

# 暗証番号入力時の腕の加速度を用いた携帯端末向け個人認証

味岡孝昇<sup>†1</sup> 梅澤猛<sup>†1</sup> 大澤範高<sup>†1</sup>

**概要:** 携帯端末上で暗証番号 (PIN: Personal Identification Number) を入力して認証する際に, 入力動作中の腕の加速度を測定して特徴ベクトルを抽出し, 機械学習によって個人識別を行う手法を提案する. 入力動作自体を認証の一要素とするため, ユーザの操作負担を増やすことなく安全性の高い多要素認証を実現することができる. 手首に無線小型加速度センサを装着した被験者 10 人による評価実験を行い, 4 桁の PIN をタップ入力する際の腕の加速度を計測し, 特徴ベクトルを抽出して本人/他人の識別を行った. サポートベクターマシンおよびランダムフォレストによる識別を行ったところ, どちらのアルゴリズムでも他人受入率 (FAR) と本人拒否率 (FRR) を共に 3.1% 以下にすることができた. 比較のために行った, 動的時間伸縮法によって相違度を求めて閾値判定する手法では, FAR=3.1% において, FRR=62.8% であったことから, 提案手法を用いることでより良好な結果を得ることができた.

**キーワード:** 行動的特徴, 機械学習, 多要素認証, 加速度センサ, ウェアラブルデバイス

## Authentication Method for Mobile Device using Wrist Acceleration during Unlock Operation

Takanori Ajioka<sup>†1</sup> Takeshi Umezawa<sup>†1</sup> Noritaka Osawa<sup>†1</sup>

### 1. はじめに

スマートフォンやタブレットなどの携帯端末では, 通話やメールなど基本的な機能以外にも様々なアプリケーションを利用するため, 端末内に保存される写真, 動画, スケジュール, SNS (Social Network Service) へのアクセス権などプライバシーに関わる重要な情報を保護するためにロックによる使用制限を行うことが一般的である. セキュリティやプライバシー保護の観点から, 他人による不正なロック解除を防ぐことは重要な課題である.

現在ロック解除に用いられている方式は, 暗証番号 (PIN: Personal Identification Number), パスワード, Android パターンロック<sup>a</sup> など知識認証によるものが一般的である. しかし, 電車内や街頭のように衆人の中でロック解除を行う機会が多いことを考慮すると, キーボードの種類や入力方法により程度に差はあるが, 他人によるショルダーハックの危険性がある[1]. 知識認証に代わる方式としては, 指紋認証や顔認証などの生体認証が挙げられるが, グミで偽造した人工指[2]や, 睡眠中の正規ユーザの指[3]を認証装置に読み取らせてロックを解除する事例が報告されている.

他人による不正なロック解除を困難にするには, 異なる複数の要素の照合による多要素認証が有効であるとされる[4]. 一方で, 認証に用いる要素が増えることでユーザの操作負担が大きくなることを避けることが課題となる.

そこで本研究では, 知識認証によるロック解除の動作にはユーザ毎に特有の特徴が含まれると仮定し, 操作負担を

増やすことなく多要素認証を実現する手法を提案する. 本稿では, 特にロック解除時の動作から個人識別に利用できる特徴量を取り出す手法について述べる.

### 2. 関連研究

#### 2.1 認証システムの評価指標

認証システムにおける個人識別の精度は, 他人受入率 (FAR: False Accept Rate), 本人拒否率 (FRR: False Rejection Rate), 等誤り率 (EER: Equal Error Rate) で評価される. FAR は他人を本人であると誤る確率であり, FRR は反対に本人を他人であると誤る確率である. EER は FAR と FRR の値が等しくなる判定基準における FAR および FRR の値である. EER の値が低いほど識別精度が高いことを示す.

#### 2.2 日常的で簡便な動作による個人識別

スマートフォンやウェアラブルデバイスに内蔵された様々なセンサを利用して, 加速度や角加速度などの計測データを駆使して個人識別を行う手法が提案されている.

奥村らは, 携帯端末を把持した状態で腕を複数回振った際の加速度データを利用して個人識別を行う手法を提案している[5]. 腕を振るときには, 振りの方向に個人の特徴が顕著に出ると考え, 振り動作の中心から見た 2 つの加速度データのなす角として「誤差角」を計算し, 閾値により個人識別を行っている. 閾値判定は Dynamic Programming (DP) マッチングにより求めた相違度により行い, 識別精度は最良で EER=5.0% である.

