

## Thu. Jun 6, 2019

## 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

○Taisuke 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"?

○Masayuki 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

○Yasuaki 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

○Daichi 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

○Yuuji 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

○Yuji 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 一 (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

○Takayoshi Yamashita<sup>1</sup> (1. Chubu University)

1:50 PM - 2:30 PM

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

○Hidenori 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

○Yoshihiro 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 一 (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

○Hiroharu 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

○Yuji 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

○Riku 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-Communications, 2. Osaka University)  
4:30 PM - 4:50 PM

[3E4-OS-12b-04] Modeling of prejudice eyes by designers

○Ryuichi 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

## Room F

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)  
1:50 PM - 3:30 PM Room F (302B Medium meeting room)

[3F3-OS-14a-01] Analyzing Gestures in Real-World Werewolf Game

○Shutarou 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 a biological signal

○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

○Atsushi 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

○Norifumi 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] Analysis of Strategies in Werewolf Game by 3 Players Considering Voting

Behaviour of Other Players

○Hinako Tamai<sup>1</sup> (1. Nara Women's University)  
3:10 PM - 3:30 PM

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)  
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  
○Eisuke Sato<sup>1</sup>, Hirotaka Osawa<sup>1</sup> (1. University of Tsukuba)  
3:50 PM - 4:10 PM

[3F4-OS-14b-02] Role estimation in Werewolf games

using a selective desensitization neural network  
Masahiro Saito<sup>2</sup>, Seiryu Mishina<sup>1</sup>, ○Ken Yamane<sup>1</sup> (1. Teikyo University, 2. Fujisoft Incorporated)  
4:10 PM - 4:30 PM

[3F4-OS-14b-03] Artificial Intelligence for Deducing Roles of Players in the Werewolf Game using Information about Conversations among Players

○Munemichi Fukuda<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University)  
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>, ○Tomonobu Ozaki<sup>1</sup> (1. Nihon University)  
4:50 PM - 5:10 PM

[3F06-09-5] Discussion / Conclusion

5:10 PM - 5:30 PM

## Room G

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)  
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

○Hideki Ohira<sup>1</sup> (1. Nagoya University)

1:50 PM - 2:30 PM

[3G3-OS-18a-02] Action Selection based on Somatic Marker Hypothesis

○Chie 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

○Takato 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

○Kazuki 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

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

○Kazuya 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

○Takahisa 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

○Kazumi Kumagai<sup>1</sup>, Ikuro 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

○Masahiro 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

○Mai 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

○Taichi 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

○Shuuhei 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>, Akinobu 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 Artificial

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

---

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)

Thu. Jun 6, 2019 1:50 PM - 3:10 PM Room D (301B Medium meeting room)

---

#### [3D3-OS-4a-01] Story Association Mediated by Individual and General Concepts

○Taisuke 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"?

○Masayuki 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

○Yasuaki 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

○Daichi 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

# 個別概念と一般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  
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事は、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]

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

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)を思い出ししたり、新しい経験を一般化・記憶したりする、発達の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示す。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、複数の小さな表象のかつ処理的なエージェントからなる、マルチエージェント

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された際に、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  $a_y$  の計算式の基本形を、

$$a_y = \sum_i^n O_{x_i} w_i \quad (1)$$

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。

$$O_{x_i} = \begin{cases} 0, & a_{x_i} < \theta_{out} \\ a_{x_i}, & a_{x_i} \geq \theta_{out} \end{cases} \quad (2)$$

表1 一般的な心的要素の種類。

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。
時間概念	ストーリー(事象)が起きる時間に対応する、言語的に分節された時間範囲(例えば「平成」「明日」)。
場所概念	ストーリー(事象)が起きる場所に対応する、言語的に分節された空間範囲(例えば「新宿」「自宅」)。
感覚運動的パターン	事物の具体的な心像(イメージ)を形作り、非言語的な感覚運動情報(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。
スキーマ	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。

