

ウェアラブルデバイスを用いた筋電位ベース遠隔操作システム構築のための上肢動作識別

EMG Classification for EMG-based Teleoperation of 3D Printed Prosthesis

叶賀卓（慶應大） 満倉靖恵（慶應大）

Suguru KANOVA, Keio University

Yasue MITSUKURA, Keio University

Abstract: Surface electromyogram (EMG) has been used as an input to systems of prostheses for providing modes such as power assist and functional recovery to users. Many studies reported excellent schemes that show high classification accuracy of one or two degree-of-freedom (DOF) upper limb movements without wrist pronation/supination in laboratory environments. This paper investigates the practical efficiency of major EMG classification schemes with wearable device to control prosthesis. Twenty-two kinds of movements in free space from fifteen able-bodied subjects and one subject with congenital cerebral palsy were recorded along with isometric force from right forearm. Twelve combinations of window size and feature extraction methods were used to generate classifier. Artificial neural networks were trained by the Levenberg-Marquardt back-propagation algorithm and leave one subject out cross validation for one and two DOF classification. The results showed 64.49 ± 16.29 or $47.03 \pm 10.37\%$ classification accuracy averaged across subjects for one or two DOF movements.

Key Words: Teleoperation, Electromyogram, Neural network

1. はじめに

筋電義肢は、ヒトが従来持つ身体能力を、ヒト由来の筋活動情報から補綴や強化できる。ヒトから得られた情報に基づく操作は、ユーザが直感的に判断でき、短期間の訓練で違和感のない操作が可能となる。また、義肢に所有させる自由度が高くなるほど、ヒト本来の動きに近いものを再現できる。コップに水を注ぐような日常生活下の何気ない動作に関しても、多自由度を必要とすることがほとんどである。したがって、自由度の高い動作のモデリングや推定の精度向上は、現在も求められている⁽¹⁾。下肢に関する動作は上肢より格段に複雑なため、現在この研究分野では、上肢を対象としたモデリングや推定の研究が主流となっている^(2, 3)。

筋活動により生じる筋電位を基に、上肢の動作を推定する場合、切断の度合いによって推定すべき動作の自由度が変化する。ここで、肘関節の有無は非常に重要な判断基準である。肘関節がある場合、指節間関節、手関節、および肘関節による屈曲/伸展、橈屈/尺屈、もしくは回内/回外の1または2自由度を対象とすることが一般的である。肘関節がない場合は、肩から手までを一直線として、指節間関節の屈曲/伸展の代行もしくは肘関節による回内/回外を対象とする必要がある⁽⁴⁾。本研究では、健常者のパワーアシスト機能への拡張も考慮し、肘関節がある場合を対象としている。

これらの研究はいずれも、リアルタイム性が明確に必要とされる。したがって、時系列信号を特定の窓長に基づいて分割することで特徴抽出を行ない、その特徴に対して高速な動作識別器を生成する必要がある。このとき、学習を行なうために、筋電位を入力として用いるが、出力は、各動作を行なっているか否かの離散的なクラスとする場合と、加速度や角速度のような慣性計測装置から得られる情報とする場合が存在する。近年では、ニューラルネットワークによる識別器生成がほとんどであり、動作を空間的にモデリングするために慣性計測装置を使用する研究が多い^(5, 6)。

一方で、出力となる動力や部品の増加による重量増加や、入力となる筋電位を計測する電極の増加による費用拡大という点から、多自由度を持つ筋電義肢の実用化は広まっていないのが現状である。これに対し、近年3Dプリンタが登場し、様々なものが簡易に作成できるようになってきた。この技術により、3Dプリントされた軽量で安価な筋電義肢を作成することが可能とな

