

筋電位からの手動作推定における特徴量と SVM カーネル・パラメータについての実験的考察*

乾 大祐^{*1}, 伊藤 聡^{*2}, 佐々木 実^{*2}

Experimental Considerations on Signal Feature and Kernel/Parameters of SVM in Hand Motion Classification from sEMG

Daisuke INUI, Satoshi ITO and Minoru SASAKI^{*2}

^{*2} Gifu Univ. Dept. of Faculty of Engineering
Yanagito 1-1, Gifu, Gifu, 501-1193 Japan

This paper introduces the Support Vector Machine (SVM) to classify finger motion patterns from surface EMG (Electromyography). Surface EMG (sEMG) contains several signals from different muscles around the electrode, which make it difficult to estimate actually produced motions. To enhance the classification performance, we investigated which feature of EMG signals is more effective of the following six: raw data, integrated EMG, voltage level difference, power spectrum, FFT peak frequency, or wavelet coefficient. Next, we also considered the selection of SVM's kernel and its parameters. We experimentally demonstrated that the "Voltage level difference" provides 95% or more correct identification rate when the radial basis function (RBF) is utilized as the kernel. Changing the parameter values of the RBF, 98% correct classification rate was obtained in our experiment from three subjects.

Key Words: Man-Machine Interface, Pattern Recognition, Signal Processing, Electromyography, Support Vector Machine

1. はじめに

総務省の統計⁽¹⁾によれば,平成24年8月現在,65歳以上の高齢者の割合は日本の総人口の約24%占めている。また厚生労働白書⁽²⁾では,2030年には65歳以上の割合は,31.8%と約3人に1人の割合になると予測されている。これに加え,医師の都市部偏在,看護師・介護福祉士の高い離職率は医療福祉分野の人手不足を助長し,今後増え続ける高齢者への医療・福祉的サービスが十分に行き渡らない状況が生じると予想される。

このような社会的背景により,福祉や介護をサポートするロボットシステムの研究が盛んに行われている。歩行サポートロボット (HONDA「リズム歩行アシスト」⁽³⁾・大和ハウス工業株式会社「HAL」⁽⁴⁾), パワーアシストスーツ (アクティブリンク株式会社「パワーローダ」⁽⁵⁾), 介護支援ロボット (東海ゴム株式会社「RIBA-II」⁽⁶⁾) 等, 各研究機関, 民間企業でシステム開発研究が進められている。

われわれの研究グループでも,脳卒中患者を対象とした手指リハビリテーション支援機器の開発を行ってきた⁽⁷⁾⁻⁽⁹⁾。18自由度をもつこの機器は,5本の指の屈曲伸展,拇指の対立運動,手首の回内外,掌背屈に対し独立した運動の補助が可能である。訓練運動は,脳卒中患者の健側の手指動作を患側訓練運動の指令とする左右対称マスタ・スレーブ型の動作方式により制御され,自分で訓練運動を生成しどのような運動を現在訓練しているか意識しながらリハビリに取り組めるよう工夫している。このとき健側の指運動は,データグローブという光ファイバを内部にとおした特殊な手袋により計測されるが,それが高価であることが本リハビリ機器の普及の妨げの一

* 原稿受付 2013年5月2日

^{*1} 岐阜大学大学院 工学研究科博士前期課程在籍中

^{*2} 正員, 岐阜大学 (〒501-1193 岐阜県岐阜市柳戸 1-1)

E-mail: ics@gifu-u.ac.jp



因となっている。このグローブに代わるような手指運動の取得方法の確立が、その機器の普及のひとつのテーマである。

そのような背景のもと、本稿では手指の運動を非侵襲性の高い表面筋電位信号から推定する手法について考察する。表面筋電位は全てのヒトから計測できる共通的な信号であり、グローブとは違って手のサイズによる制限が少ない。また、グローブの装着は指を狭い袋の中に通すという作業をとまらなうため、リハビリ現場では容易ではない作業となる。前腕から信号を取得する筋電位信号はカフなどに内蔵できる可能性があり、実現ができれば取り付け準備がスムーズに行える。また、本リハビリ機器での利用以外でも、筋電から手指の運動が推定できれば、ロボット・ハンド操作のためのコントローラや、キーボードに代わる入力インターフェースなど広い応用範囲が考えられる。

しかし、表面筋電位は、電極の貼られた周辺一帯の複数の筋活動に関する信号が混ざり合っただけで計測されるため、そこから特定の動作を推定することは難しい。特に手の場合は前腕に各指の操作を与える筋が狭い部分に集約されていること、一本の筋が手指の様々な運動に関与していることも、動作推定を困難なものとしている。

筋電位信号からの動作判別は筋電義手⁽⁸⁾の分野で古くから行われ、判別アルゴリズムには、ニューラルネットワーク⁽¹⁰⁾⁻⁽¹²⁾⁽¹⁶⁾⁽¹⁷⁾、独立成分分析⁽¹³⁾、Generic Algorithm⁽¹⁴⁾、隠れマルコフモデル⁽¹⁵⁾、Support Vector Machine (以降 SVM)⁽¹⁸⁾⁻⁽²¹⁾などが用いられている。その中でも本研究では比較的高い識別率が得られるとされる SVM を利用する。

この判別問題では、「筋電位の特徴量として何を選擇するか」および「その判別としてどのようなアルゴリズムを用いるか」に主に判別結果が依存すると考える。前者に関しては、さまざまな特徴量を実際に検出して判別成績を比較検討し、どれが高い識別率を与えるか、その識別率はどれくらいかを実験的に明らかにする。また、後者に関しては、SVM を用いることにしたが、実際にそれを利用する場合、設定・選擇すべきパラメータなどが問題に依存して変化する。そこで、筋電位からの動作推定に対してはどのような選擇が適切かを検討する。

すなわち、筋電位信号からの動作判別において、筋電位信号の特徴量として何がふさわしいか、判別アルゴリズムとして SVM を利用する場合どのパラメータ設定が適切かを実験的に比較検討することを本稿の目的とする。