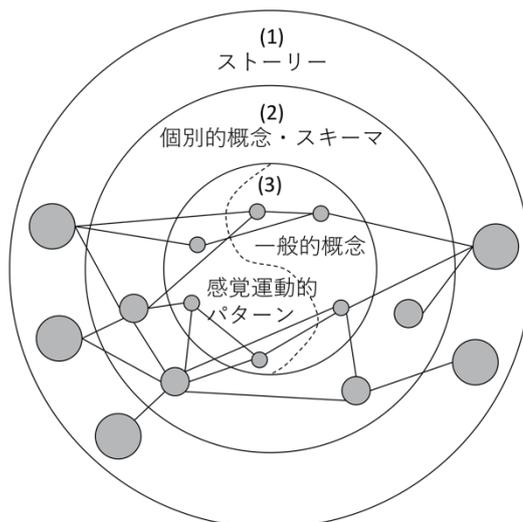


図1 心的要素の組織構造(心的世界の構造)。

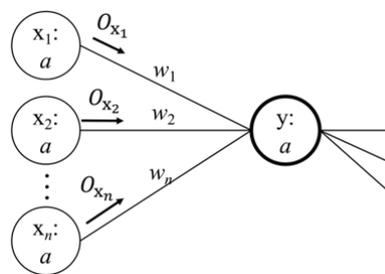


図2 活性伝播の局所的な模式図。

#### 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られる—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、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だけでなく、既存の構造の再構成等によっても生じるものと考えられる。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、個々の記憶(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  $0 < w \leq 1$  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 ( $0 < w \leq 1$ ) 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 ( $0 \leq w \leq 1$ . 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  $d_3$  の間の結合強度が 0.3 であることを意味する。

```
#1
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
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 入力ストーリーデータの記述例。

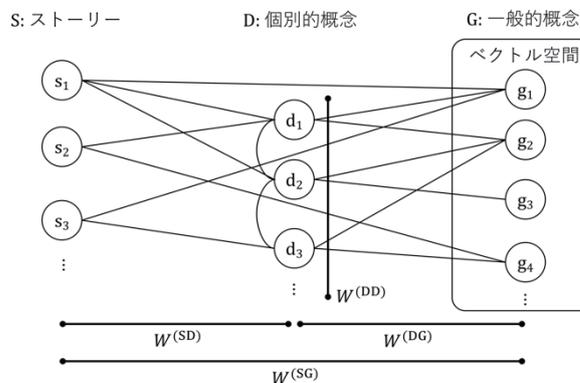


図4 心的要素のネットワーク構造。

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  $O_{s_i}$  と  $W^{(SD)}$  から、各個別的概念の活性度  $a_{d_j}$  を計算する。

$$a_{d_j} = \sum_i O_{s_i} w_{ij}^{(SD)} \quad (3)$$

**Step 2 (SD 層→G 層):** 下式により、各ストーリーの出力活性度  $O_{s_i}$  と  $W^{(SG)}$ , 及び各個別的概念の出力活性度  $O_{d_j}$  と  $W^{(DG)}$  から、各一般的概念の活性度  $a_{g_k}$  を計算する。

$$a_{g_k} = \sum_i O_{s_i} w_{ik}^{(SG)} + \sum_j O_{d_j} w_{jk}^{(DG)} \quad (4)$$

**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 ( $\text{sim}(g_i, g_j)$ ) から、各一般的概念の活性度を計算する。

$$a_{g_i} = \sum_j O_{g_j} \text{sim}(g_i, g_j) \quad (5)$$

ここで、コサイン類似度が閾値  $\theta_{sim}$  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  $O_{d_i}$  と  $W^{(DD)}$ , 及び各一般的概念の出力活性度  $O_{g_j}$  と  $W^{(DG)}$  から、各個別的概念の活性度を計算する。

$$a_{d_k} = \sum_i^{|DI|} O_{d_i} w_{ik}^{(DD)} + \sum_j^{|GI|} O_{g_j} w_{kj}^{(DG)} \quad (6)$$

**Step 5 (GD 層→S 層):** 下式により, 各一般的概念の出力活性度  $O_{g_i}$  と  $W^{(SG)}$ , 及び各個別的概念の出力活性度  $O_{d_j}$  と  $W^{(SD)}$  から, 各ストーリーの活性度を計算する.

$$a_{s_k} = \sum_i^{|GI|} O_{g_i} w_{ki}^{(SG)} + \sum_j^{|DI|} O_{d_j} w_{kj}^{(SD)} \quad (7)$$

**Step 6: 焦点移動.** ストーリー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.

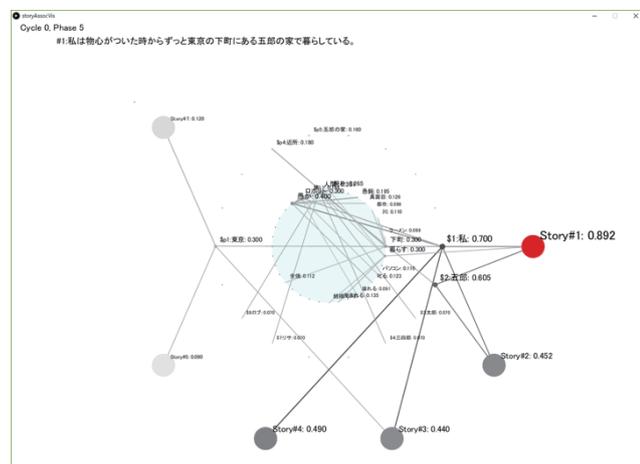


図 5 1 巡目 Step 5 終了時の活性状態.

## 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面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ではない。

## 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]。したがってこれは「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

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』というのはどうしてか』という問を設定する。

## 5. 『「知能」を『知能』というのはどうしてか』

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。

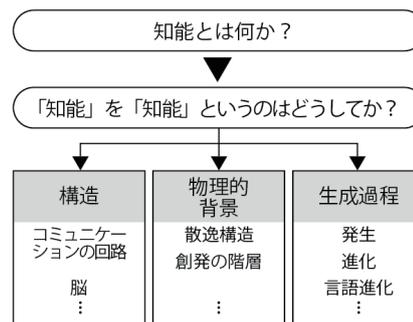


図 1 : 副問題に分解

### 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[Saussure 1910]。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たので、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]。

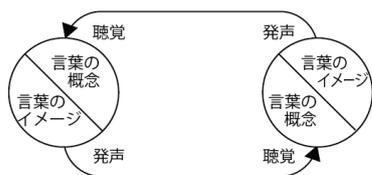


図2: コミュニケーションの回路([Constantin 1910]を元に改変)

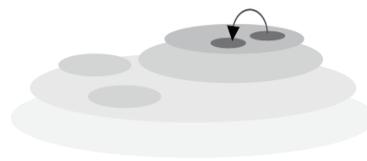


図3: 創発の階層上にある『知能』のことを『知能』という状態 (イメージ)

## 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ペロウソフ・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に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。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]。

## 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<sup>ème</sup> 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 峽, 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 \*1      尾崎 僚 \*1      谷口 忠大 \*1  
Okuda Yasuaki      Ozaki Ryo      Taniguchi Tadahiro

\*1 立命館大学  
Ritsumeikan University

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の実験を行う。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、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]。冨田らは子音を含んだ実

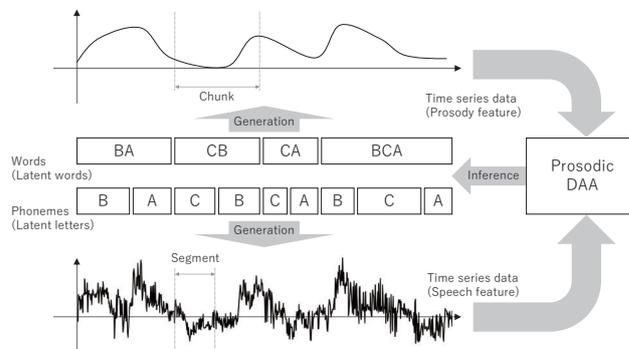


図 1: 本研究の概要図。二重分節解析器にプロソディを活用した単語分割を組み込む。ここで、Chunk は単語の継続長、Segment は音素の継続長をそれぞれ表す。

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ーを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。

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

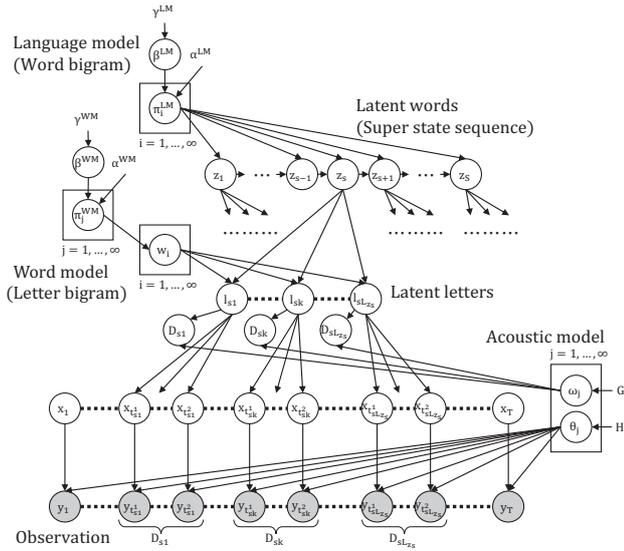


図 2: HDP-HLM のグラフィカルモデル [Taniguchi 16a]. このモデルは、二重分節構造を持つ時系列データの生成モデルである。

### 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できる。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。

$$\begin{aligned} B_t(i) &:= p(y_{t+1:T} | z_{s(t)} = i, F_t = 1) \\ &= \sum_j B_t^*(j) p(z_{s(t+1)} = j | z_t = i) \end{aligned} \quad (1)$$

$$\begin{aligned} B_t^*(i) &:= p(y_{t+1:T} | z_{s(t+1)} = i, F_t = 1) \\ &= \sum_{d=1}^{T-t} B_{t+d}(i) p(D_{t+1} = d | z_{s(t+1)} = i) \\ &\quad \cdot p(y_{t+1:t+d} | z_{s(t+1)} = i, D_{t+1} = d) \end{aligned} \quad (2)$$

$$B_T(i) := 1 \quad (3)$$

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。

$$\begin{aligned} p(y_{t+1:t+d} | i, d) &= \sum_{\mathbf{r} \in R^{(L_i, d)}} \prod_{k=1}^{L_i} p(r_k | l_k) \\ &\quad \cdot \prod_{m=1}^{r_k} p(y_{t+m} | \sum_{k'=1}^{k-1} r_{k'} | l_k) \end{aligned} \quad (4)$$

$$R^{(L_i, d)} = \left\{ \mathbf{r} \in \{1, 2, \dots\}^{L_i} \mid \sum_{k=1}^{L_i} r_k = d \right\} \quad (5)$$

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。

$$\alpha_t(k) = \sum_{d'=1}^{t-k+1} \alpha_{t-d'}(k-1) p(d' | l_k) \prod_{t'=1}^{d'} p(y_{t-t'+1} | l_k) \quad (6)$$

$$\alpha_0(0) = 1 \quad (7)$$

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。

$$\begin{aligned} p(z_s = i | y_{1:T}, z_{s-1} = j, F_{D_{1:s}^{\text{sum}}} = 1) = \\ p(i | j) \beta_{D_{1:s}^{\text{sum}}}(i) p(y_{D_{1:s}^{\text{sum}}} | i) \end{aligned} \quad (8)$$

$$\begin{aligned} p(D_s = d | y_{1:T}, z_s = i, F_{D_{1:s}^{\text{sum}}} = 1) = \\ p(y_{D_{1:s}^{\text{sum}}+1:D_{1:s}^{\text{sum}}+d} | d, i, F_{D_{1:s}^{\text{sum}}} = 1) p(d) \frac{\beta_{D_{1:s}^{\text{sum}}+d}(i)}{\beta_{D_{1:s}^{\text{sum}}}^*(i)} \end{aligned} \quad (9)$$

### 4. Prosodic DAA

本稿では、プロソディとして基本周波数  $F_0$  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  $y_t$  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変数  $F_t$  から生成されるものと仮定している。また、 $F_0$  の二次微分を表す観測を  $y_t^{F_0}$  とし、無音区間長を表す観測を  $y_t^{\text{sil}}$  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、 $\beta^{\text{WM}}$  は単語モデルにおける Dirichlet Process の基底測度を表し、 $\alpha^{\text{WM}}$  と  $\gamma^{\text{WM}}$  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  $\pi_i^{\text{WM}}$  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  $\beta^{\text{LM}}$  は言語モデルにおける Dirichlet Process の基底測度を表し、 $\alpha^{\text{LM}}$  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

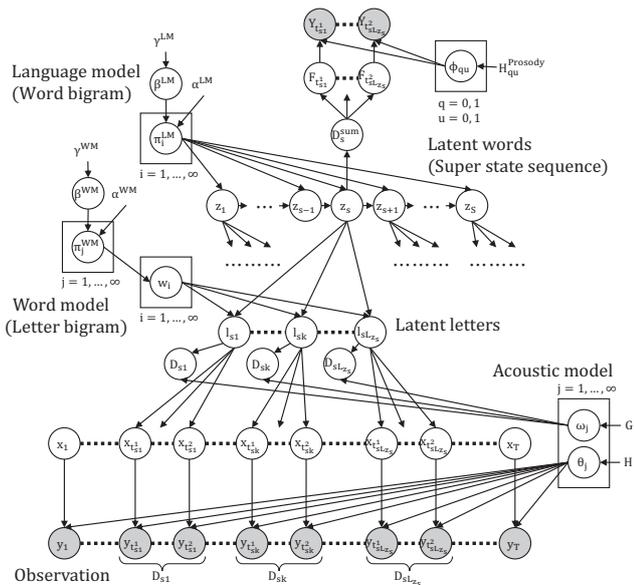


図 3: プロソディを含む HDP-HLM のグラフィカルモデル. 潜在単語  $z_s$  から  $z_s$  の継続長  $D_s^{\text{sum}}$  が生成される.  $D_s^{\text{sum}}$  から単語境界を表す  $F_t$  が生成され,  $F_t$  から  $Y_t$  が生成される.

次の状態への遷移確率を表している. また,  $Y_{1:T}$  は  $y_{1:T}^{\text{F}_0}$ ,  $y_{1:T}^{\text{sil}}$  の集合を表し,  $p(Y_t)$  ( $t = 1:T$ ) は  $p(y_t^{\text{F}_0}, y_t^{\text{sil}})$  である.

$$\beta^{\text{LM}} \sim \text{GEM}(\gamma^{\text{LM}}) \quad (10)$$

$$\pi_i^{\text{LM}} \sim \text{DP}(\alpha^{\text{LM}}, \beta^{\text{LM}}) \quad (i = 1, \dots) \quad (11)$$

$$\beta^{\text{WM}} \sim \text{GEM}(\gamma^{\text{WM}}) \quad (12)$$

$$\pi_i^{\text{WM}} \sim \text{DP}(\alpha^{\text{WM}}, \beta^{\text{WM}}) \quad (i = 1, \dots) \quad (13)$$

$$w_{ik} \sim \pi_{w_{ik-1}}^{\text{WM}} \quad (i = 1, \dots) \quad (k = 1, \dots, L_i) \quad (14)$$

$$(\theta_j, \omega_j) \sim H \times G \quad (j = 1, \dots) \quad (15)$$

$$\phi_{qu} \sim H_{qu}^{\text{Prosody}} \quad (q = 0, 1) \quad (u = 0, 1) \quad (16)$$

$$z_s \sim \pi_{z_{s-1}}^{\text{LM}} \quad (s = 1, \dots, S) \quad (17)$$

$$l_{sk} = w_{w_{z_s k}} \quad (s = 1, \dots, S) \quad (k = 1, \dots, L_{z_s}) \quad (18)$$

$$D_{sk} \sim g(\omega_{l_{sk}}) \quad (s = 1, \dots, S) \quad (k = 1, \dots, L_{z_s}) \quad (19)$$

$$x_t = l_{sk} \quad (t = t_{sk}^1, \dots, t_{sk}^2) \quad (20)$$

$$t_{sk}^1 = \sum_{s' < s} D_{s'} + \sum_{k' < k} D_{sk'} + 1 \quad (21)$$

$$t_{sk}^2 = t_{sk}^1 + D_{sk} - 1 \quad (21)$$

$$D_s^{\text{sum}} = \sum_{t=1}^{sL_{z_s}} D_t \quad (22)$$

$$y_t \sim h(\theta_{x_t}) \quad (t = 1, \dots, T) \quad (23)$$

$$F_t = \begin{cases} 0 & (t = t_{s1}^1 : t' - 1) \\ 1 & (t = t') \end{cases} \quad (t' = t_{sL_{z_s}}^2) \quad (24)$$

$$y_t^{\text{F}_0} \sim h^{\text{F}_0}(\phi_{F_t 0}) \quad (25)$$

$$y_t^{\text{sil}} \sim h^{\text{sil}}(\phi_{F_t 1}) \quad (26)$$

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.

$$\begin{aligned} \beta_t(i) &:= p(y_{t+1:T}, Y_{t+1:T} | z_s(t) = i, F_t = 1) \\ &= \sum_j \beta_t^*(j) p(z_s(t+1) = j | z_t = i) \end{aligned} \quad (27)$$

$$\begin{aligned} \beta_t^*(i) &:= p(y_{t+1:T}, Y_{t+1:T} | z_s(t+1) = i, F_t = 1) \\ &= \sum_{d=1}^{T-t} \beta_{t+d}(i) p(D_{t+1} = d | z_s(t+1) = i) \\ &\quad \cdot p(y_{t+1:t+d}, Y_{t+1:t+d} | i, d) \end{aligned} \quad (28)$$

$$\beta_T(i) := 1 \quad (29)$$

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,  $p(y_{t+1:t+d}, Y_{t+1:t+d} | z_s(t+1) = i, D_{t+1} = d)$  は以下の式のように計算できる.

$$\begin{aligned} p(y_{t+1:t+d}, Y_{t+1:t+d} | i, d) &= \sum_{r \in R^{(L_i, d)}} \prod_{k=1}^{L_i} p(r_k | l_k) \\ &\quad \cdot \prod_{m=1}^{r_k} p(y_{t+m+\sum_{k'=1}^{k-1} r_{k'}} | l_k) p(Y_{t+m+\sum_{k'=1}^{k-1} r_{k'}} | l_k) \end{aligned} \quad (30)$$

$$R^{(L_i, d)} = \{r \in \{1, 2, \dots\}^{L_i} | \sum_{k=1}^{L_i} r_k = d\} \quad (31)$$

forward message は, 以下の式で再帰的に求めることができる.

$$\begin{aligned} \alpha_t(k) &= \sum_{d'=1}^{t-k+1} \alpha_{t-d'}(k-1) p(d' | l_k) \\ &\quad \cdot \prod_{t'=1}^{d'} p(y_{t-t'+1}, Y_{t-t'+1} | l_k) \end{aligned} \quad (32)$$

$$\alpha_0(0) = 1 \quad (33)$$

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.

$$\begin{aligned} p(z_s = i | y_{1:T}, Y_{1:T}, z_{s-1} = j, F_{D_{1:s}^{\text{sum}}} = 1) = \\ p(i | j) \beta_{D_{1:s}^{\text{sum}}}(i) p(y_{D_{1:s}^{\text{sum}}}, Y_{D_{1:s}^{\text{sum}}} | i) \end{aligned} \quad (34)$$

$$\begin{aligned} p(D_s = d | y_{1:T}, Y_{1:T}, z_s = i, F_{D_{1:s}^{\text{sum}}} = 1) = \\ p(y_{D_{1:s}^{\text{sum}}+1:D_{1:s}^{\text{sum}}+d}, Y_{D_{1:s}^{\text{sum}}+1:D_{1:s}^{\text{sum}}+d} | d, i, F_{D_{1:s}^{\text{sum}}} = 1) \\ \cdot p(d) \frac{\beta_{D_{1:s}^{\text{sum}}+d}(i)}{\beta_{D_{1:s}^{\text{sum}}}(i)} \end{aligned} \quad (35)$$

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

### 5.1 実験目的

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<sub>0</sub>の推定には動的計画法を用いてF<sub>0</sub>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

実験条件として、HDP-HLMの隠れ言語モデルのハイパーパラメータは、 $\alpha^{LM} = 10.0$ と $\gamma^{LM} = 10.0$ とし、weak-limit近似における単語上限数を35個とした。同様に、隠れ単語モデルでは、 $\alpha^{WM} = 10.0$ と $\gamma^{WM} = 10.0$ とし、weak-limit近似における音素上限数を30個とした。持続時間分布には、 $\alpha_0 = 200$ ,  $\beta_0 = 10$ のポアソン分布を仮定し、MFCCの出力分布には事前分布に $\mu_0 = 0$ ,  $\Sigma_0$ に単位行列、 $\kappa_0 = 0, 01$ ,  $\nu_0 = (\text{dimension} + 2)$ の正規逆ウィシャート分布を持つ多変量ガウス分布と仮定した。さらに、提案手法では、プロソディの出力分布には事前分布に、 $F_t = 0$ のとき $\mu_0 = 0$ ,  $\Sigma_0$ に単位行列、 $\kappa_0 = 100$ ,  $\nu_0 = (\text{dimension} + 2)$ ,  $F_t = 1$ のとき $\mu_0 = 1$ ,  $\Sigma_0$ に単位行列、 $\kappa_0 = 2$ ,  $\nu_0 = (\text{dimension} + 2)$ の正規逆ウィシャート分布を持つ多変量ガウス分布と仮定した。上記条件において、100イテレーションを1試行とし、これを20試行行う。

## 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	<b>0.370±0.022</b>	<b>0.671±0.054</b>
NPB-DAA	0.261±0.014	0.497±0.072

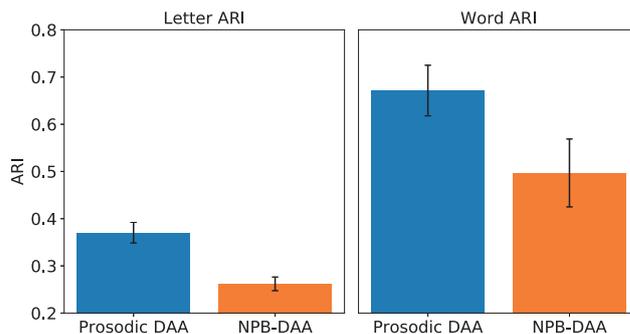


図 4: 音素及び単語分割の精度比較。

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, Elissa L.: 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

\*1 REAPER: Robust Epoch And Pitch EstimatorR : <https://github.com/google/REAPER>

# 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 \*<sup>1</sup>      平賀 元彰 \*<sup>1</sup>      大倉 和博 \*<sup>1</sup>      松村 嘉之 \*<sup>2</sup>  
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 gradient-free 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.

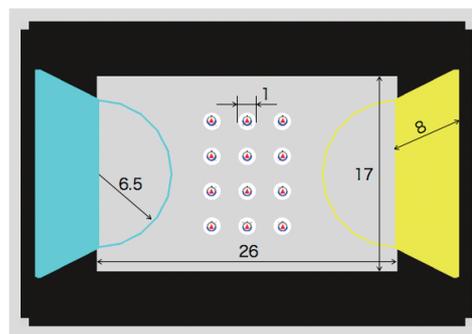


図 1: 実験環境

DNEの先行研究として [Salimans 17, Such 17] がある. Salimans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.

連絡先: 森本大智, 広島大学, morimoto@ohk.hiroshima-u.ac.jp

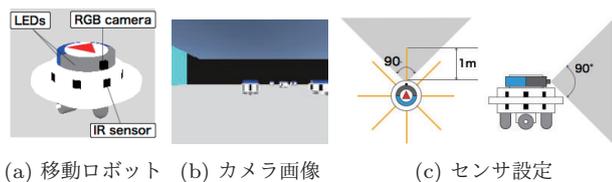


図 2: ロボットの設定

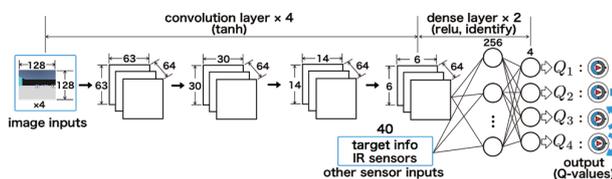


図 3: ロボットの制御器

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。制御器への入力にはカメラ画像、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、チャン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。

$$\begin{aligned} r_{d,i,t} &= 5 \times (d_{i,t-1} - d_{i,t}) \\ r_{e,i,t} &= 5 \\ r_{c,i,t} &= -5 \end{aligned} \quad (1)$$

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。 $r_{d,i,t}$  と  $r_{e,i,t}$  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。

$$R_t = \sum_i (r_{d,i,t} + r_{e,i,t} + r_{c,i,t}) \quad (2)$$

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。

$$R_t = \sum_i r_{e,i,t} \quad (3)$$

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  $\sum_t R_t$  を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の一つ、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。

$$\theta \leftarrow \theta + \epsilon \sigma \quad (4)$$

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ルパラメータである。 $\epsilon$  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。

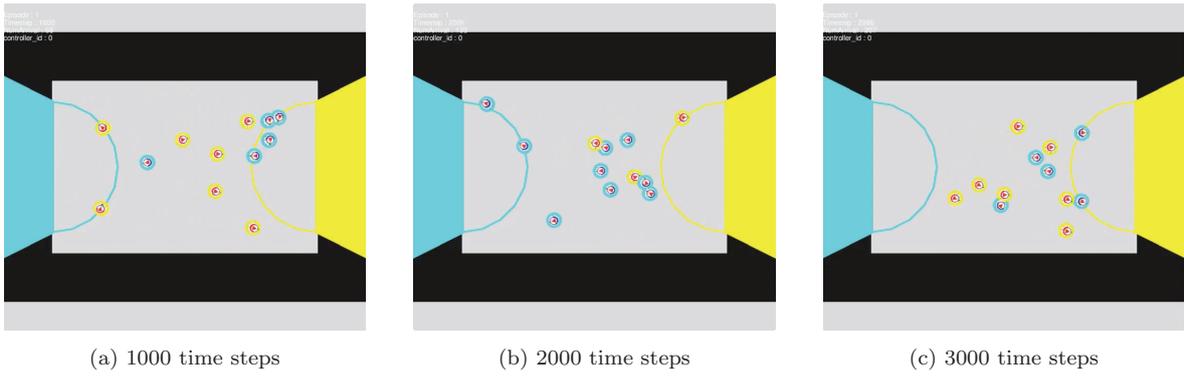


図 6: 報酬設定 (i) の条件下で DRL が生成した群れ行動

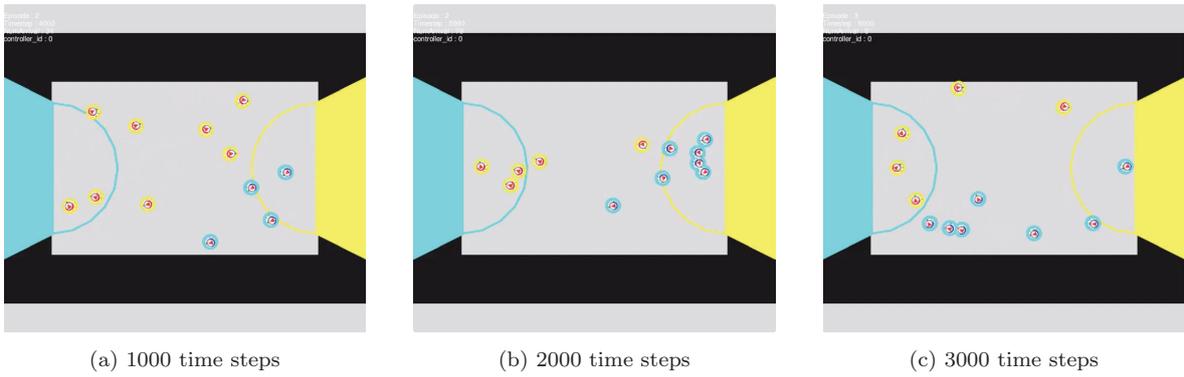


図 7: 報酬設定 (i) の条件下で DNE が生成した群れ行動

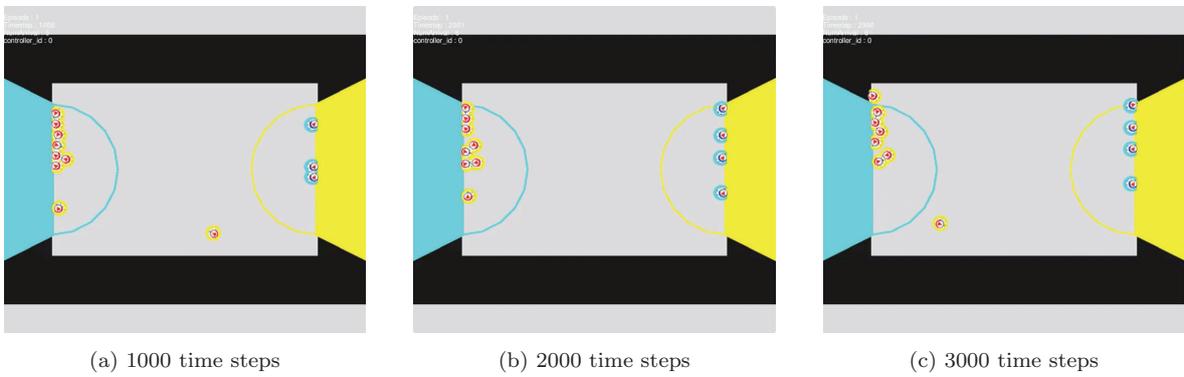


図 8: 報酬設定 (ii) の条件下で DRL が生成した群れ行動

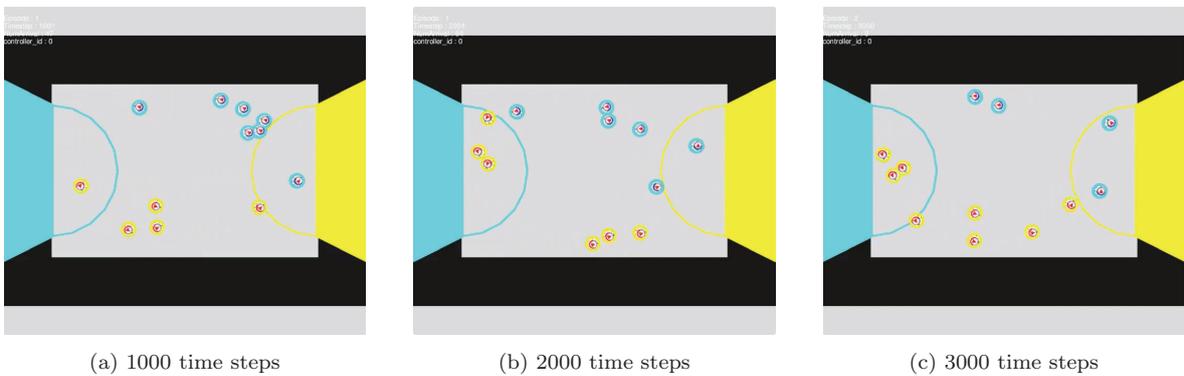


図 9: 報酬設定 (ii) の条件下で DNE が生成した群れ行動

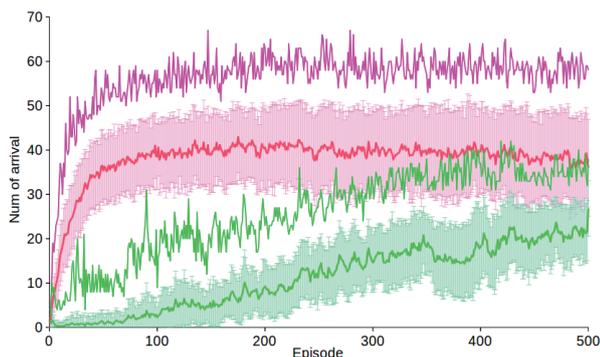


図 4: 報酬設定 (i) における到達回数の推移

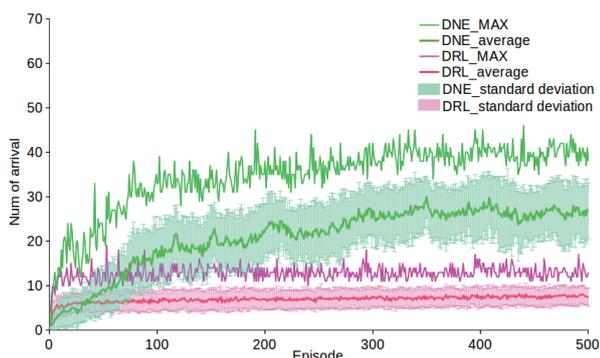


図 5: 報酬設定 (ii) における到達回数の推移

