ウェアラブルデバイスを用いたタイピング時の指の認識

濵﨑大輔[1]　長谷川達人[1]

概要：情報化社会において，コンピュータが扱えることは重要である．コンピュータを扱うには入力装置であるキーボードを扱えなければならない．キーボード操作でのタイピングは，ホームポジションに指を置き，各キーに対応した指を使うことが高速かつ正確な打鍵につながる．本研究では表面筋電位の簡易計測デバイスである Myo を用いてタイピング時の指の認識手法を開発する．提案手法では，打鍵スピードによる影響を抑制するため，特徴量抽出時にフレームに窓関数を導入した．評価実験の結果，被験者別の 10-Fold CV では 8 割弱の精度で 5 指とニュートラル状態の 6 カテゴリを認識することができた．また，窓関数を掛けることが打鍵スピードの影響を抑えることを確認した．さらに，キャリブレーションに必要なインスタンス数の検証を行い，約 50 インスタンスが必要なことを確認した．

Finger recognition using a wearable device while typing

DAISUKE HAMAZAKI[1]　TATSUHITO HASEGAWA[1]

1. はじめに

情報化社会である現代社会において，コンピュータが扱えることは重要である．総務省の「インターネットの利用動向」[1]によると，2017 年の世帯におけるコンピュータの世帯保有率は 72.5%となっている．このことから，現在においてコンピュータは広く普及していると言え，使用する機会も多いと推測される．しかし，2017 年の世帯におけるスマートフォンの世帯保有率はコンピュータを上回り，キーボード操作を必須としないスマートフォンの普及によってキーボード操作の機会が今後減少すると考えられる．それに伴い，コンピュータの操作に必要なキーボード操作に不慣れな人が今後増えることが予想される．一方で，文書作成などを頻繁に行う職種では，文字入力のためにコンピュータを扱う機会が特に多いと考えられる．文字入力のためにはコンピュータの入力デバイスであるキーボードのタイピングが必要であり，タイピング能力は業務効率に大きく影響すると考えられる．そのため，コンピュータを用いる職種では，タイピング能力が重要であると言える．

一般的にタイピング能力が高いとは，意図したキーを高速かつ正確に打鍵できることを指す．この状態になるためには以下の 3 つの技能が必要と考えられる．

1. **キー配置の把握**：意図したキーを誤りなく打鍵できる．
2. **正しい運指**：適切な指で所定のキーを打鍵できる．
3. **タッチタイプ**：キーボードを目視せずに 1,2 ができる．

タイピング能力の向上を支援するには上記の 1，2，3 それぞれの支援が考えられる．本研究では，2 の正しい運指の習得をコンピュータで支援するシステムの開発を行う．これを実現するためには，コンピュータが学習者の打鍵を認識し，誤りを提示，訂正する仕組みが必要となる．しかし，入力デバイスであるキーボードがコンピュータに伝える情報は打鍵されたキーだけであり，どの指で打鍵されたかを認識することは容易ではない．本研究では表面筋電位の簡易計測デバイスである Myo を用いてタイピング時の指の認識手法を開発する．本手法を用いることで，打鍵した指をコンピュータが認識でき，学習者にフィードバックできる．将来的にはタイピングスキル向上支援システムに組み込み，学習者の能力向上を支援することを目的とする．

2. 関連研究

2.1 タイピングに関する研究

高岡らの研究[2, 3]では，タッチタイピングを行う能力の習得を目的とした「タッチタイピングシステム」の開発や初心者のタイピング動作の特徴についての調査を行っている．タッチタイピングシステムを運用して得られた学習データを解析した結果，タイプミスの低下率とタイプ速度の上昇率は全体的に相関があることが示されている．また，効率良くタッチタイピングを習得するには，訓練前半で日数を空けず，常に自分の能力より少し上を目指して練習することが重要であることも示されている．初心者のタイピング動作の特徴については，タッチタイピングができないタイピストに焦点を当てて実験を行い，初心者の苦手な文字の傾向などを分析している．分析結果には，文字ごとの正解率と打鍵速度には相関があること，打鍵速度に関わらずミスの種類は誤打鍵が最も多いことなどが示されている．