2. 筋電位の特徴量の比較検討

2.1 問題設定

本研究のもともとの動機付けは、手指のリハビリテーション支援システムで用いる健側の手指動作の検出であった。その開発に続き、自由度を減らしコストの削減を図る方向性が検討された。その結果、手首の①回内/②回外と③掌屈/④背屈、⑤拇指屈曲/⑥拇指伸展および⑦他四指屈曲/⑧四指伸展の 8 種類の動作を訓練動作として取り扱うこととした。そこで、本稿でも以上の 8 動作の動作検出を目標とする。

取得する筋電は、上記 8 動作への関与が大きい筋をターゲットとし、その筋活動が計測できる位置に測定装置の電極を貼付する。電極を貼付する筋はそれぞれ①円回内筋、②回外筋、③尺側手根屈筋、④尺側手根伸筋、⑤長母指屈筋、⑥長母外転筋、⑦浅指屈筋、⑧総指伸筋とした。

すなわち、本稿で取り扱う問題は、主に 8 つの筋付近に貼付した電極より計測される筋電位信号から、8 つの動作を識別することである。

2.2 筋電の特徴量に基づく識別データ生成

本節の目的は、8 種類の動作を識別する場合、筋電位信号から得られる特徴量のうち、どれを利用すると識別率が上がるのか、データ量等も考慮して調査することである。特徴量として、以下の 6 種類を取り上げる。なお、筋電位の時系列データは、後述する計測装置を用いた場合、取得時に 10 Hz のハイパスフィルタ、100 Hz のローパスフィルタ、60 Hz のハムフィルタの各フィルタ処理を作用させることができる。以下の特徴量は、それらの処理が既になされた信号に対するものである。

① Raw データ(Raw data)

取得した筋電位の時系列データをそのまま用いて動作推定を行う。8チャンネル全信号の絶対値の和が最大となる時刻の前後 0.1 [sec](トータル 0.2 [sec])のデータを抽出し、全データ中で最も高い電位の大きさを基準に正規化する。図 1 に回内筋に張り付けた電極から得られた Raw データのグラフと識別データの抽出例を示す。図 1 の矢印で示した範囲が識別データとなる。データの次元は $600[\text{sample}] \times 8[\text{ch}] = 4800$ となる。

② IEMG (Integrated EMG)

整流した筋電位信号を遮断周波数約 4.8Hz の 2 次バターースフィルタを通して平滑化し、4 倍増幅されたものを IEMG 信号とする。全チャンネル IEMG の和が最大となる時刻の前後 0.1[sec](トータル 0.2[sec])を抽出し、IEMG の最大値で正規化したものを識別データとする。図 2 に回内筋に張り付けた電極から得られた IEMG データのグラフと識別データの抽出例を示す。図 1 と同様に矢印で示した範囲が識別データとなる。データの次元は、 $600[\text{sample}] \times 8[\text{ch}] = 4800$ となる。

③ 最大成分周波数(FFT peak)

筋電位信号時系列データから動作前後のデータを抽出してスペクトル解析を行い、その主成分となる周波数値を特徴量とする。動作前後のデータとして、①の時刻の前後 256 sample(トータル 512 sample)を抽出する。そのデータのパワー・スペクトルを求め、各チャンネルの主成分となる最も大きい周波数値を取り出し、8 次元のデータを識別データとする。図 3 に回内筋に張り付けた電極から得られた信号から計算されたパワー・スペクトルのデータとその最大周波数の例を示す。

④ パワー・スペクトル(Spectrum)

③で得られる 8チャンネルのパワー・スペクトルを並べ $512[\text{sample}] \times 8[\text{ch}] = 4096$ 次元データを構成し、識別データとする。前述したように図 3 は回内筋信号のパワー・スペクトルである。

⑤ 立ち上がり電位(Voltage level difference (Vol. Level))

②の IEMG の筋電位信号から静止時(動作前)の 1 秒間(3,000sample)の電位平均と活性時(動作後)の 1 秒間(3,000 sample)の電位平均との差を各チャンネルから取得する。全チャンネルデータの平均および標準偏差を用い正規分布化の要領で規格化したデータを識別データとする。次元数はチャンネルと等しい 8 次元となる。図 4 に回内筋に張り付けた電極から得られた立ち上がり電位データのグラフと識別データの抽出例を示す。

⑥ ウェーブレット係数(Wavelet coefficient)

③で抽出したデータをパワー・スペクトル解析する代わりに、一次連続ウェーブレット変換を行う。その後周波数 10, 20, 30, 40, 50, 60[Hz]の値における係数のみ選定し、それぞれの周波数に対応した時系列に出力される係数を 4 sample ごとに間引きする。次元数は抽出した 512sample から 4 sample ごと間引きした $128[\text{sample}] \times 8 [\text{ch}] \times 6 [\text{周波数帯}] = 6144$ 次元とする。

