

目 次

【第 72 卷 11 月分】

研究室活動促進を目的とした自動出退勤システム .....高辻朋輝 小高知宏 黒岩丈介 諏訪いずみ 白井治彦	1
声質変換技術によるデータ拡張を利用した話者認証モデルの学習 .....平塚 喬 小高知宏 黒岩丈介 白井治彦 諏訪いずみ	9
ChatGPT と工学部教育 —生成 AI によって大学教育は変わるのか— .....平田隆幸	17

【第 72 卷 3 月分】

金融リテラシーを工学部学生にどう教育すれば良いのか —NISA の使い方のヒント— .....平田隆幸	27
決定木実現方法の違いによるスウィング動作の個人認証性能の違い .....河村隼輝 中島基晴 黒岩丈介 小高知宏 諏訪いずみ 白井治彦	37
コンテナ型仮想化による機械学習支援を目的とした計算機環境の実現 .....織田康太郎 小高知宏 黒岩丈介 諏訪いずみ 白井治彦	45
シェアサイクリングサービスの CtoC 化を目指したプロトタイプの実装 .....風折晃輝 小高知宏 黒岩丈介 諏訪いずみ 白井治彦	53

**Memoir of Faculty of Engineering, University of Fukui  
Vol. 72, March 2024**

**CONTENTS**

**【Vol.72 November】**

**Automated Attendance System to Facilitate Laboratory Activities**

.....Tomoki TAKATSUJI, Tomohiro ODAKA, Jousuke KUROIWA,  
Izumi SUWA , Haruhiko SHIRAI 1

**Learning Speaker Authentication Models Using Data Augumentation with Voice  
Conversion Technology**

.....Kyou HIRATSUKA, Tomohiro ODAKA, Jousuke KUROIWA,  
Haruhiko SHIRAI, Izumi SUWA 9

**ChatGPT and Education of Engineering Students of University  
— New Aspect of Education for University Students —**

.....Takayuki HIRATA 17

**【Vol.72 March】**

**How to Educate a Literacy of Financial Economy in Universities  
— A Hint of Recipe for NISA —**

.....Takayuki HIRATA 27

**Differences in Individual Authentication Performance of Swinging Movements  
Based on Decision Tree Methods**

.....Shunki KAWAMURA, Motoharu NAKAJIMA, Jousuke KUROIWA,  
Tomohiro ODAKA, Izumi SUWA and Haruhiko SHIRAI 37

**Realization of Containerized Virtualization of Computing Environments  
to Support Machine Learning**

.....Kotaro ODA, Tomohiro ODAKA, Jousuke KUROIWA,  
Izumi SUWA , Haruhiko SHIRAI 45

**Implementation of a prototype aimed at CtoC of bike sharing**

.....Koki KAZAORE, Tomohiro ODAKA, Jousuke KUROIWA,  
Izumi SUWA , Haruhiko SHIRAI 53

## 研究室活動促進を目的とした自動出退勤システム

高辻 朋輝\* 小高知宏\*\* 黒岩丈介\*\* 諏訪いずみ\*\*\* 白井治彦\*\*\*\*

### Automated Attendance System to Facilitate Laboratory Activities

Tomoki TAKATSUJI\*, Tomohiro ODAKA\*\*, Jousuke KUROIWA\*\*

Izumi SUWA\*\*\*, Haruhiko SHIRAI\*\*\*\*

(Received September 29, 2023)

we do not have enough communication due to coronavirus pandemic and Spread of information devices. Therefore, I have developed automatic attendance management system for the purpose of communication activation. I installed some function to system for increases communication. For example provide some topics to office member. After the system was developed, I operationally tested the system in laboratory. As a result, population increases and Slightly increases communication.

**Key words :** Automatic Attendance and Leave System, Improve Communication,

#### 1. はじめに

近年、情報機器の普及やコロナ禍によるオンライン化が進んでおり、そのような背景で一部の組織ではコミュニケーションの減少が問題となっている。問題となっている組織の例として、例えば出退勤の確認を重点的に行わないような大学のサークルや一部の大学の研究室などが挙げられる。このような出退勤の確認を行わないような組織の場合、出退勤確認を行わないことによる出席率の減少といった問題が起きる場合がある。出席率減少は組織内オフィス人口の減少に繋がり、組織内オフィス人口が減少することで、メンバーそれぞれの士気の低下、コミュニケーションの話題性の低下、コミュニケーションの機会の減少といった問題点が見られる。また、これらのような問題点によって、個人のコミュニ

ケーション能力の低下が発生する場合があると考えられる。

また、情報機器の普及によるオンライン化によって、オフィスに行かなくても業務を支障なく行えているといった点も先述した出席率の減少によるコミュニケーション能力低下の原因となっている。実際にオンライン化によってコミュニケーション能力が減少したと感じている人は多い。文部科学省が3243名のアンケート回答者に行った令和3年度「国語に関する世論調査」では、情報機器によって人と直接話す機会が減ったと回答した回答者が54.5%、自分自身言葉や言葉の使い方に問題があると感じるか?という設問に問題があると回答した回答者は67.6%という結果になった。また、自分自身言葉や言葉の使い方に問題があるか?の設問の解答を年代別に分析すると、60代、70代といった情報機器普及率が若い世代と比べて少なく、定年を迎え、コロナ禍による労働環境への影響を受けていない人が多い世代では、それぞれ「問題がある」と回答した回答者の割合が63.7%、54.2%となっているのに対し、10代、20代、30代などの情報機器の普及率が高く、労働環境、学生の生活環境がコロナ禍によって影響を受けていると考えられる世代はそれぞれ76.2%、78.3%、79.3%と非常に高い水準となっている。<sup>[1]</sup>

コミュニケーション能力は我々の間で非常に重要な能力の1つとなっている。コミュニケーション能力を高

\*1大学院工学研究科 知識社会基礎工学専攻

\*1Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

\*\*知能システム工学講座

\*\*Department of Human and Artificial Intelligent Systems

\*\*\*仁愛女子短期大学生活科学学科

\*\*\*Jin-ai Women's College

\*\*\*\*工学部技術部

\*\*\*\*Technical Division

めることは人間関係の構築や出世競争に繋がってくる。

そこで本研究では、出退勤システムを作成し、システムの在室ステータスや出席ステータスなどを利用することで、コミュニケーション活性化を目的とした機能を追加したシステムを作成する。また、出退勤登録を自動で行えるようにすることで、出退勤登録漏れなどによるシステムの各ステータスの誤りを減らし、機能が適切なタイミングで正しく動作を行えるように調節する。

コミュニケーション活性化を目的とした機能に関しては2つの観点からアプローチを行っている。1つ目が研究室内の学生に話題を提供し、それをコミュニケーションに用いてもらうというものだ。このように研究室内のコミュニケーション量を直接的に増やすことによって、コミュニケーション活性化を図る。2つ目は研究室内人口の増加である。研究室の学生の出席率向上、並びに研究室外部の学生の訪問数向上を行うことで、研究室内人口を増加する。研究室内人口を増加することにより、学生のコミュニケーション機会の向上や話題性の拡張を行い、コミュニケーション活性化を行う。

本システムを開発後、実際に研究室で運用テストを行う。運用テストを行うことで、本システムの出退勤登録の精度、並びにコミュニケーション活性化効果をアンケート調査などを通じて測定する。

## 2. 出退勤システムを用いた研究室活動の促進

### 2.1 出退勤システムの応用

1章で述べたように、近年、コミュニケーションの減少が問題となっている。そこで、自動出退勤システムを用いてコミュニケーションの活性化を行うことが出来れば、よりよいシステムになるのではないかと考えられる。このとき、出退勤システムを、出退勤の登録だけではなく、別の事項に応用するといったことは可能であるかという疑問が生じる。

しかし、このような事項は過去に研究されており、例えば、社員証型センシングデバイスを用いた健康管理システムの開発といった研究がある。<sup>[2]</sup> この研究では、多くの従業員が利用する社員証にRFIDを内蔵することで、RFIDリーダーを用いて運動量を収集するというものだ。このシステムでは、社員が出退勤を登録するときなどに同時に運動量を収集することが出来る。

先述したシステムのように、出退勤システムを、別の事項に応用するといったことは前例があり、可能であると考えられる。よって、本システムも自動出退勤登録を行うだけではなく、そこに付随してコミュニケーション活性化を図ることを主な目的とする。

### 2.2 コミュニケーション活性化の施策

本システムでは自動出退勤登録によって登録されている出席状況、在室状況をシステムのwebサイト上でいつでも閲覧できるようになっている。

しかし、それだけではコミュニケーション活性化に繋がる可能性は低い。そこで本システムにおいてコミュニケーション活性化に必要な施策を考える必要がある。

コミュニケーション活性化を図るための施策を考えるために、まずはどのような要素がコミュニケーション活性化を図るために必要かを考える必要がある。

コミュニケーション活性化に必要な要素は以下の2点であると考えられる

- 研究室内コミュニケーションの直接的な活性化
- 研究室内人口の増加による間接的な活性化

研究室内コミュニケーションの直接的な活性化は、研究室内人口がコミュニケーションを図るために最低限必要な2人以上の場合、研究室内人口に関係なくコミュニケーションの量を増やすという要素である。

研究室内人口の増加による間接的な活性化に関しては、研究室内の人口を増加させることによって、コミュニケーションの話題性の拡張、コミュニケーション機会の増加を増やすという要素である。

この2つの要素をコミュニケーション活性化を図るための施策を考察するための観点とし、研究室内コミュニケーション活性化に必要な施策を考察する。

#### 2.2.1 研究室内コミュニケーションの直接的な活性化

研究室内人口に関係なくコミュニケーション活性化を行うためには、コミュニケーションに繋がる話題が必要であると考えられる。ある程度親密度が高く、趣味や興味の方向性が同じである集団の場合、話題が多くコミュニケーションを図りやすいといえる。しかし、そこまで親密度が高くなく、趣味や興味の方向性も異なる場合、話題に乏しくなりやすく、コミュニケーションに繋がりにくい。そこで、集団に対して共通の話題を提供することで、それを話のネタとしてコミュニケーションに利用してもらい、コミュニケーション活性化を図るといいう「話題提供」という施策を用意している。「話題提供」という施策では、ニュースを話題として研究室の学生に提供するという機能を、施策達成を目的とした機能で搭載している。この機能の詳しい説明に関しては、3.2.1項で後述する。

## 2.2.2 研究室内人口の増加による間接的な活性化

この観点では、研究室内人口を増やし、コミュニケーションの話題性拡張や機会増加を行うことを目的としている。

研究室内人口を増加させるために必要な施策は以下の2点である

- 研究室出席率の向上
- 研究室外部の学生の接触量向上

「研究率出席率の向上」という施策に関しては、親密な学生の研究室在室状況をメールで送信するという機能で施策達成を目指す。親密な学生の在室状況をメールで送信することで、本来研究室に行く予定がなかった学生であっても研究室に出席する動機づけを行うことを施策達成を目的とする。この機能の詳しい説明に関しては3.2.2項で後述する。

「研究室外部の学生の接触量向上」という施策に関しては、研究室前に在室状況をモニターを通じて表示するという機能である。研究室前に在室状況を表示することで、研究室外の学生の心理的不安の解消などの観点から施策達成を目的としている。この機能の詳しい説明に関しては3.2.3項で後述する。

## 3. 出退勤システムの設計

本研究では、2.1節で述べたように、コミュニケーション活性化を目的とする自動出退勤システムの作成を目的とする。本研究では、システムの性能並びにコミュニケーション活性化効果の検証を私が所属している研究室で行うこととする。よって本システムは研究室 web サーバー上で運営し、研究室の学生に利用してもらうことを想定して作成する。

本システムは、Djangoと呼ばれるwebアプリケーションフレームワークを用いて作成する。<sup>[3]</sup>本章では、実際にDjangoを用いて作成したシステムの基本的な機能並びにコミュニケーション活性化を目的とした機能の概要を説明する。

### 3.1 基本的なシステムの機能

本節では、基本的なシステムの機能について述べる。基本的なシステムとは、ユーザーが本システムを利用するにあたり、必要とされる機能であり、例えばユーザー情報登録機能やログイン機能などがある。また、スマートフォンとノートパソコンを用いた自動出退勤登録機能も本システムを動作させるために必要な基本的な機

表1 登録ステータス一覧

登録ステータス一覧
ユーザー ID
パスワード
メールアドレス
スマートフォンの MAC アドレス
ノートパソコンの MAC アドレス
姓
名
学年

能の1つとなる。本システムにおける基本的なシステムの概要図を図1に示す。

#### 3.1.1 ユーザー情報登録機能

ユーザー情報登録機能は、本システムを使うために必要なユーザー情報を登録する機能である。登録するユーザー情報は以下のようになっている。

本機能でユーザーに登録してもらった機能に関しては、他の機能の様々な場面で用いられることとなる。

#### 3.1.2 ログイン機能

本機能はシステムにログインを行う機能である。ログインを行うことで、本システムのホームページに移行する。ホームページでは、出席状況確認機能やユーザー情報変更機能、また、節で述べるコミュニケーション活性化を図る機能にアクセスすることが可能である。ログインは3.1.3項のユーザー情報登録機能で登録したユーザーID、パスワードを用いてログインを行う。

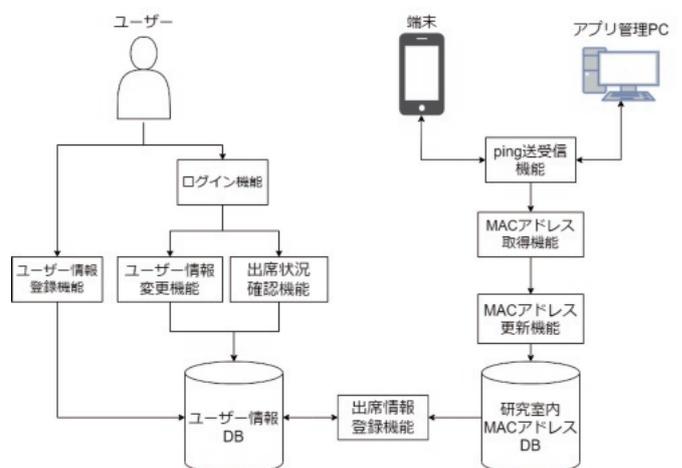


図1 基本的な機能の概要図

### 3.1.3 ユーザー情報更新機能

本機能はユーザー情報登録機能で登録したユーザー情報を更新するための機能である。何か登録したユーザー情報にミスや変更があった場合に用いることが可能である。

また、ユーザー情報登録機能やユーザー情報更新機能で登録、更新を行ったユーザー情報に関しては図1のユーザー情報DBに保存される仕組みとなっている。ユーザー情報DB内のユーザー情報に関しては、ログイン後、ユーザーが自身の詳細を確認することが出来る仕様となっている。

### 3.1.4 出席状況確認機能

本機能はログイン後のページで、研究室メンバーの出席、在室状況を確認できる機能となっている。本機能では各メンバーの名前、在室状況、出席状況、月ごとの出席日数が分かるようになっている。この機能により、他の研究室メンバーの在室、出席状況を判別できるようにすることで、研究室に学生が集まりやすくするという目的や、教授や学生が研究室メンバーの研究活動への取り組みの確認を行えるようにするという目的がある。

### 3.1.5 出席状況登録機能

本機能は研究室メンバーの出席、在室状況を自動で登録するという機能である。本機能における自動出退勤登録の仕組みは図1の右側のping送受信機能やMACアドレス収集・登録機能の部分となっている。また、より詳しく示したものを図2に示す。

ここで自動出退勤登録の具体的な流れを説明する。

まず、図2のシステム管理用PCを用いて研究室内のMACアドレスの収集を行う。本研究で開発する自動出退勤システムは、システム管理用PC上で動作している。MACアドレス収集ではpingコマンドやarpコマンドを

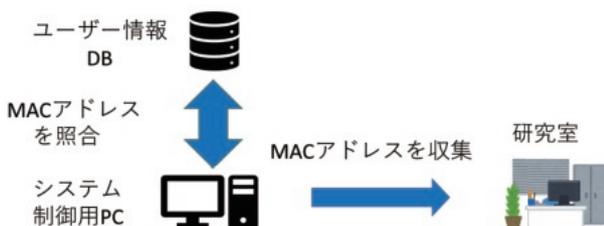


図2 自動出退勤登録の流れ

用いる。まず ping コマンドを用いることでシステム管理用 PC と研究室ネットワーク内に存在するモバイル端末間で ICMP パケットの送受信を行う。その後、arp コマンドを用いて収集した ICMP パケットにおける MAC アドレスを収集する。その後、3.1.3 項において図1及び図2のユーザー情報DBに登録してもらったMACアドレスと収集したMACアドレスの照合を行う。照合を行った結果、収集したMACアドレスとユーザー情報DB内のMACアドレスが一致すれば在室している。一致しなければ在室していないという判定となる。また、1日で初めて在室しているという判定になった時点で、出席したという判定となる。以上の流れで在室状況、出席状況の判定を自動的にを行い、その結果をユーザー情報DBに各ユーザーごとに保存する。

## 3.2 コミュニケーション活性化を図る機能

3.1 節では、本システムを構築する基本的な機能について述べた。しかし、本研究の目的は自動出退勤システムを用いた研究室活動の促進である。そこで、本節では研究室活動の促進を行うことを目的とした機能について述べる。

ここで研究室活動の促進を目的とした機能の概要を図3に示す。

図3に示すようにコミュニケーション活性化を図る機能には以下の3つが搭載されている

- A 話題提供機能
- B お気に入り学生登録機能
- C 研究室前在室状況表示機能

以下、各機能について詳しく説明する。

### 3.2.1 A 話題提供機能

話題提供機能では、トップニュースを収集し、それをWebページ上で公開する機能である。ニュースの収集

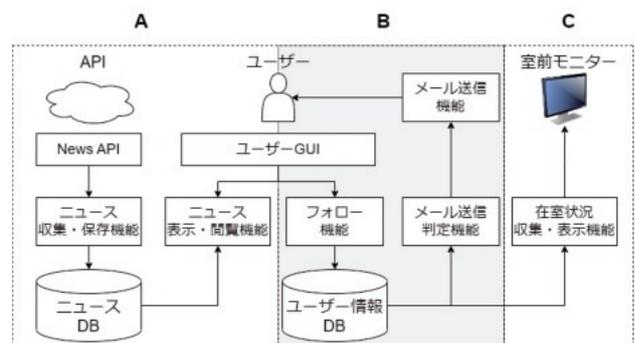


図3 研究室活動促進機能の設計

には News API を用いる。News API とは世界各国が発行しているニュースを取得できる API である。News API ではただ無作為にニュースを取得するだけではなく、ニュースの発行国やカテゴリを指定して、ニュースを収集することが可能である。<sup>[4]</sup> そこで、本研究では以下の2つのカテゴリのニュースを収集した。

- 日本のトップニュース全般
- アメリカの science カテゴリのトップニュース

日本のトップニュース全般に関しては、研究室の学生だけではなく、その他一般の日本人でもコミュニケーションに用いやすいようなニュースを話題として提供することを狙いとしている。

アメリカの science カテゴリのトップニュースに関しては研究室の学生が、勉学を通じて他の学生とコミュニケーションを図ることを目的として、ニュースの収集並びに提供を行う。

本システムは 3.1.2 項のログイン機能でログインした後に表示される 3.1.4 項の出席状況の確認を行える web ページ上のリンクより、アクセスすることが出来る。

### 3.2.2 B お気に入り学生登録機能

お気に入り学生登録機能では、研究室メンバーが他の研究室メンバーをお気に入り学生として登録することが出来る。

本機能を応用したのとして、お気に入りメンバーの在室状況をメールで送信するという機能がある。送信するメールの内容としては例えば図 4 のようなものになっている。

図 4 のメールでは、メール送信者がお気に入りユーザーとして登録していた佐藤さんと山田さんが研究室に在室している旨を伝える内容となっている。

ここで、メール送受信判定について述べる。メールを送信する判定は以下のようにになっている

- お気に入り学生が 1 人以上在室しているか

- メール送受信設定を許可にしているか

メール送受信判定は現在、各日 13 時 30 分に行われるように設定されている。この 13 時 30 分にお気に入り学生が在室していた場合、在室している学生の情報をユーザーにメールで送信する。一方、13 時 30 分にお気に入り学生が 1 人も在室していない場合、メールは送信されない。

また、ユーザーが独自にメールの受信を行うかを設定できる機能を搭載している。ここでユーザーがメールの受信を拒否する設定にしている場合、メールが送受信されることはない。

本機能では、お気に入り学生の在室状況をメールでユーザーに送信することで、本来研究室を訪れる予定がない学生であっても、「この学生がいるなら研究室に行ってみてもいいかも」などといった心理的思想にすることによって、少しでも研究室への出席率を上げることを目的としている。

### 3.2.3 C 研究室前在室状況表示機能

在室状況表示機能では、研究室前にモニターを設置することで、研究室外から学生の在室状況を判断できるようにする機能である。

本機能では、研究室内だけの学生だけではなく、研究室外の学生とのコミュニケーション活性化を図ることを目的としている。

本機能を通じて研究室外の学生とのコミュニケーション活性化を図るアプローチとしては、コミュニケーションを取りたい学生が在室しているかを確認できる点、また、心理的に入りにくい研究室であっても、研究室内に仲のいい学生が在室していれば、訪れやすくなるといった心理的安全性の向上がある。

## 4. システムに関する評価実験

本章では、本システムに関する評価実験について述べる。本システムに対しては以下の 2 種類について評価実験を行う。

- 自動出退勤システムの精度
- 自動出退勤システムに対するアンケート

### 4.1 自動出退勤システムの精度

自動出退勤システムの精度では、本研究で開発したシステムが適切に出退勤を登録できているのかを評価する。



図 4 送信メールの例

表2 精度測定実験の結果

ユーザー	精度
A	0.931
B	0.862
C	0.931
D	1.00
E	0.931
F	0.966

精度の測定期間は2023年6月10日～2023年7月8日とする。また、精度の計算式は以下のようになっている。

$$acc = \frac{correct}{days} \quad (1)$$

ここでaccは精度、correctは測定日の内、正しく出席を測定できていたもの、daysは総測定日(29)となる。

ここで、correctの測定方法について説明する。correctの測定方法は、まず研究室の学生に手動で出退勤をつけてもらい、学生が実際に研究室に出席したかを判別する。そしてそれを自動出退勤システムによる各学生の出席ステータスを日ごとに比較するという手法になっている。そしてある日の実際の学生の出席状況と自動出退勤システムによる出席ステータスを比較し、一致すればcorrectに1を加える。

学生の細かな在室時間に関しては、学生が研究室に入退出する際に、記録をとってもらおうという手法や、カメラを設置して監視するといった手法が考えられるが、今回は費用や環境、研究室の学生の負担を考え検証しないこととする。

以上より、研究室の学生6名を対象に測定した精度を有効数字3桁で示したものは表2のようになった。

研究室の学生6名に対してのシステムによる評価実験の精度では、平均約0.937となった。

#### 4.2 自動出退勤システムに対するアンケート

自動出退勤システムに対するアンケートでは、実際にシステムを研究室で運用を行い、その後研究室の学生並びにその他の学生に対してアンケートに回答してもらう。

そしてアンケートの回答結果から、本システムのコミュニケーション活性化効果について考察していく。

アンケート調査の対象に関しては以下の2通りを対象とする。

- 研究室の学生6名

- 研究室外の学生5名

また、アンケートのセクションは以下のようになっている。

- システム全体に関する評価
- 話題提供機能に関する評価
- お気に入り学生登録機能に関する評価
- 研究室前在室状況表示機能に関する評価

このうち、システム全体に関する評価、話題提供機能に関する評価、お気に入り学生登録機能に関する評価のセクションは研究室の学生6名を対象に、研究室前在室状況表示機能に関する評価では研究室外の学生5名を対象に評価実験を行っている。

また、システム全体に関する評価実験結果では研究室に来る頻度並びにコミュニケーション量の増加、それぞれの機能に関する評価実験では、機能の目的達成の評価を行っている。

実際の評価実験結果は図5～図10のようになった。

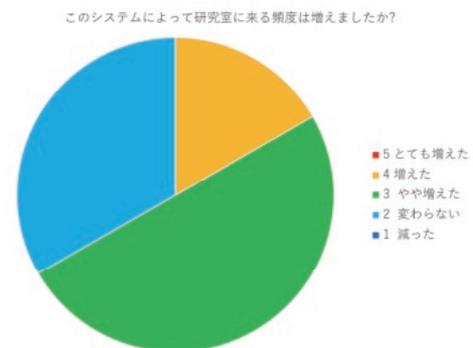


図5 システム全体に関する評価1

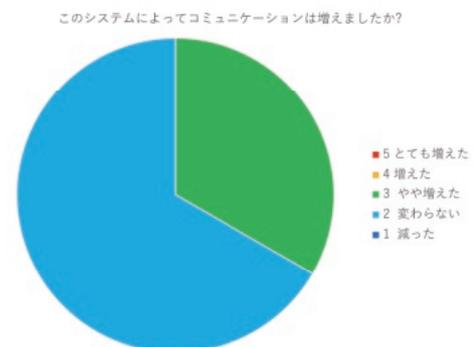


図6 システム全体に関する評価2

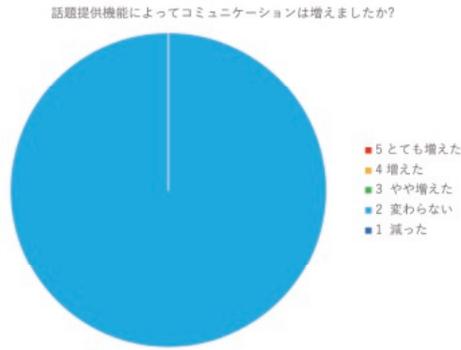


図7 話題提供機能に関する評価

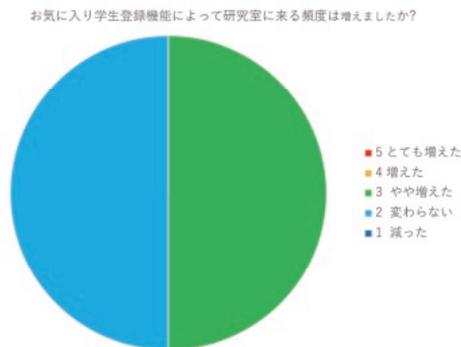


図8 お気に入り学生登録機能に関する評価

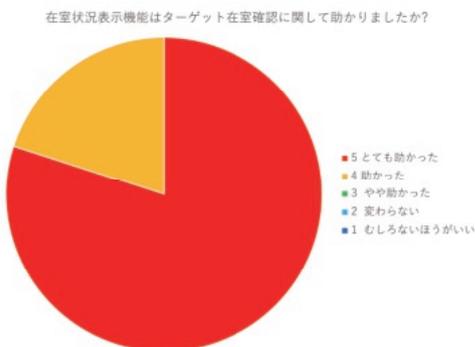


図9 研究室前在室状況表示機能に関する評価 1



図10 研究室前在室状況表示機能に関する評価 2

図5よりシステムによって研究室に来る頻度が増えたと感じた学生は66%, 図6よりコミュニケーションが増えたと考えた学生は33%であるといえる。

図7より話題提供機能では、コミュニケーションが増えたと感じた学生は皆無であることが分かる。

図8よりお気に入り学生登録機能では、50%の学生が研究室に来る頻度が増えたと回答している。

図9より、研究室前在室状況表示機能はターゲットとなる学生が在室しているかの確認に助かったと回答した学生が100%であることが分かる。また、図10より心理的負担が軽減したと回答した学生は60%であることが分かる。

## 5. 考察

### 5.1 精度に関する考察

表2より本システムの出席判定の精度は86.2%~100%となっていることが分かる。また平均精度は93.7%となっている。これは正確に測定できなかった日付が29日中0日~4日、平均2日あることを示している。この誤動作の原因としては、システムを運営しているサーバー作業による主退勤登録アルゴリズムの停止、また、3.1.5項より本システムは研究室内のモバイル端末のMACアドレスを収集することで、自動出退勤登録を行っている。しかしiPhoneは電源オフの場合、ICMP通信が出来なくなるなどの、iPhoneの動作に影響を及ぼさない通信を行わないという仕様となっている。この使用によりiPhoneユーザーの場合、正しく出席登録がされない場合があると考えられる。以上より、本システムの出席判定制度の向上を行うには、今現在の登録方法とは別の登録方法の追加、または、iPhoneの仕様に対する対策を講じる必要があると考えられる。

### 5.2 アンケートによる評価実験に関する考察

システム全体に関する評価実験結果から、本システムによって研究室の在室人数は増加、コミュニケーションは微力ながら増加したと考えられる。これの要因としては、3.1.4項の出席状況確認機能によっていつでも学生の出席、在室状況を確認できる点や、3.2節の3つの機能による影響が関わっていると考えられる。

話題提供機能に関しては、本機能によってコミュニケーションが増えたと回答した学生が0%であるのは、本機能に関して改善の余地があると考えられる。今回、話題提供機能ではある程度ジャンルを指定して無作為にトップニュースを収集し、話題として提供していた。しかし、提供したニュースの中には難しいビジネスに関するニュースといったコミュニケーションに発展させ

にくいニュースが多く、ユーザーからもっと話題にしやすいニュースを提供してほしいといった要望も見られた。話題提供機能に関して、このような改善を施す必要がある。

お気に入り学生登録機能に関する評価実験結果では、半数の学生が研究室に来る頻度が増えたと回答していることから、本機能では十分に研究室の出席率を上げることが出来ると考えられる。このことから、やはりお気に入り登録するような親密な関係の学生が研究室に在室していると、研究室に出席する意欲を上げることが出来ると考えられる。

研究室前在室状況表示機能では、アンケート結果よりターゲット在室確認並びに心理的負担の軽減両面において効果があったといえる。これらのことから、研究室外の学生が研究室を訪れやすくなっていると考えられる。

## 6. まとめ

本研究では、コミュニケーション活性化を目的とした自動出退勤システムについて開発を行い、その後システムの出勤登録精度並びにコミュニケーション活性化効果を考察した。

自動出退勤システムの精度に関しては、おおむね正しく出勤登録を行えているものの、やや誤作動が見られる場合がある。これは、本来ほぼ 100%の精度で出退勤登録を行うべき出退勤システムが、正しく出退勤登録を行うという目的を完全に達成しているとは言えないことを示しており、この点に関して改善を進めていく必要がある。

コミュニケーション活性化効果に関しては、研究室人口を増やすことが出来てはいるが、コミュニケーションの機会の増強に関しては、やや課題があるという結果となった。これより新機能の追加や、特に話題提供機能を含む各機能のアップデートを行い、コミュニケーション活性化効果を強化していく必要がある。

## 参考文献

- [1] 文部科学省 令和3年度「国語に関する世論調査」の結果の概要. [https://www.bunka.go.jp/tokei\\_hakusho\\_shuppan/tokeichosa/kokugo\\_yoronchosa/pdf/93767401\\_01.pdf](https://www.bunka.go.jp/tokei_hakusho_shuppan/tokeichosa/kokugo_yoronchosa/pdf/93767401_01.pdf), (2023-09-05).
- [2] 渡邊稔文, 山本直樹, 内藤克浩, 伊藤信行, 梶克彦, 中條直也, 水野忠則. 社員証型センシングデバイスを

用いた健康管理システムの基礎開発. 研究報告モバイルコンピューティングとパーベイシブシステム (MBL), Vol. 28, pp. 1-7, 2016.