Derawi らは, 歩容の特徴に注目した個人識別手法を提案している[6]. 服のポケットに入れた加速度センサで計測したデータを歩容の特徴とし, DP マッチングを用いて照合することで個人を識別している. 被験者 51 名を識別する実

<sup>†1</sup> 千葉大学大学院 融合科学研究科  
Chiba University Graduate School of Advanced Integration Science.

<sup>a</sup> タッチパネル上の複数の点をなぞって出来上がる形状を照合してロックを解除する方式.

験において EER=20%である。

両手法において、ユーザに要求される動作は日常的で簡便なものであるため操作負担は小さいが、認証の誤り率が高い。FAR と FRR は設定する閾値に依存して変化するが、一般にトレードオフの関係にある。そのため、安全性を重視して FAR が低くなるような閾値を設定すると、FRR が高くなり、認証操作をやり直す回数が増えてユーザの負担が大きくなる。したがって、操作負担を抑えるためには FRR が低くなるように設定する必要があるが、FAR が高くなり他人にロック解除されてしまう危険性が生じるという課題が残る。そこで、本研究では動作単体ではなく、知識認証と組み合わせることで安全性を確保する。

### 2.3 端末の操作時に得られる特徴を用いた個人識別

竹内らは、フリック入力時に得られる特徴を用いて個人識別を行っている[7]。タッチパネルで指の X, Y 軸方向の変位と速度、画面への接触時間を、3 軸加速度センサでタッチパネルに接触した時および離れた時の指の 3 軸それぞれの方向の加速度を計測し、合わせて 11 の特徴量を用いている。被験者 10 人を識別する実験において、FAR と FRR 共にほぼ 0% の良好な結果を示した被験者がいる一方で、FRR=20% に対して FAR=30% と識別困難な被験者もいた。

Luca らは、Android のパターンロックをなぞる際に、端末のタッチパネルから得られる時系列データ (X 座標, Y 座標, 圧力, タッチ面積, 速度) を用いて個人を識別する手法を提案している[8]。被験者 31 人を対象とした実験では、計 645 件の本人データと計 2790 件の他人データを DP マッチングにより識別したところ、FAR=21%, FRR=19% であった。なお、本人データは 1 日 1 件の計測を 21 日間繰り返して集められたものである。

これらの手法は、端末に入力を行う際の特徴をタッチパネルから得るため、入力内容による知識認証と組み合わせることが容易であり、安全性の高い多要素認証とすることが可能である。また、端末への入力動作から特徴量を得て個人識別をするため、ユーザは多要素認証のためにさらに他の操作をする必要がなく、操作負担が増大しない。

しかし、これらの研究で利用している特徴量は、端末自体から取得できるもののみにとどまっている。[5]や[6]で示されているように、動作時における身体部位の加速度は、識別において有効な特徴量であると考えられる。また、一般的に特徴量は多いほど、識別精度は高くなると考えられる。そこで、本研究では入力動作時の腕の加速度を特徴量として利用することを考える。

### 3. 提案手法

本研究では、ユーザの操作負担を増やすことなく、知識認証の安全性を向上させるために、携帯端末に PIN を入力する際の動作から個人を識別できる特徴量を取り出して認

証を行う方法を提案する。

PIN を入力する際の動作における特徴は、手首に装着した無線小型センサと携帯端末本体で加速度や角加速度などを計測することで得ることを想定する。リストバンドや指輪などの形状をしたウェアラブル端末が普及し始めており、腕の動きを計測できるという前提は実用上妥当なものであると考える。また、これらの機器は軽量かつ小型であるため、装着はユーザの負担とはならないと考えられる。

計測したデータから表 1 に示す 29 の特徴量を要素とする特徴ベクトルを算出し、Support Vector Machine (SVM) や Random Forest (RF) などの機械学習によって本人かどうかを識別する。ここで、X, Y, Z の 3 軸は加速度センサから見た方向に定める。また、A は  $A = \sqrt{X^2 + Y^2 + Z^2}$  として計算される加速度ベクトルの長さである。

