

Fundamentals Review

2024 October Vol.18 No.

2

<https://www.ieice.org/ess/ESS/Fundam-Review.html>

ごあいさつ

121 ソサイエティ編集の今とこれから 大橋正良

解説論文

123 知識グラフとオントロジーによる AI システムの開発 古崎晃司

137 非線形偏微分方程式に潜む離散構造
—コンピュータとの親和性の高い制御を目指して— 甲斐健也

147 ノイジーラベルを用いた画像分類 吉田 壮

158 オールフォトニクス・ネットワークに向けた光暗号回路 高橋順子

その他**ESS ニュース**

167 NOLTA, IEICE 特集号 菅野円隆

168 NOLTA, IEICE 特集号 田中悠一郎

169 2024 年電子情報通信学会 NOLTA ソサイエティ大会開催報告 佐村俊和

研究会に行こう！

172 超音波研究会 (US) 工藤すばる

172 非線形問題研究会 (NLP) 丹治裕一

173 スマートインフォメディアシステム研究会 (SIS) 笹岡直人

173 応用音響研究会 (EA) 小野順貴

174 技術と社会・倫理研究会 (SITE) 辰己丈夫

174 ワイドバンドシステム研究会 (WBS) 落合秀樹

国際会議報告

175 IEEE International Symposium on Information Theory 齋藤翔太

177 39th International Technical Conference on Circuits/Systems,
Computers, and Communications 仲地孝之

受賞者の声

179 第 80 回 (令和 5 年度) 論文賞

開催案内**論文募集**

Review

〒105-0011 東京都港区芝公園 3-5-8 機械振興会館内
電話 (03) 3433-6691 (代) FAX (03) 3433-6659
E-mail:office@ieice.org 振替口座: 00120-0-35300

IEICE 電子情報通信学会
基礎・境界ソサイエティ / NOLTA ソサイエティ

Preface

121 Current State and Future of Society Editing Masayoshi Ohashi

Review Papers

123 Developments of AI Systems Using Knowledge Graphs and Ontologies Kouji Kozaki

137 Discrete Structures Hidden in Nonlinear Partial Differential Equations :
For Control Methods that Have High Compatibility with Computers

147 Learning with Noisy Labels for Image Classification Tatsuya KAI
Soh Yoshida

158 Photonic Cryptographic Circuits for All-Photonics Network
Junko TAKAHASHI

Miscellaneous Articles

167 ESS News

172 Let's go to IEICE Workshops!

175 International Conference Report

179 Winners' Voice

183 Call for Participations

184 Call for Papers



ソサイエティ編集の今とこれから

Current State and Future of Society Editing

ソサイエティ編集長 大橋正良

小生以前 2021 年度コロナ騒ぎの真ただ中で 1 年間ソサイエティ会長を務めさせて頂きました。当時は、オンラインの活用を主として、学会が改革を行うにはいい時期であるとの趣旨を表明していました。今ほぼコロナ禍が収まってきている（まだありますが）中、本年度ソサイエティ編集長として編集の視点から意見を述べたいと思います

1. 電子情報通信学会の論文誌の役割

情報通信は今や電気、水道、ガスなどと並んで人の生活を支える基幹のインフラになったという主張を否定する人はもういないでしょう。情報通信に関わる技術の変革は、ほかのインフラを担う分野に比べ著しく早く活発です。先に例示したインフラが（実はものすごく革新はあるはずですが）少なくとも私たちの目にはあまりスペックが変わらずに利用されているのに対し、こと ICT は PC にせよ携帯にせよテレビにせよ破壊的といつてよいほどの変化を遂げてきました。

論文誌の最大の役割はもちろん最新の優れた研究成果をタイムリーに世に発信することにあります。また一方ではアーカイビングによって、上記の変化を支えた膨大な技術変革の歴史を正しく刻み伝え続けることも学会論文誌の大切な役割であると思っています。

2. 和文論文誌

和文論文誌は現在投稿数減少に苦慮しています。2024 年からは発刊の隔月化が行われるとともに和英論文誌編集幹事団も統合されました⁽¹⁾。このペースが続くと論文誌の発刊形態も更に統合などの検討が必要になってくる可能性もあります。ただ和文論文誌は個人的には何とか残して頂きたく、その理由は文献(2)にあるように、和文論文誌は、日本の基幹学会である電子情報通信学会が、そのコミュニティにおいて日本語で研究成果を示すことができる貴重な論文誌だからです。

今、英文論文誌では多言語化のトライアルが行われていますが、これを和文にも活用することで今後多少なりと和文コンテンツが多言語として理解されることにつながればと期待

します。

3. 英文論文誌

多くの先輩方が懸念されておられるとおり、インパクトファクター（IF）は今英文論文誌が抱えている大きい課題です⁽³⁾。少なくない人々が、IF のみを指標にするのは間違っているとか、いたずらに IF を気にする必要はない⁽⁴⁾とかと主張されますし、私も共感するところがありますが、今の世の論文誌の価値の指標にされているのが現実で、論文誌の浮沈がここにかかっています。ビジネスとして論文誌を維持しようとする、何らかの要素で投稿を募らないと打開できない状況になっています。

その中で、世界の潮流に沿うべくオープンアクセス化が行われました。最近の英文論文であれば、J-STAGE を通じて論文は公開され、関心ある読者は無料でダウンロードが可能です⁽⁵⁾。同時にトライアルとして、多言語化への試みも実施が始まっており、期間は限定されていますが、論文が多くの言語に翻訳されて閲覧することが可能となっています⁽⁶⁾。

これに限らず、これまで編集委員長をはじめとする多くの方々から IF 向上のための努力を払ってこられたことには、心から敬意を表します。急な改善は難しいですが、いたずらなスコア向上のためだけの策は弄さず、論文誌の支えになって頂くことを願います。

通信ソサイエティでは EB 並びに ComEX の IEEE Xplore への掲載を開始しました⁽⁷⁾。ESS もそのままそうしろと促すつもりではありませんが、ESS でも今後の対処について検討頂ければと思います。またこれまでも SITA サブソサイエティでは英文論文誌からの Selected paper として、バーチャルジャーナル SITA from IEICE-EA を発刊しています⁽⁸⁾。コンテンツとリポジトリとをうまく分けて、読者へのリーチを促すよい試みだと認識しています。

4. Fundamentals Review 誌

FR 誌は、時代にマッチした解説記事を学会誌よりも掘り

下げ、ESS ならではの専門性を発揮した記事を掲載されてきており、大変素晴らしい事業であると思います。このような事業はコストセンターとみなされがちで、ともすれば「これだけのコストをかけて何のためにやり続けるのか？」の問いを受けやすいのですが、それを跳ね返し基礎・境界ソサイエティの証とでもいうべき多くの分野の価値あるトップ記事を掲載しているのは、ひとえに FR 誌編集委員会の皆様、編集幹事会の皆様の努力のおかげです。本誌も多言語化を強く期待します。

5. これからの ESS の編集について

ESS はこれまで新しい研究の萌芽を支えてきたと思います。特定のテーマに偏っていないのはアピール力が欠如する欠点もありますが、決して大きな一つの技術分野のみに限定されていないので、新規萌芽となる研究領域にもチャレンジしやすいのではと期待します。この数十年、情報通信技術も大きく変革しましたが、まさにそれを担っている第一線の若手の研究者の方々が、査読ほか一連の編集・出版の仕事をボランティアで支えてくださっていることは素晴らしい伝統と変革であると思います。引き続き皆様のご理解とご支援をお願いします。

文 献

- (1) 岩本貢, “新しくなった編集幹事団—編集委員会のこれまでとこれから—,” 信学 FR 誌, vol. 17, no. 3, pp. 179-181, Jan. 2024.
- (2) 引原隆士, “ESS-NLS ソサイエティが始めるべきこと,” 信学 FR 誌, vol. 14, no. 2, pp. 94-96, Oct. 2020.
- (3) 田口亮, “英文論文誌・今後の方向性に対する私見,” 信学 FR 誌, vol. 16, no. 2, pp. 48-50, Oct. 2022.
- (4) 坂庭好一, “基礎・境界ソサイエティと電子出版,” 信学 FR 誌, vol. 5, no. 2, pp. 112-113, Oct. 2011.
- (5) <https://www.jstage.jst.go.jp/browse/transfun>
- (6) <https://global.ieice.org/>
- (7) <https://www.ieice.org/cs/cs-edit/en/xplore/>
- (8) https://www.ieice.org/ess/sita/sita-papers/whats_sita_from_ieice_ea.html

著者紹介

大橋正良 (正員: フェロー)

昭和 58 年京大工学研究科電子工学修了。同年国際電信電話(株)(現 KDDI)入社。以来衛星通信/符号理論/移动通信システム/IoT システムの研究開発・標準化に従事。平成 20 年 ATR メディア情報科学研究所/適応コミュニケーション研究所長。平成 25 年より福岡大学工学部電子情報工学科教授。令和 6 年より ATR 適応コミュニケーション研究所連携研究員/(株)オブテージ社外監査役。工博。情報処理学会, IEEE 各会員。

知識グラフとオントロジーによる AI システムの開発

Developments of AI Systems Using Knowledge Graphs and Ontologies

古崎晃司 Kouji Kozaki

アブストラクト 人工知能システムの開発には、機械学習や深層学習などを用いたデータ駆動型のアプローチと、知識処理技術を用いた知識型のアプローチがある。知識型の AI 技術においては知識グラフ（ナレッジグラフ）の活用が中核技術の一つに位置づけられ、様々な研究開発が進められている。知識グラフとは、知識のつながりをネットワーク型のグラフ構造で表現したものであるが、その公開や活用のためには Linked Data やオントロジーなどの技術が広く利用されている。本稿では、これらの知識グラフを用いた AI システムの開発に関わる基盤技術を解説する。

キーワード 知識グラフ, オントロジー, リンクトデータ, 人工知能

Abstract There are two main approaches to the development of AI systems: data-driven approaches primarily using machine learning and knowledge-based approaches using knowledge processing technologies. In knowledge-based AI, various knowledge graphs are developed and used as core technologies. A knowledge graph represents connections between various pieces of knowledge in a network-like graph structure, and technologies such as Linked Data and ontologies are widely used for its publication and utilization. In this paper, the foundational technologies involved in the development of AI systems using knowledge graphs are explained.

Key words Knowledge graph, Ontology, Lined data, Artificial intelligence

1. はじめに

Web での情報資源の公開方法として、個々のデータに Web ページの URL (Uniform Resource Locator) と同様なユニークなアドレスである IRI (Internationalized Resource Identifier) を付与し、それらを相互にリンクした Linked Data として公開する取り組みが 2000 年代の後半から盛んとなった。Linked Data はデータのつながりをグラフ構造で表し、データの意味を扱う Semantic Web (セマンティック Web) 技術に基づく情報検索が行える。そのため Linked Data は、知識の相互関係をグラフ構造で表した知識グラフ (ナレッジグラフ) を Web 上で公開する技術としても位置づけられる。知識グラフの構築は、2012 年にサービスが公開された Google Knowledge Graph をはじめとして、様々な機関・プロジェクトで進められており、知識処理を用いたアプローチによる人工知能技術においては知識グラフの活用が中核技術の一つとして用いられている。本稿では、これらの知識グラフを用いた AI システムの開発に関わる基盤技術

を、具体事例を示しながら概説する。

以下、2 章では知識グラフを公開する技術について Linked Data を中心に解説し、続く 3 章では公開された知識グラフを活用するための技術を解説する。4 章では様々な分野における構築・公開されている知識グラフの事例を紹介し、5 章では知識グラフの活用事例について示したのち、6 章で本解説全体の総括と今後の展望を述べる。

2. 知識グラフと Linked Data

2.1 知識グラフ

様々な「知識」の関係 (つながり) をグラフ構造で表したものを知識グラフ (ナレッジグラフ) とよび、知的システム開発の基盤となるデータベース (知識ベース) として用いる。図 1 に「本解説論文に関する知識」を表現した知識グラフの例を示す。知識グラフは、事物や事象などのエンティティ (entity) 間の関係をグラフ構造で表現する。この例では、本解説論文^(注1)、そのタイトル、FR 雑誌、解説論文、電子情報通信学会、古崎…などをエンティティとし、それらの間にある題名、掲載雑誌、論文種別、出版元、著者といった関係を表現している。このグラフ構造により、論文の基本

古崎晃司 正員 大阪電気通信大学情報通信工学部情報工学科
E-mail kozaki@osakac.ac.jp
Kouji Kozaki, Member (Department of Engineering Informatics, Faculty of Information and Communication Engineering, Osaka Electro-Communication University, Japan).
電子情報通信学会 基礎・境界ソサイエティ
Fundamentals Review Vol.18 No.2 pp.123-136 2024 年 10 月
©電子情報通信学会 2024

(注 1): ここでは本解説記事を「FR-2024-xxx」という仮想の ID で表しているが、本来は DOI など一意に管理された ID を用いて表すことが好ましい。

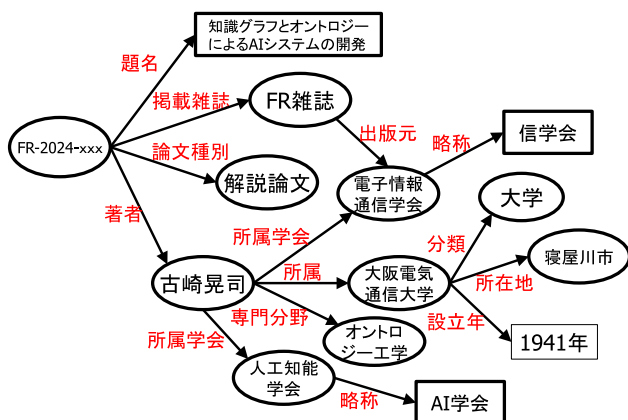
情報に加え、著者である「古崎」、古崎が所属する「大阪電気通信大学」などを含めた知識の関係性が表現されている。このようなグラフ構造を用いることで、様々な知識を柔軟に表現することができる。

グラフ構造を用いた知識の表現は、人工知能においては知識表現の分野において意味ネットワークという技術として1960年代から用いられている。その後、Webの普及に伴いWeb上で文書やデータ公開が盛んに行われるようになると、Web上で公開された文書やデータの意味をコンピュータで扱えるようにしたいというニーズが高まる。そのニーズに答えるものとして、1990年代にはWeb上で知識の意味を表現するSematic Web技術が提唱され、関連する技術の標準化が進められた⁽¹⁾。Sematic WebではRDF (Resource Description Framework)⁽²⁾と呼ばれるグラフ構造を表現するデータモデルを用いて知識を記述し、Web上で公開することができる。

2000年代後半になり、Sematic Webの技術を用いてデータを相互にリンクした形でWebコンテンツとして公開するLinked Dataの取り組みが広がった。Linked DataはWeb上で公開されている様々なデータを相互にリンクすることで、Web全体を一つのグローバルな知識ベースとして利用できるようにすることを目指している⁽³⁾。なかでも、Linked Dataを誰でも利用可能なオープンデータとして公開したものはLinked Open Data (LOD)と呼ばれ、オープンな知識グラフとして利用できる。

更に2012年にはGoogleがグラフ構造を用いて表した知識を検索に利用するGoogle Knowledge Graphというサービスを開始した。その後から、学術・研究機関、研究プロジェクト、企業など、様々な組織において、知識グラフの構築や公開が盛んに行われるようになった。

本章では、これらの知識グラフについて、グラフ構造を用いた知識の表現方法を中心に解説する。



この図では、エンティティは楕円、名称などを示す文字列は長方形で表している。

図1 知識グラフによる論文に関する知識の表現例 「本解説論文に関する知識」を表現した知識グラフの例。論文の基本情報に加え、著者である「古崎」が所属する「大阪電気通信大学」などを含めた知識の関係性が表現されている。

2.2 Google ナレッジグラフ

2012年にGoogleがサービスを開始したGoogle Knowledge Graphでは、Googleが提供するWeb検索に、Googleが構築した知識グラフが利用されている。Google Knowledge Graphでは、知識グラフは検索に用いられるキーワードを「文字列 (string)」ではなく、実社会における関係性を表した「もの (thing)」として扱うことで、より適切な検索結果を得ることに貢献するとしている⁽⁴⁾。具体的には、

1. Find the right thing (正しい「もの」を見つける)
2. Get the best summary (最適な概要を得る)
3. Go deeper and broader (より深く広い結果に到達す)

The screenshot shows the Google Knowledge Panel for '大阪電気通信大学' (Osaka Institute of Technology). The panel includes:

- ウェブサイト** (Website): 寝屋川市の私立大学 (Private University of Neyagawa City)
- 分類** (Classification): 大阪電気通信大学は、大阪府寝屋川市初町18-8に本部を置く日本の私立大学。1941年創立、1961年大学設置。大学の略称は大阪電通大、阪電通大、大電大、OECU。 [ウィキペディア](#)
- 所在地** (Location): 〒572-0833 大阪府寝屋川市初町18-8
- 在籍者数** (Enrollment): 5,887 (2023年5月1日)
- 設立** (Established): 1941年4月
- 社長** (President): 大石利光
- 電話番号** (Phone Number): 072-824-1131
- 営業時間** (Business Hours): 営業時間外・営業開始: 9:00
- 学校種別** (School Type): 私立
- 設置者** (Operator): 学校法人大阪電気通信大学
- 属性** (Attributes): A yellow box highlighting the above information.
- 情報の修正を提案** (Suggest an edit): このビジネスのオーナーですか?
- 著名な卒業生** (Famous Alumni): 他 10 件以上を表示
 - マサユキ・カワグチ
 - 速水けんたろう
 - 岡田斗司夫
 - 松尾一
- 他の知識との関係** (Other relationships): A red box highlighting the 'Famous Alumni' section.

図2 Google 検索結果の右側の「ナレッジパネル」に表示されるGoogle Knowledge Graphの内容の例 「大阪電気通信大学」を検索した際に表示されたナレッジパネルの例。ここでは、分類が「寝屋川市の私立大学」であることや、「所在地」や「在籍者数」などの属性、「著名な卒業生」といったほかの知識との関係などが表示されている。

る)

といった手法に知識グラフが利用することが想定されている。

現在の Google 検索においては、図 2 に示すように、Google 検索結果の右側の「ナレッジパネル」と呼ばれる部分に Google Knowledge Graph から得られた内容の一部が表示される。この例では、「大阪電気通信大学」を検索した際に表示されたナレッジパネルを示している。ここでは、分類が「寝屋川市の私立大学」であることや、エンティティの性質を表す属性に相当する関係である所在地や在籍者数、ほかのエンティティとの関係として「著名な卒業生」などが表示されている。これらで表示されたエンティティをクリックすることで関連する知識を確認することができる。

なお Google Knowledge Graph の内容を取得する知識グラフ検索用の API も提供されている⁽⁵⁾。ただし、この API で取得できるのは個別のエンティティに関するデータに限られており、エンティティ間の相互関係を取得するには、Wikidata (詳細は 4.1 節参照) など、LOD として公開されている知識グラフを使用することが望ましい。

2.3 Linked Data における RDF による知識グラフの表現

2.1 節で述べたように、知識グラフを Linked Data として作成・公開するは RDF を用いて表現する。図 3 に RDF を用いた知識グラフの例として、Wikidata における「大阪電気通信大学」に関する知識の一部を示したものである。RDF では、全てのデータを「主語 (subject)-述語 (predicate)-目的語 (object)」の三つ組 (トリプル, triple) で表現する。図の例では、「大阪電気通信大学 (主語)-位置する行政区画 (述語)-寝屋川市 (目的語)」や「大阪電気通信大学 (主語)-分類 (述語)-大学 (目的語)」、「大阪電気通信大学 (主語)-設立日 (述語)-1941 年 (目的語)」といったトリプルにより、大阪電気通信大学に関する知識が表現されている。

RDF において主語及び目的語となるデータには、リソー

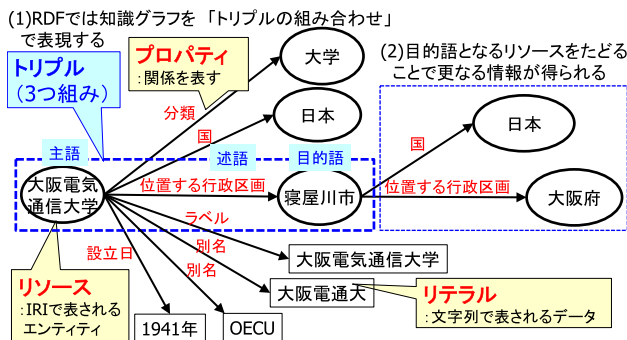


図 3 Wikidata における RDF データの例 Wikidata における「大阪電気通信大学」に関する知識の一部を RDF を用いた知識グラフとして示した例。

スと呼ばれる IRI で表される事物及び文字列を表すリテラルの 2 種類がある。図 3 ではリソースをだ円、リテラルを長方形で表し、それらの間の関係を矢印で結ぶことで、主語-述語-目的語のトリプルを表している。

各トリプルの主語にはリソースのみが、目的語にはリソースとリテラルがともに利用できる。目的語にリソースが用いられている場合は、図 3 における「寝屋川市 (主語)-位置する行政区画 (述語)-大阪府 (目的語)」のようにトリプルをたどって関連する情報を得ることができる。この例では、大阪電気通信大学が寝屋川市にあり、寝屋川市は大阪府にあることから、同大学が大阪府にある、といった情報を導出することができる。一方、目的語がリテラルとなる例としては、「大阪電気通信大学」といった名称を表すラベル、「大阪電通大」や「OECU」といった別名などの自然言語で記載された文字列 (日本語 (ja), 英語 (en) など、リテラルの「言語種別」を指定することもできる)、「1941 年」のような型 (この例では「年月日」) を指定して表されるデータなどがある。

また、RDF における述語はプロパティと呼ばれ、プロパティも IRI により表現される。よって全ての RDF データは、図 4(1)のようにリソースとプロパティを表す IRI とリテラルの組み合わせで表現される。RDF データを処理する際には、これらの IRI が特定のデータ内に限定しないグローバルな ID として、異なる情報源として公開されたデータ間をつなぐ役割を果たす。なお、図 4(2)のように接頭語 (PREFIX) を指定することで IRI の省略表現を用いることもできる。接頭語には任意の文字列を指定することができるが、公開されているデータセットごとに標準的に使用される接頭語を用いることが多く、代表的な接頭語について検索できるサイトも公開されている⁽⁶⁾。

2.4 知識グラフとオントロジー

知識グラフとして表現された知識の意味を明確にし、適切に使用するためには、知識の表現方法を統一することが重要となる。RDF による知識グラフはリソースとプロパティを用いたトリプルで表現されるため、使用するリソースとプロパティの種類を指定することで表現方法が統一される。例えばリソースの名称を表すラベルには `rdfs:label`^(注2) や `schema:name`^(注3)、リソースの分類を表すには `rdf:type`^(注4) が用いられることが多い。

このように知識グラフの表現方法を規定するにはオントロジー (ontology) が用いられる。オントロジーとは哲学における「存在論」を意味するが、人工知能分野では「概念化の明示的記述 (an explicit specification of conceptualization)」⁽⁷⁾ や「人間が対象世界をどのように見ているかを、コンピュー

(注 2) : <http://www.w3.org/2000/01/rdf-schema#label>

(注 3) : <http://schema.org/name>

(注 4) : <http://www.w3.org/1999/02/22-rdf-syntax-ns#type>

(1) RDFにおけるすべてのリソースとプロパティは、IRIを用いて表現される。



(2) 接頭語(PREFIX)を指定することでIRIの省略表現が行える。

接頭語(PREFIX)の指定

```
@prefix wd: <http://www.wikidata.org/entity/>
@prefix wdt: <http://www.wikidata.org/prop/direct/>
@prefix rdfs: < http://www.w3.org/2000/01/rdf-schema#>
```




図4 RDFデータのIRIによる表現

クラス階層

- 組織
 - 教育組織
 - 教育機関
 - 大学
 - 国立大学
 - 私立大学
 - 公立大学
- ...

プロパティ階層

- 場所
 - 位置する行政区画
 - 国
 - 本拠地
 - 出生地
 - 死没地
 - ...

図5 Wikidataにおけるオントロジーの階層例 図3で示したRDF表現においてリソースの分類として用いられている「大学」のクラス階層と、プロパティとして用いられている「位置する行政区画」階層の一部を示したオントロジーの階層例。

タと人間が理解を共有できるように書き記したもの⁽⁸⁾と定義される。知識グラフにおけるオントロジーは、表現に用いる語彙を定義し、表現されるグラフの構造を規定する役割を果たす。

RDFの表現を規定するオントロジーでは、リソースの分類を表すクラス階層、プロパティの種類を表すプロパティ階層、それらを用いて表されるトリプルの構造を規定する制約などが定義される。図5にWikidataにおけるオントロジーの階層の定義例を示す。この例では、図3で示したRDF表現においてリソースの分類として用いられている「大学」のクラス階層と、プロパティとして用いられている「位置する行政区画」階層の一部を示している。このような用いることができる語彙の種類を表す階層に加え、「分類が大学となるリソースが『主語』となるときに『述語』として用いることができるプロパティの種類」や「位置する行政区画が『述

語』となるときに『主語』や『目的語』に用いることができるリソースの種類」など、知識グラフの構造に関する制約もオントロジーで定義される。

オントロジーを記述する際に用いられる言語には様々なものが提案されているが、RDFデータに用いる語彙や制約を定義するためのオントロジー記述言語としては、RDFS (RDF Schema)⁽⁹⁾及びOWL (Web Ontology Language)⁽¹⁰⁾が主に利用される。RDFSではクラス及びプロパティの階層、及びプロパティの主語/目的語と用いることができるリソースの種類といった基本的な語彙が定義される。それに対しOWLでは、各リソースが述語としてもつプロパティに関する制約、プロパティの推移律(例:「子孫の子孫」は「子孫」)など、より詳細な制約を述語論理に基づいて定義することができる。

オントロジーの記述に用いるツールについては、代表的なものにスタンフォード大学で開発されたProtégé⁽¹¹⁾や、筆者らが開発した法造⁽¹²⁾がある。ProtégéはOWLやRDFなどのW3C標準への準拠や様々なプラグインによる拡張が可能な点の特徴としており、多くのコミュニティで利用されている。一方、法造はロール概念を中心とするオントロジー理論⁽¹³⁾に基づいて開発されている点と、独自のグラフィカル表現を用いている点が特徴で、国内を中心に様々なプロジェクトで利用されている。

3. 知識グラフを活用する技術

RDFで表現されLinked DataやLODとしてデータとして公開された知識グラフは、様々な方法で活用できる。活用のために利用できる主な手法は、1) IRIを用いたRDFデータへのアクセス、2) SPARQLクエリを用いたAPIからの検

索, 3) ダウンロードした RDF ファイルの直接利用, に大別できる。ただし, Linked Data として公開されている全ての知識グラフがこれらの利用方法に対応しているわけではないため, 各データの公開サイトなどで公開方法の詳細を確認する必要がある。

以下では 2.3 節で示した Wikidata における RDF データを例として, それぞれの手法について解説する。

3.1 IRI による RDF データへのアクセス

2.3 節で述べたように, RDF において各データ (リソース) は IRI を一意の ID としてもつ。この IRI を用いることで, 該当するデータにアクセスすることができる。例えば Wikidata において, 大阪電気通信大学は「<http://www.wikidata.org/entity/Q7105556>」という IRI により表されている。この IRI に Web ブラウザでアクセスすると, Wikidata に格納されている大阪電気通信大学の情報が図 6 のように Web ページとして表示される (表示する言語は, アカウントを作成してログインすることで切り替えが可能となる)。このページでは, 上部に「主語」となるリソースの名称が概要説明とともに表示され, その下の「文 (statement)」と書かれた箇所に大阪電気通信大学を「主語」とする「述語-目的語」の組み合わせが表示される。



図 6 Web ページとしての Wikidata のデータ表示例 大阪電気通信大学の Wikidata (<http://www.wikidata.org/entity/Q7105556>) を Web ブラウザで表示した例。名称, 概要説明, および, 大阪電気通信大学を「主語」とする「述語-目的語」の組み合わせが表示される。

的語」の組み合わせが表示される。目的語がリソースの場合は, リンクをたどることでそのリソースの情報を表示するページに移動できる。

更に IRI に加え取得するデータの形式を指定することで, 任意の形式で RDF データを取得することができる。Web ブラウザを用いる場合, 例えば「<http://www.wikidata.org/entity/Q7105556.ttl>」のように, IRI の末尾に「ttl」という拡張子を付与してアクセスすると, RDF の代表的な記述形式である Turtle 形式でデータを取得できる。Wikidata では, Turtle 形式のほかに, RDF/XML (rdf), N-Triple (nt), JSON (json), JSON-LD (jsonld) などの形式で RDF データを取得できる (カッコ内は付与する拡張子を示す)。

なお, IRI を用いた RDF データへのアクセスは, 技術的には通常の http 通信による Web サーバへのアクセスと同様に, レスポンスヘッダで応答する形式を指定することで実現されている。

3.2 SPARQL クエリによる RDF データの検索

Linked Data として公開されている RDF は, Web 経由での検索が可能な API を提供している場合が多い。RDF データの検索には SPARQL というクエリ言語が用いられ, SPARQL による検索に対応した API は SPARQL エンドポイントと呼ばれる。Wikidata では Web ブラウザ上で SPARQL クエリを入力し, 検索結果を可視化できる検索サービス^(注5)と, プログラムから検索結果を直接取得する用の SPARQL エンドポイント^(注6)を提供している。

SPARQL クエリでは, RDF で表現されたデータから「指定したグラフ構造に一致する部分」を検索する。2.3 節で述べたように, RDF においてグラフ構造はトリプルで表現されるため, 検索に用いるグラフ構造もトリプルの形で指定する。図 7~9 に Wikidata を対象とした SPARQL クエリの例を示す。SPARQL では, ?o, ?s など「?」から始まる任意の文字列は変数を表す。検索条件は where{} で囲まれた部分に「検索の対象とするグラフ構造」を記述し, select の後に結果として取得する変数の一覧を記述する。

3.2.1 「主語-述語」の組み合わせを指定したクエリ

図 7(1)に「主語と述語の組み合わせを指定してトリプルを検索し, その目的語を取得する」クエリの例を示す。検索条件は「主語-述語-目的語」の組み合わせを 1 行ごとにピリオド (.) で区切って記述する。その際, リソースとプロパティは IRI で記述する。この例では, 検索条件として指定された「**主語: 大阪電気通信大学 (Q7105556)**」の「**述語: 位置する行政区画 (P131)**」という組み合わせと一致する部分が Wikidata から検索され, 図 3, 4 で示した該当箇所が見つかり, その目的語 (?o) となる「寝屋川市」が

(注 5) : <https://query.wikidata.org/>

(注 6) : <https://query.wikidata.org/sparql>

```

(1) <主語>-<述語>を指定して<目的語>を取得する
例) <主語:大阪電気通信大学(Q7105556)>の<述語:位置する行政区画(P131)>の目的語(?o)
    を取得する

select ?o
where{
  <http://www.wikidata.org/entity/Q7105556> <http://www.wikidata.org/prop/direct/P131> ?o .
}

(1)' PREFIX (接頭語) を用いた表現
(1)のSPARQLクエリをPREFIXを用いて表現した例

PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>

select ?o
where{
  wd:Q7105556  wdt:P131  ?o .
}

(2) 複数の<主語>-<述語>を指定して、それぞれの<目的語>を取得する
例) <主語:大阪電気通信大学(Q7105556)>の<述語:位置する行政区画(P131)>の目的語(?o)
    および<述語:設立日(P571)>の目的語(?o2)を取得する

PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>

select ?o ?o2
where{
  wd:Q7105556  wdt:P131  ?o .
  wd:Q7105556  wdt:P571  ?o2 .
}

(3) <主語>を指定して<述語>-<目的語>を取得する
例) <大阪電気通信大学(Q7105556)>を主語とする述語(?p)-目的語

PREFIX wd: <http://www.wikidata.org/entity/>

select ?p ?o
where{
  wd:Q7105556  ?p  ?o .
}

```

図7 基本的な SPARQL クエリの例 「主語-述語」を指定.

取得される。なお SPARQL クエリも PREFIX (接頭語) を用いた省略表現による記述に対応しており、(1)のクエリは PREFIX を用いて(1)'のように記述することもできる。以降の例では、PREFIX を用いた省略表現によるクエリを示して説明する。

図7(2)の例では(1)の条件に加えて「<主語:大阪電気通信大学(Q7105556)>の<述語:設立日(P571)>」の目的語(?o2)が取得される。この例のように検索条件とするトリプルを複数指定すると AND 条件として検索される。また図7(3)の例のように、「主語」のみを指定して「述語(?p)-目的語(?o)」を変数とすると、指定したリソース(この例では<大阪電気通信大学(Q7105556)>)を主語とする「述語(?p)-目的語(?o)」の組を全て取得することができる。

3.2.2 「述語-目的語」の組み合わせを指定したクエリ

図8(4)に「述語と目的語の組み合わせを指定してトリプルを検索し、その主語を取得する」クエリの例を示す。この例では「<述語:位置する行政区画(P131)>が<目的語:寝屋川市(Q389633)>」となる主語(?s)を取得する。これにより Wikidata 内で「寝屋川市にある施設な

ど」の一覧を得ることができる。このような「述語-目的語」の組み合わせを用いたクエリにおいては「<述語:分類(P31)>-<目的語:大学(Q3918)>」のように、任意の分類を指定したデータ一覧を取得するクエリがよく利用される。

更に図8(5)のように「述語-目的語」を指定して得た「主語」に対して「主語-述語」の指定と組み合わせることで、その「目的語」をともに取得することができる。この例では、「<述語:分類(P31)>が<目的語:大学(Q3918)>」となる主語(?s)を、「その主語(?s)の<述語:国(P17)>」の目的語(?country)とともに取得する。すなわち Wikidata 内から「大学の一覧をその国とともに取得する」ことができる。

このようにグラフ構造の一致条件を組み合わせることで、様々な条件の検索を行うこともできる。例えば、図8(6)では、検索結果の集約(グループ化)とカウントを利用して、ランキングを取得するクエリの例を示す。このクエリでは、検索条件として指定するトリプルを複数組み合わせ得た結果を、集約(グループ化)した後、それぞれのグループに含まれるデータの数をカウントすることで簡単なランキングを取得する。このクエリ例では、Wikidata 内に登録されてい

```

(4) <述語>-<目的語>を指定して<主語>を取得する
例) <述語:位置する行政区画(P131)>が<目的語:寝屋川市(Q389633)>となる主語(?s)を
取得する
PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>

select ?s
where{
  ?s wdt:P131 wd:Q389633 .
}

(5) <述語>-<目的語>を指定した<主語>を、その<目的語>と共に取得する
例) <述語:分類(P31)>が<目的語:大学(Q3918)>となる主語(?s)を、
その(?s)の<述語:国(P17)>の目的語(?country)と共に取得する。
PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>

select ?s ?country
where{
  ?s wdt:P31 wd:Q3918 .
  ?s wdt:P17 ?country .
}

(6) 集約（グループ化）とカウントを利用したランキング
例) (5)のクエリで取得した結果を目的語(?country)が同一のもので集約(グループ化)し、
それぞれのグループに含まれる主語(?s)の数をカウントし?cに代入して取得する。
その結果として「国ごとの大学の数のランキング」を取得できる。
PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>

select ?country (count(?s) AS ?c)
where{
  ?s wdt:P31 wd:Q3918 .
  ?s wdt:P17 ?country .
} GROUP BY ?country
ORDER BY DESC(?c)

```

図8 基本的な SPARQL クエリの例 「述語-目的語」を指定。

る「国ごとの大学の数のランキング」が得られる。

3.2.3 ラベル（名称）を取得するクエリ

図7, 8で示した SPARQL クエリの例では、いずれも結果として取得されるデータが図4で示したような IRI として得られるため、人間には意味を理解しづらい。そこで結果として得られるデータに対して「主語-名称(述語)-目的語」となるトリプルを検索すると、そのリソースが表す事物の「名称」が得られる。Wikidata においては、名称を表す述語として、`rdfs:label` や `schema:name` などが用いられているので、これらを検索条件に付加すると図9のようなクエリとなる。なお、Wikidata では各リソースに対して複数の言語のラベルが得られるため、得られたラベルの言語情報を `lang(?lbl)` という関数で取得し、その結果が日本語(“ja”)となるものに絞込むという条件を `FILTER` により指定している。

3.2.4 SPARQL クエリに関する情報源

上述のように SPARQL クエリを用いることで、RDF で記述された知識グラフから指定したグラフ構造に一致する部分を検索することができる。本稿では基本的な SPARQL ク

エリのみについて示したが、より詳細な使い方については、W3C によって公開されている仕様書⁽¹⁴⁾や SPARQL の使用法を解説した書籍⁽¹⁵⁾を参照されたい。

なお SPARQL クエリによる検索結果として取得できるデータ形式については対象とする知識グラフが公開している SPARQL エンドポイントによって異なるが、多くの場合は JSON, XML, CSV などが指定できる。

3.3 RDF ファイルの直接利用

3.1 及び 3.2 節で述べた IRI によるアクセスや SPARQL クエリを用いた検索は、RDF として公開されている知識グラフから必要な部分のみを抽出する際に適している。一方、知識グラフの全体を取得したい場合にはこれらの手法は効率が悪いので、RDF ファイルをダウンロードして直接利用できるように公開されている場合がある。

RDF ファイルの公開の有無や、公開されている RDF のデータ形式は知識グラフによって異なる。例えば Wikidata では全データの RDF ファイルが N-Triples 形式⁽¹⁶⁾及び Turtle 形式⁽¹⁷⁾で公開されている⁽¹⁸⁾。図10にそれぞれの形式で図4の RDF データを記述した例を示す。N-Triples 形式で

```

(1)+ ラベルを取得する
(1)のクエリの目的語(?o)を日本語ラベル(?lbl)と共に取得する
PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>

select ?o ?lbl
where{
  wd:Q7105556 wdt:P131 ?o .
  ?o rdfs:label ?lbl .
  FILTER(lang(?lbl) = "ja")
}

(6)+ 集約（グループ化）とカウントを利用したランキング
(6)のクエリランキングを国(?country)の日本語ラベルと共に取得する
PREFIX wd: <http://www.wikidata.org/entity/>
PREFIX wdt: <http://www.wikidata.org/prop/direct/>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>

select ?country ?lbl (count(?s) AS ?c)
where{
  ?s wdt:P31 wd:Q3918 .
  ?s wdt:P17 ?country .
  ?country rdfs:label ?lbl .
  FILTER(lang(?lbl) = "ja")
} GROUP BY ?country ?lbl
ORDER BY DESC(?c)

```

図9 日本語ラベルを合わせて取得する SPARQL クエリの例

```

(1) N-Triplesによる表現
<http://www.wikidata.org/entity/Q7105556>
<http://www.wikidata.org/prop/direct/P131> <http://www.wikidata.org/entity/Q389633> .
<http://www.wikidata.org/entity/Q7105556>
<http://www.w3.org/2000/01/rdf-schema#label> "大阪電気通信大学"@ja .
※注：上記の例では紙面の都合で行の途中で改行をしているが、「<主語><述語><目的語>」の1トリプルを1行で表現する。

(2) Turtleによる表現
@PREFIX wd: <http://www.wikidata.org/entity/>
@PREFIX wdt: <http://www.wikidata.org/prop/direct/>
@PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
wd:Q7105556 wdt:P131 wd:Q389633 .
wd:Q7105556 rdfs:label "大阪電気通信大学"@ja .

(3) Turtleによる表現(主語の省略表現を使用した場合)
@PREFIX wd: <http://www.wikidata.org/entity/>
@PREFIX wdt: <http://www.wikidata.org/prop/direct/>
@PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
wd:Q7105556 wdt:P131 wd:Q389633 ;
rdfs:label "大阪電気通信大学"@ja .