#### 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ダムマークに衝突し、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  $r_{e,i,d}$  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, Szimon 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

○Yuuji 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

○Yuji 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

一杉裕志\*<sup>1</sup> 高橋直人\*<sup>1</sup> 中田秀基\*<sup>1</sup> 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

\*<sup>2</sup>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.

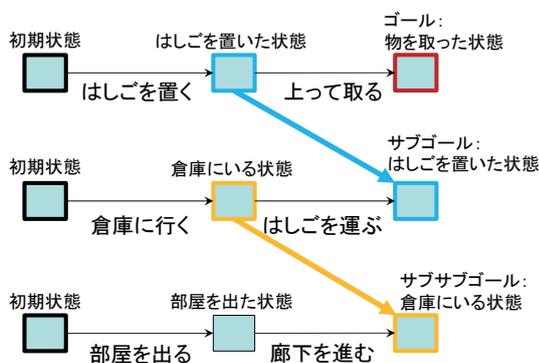


図 1: 人間が目標を達成するために、サブゴール（副目標）を再帰的に設定する例。高いところにあるものを取る（ゴール）ために、まずはしごを取る必要がある（サブゴール）。さらにはしごを手に入れるために倉庫に行く必要がある（サブサブゴール）。

## 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、サブルーチン

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を試行錯誤を限定することで、学習を速くする。
3. 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 MagicHaskell [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、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。

$$Q_G^\pi((s, g), a) = Q^\pi(s, g, a) + V_G^\pi(g) \quad (1)$$

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、 $V_G^\pi(g)$  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、

$$V_G^\pi(g) = \sum_a \pi((g, G), a) Q^\pi(g, G, a) \quad (2)$$

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。

$$a' = \operatorname{argmax}_a Q(s, g, a) \quad (3)$$

### 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。

$$\begin{aligned} & Q_G((s', g'), a') - Q_G((s, g), a) \\ &= (Q(s', g', a') + V_{g'}(g') + V_G(g)) - (Q(s, g, a) + V_G(g)) \\ &= Q(s', g', a') - Q(s, g, a) + V_{g'}(g') \end{aligned} \quad (4)$$

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  $Q$  の更新式は以下ようになる。

$$\begin{aligned} Q(s, g, a) &\leftarrow Q(s, g, a) \\ &+ \alpha(r + Q(s', g', a') - Q(s, g, a) + V_{g'}(g')) \end{aligned} \quad (5)$$

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さ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 RGoal 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: procedure EPISODE( $S, G, \text{think-flag}$ )
2:    $s \leftarrow S; g \leftarrow G$ 
3:    $\text{stack} \leftarrow \text{empty}$ 
4:   Choose  $a$  from  $s, g$  using policy derived from  $Q$ 
5:   while  $s \neq G$  do
6:     # Take action.
7:     if  $a = \text{RET}$  then
8:        $s' \leftarrow s; g' \leftarrow \text{stack.pop}(); r \leftarrow 0$ 
9:     else if  $a$  is  $C_m$  then
10:       $\text{stack.push}(g)$ 
11:       $s' \leftarrow s; g' \leftarrow m; r \leftarrow R^C$ 
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:      if  $s' = g'$  then
20:         $a' \leftarrow \text{RET}$ 
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:         $Q(s, g, a) \leftarrow Q(s, g, a)$ 
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。

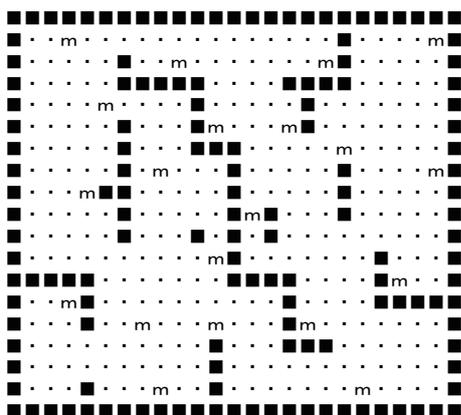


図3: 評価に用いた2次元格子上の迷路のマップ。20個のランドマーク (m で示した) がマップ上に配置されている。このランドマークの中からエピソードごとにランダムにスタート  $S$  とゴール  $G$  が選択される。

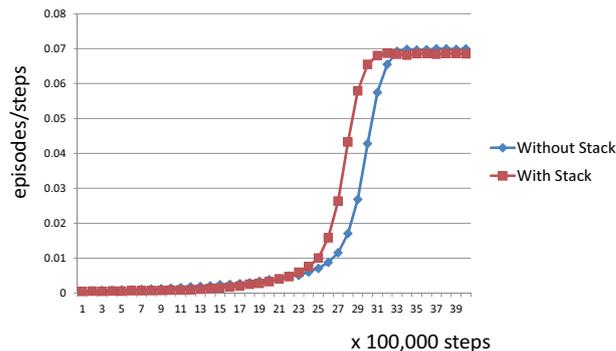


図4: 実験1: スタックのない RGoal [一杉 18a] と、スタックを導入した本稿のアルゴリズムとの比較。実験条件にもよるが、同程度の早さで収束している。

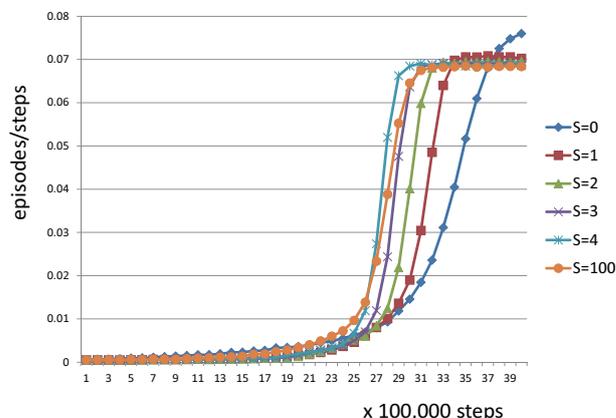


図5: 実験2: スタックの深さの上限  $S$  と性能の関係。 $S=0$  は普通の強化学習、 $S=1$  は2層の階層型強化学習に相当する。上限が大きいほど収束は早くなる傾向を示している。

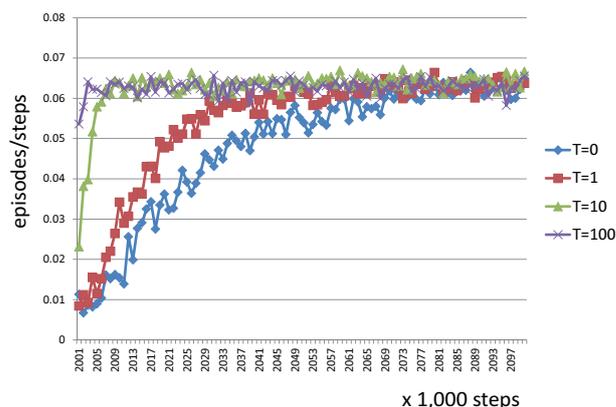


図6: 実験3: 各ステップの実行直前に実行する思考フェーズの長さ  $T$  と性能の関係。思考フェーズの長さ  $T$  は、各エピソードの直前に思考モードで「脳内シミュレーション」するエピソードの回数。思考フェーズが十分長ければ、未経験のタスクであっても、近似解がゼロショットで得られている。

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、値が大きいくほど、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  $C_m$ 、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、 $S$  が大きいく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いる。) 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  $\beta$  を小さくし探索傾向を強くして十分学習させた後、 $\beta$  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  $20 \times 19 = 380$  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ます。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 option-critic 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\*<sup>1</sup> 小笹 悠歩\*<sup>2</sup> 朴 志勲\*<sup>1</sup> 浅田 稔\*<sup>1</sup>  
Yuji Kawai Yuho Ozasa Jihoon Park Minoru Asada

\*<sup>1</sup>大阪大学先導的学際研究機構

\*<sup>2</sup>大阪大学工学部

Institute for Open and Transdisciplinary Research Initiatives, Osaka University

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 multi-task 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ーバーネットワークに入力が与えられ、リザー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、リザー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、リザー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、最適化されたリザー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、 $N$  個のリザーバーノードが入力  $u(t)$  をベクトル  $\mathbf{W}_{in}$  で重み付けられて受け取る。そして、リザーバーノードの状態  $\mathbf{x}(t) = (x_1(t), \dots, x_N(t))^T$  は次式により更新される。

$$\mathbf{x}(t+1) = f(\mathbf{W}_{in}u(t+1) + \mathbf{W}\mathbf{x}(t) + \mathbf{W}_{fb}y(t)) \quad (1)$$

ここで、 $\mathbf{W}$  は  $N \times N$  のサイズのリザーバー重み行列、 $\mathbf{W}_{in}$  は入力重みベクトル、 $\mathbf{W}_{fb}$  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、ハイボリックタンジェントを用いた。 $\mathbf{W}$  は行列  $\mathbf{W}_0$  を次式で正規化することで得られる。

$$\mathbf{W} = \alpha \frac{\mathbf{W}_0}{\rho(\mathbf{W}_0)} \quad (2)$$

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

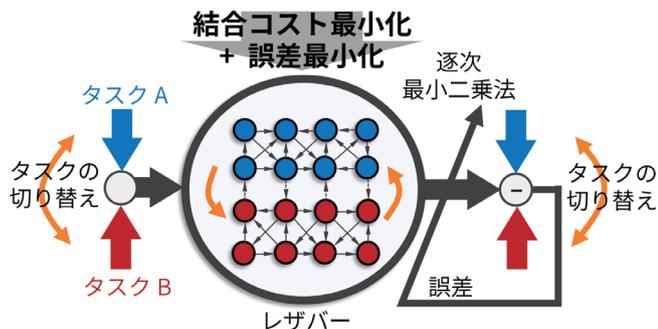


図 1: 提案モデルの概要図。一定時間経つとタスクが別のタスクに切り替わる状況におけるエコー状態ネットワークの継続学習の問題を扱う。結合コスト最小化と誤差最小化を目的関数とする遺伝的最適化により、リザーバーネットワークにモジュール性が現れ、タスクの切り替えに応じてそのモジュールの活動も切り替わることで、複数のタスクの学習が可能になる。

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、リザー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。

$$y(t) = \mathbf{W}_{\text{out}}(t)\mathbf{x}(t) \quad (3)$$

ここで、 $\mathbf{W}_{\text{out}}(t)$  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。

$$\mathbf{W}_{\text{out}}(t+1) = \mathbf{W}_{\text{out}}(t) + \Delta\mathbf{W}(t) \quad (4)$$

$$\Delta\mathbf{W}(t) = \mathbf{R}(t)\mathbf{x}(t)e(t) \quad (5)$$

ここで、誤差  $e(t)$  は ESN の出力  $y(t)$  と教師信号  $y_d(t)$  の差

$$e(t) = y(t) - y_d(t) \quad (6)$$

である。 $\mathbf{R}(t)$  は次式で与えられる。

$$\mathbf{R}(t) = \frac{1}{\mu} \left[ \mathbf{R}(t-1) - \frac{\mathbf{R}(t-1)\mathbf{x}(t)\mathbf{x}^\top(t)\mathbf{R}(t-1)}{\mu + \mathbf{x}(t)\mathbf{R}(t-1)\mathbf{x}^\top(t)} \right] \quad (7)$$

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ーバー重みの最適化

一般の ESN では、 $\mathbf{W}_0$  をランダムに決定するが、本モデルでは、 $\mathbf{W}_0$  の個々の要素を遺伝子とする遺伝的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、リザー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。

1. 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  $\mathbf{W}_{\text{out}}$  を更新する。
3. 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、 $\mathbf{W}_0$  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、リザーバーノード数  $N$  を 36 に設定し、 $6 \times 6$  の平面格子状に配置した。 $\mathbf{W}_{\text{in}}$ ,  $\mathbf{W}_{\text{fb}}$ ,  $\mathbf{W}_{\text{out}}$  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 ( $u(t) = \sin(\frac{\pi t}{10})$ )、1 時刻後の入力を教師信号とする ( $y_d(t) = u(t+1)$ )。
- 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。

リザー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ー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。

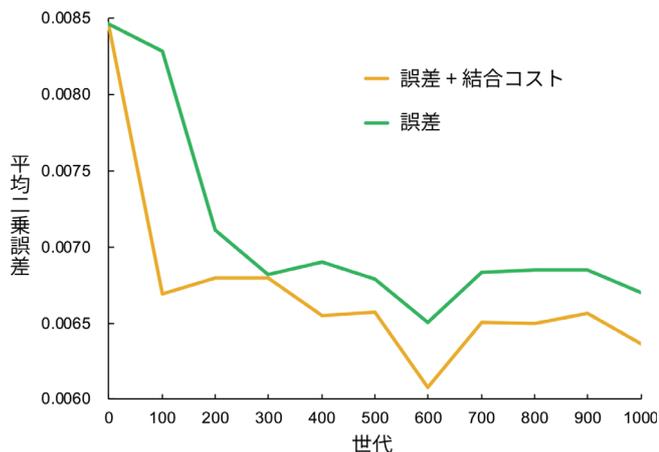


図 2: 各世代内で最小の平均二乗誤差.

### 3.2 実験結果

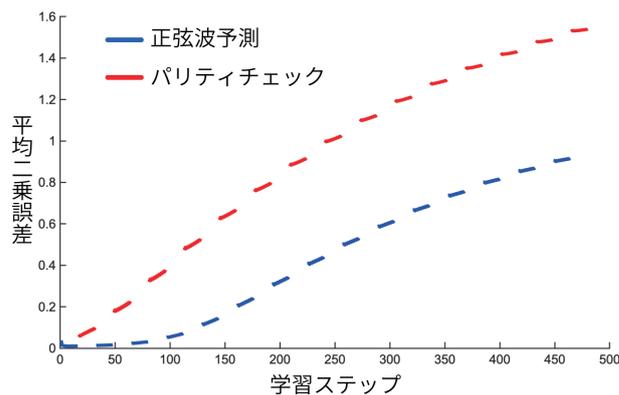
図 2 に、100 世代ごとの各世代における最小の平均二乗誤差を示す。黄色と緑の線がそれぞれ、誤差と結合コストの最小化、誤差のみの最小化の条件での結果である。この図から、結合コストを目的関数に含めることで、学習性能が向上していることがわかる。図 3 に結合コストを目的関数に入れた場合での (a) 初期世代と (b) 最終世代の学習曲線の例を示す。初期のランダムネットワークでは、タスクが切り替わるごとに再学習を繰り返していることがわかる。一方で、最終世代では、タスクが切り替わっても誤差が増大せず、破滅的忘却を回避している。

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。

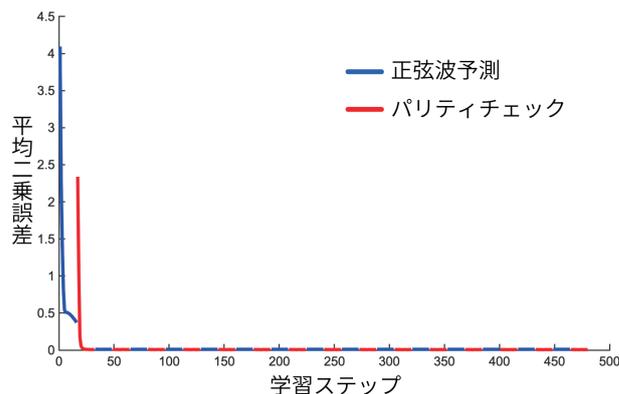
上記のモジュラリティの解析から、最終世代の正負の結合ネットワークのそれぞれにおいて、3つのモジュールがあることがわかった。それらをモジュール A, B, C とよび、タスクごとのモジュール間とモジュール内の平均移動エントロピーを図 5 に示す（ただし、負の結合ネットワークのモジュールと正の結合ネットワークのモジュールは対応しない）。正弦波予測のときには、移動エントロピーの値が全体的に小さい。しかし、負のモジュール C から A への移動エントロピーが大きく、正のモジュール B への移動エントロピーが比較的大きいことがわかる。一方で、パリティチェックのときには、負のモジュール C 内の移動エントロピーが大きく、また、正のモジュール 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 のリザーバーに結合コスト最適化を導入することで、リザーバーネットワークにモジュールが現れ、継続学



(a) 初期世代.



(b) 最終世代.

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。

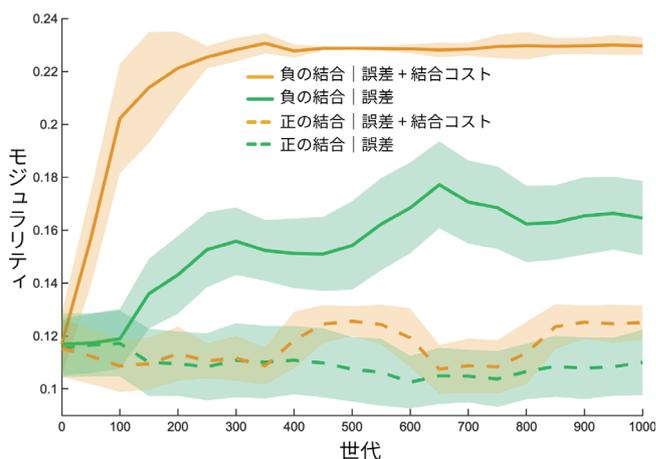


図 4: リザーバーネットワークのモジュラリティ。結合の正負で分けてモジュラリティを求めた。実線と破線はそれぞれ、負と正の結合が作るネットワークのモジュラリティである。塗りつぶし範囲は、その世代における個体間の標準偏差を表す。

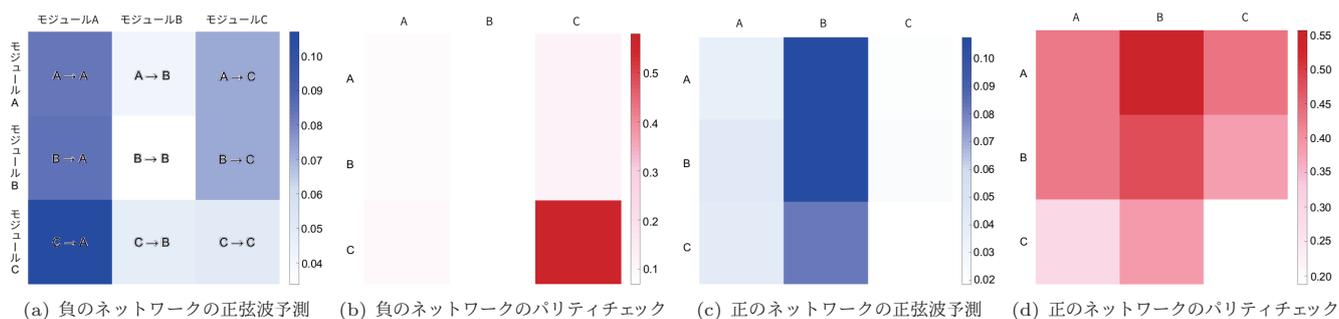


図 5: モジュール間とモジュール内の平均移動エントロピー. それぞれ 3 つのモジュールがあり, 行のモジュールから列のモジュールへの平均移動エントロピーの大きさを色の濃さで表している. 青: 正弦波予測タスク, 赤: パリティチェックタスク.

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ー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, 不要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 Neuroinform.*, 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

○Takayoshi Yamashita<sup>1</sup> (1. Chubu University)

1:50 PM - 2:30 PM

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

○Hidenori 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

○Yoshihiro 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\*<sup>1</sup>

Takayoshi Yamashita

\*<sup>1</sup>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みされており、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) や 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 Normalization [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

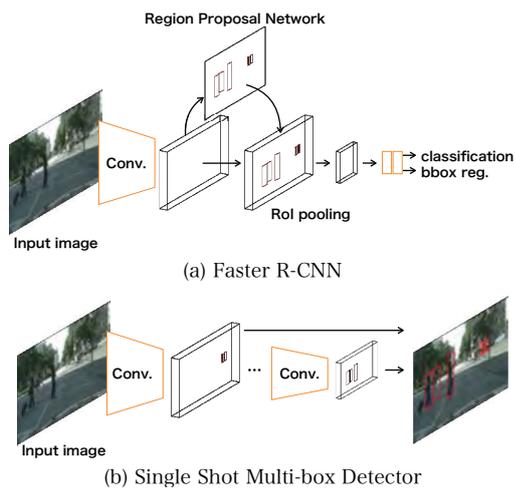


図 1: 物体検出の代表的なモデル

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 1(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へも応用されている。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

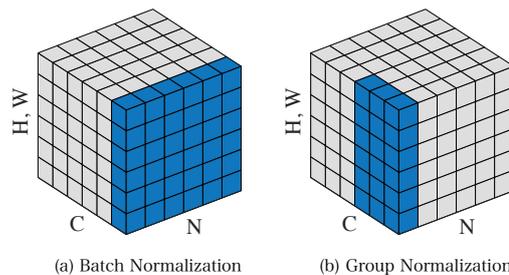


図 2: Batch Normalization の発展系の手法 (文献 [Yuxin 18] から引用)

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を用いて正規化する。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

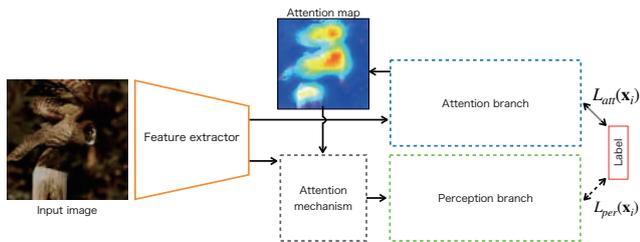


図 3: Attention Branch Network の構造

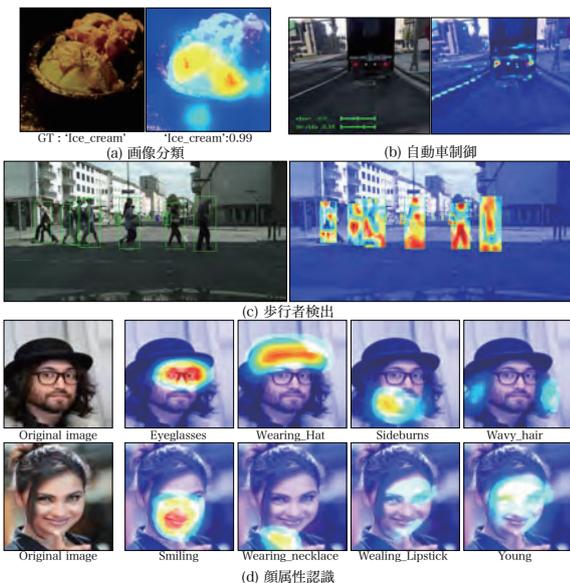


図 4: ABN が獲得した Attention map の例

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 Top-down 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值の勾配のみを用いることで、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、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

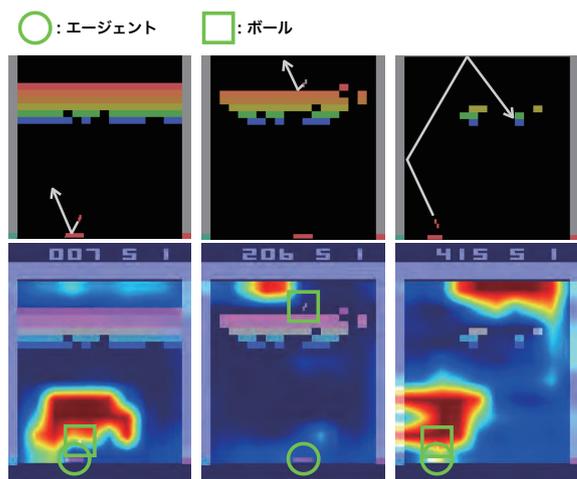


図 5: Breakout における Attention map の例

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., Fernando, 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 Vision 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 Processing 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 Conference* (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 \*<sup>1</sup>

Hidenori Itaya

平川 翼 \*<sup>1</sup>

Tsubasa Hirakawa

山下 隆義 \*<sup>1</sup>

Takayoshi Yamashita

藤吉 弘亘 \*<sup>1</sup>

Hironobu Fujiyoshi

\*<sup>1</sup>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 Unsupervised Reinforcement 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

を達成している。しかし、UNREAL 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 Auxiliary 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、Auxiliary 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

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

藤吉 弘亘 : hf@cs.chubu.ac.jp

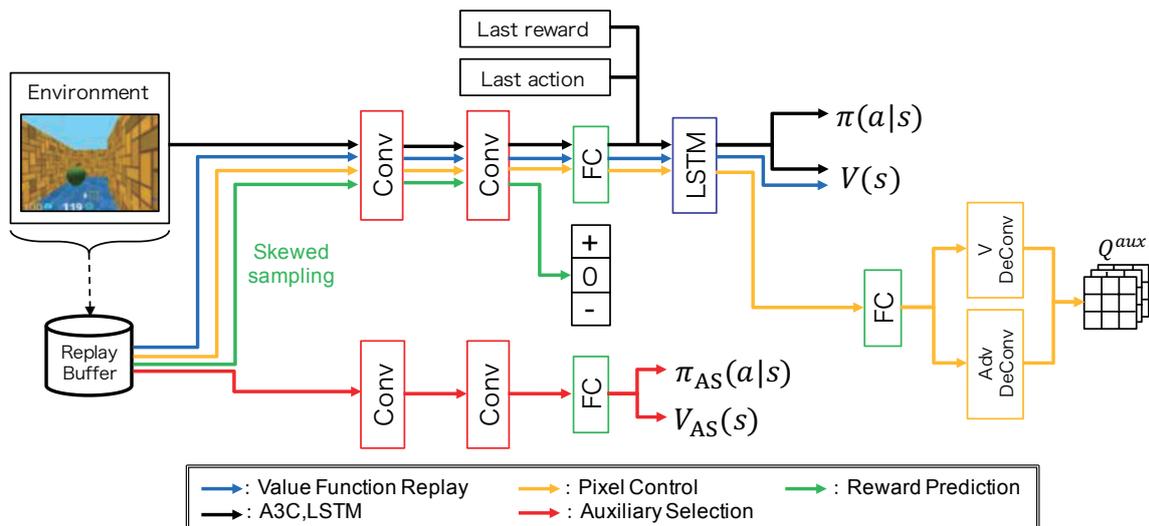


図 1: 提案手法のネットワーク構成

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  $L_{\text{proposed}}$  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。

$$L_{\text{proposed}} = L_{\text{A3C}} + C_{\text{VR}}L_{\text{VR}} + C_{\text{PC}} \sum_c L_Q^{(c)} + C_{\text{RP}}L_{\text{RP}} \quad (1)$$

提案手法では、Auxiliary Selection から獲得する  $C_{\text{VR}}$ ,  $C_{\text{PC}}$ ,  $C_{\text{RP}}$  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  $L_{\text{proposed}}$  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、 $L_{\text{proposed}}$  に基づいて行くと、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  $L_{\text{AS}_v}$  を式 (2)、方策の損失関数  $L_{\text{AS}_p}$  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、 $H(\pi_{\text{AS}})$  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。

$$L_{\text{AS}_v} = (r + \gamma V_{\text{AS}}(s_{t+1}, \theta^-) - V_{\text{AS}}(s_t, \theta))^2 \quad (2)$$

$$L_{\text{AS}_p} = -\log(\pi_{\text{AS}}(a|s))A(s, a) - \beta H(\pi_{\text{AS}}) \quad (3)$$

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  $L_{\text{AS}}$  を示す。

$$L_{\text{AS}} = L_{\text{AS}_v} + L_{\text{AS}_p} \quad (4)$$

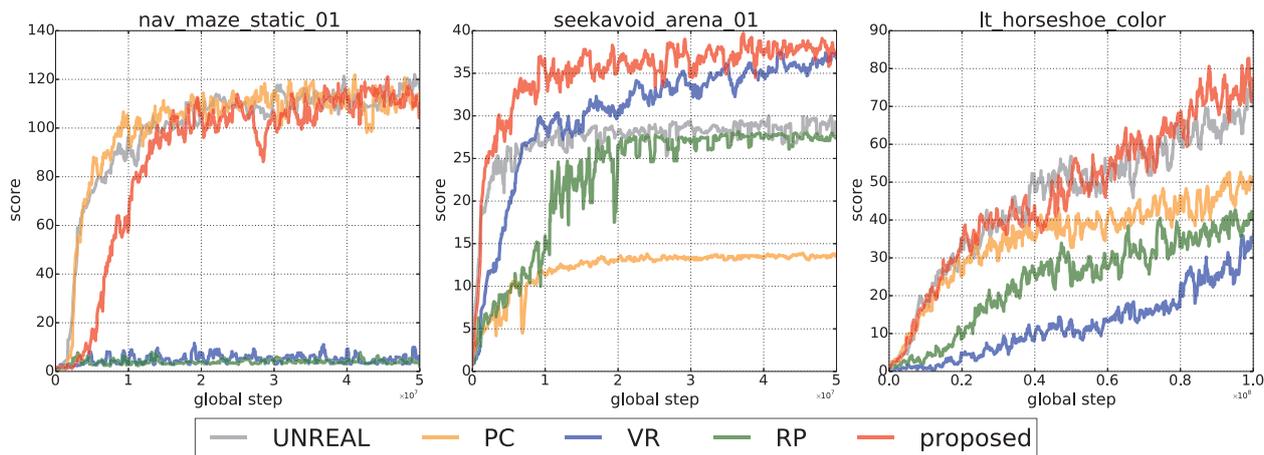


図 2: DeepMind Lab におけるステップ毎のスコア

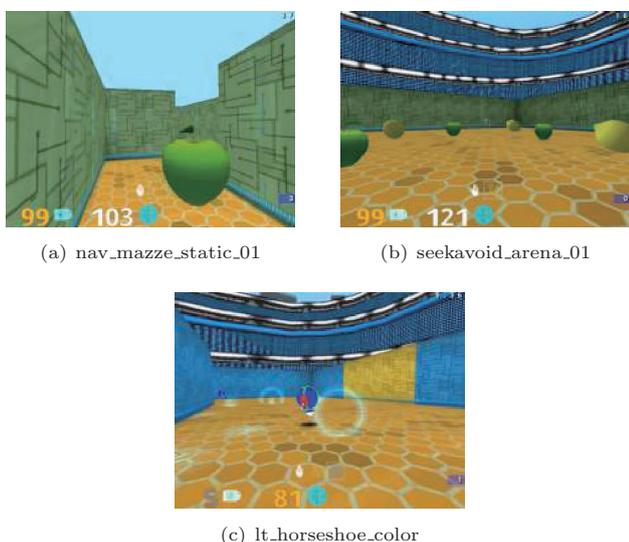


図 3: DeepMind Lab の各ゲーム画面

## 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。道中にあるリングを獲得すると +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。リングを獲得すると +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
maze	435.4 (48.3%)	487.8 (54.1%)	369.0 (41.0%)
seekavoid	0.3 (0.1%)	300.0 (100.0%)	0.0 (0.0%)
horseshoe	8545.1 (94.9%)	14.1 (0.1%)	8998.2 (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\*<sup>1</sup>      岩村 雅一\*<sup>1</sup>      黄瀬 浩一\*<sup>1</sup>  
 Yoshihiro Yamada      Masakazu Iwamura      Koichi Kise

\*<sup>1</sup>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。

$$G(x) = x + F(x) \quad (1)$$

ResNet 以降、Residual Block が式 (1) と同じ形で表される Wide ResNet [Zagoruyko 16] や PyramidNet [Han 17],  $G(x) = x + F_1(x) + F_2(x) + \dots$  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用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:

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

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。

$$G(x) = \begin{cases} x + \alpha F_1(x) + (1 - \alpha) F_2(x), & \text{in train-fwd} \\ x + \beta F_1(x) + (1 - \beta) F_2(x), & \text{in train-bwd} \\ x + 0.5 F_1(x) + 0.5 F_2(x), & \text{in test.} \end{cases} \quad (2)$$

