Fri. Jun 7, 2019

Room R

[4Rin1] Interactive Session 2

9:00 AM - 10:40 AM Room R (Center area of 1F Exhibition hall)

[4Rin1-01] Dimension reduction of nonlinear manifolds by Kernel Graph Laplacian Features

○Kazuki Takahashi[1], Takashi Takekawa[1] (1. Kogakuin University)

9:00 AM - 10:40 AM

[4Rin1-02] Initialization of a Search Space Considering a Budget for Black-box Optimization

○Masahiro Nomura[1], Kenshi Abe[1] (1. CyberAgent, Inc.)

9:00 AM - 10:40 AM

[4Rin1-03] Hierarchization of Skill Acquisition without a Reward Function in Reinforcement Learning

○Takanori Saragai[1], Izumi Karino[1], Yasuo Kuniyoshi[1] (1. University of Tokyo)

9:00 AM - 10:40 AM

[4Rin1-04] Multi-task Deep Reinforcement Learning with Evolutionary Algorithm and Policy Gradient Method in 3D Control Tasks

○Shota Imai[1], Yuichi Sei[1], Yasuyuki Tahara[1], Akihiko Ohsuga[1] (1. The University of Electro-Communications)

9:00 AM - 10:40 AM

[4Rin1-05] Generation of Question Sentences Using Conversation Corpus for Automatic Generation of Lecture Scenario on Lecture Substitution System

○Satoshi Yoshio[1], Kenji Araki[1] (1. Graduate School of Information Science and Technology, Hokkaido University)

9:00 AM - 10:40 AM

[4Rin1-06] Corpus Filtering Focusing on Named Entities for Neural Machine Translation

○Hiroki Homma[1], Hayahide Yamagishi[1], Yukio Matsumura[1], Mamoru Komachi[1] (1. Tokyo Metropolitan University)

9:00 AM - 10:40 AM

[4Rin1-07] Due to the development of artificial intelligence capitalism collapses and emancipationism comes.

○Seiji Ono[1], Mamoru Yoshino[1] (1. Association for Japanese Economic Recovery)

9:00 AM - 10:40 AM

[4Rin1-08] Evaluation of Holographic Reduced Representations in Question-Answering System using Spiking Neuron Model

○Keiji Iwao[1], Bisser Raytchev[1], Toru Tamaki[1], Kazufumi Kaneda[1] (1. Univ. of Hiroshima)

9:00 AM - 10:40 AM

[4Rin1-09] AI Trainning Platform and AI Implementation with DQN for Realtime Strategy Game

○Yikun Zhang[1], Tomonori Hashiyama[1], Shun'ichi Tano[1] (1. The University of Electro-Communications)

9:00 AM - 10:40 AM

[4Rin1-10] A Sub-policy Pruning Method for Meta Learning Shared Hierarchies

Qing Hong[2,1], Yusuke Tanimura[1,2], ○Hidemoto Nakada[1,2] (1. National Institute of Advanced Institute of Science and Technology, 2. University of Tsukuba)

9:00 AM - 10:40 AM

[4Rin1-11] Extractive Three-line Summarization of News Articles using Neural Network

○Kouhei Ogawa[1], Koichi Nagatsuka[1], Masayasu Atsumi[1] (1. Soka University)

9:00 AM - 10:40 AM

[4Rin1-12] Predicate argument structure analysis with Pointer Networks

○Keigo Takahashi[1], Hikaru Omori[1], Mamoru Komachi[1] (1. Tokyo Metropolitan University)

9:00 AM - 10:40 AM

[4Rin1-13] Constructing of the word embedding model by Japanese large scale SNS + Web corpus

○Shogo Matsuno[1], Sakae Mizuki[1], Takeshi Sakaki[1] (1. Hottolink, Inc.)

9:00 AM - 10:40 AM

[4Rin1-14] Generation of facial animations to express suppressed positive emotion using action units

○Hirofumi Omichi[1], Yuzuki Hayashi[2], Kazuya Mera[1], Yoshiaki Kurosawa[1], Toshiyuki Takezawa[1] (1. Graduate School of Information Sciences, Hiroshima City University, 2. School of Information Sciences, Hiroshima City University)

9:00 AM - 10:40 AM

[4Rin1-15] Research on performance estimation in divergent thinking task using gaze information

○Kazuhiro Nakahara[1] (1. Nihon Unisys, Ltd.)

©The Japanese Society for Artificial Intelligence

9:00 AM - 10:40 AM

[4Rin1-16] Externalization of Coaching Knowledge based on Multiple Thinking Models on Collaborative Learning Environment for Dementia Care

○Atsushi OMATA[1], Shogo ISHIKAWA[1], Yuki MATSUI[1], Hisao HARA[2], Hatsue MUNAKATA[2], Ayumi NAKANOME[2], Yutaka SAKANE[3], Miwako HONDA[4], Shinya KIRIYAMA[1,5], Yoichi TAKEBAYASHI[1,5] (1. Shizuoka University, 2. Koriyama Care Hospital, 3. ExaWizards Inc., 4. Tokyo Medical Center, 5. The Society of Citizen Informatics for Human Cognitive Disoder)

9:00 AM - 10:40 AM

[4Rin1-17] Development of Auralization System to Represent Program by Music and its Application to Programming Support

Kazuaki Rokusawa[1], ○Syogo Watanabe[1] (1. Chiba Institute of Technology)

9:00 AM - 10:40 AM

[4Rin1-18] Person Re-identification based on Interactive Transfer Deep Learning for Mobile Robots and Its Application to TA Task Support

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

9:00 AM - 10:40 AM

[4Rin1-19] Motion Planning with Deep Reinforcement Learning without Using the Pre-Environment Map for Autonomous Mobile Robot

○Jumpei Arima[1], Kuroda Yoji[1] (1. Meiji University)

9:00 AM - 10:40 AM

[4Rin1-20] Nested Rebalacing Optimization for Mobility on Demand

○Tomoki Nishi[1], Satoshi Koide[1], Keisuke Otaki[1], Ayano Okoso[1] (1. Toyota Central R&D Labs., Inc.)

9:00 AM - 10:40 AM

[4Rin1-21] Integer Programming for Cooperative Route Optimization

○Keisuke Otaki[1], Keiichiro Hayakawa[1], Satoshi Koide[1], Ayano Okoso[1], Tomoki Nishi[1] (1. Toyota Central R&D Labs., Inc.)

9:00 AM - 10:40 AM

[4Rin1-22] A Decision Support AI for Business Operations via Information Retrieval and Query Suggestion

○Morishita Terufumi[1], Ozaki Hiroaki[1], Sato Misa[1], Koreeda Yuta[1], Yanai Kohsuke[1] (1. Research &Development Group, Hitachi, Ltd.)

9:00 AM - 10:40 AM

[4Rin1-23] Product Name Extraction from Product Entries on Electronic Commerce Pages

○Peinan Zhang[1] (1. CyberAgent., Inc)

9:00 AM - 10:40 AM

[4Rin1-24] Scam Cryptocurrency Detections using Machine Learning Techniques

○Kentaro Asaba[1] (1. Keio University)

9:00 AM - 10:40 AM

[4Rin1-25] Extraction of Business Contents from Financial Reports Using Recurrent Neural Network Model

○Tomoki Ito[1], Hiroki Sakaji[1], Kiyoshi Izumi[1] (1. The University of Tokyo)

9:00 AM - 10:40 AM

[4Rin1-26] Relation between B2B Corporate Brands and Shareholder Values

○Tomonori Manabe[1,3], Kei Nakagawa[2,3], Kenichi Yoshida[3] (1. Sansan, Inc., 2. Nomura Asset Management Co,Ltd., 3. Graduate School of Business Science, University of Tsukuba)

9:00 AM - 10:40 AM

[4Rin1-27] Sentiment Analysis of Japan Economic Watcher Survey Data with Japanese BERT model

○Tomohisa Aoshima[1,2], Kei Nakagawa[3] (1. University of Tsukuba, 2. Fujitsu Cloud Technologies Limited, 3. Nomura Asset Management Co, ltd)

9:00 AM - 10:40 AM

[4Rin1-28] Economic Causal Chain Search System and its Application

○Kiyoshi Izumi[1], Hiroki Sakaji[1] (1. The University of Tokyo)

9:00 AM - 10:40 AM

[4Rin1-29] Estimating Risk Factors with High Frequency Data through Principle Component Analysis

Kentaro Nasu[2], Yasuo Yamashita[2], ○Hiroshi Takahashi[1] (1. Keio University, 2. Sumitomo Mitsui Trust Asset Management Co., ltd.)

9:00 AM - 10:40 AM

[4Rin1-30] Development of A Target Company Recommendation System for Account-Based Marketing

○Atsushi Hayakawa[1], Akira Kitauchi[1] (1. FORCAS, Inc.)

©The Japanese Society for Artificial Intelligence

9:00 AM - 10:40 AM

[4Rin1-31] Service Quality Improvement of IoT Coffee Roasting Service Using Lifestyle Analysis

○Ayaka Kimura[1], Masaaki Terano[1], Jun Ozawa[2], Yuri Nishikawa[1,2], Tsuyoshi Takenaka[2], Fuko Oura[2,3] (1. Panasonic Corporation, 2. National Institute of Advanced Industrial Science and Technology, 3. Tokyo Metropolitan University)

9:00 AM - 10:40 AM

[4Rin1-32] Unsupervised Anomaly Detection for a Machine Whose Vibration Pattern Changes

○Kazuki Kobayashi[1], Masatoshi Sekine[1], Satoshi Ikada[1] (1. Oki Electric Industry Co., Ltd.)

9:00 AM - 10:40 AM

[4Rin1-33] Development of method of spot weather forecast using machine learning

○Takao Yoshikane[1], Kei Yoshimura[1] (1. The University of Tokyo)

9:00 AM - 10:40 AM

[4Rin1-34] Tsunami Evacuation Behavior and Identification of Dameged Areas by Agents

○Yasuo Kawai[1], Yurie Kaizu[1] (1. Bunkyo University)

9:00 AM - 10:40 AM

[4Rin1-35] Deep Learning for Multifactor Models in Global Stock Markets

○Masaya Abe[1], Kei Nakagawa[1] (1. Nomura Asset Management Co.,Ltd.)

9:00 AM - 10:40 AM

[4Rin1-36] Business Confidence Prediction for Analyst Report using Convolutional Neural Networks

○Shota Takayama[1], Seiichi Ozawa[1,2], Takehide Hirose[3], Masaaki Iizuka[3] (1. Graduate School of Engineering, Kobe University, 2. Center for Mathematical and Data Sciences, Kobe University, 3. Sumitomo Mitsui DS Asset Management Company, Limited)

9:00 AM - 10:40 AM

[4Rin1-37] Asset Allocation Strategy with Non-Hierarchical Clustering Risk Parity Portfolio

○Kei Nakagawa[1], Akio Ito[1], Takanobu Kawahara[1] (1. Nomura Asset Management Co.,Ltd.)

9:00 AM - 10:40 AM

[4Rin1-38] A preliminary discussion on cultural variabilities in human-AI relation

○Osamu Sakura[1,2], Shin'ichi Fukuzumi[2], Hiroshi Nakagawa[2] (1. Univ. of Tokyo, 2. RIKEN-AIP)

9:00 AM - 10:40 AM

[4Rin1-39] Fall Risk Detection for the Elderly using Contactless Sensors

○Takeshi Konnno[1], hiroaki kingetsu[1], Daisuke Fukuda[1], Toshihiro Sonoda[1] (1. Fujitsu Laboratories LTD)

9:00 AM - 10:40 AM

[4Rin1-40] Introducing Modular Neural Networks in Learning Action Games

○Toshinori Takahashi[1], Masaharu Munetomo[2] (1. Hokkaido University, 2. Information Initiative Center, Hokkaido University)

9:00 AM - 10:40 AM

[4Rin1-41] A game operation learning model using human play data

○Tomoya Miyano[1], Katsutoshi Matsumaro[2], Hiroaki Saito[1] (1. Keio University, 2. KOEI TECMO GAMES CO., LTD.)

9:00 AM - 10:40 AM

[4Rin1-42] Neural commit message generation integrating multiple work context encoders

○Tomohiro Iwanaga[1], Yuki Managaki[1], Koichi Tanigaki[1] (1. Fukui University of Technology)

9:00 AM - 10:40 AM

[4Rin1-43] Optimization Method for Structural Engineering by Reinforcement Learning

○Takuya Suzuki[1], Kyosuke Ichikawa[2] (1. Takenaka Corporation, 2. ARK Information Systems)

9:00 AM - 10:40 AM

[4Rin1-44] Adaptive Compressed Sensing Using Deep Learning Suitable for Edge Computing

○Masatoshi Sekine[1], Satoshi Ikada[1] (1. Oki Electric Industry Co., Ltd.)

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

Interactive Session

[4Rin1] Interactive Session 2

Fri. Jun 7, 2019 9:00 AM - 10:40 AM Room R (Center area of 1F Exhibition hall)

[4Rin1-01] Dimension reduction of nonlinear manifolds by Kernel Graph Laplacian Features

○Kazuki Takahashi[1], Takashi Takekawa[1] (1. Kogakuin University)

9:00 AM - 10:40 AM

[4Rin1-02] Initialization of a Search Space Considering a Budget for Black-box Optimization

○Masahiro Nomura[1], Kenshi Abe[1] (1. CyberAgent, Inc.)

9:00 AM - 10:40 AM

[4Rin1-03] Hierarchization of Skill Acquisition without a Reward Function in Reinforcement Learning

○Takanori Saragai[1], Izumi Karino[1], Yasuo Kuniyoshi[1] (1. University of Tokyo)

9:00 AM - 10:40 AM

[4Rin1-04] Multi-task Deep Reinforcement Learning with Evolutionary Algorithm and Policy Gradient Method in 3D Control Tasks

○Shota Imai[1], Yuichi Sei[1], Yasuyuki Tahara[1], Akihiko Ohsuga[1] (1. The University of Electro-Communications)

9:00 AM - 10:40 AM

[4Rin1-05] Generation of Question Sentences Using Conversation Corpus for Automatic Generation of Lecture Scenario on Lecture Substitution System

○Satoshi Yoshio[1], Kenji Araki[1] (1. Graduate School of Information Science and Technology, Hokkaido University)

9:00 AM - 10:40 AM

[4Rin1-06] Corpus Filtering Focusing on Named Entities for Neural Machine Translation

○Hiroki Homma[1], Hayahide Yamagishi[1], Yukio Matsumura[1], Mamoru Komachi[1] (1. Tokyo Metropolitan University)

9:00 AM - 10:40 AM

[4Rin1-07] Due to the development of artificial intelligence capitalism collapses and emancipationism comes.

○Seiji Ono[1], Mamoru Yoshino[1] (1. Association for Japanese Economic Recovery)

9:00 AM - 10:40 AM

[4Rin1-08] Evaluation of Holographic Reduced Representations in Question-Answering System using Spiking Neuron Model

○Keiji Iwao[1], Bisser Raytchev[1], Toru Tamaki[1], Kazufumi Kaneda[1] (1. Univ. of Hiroshima)

9:00 AM - 10:40 AM

[4Rin1-09] AI Trainning Platform and AI Implementation with DQN for Realtime Strategy Game

○Yikun Zhang[1], Tomonori Hashiyama[1], Shun'ichi Tano[1] (1. The University of Electro-Communications)

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

[4Rin1-10] A Sub-policy Pruning Method for Meta Learning Shared Hierarchies

Qing Hong[2,1], Yusuke Tanimura[1,2], ○Hidemoto Nakada[1,2] （1. National Institute of Advanced Institute of Science and Technology, 2. University of Tsukuba）

9:00 AM - 10:40 AM

[4Rin1-11] Extractive Three-line Summarization of News Articles using Neural Network

○Kouhei Ogawa[1], Koichi Nagatsuka[1], Masayasu Atsumi[1] （1. Soka University）

9:00 AM - 10:40 AM

[4Rin1-12] Predicate argument structure analysis with Pointer Networks

○Keigo Takahashi[1], Hikaru Omori[1], Mamoru Komachi[1] （1. Tokyo Metropolitan University）

9:00 AM - 10:40 AM

[4Rin1-13] Constructing of the word embedding model by Japanese large scale SNS + Web corpus

○Shogo Matsuno[1], Sakae Mizuki[1], Takeshi Sakaki[1] （1. Hottolink, Inc.）

9:00 AM - 10:40 AM

[4Rin1-14] Generation of facial animations to express suppressed positive emotion using action units

○Hirofumi Omichi[1], Yuzuki Hayashi[2], Kazuya Mera[1], Yoshiaki Kurosawa[1], Toshiyuki Takezawa[1] （1. Graduate School of Information Sciences, Hiroshima City University, 2. School of Information Sciences, Hiroshima City University）

9:00 AM - 10:40 AM

[4Rin1-15] Research on performance estimation in divergent thinking task using gaze information

○Kazuhiro Nakahara[1] （1. Nihon Unisys, Ltd.）

9:00 AM - 10:40 AM

[4Rin1-16] Externalization of Coaching Knowledge based on Multiple Thinking Models on Collaborative Learning Environment for Dementia Care

○Atsushi OMATA[1], Shogo ISHIKAWA[1], Yuki MATSUI[1], Hisao HARA[2], Hatsue MUNAKATA[2], Ayumi NAKANOME[2], Yutaka SAKANE[3], Miwako HONDA[4], Shinya KIRIYAMA[1,5], Yoichi TAKEBAYASHI[1,5] （1. Shizuoka University, 2. Koriyama Care Hospital, 3. ExaWizards Inc., 4. Tokyo Medical Center, 5. The Society of Citizen Informatics for Human Cognitive Disoder）

9:00 AM - 10:40 AM

[4Rin1-17] Development of Auralization System to Represent Program by Music and its Application to Programming Support

Kazuaki Rokusawa[1], ○Syogo Watanabe[1] （1. Chiba Institute of Technology）

9:00 AM - 10:40 AM

[4Rin1-18] Person Re-identification based on Interactive Transfer Deep Learning for Mobile Robots and Its Application to TA Task Support

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

9:00 AM - 10:40 AM

[4Rin1-19] Motion Planning with Deep Reinforcement Learning without Using the Pre-Environment Map for Autonomous Mobile Robot

○Jumpei Arima[1], Kuroda Yoji[1] （1. Meiji University）

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

[4Rin1-20] Nested Rebalacing Optimization for Mobility on Demand

○Tomoki Nishi[1], Satoshi Koide[1], Keisuke Otaki[1], Ayano Okoso[1] （1. Toyota Central R&D Labs., Inc.）

9:00 AM - 10:40 AM

[4Rin1-21] Integer Programming for Cooperative Route Optimization

○Keisuke Otaki[1], Keiichiro Hayakawa[1], Satoshi Koide[1], Ayano Okoso[1], Tomoki Nishi[1] （1. Toyota Central R&D Labs., Inc.）

9:00 AM - 10:40 AM

[4Rin1-22] A Decision Support AI for Business Operations via Information Retrieval and Query Suggestion

○Morishita Terufumi[1], Ozaki Hiroaki[1], Sato Misa[1], Koreeda Yuta[1], Yanai Kohsuke[1] （1. Research &Development Group, Hitachi, Ltd.）

9:00 AM - 10:40 AM

[4Rin1-23] Product Name Extraction from Product Entries on Electronic Commerce Pages

○Peinan Zhang[1] （1. CyberAgent., Inc）

9:00 AM - 10:40 AM

[4Rin1-24] Scam Cryptocurrency Detections using Machine Learning Techniques

○Kentaro Asaba[1] （1. Keio University）

9:00 AM - 10:40 AM

[4Rin1-25] Extraction of Business Contents from Financial Reports Using Recurrent Neural Network Model

○Tomoki Ito[1], Hiroki Sakaji[1], Kiyoshi Izumi[1] （1. The University of Tokyo）

9:00 AM - 10:40 AM

[4Rin1-26] Relation between B2B Corporate Brands and Shareholder Values

○Tomonori Manabe[1,3], Kei Nakagawa[2,3], Kenichi Yoshida[3] （1. Sansan, Inc., 2. Nomura Asset Management Co,Ltd., 3. Graduate School of Business Science, University of Tsukuba）

9:00 AM - 10:40 AM

[4Rin1-27] Sentiment Analysis of Japan Economic Watcher Survey Data with Japanese BERT model

○Tomohisa Aoshima[1,2], Kei Nakagawa[3] （1. University of Tsukuba, 2. Fujitsu Cloud Technologies Limited, 3. Nomura Asset Management Co, ltd）

9:00 AM - 10:40 AM

[4Rin1-28] Economic Causal Chain Search System and its Application

○Kiyoshi Izumi[1], Hiroki Sakaji[1] （1. The University of Tokyo）

9:00 AM - 10:40 AM

[4Rin1-29] Estimating Risk Factors with High Frequency Data through Principle Component Analysis

Kentaro Nasu[2], Yasuo Yamashita[2], ○Hiroshi Takahashi[1] （1. Keio University, 2. Sumitomo Mitsui Trust Asset Management Co., ltd.）

9:00 AM - 10:40 AM

[4Rin1-30] Development of A Target Company Recommendation System for Account-Based Marketing

○Atsushi Hayakawa[1], Akira Kitauchi[1] （1. FORCAS, Inc.）

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

[4Rin1-31] Service Quality Improvement of IoT Coffee Roasting Service Using Lifestyle Analysis

○Ayaka Kimura[1], Masaaki Terano[1], Jun Ozawa[2], Yuri Nishikawa[1,2], Tsuyoshi Takenaka[2], Fuko Oura[2,3] （1. Panasonic Corporation, 2. National Institute of Advanced Industrial Science and Technology, 3. Tokyo Metropolitan University）

9:00 AM - 10:40 AM

[4Rin1-32] Unsupervised Anomaly Detection for a Machine Whose Vibration Pattern Changes

○Kazuki Kobayashi[1], Masatoshi Sekine[1], Satoshi Ikada[1] （1. Oki Electric Industry Co., Ltd.）

9:00 AM - 10:40 AM

[4Rin1-33] Development of method of spot weather forecast using machine learning

○Takao Yoshikane[1], Kei Yoshimura[1] （1. The University of Tokyo）

9:00 AM - 10:40 AM

[4Rin1-34] Tsunami Evacuation Behavior and Identification of Dameged Areas by Agents

○Yasuo Kawai[1], Yurie Kaizu[1] （1. Bunkyo University）

9:00 AM - 10:40 AM

[4Rin1-35] Deep Learning for Multifactor Models in Global Stock Markets

○Masaya Abe[1], Kei Nakagawa[1] （1. Nomura Asset Management Co.,Ltd.）

9:00 AM - 10:40 AM

[4Rin1-36] Business Confidence Prediction for Analyst Report using Convolutional Neural Networks

○Shota Takayama[1], Seiichi Ozawa[1,2], Takehide Hirose[3], Masaaki Iizuka[3] （1. Graduate School of Engineering, Kobe University, 2. Center for Mathematical and Data Sciences, Kobe University, 3. Sumitomo Mitsui DS Asset Management Company, Limited）

9:00 AM - 10:40 AM

[4Rin1-37] Asset Allocation Strategy with Non-Hierarchical Clustering Risk Parity Portfolio

○Kei Nakagawa[1], Akio Ito[1], Takanobu Kawahara[1] （1. Nomura Asset Management Co.,Ltd.）

9:00 AM - 10:40 AM

[4Rin1-38] A preliminary discussion on cultural variabilities in human-AI relation

○Osamu Sakura[1,2], Shin'ichi Fukuzumi[2], Hiroshi Nakagawa[2] （1. Univ. of Tokyo, 2. RIKEN-AIP）

9:00 AM - 10:40 AM

[4Rin1-39] Fall Risk Detection for the Elderly using Contactless Sensors

○Takeshi Konnno[1], hiroaki kingetsu[1], Daisuke Fukuda[1], Toshihiro Sonoda[1] （1. Fujitsu Laboratories LTD）

9:00 AM - 10:40 AM

[4Rin1-40] Introducing Modular Neural Networks in Learning Action Games

○Toshinori Takahashi[1], Masaharu Munetomo[2] （1. Hokkaido University, 2. Information Initiative Center, Hokkaido University）

9:00 AM - 10:40 AM

[4Rin1-41] A game operation learning model using human play data

○Tomoya Miyano[1], Katsutoshi Matsumaro[2], Hiroaki Saito[1] （1. Keio University, 2. KOEI

©The Japanese Society for Artificial Intelligence

TECMO GAMES CO., LTD.）

9:00 AM - 10:40 AM

[4Rin1-42] Neural commit message generation integrating multiple work context encoders

○Tomohiro Iwanaga[1], Yuki Managaki[1], Koichi Tanigaki[1] （1. Fukui University of Technology）

9:00 AM - 10:40 AM

[4Rin1-43] Optimization Method for Structural Engineering by Reinforcement Learning

○Takuya Suzuki[1], Kyosuke Ichikawa[2] （1. Takenaka Corporation, 2. ARK Information Systems）

9:00 AM - 10:40 AM

[4Rin1-44] Adaptive Compressed Sensing Using Deep Learning Suitable for Edge Computing

○Masatoshi Sekine[1], Satoshi Ikada[1] （1. Oki Electric Industry Co., Ltd.）

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

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

Kernel Graph Laplacian Features による非線形な多様体の次元圧縮

Dimension reduction of nonlinear manifolds by Kernel Graph Laplacian Features

髙橋 春輝 Kazuki Takahashi　　竹川 高志 Takashi Takekawa

工学院大学情報学部
Faculty of Information Kogakuin University

Spectral clustering is used for clustering nonlinear manifolds. The better the performance, the better the distance between the clusters. However, as the S / N ratio of the data decreases, spectral clustering does not work well. This is because the pre-processing in spectral clustering is based on the assumption that the clusters can be sufficiently separated from each other by parameter adjustment. Therefore, in this paper, we propose robust preprocessing to S / N ratio by kernelized graph Laplacian features (Kernel GLF). The GLF is a linear transformation that brings each other's data with high affinity closer and keeps each other's data with low affinity away. The results show that Kernel GLF can convert nonlinear manifold into linear structure. By clustering the pre-processed data with K-Means, it became a more robust algorithm for S / N ratio than Spectral Clustering.

1. はじめに

クラスタリングでの解析では，対象となるデータの構造に結果は影響を受けることになる．データ構造が線形な場合には，K-Means[1]でクラスタリングを行い，各クラスタを分離することが可能である．一方，データ構造が非線形な場合にクラスタリングを行うには，データに前処理を施して線形分離可能な構造への変換が必要となる．そのようなアルゴリズムとして， Spectral Clustering[2][3]が知られている．

Spectral Clustering では各データ同士の類似度から，データ間の繋がりを表現し前処理を行う．この前処理では，各クラスタに属するデータ同士は直交させることが可能である（例として，クラスタ 1 のデータは(1, 0)の座標に，クラスタ 2 のデータは(0, 1)の座標に変換可能），ことを前提にしている．そのため前処理後のデータは K-Means で分離可能となる．しかしクラスタの SN 比が低くなると，異なるクラスタに属するデータ間の距離が近づき，同一クラスタに属するデータ間の距離は離れるようになる．そのような場合に Spectral Clustering を適用すると，過度に密集したクラスタができるような結果が現れる．これは前処理における前提を満たすためには，異なるクラスタに属するデータ同士が無限の距離をとることを必要とするために起こる．SN 比が小さな場合でもパラメータ設定により，異なるクラスタに属するデータ同士の距離を離すことができるが，それは同時に同一クラスタに属するデータ同士の距離も離してしまう．このことにより，SN 比の低いクラスタ同士を分離するような前処理は Spectral Clustering の前提では困難となる．

このことから，クラスタ間は有限の距離をとることを前提に前処理を施すことを考える．このような場合では，類似度の高いデータ同士は近づけ，類似度の低いデータ同士は遠ざけるように変換する方法が想定できる．このようなアルゴリズムには Graph Laplacian Features[4]がある．

Graph Laplacian Features(以降 GLF)は，類似度の高いデータ同士の変換後のユークリッド距離を近づけることと，変換後のデータ全体の分散を最大にすることを制約にしてデータの線形変換を行う．変換後のデータの分散を最大にすることは，類似度の低いデータ同士のユークリッド距離を遠ざけるように作用する．GLF はこの条件を満たす変換行列を固有値問題の解として得ることで，データを線形変換する．したがって，データ間の繋がりを考慮した前処理を可能とするが，元データの線形変換である以上，非線形な構造をとるデータから線形分離可能な構造への変換はできない．

そこで，元データの特徴量の線形変換とすることでカーネル化した GLF を提案し，データ間の繋がりから非線形な多様体の表現を可能とする前処理を試みる．そして前処理後のデータを K-Means で分類し，非線形かつ SN 比の低いデータに対するクラスタリングの堅牢性を実験的に検証する．

連絡先：竹川 高志，工学院大学 情報学部，〒163-8677 東京都新宿区西新宿 1-24-2，03-3340-0103，E-mail: takekawa@cc.kogakuin.ac.jp

2. Kernel GLF の定式化

2.1 GLF 概要

GLF は類似度行列

$$W_{ij} = e^{\left\{-\|x_i - x_j\|^2 / \sigma^2\right\}}$$

によって，変換後のデータ間に制約を与える．ここで現れる，σ はパラメータであり詳細は 2．3 節で述べる．また

$$D_{ij} = \begin{cases} \sum_k W_{ik} & i = j \\ 0 & i \neq j \end{cases} \qquad \mathrm{L} = \mathrm{D} - \mathrm{W}$$

$$P = diag(D_{11} \quad \cdots \quad D_{nn})/\mathrm{tr}(D)$$

を定義し，二つの制約の下最適化問題に定式化していく．

元データ $X_{m\times n} = \{x_1 \quad \cdots \quad x_n\}$ を変換行列 $A_{m\times d} = \{a_1 \quad \cdots \quad a_d\}$によって線形変換したデータを$Y_{d\times n} = A^T X$する．この時，一つ目の制約を

$$c_1(A) = \sum_i^n \sum_j^n \|y_i - y_j\|^2 W_{ij} = \sum_i^n \sum_j^n \|A^T x_i - A^T x_j\|^2 W_{ij}$$

と定義する．このときを$\min_A c_1(A)$満たす変換行列は類似度が高いほど距離が近づくように作用する

二つ目の制約を$\bar{y} = \sum_i^n y_i P_{ii}$, $\bar{x} = \sum_i^n x_i P_{ii}$として，

$$c_2(A) = \sum_i^n \|y_i - \bar{y}\|^2 P_{ii} = \sum_i^n \|A^T x_i - A^T \bar{x}\|^2 P_{ii}$$

と定義する．このとき$\max_A c_2(A)$を満たす変換行列は類似度が低い程距離を離すように作用する．

制約c_1，c_2の最適化を同時に行うために，損失関数を

$$\mathrm{Cost}(A) = {}^{c_1}/_{c_2}$$

と定義し，$\max_A Cost(A)$の解として変換行列$A_{m\times d}$を求める．

本文

2.2 GLF のカーネル化

データ$X_{m\times n}$の特徴量ベクトルを$\Phi_{r\times n} = \{\phi_1 \quad \cdots \quad \phi_n\}$として，$\bar{\phi} = \sum_i^n \phi_i P_{ii}$，$\tilde{\Phi}_{r\times n} = \Phi - \bar{\phi}$と定義する．この時変換後のデータを$Y_{d\times n} = A_{r\times d}^T(\Phi - \bar{\phi}) = A^T\tilde{\Phi}$とする．そして$A$を，$\tilde{\Phi}$の線形和の成分$B_{n\times d} = \{b_1 \quad \cdots \quad b_d\}$と，$\tilde{\Phi}$に直交する成分$\Xi_{r\times d}$に分割する．するとカーネル関数$K_{ij} = \langle\phi_i, \phi_j\rangle$を用いて，$\tilde{K}_{ij} = \tilde{\phi}_j^T\tilde{\phi}_i = K_{ij} - \sum_s^n K_{is}P_{ss} - \sum_t^n K_{jt}P_{tt} + \sum_s^n\sum_t^n K_{st}P_{ss}P_{tt}$ とし，$Y_{d\times n} = B_{n\times d}^T\tilde{K}_{n\times n}$を得る．

このとき二つの制約は，$c_1(B) = 2\sum_k^d b_k^T\tilde{K}L\tilde{K}b_k$，$c_2(\boldsymbol{B}) = \sum_k^d b_k^T\tilde{K}P\tilde{K}b_k$となるため，全体の損失関数は，

$$\mathrm{Cost}(B) = \sum_k^d {b_k^T\tilde{K}P\tilde{K}b_k}\Big/{b_k^T\tilde{K}L\tilde{K}b_k} \quad ①$$

となる．ここでラグランジュ未定乗数法により，

$$\mathrm{L}(b_k,\ \lambda_k) = b_k^T\tilde{K}P\tilde{K}b_k - \lambda_k(b_k^T\tilde{K}L\tilde{K}b_k - 1)$$

$$\frac{\partial \mathrm{L}(b_k,\ \lambda_k)}{\partial b_k} = \tilde{K}P\tilde{K}b_k - \lambda_k\tilde{K}L\tilde{K}b_k = 0$$

$$\tilde{K}P\tilde{K}b_k = \lambda_k\tilde{K}L\tilde{K}b_k \quad ②$$

となり，d個の固有ベクトルbが$B_{n\times d}$の要素となる．

2.3 パラメータについて

Kernel GLF に現れるパラメータは 3 つとなる．

類似度のパラメータ σ を決める方法は，先行論文[1]を参照した．その方法は，データの近傍数Kをパラメータとして与え，すべてのデータで各データからK番目に遠いデータ点とのユークリッド距離を求め，それらの平均を局所的なデータの広がりとして基準 σ とする．基準よりも，データ間が離れているか否かを指標に類似度を決める方法となっている．

変換後の次元数dは，①②より全体の損失関数が

$$\mathrm{Cost}(B) = \sum_k^d \frac{b_k^T\tilde{K}P\tilde{K}b_k}{b_k^T\tilde{K}L\tilde{K}b_k} = \sum_k^d \frac{\lambda_k b_k^T\tilde{K}L\tilde{K}b_k}{b_k^T\tilde{K}L\tilde{K}b_k} = \sum_k^d \lambda_k$$

となるため，d個の固有値の和と全固有値の和との割合が，与えた寄与率より大きくなるように dを定める．

カーネル関数のパラメータの設定は手動で行う．また，カーネル関数自体の設定も任意である．

3. Kernel GLF の検証

以下の検証では，カーネル関数は RBF カーネルを用いた．

$$\text{RBF カーネル}\quad k_{ij} = e^{\left\{-\|x_i-x_j\|^2/\gamma\right\}}$$

3.1 Circle データの Kernel GLF による前処理

sklearn のデータセットの一つである circle データに対して，ガウスノイズが 0. 05，0. 1，0. 15，0. 2 のそれぞれに Kernel GLF を施した結果を図 1 に示す．

近傍数 K は 100，削減後の次元数dは 2，γは 50 とした．

図 1 から，Kernel GLF により類似度に基づき線形分離可能な構造に変換できていることがわかる．

3.2 Circle データのクラスタリング結果

データ数 1000 の circle データを，ノイズが 0. 05 から 0. 2 まで 0. 01 刻みで各 100 回データを作り直し，正答数の平均と標準偏差を求めた．図 2 は，横軸がノイズ，縦軸が正答数を示す．

近傍数 K は 100，寄与率は 0. 95，γは 5 から 100 までの 5 の倍数とした．また，Kernel PCA では RBF カーネルは

$$\text{RBF カーネル}\quad k_{ij} = e^{\{-\gamma\|x_i-x_j\|^2}$$

となっている．

図 2 より，Spectral Clustering での正答数はノイズが 0.1 以上になると，急激に下がり始めるのがわかる．一方，Kernel GLF 後に K-Means を行った正答数は横ばいである．Kernel GLF と Kernel PCA ではカーネル関数が同じではあるが，K-Means でのクラスタリング結果である正答数には大きな差がみられる．

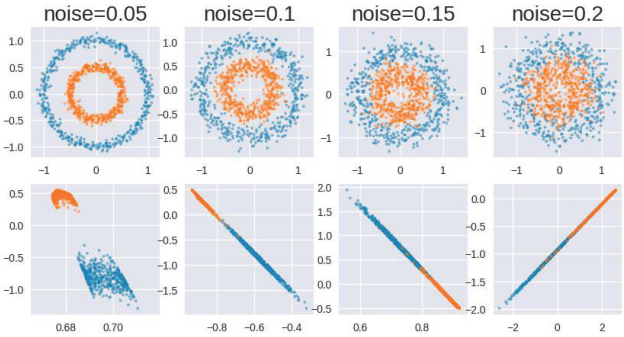


図 1:noise 毎の circle データ分布(上段). Kernel GLF 後のデータ分布(下段)

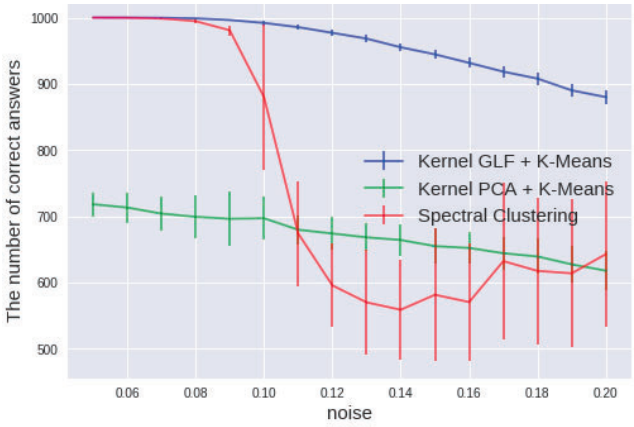


図 2:アルゴリズム毎の正答数の平均と標準偏差

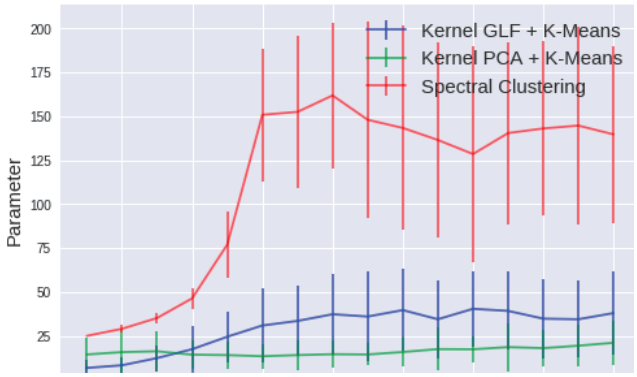


図 3:アルゴリズム毎のパラメータの平均と標準偏差(Kernel GLF と Kernel GLF, Kernel PCA でのパラメータはカーネル関数のγを，Spectral Clustering のパラメータは類似度の $\frac{1}{\sigma^2}$を示している)

4. まとめと考察

3 章の検証では, Kernel GLF により, 非線形な構造が線形な構造に変換されることが確認された. このことから, 変換後の分散だけでなく類似度を考慮することで, Kernel PCA での前処理よりも非線形な多様体を表現しようとする作用が現れることが, Kernel GLF では期待できる. しかし今回の検証は, 非線形な多様体構造であるものの比較的単純なデータであるため, 高次元となるような複雑なデータである場合でも検証が必要となる. しかしながら, カーネル関数を使用する以上, Kernel GLF により得られる結果は恣意的にならざるを得ない. Kernel PCA との比較でも見て取れるように, カーネル関数が等しくても GLF と PCA のアルゴリズムの根本的な違いにより挙動は変動する. したがって, Kernel GLF におけるカーネル関数とパラメータの選択をする際の, 客観的判断に基づいた指標を定めることが今後の課題となるだろう.

参考文献

[1] J. B. MacQueen. (1967). Some methods for classification and analysis of multivariate observations. In Proceedings of the 5th Berkeley Symposium on Mathmatical Statistics and Probability, volum 1, pages 281-297.

[2] Ulrike von Luxburg. (2007). A Tutorial on Spectral Clustering. Max Planck Institute for Biological Cybernetics.

[3] MalikShi and JitendraJianbo. (2000). Normalized Cuts and Image Segmentation. IEEE TRANSACTION ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 22, NO. 8.

[4] SpenceGhanbari Panos E. Papamichalis and LarryYasser. (2010). Graph-Laplacian Features for Neural Waveform Classification. IEEE transactions on bio-medical engineering, VOL. 58, NO. 5.

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

Black-box最適化に対するBudgetを考慮した探索空間の初期化

Initialization of a Search Space Considering a Budget for Black-box Optimization

野村 将寛　　阿部 拳之
Masahiro Nomura　Kenshi Abe

株式会社サイバーエージェント
CyberAgent, Inc.

Black-box optimization is a problem of optimizing the objective function within the bounds of a given budget for evaluations. In Black-box optimization, it is generally assumed that the calculation cost for evaluating one solution is large, so it is important to search efficiently with as few budgets as possible. However, there is a problem that state-of-the-art black-box optimization methods such as Bayesian optimization and CMA-ES do not consider a budget. In this paper, we aim to propose an initialization of a search space that takes a budget into account, dealing with the above problem. We confirm that the proposed method shows good performance by experiments on the benchmark functions.

1. はじめに

Black-box 最適化は，与えられた評価用 budget B の制限内で目的関数 $f : \mathcal{X} \mapsto \mathbb{R}$ を最適化する問題である．つまり，B 回の関数評価が可能な前提で，可能な限り低い評価値 $f(\mathbf{x})$ を持つ解 $\mathbf{x} \in \mathcal{X}$ を得ることが目的となる．Black-box 最適化において，f の代数的表現は与えられず，勾配情報は利用できない．

Black-box 最適化では，一般に 1 回の解の評価にかかる計算コストが大きいことを想定しているため，できるだけ少ない budget で効率よく探索を行うことが重要となる．Black-box 最適化における応用例として，機械学習手法のハイパーパラメータ最適化 [Bergstra 11, Ilievski 17, Golovin 17]，エージェントベースシミュレーションのパラメータ調整 [Yang 09]，飛行機の設計問題 [Chiba 05] などが挙げられる．深層生成モデルの 1 つである Generative adversarial networks (GAN) [Goodfellow 14] の性能は，ハイパーパラメータの選択に大きく依存していることが文献 [Lucic 18] により指摘されている．ここで，GAN は 1 回の学習に長時間必要なため，ハイパーパラメータ最適化のために用いることができる budget は制限されることが考えられる．このように，与えられた budget に応じて探索と活用のトレードオフをとることが重要である．

しかし，ベイズ最適化 [Brochu 10] や CMA-ES [Hansen 03] をはじめとする state-of-the-art な Black-box 最適化手法は budget を考慮していないという問題点が存在する．ベイズ最適化は探索空間全体に対する代理関数から獲得関数を構築し，それを最適化することで次の探索点を得るアルゴリズムである．budget が非常に小さいとき，正確な代理関数のモデル化（探索）に budget を消費してしまうため，評価値の良い領域に対する最適化（活用）が不十分になってしまうことが考えられる．実用上，探索空間が高次元である場合や探索空間の範囲を広く定義している場合に budget が不十分になる傾向があると考えられる．

本論文では，上記の問題点に対処した budget を考慮した探索空間の初期化法の提案を目的とする．提案手法が優れた性能を示すことをベンチマーク関数に対する実験により確認する．

連絡先: 野村 将寛，株式会社サイバーエージェント，Email: nomura_masahiro@cyberagent.co.jp

2. 提案手法

探索空間としてある任意の超立方体 $\mathcal{X} \subseteq \mathbb{R}^d$ (d : 次元数) が与えられたとき，提案手法は階層的分割により探索空間の絞り込みを行うことで，有望であると考えられる領域 $\mathcal{X}_S \subseteq \mathcal{X}$ を出力する．これにより，ベイズ最適化などの最適化手法は $\mathcal{X}$ の代わりに $\mathcal{X}_S$ を初期探索範囲とした上で最適化を実行することが可能になる．

2.1 節で提案手法を用いた最適化フレームワーク，2.2 節で探索空間の絞り込みに用いる budget の計算，2.3 節で探索空間の絞り込み方法の詳細，2.4 節で提案手法の理論解析を述べる．

2.1 最適化フレームワーク

提案手法により探索空間を初期化する最適化フレームワークを Algorithm1 に示す．1 行目で全体の budget B から探索空間の絞り込みに用いる budget B_{ref} の計算，2 行目で有望な探索空間の絞り込み，3 行目で絞り込まれた探索空間を初期探索範囲とした最適化を実行している．

Algorithm 1 提案手法により探索空間を初期化する最適化フレームワーク

Require: budget B, search space $\mathcal{X}$, dimension number d, γ, optimizer

1: $B_{\mathrm{ref}} \leftarrow \gamma \cdot B$
2: $\mathcal{X}_S \leftarrow \mathrm{refine\_search\_space}(d, \mathcal{X}, B_{\mathrm{ref}})$
3: $\mathbf{x}_{\mathrm{best}} \leftarrow$ optimize with a given optimizer for the search space $\mathcal{X}_S$ until a budget reach B

次元数 $d = 2$，budget $B = 8$，最適化手法を Random Search とした場合の提案手法の概念図を図 1 に示す．右図では，提案手法により絞り込みを行った探索空間に対して，Random Search を実行している．

2.2 探索空間の絞り込みに用いる budget の計算

全体の budget B に対して，提案手法に使用する budget B_{ref} を $B_{\mathrm{ref}} = \gamma \cdot B$ と設定する．ここで，次元数 d (≥ 1) に対して γ は $\gamma = 0.59 \cdot \exp(-0.033B/d)$ により計算を行う．γ は $B \to \infty$ のとき $\gamma \to 0$ となる．

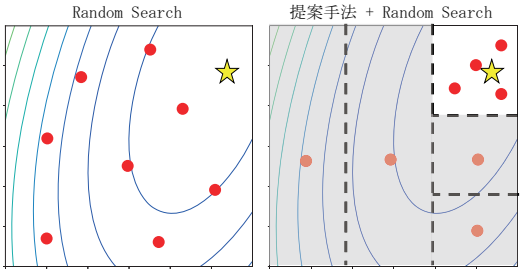


図 1: 次元数 $d = 2$，budget $B = 8$，最適化手法を Random Search とした場合の提案手法の概念図．左図は Random Search のみ，右図は提案手法 + Random Search を示す．右図の灰色の領域は，絞り込みを行った結果除外された領域を表す．

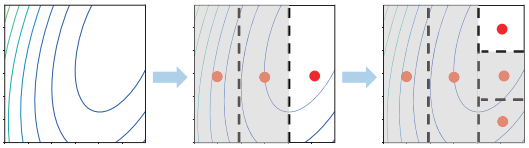


図 2: 次元数 $d = 2$，分割数 $K = 3$ の場合の提案手法の絞り込み方法．ある次元について K 分割し，中心点について評価を行う．中心点が最良となった領域を残し，別の次元に対して再び K 分割を行うことを繰り返す．

2.3 探索空間の絞り込み方法

2.3.1 アルゴリズム

提案手法は各次元に対して領域を等間隔で分割することにより，有望領域の絞り込みを行う．次元数 $d = 2$，分割数 $K = 3$ の場合の提案手法の絞り込みを図 2 に示す．提案手法では，ランダムに選択したある次元に対して K 分割し，分割された領域の中心点の評価値が最も良い領域のみを残す．この操作を，全ての次元について分割が終了するまで繰り返す．

提案手法による探索空間の絞り込みのアルゴリズムを Algorithm 2 に示す．

Algorithm 2 refine_search_space$(d, \mathcal{X}, B_{\text{ref}})$

Require: dimension number d, search space $\mathcal{X}$, budget for refinement B_{ref}

$K = \arg\max_{k \in \mathbb{N} \setminus 2\mathbb{Z}} \{B_k : B_k \leq B_{\text{ref}}\}$
if $K \leq 1$ **then**
  return $\mathcal{X}$
end if
initialization : $\mathcal{X}_S = \mathcal{X}$
for $i = 1$ to d do **do**
  randomly select d_i without replacement from index set of dimensions
  divide $\mathcal{X}_S$ into $\{X_k\}_{k=1}^{K}$ with respect to dimension d_i
  $k^* \leftarrow \arg\min_{k \in [K]} f(x_k)$, x_k is a center point of X_k
  update the search space : $\mathcal{X}_S \leftarrow X_{k^*}$
end for
return $\mathcal{X}_S$

2.3.2 分割数の計算

分割数 K が奇数である場合に，分割に必要な budget は $B_K = K + \sum_{l=1}^{d-1}(K-1)$ となる．提案手法では，式 (1) により B_K が B_{ref} に最も近づくように奇数の分割数 $K \in \mathbb{N} \setminus 2\mathbb{Z}$ を決定する．

$$K = \arg\max_{k \in \mathbb{N} \setminus 2\mathbb{Z}} \{B_k : B_k \leq B_{\text{ref}}\}. \tag{1}$$

2.4 理論解析

提案手法により得られた新たな探索空間を $\mathcal{X}_S \subseteq \mathcal{X} (\subseteq \mathbb{R}^d)$ とする．ここで，$\mathcal{X}_S$ についての損失を表す 2 種類の指標 $r_{\inf}(\mathcal{X}_S)$ と $r_{\sup}(\mathcal{X}_S)$ をそれぞれ式 (2),(3) で定義する．

$$r_{\inf}(\mathcal{X}_S) = \inf_{\mathbf{x}_s \in \mathcal{X}_S} f(\mathbf{x}_s) - \inf_{\mathbf{x} \in \mathcal{X}} f(\mathbf{x}), \tag{2}$$

$$r_{\sup}(\mathcal{X}_S) = \sup_{\mathbf{x}_s \in \mathcal{X}_S} f(\mathbf{x}_s) - \inf_{\mathbf{x} \in \mathcal{X}} f(\mathbf{x}). \tag{3}$$

以下では $d = 1$ の場合について定理と系を説明するが，$d \geq 2$ についても，目的関数が変数分離可能（$f(\mathbf{x}) = \sum_{i=1}^{d} f_i(x_i)$）である場合はそのまま成立する．

定理 1. 元の探索空間 $\mathcal{X}$ がコンパクト，f が厳密な準凸関数であり，$x = a$ $(a \in \mathbb{R})$ で対称であるとする．このとき，$\forall K \in \mathbb{N} \setminus 2\mathbb{Z}$ に対して $r_{\inf}(\mathcal{X}_S) = 0$.

Proof. 仮定より，$x \geq a$ のとき，f は x に対して単調増加，$x < a$ のとき，f は x に対して単調減少となる．K 分割された探索空間を $\{X_i\}_{i=1}^{K}$ とする．つまり，$\mathcal{X} = \bigcup_{i=1}^{K} X_i$ であり，各 X_i は互いに素である．ここで，提案手法が出力した領域 X_k でない領域 X_j $(j \in [K] \setminus \{k\})$ に最適解 $x^* = \arg\min_{x \in \mathcal{X}} f(x)$ が存在すると仮定する．つまり，$x^* \in X_j$ $(j \in [K]), f(x_k) \leq f(x_i)$ $(k \neq j, \forall i \in [K] \setminus \{k\})$ と仮定する．また，各 $X_i, i \in [K]$ の長さを l とし，$x_i, i \in [K]$ を X_i の中心点とする．

(i) $a \in \mathcal{X}$ のとき：$x^* (= a) \in X_j$ より，x_j は x^* から最大 $l/2$ しか離れていない．よって，x に対する f の単調性と $x = a$ での対称性より，$f(x_j) \leq f(x^* + l/2) = f(x^* - l/2)$．ここで，$x_k \in X_k$ に対して上記と同様に，$f(x_k) > f(x^* + l/2) = f(x^* - l/2) = f(x_j)$．これは $f(x_k) \leq f(x_i)$ に矛盾する．

(ii) $a \notin \mathcal{X}$ のとき：まず，$x_j > a$ の場合を考える．このとき，$x^* = x_j - l/2$ となるため，x に対する f の単調性より，$f(x_j) = f(x^* + l/2)$．ここで，$x_k \in X_k$ に対して上記と同様に，$f(x_k) > f(x^* + l/2) = f(x_j)$．これは $f(x_k) \leq f(x_i)$ に矛盾する．$x_j \leq a$ の場合も，$x = a$ における f の対称性より，同様に示される．

よって，提案手法が出力した領域に最適解 x^* が存在するため，$r_{\inf}(\mathcal{X}_S) = 0$. □

系 1. 元の探索空間 $\mathcal{X}$ がコンパクト，f が厳密な準凸関数であり，$x = a$ $(a \in \mathbb{R})$ で対称であるとする．ここで $\mathcal{X}$ の長さを M とすると，$\sup_{x \in \mathcal{X}_S} f(x) \leq f(a - \frac{M}{K}) = f(a + \frac{M}{K})$.

定理 2. 元の探索空間 $\mathcal{X}$ がコンパクトであり，f が $\mathcal{X}$ で連続であるとする．探索空間の絞り込みに用いる *budget* $B_{\text{ref}} \to \infty$ のとき，損失 $r_{\sup}(\mathcal{X}_S) \to 0$ となる．

Proof. 複数の大域的最適解を持つ場合のため，大域的最適解集合 $\arg\min_{x\in\mathcal{X}} f(x)$ それぞれの要素を含む領域の集合族を $\mathbb{X}^*$，最適な領域に対応するインデックス集合を $I^* \subseteq [K]$ と定義する．まず，$B_{\mathrm{ref}} \to \infty$ のとき $K \to \infty$ である．また，$\mathcal{X}$ のコンパクト性より，$\mathcal{X}$ の長さを M とすると，分割数 K のとき領域 X_i $(i \in [K])$ の長さは $l^{(K)} = M/K$ となる．すると，$\forall X_j \in \mathbb{X}^*, \forall x \in X_j, x^* \in X_j$ に対し，$|x - x^*| \leq l^{(K)}$．よって，$K \to \infty$ のとき，$x \to x^*$．ここで，f は $\mathcal{X}$ で連続より，$\forall x \in X_j$ について $\lim_{x\to x^*} f(x) = f(x^*)$．一方，$i \in [K] \setminus I^*$ について，領域 X_i は x^* を含まないので，$\inf_{x\in X_i} f(x) > f(x^*)$．このとき，提案手法は $\mathcal{X}_S$ としていずれかの $X_j \in \mathbb{X}^*$ を出力するので，$\lim_{K\to\infty} \sup_{x\in\mathcal{X}_S} f(x) = \lim_{x\to x^*} \sup_{x\in X_j} f(x) = f(x^*)$． □

3. 実験

3.1 目的

本実験では，budget が制限された Black-box 最適化に対する提案手法の優位性の確認を目的とする．

3.2 比較手法

state-of-the-art なベイズ最適化手法の 1 つである Tree-structured Parzen Estimator (TPE) [Bergstra 11] を用いた上で，提案手法による初期化を用いなかった場合と用いた場合を比較する．本実験では，TPE のみを用いた場合（提案手法による初期化を用いなかった場合），提案手法による初期化を用いた場合をそれぞれ TPE，Refine+TPE と表記する．TPE の実装には Hyperopt[*1] を用いた．

3.3 ベンチマーク関数

本実験で使用する 6 つのベンチマーク関数の名称，定義式，次元，探索範囲を表 1 に示す．ここで，Shekel, Hartmann 関数に現れる係数は文献 [Surjanovic 14] から引用している．

3.4 性能評価指標

本実験では，budget を $B = 10 \times d$ とした上で，50 試行における最良評価値の平均と標準偏差の推移を性能評価指標として用いる．

3.5 結果

TPE と Refine+TPE をベンチマーク関数に適用したときの 50 試行における最良評価値の平均と標準偏差の推移を図 3 に示す．Refine+TPE は全てのベンチマーク関数において，TPE より良い性能を示している．

3.6 考察

本節では，提案手法による初期化がアルゴリズムの振る舞いに与える影響について考察を行う．図 4 に，Hartmann 関数に対する TPE と Refine+TPE の典型的な挙動を示す．横軸は評価回数，縦軸は各評価時に得られた評価値を表す．TPE が探索終盤でも評価値の良い領域に解をサンプルできていないのに対し，Refine+TPE では有望領域の絞り込み後には評価値の良い解が多数サンプルされていることがわかる．これより，提案手法による初期化が budget の制限された問題に対し有効に機能することが示唆される．

4. おわりに

本論文では，Black-box 最適化に対する budget を考慮した初期化法の提案を行った．提案手法は budget に応じて探索空間を分割することで，超立方体を探索範囲とする最適化手法に対して有望な領域を初期探索空間として与えることが可能である．ベンチマーク関数において，提案手法による初期化を用いた場合はそれを用いない場合より良い性能を示した．

今後の課題として，より幅広い問題クラスに対する理論解析と，ハイパーパラメータ最適化をはじめとした実問題への適用が挙げられる．

*1 https://github.com/hyperopt/hyperopt

参考文献

[Bergstra 11] Bergstra, J. S., Bardenet, R., Bengio, Y., and Kégl, B.: Algorithms for Hyper-Parameter Optimization, in *NIPS*, pp. 2546–2554 (2011)

[Brochu 10] Brochu, E., Cora, V. M., and Freitas, de N.: A Tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning, Vol. abs/1012.2599, (2010)

[Chiba 05] Chiba, K., Obayashi, S., Nakahashi, K., and Morino, H.: High-Fidelity Multidisciplinary Design Optimization of Wing Shape for Regional Jet Aircraft, in *Evolutionary Multi-Criterion Optimization*, pp. 621–635 (2005)

[Golovin 17] Golovin, D., Solnik, B., Moitra, S., Kochanski, G., Karro, J., and Sculley, D.: Google Vizier: A Service for Black-Box Optimization, in *KDD*, pp. 1487–1495 (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 *NIPS*, pp. 2672–2680 (2014)

[Hansen 03] Hansen, N., D Mller, S., and Koumoutsakos, P.: Reducing the Time Complexity of the Derandomized Evolution Strategy with Covariance Matrix Adaptation (CMA-ES), *Evolutionary computation*, Vol. 11, pp. 1–18 (2003)

[Ilievski 17] Ilievski, I., Akhtar, T., Feng, J., and Shoemaker, C. A.: Efficient Hyperparameter Optimization for Deep Learning Algorithms Using Deterministic RBF Surrogates., in *AAAI*, pp. 822–829 (2017)

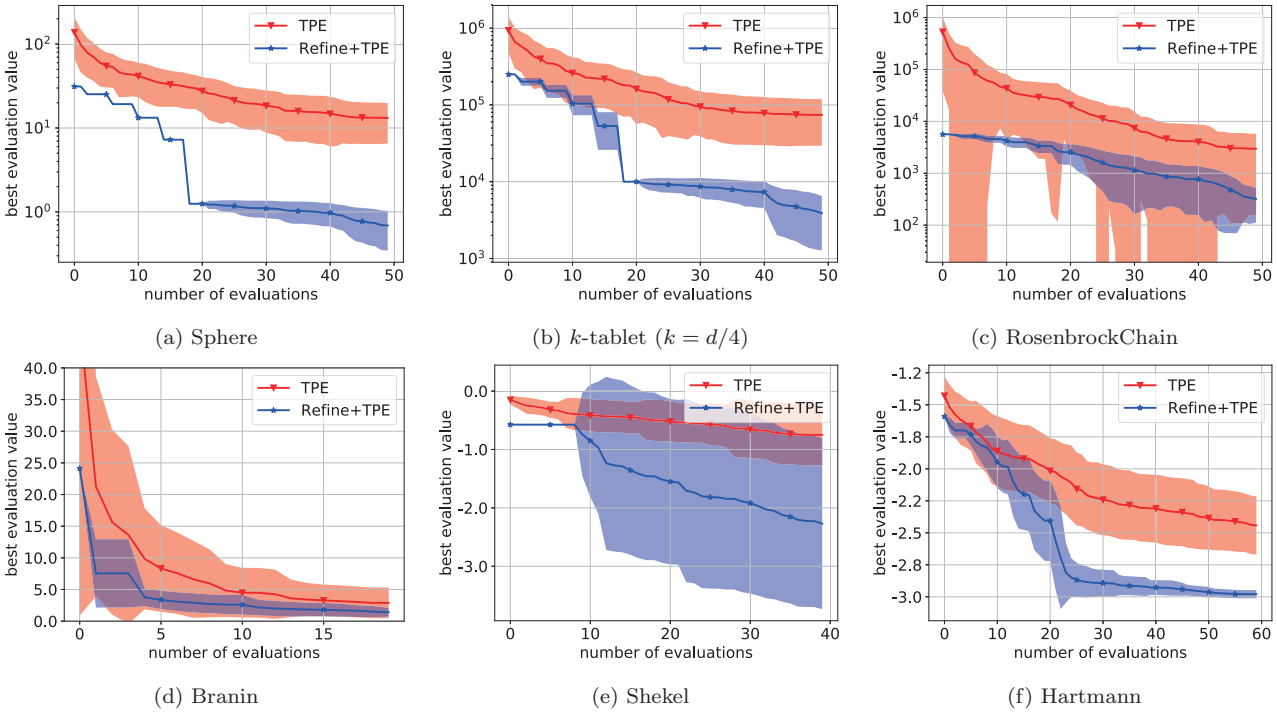
[Lucic 18] Lucic, M., Kurach, K., Michalski, M., Gelly, S., and Bousquet, O.: Are GANs Created Equal? A Large-Scale Study, in *NIPS*, pp. 698–707 (2018)

[Surjanovic 14] Surjanovic, S. and Bingham, D.: Virtual library of simulation experiments: Test functions and datasets., https://www.sfu.ca/~ssurjano (2014)

[Yang 09] Yang, C., Kurahashi, S., Kurahashi, K., Ono, I., and Terano, T.: Agent-Based Simulation on Women's Role in a Family Line on Civil Service Examination in Chinese History, *J. Artificial Societies and Social Simulation*, Vol. 12, (2009)

表 1: 実験で用いるベンチマーク関数の名称，定義式，次元，探索範囲．Shekel, Hartmann 関数に現れる係数は文献 [Surjanovic 14] から引用している．

関数名	定義式	次元	探索範囲
Sphere	$f(\mathbf{x}) = \sum_{i=1}^{d} x_i^2$	5	$[-5, 10]^5$
k-tablet ($k = d/4$)	$f(\mathbf{x}) = \sum_{i=1}^{k} x_i^2 + \sum_{i=k+1}^{d} (100x_i)^2$	5	$[-5, 10]^5$
RosenbrockChain	$f(\mathbf{x}) = \sum_{i=1}^{d-1} \left(100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2\right)$	5	$[-5, 10]^5$
Branin	$f(\mathbf{x}) = (x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1 - 6)^2 + 10(1 - \frac{1}{8\pi})\cos(x_1) + 10$	2	$[-5, 10] \times [0, 15]$
Shekel ($m = 5$)	$f(\mathbf{x}) = -\sum_{i=1}^{5} \left(\sum_{j=1}^{4}(x_j - C_{ji})^2 + \beta_i\right)^{-1}$	4	$[0, 10]^4$
Hartmann	$f(\mathbf{x}) = -\sum_{i=1}^{4} \alpha_i \exp\left(-\sum_{j=1}^{6} A_{ij}(x_j - P_{ij})^2\right)$	6	$[0, 1]^6$



(a) Sphere (b) k-tablet ($k = d/4$) (c) RosenbrockChain

(d) Branin (e) Shekel (f) Hartmann

図 3: ベンチマーク問題に対する TPE と Refine+TPE の実験結果．横軸は評価回数，縦軸は最良評価値の 50 試行における平均と標準偏差を表している．赤線は TPE，青線は提案手法である Refine+TPE を表す．

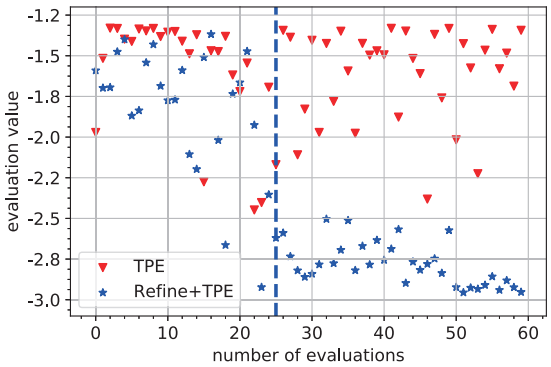


図 4: Hartmann 関数に対する TPE と Refine+TPE の典型的な挙動．横軸は評価回数，縦軸は評価値を表している．赤点は TPE，青点は提案手法である Refine+TPE を表す．また，青の点線は探索空間の絞り込みが終了した時点を表す．

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

強化学習における報酬なしスキル獲得の階層化

Hierarchization of Skill Acquisition without a Reward Function in Reinforcement Learning

皿海孝典 Takanori Saragai　狩野泉実 Izumi Karino　國吉康夫 Yasuo Kuniyoshi

東京大学
The University of Tokyo

In recent years, many researches on pre-training have been done. For the pre-training in which a target task is unknown, some methods enable an agent to acquire skills without a reward function. These methods have a limitation that learning becomes unstable as the number of skills increases. In this research, we propose a model to acquire more skills while keeping diversity by hierarchizing skill acquisition. As a result, we achieved learning in a short time compared to existing methods for the same number of skills. Examination of multiple indicators showed that the diversity of skills is preserved. In addition, we confirmed that features of an agent state tend to be passed down through the hierarchical skills.

1. はじめに

近年, 強化学習はビデオゲーム [Mnih 13] やロボットコントロール [Schulman 15] など様々な分野に応用されている. これらは単一のタスクにおいて極めて高い性能を示すものの, それぞれのタスクにおいて長い学習時間が必要となる. この問題を解消するために, 転移学習 [Pan 10] やメタラーニング [Finn 2017] のように目的タスクを解くために別のタスクで事前学習した知識を転用する手法が提案されている.

事前学習において, 目的タスクが既知であるかどうかによって方針が大きく分かれる. 目的タスクが既知であれば, 目的タスクに対して活用可能な知識を得られるタスクを選び学習することで直接目的タスクを学習するより速く学習が進むことが知られている [Svetlik 17].

一方, 目的タスクが未知であれば, 外部からの報酬がわからないため内部報酬によって事前学習を行う必要があり, エージェントが多様な動き方を獲得することを内部報酬とする手法が提案されている [Eysenbach 18, Gregor 16]. この動き方をスキルと呼び, 目的タスクを与えられたときに獲得済みスキルの中で最もタスクに適したスキルを使う, あるいはそのスキルを方策の良い初期値として用いることで目的タスクでの学習を高速化することが可能である. このとき獲得しておくスキルは, 多数かつ多様であることで広い範囲のタスクに対して適用可能であると考えられるが, スキルの数が増えると学習が不安定になることが指摘されている [Gregor 16]. また, スキルの数が増えるに従って, 必要なスキルを検索する時間も増える.

本稿では多数かつ多様なスキルの安定的な獲得と, 獲得したスキルの検索性の向上のために, スキルの獲得を階層化する手法を提案する.

2. 関連研究

目的タスクが未知の事前学習において獲得するスキルを多様化する. スキルが多様であるとは, 多数のスキルに対してスキルごとにエージェントの状態が異なるということを意味する. これを定式化するためにエージェントの状態とスキルの相互情報量に注目する.

連絡先: 皿海孝典, 東京大学, saragai@isi.imi.i.u-tokyo.ac.jp
國吉康夫, 東京大学, kuniyosh@isi.imi.i.u-tokyo.ac.jp

相互情報量 MI は, 2つの確率変数 X, Y によって以下のように定義される.

$$MI(X,Y) = \sum_{x\in X}\sum_{y\in Y} p(x,y)\log\frac{p(x,y)}{p(x)p(y)} \tag{1}$$

一般に相互情報量は非負であり, X と Y が完全従属かつ X のエントロピーが最大のときに最大値をとる.

スキルと状態の相互情報量を考える. スキルと状態の相互情報量はスキルと状態が従属であり, かつ多様な状態を取るときに最大化する. これは上で述べた多様なスキルの条件を満たすため, スキルと状態の相互情報量を内部報酬とする研究がなされている.

Variational Intrinsic Control は内部報酬をスキルと終端状態の相互情報量とする手法である [Gregor 16]. 初期状態から終端状態に到達するまでの途中経過を無視しているため, 1 エピソードあたり 1 ステップ分の経験しか得られないため学習の効率が悪い. また, 獲得するスキル数を増やすと不安定になることが指摘されている [Gregor 16].

Diversity is All You Need (DIAYN) は終端状態に限らずに, 全ての時点でのスキルと状態の相互情報量を内部報酬とする手法である [Eysenbach 18]. さらに DIAYN では安定化のために方策のエントロピー最大化強化学習を用いて定式化している. 具体的にはスキルを z, 状態を s, 行動を a, エントロピーを $\mathcal{H}[\cdot]$ として,

$$\mathcal{F}(\theta) \equiv MI(s,z) + \mathcal{H}[a|s] - MI(a,z|s) \tag{2}$$

を最大化する. 式の第一項はスキルによってエージェントの到達する状態を操作できるようにするために, 第二項はすべてのスキルを合わせたものを一つの方策としてみたときにエントロピー最大になるようにするために, 第三項はスキルを多様にするのは行動ではなく到達する状態であるようにするために, それぞれの項が設計されている. この結果, 状態空間と行動空間が連続となってもスキルを獲得することが可能となった.

しかし, いまだに獲得するスキル数を増やしたときに安定して学習を行うことはできていない. そこで本手法はスキルを階層化することによって安定してスキル数を増やす方法を提案する.

3. 目的と手法

本研究の目的は安定的に多くのスキルを獲得すること, タスクごとに最適なスキルの高速な検索を可能とすることであり, スキルの学習を階層化することによって目的を達成する.

図 1 に示すモデルによってスキルの階層化を行う. 基本的な構造は DIAYN のものを用いる. DIAYN には方策と分類器が存在し, 各エピソードで無作為に 1 つのスキルが方策に与えられる. 分類器は各ステップの行動後の状態から方策に与えられたスキルを予測する.

式 2 を変形する.

$$\mathcal{F}(\theta) \geq \mathcal{H}[a|s,z] + \mathbb{E}[\log q_\theta(z|s) - \log p(z)] \tag{3}$$

ここで, q_θ はパラメータ θ で表される分類器を表し, 状態 s のときに方策に与えられたスキルが z である確率の予測値を出力する関数となっている.

本研究ではスキルの獲得を階層化するために, この分類器を用いることを提案する.

まず DIAYN によりスキルを獲得し, 獲得したスキル集合 Z^0 のうち i 番目のものを選択する. これをスキル z_i^0 とする. このとき, DIAYN の学習において分類器 $q^0(z|s)$ を学習したとする. ここで学習が収束し, 完全な分類器ができたとすると, z_i^0 についての方策である $\pi_\theta(a|s,z_i^0)$ は報酬

$$r_i^0(s) \equiv \log q^0(z_i^0|s) - \log p(z_i^0) \tag{4}$$

の累積値を最大化する方策となっている. このとき, $q^0(z|s)$ と z_i^0 を固定することで報酬を s のみの関数とみなしている.

次に, 同じ環境においてスキルを獲得する際, DIAYN の報酬に $r_i^0(s)$ を加える. その結果スキル z_i^0 が遷移していた状態に対する指向性を持ちつつ, 多様な状態へスキルを分けようとするため, z_i^0 のスキルの特徴を持ちつつ, 様々なバリエーションを持つようなスキル集合 Z_i^1 が生まれることが予想される.

一般に, DIAYN の n 回目の適用時に獲得された i 番目のスキルに対して分類器 $q^n(z|s)$ が存在し, 同じ環境において

$$\begin{aligned} r^n(s,a) =& \mathcal{H}[a|s,z] + \mathbb{E}[\log q_\phi^n(z|s) - \log p(z)] \\ &+ \mathbb{E}[\log q^{n-1}(z_i^{n-1}|s) - \log p(z_i^{n-1})] \end{aligned} \tag{5}$$

の最大化を行うことでスキル z_i^{n-1} に判別されるという制限を満たしながら多様なスキル集合 Z_i^n を獲得することを期待する.

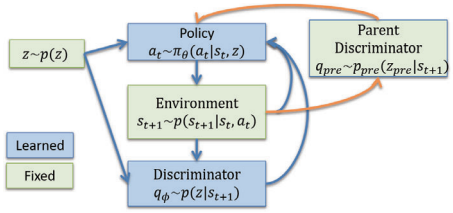


図 1: 提案手法のモデル.

4. 実験

4.1 実験環境と条件

実験環境は OpenAI Gym[Brockman 16] の Mujoco 物理シュミレータ [Todorov 12] において, 図 2(a) に示す Hopper を用いた. Hopper は状態が 11 次元, 行動が 3 次元の 3DoF ロボットである.

方策の学習手法には Soft Actor-Critic(SAC)[Haarnoja 18] を使用した. 隠れ層の大きさは全てのネットワークで (300, 300), 学習率は全て 0.0003, 割引率を 0.99, バッチサイズを 128, エントロピー最大化強化学習における温度計数を 0.1, SAC の状態価値関数の更新率は 0.01, SAC の方策の Gaussian Mixture Model の混合数を 4, リプレイバッファのサイズを 10^6, 最大エピソード長を 1000 ステップとした.

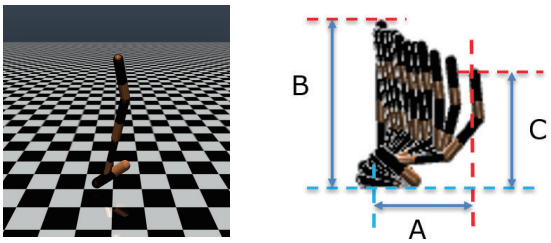
4.2 実験方法

まず DIAYN において 5 個のスキルを獲得させ, これを階層化してそれぞれ 5 個のスキルを持つ子エージェントを 5 個生成して, 計 25 個の子スキルを獲得させる. 比較のため, DIAYN において 25 個のスキルを獲得させる. ここでスキルの獲得における学習の収束時間を比較し, 提案手法の安定性を確認する.

次に獲得したスキルに対してエージェントの軌跡を取って複数の指標を測り, 既存手法と比較したときのスキルの多様性と階層構造における親スキルと子スキルの関係を調べる. 指標として,

- エピソード終了時の位置
- エピソード中の最高到達高さ
- エピソード中の最低到達高さ

の 3 つを測定する. 図 2(b) にそれぞれの指標を図示した.



(a) Hopper 環境　(b) 指標

図 2: 実験環境の概観. (a)Hopper のシミュレーション環境. (b) 各指標を Hopper の連続写真を用いて図示した. (A) エピソード終了時の位置. (B) エピソード中の最高到達高さ. (C) エピソード中の最低到達高さ.

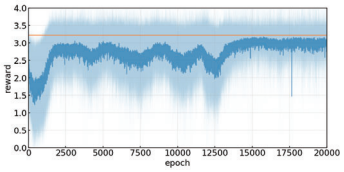
5. 結果

5.1 収束速度の比較

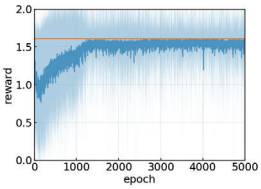
分類器の学習曲線について図 3 に示した. 図 3(a) と図 3(b) を見ると, スキル数が 5 個の場合はおよそ 1500 エポックで収束しているのに対し, スキル数が 25 個の場合は収束におよそ 15000 エポック費やしている. これは, スキル数が増えると学習が安定しないという先行研究の結果を再現している.

図 3(c) は提案手法である階層化スキル獲得に図 3(b) の 3000 エポックまで学習した分類器を用いたときの学習曲線である. 5 つの図はそれぞれ 5 個の親スキルに対応している. これらは 2000 エポックから 4000 エポック程度で十分理想値に近づき収束していることがわかる.

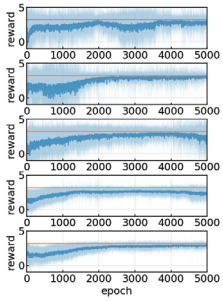
親スキルの獲得に用いた 3000 エポックを加えても 7000 エポック程度で収束をしており, 既存手法が同数のスキル獲得に費やした 15000 エポックと比較して十分早く学習ができている.



(a) DIAYN, スキル数 25 個



(b) DIAYN, スキル数 5 個



(c) 提案手法の下階層

図 3: 分類器の学習曲線. 薄い色は標準偏差, 橙色の直線は報酬の理論値を表す. (a)DIAYN において 25 個のスキルを獲得する際の学習曲線. (b)DIAYN において 5 個のスキルを獲得する際の学習曲線. (c) 提案手法において (b) の 3000 エポックにおける分類器を用いて, 子スキルを学習する際の報酬曲線.

ここで獲得したスキルを図 4 に示す. 図 4(a) の 5 個のスキルを親として, 図 4(b) に示すようにそれぞれ 5 個, 計 25 個の子スキルを獲得した. 前進するスキルを親とすると子スキルも前進するスキルとなり, 子スキル内ではそれぞれが区別可能なスキルが獲得された.



(a) 親スキル



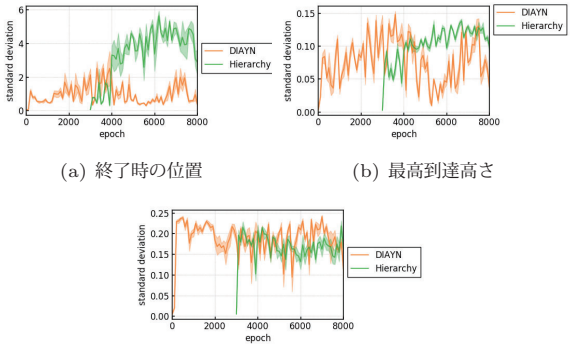
(b) 子スキル

図 4: 獲得されたスキルの 20step ごとの連続写真. (a)3000 エポック学習後の親エージェントの全 5 個のスキル. (b)4000 エポック学習後の子エージェントの全 25 個のスキル. 各列の 5 個のスキルは (a) の同じ列のスキルを親とする子スキルである.

5.2 スキルの多様性

各指標について, 学習回数とスキルの分散について図 5 に示した. 提案手法である階層的なスキルについては, 親スキルの学習に 3000 エポックを使ったため, それだけ右にずらしたものとなっている. エピソード終了時の位置と最高到達高さに関しては階層的なスキルが大きな分散を持っており, 最低到達高さに関しては大きな違いは見られなかった.

このことから, 計測した範囲内では階層化してもスキルの多様性は保たれていることがわかる.



(a) 終了時の位置　(b) 最高到達高さ

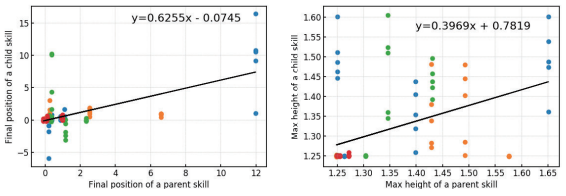
(c) 最低到達高さ

図 5: 25 個のスキルの各指標に対する標準偏差. 緑色は親の 5 スキルそれぞれから獲得された 5 × 5 スキルの標準偏差, 橙色は一つのエージェントの 25 スキルの標準偏差を示す. 100 エポックごとに各スキルで 5 個の軌跡をとった. 実線は標準偏差の平均値, 薄い色は標準偏差の標準偏差を示している.

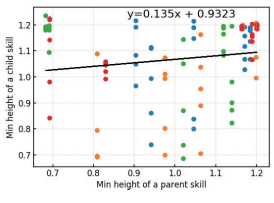
5.3 親と子の相関

同じく複数指標について, 横軸は親スキルの得た値, 縦軸は子スキルの得た値として全ての子スキルに対して散布図を取って最小二乗法によってフィッティングした結果を図 6 に示し, 親スキルと子スキルの相関係数と p 値を表 1 に示した. ここで, 分布に正規性を仮定できないため, Spearman の順位相関係数を用いた.

有意水準を 0.05 とすると, 全ての指標において親の値と子の値で有意に正の相関が見られた. 相関係数の大きさに関して, 最低到達低さに関しては弱い相関, それ以外では 0.4 を少し上回る値で中程度の相関であった.



(a) 終了時の位置　(b) 最高到達高さ



(c) 最低到達高さ

図 6: 各指標に対する親スキルと子スキルの値の関係. 同色の点は同じ親エージェントを持つ子スキルを表す. 黒い実線は最小二乗法によってフィッティングしたもので, その式は図中に示している.

表 1: 各指標に対する親スキルと子スキルの Spearman の順位相関係数と p 値.

	相関係数	p 値
エピソード終了時の位置	0.4279	0.000
エピソード中の最高到達高さ	0.4126	0.000
エピソード中の最低到達高さ	0.2360	0.018

6. 結論

スキルの獲得を階層化することにより, 25 個のスキル獲得における学習の収束時間は既存手法の約 15000 エポックから約 7000 エポックと短縮され, スキル獲得が安定化した.

また, 実験した指標において, 階層化をしてもスキルの多様性は損なわれなかった. 加えて, 階層化して生まれた子スキルは実験した指標において親スキルの性質を受け継いでいることがわかった. これは, 必要なスキルを検索する際にまず親スキルを見ることによって子スキルの傾向がある程度推測できるという利点がある.

さらに, 提案手法はスキルを獲得した後でスキル数を増やすことが可能であるため, 例えば獲得したスキルを確認して前進するスキルに関して追加で種類を増やすというような操作が可能であることが示唆される.

7. 展望

親スキルの性質が子スキルに一部受け継がれるという性質が本稿で示された. これを利用して親スキルの傾向から子スキルの傾向を予測し, 目的タスクに有効なスキルの検索を高速化する手法が今後考えられる.

また, 本稿の制限として, 今回実験した範囲では階層は 2 つとして学習を行ったが, 定式化は階層をどれだけでも深くできるようになっている. そのため, 実際に階層を深くするとスキルの獲得にどのような影響があるのかを調べることは今後の課題であると考えている.

深い階層のスキルが獲得可能になれば, 複雑な構造を持つヒューマノイドロボットなどに提案手法を適用して大量のスキルを獲得させることが考えられる. その際に手や表情といった細やかな表現が必要となる部位に関するスキルに限って深く学習をすることにより, 再学習なしでもヒトの表現に足るスキルセットの獲得につながると期待する.

8. 謝辞

本研究は NEDO の支援を受けたものです. また, 田中一敏特任研究員には多くの助言を受けました. 心より感謝申し上げます.

参考文献

[Brockman 16] Greg Brockman, Vicki Cheung, Ludwig Pettersson, Jonas Schneider, John Schulman, Jie Tang, Wojciech Zeremba: Openai gym, arXiv:1606.01540v1 (2016).

[Eysenbach 18] Benjamin Eysenbach, Abhishek Gupta, Julian Ibarz, Sergey Levine: Diversity is all you need: Learning skills without a reward function, arXiv:1802.06070v4 (2018).

[Finn 2017] Chelsea Finn, Pieter Abbeel, Sergey Levine: Model-agnostic meta-learning for fast adaptation of deep networks, ICML, 1126-1135 (2017).

[Gregor 16] Karol Gregor, Danilo Jimenez Rezende, Dann Wierstra: Variational intrinsic control, arXiv:1611.07507v1 (2016).

[Haarnoja 18] Tuomas Haarnoja, Aurick Zhou, Pieter Abbeel, Sergey Levine: Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor, NIPS Deep Reinforcement Learning Symposium (2017).

[Mnih 13] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, Martin Riedmiller: Playing atari with deep reinforcement learning, NIPS Deep Learning Workshop (2013).

[Pan 10] Sinno Jialin Pan, Qiang Yang, others: A survey on transfer learning, IEEE TKDE, 22(10), 1345-1359, 10.1109/TKDE.2009.191 (2010).

[Schulman 15] John Schulman, Sergey Levine, Pieter Abbeel, Michael Jordan, Philipp Moritz: Trust region policy optimization, ICML, 1889-1897 (2015).

[Svetlik 17] Maxwell Svetlik, Matteo Leonetti, Jivko Sinapov, Rishi Shah, Nick Walker Peter Stone: Automatic curriculum graph generation for reinforcement learning agents, AAAI, 2590-2596 (2017).

[Todorov 12] Emanuel Todorov, Tom Erez, Yuval Tassa: Mujoco: A physics engine for model-based control, IROS, 5026-5033, 10.1109/IROS.2012.6386109 (2012).

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

進化的計算と方策勾配法による学習を用いた 3次元制御タスクにおけるマルチタスク深層強化学習

Multi-task Deep Reinforcement Learning with Evolutionary Algorithm and Policy Gradient Method in 3D Control Tasks

今井 翔太 Shota IMAI　清 雄一 Yuichi SEI　田原 康之 Yasuyuki TAHARA　大須賀 昭彦 Akihiko OHSUGA

電気通信大学大学院情報理工学研究科
Graduate School of Informatics and Engineering. The University of Electro-Communications

In deep rerinforcement learning, it is difficult to converge when the exploration is insufficient or a reward is sparce. Besides, in a specific tasks, the number of exploration may be limited. Therefore, it is considered effective to learn in source tasks previously to promote learning in the target tasks. In this research, we propose a method to train a model that can work well on variety of target tasks with evolutionary algorithm and policy gradient method. In this method, agents explore multiple environments with diverce set of neural networks to train a general model with evolutionary algorithm and policy gradient methid. In the experiments, we assume multiple 3D control source tasks. After the model training with our method in the source tasks, we shows how effective the model is for the 3D Control tasks of the target tasks.

1. はじめに

近年，深層学習と強化学習を組み合わせた深層強化学習がゲーム AI[Mnih 15] や，実世界における機械制御 [Levine 16] 等の分野で大きな成果をあげている．深層強化学習は，深層ニューラルネットワークを関数近似器として用い，Q 値や方策の出力を学習する手法である．

深層強化学習においては，学習のために膨大な探索によるサンプルを必要とする．しかし，探索する環境の行動・状態空間が大きすぎる場合は，十分なサンプルを得るのに大きな時間がかかり，得られたサンプルによっては収束しないこともある．実世界において実機を用いた探索を行う場合には，物理的な条件による制約から，複数の探索自体が困難である．また，学習が完了していない方策で探索を行うことで，機器が危険な行動を行う可能性がある．この問題を解決するため，解きたいタスク（ターゲットタスク）とは別のタスク（ソースタスク）で事前に学習を行うことでニューラルネットワークの転移可能なパラメータを獲得し，解きたいタスクにおいて少数のサンプルで高速に学習が可能な汎用的学習モデルを作成することが望ましい．

深層強化学習で学習を行いたいタスク（ターゲットタスク）があるとき，最終的に解きたいタスクと性質が似ており，なんらかの理由（単にタスクが単純，シミュレータで学習可能）で学習が容易なタスク（ソースタスク）が他に存在するのであれば，ソースタスクで学習を行うことで，効率的に両タスクに共通するパラメータを獲得できる可能性がある．また，ソースタスクが複数ある場合，それら全てのタスクに対して高いパフォーマンスを発揮するようなパラメータの学習を行うことで，ソースタスク，ターゲットタスクの広い範囲のタスクで共通する良いパラメータを学習できると考えられる．

従来の研究では，勾配降下を用いた学習を工夫するなどして，複数のタスクで高速な学習が可能なパラメータを得る事前学習手法が提案されてきた [Finn 17]．しかし，事前学習を行うタスクで報酬がスパースである場合の学習の難しさ [Sutton 98]，強化学習の一般的な課題であるサンプルの偏り [Henderson 17]，初期パラメータへの依存 [Kolen 90] に対応した事前学習手法の検討は不十分である．

これらの背景を踏まえ，本研究では，進化的計算のランダム要素と，勾配降下による学習を組み合わせ，上記の課題を解決しつつ事前学習可能な手法を提案する．本研究では，解くべきタスクを 3 次元制御問題と定め，行動空間が連続である場合に用いられる深層強化学習アルゴリズムである Deep Deterministic Policy Gradient(DDPG)[Lillicrap 15] を用い，ニューラルネットワークに事前学習手法を適用する．

連絡先: 今井翔太，電気通信大学大学院情報理工学研究科，東京都調布市調布ヶ丘 1-5-1, Email:imai.shota@ohsuga.lab.uec.ac.jp

2. 関連研究

本研究では，行動空間が連続な場合に使用される深層強化学習アルゴリズムとして，DDPG[Lillicrap 15] を用いる．DDPG は，状態の入力に対して，決定論的に行動を出力する方策をパラメータで表し，期待報酬和が最大になるような勾配を用いてパラメータを更新する深層強化学習アルゴリズムである．行動空間が連続な場合における Q 学習 [Watkins 92] では，一般的に特定の状態において最も Q 値が高い行動を求めることが困難である．一方 DDPG は入力に対して，それぞれの行動の出力で，決定論的に一つの値を出力するため，主に行動空間が連続である場合のタスクで使用される．DDPG のアーキテクチャは，行動の数と同数の出力を持ち，観測した状態を入力とすることで行動の値を出力する Actor と，観測した状態と Actor の出力を入力とし，観測した状態における Actor の出力を評価する Critic で構成される．Critic は一般的な教師あり学習によって学習を行い，Actor は Critic の出力を使用し，決定論的な方策を学習する方策勾配定理 Deterministic Policy Gradient(DPG)[Silver 14] によってパラメータの更新を行う．パラメータ θ^Q を持つ Critic Q は，リプレイバッファからのサンプル (s_i, a_i, r_i, s_{i+1}) を用いて，以下の損失関数を最小化するようにパラメータを更新する．

$$L = \frac{1}{N}\Sigma_i(y_i - Q(s_i, a_i|\theta^Q))^2 \quad (1)$$

ここで y_i は，パラメータ $\theta^{Q'}$ を持つ Critic のターゲットネットワーク Q'，パラメータ $\theta^{\pi'}$ を持つ Actor のターゲットネッ

トワーク，割引報酬率 γ を用いて，以下の式で与えられる．

$$y_i = r_i + \gamma Q'(s_{i+1}, \pi'(s_{i+1}|\theta^{\pi'})|\theta^{Q'}) \quad (2)$$

Actor のパラメータは上記の Critic の出力を使用し，以下の式で与えられる勾配によって更新する．

$$\nabla_{\theta^\pi} J \approx \frac{1}{N} \Sigma_i \nabla_a Q(s, a|\theta^Q)|_{s=s_i, a=a_i} \nabla_{\theta^\pi} \pi(s|\theta^\pi)|_{s=s_i} \quad (3)$$

深層強化学習において複数タスクに適用可能な事前学習手法としては MAML(Model-Agnostic Meta-Learning)[Finn 17] がある．これは，画像認識や強化学習などの深層学習のタスクにおいて，汎用的に使用できる学習モデルのパラメータの初期値を勾配降下法による学習で得る手法である．この手法は，学習の仕方そのものを学習するメタラーニングと呼ばれる手法の一種である．

深層強化学習における効果的な学習として，進化的計算と勾配降下法による学習を組み合わせた Evolutionary Reinforcement Learning(ERL)[Khadka 18] が提案されている．ERL では，進化的計算のランダム要素によって学習するニューラルネットワークの個体群の中に，勾配降下で学習するニューラルネットワークを混ぜ，定期的に勾配降下で学習するネットワークのパラメータを個体群の一部にコピーすることで，一つのタスクに対する最適化を効率化する．進化的計算では，複数のニューラルネットを用いて学習を行うため，学習が安定しているものが最適化され，また，パラメータの初期値に対して頑健であるという特性がある．これに加え，複数の個体による探索を行うため，報酬がスパースなタスクであっても報酬の獲得がしやすいという利点がある．ERL は強化学習における課題を進化的計算を用いて解決しつつ，一般的な勾配降下による学習を取り入れることで，タスク特化の学習を効率化したものといえる．

3 次元における制御課題のように，行動，状態空間が膨大である場合は，報酬がスパースであり，事前学習に必要な探索自体が難しいという問題がある [Sutton 98]．また，単一のニューラルネットワークを用いた学習は，ネットワークの初期パラメータによって学習が左右される傾向がある [Kolen 90]．その他，単一のニューラルネットワークを用いた探索では，得られるサンプルに偏りが発生し，局所解に陥るなどして学習がうまくいかない場合がある [Henderson 17]．これらは，一般的な事前学習手法における「転移可能なパラメータを得られるかどうか」という問題設定からは独立した課題である．そのため，仮に転移可能なパラメータを得る手段があったとしても，タスクによっては，これらの課題により事前学習が阻害される可能性がある．これらの課題は上述の ERL のように進化計算的な手法を用いることで解決が可能である．したがって，ERL のように進化計算を行い，ニューラルネットワークの最適化の対象を複数のタスクに設定することにより，課題を克服しつつ様々なタスクで利用可能なパラメータを取得することができると考えられる．本研究では，進化的計算による最適化と，ソースタスクにおける複数タスクに対する勾配降下の学習を事前学習として行うことで，3D 制御タスクに共通するニューラルネットの良いパラメータを獲得し，ターゲットタスクとなる複数のタスクで高速に学習することを目指す．

3. 提案手法

3.1 問題設定

本手法の問題設定は以下の通りである．

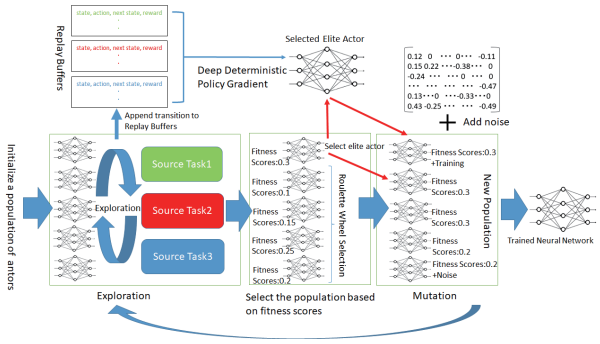


図 1: 進化的計算と方策勾配法を用いた深層強化学習

タスクの質が同じタスクの集合を仮定する．タスクの集合のうち，モデルの事前学習に用いられるものをソースタスクと呼ぶ．タスクの集合のうち，事前学習の時点では与えられず，学習後に解くべき未知のタスクをターゲットタスクと呼ぶ．すなわち，本研究では，ターゲットタスクと似たタスクのソースタスクで事前学習を行うことで，ニューラルネットがタスク間に共通する良いパラメータを獲得し，複数のターゲットタスクにおいて，高速に学習可能なニューラルネットワークを得ることを目指す．

3.2 提案手法の詳細

3.2.1 個体集団による探索

図 1 に提案手法の概要を示す．最初に，進化的計算の個体集合となる複数のニューラルネットワークを用意する．本研究では，状態を入力とし，行動を出力するニューラルネットワーク（以後 Actor） をこの個体集団のニューラルネットワークとする．個体集合 pop_π の Actor π はそれぞれランダムなパラメータ θ^π で初期化される．ソースタスクの集合を T とし，各 Actor π は各世代で全てのタスクを探索し得られた報酬 r_π を記録する．また，この探索で得られたサンプル (s_i, a_i, r_i, s_{i+1}) は各タスクのリプレイバッファに記録する．複数の Actor の探索により，偏りのないサンプルを得ることが期待でき，これらのサンプルは後の DDPG による Actor の学習に使用する．

3.2.2 適応度によるエリート選択，学習

全ての Actor π による探索終了後，記録された報酬の合計を元に各 Actor π の適応度 f_π を計算し，適応度が最も高い Actor をエリート個体として選択する．ここで選択されたエリート個体は，後述のノイズ付加をパスする．選択されたエリート個体の Actor のコピーは，勾配降下による学習で追加の最適化を行うため，確率的に選ばれたタスクのリプレイバッファ R のサンプルを用いて DDPG による学習を行う．ここで，あるタスクのリプレイバッファ R_{T_i} が選択される確率 $P_{R_{T_i}}$ は，その世代の各 Actor が各ソースタスク T_i で得た報酬 r_{T_i} を元に以下の式で与えられる．

$$P_{R_{T_i}} = \frac{r_{T_i}}{\Sigma_i r_{T_i}} \quad (4)$$

3.2.3 適応度による個体の選択，ノイズの付与と最終選択

エリート個体の選別後，次世代の個体集合となる Actor を，適応度を元にルーレット選択によって選択する．ここで選ばれたネットワークは，確率的にノイズを付与することにより，突然変異を行う．エリート個体，コピーされ勾配降下による学習を行ったエリート個体，エリートを除いて選択された個体が次世代の個体集合 pop'_π となり，現世代 pop_π にコピーされる．

Algorithm 1 提案手法の疑似コード

Initialize actor π and critic Q with weight θ^{π} and θ^{Q}, respectively
Initialize a population of k actors pop_{π}
Initialize replay buffers R
Define a random number generator $r() \in [0, 1)$
for $generation = 1, \infty$ **do**
  for actor $\pi \in pop_{\pi}$ **do**
    for all source tasks T_i **do**
      Explore T_i using θ^{π}
      Append transition to replay buffer R respectively
    end for
  end for
  Select the elite actor π based on fitness score f_{π}
  Select the replay buffer R based on all fitness scores f_{π}
  Sample a random minibatch of N transitions (s_i, a_i, r_i, s_{i+1}) from R
  Update Q by minimizing the loss
  $L = \frac{1}{N}\Sigma_i(y_i - Q(s_i, a_i|\theta^{Q}))^2$
  Update copied elite actor π using the sampled policy gradient
  $\nabla_{\theta^{\pi}} J \approx \frac{1}{N}\Sigma_i \nabla_a Q(s, a|\theta^{Q})|_{s=s_i, a=a_i} \nabla_{\theta^{\pi}} \pi(s|\theta^{\pi})|_{s=s_i}$
  Select the $(k-2)$ actors based on fitness scores f_{π} and insert selected actors into next generation's population pop'_{π}
  for $(k-2)$ actors $\in pop'_{\pi}$ **do**
    if $r() < mut_{prob}$ **then**
      Add noise to θ^{π}
    end if
  end for
  Insert the elite actor into pop'_{π}
  Insert the copied elite actor pop'_{π}
  $pop_{\pi} \leftarrow pop'_{\pi}$
end for

以降，上記の手順を最終世代まで繰り返し，最終世代で得られたエリート個体の Actor が最終的に得られるニューラルネットワークである．

4. 実験

実験では，物理演算エンジン Pybullet [Coumans 19] で提供される OpenAI Gym[Brockman 16] の 3 次元物体制御タスクを用いて，事前学習手法の有効性の評価を行う．

4.1 実験設定

PyBullet で提供されるタスクの中から，Minitaur，Hopper，Walker をソースタスクとし，HalfCheetah，Ant，Humanoid をターゲットタスクとする（図 2）．各タスクはそれぞれ，物体の部位の角度や回転，速度などを状態とし，関節など，物体の各部位の調節を出力とする．出力を調節することで，物体が適切に行動（立ち上がる，進む）すると報酬が与えられる．ソースタスクにおいて，提案手法を用いた複数世代の探索，選択，ノイズ付与，学習を行い，最終世代におけるエリート個体となる 1 つの Actor を全てのターゲットタスクに用いる学習モデルとする．各世代における Actor の個体数は 10 とし，1 つの環境における最大探索数は 1000 回，ノイズ付与のフェーズでは，エリートを除いた次世代個体にそれぞれ 1/4 の確率でランダムに発生させた平均 0 のガウシアンノイズを付与する．パラメータの過度な変動を防ぐため，このノイズの中で-0.5 以下，0.5 以上の値は 0 として扱う．本実験における事前学習の世代数は 100 とする．Actor として用いるニューラルネットワークの設定は，入力と出力はタスクごとに可変とし，隠れ層は 3 層，各層のノード数は 128 とする．Critic として用いるニューラルネットワークの設定は，状態を入力する側のネットワークをノード数 200 の隠れ層 1 層とし，Actor の入力と，状態を入力した側からの出力を受け取るニューラルネットワークは 300 ノードの隠れ層 1 層とし，出力は 1 である．活性化関数としては ReLU を使用し，最適化手法として Adam[Kingma 14] を用いた．

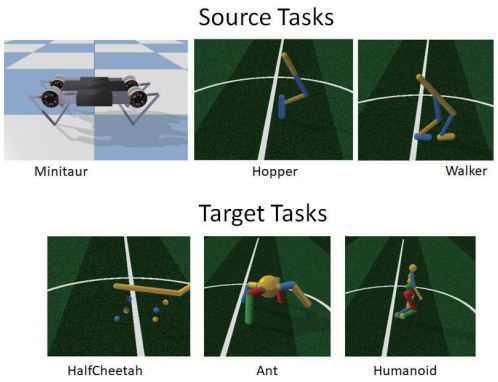


図 2: 実験で用いるソースタスクとターゲットタスク

4.2 実験結果と考察

図 3 に各ターゲットタスクにおける，提案手法によって得られた事前学習モデルと，ランダムに初期化したモデルの学習過程を示す．横軸はエピソード数，縦軸は各エピソードで得られた報酬を指す．Ant，HalfCheetah においては，事前学習モデルを使用した場合のエピソードの初期の段階で獲得する報酬量が，ランダムに初期化したモデルの報酬量を上回っていることが確認できる．両タスク共にエピソードによって得られる獲得報酬量に大きな幅があるものの，全体的に事前学習を行ったモデルの方が大きな報酬を得ており，少ないサンプルで高速に学習できているといえる．一方，Humanoid においては事前学習モデルが，ランダムな初期の場合よりも高いパフォーマンスを発揮できていないことが確認できる．これについては，Humanoid タスクは，他のタスクと異なる多くの部位の観測，行動が要求されるため，ソースタスクでそれらと紐づいた良いパラメータが学習できなかったこと，また今回実験で使用したニューラルネットワークの表現力が足りていないことなどが原因として考えられる．

5. まとめ

本稿では，深層強化学習における既存の事前学習手法において解決されていない課題に対応する手法として，進化的計算と勾配降下を用い，特に 3 次元物体制御タスクにおいて複数のタスクで高速学習可能なパラメータを得る事前学習手法を提案した．実験では，物演算エンジン PyBullet で提供される Open AI Gym の 3 次元制御タスクに提案手法を適用し，複数タスクで高速学習可能なパラメータを持ったニューラルネットが得られることを示した．

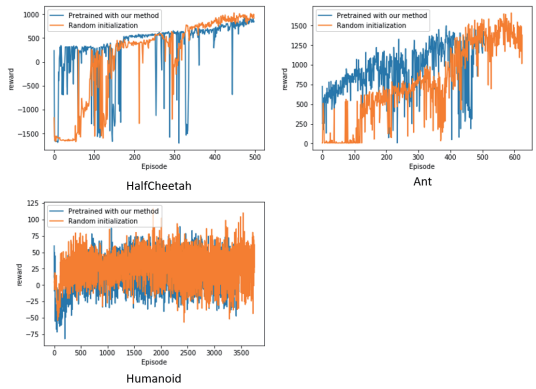


図 3: ターゲットタスクにおける事前学習モデルとランダムに初期化したモデルの学習

今後は，さらに探索空間が大きく，報酬がスパースである課題に対して本手法を適用し，有効性を検証したい．

6. 謝辞

本研究は，JSPS 科研費 16K00419，16K12411，17H04705，18H03229，18H03340 の助成を受けたものです．

参考文献

[Brockman 16] Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., and Zaremba, W.: OpenAI Gym, *CoRR*, Vol. abs/1606.01540, (2016)

[Coumans 19] Coumans, E. and Bai, Y.: PyBullet, a Python module for physics simulation for games, robotics and machine learning, `http://pybullet.org` (2016–2019)

[Finn 17] Finn, C., Abbeel, P., and Levine, S.: Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks, in Precup, D. and Teh, Y. W. eds., *Proceedings of the 34th International Conference on Machine Learning*, Vol. 70 of *Proceedings of Machine Learning Research*, pp. 1126–1135, International Convention Centre, Sydney, Australia (2017), PMLR

[Henderson 17] Henderson, P., Islam, R., Bachman, P., Pineau, J., Precup, D., and Meger, D.: Deep Reinforcement Learning that Matters, *CoRR*, Vol. abs/1709.06560, (2017)

[Khadka 18] Khadka, S. and Tumer, K.: Evolution-Guided Policy Gradient in Reinforcement Learning, in Bengio, S., Wallach, H., Larochelle, H., Grauman, K., Cesa-Bianchi, N., and Garnett, R. eds., *Advances in Neural Information Processing Systems 31*, pp. 1196–1208, Curran Associates, Inc. (2018)

[Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980, (2014)

[Kolen 90] Kolen, J. F. and Pollack, J. B.: Back Propagation is Sensitive to Initial Conditions, in *Proceedings of the 1990 Conference on Advances in Neural Information Processing Systems 3*, NIPS-3, pp. 860–867, San Francisco, CA, USA (1990), Morgan Kaufmann Publishers Inc.