SVM は汎化能力の高い 2 値分類のアルゴリズムとして知られており、また、特徴ベクトルの次元数が大きい場合でも識別精度が高いため、本研究で扱う識別問題に適していると考えられる。RF はアンサンブル学習の 1 つであり、1 つの決定木を作るときに特徴量をランダムに選択することでノイズの影響を小さくしている。また、Out-Of-Bag データを使って特徴量の重要度を計算することができる。腕の加速度から抽出した特徴量のうち、識別においてどのような特徴量が重要であるかは不明であり、また、ノイズとなってしまう特徴量が含まれてしまう可能性もあるため、RF のこれらの特徴は本研究において有用であると考えられる。

なお、機械学習では、より識別精度の高いモデルを構築するために多くの学習データを必要とするが、ロック解除の動作は携帯端末を利用する際に毎回行われるため、学習データの収集は容易であると考えられる。

### 4. 実験

提案する手法の識別精度を評価するため、被験者による個人識別実験を行った。従来手法として、ジェスチャ認識に用いられている DP マッチングによる識別も行い、提案手法による結果と比較評価した。

また、経時変化によって生じる動作の変化が識別誤りに

表 1 特徴ベクトルの要素一覧

No.	特徴量
1-4	平均値 (X, Y, Z 軸 および A)
5-8	分散値 (X, Y, Z 軸 および A)
9-12	RMS (X, Y, Z 軸 および A)
13-16	最大値 (X, Y, Z 軸 および A)
17-20	最小値 (X, Y, Z 軸 および A)
21-24	ピークピーク値 (X, Y, Z 軸 および A)
25-28	中央値 (X, Y, Z 軸 および A)
29	動作時間 (=サンプリング数)

与える影響を評価するため、6日空けた後に同じ動作を計測して評価用データを作成し、同様の識別実験を行った。

なお、本実験においては4桁のPINを入力する状況を想定し、PINを入力する際のタップ動作を計測の対象とした。

#### 4.1 実験環境

実験に用いたPIN入力をシミュレートするアプリケーションの外観を図1に示す。ユーザは、数字キーをタップすることで対応した番号を入力することができる。1回のタスクは、STARTボタンをタップしてからPINを入力し、FINISHボタンをタップするまでとした。

被験者は22~24歳の男子学生10名で、全員が右利きであり、スマートフォンやタブレット端末などのタッチパネルを備えた機器を日常的に利用している。被験者は椅子に座った状態で片方の手で端末を把持し、もう片方の手でPINを入力することとした。入力の際は、椅子のひじ掛けや背もたれに身体が触れない姿勢をとるように指示をした。

腕の加速度パターンを多く採集することを狙い、入力するPINは「4628」とした。これらの数字は、数字キーエリアの上下左右に配置されており、入力動作には縦、横、斜めの各方向の動きが含まれる。

ATR-Promotions製の小型無線多機能センサTSND121[9]を入力する方の手首にベルト状の面ファスナーを用いて固定し、計測周期は10ミリ秒とした。TSND121の仕様を表2に、装着時の様子を図2に示す。PIN入力は、7インチの



図1 実験用アプリケーションのスクリーンショット

表2 無線加速度センサの仕様 ([9]より引用)

外形寸法	: 37mm(W), 46mm(H), 12mm(D)
重さ	: 約 22g
CPU	: ルネサステクノロジ RX621
無線送信	: Bluetooth Ver2.0+EDR Class2
搭載加速度センサ	: InvenSense MPU-9250
加速度レンジ	: ±2G/±4G/±8G/±16G
サンプリングレート	: 最大 1000Hz




図2 加速度センサを装着した様子

Android タブレット Nexus7(2012)上に実装した計測用アプリケーションを使って行った。

#### 4.2 条件

タップ動作の速度や強弱の影響を調べるために、被験者に対して素早く弱めに(QW: quickly and weakly)と、遅く強めに(SS: slowly and strongly)の2つの条件でタップをするように指示した。また、タップする指の違いによる影響の有無を調べるために、人差し指のみ(IF: index finger)と、指定なし(AF: any finger)の2通りの条件でタップをするよう指示した。ただし、AFの選択条件においては人差し指のみのタップとはならないよう指示した。以上の条件を組み合わせ、表3に示す計4通りの条件で被験者によるタップ動作を計測した。

#### 4.3 手順

被験者には、次の5項目の動作を1回分の入力タスクとして指示した。

- (i) STARTボタンをタップする
- (ii) 腕を動かさずに空中で2秒間静止する
- (iii) 4桁のPINを入力する
- (iv) 腕を動かさずに空中で2秒間静止する
- (v) FINISHボタンをタップする