り、社会に大きく貢献していくことが期待されている⁽⁷⁾。さらに、入力信号を計測する機器も発展してきている。具体的には、Bluetoothのような消費電力の小さい通信規格を内蔵し、スマートフォンやタブレットコンピュータのような演算機能を持つ機器へ計測したデータを転送、記録することができる機器（ウェアラブルデバイス）が存在する。これらは、演算機能を持つ機器を仲介させて、電極から得られたデータを用いて動作のモデリングおよび推定を行ない、3Dプリントされた軽量な筋電義手の動きを担うマイクロコンピュータへコマンドを送信し、遠隔操作できる可能性を秘めている。

本研究の前提として、操作すべき対象が身体に接触している場合も、直接干渉しないならば、遠隔操作であると考えている。本論文では、簡易で安価な遠隔操作システムを構築するために、ウェアラブルデバイスから得られた筋電位8チャンネル分を用いて、上肢8動作（指節間関節2種類、手関節4種類、および肘関節2種類）の分類を目的とする。このとき、識別器生成のために、ニューラルネットワークを用い、学習時のターゲットは各動作のクラスとする。

2. 実験

本論文では、ワイヤレスのウェアラブルデバイスである Myo armband (Thalmic Labs, Canada) を用いて8チャンネル分の筋電位をサンプリング周波数200 Hzで計測した。右腕の腕橈骨筋上に、通信ポートが存在するチャンネル4を配置した。他のチャンネルも含めすべての電極は、伸縮性のゴムバンドにより腕を一周するように配置されている。既製品を用いた場合、個人の筋の位置を配慮した電極の配置は難しい。また、たとえ同じ筋へ配置できたとしても、ある動作の実行する空間の使い方は無限に存在し、個人が持つ動かし方によって筋活動が異なるため、皮膚上の電極への混信具合に差が生じ、異なる信号が得られることがある⁽⁸⁾。そこで、より簡易な計測条件下での使用を目的として、チャンネル4以外は制約を設けずに装着した。

本実験には、15名の健常者（男性9名、女性6名、 22.50 ± 1.37 歳）と1名の先天性脳性麻痺患者（男性22歳）が参加した。被験者は、右腕の手関節と右肩関節が同じ高さになる位置で右腕を維持しつつ、着座状態で実験を行なった。このとき左手と右手の手のひらは向かい合わせる状態とした。8種類の上肢の動作を独立で行なった場合と、組み合わせた場合の計22種類の動作を行なった（Table 1 参照）。

Table 1 Movements included in the protocol based on the reference⁽¹⁾.

Block index	Movement index	Movements
1	1	Rest (Hand opening)
1	2	Wrist flexion
1	3	Wrist extension
1	4	Radial deviation
1	5	Ulnar deviation
2	6	Forearm pronation
2	7	Forearm supination
2	8	Hand closing
3	9	Forearm pronation & Wrist flexion
3	10	Forearm pronation & Wrist extension
3	11	Forearm pronation & Radial deviation
3	12	Forearm pronation & Ulnar deviation
4	13	Forearm supination & Wrist flexion
4	14	Forearm supination & Wrist extension
4	15	Forearm supination & Radial deviation
4	16	Forearm supination & Ulnar deviation
5	17	Hand closing & Wrist flexion
5	18	Hand closing & Wrist extension
5	19	Hand closing & Radial deviation
5	20	Hand closing & Ulnar deviation
5	21	Hand closing & Forearm pronation
5	22	Hand closing & Forearm supination

1 施行における各動作は 6 秒で構成されている。はじめの 1 秒は初期位置で何もせずに手を開いた状態で待機する (0-1 秒)。次の 1 秒に各動作の指示が PC のディスプレイに静止画と文字で表示される。この表示を確認した後に指示された動作を行ない、その状態を維持する (1-3 秒)。静止画と文字が変化した後、初期位置へ戻す (3-4 秒)。そして、2 秒間初期位置で待機する (4-6 秒)。この施行を各動作につき 4 回ずつ連続で行なう。これらの動作は 5 つのブロックに分けられ、各ブロックが終わったあと、筋疲労を避けるために、1 分から 5 分程度の休憩を挟んだ。