伊藤の研究[4]では，タッチタイピングのスキルをほとんど習得していない女子短期大学生を対象に，打鍵ミス低減に重点を置いたタッチタイピング教育を行っている．カリ

1福井大学大学院工学研究科
Graduate School of Engineering, University of Fukui

ⓒ2019 Information Processing Society of Japan

キュラムには,「正しいフォームの意識付け」,「習得印を利用したプログラム」,「打鍵数の記録形式」,「打鍵ミスの低減」,「タッチタイピング習得の意義と有効性の理解による動機付け」などを組み込んでいる．このタッチタイピング教育カリキュラムを実施した結果，10 週間で平均打鍵数を 92.0±6.6[文字／分]から 129.2±8.1[文字／分]にまで増加させることに成功している．

2.2 カメラを用いたタイピングに関する研究

荒井らの研究[5]や今村らの研究[6]では，Web カメラなどを用いてタイピング練習者の顔を撮影することにより，タイピング練習者を支援するための視線方向を認識している．タイピング時の視線方向を検出できることで，タッチタイピングできているかどうかという点について，練習者に適切なアドバイスを行うことが可能になる．

小田らの研究[7]では，カメラを用いてタイピング時の手元の動きを撮影し，指の動きを検出している．打鍵時点の動画データのフレームから輪郭を抽出し，そこから各指の指先点の抽出している．その後，指が打鍵されたキー内に存在するか否かで打鍵した指を判定している．タイピング時の指先を取得することで，キーに対応した正しい指で打鍵したかどうかという点について，練習者に適切なアドバイスを行うことが可能になる．

タイピング練習者の状態の取得にカメラを用いた場合には，環境による影響を受けやすい．前述の視線認識であれば，目の形や眼鏡の着用やまばたきによる影響，タイピングする環境により推定精度に影響がでる．また，荒井らの研究[5]や今村らの研究[6]では，カメラで顔を撮影するため学習者の顔や部屋が移るなどのプライバシーリスクが存在する．また，小田らの研究[7]では，打鍵した指を判定する際には，指が打鍵されたキー内に存在するかどうかで判定しているため，予めカメラを固定し，座標を設定する必要がある．さらに，カメラを固定し，座標の設定ができた場合でもカメラから指先が隠れてまったり，輪郭がうまく抽出できない場合に指をうまく認識ができない場合がある．

2.3 筋電位に関する研究

吉川らの研究[8]では，筋電義手の制御のため，筋電位を利用して意図する手の動作のリアルタイム識別手法を提案している．手の動作の識別には SVM を用い，総識別率は被験者平均で 94.6%となった．平手らの研究[9]や棒谷らの研究[10]では，多次元信号の解析手法の一つである独立主成分分析を表面筋電位に適用し，手・腕の動作を識別する方法を提案している．金らの研究[11]では，ウェアラブルデバイスを用いて表面筋電位から独立成分分析を用いて筋電位の発生源を特定し，それを利用したジェスチャ認識手法を提案している．この研究では，シミュレーションを用いて提案手法の検証を行っている．

[8, 9, 10]の実験では，筋電位の測定機器を自作している．そのため，一般に販売もされておらず，開発も容易ではない．また，装置とコンピュータの接続方法も公開されていないため，タイピングのソフトに組み込むことも容易ではない．さらに，タイピング練習者に正しい運指であるかどうかをフィードバックするためには，各指の動きを認識する必要がある．しかし，吉川らの研究[8]や棒谷らの研究[10]は，各指の動きではなく，手や腕全体の動きに焦点を当てており，認識する動作の対象が違う．また，平手らの研究[9]では，指の屈伸動作の認識を行っているが，屈伸動作と打鍵動作では動作に大きな違いがある．

2.4 本研究の位置付け

従来のタイピング能力向上支援システムでは，正しい運指で打鍵が行われているかといった，学習者の動作は考慮されていない．指定されたキーが正しく打鍵されたか，その速度はどうだったかという情報でのみ学習者を評価している．どの指で打鍵したかを認識することができれば，学習者に従来までの評価に加え，正しい運指であるかどうかもフィードバックでき，タイピング能力向上の支援につながると考えられる．

