

筋電義手の前腕 17 動作識別のための周波数領域における特徴量解析

Classification of 17 Voluntary Movements Based on Spectral Features for Myoelectric Prosthetic Hand

○ 銭智定（電機大） 中西絵美（電機大） 劉超（電機大） 石川潤（電機大）

Satoshi SEN, Tokyo Denki University
Emi NAKANISHI, Tokyo Denki University
Chao LIU, Tokyo Denki University
Jun ISHIKAWA, Tokyo Denki University

Abstract: This paper presents a signal processing technique that uses spectral features and artificial neural network (ANN) to classify 17 voluntary movements from electromyographic (EMG) signals. In this study, EMG signals are recorded using six EMG sensors. To evaluate the validity of the proposed method, online classification experiments have been conducted on one male and one female participants. The results show that despite the large quantity of discriminating classes, an overall correct classification rate of 41-64 % can be achieved using the proposed method. Furthermore, classification where ANN is trained using training data acquired on a different day has achieved an overall correct rate of 21-46 %. Based on the above results and considering the fact that users can promptly modify any erroneous actions by looking at the actual output of the prosthesis, the proposed algorithm has demonstrated the potential to classify 17 voluntary movements from 6 EMG sensors.

Key Words: Artificial Neural Network (ANN), Brain Machine Interface (BMI), Electromyogram (EMG), Prosthetic Hand

1 はじめに

原厚生労働省の平成 18 年度身体障害児・者実体調査によると，日本には上肢切断者が約 8 万人存在する⁽¹⁾。この上肢切断者がより不自由なく日常生活を送れるようにするために，筋電義手の開発が盛んに行われている。後天的に上腕を失った人は，切断する以前にあった腕や手などの切断部を動かす感覚がある。これを幻肢といい，ときに失われた手を感じ痛みなどが伴う場合もある⁽²⁾。筋電義手は幻肢を動かす際に発生する筋電位信号を利用している。この筋電義手の制御を目的とした筋電信号の動作識別に関しては数多くの研究が行われており，たとえば，文献(3)では，7 つの筋電センサを用いて，前腕 8 動作をサポートベクターマシンにより識別を行っている。また，文献(4)では，筋電以外に脳波も活用し，筋電義手の性能改善を試みている。この研究においても，前腕 8 動作のみが識別対象となっている。このように，識別対象の動作は主に前腕動作のみとなっており，5 指随意動作に関する研究は少ないのが現状である。筋電義手に，前腕動作に加え，5 指随意動作を実現することができれば，使用者が実際の上肢の動きに近い，より自然な動作制御が可能となる。さらに，機構の工夫により少数のアクチュエータで多種の筋電の動作を実現する筋電義手の登場も期待されている。

本研究では，今後出現するであろう多自由度の筋電義手のハードウェア向けにできるだけ少ないセンサの数で，より多くの前腕動作が識別できるようなシステムの構築を目指す。具体的には，6 つの筋電センサを用いて，休憩を含む前腕 17 動作を識別するためのシステムの一構成法を提案する。以下 2 章では，筋電信号の基本的な信号処理方法について述べ，3 章では，周波数解析に基づく特徴ベクトルの抽出と，ニューラルネットワークによる識別アルゴリズムについてまとめる。4 章では，提案するシステムの有効性を識別率の観点から評価した実験及び実験結果について述べる。

2 筋電信号の基本的な信号処理

本章では，識別アルゴリズムを説明する上で前提条件と

なる筋電センサの数や，その貼付位置，さらに特徴抽出のための元信号を生成するための基本的な信号処理について述べる。

本研究で識別の対象とする前腕 17 種の動作は，前腕の回内，回外，屈曲，伸展，握り，及び開きの 6 種類 (Fig. 1) と 5 指それぞれの屈曲伸展動作計 10 種，さらにこれに休憩を加えたものである。これら 17 種の動作を識別するため，著者らの先行研究⁽⁵⁾を基に，Fig. 2 に示す左腕の 6 箇所（撓側手根屈筋，尺側手根屈筋，深指屈筋，長拇指屈筋，長撓側手根伸筋，長拇指伸筋）に筋電センサを貼り付け，基準電極は左肘部に取り付けた。