```

図10 図4の RDF データを N-Triples および Turtle 形式で記述した例

は1行ごと一つのトリプルを「<主語> <述語> <目的語>」の順に IRI で記述する (図10(1)) というシンプルな表現で記述される。それに対し、Turtle 形式では PREFIX (接頭語) の使用や主語が同一のトリプルの省略表現など、人間が見ても理解しやすい表現となっている (図10(2), (3))。そのほか、RDF データの表現によく用いられる形式としては、XML 形式⁽¹⁹⁾、JSON-LD 形式⁽²⁰⁾などがある。

これらの RDF ファイルを直接利用するためには、RDF データの内容を直接解析するプログラムを用意する方法や、次項で紹介するツール類を使用する方法がある。直接解析する際には、1行で一つのトリプルを表現するというシンプル

な形式である N-Triple 形式が利用しやすい。

3.4 RDF を利用するためのツール類

上述のような RDF の利用技術を効率的に活用するため、様々なツール類が開発・公開されている。RDF データを処理するためのライブラリは各種プログラム言語ごとに開発されており、主要なものには Java で開発された Apache Jena⁽²¹⁾や Python で開発された RDFLib⁽²²⁾などがある。これらのライブラリは、各種形式の RDF データの読み込み、RDF データの追加・削除・検索などの操作、SPARQL エン

ドポイントへの問い合わせなど、RDF データの処理に必要な各種機能を提供している。

また RDF データを格納するデータベースも多く開発・公開されている。RDF データベースはトリプルストア (triplestore) と呼ばれ、Apache Jena Fuseki⁽²³⁾ や Virtuoso Open-Source Edition⁽²⁴⁾ などのオープンソースソフトウェアに加え、商用の RDF データベースも多く開発されている。

4. 知識グラフの構築・公開事例

2000 年代後半より、多くの知識グラフが Web 上で LOD として公開されている。その多くは、3 章で述べた技術を利用することで、オープンなナレッジグラフとして活用できる。図 11 に代表的な LOD の公開状況や相互のつながりを示す LOD クラウド (The Linked Open Data Cloud) を示す⁽²⁵⁾。この LOD クラウドでは、LOD として公開されているデータセットを丸いノードで表し、それらのノード間をつなぐ線 (リンク) でデータセット間がつながりをもっていることを表している。2007 年に公開された初版では 12 であったデータセットの数が、現時点で最新の 2023 年 9 月 3 日版では 1,314 まで増加し、それらの間のリンクは 16,308 となっている。図 11 の凡例 (legend) に示されているようにデータセットが対象とする領域も多岐にわたっており、約 15 年間で多くの知識グラフが LOD として公開されている様子がうかがえる。なお、LOD クラウドの元データは、一定の掲載基準を満たしたデータセットの情報を登録することで管理されているため、LOD クラウドで Web 上の全ての LOD を網羅しているわけではなく、これ以外にも様々なデータセットが LOD として公開されている。

ここでは、国内で LOD として公開されているデータセットを中心に、比較的大規模で様々な用途での活用が期待される知識グラフについて紹介する。

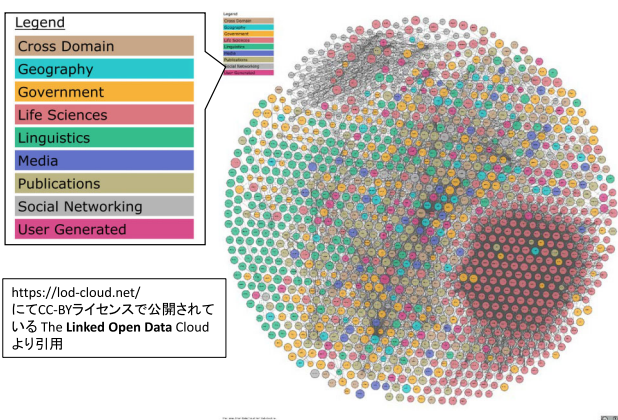


図 11 代表的な LOD の公開状況や相互のつながりを示す LOD クラウド (The Linked Open Data Cloud) この LOD クラウドでは、LOD として公開されているデータセットを丸いノードで表し、それらのノード間をつなぐ線 (リンク) でデータセット間がつながりを表している。

4.1 Wikidata

Wikidata (ウィキデータ^(注7))はウィキペディアを運営しているウィキメディア財団が提供している共同編集型の知識ベースである⁽²⁶⁾。Wikidata は誰でも編集・利用が可能なフリーのライセンスで公開されており、2024 年 4 月時点で 1 億件以上の項目をもつ。これらのデータは Wikibase というシステムを用いて公開されており、RDF データについては、SPARQL による検索が可能なクエリサービスの提供を含め 3 章で述べた 3 種類の活用技術の全てに対応している。なお Wikidata が提供しているクエリサービスでは、通常の SPARQL クエリに加えて、ラベルの扱いなど利便性を高めるための拡張したクエリ記述に対応している。また、クエリ結果の可視化やほかの Web サイトへ埋め込む機能なども提供している。

Wikidata では、Wikipedia と同様に誰でも編集が可能ではあるが、データ記述に用いる語彙がシステム上で統制されているため、各データのグラフ構造のばらつきが少なく、統一的な検索が行いやすい。データの項目数が多く、多言語によるラベルや Wikipedia との対応、外部のデータベースとのリンクなども充実していることから、オープンかつ大規模な知識グラフとして利用しやすい。

4.2 DBpedia

DBpedia (ディービーペディア)^(注8)は Wikipedia の情報をもとに構築された LOD で、LOD の構築・公開が始まった初期より様々なデータセットをつなぐハブとしての役割を果たしてきた⁽²⁷⁾。Wikidata が Wikipedia のシステムと直接的に連携されてデータの構築・管理が行われているのに対し、DBpedia は Wikipedia のデータをもとに各種変換用のプログラムを利用して半自動的に生成されている。具体的には、Wikipedia の記述に用いるテンプレートごとに RDF に変換するための対応関係を記載したマッピング情報をコミュニティの共同編集で用意している⁽²⁸⁾。また DBpedia におけるデータの分類を表現するために、DBpedia Ontology (DBO) と呼ばれるオントロジーが用いられている。

DBpedia の構築に使用されるマッピング情報の記載は Wikipedia の記事に依存するため、DBpedia では RDF データの記述に用いる語彙 (述語) の種類や数が Wikidata に比べて多く、その分、データの内容のばらつきが大きい。一方、Wikidata はそのデータ入力・管理のシステムにおいてデータ入力の統制を行う仕組みを導入することで、DBpedia よりも統一性が取れたデータが提供される。よって、これらを知識グラフとして活用する際には、双方のデータ特徴を踏まえ、必要に応じて使い分けることが好ましい。

(注 7) : <https://www.wikidata.org/>

(注 8) : <https://dbpedia.org/>

4.3 RDF Portal

生命科学分野における研究では疾患・健康、生物種、細胞、遺伝子、タンパク質など、多種多様なデータが用いられる。しかも、それぞれのデータの規模が膨大で単一の機関で全てをカバーすることは難しく、公共のデータベースを構築してデータを共有することが重要となる。そのため、多くのデータベースが公開されるとともに、それらの相互連携を実現するためのオントロジーや LOD の整備が進められており、LOD クラウドには約 370 の生命科学分野のデータセットが掲載されている。

国内では RDF 形式の生命科学データを集積したポータルサイトである RDF Portal^(注9)が公開されている⁽²⁹⁾。RDF Portal は、国内外の様々な研究機関が提供している生命科学分野の RDF データを網羅的に収集することを目的として開発・運用されている。2024 年 4 月時点で 40 のデータセットが公開されており、RDF データのダウンロードや SPARQL も用いた検索が行える。各データセットの統計情報やデータセット間の関係性の可視化、掲載する RDF データのガイドラインに基づくレビューの仕組みなど、様々な RDF データを統合し有効活用するための基盤としての完成度が高く、オープンな知識グラフ公開のベストプラクティスと位置付けることができる。

4.4 e-STAT 統計 LOD

政府統計の総合窓口 (e-Stat) では、各府省が公表する統計データを一元的にまとめ、検索、ダウンロード、可視化などができる機能が提供されている。これらの統計データの活用的高度化を目的として、統計データを LOD として提供する e-Stat 統計 LOD が 2016 年から公開されている。e-Stat 統計 LOD^(注10)では、日本政府の統計情報の一部を RDF に変換した LOD として提供しており、SPARQL クエリにより検索が行える⁽³⁰⁾。

統計データを RDF 化する方法としては、RDF データキューブ (RDF Data Cube Vocabulary)⁽³¹⁾を用いており、各統計表のセルに IRI を与え、そのセルに対応する IRI を主語とするトリプルで統計データを表現している。統計表のような表形式のデータと、関係を中心に表現するグラフ構造のデータの相互変換は、知識グラフを構築する上で重要な技術であるが、統計 LOD は表形式のデータを知識グラフで表す具体例として参考になる。

4.5 国立国会図書館の LOD

国立国会図書館では、保有しているメタデータの一部をほかのシステムなどから利用できるように LOD として公開^(注11)している⁽³²⁾。公開されている主な LOD には、本、雑

誌、記事論文、新聞、デジタルコンテンツなどの「書誌データ (国立国会図書館サーチ: NDL サーチ)」及び、著者名やテーマ (主題) を表すことばについて、同義語・関連語などを集めた「典拠データ (国立国会図書館典拠データ検索・提供サービス: Web NDL Authorities)」がある。後者の Web NDL Authorities については、SPARQL エンドポイントも提供されている。

また、美術館 (Galleries)、図書館 (Libraries)、文書館 (Archives)、博物館 (Museums) の頭文字を合わせて GLAM と呼ばれるデータに関する LOD を公開するジャパンサーチ (詳細は次節で述べる) というサービスも、国立国会図書館が運営している。

4.6 ジャパンサーチ

ジャパンサーチ^(注12)は、日本国内の様々な機関が公開しているデジタルアーカイブのメタデータを横断して検索することができるサービスを提供している。その目的としては、様々な分野・地域の多様なコンテンツをまとめて検索できるようにすることで所在を明らかにし、デジタル情報資源が効率的に発見され有効活用されること目指している。

ジャパンサーチでは 2024 年 4 月時点で、148 の連携機関から提供された 241 のデータベースに含まれる約 3,000 万件のデータが検索できる。その際、複数のデータベースを横断した利活用を促進するために、それぞれのデータベースが提供する様々な形式のメタデータを、RDF による共通の形式のデータに変換している⁽³³⁾。これらのデータは Web サイト上での横断検索に加え、SPARQL を用いた検索が可能な API が提供されている。

4.7 メディア芸術データベース

メディア芸術データベース^(注13)は、国内におけるマンガ、アニメーション、ゲーム、メディアアートの作品情報や所蔵情報を整備したデータベースである。文化庁による事業で整備されたものを、2023 年より (独行) 国立美術館国立アトリサーチセンターが引き継いで運営し、2024 年 1 月より正式公開された。メディア芸術へのアクセスや保存、利活用の要となるデータを提供することを目的としており、横断検索に加えて SPARQL エンドポイントが提供されている。更に、このデータベースを活用するための技術情報をまとめたメディア芸術データベース・ラボ^(注14)が公開されており、RDF データのダウンロードも可能である。

(注 11) : <https://www.ndl.go.jp/jp/dlib/standards/iod/>

(注 12) : <https://jpsearch.go.jp/>

(注 13) : <https://mediaarts-db.artmuseums.go.jp/>

(注 14) : MADBLab, https://mediag.bunka.go.jp/madb_lab/

(注 9) : <https://rdfportal.org/>

(注 10) : <https://data.e-stat.go.jp/iodw/>

5. 知識グラフの活用事例

知識グラフは様々なアプリケーションやサービスの開発において基盤となる知識ベースとして活用される。対象とする領域やサービスの種類によって活用のされ方や利用目的は異なるが、ここでは主な活用方法を（１）知識グラフに基づくデータ統合、（２）知識基盤としての利用に大別して活用事例を示す。合わせて知識グラフの利用技術を対象としたコンテスト「ナレッジグラフ推論チャレンジ」の概要を示す。更に、今後の様々な応用が期待される大規模言語モデルと知識グラフを組み合わせた利用についての動向を述べる。

5.1 知識グラフに基づくデータ統合

多種多様かつ膨大なデータを有効に活用するためには、様々なデータを統合して利用する仕組みが重要となる。2章で述べたように Linked Data は多種多様なデータを Web の仕組みで統合する仕組みを提供することから、様々な領域でオープンデータを Linked Data として公開する LOD の構築が進められている。その際、オントロジーに基づいてデータを表現する知識グラフの構造を規定することで、データの統一的な扱いが可能となる。

例えば、Wikidata では対象領域ごとデータ構造がシステム全体で統制されているため、それぞれのデータに応じた検索・可視化などの処理が統一に行える。Wikidata のクエリサービスでは、そのような統一した処理を利用して、棒グラフ、ネットワーク（グラフ）構造、年表、地図など、検索結果の基本的な可視化を行う機能を提供している。また特定領域を対象とした例としては、研究者や研究機関などの学術

情報について Wikidata から関連するデータを収集し、様々な観点から可視化する Scholia というサービスがある⁽³⁴⁾ (図 12)。このように様々な観点から検索結果を可視化する機能は、対象領域の知識グラフを公開した LOD と合わせて提供されることが多い。

5.2 知識グラフの知識基盤としての利用

知識グラフは様々な対象に関する知識の関係性を捉え、グラフ構造で表現することで、計算機上でその知識が表す内容を扱えるようにする。よって、知識グラフとして表現された「知識」は、様々な応用システムが扱う知識基盤として利用される。

例えば、様々なシステムにおいて基本的な機能に位置づけられる検索においても、知識グラフを利用することで単なるキーワードによる検索ではなく、「グラフ構造で表される意味」に基づいた検索が行える。ここで、図 3 などで示したような大学に関する知識グラフを対象として「関西の大学」を検索することを例に考える。まずは「関西が大阪府、京都府、兵庫県…など二府四県からなる地域を表す」ことを「関西」に関するグラフ構造から得て、「その二府四県を所在地とする大学」を各大学に関するグラフ構造から検索することで結果が得られる。その際、図 3 のように「所在地が市町村で記述されている」場合も、その市町村のグラフ構造から所在地となる都道府県を調べることで、関西に該当するかを判定できる。

このようなグラフ構造が表す知識に基づいた検索が、知識グラフを知識基盤として利用する際の中心的な技術となる。特に、検索条件を質問文で与え、知識グラフを用いてその応答を生成する技術は、Knowledge Graph Question Answering

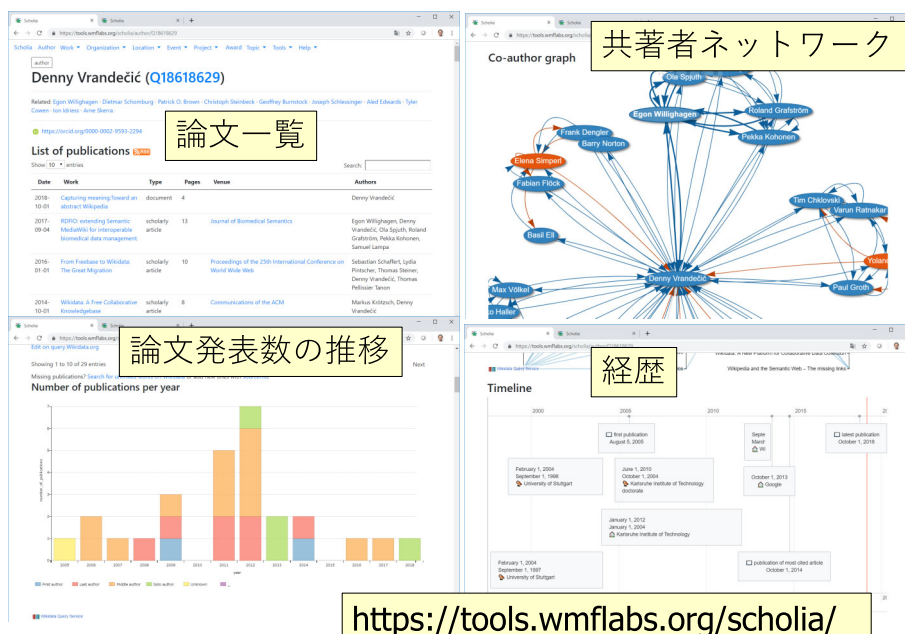


図 12 Wikidata の情報をもとにした学術情報可視化システム Scholia

(KGQA) と呼ばれ多くの研究が行われている。質問応答 (QA) に知識グラフを用いることの特徴は、グラフ構造を用いることで「知識の意味」を明示的に扱うことができる点にある。具体的には、回答の生成に用いたグラフ構造を示すことで、「その回答が、どのような内容に基づいて得られたのか？」を明確に説明することができる。人工知能システムにおける説明能力の重要性は、AI の実用が進むにつれて高まっており、知識グラフの利用は説明可能な AI を実現するための技術としても注目されている。

5.3 ナレッジグラフ推論チャレンジ

知識グラフを基盤とした説明可能 AI に関する取り組みの一つとして、筆者らが実施しているナレッジグラフ推論チャレンジがある⁽³⁵⁾。ナレッジグラフ推論チャレンジは、説明能力をもった AI 技術の開発促進を目指した技術コンテストである。2018 年に開催した第 1 回では、シャーロックホームズの推理小説を題材とし、小説で描かれた事件の犯人を同定し、その結論に至った理由を説明することをタスクとして設定した。チャレンジ開催にあたり、対象とする小説の内容をもとに構築した知識グラフを公開し、参加者は公開された知識グラフを利用して、犯人の推定とその理由を生成するシステムを開発した。その後、毎年開催を続け国内版を計 4 回、国際ワークショップの形で国際版を 1 回開催した。応募作品の総数は、対象のタスク全体を解くシステムを開発する本部門が計 15 作品、いずれかのタスクを部分的に解くツールを開発するツール部門が 9 作品、実現方法のアイデアを対象としたアイデア部門が 10 作品にのぼる⁽³⁶⁾。

更に 2022 年には、より実社会のニーズに近いタスクを設定することを目指した、ナレッジグラフ推論チャレンジ【実社会版】を開催した。実社会版の推論チャレンジでは、高齢者の家庭内における危険な状況を検出して説明するシステムの開発をタスクとして設定し、シナリオデータから得られる仮想環境内での日常的な行動をエミュレートした「動画」、動画の内容に対応する「知識グラフ」、動画の元とした「シナリオ」の 3 種類のデータが提供された。これらのデータを用いることにより、動画と知識グラフという異なる形式のデータを統合的に利用した推論及び説明生成を行う技術の開発が行われることを目指した。第 1 回のナレッジグラフ推論チャレンジ【実社会版】には 6 作品が応募され、ナレッジグラフと動画を組み合わせた作品も見られた⁽³⁷⁾。

5.4 知識グラフと大規模言語モデル

知識グラフでは様々な知識の関係をグラフ構造で明示することによりその意味を適切に扱うことを目指している。それに対し、機械学習や深層学習など、多量のデータを学習することにより AI システムを開発する手法においては、大規模な言語データを学習した言語モデル（大規模言語モデル：LLM (Large Language Model)）の活用が注目されている。

大規模言語モデルの活用は、知識グラフへの応用においても大きな可能性があると考えられており、知識グラフ関連のトップカンファレンスである ISWC2023 (The 22nd International Semantic Web Conference) においても、3 件の基調講演が全て大規模言語モデルに関するものであるなど、関連する発表が多くみられた。

ここでは、知識グラフの活用の観点から大規模言語モデルの利用について述べる。

5.4.1 QA タスクにおける知識グラフと言語モデルの比較

5.2 節で述べたように知識グラフに基づく質問応答 (KBQA) は、知識グラフの典型的な活用例である。それに対し、ChatGPT のような大規模言語モデルを用いた対話システムも、質問応答に利用される。そのため両者の性能比較は、それぞれの特徴を理解する上で重要となる。例えば、図 7(1) で示した SPARQL クエリの相当する質問文は「大阪電気通信大学の所在地 (位置する行政区画) は？」となるが、2024 年 4 月時点での ChatGPT 4 では正しく「寝屋川市」という回答が得られるが、ChatGPT 3.5 では「大阪市北区」という誤った回答となる。Tan らは、このような言語モデルの違いによる質問応答の性能を、KGQA に用いられる様々なデータセットを対象として詳細に比較している⁽³⁸⁾。

5.4.2 言語モデルに対する知識グラフの利用

言語モデルを用いて生成される内容には、前項でも述べたように誤りが含まれる場合があるため、その内容に関する事実確認 (ファクトチェック) が重要となる。一方、知識グラフは事実に関する知識を表したものであるため、事実確認への利用が見込まれる。例えば、質問文に対して言語モデルが生成した回答を知識に変換し、Wikidata がもつ知識グラフの構造と比較することでファクトチェックを行う仕組みが提案されている⁽³⁹⁾。

また、大規模言語モデルは学習に要する時間が膨大であり、リアルタイムな情報など学習データに含まれない内容への対応が必要なため、Retrieval Augmented Generation (RAG) と呼ばれる外部データベースを組み合わせる技術が用いられる。RAG の対象には様々なデータベースが用いられるが、知識グラフの利用も有用なアプローチと考えられる。

5.4.3 知識グラフに対する大規模言語モデルの利用

知識グラフの構築に必要とされるコストを軽減するため、テキストデータなどから知識グラフを (半) 自動構築する手法については多くの研究が行われている。知識グラフの構築への大規模言語モデルの活用は有望なアプローチとして、既に幾つかの取組みが行われている。Babaei らは、LLM をオントロジー学習 (オントロジーの自動構築) に利用するにあたり、九つの LLM に対して Zero-Shot プロンプティングを行い用語の分類、分類の発見、非分類関係の抽出といった主要なタスクに関して評価している⁽⁴⁰⁾。Mihindukulasooriya

らは LLM を用いてテキストからのナレッジグラフを構築する際のベンチマークデータセット Text2KGBench を作成・公開している⁽⁴¹⁾。

また、言語モデルを用いた知識グラフ構築をタスクとした技術コンテストとして、Knowledge Base Construction from Pre-Trained Language Models (LM-KBC) が行われている。この取り組みでは、Semantic Web の国際会議 ISWC2022 及び ISWC2023 において Challenge (コンテスト) を実施するとともに、ISWC2023 では国際ワークショップを開催している。国内でも、2023 年のナレッジグラフ推論チャレンジにおいては、大規模言語モデルを用いた知識グラフの構築をタスクとしてコンテストを実施した⁽⁴²⁾。

以上のような大規模言語モデルを用いた知識グラフの構築は、今後の知識グラフの構築・利用においても重要な技術の一つとして発展が期待される。

6. おわりに

本稿では、知識グラフとオントロジーに基づく人工知能システム開発のアプローチについて、知識グラフを活用する技術を中心に開設した。知識グラフの特徴は、対象とする知識の内容を明示的に表現できる点にあり、オントロジーを用いて表現方法を明確にすることにより知識の統一的な扱いが可能となる。既に多くの領域において大規模な知識グラフが構築・公開されており、それらを有効利用することで、様々な応用システムの開発が行える。更に、大規模言語モデルと組み合わせることで、知識グラフ及び言語モデルの双方がもつ特徴を活かした応用が期待される。

文 献

- (1) T. バーナーズ＝リー, J. ヘンドラー, O. ラッシーラ, “自分で推論する未来型ウェブ,” 日経サイエンス, pp. 54-65, Aug. 2001.
- (2) Resource Description Framework (RDF), <https://www.w3.org/RDF/>, 2014.
- (3) T. ヒース, C. バイツァー, Linked Data : Web をグローバルなデータ空間にする仕組み, 近代科学社, 東京, 2013.
- (4) A. Singhal, “Introducing the Knowledge Graph : things, not strings,” <https://blog.google/products/search/introducing-knowledge-graph-things-not/>, May 2012.
- (5) Google Knowledge Graph Search API, <https://cloud.google.com/enterprise-knowledge-graph/docs/search-api>.
- (6) prefix.cc-namespaces lookup for RDF developers, <https://prefix.cc/>.
- (7) T.R. Gruber, “A translation approach to portable ontology specifications,” Knowledge Acquisition, vol. 5, no. 2, pp. 199-220, June 1993.
- (8) 溝口理一郎, オントロジー工学, オーム社, 東京, 2005.
- (9) RDF Schema 1.1, <https://www.w3.org/TR/rdf11-schema/>, 2014.
- (10) OWL 2 Web Ontology Language Document Overview (Second Edition), <https://www.w3.org/TR/owl2-overview/>, 2012.
- (11) protégé, <https://protege.stanford.edu/>.
- (12) 法造一オントロジーエディタ, <https://hozo.jp/>.
- (13) 古崎晃司, 來村徳信, 池田満, 溝口理一郎, “「ロール」および「関係」に関する基礎的考察に基づくオントロジー記述環境の開発,” 人工知能学会論文誌, vol. 17, no. 3, pp. 196-208, April 2002.
- (14) SPARQL 1.1 Overview, <https://www.w3.org/TR/sparql11-overview/>, 2013.
- (15) 加藤文彦, 川島秀一, 岡別府陽子, 山本泰智, 片山俊明, オープンデータ時代の標準 Web API SPARQL, インプレス R & D, 東京, 2015.
- (16) RDF 1.1 N-Triples A line-based syntax for an RDF graph, <https://www.w3.org/TR/n-triples/>, 2014.
- (17) RDF 1.1 Turtle Terse RDF Triple Language, <https://www.w3.org/TR/turtle/>, 2014.
- (18) Wikidata, “データベースのダウンロード,” https://www.wikidata.org/wiki/Wikidata:Database_download/ja.
- (19) RDF 1.1 XML Syntax, <https://www.w3.org/TR/rdf-syntax-grammar/>, 2014.
- (20) JSON-LD 1.1, “A JSON-based serialization for Linked Data,” <https://www.w3.org/TR/json-ld11/>, 2020.
- (21) Apache Jena, <https://jena.apache.org/>.
- (22) rdflib, <https://rdflib.readthedocs.io/>.
- (23) Apache Jena Fuseki, <https://jena.apache.org/documentation/fuseki2/>.
- (24) Virtuoso Open-Source Edition, <https://vos.openlinksw.com/>.
- (25) The Linked Open Data Cloud, <https://lod-cloud.net/>.
- (26) D. Vrandečić and M. Krötzsch, “Wikidata : a free collaborative knowledgebase,” Communications of the ACM, vol. 57, no. 10, pp. 78-85, Sept. 2014.
- (27) J. Lehmann, R. Isele, M. Jakob, A. Jentzsch, D. Kontokostas, P.N. Mendes, S. Hellmann, M. Morsey, P. van Kleef, S. Auer, and C. Bizer, “DBpedia-A large-scale, multilingual knowledge base extracted from Wikipedia,” Semantic Web, vol. 6, no. 2, pp. 167-195, 2015.
- (28) DBpedia Mappings, <https://mappings.dbpedia.org/>.
- (29) 川島秀一, “NBDC RDF ポータル : セマンティックに統合された生命科学データの利用を加速するために,” 情報管理, vol. 59, no. 4, pp. 232-240, July 2016.
- (30) 西村正貴, “Linked Open Data (LOD) による統計データの提供 : 政府統計データ (e-Stat) の新しい形,” 情報管理, vol. 59, no. 12, pp. 812-821, March 2017.
- (31) The RDF Data Cube Vocabulary, <https://www.w3.org/TR/vocab-data-cube/>, 2014.
- (32) 橋詰秋子, 福山樹里, “リンクト・オープン・データの利活用 : 4. 出版物に関するメタデータと国際書誌コントロール—国立国会図書館における LOD の取り組み—,” 情報処理, vol. 57, no. 7, June 2016.
- (33) 神崎正英, “領域を超えた利活用のためのメタデータ設計,” 情報の科学と技術, vol. 74, no. 5, pp. 172-179, May 2024.
- (34) F.A. Nielsen, D. Mietchen, and E. Willighagen, “Scholia, Scientometrics and Wikidata,” Proc. ESWC2017, pp. 237-259, Portorož, Slovenia, May 2017.
- (35) ナレッジグラフ推論チャレンジ, <https://challenge.knowledge-graph.jp>.
- (36) 川村隆浩, 江上周作, 田村光太郎, 外園康智, 鶴飼孝典, 小柳佑介, 西野文人, 岡嶋成司, 村上勝彦, 高松邦彦, 杉浦あおい, 白松俊, 張翔宇, 古崎晃司, “第1回ナレッジグラフ推論チャレンジ2018 開催報告—説明性のある人工知能システムを目指して—,” 人工知能, vol. 34, no. 3, pp. 396-412, Sept. 2020.
- (37) 鶴飼孝典, 江上周作, 川村隆浩, 松下京群, 古崎晃司, 福田賢一郎, “ナレッジグラフ推論チャレンジ【実社会版】開催報告,” 人工知能学会第二種研究会資料, SWO-060, Aug. 2023.
- (38) Y. Tan, D. Min, Y. Li, W. Li, N. Hu, Y. Chen, and G. Qi, “Can ChatGPT replace traditional KBQA models? An in-depth analysis of the question answering performance of the GPT LLM family,” Proc. ISWC2023, Part I, pp. 348-367, Athens, Greece, Nov. 2023.
- (39) Deborah McGuinness, “Semantic Web Research in the Age of Generative Artificial Intelligence,” ISWC2023 Keynote, Nov 19, 2023, <https://www.slideshare.net/deborahmcguinness/iswc2023mcguinnesswc16x9finalshortpdf>
- (40) H. Babaei Giglou, J. D’Souza, and S. Auer, “LLMs4OL : Large

Language Models for Ontology Learning,” Proc. ISWC2023, Part I, pp. 408-427, Athens, Greece, Nov. 2023.

- (41) N. Mihindukulasooriya, S. Tiwari, C.F. Enguix, and K. Lata, “Text2KGBench: A benchmark for ontology-driven knowledge graph generation from text,” Proc. ISWC2023, Part II, pp. 247-265, Athens, Greece, Nov. 2023.
- (42) 古崎晃司, 江上周作, 松下京群, 鶴飼孝典, 川村隆浩, 福田賢一郎, “ナレッジグラフ推論チャレンジ2023 開催報告—生成 AI 時代のナレッジグラフ構築技術,” 人工知能学会第二種研究会資料, SWO-062, March 2024.

(TL 研究会提案, 2024 年 4 月 1 日受付,
2024 年 6 月 27 日再受付)



古崎 晃司 (正員)

1997 大阪大・工・電子卒, 2002 同大学院博士課程修了, 同年, 化学工学会嘱託研究員, 同年 12 月大阪大学産業科学研究所助手, 2008 同准教授, 2019 大阪電気通信大学教授, 現在に至る, 博士(工学), オントロジー工学の基礎理論, オントロジー構築・利用環境の設計・開発, セマンティック Web, Linked Data, 各種領域におけるオントロジー開発・応用に関する研究に従事, 2022 年度人工知能学会全国大会優秀賞受賞, 著書『オントロジー構築入門』など.

非線形偏微分方程式に潜む離散構造 —コンピュータとの親和性の高い制御を目指して—

Discrete Structures Hidden in Nonlinear Partial Differential Equations:
For Control Methods that Have High Compatibility with Computers

甲斐健也 Tatsuya KAI

アブストラクト 弦・梁・膜などの変形する物体の数理モデル、流体力学のバーガーズ方程式、量子力学のシュレーディンガー方程式などに代表される「非線形偏微分方程式」は、自然界の様々な現象を表現可能であることがよく知られている。しかし、非線形性や無限次元性などの性質から解析並びに制御が非常に難しく、現在でも様々なアプローチによる研究が活発に進められている。その中で非線形偏微分方程式の離散構造に着目した「離散力学」並びに「超離散化」というアプローチがあり、いわばシステムの重要な「離散的骨格」を抽出することに対応するといえる。更に、非線形偏微分方程式の離散構造を用いることによって、離散値のみを扱うコンピュータとの親和性の高い制御系設計が期待できる。本稿では、筆者らの研究を中心として、幾つかの基礎並びに応用を含めた関連内容を報告する。

キーワード 非線形偏微分方程式、分布定数力学システム、離散構造、離散力学、超離散化

Abstract It is well known that “nonlinear partial differential equations,” which are typified by mathematical models for transforming objects such as strings, beams, and films, Burgers equations in fluid mechanics, and Schrödinger equations in quantum mechanics, can represent a lot of phenomena in the world of nature. However, it is quite difficult to control such systems because of nonlinearity and infinite dimensionality; hence, they are actively studied by various approaches. There are some approaches, called “discrete mechanics” and “ultradiscretization,” based on discrete structures of nonlinear partial differential equations, and it corresponds to the extraction of the “discrete bony framework” from the systems. Moreover, we can expect control synthesis methods that are highly compatible with computers treating only digital data. This paper shall provide some fundamental and applied research studies on this topic with our group’s results.

Key words Nonlinear partial differential equations, Distributed parameter mechanical systems, Discrete structure, Discrete mechanics, Ultradiscretization

1. はじめに

世の中の森羅万象を解明するために、まずはじめにその「数理モデル」を構築することは、どのような研究分野でも行われる最も基本的なアプローチである。数理モデルといっても様々な種類（連続/離散、静的/動的、線形/非線形、確定的/確率的、常微分/偏微分など）が存在し、その現象の特性に合わせて種類が決定されることが多い。その中でも、非線形偏微分方程式^{(1),(2)}は簡単にいうと「変形を伴う現象」を記述する際によく用いられる。弦・梁・膜などの変形する力学的物体、流体・気流・音・電磁気などの場が変化する現象、量子力学・一般相対性理論などにおける基礎方程式はその代表例であり、その表現の多彩さから様々な研究分野において用いられている。一方、非線形偏微分方程式で記述されるシステムは非線形性や無限次元性をもち

つため、その振る舞いは非常に複雑であり、逆に考えると理論解析が難しいといえる。制御工学の観点からすると、一般的には線形よりも非線形、常微分よりも偏微分の方がより制御を行うことが難しく、研究分野としてはまだまだ未発展である。

システムを制御する際、まず連続時間の微分方程式で記述されたモデルを導出し、そのモデルのもつ特徴を解析して、制御目標を達成するような連続コントローラ的设计を行い、最終的に離散化を行ってから計算機を用いて制御を行うのが一般的な流れである。しかし、その離散化のプロセスによって、元の連続モデルや連続コントローラがもつ特徴（安定性や解の振る舞いなど）が損なわれ、制御パフォーマンスの低下、更には数値不安定化現象などが発生する可能性がある。ゆえに、連続と離散の関係性を重視しなければならず、できるだけ元の連続モデルの特性を保存するような離散化手法を用いることが制御において重要である。特に非線形偏微分方程式に対しては、時間方向だけではなく空間方向の両方を離散化する必要があり、これまでに様々な離散化手法・数値計算手法の研究が行われている。その中でも、離散力学並びに超離散化という手法が近年開発され、元のシステムの特徴を保存する新しい離散化手法として大きな可能性を秘めている。そのような離散化手法を用いた場合、誤差の減少、有限次元最適化問題に帰着した解法による高速・高

甲斐健也 正員 東京理科大学先進工学部機能デザイン工学科

E-mail kai@rs.tus.ac.jp

Tatsuya KAI, Member (Dept. of Medical and Robotic Engineering Design, Faculty of Advanced Engineering, Tokyo University of Science, 6-3-1 Nijjuku, Katsushika-ku, Tokyo, 125-8585 Japan).