個人判別に用いる特徴量を抽出するのは、(iii)の動作のみを対象とする。このタスクを18回連続で試行することを1セッションとし、4つの実験条件を1セッションずつ行うことを1セットとして計測を行った。さらに、経時変化による動作特徴の変化の有無を調べるために、6日以上の間隔を空けて同様に1セット分の計測を行った。また、実験条件の順序は、被験者ごと計測日ごとにランダムに決定した。被験者には4つの条件に従ったタップを使い分けられるよう事前に説明を行い、必要に応じてタップ入力の練習を行った。

表3 実験条件の一覧

	IF	AF
QW	QW_IF	QW_AF
SS	SS_IF	SS_AF

#### 4.4 モデル構築

全被験者の加速度データを計測した後、それぞれの被験者ごとに対応するデータセットを用意した。データセット中の各データには、表 1 に示した 29 の要素からなる特徴ベクトルに加え、「本人」または「他人」のラベル付けを行った。「他人」のラベルを付けたデータは、10 被験者のうち本人以外の 9 被験者によるデータで構成した。

オリジナルのデータセットでは本人データと他人データの構成割合は 1:9 であり不均衡であるため、件数の少ない本人データが件数の多い他人データへと誤分類されてしまう可能性が高くなるモデルを構築してしまう恐れがある。そこで、この問題を解消するために、実際にモデルの構築を行う前には SMOTE アルゴリズムを使用し[10]、本人データをオーバーサンプリングして、他人データをダウンサンプリングすることで、データセットの件数に均衡性を持たせた。SMOTE 処理後のデータ件数は、本人データが 54 件で他人データが 72 件である。このうち半数のデータをモデル構築用のデータとして利用した。

SVM のアルゴリズムを実装したプログラムには、R のパッケージとして公開されているものを利用した[11]。また、カーネルには、汎用的で設定を要するパラメータの数も少ない RBF(radial basis function)カーネルを用いた。RBF カーネル関数は次の式で表される。

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2)$$

ここで、 $\mathbf{x}$  と  $\mathbf{x}'$  はそれぞれ、元の特徴空間上における 2 点を表し、 $\gamma$  はこちらが設定するパラメータである。このパラメータ  $\gamma$  と、誤分類が発生したときのペナルティ  $C$  の 2 変数は、グリッドサーチを利用して最適化した。

RF のアルゴリズムを実装したプログラムにも、同様に R のパッケージとして公開されているものを利用した[12]。RF のパラメータには、決定木を作成するとき使用する特徴量の数  $mtry$  と決定木の数を表すパラメータの  $ntree$  がある。 $mtry$  はグリッドサーチにより最適化し、 $ntree$  はデフォルト値の 500 とした。

#### 4.5 実験 1

提案手法の識別性能を評価するため、4.4 節で述べたように構築した SVM および RF のモデルを用いて本人と他人の識別を行った。なお、評価用のデータにはモデルの構築に利用していない残りの半数のデータを利用した。

提案手法との比較のために、DP マッチングによる識別手法も行った。DP マッチングでは、まず、本人データのうち 1 件をテンプレートデータとして登録し、それ以外の本人データおよび他人データとの 2 データ間の相違度  $D$  を求めた。次に、 $D$  の値が判定閾値  $T$  以下であれば本人、 $T$  より大きい場合は他人と判定した。閾値  $T$  の値を変動させ、各閾値での FAR および FRR を求めて識別性能を評価した。なお、今回の実験ではテンプレートデータとしては最初の

1 件目のデータを使用した。

#### 4.6 実験 2

6 日後に計測したデータを評価用のデータとして用い、実験 1 で使用したものと同一モデルで識別を行い、識別モデルの経時変化に対する頑健性を評価した。また、RF での識別においては Out-Of-Bag データを使って特徴量の重要度を計算した。

### 5. 実験結果と考察

#### 5.1 実験 1

全ての実験条件における、被験者 10 人の FAR と FRR の平均値を図 3 に示す。図中のエラーバーは標準偏差である。FAR と FRR は次の式により求まる値とする。なお、FA(False Acceptance)、FR(False Rejection)、TA(True Acceptance)、TR(True Rejection)は表 4 に該当する各データ件数である。

$$FAR = \frac{FA}{FA + TR}, \quad FRR = \frac{FR}{FR + TA}$$

図 3 に示す通り、全ての実験条件において、FAR は 3.10% 以下となった。加えて、FRR は 2.10% 以下の値となった。これより、PIN の入力動作時に計測した腕の加速度データより抽出した特徴量は個人識別に寄与すると考えられる。また、SVM や RF などの機械学習で個人識別をする本手法は有効であると考えられる。なお、この実験においては条件の違いや機械学習アルゴリズムの違いによって誤り率に大きな差は現れなかった。