- [3] Django ドキュメント - django documentation. <https://docs.djangoproject.com/ja/4.2/>, (2023-07-27).
- [4] News api – search news and blog articles on the web. <https://newsapi.org/>, (2023-08-21).

# 声質変換技術によるデータ拡張を利用した話者認証モデルの学習

平塚喬\* 小高知宏\*\* 黒岩丈介\*\* 白井治彦\*\*\* 諏訪いずみ\*\*\*\*

## Learning Speaker Authentication Models Using Data Augmentation with Voice Conversion Technology

Kyou HIRATSUKA\*, Tomohiro ODAKA\*\*, Jousuke KUROIWA\*\*,  
Haruhiko SHIRAI\*\*\*, Izumi SUWA\*\*\*\*

(Received September 29, 2023)

In this paper, we tried to improve the authentication performance by increasing the training data of the speaker authentication model using voice conversion technology. We used one of the deep learning speaker authentication models, "x-vector", and increased the amount of data by incorporating data created by statistical voice conversion techniques as new speaker speech data when training the model. From the experiment, a comparison between models that incorporated data created by the voice conversion technology and those that did not, confirmed that models that incorporated data created by the voice conversion technology performed better, albeit slightly. This suggests that increasing the amount of data using voice conversion techniques is effective in learning speaker authentication models, but its impact was limited; therefore, more detailed study of data generation by voice conversion is needed in the future.

**Key words** : Speaker Authentication, Deep Learning, X-vector, Voice Conversion

### 1. 緒言

本研究では、音声を用いた生体認証方式である話者認証において、音声の声質を変換する声質変換技術を利用して生成した音声によるデータ拡張を行うことによって、話者認証を実現するためのモデルの性能向上を試みた。

話者認証とは、人間の音声データの中に含まれる音声の話者の固有特徴を用いる認証方式である。話者認

証では、音声の入力だけで、システムに登録されているユーザーの認証を行うため、認証を行うユーザーに対する負担が比較的小さく、音声データの入力についてはマイクがあれば容易に実装することできるため、認証システムの導入コストも比較的低いとされ、その活用が期待されている。

その話者認証を実現するための手法は様々なものが提案されているが、近年では、他の分野でも用いられている深層学習を利用した方法が注目を集めている。深層学習を利用した手法では、従来の標準的であった手法と比べて高い性能が発揮するものもあり、その研究と標準化が進んでいる。一方で、深層学習を利用した手法では、モデルの学習に利用する音声データが大量に必要であり、学習に利用するデータの量が性能にも大きな影響をもたらしていることが知られている。

そこで、本研究では、深層学習を利用した話者認証手法の性能向上を目的とし、声質変換技術を用いてモデルの学習データを拡張することによって、深層学習を利用した手法における話者認証のためのモデルの性

\*大学院工学研究科 知識社会基礎工学専攻

\*Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

\*\*知能システム工学講座

\*\*Department of Human and Artificial Intelligent Systems

\*\*\*工学部 技術部

\*\*\*Technical Division

\*\*\*\*仁愛女子短期大学 生活科学学科

\*\*\*\*Jin-ai Women's College

能を向上させることを試みた。ここで、声質変換技術とは、音声に含まれる音響特徴を変換し、変換前の音声とは異なる声質をもった音声を生成する手法である。本研究では、声質変換技術を用いることによって、モデルの学習データとなる人間の音声データから、元の音声データとは異なる声質を持った音声データを生成し、その音声データを深層学習の学習データとして組み入れて話者認証用のモデルを学習した。そして、学習したモデルについて、声質変換によって生成した音声データを用いずに学習したモデルと比較しながらその性能を検証し、声質変換技術によって生成した音声データを利用してデータ拡張を行うことによってモデルの性能を向上させることができるかを確かめた。

## 2. 話者認証の手法とその問題点

### 2.1 話者認証の概要

話者認証は、人間が発声する音声を生体情報データとして利用し、入力された音声を発した話者が、システムに登録されたユーザーの音声か否かを識別することによってそのユーザーの認証を行うという認証方式である。この認証方式では、入力された音声データを解析して、その音声に含まれている話者固有の特徴を何らかの手法によって抽出し、元々登録されていた音声データからも同じ手法で特徴を抽出する。そして、抽出されたそれぞれの固有特徴について比較し、同一のものであるかを判断することによって、入力された音声の話者が元々登録されていた話者と同一話者か否かを決め認証を行う。話者認証を実現するための手法としては、機械学習によって構成される i-vector<sup>[1]</sup> に基づく手法、深層学習に基づく手法など、様々なものが提案されており、それぞれ高い性能を示している。

一方、近年では、深層学習に基づく話者認証手法の1つである x-vector<sup>[2]</sup> と呼ばれる手法が注目を集めており、盛んに研究が行われている。

### 2.2 x-vector による話者認証

本研究では、話者認証を実現するための手法として、x-vector に基づく手法を用いた。この手法では、図1のような特徴抽出部と識別部に分かれた深層ニューラルネットワーク (DNN) を用いる。

DNN の学習においては、まず、多数の話者によって構成される多数の音声データを用意し、それらの音声から音響特徴量を抽出し、発声した話者を識別するための話者ラベルを付与して学習データとする。次に、用意した学習データと DNN から、話者ラベルを教師データとする教師あり学習を行い、モデルが音声データの

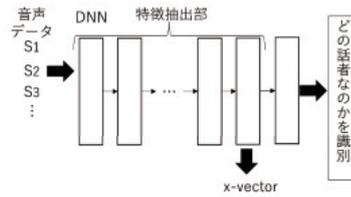


図1 x-vector の概略図

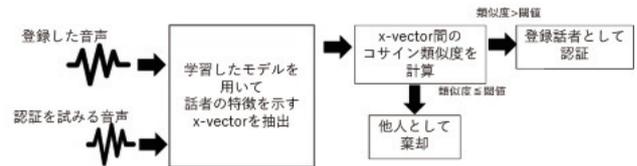


図2 本研究における話者認証の流れ

発声話者を識別することができるように学習を行う。この学習を行った DNN の特徴抽出部を利用することで、可変長の音声データから話者の特徴を効果的に示した x-vector と呼ばれる固定長のベクトルを抽出できる。これにより、音声データから抽出された x-vector を比較することによって、話者認証を行うことができる。

本研究における x-vector モデルに基づく話者認証の流れを図2に示す。本研究では、図2のように、登録されている音声(本人となる話者の音声)と、認証を試みる話者の音声を、学習した x-vector モデルにそれぞれ入力することによって x-vector を抽出し、抽出された x-vector を比較して類似度を求め、閾値によって本人か否かを区別することで認証を行うことを想定する。ここで、本研究において x-vector を比較するための類似度にはコサイン類似度を用いた。

### 2.3 x-vector の問題点と本研究のアプローチ

x-vector による話者認証は、i-vector などの従来の他の手法を上回る精度も報告されており、現在の話者認証における有用な方法の一つである。一方で、深層学習を用いた手法では、学習データが重要であり、高い性能を発揮するためには、学習を行うためのデータが大量に必要となる。x-vector による手法でも、深層学習を用いているため、x-vector の性能を高めるためには異なる複数の話者が発声した多数の発話音声データから構成される x-vector 用の学習データが大量に必要となるが、それらを準備することは容易ではない。そこで、本研究では、x-vector モデルによる話者認証の性能向上を目的とし、音声の非言語情報を変換することができる声質変換を用いて、既存の音声から新しい音声データを生成し x-vector モデルの学習データを拡張することをを行った。

### 3. 声質変換によるデータの拡張

#### 3.1 声質変換の概要

音声には、文字で伝えられるような言語情報と文字で伝えることのできない非言語情報の両方が含まれている。声質変換とは、音声の中に含まれる音の高さや音色といった音響特徴を変換することによって言語情報を維持したままで、非言語情報を変換する技術である。声質変換では、話者性のように、身体的制約が大きく、発声者による制御が困難な情報でさえも、自在に制御できるとされる<sup>[3]</sup>。

声質変換を行うためには、声質変換を行う変換元となる元話者と変換先となる目標話者の音声データを用いて、声質変換を行うためのモデルを事前に学習しておく必要がある。この時、声質変換の方法は、元話者と目標話者の音声データの関係性によって、「パラレル声質変換」と「ノンパラレル声質変換」に分けられる。パラレル声質変換とノンパラレル声質変換の違いについては以下の表1の通りである。

表1 パラレル声質変換とノンパラレル声質変換の違い

	パラレル声質変換	ノンパラレル声質変換
声質変換に利用する音声データ	同じ発話内容の音声データ (パラレル音声データ)	同じ発話内容ではない音声データ (ノンパラレル音声データ)
利点	より高い精度で簡潔に声質変換することができる	音声データの準備が比較的容易
欠点	音声データの準備が比較的難しい	パラレルの場合よりも手順が複雑で精度が低くなる

表1のように、パラレル声質変換の場合では、元話者と目標話者が同じ発話内容の音声データ(パラレル音声データ)を利用し、ノンパラレル声質変換の場合では、同じ発話内容ではない音声データ(ノンパラレル音声データ)を利用して声質変換を行う。ノンパラレルによる方法では、パラレルよりもデータの準備が容易であり、簡単に構築できるという特徴があるがパラレルによる方法では、ノンパラレルと比べると制約がある分、より高い精度で声質変換することができる。

本研究では、声質変換によるデータの拡張が可能であることを実証するために、より高精度な手法であるパラレル声質変換の方法を用いて声質変換を行う。

#### 3.2 本研究での声質変換の方法

本研究では、パラレル音声データを基にしたパラレル声質変換の中でも、混合正規分布モデル(Gaussian Mixture Model, GMM)を用いた最尤系列変換法によって行われる統計的声質変換と呼ばれる手法で音声データの声質変換を行った。このGMMを用いた統計的声質変換の流れについて図3に示す。

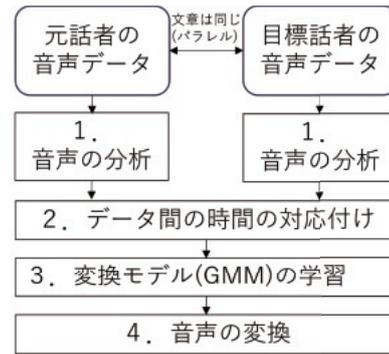


図3 統計的声質変換の流れ

以下に、図3に示したこの手法による統計的声質変換の流れの詳細を示す。

##### 1. 音声の分析

用意したパラレル音声データに対して、それぞれ分析を行い、音の高低に対応する基本周波数と、音色に対応するメルケプストラムを抽出することを行う。そして、抽出された基本周波数とメルケプストラムから変換処理で必要になる話者依存統計量系列を推定し取得する。

##### 2. データ間の時間の対応付け

文章が共通しているパラレル音声であっても、時間的に完全に対応しているわけではないため、時間的に対応するように前工程で取得した特徴量系列を変換する。

##### 3. 変換モデル(GMM)の学習

時間的に対応するように変換した特徴量系列を学習データに用いて、元話者の特徴量と目標話者の特徴量の結合確率密度関数をモデル化するGMMを学習する。

##### 4. 音声の変換

学習したGMMを用いて、元話者の音声を目標話者の音声の声質への変換を行う。この時、変換を行うのは基本周波数とメルケプストラムだけである。基本周波数は自然対数を取り、線形変換を行う。メルケプストラムは学習したGMMを用いて、結合確率密度関数が最大化されるように変換を行う。これらの変換によって、変換元となった話者の音声、言語情報はそのままに、目標話者の声質を持つように変換される。

なお、本研究では、sprocket<sup>[4]</sup>という統計的声質変換のためのソフトウェアを利用して、この声質変換を行った。

### 3.3 声質変換によるデータ拡張

本研究では、声質変換技術を用いてデータ拡張することで、x-vector モデルに利用する学習データに含まれる音声データの総数と話者数を増やすことを目指した。本研究における声質変換を用いたデータ拡張の流れについて図4に示す。

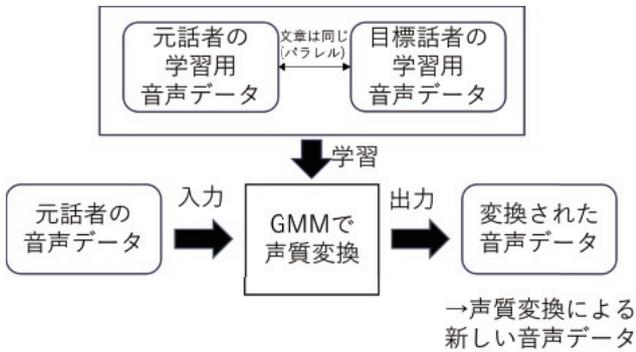


図4 声質変換を用いたデータ拡張の流れ

図4のように、声質変換を行う際には、まず、変換元となる元音声と、変換先となる目標音声をパラレル音声データとして実際の人間が発声し録音した音声データのコーパスから用意した。その上で、目標音声の話者の声質に変換することを目指して、元音声の声質を目標音声話者の声質へと変換するGMMを元音声データと目標音声データのパラレル音声データから学習した。そして、学習したGMMを利用して元音声に対する声質変換を行い、変換された音声データを作成した。この声質変換された音声データは、元音声をベースにしたもので目標音声の話者の声質に近い声質を持っているものとなるが、本研究では、この音声データについては元音声の話者でも目標音声の話者でもない全く別の新たなる話者による音声データと考えることとした。この方法によって、学習データから新たなる話者の音声データを増やし、声質変換によるデータの拡張を行う。

## 4. 実験

本研究では、前章で記述した声質変換によって生成した新しい話者の音声データをx-vectorの学習データに組み入れて学習を行った場合の有効性を調査するために、声質変換によって生成した音声データを学習データに加えてx-vectorモデルの学習を行い、声質変換によって生成した音声データを学習データに加えずに学習したモデルとの間でその認証性能を比較するという実験を行った。

### 4.1 実験に用いるデータセット

実験では、日本語音声のデータセットである「JVSコーパス<sup>[5]</sup>」と「つくよみちゃんコーパス<sup>[6]</sup>」に含まれる音声データをx-vectorモデルの学習及び検証を行うための音声データのベースとして用いた。

JVSコーパスは声優・俳優などのプロの日本語話者100人による合計30時間の音声データセットであり、それぞれの話者について、以下の表1に示す4つのサブコーパスから構成される150発話の音声データが含まれている。

表2 JVSコーパスの詳細

サブコーパス名	発話数(個)	説明
parallel100	100	パラレル音声
nonpara30	30	ノンパラレル音声
whisper10	10	ささやき音声
falset10	10	裏声音声

これらの音声は、wav形式で提供されており、サンプリング周波数は24kHzである。

また、つくよみちゃんコーパスにはJVSコーパスに含まれるparallel100と同一台本で発声されておりJVSコーパス内に含まれない話者によって別環境で収録されたサンプリング周波数96kHz、wav形式での100個の音声データが含まれている。

本研究では、モデルの学習およびテストの両方をこれらのデータセットで全て行うために、学習用データとテスト用データで表3のように分割を行った。JVSコーパスに含まれる100人の話者のうち90人分13500発話を基本の学習用データとして利用し、JVSコーパスに含まれる残りの10人の話者のうちparallel100だけの100発話およびつくよみちゃんコーパスの全発話を合わせた11人分1100発話をテスト用データとした。

表3 データセットの分割

	話者数(人)	発話数(個)	説明
学習データ	90	13500	JVSコーパスの90人分の全音声
テストデータ	11	1100	JVSコーパスの10人分のParallel100 + つくよみちゃんコーパス全音声(1人分)

### 4.2 声質変換による学習用データの拡張

モデルの学習データについては、学習用に分割したJVSコーパスの90人分のデータの中から声質変換を行うことで新しい話者の音声データを作成してデータ拡張を行った。

実験では、sprocketを用いてJVSコーパスのparallel100に含まれるパラレル音声データを声質変換する

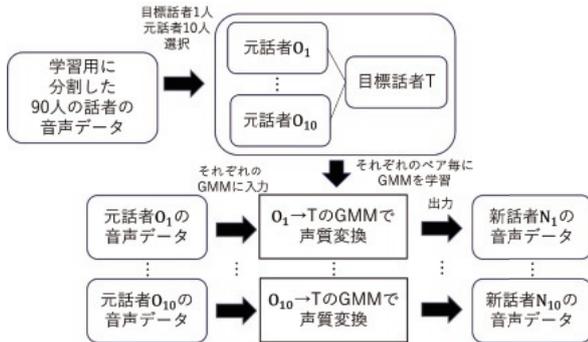


図5 実験における声質変換によるデータ拡張の流れ

ことで、声質変換による新しい話者の音声データを作成した。この声質変換によるデータ拡張の流れについて図5に示す。

図5のように、まず、学習データとして利用するために分割した90人分のJVSコーパスの中から1人を選択しそれを声質変換先となる目標音声の話者とした。次に、90人のうち、目標音声の話者として選択した話者以外の残りの89人の中から10人を選択しそれを声質変換元となる元音声の話者とした。これらによって選ばれた元音声話者10人と目標音声話者1人から(元音声話者、目標音声話者)として10組のペアを作りそれぞれのparallel100の音声からGMMを10組分学習することをを行った。そして、学習したGMMを用いて、元音声話者の音声データに対して、声質変換を行うことで声質変換によって生成された新しい音声データを作成した。

この時、sprocketの仕様に合わせるため、声質変換のために利用する元音声話者と目標話者の両方の音声データについては、サンプリング周波数を24kHzから48kHzへと音声処理ライブラリであるlibrosa<sup>[7]</sup>を用いてアップサンプリングした上で、学習と声質変換を行った。また、声質変換をするためのGMMの学習データにはparallel100に含まれる100個の発話の中から50発話分だけを利用した。声質変換に関しては、GMMの学習データに利用したものも利用しなかったものも含むparallel100に含まれる全ての音声について、変換を行った。これによって10人分1000発話の新しい音声データを生成しx-vectorモデルの学習データに組み入れることでデータの拡張を行った。

### 4.3 x-vectorモデルの学習

本研究では、学習用として分割した90人13500発話の音声及び声質変換で生成した10人1000発話を利用して2つのx-vectorモデルの学習を行った。このうち、声質変換で生成した音声10人1000発話について

はサンプリング周波数が48kHzであったため、librosaを用いて、48kHzから24kHzにダウンサンプリングを行い、学習データの全ての音声のサンプリング周波数は24kHzに統一している。モデルの学習には、音声関連の機械学習ライブラリであるSpeechbrain<sup>[8]</sup>を用いた。また、一般的なデータ拡張の一種として部屋の残響ノイズなどが含まれているRIRNOISE<sup>[9]</sup>も利用した。学習回数は15Epochとし、学習データ以外については、全モデルで統一して学習を行った。以下に各モデル毎に異なる部分について示す。

- モデル1  
90人13500発話の音声だけを用いて学習を行った。
- モデル2  
90人13500発話の音声に加えて、声質変換で作成した10人分1000発話も加えた100人14500発話で学習を行った。

### 4.4 x-vectorモデルの評価方法

学習したモデルに対して、事前に分割したテスト用データを用いて、性能を評価するための実験を行った。評価実験では、11人1100個のテスト用データから作成される全パターンである $1100 \times 1100 = 1210000$ ペアを、各モデルに入力し、各モデル毎に、それぞれの音声のx-vectorのコサイン類似度の計算を行った。この時、つくよみちゃんコーパスのデータに関しては、各モデルに入力する前に、librosaを用いてダウンサンプリングを行い、テストデータに関してもサンプリング周波数を24kHzに統一している。その後、各モデル毎に得られた1210000個の類似度をペアの音声両方も同一話者である場合と、同一話者ではない場合の2つのパターンにデータを分割した。

ここで、ペアの音声両方も同一話者である場合のデータは、システムに登録されていた本人が認証を試みたデータとし、同一話者ではない場合のデータは、システムに登録されていない他人が認証を試みたデータとした。そして、それぞれのデータに対して閾値を与え、類似度が閾値よりも低い場合には認証が拒否され、閾値よりも高い場合には認証が受理されたと考えた。

その上で、同一人物である場合のデータからは、閾値よりも低い値の割合を計算することによって、本人であるのに認証されない確率である本人拒否率(False Rejection Rate, FRR)を導出した。また、同一人物ではない場合のデータからは、閾値よりも高い値のデータの割合を計算して他人であるのに認証される確率である他人受入率(False Acceptance Rate, FAR)を導出した。これらの計算を与える閾値を変動させながら繰り返し

返して、閾値毎にそれぞれのモデルの FAR と FRR の結果を得た。

計算によって得られた結果については横軸に FRR を、縦軸に FAR を置き、閾値を変動させることによって描写して作られる両対数グラフである Detection Error Tradeoff(DET) 曲線<sup>[10]</sup>を図示してそれぞれのモデルの性能を比較するというを行った。また、FRR と FAR が一致する際のエラー率である等価エラー率 (Equal Error Rate, EER) についてもそれぞれのモデルにおいて計算して比較するというを行った。

## 5. 実験結果

2つのモデルに対して、テストデータ全てによる1210000ペアを入力して類似度を計算し閾値を変動させて FAR と FRR を計算した場合における DET 曲線について図6に示す。ここで、青色の点線は声質変換で作成した音声データを用いずに学習した「モデル1」を、赤色の線は声質変換で作成した音声データも学習データに組み入れて学習した「モデル2」を示している。また、線上にあるそれぞれの色の●印は、それぞれの曲線上で FAR と FRR が一致している箇所であり、EER となるエラー率を示している。EER についてはモデル1では1.9%、モデル2では1.8%となった。

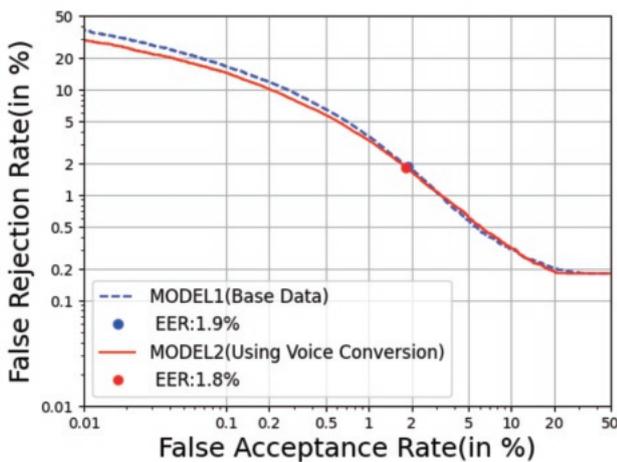


図6 全てのデータにおける DET 曲線

図6の DET 曲線では、FAR の3%程度の部分を境界にして、3%程度よりも低い部分ではモデル2がモデル1よりも図中の下側にあり、3%程度よりも高い部分では殆ど差が見られないという結果になった。また、EERの方ではモデル1が1.9%に対して、モデル2が1.8%であったため、差は大きくないが、モデル2の方が低いという結果になった。

## 6. 考察

図6では、声質変換によるデータ拡張を行ったモデル2が、FAR が3%程度よりも低い部分では、声質変換によるデータ拡張を行っていないモデル1と比べて低い位置にあるが、FAR が3%程度よりも高い部分ではあまり差が見られず、部分的にはモデル2の方が低いところもあるという結果になっている。DET 曲線では、FAR と FRR を図示しているが、これらは誤りの割合であるため両方ともより低い方が理想的であり、グラフでは下部に位置している方が望ましい。他方で、実際の認証システムにおいては、本人の認証を誤って拒絶することよりも、他人の認証を誤って受理してしまう方が、認証システムの役割上で大きな問題となるため FAR と FRR であれば、他人を誤って受理してしまう確率である FAR の方が重要視されやすいものである。よって、FAR が低い部分で、より高い性能を発揮しているモデル2の方が、DET 曲線による比較の上では、優れているのではないかと考えられる。

また、EER では、モデル1が1.9%、モデル2が1.8%となったが、EER も誤り率であり、前述の通り FAR も FRR もなるべく低い方が良いため、FAR と FRR が一致する場合の誤り率である EER も低い方が優れていると考えられるものである。したがって、EER による比較の上でもこの結果からはモデル2の方が優れているのではないかと考えられる。

これらの結果の分析から、声質変換によるデータを学習データに組み入れてデータ拡張を行ったモデル2の方が声質変換によるデータを学習データに組み入れていないモデル1よりも優れていると考えられる。よって、本研究の手法で声質変換を用いて生成したデータを学習データに組み入れてデータ拡張することによって x-vector による話者認証モデルの性能が向上することが示されたと考えられる。

しかし、一方で、本研究における実験での各モデルの性能差はそれほど大きくないものとなった。このことに関しては、声質変換によるデータを利用していないものでも性能が高いことや声質変換による学習データの拡張においてその量や手法が限られていることが影響しているのではないかと考えられる。したがって、発話長が短いものや声質が近い話者でのより難しいデータにおける実験の検討や、他の声質変換手法も交えて学習データ内における声質変換によって生成されたデータをより多様化したりその割合をさらに増やした場合での検討が必要になると考えられる。

## 7. 結言

本研究では、深層学習による話者認証モデルは高い性能を発揮するがその性能を発揮するために必要な学習データが膨大になるという問題点に注目し、実際の音声データから話者特徴も変換可能な声質変換技術を用いて音声データの声質を変換することによって新しい音声データを生成することで、深層学習を用いた話者認証モデルの一つである「x-vector」の学習データの拡張を行い、その話者認証モデルの認証性能を向上させるということを試みた。

声質変換による音声データの拡張の上では、より高精度な声質変換を行うことができるパラレル音声を利用した GMM による統計的声質変換を利用して、変換元となる元話者の音声データを、変換先となる目標話者の音声データの声質へと変換することを行い、その変換された音声データを新しい話者の音声データとすることで、話者数と音声データ数の両方を増加させるということを行った。

学習したモデルの性能を確かめるために行った実験より、声質変換によって生成した音声データを学習データとして用いてデータ拡張をしたモデルと声質変換によって生成した音声データを学習データとして用いてデータ拡張をしていないモデルとの間での比較から、声質変換によって生成した音声データを学習データとして用いてデータ拡張をしたモデルの方が限定的ではあるがその認証性能が向上することが示された。このことから、声質変換によって生成した音声データを深層学習による話者認証モデルの学習データとして用いることができるということが示唆された。

一方で、本研究での声質変換によって生成した学習データはその生成方法が限られており、データ増量の範囲も限定的である。そのため、声質変換によって生成したデータをより多く学習データに組み入れた場合や声質変換技術の中でもノンパラレルな音声を使った場合など別の方法を使って生成したデータを用いた場合にはどのように性能が変化していくのかということなどについてはより詳しく検討する必要があると考えられる。また、本研究での手法は実際の音声データからの声質変換による新しいデータの準備とモデルの学習が分離されているが、モデルの学習をより容易にしているためにはこれらを一挙に行うことができる新しいモデルを考案する必要性もあると考えられる。

## 参考文献

- [1] Najim Dehak, Patrick J Kenny, Reda Dehak, et al., "Front-end factor analysis for speaker verification", IEEE Transactions on Audio, Speech, and Language Processing, Vol.19, No.4, pp.788-798, 2010
- [2] David Snyder, Daniel Garcia-Romero, Gregory Sell, et al., "X-vectors: Robust DNN Embeddings for Speaker Recognition", 2018 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), pp.5329-5333, 2018
- [3] 戸田智基, "確率モデルに基づく声質変換技術", 日本音響学会誌, Vol.24, No.1, pp.34-39, 2010
- [4] Kazuhiro Kobayashi, Tomoki Toda, "sprocket: Open-Source Voice Conversion Software", Odyssey, pp.203-210, 2018
- [5] Shinnosuke Takamichi, Kentaro Mitsui, Yuki Saito, et al., "JVS corpus: free Japanese multi-speaker voice corpus", arXiv preprint, arxiv:1908.06248, 2019
- [6] つくよみちゃんコーパス (CV. 夢前 黎), <https://tyc.rei-yumesaki.net/material/corpus/>
- [7] Brian McFee, Colin Raffel, Dawen Liang, et al., "librosa: Audio and Music Signal Analysis in Python", Proceedings of the 14th python in science Conference 8, pp18-25, 2015
- [8] Mirco Ravanelli Titouan Parcollet, Peter Plantinga, et al., "SpeechBrain: A General-Purpose Speech Toolkit", arXiv preprint, arxiv:2106.04624, 2021
- [9] Tom Ko, Vijayaditya Peddinti, Daniel Povey, et al., "A study on data augmentation of reverberant speech for robust speech recognition", 2017 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), pp.5220-5224, 2017
- [10] Alvin F Martin, George R Doddington, Terri Kamm, et al., "The DET curve in assessment of detection task performance", Proceedings of the European Conference on Speech Communication and Technology (Eurospeech), pp.1895-1898, 1997



# ChatGPT と工学部教育

## —生成 AI によって大学教育は変わるのか—

平田 隆幸\*

### ChatGPT and Education of Engineering Students of University

#### —New Aspect of Education for University Students—

Takayuki HIRATA\*

(Received September 29, 2023)

ChatGPT has been attracting an extraordinary people's attention since first launched on November 30, 2022. ChatGPT is a generative AI (Artificial Intelligence) with huge parameters, which has possibilities to change the present common approaches in various fields. Education is one of most affected field due to appearance of ChatGPT. In this paper, I discuss the problem and potential of ChatGPT in university education.