実験を行なう前に、インフォームドコンセントと各動作について説明を行ない実験に対する同意を得ている。また、各ブロックの前にも動作の確認を行なっている。

3. 解析

3.1 データ区間切り出し

実験により各動作のデータを 4 回分ずつ取得し、全体を正規化している。得られたデータの一部として、被験者 1 人の手関節の屈曲を行なったデータ 4 回分を Fig.1 に示す。

しかしながら、識別器生成のためには、計測された連続したデータから各動作を行なっている区間のデータを切り出す必要がある。本論文では、動作の指示が提示された 0.5 秒後から 2.0 秒後の初期位置に戻り始める前までの 1.5 秒間分のデータを切り出した。この切り出しのために、Psychtoolbox-3 を使用し、提示した時間を Myo armband による計測データと同期させた状態で記録している。これにより、各動作時の 4 回分のデータを切り出し、それぞれをこの後の処理のために統合した。

3.2 特徴抽出

切り出された動作時の信号から特徴量を抽出した。本論文では、特徴量に関して 3 種類のデータセットを用意した。1 種類目は、二乗値の平均値である⁽⁹⁾。これは非常にシンプルかつ一般的で、チャンネルと同じ次元数の特徴量が得られる。本論文の場合、次元数は 8 である (mean square value (MSV) feature set)。2 種類目は、Hudgins らが提案した時系列信号の特性に着




Fig.1 Surface EMGs from right forearm where the force of wrist flexion was recorded in an able-bodied subject.

目した 4 種類の特徴量である⁽¹⁰⁾。具体的には、絶対値の平均値、ゼロクロス回数、前後のサンプルと描く凸方向の反転回数、そして前サンプルとの差の和である。この手法では 32 次元の特徴量が得られる (time-domain (TD) feature set)。最後に、3 種類目は、二乗平均平方根と 6 次の自己回帰モデルのパラメータベクトルを 2 種類目に追加した特徴量である⁽¹¹⁾。これは、各チャンネルに対して 11 次元の特徴量が得られるため、次元数が 88 となる (TD autoregression (TDAR) feature set)。比較的大きい次元数となるため、主成分分析などにより次元圧縮すると良い結果が期待できるが、本研究ではリアルタイム性を保持することを優先し、そのままの状態の結果の比較を行なう。

それぞれの特徴量は、データの特定の窓長ごとに算出される。本論文では、この窓幅を 50, 100, 150, および 200 ms の 4 種類とした。この窓長は、ユーザが 300 ms 以内にシステムが動作するとストレスを感じないという先行研究による知見に基づき、さらに後処理や義肢の制御のための時間を考慮し、決定している⁽¹⁰⁾。オーバーラップはさせていない。したがって、各特徴量ごとに 4 種類、計 12 種類の特徴量データセットが用意された。

3.3 識別器生成

特徴量データセットを入力として、Levenberg-Marquardt 誤差逆伝搬法による多層ニューラルネットワークを生成する。このとき、1 自由度と 2 自由度の各クラスに対して出力するニューラルネットワークをそれぞれ生成する。したがって、2 つニューラルネットワークが生成される。1 自由度は 8 クラス、2 自由度は 14 クラス存在し、そのクラスのデータは 1、それ以外は 0 をターゲットとして与えられる。中間層は 1 つで、ニューロンの数は 10 とした。この数は、先行研究を参考に決定した^(1, 5)。また、中間層で双曲線正接関数、出力層で線形関数を活性化関数として用いている。損失関数は、平均二乗誤差に設定した。

3.4 精度検証方法

ニューラルネットワークにより生成された識別器の精度を検証するために、一人抜き交差検証法を用いる。被験者数が 16 名であるため、被験者 1 名分のデータをテスト、残りを学習データとして 2 種類の識別器を 16 回ずつ生成した。テストデータの特徴量は、学習データを基に標準化される。