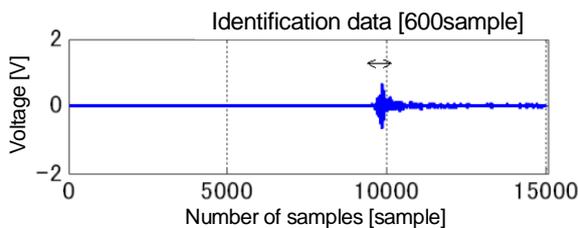


Fig. 1 Raw data measurements

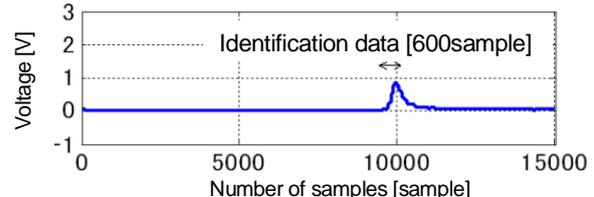


Fig. 2 IEMG data measurements

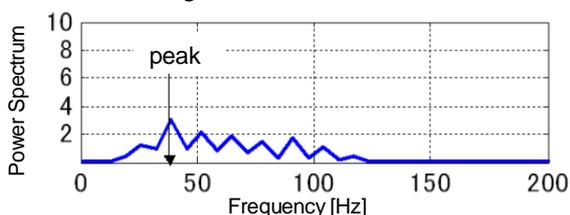


Fig.3 Power spectrum and Frequency peak

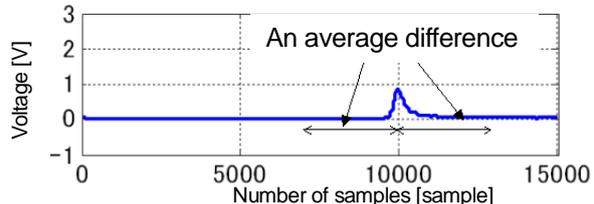


Fig.4 Voltage level difference

2・3 計測装置

筋電計測装置は有限会社追坂電子機器の Personal-EMG を用いた。付属ソフトを用いて計測を行い、サンプリング周波数は 3 kHz、前述のような 60 Hz のハムフィルタ、100 Hz のローパスフィルタ、10Hz のハイパスフィルタおよび 1000 倍ゲインをデータ取得時に作用させた。

2・4 実験

2・4・1 目的

2.2 で構成した筋電位信号からの特徴量データ①から⑥のうち、どのデータが高い識別率を与え、筋電位信号の特徴量として適切かを、SVM を用いて実験的に調査する。

2・4・2 実験方法

被験者には、椅子に座った状態で前腕を前方に伸ばし支えの上に置いてもらう。そして、図 5 に示すように、自然な状態で手をわずかに閉じた姿勢をとってもらう。この状態を動作のない静止状態とする。被験者には予め 8 動作のうちどれを行ってもらうかを知らせておく。そして計測ソフトに表示される筋電位信号のリアルタイム表示グラフが測定開始 3 秒のラインに到達した瞬間に、静止状態からその指定動作を行わせる、その後 2 秒間は動作後の姿勢・状態を維持させる。この 5 秒間の計測を 1 セットとし、15 セット連続で指定した動作を行う。この 15 セットのデータを、1 つの動作に関する筋電位データとする。15 セットの計測を 8 動作に対して 2.1 に示した順序でそれぞれ行ってもらう。

実際の計測では、22-24 歳右利きの健常な男性被験者 3 名から、右前腕にサージカルテープで乾式電極を貼付し、筋電データを取得した。実験時には固定した電極が大きく変動していないことを確認した。3 名とも 1 回 2 時間程度の計測を、日を変えて 3 回行った。

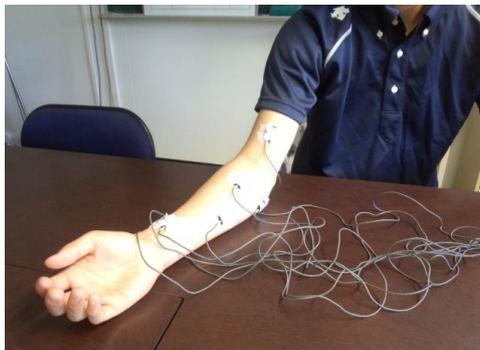


Fig.5 Experiment scenery

2・4・3 データ処理

取得したデータは 2.2 で示された 6 つの特徴量を抽出するために処理される。その後、判別アルゴリズムの SVM により学習および判別処理される。得られた 15 セットのデータのうち、最初の 10 セットは教師データとして SVM の学習すなわち識別超平面の構成に用い、残りの 5 セットを識別のためのテストデータとして識別率の評価に使用する。

SVM での計算には、Cornell 大学コンピュータサイエンス学科が開発した SVM⁽²³⁾のソフトウェア・パッケージ SVM-perf⁽²⁵⁾および SVM-multiclass⁽²⁶⁾を利用する。

SVM は基本的には 2 値の分離問題を扱うための計算手法であるため、今回のように 8 種類のパターン分類に応用するには工夫が必要である。SVM-multiclass は、分類パターンが複数扱えるように拡張されたものである。一方、通常の 2 値分離問題を取り扱う本来の SVM-perf を複数回用いてパターン分類する手法も考えられる。そこで、SVM-perf を 3 つ組み合わせることで 8 つの動作に筋電パターンを分類することを試みる。図 6 はその手法を図示したものである。SMV-perf1 では「手首」か「指」の識別、SVM-perf2 では「回内外」「親指」か「掌背屈」「四指」の識別、SVM-perf3 では「屈曲」か「伸展」かの識別（正確には「回内」「掌屈」「親指屈曲」「四指屈曲」か「回外」「背屈」「親指伸展」「四指伸展」）を行う。右端の数値は、分離結果を 0 と 1 でコーディングし、