そこで本研究では，表面筋電位を簡易計測できるウェアラブルデバイスを用いて，学習者の打鍵した指を認識する手法を開発する．従来の研究では，打鍵した指の認識にカメラを用いていたが，本研究ではアームバンド型ウェアラブルデバイスである Myo を用いる．これにより，キーボード周辺にカメラを設置場所がない，またはコンピュータ操作の邪魔になるなどのカメラの設置に難があるという問題を改善する．また，Myo はアームバンド型のウェアラブルデバイスであり，腕に装着し，無線接続のためタイピング動作を妨げないという利点がある．

3. 提案手法

3.1 使用機器

本研究では打鍵する指を認識する目的でアームバンド型ウェアラブルデバイスである Myo を使用する．Myo とは，表面筋電位や加速度などを簡易計測できるアームバンド型のウェアラブルデバイスである(図 1). 本デバイスの特徴として前腕部の表面筋電位を取得する事で指，手，腕の動きを認識する事ができる点が挙げられる．Myo の他にも指の動きを取得するセンサは存在するが，その多くが指周

図 1　アームバンド型ウェアラブルデバイス Myo

ⓒ2019 Information Processing Society of Japan

辺に装着するタイプの物が多く，タイピング動作の妨げとなる事が懸念される．また，カメラなどの環境設置型のセンサでは，設置箇所の環境に左右される点や，センサが指を捕捉できない場合に識別ができないことが懸念される．そこで前腕部に装着し，直接タイピング動作を妨げないと考えられる Myo を採用した．

Myo には，3 軸加速度センサ，3 軸ジャイロスコープ，3 軸磁力計，ステンレス筋電センサのセンサが搭載されている．Myo のサンプリング周波数は，ステンレス筋電センサが 200Hz，その他のセンサが 50Hz である．本研究には，ステンレス筋電センサで計測される表面筋電位を用いた．このセンサは腕の周囲を巻くように 8 つのセンサが搭載されている．指の認識という課題に対して筋電位を用いた理由は，前腕部にセンサ類を装着するため，打鍵による動作で前腕部の加速度やジャイロセンサなどの値には大きな変動はないものと考えられるためである．筋電位とは筋肉の収縮時に生じる電位差であり，特に皮膚表面で観測されるものを表面筋電位と呼ぶ．動く指ごとに使用される筋肉や収縮度合いは異なるため，得られる表面筋電位も動く指ごとに異なると考えられる．したがって，表面筋電位の差異を学習することで，各指の動きを推定できると考えられる．

3.2 提案手法概要

本研究では，Myo を用いたタイピング時の指の認識手法を提案する．図 2 に提案手法の概要を示す．まず，タイピング時に Myo を前腕部に装着する．その時，Myo から計測された表面筋電位時系列データから特徴量抽出を行い，どの指で打鍵したかという 5 種類のカテゴリ（親指～小指）と，打鍵していない状態（ニュートラル状態）の計 6 種類を得られた特徴量から機械学習により推定する．タイピング訓練前に作成した学習済モデルを用いることで，タイピング時に Myo から得られた表面筋電位データから打鍵に用いた指の種類を認識する．将来的には，推定結果を用いて，フィードバックすることでタイピング学習者の訓練を支援するシステムを構築することを目指す．

3.3 計測データ

計測するデータは，コンピュータから得られるタイピングデータと Myo から得られた表面筋電位データである．タイピングデータとはキーボード操作により入力される打鍵時点のキーコードとその時の時刻である．表面筋電位データは Myo から計測されるセンサデータを用いる．Myo から取得できる表面筋電位データは 8 つの表面筋電位センサの生データとその時の時刻である．実際の表面筋電位の計測データの一例を図 3 に示す．図 3 の横軸は時間，縦軸は各ステンレス筋電センサの表面筋電位データを表している．また，図 3 の emg5 のセンサデータの振幅が大きく変動している箇所が打鍵時点である．