DP マッチングによる識別手法の結果として、閾値  $T$  の値を変化させていき、縦軸に FAR の値を、横軸に FRR の値をとってプロットすることで描ける DET 曲線(detection error trade-off curve)を図 4 に示す。DET 曲線では FAR と FRR が同時に低い値にプロットされるほど、つまり曲線が左下側に寄るほど誤り率が低いということが判断できる。

比較のため、図 4 には、SVM と RF で評価用データを分類した際の FAR 値と FRR 値も示す。図 4 を見ると、SVM と RF の誤り率を示す点が、2 つとも DET 曲線より左下にあることが分かる。また、各実験条件において FAR=3.1% のときにおける FRR 値を求めたところ、平均で 62.8% となった。したがって、DP マッチングを利用した個人識別手法よりも、SVM や RF などの機械学習を利用した提案手法のほうが高い識別性能であると言える。

表 4 分類データの名称

		実際のクラス	
		本人	他人
予測した クラス	本人	TA	FA
	他人	FR	TR

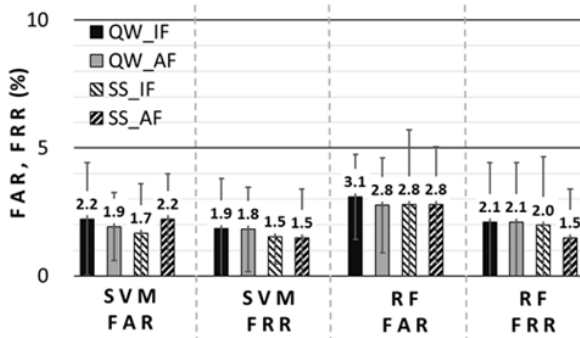


図 3 被験者 10 人の FAR, FRR (実験 1)




図 5 被験者 10 人の FAR, FRR (実験 2)

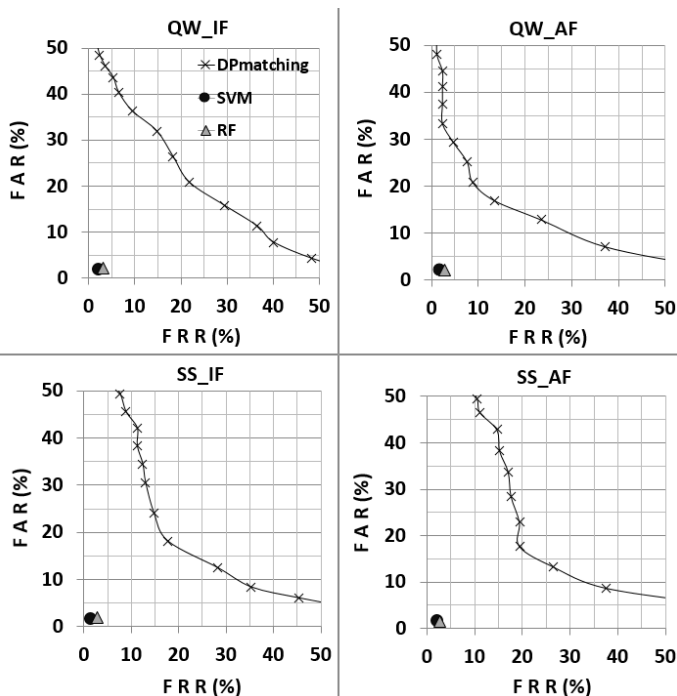


図 4 機械学習と DP マッチングの比較

## 5.2 実験 2

全ての実験条件における、被験者 10 人の FAR と FRR の平均値を図 5 に示す。図 5 において、全ての実験条件について 46.7~83.5 パーセントポイントと大幅な FRR の上昇がみられる。