出力層で得られた値の中で、最も大きな値を持つクラスが推定クラスとして判定される。各特徴量抽出手法および窓長による識別器の精度を、1 自由度と 2 自由度それぞれ総合的に比較するために、推定クラスの正解率を算出する。これにより、精度の傾向を検証する。また、ある窓長および特徴量抽出手法の組み合わせ時の推定されたクラスとターゲットクラスを比較し、正解および不正解の合計数を要素とする 8×8 の混合行列を得る。これにより、最も基礎の動作となる 1 自由度の各動作ごとの学習に関する比較も行なう。

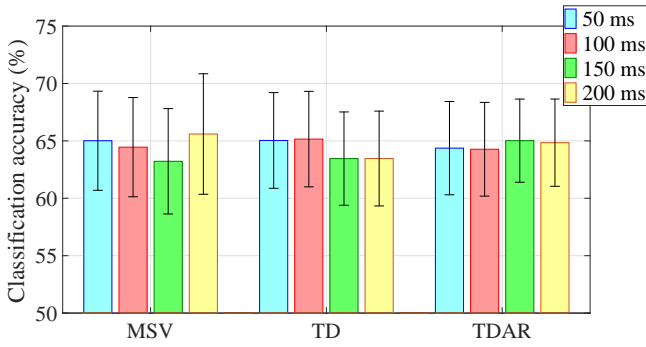


Fig.2 Effects on classification accuracy when using different feature sets and varying the size of window for feature extraction from one DOF movements.




Fig.3 Effects on classification accuracy when using different feature sets and varying the size of window for feature extraction from two DOF movements.

4. 結果および考察

4.1 特徴量と識別器

ニューラルネットワークにより出力された1自由度および2自由度の動作の推定精度に対する平均および標準偏差を，Figs.2 および 3 に示す．12 種類のデータセットから生成された識別器の全体的な精度は，1 自由度および 2 自由度に対して， 64.49 ± 16.29 および $47.03 \pm 10.37\%$ であった．1 自由度に対する識別器は 8 クラス分類，2 自由度に対する識別器は 14 クラス分類の結果である．1 自由度の場合，特徴量抽出手法および窓長によって有意差は得られなかった．一方，2 自由度の場合，特徴量抽出手法間では有意差は得られなかったが，窓長が大きくなるほど精度が向上することが示された．MSV と TDAR では 100 ms，TD では 150 ms で 50 ms の特徴量を用いた場合より有意 ($p < 0.05$) に精度が向上した．

筋電位を対象とした識別やモデリングの場合，時系列信号から特徴量を得ることが一般的であり，特徴量抽出が識別器生成より重要であることが知られている⁽¹²⁾．また，MSV より TD のほうが良い結果を示すことが知られているが，本論文では同様の傾向は得られなかった．これは，ウェアラブルデバイスのサンプリング周波数が従来の研究よりも低いことが原因であると考えられる．従来，筋電位は 1000 Hz や 1024 Hz をサンプリング周波数として設定されることが多い．表面筋電位の場合，力の入れ方や動作に関して 400 - 500 Hz の周波数成分が重要な特徴であることが知られている⁽¹³⁾．TD feature set は時系列信号から周波数成分に近い特徴量も抽出できるため，この特徴量をうまく抽出できる手法である．しかしながら，本研究で用いている機器のサ




Fig.4 Classification results under three different feature sets for each subject.

ンプリング周波数は 200 Hz である．つまり，従来研究では得られていた特徴量をうまく得ることが出来ていなかった可能性がある．一方で，サンプリング周波数が上がると無線機器で一定の通信量を維持することが困難となる．Myo では，0.5 Hz 分ほどサンプル数がずれていることがあった．したがって，ウェアラブルデバイスを用いる場合，周波数を向上させることより，適した特徴量を見つけるべきである．ただし，リアルタイム性を損なってはならない．識別器による処理時間も考慮すると，義肢を操作するための特徴量は 200 ms 以下の窓長から得ることが望ましい．

