

## 筋電信号による回内・回外動作識別手法の提案

## Technique for Discrimination between Seven Motions

## Including Wrist Pronation and Wrist Supination Using Real-Time EMG Signals

辻内伸好 (同志社大)      ○山本哲史 (同志社大院)      小泉孝之 (同志社大)

Nobutaka TSUJUCHI, Doshisha University

Tetsushi YAMAMOTO, Graduate School, Doshisha University

Takayuki KOIZUMI, Doshisha University

**Abstract:** The objective of this study is to develop a method of discriminating real-time motion from electromyogram (EMG) signals. We previously proposed a real-time motion discrimination method. This method could discriminate between five motions at a rate of above 90 percent from EMG signals in the forearm. Moreover, the discrimination processing time made was less than 300 ms by using the hyper-sphere models. However, forearm amputees cannot go about their daily life comfortably by using only five motions. We think that wrist pronation and wrist supination are important in daily life. Here, we propose a real-time motion discrimination method for seven motions: hand opening, hand closing, hand chucking, wrist extension, wrist flexion, wrist pronation, and wrist supination. Furthermore, we also created new hyper-sphere models to maintain real-time motion discrimination. We experimentally verified that the discrimination accuracies were 90 percent and the discrimination processing time was less than 300 ms.

**Key Words:** electromyogram (EMG), prosthetic hand, real-time, wrist pronation, wrist supination

## 1. 諸言

手や指は、人の知的活動のほとんどを具体化する器官であり、日常生活を支える最も重要な部分を担っている<sup>(1)</sup>。そのため、多くの上肢切断者はそれぞれの目的に合わせた様々な義手を使用している。その中で、筋電義手は、見栄えがよく、筋電信号を制御入力とするため動作時の姿勢に制約がないことから、大変注目されている。筋電義手の制御に関して、筋肉から計測された筋電信号のパターンと動作の関係を識別器により学習し、動作意図を推定する手法が使用されている。しかし、行いたい動作と実際に行う動作が異なる場合があり操作が難しい。そこで、直感的な操作を可能とする識別手法の開発が考えられる<sup>(2),(3),(4)</sup>。

動作識別には、非線形な EMG 信号を判別できるという理由から、ニューラルネットワークが多くの研究で用いられている。それらの研究において、目標とする識別可能な動作は多くなっている<sup>(5)</sup>。しかし、ニューラルネットワークの学習には、多大な時間を必要とし、学習が収束しない場合や局所解となる場合がある<sup>(6),(7)</sup>。また、筋電義手の多くは肘動作を識別する動作のどれかであると誤識別してしまう。これらに対して、過去に我々が提案した超球モデルを使用した動作識別手法は、短時間で学習が可能で、肘動作を全く誤識別せずに、手の開き、握り、摘み、手首の伸展、屈曲の 5 動作について、90%以上の識別精度が得られることを実証した。さらに、筋電信号を計測し、識別動作を得られるまでの時間を 300ms 以下にするリアルタイム動作識別を実現した<sup>(8)</sup>。一般的に 300ms を超えると、使用者は遅れを感じると言われている<sup>(2)</sup>。しかし、日常生活の中で行う動作は 5 動作ではまかなうことができないと考えられる。識別可能な動作数を増やすことが、上肢切断者の生活の水準を高めるために重要になってくる<sup>(9)</sup>。ここで、手首の回内、回外動作は、日常生活において字を書く、鍵をかけるといった様々な用途があると考えられる。

本研究では、超球モデルを用いた、手の開き、握り、摘み、手首の伸展、屈曲、回内、回外の 7 動作のリアルタイム動作識別手法を提案する。7 動作に対してリアルタイム動作識別を維持するために、新たな超球モデルの作成に取