[Levine 16] Levine, S., Finn, C., Darrell, T., and Abbeel, P.: End-to-End Training of Deep Visuomotor Policies, *Journal of Machine Learning Research*, Vol. 17, No. 39, pp. 1–40 (2016)

[Lillicrap 15] Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., and Wierstra, D.: Continuous control with deep reinforcement learning, *CoRR*, Vol. abs/1509.02971, (2015)

[Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., and Hassabis, D.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, No. 7540, pp. 529–533 (2015)

[Silver 14] Silver, D., Lever, G., Heess, N., Degris, T., Wierstra, D., and Riedmiller, M.: Deterministic Policy Gradient Algorithms, in Xing, E. P. and Jebara, T. eds., *Proceedings of the 31st International Conference on Machine Learning*, Vol. 32 of *Proceedings of Machine Learning Research*, pp. 387–395, Bejing, China (2014), PMLR

[Sutton 98] Sutton, R. S. and Barto, A. G.: *Introduction to Reinforcement Learning*, MIT Press, Cambridge, MA, USA, 1st edition (1998)

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

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

講義代行システムにおける講義シナリオ自動生成のための会話コーパスを用いた質問文生成

Generation of Question Sentences Using Conversation Corpus for Automatic Generation of Lecture Scenario on Lecture Substitution System

芳尾 哲[*1] Satoshi Yoshio
荒木 健治[*1] Kenji Araki

[*1] 北海道大学大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University

A scenario of conventional lecture substitution systems is described by hand. Automatic generation of scenario makes it possible to generate scenario without a lot of labor, which is expected to lead to further progress in research on lecture substitution systems. This paper proposes the automatic question sentence generation method, the proposed method extracts questions from conversation corpus and replaces a noun with one of lecture corpus.

1. 研究背景

近年，高性能なヒューマノイドロボットの登場により，ヒューマノイドロボットを用いて講義を行う試み[橋本 2012]がなされている．しかし，講義時に用いるシナリオは人手で作成されたものであり，労力が大きくかかるのが現状である．そこで，我々の従来の研究[芳尾 2017]では，教科書の内容をもとにシナリオを自動生成することで，労力の削減を試みた．しかし，教科書から抽出した内容のみを用いた講義では，単調な口調でロボットが一方的に話すシステムであったことから，講義に飽きてしまう被験者が多いという結果となった．そこで，聞き手が飽きない講義を目指し，講義に変化をつけるため，講義シナリオに質問文を挿入することが必要であると考える．本研究は，そのような自動生成により作られた講義シナリオに挿入するための質問文を自動生成することを目指すものである．

2. 関連研究

日本語による講義のコーパスとして，土屋らが作成した日本語講義音声コンテンツコーパス(CJLC)がある[土屋 2009]．このコーパスは理系大学の講義の書き起こし，音声，スライドなどの情報を含んでおり，40 分以上の長さの講義を 7 回分収録している．また，日本語による会話のコーパスとして，藤村らが作成した名大会話コーパスがある[藤村 2012]．このコーパスは，129 会話(約 13 万， 合計約 100 時間の日本語母語話者同士の雑談を文字化したコーパスである．本研究では，CJLC を講義文データ，名大会話コーパスを質問文データとして用い，これらを基にして講義で用いる質問文の自動生成を行う．コーパスを用いることで，多様な質問文の生成が期待される．

3. 質問文の生成

3.1. 用いるデータ

質問文データとして，名大会話コーパス中の，文末に「？」が付いている質問文と考えられる発話のみを抽出する．さらに，それらの文を MeCab[Kudo 2004]で形態素解析し，名詞を 1 つのみもつ文のみを抽出した．また，感動詞を含むものを除外した．これは，感動詞を含む質問文が講義という形式に適さないと考えられるためである．以下にその例を示す．

例1. **ふーん**，どういう機能？
例2. **えーっ**，そういう時ってびびらない？

「えーっ」，「ふーん」，などの感動詞は主に会話において相手に対する反応として使われる表現であり，講義のように話し手が一方的に話す場合の表現としては適さないと考えられる．また，名詞1つと「？」のみの文を削除した．例を以下に示す．

F023：中のお店は普通のショップなんだけど，床が．あのー
M023：**木？**
F023：木で，フロアとかが木で，で，このところの柱も木で．

このような質問文は前後の文が密接に対応していなければならないため，講義シナリオに挿入するという目的には不適切であると考えたためである．そして最後に，コーパスに元々含まれる話者 ID を削除した．この手順により，結果として 2,798 文の質問文を得た．

また，講義文データとしては，CJLC の書き起こしデータを XML 形式から 1 発話ごとに分けて発話のリストを構築した．まず，XML の〈Utterance〉タグで囲まれている部分の発話文を抽出し，〈Utterance〉タグ 1 つにつき 1 発話とした．発話文を抽出する際，フィラーや言い直しなどのタグは削除した．これは，その後の形態素解析で正しい結果が得られないことに繋がる場合があることや，言い直しのような訂正された部分が入ることは不適切だと考えたためである．上記の手順により，講義文データとして 5,376 文の講義文を得た．講義文データの例を図 1 に示す．

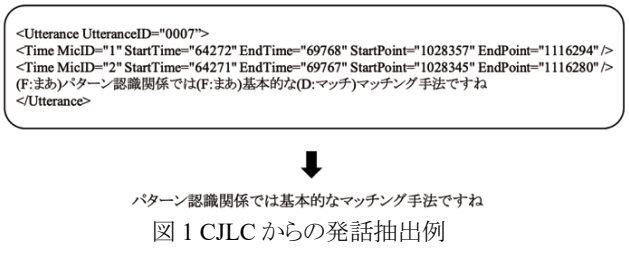


図 1 CJLC からの発話抽出例

連絡先： 北海道大学大学院情報科学研究科メディアネットワーク専攻
北海道札幌市中央区北 14 条西 15 丁目 2-10
E-mail: syoshio@eis.hokudai.ac.jp

3.2 質問文生成の処理過程

日本語講義音声コンテンツコーパスの書き起こしデータの一発話ごとに，質問文生成を行うシステムを構築した．質問文生成の処理過程を図 2 に示す．

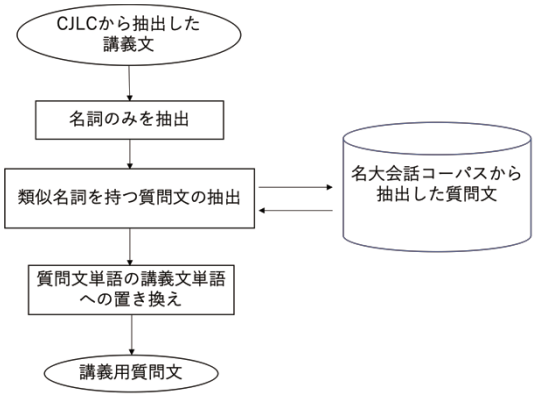


図 2 質問文生成の処理過程

まず，講義文データの 1 発話ごとに，含まれている名詞を抽出する．次に，その名詞と名大会話コーパスから得た質問文中の名詞との単語分散表現間のコサイン類似度がしきい値(今回は 0.6 とした)を超えた場合，質問文中の名詞を講義文中の名詞で置き換えることで新しい質問文を生成する．ここで，単語分散表現の生成ツールとして Word2Vec[Mikolov 2013]を用いた．Word2Vec の学習には，Wikipedia ダンプデータ*1(2018 年 2 月 7 日取得，2.6GB)と CJLC から抽出した発話文データを用いた．表 1 に質問文生成の例を示す．

表 1 講義文「情報理論とここらこの四五なんかは情報理論と関係があります」の質問文生成例

ID	変換前の単語	変換後の単語	コサイン類似度	生成文
生成文 1	記号論	情報理論	0.62	情報理論っておもしろい？
生成文 2	数学	情報理論	0.63	あーあー，情報理論でー？

名大会話コーパスから取得した質問文リストから，講義コーパス文の単語「情報理論」に対してしきい値 0.6 以上のコサイン 類似度を持つ単語を持つ質問文を取得する．これにより，「記号論っておもしろい？」という質問文を取得する．次に，質問文の単語を講義発話文の単語に置き換え，意味的に類似した名詞に置き換えることで，最終的に講義文に応じた質問文「情報理論っておもしろい？」を生成する．

3.3 ストップワードを含む質問文の除外

名詞を置き換え対象にする場合，一般的な名詞(例:「こと」，「もの」，「ため」)同士は単語分散表現が類似しているため，数多く置き換え可能と判断されてしまう．また，このような一般的な単語はどのような文脈においても出現しやすい．そのため，不適切な質問文が生成される原因となる．そのため，本手法ではこれらの一般的な名詞を含んだ質問文を除外している．一般的な名詞かどうかの判定には，SlothLib*2 が提供する日本語ストップワードのリストを用いており，上記の例は全て含まれている．

4. 結果と考察

提案手法によって生成された質問文について考察を行う．まず，生成された質問文のうち，講義文に対して妥当だと考えられる質問文について考察する．

まず，表 1 のような，用語の置き換えによって，元々質問文データにはなかった専門用語を用いた質問文を生成することができた．ただし，このような例は一般的な名詞に比べると少なく，質問文データを日常会話のコーパスから抽出したためか，講義文中の専門用語とコサイン類似度が高い値になるような名詞を持つ質問文が少なかったため，一般的な名詞を使った質問文の方が多く生成された．一般的な名詞を使った質問文で妥当なものの例を表 2 に示す．

表 2 講義文「そう．，携帯電話の中継塔ですよね」の質問文生成例

ID	変換前の単語	変換後の単語	コサイン類似度	生成文
生成文 1	電話番号	携帯電話	0.62	携帯電話持ってる？
生成文 2	インターネット	携帯電話	0.62	携帯電話よく使ってる？

これらの例はいずれも知識を問う質問文ではないが，本研究の目的である聞き手の興味を引くという役割の質問文となっており，これらの例は良い生成結果であると言える．しかし，今回質問文データとして用いた名大会話コーパスは少人数での会話コーパスであったため，講義で大人数を相手に話をする場合の言い回しとは異なっており，少し違和感のある質問文となっているものが多かった．その解決策として，上記の例1では，文頭に「皆さんは，」などの大人数に向けたフレーズを追加することで，「皆さんは，携帯電話持ってる？」のように違和感を軽減した質問文が生成できると考えられるため，今後はこのような手段も検討したい．

また，以上のような講義文に対して妥当な質問文が生成された一方で，妥当でない質問文も生成された．以下に妥当でない質問文の例を表3に示す．この例の「推論を？」や「研究を？」のように，非常に文が短かく情報が少ないために質問の意味がわからない例が数多く見られた．今後はこのような文を除去するために，適切な文字数や単語の数についても検証したい．

*1 https://dumps.wikipedia.org/jawiki/latest

*2 http://svn.sourceforge.jp/svnroot/slothlib/CSharp/Version1/SlothLib/NLP/Filter/StopWord/word/Japanese.txt

表 3 講義文「ただ定理証明のこれいろいろな推論のこと推論が形式的にできることが非常にいろんな研究されてますんでそういう意味では対話の推論の部分ではうまく」の質問文生成例

ID	変換前の単語	変換後の単語	コサイン類似度	生成文
生成文 1	考察	研究	0.67	研究を？
生成文 2	考察	推論	0.64	推論を？

また，意味的に明らかに間違っている文が生成されてしまう場合もあった．以下がその例である．

表 4 講義文「横に何個進んだか，標準パターンです．これ入力パターンね」の質問文生成例

ID	変換前の単語	変換後の単語	コサイン類似度	生成文
生成文 1	ボタン	入力	0.63	入力咲いた？

この原因は，本提案手法では名詞という品詞情報しか考慮していないためである．実際には表 5 に示すように，「ボタン（牡丹）」と「入力」では MeCab が出力する詳細な品詞情報は異なっている．

表 5 MeCab による形態素情報

表層形	品詞情報 1	品詞情報 2
ボタン	名詞	一般
入力	名詞	サ変接続

この問題の解決策として，MeCab により得られる品詞情報のより詳細な情報も一致しているかどうかも名詞の置き換え可能な条件に含めることが考えられる．また，その他にも，名詞同士の置き換えの条件であるコサイン類似度のしきい値を調整することや，今回行なっていない複数の名詞を含む質問文の生成も試みることで，妥当でない生成文を減らし，妥当な生成文を増やすことができると考えられる．

5. まとめ

異なる2つのコーパスを基にし，講義で用いるための質問文を生成した．生成された質問文の中には講義コーパス中に挿入するには妥当でない文も多かったが，有効なものも確認できた．今後の課題としては，生成された質問文が妥当なものであるか，生成した質問文を講義中のどの場所に挿入するかを自動判定することが挙げられる．それらの実現のために，学習データを作成し，SVM などの機械学習手法を用いることを予定している．

参考文献

[橋本 2012] Takuya Hashimoto, Igor M. Verner, Hiroshi-Kobayashi, Human-Like Robot as Teacher's Representative in a Science Lesson: An Elementary School Experiment, Robot Intelligence Technology and Applications, pp.775-786, 2012.

[芳尾 2017] 芳尾哲，荒木健治，“ヒューマノイドロボットを用いた講義代行システムのための講義シナリオ文自動生成手法”，電気・情報関係学会北海道支部連合大会，pp218-219, 2017.

[土屋 2009] 土屋雅稔，太田健吾，小暮悟，山本一公 ,西崎博光，中川聖一，“日本語講義音声コンテンツコーパスの作成と分析”，情報処理学会論文誌 Vol. 50 No. 2 448-459 2009

[藤村 2012] Fujimura Itsuko, Shoju Chiba, Mieko Ohso, Lexical and Grammatical Features of Spoken and Written Japanese in Contrast: Exploring a lexical profiling approach to comparing spoken and Written corpora, Proceedings of the VIIth GSCP International Conference. Speech and Corpora, p393-398, 2012.

[Kudo 2004] Taku Kudo, Kaoru Yamamoto, Yuji Matsumoto: Applying Conditional Random Fields to Japanese Morphological Analysis, Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing (EMNLP-2004), pp.230-237, 2004.

[Mikolov 2013] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S. Corrado, Jeff Dean, Distributed representations of words and phrases and their compositionality, In Advances in neural information processing systems, pp. 3111-3119, 2013.

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

ニューラル機械翻訳におけるコーパスフィルタリングに関する固有表現に注目した分析

Corpus Filtering Focusing on Named Entities for Neural Machine Translation

本間広樹 Hiroki Homma　山岸駿秀 Hayahide Yamagishi　松村雪桜 Yukio Matsumura　小町守 Mamoru Komachi

首都大学東京
Tokyo Metropolitan University

Some parallel corpora include sentences that disturb learning of machine translation systems. By removing such noisy sentences like containing many out-of-vocabulary from the training corpus, it is expected to makes better translations. In this paper, we focus on the sentences containing named entities because most of the named entities fall into out-of-vocabulary due to low-frequencies. We propose two kinds of filtering methods, using byte pair encoding and using named entity recognition. By removing noisy sentences from a training corpus on Japanese-English language pair, BLEU scores improve statistically significantly by 0.5 points in both proposed methods. Analysis revealed that both our methods overcome the mistakes such as suffix of the noun, determiner, and sentence lengths.

1. はじめに

2013 年に提案されたニューラル機械翻訳 [Kalchbrenner 13] は現在，コンピュータを用いて自動的に翻訳を行う機械翻訳の主流の手法となっている．自然言語処理の分野では学習用のデータに含まれない単語を未知語と呼び，機械翻訳システムなどの言語生成システムでは一般的に，未知語を生成できないという問題がある．さらに，ニューラル機械翻訳は計算量の関係から実際に使用する語彙サイズを絞る必要があり，既知の単語であっても低頻度のものは未知語と同様に扱われてしまう．これらの，システムが扱うことのできない単語を out-of-vocabulary (OOV) と呼ぶ．

一般的な単語は，構成性のある単語と構成性のない単語の 2 種類に分類される．ここで構成性のある単語とは，語義を持つサブワードに分割することが可能な単語を指す．例えば *unkingly* という単語は構成性があり，*un*（〜でない），*king*（王），*ly*（〜らしい）の 3 つのサブワードに分割された場合，「王らしくない」という意味を推測できる可能性がある．逆に構成性のない単語は語義のあるサブワードに分割できない単語を指す．例えば *Maldives* という単語は構成性を持たず，このような単語が OOV であった場合は元の意味を復元するのは困難である．

このように，単語をさらに小さなサブワードという単位に分割することで OOV の問題を解決する手法として Byte Pair Encoding (BPE) モデル [Sennrich 16] が提案された．この手法では OOV を高頻度の細かいサブワード，最も細かいもので文字単位に分割することで，語彙サイズの制限による OOV の問題を解消する．

また，機械翻訳の手法の多くはモデルの学習のために原言語文と目的言語文のペアを集めたパラレルコーパスを必要とする．特にニューラル機械翻訳においては他の手法と比較して大規模なデータを要する．現在公開されているパラレルコーパスの多くは，複数の言語で書かれた論文や新聞記事などの中から，対応の取れる文対を機械的に集めることで対訳文としている．しかし，正しい対訳になっている文対であってもその文対の必要性について検討されていない場合も多く，これらのコーパスは翻訳モデルの学習に悪影響を及ぼす文を含有していることが考えられる．このような文を本稿では以降ノイズ文と呼ぶ．パラレルコーパスにさまざまなノイズを与えてその影響を調べた研究 [Khayrallah 18] ではニューラル機械翻訳は以前の主流な機械翻訳手法である統計的機械翻訳に比べてノイズに弱いことがわかった．ノイズ文を学習データから取り除くことで，より精度の高い機械翻訳システムが構築されることが見込まれる．

固有名詞などに代表される固有表現は一般的な語彙に比べて出現頻度が低い．このため，固有表現を多く含む文は計算量の制約で語彙サイズが制限されるニューラル機械翻訳において，多数の OOV を持つことになる．OOV の占める割合が高い文は，文としての意味が大きく欠けている場合が多く，入力文と参照文のどちらに用いても翻訳モデルの学習に対して悪影響を与えると思われる．また，前処理として BPE などのサブワード化を行う場合を考えると，出現頻度の低い固有表現はある程度の長さのある高頻度のサブワードで構成されていないことが多く，他の構成性のある単語よりも細かいサブワードに分割される．このように細かく分割された固有表現を多く含む文は翻訳結果の改善にほとんど寄与せず，逆に文長の増加や語義を持たないサブワードの増加により正しい翻訳を妨げる学習につながってしまうと考えられる．

これらのことから，固有表現を多く含む文を学習データから取り除くことで，より正しい翻訳が行われる機械翻訳システムが構築されることが見込まれる．この仮定のもと，本研究では 2 種類のコーパスフィルタリング手法を提案する．一つは固有表現抽出を用いたフィルタリング（NERF）で，文中に含まれる固有表現数が多い文を取り除く手法である．この手法は直接固有表現抽出ツールを用いる必要があるため，ツールが存在しない言語にも容易に適用できる手法として，BPE を用いたフィルタリング（BPEF）も考案した．これはサブワード化したときに文長が大きく増加する文，つまり細かいサブワードに分割される単語を多く含む文を取り除く手法である．

本研究では，これら 2 種類の手法でパラレルコーパスからノイズ文を取り除く実験とその分析を行った．日英翻訳の実験ではノイズ文を取り除くことで，どちらの手法でも機械翻訳の自動評価尺度である BLEU スコアが 0.5 ポイント改善した．

連絡先: 本間広樹，homma-hiroki@ed.tmu.ac.jp

同実験において人手評価も実施し，NERF に関してはスコアの向上が見られた．分析から，BLEU スコアを上昇させる要因として複数形の有無や冠詞の間違いなどが改善されたほか，文長がより正しく学習できていることが分かった．

2. フィルタリング手法

パラレルコーパス内に含まれるノイズ文を取り除く方法として，固有表現抽出を用いる手法と BPE を用いる手法の 2 種類を考える．

2.1 NERF: 固有表現抽出によるフィルタリング

固有表現抽出はテキストから固有表現を抽出するタスクである．現在では計算機によって大量のテキストから固有表現を自動的に抽出する研究が一般的であり，ツールとして様々なものが公開されている．固有表現抽出手法は数多く提案されているが，本研究では機械学習を用いた系列ラベリングによる固有表現抽出の結果を用いる．

固有表現抽出による学習データのフィルタリングは以下の流れで行う．

1. 固有表現抽出を用いて原言語側または目的言語側の学習データの各文で固有表現数をカウント
2. 固有表現数の多い上位 n 文の文番号を取得 *1
3. 2. で取得した文番号の文を原言語側と目的言語側の両方から削除

2.2 BPEF: BPE によるフィルタリング

Byte Pair Encoding (BPE)[Sennrich 16] は，低頻度の単語を高頻度のサブワードに分割することで機械翻訳の OOV の処理を行う手法であり，現在，ニューラル機械翻訳では一般的に使用されている．BPE の計算方法を以下に示す．

1. 単語分割された文の集合 *2 を入力
   “*Quickly, accurately, and, effectively*”
2. 文の集合に含まれる各単語に対して文字を要素としたリスト化
   $\left[Q,\ u,\ i,\ c,\ k,\ l,\ y,\ @\right]$, $\left[a,\ c,\ c,\ u,\ r,\ a,\ t,\ e,\ l,\ y,\ @\right]$,
   $\left[a,\ n,\ d,\ @\right]$, $\left[e,\ f,\ f,\ e,\ c,\ t,\ i,\ v,\ e,\ l,\ y,\ @\right]$ *3
3. リストの要素 2-gram の頻度を計算
   {*ly*: 3, *y@*: 3, *Qu*: 1, *ui*: 1, *ic*: 1, ... }
4. 最も高頻度の 2 要素を結合してリストを更新
   $\left[Q,\ u,\ i,\ c,\ k,\ \boldsymbol{ly},\ @\right]$, $\left[a,\ c,\ c,\ u,\ r,\ a,\ t,\ e,\ \boldsymbol{ly},\ @\right]$,
   $\left[a,\ n,\ d,\ @\right]$, $\left[e,\ f,\ f,\ e,\ c,\ t,\ i,\ v,\ e,\ \boldsymbol{ly},\ @\right]$
5. 語彙サイズを決定するパラメータ η 回だけ 3. と 4. を繰り返し実行
   $\left[Quick,\ ly@\right]$, $\left[accurat,\ ely@\right]$, $\left[and@\right]$, $\left[effectiv,\ ely@\right]$
6. 使用した全ての文字とサブワードを語彙として使用
   {*Q, u, i, c, k, ..., ly, ly@, ely@, ..., accurat, effectiv*}

ここで，リストの要素 2-gram とはリストに含まれる要素を隣同士で結合したものである．例えば，リスト $[a,\ b,\ c]$ の要素 2-gram は $\{ab,\ bc\}$ となる．BPE によって使用する語彙サイズが削減され，低頻度の単語は複数のサブワード *4 に分割されるようになる．BPE によってサブワード化された文の例を以下に示す．

サブワード化前（5 トークン）
HDPE における メルトフラクチャー 特性 。

サブワード化後（8 トークン）
HDPE における メルト フラ クチャ ー 特性 。

BPE の結合回数を語彙サイズの制限以下にすることで全ての単語をサブワードで表現できるため，OOV がなくなる．その一方で，構成性のない単語は高頻度の大きなサブワードに分割できず，そのような単語を多く含む文は，とても細かく分割されたサブワードの増加と文長の増加により学習に悪影響を与える文になる可能性がある．つまり，BPE の適用で文長が大きく増加した文を学習データから取り除くことで，NERF と同様により正しい翻訳が行われる機械翻訳システムが構築されることが見込まれる．この仮定のもと BPEF では BPE の適用で文長が大きく増加した文を学習データから取り除く．

BPE を用いた学習データのフィルタリングは以下の流れで行う．

1. 原言語側または目的言語側の学習データの各文に対し，BPE を適用する前のトークン数と適用した後のトークン数をそれぞれ w と t としてカウント
2. $t/w > \theta$ を満たす文の文番号を取得
3. 2. で取得した文番号の文を原言語側と目的言語側の両方から削除

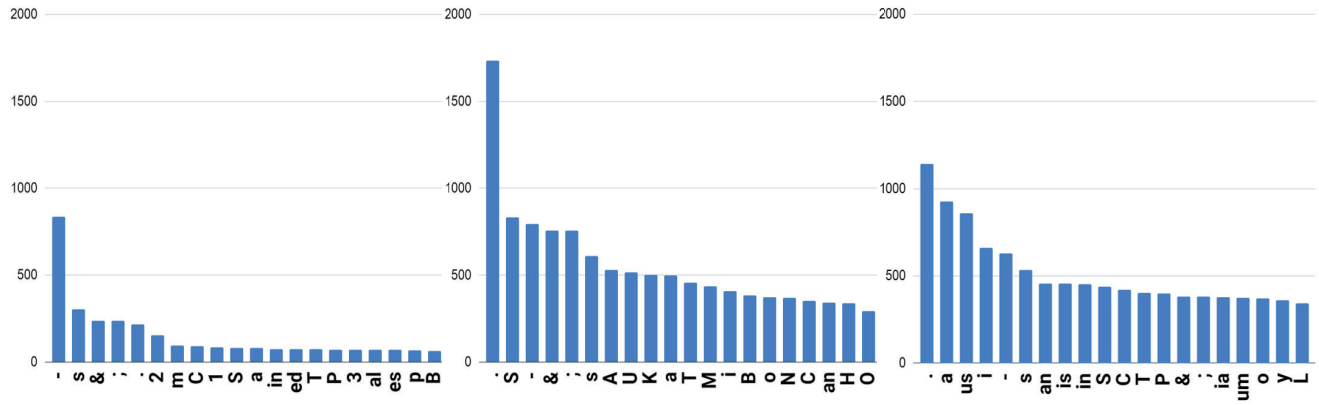
ここで θ は削除する文長比のしきい値を表す．ここでいう文長比は BPE を適用する前後の文長の増加率である．これにより，単語単位とサブワード単位で文長が大きく異なるノイズ文を削除できる．

3. 実験

3.1 実験設定

学習コーパスには科学技術論文の概要から作成された日英パラレルコーパスである Asian Scientific Paper Excerpt Corpus (ASPEC)[Nakazawa 16] を用いた．文の数は学習用，開発用，評価用それぞれ 977,367, 1,790, 1,812 文である．日本語側の単語分割には MeCab*5 (辞書: IPADic Ver. 2.7.0) を用い，英語側のトークン化には Moses*6 に付属する tokenizer.perl を用いた．さらに，OOV の処理として日本語側と英語側に BPE を適用した．これは OOV の問題を解決するための BPE の適用であるため，フィルタリングの有無に関わらず全ての実験で適用する．このとき，英語側と日本語側を合わせたコーパスに対して BPE を適用した．BPE の実装には SentencePiece*7 を使用した．また，すべての実験において BPE 化の結合回数

*1 n は削除文数を決定するパラメータ
*2 この例では 1 文からなる集合を扱う．
*3 @は単語の終わりを表すトークン
*4 ここでサブワードとは単語がサブワード化によって複数に分割されたときのそれぞれのトークンのことを指し，もとの単語まで結合されたようなサブワードは含まない
*5 http://mecab.sourceforge.net/
*6 http://statmt.org/moses/
*7 https://github.com/google/sentencepiece/



[1] ランダムな 4,030 文　[2] NERF　[3] BPEF

図 1: 削除した文中の文字 1-gram と文字 2-gram のサブワードの上位 20 件

表 1: 改善した翻訳結果の一例（置換により BPE をもとに戻した文）

例 1	入力文	感知用と出力用の 2 基のコイル, 増幅器, 及び位相シフト回路からなる, 位相シフト磁気センサーシステムを開発している。
	参照訳	here was developed a phase shift magnetic sensor system composed of two sets of coils , amplifiers , and phase shifts for sensing and output .
	ベースライン	the phase shift magnetic sensor system consists of two **coil** , **amplifier** , and phase shift circuit , which **consists of two coils** for sensing and output .
	NERF	a phase shift magnetic sensor system consists of two ***coils*** , amplifier , and phase shift circuits for sensing and output .
	BPEF	a phase shift magnetic sensor system consists of two ***coils*** , ***amplifiers*** and phase shift circuits for sensing and output .
例 2	入力文	その結果, 電気光学特性として,V10=11.8V,V90=18V を得た
	参照訳	the electro - optical property obtained was V10 = 11.8V and V90 = 18V .
	ベースライン	as a result , we obtained V10 = 11.8 V , V90 = 18V as **an** electrooptic property .
	NERF	as a result , *the* electrical optical properties were obtained with V10 = 11.8 V and V90 = 18V .
	BPEF	as a result , V10 = 11.8V , V90 = 18V were obtained as *the* electrical optical properties .

は $\eta = 32,000$ とした．各フィルタリング手法において学習データ内の語彙サイズと文数は表 2 のようになった．ここで，削除文数のパラメータは BPEF に合わせて $n = 4,030$ としている．

ベースラインは，エンコーダデコーダモデルにアテンション機構を付加したモデル [Luong 15] をフィルタリング前のデータで学習させたものである．学習は 20 epoch 繰り返し，その中で開発データで測った BLEU スコアが最も高かったものを用いて評価した．両言語の単語ベクトルには学習用データを用いて word2vec[*8] を学習させて得た分散表現を用いた．モデルの各種パラメータは，埋め込み層の次元数及び隠れ層の次元数が 512，レイヤー数が 2 とした．また，最適化手法には AdaGrad を用いて初期学習率は 0.01 とし，ドロップアウト率 0.2 でドロップアウトを行う設定とした．

BPEF では，対象を原言語側とし，サブワード化と同様に語彙サイズを決定するパラメータを $\eta = 32,000$ とした BPE を用いた．削除文数を決定するパラメータ θ の値は，$\theta = 1.2$ としたときと $\theta = 1.5$ としたときの結果を比較する予備実験 [*9] を行い，$\theta = 1.5$ がより有効であったため，本実験ではこのパラメータを用いる．NERF では，対象を目的言語側とし，固有表現抽出の実装に Stanford の CoreNLP（Ver. 3.9.2）[*10] を使用した．固有表現の数は原言語側と目的言語側とで等しいと考えられるため，どちらを対象としても問題ないとみなした．

各手法の評価には自動評価と人手評価の双方を用いた．自動評価は，BLEU スコアと METEOR スコア及び参照訳の文長との二乗誤差によって行った．BLEU スコアは n-gram 適合率に基づいて翻訳の精度を評価する評価尺度で，翻訳の流暢性などを表し，METEOR スコアは類義語，語幹正規化，並べ替え情報などを考慮した評価尺度で，翻訳の妥当性などを表す．また，BLEU スコアと METEOR スコアは機械翻訳の仮説検定ツール [*11] を用いて算出し，ベースラインに対する統計的有意差の有無も合わせて調べた．人手評価は 2 人の評価者によって行い，各手法の出力結果からランダムに抽出した 100 文に対し，流暢性と妥当性をそれぞれ 1 から 3 の 3 段階で評価し，その算術平均を用いた．数字が大きいほど良い評価である．

3.2 実験結果

表 3 に実験結果を載せる．BLEU スコア及び METEOR スコアにおける「*」は有意水準 0.05 で有意差があることを示す．NERF と BPEF の両方でベースラインより BLEU スコアが 0.5 程度改善した．また，METEOR スコアが NERF で 0.1

*8 https://radimrehurek.com/gensim/models/word2vec.html
*9 本実験と異なり，ドロップアウトを行わず，レイヤー数を 1 とした．また，BPE 化の語彙サイズは $\eta = 32,000$ 及び $\eta = 64,000$ とし，英語側と日本語側で合わせず別々に行った．その他の設定は本実験と同様である．
*10 https://stanfordnlp.github.io/CoreNLP/
*11 https://github.com/jhclark/multeval

表 2: 各手法で使用する学習データの語彙サイズと文数

フィルタリング手法	語彙サイズ		文数
	原言語	目的言語	
ベースライン	26,578	19,755	977,367
NERF	26,526	19,754	973,337
BPEF	26,453	19,753	973,337

表 3: 各手法の自動評価及び人手評価

手法	BLEU	METEOR	流暢性	妥当性
ベースライン	23.3	29.7	2.49	2.31
NERF	*23.8	29.8	2.54	2.35
BPEF	*23.8	*30.0	2.48	2.30

程度，BPEF で 0.3 程度改善した．人手評価では，流暢性と妥当性の双方において BPEF はベースラインとほぼ変わらず，NERF は 0.05 程度改善した．フィルタリングにより翻訳結果を向上させることができている．さらに，各手法における出力の参照文に対する文長の二乗誤差は，ベースライン，NERF，BPEF それぞれ，33.9，30.9，31.5 であった．

4. 分析と考察

4.1 削除した文の分析

削除した文中の文字 1-gram と文字 2-gram のサブワードの上位 20 件を図 1 に示す．NERF と BPEF の特徴を見るために学習データから抽出したランダムな 4,030 文と合わせて比較する．固有表現抽出と BPE によるフィルタリングでフィルタリングされたサブワードの数に注目すると，ランダムな 4,030 文に比べて大幅に多いことがわかる．これは，削除した文の中には BPE を適用したときに 1 文字か 2 文字の細かいサブワードが出るような細かい分割が多く行われていることによる．どちらにおいても “.” が多いのは，*the U.S.A.* など，固有表現に “.” を含む固有名詞が多いからであると考えられる．

4.2 出力結果の考察

表 1 に出力例を載せる．例 1 のベースラインの出力を見ると，本来複数形として出力するべき単語を単数形として出力している翻訳ミスや，同じフレーズを繰り返し出力している翻訳ミスが見受けられる．それに対して NERF や BPEF ではこれらの箇所に改善が見られた．また，例 2 のベースラインの出力を見ると，本来 *the* と出力するべき部分を *an* と誤って出力してしまっているが，どちらの提案手法でも正しく *the* と出力できていることがわかる．

翻訳改善の理由として，複数形や冠詞以外の意味を持つ，固有表現がサブワード化されて出現した *s* や *an* を含む文を一部取り除くことで，*s* や *an* の複数形や冠詞としての意味をモデルがより正しく学習できたことが考えられる．今回の実験結果では BLEU も METEOR も向上しているが，METEOR の改善が小さいことがわかる．METEOR スコアは妥当性を測ることのできる評価尺度であるため，妥当性より流暢性のほうが改善していると考えられる．人手評価でも NERF において流暢性のほうがわずかに上がり幅が大きいことが確認できる．妥当性が低い出力結果を見ると，*strut-screw* を *but screw* や *snut screw* と誤って出力している例があった．これは *strut* が *str* と *ut* に分かれ，*str* のほうだけうまく翻訳ができていなかったものであり，言語による BPE のかかり方の違いも関わってくると考えられる．

また，参照文との文長の二乗誤差を見ると，どちらの提案手法でもベースラインに比べて小さくなっており，出力する文長が参照文に近づいていることがわかる．このことから，固有表現を多く含む文，つまり BPE をかけたときにトークン数が増加する文を取り除いたことで，翻訳モデルの出力文長がより正しく学習できたことが考えられる．

5. 関連研究

これまでにも機械翻訳におけるパラレルコーパスのフィルタリングに関する研究が行われている．例えば外れ値検出アルゴリズムを用いてパラレルコーパスをフィルタリングする研究 [Kaveh 11] や，文対の意味の違いを識別することに焦点を当てたフィルタリングの研究 [Carpuat 17] がある．また，パラレルコーパスに様々なノイズを与えてその影響を調べる研究 [Khayrallah 18] も行われている．Khayrallah らはニューラル機械翻訳が統計的機械翻訳に比べてノイズによる悪影響を受けやすいことを示している．

6. おわりに

本論文では，ニューラル機械翻訳におけるコーパスフィルタリングに関する分析について報告した．固有表現抽出を用いる方法と BPE を用いる方法の 2 種類で学習コーパスのフィルタリングを行った．フィルタリングを行わない場合とともに日英翻訳の実験を行ったところ，BLEU スコアの 0.5 ポイントの上昇を確認した．この理由を分析したところ，複数形の有無や冠詞の間違い，誤った文長で出力される問題などが一部改善されたことが分かった．今後は異なる言語対での実験を行い，言語ごとの有効性の違いを検証していきたい．

参考文献

[Carpuat 17] Carpuat, M., Vyas, Y., and Niu, X.: Detecting Cross-Lingual Semantic Divergence for Neural Machine Translation, in *WNMT* (2017)

[Kalchbrenner 13] Kalchbrenner, N. and Blunsom, P.: Recurrent Continuous Translation Models, in *EMNLP* (2013)

[Kaveh 11] Kaveh, T., Shahram, K., and Jia, X.: Parallel corpus refinement as an outlier detection algorithm, in *MT Summit* (2011)

[Khayrallah 18] Khayrallah, H. and Koehn, P.: On the Impact of Various Types of Noise on Neural Machine Translation, in *WNMT* (2018)

[Luong 15] Luong, T., Pham, H., and Manning, C. D.: Effective Approaches to Attention-based Neural Machine Translation, in *EMNLP* (2015)

[Nakazawa 16] Nakazawa, T., Yaguchi, M., Uchimoto, K., Utiyama, M., Sumita, E., Kurohashi, S., and Isahara, H.: ASPEC: Asian Scientific Paper Excerpt Corpus, in *LREC* (2016)

[Sennrich 16] Sennrich, R., Haddow, B., and Birch, A.: Neural Machine Translation of Rare Words with Subword Units, in *ACL* (2016)

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

AIの発達で資本主義が崩壊し、解放主義社会へと移行する

Due to the development of artificial intelligence capitalism collapses and emancipationism comes.

小野盛司
Seiji Ono
日本経済復活の会
Association for Japanese Economic Recovery

吉野守
Mamoru Yoshino
日本経済復活の会
Association for Japanese Economic Recovery

In future AI is taking away most of people's jobs. A universal basic income is proposed to cope with such situation, but the problem is that huge financial resources are needed and motivation at work is lost. To solve these problems we propose emancipationism.

1. 概要

将来AI／ロボットが大半の雇用を奪ってしまうと言われている。そのときはベーシックインカムという方法が提案されているが、巨額の財源が必要になる問題と労働意欲の喪失が欠点とされている。その両者を解決するために解放主義社会を提案する。

2. ベーシックインカムの問題点

AIの進歩は著しい。数十年後には雇用はほぼすべてAI／ロボットに奪われていると予想される。ロボットばかりの巨大な独占企業は労働者を雇わなくても良く、莫大な利益を上げ規模が拡大し続け、国への影響力もつけてくる。一方で労働者は不要となり、失業者が激増し資本主義社会が崩壊する。そこでは人間はAI／ロボットではできないような仕事を探さなければならないのだろうか。AI／ロボットが究極まで進化した場合、一般人がそのような仕事を見つけるのはほぼ不可能である。そうであれば、多くの人は失業し「働かざる者食うべからず」ということなら、大部分の人は飢え死にしなければならない。小さな政府が良いのだと決めつけ、市場を神の見えざる手に任せておけば良いと考えていたら、人類の未来は地獄だ。しかしながら、国が何らかの方法で国民にお金を配ることさえできれば誰もが安心して生活できる。だから国民全員一律に一定額を配布するというベーシックインカムという方法が提案されている。しかしその場合労働意欲が失われ、巨額の財源を確保するのが難しいという問題がある。大増税で財源を確保せよという意見【原田（2015）、井上（2018）】もあるが大増税により労働意欲は失われる。そもそも税率というもの高くすればいくらでも税収は増えるというわけでもなく、ある限度を超えると逆に税収は減少し始める。これはラッファーカーブという名前で知られている。また税の補足率は業種によって大きく変わるのだから、強い不平等感が生まれ脱税・節税により税逃れの風潮が広がる。一方鈴木（2017）ではロボットに給料を払う案が検討されている。しかしロボットの定義が難しく各事業所で勝手に定義しても妥当性の確認は極めて難しい。

連絡先：小野盛司、日本経済復活の会、文京区千駄木5－42－5 プルミエ千駄木203、TEL 03－3823－5233、 FAX 03－5685－3317

3. 解放主義社会

小野（2005）は究極的には国が自ら稼ぐことを考えるべきだと主張する。例えば国がAI開発に巨額投資をし、重要な特許を押さえてしまえば、やがて巨額な利益を得る。未来社会においてAI／ロボットばかりいて人を雇わない独占巨大企業が次々と登場したとし、それらの株を国が買い進め国有化したとしよう。国は通貨発行権を持っており買収資金は無尽蔵にある。労働者への賃金は払う必要がないのだから莫大な利益が生じ、その利益を国民に還元すればよい。労働はすべてAI／ロボットに任せ、人間は各人が生き甲斐を感じることが出来る仕事ができるようなシステムを政府がつくり公務員として雇えば良い。例えば作家、タレント、小説家、俳優、評論家、記者、料理人、デザイナー、科学者、哲学者、研究者、発明家、音楽家、カメラマン、芸術家、陶芸家、園芸家、棋士、落語家、プロスポーツ、教師、等がある。現代では、このような職に就こうと思えば競争に勝たなければならないが解放主義社会では競争に勝てなくても自分が好きな職業に就けるようにする。社会主義あるいは共産主義社会では平等を重んじ、弱い立場の労働者の権利を守ろうとした。その結果頑張る人も頑張らない人も平等に扱われた。それなら頑張らなくてもいいいと人は考え生産性が落ちて国全体が貧乏になった。ベーシックインカムと違い解放主義では頑張る人の報われる社会である。ただし希望すれば誰でも公務員になれるという意味で最低限の収入が保証されるという点はベーシックインカムの考えは入っている。必要に応じ国が国民のために雇用をつくる。このことを JOD（Job-on-Demand）と呼ぶことにする。ベーシックインカムのようにお金だけ出して、好きにしてくれと言われただけでは人は幸福になるとは限らない。自分がやりたいことがやれて始めて幸せになれる。それを実現するのがJODである。

4. 政府・日銀も AI 化

ベーシックインカムという方法では、国民全員に同じ金額を毎月支給するので、行政コストが安いとい

うのがメリットとされる。しかし、大増税のため税逃れをする人が激増し、その取締のためのコストは巨額になる。未来社会では行政もAI化され、コストはほとんどかからない。各人の仕事ぶりがデータ化されそれをAIが評価し、給料を決めるのだが最低の給料でも十分暮らしていける。例えば多くのファンを持つ歌手であれば、収入が多いのは現在と変わらない。コンサートで入場料を取り、その一部が歌手の収入となる。ヒット曲の出ない歌手であっても、暮らしていけるし時々国主催のコンサートを開いて貰える。聴衆が少なすぎるときはロボットに協力してもらえばよい。人間そっくりのロボットが歌手としてデビューするから人間のプロ歌手のライバルとなる。国は豊富な財源を持つので、様々な分野の研究を大々的に行うようになる。ただし研究においてもAI／ロボットが人間を上回るようになる可能性はある。

各人の給料は、様々な要素を調べ回帰分析で AI が決定する。給料を決定する要素としては ①労働時間 ②その仕事が社会的にどれだけ必要とされているか ③他の人からどのように評価されているか ④例えばプロ野球の野手なら打率、ホームランの数、盗塁数など⑤他に収入があるかなどである。最低限の収入を保証されているが頑張れば収入が上がるのでインセンティブになる。自分で十分稼げるなら公務員にならなくてもよい。公務員でありながら別の仕事で稼いでもよいが副業と公務員の収入の合計がいくらになるかは AI が判断する。AIはどのようにすれば国民が最も幸せになるのかを判断し給料を決める。

政府や日銀のAI化も進めていく。現在の日本政府は国の借金を減らすことばかりを考えている。これは政府の重大な判断ミスであり、これが日本経済を衰退させている。実際日本の対外純資産は世界一であり、世界一の金持ちの国なのだから、政府はもっとお金を使っても良い。AIならこのような初歩的なミスはあり得ない。国の借金が今の10分の1であり財政は全く健全であった1982年に政府は財政非常事態宣言を出している。

http://ajer.cocolog-nifty.com/blog/2018/12/no327-c485.html

そもそも国の借金というものは誤解されている。日本の国の借金は過去コンスタントに増え続け、過去130年間で500万倍になっている。借金は次の世代が返済するものでなく、どの世代も増やし続けるものである。

http://ajer.cocolog-nifty.com/blog/2018/05/no301-a00c.html

国は通貨発行権を持っており国は借金をする代わりに通貨を発行して経済活性化を助けることもできた。経済成長には通貨を増やしていくことが必要であり、それは成長通貨と呼ばれる。実際江戸時代には毎年のように通貨増発（改鋳）を行い経済を活性化させていた。

http://ajer.cocolog-nifty.com/blog/2013/12/post-7af5.html

通貨増発を始めると止められなくなり、最終的にはハイパーインフレになると言われることがある。これは人間が行った場合であり、AIが経済政策を行う場合は全くその心配はない。日本経済は政府がバブルを崩壊させて以来現在まで経済成長はほぼストップした。これは完全な政策ミスであり、もしAIが経済政策を担当していたら今頃日本のGDPは現在の約2倍になっていたと考えられ、AIに経済政策を任せる意義はきわめて大きい。歴史的に見ても、人間の行った経済政策は失敗が多い。世界大恐慌、デフレ、ハイパーインフレ、株の暴落、財政破綻など失敗の繰り返しであり、それらを過度に警戒して経済を長期停滞させた日本のような例もある。AIならそのような馬鹿な失敗はあり得ない。

国民の声を政治に反映させるという意味においても現在はうまくいっていない。国民のごく一部が政治家に陳情し、そのうちのごく一部が行政に反映されるだけで、強力な圧力団体を持つ場合が特に優遇される。未来における解放主義社会では政府はAI化され、国民全員がネットで陳情できる。膨大な陳情データをAIが分析し、国民の幸福を最大化する予算配分を定める。景気刺激のためには公務員の給料を引き上げれば良く、不況にはならないし、国民に不安を与えない。死ぬまで公務員給与は支払われるから年金も不要となる。解放主義社会への移行は時間を掛けて行われ、社会保障制度も時間をかけて変えていけば良い。

社会主義思想では平等な社会を目指し、労働者の権利を守ることに重点が置かれたが、未来の解放主義社会では、AI／ロボットの登場により生活費を稼ぐための労働からの解放、貧困からの解放をする。

5. 結論

雇用の大半がAI／ロボットにより奪われてしまった未来社会において、ベーシックインカムはうまく機能しない。税の補足率は業種により大きく異なるのだから、可処分所得に極端な差が生じ可処分所得に極めて大きな不公平感が出てきてしまう。それと異なり解放主義社会においてはこの困難を克服でき、しかも国は国民が希望する職を準備するから充実した生活を過ごすことが出来る。

参考文献

原田泰（2015）「ベーシック・インカム：国家は貧困問題を解決できるか」中公新書
井上智洋（2018）「AI時代の新・ベーシックインカム論」光文社新書
鈴木貴博（2017）「仕事消滅」講談社＋α新書
小野盛司（2005）「労働はロボットに、人間は貴族に」ナビ出版

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

スパイキングニューロンモデルを用いた 質問応答システムにおけるホログラフィック圧縮表現の評価

Evaluation of Holographic Reduced Representations in Question-Answering System using Spiking Neuron Model

岩尾 桂志 *1 Keiji Iwao　ライチェフ・ビセル *1 Bisser Raytchev　玉木 徹 *1 Toru Tamaki　金田 和史 *1 Kazufumi Kaneda

*1広島大学大学院 工学研究科 情報工学専攻
Graduate School of Engineering, Hiroshima University

Symbolic reasoning is an important ability of the brain. Symbolic structures can be represented as distributed representations with binding operations. We aim to extend a conventional model for word or phrase level reasoning to sentence level reasoning and to find the optimal distributed representation for processing structural representations such as languages in a biological brain model under noise. We construct a spiking neuron model which can answer answer questions about a group of sentences. We employed Holographic Reduced Representations (HRRs) to prevent the increasing of vector dimensionality for binding operations. Experimental results show that our model can select an appropriate sentence for question-answering even in similar sentences. Experiments suggest that a noise-robust structural representations for languages can be realized by changing the role vector depending on the depth of the structure and by embedding a verb into a role vector and removing the predicate part.

1. 背景・目的

認知科学におけるアプローチの一つに，シンボル的アプローチがある．これは，人間が視覚や聴覚などで得られた実世界の連続的情報を言語というシンボルとして表現し，論理的思考を行なっていると仮定したアプローチである．シンボルの羅列を言語的に理解するために，個々の単語のシンボルをフィラー，その単語の役割をロールとし，フィラーとロールのバインディングを用いて，全体の構造表現を実現することが多い [Eliasmith 13]．しかし，実際の脳での論理的思考は，不完全な入力情報や変動する状況下においても巧みに動作する．そのため，シンボルを分散表現に符号化し，ノイズ条件下においてシンボル的処理が行われなければならない．Gayler らは，シンボル構造を分散表現に符号化する Vector Symbolic Architecture（VSA）を提案した [Gayler 03]．その中でも，Plate らのホログラフィック圧縮表現（Holographic Reduced Representations: HRRs）[Plate 94] では，巡回畳み込みによるバインディング操作を用いることで，バインディングによるベクトル次元の増加を防ぎつつ，言語表現におけるシンボル的処理が可能であることが示された．また，脳は皮質，基底核，視床において，入力の刺激情報と，脳の状態に応じて適切な処理を選択する行動選択（Action Selection）を行なっている．Eliasmith らは，行動選択をスパイキングニューロンモデルで実装し，脳の状態に応じた適切なシンボル的推論を HRRs により実現できることを示した [Eliasmith 10]．しかし，このモデルでは，実際の言語表現に見られるような，深い構造を持つ複雑な言語表現，及び構造的に類似した複数の知識表現に対しての有効性は示されていない．

そこで本論文では，言語構造から成る複数の類似した知識表現を記憶し，その中のある一つの知識に対する質問に対してシンボル的推論を行い，適切な応答を返すスパイキングニューロンモデルを提案することを目的とする．また，モデルを用いた実験結果から，質問応答システムにおける知識構造の最適な表現について考察する．まず，次節でスパイキングニューロンモデルを実装するための，Eliasmith らが提案した NEF（Neural Engineering Framework）[Eliasmith 03] について説明し，3 節で，HRRs 及び言語構造的知識の表現方法について説明する．その後，4 節で，従来モデルを拡張するための提案手法について説明する．最後に，モデルの精度を検証するための実験と結果から，言語や知識表現などの構造表現における最適な表現について考察する．

連絡先: 岩尾桂志，広島大学大学院 工学研究科 情報工学専攻，keiji-iwao@hiroshima-u.ac.jp

2. NEF

本論文では，Eliasmith らの NEF（Neural Engineering Framework）というフレームワークを用いてスパイキングニューロンモデルを実装する．NEF では，ニューロン集団は，情報となるベクトル値を入力として受け取り，スパイクを介したエンコーディング・デコーディング過程により情報を保持する．エンコーディングは，式 (1) で表される．

$$a_i(\boldsymbol{x}) = \sum_m \delta(t - t_{im}) \tag{1}$$

ここで，a はニューロンの活動，$\boldsymbol{x}$ は入力ベクトル，m はスパイクのインデックス，i はニューロンのインデックスである．また，デコーディングは，式 (2) で表される．

$$\hat{\boldsymbol{x}} = \sum_{i,m}^{N,M} h_i(t - t_{im})\boldsymbol{d}_i \tag{2}$$

ここで，$\hat{\boldsymbol{x}}$ は $\boldsymbol{x}$ のデコーディング結果，N はニューロン数，M はスパイク数，i はニューロンのインデックス，m はスパイクのインデックス，$h(t)$ はシナプス後電流（Post Synaptic Current : PSC），$\boldsymbol{d}_i$ はデコーディングベクトルである．また，本論文では，Leaky-Integrate and Fire（LIF）ニューロンを用いた．LIF ニューロンの発火頻度は，入力の大きさによって変化し，神経調和曲線に基づいて決定するが，詳細な説明は省略する [Bekolay 14]．

3. シンボル構造表現の分散表現

3.1 ホログラフィック圧縮表現

HRRs は，バインディング操作に巡回畳み込みを用いる VSA の一つである．一般に，n 次元の 2 つのベクトル $\boldsymbol{c}$ と $\boldsymbol{x}$ の巡回畳み込み結果 $\boldsymbol{t}$ の j 番目の要素は，次式で表される．

$$t_j = \sum_{k=0}^{n-1} c_k x_{j-k} \tag{3}$$

また，$\boldsymbol{t}$ を $\boldsymbol{c}$ でアンバインディングした結果 $\boldsymbol{y}$ の j 番目の要素は次式で表される．

$$y_j = \sum_{k=0}^{n-1} c_k t_{k+j} \tag{4}$$

ベクトル $\boldsymbol{c}$ 及び $\boldsymbol{x}$ を，大きさ 1，要素が平均 0，分散 $\frac{1}{n}$ の正規分布 $N(0, \frac{1}{n})$ に従うように取ることで，$\boldsymbol{y} = \boldsymbol{x} + \boldsymbol{noise} \approx \boldsymbol{x}$ となり，シンボル的推論を固定長ベクトルで実現できる．

3.2 構造表現

本論文で用いる知識表現は，主語，述語，目的語からなる文表現で考慮する．例として，“The dog chases the boy.”という文は，次のように表すことができる．

$$S1 = Agent * Dog + Verb * Chase + Object * Boy \tag{5}$$

ここで，$*$ はバインディングである．各シンボルにベクトルを割り当て，Dog，$Chase$，Boy などのフィラーベクトルと $Agent$，$Verb$，$Object$ などのロールベクトルを，式 (3) の巡回畳み込みによるバインディングを用いることで，文をベクトルで表現する．また，式 (4) により，文表現からシンボルを抽出する．

$$S1 \otimes Object \approx Boy \tag{6}$$

ここで，$\otimes$ はアンバインディング記号である．シンボル構造の特徴は，構造表現を効率的に表現できることである．“The dog chases the boy who has a ball.”という文は，次のように表される．

$$\begin{aligned} S2 = {} & Agent * Dog + Verb * Chase + Object * \\ & (Agent * Boy + Verb * Play + Object * Ball) \end{aligned} \tag{7}$$

また，アンバインディングにより，文そのものを推論することも可能である．

$$S2 \otimes Object \approx Agent * Boy + Verb * Play + Object * Ball \tag{8}$$

4. モデル

図 1 にモデルの概要を示す．まず，入力である文章を $text\_input$ より，ラベル用ベクトル STATEMENT-n を加えて入力する．$text\_input$ は順に入力される文を表現し，フィードバック要素を持つニューロン集団 $m1$ から $m20$ のいずれかへ送る．この際，基底核 $bg1$ 及び視床 $thal1$ の行動選択により，各入力文は異なるニューロン集団に送られ，記憶される．ここで本論文では，20 文からなる文章を用いるため，文章を記憶するためのニューロン集団 m を 20 個定義した．
全ての文が入力された後，質問を入力する．ここで，質問とは，アンバインディングに用いられるベクトルを指し，$text\_input$ から入力され $question$ へ送られる．また，質問入力と同時間，適切な文を選択するためのベクトルを cue_input より入力する．この際，基底核 $bg2$ 及び視床 $thal2$ により，式 (9) で表される内積が最大となる n を決定し，対応する $memory\_n$ を $question$ でアンバインディングした結果を out へ送る．ここで $Sentence\_n$ は，n 番目の文ベクトルを表す．

$$n^* = \underset{1 \le n \le 20}{\operatorname{argmax}}\, dot(cue\_input, Sentence[n]) \tag{9}$$

表 1 に，式 (5) を入力文章とした例のシミュレーションの流れを示す．

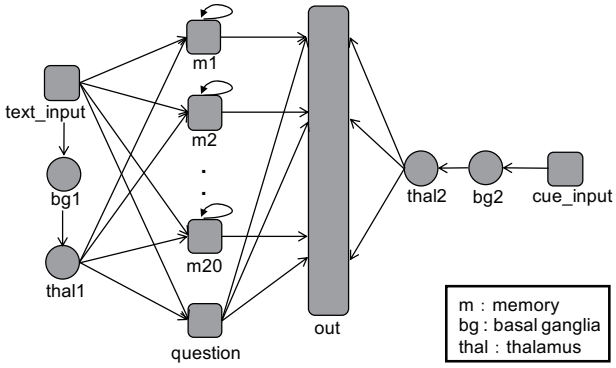


Figure 1: 本論文で用いるスパイキングニューロンモデル

5. 実験

本論文では，文の構造の深さを 1 から 4 の 4 レベルとし，各レベルに対してそれぞれ異なる 5 文，計 20 文を用いる．まず，名詞 500 単語（$\boldsymbol{N1, ...N500}$），及び動詞 500 単語（$\boldsymbol{V1, ..., V500}$）に対し，$N(0, \frac{1}{n})$ に従うランダムなベクトルをフィラーベクトルとして割り当てる．フィラーベクトルにバインディングするロールベクトルや後述する ID（Identity）ベクトルもまた，同条件で定義する．

実験では，以下で説明する条件 A～ 条件 H の表現方法を用いて 20 文を表現する．ここで条件 A～C が従来の表現方法，D～H がオリジナルの表現方法である．

- 条件 A : ロールベクトルには，$Agent1$，$Verb1$，$Object1$ の 3 個のみ用いる．
- 条件 B : 文の深さごとに異なるロールベクトルを割り当てるため，ロールベクトルには，$Agent1 \sim Agent4$，$Verb1 \sim Verb4$，$Object1 \sim Object4$ を用いる．$1 \sim 4$ は文内の深さに対応する．
- 条件 C : 述語部のロールベクトル $Verb$ を除去し，$Agent$，$Object$ をそれぞれ $Agent\_\{Vn\}$，$Object\_\{Vn\}$ に次のように置き換えることで，ベクトル $\boldsymbol{V}$ が動詞の役割を持つことを示す．

$$Agent\_\{Vn\} = (Agent + ID\_\{Vn\_agt\})/\sqrt{2} \tag{10}$$

$$Object\_\{Vn\} = (Object + ID\_\{Vn\_obj\})/\sqrt{2} \tag{11}$$

条件 D～H は，ロールベクトル $Verb$ 及び動詞 Vn を，$Agent\_\{Vn\}$，$Object\_\{Vn\}$ に埋め込む．

Table 1: $\boldsymbol{Agent} * \boldsymbol{Dog} + \boldsymbol{Verb} * \boldsymbol{Chase} + \boldsymbol{Object} * \boldsymbol{Boy}$ を入力文とした際のシミュレーション例

時間	text_input	cue_input	question	正答
$0 < t < 0.2$	$\boldsymbol{Agent} * \boldsymbol{Dog} + \boldsymbol{Verb} * \boldsymbol{Chase} + \boldsymbol{Object} * \boldsymbol{Boy}$	None	None	None
$0.2 < t < 0.4$	None	$\boldsymbol{Verb} * \boldsymbol{Chase} + \boldsymbol{Object} * \boldsymbol{Boy}$	$\boldsymbol{Agent}$	$\boldsymbol{Dog}$
$0.4 < t < 0.6$	None	$\boldsymbol{Agent} * \boldsymbol{Dog} + \boldsymbol{Verb} * \boldsymbol{Chase}$	$\boldsymbol{Object}$	$\boldsymbol{Boy}$

・Sentence1：Agent1＊N1 + Verb1＊V1 + Object1＊N2
・Sentence2：Agent1＊N3 + Verb1＊V2 + Object1＊
(Agent1＊N4 + Verb1＊V3 + Object1＊N5)
・Sentence3：Agent1＊N6 + Verb1＊V4 + Object1＊
(Agent1＊N7 + Verb1＊V54 + Object1＊
(Agent1＊N8 + Verb1＊V6 + Object1＊N9))
・Sentence4：Agent1＊N10 + Verb1＊V7 + Object1＊
(Agent1＊N11 + Verb1＊V8 + Object1＊
(Agent1＊N12 + Verb1＊V9 + Object1＊
(Agent1＊N13 + Verb1＊V10 + Object1＊N14)))

(a) a の例文

・Sentence1：Agent1＊N1 + Verb1＊V1 + Object1＊N2
・Sentence2：Agent1＊N3 + Verb1＊V2 + Object1＊
(Agent2＊N4 + Verb2＊V3 + Object2＊N5)
・Sentence3：Agent1＊N6 + Verb1＊V4 + Object1＊
(Agent2＊N7 + Verb2＊V5 + Object2＊
(Agent3＊N8 + Verb3＊V6 + Object3＊N9))
・Sentence4：Agent1＊N10 + Verb1＊V7 + Object1＊
(Agent2＊N11 + Verb2＊V8 + Object2＊
(Agent3＊N12 + Verb3＊V9 + Object3＊
(Agent4＊N13 + Verb4＊V10 + Object4＊N14)))

(b) b の例文

・Sentence1：Agent_{V1}＊N1 + V1 + Object_{V1}＊N2
・Sentence2：Agent_{V1}＊N3 + V1 + Object_{V1}＊
(Agent{V2}＊N4 + V2 + Object_{V2}＊N5)
・Sentence3：Agent_{V1}＊N6 + V1 + Object_{V1}＊
(Agent{V2}＊N7 + V2 + Object_{V2}＊
(Agent_{V3}＊N8 + V3 + Object_{V3}＊N9))
・Sentence4：Agent_{V1}＊N10 + V1 + Object_{V1}＊
(Agent{V2}＊N11 + V2 + Object_{V2}＊
(Agent_{V3}＊N12 + V3 + Object_{V3}
＊(Agent_{V4}＊N13 + V4 + Object_{V4}＊N14)))

(c) c の例文

・Sentence1：Agent_{V1}＊N1 + Object_{V1}＊N2
・Sentence2：Agent_{V1}＊N3 + Object_{V1}＊
(Agent{V2}＊N4 + Object_{V2}＊N5)
・Sentence3：Agent_{V1}＊N6 + Object_{V1}＊
(Agent{V2}＊N7 + Object_{V2}＊
(Agent_{V3}＊N8 + Object_{V3}＊N9))
・Sentence4：Agent_{V1}＊N10 + Object_{V1}＊
(Agent{V2}＊N11 + Object_{V2}＊
(Agent_{V3}＊N12 + Object_{V3}
＊(Agent_{V4}＊N13 + Object_{V4}＊N14)))

(d) d～h の例文

Figure 2: 各表現方法における例文

- 条件 D：各ロールベクトルには，述語のフィラーベクトルとの和を用いる．

$$Agent\_\{Vn\} = (Agent + Vn)/\sqrt{2} \quad (12)$$

$$Object\_\{Vn\} = (Object + Vn)/\sqrt{2} \quad (13)$$

- 条件 E：各ロールベクトルには，述語フィラーベクトルとの巡回畳み込みを用いる．

$$Agent\_\{Vn\} = Agent * Vn \quad (14)$$

$$Object\_\{Vn\} = Object * Vn \quad (15)$$

- 条件 F：各ロールベクトルには，深さによって区別した各ロールベクトルと述語フィラーベクトルの和を用いる．

$$Agent\_\{Vn\} = (Agent\_n + Vn)/\sqrt{2} \quad (16)$$

$$Object\_\{Vn\} = (Object\_n + Vn)/\sqrt{2} \quad (17)$$

- 条件 G：各ロールベクトルには，深さによって区別した各ロールベクトルと述語フィラーベクトルの巡回畳み込みを用いる．

$$Agent\_\{Vn\} = Agent\_n * Vn \quad (18)$$

$$Object\_\{Vn\} = Object\_n * Vn \quad (19)$$

- 条件 H：各ロールベクトルには，深さによって区別し重み付けされた各ロールベクトルと述語フィラーベクトルとの和を用いる．

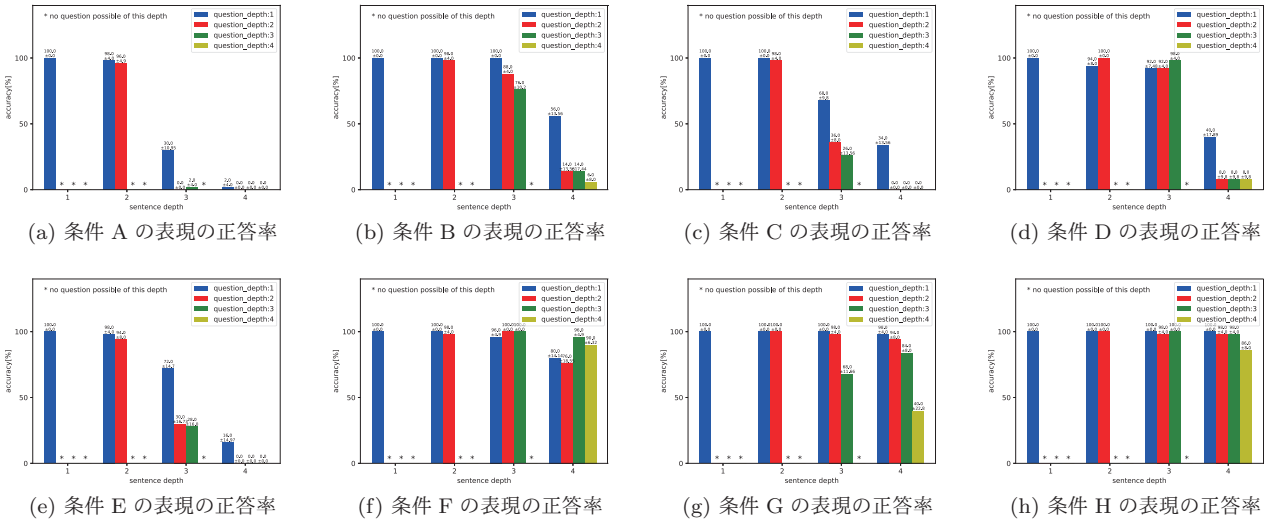
$$Agent\_\{Vn\} = (2 \times Agent\_n + Vn)/\sqrt{3} \quad (20)$$

$$Object\_\{Vn\} = (2 \times Object\_n + Vn)/\sqrt{3} \quad (21)$$

各文および各質問の入力時間は，1 つあたり 0.2[s] とした．表 1 に，“The dog chases the boy.”という 1 文のみが入力文章であり，条件 A で表現した場合のシミュレーションの流れを例として示す．質問は，例における Dog や Boy など，入力文の主語部及び目的語部に対するすべての質問を考慮する．前述の通り，実験には 20 文を用いて，合計 100 個の質問を考慮した．各質問の入力終了時点におけるニューロン集団 *out* が表現したベクトルと，ネットワーク内の全てのフィラーベクトルとの類似度を計算し，最大類似度のベクトルをモデルの出力とする．各条件に対して，24[s] のシミュレーションをそれぞれ 5 回行ない，正答率の平均値で評価した．

5.1 結果・考察

各条件における正答率を表したグラフを図 3 に示す．横軸は文の深さレベル，縦軸は正答率を表す．また，質問の難易度を示すため，文の深さレベルだけでなく質問の深さレベルによって正答率を示した．図 3a と図 3b，図 3d と図 3f，図 3e と図 3g の比較から，構造の深さによって異なるロールベクトルを用いた方が正答率が高いことがわかる．これは，同じロールベクトルを用いると文同士の類似度が大きくなるため，式 (9) に



(a) 条件 A の表現の正答率　(b) 条件 B の表現の正答率　(c) 条件 C の表現の正答率　(d) 条件 D の表現の正答率

(e) 条件 E の表現の正答率　(f) 条件 F の表現の正答率　(g) 条件 G の表現の正答率　(h) 条件 H の表現の正答率

Figure 3: 各表現方法の正答率

おいて誤った行動に対応する内積が最大になるからだと考えられる．また，図 3c と図 3d から，述語のフィラーベクトルをロールベクトルに埋め込むことで，類似した文の類似度を抑えることができることがわかる．図 3f では，複雑な文において，複雑な質問より簡単な質問の方が正答率が低くなっている．この原因として，式 (16)，(17) の Agent_{Vn} と Object_{Vn} が類似するため，Agent_{Vn} によるアンバインディング結果だけでなく，Object_{Vn} によるアンバインディング結果も同時に出力されるためだと考えられる．しかし，図 3g から，複雑な質問に対しては，巡回畳み込みより加算によるロールベクトルを用いた方が正答率が高くなることがわかる．巡回畳み込みによるロールベクトルが複雑な質問において有効でない理由として，一般的に巡回畳み込み結果が元のベクトルとのどちらとも類似しないベクトルにマッピングされることが原因として考えられる．ベクトル次元を増加させることが対策として考えられる．さらに，図 3h では，全体的な平均正答率が良く，分散も抑えられていることがわかる．これは，式 (20)，(21) のように，Agent_{Vn} と Object_{Vn} に共通する述語フィラーベクトル Vn を相対的に弱める重み付けをすることで，Agent_{Vn} と Object_{Vn} をより区別できるからだと考えられる．

6. おわりに

本論文では，文表現に対するシンボル的推論において，複数の知識表現から質問に関連する文を取り出して推論するモデルを提案した．また，生物学的なノイズ条件下においても有効な表現方法を実験によって評価した．複数の類似した表現に対しては，バインディングするロールベクトルを可能な限り区別することで，ノイズ条件下でも有効な表現が実現できることがわかった．本論文では，各シンボルに対して割り当てるベクトルを，どの二つも類似度が 0.1 以下，つまり意味的に類似しないようにランダムに定義している．今後の課題として，Word2Vec[Mikolov 13] などの意味的な類似度を分散表現に埋め込んだベクトルや，SNN において最適化されたランダムベクトル [Gosmann 16] を用いた場合の実験を行う必要がある．

References

[Bekolay 14] Bekolay, T., et al.: Nengo: A Python tool for building large-scale functional brain models, *Frontiers in Neuroinformatics* (2014)

[Eliasmith 03] Eliasmith, C., Anderson, C. H.: Neural Engineering: Computation, Representation, and Dynamics in Neurobiological Systems *MIT press* (2003)

[Eliasmith 10] Stewart, T. C., Choo, X., and Eliasmith, C.: Symbolic Reasoning in Spiking Neurons: A Model of the Cortex/Basal Ganglia/Thalamus Loop, *In 32nd Annual Meeting of the Cognitive Science Society*, Austin, TX: Cognitive Science Society (2010)

[Eliasmith 13] Eliasmith, C.: How to Build a Brain: A Neural Architecture for Biological Cognition, *Oxford University Press* (2013)

[Gayler 03] Gayler, R.: Vector Symbolic Architectures answer Jackendoff's challenges for cognitive neuroscience, *ICCS/ASCS, International Conference on Cognitive Science*, Sydney, Australia: University of New South Wales, pp. 133-138 (2003)

[Gosmann 16] Gosmann, J. and Eliasmith, C.: Optimizing Semantic Pointer Representation for Symbol-Like Processing in Spiking Neural Network, *PLoS ONE* 11(2): e0149928. doi: 10.1371/journal.pone.0149928 (2016)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient estimation of word representations in vector space, *ICLR, International Conference on Learning Representations 2013* (2013)

[Plate 94] Plate, T.: Holographic reduced representations, *Stanford, CA:CSLI Publication* (1994)

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

即時戦略ゲームにおけるAI学習プラットフォームの構築及びDQNによるAIの実装

AI Trainning Platform and AI Implementation with DQN for Realtime Strategy Game

張 翌坤 *1 Zhang Yikun　橋山 智訓 *1 Hashiyama Tomonori　田野 俊一 *1 Tano Shun'ichi

*1電気通信大学 情報理工学部
Dept. of Informatics, The University of Electro-Communications

Research on video game AI has been done for a long time. In recent years, due to the rapid development of neural networks, the game AI which was considered difficult to build has appeared. After these AI beat humans in turn based games with complete information, such as GO, the next research direction has been focused on simultaneous games with incomplete information. The RTS game is one of the simultaneous-move games with incomplete information; therefore, in this paper we report the design of a platform for AI learning in the RTS game whose mechanism has been simplified. In addition, we implemented an AI for this type of game, and carried out some experiments.

1. はじめに

ゲーム AI は、AI 研究の早い段階から研究対象となってきた。コンピュータの性能の上昇と共に、現在では様々なゲームで人間に勝利するようになってきた。特に IBM が開発した DeepBlue[1] が当時のチェス世界チャンピオンに勝利したことは大きなニュースとなった。近年になり DeepMind の AlphaGo[2] が囲碁のプロに勝利し、人工知能研究の成果を示してきた。これらのゲームは完全情報ゲームと呼ばれ、ゲームプレイに関する情報をすべて得ることができる。現在のゲーム AI に関する研究の注目は不完全情報ゲームに移っている。

本研究では不完全情報ゲームのうち即時戦略ゲーム (Realtime Strategy Game, RTS ゲーム) に分類されるオンラインゲームの Clash Royale を対象とする。RTS ゲームの状態数と行動空間はともに囲碁を超えている。Clash Royale を研究対象にすることで、AI の学習目的を RTS ゲームの中の主要目的である対戦に絞ることができる。本研究では Clash Royale の AI 学習環境を構築し、AI を実装したので報告する。

2. 関連研究

2.1 Q Learning

Q 学習は 1992 年に、WATKINS[3] らによって、強化学習の一手法として提案された。ある有限マルコフ決定過程において、すべての状態に対して、必ず最良の行動が存在する、そのすべての状態に対して十分に試行を重ねると、各状態においての各行動の評価値は収束することが証明された。現実問題に対して、連続した状態をデジタル化して、離散的な状態集合に対して学習を行うのが制約となっている。

2.2 Deep Q Learning

DeepMind は、ニューラルネットワークを用いて、Q 関数を再構築した。多層なニューラルネットワークによって構築されたため、Deep Q-Learning(DQN)[4] と名付けられている。この DQN を用いて、Atari ゲーム機で発売されたレトロゲームについて学習させた結果。Breakout、Enduro、Pong などのゲームで人間レベルのプレイ技術に達していた。

2.3 AlphaZero

囲碁のような状態数が多いゲームに対して、単純な先読みは能力不足になる。DeepMind は強化学習の手法を用いて、AlphaGo[2] を開発した。囲碁の盤面の特徴を抽出して、特徴に合わせて方策を決めるネットワークと価値を決めるネットワークを別々に学習した。実行時には両方利用して、人間の棋士に勝利した。しかし、リアルタイムに進行する不完全情報ゲームに対して、応用と検証する例はまだ少ない。

3. AI 構築用ゲーム環境の実装

本研究で構築された疑似ゲーム環境は OpenAI gym のゲーム環境を参考にした。ゲーム内全オブジェクトの処理はフレーム単位で処理される。一フレーム毎に各ユニットのやるべきことを逐次実行する。ゲーム内ユニットの活動の更新が完了後、この瞬間のゲーム内の全情報 (observation) を抽出でき、AI エージェントが取るアクションを入力 (step(action)) できる。ゲーム終了後、両側プレイヤーが獲得した合計リワード (total_reward) が取得できる。構築したゲーム環境は図 1 に示す。



図 1: ゲーム環境の実行の様子

プレイヤーは手持ちの 8 枚のカードのうちの 4 枚のカードを使って、ユニットを自分の陣地に配置する。配置されたユニットは決められた行動で相手を攻撃しに行く。ゲームの目的は相手のタワーを破壊することである。ゲーム終了時に、より多くの相手のタワーを破壊した方が勝ちとなる。

4. AI の構造

今回提案する AI はニューラルネットワークによって実現した。構造は図 2 のように設計した。各層の活性化関数は LeakyReLU を利用した。

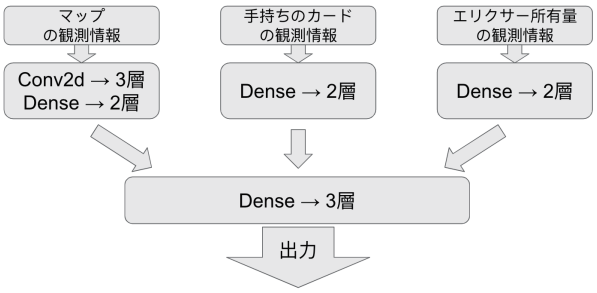


図 2: ニューラルネットワークの構造

5. 実験と結果

今回は AI として、DQN を用いる。ゲーム終了後の合計リワードは次式 1 で計算される。

$$Total\_reward = Time\_bonus * (Reward - Penalty) \quad (1)$$

Time_bonus はゲームの進行に連れて減少する係数であり、ゲームが長引かないようするためのものである。Reward と Penalty それぞれ敵陣に与えだダメージの量と自陣が受けたダメージの量がゲーム勝敗条件と計算した数となる。対戦双方は同じネットワークで判断を下し、学習していく。1 ゲームを 1 エピソードとして、学習は 3000 エピソード行った。対戦両方が勝ったときの合計リワードの 30 期間の移動平均線を図 3 に示す。横軸は訓練のエピソード数、縦軸はゲーム終了後の合計リワードになる。初期に学習は急速に進むが 700 エピソード以降は、合計リワードがほぼ変化していない。

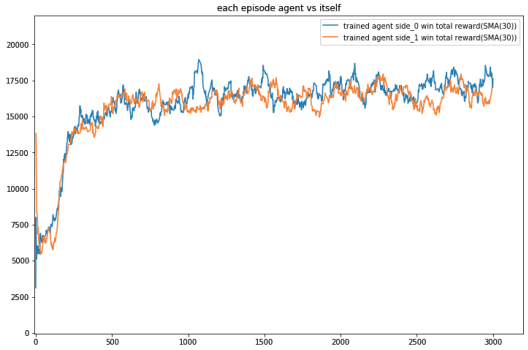


図 3: エピソードごとの自己対戦

ランダムエージェントの自己対戦の結果と学習 1000/2000/3000 エピソードのエージェントとランダムエージェントの対戦結果の合計リワードとゲームの終了までの時間の関係を図 4 に示す。ランダム/シンプル/1000/2000/3000 エピソードエージェントとランダムエージェントの対戦勝敗数を表 1 に示す。

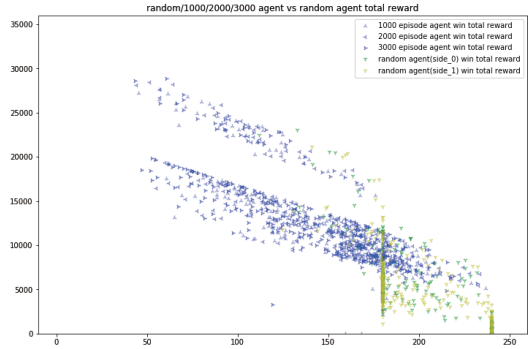


図 4: シンプル/1000/2000/3000 エピソードエージェント対ランダムエージェントの合計リワード

表 1: ランダム/シンプル/1000/2000/3000 エピソードエージェントとランダムエージェントの対戦勝敗数

エージェント	勝利数	敗北数	引き分け数	勝率
random	215	230	55	43%
1000	320	171	9	64%
2000	305	188	7	61%
3000	300	196	4	60%
simple	330	164	6	66%

図 4 で確認できるのは、ランダムエージェント (緑マーク) はゲームの終了時間は約 180 秒後であり、合計リワードは低かった。学習後のエージェント (青マーク) はゲームが早く決着するように学習できた。全体にゲームの終了時間が前倒しになったことが確認できた。ゲーム終了時のエージェントが獲得できたリワードも上昇したことが確認できた。

表 1 から、ランダムエージェントの勝率 43%と低い。学習後のエージェントのランダムエージェントに対する勝率は全体的に 20%上昇し、60%以上の勝率になった。

6. 今後の課題

今回は Clash Royale と類似した RTS ゲームの AI 学習用のプラットフォームを作成した。このプラットフォームで RTS ゲームに関する AI の研究がより簡単にできるようになった。また、今回は RTS ゲームの戦略を学習する AI を DQN により構築した。しかし、700 エピソード以降学習が余り進んでいないと思われる。これからはより勝率の高い AI を学習させるために色々な工夫を考えたい。

参考文献

[1] M. Campbell, A.J. Hoane Jr, H. Hsu, *Deep Blue*, pp.5783, Artificial Intelligence, Vol. 134, Issues 1-2, pp. 57-83, 2002

[2] D. Silver, et. al, *Mastering the game of Go with deep neural networks and tree search* , Nature, Vol. 529, pp. 484489

[3] CJCH Watkins, P Dayan, *Q-Learning* , Springer, Vol. 8, pp. 297292, (1992)

[4] Bellemare, M. G., Veness, J. & Bowling, M. *Investigating contingency awareness using Atari 2600 games.* , Proc. Conf. AAAI. Artif. Intell. 864871 (2012)

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

階層型強化学習 MLSH における枝刈りによるサブポリシ数調整

A Sub-policy Pruning Method for Meta Learning Shared Hierarchies

Qing HONG *1*2 Yusuke TANIMURA*2*1 Hidemoto NAKADA*2*1

*1筑波大学
University of Tsukuba

*2産業技術総合研究所 人工知能研究センター
Artifical Intelligence Research Center, National Institute of Advanced Institute of Technology

Meta Learning Shared Hierarchies(MLSH) is a example of Hierarchical Reinforcement Learning.n Assuming some task distribution and reusing the knowledge learned on the preceding tasks, it aims to rapidly adjust to new tasks. It divides the policy into several sub-policies and master policy which choose one of the sub-policies, expecting each sub-policy is responsible for each sub-goal in the task. One of the drawbacks of this approach is that, in general, it is not possible know the number of sub-goals in unseen task distribution, hence, the number of sub-policies. With improper number of sub-policies, the performance of MLSH is degraded. To solve this problem, we propose a method to locate the proper number of sub-policies by pruning excessive sub-policies. The proposed method save resources and reduce the time the algorithm to converge. We test the method using 2D-bandit problem and demonstrate the effectiveness.

1. Introduction

Reinforcement learning takes long time to solve tasks with sparse rewards. Hierarchical reinforcement learning (HRL) is an approach to solve this problem reusing sub-policies learned on preceding similar tasks [Bakker 04]. It could improve the exploration efficiency [Simsek 04] or learning efficiency [Bacon 16].

Traditional HRL requires hand-crafted sub-goals to solve specific tasks with pre-trained sub-policies. The agent learn a policy to take action to receive an extrinsic reward first, then separate this action into several basic actions. With this approach it is difficult to obtain good performance in practical hierarchical problems. On the other hand, finds a useful sub-policies first and use such policies to solve sparse-reward problems is more efficient in practical hierarchical problems. Such methods are called meta learning [Finn 17].

Meta learning has a problem that it can hardly discover useful sub-policies for unseen problems. MLSH (Meta Learning Shared Hierarchies) [Frans 18] is a HRL algorithm which focuses on these problems. MLSH tries to solve a wide variety of tasks by using prior knowledge and primitive policies. The goal is to rapidly reach high reward on new tasks drawn from a certain task distribution. When related tasks contains multiple sub-goals, MLSH pre-trains multiple sub-policies correspond to the sub-goals and update them accordingly. However, in some complicated tasks, the numbers of goals are unpredictable. Too many sub-policies and too few sub-policies degrade the performance of MLSH in each way. To solve this problem, we propose a method to locate the proper number of sub-policies by pruning the excessive sub-policies.

2. Background

2.1 Meta Learning Shared Hierarchies

Meta Learning Shared Hierarchies is an end-to-end meta-learning approach that uses prior knowledge to solve unseen tasks.

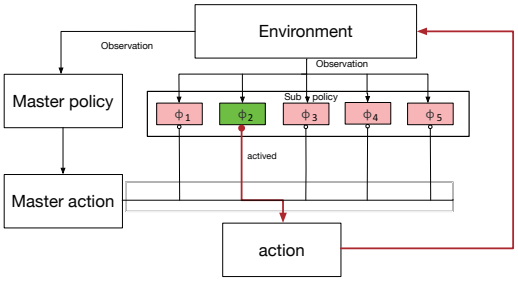


Figure 1: The Overview of MLSH

The goal of MLSH is to rapidly reach a high reward with similar tasks. By training master policy to activate one of the sub-policies that correspond to sub-goals, MLSH utilize the prior knowledge to solve tasks that share similar sub-goals. That is to say, MLSH create a probabilistic policy called master policy whose action is to choose one of the sub-policies. Master policy starts with randomly-initialized status and will be fine-tuned to each task. Then we optimize the probabilistic parameter based on the total reward from sub-policies and the master's action. At last, we update sub-policies and master policy jointly.

2.2 Simple 2D-Moving Bandits environment

We use a simple problem called 2D-moving bandid throughout this paper as an example problem. This is a simple bandit problem which contains different potential goals p(Figure 2). This environment generates one dots as our agent. Then randomly create two dots, and each dot is considered a potential goal. Our agent's goal is to reach them as close as possible. 2D-bandit problem is similar to the N-armed bandit problem. Each slot (dot) have different repay (reward depends on the rate of repaying and distance), our agent's goal is to find the highest total reward. In each iteration the position of dot and repay rate randomly be altered, our agent also needs to do such things again: 1. approach the ball. 2. confirm the reward and optimal the goal direction.

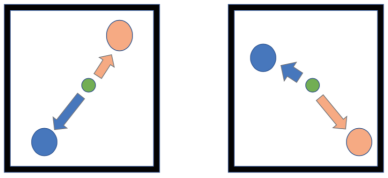


Figure 2: Simple 2D-Moving bandit problem: green dot denotes our agent, and other dots denote our potential goals.

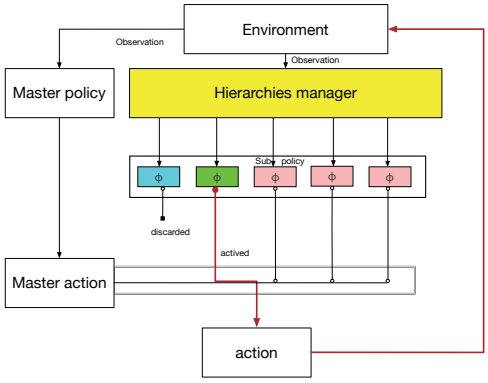


Figure 3: The Architecture of the proposed method, SPPM create hierarchies manager to formulate the policy which helps agent to locate the proper number of sub-policies.

This environment is easy to simplest hierarchical learning problem, and we will use it to help our research.

3. Sub Policy Pruning Method

We propose a method called Sub Policies Pruning Method (SPPM). The goal of SPPM is to find the proper number of sub-policies in the environment which contains an uncertain number of sub-goals. SPPM starts with enough number of sub-policies, observes the behavior of each sub-policy, and determines the proper number of sub-policies. A module called hierarchies manager is responsible for this procedure (Figure 3). With this method, we can save resources and improve learning speed.

Figure 4 shows the algorithm of SPPM. When the environment is unseen, and we do not know the number of sub-goals, we use SPPM to speed up the training. SSPM initialize an excessive number of sub-policies ϕ. To observe the behavior of each sub-policy our agent need a warm-up trial T to train the ϕ. T subjects to the complexity of the environment and it provided by our hierarchies manager. After warm-up trials, each sub-policy have a specific tendency, so we can remove the sub-policies with low-activity and replace the role of them with more active ones. In the next prune trial P, SPPM record the activated times A of each sub-policy selected by master-policy. If the A of ϕ lower than PL (Pruning threshold), the sub-policy will be pruned and will not be activated in the rest of trials. PT is provided by hierarchies manager based on the environment.

Sub Policies Pruning Method in MLSH
initialize ϕ
repeat
Initialize θ
Sample task M $\sim P_M$
For t=0,1,.....T(Test trial) do
Update ϕ to maximize expected return in W
Update θ to maximize expected return in U
end for
For P=0,1,.....P(Prune trial) do
Update ϕ to maximize expected return in W
Update θ to maximize expected return in U
If (ϕ_k|A(Activated times of ϕ_k)) < PT:
Prune ϕ_k
end if
end for
until convergence

Figure 4: The algorithm of SPPM.

3.1 When SPPM Conduct Pruning Method?

To estimate the actual value of each sub-policy , it is necessary to give enough time steps to train the sub-policies until they began to have redundancy. When the environment becomes complicated, the MLSH agent cost more time to get convergence. Hence, the pruning time point depends on the complexity of the environment. On the other hand, from the resource consumption point of view, we need to prune the unnecessary sub-policy before the convergence.

Figure 5 is the heat-map of similarity by using similarity equation:

$$\cos(\mathbf{A},\mathbf{B}) = \frac{\mathbf{AB}}{\|\mathbf{A}\|\|\mathbf{B}\|} = \frac{\sum_{i=1}^{n}\mathbf{A}_i\mathbf{B}_i}{\sqrt{\sum_{i=1}^{n}(\mathbf{A}_i)^2}\sqrt{\sum_{i=1}^{n}(\mathbf{B}_i)^2}} \quad (1)$$

The x-axis and y-axis denote sub-policies. Each cell stands for the 'similarity' of the corresponding two sub-policies. Larger value means that the two sub-policies behave similarly. With the training goes on, some of the sub-policies converge into the same behavior. Such sub-policies can be marked as redundant and one of them could be safely removed, since the other will fill in the role. We find that the behavior convergence after 50 trials. Conducting a pruning method after that may be a good time point for this case.

3.2 How SPPM Conduct Pruning Method?

Define the pruning rule to efficiently prune the redundant policies is a challenging problem. We found that pruning rule based on recent activated times is easier to obtain better performance (using moving average).

Find the best pruning threshold on a particular task is the second problem we need to consider. Pruning too much sub-policies leads to counterproductive effect. Figure 6 shows the moving average of activation ratio of each sub-policies. From the graph, we could figure out that pruning sub-policies that have activation ratio less than 50% or 60% of the most activated sub-policy will be moderate. Based on this observation, we define two threshold; aggressive threshold (50%) and conservative threshold (60%).

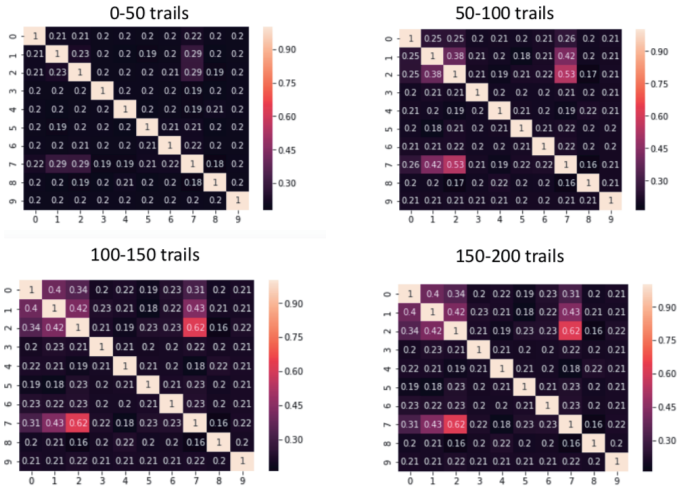


Figure 5: The heatmap of similarity using 10 sub-policies, the x-axis and y-axis denotes different sub-policies. the number denotes the similarity compare with 2sub-policy. The bigger the number is, the similar actions it take. From 50 trials some of the sub-policy start to get redundant.

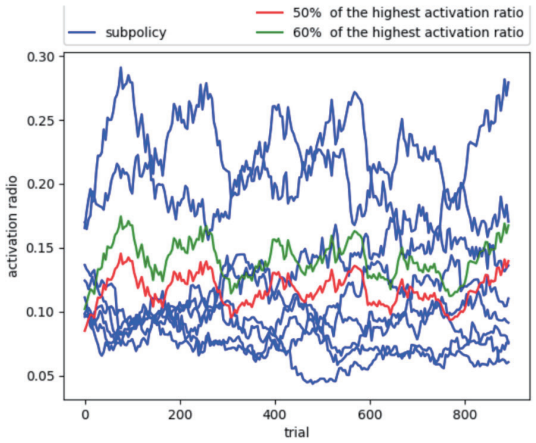


Figure 6: The result of 8sub-policies 2sub-goals. X-axis denotes the trials and Y-axis denotes the activation ratio. The red line denotes aggressive pruning threshold: less than 50% of highest activation ratio. The green line denotes conservative pruning threshold: less than 60% of highest activation ratio

4. Evaluation

To evaluate the proposed method, we conducted experiments using the 2D-moving bandits shown in 2.2 with only one sub-goal is designated as the real goal (other goals have 0 repay rate). Number of sub-goal is 2, hence the ideal number of sub-policies is also 2. As the parameter of SPPM, we employed two parameters; namely, 1) pruning threshold, 2) pruning start time. For pruning threshold, we tried aggressive (50%) and conservative (60%) setting. For start time, we tried 50 trials and 150 trials. After 50 trials is the time when the sub-policy behavior starts to converge. After 150 trials is the time just before whole algorithm reach the convergence. We started with 8 sub-policies.

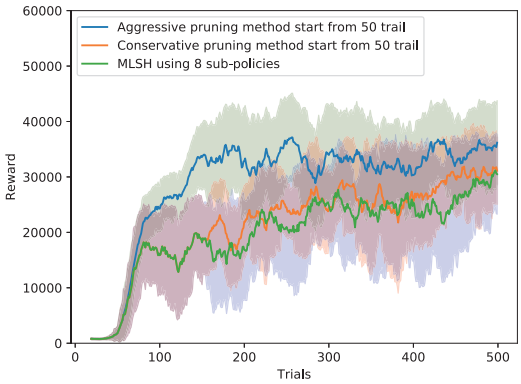


Figure 7: Comparison of aggressive pruning strategy with conservative pruning strategy with 8 sub-policies 2 sub-goals.

Figure 8 shows the results with 150 trials start and Figure 9 shows the results with 50 trials start. Left diagrams show the aggressive case while the right show the conservative case. Upper diagrams show the activated ratio of each sub-policies and lower diagrams show the reward. The blue vertical lines denote the trial we successful prune the sub-policies. When we start pruning after 150 trial (Figure 8), with aggressive pruning strategy, we successfully pruned 4 sub-policies at 150 trial and 1 sub-policy at 202 trial. With conservative pruning strategy, we could prunes 3 sub-policies at 297, 321 and 346 trial.

When we start pruning after 50 trial (Figure 9), with aggressive pruning strategy, we pruned 5 sub-policies at 27, 28, 32, 33, 38. With conservative strategy, we could prune 1 sub-policy at 153 trials

Figure 7 shows the comparison of different pruning strategies. Aggressive pruning method seems to have better performance than the conservative one. However, we have to note that there is a certain risk to prune too much sub-policies. For simple environment (the number of sub-goals is much smaller than number of sub-policies), starting to prune sub-policies at the early stage seems better. Aggressive pruning strategy seems to be better than conservative one.

5. Conclusion

In this paper, we proposed Sub Policies Pruning Method that locate proper number of sub-policies by starting with enough number of sub-policies and pruning the low-activity sub-policies during the training. We applied the proposed method to the 2D-bandid problem and confirmed the effectiveness of the method.

One of the problem with the proposed method is the tuning of the hyper parameters, namely, pruning threshold and pruning start time. Finding methods to automatically adjust these parameters is our future work.

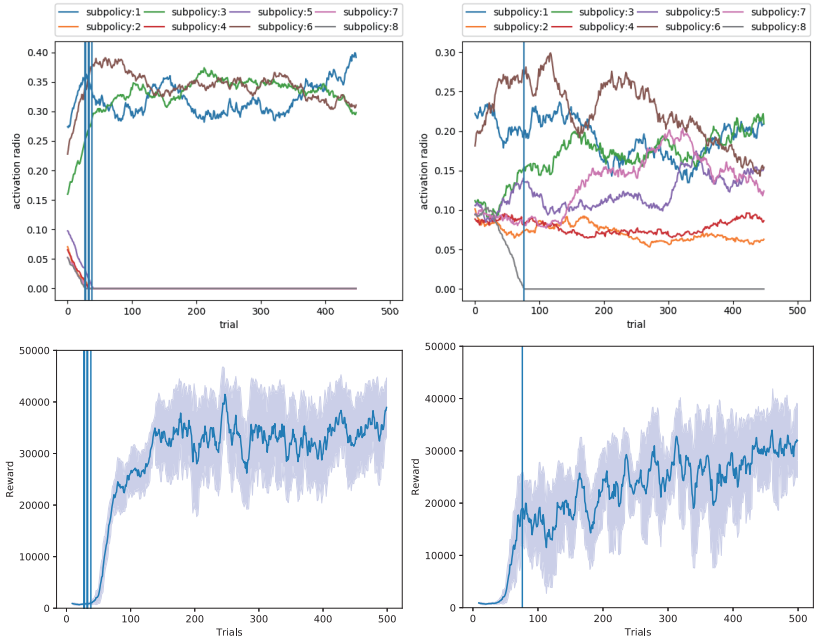


Figure 8: Evaluation Results: starts 150 trials. Left: aggressive, Right: conservative.

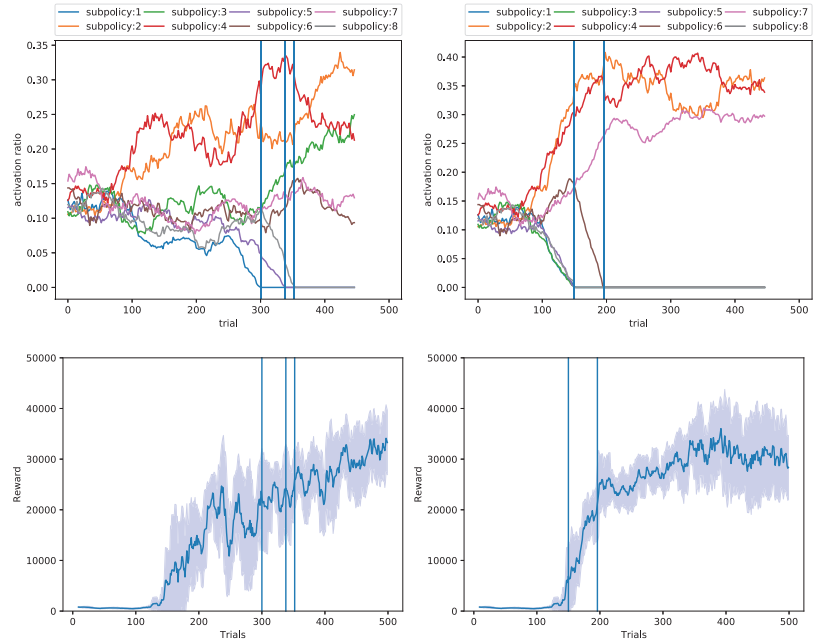


Figure 9: Evaluation Results: starts 50 trials. Left: aggressive, Right: conservative.

