{E}_{\boldsymbol{s} \sim q_{\theta}(\boldsymbol{s})}[\log D(\boldsymbol{s}, X)]$ 

$$+ \mathbb{E}_{\boldsymbol{c} \sim p_{\boldsymbol{c}}(\boldsymbol{c})}[\log\left(1 - D(G(\boldsymbol{c}, X), X)\right)]$$
(7)

$$\mathcal{L}_{I} = \mathbb{E}_{\boldsymbol{c} \sim p_{\boldsymbol{c}}(\boldsymbol{c})}[\|\boldsymbol{c} - Q(G(\boldsymbol{c}, X), X)\|^{2}]$$
(8)

ここで、式8の最小化は、Qの出力がガウス分布に従うと 仮定した場合の式3の最小化と同一である.画像キャプショニ ングを画像で条件づけられたテキスト生成として扱うことによ り、Gは画像に対する適切な文章を生成するモデル、すなわ ち画像キャプションを生成するモデルとして学習が行われる. また、相互情報量制約  $\mathcal{L}_I$ により文章ベクトルに対する潜在変 数 cの獲得が促される.



図 4: ResBlock の概要図. BN はバッチ正規化, LReLU は LeakyReLU を示す. ResBlock を用いてサイズを半分にする 場合 (ResBlock down) は, bypass および residual pass の最 後に平均プーリング層を挿入する. ResBlock を用いてチャネ ル数を変化させる場合は, bypass の最初に  $1 \times 1$  の畳み込み層 を追加し, この畳み込み層と residual pass の最初の畳み込み 層でチャネル数を変化させる. 画像に対して直接 ResBlock を 適用する場合は, residual pass の最初の BN と (L)ReLU を 取り除く.

# 4. 実験

潜在変数の評価の明確化と簡単化のため、検証課題として 複数の正解ラベルが存在する画像分類問題を用いる.画像キャ プショニングにおいて、潜在変数の値に応じて生成するキャプ ションの特徴を変化させることは、画像分類問題において、潜 在変数の値に応じた特定のラベルを出力することと対応する. ひとつの潜在変数の値に対して複数の画像を用いたときの出力 を評価することで、潜在変数として獲得された表現を明らかに する.

## 4.1 データセット

複数の正解ラベルが存在する画像分類問題として,MNIST を元に GridMNIST を作成した.GridMNIST のサンプルの一 例を図 2 に示す.GridMNIST は 64×64 の白黒画像と 4 つの 正解ラベルを持った正解ラベル集合のペアから構成される.画 像は 2×2 の格子状に配置された MNIST 画像であり,正解ラ ベル集合の要素は画像中に存在する MNIST の正解ラベルであ る.MNIST の学習データとテストデータを元に,GridMNIST の学習データを 10000 件,テストデータを 1000 件作成した.

### 4.2 実装

Encoder-Decoder モジュールはクラスラベル *L* とクラスラ ベルを表現する潜在表現 *l* の相互変換に利用され, VAE を用 いて構成される. クラスラベル *L* は 10 次元の Onehot ベクト ルで表現し, 潜在表現 *l* の次元数は 2 次元とした. VAE のエ ンコーダおよびデコーダは 1 層の全結合層を用いた. 制約係 数  $\lambda_{KL} = 0.2$ , バッチサイズ 64, エポック数 100 とし, 最適 化手法に Adam[10] を用いた.

GAN モジュールの *G*, *D*, および *Q* のネットワーク構成 を図 3 に示す.各ネットワークの計算処理は画像 *X* と追加の 入力からある値を出力するという点で同一であり,Kazemi *et al.* [11] の提案するモデルを参考にした.学習の安定化のた め,ネットワークの構成要素には、図 4 に示す ResBlock[12], バッチ正則化 [13],*G* の活性化関数は ReLU[14],*D* および *Q* の活性化関数は負側の傾きが 0.2 の LeakyReLU[15] を用い た.また式 7 を負の対数尤度から最小二乗誤差に置き換えた [16].すなわち *G* は  $\mathbb{E}_{c\sim p_e(c)}[(D(G(c,X),X)-1)^2]$  を,*D* は  $\mathbb{E}_{s\sim q_\theta(s)}[(D(s,X)-1)^2] + \mathbb{E}_{c\sim p_e(c)}[D(G(c,X),X)^2]$  を 最小化するように学習する.潜在変数 *c* の分布  $p_c(c)$  は 3 次 元の標準正規分布  $\mathcal{N}(0,I)$  とした.相互情報量制約の係数は  $\lambda_I = 1.0$  とした.バッチサイズ 64, イテレーション数 400000 とし,最適化手法に Adam を用いた. Adam のパラメータは, lr = 0.0002,  $\beta_1 = 0.5$ ,  $\beta_2 = 0.999$  とした. パラメータの更 新は式 6 に示す最適化を 1 イテレーションごとに行った.

### 4.3 実験方法

ひとつの潜在変数の値に対して複数の画像を用いたときの 出力を評価することで,潜在変数として獲得された表現を明ら かにする.ランダムに決定されたひとつの潜在変数の値に対し て,入力画像として GridMNIST のテストデータ 1000 件全て を用い,本提案モデルの分類精度および出力ラベルの出現頻 度比を評価する.ここで分類精度は、ある画像に対して出力し たラベルが正解ラベル集合に含まれる場合を正解として計算 される.分類精度は、いかなる潜在変数の値に対しても適切な 出力を得ることができるかを評価する指標であり、潜在変数と ラベルが直接対応していないことを調べるために有用である. 出力ラベルの出現頻度比は、ひとつの潜在変数の値に対する出 力ラベルの傾向を調べるために有用である.出力ラベルの出現 頻度比の比較手法には、潜在変数を全てランダムに決定する方 法を用いる.

### 4.4 実験結果

図5に実験結果を示す.異なるグラフでは異なる潜在変数の 値を用いている.分類精度はいずれも98%を超えており,潜 在変数とラベルが直接対応していないことがわかる.潜在変数 を固定した場合にはラベルの出現頻度に偏りが見られる.例え ば,潜在変数の値 $c_1$ を用いた場合はラベル0,1,2を多く出 力している.潜在変数の値 $c_2$ を用いた場合はラベル3,8を 多く出力しており,潜在変数の値 $c_3$ を用いた場合はラベル1, 7を多く出力している.一方で,潜在変数をランダムに決定し た場合は全てのラベルを概ね均等に出力している.

分類精度を維持しながら特定のラベルを多く出力できるため、潜在変数はラベルのサブグループに対応すると考えられる。例えば潜在変数の値  $c_1$  はラベル 0, 1, 2を要素としたサブグループを表現し、入力画像中の数字 0, 1, 2を優先的に扱う。潜在変数の値  $c_2$  はラベル 3 と 8 のサブグループ、潜在変数の値  $c_3$  はラベル 1 と 7 のサブグループと、数字の形が似ているものはサブグループ化されやすいと考えられる。

# 5. おわりに

本研究では、画像キャプションに対する表現学習に向けた、 深層生成モデルのアーキテクチャの検討を行った。画像キャプ ショニングを画像で条件づけたテキスト生成として扱うこと で、本提案モデルを既存の GAN のアーキテクチャの組み合わ せとして構築した.本提案モデルの有用性を示す検証課題とし て画像分類問題を扱い、本提案モデルが潜在変数としてクラス ラベルのサブグループを獲得し、生成するクラスラベルを選択 的に変化させることが可能であることを示した.

将来研究として以下が挙げられる.画像キャプショニングは 自然画像と自然言語を用いた問題であるのに対し,今回扱った 画像は自然画像ではない.画像キャプショニングに向け,自然 画像を用いた画像分類問題において本提案モデルの有用性を検 証することは直近の課題のひとつである.また,本提案モデル の出力の分析により潜在変数の表現を分析したが,潜在変数の 各次元や値が表現とどのように結びついているかは不明であ る.画像キャプションに対する表現学習の有効性の観点から, 潜在変数に対するより詳細な分析は必要である.モデルの解釈 性の観点から,人にとって解釈しやすいディスエンタングルな 潜在変数を獲得することも重要である.



図 5: 入力画像 1000 件に対する出力ラベルの出現頻度比. 潜在変数の値を固定したものが same, 潜在変数の値がランダムなもの が different である. 図 (1)(2)(3) では same は異なる潜在変数の値を用いている. acc は same に対する本提案モデルの分類精度 を示す.

- Chuang Gan, Zhe Gan, Xiaodong He, Jianfeng Gao, and Li Deng. Stylenet: Generating attractive visual captions with styles. In Proc IEEE Conf on Computer Vision and Pattern Recognition, pp. 3137–3146, 2017.
- [2] Xi Chen, Yan Duan, Rein Houthooft, John Schulman, Ilya Sutskever, and Pieter Abbeel. Infogan: Interpretable representation learning by information maximizing generative adversarial nets. In Advances in neural information processing systems, pp. 2172–2180, 2016.
- [3] Oriol Vinyals, Alexander Toshev, Samy Bengio, and Dumitru Erhan. Show and tell: A neural image caption generator. In *Proceedings of the IEEE conference* on computer vision and pattern recognition, pp. 3156– 3164, 2015.
- [4] David Donahue and Anna Rumshisky. Adversarial text generation without reinforcement learning. arXiv preprint arXiv:1810.06640, 2018.
- [5] Mehdi Mirza and Simon Osindero. Conditional generative adversarial nets. arXiv preprint arXiv:1411.1784, 2014.
- [6] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In Advances in neural information processing systems, pp. 2672–2680, 2014.
- [7] Yoshua Bengio, Aaron Courville, and Pascal Vincent. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, Vol. 35, No. 8, pp. 1798–1828, 2013.
- [8] Diederik P Kingma and Max Welling. Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114, 2013.
- [9] Martin Arjovsky and Léon Bottou. Towards principled methods for training generative adversarial networks. arXiv preprint arXiv:1701.04862, 2017.

- [10] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- [11] Vahid Kazemi and Ali Elqursh. Show, ask, attend, and answer: A strong baseline for visual question answering. arXiv preprint arXiv:1704.03162, 2017.
- [12] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770–778, 2016.
- [13] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167, 2015.
- [14] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th international conference on machine learning (ICML-10), pp. 807–814, 2010.
- [15] Andrew L Maas, Awni Y Hannun, and Andrew Y Ng. Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml*, Vol. 30, p. 3, 2013.
- [16] Xudong Mao, Qing Li, Haoran Xie, Raymond YK Lau, Zhen Wang, and Stephen Paul Smolley. Least squares generative adversarial networks. In *Computer Vision* (*ICCV*), 2017 IEEE International Conference on, pp. 2813–2821. IEEE, 2017.

深層学習を用いた画像変換に基づく会話からの音声抽出 Speech extraction from conversation based on image-to-image translation using deep neural networks

| 高市 晃佑*1         | 片上 敬雄*2         | 黒澤 義明*1           | 目良 和也*1     | 竹澤 寿幸*1            |
|-----------------|-----------------|-------------------|-------------|--------------------|
| Kosuke Takaichi | Yoshio Katagami | Yoshiaki Kurosawa | Kazuya Mera | Toshiyuki Takezawa |

\*1 広島市立大学大学院 情報科学研究科 Graduate School of Information Sciences Hiroshima City University \*2 広島市立大学 情報科学部 School of Information Sciences Hiroshima City University

We aim to separate sound sources by deep neural networks which has been active in recent years. We attempt to extract a certain human voice from usual conversation using the networks. We focus on image-to-image translation: pix2pix. The algorithm of pix2pix bases on purely procedure of the image processing. Therefore, we need an additional procedure, that is, we convert voice to spectrogram once. After that we perform to learn the networks to separate human voice, we especially pay attention to segmentation between the same sex and opposite sex. Form this point of view, we conducted two experiments using the sounds overlapped both sexes in this paper. Structure-Similarity (SSIM) index and color map representation were used as evaluation criteria. As a result, we confirmed the good extraction of the female voice from the one synthesized both sexes. However, we did not extract the female voice from same sex. Although we reached the conclusion that the separation did not work well, the generated voice seemed to be played naturally. This is not objective judgment. For this reason, it is our future work.

# 1. はじめに

これまでにも音源分離の技術が開発されてきた.例えば,複数の音源を複数のマイクで録音したデータから,それぞれの音源を分離するときに使われるブラインド信号分離等である.しかし,音源が互いに独立であると仮定する等があり,これらが成り立たない場合,適切な結果が出ない.また,人間の声と音楽等の分解を行っていることが多く,人間の声同士の分解は例が少ない.

そこで、音源の重なりを近年盛んである深層学習を利用し分離することを目的とし、合成音から一人の音声の抽出を行う.また、音声はすべてスペクトログラムと呼ばれる画像に一度変換する.一度画像に変換する理由は、音声に関する研究よりも画像に関する研究の方が多く、画像に関する知見が使用できると考えたからである.そのため、本稿では、様々な画像に対応でき、画像から学習した通りに加工し画像を出力することのできるpix2pixを用いて、音源の抽出を行う.

# 2. 提案手法

先行研究に楽曲からボーカルと音楽を分離している研究がある[Jansson 17]. 音楽と人間の声が分離できるのであれば、人間同士の発話の重なりも分離できるのではないかと考えられる.

また, RNN(Recurrent Neural Networks)という手法で分離す る研究も存在している[Huang 15]. 音声を一度スペクトログラム に変換する必要はない. しかし, 今回は画像に関する知見が使 用できることが有用であると考え, 画像を中心に学習を行う.

本稿では、音声をスペクトログラムへ変換し、pix2pixを用いて 深層学習を行い、音声抽出を試みる.pix2pix は GAN (Generative Adversarial Network)を利用した画像変換アルゴリ ズムの一種であり、例えば、白黒写真からカラー写真を生成し たり、地図から航空写真を生成したりできる.Generator と Discriminatorの2つのモデルが敵対することで変換精度を高め ていくモデルである.図1にpix2pixの変換例を示す.左が入力 であり、右が出力(predict)である. 本稿は、まず女性と男性の声に現れる特徴の違いに着目す る.人間の男性と女性の声には明確に高低差が存在する.具 体的には、男性と女性の声では平均基本周波数が異なる.基 本周波数とは、「周期的に生じる生体振動の時間間隔のうち、 最短の間隔として与えられる基本周期」[森勢 18]であり、「人間 が知覚する声の高さにおおむね対応する」[森勢 18].本稿では、 その差に注目する.すなわち、男性の声の平均基本周波数は 約 120Hz であり、女性では 240Hz であると報告されている[寺澤 84].同様に、男女の声の基本周波数と年齢の関係を報告して いる研究もある[粕谷 68].その研究によると 14 歳以降では男 女の声の平均基本周波数は大きく差がでている.

そこで本研究では、男女の声の平均基本周波数の違いから、 男女の声には大きな特徴の差異があると仮定し、音声をスペク トログラムへ変換を行い、その違いを学習する、そして、同性間 においてもある程度違いが表れると考え、同様に違いを学習す る、基本周波数が異なる男女の声の分離は容易であると思われ る、しかし、差が小さい女性同士の分離は困難であると思われる。



図1 pix2pix の入出力例

# 3. 実験と結果

本稿では、女性だけの音声と男女の合成音を変換したスペクトログラムをもとに、pix2pixによる深層学習を行う実験(3.1節)と 女性だけの音声と女性同士の合成音を同様に変換し、深層学 習を行う実験(3.2節)を行う.

また,生成された画像は元の音声のスペクトログラムと比較し て評価を行う.比較方法として SSIM(Structural Similarity)(式 1) とカラーマップ(図 2)を求め精度を測る. SSIM は人間が感じる 違いに近い結果を返し,1 に近いほど同じと言える.

連絡先:高市晃佑,広島市立大学情報科学部,広島市安佐南 区大塚東,takaichi@ls.info.hiroshima-cu.ac.jp

カラーマップは生成画像と元のスペクトログラム,2 つの画像の差で表し,青(左)に近いほど未変換,赤(右)に近いほど過変換,中央値の緑に近いほど変換ができていると言える.

図 2 カラーマップの見方  
SSIM = 
$$\frac{(2\mu_x\mu_y+C_1)(2\sigma_{xy}+C_2)}{(\mu_x^2+\mu_y^2+C_1)(\sigma_x^2+\sigma_y^2+C_2)}$$
 (1)

# 3.1 男女の分離

実験の際に、Discriminatorのネットワークパラメータを変更して3種の条件で実験を行い、各条件に対して validation、testを 実行する.なお、本研究で使用したネットワークパラメータは、以下の通りである.

- 1. NLayerDiscriminator のカーネル数が 64
- 2. NLayerDiscriminator のカーネル数が 128
- 3. PixelDiscriminator のカーネル数が 64

1 と 2 の NLayerDiscriminator のネットワークと 3 の PixelDiscriminator のネットワークを図 3 と図 4 に記載する. なお、 ここにある ngf はカーネル数のことである.



図3 NLayerDiscriminator のネットワーク



# 図4 PixelDiscriminator のネットワーク

NLayerDiscriminator と PixelDiscriminator の違いは畳み込 みを行う際に、PixelDiscriminator は 1pixel 毎に読み込みと書き 出しを行う点にある.

3 条件中で最も SSIM 値が高かった条件(0.806)について述 べる. 元音声のスペクトログラムと合成音のスペクトログラム(図5), Discriminatorが生成したスペクトログラムとSSIMを基にしたカラ ーマップ(図 6)を示す. 次に精度比較用に,最も精度が低かっ た条件(0.652)による,同一音声区間の生成画像とカラーマップ (図 7)を示す.

図 5,図 6の比較から,元音声の特徴は正確に残しつつ,図 5 右側の左下付近,特に音が重なっている部分は変換ができた. このことは,図 6 のカラーマップからもわかる.しかし,図 7 の左 では左下部分は合成音が残っており,図 7 のカラーマップから も確認できる. つまり,ネットワークパラメータによって変換精度 に大きく差があると言える. また,全体的に高周波域や無音区 間の変換は過変換気味であることが,カラーマップから読み取 れる. これにより SSIM 値が低下したと考えられる.



図5 元音声(左)と合成音(右)のスペクトログラム



図6 生成されたスペクトログラム (左) とカラーマップ



図7 別のネットワークの生成画像(左)とカラーマップ

# 3.2 女性同士の分離

女性同士の場合では、学習データを以下のように変え、学習 を行った.

1. 単独の発話のみを学習

2.1. 対話からの発話を全体の 10%になるよう追加し学習

2.2. 対話からの発話を全体の 20%になるよう追加し学習

無音区間を発話の前後に追加し、全体の 10%になるよう追加し学習

条件 1 では、学習データにラジオ CD から収集した単独の発 話をスペクトログラムで 9,235 件収集し、これを学習した. 他の条 件ではこの 9,235 件に追加していく. 各条件 1000epoch まで学 習し、SSIM 値の推移とテスト結果にはそれぞれ最も良い世代の 変換を記載する. 図 8、図 9 では、条件 1(左上)、条件 2.1(右 上)、条件 2.2(左下)、条件 3(右下)とする.

SSIM 値については、図 8 より 100~300epoch においてピー クを迎え、以降は緩やかに減少している。図 9 より、中央下の重 なりが分離できていない等、変換できていない部分は同じであ ることがわかる.また、図 9 右下の条件 3 の結果は右上に過変 換部分が見受けられる.これは右上が無音区間であると判断し たことが原因だと考えられる.また、SSIM 値については、図 8 よ り、いずれも 0.6 ほどであり、右上以外の部分は変換できている と考えられる.しかし、男女間の実験と同様に高周波域の変換 は過変換気味である.



# 4. まとめ

本研究では、重なった音源からの分離を目的とした. そのために本論文では pix2pix を用いてスペクトログラムから一人の発話を抽出する手法を提案した. 男女間では、SSIM 値とカラーマップからも抽出できていると判断できる. しかし、同性間では、黄色の箇所が残っており、抽出できているとは言いづらい. 学習データが少なかったことが原因と考えられる.

今後の課題として、学習データに音声の前後ではなく途中に 無音区間を考慮したデータを含めて再学習をし、抽出の精度を 高めていく必要がある.また、学習に使用するネットワークに関 しても、適宜パラメータを調整し、精度の向上を模索する必要が ある.また、音声を聞いた限り大きな差はないように感じられた 点は補足しておく.主観評価についても今後の課題である.

# 謝辞

この研究は、国立研究開発法人科学技術振興機構(JST)の 研究成果展開事業「センター・オブ・イノベーション(COI)プログ ラム」の補助を得ている.

# 参考文献

[Huang 15]Po-Sen Huang Minje Kim Mark Hasegawa-Johnson Senior and Paris Smaragdis, Joint Optimization of Masks and

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

Deep Recurrent Neural Networks for Monaural Source Separation, IEEE/ACM TRANSACTIONS ON AUDIO, SPEECH, AND LANGUAGE PROCESSING, VOL. 23, NO. 12, DECEMBER 2015

- [Isola 17]Phillip Isola,Jun-Yan Zhu,Tinghui Zhou,Alexei A. Efros, Image-to-Image Translation with Conditional Adversarial Networks, In CVPR 2017.
- [Isola 17] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros, Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, In ICCV 2017.
- [Jansson 17]Andreas Jansson, Eric J. Humphrey, Nicola Montecchio, Rachel Bittner, Aparna Kumar, Tillman Weyde, Singing Voice Separation with Deep U-Net Convolutional Networks, Proceedings of the 18th International Society for Music Information Retrieval Conference (ISMIR), 2017.
- [粕谷 68] 粕谷 英樹, 鈴木 久喜, 城戸 健一," 年令, 性別による 日本語 5 母音のピッチ周波数とホルマント周波数の変化," 日本音響学会誌, 24(6), pp.355-364, 1968.
- [森勢 18]森勢 将雅, "音声分析合成, 一般社団法人 日本音響学会, pp47, コロナ社, 東京, 2018 年
- [寺澤 84] 寺澤 るり子 垣田 有紀 平野 実, "平均呼気流率,声の基本周波数および声の強さの同時測定—正常成人男女 各 30 名の成績—," 音声言語医学, 25(3), pp189-207, 1984.

# 機械学習を用いた構音障害分類における 音声特徴量間の耐ノイズ性能の比較 An anti-noise performance comparison between acoustic features in detecting voice pathology using machine learning 鈴木 康大<sup>\*1\*2</sup> 篠原 修二<sup>\*2</sup> 馬目 信人<sup>\*1\*2</sup> 朝長 康介<sup>\*1\*2</sup> 光吉 俊二<sup>\*2</sup> Kouta Suzuki Shuji Shinohara Nobuhito Manome Kosuke Tomonaga Shunji Mitsuyoshi

\*1 ソフトバンクロボティクス株式会社 \*2 東京大学大学院工学系研究科 SoftBank Robotics Corp. Graduate School of Engineering, The University of Tokyo

Developing communication robots requires to analyze human voice including various kinds of human biological information because the nonverbal information plays an important role in smooth communications between humans and robots. To analyze numerous voices available via the robot by using machine learning, we should take consideration of the existence of noises added to the voices. However, some acoustic features used for sensing human biological information is not designed for the noises. To validate the variation of the accuracy of classification when the voices includes the noises, we compare the classifications using voice indexes proposed for voice pathology estimation and using Mel-Frequency Cepstrum Coefficients(MFCC) in the classification problem of voice pathology as an early study. Experimental results show that classification using MFCC can detect voice pathology more precisely despite the noises while other voice indexes are adversely affected by the noises.

# 1. はじめに

人とのコミュニケーションを目的としたロボットが円滑に行動す るためには、非言語情報を読み取ることが重要である.人から発 せられた音声には多彩な生体情報が含まれており、健康状態 や精神衛生状態を分類する試みが存在することから[光吉 2011] [Tokuno 2015] [Shinohara 2017]、声はコミュニケーション の際に重要な役割を果たすと考えられる.従って、コミュニケー ションロボットの開発の際には、人から発せられた音声の解析が 重要となる.

ロボットから取得される音声を解析する手法として、機械学習 が挙げられる.機械学習による音声分類の大まかな流れは以下 の通りである.まず分類したい状態に対応する音声をある程度 用意し、それぞれの状態における音声の特徴量を抽出する(前 処理段階).次に同じ状態の音声に現れる特徴量のパターンを 見つける(学習段階).このようにして状態ごとに得られたパター ンを使って、新たに得られた音声に対してパターンマッチングを 行い、最も適合するパターンに対応する状態を、その音声の状 態と分類する(分類段階).

ここで学習させる際の音声と分類したい音声の取得環境が異 なる場合、人の状態が同じでも異なる特徴のパターンが見られ る場合があり、分類性能に影響を及ぼす可能性がある.特に、 ロボットなどを介して取得された音声の場合、音声を取得する周 囲の環境を制御することが困難なため、周囲のノイズが音声に 含まれることを考慮する必要がある.音声を用いて人の状態を 分類することを目的とした機械学習において、いくつかの音声 指標を導出して状態を分類することが提案されているが、これら は音声にノイズが含まれることを考慮していないものが多く、音 声の一部の特徴しか用いないため、含まれるノイズ次第では指 標に大きな影響を与える可能性がある[髙野 2017].

一方,近年計算機資源が増大することにより,深層学習をは じめとして膨大なデータを使った機械学習手法による分類が大 きな成果を出している.これらは,得られた音声からヒューリステ ィックに指標を導出するのではなく,音声の様々な特徴を捉える 分類を可能にする.ここで音声の特徴を表す普遍的な特徴量と

連絡先:鈴木康大,ソフトバンクロボティクス株式会社/東京大 学大学院工学研究科, suzuki@coi.t.u-tokyo.ac.jp して、メル周波数ケプストラム係数(MFCC)が挙げられる. MFCC は音声認識でよく使われる特徴量であり、従来の提案されてき た指標よりも広い範囲で音声の特徴が含まれている. 従って、 音声にノイズが含まれている場合でも正確な分類が行えること が期待される.

本稿では、初期検討として、ノイズが含まれる環境下で音声から構音障害の有無を分類する問題を考え、音声からヒューリスティックに導出される指標と MFCC による分類を比較し、ノイズの強さ又は種類による分類性能の変動を検証した.

# 2. 関連研究

音声から構音障害の有無を分類するために,健常者の音声 と比較して構音障害と診断された人のみに現れる音声指標が いくつか提案されている. Teixeira らは,音声長母音から導出さ れる jitter, shimmer, HNR(Harmonic to Noise Ratio)が構音障害 を持つ人と健常者で異なる分布を持つことを明らかにし,これを 用いて構音障害を分類することを提案している[Teixeira 2014]. また,篠原らは,構音障害を持つ人の長母音からピッチを検出 しづらいことを踏まえ,ピッチレートを用いて構音障害を分類す ることを提案している[Shinohara 2016].

構音障害分類用に音声指標を設計するのではなく,音声特 徴量を上手く使って機械学習を行い,構音障害を分類する試 みもなされている. Londonoらは, MFCC に加えて, 音声波形か ら得られるリアプノフ指数や HNR を特徴量として、ガウス混合分 布(GMM)及びサポートベクターマシン(SVM)で構音障害を分 類する手法を提案し、マサチューセッツ工科大学が提供する構 音障害データベース(MEEI)で 98.23%の分類性能を出した [Londoño 2011]. Fang らは, MFCC のみを用いて深層学習で 構音障害を分類することを提案し, Far Eastern Memorial Hospital が取得した構音障害データベースで, 94.26%, 90.52% の分類性能を男性,女性の音声に対して出した[Fang 2018]. ALHUSSEIN らは音声をスペクトログラムに変換し、これを画像 として扱い既存の画像分類用モデルである VGG16 や Caffenet の一部分を使って学習し、先述の MEEI や saarbrücker が提供 する構音障害データベース(SVD)で93.9%の分類性能を出した [Alhussein 2018]. いずれの場合も音声にノイズが含まれていな



図 2. 車の走行音の周波数領域のパワー成分の分布

い場合に対しての性能であり、これらが外部からノイズが混入した場合の性能については改めて検討する必要がある.

# 3. 実験概要

## 3.1 使用した音声データセット

今回,構音障害データベースとして,先述の MEEI を利用した.音声のサンプリングレートは11kHzで,モノラルチャンネルで録音されている.このデータベースから,[Llorente 2006]に挙げられている,健常者 53人,構音障害者 173人の長母音(ahの発音)を実験に利用するデータセットとして使用した.このデータセットは,健常者の発音は3秒間,構音障害者の発音が1秒間であり,年齢,性別などの偏りが健常者と構音障害者で同一であるため,健常者と構音障害者のデータ分布の偏りを最小限に抑えられている.このデータセットに含まれる音声を,ffmpeg-normalizeを用いて音量の正規化を行った.ここでは,欧州放送連合が勧告している,EBU R128に従った方法で行った.

# 3.2 付加するノイズ

先述のデータセットを1:1 に分け、一方の音声にはノイズを付加させず、MFCCを用いた機械学習による訓練用のデータセットとして使用した.もう一方の音声は、ノイズを付加させて分類性能を評価するためのテスト用のデータセットとして使用した.付加するノイズの種類は2種類用意した.一つはホワイトノイズ(全周波数帯におけるレベルが均一なノイズ)で、もう一つは車の走行音(低周波におけるレベルが高いノイズ)である.各ノイズの周波数領域でのレベルを図1図2に表す.ノイズの音源に対しても音声と同様の手法で正規化を行った.この正規化されたノイズ音源のレベルを変化させ、音声に付加させた.付加するノイズのレベルは5種類用意し、2×5=10種類の音声を用意した.

## 3.3 音声指標による構音障害分類

今回使用する音声指標として, jitter, shimmer, HNR を採用した.構音障害を持つ人の音声の特徴として, 音声波形に乱れが 生じることがある.この乱れ具合を定量的に評価できる指標として, jitter, shimmer, HNR が挙げられる.jitter は時間軸方向に発 生する非常に短い変動の成分を表し, shimmer は音声の振幅 方向に発生する変動の成分を表す.また, HNR は音声波形の 基本周波数のパワーと, ノイズ成分のパワーの比を表す.今回 この 3 つのパラメータを, 音声特 徴量抽出ソフトである OpenSMILE[Eyben 2010]を用いて音声ファイルから 3 つの特徴 量を抽出した. プリセットとして, avec2011.confを使用し, 音声ファイルごとに得られたパラメータのうち, 中央値を表す値を採用した. この値を用いて健常者と構音障害者のラベル及び各指標の値を対応付け, ROC 曲線を描きその AUC の値を見ることで分類性能を評価した.

### 3.4 MFCCを用いた機械学習による構音障害分類

今回 MFCC を用いた分類を行うため、ニューラルネットワーク (DNN)および SVM の二つのモデルを構築した. 二つのモデル の構築のために、ノイズが付加されていないセットで学習を行っ た. MFCC の導出にあたっては, Python のライブラリである librosa を利用した. 音声から MFCC を抽出するにあたって, 音 声ファイルの先頭からウィンドウ幅 46 ms (512 サンプル)フレー ムシフト幅 12 ms (128 サンプル)と指定して切り出した. この切り 出したウィンドウに対して、MFCCの13次元の係数と、その一次 微分項の計 26 次元のベクトルを導出した. この 26 次元のベクト ルを, DNN 及び SVM の入力として扱った. DNN の構築には chainer を利用した. DNN は、中間層として 300 ノードの全結合 を2層用意し、出力層は2ノードの全結合を用意した、SVMは、 python のライブラリである sckit-learn を用いた. パラメータとして, コストパラメータは 1.0, 基底関数は RBF(動径基底関数)を指定 した.この2つの学習済みモデルに対して、テスト用のデータセ ットから音声を入力すると、各ウィンドウに対して健常者又は構 音障害者の分類が得られる. 今回は全体のウィンドウ数に対し て構音障害と分類されたウィンドウの数の割合を,その音声に おける構音障害のスコアとして利用し、このスコアを用いて健常 者と構音障害者のラベル及び各指標の値を対応付け, ROC 曲 線を描きその AUC の値を見ることで分類性能を評価した.

# 4. 実験結果と考察

図3図4にノイズレベルを変化させたときのAUCの値の推移、表1表2にAUCの数値を示す.音声指標を利用した分類において、jitter、shimmer、HNRなどの音声指標を利用した分類において、jitter、shimmer、HNRなどの音声指標を用いた場合の分類性能は、ノイズレベルを上昇させるといずれも低下した.ホワイトノイズを付加させた場合では、レベルが上昇するにつれて均一な下がり方をしており、車の走行音を付加した場合では、ノイズレベルが比較的高い時に性能が急激に悪化した.これは、この3つの音声指標はいずれも音の乱れが激しいほど高くなるため、ノイズの影響が無視できる際は健常者と構音障害者の声の乱れを捉えることが出来る指標となるが、ノイズレベルが大きい際は、ノイズから生じる音の乱れが指標に及ぼす影響が強くなるため、健常者と構音障害者の差が指標に含まれなくなる.そのためノイズレベルが高くなるにつれて、構音障害の分類性能が悪くなったと考えられる.

一方 MFCCを用いて DNN や SVMを用いた場合は, 音声指 標を用いた場合と比較して, ノイズレベルが上昇した場合でも 分類性能が低下しなかった. DNN と SVM の間で性能及び性 能の下がり具合に顕著な差は見られなかった. これらの結果は, MFCC から構音障害を持つ人に現れる音声特有の特徴を抽出 し, テストデータにノイズが含まれていても読み取ることが出来る 特徴を学習した結果が現れたものだと考えることが出来る. MFCC は音声特徴量として汎用的に用いることができるため, 構音障害以外の状態分類に応用出来る可能性がある.



図 3. ホワイトノイズを付加させた際の AUC 推移



図 4. 車の走行音を付加させた際の AUC 推移

# 5. まとめ

ノイズが混在するような環境下で音声を取得する際に, MFCCを用いた分類を行うことで,既存の音声指標を用いた場 合よりも分類性能を向上させる可能性が示唆された.今後の展 望としては,今回は既存のデータセットに対してノイズを付加し て評価したが,実際の録音時にノイズが含まれた場合の耐ノイ ズ性能の推移を評価することや,構音障害分類以外の問題で の耐ノイズ性能の検証を行い,音声から人の内部状態をセンシ ングする際により強固な手法を確立していくことが挙げられる.

### 参考文献

- [光吉 2011] 光吉俊二,徳野慎一,田中靖人:"音声感情技術 STを使ったストレスへの応用",日本疲労学会誌,第6巻,第 2号,pp.641-644,2011.
- [Tokuno 2015] Tokuno, Shinichi: Stress evaluation by voice: from prevention to treatment in mental health care, Econophysics, Sociophysics & other Multidisciplinary Sciences Journal, vol.5, pp30-35, 2015.
- [Shinohara 2017] Shinohara, Shuji, et al.: Case studies of utilization of the mind monitoring system (MIMOSYS) using voice and its future prospects, Econophysics, Sociophysics, and Multidisciplinary Sciences Journal, vol.7, pp7-12, 2017
- [高野 2017] 高野 毅 ほか、"走行中の自動車騒音が感情やストレス状態の分類に有用な音声構造解析に与える影響", HCGシンポジウム 2017, 2017.

### 表 1. ホワイトノイズを付加させた際の AUC

| 音声に対する     | jitter | shimmer | HNR  | DNN  | SVM  |
|------------|--------|---------|------|------|------|
| ノイズレベル[dB] |        |         |      |      |      |
| (no-noise) | 0.88   | 0.89    | 0.62 | 0.95 | 0.95 |
| -24        | 0.86   | 0.87    | 0.90 | 0.95 | 0.92 |
| -18        | 0.85   | 0.81    | 0.83 | 0.96 | 0.94 |
| -12        | 0.83   | 0.69    | 0.66 | 0.95 | 0.93 |
| -6         | 0.78   | 0.50    | 0.47 | 0.93 | 0.93 |
| 0          | 0.65   | 0.40    | 0.33 | 0.92 | 0.93 |

表 2. 車の走行音を付加させた際の AUC

| 音声に対する     | jitter | shimmer | HNR  | DNN  | SVM  |
|------------|--------|---------|------|------|------|
| ノイズレベル[dB] |        |         |      |      |      |
| (no-noise) | 0.88   | 0.89    | 0.62 | 0.95 | 0.95 |
| -24        | 0.88   | 0.89    | 0.59 | 0.94 | 0.92 |
| -18        | 0.89   | 0.90    | 0.60 | 0.94 | 0.92 |
| -12        | 0.88   | 0.87    | 0.66 | 0.92 | 0.91 |
| -6         | 0.84   | 0.82    | 0.66 | 0.90 | 0.91 |
| 0          | 0.49   | 0.56    | 0.49 | 0.88 | 0.87 |

- [Teixeira 2014] Teixeira, João Paulo, and Paula Odete Fernandes: "Jitter, Shimmer and HNR classification within gender, tones and vowels in healthy voices." Procedia Technology, vol.16 pp.1228-1237, 2014.
- [Shinohara 2016] Shinohara, Shuji, et al. "Voice disability index using pitch rate." Biomedical Engineering and Sciences (IECBES), 2016 IEEE EMBS Conference on. IEEE, 2016.
- [Londoño 2011] Arias-Londoño, Julián D., et al. "Automatic detection of pathological voices using complexity measures, noise parameters, and mel-cepstral coefficients." IEEE Transactions on Biomedical Engineering, vol.58, pp.370-379, 2011
- [Fang 2018] Fang, Shih-Hau, et al. "Detection of Pathological Voice Using Cepstrum Vectors: A Deep Learning Approach." Journal of Voice, In press, 2018.
- [Alhussein 2018] Alhussein, Musaed, and Ghulam Muhammad. "Voice pathology detection using deep learning on mobile healthcare framework." IEEE Access, vol.6, pp. 41034-41041, 2018.
- [Llorente 2006] Godino-Llorente, Juan Ignacio, Pedro Gomez-Vilda, and Manuel Blanco-Velasco. "Dimensionality reduction of a pathological voice quality assessment system based on Gaussian mixture models and short-term cepstral parameters." IEEE transactions on biomedical engineering vol.53, pp.1943-1953, 2006
- [Eyben 2010] Eyben, Florian, Martin Wöllmer, and Björn Schuller. "Opensmile: the munich versatile and fast open-source audio feature extractor." Proceedings of the 18th ACM international conference on Multimedia, 2010.

Word2vec を利用した文章校正支援に向けて Toward proofreading support using Word2vec

丸山正人\*1 Masato Maruyama

竹川 高志\*1 Takashi Takekawa

\*1 工学院大学情報学部 Faculty of Informatics, Kogakuin University

Abstract: Word2vec is a method of for learning distributed vector representations that semantic word relationships. In this paper, we aim for detection words misused from a sentence by distributed vector representations built using Word2vec. As a result, using linear discriminant analysis improved the detection rate of words misused.

# 1. はじめに

自然言語で扱われる単語の意味を計算機に理解させること は自然言語処理の分野において重要な課題である.この解決 策として,分布仮説という同じ文脈で出現する単語は同じ意味を 持つ傾向があるという事[1]に基づき,ある単語とその周辺に出 現した単語を学習し単語間の関係をベクトルで表した分散表現 という手法がある.これは現在では自動音声認識および機械翻 訳への応用など広範囲の自然言語処理タスクへ応用されてい る[2].近年 Tomas Mikolovらによって研究された Word2vec は 分散表現を得る手法であり,従来の手法より高速な学習を可能 にし[3],単語同士の関係が vec("Madrid") - vec("Spain") + vec("France")の結果に最も近い単語ベクトルが vec("Paris")と なるような線形構造を持つ[2]ことで近年話題になっている.

また,自然言語処理のタスクとして文章から誤りを検出,訂正 する作業として校正があるが,検出,訂正される誤りは事前に予 測ができる習慣的なものや,文から単語の分割を行う処理であ る形態素解析でわかるような表層的なものに限られており,文脈 や一般常識を用いた解析により判断できるような,内容レベルの 校正は困難とされている[4].

