

# 個人認証システムのための表面筋電位を用いた ハンドジェスチャ識別

2019SC013 細川千就 2020SC027 伊藤琢真

指導教員：石原靖哲

## 1 はじめに

近年、ネットワーク社会の進展に伴い、不正アクセスや個人情報漏洩等が度々問題となっている。例として令和4年の不正アクセスは、その前年から684件増加しており、不正アクセスの検挙件数の内、パスワード盗用によるものが全体の90%以上を占めていた[1]。このような不正アクセスを防ぐため、個人認証方式として生体認証が多くの場合で採用されるようになった。生体認証とは、人間の身体的特徴を用いて本人を特定する認証システムのことである。生体認証は、パスワード管理などをする必要がないためユーザの利便性が高く、また人間の身体的特徴を用いるため安全性が高い。加えて認証をスムーズに行えるため、あまり時間を要せず認証が可能といったメリットがある。しかし生体認証も絶対ではない。例えば指紋だと、接触式の指紋センサでしか読み取れない情報が窃盗されてしまう危険性[2]であったり、声紋の場合、録音した音声を再生することで認証システムを突破されてしまうといった危険性[3]がある。以上から、生体認証を使用するメリットはたくさんあるが、一方で扱う生体情報によっては一定のリスクがあることが分かる。しかし、数ある生体情報の中で、筋電位は偽造が困難であり、個人認証の観点で優れている可能性がある。生体情報に筋電位を用いるメリットは他にもある。他の人がなりすまして同じ動作を行ったとしても、そもそも筋電位は、人によって異なる特徴を持っているため認証される心配が比較的少ないことや、異なる動作を組み合わせてパスワード列とすることでさらにセキュリティを強固なものにできることなどが挙げられる。

芝田ら[4]では、ハンドジェスチャ時の筋電位を用いてジェスチャ識別を行い、その識別されたハンドジェスチャをパスワード列とみなすことで個人認証を検討していた。しかし最初の段階であるジェスチャ識別率や本人拒否率、他人受け入れ率等の問題で、実用化に向けた課題が多く挙げられていた。

本研究では、[4]で使われていたSVM(Support Vector Machine)以外の分類方法も考慮し、さらに学習用データにも着目することでジェスチャ識別の評価精度(ジェスチャ識別率や本人拒否率、他人受け入れ率)を向上させ、表面筋電位を用いた個人認証システムの実用性を評価する。

## 2 先行研究

ここでは芝田ら[4]の先行研究を取り上げ、説明する。

### 2.1 システムの概要

芝田らによるシステムの概要は、あらかじめユーザが選択したジェスチャを行った際に発生する筋電位信号データから特徴を抽出し、モバイル端末にその特徴を登録する。そして、ユーザがロックを解除するときに、登録したジェスチャを行い、その際に発生した筋電位信号データをモバイル端末に送信し、その信号の特徴を抽出する。登録しておいた特徴と送信して得られる特徴を比較し、一致していたら認証、不一致だったら拒否するものである。

### 2.2 実験

芝田らの研究では、被験者5人に対して、軽く拳を握った状態を初期状態とし、6パターンのジェスチャの筋電位信号データを測定している。筋電位信号データはサンプリングレート200[Hz]で取得し、筋電位信号の振幅の範囲を-128から127のデジタルデータとして、各ジェスチャ10回分を測定している。

芝田らは、1ジェスチャごとに筋電位信号データを抜き出し、時間領域の特徴量、及び、高速フーリエ変換(Fast Fourier Transform)から得られるパワースペクトルに関する特徴量の全19種類を算出し用いている。また、ランダムフォレスト(Random Forest)により、特徴量の重要度を評価した上で、SVMによるジェスチャ識別を行っており、その際ジェスチャ識別率が最大の時に使用した特徴量数とジェスチャ識別率、他人受け入れ率を調べるため、被験者につき60サンプルあるデータから、各ジェスチャ1サンプル(全6サンプル)を検証データとし、残りの9サンプル(全54サンプル)を学習データとし、交差検証を行っている。このときのカーネルはRBFカーネルを使用し、コストパラメータとガンマパラメータはグリッドサーチという手法を用いることで被験者ごとに最適な値を設定している。

### 2.3 結果と課題

使用した特徴量数は平均17.2個、ジェスチャ識別率は平均81.3%、他人受け入れ率は平均48.3%であった。またジェスチャごとの他人受け入れ率については、68.0%が最も大きく、続いて53.0%だった。どちらも手首を動かすジェスチャであった。

この研究から、周波数領域の特徴量においてもジェスチャ識別に有効であると確認した一方で、ジェスチャ識別率、他人受け入れ率、本人拒否率といった点が課題に挙げられていた。それらの課題を解決するために、使用するジェスチャの変更や追加、またジェスチャごとに最適な電極の

選択, 使用する特徴量の抽出方法など, 様々な視点での検討が必要であった. 例えば, 特徴量の抽出方法として, スライディングウィンドウ法の利用や, ランダムフォレストによる特徴量の選択, また識別器としてアンサンブル学習の検討や, 時間情報の利用可能なリカレントニューラルネットワークの使用なども検討していた.