**Key Words :** ChatGPT, Generative AI, Artificial Intelligence, University education, Case Study

#### 1. はじめに

ChatGPT<sup>[1]</sup>は、アカデミックな分野のみならず一般社会においても大きな注目を集めている。2022年11月30日にOpenAI社からプロトタイプが公開された生成AIであるChatGPTは、1週間たらずでユーザー数が100万を超え、2ヶ月ほどで1億人のユーザーに達した<sup>[2]</sup>。メールアドレスを登録さえすれば、無料で使えるChatGPTは、使用に際して特別な知識を必要としない手軽さもあり、一般社会を巻き込んだ大きなブームとなっている。コンピュータなどの基礎知識（リテラシー）及び金銭的なものも要求としない無料のシステムは、参入障壁が非常に低いものであった。無料（free）で使える有用なソフトウェアとしては、過去にも、Pythonなどがあったが、入門書などを読まずにシステムを構築するのは困難でもあった。しかし、ChatGPTはサイトにアクセスさえすれば使えるという点において画期的であった。

ChatGPTには、さまざまな用途が考えられる。教育現場での使用は、一つの可能性である。しかし、メリットとともにデメリットも存在する。ここでは、大学のレポート課題に生じた問題を議論する。

#### 2. 生成 AI

ChatGPTは、生成AIに分類される。AIの発展において、生成AIの登場は、過去のAIブームをはるかに超えるものであり、一般社会においても大きな注目を集めた。生成AIは、ニューラルネットワークによるAIの一種である。生成AIのニューラルネットワークも深層学習(deep learning)により学習が行われる。ニューラルネットワークという視点から見たChatGPTの特徴の一つは、学習するパラメータ数の膨大さにある。深層学習を用いたニューラルネットワークにおいて、パラメータの増加によりシステムの自由度が増し、処理できる能力が飛躍的に向上した。この恩恵を享受して、新たな可能性が芽生えたのがChatGPTに象徴される生成AIである。

さて、ChatGPTでは、数千億個（1750億個または3500億個と推測される）レベルの膨大なパラメータが使用されている。そして、この膨大なパラメータのチューニングには、大規模データが使用される。大規模データをパラメータのチューニングに使えるようになったため、ChatGPTに代表される生成AIが実用レベルに達した<sup>[3]</sup>。

\*大学院工学研究科知識社会基礎工学専攻

\* Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

#### 3. ChatGPT と大学教育

##### 3.1 ChatGPT の可能性

大学教育で ChatGPT をどのように使うことができるだろうか？2つの視点が存在する。1) 教育を受ける側の学生からの視点, 2) 教育を提供する側の教員からの視点である。ここでは, 教員の立場から大学教育における ChatGPT の可能性と問題点を議論する。具体例として, 「宮沢賢治と非線形科学」の講義を使う。



図1 講義「ロボットと非線形動力学」, 第16回: AIのトピック-ChatGPTの1, 3, 12, 14枚目のスライド

私が担当する福井大学の授業において, 最初に ChatGPT に言及したのは, 工学部の授業(専門選択, 機械・システム工学科ロボティクスコース, 3年生対象)「ロボットと非線形動力学」(授業コード:G1317, 履修者数 40 名)の第 16 回講義: AI のトピック-ChatGPT を使ってみよう- (2023 年 1 月 24 日, 学生に公開)であった。Google の Classroom のスライド (14 枚) を作成して紹介した (図 1 に使用したスライドを示す)。2022 年度後期の「ロボットと非線形動力学」で ChatGPT (2022 年 11 月 30 日にプロトタイプが公開)を紹介した時点では, 公開後 2 ヶ月あまりが経過していた。なお, ChatGPT は, 公開後 1 週間ほどで, 100 万ダウンロードが達成されたというソフトウェアであり, 2 ヶ月経過時点ではユーザー数は 1 億人を超えており, 学生間でもある程度は浸透していたと考えられる。

### 3.2 ChatGPT の登場による教育現場への影響

「宮沢賢治と非線形科学」を開講した 2023 年前期の時点では, 学生間において ChatGPT はさらに広く利用されていたと考えられる(「宮沢賢治と非線形科学」は, 共通教育科目(授業コード B3096: 履修者数 50 名)「開講年度 2023 年前期, 対象学部全学部, 対象学年全学年」である)。ChatGPT の登場から半年あまりが経過した 2023 年度前期には, 大学のレポート課題が影響を受ける可能性が生じ。また, ChatGPT を使った論文作成も議論されていた(例えば, 英語論文の作成時の補助に使うなど<sup>[4])</sup>。それゆえ, 授業中に ChatGPT などを使ってレポートを作成した場合, 使用したことを明示するように指導した。

## 4. レポートによる提出課題と ChatGPT の影響

### 4.1 講義内容と提出課題

講義中に, ChatGPT の有用性(危険性)・革新性に言及した。またレポートの作成時において, 書籍・論文などの文献のみならず Internet を使って調べる場合は, 引用元を明示するように注意した。

「宮沢賢治と非線形科学」の授業において, 3 回の課題レポートの提出を課した。MEET を通じて, 特に, 課題 2 と最終課題は, ChatGPT を使ってレポートを提出する場合は引用を忘れないように, 繰り返し注意した。

#### 課題 2 の内容

もし, 賢治が今も生きていたら, AI (人工知能) をどう思うだろうか, 記述しなさい。いろいろと想像してみよう。

課題2と最終課題を詳しく見ていこう。課題2として「賢治はAIをどう思うか」(5月21日公開, 提出期限6月9日(金))を課した(課題2の課題内容は前頁を参照)。

宮澤賢治は、時代に先駆け、レコードを聴いたり、チェロを習ったりなど、新しいものに興味を持ち、いろいろと挑戦していたことが知られている。宮澤賢治なら、AIにも興味を持ったであろうと仮定し、AIについても考えるようにするのが狙いであった。なお、課題2は、成績をつける元となる提出課題(6月9日〆切)であった。図2に、Classroomに公開した課題2を示す。



図2 Classroomに公開した課題2

提出課題である課題2は、第7回講義に対応したレポート提出課題である。それゆえ、直前に行われた授業、第6回講義および第7回講義についても簡単に見ておこう。

第6回講義「新しいものが好きな賢治」(5月8日公開)の8枚目のスライド(全19枚):スライド8(図3参照)でChatGPTをとりあげている。この講義で学生に、ChatGPTを紹介している。講義は、新しいものが好きであった宮澤賢治は、どのようにAIと向き合っただろうか?という問題提起をし、学生に考えるきっかけを与えた。講義では、スライド16からスライド19をもちいて、「ランボー風の詩をつくれ」という命令と「アルチュール・ランボー風の詩をつくれ」をChatGPTに入力して作詩した例を示した。



図3 第6回講義でChatGPTを紹介したスライド

第7回講義は、「宮澤賢治はAIをどう思うだろうか?」(5月15日公開)である。この講義では、将棋やチェス、さらに自動運転からAI(人工知能)に言及し、身体をもったAIとしてロボットを紹介している。このように、この授業ではAIについての興味を持たせ、自ら深く調べるように意図して授業を組み立てた。さらに、受講生には、AIおよびChatGPTについての興味および基本的な使い方について必要な知識は与え、かつChatGPTなど生成AIのメリットやデメリットに言及した。

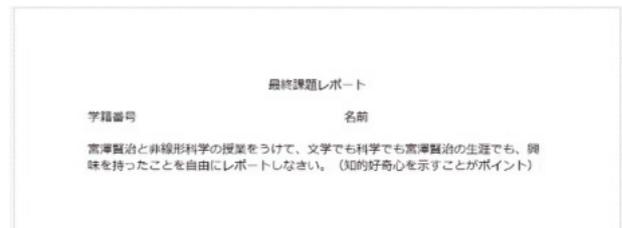


図4 Classroomに公開した最終課題レポート

#### 最終課題レポートの内容

宮澤賢治と非線形科学の授業をうけて、文学でも科学でも宮澤賢治の生涯でも、興味を持ったことを自由にレポートしなさい。(知的好奇心を示すことがポイント)

最終課題レポートは、受講生50名中45名が提出した。第15回講義(2023年7月10日, 公開)は、最終課題レポートである。提出期限は、8月4日(金)である。なお、第16回講義として、最終課題レポートの補遺(スライド2枚)を7月21日に公開している。

#### 4.2 ChatGPTのレポートへの影響

ChatGPTなどを利用して作成し、提出したと思われるレポートが現れた。レポートの作成に、ChatGPTを使用することは禁じていないが、使用した場合は、明記する(引用文献として引用する)ように繰り返して注意してあった。引用文献を示さず作成したレポートは、盗作になることも注意した。

しかし、今回のレポートでは、ChatGPTを使用した(ChatGPTにレポートを作成させた)と、明記してあるレポートはなかった。それにもかかわらず、ChatGPTによって作成したと推測されるレポートが数件あった。以下に、その例を挙げる。

最初に、ChatGPTの出現以前の過去のレポートには、現れなかった特徴から考察しよう。ChatGPT(お

よび生成 AI) を使用して作成されたと考えられるレポートに共通する点を挙げる。1) 明らかな誤りが繰り返されている。人間がチェックしたならばその後、容易に修正できる。2) 微妙に間違っている。

具体例として、4名のレポート提出者のレポート(学生 A~D) から一部抜粋しながら詳しく見ていこう。学生 A~D のレポートに共通点を挙げる。引用文献がない。そして、Google Classroom の機能を使って、盗用(独自性)を確認すると(フラグ済みの文章なし)となる(Google Classroom の機能では、盗用(ChatGPT を使って作成した)を見つけられない)。

なお、レポート提出者が特定できないように配慮するため、レポートの全文でなく、抜粋したもので議論した。一方、一部を抜粋して議論することによってレポート提出者を特定しにくいようにしたため、レポート全体が見えにくくなったかもしれない。しかし、ここでの目的が ChatGPT を利用して作成されたレポートであるかどうかを議論することに重点を置くことにしたことを思い出してほしい。逆に、原文を多く残したことによって、レポート提出者の特定ができてしまう可能性が高くなっているかもしれないことにも留意してほしい。

これから4名のレポートを個々に見ていく。提出されたレポートに、アンダーラインを付け、【】内にコメントを記していくことで議論する。学生 A のレポートから一部分を抜粋して示す。ChatGPT の使用を含め、論文等の引用はなかった。なお、繰り返になるが Google Classroom の機能を使って、盗用(独自性)を確認すると(フラグ済みの文章なし)となる。

#### 学生 A のレポート

私は「宮沢賢治と非線形科学」の講義を受けて、宮沢賢治の生涯や現在にどのような影響を与えているのか興味を持ちました。宮沢賢治は 1896 年 6 月 27 日に生まれ 1933 年 12 月 21 日に亡くなり、わずか 37 年の人生でした。【正しくは、8 月 27 日生まれ、9 月 21 日死去】……

宮沢賢治は、岩手県西磐井郡(現・岩手県花巻市)の農家に生まれました。【正しくは、岩手県花巻川口長】……

しかし、11 歳の時に父親を早くに亡くし、母親も病弱だったため、家族の経済状況は苦しかったです【正しくは、父親は賢治より長命であり、家庭は裕福であった】が、彼の内にある芸術的な才能は早くから芽生えていました。1916 年、東京帝国大学農科大学(現・東京大学農学部)に入学し、農学を学び

ながら文学の才能を磨きました。【正しくは、1915 年盛岡高等農林学校に入学】……

大学卒業後、宮沢は地元の盛岡高等農林学校(現・岩手大学)で教鞭を執りました。【正しくは、稗貫郡立稗貫農学校(翌年に岩手県立花巻農学校へ改称)】……その教育活動は彼の後の児童文学作品に大きな影響を与えました。1927 年に発表した童話「注文の多い料理店」が芥川龍之介賞を受賞し、文壇に躍り出るきっかけとなりました。【正しくは、芥川賞は受賞しておらず、芥川龍之介は、宮澤賢治と同時代人であり、芥川賞は、賢治の死後 2 年後 1935 年に創設されている】……

……その後も「銀河鉄道の夜」や「よだかの星」といった代表作を発表し、児童文学作家としての地位を確立しました。宮沢賢治は創造性と独自の文体によって、自然の美しさや人間の営みを詩的に描写しました。……

宮沢賢治の影響は、彼の死後も続いています。……現代の環境運動や持続可能なライフスタイルの提唱者たちにも、彼の思想が共鳴しています。宮沢賢治の言葉の魅力や表現力は、現代の作家や詩人にも影響を与えています。……

……人々に感動と勇気を与え、永遠に心に刻まれることでしよう。

学生 A の元のレポートは、約 2200 文字あまりのレポートであった。もっともらしくよく書かれたレポートであるのに、基本的なことが間違っており、ちぐはぐな印象をあたえる。授業では、4 月 24 日公開の第 4 回講義「宮沢賢治の略歴」では、宮澤賢治の年譜(三好京三編著、ジュニア文学館宮澤賢治<sup>[5]</sup>の一部をコピーしてスライドとして掲載してある)また、同時代の作家として、芥川龍之介にも言及している(スライドで示した)。このレポートは、レポート提出者が、授業や本・資料などを参考に自分で書いたものではないと思われる。

次に、学生 B のレポートを見ていこう。

#### 学生 B のレポート

今回、宮沢賢治と非線形化学の授業を通し、特に宮沢賢治の詩集についての講義に興味を抱いた。

「春の修羅」は、桜の花が咲き誇る春の光景を通して、生命の営みと絶え間ない変化を表現しています。

【正しくは、春と修羅であり、桜の花が咲き誇る春の描写はない】……しかし、詩の中には同時に死や破壊のイメージも組み込まれており、営みとは切っ

でも切り離せない死の存在を感じさせます。……  
彼の詩は豊かなイメージやメタファーが駆使されており、読んでいる間に心の中で花が咲き、風が吹き渡るような感覚に陥りました。【一部正しそうに思えるのが、かえって ChatGPT によるものと考えられる】  
 賢治の詩は、自然と人間の結びつき、善と悪の対立、そして生と死のテーマを織り交ぜているため、その深みに心を奪われました。…… 私自身も、「春の修羅」を読んで自然の息吹や命の尊さに改めて気づき、人間の営みに対する思いを新たにしました。…… 作品を読むことで、自然とのつながりや命の尊さ、善と悪の対立など、人間の根源的な問いに向き合う機会を得ることができます。今回宮沢賢治の詩集「春の修羅」を読んで関心を持った私は、宮沢賢治の他の作品にも興味を抱きました。【繰り返し、「春の修羅」といっているが、第 12 回講義「宮澤賢治の詩」（6 月 23 日公開）において、詩集「春と修羅」を取り上げている】…… 賢治の作品は、その深い思索と豊かな表現力によって、私たちの心に深い感銘を与えてくれました。私は今後も彼の作品を追求し、彼の世界に浸ることを楽しみにしています。

750 字ほどのレポートであった。Google Classroom の機能で「盗用（独自性）を確認する」をチェックしても「フラグ済みの文章なし」となる。

さらに学生 C のレポートを見てみよう。このレポートも Google Classroom の機能で盗用（独自性）を確認すると（フラグ済みの文章なし）となった。

#### 学生 C のレポート

自分はこの授業を受けてグスコーブドリの伝記に興味を沸きました。……

なぜグスコーブドリの伝記に興味を持つのかには、いくつかの理由が考えられます。

1. 心温まる冒険の物語: グスコーブドリの冒険は、飛行機の旅を通じて新しい場所を探索し、異なるキャラクターたちと交流を深める過程を描いています。【グスコーブドリの伝記は、グスコーブドリが飛行機に乗っての冒険ではありません。6 月 3 日公開の第 10 回講義「グスコーブドリの伝記」では、青空文庫を介して作品の一部を読めるようにしている。】これにより、読者は新しい経験と友情についての素晴らしい冒険に引き込まれました。
2. 自然との触れ合い: 宮沢賢治の作品は、……

3. 宮沢賢治の文学的才能: 賢治の作品は、……

4. 日本の児童文学の名作グスコーブドリの伝記は、日本の児童文学の中でも特に重要な作品として位置付けられています。日本の文化や価値観を理解する手助けとなるだけでなく、日本の児童文学の名作として国内外で多くの読者に愛されています。

宮沢賢治の他の作品も読んでみたいと思い、「注文の多い料理店」も読んでみました。……

この短編小説は、ジョージという料理人の視点から、さまざまな人々との交流を描写しています。【注文の多い料理店とは、まったくかけ離れており、唯一「料理店」が合っており、料理店からの連想であると思われる】ジョージの料理の美味しさに惹かれて訪れる客たちが、それぞれの物語や背景を持っていて、ジョージの心に深い影響を与える様子が描かれています。

…… この作品は、人間の心の温かさや大切さを感じさせることで、読者に感動を与えることが特徴です。

この授業でとても心を揺さぶられました。楽しく授業を受けられました。

約 850 字のレポートであったが、賢治の作品「グスコーブドリの伝記」「注文の多い料理店」を読んでいないと思われる。また、1, 2, 3, 4 と箇条書きにして書く様式は、ChatGPT で作成したものに良くみられる特徴である（次章で、ChatGPT で作成したもので現れた具体例を示す）。

最後に、学生 D のレポートを見ていこう。

#### 学生 D のレポート

宮沢賢治の『注文の多い料理店』執筆の動機  
 宮沢賢治は、日本の近代文学を代表する作家であり、詩人、童話作家としても知られています。……  
 本レポートでは、宮沢賢治がなぜ『注文の多い料理店』を執筆したのかについて考察します。  
宮沢賢治は、自然と人間の暮らしを観察することに熱心でした。彼は青森県の自然に囲まれた環境で育ち、農村の暮らしや自然の美しさに触れる中で、人間の生きる姿や社会問題に対する興味を持ちました。

【宮澤賢治が育ったのは、青森県ではなく岩手県です】

『注文の多い料理店』は、農村と都市の対比を通して、農村に対する彼の郷土愛と都市での人間の暮らしの様子に対する批判が描かれています。物語の舞台となる料理店は、農村から都市に出てきた主人公・斎藤と、その店主との対話を中心に展開されます。

【主人公は、斎藤ではありません】

物語の中で描かれる料理店の常連客たちは、それぞれ孤独な存在であり、都市の喧騒の中で人間関係が希薄になっていることが示唆されています。……

『注文の多い料理店』は、都市社会における人間関係の希薄さや孤立に対しての警鐘を鳴らす作品としても解釈できます。……

……。彼の作品には、自然と共生し、人間関係を大切に作る心の豊かさを取り戻す重要性が込められており、そのメッセージは今日においても意義深いものと言えるでしょう。

以上、700字あまりのレポートであった。岩手で生まれた宮澤賢治の出身地を青森としたり、注文の多い料理店の主人公を斎藤としたり、授業をうけた人間ならしないであろう基本的な誤りが散見された。

生成 AI を使って作成した文章かをチェックしてくれるサイト（例えば、GPTZero<sup>[6]</sup>）も現れた。しかし、4つのレポートを GPTZero を使ってチェックすると、AI によって作成した文章である確率は 0% という結果であった。ここで使用した GPTZero が英語サイトであるためか、サイトを使って AI が作成したという判断はできなかった。また、次章 4.3 に掲載した ChatGPT で作成した文章でも AI が作成したという判断はできなかった。なお、ChatGPT に「Who is T.S.Eliot?」という質問して出力された文章をチェックすると、74%の確率で AI を使い作成したものであると判断された。

### 4.3 ChatGPT (ChatGPT3.5) に聞いてみた

学生の提出したレポートが、ChatGPT など生成 AI を使用して作成したものを提出している可能性について考察してきた。しかし、提出されたレポートが ChatGPT で作成されたものか、そうでないかを確実に判断することは難しい。「疑わしい」と思えるが、「ChatGPT によって作成された」と確実に判定するのは、難しい。ここでは、学生が「宮澤賢治と非線形科学」で出された課題レポートを作成するために、ChatGPT にどのような質問をしたのかを想定し、ChatGPT の回答がどうであったかを見ていく。学生

の提出したレポートが ChatGPT を使ったものかの判定のためのヒントになるのではないだろうか。

以下に、今回の学生が提出してきたレポート（4.2 で見てきた）を作成するために、ChatGPT に質問したのではないだろうかと想定される 4 つの質問をしたときの ChatGPT の回答例を示す。

例 1 :

質問

宮澤賢治の生涯について教えて

ChatGPT の回答

宮澤賢治（みやざわけんじ）は、日本の詩人、作家、農学者で、彼の生涯は日本文学の中で重要な位置を占めています。以下は彼の生涯についての主要な情報です：

1. 生い立ち: 宮澤賢治は 1896 年に岩手県で生まれました。彼は農家の家庭に生まれ育ち、農業に関する知識を身につけました。この農村の環境が彼の後の作品に影響を与えました。
2. 文学活動: 宮澤賢治は詩、童話、小説、エッセイなど多くの文学ジャンルで活躍しました。彼の代表作には、「風の又三郎」や「銀河鉄道の夜」があり、これらの作品は今日でも愛読されています。
3. 農業と教育: 宮澤賢治は農学者としても知られており、岩手県内で農業指導に従事しました。彼は地元農村社会に貢献し、農業教育に尽力しました。
4. 健康と短い生涯: 宮澤賢治は健康の問題に悩まされ、結核などの病気に苦しんだことが知られています。彼は 1933 年にわずか 37 歳で亡くなりましたが、その後も彼の作品は多くの読者に愛され続けています。

宮澤賢治は日本文学の偉大な作家の一人として広く認識されており、彼の作品はその感受性と自然への深い愛情が反映されています。

例 2 :

質問

宮澤賢治のグスコブドリの伝記について

### ChatGPT の回答

宮沢賢治の童話「グスコーブドリの伝記」は、彼の代表作の一つであり、多くの人に愛されています。この童話は、宮沢賢治の生涯や作品の中でも特に重要な位置を占めています。以下は「グスコーブドリの伝記」についての主要な情報です：

1. 発表年: 「グスコーブドリの伝記」は 1932 年に発表されました。宮沢賢治が亡くなるわずか 1 年前に発表された作品であり、彼の最晩年の作品の一つです。
2. 内容: この童話は、主人公である少年グスコーブドリが、小さな鳥の王国での冒険を描いています。彼は鳥たちとの友情や共感を通じて、自然と調和する大切さを学びます。物語は、自然と人間の共存や環境保護のテーマを探求しています。
3. 影響: 「グスコーブドリの伝記」は、日本の童話文学において非常に重要な作品とされています。その深い哲学的要素や詩的な表現は、読者に感銘を与え、多くの人々に自然への尊敬と共感を促しました。
4. 細部への注意: 宮沢賢治はこの童話において、鳥たちの生活や感情に細かな注意を払い、人間と自然の結びつきを美しい言葉で描き出しました。そのため、この作品は多くの世代に愛され続けています。

「グスコーブドリの伝記」は宮沢賢治の文学的遺産の一部として、彼の作品群の中でも特に注目される作品であり、日本文学の名作として評価されています。

#### 例 3 :

##### 質問

宮沢賢治の注文の多い料理店について

### ChatGPT の回答

「注文の多い料理店」は宮沢賢治の短編小説で、彼の代表作の一つとして知られています。以下はこの作品についての主要な情報です：

1. 発表年: 「注文の多い料理店」は宮沢賢治によって 1924 年に発表されました。この短編小説は彼の文学的なキャリアの中で初期の作品の一つです。

2. 内容: この物語は、ある小さな料理店の経営者である鮎川（あゆかわ）と、彼が経験する奇妙な出来事を描いています。彼の料理店には、非常に特異な注文が多く寄せられ、それに応えるために奔走します。物語は鮎川の料理人としての生活や、彼の精神的な変化を探求しています。

3. 主題: 「注文の多い料理店」は人間の欲望、孤独、努力、そして意味を追求するテーマを探っています。物語は一見シュールでファンタジー的な要素を含んでいますが、その背後には深い哲学的洞察があります。
4. 影響: この作品は宮沢賢治の代表作の一つとして、日本の文学界で高く評価されています。その独特な筆致と深い思考内容は多くの読者に感銘を与え、多くの文学解釈や研究が行われています。

「注文の多い料理店」は、宮沢賢治の独創性と文学的才能を示す作品として、日本文学の現代的な古典とされており、彼の作品群の中でも特に知られています。

#### 例 4 :

##### 質問

宮沢賢治の「春の修羅」について教えて

【わざと、「春と修羅」を「春の修羅」と間違えて質問した。】

##### 回答

「春の修羅」は、宮沢賢治の詩の一つで、彼の詩作品の中で非常に重要な作品の一つです。以下は「春の修羅」についての情報です：

1. 発表年: 「春の修羅」は宮沢賢治が活着している間には発表されませんでした。宮沢賢治は 1933 年に亡くなり、その死後、彼の未発表の詩がまとめられ、出版されました。この詩もそれらの未発表作品の中に含まれています。
2. 内容: 「春の修羅」は、自然と人間の関係に焦点を当てた詩です。詩中では、春の訪れと共に自然界で起こる生と死のサイクルが描かれ、人間がその中で生きるものの意味や営みについて考察されています。

3. テーマ: この詩のテーマには、宮沢賢治の他の作品と同様に、自然と人間の調和、生命の脆さ、人間存在の哲学的な側面などが含まれています。詩の中には生と死、美と哀しみといった対照的な要素が表現されています。

4. 影響: 宮沢賢治の詩は日本の文学において非常に重要であり、その作品は多くの読者に愛され、研究されています。特に「春の修羅」は、彼の詩の中でも評価が高く、その深い哲学的洞察から多くの評論や評価が存在します。