Acknowledgement

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

References

[Bacon 16] Bacon, P., et al.: The Option-Critic Architecture, in *CoRR*, p. abs/1609.05140 (2016)

[Bakker 04] Bakker, B., et al.: Hierarchical reinforcement learning with subpolicies specializing for learned subgoals, in *Nural Networks and Computational Intelligence*, p. abs/1703.03400 (2004)

[Finn 17] Finn, C., et al.: Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks, in *CoRR*, p. abs/1703.03400 (2017)

[Frans 18] Frans, K., et al.: Meta Learning Shared Hierarchies, in *International Conference on Learning Representations* (2018)

[Simsek 04] Simsek, O., et al.: Using relative novelty to identify to identify useful temporal abstractions in reinforcement learning, in *ICML* (2004)

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

ニューラルネットワークを用いたニュース記事の抽出的三行要約

Extractive Three-line Summarization of News Articles using Neural Network

小川 恒平[*1] Kouhei Ogawa
永塚 光一[*1] Koichi Nagatsuka
渥美 雅保[*1] Masayasu Atsumi

[*1] 創価大学大学院工学研究科情報システム工学専攻
Dept. of Information Systems Science, Graduate school of Engineering, Soka University

The purpose of text summarization is to enable readers to understand the point of documents without reading overall of them. With the spread of smartphones, opportunities to view news articles within the limited screen area are increasing, so that there are needs easy to read summaries within the limited screen area. In this paper, we propose a neural network model that extracts three-line summaries from news articles. As a dataset, we use articles and three-line summaries of Livedoor NEWS on the Internet. In an experiment, we show that the proposed model performs better than a conventional method.

1. はじめに

要約の目的は,読み手が文書全体を読むことなく,その文書の内容をある程度把握できるようにすることである.今までのニューラルネットワークを用いた要約の研究では,機械翻訳で性能を向上させた,アテンションを取り入れたエンコーダデコーダモデルによる研究が盛んに行われてきた. Rushらによる単文要約[Rush 15]や,Paulusによる複文要約[Paulus 17]の研究などにおいて,大きな性能の向上が報告されている.また,スマートフォン等の普及により,限られた画面の範囲でニュース記事などのテキストを閲覧する機会が増えてきている.そのため,スマートフォンでニュース記事を読む場合は,小さな画面でも見やすい長さの要約文が理想的である.本研究では,ネット上のニュースサイトであるLivedoor NEWSの記事とそれに対応した三行要約のペアをデータセットとして使い,ニュース記事から,スマートフォンでも見やすい三行要約を自動で出力するニューラルネットワークモデルを提案し,実験によりその性能を評価する.

2. 三行要約

図1は,本研究で使用するLivedoor NEWSというサイトの人手により作られた三行要約の例である.タイトルに加えて三行要約が付いていることで,タイトルだけでは元記事の情報を把握しきれないというデメリットをカバーしている.三行要約は,スマートデバイスでも見やすい要約で,私たちが小さな画面で読みたい記事を探す際のサポートになる.



図1. Livedoor NEWS

連絡先:小川恒平,創価大学情報システム工学科,〒192-8577 東京都八王子市丹木町1-236, Tel:042-691-2211

3. 関連研究

3.1 LEAD法

抽出型要約におけるベースラインとして用いられる手法としてLEAD法がある.LEAD法は,入力文書中の文を上から任意の数取ってくるものである. これは, 文書中の重要な内容が,文書の先頭にくるという仮定のもと用いられている. 単純でありながら精度の高い手法で,特にニュース記事に有効である.本研究では,このLEAD法と提案手法の精度を比較している.

3.2 要約構造分類モデル

三行要約の先行研究として,小平が提案した要約構造分類モデル[小平 18]がある.この要約モデルでは,まず与えられたテキストに対して“並列”または“直列”タイプの三行要約構造が存在すると仮定する.“並列”タイプの三行要約構造では, 1文目の要約をトピックの中心として,2,3文目を1文目から派生するサブトピックとみなして三行要約を生成する.これに対し,“直列”タイプの三行要約構造では, 1文目のトピックを起点として, 2,3文目のサブトピックを時系列的に並べ,三行要約生成する. 各タイプに対してモデルをそれぞれ個別に訓練することで,各要約構造タイプに特化した要約生成モデルを学習する.しかし小平の研究では,“並列”と“直列”タイプに分類分けを行ったことで,データセットの量に偏りが起きてしまうという問題がある.実際,小平の研究では直列タイプが少ないと述べている.本研究では,“並列”,“直列”タイプのように分類分けは行わずに,データセットは一つにまとめている.

4. 提案モデル

図2に提案モデルを示す.モデルはHsuらのモデル[Hsu 17]をもとにしている.まず,元記事を一つ一つの文に分ける.そして各文の単語列を正方向と逆方向にBiGRUでエンコードしたのち,最初と最後の隠れ状態を足し合わせる.次にそれら隠れ状態の系列をBiGRUによりエンコードしてsoftmax関数により,各文の重要度分布を出す.最後に,重要度で各文を並べたのち,重要度が高い3文を三行要約として抽出する.訓練では,重要文の教師ラベルを,人手による

各要約文に対してそれと記事中の各文間での ROUGE-2(recall)スコアが最も高かった文に付与する.

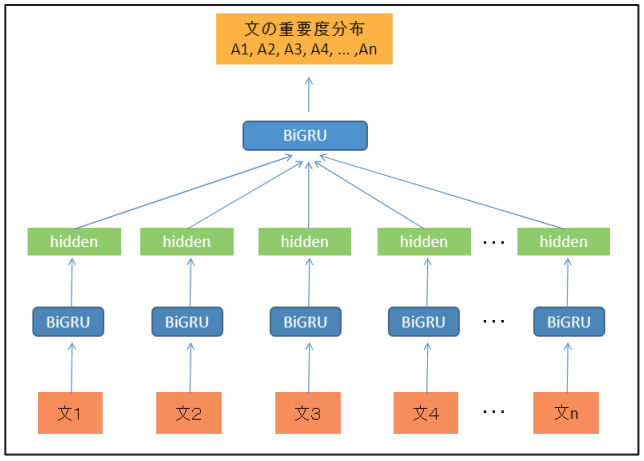


図 2.提案モデル

5. データセット

データセットは, 小平の研究[小平 18]において公開されていた Livedoor NEWS の記事と要約の URL を使い, スクレイピングをして収集したものを用いる. また, 三行要約の 1 文あたりの文長を約 30 字程度と考えたとき, 要約の合計文字数は 100 字程度になるため, 要約する元記事の文字数は要約文の倍である 200 字以上とし, 最大長は 2000 字までの範囲に限定した. データは文字化けしてしまっているものや, 記事の一部しかスクレイピングできていないものなど, データとして使えないものは除去を行い MeCab の形態素解析で分かち書きをしている. 記事とそれに対応する三行要約を 1 ペアと数え, 実験ではトレーニングデータ用に 8000 ペア, テストデータ用に 1000 ペア, バリデーションデータ用に 1000 ペアを使用した.

6. 実験

6.1 実験概要

表 1 にデータのペア数, 合計文数, 平均文数, Vocabulary 数, 平均文長を示す. 実験では評価指標として, 要約タスクに用いられる ROUGE を採用し, スコアを求めた.

表 1. データセット

	Train	Test	Validation
ペア数	8000	1000	1000
合計文数	165762	21160	19680
平均文数	20.72	21.16	19.68
Vocabulary 数	74782	29255	24592
平均文長	27.33	27.23	27.61

6.2 実験結果

今回行った実験に対する ROUGE スコアを下の表 2 に示す. LEAD 法と提案手法の二つの手法とも実験を数回繰り返し, ROUGE の平均値を取っている. 表 3 は今回の提案手法で出力された三行要の一例である.

表 2. ROUGE スコア

	ROUGE-1	ROUGE-2	ROUGE-L
提案手法	0.48	0.17	0.06
LEAD 法	0.45	0.105	0.07

実験の結果, ROUGE-1 と ROUGE-2 では, LEAD 法よりも提案手法の方が高いスコアを得ることができた. ニュース記事の先頭部分に重要な内容は固まりやすいが, 提案手法のように先頭以外からも重要だと思われる文を抽出し, 三行要約を構成した方が, 記事の先頭を抽出してくる LEAD 法よりも提案手法の方が高いスコアを得ることができた.

7. むすび

本研究では, ニュース記事から三行要約を抽出するニューラルネットワークモデルを提案した. そして Livedoor NEWS のデータセットを使い, 記事から三行要約を抽出した. LEAD 法の抽出的要約よりも ROUGE-1, ROUGE-2 に関して良いスコアを獲得することができた. しかし, データセットには少量であるが, まだノイズが残ってしまっていた. 今後もデータセットの整形やモデルの改良などを加えていき, さらなる性能の向上を試みる.

表 3. 提案手法の出力結果の一例

正解の三行要約
東日本 大震災 から 5 年 を 迎え た 11 日 , Twitter で は 「 黙祷 なう 」 が 散見 され た これ に 「 心 の 中 で やっ とけ よ 」 と いった 否定 的 の 声 が 多く 上がっ て いる 一方 で , どういう 形 で あれ 「 思い出す こと 」 が 大切 と 理解 を 示す 声 も ある
[元記事の文番号] 重要度が高いとされた 3 文（三行要約）
[0] 死者 ・ 行方 不明 者 あわせ て 1 万 8455 人 という 甚大 な 被害 を もたらし た 東日本 大震災 から 3 月 11 日 で 5 年 目 を 迎え た . [2] そんな 中 , 今年 も 物議 を 醸し て いる の が , Twitter に 書き込ま れる 「 追悼 なう 」 という 言葉 だ . [5] 」 「 心 の 中 で やっ とけ よ 」 と いった 否定 的 の 声 が 多く 上がっ て いる .

参考文献

[Rush 15]Alexander M. Rush, Sumit Chopra, Jason Weston: A Neural Attention Model for Abstractive

Sentence Summarization, *arXiv preprint arXiv:1509.00685*, 2015.

[Paulus 17]Romain Paulus, Caiming Xiong, Richard Socher: A Deep Reinforced Model for Abstractive Summarization, *arXiv preprint arXiv:1705.04304*, 2017.

[Hsu 17] Wan-Ting Hsu, Chieh-Kai Lin, Ming-Ying Lee, jing Tang, Min Sun: A Unified Model for Extractive and Abstractive Summarization using Inconsistency Loss, *arXiv preprint arXiv:1708.00391,* 2017.

[小平 18]. 文書構造に着目したニューラル文書要約. 首都大学東京大学院システムデザイン研究科修士論文.

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

Pointer Networksを用いた文内述語項構造解析

Predicate argument structure analysis with Pointer Networks

髙橋啓吾　大森光　小町守
Keigo Takahashi　Hikaru Omori　Mamoru Komachi

首都大学東京
Tokyo Metropolitan University

Recently, neural network models are used in intra-sentential predicate argument structure analysis (PASA). However, the sequence labeling approach may assign the same case for multiple arguments. Thus, we propose a novel PASA method by using the Pointer Networks and alleviate the problem of multiple case assignments.

1　2　3　4
私が**友人**に**お餅**を**あげる**と、
5　6
友人はその場で**食べ**た.

述語	ガ格	ヲ格	ニ格
あげる（4）	私（1）	お餅（3）	友人（2）
食べる（6）	友人（5）	お餅［ゼロ照応］（3）	-

図 1: 文内ゼロ照応を含む述語項構造解析の例

1. はじめに

述語項構造解析とはテキスト中に存在する述語とその項との意味構造を認識するタスクである．述語項構造解析は機械翻訳や含意関係認識など複雑な文脈の解析を必要とするタスクに有用である．そのうち，文内述語項構造解析は述語と同一文内に存在する項のみを同定する述語項構造解析タスクである．述語項構造解析では述語に対するガ格，ヲ格，ニ格の必須格や任意格を同定する．述語項構造解析の例を図 1 に示す．図 1 は必須格が省略されている文内ゼロ照応を含むものである．数字は単語の区別のため記載した．本研究では，文内の必須格の述語項構造解析を対象とする．

先行研究では，Recurrent Neural Networks (RNN) を用いた end-to-end なモデルが優れた解析精度を示しているが，これらは述語項構造解析を系列ラベリングタスクとして取り扱っている [Matsubayashi 18, Ouchi 17]．述語項構造解析を系列ラベリングで解く場合，文内に共参照関係や並列関係等の特別な文構造が存在しない場合でも，複数の項候補に対して同じ必須格をラベリングしてしまうという問題が起こりうる．

本研究では，この問題を解決するために述語項構造解析に対して Pointer Networks [Vinyals 15] を応用した手法を提案する．Pointer Networks は入力シーケンスの特定の位置を指すポインタを出力する Neural Network を用いたモデルである．本タスクは入力文の中から述語に対応した必須格の単語を同定するタスクであるので，Pointer Networks を用いて入力文の中から項の位置を表すポインタを出力し，予測に用いることで，同じ必須格を複数出力してしまう問題を解決する．

連絡先: 髙橋啓吾，takahashi-keigo@ed.tmu.ac.jp

2. 系列ラベリングによる述語項構造解析

本研究は文内述語項構造解析タスクに取り組むものである．実験の設定は Ouchi ら [Ouchi 17] のものに合わせ，述語である単語は既知，述語に対応した必須格である単語は未知とした．文内係り受け，文内ゼロ照応の推定を対象とし，文間ゼロ照応，外界ゼロ照応は対象としなかった．同様に，どの単語が述語であるかは既知，必須格である単語は未知として述語に対応した必須格を同定するタスクとした．また，一つの文に対して複数の述語が存在する場合もあるが，述語に対応する必須格はこのタスク設定において高々一つずつである．

本研究では，先行研究 [Matsubayashi 18, Ouchi 17] で行われている系列ラベリングによる述語項構造解析手法をベースラインとして，我々の提案手法である Pointer Networks を応用した手法と比較する．それぞれの手法で用いるモデルは入力層，RNN 層，出力層から構成される．ここではまずベースラインとした系列ラベリングを用いた述語項構造解析手法について記載する．図 2 にベースラインの構成を示す．

2.1 入力層

本研究では素性として述語の表層形，項候補の表層形と合わせて，述語と項候補の単語換算距離，述語を含む文節と項候補を含む文節の文節換算距離，項候補が述語かどうかを用いた．

1. 述語の表層形
2. 項候補の表層形
3. 述語と項候補の単語換算距離（述語単語の文内位置 − 項候補単語の文内位置）
4. 述語を含む文節と項候補を含む文節の文節換算距離（述語単語の文内文節位置 − 項候補単語の文内文節位置）
5. 項候補が述語かどうか

ここで項候補は文の各単語 $w_t \in [w_1, \cdots, w_T]$ とし，述語はその中の一つの単語である．述語の表層形と文中全ての単語を項候補として一つずつ組み合わせ，さらに項候補に対応した追加の素性 3〜5 を入力する．これらの素性は変換行列を介してベクトル化した．特に，1. 述語の表層形，2. 項候補の表層形のベクトル化には学習済み Word Embedding[*1] を用いた．

それぞれをベクトル化したものを結合し，x_t と表す．t は時系列の時刻とする．

*1 http://www.asahi.com/shimbun/medialab/word_embedding

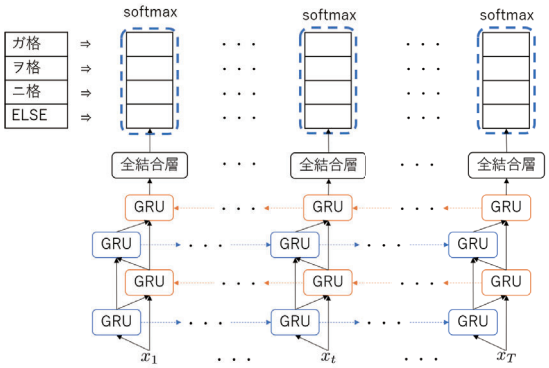


図 2: 系列ラベリングによる述語項構造解析モデル

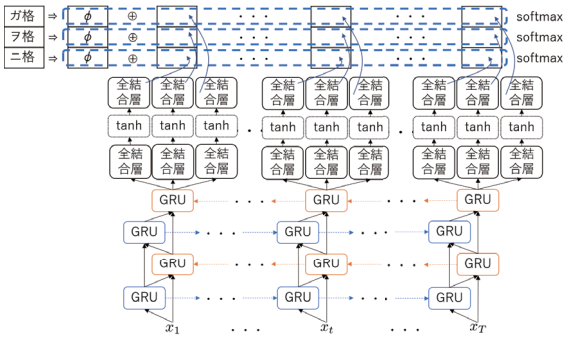


図 3: Pointer Networks による述語項構造解析モデル

2.2 RNN 層

RNN 層は 2 層の Stacked bi-directional Gated Recurrent Unit (GRU) [Cho 14] を用いた．また，Ouchi ら [Ouchi 17], Matsubayashi & Inui [Matsubayashi 18] の研究に従い，Residual 接続を用いる．各層のインデックスを $l \in [1, \cdots, L]$ とした場合の隠れ状態を $h_t^l \in \mathbb{R}^{d^h}$ とする．d^h は隠れ層の次元数である．これらを用いると各隠れ層からの出力は以下となる．

$$h_t^l = \begin{cases} \mathrm{gru}^l(h_t^{l-1}, h_{t-1}^l) & (l = odd) \\ \mathrm{gru}^l(h_t^{l-1}, h_{t+1}^l) & (l = even) \end{cases} \quad (1)$$

ここで，$\mathrm{gru}^l(\cdot)$ は l 層目の GRU であり，$h_t^0 = x_t$ である．

2.3 出力層

出力層は，RNN 層の最終層の隠れ層のテンソル h_t^L を全結合層の入力にとる．そして，その出力に softmax 関数をかけて確率ベクトル o_t^{base} を算出する．これらの処理はまとめて以下のように表される．

$$o_t^{base} = \mathrm{softmax}(W_1^{base} h_t^L + b_1^{base}) \quad (2)$$

ここで，$W_1^{base} \in \mathbb{R}^{4 \times d^h}$ は出力層の重み，b_1^{base} は出力層に用いた全結合層のバイアス項を表す．

また，ベースラインの出力層では必須格 [ガ格, ヲ格, ニ格, ELSE] の 4 種類に対応する推定確率を出力する．ELSE は述語項候補がどの必須格にも該当しない場合の要素である．

3. Pointer Networks による述語項構造解析

既存の系列ラベリング手法を用いた場合に生じる，複数の項候補に同じ必須格ラベルを割り当ててしまうという課題に対して，必須格をそれぞれ高々一つずつ割り当てるようなモデルを提案する．Pointer Networks を用いた提案手法では出力層に Pointer Networks [Vinyals 15] を応用した手法を取り入れた．入力層，RNN 層はベースラインと同じものを用いた．

3.1 出力層

提案手法ではベースラインモデルのように項候補ごとに必須格の推定確率を算出するのではなく，述語に対してどの項候補が最も必須格らしいかを表す推定確率 o_t^{ptr} を算出するようにした．図 3 に提案手法の構成を示す．以下に算出式を示す．

$$c_t^{ptr,i} = \tanh(W_1^{ptr,i} h_t^L + b_1^{ptr,i}) \quad (3)$$

$$s_t^{ptr,i} = W_2^{ptr,i} c_t^{ptr,i} + b_2^{ptr,i} \quad (4)$$

$$o^{ptr,i} = \mathrm{softmax}(\phi \oplus s_1^{ptr,i} \oplus \ldots \oplus s_T^{ptr,i}) \quad (5)$$

ここで，添字の i はそれぞれの必須格を表し，出力層は必須格ごとに用意した．右下の添字は出力層内の全結合層の layer 数を表す．$W_1^{ptr,i} \in \mathbb{R}^{d_1^{ptr} \times d^{hidden}}$ は 1 層目の全結合層の重み，d_1^{ptr} は 1 層目の全結合層の次元数，b_1^{ptr} は 1 層目の全結合層のバイアス項を表す．同様に，$W_2^{ptr,i} \in \mathbb{R}^{1 \times d_1^{ptr,i}}$ は 2 層目の全結合層の重み，d_2^{ptr} は 2 層目の全結合層の次元数，$b_2^{ptr,i}$ は 2 層目の全結合層のバイアス項を表す．2 層目からの出力はスカラー値である．ϕ は，対象となる必須格が存在しない場合に指す要素として用意したスカラー値であり，ϕ は常に 0.0 とした．

訓練時には正解の必須格の位置を教師あり学習のラベルと合わせて学習するため，モデルは必須格の位置さえ出力できればよいが，最終的に各必須格の項候補を決定するにはデコーディングを行う必要がある．この時，必須格ごとに他の必須格の予測結果を考慮せずにそれぞれの必須格で独立して項候補を選択していった場合，一つの項候補に複数の必須格ラベルを付与する場合が起こりうる．

そこで，今回はそれを防ぎ，一つの項候補には一つの必須格を割り当てるために制約付きデコーディングとして global-argmax による手法を用いた．擬似コードを Algorithm 1，7〜15 行目に示す．全ての必須格に対する各項候補の確率ベクトルを結合して，それらの中で値の高いものから必須格として割り当てていく．このとき，既に割り当てられた項候補は別の必須格の項候補に割り当てないようにした．同様に既に割り当てる項候補が決まっている必須格には複数の項候補を割り当てないようにした．それぞれ，値が高いものから順に割り当てを行なった．

文の中から最適な項候補をそれぞれの必須格に対して独立して選択する操作は，既存の系列ラベリングモデルでは単語に対して必須格ごとの推定確率を算出しているため実現できないが，本提案手法では Pointer Networks モデルを用いて文長方向の推定確率を算出できるようになったことで global な argmax を取る操作が可能となった．

4. 実験

4.1 実験設定

データは NAIST テキストコーパス 1.5 を用いた．訓練, 開発, 評価データへの分割は Taira ら [Taira 08] の方法に従った．

Algorithm 1 デコードアルゴリズム

Given:
s_{wo}: 各項候補に対するヲ格の推定確率ベクトル
s_{ga}: 各項候補に対するガ格の推定確率ベクトル
s_{ni}: 各項候補に対するニ格の推定確率ベクトル
l: 上記ベクトル長（ヲ，ガ，ニで同じ）

Do (global argmax):
$ret = [0, 0, 0]$
$s = \text{concat}(s_{wo}, s_{ga}, s_{ni})$
$s, type1, pos1 = \text{get\_index}([], [], s, l)$
$ret[type1] = pos1$
$s, type2, pos2 = \text{get\_index}([type1], [pos1], s, l)$
$ret[type2] = pos2$
$s, type3, pos3 = \text{get\_index}([type1, type2], [pos1, pos2], s, l)$
$ret[type3] = pos3$

---

procedure get_index($types, poses, s, l$)
    $index = \text{argmax}(s)$
    while is_on_restricted($types, poses, index, l$) **do**
        $s[index] = -\infty$
        $index = \text{argmax}(s)$
    end while
    $type = \text{int}(index \div l)$
    $pos = index \mod l$
    return $s, type, pos$
end procedure

---

procedure is_on_restricted($types, poses, index, l$)
    $t = \text{int}(index \div l)$
    $p = index \mod l$
    if $p == 0$ **then** return False
    end if
    if $t \in types$ **then** return True
    end if
    if $p \in poses$ **then** return True
    end if
    return False
end procedure

詳細な数は表 1 に記載する．単語境界，文節境界は NAIST テキストコーパスに付与されているものを使用した．

モデルは pytorch ver.1.0.0 で訓練，評価を行った．それぞれのモデルで利用したハイパーパラメータおよび探索範囲を表 2 に示す．ハイパーパラメータの選定には pytorch ver.0.4.1.post2, hyperopt [Bergstra 13] を用いた．hyperopt は提案手法は ver.0.1，ベースラインは ver.0.1.1 を用いた．

4.2 結果

結果を表 3 に示す．スコアは全て F1 値である．本研究で算出したスコアはモデルの重みパラメータを生成するシードの異なるモデルを 5 つ作成し，その平均と分散を示した．Dep は述語と項候補が直接の係り受け関係にあるものを表し，Zero は文内ゼロ照応によって項が省略されたものを表す．

先行研究 [Matsubayashi 18] では各必須格ごとのスコアが提示されていないが，本研究は全体，Dep の ALL において M&I [Matsubayashi 18] の手法を，各必須格に対しても Ouchi ら [Ouchi 17] の手法を上回るスコアを出すことができた．

項目	訓練	開発	評価
文数	23,218	4,628	8,816
述語数	62,489	12,724	23,981
ガ格の数 [a]	37,615/11,546	7,520/2,552	14,230/4,764
ヲ格の数 [a]	24,997/1,802	5,105/394	9,532/783
ニ格の数 [a]	5,855/359	1,637/112	2,547/211

[a] Dep/Zero の数を記載した

表 1: NAIST テキストコーパス 1.5 の文内の述語項の数

本来、百億円は自分で**借り**たものであり、
自ら返済すべきカネではないのか。

分類	ガ格	ヲ格	ニ格
正解	自分	もの	ー
ベースライン	ー	円、もの	ー
提案手法	ー	もの	ー

図 4: 格の出現を予測できなかった例

両親の選択は**誤っ**ていなかったようだ。

分類	ガ格	ヲ格	ニ格
正解	両親	選択	ー
ベースライン	ー	ー	ー
提案手法	選択	ー	ー

図 5: 格の出現は予測できたが，単語を間違えた例

5. 考察

まず各モデルの正誤の集計結果について述べる．結果はモデルパラメータ初期値の生成シードを変えたモデルを 5 つ作成し，そのうち 4 つ以上のモデルが同じ回答を出したものを用いた．正答件数はベースライン 16,037 件に対して，提案手法 16,670 件であった．同一の必須格に複数の項候補を割り当てたものはベースラインでは 76 件であったが，それらは提案手法で解消された．

提案手法の誤答例を図 4，5 に示す．図 4 は格の出現を予測できなかったものの例である．述語「借り」に対して，正解はガ格「自分」とヲ格「もの」である．ベースラインは「円」と「もの」をヲ格と出力し，ガ格を出現できておらず，また一つの必須格に複数の項候補を割り当てている．一方で，提案手法では「もの」をヲ格と正しく出力しているが，ベースライン同様にガ格の出現を予測することができなかった．同類の誤りは 2,147 件あった．また，図 5 は格の出現は予測できたが，単語を間違えたものの例である．述語「誤っ」に対して，ガ格の正解は「両親」であるが，提案手法は「選択」と誤答している．同類の誤りは 3,071 件あった．

これらは述語に関する知識（例えばガ格に有生性のものがきやすい述語）や，文脈に関する情報が足りていない事が要因であると考えられる．図 4 の述語「借り」は，主語に有生性のものがきやすい述語であるが，そのような格フレームに関する知識はモデルに与えていない．また，図 5 はガ格の「両親」は述語に直接かかっていないため難易度が高く，格フレームなどの選択選好相当の知識や文全体を考慮に入れた手法を用いる必要があると考える．特に述語の知識をモデルに組み込む研究は Neural Network 以前に盛んに行われており，それらと Neural Network を組み合わせた研究を進める必要があると考える．

パラメータ	ベースライン	提案手法	探索範囲
最適化手法	RMSprop	SGD	Adam, Adadelta, Adagrad, SGD, RMSProp から選択
学習率	0.0001	0.1	0.2, 0.1, 0.05, 0.01, 0.005, 0.001, 0.0001 から選択
バッチサイズ	10	16	2 から 200（ベースライン）, 256（提案手法）を 2 刻み
出力層サイズ: d_1^{ptr}	-	96	64 から 256 を 16 刻み
勾配クリップ	10	5	0 から 10 を 1 刻み
ドロップアウト率	0.2	0.3	0.0 から 0.7 を 0.1 刻み

表 2: ハイパーパラメータ

	全体		Dep				Zero			
手法	ALL	SD	ALL	ガ格	ヲ格	ニ格	ALL	ガ格	ヲ格	ニ格
Ouchi+ 17 Single_Seq	81.15	-	88.10	88.32	93.89	65.91	46.10	49.51	35.07	9.83
M & I 18 BASE	83.39	±0.13	89.90	-	-	-	54.37	-	-	-
Ouchi+ 17 Multi_Seq	81.42	-	88.17	88.75	93.68	64.38	47.12	50.65	32.35	7.52
M & I 18 MP_POOL_SELFATT	83.94	±0.12	90.26	90.88	94.99	67.57	**55.55**	**57.99**	**48.9**	**23**
ベースライン	83.70	±0.28	90.31	90.65	94.79	**72.09**	52.53	54.98	45.21	11.09
提案手法	**84.37**	±0.18	**90.73**	**91.01**	**95.04**	72.01	54.06	56.66	45.16	9.38

表 3: 評価データに対する F1 スコア（ベースライン，提案手法は 5 モデルの平均値）

6. 関連研究

文内述語項構造解析の研究はこれまでも盛んに行われてきている．Taira ら [Taira 08] は，ガ格，ヲ格，ニ格のそれぞれの必須格ごとにモデルを用意した手法を提案した．Yoshikawa ら [Yoshikawa 11] は，Markov Logic という統計的関係学習の枠組みで項の間の関係性を考慮した手法を提案した．Ouchi ら [Ouchi 15] は，二部グラフを用いて複数の述語と項の関係性を考慮しつつ解析する手法を提案した．本研究ではこれらの研究とは異なり，必須格ごとにモデルを構成するのではなく，出力層を除いて全ての必須格を同じモデルで構成した．また，Pointer Networks を用いて項の関係性を表現した．

今日では，本研究と同様に Neural Network を用いた手法が盛んに用いられている．Ouchi ら [Ouchi 17] は，ある 1 つの述語に対する述語項構造情報を別の述語の構造解析に役立てるために，複数の述語を同時に考慮する Grid Recurrent Neural Networks (Grid RNN) を用いた手法を提案した．また，Matsubayashi & Inui [Matsubayashi 18] は，Ouchi ら [Ouchi 17] の研究を更に発展させ，Grid RNN に対して self-attention を適用した手法を提案した．

本研究ではこれらの研究とは異なり，系列ラベリングで解く場合のように系列中の各単語がどの必須格らしいかではなく，系列の中からどの単語が最も必須格らしいかを推定するタスクとして，述語項構造解析を解く．また，先行研究 [Ouchi 17, Matsubayashi 18] では複数の述語の関係を考慮に入れたモデルが提案されているが，本研究では複数の述語の関係は考慮に入れていない．

7. おわりに

本研究では系列ラベリング手法で問題であった複数の項に同じ必須格を割り当ててしまうという問題に対し，Pointer Networks と制約付きデコーディングを組み合わせた手法を用いることで解決することができ，同時に F1 値も向上した．

一方で，提案手法でも解決できていない例も確認された．これらは述語の格フレームなどの選択選好を考慮に入れたモデルや，文脈や文全体を考慮に入れたモデルを用いることで解決できるのではないかと考える．これらを今後の課題としたい．

参考文献

[Bergstra 13] Bergstra, J., Yamins, D., and Cox, D.: Making a Science of Model Search: Hyperparameter Optimization in Hundreds of Dimensions for Vision Architectures, in *Proceedings of ICML*, pp. 115–123 (2013)

[Cho 14] Cho, K., Merriënboer, van B., Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y.: Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation, in *Proceedings of EMNLP*, pp. 1724–1734 (2014)

[Matsubayashi 18] Matsubayashi, Y. and Inui, K.: Distance-Free Modeling of Multi-Predicate Interactions in End-to-End Japanese Predicate Argument Structure Analysis, in *Proceedings of COLING*, pp. 94–106 (2018)

[Ouchi 15] Ouchi, H., Shindo, H., Duh, K., and Matsumoto, Y.: Joint Case Argument Identification for Japanese Predicate Argument Structure Analysis, in *Proceedings of the ACL–IJCNLP*, pp. 961–970 (2015)

[Ouchi 17] Ouchi, H., Shindo, H., and Matsumoto, Y.: Neural Modeling of Multi-Predicate Interactions for Japanese Predicate Argument Structure Analysis, in *Proceedings of ACL*, pp. 1591–1600 (2017)

[Taira 08] Taira, H., Fujita, S., and Nagata, M.: A Japanese Predicate Argument Structure Analysis Using Decision Lists, in *Proceedings of EMNLP*, pp. 523–532 (2008)

[Vinyals 15] Vinyals, O., Fortunato, M., and Jaitly, N.: Pointer Networks, in *Proceedings of NIPS*, pp. 2692–2700 (2015)

[Yoshikawa 11] Yoshikawa, K., Asahara, M., and Matsumoto, Y.: Jointly Extracting Japanese Predicate-Argument Relation with Markov Logic, in *Proceedings of IJCNLP*, pp. 1125–1133 (2011)

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

日本語大規模 SNS+Web コーパスによる単語分散表現のモデル構築

Constructing of the word embedding model by Japanese large scale SNS + Web corpus

松野 省吾 Shogo Matsuno　水木 栄 Sakae Mizuki　榊 剛史 Takeshi Sakaki

株式会社ホットリンク
Hottolink, Inc.

Abstract: In this paper, we present the word embedding model constructed by Japanese text existing on SNS including Twitter. This model is created from a Japanese large-scale corpus using multiple categories such as SNS data, Wikipedia, and Web pages as media. Perorming the evaluation by the word similarity calculation task with Speaman's rank correlation coefficient as the evaluation index for the created word embedding model resulted in a performance of about 7 points better than the model created by only Wikipedia as the learning corpus was obtained. The presented word embedding model in this paper is planned to be released through the website, and we hope that by utilizing this model, natural language processing research for SNS data will become more active.

1. はじめに

自然言語処理の研究開発を進める上で，単語分散表現モデルを用いる機会が多くなっている．単語分散表現は単語の周辺文脈を含めて単語の意味をベクトルとして表現する．これを用いることで，文書分類，評判分析，機械翻訳など，様々な自然言語処理タスクの性能が向上することが示されてきた．そのため，コーパスから作成した単語分散表現のモデルが活発に研究・公開されているが，大規模なコーパスはその殆どが英語を対象とするものであり，公開されている日本語を対象としたコーパスとその単語分散表現は限られている．主要な日本語大規模コーパスとしては，現代日本語書き言葉均衡コーパス(BCCWJ)[前川 2008]，国語研日本語ウェブコーパス(NWJC)[Asahara 2014]，京都大学テキストコーパス[河原 2002]，Kyoto University and NTT Blog コーパス(KNB)[橋本 2011]などが知られている．一方で，Twitter のような SNS に着目したコーパスはプライバシー保護の観点などから公開が難しく，単語分散表現モデルとしての公開も GloVe[Pennington 2015] や Twitter word2vec model[Godin 2015]といった，英語を対象としたモデルに限られる．そこで，筆者らの研究開発上で利用するリソースとして作成した単語分散表現モデルを一般に利用可能な形で配布することにした．筆者らの分散表現モデルは日本語 Wikipedia に加え，自動収集した Web ページ，ブログや Twitter 等の SNS データを中心としてコーパスを構築しており，砕けた日本語表現やネットスラングなどの新語・未知語を多く含むという特徴を持つ．

本稿では，配布する分散表現モデルの作成方法と，その学習コーパスである日本語大規模 SNS+Web コーパスについて紹介する．

2. コーパス構築方法

本稿で紹介する日本語大規模 SNS+Web コーパスは SNS データ，日本語 wikipedia，自動収集 Web ページの 3 種類の媒体から作成した日本語大規模コーパスである．複数の媒体から語彙を収集したため，語彙情報が豊富であり，応用向きであることを特徴とする．各媒体の規模は SNS（ブログ・Twitter）データ＞自動収集 Web ページ＞日本語 wikipedia の順である．

連絡先：松野省吾，株式会社ホットリンク，東京都千代田区富士見 1-3-11 富士見デュープレックスビズ 5F，shogo.matsuno@hottolink.co.jp

各媒体は以下の 4 種類の処理を順に実施した．

1. 平文コーパスの収集・構築
2. 前処理
3. 分かち書きコーパスの構築
4. 全媒体を統合，単語分散表現(Word2Vec)の学習

以下，各処理について説明する．

2.1 平文コーパスの収集・構築

平文コーパスを構築するためにデータを収集した．データ収集の期間は以下の通りである．

- ブログ：2015 年 1 月～2016 年 6 月
- Twitter：2016 年に公式アプリからの投稿の一部
- 日本語 Wikipedia：2015 年 11 月 23 日付 dump file
- 自動収集 Web ページ：2009 年 9 月～2016 年 6 月

なお，Twitter データはリツイートによる投稿を除外している．

2.2 前処理

収集した平文コーパスから本文を抽出する．各媒体から本文抽出時に加えた処理を以下に示す．

- ブログ：HTML タグの除去
- Twitter：ReTweet ヘッダ，URL，メンションタグ，ハッシュタグの除去
- 日本語 Wikipedia：タグ，テーブル等のメタ情報の除去（WikiExtractor を使用）
- 自動収集 Web ページ：HTML タグの除去

次に，意表記を吸収するための正規化処理を実施する．正規化処理を以下に示す．

- 全角英数字を半角に置換
- 半角カタカナを全角に置換
- ハイフンの類似文字をハイフンマイナス(U+002D)に置換
- 長音記号の類似文字を全角長音記号(U+30FC)に置換
- 1 回以上連続する長音記号，スペースを 1 回に置換
- チルダに類似する文字を削除
- 全角記号，全角スペースは半角に置換
- ただし，句読点，中黒，等号，カギ括弧は全角記号に置換
- テキスト先頭・末尾・文字間に含まれるスペースを削除

なお，正規化処理の実装は Python::neologdn package を用いた．

2.3 分かち書きコーパスの構築

前処理済の平文コーパスの分かち書きを実施する. 分かち書き器として MeCab を用い, システム辞書に mecab-ipadic-NEologd を用いた. ただし, Twitter 媒体のみ分かち書き器として Juman を用いている. Juman を用いる理由としては以下で述べる. また, 最小形態素数は日本語 wikipedia のみ 5 とし, それ以外の媒体では 10 とした.

Twitter はくだけた文体が多いことから, 通常の形態素解析器では分かち書きの性能が十分でないことが知られている[北川 201, 森 2016]. そのため, Twitter の分かち書き精度向上を目的としたコーパスの構築も試みられている[大崎 2016]. また, Juman は未知語モデルを搭載しているため, くだけた文体に対しても比較的ロバストな処理が可能であるという報告もある[笹野 2014]. そこで, 実際に Twitter の本文の分かち書きを行い, いずれの方法が良いかを調査した.

調査対象となる文は Twitter から 129 文をランダムで抽出し, 以下に示す形態素解析器と辞書・モデルの組み合わせを用いて分かち書きを行った. 文ごとの分かち書き結果を確認し, 特に誤りが少ないように思えるモデルを選び(複数選択可), 選ばれた回数を各組み合わせで比較した. 表 1 に分かち書き器と辞書・モデルの組み合わせと選択回数の結果を示す.

表 5 から, 今回の調査では Juman による分かち書きが最も誤りが少ないように思えるという結果となった. そこで, 日本語大規模 SNS コーパスでは Twitter の分かち書き器として Juman を用いる.

表 1: 分かち書き器と辞書・モデルの組み合わせと選択回数

分かち書き器	辞書・モデル	選択回数
Juman	default	47
MeCab	mecab-ipadic-NEologd	41
MeCab	ipadic	37
KyTea	default (BCCWJ + UniDic)	16
KyTea	Twitter Corpus (re-training)	14

2.4 単語分散表現の学習

作成した分かち書きコーパスを用い, 単語分散表現(Word2Vec [Mikolov 2013])を学習する. ここで, 実装は Python::genism package を使用した. 表 2 に Word2Vec の学習パラメータを示す.

表 2: Word2Vec の学習パラメータ

パラメータ	値
アルゴリズム	Word2Vec [CBOW,Skip-Gram]
次元数	200
最低単語頻度	10
Context window size	5
負例サンプリング	25
初期学習率 α	0.025
Context Distribution Smoothing	0.75
Down-sampling ratio	1e-5
Iteration	20
単語表現	w

3. 評価

3.1 コーパスの概要

表 3, 4 に構築したコーパスの規模を示す. また, 表 5 に分かち書きコーパスの統計量を示す.

表 3: 平文コーパスの規模

媒体	行数 [Mil]	ファイルサイズ [GB]
SNS データ	288	36.2
Wikipedia	7	2.2
Web ページ	126	25

表 4: 分かち書きコーパスの規模

媒体	行数 [Mil]	ファイルサイズ [GB]
SNS データ	180	37.1
Wikipedia	7	2.5
Web ページ	95	28

表 5: 分かち書きコーパスの統計量

指標	値
行数 [Mil]	282
トークン数[Giga]	12
頻度 10 回以上のユニークな形態素数	2,067,629

3.2 分散表現の性能評価

日本語大規模 SNS+Web コーパスによる分散表現と Wikipedia による分散表現の性能を比較する. 比較評価対象として, 本コーパスによる分散表現と同様の方法で作成した Wikipedia による分散表現, および東北大により公開されている日本語 Wikipedia エンティティベクトル[Suzuki 2016]を用いる. 加えて, 単語分散表現の性能評価用に単語ペアを厳選したデータセットである, 日本語単語類似度・関連度データセット JWSAN-1400[猪原 2018]を用い, Speaman の順位相関係数を評価指標とすることで, モデル性能評価を実施した.

表 6 に評価結果を示す. 本コーパスによる分散表現は Wikipedia のみで学習した 2 つのモデルと比較し, 良い性能を獲得することができた. Wikipedia のみで学習した 2 つのモデルはほぼ同程度の性能を示していることから, 分散表現の学習方法に関しても妥当であると考えられる.

表 6: 分かち書きコーパスの統計量

モデル	相関係数
日本語大規模 SNS+Web コーパス	0.548
Wikipedia(ホットリンク)	0.478
Wikipedia(東北大)	0.472

4. まとめ

本稿では筆者らの作成した日本語大規模 SNS+Web コーパスとその単語分散表現について, その構築方法と統計量の概要を紹介した. 本コーパスは SNS データを含む大規模な日本語コーパスである. 日本語を対象とした文・単語の分散表現モデルで公開されているものは限られ, SNS や Web 上の文書を学習コーパスとした分散表現のモデルには価値があると筆者らは考えている. 評価実験の結果から, 本コーパスから作成した単語分散表現モデルは Wikipedia から作成したモデルと比較して, 単語類似度算出タスクにおいて 7 ポイント程度良い性能

を獲得できた．本稿で紹介した単語分散表現モデルは Web サイトを通じて公開する予定である．今回のモデルが活用されることで，特に SNS データを対象とした自然言語処理研究が一層盛んになることを期待したい．

今後の予定としては，日本語の文分散表現モデルの作成や，最近の新語，流行語などを取り入れた単語分散表現モデルの更新について取り組みたい．

参考文献

[前川 2008] 前川喜久雄：KOTONOHA『現代日本語書き言葉均衡コーパス』の開発，日本語の研究，4(1), pp. 82-95, 2008.

[Asahara 2014] Masayuki Asahara, Kikuo Maekawa, Mizuho Imada, Sachi Kato, Hikari Konishi: Archiving and Analysing Techniques of the Ultra-large-scale Web-based Corpus Project of NINJAL, Japan', Alexandria, Vol 26, No.1-2, pp.129-148. 2014.

[河原 2002] 河原大輔，黒橋禎夫，橋田浩一：「関係」タグ付きコーパスの作成．言語処理学会 第 8 回年次大会予稿集，pp.495‐498，2002.

[橋本 2011] 橋本力，黒橋禎夫，河原大輔，新里圭司，永田昌明：構文・照応・評判情報つきブログコーパスの構築．自然言語処理 Volume 18, Number 2, pp.175-201. 2011.

[Pennington 2014] Jeffrey Pennington, Richard Socher, and Christopher D. Manning: GloVe: Global Vectors for Word Representation, Empirical Methods in Natural Language Processing (EMNLP), pp. 1532- 1543, 2014.

[Godin 2015] Godin, F., Vandersmissen, B., De Neve, W., & Van de Walle, R.: Named entity recognition for Twitter microposts using distributed word representations. Workshop on Noisy User-generated Text, ACL 2015.

[北川 2016] 北川善彬，小町守：深層ニューラルネットワークを利用した日本語分割，言語処理学会第 22 回年次大会，pp.933-936, 2016.

[森 2016] 森信介：多様なテキストの言語処理，第 112 回音声言語情報処理研究会，招待講演，2016

[大崎 2016] 大崎彩葉，唐口翔平，大迫拓矢，佐々木俊哉，北川善彬，堺澤勇也，小町守：Twitter 日本語形態素解析のためのコーパス構築，言語処理学会第 22 回年次大会，pp.16-19, 2016.

[笹野 2014] 笹野遼平，黒橋禎夫，奥村学：日本語形態素解析における未知語処理の一手法-既知語から派生した表記と未知オノマトペの処理-，自然言語処理，22(6), pp. 1183-1205, 2014.

[Mikolov 2013] T. Mikolov, I. Sutskever, K. Chen, G. S. Correado, and J. Dean: Distributed representations of words and phrases and their compositionality, Advances in neural information processing systems, 26, pp. 3111-3119, 2013.

[鈴木 2016] 鈴木正敏，松田耕史，関根聡，岡崎直観，乾健太郎：Wikipedia 記事に対する拡張固有表現ラベルの多重付与，言語処理学会第 22 回年次大会，2016. (http://www.cl.ecei.tohoku.ac.jp/~m-suzuki/jawiki_vector)

[猪原 2018] 猪原敬介，内海彰：日本語類似度・関連度データセットの作成，言語処理学会第 24 回年次大会，pp. 1011-1014, 2018. (http://www.utm.inf.uec.ac.jp/JWSAN/)

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

Action Unit の組み合わせを用いた快感情抑圧表現アニメーションの生成

Generation of facial animations to express suppressed positive emotion using action units

大道 博文[*1] 林 柚季[*2] 目良 和也[*1] 黒澤 義明[*1] 竹澤 寿幸[*1]
Hirofumi Omichi Yuzuki Hayashi Kazuya Mera Yoshiaki Kurosawa Toshiyuki Takezawa

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

[*2] 広島市立大学情報科学部
School of Information Sciences, Hiroshima City University

Expressing emotion is important for communication on the Internet, and some avatars can express their facial expressions. However, it is difficult to create facial animations of an avatar to express complicated emotional states (e.g. happy but embarrassed) for non-expert creators because there is no formulated method proved scientifically. This paper proposes a method to create facial animations to express "suppressed positive emotion" so called "Tsundere" by using combination of action units. In order to apply two types of suppression methods, "neutralized" and "masked," the action units are chosen by considering "suppressing or suppressed emotion" and "controllable or uncontrollable unit." 18 facial animations are created and evaluated by Sheffé's method. As a result, a combination of slight-happy action units and blushing and that of anger-shaped eyebrows and blushing were the most effective to express "suppressed positive emotion."

1. はじめに

近年, Virtual Reality（VR）ゲームや Virtual Youtuber といった CG アバターを介した他者とのコミュニケーションが普及しつつある. そしてこのようなアバターを通じてユーザの心理状態を伝達させるためには, 特定の感情を示す表情をアバターに付与する方法や, 自身の表情や動作をアバターと同期させる方法などが用いられている.

アバターに表情を付与するには, アバターの作者が表情・動作のパターンをあらかじめ設定する必要がある. 喜びや悲しみ, 怒りなど単純な感情を示す表情の生成はこれまでも多く行われており, 各感情における典型的な特徴を誇張して表現することで, アバターを見る側との共通認識に基づく感情推定が比較的容易に行われている. しかし, 複数の感情が含まれた表情やある感情を抑圧しているような表情を表現するための典型的な特徴や統一された指標は無く, 各モデルの作成者の経験や感覚に依るところが大きい. そのため, 非熟練者や表情モデルからの自動合成手法による表情モデルの作成は現状困難である.

そこで本研究では, Facial Action Coding System（FACS）[Ekman 02a]で用いられる各表情の部分的表出（Action Unit（AU））の組み合わせに基づいて複数の表情アニメーション動画を作成し, Sheffé の一対比較法を用いて表出したい感情に対する各 AU の効果について分析を行う. 本研究では所謂"ツンデレ"と呼ばれる「快感情の抑圧表情」を対象とするため, Ekman の知見に基づき"表情表出の程度を弱める"**中立化**と, "他の表情を意図的に表出する"**隠蔽**の二種類の抑圧表現について実験を行う.

2. 抑圧表情の表現方法

2.1 感情表情の偽装方法

表情分析入門[Ekman 87]では, 偽りの顔の顔面統御の技法として"メッセージの偽装"という方法が示されている. 偽装における顔面統御には, "顔の形態", "表情のタイミング" , "会話中に表れるその表情の位置" , "中断に起因する微表情"の 4 つの側面がある. "顔の形態"は, 特定の感情に応じて顔の特定の部分は別の特定の部分より偽装がされやすいことや, どこに着目すれば実際に感じている感情と偽りの感情を知ることができるかなどを示す. "表情のタイミング"は, 表情が消えるまでにかかる時間などを示す. "会話中に表れるその表情の位置"は, 表情のタイミングと綿密に関連があり, その表情が言葉との関係でどこに表れるのかを示す. そして"中断に起因する微表情"は, 実際に感じている感情を反映する表情が妨害されたその中断の結果を示す. これらのうち本研究では"顔の形態"に着目し, 偽装における顔面統御された表情を演技表情として扱う.

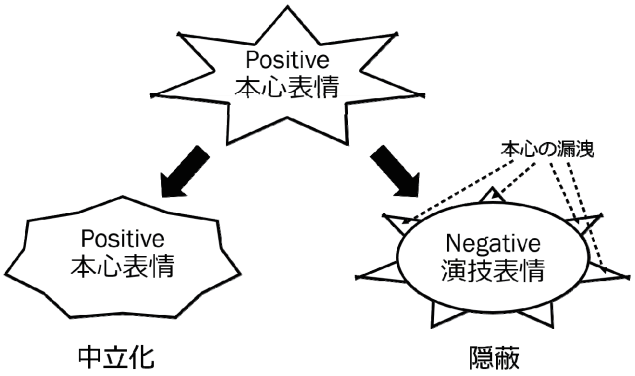


図 1: 中立化と隠蔽を用いた快感情の抑圧表現

演技表情による偽装方法は以下の 3 種類に分けられる.

- 擬態：何も感じていないのに, ある感情表情が示される
- 中立化：実際には特定の感情を感じているのに, 表情には何も表されない
- 隠蔽：実際に感じている感情の代わりに感じていない感情の顔貌を示す

本研究では快感情の抑圧表現を対象としているため, これらの偽装方法のうち"**中立化**"と"**隠蔽**"の 2 種類を用いる. 中立化と隠蔽を用いた快感情の抑圧表現のイメージを図 1 に示す. 「快感情を**抑圧している**」という状態を表現する場合, 本心である感情の兆候が完全に消えてしまっていては本心感情が存在することに気づいてもらえない. そのため, 中立化や隠蔽を行う際には本心感情の兆候を残しておく必要がある. そこで図 1 の上部に位置する本心表情の特徴を基準とし, 中立化では本心

連絡先：目良和也, 広島市立大学大学院情報科学研究科, mera@hiroshima-cu.ac.jp

表情の特徴が弱く表れることで本心が抑圧されている状態を表現する. 一方, 隠蔽では演技表情の特徴でカバーできていない本心表情の特徴が一部漏洩することで抑圧された感情の存在を表現する.

2.2 快感情の抑圧表現に用いる Action Unit

Facial Action Coding System（FACS）[Ekman 02a]は, 視認可能な顔の動きを包括的に測定するために開発された分析ツールかつ表情理論である. FACS には 41 の基本動作が定義されており, その基本動作の組み合わせによって様々な顔の動きがコード化されている. Action Unit（AU）とは FACS の基本動作の 1 つであり, 個々の筋肉または筋肉群の基本的な行動の行動単位である. 各表情の動きに番号が当てられており, 動きの名称や特徴, その動きを行うために動かされる筋肉などが定められている.

本研究では“ツンデレ”と呼ばれる快感情の抑圧状態を表現するため,「快表情の中立化」及び「快感情の怒り表情による隠蔽」の二種類の複合表情の生成を行う. そのためには AU を使って“幸福”, “怒り”, “平静”の表情を表現する必要がある. 表 1 に FACS Investor's guide [Ekman 02b]において“Happy” 及び“Anger”に関連するとされている AU の一覧を示す. なお平静表情はいずれの AU も作動していない状態であるため, 対応する AU を記載していない.

複数の感情を含む表情を生成する研究として, 檜山[檜山 08]では複数の感情を表現する際に強い感情を複数の AU で表現し, その中に弱い感情として単一 AU を加える方式を取っている. しかし, 本研究で対象としている感情の抑圧においては, “抑圧される本心の表情”と“抑圧に用いる演技の表情”の二種類が存在する. そこで本研究では, 意図的にコントロールしやすい／コントロールしづらいという観点から抑圧表情の生成に用いる AU を選定する.

表情分析入門[Ekman 87]では, 一般的に顔は全体を通して顔の上半分より顔の下半分のほうが偽装しやすいとされている. また, 中立化と隠蔽それぞれの偽装において, 中立化における顔の形態として, 筋肉が収縮しないように顔の筋肉をリラックスさせておくことや, 顔の筋肉を無表情なポーカーフェイスの状態に固定させること, 顎をこわばらせること, 唇をきつく締め付けずに閉じること, 前方を凝視するが瞼を緊張させないことなどがあげられる. 怒りを隠蔽に使用するときの顔の形態では, 怒りの特徴は顔の下半分だけでなく眉や額の両方にあらわれ, 瞼にだけは本心が漏洩する. また, 幸福に関して眼輪筋の意図的な収縮は難しいとされている.

これらをふまえ FACS Manual [Ekman 02a]に掲載されている各 AU の説明を調査した結果, AU6（頬を挙げる）は意図的にコントロールしづらく, AU12（口角をつり上げる）, AU4（両眉を中央に寄せる）, AU5（目を見開く）, AU7（瞼に力を入れる）は意図的に動作させやすいことが分かった.

また, 本研究ではアバターへの応用を想定しており, ユーザの発言にシンクロして口の形状が大きく変化することがあることと, 口の AU である AU10, 17, 22, 23, 24, 25, 26 はいずれも Anger に関連するが必須要素ではないことから, 本研究では AU10, 17, 22, 23, 24, 25, 26 を抑圧表情の作成には使用しない. しかし口の AU である AU12 は Happy 表情の認識にとって影響が大きいいとされているため抑圧表情の作成に用いる. これらより, 本研究では表 1 の AU のうち, 幸福の AU として AU6 及び 12, 怒りの AU として AU4, 5, 7 を選定し, これらの組み合わせにより快感情の抑圧表現を実現する.

表 1: Happy 及び Anger に関連する Action Unit の一覧

感情	AU number	動作の説明
Happy	**6**	**頬を上げる**
	12	**口端を上げる**
Anger	**4**	**眉を下げる**
	5	**上瞼を上げる**
	7	**瞼を緊張させる**
	10	上唇を上げる
	17	顎を上げる
	22+25	唇を漏斗型にする
	23	唇を閉じる
	24	唇を上下から圧する
	25	唇を開く
	26	顎を下げる

表 2: 中立化及び隠蔽による快感情抑圧表情に用いる AU

偽装方法	本心表情	演技表情
中立化	幸福	平静（AU 無し）
隠蔽	（AU6, AU12）	怒り（AU4, 5, 7）

さらに幸福を表すユニットとして, 従来の快感情抑圧表情のイラストでよく用いられる赤面（頬の紅潮）を追加する. 赤面は快不快の指標ではなく活性度の指標とみなすことができ, 興奮, 緊張, 怒り, 照れの意図的にコントロールできない指標と考えられる. そこで, 本研究では隠蔽において「意図的にコントロールしやすい眉で怒りを演じているが, 意図的にコントロールできない赤面として照れの本心が漏洩している」ことを仮説として提案する. 表 2 に中立化及び隠蔽による快感情抑圧表情の作成に用いる AU の一覧を示す.

3. 快感情の抑圧表情アニメーションの作成

3.1 Live2D を用いた表情アニメーションの作成

本研究で使用する表情アニメーションの生成には Live2D Cubism [Live2Da]と呼ばれる一枚の原画をもとにアニメーションを作成するツールを用いる. また, 感情を表出するキャラクターとして, Live2D が提供しているサンプルモデル [Live2Db]より“しずく”を使用する. “しずく”は各表情パーツの細かい分割が行われているため AU 単位での表情作成に適しており, 作成した表情を評価者に評価してもらう際にも, 眉, 目, 口といった表情パーツが明確に識別しやすい.

Live2D Cubism では, 眉, 目, 口などの各パーツの形状をある状態から異なる状態に徐々に変化していくようなアニメーションを生成できる. そのため, 初期状態を平静, 変化後状態を AU が動作した後のパーツの形状と設定することで, アニメーション上は平静状態から表情が表出したように見える. 例えば AU12 のみが表出する表情アニメーションを作成する場合, 変化後状態の表情において AU12 の動作により口端が上がった形状になった口を描画し, それ以外の顔パーツは初期状態と同じにして Live2D Cubism を適用する. なお, 評価時に他の要因が絡まないように, アニメーション全体の時間及び表情変化にかかる時間をすべて統一している. また, 表情変化のみに注目させるため, 肩から上のみからなるアニメーションを提示する.

評価用の表情アニメーションは, 中立化と隠蔽それぞれについて表 2 の AU を組み合わせることで作成した. 作成した全 28 件のアニメーションについて予備評価実験を行い, 不自然と評定されたアニメーション 10 件を除外した 18 件を本評価実験で用いる. 本研究で評価対象とした AU の組み合わせ表情を表 3

表 3: 中立化における AU の組み合わせ

	N1	N2	N3	N4	N5	N6
幸福(AU6+12)	○	○	△	△	×	×
赤面	×	○	×	○	×	○

表 4: 隠蔽における AU の組み合わせ

	H1	H2	H3	H4	H5	H6	H7	H8	H9	H10	H11	H12
眉(AU4)	○	○	×	×	×	○	○	○	○	○	×	×
目(AU5+7)	○	○	×	×	○	×	×	×	×	○	×	×
目(AU6)	×	×	○	○	×	○	○	○	○	×	○	○
口(AU12)	×	×	×	×	×	×	×	○	○	○	○	○
赤面	×	○	×	○	○	×	○	×	○	×	×	○

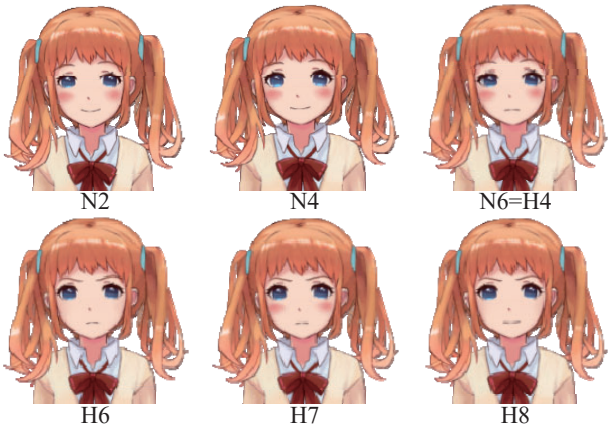


図 2: 作成した表情アニメーションの静止画(一部)

及び表 4 に示す. 表中の○は当該 AU が動作している, △は弱く動作, ×は動作せず平静であることをそれぞれ示す. ただし表 4 の目については, AU5+7 か AU6 のいずれかが動作している. また, 表情アニメーションにおける変化後状態の表情の一部を図 2 に示す.

3.2 評価実験の手順

本研究では, 作成した表情アニメーションについて, それらがどれだけ本来の感情及び“本来の感情を抑圧しようとしていること”の知覚に影響を与えるかについて分析を行うため, Sheffé の一対比較法浦の変法[高木 14][浦 59]を用いて, 主観評価実験を行う. この一対比較では, 2 枚の表情アニメーションを左右に同時に表示し, 以下の 3 種類の質問を行う.

① 喜んでいるように見えるのはどちらか
② 怒っているように見えるのはどちらか
③ 喜びを隠そうとしているように見えるのはどちらか

中立化のアニメーション評価では①, ③の質問, 隠蔽のアニメーション評価では①, ②, ③の質問を行う. 評定者は以下の 5 項目から一つ選択して回答する.

- 左がよりそのように見える
- 左がそのように見える
- どちらも同じくらいに見える, または, どちらもそのように見えない
- 右がそのように見える
- 右がよりそのように見える

評定者は 21 歳～26 歳までの男子大学生及び大学院生 6 名, 21 歳～24 歳までの女子大学生及び大学院生 6 名である.

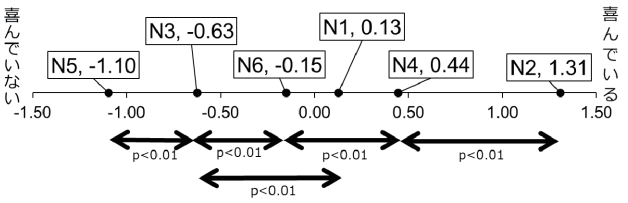


図 3: 喜び度合の多重比較結果(中立化)

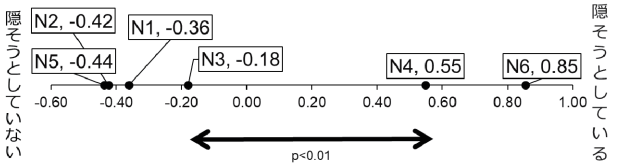


図 4: 喜びを隠そうとする度合の多重比較結果(中立化)

なお評定の際は順序効果[高木 14][浦 59]を考慮してグループ分けした評定者に異なる順序で評定作業を行ってもらった. また, 異なる項目の評価作業を行う際は, 作業の間に最低 2 時間の休憩を入れるよう指示した.

3.3 中立化による抑圧表現の評価実験結果

中立化による喜び度合の多重比較結果を図 3, 喜びを隠そうとする度合の多重比較結果を図 4 にそれぞれ示す. 数直線の下部にある矢印は $p<0.01$ の有意差がある区間を表している.

分析の結果, 「喜びを隠そうとしている」という印象について各 AU の組み合わせが与える効果について以下のことが明らかになった.

- AU6+12(幸福の目, 頬, 口の動作)が表出している時は喜んでいるように見える
- 赤面単体が表出している時は喜んでいるように見えない. 一方, AU6+12(幸福の目, 頬, 口の動作)と同時に表出することで強く喜んでいるように見える. これは 2.2 節で述べたように赤面は快不快ではなく活性度が高いことを表す指標であるため, 幸福の指標と同時に表れることで幸福の度合の高さを表すことができる
- 喜びを隠そうとしているように感じられるのは, AU6+12 が△または×で, かつ赤面が表れている表情(N4, N6)であった. これは AU6+12 で感情生起があまり観察されないにも関わらず赤面で何か活性度の高い心理状態にあるという食い違いの状況が「何らかの感情を隠しているのではないか」という感覚を与えているものと推察できる. そのため, AU6+12 が○, つまり目や口に明確に幸福の表情が見られるならば赤面があっても「素直に喜んでいる」と解釈され(N2), また赤面の無い微弱な幸福の表出(AU6+12＝△)では, 「たださほど喜んでいない」と解釈された(N3)と考えられる

以上のことから, 中立化によるツンデレ表現に最も適している AU の組み合わせは, AU6+12(幸福の目, 頬, 口の動作)が弱いか無い, かつ赤面が起こっている状態(N4, N6)であることが明らかになった.

3.4 隠蔽による抑圧表現の評価実験結果

隠蔽による喜び度合の多重比較結果を図 5, 怒り度合の多重比較結果を図 6, 喜びを隠そうとする度合の多重比較結果を図 7 にそれぞれ示す.

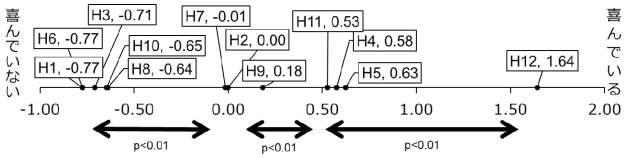


図 5: 喜び度合の多重比較結果(隠蔽)

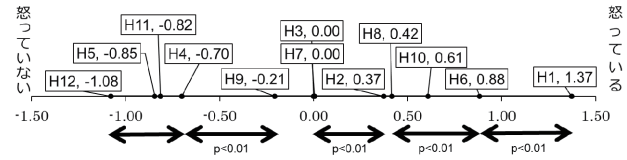


図 6: 怒り度合の多重比較結果(隠蔽)

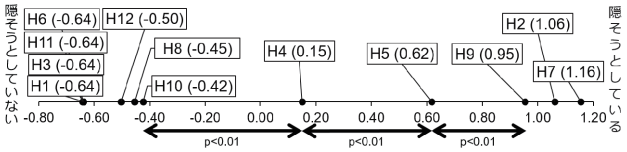


図 7: 喜びを隠そうとする度合の多重比較結果(隠蔽)

分析の結果,「喜びを隠そうとしている」という印象について各 AU の組み合わせが与える効果について以下のことが明らかになった.

- 赤面が表出している時は喜んでいるように見える. 一方 AU4(怒りの眉)が表出している時は喜んでいないように見える
- AU4(怒りの眉)が表出している時は怒っているように見える. 一方, 赤面や AU12(幸福の口)が表出しているときは怒っていないように見える
- 目の AU の違い(AU5+7(怒り), AU6(幸福))は喜び, 怒り, 喜びを隠しているのいずれの項目においても回答に有意差は無かった
- 喜びを隠そうとしているように感じられるのは, AU4(怒りの眉)かつ赤面が表出している表情(H2, H7, H9)であった. これは, 2.2 節で述べた仮説に合致する結果である. しかし, 赤面の代わりに AU6(幸福の目)で本心を表現した組み合わせ(H6)や, AU12(幸福の口)で本心を表現した組み合わせ(H10)では単なる怒りとして解釈されていた

以上のことから, 隠蔽によるツンデレ表現に最も適している AU の組み合わせは, AU4(怒りの眉))かつ赤面が表出している表情(H2, H7, H9)であることが明らかになった.

4. おわりに

本研究では, アバターの表情の生成において複数の感情を含むものや感情の抑圧のような複雑な表情の生成を行うことを目的として, 心理学的見地に基づいて表情パーツの合成を行った表情アニメーションを作成し, どのパーツの組み合わせが感情抑圧表現として有効であるかの調査を行った.

本研究では複雑な表情の事例として快感情の抑圧表情である“ツンデレ”を対象として, 中立化と隠蔽による快感情の抑圧状態を表現した. 表情アニメーションの構成パーツとして, AU6(頬を挙げる), AU12(口角をつり上げる), AU4(両眉を中央に寄せる), AU5(目を見開く), AU7(瞼に力を入れる)に赤面を加えた 6 種類を用いた.

明確に不自然なアニメーションを除外した中立化 6 種, 隠蔽 12 種のアニメーションに対して Sheffé の一対比較法を用いて,「喜んでいるか」,「怒っているか」,「喜びを隠そうとしているか」の 3 項目について評価者 12 名が評定を行った. その結果, 中立化によるツンデレ表現に最も適している AU の組み合わせは, AU6+12(幸福の目, 頬, 口の動作)が弱いか無い, かつ赤面が起こっている状態(N4, N6)であることが明らかになった. また, 隠蔽によるツンデレ表現に最も適している AU の組み合わせは, AU4(怒りの眉))かつ赤面が表出している表情(H2, H7, H9)であることが明らかになった. この結果は,「意図的にコントロールしやすい眉で怒りを演じているが, 意図的にコントロールできない赤面として照れの本心が漏洩している」という提案手法の仮説に合致する.

今後は, 生成したアニメーションのモデルにリップシンク機能を用いて発話音声を付与した場合の印象評定と, 表情のタイミングや継続時間による影響について分析する予定である.

謝辞

本研究の一部は国立研究開発法人科学技術振興機構(JST)の研究成果展開事業「センター・オブ・イノベーション(COI)プログラム」の支援によって行われています. また本研究を行うにあたり, Live2D(株)からアニメーション作成ツール Live2D Cubism をご提供頂いています.

参考文献

[Ekman 87] Paul Ekman, Wallace V. Friesen, 工藤力(訳): 表情分析入門―表情に隠された意味をさぐる, 誠信書房, 1987

[Ekman 02a] Paul Ekman, Wallace V. Friesen, and Joseph C. Hager: Facial Action Cording System The Manual, Network Information Research Corp, 2002

[Ekman 02b] Paul Ekman, Wallace V. Friesen, and Joseph C. Hager: Facial Action Cording System Investigator’s Guide, Network Information Research Corp, 2002

[檜山 08] 檜山洋一, 中坪祐介, 羽倉淳, 樽松理樹, 藤田ハミド: FACS を用いた複数感情の表情合成手法, 2008 年電子情報通信学会総合大会講演論文集, AS-7-7, 2008

[Live2Da] Cubism 3 | Live2D, 株式会社 Live2D, https://www.live2d.com/ja/products/cubism3/, (2019 年 2 月 7 日アクセス)

[Live2Db] サンプルデータ集 - Live2D Cubism 2 マニュアル, 株式会社 Live2D, http://sites.cybernoids.jp/cubism2/samples/, (2019 年 2 月 7 日アクセス)

[高木 14] 高木英行: 使える!統計検定・機械学習―Ⅲ―主観評価実験のための有意差検定, Institute of Systems, Control and Information Engineers, システム/制御/情報, Vol.58, No.12, pp.514−520, 2014

[浦 59] 浦昭二: 一対比較実験の解析, 品質管理, Vol.16, pp.78–80, 1959

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

視線情報を用いた拡散的思考タスクにおける パフォーマンス推定に関する研究

Research on performance estimation in divergent thinking task using gaze information

中原 和洋[*1]
Kazuhiro Nakahara

[*1] 日本ユニシス株式会社
Nihon Unisys, Ltd.

In creativity research, creative thinking such as fixation that negatively affects to the flexibility of idea generation are known. Currently, the detection and elimination of these negative factors highly depends on human skills and techniques. In this paper, we report a hypothesis verification aimed at detecting negative factors using gaze information. Specifically, we conducted hypothesis verification experiments on whether or not the length of gaze fixation time to the existing idea lowers the flexibility of idea generation in divergent thinking task. As a result of the experiment, there was no significant relation between the length of gaze fixation time to existing idea and flexibility of idea generation. As another characteristic result, a cubic regression was observed between blink rate and flexibility, which was similar to the previous study.

1. はじめに

創造性研究において，アイデア創造を促進するアナロジーなどの創造的思考法や，パフォーマンスを低下させる固着[Finke 92]などの現象が知られる．これらアイデア創造の促進や阻害要因の解消は，人的スキルや創造技法に依存しているのが現状であり，情報技術のアプローチによる支援が期待される．我々は，創造者の生体情報や創造物の特徴などの客観的データを用いたパフォーマンスの状況推定，低下要因の検知，解消支援を目的とした研究を進めている．本論文では，創造者の視線情報とアイデア創造パフォーマンスとの間の関係性の仮説検証を目的とした研究について報告する．具体的には，拡散的思考タスクである Alternative Uses Task[Guilford 67]において視線情報を合わせて収集する実験を行い，拡散的思考のパフォーマンスと，自身の既出アイデアへの視線停留時間の間の関連の分析，仮説検証を実施した．

2. 関連研究

本章では，拡散的思考タスクの一つである Alternative Uses Task について説明し，次に視線情報と創造性の関連についての先行研究について述べる．

2.1 Alternative Uses Task

Guilford は創造性を特徴づける思考の一つが拡散的思考(divergent thinking)であるとし，拡散的思考の測定方法として Alternative Uses Task（以降：AUT）を提案した[Guilford 67]．AUT は，被験者に日用品（レンガ，はさみ等）が一つ題材として提示され，その独創的な代替用途アイデアをできるだけ多く回答するタスクである．例えばレンガの通常用途は「積み上げて壁をつくる」等であるが，独創的な代替用途は「鉄アレイの代わりにする」「ドアストッパーにする」などである．回答アイデア群について，次の四つの指標で評価する．

1）流暢性（fluency）：重複の無いアイデア総数
2）柔軟性（flexibility）：重複の無いアイデアの種類数
3）独創性（originality）：アイデアの希少度合い．
4）綿密性（elaboration）：アイデアの表現の綿密度合い．

連絡先：中原和洋，日本ユニシス(株)総合技術研究所，東京都江東区豊洲1－1－1，kazuhiro.nakahara@unisys.co.jp

2.2 視線情報と創造性

本節では，視線情報と創造性の関係についての先行研究を記述する．Akbari Chermahini らは，AUT における柔軟性と瞬目率（1 分当たりの瞬きの回数）との間に，逆U字型の関係（中程度の瞬目率が最も高い柔軟性，低いおよび高い瞬目率が低い柔軟性）を示した[Akbari Chermahini 10]．また Ueda らは，AUT の流暢性と瞬目率の間に正の相関(線形回帰)を報告している[Ueda 15]．

Bilalić らはチェスのエキスパートへの実験において，被験者が最善手を探していたと報告したのにも関わらず，実際には次善手に関するマスへ視線が集中していたことを示した[Bilalić 08]．

これらの先行研究から，創造者の瞬きやどこを見ているかの視線情報は，創造過程における固着やパフォーマンス推定の重要なサインの一つであることが示唆される．

3. 本研究仮説

Finke らの研究において例の提示によりアイデア創造の固着が発生すること， Bilalić らの研究において視線停留により，次の手の検討に対する固着が生じていたことから，本研究では次の仮説を立てた．AUT 実施中において，自身の既出アイデアへの視線停留時間が長い被験者は，既出アイデアと異なる種類のアイデアの検討を阻害する固着が生じ，結果として柔軟性の指標が低下する，という仮説である．この仮説検証を目的の1つとして次章で示すデータ収集実験を実施した．

4. 方法

実施したデータ収集実験の概要は次の通りある．PC(ディスプレイとキーボード入力)を用いた個人ブレインストーミングを想定した拡散的思考タスク（AUT）を実施した．被験者が AUT 中に入力したテキスト表現アイデアはリアルタイムにディスプレイ上のアイデア表示部に一覧表示され，非接触型アイトラッカーにより，被験者のアイデア表示部への視線停留時間（以降：アイデア視線停留時間）を計測した．AUT 終了後，入力されたアイデ

ア群の柔軟性(アイデアのカテゴリ数)などの創造性指標を算出し，アイデア視線停留時間と創造性指標の間の関連を調査した．

データ収集実験の詳細を記述する．被験者は日本ユニシスの研究開発および企画部門の社員 24 名(男性 21 名，女性 3 名，年齢 27～59 歳(平均 M = 45.68, 標準偏差 SD = 9.25))であった．被験者の選定にあたっては，ブラインドタッチが可能もしくは一部文字のみキーボードを見るレベルの人を対象とした．AUT で提示した刺激は，例題が 1 刺激「レンガ」，本題が 2 刺激「靴下」「鉛筆」であり，この順で実施した．例題は 1 分，本題は 1 刺激につき 3 分で実施した．本題の「靴下」と「鉛筆」の実施の合間には画面を挟み，被験者のタイミングで次の問題の開始ボタン押下により開始するよう指示した．実験環境は図 1 の通り，AUT 実施画面は図 2 の通りである．画面は，問題表示部，アイデア入力部，アイデア表示部で構成される．アイデアをアイデア入力部にキーボード入力しエンターキーで確定すると，そのアイデアがアイデア表示部に四角い枠(付箋イメージ)と合わせて表示される．アイデアの枠の総数は縦 5×横 6 の 30 個であり，入力アイデアは縦の上詰め，横の左詰めの順序で表示される．出題毎に実際に入力されたアイデアおよびそのタイムスタンプをデータ(以降:AUT データ)として収集した．AUT 実施中の経過時間や残り時間は表示せず，3 分経過後自動的に終了画面に切り替わるようにした．

アイトラッカーは Gazepoint 社の GP3 HD Eye Tracker(以降 GP3 HD)を用い，図 1 のように設置した．GP3 HD のサンプリングレートは 150Hz に設定した．各被験者の実験開始前に，Gazepoint Control(v4.3.0)を用いて 9 点キャリブレーションを実施した．キャリブレーションの結果，視線座標の誤差が大きく，実際に見ているアイデアの隣接アイデアへの誤検知の可能性があると筆者が判断した被験者は，実験を実施せずに除外した．視線に関しては，実験中は頭をあまり動かさないよう指示し，それ以外の視線に関する指示(例えばアイデアを見るように等)は，一切しなかった．Gazepoint Analysis(v4.3.0)を利用し視線情報を収集・記録し，Export 機能を用いて csv 形式のデータ(以降:視線情報データ)を作成し，分析に利用した．視線情報データと先述の AUT データの突き合わせを行い，AUT 実施中のアイデア視線停留時間，1 分当たりの瞬き回数(瞬目率)を集計した．アイデア視線停留時間は，画面のアイデア表示部に実際に表示されているアイデア(その時間までに入力済みアイデアが表示されている画面領域)上への視線停留時間の総和である．瞬目率は，3 分間の AUT 実施中の瞬目回数の総和を 3 で割った 1 分当たりの回数である．

AUT 実施後，入力された AUT データから各被験者の創造性指標(流暢性，柔軟性，独創性)を算出した．AUT データは筆者が確認し，出題の回答として明らかに意味をなさないアイデアを無効回答として除外した．次に，筆者の手作業により表現の異なる同義アイデアの表現の正規化を行った．流暢性は無効回答および重複を除いた正規化済みのアイデア数とした．正規化済みのアイデアを，筆者が手作業で”身に付ける物”，”入れ物”などの 25 個のカテゴリに分類し，重複しないカテゴリの総数を柔軟性スコアとした．独創性は，正規化済みアイデアについて，全体アイデアの 5%以下の出現率アイデアには 1 点，1%以下の出現率アイデアには 2 点を与え，点数の総和を独創性スコアとした．独創性スコアは，アイデアの数(流暢性)と強い関係があることが知られているため[Clark 70]，独創性を流暢性で割ったスコア(以降:独創性/流暢性)を算出し，指標に加えた．綿密性は本研究では対象外とした．

各種統計値の算出は Python(3.7.0) のライブラリ Pandas(0.23.4)，SciPy(1.1.0)，StatsModels(0.9.0)を用いた．

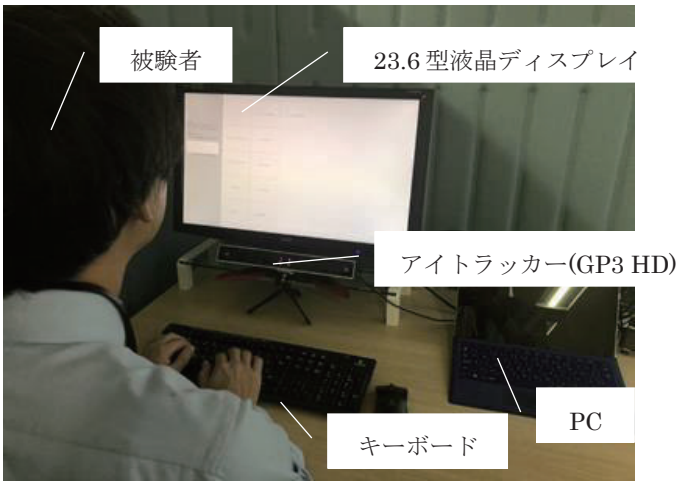


図 1　実験環境構成

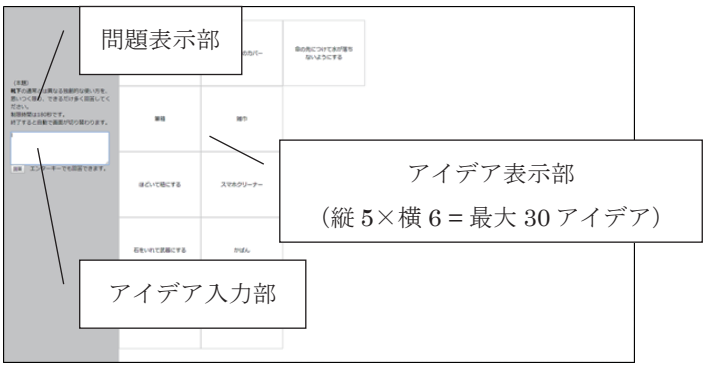


図 2　実験画面構成

5. 結果

本章では，前章で述べた実験の結果および視線情報と創造性指標の関連についての分析結果を述べる．

5.1 AUT と視線情報の結果

靴下，鉛筆それぞれの課題について，各種創造性指標とアイトラッカーで収集した視線情報の統計情報は表 1 と表 2 の通りであった．

表1　靴下課題の結果

	靴下 (N = 24)		
	M	*Mdn*	*SD*
創造性指標			
流暢性	8.08	8.00	2.28
柔軟性	5.54	5.00	1.47
独創性	10.58	10.00	3.72
独創性/流暢性	1.30	1.33	0.20
視線情報			
アイデア視線停留時間(秒)	16.30	11.38	11.92
瞬目率(回/分)	26.92	27.33	9.57

表 1 の注釈:M は平均，*Mdn* は中央値，SD は標準偏差

表 2 鉛筆課題の結果

	鉛筆 ($N = 24$)		
	M	*Mdn*	*SD*
創造性指標			
流暢性	6.79	7.00	2.11
柔軟性	5.08	5.00	1.82
独創性	7.96	7.00	3.29
独創性/流暢性	1.16	1.17	0.27
視線情報			
アイデア視線停留時間(秒)	12.97	10.82	10.51
瞬目率(回/分)	26.18	26.33	9.28

表 2 の注釈:*M* は平均, *Mdn* は中央値, *SD* は標準偏差

5.2 AUT と視線情報の関係

靴下と鉛筆の 2 課題においてそれぞれ創造性指標の z 値を算出し, 2 課題の z 値の平均を総合創造性指標とした. また視線情報については 2 課題の平均を総合視線情報とした.

まず, 本研究仮説である既出アイデアへの視線停留時間と柔軟性の間の関係についての結果を示す. 総合視線情報と総合創造性指標(柔軟性)の間の関連について, 多項式回帰分析を行った. まず, アイデア視線停留時間と柔軟性の間には, 有意水準 $\alpha = .05$ で有意となる 1〜4 次多項式回帰は存在しなかった. アイデア視線停留時間と柔軟性の散布図を図 3 に示す.

次に, すべての視線情報と創造性指標の組み合わせについて, 1〜4 次の多項式回帰分析を実施した結果を示す. 瞬目率と柔軟性における 3 次多項式回帰の組み合わせのみ $\alpha = .05$ で有意となり, それ以外に有意となった組み合わせは存在しなかった. 瞬目率と柔軟性の 3 次多項式回帰は, 1 次, 2 次, 4 次に比べ p 値, AIC, BIC のいずれも最小値を取った(決定係数 $R^2 = 0.34$, 自由度調整済み決定係数 $R'^2 = 0.24$, $F(3, 20) = 3.45$, $p = 0.036$, AIC = 58.18, BIC = 62.89). 瞬目率と柔軟性の散布図および得られた 3 次回帰曲線を図 4 に示す.

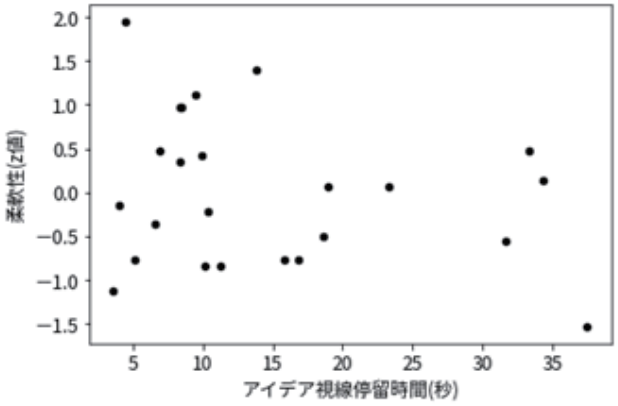


図 3 アイデア視線停留時間と柔軟性の関係(散布図)

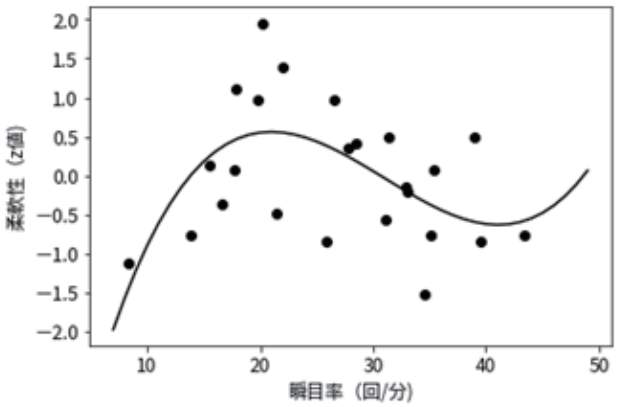


図 4 瞬目率と柔軟性の関係(散布図と 3 次回帰曲線)

6. 考察

本研究仮説では, アイデア表示部への停留時間が長い(自身が出したアイデアへの視線停留時間が長い)場合, 固着が生じ柔軟性が低下すると予測したが, アイデア表示部への視線停留時間と柔軟性の間に有意な関係は見られなかった. 今回, 1 刺激当たり 180 秒のテスト時間の中で, 中央値で約 11〜12 秒しかアイデア表示部を見ておらず, また被験者へのヒアリングから, アイデア表示部を参考に見ようとは思わなかったという意見が多かったことから, アイデア表示部を見たことによる影響が十分に計測できなかった可能性がある. 影響を計測するために, テスト時間を 180 秒よりも長くし, アイデア表示部を見る時間を増やす必要があると考える. テスト時間を長くした場合の問題として, 流暢性の高い被験者が非常に多くのアイデアを出す可能性があり, 画面上でのアイデアの視認性の悪化や認知負荷増大の影響等が考えられるため, アイデアをどのように表示すべきか検討が必要である.

瞬目率と柔軟性の間には, 図 4 に示すように, 逆 U 字型の後に増加傾向を示す 3 次回帰曲線が見られた. この結果は, Akbari Chermahini らの逆 U 字型[Akbari Chermahini 10]および Ueda らの正の相関[Ueda 15]の両方の傾向を示しており, 先行研究の結果の強化および本実験結果の妥当性を示していると考える. 先行研究および本研究で共通する結果としては, 瞬目率が低いと柔軟性も低い結果を示したことから, 低い瞬目率が, 柔軟性パフォーマンス低下要因の重要な指標の1つであることが示唆される.

7. まとめと今後の課題

7.1 まとめ

本論文では, アイトラッキングによる視線情報を用いて, 拡散的思考タスクのパフォーマンスと既出アイデアへの視線停留時間の関係の仮説検証結果を報告した. 既出アイデアへの視線停留時間と柔軟性の間に有意な関連は確認できなかったが, 瞬目率と柔軟性の間には 3 次回帰の関連が得られ, 先行研究と類似する結果が見られた.

7.2 今後の課題

本実験およびデータ収集手法により, 見たアイデアのテキスト表現(概念)を考慮した分析ができるようになった. 今後の研究課題として, 見たアイデアに含まれる概念レベルでの分析を実施予定である. 具体的には, 見たアイデア概念とその後に創造

されるアイデアとの関連，創造性指標との関連，知識，連想，類推の計算機モデルとの関連などである．また，収集データの種類，量を増やした機械学習ベースのパフォーマンス推定，グループのブレインストーミングを想定した研究へ展開予定である．

参考文献

[Finke 92] Finke, R. A., Ward, T. B., and Smith, S. M.:“Creative Cognition: Theory, Research, and Applications”, The MIT Press, Cambridge, MA , 1992.

[Guilford 67] Guilford, J. P.:“The nature of human intelligence”, New York, NY: McGraw-Hill, 1967.

[Akbari Chermahini 10] Akbari Chermahini S., Hommel B.:“The (b)link between creativity and dopamine: spontaneous eye blink rates predict and dissociate divergent and convergent thinking.”, Cognition 115, 2010.

[Ueda 15] Ueda Y., Tominaga A., Kajimura S., Nomura M.: “Spontaneous eye blinks during creative task correlate with divergent processing.”, Psychol Res., 2015.

[Bilalić 08] Bilalić M., McLeod P., Gobet F.:“Why good thoughts block better ones: the mechanism of the pernicious Einstellung (set) effect.”, Cognition, 2008.

[Clark 70] Clark, P. M., Mirels, H. L.:“Fluency as a pervasive element in the measurement of creativity”, Journal of Educational Measurement, 1970

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

認知症ケア協調学習環境における多重思考モデルに基づく指導知識の表出化

Externalization of Coaching Knowledge based on Multiple Thinking Models on Collaborative Learning Environment for Dementia Care

小俣敦士 *1 Atsushi OMATA　松井佑樹 *1 Yuki MATSUI　石川翔吾 *1 Shogo ISHIKAWA　原寿夫 *2 Hisao HARA　宗形初枝 *2 Hatsue MUNAKATA　中野目あゆみ *2 Ayumi NAKANOME
香山壮太 *2 Sota KAYAMA　坂根裕 *3 Yutaka SAKANE　本田美和子 *4 Miwako HONDA　桐山伸也 *1*5 Shinya KIRIYAMA　竹林洋一 *1*5 Yoichi TAKEBAYASHI

*1静岡大学 Shizuoka University　*2郡山市医療介護病院 Koriyama Medical Care Hospital　*3株式会社エクサウィザーズ ExaWizards Inc.
*4東京医療センター Tokyo Medical Center　*5みんなの認知症情報学会 The Society of Citizen Informatics for Human Cognitive Disorder

We describe the externalization of coaching knowledge based on Minsky's commonsense thinking models on a collaborative learning environment for dementia care. To externalize the coaching knowledge of professional caregivers, we have built computational models that represent a part of the instructor's thinking process. We have conducted collaborative learning of dementia care on the care field, and we have analyzed the instructors' coaching knowledge using multiple thinking models. The experimental results have shown the effectiveness of the proposed learning environment for dementia care.

1. はじめに

認知症の課題に苦慮する介護現場がある一方で，認知症ケアの達人は，相手の状態の変化を適切に把握し介入することで，認知症のある人と良好な関係を築くことができる [Gineste 07]．このようなケアのスキルは，言語だけでは表現が難しく，またケア実践の中で培われるため習得が容易ではない [Benner 11]．実践から効果的に学習すること，そして実践知を視覚的に理解しやすく表現しモデル化していくことを目的に，初学者と熟達者が協調的に学び教え合うための環境が必要である．

本稿では，認知症ケア協調学習における指導行為に着目し，指導者の指導知識を多重思考モデルに基づいて表出化した結果ついて述べる．

2. 認知症ケア映像を用いた協調学習環境

認知症ケアの技能習得のためには，身体に定着するまで継続的に実践を続け，適切なフィードバックで客観的に実践を振り返り，知識を更新していくことが重要である．筆者らは，介護現場において認知症ケアを組織全体で学び，高度化するための協調学習環境の構築を進めてきた [小俣 17]．**図 1** に協調学習システムを示す．

- 実践：ケアの実践の様子をビデオ撮影
- 指導：ケア動画に指導データを付与
- 学習：指導データ付き動画を視聴し学ぶ

ケアの状況を映像で共有し意見を言い合うことで，学習者はどこに注目しどのように介入するのかといった状況判断能力を養うことができ，スキル向上に有効である．一方で，熟達者の指導内容によっては学習者の混乱を招くこともわかってきた

連絡先: 小俣敦士，静岡大学創造科学技術大学院，静岡県浜松市中区城北 3-5-1，omata@kirilab.net

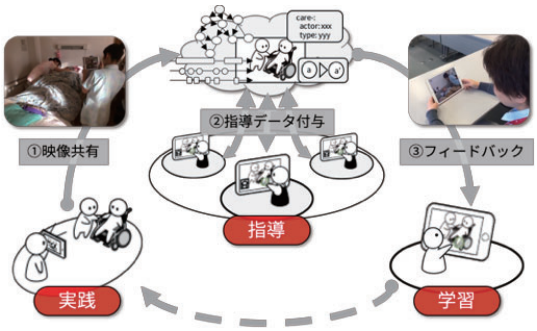


図 1: ケア映像を用いた学びの高度化と知の構造化サイクル

[石川 18]．学習者の理解度に応じたフィードバックや，指導者がどのような意図を持って指導を実施したのかを可視化できれば，より効果的な学習環境の発展につながると考えられる．本稿では，特に指導者の指導内容をもとに，指導者の思考プロセスを計算モデルを用いて表現し可視化することで学習支援に繋げる．

3. 多重思考モデルに基づく指導知識の表現

筆者らは，マルチモーダルケア技法のユマニチュード®に着目し，認知症ケアスキルの情報学的評価と，Minsky の多重思考モデル [Minsky 09] を用いた認知症ケア知のモデル設計を進めている．以下に，多重思考モデルの各表現系の内容を示す．

- ケアスクリプト：状況の流れをスクリプトの構造 [Schank 03] で表現
- トランスフレーム：状況の変化の際に必要な知識を表現
- ゴールネット：行動意図をネットワーク [Liu 04] として表現

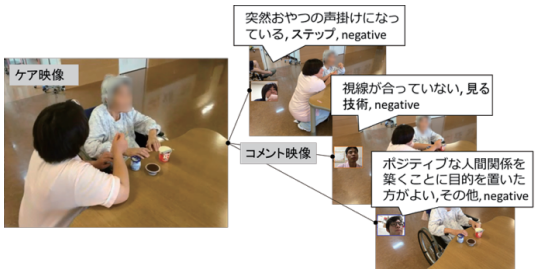


図 2: 指導データのイメージ

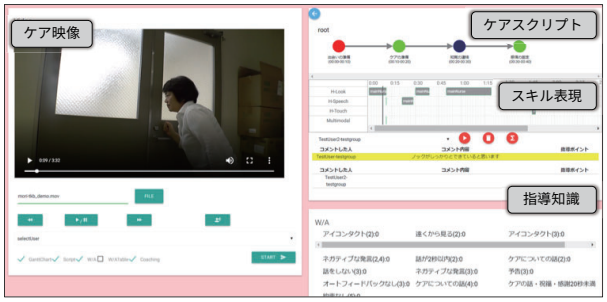


図 3: 指導知識の可視化ビュー

- 状況予測：状況における取りうる行動とその結果を if-do-then の構造で表現

これらの複数の構造を持つ多重思考モデルを活用することで，認知症ケア熟達者の思考プロセスの一部を表現できる．ケアの熟達者は，状況の流れがどうだったのか (ケアスクリプト) を常に監視しながら，状況の変化 (トランスフレーム) を適切に把握し，その時の状況に応じたゴールの構造 (ゴールネット) をもとに必要な知識を探索 (状況予測) し活用することができる．ケアの初学者は，状況の変化を適切に把握することや状況に応じて必要な知識を選択し実践することが難しい，あるいはそれらの知識自体が不足している可能性が考えられる．こういった思考方法に関するスキルは，日々の実践の中で表出化することは難しく，介護現場ではナラティブによる説明や観察によって学習・教育がされている．本協調学習環境では，指導の様子そのものを映像として記録できるため，ケアの各場面における多様な解釈を収集することが可能である．指導データのイメージを**図 2** に示す．収集した指導データは，多重思考モデルを用いて知識表現として表現し，ケア映像と同期したビューで可視化される (**図 3**)．このように，指導データを継続的に収集していくとともに，指導知識の表出化と多重思考モデルの深化を進めていく．

4. 指導知識の表出化による協調学習の分析

2 節で示した協調学習環境に基づき協調学習を実践し，指導内容と学習効果について分析を行なった．協調学習は**表 1** に示す手続きを 2 サイクル実施した．なおビデオ撮影では移動介助の場面を対象とした．指導コメントは逐次追加されていくため，後から入力するメンバーはそれまでに登録されているコメント内容を見ながら指導コメントを入力することができる．グループ 1 では，グループメンバーが先にコメント入力を実施するため，インストラクター *1 は他のメンバーが不足している点を補いながら指導ができると考えられる．一方で，グループ 2 では，インストラクターが先にコメント入力を実施するため，グループメンバーはインストラクターの指導知識を参照しながらコメント入力が可能であり，より学習効果が高いと考えられる．

*1 ユマニチュード認定インストラクターの資格を持ったスタッフをインストラクターとしている

表 1: 協調学習の手続き

グループ	手続き
1	1. ケアの実践をビデオ撮影 2. グループメンバー 5 名が指導コメント入力 3. インストラクター 1 名が指導コメント入力
2	1. ケアの実践をビデオ撮影 2. インストラクター 1 名が指導コメント入力 3. グループメンバー 4 名が指導コメント入力

表 2: グループ 1 の指導コメントの書き起こし

コメント者	書き起こし
スタッフ A	常に触れながら同じ目線でケアをしているのはとても良いと思います．
スタッフ B	アイコンタクトを取れてなかったかなって思います
インストラクタ	包括的な見る話す触れるが全体的にできていないかなと思います．相手の方の反応がまだポジティブな感情っていうか，そういうところでない状態でケアを進めているので，反応的にあまり良くないところを察知して，ケアをどう変えていくかってことを考えながらやったほうがいいのかと思います．いきなり歩くところを目的にしているので，体をベッド上で動かしてもらったりとかして歩いてもらうようにしてもいいと思います．

協調学習の結果，各グループ 1 名 2 サイクル分のケア実践映像を計 4 事例分と，指導コメント計 73 個を収集した．指導コメントを多重思考モデルを用いて表現し，分析した結果について各グループ一例づつ示す．まず，グループ 1 の 1 サイクル目のケアの靴を履かせている場面で得られた指導コメントを**表 2** に示す．また，指導コメントを多重思考モデルを用いて表現したものを**図 4** に示す．このケアの場面において，スタッフ A は”常に触れながら同じ目線でケアしている”と指導コメントを残しており，この場面では技術を使うことができていると評価している．スタッフ B はアイコンタクトができ

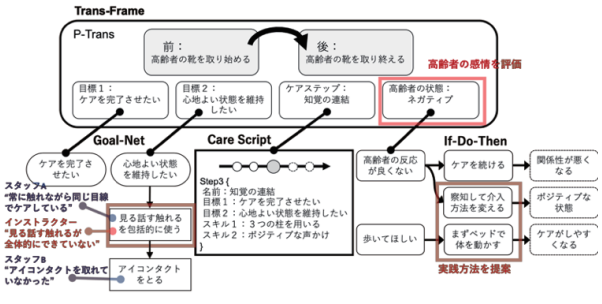


図 4: グループ 1 の靴を履かせる場面の指導知識表現

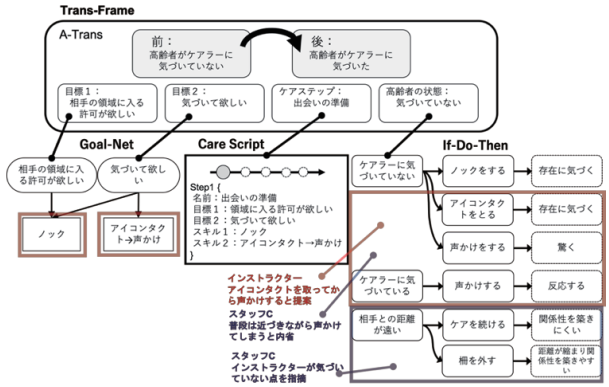


図 5: グループ２の声かけ場面の指導知識表現

ていないと評価している．その上で，インストラクターは，”見る話す触れるが全体的にできていない”と評価している．このように同じ場面でも初学者とインストラクターで，状況の解釈の仕方が異なることが確認できる．また，インストラクターは，この場面では相手がネガティブな状態なので，それを察知して介入方法を変えること，まずはベッドで体を動かしてみてからケアを実践することを提案している，このように指導知識を表出化することで，初学者やインストラクターの持つ状況把握や介入方法に関する知識を視覚的に捉えることができ，それらを比較することでスキル向上に繋がると考えられる．インストラクターからは「スタッフがどう捉えているのか一度に見えるので効率的でインストラクターとしての助言の仕方の学びになった」という意見が得られた．これは，学習者 (=グループメンバー) の表出化された指導知識を参照することで，学習者がどのようにケアを捉えているかを把握できるため，インストラクターは学習者の不足している知識を補う指導が実施でき，それが双方向の学びに繋がると示唆される．

次にグループ２で得られた高齢者に声かけをする場面での指導知識の分析について示す．**表 2** に指導コメントを，指導コメントを多重思考モデルで表現したものを**図 5** に示す．まず，インストラクターは，いきなり声かけするのではなくまずはアイコンタクトを取ってから声かけをする方が良いと言った指摘をしている．次に，スタッフ C は，”名前を呼びながら近づいてしまうことがある”といったコメントを残しており，インストラクターのコメント参照して，普段の自身のケアを内省するようなコメントが得られた．グループ２については，全てのグループメンバーがインストラクターの指導知識を参照したコメントを残しており，インストラクターの指導知識を表出化することで学習者の気づきが促進されることが示された．また，スタッフ C は，ベッド柵をとって近い距離で話をしてみてもいいといったコメントも残しており，インストラクターが気づいていない点についても指摘することができていた．このように，指導者同士が気づいた点を補足し合い協調的に学ぶことでインストラクター自身の学びにもつながると示唆される．

5. おわりに

本稿では，認知症ケアの協調学習において，指導者の指導知識を多重思考モデルに基づいて表出化することで学習者と指導者の双方の学びにつながることを示した．今後も複雑な認知症ケアの理解を深めるために，多重思考モデルの表現系を拡張していくとともに，介護現場の人でも理解しやすいユーザインタフェースの改善を進めていく．

表 3: グループ２の指導コメントの書き起こし

コメント者	書き起こし
インストラクタ	出会いの準備のところで、ノックをして、相手の反応をうかがっての入室というところができてるかと思います。ただ、この動画を見る限り、目を開けてこちらに気付いてるかっていうのがわからないところではあるんですが、「○○さん」って声をかけるタイミングとしては、ベッドボードをノックして近づいてアイコンタクトをとってからの声かけのほうが、流れとしてはセオリーなのかなと思います。
スタッフ C	ノックをして入室するところはとてもスムーズに行えていたと思います。どうしてもケアに入る時に、名前を呼びながら近づいてしまうこともあるんですが、コメントにある通りアイコンタクトをまずとって、相手が気づいたことがわかったら近づいて声をかける、というケアの入り方が良いのだなと思いました。もう一つは、柵があって患者様との距離ができてしまっているので、柵を外して話をするのもいいのかなと思いました。

謝辞 本研究を進めるにあたり協力していただいた福島県郡山市医療介護病院のスタッフ，ケア対象者とその家族の皆様に深く感謝する．

参考文献

[Gineste 07] Gineste, Y. & Pellissier, J.: Humanitude: Comprendre la Vieillesse, Prendre Soin des Hommes Vieux, Armand Colin, (2007).