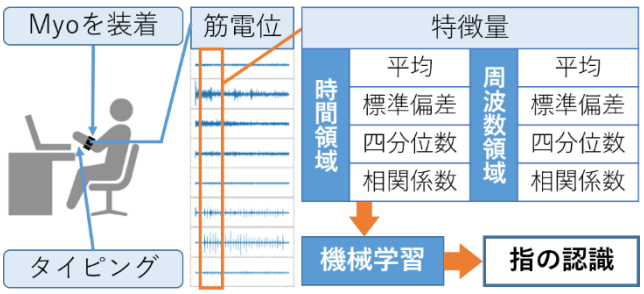

図 2　Myo を用いたタイピング時の指の認識手法

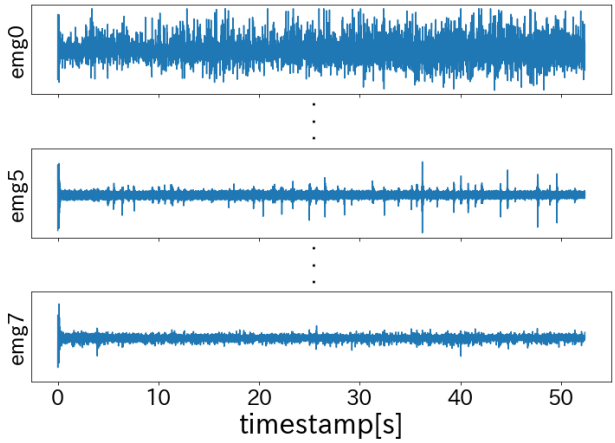

図 3　Myo から得られる表面筋電位データの例

3.4 データセット作成

計測した表面筋電位データを用いて，データセットの作成を行う．データセットの作成には打鍵時点を中心とする一定長のフレームとなるように表面筋電位の時系列データを分割し，各フレームに対して特徴量抽出を行う．表面筋電位の時系列データのフレーム分割のイメージを図 4 に示す．本研究ではフレーム幅は 128 サンプルとし，打鍵時点はタイピングデータから得られる時刻とした．また，打鍵スピードによってはフレーム同士が重なり，フレーム端に他の打鍵情報を含んでしまうことが懸念される．その影響を抑制するため，フレームに窓関数を掛けることとした．フレーム内から抽出した特徴量は表 1 に示したものとし，8 つのセンサ全てに対し合計 268 種類である．表 1 にある周波数領域は各フレームに FFT (fast Fourier transform) を施して求めている．

3.5 機械学習モデル

機械学習アルゴリズムには，Random Forest[12]を採用した．Random Forest とは，複数の決定木を弱学習器としてアンサンブル学習を行う機械学習手法の 1 つである．アンサンブル学習とは，複数の学習器を用いて判別し，各々の判別結果の多数決を最終的な推定結果とする手法である．ま

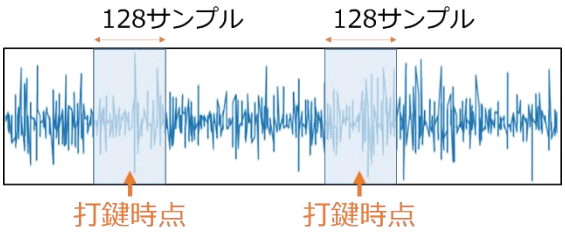

図 4　筋電位の時系列データのフレーム分割

ⓒ2019 Information Processing Society of Japan

表 1　1 フレームから抽出した特徴量

	特徴量名称	センサ番号S_i
時間領域	最小値 四分位数 最大値 平均 標準偏差	S_i $(1 \leq i \leq 8)$
	相関係数	S_i-S_j $(1 \leq i,j \leq 8, i < j)$
（低・高）周波数領域	最小値 四分位数 最大値 平均 標準偏差 最大値の周波数	S_i $(1 \leq i \leq 8)$
	相関係数	S_i-S_j $(1 \leq i,j \leq 8, i < j)$

た，Random Forest では，訓練データからインスタンス・特徴量をランダムサンプリングして各学習器を学習するため，特徴選択が不要であるという利点がある．

今回は Python の機械学習ライブラリである scikit-learn[13]に含まれている RandomForestClassifier を用いた．本研究では Random Forest の決定木の数，決定木の深さ，ノードの最適な分割地点を求める際に用いられる特徴量数のパラメータをグリッドサーチにより決定した．グリッドサーチの結果，決定木の数は 250，決定木の深さは制限なし，ノードの最適な分割地点を求める際に用いる特徴量数は全特徴量の平方根とした．その他のパラメータは RandomForestClassifier のデフォルトの値とした．