ただし、学習時の forward path, 学習時の backward path, テスト時の 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 forward path では  $F_1(x)$  と  $F_2(x)$  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

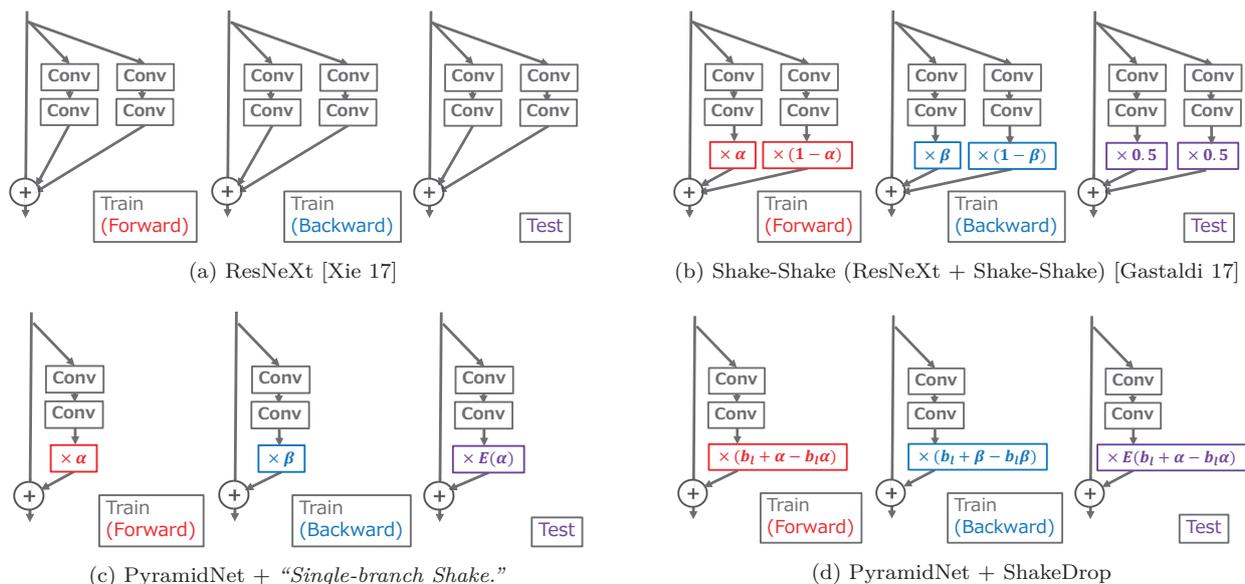


図 1: ネットワーク構造の模式図

ける (図 1(c)).

$$G(x) = \begin{cases} x + \alpha F(x), & \text{in train-fwd} \\ x + \beta F(x), & \text{in train-bwd} \\ x + 0.5F_1(x), & \text{in test.} \end{cases} \quad (3)$$

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 にそ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なく、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  $p_l = 1 - \frac{1}{2L}$  のベルヌ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

\*1 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。

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。

$$G(x) = \begin{cases} x + (b_l + \alpha - b_l \alpha) F(x), & \text{in train-fwd} \\ x + (b_l + \beta - b_l \beta) F(x), & \text{in train-bwd} \\ x + E(b_l + \alpha - b_l \alpha) F(x), & \text{in test.} \end{cases} \quad (4)$$

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 $\alpha$ と $\beta$ の影響

$\alpha$  及び  $\beta$  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、 $\alpha$  と  $\beta$  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。

表 1: CIFAR-100 における複数の  $\alpha$  と  $\beta$  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	$\alpha$	$\beta$	Error (%)
A (既存手法)	1	1	18.01
B (既存手法)	0	0	17.74
C	1	0	20.87
D	1	[0, 1]	18.80
E	1	[-1, 1]	21.69
F	0	1	99.00
G	0	[0, 1]	99.00
H	0	[-1, 1]	99.00
I	[0, 1]	1	38.48
J	[0, 1]	0	19.68
K	[0, 1]	[0, 1]	18.27
L	[0, 1]	[-1, 1]	20.61
M	[-1, 1]	1	18.68
N	[-1, 1]	0	17.28
O	[-1, 1]	[0, 1]	<b>16.22</b>
P	[-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

一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に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, + は 4 回の結果の平均である. \* は [Han 17] の結果である.

(a) Residual Block が  $G(x) = x + F(x)$  で表される場合 (ResNet, ResNeXt, PyramidNet)

Methods	Regularization	Error (%)
<b>ResNet-110</b> <Conv-BN-ReLU-Conv-BN-add>	Vanilla	+25.38
	ResDrop	+22.86
	ShakeDrop	+ <b>21.81</b>
<b>ResNet-164 Bottleneck</b> <Conv-BN-ReLU-Conv-BN-ReLU-Conv-BN-add>	Vanilla	21.96
	ResDrop	20.35
	ShakeDrop	<b>19.58</b>
<b>ResNeXt-29 8-64d</b> <Conv-BN-ReLU-Conv-BN-ReLU-Conv-BN-add>	Vanilla	20.25
	ResDrop	20.28
	ShakeDrop	<b>18.66</b>
<b>PyramidNet-110 <math>\alpha 270</math></b> <BN-Conv-BN-ReLU-Conv-BN-add>	Vanilla	+18.01
	ResDrop	+17.74
	ShakeDrop	+ <b>15.78</b>
<b>PyramidNet-272 Bottleneck <math>\alpha 200</math></b> <BN-Conv-BN-ReLU-Conv-BN-ReLU-Conv-BN-add>	Vanilla	*16.35
	ResDrop	15.94
	ShakeDrop	<b>14.96</b>

(b) Residual Block が  $G(x) = x + F_1(x) + F_2(x)$  で表される場合 (ResNeXt)

Methods	Regularization	Error (%)
<b>ResNeXt-164 2-1-40d Bottleneck</b> <Conv-BN-ReLU-Conv-BN-ReLU-Conv-BN-add>	Vanilla	21.75
	ResDrop Type-A	20.44
	ResDrop Type-B	20.21
	Shake-Shake	22.51
	ShakeDrop Type-A	<b>19.19</b>
	ShakeDrop Type-B	<b>18.66</b>
<b>ResNeXt-29 2-4-64d Bottleneck</b> <Conv-BN-ReLU-Conv-BN-ReLU-Conv-BN-add>	Vanilla	99.00
	ResDrop Type-A	20.13
	ResDrop Type-B	19.01
	Shake-Shake	18.82
	ShakeDrop Type-A	<b>18.49</b>
	ShakeDrop Type-B	<b>17.80</b>

---

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

○Hiroharu 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

○Yuji 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

○Riku 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-Communications, 2. Osaka University)

4:30 PM - 4:50 PM

### [3E4-OS-12b-04] Modeling of prejudice eyes by designers

○Ryuichi 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> 原田 達也<sup>\*1\*2</sup>  
 Hiroharu Kato Yoshitaka Ushiku Tatsuya Harada

<sup>\*1</sup>東京大学 The University of Tokyo <sup>\*2</sup>理化学研究所 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

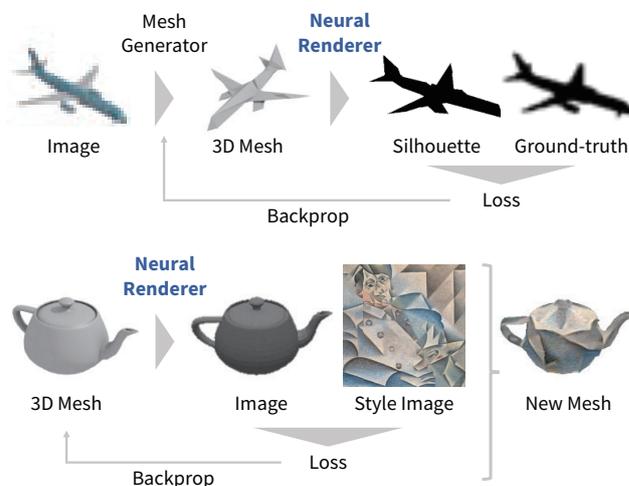


図 1: Pipelines for single-image 3D mesh reconstruction (upper) and 2D-to-3D style transfer (lower).

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3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

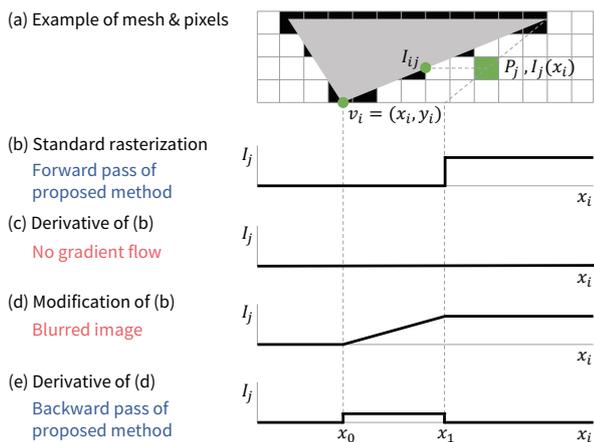


図 2: Illustration of our method.  $\mathbf{v}_i = \{x_i, y_i\}$  is one vertex of the face.  $I_j$  is the color of pixel  $P_j$ . The current position of  $x_i$  is  $x_0$ .  $x_1$  is the location of  $x_i$  where an edge of the face collides with the center of  $P_j$  when  $x_i$  moves to the right.  $I_j$  becomes  $I_{ij}$  when  $x_i = x_1$ .

Retrieval [Yan 16]	Voxel [Yan 16]	Mesh (ours)
0.4766	0.5736	<b>0.6016</b>

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 \*1。

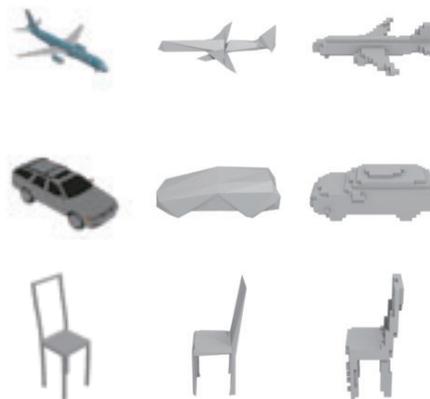


図 3: 3D mesh reconstruction from a single image. Results are rendered from three viewpoints. First column: input images. Second column: mesh reconstruction (proposed method). Third column: voxel reconstruction [Yan 16].



図 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 single-view 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)

\*1 [https://github.com/hiroharu-kato/neural\\_renderer](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> 原田 達也\*<sup>1,2</sup>  
 Yuji Tokozume Yoshitaka Ushiku Tatsuya Harada

\*<sup>1</sup>東京大学 The University of Tokyo    \*<sup>2</sup>理化学研究所 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。

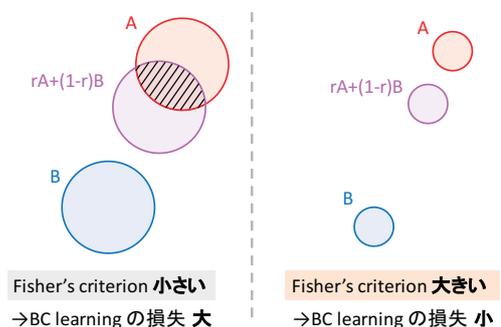


図1: BC learning による Fisher’s criterion の増大。

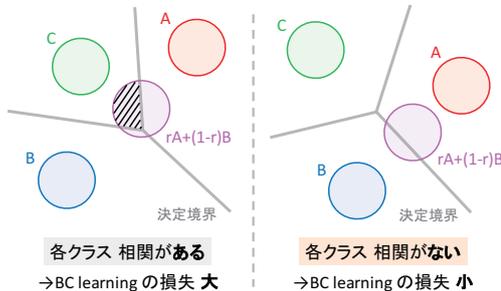


図2: BC learning による各クラスの無相関化。

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の。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。

表 1: CIFAR-10, CIFAR-100 における実験結果.

モデル	学習手法	認識率 (%)	
		CIFAR-10	CIFAR-100
11 層 CNN	Standard	6.07 ± 0.04	26.68 ± 0.09
	BC (ours)	5.40 ± 0.07	24.28 ± 0.11
	BC+ (ours)	<b>5.22 ± 0.04</b>	<b>23.68 ± 0.10</b>
ResNet-29	Standard	4.24 ± 0.06	20.18 ± 0.07
	BC (ours)	3.75 ± 0.04	19.56 ± 0.10
	BC+ (ours)	<b>3.55 ± 0.03</b>	<b>19.41 ± 0.07</b>
ResNeXt-29	Standard	3.54 ± 0.04	<b>16.99 ± 0.06</b>
	BC (ours)	<b>2.79 ± 0.06</b>	18.21 ± 0.12
	BC+ (ours)	2.81 ± 0.06	17.93 ± 0.09
DenseNet	Standard	3.61 ± 0.10	17.28 ± 0.12
	BC (ours)	2.68 ± 0.03	16.36 ± 0.10
	BC+ (ours)	<b>2.57 ± 0.06</b>	<b>16.23 ± 0.07</b>
Shake-Shake	Standard	2.86	<b>15.85</b>
	BC (ours)	2.38 ± 0.04	15.90 ± 0.06
	BC+ (ours)	<b>2.26 ± 0.01</b>	16.00 ± 0.10

**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.

$$\frac{p\mathbf{x}_1 + (1-p)\mathbf{x}_2}{\sqrt{p^2 + (1-p)^2}} \quad \text{where } p = \frac{1}{1 + 10^{\frac{G_1 - G_2}{20}} \cdot \frac{1-r}{r}} \quad (1)$$

## 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.

$$\frac{p(\mathbf{x}_1 - \mu_1) + (1-p)(\mathbf{x}_2 - \mu_2)}{\sqrt{p^2 + (1-p)^2}} \quad \text{where } p = \frac{1}{1 + \frac{\sigma_1}{\sigma_2} \cdot \frac{1-r}{r}} \quad (2)$$

## 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.

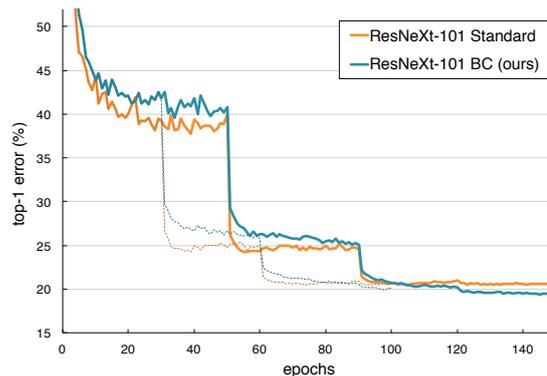


図 3: ImageNet-1K における実験結果. 破線は 100 epoch, 実線は 150 epoch での実験結果.

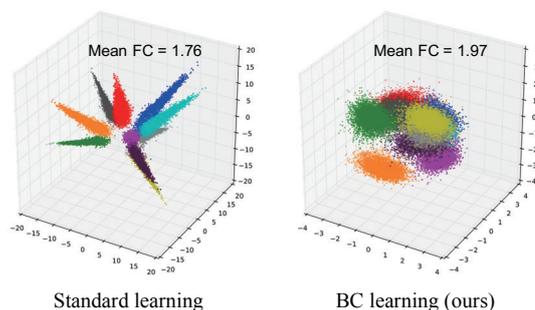


図 4: BC learning によって学習された特徴空間の可視化.

次に, ImageNet-1K における実験結果を図 3 に示す. BC learning によって最終的な認識率が 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.

## 参考文献

- [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<sup>\*1</sup> 堀井隆斗<sup>\*1</sup> 青木達哉<sup>\*1</sup> 長井隆行<sup>\*1\*2</sup>  
Riku Fujimoto Takato Horii Tatsuya Aoki Takayuki Nagai

<sup>\*1</sup>電気通信大学 The University of Electro-Communications  
<sup>\*2</sup>大阪大学 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んでいる [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のため、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

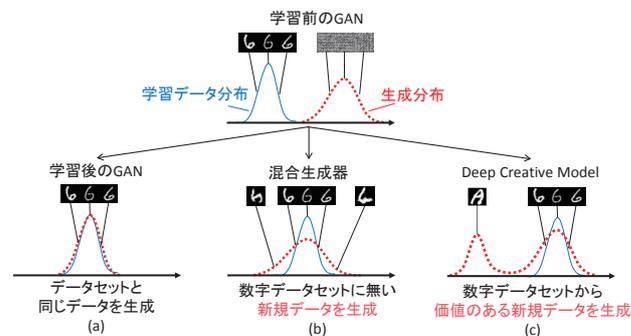


図 1: GAN, 混合生成器, DCM の比較.

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。

$$\begin{aligned} & \min_G \max_D V(D, G) \\ & = (\mathbb{E}_{x \sim P_x} \log(D(x)) + \mathbb{E}_{z \sim P_z} \log(1 - D(G(z)))) \end{aligned} \quad (1)$$

## 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な不可欠である。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  $L_G$  は次式で定義される。

$$\begin{aligned} L_G = & -H(G(z)) + \mathbb{E}_{x \sim P_G} \log P(x) \mathbb{I}[P(x) > \epsilon] \\ & + \|\mathbb{E}_{z \sim P_z} f((G(z))) - \mathbb{E}_{x \sim P_x} f(x)\|^2 \end{aligned} \quad (2)$$

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。

$$L_{PT} = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j \neq i}^{N-1} \left( \frac{f(G(z_i))^T f(G(z_j))}{\|f(G(z_i))\| \|f(G(z_j))\|} \right)^2 \quad (3)$$

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。  $\mathbb{I}$  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  $\epsilon$  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。

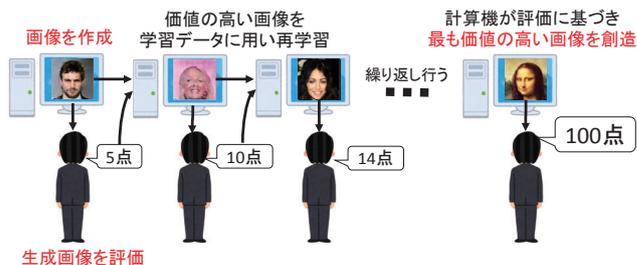


図 2: 創造的なデータ生成手法の概念図。

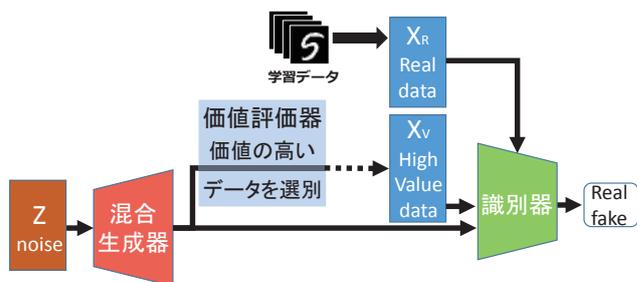


図 3: Deep Creative Model の模式図。

## 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的評価器で評価する。
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生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  $L_G$  には

$$L_G = -H(P_G) + \|\mathbb{E}_{x \sim P_G} f(x) - \mathbb{E}_{x \sim P_x} f(x)\|^2 \quad (4)$$

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、

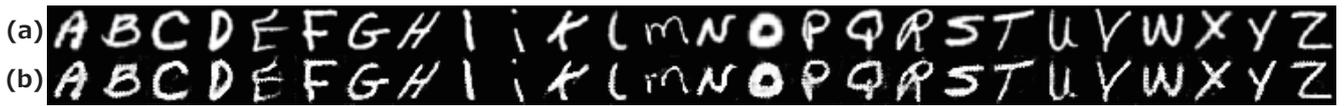


図 4: (a) 最も価値の高い画像  $X_s$ 。(b) 生成画像の中で最も価値の高い画像。

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  $X_V$  として保持する。識別器は真の学習データ  $X_R$  と生成した価値の高いデータ  $X_V$  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  $X_V$  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

$$V(X) = -(X_s - X)^2 \quad (5)$$

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.

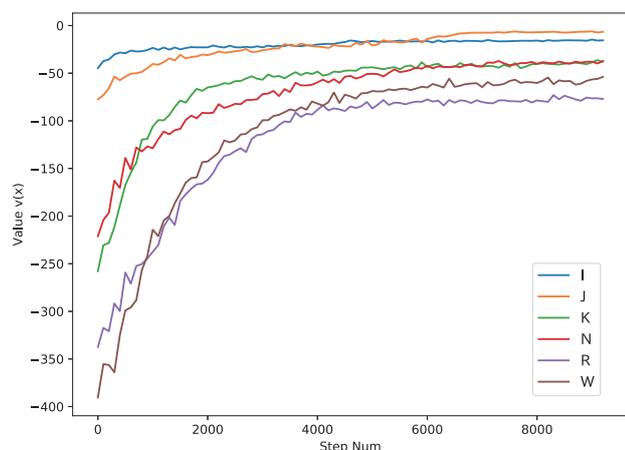


図 6: 学習による価値の推移

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デ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.

## 参考文献

- [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 Mazonzone, 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 Research 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.: Energy-based 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\*<sup>1</sup>  
Ryuichi Ishikawa

和泉 興\*<sup>1</sup>  
Kou Izumi

林 秀和\*<sup>1</sup>  
Hidekazu Hayashi

福田 宏幸\*<sup>2</sup>  
Hiroyuki Fukuda

\*<sup>1</sup> 株式会社電通デジタル  
Dentsu Digital Inc

\*<sup>2</sup> 株式会社電通  
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によるテキストの抽出

近年の研究によると、Convolution Neural Network (CNN)では、入力近隣の層で形状の情報を抽出しており、層を進むにつれてテキスト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。

先行研究によるテキスト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。

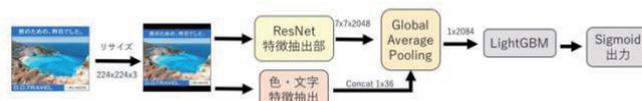


図1 提案手法の構造図

#### 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へリサイズする必要があった。しかし通常的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ぼさないと考えた。

#### 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。

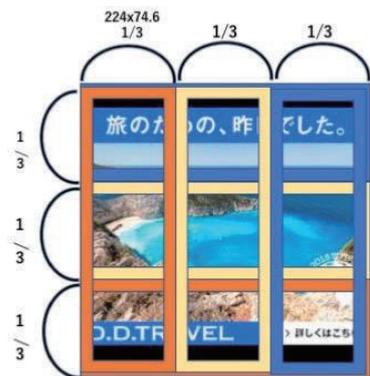


図2 新たな色彩情報の取得図

### 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。

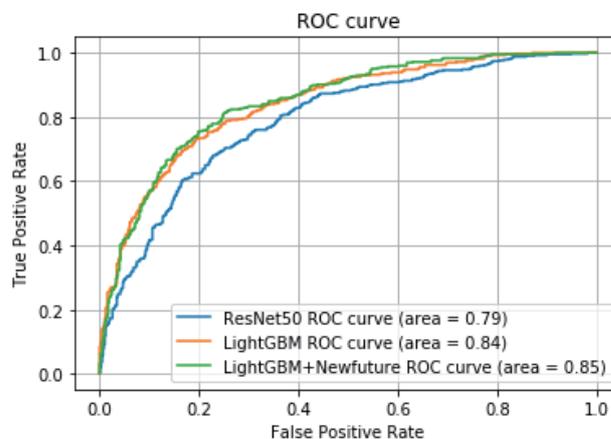


図3 モデル別 ROC 曲線

### 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

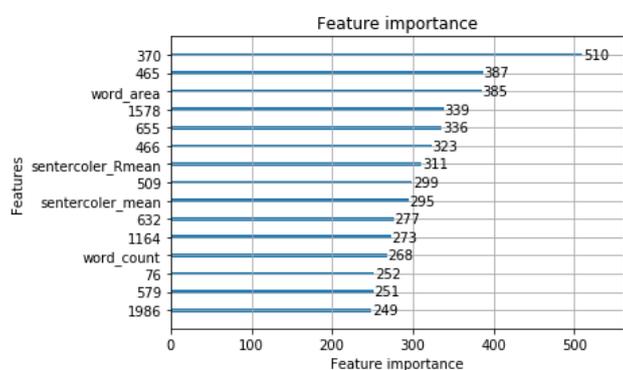


図4 Light GBM による特徴重要度

※数字カラムは CNN から抽出した画像ベクトル

## 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。

## 参考文献

- [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.

- [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. Dollár, and C. L. Zitnick. Microsoft coco: Common 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

---

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

○Shutarou 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 a biological signal

○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

○Atsushi 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

○Norifumi 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] Analysis of Strategies in Werewolf Game by 3 Players Considering Voting Behaviour of Other Players

○Hinako 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>

Hiroataka Osawa

\*<sup>1</sup> 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

\*<sup>2</sup> 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りが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

連絡先: 高山周太郎

hailabsec@iit.tsukuba.ac.jp

筑波大学 理工学群 工学システム学類

ヒューマンエージェントインタラクション研究室

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 人狼)を対象とする。本研究での5 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を知ることができる。
- 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。

### • 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。arms\_degree の値 $\theta$ は次の(1)式で与えられる。

$$\begin{pmatrix} x \\ y \end{pmatrix} = \frac{1}{\|l\|} \begin{bmatrix} l_x & l_y \\ -l_y & l_x \end{bmatrix} \cdot r \\ \theta = \tan^{-1} \frac{y}{x} \quad (1)$$

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。

### • 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。

表 1: 全ゲーム結果

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で検定( $p^* < 0.05$ ,  $p^+ < 0.1$ )

	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 最短	占い師 最長	狂人 最短	狂人 最長
平均値	-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。

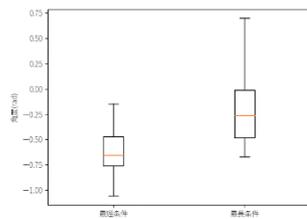


図 2: ターン数で比較した狂人の arms\_degree

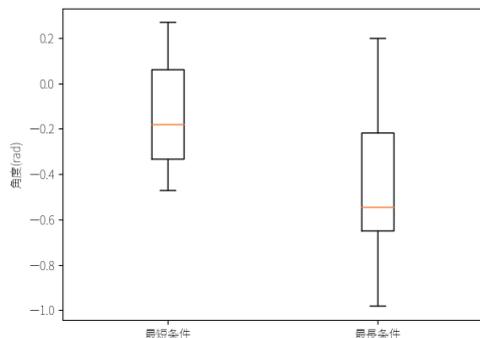


図 3: ターン数で比較した占い師の arms\_degree

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
平均値	0.493	0.206	0.387	0.167
標準偏差	0.230	0.239	0.265	0.260

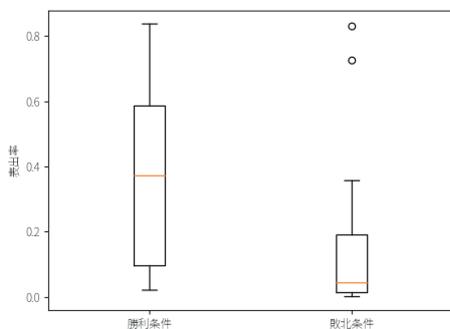


図 4: 占い師の勝敗ごとの directing\_upper\_the\_right\_arm

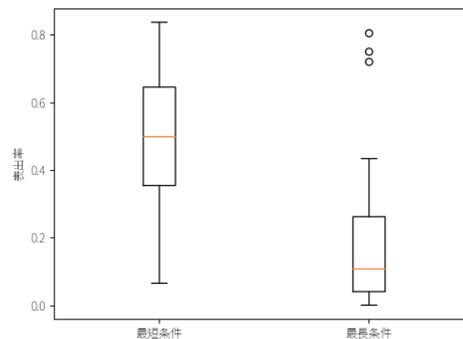


図 5: 占い師のターン数ごとの directing\_upper\_the\_right\_arm