2進表示でラベル付けしたものである。すなわち、各 SVM-perf の結果を順にならべることで、8種類の動作識別結果を得ることができる。

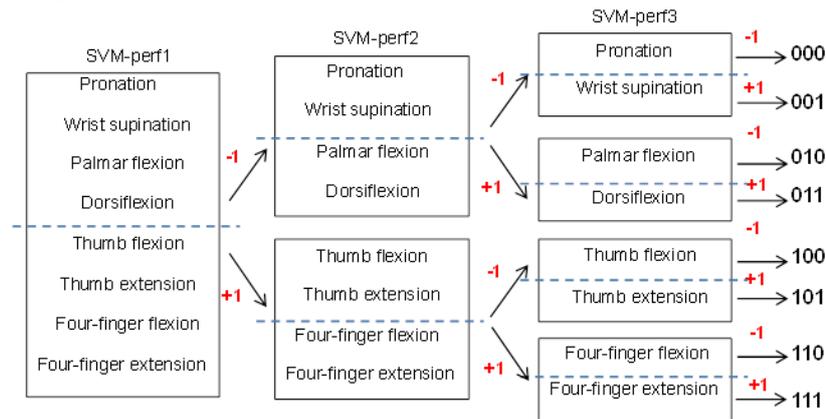


Fig.6 Classification of the 8 behaviors that combine three SVM

2・5 実験結果

2・5・1 SVM-perf による識別結果

Table 1 に SVM-perf を組み合わせて使用した場合の識別率データを示す。IEMG を用いた場合、被験者全員が 80%以上の識別率を示した。その後、立ち上がり電位、パワー・スペクトルと識別率が 80%近いデータ構成が続く。立ち上がり電位では、被験者 B の第 1 回目のように極端に識別率が下がる場合も観察された。一方、スペクトルによる識別はすべて 60%以上と安定した結果が示された。しかし、このデータから抽出した最大成分周波数 (FFT peak) では、平均識別率 40%以下とよい結果は得られなかった。残りの 2つ、すなわち Raw データ、ウェーブレット係数も識別率が 40%にも満たなかった。

2・5・2 SVM-multiclass による識別結果

Table 2 に SVM-multiclass を利用したときの識別率データを示す。この場合も、IEMG は高い識別率を示し、次にパワー・スペクトル、立ち上がり電位と続き、それらは 75%以上の識別率であった。また、Raw データ、FFT peak およびウェーブレットは 50%未満の識別率であった。

Table 1 Identification results by SVM-perf

	Subject A				Subject B				Subject C				Total Ave.
	1st	2nd	3rd	Ave.	1st	2nd	3rd	Ave.	1st	2nd	3rd	Ave.	
Raw	30.0	15.0	47.5	30.8	35.0	37.5	25.0	32.5	40.0	47.5	42.5	43.3	35.6
IEMG	80.0	72.5	87.5	80.0	72.5	95.0	80.0	82.5	100.0	85.0	77.5	87.5	83.3
Spectrum	72.5	72.5	87.5	77.5	62.5	95.0	70.0	75.8	82.5	87.5	75.0	81.7	78.3
FFT peak	30.0	27.5	40.0	32.5	35.0	35.0	37.5	35.8	47.5	27.5	57.5	44.2	37.5
Vol. Level	62.5	82.5	95.0	80.0	42.5	97.5	97.5	79.2	77.5	85.0	87.5	83.3	80.8
Wavelet	15.0	15.0	20.0	16.7	27.5	27.5	22.5	25.8	32.5	35.0	35.0	34.2	25.6

Table 2 Identification results by SVM-multiclass

	Subject A				Subject B				Subject C				Total Ave.
	1st	2nd	3rd	Ave.	1st	2nd	3rd	Ave.	1st	2nd	3rd	Ave.	
Raw	30.0	30.0	50.0	36.7	57.5	40.0	50.0	49.2	50.0	42.5	52.5	48.3	44.7
IEMG	82.5	90.0	95.0	89.2	70.0	75.0	95.0	80.0	87.5	90.0	80.0	85.8	85.0
Spectrum	72.5	80.0	80.0	77.5	57.5	92.5	75.0	75.0	87.5	87.5	67.5	80.8	77.8
FFT peak	45.0	50.0	55.0	50.0	40.0	47.5	50.0	45.8	32.5	47.5	52.5	44.2	46.7
Vol. Level	80.0	77.5	87.5	81.7	37.5	75.0	87.5	66.7	75.0	75.0	87.5	79.2	75.8
Wavelet	25.0	22.5	45.0	30.8	45.0	30.0	40.0	38.3	45.0	47.5	47.5	46.7	38.6

2・6 考察

Table 1 と Table 2 との比較より, SVM の違いによる識別率の影響は, 全体的には SVM-perf より SVM-multiclass で判別した方が良い傾向にはある. SVM-perf では組み合わせた 3 つの SVM の結果がすべて正解でなければならないため, その影響がでている可能性もある. しかし, データ構成ごとでの識別率の良否の傾向は総じて同じである. つまり, 識別率は利用したデータの質を反映したものと判断した方がよい. 今回の実験結果では, 結果的に IEMG を用いた場合が高い識別率を示した. 振動的な筋電位データそのものより, その面積に対応する IEMG を特徴量として取り出した方が, 筋活動の様子がコンピュータ処理でよく反映されるためと考える. また, 振動成分のエネルギーを評価できるパワー・スペクトルやウェーブレットも有効と考えるが, 今回は IEMG の方が結果としてよい識別率となった.

3. SVM のカーネル・パラメータの比較検討

3・1 目的

非線形 SVM のカーネル・パラメータとしてどのようなものがよいか, SVM の汎化能力が個人差や測定時刻の変化に対してどの程度有効かは問題に依存することが多い. そこで, 筋電位信号からの手・指動作識別問題に関して, SVM を非線形に拡張する際に選択可能なカーネル関数の種類およびそのパラメータが識別率や学習時間にどのように影響するか, また被験者による識別率の差 (個人差) はどの程度あるのか, の 2 点を明らかにする.

なお, SVM の非線形カーネルとして以下の 2 種類について調査する.

(A) 多項式カーネル:

$$K(\mathbf{x}_i, \mathbf{x}) = (s(\mathbf{x}_i, \mathbf{x}) + 1)^d \quad (1)$$

d は多項式カーネルの次数を決めるパラメータ, s は傾きを決めるパラメータである.

(B) RBF カーネル:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-g\|\mathbf{x} - \mathbf{x}_i\|^2) \quad (2)$$

g は RBF カーネルの傾きを決めるパラメータである.

RBF カーネルは SVM でよく使われていること, 多項式カーネルは線形カーネルからの自然な拡張として, 線形カーネルとの比較も可能であることから本節で取り上げることとした. したがって, (A), (B) の各パラメータをいくつに設定すればよいかの本節で考える問題である.