電子情報通信学会 基礎・境界サイエティ

Fundamentals Review Vol.18 No.2 pp.137-146 2024年10月

©電子情報通信学会 2024

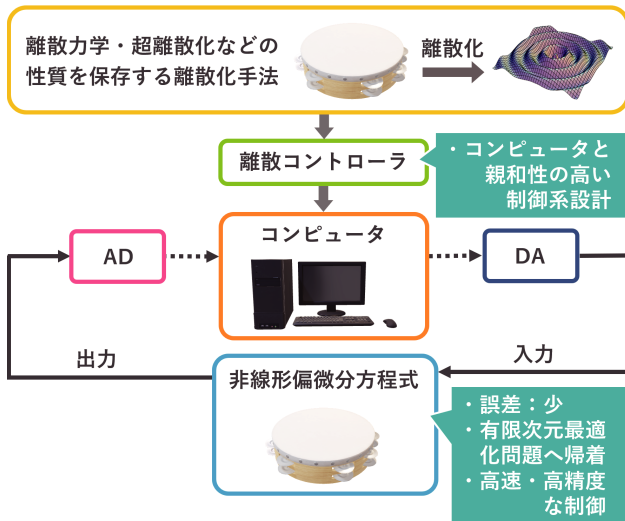


図1 離散化とコンピュータ制御の流れ

精度な制御などが期待でき、コンピュータの性能を十分発揮した制御系設計が実現できる(図1).

本解説ではこの離散力学と超離散化の二つに着目し、「非線形偏微分方程式に潜む離散構造」について考える。更に、それらの手法に基づいた「コンピュータとの親和性の高い制御」を目指した研究成果について、筆者らの研究を中心に解説する。

2. 分布定数力学システムに対する離散力学

2.1 離散力学

本章では、分布定数力学システムを対象とした「離散力学」とその制御への応用について解説する。分布定数力学システムとは、状態量が時間と位置によって決まるようなシステムであり、特に弦・梁・弦などの「変形する力学的物体」を意味する。離散力学(discrete mechanics)とは、物理学の基礎原理・構成要素(ラグランジアン、ハミルトンの原理、ラグランジュ・ダランベールの原理など)をまず最初に離散化し、そこから離散の運動方程式を導出する離散化手法の一種であり(図2)、ほかの離散化手法と比較して数値計算上の様々な長所も持っていることが知られている^{(3)~(8)}。これまでは、状態量が時間だけで決まるような「集中定数力学システム」を対象としていたが、筆者らは離散力学の分布定数力学システムへの拡張を行っている^{(9)~(16)}。

本解説では簡単のために次元の場合について説明を行うが、多次元への拡張も可能である。時間変数を $t \in \mathbf{R}$ 、次元空間を $x \in \mathbf{R}$ とし、時間 t 、位置 x における変位を $u(t, x) \in \mathbf{R}$ と記述する。また、添え字付の u はその変数に関する偏導関数を表すとする。本解説では、 u の2階偏導関数までを含むようなクラスの連続ラグランジアン密度

$$L^c(t, x, u, u_t, u_x, u_{tt}, u_{tx}, u_{xx}) \quad (1)$$

を対象とする。図3にあるように、時間変数 t と位置変数 x はそれぞれサンプリング間隔 h, d で以下のように離散化する。

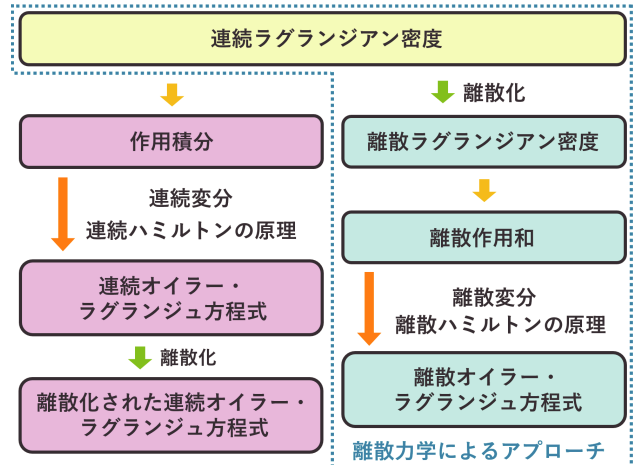


図2 通常の方法と離散力学の離散化の比較




図3 時間 t と位置 x の離散化

$$\begin{aligned} t &\approx hk \quad (k = 1, 2, \dots, K-1, K) \\ x &\approx dl \quad (l = 1, 2, \dots, L-1, L) \end{aligned} \quad (2)$$

ここで、 $k, l \in \mathbf{Z}$ はそれぞれ時間と位置の離散変数である。離散化された時刻 k と位置 l におけるシステムの変位を $U_{k,l} \in \mathbf{R}$ とすると、

$$\begin{aligned} u(t, x) &\approx (1-\alpha)(1-\beta)U_{k,l} + (1-\alpha)\beta U_{k,l+1} \\ &\quad + \alpha(1-\beta)U_{k+1,l} + \alpha\beta U_{k+1,l+1} \end{aligned} \quad (3)$$

のように変位を離散化する。ただし、 α, β は $0 < \alpha < 1, 0 < \beta < 1$ を満たすパラメータであり、4点 $U_{k,l}, U_{k,l+1}, U_{k+1,l}, U_{k+1,l+1}$ の内分比を表している(図4)。そして、 $u(t, x)$ の偏導関数は以下のように離散化する。

$$\begin{aligned} u_t(t, x) &\approx \frac{U_{k+1,l} - U_{k,l}}{h} \\ u_x(t, x) &\approx \frac{U_{k,l+1} - U_{k,l}}{d} \\ u_{tt}(t, x) &\approx \frac{U_{k+1,l} - 2U_{k,l} + U_{k-1,l}}{h^2} \\ u_{tx}(t, x) &\approx \frac{U_{k+1,l+1} - U_{k,l+1} - U_{k+1,l} + U_{k,l}}{hd} \\ u_{xx}(t, x) &\approx \frac{U_{k,l+1} - 2U_{k,l} + U_{k,l-1}}{d^2} \end{aligned} \quad (4)$$

上記のような離散化の設定のもと、連続ラグランジアン密度




図4 変位 $u(t, x)$ の離散化

(1) に (2)~(4) を代入し、そこに hd を掛けたものを離散ラグランジアン密度と呼び、

$$L_{k,l}^d = L^d(k, l, U_{k-1,l}, U_{k,l-1}, U_{k,l}, U_{k,l+1}, U_{k+1,l}, U_{k+1,l+1}) \quad (5)$$

のように記述する。離散ラグランジアン密度 (5) を用いて、離散作用和を、

$$S^d(U) := \sum_{k=2}^{K-1} \sum_{l=2}^{L-1} L_{k,l}^d \quad (6)$$

のように定義し、 U は全ての $U_{k,l}$ ($k = 1, \dots, K; l = 1, \dots, L$) をまとめて記述している変数である。この離散作用和 (6) に対し、 U を微小な値 (変分) δU だけ変化させた場合の離散変分

$$\delta S^d(U) := S^d(U + \delta U) - S^d(U) \quad (7)$$

を考える。ここで、変分 δU は境界条件として、

$$\begin{aligned} \delta U_{1,l} &= \delta U_{2,l} = \delta U_{K-1,l} = \delta U_{K,l} = 0 \\ \delta U_{k,1} &= \delta U_{k,2} = \delta U_{k,L-1} = \delta U_{k,L} = 0 \end{aligned} \quad (8)$$

$(k = 1, \dots, K; l = 1, \dots, L)$

を満たすとする。連続の場合におけるオイラー・ラグランジュ方程式の導出では通常、ハミルトンの原理が用いられるが、そのアナロジーを考えることによって、離散ハミルトンの原理を「離散作用和が停留 (任意の微小な変分を与えても値が変わらない) するような運動が実現される」と定義することにする。この離散ハミルトンの原理を離散作用和 (6) に適用することによって、次の定理が得られる。

[定理 1] 離散ラグランジアン密度 (5) に対して、離散ハミルトンの原理を満たすような離散オイラー・ラグランジュ方程式は、

$$\begin{aligned} \frac{\partial L_{k-1,l-1}^d}{\partial U_{k,l}} + \frac{\partial L_{k-1,l}^d}{\partial U_{k,l}} + \frac{\partial L_{k,l-1}^d}{\partial U_{k,l}} \\ + \frac{\partial L_{k,l}^d}{\partial U_{k,l}} + \frac{\partial L_{k,l+1}^d}{\partial U_{k,l}} + \frac{\partial L_{k+1,l}^d}{\partial U_{k,l}} = 0 \end{aligned} \quad (9)$$

$(k = 3, 4, \dots, K-2; l = 3, 4, \dots, L-2)$




図5 離散オイラー・ラグランジュ方程式

で与えられる。

離散オイラー・ラグランジュ方程式 (9) は非線形かつ陰関数の差分方程式で記述されており、図 5 にあるような合計 17 点の変数を含んでいる。更に、元の連続システムのエネルギーの性質 (保存系・散逸系) を保つ、長時間のシミュレーションでも数値誤差が増大しないなどの、マルチスケール性と呼ばれる数値計算上良い特性をもっていることが分かっている。

2.2 離散力学と非線形最適化の融合による制御法

つぎに本節では、離散力学の制御工学への応用について説明するが、最初に制御入力 of the 導入を行う。時刻 k , 位置 l における制御入力を $F_{k,l} \in \mathbf{R}$ とする。ただし、制御入力を発生させるアクチュエータが配置されている位置 l のインデックス集合を Δ で表し、アクチュエータが存在しない位置 l では、 $F_{k,l}$ ($k = 3, \dots, K-2$) は全て 0 とする。この制御入力項を加した離散オイラー・ラグランジュ方程式は、

$$\begin{aligned} \frac{\partial L_{k-1,l-1}^d}{\partial U_{k,l}} + \frac{\partial L_{k-1,l}^d}{\partial U_{k,l}} + \frac{\partial L_{k,l-1}^d}{\partial U_{k,l}} \\ + \frac{\partial L_{k,l}^d}{\partial U_{k,l}} + \frac{\partial L_{k,l+1}^d}{\partial U_{k,l}} + \frac{\partial L_{k+1,l}^d}{\partial U_{k,l}} = F_{k,l} \end{aligned} \quad (10)$$

$(k = 3, 4, \dots, K-2; l = 3, 4, \dots, L-2)$

で与えられる。

つぎに、与えられたシステムを制御するには何からの評価が必要であるが、そのための評価関数の設定を行う。 $a, b, c \in \mathbf{R}$ を重みパラメータとした評価関数

$$\begin{aligned} J(U, F) = a \sum_{k=1}^{K-1} \sum_{l=1}^L U_{k,l}^2 \\ + b \sum_{k=\kappa}^K \sum_{l=1}^L U_{k,l}^2 + c \sum_{k=3}^{K-2} \sum_{l \in \Delta} F_{k,l}^2 \end{aligned} \quad (11)$$

を考える。ここで、 F は全ての $F_{k,l}$ ($k = 3, \dots, K-2; l \in \Delta$)

をまとめて記述している変数，右辺第 1 項は初期時刻から時刻 $k = \kappa - 1$ の間の全ての位置における変位に関する評価項，右辺第 2 項は時刻 $k = \kappa$ から $k = K$ の間の全ての位置における変位に関する評価項 (κ : 安定化開始時刻)，右辺第 3 項は全ての時刻における制御入力に関する評価項である．重みを設定した評価関数 (11) を最小にすることによって，システムの状態を 0 に収束させ，更に制御入力をできる限り小さくするような最適な安定化制御が行えることが期待できる．ゆえに，本解説で考える安定化制御問題は以下のように与えられる．

[問題 1] 離散ラグランジアン (5) に対する制御入力項を有する離散オイラー・ラグランジュ方程式 (10) について，評価関数 (11) を最小化し，指定した変位 $U_{k,l}$ ($k = \kappa, \dots, K$; $l = 1, \dots, L$) を全て 0 にするような安定化制御入力 $F_{k,l}$ ($k = 3, \dots, K - 2$; $l \in \Delta$) を求めよ．

更に，適切な初期条件と境界条件を設定する．ここで適切というのは，離散オイラー・ラグランジュ方程式 (9) を用いて，全ての KL 個の $U_{k,l}$ ($k = 1, \dots, K$; $l = 1, \dots, L$) が計算するために必要な初期条件・境界条件を設定する，という意味である．これまでの設定を用いて，上記の問題 1 は次のように定式化できる．

$$\begin{aligned} & \min_{U, F} (11) \\ & \text{subject to (10)} \quad (12) \\ & \text{given initial conditions, boundary conditions} \end{aligned}$$

この安定化制御問題 (12) は，一般的には拘束条件付き有限次元非線形最適化問題に帰着される．ゆえに，逐次二次計画法⁽¹⁷⁾などの既存の最適化手法を用いることによって，比較的大規模な問題でも効率的に最適解を得ることが可能である．(12) を解くと，最適制御入力列 $F_{k,l}$ ($k = 3, \dots, K - 2$; $l \in \Delta$) が得られることになるので，これをシステム (10) へと印加することによって安定化制御が実現できることになる．

上記の方法は，1 回の計算で全ての制御入力を計算する「フィードフォワード型」の制御法であるが，このままであると外乱やパラメータ誤差などが存在する場合に制御性能を発揮することができない．そこで，この手法にモデル予測制御法を組み込むことによって，「フィードバック型」の制御法に拡張する．モデル予測制御法⁽¹⁸⁾とは，有限時間先までの最適制御問題を解き，得られた制御入力の一部を用いてシステムを駆動させ，そのステップを繰り返すことによってシステムを制御するようなフィードバック型の制御手法の一種である (図 6)．モデル予測制御法では，最適制御問題を繰り返し解き，逐次制御入力を計算しているので，外乱やモデル化誤差にロバストな制御手法であることが知られており，更に，拘束条件なども扱うことが容易であることが大きな特徴である⁽¹⁸⁾．離散力学に基づいたモデル予測型安定化制御法のアルゴリズムは以下のように与えられる．

(i) 予測ホライズン (T_p ステップ) 先までの離散力学モデル (10) に対する安定化制御問題 (12) を解いて，最適制御入力列 $F_{k,l}$ ($k = 3, \dots, K - 2$; $l \in \Delta$) を計算する．




図 6 モデル予測制御法




図 7 弦のモデル

- (ii) 最適制御入力列の最初の一部を制御ホライズン (T_c ステップ) だけシステムに印加してシステムを駆動させる．
- (iii) (i), (ii) のステップを繰り返すことによってシステムを制御させる．

2.3 応用例：非線形弦の安定化制御

本節では分布定数力学システムの物理例として非線形弦を取り上げる．図 7 に示されているような両端が固定されている弦を考え，弦の位置として x 軸を取り，時刻 t と位置 x における弦の変位を $u(t, x)$ とする．ここで，弦の変位の変動幅には制約を課さず，ゆえに非線形性を保持したままの弦 (非線形弦) を考えることとする．弦の質量密度を ρ ，弦の張力を N とすると，非線形弦の連続ラグランジアン密度は，

$$L^c = \frac{1}{2} \rho u_t^2 - N(\sqrt{1 + u_x^2} - 1) \quad (13)$$

で与えられ，この連続ラグランジアン密度 (13) は， u の 1 階偏導関数 u_t, u_x までを含んでいるところに注意する．離散化の設定は前節と同様とすると，連続ラグランジアン密度 (13) から離散ラグランジアン密度が，

$$\begin{aligned} L_{k,l}^d = hd \left\{ \frac{1}{2} \rho \left(\frac{U_{k+1,l} - U_{k,l}}{h} \right)^2 \right. \\ \left. - N \left(\sqrt{1 + \left(\frac{U_{k,l+1} - U_{k,l}}{d} \right)^2} - 1 \right) \right\} \quad (14) \end{aligned}$$

のように求められる．




図 8 非線形弦の離散力学モデル




図 9 非線形弦の制御設定

つぎに、離散ラグランジアン (14) を離散オイラー・ラグランジュ方程式 (9) に代入して計算すると、非線形弦に対する離散オイラー・ラグランジュ方程式が以下のように得られる。

$$\begin{aligned}
 & -\frac{d\rho}{h}(U_{k+1,l} - 2U_{k,l} + U_{k-1,l}) \\
 & + hN \left(\frac{U_{k,l+1} - U_{k,l}}{\sqrt{d^2 + (U_{k,l+1} - U_{k,l})^2}} \right. \\
 & \left. + \frac{U_{k,l-1} - U_{k,l}}{\sqrt{d^2 + (U_{k,l} - U_{k,l-1})^2}} \right) = 0
 \end{aligned} \quad (15)$$

これは図 8 のように $U_{k-1,l}, U_{k,l-1}, U_{k,l}, U_{k,l+1}, U_{k+1,l}$ の合計 5 点の変数を含む差分方程式である。また、(15) は $U_{k+1,l}$ について解くことができるため、陽的な差分方程式となることが分かる。

制御シミュレーションにおける共通の設定として、総ステップ数は $K = 400$, $L = 20$, 物理パラメータは $\rho = 0.1$, $N = 1$, サンプル間隔は $h = 0.01$, $d = 0.1$, 弦の初期形状は、

$$U_{1,l} = \sin\left(\frac{l-1}{L-1}\pi\right), \quad U_{2,l} = 0.99 \sin\left(\frac{l-1}{L-1}\pi\right) \quad (16)$$

$(l = 1, \dots, L)$

と設定し、また両端固定としているので、弦の両端における境界条件として、

$$U_{k,1} = U_{k,L} = 0 \quad (k = 1, \dots, K) \quad (17)$$

のように設定する。そして、図 9 のように制御入力が発生させるアクチュエータは両端に一つずつ設置されていると仮定し、ゆえに $\Delta = \{2, 19\}$ と設定する。また、モデル予測制御の設定としては、評価関数 (11) の重み $a = 1$, $b = 1000$, $c = 1$, 安定化




図 10 弦の振動の三次元プロット

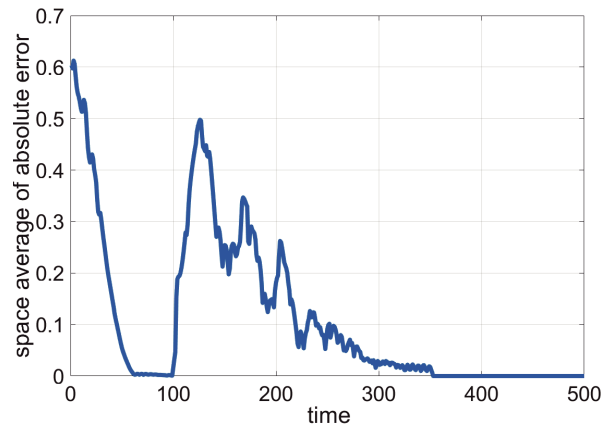


図 11 絶対値誤差の空間平均の時系列

開始時刻 $\kappa = 35$, 予測ホライズン $T_p = 40$, 制御ホライズン $T_c = 10$ とする。更にロバスト性を確認するために、弦の中心 $l = 10, 11$ の 2 箇所の場所に、時刻 $k = 100$ において大きさが 0.15 の外乱を 1 回印加する。

図 10, 11 にシミュレーションの結果を示す。図 10 は弦の変位 $U_{k,l}$ の変化を三次元的にプロットしたものであり、図 11 は各時間ステップにおける変位 $U_{k,l}$ の絶対値の空間平均をプロットしたものである。これらの結果より、提案した制御手法によって、非線形弦全体が安定化される様子が分かる ($k = 50 \sim 100$)。更に、 $k = 100$ において外乱を印加したため、非線形弦が再び振動して振る舞いが乱れるが、モデル予測制御型のフィードバック制御の効果によって再び安定化制御が行われ、非線形弦全体の振動が抑制され安定化されている ($k = 350 \sim 500$)。したがって、提案手法の安定化性能並びに外乱に対するロバスト性が確認できた。なお、離散力学に関しては、片端固定弦/梁の制御⁽¹²⁾、軌道追従制御の場合⁽¹⁴⁾、二次元への拡張・非線形膜の安定化制御^{(11), (16)}などの応用研究も進められている。

3. 非線形偏微分方程式に対する超離散化

3.1 超離散化の手法

本章では、非線形偏微分方程式を対象とした「超離散化」とその制御への応用について解説する。まず、超離散化の基礎的

な手法について説明を行う^{(19)~(21)}。超離散化 (ultradiscretization) とは、システムの独立変数だけではなく従属変数を含めた全ての変数を極限操作を行うことによって離散化することを意味し、最終的に得られた方程式は初期値が整数値ならば、任意の時刻における全ての変数も整数値を取ることが知られている。超離散化において最も基本的な公式が、

$$\lim_{\varepsilon \rightarrow +0} \varepsilon \log(e^{\frac{A}{\varepsilon}} + e^{\frac{B}{\varepsilon}}) = \max(A, B) \quad (18)$$

であり、超離散化の最終過程で重要な役割を果たす。

ここでは、代表的な非線形偏微分方程式である「一次元バーガーズ方程式」を例として超離散化の流れを説明する。拡散方程式

$$f_t = f_{xx} \quad (19)$$

を考え、 $t \in \mathbf{R}$ は時間変数、 $x \in \mathbf{R}$ は次元の空間変数、 $f(t, x) \in \mathbf{R}$ は時刻 t と位置 x における変位であり、 t または x の添字はその変数に関する偏微分を表すことにする。ここで、 $f(t, x)$ から $u(t, x)$ への変数変換であるコール・ホップ変換

$$u = (\log f)_x = \frac{f_x}{f} \quad (20)$$

を (19) に適用すると、バーガーズ方程式

$$u_t = 2uu_x + u_{xx} \quad (21)$$

が導かれる。つぎに、拡散方程式 (19) を差分化すると、

$$\frac{f_{l+1}^k - f_l^k}{h} = \frac{f_{l+1}^k - 2f_l^k + f_{l-1}^k}{d^2} \quad (22)$$

となり、ここで、 $k = 1, \dots, K$ は離散化された時間変数、 $l = 1, \dots, L$ は離散化された位置変数、 h, d はそれぞれ時間と位置のサンプリング間隔、 $f_l^k \in \mathbf{R}$ は時刻 k と位置 l における拡散方程式の変位である。簡単のため $h/d^2 = 1/2$ の場合を考えると、(22) は、

$$f_l^{k+1} = \frac{1}{2}(f_{l+1}^k + f_{l-1}^k) \quad (23)$$

のように整理でき、更に差分コール・ホップ変換

$$u_l^k = \frac{f_{l+1}^k}{f_l^k} \quad (24)$$

を (23) に適用すると、差分バーガーズ方程式

$$u_l^{k+1} = u_l^k \frac{u_{l+1}^k + \frac{1}{u_l^k}}{u_l^k + \frac{1}{u_{l-1}^k}} \quad (25)$$

に変換できる。ここで $u_l^k \in \mathbf{R}$ は時刻 k と位置 l における差分バーガーズ方程式の変位である。そして、変数変換

$$f_l^k = 2^{-k} e^{\frac{F_l^k}{\varepsilon}}, \quad u_l^k = e^{\frac{U_l^k - C}{\varepsilon}} \quad (26)$$

を考え、 C は定数とする。(23), (25) に (26) を代入すると、

$$F_l^k = \varepsilon \log \left(e^{\frac{F_{l+1}^k}{\varepsilon}} + e^{\frac{F_{l-1}^k}{\varepsilon}} \right) \quad (27)$$




図 12 バーガーズセルオートマトン

$$U_l^k = U_l^k + \varepsilon \log \left(e^{\frac{U_{l+1}^k - C}{\varepsilon}} + e^{-\frac{U_l^k - C}{\varepsilon}} \right) - \varepsilon \log \left(e^{\frac{U_{l+1}^k - C}{\varepsilon}} + e^{-\frac{U_{l-1}^k - C}{\varepsilon}} \right) \quad (28)$$

のようにそれぞれ変形される。(27), (28) において、 $\varepsilon \rightarrow +0$ の極限を行い、超離散化の公式 (18) を適用すると、超離散拡散方程式

$$F_l^k = \max(F_{l-1}^k, F_{l+1}^k) \quad (29)$$

並びにバーガーズセルオートマトン

$$U_l^{k+1} = U_l^k + \max(U_{l-1}^k, C - U_l^k) - \max(U_l^k, C - U_{l+1}^k) \quad (30)$$

が導出される。ここで、 $F_l^k, U_l^k \in \mathbf{Z}$ はそれぞれ時刻 k と位置 l における超離散拡散方程式とバーガーズセルオートマトンの変位である (図 12)。なお、(29) から (30) を超離散コール・ホップ変換

$$U_l^k = F_{l+1}^k - F_l^k + \frac{C}{2} \quad (31)$$

を用いても得ることができる。

バーガーズセルオートマトン (30) は以下のような興味深い性質が知られている。

- (i) バーガーズセルオートマトン (30) において、初期値並びに境界条件を全て整数値の $\{0, 1, \dots, C\}$ とすると (C は最大値)、全ての時間・位置におけるセルの値は常に $\{0, 1, \dots, C\}$ の範囲の整数値となる。
- (ii) バーガーズ方程式 (21) は衝撃波と呼ばれる解をもつことが知られているが、バーガーズセルオートマトン (30) も同様の解をもつことが分かっており、超離散化されても元の性質が保存される。
- (iii) バーガーズセルオートマトン (30) は右方向に進む一方通行の道路の交通流モデルとみなすことができ⁽²²⁾、各セルの値は車の台数を表す。更に、車は前に空きがあれば進むことができ、前に空きがなければその場に留まるといふ、いわゆる **184** ルールを常に満たす。

バーガーズセルオートマトン (30) はバーガーズ方程式 (21) の超離散化モデルであるが、全ての変数が離散化されても、元のシステムの性質を保存しているという意味で、非線形偏微分方程式に対する離散構造の一つと考えられる。

3.2 制御項付きバーガーズセルオートマトン

前節では、バーガーズ方程式からバーガーズセルオートマトンを導出したが、「外力項付きバーガーズ方程式」を超離散化することによって、「制御項付きバーガーズセルオートマトン」が




図 13 制御項付きバーガーズセルオートマトン




図 14 バーガーズセルオートマトン交通流モデル

得られることが知られている。まず、外力項付きバーガーズ方程式は、

$$u_t = 2uu_x + u_{xx} + s_x \quad (32)$$

で表され、ここで $s(t, x)$ は t, x に依存する外力項である。前節と同様のアプローチを行うことによって、制御項付きバーガーズセルオートマトンが

$$U_l^{k+1} = U_l^k + \max(S_l^k, U_{l-1}^k, C - U_l^k) - \max(S_{l+1}^k, U_l^k, C - U_{l+1}^k) \quad (33)$$

のように得られる⁽²⁰⁾。ここで、 $S_l^k \in \{0, 1, \dots, C\}$ はセル $l-1$ と l の間を通過できる値の上限値を表しており、制御入力として自由に設定可能である (図 13)。

更に、バーガーズセルオートマトンの性質 (iii) の交通流モデルとして考えると、この制御入力は $S_l^k = C$ のときには車を最大数通過させ (青信号)、 $S_l^k = 0$ のときには車を 1 台も通過させない (赤信号)、いわば「信号機」の役割を果たすことが分かる。このようなモデルを用いて「バーガーズセルオートマトン交通流モデル (図 14)」を構築し、交差点に設置された複数の信号機を制御することによって、街全体の渋滞数を最小化するような「信号機制御」の研究が進められている⁽²³⁾。

3.3 超離散化に基づく差分バーガーズ方程式の制御

本節では、制御項付きバーガーズセルオートマトン並びに差分バーガーズ方程式に対する、超離散化に基づいた安定化制御法を考える^{(24), (25)}。バーガーズセルオートマトンにおいて、ある固定された 1 箇所のセル位置 $l^* \in \{1, \dots, L\}$ に制御入力




図 15 制御項付きバーガーズセルオートマトン (1 入力の場合)

を印加できるとし、制御入力変数として $S_{l^*}^k \in \{0, 1, \dots, C\}$ を導入する。この場合の制御項付きバーガーズセルオートマトンは (34) で与えられる。(34) の第 1 式は制御入力の影響がないセル $l (l \in \{l^* - 1, l^*\})$ の場合、第 2 式は制御入力の前のセル ($l = l^* - 1$) の場合、第 3 式は制御入力の後のセル ($l = l^*$) の場合の発展方程式をそれぞれ表しており、ゆえに、制御入力 $S_{l^*}^k$ はセル $l^* - 1$ とセル l^* の間を通過できる値の上限値を示している (図 15)。また、ここでは周期境界条件: $U_{l^*+L}^k = U_{l^*}^k, \forall k = 1, \dots, K, \forall l = 1, \dots, L$ を仮定する。制御項付きバーガーズセルオートマトン (34) は超離散コル・ホップ変換 (31) を用いて、制御項付き超離散拡散方程式 (35) に変換できることが分かっており、ここで $F_l^k \in \mathbf{Z}$ は、時刻 k 、セル l における値である。

つぎに、制御項付きバーガーズセルオートマトン (34) を超離散化する前のシステムである「制御項付き差分バーガーズ方程式」について説明する。時刻 k 、セル l における差分バーガーズ方程式の値を $u_l^k \in \mathbf{R}$ 、制御入力を $s_l^k \in \mathbf{R}$ とし、超離散化の方法 (36) を用いることによって、制御項付き差分バーガーズ方程式が (37) で与えられる。(37) の第 1 式は制御入力の影響がないセル $l (l \in \{l^* - 1, l^*\})$ の場合、第 2 式は制御入力の前のセル ($l = l^* - 1$) の場合、第 3 式は制御入力の後のセル ($l = l^*$) の場合の発展方程式をそれぞれ表している。これらの関係式を表すと図 16 のようになる。

制御項付きバーガーズセルオートマトン (34) の初期値について、 C を偶数として、

$$\frac{1}{L} \sum_{l=1}^L U_l^1 = \frac{C}{2} \quad (38)$$

なる仮定をおく。この仮定は (36) を用いることによって、制御項付き差分バーガーズ方程式 (37) の初期値に対して、

$$\prod_{l=1}^L u_l^1 = 1 \quad (39)$$

なる条件と等価であることが分かり、これを仮定する。ここで、 $u^k = [u_1^k \dots u_L^k]^T \in \mathbf{R}^L$ とおき、差分バーガーズ方程式の安定化境界制御を以下のように定式化する。

[問題 2] (39) を満たす任意の初期値 u^1 に対して、制御項付き差分バーガーズ方程式 (37) が漸近安定化、すなわち、ある定数ベクトル $u^* \in \mathbf{R}^L$ が存在し、

$$u^\infty = u^* \quad (40)$$

となるように制御則 $s_{l^*}^k$ を設計せよ。

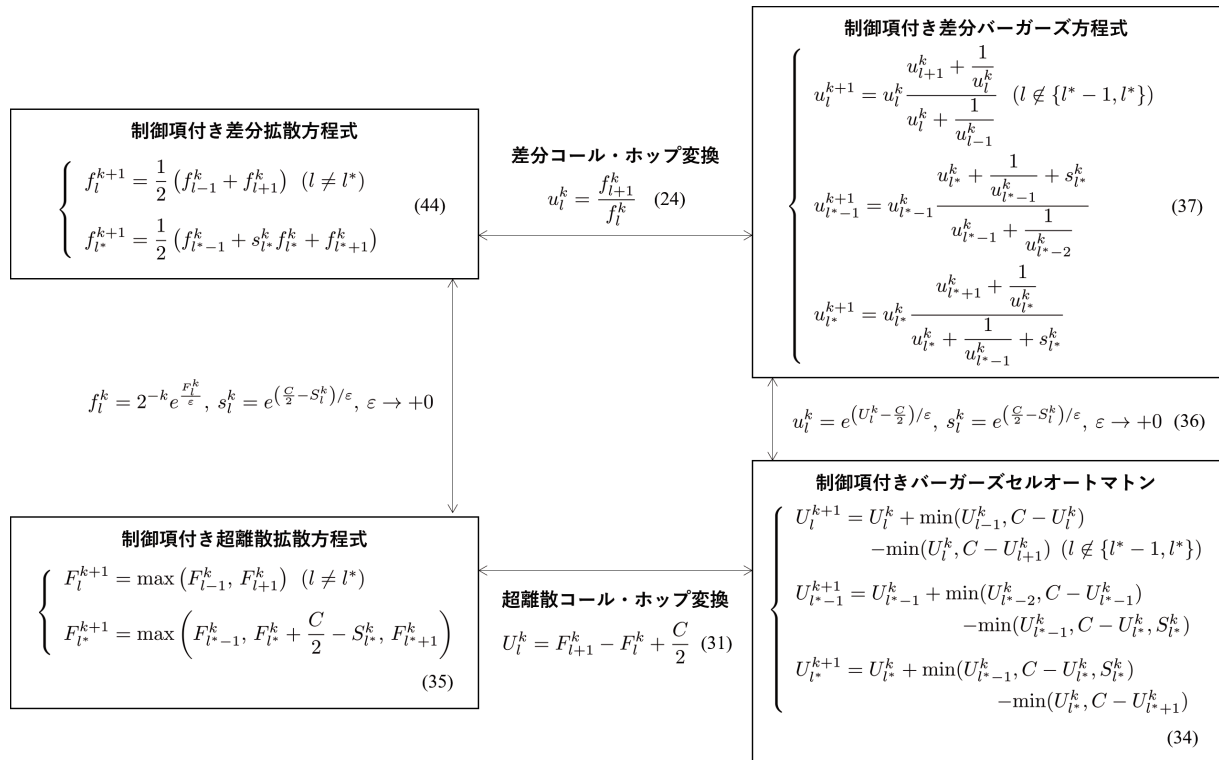


図 16 制御項付きバーガーズセルオートマトン/超離散拡散方程式/差分バーガーズ方程式/差分拡散方程式の関係図式

問題 2 の制御項付き差分バーガーズ方程式の安定化境界制御を実現するような制御則の設計を行うが、まず、制御項付きバーガーズセルオートマトン (34) に対する結果を以下に示す。

[定理 2] 制御項付きバーガーズセルオートマトン (34) に対し、制御項 $S_{l^*}^k$ を、

$$S_{l^*}^k = \frac{C}{2} \quad (41)$$

のように設計する。このとき、(41) を印加した制御項付きバーガーズセルオートマトンは、

$$k^* \leq \begin{cases} L & (L: \text{奇数}) \\ L+1 & (L: \text{偶数}) \end{cases} \quad (42)$$

を満たす時間ステップ k^* で有限次元安定化、すなわち、

$$U_l^k = \frac{C}{2}, \forall k \geq k^*, \forall l \in \{1, \dots, L\} \quad (43)$$

が成り立つ。

定理 2 では、提案した制御則 (41) を用いることにより、制御項付きバーガーズセルオートマトン (34) が (42) を満たすような有限ステップ k^* で必ず安定化することが証明されており、その最大時間ステップはバーガーズセルオートマトンのセルのサイズ L とほぼ同じであることが数学的に示されている。ここで数値シミュレーションによって確認を行うが、バーガーズセルオートマトンの総セル数について $L = 20$ と設定する。また $C = 8$ の場合を考え、初期値は条件 (38) を満たすようにランダムで決定した。更に、制御入力を印加できるセルとしては $l^* = 11$ の

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	7	1	2	3	2	5	0	0	7	5	7	6	8	3	2	1	6	1	8	6
2	1	7	1	2	3	2	5	0	4	7	6	8	3	5	3	2	1	7	6	7
3	7	1	7	1	2	3	2	5	3	6	8	3	5	3	5	3	2	6	7	1
4	1	7	1	7	1	2	3	2	6	8	3	5	3	5	3	5	3	7	1	7
5	7	1	7	1	7	1	2	3	8	4	4	3	5	3	5	3	7	1	7	1
6	1	7	1	7	1	7	1	5	4	4	4	4	3	5	3	7	1	7	1	7
7	7	1	7	1	7	1	7	2	4	4	4	4	4	3	7	1	7	1	7	1
8	1	7	1	7	1	7	2	6	2	4	4	4	4	6	1	7	1	7	1	7
9	7	1	7	1	7	2	6	2	6	2	4	4	6	2	6	1	7	1	7	1
10	1	7	1	7	2	6	2	6	2	6	2	6	2	6	2	6	1	7	1	7
11	7	1	7	2	6	2	6	2	6	2	6	4	4	2	6	2	6	1	7	1
12	1	7	2	6	2	6	2	6	4	4	4	4	2	6	2	6	2	6	1	7
13	7	2	6	2	6	2	6	4	4	4	4	4	2	6	2	6	2	6	1	7
14	2	6	2	6	2	6	4	4	4	4	4	4	4	2	6	2	6	2	6	6
15	6	2	6	2	6	4	4	4	4	4	4	4	4	4	2	6	2	6	2	6
16	2	6	2	6	4	4	4	4	4	4	4	4	4	4	4	2	6	2	6	6
17	6	2	6	4	4	4	4	4	4	4	4	4	4	4	4	4	2	6	2	6
18	2	6	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	2	6
19	6	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	2
20	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4

図 17 制御項付きバーガーズセルオートマトンの制御シミュレーション

場合を考える。図 17 は横方向をセル l 、縦方向を時間 k として、各セルの値がプロットしてあり、制御項付きバーガーズセルオートマトンの時間発展が示されている。定理 1 より $L+1 = 21$ ステップまでには安定化が完了することになるが、図 17 より 20 ステップに全てのセルが目標値 $C/2 = 4$ となっており、理論どおりに安定化が達成されていることが分かる。更に、制御入力を印加できるセルをそのほかに設定しても、全ての場合において 21 ステップ以内で安定化することが確認できている。