そこで Word2vec を用い,実在している単語かつ文法として 正しく用いられる固有名詞の誤字の検出を本研究の目的とする. これは実在している単語であり文法が正しいために事前の予測 のみでの解決や,形態素解析や文法からの検出が難しいと考え られるような内容レベルの校正になると考えられ,助詞や代名詞 などの,文脈に制限されずに出現が考えられる品詞ではなく特 定の文脈でのみ出現するような固有名詞であるため,分布仮説 に基づいた分散表現を出力する Word2vec を用いる事が適切 と考えられるためである.

以上のことから,解析対象の文章に含まれていない固有名詞 を,文脈に出現しないような単語である誤字として,文章内の固 有名詞のベクトルの平均と各固有名詞のベクトルについてユー クリッド距離を用いた誤字の検出を行い,それを通して固有名詞 のベクトルの分布を調査した.

その結果,文章内の固有名詞のベクトルの平均と各固有名詞の ベクトルについてのユークリッド距離が文章内の固有名詞のベ クトルと文章に含まれていない固有名詞のベクトルで分布が重 なっていることが分かり,文章内の固有名詞について主成分分 析を行ったものについても分布が重なっていた.これは軸が表 す意味を無視して分離を行なっているのが原因と考えられ,文 章内の固有名詞と文章に含まれない固有名詞の分布を分離す るような特徴を持つ軸を切り出す線形判別分析を行うと 2 つの 分布を分離することができた.

# 2. 実験方法

本研究では、Word2vec を用いて学習を行った Web 上で公開されている分散表現のモデル[5]用い、モデルの学習に用い られた Wikipedia の日本語記事を解析対象の文章に用いる.また、解析で用いる文章の単位は段落もしくは記事であり、単語の 分割、品詞の特定についてはシステム辞書に mecab-ipadic-NEologdを用いた MeCabを用いた.

# 2.1 ユークリッド距離を用いた誤字の検出

Wikipediaの日本語記事から段落ごとに文章を取り出し、その 中から固有名詞 1 つを段落に含まれていない固有名詞に交換 された文章を解析対象とする.文章内の固有名詞のベクトルの 平均との差が最も大きかった固有名詞が交換された固有名詞 であるか調べ、段落内の固有名詞の数ごとにその正答率を計算 した.

# 2.2 ユークリッド距離と主成分分析を用いた単語の分布

Wikipedia の日本語記事から記事ごとに文章を取り出し,記 事内の固有名詞と記事で用いられていない固有名詞の分布を グラフに表し確認する.分布をグラフに表す方法は,記事内の固 有名詞のベクトルの平均との距離を記事内の固有名詞と記事 に用いられていない固有名詞の2群つについてヒストグラムに 表す方法,記事内の固有名詞のベクトルについて2次元へ圧 縮する主成分分析を行い,得られた変換行列を用いて記事内 の固有名詞と記事に用いられていない固有名詞のベクトルに変 換行列をかけ,散布図にプロットする方法である.

# 2.3 線形判別を用いた分離

Wikipediaの日本語記事から記事ごとに文章を取り出し、記 事ごとに記事内の固有名詞と記事外の固有名詞を分離するよう な教師データとして線形判別分析を行い分離度を検証した.

# 3. 結果

### 3.1 ユークリッド距離を用いた誤字の検出

図 1 は段落内の固有名詞の数ごとに文章に含まれていなかった単語の正解率を出したグラフであり、エラーバーは誤差分散を表している. 文章内の交換されていない固有名詞の数が 2 個のときの正解率がおよそ 0.7 となり. 単語数が多くなるにつれ

連絡先:竹川 高志,工学院大学 情報学部,〒163-8677 東京都新宿区西新宿 1-24-2,03-3340-0103, E-mail: takekawa@cc.kogakuin.ac.jp

て正解率は低下し、交換されていない固有名詞の数が 30 個の時には正解率はおよそ 0.5 となった.

# 3.2 ユークリッド距離と主成分分析を用いた単語の分布

図2はWikipediaの"日本語"という記事に対して記事内の 固有名詞と記事に含まれていない固有名詞について分離を行 ったグラフである.上から順に記事内の固有名詞のベクトルの平 均との距離を用いた分離方法,主成分分析を用いた分離方法 のグラフである.ユークリッド距離を用いて分離を表したグラフは 記事内の単語のヒストグラムと記事に含まれていない単語のヒス トグラムの面積が等しくなる様にグラフの設定をおこなっている ため,実際には記事内の単語のヒストグラムは小さくなる.二つの グラフとも文章内の固有名詞の分布と文章に含まれていない固 有名詞の分布が重なっていることが分かる.



図 1. ユークリッド距離を用いて文章に含まれていなかった 固有名詞を検出できた正答率



図 2. "日本語"記事に対しユークリッド距離を用いた分離, 主成分分析を用いた分離を行なった分布

# 3.3 線形判別分析を用いた分離

図 3 は Wikipedia の"日本語"という記事に対して、図 4 は "石川県"という記事に対して記事に含まれる固有名詞と含まれ ていない固有名詞を教師データとして線形判別分析を行った 結果である. この二つのグラフについても 2 つの分布の面積が 等しくなる様にグラフの設定を行っているため、実際には記事に 含まれる固有名詞のヒストグラムは小さくなる. ユークリッド距離を 用いた分離や主成分分析を用いた分離より 2 つの分布の重な りが少ない事がわかる.



# 4. まとめ

ユークリッド距離を用いた誤字の検出では期待値よりは大き な正解率となったが、文章校正を行う上では不十分であった.そ こで実際にベクトル同士の距離についての分布と主成分分析を 行った分布について調査したところ、分離を行いたい 2 つの分 布が重なっている事がわかった.これは Word2vec のモデルが 100 次元と高次元になっているのにも関わらず、距離を用いた 分離では軸ごとの重みを考慮していないこから、主成分分析に ついても軸ごとの分布の意味を考慮していない事から起因する ものだと考えられる.そこで 2 つの分布が分離する様な軸で次 元を圧縮するために線形判別分析を行うと上の二つの手法より よく分離している事がわかった.

また,図5は"日本語"の記事に対して線形判別分析を行い, 得られた軸上に存在する単語を出力したグラフである.グラフに 記載されている単語は横軸は線形判別分析により得られた軸 であるが,縦軸に意味はない.このグラフにプロットされている単 語は横軸で正の方向に進むほど文章の内容をよく表している単 語と考えられられ,単語と文章の内容の関連度を数値化する事 が期待できると考えている.



図 5. "日本語"の記事に対して線形判別分析を行った軸に対して単語をプロットした.

- Zellig S. Harris: Distributional structure, WORD, 10:2-3 .pp.146-162, 1954.
- [2] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg Corrado and Jeffrey Dean. Distributed Repersentations of Words and Phrases and their Compositionality. Advances in Neural Information Processing Systems 26. pp.3111-3119. 2013.
- [3] Tomas Mikolov, Kai Chen, Greg Corrado and Jeffrey Dean. Efficient Estimation of Word Representations in Vector Space. In Proceedings of Workshop at International Conference on Learning Representations, 2013.
- [4] 池原 悟, 小原 永, 高木 伸一郎. 文書校正支援システムにおける自然言語処理. 情報処理. 34巻. 10号. pp.1249-1258. 1993.
- [5] 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, 言語処理学会第 22 回年次大会. pp.A5-2. 2016.

# DAMを用いた文レベルのアライメントによる テキスト平易化コーパス構築手法の提案

Construction of Corpus for Text Simplification by Sentential Alignment based on Decomposable Attention Model

> 永塚 光一<sup>\*1</sup> Koichi Nagatsuka

渥美 雅保<sup>\*1</sup> Masayasu Atsumi

\*1 創価大学大学院 工学研究科 Graduate School of Engineering, Soka University

Text Simplification is a task to generate a sentence which is easier to understand than original. Text Simplification helps beginners such as children and foreigners learn languages. Recently, seq2seq models based on large scaled datasets have achieved state-of-the-art results in many areas including Machine Translation, Summarization, and Question Answering, to name a few. Although these model can be applied in text simplification as well, it requires a large number of parallel sentence pairs. Since available sentential corpora for text simplification are inadequate, building new corpus is so critical. In this paper, we suggest the application of neural textual entailment method to detection of simplified sentence pairs so that we are able to automatically construct text simplification dataset. In experiment, we evaluated the performance of identification of simplified sentences by using manually annotated dataset, and our proposed framework outperformed a baseline method.

# 1. はじめに

テキスト平易化とは、ある文が与えられた時に、読者にとってよ り分かりやすい文に表現を変換する処理のことを指す.テキスト 平易化は、新たに言語を学び始めた子供や、外国人、難読症患 者や、リテラシーの低い人々を支援するために重要な技術であ ると言える.ここで、ある文を対応する簡易な表現の文に変換す るタスクは、単一言語における翻訳処理の一種であるとみなすこ とができる.この観点から、機械翻訳で成功を収めているニュー ラル seq2seq モデルをテキスト平易化へ応用した手法の研究が 行われてきた[Nisioi 17].

こうしたモデルの学習には入力文と出力文が1対1に対応し ている大規模なパラレルコーパスが必要とされる.しかしながら, テキスト平易化にはそのような文間でアライメントが取れたコー パスが構築されていない現状がある. テキスト平易化のための パラレルコーパスが不足する理由として,2つの理由が挙げられ る.まず,一つ目の理由として、ある同一のトピックに対して,複 数のレベルで明確に平易化された文書の数が少ないということ が挙げられる.これは、一般的に平易化という処理が翻訳に比 べてニーズが低いために、 平易化された文書のペアが手に入り にくいということに起因する. また, パラレルコーパスの構築が難 しいもう一つの原因として、平易化された文が、元の文と1対1 の対応関係を常に持つとは限らないということが挙げられる. テ キスト平易化は、元の文章の重要な部分だけを残す処理である という観点から要約の一種であり、1文を短くするだけに留まらず、 元の文章から重要でない文の削除が起きたり、2 文を1 文に統 合したりすることがある.したがって、平易化された文書ペアを取 得することができた場合でも, 文の対応関係を見つけることは容 易ではない. これに対し、人間が手作業で対応関係にアノテー ションを行うことは、質の高いコーパスのために理想的ではある が、かなりのコスト及び時間を要するため、コーパス構築のボトル ネックとなっている.

こうした中,先行研究[Xu 15]では,元文と平易化文のペア(こ れを平易化文ペアと呼ぶ)を自動的にアライメントする手法が提 案されている.しかし,これまでの手法は,表層的な情報のみに 基づいており,平易化の処理におけるパラフレーズや構文構造 の変化を判定することが難しいという課題点が残されている.

そこで、本研究では、より深層的な意味特徴に着目した Decomposable Attention Model を平易化文ペアの検出に応用 することを提案する. Decomposable Attention Model はテキスト 含意認識の分野において使用されているモデルである. テキス ト含意認識は、二つ文が与えられた時に、それらの間で含意関 係が成り立つがどうかを判定するタスクである. ここで、平易化さ れた文は元の文と等価か、少なくとも含意関係にあると言える. すなわち、平易化文ペアの検出は、含意関係認識の問題に置 き換えることができる. 含意関係の推論処理において、従来の表 層的特徴ではなく、セマンティックな特徴を効果的に利用するこ とができれば、パラフレーズが起きた平易化文ペアの検出が可 能になると期待される.

# 2. 先行研究

# 2.1 テキスト平易化コーパス

これまで開発されてきたテキスト平易化のためのデータセット として, Simple Wikipedia Corpus[Zhu 10]と Newsela Corpus[Xu 15]がある.

### (1) Simple Wikipedia Corpus

Simple Wikipedia Corpus は最初に開発されたテキスト平易化 のための大規模データセットである.データの構築には Wikipedia にある記事とその記事をより簡単な英語に置き換えた Simple English Wikipedia の記事が文書ペアとして使われている. Simple Wikipedia Corpus は、テキスト平易化の研究において貴 重なベンチマークデータセットであるものの、平易化のための再 編集をしているエディタがボランティアであることや、明確な平易 化の統一基準が不足していることに起因する平易化処理の質 の低さが問題点として指摘されている[Xu 15].

連絡先:永塚光一,創価大学大学院工学研究科,東京都八王 子市丹木町1丁目236, e18m5212@soka-u.jp

### (2) Newsela Corpus

こうした問題意識に基づき、その後 Newsela Corpus が作成された. Newsela Corpus は、児童のための学習教材からデータを 収集しており、プロのエディタにより複数の学習者レベルに応じ てテキストが編集されていることが特徴である. Newsela Corpus は Simple Wikipedia Corpus に比べて、テキスト平易化の質が高 いコーパスであるものの、どちらのコーパスも依然として文レベ ルのアライメントがなされていないという課題点がある.

# 2.2 自動アライメント

文レベルのアライメントを自動的に検出する手法がいくつか 提案されている. Newsela Corpus の作成者[Xu 15]は、最もシン プルな文間の類似度計算手法として Jaccard similarity を使用 することを提案している. Jaccard similarity は以下の式で与えら れる.

$$Jaccard(X,Y) = \frac{count(X \cap Y)}{count(X \cup Y)}$$
(1)

また、平易化文ペア間の1対1関係のみではなく、1対Nや N対1の対応関係の検出に特化した Vicinity-driven sentence alignment が提案されている. Vicinity-driven sentence alignment は TF-IDF に基づいた手法であり、実際に Newsela Corpus の 自動アライメントに適用された研究が報告されている[Scarton 18]. しかしながら、パラフレーズや省略が頻繁に起こるテキスト 平易化では、単語頻度により意味的な類似度を計算することに は限界がある.

一方で、より深層の意味関係を推論するタスクにテキスト含意 認識がある.テキスト含意認識では、ある文のペアを含意、矛盾、 中立の3つの関係に分類する.

- Bob is in his room, but because of the thunder and lightning outside, he cannot sleep.
- Bob is awake.
- It is sunny outside.

例えば、最初の文章では、「he cannot sleep」から bob が起き ている状態が推論されるので、二つ目の「bob is awake」という文 意は最初の文意に含まれ、含意関係があると言える.一方で、最 後の文の「it is sunny outside」という内容は最初の文の「the thunder and lightning」という描写に相反するので、矛盾関係に あると結論できる.本研究では、テキスト平易化文ペアの検出に テキスト含意認識モデルを適用する.

## 3. Decomposable Attention Model(DAM)

Decomposable Attention Model (DAM)[Parikh 17]は、テキスト 含意認識を学習するニューラルネットワークモデルである. DAM は文間の意味推論をある単語レベルのアテンションに分解して、 最終的な含意関係の予測を行う. このモデルではまず、アテン ション機構を用いて 2 つの入力文 $S_{\alpha}[w_{\alpha 1}, \cdots w_{\alpha l}, \cdots w_{\alpha l_{\alpha}}],$  $S_{\beta}[w_{\beta 1}, \cdots w_{\beta j}, \cdots w_{\beta l_{\beta}}]中の単語間の注意重み<math>e_{ij}$ を計算する. その後,注意重みで単語分散表現 $\alpha_{i}$ 及び $\beta_{j}$ を獲得する.

$$\alpha_i = \sum_{i=1}^{l_a} \frac{\exp(e_{ij})}{\sum_{k=1}^{l_a} \exp(e_{ki})} \bar{a}_i \tag{2}$$

$$\beta_{j} = \sum_{j=1}^{l_{b}} \frac{\exp(e_{ij})}{\sum_{k=1}^{l_{b}} \exp(e_{kj})} \bar{b}_{j}$$
(3)

ここで,  $l_a$ ,  $l_b$ は文 $S_a$ ,  $S_\beta$ の単語長である. また,  $\bar{a}_i$ 及び $\bar{b}_j$ は, 各入力文中の単語に対する事前学習された単語分散表現であ る. [Parikh17]は, GloVe[Pennington 14]を単語分散表現の事前 学習手法として用いているが, 今回のモデルでは, ELMo[Peters 18]を使用する.

次に、2 つ入力文の単語分散表現 $\bar{a}_i$ 、 $\bar{b}_j \geq \alpha_j$ 、 $\beta_i \geq 0$ 間で意味 的関係をフィードフォワードネットGにより計算して、各単語と文 間の関係を表すベクトル $v_{a,i}$ 、 $v_{b,i}$ を求める.

$$v_{a,i} = G([\bar{a}_i, \beta_i]) \qquad (4)$$

$$v_{b,j} = G([\bar{b}_j, \alpha_j]) \qquad (5)$$

$$v_a = \sum_{\substack{i=1\\l_b}}^{l_a} v_{a,i} \qquad (6)$$

$$v_b = \sum_{\substack{j=1\\j=1}}^{l_b} v_{b,j} \qquad (7)$$

最終的に、フィードフォワードネットHにより、2つの文間の関係 を表すラベルyを出力する.

$$y = H([v_a, v_b])$$
(8)

この手法は、アテンションとフィードフォワードニューラルネット ワークに、単語分散表現の事前学習を組み合わせた単純なモ デルとなっており、従来の複雑なアーキテクチャに比べて少ない パラメータで学習することができる.

# 4. 実験

# 4.1 データセット

実験では、英語学習者向けのニュースサイト Breaking News English<sup>1</sup>から収集したマルチレベルの平易化テキストを用いる. Breaking News English は、easy タイプの記事(level 0, 1, 2, 3) と hard タイプの記事(level 4, 5, 6)から構成されている. 今回の 実験では、収集サンプルから平易化文ペアであるものと平易化 文ペアでないものを 50 ペアずつランダムに抽出し、計 100 事例 を用意した. easy タイプの記事からはレベル 0 と3 を、hard タイ プの記事からはレベル 4 と 6 の文を使用する. これらのペアに 人手でアノテーションを施すことで、モデルの平易化文ペア識 別性能をテストする. ベースラインには、Jaccard Similarity を用 いる. 各モデルの閾値は、[Xu 15]に従い 0.5 とする.

## 4.2 実験結果

実験結果を表1に示す.表1から, F値において, DAM が ベースラインを大きく上回っていることが分かる. 特に, Recall に おいて, Jaccard Similarity に大きな差をつけていることから, 平

<sup>&</sup>lt;sup>1</sup> https://breakingnewsenglish.com/

表1平易化文ペア特定の実験結果

|         | Recall | Precision | F値   |
|---------|--------|-----------|------|
| Jaccard | 0.36   | 1.00      | 0.52 |
| DAM     | 0.76   | 0.82      | 0.79 |

表2特定された平易化文ペアの例

# 元文

They said our sleeping brain is much more aware of the outside world than we thought.

# 平易化された文

The researchers said our sleeping brain is active.



図1単語間のアテンション

易化文ペア間の共通単語頻度などの表層的特徴だけでは捉え きれない含意関係の認識に成功していることが分かる.

一方で、Precision においては、Jaccard Similarity が DAM より も頑健な性能を示した.これは、ベースライン手法が文のペア間 で共通する単語の重なりが一定の割合以上観測されない場合 は全て負例に分類する方式であるためと考えられる.

実際に、Jaccard Similarity では検出に失敗したが、DAM によって検出に成功した平易化文ペアを表 2 に示す. この例では、 平易化において、パラフレーズが起きているものの、含意関係が 認識され検出に成功している. また図1に、単語間のアテンションの相関を示す. ここで、平易化された文中の"acitive"が元文 中の"much more aware"というフレーズに強く対応していることが わかる.

# 5. まとめ

本研究では、テキスト平易化のパラレルコーパス構築のため に、含意関係認識モデルを用いて、自動アライメントを行うことを 提案した.実験結果より、従来の手法よりも含意関係認識モデル がより意味的な関係性を捉え、平易化文ペアの高精度なアライ メントに貢献することがわかった.今後の課題の1つは、この枠組 みを利用して、実際に作成中のコーパスに自動的にアノテーションを付与する機構を構築することが必要である.

- [Nisioi 17] : Sergiu Nisioi, Sanja Stajner, Simone Paolo Ponzetto, Liviu P. Dinu: Exploring neural text simplification models, In Proceedings of ACL. 2017.
- [Xu 15] Wei Xu, Chris Callison-Burch, Courtney Napoles: Problems in Current Text Simplification Research: New Data Help, Transactions of the Association for Computational Linguistics, vol. 3, pp. 283–297, 2015.
- [Zhu 10] : Zhu Z, Bernhard D, Gurevych I: A monolingual treebased translation model for sentence simplification, In Proceedings of the 23rd International Conference on Computational Linguistics (COLING). 2010.
- [Scarton 18] Carolina Scarton, Gustavo Henrique Paetzold, Lucia Specia: Text Simplification from Professionally Produced Corpora, In proceedings of Irec, 2018.
- [Parikh 17] Ankur P. Parikh, Oscar Tackstrom, Dipanjan Das, Jakob Uszkoreit: A Decomposable Attention Model for Natural Language Inference, arXiv preprint:1606.01933, 2017.
- [Pennington 17] Jeffrey Pennington, Richard Socher, Christopher D. Manning: GloVe: Global Vectors for Word Representation, Proceedings of EMNLP, 2014.
- [Peters 18] Matthew E. Peters, Mark Neumann, Mohit Iyyer, Matt Gardner: Deep contextualized word representations, In NAACL, 2018.

# ココハドコ?: ユーザの位置が紐付いたウェブ検索履歴の解析

What's Here Like? Analysis of Web Search Log Based on User's Location

日暮 立\*1 坪内 孝太\*1 Tatsuru Higurashi

Kouta Tsubouchi

\*1ヤフー株式会社 Yahoo Japan Corporation

In recent years, with the spread of GPS-enabled mobile phones, a huge amount of users' historical location data is able to collect. Many studies on modeling with collected location data have been conducted. In this paper, we propose a new method to analyze the area characteristics based on user's web search query logs and location data. As a result of analyzing by the proposed system with various regions and periods, the feature of the area apper in users' search behavior.

#### はじめに 1.

近年, GPS 機能を搭載したモバイル端末の普及に伴い, 膨大 な量のモバイル端末位置履歴データが蓄積されてきている. モ バイル端末に蓄積された位置履歴データを用いて,都市の分析 を行う研究や、ユーザの特徴を解析する研究が盛んである.都 市の分析を行うことで、都市における需要把握などの都市計画 への応用が期待できる.本研究では位置履歴データを利用し, ユーザのウェブ検索行動から得られる都市や地域の特徴を解 析する. Yahoo! JAPAN アプリ利用者の位置履歴データと Yahoo!検索を利用したユーザの検索クエリログを用いて、地域 と期間を指定し機械学習により特徴的な検索ワードを推定する システムを提案する. 学習の結果得られる, 地域毎の検索クエ リの特徴を分析し、指定期間の違いによる検索クエリの重みの 変化から地域内で活動するユーザの興味の変化を分析する.

#### 2. 関連研究

位置履歴データを活用して人々の活動パターンを抽出して解 析する研究は数多くあり、パターン抽出結果を利用することで 都市ごとの特性を把握することができる. [Fan 14] らは1日ご との都市の活動人口のパターンが地域の性質を表現すること に着目し、位置履歴データからその代表的なパターンを抽出し た. [Nishi 14] らは階層ベイズによるモデリング手法を用いて 活動人口のパターン抽出を行なった. これらのパターン抽出の 取り組みを応用して [Shimosaka 15] らは曜日や天気といった 要因に対して変化する活動人口の予測に取り組み, [Okawa 17] らは路線毎の交通量予測という問題に取り組んだ. [Yabe 17] らは、位置履歴データから都市ごとの人々の活動パターンを抽 出し,都市の災害に対する頑強性を示した.

大規模な位置履歴データから都市の状態を把握する研究が盛 んであるが、一方でユーザ個々の位置履歴データに着目しユー ザを解析する研究も盛んである. [Wanaka 16] らは位置履歴 データからユーザの興味関心を推定する方法を提案した. 位置 履歴データからユーザ個人の状態を推定する研究は多いが,推 定の出力結果となるモデルがユーザの検索クエリで構成される 推定モデルに関する研究は我々の知る限り存在しない.

#### 3. 提案システム

本章では、位置履歴データからユーザの特徴的な検索クエリ を予測するためのシステムの説明を行う.本提案システムで は,任意の面積の地域と任意の期間を入力とし,地域の特徴を 現す検索クエリを出力とする.本システムは、地域と期間を入 力し、位置履歴データからユーザリストを抽出するユーザ抽出 部と,抽出した活動ユーザリストを入力して機械学習によって 特徴的な検索クエリを予測するクエリ学習部で構成される. 以 下に各システムの詳細を示す.

### 3.1 ユーザ抽出部

ユーザ抽出部は、地域と期間を入力とし地域内で活動する ユーザリストを取得する処理を行う.以後ユーザ抽出部で出力 するユーザを活動ユーザと呼ぶ. ユーザ抽出部では、任意の面 積の地域と任意の期間を入力とし、蓄積された位置履歴データ を元に入力した地域内の活動ユーザと活動ユーザの滞在スコア のリストを取得する.滞在スコアの計算は位置情報の精度を加 味するためにカーネル密度推定法による推定を行う. カーネル 密度推定法とは,密度を計算する地点を中心として任意に指定 した検索半径内の点密度を,計算地点からの距離減衰効果によ る重み付けを伴って計算する手法である.

あるユーザ蓄積されている位置履歴データのタイムスタン プを $T = \{t_1, t_2, ..., t_n\}$ とし, 時刻 $t_i$ の緯度を $x_{t_i}$ , 経度を $y_{t_i}$ , 位置情報の精度を at, とし, ユーザの位置履歴データの集合を  $D = \{(x_{t_i}, y_{t_i}, a_{t_i}) \mid t_i \in T\}$ とする. $(x_{t_i}, y_{t_i})$ が指定地域に 含まれる場合, ユーザの滞在スコアは1となる. (x<sub>ti</sub>, y<sub>ti</sub>) が指 定地域に含まれない場合,指定地域の中心点と (x<sub>ti</sub>, y<sub>ti</sub>)の距 離を dti とすると、ユーザの滞在スコアはカーネル密度推定法 により,

$$\begin{cases} \frac{1}{T} \sum_{i=1}^{T} K[\frac{d_{t_i}}{a_{t_i}}] & (a_{t_i} \ge h) \\ \frac{1}{T} \sum_{i=1}^{T} K[\frac{d_{t_i}}{h}] & (otherwize) \end{cases}$$
(1)

となる. dt. の計算はヒュベニの距離計算式を用い、カーネル密 度推定法のカーネル関数 K はガウス関数を採用した.h はバン ド幅である. 蓄積されているユーザの位置履歴データから点密 度を計算し、点密度が0より大きい上位のN件のユーザを活 動ユーザとして抽出する.

#### クエリ学習部 3.2

クエリ学習部では、ユーザ抽出部で抽出した活動ユーザリス トとユーザ抽出部で指定した期間を入力として、活動ユーザら

連絡先: 日暮 立, ヤフー株式会社, thiguras@yahoo-corp.jp 連絡先: 坪内 孝太, ヤフー株式会社, ktsubouc@yahoo-corp.jp



図 1: 提案システム概要

の特徴的な検索クエリを推定する. ユーザ抽出部にて出力した N 件の活動ユーザリストを  $U_{pos} = \{p_1, p_2, ... p_N\}$ とする.ま た,  $U_{pos}$  に含まれない,指定期間に Yahool検索を利用したユー ザをランダムに N 件サンプリングし、 $U_{neg} = \{n_1, n_2, ... n_N\}$ とする.

ユーザ  $p_i \geq n_i$  が指定期間に Yahoo!検索にて検索を行なった検索クエリのリストを検索クエリログ蓄積サーバから取得し,取得した検索クエリの総数を Q とする. 各ユーザ  $p_i \geq n_i$ が,指定期間に検索したクエリは 1, それ以外のクエリを 0 とする Q 次元の one-hot ベクトル  $v \in \{0,1\}^Q$  を特徴量ベクトルとする. ユーザ抽出部によって抽出した活動ユーザリスト  $U_{pos}$  を元に生成した特徴量ベクトルの集合  $D_{pos} = \{v_{p_i} \mid p_i \in U_{pos}\}$  を学習データの正例とし, ランダムにサンプリングしたユーザリスト  $U_{neg}$  を元に生成した特徴量ベクトル v の集合  $D_{neg} = \{v_{n_i} \mid n_i \in U_{neg}\}$  を学習データの負例とする.

生成した正例 *D*<sub>pos</sub> と負例 *D*<sub>neg</sub> を学習データとし,LIBLIN-EAR<sup>\*1</sup> を使用した二値分類学習を行う.学習の結果の学習モ デルから得られる,*Q* 個の素性として入力された検索クエリと その重みを出力する.学習の正規化パラメータ*C* は交差確認 でパラメータ探索を行い,精度が最も良くなる*C* を採用するよ うにしている.

重みが高い素性は指定した地域内の活動ユーザ U<sub>pos</sub> が特徴 的に検索している検索クエリであることがわかり, 重みが低い 素性はユーザ U<sub>neg</sub> が特徴的に検索している検索クエリである ことがわかる.

# 4. データ

本章では,提案システムで使用するデータに関する詳細を 示す.

ユーザ抽出部にて利用した位置履歴データは、Yahoo! JAPAN アプリ\*<sup>2</sup> を Andorid また iOS のスマートフォンに インストールし, 位置情報を利用したサービス提供を受けるた めに「位置情報に基づいたコンテンツを表示する」という項目 をオンにした Yahoo! JAPAN ID ログインユーザのデータを 利用した.データはタイムスタンプと緯度経度と位置情報の精 度の情報を持ち, 日本全国のユーザから取得されている.デー タは基本的に移動している状態の端末や基地局が切り替わった 端末から取得されるため, 人々の動きを表したデータと言える. スマートフォンで取得した位置履歴データは個人の位置の正確 な特定を避けるために 100m メッシュデータに変換している. 利用時には k-匿名性を担保するため提案システムの抽出部に おいて抽出人数には制限をかけている.

Android 端末のスマートフォンと iOS 端末のスマートフォンは位置情報の取得頻度が異なる.提案システムで利用する位置履歴データのタイムスタンプの間隔を共通化するために位置履歴データの内挿を行う.あるユーザの位置履歴データのタイムスタンプを t, 緯度を x, 経度を y, 精度を a とし, 連続して蓄積された  $t_0 < t_1$  となる履歴データをそれぞれ  $(t_0, x_0, y_0, a_0)$ ,  $(t_1, x_1, y_1, a_1)$ とする. S を 0 より大きい任意の秒数として  $t_1 - t_0 > S$  の時, 線形補間を行う. S はシステム内で定義されるハイパーパラメータである.  $\{i \in \mathbb{N} \mid i < (t_1 - t_0)/S\}$  に対して, タイムスタンプが  $t_i = t_0 + S * i$ 時の内挿データの  $x_i, y_i, a_i$  は以下のように算出される.

$$x_i = x_0 + (x_1 - x_0) * \frac{t_i - t_0}{t_1 - t_0}$$
(2)

$$y_i = y_0 + (y_1 - y_0) * \frac{t_i - t_0}{t_1 - t_0}$$
(3)

$$a_i = a_0 + (a_1 - a_0) * \frac{t_i - t_0}{t_1 - t_0}$$
(4)

クエリ学習部にて利用しているユーザの検索データは, ウェ ブブラウザもしくは携帯端末にインストールされているアプリ で利用された Yahoo! JAPAN ID ログインユーザの Yahoo! 検索 \*<sup>3</sup> のログを利用した.

# 5. 実験と結果

実験では S = 300 として内挿を行なった位置履歴データを 利用した.提案システムのユーザ抽出部において, カーネル密 度推定法のバンド幅 h = 250, 抽出数 N = 3000 として活動 ユーザを抽出し, クエリ学習部に使用した. 3 つのケースにつ いて,提案システムによる解析例を以下に示す.

### 5.1 北海道地震(北海道厚真町)

表1の例は,北海道勇払郡厚真町を含む1600km<sup>2</sup>の地域を 指定し,2018年9月6日の4時から2018年9月7日の17時 の期間を指定して提案システムによる学習を行った時の重みが 上位の素性と重みが下位の素性の一部である.2018年9月6 日の3時7分には,北海道胆振地方中東部を震源として地震が 発生しており,厚真町では最大震度7が観測されている.

<sup>\*1</sup> https://www.csie.ntu.edu.tw/ cjlin/liblinear/

<sup>\*2</sup> https://promo-mobile.yahoo.co.jp/yjapp/

<sup>\*3</sup> https://search.yahoo.co.jp/

表 1: 厚真町に滞在していたのユーザのクエリ

| 重みが高い検索ク  | エリ    | 重みが低い検索 | ミクエリ   |
|-----------|-------|---------|--------|
| 検索クエリ     | 重み    | 検索クエリ   | 重み     |
| 新千歳空港     | 1.529 | 地下鉄     | -2.57  |
| 道路交通情報    | 1.426 | 意味      | -2.118 |
| ラジコ       | 1.408 | 旭川      | -1.779 |
| 運行状況      | 1.353 | iphone  | -1.397 |
| ガソリンスタンド  | 1.238 | ユーチューブ  | -1.386 |
| 北海道電力     | 1.232 | 吉澤ひとみ   | -1.343 |
| 苫小牧市停電情報  | 1.198 | au      | -1.249 |
| 鍋でご飯を炊く方法 | 0.97  | おしゃれ    | -1.242 |

学習結果から,指定した期間に北海道厚真町周辺に住む住民 は「道路交通情報」,「ガソリンスタンド」や「北海道電力」な どの検索クエリの重みが強く,災害時にはこれらの情報を特に 必要としていることがわかり,一方で「iphone」「ユーチュー ブ」「おしゃれ」などの日常の娯楽を連想させる検索クエリは 重みが低く,このような情報は災害時には特に必要としていな いということがわかる.実験から,提案システムによる検索ク エリを予測することで,指定地域の災害状況を把握し住民が被 災時にどのような状態かを素早く判断することができる.

## 5.2 安室奈美恵ライブ (沖縄県)

表2は沖縄県本島全域を含むを8400km<sup>2</sup>を地域として指定 し,指定期間を変化させた時の提案システムによる学習を行っ た時の重みが上位の素性の一部である. 指定期間はそれぞれ 2018年9月12日,2018年9月15日,2018年9月18日から 1日間である.沖縄県では歌手の安室奈美恵が引退ライブを 2018年9月15日に行なっており,表2ではすべての日に「安 室奈美恵」という素性が重みが高く、ライブに関する特徴がす べての日に現れている. 各日付の「安室奈美恵」という検索ク エリの重みに注目すると、ライブの前からライブ当日に向けて 「安室奈美恵」という素性の重みは高く現れているが、ライブ 終了後は重みが低くなっている.一方で「沖縄」のような地名 を表す重みは指定期間の影響を受けることなく、常に高い重み で現れている. 提案システムの出力結果からはイベントによる 瞬間的に現れる検索クエリと,常時現れている検索クエリが存 在することがわかる.瞬間的に現れる検索クエリを分析するこ とで指定地域内のユーザの興味の変遷の把握が期待でき,常時 現れる検索クエリを分析することで指定地域の特性の把握が期 待できる.

# 5.3 東京ドームのイベント (東京都)

表3,表4,表5は東京ドームを含む地域0.1km<sup>2</sup>を指定し, 指定期間を変化させた時の提案システムによる学習を行った時 の重みが上位の素性の一部である.

指定期間はそれぞれ, 2018 年 11 月 17 日から 2019 年 1 月 20 日の間の土日の 2 日間である.東京ドームでは週末には様々 イベントが開催されており,アニメ「ラブライブ!サンシャイ ン!!」の音楽イベントやアイドルグループ「嵐」「Kis-My-Ft2」 「SUPER JUNIOR」のドームライブ<sup>\*4</sup>,また音楽イベント以 外にも全国の祭りとご当地の食を堪能できる「ふるさと祭り 2019」<sup>\*5</sup>、野球のファンイベント<sup>\*6</sup>、プロレスイベント<sup>\*7</sup>が 行われていた.提案システムによって出力される検索クエリを 考察すると、東京ドーム周辺の地名以外に開催されているイベ ントに関連する検索クエリが特徴として現れている.提案シス テムによって出力される検索クエリから、指定した地域で行わ れているイベントを推定することが可能であることがわかる. また、表4のふるさと祭り東京の結果では「座席表」「時刻表」 という検索クエリが特徴として強く現れている.ふるさと祭り 東京は全国の祭りと食を堪能できるイベントとなっているた め、全国から来場者が訪れる.来場者が全国各地から東京ドー ムに訪れる際に、新幹線や特急列車を利用している可能性が高 いことが結果から考がえられる.このように、本提案システム からは、イベント抽出以外にも移動経路や移動方法の分析も期 待できる.

## 6. まとめ

本論文では、Yahoo! JAPAN アプリを利用しているユーザ の携帯端末の位置履歴データを利用して指定地域の活動ユーザ を抽出し、ユーザの検索クエリを特徴量としてロジスティック 回帰により学習することで、指定地域の特徴的なウェブ検索ク エリを学習するシステムを提案した.様々な指定地域に対して 提案システムによる分析を行なった結果、指定した地域にて行 われたイベントに関する検索行動が検索クエリに現れることが 示された.またイベント以外にも、指定地域で活動ユーザが必 要としている情報を検索クエリから抽出することが可能である ことがわかった.同じ指定地域において指定期間を変化させた ところ、提案システムによって抽出された検索クエリの重みを 比較することで、指定地域の活動ユーザの興味の変化を推定す ることが可能であることが示された.

地域ごとのウェブ検索クエリの解析の結果は、リスティング 広告などのインターネット広告の配信への応用が期待される. 今後は提案システムによって出力された地域毎のウェブ検索ク エリモデルの実活用とその効果の検証を検討したい.