使用する筋電センサは追坂電子製の IDPAD シリーズであり，筋電信号は 2.5 V を基準に生成される。特徴ベクトル抽出を行う前に，この筋電信号からオフセットを除去する。

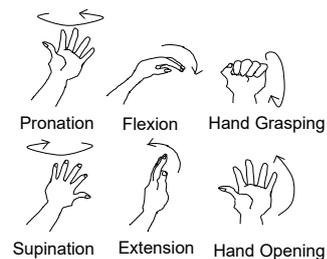


Fig. 1 Six forearm motions

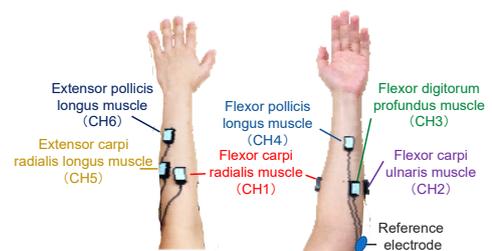


Fig. 2 Electrode placement. The six electrodes are selected with reference to previous work⁽⁵⁾

3 前腕動作の識別アルゴリズム

本章では，計測した筋電信号から 17 動作を識別する提案手法について述べる．提案手法では，まず前章で述べた基本的な信号処理を施された筋電信号を高速フーリエ変換する．次に，得られたパワースペクトラム密度から各動作の特徴点を抽出し，特徴ベクトルを生成する．最後に，特徴ベクトルを基に学習したニューラルネットワークを用いて，前腕動作を識別する．以下では，これらの手順について具体的に述べる．

3.1 周波数解析に基づく特徴抽出

本節では，筋電信号から各動作の特徴を抽出するための信号処理について述べる．特徴抽出では，まず前章で述べた基本的な信号処理を施された筋電信号に対し，窓関数をかけて高速フーリエ変換（Fast Fourier Transform: FFT）を行う．使用する窓関数はハミング窓であり，その窓幅は 32 サンプルである．また，オーバーラップを 25% とし，8 回の平均値を用いている．なお，オーバーラップ窓関数を使用した FFT は，一般にウェルチ法と呼ばれる．続いて，計算した FFT の結果からパワースペクトラム密度を計算する．次に，計算されたパワースペクトラム密度から各動作の特徴を抽出し，特徴ベクトルを生成する．具体的に，特徴ベクトルの成分は各チャンネルにおける 18.75 Hz, 25 Hz, 31.25 Hz, 68.75 Hz, 75 Hz, 81.25 Hz のときのパワースペクトラム密度の大きさをログスケールで表現したものである．したがって，特徴ベクトルは 36 次元（6 チャンネル×6 周波数成分）であり，17 動作を m セットを学習に用いる場合，特徴ベクトルをまとめた行列は

$$F = [f_1 \ \dots \ f_i \ \dots \ f_{36}]$$

$$= \begin{bmatrix} f_1(0) & \dots & f_i(0) & \dots & f_{36}(0) \\ \vdots & & \vdots & & \vdots \\ f_1(j) & \dots & f_i(j) & \dots & f_{36}(j) \\ \vdots & & \vdots & & \vdots \\ f_1(17m) & \dots & f_i(17m) & \dots & f_{36}(17m) \end{bmatrix} \in \mathcal{R}^{17m \times 36} \quad (1)$$

となる．この各動作 m セット分の特徴ベクトルの成分は，

$$\tilde{f} = \left[\frac{f_1}{\min(f_1)} \ \dots \ \frac{f_i}{\min(f_i)} \ \dots \ \frac{f_{36}}{\min(f_{36})} \right] \in \mathcal{R}^{17m \times 36} \quad (2)$$

のように振幅を正規化したのち，次節で説明するニューラルネットワークの学習に用いる特徴ベクトルとなる．

オフセット除去後の基本処理を済ませた筋電信号の時系列から，時刻 k におけるニューラルネットワークへの入力信号，すなわち正規化された特徴ベクトルは

$$T = [t_1(k) \ \dots \ t_i(k) \ \dots \ t_{36}(k)]$$

$$= \left[\frac{t_1}{\min(f_1)} \ \dots \ \frac{t_i}{\min(f_i)} \ \dots \ \frac{t_{36}}{\min(f_{36})} \right] \in \mathcal{R}^{1 \times 36} \quad (3)$$