[Benner 11] Benner, P. E., et al.: Clinical wisdom and interventions in acute and critical care: A thinking-in-action approach, Springer Publishing Company, (2011).

[小俣 17] 小俣敦士, 他: 認知症ケアの内省を促す構造化映像を用いた協調学習環境, 第 8 回恒例社会デザイン研究会, (2017).

[Minsky 09] Minsky, M., 竹林洋一 訳: ミンスキー博士の脳の探検－常識・感情・自己とは－, 共立出版,(2009).

[石川 18] 石川翔吾, 他: 認知症ケア高度化に向けた多重思考モデルを用いた協調的コーチング支援環境の構築, HCG シンポジウム 2018, (2018).

[Schank 03] Schank, R. C., & Abelson, R. P.: Scripts, plans, goals, and understanding: An inquiry into human knowledge structures, Psychology Press, (2013).

[Liu 04] Liu, H., & Singh, P.: ConceptNet—a practical commonsense reasoning tool-kit, BT technology journal, 22(4), 211-226.

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

プログラムの静的特性を楽曲で表現する可聴化システムの開発とプログラミング支援への応用

Development of Auralization System to Represent Program by Music and its Application to Programming Support

渡邉 彰吾 *1　　六沢 一昭 *2
Syogo Watanabe　　Kazuaki Rokusawa

*2千葉工業大学 情報科学部 情報工学科
Department of Computer Science, Chiba Institute of Technology

*1千葉工業大学大学院 情報科学研究科 情報科学専攻
Graduate School of Information and Computer Science, Chiba Institute of Technology

This paper describes development of auralization system to represent static characteristics of program by music and its application to programming support. The system generates rhythms, chords, tunes and harmony aiming for comfortable music. The music also represents violation of coding standards by a dissonance.

1. はじめに

ソフトウェア開発ではソースコードの保守性や信頼性などが重視されている. これらを向上する手法として静的解析がある. 静的解析では命名規則や書式, コーディング規約違反などの検出が期待される. 静的解析ツールは用途に応じて多数存在している [桑原 2015]. これらのツールで得られた解析結果は画面に出力される. 一方, 本研究では静的解析結果を音に出力する. 音に出力することで, ながら作業が可能となる. 本稿では, 静的解析ツールとして静的解析結果可聴化システムを開発する.

可聴化における様々な研究がされてきた [P. Vickers 2003] [岩田 2013]. その中で, 音の羅列で可聴化したシステムは単調で飽きやすいといった問題があった [佐藤 2011]. そこで本研究では, 自然な楽曲による可聴化を試みる. 自然な楽曲にすることで, 飽きにくさが期待できる. また, プログラム変更による楽曲の変化により, 作業が楽しく感じることも期待できる.

2. 目的

本研究では, ソースコードを解析し, 得られた情報から自然な楽曲の生成を行なう. 規約に基づいてコードを解析し, 規約違反箇所を不協和音で表現する. 生成された楽曲を聴き, 不協和音の響きによって規約違反箇所を発見できるか検証する.

3. 自然な楽曲の生成

[渡邉 2018] の手法を用いて自然な楽曲を生成する.

3.1 ダイアトニックコード (Diatonic Chord)

ダイアトニックコードとは, スケール上の音で構成される三和音 (Triad) または四和音 (Tetrad) のことである. またスケールとは音階のことで, オークターブ内の音の配列である. 本研究では, 三和音と長調 (メジャースケール) を扱う. ハ長調のダイアトニックコードを表 1 に示す. 表中の T, D, S はコードの機能を示し, 以下の特徴がある.

表 1: ダイアトニックコード (ハ長調)

コード	C	Dm	Em	F	G	Am	$Bm^{\flat 5}$
和音機能	T	S	T	S	D	T	D

トニック **(T)** – 曲のはじめと終わりによく使われる.
ドミナント **(D)** – トニックへ進もうとする.
サブドミナント **(S)** – トニックかドミナントへ進もうとする.

3.2 カデンツ (Kadenz)

カデンツとは, 終止形和音進行のことである. 文章で言う所の起承転結のようなものである. コード進行はカデンツに則って構成する. カデンツには T-S-T, T-S-D-T, T-D-T の 3 つの型がある.

これまで, 様々なコード進行が考えられてきた. J-POP 音楽によく使われる代表的なコード進行に以下がある.

カノン進行 – $|C|G|Am|Em|F|C|F|G|$
王道進行 – $|F|G|E7|Am|$
小室進行 – $|Am|F|G|C|$

本システムではこれらの進行を用い, より楽しめる楽曲生成を試みる.

4. 楽曲生成の流れ

プログラムの 1 行を楽曲の 1 小節に対応させて楽曲を生成する.

まず, プログラムのネストの深さの変化から各小節のコードを決定する. そして, 対応するプログラムの行の内容を考慮してリズムを決定し, コードをもとにメロディ生成する. 制御構造から伴奏を決定する.

連絡先: 六沢一昭, 千葉工業大学 情報科学部 情報工学科,
275-0016 千葉県習志野市津田沼 2-17-1,
rokusawa.kazuaki@it-chiba.ac.jp

4.1 コードの決定

コードの決定方式として以下の二つを用いる.

方式 A

表 2 から表 4 に基づき, 4 回あるいは 8 回のネストの深さの変化を, 前述した 3 種類のコード進行 (カノン, 王道, 小室) に対応させて 4 小節あるいは 8 小節のコードを決定する.

表 2: ネストとコード進行 (カノン進行)

ネストの深さの変化	+1	+1	+1	+1	–1	–1	–1	–1
コード進行	C	G	Am	Em	F	C	F	G

表 3: ネストとコード進行 (王道進行)

ネストの深さの変化	+1	–1	+1	–1
コード進行	F	G	$E7$	Am

表 4: ネストとコード進行 (小室進行)

ネストの深さの変化	+1	+1	–1	–1
コード進行	Am	F	G	C

方式 B

ネストの深さに応じてコードを決定する.

表 5: ネストの深さとコード (ハ長調)

ネストの深さ	0	1	2	3	4	5	6	7
コード	C	G	Am	Dm	Em	F	C	G

まず方式 A によるコード決定を試みる. これによりコードが決定できなかった場合は方式 B によりコードを決定する. 方式 A では, ネストの変化が 0 の時を省いた状態で変化パターンに当てはまるかを考える.

コードの決定例を図 1 に示す.

行	ネスト	変化量	コード	
1	0	0	C	`if ( i % 2 == 0 ) {`
2	1	+1	F	`    printf( "#" );`
3	0	–1	G	`}`
4	0	0	G	`else {`
5	1	+1	Em	`    printf( "*" );`
6	0	–1	Am	`}`

図 1: コード決定例

2 行目から 6 行目はネストの変化が +1, –1, 0, +1,–1 である. 0 を省くと, 王道進行 (表 3) と同じネストの変化パターンとなる. このことから, 2 行目から 6 行目は王道進行が適用されていることがわかる. 適用された行において, ネストの変化が 0 の行は一つ前の行に割り当てられたコードと同じコードを割り当てる. これにより, 割り当てられたコードは F, G, G, Em, Am となっている.

4.2 音楽の三要素

リズム、メロディ、ハーモニーの対応を以下に示す。

リズム – パーツ数
メロディ – パーツの ASCII 値
ハーモニー – 制御構造

5. コーディング規約

本研究では, コーディング規約として MISRA-C:2012 を採用した. MISRA-C とは, MISRA[*1] が制定した自動車関連ソフトウェア向けの C 言語の規約である. 現在では, 組み込み開発分野で広く利用されている規約であるため, C 言語の規約として最適だと考えた.

6. 規約違反の楽曲への織込み

コーディング規約違反箇所を不協和音で表現する. 不協和音とは, 全体が調和せず不安定な印象を与える和音である. 本研究では, 不協和音として減三和音 (Diminished-Triad) を用いる. この減三和音は非常に不安定な和音として知られている. このコードを用い, 音楽を大幅に逸脱することなく規約違反箇所を表現する.

7. システムの構成

楽曲生成対象プログラムは indent コマンドによって整形し, 本システムによって楽曲が生成される. 生成された楽曲は MML[*2] で記述される. その後, MIDI データに変換する. システムの構成を図 2 に示す.

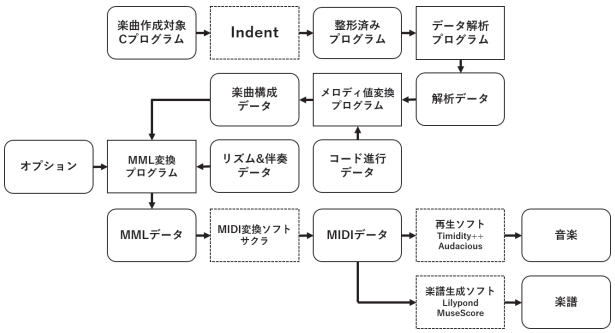


図 2: システム構成図

8. 楽曲生成例

図 3 のプログラムから得られた情報を表 6 に, その情報から生成された楽曲を図 4 に示す.

*1 MISRA(Motor Industry Software Reliability Association): 自動車メーカーや部品サプライヤー, エンジニアリングコンサルタントが連携したヨーロッパの団体

*2 MML(Music Macro Language): 楽曲記述言語の一つ

```
 1  #include <stdio.h>
 2  #define NUM 100
 3  int main( void )
 4  {
 5      int i;
 6      for ( i = 1; i <= NUM; i++ ) {
 7          if ( i % 3 == 0 ) {
 8              printf( "%d:fizz", i );
 9              if ( i % 5 == 0 )
10                  printf( "buzz" );
11          }
12          else if ( i % 5 == 0 ) {
13              printf( "%d:buzz", i );
14          }
15          printf( "\n" );
16      }
17      return ( 0 );
18  }
```

図 3: 整形済み楽曲作成対象 C プログラム

表 6: 図 3 の各行の解析データ

行	字下げ	コード	パーツ数	制御構造	規約チェック
1	0	C	2	other	ok
2	0	C	3	other	ok
3	0	C	2	other	ok
4	0	C	1	other	ok
5	1	G	3	other	ok
6	1	G	10	for	ok
7	2	Am	7	if	ok
8	3	Dm	4	if	ok
9	3	$Gdim$	6	if	err
10	4	Em	2	if	ok
11	2	Am	1	if	ok
12	2	Am	8	else if	ok
13	3	Dm	4	else if	ok
14	2	Am	1	else if	ok
15	2	$Ddim$	2	for	err
16	1	G	1	other	ok
17	1	G	3	other	ok
18	0	C	1	other	ok
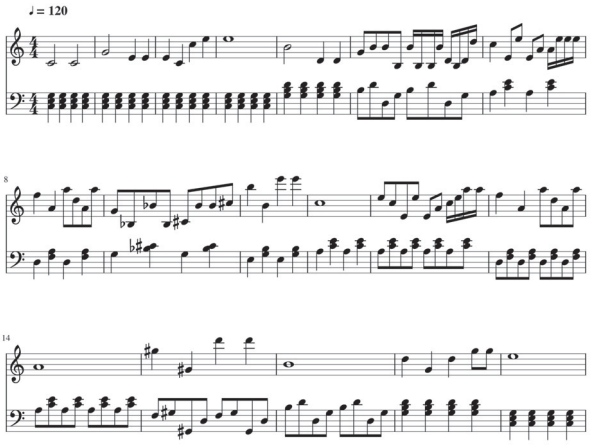


図 4: 表 6 のデータから生成された楽曲

表 6 より, 違反チェックにおいて 9 行目と 15 行目は err となっている.

9 行目は規約 15.6 に違反している. 規約 15.6 とは, 「for 文や if 文, while 文などの本文に中括弧 ({}) を使用しなければならない.」といったものである. 9 行目の if 文には中括弧がないため, 規約違反と判定されている.

また, 15 行目は規約 15.7 に違反している. 規約 15.7 とは, 「全ての if...else if 構文は else 文で終了しなければならない.」といったものである. 12 行目に else if 文があるため, 15 行目には else 文が記述されなければならない. しかし, else 文が記述されることなく if...else if 構文を終了しているため, 規約違反と判定されている.

以上のことから, 9 行目と 15 行目はコードが減三和音 (dim) となっていることがわかる.

9. 評価実験

本システムの有効性を評価するために, 本学の情報工学科の学生 20 名 (C 言語のプログラミングは学習済み) に評価実験を行なった.

本システムによって規約違反箇所の検出及び改修が可能かを検証する. まず被験者は, 不協和音のある楽曲と無い楽曲を聴き比べ, 不協和音の確認をする. 確認後, 実際に本システムを利用し, 規約違反箇所の改修をした. 被験者が修正し終えたと感じたら実験終了とする. 実験終了後, 被験者には図 5 のアンケートに対する回答を紙面に記入して提出してもらった. Q1~Q6 は 4 択の選択式で, Q7~Q9 は記述式で回答してもらった. Q7 は, Q5 で「飽きやすかった」と回答した人にのみ回答してもらった.

実験対象プログラムは 70 行程度のコンパイルエラーのない C 言語プログラムである. その中に, 規約違反箇所が 6 箇所ある. 違反箇所一覧を表 7 に示す. また, 実験時間は無制限で行なってもらった. 実験時間は約 30 分から 1 時間程度であった.

Q1 音楽に自信がありますか?
Q2 不協和音の認識は難しかったですか?
Q3 コーディング規約違反箇所の検出は難しかったですか?
Q4 本システムにより検出は簡単になりましたか?
Q5 楽曲は飽きやすかったですか?
Q6 本システムによるソースコード改修は楽しかったですか?
Q7 飽きやすいと感じた理由をお願いします.
Q8 本システムを使わないと気づかなかった規約違反はどれですか?
Q9 本システムを使ってみた意見, 感想をお願いします.

図 5: アンケート設問

表 7: コーディング規約違反箇所一覧

問題番号	違反内容
(1)	for 文に中括弧がない
(2)	実行されない文がある
(3)	for 文に中括弧がない
(4)	if 文に中括弧がない
(5)	else if 文に中括弧がない
(6)	else 文が存在しない

10. 実験結果

図 5 の Q1~Q6 のアンケート結果を表 8 に示す. また, 問題毎の正答人数と Q8 のアンケート結果から導き出した本システムの利用率を表 9 に示す. 利用率とは, 正答者の中で, 本システムを用いたことによって正解に辿り着くことができた人の割合を表している. さらに, Q7 と Q9 のアンケート結果を図 6 に示す.

表 8: アンケート結果 1/3

	当てはまる	どちらかといえば当てはまる	どちらかといえば当てはまらない	当てはまらない
Q1	2	7	6	5
Q2	4	7	6	3
Q3	3	6	10	1
Q4	8	10	2	0
Q5	1	5	6	8
Q6	11	9	0	0

表 9: アンケート結果 2/3

問題番号	正答人数 (人)	本システムにより気付いた人数 (人)	利用率 (%)
(1)	17	10	58.8
(2)	12	6	50.0
(3)	14	9	64.3
(4)	18	11	61.1
(5)	18	10	55.6
(6)	8	4	50.0

Q7. 飽きやすいと感じた理由をお願いします.

- 4 分音符が続いてたから.
- リズムが単調だから.

Q9. 本システムを使ってみた意見, 感想をお願いします.(一部抜粋)

- 小学生などの子供向けに使えそう.
- 正しく修正されているかの判断が難しかった.
- 修正前後の変化が明確だったため, わかりやすかった.
- 音楽を取り入れることでプログラミング初心者が馴染みやすいと感じた.
- 何もなしでプログラムを修正するよりもわかりやすく飽きずに作業ができた.
- 不協和音がもっとわかりやすい方が良いと感じた.
- 音楽から規約違反箇所を探すことが楽しかった.
- プログラムができる人のためだけでなく, 初心者にも使えそうだと思った.
- 明らかに間違っていない箇所での音楽が不協和音に聴こえ, 自分の回答に不安を感じた.

図 6: アンケート結果 3/3

表 8 より, Q4 は「当てはまる, どちらかといえば当てはまる」と回答した人が大多数であった. これは, 本システムがコーディング規約違反箇所の検出を容易にしていたということがわかる. このことから, 本システムはプログラム改修の一助となっていたといえる. また表 9 より, 全ての問題に対して利用率が 50%以上であった. つまり, 正答者の半数以上は本システムを利用してコーディング違反箇所を検出したということがわかる. これらのことから, 本システムがコーディング規約違反箇所検出の一助となっていたといえる. 以上のことから, 本システムはソースコードの静的解析ツールとして有効であったと考えられる. また, 本システムはソースコードの静的解析結果の可聴化システムである. 本システムの有効性を示したため, ソースコードの静的解析結果は画面に出力する可視化だけでなく, 音に出力する可聴化でも有効であることがわかった.

従来の可聴化システムでは単なる音の羅列による可聴化のため, 飽きやすいといった問題があった. 本システムは従来可聴化システムの飽きやすさを改善できたかどうかを考える. 表 8 より, Q5 は「当てはまる」と回答した人が 1 人, 「どちらかといえば当てはまる」と回答した人が 5 人であった. このことから, 本システムでは未だ不十分であると考えられる. しかし, 大多数は飽きにくいと感じており, 楽曲による可聴化は飽きやすさの改善に効果的であったと考えられる. また図 6 より, 飽きやすいと感じた理由として, 「4 分音符が続いていたから」「リズムが単調だから」があった. これらはメロディのリズムではなく, 伴奏のリズムに対してである. 制御構造に応じて伴奏を決定しているため, 制御文を使用している箇所が少なければ自ずと単調になってしまう. このため, 伴奏の決定方法を改善する必要がある. 以上のことから, 本システムは飽きやすさを完全に改善できたとはいえない. しかし, 楽曲による可聴化は飽きやすさの改善に効果的であったと考えられる. 飽きやすさを感じた人への改善策として, 伴奏の決定方法の変更が考えられる.

本研究では, コーディング規約違反箇所を不協和音で表現した. 表 8 より, Q2 は「当てはまる, どちらかといえば当てはまる」と回答した人が半数以上であった. また図 6 より, 不協和音の認識が難しいといった意見が多数あった. これらのことから, 不協和音は認識が難しく, 規約違反箇所の表現としては不十分であったと考えられる.

表 8 より, Q6 は全ての被験者が「当てはまる, どちらかといえば当てはまる」と回答していた. このことから, 本システムによりソースコードの改修作業が楽しくなったといえる.

11. おわりに

本研究では, 静的解析ツールとして, 静的解析結果可聴化システムを開発した. また, 可聴化システムにおける飽きやすさを改善すべく, 自然な楽曲による可聴化を提案した.

評価の結果, 静的解析結果の可聴化はソースコードの静的解析ツールとして有効であることを示した. また, 飽きやすいといった従来システムの問題は完全に解決できたとはいえない. しかし, 楽曲による可聴化は飽きやすさの改善に効果的であった.

参考文献

[桑原 2015] 桑原 寛明, 渥美 紀寿, “ソースコードの静的検査における警告の版間追跡ツール,” ソフトウェアエンジニアリングシンポジウム 2015, 情報処理学会 (2015).

[P. Vickers 2003] P. Vickers and J. Alty, “Siren songs and swan songs: Debugging with music,” *Communications of the ACM*, Vol.46, No.7, pp.86–93 (2003).

[佐藤 2011] 佐藤 和哉, 平井 重行, 丸山 一貴, 寺田 実, “CodeDrummer: リズムに着目したプログラム可聴化システム,” インタラクション 2011, 2SCL-14, 情報処理学会 (2011).

[岩田 2013] 岩田 まどか, 隼田 尚彦, 向田 茂, 斉藤 一, 安田 光孝, 大島 直樹, “ソースコードの可視化・可聴化によるメタ認知的学習支援手法の研究–メディアアートの要素を取り入れたアプリケーション開発–,” エンターテインメントコンピューティングシンポジウム 2013, 情報処理学会 (2013).

[渡邉 2018] 渡邉 彰吾, 六沢 一昭, “プログラムからの楽曲生成,” 第 17 回情報科学技術フォーラム (FIT2018), E-027, 電気電子情報通信学会, 情報処理学会 (2018).

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

屋内空間を巡回するロボットのための協調型転移深層学習に基づく人物再同定とその TA 業務支援への適用

Person Re-identification based on Interactive Transfer Deep Learning for Mobile Robots and Its Application to TA Task Support

村田　祐樹[*1]
Yuki Murata

渥美　雅保[*1]
Masayasu Atsumi

[*1] 創価大学大学院工学研究科情報システム工学専攻
Information Systems Science, Graduate School of Engineering, Soka University

This paper proposes interactive person re-identification method for mobile robots that periodically provide services to specific groups. This method consists of a CNN-based person feature extractor that is trained based on Triplet Loss, and a CNN-based person re-identifier that is trained based on transfer learning. Person re-ID is executed through a cooperative human-in-the-loop learning approach. As an example of a service, we apply this method to a Teaching Assistant (TA) support. This application aims to support students' study based on their identification by the proposed method and student card reading in which appearances and names are linked. Performance of the proposed method is evaluated by experiments using a large open dataset and a self-made dataset periodically collected for the same group by a mobile robot. In addition, the feasibility of the TA support is verified by experiments in which robots are operated in actual classes.

1. はじめに

人物識別は，犯罪の捜査やその防止，マーケティング情報の収集など，社会の中で重要な役割を果たしている．その中でも人物再同定は，視野を共有しない複数の固定カメラに映る人物画像から，同一人物を識別する問題と定義される．本研究では，特定の集団に定期的にサービスを提供するロボット向けの人物再同定を提案する．公開されている大規模データセットと，移動ロボットで収集した自作のデータセットを使用した実験により，本手法の有用性を評価する．

また，ロボットが各個人に合わせた最適なサービスを提供するためには，人物再同定に加えて名前等の個人識別子を用いた情報検索を組み合わせることが重要である．本研究では，提供するサービスの一例として演習授業の TA（Teaching Assistant）支援を取り上げ，人間とロボットが互いの特性を活かして受講学生の学習支援を提供するシステムを構築する．ロボットには名前と外見を結びつけるための学生証読み取り機能を搭載し，名前から得られる情報に基づいて各個人に合わせた学習支援の提供を目指す．実際の演習授業でロボットを動作させ，TA 支援の可能性を検証する．

2. 関連研究

2.1 人物再同定

近年の深層学習に基づく人物再同定には，画像のペア[Radenovic 16]に基づく siamese ネットワークや 3 つ組[Schrof 15]に基づく Triplet ネットワークモデルが用いられることが多い．これらは複数の画像を入力として受け取り，損失関数に基づいて各人物固有の特徴を出力するように学習される．テスト時には出力された特徴同士を，コサイン類似度などの距離関数を使用して人物の識別に役立てる．これらモデルは，入力サンプルの組が同一人物によるものか否かを考慮するだけで学習ができるという利点がある．一方，全てのサンプルに事前のラベル付けが必要な点は問題である．また，類似度比較に基づいて人物を識別する際には，データベース中の全てのサンプルと新たな入力サンプルを比較する必要があるため，データベースのサイズによっては計算量が膨大になる恐れがある．

これらに対処するため本研究では，人物固有の特徴を出力する特徴選択 CNN に，人物識別を実時間で行うための人物再同定 CNN を組み合わせたモデルを提案する．そして，人物データを収集しながら転移学習により短時間で繰り返し学習を実行する．

2.2 学習支援ロボット

コミュニケーションロボットを教育の分野に取り入れる試みに関心が高まっている．高石ら[高石 07]は，教師と学生のコミュニケーション促進を目的としたロボット型の IP ホンを TA として導入し，システムの試作を行った．彼らが開発したシステムでは，教師やその補助者（人間の TA）が専用のアプリケーションを介して，頷く・考える・質問する等のロボットの操作を任意のタイミングで行った．

一方 Shiomi ら[Shiomi 15]は，小学校の科学の教室内に，TA としてではなく，”科学の知識が豊富な転校生”という立場で振る舞うロボットを導入し，実地調査を行った．ロボットの行動は半自律的な遠隔操作を介して，科学に関する質問に答えられるように設計され，子供からの質問を促した．彼らは一か月間に及ぶ実験から，特に意欲的に質問をする子供らの科学的好奇心を高められると結論付けた．

本研究は，大学のプログラミング演習授業におけるロボット TA による学習支援サービスの提供を目的としている．遠隔操作によって教室内を巡回するロボットを TA として取り入れ，学生証を読み取る機能を搭載することで名前から得られる様々な情報に基づいて学生とコミュニケーションを行う．実際にロボットを授業中に動作させる中で，得られる効果や今後の可能性を検証した．

連絡先：村田 祐樹，創価大学大学院工学研究科，
〒192-8577 東京都八王子市丹木町 1-236，Tel: 042-691-2211，
Email: y.murata0105@gmail.com

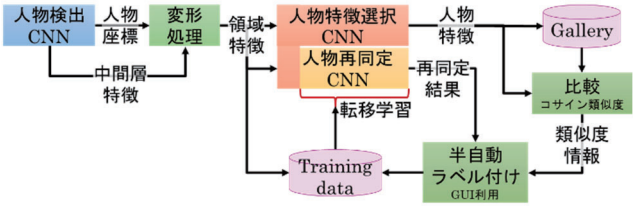


図 1　人物再同定手法

3. 移動ロボット向け人物再同定

3.1 概要

提案する手法は，図 1 に示すように 3 種類の畳み込みニューラルネットワーク(CNN)—人物検出 CNN，人物特徴選択 CNN，人物再同定 CNN—と半自動ラベル付け処理で構成される．まず，人物検出 CNN に画像を入力し，人物が存在する領域の座標と隠れ層の特徴マップを出力する．これらの出力から人物領域に限定された特徴マップが人物ごとに抽出され，後半 2 つの CNN へ入力するための変形処理が施される．人物特徴選択 CNN は人物ごとに不変の特徴を選択して出力するため，人物再同定 CNN は人物の識別を行うために利用する．出力される人物特徴は Gallery として保存され，新たに取得されるサンプルとの比較に利用される．自動的なラベル付けは，比較結果として出力される類似度情報と再同定 CNN が出力する分類確信度に基づいて行われる．また，類似度と分類確信度が共に一定以下の場合は，GUI を用いた協調ラベル付け処理に切り替える．このように本システムでは，学習用データを随時作成し，人物再同定 CNN の転移学習を実施する．

3.2 転移深層学習に基づく人物再同定

高精度かつ実時間の人物再同定を実現するため，本研究では人物検出 CNN として YOLOv2[Redmon 17]を使用する．YOLOv2 は 23 の畳み込み層と 5 つのプーリング層で構成されるモデルで，人物を含む複数の物体をリアルタイムに検出することができる．ネットワークには高さと幅が 416 ピクセルの 3 チャネルカラー画像を入力し，物体の座標とクラス，それらの確信度を含む特徴を出力する．また，本手法では検出と同時に第 2 畳み込み層の特徴マップから人物領域の特徴を取り出す．

人物特徴選択 CNN(図 2(a))は，人物検出 CNN で取得した人物領域の特徴マップを入力して人物固有の特徴を選択して出力するネットワークである．学習時には損失関数として，式(1)で表される Triplet Loss を使用する．

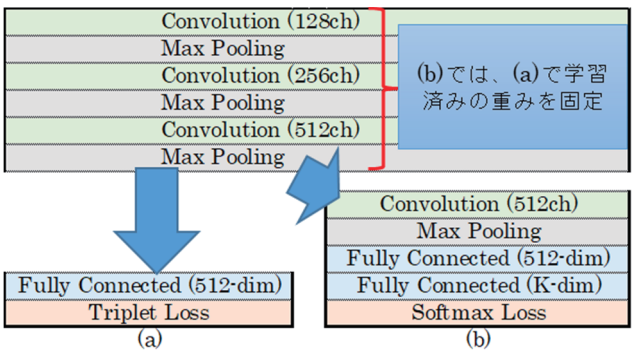


図 2　特徴選択 CNN(a)と再同定 CNN(b)の構成

$$L(a,p,n)=\frac{1}{N}\left(\sum_{i=1}^{N}\max\{d(a_i,p_i)-d(a_i,n_i)+\mathrm{margin},0\}\right) \quad (1)$$
$$\text{where } d(x_i,y_i)=\|x_i-y_i\|_2^2$$

ここで，Nはバッチサイズ，marginはマージンパラメータを表す．Triplet (a,p,n) は基準となるサンプル$a(anchor)$，それと同クラスのサンプル$p(positive)$，別クラスのサンプル$n(negative)$の 3 つの組で構成される．それぞれが重みを共有する同一の特徴選択 CNN へ入力され，人物固有の特徴が選択・出力される．これらの特徴同士を，距離関数を用いて比較したときに，同一クラス間では距離が小さく，別クラス間で距離が大きくなるように学習が行われる．

人物再同定 CNN(図 2(b))は，人物特徴選択 CNN と同様に人物領域の特徴マップを受け取り，人物 ID を識別結果として出力する．本研究で扱う人物再同定は，K人の特徴データが存在すると仮定したとき，ネットワークの出力層がK個のユニットを持つ，Kクラス分類問題として扱うことができる．出力層の各ユニット$k(k=1,\ldots,K)$の総入力をu_kとするとき，学習に用いるソフトマックス関数は以下の式(2)のように表すことができる．

$$y_k=\frac{\exp(u_k)}{\sum_{j=1}^{K}\exp(u_j)} \quad (2)$$

また，学習時の損失関数として式(3)の交差エントロピーを用いる．

$$E(\boldsymbol{w})=-\sum_{n=1}^{N}\sum_{k=1}^{K}t_{nk}\log y_k(x_n;\boldsymbol{w}) \quad (3)$$

ここで$\boldsymbol{w}$は学習するパラメータ，tは正解ラベル，xはネットワークに入力する特徴を表す．

本研究で提案する人物再同定モデルは，入力に近い層については人物特徴選択 CNN と共通の形になっており，出力側の層は人物識別結果を出力するために，畳み込み層，プーリング層，全結合層を追加する形で構成されている．訓練には，あるタスクに関して学習させたモデルを別のタスクを解くために利用する手法である転移学習を用いる．提案モデルにおいては，前半部分は人物特徴選択 CNN を事前に学習させた時点の重みを利用し，後半に追加された層のみを学習する．これによって，人物のアピアランスの変化への適応とモデル学習の収束の促進を図ることができる．

3.3 GUI を用いた半自動ラベル付け

提案手法では，以下の 3 つのステップに沿って，自動的なラベル付けが可能か，GUI を用いた人の手によるラベル付けが必要かを判断する．

(1) 人物再同定器を用いた自動ラベル付け

既に学習された人物再同定器が存在し，新たに取得されたサンプルが，あらかじめ設定された閾値以上の確信度で分類された場合，分類されたクラスをそのままラベルとして使用する．

(2) 人物特徴の類似度比較に基づく自動ラベル付け

新しく取得されたサンプルの人物特徴を，既にラベルが付けられた全サンプルの人物特徴と比較し，類似度が高い順にソートする．最上位サンプルの類似度が事前に設定された閾値以上となった場合，そのラベルが新しいサンプルに割り当てられる．

(3) GUI を用いた手動ラベル付け

上記(1)，(2)で自動的にラベル付けがされなかった場合，そのラベルは人間のユーザによって GUI を使って決定する．使用

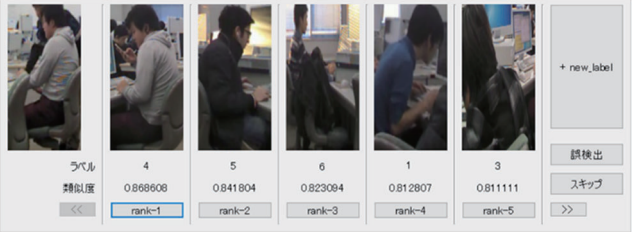


図 3 ラベル選択 GUI



図 4　ラベル調整 GUI

する GUI を図 3 に示す．入力サンプルは左端に表示され，類似度が高い順に 5 つのラベル付きのサンプルが右側に表示される．ユーザは，双方の画像を比較して最も類似する（同一人物である）と考えられる画像のラベルを選択することでラベル付けを行う．新しい画像に一致すると考えられる画像がない場合，ボタン操作によって新たなラベルを割り当てることができる．

図 4 のラベル調整 GUI には，クラス名，各ラベルに含まれるサンプル数やその代表となる画像が表示される．ユーザは既に与えられているクラス名を，人名などの任意の名前に手動で変更することができる．

4. 実験

4.1 使用するデータセット

実験に使用するデータセットの構成を表 1 に示す．人物再同定向けデータセットの多くは，人物領域が既に切り取られた状態の画像で構成されている．一方，本研究の提案手法は人物検出 CNN から人物領域の特徴を抽出するため，人物領域の座標情報を含んだ画像全体のデータが必要になる．Person Re-identification in the Wild（PRW）[Zheng 17]データセットは，公開されている大規模データセットの中でこの条件を満たすデータセットの 1 つである．

SOTARO-1 および SOTARO-2 は，当研究室で開発を進めているロボット SOTARO で収集したデータを再構成して作成したデータセットである．SOTARO の詳細については 5.2 節で改めて後述する．2 種類のデータセットは別日に収集されており，服装等見え方の異なる同一人物のサンプルが含まれている．

表 1　データセット構成

	PRW	SOTARO -1	SOTARO -2
撮影方法	固定カメラ 6 台	移動ロボット搭載のカメラ	
画像枚数	約 34,000 枚	約 16,000 枚	
含まれる人数	学習用 483 人 評価用 450 人	41 人	48 人
用途	特徴選択 CNN の学習	特徴選択 CNN の学習・再同定 CNN の転移学習	

表 2　転移学習の性能評価

CNN の学習に使用するデータセット		評価			
特徴選択	再同定	Top-1	Top-5	Top-10	Top-20
なし	SOTARO -1	66.4	83.9	89.4	94.5
PRW		78.9	90.6	94.9	98.3
SOTARO-2		80.3	91.0	95.3	99.3
なし	SOTARO -2	60.6	76.4	86.1	92.7
PRW		74.4	87.2	91.3	95.5
SOTARO-1		79.4	90.4	94.4	97.3

4.2 人物再同定 CNN の転移学習の評価

前述の 2 つのデータセットを用いて，特徴選択 CNN の学習と再同定 CNN の転移学習を実施した．評価には，分類確信度が高い上位 K 位に正解ラベルが含まれるか否かを測定する Top-K 精度を使用した．結果は表 2 に示す通りである．表からは，特徴表現の事前学習が再同定精度の向上に有効であることが分かる．また，特徴選択 CNN と再同定 CNN の学習に，類似の環境下で収集したデータセットを用いることで，更なる精度の向上に繋がることが分かった．

4.3 データセット分割による協調システムの評価

協調型ラベル付け処理が正確に行われたと仮定し，サンプル数の増加に対する人物再同定精度の推移を評価する．本実験では SOTARO データセットを 6 分割し，5 段階の再同定精度を比較する．表 2 は，特徴選択 CNN の学習に SOTARO-2 を，再同定 CNN の転移学習に SOTARO-1 を使用した場合の結果を，表 3 は逆の条件で実験を行った場合の結果を示している．学習用サンプルの増加に伴って再同定精度が改善されることから，多くのサンプルを早い段階で収集することが重要であるといえる．

表 3　データセット分割実験 1

	Stage-1	Stage-2	Stage-3	Stage-4	Stage-5
Sample 数	2,663	5,327	7,991	10,654	13,318
Class 数	35	40	40	40	40
Accuracy	23.4	40.2	60.5	64.2	81.4

表 4　データセット分割実験 2

	Stage-1	Stage-2	Stage-3	Stage-4	Stage-5
Sample 数	2,668	5,336	8,004	10,672	13,340
Class 数	28	42	45	48	48
Accuracy	32.5	52.1	46.1	64.7	80.7

5. TA 業務への適用

5.1 ロボットによる TA 支援

我々が TA を担当しているプログラミング演習授業ではこれまで，複数人の TA が，受講学生側からの意思表示（質問をするために手を挙げる・TA を呼ぶなど）に基づいて学習の支援を行ってきた．しかしこの方法では，質問する学生は限定され，TA とのコミュニケーションに抵抗のある学生の学習を支援することができない．事前に行ったアンケート調査からは，およそ 4 割の学生が TA とのコミュニケーションに何らかの問題を抱えていることが分かっている．こうした背景から我々は，授業にロボット TA を導入することを考えた．

5.2 学生証読み取りに基づく名前識別

ロボット（SOTARO[渥美 17]）を用いた TA 業務支援において，各個人に合わせたサービスを提供するためには，人物再同定に加えて名前等の個人識別子を把握することが重要である．本研究では図 5 に示すように，SIFT[Lowe 04]特徴とテンプレートマッチングによる学生証読み取り機能をロボットに搭載することで，受講学生の名前を外見画像に加えて取得し，名前から得られる情報を元にコミュニケーションを行う．

5.3 TA 業務支援の想定実験

図 6 に，実際にロボット TA による業務支援の実験を行った際の実験の流れを示す．まず，学生にプログラミングに関する基本的な知識を問う穴埋め問題を提示し，その後，ロボットがそれに関連するクイズを学生に出題する．クイズは問題・ヒント・答え・補足の 4 つで構成され，遠隔操作によって各種スクリプトの読み上げを行う．クイズは学生が希望した場合繰り返し出題し，最後にアンケートを実施する．

アンケートでは，実験協力者のうち 9 名から有効な回答が得られた．図 7 に結果の一部を示す．ロボットによるクイズの実施により，授業に関する理解を深める一定の効果が見られたといってよいだろう．今後もロボットがより多くの学生に受け入れられるよう，コミュニケーション対象の選択方法や学生への話しかけ方の検討が必要である．

6. むすび

本論では，特定の集団に定期的にサービスを提供する移動ロボット向けの人物再同定手法を提案した．公開されている大規模データセットと，移動ロボットで収集した自作のデータセットを用いた実験により，提案手法の有用性を評価した．

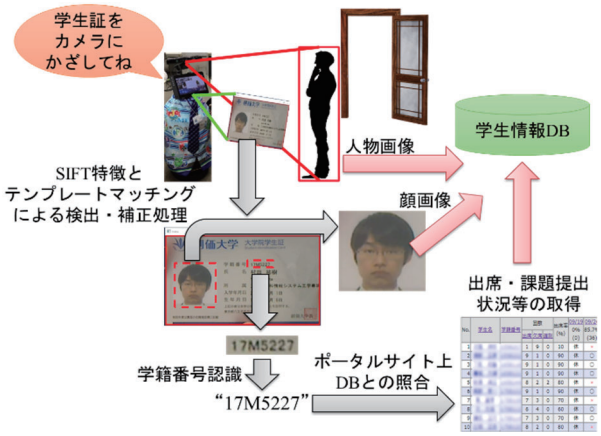


図 5　学生証読み取りと名前を介した情報取得

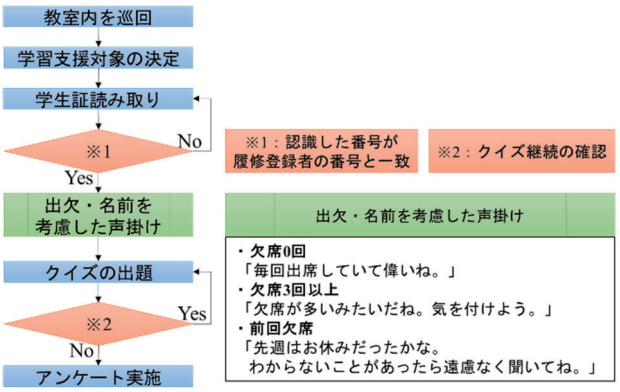


図 6　TA 業務支援実験の流れ

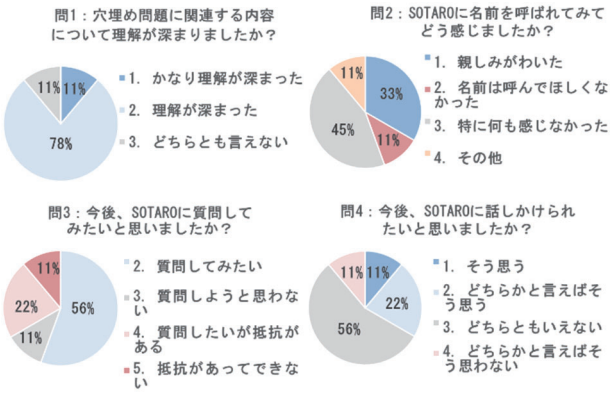


図 7　実験後のアンケート結果

また，提供するサービスの一例として演習授業の TA 業務支援を取り上げ，学生証読み取り機能を搭載したロボットを授業内で動作させる実験によって，その可能性を検証した．

参考文献

[Radenovic 16] F. Radenovic, G. Tolias, and O. Chum: CNN image retrieval learns from BoW: Unsupervised fine-tuning with hard examples, ECCV, 2016.

[Schrof 15] F. Schroff, D. Kalenichenko, and J. Philbin: Facenet: A unified embedding for face recognition and clustering, CVPR, 2015.

[高石 07] 高石悦史, 安村通晃: ロボット TA をもちいた対面型授業支援システムの試作, WISS2007 論文集, 2007.

[Shiomi 15] M. Shiomi, T. Kanda, I. Howley, K. Hayashi, and N. Hagita: Can a social robot stimulate science curiosity in classrooms?, International Journal of Social Robotics, 2015.

[Redmon 17] J. Redmon and A. Farhadi: YOLO9000: Better, Faster, Stronger, CVPR, 2017.

[Zheng 17] L. Zheng, H. Zhang, S. Sun, M. Chandraker, Y. Yang, and Q. Tian: Person re-identification in the wild, CVPR, 2017.

[渥美 17] 渥美雅保,村田祐樹,安川葵: SOTARO:オープンチャットとロボットの連携による演習授業支援システム—Human-in-the-loop 型機械学習によるアプローチ—, 情報処理学会第 79 回全国大会, 2017.

[Lowe 04] D. G. Lowe: Distinctive image features from scale-invariant feature points, International Journal of Computer Vision, 2004.

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

自律移動ロボットのための事前環境地図を必要としない深層強化学習を用いた動作計画

Motion Planning with Deep Reinforcement Learning without Using the Pre-Environment Map for Autonomous Mobile Robot

有馬 純平　黒田 洋司
Jumpei Arima　Yoji Kuroda

明治大学
Meiji University

In this paper, we propose a learning-based motion planner for autonomous mobile robot which output continuous motion commands by referring from the scan data of 2D-LiDAR and the target point without using environmental map. We aim to use this method for a safe and efficient navigation system of an autonomous mobile robot with high generalization performance in urban environment. We show that a mapless motion planner can be trained through a deep reinforcement learning method in only simulator. In order to verify the effectiveness of the proposed method, collision avoidance and navigation performance are evaluated by directly applying the learned planner to the actual machine in the real world. As a result, we showed that we can obtain navigation performance equivalent to conventional method without using pre-environment map.

1. 緒言

近年，自動運転車を中心とした自律移動ロボットの研究開発が盛んに行われている. その中でも警備ロボットや配達ロボットなどの人間に近い環境で活動するロボットへの関心が高まっている. これらのロボットが自律移動を行うためには，環境認識，自己位置推定，経路計画の三要素が重要である. 現在は，自律移動ロボットが事前に取得した環境のデータから作成した事前地図を所有し，その地図をもとに自律移動を行うことが一般的である. しかし，都市環境では事前に取得したデータと実際の環境が異なることが多い. このような場合，事前環境地図を利用したナビゲーションシステムでは，システムの安定性は 実際の環境との差異に大きく左右されてしまう. そのため，ロバスト性の高い自律ナビゲーションを行うためには，事前環境地図に依存しないシステムが求められる. そこで，我々は，一般に公開されている電子地図から交差点を node，道を edge とした Edge-node map を作成し，これと通過すべき node のみを事前情報としたナビゲーションシステムの研究を進めてきた [澤橋 18]. しかし，このシステムで採用されている経路計画は，周辺の環境認識から，複数の経路を予測し，コストの少なくロボットのモデルを考慮した最適な経路を算出するため，環境の複雑さによって処理コストがかかる欠点がある．また，経路の予測時間，コストなどのパラメータの設計は環境に依存するものであり，我々の目指す環境に汎化性能のあるナビゲーションシステムには，従来のルールベースの経路計画は適していない．

本稿では，事前環境地図を必要せずに障害物を回避し目標位置に到達可能である動作計画を深層強化学習を用いて獲得する手法を提案する．事前環境地図なしの動作計画を実現するため，センサの入力と目標位置から動作指令を出力とする動作計画をシミュレーション上で学習させ，学習された動作計画は，直接実機に適用する．本稿では，学習された動作計画を，シミュレーション上と実世界において実験を行い本手法の有用性を示す.

連絡先: 有馬純平，明治大学理工学部機械工学科，〒 214-8571 神奈川県川崎市多摩区東三田 1-1-1，044-934-7183，arijun0307@gmail.com

2. 関連研究

近年，学習ベースで自律移動ロボットの行動を獲得する研究が多く行われている．

M. Pfeiffer らは，従来のルールベースによるナビゲーションを畳み込みネットワークで表現し，模倣学習させることによって，事前地図を用いずに従来手法と同等程度のナビゲーション性能を示した [Pfeiffer 17]．この研究では，2D-LiDAR をセンサ情報とし，畳み込みニューラルネットワークで動作計画をモデル化した．L. Tai らは，2D-LiDAR の 10 本のみを入力として，事前地図なしの動作計画を学習させた [Tai 17a]．この研究では深層強化学習のアルゴリズムである DDPG をベースとした手法を用いている．

上記の 2 つはセンサ情報として LiDAR を使用した研究であるが，カメラセンサを用いた研究も盛んである [Zhu 17][Tai 17b]. しかし，方策獲得に数百万回の試行錯誤が必要である強化学習は基本的にシミュレーションで行われるが，人工的なシミュレーション空間での画像と実世界での画像との違いによってモデルの転移に課題があり実用化は難しいのが現状である．一方学習させるネットワークの入力を低次元にすることによって，複雑な動的環境において障害物回避を行う研究も行われている [Fan 17]．この研究では事前地図を用いて建造物などの静的障害物を回避し，動的障害物は LiDAR とカメラを用いて位置と速度を推定している．これは事前環境地図の作成コストと認識の精度依存といった欠点が挙げられる．そこで本稿では，事前環境地図を必要とせず，パラメータ調整を行う必要のない End-to-end の動作計画を獲得することを目指す.

3. 提案手法

3.1 深層強化学習による動作計画

自律移動ロボットの動作計画は，センサから得られる情報と取るべき行動との関係を表すモデルを求め，新しい観測に対して直ちに動作指令を実行する必要がある．本稿では，式 1 に示すように，ある時刻 t におけるセンサ情報 x_t と目標位置 p_t から適切な動作指令 v_t を直接導出する方法を提案する．

$$v_t = f_\theta(x_t, p_t) \tag{1}$$

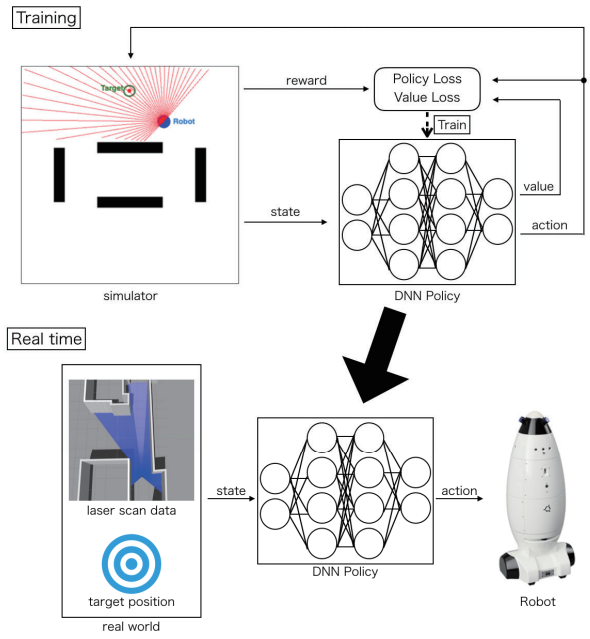


図 1: システム概要

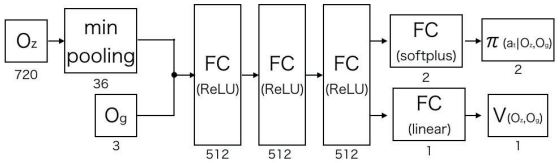


図 2: ネットワーク構造

ここで，ある時刻 t におけるロボットの状態から動作指令 v_t を出力する関数 f を θ でパラメタライズする．この θ はシミュレーション上で強化学習を行うことによって最適なものに調整する．本稿では，深層強化学習の手法として，Proximal Policy Optimization(PPO)[Schulman 17] を採用した．学習された方策は実空間へ直接適用する．本稿で提案するシステムの概要図を図 1 に示す．

3.2 ネットワーク構造

ロボットの状態と動作指令の間の End-to-end の関係を表すモデルは非常に複雑である．本稿では，この複雑モデルを万能関数近似器としてよく知られているディープニューラルネットワークで表現する．また，ロボットの状態として，2D-LiDAR から得られるセンサ情報とロボット座標系における相対的な目標位置を用いる．全体のネットワーク構造を図 2 に示す．

2D-LiDAR の情報は，ロボット正面から± 90 度の範囲の 720 本のレーザの距離情報である．ここでは，720 本の距離情報を 36 本に圧縮したものを全結合層への入力とする．圧縮方法は，式 2 に示すように Min プーリングを用いる．

$$s_{l,i} = min(s_{i\cdot k}, \cdots, s_{(i+1)\cdot k}) \tag{2}$$

ここで，k は 1D プーリングにおけるカーネルサイズを表し，本稿では k=*20* とする．このように，Min プーリングしたものを入力とすることによって，安全性を保つと共に学習の効率をあげることが出来る．また，シミュレーション上の限定的な環境で学習を行うため，畳み込みニューラルネットワークによりセンサ情報から特徴量を抽出することはせず，Min プーリングを用いて実世界との相違を緩和する．ロボット座標系に対する相対的な目標位置は，距離と角度の正弦値と余弦値の 3 次元で表す．このセンサ情報と目標位置情報を合わせたものを 3 層の全結合層への入力とし，方策 π_θ と状態価値関数 V を出力する．本稿では，ロボットの動作指令値は連続値を扱うため，方策 π_θ は確率分布のベータ分布で表現する．方策へ入力する値は隠れ層の最後の出力に対して活性化関数の softplus 関数を用いた．

3.3 報酬設計

障害物に衝突せずに目標位置へ到達するというタスクをエージェントに学習させるために，本稿では式 3 に示す報酬関数を定義する．λ^p，λ^ω は重み付け定数である．

$$R_t = r_t + \lambda^p r_t^p + \lambda^\omega r_t^\omega \tag{3}$$

ここで r_t は，衝突せず目標位置へ到達させるための報酬である．

$$r_t = \begin{cases} r_{arrive} & \text{if } d_t < c_d \\ r_{collision} & \text{if } min_{s_l} < c_o \\ c_r(d_{t-1} - d_t) & \text{otherwise} \end{cases} \tag{4}$$

ここで r_t^p と r_t^ω は，目標位置との距離および方位を考慮した報酬であり，この項を入れることによりよりサンプル効率の良い探索を促す．

$$r_t^p = \begin{cases} r_{position} & \text{if } (d_{t-1} - d_t) = 0 \\ 0 & \text{otherwise} \end{cases} \tag{5}$$

$$r_t^\omega = |\phi_t| \tag{6}$$

ここで d_t は時刻 t におけるロボットと目標位置との距離，ϕ_t は時刻 t におけるロボットと目標位置との相対角度，c_d と c_o はそれぞれ目標位置到達，衝突の判定距離である．

4. 実験

4.1 学習実験

提案する動作計画の訓練は，屋内環境を簡易的に模した OpenAI gym に準じた自作のシミュレーション環境で行う．目標位置は，各エピソードごとに障害物が存在しない場所にランダムに配置され，初期位置は環境の中心で初期方位はランダムとする．各エピソードの終了判定は，以下のいづれかとする．

- 目標位置に到達した場合
- 障害物に衝突した場合
- ステップ数が 500 ステップを超えた場合

また，学習の更新方法としては Adam を用いた．

提案手法による動作計画の訓練は，初期方策をランダムからはじめ，10 万エピソード行い学習が収束した．

4.2 評価

シミュレーション上で学習された動作計画の性能を評価するため，本稿では，学習環境とは異なる未知の環境においてシミュレーション上と実世界の双方で実験を行う．

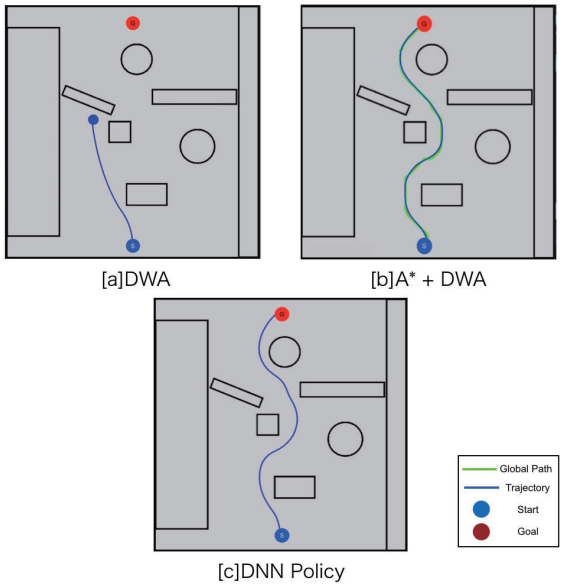


図 3: シミュレーション上での実験

表 1: シミュレーション上での実験の結果

	A* + DWA	Proposed Method
Time[s]	13.60	11.70
Distance[m]	10.51	10.43

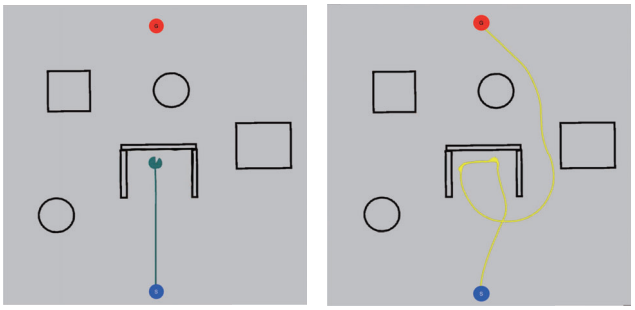
4.2.1 シミュレーション上での実験

シミュレーション上での評価環境として，学習環境とは異なる障害物が複数置かれた $10m \times 10m$ の静的な仮想環境を作った．学習した動作計画の比較対象として，事前地図から A*アルゴリズム [Hart 68] を用いて大域経路を計画し，その経路に Dynamic Window Approach[Fox 97] で経路追従を行う従来手法と事前地図を用いず Dynamic Window Approach のみを用いた従来手法を採用する．提案手法では環境の地図は与えずに目標位置のみを事前に与える．従来手法である 2 つと学習された動作計画の経路の結果を図 3 に示す．

図 3[a] より事前地図を与えず DWA のみで行う場合，行き止まりの道に入るとそこから抜け出すことができなくなってしまう．この理由としては，DWA は目標位置から離れるような行動を選択しないためだと考えられる．一方 A*を用いて計画された大域経路に DWA を用いて経路追従を行うとスムーズかつ障害物との適切な距離を保った動作を行えていることが図 3[b] からわかる．提案手法による軌跡は A*と DWA を組み合わせた手法と比較した場合僅かにふらつくことがあるが，似たような軌跡となり，障害物に衝突せず目標位置へ到達することができることがわかる．また，A*と DWA を組み合わせた従来手法と提案手法において上記の実験を 10 回行なったときの目標位置までの走行時間と走行距離の平均値を表 1 に示す．

結果から提案手法は事前地図を用いないが，シミュレーション上の静的な環境において従来手法と同程度のナビゲーション性能があると言える．表 1 では走行距離・走行時間双方で僅かに提案手法が優れているが，これは従来手法では大域経路を計画する際，コストの設計を安全に行なったおり，障害物からの距離を取るように経路を計画するため，距離が僅かに長くなったと考えられる．

提案手法では，パラメータ調整をする必要がなくセンサ情報から動作指令を出力することができるので未知の環境において事前環境地図がなくとも柔軟に対応できるといった特徴があると言える．



[a]DWA　[b]Proposed method

図 4: 袋小路環境における実験

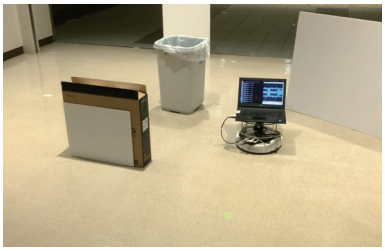


図 5: 実環境における衝突回避実験

また，上記の実験のように一般的に DWA による局所経路計画は袋小路などの局所解に陥りやすいという欠点がある．そこで初期位置と目標位置との間に袋小路が存在する環境で DWA による動作と提案手法による動作を比較した．図 4 にその結果を示す．

結果より，DWA による動作計画では，袋小路があるような環境で，そこから抜け出すことはできないが，提案手法では，抜け出し最終的に目標位置に到達することができることがわかる．提案手法では学習時にその場に留まることに負の報酬を与えているため，目標位置が与えられている限り動き続けることを学習したからだと考えられる．

4.2.2 実世界での実験

シミュレーション上で学習された動作計画を，実機に搭載し実世界での評価を行なった．評価は，提案手法による障害物回避実験と，ナビゲーション実験の 2 つを行なった．

障害物回避実験では，実機として Roomba をプラットフォームとし，センサには 2D-LiDAR を用いた．

本実験では，ロボット座標系における目標位置の算出には，AMCL[Thrun 05] による自己位置推定を用いた．図 5 に実際に行なった走行テストの様子を示す．

このような目標位置までに複数障害物が存在する環境において学習済みモデルを直接実機に適用させた場合の軌跡を図 6 に示す．

結果から，シミュレーション環境ではない未知の環境において，シミュレーションのみで学習したモデルを実世界においても直接適用し衝突回避を行うことができることがわかる．

次に，ナビゲーションの実験について述べる．この実験では，実機として SEQSENSE 社から提供された SQ-2 を用いた．ナビゲーション実験は明治大学生田キャンパス第二校舎 D 館 1F において，図 7 に示す 3 点を通るように 1 周する実験を行なった．

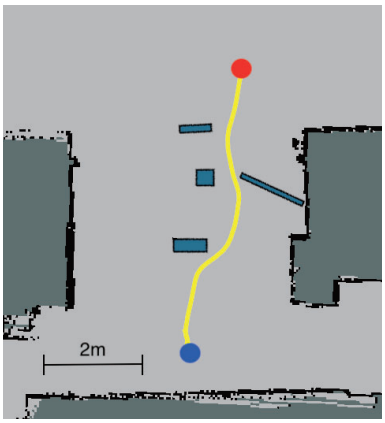


図 6: 衝突回避実験の軌跡

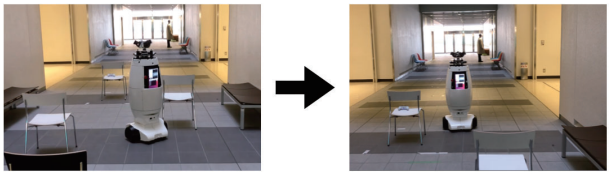


図 7: 実環境におけるナビゲーション実験

本実験で用いた SQ-2 のセンサは 3 次元点群を出力するので，それを 2 次元に圧縮し，学習済みのモデルへの入力とした．自己位置推定には衝突回避実験と同様に AMCL を用いた．実験の結果ロボットの結果を図 8 に示す．

結果より学習環境とは異なる環境においてナビゲーションを行うことができた．学習環境は 10m×10m の環境であったが，目標位置を数 10m 離れたところに設置してもそこへ到達可能であることがわかった．また，目標位置へ最短距離の壁沿いに進むわけではなく，道の中央を走行することが確認できる．これは，報酬設計に明示的に組み込んだわけではないが，衝突回避を学習する上で，できるだけ障害物から離れるように学習したからだと考えられる．

5. 結言

本稿では，深層強化学習のアルゴリズム PPO を用いて，自律移動ロボットのためのセンサの入力と目標位置から連続値の動作指令を出力とする動作計画の構築手法を提案した．提案した手法により学習された動作計画は，シミュレーション上の未知の環境において，事前地図を用いずに従来手法と同程度のナビゲーション性能を示した．また実世界では，シミュレーション上のみで学習したモデルを直接適用することで，静的環境において障害物回避とナビゲーションを実現した．以上より提案手法の有用性が示せたと言える．

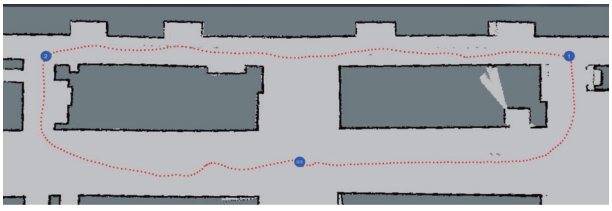


図 8: ナビゲーション実験の軌跡

謝辞

本研究の一部は，国立研究開発法人新エネルギー・産業 技術総合開発機構 (NEDO) の，次世代人工知能・ロボット中核技術開発事業による支援を受けた．ここに篤く御礼申し上げる．

参考文献

[澤橋 18] 澤橋遼太，細田佑樹，町中希彰，山崎亮太，定國 裕大，草刈亮輔，黒田洋司,「Edge-Node-Graph 及 び分岐点検出に基づく道なり走行ナビゲーション システムの開発」，第 23 回ロボティクスシンポ ジア，静岡県，2018，pp.67-72

[Pfeiffer 17] Pfeiffer, M., Schaeuble, M., Nieto, J., Siegwart, R., and Cadena, C.: From perception to decision:A data-driven approach to end-to-end motion planning for autonomous ground robots, in International Conference on Robotics and Automation (ICRA), pp. 1527-1533 IEEE (2017)

[Tai 17a] Tai, L., Paolo, G., and Liu, M.: Virtual-to-real deep reinforcement learning: Continuous control of mobile robots for mapless navigation, in International Conference on Intelligent Robots and Systems (IROS), pp. 31-36 IEEE (2017)

[Zhu 17] Zhu, Y., Mottaghi, R., Kolve, E., Lim, J., Gupta, A., Fei-Fei, L., and Farhadi, A.: Target-driven visual navigation in indoor scenes using deep reinforcement learning, in International Conference on Robotics and Automation (ICRA), pp.3357-3364 IEEE (2017)

[Tai 17b] Tai, L., Zhang, J., Liu, M., and Burgard, W.: Socially Compliant Navigation through Raw Depth Inputs with Generative Adversarial Imitation Learning, arXiv preprint arXiv:1710.02543, 2017.

[Fan 17] Chen, Y. F., Everett, M., Liu, M., and How, J. P.: Socially aware motion planning with deep reinforcement learning, arXiv preprint arXiv:1703.08862, 2017.

[Schulman 17] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O.: Proximal policy optimization algorithms, arXiv preprint arXiv:1707.06347. 2017.

[Hart 68] Hart, P., Nilsson, N., and Raphael, B.: Formal Basis for the Heuristic Determination of Minimal Cost Paths, IEEE Transactions on Systems Science and Cybernetics, 1968.

[Fox 97] Fox, D., Burgard, W., and Thrun, S.: The dynamic window approach to collision avoidance, Robotics Automation Magazine, IEEE, vol. 4, no. 1, pp. 23-33, 1997.

[Thrun 05] Thrun, S., Burgard, W., and Fox, D.: Probabilistic Robotics pp. 250-261, MIT Press, 2005.

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

オンデマンド交通システムのための階層的車両配置最適化

Nested Rebalancing Optimization for Mobility on Demand

西 智樹 *1 小出智士 *1 大滝啓介 *1 大社綾乃 *1
Tomoki Nishi Satoshi Koide Keisuke Otaki Ayano Okoso

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

Mobility-on-Demand (MoD) services are promising application for Mobility as a Service. Imbalance between locations of vehicles and customer requests worsens service quality such as waiting time of customers for MoD services. Previous work has developed the method to optimize the number of vehicles at each regions at each time using Mixed Integer Programming. However the computational complexity of the method exponentially increases in proportion to the number of regions. We develop hierarchical method to optimize the number of vehicles. We evaluate the method to a real-world taxi trip dataset in numerical experiment. The result shows that the method with three layers improve the computational time compared to one with single a layer.

1. はじめに

オンデマンド交通は客からの依頼に応じて配車する交通システムであり，移動をより効率的にする有効な手段の一つである．オンデマンド交通は，1）客からの依頼をどの車両に割り当てるか，2）割り当てられた客をどの経路で送迎するか，3）客を送迎していない空車を次の依頼のためにどこに移動または待機させるかの，3 つのタスクに分割することができる．3 つ目のタスクは，車両のリバランシング問題と呼ばれ，現時刻の車両位置の分布と将来の需要位置の分布とに大きな開きがある場合に，客の待ち時間を減らすために効果的であることが知られている [Spieser 16].

Iglesias らは各車両の配置と経路を最適化するのではなく，予め分割されたエリアに必要な車両台数の最適化問題と捉え直し，整数線形計画問題として定式化した [Iglesias 18]．この定式化では車両台数が増えても最適化にかかる時間が一定であるため，都会のような車両台数が多い場合に有効である．しかしながら，分割されたエリアの数が増えると計算時間が急速に増加するという問題があるため，現状での適用範囲は局所的な地域内での最適化に限定される．

そこで本研究では，エリアを階層的に分割し，粗いエリアから細かなエリアに必要車両台数を最適化することで計算量を削減し，エリア数の増加に対応可能な手法を提案する．

2. 関連研究

リバランシング最適化問題の定式化は様々提案されている．Pavone らは流体モデルを用いることで最適リバランシング問題を線形計画問題として定式化できることを示した [Pavone 11]．また Zhang と Pavone はモデル予測制御を用いた離散時間モデルを提案した [Zhang 16]．Iglesias らは別の定式化として，時拡張ネットワークを用いた整数計画問題として定式化した [Iglesias 18]．この定式化では，計算量が車両の台数にはよらないため都会のような車両台数が多い時には特に有効である．しかしながら，この定式化では，予め分割したエリア数に対して指数関数的に計算量が増加するという問題があった．それに対し，提案手法は階層的に最適化を行うことでエリアの数が増えた場合でも現実的な時間で最適化できる．

最適リバランシング問題は，配車リクエストの車両への割当を最適化する研究 [Bei 18, Dickerson 18, Pelzer 15] とも関連している．割当最適化問題と本研究が取り扱う最適リバランシング問題とが大きく異なる点は，我々の定式化では，個別の車両とリクエストの割当は行わず，各エリア各時刻の必要な車両台数を最適化する点である．そのため車両台数やリクエスト数に対し，割当最適化問題は計算量が増加するのに対し，Iglesias らの手法や提案法では計算量は一定である．どの車両がどの配車リクエストを処理するかに対しては，提案法は最適化後，各エリア内で割当を行う必要があるが，一般に各エリアの車両台数やリクエスト数はエリア全体に比べ十分小さいため計算時間の面では問題ないと予想される．

3. 階層的リバランシング法

基本的な考え方は，分割粒度の粗い上位層で大きなエリア間の移動を伴う移動を最適化し，上位層では最適化されなかった粗い粒度のエリア内での移動に関して，より細かな粒度の下位層で最適化する．これは例えば県全域でリバランシングを最適化する場合，従来法は県全域を最初から交差点単位で最適化するのに対し，提案法は上位層で市区町村の間の移動を，下位層で各市区町村毎の移動を最適化することに対応する．

Iglesias らが提案したリバランシング問題の定式化は総車両台数が時間によらず一定であると仮定していた．しかしながら提案法では，下位層の各エリアの総車両台数は，上位層で最適化された各時刻の各粗いエリアの車両台数によって決まるため，時々刻々変化する可能性がある．そこで本章では，まず総車両台数が時々刻々で変化する場合でも対応できるよう拡張した最適リバランシング問題の定式化を示し，階層的リバランシング法について述べる．

3.1 総車両台数時変最適リバランシング問題

最適リバランシング問題とは，需要を全て満たすという制約条件の下で，リバランシングにかかるコストを最小化するための各時刻各エリアの車両台数を決定する問題である．総車両台数が時々刻々変化する場合に対応できるよう拡張した定式化は下記の通りである．

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

$$\min_{\mathbf{x}^p,\mathbf{x}^r,\mathbf{x}^a,\mathbf{x}^d} \sum_{t\in\mathcal{T}}\sum_{i\in\mathcal{N}}\sum_{j\in\mathcal{N}} c_{ij}x^r_{ijt}, \quad \text{subject to,} \tag{1a}$$

$$x^p_{ijt} = \lambda_{ijt},\ i,j \in \mathcal{N}, t \in \mathcal{T}, \tag{1b}$$

$$\sum_{j\in\mathcal{N}} \left(x^r_{ijt} + x^p_{ijt} - x^r_{jit-\tau_{ji}} - x^p_{jit-\tau_{ji}} \right) = s_{it}, \quad \forall i \in \mathcal{N}, t \in \mathcal{T}, \tag{1c}$$

$$s_{it} \coloneqq \begin{cases} x^a_{it} & t = 1 \\ x^a_{it} - x^d_{it} & t > 1 \end{cases},\ \forall i \in \mathcal{N}, t \in \mathcal{T},$$

$$\sum_{i\in\mathcal{N}} \left(s_{it} + \sum_{j\in\mathcal{N}}\sum_{\Delta t=1}^{\tau_{ji}} \left(x^r_{jit-\Delta t} + x^p_{jit-\Delta t} \right) \right) = V_t, \quad \forall t \in \mathcal{T}, \tag{1d}$$

$$\sum_{i\in\mathcal{N}} x^a_{it} = \begin{cases} V_t - V_{t-1} & V_t \le V_{t-1} \\ 0 & \text{otherwise} \end{cases}, \forall t \in \mathcal{T}, \tag{1e}$$

$$\sum_{i\in\mathcal{N}} x^d_{it} = \begin{cases} 0 & V_t \le V_{t-1} \\ V_{t-1} - V_t & \text{otherwise} \end{cases}, \forall t \in \mathcal{T}, \tag{1f}$$

$$\mathbf{x}^r \coloneqq \{x^r_{ijt}\}, \mathbf{x}^p \coloneqq \{x^r_{ijt}\}, \mathbf{x}^a \coloneqq \{x^r_{ijt}\}, \mathbf{x}^d \coloneqq \{x^r_{ijt}\}, \quad \forall i,j \in \mathcal{N}, t \in \mathcal{T}, \tag{1g}$$

ここで，$\mathcal{N} \coloneqq \{1,\dots,N\}$ 及び $\mathcal{T} \coloneqq \{1,\dots,T\}$ はそれぞれ N 個のエリアの集合，T 時間ステップの集合を示している．上付添え字 r,p はそれぞれ，リバランシングに関する変数および顧客を目的地に運ぶ移動に関する変数を表している．x_{ijt} は時刻 t にエリア i からエリア j に移動する車両台数，c_{ij} はエリア i からエリア j に移動するためにかかるコスト，s_{it} は時刻 t にエリア i に留まっている車両台数を表している．また τ_{ij} はエリア i からエリア j に移動するのにかかる時間ステップ数を，λ_{ijt} は時刻 t にエリア i からエリア j に移動したい顧客の数を，V_t は時刻 t の総車両台数を表している．x^a_{it} は時刻 t にエリア集合 $\mathcal{N}$ の外からエリア i に流入する台数を，x^d_{it} はエリア i から $\mathcal{N}$ 外に流出する台数を示している．

リバランシング問題の目的関数 (1a) は時刻 0 から T までのリバランシングにかかるコストの合計であり，それを最小化するように各時刻の移動を最適化することが目的である．制約条件 (1b) は各時刻で客の依頼には必ず応えることを，制約条件 (1c) は車両台数の保存則であり，リバランシングまたは送迎によりエリアに流入する数と流出する数が釣り合うことを表している．制約条件（1d）は時刻 t の $\mathcal{N}$ に存在する総車両台数が V_t であることを，制約条件（1e）及び（1f）は，時刻 t に $\mathcal{N}$ 外から流入出する車両台数の釣合いを示している．

3.2 階層的リバランシング最適化アルゴリズム

従来法に比べ大規模なエリアに関して高速に最適化が可能である階層的リバランシング法について述べる．基本的な考え方は，分割粒度の粗い上位層で大きなエリア間の移動を伴う移動を最適化し，その最適化結果に基づきより細かな粒度の下位層でより小さなエリア間の移動に関して最適化する．ある層のエリア l に関して 2 つのオペレータ Children(l)，Parent(l) を定義する．Children(l) はエリア l に含まれる一つ下位層のより詳細なエリアの集合を返し，Parent(l) はエリア l が含まれる一つ上位層のより広いエリアを返す．

l 層目のエリア集合 $\mathcal{N}_l$ に含まれるエリア間の旅行時間，コスト，リクエスト数はそれぞれ $\boldsymbol{\tau}_l \coloneqq \{\tau_{ijt}\}_{i,j\in\mathcal{N}_l,t\in\mathcal{T}}$, $\mathbf{c}_l \coloneqq \{c_{ijt}\}_{i,j\in\mathcal{N}_l,t\in\mathcal{T}}$ and $\boldsymbol{\lambda}_l \coloneqq \{\lambda_{ijt}\}_{i,j\in\mathcal{N}_l,t\in\mathcal{T}_l}$ で表す．また $\mathcal{N}_l$ の車両の分配方法を $\mathbf{x}_l \coloneqq (\mathbf{x}^p_l, \mathbf{x}^r_l, \mathbf{x}^a_l, \mathbf{x}^d_l)$ とする．ただし $\mathbf{x}^p_l \coloneqq \{x^p_{ijt}\}_{i,j\in\mathcal{N}_l,t\in\mathcal{T}}$, $\mathbf{x}^r_l \coloneqq \{x^r_{ijt}\}_{i,j\in\mathcal{N}_l,t\in\mathcal{T}}$, $\mathbf{x}^a_l \coloneqq \{x^a_{it}\}_{i\in\mathcal{N}_l,t\in\mathcal{T}}$ 及び $\mathbf{x}^d_l \coloneqq \{x^d_{it}\}_{i\in\mathcal{N}_l,t\in\mathcal{T}}$．エリア l の各時刻 $t \in \mathcal{T}$ の車両台数を $\mathbf{V}_l \coloneqq [V_{lt}]_{t\in\mathcal{T}}$ で表す．この値は下記に示す式によりエリア l の一つ上位層でのリバランシング最適化結果に基づき算出され，エリア l の車両台数を最適化する際に利用される．

$$V_{lt} = s_{lt} + \sum_{j\in\text{Palent}(\mathcal{N}_l)} \left(x^r_{jlt-\tau_{jl}} + x^p_{jlt-\tau_{jl}} \right), t \in \mathcal{T}, \tag{2}$$

$$s_{lt} = \begin{cases} x^a_{lt} & t = 1 \\ x^a_{lt} - x^d_{lt} & t > 1 \end{cases}, t \in \mathcal{T}.$$

エリアを K 層に階層化した際の階層的リバランシング法 NERO_K を Algorithm 1 に示す．利用する際には各エリア各時刻の車両台数は $\text{NERO}_K(\mathcal{N}_1, 1)$ を呼び出すことにより再帰的に求めることができる．ここで，Demand($\mathcal{N}_l$) を $\mathcal{N}_l$ に含まれるエリア集合のリクエストの数を返すオペレータ，Rebalancing($\mathcal{N}_l, \boldsymbol{\tau}_l, \mathbf{c}_l, \mathbf{V}_l, \boldsymbol{\lambda}_l$) をエリア l のリバランシング最適化結果 $(\mathbf{x}^r_l, \mathbf{x}^p_l, \mathbf{x}^a_l, \mathbf{x}^d_l)$ を返すオペレータ，$\mathbf{V}_{max}$ を各時刻で利用可能な総車両台数とする．また $\mathcal{N}_1$ は最上位層のエリア集合である．

Algorithm 1 $\text{NERO}_K(\mathcal{N}, k)$

入力: エリアの集合 $\mathcal{N}$, 層のインデックス k
出力: リバランシングポリシーの集合 $\mathbf{x}$

```
x ← ∅
for l in N do
    N_l ← Children(l)
    if k = 1 then V_l ← V_max
    else V_l ← Computed using Eq. (2)
    λ_l ← Demand(N_l)
    (x^r_l, x^p_l, x^a_l, x^d_l) ← Rebalancing(N_l, τ_l, c_l, V_l, λ_l)
    x ← x ∪ {(x^r_l, x^p_l, x^a_l, x^d_l)}
    if k ≤ K then x ← x ∪ NERO_K(N_l, k + 1)
return x
```

4. 数値実験

本章では，タクシーの実データを用いて提案したリバランシング最適化法の有効性を検証する．提案法は階層的に最適化することで計算時間を短縮することができる．しかしながら上位層の粗い粒度のエリア間の移動時間は下位層の細かなエリア間の移動時間に比べ長く見積もる必要があるため，階層的に最適化する提案手法は従来法に比べ無駄な待機時間が発生する．そこで数値実験では提案手法の計算時間と，階層化することで発生する無駄時間について評価を行う．

4.1 実験設定

顧客のリクエストデータとして，オープンデータとして公開されているニューヨーク市マンハッタン島のタクシーのトリップデータ [*1] を用いた．トリップデータに含まれる情報の内，乗車位置を出発位置，降車位置を目的地，乗車時刻を顧客が配車をリクエストした時刻とした．本実験では，リクエストデータ

*1 Brian, D. and Dan, W.:New York City Taxi Trip Data (2010-2013),https://databank.illinois.edu/datasets/IDB-9610843 アクセス日：2019/1/29

として 2013 年 5 月 3 日の 24 時間にマンハッタン島内で乗降車したデータを抽出し，1 時間毎に最適化した結果により評価を行った．本実験では，利用可能な総車両台数として 2013 年 5 月 3 日の各時間帯に少なくとも 1 人は客を乗せたタクシーの台数の 110%を用いた．これは，実際に客を乗せるために利用された台数に追加して，10%がリバランシングのために利用できると仮定した設定である．また最適化する際，マンハッタン島を均一な 3 種類メッシュ（500m，1km，2km）で分割し，各メッシュサイズでの隣接エリアまでの移動時間 Δt_{adj} はそれぞれ 3 分，6 分，12 分とした．各メッシュサイズで分割した際のエリアの数及び移動時間を表 1 に示す．

表 1: 各メッシュで分割時のエリア数及び隣接エリアまでの移動時間

	500-m mesh	1 km	2 km
N	261	79	26
Δt_{adj}	3 min.	6	12

提案手法を評価するために，階層数を 1 から 3 層まで変化させた時の計算時間を評価した．階層数が 1 の場合が従来法 [Iglesias 18] におおよそ対応する *2．階層数の場合の各層のエリアのメッシュサイズの組合せを表 2 に示す．整数計画問題を最適化するソルバとして Gurobi-8.5*3 を用い，Intel Core-i7 CPU X980@3.33GHz 及び 46GB のメモリを有するコンピュータにより最適化計算を行った．

表 2: 比較手法

手法	エリアのメッシュサイズ
NERO(1 階層)	(500m)
NERO(2 階層)	(1km, 500m)
NERO(3 階層)	(2km, 1km, 500m)

4.2 実験結果

提案法の階層数と計算時間の関係を図 1 に示す．この図から提案法は 2 層，3 層と深くするに従い計算時間を短縮することができ，3 階層にすることで階層化しない場合に比べ計算時間を約 100 分の 1 にすることができた．

また，提案法の階層数と車両 1 台当りのリバランシングに費やす平均時間を図 2 に示す．この図から階層数を増やすにつれ，1 台当りのリバランシングに費やす移動時間が増加しており，3 階層の場合には階層化しない場合に比べ，リバランシングに費やす時間が約 3 分増加していることが分かった．

5. 結論

本研究では，より効率的な Mobility-on-Demand サービスの実現を目指し，サービスのエリアの数が増加により柔軟に対応できる手法を提案した．我々は，まず総車両台数が時々刻々変化する場合のリバランシング問題を整数計画問題として定式化した．次に，サービスエリアを粗い粒度で分割したエリアに対して最適化した後，その結果に基づきより詳細な粒度のエリアに対して最適化を行う階層的なリバランシング法を提案した．また，提案手法の有効性を検証するために，ニューヨーク市マンハッタン島のタクシートリップデータを用い，階層数と計算時間及び，車両一台当りのリバランシングに費やす時間について評価した．その結果，提案法は階層数を増やすことで計算時間を指数関数的に削減することが出来ることを確認した．しかしながら，階層数を増やすことでリバランシングに費やす時間が増加することも分かった．今後は，より広いサービスエリアに対して提案法の有効性を検証していく予定である．

*2 総車両台数に関する制約（1d）が追加されている点が異なり，制約（1e），(1e) は 1 階層の場合常に 0 となるため無視される．

*3 Gurobi Optimization, LLC, Gurobi Optimizer Reference Manual,2018,http://www.gurobi.com アクセス日:2019/1/29

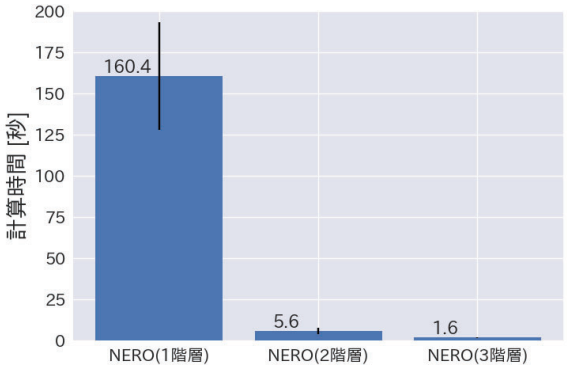


図 1: 最適化にかかる計算時間

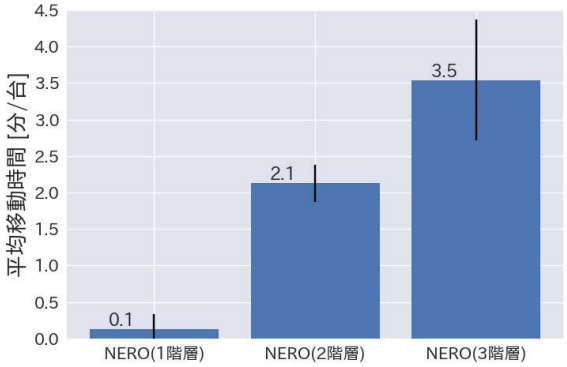


図 2: 一台当りのリバランシング費やした平均時間

参考文献

[Bei 18] Bei, X. and Zhang, S.: Algorithms for Trip-Vehicle Assignment in Ride-Sharing, in *AAAI Conference on Artificial Intelligence* (2018)

[Dickerson 18] Dickerson, J. P., Sankararaman, K. A., Srinivasan, A., and Xu, P.: Allocation Problems in Ride-Sharing Platforms: Online Matching with Offline Reusable Resources, in *AAAI Conference on Artificial Intelligence* (2018)

[Iglesias 18] Iglesias, R., Rossi, F., Wang, K., Hallac, D., Leskovec, J., and Pavone, M.: Data-Driven Model Predictive Control of Autonomous Mobility-on-Demand Systems, in *IEEE International Conference on Robotics and Automation (ICRA)*, pp. 1–7 (2018)

[Pavone 11] Pavone, M., Smith, S. L., Frazzoli, E., and Rus, D.: Load Balancing for Mobility-on-Demand Systems, in *Robotics: Science and Systems VII (RSS)* (2011)

[Pelzer 15] Pelzer, D., Xiao, J., Zehe, D., Lees, M. H., Knoll, A. C., and Aydt, H.: A Partition-Based Match Making Algorithm for Dynamic Ridesharing, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 5, pp. 2587–2598 (2015)

[Spieser 16] Spieser, K., Samaranayake, S., Gruel, W., and Frazzoli, E.: Shared-vehicle Mobility-on-Ddemand Systems: A Fleet Operator's Guide to Rebalancing Empty Vehicles, *TRB 2016 Annual Meeting*, pp. 0–16 (2016)

[Zhang 16] Zhang, R. and Pavone, M.: Control of Robotic Mobility-On-Demand Systems: a Queueing-Theoretical Perspective, *The International Journal of Robotics Research*, Vol. 35, No. 1-3, pp. 186–203 (2016)

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

異種車両連携を考慮する経路計画における整数計画法

Integer Programming for Cooperative Route Optimization

大滝啓介 *1 Keisuke Otaki　早川敬一郎 *1 Keiichiro Hayakawa　小出智士 *1 Satoshi Koide　大社綾乃 *1 Ayano Otaki　西 智樹 *1 Tomoki Nishi

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

Cooperation among vehicles is essential for MaaS. In previous work, we developed a new cooperation concept, named delegation, using different types of vehicles. Further, we formalized a new route optimization problem enabling delegation. A fundamental approach to solve the problem is to define IP instances representing the optimization problem, and to solve the instances using a modern IP solver (e.g., Gurobi). However, the performance of solver-based methods highly depends on the instances and a subset of decision variables is not fully-used in optimization. In this paper, we develop a new IP instance of the optimization problem, evaluate them through numerical experiments, and discuss the instances and their features.

1. はじめに

交通や物流における社会問題は，都市化に伴って悪化することが予測されている *1．これらの社会問題に対処するため，既存の交通システムを有効活用する必要があり MaaS*2 が注目されている．MaaS では様々な意思決定の最適化が必要となり，例えばライドシェアでは，車両の待機場所や顧客への訪問経路，相乗り方法等を最適化することで，車両移動コストや顧客の待機時間を削減できると期待されている [Agatz 12, Ma 15, Furuhata 13]．同時に様々な機能を持った車両 (**異種車両**) が連携することで，新しいサービスが創発されることが期待されている [Hietanen 14]．我々は特に車両の経路計画に着目し，車両が取るべき経路の最適化について議論する．本稿では配送サービスを例として，サービス供給車両が出発地から目的地へ移動する際に利用する経路を最適化する問題を扱う．

図 1 にコンセプト図を示す．個別のモビリティが独立して配送サービスを行う場合，図 1(1) に示すように，最短経路によって移動コストを最小化できる．一方で図 1(2) に示すように**隊列** (platoon) を形成して移動経路を共有する場合，燃料消費が削減されることが知られている [Bonnet 00]．このような燃料消費削減効果を想定した経路計画は**車群経路計画** (vehicle platooning problem; VPP) と呼ばれ，整数計画法 (Integer programming; IP) を用いる解法や近似解法が研究されている [Larsson 15]．また似た目的関数を想定したグラフ上の最適化問題に対する手法を転用することもできる [Takise 16]．VPP では単一種の車両の経路を最適化するため，MaaS のように異種車両が存在する状況のモデルとして表現力が十分ではない．例えば図 1(3) に図示するように，ドローンがトラックに格納されて移動する配送などの異種車両連携を扱うためには，VPP よりも一般的なモデルが必要となる．

我々はこれまで，隊列を一般化させた**委譲** (delegation) という概念を定義し，委譲によって異種車両連携を考慮する最適化問題として，*Two-modal palette platooning problem* (2MP^3) と呼ばれる最適化問題のクラスについて議論してきた [Otaki 19]．この最適化問題は NP 困難であるため，大規模な問題を得ためには発見的解法が重要となる．しかし発見的解法自体を評価するために，厳密解が必要になる場面も多くある．そのため既存の研究では整数計画ソルバーを利用し，小規模な問題について厳密解を求め，発見的解法による解と比較することで，手法の性能を議論してきた．しかし既存の IP インスタンスは

(a) スケーラビリティが低く，小規模な問題であっても解けない場合がある

(b) 目的関数が限定的であり，決定変数に無駄がある

(c) 解に冗長な閉路を含むことがあり，最適値を求められない場合がある

という 3 つの問題があった．本稿では，2MP^3 に関する発見的解法を議論するための厳密解をより高速に，大規模な問題に対して与えることを目的として，VPP における既存研究 [Larsson 15] に基づいて，新たな IP インスタンスやその拡張の例を新しく提案し，数値実験を行って性質や性能を評価する．

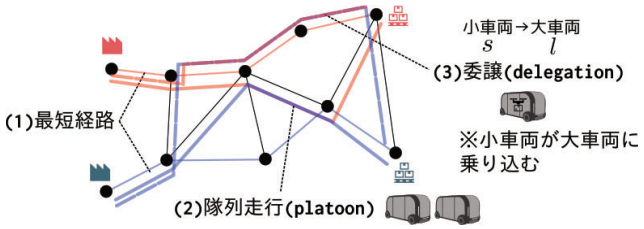


図 1: 経路計画のコンセプト比較: (1) は最短経路 (2) は隊列走行 (3) はコスト委譲による乗り込み型の連携走行

2. 準備

自然数 $n \in \mathbb{N}$ に対して $[n] = \{1, \cdots, n\}$ とし，記号 $\langle \cdot \rangle$ はリストを，演算子 $+$ でリストの連結演算を表す．

2.1 グラフと異種車両リクエスト

本稿では $G = (V, E, w)$ を単純な重み付き有向グラフとする．辺 $(u, v) \in E$ の重み $w(u, v)$ は単純に $w_{u,v}$ と記す．

連絡先: 大滝啓介，豊田中央研究所，愛知県長久手市横道 41-1，otaki@mosk.tytlabs.co.jp

*1　都市化について，例えば World Urbanization Prospects: The 2014 Revision Population Database が参考になる．

*2　Mobility as a Service

2 頂点 $s,t \in V$ 間の経路 $p_{s,t}$ を頂点の列として $p_{s,t} = \langle v_1, v_2, \ldots, v_{k+1} \rangle, v_1 = s, v_{k+1} = t, (v_i, v_{i+1}) \in E$ $(1 \leq i \leq k)$ と表し，i 番目の頂点 v_i を $p_{s,t}(i)$ で表す．また 2 頂点 s,t 間の全ての経路の集合を $\Pi(s,t)$ で表し，特に最短経路を $\pi(s,t) \in \Pi(s,t)$ です．なお最短経路 $\pi(s,t)$ とは，経路に沿った辺重みの総和で定義される距離 $d(s,t) = \sum_{1 \leq i \leq k} w(v_i, v_{i+1})$ が最小となる経路である．

本稿ではトラックなどを想定した「大車両」と，小型の配送車両やドローンを想定した「小車両」の二種類の車両を扱う．これらの車両はいずれも移動サービスを提供し，図 1 で例示したように**小車両は大車両に乗り込む**ことができるといった，特殊な連携を可能とする．大車両と小車両は，それぞれ N_L 台と N_S 台存在し，識別子 $l \in [N_L]$ と $s \in [N_S]$ で表す．個別の車両は，移動サービスを表現する単一の**リクエスト** $r = (o, d) \in V \times V$ を持つ．ある経路 p が $p \in \Pi(o,d)$ であるとき，p は r を達成する充足経路と呼ぶ．本稿では，与えられた全ての車両に対する充足経路の集合を，問題の解と呼ぶ．以上の定義より連携を考慮しない場合には，最短経路を移動することで解のコストを最小化することができる．

2.2 単一車種を想定した経路計画 VPP

車両連携を考慮する場合の基本的な考え方は，最短経路を利用する場合と比較し，複数の車両が連携を行うことが移動コストに対して利益を生む（つまり**移動コストを削減する**）ような目的関数を用いて経路計画を行うことである．単一車両を想定する VPP においては，以下の式に応じて移動コストを低減するような目的関数が利用されている [Larsson 15]．解 $\mathcal{P}$ のコスト $c(\mathcal{P})$ を，パラメータ η $(0 < \eta < 1)$ を用いて

$$
\begin{aligned}
c(\mathcal{P}) &= \sum_{(u,v) \in E} w_{u,v} g_{u,v} \\
g_{u,v} &= (\mathcal{P} \text{ 中の車群の先頭車両台数}) \\
&\quad + \eta \times (\mathcal{P} \text{ 中の車群の後続車両台数})
\end{aligned} \tag{1}
$$

と定義する．式 (1) によれば，辺 $(u,v) \in E$ を可能な限り車群を構成して通過することで，本来 $w_{u,v}$ が必要だった移動コストが $\eta w_{u,v}$ に削減される．

2.3 複数車種を想定した経路計画 2MP^3

最適化問題 2MP^3 は，図 1(3) で想定した用に，大車両が小車両に乗り込むことで，移動コストを 0 と見なす連携に対する経路計画である．式 (1) を参考にして定義された式 (2) を目的関数に用いている [Otaki 19].

$$
\begin{aligned}
c^{(\mathrm{del})}(\mathcal{P}) &= \sum_{(u,v) \in E} w_{u,v} g_{u,v}^{(\mathrm{del}),L} \\
g_{u,v}^{(\mathrm{del}),L} &= (\text{車種 } L \text{ の走行台数}) \\
&\quad + (\text{どの } L \text{ にも搭乗していない } S \text{ の台数})
\end{aligned} \tag{2}
$$

以下に形式的な経路最適化問題を定義する．

問題 1 (2MP^3 [Otaki 19]). 小車両と大車両の移動リクエストがそれぞれ $\mathcal{R}_S = \{r_1^{(S)}, \cdots, r_{N_S}^{(S)}\}$ と $\mathcal{R}_L = \{r_1^{(L)}, \cdots, r_{N_L}^{(L)}\}$ として所与とする．2MP^3 とは容量制約 $Q_l^{(LS)}$ の下で，式 (2) を最小化する解 $\mathcal{P}_T = \{P_i \mid i \in [N_T], P_i \in \Pi(o_i^{(T)}, d_i^{(T)})\}$ $(T \in \{S, L\})$ と，乗合いの組合せ $\mu = \{(s, l, u, v) \mid s \in [N_S], l \in [N_L], u, v \in V\}$ を求める問題である．集合 μ は車両間の連携を表す **(コスト委譲) 割当**と呼ぶ．もし $(s, l, u, v) \in \mu$ であるとき，(u,v) の移動の際に s は l に積載されていると解釈する．

3. 2MP^3 のための整数計画法

本章では既存の IP インスタンスを解説し，次にこれを改良した IP を提案・議論する．

3.1 既存の IP インスタンス IP-NA [Otaki 19]

既存の IP インスタンスとして以下の式が提案されている．本稿ではこの既存インスタンスを IP-NA と呼ぶ．インスタンス IP-NA では決定変数として，大/小車両が辺 $(u,v) \in E$ を通過するかどうかを表す変数 $f^{(L)}, f^{(S)}$ と，2MP^3 に定義される割当 μ を表す変数を最適化する．目的関数は移動コストの最小化である．以下の式では，添字は $s \in [N_S], l \in [N_L], T \in \{S, L\}$, $(u,v) \in E$ である:

$$
\min_{f^{(L)}, f^{(S)}, \mu} \sum_{(u,v) \in E} w_{u,v} g_{u,v}^{(\mathrm{del}),L} \tag{3}
$$

subject to

$$
g_{u,v}^{(\mathrm{del}),L} = \sum_{l \in [N_L]} f_{u,v,l}^{(L)} + \sum_{s \in [N_S]} \phi_{u,v}^{s} \tag{4a}
$$

$$
\phi_{u,v}^{s} = \prod_{l \in [N_L]} (1 - \mu_{u,v}^{s,l}) \times f_{u,v,s}^{(S)} \tag{4b}
$$

$$
2\mu_{u,v}^{s,l} \leq f_{u,v,s}^{(S)} + f_{u,v,l}^{(L)} \tag{4c}
$$

$$
\sum_{l \in [N_L]} \mu_{u,v}^{s,l} \leq 1, \sum_{s \in [N_S]} \mu_{u,v}^{s,l} \leq Q_l^{(LS)} \tag{4d}
$$

$$
\sum_{v} f_{u,v,i}^{(T)} - \sum_{v} f_{v,u,i}^{(T)} = \begin{cases} 1 & \text{if } u = o_i^{(T)} \\ -1 & \text{if } u = d_i^{(T)} \\ 0 & \text{o/w} \end{cases} \tag{4e}
$$

$$
f_{u,v,l}^{(L)}, f_{u,v,s}^{(S)}, \mu_{u,v}^{s,l} \in \{0, 1\} \tag{4f}
$$

なお i は $T = L$ の場合には $[N_L]$ を，$T = S$ の場合には $[N_S]$ を動く車両の識別子である．制約 (4a) は式 (2) に対応する．制約 (4b) は単独で移動する小車両を規定する．制約 (4c) では相乗り $\mu_{u,v}^{s,l} = 1$ は l と s が共に (u,v) を移動している場合に限ることを意味する．制約 (4d) は乗り込む割当の排他性と容量制約を示す．制約 (4e) は解となる経路の条件を示す．制約 (4f) は決定変数の値域を制約している．

3.2 改良 IP インスタンス IP-A

前節の IP-NA は，車両同士の組合せに関する決定変数 μ を導入しているため表現力が高いが，一方で目的関数に μ が出現しないため冗長であり，結果として大規模な問題に対してパフォーマンスが低下する．そこで式 (2) を直接表現するような改良型の IP インスタンスとして IP-A を提案する．インスタンス IP-A では，IP-NA と同様に経路 $f^{(L)}, f^{(S)}$ を決定変数として持ち，新しい整数変数として $z_{u,v}$ を導入し辺 (u,v) を通過する際に乗り込む小車両の台数として最適化する．以下に追加される制約を示す．

$$
0 \leq z_{u,v} \leq \min \left(\sum_{l \in [N_L]} Q_l^{(LS)} f_{u,v,l}^{(L)}, \sum_{s \in [N_S]} f_{u,v,s}^{(S)} \right)
$$

以上の制約と決定変数により，換算量 $g_{u,v}^{(\mathrm{del}),L}$ を

$$
g_{u,v}^{(\mathrm{del}),L} = \sum_{l \in [N_L]} f_{u,v,l}^{(L)} + \sum_{s \in [N_S]} f_{u,v,s}^{(S)} - z_{u,v} \tag{5}
$$

として再定義する．式 (5) は，式 (2) に定義された車両の台数を直接計算するような IP になっている．

表 1: IP インスタンスの比較

name	種類	変数	特徴	変数/制約数
IP-NA	01-IP	経路 $f^{(L)}, f^{(S)}$ 組合せ μ	非匿名	多い
IP-A	IP	経路 $f^{(L)}, f^{(S)}$ 乗込台数 z	匿名	少ない

3.3 冗長な閉路の除去

車両が乗り込むことで移動コストが 0 と見なされる性質から，インスタンス IP-NA および IP-A は，いずれも冗長な閉路を含むことがあった．このような巡回路を避けるには，例えば MTZ 制約などを利用することができる [Miller 60].

3.4 IP の特徴比較

提案した手法の比較結果を表 1 に示す.

定義より，IP-NA における全ての決定変数は二値変数であるため，これは 01-IP である．一方で，IP-A においては，辺 $(u, v) \in E$ を移動する際に大車両に乗り込む小車両の台数 z を用いて容量制約を考慮しているため，一般の IP である．

次に IP インスタンスの決定変数から区分けされる特徴について述べる．インスタンス IP-NA では，割当 μ によって,「ある辺 $(u, v) \in E$ において，どの小車両 s が，どの大車両 l に乗車」に関する情報を全て得ることができる．我々はこのような状況を (連携が) **非匿名**であると呼んでいる．一方で IP-A では，式 2 に基づいて,「どの大車両にも乗車していない小車両の台数」を，変数 z を用いて直接最適化している．つまり，どの大車両が小車両を運搬しているかに関する情報を得ることができない．そのため我々はこのような状況を（連携が）**匿名**であると呼んでいる．VPP に対する既存の IP インスタンスは匿名なインスタンスとなっている [Larsson 15].

4. 数値実験による IP インスタンスの検証

提案した IP インスタンスを人工グラフ上のランダムなリクエスト群に対して適用し，評価と考察を行う．実験は Intel Core i7-3770K (3.50GHz) の CPU，32GB のメモリ，Gurobi 7.5.2, Python 3.5.2，Julia 0.6 を備えた PC を用いて実施した.