この結果より、時間が経ってしまうと過去の動作とのずれが大きくなってしまい、本人データを正しく識別することが困難になっていると考えられる。

また、FRR が上昇した原因としては、実験時のデータの計測の方法に問題があった可能性がある。今回の実験では、1セッションの計測を行うとき、被験者は 18 回のタスクを、タブレット端末を持ち直したり腕を休めたりすることなく、連続で行った。そのため、同じ計測日のデータ間ではばらつきが非常に小さくなってしまい、識別モデルもこれらのデータの識別問題にのみ適応したものが構築されてしまったと考えられる。この影響を除去するためには、1 回のタスクごとに腕を休めて計測を行うことで同じ日の計測データの分布が密集しすぎないようにすることや、モデル構築


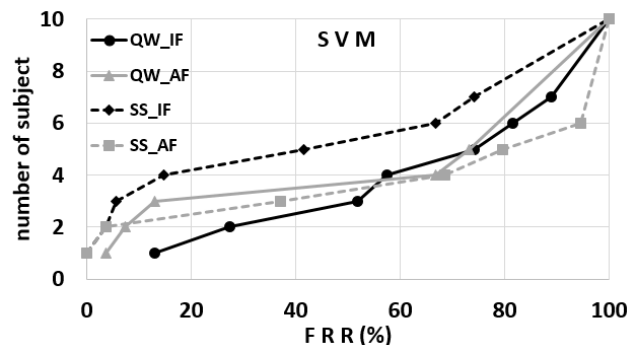


図 6 FRR の累積度数 (実験 2)

には数日間をわたって計測したデータを学習データとして利用することなどが必要であると考えられる。

さらに、今回の実験では、3 軸の加速度値を加速度センサからみた座標系の軸で定めていたため、動作自体は大して変わっていても、端末を把持する角度やタップをする腕の角度、もしくはセンサの装着位置がずれたことで、加速度値が大きく変わってしまい、FRR が大きく上昇した可能性がある。今後は、センサの向きによって腕の加速度値が依存しないように、加速度センサの出力値を絶対座標系に直す必要がある。また、もしくは、両手の動作においては、非利き手で座標系を定め、利き手で細かな動きをするという連動の性質が見られるため[13]、端末からみた座標系に変換することも有効であると考えられる。

RF を利用した識別時に、4 つの実験条件それぞれにおいて FRR が良好であった上位 5 人の被験者について、どの特徴量が重要であったのか調査した。すると、SS の条件においては動作時間の重要度が高いことが分かった。動作時間は、表 1 に示した 29 個中の重要度の順位において、QW\_IF

では 20 位, QW\_NS では 17 位であったのに対し, SS\_IF と SS\_NS では, 共に 1 位であった. SS の動作については「ゆっくり」という指示を被験者にしたが, 具体的な時間や動作例などは詳しく説明していない. そうしたところ, 目で見て分かるほどに, 被験者ごとに「ゆっくり」に対する加減が異なっていた. そのため, 識別に大きく寄与した特徴量とされたのだと思われる. ただし, この差異は目で見て分かるほどの違いであったので, 模倣されやすい危険性もある. 実際に動作の模倣に対して頑健かを検証するため, ロック解除の様子を撮影した映像を見た他者が動作を真似た場合の FAR を調査する必要がある.

FRR に関しては, SVM と RF のどちらにおいても SS\_IF の条件における平均値が最も低くなった. また, 被験者数で見ても, SS\_IF の条件における FRR が最も低くなった日検者は 10 人中 5 人であり, 4 つの実験条件の中では最多であった. これより, ゆっくり強めのタップは, 素早い弱めのタップに比べて安定しており, 時間の経過によって動作が大ききずれないと考えられる. また同様に, タップに使用する指を被験者が任意で選ぶよりは, 使用する指を限定したほうが動作のずれは小さくになると考えられる.

図 6 は実験 2 おける FRR の累積度数を示している. QW の条件では FRR=0% となる被験者がのべ 0 人であるのに対して, SS の条件では FRR=0% となる被験者はのべ 7 人である. QW と SS の条件でこの差が見られたのは, 前述したとおり, ゆっくり強めのタップは, 素早い弱めのタップより安定しているためであると考えられる. しかし, 本実験では被験者数が 10 人と少ないため, より被験者数を増やした実験をして確認する必要がある.