- [Fan 14] Fan, Z., Song, X., and Shibasaki, R.: CitySpectrum: A non-negative tensor factorization approach, UbiComp (2014)
- [Nishi 14] Nishi, K., Tsubouchi, K., and Shimosaka, M.: Extracting Land-use Patterns Using Location Data from Smartphones, URB-IOT (2014)
- [Okawa 17] Okawa, M., Kim, H., and Toda, H.: Online Traffic Flow Prediction Using Convolved Bilinear Poisson Regression, MDM (2017)
- [Shimosaka 15] Shimosaka, M., Maeda, K., Tsukiji, T., and Tsubouchi, K.: Forecasting Urban Dynamics with Mobility Logs by Bilinear Poisson Regression, UbiComp (2015)
- [Wanaka 16] Wanaka, S. and Tsubouchi, K.: Location History Knows What You Like: Estimation of User Preference from Daily Location Movement, Urb-IoT (2016)
- [Yabe 17] Yabe, T., Tsubouchi, K., and Sekimoto, Y.: CityFlowFragility: Measuring the Fragility of People Flow in Cities to Disasters Using GPS Data Collected from Smartphones, Ubicomp (2017)

<sup>\*4</sup> https://www.tokyo-dome.co.jp/dome/event/artist/

<sup>\*5</sup> https://www.tokyo-dome.co.jp/furusato/

<sup>\*6</sup> http://meikyu-kai.org/bf2018/

<sup>\*7</sup> https://www.njpw.co.jp/tornament/163210

| 安室奈美恵のラ | ライブ3日前 | 安室奈美恵のライブ当日 |       | 目前   安室奈美恵のライブ当日   安室湾 |       | 安室奈美恵のラ | ・イブ3日後 |
|---------|--------|-------------|-------|------------------------|-------|---------|--------|
| 検索クエリ   | 重み     | 検索クエリ       | 重み    | 検索クエリ                  | 重み    |         |        |
| 沖縄      | 3.108  | 沖縄          | 3.644 | 沖縄                     | 2.711 |         |        |
| 安室奈美恵   | 1.411  | 那覇          | 2.555 | 沖縄県                    | 0.849 |         |        |
| 那覇      | 1.17   | 那覇市         | 1.772 | 古賀淳也                   | 0.763 |         |        |
| 那覇市     | 0.763  | 安室奈美恵       | 1.769 | 那覇市                    | 0.445 |         |        |
| 沖縄県     | 0.672  | ほっともっと      | 1.757 | 那覇                     | 0.417 |         |        |
| 直接謝罪    | 0.67   | 宜野湾         | 1.596 | 沖縄市                    | 0.157 |         |        |
| 台風情報    | 0.404  | 地震速報        | 1.388 | 山本 kid 徳郁              | 0.116 |         |        |
| 沖縄宝島    | 0.351  | 読谷          | 1.38  | 沖縄タイムス                 | 0.116 |         |        |
| 巨人杉内    | 0.335  | 今週の急上昇ワード   | 1.344 | 安室奈美恵                  | 0.041 |         |        |
| ひびきわたる  | 0.202  | 浦添          | 1.189 | 琉球新報                   | 0.035 |         |        |

表 2: 沖縄に訪れたユーザの検索クエリ

表 3: 東京ドームを訪れたユーザの検索クエリ (2018 年 11 月付近)

| ラブライブ音楽イベント | 野球のファンイベント      | SUPER JUNIOR のライブ |
|-------------|-----------------|-------------------|
| ラブライブサンシャイン | 名球会フェスティバル 2018 | 新宿                |
| 東京ドーム       | 東京              | super             |
| ラブライブ       | 東京ドーム           | 東京ドーム             |
| aqours      | 池袋              | 東京                |
| 新宿          | jra             | 水道橋               |
| アクセス        | アクセス            | 池袋                |
| 東京          | 銀座              | 死去                |
| 文京区         | 上野              | 今週の急上昇ワード         |
| 秋葉原         | 死去              | 渋谷                |
| 紅白          | 名球会             | 秋葉原               |

表 4: 東京ドームを訪れたユーザの検索クエリ (2018 年 12 月付近)

| 嵐のライブ     | Kis-My-Ft2 のライブ | 嵐のライブ     |
|-----------|-----------------|-----------|
| 嵐         | キスマイ            | 東京ドーム     |
| 東京ドーム     | 東京ドーム           | 嵐         |
| 銀座        | アクセス            | 銀座        |
| 今週の急上昇ワード | 東京              | 神楽坂       |
| 池袋        | 秋葉原             | 水道橋       |
| 水道橋       | 東京駅             | 東京        |
| ヌード       | 池袋              | みずほ銀行     |
| 東京        | 大恋愛             | 浅草        |
| 浅草        | 新宿              | 今週の急上昇ワード |
| 東京駅       | 千葉              | 鶯谷        |

表 5: 東京ドームを訪れたユーザの検索クエリ (2019 年 1 月付近)

| 新日本プロレス興行 | ふるさと祭り        | ふるさと祭り        |
|-----------|---------------|---------------|
| 東京ドーム     | ふるさと祭り東京 2019 | ふるさと祭り東京 2019 |
| 池袋        | 東京ドーム         | 銀座            |
| news      | 新宿            | 新宿            |
| 祝日        | 今週の急上昇ワード     | 時刻表           |
| 東京        | アクセス          | 悲痛コメント        |
| 新日本プロレス   | 池袋            | 渋谷            |
| 東京ドームシティ  | 天地総子          | ランチ           |
| 高校サッカー    | 東京            | 座席表           |
| 箱根駅伝      | 北千住           | 東京ドーム         |
| 上野        | 東京駅           | 浅草            |

# ニュースサイト閲覧者の興味関心を用いた 地域と観光要素の関連性抽出

Extraction of Relevance between Regions and Domestic Enjoyments based on News Site App Users' Interest

| 川口輝太 *1*2      | 井上裁都 *2         | 長田誠也 * <sup>2</sup> | 山下達雄 *2          |
|----------------|-----------------|---------------------|------------------|
| Kota Kawaguchi | Tatsukuni Inoue | Seiya Osada         | Tatsuo Yamashita |

\*<sup>1</sup>筑波大学大学院 システム情報工学研究科 \*<sup>2</sup>ヤフー株式会社 Graduate School of Systems and Information Engineering, University of Tsukuba Yahoo Japan Corporation

We proposed a method to discover domestic enjoyments information that are specific and original to individual domestic area. The proposed method is based on article follow information of news site users and themes given to articles. We extracted the relationship between regional theme and sightseeing theme using co-occurrence information of themes in each article. In addition, We pulled out the relationship between regional theme and sightseeing theme using theme and sightseeing theme using themes actively selected by the user for personalization. By filtering with similarities between those two types of relevance, accuracy improvement was achieved. Moreover, by focusing on sightseeing theme with low similarity, error candidates for theme linking can be extracted.

# 1. はじめに

地域活性化のために,我が国の重要な成長分野である観光 に注目が集まってきている.日本政府観光局の資料によると, 2018年は年間の訪日外国人数が 3119万人と過去最高を記録 した [1].産業の観光化を推進するにあたり,観光地として訴 求すべき観光コンテンツを正確に把握することは,地域への 観光誘致のために重要であり,種々の研究がおこなわれてい る [2] [3].

本研究では、実際のユーザの行動データを使って、各地域 と観光要素の紐付けを行い、地域ごとの観光要素のクラスタ を抽出することを目的とする.分析対象として、ニュースサイ ト「Yahoo!ニュース」[4] を用いた.Yahoo!ニュースの閲覧者 は、興味のある地域や娯楽のテーマをフォローすることで、そ のテーマが紐付けられた記事を優先的に閲覧できる.そこで、 ニュース閲覧者の興味対象のテーマと実際の記事に付与されて いるテーマを併用した、観光要素別の地域ランキングと地域別 観光要素ランキングの作成手法を提案する.

### 2. Yahoo!ニュースとテーマ

本研究でのターゲットである,Yahoo!ニュースについて説 明する.Yahoo!ニュースは,新聞・通信社が配信する報道をは じめ,個人により執筆された記事や話題の動画,写真などを, ウェブサイトとアプリを通じて,提供するサービスである [4]. Yahoo!ニュースで用いられる「テーマ」とは,サービス側が 事前に定義した興味関心の単位である.記事には複数のテー マが自動的に付与される.例えば,青森ねぶた祭りに関する記 事は,「祭りと伝統行事」,「青森市」,「青森ねぶた祭り」など のテーマが付与される.これにより,ユーザはテーマ別に記事 を閲覧できる.ユーザが上記のテーマを選択することを「フォ ロー」と呼ぶ.ユーザが各テーマをフォローをすることで,そ のテーマが紐付けられた記事を優先的に閲覧できる.図1に ニュース閲覧者とテーマと記事の関係を示す.

### 3. 地域テーマと観光テーマの関連性

本章では、「地域テーマ」と「観光テーマ」の関連性につい て述べる.地域テーマとは各都道府県と市区町村のテーマ、観

連絡先: \*1s1820785@s.tsukuba.ac.jp, \*2{tatinoue, sosada, tayamash} @yahoo-corp.jp

光テーマとは観光に関するテーマである.この二つの集合の各 要素同士のつながりを明らかにすることで、地域ごとの特徴的 な観光要素や観光要素ごとの特徴的な地域を抽出できると考 える.これらのテーマ間の関連性を取り出すにあたり、ユーザ がフォローするテーマ、記事に付与されるテーマの2種類の データセットを用いた.

# 3.1 ユーザがフォローするテーマ

各ユーザがフォローする複数のテーマに着目した.ユーザが フォローするテーマはそのユーザの嗜好を反映している.その ため、同時にフォローされる複数のテーマはそれぞれに関連性 を持つと言える.後述の手法により関連度を計算し、地域と観 光要素のつながりを明らかにしていく.以下このテーマをユー ザ由来テーマと呼ぶ.

### 3.2 記事に付与されるテーマ

次に配信される記事に同時に付与される複数のテーマに着目 した.ニュース記事には,機械学習や言語処理技術(エンティ ティリンキング等 [5])を用いて複数のテーマを付与している. 各記事に付与された地域テーマと観光テーマの共起を調べるこ とにより,それらの関連性が分かる.以下このテーマを記事由 来テーマと呼ぶ.

### **3.3** 関連性の意味

ここで関連性の意味について議論する必要がある.地域テーマをフォローするユーザは,その地域について興味を持つユー ザではあるが,その興味を分類すると少なくとも次の2種類 がある.

1. 地元民:その地域に住んでいる・係わりの深いユーザ

2. 観光民:その地域に観光等で行きたいユーザ

例えば、地域テーマ「渋谷区」と観光テーマ「スキー」を同時にフォローしているユーザがいるとする.渋谷区にはスキー を行う場所がないので、このユーザは1の地元民であると考 えられる.そのため「渋谷区」と「スキー」の関連性は低くな るべきである.また、地域テーマ「長野県」と観光テーマ「ス キー」を同時にフォローしているユーザの場合、「長野県」で 「スキー」はメジャーであるため、このユーザは2の観光民の 可能性が高い.そのため「長野県」と「スキー」の関連性は高 くなるべきである.一方、地域テーマが付与された記事は、基



図 1: ニュース閲覧者とテーマと記事の関係



図 2: ユーザのフォローによるテーマ間の類似度の算出方法例

本的にその地域の話題であり、同時に付与された観光テーマが あればそれはその地域での観光要素であると言える。例えば、 長野県でのスキー大会のニュース記事に、「長野県」「スキー」 の両テーマが付与された場合、これらの関連性は高いと言え る.ユーザのフォローするテーマのときとは異なり、記事に付 与された地域テーマと観光テーマの関連性は高くなる.

### 3.4 ユーザと記事におけるテーマ間関係の差

ユーザがフォローするユーザ由来テーマ,および,記事に付 与される記事由来テーマから,それぞれ地域・観光間の関連性 を得ることができる.ここで,テーマ間の関連度がユーザ由来 と記事由来とでの間でかけ離れていた場合,少なくとも下記の 2つの可能性がある.

1. 誤った関連

2. ユーザの嗜好と供給されている記事とのミスマッチ

1 は、3.3 節の例で挙げた、ユーザ由来のデータから得られた 「渋谷」と「スキー」のような、地域と観光要素の本来の組み 合わせでないケースである.2 は、ある地域テーマとある観光 テーマの関連性が、ユーザ由来では高く、記事由来では低い場 合、ユーザの需要に対してニュース記事が供給不足の可能性が ある.これらを実際の分析結果から確認する.

## 4. 関連性の抽出手法

本章では、地域テーマと観光テーマの関連性を明らかにする ための関連度の計算方法について述べる.

### 4.1 抽出対象テーマの選択

関連性の抽出対象である地域テーマと観光テーマの選択手順 について説明する.地域テーマは、47都道府県+52市区町村 の計99テーマを人手で選定した.この52市区町村は、観光 に強く関連すると考えられる市区町村を主観に基づいて選定 した.これらの地域テーマをフォローしているユーザが同時に フォローしているテーマの中から,旅・レジャー・観光に関す る,フォロー数が145以上の160件を「観光テーマ」とした. 表1に地域テーマと観光テーマの一例を示す.観光テーマの 中には,移動手段などの間接的に観光と関係するテーマも含ま れている.

### **4.2** 関連度の計算

地域テーマ集合と観光テーマ集合のそれぞれのテーマ同士の 関連度を計算する. 関連度の計算には、Simpson 係数を採用 した (図 2). 集合 X と集合 Y の間の Simpson 係数は、下記 の式によって定義される [6].

$$Simpson(X, Y) = \frac{|X \cap Y|}{min(|X|, |Y|)}$$

例えば、ユーザ由来テーマを用いる場合、「X = 長野県」「Y = スキー」とすると、|X|は地域テーマ「長野県」をフォローしているユーザ数、|Y|は観光テーマ「スキー」をフォローしているユーザ数、 $|X \cap Y|$ は「長野県」と「スキー」を両方フォローしているユーザ数となる.また、記事由来テーマを用いる場合、同じく「X = 長野県」「Y = スキー」とすると、|X|は地域テーマ「長野県」が付与された記事数、|Y|は観光テーマ「スキー」が付与された記事数、 $|X \cap Y|$ は「長野県」と「スキー」の両方が付与された記事数となる.

### 5. 関連性の抽出

関連性の抽出にあたって,2018年11月8日時点のユーザ のフォローデータを使用した.対象ユーザ数は約1000万人で あった.ニュース記事は,2018年12月に配信された中から約

表 1: 地域テーマ,観光テーマの一例

| 地域テーマ例                 | 観光テーマ例                          |
|------------------------|---------------------------------|
| 軽井沢市,日光市,さいたま市,相模原市,   | 航空業界,東京ディズニーリゾート,全日本空輸(ANA),    |
| 新潟市, 倉敷市, 函館市, 川越市,    | 日本航空(JAL), ユニバーサル・スタジオ・ジャパン,    |
| 横須賀市, 西表島, 釧路市, 花巻市,   | 旅行・宿泊(国内), 温泉, 釣り, 釣り情報, アウトドア, |
| 祗園,難波,松山市,久留米市,佐世保市, … | キャンプ場, オリエンタルランド, 登山家, 旅行・宿泊,   |
| 計 99 テーマ               | 計 160 テーマ                       |

表 2: ユーザ由来のデータを用いた観光テーマ毎の関連度上位 の地域 (括弧内の数字は関連度)

| テーマ名/関連度  | 1位          | 2位          | 3位           |
|-----------|-------------|-------------|--------------|
| スコア上位 3 位 |             |             |              |
| 地域        |             |             |              |
| 温泉        | 東京都 (0.196) | 箱根町 (0.175) | 熱海市 (0.174)  |
| 民泊        | 京都市 (0.236) | 東京都 (0.236) | 京都府 (0.194)  |
| パワースポット   | 京都市 (0.134) | 京都府 (0.119) | 大阪府 (0.104)  |
| グランピング    | 北海道 (0.196) | 兵庫県 (0.196) | 京都府 (0.176)  |
| スキューバダイビ  | 石垣島 (0.167) | 東京都 (0.167) | 北海道 (0.167)  |
| ング        |             |             |              |
| 日本庭園      | 京都市 (0.438) | 大阪市 (0.250) | 京都府 (0.250)  |
| シュノーケリング  | 沖縄県 (0.462) | 石垣島 (0.308) | 名古屋市 (0.308) |
| 平等院       | 京都府 (0.500) | 京都市 (0.500) | 祇園 (0.313)   |
| グリーンツーリ   | 北海道 (0.500) | 山梨県 (0.500) | 宮崎県 (0.500)  |
| ズム        |             |             |              |
| 宿坊        | 京都府 (0.500) | 山梨県 (0.250) | 長野県 (0.250)  |

4000 件を使用した.

表 2 と表 3 にユーザ由来,記事由来における観光テーマ毎 の地域ランキングを示す.

表2では「温泉」に対して「箱根町」「熱海市」,表3でも 「大分県」「群馬県」といった温泉地として有名な観光地が抽出 できた.また「宿坊」については,表2/表3ともに関連性が 高い「京都市」が抽出できた.表4と表5に地域毎の観光要 素ランキングを示す.表4では「宮崎県」に対して「海水浴」, 「北海道」に対して「トロッコ列車」,表5では「京都市」に 対して「紅葉」などの妥当な組み合わせが抽出できた.

### 6. ユーザ由来と記事由来テーマ間の類似度

記事由来テーマ間の関連性は、システムが自動的に記事に 付与するテーマに基づくものであり、実際に配信された記事の 中身に基づく.一方、ユーザ由来テーマ間の関連性は、ユーザ のニュースに対する興味関心に基づくものである.これら記事 由来とユーザ由来の観光テーマを比較するための手法を述べ る.5.章で得られた、観光テーマ毎の地域ランキング(表 2, 表 3)データに着目する.各観光テーマは、地域テーマを要素 としたベクトルを持つ.各地域テーマは各観光テーマとの関連 度を持っている.これをここでは、観光地域ベクトルと呼ぶこ ととする. ni は、ユーザ由来のデータによる観光地域ベクトル ル、ng は、記事由来のデータによる観光地域ベクトルである. 観光地域ベクトル毎に、ユーザ由来テーマと記事由来テーマ間 の類似度を算出した.類似度尺度には、cos 類似度を用いた. cos 類似度は次のように定義される [6].

$$\cos(\vec{v_1}, \vec{v_2}) = \frac{\vec{v_1} \cdot \vec{v_2}}{|\vec{v_1}| |\vec{v_2}|}$$

| 表 3: | 記事由来のデータを用いた観 | 光テーマ | ,毎の関連度 | 上位の |
|------|---------------|------|--------|-----|
| 地域   | (括弧内の数字は関連度)  |      |        |     |

| × . 4 /m +++ | · //·         | - 11-        | ~ /I:         |
|--------------|---------------|--------------|---------------|
| テーマ名/関連度     | 1位            | 2 位          | 3位.           |
| スコア上位 3 位    |               |              |               |
| 地域           |               |              |               |
| クルーズ客船       | 小樽市 (0.333)   | 長崎市 (0.222)  | 鹿児島県 (0.167)  |
| トレッキング       | さいたま市 (0.375) | 屋久島 (0.250)  | 岩手県 (0.125)   |
| パワースポット      | 宮崎市 (0.200)   | 川越市 (0.167)  | 宮崎県 (0.125)   |
| 宿坊           | 京都市 (0.667)   | 祇園 (0.500)   | 大阪市 (0.333)   |
| キャンプ         | 宮崎市 (0.200)   | 宮崎県 (0.125)  | 金沢市 (0.067)   |
| 日本庭園         | 神戸市 (0.222)   | 長崎市 (0.111)  | さいたま市 (0.071) |
| 釣り           | 沼津市 (0.500)   | 相模原市 (0.125) | 兵庫県 (0.111)   |
| 民泊           | 新潟県 (0.222)   | 新潟市 (0.200)  | 北海道 (0.187)   |
| 日本の観光列車      | 北海道 (0.333)   | 北九州市 (0.167) | 札幌市 (0.067)   |
| スキューバダイビ     | 大阪市 (0.219)   | 高知件 (0.167)  | 富山県 (0.063)   |
| ング           |               |              |               |
| 温泉           | 日光市 (0.857)   | 大分県 (0.650)  | 群馬県 (0.622)   |

v1 と v2 の次元数は、地域テーマの数、つまり、99 である.

# 7. 観光テーマ別地域ランキングの評価

観光テーマを中心に関連する地域テーマが正しく抽出できた か評価を行った.

### 7.1 評価用データ

評価対象は前述の観光テーマ 160 件のうち,10 記事以上に 付与された 71 テーマとした.記事由来とユーザ由来,それぞ れにおいて,観光テーマ別地域ランキングの TOP3 にその観 光テーマで有名な地域が入っているか否かの 2 値のラベル付 けの作業を行った.作業は 2 名で行い,ラベルが一致したテー マのみを評価に用いた.そのうち,ラベルが positive なもの を正例とした.記事由来は正例 34 件,負例 16 件,ユーザ由 来では正例 37 件,負例 11 件であった.

### 7.2 評価結果

観光テーマ別地域ランキングの記事由来での評価 (article theme) と,ユーザ由来での評価 (follow theme) を図 3 に示 す. 6. 章で得られた cos 類似度に下限値を設けて,下限値以 上での判定結果における再現率,適合率をプロットした.ユー ザ由来と記事由来の類似度でフィルタリングしないときの精度 はグラフ上, *Recall* = 1 に対応する *Precision* であり,この 時のユーザ由来と記事由来の *Precision* は,それぞれ 0.771, 0.680 であった.ユーザの嗜好を直接反映していると考えられ るユーザ由来の精度が,両手法の類似度でフィルタリングする ことで,向上している.記事由来でもフィルタリングによる精 度の向上が見られるが,ユーザ由来の精度には及ばないことが わかる.

### 8. ユーザ由来と記事由来テーマの差異分析

7.2 節で述べたように記事由来とユーザ由来の間で類似度 が低いテーマをフィルタリングすると適合率が向上する.そこ で,類似度が低い観光テーマについて,個別のテーマ毎に3.4

| <ul><li>デーマ名/</li><li>関連度</li><li>上位3件</li></ul> | 1位                | 2位                | 3位                |
|--|-------------------|-------------------|-------------------|
| 北海道  | トロッコ列車 (0.556)    | グリーンツーリズム (0.500) | 隠れ宿 (0.304)       |
| 静岡県  | 富士山 (0.272)       | カヌー (0.200)       | フライフィッシング (0.188) |
| 京都府  | 宿坊 (0.500)        | 日本庭園 (0.250)      | グリーンツーリズム (0.250) |
| 宮城県  | 海水浴 (0.304)       | カヌー (0.200)       | シュノーケリング (0.154)  |
| 大阪市  | 観光競争力 (0.281)     | 海水浴 (0.217)       | 日本庭園 (0.125)      |
| 長野県  | しなの鉄道 (0.667)     | グリーンツーリズム (0.250) | 宿坊 (0.250)        |
| 山梨県  | グリーンツーリズム (0.500) | 宿坊 (0.250)        | トロッコ列車 (0.222)    |
| 金沢市  | 隠れ宿 (0.087)       | リアル脱出ゲーム (0.083)  | 鮎釣り (0.071)       |
| 宮崎市  | キャンプ (0.118)      | 鮎釣り (0.071)       | フライフィッシング (0.063) |
| 青森市  | 青森ねぶた祭り (0.353)   | 鮎釣り (0.071)       | 温泉 (0.051)        |
| 佐世保市   | カヌー (0.200)       | フライフィッシング (0.063) | 海水浴 (0.043)       |
| 沼津市  | フライフィッシング (0.125) | 釣り大会 (0.105)      | ワカサギ釣り (0.091)    |
| 熱海市  | 温泉 (0.174)        | 隠れ宿 (0.087)       | 秘湯 (0.087)        |
| 箱根町  | 温泉 (0.175)        | 紅葉 (0.100)        | 秘湯 (0.075)        |
| 日光市  | 温泉 (0.083)        | 日本の観光列車 (0.083)   | リアル脱出ゲーム (0.083)  |

表 4: ユーザ由来のデータを用いた地域テーマ毎の関連度上位の観光テーマ (括弧内の数字は関連度)

表 5: 記事由来のデータを用いた地域テーマ毎の関連度上位の 観光テーマ (括弧内の数字は関連度)

|                      | (                | /            |                  |
|----------------------|------------------|--------------|------------------|
| テーマ名/<br>類似度<br>上位3件 | 1位               | 2位           | 3位               |
| 大分県                  | 温泉 (0.650)       | 土産 (0.100)   | 温泉宿 (0.100)      |
| 金沢市                  | 土産 (0.267)       | 紅葉 (0.267)   | はとバス (0.167)     |
| 滋賀県                  | 紅葉 (0.316)       | 鮎釣り (0.286)  | 土産 (0.105)       |
| 群馬県                  | 温泉 (0.622)       | 秘湯 (0.333)   | 温泉宿 (0.077)      |
| 京都市                  | 宿坊 (0.667)       | 紅葉 (0.250)   | グリーンツーリズム (0.25) |
| 北海道                  | ワカサギ釣り (1.000)   | 鉄道旅行 (0.600) | 日本の観光列車 (0.333)  |
| 兵庫県                  | バーベキュー (0.333)   | 温泉 (0.270)   | 渓流釣り (0.222)     |
| 山梨県                  | 富士急ハイランド (0.667) | 富士山 (0.490)  | 渓流釣り (0.222)     |
| 大阪市                  | 天王寺動物園 (0.9)     | ユニバーサル・スタジオ・ | 宿坊 (0.333)       |
|                      |                  | ジャパン (0.608) |                  |

節であげた項目を検証した.

### 誤った関連

### 例1:「東京都」「温泉」のような明らかな誤り

「東京都」と「温泉」テーマの間では、ユーザ由来テーマでは、 関連度が高かったが、記事由来では、関連度は低かった(表 2, 表 3). つまり、「東京都」をフォローしている人が同時に「温 泉」テーマをフォローしていると考えられるので 3.3 節の1の 地元民による「温泉」テーマのフォローであると考えられる.

例2:「大阪府」「スキューバダイビング」のような記事テーマ 付与の誤り候補

「大阪府」と「スキューバダイビング」のテーマの間では、ユー ザー由来の関連度が低く、記事由来の関連度が高かった(表 2, 表 3). 実際に、「大阪府」と「スキューバダイビング」に同時 に紐付く記事を見てみると、大阪府の水族館でコスプレをした スキューバダイバーが水槽内に現れたという内容であった.こ こでは、スキューバダイビングのテーマに紐付くのは、誤りで あると考えられる.記事に対するテーマの紐付けの誤り候補を 取り出すことができた.

### • ユーザの嗜好と供給されている記事とのミスマッチ

ユーザ由来と記事由来間の類似度の低いテーマ「日本庭園」 に着目する.「日本庭園」と「京都市」は、ユーザ由来のテー マでは関連が高いが、記事由来のテーマでは、関連が小さい (表 2,表 3).しかし、例1のような誤った地域は確認されず、 配信側の記事テーマとユーザーの嗜好の間に差がある可能性が ある.



図 3: 観光テーマ別地域ランキングの人手評価結果

# 9. おわりに

本研究では、ニュースサイトにおいて、「ユーザによって能動的に選択されたテーマ」および「記事に内容に基づき自動的に付与されたテーマ」のそれぞれを用いて地域と観光要素の紐付けを行い、観光要素別地域ランキングと地域別観光要素ランキングを作成した.そして、両者の類似度を利用することにより精度の向上を確認できた.また、類似度が低いテーマを分析し、テーマ紐付けの誤りパターンの知見を得た.さらに、ユーザと記事配信の需要供給の間にミスマッチが存在すると思われるケースも発見した、今後は分析を深めて、より正確な地域・観光要素間の関連性の抽出を実現し、地域の意外な観光テーマの発見など、地域活性化に貢献していきたい.

- 日本政府観光局 (JNTO). 国籍/月別 訪日外客数. https://www.jnto.go.jp/jpn/statistics/since2003\_ visitor\_arrivals.pdf.
- [2] 王怡青, 土井俊弥, 井上祐輔, 宇津呂武仁. ご当地グルメを題材と するクイズ・コンテンツの作成. 第8回 DEIM フォーラム論文 集, 2016.
- [3] 土井俊弥, 王怡青, 井上祐輔, 宇津呂武仁. 観光情報 PR のための 旅ゲー風アプリの提案およびご当地グルメ版の作成. 言語処理学 会第 22 回年次大会論文集, pp. 59–62, March 2016.
- [4] Yahoo!ニュース. https://news.yahoo.co.jp/.
- [5] 井上裁都, 末永圭吾, 長田誠也, 立石健二. Entity linking を用い たニュース記事に対する市区町村単位の地域情報の付与. 言語処 理学会第 22 回年次大会論文集, pp. 45-48, March 2016.
- [6] 相澤彰子. 大規模テキストコーパスを用いた語の類似度計算に関 する考察. 情報処理学会論文誌, Vol. 49, No. 3, pp. 1426–1436, 2008.

# 解釈性のあるフェイクニュース検出器の実装と評価

# Implementation and Evaluation of an Interpretable Fake News Detector

山本 和矢 \*1 Kazuya Yamamoto\*1 小山 聡<sup>\*2</sup> 栗原 正仁<sup>\*2</sup> Satoshi Oyama Masahito Kurihara

\*<sup>1</sup>北海道大学工学部 School of Engineering, Hokkaido University Graduat \*2北海道大学大学院情報科学研究科

versity Graduate School of Information Science and Technology, Hokkaido University

Interpretability is an important element of fake news detection so that readers can assess the credibility of news by themselves. We implemented a naive Bayes fake news detection model proposed by Granik and Mesyur and evaluated it with the LIAR dataset in terms of recall, effect of stop words, and interpretability. The recall was affected by the imbalanced data and eliminating stop words did not improve the accuracy but slightly deteriorated it. Some high probability words were interpretable as reasons for fake news but longer phrases had better be considered as clues for fake news.

# 1. はじめに

SNS の普及により人々が手軽に情報を発信したり,入手す ることが可能になり我々の生活はより利便性を増した.一方 でそうした情報の中には信憑性に欠けたものが含まれている. 虚偽の情報でつくられたニュースをフェイクニュースと呼ぶ. フェイクニュースの目的は人を欺くことや衝撃的なタイトル で閲覧数を稼ぎ広告収入を得ること,また特定の人物や団体 の根拠のない誹謗中傷をすることである.近年,このフェイク ニュースを発端として様々な問題が発生している.その例とし て,2016 年 12 月 4 日にアメリカ大統領選中に SNS で拡散さ れたクリントン候補の陰謀説に関するフェイクニュースの真相 を確かめようと銃を持った男がレストランに侵入するという事 件が起こった\*<sup>1</sup>.

あるニュースがフェイクニュースであるか人手で判別する には内容が虚偽であるか精査しなければならないため時間が かかる.また、メディアの多様化により大量のニュースが生み 出されている.それゆえフェイクニュースをすべて人手で検 出することは非常に困難である.そうしたことから、フェイク ニュース自動検出の研究に対するニーズが高まっている.

一方で、フェイクニュースの自動検出器が構築できたとし ても、それを無条件に信頼することにも問題がある。フェイク ニュースの検出に誤りがあったり、検出器自体が「フェイク」 である可能性も完全には否定できないからである。必要に応 じて、読者が検出のプロセスを精査できることや、読者自身が ニュースを批判的に読む能力を身に付けることも重要である。 そのためには、なぜあるニュースがフェイクだと判定できたの か、その原因を調べることが可能な、解釈性の高い検出器が必 要となる.

フェイクニュースの自動検出の試みの一つとして, [Granik 17] はフェイクニュースがスパムメッセージと類似 点があるという仮定の元で,スパムフィルターに用いられるナ イーブベイズ分類器を用いてフェイクニュースの自動検出を 行い74%の精度でフェイクニュースを分類している.しかし, これには「データの偏ったデータでしか実験していない」,「ス トップワードの除去を行っていない」,「使用しているモデルの 解釈性が高いにもかかわらず検出の要因を分析していない」と いった課題が存在している.

本研究の目的は [Granik 17] の用いた手法を実装し, ラベル の偏りによりどのような違いが生じるか調べること, ストップ ワードの除去を行い分類結果の変化を検証すること, フェイク ニュース検出の要因となった単語を分析することである.

# 2. 関連研究

[Granik 17] はフェイクニュースがスパムメッセージと,(1) 文法的な間違い,(2)感情的に誇張された表現,(3)読者の 意見を操作,(4)内容が虚偽,(5)限定的な類似単語の使用, のような類似点があるという仮定の元で,スパムフィルターに 用いられるナイーブベイズ分類器を用いてフェイクニュースの 自動検出を行った.

この研究において使われたデータセットはラベルに偏りが ありフェイクニュースは全体の5%ほどしか含まれていない. [Granik 17] はラベルの偏りが原因で検出の再現率が低くなっ たと主張している.また、ストップワードの除去を行えば分類 の精度が向上すると主張している.しかし、いずれの主張も検 証されておらず仮説にすぎない.また、単語的特徴から解釈性 の高いモデルを用いてフェイクニュースの分類を行っているに もかかわらず、分類の要因となった単語を分析していない.

その他にもフェイクニュースの自動検出の研究が盛んに行われている.フェイクニュースの自動検出の手法として,ニュース記事の文章のみの情報を利用する言語的アプローチとソーシャルメディアや WEB 上の情報といった外部の情報を利用するネットワークアプローチがある.

欺瞞的な文章には代名詞や接続詞の頻度や出現パターン,否 定的な感情を表現する言葉が多く用いられるといった言語的な 特徴が存在する [Feng 13]. 言語的アプローチはそうした特徴 をニュースの文章から検出することを目的としている.

ソーシャルメディアで発信されたニュースに対して,ニュー ス記事の文章以外の特徴を用いてフェイクニュースの自動検出 を行った例も存在する. [Tacchini 17] は Facebook の投稿がそ れに「いいね!」を付けたユーザに基づいてデマであるかそう でないかに分類した. このように文書以外の情報を用いて分類 する試みが存在するがフェイクニュースは必ずしも文書以外の 情報が手に入るとは限らない. こういった手法は分類できる状 況を限定してしまうという問題点がある.

連絡先: 山本和矢, yamamoto@complex.ist.hokudai.ac.jp \*1 https://www.cnn.co.jp/usa/35093206.html

# 3. 実験

### 3.1 使用手法

本実験では [Granik 17] が提案したナイーブベイズ分類器に 基づくフェイクニュース検出器を実装して用いた.手法の詳細 については [Granik 17] を参照されたい.

# 3.2 使用データ

先行研究で使われたデータは、入手不可能であったため代 わりに形式の類似した別のデータを用いた.使用したデータ は LIAR\*<sup>2</sup> である.LIAR は [Wang 17] によってつくられた フェイクニュース検出用のベンチマークデータセットである. アメリカの政治にまつわる声明のファクトチェックを行って いるウェブサイト POLITIFACT.COM\*<sup>3</sup> の API で取得され たデータである.共和党及び民主党員の発言,ソーシャルメ ディアの投稿など約 1.2 万個の声明に対し, ID, 6 段階の真偽 ラベル (pants-fire, false, barely-true, half-true, mostly-true, true), 題目,発言者,発言者の職業,故郷の州,所属政党,発 言者の声明に付けられたそれぞれのラベルの数,どこでの発言 かといったタグが付与されている.実験では6 段階のラベル のうち pants-fire, false, true のみを使用し, pants-fire と false をラベル Fake として扱った.またいくつかのデータの情報が 欠損していたため除外した.

### 3.3 実験結果

ナイーブベイズ分類器を用いたフェイクニュース検出のデー タの偏りによる再現率の変化を確認した.元のデータからラベ ルに偏りが生じるように抽出したデータとラベルに偏りがない ように抽出したデータをデータ数の合計が同じになるように用 意した.用意した2つのデータに対しナイーブベイズを用いた フェイクニュースの検出を行いそれぞれの再現率を比較した. 偏りのあるデータの再現率は 0.04,偏りのないデータの再現 率は 0.68 であった.これは [Granik 17] の仮説を支持する結 果である.

Python の NLTK\*<sup>4</sup> コーパスのストップワードリストに含ま れる単語を辞書から除去した場合とストップワードを辞書か ら除去しなかった場合の精度,再現率,適合率,F値を比較し たところ,ストップワードの除去によってこれらが改善され ず,むしろ僅かながら低下する傾向があった.これは,フェイ クニュース検出においてはストップワードは除去すべきもので はなく,むしろ検出に有効な情報を含んでいる可能性があるこ とを示している.

辞書に含まれた 9328 種類の単語のうち,単語がニュース記 事中に存在するときの,フェイクニュースである確率が大き い上位 30 単語を表1 に示す.このうち socialists, muslim, bad について,これらの単語が出現する訓練データの文書の例 を表2 に示す.表から分かるようにこれらの単語は文書中に おいて特定の人物や組織を批判する目的で使われている.この ことからフェイクニュース検出の要因となった単語には特定の 人物や組織を批判する目的で使われる単語が含まれていること が分かる.フェイクニュースらしさの大きい他の単語は,単語 自体ではなぜそれがフェイクニュースと判定する要因とするの かが分かりにくいものが多い.しかし,たとえば responsible は is responsible for というフレーズで,他者を批判する文脈 で用いられるなど,フレーズや文脈を考慮すれば,フェイク ニュース判定の要因となった理由を解釈できるものもある. face, governments, anything, responsible, began, reps, socialists, muslim, tell, scheme, cabinet, information, surplus, data, groups, census, benefit, reason, murphy, outside, loan, balanced,admits, parks, terry, provision, study, recently, bad, josh

表1:フェイクニュース検出の要因となった単語

| 単語         | 単語が出現する訓練データの文書                            |
|------------|--|
|            | Say Oregon Reps. Peter DeFazio and Earl    |
| socialists | Blumenauer are socialists who are openly   |
|            | serving in the U.S. Congress.              |
|            | Says large majority of Republicans believe |
| musmin     | Obama is a Muslim and not U.Sborn.         |
| had        | The Mexican government forces many bad     |
| Dau        | people into our country.                   |

表 2: 特定の単語が出現する訓練データの文書の例

# 4. まとめ

本稿では、先行研究で提案されたフェイクニュース検出の実 装と評価を行った.これにより先行研究の仮説の検証と先行研 究では着目されていなかったモデルの解釈性について分析を行 いフェイクニュースに含まれる単語について知見を得ることが できた.

本稿においては解釈性を活かすためナイーブベイズ分類器 のみを用いたが、同様に解釈性のあるモデルに関して分類精度 を比較する必要がある。検出の要因として単語だけでは解釈 することが困難な場合が多いため、フレーズを抽出するなど、 特徴のとり方を工夫するなどしてより人が解釈しやすくする必 要がある。今回用いたフェイクニュース自動検出用のデータで は含まれる文書がアメリカの政治に関する限定的な題材であっ たが、様々なフェイクニュースを検出するためにはより多種多 様なフェイクニュースに関するデータが必要であるため他の利 用可能なデータの調査や SNS などを利用したデータの収集が 必要である。将来的にはフェイクニュースの検出結果の根拠を ユーザが解釈可能しやすい方法で可視化するシステムに関する 研究を行いたいと考えている。

- [Feng 13] Feng, V. W. and Hirst, G.: Detecting deceptive opinions with profile compatibility, in *IJNLP*, pp. 338–346 (2013)
- [Granik 17] Granik, M. and Mesyura, V.: Fake news detection using naive Bayes classifier, in *IEEE UKRCON*, pp. 900–903 (2017)
- [Tacchini 17] Tacchini, E., Ballarin, G., Della Vedova, M. L., Moret, S., and Alfaro, de L.: Some like it hoax: Automated fake news detection in social networks, *arXiv preprint arXiv*:1704.07506 (2017)
- [Wang 17] Wang, W. Y.: " liar, liar pants on fire": A new benchmark dataset for fake news detection, arXiv preprint arXiv:1705.00648 (2017)

<sup>\*2</sup> https://www.cs.ucsb.edu/~ william/ data/liar\_dataset.zip

<sup>\*3</sup> https://www.politifact.com

<sup>\*4</sup> https://www.nltk.org/

# 統計的尺度に基づく有害表現抽出手法の自動評価

Automatic Evaluation for Cyberbullying Detection Method based on Statistical Scale

荒田 真輝 <sup>\*1</sup> 桝井 文人 <sup>\*2</sup> プタシンスキ ミハウ <sup>\*3</sup> Masaki Arata Fumito Masui Michal Ptaszynski

\*1北見工業大学大学院 工学研究科 情報システム工学専攻 Kitami Institute of Technology Department of Computer Science

\*<sup>2\*3</sup>北見工業大学 地域未来デザイン工学科 Kitami Institute of Technology School of Regional Innovation and Social Design Engineering

Various methods have been proposed to detect harmful information automatically as a support of cyberbullying countermeasures. However, there remain various problems such as detection performance deterioration over time and detection of information including private information. In this paper, we propose an automatic evaluation method for harmful expression extraction method using BLEU, an automatic evaluation method typically used in evaluation of machine translation methods. In this method, for as a detected as a harmful by the harmful expression extraction method, the evaluation is performed based on word N-gram Precision using the harmful entry gold standard dataset. As a result of the evaluation, the proposed allowed assigning a high score to harmful entries, which confirmed the effectiveness of the method.

# 1. はじめに

インターネットの普及に伴い, Web 掲示板や SNS 等に特定 個人への誹謗中傷や個人情報等を書込む「ネットいじめ」が社 会問題となっている [1]. しかし「ネットいじめ」の対処には 膨大なコストがかかることや, 監視自体が困難になってきてい るなど多くの課題があり,これらに対処するための有害書込み 自動検出手法が数多く提案されている.

新田ら [2] は松葉ら [3] が提案した PMI-IR を用いた有害極 性判定手法を拡張し,カテゴリ別関連度最大化手法 (CRM 手 法)を提案している.新田らは松葉らが用いた種単語と呼ばれ る有害極性単語を 3 カテゴリに分類し,種単語を各カテゴリ に頻出の 3 単語ずつ含めることにより,90%を超える精度で有 害書込みを判定できたと報告している.

しかし,後に畠山ら [4] が CRM 手法を再現した際,精度が 低下していたことが報告されている. 畠山らは原因として種単 語が時代に適さないものになっていたことを挙げ,有害極性単 語の組合せや規模を変化させた結果,人間の判断による有害極 性単語の更新が性能に良い影響を及ぼしたと報告している.

