

SEMG を用いた多クラス SVM による前腕部の動作識別における カーネルとパラメータの検討

二股 大央^{*1} 永田 健太郎^{*2} 曲谷 一成^{*3}

The Evaluation of the Kernel and Parameters of Multiclass SVM in a Study of Hand Motion Recognition by Using SEMG

by

Masachika FUTAMATA^{*1}, Kentaro NAGATA^{*2} and Kazushige MAGATANI^{*3}

(Received on Sep. 27, 2012 and accepted on Dec. 20, 2012)

Abstract

Electromyogram (EMG) is a kind of biological signal that is generated because of excitement of muscle according to the motor instruction from a brain. We have been experimentally developing the hand motion recognition system by using 4 channels forearm SEMG signals. In our system, in order to classify measured SEMG SVM (Support Vector Machine) that has higher discriminability is used. Usually SVM is used as a non-linear classifier. However, In the conventional system that we developed, we used a canonical discriminant analysis (CDA) method. CDA method is based on linear discriminant function, and it has shown good experimental results. Therefore, we have compared the discriminant ability between SVM and CDA. In this report, we will describe about the results of this experiment.

Keywords: Biosignal processing, Surface Electromyogram, SEMG, Support Vector Machine, SVM

1. まえがき

筋電位(EMG)とは、生体信号の一種であり脳からの運動命令による筋収縮が起こる際に発生する。筋電位は皮膚表面より導出可能であり、この場合表面筋電位(Surface EMG : SEMG)と呼ばれる。EMG は筋毎に発生し、手指の動作において使用される筋の組み合わせが異なることから、EMG の発生パターンを解析することにより手の動作を識別することが可能となる¹⁾。また発生する EMG の電位特性は動作毎に大きく異なる。そのためこの電位特性は動作との関連が容易である。さらに随意筋の場合には自分の意志を反映し筋の動作を能動的に制御することが可能である。これらのことから、EMG を利用して体の各部動作を認識する試みは古くから着想されてきた。現在まで、EMG を信号制御源として利用する様々なシステムが開発されている^{2), 3)}。本研究の目的は、同様に SEMG を用いたマン・マシンインタフェースの構築である。そのためには、以下の二つのことが重要となる。

- 1) SEMG の導出位置の決定
- 2) SEMG の識別規則の選択と構築

SEMG により手指の動作を正確に識別するためには、

*1 工学研究科電気電子システム工学専攻修士課程

*2 早稲田大学人間総合研究センター

*3 工学部電気電子工学科教授

SEMG の導出位置と動作識別規則が重要となる。導出位置については、我々の先行研究により開発された 96 チャネルの電極を持つ多チャンネル電極(以下、96 多チャンネル電極とする)を用いることにより、良好な結果が得られている³⁾。

識別規則については、我々は、前腕部から SEMG を取得し、正準判別分析法(CDA)⁴⁾と呼ばれる識別手法を用いることにより手指の動作認識システムの構築を行ってきた。近年の試みとしては、Support Vector Machine(SVM)を識別規則として用いることにより、前腕部の各部動作を識別(以下、動作識別)する際の精度向上が見込めるとの報告⁵⁾があることから、動作識別に利用するための基礎研究行っている。本論文は、SVM を用いた動作識別システムについての報告である。先行研究では、識別規則として SVM を利用する際には、多くの場合非線形識別規則として SVM を用い、さらに複数の手指の認識対象動作を識別せねばならないため、多クラス分類規則として用いてきた⁶⁾。

先述したとおり、我々が従来から開発してきたシステムは、CDA を用いている。CDA とは線形識別規則の一種であり、このシステムにおいては高い動作識別率で手指の動作識別を行うことが可能である。そこで、その先行研究での実験結果を受け SEMG は線形分離可能であるという予想のもとに、汎化性に優れるという報告の多い SVM を線形識別規則として利用することにより、更なる認識率の向上が見込めるのではないかと、また複雑な識別

規則を構築せずとも動作識別が可能ではないのかという仮説を立て、本報告にて実際に検証を行った。本報告では非線形 SVM と線形 SVM、そして CDA との比較を行いその結果を報告すると同時にそれに付随する予備実験にて得られた結果、また従来のシステムとの比較した実験結果について報告を行う。

