

# 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

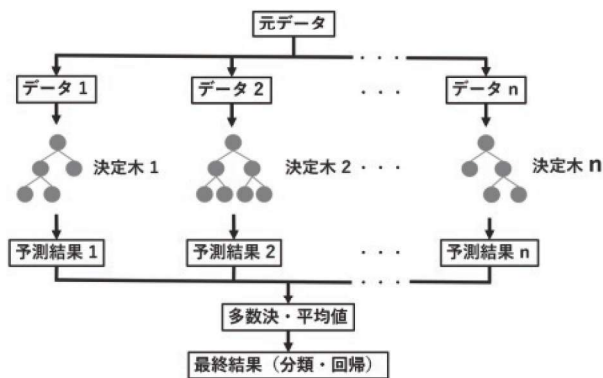


図1 ランダムフォレストの概略図

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．また決定木の数を増やす，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の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

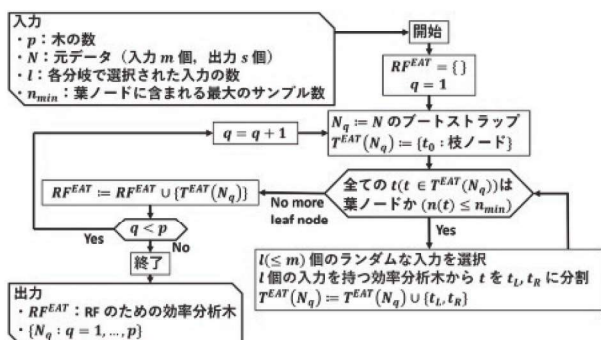


図2 ランダムフォレストのアルゴリズム



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

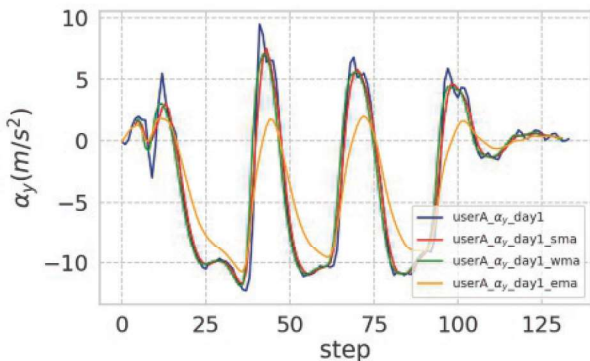


図3 移動平均処理前後の  $y$  軸方向加速度（ユーザ A）

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

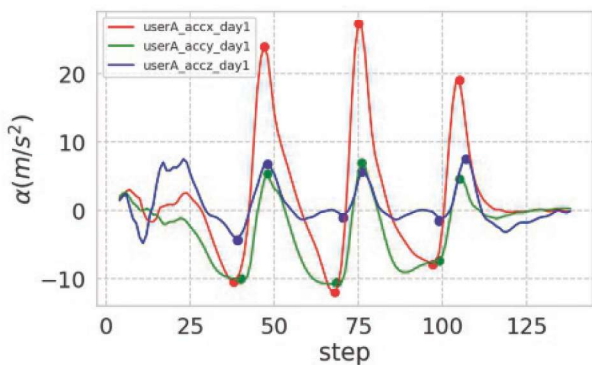


図 4 3 軸加速度データにおける特徴点抽出 (ユーザ A)

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)

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.