り組んだ。実験では、7 動作の識別を行い、識別精度と識別処理時間を計測する。また、肘動作による誤識別の有無も同時に確認することで、提案手法の有効性を検証する。

## 2. 理論

図 1 に構築するシステムを示す。システムは、前処理、特徴抽出、識別器から成る。前腕部から計測し、整流及び平滑化した筋電信号から特徴を抽出する。その特徴から超球モデルを用いて、動作識別を行う。ここで、識別する動作は、手の開き、握り、摘み、手首の伸展、屈曲、回内、回外の 7 動作とする。




Fig.1 Motion Discrimination System

## 2-1 前処理

前腕部と上腕部の 5 箇所から筋電信号を取得し、前処理部でハイパスフィルタ及びノッチフィルタ処理、整流化、移動平均による平滑化を行う。図 2 に位相遅れが 0 のローパスフィルタ、100 点、150 点、300 点の移動平均によりそれぞれ平滑化した筋電信号の総和を示す。図 2 より、位相遅れが 0 のローパスフィルタよりも、100 点の移動平均は約 50ms、150 点の移動平均では約 75ms、300 点の移動平均では約 150ms の遅れが生じているという傾向が見られた。また、ハイパスフィルタとノッチフィルタによる遅れは約 20ms であったことから、平滑化による遅れの影響が大きいと考えられる。




Fig.2 Filtering Delay

## 2-2 特徴抽出

図3に動作*i*と動作*j*を識別する場合の超球モデルによる決定領域を示す。図3(a)のように、各チャンネルで計測される筋電信号の大きさを軸にとった空間において、各動作の筋電信号が描く軌跡を覆うように決定領域を設定している。しかし、図3(b)に示すように、描かれる軌跡が近接していると、決定領域が小さくなってしまふ。そこで、二次多項式を用いて十分大きな決定領域を得るために特徴空間に軌跡を射影する。

筋電信号から識別する動作*i*の特徴量 $f_{q_i}$ を次式に示す二次多項式により表す。

$$f_{q_i} = \sum_{l \leq m=1}^L a_{lm} emg_l emg_m + \sum_{l=1}^L b_{il} emg_l + c_i \quad (2.1)$$

ここで、 $a$ ,  $b$ ,  $c$ は係数であり、学習により求めるパラメータである。この係数は、以下の式に示す教師信号を用いて最小二乗法により推定する。

$$ts_k = \begin{cases} S - e & (i = k) \\ d(S - e)(i \neq k) \end{cases} \quad (2.2)$$

$i$ はピークの数を表す。 $d$ は0より大きく1より小さい値をとる係数である。 $e$ は閾値であり、筋電信号の総和 $S$ が閾値 $e$ 以上の間は動作が行われているとする。また、総和 $S$ が閾値 $e$ 以下の時は動作を行っていないとし、教師信号 $ts_n$ は0とした。これにより、対応する動作を行った時に教師信号は最も大きい値となる。なお、入力である筋電信号と教師信号をリアルタイムで計測することが可能であるため、係数の推定に時間はかからない。




Fig.3 Example of Decision Regions using Hyper-Sphere Models

## 2-3 識別器

図4に特徴空間上における動作の軌跡と超球モデルにより作成した決定領域を示す。動作の立ち上がりに着目することで、複雑な特徴軌跡を描いた場合においても決定領域内に素早く入るため、識別処理時間の短縮につながる。また、超球モデルは超球の決定領域を複数組み合わせることで、複雑な決定領域を生成することが可能である。このように、特定の動作に対して複雑な決定領域を設定できるため、肘動作などの他の動作を誤識別することを防ぐことが

可能である。動作*i*に対応する動作信号 $msh_i$ は、

$$msh_i = \|\mathbf{feature} - \mathbf{s}\| \mathit{sign} \left\{ \sum_{j=1}^J f(r_{ij} - \|\mathbf{feature} - \mathbf{c}_{ij}\|) \right\} \quad (2.3)$$

である。ここで、係数ベクトル $\mathbf{c}$ は超球の中心ベクトル、 $r$ は超球の半径、 $\mathbf{s}$ は1番目の超球の中心ベクトル、 $J$ は超球の数である。識別する動作における超球モデルを作成し、作成した動作信号のうち、正かつ最大の値となる動作信号に対応する動作を識別結果とする。