2. システム構成

2.1 ハードウェアについて

2.1.1 システム構成

システム構成を示すブロック図を以下の Fig.1 に示す。

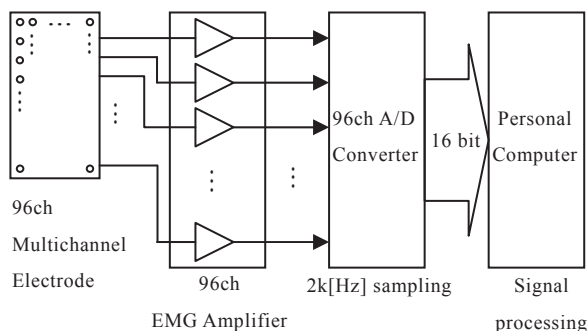


Fig.1 A Block Diagram of SEMG Measurement System

ここに示されるように 96 多チャンネル電極から導出された SEMG は生体アンプ(EMG アンプ)にて増幅された後に、A/D コンバータを介しパーソナルコンピュータ(以下、PC とする)に入力され、信号処理を行い、手指の動作が識別される。

2.1.2 96 多チャンネル電極




Fig.2 Structure of the 96-channel surface multi-electrode.

本研究において重要となるのは、96 チャンネルの電極を持つ多チャンネル電極(Fig.2)である。96 多チャンネル電極は、96 個の銀電極から構成されており、2mm 径のプラワッシャに埋め込まれる形で 3mm のシリコンゴム上に縦 10mm、横 15mm の間隔で横方向に 16 個、縦に 6 列配置されている。ペースト(日本光電社製、Elefix)をワッシャ内に塗り埋めて、皮膚表面に貼り付けて使用する。

2.1.3 生体アンプ(EMG アンプ)

今回の実験にて用いた生体アンプでは、初段の増幅回路として CMRR が極めて高いインストルメンテーションアンプ(Instrumentation Amplifier)を採用している。この生体アンプは 3,000 倍の増幅度を持つが、初段を構成す

るインストルメンテーションアンプは 50 倍程度にゲインを押さえ、この後 1 次ハイパスフィルタにより直流成分をカット、次段で 60 倍のゲインを持たせている。この後低域は 10Hz 以下を、高域は 1kHz 以上を 2 次のアクティブフィルタによりカットしている。1 チャンネル分の回路図を Fig.3 に、代表する 1ch 分の周波数特性表を Fig.4 に示す。




Fig.3 A Circuit Diagram of our EMG Amplifier




Fig.4 A Frequency Property of our EMG Amplifier

2.1.4 A/D 変換器と処理系

96 個の電極から SEMG を導出し、生体アンプにて増幅された後に、パーソナルコンピュータ内に A/D 変換器(コンテック社製、ADA16-32PCI/F)を通し取得する。実験時のサンプリング周波数は 2kHz とし、900ms 分の SEMG を取得する。取得された SEMG はパーソナルコンピュータ内に構築した識別規則に適用され、動作識別が行われる。

2.1.5 チャンネル選択法

識別規則の構築の際には、96 多チャンネル電極から取得された SEMG のうち、任意のチャンネル数を選択して取得することができる。これを「チャンネル選択法」と呼ぶ。96 個のチャンネルすべての EMG を動作識別の解析に使用することを考えた場合、チャンネル数が多いために処理に時間がかかってしまい、システムの即応性が問題となる。そこで動作識別に適した少数個のチャンネルを選択する必要があるが、以下に示す留意すべき点がある。

- 1) 選択するチャンネル数を幾つに設定するか
- 2) チャンネルをどのように選択するか

まず 1) に関して考える. Fig.5 は, 選択チャンネル数を 1 チャンネルから 16 チャンネルまで変化させた際の手指の基本 18 動作(握り, 開き, 掌屈, 背屈, 尺屈, 橈屈, 回内, 回外と各指の屈曲と伸展, 以下識別対象動作, もしくは基本動作とする)を行う実験の際に使用したチャンネル数と識別率の関係を示したものである(識別規則は CDA である)⁷⁾.

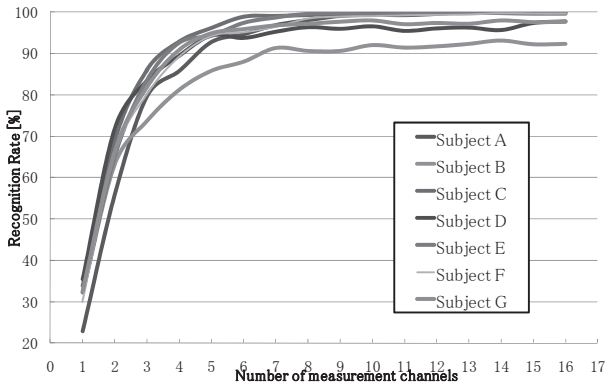


Fig.5 A relationship between the number of channel and recognition rate

この結果より, 殆どの場合について, 使用したチャンネルが 4 チャンネル以上の時に動作識別率に飽和傾向が見られた. そのため, 実験の際は 4 チャンネルから 6 チャンネルの間で選ぶのが妥当であると考えられる.