また, Zhang ら [5] は学習素性に音素を用いたニューラル ネットワークによる有害書き込み検出手法を英語のために提案 している.この手法は有害情報に見られる意図的なスペルミス を音素を用いて訂正しており, 98.9%の精度で有害情報を判定 が可能であった.

上記のように有害表現抽出手法は数多く提案されているが, 課題も多く残されている.そこで,本稿では各手法における課 題の整理に向けた,有害表現抽出手法の自動評価手法を提案す る.具体的には,Papineniらにより提案された,機械翻訳に おける自動評価手法である BLEU[6]を有害表現抽出手法の評 価へと応用,自動評価を行う.

# 2. 基本的な考え方

本章では、機械翻訳の自動評価手法 BLEU を活用した有害 表現抽出手法の自動評価について説明する.

### 2.1 機械翻訳自動評価手法 BLEU

BLEU は Papineni らにより提案された機械翻訳における自動評価手法である.

BLEU では,機械翻訳文とプロの翻訳者による翻訳文の似 ている度合いを数値で表すため,対象文を2つの文章間の Ngram 一致度 Pn(式 1) と,機械翻訳文の長さに応じたペナル ティ係数 BP(式 2)を用いて表される式3により評価する.ま た,BLEU は 0~1 の範囲になり,0 は類似度なし,1 は完全 な類似度を表している.

$$Pn = \frac{ \delta \delta \delta 照訳 と の 単語 n - gram 共有数の最大値}{MT 訳中の 単語 n - gram 数}$$
(1)

$$BP = \begin{cases} 1 & (c > r) \\ e^{(1-r/c)} & (c \le r) \end{cases}$$
(2)

$$BLEU = BP \cdot \exp\left(\sum_{n=1}^{N} \frac{1}{N} \log P_n\right)$$
(3)

# 2.2 BLEU の有害表現抽出手法評価への応用

本研究でも,BLEUの評価の根拠であるプロの翻訳者によ る翻訳文が似ているほど機械翻訳文の質が良いという考え方と 同様に,プロとしてネットいじめ書き込みを手作業で検索し通 報するインターネットパットロールメンバーが集めた有害な文 書と似た文書は有害であるとの考え方を根拠に,本提案手法に よる有害表現抽出手法の評価を行う.有害表現抽出手法が有害 と判断した文書に対して,人間により有害であると判断された ネット上から抽出された文書を参照し,対象の文と有害な文の 間の N-gram 一致度 Pn(式 4)を算出する.

$$Pn = \frac{ ある有害文書との単語 n - gram 共有数の最大値}{対象の評価文中の単語 n - gram 数}$$
(4)

連絡先: 北見工業大学, 〒 090-8507 北海道北見市公園町 165 番地, m1852400016@std.kitami-it.ac.jp

また,機械翻訳文の評価の場合とは異なり,有害な文章の評価では,とても短い文章の場合でも有害な文章である場合がある.そのため,有害な文章としての評価である本提案手法では,BLEUにおいて評価対象の文の長さに応じてかけられるペナルティ係数 BP の適用は行わなず,有害な文との近さを表す harmBLEU スコアは式5 で求められる.

$$harmBLEU = \exp\left(\sum_{n=1}^{N} \frac{1}{N} \log P_n\right) \tag{5}$$

# 3. 提案手法

本章では、本提案手法の評価の妥当性について確認するため、松葉らが学校非公式サイト等のネット掲示板から抽出した 書込み 2,998 件 (有害 1,509 件,非有害 1,489 件) に対し、本 提案手法による評価を行った.以下に評価の流れを示す.

- 1. データセットから評価対象の書込みを抽出する
- 2. 対象の書込み以外の有害書込み全てを参照文とし、対象のharmBLEUスコアを算出
- 3. データセット中の全書込みに対し, harmBLEU スコアを 算出し, スコアの高い順に並べ替える
- 4. 順位毎にその順位以上の書込みを有害な書込み,順位未満の書込みを非有害な書込みとした際の適合率,再現率 を算出

各順位における適合率,再現率を図1に示す.図1より,順 位が1000位程度の閾値まで適合率が0.8以上と高い値が見ら れる.これより,有害な書込みは相対的にみて非有害な書込み より高いharmBLEUスコアを付与できており,本提案手法が 有害書込みの評価に一定の有効性が有ることを示している.

# 4. 適用実験

次に,既存手法への評価の有効性について調査を行うため, 同様のデータセットを用いた畠山らがアンケートを行い人手に より有害と判断された単語を使用し改良を行った CRM 手法 による有害書込みの判定実験の結果に対し,本提案手法を用い て評価を行った.

CRM 手法では,各書込みに対し有害度合いを表すスコア (SO 値)を付し,一定の閾値を用いて判定を行う手法であるた め,本実験では各閾値毎の harmBLEU スコア平均を算出し た.閾値による適合率,再現率と harmBLEU スコア平均の推 移を図 2 示す.

図2より, harmBLEU スコア平均は閾値である SO 値の低下に伴い,緩やかに低下していることが読みとれる. これは改良 CRM 手法における SO 値が高いほど harmBLEU スコア も高い傾向にあることを示している.

# 5. 結果と考察

本適用実験の結果,本提案手法による改良 CRM 手法の評価 は閾値が高い場合に高く,閾値を低くしていくにつれて評価も 低くなっていることが分かった.これは,畠山らの改良 CRM 手法おいて,閾値が厳しい場合は適合率が約8割,閾値を緩 くしていくと適合率が5割に近づき判定が機能しなくなって いくという結果と一致しており,本提案手法による評価が有効 である可能性を示している.

一方, 閾値を低くした場合に着目してみると SO 値の上位約 1500 件を境に改良 CRM 手法の適合率の値が上昇を始めてい



図 2: 各閾値における適合率,再現率と hamBLEU スコア平均

るが、harmBLEUスコア平均はほぼ一定の値を取っていることが読み取れ、本提案手法は有害である可能性が低い文書に対しては上手く評価が出来ていないことが分かった.

### 6. おわりに

今回,機械翻訳における自動評価手法である BLEU を有害 表現抽出手法へと応用し,その手法を自動評価する手法を提案 した.本提案手法による掲示板書込みの評価により,本提案手 法が有害表現抽出手法の評価について一定の有効性を確認でき た.しかし,今回の実験では参照文,対象文共に同じ掲示板の 書き込みを利用しており,N-gram 一致度の算出の際において, 個人名による影響が大きくなっていることが考えられるため, 今後さらに異なるデータを用いた性能も確認する必要がある.

- [1] 文部科学省:"「学校ネットパトロールに関する取組事例・資料集」(教育委員会等向け) 資料編第2章・巻末資料",文部科学省,(2012.9).
- [2] 新田大征,桝井文人,プタシンスキ・ミハウ,木村泰知,ジェブカ・ラファウ,荒木健治:"カテゴリ別関連度最大化手法に基づく学校非公式サイトの有害書き込み検出",第 27回人工知能学会全国大会発表論文集,(2013.6).
- [3] 松葉達明, 桝井文人, 河合敦夫, 井須尚紀:"学校非公式サイトにおける有害情報検出 を目的とした極性判定モデルに関する研究", 言語処理学会第 17 回年次大会発表論文 集, P2-26(2011.3).
- [4] 畠山鈴生, 桝井文人, ブタシンスキ・ミハウ, 山本和英:"有害表現抽出に対する種単 語の影響に関する一考察",第 30 回人工知能学会全国大会, (2016.6).
- [5] Xiang Zhang, Jonathan Tong, Nishant Vishwamitra, Elizabeth Whittaker, Joseph P.Mazer, Robin Kowalski, Hongxin Hu, Feng Luo:"Cyberbullying Detection with a Pronunciation Based Convolutional Neural Network", 15th IEEE International Conference on Machine Learing and Applications, (2016).
- [6] Kishore Papineni, Salim Roukos, Todd Ward, Wei-Jing Zhu:"BLEU: a Method for Automatic Evaluation of Machine Translation", 40th Annual Meeting of the Association for Computational Linguistics, Philadelphia, pp. 311-318, (2002.7).

# Twitter データを用いたアプレイザル評価表現辞書に基づく 印象の自動指標化

Automatic Impression Indexing based on Appraisal Dictionary from Tweet

山田瑠奈 Runa Yamada

a Sho Hashimoto

山田篤拓 Atsuhiro Yamada 長田典子 Noriko Nagata

# 関西学院大学

Kwansei Gakuin University

With the development of social media, interest in text mining has been growing steadily during the past few years. Although these research studies have been conducted on product development and marketing, no research has been conducted to explore cultures that create new value not found in existing products. Therefore, we propose a method of extracting topics related to specific product domains and indexing impressions from tweets containing a wide range of descriptions of cultures and values. Our method is based on the appraisal dictionary as well as the structures of impressions for the target domain to become clear. A result of our method has been applied to the lawn culture. We extracted 13 ground topics and the impressions related to each of them. Moreover one of them was an unexpected concept. This result indicates the usefulness of the method in exploring a new concept of value related to a specific field.

# 1. はじめに

近年,Web上に公開されている膨大なテキストデータから 有益な情報を抽出するテキストマイニング技術に注目が集まっ ている. 中でも, Twitter を代表とするソーシャルメディアの 普及にともない、ソーシャルメディアから得られる商品やサー ビス,出来事などに対する記述文から評判分析を行い,商品 開発やマーケティングに活用する研究が活発に行われている. 特に Twitter では、評判分析の一つである感情分析の研究が 広く行われており、ブランドごとに喜怒哀楽などの感情カテゴ リ分類を行う研究 [Shukri 15] や, 製品の構成要素に対する感 情を推定する研究 [Hridoy 15] などが存在している. しかし商 品開発,特にユーザのニーズを反映させた製品設計を行う上で は, 従来の Twitter データを用いた分析によって得られる「何 が好き・欲しい」といったユーザの嗜好や感情に関する情報の みでは、その要因となる製品の特性や、機能に対する印象が明 らかでなく,全体の設計への十分なフィードバックが行えない 恐れがある.

一方で商品レビューを用いた研究 [山田 18, Hashimoto 19, 橋本 19] においては,製品に対する嗜好とそれに繋がる印象 要因を明らかにする分析手法が提案されている.これらの研究 では製品仕様(形態要素)と,そこから喚起される好き/嫌い といった「感情」との間に,製品の特徴や特性を表す「印象」 を介した階層構造(図1)が仮定されている.この階層構造に 則って商品レビューから対象製品分野の印象構造を明らかにす る印象の指標化 [山田 18, Hashimoto 19]と,製品の印象構造 とユーザの感情との関係性を明らかにする感情の指標化を行っ ている [橋本 19].上述のような印象を介した分析によって,製 品に対するより詳細な情報を得ることができ,ユーザの感情を 製品設計にフィードバックすることが可能となる.しかし商品 レビューに記述されている内容は,既存の製品に関する印象や 嗜好であり,周辺領域の記述やトレンドなど既存の製品にはな い新たな価値を見出すことは困難である.そのため製品に対す

連絡先:関西学院大学理工学部人間システム工学科
 〒 669- 1337 兵庫県三田市学園 2 丁目 1 番地
 E-mail: nagata@kwansei.ac.jp

る印象だけでなく、その製品を使う理由や文化的背景、製品の 使用を通して得られる印象など、対象製品ドメインに対する幅 広い記述からの指標化が必要とされている.

そこで本研究では、文化や価値観など幅広い記述が含まれる Twitter データからの指標化の第一段階として、対象製品 ドメインの印象構造を明らかにする印象の自動指標化を行う.



図 1: 感性の階層構造

# 2. 関連研究

1章で述べたように商品レビューを用いた印象の指標化手法 が山田ら [山田 18] や Hashimoto et.al. [Hashimoto 19] によっ て提案されている.これらの手法ではレビューから印象構造を 構成する印象軸を抽出するにあたり,はじめに評価表現辞書に 基づいた評価語(製品に対する評価を表す単語)の収集を行 い,その後,収集した評価語をユーザの嗜好を表す感情語と製 品の特徴や特性を表す印象語に分類している.

また印象軸の抽出においてはトピック抽出手法の一つである HDP-LDA[Teh 06]を用いている.LDA は、トピック分布に ディレクレ事前分布を仮定しベイズ推定する手法であり、文書 中の単語の「トピック」(話題やカテゴリ)を確率的に求める 言語モデルである.さらに HDP-LDA は LDA をノンパラメ トリックベイズに拡張した手法であり、LDA ではトピック数 を指定する必要があるが、HDP-LDA では適切なトピック数 が学習されるという特徴を有する.Hashimoto et.al.はLDA の特性を利用し、印象語のみを入力としたトピック抽出を適用 することで得られた各トピックを対象製品分野の印象構造を表 す印象軸として扱っている.

### 3. 提案手法

## **3.1** Twitter データを用いた指標化の課題と アプローチ

本手法では Twitter データを用いた印象の指標化を行う. 全体のアプローチとしては Hashimoto et.al.[Hashimoto 19] が提案した商品レビューに対する印象の指標化手法に則り,評価語の収集・分類を行った後に,印象語のみを用いて印象軸を推定する.しかし Twitter データへの印象の指標化手法の適用には 2 つの課題が存在する.1 つ目の課題は,評価対象となる文化や価値観があらかじめ特定できないことである.2 つ目の課題は,Twitter では 1 文書に含まれる印象語数が少ないため,先行研究において印象軸推定で用いている LDA は,適切に機能しないことである.

これらの課題を解決するため、本手法では特定製品ドメインにおける基本的な話題を、名詞を対象とした LDA より抽出し、各話題に対して印象語の分散表現を利用して推定した印象軸との関連付けを行う.

本手法の流れとして,対象製品ドメインにおける話題抽出, 評価語の収集・分類,印象軸の推定,対象製品ドメインにおけ る話題と印象軸との関連度の算出,の4つの手順で印象の指 標化を行う.また多様な文化における本研究の利用可能性の向 上のために,分析は英語で記述された文書を対象に行う.その ため英語の評価表現辞書を作成する必要がある.そこでまず, 指標化の基盤となるアプレイザル評価表現辞書の英語対応を 行う.

### 3.2 英語アプレイザル評価表現辞書の作成

先行研究 [山田 18] では, 評価表現のカテゴリ情報が付与さ れている日本語アプレイザル評価表現辞書に基づいて評価語を 分類している.アプレイザル理論において評価表現には「外評 価」と「内評価」という2種類のカテゴリがあるとされている [佐野 11].内評価とは「嬉しい」や「楽しい」といった評価対 象に対する評価者の感情や感情を表す行為を示す表現であり, 外評価とは「やわらかい」や「きれい」といった評価対象の特 徴を示す表現である.つまり図1において,内評価は感情層, 外評価は印象層に位置づけられると考えられ,これらを分類し た評価表現辞書もとに印象語と感情語の分類を行っている.

本研究では、クラウドソーシングサービスと和訳情報を用 いて、Opinion Lexicon[Hu 04]内に含まれる 6,789 語の評価 語を「内評価」と「外評価」のカテゴリに分類することにより 英語対応を行う.クラウドソーシングを用いた分類では1件の 回答あたり 25 語の分類を行い、計 2,009 件の回答結果によっ て全体の約 74%にあたる 5,021 語を分類した.さらにクラウ ドソーシングを用いた分類できなかった評価語に関しては、各 評価語の和訳情報と日本語アプレイザル評価表現辞書との対応 により分類を行った.その結果、全体の約 93%にあたる 6,317 語を分類した.各分類結果の内訳は内評価が 1,276 語、外評価 が 4,985 語、どちらにも当てはまるものが 53 語であった.本 研究では、この分類結果を英語アプレイザル評価表現辞書とし て定義する.作成した辞書内の単語の例を表 1 に示す.

表 1: 英語アプレイザル評価表現辞書内の単語例

| 内評価                         | 外評価                   |
|-----------------------------|-----------------------|
| like love enjoy beautiful   | good great fresh best |
| hate happy cool nice        | hard clean hot fast   |
| perfect well enjoy favorite | easy warm cold wrong  |

# **3.3** Twitter データを用いた印象の指標化手法 (1)対象製品ドメインにおける話題抽出

はじめに名詞のみを対象としたトピック抽出により対象製 品ドメインにおける話題を抽出する.トピック抽出には HDP-LDA を用いる.前節の課題で述べたように,一文書あたりに おける単語数が少ない(印象語だけで構成される文書など)場 合,LDA は適切に機能しないが,名詞であれば十分な単語数 が確保できると考えられるため,適用可能と判断した.

トピック抽出の入力文書群としては、ストップワード、ユー ザ名、URL、ハッシュタグ、絵文字・記号の削除を行った前処 理後のデータから、品詞が名詞と推定された単語を抽出したも のを用いる.なお品詞の推定は形態素解析ツール NLTK を用 いた.このとき、極端に単語数が少ない文書では適切なトピッ ク抽出が行われないため、ツイート中の名詞数が3 語以下の 文書は分析対象としなかった.

また HDP-LDA によって得られるモデルには初期値や乱数 による依存性があるため、同一のハイパーパラメータ設定で複 数のモデルを比較し最適なモデルを選ぶ必要がある.そこでモ デルの汎化性能を表す指標である Perplexity に基づいて、複 数のモデルから最良(Perplexity が最も低い)のモデルを採用 する.本研究では 10回の学習のうち Perplexity の値が最も低 いモデルを採用した.しかしながら、採択したモデルにおける すべてのトピックが評価の基盤と言えるほどの頑健性があると は考えづらい.そのため得られたトピックの中でも、10モデ ル中の5モデルで共通して抽出されたトピックのみを頑健性 の高いトピックとして採用した.

### (2) 評価語の収集・分類

印象軸の抽出を行う上で必要な印象語を抽出するため,前処 理後の Twitter データから評価語の収集・分類を行う. 英語ア プレイザル評価表現辞書によって内評価と分類された単語を感 情語,外評価と分類された単語を印象語として評価語を収集・ 分類する.

### (3) 印象軸の推定

印象語の中には類似した印象を表現する複数の印象語が存在 しており,類似した方向性を持つ単語を束ねることで軸となる 印象が推察されると考えられる.そのため,本研究においては 単語を分散表現に変換しクラスタリングすることで印象軸の推 定を行う.

単語の分散表現の学習方法としては Word2Vec[Mikolov 11] を用いる.Word2Vec とは、Skip-gram モデルと呼ばれる二 層ニューラルネットワークを用いて単語の分散表現を得る手法 である.次にWord2Vec によって得られた印象語の分散表現 によって印象語間のコサイン類似度を求め、それに基づいた距 離を算出し、ウォード法による階層クラスタリングを行う.ク ラスタ数はクラスタの集中度と孤立度に関する指標 [斎藤 06] をもとに決定した.

(4) 対象製品ドメインにおける話題と印象軸の関連度の算出

名詞を対象としたトピック抽出によって得られた対象製品ド メインにおける話題と、印象構造を表す印象軸との関連度を算 出する.これによって話題に対するユーザの印象を特定できた り、あるいはユーザが感じる印象を象徴する話題の推定が可能 となる.

関連度は、話題として抽出した各トピックにおいて重要度の 高いいくつかの名詞と、印象軸を構成する各印象語との分散 表現のコサイン類似度に基づいて算出する.本手法ではトピッ クにおける単語(名詞)の重要度として term-score を用いて, 上位 10 語の名詞をそのトピックにおいて重要度の高い名詞と した. コサイン類似度は対象のすべての名詞と印象語間で計 算し,その平均類似度を話題と印象軸との関連度として算出 する.

# 4. 実験

本章では、実際の Twitter データに対して手法を適用し、手 法の有用性を確認する.

### 4.1 対象製品ドメイン

本研究では芝刈機を対象製品とし、その背後にある芝生文化 (芝文化)[北村 98]をドメインとする.芝文化とは、芝生に関 わる価値観を反映した物心両面の行動様式を示しており、気候 風土や歴史的背景の違いから国によって異なると考えられてい る.この芝文化の印象構造を明らかにすることで、芝刈機など 芝に関連する製品のデザインの支援への活用が期待される.

### 4.2 データ概要

芝文化に関するキーワード検索(e.g. yard work, cut grass, lawn care)によって得られたツイートをデータとして扱った. 本実験ではアメリカ,イギリス,欧州連合加盟を分析対象国と した.これらの国は日本に比べ芝の手入れに適した気候である ことや,個人住宅での芝庭が多いことから,芝文化調査の対象 国とした.取得したツイート数122,877件で,形態素解析の結 果,総単語数は1,178,039語,総語彙数は37,695 語となった.

### 4.3 結果·考察

芝文化に関する Twitter データに対する適用結果を印象の 指標化の4つの手順ごとに示し,考察する.

(1)対象製品ドメインにおける話題抽出

最も精度の高いモデルのハイパーパラメータは  $\alpha = 2.0$ ,  $\beta = 0.1$ ,  $\gamma = 0.01$ , Perplexity の値は 50.731 となり, 19 個のトピック(話題)が抽出された.抽出されたトピックのう ち,頑健性の高かった 13 個のトピックを表 3 に示す.トピッ ク1 や 3 のような文化的背景を連想させるトピックや,トピッ ク5 や 11 のように特定の話題が顕著に表れているトピックが 抽出することができた.その他のトピックは芝庭・芝刈りに関 連するトピックと考えられる.

表 2: 芝文化における話題抽出結果

| 大台についる品色品目相応 |          |   |  |
|--------------|----------|---|--|
|              | 解釈結果     | term-score の高い上位 5 単語                       |  |
| 1            | 武器       | people, gun, car, truck, weapon             |  |
| 2            | 人・家      | man, woman, men, car, tire                  |  |
| 3            | 低賃金労働    | lawn, program, worker, people, food         |  |
| 4            | 近隣       | lawn, people, home, neighbor, business      |  |
| 5            | 風景設計・造園  | landscape, architect, designer, space, city |  |
| 6            | 季節       | spring, lawn, season, news, summer          |  |
| 7            | 庭の手入れ    | yard, leaf, grass, neighbor, weed           |  |
| 8            | 子供       | kid, school, car, paper, neighbor           |  |
| 9            | 天候       | weather, yard, winter, week, snow           |  |
| 10           | 植物       | plant, garden, lawn, flower, grass          |  |
| 11           | スポーツ・ゴルフ | game, golf, shoe, shirt, yard               |  |
| 12           | 買い物      | yard, dog, home, car, grocery               |  |
| 18           | 芝刈機      | lawn, mower, gas, equipment, power          |  |

### (2) 評価語の収集・分類

評価語の収集・分類結果の一部を表2に示す.収集された 評価語は2,083 語,うち内評価を表す評価語が717 語,外評 価を表す評価語が1,366 語となった.抽出された評価語は,対 象製品ドメインにおける話題への感情・印象を表している評 価語であることがわかる.最も多くのツイートで用いられた 「good」(良い)という印象語は、商品レビューにおいても最 も出現頻度が高かったことから、普遍的な印象語であるといえ る.「fresh」という単語が「good」に次いで出現頻度が高いこ とから、芝生の新鮮さや芝刈りによってすっきりしたといった 記述が多いことが推定可能である.感情語と印象語の出現頻度 を比較すると、感情語の方が圧倒的に高い頻度で出現してい る.これは、Twitter上には感情的な表現を投稿されることが 多いという特性を示している.また、「like」や「love」などの 個人の感情に関する評価語は適切に感情語として分類され て おり、手法の有効性が確認された.

表 3: 評価語の収集・分類結果 (一部抜粋)

|     | X 0. IIII |       |        |      |
|-----|-----------|-------|--------|------|
| 感情語 |           | 印象    | 語      |      |
|     | like      | 68982 | good   | 3169 |
|     | love      | 22907 | fresh  | 3019 |
|     | well      | 11612 | great  | 1910 |
|     | nice      | 8481  | right  | 1837 |
|     | enjoy     | 7659  | best   | 1076 |
|     | fun       | 7190  | bad    | 1068 |
|     | hate      | 6896  | free   | 1005 |
|     | beautiful | 6372  | ready  | 974  |
|     | happy     | 5956  | hard   | 851  |
|     | damn      | 5309  | enough | 777  |

### (3)印象軸の推定

0.05%以上のツイートに含まれる印象語 77 語を対象とした クラスタリングの結果,13の印象軸が得られた.表4は各印 象軸を構成する印象語と印象軸の解釈を示している.注目すべ き点として,印象軸1や11のような印象語の中でも強い感情 に結びつくような軸が表れた.これは山田ら[山田 2018]のよ うなレビュー文章を対象とした研究ではあまり見られない特徴 であり,Twitter データの特性であると考えられる.また,印 象軸8や10,12,13は物理的要因に対する印象を表す軸であ り,印象語の集合として解釈可能な結果が得られていると考え られる.さらに印象軸4は文化特有の社会問題に対する印象 と解釈できる.

### (4)対象製品ドメインにおける話題と印象軸の関連度の算出

対象製品ドメインにおける話題抽出で得られた各話題に対し て 3.3.4 項で提案した手法を用いて関連度を算出した結果,特 に関連度の高かったペアを印象軸と話題の 2 つの観点から取 り上げたものを表 5 と表 6 に示す.

表5を見ると,庭の手入れには有用性が求められており,芝 刈りの場面では植物に対して憤慨するような印象を持つことが 推測できる.また,印象軸と話題のどちらの観点においても, 印象軸4と話題3の関連性が見られたことから,芝刈りは低賃 金労働であるという社会的背景があり,貧困性・犯罪性といっ た印象を持たれていることが示唆された.

このような知見はレビュー等を用いて製品同士を比較するな かでは得られがたい知見である.「植物に対してもいらつかな い」「芝刈りは単純労働であるというイメージをくつがえす」 といった新しい価値はプロダクトデザインに有用であると考え られる.これらより,本研究の手法で特定製品ドメインにおけ る製品評価につながる可能性のある価値観や文化に対する新た な知見を獲得できることが示された.

# 5. おわりに

本研究では、Twitter上に存在している製品分野に対する幅 広い記述から、製品を使う理由、文化的背景、並びに製品の使 用を通して得られる価値観に対する印象を指標化する手法を提 案した.提案手法では、はじめにアプレイザル理論に基づいて

|    | 解釈結果    | 印象軸を構成する印象語   |
|----|---------|---|
| 1  | 憤慨      | fuck, fake, dumb, shit, stupid  |
| 2  | 良否・正誤   | good, right, wrong, weird, bad, clearly, positive, ridiculous, strong, terrible |
| 3  | 高品質感    | enough, pretty, worth, odd, decent, smart, afraid, expensive                    |
| 4  | 貧困性・犯罪性 | clean, rich, honest, fine, lazy, poor, cheap, illegal, criminal                 |
| 5  | 適性      | important, proper, properly, complimentary                                      |
| 6  | 有用性     | available, leading  |
| 7  | 孤高さ     | free, top, proud  |
| 8  | 安全性     | safe, hard, tough, easy, difficult, useful, dangerous                           |
| 9  | 完全性     | dead, ideal   |
| 10 | 遅速・円滑性  | enough, fast, weed, clear, slow   |
| 11 | 称賛      | wonderful, lovely, great, best, excellent, awesome, amazing                     |
| 12 | 寒暖・硬軟   | ready, hot, fresh, warm, cold, bright, delicious, soft                          |
| 13 | 生産性・静騒  | super, lucky, quiet, loud, productive, wild, dark                               |

# 表 4: 印象語 77 語を対象とした印象軸推定結果

表 5: 印象軸に対する話題の関連度算出結果

| 単参引        | 関連度//同い 前越 |
|------------|------------|
| 4【貧困性・犯罪性】 | 3【低賃金労働】   |
| 5【適正】      | 6【季節】      |
| 6【有用性】     | 5【風景,建築】   |
| 7【孤高さ】     | 8【子供】      |
| 8【安全性】     | 1【武器】      |
| 10【遅速・円滑性】 | 7【庭の手入れ】   |
| 12【寒暖,硬軟】  | 9【天候】      |

表 6: 話題に対する印象軸の関連度算出結果

| 話題           | 関連度が高い印象軸  |
|--------------|------------|
| 3【低賃金労働】     | 4【貧困性・犯罪性】 |
| 4【近隣】        | 1【憤慨】      |
| 7【庭の手入れ】     | 6【有用性】     |
| 8【子供】        | 5【適正】      |
| 10【植物】       | 1【憤慨】      |
| 11【スポーツ・ゴルフ】 | 2【良否・正誤】   |
| 12【買い物】      | 4【貧困性・犯罪性】 |

英語アプレイザル評価表現辞書を作成した.次にドメインにお ける基本的な話題をトピック抽出により推定し,その後,作成 した辞書と単語の分散表現を利用した印象軸の抽出,および話 題との関連度を算出した.

実験では芝刈機を対象製品とし、本手法を芝文化に関する ツイートに適用した.トピック抽出によって得られた芝刈機分 野における話題と印象軸の関連性を確認した結果,製品評価に つながる可能性のある知見を獲得することができ,手法の有用 性が示された.

今後の課題としてはトピック抽出の精度向上や,共起率を考 慮した関連度の算出などを行うことにより,得られる情報の多 様性・有用性を向上していくことが挙げられる.

### 謝辞

本研究の一部は国立研究開発法人科学技術振興機構(JST) の研究成果展開事業「センター・オブ・イノベーション(COI) プログラム」の支援によって行われた.また,共同研究を通し てデータをご提供いただき,有益なご議論,ご提案をいただき ました(株)本田技術研究所パワープロダクツR&Dセンター の関係各位に深く御礼申し上げます.

# 参考文献

[Hashimoto 19] Hashimoto, S., Yamada, A., and Nagata,N: A Quantication Method of Composite Impression of Products by Externalized Evaluation Words of the Appraisal Dictionary with Review Text Data, International Journal of Affective Engineering, Online ISSN 2187-5413, Advance publication Released January 25 (2019)

- [橋本 19] 橋本翔,山田篤拓,長田典子: レビューデータを用い た評価表現辞書に基づく感性の自動指標化,人工知能学会 全国大会論文集 (2019)
- [Hridoy 15] Hridoy, S. A. A., Ekram, M. T., Islam, M. S., Ahmed, F., and Rahman, R. M.: Localized twitter opinion mining using sentiment analysis, *Decision Analytics*, Vol.2, No.1, p.8 (2015)
- [Hu 04] Hu, M. and Liu, B.: Mining opinion features in customer reviews, AAAI 2004, pp.755-760 (2004)
- [北村 98] 北村文雄: 日本における芝生文化の展開, 芝草研究, vol.27, No.suppllement1, pp.1-8 (1998)
- [斎藤 06] 齋藤堯幸, 宿久洋: 関連性データの解析法, 共立出版 (2006)
- [佐野 11] 佐野大樹: 『日本語アプレイザル評価表現辞書(態度表現編)』の構築-評価の多様性を捉えるための言語資源の開発-, 言語処理学会第 17 回年次大会発表論文集, pp.115-118 (2011)
- [Shukri 15] Shukri, S. E., Yaghi, R. I., Aljarah, I., and Alsawalqah, H.: Twitter sentiment analysis: A case study in the automotive industry, AEECT, 2015 IEEE Jordan Conference on, pp.1-5 (2015)
- [Teh 06] Teh, Y. W., Jordan, M. I., Beal, M. J. and Blei, D. M.: Hierarchical Dirichlet processes, *Journal of the American Statistical Association*, Vol.101, issue 476, pp.1566-1581 (2006)
- [Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient estimation of word representations in vector space, *ICLR Workshop 2013* (2013)
- [山田 18] 山田篤拓,橋本翔,長田典子: レビューデータを用い た評価表現辞書に基づく印象の自動指標化,日本感性工学 会論文誌, Vol.17, No.5, pp.567-576 (2018)
# 潜在的な旅行者への宿泊施設の提案 Catch Me if Yahoo Can: Hotel Recommendation for Potential Travelers using Transit App Log

| 丸山 三喜也*1        |  |
|-----------------|--|
| Mikiya Maruyama |  |

高濱 康太郎\*1 Kotaro Takahama 寺岡 照彦<sup>\*1</sup> Teruhiko Teraoka

Kota Tsubouchi Teruhiko To

\*1 ヤフー株式会社 Yahoo Japan Corporation

We suggest new hotel recommendation method that catches user context from transit log and recommends information before they need. People who are planning to travel or business trip tend to search a route to go to the destination beforehand. In this case, we use the transit search log to find out the potential travellers and recommend hotels near their destination. As a result, we confirmed that the method is more effective to reach the potential travellers than existing methods for potential user. This paper is consideration and summary of the method's verification.

# 1. はじめに

インターネットやスマホの普及により,情報がすぐ手に入るよう になった反面,本当に必要とする情報を得るまでに時間と労力 がかかることが少なくない.一般的に旅行は,宿泊施設,観光施 設,飲食店,交通機関など,複合的な計画や調査が必要であり, ユーザにとって大変な手間のかかるものである.一連の調査や 計画の早い段階で,ユーザの意図やコンテキストを読みとって, 適切な情報を先回りして推薦できれば利便性が大きい.そこで 我々は乗換検索に注目し,そこから潜在的な旅行者を予想して, 宿泊施設の推薦を行うことを考えた.但し,移動距離や実際の移 動日までの日数はユーザ毎にまちまちであり,どの程度の移動 距離に対して,どのタイミングで,どのような施設を推薦すればよ いかを決めることは難しい.

これらを明らかにするため、ヤフー乗換案内の検索ログを利 用した実験を実施した.ルート検索の出発地と目的地から移動 距離を計算し、一定以上の距離を移動する潜在的な旅行者に ヤフートラベルを使って移動先周辺の宿泊施設の推薦をメール で配信した.

実験結果によれば、移動距離や検索日と実際の移動予定日 の差が大きくなるほど、宿泊予約に至る傾向が見られた.

#### 2. 関連研究

旅行や出張など長距離移動に伴う情報推薦では、観光場所 で次に行くスポットの推薦[E.Palumbo 17]や、場所や時期、ロコミ からの宿泊施設の推薦[M. A-Ghossein 18]などの研究がある.本 論文のように、ユーザが長距離移動の交通手段を検討中に、先 読みして宿泊施設を推薦することは、あまり検討されていない.

# 3. データセット

今回考案した手法では以下のデータを用いる.

- 乗換案内ルート検索ログ
- ホテルマスタデータ

乗換案内ではユーザーがルートを検索する毎に検索結果を ログとして蓄積しており、いつどこに、どのようなルートで移動する 予定かを知ることができる。このログを用いて長距離移動ユーザ ーを抽出する。またレコメンドするホテルの選定のため、ホテルマ スタデータを用いる。到着地に近いホテルをレコメンドするため、 緯度経度で紐付けられるようになっている。

## 4. 考案手法

坪内 孝太\*1

# 4.1 対象となるユーザーの抽出

乗換案内のルート検索ログの出発地/到着地から距離を取得. そこから具体的に何 km 移動するかを算出する. 長距離移動の 定義は最低 100km 以上とし,その距離以上移動する予定,かつ メールの配信日以降の日付で検索したユーザーのみレコメンド 対象ユーザー群として扱う.

# 4.2 送信するメールコンテンツの生成

抽出した対象ユーザーがルート検索時に指定した到着地を 基に、ホテルマスタデータからレコメンドするホテル情報を取得し、 以下のようなメールコンテンツを生成する.



図 1. 生成したメールコンテンツ

またレコメンドするホテルは、到着地に指定された場所より半径 10km 以内に存在し、距離の近い順とした.生成したメールは、 ユーザーがルートを検索した翌日、又は翌々日に配信されるよう 設定した.長距離移動ユーザーの抽出からメール配信までの流 れを下図に示す.



図 2. メール配信までの流れ

# 5. 検証結果

#### 5.1 メール配信結果

3 日間メールの配信を行ったところ、それぞれ以下のような結果となった.

|      | 表 1.メール配信結果 |        |            |           |  |  |
|------|-------------|--------|------------|-----------|--|--|
| 配信日  | 集計期間        | 配信数    | クリック数      | 予約数       |  |  |
| 12/6 | 10日間        | 77,065 | 134(0.17%) | 20(14.9%) |  |  |
| 12/8 | 10日間        | 53,235 | 106(0.20%) | 15(14.2%) |  |  |
| 1/19 | 10日間        | 44,112 | 108(0.24%) | 19(17.6%) |  |  |

集計期間は、メールを配信してから何日以内に予約に至った ユーザーをメール配信効果のあったユーザーとみなすかを指 す. 今回は全て10日間としたので、それぞれ12/6~12/15,12/8 ~12/17,1/19~1/28の期間に、メールをクリックして予約に至っ たユーザーの人数を予約数に記載している.予約数の括弧内 の数値は、クリック数に対するCVR(コンバージョンレート)を指す. 1/19 に関しては、対象者を200km 以上移動する予定のユーザ ーに変更したので配信数は減っているが、予約数のCVRを比 較すると向上していることが見て取れる.

# 5.2 予約に至ったユーザーの検索した条件

予約に至ったユーザーの移動距離と実際に移動するまでの 期間をマトリクスにしたものを図に示す.



図 4. 配信したユーザーに対する予約ユーザーの比率

横軸が何日前に検索したか,縦軸が移動距離,枠内の数値 が比率を指している.一瞥しただけでも,移動距離と実際に移動 する日までの間が長いほど予約する可能性が高まることが見て 取れる.

## 6. 考察とまとめ

#### 6.1 考察

検証の結果,移動距離が伸びるほど予約に至る可能性が高 まる傾向にあった.特に40-60日前にルート検索を行った予約 ユーザーではその傾向が顕著に出ており,最小値と最大値で約 14倍もの差がある.(図4参照)また距離だけでなく,検索日と実際に移動する日までの差が大きいほど予約に繋がりやすい傾 向が見て取れた.各セグメント別に見ると,約10倍-1000倍の 差が出ていることが確認できる.今回は試行回数が少ないため 一概には言えないが,回数を増やしても同様の結果が出てくる のではないかと思われる.今回の結果をもとに,より効果的に宿 泊情報を必要としているユーザーに対して,必要な情報を届け ることができるようになった.

通常トラベルを来訪していないユーザへの訴求の場合,既存 ユーザへの訴求よりも効果は乏しくなる傾向になるが,今回路線 データを利用することにより,トラベル既存ユーザに迫るレコメン ド施策の効果を確認できた.新規ユーザに対する施策の中では 非常に高いスコアといえる.今回の結果を利用して,距離や検索 日を最適化することで,さらに的確な潜在顧客にリーチできるよ うになると考えられる.

一方で、長距離移動ユーザーを抽出するために利用した乗 換案内では当日検索するユーザーが最も多く、1ヶ月以上先の 検索をするユーザーの数はそれほど多くない、より多くの潜在的 な旅行者を検知し情報を提供するには、乗換案内だけではなく 他のデータを用いて検知する必要がある。例えば、旅行者が事 前に検索するのはルートだけでなく、目的地周辺の観光施設や 飲食店の情報といった可能性も高い、そういった検索クエリから 旅行を計画していることが判別できれば、ルートを検索していな くとも潜在的な旅行者を抽出することができると考えられる。

またユーザーへのアプローチも、今回メールという手段を用い たが、そもそもメールが使っていない、他のメールに埋もれ見て いないユーザーも多数存在すると考えられる.予約に至ったユ ーザーの年齢層を調べたところ、40代以上のユーザーが90% 以上を占めていた.旅行に行きやすいのが金銭的に余裕の出 てくるこの年代なのかもしれないが、乗換案内のユーザー層等 を加味するとこの数値は非常に低いため、若年層がほとんどメ ールを利用しておらずリーチ出来ていない可能性を示唆してい る.乗換案内の場合、アプリやwebでルートを検索した時点で宿 泊施設をレコメンドするといったやり方の方が、全てのユーザー にリアルタイムで情報を届けられる.今後はメール以外のアプロ ーチ方法や乗換案内以外のデータ活用も検討していきたい.

# 6.2 結論

移動距離,及び検索してから実際に移動するまでの期間に着 目することで潜在的な旅行者を判別することができ,適切な宿泊 情報を提供することで,高い確率で予約に繋がることが判明した. この知見をもとに,サービス間の連携を強化し,より効果的な ユーザーへのアプローチを試みる.