4.　評価実験

4.1　実験概要

提案手法の推定精度を評価するため，以下の手順でデータ計測実験を行った．はじめに表面筋電位データの収集を行う．Myo を右腕に装着し，ランダムに指示した特定の指で打鍵する動作を行う．この動作を各指の入力が 10 回ずつになるように全 50 回実施し，これを 1 セッションとしてデータを取得する．指はキーボードのホームポジションに固定し，指の動き以外のノイズを減らすために腕を机の上に置き力を抜くこととする．また，打鍵は長押しせずに，指示されたキーを打鍵後すぐに戻してもらうこととする．計 5 セッションを，セッション間で Myo の着脱は行わずに実施する．これは，Myo の着脱毎に計測機器を個人用に微調整するキャリブレーションをしてから使用することを前提とするためである．データの収集は 20 代の健常男女 10 名(男性 9 名，女性 1 名)で行った．1 人あたり計測にかかる時間は約 10 分間であった．

収集した 10 名分の表面筋電位時系列データから時系列データの分割と特徴量抽出を行う．各フレームに対応する打鍵した指の種類を正解ラベルとする．また，各セッション内で連続する打鍵間隔が十分に空いている箇所から抽出したフレームをニュートラル（どの指も打鍵していない）状態とした．この時，得られたインスタンス数は全員で 2782 個であり，これを Random Forest の入力として推定モデルを生成する．

4.2　窓関数に関する検証

今回取得した表面筋電位データを見ると，データ取得時に 2 打/秒以上のスピードで打鍵を行っている場合，図 5 に示す斜線部分のように特徴量抽出時にフレーム同士の重なりが生じることが確認できた．このフレーム同士の重なりにより，1 フレーム内に該当の打鍵以外の打鍵情報を含んでしまい，Accuracy に悪影響が生じると考えられる．そこで，本現象を抑制するため窓関数の導入を検証する．窓関数とは，図 6 のオレンジの部分のような関数であり，この窓関数をフレームに掛けることで，フレームの中央付近（打鍵時周辺）が強調され，反対にフレーム端付近が減衰する．フレームに窓関数を掛けた一例を図 6 に示す．図 6 からフレーム端の振幅が減少し，フレーム同士の重なり部分では，0 に近い値となっていることが分かる．これにより，該当する打鍵以外の影響を抑制できると考えられる．

本節では，適切な窓関数の選択のために窓関数の形状による Accuracy の影響を検証する．窓関数はガウス窓を用いるものとし，窓関数の形状の変化はガウス窓の標準偏差を 5 から 0.05 まで変えることで実現した．標準偏差の値が小さいほど打鍵時周辺が強調され，フレーム端の影響が減衰する窓関数となる．提案手法では，Myo 装着時にキャリブレーションを行うことを想定している．そこで，モデルの評価には各被験者のデータに対して 10-Fold CV（10-Fold