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。

## 参考文献

- [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ーの「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 University

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, a 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、プレイヤー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。プレイヤー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、エンターテインメントとして「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-Agent Interaction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ー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ー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、精神性発汗を電氣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

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、プレイヤー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られる。人狼プレイヤーが重要であると考えられ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、人狼プレイヤーの「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ーの分析

御手洗らは、人狼ゲームプレイヤー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。プレイヤー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ーに影響を与え、ゲームを動かしているのかを調べるために、情動反応のマーカーとして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ーの発話を抽出した結果、人狼プレイヤーは他プレイヤーに疑われた際に、嘘をつくりリスクを減らす、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、村人プレイヤーの思考過程とSCRの発現のタイミングから、村人プレイヤーは他プレイヤーへの疑いに、人狼プレイヤー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]。

連絡先: 棟方 渚, 京都産業大学情報理工学部,  
munekata@cc.kyoto-su.ac.jp

### 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)：他のプレイヤーの役職をみる
- 人狼：他のプレイヤーを殺害する
- 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ー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。

1. 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. をもう一度繰り返す。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ー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、個々のプレイヤーのSCLは常に上昇と下降を繰り返していると考えられるが、複数のプレイヤーの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、全プレイヤーの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」プレイヤーと「弱い」プレイヤー間でのSCLの振る舞いを比較することとした。ここでいう「強い」プレイヤーは、10から15回の試行のうち、勝率が高いプレイヤーとし、勝率の低い者を「弱い」プレイヤーとした。

#### 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、プレイヤーのジェスチャ等の振る舞いを妨げることを無いうように計測装置を配置し、電極やリード線をプレイヤーの身体に固定した。ゲームの進行やプレイヤーの言動を記録するために、各プレイヤー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

複数のプレイヤーの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ー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、各プレイヤーによって多少の時間差があることを考慮し、SCLの同期的な上昇は誤差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数

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箇所複数のプレイヤーの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ー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、あるプレイヤー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ー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、他プレイヤーへの疑い(他プレイヤーからの疑い)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、まあ人狼かもしれないけど(他プレイヤーを指差しながら)」、「C君人狼だからね〜」など特定のプレイヤー、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ーを指差し)」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、プレイヤーの振る舞いを分析することとした。

#### 4.2 勝率による「強い」プレイヤーの選定

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、強いプレイヤーと弱いプレイヤーを選定することにした。各プレイヤーの勝率を以下(表2)に示す。

表 2: 各プレイヤーの勝利数と試行回数

プレイヤー	A	B	C	D	E	F
勝率	70%	67%	40%	70%	40%	40%
試行回数	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ーBを「強い」プレイヤー、試行回数が多く勝率の低いプレイヤーCとFを「弱い」プレイヤーとする。全15試行における人狼陣営の勝率は33%、村人勝率の67%であった。強いプレイヤーと弱いプレイヤーの各陣営に属した回数を表3に示す。

表 3: 各プレイヤーの勝利数と試行回数

	プレイヤーB	プレイヤーC	プレイヤー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、強いプレイヤー(B)と弱いプレイヤー(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ー、弱いプレイヤーについて、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ーの振る舞いを調査する。次章では、両プレイヤー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ー(B)と弱いプレイヤー(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、強いプレイヤー(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、弱いプレイヤー(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ー(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ー(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、強いプレイヤーは会議開始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は複数のプレイヤーの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ー

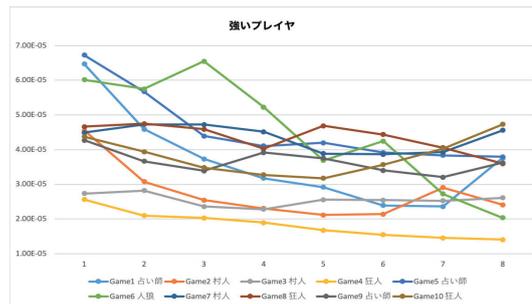


図 1: 各試行の会議中の強いプレイヤー

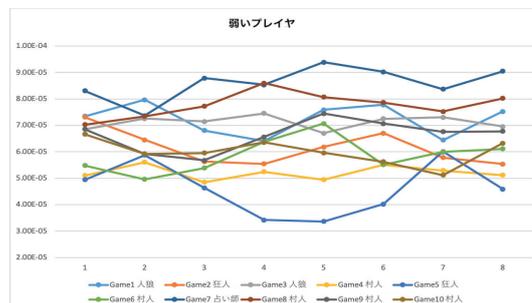


図 2: 各試行の会議中の弱いプレイヤー

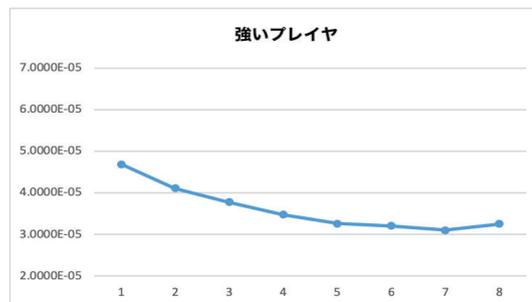


図 3: 会議時: 強いプレイヤーのSCL (全試行)

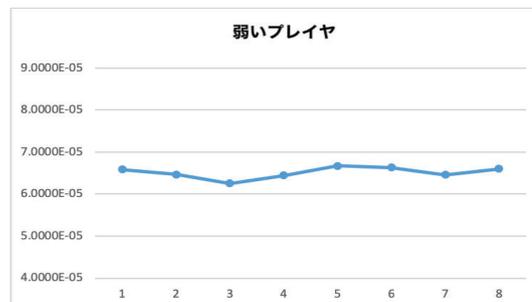


図 4: 会議時: 弱いプレイヤーSCL (全試行)

と弱いプレイヤーの言動に着目し調査した。具体的には、CO時のプレイヤーの「挙手の有無」つまり、占い師として名乗りをあげたかどうかを調べ（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 SCL上昇	挙手無し SCL上昇	挙手有り SCL変化無
強いプレイヤー	4	3	0
弱いプレイヤー	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ーは、他プレイヤー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ー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、他プレイヤーの様子（発言や指差し）をただ観察する様子のみがみられた。表3の結果から、強いプレイヤーは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ーでは、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、強いプレイヤーは弱いプレイヤーよりも、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、どのプレイヤーが、どのプレイヤーに対し、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、強いプレイヤー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、複数のプレイヤーの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、強いプレイヤーと弱いプレイヤーの初日の会議時のSCLの振る舞いと言動を分析した。その結果、強いプレイヤーはいずれのゲーム、役職でも傾向がみられ、弱いプレイヤー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、強いプレイヤーは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ーと弱いプレイヤーの選定には未だ改良の余地があると思われる。プレイヤー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、プレイヤーが電極に触れてもノイズの混入を防ぐ計測システム的设计が必要となる。

## 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

- [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 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: 人狼プレイヤー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.u-  
tokyo.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はできない.

#### (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はできない.

#### (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	⑦	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	○	○	○	○	○	○	-	×	○

表 2: 特徴量

番号	概要	値
1	人狼占いCO	二値(0 or 1)
2	占い師2ターン目CO	二値(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	二値(0 or 1)
6	2CO盤面における裏切り者黒だし	二値(0 or 1)
7	3CO盤面における占い結果騙り	二値(0 or 1)
8	3CO盤面における裏切り者対抗占い	二値(0 or 1)
9	3CO盤面における人狼対抗占い	二値(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す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、裏切り者のとす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する。 $S', W', P'$ の値と各プレイヤーのとした行動から、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、 $p_v(S, W, P, S', W', P')$ と書くことにする。

各役職は、ほかの役職のとす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、 $4 \cdot 2 = 8$ 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、対抗の一人に白出しすることは、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ない、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られる。

表 4: シミュレーション変数

変数名	意味
$s_1$	2CO 盤面における占い師の結果騙り率
$w_1$	3CO 盤面における占い師の結果騙り率
$p_1$	人狼の占い師CO率
$s_2$	3CO 盤面における人狼の対抗占い率
$w_2$	裏切り者の占い師CO率
$p_2$	3CO 盤面における裏切り者の対抗占い率

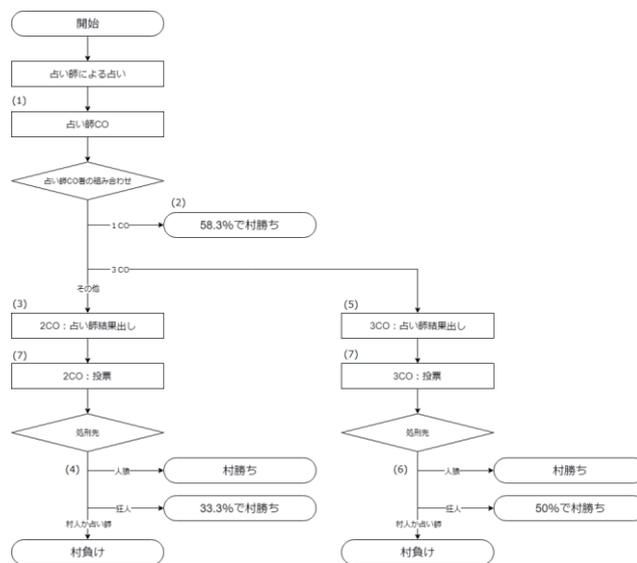


図 1: モデル化されたゲームのプロチャート

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) +  $(1/2) \cdot (\text{裏切り者確率})$  が最大のプレイヤーに投票し、2CO 盤面の場合、(人狼確率) +  $(1/3) \cdot (\text{裏切り者確率})$  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  $p_v(S, W, P, S', W', P')$  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、下段が左から  $s_2, w_2, p_2$  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と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1状態に収束せず、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.

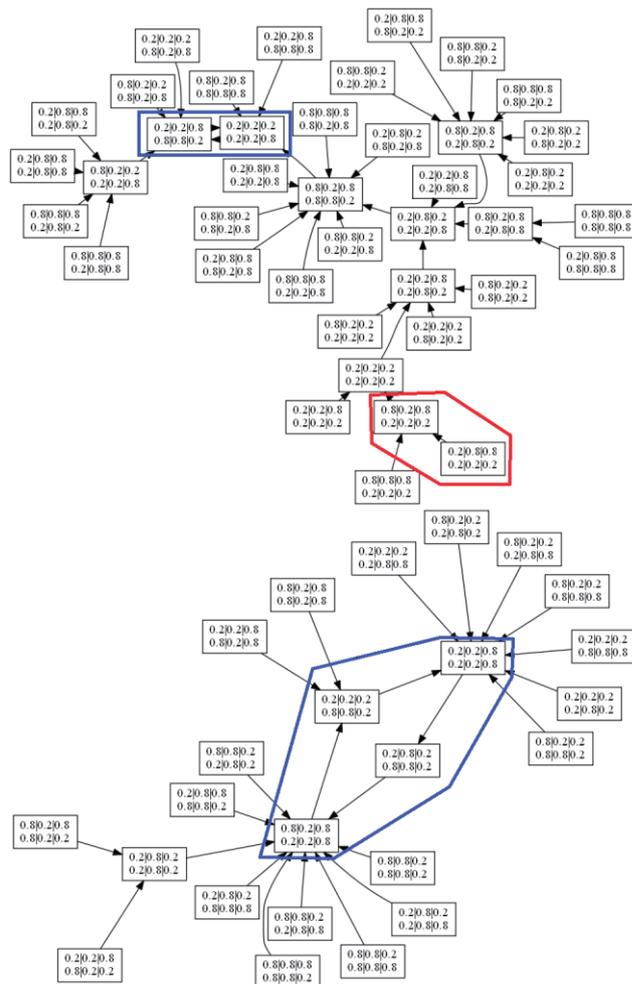


図 2: シミュレーション結果の遷移図

[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 \*<sup>1</sup>  
Norifumi Watanabe

糸田孝太 \*<sup>2</sup>  
Kota Itoda

\*<sup>1</sup> 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", "self-priority 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、それに合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置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。

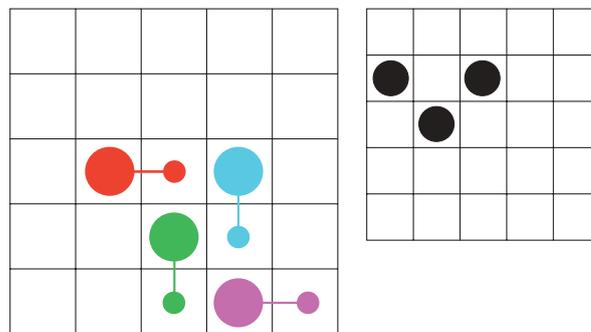


図1: 被験者が移動するグリッドワールド (左)。大きい円のコマで各被験者のそれぞれの位置を示し、小さい円によって一ステップ前に被験者がどこにいたのかを表示している。目標となるパターン (右)。

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捗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

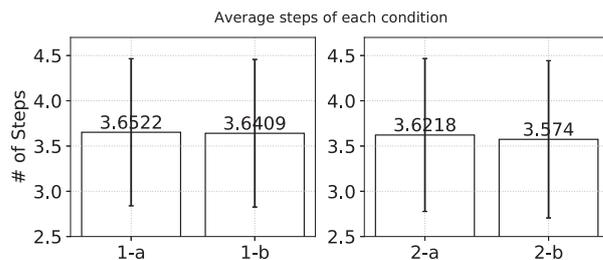


図2: 目標パターン到達のステップ数の比較. 1-a:ランダム選択+他者エージェントの推定無, 1-b:ランダム選択+他者エージェントの推定有, 2-a:自己優先選択+他者エージェントの推定無, 2-b:自己優先選択+他者エージェントの推定有.

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。

## 参考文献

- [1] 子安増生, 心の理論一心を読む心の科学 (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 understanding 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

## Analysis 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 発言について

発言の種類は以下の 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) の発言がありえる。従って、発言の可能性は計 27 通りある。

#### 4.4 投票について

占い師は、誰が人狼であること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 通りの発言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・占い師の発言、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	Pw	Ps	Vv	Vw	result
To	To	To	U	U	case 3.1
To	To	Tv	S	U	draw or W_win
To	To	Tw	W	S	V_win
To	Tv	To	W	U	V_win
To	Tv	Tv	U	U	case 3.1
To	Tv	Tw	W	S	V_win
To	Ts	To	S	U	draw or W_win
To	Ts	Tv	S	U	draw or W_win
To	Ts	Tw	U	S	V_win or W_win
Tw	To	To	U	V	V_win or draw
Tw	To	Tv	S	V	draw
Tw	To	Tw	W	U	V_win
Tw	Tv	To	W	V	V_win
Tw	Tv	Tv	U	V	V_win or draw
Tw	Tv	Tw	W	U	V_win
Tw	Ts	To	S	V	draw
Tw	Ts	Tv	S	V	draw
Tw	Ts	Tw	U	U	case 3.1
Ts	To	To	U	U	case 3.1
Ts	To	Tv	S	U	draw or W_win
Ts	To	Tw	W	S	V_win
Ts	Tv	To	W	U	V_win
Ts	Tv	Tv	U	U	case 3.1
Ts	Tv	Tw	W	S	V_win
Ts	Ts	To	S	U	draw or W_win
Ts	Ts	Tv	S	U	draw or W_win
Ts	Ts	Tw	U	S	V_win or W_win

表 3: 一回同時発言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言行動について考察されている。具体的には、各プレイヤーの発言の選択肢が削減できるかどうかを考えており、特定の発言を行った場合、全ての状態において他の発言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、発言の削減については考慮せず、全ての発言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のかを考察し、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  $V_n$  の戦略を選択すると仮定した場合の最適な狼の戦略を  $W_{n+1}$ 、狼が  $W_n$  の戦略を選択すると仮定した場合の村人の戦略を  $V_{n+1}$  と表す ( $n$  は 0 以上の整数)。また、 $V_0$ 、 $W_0$  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  $P_v = T_o$ ,  $P_w = T_o$ ,  $P_s = T_v$  と、 $P_v = T_o$ ,  $P_w = T_v$ ,  $P_s = T_o$  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、 $P_v = T_s$ ,  $P_w = T_o$ ,  $P_s = T_v$  と、 $P_v = T_s$ ,  $P_w = T_v$ ,  $P_s = T_o$  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。

$P_v$	$P_w$	$P_s$
$T_o$	$T_o$	$T_o$
$T_o$	$T_o$	$T_v$
$T_o$	$T_v$	$T_o$
$T_o$	$T_o$	$T_w$
$T_o$	$T_s$	$T_o$
$T_o$	$T_v$	$T_v$
$T_o$	$T_s$	$T_w$
$T_o$	$T_v$	$T_w$
$T_o$	$T_s$	$T_v$
$T_w$	$T_o$	$T_o$
$T_s$	$T_o$	$T_o$
$T_w$	$T_o$	$T_v$
$T_s$	$T_v$	$T_o$
$T_w$	$T_o$	$T_w$
$T_s$	$T_s$	$T_o$
$T_w$	$T_v$	$T_o$
$T_s$	$T_o$	$T_v$
$T_w$	$T_v$	$T_v$
$T_s$	$T_v$	$T_v$
$T_w$	$T_v$	$T_w$
$T_s$	$T_s$	$T_v$
$T_w$	$T_s$	$T_o$
$T_s$	$T_o$	$T_w$
$T_w$	$T_s$	$T_v$
$T_s$	$T_v$	$T_w$
$T_w$	$T_s$	$T_w$
$T_s$	$T_s$	$T_w$

$P_v$	$P_w$	$P_s$
$T_o$	$T_o$	$T_o$
$T_o$	$T_o$	$T_v$
$T_o$	$T_v$	$T_o$
$T_o$	$T_o$	$T_w$
$T_o$	$T_s$	$T_o$
$T_o$	$T_v$	$T_v$
$T_o$	$T_s$	$T_w$
$T_o$	$T_v$	$T_w$
$T_o$	$T_s$	$T_v$
$T_w$	$T_o$	$T_o$
$T_s$	$T_o$	$T_o$
$T_w$	$T_o$	$T_v$
$T_s$	$T_v$	$T_o$
$T_w$	$T_o$	$T_w$
$T_s$	$T_s$	$T_o$
$T_w$	$T_v$	$T_o$
$T_s$	$T_o$	$T_v$
$T_w$	$T_v$	$T_v$
$T_s$	$T_v$	$T_v$
$T_w$	$T_v$	$T_w$
$T_s$	$T_s$	$T_v$
$T_w$	$T_s$	$T_o$
$T_s$	$T_o$	$T_w$
$T_w$	$T_s$	$T_v$
$T_s$	$T_v$	$T_w$
$T_w$	$T_s$	$T_w$
$T_s$	$T_s$	$T_w$

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かず、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  $W_S$ 、人狼の場合  $V_S$  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

$V_0$  を起点とした場合、 $V_6$  以降  $V_2 \sim W_5$  をループし、 $W_0$  を起点とした場合、 $W_6$  以降  $W_2 \sim V_5$  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。 $VW_0$  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  $W_n$  は、村人が  $V_{n-1}$  の戦略、人狼が  $W_n$  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)。 $V_n$  についても同様である。 $W_1$  では例えば  $P_v = T_o$ ,  $P_w = T_o$ ,  $P_s = T_w$  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  $W_4$ 、村人は  $V_4$ 、 $V_6$  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  $V_0$ 、村人は  $W_0$ 、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。

## 参考文献

- [篠田 14] 篠田孝祐, 鳥海不二夫, 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.

	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 case 3.1	2	3	1	1	1	1	1	0	3	1	0	1	2
V_win or W_win draw	5	3	1	1	1	1	1	8	4	4	4	4	4
draw or W_win	2	3	1	1	1	1	1	1	2	0	1	2	1
W_win	3	0	10	0	11	0	11	6	0	10	0	10	0
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	Pw	Ps	V0	W1	V2	W3	V4	W5	V6
To	To	To	U	U	U	U	U	U	U
To	To	Tv	S	S	W	V	S	S	W
To	To	Tw	W	V	S	S	W	V	S
To	Tv	To	W	V	S	S	W	V	S
To	Tv	Tv	U	V	U	S	U	V	U
To	Tv	Tw	W	V	S	S	W	V	S
To	Ts	To	S	S	W	V	S	S	W
To	Ts	Tw	U	S	U	V	U	S	U
To	Ts	Tv	S	S	W	V	S	S	W
Tw	To	To	U	S	W	V	S	S	W
Tw	To	Tw	W	U	S	U	W	U	S
Tw	To	Tv	S	S	W	V	S	S	W
Tw	Tv	To	W	V	S	S	W	V	S
Tw	Tv	Tv	U	VS	W	V	S	S	W
Tw	Tv	Tw	W	V	S	S	W	V	S
Tw	Ts	To	S	S	W	V	S	S	W
Tw	Ts	Tv	S	S	W	V	S	S	W
Tw	Ts	Tw	U	S	W	V	S	S	W
Ts	To	To	U	V	S	S	W	V	S
Ts	To	Tv	S	U	W	U	S	U	W
Ts	To	Tw	W	V	S	S	W	V	S
Ts	Tv	To	W	V	S	S	W	V	S
Ts	Tv	Tv	U	V	S	S	W	V	S
Ts	Tv	Tw	W	V	S	S	W	V	S
Ts	Ts	To	S	S	W	V	S	S	W
Ts	Ts	Tv	S	S	W	V	S	S	W
Ts	Ts	Tw	U	VS	S	S	W	V	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 人狼の戦略分析, HAI シンポジウム 2017 論文集, 2017.

Pv	Pw	Ps	W0	V1	W2	V3	W4	V5	W6
To	To	To	U	U	U	U	U	U	U
To	To	Tv	U	WS	S	W	V	S	S
To	To	Tw	S	W	V	S	S	W	V