「春の修羅」は宮沢賢治の詩の中でも美しい言葉と哲学的な内容が際立つ作品であり、彼の詩作品の中で特に注目されています。

上記では、学生のレポートとよく似た4つの質問をしたときの回答例を示した(9月23日、ChatGPT 3.5を使った)。これらの回答例と学生が提出したレポートを比較すると、共通している部分があるように思える。

## 5. おわりに

ChatGPTを大学教育で利用することの問題点を議論してきた。2023年前期、共通教育「宮沢賢治と非線形科学」のレポート提出課題において、提出されたレポートがChatGPTによって作成されたものである可能性について議論した。宮沢賢治と非線形科学の授業では、ChatGPTを取り上げ、ChatGPTを含む生成AIの可能性を紹介し、有効に使えば新しい世界が広がることに言及しており、ChatGPTを学習やレポート作成に使うことは否定していない。ただし、ChatGPTを使用してレポートを作成した場合、引用しなければならないこと(ChatGPTを使用した)を強調し、また現在のChatGPTは不完全であり、作成したレポートには誤りも多く含まれているので、下書きとして使用するのには良いが、チェックし、添削・修正しなければならないことを繰り返し注意した。しかしながら、今回、サンプルとして挙げたレポートは、引用がないうえに、多くの誤りを含んだままのものが提出されていたのが問題であった。

ChatGPTなどで作成したままのレポートの提出は、学生の学習にマイナスの影響があると考えられる。テクノロジーの進歩を妄信することを助長し、批判的な精神を育てることを阻害する危険性がある。現時点では、ChatGPTはまだ完成度が低いため、

ChatGPTで作成したものについて教員側は簡単に気が付くことができるが、ChatGPTなど生成AIの完成度が上がってきたときはどうなるのだろうか。人類は、生成AIの提案した回答(解)を盲目的に信じるようになるかもしれない。例えば、現在、電卓を用いて計算した計算結果に疑問をもつ人はほとんどいないように、多くの人々は「AIが提案した解を批判せずに信じる」ようになる未来が想像される。この段階になると、生成AIの出した回答を妄信してしまう人が多数派を占めるだろう。それゆえ、未来を担う大学生に批判精神が薄れてしまう可能性があることは、憂慮しなければならないことである。

生成AIは、ChatGPTに留まらない。Microsoft社のブラウザ、Microsoft EdgeにもAIが搭載され、検索エンジンBing<sup>[7]</sup>には、マイクロソフト社(マイクロソフト社はChatGPTを開発したOpenAIに出資していた)によると「AIとのチャット機能」BingAIが組み込まれている。アマゾンもアレクサ(Alexa:Amazonが提供するクラウドベースの音声サービス<sup>[8]</sup>)に生成AIを搭載して発売すると発表している。生成AIは、我々の生活にどんどん入り込み、身近なものになるだろう。

現時点での「宮沢賢治と非線形科学」の授業でのChatGPTを使うことによって生じた問題点のポイントは、「ChatGPTなど生成AIを使って、レポートを作成することを禁じてはいない。ただし、レポートを作成に生成AIの助けを借りた場合は、使用したこと明示(文献として引用)しなければならない」を守っていないことである。今回の例は、ChatGPTが作成したものをほとんどそのままレポートとして提出している点である。ChatGPTに代表される生成AIをもちいてレポートを作成することは、科学技術の進歩を効率よく使えているという意味で良いことであると言える。ただし、現時点では、AIの完成度はまだ低いので、そのまま提出するのは「レポート提出者」の問題である。しかし、将来、生成AIの完成度が高まったときは、どうなるのであろうか。その場合は、「レポート課題」自体が問題になる。生成AIでは、作成できない「レポート課題」を考えるなど、教員側の対応に問題がシフトしていくだろう。あるいは、レポート課題というものの自体の存在意義が問われるようになるかもしれない。

## 謝辞

本論文を執筆するにあたり、議論および有益なコメントをしてくださった高田宗樹教授、および研究室の吉田達成君に感謝いたします。

## 参考文献

- [1] ChatGPT <https://chat.openai.com/>
- [2] Alexandra Garfinkle·Senior Reporter, yahoo!finance  
ChatGPT on track to surpass 100 million users faster than  
TikTok or Instagram: UBS  
<https://finance.yahoo.com/news/chatgpt-on-track-to-surpass-100-million-users-faster-than-tiktok-or-instagram-ubs-214423357.html>
- [3] 田中 一男: 自社のデータで生成 AI を強化すべし: ファインチューニングしてビジネスに活用させたい基盤モデル (その1)  
<https://www.intellilink.co.jp/column/ai/2023/080200.asp>
- [x](#)
- [4] 牧聡: ChatGPT を使って論文の英文校正をする, 千葉大学大学院 医学研究院 整形外科 HomePage, [http://www.ortho.m.chiba-u.jp/research\\_tips/4709](http://www.ortho.m.chiba-u.jp/research_tips/4709)
- [5] ジュニア文学館宮沢賢治 写真・絵画集成 1 宮沢賢治の生涯, 三好京三編著, 日本図書センター, pp. 186 (1996)
- [6] AI 生成文章の検出するサイト GPTZero  
<https://gptzero.me/>
- [7] Bing <https://www.bing.com/?cc=jp>
- [8] alexa <https://developer.amazon.com/ja-JP/alexa>



# 金融リテラシーを工学部学生にどう教育すれば良いのか －NISA の使い方のヒント－

平田 隆幸\*

## How to Educate a Literacy of Financial Economy in Universities － A Hint of Recipe for NISA－

Takayuki HIRATA\*

(Received January 19, 2024)

Financial education in universities is now an important matter. Japanese government has been promoting financial education for all generations. “From savings to investment” is the government’s slogan. The questionnaire survey on financial literacy of engineering students is carried out. NISA (Nippon Individual Saving Account) is the Japanese government’s tax incentive program for its citizens. The strategy how to use the benefit of NISA is discussed. Simulations of periodic and lump-sum investments were carried out by using Python. In this paper, I discuss how to educate basic knowledge of the financial system in university education.

**Key Words** : Financial education, NISA, University education, Lump-sum investments, Periodic investment, Simulation

### 1. はじめに

大学生など若い世代の金融リテラシー教育の必要性が議論されている。政府は若い世代の金融経済教育に力を入れており、2022年4月から高校で金融経済教育を義務化した<sup>[1]</sup>。同時に、高校学習指導要領改訂では、金融経済教育の内容が拡充された。また、金融庁のホームページ<sup>[2]</sup>において、「利用者の方へ」という項目の下に、「中学生・高校生向け」のパンフレット・教材等が準備されており、「中学生・高校生のみなさまへ」<sup>[3]</sup>のタイトル下、金融教育の教材としてのPDF<sup>[4]</sup>などの多くのコンテンツが公開されている。なお、「社会人になる方向け」「一般向けパンフレット等」の項目の下にも、「中学生・高校生向け」の項目の下に掲載されていた同じPDF「基礎から学べる金融ガイド」<sup>[4]</sup>が掲載されている。

政府は、若い世代の金融教育とともに、国民の資産運用を促している。このことは、金融庁のホームページのトップで、トピックスとして、NISA、資産

運用立国などが取り上げられていることからわかる。さらに、政府は2023年6月に持続的成長に貢献する「資産運用立国」を目指す方針を閣議決定し、「経済財政運営と改革の基本方針 2023 加速する新しい資本主義～未来への投資の拡大と構造的賃上げの実現～」(骨太方針 2023)」を示した<sup>[5]</sup>。

さて、現時点で大学に入学している大学生は、どのような金融教育を受けてきており、どれだけの金融リテラシーを身につけているのだろうか？すでに大学に入学している学生が高校生だったころは、金融教育の端境期であり、十分な金融教育をうけていない可能性がある。しかし、今日の金融学では数学・コンピュータを使うことが必須となっており、工学部を含む理科系の学生の方が金融を理解するのに有利であり、チャンスと言えるかもしれない。

本論文では、現役の大学生・大学院生の金融リテラシーについての状況を調査し、工学部の学生の長所を生かした金融教育の可能性を議論する。特に、金融庁のシミュレーション<sup>[6]</sup>を参考にしながら、金利(複利の効果)とPythonプログラムに焦点を当てて工学部における金融教育の可能性を議論する。

\*大学院工学研究科知識社会基礎工学専攻

\* Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

## 2. 金融資産とは

最初に、本論文で議論する金融資産についてみておこう。金融資産の解説については、日本銀行のホームページが充実している<sup>[7]</sup>。ここでは、日本銀行のホームページを軸に、金融資産の基礎情報をみていくことにする。

政府（担当省庁は金融庁）は、なぜ「貯蓄から投資へ」と、投資を勧めているのだろうか？ここで、日本と海外との比較をしてみよう（日米欧の比較PDF<sup>[8]</sup>を中心にしてみていく）。特に、家計の金融資産に焦点を当ててみていくことにする。図1に日米欧の家計の金融資産の割合を示す。

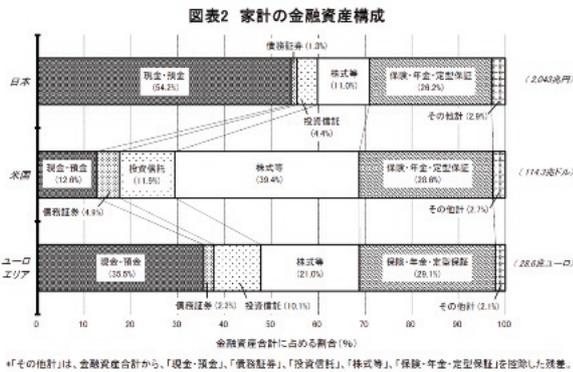


図1 日米欧の金融資産の構成（日本銀行ホームページから引用）<sup>[8]</sup>

家計の金融資産の割合を日米欧で詳しく比べてみよう（ユーロエリアを欧州とする）。データとしては、金融庁のホームページに掲載されているデータを用いることにする。家計の金融資産の割合において、日本は現金・預金の比較が米国や欧州と比べて大きい。現金・預金の比率は、日本 54.2%、米国 12.6%、ユーロエリア 35.5%である。日本は、現金・預金の比率が米国・欧州と比べてとびぬけて大きい。一方、リスク資産である投資信託と株式等は、日本：投資信託 4.4%、株式等 11.0%、米国：投資信託 11.9%、株式等 39.4%、ユーロエリア：投資信託 10.1%、株式等 21.0%である。そして、保険・年金・定額保証は、日本：26.2%、米国：28.6%、ユーロエリア：29.1%と日米欧とも3割弱と大きな差はない。

日本と米国の金融資産の割合の大きな違いは何であろうか？日本は、現金・預金の比率がとびぬけて大きいことである。日本の金融資産における現金・預金の比率は、米国の4倍以上である。なお、ユーロエリアと比較しても約1.5倍である。逆に、米国の金融資産における現金・預金の比率が日本やユー

ロエリアと比較して非常に低いと言える。一方、リスク資産である投資信託と株式等を合わせた金融資産を比べると、日本：米国：ユーロエリアの比は、15.4：50.4：21.1となる。米国の家計は、リスク資産の割合を日本の3倍以上保有していることになる。

米国は、1978年に制定された401K（確定拠出型年金）を通じて投資信託・株式等の保有率が大きくなったという経緯がある。日本は、公的年金制度が米国と比較して充実していたことがあり、個人で準備する確定拠出型年金が広まらなかったとも言える。それゆえ、米国人は株価上昇の恩恵を享受することになり、家計の金融資産が大きく増えた。2000年末を100としたとき、20年間で家計の金融資産は、米国で約3倍、日本で約1.4倍になった<sup>[9]</sup>。

日本は、出生率の低下により人口減少が予測され少子高齢化社会になると考えられている。それゆえ、公的な年金制度の維持が困難になることが予想される。そのため、公的年金のみでは老後の生活が苦しくなると思われ、自己責任の名のもとに個人が各自老後資金を準備する必要性が大きくなっている。以上、国レベルの違いをみてきたが、つぎに個人レベルの老後の金融資金について考える。

個人が、老後資金を準備する方法の一つとして、銀行預金が考えられる。日本においては、老後資金の準備として前述のように銀行預金が主流であった。しかし、銀行預金の金利は非常に低い。例えば、三菱UFJ銀行の定期預金の金利は、1年定期：年0.002%、3年定期：年0.002%、5年定期：年0.07%、10年定期：年0.2%である（2024年1月1日時点）。物価が上昇しないデフレーション時代であれば、この金利でも大きな問題はない。しかし、インフレーション時代においては、お金の価値が年とともに減ってしまう。例えば、年3%のインフレーションが10年間継続した場合、100円で買ったものが10年後には約134円必要になり、円の価値が約74%に減じたことになる。これでは、銀行に定期預金しておくだけでは、老後資金は守れない。

そのため、各個人がリスクを取って、リスク資産である投資信託や株式に投資をする必要性が生じたのである。そのため、国民は、これまで以上に正しい金融知識を持ち、金融リテラシーを高める必要がある。

## 3. 大学生の金融知識に関する状況

「貯蓄から投資へ」のスローガンの名のもとに、国民は、正しい金融知識をもつ必要性を迫られている。政府もこの指針のもとに、2022年4月に高校学

習指導要領を改訂し、高等学校における金融経済教育の内容が拡充した。しかし、現時点では、大学生の多くは、金融教育を受けておらず、「貯蓄から投資へ」時代に必要な金融知識を有していない危惧がある。ここでは、大学生の有している金融知識についての状況を調べる。

さて、現在の福井大学工学部の学生の金融知識についての現状をみてみよう。そこで、研究室の学生に協力してもらい、アンケート調査をした。2023年12月20日（水）の3時限の研究室のゼミナールの時間を利用してアンケート調査を実施した。アンケートには、インターネットなどを使わず、アンケート実施時点での知識で答えるように注意した。また、アンケートの回答時間は、3分とした。大学院生7名、学部4年生9名の16名がアンケートに答えてくれた。アンケートはGoogle Classroomを使って実施した。質問事項は、はい・いいえで答える13問であった。また、アンケートの回答と回答者を特定できないようにした。付録1に、アンケート内容とGoogle Classroomのアンケート画面を載せておく。

図2に、Q2～Q13のアンケート結果を円グラフで示す。それぞれのアンケート結果を詳しくみていこう。Q2～Q4：高校生の時に金融教育の授業を受けていない学生が大半であるが、多くの学生が金融庁の存在を知っており、「貯蓄から投資へ」という政府からのメッセージも知っていた。Q5～Q7：NISAについて多くの学生が知っており、興味もっていた。しかし、認知が十分であるとは言えなかった。Q8：複利の効果についての概算については、半数以上が過小評価していた。Q9～Q10：ドルコスト平均法について、回答者全員が知らなかった。Q11～Q13：銀行預金に関する知識（元本保証、銀行が破綻したときの1000万円までの保証など）も完全に理解されているとは言えなかった。

#### 4. 金利と投資

「貯蓄から投資へ」という意味を考えよう。投資には、株式投資、債券投資、不動産投資、金への投資など様々な投資がある。しかし、ここでは議論を簡単にするため、投資は株式投資に限定して議論する。

政府が勧める「貯蓄から投資」には、暗黙の大前提が存在する（金融庁HP：投資を行っている方へ、証券税制が変わります<sup>[10]</sup>）。金融市場は、長期的に成長するという前提である。年単位レベルの短期的には、プラスにもマイナスになるという揺らぎは存在

するが、10年単位という中長期レベルではプラスに成長するということである。政府の新NISAにおいて、株式の配当金（ETFの分配金を含む）による利益（インカムゲイン）や取得した株式の値上がりによる利益（キャピタルゲイン）が無税になるシステムである。プラスになった利益にかかる税金が0になるのであって、マイナスになった場合にはメリットはない。逆に、マイナスになった場合、NISA以外の口座でのマイナスは確定申告をすることにより税金が返ってくる可能性があるが、NISA口座の場合は、損失になった場合は考慮されていない。本論文では、長期的に年利がプラスであっても短期的にはマイナスになることがあることによる影響を考察する。

最初に、複利の効果を考える。例えば、100万円を年利10%で10年間運用すると、10年後には約260万円になる。金融庁のホームページには、金融庁・資産運用シミュレーションがあり、複利の効果がわかりやすく示されている<sup>[6]</sup>。図3に、金融庁の資産運用シミュレーションをホームページの様子を示す。ホームページにおいて、毎月の積立金額、想定利回り、積立期間の3つを入力することにより、最終積立金額が出力される。



図3 金融庁 資産運用シミュレーション(2023年12月30日)から引用<sup>[6]</sup>

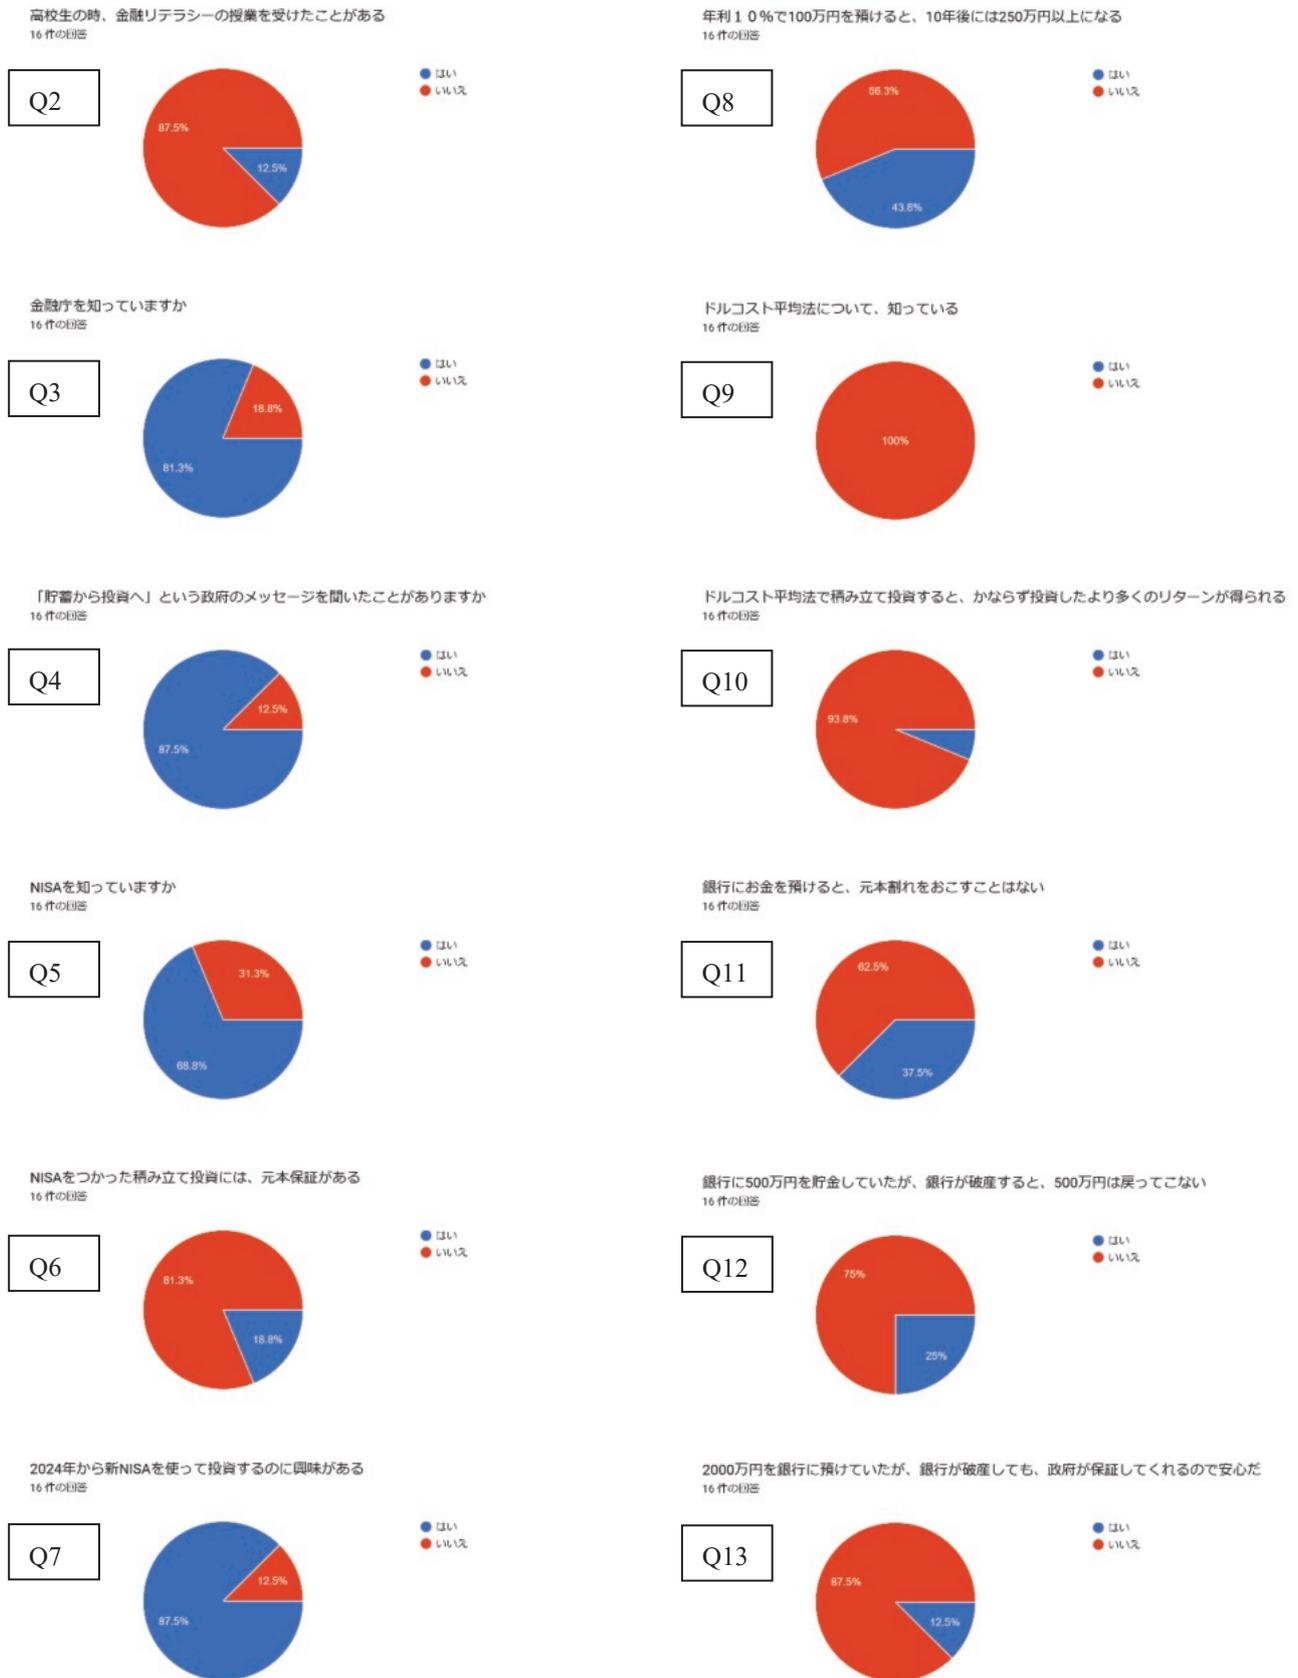


図2 Q2～Q13の回答結果の円グラフ

本論文は、利回りに焦点を絞って、工学部の学生が興味をもち、かつ各自が Python などのプログラミングを行うことによって、より深い理解へのきっかけとなることを目指す。そこで、金融庁のホームページのシミュレーションをより現実に即した改良を行うことを通して、工学部ならではの金融リテラシー教育の可能性を試みる。

#### 4.1 金利に揺らぎのある場合

複利の効果をみていこう。もっとも簡単な例から始める。元本  $P$  を年  $R\%$  の利回りで運用した場合、 $n$  年後の資金  $F$  は、

$$F = P(1.0 + R/100)^n$$

となる。 $R > 0$  の時、資金  $F$  は年毎に幾何級数的に増加する。

これは、 $R$  が一定であると仮定したときの計算式である。銀行預金においてさえ、利回り  $R$  は変化する。株式投資の場合は、さらに大きく変化する。例えば、日経平均に連動する金融商品に投資した場合、元本割れすることもある。それゆえ、市場金利（想定利回り）に揺らぎがあった場合の投資した資金の時間変化をみるシミュレーションを行うことは重要である。

さて、工学の学生の金融教育を想定した場合、学生に金利  $R$  が揺らぐ場合の資金  $F$  がどうなるかのシミュレーションのプログラムを作成させることは、興味深いことではないだろうか。例えば、Python のプログラムを課することで、金融教育へのモチベーションアップと同時に生きたプログラミング教育が期待できる。そこで、年毎の金利  $R$  に正規分布に従う揺らぎがある場合のシミュレーションを行い、一括投資と時間分割投資の時のリスクとリターンについてみていく。

#### 4.2 一括投資と時間分散投資

一括投資と分散投資について考える。投資においてリスク分散のために、分散投資が推奨されることが多い。例えば、株式市場で A 社と B 社の 2 社に投資が可能であるとしよう。ケース 1 : A 社 1 社だけに 100 万円投資するのと、ケース 2 : A 社に 50 万円 B 社に 50 万円と分散投資をする場合を考える。もし A 社の株価が半額になったとき、ケース 1 では資金は 50 万円になってしまうが、ケース 2 では資金は 75 万円になり損失は軽減される。それゆえ、リスク分散のために、分散投資が推奨されるのである。しかし、A 社の株価が 2 倍になった場合は、どうだろうか？ ケース 1 では資金は 200 万円になるのに対して、ケース 2 では資金は 150 万円にしかならない。

つまり、リスクもマイルドになるが利益もマイルドになってしまう。老後資金の形成など長期での資産形成を考えた場合、リスクを小さくする方が優先されるため、少数個の銘柄に集中投資するよりもある程度多くの複数個の銘柄に投資する分散投資が推奨されるのは理にかなったことである。

次に、時間分散投資について考察しよう。例えば、100 万円を S&P500 に連動する ETF (Exchange Traded Fund の略) に投資する場合を考えよう (S&P500 に連動する ETF の場合は、500 社に投資することになるので最初から銘柄分散されている)。年利回りは一定であるとしよう。100 万円を最初一括投資するのと毎年 10 万円を 10 年間かけて分割投資をする場合を考える。年利回り 10% で S&P500 に連動する ETF に 100 万円一括投資した場合は、10 年後には、複利の効果で約 260 万円になる。一方、毎年 10 万円ずつ 10 年間かけて分散投資した場合は、等比数列の和の公式に従って、

$$10(1 - 1.1^{10}) / (1 - 1.1) \approx 159$$

約 160 万円となる。元本  $P$  を年  $R\%$  の利回りで  $n$  年間積み立て投資をした場合の資金  $F$  は、

$$F = P (1 - (1 + R/100)^n) / (1 - (1 + R/100))$$

である。年利が一定で市場が成長するとき、100 万円の資金がある場合、時間分散させて投資するより、最初一括投資した方が明らかに大きなリターンが得られる。

しかし、現実的には年利には揺らぎが存在するので、一括投資には危険がともなう。例えば、まとまった資金として退職金を一括で投資するのはリスクが大きい。そのため、政府の新 NISA でも最大 1800 万円の投資枠は、最短でも 5 年間かけて投資するように設計されている。

では、年利回りに揺らぎがある場合について考察しよう。ここで、シミュレーションを行うことにより、利回りに揺らぎがあるとき、年平均利回り 7% で、毎年 10 万円を 10 年間積立投資をおこなったとき、最初に 100 万円を一括投資したときの比較をしてみよう。なお、SBI 証券のホームページ (図表 8) [11] によると、1999 年から 2022 年の 24 年間で全世界株式・全米株式の平均利回りは、5%~8% であることから、利回り 7% でシミュレーションした。年金の揺らぎは、 $\sigma = 0.1$  の正規分布に従うものとした。図 4 に、一括投資と時間分割投資のシミュレーション結果の例を示す。

つぎに、金利に揺らぎがあるときに、シミュレーションを 1000 回おこない、一括投資および時間分割で積立投資をおこなったとき、10 年後の資産額がどのようなになるかを調べた。図 5 に、資産額の最大値・

最小値・平均値の時系列と 10 年後の資産額分布を示す。

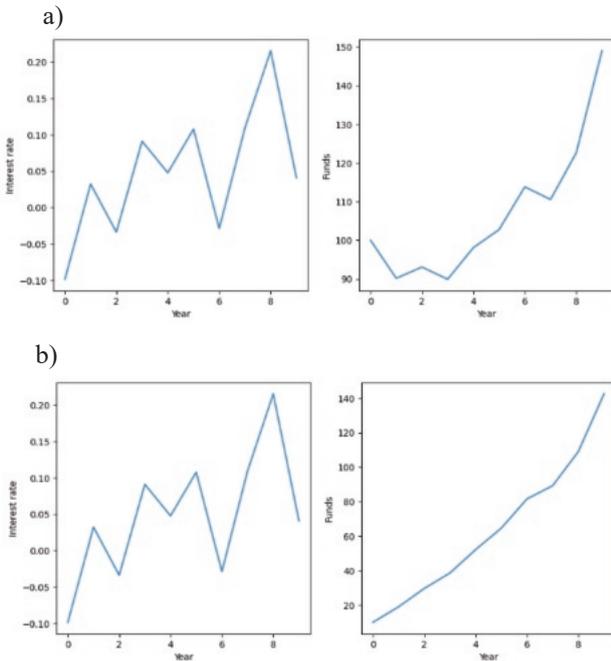


図 4 年利および資産の時系列の例. a) 一括投資, b) 積立投資 (年利 7%,  $\sigma = 0.1$  の正規分散に従う揺らぎ)

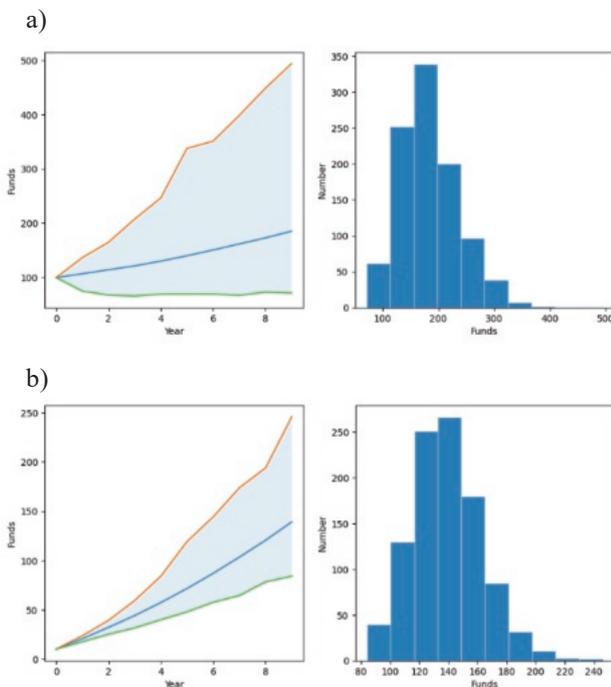


図 5 時系列と 10 年後の資産額分布. 金利に揺らぎがあるときの 1000 回のシミュレーション結果. a) 一括投資, b) 積立投資 (年利 7%,  $\sigma = 0.1$  の正規分散に従う揺らぎ)

年利 7% で 10 年間投資するシミュレーションを 1000 回行ったときの結果をまとめると, 10 年後の平均資産額, 資産額の最小値, 資産額の最大値は, 一括投資の場合: 平均資産額は 185.3 万円, 資産額の最小値は 71.5 万円, 資産額の最大値は 493.4 万円, 積立投資の場合: 平均資産額は 139.2 万円, 資産額の最小値は 84.1 万円, 資産額の最大値は 246.0 万円であった (表 1 を参照). 一括投資の方が 10 年後に期待できる資産額は, 平均値, 最大値とも時間分散投資である積立投資より大きくなるのがわかる. 一方, 最小値は, 一括投資の方が積立投資により小さくなる. 結論として, リスクは大きいが一括投資の方が, 時間分散投資より得られるリターンの期待値は大きいことがわかる.