そして、制御項付き差分バーガーズ方程式 (37) と差分コル・ホップ変換 (24) に対応する制御項付き差分拡散方程式は (44) で与えられることが分かり、ここで $f_l^k \in \mathbf{R}$ は時間 k 、セ




図 18 差分バーガーズ方程式の制御シミュレーション

ル l における制御項付き差分拡散方程式の変位である。この制御項付き差分拡散方程式と定理 2 を用いることによって、制御項付き差分バーガーズ方程式 (37) の安定化に関する以下の重要な定理を得ることができる。

[定理 3] 制御項付き差分バーガーズ方程式 (37) に対して、制御項 $s_{l^*}^k$ を、

$$s_{l^*}^k = 1 \quad (45)$$

のように設計する。このとき、(45) を印加した差分バーガーズ方程式は、(39) を満たす任意の初期状態 u^1 に対して漸近安定となる。更に、以下で定義される行列 $A \in \mathbf{R}^{L \times L}$

$$A = \frac{1}{2} \begin{bmatrix} 0 & 1 & \cdots & 0 & 0 & 0 & \cdots & 0 & 1 \\ 1 & 0 & \cdots & 0 & 0 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & 0 & 1 & 0 & \cdots & 0 & 0 \\ 0 & 0 & \cdots & 1 & 1 & 1 & \cdots & 0 & 0 \\ 0 & 0 & \cdots & 0 & 1 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & 0 & 0 & 1 & \cdots & 0 & 1 \\ 1 & 0 & \cdots & 0 & 0 & 1 & \cdots & 1 & 0 \end{bmatrix} < l^* \quad (46)$$

の最大固有値の固有ベクトルを $p^* = [p_1^* \cdots p_L^*]^\top \in \mathbf{R}^L$ とすると、制御項付き差分バーガーズ方程式 (5) の収束値は、

$$u_l^\infty = \frac{p_{l+1}^*}{p_l^*} \quad (l = 1, \dots, L) \quad (47)$$

で与えられる。ただし、 $p_{L+1}^* = p_1^*$ とする。

定理 3 は、制御入力を施した差分バーガーズ方程式の漸近安定性の保証、並びに安定状態の収束値の計算方法を示しており、簡単な定数行列 A の固有ベクトルから計算可能であることは興味深いといえる。

ここで、差分バーガーズ方程式に対する安定化境界制御法を用いて数値シミュレーションを行い、有効性を検証する。総時間ステップ数を $K = 100$ 、総セル数について $L = 50$ と設定し、初期値は条件 (39) を満たすようにランダムで決定した。また、制御入力を印加できるセルとしては $l^* = 26$ の場合を考える。図 18 にシミュレーション結果が示してあり、初期状態 ($k = 1$)、中間状態 ($k = 10, 50$) 並びに最終状態 ($k = 100$) における差分バーガーズ方程式の形状がプロットしてある。初期状態から徐々に変化し、最終状態ではシステムがある安定状態に収束していることが分かり、これは定理 3 における理論収束値 (47) に一致することが固有ベクトルの計算から確認できる。

本節では、バーガーズ方程式を制御対象として、超離散化に基づく制御系設計法を示したが、筆者らは KdV 方程式と呼ばれる非線形偏微分方程式に対しても制御系設計を試みており⁽²⁶⁾、超離散化の性質を利用した非線形偏微分方程式に対する制御系設計の研究は、まだまだ未解決問題を数多く含んでいる。

4. おわりに

本解説では、「離散力学」と「超離散化」という 2 種類の離散化手法を通して、「非線形偏微分方程式に潜む離散構造」を考え、更に制御工学への応用について解説した。離散力学も超離散化もまだ発展途上の研究分野であり、制御工学以外にも様々な分野への応用可能性を秘めていると考えられる。更にこのような理論は、デジタル全盛時代における連続 (現実世界) と離散 (コンピュータ) の間における、高い親和性をもつ橋渡し役と

して、今後需要が高まると予想される。本解説が離散力学・超離散化に興味をもつきっかけとなれば大変幸いである。

謝辞 本解説の執筆をご提案・ご承認頂いた非線形問題研究会の専門委員の皆様、並びに Fundamental Review 誌の編集委員の皆様にご礼申し上げます。

文 献

- (1) 柴田良弘, 久保隆徹, 非線形偏微分方程式, 朝倉書店, 東京, 2012.
- (2) 田中光宏, 非線形波動の物理, 森北出版, 東京, 2017.
- (3) J.E. Marsden, G.W. Patrick, and S. Shkoller, “Multisymplectic geometry, variational integrators and nonlinear PDEs,” *Comm. in Math. Phys.*, vol.199, pp.351–395, 1998.
- (4) C. Kane, J.E. Marsden, M. Ortiz, and M. West, “Variational integrators and the newmark algorithm for conservative and dissipative mechanical systems,” *Int. J. for Numer. Meth. in Engineering*, vol.49, pp.1295–1325, 2000.
- (5) J.E. Marsden and M. West, “Discrete mechanics and variational integrators,” *Acta Numerica*, vol.10, pp.3571–5145, 2001.
- (6) O. Junge, J.E. Marsden, and S. Ober-Blöbaum, “Discrete mechanics and optimal control,” *Proc. 16th IFAC World Congress, Praha, Czech Republic*, paper no.We-M14-TO/3, 2005.
- (7) T. Kai and K. Bito, “A new discrete mechanics approach to swing-up control of the cart-pendulum system,” *Communications in Nonlinear Science and Numerical Simulation*, vol.19, pp.230–244, 2014.
- (8) T. Kai and T. Shibata, “Gait generation for the compass-type biped robot on general irregular grounds via a new blending method of discrete mechanics and nonlinear optimization,” *Journal of Control, Automation and Electrical Systems*, vol.26, no.5, pp.484–492, 2015.
- (9) T. Kai, K. Yamaki, and S. Koike, “Development of discrete mechanics for distributed parameter mechanical systems and its application to vibration suppression control of a string,” *Proc. 13th Int. Conf. Informatics in Control, Automation and Robotics, Lisbon, Portugal*, pp.492–498, 2016.
- (10) T. Kai and K. Yamaki, “Vibration suppression control of an Euler-Bernoulli beam via a new blending method of discrete mechanics and nonlinear optimization,” *Proc. SICE Annual Conf. 2016, Tsukuba, Japan*, pp.1087–1090, 2016.
- (11) T. Kai and K. Yamaki, “Development of discrete mechanics for 2-dimensional distributed parameter mechanical systems and its application to vibration suppression control of a film,” *Proc. Int. Symp. NOLTA 2016, Yugawara, Japan*, pp.638–641, 2016.
- (12) T. Kai and K. Yamaki, “Discrete mechanics for 1-dimensional distributed parameter mechanical systems under free boundary conditions and its application to vibration suppression control of free-fixed strings,” *Proc. SICE Annual Conf. 2017, Kanazawa, Japan*, pp.361–364, 2017.
- (13) T. Kai and K. Yamaki, “A discrete mechanics approach to vibration suppression control of free-fixed Euler-Bernoulli beams,” *Proc. Int. Symp. NOLTA 2018, Tarragona, Spain*, pp.638–641, 2018.
- (14) T. Kai and H. Yasumi, “Trajectory tracking control for 2-dimensional distributed parameter mechanical systems via a blending method of discrete mechanics and nonlinear optimization,” *Proc. Int. Symp. NOLTA 2019, Kuala Lumpur, Malaysia*, pp.316–319, 2019.
- (15) 八住拓利, 甲斐健也, “1次元非線形分布定数力学システムに対する離散力学と非線形最適化の融合による制御手法の開発,” *信学技報, CAS2019-73*, pp.53–58, 2020.
- (16) T. Kai and M. Koike, “A blending stabilization method of discrete mechanics and nonlinear optimization for 2-dimensional nonlinear films,” *Proc. Int. Symp. NOLTA 2022, Online*, p.309, 2022.
- (17) 寒野善博, 土谷隆, 基礎系 数学 最適化と変分法, 丸善出版, 東京, 2014.
- (18) 大塚敏之, 非線形最適制御入門, コロナ社, 東京, 2011.
- (19) K. Nishinari and D. Takahashi, “Analytical properties of ultradiscrete Burgers equation and Rule-184 cellular automaton,” *J. Phys. Soc. Jpn.*, vol.63, pp.3609–3618, 1998.
- (20) 広田良吾, 高橋大輔, 差分と超離散, 共立出版, 東京, 2003.
- (21) 時弘哲治, 箱玉系の数理, 朝倉書店, 東京, 2010.
- (22) K. Nishinari and D. Takahashi, “A new deterministic CA model for traffic flow with multiple states,” *J. Phys. A: Math. Gen.*, vol.32, pp.93–104, 1999.
- (23) T. Kai and M. Sato, “Model-predictive-type signal control for a Burgers’ cellular automaton traffic flow model based on particle swarm optimization,” *Proc. IFAC World Cong. 2020, Online*, paper no.429, 2020.
- (24) 甲斐健也, 田邊瑛士, “バーガーズセルオートマトンに対する安定化境界制御と安定性解析,” *信学技報, NLP2023-68*, pp.44–47, 2023.
- (25) 田邊瑛士, 甲斐健也, “バーガーズセルオートマトンに対する安定化境界制御と安定性解析,” *信学技報, NLP2023-134*, pp.58–61, 2024.
- (26) 荒井優海, 甲斐健也, “超離散化手法に基づく KdV 方程式の安定化制御,” *信学技報, NLP2023-13*, pp.1–4, 2023.

(NLP 研究会提案, 2024 年 6 月 19 日受付,

2024 年 6 月 27 日再受付)



甲斐健也 (正員)

2005 東京大学大学院新領域創成科学研究科博士課程終了。2005 大阪大学大学院工学研究科助手。2007 同大学大学院工学研究科助教。2010 九州大学大学院情報科学研究院助教。2012 東京理科大学基礎工学部講師。2018 東京理科大学基礎工学部准教授。2021 東京理科大学先進工学部准教授, 現在に至る。制御工学, 非線形システム論の研究に従事。博士(科学)。

ノイジーラベルを用いた画像分類

Learning with Noisy Labels for Image Classification

吉田 壮 Soh YOSHIDA

アブストラクト 深層ニューラルネットワークは画像分類タスクにおいて成果を上げている一方で、誤ったラベル(ノイジーラベル)に対して脆弱であることが知られている。本稿では、ノイジーラベルが存在する状況下における頑健な学習手法について概説する。まず、本稿が対象とするノイジーラベルの定義とそのパターンについて述べる。その後、ノイジーラベルを含む実世界データセットを紹介し、ノイジーラベルへの頑健性を高めるための手法として注目される半教師あり学習の概要を述べる。最後に、正則化、ラベル補正、サンプル選択に基づくノイジーラベルへの頑健化手法、並びにサンプル選択と半教師あり学習を組み合わせた手法について述べる。

キーワード 画像分類, ノイジーラベル, 半教師あり学習, 正則化, ラベル補正, サンプル選択

Abstract Deep neural networks have achieved remarkable success in image classification tasks, but their performance is known to be vulnerable to incorrect labels, also known as noisy labels. In this paper, we provide a comprehensive overview of robust learning methods designed to mitigate the impact of noisy labels. We first define the concept of noisy labels and discuss the different patterns of label noise. We then introduce real-world datasets that contain noisy labels and outline a promising approach to semisupervised learning for improving robustness against label noise. Finally, we explore the details of methods that enhance robustness to noisy labels, including regularization, label correction, sample selection, and the combination of sample selection with semisupervised learning.

Key words Image classification, Noisy labels, Semisupervised learning, Regularization, Label correction, Sample selection

1. はじめに

深層ニューラルネットワーク(DNN)は画像分類、物体検出、セグメンテーションなどのコンピュータビジョンタスクで成果を上げている。DNNの目覚ましい発展は、大量の正確にラベル付けされたデータに大きく依存している。ImageNet⁽¹⁾のような大規模データセットは、DNNの開発において重要な役割を果たしている。しかし、信頼性の高いラベル付きデータが常に大量に利用可能とは限らない。クラウドソーシングサービスAmazon Mechanical Turkやオンライン検索エンジンを利用した非専門家によるデータ収集では、信頼性の低いラベルが発生する可能性が高くなる。更に、専門家であっても、アノテーションは複雑で時間がかかるプロセスであり、結果として不正確なラベルが付与される可能性がある。このような信頼性の低いラベルはノイジーラベル(noisy label)と呼ばれている。

DNNの学習はノイジーラベルの影響を受けやすいことが知られている⁽²⁾。これはDNNのモデルパラメータが膨大であるため、ノイジーラベルにも過剰適合してしまうためである⁽³⁾。ま

た、DNNがノイジーラベルの割合に関係なく、訓練データセット全体に適合できることが実証されている。データ拡張、重み減衰、ドロップアウト、バッチ正規化など、現在一般的な正則化手法だけでは、過剰適合の問題を完全に克服できない。したがって、ノイジーラベルが存在する状況下で優れた汎化能力を実現することは、重要な課題である。本稿では、画像の分類問題に焦点を当て、ノイジーラベルに頑健な学習方法について解説する。

2. 予備知識

本章では、ノイジーラベル学習の予備知識について述べる。まず、2.1節でノイジーラベルの定義を与え、2.2節でノイズのパターンについて説明する。最後に、2.3節で早期学習現象と記憶効果について説明する。

2.1 対象とするノイズ

ノイズは、分類問題における画像単位のラベルや、セグメンテーション問題におけるピクセル単位のラベルなど、様々なタスクで発生する可能性がある。本稿では、画像分類タスクにおけるノイジーラベルについて議論することに焦点を当てる。画像分類タスクは、既知のデータから学習したモデルを用いて、新しいデータのクラスを予測することを目的としている。各学習サンプルには一つの観測ラベルが関連付けられていると仮定し

吉田 壮 正員 関西大学システム理工学部
E-mail sohy@kansai-u.ac.jp
Soh YOSHIDA, Member (Faculty of Engineering Science, Kansai University, 3-3-35 Yamate-cho, Suita-shi, Osaka, Japan).
電子情報通信学会 基礎・境界サイエティ
Fundamentals Review Vol.18 No.2 pp.147-157 2024年10月
©電子情報通信学会 2024

ており、このラベルは真のラベルとは異なる可能性がある。ノイジーラベルは、アノテーションの誤りや主観的なバイアスなどにより、ラベルが破損することで生成される。ラベルが真のものとは異なるサンプルをノイジーサンプル、真のラベルをもつサンプルをクリーンサンプルと呼ぶ。

本稿では、典型的な教師あり学習タスクである C クラス分類問題を考える。学習データセット $D = (\mathbf{x}_i, \mathbf{y}_i)_{i=1}^n$ が与えられているとする。ここで、 $\mathbf{x}_i \in \mathbb{R}^d$ は i 番目のサンプルの d 次元の特徴ベクトル、 $\mathbf{y}_i \in \{0, 1\}^C$ は C クラスの one-hot ラベル、 n はサンプル数である。

ノイジーラベルが存在する状況下では、アノテーションの過程でノイズが発生する可能性があるため、観測ラベル $\tilde{\mathbf{y}}$ は真のラベル \mathbf{y} とは異なる可能性がある。分類タスクは、データ空間をラベル空間にマッピングするニューラルネットワーク $f_\theta: \mathbb{R}^d \rightarrow \mathbb{R}^C$ を学習することを目的としており、損失関数 \mathcal{L} で定義される経験的リスク \mathcal{R} を最小化するための最適なパラメータ θ を見つける。

$$\mathcal{R} = \mathbb{E}_{(\mathbf{x}, \mathbf{y}) \sim D} [\mathcal{L}(f_\theta(\mathbf{x}), \mathbf{y})] \quad (1)$$

ここで、 \mathbb{E} は期待値を表す。上記のように、最終的に得られる経験的リスクは、ノイジーラベルを含む損失関数の計算プロセスのため、ノイズに対して頑健ではない。したがって、ノイジーラベルが DNN に与える悪影響を軽減するためのノイズに頑健なアルゴリズムを設計することが不可欠である。

2.2 ノイズパターン

実世界のノイズを想定した場合、ノイズの種類は大きく以下の三つに分類される。

- (1) **対称ノイズ (Symmetric noise)**: サンプルの一部のラベルをほかのクラスにランダムに置き換えることによって生成されるノイズ⁽⁴⁾。
- (2) **非対称ノイズ (Asymmetric noise)**: クラスに依存する実世界のノイズを考慮して、類似したクラス間でラベルの置き換えを行うことによって生成されるノイズ⁽⁵⁾。例えば、CIFAR-10 データセットでは “bird” クラスは “cat” ではなく “airplane” と混同される可能性が高い。
- (3) **インスタンス依存ノイズ (Instance-dependent noise)**: クラス間の類似性と個々のサンプル (インスタンス) ごとの特徴の類似性に依存した、より複雑なノイズ⁽⁶⁾。このノイズのシミュレーションの際には、DNN の予測誤差を利用して生成される⁽⁷⁾。

一般的に、実世界のデータセットにおいてそのノイズの特性を事前に定義することはできない。しかし、対称ノイズと非対称ノイズは事前に定義した割合によって、データセットに含まれるノイズの割合 (ノイズ率) を制御することが可能であることから、ノイジーラベルを用いた学習手法の評価を行うためのシミュレーション実験に用いられる。データセットには CIFAR-10/CIFAR-100 などが使用され、異なるノイズ率、例えば、対称ノイズの場合、20%、50%、80%、90% で評価が行

われることが多い。一方で、非対称ノイズの場合、ノイズ率が 50% を超える非対称ノイズでは、クラスを識別することは不可能であるため、40% のみで評価が行われる。

ノイズ遷移行列 $\mathbf{T} \in [0, 1]^{C \times C}$ は、真のクラスがクラス i のサンプルに誤ってクラス j のラベルが付与される確率を表した行列である。クラス i のサンプルにクラス j のラベルが付与される確率を表すノイズ遷移行列の成分は次式のように表される。

$$T_{i,j} = P(\tilde{Y} = j | Y = i) \quad (2)$$

ここで、 \tilde{Y} 、 Y はそれぞれノイジーラベルの分布と真のラベルの分布を表す。ノイズ率 r 、クラス数 $C = 4$ の場合、対称ノイズにおける遷移行列は式 (3)、非対称ノイズにおける遷移行列は式 (4) のように表される。なお、式 (4) は簡単のため、非対称ノイズにおける類似クラスを真のクラスと隣接するクラスとしている。

$$\mathbf{T}_s = \begin{bmatrix} 1-r & \frac{r}{3} & \frac{r}{3} & \frac{r}{3} \\ \frac{r}{3} & 1-r & \frac{r}{3} & \frac{r}{3} \\ \frac{r}{3} & \frac{r}{3} & 1-r & \frac{r}{3} \\ \frac{r}{3} & \frac{r}{3} & \frac{r}{3} & 1-r \end{bmatrix} \quad (3)$$

$$\mathbf{T}_a = \begin{bmatrix} 1-r & r & 0 & 0 \\ 0 & 1-r & r & 0 \\ 0 & 0 & 1-r & r \\ r & 0 & 0 & 1-r \end{bmatrix} \quad (4)$$

ここで、対称ノイズの遷移行列 \mathbf{T}_s では、真のラベルが i のサンプルが確率 r でほかのラベルに一律にフリップする。一方、非対称ノイズの遷移行列 \mathbf{T}_a では、真のラベルが i のサンプルが確率 r で類似するラベルにのみフリップする。このように、ノイズパターンを定義することで、ノイジーラベルを含むデータセットをシミュレートし、ノイズに対する頑健性を評価することができる。

2.3 早期学習現象と記憶効果

実際のデータにおいて、正しく分類されるサンプルと間違えて分類されるサンプルに一貫性があることが報告されている⁽⁸⁾。例えば、100 回の実験で異なるネットワークの初期化を毎回行ったにもかかわらず、正しく分類されるサンプルは一貫して正しく分類される傾向にあり、誤って分類されるサンプルは誤って分類され続ける傾向が確認されている。つまり、単純なサンプルは学習が容易であり、複雑なサンプルは学習が困難である。また、モデルは学習過程で単純なパターンを先に学習し、エポックが経過するにつれてノイジーラベルのような複雑なパターンを記憶する。

図 1 は、真のラベルのみを含むデータセットで学習した場合 (a) と 40% の対称ノイズを含んだデータセットで学習した場合 (b) における DNN の予測割合を示している。具体的には、正しく予測されたサンプルの割合を緑色で、誤って予測されたサンプルの割合を青色で、そしてノイジーラベルを記憶した割合 (ノイジーラベル付きのサンプルを真のラベルとして予測した割合) を




図 1 対称ノイズ 40%で学習した結果 ResNet-34 を CIFAR-10 データセットで学習。(a) は真のラベルのみを含むデータセットの場合で、予測が真のラベルのサンプルの割合 (緑) と誤分類されたラベルをもつサンプルの割合 (青) を示している。(b) は、ノイズラベルが付いたサンプルのうち、真のクラスを正しく予測されたもの (緑)、記憶 (予測がノイズラベルと一致) されたもの (赤)、および誤分類されたもの (青) の割合を示している (図は文献(8) から引用)。

赤色で表している。この結果はノイズラベルを含んだデータセットにおいても学習の初期段階 (0 から 20 エポック程度) は真のラベルを予測し、それ以降は徐々にノイズラベルを記憶していくことを示している。本稿では、学習の初期段階に真のラベルを予測する現象を早期学習現象 (early-learning phenomenon) と呼び、ラベルを記憶する現象を記憶効果 (memorization effect) と呼ぶ。早期学習現象は、DNN がまず単純なパターンから学習を始め、徐々に複雑なパターンを学習していくという性質に起因している。一方、記憶効果は、DNN のパラメータ数が非常に多いため、ノイズラベルにも過剰適合してしまうことが原因である。これらの性質を利用することで、ノイズラベルに頑健な学習アルゴリズムを設計することができる。例えば、早期学習現象を利用して、学習初期のモデルの出力を真のラベルの代わりに用いることで、ノイズの影響を軽減できる。また、記憶効果を利用して、学習後期のモデルの出力とラベルの不一致度合いからノイズサンプルを検出できる。

3. ノイズを含む実世界データセット

ノイズラベルを含む実世界のデータセットは、DNN のノイズ耐性を評価するために重要である。これらのデータセットは、

人工的なノイズ合成ではなく、実際のアノテーションプロセスで発生したノイズを含んでいるため、より現実的な設定でアルゴリズムの性能を検証できる。本章では、ノイズラベルを含む代表的な実世界データセットを紹介する。

- a) **ANIMAL-10N**: ANIMAL-10N^(注1) は、10 種類の動物の画像 55,000 枚で構成されるデータセットである。画像は Bing と Google の検索エンジンを用いて、動物の名前をキーワードとして収集された。その後、クラウドソーシングプラットフォームを通じて、15 人の非専門家によってアノテーションが行われた。動物の種類は、(猫, 山猫), (ジャガー, チーター), (オオカミ, コヨーテ), (チンパンジー, オランウータン), (ハムスター, モルモット) の五つのペアに分けられており、各ペア内の動物は視覚的に類似しているため、非専門家にとって判別が難しい。その結果、アノテーションの品質は完璧ではなく、ノイズラベルが含まれている。ANIMAL-10N の推定ノイズ率は約 8% である。
- b) **Food-101N**: Food-101N^(注2) は、Food-101 と同じカテゴリーの 101 種類の料理レシピの 310,009 枚の画像で構成されている。画像は、Food-101 の分類に基づいて Google, Bing, Yelp, TripAdvisor から収集された。Food-101 の画像の出典である foodspotting.com は、収集プロセスでは避けられている。各画像にはクラスラベルが割り当てられているが、それは不正確である可能性がある。一方で、学習データと検証データの一部について、0 または 1 の形式で、クラスラベルが正しいかどうかを表す 60,000 個の検証ラベルが、対象となるノイズ検出のために手動で追加されている。Food-101N の推定ノイズ率は約 18.4% である。
- c) **Clothing1M**: Clothing1M^(注3) は、大規模な衣料品画像データセットであり、14 カテゴリー (T シャツ, シャツ, セーターなど) の画像 100 万枚以上で構成されている。画像は、複数のオンラインショッピングサイトからクロールされ、商品説明文などの周辺情報も一緒に収集された。ラベル付けは、画像に付随するテキスト情報をキーワードマッチングすることで自動的に行われた。したがって、ラベルの品質は完璧ではなく、ノイズを含んでいる。また、このデータセットのノイズはインスタンス依存ノイズであることが報告されている⁽⁷⁾。推定ノイズ率は 38.5% である。Clothing1M には少量の正解ラベル付き画像も含まれており、訓練・検証・テストに使用できる。
- d) **WebVision**: WebVision^(注4) は、ImageNet と同じ 1,000 カテゴリーの画像で構成された大規模データセットである。画像は、Google と Flickr から「カテゴリ名」をキーワードとして収集された。ラベル付けは、画像のメタデータやページのテキスト情報を利用して自動的に行われ

(注1) : <https://dm.kaist.ac.kr/datasets/animal-10n>

(注2) : <https://kuanghui.github.io/Food-101N>

(注3) : <https://www.floydhub.com/lukasmyth/datasets/clothing1m>

(注4) : <https://data.vision.ee.ethz.ch/cvl/webvision/download.html>

た。その結果、ラベルの品質は完璧ではなく、ノイズを含んでいる。推定ノイズ率は20%程度である。WebVisionには250万枚以上の画像が含まれており、大規模なWebデータを用いた機械学習の研究に適している。また、このデータセットの一部(10万枚)に対しては、人手で正解ラベルが付与されており、これらはテストセットとして使用できる。なお、WebVisionのGoogle画像サブセットから最初の50クラスを含むmini WebVisionが使用されることもある。

これらのノイズを含む実世界データセットは、ノイズ耐性を評価するためのベンチマークとして広く使用されている。特にClothing1MとWebVisionは、研究コミュニティで最も一般的に使用されているデータセットであり、現在のノイズラベル学習手法の性能比較に欠かせない存在となっている。ただし、これらのデータセットには以下のような制約もある。

- ノイズの種類や分布が明示的に与えられていない。
- 正解ラベルが全サンプルに対して付与されていない。
- ノイズの割合が極めて高い場合の評価ができない。

そのため、人工的にノイズを合成したデータセットと組み合わせることで、より詳細なアルゴリズムの特性評価が可能となる。

4. 半教師あり学習

半教師あり学習は、ラベル付きデータ $\mathcal{X} = \{(\mathbf{x}_b, \mathbf{y}_b)\}_{b=1}^B$ とラベルなしデータ $\mathcal{U} = \{\mathbf{u}_b\}_{b=1}^B$ を含むデータセットから学習することを目的とした枠組みである。ここで、 $\mathbf{u}_b \in \mathbb{R}^d$ はラベルなしサンプルの特徴ベクトル、 B はバッチサイズを表す。本章では、半教師あり学習の基本的なアイデアについて説明する。

4.1 疑似ラベリングと一貫性正則化

半教師あり学習は、疑似ラベリング (pseudo-labeling) と一貫性正則化 (consistency regularization) で構成される。疑似ラベリングは、ラベルなしデータに対して、現在のモデルの予測を疑似ラベルとして割り当て、それを使って学習を行う。

具体的には、ラベルなしサンプル \mathbf{u}_b が与えられたとき、その拡張である $\text{augment}(\mathbf{u}_b)$ と \mathbf{u}_b に対して同じように分類するようにモデルを強制する。ラベルなしサンプル \mathbf{u}_b が与えられた場合の最も単純な損失関数は次のように表される。

$$\|f_\theta(\text{augment}(\mathbf{u}_b)) - f_\theta(\mathbf{u}_b)\|_2^2 \quad (5)$$

ここで、 $\text{augment}(\mathbf{u}_b)$ は確率的な拡張であるため、二つの項は同一でないことに注意されたい。

半教師あり学習は、ノイズラベルを含むデータセットにおいても有効であることが知られている。その主な理由は以下の2点である。

- (1) ラベルなしデータを活用することで、ノイズの影響を軽減できる。疑似ラベリングにより、ノイズを含むラベ

ルを、モデルの予測に基づいて修正することができる。

- (2) 一貫性正則化により、ノイズに対する頑健性を高められる。ノイズを含むラベルは、データ拡張に対して不変ではないため、一貫性正則化を適用することでノイズの影響を抑制できる。

4.2 MixMatch と FixMatch

MixMatch⁽⁹⁾は、疑似ラベリングと一貫性正則化に加えて、MixUp⁽¹⁰⁾というデータ拡張手法を組み合わせた半教師あり学習アルゴリズムである。MixUpは、凸線形結合を用いて、生成された合成画像が訓練データの多様体の近くに存在することを保証する混合データ拡張手法である。混合データの生成過程では、ランダムに選択された画像ペア $(\mathbf{x}_1, \mathbf{x}_2)$ とそれらに対応するラベルのペア $(\mathbf{y}_1, \mathbf{y}_2)$ を組み合わせ、新しい混合画像 $\tilde{\mathbf{x}}$ と混合ラベル $\tilde{\mathbf{y}}$ を次のように作成する。

$$\lambda' = \max(\lambda, 1 - \lambda) \quad (6)$$

$$\tilde{\mathbf{x}} = \lambda' \mathbf{x}_1 + (1 - \lambda') \mathbf{x}_2 \quad (7)$$

$$\tilde{\mathbf{y}} = \lambda' \mathbf{y}_1 + (1 - \lambda') \mathbf{y}_2 \quad (8)$$

ここで、 λ は、ハイパーパラメータ $\alpha \in (0, \infty]$ を用いたベータ分布 $\text{Beta}(\alpha, \alpha)$ から得られたランダム混合重みを表す。

MixMatchでは、まず、ラベルなしサンプル \mathbf{u}_b に対して、事前定義したデータ拡張(例えば、ランダムな水平反転や切り出し)を適用した K 個の拡張されたデータ $\hat{\mathbf{u}}_{b,k}$ を生成する。次に、これらの拡張データに対するモデルの予測の平均を算出する。

$$\mathbf{q}_b = \frac{1}{K} \sum_{k=1}^K f_\theta(\hat{\mathbf{u}}_{b,k}) \quad (9)$$

続いて、疑似ラベルをシャープ化することで、ラベルの確信度を高める。シャープ化とは、疑似ラベルの分布をより尖らせる操作であり、次式で定義される。

$$\hat{\mathbf{y}}_b = \text{Sharpen}(\mathbf{q}_b, T) = \mathbf{q}_b^T / \sum_{c=1}^C q_{b,c}^T \quad (10)$$

ここで、 T はシャープ化のハイパーパラメータである。 $T \rightarrow 0$ としたとき、シャープ関数の出力は特定のクラスのみで1を示すone-hotラベルに近づく。

サンプル \mathbf{x}_b とそのラベル \mathbf{y}_b を含むラベル付きサンプル集合 \mathcal{X} と、ラベルなしサンプル集合 \mathcal{U} が与えられたとき、MixMatchではデータ拡張と疑似ラベル $\hat{\mathbf{y}}_b$ を用いて $\hat{\mathcal{X}} = \{(\hat{\mathbf{x}}_b, \mathbf{y}_b)\}_{b=1}^B$ 、 $\hat{\mathcal{U}} = \{(\hat{\mathbf{u}}_{b,k}, \hat{\mathbf{y}}_b)\}_{b=1}^B$ を生成する。続いて、MixUpを適用して生成された $\tilde{\mathcal{X}}, \tilde{\mathcal{U}}$ を組み合わせた損失関数を最小化することで、ネットワークを学習する。損失関数は、ラベル付きデータに対しては交差エントロピー損失を使用し、ラベルなしデータに対しては平均2乗誤差を使用する。

$$\mathcal{L}_{\mathcal{X}} = \frac{1}{|\tilde{\mathcal{X}}|} \sum_{b=1}^B H(\mathbf{y}_b, f_\theta(\tilde{\mathbf{x}}_b)) \quad (11)$$

$$\mathcal{L}_u = \frac{1}{|\mathcal{U}|} \sum_{b=1}^B \|\hat{\mathbf{y}}_b - f_\theta(\hat{\mathbf{u}}_{b,k})\|_2^2 \quad (12)$$

$$\mathcal{L} = \mathcal{L}_x + \lambda_u \mathcal{L}_u \quad (13)$$

ここで、 $H(\cdot, \cdot)$ は交差エントロピー損失、 $\lambda_u > 0$ はラベルなし損失の重みを表す。ラベルなしデータに対して平均 2 乗誤差を使用する理由は、シャープ化された擬似ラベル $\hat{\mathbf{y}}_b$ が確率分布の形式をとるためである。交差エントロピー損失は、ラベルが one-hot 形式で与えられることを前提としているが、擬似ラベルはシャープ化された確率分布であるため、平均 2 乗誤差の方が適している。

一方、FixMatch⁽¹¹⁾ は、MixMatch を更に簡略化した手法である。FixMatch では、ラベルなしデータに対して、弱い拡張 $\alpha(\cdot)$ と強い拡張 $\mathcal{A}(\cdot)$ の 2 種類の拡張を適用する。そして、弱い拡張を適用したデータに対するモデルの予測の最大値がしきい値 $\tau \in (0, 1)$ 以上の場合にのみ、強い拡張を適用したデータに対する予測を擬似ラベルとして採用する。

$$\hat{\mathbf{y}}_b = \begin{cases} \arg \max f_\theta(\alpha(\mathbf{u}_b)) & \text{if } \max f_\theta(\alpha(\mathbf{u}_b)) \geq \tau \\ \text{ignored} & \text{otherwise} \end{cases} \quad (14)$$

FixMatch の損失関数は、ラベル付き損失とラベルなし損失の和である。ラベル付き損失には交差エントロピー損失を使用し、ラベルなし損失には擬似ラベルに対する交差エントロピー損失を使用する。

$$\begin{aligned} \mathcal{L} &= \frac{1}{B} \sum_{b=1}^B H(\mathbf{y}_b, f_\theta(\mathbf{x}_b)) \\ &+ \lambda_u \frac{1}{\mu B} \sum_{b=1}^{\mu B} \mathbf{1}(\max f_\theta(\alpha(\mathbf{u}_b)) \geq \tau) H(\hat{\mathbf{y}}_b, f_\theta(\mathcal{A}(\mathbf{u}_b))) \end{aligned} \quad (15)$$

ここで、 B はミニバッチサイズ、 μ はラベルなしデータに対するミニバッチサイズの倍率、 $\mathbf{1}(\cdot)$ は指示関数を表す。

5. ノイジーラベルを用いた学習

本章では、ノイジーラベルを用いた学習における代表的な手法について解説する。まず、5.1 節で正則化に基づく手法について述べ、ノイジーラベルの記憶を防ぐための正則化項の設計について説明する。次に、5.2 節では半教師あり学習における擬似ラベルに基づくノイジーラベルの補正方法について説明する。続いて、5.3 節ではサンプル選択に基づく手法について述べ、低損失サンプルのみを選択する低損失戦略を採用した手法を紹介する。最後に、5.4 節ではサンプル選択と半教師あり学習を組み合わせる手法について説明する。

5.1 正則化に基づく手法

正則化に基づく手法は、正則化項を用いてノイジーラベルの

記憶を防ぐ手法である。代表的な手法として、Early-learning Regularization (ELR)⁽¹²⁾ がある。

ELR は、早期学習現象を利用して、学習初期のモデルの予測確率ベクトルからターゲット \mathbf{t}_i を生成する。ここで、ターゲットとは、真のクラスを表す確率ベクトルである。サンプル \mathbf{x}_i に対するターゲットは、Temporal ensemble⁽¹³⁾ の移動平均を用いて次式によって算出される。

$$\mathbf{p}_i = \text{softmax}(f_\theta(\mathbf{x}_i)) \quad (16)$$

$$\mathbf{t}_i = \beta \mathbf{t}_i + (1 - \beta) \mathbf{p}_i \quad (17)$$

ここで、 $\beta \in [0, 1]$ は移動平均の係数を表す。

サンプル数 n のラベル付きデータセット $\mathcal{D} = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^n$ が与えられたとき、クラス数 C の画像分類における損失関数は次式で算出される。

$$\mathcal{L}_{\text{CE}} = -\frac{1}{n} \sum_{i=1}^n \sum_{c=1}^C y_{i,c} \log p_{i,c} \quad (18)$$

また、この損失関数に対する勾配は次式のように表される。

$$\nabla \mathcal{L}_{\text{CE}} = \frac{1}{n} \sum_{i=1}^n \nabla f_\theta(\mathbf{x}_i) (\mathbf{p}_i - \mathbf{y}_i) \quad (19)$$

ここで、 $\nabla f_\theta(\mathbf{x}_i)$ は i 番目の入力に対するモデルのヤコビ行列を表す。サンプル \mathbf{x}_i の真のクラスが c である場合、 $y_{i,c} = 1$ となる。一方、ノイジーラベルが付与されていた場合、 $y_{i,c} = 0$ となり、 $\nabla \mathcal{L}_{\text{CE}}$ に対する勾配は逆方向となる。その結果、確率的勾配降下法 (SGD) を行うと、ノイジーラベルに対する記憶が発生する。