## 6. まとめ

本研究では, 知識認証の安全性を確保する目的で, 携帯端末のロック解除動作時に計測した腕の加速度による個人識別を行うことを提案した. また, SVM や RF などの機械学習を利用する個人識別の手法を提案した. 提案手法の評価のために, PIN 入力の動作時に計測した加速度データより特徴量を抽出して, SVM および RF で構築したモデルで本人/他人の識別を行った. 実験の結果, PIN 入力動作時の腕の加速度データより抽出した特徴量は, 個人識別に寄与することが分かった. また, SVM や RF による識別では FAR と FRR は共に 3.1% 以下となり, DP マッチングによる識別では, FAR=3.1% において, 平均で FRR=62.8% となったため, 提案手法による識別性能のほうが高いことが示された.

また, 別の実験として, 経時変化による動作の変化が誤り率に与える影響を調査したが, FRR が大幅に上昇してしまうという課題が明らかになった. これは, 時間が経過してしまったことにより本人内の時点間で動作のずれが大きくなってしまったためだと考えられる.

今後は FRR が悪化することを抑制する必要がある. 対策手法としては, モデルの構築段階で学習に使用するデータ構成を更新していくことや, 経時変化の影響を受けにくい特徴量を調査することなどが考えられる.

## 参考文献

- [1] Schaub, F., Deyhle, R., and Weber, M.: Password entry usability and shoulder surfing susceptibility on different smartphone platforms, Proc. 11th International Conference on Mobile and Ubiquitous Multimedia (MUM 2012), Article No. 13 (2012).
- [2] Matsumoto, T., Matsumoto, H., Yamada, K., and Hoshino, S.: Impact of artificial "gummy" fingers on fingerprint systems, Proc. SPIE 4677, *Optical Security and Counterfeit Deterrence Techniques IV*, (2002).
- [3] Constine, J.: Your Nosy Boy/Girlfriend Can Unlock Your iPhone 5S with your Thumb While You Sleep, TechCrunch. <<http://techcrunch.com/2013/09/20/fingerprint-unlock-while-sleeping/>>(参照 2016-11-01)
- [4] O’Gorman, L.: Comparing passwords, tokens, and biometrics for user authentication, *IEEE*, VOL.91, NO.1, pp.2021-2040 (2003)
- [5] Okumura, F., Kubota, A., Hatori, Y., Matsuo, K., Hashimoto, M., and Koike, A.: A study on biometric authentication based on arm sweep action with acceleration sensor, Proc. *International Symposium on Intelligent Signal Processing and Communications (ISPCS 2006)*, pp.219-222 (2006).
- [6] Derawi, M. O., Nickel, C., Bours, P., and Busch, C.: Unobtrusive user-authentication on mobile phones using biometric gait recognition, Proc. *6th International Conference on Intelligent Information Hiding and Multimedia Signal Processing (IIH-MSP 2010)*, pp.306-311 (2010).
- [7] Takeuchi, N., Kobata, S., and Uda, R.: Improvement of personal identification by flick input with acceleration sensor, Proc. *IEEE 38th Annual International Computers, Software and Applications Conference Workshops (COMPSACW 2014)*, pp.276-281 (2014)
- [8] Luca, D. A., Hang, A., Brudy, F., Lindner, C. and Hussmann, H.: Touch me once and I know it’s you! Implicit Authentication based on Touch Screen Pattern, Proc. *ACM SIGCHI Conference on Human Factors in Computing Systems (CHI2012)*, pp.987-996 (2012).
- [9]ATR-Promotions: 小型無線多機能センサ「TSND121/151」 <<http://www.atr-p.com/products/TSND121.html>> (参照 2016-11-01)
- [10] Chawla, N. V., Bowyer, K. W., Hall, O. L., and Kegelmeyer, P. W.: Smote: synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, Vol.16, pp.16321-357 (2002).
- [11]Karatzoglou, A., Smola, A. and Hornik K.: Kernel-based Machine Learning Lab. R package version 0.9-25. <<https://cran.r-project.org/web/packages/kernlab/kernlab.pdf>>(参照 2016-11-01)
- [12] Breiman, L., Cutler, A., Liaw, A., and Wiener, M.: Breiman and Cutler’s Random Forests for Classification and Regression. R package version 4.6-12.<<https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>>(参照 2016-11-01)
- [13] Yves Guiard: Asymmetric Division of Labor in Human Skilled Bimanual Action: The Kinematic Chain as a Model, Slightly edited version of an article originally published in *Journal of Motor Behavior*, 19, pp.486-517 (1987).