のようにリアルタイムに計算することができる．なお， $\min(f_i)$ ($i=1,2,\dots,36$) は， m セットの事前実験により求めた値を使用する．

3.2 人工ニューラルネットワーク

本節では，前腕 17 動作の識別を行う上で必要となる人工ニューラルネットワーク（Artificial Neural Network: ANN）の学習について述べる．

学習に用いるデータは，180 秒間で 17 動作を順に行うものを 1 セットとし， m セットを使用する．なお，信号のサ

ンプリング周波数は 200 Hz である．これら m セットのデータから式(1)に定義したように，各セットから動作に対応した 17 点のパワースペクトラム密度を選ぶ．すなわち，学習に用いる特徴ベクトルの行列(2)は各セットごとに 17 動作が順に並んでいるので，対応する教示信号は

$$T = [I_{17} \ I_{17} \ \dots \ I_{17}]^T \in \mathcal{R}^{17m \times 36} \quad (4)$$

となる．

筋電信号の主成分からなる特徴ベクトルから 17 動作を識別するために，識別器としてフィードフォワード型の人工ニューラルネットワークである多層パーセプトロンを用いる．多層パーセプトロンは，入力層，中間層，出力層の 3 層からなる ANN である．

多層パーセプトロンでは，学習データである特徴ベクトルと教示信号を用意し，学習データをうまく表現できる，すなわち ANN の出力が教示信号 T と一致するようにパーセプトロンのパラメータ（中間層と出力層の重みや閾値）を機械学習により獲得していく．機械学習では，誤差逆伝播法を用いて，入力した学習データに対して対応する出力データとネットワークの出力の誤差が小さくなるように，入力層から中間層および中間層から出力層への結合荷重と閾値の調整を行う⁽⁶⁾．オンライン識別の際には，これらのパラメータを固定して用いる．

4 実験

4.1 実験条件

実験では，20 代の男性健常者 1 名（協力者 A）と 20 代の女性健常者 1 名（協力者 B）に対して筋電信号の計測を行った．なお，本実験は，東京電機大学ヒト生命倫理審査委員会の承認を得て実施している．実験では，まず，学習用データを得るために，Fig. 3 に示す実行順序に従い 17 動作時の筋電信号を取得した．そして，この一連の動作を協力者 1 人あたり 5 セット実施した．次に，識別用のデータを取得するために，同様の動作順序で新たに 10 セットを行った．この 1 人あたり学習用 5 セット，識別用 10 セットの計測は，日を変えて 2 回実施した．

本実験では，2 日間の実験中から 1 日分の学習データ 5 セットを用いて ANN の学習を行った．提案手法の有効性を確認するために，同日に取得した識別用データ 10 セットに対してオンライン識別を行った．また，上記で選択した 1 日分の学習結果を用いて，異なる日に取得した識別用データ 10 セットに対する識別性能も評価し，学習結果の経時変化に対する学習結果の有効性についても検討する．結果として，1 協力者あたり，Table 1 に示したような 4 通りの組み合わせで評価する（同表には後述の実験結果に対応する図番号も併記されている）．なお，今回は，識別率および誤識別率を評価指標として用いる．識別率と誤識別率は以下のように定義する．Fig. 4 に示すように，識別率は，教示信号の区間内で ANN の識別信号が出ている部分の面積（Fig. 4 中の緑の網掛け部分）と教示信号内の面積の比として定義される．誤識別率は，教示信号の区間外の ANN の識別信号が出ている部分（Fig. 4 中の赤の網掛け部分）と教示信号外の面積の比として定義される．そして，この識別率および誤識別率を各動作ごとに算出する．今回の実験では，ANN の入力層のニューロセルの数は 36，出力層のニューロセルの数は 17 となる．また，試行錯誤により中間層のニューロセルの数は 20，誤差逆伝播法の学習係数は 1.2 とした．