交差エントロピー損失の勾配に対するノイジーラベルの影響は、式 (19) の $\mathbf{p}_i - \mathbf{y}_i$ に限定される。これに基づいて、ELR ではターゲット \mathbf{t}_i とモデルの予測 \mathbf{p}_i の一致度を評価し、両者が近づくように働きかける正則化項によって、ノイジーラベルに対する記憶の発生を抑制する。

$$\mathcal{L}_{\text{ELR}} = \mathcal{L}_{\text{CE}} + \frac{\lambda}{n} \sum_{i=1}^n \log(1 - \langle \mathbf{p}_i, \mathbf{t}_i \rangle) \quad (20)$$

$$\nabla \mathcal{L}_{\text{ELR}} = \frac{1}{n} \sum_{i=1}^n \nabla f_\theta(\mathbf{x}_i) (\mathbf{p}_i - \mathbf{y}_i + \lambda \mathbf{g}_i) \quad (21)$$

ここで、 $\lambda > 0$ は正則化の強さを制御するハイパーパラメータである。また、クラス c に対する \mathbf{g}_i の要素は次式によって与えられる。

$$g_{i,c} = \frac{p_{i,c}}{1 - \langle \mathbf{p}_i, \mathbf{t}_i \rangle} \sum_{k=1}^C (t_{i,k} - t_{i,c}) p_{i,k} \quad (22)$$

この正則化項は、ノイジーラベルを含むサンプルに対する勾配を打ち消す方向に働く。なぜなら、ノイジーラベルを含むサンプルでは、真のラベル \mathbf{y}_i とターゲット \mathbf{t}_i が大きく異なるため、正則化項の勾配が主に \mathbf{p}_i を \mathbf{t}_i に近づける方向に働くからである。一方、真のラベルをもつサンプルでは、 \mathbf{y}_i と \mathbf{t}_i が近い値を取るため、正則化項の影響は小さくなる。

ELR は、更に三つの手法を用いることで、ターゲットの推定

Algorithm 1 ELR+

input: training data $\mathcal{D} = (\mathbf{x}_i, \mathbf{y}_i)_{i=1}^n$, neural networks f with trainable parameters $\theta^{(1)}, \theta^{(2)}$, regularization parameter λ , MixUp hyperparameter α , temporal ensembling momentum β , weight averaging momentum γ

- 1: $\mathbf{t}^{(1)}, \mathbf{t}^{(2)} \leftarrow \mathbf{0}_{[B \times C]}, \mathbf{0}_{[B \times C]}$ ▷ set initial average predictions
- 2: $\bar{\theta}^{(1)}, \bar{\theta}^{(2)} \leftarrow \mathbf{0}, \mathbf{0}$ ▷ set initial average weights
- 3: **for** e in $[1, num_epoch]$ **do**
- 4: **for** k in $[1, 2]$ **do**
- 5: **for** each mini-batch B **do**
- 6: $\tilde{B} \leftarrow \text{MixUp}(B, \alpha)$ ▷ apply *MixUp* augmentation
- 7: $\bar{\theta}^{(k)} = \gamma \bar{\theta}^{(k)} + (1 - \gamma) \theta^{(k)}$ ▷ apply weight averaging
- 8: From \mathcal{D} , draw a mini-batch $\{\mathbf{x}_b, \mathbf{y}_b; b \in (1, \dots, B)\}$
- 9: **for** b in \tilde{B} **do**
- 10: $\mathbf{p}_b = \text{softmax}(f_{\bar{\theta}^{(1,2)} \setminus k}(\mathbf{x}_b))$
- 11: $\mathbf{t}_{[b]}^{(k)} = \beta \mathbf{t}_{[b]}^{(k)} + (1 - \beta) \mathbf{p}_b$ ▷ apply temporal ensembling
- 12: **end for**
- 13: loss \leftarrow Eq. (20)
- 14: Update $\theta^{(k)}$ using SGD ▷ update network parameters
- 15: **end for**
- 16: **end for**
- 17: **end for**

output: θ_1, θ_2

を改善する。一つ目は、Weight Averaging⁽¹⁴⁾である。これは、学習中のモデルの重みの移動平均を用いてモデルの出力を安定化させる手法である。二つ目は、Co-teaching⁽¹⁵⁾のように2つのモデルを用いる手法である。Co-teachingでは、二つのモデルが互いにノイズの影響を受けにくいサンプルを選択し、それらを用いて学習を行う。三つ目は、MixUp⁽¹⁰⁾を用いたデータ拡張である。ELRでは、これらの手法を組み合わせたアルゴリズムをELR+と呼び、アルゴリズムをAlgorithm 1に示す。

5.2 ラベル補正に基づく手法

ラベル補正に基づく手法は、半教師あり学習における擬似ラベルに基づき、モデルの予測を用いてノイズラベルを補正する。ラベル補正に基づく手法の中でも、DivideMix⁽¹⁶⁾とTwin Contrastive Learning (TCL)⁽¹⁷⁾は代表的な例であり、それぞれ独自のアプローチでノイズラベルの問題に取り組んでいる。DivideMixは、学習初期にクリーンサンプルに対する損失が低くなり、ノイズサンプルに対する損失が高くなる傾向があることを利用して、ガウス混合モデル(GMM)を適用したラベル補正法を提案し、高い性能を達成した。一方、TCLは、損失ベースのGMMとは異なり、ラベル情報を用いない教師なしの対照学習で画像特徴表現を学習し、その特徴表現に対してGMMを構築することで、ラベル補正を行う手法である。これらの手法は、ノイズラベルを含むデータセットにおいて優れた性能を示しており、ラベル補正に基づく手法の発展に貢献している。そ

こで、本節ではDivideMixとTCLを取り上げ、それぞれの手法の詳細について解説する。

DivideMixは、各サンプルに対する損失値を算出し、クリーンとノイズの2成分GMMを全訓練サンプルに対する損失分布に適合させる。そして、サンプル \mathbf{x}_i に対するクリーンの分布に属する確率 w_i を得る。次に、MixUpの結合方法に基づき、ラベル \mathbf{y}_i とモデルの予測 \mathbf{p}_i 及びGMMの予測確率 w_i を用いて次のようにラベルを補正する。

$$\bar{\mathbf{y}}_i = w_i \mathbf{y}_i + (1 - w_i) \mathbf{p}_i \quad (23)$$

DivideMixでは、ラベル補正手法はアルゴリズムの一部として組み込まれている。DivideMixの詳細については、5.4節で述べる。損失に基づいたラベル補正手法は、損失値の算出にラベルを用いることから、その性能はラベル情報によって大きく左右され、ノイズラベルを多く含んだ高ノイズの状況下ではうまく機能しない。

近年のノイズラベルを用いた学習手法では、入力画像に対してDNNから得られる特徴表現を学習する対照学習(Contrastive Learning)⁽¹⁸⁾が高い性能を発揮している。対照学習とは、対象とする画像(アンカー)とその画像に拡張を適用して得られた画像(ポジティブ)、そしてそれ以外の画像(ネガティブ)を対象として、 d 次元の単位超球空間上でアンカーとポジティブの特徴表現は近くなるように、逆にアンカーとネガティブの特徴表現は遠くなるように学習する手法である。この学習を可能とする、サンプル \mathbf{x}_i に対する損失関数であるInfoNCE損失⁽¹⁹⁾は次式で表される。

$$\mathcal{L}_{\text{ctr}, i} = -\log \frac{\exp\left(h(\mathbf{x}_i^{(1)})^T h(\mathbf{x}_i^{(2)}) / \tau\right)}{\sum_{k=1}^{2N} \mathbf{1}_{[k \neq i]} \exp\left(h(\mathbf{x}_i^{(1)})^T h(\mathbf{x}_k) / \tau\right)} \quad (24)$$

ここで、 τ は温度パラメータ、 $\mathbf{x}_i^{(1)}$ 、 $\mathbf{x}_i^{(2)}$ は、サンプル \mathbf{x}_i にデータ拡張を適用して得られたサンプル、 $h(\cdot)$ はDNNの出力を入力とした d 次元の単位超球に非線形写像する多層パーセプトロンの出力を表す。

TCLは、ラベル情報を用いない教師なしの対照学習で画像特徴表現を学習し、その特徴表現に対してGMMを構築する。そして、GMMの予測確率を用いて、式(23)と同様にラベル補正を行う。TCLにおけるGMMは、一般的な教師なしGMMと異なり、GMMの潜在変数をGMMのパラメータを更新するためのモデルの予測で置き換える。これによって、教師なしGMMとノイズラベルの情報を接続する。この操作について、以降に詳述する。

ラベル $y \in \{1, 2, \dots, C\}$ をもつデータセット \mathcal{D} が与えられたとき、球面GMMを介して、その特徴表現 $\mathbf{v} = h(\mathbf{x})$ 上の \mathbf{x} をモデル化することを考える。入力に対する混合成分への割り当てを決定する潜在変数 $z \in \{1, 2, \dots, C\}$ を用いて、教師なしGMMは次式のように定義される。

$$\begin{aligned} p(\mathbf{v}) &= \sum_{c=1}^C p(\mathbf{v}, z = c) \\ &= \sum_{c=1}^C p(z = c) \mathcal{N}(\mathbf{v} | \boldsymbol{\mu}_c, \sigma_c) \end{aligned} \quad (25)$$

ここで、 μ_c, σ_c は正規分布 \mathcal{N} の平均と分散を表す。潜在変数 z が一様に分布している、すなわち $p(z = c) = 1/C$ であると仮定すると、 c 番めのクラスターに \mathbf{x}_i を割り当てる事後確率は次式のように定義できる。

$$\gamma_{i,c} = p(z_i = c | \mathbf{x}_i) \propto \mathcal{N}(\mathbf{x}_i | \mu_c, \sigma_c) \quad (26)$$

全てのサンプルがクリーンサンプルをもつような理想的な環境下では、潜在変数 z はラベル y と同一であり、パラメータ μ_c, σ_c 及び潜在変数 z は標準的な Expectation-Maximization (EM) アルゴリズム⁽²⁰⁾によって解くことができる。しかし、ノイズラベルを含んだ環境下では、教師なしで推定された潜在変数 z とラベル y には関連性がない。したがって、TCL はこれを関連づけるために、ノイズラベルを含んだデータセットで学習したモデルの予測 $p_\theta(y_i = c | \mathbf{x}_i)$ を $p(z_i = c | \mathbf{x}_i)$ と置き換えることで、潜在変数 z に組み込むことを提案している。更新された GMM のパラメータは次のように表される。

$$\mu_c = \text{norm} \left(\frac{\sum_i p_\theta(y_i = c | \mathbf{x}_i) \mathbf{v}_i}{\sum_i p_\theta(y_i = c | \mathbf{x}_i)} \right) \quad (27)$$

$$\sigma_c = \frac{\sum_i p_\theta(y_i = c | \mathbf{x}_i) (\mathbf{v}_i - \mu_c) (\mathbf{v}_i - \mu_c)^T}{\sum_i p_\theta(y_i = c | \mathbf{x}_i)} \quad (28)$$

ここで、 $\text{norm}(\cdot)$ は $\|\mu_c\|_2 = 1$ となるような ℓ_2 正規化を表す。

最近傍のサンプルの情報を用いてノイズラベルを検出する以前の研究^{(21), (22)}では、隣接するサンプルが同時に誤ってラベル付けされる環境下ではうまく機能しないという問題があった。TCL では、この問題に対処するために、分布外のサンプルを検出するようなノイズラベル検出法が提案されている。分布外のノイズサンプル検出は、式 (27) と式 (28) を用いて潜在変数 z とラベル y を関連づけた後、式 (26) を通じて実現できる。クラスター内距離を考慮した事後確率は次式で表される。

$$\gamma_{i,c} = \frac{\exp(-(\mathbf{v}_i - \mu_c)^T (\mathbf{v}_i - \mu_c) / 2\sigma_c)}{\sum_c \exp(-(\mathbf{v}_i - \mu_c)^T (\mathbf{v}_i - \mu_c) / 2\sigma_c)} \quad (29)$$

また、 ℓ_2 正規化は \mathbf{v} と μ_c の両方に適用されているため、 $(\mathbf{v} - \mu_c)^T (\mathbf{v} - \mu_c) = 2 - 2\mathbf{v}^T \mu_c$ と表すことができ、式 (29) は次式のように書き直せる。

$$\begin{aligned} \gamma_{i,c} &= p(z_i = c | \mathbf{x}_i) \\ &= \exp(\mathbf{v}_i^T \mu_c / \sigma_c) / \sum_c \exp(\mathbf{v}_i^T \mu_c / \sigma_c) \end{aligned} \quad (30)$$

クラス $y = c$ が与えられたとき、このクラス内のサンプルはクリーンサンプルである分布内のサンプルと、ノイズサンプルである分布外のサンプルの二つに分けて考えることができる。また、あるサンプル \mathbf{x}_i が分布内に属する確率を推定するために、次式の条件付き確率を定義する。

$$\begin{aligned} \gamma_{y=z|i} &= p(y_i = z_i | \mathbf{x}_i) \\ &= \exp(\mathbf{v}_i^T \mu_{z_i} / \sigma_{z_i}) / \sum_c \exp(\mathbf{v}_i^T \mu_c / \sigma_c) \end{aligned} \quad (31)$$

式 (29) と式 (31) は、同じような式であるが、異なる計算をしている。具体的には、式 (29) は一つのサンプルが c 番めのクラスに属する確率を計算し、式 (31) ではある一つのサンプルが

分布内に属する確率を計算しているという点で異なる。一方で、ある一つのサンプルが分布外に属する確率は、次式のように表される。

$$\begin{aligned} \gamma_{y \neq z|i} &= p(y_i \neq z_i | \mathbf{x}_i) \\ &= 1 - p(y_i = z_i | \mathbf{x}_i) \end{aligned} \quad (32)$$

更に、各サンプルに対してクリーンな確率 $\gamma_{y=z|i}$ を自動的に推定するために、次式に示す 2 成分 GMM を用いる。

$$p(\gamma_{y=z|i}) = \sum_{k=0}^1 p(\gamma_{y=z|i}, k) = \sum_{k=0}^1 p(k) p(\gamma_{y=z|i} | k) \quad (33)$$

ここで、 $k \in \{0, 1\}$ はクリーン ($k = 1$) とノイズ ($k = 0$) のクラスター番号を表す。最後に、式 (33) で定義された GMM の事後確率 $w_i = p(k = 1 | \gamma_{y=z|i}) \in [0, 1]$ を用いて、式 (23) のラベル補正を行う。

5.3 サンプル選択に基づく手法

正則化に基づく手法やラベル補正に基づく手法とは異なり、サンプル選択に基づく手法は、訓練データの一部を選択的に用いることでノイズラベルの影響を軽減することを目的としている。具体的には、低損失サンプルはクリーンサンプルである可能性が高く、高損失サンプルはノイズサンプルである可能性が高いという仮定に基づき、図 2 のように低損失サンプルのみを選択する低損失戦略 (small-loss strategy) を採用している。これにより、ノイズサンプルを学習に用いないようにすることで、モデルの頑健性を高めることができる。低損失戦略を採用した代表的な手法として、MentorNet⁽²³⁾、Co-teaching⁽¹⁵⁾、Co-teaching+⁽²⁴⁾がある。

MentorNet は、カリキュラム学習⁽²⁵⁾の考え方を取り入れた手法である。この手法では、事前定義されたカリキュラムを近似する Self-paced MentorNet が存在し、StudentNet と呼ばれるメインモデルの訓練サンプルを選択するために、追加のモデルを事前に訓練する。具体的には、事前訓練されたモデルを用いて StudentNet の訓練サンプルに重み付けを行い、StudentNet の頑健性を向上させる。しかし、この手法では一度誤ってサンプルに重み付けされた場合、その影響が維持され続けるために、エラーが蓄積してしまうという問題がある。




図 2 サンプル選択の概要 低損失戦略は低損失サンプルのみを選択して学習する。

Co-teaching は、エラーの蓄積を防ぐために二つのモデルを用いて学習を行う。訓練過程では、一方のモデルで低損失戦略を用いて低損失サンプルを選択し、もう一方のモデルに対する訓練サンプルとして用いる cross-update を導入した。このように、二つのモデルを交互に用いてサンプリングを行うことで、異なる訓練サンプルが選択されるため、エラーの蓄積を緩和することができる。しかし、学習が進むにつれて二つのモデルの出力は収束してしまう。したがって、MentorNet と同様にエラーの蓄積問題に直面してしまう。

Co-teaching+ は、Decoupling⁽²⁶⁾ を導入することで、二つのモデル出力の収束を防ぐ。Decoupling は、二つのモデルの出力が不一致であるサンプルを訓練に用いる手法である。これは、学習の後半において、モデルのパラメータ更新のほとんどがノイズサンプルによるものであり、クリーンサンプルはほとんど訓練に影響しないためである。ゆえに、二つのモデルの出力が一致するような十分に学習されたサンプルを省いてモデルの訓練を行い、ノイズラベルへの頑健性を高めている。この Decoupling を用いて、Co-teaching+ は低損失戦略に基づいて選択した低損失サンプルのうち、二つのモデルの出力が不一致であるサンプルのみを用いてモデルの訓練を行う。これにより、二つのモデルの出力の収束を防ぎつつ、学習を行うことができる。

サンプル選択に基づく手法は、正則化に基づく手法やラベル補正に基づく手法とは異なるアプローチで、ノイズラベルの影響を軽減することを目的としている。これらの手法は高い頑健性を発揮している一方で、訓練データの一部のみを学習に用いることから、利用可能な訓練データ全てを有効活用することができていないという問題がある。

5.4 サンプル選択と半教師あり学習を組み合わせた手法

サンプル選択において有効活用されていない訓練データを用いる効果的な方法は、半教師あり学習と組み合わせる方法である。具体的には、図3に示されるように、サンプル選択によってクリーンサンプルとみなされたサンプルのラベルを用いてモデルを学習し、残りのサンプルはラベルなしデータとして活用する。この方法により、サンプル選択で有効活用されていない訓練データを半教師あり学習に利用することができる。本節では、代表的な手法として DivideMix⁽¹⁶⁾ について説明し、幾つかの関連手法についても紹介する。

DivideMix は、サンプル選択と半教師あり学習を組み合わせることで、顕著な性能向上を達成した手法である。この手法では、モデルが学習初期にクリーンサンプルを先に学習する傾向があることを利用し、損失関数として交差エントロピーを用いて、全ての訓練サンプルでモデルのウォームアップを行う。次に、全てのサンプルに対する交差エントロピーの損失値を算出し、損失分布としてクリーンとノイズの2成分 GMM に適合させる。そして、GMM から各サンプルがクリーンの分布に属する予測確率 w_i が得られる。DivideMix では、損失値にし

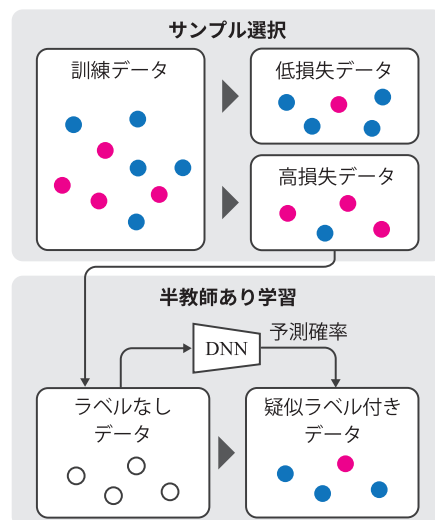


図3 サンプル選択と半教師あり学習を組み合わせた手法の概要
高損失データはラベルなしデータとして扱われ、DNN の予測確率に基づいた疑似ラベルが付与される。

きい値を用いる一般的なサンプル選択とは異なり、この確率を用いることで、もう一方のモデルの訓練サンプルの選択を行う。また、DivideMix における二つのモデルを用いたサンプル選択を co-divide と呼ぶ。GMM によるサンプル選択は、全訓練データの損失分布がクリーンサンプルの低損失分布とノイズサンプルの高損失分布の重ね合わせとして、正規分布の重ね合わせである GMM で近似できることに基づいている。すなわち、DivideMix は低損失戦略に基づいたサンプル選択手法である。

サンプル選択段階で分割された訓練データは、クリーンサンプルである可能性が高いラベル付きサンプル集合 $\mathcal{X} = \{(\mathbf{x}_b, \mathbf{y}_b)\}_{b=1}^B$ とクリーンサンプルである可能性が低いラベルなしサンプル集合 $\mathcal{U} = \{\mathbf{u}_b\}_{b=1}^B$ に分けられる。また、DivideMix は半教師あり学習手法として MixMatch を採用している。半教師あり学習段階では、式(23)のラベル補正と MixUp による補正されたラベル付き集合 $\hat{\mathcal{X}}$ 及び疑似ラベル付きサンプル集合 $\hat{\mathcal{U}}$ のデータ拡張が行われる。最終的に、次式に表される MixMatch の式(13)に正則化項を追加した損失関数を用いてモデルの訓練を行う。

$$\mathcal{L} = \mathcal{L}_{\mathcal{X}} + \lambda_u \mathcal{L}_{\mathcal{U}} + \mathcal{L}_{reg} \quad (34)$$

$$\mathcal{L}_{reg} = \sum_c \pi_c \log \left(\pi_c / \frac{1}{|\hat{\mathcal{X}}| + |\hat{\mathcal{U}}|} \sum_{\mathbf{x} \in \hat{\mathcal{X}} + \hat{\mathcal{U}}} f_{\theta}^c(\mathbf{x}) \right) \quad (35)$$

ここで、 λ_u は教師なし損失 $\mathcal{L}_{\mathcal{U}}$ の正則化の強度を制御するハイパーパラメータ、 $\hat{\mathcal{X}}, \hat{\mathcal{U}}$ は MixUp によって拡張された補正ラベル付き集合及び疑似ラベル付き集合、 f_{θ}^c はクラス c のモデル出力を表す。この正則化項は、モデルの予測確率の平均が、事前に設定した目標確率 π_c に近づくように働く。 π_c は一様分布であり、各クラスの目標確率は $\pi_c = 1/C$ と定義される。DivideMix のアルゴリズムを Algorithm 2 に示す。ここで、WarmUp(\cdot) は交差エントロピーを用いたウォームアップ、SGD(\cdot) は確率的

Algorithm 2 DivideMix

input: $\theta^{(1)}$ and $\theta^{(2)}$, Labeled data \mathcal{X} , unlabeled data \mathcal{U} , clean probability threshold τ_w , model's output softmax probability $f_{\theta^{(n)}}$, weight for unlabeled loss λ_u , batch size B , number of augmentations K , sharpening temperature T , beta distribution parameter α

- 1: $\theta^{(1)}, \theta^{(2)} = \text{WarmUp}(\mathcal{X}, \mathcal{U}, \theta^{(1)}, \theta^{(2)})$
- 2: **for** e in $[1, \text{num_epoch}]$ **do**
- 3: $\mathcal{W}^{(2)} = \text{GMM}(\mathcal{X}, \mathcal{U}, \theta^{(1)})$
- 4: $\mathcal{W}^{(1)} = \text{GMM}(\mathcal{X}, \mathcal{U}, \theta^{(2)})$
- 5: **for** $n = 1, 2$ **do**
- 6: $\mathcal{X}_e^{(n)} = \{(\mathbf{x}_i, \mathbf{y}_i, w_i) | w_i > \tau_w, \forall (\mathbf{x}_i, \mathbf{y}_i, w_i) \in (\mathcal{X}, \mathcal{W}^{(n)})\}$
- 7: $\mathcal{U}_e^{(n)} = \{\mathbf{u}_i | w_i < \tau_w, \forall (\mathbf{u}_i, w_i) \in (\mathcal{U}, \mathcal{W}^{(n)})\}$
- 8: **for** iter in $[1, \text{num_iters}]$ **do**
- 9: From $\mathcal{X}_e^{(n)}$, draw a mini-batch $\{(\mathbf{x}_b, \mathbf{y}_b, w_b); b \in (1, \dots, B)\}$
- 10: From $\mathcal{U}_e^{(n)}$, draw a mini-batch $\{\mathbf{u}_b; b \in (1, \dots, B)\}$
- 11: **for** b in B **do**
- 12: **for** k in K **do**
- 13: $\hat{\mathbf{x}}_{b,k} \leftarrow \text{augment}(\mathbf{x}_b)$
- 14: $\hat{\mathbf{u}}_{b,k} \leftarrow \text{augment}(\mathbf{u}_b)$
- 15: **end for**
- 16: $\mathbf{p}_b \leftarrow \frac{1}{K} \sum_k f_{\theta^{(n)}}(\hat{\mathbf{x}}_{b,k})$
- 17: $\bar{\mathbf{p}}_b \leftarrow w_b \mathbf{p}_b + (1 - w_b) \mathbf{p}_b$
- 18: $\bar{\mathbf{y}}_b \leftarrow \text{Sharpen}(\bar{\mathbf{p}}_b, T)$
- 19: $\mathbf{q}_b \leftarrow \frac{1}{K} \sum_k (f_{\theta^{(1)}}(\hat{\mathbf{u}}_{b,k}) + f_{\theta^{(2)}}(\hat{\mathbf{u}}_{b,k}))$
- 20: $\hat{\mathbf{y}}_b \leftarrow \text{Sharpen}(\mathbf{q}_b, T)$
- 21: **end for**
- 22: $\hat{\mathcal{X}} = \{(\hat{\mathbf{x}}_b, \bar{\mathbf{y}}_b)\}_{b=1}^B, \mathcal{P} = \{(\hat{\mathbf{u}}_b, \hat{\mathbf{y}}_b)\}_{b=1}^B$
- 23: $\mathcal{L}_{\mathcal{X}}, \mathcal{L}_{\mathcal{U}} = \text{MixMatch}(\hat{\mathcal{X}}, \mathcal{U})$
- 24: $\mathcal{L} \leftarrow \mathcal{L}_{\mathcal{X}} + \lambda_u \mathcal{L}_{\mathcal{U}} + \mathcal{L}_{\text{reg}}$
- 25: $\theta^{(n)} = \text{SGD}(\mathcal{L}, \theta^{(n)})$
- 26: **end for**
- 27: **end for**
- 28: **end for**

勾配降下法を表す。

最後に、最先端のサンプル選択と半教師あり学習を組み合わせた手法について説明する。Fine (Filtering noisy instances via their eigenvectors)⁽²⁷⁾は、ノイズラベルをフィルタリングするために、潜在表現の主成分を使用した手法である。MOIT (Multi-Objective Interpolation Training)⁽²⁸⁾は、 k 最近傍探索を行いノイズラベルを特定するために、対照学習と組み合わせ特徴表現とラベル間の一致度を定量化した手法である。LongReMix⁽²⁹⁾は、クリーンサンプルを選択するために、2段階のサンプル選択手法を提案し、信頼できるクリーンサンプル集合を選択する。OT-Filter (Optimal Transport Filter)⁽³⁰⁾は、特徴ベクトルのユークリッド空間から、確率空間への最適化輸送計画を解くことによってサンプル選択を改善した。

6. まとめ

本稿では、ノイズラベルを含む画像分類タスクにおける頑

健な学習手法について概説した。ノイズラベルは、アノテーションの誤りや主観的なバイアスなどにより発生し、DNNの学習に悪影響を及ぼす。これに対して、半教師あり学習、正則化、ラベル補正、サンプル選択など、様々なアプローチが提案されている。最後に、筆者の研究グループが行った、サンプル選択と半教師あり学習を組み合わせる際に生じる課題への取り組みについて触れておく。

まず、訓練の反復ごとにサンプル選択を行うと、ラベル付きとラベルなしデータの比が変化し、特定クラスのラベル数に偏りが生じる。この偏りは、半教師あり学習で生成される擬似ラベルの品質を低下させ、モデルの頑健性を損なう。そこで、筆者らはデータの偏りを推定し除去する手法を提案した⁽³¹⁾。複数のモデルの出力を用いてバイアスを推定し、擬似ラベルから除去することで、偏りの影響を抑制できる。

次に、サンプル選択では、信頼できるサンプルを選ぶために十分に訓練されたモデルが必要である。しかし、ノイズラベルが多く含まれるデータセットでは、モデルの訓練が不十分となり、サンプル選択の精度が低下する。また、選択されるラベル付きデータ数が極端に少なくなると、モデルが少数の信頼性の低いラベルに過適合してしまう。これらの問題に対して、筆者らはノイズラベルへの適合を抑制しつつモデルを十分に訓練する手法と、ラベル数の変動に応じて正則化の重みを調整する手法を提案した⁽³²⁾。損失関数の設計とハイパーパラメータの適応的な調整により、サンプル選択に適したモデルを学習できる。

更に、MixUpなどの混合データ拡張は、ノイズラベルへの適合を抑制する上で効果的だが、ラベルの信頼性を考慮しないランダムな混合により、クリーンなラベルを破損させてしまう恐れがある。そこで、筆者らはラベルの信頼性を考慮した混合重みの設計を行う手法を提案した⁽³³⁾。サンプル選択の結果に基づき、信頼できるラベルをもつサンプルの混合重みを高くすることで、ラベル破損を抑制し、モデルの汎化性能を高められる。

ノイズラベルを含む画像分類タスクは、機械学習における重要な課題である。今後は、実世界の複雑なノイズへの対応、画像の潜在的な特徴表現の活用、サンプル選択に依存しないラベルの信頼性推定など、更なる課題への取り組みが期待される。ノイズラベル学習の発展は、アノテーションコストの削減や、ラベル付けが困難なドメインへの機械学習の適用を促進し、実世界の様々な問題解決に貢献すると考えられる。

謝辞 本論文は関西大学大学院システム理工学専攻の東本良太氏による研究成果を基にまとめたものである。また、本研究を遂行するにあたり、関西大学システム理工学部の棟安実治教授からご助言を頂いた。ここに両氏に感謝の意を表す。

文 献

- (1) J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "ImageNet: A large-scale hierarchical image database," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.248-255, 2009.
- (2) B. Zoph, E.D. Cubuk, G. Ghiasi, T.-Y. Lin, J. Shlens, and Q.V. Le, "Learning data augmentation strategies for object detection," Proceedings of the European

- Conference on Computer Vision, pp.566–583, 2020.
- (3) C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals, “Understanding deep learning requires rethinking generalization,” *International Conference on Learning Representations*, 2017.
 - (4) B. vanRooyen, A. Menon, and R.C. Williamson, “Learning with symmetric label noise: The importance of being unhinged,” *Advances in Neural Information Processing Systems*, pp.10–18, 2015.
 - (5) C. Scott, G. Blanchard, and G. Handy, “Classification with asymmetric label noise: Consistency and maximal denoising,” *Proceedings of the Annual Conference on Learning Theory*, vol.30, pp.489–511, 2013.
 - (6) A. Garg, C. Nguyen, R. Felix, T.-T. Do, and G. Carneiro, “Instance-dependent noisy label learning via graphical modelling,” *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pp.2288–2298, 2023.
 - (7) P. Chen, J. Ye, G. Chen, J. Zhao, and P.-A. Heng, “Beyond class-conditional assumption: A primary attempt to combat instance-dependent label noise,” *Proceedings of the AAAI Conference on Artificial Intelligence*, pp.11442–11450, 2021.
 - (8) D. Arpit, S.K. Jastrzebski, N. Ballas, D. Krueger, E. Bengio, M.S. Kanwal, T. Maharaj, A. Fischer, A.C. Courville, Y. Bengio, and S. Lacoste-Julien, “A closer look at memorization in deep networks,” *International Conference on Machine Learning*, pp.233–242, 2017.
 - (9) D. Berthelot, N. Carlini, I. Goodfellow, N. Papernot, A. Oliver, and C.A. Raffel, “MixMatch: A holistic approach to semi-supervised learning,” *Advances in Neural Information Processing Systems*, pp.5049–5059, 2019.
 - (10) H. Zhang, M. Cisse, Y.N. Dauphin, and D. Lopez-Paz, “mixup: Beyond empirical risk minimization,” *International Conference on Learning Representations*, 2018.
 - (11) K. Sohn, D. Berthelot, N. Carlini, Z. Zhang, H. Zhang, C.A. Raffel, E.D. Cubuk, A. Kurakin, and C.-L. Li, “FixMatch: Simplifying semi-supervised learning with consistency and confidence,” *Advances in Neural Information Processing Systems*, pp.596–608, 2020.
 - (12) S. Liu, J. Niles-Weed, N. Razavian, and C. Fernandez-Granda, “Early-learning regularization prevents memorization of noisy labels,” *Advances in Neural Information Processing Systems*, pp.20331–20342, 2020.
 - (13) S. Laine and T. Aila, “Temporal ensembling for semi-supervised learning,” *International Conference on Learning Representations*, 2017.
 - (14) A. Tarvainen and H. Valpola, “Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results,” *Advances in Neural Information Processing Systems*, pp.1195–1204, 2017.
 - (15) B. Han, Q. Yao, X. Yu, G. Niu, M. Xu, W. Hu, I. Tsang, and M. Sugiyama, “Co-teaching: Robust training of deep neural networks with extremely noisy labels,” *Advances in Neural Information Processing Systems*, pp.8536–8546, 2018.
 - (16) J. Li, R. Socher, and S.C. Hoi, “DivideMix: Learning with noisy labels as semi-supervised learning,” *International Conference on Learning Representations*, 2020.
 - (17) Z. Huang, J. Zhang, and H. Shan, “Twin contrastive learning with noisy labels,” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.11661–11670, 2023.
 - (18) T. Chen, S. Kornblith, M. Norouzi, and G. Hinton, “A simple framework for contrastive learning of visual representations,” *International Conference on Machine Learning*, vol.119, pp.1597–1607, 2020.
 - (19) A. van den Oord, Y. Li, and O. Vinyals, “Representation learning with contrastive predictive coding,” *arXiv preprint arXiv:1807.03748*, 2018.
 - (20) A.P. Dempster, N.M. Laird, and D.B. Rubin, “Maximum likelihood from incomplete data via the em algorithm,” *Journal of the Royal Statistical Society: Series B (Methodological)*, vol.39, no.1, pp.1–22, 1977.
 - (21) J. Li, C. Xiong, and S.C. Hoi, “Learning from noisy data with robust representation learning,” *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.9485–9494, 2021.
 - (22) S. Li, X. Xia, S. Ge, and T. Liu, “Selective-supervised contrastive learning with noisy labels,” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.316–325, June 2022.
 - (23) L. Jiang, Z. Zhou, T. Leung, L.-J. Li, and L. Fei-Fei, “MentorNet: Learning data-driven curriculum for very deep neural networks on corrupted labels,” *International Conference on Machine Learning*, vol.80, pp.2304–2313, 2018.
 - (24) X. Yu, B. Han, J. Yao, G. Niu, I. Tsang, and M. Sugiyama, “How does disagreement help generalization against label corruption?,” *International Conference on Machine Learning*, vol.97, pp.7164–7173, 2019.
 - (25) Y. Bengio, J. Louradour, R. Collobert, and J. Weston, “Curriculum learning,” *International Conference on Machine Learning*, pp.41–48, 2009.
 - (26) E. Malach and S. Shalev-Shwartz, “Decoupling “when to update” from “how to update”,” *Advances in Neural Information Processing Systems*, pp.961–971, 2017.
 - (27) T. Kim, J. Ko, S. Cho, J. Choi, and S.-Y. Yun, “FINE samples for learning with noisy labels,” *Advances in Neural Information Processing Systems*, pp.24137–24149, 2021.
 - (28) D. Ortego, E. Arazo, P. Albert, N.E. O’Connor, and K. McGuinness, “Multi-objective interpolation training for robustness to label noise,” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.6606–6615, 2021.
 - (29) F.R. Cordeiro, R. Sachdeva, V. Belagiannis, I. Reid, and G. Carneiro, “LongReMix: Robust learning with high confidence samples in a noisy label environment,” *Pattern Recognition*, vol.133, 109013, 2023.
 - (30) C. Feng, Y. Ren, and X. Xie, “Ot-filter: An optimal transport filter for learning with noisy labels,” *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.16164–16174, 2023.
 - (31) R. Higashimoto, S. Yoshida, T. Horihata, and M. Muneyasu, “Unbiased pseudo-labeling for learning with noisy labels,” *IEICE Trans. Inf. & Syst.*, vol.E107-D, no.1, pp.44–48, 2024.
 - (32) R. Higashimoto, S. Yoshida, and M. Muneyasu, “CRAS: Curriculum regularization and adaptive semi-supervised learning with noisy labels,” *Applied Sciences*, vol.14, no.3, pp.1–19, 2024.
 - (33) R. Higashimoto, S. Yoshida, and M. Muneyasu, “Confidencemix: Confidence-guided mixup for learning with noisy labels,” *IEEE Access*, vol.12, pp.58519–58531, 2024.
- (SIS 研究会提案, 2024 年 6 月 16 日受付,
2024 年 6 月 26 日再受付)



吉田 壮 (正員)

2016 北海道大学大学院情報科学研究科博士後期課程了。同年関西大学システム理工学部助教。2023 関西大学システム理工学部准教授。画像認識及びマルチメディア情報検索の研究に従事。博士 (情報科学)。ACM, IEICE, IEEE, ITE 各会員。

オールフォトニクス・ネットワークに向けた 光暗号回路

Photonic Cryptographic Circuits for All-Photonics Network

高橋順子 Junko TAKAHASHI

アブストラクト 通信ネットワークから端末デバイスに至るまで光技術を活用し、低遅延、大容量通信と高速・高機能情報処理を低消費電力で実現する光情報処理基盤の実現を目指す取組みが 2019 年頃から行われている。そのような光情報処理基盤で利用される暗号などのセキュリティ機能も光技術での実現が求められており、近年その研究が行われ始めた。本稿では、光演算素子を用いて共通鍵暗号の非線形関数を構成する光暗号回路を紹介する。シリコンフォトニクス技術を利用して作製された光回路チップ及びその動作検証に関して述べ、光技術により暗号回路が具現化できていることを俯瞰する。

キーワード 光暗号回路, 光論理ゲート, 光コンピューティング, 光セキュリティ, オールフォトニクス・ネットワーク

Abstract Recently, an optical information processing infrastructure has been developed to achieve low-latency, high-capacity communication and high-speed, high-performance information processing with low power consumption. Security functions are required to implement using an optical technology for the infrastructure. Therefore, a study has begun to be proceeded. In this article, we introduce photonic cryptographic circuits using photonic logic gates to construct a non-linear function of block ciphers. We present silicon photonic chips of the cryptographic function and their experimental evaluations. We also present an overview of the realization of cryptographic circuits using the optical technology.