また，全体的な比較のみでなく，被験者ごとの識別器の精度を検証した．その結果を Fig.4 に示す．被験者 2 は，先天性の脳性麻痺患者である．下肢に関する麻痺が主体であるため，上肢に関してはある程度動作を行なうことが可能であった．しかしながら，健常者と比べ，関節の駆動域が狭いことが実験中に観測されていた．駆動域が狭さは筋活動量の少なさを意味する．したがって，必然的に筋電位の振幅が小さくなり，動作の識別が困難であったと考えられる．さらに，健常者の中でも振幅が小さい者が何名いることがわかった．本論文のようにクラスを識別するために 0 か 1 のような離散的なターゲットを学習させると，同じターゲットを持つデータの分布が広い場合，重なりやすくなる．振幅値の差が小さい状態を，時系列信号から識別するための有効な特徴量抽出が今後の課題である．分布が重ならないための実験デザインの構築や，力センサや加速度センサなどによる連続的なターゲットを用いた識別器の学習が今後求められる．

4.2 動作による識別精度の比較

窓長を 200 ms とした TDAR feature set を用いた識別器の各動作に対する推定精度を Table 2 に示す．回内/回外に関する推定が，他の動作よりも精度が低いことが示された．基本的に，これらの動作を担う筋（円回内筋，方形回内筋や回外筋）は骨に近い位置にあり，皮膚表面から情報を得ることが難しく，推定やモデリングが難しい動作として考えられている．しかしながら，これらの動作はドアノブをひねる時や，コップに水を注ぐ時のように，日常生活で必須の動作と言える．したがって，今後これらの動作の精度を向上させる必要がある．

本論文の場合，この点のみでなく，他にも推定の精度を下げていく可能性がある．それは，フリースペースで動作を行なったという点である．初期位置は共通位置としたが，実際にその位置に毎回戻っていたかが不明であった．手のひらを身体のほうに向けてということは，右手の親指が常に地面と垂直にならなければならない．これに対して，ヒトの手のひらは肘の位置が高くなるほど回内しやすくなる．本実験では，肩関節と同じ高さにしていったため，少しずつ初期状態が回内の状態になりつつあった可能性がある．今後角速度センサを取り入れ，正しく位置を合わせることができているかも検証していく必要がある．

Table 2 Confusion matrix for each movement from TDAR feature set with 200 ms window size (HO: hand opening, WF: wrist flexion, WE: wrist extension, RD: radial deviation, UD: ulnar deviation, FP: forearm pronation, FS: forearm supination, and HC: hand closing).

	HO	WF	WE	RD	UD	FP	FS	HC
HO	75.0	3.1	2.5	2.1	0.4	6.5	9.8	0.6
WF	3.5	72.3	0.4	2.3	2.7	7.9	5.0	5.8
WE	2.5	0.0	67.7	9.8	4.4	10.6	4.0	1.0
RD	5.2	4.6	14.6	65.2	0.2	8.3	1.7	0.2
UD	0.4	4.2	4.8	0.2	67.7	5.6	16.7	0.4
FP	10.8	11.9	9.8	9.2	6.5	35.4	12.1	4.4
FS	4.2	7.1	5.6	1.9	10.8	8.5	52.5	9.4
HC	0.8	1.5	1.7	0.6	3.3	6.3	2.9	82.9

5. おわりに

本論文では、簡易で安価な遠隔操作システムを構築するために、ウェアラブルデバイスから得られた筋電位 8 チャンネル分を用いて、上肢 8 動作の分類を目的とした。識別器生成のために、ニューラルネットワークを用い、学習時のターゲットは各動作のクラスとした。

結果として、1 自由度および 2 自由度に対して、 64.49 ± 16.29 および $47.03 \pm 10.37\%$ の精度が得られた。全体として同じ傾向は得られず、識別器生成に有効な特徴量抽出手法の特定はできなかった。一方で、窓長が長いほど精度が向上することや、回内/回外の動作が他の動作と比べ困難であるという点が、従来研究を支持する結果となった。