次に, 2) に関してはチャンネルの評価方法が問題となる. 96 チャンネルの中から最大識別率を示す最適な 4 チャンネルから 6 チャンネルを求めようとすれば, 96ch から選択出来る全てのチャンネルの組に対して評価を行う必要があり, その計算量は膨大なものになる. そこで識別対象動作全てに対し最適であるチャンネルの組み合わせを厳密に選択するのではなく, 乱数を用いてランダムに選択された複数の選択チャンネルの組を用いて評価する方法を用いている. つまり選択チャンネル数分の電極より構成された 1 つの電極の組に対し, 予め被験者毎に計測を行っておいた各動作の 96 チャンネルの EMG パターンからこの電極の組のデータを取り出し, これを用いて動作識別率を求める. ここで動作識別率とは, 試行により識別した動作と, 入力した動作が合致する正答率のことである. これをランダムに抽出した 1000 個の電極の組に対して計算し, その上で最も高い動作識別率を示す選択チャンネルの組を実際の動作識別に際して採用する電極の組とした.

2.2 ソフトウェアについて

2.2.1 特徴量抽出について

先に述べた通り, 本研究にて開発した動作識別を行うためのソフトウェアには, SVM と呼ばれる識別規則を適応し, 動作識別を行う手法をとっている. まず, 識別規則を構築する際には, SEMG から特徴量を抽出する必要がある. まず SEMG の特徴量を決定する必要があるが, 本システムでは SEMG の振幅成分に着目し, その時間的な加算値を用いた各チャンネル特徴量を $X_i(i=1,2,\dots,4)$ とす

れば, X_i は式(1)で表される

$$X_i = c \sum_{t=1}^{T_1} |x_i(t)| \quad (1)$$

c はパターンを正規化するための定数, $x_i(t)$ は時刻 t におけるサンプル値, T_1 は加算時間を表している. T_1 は長いほど X_i が安定することが先行研究からわかっているが⁸⁾, システムの即応性を考慮するため, ここでは 300ms に設定した.

2.2.2 SVM について

抽出された特徴量 X_i を用いて動作識別をするための識別規則を構築する. 本研究において識別器として用いる SVM とは, これまでの手法と比べて汎化性能が高いことが知られており, 最近注目を集めている^{9), 10)}. SVM とは 2 クラスのパターン識別手法であり, 学習パターンを使って最適な識別境界を決定する技術である. 与えられたデータ集合が線形分離可能な場合には識別関数に線形関数を使用することで分離が行えるが, 線形分離不可能な場合でも識別関数にカーネル関数を使用することで非線形性のある識別関数を実現し, 適切な分離結果を得ることができる. カーネル関数を適応した識別関数を式(2)に, 目的関数とその制約条件を式(3)に示す.

$$f(x) = \text{sign} \left(\sum_{i=1}^d \lambda_i y_i K(x_i, x) + b \right) \quad (2)$$

$$\begin{aligned} \text{目的関数} &: \sum_{i=1}^D \lambda_i - \frac{1}{2} \sum_{i,j=1}^D \lambda_i \lambda_j y_i y_j K(x_i, x_j) \\ \text{制約条件} &: \sum_{i=1}^D \lambda_i y_i = 0, \quad 0 \leq \lambda_i \leq C \end{aligned} \quad (3)$$

式(2)の識別関数は, 2 値の分離対象クラス同士が最大マージンをとる時の識別平面を示し, 式(3)の目的関数をラグランジュ乗数 λ_i について解くことにより, λ_i が 0 にならない場合(解の大半が 0 となる), 分離対象クラスが最大マージンをとる. それを式(2)の識別関数に適応させ識別関数を構築するのが, SVM における学習となる. すなわちこの学習により識別関数を構築し, 未知の分離対象サンプルを学習済みの識別関数に適応させ, 識別を行う.