Key words Photonic cryptographic circuits, Photonic logic gates, Optical computing, Optical security, All-photonics network

1. はじめに

近年、通信ネットワークから端末まで全てに光技術を導入することにより、現状の電子を基本とした技術では困難な圧倒的な低消費電力、高品質・大容量、低遅延の伝送の実現を目指したオールフォトニクス・ネットワーク (All-Photonics Network (APN)) 構想に向けた取り組みが行われている⁽¹⁾。APN は光通信と情報処理の基盤となるものであり、その光情報処理基盤を実現するためには光技術をチップ内の演算処理部にも導入した光電融合技術や光演算処理が必須である。現状は電子によるコンピューティング技術を用いた演算処理が行われているが、半導体の微細化や集積化の限界により電子による演算処理性能は限界に近づきつつあるといわれている。

そこで電子によるコンピューティングの限界を打破するためにも新たな光コンピューティング技術の開発が進められている⁽²⁾。特に深層学習の分野では、学習演算に多くの時間や消費電力が必要であるため、光技術を用いることにより、それらの課題が解決できることが期待されている。実際、光集積回路を用いた Artificial Intelligence アクセラレータ (光 AI アクセラレータ) の研究が近年盛んに行われている^{(3)~(5)}。これらの研究では、光

が光速で回路を通過できるという特長を生かすことによって、電気回路に比べて低遅延及び低消費電力の演算が可能であることが示されている。2022 年に Cong らは、ニューラルネットワークの積和演算に関する光集積回路をシリコンフォトニクス技術により作製し、植物の種別を判定する例において高い正答率が得られることを実験で確認している⁽³⁾。本実験では、光集積回路の遅延は電子回路の約千分の一、回路の動作に要した電力は電子回路の数十分の一であることが示されている。また、文献⁽⁴⁾では、光演算素子を用いて深層学習のアルゴリズムを再帰的に計算する方法が提案されている。実際に作製した光電融合回路において、遅延はナノセック、消費電力はフェムトジュール単位であることを示している。更に、別の文献において、Peng らは波長多重を利用した深層学習における積和演算を計算する光電融合回路の回路構成を提案している⁽⁵⁾。本文献では、シミュレーション結果において、電気回路を用いた演算に比べて約 19 倍高速に演算できることを示している。

光 AI アクセラレータは、研究だけでなく商用に向けた開発も進められており、各社がニューラルネットワーク演算を光で実装する独自のアルゴリズムを搭載した光アクセラレータを開発している^{(6)~(9)}。例えば、Lightmatter 社は光演算素子の一種であるマッハツェンダー型変調器 (Mach-Zehnder Modulator (MZM)) を用いた光チップである ENVISE を開発している^{(6)・(7)}。Lightelligence 社は、電子チップと光インターコネクト技術を三次元積層により組み合わせたプロセッサである Hummingbird oNOC を開発し、低消費電力の AI 演算を実現している。また、同社は AI 演算のみならず、MZM による光積和

高橋順子 正員 NTT 社会情報研究所
E-mail junko.takahashi@ntt.com
Junko TAKAHASHI, Member (NTT Social Informatics Laboratories, Musashino-shi, 180-8585 Japan).

電子情報通信学会 基礎・境界サイエンス
Fundamentals Review Vol.18 No.2 pp.158-166 2024 年 10 月
©電子情報通信学会 2024

演算回路を基本としたイジングモデル用の光チップ (Photonic Arithmetic Computing Engine (PACE)) も提案している⁽⁸⁾。このように、特に AI アクセラレータの開発において光技術の適用が注目されており、演算による環境負荷の少ない光 AI アクセラレータが実現されようとしている。

1.1 光による暗号演算が可能であるか

前章で述べた光情報処理基盤においても現状の電子による情報基盤と同様にセキュリティ機能を搭載し、通信や演算の安全性を確保する必要がある。セキュリティ機能を従来の電子回路で実現する方法もあるが、情報処理基盤全体において低遅延・低消費電力の処理を実現するためには、ほかの演算と同様に、将来的には暗号や認証といったセキュリティ機能も光技術を用いて搭載する必要があると筆者らは考える。そこで、本章では光技術による暗号演算に関して述べる。

光技術によるランダム化に関する研究は、1990年代頃に画像を対象とした研究が行われていた⁽¹⁰⁾。これは、光学的相関演算⁽¹¹⁾を画像のランダム化に適用したものである。レンズを用いた光学的なフーリエ変換により入力画像を変換したのに対して、ランダム化用の位相マスクを掛け合わせ、再度フーリエ変換することにより画像を得る。元の画像に変換する際にはランダム化用の位相マスクの複素共役をマスクとして利用する。これらはレンズを用いた系であるため、実験系の空間サイズが比較的大きい。また、画像をランダム化するという特別な処理が対象であった。

一方、1990年代後半から研究開発が開始されたシリコンフォトニクス技術^(注1)、⁽¹²⁾の発展に伴い、近年、光学系の小型化・集積化が可能となった。そのため、シリコンフォトニクス技術を利用した、サーバや PC への搭載を念頭に置いた暗号演算の研究が行われ始めている。例えば、前章で述べた光 AI アクセラレータにおける行列計算を応用し、MZM を利用した光学的フーリエ変換システムによって行列演算を行う Fully Homomorphic Encryption (FHE) の演算方法や耐量子公開鍵暗号方式の演算方法が提案されている⁽¹³⁾。これらの方法では、デジタル信号を MZM を用いてアナログ信号へ変換した後に光空間においてフーリエ変換を行い、行列演算を行っている。

デジタル回路による実装に基づく暗号演算を光で実装する例として、単一の MZM を利用したバーナム暗号の実装方式が提案されている⁽¹⁴⁾。この文献では、シミュレーションにより単一の排他的論理和演算 (XOR 演算) による暗号・復号演算が可能であることが示されている。近年、複雑な暗号関数を用いた、数学的安全性に基づく既存の共通鍵暗号方式を光演算素子を用いて実装する回路方式が提案された⁽¹⁵⁾。本実装回路は光暗号回路と呼ばれており、複数段の MZM や Y-branch 素子といった光演算素子を組み合わせて共通鍵暗号方式の重要な関数の一つである非線形関数を実現している。

(注1)：半導体の微細加工技術を利用することにより、光導波路、光変調器、光送信器、光検出器などを Silicon on Insulator (SOI) 基板上に集積・加工する技術⁽¹²⁾。

このように、シリコンフォトニクス技術を用いることにより、小型化・集積化された回路内で暗号演算を行うことが可能であることが示されてきた。本稿では、通信の暗号化に標準的に用いられるデジタル回路による実装を基本とした暗号方式を光技術により実装する新たな試みである光暗号回路⁽¹⁵⁾を紹介する。

2. 光暗号回路を構成する光演算素子

本章では、光暗号回路の構成に利用される代表的な光演算素子を紹介する。

2.1 マッハツェンダー型変調器 (Mach-Zehnder Modulator (MZM))

マッハツェンダー型変調器 (MZM) は、強度変調 (または振幅変調) を利用した光変調器である⁽¹⁶⁾。光の干渉や素子の製造による挿入損失が小さく、高い消光比 (スイッチオン/オフの強度比) を得ることができるため、光 AI アクセラレータを含む多くの光回路で演算を行う際に利用されている。MZM は、電圧 (または電流) で位相変調器を制御し、二つの経路の位相差により光信号を干渉させて出力を得る。図 1 (a) に光導波路による MZM の構成図を示す。本図では、例として 2 入力、2 出力の MZM を示しており、位相変調器は下側の経路のみに搭載している (上側の経路のみ、または両経路に搭載する場合もある)。この干渉系の作用は、 2×2 の行列式で記述することが可能である⁽¹⁷⁾。図に示すとおり、MZM は二つの結合器と位相変調器から構成され、入力光を入力側の結合器で 1 対 1 に分岐し、出力側の結合器で再度合流させて光を干渉させる。位相変調器が埋め込まれた経路に電圧を印加する (オン) か否か (オフ) によって、上下の光導波路の屈折率の変化を起し、位相差を π とすることにより、二つの出力経路の光強度を変化させる。電圧の切り替えにより、光の経路が変わることから MZM は光の経路を切り替えるスイッチとして利用することができる。

図 1 (b) に MZM スwitch の動作を示す。図のとおり、上側

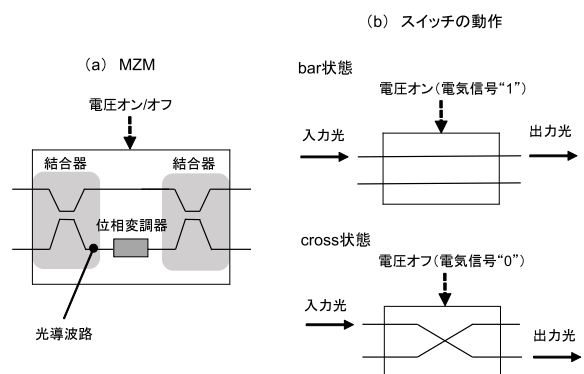


図 1 (a) MZM の構成図 MZM は二つの結合器と位相変調器から構成される。(b) MZM の動作。bar 状態では光が直進した経路から出力され、cross 状態では光が入力とは反対の経路から出力される。

の経路に光が入力された場合、入力値（電気信号）が High レベルの際（ビット“1”に相当する）には、光信号はそのまま直進した経路（上側）から出力される。これを bar 状態と呼ぶ。一方、入力値が Low レベルの際（ビット“0”に相当する）には、光信号は上下を反転させた経路であるクロスした経路（下側）から出力される。これを cross 状態と呼ぶ。上記のとおり、電圧制御により光の経路を切り替え、MZM を光の経路切り替えスイッチとして利用することが可能である。MZM は複数個接続することができ、演算の入力値に応じて複数の MZM を同時に切り替えることが可能である。そのため、経路の切り替え時間を短縮できれば、光は光速で導波路を伝搬するため、低遅延な演算を行うことが可能と考えられている。

2.2 Y-branch 素子

次に、Y-branch 素子に関して述べる。Y-branch 素子は、1 入力 2 出力の Y 分岐または 2 入力 1 出力の Y 合流として利用できる光演算素子の一種である⁽¹⁸⁾。図 2 に Y 分岐と Y 合流の回路の動作を示す⁽¹⁶⁾。

Y 分岐は 1 入力 2 出力であり、バランスのとれた分岐回路では光強度は二つの光導波路へ 50% ずつ等しく分配される。つまり、1 入力の光強度を I_i 、2 出力の光強度を I_1 及び I_2 とすると、 $I_1 = I_2 = I_i/2$ と表すことができる（振幅は $1/\sqrt{2}$ となる）。

Y 合流は 2 入力 1 出力であり、各々の入力経路の透過率が $1/\sqrt{2}$ の場合、出力強度 I は $I = (\sqrt{I_1/2} + \sqrt{I_2/2})^2$ と表される。このとき、2 入力 (I_1, I_2) のうち 1 入力のみが光が通過する状態では（例えば $I_2 = 0$ ）、光導波路への基本モードと放射モードへ等しく分岐されるため、結合された出力ポート I_i では、出力は $I_i = I_i/2$ となる⁽¹⁶⁾。ここで、半分の光強度が失われることになるが、これは放射モードに変換されて導波路外に散逸することに起因する。このように、光入力が一方のポートからのみであるときには、光出力ポートと放射モードにエネルギーが分配されるため損失が生じ、両方の入力ポートから等しい振幅の光が入力される場合のみ出力ポートから全ての光が出力される。




図 2 Y 分岐（上図）と Y 合流（下図）の動作 Y 分岐により光は分岐され、Y 合流により光は合流される。

上記より、2 入力ともに光が存在する状態のときの出力をビット“1”、1 入力のみが光が存在する状態のときと両方の入力ポートに光が存在しないときの出力をビット“0”に対応させることにより、擬似的に AND 演算などの論理演算を行うことができる⁽¹⁹⁾。このときのビット 1 とビット 0 の強度比は理想的には 4 となり、ビット 1 とビット 0 の比であるバイナリコントラストは 6dB 程となることが分かっている⁽¹⁹⁾。Y-branch 素子は複数段、カスケード接続させて論理演算を行うことが可能である。また、Y-branch 素子内を光が高速に通過できるため、低遅延の演算が可能であることが示されている。

3. 光暗号回路の概要

本章では、前章で紹介した光演算素子を用いた光暗号回路の概要を紹介する⁽¹⁵⁾。本文献では、one-hot encoding の概念を利用することにより、共通鍵暗号方式の主要な関数である Substitution box (S-box) の実装方式を提案している。

3.1 One-Hot Encoding 手法

One-hot encoding は、機械学習やデジタル回路の分野で基本となるエンコーディング方法⁽²⁰⁾であり、Regular 表現と呼ばれる $0, 1, 2, \dots, l$ の値を 0 と 1 のデジタル値で表現する⁽²¹⁾。このとき、各値を 1 ビットだけ“1”となるように設定し、それ以外は 0 の数値列で表現する。one-hot encoding は、データ表現の冗長性から単純に回路を実装すると規模が増大する。その一方で、光演算においてはアナログ信号とデジタル信号の変換の回数を削減でき、その変換に必要な消費電力などを削減できるため、光回路を用いた深層学習に関する演算でも本方式が採用されている⁽⁵⁾。

3.2 One-Hot Encoding 手法の S-box 実装への適用

文献(15)の光暗号回路では、one-hot encoding を応用して S-box を構成する。S-box は共通鍵暗号方式の一種であるブロック暗号で用いられる非線形関数であり、 n ビットの入力を m ビット出力に変換し、 2^n のテーブル置換によって実装することが可能である。光暗号回路では入力の n ビット値を光アドレスへの変換する部分と、光配線によって値をシャッフルする部分によって構成され、出力光ポートのうち正しい演算結果のみにポートに光が到着することで S-box の演算結果を得る。光アドレスへの変換では、S-box の n ビット入力値を 2^n の光アドレス値へ変換する。この光アドレス値は物理的には光ポートの番号に相当する。例えば、S-box の入力値が 4 ビット： $(x_0, x_1, x_2, x_3) = (1, 0, 0, 0)$ (x_3 が最下位ビット) のとき、光アドレス値“8”に変換される。本回路では、この入力ビット値を光アドレス値へ変換する際に MZM や Y-branch 素子といった光演算素子を用いる。

光配線によるシャッフル部では、光配線の接続により値を変換する。この光配線は物理的には光導波路で構成される。S-box

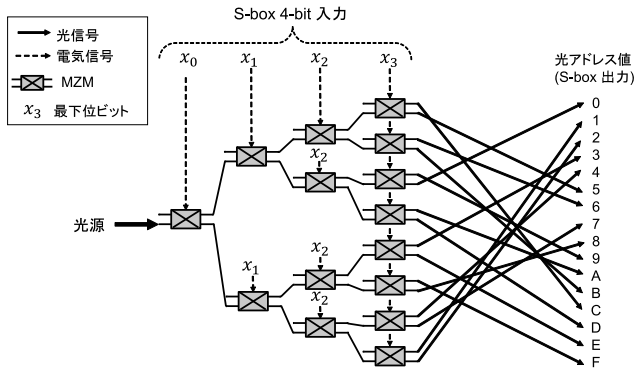


図3 光アドレス値への変換に MZM を利用した場合の S-box 回路 (a) の論理図 16 通りの光アドレス値のうち、光源から入力された光が 1 通りに到達することで演算を行う。ここで、MZM を同時に切り替えることが可能である。

演算の場合は、あらかじめ S-box テーブル変換表に基づいて光導波路を配線する。光配線は、基本的に配線による抵抗がないため、光の速度で導波路内を伝送することができる。そのため、消費電力も発生しないため、低遅延及び低消費電力の演算が期待できる。

最終的な回路の光出力は、 2^n 通りのポートのうち、一つの光ポートから出力され、これが S-box 関数の出力となる。つまり、 2^n 通りのポートのうち、1 箇所だけ光強度が高くなることにより (one-hot), S-box の出力を得ることができる。

3.3 軽量暗号 PRESENT の S-box を光で実装する

前章で述べた光回路による S-box の実装方式は原理的には任意の入出力サイズの S-box 関数を構成可能である。本稿では、S-box 関数の実装例として、軽量暗号 PRESENT の 4 ビット S-box 関数⁽²²⁾を光回路を用いて実装する方式を紹介する⁽¹⁵⁾。

軽量暗号 PRESENT は、ブロック長 64 ビット、鍵長 80 ビットまたは 128 ビットの 31 ラウンド SPN 構造の共通鍵暗号 (ブロック暗号) である⁽²²⁾。各ラウンドは、addRoundKey, sBoxLayer, pLayer の三つの関数から構成される。非線形関数である sBoxLayer は、16 個の S-box からなる。各 S-box は 4 ビット入出力のテーブル変換であり、同一の S-box が利用されている。

文献(15)では、前章で述べた入力ビットを光アドレス値に変換するために、(a) MZM を利用する方法と、(b) Y-branch 素子を利用する実装方式の 2 種類を提案している。以下に、それぞれの方式を述べる。

3.3.1 (a) MZM を利用した S-box 回路

図3に MZM を用いた場合の 4 ビット入出力の S-box 光回路の論理図を示す。本図では、光源から発せられた光が最初の段の MZM の下側の経路に挿入されることを想定する (上側の経路に MZM が入力されてもよい)。S-box の入力 は 4 ビットの電気信号 (x_0, x_1, x_2, x_3) (x_3 が最下位ビット) であり、それを




図4 S-box の入力 が 0xB (= (1, 0, 1, 1)) のときの光経路の例 光がポート 0x8 から出力され、これが S-box の出力となる。

各々の MZM へ入力する。4 ビットの電気信号に基づき、MZM 内の光が通過する経路が切り替えられ、16 通りのうちの 1 通りの光アドレス値へ変換される。このとき、MZM は同時に切り替えが可能である。光アドレス値へ変換した後は S-box テーブル変換表に基づき、あらかじめ結線された光配線を光が通過する。最終的に、16 通りの光ポートのうち一つだけ光強度が高い箇所を S-box の出力値と判定する。

図4に、S-box の 4 ビット入力値が $(x_0, x_1, x_2, x_3) = (1, 0, 1, 1)$ のときの光経路の例を示す。本図のとおり、 x_1 を入力とする MZM は cross 状態となり、ほかの MZM は bar 状態となる。よって、4 ビット入力値は光アドレス 0xB と変換され、光配線を通ったのち、光がポート 0x8 から出力される。したがって、S-box 出力は 0x8 と判定できる。

sBoxLayer は 16 個の S-box から構成される。それら全てを計算するためには、上記の回路を 16 個実装する方法もあるが、光の特長である波長多重を利用して、 $16/W$ 個 (W : 波長多重の数) の回路を用いて実装することで回路規模を抑えることが可能である。また、本回路では S-box の入力値を光アドレスに変換することにより、S-box の後続の演算である pLayer なども光アドレス値による配線のみで演算を行うことが可能である。

本回路は、入力が電気、出力が光の光電融合回路である。MZM を用いることで、高い消光比が得られるため、S-box 出力の判別が容易であるという特長をもつ。

3.3.2 (b) Y-branch 素子を利用した S-box 回路

図5に Y-branch 素子を用いた場合の 4 ビット入出力の S-box 光回路の論理図を示す。本実装では、入出力信号を光信号とする。S-box 関数の入出力を光信号とするために、4 ビット入力を 16 個の光アドレス値へ変換することを dual-rail logic による組み合わせ回路であるデコード回路⁽²³⁾を用いて行う。dual-rail logic はデジタル回路で利用される方式であり、 (x_i, \bar{x}_i) (\bar{x}_i は x_i の補数) の組み合わせを用いて回路を構成する。本回路ではデコード回路を構成するために複数段の Y-branch 素子を用いている。

図5に示すとおり、S-box 回路は 3 段の Y 分岐と 2 段の Y 合流によって 4 ビット入力を 16 個の光アドレス値へ変換する回

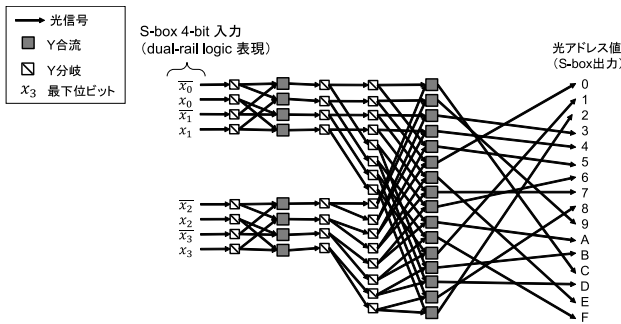


図5 光アドレス値への変換に Y-branch 素子を利用した場合の S-box 回路 (b) の論理図 最終的に最も光強度が強い光アドレス値を出力とする。

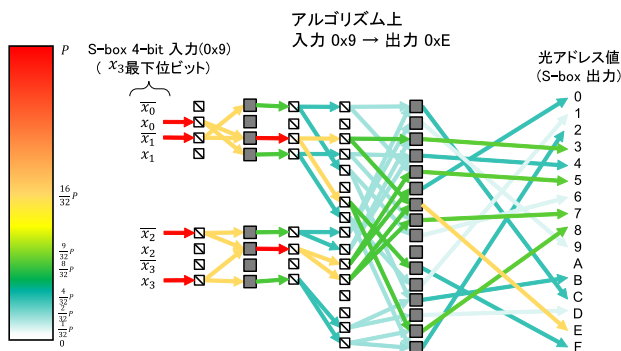


図6 S-box 入力値が 0x9 (= (1, 0, 0, 1)) のときの光経路の例 光アドレス値が 0xE の際に光強度が最も強くなり、これを S-box 出力値とする。

路と S-box テーブル変換表に基づいた光配線から構成されている。Y 合流では、擬似的な AND 演算を実現している。本回路も、前章で述べた回路 (a) と同様に、16 通りの光出力ポートのうち、最も光強度が強いポートを S-box の出力とする。このとき、3 段の Y 分岐により光が分岐されることが繰り返し行われるため、S-box の出力解とは異なる光ポート番号にも光が到達する。よって、本実装方式では適切なしきい値処理で最も強い光強度の光ポートを判定する必要がある。

図 6 に、S-box の 4 ビット入力値が $(x_0, x_1, x_2, x_3) = (1, 0, 0, 1)$ のときの光経路の例を示す。各々の経路の色は、図のカラーバーに基づいてビット 1 に対応する入力光の強度を P としたときに Y 分岐や Y 合流で変化する光強度の値を示している (0~ P)。入力の光強度が最も高いとき (P) をビット 1、光が存在しないとき (0) をビット 0 と設定する。図のとおり、取り得る光強度のパターンは理論的には 8 通りであり、15 通りの出力に光が到達するが、最も強い光強度 ($\frac{16}{32}P$) を示すポート番号が一つだけ存在する。このときの光ポート番号 (0xE) を S-box の出力値とする。これは PRESENT のアルゴリズム上の S-box 出力値と一致する。また、本実装例では、最も光強度が高い出力結果 ($\frac{16}{32}P$) と 2 番目に光強度が高い出力結果 ($\frac{9}{32}P$) の比はおおよそ 1.78 である。

本回路は、理論的には入出力ともに光信号である。Y 分岐により光が分岐され、Y 合流により擬似的な AND 演算が行われるため、前述の MZM を利用する回路 (a) に比べて消光比が劣る。よって、S-box 出力を得るためにしきい値処理が必要となる。

4. シリコンフォトニクス技術による S-box 光回路の実装

本章では、前章で紹介した光演算素子を用いて構成する S-box 回路 ((a) と (b)) に基づき、シリコンフォトニクス技術を用いて実際に作製した回路に関して述べる。

本章で紹介する S-box 光回路は、シリコン基板上に、光導波路、光変調器および受光器などの光素子を集積する技術であるシリコンフォトニクス⁽¹²⁾を用いて作製している。シリコンフォトニクスは、集積密度、エネルギー効率、実装の容易性といった観点で近年注目を集めており、通信・センサ機器及び光アクセラレータの開発に多く利用されている。

表 1 に作製した光回路チップの諸元を示す。なお、本回路では受光器はチップ外部の装置を利用するオフチップ実装としている。また、本回路は光チップの動作検証を主な目的として作製されているため、回路サイズの最適化は実施されていない。各実装方式を基に CAD 設計を行い、CAD 図面を基にした光回路チップが作製されている。

図 7 に作製された光回路チップをデジタルマイクロスコップで撮像した画像及び光演算素子を拡大した画像を示す。MZM を利用した光回路 (a) に関して、本回路では MZM を 15 個実装し、各 MZM の位相変調器部 (上下のアーム) に、熱光学効果により光の位相を変化させるためのヒータを設置している。図 7 (a) の赤枠で囲った部分の MZM は、二つの 3 dB 方向性結合器 (Directional Coupler (DC)) とヒータで構成される。本回路では、挿入損失が比較的小さい (0.1 dB 程度) という特長をもつ DC を採用している。ヒータは上下のアームに設置しているが、一つは破損用の予備として実装されており、位相変調器の動作として基本的には上側のヒータを利用している。アームに印加される電圧に応じて、両経路の位相差を π にするか否かで bar/cross 状態を制御している。また、図 7 (a) の金属部の電極パッドはヒータの制御用の電極及びグランド電極である。

Y-branch 素子を利用した光回路 (b) に関して、将来的に合流素子を Y 合流ではなく、 Ψ ゲート⁽¹⁹⁾として利用するために、3 入力 1 出力の素子を作製している。ただし、以降に述べる光回路の動作検証においては中央の導波路には光を入力せず、各素子を 2 入力 1 出力の Y 合流として利用している。Y 合流素子の入力である二つの光が合波した際に、常に同位相となるように、電流値を変化させながら各素子の較正を行う必要がある。そのため、Y 合流素子の入力部手前の導波路に移相器を設置している。本回路では実装例として、4 ビットの光信号を模擬するために、(a) の回路で用いたものと同様の熱光学効果による MZM を利用して、入力信号光の組 (x_i, \bar{x}_i) をオンチップで生成している。MZM を用いず、光信号をオフチップの信号光生成装置などで生成し、直接光信号を光回路に入力しても同様の動作は可能である。上記の移相器や MZM の制御用のヒータの制御用及びグランド電極用に 95 チャンネル分の電極パッドを実装している。また、16 通りの経路の交差数の差異による損失差が生じることを防ぐため、意図的に Y 合流の直前で交差を挿入し、同等の交差数になるように調整する工夫をしている。

表 1 光回路チップの諸元

項目	内容
基板	Silicon on Insulator (SOI) 基板
シリコン導波路の厚さ	220 nm
シリコン導波路幅	450 nm 程度
オーバークラッド (SiO ₂ 膜) の厚さ	1.0 μm 程度
チップサイズ (a)	縦 4.1 mm, 横 4.7 mm
チップサイズ (b)	縦 7.6 mm, 横 10.6 mm
MZM のサイズ	0.22 mm 程度
Y-branch 素子のサイズ	0.21 mm 程度

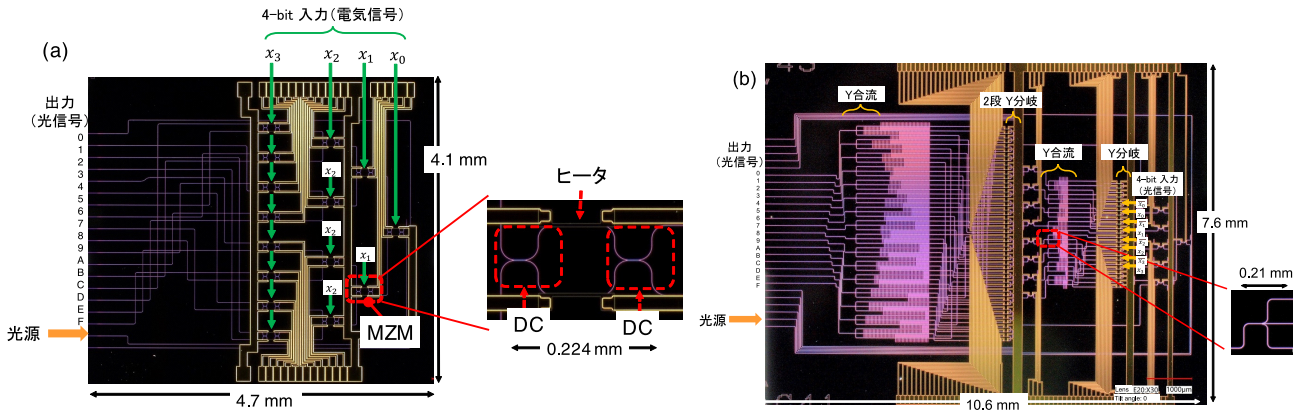


図 7 デジタルマイクロスコープにより撮影した 4 ビット S-box 演算用の光回路チップ (a) MZM を利用した光回路. (b) Y-branch 素子を利用した光回路.




図 8 光ファイバと電極を実装した S-box 光回路モジュール (a) MZM を利用した光回路の光電実装を行ったモジュール. (b) Y-branch 素子を利用した光回路の光電実装を行ったモジュール.

上記作製したチップの回路の動作を確認するためには、電極や光ファイバの接続が必要である。そこで、これらのチップに適合した端子台に、各々ダイボンディングとワイヤボンディングを行い、電極を接続している。また、光源を接続するために 160 μm ピッチのファイバアレーを作製し、光ファイバと光回路チップの光導波路を結合している。光回路チップに光電実装を行ったモジュールを図 8 に示す。本図のように電極をワイヤボンディングで実装し、電気的に固定して接続することにより、安定的な電流印加が可能となる。

5. S-box 光回路の動作検証

本章では、S-box 光回路モジュールの動作検証に関して紹介する。

5.1 実験環境

実験環境の例を以下に述べる。実験条件として、特別な温度管理を実施せず、室温 (20~25°C) で実験を実施した結果に関して記載する。表 2 に実験で利用された装置を、図 9 に動作検証のための実験環境のブロック図を示す。図 9 に示すとおり、レーザから発せられた光は偏波を補正した後、S-box 回路へ入力される。

回路 (a) の実験検証に関して、S-box 入力値に基づき、電気信号によって MZM のヒータのオン/オフを電流制御装置により制御する。このとき、各 MZM のヒータへ投入する電流値を変化させながら、cross 状態 (入力電気信号 0 に相当) から bar 状態 (入力電気信号 1 に相当) へ移行する電流値を各 MZM で

表 2 実験に利用された装置

実験装置	型番
1ch 波長可変レーザ	Keysight 81600B
電流制御装置 (Source Measure Unit (SMU))	National Instruments PXIe-4163
SMU の筐体	National Instruments PXIe-1078
光パワーメータ	Keysight N7745C
回路制御プログラム用ソフトウェア	National Instruments LabVIEW




図 9 光回路の動作検証に利用された実験環境のブロック図 レーザ光源を S-box 回路へ入力し、出力結果を光パワーメータにより測定する。(a) の場合のレーザ波長：1532 nm，強度：1.83 dBm，(b) の場合のレーザ波長：1530.02 nm，強度：0 dBm。

確認し、S-box の入力に応じて設定する電流値を計測している。なお、S-box 値の入力値に基づいた MZM の電流値の制御は、LabVIEW ソフトウェアで作製した制御プログラムを利用している。演算出力光（出力結果）は光パワーメータにより光強度を測定し、結果を PC に表示している。

回路 (b) の実験検証に関して、4 ビット入力の補数の組 (x_i, \bar{x}_i) ($i = 0, 1, 2, 3$) を生成するための MZM の電流値の制御方法に関しては上記記載の回路 (a) とほぼ同等である。位相変調器へ印加する電流値を LabVIEW ソフトウェアで制御し、二つの光信号が存在する際に合波により最も光強度が強くなるように電流値を調整している。回路 (a) と同様に、光パワーメータで出力の光強度を測定し、出力結果を PC に表示している。

5.2 実験結果

実験結果の例を以下に述べる。図 10 に、S-box の入力が (a) $0x8$ のとき、(b) $0x1$ のときの実験結果を示す。横軸は光ポート番号（光アドレス値）、縦軸は光パワーメータで測定した光出力強度を示す。

実験結果 (a) に関して、入力が $0x8$ のとき、光ポート番号 $0x3$ のときがほかと比べて最も強い光強度を示す ($177 \mu\text{W}$)。これは、PRESENT のアルゴリズム上の S-box のテーブル変換表の出力と一致する。

実験結果 (b) に関して、入力が $0x1$ のとき、光ポート番号 $0x5$ が最も強い光強度を示しており（およそ 10 nW ）、これは S-box の出力結果と一致する。回路 (b) の場合は、正しい出力値と誤りの出力値のしきい値を 6.5 nW に設定することにより、正しい出力値を判定できる。最も高い光強度と 2 番めに高い光強度の比はおよそ $1.77 (= 10.4 \text{ nW}/5.89 \text{ nW})$ であり、3.3.2 章で述べた理論的な回路動作と一致している。

実験結果 (b) では、実験結果 (a) に比べて光強度が一番高いとき（正しい S-box 演算結果）と 2 番めのとき（不正解の S-box 演算結果）の光強度の比が相対的に小さくなっている。これは、回路 (b) では Y-branch 素子を用いているが、Y 合流




図 10 S-box の入力値が回路 (a) $0x8$ 、回路 (b) $0x1$ のときの実験結果 横軸は光ポート番号 ($0x0 \sim 0xF$)、縦軸は光出力強度である。両回路において、最も高い光強度を示す光ポート番号と PRESENT のアルゴリズム上の S-box 出力結果が一致している。

が必ずしも理想的な AND 演算になっておらず、ビット 0 を示す場合でも光強度が 0 付近になっていないことが原因と考えられている。例えば、Y 合流の 2 入力 $(0, 1)$ のとき、理想的な AND 演算の結果は 0（つまり光強度は 0）となるが、Y 合流素子を用いた場合はその性質上、出力強度は $I_1/2$ となり (I_1 はビット 1 を示す光強度)、完全に光がない状態 (0 の状態) とはならないことが知られている⁽¹⁹⁾。更に回路 (b) では、Y 合流が 2 段接続されているため、0 とみなす弱い強度の光が最終的に干渉効果で強め合うことにより、出力結果の強度の消光比が低くなると考えられている。したがって、Y 合流素子の代わりに Ψ ゲートを用いることで消光比を高められる可能性があり、正しい出力結果をより容易に判定できる可能性があると考えられている。

なお、文献(15)では、回路 (a) と (b) の両方ともに、16 通りの全ての入力パターンにおいて、最も光強度が高い光ポート

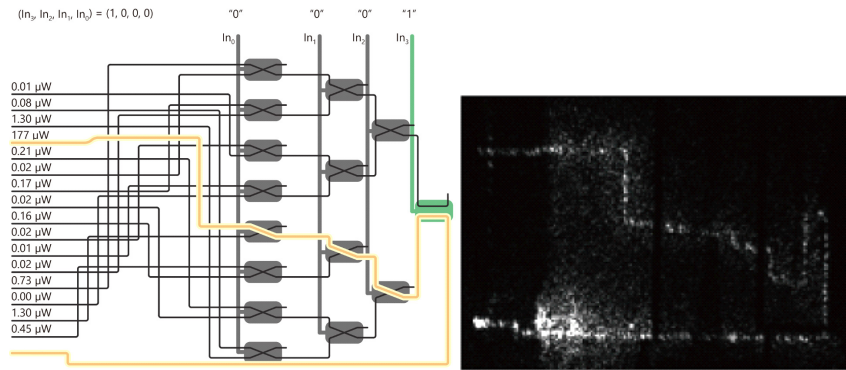


図 11 MZM を利用した回路 (a) の光回路を光が通過する様子 (S-box の入力値が 0x8 のとき) 回路レイアウトを基に LabVIEW で作成した制御プログラム (左図) と S-box 入力値に基づく光経路 (右図)．光経路の観測のため、近赤外線カメラを利用して光回路からの散乱光を取得している．光源付近で強い光の散乱が見られるが、これはファイバアレーの入力での反射を示している．

番号と S-box 出力の結果が一致していることを確認している．

正しい演算結果であることは、光経路を可視化することによっても判断できる．ここで例として、回路 (a) に関して回路の動作時に近赤外線カメラで回路を撮像した光経路からの散乱光を図 11 に示す．本図では、S-box 入力値を 0x8 と設定したときの、LabVIEW ソフトウェアで作製した制御プログラム (左図) と近赤外線カメラで撮像した光経路からの散乱光 (右図) を示している．本図において、入力値の最上位ビットのみが 1 であるため bar 状態となり、ほかの三つのビットは 0 で cross 状態をとる．4 ビットの値が光アドレス変換部分により 0x8 へ値が変換されたのち、光配線を通過して最終的に光ポート番号 0x3 から出力される様子を本図から読み取ることができる．

以上より、光回路により S-box 関数が正しく演算でき、S-box 光回路が具現化できていることが実験的にも示されている．

5.3 S-box 光回路の性能

本章の最後に、上述の光回路の性能を理論的に算出した結果を述べる．前述の回路構成は光配線を主とする特長から、伝搬遅延が小さくなると考えられるため、その評価と光回路の重要なパラメータの一つである挿入損失に関する評価を述べる．