3・2 実験方法

2.4.2 に示した方法により 20-23 歳右利きの健常な男性被験者 7 名より筋電データを計測し, 前節で識別率が高かった特徴量の 1 つである「立ち上がり電位」を計算した. 「立ち上がり電位」は IEMG に比べデータの次元数が少なく, SVM での学習時間が短くなる.

また, 計測データを見てみると, 回外筋の動作判別を計測するために貼り付けた電極からは, 回外筋が深部筋であったため応答が小さく, 動作判別に有効に働くとは思われなかった. 前節で既に動作判別に用いるべき筋電位信号の特徴量が明らかになったこと, 本節では識別率向上のためパラメータなどの検討をするのが目的であることを鑑み, 回外動作の検出にはそのもう一つの主要筋である上腕二頭筋の活動検出ができる位置に電極を貼ることとした.

15 セットのデータのうち, 本節では 5 セットを教師データ, 残りの 10 セットを識別のためのテストデータとし, 線形 SVM と非線形 SVM でクラス分類させた. 判別アルゴリズムには, 2.5 から判別率の高かった SVM-multiclass を用いた.

線形 SVM での 7 人の識別率を平均した結果は, 87.5% であった. 非線形 SVM に関しては, 多項式カーネル, RBF カーネルのパラメータを変えて識別率がどのように変わるかを解析した.

3・3 非線形カーネルによる実験結果

3・3・1 多項式カーネル・パラメータ

多項式カーネル(1)では, まずパラメータ d つまり, 多項式カーネルの次数を決めるために $s=1$ に固定し, 同じ条件で計測した被験者 7 人中最初の 4 人の筋電データを学習させた. 識別結果を図 7 に示す.

次数が5以上になると識別率は上がらず、すべての被験者で次数が3, 4で最も高い識別率が得られている。学習時間(5セット×8動作を1人の被験者に対して学習, 4人で平均)は、次数が上がるにつれて長くなる傾向があった。以上から多項式カーネルではパラメータ d が $d=3, 4$ のとき良好な結果が得られることがわかった。

そこで $d=3, 4$ に対し、今度はパラメータ s を $s=0.1\sim 1000$ で対数的に変更した。その時の識別率を図8, 図9に示す。

すべての被験者において、 $d=3$ では $s=0.2\sim 3$ で、 $d=4$ では $s=0.2\sim 1000$ で線形SVMよりも高い識別率であった。どちらも $s=1$ の時で識別率が最も高くなっていて、その他のパラメータ設定では全体的に識別率が下がる傾向にあった。 $s=1$ の場合、 $d=3$ では識別率が一番低い被験者で92.5%、一番高い識別率は100%である。 $d=4$ では、一番低い被験者で90%、最も高い被験者で100%となっている。この二つを比較すると、識別率の最大値と最小値の差(範囲)が $d=3$ では8.75%となり、 $d=4$ の10%よりも被験者間での識別率の差は少ないことがわかる。一方、すべての被験者の識別率の平均は $d=4$ で98.57%、 $d=3$ で97.86%となり、 $d=4$ の方が高い結果となった。本研究で用いた筋電データの空間において、パラメータ s はカーネルの傾きを表す。結果的にこのデータ構造では筋電位信号の判別に $s=1$ の傾きが一番適していることが分かった。

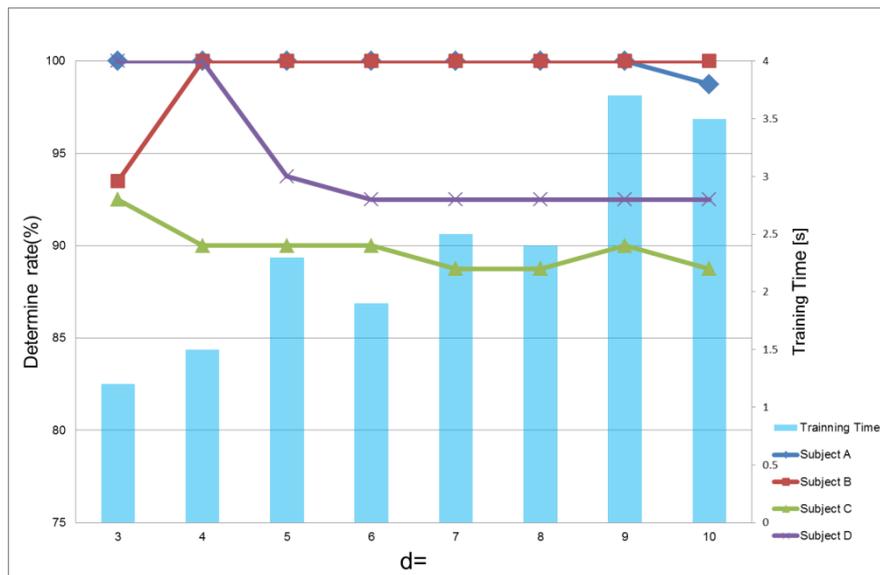


Fig.7 Comparison of identification and learning time

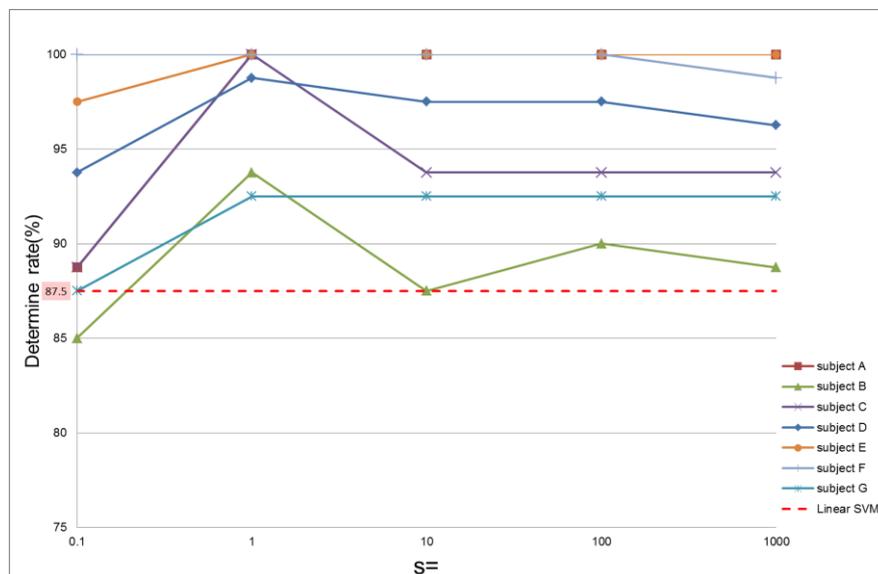


Fig.8 Polynominal kernel ($d=3$)