To	Tv	To	U	WS	V	S	S	W	V
To	Tv	Tv	U	U	VS	U	VS	U	VS
To	Tv	Tw	S	W	V	S	S	W	V
To	Ts	To	U	S	S	W	V	S	S
To	Ts	Tv	U	S	S	W	V	S	S
To	Ts	Tw	S	U	V	U	S	U	V
Tw	To	To	V	S	S	W	V	S	S
Tw	To	Tv	V	S	S	W	V	S	S
Tw	To	Tw	U	WS	U	WS	U	WS	U
Tw	Tv	To	V	S	S	W	V	S	S
Tw	Tv	Tv	V	S	S	W	V	S	S
Tw	Tv	Tw	U	WS	V	S	S	W	V
Tw	Ts	To	V	S	S	W	V	S	S
Tw	Ts	Tv	V	S	S	W	V	S	S
Tw	Ts	Tw	U	S	S	W	V	WS	S
Ts	To	To	U	W	V	S	S	W	V
Ts	To	Tv	U	W	U	S	U	W	U
Ts	To	Tw	S	W	V	S	S	W	V
Ts	Tv	To	U	W	V	S	S	W	V
Ts	Tv	Tv	U	W	V	S	S	W	V
Ts	Tv	Tw	S	W	V	S	S	W	V
Ts	Ts	To	U	WS	VS	WS	VS	WS	VS
Ts	Ts	Tv	U	WS	S	W	V	S	S
Ts	Ts	Tw	S	W	V	S	S	WS	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

○Eisuke Sato<sup>1</sup>, Hirotaka Osawa<sup>1</sup> (1. University of Tsukuba)

3:50 PM - 4:10 PM

### [3F4-OS-14b-02] Role estimation in Werewolf games using a selective desensitization neural network

Masahiro Saito<sup>2</sup>, Seiryu Mishina<sup>1</sup>, ○Ken Yamane<sup>1</sup> (1. Teikyo University, 2. Fujisoft Incorporated)

4:10 PM - 4:30 PM

### [3F4-OS-14b-03] Artificial Intelligence for Deducing Roles of Players in the Werewolf Game using Information about Conversations among Players

○Munemichi Fukuda<sup>1</sup>, Hajime Anada<sup>1</sup> (1. Tokyo City University)

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>, ○Tomonobu Ozaki<sup>1</sup> (1. Nihon University)

4:50 PM - 5:10 PM

### [3F06-09-5] Discussion / Conclusion

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

\*<sup>1</sup> 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>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、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。

一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誤って解釈しており、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。

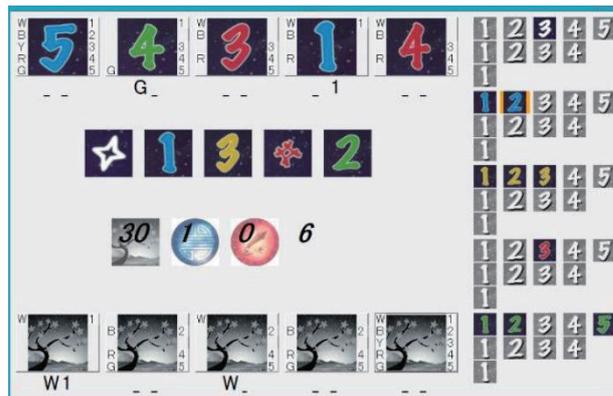


図 1 Hanabi のインタフェース

### 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

- Q5. 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 問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。

表 1. アンケートの結果

	A(h)条件平均	B(h)条件平均	p 値
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

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。( $r > .4$ )

表 2. 相関係数

	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*

\*  $r > .4$

## 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。

## 参考文献

- [1] 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, 412-01
- [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)

# 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、他プレイヤー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、プレイヤー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ー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ー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ー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ー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

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

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、全プレイヤー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

プレイヤー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、プレイヤーの人数が増えた（役職の種類が増えた）ことやプレイヤー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 発言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

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、 $21 \times 20 \times 100 = 42,000$  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 を用いた推定結果  
SVM (RBF,  $\gamma = 0.5$ ,  $cost = 32$ )  
精度: 66.6%

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%

表 2: SDNN を用いた推定結果

役職	best 精度: 69.4%		worst 精度: 67.6%	
	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。

## 参考文献

- [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\*<sup>1</sup>  
Hajime Anada

\*<sup>1</sup> 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人狼で勝つために、各プレイヤー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、どのプレイヤー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ー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ーが投票した対象、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人狼を取り扱う。5人狼の場合は各プレイヤーは役職(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。またプレイヤーの役職と種族、陣営は他のプレイヤーに非公開である。

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人のプレイヤー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人のプレイヤー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

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。昼はプレイヤー同士で会話し、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ーを騙し、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、最多票のプレイヤーが追放される。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。

プレイヤー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。

発言に用いる定型文の種類を表1に示す。

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

ここで、Pはプレイヤー、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。

- 全てのプレイヤーが発言 OVER をする。
- 全てのプレイヤーが発言 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、プレイヤー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に示すプレイヤーの特

徴から各プレイヤーの役職を推定する NN を構築している。この NN ではプレイヤーの役職が村人, 占師, 人狼, 裏切り者である確率をそれぞれ出力する。

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)をしたプレイヤーの数
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	(占師 CO をしたプレイヤーのみ) X が何番目に占師 CO をしたか
占い結果	(占師 CO をしたプレイヤーのみ) 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ーと, 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
肯定的意見の数	X が別のプレイヤー Y に対して村陣営であると推定した, または Y の発言で発言 AGREE をした数
否定的意見の数	X が別のプレイヤー Y に対して狼陣営であると推定した, 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ー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, どのプレイヤー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, どのプレイヤー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ー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 人狼で勝つために, 経過日数と追放投票で各プレイヤーが投票した対象, 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ーが投票した対象
- 各プレイヤーの 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ーへの発言内容
- 他のプレイヤーから推定対象者への発言内容
- 他のプレイヤー同士の発言内容

このモデルを自分以外の推定対象者のプレイヤー 1 人 1 人に使い, 各プレイヤーの役職を推定する。

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

特徴	詳細
経過日数	現在何日目か
追放投票で各プレイヤーが投票した対象	追放投票で各プレイヤーが投票した対象
各プレイヤーの CO した役職とその日時	各プレイヤーが CO した役職とその時の経過日数, ターン数を記録
推定対象者から他プレイヤーへの推定発言	推定対象者から他プレイヤーへの役職で, 発言 ESTIMATE したか
推定対象者から他プレイヤーへの投票発言	推定対象者から他プレイヤーへ, 発言 VOTE したか
推定対象者が他プレイヤーを占いたいと発言	推定対象者から他プレイヤーへ, 発言 DIVINATION したか
推定対象者が他プレイヤーを占った結果を発言	推定対象者から他プレイヤーへ, どういう発言 DIVINED したか
推定対象者が他プレイヤーの発言に同意する	推定対象者から他プレイヤーへ, 発言 AGREE したか
推定対象者が他プレイヤーの発言に反対する	推定対象者から他プレイヤーへ, 発言 DISAGREE したか
他プレイヤーから推定対象者への推定発言	他プレイヤーから推定対象者への役職で, 発言 ESTIMATE したか
他プレイヤーから推定対象者への投票発言	他プレイヤーから推定対象者へ, 発言 VOTE したか
他プレイヤーが推定対象者を占いたいと発言	他プレイヤーから推定対象者へ, 発言 DIVINATION したか
他プレイヤーが推定対象者を占った結果を発言	他プレイヤーから推定対象者へ, どういう発言 DIVINED したか
他プレイヤーが推定対象者の発言に同意する	他プレイヤーから推定対象者へ, 発言 AGREE したか
他プレイヤーが推定対象者の発言に反対する	他プレイヤーから推定対象者へ, 発言 DISAGREE したか
他プレイヤーから別の他プレイヤーへの推定発言	他プレイヤーから別の他プレイヤーへの役職で, 発言 ESTIMATE したか
他プレイヤーから別の他プレイヤーへの投票発言	他プレイヤーから別の他プレイヤーへ, 発言 VOTE したか
他プレイヤーが別の他プレイヤーを占いたいと発言	他プレイヤーから別の他プレイヤーへ, 発言 DIVINATION したか
他プレイヤーが別の他プレイヤーを占った結果を発言	他プレイヤーから別の他プレイヤーへ, どういう発言 DIVINED したか
他プレイヤーが別の他プレイヤーの発言に同意する	他プレイヤーから別の他プレイヤーへ, 発言 AGREE したか
他プレイヤーが別の他プレイヤーの発言に反対する	他プレイヤーから別の他プレイヤーへ, 発言 DISAGREE したか

### 参考文献

- [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      坂本 航      尾崎 知伸  
Yuki Omura      Wataru Sakamoto      Tomonobu Ozaki

日本大学 文理学部  
College of Humanities and Sciences, Nihon University

The Werewolf game is a conversation-based multi-player incomplete information game. 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 judgements 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 ensembles.

### 1. はじめに

不完全情報ゲームの一つである人狼ゲームでは、各プレイヤー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、他プレイヤーを騙すための嘘をつく、他プレイヤーの嘘を見抜く、他プレイヤー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。特にプレイヤー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 を用いてプレイヤー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<sup>\*1</sup> (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ー (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言状況や占い・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。

### 3. 推定モデル構築実験

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 inTrees[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

連絡先: 尾崎 知伸, 日本大学 文理学部 情報科学科, 〒156-8550  
東京都世田谷区桜上水 3-25-40, tozaki@chs.nihon-u.ac.jp

\*1 <http://aiwolf.org/4th-aiwolf-contest>

\*2 <https://cran.r-project.org/web/packages/inTrees/index.html>

表 2: 実験結果 : 推定精度

役職推定タスク	ランダムフォレスト			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

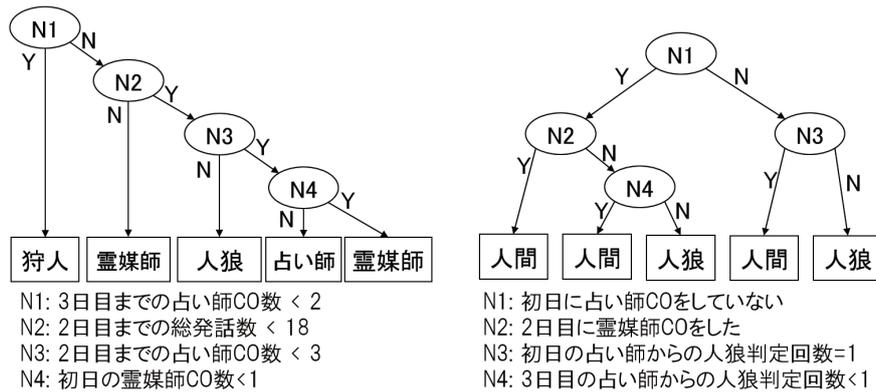


図 1: 得られた決定木 : 役職推定 (左), 陣営推定 (右)

### 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ないことが確認できる。また, 決定木と inTrees 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, inTrees 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

役職判定ルール	
狩人	2 日目に占い師が人間判定した回数 $\leq 1$ & 2 日目にプレイヤーが賛成し高い数 $> 0.5$ & 3 日目までのプレイヤーの総発言数 $> 4.5$
霊媒師	2 日目のプレイヤーの総発言数 $> 17.5$ & 2 日目のプレイヤーが否定された回数 $> 0.5$ & 2 日目と 3 日目のプレイヤーの発言数の差 $> 3.5$
占い師	3 日目に賛成し高い数 $> 0.5$ & 3 日目のプレイヤーの総発言数 $> 3.5$
狩人	1 日目のプレイヤーの総発言数 $\leq 0.5$ & 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
陣営判定ルール	
人間	2 日目のプレイヤーの総発言数 $> 2.5$ & 3 日目に占い師 CO した順序 $\leq 0.5$ & 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 $\leq 0.5$ & 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 $\leq 0.5$ & 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 $\leq 0.5$ & 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 $\leq 0.5$
人間	デフォルト

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

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

- [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ー推定法, 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: プレイヤー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, 大島菜 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言行為タグセットの提案とプレイヤーの行動・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

○Hideki Ohira<sup>1</sup> (1. Nagoya University)

1:50 PM - 2:30 PM

#### [3G3-OS-18a-02] Action Selection based on Somatic Marker Hypothesis

○Chie 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

○Takato 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

○Kazuki 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

○Hideki 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态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 Hypothesis

日永田智絵 \*1 堀井隆斗 \*1 長井隆行 \*1\*2

Chie Hieida Takato Horii Takayuki Nagai

\*1電気通信大学 \*2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ミュラタスクを設計した。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る。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。

## 3. 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に、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

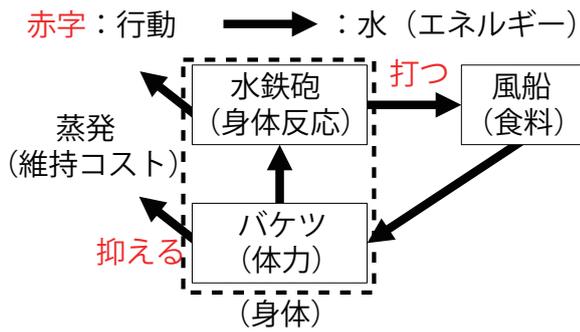


図 1: タスク設計概要

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  $5 \times 5 \times 5$  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 ( $65 \times 65 \times 12$  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。

$$R(t) = C - \|\mathbf{m}(t)\| - \|\mathbf{a}'(t)\|, \quad (1)$$

$R(t)$  は時間  $t$  における報酬値、 $\mathbf{a}(t)$  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、 $\mathbf{a}'(t)$  は  $\mathbf{a}(t)$  に行動後の変化 (例えば風船から水が得られたなど) を加味したものととなる。 $\mathbf{m}(t)$  は時間  $t$  での保つべき基準の値となって

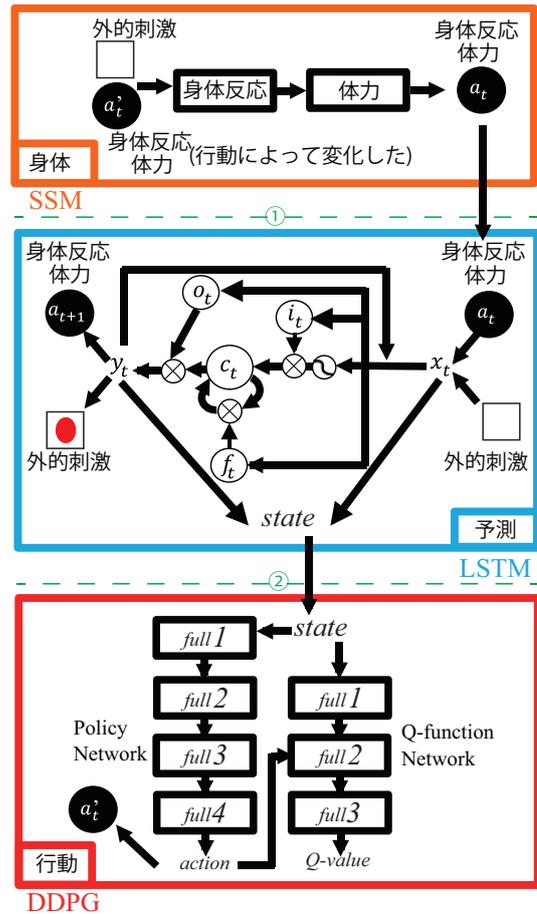


図 2: 実装したネットワーク

おり、本研究では初期値の値  $\mathbf{a}(0)$  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、 $\|\mathbf{a}'(t)\|$  が 0 のとき、 $R(t)$  も 0 とし、 $\mathbf{a}'(t)$  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 が無い条件を 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 が無い条件を 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 20000 epochs 行った。グラフは見やすくするために 50 epochs 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

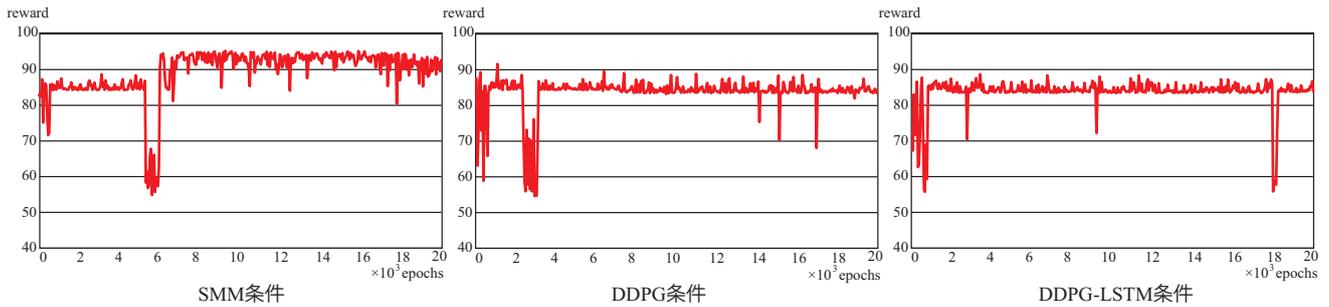


図 3: 学習時の報酬の推移

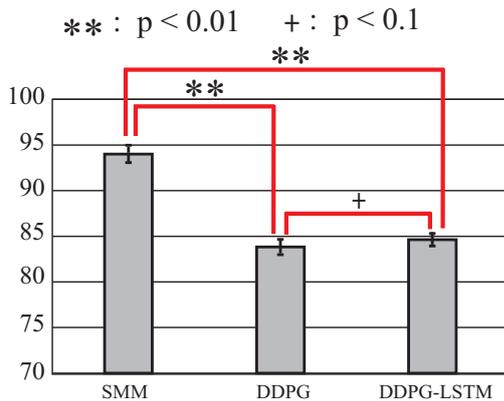


図 4: 学習済みモデルでの報酬平均の比較

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ない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くことがわかる。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。

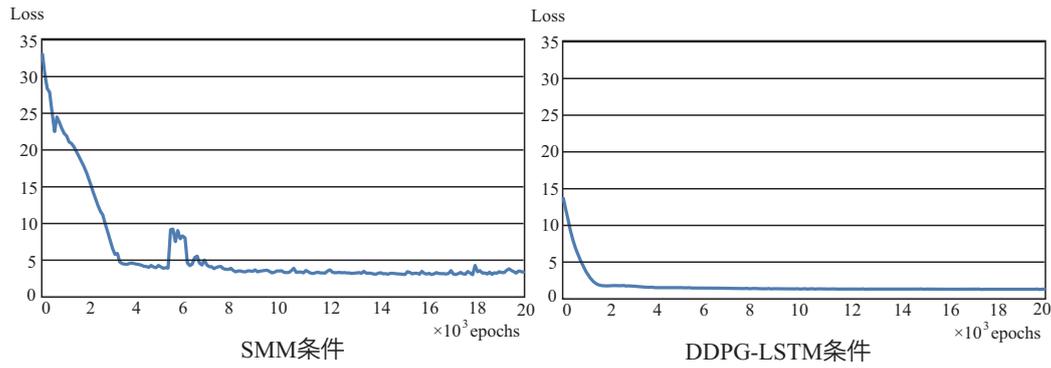


図 5: 学習時の LSTM の Loss の推移

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	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	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	0
		b 群	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1	0	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	1	
	b 群	1	1	1	0	0	0	0	0	1	1	0	1	1	0	1	1	0	1	1	0	1	

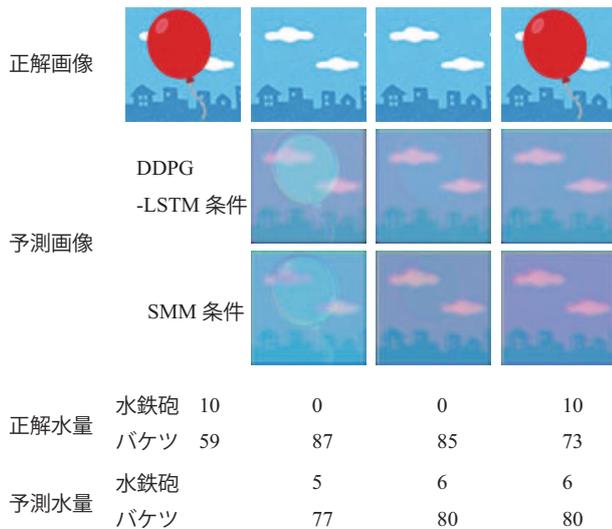


図 6: LSTM による予測の一例

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。

## 参考文献

- [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 personality 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 \*1  
Takato Horii

長井隆行 \*1\*2  
Takayuki Nagai

\*1電気通信大学

The University of Electro-Communications

\*2大阪大学

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 ら [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

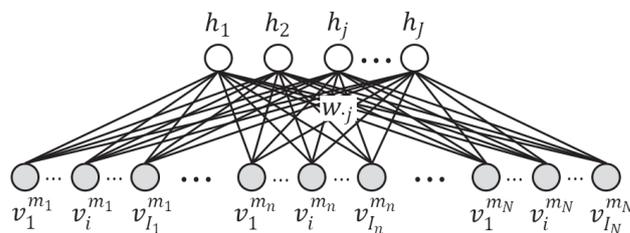


図 1: RBM による多感覚統合モデル

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  $\mathbf{h}$  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  $p(\mathbf{v} = \{v^{m_1}, \dots, v^{m_N}\})$  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  $p(\mathbf{v})$  は次式で表現される。

$$\begin{aligned} p(\mathbf{v}) &= \sum_{\mathbf{h}} p(\mathbf{v}, \mathbf{h}) \\ &= \exp\left(\mathbf{c}^T \mathbf{v} + \sum_{j=1}^J \log(1 + \exp(b_j + \mathbf{W}_{.j} \mathbf{v}))\right) \quad (1) \\ &= \exp(-F(\mathbf{v})) / Z \end{aligned}$$

**Algorithm 1** Active perception based on free-energy minimization on RBM