伝搬遅延に関して、シリコンフォトニクス上における光配線では、 $100\ \mu\text{m}$ でおよそ $0.8\ \text{ps}$ の遅延とすると回路 (a) ではおよそ $47\ \text{ps}$ 、回路 (b) ではおよそ $201\ \text{ps}$ の伝搬遅延であることが示されている⁽¹⁵⁾．ただし、いずれの場合も MZM のスイッチングにかかる時間は含まれておらず、いったん、MZM の経路が確定した後の光の伝搬遅延を示している．回路 (a) は回路 (b) に比べてサイズが小さいため、その分、配線も短くなっており、伝搬遅延が小さいと考えられる．

挿入損失に関して、文献(24)に記載されている各演算素子のパラメータを用いると、回路 (a) に関しては $8\ \text{dB}$ 、回路 (b) に関しては $27\ \text{dB}$ と計算されている⁽¹⁵⁾．ここで回路 (a) に関しては、光ファイバとの接続による挿入損失を含む値である．回路 (b) に関しては、主に Y-branch 素子での損失となっており、

分岐や合流を繰り返すため、回路 (a) に比べて比較的損失が大きくなると考えられる．

6. まとめと今後の展望

最後に、光暗号回路に関する研究のまとめと今後の展望に関して述べる．

本稿では、既存のブロック暗号の非線形関数を光演算素子を用いて実装する光暗号回路の概要を紹介した．本稿で紹介したとおり、一部の暗号関数に関して、光回路で実装することができ、アルゴリズム上の関数の出力結果と一致することが確認されている．光回路における S-box の実装方法は、入力が電気、出力が光の光電融合における回路と入出力全てが光で実装可能な回路の 2 種類が提案されている．いずれの回路も具現化されており、低遅延で動作することが確かめられている．

光暗号回路は、2030 年以降にコンピューティング環境が光電融合技術を基本としたオールフォトン環境となった際に、暗号演算を行う光暗号アクセラレータとして用いられることが期待される．例えば、スマートシティ、スマートモビリティ、スマートスポーツなどといった各種スマートサービスを実現するための光ディスクアグリゲータッドコンピューティング環境^(注2)、⁽²⁵⁾において、大容量のデータ処理やリアルタイムに高い負荷の演算処理を行う際に、光暗号アクセラレータを用いることによってコンピューティング環境のセキュリティを確保することが可能となる．その結果、安全性と性能の両方を高く保つことが可能なスマートサービスを実現できると筆者らは考える．更に将来的には、地上のコンピューティング環境だけでなく、宇宙でのコンピューティング環境 (宇宙統合コンピューティング・ネットワーク⁽²⁶⁾) といった地上に比べて過酷な環境下でも利用できる光暗号回路を作製し、システムへ搭載することも考えられる．宇宙でのコンピューティング環境では、地上とは異なり、光回

(注2)：従来の箱に閉じたコンピュータをネットワークでつなぐこれまでのサーバオリエンテッドな概念から、CPU、メモリなどのハードウェアリソースを直接光で接続し、光の高速性を活かし、ラックスケールやデータセンタスケールの一つのコンピュータとして扱う概念．

路の放射線への耐性を有する必要があるなどの課題を解決していく必要がある。このように、光暗号回路は新時代の通信基盤に貢献する大きな技術へと発展することが期待される。

文 献

- (1) IOWN GLOBAL FORUM, “Innovative optical and wireless network global forum vision 2030 and technical directions,” White Paper, <https://iowngf.org/white-papers/>
- (2) 成瀬誠, 内田淳史, 内山和治, 赤羽浩一, “光の極限性能を生かすフォトニックコンピューティング—光を用いた意思決定—,” 信学 FR 誌, vol.15, no.4, pp.310–317, 2022.
- (3) G. Cong, N. Yamamoto, T. Inoue, Y. Maegami, M. Ohno, S. Kita, S. Namiki, and K. Yamada, “On-chip bacterial foraging training in silicon photonic circuits for projection-enabled nonlinear classification,” *Nature Communications*, vol.13, no.3261, June 2022.
- (4) S. Bandyopadhyay, A. Sludds, S. Krastanov, R. Hamerly, N. Harris, D. Bunandar, M. Streshinsky, M. Hochberg, and D. Englund, “A photonic deep neural network processor on a single chip with optically accelerated training,” *Proc. IEEE CLEO 2023*, pp.1–2, California, USA, May 2023.
- (5) J. Peng, Y. Alkabani, K. Puri, X. Ma, V. Sorger, and T.E. Ghazawi, “A deep neural network accelerator using residue arithmetic in a hybrid optoelectronic system,” *ACM Journal on Emerging Technologies in Computing Systems*, vol.18, no.4, article no.81, pp.1–26, Oct. 2022.
- (6) C. Demirkiran, F. Eris, G. Wang, J. Elmhurst, N. Moore, N.C. Harris, A. Basumallik, V.J. Reddi, A. Joshi, and D. Bunandar, “An electro-photonic system for accelerating deep neural networks,” *ACM Journal on Emerging Technologies in Computing Systems*, vol.19, no.4, article no.30, pp.1–31, Sept. 2023.
- (7) Lightmatter, ENVISE, <https://lightmatter.co/products/envise/>
- (8) Lightelligence, <https://www.lightelligence.ai/index.php>
- (9) M. Miscuglio, Z. Hu, S. Li, J.K. George, R. Capanna, H. Dalir, P.M. Bardet, P. Gupta, and V.J. Sorger, “Massively parallel amplitude-only Fourier neural network,” *Optica*, vol.7, no.12, pp.1812–1819, Dec. 2020.
- (10) P. Refregier and B. Javidi, “Optical image encryption based on input plane and Fourier plane random encoding,” *Optics Letters*, vol.20, no.7, pp.767–769, 1995.
- (11) 谷田純, 光計算 (ナチュラルコンピューティング・シリーズ), 萩谷昌己, 横森貴 (共編), 3.3.2 章, pp.50–54, 近代科学社, 2011.
- (12) シリコンフォトニクス 先端光テクノロジーの新展開, 金光義彦, 深津晋 (共編), オーム社, 2007.
- (13) Optalysys, “Optical computing, the hardware solution for cryptography: Fully Homomorphic Encryption,” <https://optalysys.com/wp-content/uploads/2023/10/FullyHomomorphicEncryption-Optalysys-1.pdf>
- (14) V. Agarwal and V. Chaurasia, “All optical SOA-MZI-based encryption decryption system using co propagating optical pulses and CW wave at 40 Gb/s,” *Proc. IC3T 2015, AISC*, vol.381, pp.201–208, Sept. 2015.
- (15) J. Takahashi, S. Kita, A. Shinya, K. Aoki, K. Chida, and F. Hoshino, “Photonic cryptographic circuits consisting of thermo-optic MZI switch or Y-branches,” *Proc. IEEE SiPhotonics 2024, IEEE-CS*, Tokyo, Japan, TuA4, April 2024.
- (16) 川西哲也, 高速高精度光変調の理論と実践: 電気光学効果による光波制御, 2.3 章, pp.28–35, 培風館, 2016.
- (17) C.K. Madsen and J.H. Zhao, *Optical Filter Design and Analysis: A Signal Processing Approach*, Section 3.3, pp.126–137, John Wiley & Sons, Jan. 1999.
- (18) L. Chrostowski and M. Hochberg, *Silicon Photonics Design from Devices to Systems*, Section 4.2, pp.110–113, Cambridge University Press, March 2015.
- (19) S. Kita, K. Nozaki, K. Takata, A. Shinya, and M. Notomi, “Ultrashort low-loss Ψ gates for linear optical logic on Si photonics platform,” *Communications Physics*, vol.3, 33, March 2020.
- (20) D.M. Harris and S.L. Harris, *Digital Design and Computer Architecture*, 2nd ed., Section 3.4.2, pp.129–131, ELSEVIER, 2013.
- (21) F. Jafarzadehpour, A.S. Molahosseini, A.A.E. Zarandi, and L. Sousa, “Efficient modular adder designs based on thermometer and one-hot coding,” *IEEE Trans. VLSI Syst.*, vol.27, no.9, pp.2142–2155, June 2019.
- (22) A. Bogdanov, L.R. Knudsen, G. Leander, C. Paar, A. Poschmann, M.J.B. Robshaw, Y. Seurin, and C. Vikkelsoe, “PRESENT: An ultra-lightweight block cipher,” *Proc. CHES 2007, LNCS vol.4727*, pp.450–466, Sept. 2007.
- (23) 浅川毅, 論理回路の設計, 3 章, pp.15–17, コロナ社, 2007.
- (24) 高橋順子, 北翔太, 新家昭彦, 青木和麻呂, 千田浩司, 星野文学, “All 光演算に向けた S-box 光回路の動作検証,” 暗号と情報セキュリティシンポジウム 2024, 1F1-3, Jan. 2024.
- (25) 岡田顕, 本原誠司, 岡崎義勝, “IOWN を支えるディスプレイゲートッドコンピューティング,” *NTT 技術ジャーナル*, 2021, vol.33, no.5, pp.40–44.
- (26) 山下史洋, 堀茂弘, “宇宙コンピューティング・ネットワーク構想の実現に向けた基盤技術の研究開発,” 信学誌, vol.106, no.5, pp.376–381, 2023.

(HWS 研究会提案, 2024 年 6 月 1 日受付,
2024 年 7 月 1 日再受付)



高橋順子 (正員)

2004 早稲田大・理工・物理卒。2006 同大学院修士課程了。同年日本電信電話(株)入社。2012 電気通信大博士課程了。入社以来, ハードウェアセキュリティの研究に従事。現在, 社会情報研究所特別研究員。博士(工学)。SCIS 論文賞(2008), JIP 特選論文(2016), ICICS Best Paper Award(2020), SCIS イノベーション論文賞(2023) 各受賞。

ESS ニュース

NOLTA, IEICE 特集号

Guest Secretary 菅野円隆

特集タイトル：

Special Section on Emerging Technologies of Complex Communication Sciences and Multimedia Functions

掲載誌：

NOLTA IEICE, 2024 年 10 月発行

複雑コミュニケーションサイエンス研究会 (CCS) は、電子情報通信学会 NOLTA ソサイエティの第 2 種研究専門委員会として 2011 年 4 月に発足し、2015 年 4 月からは、NOLTA ソサイエティの第 1 種研究専門委員会として活動しています。

CCS 研究専門委員会は、情報通信技術、神経系や生物システム及び、ソーシャルコミュニケーションを含めたネットワーク技術とその応用を含む、幅広い分野に関する研究成果を発表する場となっています。本特集では、「複雑コミュニケーションサイエンス」に関連する最新の研究成果を国内外に発信することを目的として企画しました。投稿された全ての論文は NOLTA, IEICE の標準査読プロセスに従って審査され、9 編の一般投稿論文が掲載されることになりました。掲載論文には、リザーバコンピューティング、ニューラルネットワークモデル、画像処理、ロボット制御などのトピックスが含まれています。これらの論文は、「複雑コミュニケーションサイエンス」の分野における最先端の研究成果であり、読者に新しい研究の方向性のインスピレーションをもたらすとともに、様々な学際的研究分野の将来の発展の基礎として役立つと考えております。掲載論文は <https://www.jstage.jst.go.jp/browse/nolta/-char/ja> から無料で御覧頂けます。

最後に、本特集の企画並びに編集作業にあたり、多大な御協力を頂きました NOLTA, IEICE 編集委員会、IEICE 事務局、編集委員、査読委員、そしてお投稿頂きました全ての著者の皆様に感謝申し上げます。



菅野円隆 (正員)

2009 埼玉大学工学部情報システム工学科卒業。2011 埼玉大学大学院理工学研究科数理電子情報系専攻修士課程修了。2013~2014 日本学術振興会特別研究員 (DC2)。2014 埼玉大学大学院理工学研究科理工学専攻博士課程修了。2014~2018 福岡大学工学部電子情報工学科助教。2018~2023 埼玉大学大学院理工学研究科助教。2023~埼玉大学大学院理工学研究科准教授。現在に至る。博士 (工学)。第 45 回 (2018 年秋季) 応用物理学会講演奨励賞受賞。2022 年 5 月第 46 回レーザー学会奨励賞受賞。半導体レーザーカオスと光リザーバコンピューティングに関する研究に従事。著書『光リザーバコンピューティング：原理と実装』。応用物理学会会員。

ESS ニュース

NOLTA, IEICE 特集号

Guest Secretary 田中悠一朗

特集タイトル：

Special Section on Recent Progress in Neuromorphic AI Hardware

掲載誌：

NOLTA IEICE, 2024 年 10 月発行

現行の AI 技術は目覚ましい発展を遂げている一方で、その膨大な消費電力の問題に直面しています。この問題を解決するため、エネルギー効率の高い情報処理を実現する生物の脳を模倣した AI システム、すなわちニューロモルフィック AI ハードウェアの開発が求められています。これを実現するためには学際的な研究のアプローチが必要で、例えば、新たな AI ハードウェアのコアとなる“物質に潜在的する演算能力を引き出す”材料の研究、ニューロモルフィック AI の数理モデルの研究、材料や数理モデルを基にした AI システムを構築する回路の研究、そして AI システムをロボットに応用する研究を融合することで、これまでになく高効率な AI システムを実現することができます。

2019 年より毎年度開催し、今年 5 回目を迎えた国際シンポジウム“International Symposium on Neuromorphic AI Hardware”では、材料・数理モデル・回路・ロボットに関する最新の研究について発表・議論できる場を提供し、ニューロモルフィック AI ハードウェアの開発コミュニティの活性化を図っています。本特集では、第 5 回の国際シンポジウムの発表者より投稿された論文が通常の NOLTA, IEICE と同様の査読プロセスで審査され、9 編の論文が掲載されることとなりました。ニューロモルフィック AI ハードウェアに関する最新の研究成果をぜひご覧いただきたく存じます。

最後に、本特集にご投稿頂きました著者の皆様、編集作業にあたり多大なご協力を頂きました編集委員の皆様、査読委員の皆様、事務局の皆様に感謝申し上げます。



田中悠一朗 (正員)

平 28 九州工業大・工学。平 30 同大学院博士前期課程修了。平成 31 日本学術振興会特別研究員 (DC2)。令和 3 同大学院博士後期課程修了。博士 (工学)。同年同大学ニューロモルフィック AI ハードウェア研究センター助教着任。令和 6 年同大学院生命体工学研究科准教授着任。現在に至る。脳の記憶の機能を模倣した人工知能ハードウェアの開発、及び家庭用サービスロボットへの応用の研究に従事。令和 5 年より電子情報通信学会スマートインフォメディアシステム研究専門委員会幹事補佐。

2024年電子情報通信学会 NOLTA ソサイエティ大会開催報告

2024年電子情報通信学会 NOLTA ソサイエティ大会実行委員 佐村俊和



1. 開催概要

NOLTA ソサイエティ（以下、NLS）が主催する「2024年電子情報通信学会 NOLTA ソサイエティ大会」（以下、NLS 大会）が6月8日（土）に対面形式で開催されました。

- ・開催日：2024年6月8日（土）
- ・場 所：西日本総合展示場 AIM 3F（福岡県北九州市）
- ・主 催：電子情報通信学会 NOLTA ソサイエティ
- ・大会組織：

実行委員長	立野勝巳（九州工業大学）
総務・庶務	佐村俊和（山口大学） 菅野円隆（埼玉大学）
会計	木村貴幸（日本工業大学） 加藤秀行（大分大学）
投稿システム	美井野優（鳴門教育大学）
広報・出版	木村真之（摂南大学）

2. 開催状況

2024年NLS大会は、全92名（招待：5名、一般：40名、学生：47名）のご参加がございました。本大会の前、6月6日（木）、6月7日（金）にはNLSの研究会である非線形問題研究会（以下、NLP）と複雑コミュニケーションサイエンス研究会（以下、CCS）が共催され、それに引き続きの開催となりました。

本大会のタイムテーブルを表1に示します。はじめに、大会実行委員長の立野勝巳先生（九州工業大学）から開会の挨拶を頂き、続いて、2024年度NLS会長の夏目季代久先生（九州工業大学）から挨拶を頂きました。次に、NLSが主催する国際会議である「NOLTA2024」及び「NOLTA2025」について、それぞれのGeneral Chairである長谷川幹雄先生（東京理科大学）、鳥飼弘幸先生（法政大学）よりご報告頂きました。昼の休憩をはさむ形で二つのポスターセッションが行われ、全体で47件のご発表とこれらの発表に対する活発な議論が行われました。その後、NLSが発行する国際学術論文誌 *Nonlinear Theory and Its Applications*, IEICE について、編集委員長の上田哲史先生（徳島大学）よりご報告頂き、同誌のBest Paper Awardの授賞式と記念講演が執り行われました（表2）。続いて、NLPとCCSの年次報告と専門研究会奨励賞の授賞式と受賞者による講演（表3、4）。NOLTA ソサイエティ大会奨励賞の授与式が執り行われました。NLSでは、NLS大会において、ソサイエティの発展に貢献しうる講演論文を発表した著者に対し贈呈する表彰制度を設けております。本年度は、2件の発表に対して奨励賞が贈られました（表5）。最後に、大会実行委員長による閉会の言葉をもって、本大会は無事終了いたしました。

3. おわりに

本大会も昨年に引き続き多くの方にご参加頂き盛会のうちに終わることができました。本大会にてご講演・ポスター発表された皆様、聴講参加された皆様に深く感謝申し上げます。次回の大会は、岡山県での開催が予定されております。ふるってご参加

下さいますよう。よろしくお願いたします。

表 1 2024 年 NLS 大会タイムテーブル

開始	終了	イベント	プレゼンター
9:50	9:55	開会の挨拶	2024 年 NLS 大会実行委員長 立野勝巳 (九州工業大学)
9:55	10:00	NOLTA ソサイエティ会長挨拶	2024 年度 NOLTA ソサイエティ会長 夏目季代久 (九州工業大学)
10:00	10:10	NOLTA2024 について	NOLTA2024 General Chair 長谷川幹雄 (東京理科大学)
10:10	10:20	NOLTA2025 について	NOLTA2025 General Chair 鳥飼弘幸 (法政大学)
10:25	11:35	ポスターセッション A	
12:35	13:45	ポスターセッション B	
13:50	14:05	NOLTA Journal の現状について Best Paper Award 授賞式	2024 年度 NOLTA 誌編集委員長 上田哲史 (徳島大学)
14:05	14:45	NOLTA Journal Best Paper Award 記念講演	上田哲史 (徳島大学)
14:50	15:05	非線形問題研究専門委員会 年次報告・奨励賞授賞式	2024 年度 NLP 委員長 丹治裕一 (香川大学) 2023 年度 NLP 委員長 鳥飼弘幸 (法政大学)
15:05	15:35	非線形問題研究会 奨励賞受賞者講演	鳥飼弘幸 (法政大学)
15:40	15:55	複雑コミュニケーションサイエンス研究専門委員会 年次報告・奨励賞授賞式	2024 年度 CCS 委員長 中野秀洋 (東京都市大学)
15:55	16:25	複雑コミュニケーションサイエンス研究専門委員会 奨励賞受賞者講演	中野秀洋 (東京都市大学)
16:25	16:40	2024 年 NOLTA ソサイエティ大会の奨励賞授与式	2024 年度 NLS 大会実行委員長 立野勝巳 (九州工業大学)
16:40		閉会の挨拶・写真撮影	

表 2 NOLTA, IEICE Best Paper Award 記念講演 (太字は講演者)

著者	タイトル	文献番号
Keita Matsuura (Techno Project Japan Co.), Ibuki Nakamura (Hiroshima City University), Hisato Fujisaka (Hiroshima City University)	Analysis of Coupled Quantum Parametric Harmonic Oscillators by Classical Nonlinear Modeling	Vol. 13, No. 3, pp. 570-581, 2022.

表 3 NLP 奨励賞受賞者講演 (太字は講演者)

著者	タイトル	文献番号
伊藤大輔 (岐阜大学)・霜田幸長 (岐阜大学)・ 中村誠 (岐阜大学)	多値変調符号に対するイコライザ設計法の伝送線路依存性の検討	信学技報, vol. 123, no. 21, NLP2023-12, pp. 50-53, 2023 年 5 月
片山充二 (徳島大学)・上田哲史 (徳島大学)	2 次元非自律系の逆時間応答・分岐について	信学技報, vol. 123, no. 354, NLP2023-96, pp. 66-69, 2024 年 1 月

表 4 CCS 奨励賞受賞者講演 (太字は講演者)

著者	タイトル	文献番号
新井文也 (北海道大学)・堀篤史 (北海道大学)・ 浅井哲也 (北海道大学)・安藤洸太 (北海道大学)	ニューラルネットワークの共通基底に基づくマルチタスク協調学習の検討	信学技報, vol. 123, no. 452, CCS2023-45, pp. 36-41, 2024 年 3 月
徳永晃一 (千葉大学)・向陽 (千葉大学)・グエン キエン (千葉大学)・馬ジン (トヨタ自動車)・塩 田茂雄 (千葉大学)・関屋大雄 (千葉大学)	Wi-Fi センシングによる動体検知の一検討	信学技報, vol. 123, no. 452, CCS2023-40, pp. 6-11, 2024 年 3 月

表 5 2024 年 NOLTA ソサイエティ大会奨励賞受賞者

受賞者	タイトル
加藤海渡 (中京大学)	Extreme learning machine を用いた自律系回路の実験データに基づく分岐解析
小原翔馬 (東京工科大学)	間欠性カオスの局所アトラクタの遷移予測における力学的挙動の影響



NOLTA ソサイエティ大会奨励賞受賞者とNLS 大会実行委員長 立野勝巳先生（九州工業大学）



佐村俊和（正員）

2009 慶應大大学院政策・メディア研究科後期博士課程修了。九州工業大学大学院、玉川大学脳科学研究所での博士研究員を経て、2014より山口大学大学院・助教。2017より同大学院・准教授。2023.11月より同大学大学研究推進機構応用衛星リモートセンシング研究センター・准教授となり、現在に至る。脳神経活動シミュレーション・解析及び深層学習を用いたリモートセンシングデータ解析の研究などに従事。

研究会に行こう！

「研究会に行こう！」では基礎・境界ソサイエティの研究会などの様子を御紹介しています。情報交換や懇親、新たな研究との出会いの場としてはいかがですか？

■超音波研究会 (US)

超音波研究会 (US) は、最も古くからある研究会の一つで電子情報通信学会と日本音響学会との共催で運営されており、今年度設立 75 周年を迎えました。超音波研究会では、医用超音波、超音波スペクトロスコピー、超音波計測、強力超音波、弾性表面波デバイス、圧電材料と圧電デバイス、超音波非破壊検査、水中超音波、非線形音響などの超音波関連分野の基礎から応用にわたる広範な分野を取り扱っています。超音波研究会は、毎年 9 回全国各地の大学などで対面及びオンラインで研究会を開催しており、年間 80 件程度の発表があります。2024 年度は、5 月：東京、6 月：金沢、7 月：松江、8 月：東京、10 月：仙台、11 月：名古屋、12 月：大分、1 月：オンライン、2 月：東京（75 周年記念イベント開催予定）で開催されます。超音波研究会では、これまで非線形音響研究会、海洋音響学会、日本レオロジー学会、日本超音波医学会といった様々な研究会との共催も活発に行っており、異分野の研究者が出会う機会を提供しています。研究会では、1 件あたり 25 分間の発表・質疑応答時間を確保するとともに、セッション間のフリータイムでは文字どおり自由な意見交換を行っています。また、若手研究者育成のために「学生研究奨励賞」を設けていますのでぜひチャレンジしてください。研究会後に行われる懇親会では、研究発表では聞けない話や研究以外の話題で盛り上がり、新たな交友関係をもたらしてくれます。皆様が積極的に発表及び参加されることを幹事団一同心よりお待ちしております。

以下のホームページに研究会に関する最新の情報を掲載しております。

<https://www.ieice.org/~us/>



工藤すばる (正員：シニア会員)

1982 山形大・工・電気卒。1984 東北大・大学院修士課程了。博士 (工学)。現在、石巻専修大学教授、圧電デバイスの研究開発に従事。日本音響学会、計測自動制御学会各会員。

■非線形問題研究会 (NLP)

非線形問題 (NLP) 研究会では、非線形に関する基礎から応用に至る様々な研究が発表されております。カオスや分岐現象など古くから行われている非線形現象に関する研究は現在も盛んに行われ、深層学習と組み合わせた新たな展開も見られるようになりました。非線形の問題は、通信工学、時系列データ解析、生体信号、電子回路、数値解析など、様々な分野に存在し、その共通性や相違などを議論することが、本研究会の目的の一つになっています。そのため、近年では、ほかの委員会との共催、併催が盛んであり、研究会の垣根を取り払いながら、自由で活発な議論を行っており、ご聴講頂いている方から様々なご質問、コメントがございます。したがって、ご自身の分野では有益な方向性が見出せない場合にも、当研究会にご参加頂くことで、その解決に向けたきっかけが掴めるかもしれません。

当研究専門委員会では、できるだけ若い方に研究専門委員になって頂くように心がけております。また、女性の委員も増える傾向にあります。そして、研究会の運営は多くの方々のご意見を取り入れながら、進めさせて頂いております。

2024 年度は、6 回の研究会の開催 (高松、小倉、飛騨高山、鳥取、けいはんな、宮古島) を予定しております。詳細は、Web ページ (<http://www.ieice.org/~nlp/>) をご覧ください。発表論文の中から優秀な論文 (発表総数の 5%) に対して、NLP 奨励賞を授与させて頂いております。大学院生や若い研究者の方が受賞される場合が多く、受賞者の方には NOLTA ソサイエティ大会において、受賞記念講演をお願いしております。また、NOLTA ソサイエティが主管するオンラインジャーナル NOLTA において、当研究会で発表された論文を中心に、様々な非線形問題に対する研究成果をご投稿頂ける特集号を企画しております。必ずしも、研究会での発表を前提としておりませんので、多くの方にご投稿をお願いできればと思います。更に、NOLTA ソサイエティと共同して、様々な試みを行っております。特に、国際会議 NOLTA シンポジウムは、当研究会が中心の一つとなっております。

皆様のご尽力・ご協力により当分野が更に発展することを願っております。そして、研究会で皆様にお会いできることを楽しみにしております。



丹治裕一 (正員)

1993 徳島大・工・電気電子卒、1997 同大学院博士後期課程終了。博士 (工学)。現在、香川大・創造工・教授、科学計算アルゴリズムに関する研究に従事。IEEE 会員、2024 年度非線形問題研究専門委員会委員長。

■スマートインフォメディアシステム研究会 (SIS)

スマートインフォメディアシステム (SIS) 研究会は、人に優しいシステム、通信や情報技術におけるシームレスシステム、柔軟性を有するソフト化システムなど、広い分野において様々な要求に適用できる高度なシステムの設計・開発・実現を研究テーマとし、それらの実用化を目的として 2004 年度に発足し、今年で 20 年となります。スマートフォンという言葉も一般的ではなかった当時から 20 年経ち、AI 技術などの劇的な発展もあり、ますます人に優しい、柔軟性のあるシステムへの要求は高まっているものと思います。

SIS 研究会の具体的な技術分野は、スマートモバイルシステム、ソフトコンピューティング、知的マルチメディア処理システム、システム実現技術、近距離無線通信応用システムなど、横断的な分野に関して理論から実システムのハードウェアを含む開発までを対象としています。ソサイエティ横断型で、かつ、ほかの学会とも緩やかな研究連携を図りながら、新しい情報交換・研究討論の場を提供したいとも考えておりますので、皆様の研究が横断的であったり、システムを作ってみたがどこで発表してよいかわからないなどありましたら、ぜひ SIS 研究会での発表をご検討頂ければと思います。

年間の主な活動は、総合大会、ソサイエティ大会と年 4 回の研究会、国際ワークショップ SISA (International Workshop on Smart Info-media Systems in Asia) を中心に行っています。本年度 10 月研究会は 10 月 3、4 日に北星学園大学とオンラインのハイブリッド形式で映像情報メディア学会の「放送技術研究会 (ITE-BCT)」との連催を企画しています。以降の研究会は SIS 研単独開催で 12 月は大阪電気通信大学、3 月は神奈川工科大学で開催予定となっております。全ての研究会をハイブリッド開催としていますので、これまで SIS 研究会に参加したことのない方にも気軽に参加して頂ける研究会となっております。

また毎回の研究会では、研究専門委員によるチュートリアル講演も実施しており、チュートリアル講演や招待講演の一部は、IEICE ビデオアーカイブでも公開しております。そちらもチェック頂き、皆様の研究のお役に立てればと思っております。

SIS 研究専門委員会主催の大きな行事として、国際ワークショップ SISA を毎年開催しています。本ワークショップは大学院生を含めた若手研究者に国際会議の場を体験してもらい、他国の方々と積極的に交流頂くことを主眼に置いたワークショップです。2024 年は 12 月 5 日～6 日の 2 日間、大阪電気通信大学にて開催する予定です。

研究会をはじめ関連行事の詳細は SIS 研究会のホームページ (<http://www.ieice-sis.org/>) をご参照ください。皆様のご参加をお待ちしております。



笹岡直人 (正員：シニア会員)

2006 鳥取大学大学院博士後期課程修了。博士 (工学)。現在、鳥取大学工学部電気情報系学科教授。主に、適応フィルタ、無線伝搬路推定、ミリ波センサに関する研究に従事。IEEE、日本音響学会、信号処理学会各会員。2024 から本会スマートインフォメディアシステム (SIS) 研究専門委員会委員長。

■応用音響研究会 (EA)

応用音響研究会 (EA) では、音の録音再生と信号処理を中心とした、音に関する関連分野を幅広く包含した様々な研究を取り扱っています。具体的なトピックとしては、マイクロホンやスピーカ、音源の方向や位置の推定、音源分離、雑音や残響の抑圧、アクティブノイズ制御 (ANC) を含む音場の制御などが挙げられ、近年では深層学習を利用した音響シーン認識やイベント認識の発表も増えています。

EA 研究会は、コロナ以降はオンラインやハイブリッドでの開催を併用してきましたが、2023 年度は感染動向を注視しつつもほぼ対面開催に戻りつつあり、オンラインのみの開催を 1 回 (5 月)、現地とオンラインのハイブリッド開催を 1 回 (3 月)、現地のみの開催を 4 回 (7 月、8 月、11 月、12 月) と、計 6 回の研究会を開催しました。これには、信号処理、超音波、音声、聴覚、音楽音響といった、様々な研究会との共催や併催も含まれています。現地開催への参加者数も戻りつつあり、通年で発表 164 件、参加者数も約 520 名と、2023 年度の研究会も大変盛況となりました。特に、音声研究会 (SP)、信号処理研究会 (SIP)、情報処理学会音声言語情報処理研究会 (IPSJ-SLP)、APSIPA Japan Chapter と、例年 3 月に離島で開催している SPEASIP ワークショップという共催研究会には、90 件の発表と 154 名の参加者を集めました。

2023 年度も、2024 年度も同様に 6 回の開催を予定しています。遠方からも参加が容易なオンライン開催を前提とした 5 月の研究会に加え、7 月は北海道、8 月は東北、11 月は北陸、12 月は中国・九州と、各地区で定例的な現地開催に向けて、現地世話役の先生や共催する他研究会とともに検討を進めています。また、3 月の SPEASIP ワークショップも昨年度と同様、離島での現地開催を実現したいと思っています。招待講演も随時企画していますので、研究発表若しくは聴講に、ぜひ EA 研にご参加頂ければと思います。下記のホームページに研究会に関する最新の情報を掲載しています。

<https://ken.ieice.org/ken/program/index.php?tgid=IEICE-EA>
<http://asj-eacom.acoustics.jp/>



小野順貴 (正員)

2001.3 東京大学大学院工学系研究科計数工学専攻博士課程修了。博士(工学)。同年東京大学助手。2005 同大学講師。2011 NII 准教授。2017 東京都立大学教授。音響信号処理、マイクロフォンアレイ、音源分離、これらのための最適化アルゴリズムなどの研究に従事。

■技術と社会・倫理研究会 (SITE)

技術と社会・倫理研究会 (Social Implications of Technology and Information Ethics) では、情報通信や工学一般に関する倫理問題を中心として、情報リテラシー、知的財産権、情報セキュリティなど、種々の分野を対象として講演発表、意見交換を行ってきております。2024年6月の研究会では、「コンテンツモデレーション」「修理する権利」「EU DORA」「シェアリング・エコノミー」などの研究発表があり、また、連催を引き受けられた IPSJ EIP 研究会からも Personal AI に関する招待講演もありまして、議論が大いに進みました。

SITE 研究会は、他研究会との共催や、他学会の他研究会との連催を積極的に行っています。知的財産では IPSJ-EIP、情報セキュリティでは ISEC、BioX、HWS、ICSS、EMM、IA、IPSJ-CSEC、IPSJ-SPT、LOIS、IPSJ-IOT、教育関係では IPSJ-CE と議論を深めております。当研究会は、様々な領域との関わりがあり、HUB (中心) となっていると認識しています。

最新の情報は、<https://www.ieice.org/~site/>をご覧ください。

会員の皆様、研究者の皆様の御発表・御参加をお待ちしています。



辰己丈夫 (正員)

1991 早稲田大学理工学部数学科卒業、2014 筑波大学博士(システムズ・マネジメント)。現在、放送大学教養学部情報コース・教授。情報倫理教育、情報教育、情報科教育法などを研究している。2024 年度技術と社会・倫理研究会委員長。

■ワイドバンドシステム研究会 (WBS)

ワイドバンドシステム (WBS) 研究会では、文字どおり広帯域な信号を用いた通信システムをはじめ、センサネットワークのようなナローバンドも包含し、またセンシングなど、ワイドな研究テーマを扱っています。基礎・境界ソサイエティに属する研究会として、産業応用のみでなく通信理論のような学術的側面の強い研究成果の積極的な発表も期待いたします。

プロ野球選手がメジャーリーグを目指すように、日本の研究者・技術者の国際的なプレゼンスを高めるには、やはり IEEE など国際的な舞台での研究発表を推奨すべきですが、そのためには、学生が研究者としての第一歩を踏み出す場をはじめ、若手研究者の交流の場、その他多くの研究者の学びと議論の場が必要不可欠です。

本研究会がそのような場の提供に少しでも貢献できるよう、知恵を絞っていきたくと考えています。



落合秀樹 (正員)

1996 大阪大学工学部通信工学科卒。1998 東京大学大学院工学系研究科・電子情報工学専攻・修士課程修了。2001 同大学院・博士課程修了。2024 大阪大学大学院工学研究科・教授。1994 カリフォルニア大学ロサンゼルス校 (UCLA) 政府派遣留学。1999 日本学術振興会特別研究員。2003 ハーバード大学博士研究員。2019 ウォータールー大学客員教授及びプリンストン大学客員研究員。第一級陸上無線技術士。IEEE フェロー。

国際会議開催報告

IEEE International Symposium on Information Theory (ISIT2024, <https://2024.ieee-isit.org/home>)

Athenaeum Intercontinental Athens, Athens, Greece

2024年7月7日~12日

2024年7月7日から12日にかけて、IEEE International Symposium on Information Theory (IEEE ISIT) が開催されました。ISITは、IEEEのInformation Theory Societyが毎年開催している情報理論分野における世界最大の国際会議です。今年はギリシアのアテネで開催されました(図1)。昨年のISITではオンラインセッションが設けられていましたが、今年は完全対面形式で開催されました。また、今年は新たな試みとして初日にワークショップが開催されました。プログラムの詳細はISITのwebページ(<https://2024.ieee-isit.org/home>)に情報がまとまっておりますので、そちらをご参照ください。ここでは私がISITに参加して感じたことを記載いたします。



図1 学会会場 (Athenaeum Intercontinental Athens)

アテネ、遠いです。日本からの直行便がないため、私はトルコのイスタンブール経由の飛行機を使い、乗り継ぎの待ち時間を含めると片道約20時間かけて行きました。こんなときオンライン参加ができると楽ちんですが、やはり現地へ赴き対面で参加してよかったと思います。以下では、その理由を挙げてみます。

- (1) 私の発表内容はシャノン理論の「Guessing」というものでした。Guessingの研究で有名な先生の1人が、イスラエル工科大学(Technion)のMerhav教授です。私の発表の際、Merhav教授が最前列の私の目の前にどっかりと腰を下ろし、発表の途中で質問をしてくれます。「その量はあらかじめ決めておくのか、それとも後で最適化するのか?」「主結果の不等式において ϵ を0とすると、従来研究の結果と一致するのか?」等々。

これじゃあ、Merhav教授とゼミをやっているみたいだよ……と思いながら発表をしましたが、熱心に話を聞いて頂けたのはありがたいことだと思います。オンライン発表ですと、なかなかこのようにはなりません。

ん。対面発表ならではの経験といえましょう。

- (2) 昨年のシャノン賞受賞者(IEEE Information Theory Societyでは情報理論分野で多大な貢献をした研究者1名に毎年シャノン賞を授与しています)のBarron教授が行った講演では、盛りだくさんの内容を理路整然とお話しされている様子が印象的でした。また、一般公演の発表で自身の研究を熱く発表している世界各国の研究者の様子を見て、改めて「自分も研究をがんばろう」と思ったのでした。やはり、オンライン参加よりも対面で学会に参加したほうが発表者の雰囲気や熱量を感じることができ、研究に対するモチベーションが上がります。

- (3) 初めて見たアクロポリス、特にパルテノン神殿は圧巻でした。また、アクロポリスの近くの古代の音楽堂にてオーケストラ演奏のイベントが開催されておりました(図2)。開催時間は21時から23時までと遅い時間帯ではあったものの、チケットを購入し参加してみました。21時を過ぎて次第に辺りが闇に包まれる中、ライトアップされた古代音楽堂に鳴り響くオーケストラの演奏。まるで古代ギリシアにタイムスリップしたようです。現地参加したからこそ、このような貴重な体験ができました。




図2 アクロポリス近くの古代音楽堂にて開催されたオーケストラの演奏

さて、来年のISITはミシガン州のAnn Arborで開催される予定です。アメリカでISITが現地開催されるのは2018年のコロラド州Vailでの開催以来です。次回のISITでは、現地参加ならではの、どんな経験ができるでしょうか。来年

の ISIT に参加することも楽しみです。



齋藤翔太 (正員)

平 25 早大・基幹理工・応用数理卒。平 30 同大学院数学応用数理専攻博士課程了。博士(工学)。同年、早大応用数理講師着任。令 3 より群馬大准教授。情報理論とその応用の研究に従事。平 30 年度情報理論とその応用シンポジウム若手研究者論文賞受賞。平 28 年度 IEEE IT Society Japan Chapter Young Researcher Best Paper

Award 受賞。

国際会議開催報告

39th International Technical Conference on Circuits/Systems, Computers, and Communications

(ITC-CSCC2024, 第39回 回路とシステム, コンピュータ及び通信に関する国際会議)

Okinawa Institute of Science and Technology Graduate University (OIST), Okinawa, Japan

<https://itc-cscc2024.org/>

2024年7月2日~5日

The 39th International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC2024) が2024年7月2日~5日の4日間にわたって、沖縄の代表的なリゾート地である恩納村に位置する Okinawa Institute of Science and Technology Graduate University (OIST) にて開催されました。ITC-CSCC は毎年、電子情報通信学会、韓国の IEIE 及びタイの ECTI が共同で開催している回路とシステム、コンピュータ及び通信に関する国際会議です。日本、韓国、タイの3か国で開催地をローテーションしており、今年で39回めとなりました。アジア地域における研究者の交流を活性化し、特に若手研究者の育成を目的としています。参加登録者数は407名で日本国内から173名、韓国166名、タイ52名、その他7か国から参加登録がありました。

ITC-CSCC2024 では、22か国から302件の論文の投稿がありました。分野別の論文投稿数トップ5はAI, Neural Network, Computer Systems, Image Processing, Computer Vision となっていました。採択された論文は、20の特別セッション、14の一般セッション並びに三つのポスターセッションにおいて発表され、活発な議

論が行われていました。また、その中から114件の論文がIEEE Exploreへ掲載となりました。

基調講演では世界的に著名な Antonio Ortega 教授並びに Thierry Blu 教授を招待し、以下のタイトルで基調講演が行われました。

基調講演



- ・“Graph Constructions for Machine Learning Applications: New Insights and Algorithms,” Prof. Antonio Ortega (University of Southern California)
- ・“Local All-Pass Image Registration,” Prof. Thierry Blu (National Taiwan University)

Antonio Ortega 教授からはグラフ信号処理 (GSP) とモデルの説明可能性、ローカル補間分類、自己教師あり学習などの機械学習への応用についてご紹介頂きました。Thierry Blu 教授からは計算効率とノイズ耐性を大幅に向上させる画像レジストレーションの新しいアルゴリズムフレームワークの紹介がありました。更に以下に示す3件のプレナリ講演



ポスター発表





基調講演の様子。左：Prof. Antonio Ortega，右：Prof. Thierry Blu.