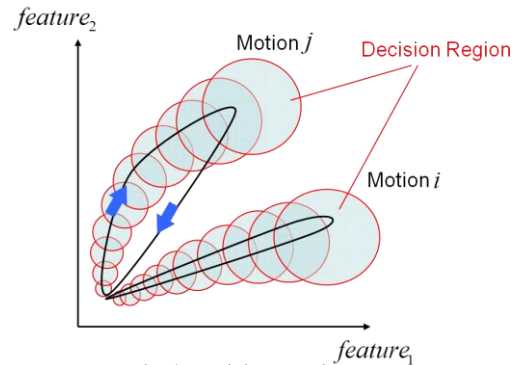


Fig.4 Decision Regions

## 3. 実験

### 3-1 実験条件

実験システムの全体図を図5に示す。被験者の前腕部と上腕部に設置した表面電極から測定した筋電信号を、DSPを介してホストコンピュータに取り込み、ホストコンピュータ内部に設計したシステムにより、ディスプレイに表示した3Dハンドモデルの操作を行った。

筋電信号の計測には、ハラダハイパープレジジョン社製の表面筋電位測定器(電極分離型 EMG-025)を用いた。また、筋電信号は双極誘導法によって計測し、電極には Ambu 社製のディスプレイ電極 (Blue Sensor P-00-S) を使用した。増幅した筋電信号は A/D 変換 (サンプリング周波数 400[Hz], 分解能 16[bit]) を行い、DSP に入力した。電極の配置位置は、前腕部の伸筋、屈筋、斜骨筋、伸筋と屈筋の間、上腕筋の計 5ch を配置するが、専門知識のない人が使用することを想定し、電極の配置位置は厳密に決めない。アース電極は筋肉のない肘に配置することによりクロストークを防止する。DSP および A/D 変換部には、dSPACE 社製のモジュラ型ハードウェア DS1005 (PowerPC 800[MHz]) および入出力ボード DS2002, DS2103, DS3002 を用いた。ホストコンピュータに、DELL 社製の PC/AT 互換機 (Core 2 Duo, 3.16[GHz], 2[GB], OS: Windows XP) を使用し、制御系 CAD ソフト MATLAB/Simulink を用いてシステムを設計した。3D ハンドモデルは dSPACE 社製ソフトウェア Motion Desk によって構築した。

入力した筋電信号は、10 次の IIR フィルタで構成した 20[Hz] のハイパスフィルタと、10 次の IIR フィルタで構成した 60[Hz] のノッチフィルタに通した後、整流化した。その後、150 点の移動平均で平滑化した。従来の手法では 300 点の移動平均で平滑化していたが、超球モデルでは複雑な決定領域を生成でき、平滑化に用いる移動平均の点数を少なくしても高い識別率を得ることができる。そして、識別器により出力された動作識別結果から 3D ハンドモデルを操作する。筋電信号の総和に閾値を設置し、筋電信号の振幅の総和が閾値を超えている限り動作が行われ継続されているものとし、また、筋電信号の振幅の総和が閾値以下の際は、何の動作も行っていないものとした。




Fig.5 Experimental System

### 3-2 実験方法

被験者は、健康な成人5名(A, B, C, D, E)とし、うちの被験者A, Bは実験の経験者であり、被験者C, D, Eは、今回初めて実験に参加した。未経験者は本システムに慣れるため、1時間から2時間の練習後に実験を行った。

教師信号を生成するために、被験者に手の開き、握り、摘み、手首の伸展、屈曲、回内、回外動作を各1回ずつ行うように指示した。次に、特徴抽出に用いる二次多項式の学習を行うために、被験者に各動作を各5回ずつ行うように指示した。特徴抽出の教師信号の係数 $d$ は0.2とし、閾値 $e$ は0.075とした。さらに、二次多項式の学習後、超球モデルの学習を行うため、被験者に前腕部の動作を各1回ずつ行うよう指示した。超球モデルの動作信号の閾値は0.2とし、動作継続のための筋電信号の総和の閾値は0.008とした。また、超球の数は各動作10個とする。