- [E.Palumbo 17] E.Palumbo, and G. Rizzo, "Predicting Your Next Stop-over from Location-based Social Network Data with Recurrent Neural Networks", pp.1-8, RecTour 2017 (2017).
- [M. A-Ghossein 18] M. A-Ghossein, T. Abdessalem, and A. Barre, "Exploiting Contextual and External Data For Hotel Recommendation", pp.323-328, UMAP'18 (2018)

# ニューラル機械翻訳による公的文書平易化

Official document simplification using neural machine translation approach

丸山拓海\*1 山本 Takumi Maruyama Kazuhid

山本 和英\*1 Kazuhide Yamamoto

\*1長岡技術科学大学大学院 電気電子情報工学専攻

Electrical, Electronics and Information Engineering, Nagaoka University of Technology

Official documents are documents distributed at public facilities such as city halls, hospitals and schools. These documents contain a lot of important information for living. However, they are difficult for non-native speakers because they contain difficult vocabulary and expressions. Therefore, official documents must be simplified. We try to simplify official document using machine translation approach. We use a parallel corpus of the original and three kinds of simplified ones including literal translation, free translation and summary. They are rewritten by 40 Japanese teachers. We adapt several methods for low-resource machine translation such as pre-trained embeddings and sharing encoder, decoder and output embeddings (tied-embeddings). The result shows that Transformer can simplify official document using pre-trained embeddings and tied-embeddings in spite of low resource. Performance improvement using several methods of low resource machine translation shows that Transformer can improve performance more than other methods by extending training data.

## 1. はじめに

近年、たくさんの外国人が日本を訪れている。その数は年間 で 2,800 万人 \*1 にのぼる。 また、日本に住む外国人は 232 万 人\*<sup>2</sup>であり、増加の傾向にある。このような状況の一方、日 本社会においては、日本語で情報提供されることが多い。情報 提供の最も理想的な方法は、すべての外国人に対してそれぞれ の母語で情報を伝えることであるが、世界には多くの言語が存 在するため、現実的には不可能である。このような言語の選択 という問題を解決するための情報提供の一手段として、近年、 「やさしい日本語」という考え方が注目されている。 ここで、 「やさしい日本語」とは、簡単な語彙や文構造のみを用いて、 日本語に不慣れな外国人にもわかりやすくした日本語のことを 指す。 また、国立国語研究所の全国調査では、日本に住む外 国人のうち、英語を理解できる人の割合よりも、簡単な日本語 を理解できる人の割合の方が多いと報告されており [岩田 10]、 英語よりも簡単な日本語の方が外国人には伝わりやすいことが 知られている。

本研究では、公的文書を対象とする。公的文書とは、市役所 や病院、学校等の公共施設で配布される文書であり、これらの 文書は生活する上で重要な情報を多く含んでいる。しかし、日 本語初学者が学習する文に比べ、難解な語彙や公的文書に出現 する固有の表現も含み、理解が困難であるため、平易化が必要 な文書である。我々は、日本語教育者が公的文書の日本語を逐 語訳、意訳、要約の3段階の「やさしい日本語」に書き換えた ものをコーパスとし、機械翻訳的なアプローチにより、文単位 の平易化を試みる。

## 2. 関連研究

公的文書平易化の試みとして、 本らの研究がある。 彼らは次 のような手順に従って、 公的文書の平易化を行った [杢 13]。

- 1. 重要部分の抽出
- 2. 短文化
- 3. 表現意図を用いた図示への変換
- 4. 「やさしい日本語」への変換

ステップ1からステップ3までの処理によって、文の構造 を読みやすくしたのちに、彼らが構築した換言辞書を用いて、 語彙的な平易化を行っている。 平易化システムの出力を「日 本語としての正しさ」と「やさしさ」という観点で人手により 評価した結果、公的文書をやさしく書き換えることには成功し たが、抽出した換言ルールを直接適応させているため、文法的 な誤りや意味を保持できない場合が多いことが報告されてい る。また、直接的表現へ言い換えを行った研究 [Moku 12] で は、変換ルールの規模が小さく、平易化としての効果があまり 得られなかったことが報告されている。

一方で、松田らは、統計的機械翻訳を用いて公的文書を「や さしい日本語」へ変換する研究を行っている [松田 09]。BLEU による精度評価では、20 ポイントと低い値に留まった結果と なった。また、原文と原文から語彙的なレベルで平易化を 行った逐語訳、そして機械翻訳による翻訳結果の3つを人手 で、1:比較的良質、2:解読不能・翻訳誤り、3:変化なし、の3 段階に評価したところ、比較的良質な変換とされた翻訳結果は 7.5%と少なく、そのうちのほとんどが見出しのような短い句 であったことが報告されている。この理由として、対訳コーパ スが少ないことや、公的文書特有の記号や括弧表記がノイズに なっていることを指摘している。また、適切にドメインを設 定することによって、性能改善ができる可能性についても述べ られている。

機械翻訳の分野では、統計的機械翻訳の性能をはるかに 上回るニューラル機械翻訳が提案されている [Bahdanau 14, Luong 15, Gehring 17, Vaswani 17]。近年、テキスト平易化 においても、ニューラル機械翻訳を用いるアプローチが盛んに研 究されており [Maruyama 17, Nisioi 17, Zhang 17, Surya 18, Zhao 18]、既存の統計的機械翻訳をベースとしたモデルより

連絡先: 丸山拓海, 長岡技術科学大学大学院電気電子情報工学専 攻, 新潟県長岡市上富岡町 1603-1, maruyama@jnlp.org

<sup>\*1</sup> https://www.jnto.go.jp/jpn/statistics/visitor\_trends

<sup>\*2</sup> https://www.e-stat.go.jp

も、高い平易化性能を記録している。 ニューラル翻訳をベー スとしたモデルでは、学習に大量のデータが必要となるが、テ キスト平易化のための大規模な対訳コーパスを用意することは 容易ではない。

本研究では、ニューラル機械翻訳のモデルが公的文書の平易 化という言語資源が少ないタスクにおいて、どの程度効果を発 揮できるのかを検証する。

# 3. データセット

本研究では、杢らが利用した平易化コーパス [杢 13] と同じ もの (以下、「公的文書書き換えコーパス」と呼ぶ) を利用す る。これは「やさしい日本語」のプロジェクトで作成されたも のであり、約 40 名の日本語教師が、市役所や病院、学校等の 公共施設で配布される公的文書を「やさしい日本語」に書き換 えたものである。 このコーパスは原文である公的文書 1,101 文書と共にその逐語訳、意訳、要約という 3 段階の翻訳を含 む対訳コーパスである。 それぞれの翻訳の位置付けは下記の 通りである。

- 逐語訳:日本語文の難解な語彙や句をやさしい表現に、書き換えたもの。
- 意訳: 文意等を損なわないように可能な限り、やさしい 表現に書き換えたもの。
- 要約:可能な限り文を平易化したもの。

これらは一定の文法基準 [庵 08] と旧日本語能力試験 2 級 (現 試験における N2) レベルの語彙のみに制限されている。 コー パスにおける「やさしい」の基準は日本語教師の主観である。 各翻訳の例を以下に示す。

- 原文:ニュース等で報道されておりますように、世界的 に新型(豚)インフルエンザの流行が危惧されています。
- 逐語訳:ニュースなどにもあるように、世界中で新型インフルエンザの流行が心配されています。
- 意訳: さて, ニュースでもありますが, 世界中で新型イ ンフルエンザが増えています。
- 要約: さて, 世界中で新型インフルエンザが増えています.

上記の例では、原文に対して3種類の翻訳文が存在するが、 場合によっては、翻訳するのではなく原文全体を削除する事例 も存在する。そのため、原文と逐語訳・意訳・要約のそれぞ れの文数は必ずしも一致しない。本コーパスの文数、平均文 長、語彙数を表1に示す。

表 1: 公的文書書き換えコーパスの統計量

|      |        | 1          | - 1/4/ |        |
|------|--------|------------|--------|--------|
|      | 原文     | 逐語訳        | 意訳     | 要約     |
| 文数   | 35,861 | 35,809     | 32,841 | 27,588 |
| 平均文長 | 25.32  | 28.55      | 26.20  | 24.74  |
| 語彙数  | 14,848 | $11,\!337$ | 10,243 | 9,259  |



図 1: Transformer

#### 4. 実験方法

今回は、機械翻訳モデルを利用し、原文から逐語訳・意訳への文単位の変換を試みる。我々は公的文書書き換えコーパスを、学習データ34,000文、開発データ1,000文、評価データ861文のように分割した。これらのデータを用いて、翻訳モデル(4.1節)をトレーニングし、モデルの出力結果をBLEU,SARI(4.2節)により評価する。

#### 4.1 Transformer

本研究では、翻訳モデルとして、Vaswani らが提案している Transformer を用いる [Vaswani 17]。モデルの概略図を図1 に示す。 Transformer の encoder(図1左側) は、 multi-head self-attention と Feed Forward Neural Network で構成される層をL 段積み上げた構成となっている。 multi-head self-attention は、次式に従って、前段の隠れ状態  $e_{(s',l)}$  から隠れ状態  $e_{(s',l)}$  を計算する。

$$e_{(s,l)} = \sum_{s'} \alpha^{enc}_{(s',l)} e_{(s',l-1)}$$
 (1)

$$\alpha_{(s',l)}^{enc} = a(e_{(s',l)}, e_{(s',l-1)}, H)$$
(2)

ここで、 $\alpha_{(s',l)}^{enc}$ は、l 層目、s'ステップの attention distribution を意味する。 $a(\cdot)$ を multi-head self-attention 表す関数、Hはヘッド数を意味する。一方、decoder(図 1 右側)は、

encoder と同様な機構に加え、encoder の出力に対する attention 機構が存在する。1 段目の multi-head attention では、 encoder と同様に次式に従って隠れ状態  $d_{(s,l)}$  を計算する。

$$d_{(s,l)} = \sum_{s'} \alpha_{(s',l)}^{dec} d_{(s',l-1)}$$
(3)

$$\alpha_{(s',l)}^{enc} = a(d_{(s',l)}, d_{(s',l-1)}, H)$$
(4)

2 段目の multi-head attention では、encoder の出力と前段 の multi-head attention による隠れ状態から、次式により、文 脈ベクトル  $c_{(s,l)}$ を計算する。

$$c_{(s,l)} = \sum_{s'} \alpha_{(s',l)}^{dec2} e_{(s',l-1)}$$
(5)

$$\alpha_{(s',l)}^{enc} = a(d_{(s',l)}, e_{(s',l)}, H)$$
(6)

このモデルは、対数尤度  $P = log P(O|I, \theta)$ を最大化するようにトレーニングされる。ここで、Oは平易文、Iは原文、 $\theta$ はモデルのパラメータを意味する。

エンコーダとデコーダの単語埋め込み層では、学習済みの 単語ベクトル nwjc2vec[浅原 17](pre-emb.)を用いる。また、 エンコーダの単語埋め込みとデコーダの入出力の単語埋め込 み層を共有する (tied-emb.)。モデルのハイパーパラメータは、 Zhao らの研究に倣い、エンコーダとデコーダを 4 層、それぞ れのアテンション機構のヘッド数を 5、ドロップアウトを 0.3 に設定している。また、各単語埋め込み層の次元は、nwjc2vec に合わせ、200 次元としている。

#### 4.2 評価方法

テキスト平易化では、一般的に流暢性、意味保持性、平易さ の3つの観点からモデルの出力結果を評価する。ここで、流 暢性とは、日本語として正しい文を出力できているかを測る 評価尺度であり、意味保持性とは、原文(モデルに対する入力 文)とモデルが出力した文の意味が一致するかどうかを測る評 価尺度である。また、平易さとは、出力文が入力文に比べ、ど の程度簡単になっているかを示す評価尺度である。これらを 自動で評価する方法として、BLEUと SARI[Xu 16]が用いら れる。

BLEUとは、機械翻訳の評価で広く用いられる評価尺度で あり、テキスト平易化においては、流暢性と意味保持性に関し て正の相関があることが知られている [Vu 18]。

SARI は、最近提案された平易化の評価指標であり、平易 化で行われる単語の追加、削除、保持の3つの操作における n-gramのprecision及びrecallである。この尺度は、平易化 すべき部分を適切に平易化した際に、高いスコアを与える仕組 みとなっている。具体的には、モデルが参照文にのみ存在す る単語を追加した場合や参照文に存在する単語をそのまま出 力(保持)した場合、参照文にない単語を削除した場合などに 高いスコアを与える。一方、入力文をそのまま出力するような モデルに対してはペナルティが与えられるように構成されてい る。実験的評価より、SARIが人間の平易さの判断とよく相 関があることを示している[Xu 16, Vu 18]。

#### 5. 結果と考察

原文から逐語訳への変換及び原文から意訳への変換の結果を 表2に示す。Originは、原文をそのまま出力した際の結果で ある。NTSは、Nisioiらのニューラル機械翻訳によるテキス ト平易化モデルである。ハイパーパラメータは、先行研究と同様に設定している。ただし、単語埋め込み層は、nwjc2vecの次元数に合わせて、200次元に設定している。

表 2: 実験結果

|             | 逐語訳   |              | 意     | 訳     |
|-------------|-------|--------------|-------|-------|
|             | BLEU  | SARI         | BLEU  | SARI  |
| Original    | 34.24 | 16.65        | 28.14 | 14.17 |
| NTS         | 36.49 | 46.47        | 29.46 | 41.85 |
| + pre-emb.  | 34.60 | 45.17        | 28.87 | 41.31 |
| + tied-emb. | 34.85 | 44.94        | 29.69 | 41.38 |
| Transformer | 33.88 | 45.94        | 18.61 | 35.56 |
| + pre-emb.  | 34.52 | 46.01        | 24.65 | 39.90 |
| + tied-emb. | 41.89 | <b>48.43</b> | 29.41 | 41.63 |

実験結果より、NTS, Transformer どちらも、Original を上 回る BLEU, SARI を記録しており、流暢性を保ちつつ、平易 化できていることが分かる。 NTS の結果に注目すると、逐語 訳への変換、意訳への変換どちらの場合においても、学習済み の単語ベクトルの使用 (NTS + pre-emb.) やエンコーダの単 語埋め込みとデコーダの入出力の単語埋め込み層の共有 (NTS + tied-emb.) を行なっても、BLEU や SARI の向上にあまり 効果がないことが分かる。 一方で、Transformer の結果に着 目すると、それらの工夫が大きく効果を示していることが分か る。特に、単語埋め込み層の共有 (Transformer + tied-emb.) の効果は大きく、逐語訳においては、そのままの Transformer に比べ、BLEUを 8.0 ポイント、SARI を 2.5 ポイント向上さ せている。 意訳においては、BLEU を 11 ポイント、SARI を 6.1 ポイントを改善させている。 これらの結果は Transformer において、学習データを拡張させることでさらなる性能改善が 可能であることを示している。

#### 6. まとめ

我々は公的文書を対象に平易化を試みた。 公的文書とは、 市役所や病院、学校等の公共施設で配布される文書であり、生 活する上で重要な情報を多く含んでいる。 しかし、日本語初 学者が学習する文に比べ、難解な語彙や公的文書に出現する固 有の表現も含み、理解が困難であるため、平易化が必要な文書 である。

本研究では、約40名の日本語教師がが公的文書の日本語を 逐語訳、意訳、要約の3段階の「やさしい日本語」に書き換え たものをコーパスとし、機械翻訳的なアプローチにより、文単 位の平易化を行った。また、学習済みの単語ベクトルの使用 やエンコーダの単語埋め込みとデコーダの入出力の単語埋め込 み層の共有を行い、モデル側で学習データの不足を補うことを 試みた。

結果として、Transformer に学習済みの単語ベクトルやエン コーダの単語埋め込みとデコーダの入出力の単語埋め込み層 の共有を利用することにより、小規模な学習データであっても 適切に平易化できることを示した。 学習済みベクトルや単語 埋め込み層の共有による性能改善は、Transformer において、 学習データの拡張によってさらなる改善が可能であることを示 している。 今後は、学習データの擬似的な拡張や転移学習と いった方法を検討していきたい。

- [Bahdanau 14] Dzmitry Bahdanau, Kyunghyun Cho, Yoshua Bengio: Neural Machine Translation by Jointly Learning to Align and Translate, arXiv:1409.0473 (2014).
- [Gehring 17] Jonas Gehring, Michael Auli, David Grangier, Denis Yarats, Yann N. Dauphin: Convolutional Sequence to Sequence Learning, arXiv:1705.03122 (2017).
- [Luong 15] Minh-Thang Luong, Hieu Pham, Christopher D. Manning: Effective Approaches to Attention-based Neural Machine Translation, Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, pp.1412-1421 (2015).
- [Maruyama 17] Takumi Maruyama, Kazuhide Yamamoto: Sentence Simplification with Core Vocabulary, Proceedings of the International Conference on Asian Language Processing, pp.363-366 (2017).
- [Moku 12] Manami Moku, Kazuhide Yamamoto, Ai Makabi: Automatic Easy Japanese Translation for information accessibility of foreigners, Proceedings of the Workshop on Speech and Language Processing Tools in Education, pp.85-90 (2012).
- [Nisioi 17] Sergiu Nisioi, Sanja Štajner, Simone Paolo Ponzetto, Liviu P. Dinu: Exploring Neural Text Simplification Models, Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), pp.85-91 (2017).
- [Surya 18] Sai Surya, Abhijit Mishra, Anirban Laha, Parag Jain, Karthik Sankaranarayanan: Unsupervised Neural Text Simplification, arXiv:1810.07931 (2018).
- [Vaswani 17] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin: Attention Is All You Need, 31st Conference on Neural Information Processing Systems (NIPS 2017), pp.5998-6008 (2017).
- [Vu 18] Tu Vu, Baotian Hu, Tsendsuren Munkhdalai, Hong Yu: Sentence Simplification with Memory-Augmented Neural Networks, Proceedings of NAACL-HLT 2018, pp.79-85 (2018).
- [Xu 16] Wei Xu, Courtney Napoles, Ellie Pavlick, Quanze Chen, Chris Callison-Burch: Optimizing Statistical Machine Translation for Text Simplification, Transactions of the Association for Computational Linguistics, Vol.4, pp.401-415 (2016).
- [Zhang 17] Xingxing Zhang, Mirella Lapata: Sentence simplification with deep reinforcement learning, Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, pp.584-594, (2017).

- [Zhao 18] Sanqiang Zhao, Rui Meng, Daqing He, Andi Saptono, Bambang Parmanto: Integrating Transformer and Paraphrase Rules for Sentence Simplification, Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, pp.3164-3173 (2018).
- [浅原 17] 浅原 正幸,岡 照晃:nwjc2vec:『国語研日本語ウェブ コーパス』に基づく単語の分散表現データ,言語処理学会 第 23 回年次大会 発表論文集, (2017).
- [庵 08] 庵功雄:「やさしい日本語」をめぐって.多文化共生 社会における日本語教育研究会,第4回研究会, pp.1-12 (2008).
- [岩田 10] 岩田 一成: 言語サービスにおける英語志向:「生活のための日本語:全国調査」結果と広島の事例から(j特集)、日本社会の変容と言語問題),社会言語科学会, Vol.13, No.1, pp.81-94 (2010).
- [松田 09] 松田真希子:やさしい日本語への自動言い換えシス テムの開発,日本語教育学会大会 2009(平成 21)年度春季 大会予稿集, pp.91-93 (2010).
- [杢 11] 杢 真奈見,山本 和英:公的文書に対する「やさしい日本語」換言辞書作成のための調査,言語処理学会 第17回 年次大会 発表論文集, pp.376-379 (2011).
- [杢 13] 杢 真奈見,山本 和英: 「やさしい日本語」変換シス テムの試作,言語処理学会 第 19 回年次大会 発表論文集, pp.678-681 (2013).

# 擬似誤りコーパスを用いた天気予報原稿のニューラル誤り検出

Neural Error Detection for Weather Forecast Manuscript by Pseudo Error Corpus

白井稔久\*1 Naruhisa Shirai N

萩行正嗣<sup>\*2</sup>小町守<sup>\*1</sup> Masatsugu Hangyo Mamoru Komachi

誤りが含まれる文章対

\*<sup>1</sup>首都大学東京 \*<sup>2</sup>株式会社ウェザーニューズ Tokyo Metropolitan Univercity WEATHERNEWS INC.

In this paper, we propose a neural method for detecting errors in Japanese weather forecast manuscripts. First, we analyze errors in weather forecasts to understand how native Japanese mistake. According to our analysis, we found native Japanese tend to cause errors in three types: particle error, conversion error and typo. in this paper, we focus on particle and conversion errors. However, any corpora written by native Japanese are not large enough for supervised learning. Therefore we use pseudo error corpus to augment training data. We generate pseudo particle errors by confusion matrix and we also generate pseudo conversion errors by back transliteration. As a result, we find pseudo corpus is effective for neural error detection for text written by native Japanese.

## 1. はじめに

天気予報原稿は一般的に人手で記述されているため, 誤り を含んでいる場合がある.それらの誤りは公開する前に校正す る必要がある.通常これらの誤りは人手での多重チェックなど で公開前に校正されているが,この校正には大きなコストがか かっている.

日本語母語話者が記述したテキストの自動誤り検出を行う には、テキストに誤りがアノテーションされているコーパスが 少ないため、教師あり学習の手法をとることは困難である.ま た、日本語学習者が記述したテキストに比べて誤りが少なく、 加えて誤り傾向が異なる可能性があり学習者のコーパスを学習 にそのまま使用することは不適切であると考える. RNN 言語 モデルを用いた誤りの自動検出 [9] では、誤警報率が非常に高 く日本語母語話者の誤り検出が難しいことが報告されている.

そこで我々はまず誤り傾向を分析するためウェザーニューズ<sup>\*1</sup>の天気予報原稿コーパスを用いた.このコーパスは2年分の天気予報原稿があり,編集前の原稿と編集後の原稿がペアになっているため,擬似的に校正コーパスとみなすことができる.実際に含まれていた編集前後の文章対を図1に示す.このコーパスを用いた分析の結果,誤りの大部分は誤変換,助詞誤り,タイポの3つに分類できることが分かった.

そのため我々は教師あり学習が適用可能な誤変換と助詞誤り に着目しそれらの検出を行うことにした.しかし,それらを教 師ありの手法を用いて検出するにはアノテーションされている データ数が少ない.そこで我々は小規模データでの教師あり学 習に有用であることが分かっている擬似コーパス [4] でコーパ スを拡充するために,擬似誤りを生成した.

擬似誤りの生成は助詞の擬似誤りと誤変換の擬似誤りで分 けて生成した.助詞の擬似誤りに関しては,助詞ごとに誤り傾 向を分析し,その傾向に従って分布を作り擬似的な誤りを生成 した.誤変換に関しては分析したコーパス全体で単語単位で誤 変換をしている割合を基に,単語を別の同音の単語に変換して 擬似誤りを生成した.

本研究の貢献は以下の2つである.

• 天気予報原稿の誤り検出のためのコーパスを分析した

連絡先: 白井 稔久, shirai-naruhisa@ed.tmu.ac.jp

\*1 https://weathernews.jp

編集前 今日は雲優勢のスッキリしない空。 髪が乱れるほど<u>の</u>風が強いのでご注意下さい。 日差しが少なくてもムシ暑くなります。 **編集後** 今日は雲優勢のスッキリしない空。 髪が乱れるほど風が強いのでご注意下さい。 日差しが少なくてもムシ暑くなります。 誤りが含まれない文章対 編集前 今日も雨が降り続きます。 激しく降る可能性があるので大きめの傘やレインコート・ブーツが良さそうです。 河川の増水・道路冠水・土砂災害にご注意下さい。 編集後 -今日も雨が降り続きます。 激しく降る可能性があるので大きめの傘やレインコート・ブーツが良さそうです。 河川の増水・道路冠水・土砂災害にご注意下さい。

図 1: 編集前後の文章対の例. 下線部が編集された部分である.

 擬似誤り生成によるコーパスの拡充が日本語母語話者が 記述したテキストのニューラル誤り検出に関して有用で あることを示した

#### 関連研究

日本語母語話者が記述したテキストの誤り訂正の研究とし て,新納らは平仮名 n-gram を用いて誤りを検出し,訂正する 手法を提案した [5].また,南保らは文節内の特徴からルール を自動作成し,ルールベースで,日本語の助詞誤りを検出し, 校正する手法を提案した [8].これら2つの手法は我々と同じ く,日本語母語話者が記述したテキストを対象にしていて,特 に南保らの研究とは助詞誤りに着目した点で我々の研究と共通 する.一方我々の研究では教師あり学習を用いている.

また,日本語学習者が記述したテキストに対する自動訂正 の研究も広く進められている.今村らは日本語学習者が助詞 を間違えやすいことを指摘し,その助詞を,間違えやすい助詞 の単語テーブルを用いることによって修正する手法を提案した [4].また,今村らは小規模の誤りデータから擬似誤りを生成 し,コーパスを拡充した.この研究は助詞に着目した点,擬似 誤りを生成した点で我々と共通するが,我々の提案手法では助 詞だけではなく,誤変換も対象としていて,誤りの検出のみで 訂正はしない. また, 今村らは訂正に CRF を用いているが, 本研究では Bi-LSTM を用いた RNN を使った.

水本らは, 語学学習 SNS である Lang-8 から添削ログを抽 出しコーパスを作成し, そのコーパスを用い, 文字単位での修 正と, 文字-単語間での修正の二つの手法を提案した [6]. 彼ら が提案した手法は, 統計的機械翻訳モデルを用いて誤りを修正 するものである. 我々の研究とコーパスを作成した点で共通す るが, 我々の提案手法では擬似誤りを生成してコーパスの拡充 を図っている. また, 本研究では RNN を用いている.

# 3. 擬似誤りコーパスの作成

我々は教師あり学習を行うには少ないコーパスを拡充する ために,擬似誤りコーパスを作成した.擬似誤りコーパス内に 含まれる擬似誤りは,助詞誤りと誤変換で異なる方法で作成 した.擬似的な助詞誤りは実際に天気予報原稿コーパスで誤っ た助詞を基に誤りを作成した.擬似的な誤変換は天気予報原稿 コーパスに含まれる誤変換の割合で元の単語を誤変換させて作 成した.また,それらの誤変換は元の単語を平仮名にした後に 再変換し,元の単語と異なるものに置換することで作成した.

#### 3.1 天気予報原稿の誤り傾向分析

誤りの傾向を分析するために本研究ではウェザーニューズ 社の天気予報原稿コーパスの分析を行った.このコーパスには 2014 年と 2015 年の 2 年分の天気予報原稿の,編集前の文章 と編集後の文章対が入力されている.それらの文章対の総数は 100,931 対である.

これらの文章対における編集の内容は、文法誤りなどの校正 だけでなく、原稿内容や表現を大きく書き換えるようなものも 含まれる.それらを除外するために、編集前後の文章間の文字 単位での編集距離が1以上5以下の文章対を抽出した.本研 究で学習データとして用いた2014年のデータを対象に抽出さ れた文章対は2,575対で、文対数は7,765文対だった.また、 天気予報原稿内に5文字以下の文が含まれている可能性は非 常に低いと考え、編集距離で抽出した文章対に編集前後で文数 が異なるものは含まれていないと判断した.

その後,日本語形態素解析システム JUMAN7.0\*2 を用いて 文を形態素解析し,編集距離を用いた動的計画法で形態素単位 でアライメントをとり,異なり形態素対およびその異なりが含 まれる文を人手で確認し,実際に誤りであると判断したものの 編集前後の形態素対を記録し分析した.その結果誤りは大きく 分けて誤変換,助詞誤り,タイポの3つに分類できることが分 かった.

#### 3.2 誤りタグ付きコーパスの作成

3.1 項と同様にして誤りであると判断した単語対にアノテー ションを付与し、学習データとしてコーパスを作成した. 誤り にアノテーション付与する際、以下のルールに基づきアノテー ションを付与した. 下記のルールに基づきアノテーションを付 与する例を図 2 に示す.

- 置換 編集前の単語と編集後の単語を置換して文が成立する場合,その単語に誤りタグを付与
- **文の不成立**編集前の文が成立していない場合に原因と思われ る単語に誤りタグを付与
- 余字編集前の単語を削除すると文が成立する場合その単語に 誤りタグを付与

\*2 http://nlp.ist.i.kyoto-u.ac.jp/index.php?JUMAN

置換
編集前: こまめに水分を<u>取って</u>熱中症対策を万全にしてください。
編集後: こまめに水分を摂って熱中症対策を万全にしてください。
文の不成立
編集前: 室内でも熱中症になることがあり体調管理は万全に。
編集後: 室内でも熱中症になることがある体調管理は万全に。
余字
編集後: 今日の 朝朝朝は雨の可能性がありますが~
脳字
編集前: 今日は夏空広がりますが急な雨もあります。
編集後: 今日は夏空がますが急な雨もあります。

図 2: ルールに基づいてタグを付与した例. 下線部の単語に誤 りのタグを付与する. 編集後の文は編集前の文中における単 語にアライメントを取っている単語の列であるため,実際の文 ではない.また,編集前の文中における1単語に対して編集後 の文中における複数の単語がアライメントを取っている場合, 最も文頭に近い単語のみを出力している.

表 1: 学習・開発・評価データの詳細

|       | 学習      | 開発      | 評価      |
|-------|---------|---------|---------|
| 誤変換   | 90      | 5       | 2       |
| 助詞誤り  | 76      | 5       | 6       |
| タイポ   | 190     | 8       | 20      |
| 誤りの総数 | 356     | 18      | 28      |
| 総文数   | 7,765 文 | 3,842 文 | 2,971 文 |

- 脱字 編集前の文に明らかに単語が不足している場合,不足していると思われる位置の直後の単語に誤りタグを付与
  - 上記に該当しない単語は誤っていないものとして誤りタグを 付与しない

また、上記とほぼ同様の手順で誤りがアノテーションされ ているテストデータも作成した.相違点は、2014年のデータ ではなく2015年のデータを対象にしたこと、編集距離が1以 上5以下の文章対ではなく0以上5以下の文章対を用いたこ と、そうして抽出された文章対の中から、季節や時期による文 章の内容の偏りを防ぐために各月ごとに200対ずつランダム サンプリングしたことである.その結果2,400文章対からなる 6,813文のアノテーション付きのデータを作成した.さらに作 成したコーパスを各月から100対ずつ、合計1,200対ずつ開 発データと評価データに分割した.学習データ、開発データ、 評価データ誤りの種類毎の件数、総文数を表1に示す.

#### 3.3 擬似誤りを含む文の生成

本研究では今回作成したコーパスが小規模であることから, 小規模のコーパスでも誤りが検出できるよう擬似的に誤りを作 成した.本研究では誤変換と助詞誤りを対象に擬似誤りを生成 し,学習データの拡充を行う.

学習者が記述したテキストの擬似的な誤りの生成は一般的 に実際に誤ったような誤りの生成割合で行われる [4]. しかし, 予備実験によって本コーパスにおいてはこの手法はあまり有用 でないことが分かった.そこで,本研究では 3.2 項で作成した コーパスの誤った単語対を基に,一様分布を用いて抽出前の全 ての編集後の文章を誤らせることで擬似的に誤りを生成した.





図 3: 擬似誤変換生成の例

図 4: 擬似助詞誤り生成の例

我々は誤変換はどのような単語に対しても起こりうると考え た.そこで,作成したコーパスの全単語を定めた割合に基づき 再変換し,擬似的な誤変換を生成した.誤変換の作成は1度単 語を京都テキスト解析ツールキット KyTea [2] を用いてかな に直し,その後 Google 日本語入力 API \*<sup>3</sup> を用いて,ランキ ング上位5件から無作為に元の単語と異なる単語を選び,擬似 的な誤変換を作成した.擬似誤変換の生成の例を図3に示す.

助詞の誤りに関しては、2つの方法で擬似誤りを生成した.1 つは3.2項で作成した学習コーパス中で出現した編集後の各助詞 wについて編集前では誤っている各単語 $w_i = \{w_1, w_2, ..., w_L\}$ と元の単語に対して一様に確率を割り当てる一様分布に従い擬 似的な助詞の誤りを生成した.また、元の単語を選んだ場合誤 りタグは付与しない.助詞の擬似誤り生成の例を図4に示す. もう1つは擬似誤変換の生成と同様に一定の割合で助詞誤り を発生させる方法である.全ての助詞に対して一定の割合に基 づきその助詞を誤らせるか決め、誤らせる場合学習コーパス 内で出現した誤り方から無作為に1つ選択肢誤らせる.また、 学習コーパス内で誤らなかった助詞を誤らせることが選択され た場合、その助詞を削除することで擬似助詞誤りを生成した.

#### 4. 助詞誤りと誤変換の検出実験

#### 4.1 誤り検出器

本研究では Bi-LSTM [1] を用いた誤り検出器で実験を行う. 入力文  $S = (w_1, w_2, \cdots, w_n)$ の各単語  $w_t$  は単語ベクトル  $e_t \in \mathbb{R}^{de \times 1}$  に変換される. n は文長であり, de は単語ベクト ルの次元である. 単語ベクトルから LSTM により順方向の隠 れ層  $\overrightarrow{h_t} \in \mathbb{R}^{dh \times 1}$  と逆方向の隠れ層  $\overleftarrow{h_t} \in \mathbb{R}^{dh \times 1}$  を作成する. dh は隠れ層の次元とする.  $\overrightarrow{h_t} \succeq \overleftarrow{h_t}$  を連結することで最終的 な隠れ層  $h_t^{(1stm)} \in \mathbb{R}^{2dh \times 1}$ を獲得する. 隠れ層  $h_t^{(1stm)}$ を以下 のように線形変換しソフトマックス関数を使い正誤タグの確率 分布  $p_t \in \mathbb{R}^{t \times 1}$ を獲得する. t はタグのサイズであり, 正誤の

表 2: 実験に用いた各学習データの文数.「orig」は 3.2 項で作成したコーパス,「pp」は助詞の擬似誤りを生成したコーパス,「conv」は誤変換を擬似生成したコーパスを示す.

| 学習データ        | 文数        |
|--------------|-----------|
| orig         | 7,765 文   |
| orig+pp      | 115,744 文 |
| orig+conv    | 115,744 文 |
| orig+pp+conv | 225,305 文 |

どちらかのタグを予測するためサイズは2である.

$$p_t = \operatorname{softmax}(W_h h_t^{(lstm)} + b_h) \tag{1}$$

 $W_h \in \mathbb{R}^{v \times dh}$  は重み行列であり,  $b_h \in \mathbb{R}^{v \times 1}$  はバイアスである. v は語彙サイズの次元数である.

誤差関数である loss は交差エントロピーによって以下の式 を用いて計算される.

$$loss = -\sum y_t \log p_t \tag{2}$$

 $y_t$  は正解のタグであり学習データ内で正誤のどちらかが付与 されている.

#### 4.2 実験設定

入力はあらかじめ学習済みの朝日新聞単語ベクトル [7] を用 いてベクトル化した.このときの埋め込み層は 300 次元であ る.このモデルは PyTorch 1.0 で実装し,出力層の値を基に 誤っている確率を出力する.この確率が 0.5 を超えているもの を誤りとして検出する.隠れ層は開発データを用いて 1 層で 1024 次元に定めた.また,出力層は 200 次元,初期化は -0.1 から 0.1 の間でランダムに初期化した.バッチサイズは 64,最 適化には ADADELTA [3] を用いて学習した.

学習には 3.2 項で作成したコーパスとそれに擬似誤りを生成 したコーパスを用いる.また,今回の誤り検出では擬似誤りを 加えたことによる有用性を確かめるために助詞誤りと誤変換の みを誤りとして検出する.よって学習データのタイポの誤りは 誤りでないものとして学習した.開発データを用いて各エポッ クで再現率が最大のときに適合率が最も高いエポックのもの を評価データの実験に用いた.また各データの文量を表 2 に 示す.

評価には適合率と再現率を用いた.適合率はシステムが誤り だと判断した単語の内,実際に誤りである割合である.再現率 はコーパス内の検出の対象である全ての誤りである単語の内, システムが検出した誤りの割合である.

#### 4.3 実験結果

実験結果を表3に示す.表を見ると擬似誤りコーパスを学 習データとして追加すると適合率,再現率ともに上昇している ことがわかる.ただ,再現率は全体的に低く,誤りをほとんど 検出できていないことがわかる.また,3.2項で作成したコー パスだけでは学習のための文数が非常に少ないため誤りを検出 することができていないことが分かる.

また,コーパス内で擬似誤りを生成する割合を変えて実験 した結果を表4に示す.この実験のデータ量は orig+conv, orig+pp と同一である.表を見ると擬似誤りを生成する割合を 増やすと性能が向上していることが分かる.特に助詞誤りは生 のが著しく向上している.また,予備実験で行った助詞の擬似 誤りを実際に誤った分布に従って生成する実験で擬似誤りを生 成する割合を増やしたが,特に性能の向上が見られなかった.

<sup>\*3</sup> https://www.google.com/inputtools/try/

表 3: 誤り検出実験の結果. pp\*は元の誤り分布に従い助詞誤 りを生成したコーパスで学習したものである. @以下の数字は 擬似誤りの生成割合である.

| 学習データ                  | 分割 | 適合率  | 再現率  |
|------------------------|----|------|------|
| orig                   | 開発 | 0.00 | 0.00 |
|                        | 評価 | 0.00 | 0.00 |
| orig+pp*               | 開発 | 0.00 | 00.0 |
|                        | 評価 | 0.00 | 00.0 |
| orig+pp                | 開発 | 0.21 | 20.0 |
|                        | 評価 | 0.26 | 25.0 |
| orig+conv              | 開発 | 1.75 | 20.0 |
|                        | 評価 | 0.00 | 0.00 |
| orig+pp*+conv          | 開発 | 0.16 | 20.0 |
|                        | 評価 | 0.00 | 0.00 |
| orig+pp+conv           | 開発 | 1.38 | 50.0 |
|                        | 評価 | 0.29 | 37.5 |
| orig+pp@50.0%+conv@50% | 開発 | 1.03 | 70.0 |
|                        | 評価 | 0.71 | 50.0 |

# 5. 分析

助詞誤りに関しては生成割合を一様分布に変えた結果,適 合率は非常に低いが再現率は上がり,一定の生成割合で助詞誤 りを生成した結果,適合率と再現率両方の上昇が見られた.こ のことから助詞の誤り検出に関しては母語話者の誤る割合より も大きい割合で擬似誤りを生成した方が,性能が向上すること が分かった.又,一定の割合での助詞誤りを生成したコーパス で学習したモデルは,"は"や"が"の助詞誤りは検出できる 傾向にあった.これは"は"と"が"は元のデータ内でも誤り 件数と誤り方の種類も多いため,ほとんどの誤り方を再現でき たからではないかと考える.

誤変換に関しては生成割合を上昇させた結果,評価データ 内の誤変換は2件とも検出できているが開発データ内の誤変 換は2件検出できていない.これは両方とも"うだるような" が"うだる様な"に変換されてしまっているものだった.この 変換を学習データ内には存在したが単語分割が開発データでは "よう\_な"と分割されていたのに対し,学習データでは"よ うな"と分割されていたため,実質学習データ内に存在しない 誤りになってしまったためだと考える.

助詞誤りの誤検出に関しては"は","の","を"の誤検出 が多く見られた.この3つの助詞は全ての擬似助詞誤り生成 法で誤りとして生成する割合が他の助詞よりも高いため,誤り として誤検出してしまう傾向にあるのではないかと考える.

誤変換の誤検出に関しては"熱"という単語をよく誤検出し てしまう傾向にあった.これは学習データ内の"熱"という単 語ほとんどに誤りのアノテーションが付与されており,出現し てしまうこと自体が誤りだと認識したためだと考える.