がありました。

プレナリ講演

- ・“Processing-in-DRAM: Opportunities and Design Considerations,” Prof. Seon Wook Kim (Korea University)
- ・“Approximating and learning 1-Wasserstein Distance with Trees,” Prof. Makoto Yamada (OIST)
- ・“Metaverse of Academic Nexus for Global Opportunities (MANGOs),” Prof. Lunchakorn Wuttisitkulkij (Chulalongkorn University)

それぞれ回路システム、機械学習、メタバース通信の分野における最新の研究成果について紹介がありました。

また、以下の2件のチュートリアル講演も開催されました。

チュートリアル講演

- ・“Harnessing Artificial Intelligence for Enhanced Screening of Regional Diseases,” Assistance Professor Dr. Thanapong Intharah (Khon Kaen University)
- ・“Brain-Computer Interfaces and Artificial Intelligence in Digital Health: Opportunities and Challenges,” Prof. Dong-Ok Won (Hallym University)

初日の7月2日には、チュートリアル講演終了後にOIST内のレストランでWelcome Receptionを開催しました。リゾート地の小高い丘に位置するOISTレストランからは沖縄の青い空と海の絶景が見渡せ優雅なReceptionとなりました。

なおOISTは都会ではないリゾート地にあることから、アクセスは多少不便なところがありますが、会議期間中は

OISTと公式ホテル間で1時間に1本の頻度で無料シャトルバスを運行しました。またお昼時には、OISTの研究ユニット訪問などキャンパスツアーを実施しました。

7月4日の夕刻からは、シャトルバスで移動し景勝地の万座毛に立ち寄った後、インターコンチネンタルANA万座ビーチリゾートホテルで懇親会が開催されました。前回ITC-CSCC2023最優秀論文賞の受賞式、次回ITC-CSCC2025の紹介などが行われました。また余興として、沖縄伝統芸能エイサーが披露され大変盛り上がりしました。

次回は来年、韓国・ソウルにて行われる予定です。最後に、企画運営に携わった組織委員会メンバー、著者、発表者並びに参加者の皆様に心から感謝申し上げます。



仲地孝之（正員：シニア会員）

1997 慶應義塾大学大学院後期博士課程修了（工博）。同年日本電信電話（株）入社。2006～2007 スタンフォード大学客員研究員。主にセキュア信号処理、エッジAI・機械学習、超高精細映像符号化・伝送の研究に従事。2021年4月より、琉球大学情報基盤統括センター・教授。ITC-CSCC2024 General Chair, 2023年度信号処理研究専門委員会委員長、スマートインフォメディアシステム研究専門委員会顧問、IEEE 会員。

電子情報通信学会に関連する賞を受賞された方を御紹介します。

第 80 回 (令和 5 年度) 論文賞

令和 5 年度は学会全体で 12 編の論文が論文賞を受賞しました。そのうち、基礎・境界ソサイエティでは 3 編の論文が受賞しています。受賞した 3 編の論文の著者にインタビューしました。

Ouyang JUNJIE (阪大), 矢内 直人 (阪大), 竹村 達也 (阪大),
岡田 雅之 (長崎県立大), 岡村 真吾 (奈良高専), Jason Paul CRUZ (阪大)

[APVAS: Reducing the Memory Requirement of AS_PATH Validation by Introducing Aggregate Signatures into BGPsec]⁽¹⁾

Q. 論文賞を受けられた御感想をお聞かせ下さい。

伝統ある学会の論文賞を頂けて、とてもうれしいです！ 受賞した論文はインターネット経路制御のセキュリティに関する研究課題であり、当該課題に対し筆者の研究チームを編成してから丸 10 年が経ちました。この 10 年めという一つの節目に栄えある賞を頂くことができ、とても感慨深いです。本受賞をきっかけとして、インターネット経路制御のセキュリティの研究課題を、更に飛躍させていきたいと考えています。

Q. 論文賞を受けられた御研究について教えてください。

インターネットの経路制御において、独立に生成されたデジタル署名のデータサイズを集約できる集約署名を新たに設計・導入することで、インターネット経路の正当性を保証する研究です。集約署名のインターネット経路制御への導入は暗号理論では言及されていたものの、具体的な検討まではされてきませんでした。これに対し、本研究では 2 点の特徴があります。まず、集約署名をインターネット経路制御に導入する際の問題を新たに発見して、その問題を解決する集約署名を新たに設計しました。次に、提案した集約署名をソフトウェアルータに搭載することで、実際に経路制御をする際の性能を評価しました。これは集約署名はもちろん、より広い枠組みとしての高機能暗号において、ソフトウェアルータとして実装した初めての成果になります。本研究が 10 年、20 年後のインターネットに役立つことを期待しています。

Q. 現在、御興味をもたれている研究テーマを教えてください。

IP アドレスやドメイン名といったインターネットを構成する基本的な資源を更に安全に取り扱うことに興味をもっています。また、AI やブロックチェーンといった最新技術のセキュリティも、現代社会において重要な課題です。これらの最新技術についても取り組んでいます。また、世の中の動向として暗号技術を、量子計算機に対しても安全性が保証される耐量子計算機暗号に移行する時期が来ています。耐量子計算機暗号を様々な場面で設計・導入することも今後の重要な研究課題の一つです。

Q. 今後の抱負をお聞かせ下さい。

著者の半数は、今は産業界に所属しています。第 2 著者は現在パナソニックホールディングス株式会社に所属しており、今後は学術と産業の狭間の研究者として、社会的な問題を学術的な観点から解決していきたいと考えています。また、第 4 著者の所在である長崎は国際電信発祥の地です。その長崎からインターネットの安全を研究・発信していきたいと考えています。

Q. 読者へのメッセージをどうぞ！

最初の感想でも述べましたとおり、本受賞に至るまで 10 年の月日がかかりました。どのような研究課題でもじっくりコツコツと取り組んでいけば、大きな成果につながります。是非皆様もご自分のテーマについて、根気強く取り組んでください。また、私たちはコンピュータネットワーク技術を壊して覚えることができました。今の若手や初学者にもそういった機会を皆で提供したいと思います。ご協力をお願いします。



左から Ouyang Junjie 氏, 岡田雅之氏



左から矢内直人氏, 岡村真吾氏



竹村達也氏



Jason Paul Cruz 氏

Yang CHEN (東工大), 山岸 昌夫 (東工大 (現・法政大)), 山田 功 (東工大)

[A Unified Design of Generalized Moreau Enhancement Matrix for Sparsity Aware LiGME Models]⁽²⁾

Q. 論文賞を受けられた御感想をお聞かせ下さい。

名誉ある賞を頂き、大変光栄に思っております。本論文を高く評価して頂いた方々に深く感謝申し上げます。

Q. 論文賞を受けられた御研究について教えて下さい。

信号処理や機械学習の領域の逆問題では、古くから最小二乗推定が標準解法でしたが、最近では推定対象の先験知識としてスパース性を活用する「正則化付き最小二乗推定 (Lasso では l_1 ノルムが正則化項に使われています)」が広く利用されるようになってきました。 l_1 ノルムに代表される凸関数を正則化項に利用すると、最適化問題の目的関数全体が凸関数となり、大域的最適解も得られるのですが、スパース性利用効果の更なる促進には正則化項に非凸関数を使うことが求められるため、スパース性利用効果促進問題と大域的最適解算出問題は長年トレードオフの関係にありました。

筆者らの研究グループでは、線形変換域のスパース性利用効果を高める非凸関数を正則化項に活用しながら、目的関数の全体凸性を維持できる「LiGME 型最小二乗推定モデル (LiGME モデル)」と非拡大写像の不動点理論を応用した大域的最適化アルゴリズムを実現しています [Abe, Yamagishi, Yamada 2020]。LiGME モデルに全体凸性をもたらす鍵は、パラメータ行列 (GME 行列と呼ぶ) の周到な設計にあり、[Abe, Yamagishi, Yamada 2020] では、特定の条件を満たす線形変換に対して、代数的 GME 行列設計法 (有限回計算で実現可能) を与えていました。最近、任意の線形変換に応用可能な逐次近似型 GME 行列設計法が米国の統計学者 [Liu and Chi 2022] によって提案されたのですが、反復計算に要する計算量が大きく、その解決策が待望されていました。

今回受賞対象となった論文では、任意の線形変換に対して有限回の計算 (1 回の LDU 分解と部分空間への 1 回の直交射影計算) で所望の GME 行列が得られる代数的 GME 行列設計法を提案しており、また、グループスパース性を活用した信号処理問題への応用例を示し、その優れた効果を確認しています。提案法は、固有値分解や反復計算を必要としないため、従来の逐次近似型 GME 行列設計法に比べて圧倒的に低い計算量で GME 行列を実現することができ、LiGME モデルの応用領域を飛躍的に拡大することができます。

Q. 現在、御興味をもたれている研究テーマを教えてください。

データサイエンスの広範な領域へ貢献することを目指し、普遍的かつ基礎的な問題を対象に、優れた解法やアルゴリズムを構成することを目指した研究を行っています。特に、問題に対する様々な観察を通して得られた知見をもとに、数学的なモデルを設計し、数理最適化を活用して解法やアルゴリズムを構成する手法に興味をもっています。

Q. 今後の抱負をお聞かせ下さい。

第 1 著者 (Yang Chen) は、中国の大学 Wuxi Institute of Technology の講師として研究者としてのキャリアをスタートしたところであり、第 2 著者 (山岸) は、所属を東京工業大学から法政大学へと移し、研究室運営を始めたところです。新しい環境でもそれぞれの研究を継続して、微力でもデータサイエンスの発展に貢献していきたいと考えています。第 3 著者 (山田) は、少しでも普遍的価値が感じられそうな研究に取り組み、楽しんでいきたいと思っています。

Q. 読者へのメッセージをどうぞ！

世界中で熾烈な競争が繰り広げられていますが、そんな時代だからこそ、私たちは敢えて気持ちを楽にして、じっくりと研究を楽しんでいきたいですね。



Yang Chen 氏

植松 友彦 (東工大), 松田 哲直 (埼玉大)

[Equivalences among some information measures for individual sequences and their applications for fixed-length coding problems]⁽³⁾

Q. 論文賞を受けられた御感想をお聞かせ下さい。

名誉ある論文賞を重ねて受賞できたことを大変うれしく思います。

Q. 論文賞を受けられた御研究について教えてください。

1972年にイスラエルの研究者 Ziv は、無限に長い系列（個別系列と呼ぶ）が唯一つ与えられたとき、その系列を長さ n のブロックに区切り、各ブロックを固定長 k ビットに圧縮する固定長符号化について、その符号化率 (k/n) の下限が Ziv エントロピーで与えられることを示しました。本研究では、個別系列における部分系列の出現頻度から計算できる情報量である 2 種のスムーズ最大エントロピーの極限が Ziv エントロピーと一致することを示すとともに、スムーズ最大エントロピーを利用した新しい固定長符号化法を 2 種提案しています。提案した方法は、長さ n のブロックの符号化に必要な計算量が $n \log(n)$ のオーダの計算によって行え、長さ n の指数関数オーダの計算量が必要だった Ziv の符号化法に比べて著しく効率的であることを明らかにしました。

Q. 現在、御興味をもたれている研究テーマを教えてください。


個別系列から真の乱数を生成する手法や二つの個別系列の分散符号化などについて興味をもっています。

Q. 読者へのメッセージをどうぞ！

時代とともにスパイラル状に発展を遂げる情報理論は古くて新しい分野です。フレッシュで野心あふれる方のこの分野への参入を期待しています。



植松友彦氏



松田哲直氏

-
- (1) Ouyang Junjie, 矢内直人, 竹村達也, 岡田雅之, 岡村真吾, Jason Paul Cruz, "APVAS: Reducing the Memory Requirement of AS_PATH Validation by Introducing Aggregate Signatures into BGPsec," IEICE Trans. Fundamentals, vol. E106-A, no. 3 March 2023.
 - (2) Yang Chen, 山岸昌夫, 山田 功, "A Unified Design of Generalized Moreau Enhancement Matrix for Sparsity Aware LiGME Models," IEICE Trans. Fundamentals, vol. E106-A, no. 8 Aug. 2023.
 - (3) 植松友彦, 松田哲直, "Equivalences among some information measures for individual sequences and their applications for fixed-length coding problems," IEICE Trans. Fundamentals, vol. E107-A, no. 3 March 2024.

開催案内

NOLTA2024 開催案内

General secretary 木村 貴幸 (日本工業大学)

2024年12月3日から12月6日にかけて、2024 International Symposium on Nonlinear Theory and Its Applications, NOLTA2024 (<https://nolta2024.org>) をベトナムのハロン湾にて開催いたします。ハロン湾は、ベトナム北部に位置する非常に有名な観光地であり、ユネスコの世界遺産にも登録されています。また、ハロン湾には石灰岩などの島々が点在しており、透き通ったエメラルドグリーンのお海とのコントラストが、静かで神秘的な風景を生み出しています。NOLTAは、非線形や複雑系の理論を基盤とし、工学のさまざまな分野に広がる分野横断的な議論を行う会議です。また過去の会議の予稿集は、IEICE Proceedings seriesにて無料で公開されておりますので、ぜひご覧ください。本シンポジウムは国内外から200件を超える投稿がありました。Committee一同、心より感謝申し上げます。現在、プログラムの編成を進めておりますが、準備が整い次第、上記のホームページでご案内いたします。本年は、NOLTA ソサイエティ、韓国マルチメディア学会 (KMMS)、韓国情報通信技術学会 (KICS) の会員が聴講参加される場合、参加費が1万円割引となります。皆様のご参加を心からお待ちしております。また、NOLTA2024では、下記の先生方からのPlenary talkを予定しています。

NOLTA2024 Plenary talks

Professor Yoshihiko Horio

Title: Brainmorphic Computing Paradigm and Hardware Abstract

This talk introduces the brainmorphic computing paradigm and its hardware architecture. In this paradigm, information processing is performed through the complex dynamics emerged on the complex structure of the brain. In addition, the bodily and environmental constraints are considered and utilized as embodiment. Finally, our efforts on physical implementation of the brainmorphic computing hardware are illustrated.

Professor Luigi Fortuna

Title: Nonlinear Systems: Imperfections and Noise towards the Hidden Technologies

The dynamics of nonlinear systems will be emphasized in order to give focus on how noise and imperfections allow the emergence of novel control systems thanks to the hidden characteristics of a class of nonlinear devices. More experiments and real applications are discussed.

Professor Nguyen Linh Trung

Title: Semi-blind MIMO system identification: from blind to informed paradigm

This talk addresses the limitations of Blind System Identification (BSI) and introduces Semi-Blind System Identification (SBSI) as a promising alternative that leverages additional knowledge about the system or source signals. The focus is on overcoming challenges related to model complexity, computational efficiency, robustness, and integration of machine learning in SBSI. The application of SBSI in MIMO communication systems is highlighted, particularly in the context of enhancing spectral efficiency for future 6G networks with extremely-large antenna arrays.

論文募集

2025 年暗号と情報セキュリティシンポジウム (SCIS2025)

2025 Symposium on Cryptography and Information Security

開催期日：2025 年 1 月 28 日（火）～1 月 31 日（金）

開催会場：リーガロイヤル小倉（福岡県北九州市）

開催形態：現地開催

Web ページ：<https://www.iwsec.org/scis/2025/>

1. 概要

暗号と情報セキュリティシンポジウムは、暗号と情報セキュリティ技術に関する最新の研究成果の発表および情報交換の場として、1984 年以来毎年開催されているセキュリティ分野における日本最大規模のシンポジウムです。第 42 回となる SCIS2025 は、福岡県北九州市で開催します。

2. 募集テーマ

暗号および情報セキュリティに関する分野、特に新しく発展しつつある研究分野。募集テーマを以下に挙げますが、これらに限らずセキュリティ技術に関わる論文を広く募集します（査読による絞込みはありません）。

[募集テーマ例]

暗号理論、情報理論的安全性、数論応用、公開鍵暗号、ID ベース暗号／属性ベース暗号／関数暗号、楕円・超楕円曲線暗号、格子暗号、秘密計算、高機能暗号、多機能署名、共通鍵暗号、ブロック暗号、ストリーム暗号、ハッシュ関数、乱数、署名、認証、鍵管理、暗号プロトコル、フォーマルメソッド、耐量子計算機暗号、量子暗号・量子計算、ハードウェアセキュリティ、サイドチャネル攻撃、ネットワークセキュリティ、ネットワーク攻撃検知・対策、マルウェア対策、ウェブセキュリティ、クラウドセキュリティ、モバイルセキュリティ、組み込みセキュリティ、制御システムセキュリティ、自動車セキュリティ、フィンテック、ブロックチェーン、電子透かし、コンテンツ保護、ソフトウェア保護、プライバシー保護、生体認証・バイオメトリクス、教育・心理学、セキュリティ評価・モデル、IoT セキュリティ、AI セキュリティ、デジタルアイデンティティ、トラスト、偽情報・誤情報対策、サプライチェーンセキュリティ

※原稿に関する著作権は電子情報通信学会に帰属します。

3. 論文賞

● イノベーション論文賞

情報セキュリティ (ISEC) 研究専門委員会では暗号と情報セキュリティシンポジウム (SCIS) のさらなる発展と活性化を目的として、「新しい研究・技術開発」の奨励を行うイノベーション論文賞を SCIS2012 より設定しています。その奨励対象は理論的新規な論文だけでなく ICT での問題提起や新しい研究分野の提案も含まれます。イノベーション論文賞の対象は全講演論文となります。多くの技術者・研究者による積極的なご発表をお願いいたします。

● SCIS 論文賞

情報セキュリティ (ISEC) 研究専門委員会では暗号と情報セキュリティシンポジウム (SCIS) の発展と活性化、並びに、暗号と情報セキュリティ分野で活躍する若手の奨励を目的として、1993 年より SCIS 論文賞を設定しています。SCIS 論文賞の対象は、SCIS 論文賞を未受賞の講演者で、主に学部在学中もしくは学部卒業後 10 年以内の講演者による論文となります。論文賞の対象として取り扱われるかどうか不明な方は事務局までお問い合わせください。

4. 開催場所

リーガロイヤルホテル小倉 〒802-0001 福岡県北九州市小倉北区浅野 2-14-2

5. 主なスケジュール (予定)

2024 年

- ・ 11 月 8 日 (金) 参加申込・発表申込受付開始
- ・ 11 月 29 日 (金) 発表申込メ切
- ・ 12 月 6 日 (金) 発表題目・概要メ切
- ・ 12 月 16 日 (月) 17:00 原稿提出メ切
- ・ 12 月末 プログラム公開

2025 年

- ・ 1 月 14 日 (火) 事前参加申込メ切
- ・ 1 月 21 日 (火) 論文集公開開始
- ・ 1 月 28 日 (火)~31 日 (金) SCIS 2025 開催

概要は原稿提出の有無に関わらずプログラムに掲載されます。

6. 申込み

参加・発表申し込みを、11 月上旬より本シンポジウムの Web ページで受け付ける予定です。投稿原稿は「概要：日本語 500 文字以内、英語 1300 文字以内」および「論文：8 ページ以内 (A4 版, 1.5 MB 制限)」をご準備ください。

7. 諸注意

本シンポジウムに関する最新の情報は、Web ページをご参照ください。また、参加・発表申込み及び原稿提出の各締切を厳守してください。締切以降の提出は一切受け付けられません。

[主催]

電子情報通信学会 情報セキュリティ研究専門委員会 (ISEC 研)

[協賛]

情報処理学会 コンピュータセキュリティ研究会 (CSEC 研)



第14回 バイオメトリクスと 認識・認証シンポジウム



会場：伊香保温泉 ホテル天坊（群馬県渋川市）

会期：2024年12月10日～11日

HP：

<https://www.ieice.org/ess/biox/sbra2024/>

お問合せ：biox-sbra2024[at]mail.ieice.org

生体認証として知られる「バイオメトリクス」は、センサ、アルゴリズムに関する基礎技術からシステム構築、サービス提供のような実利用まで、多岐にわたる認識・認証技術として発展してきました。すでに、指紋認証や顔認証は安全安心な社会を実現するためのインフラストラクチャーとして実用化しています。最近では、多様化したインターネットサービスの普及やDXの推進に伴い、Trusted Webの実現に向けた取り組みも進められており、バイオメトリクス技術の新たな展開も期待されています。

このような背景をもとに、「バイオメトリクスと認識・認証シンポジウム（SBRA）」は、バイオメトリクスや認証・認識に関する様々な研究分野の研究者や開発者、利用者が一堂に会し、交流、情報交換、相互啓発を広げていくための場として開催されてきました。SBRA2024では、SBRA2022から始まった地方開催の流れを踏襲しつつ、初めての試みとして、温泉旅館での開催となります。多くの皆様からのご発表・ご参加いただけることを実行委員一同、お待ちしております。

SBRA2024 実行委員長 今岡 仁

スケジュール

発表申込締切：2024年10月頃

原稿投稿締切：2024年10月頃

参加申込締切：2024年11月頃

基礎・境界ソサイエティ運営委員会

会長	和田山 正	(名古屋工業大学)
次期会長	尾上 孝雄	(大阪大学)
ソサイエティ編集長	大橋 正良	(国際電気通信基礎技術研究所)
副会長 (事業担当)	澁谷 智治	(上智大学)
副会長 (システムと信号処理)	田中 聡久	(東京農工大学)
副会長 (音響・超音波)	小野 順貴	(東京都立大学)
副会長 (情報理論とその応用)	小嶋 徹也	(東京工業高等専門学校)
庶務幹事	葛岡 成晃	(和歌山大学)
庶務幹事	傘 昊	(東京都市大学)
会計幹事	小林健太郎	(名城大学)
会計幹事	小筒井 弘	(北海道大学)
事業担当幹事	三村 和史	(広島市立大学)
事業担当幹事	黒崎 正行	(九州工業大学)
大会担当幹事	大東 俊博	(東海大学)
大会担当幹事	伊藤 大輔	(岐阜大学)
電子広報担当幹事	西川 広記	(大阪大学)
電子広報担当幹事	古賀 崇了	(近畿大学)
論文誌編集委員長	岡田 実	(奈良先端科学技術大学院大学)
論文誌編集幹事	林 和則	(京都大学)
ソサイエティ誌編集委員長	高島 康裕	(北九州市立大学)
ソサイエティ誌担当幹事	松田 哲直	(埼玉大学)
ソサイエティ誌担当幹事	松井健太郎	(日本放送協会)
特別委員 (ソサイエティ誌多言語化)	鎌部 浩	(岐阜大学)
編集特別幹事 (オブザーバ)	山脇 大造	(日立製作所)
出版委員会委員 (オブザーバ)	藤沢 匡哉	(東京理科大学)
研究会連絡会幹事 (オブザーバ)	高島 康裕	(北九州市立大学)
ハンドブック/知識ベース委員 (オブザーバ)	太田 隆博	(専修大学)
男女共同参画委員会 (オブザーバ)	小西 かつ美	(愛知工業大学)
プラチナクラブ運営委員会 (オブザーバ)	前田 義信	(新潟大学)
事務局	水橋 慶, 永井 宏, 中嶋 彩乃	(電子情報通信学会)

基礎・境界ソサイエティサブソ・研専会議

副会長 (事業担当)	澁谷 智治	(上智大学)
副会長 (システムと信号処理)	田中 聡久	(東京農工大学)
副会長 (音響・超音波)	小野 順貴	(東京都立大学)
副会長 (情報理論とその応用)	小嶋 徹也	(東京工業高等専門学校)
事業担当幹事	三村 和史	(広島市立大学)
事業担当幹事	黒崎 正行	(九州工業大学)
回路とシステム (CAS)	篠宮 紀彦	(創価大学)
情報理論 (IT)	野上 保之	(岡山大学)
信頼性 (R)	門田 靖	(リコー先端研究所)
超音波 (US)	工藤 ずばる	(東京都立大学)
応用音響 (EA)	小野 順貴	(東京都立大学)
VLSI 設計技術 (VLD)	桜井 祐市	(日立製作所)
情報セキュリティ (ISEC)	四方 順司	(横浜国立大学)
信号処理 (SIP)	市毛 弘一	(横浜国立大学)
ワイドバンドシステム (WBS)	落合 秀樹	(大阪大学)
システム数理と応用 (MSS)	山口 真悟	(山口大学)
思考と言語 (TL)	坪田 康	(京都工芸繊維大学)
技術と社会・倫理 (SITE)	辰巳 丈夫	(放送大学)
ITS (高度交通システム) (ITS)	高取 祐介	(神奈川工科大学)
スマートインフォメディアシステム (SIS)	笹岡 直人	(鳥取大学)
イメージメディアクオリティ (IMQ)	工藤 博章	(名古屋大学)
高信頼制御通信 (RCC)	石井 光治	(香川大学)
バイオメトリクス (BioX)	高野 博史	(富山県立大学)
安全・安心な生活と ICT (ICTSSL)	大塚 晃	(事業創造大学院大学)
ハードウェアセキュリティ (HWS)	林 優一	(奈良先端科学技術大学院大学)
光輝会 (SSA) (オブザーバ)	宮地 充子	(大阪大学大学院)
技術の歴史 (オブザーバ)	篠田 庄司	(中央大学)
技術者教育と優良実践 (オブザーバ)	横田 光広	(宮崎大学)
ヒューマンコミュニケーション G (オブザーバ)	松田 昌史	(NTTコミュニケーション科学基礎研究所)
会長 (オブザーバ)	和田山 正	(名古屋工業大学)
次期会長 (オブザーバ)	尾上 孝雄	(大阪大学)
庶務幹事 (オブザーバ)	葛岡 成晃	(和歌山大学)
庶務幹事 (オブザーバ)	傘 昊	(東京都市大学)
研究会連絡会幹事 (オブザーバ)	高島 康裕	(北九州市立大学)
事務局	水橋 慶, 永井 宏, 中嶋 彩乃	(電子情報通信学会)

NOLTA ソサイエティ運営委員会

ソサイエティ会長	夏目 季代久	(九州工業大学)
ソサイエティ次期会長	関屋 大雄	(千葉大学)
庶務幹事	立野 勝巳	(九州工業大学)
庶務幹事	荒井 伸太郎	(岡山理科大学)
会計幹事	木村 貴幸	(日本工業大学)
電子広報担当幹事	加藤 秀行	(大分大学)
大会担当幹事	伊藤 大輔	(岐阜大学)
運営委員	小西 啓治	(大阪府立大学)
運営委員	鳥飼 弘幸	(法政大学)
運営委員	上田 哲史	(徳島大学)
運営委員	清水 邦康	(千葉工業大学)
運営委員	丹治 裕一	(香川大学)
運営委員	長谷川 雄一	(東京理科大学)
運営委員	青森 久	(中京大学)
運営委員	保坂 亮介	(芝浦工業大学)
運営委員	中野 秀洋	(東京都市大学)
運営委員	内田 淳史	(埼玉大学)
運営委員	上山 憲昭	(立命館大学)
運営委員	佐々木 智志	(湘南工科大学)
運営委員	斎藤 利通	(法政大学)
運営委員	浅井 哲也	(北海道大学)
運営委員	井岡 恵理	(芝浦工業大学)

Fundamentals Review 編集委員会

編集委員長	高島 康裕 (北九州市立大学)
編集委員会幹事 (正)	松田 哲直 (埼玉大学)
編集委員会幹事 (副)	松井健太郎 (日本放送協会)
編集委員会幹事補佐	宮北 和之 (新潟大学)
編集委員	
編集委員 (CAS)	越田 俊介 (八戸工業大学)
編集委員 (VLD)	新谷 道広 (京都工芸繊維大学)
編集委員 (SIP)	小西 克巳 (法政大学)
編集委員 (MSS)	野村 雅司 (三菱電機株式会社)
編集委員 (IT)	金子 晴彦 (東京科学大学)
編集委員 (ISEC)	海上 勇二 (パナソニックホールディングス)
編集委員 (WBS)	孫 冉 (茨城大学)
編集委員 (US)	大久保 寛 (東京都立大学)
編集委員 (EA)	加古 達也 (日本電信電話株式会社)
編集委員 (NLP)	伊藤 大輔 (岐阜大学)
編集委員 (R)	吉川 隆英 (富士通研究所)
編集委員 (TL)	神長 伸幸 (ミイダス)
編集委員 (SITE)	山肩 大祐 (IGDA 日本)
編集委員 (ITS)	金 帝演 (鶴岡工業高等専門学校)
編集委員 (SIS)	二神 拓也 (愛知学院大学)
編集委員 (IMQ)	山添 崇 (湘南工科大学)
編集委員 (BioX)	河原 智一 (東芝インフラシステムズ株式会社)
編集委員 (RCC)	鍋谷 寿久 (株式会社東芝)
編集委員 (CCS)	眞田 耕輔 (三重大学)
編集委員 (ICTSSL)	宇津 圭祐 (東海大学)
編集委員 (HWS)	矢嶋 純 (富士通株式会社富士通研究所)

(上記に含まれない右側の編集幹事会の委員も編集委員として含む)

学会事務局

水橋 慶, 永井 宏, 中嶋 彩乃
(電子情報通信学会)

Fundamentals Review 編集幹事会

編集委員長	高島 康裕 (北九州市立大学)
編集幹事会幹事 (正)	松田 哲直 (埼玉大学)
編集幹事会幹事 (副)	松井健太郎 (日本放送協会)
編集幹事会幹事補佐	宮北 和之 (新潟大学)
編集幹事	
幹事 (総務)	八木 秀樹 (電気通信大学)
幹事 (渉外)	傘 昊 (東京都市大学)
幹事 (企画)	山岸 昌夫 (法政大学)
幹事 (Web: 正)	西川 広記 (大阪大学)
幹事 (Web: 副)	古賀 崇了 (近畿大学)
特別編集幹事 (Vol.18 No.1)	孫 冉 (WBS) (茨城大学)
特別編集幹事 (Vol.18 No.2)	山肩 大祐 (SITE) (IGDA 日本)
特別編集幹事 (Vol.18 No.3)	越田 俊介 (CAS) (八戸工業大学)
特別編集幹事 (Vol.18 No.4)	金子 晴彦 (IT) (東京科学大学)
顧問	貴家 仁志 (東京都立大学)
顧問	白井 宏 (中央大学)
顧問	今井 浩 (東京大学)
顧問	牧野 光則 (中央大学)
顧問	高橋 篤司 (東京科学大学)
顧問	國廣 昇 (筑波大学)
顧問	関屋 大雄 (千葉大学)

編集後記

FR 誌 Vol. 18 No. 2 をお届けいたします。今号の編集作業は真夏に行われたのですが、今年の夏は、文字どおり災害級の猛暑でした。ただ、今号が発行される10月1日には、この暑さが緩和されていることを願ってやみません。そして、秋の夜長の候です。我々の期待は、その秋の夜長に上質なFR誌の記事を読んで頂き、基礎・境界ソサイエティがカバーする幅広さと奥深さを感じて頂けることです。今後ともよろしく願っています。(高島康裕)

今号も皆様のおかげで無事に発行することができました。誠にありがとうございます。前号が発行されてから、公私ともに忙しい日々が続き、気付けばあっという間に今号の発行となりました。この調子だと、次号もその次の号も、気付けばもう発行の時期になるのだろうと感じております。全く中身の無い後記となってしまい大変恐縮ですが、これからも皆様にとって有益な記事となるように編集作業に努めてまいります。引き続きどうぞよろしくお願い致します。(松田哲直)

開催案内をはじめとする「やわらかい記事」の編集を担当しました。ご執筆頂いた皆様並びにご担当頂いた事務局・出版社の皆様にお礼申し上げます。コロナ禍以降、会議や研究会のハイブリッド開催がすっかり定着したように思います。それとは関係ないのですが、高温多湿の日本の夏を、今年はエアコンと除湿機とのハイブリッドで何とか乗り切りました。今号の発行される10月1日には既に引き落とされているであろう電気代が今から心配です。(松井健太郎)

今号の「受賞者の声」の編集を担当しました。受賞された皆様、改めましておめでとうございます。また、スムーズな編集作業にご協力頂きまして、誠にありがとうございました。今号の「受賞者の声」では、論文賞を受賞された方々の研究概要の紹介に加え、読者へのメッセージなどの生の声をお届けしていますので、読者の皆様にも興味深くお読み頂けるものと思います。ぜひご一読ください。(宮北和之)

Fundamentals Review へのお問い合わせ

- ・ 本誌への御意見、御要望、入手など : fr-ess@ieice.org
- ・ Fundamentals Review Homepage : <https://www.ieice.org/ess/ESS/Fundam-Review.html>

複写される方へ

一般社団法人電子情報通信学会は、本誌に掲載された著作物の複写複製に関する権利を一般社団法人学術著作権協会に委託しております。複写複製を御希望の方は、一般社団法人学術著作権協会 (<https://www.jaacc.org>) が提供している複製利用許諾システムを通じて申請して下さい。

なお、複写以外の許諾（著作物の転載、翻訳等）に関しては、委託致しておりませんので、直接本会へお問い合わせ下さい。

<問合せ先> 一般社団法人電子情報通信学会
TEL [03] 3433-6691 FAX [03] 3433-6659
著作物利用許諾申請：<https://www.ieice.org/jpn/copyright/tensai.html>

Reprographic Reproduction outside Japan

Making a copy of this publication

The IEICE authorized Japan Academic Association For Copyright Clearance (JAC) to license our reproduction rights of copyrighted works. If you wish to obtain permission of these rights, please refer to the homepage of JAC (<https://www.jaacc.org/en/>) and confirm appropriate organizations to request permission.

Obtaining permission to quote, reproduce; translate, etc.

Please contact the copyright holder directly.

IEICE Secretariat Office,

E-mail: permission@ieice.org

Permission request form: <https://db.ieice.org/chosaku/sinsei/index-e.php>

Fundamentals Review 第十八巻 第二号

令和六年十月一日発行

発行人	白石 智
発行所	一般社団法人 電子情報通信学会 基礎・境界ソサイエティ 〒105-0011 東京都港区芝公園 3-5-8 (機械振興会館内) 電話 03-3433-6691(代) FAX 03-3433-6659
WEB化担当	山岡影光
WEB化担当会社	三美印刷株式会社 東京都荒川区西日暮里 6-28-1