実験では $(N_L, Q_l^{(LS)})$ のラベルを利用して問題例を表現する．例えば $(N_L, Q_l^{(LS)}) = (2, 3)$ は，大車両が 2 台，それぞれの容量が 3 台分であり，小車両は 6 台 $(= 2 \times 3)$ 用意する問題を意味する.

4.1 IP インスタンス同士の計算時間比較

我々が提案した IP インスタンスを，人工データを用いて評価する．まず頂点位置にノイズを付与した 10×10 の格子グラフを作成し，グラフ頂点をランダムに選択してリクエストと見なして実験を行う．問題例として $(N_L, Q_l^{(LS)}) \in [2] \times [4]$ となる例をそれぞれ 30 問作成して，解を得るために必要だった計算時間の平均を求める．図 2 に結果を図示する．横軸は問題ラベル，縦軸は計算時間の対数である.

今回のランダムなリクエストに対しては，2 つの IP インスタンスを比較しても，計算時間に大きな差は見られなかった．一つの理由として，IP ソルバー Gurobi [Gurobi Optimization, LLC 18] が IP インスタンスを事前処理する際に，IP-NA において一見冗長に見える変数や制約を除去し，結果として似たような問題を解くことになっていると予測できる.

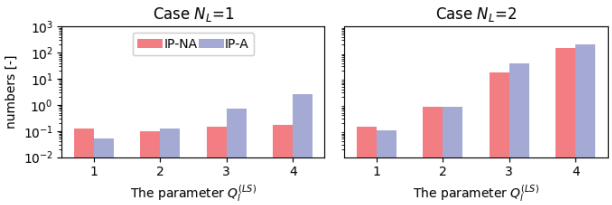
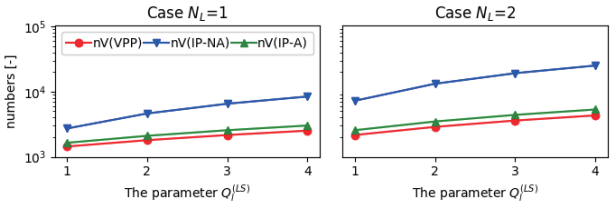
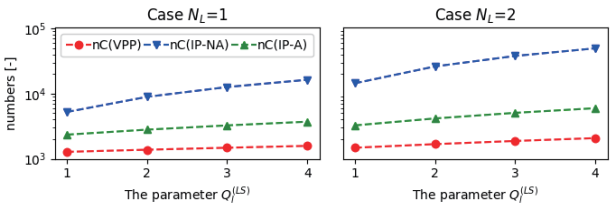


図 2: IP-NA と IP-A の計算時間比較



(a) 変数数 nV



(b) 制約数 nC

図 3: VPP，IP-NA，および IP-A 変数数と制約数の比較

4.2 IP インスタンス同士の変数・制約数比較

次に IP で問題例を表現した際の，IP インスタンス自体を比較し，表 1 で述べた変数/制約数の比較が正しいかどうかを確認する．インスタンスの比較を行うため，前節と同じく 10×10 のランダムな格子グラフを作成した．また $(N_L, Q_l^{(LS)}) \in [2] \times [4]$ の問題例を利用し，それぞれを IP インスタンスで表現した際の変数数と制約数を比較した．比較する際に，参考として元となった VPP の IP インスタンス [Larsson 15] を同時に計測した．図 3 に結果を示す．結果から分かる通り，図 3a に示す変数数や図 3b に示す制約の数は非匿名の IP インスタンス IP-NA は 10^1 個程度のオーダで多いことが分かる．一方で匿名の IP インスタンス IP-A や既存の VPP インスタンスはそれらの数が小さく，増加も緩やかである.

5. 拡張

IP インスタンス IP-NA 及び IP-A はいずれも最低限の目的関数となっているため，これを元にして様々な目的関数や所望の性質を加え拡張することができる.

5.1 グラフ G のトポロジが変化する場合

大車両がグラフ $G_L = (V_L, E_L)$ を，小車両がグラフ $G_S = (V_S, E_S)$ を移動する場合，IP を適用するためのグラフ $G = (V, E)$ を次のように作成する．まず頂点集合 $V = V_L \cup V_S$ と辺集合 $E = E_L \cup E_S$ を設定する．制約式 (4e) における経路 $f^{(L)}$ と $f^{(S)}$ については，それぞれの辺集合 E_L と E_S 上で定義する．制約式 (4a) において換算量 $g_{u,v}$ を定義する際には，辺集合 E を $E_{L\cap S} \cup E_{L\setminus S} \cup E_{S\setminus L}$ として共通の辺と片方にのみ移動可能な辺を集合として分離し，$(u, v) \in E_{L\cap S}$ であれば

式 (4a) を，そうでなければ $f^{(L)}$ もしくは $f^{(S)}$ によって単に経路を計上すれば良い．

5.2 辺や頂点の通過時間を明示的に扱う場合

本稿では問題を簡単にするため，時間情報は扱わず，静的な問題として異種車両連携経路計画を定義している．例えば既存モデルである VPP では，通過時間に相当する量を IP インスタンスに導入することで，時間を考慮して同じ辺を移動する経路計画を可能にしている [Larsson 15]．また時拡大ネットワークを用いて時間情報を静的グラフに表現することで，間接的に時間情報を扱うことができる．

5.3 組合せ μ を利用して目的関数を拡張する場合

既存の IP インスタンスである `IP-NA` は，車両連携を組合せ μ として明示的に扱うことができるため，スケーラビリティに劣る分，モデルとしての表現力が高い．つまりある辺 $(u, v) \in E$ にといて，$\sum_{s\in[N_S]} \mu^{s,l}_{u,v} \geq 1$ である車両 $l \in [N_L]$ は，車両連携の委譲先になっている大車両であると判定される．これを利用することで，例えば「少なくとも k 回以上は，どの大車両もドローンを載せる」といった負荷を均等にする制約などを記述することが出来る．

6. 結論

本稿では，異種車両の経路を最適化する問題に利用される整数計画法の性質とスケーラビリティについて実験を通じて議論した．また目的関数や制約を拡張することで，基本となる IP インスタンスを拡張していくことができることを議論した．今後は具体的な MaaS アプリケーションを想定した検証を行い，整数計画法の知見を利用した高度な発見的解法の設計を行う．

参考文献

[Agatz 12] Agatz, N., Erera, A., Savelsbergh, M., and Xign, W.: Opimization for dynamic ride-sharing: A review, *EJOR*, Vol. 223, pp. 295–303 (2012)

[Bonnet 00] Bonnet, C. and Fritz, H.: Fuel consumption reduction in a platoon: Experimental results with two electronically coupled trucks at close spacing, Technical report, SAE Technical Paper (2000)

[Furuhata 13] Furuhata, M., Dessouky, M., Ordóñez, F., Brunet, M.-E., Wang, X., and Koenig, S.: Ridesharing: The state-of-the-art and future directions, *TRP-B*, Vol. 57, pp. 28–46 (2013)

[Gurobi Optimization, LLC 18] Gurobi Optimization, LLC, : Gurobi Optimizer Reference Manual (2018)

[Hietanen 14] Hietanen, S.: Mobility as a service, pp. 2–4 (2014)

[Larsson 15] Larsson, E., Sennton, G., and Larson, J.: The vehicle platooning problem: Computational Complexity and Heuristics, *TRP-C*, Vol. 60, pp. 258–277 (2015)

[Ma 15] Ma, S., Zheng, Y., and Wolfson, O.: Real-Time City-Scale Taxi Ridesharing, *IEEE Transactions on Knowledge and Data Engineering*, Vol. 27, No. 7, pp. 1782–1795 (2015)

[Miller 60] Miller, C. E., Tucker, A. W., and Zemlin, R. A.: Integer programming formulation of traveling salesman problems, *Journal of the ACM (JACM)*, Vol. 7, No. 4, pp. 326–329 (1960)

[Otaki 19] Otaki, K., Koide, S., Okoso, A., and Nishi, T.: Cooperative Routing with Heterogeneous Vehicles, in *to appear in AAMAS2019 (Main Track Extended Abstract)* (2019)

[Takise 16] Takise, K., Asano, Y., and Yoshikawa, M.: Multi-user routing to single destination with confluence, in *Proc. of the 24th ACM SIGSPATIAL*, pp. 72:1–72:4 (2016)

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

事例検索と調査テーマ推薦に基づく ビジネス戦略支援 AI

A Decision Support AI for Business Operations via Information Retrieval and Query Suggestion

森下 皓文 Terufumi Morishita　尾崎 太亮 Hiroaki Ozaki　佐藤 美沙 Misa Sato　是枝 祐太 Yuta Koreeda　柳井 孝介 Kohsuke Yanai

日立製作所 研究開発グループ
Research & Development Group, Hitachi, Ltd.

We developed a system that supports decision making in business operations, which interactively assists iterative investigations. For example, for a decision "Should we buy Hitachi's stock?", the user may first query "What is the business domain of Hitachi?" to which the system responds "Electric power industry". This encourages the user to query "How big is the power industry?", and so on. Our system consists of two modules. The document retrieval module extracts pieces of texts given a "relation query" which consists of entities (e.g.. "Hitachi", "Electric power industry") and their relationship (e.g.. "be engaged in"). The query suggestion module proposes "relation queries" based on the previous query and the response. We developed a set of extraction rules for each of nine relationships in business domain to implement the two modules. We evaluated our rules in terms of precision of document retrieval and obtained significant gains over the baselines.

1. ビジネス上の意思決定支援

筆者らの研究グループでは，電子化されたテキストデータを意思決定支援に活用することを目的として，ディベートをする人工知能（以下ディベート型 AI）を開発している [Sato 15]. これを活用し，ビジネスにおける意思決定を支援するためのシステムを開発した．経営者の意思決定を考えれば分かるように，ビジネス上の意思決定は組織に対して大きな影響を与えるが，限られた時間の中で可能な限り正確に行わなければならない．このため，ディベート型 AI によって様々な観点での意見を自動で提示することが，有益である．本発表ではこのシステムのデモンストレーションを行う．

ディベート型 AI は，論題を入力として，経済・社会・科学などの "一般的な観点" に基づく事例をテキストデータから収集し，賛否意見として出力するシステムである。例えば「カジノを推進すべきか」という論題に対しては，経済の観点から「カジノは経済を活性化させる」といった事例や，社会の観点から「カジノによって犯罪が増加する」といった事例を，提示することができる。これらの観点は，事前に設定することができる．

ディベート型 AI をビジネス上の意思決定支援に活用するにあたり，前述の "一般的な観点" に加えて "ビジネス上の観点" で事例を収集する必要がある．更に，意思決定までの予備調査として，以下に例示するような一連のプロセスを支援する必要がある．

「日立に投資すべきか？」という意思決定の予備調査は以下のように行われるであろう：

1. 「まずは，日立が最近参入した事業を調べよう.」
   ⇒「日立は太陽光発電に参入したようだ.」
2. 「それでは，太陽光発電のニーズを調べよう.」
   ⇒「発展途上国のニーズが増えている.」
3. 「それでは，途上国市場の今後の成長度合いを調べよう.」
   ⇒ 「...」

連絡先: 森下 皓文，株式会社 日立製作所，〒 185-8601 東京都国分寺市東恋ヶ窪一丁目 280 番地，042-323-1111，terufumi.morishita.wp@hitachi.com

この例から分かるように，「日立」「太陽光発電」「発展途上国」という調査対象を，「参入する」「ニーズがある」といったビジネス上の調査観点によって結びつけながら，新規の予備調査テーマ（「それでは，太陽光発電のニーズを調べよう.」）を次々と創案していく必要がある．よって，この調査テーマ創案を支援できることが望ましい．

そこで，"ビジネス上の観点" に基づいて関連事例を検索する機構と，予備調査プロセス支援のために新規調査テーマを推薦する機構を作成した．両機構の中核となるのは，調査対象間の関係性を特定するための，関係性抽出技術である．そこで，ビジネスドメインで重要な関係性を 9 つ定義し，関係性を特定するためのルールを作成した．また，これらの関係性を用いた事例検索の精度を計測することにより，効果を確認した．

2. 調査フローとシステム構成

2.1 調査フローとシステム構成

本システムが対象とする調査フローは，調査テーマの提案と，調査テーマに応じた事例の収集とを繰り返すことで，意思決定に有用な情報を探索的に収集するものである．

これを支援するための中核コンポーネントとして，調査テーマの推薦機構と，関連事例検索機構を，構築した．具体的な調査フローと共に図 1 に示す．

1. ユーザがテーマを考え，システムに入力する（図中①）.（例:「日立に投資すべきか.」
2. ユーザは，テーマに応じた予備調査を開始する．システムは予備調査テーマを推薦する（図中②）.（例:「日立が参入した事業を調べますか？」）
3. ユーザは予備調査テーマを選択する（図中③）．システムは，選択された予備調査テーマに関連する事例を検索しユーザに提示する（図中④）.（例:「日立は太陽光発電に進出する.」）
4. また，システムは，取得された事例を元に，次の予備調査テーマを推薦する（図中⑤）.（例:「太陽光発電のニーズを調べますか？」）

2〜4 の調査サイクルを繰り返すことにより情報を蓄積し，意思決定に至る．

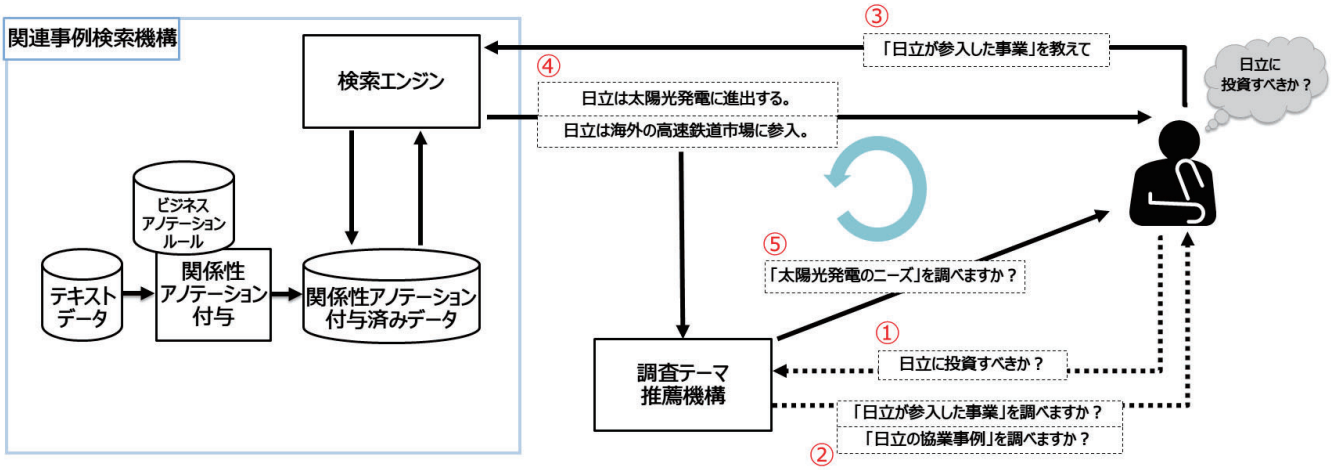


図 1: 本システムのコンポーネントと，ユーザーの調査フローとの関係

2.2 調査テーマに応じた関連事例の検索

2.2.1 ディベート型 AI における関係性抽出

調査テーマに応じた関連事例を検索するために，ディベート型 AI の中核技術である関係性抽出技術と，関係性に基づくテキスト検索技術を活用する．

関係性抽出技術では，構文パターンと述語辞書に基づくルールによって，テキスト中で述べられた関係性を特定する [Yanai 17]．例えば「カジノは経済を活性化する」というテキストでは，「カジノ」という主体が，「経済」という客体に対して，「Positive な影響を与える」という関係性が述べられている．この関係性を特定するために，「x は y を活性化する」といった構文パターンを事前に用意しておき，入力テキストの構文と照合することで，主体 x と客体 y を特定する．また，Positive な影響を表す「活性化する」「促進する」「増やす」等の述語を含む辞書を構築する．辞書中の語句に全てに関して照合することにより，述語表現の揺れを吸収することができる．

関係性と主体・客体の情報（関係性情報）だけでなく，関係性情報を述べた元テキストにも，重要な情報が含まれる．そこで，関係性情報を元テキストに紐づけて検索エンジンへと登録する（この操作を，テキストへの “関係性アノテーションの付与” と呼ぶ）．これにより，関係性情報を指定して元テキストを検索する関係性検索が可能となる．例えば，主体を「カジノ」，関係性を「Positive な影響」と指定して検索することで，「カジノは経済を活性化する」といったテキストが取得される．元テキストの検索機能を持つことが，Virtuoso のような RDF ストアとの違いである．

ディベート型 AI では，主体が客体に対して「Positive/Negative な影響を与える」という影響関係 [佐藤 16] が重要となる．この関係性を利用して，「カジノは経済を活性化する」というように，議題語（カジノ）による影響を述べたテキストを検索し，賛否意見として提示する．

ビジネス上の意思決定においても，影響関係による検索は有用であると考えられる．影響関係で表された「日立は IoT 事業を行う会社を設立する.」といった事例を取得できるからである．しかし，次の問題が存在する．

まず「企業と企業が協業する」というように，影響関係ではない重要な関係性が存在する．

次に，ビジネスにおける意思決定支援では，単一観点での事例検索が重要である．複数の観点を含む事例が取得された場合，ユーザ側の追加作業として，不要な観点を述べた事例の除去と，事例を観点毎に仕分け直すこと，が必要となる．結果として，調査の効率が著しく損なわれる．影響関係は，ビジネス上有用でない観点まで含めて，複数の観点を含んでしまっている．

そこで，ビジネス上重要で，粒度が小さく単一の観点を表せるような関係性を定義し，これらの構文パターン・述語辞書を作成した．

2.2.2 ビジネスドメイン関係性アノテーション

まず，ビジネスにおいて重要な存在である「事業主体」や「事業分野」等のエンティティ間の関係性を 5 つのグループに類型化した．次に，これら関係性グループにぶら下がる形で，実際の関係性を合計 9 つ定義した（表 1）．

例えば 3 行目（enter(x,y)）に着目する．1 列目から関係性グループの意味が「（企業のような）事業主体が事業を行う」であることが分かる．また，3・4 列目から，実際の関係性アノテーションは「事業主体が新規事業に参入する」と明示的に述べたテキストに付与される，と分かる．

2.3 調査テーマ推薦機構

システムが推薦調査テーマを構築する際に利用できる情報として，ユーザが選んだ調査テーマの履歴や，取得された事例の履歴，また，検索対象となる文書集合の情報 (例：文書間の類似度) 等が挙げられる．2.1 節で述べた調査フローを支援するには「ユーザが直近調べていること」に関係する情報が最も重要である．そこで，「直前の調査テーマ」と「ユーザが注目中の事例」から推薦クエリを構築する．

本システムでは，調査テーマと，関係性検索のクエリとが一対一で紐付けられている．例えば「日立が手がける事業を調べる」という調査テーマは，enter（日立, ●）というクエリに対応する（● は，語句の指定が無いでことを表す.）．

「直前の調査クエリ」と「ユーザが注目中の事例」を入力とし，「推薦クエリ」を出力とする遷移テーブルを表 2 に作成した．各行が 1 つの遷移ルールを表す．ユーザが現在調査中のクエリ（1 列目）と，ユーザが興味を持ったエンティティ（2 列目）から，推薦クエリ（3 列目）を導出する．

遷移ルールは，2.2.2 項で定義した関係性グループの間に定義されている．粒度の大きな関係性グループ間の遷移という形で予備調査の大域的な方向を定めつつ，より粒度の小さい単一観点での関係性検索によって有用な事例情報を提供することができる．また，遷移ルールを変更することなしに，新たな観点

表 1: ビジネスドメイン 関係性アノテーション.

関係性グループ 略記	関係性グループ 意味	関係性アノテーション 略記	関係性アノテーション 付与条件	エンティティ
SERVE(x,y)	事業主体が，事業を 行う.	serve(x,y)	x が y という事業を営んでいる.	x: 事業主体 y: 事業分野
		supply(x,y)	x が y を実際に売る・受注する. 実際に市場で取引がなされている.	x: 事業主体 y: 事業分野
		enter(x,y)	x が y という新しい事業を立ち上げる、 あるいは、y から撤退する.	x: 事業主体 y: 事業分野
COLLABORATE(x,y)	事業主体と，企業が 協力する.	collaborate(x,y)	x と y が協業関係にある.	x: 事業主体 y: 事業主体
		agree(x,y)	x と y がビジネスに関して合意する.	x: 事業主体 y: 事業主体
		M_and_A(x,y)	x が y を買収・売却する.	x: 事業主体 y: 事業主体
PROMOTE_DOMAIN(x,y)	何らかの原因が，事業分野への 追い風となる	demand(x,y)	x が y に需要を持つ.	x: 消費者 y: 事業分野
SUPPRESS_DOMAIN(x,y)	何らかの原因が，事業の 向かい風となる	regulate(x,y)	x が y を規制する．x が y を解禁する.	x: 規制の原因. y: 事業分野
SUPPRESS_COMPANY(x,y)	何らかの原因が，事業主体への 向かい風となる	sanction(x,y)	x が y に対して、調査・警告・制裁等を行う.	x: 当局機関 y: 事業主体

を追加することも可能となる.

遷移ルール適用に係るフローを図 2 に示す.

1. ユーザが「日立が参入した事業を調べる（enter(日立,●)）」というクエリで事例を取得する（図中①）.
2. ユーザは，最も興味のある事例（「日立は太陽光発電に進出する」（enter(日立, 太陽光発電)））を選択する（図中②）. ユーザの興味は「太陽光発電」エンティティに向いている.
3. システムが次のクエリを推薦する．まず，enter(日立, 太陽光発電) を関係性グループで表すと SERVE(日立, 太陽光発電) である（図中③）.
4. 次に，適用可能な遷移ルールである表 2 中の 2 行目に従い，PROMOTE_DOMAIN(●, 太陽光発電) を導出する（図中④）.（SUPPRESS_DOMAIN も同様.）
5. 最後に，PROMOTE_DOMAIN グループの関係性である demand を用いて，「太陽光発電のニーズを調べますか？」demand(●，太陽光発電) を推薦する（図中⑤）.（SUPPRESS_DOMAIN も同様.）

3. 評価

3.1 システム構築

今回のシステムを構築するにあたり，関係性検索の対象となるテキストデータとして，新聞記事 230 万件 *1 と，RSS で取得した Web ニュース 60 万件を用いた.

これらのテキストデータに対して，2.2.2 項で述べたビジネスドメイン関係性アノテーション 9 種を付与した．計算機資源としてＣＰＵ 30 コア（60 スレッド）を用いて，およそ 4 日間の実行時間であった．なお，この処理は事前にバッチ実行できるので，実運用上の問題は生じない.

検索エンジンは Apache Solr*2 を用いた。

3.2 事例検索の精度評価

3.2.1 評価手順

本システムのような検索システムを評価する上で重要な指標として，応答速度等のユーザビリティ，検索の再現率・精度などが挙げられる.

システムの応答速度に関して，まず，関連事例検索の速度は，Apache Solr の速度に準じる．次に，調査テーマ推薦では，ユーザが選択した事例文へのアノテーション付与と遷移テーブルの参照のみを行うため，高速である．以上により，本システムの応答速度は十分に担保されていることが分かる.

次に，今回は網羅的な調査が難しいため，再現率の計測実験を行わなかった．再現率に関しては，[佐藤 16] が参考になる．佐藤らによれば，影響関係として同一な事例を述べた文のうち，構文パターン・述語辞書によって取得できる文は，全体の 8 %であった.

本システムを評価する上で重要な指標となるのは，図 1 中④での事例検索の精度である．これまでに述べてきたように，事例検索では，単一の観点に合致した事例を精度良く検索できる必要がある．更に，クエリ推薦では事例中のエンティティの情報を利用するので，事例が検索されるだけでなく，エンティティも精度良く特定される必要がある.

事例検索のクエリでは，エンティティのうちの片方が特定されており，もう片方が検索対象となる（例「日立が参入した事業を調べる」enter(日立,●)）.

そこで，エンティティを表す語句を複数サンプリングし，精度評価を行った：

$$\frac{1}{|S|}\sum_{w\in S} Precision(\text{enter}(w,\bullet)) \tag{1}$$

S はサンプル語句の集合，$|S|$ は集合の要素数を表す.

エンティティが事業主体の場合，企業名を日経一部上場企業から 20 社名を語句として選んだ．エンティティが事業分野の場合，日経一部のビジネスドメイン分類枠（計 35 種類）を利用し，分類枠に対して評価者が想起した語句合計 20 種類を使用した（例：「通信」-「スマートフォン」）.

enter(s,●) の場合の評価手順例を示す：

1. 事業主体エンティティとして「日立」を採用する.
2. enter（日立, ●）というクエリで事例を検索する.「日立は太陽光発電に進出.」といった事例が取得される.
3. 各事例に対して，その事例が表 1 記載の関係性アノテーション付与条件と，エンティティ条件を満たすかを確認する．今回の条件は「事業主体が新規事業に参入する」なので，満たす.

ベースラインとして，影響関係アノテーションも評価した.

3.2.2 結果

表 3 に結果を示す．表中の各列が，1 つの事例検索タスクを表す．例えば enter(s,●) は，enter という関係性に関する事例検索タスクであり，事業主体 s をサンプリング語句で固定した上で，事業ドメインを検索するタスクである.

*1 毎日新聞記事データ集 91〜2015 年版
http://www.nichigai.co.jp/sales/mainichi/mainichi-data.html
*2 http://lucene.apache.org/solr/

表 2: 調査テーマ推薦のための，関係性クエリ間の遷移テーブル．● は，検索対象の語句であることを表す．

現在調査中のクエリ	ユーザ興味エンティティ	推薦 関係性クエリ
SERVE(x,y)	x	COLLABORATE(x,●), SUPPRESS_COMPANY(●,x)
SERVE(x,y)	y	PROMOTE_DOMAIN(●,y), SUPPRESS_DOMAIN(●,y)
COLLABORATE(x,y)	x	SERVE(x,●)
COLLABORATE(x,y)	y	SERVE(y,●)
PROMOTE_DOMAIN(x,y)	y	SUPPRESS_DOMAIN(●,y), SERVE(●,y)
SUPPRESS_DOMAIN(x,y)	y	PROMOTE_DOMAIN(●,y), SERVE(●,y)

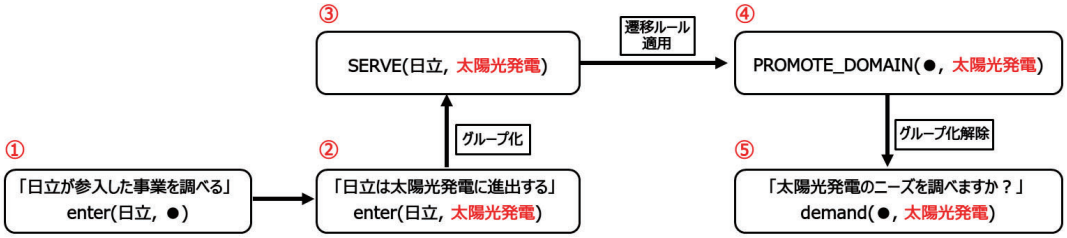


図 2: 遷移ルール適用に関するフロー．

表 3: 事例検索の精度評価．各列が 1 つの検索タスクを表す．enter(s,●) は，s をサンプリング語句とするタスクである．

事例検索タスク	serve(s,●)	supply(s,●)	enter(s,●)	serve(●,s)	supply(●,s)	enter(●,s)
影響アノテーション（ベースライン）	43%	3%	51%	41%	14%	24%
ビジネスドメインアノテーション	**47%**	**88%**	**56%**	**50%**	**61%**	**65%**

collaborate(●,s)	agree(●,s)	M_and_A(●,s)	demand(●,s)	regulate(●,s)	sanction(●,s)
15%	0%	0%	8%	3%	4%
83%	**50%**	**50%**	**31%**	**53%**	**48%**

全ての事例検索タスクにおいて，ビジネスドメイン関係性アノテーションはベースラインよりも，精度良く事例検索を行えることが分かった．

一方，精度は概ね 5 割程度であるので，改善の余地がある．そこで，偽陽性事例の解析を行い課題を精査した．特に精度が低い 2 つのタスクに関して以下に述べる．

demand(●,c) の事例検索精度は 31 %と最も低かった．例えば，demand(●, 半導体) クエリに関して「..鴻海はあらゆるモノがネットにつながる「IoT」の普及をにらみ，半導体メモリーの需要が急増するとみて，..」[*3] という事例が取得されていた．このように，需要者への言及が無い文が多かった．おそらく，事業の需要を述べる際には「特定のエンティティが事業分野を需要する」と直接述べることはせず,「ビジネス状況の変化（新規技術の登場，消費者趣向の変化，等）という理由に応じて，商材の需要が変化する」と述べることが多いからであろう．上記の文は「IoT が半導体需要を押し上げる」と理解できるので,「IoT のニーズを調べますか？」（demand(●, IoT)）といったクエリを次に推薦すべきである．そのためには,「IoT」と「半導体」の関係性のように，明示的に述べられていない関係性を推論する必要がある．

serve(s,●) では，例えば「ヤフーは昨年 10 月，既卒者も含めた通年採用を始めた.」[*4] というように，企業のアクションを述べた文が 5 割以上を占めた．これらの構文・述語は,「事業主体が事業をやっている」と述べた文と共通している．よって，エンティティに入る語句から文の意味を判定する必要である．

*3 日本経済新聞 2017/04/20
*4 日本経済新聞 2017/05/12

4. おわりに

ビジネス上の意思決定支援システムを開発した。「会社が事業に参入する」というような“ビジネス上の観点”に基づいて関連事例を検索する機構を構築した。また,「日立が太陽光発電に参入する」事例に対して「太陽光発電のニーズを調べますか？」といった新規調査テーマを推薦する機構を作成した。両機構の中核となる，ビジネスドメインの関係性抽出ルールを作成した．これを用いた事例検索精度計測により，効果を確認した．

今後は，直接的な言及が無い語句間の関係を推論する手法や，構文構造だけでなく語句のタイプ（会社，事業領域，等）から文全体の意味の判定をする手法の開発を目指す．また，ユーザの現在までの調査状況を総合的に踏まえた上でクエリを推薦する技術の開発に，取り組む．

参考文献

[Sato 15] Sato, M., Yanai, K., Miyoshi, T., Yanase, T., Iwayama, M., Sun, Q., and Niwa, Y.: End-to-end Argument Generation System in Debating, in *Proceedings of ACL-IJCNLP 2015* (2015)

[Yanai 17] Yanai, K., Sato, M., Yanase, T., Kurotsuchi, K., Koreeda, Y., and Niwa, Y.: StruAP: A Tool for Bundling Linguistic Trees through Structure-based Abstract Pattern, in *Proceedings of EMNLP 2017* (2017)

[佐藤 16] 佐藤 美沙, 柳井 孝介, 柳瀬 利彦, 三好 利昇, 丹羽 芳樹：ディベート人工知能における影響関係認識のためのテキスト内の論理構造に関する考察，人工知能学会全国大会 (2016)

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

EC サイトにおける商品タイトルからの商品名抽出

Product Name Extraction from Product Entries on EC Pages

張 培楠
Peinan Zhang

株式会社サイバーエージェント
CyberAgent., Inc.

We propose a task to identify a product name from an EC page title. On EC pages, sellers need to design their posts to increase the visibility of their products in search results. One of the common techniques is including extra information to the title of their product page. However, adding many keywords can result in such a complicated page title that it is hard for buyers to distinguish a product name from the title. Therefore, extracting product names is important, yet has some challenges especially when titles are in Japanese. (1) Most titles do not have standard grammatical structures. (2) Diverse characters, such as Kanjis, Kanas, alphanumerics, and symbols often appear in a single title. These make models hardly handle the boundaries of words and lead to incorrect learning. In this work, we create a corpus and evaluate several conventional approaches for basic analysis. The results show that this task is still challenging; an existing approach for named entity recognition, which performs very well at some open datasets, can only achieve 23.0 of the F1 score with our dataset.

1. はじめに

インターネットの普及に伴い，電子商取引—いわゆる EC (Electronic Commerce) —が一般的になってきている．中でも多いのが提供された EC サイトのプラットフォーム内で各小売店が出店して自らの商品を売り出す形式である．この形式では，商品ページの閲覧が購買に直結するケースが多いため [1, 2]，商品に関連するキーワードを使用して検索される結果への露出を増やすための検索エンジン最適化 (SEO) 対策を各出品者側で施すことが多い．その中でも特によく行われる方法が商品タイトルへの情報付加である (図 1)．このような方法を多くの出品者が特定のルールや基準に従うわけでもなく行っているため，購入者側からは何を売っているのか咄嗟に判別しにくく，さらに EC サイトの運営者としても販売内容を把握するための障害になりうる．そのため雑多な商品タイトルから出品している商品名を判別することには高い需要がある．

商品タイトルから商品名を抽出することは，固有表現抽出のタスクとして考えることができるが，一般的な固有表現抽出タスクと異なる性質がいくつか存在する．ひとつは，固有表現抽出タスクで想定されている多くのデータは正しい文法で成り立っている自然文であるが，この場合商品タイトルに含まれるトークンのほとんどが名詞・名詞句である上に，通常の文にあるような文法性がなく，語順も考慮されていない．したがって固有表現抽出のような系列ラベリング問題では，ラベルと周囲の語の依存関係を仮定したモデルを採用しているが，そのような仮定が商品タイトルにおいては成立しない．ふたつめは，既存の系列ラベリングの手法ではある程度分かち書きが正しくされていることが前提になることが多いが，今回の場合ではブランド名や商品名，型番，サイズ情報，色情報といった数多くの未知語が頻出する上に，漢字かな，アルファベットや記号，スペース区切りなどの使用頻度や使用ケースも出品者に大きく依存していて統一性がない．そのため高精度の単語分割は困難である．これらのことから，本タスクは非常に難易度が高いタスクであると言える．

このような背景を元に，我々はこのタスクを商品名抽出と定義し，本研究ではそれに必要なコーパスの作成および複数のベースラインを本コーパスで評価する．

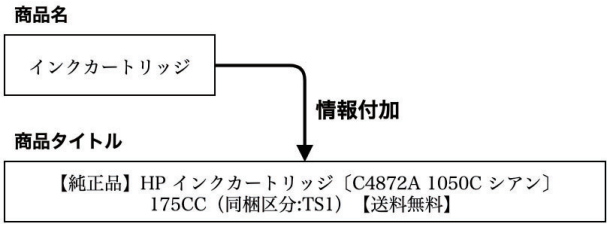


図 1　出品者が出品商品タイトルへ情報付加する例

2. 商品名抽出

2.1 タスクの定義とデータセットの作成

本タスクでは，EC サイトに掲載されているような商品のタイトルから商品そのものを指す商品の名称を抽出することを目標とする．そのためのデータセットを作成するにあたって，まずその特徴を分析する．データには Yahoo!ショッピング [*1] に掲載されている商品を用いた．特定のドメインに依存する言語的な特徴に偏りが生じないよう 18 カテゴリから合計で約 3 億件の商品タイトルを集め，そのうちの約 15,000 件を無作為に選んで分析に使用した．そのうちのいくつかの例を表 1 に列挙する．

例を見て分かるように，いずれの商品タイトルも各単語・フレーズがほぼ名詞・名詞句になっており，「送料 300 円選択可能です」といった部分的に文法的なフレーズは存在するが，タイトル全体で一貫して文法構造は持っていない．各単語・フレーズも商品に関連する製造元やブランド名，商品名，型番，サイズ，色，内容量以外に，商品自体に関連しない「送料無料」といった配送情報や「代引き不可」といった取引情報が散見される．さらには漢字，かな，アルファベット，数字や記号といった表層が特定のルールに則ることなく書かれていることが見て取れる．

*1 https://shopping.yahoo.co.jp

表 1　商品タイトル例

最大 75 % off！ SALE 開催中★ [ロイネス]Roiness 犬用 いわし 150g /ウエット パウチ 国産 4571245858269 #w-148985
〔純正品〕 HP インクカートリッジ/トナーカートリッジ 〔C9363HJ HP134 3 色カラー〕
ＴＲＵＳＣＯ　ナベ頭組込ネジ　クロメートＰ－４　サイズＭ６Ｘ１０　５０本入【メール便 送料 300 円選択可能です。】
（送料無料）（代引き不可）アーノルドパーマー　ベビー サンダル 13.5cm AP4111
当店 1 年保証 カシオ Casio General Men's Watches Metal Fashion MTP-1183A-7ADF - WW

表 2　付加情報のカテゴリとその例

カテゴリ	例
商品名	「インクカートリッジ」
商品の別名	「トナーカートリッジ」
規格情報	「サイズＭ６Ｘ１０」「白」「90g」
製造元名	「ロイネス」「HP」
配送情報	「送料無料」「メール便」
その他情報	「最大 75 % off！」

また，ここで考慮しなければならない重要な事柄のひとつが，正解ラベルの付け方である．出品者は商品に対して数多くの情報を付与するが，それらを分類すると表 2 のように大別できる．その商品自体に関するものとしては，「商品名」「商品の別名」とそれらのサイズ，色などといった情報を補足する「規格情報」，さらに製造元やブランドを示す「製造元名」がある．配送に関しては「配送情報」があり，セール情報などは「その他情報」に属するように分類を行った．

本研究のゴールは商品タイトルから商品名を抽出することであるため，正解ラベルは「商品名」と「商品の別名」とすべきところだが，商品名の定義に情報の粒度からくるゆらぎが生じることが確認されている．例えば「ジャケット HOUSTON MA-1 ALL フライトジャケット ミリタリージャケット メンズ アメカジ 送料無料」というタイトルに対して，「ジャケット」「フライトジャケット」「ミリタリージャケット」「MA-1」のすべてが同じものを指しており，粒度が粗くカテゴリの意味合いが強い「ジャケット」から粒度が細かい型番に近い「MA-1」が存在する．この際にどれを商品名とすべきかは定量的な指標がないため，今回は広告制作者の感覚で選択してもらいながら約 3,800 件事例のコーパスを作成した．その内訳を表 3 に示す．

表 3　コーパスの内訳

商品タイトル数	3,841
商品タイトル延べ文字数	220,900
商品タイトル異なり文字数	1,634
商品タイトル平均文字数	57.5

また，コーパスを作成するに当たって設けた制約を以下に記す．

制約 1. 連続した単語を選択　例えば「[ロイネス]Roiness 犬用 いわし 150g /ウエット パウチ」という商品タイトルに対して，商品名に「犬用 いわし」や「Roiness 犬用 いわし」は使用可能だが，「ロイネス 犬用 いわし」は単語がタイトルで連続していないので不可とした．

制約 2. 複数単語は使用不可　「アーノルドパーマー ベビー サンダル」という商品タイトルの場合，「アーノルドパーマー サンダル」や「ベビー サンダル」ではなく「サンダル」もしくは「アーノルドパーマー」を使用する．

制約 3. より認識される最小単位の単語を選択　これは前述の通り，「ジャケット HOUSTON MA-1 ALL フライトジャケット ミリタリージャケット メンズ アメカジ 送料無料」といった，同じ商品に複数の名称が存在する時，一般的に最もよく用いられる名称を選択する．この場合だと「MA-1」が選択される．

制約 1 と 2 はタスクをよりシンプルにするために設けた制約である．この制約を解除することで，現実的にはより需要のある，しかし研究的により難しいタスクとして派生させることも可能である．また，現時点では制約 3 が最も定性的だが，定量的な指標が利用または発見できていないため，一時的な妥協点として設けている．より定量的な指標を設計することを今後の課題とする．

2.2　手法

2.1 節で作成した商品コーパスを使用して，いくつかの手法を使って商品タイトルから商品名を抽出する実験を行っていく．実験に使用したアプローチは大きく Term Weighting として解く方向と系列ラベリング問題として解く方向のふたつに分けられる．

2.2.1　Term Weighting として解くアプローチ

Term Weighting は，抽出対象のドキュメントに含まれる単語に対して重要度を示すスコアを付与していく伝統的な情報抽出のいちタスクである．スコアの付与には多くの手法が存在するが，中でもよく使用されるのは TF-IDF (Term Frequency Inversed Document Frequency) と呼ばれる手法である．TF-IDF は単語の出現頻度（TF）と単語逆文書頻度（IDF）に分かれており，以下のように定式化される．

$$\begin{aligned}\mathrm{tfidf}(t,d,D) &= \mathrm{tf}(t,d)\cdot\mathrm{idf}(t,D)\\ &= \frac{\mathrm{freq}(t,d)}{\sum_{t_i\in d}\mathrm{freq}(t,d)}\cdot\log\left(\frac{|D|}{1+n_t}\right)\end{aligned}$$

t は各単語を表し，$d \in D$ は各ドキュメント，$\mathrm{freq}(*)$ は頻度を返す関数であり，n_t は単語 t が出現する文書数である．

TF-IDF の根幹にある考え方は，多くのドキュメントで出現する単語は重要でない単語である可能性が高く，反対に特定のドキュメントにしか多く出現しない単語は重要な単語である可能性が高い，というものである．本タスクにおいて各商品タイトルをドキュメントとして見立て，「送料無料」や「代引不可」といった商品以外の情報は特定の商品タイトルに限らず広く出現し，反対に商品名といったその商品自体を表している単語は限定的な商品タイトルにしか存在しない，と仮定することができる．そうすることで TF-IDF を本タスクに適用できると考え，この手法による商品名抽出を試みた．

2.2.2　系列ラベリング問題として解くアプローチ

本タスクに近しい分野として固有表現抽出があり，一般的な固有表現抽出タスクは系列ラベリング問題として解かれることがほとんどである．系列ラベリング問題とは，入力文の単語列 $\mathbf{X} = (x_1, x_2, \ldots, x_n)$ からラベル列 $\boldsymbol{y} = (y_1, y_2, \ldots, y_n)$

表 4　人手によって設計された素性

素性分類	説明・例
品詞素性	名詞や接続詞など
表層素性	漢字かな，数字やアルファベットなど
位置素性	タイトルでの単語が存在している位置
辞書素性	形態素解析器の辞書に含まれているかどうか

を予測するタスクで定式化でき，y_i にあたるラベルには固有表現のタグが付与される．このタグ付与の一例として BIO タグ (Begin, Inside, Other) があり，例えば $\mathbf{X}$ = (太郎, は, 明日, 東京, ディズニーランド, に, 行く) という系列に対して $\boldsymbol{y}$ = (B-PER, O, B-DAT, B-LOC, I-LOC, O, O) という正解のラベル列が付けられる．ハイフン後の表記は，人物であれば PER，日付や場所であれば DAT と LOC というように，そのタグが示す固有表現の種類である．今回は BIO タグに商品名を示すタグである PRD タグの 1 種類のみを使用した．つまり $\mathbf{X}$ = (Steve, Madden, メンズ, Taslyn, ロー, ファー, Grey) という系列に対して，$\boldsymbol{y}$ = (O, O, O, O, B-PRD, I-PRD, O) というラベル列を付与する．

系列ラベリング問題として解く際にふたつの手法を使用した．ひとつめは人手によって素性を設計し，その素性をもとに学習する手法．ふたつめはニューラルネットワークによる End-to-End に学習してタグを予測する手法である．

素性設計による手法　今回設計した素性を表 4 に示す．これらの素性を用いて条件付き確率場 (CRF) でラベリングを行う [3]．CRF は識別モデルの一種で，入力系列 $\mathbf{X} = (x_1, x_2, \ldots, x_n)$ に対して系列 $\boldsymbol{y} = (y_1, y_2, \ldots, y_n)$ を予測系列として出力する．系列の確率の予測は以下のように定式化できる．

$$P(\boldsymbol{y}|\mathbf{X}) = \frac{1}{Z} \exp \sum_{t=1}^{n} \sum_{k=1}^{K} \lambda_k f_k(x, y_{\{t-i,\ldots,t\}}, t)$$

$$Z = \sum_{y \in \boldsymbol{y}} \exp \sum_{t=1}^{n} \sum_{k=1}^{K} \lambda_k f_k(x, y_{\{t-i,\ldots,t\}}, t)$$

k は素性の数で，$f_k(*)$ はウィンドウ幅 i の素性関数，λ_k は素性ベクトルの重みを表している．計算されるラベル列 $\boldsymbol{y}$ の確率 $P(\boldsymbol{y}|\mathbf{X})$ を最大化するための重み λ_k を最急降下法などの最適化手法によって最適化する．

ニューラルネットワークによる手法　Lample ら [4] によって提案された，単語・文字を Bidirectional LSTM (BiLSTM) を用いて得られた内部表現を CRF でラベルを予測する手法（図 2）．具体的には単語列を $\mathbf{X} = (x_1, x_2, \ldots, x_n)$ としたときに，t 番目の単語の分散表現を $\boldsymbol{w}_t$ とする．また単語 x_t は文字列 $\mathbf{C}_t = (c_1, \ldots, c_m)$ から構成されており，内部で使用する t 番目の単語は $\boldsymbol{h}_t$ で表現し，以下のように算出する．なお $\oplus$ はベクトルの連結を表す．

$$\boldsymbol{h}_t = \mathrm{BiLSTM}(\boldsymbol{w}_t \oplus \boldsymbol{c}_t)$$

$$\boldsymbol{c}_t = \mathrm{BiLSTM}(\mathbf{C}_t)$$

これにより得られた $\boldsymbol{h}$ を $\boldsymbol{z} = \mathbf{W}\boldsymbol{h} + \boldsymbol{b}$ のように重み $\mathbf{W}$ でラベル数次元に非線形変換したのち，CRF を用いてラベル列 $\boldsymbol{y}' = (y'_1, \ldots, y'_n)$ を予測値として出力する．
なお、この手法は CoNLL2003 データセット [5] において F 値 90.93 を達成しており，当時の固有表現抽出において最高精度を持つ手法であった．

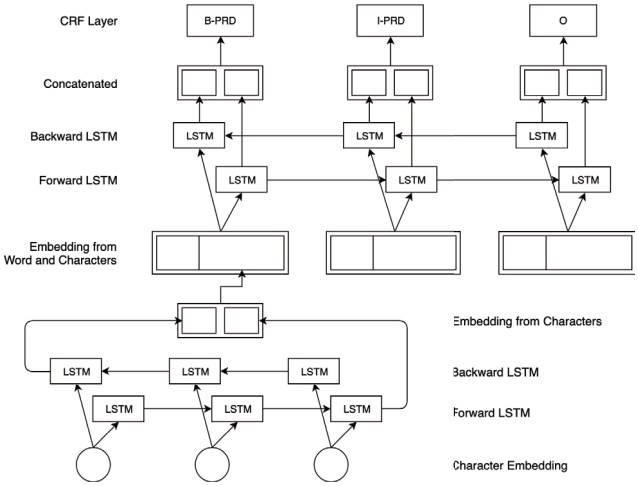


図 2　BiLSTM + CRF の構造図

3. 実験

3.1 実験設定

2.1 節で作成した商品コーパスを用いて評価実験を行っていく．全ての手法において共通する 10 個のシード値でコーパスを (train : valid : test) = (8.5 : 0.5 : 1) の割合で分割し，評価は予測ラベルと正解ラベルの F 値，適合率，再現率で行う．

TF-IDF　TF-IDF の場合は出力が各単語に対するスカラー値となるので，タイトル内の単語で最も高い TF-IDF 値を持つ単語を B タグとし，他を O タグとして評価する．また，TF-IDF は分かち書きされた単語がそのまま固有表現のチャンクになるため，分かち書きに使用する辞書の比較と前処理を施した．

CRF　前後 2 単語のウィンドウ幅での素性を作成し，L1/L2 正則化と準ニュートン法 (L-BFGS) [6] で最適化を行う．L1/L2 の重みはそれぞれ 1.0 と 0.001 で early stopping を考慮した最大 50 回のイテレーションを実行する．

BiLSTM + CRF　最大 100 epoch の early stopping で学習し，単語と文字の分散表現の次元はそれぞれ 100 と 25，Dropout は 0.5 に設定して Adam を用いて最適化を行った．

3.2 実験結果と分析

実験結果を表 6 に示す．結果より，全ての指標において BiLSTM+CRF が他手法を大きく上回った．しかし最も高い F 値でも 23.0 であることから，本タスクの難易度の高さが分かる．

TF-IDF 系列ラベリング問題とは異なるアプローチをしているので厳密には同じ基準での比較はできないが，正解ラベルを必要としない教師なし手法であり，それと比較すると正解ラベルを使用した教師あり手法のほうが F 値において 2〜3 倍以上の性能を達成していることが見て取れる．

人手による素性設計を元に学習する CRF は適合率が 20.3 と再現率に比べて高いことが見て取れる．これはハンドクラフトな素性では正しい商品名を正確に抽出できていないことに起因すると考えられる．品詞，表層，位置以外に考慮できていない特徴が商品名には潜んでおり，意味的な観点でも辞書を一般的な文書コーパスから作成されたものではなく，EC サイトに特化した辞書を使用することで単語の適用範囲が限定され，より

表 5　正答例および誤答例

1 正答例	Steve Madden (スティーブマッデン) メンズ Taslyn ロー ファー Grey
2 正答例	防 ダニ ・ 抗菌 ・ 防臭 フランネルラグマット / 絨毯 〔 ボリューム タイプ / 約 185 × 280 cm ピンク 〕
3 両方	(業務 用 10 個 セット) 三甲 (サンコー) ベタ 目 コンテナ ボックス / サンボックス 11 - 2 (代 引 不可)
4 誤答例	メンズ ブーツ チャッカブーツ カジュアル Timberland Men ' s Groveton Leather Fabric Boot 正規 輸入 品
5 誤答例	日本 製 【 ■ nano cafe 】 ベビー 手 マグ54294 4522202542943
6 誤答例	HiKOKI (旧 日立工機) フロア 用 タッカ 電源 電圧 V N 5004 MF (送料 無料)(代 引き 発送 不可)
7 誤答例	ジョインテックス 応接 センター テーブル KE - 1260 W

表 6　商品コーパスに対する各手法の実験結果

手法	適合率	再現率	F 値
TF-IDF	5.7	11.1	7.0
CRF	20.3	11.4	14.5
BiLSTM + CRF	**25.4**	**21.2**	**23.0**

効果を発揮する素性になりうる．また，ただ辞書に存在するかどうかという 0/1 のバイナリ値だけでなく，単語が属するドメイン名そのものを利用することでより情報に富んだ素性として使える可能性がある．

ニューラルネットワークによる手法では適合率と再現率のバランスが他手法と比べて取れており，F 値も他より大きく上回る．それでも全体的にスコアが低いのはデータに依るものと考察できる．まず今回使用したデータのサイズは大きくなく，性能を発揮するにはより大きなコーパスが必要となる．また，データの性質上，ひとつの商品タイトルにはひとつの商品名しか正解ラベルが付与されないため，たとえ類似した単語 — 2.1 節の分類で言うところの「商品の別名」など — があったとしてもそれにはネガティブなラベルが付与されている．したがって，意味的に類似している単語の表現を捉える傾向があるニューラルネットワーク手法ではそれに引っ張られ，商品名を当てることが難しくなっている可能性が考えられる．

より詳細な分析をするため，BiLSTM+CRF の出力と正解データを照らし合わせて正答例と誤答例を表 5 に示した．緑ハイライトが正解箇所，赤ハイライトが予測箇所，青ハイライトが正解と予測が被っている箇所になる．(1)(2) はふたつとも正答できている例で，(2) のような長いチャンクでも正しくラベリングできていることが見て取れる．(3) はシステムが複数の商品名を認識できた例で，意味表現の近い「コンテナボックス」と「サンボックス」が識別されており人間が見ても正しいが，制約上正解ラベルはひとつしか存在しないため正解と不正解両方の判断になっている．(4) は (3) に類似しているが，意味的に近い「メンズ ブーツ」を認識したが，正解ラベルである「チャッカブーツ」を認識できなかった誤答例である．(5) はブランド名を商品名と誤認識した例であり，(6) では「フロア用タッカ」を予測しており，それは人間が見ても正しく認識できているが，教師データ作成時のゆらぎで正解ラベルが型番に近い「N5004MF」になっているため不正解となっている．(7) はシステムの出力が「センターテーブル KW-1260W」となっているが，正解ラベルは「応接センターテーブル」と範囲を誤っている．

これらのことから，実験結果においての F 値の低さは全てがシステムの性能が低いことに起因するだけではなく，人間が見ても理解できる予測をしているがデータの基準や制約条件に依るものであるものも多いと考えられる．したがって，性能向上のためには手法の改善に伴ってより基準に一貫性がある直感的なデータ作成が今後必要になる．

4.　まとめと今後の課題

本研究では EC サイトにおける商品タイトルからの商品名抽出というタスクを提案し，そのためのコーパスの作成およびそれを使った実験・分析を行った．実験に使用した手法は Term Weighting としてのアプローチである TF-IDF と，系列ラベリング問題として解くアプローチである CRF があり，CRF を用いる場合は素性設計による手法と End-to-End なニューラルネットワークによる手法で比較実験を行った．その結果，ラベル列を F 値で評価した場合はニューラルネットワーク手法である BiLSTM+CRF が最も良い性能である 23.0 を達成した．しかしこの数字は CoNLL 2003 データセットと比較して大きく下回ることから，本タスクの難易度の高さを裏付けることができた．

これからの展望として，データに関しては商品名を定義づけるより定量的な指標を設計することやタグの種類の拡張や複数単語対応すること，手法に関しては，ノイジーな入力に頑健な単語分割に依存しないような文字ベース・サブワードベースの固有表現抽出手法を使用することなどが挙げられる．また，今回の方向性以外のアプローチも存在し得るので探っていきたい．

参考文献

[1] Eric Enge, Stephan Spencer, Jessie Stricchiola, and Rand Fishkin. *The art of SEO*. O'Reilly Media, Inc., 2012.

[2] StephenO' Neill, Kevin Curran. The core aspects of search engine optimisation necessary to move up the ranking. *International Journal of Ambient Computing and Intelligence (IJACI)*, Vol. 3, No. 4, pp. 62–70, 2011.

[3] John Lafferty, Andrew McCallum, and Fernando CN Pereira. Conditional random fields: Probabilistic models for segmenting and labeling sequence data. In *Proceedings of International Conference on Machine Learning (ICML)*, pp. 282–289, 2001.

[4] Guillaume Lample, Miguel Ballesteros, Sandeep Subramanian, Kazuya Kawakami, and Chris Dyer. Neural architectures for named entity recognition. In *Proceedings of NAACL-HLT*, pp. 260–270, 2016.

[5] Erik F. Tjong Kim Sang and Fien De Meulder. Introduction to the conll-2003 shared task: Language-independent named entity recognition. In *Proceedings of NAACL-HLT*, pp. 142–147, 2003.

[6] Jorge Nocedal. Updating quasi-newton matrices with limited storage. *Mathematics of computation*, Vol. 35, No. 151, pp. 773–782, 1980.

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

Scam Cryptocurrency Detections using Machine Learning Techniques

Kentaro Asaba

Keio University

It has been reported that more than 2,400 cryptocurrencies have been created by October 2018 [Investing.com, 2018], and new coins are constantly produced even today. However, a large number of so-called *scam coins* are also produced, and they are generating a huge amount of loss to the investors [Seth, 2018]. This research tries to build models that estimate whether a cryptocurrency is a scam, using the following machine learning techniques: Doc2Vec, Word2Vec, Support Vector Machine (SVM), Decision Tree, Neural Net Classifier, and Random Forest. It has been found that Doc2Vec×Random Forest has the highest performance.

1. Introduction

Since the very first cryptocurrency called Bitcoin was published in 2009, more than 2,400 cryptocurrencies have been created by October 2018 [Investing.com, 2018]. Many investors seek for investment opportunities in cryptocurrencies' Initial Coin Offering (ICO), a newly invented way to fund money using cryptocurrencies, as the prices of the newly published coins often dramatically increased after the launch of ICOs. It has previously been observed that the average return brought by ICO is 179% [Kostovetsky and Benedetti, 2018]. Nevertheless, so-called scam coins, which can be defined as cryptocurrencies that have no practical use and created solely to deceive money from investors, are also being produced. It has been estimated that almost $9 million worth of money was lost every day due to cryptocurrency frauds for the first two months of 2018 [Seth, 2018]. Therefore, there is a strong demand for methods to prevent the loss caused by cryptocurrency scams.

This paper attempts to create models which receive cryptocurrencies' whitepapers as inputs, and predict whether they are scam coins or not, by following the process illustrated by previous researches [Basavaraju and Prabhakar, 2010], [Bergsma, et al., 2012].

2. Methods

The document classification task includes the following procedures:

(1) Training data preparation
(2) Preprocessing transformation
(3) Document vectorization
(4) Application of classification models
(5) Evaluation

(1) Training Data Preparation

In total, 120 whitepapers are collected from each cryptocurrencies' website. 60 of them are labeled as "scam", which represents deceptive cryptocurrencies, and rest of 60 papers are labelled as "listed", whose coins are listed on binance.com, the world's largest cryptocurrency exchange website. The list of scam coins is extracted from deadcoins.com.

(2) Preprocessing transformation

When converting the documents into text, Reference sections are removed since they are irrelevant with the content of the papers. In addition, images, graphs, and tables are also removed from the documents before analysis.

After unnecessary parts are removed, all capital letters are converted into lowercase letters. Occasionally, in other classification tasks, words that include capital letter(s) are excluded from the texts [Bergsma, et al., 2012]. The advantage of removing them is that names, citations, and other proper nouns can be extracted which can contribute to the removal of nonessential parts. However, this research does not remove the words with capital letters in order to minimize the information loss.

(3) Document Vectorization

The next step is document vectorization. Sentences need to be transformed into vectors with this process because the classification models can only receive vectors. TF-IDF, Average vector of Word2Vec [Mikolov, et al., 2013] embedding, Doc2Vec [Le & Mikolov, 2014] are used in this research to compare their performances, and to achieve the highest accuracy as possible.

Average Word2Vec method takes the average of the word vectors of every words v_{wi} in the document and defines it as a document vector $\mathbf{d}$.

$$\mathbf{d} = \frac{1}{n}\sum_{i=1}^{n} v_{wi},$$

where w_i is the i-th word in the document, and v_{wi} is the word embedding for the word w_i.

In this research, pre-trained 300-dimension word vectors which are obtained from training of Wikipedia documents are employed since it is found that the pre-trained word vector is useful in sentence categorization tasks [Kim, 2014].

(4) Application of classification models

This paper will compare the performance of five classification techniques: Support Vector Machine, Logistic Regression, Decision Tree, Random Forest, and Neural Net Classifier. As the

Contact: Kentaro Asaba, Keio University, kentaroasaba@keio.jp

documents are labeled when they are collected, the training will be conducted in a supervised way.

(5) Evaluation

The models are evaluated based on four criteria: Accuracy, F1-score, Recall, and Precision. We define *True Positive* as number of scam currency correctly classified as scam, *True Negative* as number of listed currencies correctly classified as listed, *False Positive* as number of listed currencies classified as scam, and *False Negative* as number of scam currency classified as listed.

3. Results

3.1 Model Performance

Table 1 displays the model performances based on the four criteria. Among all combinations of methods, Doc2Vec×Random Forest method has the highest performance, and has 90% accuracy.

	Doc2Vec				TF-IDF				Avg. Word2Vec			
	Acc.	F1	Recall	Prec.	Acc.	F1	Recall	Prec.	Acc.	F1	Recall	Prec.
SVM	0.892	0.901	0.933	0.878	0.850	0.860	0.883	0.865	0.733	0.712	0.667	0.780
LR	0.883	0.894	0.933	0.867	0.842	0.857	0.900	0.836	0.758	0.747	0.733	0.775
DT	0.825	0.818	0.833	0.823	0.733	0.777	0.900	0.702	0.650	0.591	0.617	0.591
RF	**0.900**	**0.915**	**0.900**	**0.931**	0.892	0.915	0.833	0.993	0.800	0.750	0.733	0.794
NN	0.825	0.855	0.933	0.794	0.833	0.855	0.950	0.786	0.767	0.748	0.733	0.795

Table 1: *Model performances*

The confusion matrix for the best-performing method (Doc2Vec×Random Forest) is illustrated in Table 2 This method has almost the same numbers of FP and FN, thus has potential to be used in the real practices.

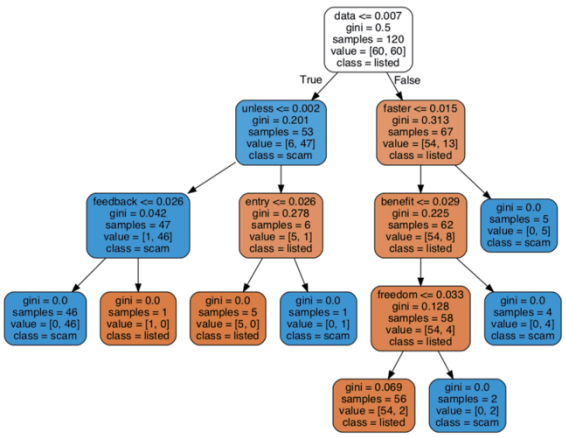
		Predicted Class	
		Scam	Listed
Actual Class	Scam	**54**	6
	Listed	4	**56**

Table 2: *Confusion matrix of Doc2Vec×Random Forest*

3.2 Visualization

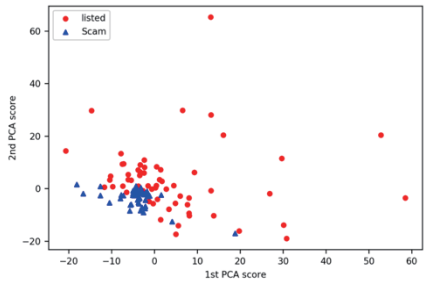
The Decision Tree thresholds when TF-IDF is used is visualized in Figure 1. The top words in the top of the boxes represent the feature and the threshold value, and the gini values show the impurities. From this figure, it seems clear that scam cryptocurrency documents are likely to have words *faster*, *benefit*, and *freedom*, and that of listed cryptocurrencies are likely to have words *data* and *unless*.

Figure 1: *Decision Tree Thresholds*



In order to visualize the distribution of vectorized documents, PCA is applied after Doc2Vec to reduce the dimensions to 2 (Table 2). The red dots, which represent the listed coins, are spread in upper right area, and the difference in distribution between scam and listed coins can still be seen even after the dimension reduction. The difference between listed and scam coins can still be detected even after the dimension reduction.

Figure 2: *Mapping of two dimension document vector by Doc2Vec and PCA*



4. Conclusion

This study has developed multiple models for scam cryptocurrency detection and compared their performance. Among all models, Doc2Vec×Random outperformed other methods and had 90% accuracy rate. However, it was not possible to include various kinds of domains other than whitepaper's texts as coin's representations due to the availabilities. Further research is required to build more effective models which includes other domains such as number and contents of images, graphs, mathematical formulae in the whitepapers, as well as domains from the coins themselves such as the types of coins (e.g. Ethereum based, non-Ethereum based), coin-names, and author's traits which can be utilized when classifying coins.

References

[Investing.com, 2018] Investing.com: All Cryptocurrencies , October 17, 2018, Retrieved from https://www.investing.com/crypto/currencies

[Seth, 2018] Seth, S: 80% of ICOs Are Scams: Report, Investopedia, 2018.

[Basavaraju and Prabhakar, 2010] Basavaraju, M., and Prabhakar, D. R.: A novel method of spam mail detection using text based clustering approach, International Journal of Computer Applications, 5(4), 15-25, 2010.

[Bergsma, et al., 2012] Bergsma, S., Post, M., and Yarowsky, D.: Stylometric analysis of scientific articles, 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 327-337, 2012

[Kostovetsky and Benedetti, 2018] Kostovetsky, L., and Benedetti, H.: Digital Tulips? Returns to Investors in Initial Coin Offerings, 2018

[Mikolov, et al., 2013] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient estimation of word representations in vector space, Workshop at the International Conference on Learning Representations, 2013

[Le & Mikolov, 2014] Le Q. and Mikolov T.: Distributed representations of sentences and documents, The 31st International Conference on Machine Learning, 1188–1196, 2014

[Kim, 2014] Kim, Y.: Convolutional neural networks for sentence classification. arXiv preprint arXiv:1408.5882, 2014

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

Extraction of Business Contents from Financial Reports Using Recurrent Neural Network Model

Tomoki Ito*1 Hiroki Sakaji*1 Kiyoshi Izumi*1

*1Graduate School of Engineering, The University of Tokyo

To extract business contents automatically from financial reports is an important problem in the financial area. Especially, segment names and their explanations are important contents that should be extracted. However, the methods for extracting these types of information from financial reports have not been established. In this study, we aim to develop a practical solution for extracting these types of information. To solve this problem, we developed a manually annotated dataset for the task of extracting the segment names and their explanations of each company from financial reports and then developed a recurrent neural network model to solve this task. Our method using the manually annotated dataset outperformed the baseline methods without the dataset in the task of extracting segment names and their explanations of each company. This results demonstrated that our approach is useful for extracting the business contents of each company. This work is the first work for applying a machine learning method to the task of extracting segment names and their explanations. The insights from this work should be valuable in the industrial area.

1. Introduction

With the development of information and communication technology, interest from investors on the technology of financial text mining has been increasing. When investors conduct investment activities, it is indispensable to gather performance information on listed companies. Among them, "financial summary reports" in which listed companies are published quarterly is one of the useful information sources for making investment decisions.

To analyze the financial summary reports, Information on business segments name and segment explanation is important, because each company usually describes settlement information in business segment units, as shown in Figure 1. However, it is heard that some financial companies usually extract these segment information manually, and it makes costs. Therefore, to extract this information has a great demand in the financial area.

Several studies on extracting the important contents from financial reports have been conducted, [Sakaji 17, Kitamori 17, Isonuma 17]. However, the method for extracting the segment names and segment explanations has not been established.

In this research, we aim to develop a practical method for extracting "business segment name" and "the explanation of the segment name" from the financial summary report. To achieve our aim, we first developed manually annotated dataset including textual data for "overview of reporting segments" and "business segment name" for each financial summary reports. We then develop a recurrent neural network model (RNN) that can extract "business segment name" from financial summary reports using the annotated dataset. To demonstrate the practicality of our method, we demonstrate whether our appraoch can extract segment names using only small training dataset. This insight should be useful for the industrial area.

Contact: m2015titoh@socsim.org

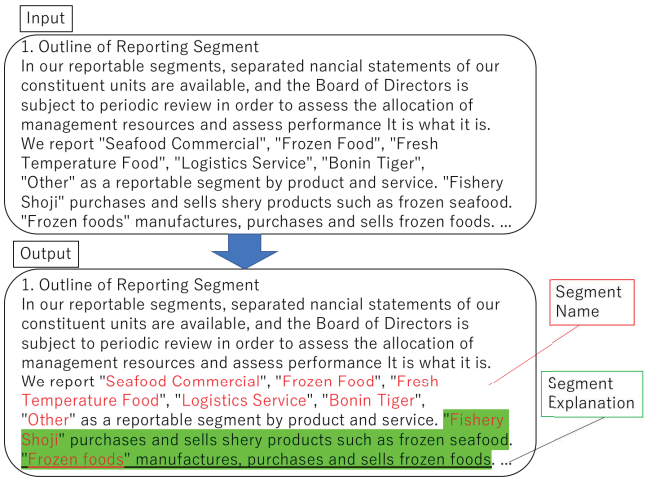


Figure 1: Goal Image: extraction of segment names and their explanations from a financial report

Our contributions are summarized as follows.

1) We present a crucial task setting: extraction of segment names and segment extractions from financial reports, and created an annotated dataset for this task.

2) We developed a practical method for extracting segment names and segment explanations from financial reports. This work is the first implementation for this task using a machine learning method, as far as we know.

2. Extraction of the segment information using RNN

This section introduces the proposed method for extracting segment names and their explanations from financial summary reports.

2.1 Task Setting

Let $\mathbf{Q} = \{w_t^{\mathbf{Q}}\}_{t=1}^{N}$ be a document. Our task is to extract

a) a set of segment names $\Omega^{\mathbf{Q}}$, and

b) a set of segment explanations $\{\{w_t^{\mathbf{Q}}\}_{t=s}^{f}\}_{s\in S^{\mathbf{Q}},f\in F^{\mathbf{Q}}}$ from $\{w_t^{\mathbf{Q}}\}_{t=1}^{N}$.

It should be noted that $|\Omega^{\mathbf{Q}}|and|S^{\mathbf{Q}}|, |F^{\mathbf{Q}}|$ are not constant values because the number of the segment differs between financial summary reports.

2.2 Structure of RNN

To solve the this task, we developed the RNN model as shown in Figure 2. This RNN model is constructed using the idea in the pointer network model [Vinyals 15].

2.2.1 Embedding

Given a comment $\mathbf{Q} = \{w_t^{\mathbf{Q}}\}_{t=1}^{n}$, this layer, first, converts all words in the comment to their respective word-level embeddings $\{\boldsymbol{e}_t^{\mathbf{Q}}\}_{t=1}^{n}$ where $\boldsymbol{e}_t^{\mathbf{Q}} \in \mathbb{R}^e$.

2.3 Segment Name Layer

This layer converts $\{\boldsymbol{e}_t^{\mathbf{Q}}\}_{t=1}^{n}$ to context representations $\{\boldsymbol{h}_t^{\mathbf{Q}}\}_{t=1}^{n}$ using a bi-directional long short-term memory, LSTM[Schuster 97]:

$$\boldsymbol{h}_t^{\mathbf{Q}} = \mathrm{LSTM}(\boldsymbol{e}_t^{\mathbf{Q}}) \tag{1}$$

where $\boldsymbol{h}_t^{\mathbf{Q}} \in \mathbb{R}^e$. This layer, then, converts $\boldsymbol{h}_t^{\mathbf{Q}}$ to the segment name layer$\{y_t^{\mathbf{Q}}\}_{t=1}^{n}$:

$$\boldsymbol{a}_t^{\mathbf{Q}} = \boldsymbol{W}^O \boldsymbol{h}_t^{\mathbf{Q}} + \boldsymbol{b}, \tag{2}$$

$$y_t^{\mathbf{Q}} = \mathrm{argmax} a_t^{\mathbf{Q}} \tag{3}$$

where $y_t^{\mathbf{Q}}$ represents word $w_t^{\mathbf{Q}}$ is included in a segment name set Ω^Q ($y_t^{\mathbf{Q}} = 1$) or not ($y_t^{\mathbf{Q}} = 0$), and $\boldsymbol{W}^O \in \mathbb{R}^{2\times e}$ and $\boldsymbol{b} \in \mathbb{R}^2$ are the parameter values.

2.4 Segment Explanation Start Layer

This layer converts $\{\boldsymbol{e}_t^{\mathbf{Q}}\}_{t=1}^{n}$ to context representations $\{\boldsymbol{u}_t^{\mathbf{Q}}\}_{t=1}^{n}$ using a LSTM:

$$\boldsymbol{u}_t^{\mathbf{Q}} = \mathrm{LSTM}(\boldsymbol{e}_t^{\mathbf{Q}}) \tag{4}$$

where $\boldsymbol{u}_t^{\mathbf{Q}} \in \mathbb{R}^e$. This layer, then, converts $\boldsymbol{h'}_t^{\mathbf{Q}}$ to the segment explanation start point layer$\{y_t^{\mathbf{Q}}\}_{t=1}^{n}$:

$$\boldsymbol{c}_t^{\mathbf{Q}} = \boldsymbol{W}_s^O \boldsymbol{h}_t^{\mathbf{Q}} + \boldsymbol{b}_s, \tag{5}$$

$$s_t^{\mathbf{Q}} = \mathrm{argmax}\ \boldsymbol{c}_t^{\mathbf{Q}} \tag{6}$$

where $y_t^{\mathbf{Q}}$ represents word $w_t^{\mathbf{Q}}$ is included in a start point set $S^{\mathbf{Q}}$ ($y_t^{\mathbf{Q}} = 1$) or not ($y_t^{\mathbf{Q}} = 0$), and $\boldsymbol{W}_s^O \in \mathbb{R}^{2\times e}$ and $\boldsymbol{b}_s \in \mathbb{R}^2$ are the parameter values.

2.5 Segment Explanation Finish Layer

This layer converts $\{\boldsymbol{e}_t^{\mathbf{Q}}\}_{t=1}^{n}$ to context representations $\{\boldsymbol{g}_t^{\mathbf{Q}}\}_{t=1}^{n}$ using a LSTM:

$$\boldsymbol{g}_t^{\mathbf{Q}} = \mathrm{LSTM}(\boldsymbol{e}_t^{\mathbf{Q}}) \tag{7}$$

where $\boldsymbol{g}_t^{\mathbf{Q}} \in \mathbb{R}^e$. This layer, then, converts $\boldsymbol{g}_t^{\mathbf{Q}}$ to the segment explanation finish point layer$\{y_t^{\mathbf{Q}}\}_{t=1}^{n}$:

$$\boldsymbol{d}_t^{\mathbf{Q}} = \boldsymbol{W}_f^O \boldsymbol{h}_t^{\mathbf{Q}} + \boldsymbol{b}_f, \tag{8}$$

$$f_t^{\mathbf{Q}} = \mathrm{argmax}\ \boldsymbol{d}_t^{\mathbf{Q}} \tag{9}$$

where $f_t^{\mathbf{Q}}$ represents word $w_t^{\mathbf{Q}}$ is included in a finish point set $F^{\mathbf{Q}}$ ($f_t^{\mathbf{Q}} = 1$) or not ($f_t^{\mathbf{Q}} = 0$), and $\boldsymbol{W}_f^O \in \mathbb{R}^{2\times e}$ and $\boldsymbol{b}_f \in \mathbb{R}^2$ are the parameter values.

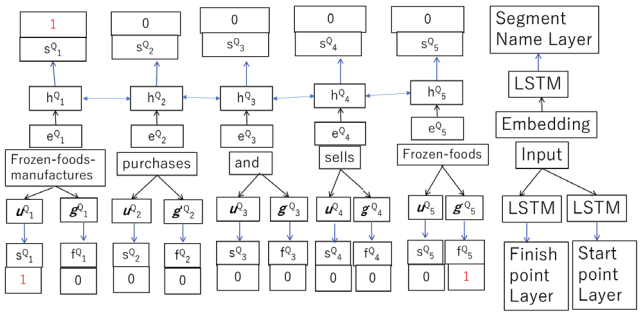


Figure 2: RNN Architecture

2.6 Learning

We can develop the RNN with a training dataset including $\{w_t^{\mathbf{Q}}\}_{t=1}^{N}$ and $\{\Omega^{\mathbf{Q}}, S^{\mathbf{Q}}, F^{\mathbf{Q}}\}$. We used the following L as a loss function

$$\begin{aligned} L &= CE(\{\boldsymbol{a}_t^{\mathbf{Q}}\}_{t=1}^{N}, \{w_t^{\mathbf{Q}} \in \Omega^{\mathbf{Q}}\}_{t=1}^{N}) \\ &+ CE(\{\boldsymbol{c}_t^{\mathbf{Q}}\}_{t=1}^{N}, \{w_t^{\mathbf{Q}} \in S^{\mathbf{Q}}\}_{t=1}^{N}) \\ &+ CE(\{\boldsymbol{d}_t^{\mathbf{Q}}\}_{t=1}^{N}, \{w_t^{\mathbf{Q}} \in F^{\mathbf{Q}}\}_{t=1}^{N}) \end{aligned}$$

where $CE(a, b)$ represents the softmac cross entropy between a and b.

3. Experimental Evaluation

This section introduces how we evaluated our method using a real textual dataset.

3.1 Dataset

To evaluate our method, we manually created a dataset including textual data for "overview of reporting segments", "business segment name," and "segment explanation" for each financial summary reports. We created dataset for 880 financial summary reports.

3.2 Segment information Extraction

We split the dataset into a training dataset and the remainder as a test dataset. We then developed the RNN model using the training dataset and extracted the segment names and the segment explanations from the test dataset.

3.2.1 Segment name

In extracting the segment names with the RNN, we extracted all the words $\Omega' = \{w_t^{\mathbf{Q}} | y_t^{\mathbf{Q}} = 1, 1 \le t \le n\}$ as the predicted segment names.

3.2.2 Segment explanation

In extracting the segment explanations with the RNN, we first extracted all the word positions $S' = \{t | s_t^{\mathbf{Q}} = 1, 1 \le t \le n\}$ and $F' = \{t | f_t^{\mathbf{Q}} = 1, 1 \le t \le n\}$ as the predicted start terms and finish terms. We then extracted segment explanations as shown in Algorithm 1.

After that, we evaluated the result using the F_1 score. To evaluate the practicality of our method, we evaluated our method in the case where the size of the training dataset is small and the size of the training dataset is sufficiently large. Table 1 summarizes the dataset organizations.

Table 1: Dataset details
(a) Training dataset

ID	1	2	3	4	5
number reports	50	100	200	300	400
number of segment names	116	250	543	836	1,134
number of non-segment names	9,115	20,892	40,263	59,026	79,167

(b) Test dataset

ID	1	2	3	4	5
number of reports	830	780	680	580	480
number of segment names	2,351	2,217	1,924	1,631	1,333
number of non-segment names	162,881	151,104	131,733	112,970	92,829

Algorithm 1 Extraction of Segment Explanation Part

$P \leftarrow \phi$, $m \leftarrow 0$, $d \leftarrow \{\}$;
for $l \in S' + F'$ **do**
  if m $= 0$ **then** m $\leftarrow l$;
  else P $\leftarrow \{w_t^{\mathbf{Q}}\}_{t=m}^{l}$, m $\leftarrow 0$;
  end if
end for
for $\{w_t^{\mathbf{Q}}\}_{t=m}^{l} \in P$ **do**
  for $t \in [m, m+1, \cdots l]$ **do**
    if $y_t^{\mathbf{Q}} = 1$ **then** $d[w_t^{\mathbf{Q}}] = \{w_t^{\mathbf{Q}}\}_{t=m}^{l}$;
    end if
  end for
end for
return d: dictionary of segment name (key) and explanation (value);

3.3 Comparison Method

3.3.1 Segment name

To evaluate our method for extracting segment names, we compared the results of our method with the results of extracting segment names using word embedding representations and the logistic regression model (baseline method).

3.3.2 Segment explanation

To evaluate our method for extracting segment explanations, we compared the results of our method with the results of the following baseline methods, namely, baseline (100), baseline (200), and baseline (300). In the baseline (100), baseline (200), and baseline (300) methods, we extracted the 100, 200, and 300 terms that existed after the predicted segment names as the explanation part.

3.3.3 Other Settings

Other experimental settings are summarized as follows: In developing RNN, we used the word embeddings calculated using the skip-gram method (window size = 5) [Mikolov 13] based on financial reports (between October 2002 and May 2018, 90,813 files). We set the dimensions of the RNNs' hidden and embedding vectors to 200, epoch to 40 with early stopping.

4. Results and Discussion

Table 2 summarizes the results, showing that the proposed method outperformed the baseline method.

In addition, the results demonstrated that the proposed method was practical because this method was able to extract segment names even with small training data. This practicality is considered to be caused by the consistent usage of words in the financial documents.

Table 2: Evaluation Result
(a) Segment Name

ID	1	2	3	4	5
Baseline	0.058	0.371	0.497	0.505	0.510
RNN	**0.827**	**0.851**	**0.873**	**0.869**	**0.843**

(b) Segment Explanation

ID	1	2	3	4	5
Baseline (100)	0.038	0.037	0.034	0.035	0.036
Baseline (200)	0.127	0.111	0.114	0.115	0.114
Baseline (300)	0.106	0.100	0.097	0.098	0.098
RNN	**0.587**	**0.570**	**0.619**	**0.594**	**0.652**

5. Related Works

Several studies have been done for extracting important information from financial documents[Sheikh 12, Pires 13, Sakaji 17, Kitamori 17, Isonuma 17]. In [Sheikh 12], the rule-based method for extracting up-date information form a news article was proposed. In [Pires 13], the method for extracting table contents from a financial document was proposed. Combining these works and our method, it can be possible to extract more valuable information from financial documents.

As for useful technique for information extraction, techniques used in Question Answering[Wang 17, Wang 18] can be useful. The application of these technique to our task can lead to the improvement of the extraction technique for extracting segment information.

6. Conclusion

In this study, we applied the RNN model to the task of extracting segment names and their explanations form financial reports. This work is the first implementation for these types of information using a machine learning method, as far as we know. We demonstrated that our method could extract segment names and their explanations with more higher F_1 scores than the baseline method. In addition, we experimentally demonstrated that we could extract seg-

ment names and their explanations with only small training dataset. This result should be the usual insight for the industrial area because this showed that our method was sufficiently practical. In the future, we will apply our method to the other similar tasks, and finally, develop a text-visualization system that visualizes the financial report contents of each company in a user-friendly manner.

References

[Isonuma 17] Isonuma, M., Fujino, T., Mori, J., Matsuo, Y., and Sakata, I.: Extractive Summarization Using Multi-Task Learning with Document Classification, in *EMNLP 2017* (2017)

[Kitamori 17] Kitamori, S., Sakai, H., and Sakaji, H.: Extraction of sentences concerning business performance forecast and economic forecast from summaries of financial statements by deep learning, in *IEEE CIFEr 2017* (2017)

[Mikolov 13] Mikolov, T., Sutskever, I., Chen, K., Corrado, G., and Dean, J.: Distributed Representations of Words and Phrases and their Compositionality, in *NIPS 2013* (2013)

[Pires 13] Pires, F. M. and Abreu, S.: Automatic Selection of Table Areas in Documents for Information Extraction, in *EPIA 2003* (2013)

[Sakaji 17] Sakaji, H., Murono, R., Sakai, H., Bennett, J., and Izumi, K.: Discovery of Rare Causal Knowledge from Financial Statement Summaries, in *IEEE CIFEr 2017* (2017)

[Schuster 97] Schuster, M. and Paliwal, K.: Bidirectional Recurrent Neural Networks, *IEEE Transactions on Signal Processing*, Vol. 45, No. 11, pp. 2673–2681 (1997)

[Sheikh 12] Sheikh, M. and Conlon, S.: A rule-based system to extract financial information, *Journal of Computer Information Systems*, Vol. 52, (2012)

[Vinyals 15] Vinyals, O., Fortunato, M., and Jaitly, N.: Pointer Networks, in *NIPS 2015* (2015)

[Wang 17] Wang, W., Yang, N., Wei, F., Chang, B., and Zhou, M.: Gated Self-Matching Networks for Reading Comprehension and Question Answering, in *ACL 2017* (2017)

[Wang 18] Wang, W., Yan, M., and Wu, C.: Multi-Granularity Hierarchical Attention Fusion Networks for Reading Comprehension and Question Answering, in *ACL 2018* (2018)

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

B2B 企業ブランド評価と株主価値

Relation between B2B Corporate Brands and Shareholder Values

真鍋 友則 *1 *3 Tomonori Manabe
中川 慧 *2 *3 Kei Nakagawa
吉田 健一 *3 Kenichi Yoshida

*1Sansan 株式会社 Sansan, Inc.
*2野村アセットマネジメント株式会社 Nomura Asset Management Co,Ltd.
*3筑波大学大学院ビジネス科学研究科 Graduate School of Business Science, University of Tsukuba

It has been reported that the customer satisfaction which represents corporate brand affects future risk of cash flows and shareholder value in B2C companies. In this study, we verify whether the same relationship holds for B2B companies. For that, we used new B2B brand score which was developed based on the reputation for the company among people who have connection with employees of the company. We showed that the B2B brand score is positively associated with shareholder value.

1. はじめに

無形資産は知的財産, 商標, 技術や知識の集積, 人的資源, 組織風土, 企業や商品に関する風評など, 財務指標には表れにくい, 企業の有する無形の資源である [Hall 92]. この無形資産への投資は短期的には企業の利益を圧迫する一方で, 差別化を産み出す競争力の源泉と見なされ, 長期的な戦略投資上重要視されている. 近年では英国と米国においてこのような無形資産への投資総額が有形資産への投資額を上回っていることが指摘されている [経済 17].

顧客のロイヤルティと関わる企業ブランドも無形資産の重要な要素であり, 将来のキャッシュ・フロー創出能力を予測するため, または株主価値の増大を図るため, その価値を適切に評価することが課題として挙げられてきた [経済 02]. 企業ブランドと企業業績の関連は実証的研究で示されており, Chaudhuri らは ブランドに対する信頼感および親和性は購入ロイヤルティや態度的ロイヤルティに正の影響を示し, 前者はマーケットシェアに, 後者は価格優位性に影響を及ぼすという構造を明らかにしている [Chaudhuri 01].

ブランド・ロイヤルティに影響する要因の一つに購入した商品や受けたサービスに関する顧客満足度がある [Bloemer 92]. アメリカにおける顧客満足度調査指標 ACSI (American Customer Satisfaction Index[Fornell 96]) を用いた研究で, 顧客満足度が企業の業績のみならず, 株主価値とも正の関連性があることが複数報告されている [Anderson 04, Ittner 98, Matzler 05]. Anderson らは, 顧客満足度と株主価値が正に関連するメカニズムとして, 顧客満足度の高い顧客はリテンションや購買量の増加, 価格許容性の増大, 他者への推奨, WOM などを通じて企業へのキャッシュ・フローを増加させるため, 将来のキャッシュ・フロー創出への期待指標である株主価値と相関する, と解釈している [Anderson 04].

このように, 無形資産の一部であるブランド価値や顧客満足度が, 企業業績や株主価値を増大させることは実証されており, 重要な指標として位置付けられている. ただし, これら研究は主に B2C 企業についての調査研究であり, B2B 企業に関するブランド価値の実証研究は, 筆者らの知る限りこれまで行われていない. その原因として, B2B 企業についてはそもそも一般的なブランド評価指標が得にくいことが挙げられる. すなわち, B2B 企業は B2C 企業と比べ, その業態やサービスについて一定以上の知識を有する者は実際に商取引のある人々や近しい業種の集団に限定されアクセスし難いため, 業種を跨いだ大規模な調査を効率的に実施することが困難であったためである. しかし B2C 企業と同様, B2B 企業においても企業ブランドは重要な無形資産の一種であり, その適切な定量評価は企業戦略および投資戦略上, 非常に重要な課題である.

Sansan 株式会社が 2018 年にリリースした B2B 企業ブランド指標 BBES (B2B Engagement Score) は, 上記のような問題点を乗り越え, B2B 企業についての効率的なアンケート調査システムを実現している [Sansan Inc.] *1. Sansan 社は名刺アプリ Eight を運用し, 名刺交換ネットワークデータを構築している. Eight ユーザーの内で対象企業の名刺保有者に対して任意のブランド等の印象調査を行うことで, ステークホルダーやそれに準ずる者達から成る集団に母集団を限定した企業ブランド評価を可能にした（2.1 参照）.

本研究では, この新規な企業ブランド指標 BBES が無形資産としてのブランド価値を含む指標であるかどうかを評価するため, ACSI で研究されてきたような, 株主価値との正の関連性が, ACSI と同様に存在するかどうかを調べた. Anderson らは ACSI と株主価値の関連性を評価するモデルにおいて, 株主価値の指標にトービンの q を用いている [Anderson 04]. トービンの q は株価に基づく指標であるため, ROI のような指標と比べた場合, より長期的な将来価値を表すものであり, また, ブランド価値を反映した指標であることが示されている [Simon 93]. 本稿ではトービンの q の代理変数として株価純資産倍率 (PriceBook-value Ratio;PBR) を用いた (2.2 参照).

上場企業 122 社について, BBES と PBR の関連を調べたところ, 業種と売上規模をコントロールしたモデルにおいて,

連絡先: 真鍋 友則，Sansan 株式会社，manabe@sansan.com

*1 BBES（BtoB Engagement Score）とは, Sansan 株式会社が発表した、BtoB 企業のブランド力指標である. Sansan 株式会社は, 名刺アプリ Eight のユーザーに任意の大規模調査アンケートを実施し, その結果をもとに BBES スコアを構築している. また, Sansan 株式会社は, 大規模調査済み BBES データを閲覧・比較・評価することができるモニタリングサービス「BBES Monitor」を提供している.

BBES と PBR には統計的有意に正の関連性があることを確認した. すなわち, これは名刺交換ネットワーク上の人的ネットワークを利用して算出されたブランド指標である BBES が, 同業種・同程度の売上規模の企業間で比較して高い場合, 株主価値もより高いことを示しており, BBES が業種や売上規模では説明できないブランド価値を反映した指標であることを示唆する結果である. また, この結果は, B2B 企業においてもブランド価値が株主価値と関連することを示すものである.

2. 方法

2.1 BBES (B2B Engagement Score)

Sansan 社の BBES は, 半年に一回, 調査対象企業の名刺を有する人にランダムに調査票をメール送付し, 任意のアンケート結果を回収することで作成される. 調査母集団を名刺所有者に限定することにより, 全母集団からのランダムサンプリングと比べ, その企業の人と実際に面識があり関連度のより高い人たちを対象とした調査が実現されている.

調査はこれまでのところ 2018 年の 5 月と 11 月に行われており, 本稿ではその両方を分析に利用した. 対象企業数, 調査人数と数値を表 1 に記す.

表 1: BBES 調査企業数と回答者数

	5 月調査	11 月調査
調査対象企業数	1,406	1,388
上場企業数	564	582
調査人数 *1	1,500	1,500
平均有効回答者数 *1	190 (79-318)*2	154 (87-218)

[1] 企業 1 社あたりの人数　[2] カッコ内は最小値と最大値

アンケートは「ブランド」, 「サービス」, 「ヒト」の 3 項目に関する意識調査から成り, 回答者は, 「〜社のブランドイメージは魅力的だと思いますか?」「〜社の製品・サービスは自社/社会に有用だと思いますか?」「〜社の人は好印象だと思いますか?」と言う 3 つの質問に対し, 0 - 10 の 11 段階の評点をつける. 1 人の回答者が回答する企業数は, 最大 3 企業と設定されている.

企業ごとの回答者評点の項目別平均値の分布, 平均値, 標準偏差を図 1, 表 2 に記す. その平均値や分布は半年期間の異時点間でおおよそ等しく, 回答の傾向が安定していることを示している.

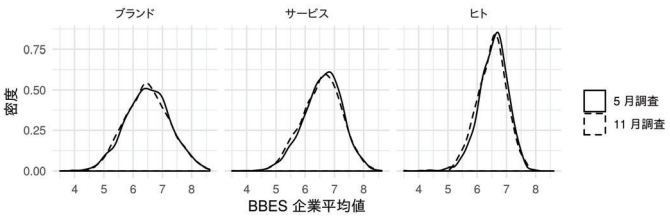


図 1: BBES 企業得点の分布

BBES 企業ごとの回答者平均値は, 項目間で高い相関を示しており, ブランド-サービス間で 0.88, ブランド-ヒト間で 0.83, サービス-ヒト間で 0.83 であった. これら 3 項目を次元圧縮し, 合成得点を算出するため, 主成分分析を行なった (表 3). 第一主成分は固有値が 1 以上でまた寄与率が 81.2 % であり, 因子負荷量もそれぞれの項目について同程度に高いことから, この第一主成分を BBES の総合力と考え, 企業ごとの平均値を算出し, その値を企業 BBES の代表値とした (cBBES). cBBES の 5 月と 11 月の調査時点間の相関値は 0.92 ($n = 1,380$) と高く, cBBES は半年の期間でその時点間の変化は小さく, 安定的に推移していることを示している.

2.2 企業価値評価の尺度について

BBES が 企業価値にどのような影響を与えるかについて, トービンの q の代理変数として株価純資産倍率 (Price Book-value Ratio;PBR) を使用する. トービンの q は企業価値 (Market Value;MV) を資本の再取得価格, すなわち総資産の簿価 (Total Book Value;BV) で割った値として定義される. まずはトービンの q が顧客満足度のような無形資産とどのような関係にあるかを整理する. 企業価値のうち, バランスシートに計上されている総資産の簿価 BV と財務諸表には計上されない無形資産の価値 (Intangible assets value;IV) に分解する.

$$MV = BV + IV \tag{1}$$

ここで式 (1) の両辺を, BV で除すると,

$$\frac{MV}{BV} = 1 + \frac{IV}{BV} \tag{2}$$

となる. したがって無形資産の価値を計測するためにトービンの q を代理変数として使用することが多い [Konar 01, Simon 93].

ここで, 企業価値は株主価値の時価 (Equity Value;EV) と負債価値の時価 (Debt Value;DV) の和と等しく, 総資産の簿価は株主価値の簿価 (Equity Book Value;EB) と負債価値の簿価 (Debt Book Value;DB) に等しいため, 負債の時価と簿価が等しいとすると,

$$\frac{MV}{BV} = \frac{EV + DV}{EB + DB} \propto \frac{EV}{EB} \tag{3}$$

となり, 式 (3) の右辺は PBR を表す. 一般に負債の時価評価は難しく, 負債の時価と簿価が等しいと仮定することが多い [野村 15]. その場合には, PBR もまた無形資産の価値を計測するための簡便的な代理変数として使用できる.

また, 株式市場において PBR はバリュー (HML) ファクターとしてその有効性が古くから知られており, 重要な投資指標でもある [Fama 92, 久保 07].

2.3 BBES と株主価値

BBES と PBR の関係を評価するため, 次のような評価式を作成して係数の値を検証した.

$$\begin{aligned} ln(PBR_{im}) =& \beta_0 cBBES_{im} + \beta_1 ln(AD_i) \\ &+ \beta_2 ln(Sales_i) + \beta_3 ln(SR_i) \\ &+ \gamma_j TypeDummy_{ji} + \varepsilon_i \end{aligned} \tag{4}$$

表 2: BBES 企業得点の項目別平均値

	5 月調査	11 月調査
ブランド	6.5 (0.7) *1	6.5 (0.7)
サービス	6.6 (0.7)	6.6 (0.7)
ヒト	6.6 (0.5)	6.5 (0.5)

[1] 平均値 (標準偏差)

表 3: BBES の主成分分析

	因子負荷量		
	PC 1	PC 2	PC 3
ブランド	0.58	0.30	-0.76
サービス	0.58	0.50	0.64
ヒト	0.57	-0.81	0.12
固有値	2.44	0.32	0.25
寄与率	0.81	0.11	0.08

ここで, PBR_{im}, $cBBES_{im}$ はそれぞれ企業 i の月 m の PBR 値, cBBES 値である. 両者の関係性を明確にするため, PBR に影響する以下の変数を統制項として加えている. AD_i は企業 i の 2017 年 6 月から 2018 年 5 月までの 1 年間の広告宣伝費累計, $Sales_i$ は企業 i の 2017 年度の売上額を表す. SR_i は企業 i の 2016 年から 2017 年にかけての売上成長率, $TypeDummy_{ji}$ は企業 i の属する業種 j のダミー変数行列であり, 企業 i が属する唯一の業種について 1, それ以外は 0 が入る. なお業種は東証株価指数 33 業種 [東証] を元に, ダミー変数あたりの企業数が少なくとも 6 以上になるように再分類を行ない, 9 個のダミー変数とした [*2]. これらの変数を加えることで, 企業固有の要因, および業種に起因する要因を統制している. β_k はそれぞれの係数を表しており, これらの推定値は一般的な最小二乗法によって求めた. cBBES を除く連続値変数については, それらの分布が右側に歪んだ分布であったため, 対数変換を行なった. 係数の推定は BBES 調査月である $m = 5$ と $m = 11$ の 2 通りについて行なった. なお, 本モデルに使用した企業数は, 広告宣伝費の入手できる企業にさらに限定された結果, 最終的に 122 社となった.

3. 結果

式 (4) の変数間の相関を 4 に記す. cBBES と 2017 年度の売上高および 広告費の間には正の相関があり, 規模の大きい企業ほど cBBES が高い傾向にあることがわかる. 一方で PBR と cBBES, Sales, AD との間には, 有意ではないが負の相関関係があり, 企業規模が大きい場合その PBR は小さくなる傾向が見てとれる.

表 4: モデル 4 における変数間の相関

	PBR	$cBBES$	$Sales$	AD	SR
PBR	1				
$cBBES$	-0.15	1			
$Sales$	-0.12	0.31^{**}	1		
AD	-0.09	0.22^{*}	0.71^{**}	1	
SR	0.16	0.08	-0.01	0.21^{*}	1
Note:	*p<0.05; **p<0.01				

式 (4) の推定結果を表 5 に記す. $m = 5$ 月 の列は PBR および cBBES が 2018 年 5 月の値の場合, $m = 11$ 月 の列は 2018 年 11 月の値の場合の係数推定値をそれぞれ表す.

どちらのデータセットにおいても, cBBES の係数は有意に正の値を示した.

*2 「サービス」, 「その他」, 「不動産」, 「化学」, 「卸売」, 「小売」, 「情報通信」, 「輸送用機器」, 「電気機器」の 9 業種

表 5: 式 (4) の係数推定値のサマリー: BBES と PBR の関連

	Dependent variable:	
	ln(PBR)	
	m = 5 月	m = 11 月
β_{cBBES}	0.426^{*}	0.501^{**}
	(0.180)	(0.167)
β_{Sales}	-0.292^{**}	-0.302^{**}
	(0.064)	(0.060)
β_{AD}	0.165^{**}	0.189^{**}
	(0.049)	(0.048)
β_{SR}	0.766^{**}	0.556^{**}
	(0.206)	(0.193)
Constant	3.295^{**}	3.115^{**}
	(0.514)	(0.484)
Observations	122	122
R^2	0.495	0.522
Adjusted R^2	0.439	0.470
Residual Std. Error (df = 109)	0.666	0.628
F Statistic (df = 12; 109)	8.896^{**}	9.927^{**}
Note:	*p<0.05; **p<0.01	

$TypeDummy$ の係数 γ の推定値の記載は省略.

$Sales$ の係数が有意に負の値を示したが, これは売上規模の小さい企業と比べた場合, 大企業は低い PBR をとりやすい傾向を表している (表 4). AD と SR の係数はどちらも有意に正の数値となり, 広告宣伝費の多い企業, および売上成長率の大きい企業は, PBR がより高い傾向にあることを表す.

このように, 売上高, 広告費, 成長率, 業種を統制した上で, 名刺所有者というステークホルダーからの企業評価指標と, 企業無形資産価値を含む PBR の間の関連性を評価したところ, 両者に有意な正の関連があるという結果が得られた.

4. 考察

本稿では, 始めに, 名刺ネットワークを用いた新たな調査手法を用いて開発された B2B 企業ブランド指標 BBES について, その性質を記述した. BBES は, 対象の企業の名刺を所有している者に任意の調査を行うことにより, その企業と一定以上のビジネス上の関連をもつ集団からのブランド評点を実現している. 名刺所有集団は, 取引関係者から挨拶を交わした程度の関係まで, その紐帯の軽重は多様であろうが, 少なくともランダムサンプリングによる集団よりは, その企業や業界に対する知見を多く有する集団であると想定することは自然である. また, 調査対象企業には B2C ビジネスを展開する企業も含まれるが, 企業の名刺所有者は一般的な消費者よりも企業間取引関係に近しい者と考えられる.

今回我々は, そのような調査対象から収集された BBES が

PBR と正の関連があることを示した. 広告費, 売上, 売上成長率, 業種などを統制した上での PBR と BBES との間の関連性は, 同業種同規模の企業において, BBES が企業の無形資産としてのブランド力を反映した指標であることを示唆するものである. また, PBR は無形資産価値を含む一方, あくまで株式市場における評価値であり, 株式市場の要因を受けても変動する. B2B 企業ブランド力の指標として BBES を継時的に把握することは, 企業ブランド戦略上固有の優位性が期待される.

B2B 企業ブランドが株主価値に影響することの背後には, B2C と類似したメカニズムが働いていることが想定される. B2C ではブランド・ロイヤルティの向上は, 顧客の購買や推奨の促進を通して企業のキャッシュ・フローを増大させるため, その期待によって株主価値を引き上げるとされる. B2B においても同様に, 周囲からの評価の高い企業は, 取引成立時のコストを引き下げたり, 長期取引の安定化をもたらすことによって, キャッシュ・フローが増大する期待が上がり, 株主価値が増大するというフローが想定できる. このようなフローの実証は, 今後の研究課題である.

本研究の限界として, PBR と BBES の関連性が, 同時点についての分析結果に留まることがあげられる. 本分析では明確な因果関係を示せず, したがって, 先行指標となり得るかどうかについての検討が課題として残っている. 今後, BBES の時系列データが蓄積するに従い, 先行指標としての機能をより明らかにしていくことを目指している.