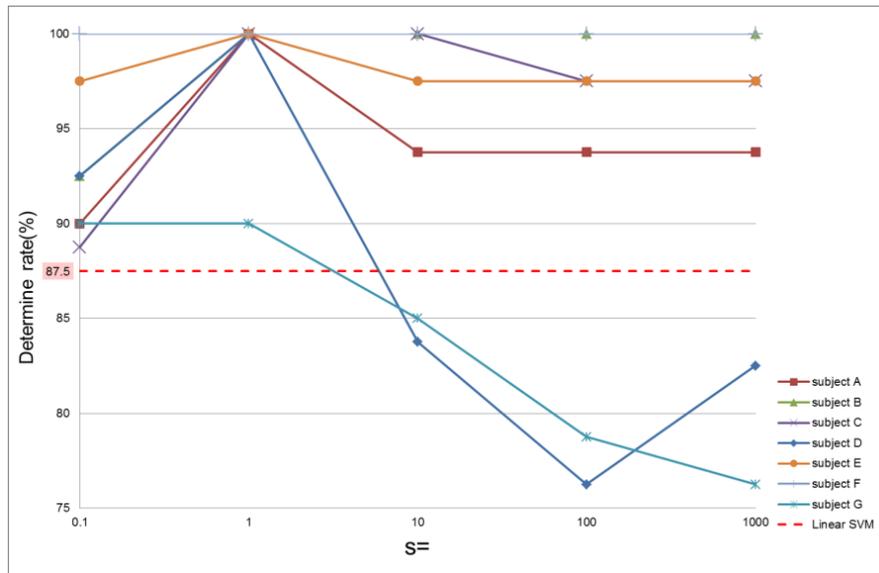


Fig.9 Polynominal kernel ($d=4$)

3・3・2 RBF カーネル・パラメータ

RBF カーネル(2)のパラメータ g を $g = 0.1 \sim 10000$ で対数的に変化させ、それぞれの場合の識別率を求めた。そのグラフを図 10 に示す。

まず、 $g=100$ 以上になると識別率が大きく下がる傾向がある。しかし、 $g=0.1 \sim 100$ では線形 SVM より高く $g=1$ 付近では、すべての被験者が 95%以上である。もう少し詳しく識別率の変動をみるため、 $g=0.1 \sim 100$ を拡大したグラフを図 11 に示す。

$g=0.5 \sim 1$ では、すべての被験者で識別率は 95%以上となっており、その中でも $g=0.8$ では被験者 7 人の平均識別率が 98.21%と最も高くなっている。パラメータ g の値は識別平面の傾きに関係しており、この傾きが本稿の筋電位信号に最も適していることが、高い識別率が得られた要因だと考えられる。

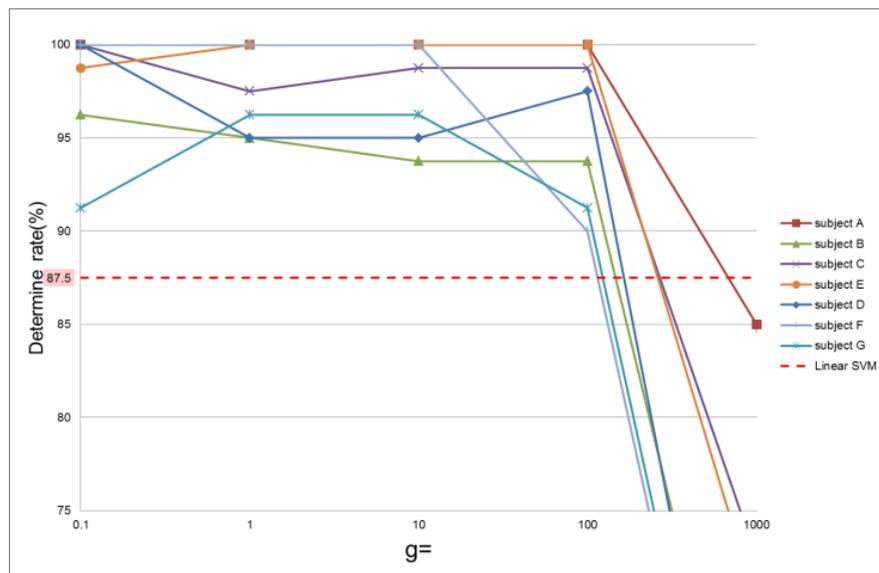


Fig.10 RBF kernel ($g=0.1 \sim 1000$)