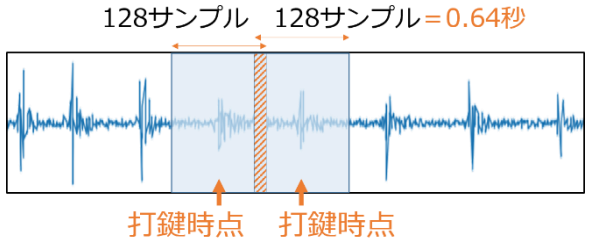

図 5　特徴量抽出時のフレームの重なり

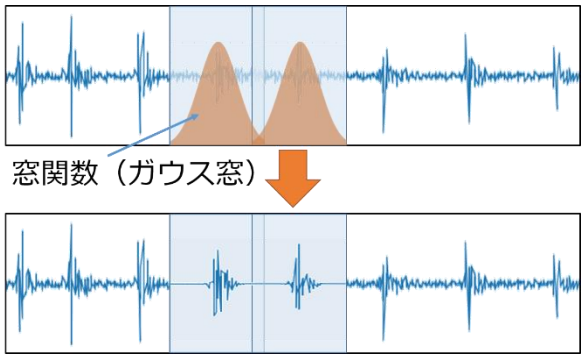

図 6　窓関数を適応した結果の例

ⓒ2019 Information Processing Society of Japan

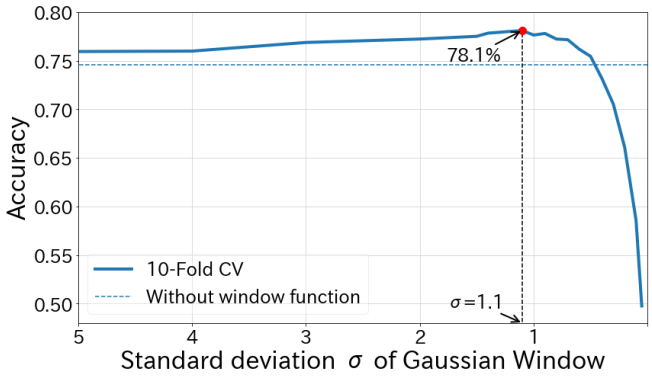

図 7　窓関数の形状による Accuracy の変化

Cross Validation）を行った．10-Fold CV とは，データセットを 10 個に分割し，そのうち 1 個を検証用データ，残る 9 個を訓練用データとしてデータを入れ替えながら訓練，検証を 10 回行う評価手法である．

窓関数の形状毎の推定精度の変化を図 7 に示す．図 7 の横軸はガウス窓の標準偏差 σ，縦軸は Accuracy，赤点は Accuracy の最大値を表している．また，点線は窓関数を用いない場合の Accuracy を示している．図 7 の結果より窓関数を掛けフレームの打鍵時周辺の特徴をある程度強調し，フレーム端付近の特徴を弱めた方が Accuracy の向上が見られることを確認した．そのため，フレーム端に含まれる可能性のある他の打鍵情報は Accuracy に影響を与えていると考えられる．また，ガウス窓の標準偏差 σ を過剰に小さくすると，Accuracy が悪化することを確認した．よって Accuracy を高めるにはガウス窓の標準偏差 σ を適切に設定することが必要であると考えられる．

以上より，フレーム内に他の打鍵が含まれた場合，他の打鍵情報が Accuracy に影響を与えることが分かった．この影響を抑制するために，窓関数は有効な手段であることを確認した．また，図 7 の結果からガウス窓の標準偏差 σ が 1.1 の時に Accuracy が最大になることを確認した．

4.3　提案手法による指の認識精度の上限値の検証

第 4.2 節で示された Accuracy が最大になるガウス窓（標準偏差 σ =1.1）を用いて，提案手法の評価を行う．10-Fold CV は，十分なキャリブレーション用のデータが用意できる環境を再現した評価指標となるため，提案手法による指の認識精度の上限値を評価することとなる．

10-Fold CV の Accuracy と混同行列，F 値を表 2 示す．表 2 中の N はニュートラル状態を示している．Accuracy とは，予測したデータのうち，実際に正しく予測できたものの割合である．混同行列とは，ある教師ラベルがついたデータがどのカテゴリに判定されたかを示した表である．また，F 値とは，適合率と再現率の調和平均であり，その指が正しく評価できたかどうかを確かめるための指標の 1 つである．適合率とは，あるカテゴリと予測したデータのうち，実際にそのカテゴリに属しているものの割合であり，再現率とは，あるカテゴリに属しているもののうち，実際にそのカテゴリであると予測されたものの割合である．

10-Fold CV の Accuracy は 78.8%となった．表 2 の Accuracy は全被験者分の予測結果を連結して混同行列にした結果であり，混同行列から算出した Accuracy である．一方図 7 の Accuracy は各被験者の Accuracy の全被験者分の平均である．このため，図 7 のグラフと表 2 の Accuracy の値が異なる．表 2 の混同行列や F 値から，他の指と比べて人差指に対する認識精度が低く，様々な指と誤認している．特に人差し指は中指と相互に誤認識するケースが目立つ．これの原因としては，人差指では使用する筋肉が他の指と重複していることが考えられ，特に人差指と中指の表面筋電位データの特徴が似ていることが考えられる．一方で，ニュートラル状態，薬指は高い精度で認識ができている．表 2 の混同行列から他の指がニュートラル状態と誤判定されることも少ないため，ニュートラル状態を連続する打鍵間隔が十分に空いている箇所から抽出した特徴量としたことは問題ないと考えられる．しかし，今回は連続する打鍵間隔が十分に空いている箇所から特徴量を抽出したため，瞬間的なニュートラル状態となった箇所を認識できるかどうかは，今後検証する必要がある．