```

add perceived modality  $m_n$  to set  $M_r$ 
for  $n = 0$  to  $N$  do
  if  $m_n \in M_r$  then
     $\mathbf{v}^{m_n} = \mathbf{v}^{m_n}$ 
  else
     $\mathbf{v}^{m_n} = \mathbf{0}$ 
  end if
   $\mathbf{h} \sim p(\mathbf{h}|\mathbf{v}^{m_1}, \dots, \mathbf{v}^{m_n}, \dots, \mathbf{v}^{m_N})$ 
  for  $n = 1$  to  $N$  do
    if  $m_n \notin M_r$  then
       $\mathbf{v}^{m_n'} \sim p(\mathbf{v}^{m_n'}|\mathbf{h})$ 
       $E_n \leftarrow F(\mathbf{v}^{m_n'})$ 
    end if
  end for
end for
 $n = \operatorname{argmin} E_n$ 
 $M_r \leftarrow M_r \cup m_n$ 

```

$F(\mathbf{v})$  は RBM の自由エネルギーである。以上より、ある情報  $\mathbf{v}$  の自由エネルギーが小さいことは、 $\mathbf{v}$  の発生確率  $p(\mathbf{v})$  が高いことと対応する。

次にある部分観測情報  $\mathbf{v}' = \{\mathbf{0}, \dots, \mathbf{v}^{m_n}, \dots, \mathbf{0}\}$  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  $\mathbf{v}^{m_u}$  は部分観測情報  $\mathbf{v}'$  から推定された  $\mathbf{h}$  を介して再構成できることから、次のように予測される。

$$\begin{aligned} \mathbf{h} &\sim p(\mathbf{h}|\mathbf{v}') \\ \mathbf{v}^{m_u} &\sim p(\mathbf{v}^{m_u}|\mathbf{h}) \end{aligned} \quad (2)$$

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 (Random) 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。

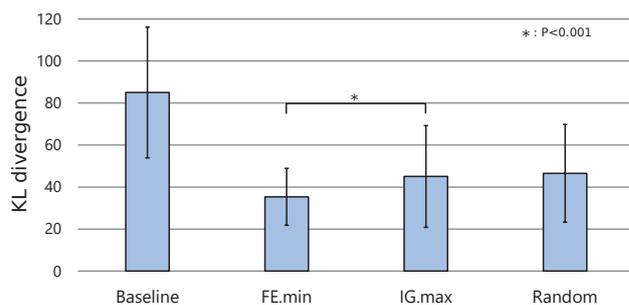


図 2: 各能動的知覚手法による感情状態推定に対する評価値

## 4. おわりに

人の脳情報処理の基本原則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。

## 参考文献

- [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\*<sup>1</sup> 森田純哉\*<sup>1</sup> 野村太輝\*<sup>2</sup> 平山高嗣\*<sup>3</sup> 榎堀優\*<sup>3</sup> 間瀬健二\*<sup>3</sup>  
 Kazuki Sakuma Junya Morita Taiki Nomura Takatsugu Hirayama Yu Enokibori Kenji Mase

\*<sup>1</sup>静岡大学情報学部

Faculty of Informatics, Shizuoka University

\*<sup>2</sup>名古屋大学大学院情報科学研究科

Graduate School of Information Science, Nagoya University

\*<sup>2</sup>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 [Ramprasaath 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。

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

### 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

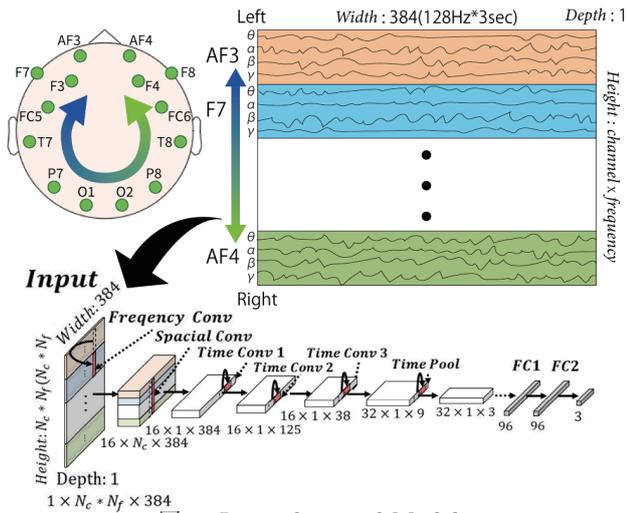


図 1: Input data and Model

表 1: Parameters of CNN

Type	Structure
Input	$Depth \times Height(N_f * N_c) \times Width(Times)$
Frequency Conv	Kernel: $16 \times N_f \times 1$ , Stride: $N_f \times 1$ , pad=0, elu
Spatial Conv	Kernel: $16 \times N_c \times 1$ , Stride: $N_c \times 1$ , 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
FC 2	Classes, Softmax

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 学習フェーズ

##### 3.1.1 入力特徴

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。

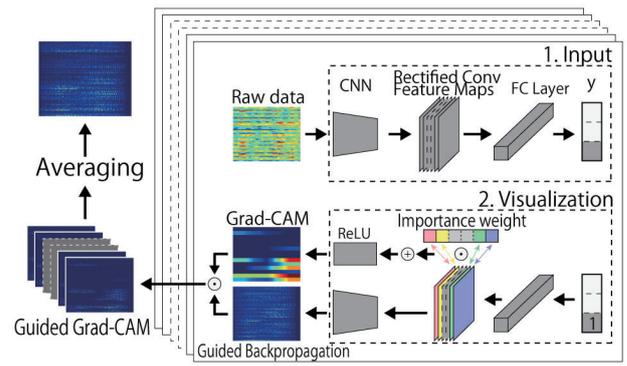


図 2: Guided Grad-CAM Procedure

##### 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 Backpropagation 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 (不快と覚醒度) と記憶の主観的評価を行わせた。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) サンプル周波数 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  $\times$  3sec)、Height=56 (4 周波数帯域  $\times$  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 [Schirmer 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态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。

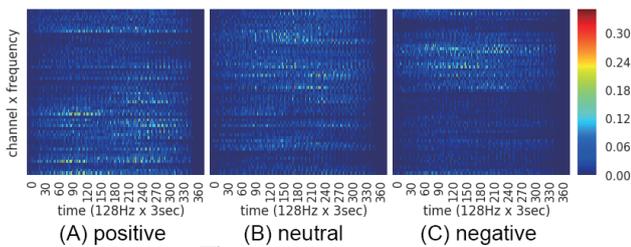


図 3: Average of GGC

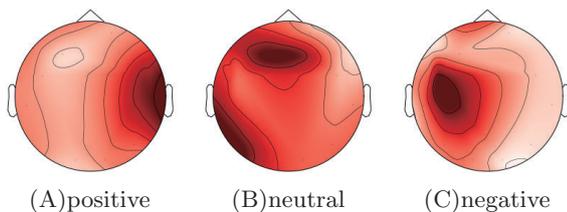


図 4: Topomap of GGC ( $\alpha$  band)

### 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。

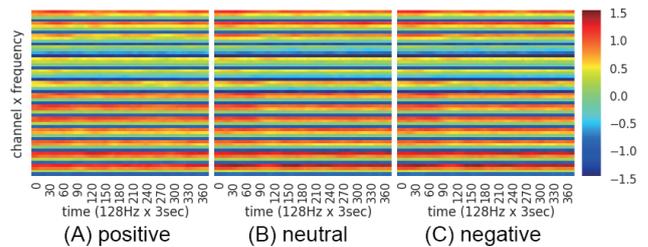


図 5: Average of RAW data

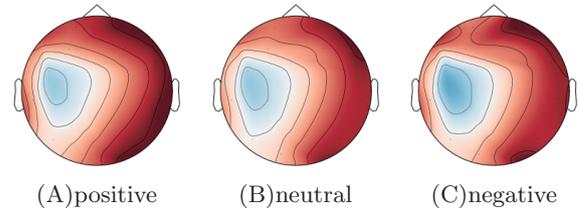


図 6: Average topomap of RAW data ( $\alpha$  band)

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:  $t(32) = -4.57$ ,  $p < 0.01$ )。 .

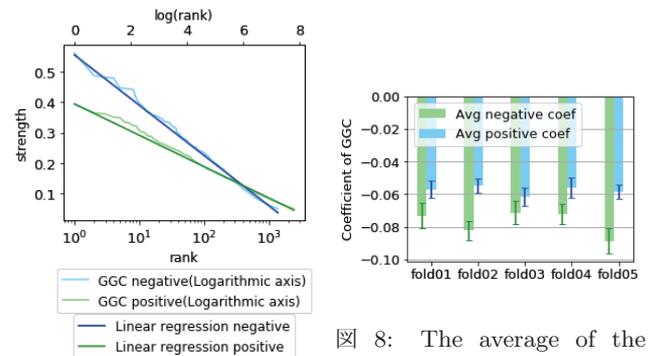


図 8: The average of the localities of each fold

図 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見られ、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。

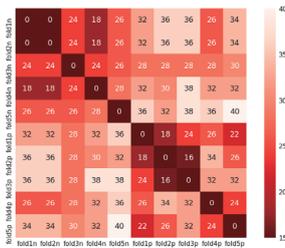


図9: Cosine similarity between Guided Grad-CAM in each fold



図10: Difference in hash value of Guided Grad-CAM in each fold

## 6. 考察

快不快の主観的状态を識別する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られる。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。

## 参考文献

- [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)
- [Schirrmester 17] Schirrmester, 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)

**[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**○Kazuya 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**○Takahisa 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**○Kazumi 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**○Masahiro 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**○Mai 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<sup>\*1</sup>  
Kazuya MIO石野 亜耶<sup>\*2</sup>  
Aya ISHINO目良 和也<sup>\*1</sup>  
Kazuya MERA竹澤 寿幸<sup>\*1</sup>  
Toshiyuki TAKEZAWA<sup>\*1</sup> 広島市立大学大学院情報科学研究科  
Graduate School of Information Sciences, Hiroshima City University<sup>\*2</sup> 広島経済大学メディアビジネス学部  
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 F-measure (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、発話の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。

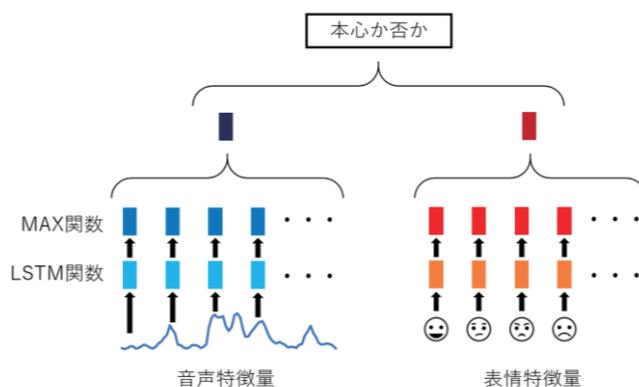


図 1 本心でない発話の自動検出手法のイメージ図

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 *suppressed 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  $v_{voice,2}$ ,  $v_{face,2}$  を得る。 $v_{voice,2}$  と  $v_{face,2}$  を連結後、線形関数を適用し、2 次元のベクトル  $v_{voice+face}$  へ変換する。最後に、 $v_{voice+face}$  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。

## 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。



図 2 データ収集に用いた画像

画像を見て、例えば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 (正例)	本心である発話 (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れる。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。

## 参考文献

- [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.

表 2 実験結果

手法	台詞固定			台詞自由		
	精度	再現率	F 値	精度	再現率	F 値
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

# 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  
Takahisa Uchida

港隆史 \*1  
Takashi Minato

中村泰 \*2  
Yutaka Nakamura

吉川雄一郎 \*2  
Yuichiro Yoshikawa

石黒浩 \*1\*2  
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

\*2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できるロボットは、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  $M \times N$  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。

		属性		
		メニュー	味	雰囲気
アイテム	レストランA	1	1	-1
	レストランB	1	1	0
	レストランC			1

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  $M \times M$  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。

		アイテム		
		レストランA	レストランB	レストランC
アイテム	レストランA	1	0	0
	レストランB	0	1	
	レストランC	0		1

メニューの類似表

		アイテム		
		レストランA	レストランB	レストランC
アイテム	レストランA	1	0	0
	レストランB	0	1	
	レストランC	0		1

味の類似表

		アイテム		
		レストランA	レストランB	レストランC
アイテム	レストランA	1	0	0
	レストランB	0	1	
	レストランC	0		1

雰囲気の類似表

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  $\langle \rangle$  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。

		属性		
		メニュー	味	雰囲気
自分の選好表	レストランA	1	1	-1
	レストランB	1	1	1
	レストランC	-1	1	-1

		属性		
		メニュー	味	雰囲気
相手の選好表	レストランA			-1
	レストランB			1
	レストランC			

雰囲気に関して類似度 = 2/3

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）になったときに、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。

		属性		
		メニュー	味	雰囲気
選好表 (相手)	レストランA	-1	1	-1
	レストランB	1	1	1
	レストランC	1		

		アイテム		
		マクドナルド	モスバーガー	桜
メニューの類似表 (相手)	レストランA	1	0	0
	レストランB	0	1	$\langle -1 \rangle$
	レストランC	0	$\langle -1 \rangle$	1

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。

	メニュー	味	雰囲気
レストランA			-1
レストランB			
レストランC			<-1>

相手(自分)の選好表

	マクドナルド	モスバーガー	ロイヤルリア
レストランA	1	0	1
レストランB	0	1	0
レストランC	1	0	1

相手(自分)の雰囲気の類似表

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。

	レストランA	レストランB	レストランC
レストランA	1	0	<-1>
レストランB	0	1	
レストランC	<-1>		1

メニューの類似表(自分)

	レストランA	レストランB	レストランC
レストランA	1		1
レストランB		1	
レストランC	1		1

メニューの類似表(相手)

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、属性を追加する発話

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のメニューは好きですか?」	例)「それじゃあ、Aのメニューは好きですよ?」
類似性	例)「Aの雰囲気はBに似てますか?」	例)「それじゃあ、AとBの雰囲気は似てますよ?」

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ものでは?【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。レストランBとメニューが似てないだったら【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。  
 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。

## 参考文献

- [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. 210–217 ACM 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-162.1 (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

\*<sup>1</sup>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に分かれる。ロボットがした行動も好みによっては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

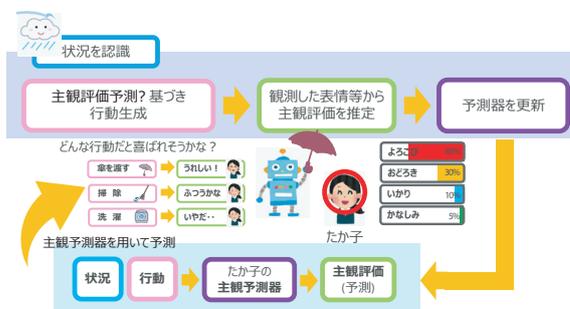


図 1: 実際の観測表情を利用した感情推定結果に基づくロボット行動の個人適合手法

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。

## 3. 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、してもよい行動を選択する頻度を高める。

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

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 (ロボット動作中の平均)	声かけ (自然言語)・単純動作	曜日・時間帯・天気・ 忙しさ・体勢	[Kumagai 14]
インタラクティブ メディアアート	表情 (ロボット動作中の 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]

### 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。動作はシンボルの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

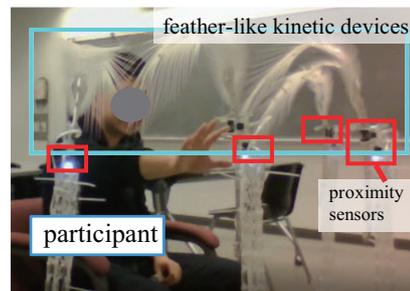


図 2: 実験システムと実験参加者とのインタラクションの様子。手を近づけると動作を開始する。[Kumagai 18]

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 に取り付けられ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。

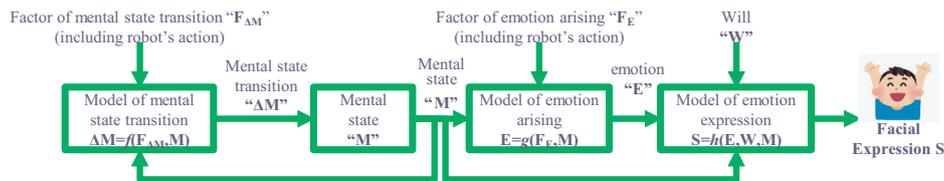


図 3: 情動・表情・心的状態・因子の関係図 [Ekman 75][Zajonc 89][Ekman 99][Forgas 92][Ekman 71]

## 5. 外部から直接観測困難な心的状態の推定

### 5.1 心的状態を因子を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。

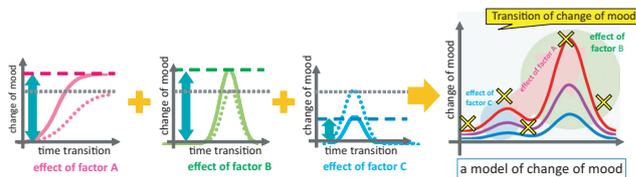


図 4: 非線形関数の重み付和による心的状態推定モデルの個人適合 [Kumagai 16]

## 6. 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に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

表情の扱いはロボット行動の意味的特徴や動作の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、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ー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。

## 参考文献

[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 Review*, 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

\*<sup>1</sup> 玉川大学大学院 工学研究科 \*<sup>2</sup> 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。その典型例に对人インタラクションがある。对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对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リックな処理を 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リック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、確率のかつ並列的に探索する直観的推論を相想起により、意識の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。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。

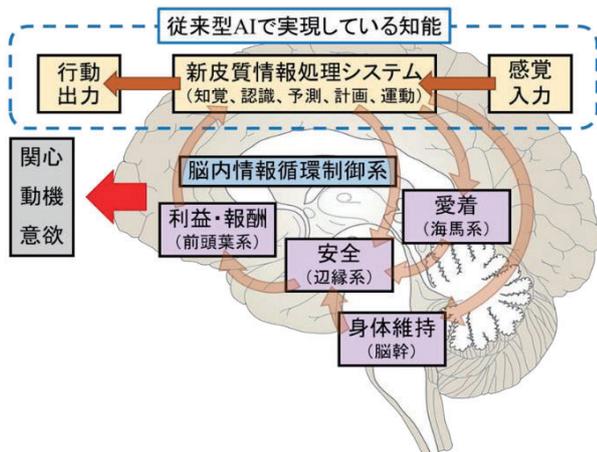


図1 感情＝価値計算システム仮説の概要

## 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の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

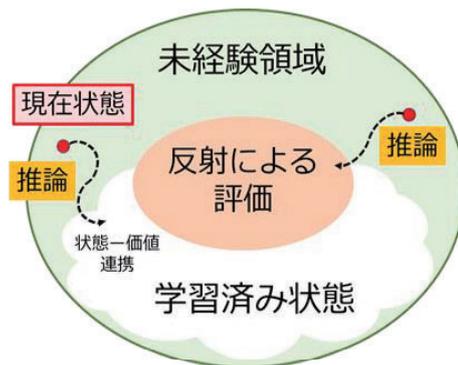


図2 推論による価値探索の位置づけ

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リックな方式である[Russel 2008]。また、我々はシンボリック推論とは別に、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ものと考えられる。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るか、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、シンボリック
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

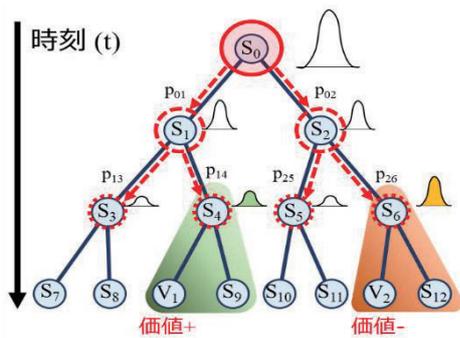


図3 推論の処理過程イメージ

## 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、複数の記憶事項の記録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、 $x_t$  は相互想起行列  $W^e$  にかけ合わせることで次の時刻の状態  $x_{t+1}$  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

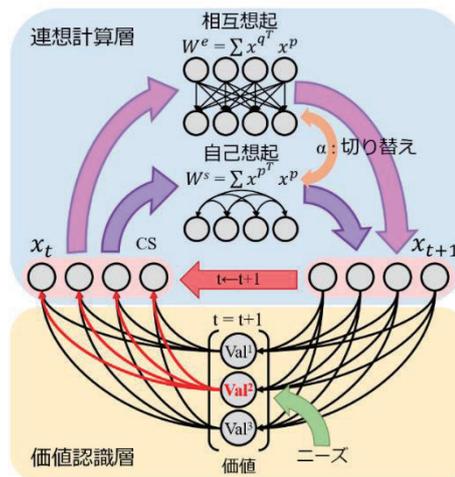


図4 推論システム全体像

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。

$$x_{t+1} = \alpha (\sum_q Pr(x_{t+1}^q | x_t^p) W_{pq}^e) x_t^c + (1 - \alpha) \sum_q W_{pq}^s x_t^c \quad \dots (1)$$

(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 ( $W_{pq}^e$ ) を作成し、入力ベクトル ( $x_t^c$ ) 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

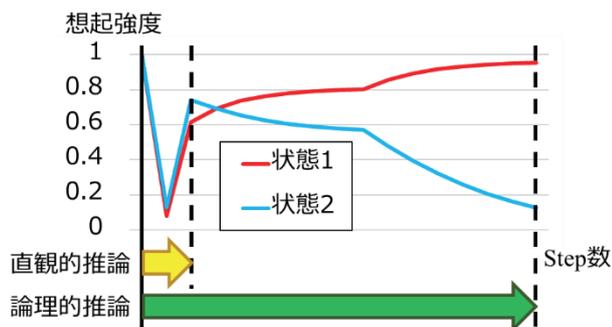


図5 連想記憶を用いた2つの推論の違い

シ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録する。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。

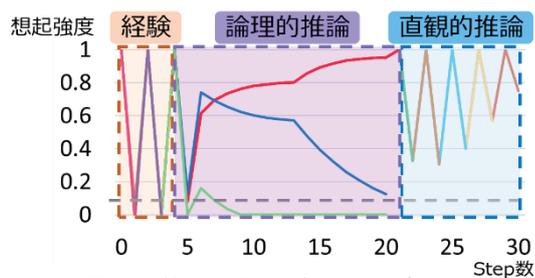


図6 推論-強化学習-反射を

組み合わせたシミュレーションの結果

## 参考文献

- [ヴァンター 2017] エヤル・ヴァンター: 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・ブックス, 2012
- [Evans 2009] Jonathan St. B. T. Evans et al.: How many dual-process 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ymbol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。现阶段では、構文解析に適した形に手直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、両方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感じた時、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。

$$Joy_{f(d)}^i \phi := Des_d^i \phi \wedge Bel^i \phi \quad (1)$$

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、 $Des_d^i \phi$  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」、 $Bel^i \phi$  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。

$$Guess\_Joy_{f(d)}^{i,j} \phi := Bel^i Des_d^j \phi \wedge Bel^i Bel^j \phi \quad (2)$$

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、 $Bel^i Des_d^j \phi$  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」、 $Bel^i Bel^j \phi$  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。

$$Guess\_Joy_{f(d)}^{i,j} \phi \equiv Bel^i (Des_d^j \phi \wedge Bel^j \phi) \quad (3)$$

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』ことをエージェント *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  $Bel^i$  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] 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、感情が生起する。

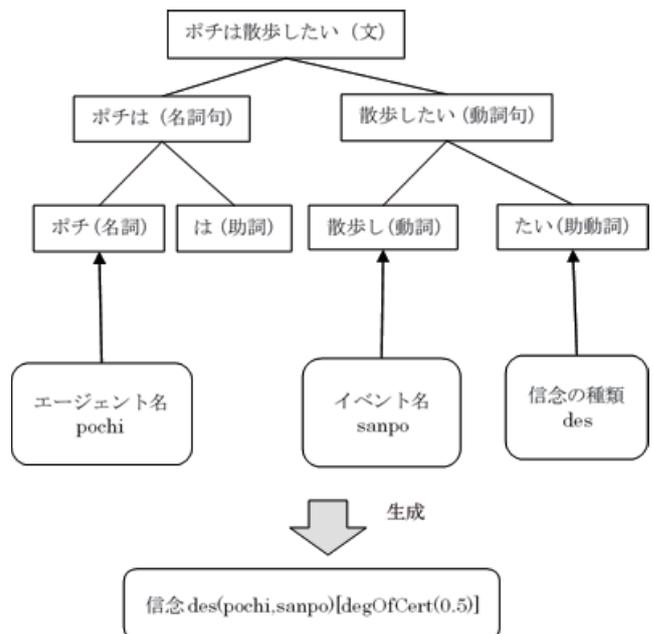


図 1: 構文木および生成される信念

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ない)

$bel(michan, find)$   
(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  
 → `bel(haha,des(michan,otsukai)[degOfCert(0.5)])`  
 みいちゃんは転んでしまった  
 → `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  
 → `bel(michan,otosu)`  
   `des(michan,not otosu)[degOfCert(0.5)]`  
 みいちゃんはお金を探した  
 → `bel(michan,sagasu)`  
   `des(michan,find)[degOfCert(0.5)]`  
 みいちゃんはお金を見つけた  
 → `bel(michan,find)`  
 みいちゃんはお母さんにお使いを伝えた  
 → `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、生じた、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っている。

## 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。

## 参考文献

- [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 Cognitive 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

○Taichi 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

○Shuuhei 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

○Haruka 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

○Naoki 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、効率化が行き切れていない。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

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ているが、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

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

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>  
Katsuhiko Noguchi

中矢 誠\*<sup>2</sup>  
Makoto Nakaya

\*<sup>1</sup> 漫画家  
Comic Artist

\*<sup>2</sup> 株式会社アキュトラス  
Aqutras 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、エンターテイン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、エンターテイン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た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合わせ構造を持つことが多い。

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ーについては、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。

$$P = -\cos(t) \quad (1)$$

$$P(t) = \begin{cases} \text{日常,} & P < 0 \\ \text{日常と非日常の境界線上,} & P = 0 \\ \text{非日常,} & P > 0 \end{cases} \quad (2)$$

$$P' = \sin(t) \quad (3)$$

#### 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 $\pm\sigma$ 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。 $P$ 、 $P'$ と $P'_{allow}$ 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搜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られる。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。

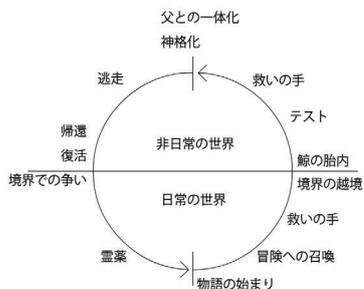


図1 ヒーローズジャーニーの概念図

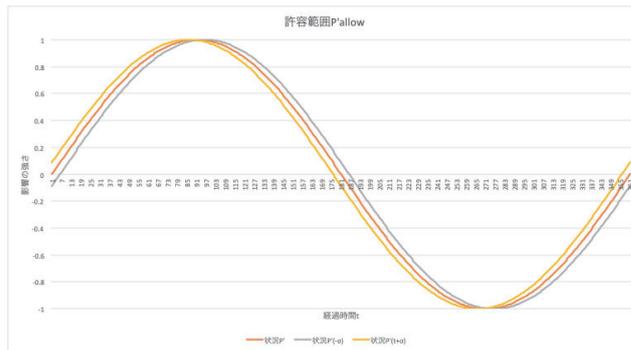


図3 状況 $P'$ の許容範囲

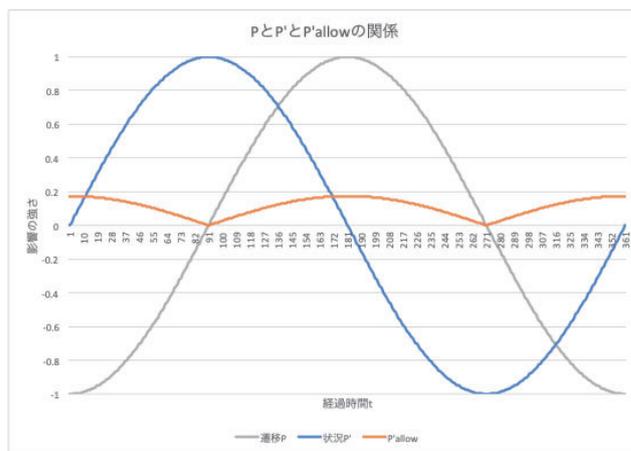


図4 .  $P$ 、 $P'$ と $P'_{allow}$ の関係

参考文献

- [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.

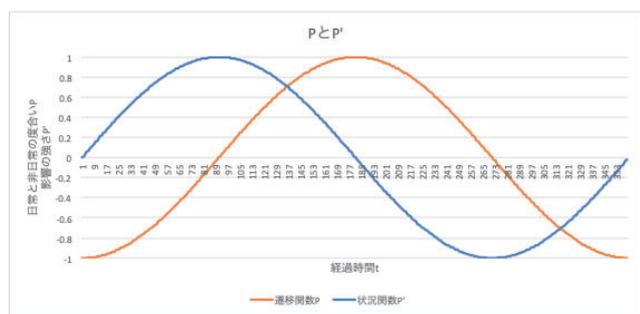


図2 主人公の遷移関数と状況関数

# 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\*<sup>1</sup>  
Shuuhei Toyosawa

村井源\*<sup>1</sup>  
Murai Hajime

\*<sup>1</sup> 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られる。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。

基本的な物語のマイ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き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組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し、可変事項の前に遭遇する場合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し、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し、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ふ。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の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。

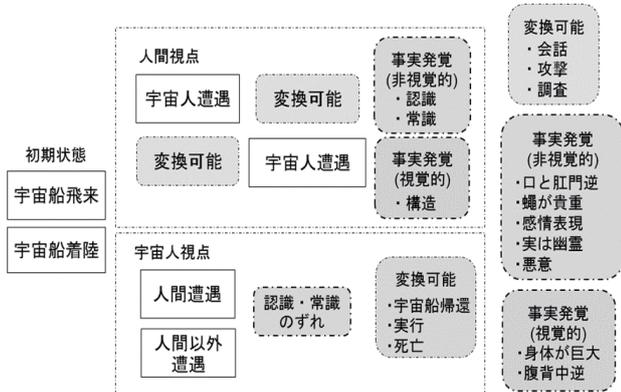


図 1 遭遇パターン

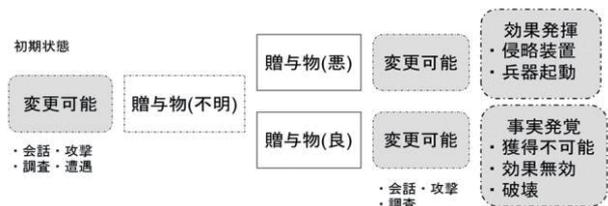


図 2 贈り物パターン

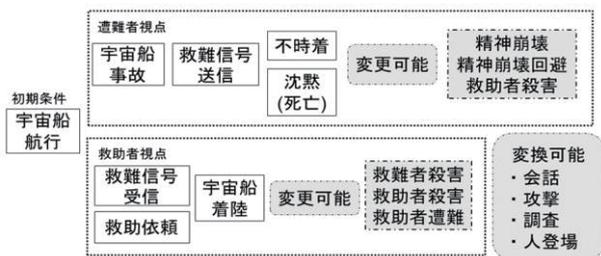


図 3 沈黙・遭難パターン

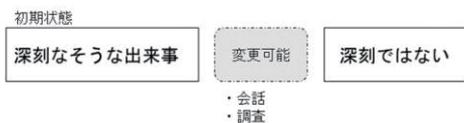


図 4 間抜けオチパターン

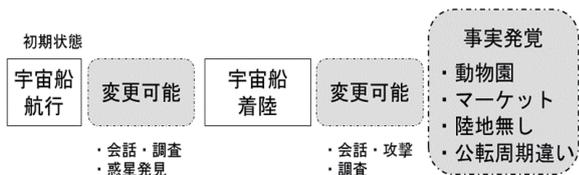


図 5 惑星パターン



図 6 カニバリズムパターン

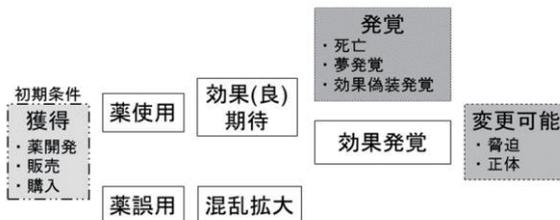


図 7 薬効果明示パターン



図 7 薬効果不明パターン

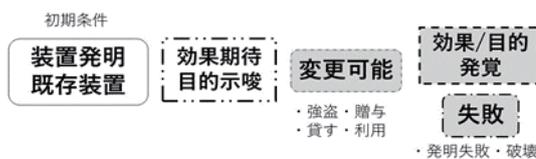


図 9 装置効果明示パターン

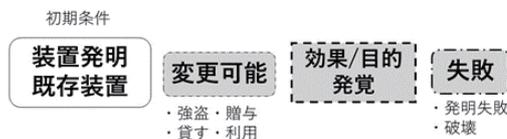


図 10 装置効果不明パターン

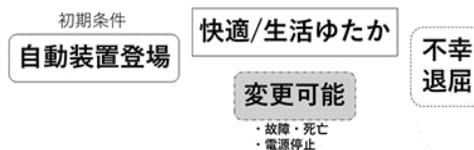


図 11 自動装置パターン

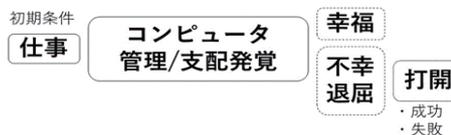


図 12 コンピュータパターン

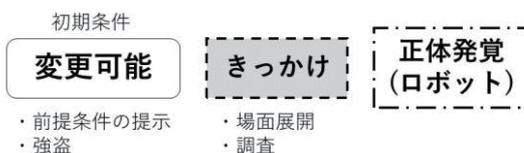


図 13 正体ロボットパターン



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
ロボットは命がない
ロボットは痛覚がない
ロボットは複製可能
ロボットは生物ではない
ロボットは合理的

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れる。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な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はいくつか見られた。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。

## 参考文献

- [工藤 2011] 工藤彰, 村井源, 往住彰文: "計量分析による村上春樹長篇の関係性と歴史の変遷", 情報知識学会誌, Vol.21, No.1, pp.18-36, 2011.
- [佐藤 2009] 佐藤知恵, 村井源, 往住彰文: "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 Annual 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, 往住 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, pp.1-5, 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 -一〇〇編ショート・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\*<sup>1</sup>      上野 未貴      井佐原 均  
Haruka Takahashi      Miki Ueno      Isahara Hitoshi

\*<sup>1</sup>豊橋技術科学大学  
Toyohashi University of Technology

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

### 2.1 ストーリー創作支援

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 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ルして収集した。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 Vector 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ヶ丘 1-1, takahashi@lang.cs.tut.ac.jp

\*<sup>1</sup> NAIST Japanese Dictionary, <http://naist-jdic.osdn.jp/>

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

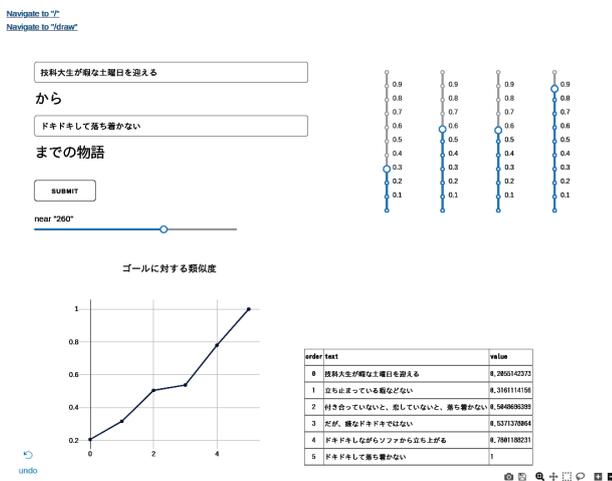


図 1: ストーリー生成システムのユーザインタフェース

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 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。
- 2)  $\mathbf{R}_s$  の末尾の文に対し近傍  $n$  の文を取得し、  $r'_g$  との類似度の高い順にソートした配列  $\mathbf{A}_s = \{a_1, a_2, \dots, a_n\}$  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。
- 4)  $\mathbf{A}_s$  に  $r'_g$  が存在すれば、  $r'_g$  と  $r_g$  を  $\mathbf{R}_s$  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  $\mathbf{R}_s$  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。

\*2 Gensim, <https://radimrehurek.com/gensim/>\*3 Dash by plotly, <https://plot.ly/products/dash/>

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がない	0.316
2	付き合っていないと、恋していないと、落ち着かない	0.505
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がる	0.780
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

入力	近傍	文数	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
1	50	9	0	1	2	1
	100	7	0	1	2	1
	300	7	0	2	2	0
2	50	29	0	0	1	3
	100	9	0	1	2	1
	300	11	0	0	4	0
3	50	7	0	0	3	1
	100	6	1	1	2	0
	300	6	0	0	2	2
4	50	7	1	2	1	0