#### 3-2-1 識別精度、識別処理時間の検証実験

識別精度と識別処理時間を検証するために、15秒間に、手の開き、握り、摘み、手首の伸展、屈曲、回内、回外動作を順に行うことを1セットとし、被験者に20セット行うように指示した。そのうち成功した回数により識別精度を求めた。動作中に少しでも異なる動作を識別した場合、及び、何の動作も識別しなかった場合は、識別失敗とした。20セット終了後、肘動作を誤識別しないことを確かめるために、肘の代表的な動作を行うように指示した。

また、図6に識別処理時間の決定法を示す。(平常時における筋電信号の総和の標準偏差の3倍+平均値)を筋活動開始とした。そして、各動作の識別結果を得る時間との差を識別処理時間とし、それを計測した<sup>(10),(11)</sup>。




Fig.6 EMG Onset

## 4. 結果及び考察

### 4-1 超球モデルの作成

被験者A, Bによる先行実験の結果から、各被験者について識別精度が90%を下回る動作があった。そして、被験者Aについては、識別処理時間が300msを上回る動作があった。以上の結果から、識別精度が低く、使用者が動作に遅れを感じる結果となったため、従来の超球モデルは7動作のリアルタイム動作識別手法に有効でないと考える。そこで、識別処理時間に着目して、7動作のリアルタイム動

作識別手法に有効な新たな超球モデルの作成を行う。

例として、図7に被験者Aの3動作の特徴軌跡を3次元の特徴空間に表す。特徴軌跡の始点は共通であるので、特徴軌跡同士が立ち上がり部分において近接していると考えられる。このことを考慮し、超球の配置を変え、立ち上がりの部分の配置を密にすることにより識別処理時間の短縮を図る。従来の超球モデルは、超球間の距離が等距離間隔であった。今回作成したモデルは、配置する超球10個のうち、特徴軌跡の始点から前半5個の超球間距離と後半5個の超球間距離の比率を変えた4種類である。これを図8に示す。これらのモデルについて、被験者Aの先行実験の結果をもとにシミュレーションを行い、有効性を検証した。




Fig.7 Example of Feature Trajectory




Fig.8 Example of four types of Hyper-Sphere Models. (a) 2:3 hyper-sphere models, (b) 1:2 hyper-sphere models, (c) 1:3 hyper-sphere models, and (d) 1:4 hyper-sphere models

### 4-2 シミュレーションによる超球モデルの有効性検証

シミュレーション結果を表1に示す。表1より、4種類のモデルは、ほぼ全ての動作に対して識別処理時間を短縮できた。最も識別処理時間を短縮できたモデルは配置比率2:3のモデルであった。図9に各モデルの識別処理時間の平均を示す。図9より、識別処理時間の減少が2:3のモデルにおいて収束していると考えられる。シミュレーション結果のように、2:3のモデルが有効であるかを考察する。

従来の超球モデルにおいて、特徴軌跡の立ち上がり部に設置された超球を1個目とし、計10個の超球のうち、識別動作の特徴軌跡が何個目の超球に進入しているのかを調べた。被験者Aの先行実験の結果より、約80%の動作が1~4個目の超球に進入していることがわかった。新しく作成した2:3のモデルでは、従来の超球モデルにおいて1~4個目の超球が配置されていた位置に5個の超球が密になって配置されている。よって、2:3のモデルがシミュレーションを行ったモデルの中で最も効率的な配置であると考えられる。そこで、超球の配置比率2:3の超球モデルを用いて実験を行い、本動作識別手法の有効性を検証した。