### 3 実験概要

本節では個人認証システムのための表面筋電位を用いたハンドジェスチャ識別の概要と手順について示す. まず図1に本研究の実験手順を示す.

本研究では, 測定された筋電位データを解析し, 特徴量を抽出する必要がある. そして抽出された特徴量を元に機械学習モデル, つまりジェスチャ識別器を作成し, その評価を行う. 具体的には, 被験者毎のジェスチャ識別率, 本人拒否率 (1 - ジェスチャ識別率), また他人のジェスチャを入力した際に, 受け入れてしまう他人受け入れ率を評価する.

本研究では, Python を用いて, プログラムを作成する. また機械学習の実装には, scikit-learn を用いる.

#### 3.1 筋電位の測定方法

本研究では, Advancer Technologies 社の筋電位センサ (MyoWare) を用いる. 今回 Myoware で筋電位データを測定するため Arduino を用いた. 筋電位データの解析については, Arduino 単体では出来ないため, PC で行う. 本研究では, 被験者に対して, ハンドジェスチャ動作時に生じる前腕部の筋電位データを測定する. 拳を軽く握った状態を初期状態とし, 5種類のジェスチャ (チョキ, パー, 親指と人差し指と中指を手の甲側に向けて開く, 拳を軽く握った状態で手首を返す, 人差し指と中指の交差) の測定を行う (以降, 5種類のジェスチャをそれぞれチョキ, パー, 3本指, 曲げる, 交差とする). その際, 取得する筋電位信号はサンプリングレートを 200[Hz], 振幅を 0[V] から 5[V] に変換する. 例としてチョキのジェスチャを行った際に発生した筋電位データを図2に示す. 図2のような時系列データ (筋電位データ) を各ジェスチャ最大 20回ずつ測定する.




図1 実験手順




図2 チョキを行ったときに発生した筋電位例

#### 3.2 学習用筋電位データ

本研究では, 測定した筋電位データの中から, 当該のジェスチャの特徴が最も反映されていると期待できる筋電位データを標準波形とし, それを元に学習用データを選択するという黒木ら [5] の研究で報告されていた考え方を参考ににする. 具体的には, 各ジェスチャ毎に標準波形 (理想的な筋電位データ) を選出し, それに類似する筋電位データを学習用データとして採用する. 黒木ら [5] の研究では相関係数を用いて標準波形を選出していたが, 我々はユークリッド距離 (Euclidean distance) を用いることで標準波形を選出する. ユークリッド距離はある2つのデータ間の距離のことであり, 以下の式で求められる.

$$d = d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

式 (1) はある2つのデータ  $p, q$  の距離を求める式ではあるが, 類似度を評価する式でない. そのため, 以下の式から類似度  $s$  を求める.

$$s = \frac{1}{(1 + d)} \quad (2)$$

各ジェスチャ毎に測定した筋電位データを2つ取り出し, 全ての組み合わせについて式 (1) と式 (2) から類似度を求める. そして, 各筋電位データの類似度の平均値が最大となるものを各ジェスチャの標準波形とし選出する. その標準波形に対する類似度が高い10個の筋電位データと標準波形を加えた筋電位データを学習用データ (11データ × 1ジェスチャ) として採用し, 各被験者毎に全55個の筋電位データからジェスチャ識別器を作成する.

#### 3.3 使用する特徴量と分類方法

本研究では, 筋電位データに関する特徴量を算出し, それを元に機械学習モデル, つまりジェスチャ識別器を作成する. 特徴量は平均値 (mean), 総和 (sum), 最大値 (max), 最小値 (min), 範囲 (range), 第1四分位数 (q1), 中央値

(median), 第3四分位数 (q3), 四分位範囲 (iqr), 四分位偏差 (qd), 分散 (var), 標準偏差 (std), 歪度 (skew), 尖度 (kurt), 変動件数 (cv), 平方根の平均 (msr), 二乗の平均値 (msq) の計 17 個を算出し, それらを csv ファイル形式で記録する. 芝田ら [4] の研究では, 筋電位データに対して高速フーリエ変換を適用することで, 周波数領域における特徴量も算出していたが, 図 3 のようにジェスチャ動作時の筋電位データには高周波数成分が全く含まれていないことが分かる. そのため本研究では, 周波数領域における特徴量は考えないものとする.