参考文献

[Anderson 04] Anderson, E. W., Fornell, C., and Mazvancheryl, S. K.: Customer Satisfaction and Shareholder Value, *Journal of Marketing*, Vol. 68, No. 4, pp. 172–185 (2004)

[Bloemer 92] Bloemer, J. M. M. and and, J. G. A. M. L.: The importance of customer satisfaction in explaining brand and dealer loyalty, *Journal of Marketing Management*, Vol. 8, No. 4, pp. 351–363 (1992)

[Chaudhuri 01] Chaudhuri, A. and Holbrook, M. B.: The Chain of Effects from Brand Trust and Brand Affect to Brand Performance: The Role of Brand Loyalty, *Journal of Marketing*, No. 65, p. 81 (2001)

[Fama 92] Fama, E. F. and French, K. R.: The cross-section of expected stock returns, *the Journal of Finance*, Vol. 47, No. 2, pp. 427–465 (1992)

[Fornell 96] Fornell, C., Johnson, M. D., Anderson, E. W., Cha, J., and Bryant, B. E.: The American customer satisfaction index: nature, purpose, and findings, *the Journal of Marketing*, pp. 7–18 (1996)

[Hall 92] Hall, R.: The Strategic Analysis of Intangible Resources, *Strategic Management Journal*, No. 13, pp. 135–144 (1992)

[Ittner 98] Ittner, C. D. and Larcker, D. F.: Are Nonfinancial Measures Leading Indicators of Financial Performance? An Analysis of Customer Satisfaction, *Journal of Marketing*, Vol. 36, pp. 1–35 (1998)

[Konar 01] Konar, S. and Cohen, M. A.: Does the market value environmental performance?, *Review of economics and statistics*, Vol. 83, No. 2, pp. 281–289 (2001)

[Matzler 05] Matzler, K., Hinterhuber, H., Daxer, C., and Huber, M.: The relationship between customer satisfaction and shareholder value, *Total Quality Management Business Excellence*, Vol. 16, No. 5, pp. 671–680 (2005)

[Sansan Inc.] Sansan Inc., : BBES ホームページ, https://bbes.sansan.com/: Accessed: 2019-01-15

[Simon 93] Simon, C. J. and Sullivan, M. W.: The measurement and determinants of brand equity: A financial approach, *Marketing science*, Vol. 12, No. 1, pp. 28–52 (1993)

[久保 07] 久保田敬一, 竹原均 : Fama-French ファクターモデルの有効性の再検証, 現代ファイナンス, Vol. 22, pp. 3–23 (2007)

[経済 02] 経済産業省 : ブランド価値評価研究会報告書, Technical report (2002)

[経済 17] 経済産業省 : 伊藤レポート 2.0 持続的成長に向けた長期投資 (ESG・無形資産投資) 研究会報告書, Technical report (2017)

[東証] 東証 : 東証株価指数 33 業種, https://www.jpx.co.jp/markets/indices/realvalues/01.html: Accessed: 2019-01-15

[野村 15] 野村篤史 他 : 金融負債の公正価値測定, 関西学院商学研究, No. 69, pp. 57–84 (2015)

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

日本語BERTモデルを用いた 経済テキストデータのセンチメント分析

Sentiment Analysis of Japan Economic Watcher Survey Data with Japanese BERT model

青嶋 智久 *1*3　中川 慧 *2
Tomohisa Aoshima　Kei Nakagawa

*1富士通クラウドテクノロジーズ株式会社　*2野村アセットマネジメント株式会社
Fujitsu Cloud Technologies Limited.　Nomura Asset Management Co,ltd

*3筑波大学大学院 リスク工学専攻
Department of Risk Engineering, University of Tsukuba

A new language representation model called BERT, which stands for Bidirectional Encoder Representations from Transformers obtains new state-of-the-art results on eleven natural language processing tasks in English. We build a Japanese version of BERT model with Japanese Wikipedia data and perform sentiment analysis of Japan Economic Watcher Survey Data. We confirmed that the result of sentiment analysis using the Japanese version of BERT model is better than the result without the model.

1. はじめに

政府や日銀、あるいは様々な金融機関が、膨大な数の経済レポートを日々発行している。投資家はこれらの膨大なレポートから投資行動に有用な情報を得るために、非常に多くの時間を費やす必要がある。しかしながら投資家は時間的な制約から、膨大なレポートの一部しか読むことが出来ず、大量のテキストデータを十分に活用出来てない。そういった問題意識から、経済テキストデータをコンピューターが自動処理し、投資判断に活用する金融テキストマイニング技術が金融市場で普及してきた。金融テキストマイニングでは、あるテキストが表す状況が市場や景気に対してポジティブもしくはネガティブかを評価するセンチメント分析の事例が多くある [和泉 17]。

センチメント分析には様々な手法が存在し、[Turney 02] などの極性辞書ベース・アプローチと [Pang 02] などの機械学習アプローチとに大別される。極性辞書ベース・アプローチでは、テキスト中に出現するポジティブな単語 (市場や景気にとって良い意味の単語) の出現比率とネガティブな単語の出現比率の差で対象となるテキスト全体の極性を算出する方法が用いられる。一方、機械学習アプローチでは、テキストの特徴量とポジティブやネガティブなどの極性ラベルとの関係性を、機械学習モデルによって学習し、極性付与されていないテキストに対して学習済みモデルを適用することで極性を付与する。このアプローチで特に、深層学習を用いることで高い精度が得られることが報告されている。例えば、RNN を用いた金融関連テキストの分析としては、ニュース記事の要約を試みた [Chen 15] がある。また LSTM を用いて景気ウォッチャー調査 [内閣] を学習データに用いることで、経済テキストのセンチメント分析を行った [山本 16] がある。

近年、[Devlin 18] は大規模なコーパスによる双方向の Transformer [Vaswani 17] を用いた教師なし学習による事前学習を行い、その事前モデル (BERT モデル) を個別のタスクごとにファインチューニングすることで自然言語処理の様々なタスクにおいて最高のスコアを更新した。

本研究では、[Devlin 18] の BERT モデルを Wikipedia 日本語版データ [Wikimedia Foundation] を用いて学習し、その事前モデルを用いて内閣府の景気ウォッチャー指標を学習したセンチメント分析を行う。そして、[山本 16] よりも高精度のセンチメント分析が可能であることを実証する。

連絡先: 青嶋 智久,
富士通クラウドテクノロジーズ株式会社
筑波大学大学院 リスク工学専攻
tomohisa.aoshima@blue271828.com

2. BERT モデル

様々な自然言語処理タスクは、トークンレベルのタスク、文レベルのタスクに大別できる。トークンレベルのタスクはトークン同士の関係性を学ぶのに対して、文レベルのタスクは文同士の関係性を学ぶ。いずれのタスクにおいても、事前学習は有効であることが確認されている。様々なタスクへの応用を前提とし、有効な特徴量を学習されることを事前学習という。事前学習のアプローチは特徴量ベースのアプローチとファイン・チューニングのアプローチがある。前者は自然言語処理において代表的な N-gram モデルや Word2Vec [Mikolov 13] などが該当し、事前学習により得られた特徴量をそのまま、様々な NLP タスクに利用する。後者は、次の単語を予測する言語モデルを事前学習として行い、その後にタスクに応じた教師あり学習でファイン・チューニングするアプローチである。BERT モデルは後者のファイン・チューニングアプローチによる事前学習モデルで、具体的には双方向 Transformer を用いたモデルである。

Transformer は、Attention のみを使用したニューラル翻訳モデルで、わずかな訓練で LSTM よりも良好な結果を得ている。Attention とは、系列データを扱う際に重要な箇所に注目 (Attention) するための手法で、加法注意・内積注意・自己注意等がある。中でも、自己注意 (Self-Attention) は汎用的で有効であり、言語処理のあらゆるタスクにおいて高い性能を発揮することが知られている [Vaswani 17]。BERT モデルはこの Transformer をユニットとして複数個利用している。

BERT モデルの特徴のひとつは、注目する単語の前後の文脈の両方 (双方向) について学習している点にある。従来のモデルでは単語の先読みをしてしまうという問題から前の文脈 (単方向) しか利用できなかったのに対して、BERT モデルは学習方法を事前学習のタスクを工夫することで、双方向での学

習が可能となった。BERT モデルにおける事前学習のタスクは以下の 2 つである。

1. マスクされた単語の予測

   N 個の単語を持つ文章において、$n-1$ 番目までの単語から n 番目の単語を予測するタスクにおいては、予測モデルにおいて予測するべき未来の単語情報 (n 番目以降の単語) を予測に用いないような制約が先読みを防ぐために必要となる。したがって、モデル自身は後の文脈を考慮できず、前の文脈のみで次の単語を予測する必要があった。しかし、モデル側ではなく入力データをマスク化し制約をかけることことで、前後の文脈を考慮するモデルで学習が可能となった。具体的には、 系列の 15%を [MASK] トークンに置き換えて予測を行う。[MASK] トークンのうち、80%がマスク、10%がランダムな単語、10%を置き換えない方針で置換する。

2. 隣接文の判定

   質疑応答や自然言語推論といったタスクでは 2 つの文章の関係性を理解できる必要がある。しかしながら、文章間の関係性は、単語の発生確率をモデリングしている言語モデルのみではとらえきれない特徴量を含んでいる。そこで、隣接文判定問題を解かせることで、文章単位での意味表現を獲得する。具体的には、2 つの文章を与え、文章が隣り合っているかを 2 値判定する。2 つの文章の片方を 50%の確率で別の文章に置換する。

BERT モデルは multilingual モデルとして日本語のモデルも提供されている。しかしながら、トークン区切りが日本語に適切なものでなく、これを日本語に適したものに変更する必要がある。英語版の BERT モデルと同様にトークン単位で日本語を取り扱うために、SentencePiece [Kudo 18] を使用する。SentencePiece は、日本語のようなスペースで単語が区切られていない言語にも対応したトークン区切りのアルゴリズムであり、辞書に基づく単語列ではなく、文章から直接トークン区切りを高速に学習する。我々は日本語の Wikipedia をコーパスとして、SentencePiece を使った日本語版の BERT モデルの事前学習を行う。

3. 実証分析

3.1 BERT モデルの事前学習

まずはデータセットとして、Wikipedia 日本語版からコーパスを作成する。コーパスの作成には、2018 年 12 月 20 日時点のダンプデータを用いた。本文の抽出にはオープンソースプロジェクトである WikiExtractor*1 を利用し、不要なマークアップを取り除いた。その後、不要なタグの削除、空白・改行削除、大文字小文字変換などの正規化処理を行い、学習に必要な前処理を施した。BERT モデルの事前学習の際には隣接文の判定のため、Wikipedia の一記事ごとに偶数個の文章からペアを作成し適用する。なお BERT モデルのサイズでは、[Devlin 18] の $\text{BERT}_{\text{BASE}}$ と同様の設定を行った。

3.2 景気ウォッチャー調査を用いたセンチメント分析

センチメント分析のための評価データに内閣府が調査・公表している景気ウォッチャー調査を用いた。景気ウォッチャー調査とは内閣府が行う景気動向に関するアンケート調査で、タクシー運転手や小売店の店主等、景気に敏感な人達 (景気ウォッチャー) に景気に対する判断 (5 段階で、現状と先行きの 2 種類がある) とその理由を毎月アンケート調査している。5 段階の判断はそれぞれ、「良い」、「やや良い」、「変わらない」、「やや悪い」、「悪い」である。これら全件のテキストデータと景気判断が CSV で利用可能となっている。実際の回答サンプルや質問項目の詳細については [内閣] を参照。

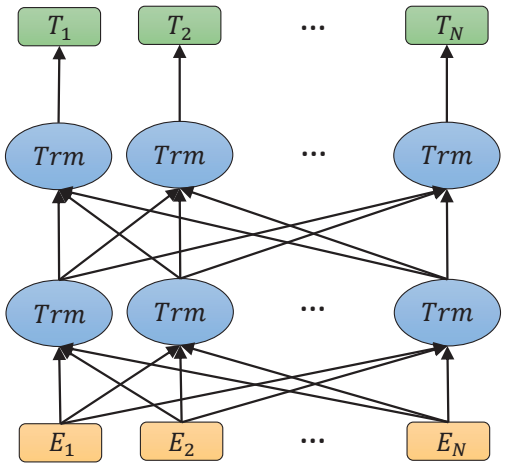


図 1: BERT model の構成。[Devlin 18] より著者作成。Trm は Transformer を表す。

表 1: LSTM を用いたセンチメント分析

	precision	recall	F1 score	support
良い	0.69	0.60	0.64	1,715
やや良い	0.86	0.86	0.86	18,935
変わらない	0.84	0.85	0.84	41,601
やや悪い	0.76	0.77	0.76	23,866
悪い	0.71	0.65	0.68	8,427
Total	0.772	0.746	0.756	94,544

これらのデータのうち、ランダムに 6 割を学習データ、2 割を検証データ、残りの 2 割を評価データとして用いて実験を行う。景気に対する判断のテキストを入力に、そのラベル (5 段階の評価) であるセンチメントを予測するタスクを行い、BERT モデルの有効性を確認する。前節の Wikipedia 日本語版 BERT モデルを事前学習として使用し、ファインチューニングしたモデルと、ベンチマークとして先行研究である [山本 16] で用いられた LSTM モデルを使用する。LSTM モデルの学習では [山本 16] と同様の値を採用し、主なパラメーターに中間層の次元数=250、バッチサイズ=50、ドロップアウト=0.3、エポック数=40 を設定した。結果は表 3.2 および 3.2 の通りである。

BERT モデルを使用することで、「良い」の再現率を除き、**他の全てのラベルおいて適合率・再現率・F 値が改善している**のが見て取れる。また、ラベルごとのサンプル数の多寡に寄らない改善が行われていることから、適度な汎化性能を有していると考えられる。これにより、経済テキストデータによるセンチメント分析でも BERT の事前学習が有効であることが確認できた。

*1 https://github.com/attardi/wikiextractor

表 2: BERT による事前学習を用いたセンチメント分析

	precision	recall	F1 score	support
良い	**0.75**	0.58	**0.65**	1,715
やや良い	**0.88**	**0.90**	**0.89**	18,935
変わらない	**0.87**	**0.86**	**0.86**	41,602
やや悪い	**0.77**	**0.81**	**0.79**	23,866
悪い	**0.76**	**0.67**	**0.71**	8,427
Total	**0.806**	**0.764**	**0.78**	94,545

4. まとめ

本研究では、[Devlin 18] の BERT モデルを Wikipedia 日本語版 [Wikimedia Foundation] と SentencePiece を用いて学習し、その事前モデルを用いて内閣府の景気ウォッチャー指標を学習したセンチメント分析を行った。BERT モデルを使用することで、先行研究である [山本 16] のモデルと比較して、適合率・再現率・F 値の改善を確認した。日本語の経済テキストデータによるセンチメント分析においても、BERT モデルによる事前学習の有効性を確認することができたことから、他の応用事例においても活用が期待できるだろう。

参考文献

[Chen 15] Chen, K.-Y., Liu, S.-H., Chen, B., Wang, H.-M., Jan, E.-E., Hsu, W.-L., and Chen, H.-H.: Extractive broadcast news summarization leveraging recurrent neural network language modeling techniques, *IEEE Transactions on Audio, Speech, and Language Processing*, Vol. 23, No. 8, pp. 1322–1334 (2015)

[Devlin 18] Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K.: Bert: Pre-training of deep bidirectional transformers for language understanding, *arXiv preprint arXiv:1810.04805* (2018)

[Kudo 18] Kudo, T.: Subword Regularization: Improving Neural Network Translation Models with Multiple Subword Candidates, *arXiv preprint arXiv:1804.10959* (2018)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient estimation of word representations in vector space, *arXiv preprint arXiv:1301.3781* (2013)

[Pang 02] Pang, B., Lee, L., and Vaithyanathan, S.: Thumbs up?: sentiment classification using machine learning techniques, in *Proceedings of the ACL-02 conference on Empirical methods in natural language processing-Volume 10*, pp. 79–86Association for Computational Linguistics (2002)

[Turney 02] Turney, P. D.: Thumbs up or thumbs down?: semantic orientation applied to unsupervised classification of reviews, in *Proceedings of the 40th annual meeting on association for computational linguistics*, pp. 417–424Association for Computational Linguistics (2002)

[Vaswani 17] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I.: Attention is all you need, in *Advances in Neural Information Processing Systems*, pp. 5998–6008 (2017)

[Wikimedia Foundation] Wikimedia Foundation, I.: Wikipedia 日本語版: `https://ja.wikipedia.org/`

[山本 16] 山本裕樹, 松尾豊 : 景気ウォッチャー調査の深層学習を用いた金融レポートの指数化, in *The 30th Annual Conference of the Japanese Society for Artificial Intelligence*, pp. 1–4 (2016)

[内閣] 内閣府 : 景気ウォッチャー調査 : `http://www5.cao.go.jp/keizai3/watcher/watcher_menu.html`

[和泉 17] 和泉潔, 坂地泰紀, 伊藤友貴, 伊藤諒 : 金融テキストマイニングの最新技術動向, 証券アナリストジャーナル』, 日本証券アナリスト協会, Vol. 55, No. 10, pp. 28–36 (2017)

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

経済因果チェーン検索のシステム紹介と応用
Economic Causal Chain Search System and its Application

和泉　潔[*1]
Kiyoshi Izumi

坂地　泰紀[*1]
Hiroki Sakaji

[*1] 東京大学大学院工学系研究科 システム創成学専攻
Department of Systems Innovation, School of Engineering, the University of Tokyo

In this research, we introduce a system for searching causal relationships of events related to economics and finance in a chain-like manner from a database extracted from economic text data. This system also introduces service application ideas such as inferring economic ripple effects from events entered by users and presenting related stocks tracing the causal chain from news articles.

1. はじめに

経済ニュース記事を読んでいると，株価の動きや商品の売り上げ，雇用や貿易など様々な経済事象に関する原因と結果の関係の記述がよく出てくる．例えば「将来の少子高齢化が○○を引き起こし，それに関連した○○に関する需要が増えることが予想される」とか「現在の株価下落は○○による市場参加者のリスク警戒心理の高まりを反映している」など，ある事象の経済的な波及効果やその事象の原因について述べている．

しかし経済現象のように人間の行動が関係する事象の因果関係を，数値データだけから統計的に解析することは難しい．なぜなら，人間が原因事象をどのように認識して，それに対してどのような行動を取るのかという行動ルールが因果関係の鍵となっているからである．時と場合によって因果関係が変化する．自然科学的現象のように数値データの統計分析で，客観的かつ普遍的な因果系列を取り出すことはほぼ不可能である．

そこで，本研究では人間が認識した因果関係が含まれていると思われる経済テキストデータを解析し，経済分野に関わる因果関係のデータベースを構築する．さらに，特定の事象を表すフレーズから派生する因果系列を検索する手法を開発する．本手法を用いて，ユーザが入力した語句に対して因果系列を表示し，ユーザが適切な系列に選択したり適切でない系列を削除したりできるシステムを実装した．本システムで作成された因果チェーン，経済的な波及効果と要因列挙が可能となる．

本稿では，因果チェーン検索システムと，本システムやアルゴリズムを用いた応用例を紹介する．

2. 経済的因果関係の抽出とデータベース構築

人間が認知した因果関係について記述されたテキストデータを解析し，そこから因果関係を抽出する技術が必要となる．本システムでは，決算短信という上場企業が業績や財務状況を開示するために定期的に発行しているテキストから，手がかり表現を用いた手法[坂地 2015]により因果関係を抽出した．

- 使用したテキストデータ:2012 年 10 月から 2018 年 5 月に約 2,300 社が発行した約 2 万個の決算短信テキスト
- 抽出した因果関係:1,078,542 個

抽出された因果関係は，決算短信の発行された日付，決算短信を発行した銘柄などと一緒にデータベースに保存される．

3. 因果チェーンの構築アルゴリズム

上述の経済因果データベースから，特定の語句から関連する因果系列を構築する手法には，[西村 2018][Nishimura 2018]を基に改良した手法を用いた．具体的には以下の 4 ステップからなる(図 1).

1. ユーザがフレーズを入力する．最初は終端ノードを入力テキストとする．
2. 終端ノードの表現と一定の類似性がある因果関係を経済因果データベースから選択し，ネットワーク追加候補とする．
3. Step 2 で抽出したネットワーク追加候補と終端ノードの組み合わせについて因果関係ノード間の類似度を計算する.因果関係ノード間の類似度が閾値 α 以上あるときにノードをネットワークに追加してネットワークを拡張する．
4. Step 3 でネットワークに追加したノードを終端ノードとして Step 2, Step 3 を繰り返す．

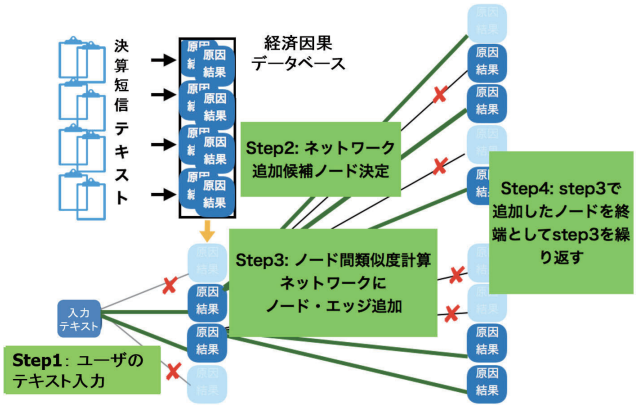


図 1. 因果チェーン構築のアルゴリズム
([西村 2018] [Nishimura 2018]を基に作成)

4. 経済因果チェーン検索システム

上述の因果チェーン構築アルゴリズムを基に，ユーザが提示された因果関係を編集できる機能を加えた経済因果チェーン検索システムを実装した[1][坂地 2018]. 以下に本システムの動作する様子を説明する．

連絡先：和泉　潔，東京大学大学院工学系研究科，
izumi-sec@socsim.org

[1] 本システムは 2019 年 3 月より東京大学 和泉研究室のサイト (http://socsim.t.u-tokyo.ac.jp)にて公開予定である．

最初に開始テキストをユーザが入力する(図 2). その際に, 原因から結果への波及効果の検索か結果から原因への要因検索かを指定する. さらに, 因果チェーンを構築する対象となる因果関係が発行された期間を限定することも可能である.

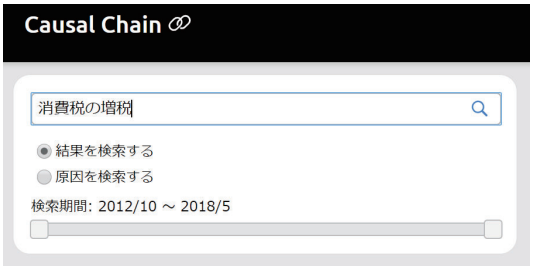


図 2. 開始テキストを入力するテキストボックス

テキストボックスの右にある検索ボタンをクリックすると, 開始テキストに連鎖する因果関係を表示する(図 3). デフォルトでは関連性の高い順に 3 個の因果関係を表示する. より多くの因果関係を見たければ,「もっと見る」ボタンをクリックし因果関係ノードの表示を増やすことが出来る. 因果関係の各ノードに対して, ユーザが適切な因果でないと判断した場合は, 各ノードの右上にある削除ボタンを押して, ノードを削除できる.

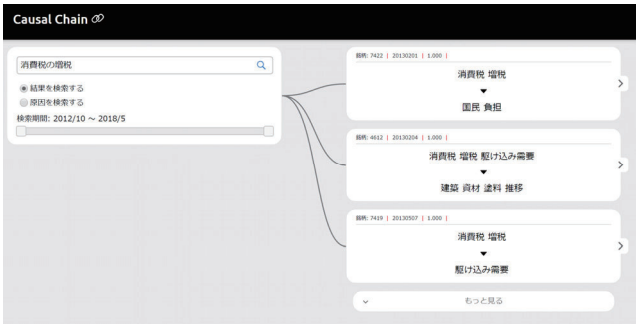


図 3. 連鎖する因果関係の表示

各ノードからさらに因果チェーンを伸ばしたい場合は, 各ノードの右側にある「>」ボタンをクリックすると, クリックされたノードを終端ノードとして関連する因果関係が追加される(図 4).



図 4. 因果チェーンの追加

上記の因果チェーンの構築作業を繰り返し, ユーザが必要とする因果チェーンを構築できたら, 構築した因果チェーンをファイルに保存することが出来る.

5. 経済因果チェーン検索システムの応用例

経済因果チェーン検索システムや因果チェーン検索アルゴリズムを応用したサービスの例を以下に示す.

5.1 個人投資家向けサービス

一般の個人投資家, 特に資産運用を始めたばかりの個人投資家には, 資産運用を判断するための情報が難解であることがある. この難解さの原因の一つとして, 自分たちが日常生活で得てきた知識と金融の専門的な知識との間に大きなギャップがあることである. 日常的な事象から金融市場動向へは, いくつかの経済事象の因果関係の連鎖が存在する. 提案手法により, このギャップを埋めるような知識を提供するサービスを実装できる.

(1) ニュース内容の波及効果と背景情報の提示

ユーザが日常的に見るニュース記事の中に気になる語句があれば, そこを指定しその語句から派生して関連する経済事象を本手法により提示することができる(図 5). 波及効果の中には, ある企業の業績や経営状況に直接関わる事象も含まれるので, ユーザが様々なニュースから関連銘柄を検索するサービスを構築することが可能である. また, 逆に指定した語句の要因となり得る事象を検索してユーザに表示することもできる.

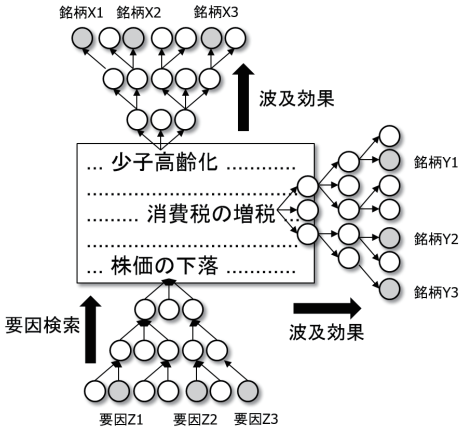


図 5. ニュース内容の波及効果と背景情報の提示サービス

(2) 質問応答システム

金融機関が個人投資家向けに提供する対話エージェントサービスに提案手法を応用可能である. 個人投資家があまり金融専門知識を有していない場合, 対話システムのエージェントに対して, 質問をしてくる場面が多くなると考えられる. 自分の経験や興味に関連する一般的な話題を切り口にして, 関連する経済事象や銘柄を質問してきた場合に, 提案手法により関連しうる事象や銘柄と, なぜ関連すると考えられるかを答えることができる(図 6). また, 事象を引き起こした要因も返答できる.

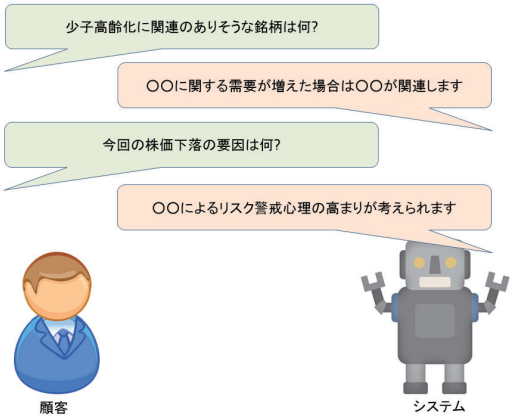


図 6. 個人投資家向けの質問応答システム

5.2 金融実務家向けの業務支援

提案手法により，アナリストや営業担当者など金融機関の様々な部門の実務者の業務支援システムを構築することができる．

(1) レポート作成支援

金融機関のアナリストは，顧客向けに特定の銘柄や市場全体の動向に関するレポートを定期的に発行する．提案手法により，アナリストがレポートを作成する際のコンテンツを決めることを支援することができる．例えば，ある事象から解説対象の市場に対して何か波及効果がなかったかを検索し，レポートにこの事象を書くべきかどうか決める．また，ある市場の動きに対して，潜在的な要因を検索し，レポートに書くべき要因に漏れがないかどうかをチェックできる．他にも，ある事象 X が別の事象 Y を引き起こすとレポートに書いた場合に，事象 X から事象 Y への因果系列を検索して，因果の飛躍がないかどうかチェックすることができる．途中にある因果系列のステップ数が長い場合には，途中の因果の一部をレポートに追記して，読者に理解しやすいようにする．

(2) セールス支援

上述の個人投資家向けの質問応答システムと同様の機能で，金融機関の営業担当者が顧客にセールスを行う際に，顧客の興味や関心と関連する銘柄を検索することができる．顧客の属性や興味に関連してあらかじめ関連銘柄を検索しておけば，営業活動の支援となり得る．また，顧客からの質問に対しても，上述の質問応答システムで，返答すべき内容の候補を得ることができる．このような対面営業以外でも，オンライン上での資産運用アドバイスで，基本的な相談であれば本手法により自動化を支援することができる．

5.3 多種の因果データベースとの連鎖

決算短信以外のテキストデータから因果関係データベースを構築し，多様な分野の因果データベースを組み合わせることによって，以下のような解析や応用をすることができる．

(1) 業務報告書・社内文書

各企業には，通常業務において担当者が作成した社内文章が存在する．例えば，金融機関では営業部門や融資部門が対応した顧客に関して，業務報告書や稟議報告書などを作成している．また，アナリストやトレーダーなどの市場の専門家が，作成した相場見通しに関する定期的な分析レポートもある．このような今までの業務で蓄積された社内文章には，有用な業務知識や専門知識が多く含まれおり，大量に集めて解析することによりデータを保有する独自の知識として高い価値を有することがある．例えば，地域の金融機関の業務報告書を機械学習手法で解析し，その地域の詳細な経済活動指標を作成した例がある [坂地 2019]．同様に，本提案手法を用いて，その企業しか持っていない社内文章から因果データベースを構築し，決算短信などの一般的な文章からの因果データベースと組み合わせれば，その企業の独自知識を活用した新たな因果系列を探索できる．

(2) 特許文書

金融以外の分野でも，有用な因果データベースを構築できるテキストデータは多数ある．例えば特許文書の中には，特定の技術がどのような効果をもたらすのかという因果関係の情報が多く含まれている．特許文書から構築した因果データベースを用いて，因果チェーンを探索すれば，複数の技術の組み合わせによりどのような効果が期待できるかということを見つけることができる．また，特許文書の因果データベースと経済分野の因果データベースを合わせれば，技術の経済的波及効果や技術に対するニーズを調べることができる．

(3) ミッシングリンクの発見

上述の経済や技術分野だけでなく，より一般的な分野での因果関係をニューステキストなどから構築し，これらの因果データベースを組み合わせれば，現在は存在していない重要な因果関係を探索することができる．現状 X から開始した波及効果 $\{x_1, x_2, .., x_n\}$ を検索する．次に，達成したい状況 Y から因果関係を遡って要因 $\{y_1, y_2, \ldots, y_m\}$ を検索する．最後に，x_i と y_j の組み合わせについて，x_i を原因として y_j が結果となるような現象や技術がないかを検討してみる．こうすることによって，目標状況 Y を達成するために，現在は存在しないが重要な技術や現象を発見することを支援できる．

6. まとめ

本研究では，経済・金融に関わる事象の因果関係を，経済テキストデータから抽出したデータベースから連鎖的に検索するシステムの紹介をした．本システムにより，ユーザが入力したイベントからの経済的な波及効果を推論したり，ニュース記事からの因果チェーンをたどった関連銘柄を提示したりするなどのサービス応用のアイデアを紹介した．

謝辞

本システムを実装するにあたって，日名 洋平 氏と松田 健児 氏に多大な助力をいただいた．ここに深謝の意を表する．

参考文献

[坂地 2015] 坂地 泰紀, 酒井 浩之, 増山 茂: 決算短信 pdf からの原因・結果表現の抽出, 電子情報通信学会論文誌 D, vol. 98, no.5, pp.811-822, 2015.

[西村 2018] 西村 弘平, 坂地 泰紀, 和泉 潔: ベクトル表現を用いた因果関係連鎖の抽出, 人工知能学会 第 20 回金融情報学研究会, pp.50-53, 2018 年 3 月.

[Nishimura 2018] K. Nishumura, H. Sakaji, K. Izumi: Creation of Causal Relation Network using Semantic Similarity, 第 32 回人工知能学会全国大会, p. 1P104, 2018 年 6 月.

[坂地 2018] 坂地 泰紀, 和泉 潔, 松島 裕康: 金融テキストマイニングの基づいた投資家支援プラットフォームの開発, 人工知能学会 第 21 回金融情報学研究会, 2018 年 10 月.

[坂地 2019] 坂地 泰紀, 和泉 潔, 松島 裕康, 川瀬 和哉, 林 寛, 接触履歴を用いた地域景況インデックスの自動生成, 日本知能情報ファジィ学会誌 (to be appeared)

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

主成分分析による高頻度データ内のリスクファクター抽出手法

Estimating Risk Factors with High Frequency Data through Principle Component Analysis

那須 健太郎[*1] 山下 泰央[*1] 高橋 大志[*2]
Kentaro Nasu Yasuo Yamashita Hiroshi Takahashi

[*1] 三井住友トラスト・アセットマネジメント株式会社
SUMITOMO MITSUI TRUST ASSET MANAGEMENT CO., LTD.

[*2] 慶應義塾大学大学院経営管理研究科
Graduate School of Business Administration, Keio University

This paper proposes a unique estimation method of Jump Factor with high frequency data. Our method employs bi-power variation technique and principle component analysis. Proposed method is unique and exhibits a new measure for financial risk. In this study, we calculated four Jump Factors in United States and Germany and integrated them through principle component analysis. In addition, we could confirm the influence of Jump Factors on financial markets by using the proposed method.

1. はじめに

これまでの研究から債券の超過リターンは金利の期間構造が持つ情報によってある程度予測可能であることが知られている。[Fama 87]は、n 年フォワード・レートと 1 年債利回りのスプレッド(フォワード・スプレッド)が、n 年債の超過リターンの挙動を予測することを示した。[Campbell 91]は、n 年債と 1 年債のイールド・スプレッドが n 年債投資の超過リターンを予測することを示した。[Fama 87]や[Campbell 91]が、各年限の債券の超過リターンを、それぞれの年限のフォワード・スプレッドやイールド・スプレッドに関連付けたのに対し、[Cochrane 05]は、同一のフォワード・レートの線形集合によって、様々な年限の債券の超過リターンを高い精度で予測することが可能であることを示した。具体的には、フォワード・レートの線形集合によって、債券の超過リターンの予測を試み、回帰モデルの自由度調整済み決定係数が 0.37 に達することを確認した。

日本においては、[作道 10] が、1991 年から 2010 年の日本市場のデータを用いて[Cochrane 05]と同様の分析を行った。その結果、回帰モデルの自由度調整済み決定係数が 0.68 であり、日本においてもフォワード・レートの線形集合によって債券の超過リターンを予測できることを確認した。近年では、[Cochrane 05]をベンチマークに、その予測力を上回るモデルの構築を目的とした研究が行われている。[Ludvigson 09]は、マクロ経済の共通成分とフォワード・レートの線形集合を組み合わせた 2 ファクター・モデルが、[Cochrane 05]のモデルの予測力を上回ることを示した。

また、[岩永 17] は、海外で分析された[Cochrane 05]の予測力を上回るモデルの中から、[Wright 07]が米国市場のジャンプ・ファクターを用いた分析に倣い、日本市場の分析を行い、[Cochrane 05]のモデルの予測力を上回ることを示した([Barndorff-Nielsen 04] が提唱する bi-power variation technique という手法によってジャンプ・ファクターを評価する方法を使用)。その後、[井形 18] は、ジャンプ・ファクターがグローバル債券市場に与える影響について分析を行い、米国株式市場の影響が、米国以外の先進国およびエマージング国の債券市場に波及することを示し、波及の仕方に資本規制が影響している可能性を指摘した。

本稿では、先行研究を踏まえ、さらなるジャンプ・ファクターの活用余地を探るため、ジャンプ・ファクターの計測システムの構築そのものに焦点を当てた研究を行った。まずは、[Wright 07] の分析に倣い、米国市場とドイツ市場のジャンプ・ファクター計測システムを構築した。そのうえで、[岩永 17] や[井形 18] ではジャンプ・ファクターが 4 種類計測されていたが、これらのジャンプ・ファクターに主成分分析を行い、第一主成分を抽出した。これにより、各国のジャンプ・ファクターの比較や分析などを容易にし、新たな知見が得られないか検証した。

本稿の構成は次の通りである。第 2 章では、[Barndorff-Nielsen 04]が提唱する bi-power variation technique という手法によってジャンプ・ファクターを評価する方法について説明する。第 3 章では、本稿の分析手法と結果について説明する。第 4 章では、本稿の分析結果の総括を行う。

2. ジャンプ・ファクターの評価

価格変動の中からジャンプという事象のみを抽出する方法として、[Barndorff-Nielsen 04] が提唱した bi-power variation technique という手法がある。このアプローチは、日中の価格変動全体の分散を通常変動成分とジャンプ成分に区別することで、ジャンプが発生した日を特定し、発生したジャンプの大きさを測定する。[Barndorff-Nielsen 04] は 2 種類の尺度を提唱し、それぞれ realized variance(RV) と realized bi-power variation(BV)と名付け、以下の通り定義した。

$$RV_t \equiv \sum_{j=1}^{m} \left| r_{t,j} \right|^2$$

$$BV_t \equiv \frac{\pi}{2} \frac{m}{m-1} \sum_{j=2}^{m} \left| r_{t,j} \right| \left| r_{t,j-1} \right|$$

ただし、r は t 時点の日中の j 番目のリターン、m は日中の時点数を表す。RV は、時点 t における価格変動全体の分散を表し、BV はその中の通常変動部分のみからなる分散を表している。このため、両者の差分がジャンプ成分からなる分散に該当する。両者の差分がゼロであれば、ジャンプは生じていない。一

連絡先:那須健太郎, 三井住友トラスト・アセットマネジメント株式会社, 東京都港区芝公園一丁目 1 番 1 号住友不動産御成門タワー, Nasu_Kentaro@smtb.jp

方、両者の差分が極めて大きい場合には、ジャンプが生じていると判断される。ジャンプが生じているか否かを判断するために、以下の指標を用いる。

$$RJ_t = \frac{RV_t - BV_t}{RV_t}$$

[Barndorff-Nielsen 04]の手法の優れている点は、RJ に確率分布が与えられている点が挙げられ、これにより統計的に有意にジャンプが生じたか否かを判別することが可能となる。具体的には、RJ を正規化した以下の ZJ が標準正規分布に従うことが知られている。

$$ZJ_t \equiv \frac{RJ_t}{\sqrt{\left[\left(\frac{\pi}{2}\right)^2 + \pi - 5\right]\frac{1}{m}\max\left(1, \frac{TP_t}{BV_t^2}\right)}} \to N(0,1)$$

$$TP_t \equiv m\mu_{4/3}^{-3}\frac{m}{m-2}\sum_{j=3}^{m}\left|r_{t,j-2}\right|^{4/3}\left|r_{t,j-1}\right|^{4/3}\left|r_{t,j}\right|^{4/3}$$

$$\mu_k \equiv 2^{k/2}\frac{\Gamma\left(\frac{k+1}{2}\right)}{\Gamma\left(\frac{1}{2}\right)}$$

z検定において、ZJ がゼロであるという帰無仮説を棄却できなければ、t 時点ではジャンプは生じていなかったものとみなす。棄却できた日については、下式で表わされる大きさ J のジャンプが生じたものとみなす。

$$J_t = sign(r_t)\times\sqrt{(RV_t - BV_t)\times I_{(ZJ_t \geq \Phi_\alpha^{-1})}}$$

ここで Φ は、標準正規分布の累積分布関数、α は Z 検定有意水準、I は日中にジャンプが生じたときのみ 1 を返すインディケーター関数である。

日々のデータから抽出されたジャンプサイズ J をもとに h か月ローリングの realized variance および各種ジャンプ・ファクターを下式で定義する。

RV(日中の価格変動全体の分散):

$$RV_t^h = \frac{1}{h\times 22}\sum_{j=0}^{h\times 22-1} RV_{t-j}$$

JI(一定の期間内においてジャンプが生じる確率):

$$JI_t^h = \frac{1}{h\times 22}\sum_{j=0}^{h\times 22-1} D_{t-j}$$

JM(ジャンプサイズの平均値):

$$JM_t^h = \frac{\sum_{j=0}^{h\times 22-1} J_{t-j}D_{t-j}}{\sum_{j=0}^{h\times 22-1} D_{t-j}}$$

JV(ジャンプサイズの標準偏差):

$$JV_t^h = \sqrt{\frac{\sum_{j=0}^{h\times 22-1}\left(J_{t-j} - JM_t^h\right)^2 D_{t-j}}{\sum_{j=0}^{h\times 22-1} D_{t-j}}}$$

ここで、D は時点 t にジャンプがあった場合は 1 を、そうでない場合は 0 を返すインディケーター関数を表す。

3. 分析手法および結果

米国とドイツの代表的株価指数である S&P500 先物と DAX 先物の 5 分刻みデータに、第 2 章で説明した計算方法を用い、RV、JI、JM、JV を求めた。その後、主成分分析を行い、第 1 主成分を抽出した。図 1 は、米国とドイツの第 1 主成分(以下、PC1)について、2004 年 5 月から 2018 年 10 月まで、各月の最大日付をプロットしたものである(各月の最大日付以外の値もあるが、グラフの形状に大きな変化は生じない)。

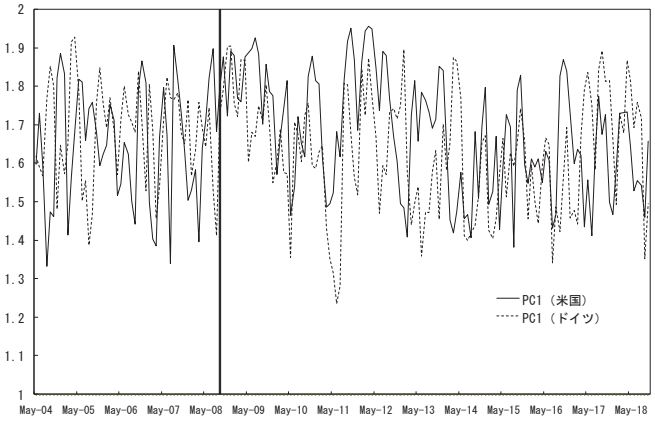


図1 ジャンプ・ファクターの時系列推移(第一主成分)

グラフをみると、リーマンショック前後で、米国とドイツの PC1 について、相関関係が変化している様子がみられる。相関係数をみると、表 1 のとおり、リーマンショック前は逆の相関であったが、リーマンショック後は正の相関があることが確認できた。全期間の相関係数は、リーマンショック後に比べて、低い値であるものの、正の相関であることが確認できた。

よって、リーマンショックを経ることで、ジャンプ・ファクター(リスクファクター)の在り方が変化したことが示唆される。

表1 ジャンプ・ファクター間の相関(米国, ドイツ)

相関係数の計算期間		相関係数
2004年5月から2008年8月	リーマン前 (52か月間)	-0.19
2008年9月から2012年12月	リーマン後 (52か月間)	0.50
2004年5月から2018年10月	全期間 (174か月)	0.13

4. まとめ

本稿では、先行研究を踏まえ、さらなるジャンプ・ファクターの活用余地を探るため、ジャンプ・ファクターの計測システムの構築手法そのものに焦点を当てた研究を行った。まずは、米国市場とドイツ市場のジャンプ・ファクターを計測した。従来、ジャンプ・ファクターが 4 種類計測されていたが、これらのジャンプ・ファクターに主成分分析を行い、第一主成分を抽出し、1 つの指標に纏める、ジャンプ・ファクター計測システムを構築した。これにより、ジャンプ・ファクターの主要成分の分析・比較を容易にし、新たな知見が得られないか検証した。検証の結果、リーマンショック前後で、ジャンプ・ファクター(リスクファクター)の在り方が変化したことが示唆された。今後は、本稿で提案したジャンプ・ファクターをもとに、債券の超過リターンの予測精度の向上や、ジャ

ンプ・ファクターが与える影響の国別・期間別分析など、さらなる分析が進められることを期待している。

参考文献

[井形 18] 井形宣一朗, 菅愛子, 高橋大志: グローバル債券市場とジャンプ・ファクター, 日本ファイナンス学会第 26 回大会予稿集, 日本ファイナンス学会 (2018)

[岩永 17] 岩永安浩: 高頻度データを用いた債券超過リターンの予測, 証券アナリストジャーナル, 55(4), pp.72-82 (2017)

[作道 10] 作道俊夫:金利のリスクプレミア, 証券アナリストジャーナル, 48(8), pp.5-13 (2010)

[Barndorff-Nielsen 04] Barndorff-Nielsen, O. and N. Shephard: Power and Bipower Variation with Stochastic Volatility and Jumps , Journal of Financial Econometrics, 2, pp.1-37 (2004)

[Campbell 91] Campbell, J. Y. and R. J. Shiller: Yield Spreads and Interest Rate Movements:A Bird's Eye View, Review of Economic Studies, 95, pp.138-160 (1991)

[Cochrane 05] Cochrane, J. H. and M. Piazzesi: Bond Risk Premia , American Economic Review , 95, pp.138-160 (2005)

[Diebold 95] Diebold, F. X. and R. S. Mariano: Comparing Predictive Accuracy , Journal of Business and Economic Statistics, 13, pp.253-263 (1995)

[Fama 87] Fama, E. F. and R. R. Bliss: The Information in Long-Maturity Forward Rates , American Economic Review, 77, pp.680-692 (1987)

[Ludvigson 09] Ludvigson, S. C. and S. Ng: Macro Factors in Bond Risk Premia, Review of Financial Studies, 22, pp.5027-5067 (2009)

[Wright 07] Wright, J. H. and H. Zhou: Bond Risk Premia and Realised Jump Volatility , Working Paper, Federal Reserve Board (2007)

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

Account-Based Marketing のためのターゲット企業推薦システムの構築

Development of A Target Company Recommendation System for Account-Based Marketing

早川 敦士[*1]
Atsushi Hayakawa

北内 啓[*1]
Akira Kitauchi

[*1] 株式会社 FORCAS
FORCAS, Inc.

In this paper, we developed a system for the new B2B marketing method ABM (account-based marketing). The system recommends target companies as future potential customers by analyzing current customers. There are two requirements in recommending target companies. (1) Users can grasp the impact of future importance on prediction score. (2) Users can update the model by modifying the importance of features without affecting that of other features. We propose a model that extends Naive Bayes classifier with a modified smoothing method. The experimental results show that the classification accuracy of our proposed model achieves AUC equal to or better than logistic regression and GBDT.

1. はじめに

新しい B2B マーケティング手法として ABM（account-based marketing，アカウントベースドマーケティング）の活用が広がっている．アメリカに本社をおくアドバイザリーファーム ITSMA が 2003 年に ABM を初めて提唱した [Bev 17]．2010 年頃よりアメリカで注目され始め，ABM に特化したソリューションが誕生している [庭山 16]．シンフォニーマーケティング株式会社は「全社の顧客情報を統合し，マーケティングと営業の連携によって，定義されたターゲットアカウントからの売り上げ最大化を目指す戦略的マーケティング」と ABM を定義している [シンフォニーマーケティング 19]．株式会社 FORCAS 代表の佐久間は ABM を「ターゲットアカウントを定義し，アカウント別に営業，マーケティング情報を集約・分析し，アカウント別に営業，マーケティング組織を再編成し，ターゲットアカウントの LTV 最大化を目指すマーケティング」と位置づけている [佐久間 17]．従来のデマンドジェネレーション（マーケティング活動において営業部門への見込み顧客を渡す活動全般）は個人に集中して実施されていたのに対し，ABM ではターゲットとなるアカウント（企業）に集中して実施するのが大きな違いである [庭山 16]．

成約確度が高いと推測されるターゲット企業の特定には，自社の営業データ（特に成約済みの顧客データ）と豊富な属性データをもつ企業マスターデータが必要となる．属性データとしては，従業員数，業種，上場/非上場など企業の規模や種別を表すファーモグラフィックと呼ばれるデータがよく利用されるが，企業が利用するサービス，求人の募集職種といった行動解析的なデータも有用である．これらのデータを組み合わせたマーケティング活動を実施することで営業の生産性を向上する企業が増えてきており，ABM の重要性が高まっている．

我々は，成約済みの企業データ（以下，既存顧客データとよぶ）を分析して既存顧客以外の企業（以下，潜在企業とよぶ）の中から成約確度の高い企業をターゲット企業として推薦するシステムを構築した．ターゲット企業の推薦を分類タスクととらえ，ナイーブベイズを用いて特徴量の重要度を算出し，さらにスムージングによって補正することで，推薦するターゲット企業の根拠を解釈しやすい指標とともに提示することが可能となる．また，ユーザーが特徴量の重要度を変更でき，他の特徴量に影響を与えずに潜在企業の予測スコアを再計算することも可能となる．提案手法の分類精度を評価し，特徴量間の依存関係を考慮するロジスティック回帰，GBDT と同等以上の精度を達成することを確認する．

連絡先：早川敦士，株式会社 FORCAS，
atsushi.hayakawa@uzabase.com

2. システムの概要

本システムの構成を図 1 に示す．システムは大きく 3 つのステップからなる．(1) ユーザーがアップロードした既存顧客データを名寄せ処理によりシステム内の企業マスターデータと紐づけ，ファーモグラフィックデータおよび行動解析的なデータを特徴量としてモデルを学習する．(2) モデルをもとに潜在企業の成約確度を企業スコアとして予測し，予測スコアの高い順に提示することでターゲット企業を推薦する．また各企業がもつ特徴量を重要度とともに提示することで，その企業が推薦された根拠をユーザーが理解できる．(3) マーケターの経験や意思に応じてユーザーが特徴量の重要度を変更でき，その変更内容をもとにモデルを再学習して潜在企業の予測スコアを更新する．

本システムが上記の 3 つのステップを持つ理由を述べる．(1) 日本国内には同名の企業が存在したり，ユーザーが管理する既存顧客データにおける企業名とシステム内で管理する企業名の表記が異なる場合がある．アップロードされた各既存企業を一意に特定するために，企業名，所在地，電話番号，法人番号などの情報を用いて名寄せする必要がある．名寄せ後は企業マスターデータと既存顧客データの対応付けができているので，モデルの学習に必要なデータを作ることができる．(2) ターゲット企業に集中し，優先順位をつけるために必要な予測スコアである．(3) 既存顧客の中には，経営者どうしが親しいなどの外部要因による獲得や，現在とは異なるマーケティング戦略による獲得が含まれている場合がある．そのため，マーケターや営業の意思や経験をターゲット企業の推薦アルゴリズムに反映する仕組みが必要である．既存顧客データから意思や経験に反する企業を除外する方法では，企業に結びつく特徴量は複数存在するので戦略上重要な特徴量も同時に失う可能性がある．既存顧客データに存在しない特徴量を重視するような戦略をモデルに反映することもできない．したがって，特徴量の重要度を直接変更する方法を提案する．

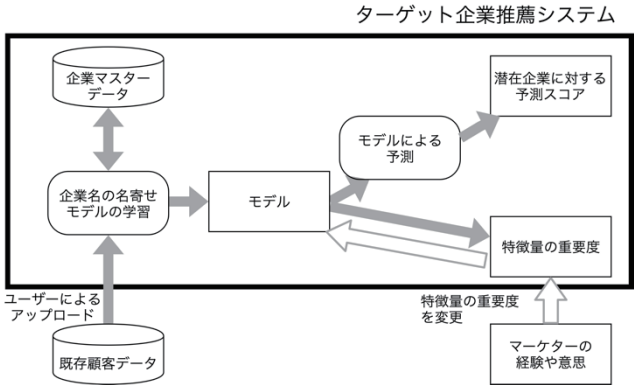


図 1: ターゲット企業推薦システムの構成

3. 問題設定

本システムにおいて，自社の既存顧客データを用いてターゲット企業を推薦する際に生じる以下の課題を解決する手法を提案する．なお，ターゲット企業の推薦には分類，回帰，協調フィルタリングなど様々な手法が存在するが，本研究では 2 値分類タスクととらえ，分類スコアをもとに潜在企業の予測スコアを算出する．また，企業の属性データのほとんどが質的データであるため，従業員数等の量的データを 2 値データに変換することで，すべての特徴量を 2 値データとして扱う．

課題 1. 特徴量の重要度が予測スコアの増減に与える影響を解釈しやすいこと
課題 2. 推定時に各特徴量が相互に影響を与えないこと

前述の通り，本システムではターゲット企業がもつ特徴量の重要度を予測スコアの根拠として提示する．推薦されたターゲット企業をもとに営業活動を行う際，その根拠が明確で理解しやすいことが重要である．ABM ではマーケターと営業の連携が不可欠となる．マーケターから営業にターゲット企業のリストを提供したとき，その根拠が明確でないと，営業側が押し付けられたと感じるなど信頼を得にくい．明確な根拠があれば，適切な営業手段を選択できる．そのためには，重要度が予測スコアの増減に与える影響を解釈しやすいことが望ましい（課題 1）．また，特徴量どうしの依存関係がある場合でも，特徴量単体でどの程度重要かが分かるような指標がよい．すなわち，推定時に他の特徴量の影響を受けないモデルがよい（課題 2）．

また，ある特徴量の重要度を変更したときに，他の特徴量の重要度も変更されてしまうと，マーケターや営業の意思や経験をうまく反映することができない．したがって，他の特徴量に影響を与えずに潜在企業の予測スコアを再計算できるモデルが必要となる（課題 2）．

4. 関連研究

河村らは，勘と経験に頼っていた営業を置き換えるために，機械学習を用いて申込み顧客リストを作成することによって営業の効率化を支援する推薦モデルを提案した [河村 17]．この研究では，ベテランな営業への聞き取り調査を 2 度実施した．1 度目の調査により作成した特徴量に基づくモデルに対しての推定結果を掲示し，フィードバック（2 度目の調査）を得て特徴量を作り，営業の経験を加味したモデルを構築した．特徴量の追加は，現在のマーケティング戦略に基づくターゲット企業の予測精度向上には貢献するが，マーケティング戦略を変更した場合の予測スコア算出には対応できず，課題 2 を解決できない．

Takahama らは，人の知識をモデルに反映する研究として，誤分類されやすい画像データを分類できるようにするためにクラウドワーカーに対して特徴量定義に一致するかどうかを答えさせて特徴ベクトルを作成した [Takahama 18]．この方法では，提示された企業の属性情報を確認しなければ，自社のマーケティング戦略に一致するかを判断できず，課題 2 に対応できない．つまり，属性情報を個別に判断しているのと同等である．意思や経験を組み込む必要があり現在のデータで解決できない問題に対しては，所与のデータを超えた一般化を実現するために，そのデータを超えた知識や仮説を学習者は盛り込む必要があるとしている [Domingos 12]．

前述したように，本研究ではターゲット企業の推薦を 2 値分類タスクととらえる．代表的な分類手法であるロジスティック回帰は回帰係数を特徴量の重要度とし，大きさを変えることによって該当する企業の予測スコアも変えることができ課題 1 の要件を満たすが，回帰係数の推定には他の特徴量の影響を受けるため課題 2 の要件を満たさない．Gradient Boosting Decision Tree（GBDT）も特徴量の重要度を算出できるが，重要度の大きさを意図的に変えることは木の構造を変えることになるので，変えた特徴量の下位ノードに影響を与えてしまい，課題 2 の要件を満たさない．

5. 提案手法

課題 1,2 を解決するため，ナイーブベイズを拡張した手法を用いる．x_iを特徴量として，ナイーブベイズにおけるクラスyの条件付き事後確率は以下となる．

$$P(y|\boldsymbol{x}) = P(y)\prod_i P(x_i|y)$$

既存企業，潜在企業のクラスをそれぞれy_1，y_2とすると，双方の条件付き事後確率の比$R(\boldsymbol{x})$は次式のようになる．この値を潜在企業の予測スコアとする．

$$R(\boldsymbol{x}) = \frac{P(y_1|\boldsymbol{x})}{P(y_2|\boldsymbol{x})} = \frac{P(y_1)\prod_i P(x_i|y_1)}{P(y_2)\prod_i P(x_i|y_2)} = \frac{P(y_1)}{P(y_2)}\prod_i \frac{p(x_1|y_1)}{P(x_1|y_2)}$$

また$R(\boldsymbol{x})$の中の下記の部分$S(x_i)$を特徴x_iの重要度とする．

$$S(x_i) = \frac{P(x_i|y_1)}{P(x_i|y_2)}$$

$S(x_i)$は，既存企業における特徴x_iの生起確率が，潜在企業におけるそれと比べてどの程度大きいかを表す値と言える．$S(x_i)$はx_iのみに依存するため，課題 2 の要件を満たす．なお，$S(x_i)$を人為的に変更した場合，それに応じて$R(x)$も変わり，$S(x_i)$以外の特徴量の重要度には影響を与えない．

$P(x_i|y_j)$は次式によって算出する．

$$P(x_i|y_j) = \frac{N(x_i, y_j)}{N(y_j)} + \alpha$$

$N(x_i, y_j)$はクラスy_jにおいて特徴x_iをもつ企業数，$N(y_j)$はクラスy_jの企業数である．右辺の第 1 項は多変数ベルヌーイモデルでの最尤推定によって導出される値である．α $(0 < \alpha < 1)$はスムージングのための値であり，$N(x_i, y_j)$が小さいほど$S(x_i)$は 1 に近づく．また，既存企業における特徴x_iの生起確率が潜在企業におけるそれと等しい，すなわち$N(x_i, y_1)/N(y_1) = N(x_i, y_2)/N(y_2)$のとき$S(x_i) = 1$となり，スムージングしないとき

と同じ値となる. 上記 2 点の性質から提案手法は課題 1 の要件を満たす.

6. 実験

提案手法がどの程度ターゲット企業を正しく推薦できるかを確認するため, 分類性能を評価した.

6.1 データセット

FORCAS[1]上にある既存顧客データと企業マスターデータを用いる. 企業マスターデータの特徴量は 1,677 種類あり, 従業員数, 外部利用サービス等が含まれる. 従業員数のような数値データはビン分割により2 値データに変換している. 分析対象となる企業は約 12 万社ある. マーケティング戦略の異なる 4 種類の既存顧客データを用意した. それぞれに含まれる企業数は Data1 が 95 社, Data2 が 167 社, Data3 が 349 社, Data4 が 817 社である.

6.2 実験条件

scikit-learn に含まれる分類手法のうち, ラプラススムージングによるナイーブベイズ(NB), ロジスティック回帰(LR), および GBDT の 3 種類を提案手法と比較する. 既存顧客を正例, それ以外を負例として 3 分割の交差検証を行った. 評価尺度には AUC を用いた.

6.3 実験結果

実験結果を表 1 に示す. LR と GBDT は Data1, Data3 において AUC が 0.9 を下回ったのに対し, 提案手法と NB はいずれのデータセットにおいても 0.9 以上であった. 提案手法と NB の AUC は大きな差がなかった. ABM での営業データは既存顧客数が少なく不均衡データであるため, 提案手法の精度が LR, GBDT を上回ったと考える.

表 1: 各手法による AUC の比較

手法	Data1	Data2	Data3	Data4
提案手法	0.929	0.986	0.929	0.920
NB	0.904	0.983	0.916	0.924
LR	0.877	0.985	0.881	0.925
GBDT	0.746	0.989	0.822	0.874

7. おわりに

既存顧客データを分析して成約確度の高い企業をターゲット企業として推薦するシステムを構築した. 本システムは予測したターゲット企業の根拠を解釈しやすく, マーケターの経験や意思をターゲット企業の予測に反映できる特徴をもつ. それらの特徴を実現するため, ナイーブベイズを拡張することで企業の予測スコアを算出し, スムージングにより特徴量の重要度を補正する手法を提案した. 提案手法の有効性を評価した結果, 既存顧客データの数が少ない場合でも精度の高い予測ができることを確認した.

今後は, 特徴量の重要度を変更したときの分類精度についても評価する予定である. たとえば, ある時点までの既存顧客データとそれ以降の既存顧客データの 2 種類を用意し, 前者をもとに算出した特徴量の重要度を変更してターゲット企業を予測し, 後者を用いて評価するといった方法を考えている.

[1] https://www.forcas.com/

参考文献

[Bev 17] Bev Burgess, Dave Munn: A Practitioner's Guide to Account-Based Marketing: Accelerating Growth in Strategic Accounts (English Edition), Kogan Page (2017).

[庭山 16] 庭山一郎: 究極の BtoB マーケティング ABM(アカウントベースドマーケティング, 日経 BP 社 (2016).

[シンフォニーマーケティング 19] 株式会社シンフォニーマーケティング: アカウント・ベースド・マーケティング(ABM)とは, https://www.symphony-marketing.co.jp/abm/about/ (2019-1-17 最終閲覧).

[佐久間 17] 佐久間衡: Account Based Marketing を実践する, MarkeZine 第 21 号 特集「戦略的 BtoB マーケティング」, 翔泳社 (2017).

[河村 17] 河村一輝, 諏訪博彦, 小川祐樹, 荒川豊, 安本慶一, 太田敏澄: 飲食店向け不動産営業を支援する申込み顧客推薦モデルの提案, Web インテリジェンスとインタラクション 2017, 人工知能学会 (2017).

[Takahama 18] Ryusuke Takahama, Yukino Baba,Nobuyuki Shimizu, Sumio Fujita,Hisashi Kashima: AdaFlock: Adaptive Feature Discovery for Human-in-the-Loop Predictive Modeling,The Thirty-Second AAAI Conference on Artificial Intelligence (AAAI-18), pp. 1620-1626 (2018).

[Domingos 12] Domingos, P.: A Few Useful Things to Know About Machine Learning, Communications of the ACM, Vol. 55, No. 10, pp. 78–87 (2012).

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

ライフスタイル分析を用いたIoT珈琲焙煎サービスの品質向上

Service Quality Improvement of IoT Coffee Roasting Service Using Lifestyle Analysis

寺野 真明[*1] 木村 文香[*1] 小澤 順[*2] 西川 由理[*1,2] 竹中 毅[*2] 大浦 楓子[*2,3]
Masaaki Terano Ayaka Kimura Jun Ozawa Yuri Nishikawa Tsuyoshi Takenaka Fuko Oura

[*1] パナソニック株式会社 Panasonic Corporation
[*2] 産業技術総合研究所 National Institute of Advanced Industrial Science and Technology
[*3] 首都大学東京 Tokyo Metropolitan University

Abstract: This paper discusses service improvement by utilizing the lifestyle analysis result of IoT coffee roasting service "The Roast". Through our past research, we have extracted "active life" as the most prominent lifestyle factor by performing factor analysis. As a result of distributing a roasted coffee gift kit to stimulate the desire of such sociable users, more than 80% of inactive users continued to use the service. In addition, the average number of roasting activity after service continuation increased.

1. はじめに

IoT 家電は，メーカーとユーザ間の直接的なチャネルを構築し，利用者に最適なサービスを継続的に提供するインタフェースとして着目されている[岡野原 17]．また，同家電から取得されるログデータがライフスタイル推定の手がかりになることが示されている[Takenaka16]．特に珈琲においては，個人の消費傾向が、嗜好やライフスタイルと強く関連性を有すると考えられる．そこで，IoT 珈琲焙煎機とサブスクリプション型の生豆頒布がセット化された珈琲焙煎サービス “The Roast” において，取得されたログデータ等を利用した著者らのライフスタイルに関する分析も行われている[寺野 18][Terano19]．

本稿では，珈琲焙煎サービスからのライフスタイルの分析結果を活用したサービス品質向上について考察する．特に，サービス開始後，一部のユーザにおいては，サービスに対する満足度低下を示す焙煎機の利用回数等の低下が問題となっている．そこで，IoT 珈琲焙煎機のライフスタイルを利用し，珈琲の焙煎回数が低下しているユーザに対して，サービスを継続させるための施策を実施することで，変化が生じるかについて，実サービスを用いて分析し，その結果について述べる．

2. 珈琲焙煎サービスにおけるライフスタイル分析

2.1 珈琲焙煎サービス The Roast

本稿で対象とする IoT 珈琲焙煎機を用いた珈琲焙煎サービス“The Roast" [Panasonic] について述べる．珈琲の味は，生豆の種類とその生豆に適した焙煎方法（以後「焙煎プロファイル」と述べる）が大きく影響するとされることから，本サービスでは，個々の生豆に対し，焙煎の専門家が作成した焙煎プロファイルを Bluetooth 経由で転送できる家庭用焙煎機を開発し，生豆の定期頒布サービスと共に提供している．

ユーザは焙煎プロファイルをスマートフォン経由で焙煎機に転送することで，ヒーター出力とファン風量が制御でき，専門家による焙煎を自宅で再現できる．同サービスでは，毎月定期頒布される 2〜3 種類の生豆に対し，各々の特性を引き出す数種類の焙煎プロファイルがクラウドから入手可能である[寺野 18]．

連絡先：terano.masaaki@jp.panasonic.com

2.2 顧客のライフスタイル分析

日常生活で用いる IoT 家電から得られるログデータは，ユーザの嗜好や生活パターン等，ユーザの特徴あるいは特性を推定する手がかりとなることが期待される．そして，珈琲をはじめとするユーザの好みが反映されやすい食サービスには，個人の生活環境や生活パターン，さらにそれらのもとで形成される嗜好や価値観との関連が強く現れると考えられ，ユーザのライフスタイルに適したサービスの最適化・パーソナライズ化が一層重要となる．そこで我々は，同サービスを使用するユーザに対するアンケート分析を行い，因子分析から得た 6 つのライフスタイル因子と，焙煎機の操作履歴の関係について検討を行った[Terano19]．

先行研究から得られた 6 つのライフスタイルを，表 1 に示す．珈琲焙煎サービスの利用者は，特に，(A) アクティブ社交性，(C) こだわり消費，(D) 食へのこだわり，(E) 生活不安の因子が，サービス非利用者よりも高く，さらには(C)の因子が高いユーザの焙煎機の使用履歴を分析した結果，それ以外のユーザに比べ，平日・週末にかかわらず，定常的に焙煎機を利用する傾向がある等の知見を得ている．

表 1：珈琲焙煎サービス利用者のライフスタイル因子

ライフスタイル因子	ライフスタイルの特色
(A) アクティブ社交性	自分は社交的だと思う,コミュニケーションや，SNS の情報発信が好き，もてなすことが好き，新しいことを体験するのが好き
(B) 美意識	綺麗・格好良くいたい，ファッションに関心
(C) こだわり消費	高くても健康に良く品質の良いものを選ぶ，インテリアにこだわる
(D) 食へのこだわり	料理が好き，食のノウハウに関心
(E) 生活不安	気分が変わりやすい，飽きっぽい，無駄遣いしやすい，自分の健康に不安，忙しくて時間が取りにくい
(F) 堅実	人の役に立ちたい，できるだけ安い商品，選択肢は多いほうが良い，几帳面である，家計簿をつけている

3. ライフスタイル分析を活用したサービス品質向上の取り組み

3.1 サービス継続性指標の算出と継続施策

各ユーザの機器の利用回数の時系列データを分析することで，本サービスに対する継続性を分析することが可能である．具体的には，焙煎の頻度が高いユーザは本サービスの満足度が高く，逆に購入からの時間の経過とともに焙煎回数が低下しているユーザは満足度が低下していると解釈できる．そこで本研究では，サービス継続性が低下しつつあるユーザを「離脱可能性ユーザ」と定め，ライフスタイル因子を考慮した施策により，ユーザのサービス継続性が向上するかどうかを調べた．

まず，ユーザのサービス継続性指標には，先行研究で定めた指標 *cont_value* を用い，離脱可能性ユーザを抽出した．

$$cont\_value = \frac{\text{直近 2 ヶ月での月平均焙煎回数}}{\text{利用期間全体での月平均焙煎回数}}$$

なお，*cont_value* の値は，0.0 から 1.0 までの毎月算出される値であり，値が小さくなるほど，サービスの離脱可能性が高いユーザであると解釈できる．

2 章で述べたように，ライフスタイルに関する質問を実施した 75 名のうち，6 つのライフスタイル因子を持つ人数を調べている．その結果，(C)こだわり消費，(D)食へのこだわりの因子が高いユーザ多かった．これは，珈琲へのこだわりに起因するものと考えらえる．さらに，特徴的な因子として，(D)の因子と同程度に，(A)アクティブ社交性の因子が高いユーザも多いことが確認された．(A)の因子以外が高いユーザにおいても，(A)の因子を保有しているユーザが多かった．離脱可能性の高いユーザにおいても，(A)の因子を持つユーザが多いと推定される．

(A)アクティブ社交性が高いユーザは，一般的に，新しい体験等を情報発信したり，他人をもてなしたりすることが好きであるという特性を保有する．そこで，全ユーザに対し，焙煎済珈琲豆のプレゼント(ラッピング)用キットを配布する施策を実施し，アクティブ社交性が高くかつ離脱可能性の高いユーザに対する効果を確認した．これは，プレゼント用キットを提供することで，自ら焙煎した珈琲を飲むことによる楽しみだけでなく，焙煎した豆を他人にプレゼントとして贈呈する行為により，改めて関心や満足を誘発する目的がある．ここでは *cont_value*≦0.8 のユーザを離脱可能性が高いと定義した．

3.2 サービス継続施策の効果

2018 年 7 月，2018 年 11 月に，全ユーザにプレゼント用キットを配布した結果，7 月送付ユーザの中でアンケート回答者かつ *cont_value*≦0.8 であるユーザが 34 人存在した．この中で，プレゼントキット配布後，29 人がサービスを継続して利用した．また，11 月送付のユーザにおいては，同様のユーザが 26 人存在し，この中で，21 人がサービスを継続して利用した．この 2 回のプレゼントキット配布の前後で，合計 60 名中 50 名のユーザ(83%のユーザ)がサービスを継続したことになる．

また，サービスを継続したユーザの，施策実施前後の月平均焙煎回数の比較を図1に示す．図 1 より，7 月及び 11 月それぞれアンケート回答者全体で施策の実施前後の月平均焙煎回数が増えている．このうち，*cont_value*≦0.8 のユーザの月平均焙煎回数も施策の実施前後で増えている．さらに，*cont_value*≦0.8 のユーザのうち，アクティブ社交性因子が高いユーザの焙煎回数の増加量は，アンケート回答者全体と比べても高い．

以上により，ライフスタイル分析を活用した施策が，ユーザの満足度向上やサービス継続に対し，一定の効果を持つ可能性があることが確認できた．ただし，この結果の全てがプレゼント用キット配布によるサービス継続施策の効果であるか否かについては，さらなる分析が必要と思われる．

4. まとめ

本論文では，珈琲焙煎サービスの利用者のライフスタイル分析に基づき，利用者の中で特徴的なライフスタイル因子としてアクティブ社交性の因子を抽出し，その因子を持つユーザを対象としたサービス継続施策として，焙煎豆プレゼント用キットの配布サービスを実施した．2 回のプレゼント用キット配布を実施した結果，サービスの離脱可能性の高い 60 名のユーザ中，80%を超えるユーザにおいてサービスの継続が確認できた．特に，離脱可能性が高くかつアクティブ社交性因子が高いユーザが，全体と比較しても施策の実施前後でより焙煎回数が多くなることを確認できた．

今後は，クラウドに蓄積されている利用者のログデータから継続して毎月の焙煎回数・時刻等を分析することで，焙煎が習慣化しているかどうかを抽出することが考えられる．また，焙煎された珈琲の香りや味などの満足度等に関する情報の入力をユーザに促し，サービスに関する関心の度合いの計測を検討している．2018 年 12 月には，精密な焙煎プロファイルがカスタマイズ可能な，上級者向けサービス “The Roast Expert” も開始した．これらのカスタマイズデータをユーザ間で焙煎プロファイルとして共有するコミュニティ作りなども検討している．

参考文献

[Panasonic] Panasonic: The Roast, https://panasonic.jp/roast/.

[Takenaka16] T.Takenaka, Y.Yamamoto, K.Fukuda, A.Kimura, K.Ueda: Enhancing products and services using smart appliance networks, CIRP Annals – Manufacturing Technology, 2016.

[Terano19] M.Terano, A.Kimura, J.Ozawa, Y.Nishikawa, T.Takenaka, F.Oura: Lifestyle analysis with IoT data acquired from coffee roaster for service development, In Proceedings of 2019 IEEE International Conference on Consumer Electronics, 2019.

[岡野原 17] 岡野原: IoT と人工知能に基づく新しい社会; 電子情報通信学会誌, Vol. 100, No. 1, pp.19-24, (2017) .

[寺野 18] 寺野，木村，小澤，西川，竹中，大浦：IoT 焙煎機を用いた珈琲焙煎サービスからのライフスタイル分析，ヒューマンインタフェースシンポジウム 2018, 7D3-4, (2018).

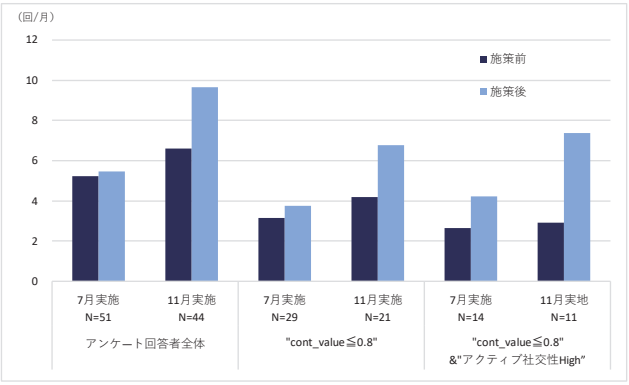


図1 サービス継続者におけるプレゼントキット配布施策前後の月平均焙煎回数の比較

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

多様な動作パターンを有する機器に対応した教師なし異常度推定手法

Unsupervised Anomaly Detection for a Machine Whose Vibration Pattern Changes

小林 一樹 Kazuki Kobayashi　関根 理敏 Masatoshi Sekine　伊加田 恵志 Satoshi Ikada

沖電気工業株式会社 経営基盤本部 研究開発センター
Corporate R&D Center, Corporate Infrastructure Group, Oki Electric Industry Co., Ltd.

In recent years, there have been many activities to solve problems on manufacturing utilizing digital technologies such as IoT and AI. We have been working on research and development of vibration abnormality detection technologies for mechanical devices with various motion patterns, such as robotics arm and printing machines. Our previous method can quantitatively express the degree of motion abnormality of the observation target without performing preprocessing work for extracting vibration data. However, since this method is based on supervised learning which requires both normal and abnormal data, there is a problem that a highly accurate discrimination model can not be built when the abnormal data is insufficient. To address this problem, we propose a new method to improve our traditional method using unsupervised learning. In addition, we also report on the results of the evaluation experiment using the actual machine and show the effectiveness of our proposed method.

1. はじめに

近年, 工場の IoT 化が進められ, AI 技術を利用した製造現場の課題解決に向けた取り組みが活発である [METS 17]. とりわけ, 異常検知を目的とした機器から得られる振動などの各種センサ情報や稼働ログの解析技術は主要な研究分野の 1 つである.

筆者らはこれまでに, アームロボットやプリンタに代表される, 動作部を多く有し, かつ動作箇所が時間で推移する機器 (以下, 多様な動作パターンを有する機器とする) を対象とした振動異常検知技術の研究開発を行ってきた. このような機器は動作パターンごとに正常な振動状態が異なるため, その動作パターンごとに振動データを切り出し, 分類する前処理作業を行い, 分類パターンごとに異常検知を行う必要がある. そのため, ボールネジやタービンのような動作が単調な機器と比べると振動による異常検知が扱いづらいという課題があった. この課題に対し, 筆者らは振動データ切り出しの前処理作業を行わず全ての動作パターンに共通する特徴量の抽出を行い, 得られた特徴量と機器の動作情報の関係を確率モデルで表すことで, 動作パターンの時間的推移を考慮しつつ, 観測対象の動作異常度を定量的に表すことができる手法を提案している [Kobayashi 18]. しかしながら, この手法は機器の異常稼働時の振動データを必要とする教師あり学習であるため, 異常時の振動データが十分に取得できない場合に高精度の判別モデルが学習できないという課題がある.

この課題に対し, 本稿ではこの手法を教師なし学習に改良した振動異常検知手法を提案する. 具体的には, 振動データから特徴量を抽出する際, 変分オートエンコーダ (Variational Autoencoder : VAE) [Francois 18] を用いることで異常時の振動データがなくとも高精度なモデルを学習できるようにする.

連絡先: 沖電気工業株式会社 経営基盤本部 研究開発センター
〒 335-8510 埼玉県蕨市中央 1-16-8 TEL:048-431-2481
e-mail:kobayashi492, sekine566, ikada333@oki.com

2. 従来手法

本章では従来手法として, 前節であげた筆者らの教師あり学習による手法を紹介する. 従来手法は大きく (1) 特徴量抽出部と (2) 異常度推定部 の 2 つから構成される. 以下, 特に重要な特徴量抽出部について説明する. 特徴量抽出部では, まず, 学習データとして振動データのスペクトログラムの平均値と, それに対応する正常振動か異常振動かという正解ラベルをニューラルネットワーク (以下, ネットワークと記す) に与え, 入力されたスペクトログラム平均値の正常・異常を判別するための特徴量を抽出するモデルを学習する. このように, 特徴量抽出部の学習時に振動スペクトログラムの平均情報を与えることにより, 前処理作業を行わずに全ての動作パターンで共通の特徴量を抽出できるモデルが構築できる. しかしながら, この方法での特徴量抽出は機器の異常動作時の振動データを必要とする教師あり学習であるため, 異常動作時のデータ取得が難しい機器に対しては適用が現実的でない.

3. 提案手法

本章では, 教師なし学習による提案手法について説明する. 提案手法では特徴量抽出部において VAE を適用することにより, 教師ラベルのないデータから動作パターンごとに正常振動のモデルを学習する. なお, 異常検知対象となる機器の動作時に発生する振動情報を取得・解析することを想定する.

3.1 変分オートエンコーダ (VAE)

まず, VAE について説明する. VAE は入力されたデータを出力で再現するように学習する Autoencoder (以下, AE) の一種である. AE では入力されたデータから特徴量を抽出することで圧縮 (エンコード) した後, 圧縮した特徴量から入力データと同じ次元数のデータを出力 (デコード) する. その際, 入力データと同じデータを正解データとして用いることで, 教師なしでの特徴量抽出が可能となる.

VAE では入力データが平均:μ, 分散:σ^2 のある確率分布に従うと仮定し, 入力データから特徴量として μ, σ^2 を抽出した後, 入力データと同じデータを出力するように学習する. すなわち, 入力データ z と出力データ $z' = \mu + \log\sigma^2 * \epsilon$ の差が小

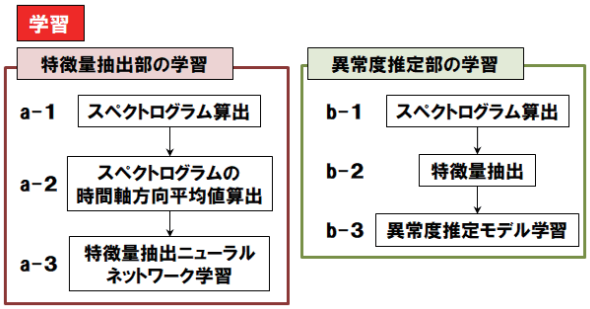


図 1: 学習段階の処理

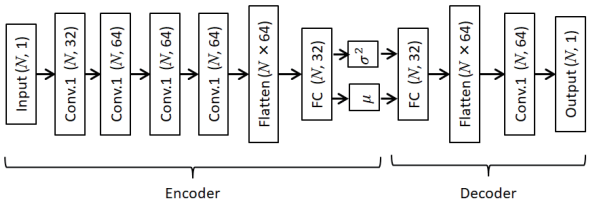


図 2: 変分オートエンコーダを持つ特徴量抽出ニューラルネットワークの構造 (N は入力データの次元数)

さくなるように学習する. (ϵ はランダムパラメータ.) このように, 入力データが確率分布に従うことを仮定することで, 異常度推定に適した特徴量抽出が可能になることが期待できる [Diederik 13][Danilo 14].

3.2 学習方法

本節では, VAE を適用した特徴量抽出部の学習方法と, 特徴量抽出部の出力を入力とする異常度推定部の学習方法について説明する (図 1). 学習用の振動データは機器の正常動作時に取得するものとし, 特徴量抽出部の学習用と異常度推定部の学習用の 2 種類を用意する. 特徴量抽出モデルの生成手順は次の通りである.

特徴量抽出部の学習

a-1: 特徴量抽出部の学習用の振動データをフーリエ変換し, スペクトログラムを計算する. このとき得られるスペクトログラムの時間軸方向の次元数は T, 周波数軸方向の次元数は特徴量抽出部のネットワークへの入力と同じ N であるとする.

a-2: **a-1** で得られたスペクトログラムについて, 時間軸方向の平均値を求める.

a-3: **a-2** で得られた結果を学習前の特徴量抽出部のネットワークへ入力する. 提案手法では, 畳み込みニューラルネットワークと VAE を組み合わせたネットワークを特徴量抽出部で利用する. 図 2 に構成の一例を示す.

a-3 で学習した特徴量抽出モデルは異常度推定部の前段において利用する.

異常度推定部の学習

b-1: 異常度推定部の学習用の振動データをフーリエ変換し, スペクトログラムを計算する.

b-2: **b-1** で得られたスペクトログラムを時刻 $t(t = 1, 2, ...\mathrm{T})$ ごとに, 学習済みの特徴量抽出部へ入力することで, 得られるエンコーダ部の出力 (図 2 の μ, σ) を時刻 t における振動特徴量として用いる.

b-3: **b-2** で出力された振動特徴量を異常度推定部の学習データとして与える.

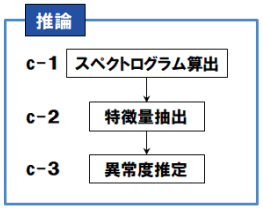


図 3: 評価段階の処理

提案手法では, マハラノビス距離に基づき, 機器の異常度を推定する [Ide 15]. この場合, 異常度推定部の学習用振動データ $X_k(k = 1, 2, ...\mathrm{K})$ から時刻 t における振動特徴量を y_{tk} を抽出することで各時刻 t における特徴量の分布を学習する. ここで, K は学習データの個数, T は評価対象となる振動データのスペクトログラムの時間軸方向の次元数である.

3.3 推論方法

前節の方法で学習した特徴量抽出部と異常度推定部を用いた推論について説明する (図 3).

c-1: 評価対象の振動データについて, スペクトログラムを計算する.

c-2: **c-1** で得られたスペクトログラムを時刻ごとに, 学習済みの特徴量抽出部へ入力することで, 時刻ごとの振動特徴量を得る.

c-3: **c-2** で得られた結果を, **b-3** で得た異常度推定部へ入力することで, 時刻ごとの動作異常度を得る. 提案手法では異常度推定対象の評価データ X から抽出した時刻 $t(t = 1, 2, ...\mathrm{T})$ における振動特徴量 y_t と, 学習段階で得られた特徴量 y_{tk} とのマハラノビス距離を求めることで, 時刻 t における振動の異常度として算出する.

c-3 において, ある時刻 t における異常度 d_t は次式で求められる.

$$d_t = \sqrt{(y_t - m_t)^{\mathrm{T}} \sum^{-1} (y_t - m_t)}$$

ここで,

$$m_t = \frac{1}{\mathrm{K}} \sum_{k=1}^{\mathrm{K}} y_{tk}$$

$$\sum = \frac{1}{\mathrm{K}} \sum_{k=1}^{\mathrm{K}} (y_t - m_t)(y_t - m_t)^{\mathrm{T}}$$

である.

4. 評価実験

提案手法の有効性を評価するため, 自社で生産している複数のモータおよび機械式の可動部を有し, それらが順次動作する機器 (以下, 評価機とする) を対象に実験を行った. 振動データの取得は検知周波数が 10Hz〜15kHz の振動センサを評価機の表面に設置し, 評価機を約 4 ヶ月間連続稼働させることで取得した. 本実験では評価機のある複数の動作パターンを含む, 30 秒間の一連動作を 1 サンプルとみなして異常度の推移を評価した. 図 4 に評価機の 1 サンプル分の振動波形とスペクトログラムを示す.

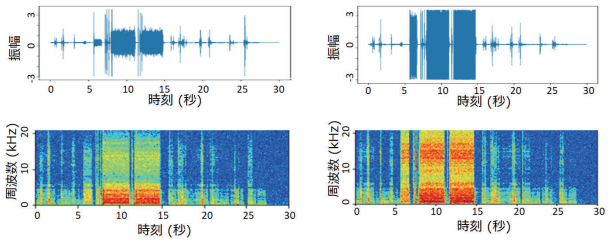


図 4: 評価対象の振動波形とスペクトログラム (左:実験初日, 右:実験開始約 4 ヶ月後)

4.1 特徴量抽出部の学習, 特徴量抽出および異常度推定

提案手法による特徴量抽出モデルの作成, 特徴量抽出および異常度推定の手順は 3.2 から 3.3 節で述べた通りである. 本節では, 評価実験におけるこれらの処理について補足する. モデルの学習には正常データとして実験初日の振動データ 550 サンプル (およそ 4.5 時間分) を用い, このうち 500 サンプルを特徴量抽出部の学習, 残り 50 サンプルを異常度推定部の学習に利用した. スペクトログラムについてはウィンドウ幅を 0.1 秒, シフト幅を 0.05 秒として算出し, 特徴量抽出部には, 図 2 に示したネットワークを用いた. また, 振動特徴量として, ネットワークのエンコーダ部の出力 (図 2 の μ, σ) を取得し, 異常度推定部のモデル学習に利用した.

4.2 実験結果と考察

実験開始から 1〜4 週間後および実験開始から 1〜 4ヶ月後に取得した振動データ各 5 サンプルについて, 提案手法による異常度推定を行った. それら 5 サンプル分の異常度の平均をとった結果を図 5 に示す. この結果から, 実験開始より 1 週間後以降, 評価機の動作開始 6〜15 秒後 (図 5 中の※印) で異常度が大きくなった. また, このタイミングにおける 1〜3 週間後の異常度の値についてはあまり違いがみられないものの, 4 週間後以降ではさらに異常度の値が大きくなった.

次に, 実験用の機器の状態について調査を行い, 以上の結果が得られた理由について考察を行う. まず, 図 4 の波形およびスペクトログラムから分かるように, 評価機は動作開始 6〜15 秒後 (図 5 中の※印) のタイミングで動作しているが, このとき生じる振動の大きさは実験初日と実験開始 4 ヶ月後で明らかに異なる. また, このタイミングで動作する部材を調査したところ, あるギヤ (ギヤ X) が摩耗していたことが確認できた. これらのことから, ギヤ X の動作タイミング (評価機の動作開始 6〜15 秒後) において異常度が大きくなり, なおかつ実験開始 4 週間後以降でさらに異常度が大きくなるという結果が得られたのはギヤ X の摩耗による評価機の振動変化を捉えたためであると考えられる. ただし, 今回の評価実験では提案手法によって得られた異常度推定結果と, ギヤ X の摩耗の程度との対応を明らかにできなかった.

5. おわりに

本稿では多様な動作パターンを有する機器を対象に, 動作時の振動の異常度を教師なし学習で推定するための手法を提案し, 実験用の機器から得られた振動データを使った評価実験とその結果について説明した.

提案手法の評価実験では, あるギヤが稼働に伴い, 次第に摩耗していくことで生じた評価機の振動変化を捉えたと考えられる実験結果が得られた. しかしながら, 機器が故障して動作しなくなる等, 実際の異常と提案手法による異常度推定結果との

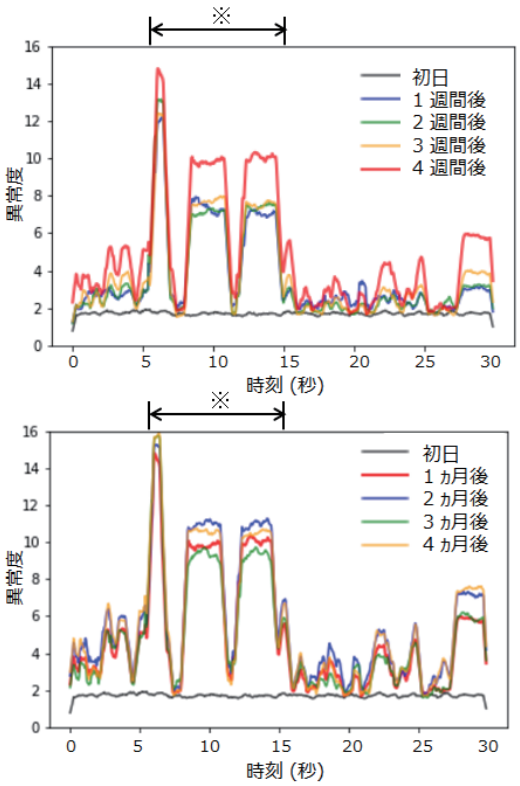


図 5: 実験結果 (上:一週間ごとの異常度推移変化, 下:一ヶ月ごとの異常度推移変化)

対応を確認するには至らなかった.

今後も引き続き, 他の機器を対象に提案手法の追加評価を重ねつつ, 多様な動作パターンを有する機器の高効率で高精度な異常検知や異常原因特定に有効な手法の開発に引き続き取り組みたいと考える.

参考文献

[METS 17] 経済産業省, 2017 年版ものづくり白書.

[Kobayashi 18] 小林 一樹, 関根 理敏, 伊加田 恵志, “多様な動作パターンを有する機器に対応した異常度推定手法の提案,” 信学技報, vol. 118, no. 219, PRMU2018-56, pp.133-138, 2018.

[Francois 18] Francois Chollet, “Python と Keras によるディープラーニング,” マイナビ出版, 2018.

[Diederik 13] Diederi P.Kingma and Max Welling, “Auto-Encoding Variational Bayes,” arXiv (2013), http://arxiv.org/abs/1312.6114.

[Danilo 14] Danilo Jimenez Rezende, Shakir Mohamed, and Daan Wierstra, “Stochastic Backpropagation and Approximate Inference in Deep Generative Models,” arXiv (2014), http://arxiv.org/abs/1401.4082.

[Ide 15] 井出 剛, 杉山 将, “異常検出と変化検知 (機械学習プロフェッショナルシリーズ),” 講談社, 2015.

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

機械学習による局地気象予報手法の開発

Development of method of spot weather forecast using machine learning

吉兼 隆生[*1]　　芳村 圭[*1]
Takao Yoshikane　　Kei Yoshimura

[*1] 東京大学生産技術研究所
Institute of Industrial Science, The University of Tokyo

Local weather forecasting is a very challenging issue because it is technically very difficult and there are a lot of problems with numerical model for now. In this study, we found the linkage between the observation and simulated regional patterns and then estimate the local precipitation, temperature, and surface wind recognizing the regional distribution patterns, which is corresponded to the weather patterns, using machine learning (A regression model of support vector machine). As the result, the model biases were drastically reduced by the innovative approach. This method could greatly contribute to realize the local weather forecast.

1. はじめに

1.1 数値シミュレーションの限界

今いる場所の天気がどうなるのか．天気の変化が自然災害や経済活動に直結するため，古くから局地気象予報の実現が期待されてきた．近年，計算機性能の飛躍的な向上に伴い，数値シミュレーションによる気象予測精度も大きく向上してきた．しかし，局地気象予報については多くの問題があり，未だに実現できていない．局地気象に大きな影響を与えるメソスケール気象現象のメカニズムに未解明の部分が多く，複雑な現象を適切にモデル化できていないことが主な原因として挙げられる．数 km の解像度では複雑な地形に対応したプロセスを再現することは難しく，モデルバイアスの大きな原因となる．実際の局地気象は，地形だけでなく，土地利用分布，海陸分布の影響を受けており，降水過程に大きな影響を与える．降水活動が他の気象現象（地上風など）に影響を与えて，局地気象をより複雑にする．降水過程など物理プロセスについても未解明の部分が多く，複雑な現象を適切に再現するには至っていない．

数値モデルの高解像度化が解決方法の1つと考えられるが，現状では技術的な難しさに加えて膨大な計算機資源を必要とするため，実用化にはかなりの時間を要するかもしれない．また，高解像度化で本当に複雑な局地気象を予測できるのかもよく分かっていない．自然現象は極めて複雑であり，それらを完全に理解してモデル化できるのか不明な点も多い．（自然を理解してモデル化するのは自然科学分野において目標であり，研究の主流であるが）．何れにしても，数値シミュレーションには限界があり，数値シミュレーションのみに依存せずに局地気象予測を行う方法を見つけ出す必要がある[1].

数値シミュレーションを行う以前は，経験的に知られていた天気の変化パターンにから局地気象を予測してきた[2].「観天望気」とも呼ばれており，現在も船舶の出航の判断などに利用されている[3][4][5]. 複雑なプロセスやメカニズムは理解できていないが，もし明らかに何らかの規則性（パターン）があるならば，それに関係した局地気象を予測することは可能だろう．このような経験則に基づく気象予測も過去に多く試みられている．例えば，地上気圧パターンなどから予測する方法などがあるが，十分な精度が得られているとは言い難い．局地気象は，様々な局地的な要因の影響を受けて複雑にかつ短時間で大きく変化する特性があり，広域での気圧パターンとの関係性がそれほど大きくないためと推測される．予測精度を高めるには局地気象と強い関係性をもつパターンを認識する必要があるだろう[5].

連絡先：吉兼隆生，東京大学生産技術研究所，277-8574 千葉県柏市柏の葉 5-1-5，E-mail takao-y@iis.u-tokyo.ac.jp

1.2 局地気象予測における機械学習の可能性

2018 年度人工知能学会での発表では，数値シミュレーションによる降水パターンを認識して局地降水を推定した[6]. 広域での降水変化パターンが観測とよく一致しており，数値シミュレーションと実際の地形の違いが，降水分布の違いを形成したと仮定し，機械学習を用いて実証した．この方法により，高い精度で局地降水予測が可能であることを示した．（図1）

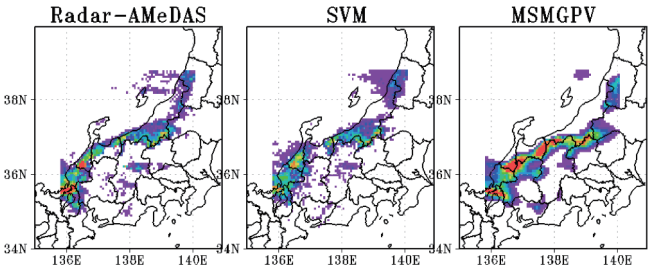


図1 2015 年 1 月 17 日12時の降水量分布．観測（左），機械学習（中央），数値シミュレーション（右）．

数値シミュレーションでは，直接局地気象を予測することは不可能だが，広域での特性は現実をよく反映している．つまり，大規模スケールでの気象現象（季節風や低気圧など）に伴う天気パターンに領域での降水分布が対応しており，結果的に領域内のシミュレーションと観測のそれぞれの降水分布パターンがお互いに強く関係する．（分布特性自体を大きく異なる）（図2）．つまり，局地降水を推定するためには，天気パターンに対応し，かつ観測の領域での降水パターンとの関係性が高い降水パターンを再現可能な数値シミュレーションが不可欠となる．それには，領域内のメソスケール現象の特性を再現できる解像度を持つ数値モデル（メソスケールモデル）が必要となる[7]. 解像度が粗すぎると，観測と関係性を持つ分布パターン自体を再現できない．領域の設定も重要になる．領域が狭すぎると，分布パターンを認識できず（機械学習では領域全体で晴れているのか局所的に晴れているだけなのか識別できない），局地降水予測

に大きな誤差を生じる．つまり，シミュレーションによる降水分布が機械学習での特徴量であり，特徴量を適切に設定することが局地降水を推定する上で最も重要となる．

降水に限らず，その他の気象要素についてもメソスケール現象の影響を受けているため，この手法が降水以外の局地気象予測にも適用可能であると推測される．本研究では，この仮説を検証するため，地上風，気温，湿度，降雪などアメダスにより観測される要素について手法を適用して，評価を行った．また，手法の拡張性を調査するために，衛星データを用いた降水分布推定の有効性についても調査を実施した．

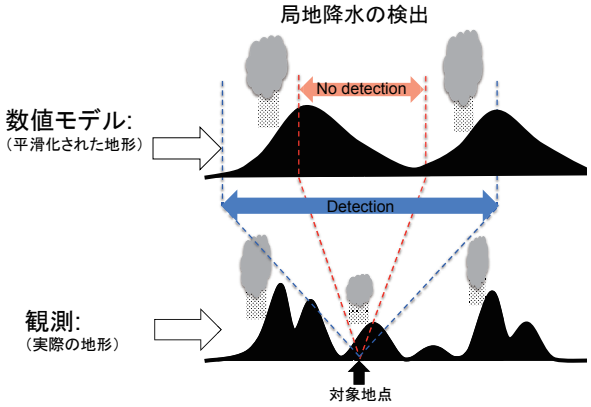


図2　数値シミュレーションと観測による降水分布の違い．対象地点での降水を推定するために必要な情報（数値シミュレーションでの降水分布）の範囲を設定．

2.　方法

機械学習にはサポートベクターマシンの回帰モデル（SVR）を用いた．SVR は統計解析ソフト R のパッケージソフトウェアである e1071 を利用した[8]．

入力には3時間ごとのアメダスと気象庁メソスケールモデルによる解析値（MSMGPV）[7]の地上風，気温データを用いた．学習期間は，テスト期間を除く 2011 年～2018 年までの対象月の前後 3 ヶ月間（例えば，対象月が 7 月の場合，6 月~8 月）とした．各地点での観測値（地上風と気温）と 0.06 度四方（約 5km 四方）の格子に対して観測地点に最も近い格子を中心とした 30x20 格子の領域での数値シミュレーションによる地上風と気温をそれぞれ SVM により学習させた（図3）．（地上風を推定するときは，地上風の東西および南北風を特徴量とし，東西風，南北風を正解データとしてそれぞれ別に推定した．気温の推定では，特徴量，正解データ共に地上気温データを用いた．）

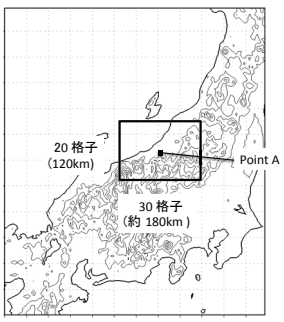


図2　機械学習で適用した入力データの範囲．数値シミュレーションデータ 30 x 20 格子と特徴量，その中心にあたる地点での観測値を正解データに設定．

3.　予測結果

SVM(SVR)による 2018 年 7 月の熊谷（アメダス）での気温の時系（3時間ごと）を図 4 に示す．2018 年 7 月 23 日は熊谷で歴代最高気温 41.1℃を記録している．数値シミュレーションでは全体的に過小評価傾向があるもが，変動パターンはよく再現した．機械学習による推定では，過小評価傾向がほぼなくなり，定量的にも観測値とよく一致した．しかし，歴代最高気温を記録した 23 日の日最高気温の推定は難しく過小評価であった．

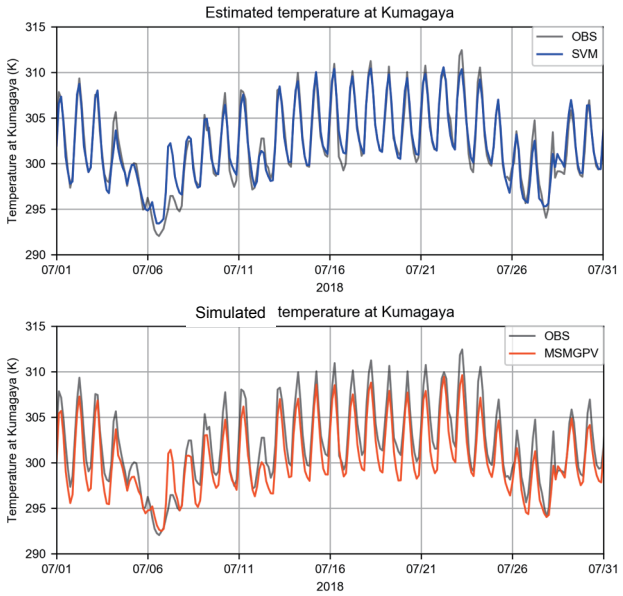


図4　2018 年 7 月の熊谷（アメダス）での観測（灰色），機械学習（青色），数値シミュレーション近傍格子（赤色）の気温時系列．23 日に歴代最高気温 41.1℃を記録．

図5は，富士山山頂付近(3775m)での気温の時系列を示す．数値シミュレーションでは地形の平滑化の影響で，実測値との誤差が大きくなる．一方で，機械学習による推定値では，観測値と比較的よく一致しており，変動特性もよく似ていた．

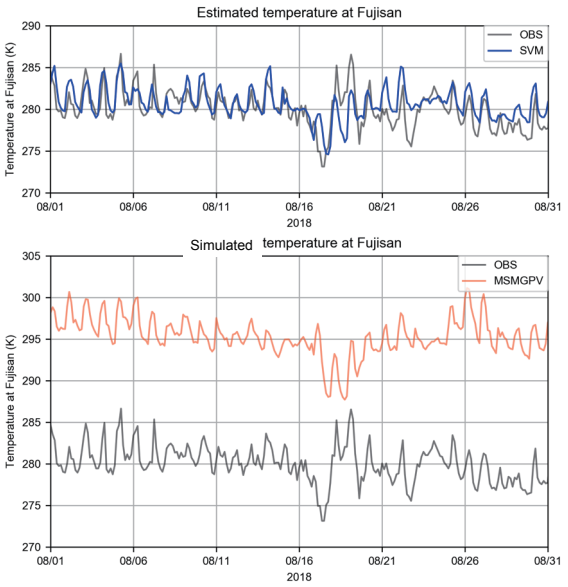


図5　富士山山頂付近での 2018 年 8 月の気温時系列．

次に，地上風のバイアスが顕著になる冬季の富山平野での地上風に注目し，機械学習で推定を行った．図6は北陸地域での観測（左），数値シミュレーション（中央），機械学習（右）の地上風分布（月平均値と北西季節風時）を示す．今回，機械学習による推定では富山（アメダス）での観測値を用いた．冬季の富山平野では，北西季節風時に南風がよく観測される．このメカニズムについては，実際にはよく分かっていない．北アルプスが障壁となって迂回風が関係する可能性の他，日本海上での暖かい海面水温による暖気と内陸での寒気の温度差による重力流の形成による可能性も考えられる．数値シミュレーションでは，月平均値で見ると富山平野内部で南西風が弱いながら再現されているが，北西季節風が強まるときは，ほとんど再現されない．一方で，アメダスでは，どちらの場合も南風が観測されており，顕著なバイアスが確認できる．機械学習により地上風を推定した結果，観測と変動パターンがよく一致しており，北西季節風時の南風も推定された（図7）．

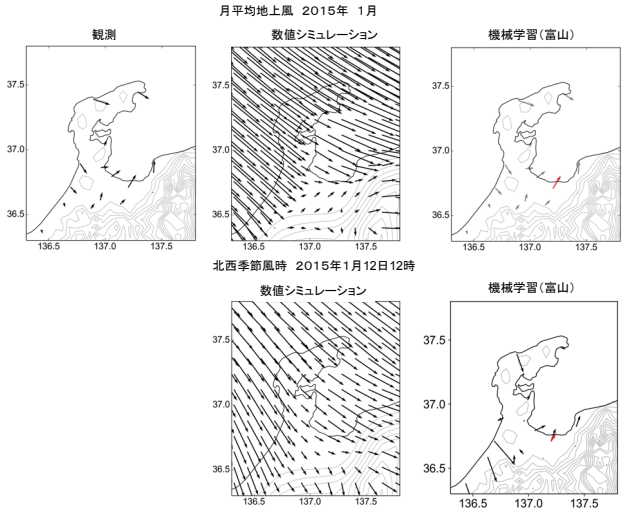


図6 北陸地域での 2015 年 1 月の月平均値と北西季節風時の地上風．赤色の矢印が富山（アメダス）での機械学習による推定値．

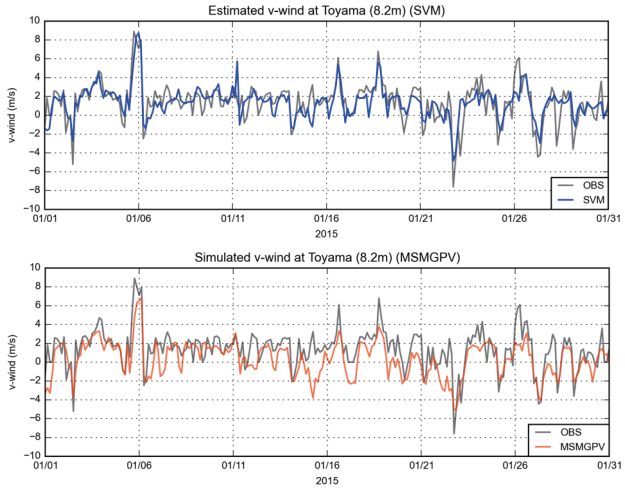


図7 2015 年 1 月の富山（アメダス）での観測（灰色），機械学習推定値（青色），数値シミュレーション（赤色）の南北風の時系列．

4. 考察

数値シミュレーションでは，地形が平滑化されるため，山岳地域の気温のバイアスを避けることが難しい．本手法による推定値がバイアスを低減に成功し，観測値と変動特性がよく一致していたことは，気温についても天気パターンに対応した領域での気温分布パターン（数値シミュレーション）が観測値を推定するための情報を有していたことを意味する．気温は，低気圧や季節風などの大規模スケールの気象システムだけでなく，局地循環やフェーンなどの局地的な影響を大きく受けている．数値シミュレーションでは，領域内の細かい気温分布は異なるものの，領域での天気パターンに対応した気温特性をよく再現していることを示している．局地での気温は，天気パターンによる影響だけでなく，付近の土地利用や建物の影響も大きいと推測されるが，それらの局所的な影響も天気パターンに何らかの形で連動していると推測される．数値シミュレーションでは局所的な要因を詳細に再現するだけの性能は有しておらず局地気温の予測は難しいが，本手法を用いることによりモデル化されていないプロセスの効果を反映して予測推定することが可能になる．ただし，図4で示したように，過去に例のない事象の再現は難しく，過小評価になる．

地上風についても同様のことが言えるだろう．数値シミュレーションでは，北西季節風時に富山平野で形成する南風を精度よく再現することができない．解像度が不十分，あるいは物理プロセスに問題があると考えられる．ただし，天気パターンに対応した領域での地上風分布の特性はよく再現しており，かつ観測点での地上風パターンとも連動していることから，機械学習による推定が高い精度で実現したと推測される．

図8は昨年度発表時に示した機械学習による降水分布推定値（中央）であるが，若干過小評価傾向が見られるものの観測と同様に沿岸域に沿って降水の形成が確認できる．北陸地域では冬季に雷がよく観測される．雷の発生は，寒ブリ漁とも時期が重なることから「鰤起こし」とも呼ばれている．観測される降水帯とも何らかの関係があると考えられるため，局地降水の予測は社会的にも重要になる．一方で，数値シミュレーションでは再現が難しく，山岳で降水が多くなるモデルバイアスが顕著に見られる．本手法を用いることにより，数値シミュレーションの予報値を活用しつつ，局地気象予測が可能になるだろう．

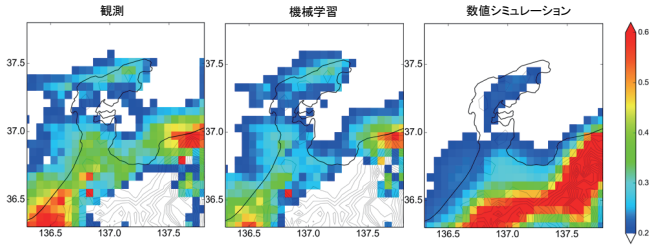


図8 2015 年 1 月の北陸地方における観測（左），機械学習による推定値（中央），数値シミュレーション（右）．観測は雨量解析値[9]を使用．成果の一部は 2018 年度人工知能学会で発表．

5. まとめと課題

カオス現象（初期値依存性）により，気象予報ではアンサンブル手法等を用いた確率予報が不可欠である．本手法による局地気象予報においても，個々の積雲対流，メソスケール気象現

象の発達状態までは予測できないため，定量的に正確に予報することは不可能である．一方で，本手法でバイアスを低減することにより，局地気象予報（確率予報）の実現に大きく前進したと考えている．基本的に数値シミュレーションは仮想世界であり，現実世界とは大きく異なる．数値モデルは人が理解できるプロセスで構成されており，再現される現象も限定される．自然の複雑さを完全に理解して全てをモデル化することは容易ではない．当然ながら数値シミュレーションには本来は評価できない，あるいは評価してはならない結果も含まれており，大きな誤差や誤解を生じる原因になる．数値シミュレーションで再現されるもののうち，何が現実を反映したものかを正しく評価する必要がある．機械学習によるアプローチは，数値シミュレーションの結果を検証し、気象研究を大きく発展させるためのポテンシャルを有している．

機械学習と数値シミュレーションによる組み合わせは，お互いの長所を活かすことにより，従来の方法では不可能であった問題の解決が可能になるだろう．特に複雑さを扱う自然科学分野にとって極めて強力な手法になると期待される．

さらに高精度の予測情報を得るには，最適な特徴量を見つけ出す必要がある．理論に基づいた手法の開発およびその検証を継続して実施することにより大きく改善できるだろう．その一方で，デープラーニング[10]による手法の発展も無視できない．人には複雑すぎて発見が難しい規則性（パターン）も多くあると想定される．デープラーニングにより未知の規則性の発見が容易になるかもしれない。人工知能技術は，従来の研究のあり方を大きく変革し発展する端緒となり得るだろう．

謝辞

本研究の一部は，統合的気候モデル高度化研究プログラム(MEXT)，統合的データ解析システム(DIAS)，宇宙航空研究開発機構(JAXA)，内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム（SIP）「国家レジリエンス（防災・減災）の強化」（管理法人：防災科研）によって実施されました．

参考文献

[1] Rummukainen, Markku. State-of-the-art with regional climate models. Wiley Interdisciplinary Reviews: Climate Change 1.1, 82-96. 2010.