Table 1 Classification Conditions

Condition Number	Training Data	Classifying Data	Participant	Figure Number
1	Day 1	Day 1	A	Fig. 5
2	Day 2	Day 2	A	
3	Day 1	Day 2	A	Fig. 6
4	Day 2	Day 1	A	
5	Day 1	Day 1	B	Fig. 7
6	Day 2	Day 2	B	
7	Day 1	Day 2	B	Fig. 8
8	Day 2	Day 1	B	

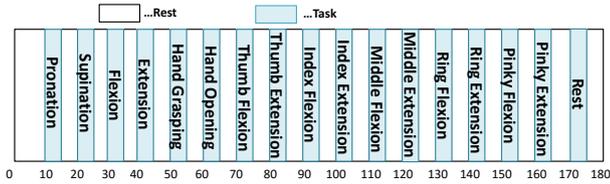


Fig. 3 Execution sequence of 17 motions (including rest state). Each motion is executed for five seconds with a five second resting interval in between each motion. The total duration of each run is 180 seconds. The feature point for rest state is selected between 170 to 175 seconds.

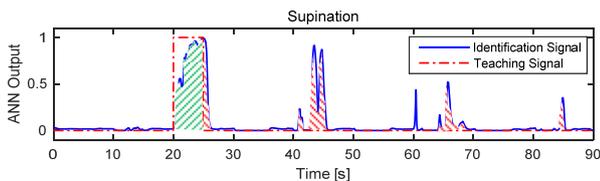


Fig. 4 Definition of correct and incorrect rates. The blue line indicates the identification signal. The red dashed dotted line indicates teaching signals. The green hatched area represents correct classification. The red hatched area represents incorrect classification.

5 実験結果

図 8 から図 15 に実験結果を示した。各図のグラフは(a)が識別率，(b)が誤識別率となっており，10 回の平均値を棒グラフで示している。また，10 回の識別率・誤識別率の標準偏差を同図にエラーバーとして示している。各図の条件は既出の表 1 に示したとおりである。たとえば，比較的識別率の良かった実験条件 2（協力者 A，Day 2 学習，Day 2 識別）や実験条件 6（協力者 B，Day 2 学習，Day 2 識別）では，実験を重ねることで誤識別率を悪化することなく識別率が改善される傾向が認められ，いずれの場合も 2 日目では 17 動作中 9 動作が識別率 50 %以上となっている。実際に筋電義手を用いる際は，使用者は義手の動きを見て修

正対応ができることを考慮すれば，6 つのセンサによる 17 動作の識別の実現に一定の可能性を示すことができたと考えられる。また，学習データを取得した日と異なる日に取得した識別データの評価結果からは，実験条件 3（協力者 A，Day 1 学習，Day 2 識別）の場合を除き，17 動作中 6 動作が識別率 50 %以上となっている。この結果から，提案手法を用いることで，識別器を再学習しなくてもある程度の識別性能を維持することができる。これは，筋電義手を日常的に使っていくうえで，再学習の回数を減らすことにつながれると考える。

また，Table 2 に 17 動作×10 セット，すなわち 170 点の識別率および誤識別率をすべてまとめて平均した結果を，その標準偏差とともに示した。さらに，各識別条件における 10 セット中の最高および最低識別率も示した。上記で議論した動作ごとの評価結果と同様に，平均的に見ても，学習データと同じ日に取得した識別データの評価では，2 名の協力者のいずれの場合においても，二日目の識別結果の方が，全体の平均識別率が上がることを確認した。また，最高識別率からは，条件が良ければ 60 %程度以上の識別率が実現できる可能性があることがわかり，今後，使用者のトレーニング方法の検討なども含めて，実用レベルの識別率の実現を目指していく。

6 おわりに

本稿では，6 個の筋電位センサを用いて，前腕動作 6 動作，5 指の動作 10 動作，休憩の 17 動作を識別する一手法を提案した。提案手法は，筋電信号のパワースペクトラム密度を特徴点とし，人工ニューラルネットワークにより，多種類の動作の識別を行うことを特徴としている。本手法の有効性を評価するために，17 動作の識別率および誤識別率を評価した。その結果，協力者が学習データを 5 セット分用意することで，同日の評価で 41-64 %の全体識別率が得られ，日が異なる場合でも 21-46 %の全体識別率が得られた。つまり，本手法では，識別器を再学習しなくても，ある程度の識別性能を維持することができた。実際に筋電義手を用いる際は，使用者は義手の動きを見て修正対応ができることを考慮すれば，本提案手法による筋電義手の多種動作識別への可能性を示すことができた。