平田ら [6] の研究では筋電位データ全体から特徴量を算出しても, 元のデータでは大きく特徴が出にくいという理由から, 図 4 のように筋電位データを時間方向に分割し, 分割した各部分に対して, 特徴量を算出している. 本研究でも, 筋電位データを分割し, 特徴量を算出する. さらに何分割が被験者毎に最適なのかも調査する.

本研究では, 先行研究で使われていた SVM 以外の分類方法にも着目する. 表面筋電位を用いた動作識別に関する研究では, SVM 以外にも,  $k$ -近傍法 ( $K$ -NN), ランダムフォレスト (RF), ニューラルネットワーク (MLP) で高い識別精度が得られていたため採用する. さらに, 他の生体認証で用いられていた決定木 (DT) やロジスティック回帰 (LR), ガウシアンナイーブベイズ (NB) についてや, 芝田らの研究 [4] で今後の課題として挙げられていたアンサンブル学習も取り入れる. 具体的には, AdaBoost と決定木 (AdaBoost  $\times$  DT), AdaBoost と SVM (AdaBoost  $\times$  SVM) を取り入れる.

以上, 計 9 つの分類方法を用いて, 比較実験を行う. また各分類方法の評価方法は, 5 分割の交差検証を行うこととする.

### 3.4 パラメータの最適化

機械学習モデルにはハイパーパラメータという人自らが設定しなければならないパラメータがある. このハイパー




図 3 FFT を適用させた筋電位例




図 4 分割した筋電位データ例

パラメータを最適化することでモデルの精度向上が見込まれる. しかし, 幾通りの組み合わせを手動で行い, モデルを作成するには非常に時間がかかる. そこで本研究では, 芝田ら [4] の研究でも使用されていた, グリッドサーチという手法を用いることで, ハイパーパラメータを調整する. グリッドサーチとは, 機械学習モデルのハイパーパラメータを自動的に最適化してくれる方法で, 具体的には全てのパラメータの組み合わせを試し, 最も高い評価精度を探索する方法である. そのグリッドサーチを被験者ごとに行い, 最適なパラメータを各分類方法で用いる.

## 4 実験結果と考察

本研究では, 被験者 5 名 (a, b, c, d, e) の筋電位データを用いてハンドジェスチャ識別評価を行った. 具体的には各被験者毎に, 最適な筋電位データの分割数とパラメータの最適化を行った上で, 3.3 節で紹介した各分類方法における比較実験を行い, その中で最も優れている分類方法のジェスチャ識別率, 本人拒否率, 他人受け入れ率を評価した.

### 4.1 実験結果

まず表 1 に, 各分類方法における各被験者のジェスチャ識別率を示す. 表 1 から, 各分類方法においてジェスチャ識別率の平均が一番高かったのが, 87.3% の AdaBoost  $\times$  DT であった. また二番目は, 86.6% の RF だったため, ジェスチャ識別には木構造のモデルをベースとした分類方法が適していることがわかった.

また 3.4 節で紹介したグリッドサーチという手法を用いることで, 各機械学習モデルのパラメータの最適化を行ったと同時に, 最適な筋電位データの分割数も調べた. このとき, 最適な分類方法であった AdaBoost  $\times$  DT の結果を表 2 に示す. また AdaBoost のベースとなる DT のパラメータは被験者 b, c, d は, criterion が entropy, max\_depth が 2, min\_samples\_leaf が 2, min\_samples\_splits が 3 となり, 被験者 a, e は, max\_depth が 1 となった. そして, 元の筋電位データを分割せず特徴量を抽出するより, 筋電位データを分割し, 各分割部分においてそれぞれ特徴量を抽出する方が精度向上に良いと明らかになった.

表1 各分類方法におけるジェスチャ識別率 [%]

被験者	a	b	c	d	e	平均
SVM	92.7	90.9	81.8	87.3	58.2	82.2
K-NN	83.6	90.9	81.8	85.5	56.4	79.6
LR	90.9	87.3	87.3	81.8	58.2	81.1
DT	94.5	85.5	87.3	85.5	70.9	84.7
RF	96.4	90.9	92.7	85.5	67.3	86.6
NB	89.1	96.4	92.7	81.8	58.2	83.6
MLP	89.1	83.6	89.1	76.4	54.5	78.5
AdaBoost × DT	96.4	92.7	90.9	85.5	70.9	87.3
AdaBoost × SVM	89.1	83.6	78.2	80.0	50.9	76.4

表2 AdaBoost × DT のパラメータ及び分割数

被験者	algorithm	learning_rate	n_estimators	分割数
a	SAMME.R	0.25	50	7
b	SAMME	0.50	50	1
c	SAMME	0.25	50	4
d	SAMME	1.00	100	3
e	SAMME.R	0.50	100	3