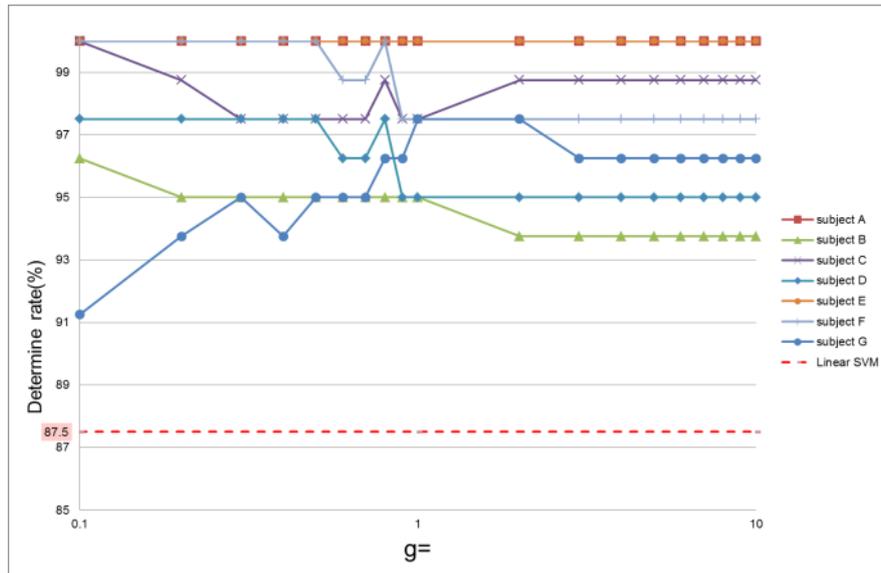


Fig.11 RBF kernel (g=0.1~10)

3・4 被験者による変化とその考察

各カーネルで最も高い識別率を与えるパラメータは、多項式カーネルでは $d=3, s=1$ および $d=4, s=1$ のとき、RBF カーネルでは $g=0.8$ のときである。このパラメータ設定において、被験者 7 人の識別率の平均、最も低い識別率、識別率の変動範囲、SVM の学習時間（識別平面の算出時間）を Table 3 にまとめた。比較のため線形カーネルを用いた識別も行った。

線形カーネルの識別率は、非線形カーネルより 9~11% も低く、変動範囲も 21.25% と個人間での識別率の差が大きいことを表している。しかし、学習時間は最も短くなっている。以上より、線形カーネルより非線形カーネルのほうが高い識別率を得られることがわかった。

識別率平均をみると多項式カーネルの $d=4, s=1$ で 98.57% と最も高い。しかし、変動範囲は 10% もあり、学習時間も他のカーネル設定よりも長い。 $d=3, s=1$ では少し識別率は下がるが変動範囲は 7.5% と小さくはなる。しかし、計算時間は他のカーネルと比べて長い。

一方、RBF カーネルでは、 $g=0.5\sim 1$ とパラメータ設定すれば、どの被験者でも 95% 以上の識別率が得られた。平均識別率は多項式カーネルの $d=4, s=1$ よりも 0.36% 低いが、最も低い識別率は 95% と高く、変動範囲が 5% と個人差がきわめて小さい。さらに、計算時間が多項式カーネルに比べ 1/100 程度である。

以上より、RBF カーネルが本稿の筋電位信号の識別問題では最も適していると判断した。

Table 3 Identification result

Kernel Parameter	linear	Polynomial		RBF
		$d=3, s=1$	$d=4, s=1$	$g=0.8$
subject A	90	100	100	100
subject B	85	93.75	100	95
subject C	88.75	100	100	98.75
subject D	93.75	98.75	100	97.5
subject E	88.75	100	100	100
subject F	93.75	100	100	100
subject G	72.5	92.5	90	96.25
Ave.	87.50	97.86	98.57	98.21
Min	72.5	92.5	90	95
Range	21.25	7.5	10	5
Training time(s)	0.024	1.002	1.278	0.084

4. おわりに

本稿では、マシン・ラーニングにおいて汎化能力が高いとされている SVM を用い、表面筋電位からの手・指動作判別を行った。目的は、表面筋電位の特徴量として何が適切であるか、SVM をこの問題に応用した場合どのようなパラメータ設定が適切かを明らかにすることである。

手・指動作は「回内」「回外」「掌屈」「背屈」「親指屈曲」「親指伸展」「四指屈曲」「四指伸展」の8つとし、それぞれの動作に主要な働きをする「円回内筋」, 「回外筋 (上腕二頭筋)」, 「尺側手根屈筋」, 「尺側手根伸筋」, 「長母指屈筋」, 「長母外転筋」, 「浅指屈筋」, 「総指伸筋」から筋電位を取得した。その筋電位のどのような特徴量を用いれば高い識別率が得られるかを「筋電位 Raw データ」「IEMG」「最大成分周波数」「パワー・スペクトル」「立ち上がり電位」「ウェーブレット係数」の6つを用いて比較、検討を行った。また、SVM も SVM-perf と SVM-multiclass の2つのアルゴリズムの比較を行った。

その結果、6つの特徴量中では「IEMG」が、被験者3名、各3回の実験においてほぼ80%以上の判別率を示し、「パワー・スペクトル」と「立ち上がり電位」の識別率も80%近くを示した。2つのSVMの比較においては、全体的にSVM-multiclassを用いた識別の方が高い識別率を得ることができた。

次に、カーネル・パラメータが識別率にどのような影響をあたえるかを解析することで筋電位に有効なカーネル・パラメータの比較検討を行った。その結果、RBFカーネルでパラメータ $g=0.5\sim 1$ に設定した場合が、最も低い識別率でも95%、個人差は5%以内、学習時間も短いという点でもっとも有効であると判断した。その中でも $g=0.8$ の設定が、すべての被験者での平均識別率が98.21%と最も高かった。多項式カーネルもRBFカーネルと同等の識別率を示したが、学習時間・個人差を考慮するとRBFに劣った。

今後の課題として、計測条件・個人によるばらつき、少数電極からの動作識別、連続した動作内での動作識別、複数の組み合わせ動作の識別、オンライン識別に応用することなどが考えられる。本稿では様々な特徴量の動作識別への有効性を比較したが、これらの特徴量を組み合わせることも識別率向上には将来的に必要なかもしれない。これらの特徴量を並列計算で計算し識別データを統合して構成するような演算システム構築が、統合識別データを用いたオンライン判別には必要となる。