ここで y_i は i 番目の学習サンプル x_i に対応するクラスラベルであり, λ_i はラグランジュ乗数, b はバイアス項である. また $K(x_i, x)$ はカーネル関数である. カーネル関数は, 線形分離不可能な学習データに対して, これを高次元の特徴空間に写像することで, 写像先の特徴空間において線形分離可能にする. 実際に式(2)で示した識別関数を求めるためには, 式(3)を最大にする λ_i を求める必要がある. カーネル関数は, 代表的なものに次の 3 つがある¹¹⁾

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2) \quad (4)$$

$$K(x_i, x) = (c + s \cdot x_i^T x)^d \quad (5)$$

$$K(x_i, x) = \tanh(a \cdot x_i^T x - b) \quad (6)$$

式(4)は RBF カーネル, 式(5)は多項式カーネル, 式(6)はシグモイドカーネルと呼ばれる. カーネル関数にはそれぞれパラメータが存在しており, パラメータの適切な設定は分離性能に大いに影響を及ぼす. 式(4)の RBF カーネルの場合は, γ がパラメータであり, 式(5)の多項式カーネルの場合は c, s , および乗数の d がパラメータとなり, 式(6)のシグモイドカーネルの場合は a, b がパラメータとなる. さらに, 式(3)の目的関数の制約条件であるラグランジュ乗数の上限を決める C もパラメータとなるので, 線形 SVM の場合もこの値を最適値に設定する必要がある. このパラメータは学習時に決定しておかなければならない.

先に述べたように, SVM は本来 2 クラスを識別する手法であるため, 多クラスを識別するために各クラスにおいて 1 対 1 対応をとる one-against-one 法を用いるか, 1 対その他の対応をとる one-against-all 法を用いる必要がある. 本研究では one-against-one 法を用いた. one-against-one 法では N クラスを識別するために式(7)より求められる数だけ識別関数を構築する必要があり, これらの識別関数を用いて特徴ベクトルの識別を行う.

$$\frac{N(N+1)}{2} \quad (7)$$

今回は識別対象動作を 18 動作と設定しているため, 171 個の識別関数を構成して識別を行っている.

2.2.3 パラメータ推定について

本研究では, パラメータの決定の際に粒子群最適化法 (Particle Swarm Optimization : PSO)¹²⁾を用いた.

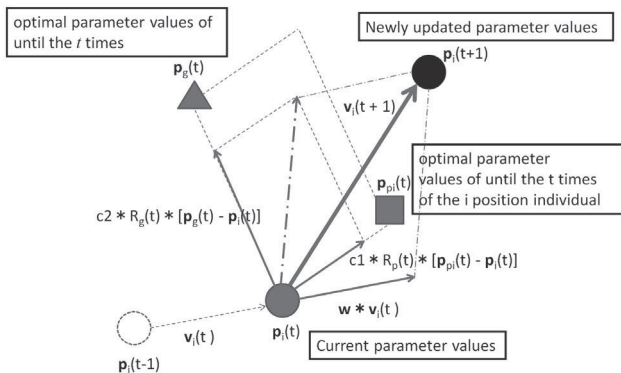


Fig.6 The Description of PSO Method

PSO は集団的効果法と呼ばれる手法の一つであり, 複数の解の集合により集団を形成し, 集団から得られる情報に基づき, 集団の各要素に対して順次新しい解を生成し, 新しい解が良ければ古い解と置換するという手法の一種である. PSO では, 解に対応する位置の情報を持つエージェント(個体)により集団を形成し, 各エージェン

トの現在位置とエージェントの最良位置と集団の最良位置により新しい位置を生成し, その位置が最良位置より良ければ古い最良位置と置換する¹³⁾. 解の更新は Fig.6 のようになる. $\mathbf{p}_i(t)$ は, パラメータ値を持つベクトルであり, $\mathbf{v}_i(t)$ は解の変化度合いを決めるベクトルである.

PSO にも解の探索効率を変化させることができるパラメータが存在しており, $\mathbf{v}_i(t)$ に慣性項と呼ばれるパラメータ w , 加速定数 c_1, c_2 がある. 慣性項 w を適応することにより, 速度を変化させるとが可能であり, 広域または詳細に探索することができる.