表 1 投資額 100 万円の 10 年後の資産額\*

10 年後資産額	一括投資	時間分散投資
平均	185.3 万円	139.2 万円
最小	71.5 万円	84.1 万円
最大	493.4 万円	246.0 万円

\*年利 7% で 1000 回シミュレーションした

このように, 経済が過去と同様に右肩上がり成長するならば, 投資にまわせる余裕資金を保有している場合, 早い時期にできるだけ多くの投資を行うことが, 資産を増やすのによい戦略であることがわかる. これは資金を持っているものに有利であること, 「富むものは, より富むようになる」を示唆する.

なお, シミュレーション期間や年利回りなどのパラメータを変えたシミュレーションを行えるように, Python のプログラムの核になる部分のプログラムリストを付録として載せておく (付録 2 参照).

## 5. おわりに

「貯蓄から投資へ」のスローガンの下, 政府は NISA や iDeCo を通して, 投資をおこなった折にかかる税を 0 にするという税の優遇措置をおこなっている. 少子高齢化社会の到来とともに, 公的年金のみでは老後の生活に破綻をきたす可能性が高まってきている. 2019 年に金融庁の金融審議会「市場ワーキング・グループ」が公表した「老後 2000 万円問題」に象徴されるように, 数年前から政府は国民に「公的年金のみでは老後の生活が逼迫する可能性が高いので, 国民は各自自己責任で老後に備えましょう」というメッセージを送ってきている. 政府にとって, 国民に対する金融教育は緊急の重要な課題なのである.

大学においても金融教育の必要性は高まっている。

基礎的な知識は、金融庁ホームページから download できる PDF「基礎から学べる金融ガイド」<sup>[4]</sup>で良いだろう。高校生から一般向けにわかりやすくまとめられている。大学の「金融教育」授業として考えた場合、金融の基礎知識の再確認として、1 から 2 コマで復習させたのち、各自に考えさせる授業をするのが良いかもしれない。工学部の学生の特色を生かし、数学・コンピュータを積極的に利用した授業を行うのはどうだろうか。金融教育と同時に、プログラミングの技能を向上させるという狙いがある。例えば、本論文で示したように Python でプログラムさせる課題を課すことにより、生きたプログラミングを实践させ、学生にとって学習のモチベーションアップにつながるだろう。

ここでは、年金利に揺らぎを導入することで、より現実的な資産の時間変化のシミュレーションを行うことができた。例えば、平均的に年金利 7% で 10 年間運用してさえ、元本割れ（投資した額より資金が減ること）がおこることをデモンストレーションできた。銀行預金であれば、元本は保証されており元本割れはおきない。株式投資には、大きなリターンが期待できるが同時にリスクが伴うのである。リスクとリターンは、株式投資の世界だけではない。Engineering の世界でもリスクとリターンは重要な概念である。例を挙げると、原発事故、自動車事故など絶対に事故がおきないシステムは作れない。株式投資を考えることは、リスクとリターンについてより深く考えるきっかけになるだろう。

今回 Python のプログラミングで金融庁のシミュレーションモデルを改良したが、NISA の活用を家族と議論する状況を想像してみよう。学生が両親に退職金の運用を相談されたとしよう。どのようにアドバイスすれば良いのだろうか？NISA 枠(1800 万円)を 5 年間で使い切ることをアドバイスするか、毎年 180 万円を 10 年間で使うようにアドバイスするか？期待値からは、年初に 360 万円投資するのを 5 年間行うのがもっとも大きなリターンが得られる可能性が高い(過去、30 年間ほどのデータに従って、株式市場が年平均 7% で成長すると仮定すると)。しかし、平均年利 7% で成長するかもしれないが、現実的には年利には揺らぎがある。シミュレーションの結果をみると、一括投資は、得られるリターンの期待値は大きいですが、分散も大きい。10 年間かけて、毎月 15 万円ずつ投資する方が、揺らぎが小さい。

もし、市場が過去と同様に、右肩上がり成長をつづけるなら、できる早く持てる資金を市場に投入することが、もっとも大きなリターンにつながる。そうでないと、機会損失につながる。期待値として

は、正しい戦略である。しかし、現実とは違おう。今回のシミュレーションにおいてみたように、揺らぎがあると単純にはいかない。期待値だけでみると、揺らぎがあっても結論はかわらない。市場経済が右肩上がり成長するなら、「できるだけ早く、全力で投資せよ」である。10 年もすれば、損失は回復する。しかし、一般に人間は数年レベル続く損失に耐えられない。リスク分散を考える必要がある。株式だけでなく、他のアセットにも資金を分散しておこう、となる。知能システム工学の学生なら、人間(年齢、性別(男女によって平均寿命が違う)、保有する資産など)の心理までを考慮した個人の特性に合わせた投資戦略を考えるのも面白いだろう。

最後に、思いつくままに、株式市場と数理モデリングのテーマとして、いくつかの例をあげておく。「ゴルディロックス相場を、不安定平衡点としてモデル化できるか(4 次関数のポテンシャルで近似してみる)? : 株価が上がるか下がるかを 4 次関数ポテンシャルで近似してみる」、「資本収益率 > 経済成長率 : トマ・ピケティ<sup>[12]</sup>をシミュレーションで検証する」、「経済市場は、成長し続ける : 世界が無限に大きければ可能だが、地球は有限である」などである。

さらに、政府の NISA などの戦略に関して、根本的な問題点として国民が投資に回せる資金を準備できるかという問題がある。現在、家庭の経済格差を表す日本のジニ係数は改善されていない<sup>[13]</sup>。投資に回せる資金があるかないかで、ますます格差が広がる可能性がある。「富を持つものはますます富を増大させる」という不都合な現実と直面することになってしまう。政府は、少子高齢化社会の到来にそなえ、NISA などの個人の自助努力に期待するだけでなく、公的なセーフティネットを準備しなければならないだろう。

最後に、大学における金融教育は、今後より重要になってくると思われる。本論文が、現状を理解するための基礎的なデータの提供、および将来ますます期待される工学部における金融教育のヒントになることを願う。

## 謝 辞

本論文を執筆するにあたり、議論および有益なコメントをくださった高田宗樹教授、アンケートに協力してくれた研究室のメンバーに感謝いたします。

## 参考文献

[1] 文部科学省：高校向け金融経済教育指導教材に

ついて

[https://www.mext.go.jp/content/20231017-kyoiku01-100002611\\_1.pdf](https://www.mext.go.jp/content/20231017-kyoiku01-100002611_1.pdf)

- [2] 金融庁 HP 高校向け金融経済教育指導教材の公表について  
<https://www.fsa.go.jp/news/r3/sonota/20220317/20220317.html>
- [3] 金融庁 HP 中学生・高校生のみなさんへ  
<https://www.fsa.go.jp/teach/chuukousei.html>
- [4] 金融庁 HP 「基礎から学べる金融ガイド」  
<https://www.fsa.go.jp/teach/kou4.pdf>
- [5] 内閣府 経済財政運営と改革の基本方針 2023  
[https://www.cao.go.jp/press/new\\_wave/20230626.html](https://www.cao.go.jp/press/new_wave/20230626.html)
- [6] 金融庁 資産運用シミュレーション :  
[https://www.fsa.go.jp/policy/nisa2/moneyplan\\_sim/index.html](https://www.fsa.go.jp/policy/nisa2/moneyplan_sim/index.html)
- [7] 日本銀行ホームページ・統計  
<https://www.boj.or.jp/statistics/>
- [8] 日本銀行ホームページ：統計，その他，日米欧比較（2023年第1四半期）  
<https://www.boj.or.jp/statistics/sj/index.htm>
- [9] 岡三証券ホームページ：  
[https://www.okasan.co.jp/service/navihybrid/okasan\\_column18.html](https://www.okasan.co.jp/service/navihybrid/okasan_column18.html)
- [10] 金融庁 HP 投資を行っている方へ，証券税制が変わります  
<https://www.fsa.go.jp/ordinary/zeisei/index2.html>
- [11] SBI 証券ホームページ：米国株式 v s 全世界株式 2023年を考える  
[https://go.sbisec.co.jp/media/report/fund\\_info\\_plus/fund\\_info\\_plus\\_230124.html](https://go.sbisec.co.jp/media/report/fund_info_plus/fund_info_plus_230124.html)
- [12] トマ・ピケティ著山形浩生，守岡桜，森本正史訳，みすず書房，pp. 728 (2014)
- [13] 厚生労働省 HP：令和3年所得再分配調査の結果  
[https://www.mhlw.go.jp/stf/houdou/96-1\\_r03kekka.html](https://www.mhlw.go.jp/stf/houdou/96-1_r03kekka.html)

## 付録1

アンケートの質問リスト（2023年12月20日（水）実施）

- Q1 学部学生か、大学院生か教えてください
- Q2 高校生の時、金融リテラシーの授業を受けたことがある
- Q3 金融庁を知っていますか
- Q4 「貯蓄から投資へ」という政府のメッセージを聞いたことがありますか
- Q5 NISAを知っていますか
- Q6 NISAをつかった積み立て投資には、元本保証がある
- Q7 2024年から新NISAを使って投資するのに興味がある
- Q8 年利10%で100万円を預けると、10年後には250万円以上になる
- Q9 ドルコスト平均法について、知っている
- Q10 ドルコスト平均法で積み立て投資すると、かならず投資したより多くのリターンが得られる
- Q11 銀行にお金を預けると、元本割れをおこすことはない
- Q12 銀行に500万円を貯金していたが、銀行が破産すると、500万円は戻ってこない
- Q13 2000万円を銀行に預けていたが、銀行が破産しても、政府が保証してくれるので安心だ

Google Classroom のアンケート画面

The screenshot shows a Google Classroom interface for a survey titled "金融リテラシーについて" (About Financial Literacy). The survey is currently in the "質問" (Questions) phase, with 16 responses. The survey content is as follows:

**金融リテラシーについて**

アンケートに協力、お願いします。  
アンケート結果は、学術研究にのみ使用します。  
また、個人情報に関しては、個人が特定されないように回答者の情報は収集していません。  
よろしくお願いします。

**学部学生か、大学院生か教えてください**

- 学部学生
- 大学院生

**高校生の時、金融リテラシーの授業を受けたことがある**

- はい
- いいえ

## 付録2

Python program リスト

```

import numpy as np
from matplotlib import pyplot as plt

np.random.seed(20240101) # 乱数の種を設定
interest_rate = 0.07 # 利率 (年利)
sigma = 0.1 # 分散
ganpon = 100 # 元本
tumitate = 0 # 積立金額
number_of_year = 10 # 投資年数
number_of_ransuu = 10 # シミュレーション回数

# 階数が number_of_ransuu の配列を作る
tmp = np.zeros((number_of_ransuu, number_of_year))
# numpy 配列を Python の配列に変換
deposit = tmp.tolist()

# 元本の設定
for i in range(number_of_ransuu):
    deposit[i][0] = ganpon + tumitate

# number_of_year 個の正規乱数系列を number_of_ransuu 組作る
risoku = sigma*np.random.randn(number_of_ransuu,number_of_year) + interest_rate

# 0~number_of_year の設定
years = [x for x in range(number_of_year)]

# 資産の年毎の成長の計算
def saving():
    for j in range(number_of_ransuu):
        for i in range(number_of_year - 1):
            deposit[j][i + 1] = tumitate + deposit[j][i] + risoku[j][i] * deposit[j][i]

    return

saving()

fig, axs = plt.subplots(1, 2, figsize=(11, 5))
for i in range(number_of_ransuu):
    axs[0].plot(years, risoku[i])
for i in range(number_of_ransuu):
    axs[1].plot(years, deposit[i])

plt.show()

```

# 決定木実現方法の違いによるスウィング動作の 個人認証性能の違い

河村 隼輝\* 中島 基晴\*\* 黒岩 丈介\*\* 小高 知宏\*\* 諏訪 いずみ\*\*\* 白井 治彦\*\*\*\*

## Differences in Individual Authentication Performance of Swinging Movements Based on Decision Tree Methods

Shunki KAWAMURA\*, Motoharu NAKAJIMA\*\*, Jousuke KUROIWA\*\*, Tomohiro ODAKA\*\*  
Izumi SUWA\*\*\* and Haruhiko SHIRAI\*\*\*\*

(Received January 31, 2024)

In this paper, we evaluate personal authentication performance of swinging movements of a Smartphone by using Random Forests and Extremely Randomized Trees based on Decision Trees. Furthermore, we studied whether duration of days of acquired training data would influence the authentication accuracy. In the case of large variance of the data, Extremely Randomized Trees gives better performance, on the other hand, in the case that variance converges into small value as the duration of days becomes large, Random Forests is better.

**Key words** :Random Forest, Personal Identifier, Deep Learning, Smartphone

### 1. はじめに

現在、スマートフォンは至る所で使用されており、多くの人が所持するものとなっている。総務省によると、2022年における個人のスマートフォンの所有割合は77.3%となっている<sup>[1]</sup>。この割合は増加傾向にあり、デジタル化社会への移行やリモートワークの推進などにより我々の生活に欠かせないものとなっている。スマートフォンは多くの情報を保持しており、その中には個人情報など重要な情報も含まれている。そのため、認証システムの利用などによって、情報漏えいを防ぐ必要がある。スマートフォンに搭載さ

れている個人認証システムは、知識認証と身体認証の2種類に分類することができる。知識認証では本人のみが知り得る情報、身体認証では個人の身体的特徴をそれぞれ用いて個人認証を行う。知識認証ではパスワード認証、PIN認証、パターンロック認証の3種類、身体認証では指紋認証、顔認証の2種類、計5種類の認証手法がスマートフォンの認証システムとして用いられている。しかし、この5つの認証システムにはそれぞれ欠点があり、他人に突破されてしまう可能性があるため、新たな認証システムの導入が必要である。新たな個人認証システムの可能性として、人間の行動や動作を利用した行動認証という認証手法がある。無意識的な行動や動作には身体情報と同様に個人特性が存在しており、他人による模倣が非常に困難である<sup>[2]</sup>。行動認証では、このような個人特性を検出して個人認証に用いている。

一方、認証システムにおけるシステム開発では、そのシステムがユーザにとって使いやすいものであるかを考慮する必要がある。例えば、指紋認証や顔認証は身体情報の入力完了までの所要時間が短く、入力後は指紋や顔を照合するだけで個人認証を行う

\*大学院工学研究科 知識社会基礎工学専攻

\*\*Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

\*\*\*知能システム工学講座

\*\*\*\*Department of Human and Artificial Intelligent Systems

\*\*\*\*\*仁愛女子短期大学 生活科学学科

\*\*\*\*\*Jin-ai Women's College

\*\*\*\*\*工学部 技術部

\*\*\*\*\*Technical Division

ことが可能である。これは利用者にとって使いやすく、他の個人認証手法よりも利便性が高いシステムであると言える。行動認証の場合、より単純な動作から認証が可能であれば高い利便性を獲得することができる。本研究では、スマートフォンを持った状態で腕を振るというスウィング動作が単純な動作の1つであると考え取り入れた。スウィング動作から、スマートフォンの基本操作を行うことができるものの例として、NTT docomo がサービスを提供していたスグアプリやスグ電を挙げる<sup>[3]</sup>。このサービスでは、スマートフォンを振るなどの直感操作で、アプリを起動させたり、タッチ操作をすることなく電話の発信や応答などの基本操作を行うことができる。スグアプリでは、ホーム画面やアプリ使用時などのスマートフォンが起動した状態でのみ特定のアプリを起動することができる。これは、振り方に指定が無く、第三者による不正利用を防止するためであると考えられる。スマートフォンを振ることで個人認証が行われ、アプリの立ち上げのみならずロックの解除もできることが理想的である。そのため、スウィング動作に何らかの個人特性が存在することを調べる必要がある。自然なスウィング動作には無意識的な特徴が潜在しており、個人認証が可能であると考えられる。本研究では、ランダムフォレストとその派生モデルであるエクストラツリーを用いた個人認証実験を行った。各モデルに対して適切なスウィングデータの条件やモデルの特性を明らかにすることを目的とする。

## 2. ランダムフォレスト

ランダムフォレストとは、弱学習器（決定木）を並列に複数作成し、各決定木の出力結果における平均または多数決を算出して予測を行うモデルである<sup>[4]</sup>。図1に概略図を示す。前の決定木の情報を利用するブースティングなどの直列的なアルゴリズムに対し

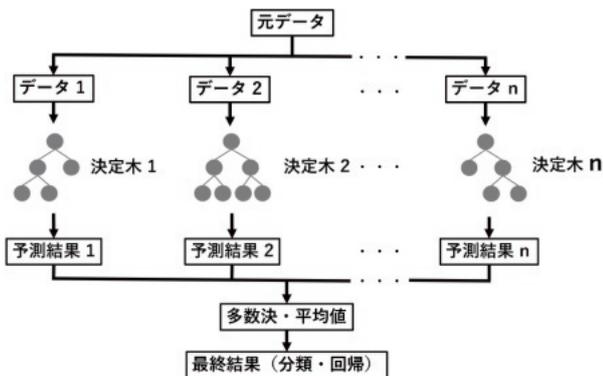


図1 ランダムフォレストの概略図

て同時に複数の木を作成することができるため、計算コストが低いアルゴリズムとなっている。このように、複数の学習器を融合させて1つの学習モデルとして学習する手法をアンサンブル学習と呼ばれる。

### • 分岐の基準

ランダムフォレストで用いる決定木では、不純度という指標に基づいて分岐を行う。ここでは、交差エントロピー誤差、ジニ不純度の2つを挙げる。決定木のあるノード  $t$  に対してノード内のサンプルが  $N(t)$  個、ノード内のクラスが  $c$  個の場合について考える。ノード  $t$  内でクラス  $i$  に属しているサンプル数を  $n_i$  とすると、クラス  $i$  に属するサンプルの割合は式 (1) のようになる。

$$p(i|t) = \frac{n_i}{n} \quad (1)$$

このとき、各不純度指数はそれぞれ式 (2), (3) のように定義される。

$$I_H(t) = - \sum_{i=1}^c p(i|t) \log_2 p(i|t) \quad (2)$$

$$I_G(t) = 1 - \sum_{i=1}^c p(i|t)^2 \quad (3)$$

### • 分岐の基準

交差エントロピー誤差は、分岐前の  $I_H(t)$  と分岐後の  $\sum_{i=1}^c I_{H_i}(t)$  の差（ゲイン）を基準化したゲイン比 (*Gain/Split Info*) が最大となるものを分岐の変数として選択する。ゲイン比は式 (4) のようになる。

$$Gain = I_H(t) - \sum_{i=1}^D \frac{N(t_i)}{N(t)} I_H(t_i) \quad (4)$$

$$Split\ Info = - \sum_{i=1}^D \frac{N(t_i)}{N(t)} \log_2 \left( \frac{N(t_i)}{N(t)} \right)$$

また、ジニ不純度では  $s$  という分岐を行った際、分岐前の  $I_G(t)$  と分岐後の複数の  $I_G(t_i)$  の差  $\Delta I_G(s, t)$  が最大となるような分岐  $s$  を選択する。ノードの分岐前後におけるジニ不純度の差は式 (5) のようになる。

$$\Delta I_G(s, t) = I_G(t) - \sum_{i=1}^D \frac{N(t_i)}{N(t)} I_G(t_i) \quad (5)$$

ランダムフォレストでは、分岐前後の差が最大となる不純度を選択し、分岐を作成する。

1つの決定木を作る際は重複を認めて訓練データからランダムに指定された個数のデータをサンプリング

して決定木を作成する．このようにデータセットを用意する方法をブートストラップといい，ブートストラップを用いて複数の弱い学習器（決定木）を組み合わせる方法はブートストラップアグリゲーション（bootstrap aggregation），またはバギングと呼ばれる．バギングを用いることで各決定木を作成する際のデータが異なるため，決定木間の相関が低くなる．また，ブートストラップでデータセットを作成する際，重複が許されているため元のデータセットから決定木を作成する際に選ばれないデータ（Out of bagging）が現れる可能性がある．選択されなかったデータセットは，検証データとして用いることでモデルの評価を行うことが可能である．回帰やカテゴリ分類のためのランダムフォレストのアルゴリズムを図2に与える． $B$  個の確率変数における平均の分散は，それぞれの分散が  $\sigma^2$  の独立分布に従う場合  $\frac{1}{B}\sigma^2$  となる．各確率変数は同一の分布に従っているが，独立ではなく正の相関  $\rho$  を持つ場合，平均の分散は式（6）のようになる．

$$\rho\sigma^2 + \frac{1-\rho}{B}\sigma^2 \quad (6)$$

$B$  は決定木の数で  $\rho$  は相関係数を表す． $\rho$  に関して微分を行うと正になることから，相関係数が増加すると全体の分散が大きくなるのが分かる．また決定木を増やす，すなわち，バギングを行うことで第2項が減少し，平均からの分散が小さくなる．

## 2.1 エクストラツリー

エクストラツリー（Extremely randomized trees）<sup>[5]</sup> は，ランダムフォレストと同様に弱学習器（決定木）を並列に複数作成し，各決定木の出力結果における平均または多数決を算出して回帰や分類を行うモデルである．ランダムフォレストと異なる部分は主に2つある．

1つ目は，入力データの選択である．ランダムフォレストでは，ブートストラップによって訓練データの

一部または全てを用いて入力する．一方，エクストラツリーでは，ブートストラップを行わずに全てのデータを入力する場合がある．

2つ目は，ノードを分割する際における不純度の選択方法である．ランダムフォレストでは，ノードの分岐前後で不純度の差がより大きくなるものを選択する．一方，エクストラツリーでは，ランダムに不純度を選択する．

エクストラツリーは，よりランダム性が高いモデルと言えるが，必ずしも精度が向上するとは限らない．しかし，ブートストラップを行わなくてもよく，ノードの分割を評価する部分を省略できるため，高速なモデル構築が可能となる．

## 3. スウィングデータの計測実験

### 3.1 スウィングデータの取得

本実験では，スマートフォンに搭載されたセンサから加速度及び角速度データを特徴データとして取得した．計測実験の条件として，腕を振る動作について登録する真のユーザ3人（A, B, C）と，そのユーザに扮した偽のユーザ8人（I<sub>1</sub>~I<sub>8</sub>）から動作時の3軸加速度（ $\alpha_x, \alpha_y, \alpha_z$ ）及び3軸角速度（ $\omega_x, \omega_y, \omega_z$ ）の計測データを収集した．各ユーザに対して，腕を上下に3回振る動作を起立と着席した状態でそれぞれ5回ずつ行っており，平日5日×3週間の15日間継続した．真のユーザに対して，無意識的なスウィング動作に潜在する個人特性を探るため，腕を振る方向や速さ，大きさは指定していない．ただし，個人特性が変化することを防ぐため，1度振り方を決定して以降は振り方を統一した．また，各週の初日に動作の様子を撮影しており，偽のユーザは，真のユーザのうち何れか1人の振り方に対して動画を視聴しながら動作を模倣した．

### 3.2 スウィングデータのノイズ除去

取得したデータの中には，ノイズが含まれているものがある．本研究では，特徴データから特徴となる点（特徴点）を検出し，それらを特徴量とした．その際，ノイズが含まれていると特徴点がうまく検出されない場合がある．そこで，移動平均法というデータ分析手法を用いた．移動平均法とは，連続するデータの集合において特異点やノイズをなくすためにある点のデータをその近傍の点のデータを用いて平均化処理を行い，滑らかにつながるデータの集合（曲線）になるようにする手法である．移動平均法には，単純移動平均法（SMA），加重移動平均法（WMA），指数移

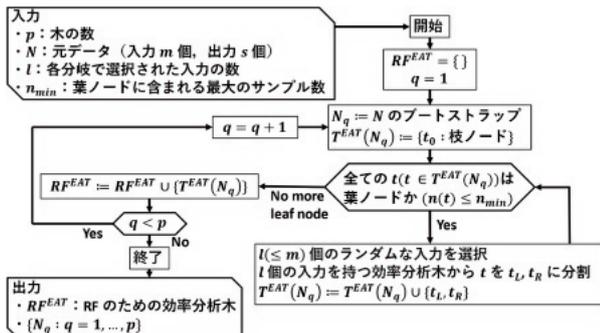


図2 ランダムフォレストのアルゴリズム

動平均法 (EMA) の 3 種類が主に挙げられる。

- 単純移動平均法

単純移動平均法とは、あるデータの中で設定した範囲内の値における平均値を求める手法である。本研究では、特徴データの  $k$  ステップ目から始端方向に向けて  $t$  個の平均区間をとり、平均りを求める。その平均値を単純移動平均処理による  $k-t$  ステップ目の出力とする。例えば、データ長を  $l_N$  とすると、 $t$  ステップ目から  $l_N$  ステップ目まで平均区間を 1 ステップずつずらしながら移動平均処理を  $(l_N - t + 1)$  回行う。単純移動平均法は式 (7) で定義される。

$$S(k-t) = \frac{1}{t} \sum_{i=0}^{t-1} a(k-t+i) \quad (7)$$

本研究では、始端のインデックス番号を 0 とする。また、移動平均前の計測値を  $N(k)$ 、出力された平均値を  $S(k-t)$  とし、 $t \leq k \leq l_N$  とする。