参考文献

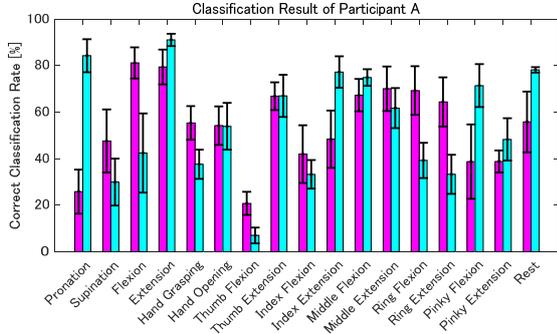
- (1) 厚生労働省社会・援護局障害保健福祉部企画課：“平成18年身体障害児・者実態調査結果”，pp. 3-4，厚生労働省，2008.
- (2) B. Subedi and G. T. Grossberg, “Phantom Limb Pain: Mechanisms and Treatment Approaches,” *Pain Research and Treatment*, Vol. 2011, pp. 1-8, 2011.

Table 2 Overall Classification Results [%] (Mean ± Standard Deviation)

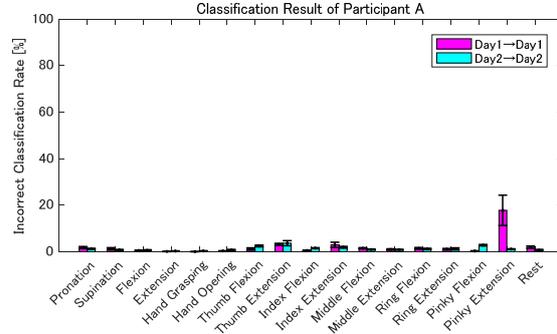
Condition Number	Training Data	Classifying Data	Participant	Average Correct Rate	Average Incorrect Rate	Highest Correct Rate	Lowest Correct Rate
1	Day 1	Day 1	A	54 ± 25	2 ± 5	64 ± 20	41 ± 30
2	Day 2	Day 2	A	55 ± 28	1 ± 1	61 ± 28	44 ± 25
3	Day 1	Day 2	A	26 ± 28	2 ± 2	31 ± 33	21 ± 22
4	Day 2	Day 1	A	36 ± 31	2 ± 2	42 ± 31	26 ± 34
5	Day 1	Day 1	B	52 ± 33	1 ± 1	59 ± 31	46 ± 35
6	Day 2	Day 2	B	59 ± 30	1 ± 2	64 ± 28	54 ± 33
7	Day 1	Day 2	B	40 ± 35	1 ± 1	46 ± 37	32 ± 37
8	Day 2	Day 1	B	42 ± 32	2 ± 2	46 ± 32	31 ± 35

- (3) P. Shenoy, K. J. Miller, B. Crawford and R. P. N. Rao, "Online Electromyographic Control of a Robotic Prosthesis," *IEEE Transactions on Biomedical Engineering*, Vol. 55, pp. 1128-1135, 2008.
- (4) K. Kuniyasu and J. Ishikawa, "Operability Improvement for Myoelectric Prosthetic Hand Using Brain Machine Interface Identification of Eight Forearm Motions Based

- on Myoelectric Potential," *IEEE International Conference on Systems, Man, and Cybernetics*, pp. 3083-3088, 2013.
- (5) 神林明日香, 國安夏奈, 錢智定, 石川潤: "筋電義手の5指随意動作識別に関する研究", 日本ロボット学会, RSJ2014AC3B1-07, 2014.
- (6) 小高知宏: はじめての機械学習, オーム社, 2011.