4.4　キャリブレーションに要するデータ量に関する検証

提案手法では，Myo 装着時にキャリブレーションを行うことを想定している．そのため，キャリブレーションに使う学習データが少ないほどタイピング学習者への負担が小さい．そこで，キャリブレーションに必要なインスタンス数を検証するため，学習インスタンス数を変化させながら複数回学習を行う評価を行った．今回，指の認識は分類問題のため，学習データに含まれていないカテゴリは予測できない．そのため，学習データには親指から小指，ニュートラル状態の 6 つのカテゴリのインスタンスを含む必要がある．したがって，これらの 6 つのカテゴリのインスタンスを 1 組として用いることとした．この組をインスタンス組と呼ぶこととする．評価には全データのうち 3 割を用いるものとし，学習に用いるインスタンス組は残りの 7 割のデータの中からランダムに抽出することとする．ランダムサンプリングによる精度のばらつきを踏まえ，これを各インスタンス組で 10 回繰り返す．なお学習に用いるデータ

表 2　10-Fold CV の Accuracy と混同行列，F 値

正解		N	親	人	中	薬	小
予測	N	303	1	10	5	1	7
	親	12	393	40	29	9	31
	人	14	39	315	50	26	21
	中	4	17	65	376	18	12
	薬	3	7	34	24	419	24
	小	7	28	26	11	16	385
F 値[%]		90.5	78.7	66.0	76.2	83.8	80.8
Accuracy		78.8					

ⓒ2019 Information Processing Society of Japan

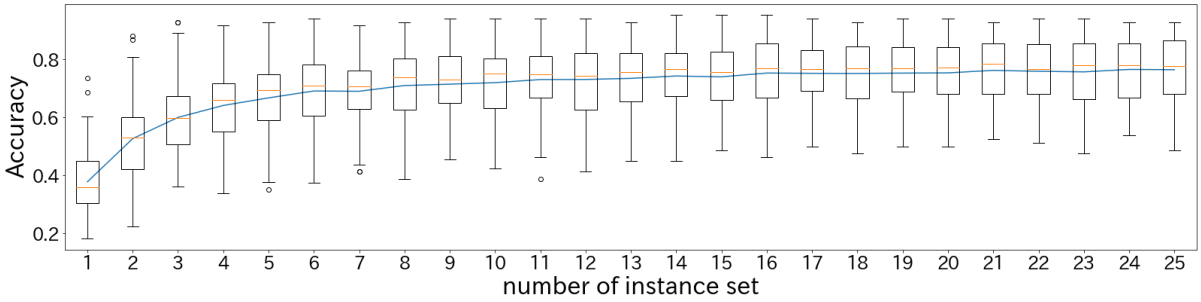

図 8　学習インスタンス組による Accuracy の変化

には，第 4.2 節で示された Accuracy が最大になるガウス窓（標準偏差 σ =1.1）を用いることとする．

学習インスタンス組を変化させたもののグラフを図 8 に示す．図 8 の縦軸は Accuracy，横軸は学習インスタンス組のセット数，各インスタンス組に対応する箱ひげ図は全被験者の学習データで複数回学習を繰り返した Accuracy の分布を表している．図 8 より 1 から 7 組だと 10-Fold CV と比べ精度が低いことが分かる．これは，学習データが少なく，表面筋電位データの特徴を十分に学習できていないことが原因と考えられる．また，Accuracy の収束が約 8 インスタンス組であることから，最低でもキャリブレーションには約 8 インスタンス組が必要なことが分かる．これは 1 カテゴリ当たり 8 つのインスタンスが必要だということである．一被験者あたり約 10 分の計測で約 50 インスタンス組のデータを取得できたため，8 インスタンス組では約 1 分 40 秒のデータが必要であると考えられる．以上より，提案手法利用時には，約 1 分 40 秒間キャリブレーションを利用者に依頼することで，約 8 割の認識精度を実現できることを確認した．