本研究の一部は平成22年度地域イノベーションクラスタープログラム(都市エリア型) 岐阜県南部エリア可能性試験事業の補助を得た。また本研究の実験では岐阜大学大学院 小島 一樹氏(平成23年修了)の協力を得た。ここに感謝の意を表す。

文 献

- (1) 総務省統計局, “統計局ホームページ/人口推計”, 総務省統計局, <http://www.stat.go.jp/data/jinsui/index.htm> (参照日 2012年8月20日).
- (2) 厚生労働省, “平成24年厚生労働白書 資料編 人口構造”, 厚生労働省, <http://www.mhlw.go.jp/wp/hakusyo/kousei/12-2/> (参照日 2012年8月20日).
- (3) Honda Corporate, “Walking assist device with stride management system”, *Honda R&D technical review*, Vol. 21, No. 2 (2009), pp. 54-62.
- (4) Hayashi, T., Kawamoto, H., and Sankai, Y., “Control method of robot suit HAL working as operator's muscle using biological and dynamical information”, *Intelligent Robots and Systems*, Vol. 2, No. 2 (2005), pp. 3063-3068.
- (5) 城垣内剛, “パワーロボット増幅における操作者への過負荷を排除する機構設計”, *パナソニック技報*, Vol. 55, No. 4 (2010), pp. 284-286.
- (6) 佐藤侑, 郭土傑, 稲田誠生, 向井利春, “介護支援ロボット RIBA-II の動作設計と評価実験”, *日本機械学会論文集 C 編*, Vol. 78, No. 789 (2012), pp. 1899-1912.
- (7) 川崎晴久, 伊藤聡, 石樽康彦, 西本裕, 青木隆明, 安倍基幸, 栄枝裕文, 小鹿丈夫, 毛利哲也, 上木諭, “拇指対向運動を支援するハンドリハビリ支援ロボットの設計と動作評価”, *日本機会学会論文集 C 編*, Vol. 74, No. 748 (2008), pp. 3019-3027.

- (8) 伊藤聡, 石樽康彦, 水元淳, 上木諭, 川崎晴久, “手指上肢リハビリ支援ロボットの開発”, 日本生活支援工学会誌, Vol. 8, No. 2 (2008), pp. 20-22.
- (9) Ito, S., Kawasaki, H., Ishigure, Y., Natsume, M., Mouri, T., and Nishimoto, Y., “A design of fine motion assist equipment for disabled hand in robotic rehabilitation system”, *Journal of the Franklin Institute*, Vol. 348, No.1 (2011), pp. 79-89.
- (10) 片山敦史, 辛徳, 小池康晴, “筋電信号を用いた指関節角度推定”, 電子情報通信学会技術研究報告 MVE マルチメディア・仮想環境基礎, Vol. 106, No. 611 (2007), pp. 7-12.
- (11) 加藤龍, 横井浩史, “適応機能を有する運動意図推定システム:高機能ロボットハンドと日常生活支援”, 人工知能学会誌, Vol. 23, No. 3 (2008), pp. 326-333.
- (12) 森田聡, 柴田克成, 伊藤宏司, “ニューラルネットワークを用いた人間-筋電義手インターフェース”, 電気通信学会技術研究報告 MBE ME とバイオサイバネティクス, Vol. 99, No. 688 (2000), pp. 37-42.
- (13) 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. 23, No. 2 (2009), pp. 134-141.
- (14) Peleg, D., Braiman, E., Yom-Tov, E., and Inbar, G.F., “Classification of finger activation for use in a robotic prosthesis arm”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 10, No. 4 (2003), pp. 290-293.
- (15) Ju, P., Kaelbling, L.P., and Singer, Y., “State-based Classification of Finger Gestures from Electromyographic Signals”, *International Conference on Machine Learning* (2000), pp. 439-446.
- (16) 平岩明, 内田典佳, 下原勝憲, 曾根原登, “筋電操作ハンドのための皮膚表面筋電信号のニューラルネットワークによる認識”, 計測自動制御学会論文集, Vol. 30, No. 2 (1994), pp. 216-224.
- (17) 辻敏夫, 島圭介, 村上洋介, “筋シナジーに基づく複合動作のパターン識別”, 日本ロボット学会誌, Vol. 28, No. 5 (2010), pp. 606-613.
- (18) Scott Saponas, T., Tan, D.S., Morris, D., and Balakrishnan, R., “Demonstrating the Feasibility of Using Forearm Electromyography for Muscle-Computer Interfaces”, *CHI 2008 Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (2008), pp. 515-524.
- (19) Crawford, B., Miller, K., Shenoy, K., and Rao, R., “ Real-Time Classification of Electromyographic Signals for Robotic Control”, *Proceedings of AAAI* (2005), pp. 523-528.
- (20) Bizter, S., and Smagt, P., “ Learning EMG control of a robotic hand Towards Active Prostheses”, *IEEE International Conference on Robotics and Automation* (2006), pp. 2819-2823.
- (21) Castellini, C., and Smagt, P., “surface EMG in advanced hand prosthetics”, *Biological Cybernetics* 100 (2009), pp. 35-37.
- (22) 木塚朝博, 増田正, 木竜徹, 佐渡山亜兵, バイオメカニズムライブラリー 表面筋電図 (2008), 東京電機大学出版局.
- (23) Christianini, N., and Shawe-Taylor, J., サポートベクターマシン入門 (2008), 共立出版株式会社.
- (24) 長島聖司, 分冊 解剖学アトラス I (2002), 株式会社文光堂.
- (25) Joachims, T., “Support Vector Machine for Multivariate Performance Measures”, Cornell University Department of Computer Science, http://www.cs.cornell.edu/people/tj/svm_light/svm_perf.html (参照日 2008 年 10 月 11 日).
- (26) Joachims, T., “ Multi-Class Support Vector Machine ”, Cornell University Department of Computer Science, http://svmlight.joachims.org/svm_multiclass.html (参照日 2008 年 10 月 11 日).