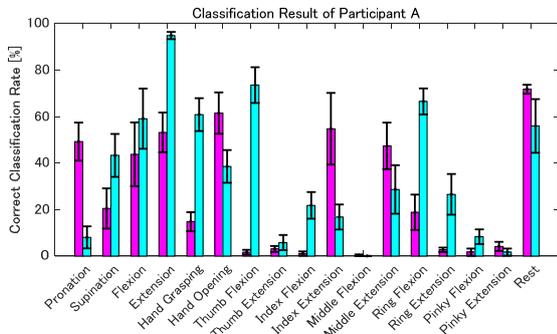


(a) Correct classification rate

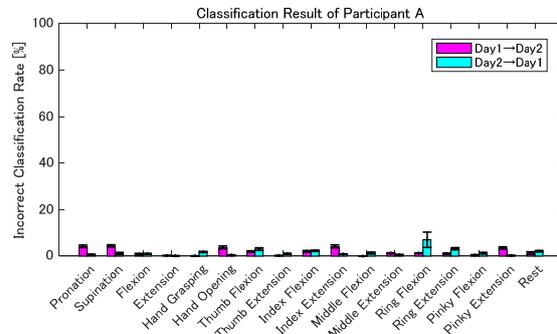


(b) Incorrect classification rate

Fig. 5 Classification results of participant A. Training data sets and testing data sets of the same day are used.

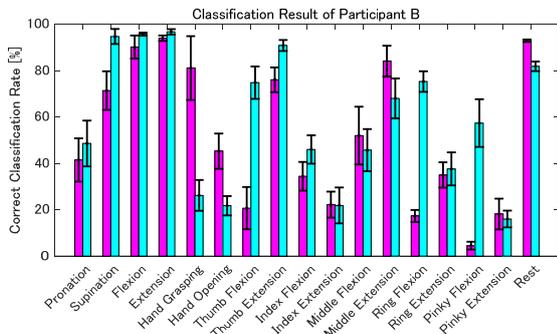


(a) Correct classification rate

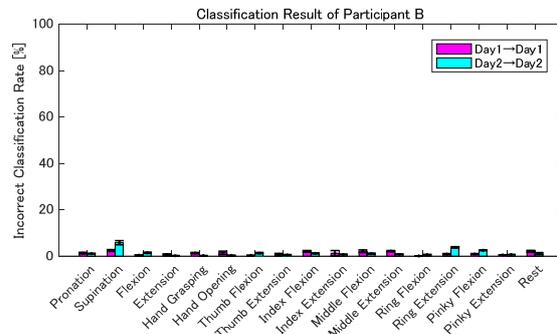


(b) Incorrect classification rate

Fig. 6 Classification results of participant A. Training data sets and testing data sets of different day are used.

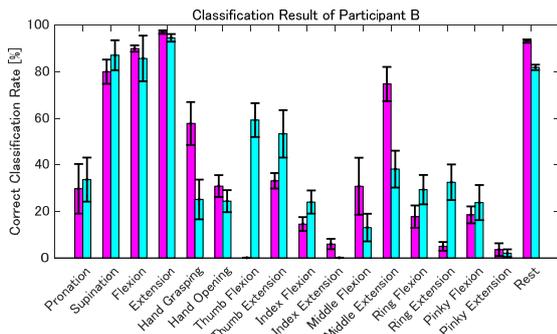


(a) Correct classification rate

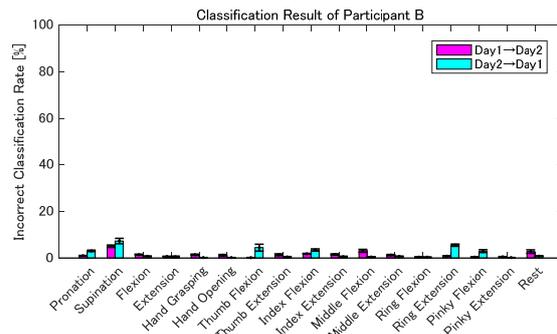


(b) Incorrect classification rate

Fig. 7 Classification results of participant B. Training data sets and testing data sets of the same day are used.



(a) Correct classification rate



(b) Incorrect classification rate

Fig. 8 Classification results of participant B. Training data sets and testing data sets of different day are used.