## 6. おわりに

本研究では天気予報原稿の誤り検出において教師あり学習 を行うためのコーパスの作成と、そのコーパスを拡充するた めに実際に日本語母語話者が誤った確率を基に擬似誤りの生成 を行なった.擬似誤りを生成する提案手法は結果として日本語 母語話者が記述した日本語テキストのニューラル誤り検出に 有用であることが分かった.加えて実際の誤る割合,および分 布に従って擬似誤りを生成するよりも擬似誤りの生成割合を

| 表 | 4: | 擬似誤り | の生成割合 | を変えた | :実験結果 |
|---|----|------|-------|------|-------|
|   |    |      |       |      |       |

|       |    | orig+conv |      | orig | +pp  |
|-------|----|-----------|------|------|------|
| 生成割合  | 分割 | 適合率       | 再現率  | 適合率  | 再現率  |
| 0.01% | 開発 | 0.00      | 0.00 | 0.00 | 0.00 |
|       | 評価 | 0.00      | 0.00 | 0.00 | 0.00 |
| 0.1%  | 開発 | 3.30      | 30.0 | 0.00 | 0.00 |
|       | 評価 | 0.00      | 0.00 | 0.00 | 0.00 |
| 1.0%  | 開発 | 0.79      | 20.0 | 13.3 | 20.0 |
|       | 評価 | 0.00      | 0.00 | 16.6 | 12.5 |
| 10.0% | 開発 | 0.90      | 30.0 | 8.33 | 10.0 |
|       | 評価 | 0.31      | 12.5 | 7.14 | 12.5 |
| 20.0% | 開発 | 0.71      | 30.0 | 3.03 | 30.0 |
|       | 評価 | 0.52      | 25.0 | 3.09 | 37.5 |
| 30.0% | 開発 | 0.69      | 30.0 | 0.77 | 40.0 |
|       | 評価 | 0.49      | 25.0 | 1.13 | 62.5 |
| 40.0% | 開発 | 0.74      | 30.0 | 1.26 | 50.0 |
|       | 評価 | 0.51      | 25.0 | 1.47 | 62.5 |
| 50.0% | 開発 | 1.50      | 30.0 | 1.24 | 50.0 |
|       | 評価 | 1.03      | 25.0 | 1.52 | 62.5 |

上げる方がモデルの性能が向上することが分かった.しかし, Bi-LSTM を用いたモデルでの検出は未知の誤りの検出が非常 に困難であることが分かった.また,本研究の提案手法では適 合率が低いため,適合率を上げる手法を検討する必要がある.

- Alex Graves and Jürgen Schmidhuber. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, Vol. 18, pp. 602–10, 07 2005.
- [2] Graham Neubig and Shinsuke Mori. Word-based partial annotation for efficient corpus construction. *LREC*, pp. 2723– 2727, 2010.
- [3] Matthew D. Zeiler. ADADELTA: an adaptive learning rate method. CoRR, Vol. abs/1212.5701, , 2012.
- [4] 今村賢治,齋藤邦子,貞光九月,西川仁.小規模誤りデータからの
   日本語学習者作文の助詞誤り訂正.言語処理学会論文誌, Vol. 19,
   No. 5, pp. 381–400, 2012.
- [5] 新納浩幸. 平仮名 n-gram による平仮名文字列の誤り検出とその修 正. 情報処理学会論文誌, Vol. 40, No. 6, pp. 2690-2698, 1999.
- [6] 水本智也,小町守,永田昌明,松本裕治.日本語学習者の作文自動 誤り訂正のための語学学習 SNSの添削ログからの知識獲得.人工 知能学会論文誌, Vol. 28, No. 5, pp. 420-432, 2013.
- [7] 田口雄哉,田森秀明,人見雄太,西鳥羽二郎,菊田洸. 同義語を考慮 した日本語単語分散表現の学習. 情報処理学会第 233 回自然言語 処理研究会, Vol. 2017-NL-233, pp. 1–5, 2017.
- [8] 南保亮太, 乙武北斗, 荒木健治. 文節内の特徴を用いた日本語助詞 誤りの自動検出・校正. 情報処理学会第 181 回自然言語処理研究 会, Vol. 2007, No. 94, pp. 107–112, 2007.
- [9] 白井稔久. RNNLM を用いた日本語テキストの誤字・脱字検出および再変換を用いた誤変換検出. 首都大学東京卒業論文, 2018.

# ニューラル系列ラベリングを用いた音声認識誤り訂正

Neural Sequence-Labelling Models for ASR Error Correction

| 池田 大志        | 藤本 拓             | 吉村 健              | 礒田 佳徳           |
|--------------|------------------|-------------------|-----------------|
| Taishi Ikeda | Hiroshi Fujimoto | Takeshi Yoshimura | Yoshinori Isoda |

株式会社 NTT ドコモ NTT DOCOMO, INC.

本稿では,音声認識処理の後処理として,音声認識誤りを訂正する手法を提案する.提案手法は,まず Bidirectional LSTM を用いて音声認識結果から音声認識誤り箇所を検出する.次に,誤り検出の結果と辞書を用いて単語ラティスを 構築し,識別モデルにより最適な単語列を選択することで音声認識誤りを訂正する.評価実験の結果,提案手法により 音声認識結果の文字誤り率と単語誤り率が改善することを示す.

#### 1. はじめに

近年,音声認識システムと自然言語処理の技術を応用した 音声エージェントや音声翻訳などのアプリケーションの普及を 背景として,ディープニューラルネットワークによる音声認識 手法が盛んに研究されている.一例として,電話会話を録音し た Switchboard 音声コーパスを用いた実験では,人手による 書き起こしに匹敵する認識結果が報告されている[1].しかし, 実世界で音声認識システムを利用する場合,集音マイクの性能 や周囲の雑音など,使用環境による認識精度の低下が依然課題 となっている.

このような音声認識誤りは,音声認識システムを利用した アプリケーションの自然言語理解(対話システムや機械翻訳) に悪影響を及ぼすことが報告されている.例えば,Sanoらの 研究 [2] では,音声エージェントにおいて,ユーザーとシステ ムによる対話のログデータを分析した結果,音声による入力に は 31.7% の音声認識誤りが含まれており,自然言語理解にお ける解析誤りの 57.2% は音声認識誤りが原因であると報告さ れている.また,Yoshikawa らの研究 [3] では,音声認識誤り が依存構造解析に悪影響を及ぼすことを報告されており,音声 認識誤りは自然言語理解に必要な基礎解析の精度低下を招くた め,その後段処理である応用アプリケーションの精度低下の原 因となる.

ー般的な音声認識システムは,音響モデル・単語辞書・言語 モデルを組み合わせ構成されている.ある特定の誤りに対して は,各構成要素のいずれかの部分に学習データを追加すること で,音声認識誤りの対策ができる.しかし,音声認識システム は各構成要素が相互作用しており,音響モデルや言語モデルに チューニングを施すことは,再学習の時間や精度検証など運用 上のコストが掛かる.また,一般に API などで提供されてい る音声認識システムは,ブラックボックスであることが多く, 音声認識誤りを発見し,対策を施そうとしても,音声認識シス テム自体に手を加えることができない問題もある [4].

そこで本研究では、音声認識処理の後処理として、音声認識 誤りを訂正する手法を提案する.音声認識システムの 1-best の音声認識結果を入力として、音声認識誤りとなる単語を発 話内容の正しい表記に変換するテキスト正規化の問題として、 音声認識誤り訂正を考える.提案手法では、音声認識誤り訂 正を二段階のパイプライン処理により行う.具体的には、まず

Contact: taishi.ikeda.fz@nttdocomo.com

Bidirectional LSTM (BiLSTM)を用いて音声認識結果から 音声認識誤り箇所を検出する.次に,辞書を用いて訂正候補を 含む単語ラティスを構築し,構造化パーセプトロンを用いて, 最適な単語列を選択することで音声認識結果を訂正する.

本研究では、提案手法の有効性を音声認識アプリケーション のログデータを用いた実験により検証した。その結果、提案手 法を用いることで音声認識結果の文字誤り率と単語誤り率が、 それぞれ 0.28 ポイントと 0.52 ポイント改善することを確認 した.本稿では、本手法では解決することができなかった事例 について考察し、今後の課題とその対策について述べる.

#### 2. 関連研究

本研究では、テキスト正規化の問題として、系列ラベリング による音声認識誤り検出と、構造化パーセプトロンによる識別 モデルを用いた二段階のパイプライン処理により、音声認識誤 り訂正を行う.そこで本章では、音声認識結果から音声認識誤 りを検出する研究と日本語を解析対象としたテキスト正規化の 研究について、それぞれ詳細を記述する.

#### 2.1 音声認識誤り検出

Byambakhishig らの研究 [5] では,条件付き確率場を用い てコンフュージョンネットワーク上から音声認識誤りを検出し, リランキングにより音声認識誤り単語を訂正することで,音声 認識システムの改善を行っている.それに対し,本研究では, ブラックボックスの音声認識システムを利用すると仮定し,コ ンフュージョンネットワークを利用せず,音声認識システムの 1-best の認識結果を入力とする音声認識誤り訂正タスクに取 り組む.

Ghannay らの研究 [6] では,系列ラベリング手法を用いて, 音声認識結果の各単語に対して,「正解」または「誤り」のラ ベルを付与することで,音声認識誤りを検出する手法を提案し ている.それに対し,本研究では,音声認識誤りを訂正するこ とを目的とするため,音声認識結果の各単語に対して,「操作 なし」「置換」「削除」の三種類のラベルに拡張したラベル付与 を行う.これらのラベルと辞書を用いて訂正候補を含む単語ラ ティスの構築を行い,音声認識誤りの訂正を行う.

#### 2.2 テキスト正規化

近年,Web テキストを対象としたテキスト正規化手法が盛んに研究されている [7, 8, 9].テキスト正規化の研究では,入力文中の表記揺れや口語表現を辞書に存在する正規表記に変換

することを目的としている.本研究では,音声認識誤り訂正タ スクを,音声認識結果の認識誤りを発話内容の正しい表記に変 換するテキスト正規化の問題として考える.

テキスト正規化の手法としては, Encoder-Deocder モデル を用いて, 音声認識誤りを正しい表記に翻訳する問題として 取り込むことができる.しかし, 音声認識結果と音声認識誤り を訂正したペアデータを大量に収集することは難しく, 小規模 なデータを用いて Encoder-Deocder モデルを学習する場合, データ拡張などの手法が必要となる [9, 10, 11].そこで本研究 では, Kaji ら [7] や Saito らの研究 [8] を参考として, 辞書と 識別モデルを用いた音声認識誤りの訂正を行う.

# 3. 提案手法

図1に提案手法の概要を示す.図1では,音声認識結果が 「セキュリティ祖父とにログイン」,書き起こしが「セキュリ ティソフトにログイン」の例を示している.この例では,音声 認識結果の「祖父と」の部分が音声認識誤りである.図1下 部は,BiLSTMを用いて,音声認識結果から音声認識誤りを 検出する過程を示している.図1上部は,辞書を用いて単語 ラティスを構築し,識別モデルにより最適な単語列を選択する 過程を示している.以下,それぞれ詳細を記述する.

#### 3.1 系列ラベリングを用いた音声認識誤り検出

本研究では,音声認識結果から音声認識誤りを検出するた め,形態素解析後の単語列に対して系列ラベリングを行う.ま た,音声認識誤りを検出するだけではなく,訂正することを 目的とするため,音声認識結果の単語列に対して「操作なし」 「置換」「削除」の三種類のラベル付与を行う.各単語に対する ラベルは,動的計画法を用いて,音声認識結果と書き起こしの アライメントを求め,ラベル付与を行う.

図2にラベル付与の例を示す.具体的には、単語が一致する 場合はスコア0を与え、削除と置換の操作が必要な場合には スコア1を各単語に与える.各単語のスコアを足し合わせアラ イメントのスコアを計算し、ビタビアルゴリズムによりスコア が最小となるアライメントを求める.得られたアライメント結 果を元に、対応する単語が一致する場合は「操作なし」ラベル を付与し、不一致となる場合は「削除」または「置換」ラベル を付与する.図2の例では、書き起こしの「セキュリティ」と 音声認識結果の「セキュリティ」が一致するため「操作なし」 ラベルを付与する.また、「ソフト」と「祖父」が不一致とな るため「置換」ラベルを付与し、「と」に対してはアライメン ト対象が存在しないため「削除」ラベルを付与する.

上記の操作により,BiLSTMの入出力となる単語列  $W = w_1, w_2, \cdots, w_n$ ,品詞列  $P = p_1, p_2, \cdots, p_n$ , ラベル列  $Y = y_1, y_2, \cdots, y_n$ を得る.ただし,nは単語数を示す.また,単語 列 W と 品詞列 P は,埋め込みベクトルに変換され,BiLSTM の入力となる.時刻iの入力となる $\mathbf{x}_i \in \mathbb{R}^{d^{word}+d^{pos}}$ は、 $d^{word}$ 次元の単語ベクトル  $\mathbf{w}_i \in \mathbb{R}^{d^{word}}$ と $d^{pos}$ 次元の品詞ベクト ル  $\mathbf{p}_i \in \mathbb{R}^{d^{pos}}$ を結合したものである.単語ベクトルは、Skipgram などにより事前学習した単語埋め込みを初期値とし、品 詞ベクトルは、一様分布によりランダムに初期化し、それぞれ 学習中に更新する.BiLSTM は、各時刻の入力として $\mathbf{x}_i$ を受 け取り、 $d^{hidden}$ 次元のベクトル  $\mathbf{h}_i \in \mathbb{R}^{d^{hidden}}$ を計算する.

#### h = BiLSTM(x)

ただし,  $\mathbf{x} = \mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_n$  は埋め込みベクトル系列,  $\mathbf{h} = \mathbf{h}_1, \mathbf{h}_2, \cdots, \mathbf{h}_n$  は BiLSTM の出力ベクトル系列である. 各ラ



図 1: 提案手法の概要(単語ラティスの太線は正解系列を表す)

| 書き起こし  | セキュリティ | ソフト  |      | に    | ログイン |
|--------|--------|------|------|------|------|
| ↓①比較   | ↓一致    | ↓不一致 | ↓不一致 | ↓一致  | ↓一致  |
| 音声認識結果 | セキュリティ | 祖父   | ک    | に    | ログイン |
| ↓②付与   | ţ      | Ļ    | Ļ    | Ļ    | Ļ    |
| ラベル    | 操作なし   | 置換   | 削除   | 操作なし | 操作なし |

#### 図 2: 動的計画法によるラベル付与

ベルの予測は、各時刻の $\mathbf{h}_i$ を入力として受け取り、アフィン変換とソフトマックス関数により各ラベルに対する確率値のベクトル $\mathbf{z}_i \in \mathbb{R}^{|T|}$ を得る.

#### $\mathbf{z}_i = \mathbf{Softmax}(\mathbf{W}_{out}\mathbf{h}_i + \mathbf{b}_{out})$

ただし, |T| はラベル数,  $\mathbf{W}_{out} \in \mathbb{R}^{d^{|T| \times hidden}}$  は重み行 列,  $\mathbf{b}_{out} \in R^{|T|}$  はバイアスベクトルである.また,目的関数 としてクロスエントロピー,パラメーターの最適化には Adam ( $\beta_1 = 0.9, \beta_2 = 0.999$ )を用いる.

#### 3.2 辞書による単語ラティスの構築と識別モデルによ る選択

本研究では,辞書を用いて単語ラティスを構築し,構造化 パーセプトロンにより最適な単語列を選択することで音声認識 結果を訂正する.

まず、単語ラティスの構築方法について説明する.入力単語 列 W と BiLSTM による予測ラベル列 Ŷ が与えられたとき、 BiLSTM により「操作なし」ラベルが付与された単語は、単 語ラティスに追加し、「置換」ラベルが付与された単語は辞書 により展開した訂正候補とともに単語ラティスに追加する.ま た、「削除」ラベルが付与された単語は単語ラティスには追加 しない.図1上部の例では、「操作なし」ラベルが付与された 「セキュリティ」は、単語ラティスに追加し、「置換」ラベルが 付与された「祖父」は、辞書を参照し、訂正候補が存在するの であれば訂正候補の「ソフト」と「祖父」を単語ラティスに追 加する.「削除」ラベルが付与された「と」は単語ラティスに追 追加しない.本研究では、人手による辞書構築を行い、辞書に は音声認識誤りとその訂正後の表記のペアデータが 129 件含 まれる.

次に,構造化パーセプトロンを用いて最適な入力単語列を

表 1: 本研究での実験で用いたコーパス概要

|             | 学習          | 評価         |
|-------------|-------------|------------|
| 文数          | 9,724       | 4,490      |
| 誤り文数        | 4,213       | 2,068      |
| 単語数(音声認識結果) | $113,\!993$ | 55,265     |
| 単語数(書き起こし)  | $112,\!699$ | $54,\!896$ |

選択する方法について説明する.本研究では,単語列 W と BiLSTM による予測ラベル列 Ŷ に対し,音声認識誤りが訂正 された単位列 Ŵ を求める問題を考える.この問題は次のよう に定式化できる.

$$\hat{W} = \underset{\ell \in \mathbf{L}(\mathbf{W}, \hat{\mathbf{Y}})}{\arg \max} \ w \cdot f(\ell)$$

ここで,  $\ell \in L(W, \hat{Y})$ は,入力単語列 W と BiLSTM による 予測ラベル列  $\hat{Y}$ により構築された単語ラティス(各ノードは 単語)である. $w \cdot f(\ell)$ は,重みベクトル w と素性ベクトル  $f(\ell)$ の内積を表す.最適系列は $w \cdot f(\ell)$ の値にしたがって選 択される.

素性は、学習データの書き起こし bi-gram 素性を用いる. こ こでは、書き起こしの単語列を選択するよう学習を行い、構造 化パーセプトロンにおける重みベクトル w の推定を行う. 正 解データの値  $w \cdot f(\ell)$  が、正解以外のどの値よりも大きくな るように  $\hat{W}$  を求める.

重みベクトル w の推定は、平均化パーセプトロン学習に基 づいて行う. 平均化パーセプトロンでは、正解である単語系列 W が付与された N 個の文が与えられたとき、現在のパラメー タ w<sup>i</sup> に基づいて一文ずつ最適解 Ŵ を求め、もしこの系列が 正解と異なる場合は重みパラメータ w<sup>i+1</sup> を下記の式により更 新する.

#### $w^{i+1} = w^i + f(\hat{\ell}) - f(\ell)$

ただし,  $f(\hat{\ell})$  は正解系列から得られる素性であり,  $f(\ell)$  は パラメータ  $w^i$  より求めた系列から得られる素性である. もし 現在のパラメータに基づいて出力された最適解が正解と一致す る場合にはパラメータの更新を行わない. 最後に, 文数と繰り 返し回数の積で平均化した重みパラメータを計算する. 以上の 二段階のパイプライン処理により, 音声認識誤り訂正を行う.

#### 4. 実験

提案手法の有効性を検証するため,音声認識アプリケーションのログデータを用いて,音声認識誤り訂正の評価実験を行う.

#### 4.1 実験設定

本研究では、重み付き有限状態トランスデューサを用いた音 声認識システムを利用し、携帯電話に関する問い合わせに応 答する音声認識アプリケーションからログデータを収集する. ここでは、一般に API などで提供されている音声認識システ ムを利用することを想定とする.そこで、ユーザーから収集し た音声発話を用いて、1-best の音声認識結果を取得した.ま た、人手による音声発話の確認を行い、正解データとなる書き 起こしの作成を行った.表1に学習と評価に用いたデータ数 を示す.

評価データに対して,提案手法の誤り訂正処理を適応し,文 字誤り率(Character Error Rate:CER)と単語誤り率(Word

|         | 表 2: 音声 | 認識誤り検出結果 |  |
|---------|---------|----------|--|
| الا لأم | 这人去     | 百田云 D1 店 |  |

| ラベル  | 適合率  | 再現率  | F1 值 | 件数        |
|------|------|------|------|-----------|
| 操作なし | 0.95 | 0.98 | 0.96 | 50,220    |
| 削除   | 0.51 | 0.19 | 0.28 | $1,\!691$ |
| 置換   | 0.61 | 0.43 | 0.50 | 3,354     |

表 3: 音声認識誤り訂正結果

| 訂正方法         | CER   | WER   | 相対向上数         |
|--------------|-------|-------|---------------|
| 操作なし         | 10.10 | 11.59 | 0 (0-0)       |
|              | 10.01 | 11.22 | +10(74-64)    |
| 置換           | 9.954 | 11.43 | +34 (125-91)  |
| 削除+置換        | 9.819 | 11.07 | +64 (188-124) |
| - 削除 (正解ラベル) | 8.068 | 8.517 | +298(298-0)   |
| 置換(正解ラベル)    | 9.302 | 10.91 | +181 (181-0)  |
| 削除+置換(正解ラベル) | 7.248 | 7.820 | +511(511-0)   |

Error Rate:WER) がどの程度改善できるかを評価する. CER とWER は、音声認識結果と書き起こしの編集距離を計算し、 文字単位の誤り数と単語単位の誤り数を元に求める.以下, CER とWER の定義を示す.

$$\mathbf{CER} = \frac{\mathbb{E} 換誤り文字数 + 削除誤り文字数 + 挿入誤り文字数}{全文字数} \times 100$$

WER = 
$$\frac{$$
置換誤り単語数 + 削除誤り単語数 + 挿入誤り単語数  $\times 100$   
全単語数  $\times 100$ 

また,訂正によって音声認識結果が書き起こしと一致した件 数と書き起こしと一致せず差分が発生した件数の差である相対 向上数を表3に示す.

音声認識結果と書き起こしの形態素解析には、MeCab<sup>\*1</sup> と その辞書である Unidic<sup>\*2</sup> を利用した.BiLSTM のハイパー パラメータは、学習データの 5%を開発データとして利用し、  $d^{word} = 100, d^{pos} = 32, d^{hidden} = 100$  と設定した.開発 データにおいて、WER が最小となるモデルを保存し、評価 データで性能の評価を行う.また、BiLSTM のラベル予測に は、三種類のラベルを利用するため、|T| = 3 となる.

#### 4.2 結果

音声認識結果から音声認識誤りをどの程度検出することが 可能か検証するため,評価データに対して,音声認識誤り検 出の精度評価を行った.表2には音声認識誤り検出の精度評 価を示す.ここでは,音声認識誤りである単語の検出率を確認 するため,「削除」ラベルと「置換」ラベルの再現率に注目す る.「削除」ラベルの再現率が 0.19,「置換」ラベルの再現率が 0.43 と各ラベルとも低く,多くの音声認識誤りの検出に失敗 していることがわかる.この結果より,音声認識誤り検出の再 現率をさらに上げる方法の検討が必要になると考えられる.

次に, 音声認識誤りの検出結果から音声認識誤りをどの程 度訂正することが可能か検証するため, 評価データに対して, 音声認識誤り訂正の精度評価を行った.表3には音声認識誤り 訂正の精度評価を示す.音声認識誤り訂正の効果を測るため, 以下の方法を比較することで精度評価を行った.

操作なし 音声認識結果に訂正を一切行わない場合.

 $<sup>*1 \</sup>quad http://taku910.github.io/mecab/$ 

<sup>\*2</sup> https://unidic.ninjal.ac.jp/

- 削除 「削除」ラベルを用いて, 音声認識誤りを削除した場合.
- 置換 「置換」ラベルを用いて,識別モデルによる訂正を行った場合.

削除+置換 削除と置換を同時に行った場合.

ここでは,操作なしと比較し,どの程度 CER と WER が 改善したか確認することで,提案手法の有効性を検証する.提 案手法である削除+置換を評価データに適応した場合,操作 なしの CER と WER と比較し,CER が 0.28 ポイント と WER が 0.52 ポイント改善したことから,提案手法により音 声認識誤りの訂正が行われていることが確認できる.また,提 案手法によって正しく訂正された例を示す.一番目と二番目の 例では,提案手法によって助詞の重複や助詞の間違いを正しく 訂正している事例を確認できた.

| 正解   | 暗証 番号 の   |
|------|-----------|
| 認識結果 | 暗証 番号 を の |
| 訂正結果 | 暗証 番号 の   |
| 正解   | サービス の 廃止 |
| 認識結果 | サービス が 廃止 |
| 訂正結果 | サービス の 廃止 |

しかし,提案手法により悪化した事例も存在する.例えば, 一番目の例のように,不必要に単語を削除してしまう事例が多 く存在した.また,提案手法では,二番目の例のような挿入操 作に対応できないため,今後の課題として,挿入操作への対応 を検討する必要がある.

| 正解   | 五月十五日                |
|------|----------------------|
| 認識結果 | 五月十五日                |
| 訂正結果 | 月五日                  |
| 正解   | アプリ が ダウンロード でき ませ ん |
| 認識結果 | アプリ がた の でき ませ ん     |
| 訂正結果 | アプリ がた の でき ませ ん     |

また,表3では,BiLSTM の各単語の予測ラベルを全て本 来の正解ラベルとした場合の CER と WER を示している. 削除(正解ラベル)の場合は,操作なしと比較し,CER では 2.03 ポイント,WER では 3.07 ポイントと大幅に誤り率が減 少している.しかし,置換(正解ラベル)の場合は,操作なし と比較し CER では 0.79 と WER では 0.67 ポイントと誤り 率が少ないことがわかる.この結果から,辞書の網羅性が低 かったと考え,読み情報を利用した辞書構築など辞書構築方法 の再検討が必要であると考えられる.

#### 5. おわりに

本研究では,BiLSTM を用いて音声認識結果から音声認識 誤り箇所を検出し,誤り検出の結果と辞書を用いて単語ラティ スを構築後,識別モデルにより最適な単語列を選択することで 音声認識誤りを訂正する手法を提案した.音声認識アプリケー ションのログデータを用いた実験では,提案手法を用いること で音声認識結果の文字誤り率と単語誤り率が改善することを確 認した.

今後の課題として, 音声認識誤り検出に対する再現率の向 上と辞書の構築方法の検討が考えられる.

- Wayne Xiong, Lingfeng Wu, Fil Alleva, Jasha Droppo, Xuedong Huang, and Andreas Stolcke. The microsoft 2017 conversational speech recognition system. In *Proc. ICASSP.* IEEE, 2018.
- [2] Shumpei Sano, Nobuhiro Kaji, and Manabu Sassano. Predicting causes of reformulation in intelligent assistants. In *Proc. SIG dial*, 2017.
- [3] Masashi Yoshikawa, Hiroyuki Shindo, and Yuji Matsumoto. Joint transition-based dependency parsing and disfluency detection for automatic speech recognition texts. In *Proc. EMNLP*, 2016.
- [4] Dong Yu, Jinyu Li, and Li Deng. Calibration of confidence measures in speech recognition. *IEEE Transactions on Audio, Speech, and Language Processing*, 2011.
- [5] E Byambakhishig, Katsuyuki Tanaka, Ryo Aihara, Toru Nakashika, Tetsuya Takiguchi, and Yasuo Ariki. Error correction of automatic speech recognition based on normalized web distance. In *Proc. ACL*, 2014.
- [6] Sahar Ghannay, Yannick Estève, and Nathalie Camelin. Task specific sentence embeddings for asr error detection. In *Proc. Interspeech*. ISCA, 2018.
- [7] Nobuhiro Kaji and Masaru Kitsuregawa. Accurate word segmentation and pos tagging for japanese microblogs: Corpus annotation and joint modeling with lexical normalization. In *Proc. EMNLP*, 2014.
- [8] Itsumi Saito, Kugatsu Sadamitsu, Hisako Asano, and Yoshihiro Matsuo. Morphological analysis for japanese noisy text based on character-level and word-level normalization. In *Proc. COLING*, 2014.
- [9] Taishi Ikeda, Hiroyuki Shindo, and Yuji Matsumoto. Japanese text normalization with encoder-decoder model. In *Proc. WNUT*, 2016.
- [10] Itsumi Saito, Jun Suzuki, Kyosuke Nishida, Kugatsu Sadamitsu, Satoshi Kobashikawa, Ryo Masumura, Yuji Matsumoto, and Junji Tomita. Improving neural text normalization with data augmentation at character-and morphological levels. In *Proc. IJCNLP*, 2017.
- [11] Jun Harashima and Yoshiaki Yamada. Two-step validation in character-based ingredient normalization. In Proceedings of the Joint Workshop on Multimedia for Cooking and Eating Activities and Multimedia Assisted Dietary Management. ACM, 2018.

# 認知症の状態像理解を深めるためのConceptNetを用いた認知症見立 て表現モデルの構築

Construction of a Diagnosis Representation Model of Person with Dementia Based on ConceptNet for Deeper Understanding of Physical and Mental Conditions

| 神谷直輝 *1<br>Naoki Kamiya | 吉沢拓実 *1<br>Takumi Yoshizawa                | 石川翔吾 *1<br>Shogo Ishikawa                | 上野秀樹 * <sup>2,4</sup><br>Hideki Ueno | <sup>l</sup> 小林美亜 * <sup>2,4</sup><br>Mia Kobayashi | 前田実 * <sup>3</sup><br>Minoru Maeda |
|-------------------------|--|--|--------------------------------------|---|------------------------------------|
|                         | 西山千秋 * <sup>3</sup><br>Chiaki Nishiyama    | 村上佑順 * <sup>3</sup><br>Yujun Murakami    | 桐山伸也 *1,4<br>Shinya Kiriyama         | 竹林洋一 *1,4<br>Yoichi Takebayashi                     |                                    |
|                         | * <sup>1</sup> 静岡大学<br>Shizuoka University | * <sup>2</sup> 千葉大学医学<br>Chiba Universit | 部付属病院<br>y Hospital                  | <sup>*3</sup> オレンジクロス<br>Orange Cross Foundation    |                                    |

\*4みんなの認知症情報学会

The Society of Citizen Informatics for Human Cognitive Disorder

This paper describes construction of a diagnosis representation model of person with dementia based on ConceptNet to understand physical and mental conditions deeper. We constructed diagnosis knowledge of treatable dementia using ontology, as many of it remain tacit knowledge for familiar persons. The result of analyzing learners' diagnosis shows that our knowledge structure are useful to evaluate diagnosis by learner and represent diagnosis skills. Furthermore, the result suggest that practice of learning environment lead to understanding learning process on the basis of learner's diagnosis knowledge and improving accumulated knowledge structures.

# 1. はじめに

認知症は医学的な疾患が原因であり,その原因は 70 種類以 上ある.その中には,原因を治療で取り除くことで脳機能を回 復することができる治療可能な認知症があり,医療の関与は欠 かせない.本稿では,認知機能の低下をもたらす多数の原因疾 患の可能性について分析することを見立てと呼ぶ.これは,医 師が原因疾患を鑑別診断するプロセスとは異なり,あくまでも 医療職ではない身近な支援者が治療可能な認知症の可能性を 検討することを意味する.しかし,関わりを主体とした介護現 場では医学的に改善可能な側面が見逃されていることが多い. それに加えて見立てのプロセスを学ぶための方法が確立され ていない.身近な支援者が医師の見立ての知識を学ぶことで, 医師がどのような情報を必要としているかを理解することがが き,適切な情報提供によって支援の質が改善されることが期待 される.本研究では,介護従事者が見立てのプロセスを学べる ようにするため,見立てを表現する知識構造の設計を目指す.

# 2. 学びを活用した見立て知の構築

## **2.1** 認知症の見立て

治療可能な認知症には、日常生活の中で気が付くためのポ イントがある(表1).身近な人がそれらのポイント手掛かりに 日々の関わりの中から治療可能な認知症を見つける必要があ る.筆者らは、実践的な学びに繋げるためにケースメソッドア プローチの構成をベースに家族や介護、医療に従事する多職種 が集い、ケースを通して認知症の見立てを実践的に学ぶ学習環 境を設計した.学習会では、提示されたケースについて個人で 見立てを行い、その結果をもとに3名から5名程度の少人数 で見立てを行う.ケースメソッドアプローチではグループで出 た意見を集約するが、本学習環境では、あらゆる改善可能な側 面について検討し、知識を共有できるよう意見を集約させない 所が大きな特徴である.

連絡先:神谷直輝,静岡大学桐山研究室,浜松市中区城北 3-5-1

表 1: 治療可能な認知症

| 脳機能低下の原因        | アセスメント方法       |
|-----------------|----------------|
| 薬剤の副作用          | 薬の内服内容のチェック    |
| うつ病,精神的ストレス     | うつ病の症状があるか     |
| 甲状腺機能低下症        | むくみ,食欲がないのに体重が |
|                 | 増える            |
| ビタミン B1, B12 欠乏 | 食事をきちんとしていない   |
| 正常圧水頭症          | 三主徴(歩行障害,尿失禁,  |
|                 | 認知症)           |
| 意識障害、せん妄状態      | 状態の時間的変動,      |
|                 | 特定の時間帯での増悪     |

2016年より見立ての学習会を開催してきた結果,身近にい る人ならではの新たな解釈が得られることが分かり,見立て知 の集積と洗練のための認知症の見立てコーパスの構築を進めて いる [神谷 2018]. 学びを活用して多様な人々の知を収集・分 析できる仕組みを構築することで,見立ての知を深め,皆がそ の知を学べる環境につながると期待される.

#### 2.2 見立て表現モデルの設計

看護・介護に関する技術や行為に関する知識をオントロジー を用いて表現し,教育や知識共有で活用する取り組みが進んで いる [西村 2015][Hsieh2015]. 筆者らは見立て知を収集するた めに,見立てを行う際に着目するケース中のポイントや判断プ ロセスを表現する見立て知を設計した.図1は,治療可能な 認知症の一つ,せん妄の知識をオントロジーで表現したもので ある.身近な支援者は,日常生活の中でせん妄に気付ける能力 を習得する必要があるため,まずは,学習会のケース中から適 切な情報を拾い上げることができたか評価する.そこで,せん 妄の知識に対してケース中の語句をインスタンスとして結び付 けておき,学習者が見立てた際の記述からせん妄に関する語句 を抽出することでせん妄の知識構造との対応を分析した.



図 1: せん妄の知識の一部



図 2: せん妄の構造を用いた見立ての評価

# 3. 見立て表現モデルを用いた学習プロセスの 分析

## 3.1 学習者の見立ての評価

せん妄の見立て表現モデルを用いて学習者の回答を分析し, 基本的なポイント全てが表示されるよう可視化すると図2の ように表現できる.緑色のノードは回答に含まれていたポイン トであり,赤色のノードは回答に含まれていなかったせん妄に 関するポイントを意味する.例えば、「特定の時間帯で増悪」の 下にある「判別E:夕方(夕方)」は、学習者が「夕方」とい う語句を使って見立てた結果を記述しているため緑色のノード となっており、その隣の「判別E:暴力・暴言(暴力、暴言)」 は「夕方」と「暴力」「暴言」「暴れる」という語句を使わずに 見立てていたので赤色のノードとなっている.

## 3.2 学習者の見立て知の抽出

学びの評価を通して学習者がもつ見立て知を集積するため に、学習者の見立てを ConceptNet[Liu2004] を用いて分析し た. ConceptNet は、コモンセンス知識を扱うためのデータ ベースとして設計され、概念 (Concept) をノードして表し、概 念間の関係性 (Relation) を矢印で表す. IsA や PartOf, MotivatedByGoal といった関係性は 36 種類ある.

図3に図2と同じ学習者のひと月前後の回答結果とせん妄 に関連する知識構造を示す.月に1度2時間の学習会を開催 し,第2回目と第3回目の中で得られた結果である.回答の 記述で下線を引いた部分が,ケースについて治療可能な側面が あるか状態を分析した箇所であり,それ以外は対応方法に関す る記述である.下線部を分析対象とし,回答に含まれていた語 句を赤色のノードと関係性で示し,それらのノードに関係する せん妄の知識を黒色のノードと関係性で示した.得られたグラ フを比較すると、ひと月後の方がせん妄に知識に関連する記述 が増えており、せん妄の特徴の「夕方から症状」に気づいた事 を起因として「せん妄状態を検討」、という見立てのプロセス も表現できた.また、誘因と薬剤の間にある知識を省略した関 係性も見つかった.

#### 1カ月後の学習会での回答と構造

タ方から症状が出てくるという事なので、せん妄状態を検討する。誘因は、内服している胃薬、 <u>睡眠薬、が該当する可能性がある。</u>服薬指導、薬剤を減らす。<u>以前からのアルコールの依存に</u> よる、脳の障害。



図 3: 見立て結果から抽出した知識構造の違い

# 4. まとめ

本稿では、見立て表現モデルを設計するために治療可能な認 知症の知識を設計し、その表現モデルを活用することで学習者 の見立ての評価と見立て知の表現に応用できることを示した. また、未解明な部分が多い見立てにおいて、学習者の常識的知 識に基づいた見立ての分析や知の集積につながることが示唆さ れた.今後は見立ての協調学習会を継続的に開催しながら見立 て知の集積と利用を進め、多様な人々による協調学習が創り出 す知識を蓄積できるよう構造を洗練させる.

- [神谷 2018] 神谷,上野,他:認知症ケア高度化のための協調 学習環境を活用した認知症の見立てコーパスの構築,2018 年度人工知能学会全国大会(第 32 回),3Pin1-45(2018).
- [西村 2015] 西村, 笹嶋, 他: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, 30(1), pp.22-36(2015).
- [Hsieh2015] Hsieh,NC., Chiang, RD., et al., Ontology Based Integration of Residential Care of the Elderly System in Long-Term Care Institutions, Journal of Advances in Information Technology 6(3)(2015).
- [Liu2004] Liu, H. and Push S., "ConceptNet a practical commonsense reasoning tool-kit, BT technology journal 22(4),pp.211-226(2004).

# 認知症のある人の個性表現に基づく 自立を重視した生活環境デザインの評価と分析

Evaluation and Analysis of design for life environment with a high regard for self- reliance based on the representation of a self of people with dementia

| 寺面 美香 <sup>*1</sup> | 石川 翔吾 <sup>*1</sup> | 桐山 伸也*1           | 加藤 忠相*2       | 井出 猛*2            | 竹林 洋一*1·3            |
|---------------------|---------------------|-------------------|---------------|-------------------|----------------------|
| Mika Teramen        | Shogo Ishikawa      | Shinya Kiriyama   | Tadasuke Kato | Takeshi Ide       | Yoichi Takebayashi   |
| *1 静岡大              | 学 *2 株式             | 式会社あおいけあ          | *3 みんた        | の認知症情             | 報処理学会                |
| Shizuoka Uni        | versity             | Aoicare Co., Ltd. | Citizen Info  | rmatics for Human | n Cognitive Disorder |

This paper describes the evaluation of design for life environment with a high regard for self-reliance based on the representation of a self of people with dementia. We have structured care records in a care home where is pioneering efforts to support people with dementia, and constructed a model of personality expression. The personality expression tree makes it possible to see the connection of the life data and to compare and analyze the record of each facility. The result shows that the tree was possible to objectively evaluate the record of the facility, and learning with tree introduction is effective for reforming the consciousness of care practitioners toward self-reliance support.

# 1. はじめに

認知症は、何らかの脳機能低下の要因による認知機能障害 とそれにより生じる生活障害で定義される.認知症とともに生き るには、生活に支障が出る状況において適切な生活環境を整 えられるよう支援する必要がある.多くの当事者が声を上げてい る[佐藤 14, 丹野 17]ように、認知症の症状は千差万別で、ゆえ に、型にはまった支援方法があるわけではない.生活は個人ご とに異なるため、当事者のパーソナリティ、身体的状況や精神 的状況、家庭や地域における暮らし方(本稿ではこれらを個性 を構成する要素として捉える)を理解しながら支援につなげる必 要がある.介護においては作成したケアプランにそった支援が 行われるが、目標の立て方、支援のための記録の作り方やその 使い方には方法論がない[日総 12]のが現状である.

そこで本稿では、認知症のある人の個性表現に基づき、自立 を重視した生活支援の評価と分析について述べる.