本研究においては, $w=0.9, c_1=0.0006, c_2=0.001$ に設定した. パラメータ値を更新するための式は以下の(8), (9)となる.

$$\mathbf{v}_i(t+1) = w\mathbf{v}_i(t) + c_1 R_p(t)[\mathbf{p}_{pi}(t) - \mathbf{p}_i(t)] + c_2 R_g(t)[\mathbf{p}_g(t) - \mathbf{p}_i(t)] \quad (8)$$

$$\mathbf{p}_i(t+1) = \mathbf{p}_i(t) + \mathbf{v}_i(t+1) \quad (9)$$

式(8)は $\mathbf{v}_i(t)$ を $\mathbf{v}_i(t+1)$ へと更新するための式, 式(9)は $\mathbf{p}_i(t)$ を $\mathbf{p}_i(t+1)$ へと更新するための式である. この式を用いて解を置換し, 指定した置換回数分更新を行い, その中から最適と思われるパラメータ値を選択する. PSO にて最適と思われるパラメータ値を探索した後に, SVM にそのパラメータを適応させ, 学習データを用いて個人毎に SVM の学習を行った.

開発したソフトウェアのインタフェース部や PSO に関しては Microsoft 社製の Visual Studio 2008 を用いて C 言語で実装した. SVM に関しては T. Joachims(Cornell University, Department of Computer Science)による SVM multiclass Version 2.20 ライブラリを用いて実装した.

3. 実験および実験結果

3.1 予備実験

本研究においては, 本実験を行う前に以下の予備実験を行う必要がある.

- 1) PSO におけるエージェント数(個体数)と解の置換回数(集団数)の決定
- 2) 非線形 SVM に用いるカーネルの決定

次に実験条件について説明する. 成人健常者 3 名から識別対象動作(18 動作)毎に 96 チャネル分の SEMG データを動作開始から 900ms の長さで計測した. このデータを 5 回取得し, 動作開始より 300ms 間の SEMG を学習のための特徴量として抽出する. また動作開始から 60ms の時間間隔をとり 300ms の SEMG を 10 データ取得し, これを動作識別実験に用いる識別対象データとする. つまり各動作で 5 回計測された SEMG データを 10 個切り出すため, すべての対象動作では計 900 個のデータが取得される. 上記の学習データと識別対象データの抽出を

1,000 の異なるチャンネルの組み合わせごとに行う。その学習データと識別対象データを SVM に適応した場合のそれぞれの最適なパラメータを探索し、学習データを用いて SVM の学習を行い、学習済みの SVM に識別データを適応させ、プログラム上で筋電位データの識別を行う。

実験 1)においてはパラメータ探索の際に“エージェント数(個体数)-解の更新回数(集団数)”の組み合わせを“5-5”, “5-10”, “5-15”, “10-5”, “10-10”, “15-5”の組み合わせで実験を行った。SVM は非線形識別器として用いて、使用したカーネルは RBF カーネル(式(4))を用いて実験を行った。実験結果を以下の Fig.7 に示す。




Fig.7 The Relationship between recognition rate and particle-swarm rate in PSO

Fig.7 の実験結果より、“5-10”の組み合わせが被験者平均の識別率とパラメータ探索時間(計算コスト)を考慮した場合に最適かと思われたため、実験においてはエージェント数を 5、解の置換回数を 10 と定めた。

実験 2)においては、PSO をエージェント(個体)数を 5、解の置換回数(集団数)を 10 とし、式(4)、(5)、(6)に示す代表的な各カーネルにおいて実験を行った。以下の Table 1 から 3 に実験結果を示す。

Table 1 A relationship between recognition rate and kernel parameters (RBF kernel)

Subject	C Parameter	γ Parameter	Recognition rate[%]
A	0.1060328	0.000089	93.11
B	0.0029600	0.000780	88.44
C	0.0005069	0.000080	76.22

Table 2 A relationship between recognition rate and kernel parameters (Polynomial Kernel)

Subject	C Parameter	s Parameter	c Parameter	Recognition rate[%]
A	1.231804241	2.855544763	7.71845500	90.00
B	N/A			
C	3.173071433	5.530446650	8.31339600	81.22

Table 3 A relationship between recognition rate and kernel parameters (Sigmoid Kernel)

Subject	C Parameter	a Parameter	b Parameter	Recognition rate[%]
A	0.514909217	0.018637214	8.83767E-07	5.56
B	3.17569E-16	1.68247E-08	9.89944E-17	5.56
C	1.471165956	4.710368733	48.15454279	5.56

実験結果について、まず RBF カーネルに関しては探索時間も短く、学習も高速だった。被験者 A は実験に習熟しており、高い識別率を示した。被験者 B、C についても高い識別率を示した。

多項式カーネルについては、被験者 C に関しては RBF カーネルを用いた場合よりも高い識別率を示した。被験者 A に関しても 90%以上の高い識別率を示した。欠点としては探索、学習ともに計算時間が長く、計算コストが大きくなる。さらに、被験者 B に関しては計算が収束せず、失敗した。このことから、RBF カーネルと比較した場合、多項式カーネルは安定性が劣るように考えられる。