- 加重移動平均法

加重移動平均法とは、単純移動平均法の処理に加えて、直近のデータの値に比重をおいた手法である。平均区間を  $t$  とすると、 $k$  ステップ目の計測値の重みは  $t$  となる。重みは  $k$  ステップ目から離れるほど減少するため、最も離れた計測値の重みは 1 となる。加重移動平均法は式 (8) で定義される。

$$W(k-t) = \frac{\sum_{i=0}^{t-1} (i+1) \times a(k-t+i)}{\sum_{i=1}^{t-1} (i+1)} \quad (8)$$

ここで、データに対して出力された平均値を  $W(k-t)$ 、 $t \leq k \leq l_N$  とする。重みの変化率

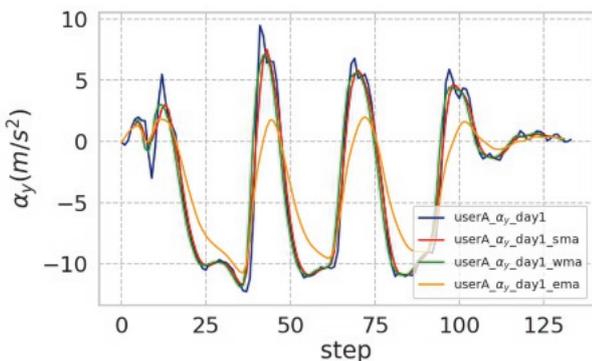


図 3 移動平均処理前後の  $y$  軸方向加速度 (ユーザ A)

は 1 であり、重みを掛けた計測値の合計で割ることにより  $W(k-t)$  が求まる。

- 指数平滑移動平均法

指数平滑移動平均法とは、加重移動平均法と同様に直近のデータに重みを加えた手法である。この手法では、過去のデータの影響を指数関数的に減少させるため、平滑化定数  $\alpha$  ( $0 < \alpha < 1$ ) を重みとして用いる。指数平滑移動平均法は式 (11) で定義される。

$$\alpha = \frac{2}{t+1} \quad (9)$$

$$E(0) = a(0) \quad (10)$$

$$E(k-t+1) = \alpha a(k) + (1-\alpha)E(k-t) \quad (11)$$

指数平滑移動平均処理による出力の初期値  $E(0)$  は、式 (7) から求めた単純移動平均処理の初期値 ( $S(0)$ ) とする。平滑化定数  $\alpha$  を平均区間  $t$  によって決定する。初期値を除いた出力値  $E(k-t+1)$  を移動平均処理前の計測値  $N(K)$  を  $\alpha$  倍した値と直前の出力結果  $E(k-t)$  を  $(1-t)$  倍した値の和として求める。なお、指数平滑移動平均法では  $t \leq k \leq l_N - 1$  とする。

以上の 3 つの計算手法の中から、最も適切な手法を決定する。ユーザ A の  $y$  軸加速度  $\alpha_y$  に対して各手法の移動平均処理を行った加速度データを例に挙げる。図 3 は、1 日目における座った状態での 1 回目のスウィング動作に対するユーザ A についての  $\alpha_y$  の推移である。各線の色について、青色が移動平均処理前の加速度データ、赤色が単純移動平均処理 (sma)、緑色が加重移動平均処理 (wma)、橙色が指数平滑移動平均処理 (ema) を行った加速度データである。各手法について、平均に用いるデータの範囲を  $n = 5$ 、平滑化定数を決定するための値を  $M = 5$  とした。図 3 より、指数平滑移動平均処理後の加速度データは、他の手法よりも処理前の波形が比較的大きく異なっていることが分かる。よって、この時点で指数平滑移動平均法は使用しないことを決定した。単純移動平均法と加重移動平均法のどちらかを採用する上で、移動平均の処理前のデータと処理後のデータに対して平均二乗誤差を算出し、最も誤差が小さい手法を採用する。平均二乗誤差の算出結果を表 1 に示す。表 1 より、単純移動平均処理の方が誤差が小さい。この結果は、他のユーザのデータに対しても同様である。よって、本研究では単純移動平均法を用いてノイズ除去を行った。

表 1 各移動平均手法における平均二乗誤差

手法	平均二乗誤差
単純移動平均法	1.03
加重移動平均法	2.00

### 3.3 特徴点抽出手法

単純移動平均法を用いて特徴データのノイズを除去した後、特徴点を検出して特徴量を取得した。ここで、図 4 にユーザ A について、3 軸加速度データの特徴点と特徴量を示す。赤、緑、青色の波形はそれぞれ、 $x, y, z$  軸の加速度データである。本研究では、図 4 のように、各特徴データの極小点及び極大点を特徴点とした。しかし、短時間の間に複数の極値が現れる場合がある。そこで、次の手順から特徴点を抽出を行った。初めに、各軸方向の加速度及び角速度の推移を平滑化した後、大域的 maximum と大域的 minimum を 1 つずつ取得し、絶対値が大きい方を選択する。次に、選択された極値から 30% 以下の値を取り除き、極値が 3 つ残るようにする。最後に、残った 3 つの極値に対してそれぞれ直近の極値を選択することで、合計 6 つの極値が獲得できるためこれらの特徴点として取得した。本研究では、3 軸方向の加速度及び角速度を計測しており、式 (12) のように加速度ベクトル及び角速度ベクトルを作成した。

$$\alpha_x = \{x_{min1}, x_{min2}, x_{min3}, x_{max1}, x_{max2}, x_{max3}\} \quad (12)$$

また、各ベクトルを式 (13) のようにまとめた特徴ベクトルを作成した。

$$F = \{\alpha_x, \alpha_y, \alpha_z, \omega_x, \omega_y, \omega_z\} \quad (13)$$

11 人のユーザに対して立った状態と座った状態での計測を 5 回ずつ行っており、計測期間を 15 日として

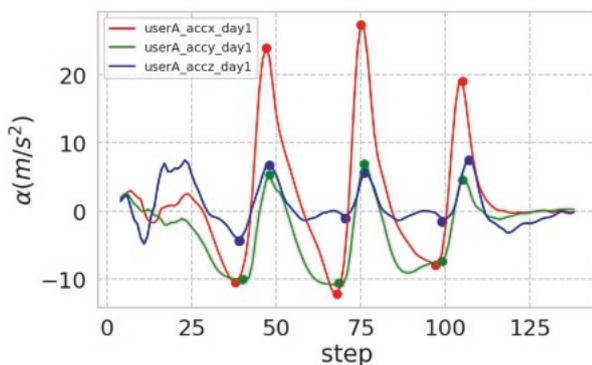


図 4 3 軸加速度データにおける特徴点抽出 (ユーザ A)

いるため、1650 個の特徴ベクトルを作成した。

## 4. モデルの性能評価実験

### 4.1 実験方法

計測実験では、11 人の右利きの被験者を対象に、3 人を真のユーザ、残り 8 人を偽のユーザとした。立った状態と椅子に座った状態で腕を上下に 3 回振る動作をそれぞれ 5 回ずつ行い、特徴データを取得した。また、1 日の特徴データを順に配列した特徴ベクトルを生成した。特徴ベクトルは、1 ユーザにつき 10 個  $\times$  15 日間の計 150 個である。得られた特徴ベクトルを学習データとテストデータに分類し、ランダムフォレストを用いて個人認証を行った。

### 4.2 特徴量データの分類

取得した特徴ベクトルを用いて個人認証実験を行う際、1 週目の 5 日間を学習データ、2, 3 週目をテストデータに分類した。さらに、学習データのうち、訓練データと検証データをそれぞれ半分ずつに分類した。また、データの日数は 1 ~ 5 日間で 1 日ずつ増やしていき認証精度がどのように変化するかを調べた。テストデータは、時間経過による認証精度の変化を調べるため、2 週目のみをテストデータとした場合と 3 週目のみをテストデータとした場合で認証実験を行った。

### 4.3 評価指標

生体認証によく用いられる本人拒否率 FRR (False Rejection Rate) と他人受け入れ率 FAR (False Acceptance Rate) を評価指標として採用した。FRR 及び FAR は式 (14), (15) のように定義される。

$$FRR = \frac{\text{本人拒否回数}}{\text{試行回数}} (\%) \quad (14)$$

$$FAR = \frac{\text{他人受け入れ回数}}{\text{試行回数}} (\%) \quad (15)$$

### 4.4 評価実験結果

ランダムフォレスト及びエクストラツリーによる真のユーザの認証精度をそれぞれ表 2, 3 に示す。スマートフォンの個人認証において重要なことは、他人の認証を受け入れないことである。よって、FAR の結果が重視される。一方、本人の認証はある程度の失敗を許容するものとして FAR の結果よりも重要度は低くなる。このことを踏まえた上で、結果について述べる。ユーザ A に関して、訓練データを 5 日まで増やしたことで、ランダムフォレスト及びエクスト

表2 ランダムフォレストによる  $n$  日分の訓練データにおける評価値 (%) (FRR, FAR)

$n$	ユーザ A		ユーザ B		ユーザ C	
	2 週目	3 週目	2 週目	3 週目	2 週目	3 週目
1	(74.0, 0.3)	(92.0, 0.0)	(40.0, 0.0)	(78.0, 0.0)	(0.0, 9.3)	(4.0, 9.5)
2	(60.0, 1.5)	(70.0, 0.8)	(20.0, 0.0)	(46.0, 0.0)	(28.0, 2.8)	(40.0, 2.3)
3	(10.0, 0.0)	(6.0, 0.3)	(20.0, 0.0)	(40.0, 0.0)	(62.0, 1.0)	(60.0, 0.5)
4	(12.0, 0.0)	(8.0, 0.0)	(20.0, 0.0)	(40.0, 0.0)	(6.0, 0.8)	(10.0, 0.8)
5	(10.0, 0.0)	(12.0, 0.0)	(12.0, 0.0)	(28.0, 0.0)	(38.0, 0.0)	(48.0, 0.3)

表3 エクストラツリーによる  $n$  日分の訓練データにおける評価値 (%) (FRR, FAR)

$n$	ユーザ A		ユーザ B		ユーザ C	
	2 週目	3 週目	2 週目	3 週目	2 週目	3 週目
1	(16.0, 0.0)	(18.0, 0.3)	(56.0, 0.0)	(80.0, 0.0)	(0.0, 12.5)	(0.0, 12.5)
2	(30.0, 1.3)	(46.0, 0.8)	(22.0, 0.0)	(36.0, 0.0)	(30.0, 1.5)	(16.0, 3.0)
3	(8.0, 0.0)	(8.0, 0.0)	(28.0, 0.0)	(52.0, 0.0)	(22.0, 3.5)	(26.0, 4.3)
4	(10.0, 0.0)	(24.0, 0.0)	(28.0, 0.0)	(52.0, 0.0)	(0.0, 1.3)	(0.0, 1.8)
5	(12.0, 0.0)	(10.0, 0.3)	(26.0, 0.0)	(42.0, 0.0)	(18.0, 5.3)	(18.0, 6.0)

ラツリーともに、FRR を 10 % 程度に抑えることができています。どちらのモデルを用いた場合でも同様の認証精度の変動をしており、3 日目を加えた際に認証精度が向上していることが分かる。ユーザ B に関して、2 週目から 3 週目に変更した場合に、本人拒否率の差が他のユーザよりも比較的大きくなっている。モデル別で見ると、ランダムフォレストを用いた場合で、より高精度の認証ができていていることが分かる。ユーザ C に関して、どちらも 4 日目の訓練データを加えた際に認証精度が向上していることが分かる。モデル別で見ると、エクストラツリーを用いた場合で、より高精度の認証ができていていることが分かる。また、真のユーザ全体に対して、テストデータを 2 週目とし、 $n = 5$  のとき本人拒否率を 40 % 以内に抑えることができています。訓練データを増加させることで認証精度が向上する傾向にあると言える。テストデータを 2 週目から 3 週目に変更した場合でも、認証精度に大きな差は無いと言える。

## 5. 考察

表 2, 3 における認証結果の要因を探るため、真のユーザに対し、各特微量について図 5 のような箱ひげ図を作成した。図 5 では横軸が訓練データに用いた日数、縦軸がユーザ A における  $x$  軸加速度の箱ひげ図であり、極大値を赤及び極小値をマゼンタで示している。図 5 では、ひげの長さを四分位範囲 (IQR) の 1.5 倍を上下限としている。このとき、「第一四分位数  $-1.5 \times IQR$ 」がひげの下限、「第三四分位

数  $+1.5 \times IQR$ 」がひげの上限となり、ひげの下端より小さい値やひげの上端より大きい値を「外れ値」として扱う。箱ひげ図における外れ値の個数と日ごとの標準偏差を求め、表 4, 5, 6 に示した。また、標準偏差  $s$  は与えられたデータセット  $X = \{x_1, x_2, \dots, x_n\}$  に対して平均が  $\bar{x}$  であるとき、式 (16) のように求まる。

$$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (16)$$

ユーザ A に関して、3 日目における外れ値の個数が合計 5 個と他の週よりも少なくなっており、標準偏差も 2 日目とあまり変化が見られないことから、認証精度の向上につながったと考える。4, 5 日目では外れ値の個数が増加していることから、認証精度の悪化につながったと考える。ユーザ B に関して、標

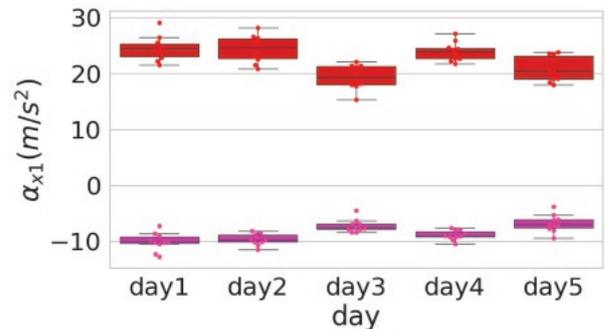
図 5 日ごとの  $x$  軸加速度の箱ひげ図 (ユーザ A)

表 4  $n$  日分の訓練データにおける特徴点のばらつき (ユーザ A) (外れ値 (個), 標準偏差)

n (極小) (極大)	$\alpha_x$	$\alpha_y$	$\alpha_z$	$\omega_x$	$\omega_y$	$\omega_z$
1	(2, 1.13) (0, 2.4)	(0, 0.97) (0, 1.35)	(0, 0.97) (0, 2.28)	(1, 0.52) (0, 0.94)	(0, 0.74) (0, 1.32)	(0, 0.69) (0, 0.75)
2	(0, 1.2) (0, 2.57)	(0, 0.93) (1, 1.4)	(1, 0.74) (1, 1.55)	(0, 0.43) (1, 0.61)	(1, 0.8) (0, 1.07)	(0, 0.69) (0, 0.78)
3	(0, 0.9) (0, 2.08)	(0, 0.8) (1, 1.29)	(0, 0.58) (1, 1.46)	(1, 0.51) (1, 0.66)	(0, 0.55) (0, 0.91)	(1, 0.53) (0, 0.79)
4	(0, 1.15) (0, 2.19)	(0, 1.01) (0, 1.72)	(0, 0.67) (0, 1.71)	(0, 0.51) (0, 0.65)	(1, 0.55) (1, 0.81)	(0, 0.93) (1, 1.36)
5	(1, 1.06) (0, 1.52)	(1, 1.08) (0, 1.08)	(0, 0.72) (1, 1.67)	(1, 0.39) (0, 0.82)	(1, 0.5) (1, 0.63)	(1, 0.68) (0, 0.71)

表 5  $n$  日分の訓練データにおける特徴点のばらつき (ユーザ B) (外れ値 (個), 標準偏差)

n (極小) (極大)	$\alpha_x$	$\alpha_y$	$\alpha_z$	$\omega_x$	$\omega_y$	$\omega_z$
1	(0, 1.38) (0, 3.77)	(0, 4.42) (2, 1.98)	(1, 1.94) (0, 4.15)	(1, 1.32) (1, 0.72)	(1, 0.85) (0, 0.88)	(0, 0.81) (0, 1.01)
2	(1, 1.18) (2, 2.4)	(1, 2.5) (1, 1.6)	(1, 1.01) (1, 3.29)	(0, 1.02) (0, 0.48)	(0, 0.53) (1, 0.8)	(0, 0.71) (0, 0.68)
3	(1, 1.41) (0, 2.99)	(1, 3.88) (0, 1.73)	(0, 1.08) (1, 2.58)	(1, 0.65) (0, 0.74)	(1, 0.57) (1, 0.9)	(0, 0.79) (1, 0.89)
4	(0, 1.99) (1, 3.75)	(0, 3.73) (1, 1.64)	(1, 1.69) (0, 4.45)	(0, 1.15) (1, 0.6)	(0, 0.44) (0, 0.9)	(0, 0.66) (1, 1.04)
5	(0, 1.74) (0, 2.54)	(0, 4.16) (0, 1.96)	(1, 2.28) (1, 3.92)	(1, 0.95) (1, 0.8)	(1, 0.59) (0, 1.03)	(0, 0.73) (0, 1.22)

標準偏差の値がどの特徴量においても減少傾向にあることから、認証精度の向上につながったと考える。また、3日目の標準偏差が増加しているものが多く、エクストラツリーでの認証精度の悪化につながったと考える。ユーザ C に関して、全体的に標準偏差の増減が一定でないことが分かる。エクストラツリーでは、ランダムフォレストよりもランダム性が高いモデルとなっていることから、このような標準偏差の変化にも対応できたと考えられる。また、4日目の標準偏差は以前の週よりも標準偏差の変化が抑えられていることから、認証精度が向上したのではないかと考える。

また、表 2, 3 に関して、訓練データを増加させたことで、データの偏りが軽減され、モデルがユーザごとの特徴を学習しやすくなった。これにより、未知データに対するモデルの性能が向上し、認証精度が向上した要因の 1 つであると考えられる。また、テストデータを 2 週目から 3 週目に変更した際に認証精度に大きな差は見られなかった。以上のことから、ス

マートフォンにおける自然なスウィング動作には個人特性が存在していると考えられる。本研究では、図 4 のように抽出した各特徴点について、特徴量の大きさに該当する  $y$  座標のみの値を入力しているため、ステップ数に該当する  $x$  座標の情報も取り入れることで、更なる精度の向上が見込まれる。

## 6. おわりに

本論文では、ランダムフォレスト及びエクストラツリーを用いて、スマートフォンのスウィング動作における個人認証実験を行った。真のユーザ 3 人に対して認証実験を行い、認証結果における精度の変動と特徴点のばらつきとの関係性を調べた。訓練データを増やすごとに特徴点の標準偏差が小さくなっている場合、ランダムフォレストでの認証精度が高くなっていた。また、訓練データを増やしても特徴点の標準偏差における増減が不定である場合、エクストラツリーでの認証精度が高くなっていた。これは、2つのモデルにおける違いの 1 つである決定木における不

表 6  $n$  日分の訓練データにおける特徴点のばらつき (ユーザ C) (外れ値 (個), 標準偏差)

n (極小) (極大)	$\alpha_x$	$\alpha_y$	$\alpha_z$	$\omega_x$	$\omega_y$	$\omega_z$
1	(0, 1.41) (0, 2.02)	(0, 2.1) (1, 1.44)	(1, 2.52) (0, 2.93)	(1, 0.6) (0, 0.67)	(1, 0.58) (0, 0.34)	(1, 0.42) (0, 0.61)
2	(0, 0.7) (1, 1.43)	(0, 1.39) (1, 0.78)	(1, 1.56) (0, 2.8)	(0, 0.38) (0, 0.48)	(1, 0.64) (1, 0.46)	(1, 0.29) (1, 0.43)
3	(0, 1.11) (1, 1.4)	(1, 1.1) (0, 1.27)	(2, 1.35) (0, 2.9)	(1, 0.38) (1, 0.34)	(0, 0.42) (0, 0.43)	(0, 0.42) (0, 0.49)
4	(0, 1.82) (3, 3.13)	(1, 2.04) (1, 1.09)	(0, 2.58) (0, 2.6)	(0, 0.52) (1, 0.48)	(1, 0.57) (1, 0.44)	(0, 0.49) (1, 0.77)
5	(1, 1.69) (0, 2.38)	(1, 1.35) (0, 1.13)	(0, 1.61) (0, 2.24)	(1, 0.52) (0, 0.47)	(0, 0.65) (0, 0.55)	(0, 0.48) (0, 0.58)

純度の選択方法によるものと考えている。訓練データを日ごとに見た際にも特徴点のばらつきが大きいデータを加えると認証精度が低下し、ばらつきが小さいデータを加えると認証精度が向上する傾向にあることが分かった。よって、特徴点のばらつきが小さくなる場合、最良な不純度が選択できるランダムフォレストでの認証が適している。また、特徴点のばらつきの増減が不定または大きくなる場合、不純度をランダムに選択するエクストラツリーでの認証が適している。以上のことから、データのばらつき具合から適したモデルを推測することが可能であると言える。

今後の課題としては、計測日数、人数や条件を増やすことでランダムフォレスト及びエクストラツリーの特性についてより深く探求を行っていくことである。また、今回外れ値として扱った値を除外した場合での個人認証実験を行うことで、特徴点のばらつきとは異なる観点からモデルの特性を見出していく。

#### 参考文献

- [1] 総務省. 通信利用動向調査. 令和 4 年調査 (令和 05.05.29 公表)  
[https://www.soumu.go.jp/johotsusintokei/statistics/data/230529\\_1.pdf](https://www.soumu.go.jp/johotsusintokei/statistics/data/230529_1.pdf). (2023/12/3 参照)
- [2] 井芹隼人, 岡本栄司, et al. タッチパネルを用いた行動的特徴に基づくバイオメトリクスに関する一考察, コンピュータセキュリティシンポジウム 2011 論文集, 2011 (3): pp84-88, 2011
- [3] スグアプ・スグ電  
<https://www.docomo.ne.jp/service/suguapp/?d=2&p=3,6>. (2023/12/3 参照)

- [4] Yanli Liu, Yourong Wang and Jian Zhang. New Machine Learning Algorithm: Random Forest, Proc. of ICICA 2012, pp.246–252, 2012.
- [5] Geurts, Pierre, Damien Ernst and Louis Wehenkel. “Extremely randomized trees.” Machine Learning 63 pp3-42, 2006.

# コンテナ型仮想化による機械学習支援を目的とした 計算機環境の実現

織田康太郎\* 小高知宏\*\* 黒岩丈介\*\* 諏訪いずみ\*\*\* 白井治彦\*\*\*\*

## Realization of Containerized Virtualization of Computing Environments to Support Machine Learning

Kotaro ODA\*, Tomohiro ODAKA\*\*, Jousuke KUROIWA\*\*  
Izumi SUWA\*\*\*, Haruhiko SHIRAI\*\*\*\*

(Received January 26, 2024)

Using container virtualization, we have developed a system that provides a computing environment capable of running machine learning to a larger number of users. Conventional GPU servers do not provide sufficient separation of the computing environment between users, and when a GPU server is shared by multiple users, many things need to be taken care of. This system provides a computing environment as a container, making it difficult for users to be affected by the operations of other users, and enabling the stable provision of computing resources such as GPUs to a larger number of users.

**Key words :** Kubernetes, GPGPU, Machine Learning, Deep Learning, JupyterHub

### 1. 緒言

近年、深層学習は様々な分野で非常に高い注目を浴びている。これは OpenAI が 2022 年に公開した ChatGPT の影響が非常に大きいと考えられる。ChatGPT は大規模言語モデルの一種である GPT-3 を使用したチャットボットであり、回答の正確さや柔軟性から世界的に注目されている。その注目度の高まりは 1 年以上が経過した 2023 年 12 月現在でも継続している。

このように近年の深層学習は大規模化の流れにあるが、同時にこれらのモデルをより低性能な計算機で学習できるようにしようという流れも存在する。例えば、2022

年 8 月にオープンソース化し一般向けに公開され、非常に高い注目を集めている画像生成モデルである Stable Diffusion は、厳密には条件によって異なると思うが、GPU の VRAM が 12GB 以上であれば動作するため家庭用の GPU でも画像の生成を行うことが可能である。Stable Diffusion は Stability AI が提供する画像生成モデルである。主に txt2img は Text to Image の略であり、文章から画像を生成することが可能であるという特徴から誰でも簡単に利用できる。更に img2img は Image to Image の略であり、画像から画像を生成するという場合においても、最低 1 枚の画像から新たに画像を生成することが可能であるなど、こちらも非常に簡単に利用できる。また、txt2img と img2img のどちらも様々なパラメータの調整を行うことで細かな修正を行うことができ、それらのパラメータの修正も専用の Stable Diffusion Web UI を利用することで行いやすくなっている。こういった理由から Stable Diffusion は公開直後から非常に高い人気があった。最も簡単に GPU を利用できる環境の 1 つである Google Colaboratory では、かつて無料で NVIDIA T4 という GPU が割り当てに失敗することもあるが、基本的に無制限に利用できた。この NVIDIA T4 は GPU の VRAM 容量が 16GB あり、Stable Diffusion を実行する

\*1 大学院工学研究科 知識社会基礎工学専攻

\*\*Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

\*\*\*知能システム工学講座

\*\*\*\*Department of Human and Artificial Intelligent Systems

\*\*\*\*\*仁愛女子短期大学 生活科学学科

\*\*\*\*\*Jin-ai Women 's College

\*\*\*\*\*工学部 技術部

\*\*\*\*\*Technical Division

ことができたため、画像生成が非常に多く行われた。そのため、2022年の9月30日以降、Google Colaboratoryの有料プランで従来の優先的に上位のランタイムやGPUを割り当てるといった定額で使い放題という形態から、毎月一定のコンピューティングユニットが割り当てられるという形態に変わった。使用するランタイムやGPUによって消費するコンピューティングユニットは異なるが、使い切ると追加でコンピューティングユニットを購入しない限り、それ以上GPUの利用ができなくなった。さらに、2023年の4月にGoogle ColaboratoryのプロダクトリーダーであるChris Perryが「Stable Diffusion Web UIの利用量が非常に多くなり、Google Colabチームの予算では対応できなくなった」という趣旨の投稿を旧Twitter（現X）にて行っており、そのあとGoogle Colaboratoryの無料プランでは、Stable Diffusion Web UIの利用に制限がかかるようになった。

以上をまとめると、生成AIの登場によって深層学習に対する注目度はこれまで以上に高まっているが、それを実行するために大きな企業などのプラットフォームが提供する計算機環境は突然の料金プランの変更などを受け、利用方法を変える必要が生じることがある。そういった事態を避けるために最も効果的な方法はやはり自前の計算機環境を用意することであり、本研究では主に家庭用GPUを搭載した複数のコンピュータを利用することでユーザーがより安定して機械学習や深層学習を実行できる計算機環境提供システムの実現を目指す。また、ユーザーの利用に際して、より機械学習や深層学習の実行を支援するために、コンテナ型仮想化を使用した計算機環境の生成を行う。

## 2. 機械学習と計算機環境

本章では、機械学習と計算機環境の関係について、歴史を踏まえつつ説明する。

### 2.1 機械学習とは

一言に機械学習と言っても、この言葉の持つ意味は回帰分析や帰納学習、進化的計算など多数あるが、今回はその中でもニューラルネットワークを使用した手法について説明する。

ニューラルネットワークとは、生物の神経細胞によるネットワークをモデル化したものとして人口ニューラルネットワークとも呼ばれる。ニューラルネットワークは、ニューロンという神経細胞をモデル化したものを複数組み合わせたものとなる。ニューロンは主にパーセプトロンを使ってモデル化される。パーセプトロンとは、複数の入力に対して一つの出力を行う関数である。こ

のパーセプトロンを用いることで、線形分離可能な問題は学習することが可能である。しかし、一つのパーセプトロンでは排他的論理和のような線形分離することができないものは学習することができないという問題がある。複数のパーセプトロンを用いてニューラルネットワークを構成することで、線形分離不可能なものであっても学習が可能となる。実際に排他的論理和は3つのパーセプトロンを使って2層のニューラルネットワークを構成することで学習可能である。つまり、ニューラルネットワークは層を重ね、ニューラルネットワークを構成するパーセプトロンの数を多くすることでより複雑な問題にも対応することが可能であると言える。このように複数のパーセプトロンを使って2層以上のニューラルネットワークを構成したものを多層パーセプトロンとも言う。余談ではあるが、反対に一つのパーセプトロンのみにより構成されるニューラルネットワークを単純パーセプトロンという。

単純パーセプトロンよりも多層パーセプトロンの方がパラメータ数が多く、より複雑な問題に対応できるということから非常に注目度は高かったが、単純に多層パーセプトロンの一層あたりのパーセプトロンの数を増やしたり、層の数を増やしたりなどしても学習がうまくいかないという問題が発生した。それが、局所最適化と勾配消失問題である。局所最適化は最適化分野の問題とも言える問題である。具体的には、多層パーセプトロンの中間層や学習データを増やしていくと、学習データと出力との誤差を減らす際に、局所最小値にはまってしまうという問題である。この現象は過学習とも言われる。勾配消失問題は活性化関数であるシグモイド関数によって学習データと出力の誤差を減らそうとしても中間層を増やすほど誤差の勾配がシグモイド関数の端によってしまい、誤差の減少が思うように進まなくなるとい問題である。これらの問題によって多層パーセプトロンは機械学習手法としてあまり注目されなくなった。