5. 終わりに

本研究では，表面筋電位の簡易計測デバイスである Myo を用いてタイピング時の指の認識手法の開発と評価を行った．評価データで得られた表面筋電位データを，機械学習を用いて解析し，打鍵した指の認識を行った．

Myo の装着の度にキャリブレーションをすることを前提とした場合，指の認識は 78.8%の Accuracy で推定できた．指の認識において打鍵スピードによる影響を受けるが，窓関数を導入することで改善できた．また，キャリブレーションに必要なデータ数の検証も行い，1 カテゴリ当たり 8 つのインスタンスが必要であることを確認した．

今後は，人差指の認識精度の向上や実際のタイピング時における推定精度の検証，Myo の装着位置や角度による影響による考察を行っていきたい．さらに，センサデータの前処理，他の機械学習手法などを用いて精度向上を目指す．

謝辞　本研究の一部は科学研究費助成事業若手研究（B）（16K16175）の助成によるものである．ここに謝意を表す．

参考文献

[1] 総務省：総務省｜平成 30 年版情報通信白書｜情報通信機器の保有状況，総務省(オンライン)，入手先 <http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h30/html/nd252110.html>(2019-05-13).
[2] 高岡詠子，橋本知佳：タッチタイピング学習システムを用いたタッチタイピング訓練法に関する研究，研究報告コンピュータと教育 (CE)，Vol. 2010，No. 2，pp.1-10(2010).
[3] 高岡詠子，田村啓，杉浦学：初心者のタイピング動作特性の解析，研究報告コンピュータと教育(CE)，Vol. 2013，No. 9，pp. 1-8(2013).
[4] 伊藤弘顕.：打鍵ミス低減に重点を置いたタッチタイピング教育の評価，甲子園短期大学紀要，Vol. 33，pp. 23-30(2015).
[5] 荒井正之，下境浩，渡辺博芳，武井惠雄：カメラを用いたタイピング練習システムにおける目の向きの認識，情報処理学会研究報告コンピュータと教育 (CE)，Vol. 2002，No. 39 (2002-CE-064)，pp. 49-55(2002).
[6] 今村貴明，永井孝幸，中野裕司：視線判定機能によりタッチタイピング練習を支援するツールの開発，研究報告コンピュータと教育 (CE)，Vol. 2012，No. 5，pp. 1-8(2012).
[7] 小田航，鹿嶋雅之，佐藤公則，渡邊睦.：タッチタイピングの習得支援システムに関する研究，電気関係学会九州支部連合大会講演論文集 平成 26 年度電気・情報関係学会九州支部連合大会 (第 67 回連合 大会) 講演論文集，pp. 226-226. (2014).
[8] 吉川雅博，三河正彦，田中和世：筋電位を利用したサポートベクターマシンによる手のリアルタイム動作識別，電子情報通信学会論文誌 D，Vol. 92，No. 1，pp. 93-103(2009).
[9] 平手庸介，大日方五郎，長谷和徳，中山淳，金泳佑：独立成分分析による表面筋電位からの手の動作の推定，バイオメカニズム学会誌，Vol. 33，No. 2，pp. 134-141(2009).
[10] 棒谷英法，大須賀美恵子：表面筋電信号に基いた腕・手の動作識別，人間工学，Vol. 49，No. 1，pp. 1-9(2013).
[11] 金成柱，田野俊一，橋山智訓，岩田満：指の動的な遷移情報と SEMG より推定した EMG の発生源を対応付けたハンドジェスチャ認識器の提案，日本知能情報ファジィ学会 ファジィ システムシンポジウム 講演論文集 第 31 回ファジィシステムシンポジウム，pp. 385-388. 日本知能情報ファジィ学会(2015).
[12] Leo Breiman: Random forests. Machine learning, Vol. 45, No. 1, pp. 5–32(2001).
[13] scikit-learn: machine learning in python− scikit-learn 0.21.0 documentation. 入手先<https://scikit-learn.org/stable/index.html >(2019-05-13).

ⓒ2019 Information Processing Society of Japan