Table 1 Simulation Result of Hyper-Sphere Model

| Discrimination Motions | Hyper-sphere Model |       |       |       |       | Average |
|------------------------|--------------------|-------|-------|-------|-------|---------|
|                        | 1:1                | 2:3   | 1:2   | 1:3   | 1:4   |         |
| Open                   | 239.9              | 183.1 | 204.8 | 179.3 | 189.5 | 199.3   |
| Close                  | 266.5              | 226.7 | 241.1 | 246.6 | 224.7 | 241.1   |
| Chuck                  | 330.7              | 277.3 | 281.6 | 289.6 | 293.6 | 294.6   |
| Wrist Ext.             | 351.8              | 343.9 | 342.8 | 349.9 | 351.8 | 348.0   |
| Wrist Fle.             | 228.0              | 198.6 | 204.1 | 202.4 | 224.9 | 211.6   |
| Wrist Pro.             | 338.5              | 297.0 | 316.3 | 302.4 | 361.3 | 323.1   |
| Wrist Sup.             | 239.5              | 237.9 | 235.4 | 236.2 | 238.1 | 237.4   |
| Average                | 285.0              | 252.1 | 260.8 | 258.0 | 269.1 | 265.0   |

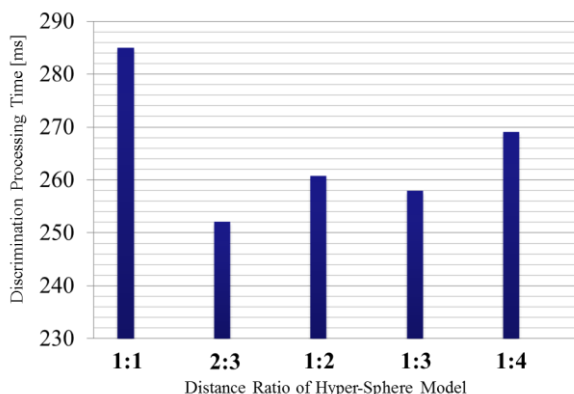


Fig.9 Discrimination Processing Time of Hyper-Sphere Model

## 4-3 識別率と識別処理時間

表2に比率2:3の超球モデルにより得られた識別率を示す。全被験者について90%以上の精度で動作識別が可能であった。表3に比率2:3の超球モデルにより得られた識別処理時間を示す。全被験者について、各動作300ms以下の識別が可能であった。肘の代表的な動作を組み合わせた動作について、他の動作と誤識別することはなかった。

Table 2 Discrimination Accuracy of 2:3 Hyper-Sphere Model

| Discrimination Motions | Subject |      |     |      |      | Average |
|------------------------|---------|------|-----|------|------|---------|
|                        | A       | B    | C   | D    | E    |         |
| Open                   | 100     | 100  | 100 | 95   | 100  | 99.0    |
| Close                  | 100     | 95   | 100 | 100  | 95   | 98.0    |
| Chuck                  | 100     | 100  | 100 | 100  | 90   | 98.0    |
| Wrist Ext.             | 90      | 90   | 100 | 100  | 95   | 95.0    |
| Wrist Fle.             | 100     | 100  | 100 | 90   | 90   | 96.0    |
| Wrist Pro.             | 95      | 90   | 100 | 100  | 90   | 95.0    |
| Wrist Sup.             | 100     | 100  | 100 | 95   | 100  | 99.0    |
| Average                | 97.9    | 96.4 | 100 | 97.1 | 94.3 | 97.1    |