[2] Kimura R, Numerical weather prediction. Journal of Wind Engineering and Industrial Aerodynamics. 90.12-15, 1403-1414, 2002.

[3] 山田力: 小型船舶安全運航のための観天望気を入れた気象海象の話,関東小型船安全協会, 2007, http://www.shoankyo.or.jp/kisyou/pdf/khn2.pdf.

[4] Acharya, S., Presage biology Lessons from nature in weather forecasting. Indian Journal of Traditional Knowledge, 10, 114-124. 2011.

[5] Met Office: Red sky at night and other weather lore, 2017, https://www.metoffice.gov.uk/learning/learn-about-the-weather/how-weather-works/red-sky-at-night.

[6] 吉兼隆生，芳村圭．機械学習による局地気象予報の試み，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．一般社団法人 人工知能学会，2018.

[7] 気象庁: メソモデル・局地モデル. 2018. http://www.jma.go.jp/jma/kishou/know/whitep/1-3-6.html.

[8] David Meyer et al.: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien, 2017. https://cran.r-project.org/web/packages/e1071/e1071.pdf

[9] 気象庁: 解析雨量. 2018. http://www.jma.go.jp/jma/kishou/know/kurashi/kaiseki.html.

[10] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton: Deep learning. nature 521.7553, 436. 2015.

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

エージェントによる津波避難行動と被災箇所の特定

Tsunami Evacuation Behavior and Identification of Dameged Areas by Agents

川合康央[*1]
Yasuo Kawai

海津ゆりえ[*2]
Yurie Kaizu

[*1] 文教大学情報学部
Faculty of Information and Communications, Bunkyo University

[*2] 文教大学国際学部
Faculty of International Studies, Bunkyo University

Abstract: Currently, hazard maps are developed using computationally expensive techniques. After a major disaster, these maps must be revised. We developed a tsunami evacuation simulation system using a game engine and open data at low cost. We then conducted a simulation evaluation using the target area as Kamakura City, Japan. An agent that performs evacuation actions, and autonomously searches for evacuation destinations and evacuation behaviors at specified speeds was developed, to clarify current issues with the location of evacuation sites. The agent prepared three types of walking speeds and disaster conditions, and two types of evacuation behaviors, and could freely change the number and ratio of agents. As a result of the simulation, it became clear that there are places where victims are concentrated even in inland areas.

1. はじめに

津波は，海底を震源とする地震時に，海底地形の短時間での急激な変形によって発生する．この津波は，波高が低いものであっても非常に強い圧力を持ち，沿岸地域の広範囲にわたって大きな被害を与える[松冨 94]．これまでの研究では，津波の波動による数値計算から，津波到達時間や地形効果による津波集中などについて，多くの成果が発表されてきた[相田 77] [小谷 94] [首藤 94]．これらは，波長数キロ単位の津波と地形の関係について着目したものであり，国土レベルでの防災計画を検討する際に重要なものである．

一方で，住民にとって身近な防災情報である津波ハザードマップなどは，主として地方自治体が防災計画を策定している．そこでは，国や県から提供された津波シミュレーションのデータをもとに，浸水域や津波到達時間，最大津波高さを参照し，個別の街路における避難経路や津波簿避難ビルの選定を行っている．しかし，提供されるデータによって防災計画を策定するため，元となるデータが変更されると，防災計画を大幅に見直すことが必要となる．例えば，神奈川県鎌倉市では，2011年の東日本大震災以前と以後によって，県提供データにおける津波浸水域の大規模な見直しが行われため，ハザードマップの再作成が行われた（図1）[鎌倉市 09, 12, 13a]．

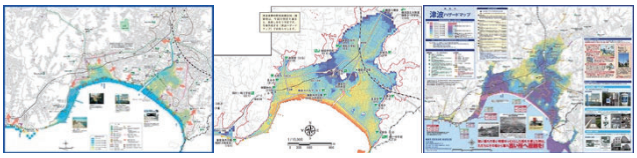


図 1　鎌倉市のハザードマップの推移（左から 2009 年[鎌倉市 09], 2012 年[鎌倉市 12], 2013 年[鎌倉市 13a]）

本研究では，ゲームエンジンとオープンデータを用いることによって，低コストで地域の実情を詳細に反映した，エージェントによる津波避難行動のシミュレーションシステムの構築を行う．本システムでは，津波そのものではなく，エージェントによる避難者の避難行動に着目し，被災が予測される個所を可視化することによって，防災計画に資する基礎的なデータを提供することを目的とする．

2. 方法

2.1 地理情報

地理情報として，国土地理院の基盤地図情報ダウンロードサービス*1を使用した．本サービスでは，Web 上から任意の地域のメッシュにおける，様々な種類の基盤地図情報を XML データ形式で取得することが可能である．ダウンロードした XML データは，基本項目と数値標高モデルの専用表示ソフトウェアである基盤地図情報ビューア*2によって読み取られ，これを Shape 形式のデータに変換して書き出すこととする．

次に，フリーオープンソースの地理情報システムである QGIS*3に，変換した Shape ファイルを新規ベクターレイヤとして読み込んで表示させた．QGIS 上では，マップキャンバスにタイルマップを追加するためのプラグインである TileLayerPlugin*4と，WebGL と three.js Javascript 3D library を使用した視覚化プラグインである Qgis2threejs*5を使用し，高さ情報を持った 3 次元の地理情報データを作成した．テクスチャデータとして，国土地理院の地図・空中写真サービス*6を利用し，前掲の TileLayerPlugin を用いて，航空写真を地形モデルに投影した．QGIS 上で加工された 3 次元データは，地形，道路縁，建築物の外周線の 3 つのレイヤを，夫々STL 形式のデータとして書き出した．

加工された 3 次元地理情報データは，3DCG の統合環境である blender*7上に読み込んだ．道路縁データは，路面に相当する面にポリゴンを手動で生成し，市街地の道路面を詳細に作成した．道路面を表すポリゴンは，地形モデルの高さ情報と値が異なる箇所があったため，blender の cloth モディファイアを用いて，道路面を地形モデルに沿って落とし込んだ．建築物の外

連絡先：川合康央，文教大学情報学部情報システム学科，
kawai@shonan.bunkyo.ac.jp

*1 https://fgd.gsi.go.jp/download/menu.php
*2 https://fgd.gsi.go.jp/otherdata/tool/FGDV.zip
*3 https://www.qgis.org/
*4 https://plugins.qgis.org/plugins/TileLayerPlugin/
*5 https://plugins.qgis.org/plugins/Qgis2threejs/
*6 https://mapps.gsi.go.jp/maplibSearch.do#1
*7 https://www.blender.org/

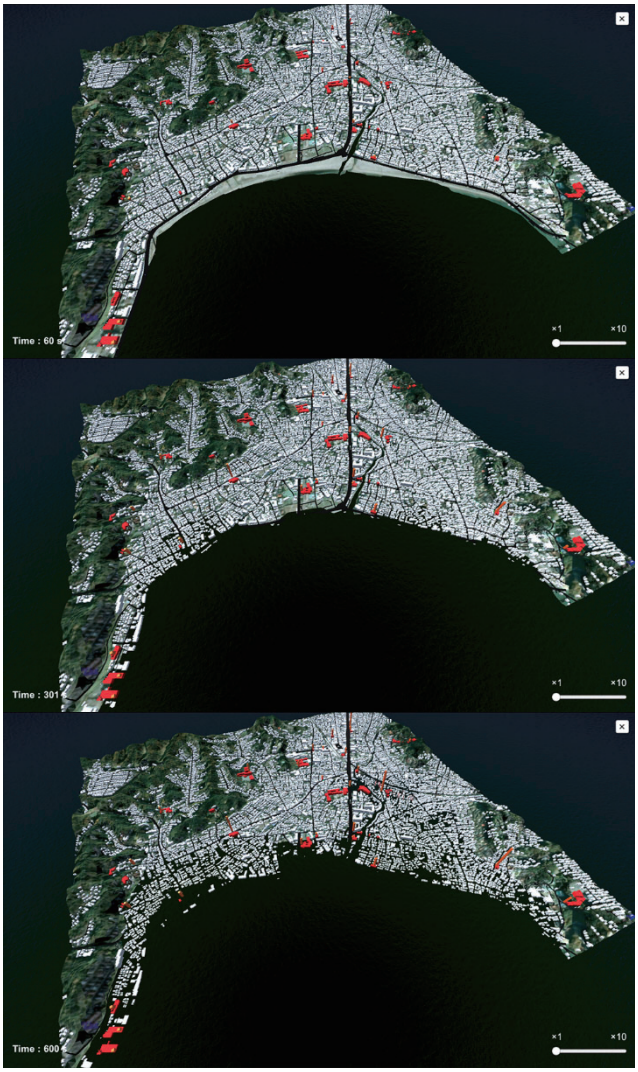


図 2　津波浸水域（上から 1 分後，5 分後，10 分後）

周線は，対象地域の都市計画地図の用途地域[鎌倉市 18a]を参照し，容積率から想定される凡その建物高さを地区ごとに入力した．これら blender 上で生成された 3 次元モデルデータは，FBX 形式のデータとして書き出し，これを統合開発環境であるゲームエンジン UNITY*[8]に読み込むこととした．

2.2 津波の再現

国によって作成された津波・高潮ハザードマップマニュアル[内閣府 04]によれば，浸水予測手法の考え方として，作成目的・評価対象に応じた精度が求められるとされている．浸水予測手法として，時系列を考慮した数値計算シミュレーションによる設定は，ハザードマップ作成に必要な浸水の時間的経過に関するデータ，地点ごとの浸水深データ等を精度よく得られるが，技術力と費用を要するため高コストのものとなることが課題であるとされている．一方で，簡便な手法として地盤高による設定手法も挙げられており，これは簡便で安価に実施できるが，正確な流速や浸水開始時刻，地形による津波遡上の時系列的な影響が予測されないものとなっている．

本システムでは，津波・高潮ハザードマップによる浸水予測手法のうち，地盤高による設定手法をベースとし，これに津波モデルを一定速度で移動させることによって，浸水開始時刻等の時系列を部分的に考慮したモデルを採用する．ここでは，津波を表すモデルとして，0.1 度回転させた傾斜平面を用意し，これを 3 次元地形モデルに挿入することで，時系列浸水を再現した．地形や建物による流速の変化や施設等の破壊条件は設けていないため精度は劣るが，簡易な計算で表すことができるため，軽量な津波モデルとして採用した（図 2）．

2.3 避難者エージェント

本システムは，津波から自律的に避難するエージェントを作成し，アルゴリズムを改良することで動作の軽量化をはかることで，1 万体のエージェントが同時に動作するものとして開発を行った．

避難するエージェントは，2 種類の避難行動パターンと 3 つの年齢属性を持つものとした．本システムでは，避難行動パターンとして，在住者と来街者の 2 種類を想定している．在住者は，避難場所を予め知っているエージェントとして設定されている．在住者エージェントは，津波発生後に，自らの座標から最も近い位置にある高台または津波避難ビルに向かって，最短のルートを検索し，定められた速度で移動することとした．また，津波避難ビルに収容定員を設定し，避難したエージェントが到着した際に既に津波避難ビルが収容定員を超えていた場合，そのエージェントは津波避難ビルに避難できないものとした．そのため，収容定員を超えていたことを確認したエージェントは，現在の座標から最も近い避難先を検索し，再度避難行動を始める．一方で来街者は，避難先を知らないエージェントとして設定されており，津波発生後，自らの座標に最も近いエージェントに従って避難行動するものとした（図 3）．

また，年齢属性として，成人，児童，高齢者の 3 種類を用意した．成人エージェントは，移動速度 0.8m/s，被災津波深さ 0.6m，児童エージェントは，移動速度 0.8m/s，被災津波深さ 0.3m，高齢者エージェントは移動速度 0.6m/s，被災津波深さ 0.6mとした．計 6 種類の各エージェントは，その性質に応じて色分けを行った．

本システムでは，シミュレーション開始後，設定画面で登録した数と特質を持ったエージェントが，範囲内にある道路面上にランダムに配置される．夫々のエージェントは，自らの座標から最も近い位置にある高台または赤色で表された津波避難ビルを目指して移動，あるいは最も近いエージェントに従って移動する．設定された津波高さ以上の高台または津波避難ビルに収容されたエージェントは，避難完了者としてオレンジ色のバーで表され，どこの高台や津波避難ビルに避難者が集中しているのかを可視化する．一方で，津波を表す傾斜平面が，夫々のエージェントに設定された被災津波高さ以上の値となった際には，被災したエージェントとして判定される．被災エージェントは，その場でピンク色のバーとなり，被災した位置に留まる．結果，ピンク色のバーが集中している地域が，被災者が多く発生する位置であると考えられる（図 4）．

シミュレーション終了後，結果画面が表示される．ここでは，在住者，来街者と年齢属性別の被災者の数が表示されるとともに，その結果を CSV 形式のファイルとして，システム内に出力を行うものとなっている．エージェントはランダムに道路上に配置されるため，シミュレーションの初期条件によって結果は異なる．そのため，条件を設定した後，繰り返し試行してデータを収集し，分析することが可能なものとした．

*8 https://unity3d.com/

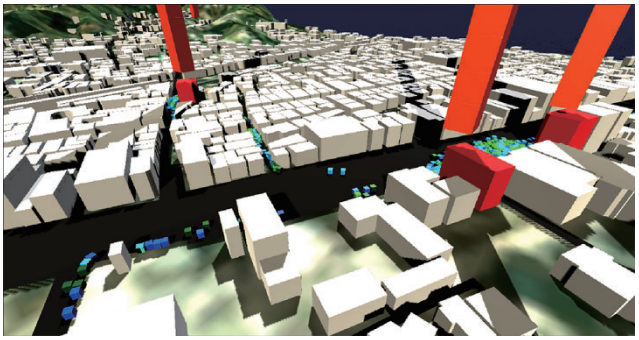


図 3　避難するエージェント群

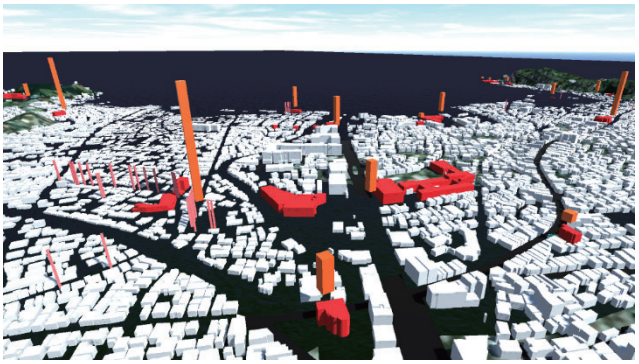


図 4　津波避難ビル（赤），避難者収容者数（橙），エージェント被災箇所（桃）

3. 結果と考察

本システムを用いて，エージェントによる避難行動シミュレーションを行った．対象地区は，神奈川県鎌倉市市街地とし，由比ガ浜及び材木座に面する海岸から，JR 鎌倉駅周辺を含む凡そ 9 ㎢の範囲とした．本対象地区における避難困難区域内人口は浸水区域内建物数から約 10,420 人と推計されている[鎌倉市 16]．そこで，本システム上で 10,000 体のエージェントを対象地区の道路上にランダムに配置し，対象地区の地形に基づく高台または市が指定されている津波避難ビル 23 棟[鎌倉市 13a]を避難先として，エージェントに避難行動を行わせた．

エージェントの年齢属性として，本シミュレーションでは児童を 5～14 歳，成人を 15～64 歳，高齢者を 65 歳以上とし，また 5 歳未満のエージェントは成人とともに避難するものとした．本実験では，鎌倉市の年齢別人口[鎌倉市 18b]に基づき，児童 8%，成人 61%，高齢者 31%とした．次に，在住者と来街者の比率を，資料[鎌倉市 13b]の入込観光客調査から 1 日当たりの平均観光客数を割り出し，その比率を在住者 78%，来街者 22%とした．今回は津波高さとして 5m，10m，15m の三種類を用意し，それぞれの場合について 50 回のシミュレーションを行った．

シミュレーションを試行し，その集計を行った結果，エージェント別の平均被災率は，次のような値となった．津波高さ 5mの時に，在住者は児童 0.27%，成人 0.05%，高齢者 0.25%，来街者は児童 0.20%，成人 0.05%，高齢者 0.26%となった．津波高さ 10m の時，在住者児童は 5.00%，成人は 3.36%，高齢者は 5.50%，来街者児童は 4.85%，成人は 3.53%，高齢者は 5.56%となった．また，津波高さ 15m 時には，在住者児童 21.60%，成人 12.81%，高齢者 18.85%，来街者児童 22.33%，成人 13.36%，高齢者 19.08%であった（図 5）．いずれのケースにおいても，成人エージェントに比して，被災する津波高さの低い児童エージェントと，移動速度の遅い高齢者エージェントは，成人エージェントに比して被災率が高いものとなった．また，対象地区全域での平均被災率は，津波高さ 5m の時 0.13%であったが，津波高さ 10m時には 4.19%，15m 時には 15.57%であり，津波高さに応じて甚大な被害が生じる可能性があることが分かった．

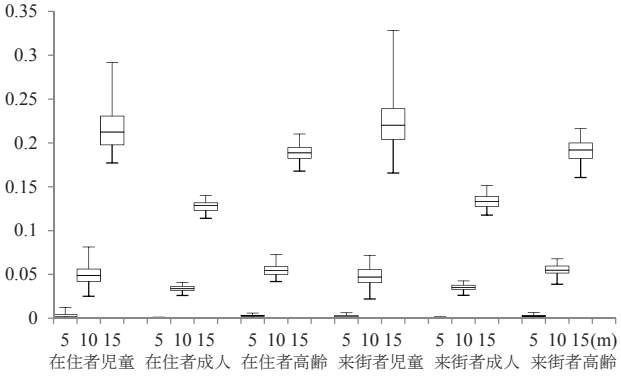


図 5　エージェント種別被災率

シミュレーションの結果，内陸部においても被災者が集中してみられる箇所が存在することが明らかとなった．これらは，内陸部に河川が入り込んだ低地に多くみられ，津波が河川を遡上し，海岸方向からの津波と挟まれる個所が見られた．また，避難者は津波発生後に何らかの避難行動を行うため，実際には内陸部に避難してはいたが，低地が続く地形においては，内陸部の市街地において津波被害に遭遇する事態も見られた．海岸沿いの津波避難ビルとともに，低地の内陸部における市街地においても，被災者が集中してみられる箇所が観測されたため，適切な避難場所と川沿いを迂回する安全な避難経路の策定が必要であると考えられる．さらに避難経路によっては目の前に津波が迫る海側へ避難しなければならない箇所もあり，避難サインや誘導方向などの改善を必要とする場所があることも明らかとなった．

4. まとめ

本研究では，ゲームエンジンを用いた津波避難行動シミュレーションシステムを開発し，実在する市街地として，鎌倉市を対象としたシミュレーションによる評価を行った．津波の再現については，仮想海面を模した傾斜平面挿入による簡易な表現を用いることによって，処理を軽量化し，リアルタイムでの検討を可能とした．一方，避難者については，自律的に避難先を検索し，定められた速度で移動するエージェントを作成した．このエージェントは，歩行速度や被災条件の異なる 3 種類と，避難行動の異なる 2 種類のものを用意し，その数や比率を自由に可変できるものとした．また，津波発生時には，在住者や来街者がどのような状態であるかは不確定であるため，本システムでは避難者を対象地区の道路面上にランダム配置することとした．

結果，鎌倉市では，沿岸部だけでなく，避難途中の内陸部でも大きな被害が発生することが明らかとなった．また，低標高が続く道や川に挟まれた場所など，高さの比較的低い津波であっても大規模な被害が出るポイントがあることを確認した．一方で，鎌倉市は歴史的文化都市でもあり，景観法に基づく景観計画が施されており，景観地区[鎌倉市 07]や風致地区[鎌倉市 14]が定められている．そのため，建物高さは地区により 8~15m の高さ制限が課されており，津波避難ビルとしての収容定員は小さいものとなっている．今後，多くの被災が予測される箇所においては，地方自治体と地域住民の協働によって，適切な津波避難ビルの配置計画と指定が必要であると考えられる．また鎌倉市では，発災後の速やかな行動が被災率に大きな影響を持つ

ため，詳細な地域別に，発災後約 8 分間と約 3 時間までの状況に備えた地域別津波避難実施計画とこれに伴うワークショップを実施しており，実効性の高い津波防災のための施策を行っている[鎌倉市 16].

提案したシステムは，オープンデータを用い，開発環境としてゲームエンジンやフリー・オープンソースソフトウェアを活用することによって，低コストで開発が可能であるため，地方自治体などで，地域住民とともに防災計画を検討する際に有効なツールとなると考えられる．今回提案したシステムは，津波表現について簡易なものを用いたが，別途いくつかの条件を設定した動的な津波モデルと置き換えることで，より正確なシミュレーションが可能になると考えられる．また，実際に防災計画を検討するにあたり，津波避難ビルなどの避難先や災害時に通行を可能とする私有地が追加できる等，都市条件をインタラクティブに変更が可能なツールへと発展していく必要がある．

今回のシステムでは，津波に対する避難行動をシミュレートするものとして開発を行ったが，津波発生前の地震が近い場所で発生した場合，建物や都市設置物等の火災，崩壊などによる道路の寸断が起こる可能性がある．また，津波避難ビルについても，すべて稼働することが前提となっているが，震源が近い場所で大規模な地震が発生した場合には，これらのビルそのものが避難場所として使用できないケースが考えられる．今後は，本システムを改良し，大規模火災，地震，洪水等，複合的な災害を組み合わせた総合的な防災シミュレーションモデルを作成し，実際の防災計画に資するシステムの開発を行っていくこととする．

謝辞

本研究は JSPS 科研費 JP16K02080 の助成を受けたものです．

参考文献

[相田 77] 相田勇: 陸上に溢れる津波の数値実験-高知県須崎および宇佐の場合，地震研究所彙報, Vol.52, pp.441-460, 1977.

[鎌倉市 07] 鎌倉市都市景観部都市景観課都市景観担当: 鎌倉市景観計画，鎌倉市, 2007.

[鎌倉市 09] 鎌倉市防災安全部総合防災課: 鎌倉市津波ハザードマップ材木座から稲村ガ崎，鎌倉市, 2009.

[鎌倉市 12] 鎌倉市防災安全部総合防災課: 鎌倉市津波浸水予測図（暫定版），鎌倉市, 2012.

[鎌倉市 13a] 鎌倉市防災安全部総合防災課: 鎌倉市津波ハザードマップ材木座から稲村ガ崎，鎌倉市, 2013.

[鎌倉市 13b] 鎌倉市観光基本計画推進協議会災害時観光客対策部会: 鎌倉市観光客等地震・津波対策ガイドライン，鎌倉市, 2013.

[鎌倉市 14] 鎌倉市都市景観部都市景観課風致担当: 鎌倉市風致地区条例による許可の審査基準・運用と解釈，鎌倉市, 2014.

[鎌倉市 16] 鎌倉市防災安全部総合防災課: 鎌倉市津波避難計画地域別実施計画由比ガ浜・材木座エリア（第 1 版），鎌倉市, 2016.

[鎌倉市 18a] 鎌倉市まちづくり計画部都市計画課都市計画担当: 用途地域等閲覧用参考図書，鎌倉市, 2018.

[鎌倉市 18b] 鎌倉市総務部総務課統計担当: 年齢(各歳・5 歳階級)別，男女別人口，鎌倉市, 2018.

[小谷 94] 小谷美佐, 今村文彦, 首籐伸夫: GIS を利用した津波遡上計算と被害推定法，海岸工学論文集, Vol.45, pp.356-360, 1998.

[松冨 94] 松冨英夫, 首藤伸夫: 津波の浸水深，流速と家屋被害，海岸工学論文集, Vol.41, pp. 246-250, 1994.

[内閣府 04] 内閣府（地震・火山対策担当），農林水産省農村振興局防災課，農林水産省水産庁防災漁村課，国土交通省河川局海岸室，国土交通省港湾局海岸・防災課: 津波・高潮ハザードマップマニュアル，国土交通省，2014.

[首藤 94] 首藤伸夫, 永井孝志: 津波の数値シミュレーションと可視化，可視化情報学会誌, Vol.14, No.52, pp.2-6, 1994.

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

グローバル株式市場における深層学習を用いたマルチファクター運用の実証分析

Deep Learning for Multifactor Models in Global Stock Markets

阿部　真也　　中川　慧
Masaya Abe　　Kei Nakagawa

野村アセットマネジメント株式会社
Nomura Asset Management Co.,Ltd.

Many studies have been undertaken by using deep learning techniques to predict stock returns in terms of time-series prediction.However, from the viewpoint of the cross-sectional prediction, there are no examples that verify its effectiveness in the global stock market.This paper implements deep learning to predict stock returns in the cross-section in the global stock market and investigates the performance of the method.Our results are followings.

1. Deep learning is superior in terms of return / risk as compared with random forest and ridge regression.
2. Especially, in terms of risk, the deep learning model is outstanding.
3. If market efficiency declines, opportunities for return may increase.

1. はじめに

株価を予測するためのアプローチとして、(1) 株価を時系列データとみなして予測する方法、(2) あるクロスセクション (断面) での銘柄間の相対的な順位 (魅力度) に基づいて予測する方法の 2 つがある。一般的な時系列データとは異なり、株価を時系列データとしての予測、すなわち過去の株価を特徴量として利用し、将来の株価を予測するという前者のアプローチは短期的には可能でも、長期的には難しいことが知られている。

一方で、後者の複数の株価をクロスセクションデータとして見た中で、どういった銘柄群が相対的にリターンが高くなり、どういう銘柄群が低くなるかは、中長期的な期間である程度明らかにされている。こういったクロスセクションで株価を説明する要因を「ファクター」という。実際にはこれら複数のファクターを組み合わせ、株価の相対的な魅力度をより詳細に、多角的に明らかにするマルチファクターモデルが用いられる。ファイナンスの学術的には、[Fama 92] による Fama-French の 3 ファクターモデルが一般的である。以降、[Harvey 16] によれば、2012 年までの間に 316 ものファクターが「発見」された。しかも、これらファクターの大部分は過去 10 年間で検証された。そのため近年、運用者が検討すべきファクターは急速に増大しているものの、次元の呪いの問題から 316 ものファクターを同時に検証することはできない。一方で、ファイナンスにおいては統計的な扱いや理論的な解析が容易であること、結果の頑健性から線形回帰モデルを用いる。実務的には、これらのうち幾つかのファクターと将来リターンの相対的順位との回帰分析から、ある銘柄についての総合的な魅力度を計算し、当該魅力度に基づいてポートフォリオ構築を行う。しかしながら、これらファクターと将来リターンの関係は複雑であることが古くから知られているため、単純な線形回帰モデルでは予測精度に限界がある。金融市場の非線形な関係をとらえるため、単純な線形回帰モデルではなく、機械学習の手法を用いて、時系列予測の観点から、将来リターンを予測する問題に取り組んでいる研究が学術的には盛んである [Bahrammirzaee 10, Cavalcante 16, Nakagawa 18a]。

しかしながら、クロスセクションでのマルチファクターモデルの観点から、機械学習を適用する試みは [Sugitomo 18, Abe 18, Nakagawa 18b] といった少数の例を除くとあまりなく、特に様々なファクターを用い、グローバルな株式市場においてその有効性を検証した例は筆者らの知る限り存在しない。

そこで本稿では、グローバルな株式市場において画像認識、音声認識、自然言語処理など様々なタスクにおいて、優れた非線形関数近似能力を示している深層学習を用いたマルチファクターモデルに基づく相対的な魅力度の有効性を検証する。

連絡先: 連絡先： 野村アセットマネジメント株式会社
〒 103-0027 東京都中央区日本橋 1 丁目 12-1
E-mail: m-abe@nomura-am.co.jp

本稿の内容は筆者らが所属する組織を代表するものではなく、本稿の全ての誤りは、筆者らの責に属するものである。

2. 深層学習を用いたマルチファクターモデル

銘柄の相対的な魅力度を判断するマルチファクターモデルを構築するためにはまず、データとして PER や ROE などの株価を説明するであろう指標 (ディスクリプター) を幾つか用意する。[Fama 92] などのファイナンスの学術研究とは違い、それらのディスクリプターを標準化したものを複数組み合わせてファクターを作る。例えば、株価の割安感を表すバリューファクターを、PBR、PER、配当利回りを 1:1:1 で組み合わせて作る。そして複数のファクターから回帰モデルで相対的な魅力度を予測する。最後に予測された魅力度を期待リターンとして、銘柄間のリスクと組み合わせてポートフォリオを構築する。

従来はディスクリプターからファクターの作成、そしてどのファクターをいくつ使うのかを人が選択していたため、モデルの見直し・チューニングには非常に多くの時間がかかった。またそれらの多くは運用者であるファンドマネージャーの経験によって決定されていた。しかしながら、ディスクリプターから株式リターンの予測を表現力に優れた深層学習を用いて置き換えることで、長年の経験をパラメータチューニングに置き換えることができる。

具体的には、ディスクリプターをインプットとして与え、アウトプットとして一定期間後の将来リターンの順序関係を与える。すると隠れ層にはこれらディスクリプターが非線形に合成されたファクターとファクターリターンが表現される (図 1)。

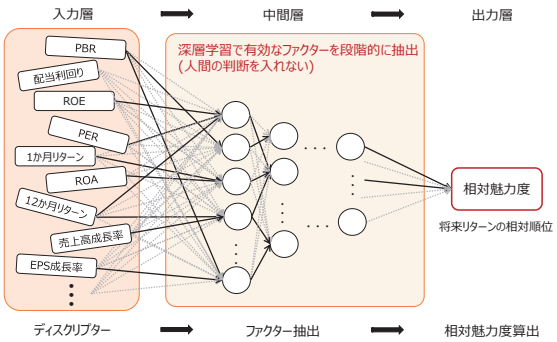


図 1: 深層学習を用いたマルチファクターモデル

3. 実証分析

3.1 データセット

ここではグローバルな株式市場を対象に分析を行う。分析のユニバースとして、機関投資家の投資対象として使用されることの多い MSCI 社の株式指数である、MSCI Americas、MSCI Europe & Middle East、MSCI Pacific の 3 地域を使用する。

特徴量として用いるディスクリプターは表 1 の通りである。これらのディスクリプターの計算のため、WorldScope、Thomson Reuters、I/B/E/S および EXSHARE からデータを取得した。実績財務データは、WorldScope と Reuters Fundamentals(WorldScope 優先) から、予想利益 (No.15-16) は Thomson Reuters Estimates、I/B/E/S Estimates(Thomson Reuters 優先) から取得している。これらのディスクリプターはすべて実務でよく使用されるものである。

3.2 分析方法

特徴量として、表 1 のディスクリプターを用い、教師データには翌月の現地通貨建てのリターンとする。これらは月次系列データである。また各データは時点毎に 0 から 1 のパーセンタイル化の前処理を行っている。訓練期間として直近 120 か月 (ただし、直近 1 か月を除く) のデータを使用し、モデルの学習を行う。モデル学習後は、直近時点の特徴量をモデルに入力し、各銘柄の予測スコア (相対魅力度) を算出する。この処理を 3 地域別に毎月行っていく。具体的なモデルとして深層学習とベンチマークとしてランダムフォレスト、リッジ回帰を用いる。

1. 深層学習 (DNN): パッケージ TensorFlow を用いて実装を行った。7 層の全結合型の構造で、活性化関数は全て ReLU 関数を用いた。ネットワークにおける隠れ層の構造 (ユニット数) は $\{150-150-100-100-50-50\}$ であり、各層に対応するドロップアウトは $(50\%-50\%-30\%-30\%-10\%-10\%)$ である。最適化アルゴリズムに学習率 0.001 の Adam を用い、 ミニバッチサイズは 300 とした。初期値 (分析開始月) については、バイアスを 0、ウェイトを TensorFlow の関数”tf.truncated_normal”の平均 0、標準偏差を $\sqrt{2/M}$ として与えた。ただし、M は前層のユニットのサイズである。また各層でバッチ正規化を行っている。学習度合いについては、各時点の銘柄数が異なり、訓練データサイズが一定ではないため、エポックス数ではなく、訓練データの特徴量から計算した予測スコアと教師データの順位相関係数を用いた。具体的には、訓練データ内の時点 (年月) 別に順位相関係数を計算し、その平均値が 0.20 を超えたらネットワークの学習を終了させている。また fine tuning として、分析開始月の後の学習については、前月の訓練過程において順位相関係数 0.18 を超えた時点のネットワークを呼び出して、学習を開始させている。
2. ランダムフォレスト (RF):パッケージ scikit-learn のクラス”sklearn.ensemble.RandomForestRegressor”を用いて実装を行った。パラメータについては、特徴量の数 (max_features) を 20、木の数 (n_estimators) を 1,000、深さ (max_depth) を 5 とした。
3. リッジ回帰 (RR):パッケージ scikit-learn のクラス”sklearn.linear_model.Ridge”を用いて実装を行った。正則化パラメータ (alpha) は、1(デフォルト値) とした。

パフォーマンス評価のために構築するポートフォリオは、予測スコアで 5 分位し、最上位の第 5 分位に属する銘柄群を等ウェイトで買った「5 分位ポートフォリオ」と、5 分位ポートフォリオと最下位の第 1 分位に属する銘柄群を等ウェイトで売った 1 分位ポートフォリオを合成した「5 分位-1 分位ポートフォリオ」の 2 パターンとする。5 分位ポートフォリオは投資対象銘柄の等ウェイトリターンを引いて、5 分位-1 分位ポートフォリオは、5 分位ポートフォリオから 1 分位ポートフォリオのリターンを引いて、ポートフォリオのリターンを計測する。なお、検証期間は 2005 年 1 月から 2017 年 12 月までとし、毎月予測スコアを計算し、ポートフォリオ内の構成銘柄を入れ替えていく。

3.3 分析結果

5 分位ポートフォリオ、5 分位-1 分位ポートフォリオの結果のサマリーがそれぞれ表 2、3 である。年率リターン、リスク、リターン/リスク比 (R/R)、最大ドローダウン (最大 DD)[*1] を評価指標とする。なお、表中の太字は DNN、RF、RR それぞれの手法内で最も良いものを表している。

表 2、3 ともに、DNN は R/R で見て全ての地域で他の手法を大きく上回っている。また年率のリスクと最大ドローダウンに着目すると、DNN は他の手法と比べて小さく、リスクを回避した運用を行う場合に特に DNN に優位性がある。年率リターンについては、Europe & Middle East を除いて、両ポートフォリオ戦略において DNN が最も高く、低リスクでありながらも、相対的に高いリターンを獲得できている。対して、RF と RR は地域ごとに優劣のばらつきがあり、どちらが優れているとは言い難い。なお、RR は最大ドローダウンが大きくなりがちであることが確認できる。地域別に結果を確認すると、使用するモデルに関わらず Pacific、Europe & Middle East、Americas の順でパフォーマンスが悪化していることがわかる。この結果は、一般にアジア、欧州、米国の順に株式市場の流動性が高くなり、市場の効率性が向上することで、収益獲得が困難となることと整合的であると考えられる。

4. おわりに

本稿では、深層学習を用いたマルチファクターモデルに基づく相対魅力度の有効性の検証を、グローバル株式市場で行った。各地域の MSCI Americas、MSCI Europe & Middle East、MSCI Pacific を対象とした実証分析の結果、以下の知見が得られた。

*1 リターンの最大収益時からの下落率をドローダウンという。そのドローダウンが最大のケースを最大ドローダウンといい、リスク指標として用いられる。

表 1: 使用したディスクリプターの定義

No	ディスクリプター	項目説明
1	B/P	総資産/時価総額
2	E/P	当期純利益/時価総額
3	D/P	配当/時価総額
4	S/P	売上高/時価総額
5	CF/P	営業キャッシュフロー/時価総額
6	ROE	純利益/純資産
7	ROA	営業利益/総資産
8	ROIC	税引後営業利益/(有利子負債＋株主資本)
9	アクルーアルズ	-(流動資産の変化+現金の変化-流動負債の変化-減価償却費)/総資産
10	総資産成長率	総資産の前期からの成長率
11	流動比率	流動資産/流動負債
12	自己資本比率	純資産/総資産
13	総資産回転率	売上高/総資産
14	CAPEX 成長率	資本的支出の前期からの成長率
15	EPS リビジョン (対 1 か月)	利益予想変化 (対 1 か月)　※ローゼンバーグ方式
16	EPS リビジョン (対 3 か月)	利益予想変化 (対 3 か月)　※ローゼンバーグ方式
17	1 か月モメンタム	過去 1 か月リターン
18	12 か月モメンタム (直近 1 か月除く)	過去 12 か月リターン (直近 1 か月除く)
19	ボラティリティ	過去 60 カ月リターンの標本標準偏差
20	歪度	過去 60 カ月リターンの標本歪度

表 2: 5 分位ポートフォリオの結果

MSCI Americas

Q5	DNN	RF	RR
年率リターン	**1.76%**	0.14%	0.34%
年率リスク	**3.51%**	5.05%	5.88%
年率 R/R	**0.50**	0.03	0.06
最大 DD	**-11.21%**	-25.26%	-27.19%

MSCI Europe & Middle East

Q5	DNN	RF	RR
年率リターン	2.55%	1.73%	**2.81%**
年率リスク	**3.29%**	4.73%	5.23%
年率 R/R	**0.78**	0.36	0.54
最大 DD	**-6.47%**	-15.94%	-16.61%

MSCI Pacific

Q5	DNN	RF	RR
年率リターン	**4.59%**	3.15%	3.08%
年率リスク	**3.59%**	4.90%	4.81%
年率 R/R	**1.28**	0.64	0.64
最大 DD	**-6.93%**	-10.03%	-10.36%

表 3: 5 分位-1 分位ポートフォリオの結果

MSCI Americas

Q5-Q1	DNN	RF	RR
年率リターン	**4.16%**	2.23%	2.04%
年率リスク	**7.41%**	11.28%	11.58%
年率 R/R	**0.56**	0.20	0.18
最大 DD	**-28.40%**	-38.68%	-42.40%

MSCI Europe & Middle East

Q5-Q1	DNN	RF	RR
年率リターン	5.01%	5.53%	**6.90%**
年率リスク	**7.58%**	12.90%	12.14%
年率 R/R	**0.66**	0.43	0.57
最大 DD	**-17.92%**	-37.72%	-34.71%

MSCI Pacific

Q5-Q1	DNN	RF	RR
年率リターン	**9.48%**	8.26%	7.18%
年率リスク	**6.49%**	9.11%	9.04%
年率 R/R	**1.46**	0.91	0.79
最大 DD	**-13.11%**	-18.73%	-19.01%

- どの地域でも、深層学習による株価予測モデルはランダムフォレストやリッジ回帰に比べ、リターン/リスク比の面で大きく優れている。
- 低リスクという観点で深層学習モデルは優れており、リターンについても MSCI Europe & Middle East を除き、相対的に高い水準を獲得している。
- 手法に関わらず、市場の効率性が向上すると、収益獲得の機会が低下する可能性がある。

参考文献

[Abe 18] Abe, M. and Nakayama, H.: Deep Learning for Forecasting Stock Returns in the Cross-Section, in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 273–284, Springer (2018)

[Bahrammirzaee 10] Bahrammirzaee, A.: A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems, *Neural Computing and Applications*, Vol. 19, No. 8, pp. 1165–1195 (2010)

[Cavalcante 16] Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., and Oliveira, A. L.: Computational intelligence and financial markets: A survey and future directions, *Expert Systems with Applications*, Vol. 55, pp. 194–211 (2016)

[Fama 92] Fama, E. F. and French, K. R.: The cross-section of expected stock returns, *the Journal of Finance*, Vol. 47, No. 2, pp. 427–465 (1992)

[Harvey 16] Harvey, C. R., Liu, Y., and Zhu, H.: … and the cross-section of expected returns, *The Review of Financial Studies*, Vol. 29, No. 1, pp. 5–68 (2016)

[Nakagawa 18a] Nakagawa, K., Imamura, M., and Yoshida, K.: Stock Price Prediction with Fluctuation Patterns Using Indexing Dynamic Time Warping and k^*-Nearest Neighbors, *New Frontiers in Artificial Intelligence*, pp. 97–111 (2018)

[Nakagawa 18b] Nakagawa, K., Uchida, T., and Aoshima, T.: Deep Factor Model, in *MIDAS 2018 : MIDAS @ECML-PKDD 2018 - 3rd Workshop on MIning DAta for financial applicationS* (2018)

[Sugitomo 18] Sugitomo, S. and Minami, S.: Fundamental Factor Models Using Machine Learning, *Journal of Mathematical Finance*, Vol. 8, No. 01, p. 111 (2018)

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

畳み込みニューラルネットワークを用いた アナリスト往訪記録における景況感判定

Business Confidence Prediction for Analyst Report using Convolutional Neural Networks

高山 将丈[*1] Shota TAKAYAMA
小澤 誠一[*1,2] Seiichi OZAWA
廣瀬 勇秀[*3] Takehide HIROSE
飯塚 正昭[*3] Masaaki IIZUKA

[*1] 神戸大学大学院 工学研究科 Graduate School of Engineering, Kobe University
[*2] 神戸大学 数理・データサイエンスセンター Center for Mathematical and Data Sciences, Kobe University
[*3] 三井住友 DS アセットマネジメント株式会社 Sumitomo Mitsui DS Asset Management Company, Limited

To decide valuable companies to be invested, investment trust and fund management companies, which manage funds deposited from investors, have collected information on company's budget status and plans. However, the number of visit reports are usually too large even for skilled fund managers to easily derive reliable business outlooks and investment decisions. In this research, to alleviate fund managers' and analysts' commitment for the investigation and analysis, we propose a machine learning system that can support them to make accurate predictions on business outlook from collected visit reports. We attempt to predict business confidence for specific companies and industries using CNN that is expected to have good readability and robustness for polarity perturbation. As a result, we obtain 81.4% in classification accuracy for analysts' reports provided by the Sumitomo Mitsui DS Asset Management Company, Limited. It has 5.7% better accuracy than the best baseline model using Word2Vec and SVM.

1. はじめに

投資家の資金を預かり，その運用を行う運用会社では，投資対象の企業を決定するため，各企業にアナリストがヒアリングして財務状況や将来計画などの情報を収集している．この調査分析結果は往訪記録やアナリストレポートとしてまとめられ蓄積されているが，その量が膨大であるため，たとえ熟練したファンドマネージャであっても，これらから適切な投資判断を導き出すことは容易でない．

この業務を支援するため，アナリストレポートに対して深層学習を用いて景況感判定を行う試みが行われている[小林 2017]．小林らの手法では，アナリストレポートから景況感判定の根拠となる表現を得るため，学習を行う前にキーとなる表現を人手で与える．次いで，得られた特徴量を 12 層の階層型ニューラルネットを伝播させ，判定を行う．しかしこの手法には，個々のアナリストの書き方の違いによって，有用表現が異なるため，分析者が分析対象文書の特徴を十分に把握している必要がある点や，勾配消失及び発散，過学習などが懸念されるなどの問題が存在する．

一方で，深層学習，特に畳み込みニューラルネットワーク[LeCun 1998](CNN)を用いて文書分類を行う研究も行われている[Kim 2014]．この研究では学習済みの単語ベクトルを単語数分並べ，(単語ベクトル長×単語数)の 2 次元ベクトルとして文書ベクトルを作成した後，CNN を用いて文書の分類を行っている．

本研究の最終目標は，投資先企業を決定するファンドマネージャをサポートするシステムの開発である．時々刻々と状況が変化する投資業界において実用的なシステムを開発するためには，即時性が必要となる．本研究では，CNN で文書分類を行う

連絡先：小澤 誠一，神戸大学数理・データサイエンスセンター，
〒657-8501 神戸市灘区六甲台町 1-1
TEL:078-803-6466，E-MAIL:ozawasei@kobe-u.ac.jp

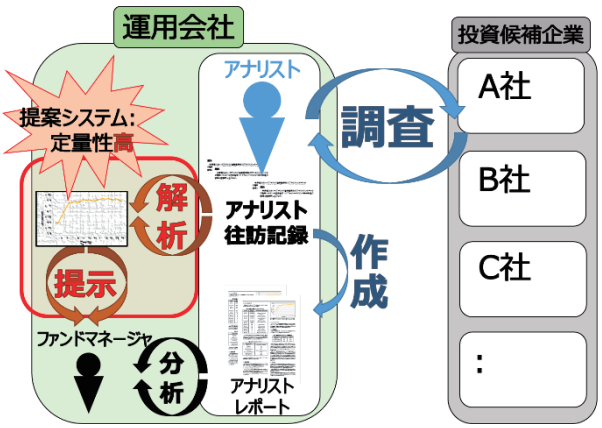


図 1 提案システムの概念図

Kim らの研究[Kim 2014]をベースに，往訪記録やアナリストレポートなどの金融文書の特徴を活かした新たな機械学習システムを提案する(図 1)．

2. アナリスト往訪記録について

アナリストは投資候補企業に訪問したり説明会に参加したりして情報を収集する．調査結果の正式な報告に先立ち，まずアナリスト往訪記録と呼ばれる文書に簡潔にまとめる．継続的に調査を行い，十分に情報を収集したところで，アナリストレポートと呼ばれる報告書にまとめる．このアナリストレポートを1つの情報源としてファンドマネージャは投資先企業を選定する．

しかし，この投資先企業の選定フローには 3 つの問題がある．1 点目は，膨大な数に上るアナリストレポートを担当部署の各員が目を通し，投資先企業を決定しているということである．アナリストレポートは図表も文章量も多いため，各ファンドマネージャが複数のレポートを通読するのに相応の時間が必要となる．2 点目は，アナリストが調査先企業の情報を入手してから，アナリ

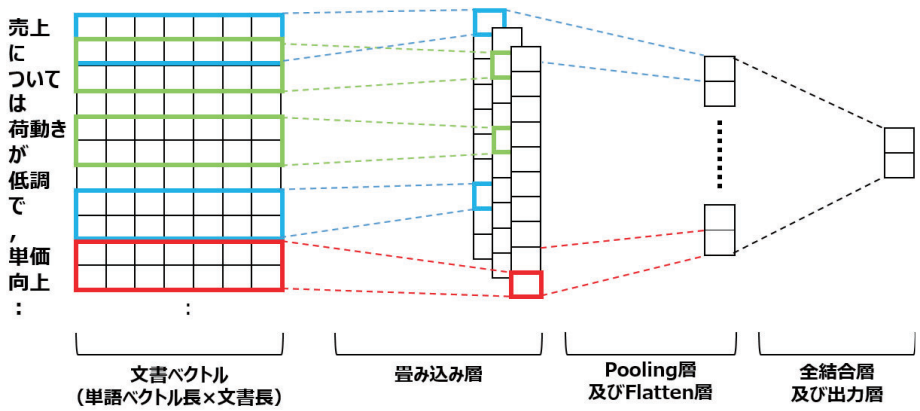


図 2 CNN を用いた文書分類モデルの概念図

ストレポートを発行するまでに時間がかかるということである．アナリストは十分な情報を収集してからレポートを発行するため，判断の遅れが大きな機会損失につながる可能性がある．3 点目は，アナリストレポートには，アナリストが十分な自信や裏づけを持った内容しか掲載しないということである．投資判断を左右する情報源を提供するため，アナリストは自らの提出したアナリストレポートの説明責任を負っている．したがってアナリストの率直な意見や経験に基づく勘など，業績判断に有用だが裏打ちの少ない内容はアナリスト往訪記録のみに記載され，アナリストレポートには記載されない傾向がある．その結果として投資機会を逃してしまうケースが少なからず存在する．

これらの問題点を踏まえて，人間が読むには多くの負担がかかるが，アナリストの本音やニュアンスといった有用な情報が含まれていると考えられ，速報的に発行されるアナリスト往訪記録を分析し，定量的な出力を行うモデルを構築することで，これらの問題点を解決すると共に，有用なシステム開発の一助になると考えている．

3. 提案手法

本論文では文書の判定に CNN を用いた．CNN の模式図は図 2 の通りである．CNN を用いた理由の 1 つ目として，CNN の特徴である位置不変性に注目したからである．アナリスト往訪記録では，公平性を期した報告の必要性から，一文書内に極性が混在するという特性がある．また 2 つ目として，モデルの学習結果の可視化が容易だと考えたからである．運用会社は投資家に対し自身の投資の根拠について説明する責任を持つ．そこで可読性と極性揺らぎへのロバスト性をあわせもつと期待される CNN を用い，往訪記録に対する景況感判定を試みた．

3.1 判定を行うネットワーク

先行研究として既に CNN を用いて文書分類を行う研究がなされている[Kim 2014]．Kim らは極性判定タスクでの検証に映画レビューデータセットを使用している．しかしこのデータセットに比べて，今回の解析対象のアナリスト往訪記録には 1 文書内に極性が混在する文章が多い．これは自らの調査結果をポジネガ双方向からの視点で述べる必要があるからである．したがって局所表現ではなく，文書全体の傾向を見る必要があると予想した．すなわち，プーリング層にはデータの削除によってデータサイズを小さくする MaxPooling ではなく，全体的な特徴を残したままデータを伝播できる AveragePooling がより適切だと考えた．

3.2 文書ベクトルの作成

アナリスト往訪記録及びアナリストレポートについて適当な前処理を行った後，MeCab[工藤 2004]を用いて分かち書きを行った．活用を行う品詞は全て原型に変換した．辞書として NEologd[Sato 2015]を用いた．

次に，単語ベクトルを作成した．上記で作成したコーパスを元に Word2Vec[Mikolov 2013]で各単語ベクトルの学習を行った．本論文では単語ベクトルの学習に用いたコーパスにはアナリスト往訪記録及びアナリストレポートを用いた．アナリストが用いる語彙は特徴的であるためこのドメインに特化したモデルの構築という目的においては，大規模なコーパスを用いるより，少ないながらもドメインに特化したコーパスを用いる方が良いと考えたからである．

最後に文書ベクトルを作成した．作成対象の文章に出現する順番に単語ベクトルを並べてゆき，(Word2Vec の次元数×各文書の単語数)の 2 次元配列として文書ベクトルを作成した．固定長のベクトルとしてモデルに入力するため，今回は各文書で 300 単語を上限として文書の前方から取り出した．また 300 単語に満たない文書においては，文書ベクトル後部をゼロパディングし，サイズを統一した．

4. 性能評価

4.1 使用したデータ

本研究では，三井住友 DS アセットマネジメント株式会社（旧，大和住銀投信投資顧問株式会社）の協力のもと，アナリスト往訪記録及びアナリストレポートを使用した．各データ数の詳細は表 1 の通りである．

表 1 使用した金融文書の構成

文書種類		数量
アナリスト往訪記録	ポジティブ	838
	ネガティブ	573
	ニュートラル	1,834
	ラベルなし	12,261
アナリストレポート		21,892

事前学習として Word2Vec の学習を行う必要があるが，今回はアナリスト往訪記録及びアナリストレポートの全文章を用いた．また提案手法の評価には，入力した文書から景況感判定を行うためラベル付きのデータが必要である．今回の評価ではアナリ

スト往訪記録のうち，ポジネガのラベルをもつ 1,411 文書のみを対象として評価を行った．

4.2 Word2Vec について

今回は Word2Vec の学習に Python モジュールである gensim[Řehůřek 2010]を用いた．Word2Vec の学習に用いたパラメーターは表 2 の通りである．本研究では一文書内にポジネガが混在する特性を考慮し，文ごとに学習を行った．

表 2 Word2Vec のパラメーター

Parameters	
Vector size	500
Window	10
Min_count	1
iter	50

4.3 CNN について

まず，本実験において用いた CNN の構成を表 3 に示す．またこのネットワークのパラメーターを表 4 に示す．

表 3 検証に使用した CNN のモデル

Name	Shape	Operation performed
Input	500×300×1	-
Conv-1	1×296×32	500×5 convolution 32 filters
Activate-1	1×296×32	ReLU activation
Pool-1	1×74×32	1×4 AveragePooling
Conv-2	1×74×32	1×5 convolution 32 filters
Activate-2	1×74×32	ReLU activation
Pool-2	1×18×32	1×4 AveragePooling
Flatten	576	-
Dropout-1	576	50 % dropout
Dence-1	32	Fully connected
Activate-3	32	ReLU activation
Dropout-2	32	50 % dropout
Dence-2	2	Fully connected
Activate-4	2	Softmax activation
Output	2	Binary classification

Input 層に入力されるデータが各文書ベクトルである．畳み込み層と Pooling 層を交互に 2 層ずつ，その後 2 層の全結合層ののち出力層で二値分類を行い，景況感判定を行うモデルである．

表 4 CNN のパラメーター

Parameters	
Optimizer	Adam[Diederik 2014]
Epochs	25
Batch sizes	100
Random Sampling	True
Validation	10-fold cross validation
Learning rate(Adam)	0.001
Beta_1(Adam)	0.9
Beta_2(Adam)	0.999

モデルの評価では 10-fold cross validation を行った．1 epoch 終了ごとにテストデータで評価を行い，精度を記録した．

このモデルの学習は 25 epochs 行い，最終 10 epochs 分の結果を平均し，精度とその分散を求めた．

4.4 比較手法

今回は提案手法の有効性を比較するための baseline として後述の 2 手法においても同様に景況感判定を行った．10-fold cross validation を行い，平均値をモデルの精度とした．

(1) Word2Vec+SVM[Boser 1992]

Word2Vec+SVM では，提案手法と同様に学習した単語ベクトルを文書内で加算平均することで文書ベクトルとした．この文書ベクトルを SVM に入力し景況感判定を行った．

SVM には Python モジュールである scikit-learn[Pedregosa 2011]を用いた．

(2) Doc2Vec+SVM

Doc2Vec+SVM では提案手法と同様のデータセットから学習した Doc2Vec を用いて文書ベクトルを作成した．文単位でベクトルを作成し，文書内で加算平均することで文書ベクトルとした．この文書ベクトルを用いて(1)と同様に評価を行った．

4.5 実験結果

今回の実験結果は表 5 のようになった．また提案モデルの Epoch 毎の Accuracy 変化は図 3 のようになった．

表 5 提案手法と baseline の精度比較

Model Name	Accuracy[%]	分散
提案手法	81.4	13.7
Word2Vec+SVM	75.7	17.0
Doc2Vec+SVM	66.8	6.19

比較手法のうち，提案手法が一番良い精度を得られた．baseline として比較したモデルでは Word2Vec+SVM が最も良い精度であった．十分なデータが存在していたため，単語ベクトルが十分に学習できていたためであると考えられる．また Doc2Vec では分散が最も小さい値となったが，Accuracy が最も低くなった．

また Epoch 毎の精度変化であるが，7epoch 程度で学習が一旦安定化していることがわかる．そして徐々に Accuracy が上昇した後細かな上下を繰り返している．これは過学習抑制を狙い，Dropout 層を 2 層使用しており，ランダムに結合重みが更新されているためであると考えられる．このまま学習を続けることで過

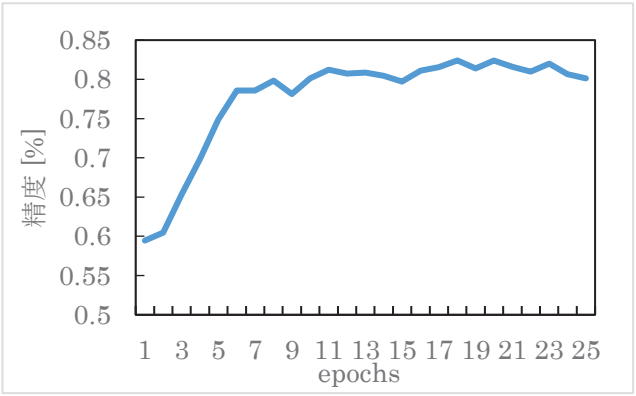


図 3 エポック毎の精度変化

学習が発生することが想定されるため，どのタイミングで学習を終え，実際の業務のシステムに組み込んで使用するかが今後の課題である．

5. まとめ

本研究では，運用会社の運営を補助するシステム開発の一助として，アナリスト往訪記録における文書の景況感判定に有効なモデルの提案を行った．その結果ラベルの付いたアナリスト往訪記録において 81%程度の性能が得られた．

今後の展望としては，今回の研究で分かち書きの際に使用した汎用的な辞書ではなく，アナリスト特有の語彙に対応した辞書の作成を考えている．

アナリスト往訪記録を定量的に分析できるモデルの構築が出来たことから，このモデルを礎に業務補助を行うシステムの開発へと進んでいくことが出来るであろう．

参考文献

[Boser 1992] Bernhard E. Boser., Isabelle M. Guyon, Vladimir N. Vapnik: A training algorithm for optimal margin classifiers, COLT '92 Proceedings of the fifth annual workshop on Computational learning theory, Pages 144-152, ACM , 1992.

[Diederik 2014] Diederik P. Kingma, Jimmy Lei Ba, Adam: A Method for Stochastic Optimization, ICLR 2015, 2015

[Kim 2014] Yoon Kim: Convolutional Neural Networks for Sentence Classification, Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), Association for Computational Linguistics , 2014.

[LeCun 1998] Yann LeCun, Léon Bottou, Yoshua Bengio, Patrick Haffner: Gradient-Based Learning Applied to Document Recognition , Proceedings of the IEEE 86(11), Pages 2278-2324, IEEE , 1998.

[Mikolov 2013] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space, In Proceedings of ICLR Workshops Track, 2013.

[Pedregosa 2011] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, et al.: Scikit-learn: Machine Learning in Python, JMLR 12, pp. 2825-2830 , JMLR, Inc. and Microtome Publishing , 2011.

[Řehůřek 2010] Radim Řehůřek and Petr Sojka: Software framework for topic modelling with large corpora , THE LREC 2010 WORKSHOP ON NEW CHALLENGES FOR NLP FRAMEWORKS, University of Malta , 2010.

[Sato 2015] Toshinori Sato, Taiichi Hashimoto and Manabu Okumura: Operation of a word segmentation dictionary generation system called NEologd (in Japanese), Information Processing Society of Japan, Special Interest Group on Natural Language Processing (IPSJ-SIGNL) , Information Processing Society of Japan, 2016.

[小林 2017] 小林 和正, 酒井 浩之, 坂地 泰紀, 平松 賢士: アナリストレポートからのアナリスト予想根拠情報の抽出と極性付与, 人工知能学会研究会資料, 一般社団法人情報処理学会, 2017.

[工藤 2004] 工藤 拓, 山本 薫, 松本 悠治: Conditional Random Fields を用いた日本語形態素解析, 情報処理学会研究報告自然言語処理(NL), 一般社団法人情報処理学会, 2004.

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

非階層型クラスタリング・リスクパリティによる資産配分戦略

Asset Allocation Strategy with Non-Hierarchical Clustering Risk Parity Portfolio

中川 慧　伊藤 彰朗　川原 一修
Kei Nakagawa　Akio Ito　Takanobu Kawahara

野村アセットマネジメント株式会社
Nomura Asset Management Co,ltd

Since the great financial crisis of 2008, many studies have pointed out that even in the portfolio where the asset allocation is sufficiently diversified, it is still possible that risk allocation is well concentrated to a few assets. One approach to this problem is risk parity strategies which equalize the risk contribution of each asset. However, even if we equalize the risk contribution, risk sources are not necessarily diversified.

In this paper, we propose non-hierarchical clustering-risk parity strategy which will equalize risk contribution from and within each cluster. In addition, in order to ensure robustness of clustering, we also propose x-means++ algorithm which combines k-means++ with x-means. Assuming assets with similar movement have common risk sources, our approach will construct a portfolio which equalizes risk sources. Empirical analysis using actual price data of various asset classes shows that our proposed method will outperform risk-parity strategies or hierarchical clustering risk parity strategies.

1. はじめに

2008 年の金融危機以降、資産配分が十分に分散されているポートフォリオでも、リスク配分は大きな偏りが生じている点が指摘されるようになった。伝統的にポートフォリオは、[Markowitz 52] の平均分散アプローチにより構築される。この手法は、期待リターンとリスクを用いて最適化を実行し、最適な投資ウェイトを算出する。しかし、推定の難しい期待リターンの推定誤差により、非常に偏ったウェイトを算出しがちであり、意図したとおりの分散されたポートフォリオが構築できないことが指摘されている [Michaud 89]。この問題に対するアプローチの一つとして、各資産のリスク寄与度を等しくする、リスクパリティ戦略に注目が集まっている。リスクパリティは全ての資産のリスク寄与度 (配分) が等しいポートフォリオである ([Qian 05])。また、[Nakagawa 18] によると、平均分散と異なり、リスクパリティは共分散行列の推定精度にパフォーマンスは依存しない。一般に、年金運用のポートフォリオには、リスク寄与度に大きな偏りがあると言われてきた。債券と株式に分散投資をしても、株式のリスクは債券より大幅に大きいため、ポートフォリオのリスク寄与度は株式が大半を占める。そもそも分散投資を行うのは、ある資産が不調の時に、他の資産で全体のパフォーマンスを支えることを期待しているからである。しかし、株式のリスク寄与度が大半を占める状態では、他の資産が株式の不調を補うまでには至らず、期待した分散投資による効果が得られない。リスクパリティ戦略は、こうした状態に対する代替案として提唱された。リスクパリティの概念は、資産配分問題へ適用され多くの先行研究がある。例えば、[Qian 05] は株式と債券への投資割合が 60:40 の伝統的なバランス型のポートフォリオと比較して、リスクパリティのパフォーマンスがシャープレシオで測ってより効率的であることを実証している。一方で、リスクパリティ戦略には課題も指摘されている。多くの先行研究で指摘される点は、リスク寄与度を等しくしても、リスクの源泉を分散したことにはならない点である [Meucci 09, Uchiyama 19]。

そこで本稿では、まず各資産に対して、非階層クラスタリングを用いて似た変動をする資産グループを特定する。そして、各クラスタ毎およびクラスタ内の両方でリスク寄与度が均等になる、階層型クラスタリング・リスクパリティ戦略を提案する。また、クラスタリングのロバスト性を担保するため、x-means アルゴリズムに k-means++アルゴリズム [Arthur 07] を組み合わせた x-means++を提案する。似た変動をする資産グループをリスクの源泉が同一であると仮定すれば、提案手法により、リスクの源泉を均等にしたポートフォリオが構築できる。

実際に様々な資産クラスの価格データを用いた実証分析の結果、提案手法は通常のリスクパリティ戦略 [Qian 05] および先行研究の階層型クラスタリング・リスクパリティ戦略 [Prado 16] よりも良好なパフォーマンスであることを確認した。

連絡先: 中川 慧, 野村アセットマネジメント株式会社 資産運用先端技術研究室
k-nakagawa@nomura-am.co.jp

2. リスクパリティ

以下では、N 個の資産を考え、それらの収益率 (確率変数) を $\boldsymbol{R} = (R_1, \cdots, R_N)^{\mathrm{T}}$、それぞれのウェイトを $\boldsymbol{w} = (w_1, \cdots, w_N)^{\mathrm{T}}$、期待収益率を $\boldsymbol{\mu} = (\mu_1, \cdots, \mu_N)^{\mathrm{T}}$、分散共分散行列を $\boldsymbol{\Sigma} = E[(\boldsymbol{R} - \boldsymbol{\mu})(\boldsymbol{R} - \boldsymbol{\mu})^{\mathrm{T}}]$ と書く。

リスクパリティの具体的な定式化のため、ポートフォリオのリスク $\sigma_P = \sqrt{\boldsymbol{w}^{\mathrm{T}}\boldsymbol{\Sigma}\boldsymbol{w}}$ をウェイト $\boldsymbol{w}$ で微分した (1) 式の限界リスク寄与 (Marginal Risk Contribution;MRC) を定義する。これによりポートフォリオのリスクは (2) 式のように MRC を用いて分解することができる。そして (2) 式をポートフォリオのリスクで除すことで、リスクの寄与度 (Risk Contribution; RC) が定義される。リスクパリティの満たす条件は、この RC_i が各資産で一定になることである。

$$MRC = \frac{\partial \sigma_P}{\partial \boldsymbol{w}} = \frac{\boldsymbol{\Sigma}\boldsymbol{w}}{\sigma_P} \tag{1}$$

$$\sigma_P = \sum_{i=1}^{N} w_i \times MRC_i = \boldsymbol{w}^{\mathrm{T}} MRC \tag{2}$$

$$RC_i = w_i \times MRC_i \tag{3}$$

空売りとレバレッジを許さない場合には [Maillard 10] において (4) 式の最小化問題を解くことで効率的にウェイトが計算できることが示されている。しかも、(4) 式は凸最適化問題であり、ユニークな解を持つ。

$$\min_{\boldsymbol{w}} \sum_{i=1}^{N}\sum_{j=1}^{N}(RC_i - RC_j)^2 \quad (4)$$

$$s.t. \sum_{i=1}^{N} w_i = 1, w_i > 0 \quad (5)$$

3. 提案手法:非階層型クラスタリング・リスクパリティ

リスクパリティは見方を変えるとリスク配分をコントロールしている考えられる。この観点から、リスク寄与度 RC に対して等寄与ではなく、個別に寄与度を指定することができる。このようなリスク寄与度を配分するポートフォリオをリスクバジェッティング戦略という [Roncalli 13]。このリスクバジェッティング戦略を用いて、リスク寄与度をクラスタ間およびクラスタ内で均等にすることが目標である。クラスタを定義するにあたり、クラスタリングのロバスト性を担保するため、非階層型クラスタリング手法である x-means アルゴリズム [石岡 06] に k-means++法 [Arthur 07] を組み合わせた x-means++を提案する。

3.1 x-means++ アルゴリズム

階層的クラスタリング手法である、k-means 法は実装が容易であり計算効率にも優れているため、クラスタリングにおける定番アルゴリズムとなっている。k-means 法は、クラスタの重心点であるセントロイド C_i をクラスタの代表点とし、入力データを x とすると $\sum_k \sum_{x \in C_i} (d(x, C_i))^2$ の評価関数を最小化するように k 個のクラスタを分割する。具体的には、対象のクラスタへの割り当てと代表点の再計算を交互に繰り返して行う。

一方で、初期値が不適切であるときにうまく分類ができなかったり、クラスタの個数 k を指定しなければならないといった問題も抱えている。前者の問題について解決を図るために k-means 法の改良として考案されたのが、k-means++法 [Arthur 07] である。後者の問題について k-means 法の改良として提案されたのが、x-means 法 [石岡 06] である。我々は、k-means++法における初期値の設定を x-means 法に組み合わせる。以下では提案手法の構成要素である x-means アルゴリズムと k-means++法について概観する。

k-means++法

k-means++法の特徴はセントロイド C_i の初期値の決定方法にある。n 個の入力データ x_i を k 個のクラスタに分類するとき、次の手順で各セントロイドの初期値を決める。

1. 入力データを一つランダムに選択し、その座標をクラスタ 1 のセントロイドの初期値とする。
2. 全データに対し、既に座標が決定している最も近いセントロイドとのユークリッド距離を計算する。ここで x_i と最近傍のセントロイドとの距離を $d(x_i)$ とおく。
3. データ x_p の座標を、次のセントロイドの座標として以下の式の確率で選択する。$d(x_p)^2 / \sum_{i=1}^{n-1} d(x_i)^2$ ここで既にセントロイドの座標として選ばれているデータは、最近傍のセントロイドとの距離が 0 であり、選択される確率も 0 になり、分母の総和に影響を与えない。
4. 手順 2〜3 を k 個のセントロイドの初期値が選択されるまで繰り返す。

x-means 法

x-means 法は、あらかじめクラスター数を決めておかなければならない k-means 法とは違い、最適なクラスター数を推測することができる。x-means 法の考え方は、$m = 2$ で再帰的に k-means 法を実行していくというもので、クラスタの分割前と分割後でベイズ情報量規準 (BIC) を比較し、BIC が改善 (低下) しなくなるまで分割を続ける。つまり、分割前の BIC を B_1、分割後の BIC を B_2 とし、

1. $B_1 > B_2$ ならば 2 分割する
2. $B_1 \leq B_2$ ならば 2 分割しない

を 2 分割できなくなるまで繰り返すことで最適なクラスター数を決定する。BIC は以下のように定義される。p 変量正規分布を $f(X;\theta_i) = \frac{1}{(2\pi)^{p/2}\sqrt{\det|\Sigma_i|}} \exp\{-\frac{1}{2}(X-\mu_i)^T\Sigma_i^{-1}(X-\mu_i)\}$ と仮定すると、$BIC = 2\log L(X;\theta_i) + q\log n_i$ ここで $\theta_i = [\mu_i, \Sigma_i]$ は、p 変量正規分布の最尤推定値とする。μ_i は p 次の平均値ベクトル、Σ_i は $p \times p$ の分散共分散行列であり、q は自由度で、Σ_i の共分散を無視すれば (0 とおくと)$q = 2p$ である。一方で、共分散を無視しなければ $q = p(p+3)/2$ である。L は尤度関数で $L(\cdot) = \prod f(\cdot)$ で、n_i はデータ数である。2 分割したモデルにおける BIC は以下のようになる。$BIC = 2\log L(X;\hat{\theta}_i) + q\log n_i$

$\hat{\theta}_i = [\hat{\theta_1}, \hat{\theta_2}]$ は、2 分割されたそれぞれの p 変量正規分布の最尤推定値とする。共分散を無視すれば、各 p に対し平均と分散の 2 つのパラメータが存在するので、パラメータ空間の次元は $q = 2 \times 2p = 4p$ となる。共分散を無視しなければ $q = 2p = p(p+3)$ である。

また、x-means 法に改良を加えた方法に、石岡がある。石岡 [石岡 06] は、x-means 法の 2 分割手続きによって生成されたクラスターを再評価し、必要ならばそれらのクラスターを併合するという手続きを加えることで、x-means 法の性能が格段に向上することを、シミュレーションによって示している。

3.2 非階層型クラスタリング・リスクパリティ

リスクパリティは見方を変えるとリスク配分をコントロールしている考えられる。この観点から、リスク寄与度 RC に対して等寄与ではなく、他の寄与の方法を指定することができる。このようなリスク寄与度を配分するポートフォリオをリスクバジェッティング戦略という [Roncalli 13]。

本稿では、リスク寄与度をクラスタ間およびクラスタ内で均等にすることが目標である。そのために資産のリターンを用いて非階層型クラスタリングを行い、その結果を用いてクラスタを定義する。そして、総クラスタ数を k、各クラスタ内の資産数を N_k とすると、次の最適化を解くことで目標のポートフォリオを構築できる。定式化からこのポートフォリオはクラスタ間、およびクラスタ内の資産間の両方でリスク寄与度が均等になっていることがわかる。これが非階層型クラスタリング・リスクパリティ戦略である。

$$\min_{\boldsymbol{w}} \sum_{i=1}^{N} \left(RC_i - \frac{1}{k} \times \frac{1}{N_k} \right)^2 \quad (6)$$

$$s.t. \sum_{i=1}^{N} w_i = 1, w_i > 0$$

本稿では、非階層型クラスタリングに前章の $x-$means++ 法を用いる。

4. 実証分析

株式、債券、為替、商品といった様々な資産クラスのデータを用いて分析を行う。投資対象資産は表 1 の通りである。各資産のデータの取得期間は異なるものの、1999 年 1 月から 2018 年 1 月までの月次データを分析対象としている。

比較手法として、通常のリスクパリティ戦略 (RP)、先行研究 [Prado 16] の階層型クラスタリング・リスクパリティ戦略 (HRP)、k を固定した k-means++法と x-means++法によるクラスタリング・リスクパリティ戦略 (CRP、XRP) である。k-means++法の k として、2 から 10 を使用した。具体的なシミュレーション手順は次の通りである。まず過去 120 カ月のデータを使用して、共分散行列または各手法を用いたクラスタリングを行い、その結果を用いて各ポートフォリオを構築し、毎月リバランスで運用する。検証期間は 2009 年 2 月から 2018 年 1 月までの 108 カ月である。様々な資産クラスを対象とした分析であり、各ポートフォリオのリスク水準が大きく異なる可能性があるため、ポートフォリオの運用効率を示すリスク/リターンを評価する。結果は表 2 通りである。RP はリスクパリティ、CxRP はそれぞれクラスタ数を x 個に固定した非階層型クラスタリングリスクパリティ、HRP は階層型クラスタリスクパリティ、XRP は提案手法の x-means++による非階層型クラスタリスクパリティを表す。ここあら提案手法がリスク/リターンで見て最も優れていることが確認できた。

5. まとめ

本研究では、まず各資産に対して、非階層クラスタリングを用いて似た変動をする資産グループを特定し、各クラスタ毎およびクラスタ内の両方でリスク寄与度が均等になる、階層型クラスタリング・リスクパリティ戦略を提案した。また、クラスタリングのロバスト性を担保するため、x-means アルゴリズムに k-means++アルゴリズム [Arthur 07] を組み合わせた x-means++を提案した。似た変動をする資産グループをリスクの源泉が同一であると仮定すれば、提案手法により、リスクの源泉を均等にしたポートフォリオが構築できる。

実際に様々な資産クラスの価格データを用いた実証分析の結果、提案手法は通常のリスクパリティ戦略 [Qian 05] および先行研究の階層型クラスタリング・リスクパリティ戦略 [Prado 16] よりも良好なパフォーマンスであることを確認した。

今回は様々な資産クラスをベースにした実証分析を行ったが、株式市場の個別銘柄ベースのさらに大規模な検証を行い、提案手法の頑強性を検証すること、そして、[Uchiyama 19] のように複素リスクへと拡張したリスク分散戦略についてクラスタ化を行うことなどが今後の検討課題として挙げられる。

参考文献

[Arthur 07] Arthur, D. and Vassilvitskii, S.: k-means++: The advantages of careful seeding, in *Proceedings of the*

表 1: 投資対象資産の一覧

Name	Ticker	Class
ICE ブレント原油先物	CO1 Comdty	商品
ICE 軽油先物	QS1 Comdty	商品
WTI 原油	CL1 Comdty	商品
NY 改ガソリン先物	XB1 Comdty	商品
NYM 灯油	HO1 Comdty	商品
NY 天ガス	NG1 Comdty	商品
NYB コットン	CT1 Comdty	商品
NYB コーヒー	KC1 Comdty	商品
NYB ココア	CC1 Comdty	商品
NYB 砂糖	SB1 Comdty	商品
CBT 大豆	S 1 Comdty	商品
KCBT Hard Red Winter Wheat	KW1 Comdty	商品
CBT コーン	C 1 Comdty	商品
CBT 小麦	W 1 Comdty	商品
CME 豚赤身先物	LH1 Comdty	商品
CME Feeder Cattle Future	FC1 Comdty	商品
CME 生牛	LC1 Comdty	商品
CMX 金先物	GC1 Comdty	商品
銀先物	SI1 Comdty	商品
LME アルミ新地金 先物	LA1 Comdty	商品
LME ニッケル 先物	LN1 Comdty	商品
LME 鉛 先物	LL1 Comdty	商品
LME 亜鉛 先物	LX1 Comdty	商品
CMX 銅	HG1 Comdty	商品
ユーロ/米ドル	EUR Curncy	為替
オーストラリア ドル	AUD Curncy	為替
カナダ ドル	CAD Curncy	為替
デンマーク クローネ	DKK Curncy	為替
米ドル/円	JPY Curncy	為替
ニュージーランド ドル	NZD Curncy	為替
ノルウェー クローネ	NOK Curncy	為替
スウェーデン クローナ	SEK Curncy	為替
スイス フラン	CHF Curncy	為替
英ポンド	GBP Curncy	為替
シンガポール ドル	SGD Curncy	為替
香港 ドル	HKD Curncy	為替
南アフリカ ランド	ZAR Curncy	為替
ポーランド ズロチ	PLN Curncy	為替
CBOT10 年 米国債先物	TY1 Comdty	債券
SFE 10 Year Australian Bond	XM1 Comdty	債券
Montreal Exchange 10 Year	CN1 Comdty	債券
Eurex 10 Year Euro BUND	RX1 Comdty	債券
Long Gilt Future	G 1 Comdty	債券
長国先物	JB1 Comdty	債券
Euro-BTP Italian Bond Future	IK1 Comdty	債券
French Government Bond	OAT1 Comdty	債券
S&P500 先物 CME	SP1 Index	株式
SP トロント 60 指数先物	PT1 Index	株式
FTSE100 指数先物	Z 1 Index	株式
CAC40 先物	CF1 Index	株式
DAX 先物 EUX	GX1 Index	株式
IBEX35 先物 MEFF	IB1 Index	株式
FTSE/MIB Index Future	ST1 Index	株式
AEX 指数先物	EO1 Index	株式
OML Stockholm OMXS30 Index	QC1 Index	株式
スイス株価式指数先物	SM1 Index	株式
日経先物 OSE	NK1 Index	株式
ハンセン先物	HI1 Index	株式
ASX 200 指数先物	XP1 Index	株式
KFE KOSPI 200 Index	KM1 Index	株式
OBX OSLO Index	OI1 Index	株式
SGX MSCI Singapore Index	QZ1 Index	株式
ICE 米国 EM インデックス	MES1 Index	株式

表 2: 検証期間は 2009 年 2 月から 2018 年 1 月までの月次リバランスポートフォリオのシミュレーション結果のサマリー。RP はリスクパリティ、CxRP はそれぞれクラスタ数を x 個に固定した非階層型クラスタリングリスクパリティ、HRP は階層型クラスタリスクパリティ、XRP は提案手法の x-means++による非階層型クラスタリスクパリティ。

	RP	C2RP	C3RP	C4RP	C5RP	C6RP	C7RP	C8RP	C9RP	C10RP	HRP	XRP
年率リターン	5.99%	11.04%	11.55%	8.21%	6.78%	6.05%	6.82%	6.36%	5.68%	4.75%	0.42%	7.22%
年率リスク	7.70%	16.41%	16.34%	11.07%	10.30%	9.39%	9.84%	9.45%	8.75%	8.86%	0.98%	8.72%
リターン/リスク	0.78	0.67	0.71	0.74	0.66	0.64	0.69	0.67	0.65	0.54	0.44	0.83
合計収益率	53.91%	99.39%	103.94%	73.86%	61.01%	54.46%	61.37%	57.26%	51.16%	42.74%	3.82%	64.98%

eighteenth annual ACM-SIAM symposium on Discrete algorithms, pp. 1027–1035Society for Industrial and Applied Mathematics (2007)

[Maillard 10] Maillard, S., Roncalli, T., and Teïletche, J.: The Properties of Equally Weighted Risk Contribution Portfolios, *Journal of Portfolio Management*, Vol. 36, No. 4, p. 60 (2010)

[Markowitz 52] Markowitz, H.: Portfolio selection, *The journal of finance*, Vol. 7, No. 1, pp. 77–91 (1952)

[Meucci 09] Meucci, A.: Managing diversification, *Risk*, Vol. 22, No. 5, p. 74 (2009)

[Michaud 89] Michaud, R. O.: The Markowitz optimization enigma: Is 'optimized' optimal?, *Financial Analysts Journal*, Vol. 45, No. 1, pp. 31–42 (1989)

[Nakagawa 18] Nakagawa, K., Imamura, M., Yoshida, K., et al.: Risk-Based Portfolios with Large Dynamic Covariance Matrices, *International Journal of Financial Studies*, Vol. 6, No. 2, pp. 1–14 (2018)

[Prado 16] Prado, de M. L.: Building Diversified Portfolios that Outperform Out of Sample, *The Journal of Portfolio Management*, Vol. 42, No. 4, pp. 59–69 (2016)

[Qian 05] Qian, E.: Risk parity portfolios: Efficient portfolios through true diversification, *Panagora Asset Management* (2005)

[Roncalli 13] Roncalli, T.: *Introduction to risk parity and budgeting*, CRC Press (2013)

[Uchiyama 19] Uchiyama, Y., Kadoya, T., and Nakagawa, K.: Complex Valued Risk Diversification, *Entropy*, Vol. 21, No. 2, p. 119 (2019)

[石岡 06] 石岡恒憲 : x-means 法改良の一提案: k-means 法の逐次繰り返しとクラスターの再併合, 計算機統計学, Vol. 18, No. 1, pp. 3–13 (2006)

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

人-AI 関係の文化差を共視論から考える:試行的分析

A preliminary discussion on cultural variabilities in human-AI relation: a trial of application with "viewing together" theory

佐倉 統[*1, *2] 福住 伸一[*2] 中川 裕志[*2]

Osamu Sakura Shin'ichi Fukuzumi Hiroshi Nakagawa

[*1] 東京大学大学院情報学環 [*2] 理化学研究所革新知能統合研究センター

University of Tokyo RIKEN-AIP

The aim of the paper is to demonstrate the possibility that iconographical analysis of the composition of humans and AI/robots would contribute to acquire new perspectives in cultural variabilities in public image and social epistemology of AI/robots. While placing humans and AI/robots side by side is preferred in Japanese pictures, Western photos tend to capture humans and AI/robots with gazing together. Applying the theory of "viewing together," or joint attention, we may suggest from the observed difference that Japanese society may regard AI/robots as more human-like agents, or may consider them in more anthropomorphic way than in Western countries. We need more organized analysis of pictures on the internet, careful investigation of the concept of animism, as well more systematic comparative surveys of the public images of AI/robots within East-Asian countries which share many of ecological and cultural conditions.

1. はじめに

人工知能(AI)やロボットのような萌芽的技術(emergent technology)が社会に普及・定着する過程や要因は,技術の開発供給側からだけでは適切には把握できない.その技術が普及した帰結として,開発者が予想していなかった機能が出現したり,想定外の影響が生じたりすることがしばしば生じるからである [佐倉 19].これらの現象や過程を“技術の社会的形成 social shaping of technology”と総称する [MacKenzie 99].この過程において重要なのは,時代的制約や社会の側の文化的背景,歴史的経緯などである.昨今,AI やロボットも含めて,萌芽的技術の社会普及を考察する際に倫理的・法的・社会的諸課題(ethical, legal, and social issues: ELSIs)の重要性がしばしば強調されるが――そしてそのことは一概に悪いことではないのだが――,技術と社会が双方向に影響し合っていく形成過程を考えれば,ELSI だけを考慮するのでは不十分であり,社会の文化的・歴史的背景や,社会の中での技術の生態系的動態を視野に入れて考察する必要がある [佐倉 19].

AI やロボットについての文化比較研究は,認知科学や文化人類学をベースにしたものがいくつかある [e.g., MacDorman 08, Nomura 15, Syrdal 13].しかしこれらのほとんどは文化的な差異があるのか,あるとすればどのようなものなのか,についての実証的研究であり,その差異のよってきたるところについての分析は主たるテーマではない.また,多くは日本と”欧米”の比較であり,東アジア文化圏を視野に入れた比較研究は少数である.

文化的背景についての考察を深めたものとしては,情報文化思想研究者の西垣通が AI 研究をめぐるユダヤ=キリスト教的偏向を指摘している [西垣 88, 18].また人工生命については,文化人類学者の Stefan Helmreich が生命概念の西洋的(さらにいえば白人的,男性的)偏向を踏まえつつ,人工生命研究の文化的多元性の可能性を論じている [Helmreich 98].しかし,人工知能や人工生命の一般社会におけるイメージ(public image)についての考察は必ずしも十分ではない.

連絡先:佐倉統,東京大学情報学環/理研 AIP,東京都文京区本郷 7-3-1, sakura@iii.u-tokyo.ac.jp

本研究ではこれらの先行諸研究を踏まえ,日本の一般社会における AI/ロボットのパブリックイメージが諸外国とどのように異なるか,また違いがあるとすればその原因は何なのかを推測するための,理論的枠組みと方法論についての予備的な検討をおこなう.

調査対象は,人と AI/ロボットとが一緒に写っているウェブ上の写真である.写っているときの構図(どのような位置関係にあるか)を予備的に分析する.

その結果を,共同注視研究 [遠藤 06] や共視論 [北山 05a] を援用し,人と AI/ロボットとの視線の方向から両者がどのような関係にあると想定されているかを推測する.次に,劇場型文化論 [田中 2005] と鑑賞者の視点移動論 [高階 96] を援用し,被写体である AI/ロボットと鑑賞者との関係が独立していないことの文化的意味を解釈する.

本稿の内容はいずれも,理論的にも実証的にも未整備の段階の仮説あるいは展望であり,今後,解決すべき課題を整理する.必要がある.以下,順に詳述する.

2. 共視論からの予備的分析

人と AI/ロボットが一枚の写真に収まるときの構図を見ると,日本では横並びが,欧米では相互に向き合った構図が多いように思える.ごく大雑把な予備調査として,日本語で {人, ロボット, 関係} を検索語として画像検索した場合と,英語で {human, robot, relation} で画像検索した場合の結果を,図 1,2 に示す(どちらも 2019 年 2 月 7 日検索).厳密な比較をおこなうことではなく,本調査のための作業仮説を導くための”見当”を付けるのが目的である.英語を検索語とした場合は相互に向かい合っている構図が,日本語の場合は横並び,あるいは人と AI/ロボットが何か他のものを共に注視している構図が,多いように見てとれる.

この違いは,人と AI/ロボットの関係が両者だけの世界で完結しているか,こちら側(写真撮影者や鑑賞者)にも開かれたものになっているか,の違いである.この“こちら側”は,すなわち写真の中の人と AI/ロボットにとっての“第三項”である.つまり,

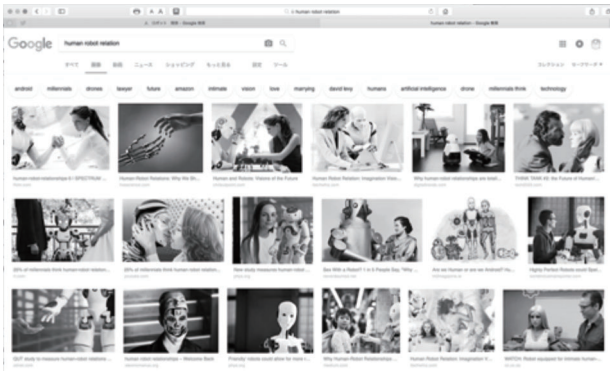


図 1　英語を検索語としたときの human-robot relation のイメージ例（2019 年 2 月 7 日検索）．人とロボットが向かい合っている構図が多い．

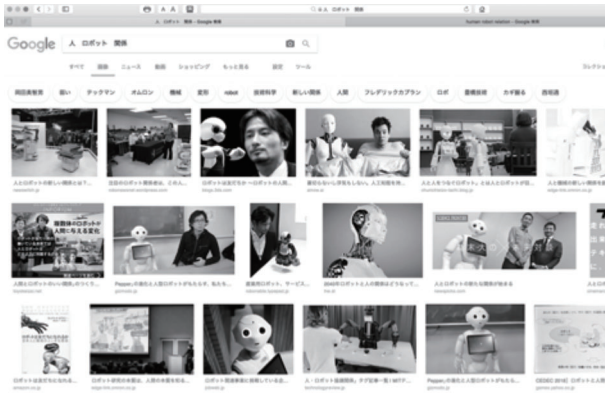


図 2　日本語を検索語としたときの 人−ロボット関係のイメージ例（2019 年 2 月 7 日検索）．人とロボットが横並びの構図が散見される．

英語検索の結果は第三項を含まない二項関係として人−AI／ロボット関係が捉えられているのに対して，日本語検索の結果は三項関係として捉えられていることを示唆する．

母子関係において，母親と子供とが相互に見つめ合うだけでなく，共通の第三項を注視する共同注視 (joint attention) が生後いつごろから見られるかは，発達心理学において重要な研究課題となっている [Scaife 75]．おおまかに言っておよそ生後 9 か月ごろからであるとされており，この時期が乳児の認知能力発達において大きな革命的進展を示すことの現れでもあるらしい [遠藤 06]．このことは，日本の構図は，AI／ロボットが“共に第三項を注視するだけの能力をもっている存在”として扱われていること――少なくとも，撮影者や被写体の人間がそのように無意識に感じていること――を示していると言えるのではなかろうか．

日本の浮世絵における母子関係の描かれ方を調査した精神科医の北山修は，213 枚の浮世絵母子像のうち 3 割ほど（定義を少し広げれば約 5 割）が母子共同注視であり（図 3），同様の構図は西洋の絵画では 5%ほどしかないのに比べると著しく多いと報告している [北山 05b，山口 05]．北山はこのように描かれている母子の共同注視に“共視 viewing together”という新しい用語を与え，母子が共視している第三項が，多くの場合，花やおぼろ月などの移ろいやすい，はかない存在であることから，日本社会の人間関係の特徴――良く言えば繊細で微妙な機微に富む，悪く言えば“空気を読む”ことや忖度が要求される――が生じる理由をここに求めている．また，同様の第三項共視的構図は母子関係だけでなく，大人同士の関係を描く際にも，たとえば小津安二郎の映画などで多用されているという [やまだ 05，三浦 05]．日本社会の人間関係全般の特徴に深く関係していると言って良さそうである．実際，西洋史学者の阿部謹也は，日本社会の特徴を“世間”というキーワードに集約して考察を展開している [阿部 95]．彼によれば，世間は，西洋の“公共”空間とも“社会”とも異なり，個人や私空間をベースにした関係性ではない．茫漠として言語化しにくく，しかし厳然たる力をもって個人の行動や思考を制約している．西洋の社会は個人によって形作られるが，日本の個人は世間によって規定される．

もっとも，母子関係に第三項を共視する関係が支配的だから長じて“世間”のような曖昧な関係性を構築していくのか，そもそも日本社会に“世間”的関係性が埋め込まれているから母子像に共視的関係が多く描かれるのか，因果関係はわからない．両者が相互に強化しあうループ効果にあるのではないかとは思う．

ともあれ，これらのことからも，AI／ロボットに対して共同注視的ポジションをとることが多い日本の構図は、AI／ロボットが第三項への注意共有ができる存在（エージェント）であること，すなわち同じ“世間”の仲間であることを無意識に想定していると言えそうだ．それに対して，人と AI／ロボットが向かい合った二項関係的なものに配置されることの多い欧米の構図は，AI／ロボットが人に対してむしろペットなどのような従属的な関係にイメージされていることが反映されているのではなかろうか．

3. 劇場型鑑賞論からの予備的分析

江戸文化研究者の田中優子は，浮世絵で描かれる共視関係が鑑賞者を絵の中の世界に引きずり込む機能をもっていると述べている [田中 05]．そこには母子関係として描かれている人間関係が大人の男女関係の代替であるという，浮世絵のポルノグラフィーとしての機能との関連も指摘されているのだが，それはさておき，本論での論旨にとって重要な田中の主張は，日本に 18 世紀ごろに導入された遠近法（透視図法）が，日本では写実性を高めるためではなく，「絵の中の世界と観る側の世界とをつなげてしまおう，という意図」を実現するために使われたという指摘である [田中 05, p.49]．言いかえると，西洋の鑑賞法では見る主体（鑑賞者）と見られる客体（絵画）は分離した二者関係（二項関係）であるのに対し，日本の絵画鑑賞法では両者は独立しておらず，鑑賞者が「場への参加，登場人物への同化，という行為を経由して絵画に入ること」が促されるように絵画が制作されている [田中 05, p.69]（図 4）．



図 3　母子共視図の例



図４　奥村政信「芝居狂言浮絵根元」．鑑賞者を絵の中に引き込むように遠近法が使われている．

美術史研究者の高階秀爾は，同様のことを“視点の移動”として説明している [高階 96]．西洋絵画では“画家”の自我という固定した視点からの視線によって，一定の画面の枠の中に切り取った形で絵画は描かれ，したがって絵画は周囲から独立したものとして存在する．一方，日本絵画では画家の視点は固定しておらず，興味関心にしたがって空間を移動し，一部を拡大し，場合によっては時間軸も異なったものが，同じ平面にひとつの絵画として描かれる．絵画作品としての独立性は低く，周囲から絵画を切り取る枠の重要性も低い．「実際には，屏風なり襖なりの現実の画面によって作品の枠は決定されているのだが，そのなかに表現された世界は，枠の中だけで完結するのではなく，その枠を越えてさらに外に拡がっていく傾向をもつ」[高階 96, p.21]．

これらの分析を，人と AI／ロボットが共に被写体となっている写真に当てはめて解釈すると，人と AI／ロボットが横並びでこちらを向いている構図は，単に両者が共視しているというだけでなく，写真を見る鑑賞者を彼ら／彼女らの世界の一構成要素として誘（いざな）っているかのようにも思える．すなわち，AI／ロボットは被写体である人と同列であるだけでなく，鑑賞者である私たちとも同列，またはそれに近い存在として扱われているのではないか．

このことは，人とサルや類人猿とが一緒に写っている写真の構図にも，似たような文化差――日本の場合は人とサルが横並び，または人がサルの側にいてこちらを見ている構図が多く，欧米の写真では人とサルが向き合っている構図が多い――が認められるように思える（未発表予備的調査）ことと合わせて考えると，示唆に富む．日本のサル学はサルを擬人化して観察したことで，サルを機械論的に研究対象として扱った観察からは明らかにできなかったサル社会の複雑性などを解明していった [佐倉 00]．日本では類似の扱いを AI／ロボットに対してもおこなっているのだとすると，人や社会と AI との関係において，日本や東アジア文化圏から，ユニークな展望が発信できるかもしれない．

4．考察と課題

以上述べてきたことは，いずれも予備的あるいは試行的な段階の分析であり，実証的な裏付けや論証が十分なものではない．いわば，仮説的な“見通し”にすぎない．最後に，これらの見通しを踏まえて，より実証的な研究と精度の高い議論を発展させるための課題を述べる．

まず第 1 に，インターネット上の画像の体系的な分析をおこなう必要がある．どのような画像を対象とするかは課題が残るが，被写体となっている人と AI／ロボットの相互の姿勢や身体の向き，視線の方向などを収集し，画像がどこの国で作られたものかと合わせて解析する作業が必要である．

第 2 に，日本における遠近法の使われ方や絵画鑑賞法についてのさらに体系的な調査が必要であろう．これらについては筆者らは専門的技能を持ち合わせていないので，適切な専門家の協力を仰ぐ必要があると考えている．

第 3 に，アニミズムについての考察を深める必要がある．日本の絵画の描き方や鑑賞法が視点移動型である理由について，諏訪春雄はアニミズムとの関係を強調している [諏訪 98]．しかし彼の主張は説得的な論証がほとんどなされておらず，より体系的かつ合理的な検討が必須と思われる．一方で，日本のポップカルチャーを分析した人類学者の Anne Allison は，最先端技術とアニミズムが結びついていることを見出し，“テクノアニミズム techno-animism”と名付けて現代日本文化の大きな特徴であるとした [Allison 06]．興味深い指摘である反面，日本文化についての表層的な理解も垣間見られ，より厳密な精査が必要である．

第 4 に，逆に西洋の思想や自然観についても，注意深い検討が必要だ．西洋の知の伝統の中にも，主体と客体を明確に分けるのではなく，身体的運動や身体知を通して主体と環境の密接な関係を強調する考えかたが根強く脈打っている（たとえば，H. Bergson や J von Uexküll など）．身体知の重要性に注目する言説も少なくない（たとえば，M. Merleau-Ponty など）．これらの諸言説が人-AI／ロボット関係の文脈にどのように位置づけられるのか，再検討する必要がある．

第 5 に，AI／ロボットのパブリックイメージや社会的認知における文化差の研究を，東アジア諸国内（日本，韓国，台湾，中国）で行う必要がある．この地域は自然の生態的条件も森林を基盤とした共通点をもっており，文化的には中国文化圏の影響が大きい地域である．“日本 vs 欧米”という歪んだ比較研究ではなく，文化圏の特性を踏まえた体系的な比較をおこなう必要がある．

これらの課題を解決していくことで，人と AI／ロボットの関係について，東アジア圏の生態的・文化的特性を踏まえた建設的な展望を得ることができるであろう．

参考文献

[阿部 95] 阿部謹也：「世間」とは何か．現代新書，講談社（1995）

[Allison 06] Allison, A.: Millennial Monsters: Japanese Toys and the Global Imagination. University of California Press, Berkley, CA. (2006)［実川元子訳：菊とポケモン―グローバル化する日本の文化力―．新潮社（2010）］

[遠藤 06] 遠藤利彦：総説：視線理解を通して見る心の源流．所収：遠藤利彦，編．読む目・読まれる目―視線理解の進化と発達の心理学―．東京：東京大学出版会，pp. 11-66 (2006).