# 2. 個性表現モデルの基本構造

#### 2.1 個性情報の構造化

本稿では、生活支援を評価するために介護記録に着目する. 介護現場では、生活支援のためのケアプランや利用者の特徴 を表すフェイスシート、日々の記録等、様々な個性に関する情 報がある.しかし、これらは介護業界全体で統一された指標が あるわけではなく、独自のフォーマットや書き方の作法がある. そこで、記録と支援の関係を整理するために、個性に基づく自 立支援において先駆的な取り組みを実施している介護施設の 記録を分析し、記録の特徴を表現するための構造化を行った. 以下に手順を示す.

(1)介護施設で収集している利用者に関する情報の調査

(2)スタッフ 20 名が参加し,生活支援情報の特徴を抽出する 検討会の実施

(3)抽出した生活支援に関する情報を[大久保 13]のキーワードを活用して KJ 法でグルーピング

(4)項目間の関係を ConceptNet [H Liu 04]を活用し構造化

その結果,日々の変動の大きい日常生活動作(Activity of Daily Living: ADL)の把握以上にパーソナル情報の収集を重視することにより当事者を理解し寄り添う支援を実現させていることがわかった[寺面 18](図).



図1個性表現ツリー

#### 2.2 個性情報可視化ツール

構造化した結果を元に情報の可視化ツールを作成した.ツ ールではデータベースにカテゴリ情報や入力者情報,当事者情 報の登録を行うことで各情報のツリーやログを生成し状況を可 視化することができる(図).このツールを用いて施設のアセスメ ントの状況の評価・分析を行う.



# 3. 個性表現に基づく介護記録の評価

2.2節で作成したツールを活用し、施設ごとのデータを比較す ることで個性に基づいた生活支援の質を評価する.施設A,施 設Bの二つの施設を対象に特定の利用者1名に関する施設の 記録を収集し分析した.

連絡先:寺面美香,静岡大学,静岡県浜松市中区城北 3-5-1,053-478-1488,men@kirilab.net

図に比較結果を示す.①医療関係と②性格・嗜好に関する 情報を可視化したものである.施設Bでは医療に関する項目は 詳細に設定されており症状が丁寧に記載されている.それに対 して,施設Aでは身体状況に関する本人の不安や家族の願い が表れるツリーとなった.また,施設Aでは性格・嗜好情報の収 集を重視しており,味の好み等を細かく行っている他,それに関 する本人の発言やエピソードも拾われている.施設Bでは性格 や嗜好に関する記述はほとんど見られなかった(表).このこと から,施設Aは個性情報の中のパーソナリティに関することとそ の他のことを関係づけて支援をしており,当事者のこれまでの生 活を踏まえながら自立支援に繋げていると評価される.



図3施設A/施設Bの個性表現ツリー

表1 施設A/施設Bの個性情報に関するノード数

|        | 施設A   |        | 施設B   |        |
|--------|-------|--------|-------|--------|
|        | ①医療関係 | ②性格·嗜好 | ①医療関係 | ②性格·嗜好 |
| ノードの深さ | 7     | 7      | 8     | 6      |
| 全ノード数  | 18    | 26     | 30    | 4      |
| 本人の発言  | 0     | 6      | 0     | 0      |
| 本人の願い  | 0     | 3      | 0     | 1      |
| 本人の不安  | 1     | 2      | 0     | 0      |
| 家族の願い  | 2     | 0      | 0     | 1      |
| 家族の不安  | 1     | 1      | 0     | 0      |

# 4. 個性表現に基づくケース検討の分析

#### 4.1 個性表現ツリーに基づく学習支援

個性表現ツリーが介護スタッフにどのような気付きを与えるか を検証するため,施設Bにて個性表現ツリーを用いた生活支援 検討の場を設計した.12人の介護スタッフを3チームに分けグ ループワークを行い,個性表現ツリーを見ながら各項目に対し て検討することとした.支援に関する検討として,以下の結果が 得られた.

グループA:「できることはやってもらって、できていないことを サポートする形」と、ツリーから読み取れるケアに対して自立支 援に繋がることをやっているという評価を行っていた.

グループB:「その場しのぎのケアが多い」と原因探索の必要 性に対する議論が行われ、また、「個性が認知症に締められる のはおかしい」という評価も行っていた.

グループC:グループBと同様に「自立支援に向け成功事例 や失敗事例の詳細を共有する必要がある」という議論がなされ, また,「本人の意向を無視して施設の都合の良いように動かして しまっているかも」という意見も出ていた.

グループAと他のグループの意見が異なるが、これを全体で 議論することによって考えが共有され、グループBやCの検討の 方向で考えることが重要であると結論づけられた.以上のように、 記録の意味や記録の作り方、活用の仕方について気づきが得 られた結果が示された.

## 4.2 ConceptNetを用いた比較

生活支援は常識的思考が集約された場である.そこで, ConceptNet に着目し、実際の現場のケース会議における議論 が、個性表現モデルと対応するかを分析することで支援の質の 評価につながるかを分析した. ConceptNet5 の Relation に基づ いて設計された個性表現ツリーに基づき施設Aと施設Bの議論 を Relation の数で算出すると IsA,HasA 以外の関係と数は表 のようになった. グループBの議論で医療情報について触れら れていたが,施設Bの医療情報は IsA,HasA,Causes 関係のみ で構成されていたのに対し,施設Aの医療情報では事象から引 き出される望み(CausesDesire)や目標(MotivatedByGoal)が見て 取れた(図 4). 全体も思い(MotivatedByGoal, Desires),原因探 索(Desires, CausesDesire, ReceivesAction, ObstructedBy),詳細 化(InstanceOf, RelatedTo)に関わる記述が多くなっており、質の 高い記録は単純なデータの数やノードの深さだけでなく情報の 繋がりも重要となってくることが伺える.

以上のことから、個性を重視した介護記録を作るには利用者 との関係を築いて人となりを理解することが重要となり、そこから 見えてきた本人や家族の意思の尊重・不安の解消を目指すこと が質の高い自立支援に繋がることが示唆された.



表2 施設A/施設Bのツリーで表出したノードの関係と数

| ConceptNet 5 Relation URI | 施設A | 施設B |
|---------------------------|-----|-----|
| MotivatedByGoal           | 1   | 1   |
| Desires                   | 2   | 0   |
| Causes                    | 5   | 6   |
| CausesDesire              | 5   | 3   |
| ReceivesAction            | 1   | 0   |
| ObstructedBy              | 3   | 1   |
| InstanceOf                | 3   | 0   |
| RelatedTo                 | 5   | 1   |
|                           |     |     |

# 5. おわりに

本稿では個性表現モデルの設計と、モデルを活用して生活 環境デザインプロセスを分析した.モデルを個性表現ツリーとし て可視化することにより客観的な比較・分析が可能となり、ツリー を導入した学習は質の高い支援に向けてのスタッフの意識変革 を行うものとなった.生活環境デザインは、個性の理解と環境デ ザインに大別される.今後は、環境デザインの方法論も検討す ることで、自立重視の支援の実現に貢献したい.

- [H Liu 04] H Liu and P Singh: ConceptNet a practical commonsense, BT Technology Journal, 2004.
- [大久保 13] 大久保幸積,他:認知症ケアの視点が変わる「ひ もときシート」活用ガイドブック,認知症介護研究・研修東京 センター,2013.
- [佐藤 14] 佐藤雅彦: 認知症になった私が伝えたいこと,大月 書店,2014.
- [丹野 17] 丹野智文: 丹野智文 笑顔で生きる -認知症とともに-, 文藝春秋, 2017.
- [寺面 18] 寺面美香,他:認知症のある人の生活環境デザインのためのあおいけあナレッジの抽出と構造化,2018 みんなの認知症情報学会,2018.
- [日総 12] 日本総合研究所:介護支援専門員の資質向上と今後のあり方に関する調査研究ケアプラン詳細分析結果報告書,2012.

# 畳み込みニューラルネットワークを用いた

脳波ブレイン・マシン・インターフェイスの開発

Development of Electroencephalogram brain-machine interface using convolutional neural network

加藤正起<sup>\*1</sup> Masaki Kato 嶋田総太郎<sup>\*2</sup> Sotaro Shimada

\*1 明治大学大学院 Meiji University Graduate School <sup>\*2</sup> 明治大学 Meiji University

Brain-machine interface (BMI) is a system that manipulates machines directly from the brain activity data. Convolutional Neural Network (CNN) which enables end-to-end learning allows extracting information from brain activity [Antoniades 2016][Bashivan 2016]. In the previous study [Schirrmeister 2017], CNN was used to predict four kinds of motor imagery of right arm, left arm, foot and rest from electroencephalogram (EEG) data. In this study, we measured EEG when an individual performed reaching movements with his right arm. We propose a BMI system by using CNN that can classify four directions of reaching motion of the right arm from EEG data with about 78% accuracy.

# 1. はじめに

ブレイン・マシン・インターフェイス(BMI)は脳活動を解析す ることで、脳から直接、コンピュータや機械を操作する技術であ る. 非侵襲的な脳波(EEG)や機能的核磁気共鳴計測(fMRI) による研究では、脳活動からコンピュータ画面上のカーソルの 操作[Wolpaw 1991]や車椅子の操作[Choi 2012]を可能にする 研究が行われている.近年では脳波を含む脳活動の分析のた めに end-to-end 学習が可能である畳み込みニューラルネットワ ーク(Convolutional Neural Network : CNN)を用いた研究が行 われている[Antoniades 2016][Bashivan 2016].

先行研究[Schirrmeister 2017]では CNN を用いて脳波から右腕, 左腕, 足の運動想起とレストの4 種類を約 90%の精度で予測した.しかし, それぞれの運動想起では握るなど具体的な運動を行っているわけではないため, 四肢の詳細な運動を分類できるわけではない.

本研究では、右腕でリーチング運動を行った時の脳波を計測 し、CNN を用いて、右腕の4 種類の運動を分類することを可能 にする BMI を開発した.

# 2. 実験方法

#### 2.1 被験者

2名の健康な右利きの男性(23歳)が実験に参加した.被験者 には、事前に実験方法などの説明を行い、書面にて実験参加 の同意を得た.

#### 2.2 実験環境

図1のようにプロジェクタ(EB-W420, EPSON)によって壁にゲ ーム開発ソフト(Unity, Unity Technologies)で作成したアバター アームを呈示した.このアバターアームの動作はジョイスティック (T.Flight Stick X, THRUSTMASTER)により制御され,被験者 はアバターアームを右腕で操作することで,リーチング課題を行 った.被験者は実験中,顎台に顎を置き,自分の手を見ないよ うにした.

連絡先:加藤正起,明治大学大学院理工学研究科,神奈川県 川崎市多摩区東三田1-1-1,E-mail: ce181021@meiji.ac.jp 実験装置を接続することによって生じる被験者の実際の手と アバターアームの運動の遅延は、ハイスピードカメラ(EX-F1, CASIO)で測定したところ約 200ms であった.

また, EEG の計測は g.tec 社製の g.USBamp を用いて, 以下 の条件で行った.

• 電極数: 60ch

(Fp1,Fpz,Fp2,AF7,AF3,AF4,AF8,F7,F5,F3,F1,Fz,F2,F4,F 6,F8,FT7,FC5,FC3,FC1,FCz,FC2,FC4,FC6,FT8,T7,C5,C3, C1,Cz,C2,C4,C6,T8,TP7,CP5,CP3,CP1,CPz,CP2,CP4,CP6 ,TP8,P7,P5,P3,P1,Pz,P2,P4,P6,P8,PO7,PO3,POz,PO4,PO8 ,O1,Oz,O2)

- 眼電:4ch(左右の垂直水平成分)
- サンプリング周波数:1200 Hz
- 帯域通過フィルタ: 0.5-100 Hz



図1 実験風景

#### 2.3 実験手順

1トライアルの流れを図 2 に示す. 被験者がアバターアームを一辺 12cmのベースポジション上に置くことでトライアルの開始とした. ベースポジションの位置は毎回同じで, 直径 12 cmの円のターゲットはベースポジションの位置から前後左右の 20 cm離れた場所に出現させた. ターゲットの 4 通りの位置(front, back, left, right)はランダムに出現させた. 実験中は右腕のアバターアームだけが表示された. また, 左腕は動かさないように被験者に指示をした. 実験では 2 セッションを行い, セッション内には 8 つのブロックがあった. それぞれのブ

ロックでは 150トライアル繰り返した. 被験者には, できるだけ 早く, 正確にリーチング運動を行うよう教示した. なお事前に 1ブロック分(150トライアル)の練習を行った.



図2 1トライアルの流れ

#### 3. 解析

#### 3.1 前処理

測定した脳波データに対して、1Hz の高域通過フィルタをかけ、250Hz までダウンサンプリングを行った。1 セッション分のトライアルの中で-100μV~+100μV の範囲を超える脳波データが50% 以上含まれる電極(Subject1: F6,T8,PO8,O1,Oz,O2,Subject2: T8,PO3)を解析から除外した.ターゲットが表示される0.5秒前から表示後3.25秒(Subject2は3.2秒)までを1トライアルとし脳波データを分割した.-100μV~+100μVまたは-60dB~40dBの範囲を超える脳波データを含むトライアルを除いた後、脳波データに含まれる眼電成分と筋電成分を取り除くために独立成分分析を行った。

Subject2の脳波データは測定機器の不良により,セッション1と2の5,6,7,8ブロックのデータにノイズが多く含まれていたため,解析から除外した.これらの前処理は脳波解析ソフトである EEGLAB(v14.1.2)で行った.

#### 3.2 入力データの作成

トライアルごとに分割された脳波データに対し、それぞれに対応した種類のラベル(front, back, left, right)を付けた.1トライアル分の脳波データを時間窓2秒、スライド幅0.04秒で分割することで1トライアルあたり44個(Subject2は43個)の脳波データを作成し、入力データとした.1トライアルあたり44個または43個の入力データが作成されるが、それぞれのラベルについては分割する前のトライアルに付属されたラベルと同じものを使用した.入力データのサイズは時間ステップ数×電極数で、Subject1は500×53, Subject2は500×58であった.

また,脳波データを学習データ,検証データ,テストデータの3つに8:1:1で分割した.

#### 3.3 CNNによる運動方向分類モデル

先行研究[Schirrmeister 2017]のモデルをもとに脳波から右腕の運動方向を分類するために図 3 のような CNN を深層学習の フレームワークである TensorFlow を用いて作成した.

CNN は主に、画像データに対して用いられているが、本研究 では入力データとして時系列信号を用いた.これは、脳波をウ ェーブレット変換などの時間周波数解析によって、画像として学 習することも可能であるが、学習させる特徴量が1つの電極に つき周波数分、増えてしまう.そのため本研究では、脳波を時 系列信号の状態で学習することで特徴次元数を減少させた.

脳波は時系列情報を持つ信号であり, 脳内の複数の双極性 電流源によって引き起こされる空間的に広がる電圧の線形重ね 合わせに近似すると仮定されている[Nunez 2006]. 時間的空間 的な情報をもつ脳波の特徴を捉えるため, 第1層目で電極ごと に脳波データを時間方向に畳み込んだ後,全電極分の特徴量 を一度に畳み込むようなモデルを設計した.また,すべての畳 み込み層のレイヤーにおいてドロップアウトを使用することで過 学習を抑制した.最後の全結合層のソフトマックス関数によって 入力データは4種類の運動のいずれかに分類された.



図3 運動方向分類モデルの構造

### 4. 結果

テストデータを入力したときの混合行列を図 4 に示す. Subject1とSubject2の分類精度はそれぞれ 77.90%と 56.73%で あった(チャンスレベルは 25%).

本実験結果より,作成したモデルによって脳波から右腕の 4 種類の運動を最大で約 78%のという高い精度で分類できることが分かった. Subject2 の分類精度が Subject1 に比べ,20%程低 くなっている.これはノイズにより全データの半分しか学習データに使用できなかったため,汎化性能が低くなってしまったと考えられる.



図4 テストデータ入力時の混合行列

#### 5. まとめ

分類精度が約 78%と先行研究[Schirmeister 2017]の 90%と 比べ低くなっているが,先行研究で行われた右腕,左腕,足の 運動想起はそれぞれ,左脳の一次運動野,右脳の一次運動野, 頭頂葉付近の一次運動野など脳の活動領域が異なる.それに 比べ本研究で行った右腕のリーチング運動は左脳の一次運動 野の中での活動であり,その狭い脳領域で4種類の運動の特 徴を捉える必要があったため,精度が下がってしまったと考えら れる.また,1トライアルのなかでターゲットにアバターアームを 伸ばして戻すという運動を行うが、この一連の動作に対して1つのラベルを割り当てているためだと考えられる.

しかし,本研究では右腕の4種類の運動の分類を可能にした. 今度は学習データとして右腕運動時の脳波だけでなく,左腕や 両腕を動かしたときの脳波を用いて,BMIとしての分類数をさら に増やしていきたい.これによって,より現実的なBMIの開発を 目指す.

- [Wolpaw 1991] Wolpaw, J R.,McFarland, D J.,Neat, G W.,Forneris, C A: An EEG-based brain-computer interface for cursor control, Electroencephalography and Clinical Neurophysiology, Vol.78(3), pp.252-259, 1991.
- [Choi 2012] Choi.K.: Control of a vehicle with EEG signals in real-time and system evaluation, European Journal of Applied Physiology, Vol.112(2), pp.755-766, 2012.
- [Antoniades 2016] Antoniades, A., Spyrou, L., Took, C. C., & Sanei, S.: Deep learning for epileptic intracranial EEG data, IEEE International Workshop on Machine Learning for Signal Processing, MLSP, 2016.
- [Bashivan 2016] Bashivan, P., Rish, I., Yeasin, M., & Codella, N.: Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks, ICLR, pp.1-15, 2015.
- [Schirrmeister 2017] Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., ... Ball, T.: Deep learning with convolutional neural networks for EEG decoding and visualization, Human Brain Mapping, 38(11), 5391–5420, 2017.
- [Nunez 2006] Nunez, P. L., & Srinivasan, R.: Electric Fields of the Brain, The Neurophysics of EEG Second Edition, Oxford University Press, 2006.

# 点眼瓶センサーと Deep Learning による 緑内障患者点眼アドヒアランス自動把握能力の評価

# Evaluation of Automatic Monitoring of Instillation Adherence Using Eye Dropper Bottle Sensor and Deep Learning in Patients with Glaucoma

| 田淵 仁志*1*2       | 西村 和晃*1                               | 中倉 俊祐*1                           | · 升本 浩紀*1                                 | 田邊 裕貴*2         |
|-----------------|---------------------------------------|-----------------------------------|---|-----------------|
| Hitoshi Tabuchi | Kazuaki Nishimura                     | Shunsuke Nakakura                 | Hiroki Masumoto                           | Hirotaka Tanabe |
|                 | 野口 明日香 <sup>*1</sup><br>Asuka Noguchi | 青木 良太 <sup>*1</sup><br>Ryota Aoki | 木内 良明 <sup>*2</sup><br>Yoshiaki Kiuchi    |                 |
| *1 社会           | 医療法人三栄会<br>Tsukazaki Hosipi           | ツカザキ病院<br>ital                    | <sup>*2</sup> 広島大学<br>Hiroshima Universit | у               |

Purpose: We developed and evaluated an eye dropper bottle sensor system comprising motion sensor with automatic motion waveform analysis using deep learning (DL) to accurately measure adherence of patients with antiglaucoma ophthalmic solution therapy. Results: The developed eye bottle sensor detected all 60 instillation events (100%). Mean difference between patient and eye bottle sensor recorded time was  $1 \pm 1.22$  (range; 0–3) min. Additionally, mean instillation movement duration was  $16.1 \pm 14.4$  (range; 4–43) s. Two-way ANOVA revealed a significant difference in instillation movement duration among patients (P < 0.001) and across days (P < 0.001). Conclusion: The eye dropper bottle sensor system developed by us can be used for automatic monitoring of instillation adherence in patients with glaucoma.

# 1. 諸言

緑内障患者は約8千万人いると推測され、年々その数は増 え続けている。緑内障は世界的に失明の主要な原因の病気の 1つである。緑内障点眼治療には患者アドヒアランスの問題が 大きく存在する、例えば、新規にプロスタグランジン系の緑内障 点眼薬を開始した患者の約3割が点眼治療を開始して3ヵ月の 間で治療をドロップアウトしているという報告がある。こうしたアド ヒアランス不良は治療の非効率化を招くと同時に、視野障害の 進行するリスクが6倍以上になると報告されている。従って、緑 内障点眼治療におけるアドヒアランス向上のための方法論は、 臨床上重要な視点として、自己申告によるもの、点眼瓶の重量 変化によるもの、点眼瓶ケースの挙動によるものなど、様々に報 告されてきた。ただ煩雑さや信用性の低さなどの問題がそれぞ れにあり、実際の臨床現場で一般的に定着している方法論が 我々の知る限り、いまだ存在しない。

一方で、最近になって、モバイルヘルスを利用した薬物治療 におけるアドヒアランス向上の取り組みが報告されている。モバ イルヘルスは、スマートフォンやタブレット端末を用いて個別の 情報をネットワーク接続し集積するという Internet of things の概 念の範疇である。自動的に膨大なデータを緻密に収集できる上 に、人手を介することがないためにコストパフォーマンスに圧倒 的に優れている。すでに慢性の病気である高血圧における降 圧剤の錠剤にセンサーを装着する事で患者の内服状況を監視 するシステムなどが報告されている。IoT と同様に、医療への応 用が広がり始めた技術が、Deep Learning である。DL は、それ 以前の機械学習の方法論からは一線を画す高い精度の識別 能力を持つ。眼科領域でも、画像識別の領域を中心に数多くの 報告が出始めている。まだ定まった方法論がない緑内障治療 における点眼アドヒアランス向上に、新しい技術である IoT や DL を応用した取り組みは我々の知る限り報告がない。 今回我々は点眼瓶の挙動そのものを自動的に検出する点眼 瓶センサーを開発した。さらに、DLを用いたセンサー波形の点 眼挙動自動識別モデルを作成し、システムとして組み合わせた。 (以下、点眼瓶センターシステム)。今回の検討では、緑内障患 者に実際に点眼瓶センサーを使用してもらい、緑内障点眼に関 する患者アドヒアランス自動把握の能力の評価を行った。

# 2. 方法

#### 2.1 点眼瓶センサーの構造

点眼瓶センサーの構造は以下で構成される。点眼瓶、TWE-Lite2525A(以下センサー)、点眼補助フォルダ、処理端末部、電 源コードからなる。点眼補助フォルダは点眼瓶を上にのせるた めのベースと点眼瓶を固定させるためのキャップと底蓋からなる。 ベースは中が空洞になっており、センサーを装着する事が可能 である。尚、センサーに CR1632 型リチウム電池をセットする必 要がある。処理端末部の詳細は以下の通りである。(図 2)処理 端末部のデータを記録するシールドにはデータロガーシールド (ADLSLD)を使用した。データロガーシールドには RTC(real time clock)機能、RTCを動かすためのCR1220型リチウム電池、 SD ソケット、外部データインターフェイス、誤動作した際に押す とプログラムが元に戻るリセットボタンなど様々な機能が元々備 わっている。さらに電源コードとつなげるための電源アダプター 差し込み口やUSB差し込み口も存在する。これにTWE-Lite無 線マイコン、12C バス用双方向電圧レベル変換モジュール (PCA9306)、ケース内組込型アンテナ MW-A-P4208、データ受 信確認用の LED やブザーも付け加えた。

#### 2.2 点眼瓶センサーの仕組み

点眼瓶の挙動によりセンサーが検知し IEEE802.15.4 準拠の 無線で処理端末部へデータを送信する。センサーはX,Y,Zの3 軸の加速度センサーが掲載されており、約 0.08 秒刻み間隔で

重力加速度値を検出する。送信されたデータはケース内組込 型アンテナ MW-A-P4208 で受信されて、TWE-Lite 無線マイコ ンにデータが送られる。無線マイコンでデータを処理し、ケーブ ルを通じて外部データインターフェイスに送られ、最終的に SD ソケット内の SD Memory Card にデータが記録される。TWE-Lite 無線マイコンの電源電圧が 5V で SD ソケット内の電源電圧が 3.3V のために 12C バス用双方向電圧レベル変換モジュール (PCA9306)を使用した。さらに、無線でデータが受信するとLED が光り、ブザーが鳴るなどデータの受信が確認可能な機能も併 せて掲載した。データロガーシールドに RTC 機能が掲載されて いるため、縦軸が重力加速度、横軸が時刻のグラフ化された形 で SD カードに記録される仕組みである。加速度センサーは重 力加速度を検出するために、重力加速度がどの方向にどれだ けかかっているのかを検出する事でセンサーがどれだけ傾いて いるか検出可能である。今回のシステムでは重力加速度が最小 値となる時刻が点眼中である。重力加速度が+1Gから小さくな っていく時刻を A、再び+1G に戻ってくる時刻を B として(A+B) ÷2 を点眼波形データの点眼時刻(秒単位まで)、(B-A)を点眼 動作時間と定義した。

# 2.3 DL 点眼判定モデルの構築法

点眼瓶にセンサーを装着し、直立した状態を 1、そこから反転して下方を向いた状態を-0.1 として約 0.08 秒刻み間隔で取得した 1 次元の波形データを 216pixel×216pixelのフルカラー 画像の線グラフとして、それを入力値として解析を行った。

学習モデルを生成するため健常者によるデータ 400 個を使用した。健常者に空のラタノプロスト点眼液 0.005%と点眼瓶センサーを渡し、両眼に点眼薬が入ったという仮定(シミュレーション点眼)を行ってもらい、点眼波形データを 200 個取得した。さらに点眼瓶を横に移動させるといったような点眼でない動作波形データも 200 個取得した。学習精度を上げるために波形全体のデータの他、波形の前部分を切り出したもの、波形の後方を切り出したもの、波形を平滑化したものを元のデータから新たに生成し、これも学習データとして使用した。

学習データを64×64pixelの画像に変換し入力値として使用。 各畳込み層(conv2d 1~conv2d 5)と、活性化関数(ReLU を使 用)とpooling層(max pooling2d 1~max pooling2d 4)を通り、平 滑化(Flatten)の工程を経て、その後に全結合層(dense 1、dense 2)と、その間に 10%の確率を設定した Dropout 処理を挟んで凡 化性能を上げ、最終的に出力層で Softmax 関数を用いたクラス 分類を行い、点眼動作をしている波形かを識別した。重みを最 適化させるためのアルゴリズムはAdamを採用した。上記の学習 サイクルを 30 回繰り返すことで内部パラメータを最適化した DL 点眼判定モデルを作成した。

#### 2.4 対象患者と評価方法

2017.3/1~2017.9/30の間でラタノプロスト点眼液 0.005%もし くはラタノプロスト・チモールマレイン酸塩配合点眼液を両眼に 点眼中の開放隅角緑内障患者 20人を対象にした。患者 20名 の平均年齢(標準偏差)は 64.1(12.06)歳で性別比は男 9名女 11名であった。点眼瓶センサーを自宅にて設置してもらった。 (図 5)同一空間内で処理端末部からおよそ 10m範囲内で 3日 間の点眼と点眼時刻の自己記載(分単位まで)をしてもらい、後 日、SDカードと点眼時刻の書かれた紙を回収した。患者データ から DL 点眼判定モデルを利用して自動取得された点眼と判 定された波形データの点眼時刻と、自己記載点眼時刻を比較 して 5 分以内であるものを検出成功として、検出率を算出した。 さらに各々の点眼動作時間についても算出した。点眼動作時間について個人間の差を分散分析にて検討した。Deep Learning モデルでの解析時間も算出した。使用コンピューター は MacBook Pro(Retina,13-inch,Early 2015)、外部装置と eGFX Breakway Box(eGPU Expansion System)[GPU-350W-TB3Z]と NVIDIA GeForce を使用した。

# 3. 結果

患者 20名の各年齢及び性別については表1に示す。また、患者 20名の MD 値の平均(標準偏差)が右眼は-8.5(7.48)デシベルで左眼は-6.9(6.55)デシベルであった。DL 点眼判定モデルから点眼と判定された波形データは60 個であった。各患者における点眼波形データの点眼時刻と自己記載時刻の差の平均(標準偏差)1(1.22)分(最大3分~最小0分)であった。今回の検出成功基準(<5分以内)にあてはめると検出率は100%であり、実際の点眼回数と過不足なく自動取得できた。計60 個の点眼動作時間の各患者の平均(標準偏差)が16.1(14.41)秒(最大43秒~最小4秒)であった。点眼動作時間は一元配置の分散分析にて個人間で有意差があった。(ANOVA P<0.0001)

#### 4. 考察

第一に、我々が開発した点眼瓶センサーシステムを緑内障 患者 20名に使用し、3日間の点眼状況を100%正確に自動抽 出することに成功した。そのデータの解析時間は1分以内であ った。まず、自己申告によらず、点眼状況が客観的に正確に把 握できるという点に価値がある。なぜなら実際のアドヒアランスと 自己申告にはほとんど相関がなく、点眼を本当はしていないの に、点眼をしていると報告する傾向があるからである。5)さらに 短時間で情報を自動取得できる点は、実臨床への適応の障壁 が低いことを示唆している。

第二に、点眼動作時間という我々の知る限りこれまでに報告 のない新しい指標を計測することに成功し、個人間でその時間 に統計学的に差があることを示した。今回のデータでは、最長 の平均点眼時間は、個人No14の43秒であり、最小は個人No3 の4秒であった。約40秒の差は2滴以上の点眼や正確に眼中 に滴下することが困難など点眼動作に何らかの違いがあること が予想される。過去の報告では、点眼手技の問題がアドヒアラ ンス不良の要因になっていると指摘されている。点眼動作時間 という新しい指標が、手技の改善指導に役立つ情報となると私 達は考えている。

今回の検討が3日間という短期間である点が、結果の解釈で 最も注意が必要な点である。期間が長くなることで、機械的な問 題が発生しやすくなり、患者さんのシステムの扱いもより雑にな る可能性が否定できない。さらに、今回の検討は1種類の点眼 での検討であり、多剤点眼使用者に対してどの程度システムが 応用できるかについても今後の検討が必要である。点眼瓶セン サーにかかる経費の詳細な検討も今回は行っていない。ただ、 センサーの部品については携帯電話に用いられる大量生産さ れている低コストの部品を用いており、部品代については日本 円で1000円程度である。

薬剤師が高齢者などの残薬を整理した所、医療費が約 80% 削減されたと報告されている。先進国共通のテーマである社会 保障費増大の問題に対して、残薬による医療費の浪費は小さく ない問題である。点眼瓶センサーシステムの実用化は、アドヒア ランス向上につながり、ひいては医療費の効率利用につながる 可能性を持っている。 今回我々は、Deep learningと点眼瓶センサーを組み合わせることで、点眼状況を客観的に正確に把握できるシステムを開発した。さらなる開発、検討を重ねて、実用化を目指していきたい。

- [Quigley 2006] Quigley HA, Broman AT: The number of people with glaucoma worldwide in 2010 and 2020, British Journal of Ophthalmology, BMJ, 2006
- [Pascolini 2012] Pascolini D, Mariotti SP:Global estimates of visual impairment: 2010, British Journal of Ophthalmology, BMJ, 2012
- [Nordstrom 2005] Nordstrom BL, Friedman DS, Mozaffari E, Quigley HA, Walker AM: Persistence and adherence with topical glaucoma therapy, American Journal of Ophthalmology, American Academy of Ophthalmology, 2005
- [Okeke 2009] Okeke CO, Quigley HA, Jampel HD, Ying GS, Plyler RJ, Jiang Y, Friedman DS: Adherence with topical glaucoma medications monitored electronically the Travatan Dosing Aid study, Ophthalmology, American Academy of Ophthalmology, 2009
- [Sleath 2011] Sleath B, Blalock S, Covert D, Stone JL, Skinner AC, Muir K, Robin AL: The relationship between glaucoma medication adherence, eye drop technique, and visual field defect severity, Ophthalmology, American Academy of Ophthalmology, 2011
- [Lievens 2006] Lievens CW, Gunvant P, Newman J, Gerstner M, Simpson C: Effect of Proview self-tonometry on pharmaceutical compliance, Clinical and Experimental Optometory, Wiley, 2006
- [Robin 2007] Robin AL, Novack GD, Covert DW, Crockett RS, Marcic TS: Adherence in glaucoma: objective measurements of once-daily and adjunctive medication use, American Journal of Ophthalmology, American Academy of Ophthalmology, 2007
- [Stegemann 2012] Stegemann S, Baeyens J-P, Cerreta F, Chanie E, Lőfgren A, Maio M, Schreier G, Thesing-Bleck E: Adherence measurement systems and technology for medications in older patient populations, European Geriatric Medicine, Springer, 2012
- [Park 2016] Park N, Kang N: Mutual Authentication Scheme in Secure Internet of Things Techonology for Comfortable Lifestyle, Sensors(Basel), MDPI, 2016
- [DiCarlo 2016] DiCarlo LA, Weinstein RL, Morimoto CB, Savage GM, Moon GL, Au-Yeung K, Kim YA: Patient-Centered Home Care Using Digital Medicine and Telemetric Data for Hypertension: Feasibility and Acceptability of Objective Ambulatory Assessment, The Journal of Clinical Hypertension(Greenwich), Wiley, 2016

- [Trebeschi 2017] Trebeschi S, van Griethuysen JJM, Lambregts DMJ, Lahaye MJ, Parmar C, Bakers FCH, Peters NHGM, Beets-Tan RGH, Aerts HJWL: Deep Learning for Fully-Automated Localization and Segmentation of Rectal Cancer on Multiparametric MR, Scientific Reports, Springer, 2017
- [大杉 2017] 大杉秀治、田淵仁志、遠野宏季、石飛 直史: Accuracy of deep learning, a machinelearning technology, using ultra-wide-field fundus ophthalmoscopy for detecting rhegmatogenous retinal detachment, Scientific Reports, Springer, 2017
- [Tamrat 2015] Tamrat L, Gessesse GW, Gelaw Y: Adherence to topical glaucoma medications in Ethiopian patients, Middle East African Journal of Ophthalmology, Wolters Kluwer, 2015
- [小栁 2013]小栁香織、窪田敏夫、小林大介、木原 太郎、吉田武夫、三井所尊正、斎藤友亮、打越 英恵、髙木淳一、瀬尾隆、島添隆雄:節薬バッグ 運動 外来患者の残薬の現状とその有効活用に よる医療費削減の取組み、薬学雑誌、日本薬学 会、2013

# リモート PPG 信号による睡眠/覚醒判別

Sleep/wake classification using remote PPG signals

張雅文<sup>\*1</sup> Yawen Zhang 辻川 剛範<sup>\*2</sup> Masanori Tsujikawa

大西祥史<sup>\*2</sup> Yoshifumi Onishi

\*1 Department of Electronic & Computer Engineering, Hong Kong University of Science and Technology

# \*2 Biometrics Research Laboratories, NEC Corporation

This paper proposes a remote sleep/wake classification method by combining vision-based heart rate (HR) estimation and convolutional neural network (CNN). Instead of directly inputting the estimated HR to CNN, we input remote PPG (Photoplethysmogram) signals filtered by a dynamic HR filter, which can overcome two main problems: low temporal resolution of estimated HR; much noise exists in the estimated remote PPG signals. Evaluation results show that the dynamic HR filter works more effectively compared to the static one, which helps improve AUC (area under the curve) index of the classification to 0.70, as good as the performance (0.71) of HR from a wearable sensor.

# 1. はじめに

眠気推定や睡眠/覚醒判別など覚醒度低下の定量化は, 疲労のリスク管理,運転中,勉強中,仕事中の状態モニタリング や,ヘルスケア等の応用のために広く研究されている. 眠気推 定手法としては,装着型センサを利用する手法やカメラを利用 する手法があるが,中でも顔映像から抽出した瞼の動きを用い る手法は,非接触型で使い勝手が良く,また高精度に眠気を推 定できる[Oliveira 2018, Tsujikawa 2018]. しかし,その手法は瞼 を閉じている状況(閉眼時)では常に眠いと判定されてしまうと いう問題があり,実際に寝ているのか,目を閉じているだけなの か判別できない.

閉眼時でも睡眠/覚醒を判別できる手法として,心電図 (Electrocardiogram: ECG)信号や光電式容積脈波記録法 (Photoplethysmogram: PPG)信号を用いる手法がある [Aktaruzzaman 2015, Ye 2016, Scherz 2017, Malik 2018]. ECG 信号や PPG 信号から,連続した心拍の間隔(Interbeat interval: IBI)の時系列信号を抽出し, IBI の逆数である心拍数(Heart rate: HR)や, IBI の時間変動である心拍変動(Heart rate variability: HRV)を分析して,睡眠/覚醒を判別する.心臓の 動きは自律神経により制御されており,覚醒中は交感神経が, 睡眠中は副交感神経が支配的になるため,覚醒中は睡眠中よ り心臓が活発に動く[Somers 1993]. そのため,睡眠/覚醒判別 において,心臓の動きを表す HRや HRV は重要な生理学的指 標とされている.

近年, HR や HRV を算出するための脈波を含む信号を取得 する手法として,離れて配置された(リモート)センサを利用する 手法の研究が盛んである.文献[Rahman 2015]は、ドップラーレ ーダで抽出した HRと呼吸数,体動を用いて,睡眠をセンシング できるシステムを提案している.そのシステムにより,高精度に 睡眠/覚醒を判別できると報告されている.しかし,前述の顔映 像から眠気を推定するシステムとの統合のためには、リモートセ ンサとしてカメラを利用することが望ましい.

顔映像から HR を推定する手法は、ますます盛んに研究され ている[Wang 2018, Utkarsh 2018]. それは、顔の輝度値に基づ く推定手法と顔の動きに基づく推定手法の二種に大別されるが、 前者の研究が盛んである. カメラで捉えた顔の輝度値から PPG 信号(リモート PPG 信号)を抽出した後,高速フーリエ変換(Fast Fourier Transform: FFT)などの周波数分析を用いて,HRを推 定する. 心臓は周期的に動いているため,パワーが大きい周波 数成分をHR成分とする. 欠点は,周波数分析の窓幅に相当す る区間のHRしか計算できず,一拍一拍の瞬間的なHR (Instantaneous HR: IHR)の変化を高精度に捉えることが困難な 点である. それは,短い周波数分析窓幅ではHR 情報が,頭の 動きや光の変化等で生じる大きなノイズに埋もれるためである. IHR の変化はHRV の算出において重要であり,そのHRV は 睡眠/覚醒判別の重要な指標の一つである.したがって、リモ ートセンサとしてカメラを利用して,睡眠/覚醒を判別する際の 課題は,リモートPPG 信号からIHR の情報,すなわち高時間解 像度のHR 情報を高精度に抽出することである.

上記の課題に対して、高時間解像度のHR情報を含むリモートPPG信号による睡眠/覚醒判別を提案する.頭の動きや表情変化,光の変化により生じる大きなノイズで埋もれた、高時間解像度のHR情報を抽出するために、低時間解像度のHRの分布情報から動的に設計したフィルタを用いてノイズを除去する. ノイズ除去後のリモートPPG信号は、手動での特徴抽出を避けるために、畳み込みニューラルネットワーク(Convolutional neural network: CNN)に直接入力し、睡眠/覚醒を判別する. 2章で提案法を詳細に説明し、3章で、睡眠/覚醒判別の評価実験において提案法の有効性を示す.

# 2. 睡眠/覚醒判別法

#### 2.1 従来法

図 1 に文献[Malik 2018] で提案されている従来の睡眠/覚 醒判別手法の構成を示す. 装着型センサである ECG センサか ら ECG 信号を得て, 連続した心拍の間隔 IBIを算出し, その逆 数である IHR を 以下の式で算出する.