Table 3 Discrimination Processing Time of 2:3 Hyper-Sphere Model

| Discrimination Motions | Subject |       |       |       |       | Average |
|------------------------|---------|-------|-------|-------|-------|---------|
|                        | A       | B     | C     | D     | E     |         |
| Open                   | 190.1   | 90.5  | 286.4 | 168.5 | 94.2  | 165.9   |
| Close                  | 192.7   | 131.8 | 263.1 | 131.9 | 131.8 | 170.3   |
| Chuck                  | 206.8   | 106.1 | 203.0 | 264.2 | 138.1 | 183.6   |
| Wrist Ext.             | 250.9   | 117.5 | 121.8 | 97.7  | 176.2 | 152.8   |
| Wrist Fle.             | 227.4   | 88.9  | 122.1 | 161.2 | 135.4 | 147.0   |
| Wrist Pro.             | 270.9   | 185.6 | 128.1 | 105.7 | 186.0 | 175.3   |
| Wrist Sup.             | 179.1   | 77.4  | 204.9 | 106.1 | 219.1 | 157.3   |
| Average                | 216.8   | 114.0 | 189.9 | 147.9 | 154.4 | 164.6   |

## 5. 結言

本研究では、筋電信号により、回内・回外動作を含む7動作をリアルタイムに識別することを目的として、超球モデルによる動作識別手法を提案した。また、これらを本研究室で設計した3Dハンドモデルに適用した。検証実験を行った結果、以下の結論を得た。

1. 超球モデルでは手の開き、握り、摘み、手首の伸展、屈曲、回内、回外動作を90%以上の精度で識別可能である。
2. 超球モデルにより、平均約300ms以下の識別処理時間で識別することが可能である。

## 謝辞

なお本研究の一部は、日本学術振興会科学研究費補助金基盤研究(B)(課題番号:25289053)の援助を受けた。記して謝意を表す。

## 参考文献

- (1) 横井浩史, 加藤龍, 中村達弘, 北佳保里, ロボットのあらし 筋義手のための五指ハンド制御技術, 自動車技術, vol.64, no.5, pp.65-69, 2010.
- (2) Jun-Uk Chu, Inhyuk Moon, Yun-Jung Lee, Shin-Ki Kim, Mu-Seong Mun, A Supervised Feature-Projection-Based Real-Time EMG Pattern Recognition for Multifunction Myoelectric Hand Control, IEEE/ASME TRANSACTIONS ON MECHATRONICS, vol.12, no.3, pp.282-290, 2007.
- (3) Kaveh Momen, Sridhar Krishnan, Tom Chau, Real-Time Classification of Forearm Electromyographic Signals Corresponding to User-Selected Intentional Movements for Multifunction Prosthesis Control, IEEE TRANSACTION ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING, vol.15, no.4, pp.535-542, 2007.
- (4) 辻敏夫, 島圭介, 生体信号でロボットを自在に操る, 電子情報通信学会誌, vol.90, no.10, pp.854-858, 2007.
- (5) 井部鮎子, 郷古学, 伊藤宏司, 表面電位を用いた前腕義手の複合動作識別, 計測自動制御学会論文集, vol.45, no.12, pp.717-723, 2009.
- (6) Dorffner G, A Unified Framework for MLPs and RBFNs, Cybernetics and Systems, vol.25, no.4, pp.551-554, 1994.
- (7) Bekir Karlik, A Fuzzy Clustering Neural Network Architecture for Multifunction Upper-Limb Prosthesis, IEEE Transactions on Biomedical Engineering, vol.50, no.11, pp.1255-1261, 2003.
- (8) 辻内伸好, 小泉孝之, 水野陽章, 筋電信号による前腕部動作識別手法のリアルタイム化, 第12回「運動と振動の制御」シンポジウム講演論文集, vol.11, no.6, pp.523-527, 2011.
- (9) 西川大亮, 兪文偉, 山口博紀, 横井浩史, 嘉数侑昇, 丸石正治, 渡辺一郎, 眞野行生, 実時間学習型筋電義手装置による前腕10種の動作パターン識別, 第16回バイオメカニズム・シンポジウム予稿集, pp.201-212, 1999.
- (10) Peter Konrad, "The ABC of EMG", Noraxon INC.USA, pp.60.
- (11) 宮城尚史, 福井忠雄, 骨格性下顎前突症患者における咀嚼運動の解析, 日本顎口腔機能学会雑誌, vol.10, no.1, pp.94-95, 2003.