### 2.2 深層学習とGPGPUの活用

多層パーセプトロンによるニューラルネットワークを用いた機械学習に転機が訪れたのは、局所最適化と勾配消失問題を解決する方法として、ヒントンがオートエンコーダとディープピラーフネットワークを提案した2006年である。これらの方法によって中間層が2層以上であっても学習が継続できるようになった。そのため、これ以降の3層以上の多層パーセプトロン、つまりディープニューラルネットワークを使った学習における問題点は計算量の多さと学習データの収集になった。ディープニューラルネットワークは層と学習データを増やせば増やすほど性能が向上すると言えるので、それ

らの計算を効率よく行うことが次の課題になるからである。その問題に対する有効な手段は2012年に開催された画像認識AIの競技「ImageNet Large Scale Visual Recognition Challenge」(ILSVRC)<sup>[1]</sup>においてトロント大学のアレックスらが、2基のGPGPUによる学習で平均的な人間の正答率を超える結果を出したことで示された。この時に行われた学習には畳み込みニューラルネットワークが使われている。畳み込みニューラルネットワークとは、畳み込み演算を加えたニューラルネットワークの総称であり、ディープニューラルネットワークがDNNと呼ばれるようにCNNと呼ばれる。これは畳み込み演算が英語で、「Convolution」というためである。畳み込み演算とは、与えられた2つの数列の要素同士を全組合せで乗算して加算する計算のことである。例えば画像であれば、1つの画素だけ見ているでもそれがなんであるかわからないため、周囲の画素との関係を見ることが重要である。畳み込み演算はそういった状況において5x5の範囲の特徴などを計算する際に有効な演算である。CNNを使った学習ではこの畳み込みの計算が学習過程で大量に行うことになり、その計算には非常に時間がかかる。そこでGPGPUを使用することが重要になる。GPGPUとは「General-purpose computing on graphics processing units」の略称であり、日本語に訳すと「GPUによる汎用的な目的における計算」となる。GPUとは元々画像処理に使われていた計算装置であるが、それを画像処理以外に利用する技術がこのGPGPUである。畳み込み演算は、行列同士の掛け算が主な処理内容であり、この計算はGPUが画像処理用に持っている持つプログラマブルシェーダー実行装置によってそのまま計算可能である。つまり、GPUをGPGPUとして活用することで、大量のデータの畳み込み演算を高速に実行可能になり、CNNによる学習を促進することになった。

### 3. 計算機環境提供システムの構築

本章では、コンテナ仮想化を使った機械学習環境の構築について、ハードウェアやソフトウェアなどをどのように使用したか具体的に述べる。主に家庭用GPUを搭載した複数のコンピュータを利用することでユーザーがより安定して機械学習や深層学習を実行できる計算機環境提供システムの構築を行う。また、ユーザーの利用に際して、より機械学習や深層学習の実行を支援するために、コンテナ型仮想化を使用した計算機環境の生成を行う。

#### 3.1 ハードウェアの準備

今回は2つの研究室で別々に複数のコンピュータを使用した。それぞれの研究室で使用したコンピュータのスペックは表1と表2の通りである。

これらのコンピュータを用いてクラスタリングを行うことで機械学習用の計算機環境を用意する。どのようにクラスタリングを行うかは3.3節に記載する。

#### 3.2 コンテナ型仮想化

本研究では、コンテナ仮想化を用いて計算機環境を用意する。コンテナ型仮想化はほかの仮想化技術とどのように異なるのか、具体的にどのようなコンテナ型仮想化技術を用いたのかなどについて述べる。

まず、IT分野における仮想化とは論理的にハードウェアなどのリソースを分離したり、複数のハードウェアで共有したりする技術を指す言葉である。仮想化を利用することで、1台のコンピュータで複数の異なるOSを動作させることが可能となったり、別のコンピュータにOSなどのコンピュータの動作に必要なデータを移すことでOSを停止させずにコンピュータの停止を行うライブマイグレーションが可能となったりする。仮想化技術にはハイパーバイザー型とコンテナ型の2種類が存在する。

- ハイパーバイザー型仮想化技術

ハイパーバイザー型は物理コンピュータにインストールされたOSの上で仮想ハードウェアをエミュレーションする。そのため、ホストとなっている物理コンピュータで動作可能なOSであれば仮想ハードウェアにインストールすることができる。つまり、1台のコンピュータ上でWindowsやLinuxなど多種多様なOSを同時に動作させることが可能となる。VMware, Proxmox VE, KVMなどがハイパーバイザー型仮想化ソフトウェアとして挙げられる。

- コンテナ型仮想化技術

コンテナ型はホストマシンのOSとコンテナで動作するゲストOSとでカーネルを共有するため、ハイパーバイザー型と比較してリソースのロスが少なく、リソースを最大限活用することが可能であるが、カーネルを共有するという性質上、ゲストOSとして活用することのできるOSには制限があり、カーネルのアップデートもゲストOSでは行うことができないという制限もある。代表的なソフトウェアとしてDockerが挙げられるが、Docker以外にも、containerdやcri-o, podman, runcなどがある。

今回の環境構築ではクラスタリングにKubernetesを

表 1 研究室 A

	A-01	A-2	A-3
CPU	Intel Core i5 10400	Intel Core i7 13700	AMD Ryzen 7 1800X
Memory	DDR4 16GB	DDR4 48GB	DDR4 16GB
Storage	HDD 6TB	SSD 512GB	SSD 256GB + HDD 1TB
GPU	(none)	NVIDIA GeForce RTX 4080 NVIDIA A2	NVIDIA GeForce GTX 1080 Ti

表 2 研究室 B

	B-0	B-1	B-2	B-3	B-4
CPU	Intel Core i5 13400	Intel Core i7 3770	AMD Ryzen 7 1800X	AMD Ryzen 5 2600X	Intel Core i7 10700
Memory	DDR5 16GB	DDR3 16GB	DDR4 16GB	DDR4 16GB	DDR4 64GB
Storage	SSD 512GB	HDD 2TB x4 (RAID10)	SSD 256GB	SSD 256GB	SSD 1TB
GPU	(none)	(none)	NVIDIA GeForce GTX 1080 Ti	NVIDIA GeForce RTX 2080 Ti	NVIDIA GeForce RTX 3070

利用している関係上,containerd をコンテナソフトウェアとして利用する。

### 3.3 Kubernetes によるクラスタリング

今回は計算機環境をユーザーに対して提供するにあたって,クラスタリングを行うことにする。クラスタリングを行う利点は大きく 3 点ある。

1. ユーザーが複数のコンピュータを一つのサービス,例えば Web ページから選択して利用することが可能になる。
2. クラスタにコンピュータを追加することで計算機の数を拡張できる。
3. クラスタを構成するコンピュータの役割を分けることで負荷分散ができる。

Kubernetes をクラスタリングソフトウェアとして選んだ理由は,1 つ目と 2 つ目の利点を実現するためである。

Kubernetes は複数のコンテナを管理するためのソフトウェアであり,JupyterHub を Kubernetes にインストールすることでユーザーは Web ブラウザ上の操作によって Jupyter Notebook のコンテナを任意のコンピュータに作成し,利用することが可能となる。

また,クラスタの拡張については,Kubernetes は後からクラスタにコンピュータを追加しても,それを計算用コンピュータとして利用するために必要なソフトウェアをコンテナとして自動で作成し機能を追加する仕組みを持っているので,計算機環境提供システムを必要に応じてスケールアウトすることが非常に容易である。

そして,3 つ目の利点を実現するためにクラスタリングを行うコンピュータの数を最低でも(計算用コンピュータの数+1) 台となるようにした。これはクラスタの管

理を行うコンピュータとデータを保存するコンピュータを計算用コンピュータとは別に用意するためである。この役割の分離についても Kubernetes を使用することである程度容易に行うことができる。また,できればクラスタの管理とデータ保存のコンピュータも分けたほうが無難ではあるため,コンピュータの数に余裕があった研究室 B ではクラスタに使用したコンピュータの数を(計算用コンピュータの数+2) 台としている。

ここで表 1 と表 2 について補足すると,それぞれのコンピュータの名前について,最初のアルファベットがどの研究室のものであるかを示しており,「-」の後に続く数字がそのコンピュータのクラスタにおける役割を示している。具体的には「0」がクラスタの管理を行うコンピュータであり,「1」がデータを保存するコンピュータ,「2」以降が計算用のコンピュータである。つまり,表 1 の研究室 A では,A-01 がクラスタの管理とデータ保存の両方を担っている。

### 3.4 JupyterHub によるノートブックコンテナの提供

JupyterHub は Jupyter Notebook を作成し,ユーザーに提供するための Web アプリケーションである。Jupyter Notebook は IPython<sup>[2]</sup> をブラウザから利用することを可能にする。

仕組みを簡単に説明すると,JupyterHub はスポンサーによって Jupyter Notebook 環境を提供する。動作する環境によってスポンサーの種類は異なり,Kubernetes 環境では専用のスポンサーである KubeSpawner が動作している。KubeSpawner にはリソース制限をかけたり,GPU などを利用したり,コンテナのもとになるコンテナイメージを設定したりするための設定を行うことが可能となっている。ユーザーが HTTP Proxy 経由で Hub にアクセスし Jupyter Notebook 環境の作成を要求すると,KubeSpawner

はコンテナ上で動作する Jupyter Notebook をユーザーが指定したコンピュータ上に作成するという処理の流れで計算機環境が環境が構築されてる。

このような機能を持つ JupyterHub であるが、今回計算機環境の提供にあたって選択した理由は主に下記の2つである。

1. ノートブック環境をブラウザ上で作成し、利用できる使いやすさ。
2. コンテナイメージを追加できる拡張性。

まず、1つ目の理由について説明すると、JupyterHub は JupyterHub によるノートブック環境の構築と構築したノートブック環境の利用をブラウザ上で完結することができ、システム全体を通してユーザーが利用しやすいようにシンプルな操作だけで使うことが可能となっている。例えば、コンテナに必要なパッケージをインストールしたいという場合でも、ブラウザ上の操作でインストール操作を完結することが可能である。

次に2つ目の理由について説明すると、JupyterHub にはノートブックコンテナを作成するためのコンテナイメージを複数登録することが可能である。しかし、それらのコンテナイメージは Jupyter 公式によって提供される特定のスクリプトを持っている必要がある。ただ、それらのスクリプトや公式の提供するイメージのもとになっている Dockerfile は GitHub<sup>[3]</sup> で公開されており、それらのファイルを GitHub に登録されている Dockerfile を参考にしてコンテナイメージ内部にコピーすれば、オリジナルのコンテナイメージを作成することが可能となる。つまり、必要に応じてコンテナイメージを自作することが可能である。コンテナイメージを自作することのメリットは多数あり、例えば、Jupyter 公式が提供するノートブックコンテナのもとになるコンテナイメージに含まれる Tensorflow では GPU が利用できないが、Tensorflow のインストールや深層学習に必要なライブラリ類や GPU ドライバー類を内包したコンテナイメージを自作することで GPU の利用が可能となっている。また、これらの作業は先に述べたようにコンテナ作成後にブラウザからの操作で行うことも可能といえは可能であるが、非常に時間のかかる作業である。そういった際に、予め GPU の利用に必要なソフトウェアを持ったコンテナイメージからコンテナを作成することで時間の節約につながるという利点もある。ただし、そういった大きなファイルを含んだコンテナイメージは必然的にそのファイルサイズも大きくなるので、どこまで事前にソフトウェアをインストールしておくかは場合によるとしか言えない。今回は3つのオリジナルイメージを作成した。

- **Simple Container Image** : Jupyter 公式のイメージのベースイメージを通常の Ubuntu から NVIDIA が提供する CUDA 関係のファイルを含んだものに変更してビルドし直したコンテナイメージ。
- **AutoML Container Image** : 上記の Simple Container Image に AutoML 関係のライブラリをインストールしたコンテナイメージ。
- **Multi Kernel Container Image** : Jupyter Kernel として複数のプログラミング言語をノートブックから実行できるようにしたコンテナイメージ。

以上の理由から今回は JupyterHub を利用することとした。また今回は、Kubernetes に JupyterHub などアプリケーションをインストールするにあたって Helm という Kubernetes 用パッケージマネージャを利用した。

### 3.5 KubeSpawner のカスタマイズ

JupyterHub にはプロファイルリストとして複数のコンテナ実行条件を設定できる。例えば、「CPU やメモリ、GPU をどのように利用するか」、「コンテナのもととなるイメージには何を使用するか」などである。これによって事前に作成したオリジナルイメージをもとにノートブックコンテナを作成する選択肢を追加することが可能となるが、それと同時にユーザーが利用するリソースの利用量の予測しづらくなり、結果としてリソース超過が発生する恐れが高まることが考えられる。

今回のシステム中でリソース超過が発生する状況には以下の2つが考えられる。なお、ここで言う「リソース」は CPU コア数やメモリ容量などのコンピュータリソースを指す。

- コンテナが要求した最低リソースの合計が実際にコンピュータ上にあるリソースを上回る。
- コンテナに設定されたリソース制限の最大までリソースを利用するコンテナが複数あったり、そもそもリソースを制限されていないコンテナが膨大な量のリソースを使用したりすることでリソース使用量が実際のコンピュータ上にあるリソースを上回る。

通常のシステムであれば、少なくとも前者の原因については発生しないようにされているのが通常であると思われるが、今回使用した JupyterHub では特にそういったリソース超過の検知機能などはなかったため、リソースが不足していてもノートブックコンテナの作成を行い、作成に失敗するという現象が発生していた。問題は JupyterHub がノートブックコンテナの作成に失敗して

も、それを失敗と認識してユーザーが再度ノートブックコンテナの作成を行うことができるようになるまでに5～10分とかなりの時間がかかることである。また、適切なエラーメッセージを表示して、別のもっと低いリソースでノートブックコンテナの作成を促すような機能もないため、ユーザーが再度同じリソースでノートブックコンテナの作成を要求し、同じ問題に何度も遭遇するという現象も考えられる。

今回はそういった問題を回避するために JupyterHub の KubeSpawner の一部をオーバーライドすることでカスタマイズした CustomSpawner を実装した。

CustomSpawner の機能は次の2つである。

- リソース超過の検知
- リソース超過発生の恐れのあるコンテナイメージの不可視化

前者の機能は図1のように Kubernetes クラスターのノードのキャパシティとコンテナが要求するリソースの差を調べ、その差よりも大きなリソースを要求していないかを調べる機能である。後者の機能は前者の機能を利用し、プロファイルリストに登録されているすべてのコンテナ実行条件を調べて、リソース超過が発生すると検知されたものはユーザーから選択できないように不可視化するという機能である。

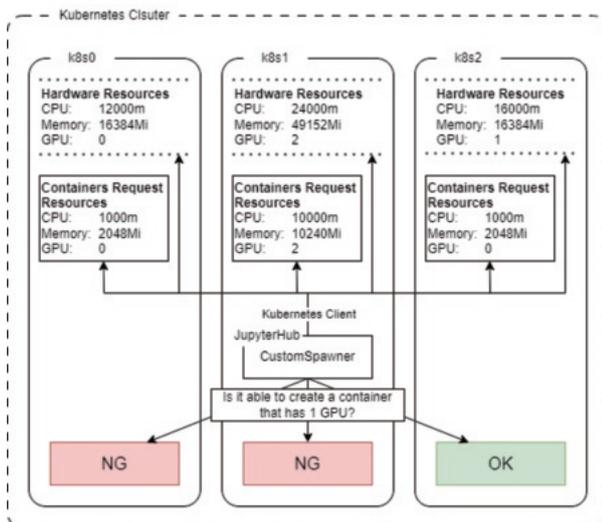


図1 リソース超過検知の概要

これらの機能によって JupyterHub によるノートブックコンテナの作成においてリソース超過をある程度抑制することができた。また、リソース超過が発生する原因の2つ目については、プロファイルリストに登録する際に、コンテナが要求する最低リソースと、コンテナが利用できる限界リソースの差を小さくすることである

程度発生を抑制できるのではないかと考え、それらの値の差を1から1.5倍くらいの値になるように設定した。

#### 4. 計算機環境の性能計測と効果検証

構築した計算機環境提供システムに対していくつかのベンチマークツールを使用して性能の計測を行う。計測は「段階的にリソース制限をかけた際の性能変化」と「同一コンピュータ上で同時にベンチマークツールを複数実行したときの性能変化」の2つを調べるために行う。

効果検証は実際にユーザーに今回構築した計算機環境提供システムを利用してもらった上でアンケートを実施することで調べた。

##### 4.1 性能計測実験

先に述べたように2つの方法で性能の計測を行う。それぞれの方法について具体的に説明する。

まず、「段階的にリソース制限をかけたときの性能変化」の調査は、CPUやメモリなどのリソースに制限をかけたときに、その性能変化にGPUの性能が影響を受けて変化するのかを調べるための実験である。

次に、「同一コンピュータ上で同時にベンチマークツールを複数実行したときの性能変化」の調査は、複数のユーザーが同時に一つのGPUを使用することを想定して、実際にどのような性能の変化があるのかを調べるための実験である。

それぞれの結果は次のようになった。なお、ここでは表1における「A-3」上で実行した結果のみを載せる。

まずは「段階的にリソース制限をかけたときの性能変化」の結果を図2、図3、図4に載せる。図は縦軸がメモリの容量を横軸がCPUのコア数を示している。

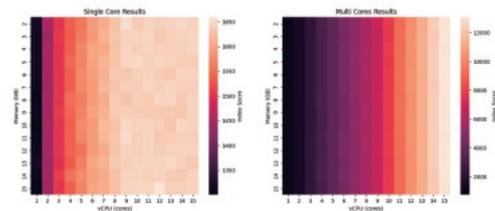


図2 段階的にリソース制限をかけたときの性能変化 (UnixBench)

次に「同一コンピュータ上で同時にベンチマークツールを複数実行したときの性能変化」の結果を図5、図6に示す。

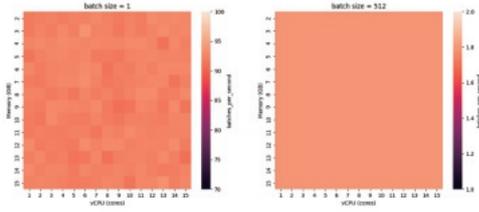


図3 段階的にリソース制限をかけたときの性能変化 (pytorch-benchmark<sup>[4]</sup>)

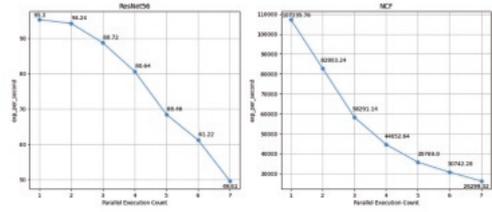


図6 同時にベンチマークツールを複数実行したときの性能変化 (PerfZero<sup>[5]</sup>)

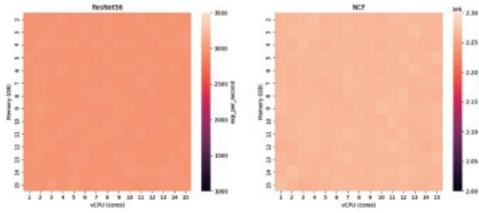


図4 段階的にリソース制限をかけたときの性能変化 (PerfZero<sup>[5]</sup>)

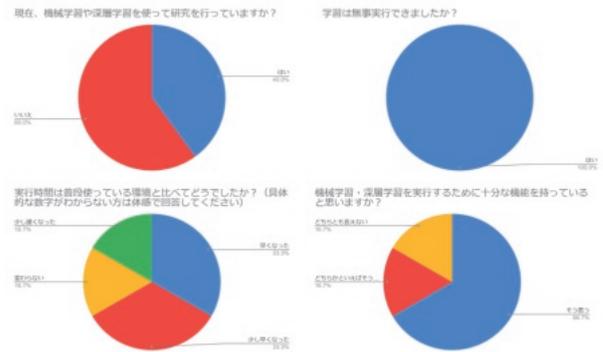


図7 アンケート結果

### 4.2 効果検証のための評価実験

今回構築した計算機環境提供システムとシステムによって提供された計算機環境がどの程度使えるのか調査するためにアンケートを実施する。アンケートにはシステムを全体的に使用してもらうためにいくつかの作業とユーザーの背景を知るための質問と、システムの評価に関する質問が含まれている。ここではその一部を抜粋して図7に示す。

## 5. 考察

ここでは先の実験についての考察を行う。

まず4.1節の「段階的にリソース制限をかけたときの性能変化」の結果は、GPUを使用しない UnixBench では顕著な差がみられたため、特にCPUのリソース制限によって計算機環境の性能は変化するということが分かった。しかし、pytorch-benchmark<sup>[4]</sup>とPerfZero<sup>[5]</sup>の結果を見るとほとんど変化していないことから、計算機環

境であるコンテナの性能が変化してもGPUの動作にはそれほど大きな影響はないと考えられる。

次に同じ節の「同一コンピュータ上で同時にベンチマークツールを複数実行したときの性能変化」の結果は、明らかに性能が変化していることが確認できた。一度の実行が比較的短時間で終了するものと長い時間を要するものでスコアの下がり方に違いがみられたが、これはベンチマークツールを本当に同時には実行できておらず、その結果実行タイミングに多少のズレが生じているためであると思われる。つまり複数同時に処理を実行している時間が長いものほど、同時実行数とスコアが反比例のような関係を示していると考えられる。

最後に4.2節のアンケート結果は、4つの結果のみを挙げているが、最初の一つがユーザーの背景調査でありアンケートに回答してくれた15名全員に聞いている質問である。内容は「現在深層学習を使用して研究を行っているか」であり、ここで「はい」と答えた6名に残りの3つの質問に回答してもらっている。残りの3つの質問は計算機環境提供システムと提供された計算機環境の機能や性能を回答者の主観を交えて回答してもらう内容となっている。3つすべてで過半数を超える肯定的な回答を得られたことから、今回のシステムはある程度実用に耐えうる計算機環境を提供できていると考えられる。

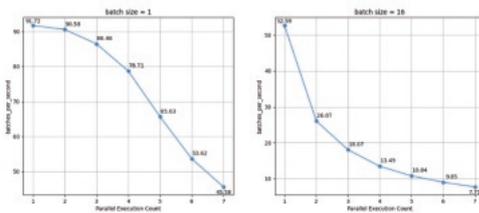


図5 同時にベンチマークツールを複数実行したときの性能変化 (pytorch-benchmark<sup>[4]</sup>)

## 6. 結言

本研究では、計算機環境を提供するシステムを構築し、多くのユーザーに安定した計算機環境を提供することを目的としている。計算機環境提供システムは Kubernetes と JupyterHub を使用し、ユーザーのリクエストに応じてノートブックコンテナを提供するという機能を実現した。

計算機環境提供システムは複数のコンピュータ上で動作するが、実際に計算機環境を使用するユーザーの数と計算機環境提供システムを構成するコンピュータの数を比較すると、ユーザーの数の方が多いため、一台のコンピュータ上に提供される計算機環境であるノートブックコンテナを複数同時に実行できるようにした。

同時に複数の計算機環境を実行する場合、各コンテナに対して使用可能なリソースを制限しないと、実際に存在するリソース以上にリソースを使用しようとしてしまうため、JupyterHub のスポンサーに実際に存在する以上のリソースを要求しないようにする機能を追加した。また、リソース制限がコンテナの性能にどのような影響を及ぼすのか、そのコンテナの性能変化が GPU の性能にどのような影響を及ぼすのか、複数のコンテナが同時に GPU を使用した場合それぞれのコンテナ中の処理の性能はどのように変化するかなどを調べた。結果は CPU のリソース制限によってコンテナの性能は低下するが、GPU にはあまり大きな影響はないということがわかり、複数のコンテナが GPU を同時に使用した場合は同時使用数と性能は反比例するように低下することが確認できた。

また、アンケートではおおむね実用に耐えうる計算機環境が提供できていることが確認できた。

以上のことから、家庭用の GPU を搭載したコンピュータを複数統合管理して複数のユーザーが利用できるような計算機環境提供システムが実現できたと考えられる。

今後は、アンケートに多数寄せられたシステムの UI に関する改善や、複数の GPU を利用することでより強力な計算機環境を提供できるような機能の実現を目指したい。

## 参考文献

[1] Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, et al. Imagenet large scale visual recognition chal-

lenge. *International journal of computer vision*, Vol. 115, pp. 211–252, 2015.

- [2] Fernando Pérez and Brian E Granger. Ipython: a system for interactive scientific computing. *Computing in science & engineering*, Vol. 9, No. 3, pp. 21–29, 2007.
- [3] Github - jupyter/docker-stacks: Ready-to-run docker images containing jupyter applications. <https://github.com/jupyter/docker-stacks/>(2024/01/23).
- [4] Github - lukashedegaard/pytorch-benchmark: Easily benchmark pytorch model flops, latency, throughput, allocated gpu memory and energy consumption. <https://github.com/LukasHedegaard/pytorch-benchmark>(2024/01/24).
- [5] Github - tensorflow/benchmarks: A benchmark framework for tensorflow. <https://github.com/tensorflow/benchmarks/>(2024/01/23).

## シェアサイクリングサービスのCtoC化を目指したプロトタイプの実装

風折晃輝\* 小高知宏\*\* 黒岩丈介\*\* 諏訪いずみ\*\*\* 白井治彦\*\*\*\*

### Implementation of a prototype aimed at CtoC of bike sharing

Koki KAZAORE\*, Tomohiro ODAKA\*\*, Jousuke KUROIWA\*\*

Izumi SUWA\*\*\*, Haruhiko SHIRAI\*\*\*\*

(Received February 1st, 2024)

In this research, we proposed a bike sharing service aiming at CtoC, and designed and implemented a prototype to realize the service. In recent years, bike sharing services that allow people to use bikes at any time and for any period of time have become popular worldwide, especially in Europe, the United States, and China. However, one issue is that it is still not as popular in rural areas as a whole compared to urban areas.

Therefore, in this study, we assumed that although the spread of bike sharing services is uneven between urban and rural areas, the distribution of privately owned bikes is not so uneven. The purpose of this study was to propose a bike sharing service that could be used and develop a prototype for its realization. This prototype was constructed by separating software and hardware. Regarding the hardware, we built a smart lock by incorporating a microcomputer and servo motor into an existing bike lock and adding optional authentication sensors. The software was constructed using two approaches: authentication using NFC and fingerprint authentication. As for the completed system as a whole, although we were able to build a prototype that could unlock and lock even when multiple authentication sensors were used, it could only be executed in a local environment, making it difficult to deploy it as a service. It can be said that there are still many points that need to be improved.