ただし、IHR(i)はi番目の IHR で単位は bpm(beat per minute), IBI(i)はi番目の IBI で単位は秒である. IHR(i)は不等間隔でサ ンプリングした時系列信号のため、補間処理により等間隔でサ ンプリングして HR の時系列信号を得た後、一定の時間窓で区 切った HR の時系列信号を CNN に入力する. HR 信号から睡

連絡先:辻川剛範, NEC バイオメトリクス研究所, tujikawa@cb.jp.nec.com

眠/覚醒を判別できるように学習した CNN により,新たに入力 された HR 信号に対して睡眠/覚醒の判別結果を出力する.

文献 [Malik 2018] では、二つの公開データベース① DREAMS Subject Database<sup>1</sup>、②UCDSADB<sup>2</sup>を用いて、学習したモデルの判別精度を評価している。①に対する AUC (Area under the curve) が 0.81、②に対する AUC が 0.72 で判別可能と報告されている。

上記の従来法における装着型センサから算出した HR (Wearable HR)を、カメラから算出した HR (Camera HR)に置き 換えると、次の問題がある. 主問題は、Camera HR の時間解像 度が低いことである. Camera HR は、一定の推定精度を得るた めに、通常、IBIより長い時間窓で PPG 信号を周波数分析して 算出される. もう一つの問題は、ノイズに起因する推定誤差であ る. 次節で説明する提案法では、高い時間解像度の HR 情報を 含む PPG 信号に混在したノイズを動的なフィルタで除去し、そ れを CNN に入力することで上記の二つの問題を解決する.

#### 2.2 提案法

図 2 は,提案する睡眠/覚醒判別手法の構成を示す.それ は,文献[Utkarsh 2018]の Camera HR 推定法と文献[Malik 2018]で適用された CNN を組み合わせた手法である.その Camera HR 推定法は他手法と比較して高精度に HR を推定で きると報告されている.まず,提案法ではカメラで取得した顔映 像から PPG 信号(Camera PPG)を抽出する.次に, Camera PPG から Camera HR を推定し, Camera HR の値に基づいて動的に 設計したフィルタ(Dynamic Camera-HR filter)で Camera PPG に 含まれるノイズを除去する.ノイズ除去後の Camera PPG を図 3 に示す CNN に入力し,睡眠/覚醒を判別する.以下, Camera PPG に含まれるノイズの除去手順と文献[Malik 2018]の CNN と のモデル構造の違いについて説明する.その他に関しては,文 献[Utkarsh 2018]と[Malik 2018]を参照して欲しい.

Dynamic Camera-HR filter は、Camera-PPG に含まれるノイズ を除去することで、HR 情報を強調するバンドパスフィルタである。 それは Camera HR を用いて設計される。一定時間窓内の HR が正規分布に従うと仮定し、その平均を $\mu$ 、標準偏差を $\sigma$ とする と、 $\mu \pm 3\sigma$ の範囲に 99.7%の値が含まれる。窓番号 *I* の Dynamic Camera-HR filter のカットオフ周波数の下限 $L_D(I)$ と上 限 $H_D(I)$ を $\mu(I)$ と $\sigma(I)$ を用いて次のように算出する。

 $L_D(I) = \frac{\mu(I) - 3\sigma(I)}{60}, H_D(I) = \frac{\mu(I) + 3\sigma(I)}{60}$ (2) 窓番号 I 毎に, 推定した HR に応じてバンドパスフィルタの下限

と上限を動的に調整する. その下限と上限を用いて, 2次のバタ ワースバンドパスフィルタを設計する.

Dynamic Camera-HR filter の効果を検証するため、次章の評価で用いる学習データセット(DREAMS)のHR 情報から設計した静的なバンドパスフィルタ(Static HR filter)と比較する. Static HR filter においては、下限 $L_S = 0.53$ Hz、上限 $H_S = 1.75$ Hz である. それらの値は次式で算出した.

$$L_{S} = \min[L_{wake}, L_{sleep}], H_{S} = \max[H_{wake}, H_{sleep}]$$
(3)  
$$L_{wake} = \frac{\mu_{wake} - 3\sigma_{wake}}{2} L_{sleep} = \frac{\mu_{sleep} - 3\sigma_{sleep}}{2}$$
(4)

$$H_{wake} = \frac{\mu_{wake} + 3\sigma_{wake}}{\epsilon_0}, H_{sleep} = \frac{\mu_{sleep} + 3\sigma_{sleep}}{\epsilon_0}$$
(5)

ただし、 $\mu_{wake} \geq \mu_{sleep}$ は、それぞれ学習データにおいて覚醒状態または睡眠状態とラベル付けされた時刻の HR の平均、同様に $\sigma_{wake} \geq \sigma_{sleep}$ は標準偏差である.それらを用いて、覚醒状態における HR の分布の下限 $L_{wake}$ と上限 $H_{wake}$ ,睡眠状態にお



図3 (a) PPG 信号を入力する場合の1次元 CNN の構造. *m*-Dense は *m* ノードの全結合層. (b)単一の畳込ブロックの構造. (*f*, *k*, *s*)-convolution はフィルタ数*f*, カーネルサイズ*k*, ストライ ド*s* の畳込層.







図5 Static HR filter と Dynamic HR filter の適用例.

ける下限L<sub>sleep</sub>と上限H<sub>sleep</sub>を算出し、最小値演算と最大値演算により、Static HR filterの下限L<sub>s</sub>と上限H<sub>s</sub>を算出した.

図 4 に Static HR filter と Dynamic HR filter の周波数帯域を 例示する. 比較のため, Dynamic HR filter は, Wearable HR か ら設計した Dynamic Wearable-HR filter と Dynamic Camera-HR filter の二種を示す. 二種の Dynamic HR filter の周波数帯域は

<sup>&</sup>lt;sup>1</sup> http://www.tcts.fpms.ac.be/~devuyst/Databases/DatabaseSubjects

<sup>&</sup>lt;sup>2</sup> https://physionet.org/pn3/ucddb



図6 三つの評価の関係. E1:評価1, E2:評価2, E3:評価3.



図7 検証用データの収集

表1

評価に用いたデータ

|          | Dataset   | # of<br>subjects                         | Recording<br>length                                 | Contents  |
|----------|---|--|---|---|
| Train    | DREAMS<br>Subjects<br>Database+<br>DREAMS<br>Patients<br>Database | 7 healthy<br>subjects<br>+12<br>patients | ~8hours/pe<br>rson,<br>19182 1-<br>min.<br>segments | Wearable sensor:<br>PPG signals, ECG<br>signals.            |
| Validate | Data<br>collected by<br>ourselves                                 | 25 healthy<br>subjects                   | ~30min/per<br>son,<br>1581 1-<br>min.<br>segments   | Wearable sensor:<br>PPG signals, IBI<br>Camera: face videos |



Wearable HR における時間解像度 (0.25/0.5/1/2/4 Hz)の違い

Static HR filterと比較して狭い.人や状態(睡眠/覚醒)に応じて HR の分布が異なるため,その分布に応じて動的に算出する ことで周波数帯域が狭くなる.その周波数帯域の外側に存在するノイズを除去するため,帯域が狭い Dynamic HR filterの方が ノイズの除去量が多くなる.さらに,Dynamic Wearable-HR filterの方が Dynamic Camera-HR filter より周波数帯域が狭い. Dynamic Camera-HR filter より周波数帯域が狭い. Dynamic Camera-HR filter の周波数帯域は HR の推定誤差が 含まれるためである.しかし,多くの場合に Dynamic Camera-HR filterの周波数帯域は Dynamic Wearable-HR filterの帯域を含んでおり,ノイズ除去量は劣るが,HR 情報は殆ど欠落しない.

図 5 に、図 4 の窓番号 *I*=561 の Camera PPG に対して、(b)/ イズ除去フィルタ無しの場合、(c) Static HR filter を掛けた場合、 (d) Dynamic Camera-HR filter の場合, (e) Dynamic Wearable-HR filter の場合を例示する. なお,参考のため, (a)には装着型 センサで得た PPG 信号 (Wearable PPG)を示す. (b)と(c)には多 くのノイズが含まれるが, (d)と(e)は Dynamic HR filter により HR 情報を残しつつノイズが除去されている.

ノイズ除去後の Camera PPGを図 3 に示す CNN に入力して 睡眠/覚醒を判別する. 図 3 に示す CNN の構造は文献[Malik 2018]のモデル構造に従う. そのモデル構造は睡眠/覚醒判別 に必要な HRV を適応的に抽出できるものである. 文献[Malik 2018]との違いは,入力サイズとカーネルサイズを 2 倍にした点 のみである. それは,同等の HR 情報を含むように, HR の時系 列信号に対して, PPG信号のサンプリングレートを 2 倍に設定し たためである. HR に関する情報量は同じであるため, PPG信号 にノイズが含まれなければ,文献[Malik 2018]と同等の精度で 睡眠/覚醒を判別できると想定される.

#### 3. 睡眠/覚醒判別評価

提案法の有効性を確認するため、CNN への入力を変えて、 睡眠/覚醒の判別結果に対するAUC指標を比較した.具体的 には、以下三つの評価を行うことで、文献[Malik 2018]の Wearable HR を入力した場合(従来法)に対する、Camera PPG を入力した場合(提案法)の有効性を確認した.各評価での確 認事項は⇒印で示す通りである.

評価1: Wearable HR vs Camera HR ⇒HR の時間解像度の低さが問題であること 評価2: HR vs PPG 信号

⇒PPG 信号が高時間解像度の HR 情報を含むこと

⇒PPG信号がノイズを含み、それが問題になること

評価3: PPG信号へのノイズ除去フィルタの適用

⇒Dynamic HR filter によりノイズ除去が可能なこと ⇒Camera PPG でも睡眠/覚醒判別が可能なこと

図 6 は評価1~3の関係図である. 最終的に,図 6 の赤矢印の 比較により, Camera PPG(提案法)でも, Wearable HR(従来法) と同等精度で睡眠/覚醒判別が可能なことを確認する.

#### 3.1 評価に用いたデータ

表1に、評価に用いた学習データと検証データを示す.学習 データは、公開データ(DREAMS Subject Database<sup>1</sup>と DREAMS Patient Database<sup>2</sup>)から選択した計 19 名分である. それらには Wearable HR と Wearable PPGの両方が含まれる. Wearable HR 算出のための ECG 信号と Wearable PPG のオリジナルのサンプ リングレートは 200Hz であった. 1 分区切りの 19182 サンプルの うち覚醒 (Positive)が 4239 サンプル,睡眠 (Negative)が 14942 サンプルであった.

検証データは、我々が収集した. 図 7 に示すように、装着型 センサ(Empatica 社 E4)と上下の顔向き変動に対処するための 二つのカメラ(640×480 画素、30fps)を用いた. 収集は覚醒と 睡眠の二つのステージを含む. 覚醒ステージで、実験協力者は 15 分間スマートフォンを利用した. 睡眠ステージの準備として単 調な計算タスクを 10 分間行った. その後の 40 分間が睡眠ステ ージである. 最後に、実験協力者は目覚めた時刻と、睡眠ステ ージ開始から何分ぐらいで眠りに落ちたかを質問紙に回答した. 睡眠の平均時間は12.3 分,標準偏差は 6.6 分であった. 1 分区 切りの 1581 サンプルのうち覚醒(Positive)が 898 サンプル、睡 眠(Negative)が 683 サンプルであった.

 $<sup>^{1}\,</sup>http://www.tcts.fpms.ac.be/~devuyst/Databases/DatabaseSubjects$ 

<sup>&</sup>lt;sup>2</sup> http://www.tcts.fpms.ac.be/~devuyst/Databases/DatabasePatients

#### 3.2 評価1:Wearable HR vs Camera HR

CNN への入力として, Wearable HR と Camera HR を比較した. 何れも4Hz でサンプリングされた HR の時系列信号で, 窓幅は 1 分, つまり入力サイズは 240 で固定である. 睡眠/覚醒判別結果として, ROC(Reciver Operating Characteristic)カーブを図8に示す. Wearable HR の AUC は 0.71 で, Camera HR の 0.58 より高い. その理由として次の二つが考えられる. ①Camera HR は推定誤差が大きい. ②Camera HR の時間解像度が低い. まず理由①の確認のため, Wearable HR を正解として, Camera HR の推定誤差を算出した. RMSE は 11.1bpm, 相関は 0.49 であり, 比較的誤差が大きい.

理由②の確認のため、CNN の入力に含まれる HR 情報の時 間解像度を低くして睡眠/覚醒判別の評価を行った. 具体的 には、4Hz の Wearable HR の算出において、0.25/0.5/1/2 Hz で サンプリング後に、4Hz でサンプリングした. 図 9 において、最も 高時間解像度である 4Hz の AUC が 0.71 と最も高く、時間解像 度が低いと AUC は低下する. 低時間解像度の HR 情報では、 睡眠/覚醒判別に有効な、HRとHRV の情報が欠落している.

#### 3.3 評価2: HR vs PPG 信号

Camera HR では高時間解像度の HR 情報を得ることが困難 なため、Camera PPGを CNN に入力し、Camera HR と比較した. Camera PPG のサンプリングレート 30Hz は顔映像のフレームレ ートと同じ 30fps だが、比較する 4Hz の HR と情報量をそろえる ため、8Hz にダウンサンプリングした. CNN の入力サイズは 8Hz ×60 秒間で、480 である. Wearable HR と Wearable PPG の比 較も参考のために行った.

図. 10(a)は装着型センサを,(b)はカメラを用いた場合の睡眠 / 覚醒判別結果である.(a)では Wearable HR の AUC(0.71)が Wearable PPG の AUC(0.62)より高いが,(b)では Camera PPG の AUC(0.66)が Camera HR の AUC(0.58)より高い.(b)の結果は高 時間解像度の HR 情報が睡眠/覚醒判別において重要で,そ れが含まれるPPG信号から抽出できることを示す.(a)の結果と, Camera PPG の AUC が Wearable AUC より低い原因としては, PPG 信号に含まれるノイズが問題と想定される.次節で,ノイズ 除去フィルタの効果を示す.

#### 3.4 評価3: PPG 信号へのノイズ除去フィルタの適用

PPG 信号に対してノイズ除去フィルタを適用し,睡眠/覚醒 判別結果を比較した.図.11の(a)装着型センサと(b)カメラの両 方で,ノイズ除去フィルタの適用による判別精度改善を確認で きる.また,Dynamic HR filter は Static HR filterより判別精度の 改善効果が高く,(a)と(b)の両方で,Wearable HRのAUC=0.71 とほぼ同じ精度を達成した.



図10 ROC カーブ: HR vs PPG 信号

予想した通り, (b)において, Dynamic Wearble-HR filter の改 善効果が Dynamic Camera-HR filter より少し高い. その理由は 図 4 で示したように, Dynamic Wearble-HR filter の帯域幅が Dynamic Camera-HR filter より狭く, ノイズ除去効果が高いため である. Dynamic HR filter の改善効果が Static HR filter より高 い理由も同じである.

#### 4. まとめ

リモート PPG 信号 (Camera PPG) による睡眠/覚醒判別方法 を提案した. 提案法は, Camera HR と CNN を組み合わせた手 法であり, まぶたの動きに基づく眠気推定方法と統合可能であ る. Camera HR を直接 CNN に入力する代わりに, Dynamic HR filter で処理した Camera PPG を CNN に入力する. それは, Camera HR の時間解像度の低さ, Camera PPG に含まれるノイ ズという二つの問題を解決する. 評価において, Dynamic HR filter が Static HR filter より効果的であり, 判別精度指標 AUC を 0.70 に改善できることを示した. それは, Wearable HR の AUC (0.71)と同等である.

- [Oliveira 2018] L. Oliveira, et al.: Driver drowsiness detection : a comparison between intrusive and non-intrusive signal acquisition methods, 2018 7th European Workshop on Visual Information Processing (EUVIP), IEEE, 2018.
- [Tsujikawa 2018] M. Tsujikawa, et al.: Drowsiness Estimation from Low-Frame-Rate Facial Videos using Eyelid Variability Features, 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), IEEE, 2018.
- [Aktaruzzaman 2015] M. Aktaruzzaman et al.: The addition of entropy based regularity parameters improves sleep stage classification based on heart rate variability, Medical & Biological Engineering & Computing, vol. 53, Issue 5, pp. 415-425, Springer, 2015.
- [Ye 2016] Yanqing Ye et al.: Automatic Sleep and Wake Classifier with Heart Rate and Pulse Oximetry : Derived Dynamic Time Warping Features and Logistic Model, 2016 Annu. IEEE Syst. Conf., IEEE, 2016.
- [Scherz 2017] W. D. Scherz et al.: Heart rate spectrum analysis for sleep quality detection, EURASIP Journal on Embedded Systems, EURASIP, 2017.
- [Malik 2018] J. Malik et al.: Sleep-wake classification via quantifying heart rate variability by convolutional neural network, Physiological Measurement, 29.8, 2018.
- [Somers 1993] V. K. Somers et al.: Sympathetic-Nerve Activity during Sleep in Normal Subjects, New England Journal of Medicine, 328.5, pp. 303-307, 1993.
- [Rahman 2015] T. Rahman et al.: DoppleSleep: A Contactless Unobtrusive Sleep Sensing System Using Short-Range Doppler Radar, Proceedings of the 2015 ACM international Joint Conference on Pervasive and Ubiquitous Computing, ACM, 2015.
- [Wang 2018] C. Wang et al.: A Comparative Survey of Methods for Remote Heart Rate Detection From Frontal Face Videos, Frontiers in Bioengineering and Biotechnology, vol. 6, no. May, pp. 1–16, 2018.
- [Utkarsh 2018] S. Utkarsh et al.: Adaptive Heart rate estimation from face videos, The 8th Symposium on Biometrics, Recognition and Authentication, S2-9, IEICE, 2018.



図11 ROC カーブ: PPG 信号に対するノイズ除去フィルタの効果

サンプル混合度を考慮した遺伝子発現量のがんバイオマーカー探索 Biomarker discovery from gene expression data of mixed tumor samples

> 村上 勝彦<sup>\*1</sup> Katsuhiko Murakami

# \*1 富士通研究所 FUJITSU LABORATORIES LTD.

To diagnose the state of tissues from cancer patients, utilization and discovery of biomarker with high discrimination accuracy is important. It is difficult to determine biomarkers that can cleanly separate cancer and normal tissues when normal tissues are mixed at the time of collecting a cancer sample. The purpose of the study is to provide method to discover biomarkers or characteristics of tissues with high accuracy for distinguishing between cancer tissues and non-cancer tissues. By utilizing a parameter  $\lambda$ , which indicates purity and status of each sample, highly accurate biomarker discovery became possible.

# 1. はじめに

細胞の状態を診断するため、判別精度が高いバイオマーカ ー探索方法は重要である.バイオマーカーとは、一般には病気 の変化や治療に対する反応に相関し、指標となるものである.よ り具体的には、血液や尿などの体液や組織に含まれる、タンパ ク質や遺伝子などの生体内物質の存在、またはその量がバイオ マーカーとなる.

本稿で扱う問題は、がん細胞と非がん細胞を判別するための バイオマーカー(がん細胞で高発現する遺伝子セット)探索であ る. 良い特徴量を選択できれば、新規の患者候補のサンプルが、 癌であるかを精度良く判定できる. 高精度の判定ができれば、 治療の前後でサンプルを判定することで、治療がすすんでいる か、転移していないかを判定することにも用いられる.

バイオマーカー利用の際には、未知サンプルのバイオマーカ ー値を計測してサンプルの医学・生物学的な状態を推定する. 探索時に構築した予測モデルを用いてバイオマーカー値を算 定し、未知サンプルが、がんであるかの判定する.判定結果は、 採取したサンプルが癌であるかの判定、癌種類や進行度の特 定、臨床における治療効果の判定等に利用される.判別モデ ルは、回帰分析や LinearSVM [Abeel 2009] など通常の機械学 習で学習、判別する.

実際のデータでは、がんサンプルを採取する際に正常細胞 が混じったり,がん細胞内で特徴が大きくばらつく場合があり, がんと正常細胞をきれいに分離できるバイオマーカーを決定す ることが困難になることがある. そこでサンプル内の正常細胞と がん細胞の割合をパラメータとして統計モデルを作り ML(最尤 法) で求める方法がある [Shen 2015]. しかしこれらは、「癌」と「正 常」の2クラス分類で、学習や判定の際に、クラス内サンプルを 等価に扱っている. 「癌」も「正常」が均一であると仮定していて これらの多様性が考慮されてない.また,癌には同種のがん(例 えば「大腸がん」)でも様々なタイプや進行度がある.現在は同 じ分類でもサブクラス分類が有効かもしれないが解析には考慮 されていない. 遺伝子発現量も安定な線形を仮定し, 遺伝子の 多様性を扱っていない. サンプルや遺伝子によって, 外れ値の ようにモデルにあわない部分がある. これらをノイズと扱うべき場 合でも,等価に学習してしまうため,正しいパラメータを推定でき なくなる.

連絡先:村上勝彦,富士通研究所,<u>murakami.ktk@gmail.com</u>

本研究の目的は,提案した手法により混合度がどのていど推 定可能を評価することである.

# 2. データと方法

### 2.1 データセット

バイオマーカー探索の際には,癌サンプルと,(ネガティブ) コントロールとしてがんが発生している組織(例:肺,肝臓)の正 常サンプルを採取する.組織サンプルごとに遺伝子jの発現量 を計測する.サンプルiに対して,測定値j(遺伝子jの発現量) x<sub>ij</sub>とすると,データは行列形式に書ける.サンプルは大きく2つ にわかれる.「がんサンプル」とラベルされたものと、「正常サン プル」である.しかしこれらはすべてが正しいものではない、とい う前提が本研究で重要なポイントである.解析の過程ではこれら のラベルは訂正される段階を経て,全体が解析される.

評価用のデータとして、NCBI GEO 遺伝子発現データベース (http://www.ncbi.nlm.nih.gov/geo/)から、アクセッション番号 GSE16515 として公開されている膵臓癌のデータを用いた.これ には正常サンプル 16 個、がんサンプル 36 個、合計 52 サンプ ルのデータである.この実データをもとにして混合率の異なるデ ータセットを作成した.それらが以下に述べる手法で同定可能 かどうかを検討した.

#### 2.2 混合度の推定とバイオマーカー探索方法

「癌細胞として採取したサンプル内に混在する正常細胞の割合」を、隠れた変数として推定できるように、正常細胞の混在率(0から1) λ(正常度と呼ぶことにする)をモデルに組み込む. λ は正常細胞とみなせる程度のパラメータとも解釈できる.

また, 癌細胞はいくつかのステージで進行するものや分岐す るなどの例が知られている. 現在同じラベル(例「大腸がん」)と いってもサブクラスで状態が異なる可能性がある. 異なる状態に は異なるバイオマーカーで状態を判定するのが適当である. λ は細胞の正常度・非進行度とも解釈できる.

この状態をとらえる隠れ変数を導入して、データから細胞の 状態を推定できるようにする.これは教師ラベル(癌,正常)と高 い相関があるが異なるものである.

正常度パラメータんが1に近いサンプル(第1グループ)は正 常細胞とみなせる.一方,正常度パラメータんが0に近いサンプ ル(第2グループ)は癌細胞とみなせる.またんが 0.5 に近いサ ンプル(第3グループ)は混合したサンプルか,ずれた正常細胞 か,初期の癌細胞とみなせる.第3グループのサンプルは,判別の教師データとしてはのぞましくない.これを除いた(第1と第2グループからなる)学習データを作成し,再度判別モデルを構築すると,精度高い判別モデルが作成できる.同時に癌細胞の特徴をよく捉える特徴量のセット(バイオマーカー)が決定できる.

詳細には、以下の手順で行う(図1).発現量など特徴量の変数を規格化する. SVDにより次元削減(約54,613次元から50次元程度へ)をする.5万という数はプローブの数であり、遺伝子数の数倍になっている.多くの場合はサンプル数が100個程度なので、それが次元の上限となる.

次にサンプルのクラスタリングを行う.例はガウス混合分布だが, k 平均法など他の方法でもよい.

クラスター数 n(>2)を決め, n の数だけのガウス分布の重なり で表現する「混合ガウス分布(GMM)」のパラメータを求める.

ガウス分布のパラメーターは、クラスター*l*に対して、 平均  $\mu_l$ ,分散  $\sigma_l$ ,中心位置ベクトル $\vec{c_l}$ , (l=1,2,...,n)である. 各サンプル (x i) <sup>\*</sup>生成確率分布は、

$$P(\overrightarrow{x_{l}}) = \sum_{l=1}^{n} \pi_{l} C_{l} e^{-\left\{ (\overrightarrow{x_{l}} - \overrightarrow{c_{l}}) \right\}^{2}}$$

とする. ここで $\pi_l$ はクラスター lの推定比率,  $C_l$  は規格化定数. この全サンプルで和をとり, 最大化するように求める.

常細胞サンプルだけから平均ベクトル**x**<sub>v</sub>を求めておき, x<sub>v</sub>を 含むクラスターと含まないクラスターに分ける.

 $x_v$ に近いクラスター中心を持つクラスターから順に,属するメンバーのクラスターを結合していき,教師データラベルが正常 細胞のサンプルのうち,9割以上を含むクラスターが見つかった ところで結合を停止する.その時点で結合されたクラスター群  $n_n$ 個を「正常クラスター」,それ以外 $n_a$ (= $n - n_n$ )個を「異常ク ラスター」とみなす.よって各サンプルi毎に

 $\lambda_i = \sum_{l \in N} \pi_{il}$ 

が計算できる. 正常度*\lambda*iが両極値を含まない領域(例えば 0.2 から 0.8)のサンプルを, 混在サンプルグループ M に属するとみな す. はじめのデータセットのサンプルのうちからサンプル群 M を 除き, 混合度の低い新規学習データ D\_new を作成する. D\_new を用いてロジスティック回帰などのなんらかの判別器を 作成する. 結果, 判別モデルと, バイオマーカーが得られる.



図1 解析方法のフローチャート.赤字が特徴的部分.

## 3. 結果

混合率の異なるデータセットごとに本手法を適用した結果, 人工データにおいて混合サンプルを作成し,混合サンプルのう 70%を同定でき,それに基づくバイオマーカーを得た.

#### 4. 議論

#### 4.1 パラメータの意義

癌細胞と正常細胞の実サンプルには、それらの混在サンプ ルがあり得る.サンプルがマッピングされる特徴量空間で、2サ ンプル群の中間に位置する細胞は混在サンプルであることが想 定される.これらのサンプルは、本来離れた位置にあるはずの2 種のサンプルが混在した疑似サンプルであり、細胞としては実 在しない.これらを、中間的な特徴量をもつサンプルとして学習 するのは正しくない.これは生体サンプルでの特別な状況であ る.本方法ではパラメータンを導入して混在状況を把握できる.

混在サンプルが多い場合,通常のモデル構築では,精度の 悪い結果を得るだけである.しかし本発明では,もしんが中間 値をとるようなサンプルが多い結果となれば,混合サンプルが多 いという情報が得られる.

混合サンプルがあると,正しいモデル構築が非常に困難になる.ここでは混合サンプルをほぼ無視したきれいな学習データによるモデル構築ができる.その結果,高精度で安定的なバイオマーカー探索が行える.

# 5. おわりに

がん細胞を採取する際,目視で正常細胞と見分けることがし ばしば困難であり,採取したサンプルに正常細胞が混在するこ とがある.正常サンプルについても,その外れ値や異常性は考 慮できなかった.混合サンプルがあるとそれらがノイズとなり特 徴量を正しく学習できない.

本提案では、教師付学習の正解ラベル第1値(正常サンプル) の学習データ数の情報に基づいて、複数クラスタを統合した統 合クラスを生成することで、正常サンプルのラベル修正を可能と した.その結果、70%の混合サンプルを同定できた.結果、判 別に有効なバイオマーカーを得た.今後、モデルを改良したり、 さまざまなサンプルについて実験を重ねていく予定である.

- [Abeel 2009] T. Abeel, T. Helleputte, Y. Van de Peer, P. Dupont, and Y. Saeys, "Robust biomarker identification for cancer diagnosis with ensemble feature selection methods," Bioinformatics, 2009.
- [Emmert 1996] M. R. Emmert-Buck, et al. "Laser Capture Microdissection", Science, 1996.
- [Zhao 2018] L. Zhao, V. H. F. Lee, M. K. Ng, H. Yan, and M. F. Bijlsma, "Molecular subtyping of cancer: current status and moving toward clinical applications," Brief. Bioinform., 2018.
- [Ahn 2013] J. Ahn et al., "DeMix: Deconvolution for mixed cancer transcriptomes using raw measured data," Bioinformatics, 2013.
- [Shen 2016] Q. Shen, J. Hu, N. Jiang, X. Hu, Z. Luo, and H. Zhang, "contamDE: differential expression analysis of RNA-seq data for contaminated tumor samples," Bioinformatics, 2016.

Plenary session

# [3A1-PS-3] Explain Yourself – A Semantic Stack for Artificial Intelligence

Thu. Jun 6, 2019 9:00 AM - 10:10 AM Room A (2F Main hall A) The room is connected with B and the lecture is broadcast to room C.

# [3A1-PS-3] Explain Yourself – A Semantic Stack for Artificial Intelligence

Randy Goebel<sup>1</sup> (1. Professor of Computing Science at the University of Alberta, Canada, and co-founder of the Alberta Machine Intelligence Institute (AMII)) 9:00 AM - 10:10 AM 9:00 AM - 10:10 AM (Thu. Jun 6, 2019 9:00 AM - 10:10 AM Room A)

[3A1-PS-3] Explain Yourself – A Semantic Stack for Artificial Intelligence Randy Goebel<sup>1</sup> (1. Professor of Computing Science at the University of Alberta, Canada, and co-founder of the Alberta Machine Intelligence Institute (AMII))

Artificial Intelligence is the pursuit of the science of intelligence. The journey includes everything from formal reasoning, high performance game playing, natural language understanding, and computer vision. Each AI experimental domain is littered along a spectrum of scientific explainability, all the way from high-performance but opaque predictive models, to multi-scale causal models. While the current AI pandemic is preoccupied with human intelligence and primitive unexplainable learning methods, the science of AI requires what all other science requires: accurate explainable causal models. The presentation introduces a sketch of a semantic stack model, which attempts to provide a framework for both scientific understanding and implementation of intelligent systems. A key idea is that intelligence should include an ability to model, predict, and explain application domains, which, for example, would transform purely performance-oriented systems into instructors as well.

Proposed session

[313-KS-8] 役に立つ人の心の過程のモデリング Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room I (306+307 Small meeting rooms)

[3I3-KS-8] 役に立つ人の心の過程のモデリング 1:50 PM - 3:30 PM 1:50 PM - 3:30 PM (Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room I) [3I3-KS-8] 役に立つ人の心の過程のモデリング

対人サービスでは人の心の状態の推定はサービスの質向上に重要である.現在の人工知能は人の知的機能をモデ ル化しようとしているが、人の非言語であいまいな過程が意思決定を支配するというのが認知科学の知見であ る.本セッションは、この人の意思決定と人工知能の溝を埋めるべく、いくつかの事例についての人の認知過程 のモデルとありうる展開を紹介し、対人サービス人工知能の新たな開発に資することを目指す. Proposed session

# [3I4-KS-10] AIマップタスクフォースの活動一 AI初学者・異分野研究者のための AI研究の俯瞰一

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room I (306+307 Small meeting rooms)

# [3I4-KS-10] AIマップタスクフォースの活動一 AI初学者・異分野研究者のための AI研究の俯瞰一

3:50 PM - 5:30 PM

3:50 PM - 5:30 PM (Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room I)

# [3I4-KS-10] AIマップタスクフォースの活動一 AI初学者・異分野研究者のための AI研究の俯瞰一

AI研究は21世紀に大きく拡大し,全貌の俯瞰的な把握が難しくなっている.そこで,研究発展と外部アピールを 目的に,主にAI初学者および異分野研究者のためのAIマップのβ版を理事会中心に作成した.β版は「知能を捉 える視点」「基盤・手法・応用の相互作用」「知能活動のフロー」「技術と応用対象の連関」という異なる観点 に基づく4枚のマップからなる.β版の紹介と参加者との意見交換,また関連してJST俯瞰報告書や機械学習 マップを紹介する.
Proposed session

## [3M4-KS-11] ヒューマンインタラクション技術による自立共生支援 AIの研 究開発と社会実装に向けて

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room M (Front-right room of 1F Exhibition hall)

#### [3M4-KS-11] ヒューマンインタラクション技術による自立共生支援 AIの研究開発と社 会実装に向けて

3:50 PM - 5:30 PM

3:50 PM - 5:30 PM (Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room M)

## [3M4-KS-11] ヒューマンインタラクション技術による自立共生支援 AIの研 究開発と社会実装に向けて

全国大会の近未来チャレンジ「認知症の人の情動理解基盤技術とコミュニケーション支援への応用」の活動を基盤に、内閣府の戦略的イノベーション創造プログラム(SIP)に採択された「"認知症の本人と家族の視点を重視する"マルチモーダルなヒューマン・インタラクション技術による自立共生支援 AIの研究開発と社会実装」のプロジェクトを紹介する.オープンイノベーションに基づく社会課題解決のための AI研究について参加者全員で議論したい.

Proposed session

#### [3O3-KS-9] 人工知能国際標準化への誘い Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room O (Front-left room of 1F Exhibition hall)

[3O3-KS-9] 人工知能国際標準化への誘い 1:50 PM - 3:30 PM 1:50 PM - 3:30 PM (Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room O)

#### [303-KS-9] 人工知能国際標準化への誘い

人工知能の標準化が ISO/IEC JTC 1/SC 42で開始されて1年余が経過し、参加者も急増して活発な議論が行われ ている.日本はユースケースとアプリケーションの議論をリードしているが、他にも Trustworthiness, Bias, リ スク管理、ライフサイクルなど多くの標準化が始まった.これら活動をリードする企業や研究機関のリーダから 現状や方向性を紹介頂き、より多くの参加と活発な議論を誘う. Proposed session

## [3O4-KS-12] NEDO次世代人工知能中核技術 ~人を見守り協働する人工知 能の実現に向けて~

Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room O (Front-left room of 1F Exhibition hall)

#### [3O4-KS-12] NEDO次世代人工知能中核技術 ~人を見守り協働する人工知能の実現に 向けて~

3:50 PM - 5:30 PM

3:50 PM - 5:30 PM (Thu. Jun 6, 2019 3:50 PM - 5:30 PM Room O)

# [304-KS-12] NEDO次世代人工知能中核技術 ~人を見守り協働する人工知能の実現に向けて~

2015 年度に開始された NEDO「次世代人工知能・ロボット中核技術開発」プロジェクトは研究開発の終盤に入り,次世代人工知能中核技術の研究開発に留まらず,産学官連携によるそれら技術の社会実装により,現代社会の課題を解決すべく取り組んでいる.本企画セッションでは,人を見守り生活を支援する人工知能,人と共に働くロボット等を例に,それらを実現するための次世代人工知能中核技術の研究開発成果を紹介する.

Industrial session

## [3M3-IND-5] Industrial session 5

吉岡 健(富士ゼロックス株式会社) Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room M (Front-right room of 1F Exhibition hall)

[3M3-IND-5] Industrial session 5 1:50 PM - 3:30 PM 1:50 PM - 3:30 PM (Thu. Jun 6, 2019 1:50 PM - 3:30 PM Room M) [3M3-IND-5] Industrial session 5

コンペティションによる AI開発の可能性(未定,(株)SIGNATE) IBM Researchの最近の研究と実用事例(立花 隆輝,日本 IBM(株)) NECの AI技術による社会価値創造(亀田 義男, NEC) AI関連技術の研究開発のご紹介(植野 研,(株)東芝) 広告メディア研究の最先端(大谷 まゆ,(株)サイバーエージェント)

## [3C-LS] NEC Corporation

Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room C (4F International conference hall)

#### [3C-LS] NEC Luncheon Seminar

今岡 仁<sup>1</sup>、中台 慎二<sup>1</sup>(1. NEC) 12:50 PM - 1:40 PM 12:50 PM - 1:40 PM (Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room C)

#### [3C-LS] NEC Luncheon Seminar

今岡 仁<sup>1</sup>、中台 慎二<sup>1</sup> (1. NEC)

顔認証技術の最前線:NECが誇る NIST連続4回 No.1の顔認証技術は、海外の空港に多数採用されています.また、南紀白浜エリアでは、空港やホテル、商店街で顔認証を活用した手ぶら決済の実証実験も取り組んでいます.空港や街並みの顔認証だけでなく、高精度な認証技術ならではの決済、おもてなし、セーフティ、そして、医療など新しい分野への応用が期待されています.顔認証技術の最新トレンドを交えてご紹介します.
AI間連携の取り組み:AIの「認識」や「予測」「制御」といった機能が実世界に適用され、様々なシステムがスマート化されてきていますが、近い将来には、こうしたシステム間での挙動調整や利害調整のための新機能が必要になります.本講演では、様々な分野の専門家と共同で取り組んでいる国家プロジェクトの活動を中心に、この新機能を担う次世代人工知能の研究開発についてご紹介します.(想定人数150名)

## [3E-LS] HAKUHODO Inc.

Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room E (301A Medium meeting room)

#### [3E-LS] Hakuhodo Luncheon Seminar

猪谷 誠一<sup>1</sup>、藤井 遼<sup>1</sup> (1. 株式会社博報堂) 12:50 PM - 1:40 PM 12:50 PM - 1:40 PM (Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room E)

#### [3E-LS] Hakuhodo Luncheon Seminar

猪谷 誠一<sup>1</sup>、藤井 遼<sup>1</sup> (1. 株式会社博報堂)

博報堂は広告会社です.広告会社の様々な業務において,一見縁遠いと思われる機械学習やデータ分析,人工知能といった技術がどのように活用されているか,また,どのような研究開発が行われているかについて,現役の研究員がお話します.(想定人数60名)

## [3M-LS] Intel Corporation

Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room M (Front-right room of 1F Exhibition hall)

#### [3M-LS] Intel Luncheon Seminar

志村 泰規<sup>1</sup>(1. インテル株式会社) 12:50 PM - 1:40 PM 12:50 PM - 1:40 PM (Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room M)

#### [3M-LS] Intel Luncheon Seminar

志村 泰規<sup>1</sup> (1. インテル株式会社)

イメージセンサーとディープラーニング技術の飛躍的な進歩により、コンピューター・ビジョンを組込み機器に 採用する事例が増加してきている.

従来型の SaaS型ソリューションでは解決の難しい低レイテンシー、高セキュリティーという組込み機器ならでは の要求にこたえるため、インテルでは組込み向けのディープラーニング・ソリューションを展開している.ここ ではインテルの推論アクセラレーターとそれらを活用するソフトウエアソリューションについて紹介を行う. (想定人数150名)

## [30-LS] DENTSU Inc.

Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room O (Front-left room of 1F Exhibition hall)

## [30-LS] Dentsu Luncheon Seminar

12:50 PM - 1:40 PM

12:50 PM - 1:40 PM (Thu. Jun 6, 2019 12:50 PM - 1:40 PM Room O)

#### [3O-LS] Dentsu Luncheon Seminar

AI活用のひろがりは、マスメディア業界にもさまざまな変化を起こし始めています.日本独自の特徴のある業界だからこそ、これからさまざまなイノベーションが生まれる可能性のあるメディア・マスコミ業界. AI活用の今後の展望について、オープンなディスカッションを通して切り口を探ります.(想定人数100名)

Networking Meeting

## [3Y5-PS-5] Paricipants' networking meeting

Thu. Jun 6, 2019 6:00 PM - 7:30 PM Room Y (Bandaijima multi-purpose square)

[3Y5-PS-5] Participants' networking meeting 6:00 PM - 7:30 PM 6:00 PM - 7:30 PM (Thu. Jun 6, 2019 6:00 PM - 7:30 PM Room Y) [3Y5-PS-5] Participants' networking meeting

The meeting will be held at Bandaijima multipurpose indoor square, which is a renovated building of original fish market with the semicylindrical roof. It is located at the south-western side of the parking lot in front of Toki Messe. All people bearing the JSAI2019 participant pass can join this meeting without extra charge. Some food and drinks including Niigata's specialties will be served.