また、最適な分類方法と判明した AdaBoost × DT と先行研究で多く使用されていた SVM のジェスチャ識別率、本人拒否率、他人受け入れ率をそれぞれ表 3、表 4 に示す。このとき、各被験者毎に最適なパラメータ、分割数は各分類方法に適応しているものとし、本人拒否率、他人受け入れ率は、以下の式から求めるものとする。

$$\text{本人拒否率} = 1 - \text{ジェスチャ識別率} \quad (3)$$

$$\text{他人受入率} = \frac{\text{受入数}}{\text{自身以外の全筋電位データ数}} \quad (4)$$

表 3,4 から、SVM より AdaBoost × DT の方が、全体的に識別評価が高いことが判明した。

また、表 5 に AdaBoost × DT におけるジェスチャ毎の他人受け入れ率を示す。このとき、ジェスチャ毎の他人受け入れ率は以下の式で求めるものとする。

$$\text{他人受入率 (ジェスチャ毎)} = \frac{\text{ジェスチャ毎の受入数}}{\text{全被験者の他人受入数}} \quad (5)$$

表 5 から、チョコキと交差のジェスチャがそれぞれ 35.5% と 31.3% となり、他のどのジェスチャよりも他人受け入れ率が高い結果となった

#### 4.2 考察

表面筋電位を用いたハンドジェスチャ動作識別を評価した結果、最適な分類方法 AdaBoost × DT を選ぶことにより、ジェスチャ識別率が 87.3%、本人拒否率が 12.7%、他人受け入れ率が 19.2% という良好な結果となった。しかし表 5 より、他人受け入れ率はジェスチャ毎で最大 27.0% の差があった。よって、まだ改善の余地がある。具体的には本研究で採用した 5 種類のジェスチャ以外に、より適しているジェスチャを採用する必要がある。

表3 AdaBoost × DT における評価精度 [%]

被験者	a	b	c	d	e	平均
ジェスチャ識別率	96.4	92.7	90.9	85.5	70.9	87.3
本人拒否率	3.6	7.3	9.1	14.5	29.1	12.7
他人受け入れ率	18.6	28.2	20.5	12.7	15.9	19.2

表4 SVM における評価精度 [%]

被験者	a	b	c	d	e	平均
ジェスチャ識別率	92.7	90.9	81.8	87.3	58.2	82.2
本人拒否率	7.3	9.1	18.2	12.7	41.8	17.8
他人受け入れ率	20.0	20.9	17.7	23.2	20.0	20.4

表5 ジェスチャ毎の他人受け入れ率 [%]

ジェスチャ	チョコキ	パー	3本指	曲げる	交差
他人受け入れ率	35.5	8.5	12.8	11.8	31.3

## 5 今後の課題

本研究では、先行研究で個人認証を実現するために課題として挙げていたジェスチャ識別に着目し、9つの分類方法を試した。その結果、ジェスチャ識別には木構造のモデルをベースとしたものが適していると判明し、先行研究からの識別評価の向上を確認した。しかし、他人受け入れ率については、改善の余地がある。今後の課題として、最適なジェスチャの模索や、使用する特徴量の見極めが挙げられる。さらに、ジェスチャ列をパスワード列として扱うシステムを構築し、個人認証についても検討する必要がある。

## 参考文献

- [1] 警察庁, 総務省, 経済産業省. 不正アクセス行為の発生状況及びアクセス制御機能に関する技術の研究開発の状況, 2023. [https://www.soumu.go.jp/main\\_content/000868634.pdf](https://www.soumu.go.jp/main_content/000868634.pdf).
- [2] 越前功, 大金建夫. 写真からの指紋復元の脅威とその対策技術. 情報処理, Vol. 58, No. 9, pp. 824–829, 2017.
- [3] 平澤翼, 納富一宏, 斎藤恵一. 音声認証における「なりすまし」の検証と対策の検討. 第 73 回全国大会講演論文集, Vol. 2011, No. 1, pp. 505–506, 2011.
- [4] 芝田龍正, 三上剛, 秋月拓磨, 大前佑斗, 高橋弘毅. 個人認証を念頭に置いた表面筋電位を用いたジェスチャ識別. 知能と情報 (日本知能情報ファジィ学会誌), Vol.33, No.1, pp. 549–554, 2021.
- [5] 黒木聡舜, 山場久昭, 油田健太郎, 岡崎直宣. 表面筋電位を用いた認証システム実現のための個人識別手法の提案. 宮崎大学工学部紀要, Vol. 47, pp. 227–236, 2018.
- [6] 平田木乃美, 横山美波, 山場久昭, 油田健太郎, 岡崎直宣. 表面筋電位を用いた認証システム実装のための筋電波形の特徴量の選出. 宮崎大学工学部紀要, Vol. 47, pp. 315–319, 2018.