**Key words** : IoT, Smart Lock, Bike sharing

### 1. はじめに

近年、欧米や中国を中心として世界的に、自転車を好きなタイミングで好きな期間利用することができる

\*1大学院工学研究科 知識社会基礎工学専攻

\*\*Fundamental Engineering for Knowledge-Based Society, Graduate School of Engineering

\*\*\*知能システム工学講座

\*\*\*\*Department of Human and Artificial Intelligent Systems

\*\*\*\*\*仁愛女子短期大学生活科学学科

\*\*\*\*\*Jin-ai Women's College

\*\*\*\*\*工学部技術部

\*\*\*\*\*Technical Division

シェアサイクルサービスが普及している<sup>[1]</sup>。しかし、都市部と比較して人口の少ない地方では駅前などの比較的栄えている部分でのみサービスが展開されていることはあれど、地方全体としてはまだまだ普及していないという課題が挙げられる。原因としては、自転車を設置するポートを新設したとしても利用者数が少ないために採算が取れないことが考えられる。

しかし、地方であったとしてもシェアサイクルサービスを利用したいという需要は必ず存在していると感じる。例えば、徒歩圏内にあるコンビニエンスストアへ行きたいが時間は無い状況が一例として挙げられる。今すぐに少しでも自転車を借りたい場合、すぐそばにシェアサイクルサービスを利用することのできる環境

が整っていれば便利であろう。

また、自転車を借りる立場からのシェアサイクルだけでなく、自転車を貸す立場からのシェアサイクルにも一定数の需要があるのではないかと考える。例えば、自転車を所有しているが、普段ほとんど使用することがなく、駐輪場に放置されている自転車を例に挙げる。普段使用していない自転車をシェアサイクルサービスの1つの自転車として他人に貸し出すことによって、自転車を有効活用できる。ひいては、使われていない自転車がゴミとして処分されることを防ぎ、環境にも好影響を与えるかもしれない。

その上、これらの個人所有された自転車は、都市部と地方との偏りが比較的少なく、基本的にどこにでも分布している。

本研究では、個人所有の自転車を個人間でシェアすることのできるシェアサイクルサービスを提案し、それを実現するためのプロトタイプを実装する。前述したように、地方でシェアサイクルサービスが普及しない原因として採算性が悪い点が考えられる。しかし、個人所有の自転車をシェアする場合については、予めシェアするための自転車を用意する必要が無いため、初期費用がかなり抑えられることが期待される。また、個人所有の自転車を駐輪している駐輪場が、一般的なシェアサイクルサービスにおけるポートのような存在になるため、新しくポートを確保するための手間や費用も抑えられる。なおかつ、あらゆる場所をポートととして捉えることができる。本研究では提案するサービスを実現するためのスマートロックプロトタイプについては、認証手法としてNFC(Near Field Communication)と指紋認証の2種類を用いることとし、プロトタイプとしての拡張性についても配慮したシステムを構築する。

## 2. 既存のシェアサイクリングサービスについての課題とソリューション

シェアサイクルとは、「相互利用可能な複数のサイクルポートが設置された、面的な都市交通に供されるシステム」<sup>[2]</sup>と定義されており、自転車が設置されているサイクルポートを起点として、直接的には繋がりのない他者同士がその自転車をシェアリングするシステムを指す。PR Times<sup>[3]</sup>によると、世界におけるシェアサイクル市場規模は、2019年に34.9億ドルであったのに対し、2027年には698万ドルに達すると試算しており、成長産業であることが窺える。そのようなシェアサイクルを提供している既存のサービスとして「LUUP<sup>[4]</sup>」や「ドコモバイクシェア<sup>[5]</sup>」等のサービスが挙げられる。これら既存のシェアサイクルサービスを比較する

と、サービスを利用する際のトリガーとして用いられるものは、ICカードやQRコード、Bluetoothが多い。これらのトリガーと共に専用のアプリケーションを用いて施錠や解錠を行ったり、利用予約ができたりする。また、これらのサービスではそれぞれのベンダーがサイクルポートを設置し、そのサイクルポートに自転車を準備することによってユーザーにサービスを提供する構造になっているため、自ずと人口が多くて需要の高い都市部や主要な駅周辺において中心的にサービスが提供されやすい形態となっている。一方で、比較的需要の低いとされている人口の少ない地方や駅から離れた地域ではシェアサイクリングサービスが提供されていないことが多く、そのような地域でも一定の需要は存在すると考えられる中で、シェアサイクリングサービスを利用したい人が利用できない状態に陥っている。これは、地方や田舎・離島地域におけるシェアサイクリングの普及の遅れが移動手段の選択肢を限定し、地域住民のモビリティの質を低下させる一因となっている可能性が示唆される。このような背景からシェアサイクリングサービスの地域間格差を是正し、より包括的な交通ネットワークを構築することが必要不可欠である。

そこで、シェアサイクリングサービスが普及していない地域ではそのサービスを利用したい需要に対応できない点を課題として挙げ、その課題を解決するためのソリューションとなる、自転車の個人間シェアリングを可能とすることを目指すIoTシステムの開発を行った。図1に一般的な既存のシェアサイクリングサービスの形態を示す。前述した通り、ベンダーから提供される自転車ポートをベースとして利用者がサービスを利用する。一方で、本研究で想定するサービスの概要図は図2のようになる。図2のようなモデルでは個人所有の自転車が駐輪されている駐輪場をベースとして利用者がサービスを利用することを想定している。図1で示している自転車ポートの設置分布と比較して図1で示す駐輪場の設置分布はより広範な地域を網羅できていると想定されるため、シェアサイクリングサービスを利用したいユーザーが、そのサービスが普及していない地域でも利用することができ、課題の解決につながると期待できる。また、ステークホルダーに含まれる、自転車を貸し出す側の個人所有者についても、所有している自転車を使っていない間に有効活用できる点において付加価値を提供できると考える。

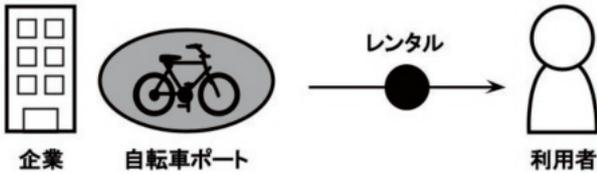


図1 既存のBtoCによるサービスモデル

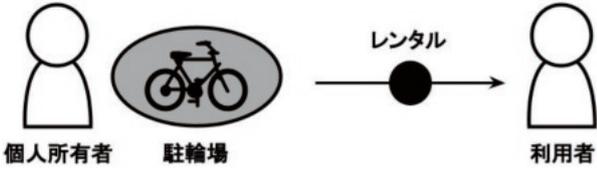


図2 構築するCtoCによるサービスモデル

3. システム構成

本研究において構築するシステム構成の全体像を、既存のシェアサイクルサービスと比較して図3に示す。既存のシェアサイクルサービスではベンダーが提供しているシェアサイクルポートの設置位置に依存してサービスが展開される。一方で、本研究において構築するサービスモデルでは個人所有の自転車が駐輪されている駐輪場に依存してサービスを展開することが可能である。それ故に、個人所有の自転車を用いられているそれぞれの鍵の形態を考慮する必要があるが、ここではプロトタイプ提案として一般的な自転車に標準装備されているシリンダー式のリング錠を前提としてシステムを構成することとする。

図3に示したようなシステムを構成するにあたって自転車の鍵をスマートロック化し、利用するユーザーに応じてスマートロックを解錠する必要がある。そこで、本研究ではNFCを用いたスマートロックの認証と指紋を用いた生体認証の2つのパターンからそれぞれアプローチする。それぞれの認証についてのシステム構成の詳細は3.1節と3.2節にて後述する。

本研究にて想定する具体的なシステムの利用順序を図4に示す。構築したスマートロックを自転車のオーナーが自身の自転車に取り付け、専用のモバイルアプリにて、利用を希望しているユーザーが利用しても良い時間帯を予め登録しておく。ただし、本研究においてはこのモバイルアプリの構築は対象外とし、スマートロックのプロトタイプに限定している。

その後、ユーザーは利用したい際にモバイルアプリから利用したい時間帯とマッチする自転車を探し出し、利用の申請をする。

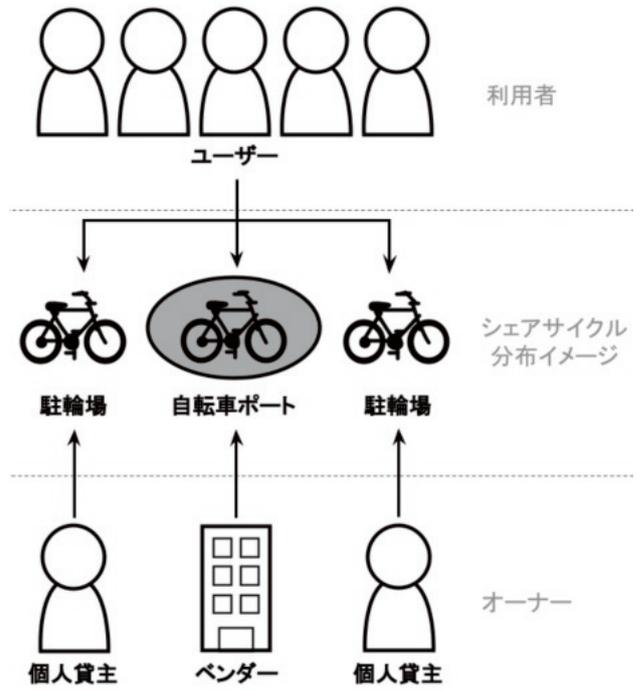


図3 本研究において構築するシステム構成の全体像



図4 想定するシステム利用手順概要図

3.1 NFCによる認証

NFCによる認証をベースとした自転車のスマートロックシステムの概要を図5に示す。NFCとは近距離無線通信 (Near Field Communication) を意味し、電子機器間の数センチメートル範囲内で発生する電磁誘導に起因してそれらの機器間の通信を可能とする<sup>[6]</sup>。そのNFC技術が用いられているNFCタグをスマートロックと連携することによって自転車の鍵を解錠する仕組みを構築する。想定する具体的な認証手順としては、まず、NFCを用いた自転車の鍵を自転車のオーナーが自身の自転車に取り付け、別途用意するアプリケーション上でユーザーが利用可能な時間を予め設定しておく。次に、ユーザーは、利用したいタイミングでそのアプリケーションから利用したい希望の時間帯とマッチする自転車を

探し出し、利用申請する。自転車の鍵には NFC の他、マイコンやサーボモータを組み込み、スマートフォンが NFC にかざされ、認証されるとサーボモータが回転し、解錠する。

具体的な認証手順については、主に Blynk と IFTTT と呼ばれる 2 つの外部アプリケーションと連携して自転車の鍵に組み込まれている ESP32 マイコンと通信する。解錠する場合と施錠する場合で呼び出す IFTTT API が異なるため、それぞれの処理を実施するための NFC タグを別で計 2 枚準備する。それぞれのアプリケーションの詳細や実装については 4.2 節にて後述することとする。

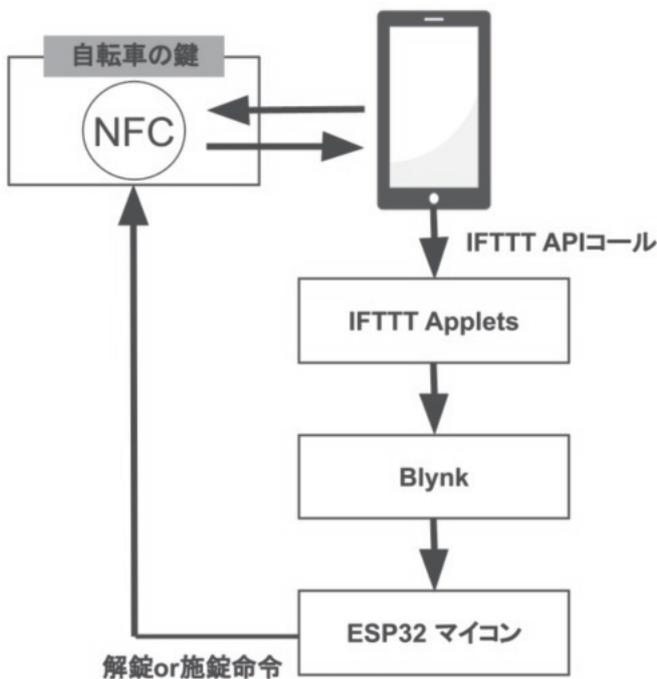


図5 NFC認証をベースとしたスマートロックの概要図

### 3.2 指紋による認証

指紋による認証をベースとした自転車のスマートロックシステムの概要を図6に示す。多くの指紋認証センサーにおけるセンサーモジュール内部は図6に示すようにセキュアに指紋情報を管理するため、その指紋認証センサーを1つのモジュールとして指紋の登録や保存、認証といった一連の動作が指紋認証センサー内で完結するように組み込まれている。つまり、指紋認証センサーにかざした指の指紋が、既に登録されている指紋かどうかを判定し、その結果のみが戻り値として通信される。そのため、認証結果としてマイコンが指紋認証センサーから受け取る値は真偽値のみであるため、生体認証情報の漏洩リスクに関してはある程度担保されている。

ESP32 マイコンの解錠処理では、指紋認証センサーから取得した真偽値を元に自転車の鍵に組み込まれたサーボモータを回転させて解錠するか否かを処理する。3.1節にて前述した通り、NFCによる認証を行う場合は解錠する場合と施錠する場合でそれぞれの NFC タグを用意し、処理を分けることができていたが、指紋による認証の場合、1つの指紋認証センサーで解錠処理と施錠処理を分けることができず、また、それぞれの処理のために2つ準備することも現実的ではないため、時間差でサーボモータが元の位置に戻り、いつでも施錠することができる状態となる。

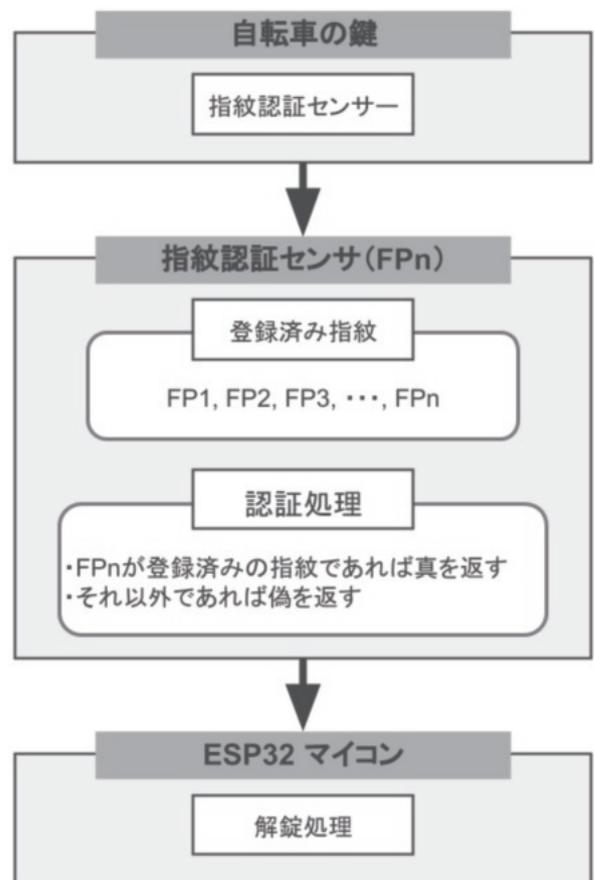


図6 指紋認証をベースとしたスマートロックの概要図

## 4. 実装

本研究におけるプロトタイプの実装については、ハードウェアとソフトウェアのそれぞれについて切り分けて実装する。ハードウェアにおいては自転車の鍵をスマートロックとして解錠・施錠の最低限の動作の確認ができるベースを構築する。ソフトウェアにおいては2種類の認証手法を実装し、それぞれ解錠・施錠の処理が実行できるよう構築する。全体として、極力拡張性を持たせた自転車の鍵におけるスマートロックのプロ

トタイプとなるよう構築する。

#### 4.1 ハードウェア

3.章でも述べた通り、一般的な自転車に標準装備されているシリンダー式のリング錠をベースとして、ESP32 マイコンやサーボモーターを組み込み、スマートロックを構築する。NFC による認証と指紋による認証はそれぞれ構築したスマートロックの右上に NFC タグや指紋認証センサーを組み込み、解錠するためのトリガーとする。ハードウェア全体としてのプロトタイプは図7のようになる。図7では認証手法に NFC を用いた場合の様子であるため、スマートロックの右上に NFC タグを組み込んでいるが、認証手法に指紋認証を用いる場合は図7で NFC タグが組み込まれている部分を指紋認証センサに置き換えれば良い。

この自転車のスマートキーを解錠させる仕組みとしては、マイコンで制御されたサーボモーターの回転数によって物理的に鍵を回転させる手順となる。この際にサーボモーターのトルクを無駄なく鍵の回転に利用するため、1立方センチメートル程度の大きさの木材を支柱として鍵に対して対角線上に取り付ける。このようにすることでサーボモーターの回転を間接的に利用することができる。



図7 スマートロックのハードウェア全体像

#### 4.2 ソフトウェア

ソフトウェアの実装については、NFC による認証と指紋による認証で異なるため、それぞれについて言及する。

まず、NFC 認証の場合のソフトウェアの実装については、3つの外部アプリケーションを利用して構築する。

1つ目は、Web アプリケーションや Android/iOS アプリケーションを用いて電子機器を遠隔操作することができる IoT プラットフォーム「Blynk」である。Blynk のアプリケーション上で、遠隔操作する対象となるデバイスを追加する必要があるため、ここでは ESP32 マイコンを対象デバイスとして追加し、接続方法は Wi-Fi として設定する。続いて、実際に Blynk プロジェクトを構築するため、提供されている Button ウィジェットを画面に追加し、そのウィジェットに対するピン番号を V0 として設定する。設定完了後の Blynk プロジェクト画面は図8のようになる。設定後発行されるトークンと Blynk-TEMPLATE-ID、Blynk-DEVICE-NAME を ESP32 マイコンに書き込むプログラムで指定することで ESP32 マイコンと Blynk との双方向通信が可能となり、遠隔で操作できるようになる。

2つ目は、IoT 機器と Web アプリケーションとの連携を自動化できるアプレットを備えたトリガーアクションプログラミングプラットフォームである「IFTTT」である。本研究で構築する IFTTT のアプレットでは、Web リクエストによって様々なトリガーアクションを指定することのできる Webhooks をサービスとして選択して作成する。なお、解錠する場合と施錠する場合で実行する Web リクエストが異なるため、それぞれ別のアプレットを作成する。IFTTT 上で作成したアプレットは図9のようになる。図9の「If」の部分ではアプレットが実行されるためのトリガーとなる Webhooks を設定する。このトリガーは、スマートフォンを NFC をタグにかざした際に発火し、ウェブリクエストを受け取ることとなる。続いて、図9の「Then」の部分ではアクションとして「Make a web request」を選択肢の中から選択し、Blynk に対して呼び出す API リクエストのメソッドとエンドポイントとなる URL を設定する。エンドポイントに関しては、Blynk プロジェクトのリージョンコード、Auth Token、ピン番号をパラメータとして指定する必要がある。解錠を行う場合については、Blynk のクラウドサービスの特定のリージョンコードを含む API エンドポイントに対して、認証トークンとピン番号をパラメータとして含めたリクエストを送信する。具体的には、ピン番号を 1 に設定した状態でリクエスト実行する。一方で、施錠を行う場合については、同じ API エンドポイントに対して、ピン番号を 0 に設定してリクエストを送信する。

3つ目は、iOS スマートフォンにデフォルトでインストールされている Shortcuts application を用いる。今回の実装においては iOS が搭載されているスマートフォンを用いているため Shortcuts application を用いるが、Android OS が搭載されているスマートフォンの場合は

この限りではない。ここではオートメーションを作成し、トリガーとなる特定の NFC タグと実行される処理を紐付ける設定を行う。オートメーションでは主に 3 つのアクションを指定する。1 つ目のアクションでは「Text」を選択し、前述した IFTTT アプレットを実行するための API エンドポイントとなる URL を設定する。

一方で、指紋による認証を用いたソフトウェアの実装については外部アプリケーションを利用せずに指紋認証センサーを用いてネットワークに接続しなくても動作確認ができる状態を構築する。制御方法の概要については図 6 にて示した通りであるが、ここではより具体的に説明を加える。

NFC 認証を利用したスマートロックの実装との差分は指紋認証センサとその配線にあるためそれぞれについて説明する。指紋認証センサーは光学式指紋認証センサーモジュール (ZFM-70 シリーズ) を用いて、センサーの 5V と GND の配線についてはマイコンの該当する 5V ピンと接地ピンに接続する。センサーの受信コード (Rx) と送信コード (Tx) についてはマイコンの任意のピン番号に接続する。なお、本実装についてはそれぞれ 19 番ピンと 18 番ピンに接続する。マイコンに書き込むプログラムについては主に指紋の入力・認証処理・モーター回転命令出力の 3 つに大別される。また、それらとは別に予め指紋登録用のプログラムを書き込むことによって指紋認証センサー上に認証するための指紋情報を登録する。

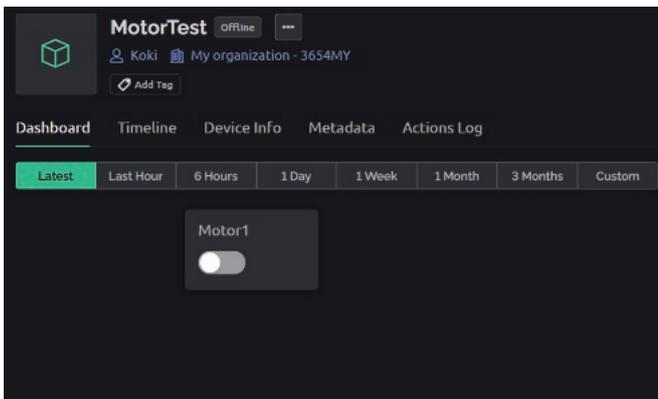


図 8 Blynk プロジェクト作成画面

## 5. 考察

ハードウェアについては、サーボモーターと一般的な自転車に標準装備されているシリンダー式のリング錠をベースとして構築し、その上に NFC タグや指紋認証センサーを組み込み、解錠と施錠を制御するためのスマートキーのプロトタイプを作成した。認証手法に

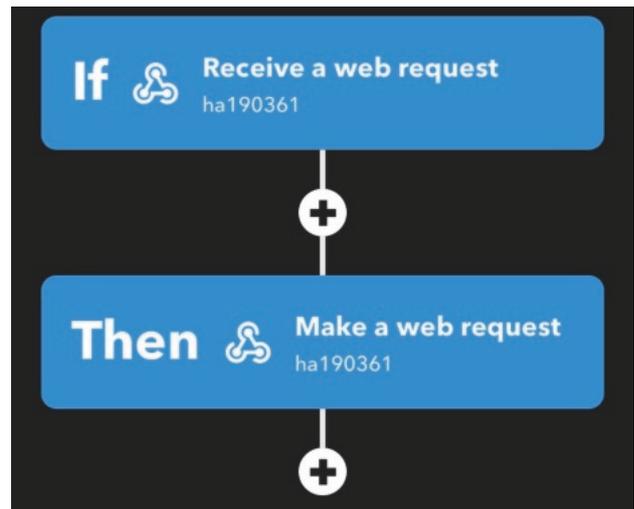


図 9 IFTTT を用いて作成したアプレット全体像

ついて、NFC 認証と指紋認証の異なる 2 つの手法を組み込む試みに対して、サーボモーターとシリンダー式リング錠をベースとした同一のハードウェアを用いて大抵の部分を実装することができた点はハードウェアとしてのプロトタイプの拡張性の面において評価できるポイントであると考えられる。一方で、物理的な破損リスクに対してのリスクヘッジや、シリンダー式リング錠ではないタイプの自転車鍵に対しての拡張性についてはまだまだ課題が残る。

ソフトウェアについて、NFC を用いた制御では主に iPhone の Shortcuts application, Blynk, IFTTT のアプリケーションを組み合わせ、ローカル環境で施錠と解錠を行うためのシステムを構築した。ローカル環境に限定されてはいるものの、スマートフォンを NFC タグにかざすことによりシームレスに解錠と施錠を行うことができたため、実際に利用する際にはストレスなく利用できる状態であると期待される。しかし、様々なアプリケーションを経由して操作を実行しているため、冗長的になっている可能性もある。利用しているアプリケーションに依存したシステム構成となっているため、それらの接続が不安定であったり、サービスが停止してしまうと、本システムが成り立たない可能性も示唆される。実際にソフトウェアを構築する中で、利用したソフトウェアの 1 つである IFTTT がシステムダウンし、アプレットを作成することができなかった期間があった。システムが冗長的になるとそのようなリスクも考慮しなければなくなるため、よりシンプルな構築方法も検討していくべきであると考えられる。加えて、NFC タグについても、施錠と解錠でタグを分離している点が冗長的であると考えられる。1 つの NFC のタグで 2 つの操作を区別しているようなシステム構成についても検

討していくべきである。また、4.2節でも紹介したとおり、ESP32の接続方法を「Wi-Fi」と設定しているが、サービスとして運用する場合について考えると、Wi-Fiの無い環境下での利用の方が多くが想定されるため、IoT向けのSIMカードを用いた通信についても将来的には検討しなければならない。

指紋認証を用いた制御ではスマートロックの認証システムとしての一連の流れやユーザーに価値提供できる最小限のプロダクトとなり得る軸としてのシステムを構築することはできたものの、認証に関しては予め設定されたごく限られたユーザーにしか利用することができず、サービスとして機能するための拡張性の面では多くの課題が残る状態である。

## 6. まとめ

個人が所有している自転車を共有するための新たなシェアサイクルサービスについて提案し、サービス実現のためのシステムのプロトタイプ的设计と実装を試みた。本プロトタイプでは、NFC認証と指紋認証の2つの認証手法を用いてハードウェアとソフトウェアの面からアプローチした。ハードウェアについては、NFCタグを用いた場合でも、指紋認証センサーを用いた場合でも解錠・施錠処理を実行可能とするベースを、主にサーボモーターとマイコンを組み込んで構築することができた。自転車の鍵として一般的に用いられているシリンダー式のリング錠の上に組み込んだ簡易的なスマートロックとなったが、認証結果によって解錠・施錠処理を確認する手段としては十分な役割を果たす。ソフトウェアについては、NFC認証を実装した場合と指紋認証を実装した場合とで実装プロセスが、ハードウェアの実装プロセスと比較すると大きく異なるため、それぞれについて順を追ってまとめ、ハードウェアと連携して解錠・施錠動作を実行するフェーズまで構築することができた。全体を通して、NFC認証と指紋認証の2つの手法それぞれでスマートロックの解錠・施錠処理を実行できるプロトタイプを構築することができたものの、実行環境がローカル環境である点や、特定のユーザーのみに対しての施錠・解錠処理を実装している点から、より広範な物理的範囲において不特定多数の想定されるユーザーからのアクセスを正確に制御できるのかといった観点についての実現可能性については不確実である。

ハードウェアにおける今後の課題としては、不確実性を極力排除し、より洗練されたプロトタイプとしてのシステムの構築を目指す上ではソフトウェア上で動作確認・テストすることのできるシミュレーターを利

用した実装のアプローチも選択肢の1つとして考慮する必要がある。プロトタイプではなく、実際にハードウェアとして洗練されたスマートロックの構築を目指す上では3DCADのソフトウェアと利用して自転車の鍵がむき出しにならないような、セキュリティー面を考慮したハードウェアを作成する必要がある。また、本研究における実装で用いたリング状の自転車の鍵だけでなく、ワイヤー上の自転車の鍵を用いた解錠・施錠の方法についての検討も課題の1つとして挙げられる。

ソフトウェアにおける今後の課題として、NFC認証を実装した場合においては、よりシンプルな設計での制御方法を検討したり、1つのNFCタグで施錠と解錠のどちらの操作も実行できるようなシステムを構築したりすることが課題として挙げられる。指紋認証を実装した場合においては、現状、登録した指紋情報を一元管理することができていないシステム構成になっているため、指紋を登録したセンサーとは別のセンサーで認証を試みても許可されない。特定のユーザーのみでなく、不特定多数のユーザーでも安全に認証することができるシステムを構築する必要がある。

## 参考文献

- [1] 北村 舜・鈴木美緒. 非観光都市におけるシェアサイクルの導入動機が利用意向に及ぼす影響に関する研究. 自転車対策審議会資料 No5, 2019.
- [2] シェアサイクルに関する現状と課題 - 国土交通省. <https://www.mlit.go.jp/road/ir/ir-council/sharecycle/pdf01/03.pdf>. (Accessed on 29/1/2024).
- [3] 自転車シェアリング市場は2027年までCAGR14%で大きな成長が見込まれる | Report Ocean のプレスリリース. <https://prtnews.jp/main/html/rd/p/000002329.000067400.html>. (Accessed on 16/1/2024).
- [4] LUUP (ループ) — 電動キックボードシェア/シェアサイクルアプリ — Luup (ループ) — 電動キックボードシェア/シェアサイクルアプリ. <https://luup.sc/>. (Accessed on 17/1/2024).
- [5] バイクシェアサービス | 自転車シェアリング. <https://docomo-cycle.jp/>. (Accessed on 17/1/2024).
- [6] Hussein Ahmad Al-Ofeishat and Mohammad AA Al Rababah. Near field communication (nfc). *Inter-*



## 福井大学学術研究院工学系部門研究紀要編集委員会

橘 拓至	情報・メディア工学講座（紀要編集委員長）		
川井 昌之	機械工学講座	田邊 英彦	電気・電子工学講座
斐 敏廷	建築建設工学講座	入江 聡	材料開発工学講座
寺田 聡	生物応用化学講座	光藤誠太郎	物理工学講座
小高 知宏	知能システム工学講座	平田 豊章	繊維先端工学講座
松尾陽一郎	原子力安全工学講座		

福井大学学術研究院工学系部門研究報告

<http://www.eng.u-fukui.ac.jp/research/memoirs-2/index.html>

福井大学学術研究院工学系部門研究報告 別冊 研究活動一覧

<http://www.eng.u-fukui.ac.jp/research/researchactivities-2/index.html>

国立情報学研究所 論文情報ナビゲータ（福井大学関連）のURL（書誌情報のみ）

<https://ci.nii.ac.jp/ncid/AA12208150>

## 福井大学学術研究院工学系部門研究報告

2024年3月17日 発行

### 福井大学大学院工学研究科

〒910-8507 福井市文京3丁目9-1

電話（0776）27-8016（研究・地域連携推進部研究推進課）

印刷所 能登印刷株式会社