今後、ウェアラブルデバイスの「データ計測が容易」という利点を生かし、データを大量に取得し、主成分分析をはじめとした特徴量抽出を行ない、動作を判別するために重要な特徴量を調査する予定である。このとき、筋電位のみではなく、力センサや加速度センサを同時に用いることで、動作の空間的な学習および計測の再現性を向上させることを重視する。また、実環境で利用する際に、振動や電極のスライディングにより生じる入力信号の劣化を避ける方法も並行して進め、実環境下でストレスなく義肢を操作できるシステムの構築に取り組んでいく。

謝辞

本研究は科研費 (15J03395) の助成を受けたものである。

参考文献

- (1) S. Muceli and D. Farina, Simultaneous and Proportional Estimation of Hand Kinematics from EMG During Mirrored Movements at Multiple Degree-of-Freedom, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol.20, no.3, pp.371-378, 2012.
- (2) E. A. Clancy, C. Dai, M. Wartenberg, C. Martinez-Luna, T. R. Hunt, and T. R. Farrell, A Pilot Study Assessing Ipsilateral vs. Contralateral Feedback in EMG-Force Models of the Wrist for Upper-Limb Prosthesis Control, *IEEE Signal Processing in Medicine and Biology Symposium*, pp.1-8, 2015.
- (3) D. Blana, T. Kyriacou, J. M. Lambrecht, and E. K. Chadwick, Feasibility of Using Combined EMG and Kinematic Signals for Prosthesis Control: A Simulation Study Using a Virtual Reality Environment, *Journal of Electromyography and Kinesiology*, doi:10.1016/j.jelekin.2015.06.010.
- (4) C. L. Pulliam, J. M. Lambrecht, and R. F. Kirsch, Electromyogram-Based Neural Network Control of Transhumeral Prostheses, *Journal of Rehabilitation Research and Development*, vol.48, no.6, pp.739-754, 2011.
- (5) J. L. Nielsen, S. Holmgaard, N. Jiang, K. B. Englehart, D. Farina, and P. A. Parker, Simultaneous and Proportional Force Estimation for Multifunction Myoelectric Prostheses Using Mirrored Bilateral Training, *IEEE Transactions on Biomedical Engineering*, vol.58, no.3, pp.681-688, 2011.
- (6) A. G. Cutti, A. Giovanardi, L. Rocchi, A. Davalli, and R. Sacchetti, Ambulatory Measurement of Shoulder and Elbow Kinematics through Inertial and Magnetic Sensors, *Medical and Biological Engineering and Computing*, vol.46, no.2, pp.169-178, 2008.
- (7) exiii [Online], Available: <http://exiii.jp/index.html>.
- (8) D. W. Franklin and D. M. Wolpert, Computational Mechanisms of Sensorimotor Control, *Neuron*, vol.72, no.3, pp.425-442, 2011.
- (9) N. Jiang, K. B. Englehart, and P. A. Parker, Extracting Simultaneous and Proportional Neural Control Information for Multiple-DOF Prostheses from the Surface Electromyographic Signal, *IEEE Transactions on Biomedical Engineering*, vol.56, no.4, pp.1070-1080, 2009.
- (10) B. Hudgins, P. Parker, and R. N. Scott, A New Strategy for Multifunction Myoelectric Control, *IEEE Transactions on Biomedical Engineering*, vol.40, no.1, pp.82-94, 1993.
- (11) Y. Huang, K. B. Englehart, B. Hudgins, and A. D. Chan, A Gaussian Mixture Model Based Classification Scheme for Myoelectric Control of Powered Upper Limb Prostheses, *IEEE Transactions on Biomedical Engineering*, vol.52, no.11, pp.1801-1811, 2005.
- (12) L. J. Hargrove, K. Englehart, and B. Hudgins, A Comparison of Surface and Intramuscular Myoelectric Signal Classification, *IEEE Transactions on Biomedical Engineering*, vol.54, no.5, pp.847-853, 2007.
- (13) P. Liang, C. Yang, Z. Li, and R. Li, Writing Skills Transfer from Human to Robot Using Stiffness Extracted from sEMG, *IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems*, pp. 19-24, 2015.