[Helmreich 98] Helmreich, S.: Silicon Second Nature: Culturing Artificial Life in A Digital World. University of California Press, Berkley, CA. (1998, revised version 2000).

[北山 05a] 北山修，編：共視論―母子像の心理学―．選書メチエ，講談社（2005）

[北山 05b] 北山修：共視母子像からの問いかけ．所収：[北山 2005a], pp.7-46 (2005).

[MacDorman 08] MacDorman, K. F., Vasudevan, S. K. and Ho, C.-C.: Does Japan really have robot mania? Comparing attitudes by implicit and explicit measures. AI & Society, 23(4): 485-510 (2008)

[MacKenzie 99] MacKenzie, D. and J. Wajcman, eds.: The Social Shaping of Technology, 2nd ed., Open University Press (1999)

[三浦 05] 三浦佳世：視線の構造. 所収：[北山 05a], pp.129-158 (2005)

[西垣通 88] 西垣通：AI―人工知能のコンセプト. 現代新書, 講談社（1988）

[西垣通 18] 西垣通：AI 原論―神の支配と人間の自由―. 選書メチエ, 講談社（2018）

[Nomura 15] Nomura, T. and Kanda, T.: Influences of evaluation and gaze from a robot and humans' fear of negative evaluation on their preferences of the robot. International Journal of Social Robotics, 7(2): 155-164 (2015)

[佐倉 00] 佐倉統：文体・フィールド・構造―『高崎山のサル』が今もおもしろい理由―. 所収：伊谷純一郎：高崎山のサル. 学術文庫, 講談社 (2010)

[佐倉 19] 佐倉統：自動運転を科学技術社会論的に考える. 自動車技術, 73(3)（印刷中）

[Scaife 75] Scaife, M. and Bruner, J. S. The capacity for joint visual attention in infant. Nature 253, 265-266 (1975)

[諏訪 98] 諏訪春雄：日本人と遠近法. ちくま新書, 筑摩書房（1998）

[Syrdal 13] Syrdal, D. S., Nomura, T., and Dautenhahn, K.: The Frankenstein Syndrome questionnaire: Results from a quantitative cross-cultural survey. In: Herrmann, G. et al., eds., Social Robotics (ICSR 2013, Proceedings), pp. 270-279, Springer (2013)

[高階 96] 高階秀爾：日本美術を見る眼：東と西の出会い（新版）. 岩波書店（1996, 初出 1991）

[やまだ 05] やまだようこ：共に見ること語ること―並ぶ関係と三項関係. 所収：[北山 05a], pp.73-87 (2005)

[山口 05] 山口裕幸：タテ社会における視線. 所収：[北山 2005a], pp. 159-175 (2005).

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

非接触センサーを活用した転倒リスク予測の検討

Fall Risk Detection for the Elderly using Contactless Sensors

紺野 剛史[*1] 金月 寛彰[*1] 福田 大輔[*1] 園田俊浩[*1]
Takeshi Konno Hiroaki Kingetsu Daisuke Fukuda Sonoda Toshihiro

[*1] 株式会社富士通研究所
Fujitsu Laboratories LTD.

In recent years, Japan's elderly population has been growing. As a method of reducing the nursing care period, we studied a fall risk detection for elderly people. Our aim is to detect the fall risk with contactless sensors. First, we took a video of the 5-meter walking test by 40 subjects. Then, we processed them using OpenPose. Finally, rehabilitation exercise instructors evaluated the fall risk at 3 levels. In this paper, we reported on 3 machine learning models and evaluated the accuracy of the fall prediction. As a result, we found that all algorithms obtained accuracy of around 80% even with contactless sensors.

1. はじめに

近年，日本では高齢者が増加している．日本は 2010 年に高齢化率が 20%を超えた．2025 年には約 30%，2060 年には約 40%に達すると予測されている．将来，高齢者の面倒をみる若い人の数が足りなくなる．そのため，健康寿命を延ばして，介護期間を減らす仕組みが必要である．

転倒リスクに用いられるセンサーは，接触型と非接触型に分けられる．接触型センサーを使った先行研究がある[Gervásio 16] ．しかし，高齢者は接触型センサーを好まない．また，長期的に使用する場合，非接触型センサーの方が高齢者への負担が少ないため好ましいという報告がある[高橋 18] ．

我々の目的は，高齢者の負担が少なく長期的なモニタリングを実現するため，非接触センサーを使った転倒予測システムの構築を行うことである．画像情報から身体部位の 2 次元座標を抽出できる OpenPose という技術が開発された [Cao 17] ．これらの技術を使うことで高齢者の歩行シーンから非接触に特徴量を抽出することが可能となった．OpenPose を活用した先行研究として，転倒している状態を判定する研究 [Solbach 17]や歩行障害を判定する研究 [Esmaeilzadeh 18]が行われてきた．しかし，転倒リスク予測に活用した研究は未だない．

本論文では，OpenPose を使った高齢者の転倒リスク予測について評価を行ったので報告する．

2. 転倒リスク検知予測

2.1 ビデオカメラの設置方法

本実験では，障害物のない体育館(図 1)で被験者 36 人に普通歩行の 5 m 歩行テストを行い，ビデオカメラ(SONY: HDR-CX470W)にて撮影を行った．5 m 歩行テストは 5 m 歩行テストは前後の予備路 3 m と測定区間 5 m からなる．ビデオカメラは全体が映る様にセッティングし，歩行中にズームはせずに撮影を行った(図 2) .

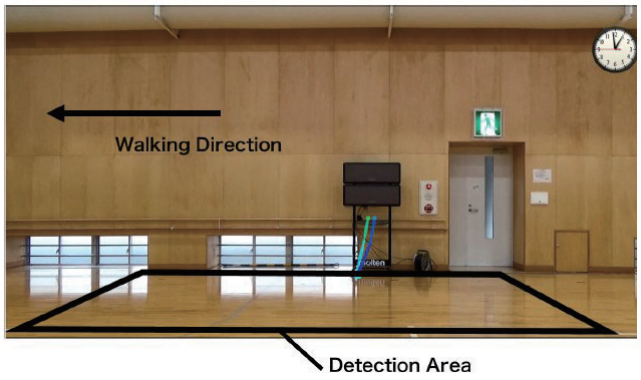


図 1: 識別エリア

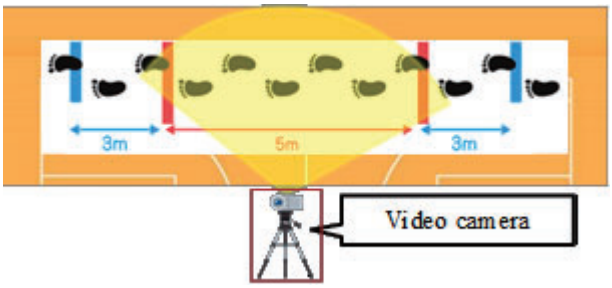


図 2: 撮影方法

2.2 特徴量の抽出

転倒リスク予測で使用する特徴量は，介護施設で働く複数の機能訓練士にヒヤリングし 5 つの指標を用いることにした．

対象者の動画データを OpenPose にて 2 次元の座標にした後，以下の計算方法により集計した．

- 目線の高さ（角度): 鼻(図2における Nose，0)，首(Neck，1) and 腰 (CHip, 8)の座標から角度
- 着地時の踵の高さ（cm): 踵 (LAnkle，14) とつま先 (LLToe, 20)の座標から計算した最大値

連絡先:紺野 剛史，株式会社富士通研究所，神奈川県川崎市中原区上小田中 4-1-1，konno.takeshi@jp.fujitsu.com

- 蹴り出し時のつま先の高さ(cm): 踵(LAnkle, 14) とつま先の (LLToe, 20) の座標から計算した最大値
- 歩幅 (cm): 平均の歩幅. 計算を簡単にするために歩数を 5m で割った値とした
- 歩行速度 (m/s): 平均の歩行速度

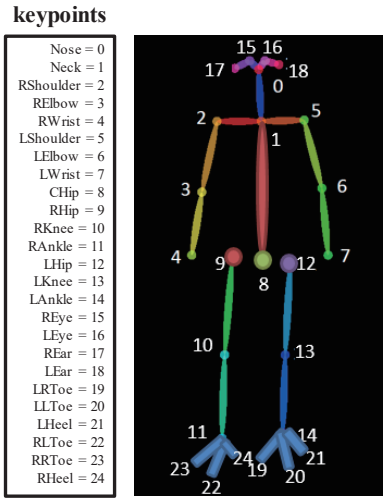


図 2: 0penPose による骨格検出位置

最後に, 機能訓練士に被験者 40 人(認知症患者を含む)に対して転倒リスクのラベルとどのような観点でラベルを付けたかを記載して貰った.

- 高 (4 人) :認知症や大幅な下半身の筋力低下により歩行時にふらつきがみられる
- 中 (4 人) :認知症はないが, 下半身の筋力低下が始まり, すり足や歩行速度低下がみられる
- 低 (32 人) :下半身の筋力があり歩行が安定している



Subject A　Subject B　Subject C

Subject	A	B	C
Eye line (degree)	139	127	133
Heel height (cm)	10.6	7.0	8.8
Toe height (cm)	6.2	6.1	2.6
Stride length (cm)	71.4	45.5	33.3
Gait velocity (m/s)	1.5	0.7	0.6
Possibility of fall risk	低	中	高

図 3:被験者と転倒リスク例

3. 評価方法

36 人のデータを 4-fold のクロスバリデーションにより予測精度の評価を行った. 評価に使用したアルゴリズムは以下である.

- SVM (Linear kernel)
- Logistic regression
- Linear discriminant analysis

4. 結果

表 1 に各アルゴリズムおける Accuracy を示す. 5 名(No.1-5)については全部のアルゴリズムで予測を外した. 2 名(No.6-7)については, SVM (Linear kernel)と Logistic regression で外した. 理由として, どちらも歩行速度の重みが影響して誤判別をしていた(表 2).

表 1: 手法に対する各結果

Learning algorithm	Accuracy(%)
SVM (Linear kernel)	83
Logistic regression	83
Linear discriminant analysis	88

表 2: 誤判別リスト

No.	正解	SVM (Linear kernel)	Logistic regression	Linear discriminant analysis
1	高	中	中	中
2	低	高	高	高
3	高	低	低	低
4	低	高	高	高
5	低	中	中	中
6	中	高	高	中
7	中	低	低	中

5. 結論

本論文では, 被験者 40 人に対して非接触センサーを用いた転倒リスクの評価を行った. その結果, 非接触センサーを用いてもおよそ 80%の予測精度が出ることが判った.

今後は, データ数を増やして更なる精度向上を目指す. また, 機能訓練士に精度向上についてインタビューをした結果, 歩行バランスと柔軟性を加味すると良いことがわかった. 歩行バランスは, 被験者を正面から撮影することで特徴量として入れることが可能だと考える. また, 柔軟性については, 5 m 歩行テストから取得することが難しく, 前屈テストの値を特徴量として入れることを考えている.

参考文献

[Gervásio 16] Gervásio, F. M., Santos, G. A., Ribeiro, D. M., & Menezes, R. L. D. 2016. Falls risk detection based on spatiotemporal parameters of three-dimensional gait analysis in healthy adult women from 50 to 70 years old. Fisioterapia e Pesquisa, 23(4), 358-364.

[Cao 17] Cao, Z., Simon, T., Wei, S. E., & Sheikh, Y. 2017. Realtime multi-person 2d pose estimation using part affinity fields. In CVPR: pp. 1302-1310.

[Solbach 17] Solbach, M. D., & Tsotsos, J. K. 2017. Vision-based fallen person detection for the elderly. CoRR, abs/1707.07608.

[Esmaeilzadeh 18] Esmaeilzadeh, S., Khebzegga, O., & Moradshahi, M. 2018. Clini-cal Parameters Prediction for Gait Disorder Recognition. arXiv preprint arXiv:1806.04627.

[高橋 18] 高橋雄太, 音田恭宏, 藤本まなと, 荒川豊: “センサ装着杖を介した歩行動作検出手法の提案,” 情報処理学会論文誌コンシューマ・デバイス&システム, Vol.8, No.2, pp.43-55, 2018 年 5 月.

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

アクションゲーム学習におけるモジュラーニューラルネットワークの導入

Introducing Modular Neural Networks in Learning Action Games

高橋　寿徳 *1　　棟朝　雅晴 *2
Toshinori Takahashi　　Masaharu Munetomo

*1北海道大学　工学部
School of Engineering, Hokkaido University

*2北海道大学　情報基盤センター
Information Initiative Center, Hokkaido University

In this paper, we introduce a modular network approach in neuroevolution for action game learning. We employ NEAT (NeuroEvolution of Augmenting Topologies) to generate modular networks learning game stages under different conditions, which are combined to obtain networks that can adapt to difficult situations appeared in actual game playing. We show the effectiveness of our approach in a Pygame instance compared to the original NEAT.

1. はじめに

NEAT(NeuroEvolution of Augmenting Topologies)[1][2] はニューラルネットワークを遺伝的アルゴリズムを用いて進化させ, 入出力に対して最適な接続, 重み付け, バイアス設定を探索する事で問題解決を図る事を目的としており, ニューラルネットワークの集団を構造上の類似性に基づいて種集団に分け, 種集団の中で競争, 交叉を行わせる事で効率的な探索を可能としている.NEAT において, 学習後のネットワークを保存し、それらのネットワークをモジュラーネットワーク [3] として再利用する事で, 単一のニューラルネットワークでは解決が困難な問題に対しても対応できる.

アクションゲーム学習においては同一の規則 (ゲームルール) の下, 同一の状態 (ステージ) から学習を始める事が前提となっており, 同一のステージでも予め他のステージを学習していた場合, 学習の動きがどのように変化するかについて議論は不十分である. 本研究では, 同一のゲームルールを保った状態で, 互いに異なる複数のステージを学習したネットワークを準備し, これらのネットワークを困難なステージの学習に活用した際に,NEAT のみで困難なステージに取り組んだ場合に比べて, モジュラーネットワークの導入により学習結果が改善されるかを調べる事を目的とする.

2. アクションゲームにおける NEAT の適用

今回学習の題材とするのは,Pygame での使用を想定されたゲーム基盤 [4] を用いて実装したアクションゲームであり, ゲームの目的は, 蛇の姿をした自機を操作して, 敵キャラクターや棘といった障害物を乗り越えながらステージ最奥のゴールに触れる事である. 行える操作は, 左移動, ジャンプ, 右移動,(空中でのみ) 急降下, 近接攻撃, 形態変更の 6 つであり, 有意な操作の組み合わせは全 21 通りである.

自機は二形態あり, 形態の違いで性能が変化するが, どちらの形態でもクリアできるものとしている. ゴールに接触すればゲームクリアとなるが, ゲームオーバーとなる条件は,(1) 敵に複数回接触して自機の LIFE が 0 になる,(2) 棘に接触する,(3)TIME が 0 になって時間切れになる, の 3 つである.

NEAT をゲーム学習に適用するために, ゲームから得られる情報を入力, ゲームに対する操作を出力として返すニューラルネットワークのトポロジーを作成する.

入力は表 1 左に記す自機の状態に関する情報と, 自機周囲のオブジェクトの情報を得るために, 表 1 右に基づいて周囲 3 マスの物体の種類を特定する.

表 1: 入力に用いる自機の情報とオブジェクトの情報

自機の情報 ([-1,1] に正規化)	オブジェクトの種類と値
x 方向の速度	何もなし:0.0
y 方向の速度	自機:2.0
現在の形態	ブロック:-1.0
接地しているか	アイテム:-0.5
急降下中か	モンスター:0.5
空中ジャンプできるか	棘:1.0
攻撃できるか	
現在 HP	

また, ネットワークの適合度はステージクリアまで進められたか, 途中でゲームオーバーとなったかで以下の 2 式から求める.

$$fitness = \begin{cases} -10 + \frac{LIFE}{20} + \frac{Score}{50} - \sqrt{|PlayerX - GoalX|} \\ if \quad Gameover \\ 150 + LIFE + \frac{Score}{100} + \frac{restframes}{60} \\ if \quad Stageclear \end{cases} \tag{1}$$

3. モジュラーネットワークの適用

実際のゲームプレイを想定した, 応用ステージに取り組むためのモジュラーネットワークとして, 敵だけが登場するエネミーステージ 15 種類を順不同で学習させたネットワーク 15 種類と, 棘とアイテムだけが登場するジャンプステージ 15 種類を順不同で学習させたネットワーク 15 種類を作成した. 本研究における全体のアルゴリズムは図 1 におけるフローチャートで示される. モジュラーネットワークを作る際の, ゲーム情報を受けて次の操作を決めるネットワークと, モジュラーネット

連絡先: 高橋寿徳, 北海道大学工学部情報エレクトロニクス学科，trpg_igo3576eigo@eis.hokudai.ac.jp

ワークを利用する際の, ゲーム情報を受けて次の 20 フレーム間の操作を担うモジュラーネットワークを決めるネットワークが異なる事に留意する. NEAT のパラメーター設定は,NEAT を用いて各種 Atari ゲームの実験を行う OpenAI-NEAT プロジェクトの設定 [5] を参考にした.

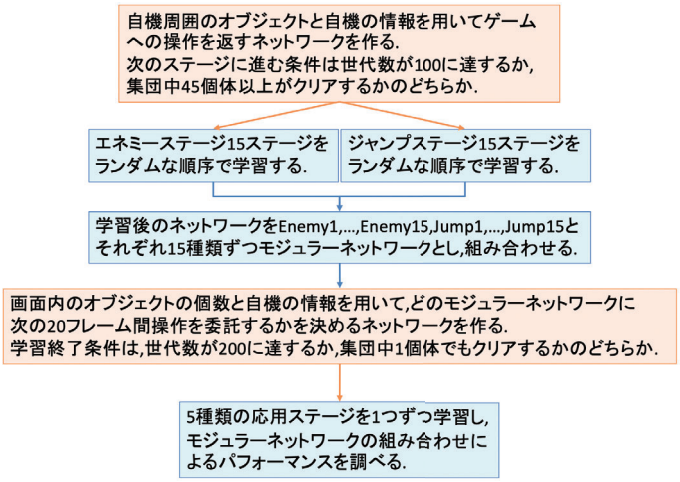


図 1: ゲーム学習におけるモジュラーネットワークを用いた NEAT のフローチャート

応用ステージはエネミーステージとジャンプステージの要素が交互に繋がったステージであり, ステージの長さは各種エネミー, ジャンプステージに比べておよそ 2.5 倍としている. 応用ステージを実践するには, 新たにどのモジュラーネットワークに操作を委託するかを決めるネットワークを作る必要がある. 図 2 左にそのネットワークによって使用するモジュラーネットワークを決定する様子を示し, 図 2 右に作られたモジュラーネットワークが動作する様子を示している.

その出力は, 全部で 31 通りあり, 順に接続なし, エネミーステージネットワーク 15 種, ジャンプステージネットワーク 15 種としており, 接続なしのネットワークは, 入出力が繋がっていないうちにのみ委託される可能性がある (何も操作をしない),

入力は, 自機の情報は表 1 の情報に自機の現在の x 座標と y 座標, 現在スコア, 残り時間を加え, オブジェクト情報は周囲 7 マスの各種オブジェクトの個数についての情報をとる.

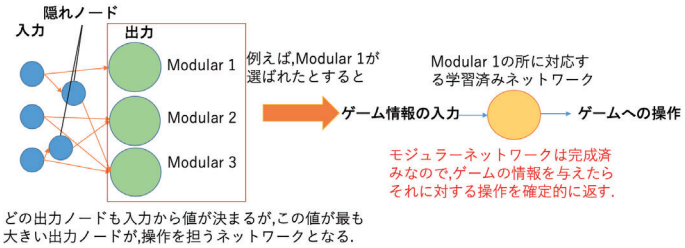


図 2: NEAT によるモジュラーネットワークの決定

また, 応用ステージ実践中の NEAT の出力となる, モジュラーネットワークの切り替えはゲーム内の時間で 20 フレーム毎としており, ゲームへの操作は第二章と同様のゲームの情報をゲームプレイ中常にモジュラーネットワークへの入力として与え, 操作はモジュラーネットワークの出力として確定的に返される.

NEAT のパラメーター設定は, 大半は複数ステージ学習と応用ステージ学習でパラメーター設定は同じだが, 複数ステージ学習では初期ネットワークを無接続状態, 応用ステージ学習ではランダムな入出力 1 組を初期ネットワークとする FS-NEAT と設定している. この理由としては, ランダムな入出力 1 組の構造から始める FS-NEAT の方が, 与えられた一つの応用ステージに対して有効な入出力接続を決め打ちする事で, 効率よく解候補を探索できる動きが見られたためである. 一方で, 複数ステージ学習の場合では, 決め打ちされた入出力が与えられた最初のステージに依存する傾向があり, 第二, 第三のステージを学習させる際に悪影響を与える事が見られたため, 無接続状態から開始している.

応用ステージは 1 ステージずつ学習させる為, 費やす最大の世代数は 200 とし,1 個体でもクリアした個体が出現した時点で学習の 1 サイクルを終了させるものとする.

4. 評価実験

応用ステージは 5 種類用意し, モジュラーネットワークは各々のステージを 15 種類全て学習したネットワーク 30 種類 (FULL) だけではなく, 実験の中で, クリアが容易とされた上位 10 ステージだけを学習させたネットワーク (Easy10) や,15 種類のステージを一つずつのみ学習させたネットワーク (Singles) を用意し, これに第二章と同様に NEAT で応用ステージに取り組んだ結果 (Normal) を加えて互いに比較させた.

今回の実験では, 適合値はスコアやゴールまでの距離など, 複数の要素が絡む上にクリアか否かで大きく値が変わるため, 各ネットワークのステージ毎の評価には,200 世代以内のステージ達成度 (どこまでゴールに近づけたか) の最大を使用した. 達成度が 100 であれば, そのステージをクリアした事を意味する. 各グラフは, 左から順に FULL,Easy10,Singles,NormalNEAT のネットワークを用いて,20 回ステージを学習した際の進行度の統計を箱ひげ図で表しており, グラフ内では応用ステージの事を Multi Stage と呼んでいる. 各応用ステージを 20 回実践した際の達成度について, 特にネットワーク間で有意な差が見られた結果を図 3 から図 7 で示す.

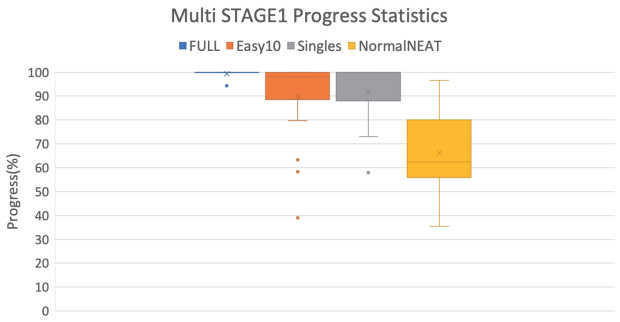


図 3: 応用ステージ 1 を 20 回学習させた時の進行度

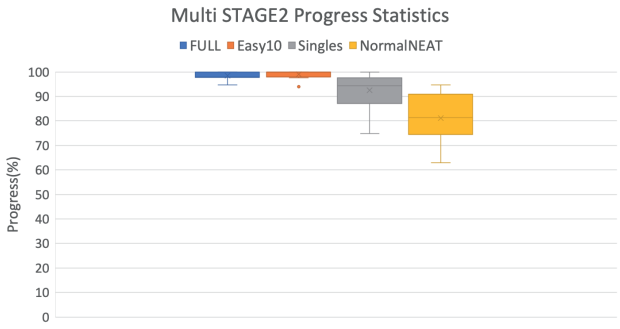


図 4: 応用ステージ 2 を 20 回学習させた時の進行度

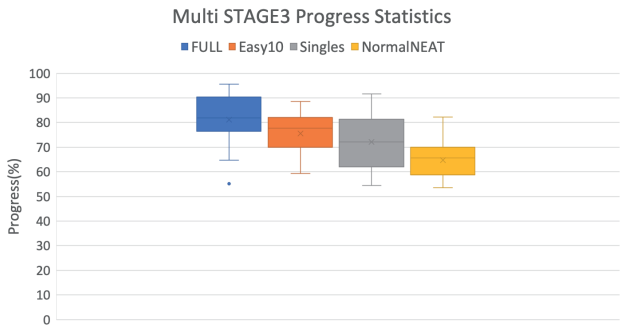


図 5: 応用ステージ 3 を 20 回学習させた時の進行度

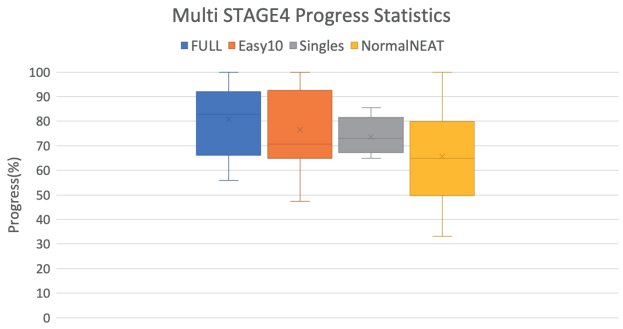


図 6: 応用ステージ 4 を 20 回学習させた時の進行度

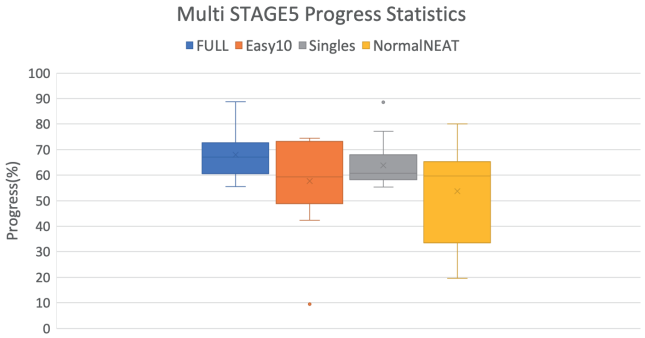


図 7: 応用ステージ 5 を 20 回学習させた時の進行度

この結果から, 応用ステージ 1,2 のように,FULL ネットワークであれば 20 回とも殆どクリアまで近づける難易度であれば,Easy10,Singles といった比較的学習量が少ないネットワークでも, 普通に NEAT で学習させた場合より目に見えて良好なパフォーマンスを出せる事が挙げられる. さらに, 応用ステージ 3 から 5 のように, 殆どクリアが見込めないほどの難易度となると, 多くのステージを学習したネットワークであるほど, 安定して高い進行度を保つことができると言える. 本研究では, いずれの場合でもモジュラーネットワークを通した方が NEAT のみで学習させるより平均的に高い進行度を出せており, 予めステージを学習させた経験を役立てられているといえる.

5. おわりに

本研究では, 敵が登場するステージ, 棘が登場するステージで分けて, 短いステージを複数学習させてネットワークを用意し, そのネットワークを応用ステージに再利用する事で, 直に応用ステージを学習させるよりも効率よくステージ進行を進められる結果を示した.

一方で, 本実験には応用ステージの定義や, モジュラーネットワークを作るために学習させるステージ群は他にも色々な種類が考えられ, 自機の形態なども考慮したステージでネットワークを作るなど, 自機の二形態の特性も含めて学習させられる可能性があるという点で, 多くの検証が行える余地がある.

参考文献

[1] Kenneth O. Stanley and Risto Miikkulainen. ”Efficient Evolution of Neural Network Topologies.” *Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No.02TH8600).*

[2] Kenneth O. Stanley and Risto Miikkulainen. “Evolving Neural Networks through Augmenting Topologies.” *Evolutionary Computation 10(2): 99-127. 2002.*

[3] Bart L.M. Happel and Jacob M.J.Murre. ”The Design and Evolution of Modular Neural Netowork Architectures” *Neural Networks,1994,7,985-1004.*

[4] https://github.com/aidiary/pygame/tree/master/action

[5] https://github.com/HackerShackOfficial/OpenAI-NEAT

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

人間のプレイデータを用いたゲーム操作学習モデル

A game operation learning model using human play data

宮野友弥 *1　松麿勝利 *2　斎藤博昭 *1
Tomoya Miyano　Katsutoshi Matsumaro　Hiroaki Saito

*1慶應義塾大学理工学部
Faculty of Science and Technology, Keio University

*2株式会社コーエーテクモゲームス
KOEI TECMO GAMES CO., LTD.

Recently, many artificial intelligence (AI) researches conducted in the video game industry employ neural networks. By using the human play data as "teacher" data of the neural network, it is expected to obtain NN models that can output human game operation with high reproducibility. In this research, we employed LSTM and CNN as our learning models and evaluated our results by comparing the winning percentage and the behavior of the game character. Experimental results show that both models outperform the random-action model and the LSTM model learns human-like behaviors, while the CNN model presents patterned behaviors.

1. はじめに

ゲーム AI 研究はチェス，囲碁，将棋などのボードゲームから始まり，現在では不完全情報ゲームやビデオゲームなど様々な種類のゲームに関しても成果が挙げられている．2013 年に DeepMind が発表した DQN[Mnih 13] におけるディープラーニングの成果は世界を驚かし，2016 年にはアルファ碁 [Silver 17] がトッププロ棋士との 5 番勝負で 3 勝を挙げた．近年，これらの研究を筆頭にニューラルネットワークを用いたゲーム AI の研究が盛んになっている．

本研究では (株) コーエーテクモゲームスのアクション RPG『仁王』をカスタマイズしたツールの上で，ニューラルネットワークを用いて人間のプレイデータを元にゲームキャラクタ操作を学習するモデルを構築し，その勝率を比較した．

本研究では人手による AI 制作ではなく，ニューラルネットワークのパラメータを調整するだけでゲームキャラクタを自動操作出来るようにするのが目的である．また本手法は同様の操作体系が適用できる異なったキャラクタにも応用可能であるという点において再利用性の高いゲームキャラクタ操作学習モデルが構築出来ることも期待できる．

2. 『仁王』

本研究に用いた研究用ステージを図 1 に示す.『仁王』は図 4 の配置を持つコントローラを用いて，剣などの武器で敵キャラクタと戦いながらマップを進んでいくアクション RPG である．本研究ではゲームの対戦部分だけに着目し，効果的に敵を倒すモデルの学習を目指した．

『仁王』はこれまでに数多く研究されてきた 2D ゲームではなく，視点移動をともなう 3D ゲームである．それにより 2D ゲームと比較して，敵を回り込んで背後をとって倒すなどのより多彩な動きが可能になる．3D 視点のゲームを題材にした先行研究としては深層強化学習を行った研究 [Harmer 18] があげられる．本研究ではカメラ自体の操作は行わなかったが，ゲーム側で自動的にカメラ位置の移動がなされ，それに応じてキャラクタのスティック操作における移動方向も変化する．

本研究では製品版のゲームに対し，本研究用の特別ステージ，コントローラデータ等の入出力機能およびゲーム画面を画像出力する機能を追加したツールで行った．ゲームを操作するのはコントローラではなく，コントローラと同様の入力が行えるファイル (以下 Input ファイル) を書き換えることにより行う．ゲームから出力される Output ファイルや画像を元にアクション選択を行うモデルを構築する．

※なお，本研究で用いたツールは『仁王』をカスタマイズして利用したものであり,『仁王』の製品自体とは関係がない．



図 1: 『仁王』の研究用ステージ画面

3. アクション選択のプロセス

本研究で構築するモデルは，ゲームから出力される各種数値データ (Output ファイルとしてまとめられている) やゲーム画面の画像データなどの情報を元に，選択すべきボタンやスティックの移動量を計算する．モデルはさらに Input ファイルにコントローラのボタンとスティック移動量の値を書き込み，情報をゲームに読み込ませて環境を更新する．つまり，ゲームプレイの流れとしてはまずゲームの環境更新と Output ファイルおよびゲーム画面の画像出力があり，それに対してモデルがアクションを選択し，さらにゲームが選択されたアクションに対して環境更新とデータ出力を行う，というサイクルを回していく．ゲームプレイのプロセスを示したものを図 2 に示す．

連絡先: miyano_tomoya380@keio.jp

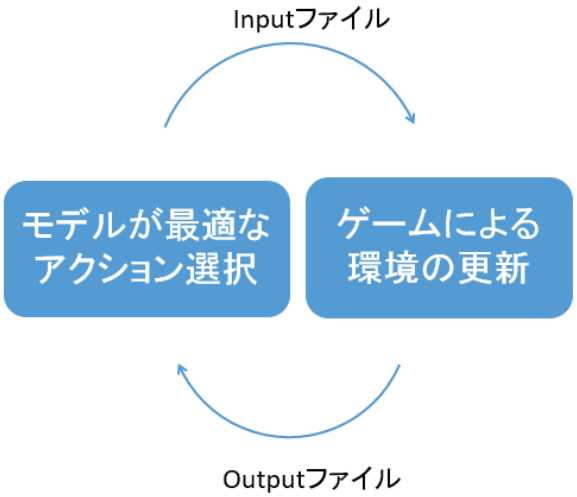


図 2: ゲームプレイのプロセス

3.1 本研究で特別に用いた対戦時のルール

以下に本研究で用いたゲームのプレイのルールを示す．なお，HP はヒットポイントの略称で体力値を表したものであり，相手の攻撃を受けると減少して時間が経過しても回復しない．これに対してスタミナは自分がアクション操作をすることによって減少し，時間が経つと自動的に回復する．この両者が全く別の概念であることに注意する．

a 攻撃が当たると，攻撃の種類や状況に応じたダメージが発生し，相手の HP を減らせる

b 相手の HP を 0 にした方が勝利とする

c スタミナがなくなるとボタン，スティック操作が無効になる

d アクション中のボタン，スティック操作は無効になる

e 一定時間がたった時にはゲーム側の勝利とする

f 操作でのカメラ移動は無効にし，常に敵にロックオン (敵が正面の位置にくるよう，自動的にカメラが移動する) した状態でプレイする

3.2 入出力に用いるファイル

Input ファイルの形式

Input ファイルはゲームに選択したアクションを入力する際に用いるファイルである．

左右スティックの移動量の X・Y 座標 (−32768〜32767 の整数値) と，各種ボタンについての情報 (押すとき 1，押さないとき 0) をモデルが書き込む．

Output ファイルの形式

Output ファイルはゲームから出力情報が書き込まれるファイルである．

Input ファイルの情報に加えて，3 次元位置座標 (カメラ位置，カメラ注視点，敵とプレイヤー位置，敵とプレイヤー前方方向)，整数値 (敵とプレイヤーのモーション ID，敵とプレイヤーの現在 HP，敵とプレイヤーのスタミナ残量，試合が始まってからのフレーム数，出力した画像ファイルの通し番号) が書き込まれている．なお，モーション ID とはゲームキャラクタの各動きに 1 つずつ割り振られた固有の番号である．Output ファイルのイメージの一部を図 3 に示す．

```
-31371, -9462,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,789.0113,266.0265
-31596, -8680,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,822.8789,266.7411
-31766, -8035,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,860.1340,266.9269
-31920, -7400,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,898.9823,266.9270
-31941, -7311,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,936.9050,267.0078
-31961, -7224,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,972.7897,267.0600
-31961, -7224,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1006.418,267.0978
-31961, -7224,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1037.768,267.1861
-31948, -7284,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1066.539,267.3402
-31948, -7284,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1092.810,267.5089
-31912, -7436,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1116.663,267.8054
-31766, -8037,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1138.088,268.3577
-31486, -9072,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1157.110,269.2989
-31280, -9758,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1174.332,269.9372
-31143,-10188,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1189.781,270.0214
-30910,-10873,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1202.677,270.0214
-30600,-11717,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1212.725,270.0214
-30354,-12339,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1219.858,270.0214
-30250,-12593,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1223.988,270.0214
-30024,-13123,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1225.375,270.0214
-29952,-13286,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1224.321,270.0214
-29892,-13421,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1221.281,270.0214
-29892,-13421,    0,    0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,1216.051,270.0214
```

図 3: Output ファイルのイメージ

図 3 は 1 行当たりに 1 フレームの状態を示し，左から順に前述の情報が書き込まれている．

3.3 選択出来るアクションの概要

実際にプレイに用いたスティック以外のボタンは 4 種類あり，それぞれ違う機能を持っている．また，左スティックにより上下左右移動をコントロールする．右スティックでカメラを移動させられるが，本研究ではこの部分は操作の対象にしない．X，Y，LB，A の各ボタンで弱攻撃，強攻撃，ガード，退避を行える．他にも細かい操作は可能だが，本研究では操作の対象にしなかった．コントローラを図 4 [*1] に示す．

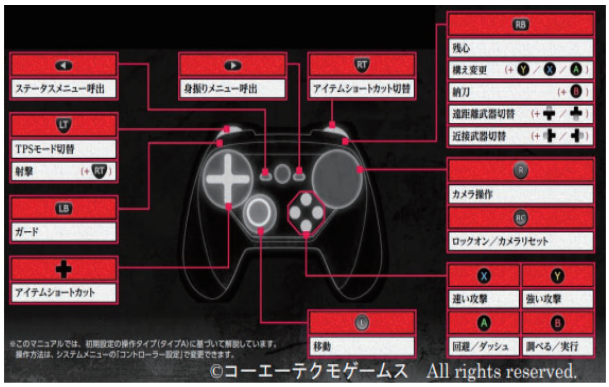


図 4: コントローラ

4. ニューラルネットワーク行動選択モデル

本研究では，状態とアクションの列または画像列から次のアクションを推定する 2 つのモデルを構築する．学習には LSTM(Long Short-Term Memory) と，CNN(Convolutional Neural Network) の 2 種のモデルをそれぞれ採用した．

*1 https://steamcdn-a.akamaihd.net/steam/apps/485510/manuals/Nioh_steam_JP.pdf

4.1 数値データの前処理について

各モデルにゲームから出力された Output ファイルを単純に入力するだけでは，上手く学習が進まない．そのため敵，自分，カメラ，注視点などの 3 次元座標をフレーム間隔と座標差から計算で求めた敵と自分の距離や内積などに変換し，モーション ID 部分を one hot ベクトルに変換した．本研究ではこれを状態と呼んでいる．

例えば敵位置の座標 (133, 10, 48)，自位置の座標 (125, 0, 58)，敵前方方向ベクトル (43, 0, 108) ，自前方方向ベクトル (57, 3, 87)，カメラ位置の座標 (0, 23, 43)，カメラ注視点位置の座標 (100, 234, 48) が，敵との距離 [0.40]，速度 [0.23]，カメラ方向ベクトルと敵方向ベクトルの内積 [0.32]，敵方向ベクトルと敵の前方方向ベクトルの内積 [0.76] のようになる．

4.2 用いた入力と正解データ

ニューラルネットワークの特性上，正解を 1 つに固定しなければならないので，スティックやボタンが複数押された時の処理が別に必要である．本研究では対応策として，スティックの X 座標と Y 座標とボタンを分けて考える．つまり別々に 3 つのモデルで学習する．その上でボタンが複数押された場合は，複数回に分けて正解データを取る．具体的には，(7, 10, 12) というボタンが同時に押された時は，1 つずつ 7 → 10 → 12 とボタンが押されたということになる．そのため正解のアクションが本物のデータとずれることになるが，とても短いフレーム間隔のため時間差は実プレイ上では無視できると考えた．実際にプレイ時に学習したモデルでアクションを生成する時には，各スティックとボタンで別々に 1 つずつ推定アクションを出力する．モデルで用いた学習とプレイの流れを図 5 に示す．

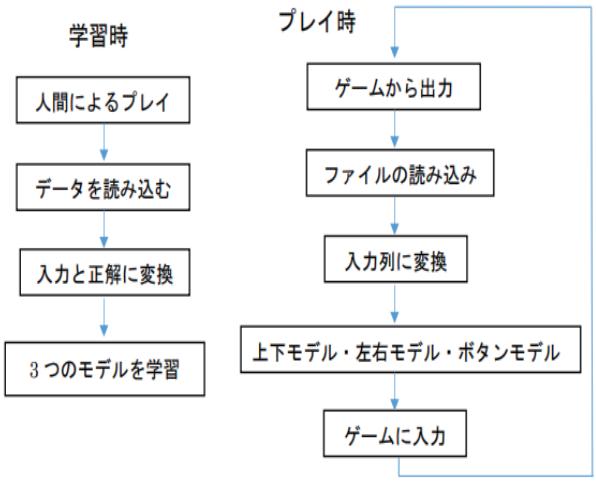


図 5: モデルで用いた学習とプレイの流れ

4.3 LSTM モデル

LSTM モデルでは図 6 のように状態とアクションの列を入力，次のアクションを正解として学習し，ゲームキャラクタのアクションを自動生成する．本研究では状態とアクションを 10 列ずつ入力列として用いて学習を行った．LSTM モデルで用いた学習の構成は，移動量予測の活性化関数には Linear を用い，最適化関数には Adam を利用した．ボタン選択の活性化関数には Softmax を用い，最適化関数には RMSProp(学習率 0.01) を利用した．LSTM の概要を図 6 に示す．

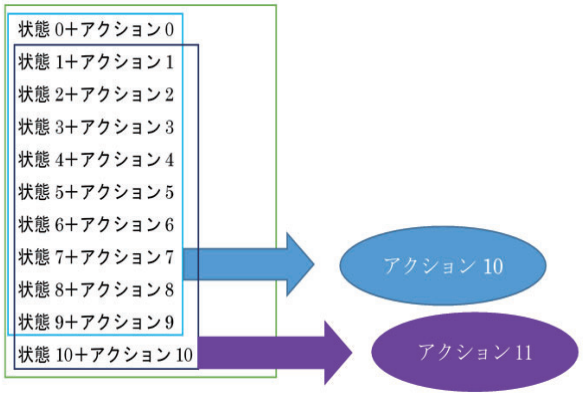


図 6: LSTM の概要

4.4 CNN モデル

CNN モデルでは，LSTM モデルで用いていた状態とアクションによる入力列を 72 × 128 の画像にする．モデルの入力に画像を用いることで様々なゲームに同一方法で学習可能になることが期待される．本研究では画像を 10 列ずつ入力列として用いて学習を行った．

ゲームが 3 次元位置座標などの数値データを出力する場合と異なり，モデルでは前処理を行わず，画像をモデルに直接入力する．畳み込み層を入れることで特徴量を抽出し，そこから全結合層につないでアクション決定を行う．ボタン選択モデルでは全結合層で 4 つのボタンと無操作についての選択確率をそれぞれ出力し、移動量決定モデルでは一つの数値が出力される。移動量予測の活性化関数には Linear を用い，最適化関数には Adam を利用した．ボタン選択の活性化関数には Softmax を用い，最適化関数には RMSProp(学習率 0.01) を利用した．CNN モデルのネットワーク構成を図 7 に示す．

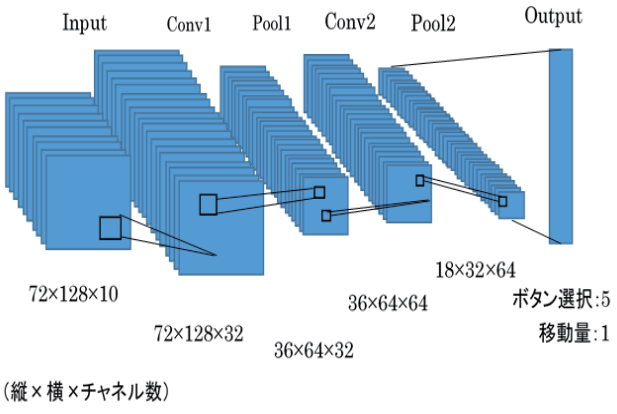


図 7: CNN 行動決定モデルの概念図

5. 結果

学習時と同様の特別ステージにて対戦を行い，各手法に対する評価を行う．当初の狙いでは単純に勝率の高いものが強くて良いモデルと考えたが，対戦相手となるプレーヤーを楽しませることを念頭においたキャラクタ操作モデルを構築することを考慮すると，必ずしも強いものが良いとは言い切れなかった．そのためゲーム対戦時の振る舞いについても評価の対象に含めた．

ここではランダム性などは完全に排除し，作成した 1 つの固定モデルで毎フレームの入力に対して最大確率のアクションを選択することを基本とする．

5.1 勝率

本研究では評価のために学習時に用いていたのと同じ敵と 100 試合対戦を行い，その勝率を比較して検討を行った．なお，ここでも学習時と同様に一定時間を超えて逃げ続けた場合は作成したモデルの敗北とする．構築した LSTM，CNN の各モデルでアクションをランダムに選択するよりも勝率が高くなった．表 1 に結果をまとめて示す．

表 1: 各手法による対戦勝率

モデル	勝率
LSTM	0.42
CNN	0.53
ランダム	0.18

5.2 振る舞いに関する考察

LSTM モデルではプレイに人間らしさが見られるようになった．具体的には攻撃を受けた時にはガードを選択して，敵との間合いを取り，タイミングに合わせて攻撃するような動きになった．教師データとして人間のプレイを学習していることにより，スティックの移動量を固定する必要がなく，制約が少なくて済む点が功を奏したと考えられる．

しかし攻撃が消えてしまっているのではないかと思われるところもあった．これは同じような状況において，攻撃よりも回避行動の方が多いせいで，アクション選択時に回避行動の確率が上昇し，結果的に攻撃が見送られたのではないかと考えられる．そのため行動選択時に最大確率のアクションを毎回選ぶのではなく，それぞれの確率に応じてアクションを選ぶ手法も試してみたが，違いは殆ど見られなかった．

また移動量に関しても，正解データの半分は移動量が 0 だが，モデルからは常に正か負の値が出力された．これは学習データで全ての状況を網羅することが難しいことによると思われる．訓練データの学習時には 0 を出力するように学習したはずだが，実際の対戦における多様な入力に対しては学習出来ていない場合が多く，結果として適当な値が出力されたのだと考えられる．

CNN モデルでは，LSTM モデルと同様にプレイに人間らしさが見られるようになった．その一方で画像列の特徴量を抽出することにより，似たような状況に対してある程度パターン化されたような動きをした．

6. 今後の展望

本研究により，深層学習を用いてゲームのキャラクタを自動操作するモデルを構築するプリミティブなシステムが出来たが，勝率の問題など課題はまだ残されている．

今後はゲーム操作に関する学習上のいくつかの問題を解決し，より環境に応じてアクションを選択出来るモデルを実現したい．また時間方向にも畳込みを行う 3D-CNN を用いたモデルなども実装することで，より教師データとして用いた人間のプレイを模倣するようなモデルの構築に努めたい．

また本研究では学習時に決定するハイパーパラメータに関する調整はあまり行わなかったが，その点を考慮することによって，より意図に沿ったモデルの構築が期待出来ると考えられる．

参考文献

[Harmer 18] Harmer, J., Gisslén, L., Val, del J., Holst, H., Bergdahl, J., Olsson, T., Sjöö, K., and Nordin, M.: Imitation learning with concurrent actions in 3D games, in *2018 IEEE Conference on Computational Intelligence and Games (CIG)*, pp. 1–8 (2018).

[Mnih 13] Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., and Riedmiller, M.: Playing atari with deep reinforcement learning, *NIPS Deep Learning Workshop* (2013).

[Silver 17] Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., Hubert, T., Baker, L., Lai, M., Bolton, A., Chen, Y., Lillicrap, T., Hui, F., Sifre, L., Driessche, G., Graepel, T., and Hassabis, D.: Mastering the game of Go without human knowledge, *Nature*, Vol. 550, No. 7676, pp. 354–359 (2017).

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

複数の作業文脈の統合深層モデルによるコミットメッセージ生成

Neural commit message generation integrating multiple work context encoders

岩永 知裕 *1 Tomohiro Iwanaga
眞名垣 優希 *1 Yuki Managaki
谷垣 宏一 *1 Koichi Tanigaki

*1福井工業大学
Fukui University of Technology

This paper proposes a new neural network model for commit message generation. Previous studies simply apply machine translation models to convert code diffs to commit messages, which lacks the mechanism to learn how to write intentions of code modifications, although it is often required in desirable commit messages. The proposed model introduces multiple encoders to efficiently capture different levels of working contexts, such as code modifications and original bug reports. Experimental results using GitHub dataset showed degradation when adopting issues as additional contexts, which suggests the commit style specificity of the dataset.

1. はじめに

ソフトウェア開発の現場では、過去のソースコードがしばしば参照される。例えば、ソフトウェア改修においてバグが混入したとき、あるいは仕様変更が生じたとき、過去のソースコードから目的のバージョンを特定し参照する作業が発生する。こうした作業を容易にするため、バージョン管理システムが広く用いられている。バージョン管理システムとは、開発物の変更履歴を記録管理するシステムである。バージョン管理システムは、ソースコードの変更をコミットという単位で管理している。各コミットには、ソースコードの変更内容や目的を自然言語で説明した文（コミットメッセージ）が紐づけられている。コミットメッセージを読む事で、過去の膨大なコミットから、必要なコミットを特定する事が容易になる。

しかし、有益なコミットメッセージを作成することは必ずしも全ての開発者にとって容易なことではない。この問題に対して、コード差分からコミットメッセージを自動生成する研究が試みられている [Jiang 17]。しかし、コード差分のみを入力とする手法では、コード変更の意図のような説明をメッセージ中に含めることが難しい。そこで本研究では、より有益で高品質なコミットメッセージ自動生成を狙い、問題報告とコード差分の 2 つの文脈を利用したメッセージ生成方式を提案する。

2. 関連研究

ソースコードを入力として自然言語を出力する研究は様々存在している。Xing らはソースコードから、コメント文を生成する手法を提案している [Schuster 18]。Jayavardhan らはプログラムの実行中に出力される実行ログのメッセージを自動生成する方式を提案している [Pinji 18]。Alireza らは android アプリのメソッドに対して要約文を生成している [Alireza 18]。これらの研究ではソースコードのみをメッセージ生成の文脈として用いている。それに対して本研究では、複数の文脈を複合的に用いた文生成を試みる。

3. 提案法

我々は、有益なコミットメッセージには変更意図などの説明が記載されており、そうした説明は、修正したコードのリテラルな内容よりも、変更に至った経緯のような抽象的文脈に強く依存して記載されると考える。そのような文脈を捉えるのに有効な情報として、問題報告 (Issue) を用いることができる。バージョン管理システムを利用した開発現場では、ソフトウェアの問題点や発見したバグ、追加すべき機能などを問題報告という機能を用いて共有している。開発者は、これら問題報告を参考にしてソフトウェアの変更を行う。そこで、本研究ではコミットメッセージ生成に問題報告を利用するモデルを提案する。

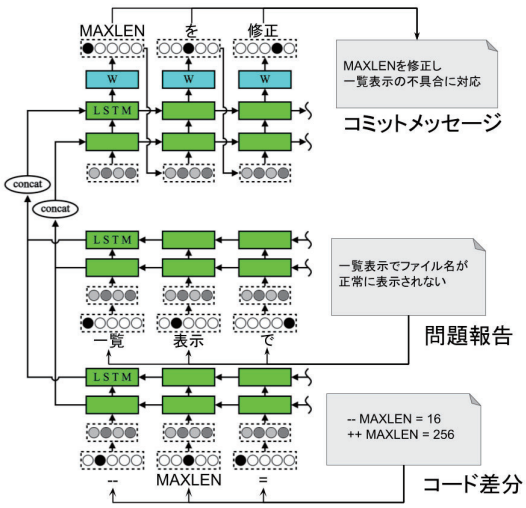


図 1　提案モデル

提案モデルを図 2 に示す。先行研究 [Jiang 17] で用いられた機械翻訳のモデルが、コード差分に対するエンコーダ 1 つと，コミットメッセージ生成のためのデコーダ 1 つから構成されるモデルであったのに対し、提案モデルでは 2 つの作業文脈からコミットメッセージを生成するため、2 つのエンコーダを持つ点が特徴である。このモデルは bi-LSTM[Schuster 18] から発想を得たもので、エンコーダ部を 2 つにした seqence to seqence（以下 seq2seq）[Sutskever 14] モデルである。bi-LSTM では、同一文の入力順序を逆にして入力していたが、提案モデルでは、問題報告とコード差分の単語列をニューラルネットの階層に逐次的に入力している。それぞれの単語列を入力後、メモリーセルを統合 (concatenate) しデコーダに渡すことで入力と出力が 2 対 1 のコミットメッセージ生成が可能となっている。

連絡先: 岩永 知裕, 福井工業大学, tomo1996722@gmail.com

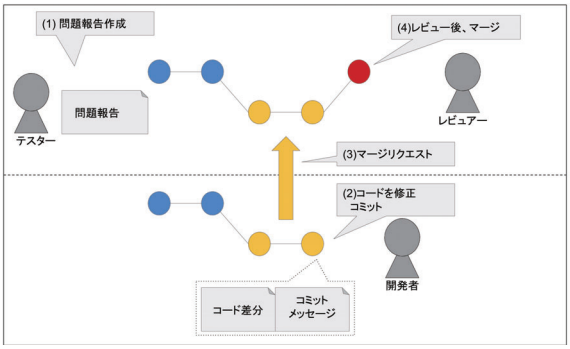


図 2　GitHub における開発の流れ

4.　評価実験

本研究によるメッセージ生成の有効性を評価するため評価実験を行った。

4.1　実験データの収集

本研究で使用したデータは GitHub*1 から取得した。GitHub では、大人数でコードを編集してもバージョンを管理できるよう、図 4.1 に示す作業フローでコード変更がコミットされる。まずユーザやテスターは、バグや不足機能を見つけると問題報告を作成する。この問題報告には問題を要約したタイトルと、その詳細が記載されている。また問題報告にはアサイン機能も存在し、実際にこの問題に対処する開発者の割り当てを行う事が出来る。問題報告に割り当てられた開発者は、この問題報告を参考にソースコードの変更を行い、1 回ないし数回のコミットを行う。このとき他の開発者が平行して開発を進められるよう、履歴を分岐させる。開発者は、修正に必要なコミットが全て完了すると、分岐後の全てのコミットを分岐元にマージするよう要請する。要請されたコミット群をマージしても問題が無いか、レビュアーが確認を行い、問題がなければこれらのコミットを履歴元にマージする。この時、問題報告に対して、マージリクエストの ID が採番される。本研究では、これらマージリクエスト ID を問題報告から抽出し、マージリクエスト内の全コミットと問題報告文を関連づけた。この関連から問題報告、コード差分、コミットメッセージの 3-tuple を作成した。

4.2　実験設定

メッセージ生成精度の定量評価尺度には BLEU を用いる。[Jiang 17] と同様に、生成されたコミットメッセージとオリジナルの文から BLEU スコアを算出し、各手法による精度を比較する。実験では 2 つのデータセットを用いる。これらはいずれも Java 言語を使用する OSS プロジェクトのデータであり、ランキング Top 100 プロジェクトのデータセットと、Top 1000 プロジェクトのデータセットとを用いた。表 1 に両データセットの詳細を示す。ただし問題報告とコード差分はメモリの制約から先頭 200 単語のみを用いた。語彙は頻度上位 4,000 語で生成した。ハイパーパラメータ探索用の開発データと評価用のデータは、それぞれ 1,000 セットずつランダムで抽出した。ただしハイパーパラメータの探索は Top100 のデータセットのみで行い、Top1000 のデータセットでは Top100 と同一のハイパーパラメータを使用した。これらデータセットを用いて複数エンコーダ seq2seq、およびコード差分のみを入力した seq2seq、コード差分と問題報告を連結して入力した seq2seq、の 3 つを比較し、問題報告を利用する効果と、複数エンコーダ seq2seq の有効性を確認する。

*1　https://github.com/

表 1　データセット：diff/issue/コミットメッセージ

–	Top100	Top1000
3-tuple	18,183	46,257
bytes	27M/14M/812K	67M/34M/2.1M
語彙	40000/24543/9704	40000/40000/40000

表 2　各手法によるメッセージ生成精度 (BLEU スコア)

–	Top100	Top1000
複数エンコーダ (提案手法)	0.258	0.179
コード差分のみ	0.313	0.243
コード差分＋問題報告	0.299	0.207

4.3　実験結果

実験結果を表 2 に示す。BLEU スコアはコード差分のみを用いた seq2seq が最も高く、次に問題報告とコード差分を結合した seq2seq、最も低いのが提案モデルという結果になった。またデータセット間においては、すべての手法において、Top100 のデータセットにおいて Top1000 を大きく上回るスコアが得られた。本実験結果からはコミットメッセージ生成に問題報告を用いる有効性は確認できなかった。

5.　考察

今回の実験で提案法により期待する性能が得られなかった要因として、GitHub における開発が、我々の想定する流れと異なっていたことが考えられる。GitHub における開発では、メインの履歴に対して直接コミットされるのではなく、分岐した履歴に対しローカルにコミットしておいて、最後にメインにマージリクエストする形式で開発が進む（図 2）．このような二段階の作業フローでは、マージリクエストのメッセージにおいては元の問題報告を強く意識し、それに対応したことを示すメッセージが作成される傾向があると考えられるが、それ故、前段階のコミットでは問題報告との関係が希薄なメッセージがローカルに作成される可能性がある．今後、GitHub 以外の、チケット駆動開発のプロジェクトデータや、企業など一定の統制の元で作成されたデータにも適用し、提案法の有効性を検証したい。

謝辞

本研究は三菱電機株式会社の協力を得たものです。

参考文献

[Jiang 17] Jiang, D et al.'s: "Automatically Generating Commit Messages from Diffs using Neural Machine Translation", Proc. of ICAE. (2017)

[Sutskever 14] Sutskever, I et al.'s: "Sequence to Sequence Learning with Neural Networks", ANIPS. (2014)

[Schuster 18] Schuster, M et al.'s: "Bidirectional Recurrent Neural Networks", IEEE TSP,(1997)

[Alireza 18] Alireza, A et al.'s: "GENERATING SUMMARIES FOR METHODS OF EVENT-DRIVEN PROGRAMS: AN ANDROID CASE STUDY", arXiv preprint,(2018)

[Pinji 18] Pinji, H et al.'s: "Characterizing the Natural Language Descriptions in Software Logging Statements", ACM/IEEE ICASE(2018)

[Schuster 18] Xing, H et al.'s: "Deep Code Comment Generation", CPC ACM,(2018)

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

強化学習による建築構造最適化の適用性検討

Optimization Method for Structural Engineering by Reinforcement Learning

鈴木　琢也[*1]
Takuya Suzuki

市川　享祐[*2]
Kyosuke Ichikawa

[*1] 竹中工務店
Takenaka Corporation

[*2] アーク情報システム
Ark Info. Sys.

The purpose of this paper is to confirm an applicability of the structural optimization methods by reinforcement learning. First, the outline of the developed application is explained. This application takes advantage of the features of smart devices as to anyone from adults to children can enjoy it. Secondary, the detail of optimization method by reinforcement learning is explained. And then, by proposed method, optimization analyses are conducted. Finally, the optimization result are compared with the result by the traditional method, and the applicability of proposed methods is examined.

1. はじめに

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

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

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

本報では，このタッチで出来る構造最適化アプリケーションにおいて利用する対戦コンピューターの戦略ロジックを決定するために，新たに強化学習による構造最適化手法を提案し，その適用性検討結果を報告する。

2. 開発するアプリケーションの概要

タッチで出来る構造最適化アプリケーションであるStartOPT[鈴木 2017]を対戦型に改良したものである[鈴木 2018]。

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

様々な荷重条件，境界条件下における強い形を数多く試すことを通して，効率的な構造を直感的に理解するとともに，建築

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

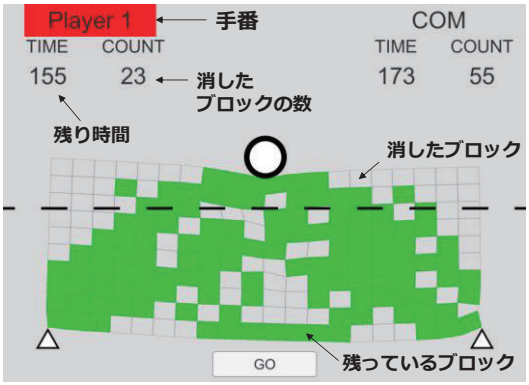


図 1　ゲーム画面

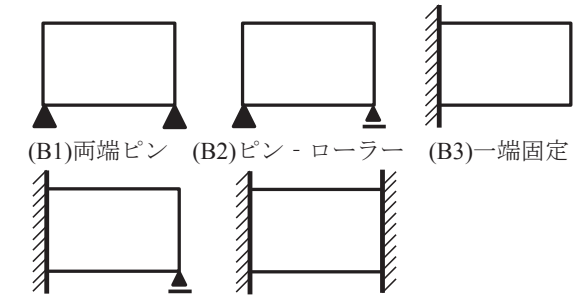


図 2　境界条件

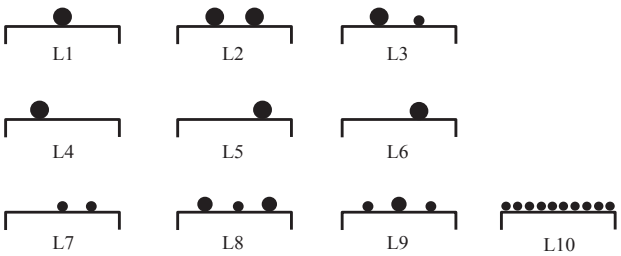


図 3　荷重条件

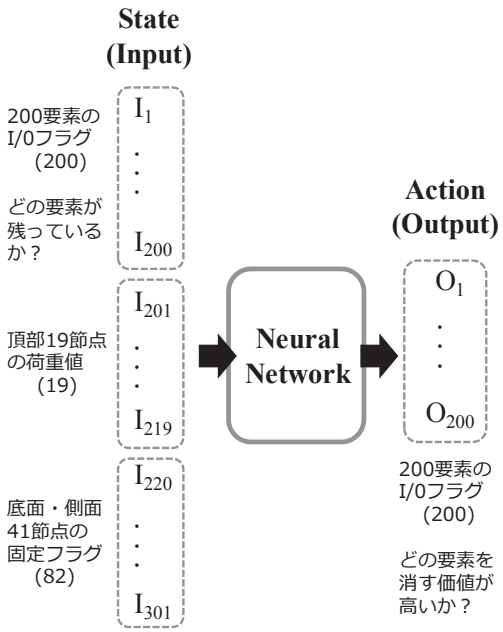


図 4　Neural Network の入出力

構造の基礎である「力の流れ」を，老若男女問わず楽しく理解することができる。

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

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

3. 学習計画

与えられた状態（State）から各行動の行動価値 Q を算定し，次の行動（Action）を決定するエージェントを強化学習によって構築する。

この場合，行動価値 Q を正しく見積もることが重要である。行動価値 Q は収益の期待値であり，厳密には次のベルマン方程式で算出できる。

$$Q(s,a)=\sum_{s'}P(s'\mid s,a)\{r(s,a,s')+\gamma\sum_{a'}\pi(a'\mid s')Q(s'\mid a')\} \quad (1)$$

ここで，P(s'|s,a)は状態遷移確率であり，状態 s において行動 a を決定したとき，状態が s'に遷移する確率である。この確率は未知であるため，この値を直接使わずに行動価値を求める必要がある。その方法として，Sarsa や Q-learning が知られている[牧野 2016]。Q-learning では，収束先を(1)式ではなく，次の最適ベルマン方程式とする。

$$Q^*(s,a):=\sum_{s'}P(s'\mid s,a)\{r(s,a,s')+\gamma\max_{a'}Q^*(s'\mid a')\} \quad (2)$$

そして，次式で行動価値 Q を更新する。

$$Q(s_t,a_t)\leftarrow(1-\eta)Q(st,at)+\eta\{r(s_t,a_t,s_{t+1})+\gamma\max_{\tilde{a}\in A}Q(s_{t+1},\tilde{a})\} \quad (3)$$

ここで，η(0<η<1)は学習率と呼ばれる微小なパラメータである。行動決定と状態遷移が行われるたびに，この式によって更新する。現状値の $Q(s_t,a_t)$と，目標値の $r(s_t,a_t,s_{(t+1)})+\gamma\max Q(s_{(t+1)},a)$との内分によって，Q を更新している。状態遷移確率 P(s'|s,a)を使用しない代わりに，この計算の頻度（更新頻度）で状態遷移確率 P(s' |s,a)が表現される。

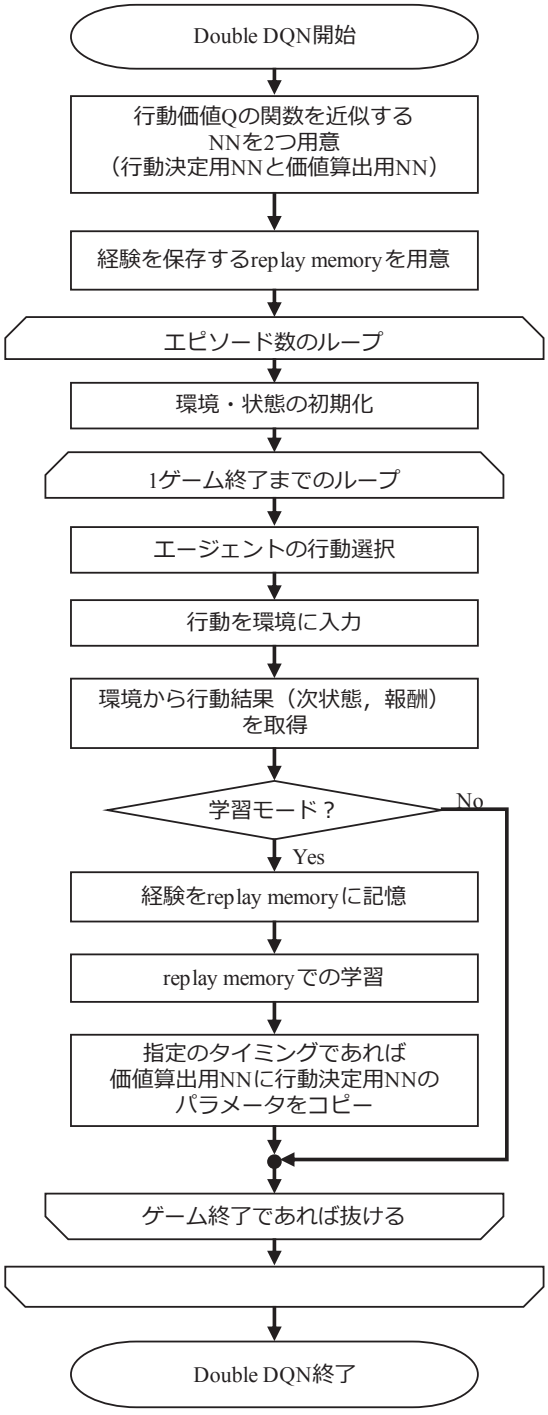


図 5　学習のフロー

さて，行動価値 Q は Q-learning によって更新可能だが，この関数をテーブルとして保存すると，状態数と行動数の組み合わせだけ行動価値が存在し，膨大なメモリが必要となる。そこで，この関数をニューラルネットワーク（以降,NN）で近似する（図 4）。この手法は Deep Q Networks[Mnih 2013]（以下，DQN）と呼ば

れる。ただし，本作業では改良型の Double DQN[Hasselt 2015] と呼ばれる手法を用いた。図 5 にそのフローを示す。

エージェントは，一般的に最適行動とは最も行動価値の高い行動を選択する。しかし，今回の問題では既に削除されたブロックを削除することはできないため，次の修正された行動価値 $\tilde{Q}$ を求め，それが最も大きい行動を最適行動とした。

$$\tilde{Q}(s_t,a_t) := Q(s_t,a_t) - \lambda(s_t,a_t)\max Q(s_{t+1},\tilde{a}) \quad (4)$$

ただし，λは行動 a_t で選択されたブロックが削除済であれば 1，未削除であれば 0 となる関数である。これにより，削除済のブロックに対する行動価値は最小となる。また，ランダムに行動する際も，削除済のブロックを削除する行動は選択されない仕様にした。

4. 検討結果

深層強化学習の検証を行った。本検証では，エージェント同士の対戦を行い学習させた。ただし，エージェントは複数用意するのではなく，同一のものを使用した。検証ケースを表 1 に示す。中間層および中間層のノード数をパラメータとし，計 3 ケースについて実施した。なお，プレイするステージは，境界条件 B1，荷重条件 L1 のステージ 1 としている。

また，全ケース共通のハイパーパラメータを表 2 に示す 。

テスト(推論)は 10 エピソードに 1 回実施し，報酬和が最大になったエピソードの学習結果を保存するようにした。また，100 エピソード毎に学習結果を保存するようにした。

図 6 には学習後のエージェントによるゲームのプレイ結果を示す。

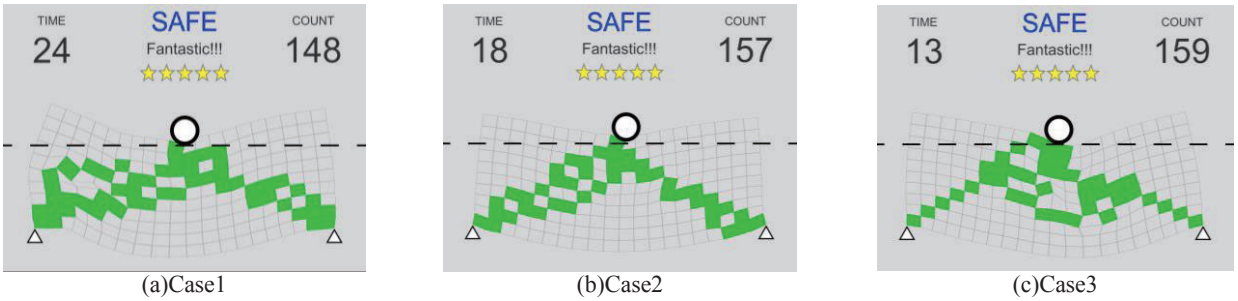
図より，ノード数，中間層数の少ない Case1 に比べて，ノード層の多い Case2 や，中間層数の多い Case3 の方が高得点を記録していることがわかる。ノード数，中間層数を増やすことでより複雑な行動判断が可能になった結果，高得点を記録できるエージェントが作成できたと考えられる。一方，Case2 と Case3 を比較すると，Case3 の方が高得点を記録できており，中間層数

表 1 解析ケース一覧

Case No.	中間層 層数	中間層 ノード数
1	1	1000
2	1	2000
3	2	1000

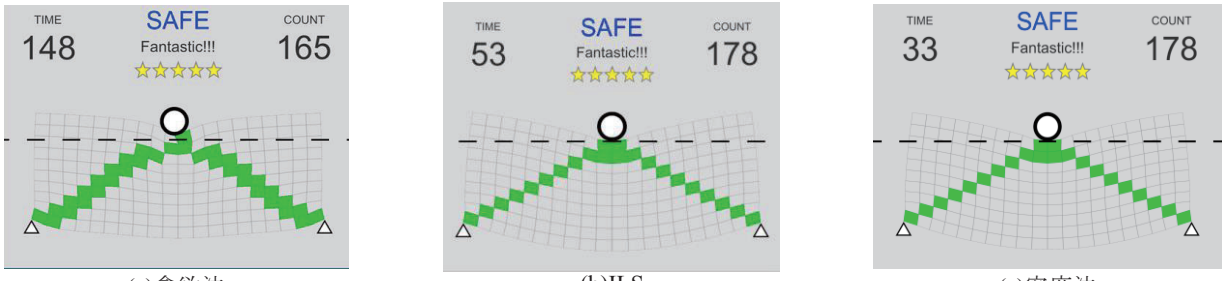
表 2 Hyper Parameters

項目	設定
エピソード数	5000
割引率 γ	0.997
ミニバッチサイズ	32
初期学習率 η	1.0E-05
重み行列初期値の 標準偏差	0.01
replay memory のサイズ	104 の経験分
学習を開始する replay memory のサイズ	ミニバッチサイズ
価値算出用 NN の 更新間隔	経験を 1000 格納する毎に 1 回
ε (学習時ランダム行動の確率)	Episode 毎に 線形に減衰 Episode 1: ε=1.00 Episode 2000: ε=0.05 以降，ε=0.05
報酬関数	両者の消した ブロック数



(a)Case1　(b)Case2　(c)Case3

図 6　強化学習による最適化結果



(a)貪欲法　(b)ILS　(c)密度法

図 7　既存手法による最適化結果 [鈴木　2018]

を増やすほうがより効果的であるといえる。

また，図 7 には比較のため，[鈴木 2018]に示された既存の最適化手法の結果を示す。図より，今回実施した，強化学習による方法に比べて，既存の最適化手法の方がよりよい結果を示していることがわかる。強化学習による方法で既存の最適化手法よりも良い結果を出すためには，今回よりも複雑な NN を用いるなどの改良が必要であるといえる。

5. まとめ

本報では，タッチで出来る構造最適化アプリケーションにおいて利用する対戦コンピューターの戦略ロジックを決定するために，新たに強化学習による構造最適化手法を提案し，その適用性について検討した。

その結果，一定の精度で最適化形状に至るエージェントを作成できたものの，既存の最適化手法に比べるとやや劣る結果となった。より精度の高い最適化を行うエージェントを作成するには，今回よりも複雑な NN を用いる等の改良が必要と考えられる。

参考文献

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

[鈴木 2018] 鈴木琢也ほか:建築構造教育アプリケーションに対する各種最適化手法の適用性検討，JSAI2018，教育，3Pin1-01, 2018.6

[牧野 2016] 牧野貴樹, 澁谷長史, 白川真一, 他: これからの強化学習, 森北出版, 2016.

[Mnih 2013] V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves I. Antonoglou, D. Wierstra, M. Riedmiller: Playing Atari with Deep Reinforcement Learning, arXiv:1312.5602, 2013.

[Hasselt 2015] H. van Hasselt, A. Guez, and D. Silver: Deep Reinforcement Learning with Double Q-learning, arXiv: 1509.06461, 2015.

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

エッジコンピューティングに適した 深層学習を用いた適応的圧縮センシング

Adaptive Compressed Sensing Using Deep Learning Suitable for Edge Computing

関根 理敏 *1　　伊加田 恵志 *1
Masatoshi Sekine　　Satoshi Ikada

*1沖電気工業株式会社 経営基盤本部 研究開発センター
Corporate Research and Development Center, Oki Electric Industry Co., Ltd.

In this paper, we propose a method to dynamically and directly estimate the optimal compression ratio based on sensor data in compressed sensing. It is able to be executed at edge devices for efficient data transmission in wireless sensor networks. Generally, the optimization in data compression requires a large amount of calculation. Therefore, in our proposed method, the optimal compression ratio can be obtained with lightweight processing by using the pre-trained model of supervised learning or reinforcement learning in deep learning. As a result of the performance evaluation using acceleration data generated from the sensor placed on a bridge, our proposed method can reduce the estimation delay of the optimal compression ratio. In addition, both the compression ratio and reconstruction error can be reduced by changing compression ratio dynamically based on the sensor data in time domain.

1. はじめに

近年，橋梁やトンネルなどの社会インフラの老朽化に伴い，その維持管理のための IoT を活用したモニタリングシステムが重要となっている．これらの構造物は日本の高度経済成長期に集中的に整備され，今後 20 年間で建設後 50 年以上経過する施設の割合は急激に高くなる見込みであり [MLIT], 今後老朽化が拡大することが懸念されている．そのため, このような社会インフラ構造物を戦略的に維持管理・更新することが求められている．IoT を活用したモンタリングシステムの試みとしては, RAIMS[RAIMS] での社会インフラのモニタリング技術の活用推進に関する技術研究開発等が挙げられ，活発に研究開発が行われている．

社会インフラ構造物のモニタリングや点検では加速度データ，歪みデータ，画像データ，音声データ等の様々なセンサデータが必要とされ, 一般にセンサデータの量が多いほど人工知能等を活用したより高度なデータ分析が可能となるため, 配置される個数も多い方が望ましく，さらにモニタリング期間も長期間であることが望ましい．しかしながら, このようなセンサデータは一般に．温度・湿度等の環境データよりリアルタイムで，はるかに大きいデータ量が発生するため, 収集されるデータも膨大となってしまう．さらに，センシングを行いデータを収集するエッジ端末は計算能力, バッテリ容量, メモリ量, データ伝送レート等に制約がある場合が多く, 前述のようなセンシングデータを処理する上で無線リソースや消費電力の浪費が発生する．このような条件においてモニタリングシステムを構築するには, データの送信を省リソースでかつ効率的に行う必要があると考える．

もし予めセンサデータからモニタリングに必要な特徴量が既知である場合はエッジ側でデータを加工して特徴量を抽出し，その特徴量のみを送信することにより送信量を削減することが可能である．しかし，橋梁といった構造物のモニタリングに必要となる加速度データ等は，その構造物のそれぞれ構造や形状が異なり, その発生するデータのメカニズムが十分に解明されていないため，どのような特徴を抽出すれば良いかが事前に明確でない場合もある．

そこで本稿では，元のデータの情報量をなるべく落とさず，復元において元のデータに近似可能な圧縮データを少ないリソースで生成することを目的とする．我々はデータのスパース性を仮定し，より少ない観測データから元のデータを復元可能な圧縮センシングと呼ばれる手法に着目する．一般にセンサデータの情報量を表す指標であるスパース性の度合いはリアルタイムに変動するため，圧縮センシングにおいてデータ圧縮の効率を上げるためには圧縮比の最適化制御を行う必要がある．また, この制御においてリソースが少ないエッジ端末でも省リソースで行えるようにする必要がある．このため, 事前に計算能力の高い端末で教師あり学習または強化学習で最適な圧縮比を推定するモデルを学習し, それをエッジ端末に搭載することにより，センサデータから最適な圧縮比を省リソースで動的かつ直接的に推定し, データ圧縮を高効率に実施可能な手法を提案する．この結果，アプリケーションで実際に必要な特徴量が特定できない場合においても 提案手法を用いることで, エッジ側でデータを適応的に削減することにより通信コストを削減し，かつアプリケーションにおける高度なデータ分析に必要な情報量を確保し, 分析精度の劣化も抑制することが可能となる．

2. 関連研究

2.1 圧縮センシング

データ送信量の削減方法として圧縮センシング [Donoho 06] がある．これはデータの取得と圧縮を同時に行うことで，エッジ端末において低負荷に処理が可能であるためである．圧縮センシングでは，生成される N 次元のセンサデータを $\mathbf{x} \in \mathbb{R}^N$，$M \times N$ の観測行列を $\mathbf{\Phi} \in \mathbb{R}^{M \times N}$ として，観測データ $\mathbf{y} = \mathbf{\Phi x} \in \mathbb{R}^M$ の送受信を行う．復元側では元のデータの個数＞観測データの個数となることから通常は一意な解を求めることができないが，$\mathbf{x} = \mathbf{\Psi s}$ のように，元のデータ $\mathbf{x}$ が，要素に 0 を多数含むスパース行列 $\mathbf{s}$ と基底変換行列 $\mathbf{\Psi}$ の積により表すことができるとすると，圧縮後の観測データ $\mathbf{y}$ を完全に復元できる可能性がある．具体的には，下記の式 (1) のようなスパース表現

連絡先: 関根理敏，沖電気工業株式会社 経営基盤本部 研究開発センター，埼玉県蕨市中央 1-16-8，sekine566@oki.com

を仮定し，式 (2) のように $\mathbf{s}$ の L1 ノルムを最小化する問題に帰着して求めることが可能である．

$$\mathbf{y} = \mathbf{\Phi x} = \mathbf{\Phi \Psi s} = \mathbf{As} \tag{1}$$

$$\begin{aligned} &\underset{\mathbf{s}\in\mathbb{R}^N}{\text{minimize}} ||\mathbf{s}||_1 \\ &\text{subject to} \mathbf{y} = \mathbf{As} \end{aligned} \tag{2}$$

ここで求めた $\mathbf{s}$ を利用して $\mathbf{x} = \mathbf{\Psi s}$ を計算することにより，元のデータ $\mathbf{x}$ を復元することが可能である．

2.2 圧縮比の適応化

一般に μ を観測行列 $\mathbf{\Phi}$ や基底変換行列 $\mathbf{\Psi}$ に依存した定数として，もし観測数 M が近似的に $\mu||\mathbf{s}||_0 \log(N)$ であれば高確率で復元可能である [Donoho 06][Candes 06]．つまり $\mathbf{x}$ を基底変換した $\mathbf{s}$ の L0 ノルムの値が復元誤差に影響する．しかしながら元のデータ数 N の増加に伴う基底変換のオーバヘッドが存在したり，元の信号のスパース表現において要素が完全には 0 にはならなかったりするため，$\mathbf{s}$ の L1 ノルムの値から最適な圧縮率へのマッピングは容易ではない [Behravan 15]．

一方，復元を行う端末からのフィードバックを前提としている方式 [Zhu 14][Charalampidis 15] では受信端末がリアルタイムに複合処理を行わなければ動的に圧縮比を変更できなかったり，送信端末のデータを受信端末に送信後に受信端末からのフィードバックにあるため，圧縮比を反映するまでの遅延が生じ，送信端末リアルタイムなデータ特性の変化に十分対応できない可能性がある．

近年，無線通信・ネットワーク技術分野に機械学習の活用が進んでいる．理論的なモデル化が難しい場合，または仮にモデル化ができてもシステムが複雑で計算量が多い場合に，データ駆動でモデル化が可能な場合がある [Hoydis 18]．しかしながらセンサ信号から圧縮センシングにおける最適な圧縮比へのマッピングについてはまだ論じられていない．

3. 深層学習を利用した適応的圧縮センシング

3.1 データ伝送効率の最適化

提案手法におけるデータ圧縮法として，圧縮センシングを利用する．データの取得と圧縮とを同時に行うことでエッジ端末で低負荷で圧縮可能であるためである．一般にセンサデータの特性はリアルタイムに変動すると仮定すると，圧縮比 $c = M/N$ が固定な場合，冗長な観測データを送信したり，逆に十分な観測データを送信できず，受信側での復元誤差が増大するという問題が生じる．

その問題に対応するため，提案手法では復元誤差と圧縮比とを含む評価指標であるデータ伝送効率を定義し，そしてセンサデータに応じて圧縮比 c を動的に変更することにより，データ伝送効率を最大化する．データ伝送効率において，元のセンサデータ $\mathbf{x}$ に対して送信端末で送信するデータ量 $d(c)$ 及び受信端末でのデータの復元誤差 $e(c)$ を考慮する．

データ伝送効率を $E(c) = f(d(c), e(c))$ とすると，センサデータ $\mathbf{x}$ に対する最適な圧縮比 c_{opt} は以下のように表される．

$$c_{opt} = \underset{c\in\{\frac{1}{N}, \frac{2}{N} \cdots, 1\}}{\arg\max} \quad E(c) \tag{3}$$

一例として圧縮効率を $E(c)$ を以下のように定義する．ここで閾値 e_{thre} 未満の復元誤差 $e(c)$ はデータ伝送効率に影響を与えないものとする．

$$E(c) = k_1(-C_{err} + k_2 c^{k_3} + k_4) \tag{4}$$

ただし

$$C_{err} = \begin{cases} 0 & (e(c) < e_{thre}) \\ k_5(e(c) - e_{thre})^{k_6} & (e(c) \geq e_{thre}) \end{cases}$$

またここで k_1 から k_6 は定数である．式 (4) のデータ伝送効率は，データに応じて一般に圧縮比が小さければ小さいほど，また復元誤差が小さくなればなるほど高くなるように設定し，これを最大化することにより，圧縮比と復元誤差の低減を両立することができる．一般にデータ伝送効率の関数は，ユーザがデータ量低減を重視するのか，また誤差低減を重視するのかに依存して設定する必要がある．

3.2 深層学習による最適な圧縮比の推定

上記の最適な圧縮比を求めるために，あるセンサデータに対する圧縮比と復元誤差の関係を繰り返し求めたり，センサデータを基底変換したりするのは計算量が増大する．また，復元側から復元に関する情報のフィードバックを受けて最適な圧縮比の推定することができない場合や，フィードバックを受けた後に結果を反映させることで送信側がリアルタイムに最適な圧縮比を反映できない場合がある．

そこで，このような送信端末での最適化制御の処理を軽減するために，深層学習を利用して最適な圧縮比を推定する．深層学習では表現学習により自動で特徴設計することでき，センサデータからの自動特徴抽出や最適な圧縮比の推定が可能になると考えられる．図 1 のように，学習段階で予めセンサデータからエンドツーエンドで最適な圧縮比を推定する学習モデルを構築し，推論段階で送信端末でその学習モデルを利用して最適な圧縮比を推定し，その圧縮比で圧縮センシング及びデータの送信を行う．一般に深層学習において，学習段階では順伝搬と逆伝搬を繰り返し行うため膨大な計算量が必要となるが，学習後の推論段階では順伝搬の計算を一度行えば良いため計算量は小さくなる．最適な圧縮比を推定するための学習方法として，教師あり学習または強化学習を利用する．特徴として教師あり学習は教師データの作成の計算コストが大きいが，ニューラルネットワークで出力されるべき目的変数が明確なため最適な圧縮比の精度が高いことが挙げられる．一方，強化学習では目的変数を試行錯誤で探索し推定精度を改善していくため，教師あり学習よりは最適な圧縮比の推定精度が低くなる可能性はあるものの，予め最適な圧縮比を学習データとして求める必要がないため，計算コストが低くなる．

3.2.1 教師あり学習による学習モデル構築

上記で述べたようにあるセンサ信号に対して最適な圧縮比を予めグリッドサーチ等を利用して求め，それを教師データとして，センサ信号を説明変数，圧縮比を目的変数として深層学習における回帰モデルを利用して学習する．

3.2.2 強化学習による学習モデル構築

強化学習では状態，行動，報酬を以下のように設定して学習を行う．

・状態：センサデータ（時間領域または周波数領域の信号）
・行動：圧縮比（離散値または連続値）
・報酬：式 (4) のデータ伝送効率

強化学習の場合，教師あり学習のように最適な圧縮比を予め求めることなく，試行錯誤によってセンサデータに対する最適な圧縮比を学習する．圧縮センシングにおいて圧縮比は

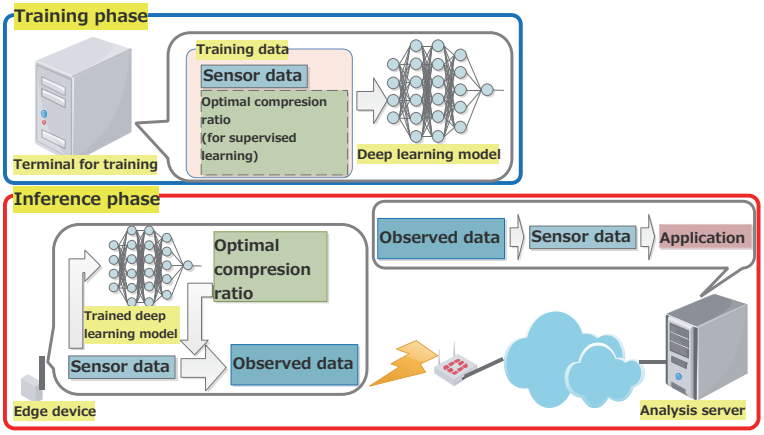


図 1: 深層学習による圧縮比設定モデルの構築

$1/N, 2/N, ..., 1$ の離散値をとるが，N が大きい場合は近似的に 0 から 1 までの連続値とみなし，行動として連続値を扱うことができる深層強化学習（一例として Deep Deterministic Policy Gradient（DDPG）[Lillicrap 15]）を適用する．ただし，行動の圧縮比 c は $1/N$ から 1 までの値を取るとして，それ以外の値を推定した場合は負の報酬を与えるようにした．

4. 性能評価

4.1 概要

以下の通り，4.2 で全探索，勾配法，提案手法 2 種（教師あり学習・強化学習）の性能を比較評価した．評価には 100Hz でサンプリングされた国内のある橋梁の垂直方向の加速度データ 6000 秒のデータを利用した．2 秒間 200 サンプルを 1 データブロックとして，1 データブロックごとに圧縮センシングを実施し，送信するものとする．最適な圧縮比は式 (4) で $k_1 = 10^5/2.6$, $k_2 = -2.6 \times 10^{-3}$，$k_3 = 3.0$，$k_4 = 2.6 \times 10^{-3.0}$，$k_5 = 1.0$, $k_6 = 2.0$ とした時に最大となる圧縮比とした．e_{thre} を元データの標準偏差の 5% である 4.73×10^{-4} とした．圧縮センシングの復元における L1 ノルム最小解の算出には凸最適化ライブラリ CVXPY[CVXPY] を利用した．また，基底変換行列 $\mathbf{\Psi}$ を逆離散フーリエ変換行列とした．

全探索では 1 データブロックのデータに対して，圧縮比が 0.005 から 1.0 までの 0.005 刻みで圧縮比と復元誤差を求め，最適な圧縮比を計算した．勾配法では学習率 η を 0.001 とし，ある圧縮比 c における一階導関数 $dE(c)/dc$ を以下のようにして求めた．

$$\frac{dE(c)}{dc} = \frac{E(c+h) - E(c-h)}{2h} \tag{5}$$

ただし $h = 0.1$ とした．そして以下のように学習率をステップバイステップで圧縮比を更新した．

$$c_{n+1} = c_n - \eta \frac{dE(c)}{dc} \tag{6}$$

また収束条件を過去 5 ステップの一階導関数 $dE(c)/dc$ の平均値が 1.0 未満になった時点とした．

提案手法の教師あり学習では，最適な圧縮比の正解値を求めるため，全探索で 0.005 から 1.0 までの 0.005 刻みの圧縮比と復元誤差を求め，3000 データブロックに対してそれぞれ圧縮効率を計算した．一次元畳み込み及びプーリング層 2 層，全結合層 2 層の多層ニューラルネットワークモデルを構築した．入力を 200 次元の加速度データ，出力を圧縮比として回帰学習を行った．

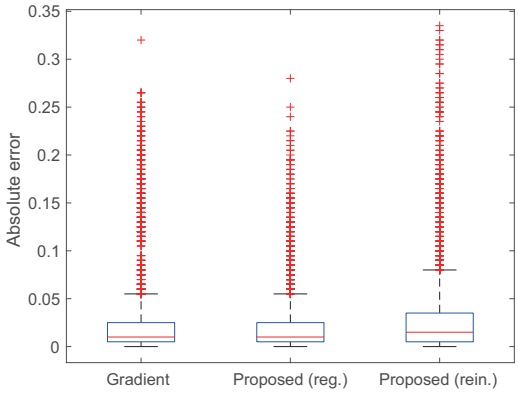


図 2: 最適な圧縮比の推定誤差

一方，提案手法の強化学習では actor のニューラルネットワークの構造は上記の回帰モデルと同様とした．critic のニューラルネットワークの構造は，入力を 200 次元の加速度データと 1 次元の行動データの計 201 次元のデータとし，actor と同じ構造のニューラルネットワークの出力と 1 次元の行動データを結合し，さらに全結合層 4 層を追加した構造をとった．

提案手法の教師あり学習及び強化学習ともに 10 分割交差検証を行った．

4.2 各手法の圧縮比推定精度，推定遅延，平均圧縮比と平均復元誤差

図 2 に各手法の 3000 データブロック分の最適な圧縮比の推定精度を示す．推定精度はあるセンサデータに対する最適な圧縮比を全探索で厳密に求めた圧縮比と，推定によって求めた圧縮比との誤差の絶対値とした．提案手法は勾配法と同程度で最適な圧縮比の推定が可能であることが分かる．

図 3 に各手法の 3000 データブロック分の圧縮比推定遅延の分布を示す．なおシングルボードコンピュータ Raspberry Pi 3 Model B+[Raspberry Pi] で圧縮比推定処理を行った場合の遅延とした．全探索法は 0.005 から 1.0 までの 200 段階の圧縮率を設定したときの復元誤差からデータ伝送効率を求めるまでの遅延とした．勾配法では圧縮比の初期値を 0.5 とし，式 (5) の一次導関数を求めて式 (6) で圧縮比を更新し，収束条件を満たすまでの遅延とした．提案手法の 2 種では学習モデルに 200 次元の加速度データを入力とし，学習モデルからデータ伝送効率を求めるまでの遅延とした．ここで，平均推定遅延は全探索法が 95.9 秒，勾配法が 29.3 秒，提案手法の教師あり

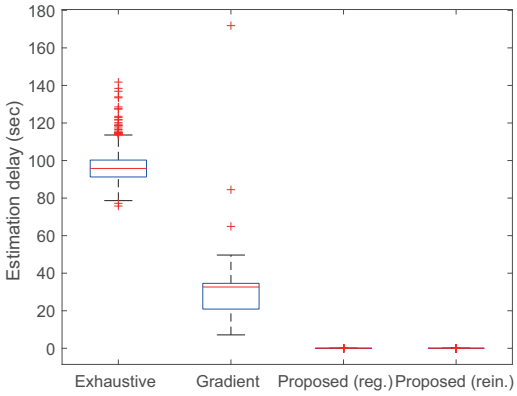


図 3: 各手法の圧縮比推定遅延

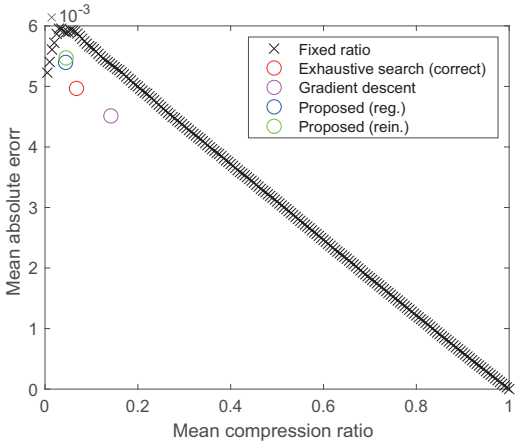


図 4: 平均圧縮比と平均絶対復元誤差

学習・強化学習がそれぞれ 0.013 秒，0.012 秒であった．全探索法や勾配法が圧縮比とそれに対する復元誤差を繰り返し求めるのに対し，提案手法は加速度データから多層ニューラルネットワークを用いて直接最適な圧縮比を推定するため，推定遅延は小さくなることが分かる．また勾配法では 1 回の探索時にその圧縮比 c での復元誤差と，一次導関数の値を求めるのに圧縮比 $c-h$ 及び $c+h$ における復元誤差の計 3 回の復元誤差を求めるため，検索回数が多くなると全探索より平均推定遅延が大きくなる場合もある．

図 4 に各手法の 3000 データブロック分の平均圧縮比と平均絶対復元誤差を示す．圧縮比が固定の場合は平均圧縮比が減少すると平均絶対復元誤差が増大し，逆に平均絶対復元誤差が減少すると平均圧縮比が高くなるというトレードオフの関係があるのに対して，動的に圧縮比を設定する全探索法，勾配法，提案手法 2 種は圧縮比が固定の場合の同じ平均圧縮比に対して，平均絶対復元誤差が小さくなっていることが分かる．これは平均圧縮比と平均絶対復元誤差がともに小さくなることで最適となるデータ伝送効率に基づいて圧縮比が設定されるためである．提案手法は全探索による厳密な最適解の導出の場合よりはデータ伝送効率が低くなるものの，圧縮比が固定の場合より，平均圧縮比と平均絶対復元誤差の両者を同時に低下できることでデータ伝送効率が高くなる．

5. おわりに

本稿ではエッジ端末において深層学習を利用して，時間領域のセンサデータから直接的に最適な圧縮比を推定する手法を提案した．提案手法により，最適な圧縮比を求めるにあたり，圧縮比とそれに対する復元誤差を逐次エッジ端末や復元端末で求めることなく，エッジ端末が多層ニューラルネットワークにより時間領域のセンサデータから直接推定ことで計算遅延を削減できる．そのため，計算処理能力が低いエッジデバイスでもリアルタイムに最適化が可能となる可能性がある．また，送信するデータ量と復元誤差を考慮した最適な圧縮比を低負荷に推定し，高効率なデータ伝送が可能となる．今後の課題として，深層学習のハイパーパラメータの最適化，推論段階で未知の特性を持つセンサデータを圧縮するときの対応，複数センサ環境での高効率伝送，実機への実装・評価等が挙げられる．

謝辞

本研究の一部は，総務省「戦略的情報通信研究開発推進事業（SCOPE） 国際標準獲得型研究開発」によるものである．

参考文献

[MLIT] 国土交通省，インフラメンテナンス情報，`http://www.mlit.go.jp/sogoseisaku/maintenance/index.html`

[RAIMS] モニタリングシステム技術研究組合，RAIMS (Research Association for Infrastructure Monitoring System)，`http://www.raims.or.jp/raims/`

[Donoho 06] D.L. Donoho, “ Compressed sensing,” IEEE Transactions on Information Theory, vol.52, no.4, pp.1289–1306, Apr. 2006.

[Candes 06] E.J. Candes, T. Tao, “ Near-Optimal Signal Recovery From Random Projections: Universal Encoding Strategies?,” Information Theory, IEEE Transactions on , vol.52, no.12, pp.5406,5425, Dec. 2006.

[Behravan 15] V. Behravan, N. E. Glover, R. Farry, “Rate-adaptive compressed-sensing and sparsity variance of biomedical signals,” IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN), Jun, 2015.

[Zhu 14] J. Zhu, Y. Zhang, G. Han, C. Zhu,“Block-based adaptive compressed sensing with feedback for DCVS”, 9th International Conference on Communications and Networking in China, Aug. 2014.

[Charalampidis 15] P. Charalampidis, A.G. Fragkiadakis, and E. Z. Tragos,“Rate-Adaptive Compressive Sensing for IoT Applications,” 2015 IEEE 81st Vehicular Technology Conference, May 2015.

[Hoydis 18] J. Hoydis, S. Cammerer, “Deep Learning for Communications,” Tutorial at IEEE GLOBECOM 2018, Dec. 2018.

[Lillicrap 15] T. P. Lillicrap et al.,“Continuous control with deep reinforcement learning,” *arXiv preprint arXiv:1509.02971*, 2015.

[CVXPY] Welcome to CVXPY 1.0 – CVXPY 1.0.12 documentation, `https://www.cvxpy.org/`

[Raspberry Pi] Raspberry Pi – Teach, Learn, and Make with Raspberry Pi, `https://www.raspberrypi.org/`