	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

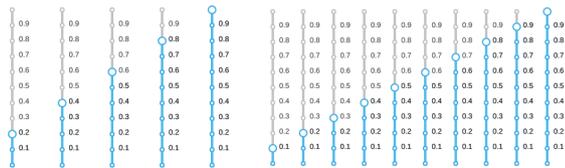


図 2: 類似度調節 5 文

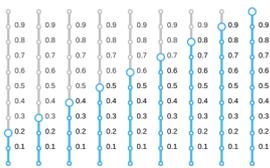


図 3: 類似度調節 10 文

表 4: ランダムとの比較結果

パターン	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、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思われる。

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

対象	変更前	変更後
空白	削除	文の終端として、そこで文章を分割
鉤括弧 (「」)	読点に置換	文の終端として、そこで文章を分割
全角記号	処理なし	感嘆符 (!), 疑問符 (?), 二重鉤括弧 (『』) 以外を削除

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。

表 6: 生成されたストーリーの例 2

	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 7: 実験 2 のアンケート結果

入力	近傍	文数	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
1	50	7	0	2	2	0
	100	6	0	3	1	0
	300	5	0	0	3	1
2	50	10	0	0	2	2
	100	10	0	3	1	0
	300	7	2	1	1	0
3	50	10	0	1	1	2
	100	6	0	2	2	0
	300	6	1	1	2	0
4	50	10	0	0	2	2
	100	10	0	0	2	2
	300	5	0	2	1	1

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、この入力が入力の目から見て明らかに繋がりかけの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い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 (グラント番号:JPMJPR17U4) の支援による。

## 参考文献

- [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

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 (駒) 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

連絡先: 森 直樹, 大阪府立大学, mori@cs.osakafu-u.ac.jp

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ない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.

### 3. 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,  $\text{com}:[n,m]$  で表す.

台詞例:

$\text{com}:[1,2]$

(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:

$\text{com}:[1,2,3]$

(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,  $\text{com}:[n,m][s,t]$  と表す.

台詞例:

$\text{com}:[1,2][3,4]$

(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 「彼女さえできれば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  $\text{sum}:[n,m]$  および  $\text{sep}:[n]$  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:

$\text{sum}:[n,n+1]$

( $n$  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:

$\text{sep}:[n]$

( $n$  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:

$\text{sum}:[n,n+1]$  (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 同値関係

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

一般的に, 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  $S_i$  における共通部分を

$$\bigcap_i S_i \quad (1)$$

と表現する。このとき各ストーリーは以下で表現できる。

$$S_i = \{s_{i,1}, s_{i,2}, s_{i,3}, s_{i,4}\} \quad (2)$$

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ください」  
 (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 「困ったなあ… 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ください」  
 (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 「研究費厳しいけどなんとか学生を学会に行かせてやりたいな」  
 (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な」  
 (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な」  
 (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

一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 なんだ？」  
 (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。

## 参考文献

- [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 Ishihara, 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)

上野 未貴 (豊橋技術科学大学)、森 直樹 (大阪府立大学)

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 Dialogue Contents Circulation

Masaki Mori<sup>1</sup>, O Akinobu 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 Artificial Intelligence

OMiki Ueno<sup>1</sup> (1. Toyohashi University of Technology)

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 Technology, 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 scheme 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（クリエイター）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ーへ積極的に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、それをクリエイター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、クリエイター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。



図 1: 音声対話コンテンツの循環系

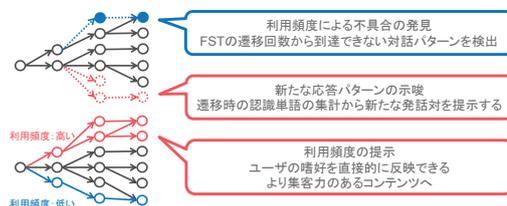


図 2: 対話シナリオ利用統計からのフィードバック

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ーへ強くフィードバックする仕組みが重要であると考えられる。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。

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

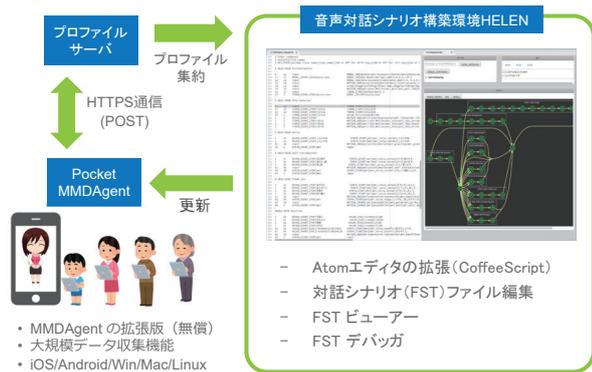


図 3: 提案システムの全体像

### 3.1 対話プロフィールからのフィードバック

図 2 に、対話プロフィー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 対話プロフィールの自動収集

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、編集時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<sup>\*1</sup> 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ィール情報を集計・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ィー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った実験を行った。まずプロフィールなしの状態ですべての課題を行い、次に事前実験で収集したプロフィー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。

\*1 近日中に GitHub にて公開予定

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

プロフィー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クリエイター（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った実験を行った。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、コンテンツ制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ィー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。

## 参考文献

- [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.

## 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 \*1

Daichi Ando

\*1 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 internalized 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・記述しやすいとすることができる。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

れになりのもので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。

### 3. 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、ギターの場合や 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ズングの基礎能力を有している。また作曲を行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でまとめて提示し、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 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)

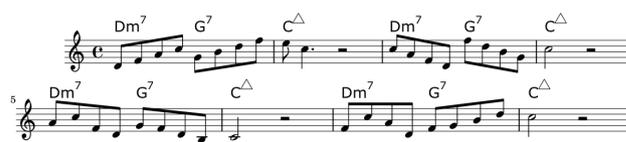


図 1: 練習用として指示された、または著者自身が考えた 2-5-1 のコードトーンアルペジオフレーズ。

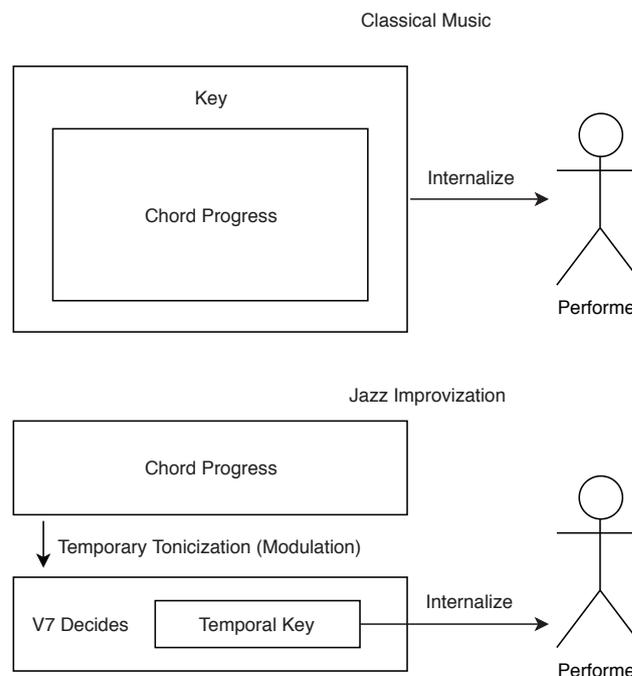


図 2: 著者の中でのクラシックとジャズの調性の把握感覚の違い。クラシックの和声進行は調・キーに内包されているのに対して、ジャズ即興演奏の場合はコード進行の中の属七 (図中「V7」) が部分転調の調・キーを生成しているイメージ。クラシックとジャズでは五線譜上での表現に差がないのに、演奏時の著者の「認識」もしくは「認知」は明らかに異なっている。

##### 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く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うと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く。

#### 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ズングの発想が、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ウ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ブティ」だとするならば、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う、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、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的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。

## 参考文献

- [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・ディエニエー著, シンフォニア (1986)
- [Biles 94] Biles, J.: GenJam: A genetic algorithm for generating 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-Evolution 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る、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

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ァ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、既存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る、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

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

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要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

ァ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—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、多くの仕事はこれらの 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。ファ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の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多い。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ことが多い。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、人工知能だけ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

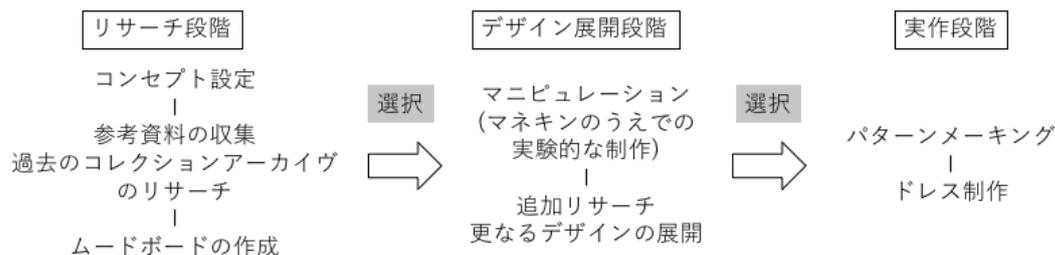


図2 ファッションデザインにおける一般的な制作プロセス

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。

## 参考文献

- [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      相澤 清晴  
Koki Tsubota    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.

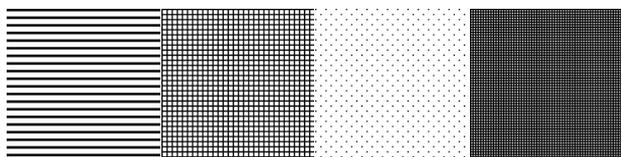


図 1: トーンの例. トーンには特有のパターンが存在する.

## 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るため人手が必要となる。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 conditional 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。

## 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は、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。

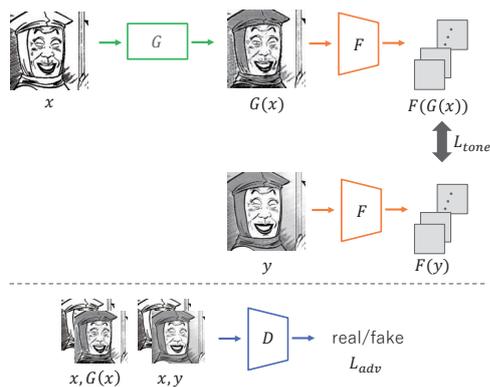


図 2: 手法概要. ©やまだ 浩一

### 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

$$\mathcal{L}_{adv}(G, D) = \mathbb{E}_{x,y} [\log D(x, y)] + \mathbb{E}_{x,y} [\log (1 - D(x, G(x)))], \quad (1)$$

を導入している。また、タスク依存の損失関数としては  $L_1$  loss を用いている。 $L_1$  loss は以下の式で定められる。

$$\mathcal{L}_1(G) = \mathbb{E}_{x,y} [\|y - G(x)\|_1]. \quad (2)$$

全体の損失関数としては、この両式を組み合わせた、

$$\mathcal{L}(G, D) = \mathcal{L}_{adv}(G, D) + \lambda \mathcal{L}_1(G), \quad (3)$$

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。

$$G^* = \arg \min_G \max_D \mathcal{L}(G, D). \quad (4)$$

しかし、前述したように、タスク依存の損失関数として  $L_1$  を用いた場合は、トーンのパターン学習が難しい。

### 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、

$$\mathcal{L}_{tone}(G) = \mathbb{E}_{x,y} [\|F(y) - F(G(x))\|_1], \quad (5)$$

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  $\mathcal{L}_{tone}$  を導入した場合、全体の損失関数は以下の式で表される。

$$\mathcal{L}(G, D) = \mathcal{L}_{adv}(G, D) + \lambda_{tone} \mathcal{L}_{tone}(G). \quad (6)$$

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

図 3: 学習データの例。左側が“留”，右側が“篠原かもき”。  
©やまだ 浩一 ©ふくやま けいこ

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 U-net [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

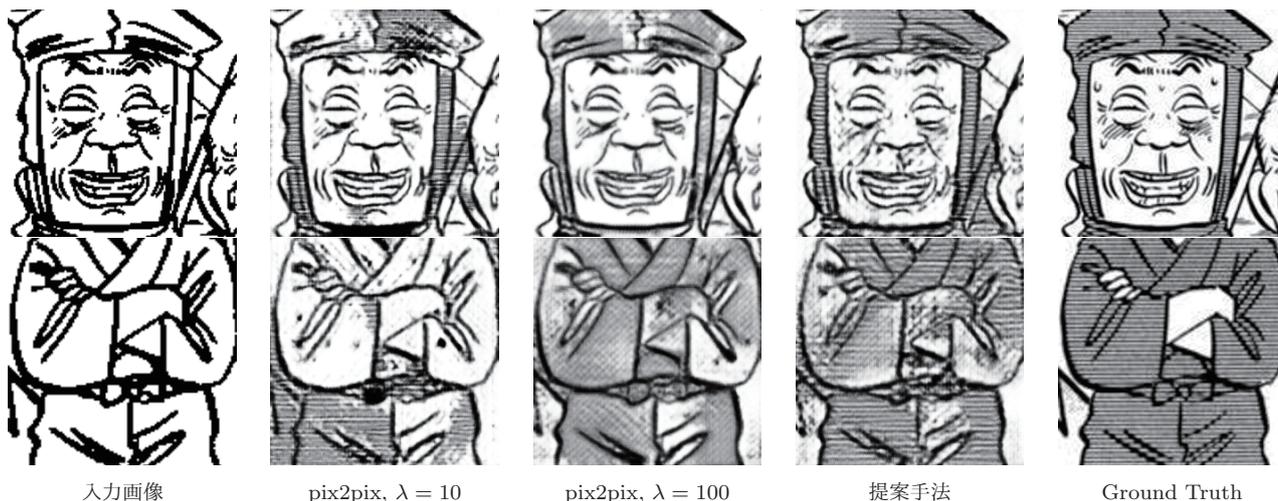


図 4: “留”での実験結果. ©やまだ 浩一

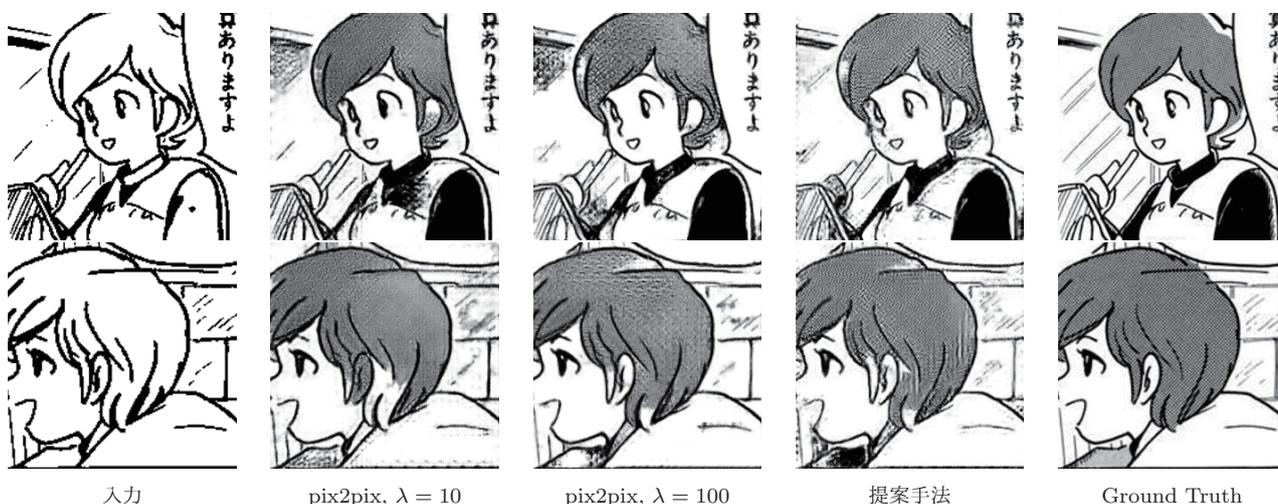


図 5: “篠原かもき”での実験結果. ©ふくやま けいこ

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。

## 参考文献

- [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 Conference 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 of 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

\*1 《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](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ーの感情である。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ーの感情識別 [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ーの感情を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種類の構造の識別タスク [31] を定義した。

#### 多様性識別:

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、コマの多様性識別 [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、多様性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\*2。

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。

\*2 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>

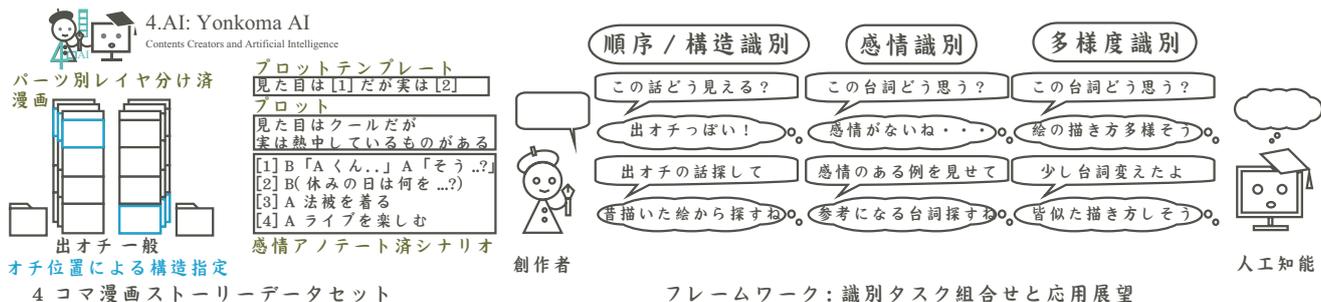


図 1: 4コマ漫画ストーリーデータセットおよびフレームワークの概要



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と。
- 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と。

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もある。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

表題の研究に関わった方々、特に本稿の4章の研究に関わっていた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(グラント番号: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ジタルマンガのアクセスと制作の支援—デ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—, 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, Sketch-based 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 auto-encoder 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] Kiyohito 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] コミ 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次元キャラクター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

○Rino 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

○Mingchuan 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

○Satoka 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

○Kentaro 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

○Tsuneo 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  
Rino Urushihara小林 一郎 \*1  
Ichiro Kobayashi山口 裕人 \*2\*3  
Hiroto Yamaguchi中井 智也 \*2\*3  
Tomoya Nakai西本 伸志 \*2\*3  
Shinji Nishimoto\*1お茶の水女子大学  
Ochanomizu University\*2情報通信研究機構 脳情報通信融合研究センター  
National Institute of Information and Communications Technology\*3大阪大学  
Osaka University

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。

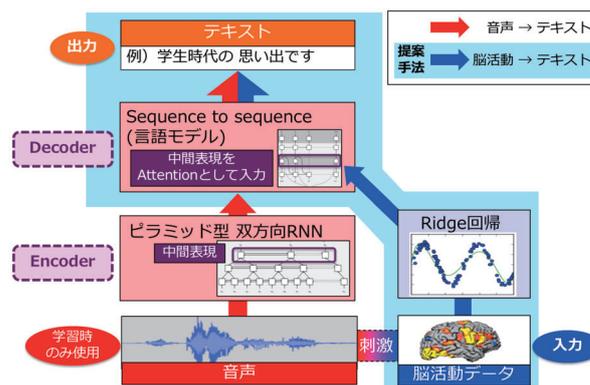


図 1: 本研究の概要図

## 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 (Phonetic Transcription) を用い, 発音されている文字に start-of-sentence (sos) と end-of-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捗を確認し, 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

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.

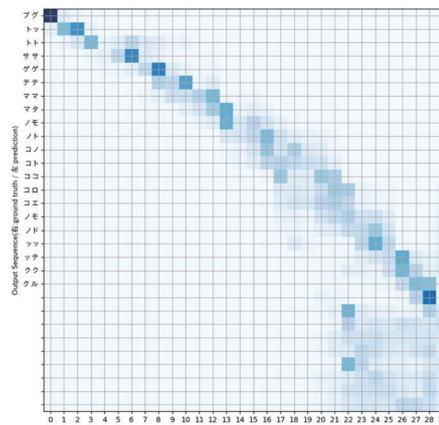


図 2: 実験 1 attention の可視化

**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  $96 \times 96 \times 72$  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

\*1 [https://github.com/thomasschmied/Speech\\_Recognition\\_with\\_Tensorflow](https://github.com/thomasschmied/Speech_Recognition_with_Tensorflow)

表 1: 各パラメータ設定 (詳細)

	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 × 70 epochs	100,938 sample (9,841sample を元に線形補間し増強)
アルゴリズム	Adam	Ridge 回帰
学習に関するパラメータ	学習率: 0.00001	L2 正則化項: 1.0
隠れ層次元	入力: 494 次元 Encoder 2 層: 全て 450 次元 Decoder 2 層: 全て 450 次元 Embedding: 10 次元 出力: 84 次元	Attention となる中間表現: 62,552 次元 - 900 次元  RNN の隠れ層: 62,552 次元 - 1800 次元
誤差関数	交差エントロピー	
その他	Cyclic Learning Rate Max 学習率: 0.00003 Step size: 700	

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
トコブンデハ	トコブンデハ
コノヨーニ	コノヨーニ
マチガウカノセーガ アリアスノデ	チチカカノノー ガガアリアマステ
編集距離のマクロ平均: 11.3 (平均文字数: 21.8)	

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 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

表 5: テキスト生成実験結果 (生成例)

正解	脳活動から生成 (4 秒)	脳活動から生成 (4,5,6 秒)	音声から生成
テーマワ	エー	ウーカカカ	テーマワ
アルト	デテ	デデン	アルト
マダ	イイ	ネネ	マダ
ヤッパリ	ノノ	エエ	ヤッパリ

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察していきたい。

### 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) そ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

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 vo-

cabulary 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\*<sup>1</sup> 田口亮\*<sup>1</sup> 深井健太郎\*<sup>2</sup> 桂田浩一\*<sup>2</sup> 新田恒雄\*<sup>3,4</sup>  
 Mingchua Fu Ryo Taguchi Kentaro Fukai Kouichi Katsurada Tsuneo Nitta

\*<sup>1</sup> 名古屋工業大学 Nagoya Institute of Technology \*<sup>2</sup> 東京理科大学 Tokyo University of Science \*<sup>3</sup> 早稲田大学 Waseda University \*<sup>4</sup> 豊橋技術科学大学 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コ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コードするには、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

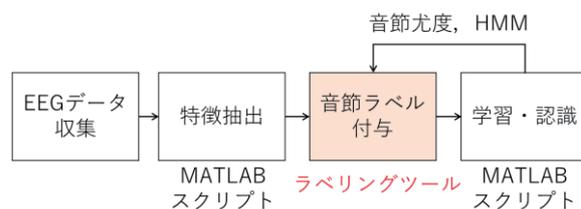


図1 ラベリングツールを用いた作業の流れ

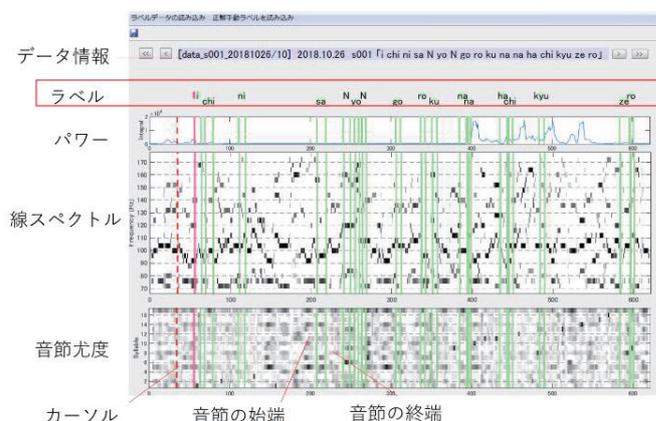


図2 ラベリングツールの実行画面

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、ある程度データを累積した段階で、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、確証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、共通の特徴を探ることが行われる。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

- [1] 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/>

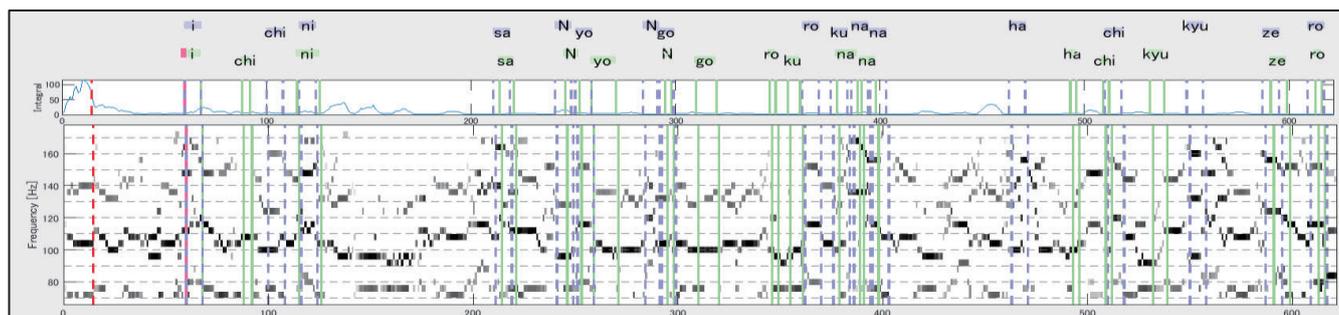


図3 HMMの推定結果と人手によるラベルデータの比較

# 音声想起時脳波からの単語認識

## Word Recognition from speech-imagery EEG

平田 里佳\*<sup>1</sup> 入部 百合絵\*<sup>1</sup> 深井 健太郎\*<sup>2</sup> 桂田 浩一\*<sup>2</sup> 新田 恒雄\*<sup>3,4</sup>  
 Satoka Hirata Yurie Iribe Kentaro Fukai Kouichi Katsurada Tsuneo Nitta  
 Aichi Prefectural 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 回繰り返して繰り返した。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

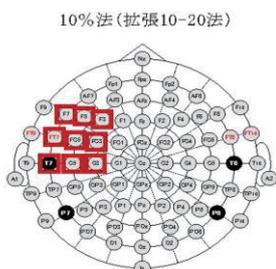


図 1 電極配置

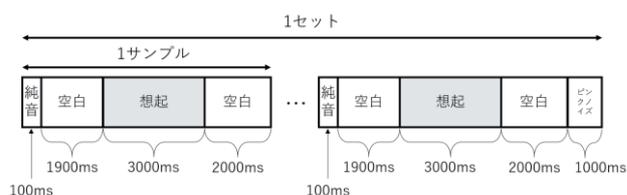


図 2 収録プロトコル

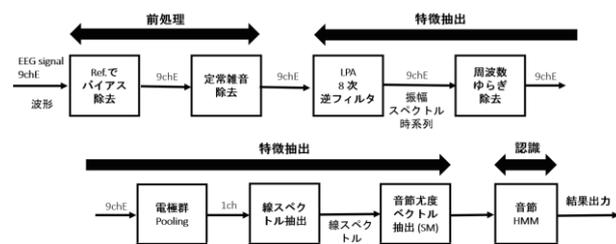


図 3 音声想起単語認識システム

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、および定期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- $\gamma$  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、歯ざ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 特徴抽出

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 [6]。線スペクトル抽出では、周波数のゆらぎが観測された

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、線スペクトルのみ、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。

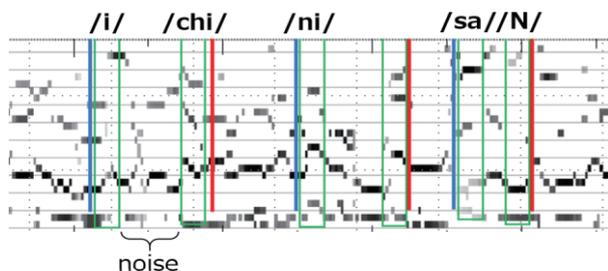


図 4 線スペクトルパターンによるラベリング

## 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

特徴量	正解率(%)		
	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 + 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 健太郎\*<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。

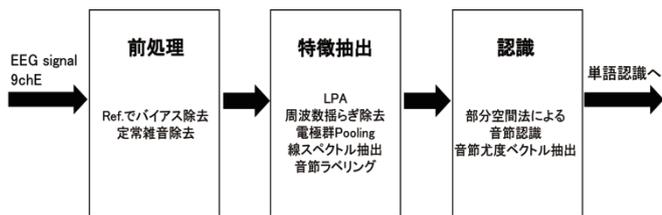
本報告では、音声想起時の言語表象は tone-burst 波群、すなわち線スペクトル群であるという仮説を基に、線形予測分析 (LPA) を適用して、線スペクトル特徴時系列を抽出する。続いて、時系列中の音節セグメントを目視でラベリングしたデータを対象に[6]、leave-one-out 法による識別実験を行う。識別器には、小規模コーパスで比較的高い精度が得られる部分空間法 (Subspace Method; SM) を用いた[7]。

### 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、 $\alpha$  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



連絡先: 深井健太郎, 東京理科大学,  
6318526@ed.tus.ac.jp

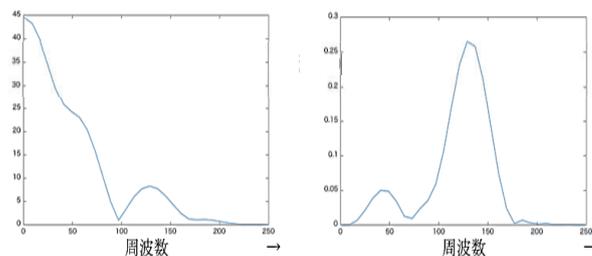


図 2 ノイズ除去前後の振幅スペクトル比較 (/a/)

に係る High- $\gamma$  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  $T_s = 2\text{msec}$ ))。

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  $f_M(m)$  とし、音声想起の脳波を生成する合成フィルタ係数を  $a_M(m)$  として次式の畳み込み演算で表現できる。

$$s(n) = -\sum_{m=1}^M a_M(m)s(n-m) + f_M(n) \quad (1)$$

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 filter 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  $p$ -norm ( $p = 4$ ) 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  $\Delta = 0$  となる極大値, 及び, 2 階微分  $\Delta\Delta = 0$  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  $\Delta\Delta = 0$  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.

- $\Delta > 0$  かつ  $\Delta\Delta$  が + から - に変化
- $\Delta < 0$  かつ  $\Delta\Delta$  が - から + に変化

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.

$$s_k(x) = \sum_{m=1}^M (x \cdot \varphi_{km})^2 \quad (3)$$

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,  $m = 1, \dots, M$  は部分空間の番号を示す. 部分空間法では, 通常, 入力パターンを正規化(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].

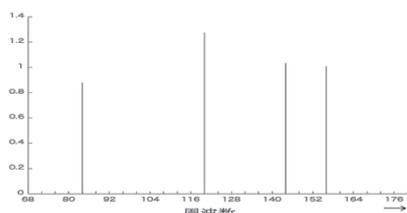


図 3 /a/と想起した際の線スペクトル

## 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.

表 1 母音, 有声音, 無声音毎の認識結果 正解率 (%)

	母音音節	有声音音節	無声音音節
線スペクトル	43.8	43.6	38.1
Bi-Spectrum	51.2	40.0	36.3

表 1 から, 母音音節, 有声音音節, 無声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 orthogonal 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 健太郎<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 Toyoashi Univ. of Tech.#2 Tokyo Univ. of Science#3 Aichi Prefectural 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、言語に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

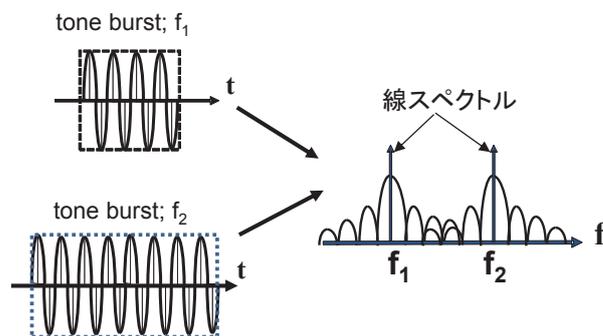
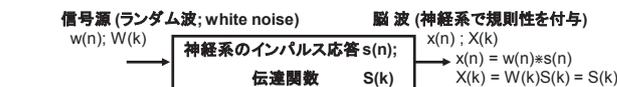


図1 tone-burst 信号とスペクトル形状

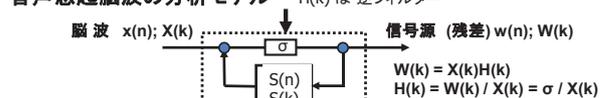
## 音声想起脳波合成モデル



$$X(k) = \mathcal{F}[s(n)] = \mathcal{F}[a_0\delta(n) + a_1\delta(n-1) + a_2\delta(n-2) + \dots + a_p\delta(n-p)]$$

{ $a_n$ } は線形予測係数。{ $x(n)$ } から (Levinson) Durbin の再帰的アルゴリズムで求める

## 音声想起脳波の分析モデル



$$H(z) = \sigma / \sum_{i=0}^p a_i z^{-i}, a_0 = 1, \sigma = x(n) \text{ の rms 値}; \text{分母は合成フィルターの } z\text{-変換}$$

$H(k) = \sigma / \mathcal{F}[1, a_1, a_2, \dots, a_p, 0, 0, \dots]$ ; 0-paddingで周波数分析精度を調整する

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

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  $\{a_0, a_1, \dots, a_p\}$  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とガウス平滑フィルタ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。

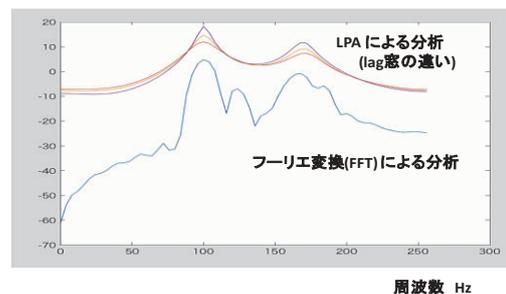


図 3 FFT 分析と LPA 分析のパターン比較 (/a/)

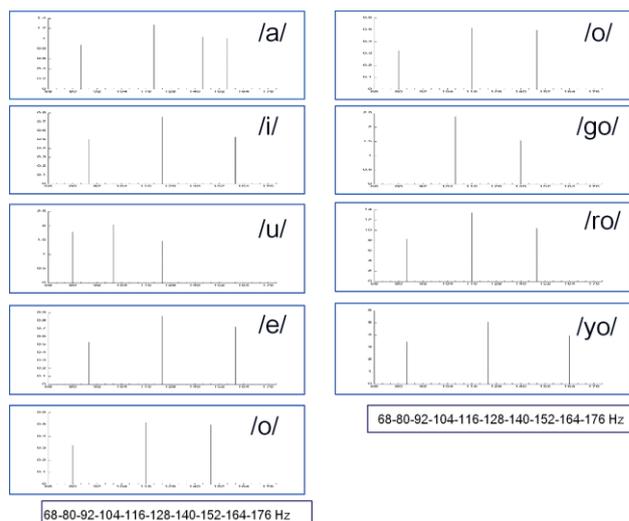


図 4 音節の線スペクトルパターンの例

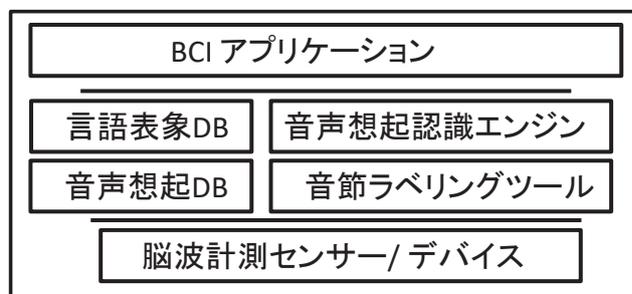


図 6 言語表象に基づく BCI 研究フレームワーク

### 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

- [1] 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](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] 傳ほか, 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)*.

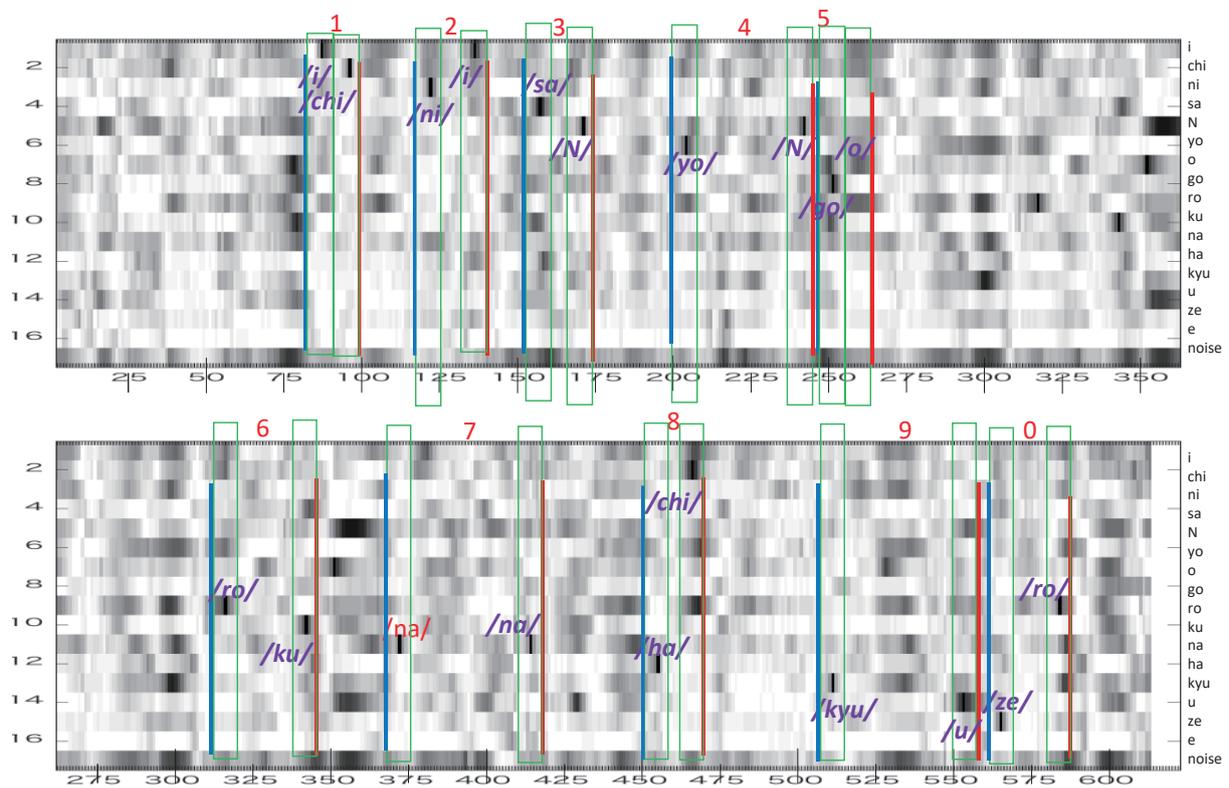


図5 連続数字音声想起データに対する手動音節ラベリング

(図の右端に音節名を示し, 図は濃淡で音節尤度を示した.)