シグモイドカーネルに関しては、パラメータ探索を行ったが、その際に良否の判断指標として利用している識別率が、いずれの被験者においても 5.56[%]を示し、計 50 回の探索のうち、最終的に探索されたパラメータを用いた動作識別率まですべて 5.56[%]となってしまう。探索が成功しなかった。そこで最終的に求められた 50 回目のパラメータ値を利用し動作識別を行ったが、すべての被験者において 5.56[%]の識別率という結果となった。すべて同値になってしまう理由として考えられるのは、識別データに学習データとして利用している部分が一部オーバーラップしていることである。動作開始から 300[ms]分の各動作分のデータ計 50 個があり、900 個中の 50 個が正答となるため、5.56[%]という結果となる。つまりオーバーラップしている部分しか識別できていない。すなわちシグモイドカーネルの利用では汎化性能を高めることが出来ず、SEMG の分類には適さないものと考えられた。

今回の予備実験 2)での結果を総合的にとらえると、非線形 SVM を利用した SEMG の分類に際して、安定性も高く計算コストも低い RBF カーネルを SVM に適応することが望ましいといえる。

予備実験 1)、2)より、本実験において、PSO にてパラメータ探索を行う場合には、エージェント数(個体数)を 5、解の置換回数(集団数)を 10 と定めた。また非線形 SVM における使用カーネルを RBF カーネルと定めた。

3.2 実験

これより、行った実験について述べる。本実験では先に述べた通り、SVM の線形識別規則としての汎化性能に注目し、線形 SVM を SEMG に適応し識別を行い、その識別率を求めた。選択チャンネル数を 1 チャンネルから 6 チャンネルまで変化させた際の識別率を比較した。また非線形 SVM と従来のシステムで用いてきた CDA を利用した際の識別率の比較を行った。

まず、実験条件について説明する。成人健常者 3 名から識別対象動作毎に 96 チャンネル分の SEMG データを動作開始から 900ms の長さで 5 回計測した。取得した 900ms の SEMG データを用いて、異なるチャンネルの組み合わせの 1000 個の学習データと識別データを生成し、SVM に適応した場合のそれぞれの最適なパラメータを探索し、学習データを用いて SVM の学習を行い、学習済みの SVM に識別データを適応させ、プログラム上で筋電位データの識別を行った。実験のフローチャートを Fig.8 に示す。

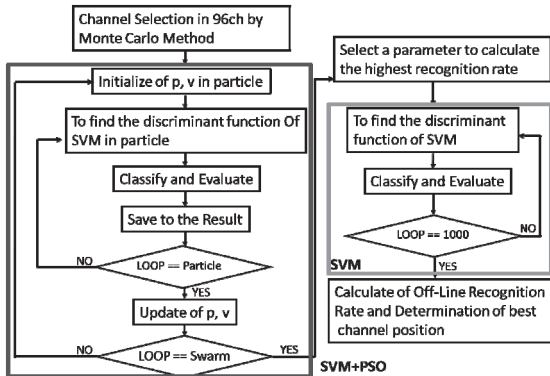


Fig. 8 The Flowchart of Our Hand Motion Recognition System

予備実験の結果を参照し、PSO のエージェント数(個体数)を 5、解の置換回数(集団数)を 10 とし、また非線形 SVM における使用カーネルは RBF カーネルとした。

実験結果は次の Table 4 から Table 12 の通りである。

Table 4 A relationship between recognition rate and kernel parameters (linear SVM, subject A)

The Number of Channel	C Parameter	Recognition Rate[%]
1	1.005217017	5.56
2	162.9115409	43.33
3	10.42090740	87.22
4	248.2563827	94.56
5	22.30804220	99.56
6	643.6796284	98.67

Table 5 A relationship between recognition rate and kernel parameters (non-linear SVM, subject A)

The Number of Channel	C Parameter	γ Parameter	Recognition Rate[%]
1	0.501302731	1.614070954	44.00
2	0.038660765	0.022963080	82.89
3	0.029306185	0.003345731	90.00
4	0.015218690	0.001631888	93.33
5	0.028592132	0.000701303	94.56
6	0.103502463	0.000433237	94.44

Table 6 A relationship between recognition rate and kernel parameters (CDA, subject A)

The Number of Channel	Recognition Rate[%]
1	39.7
2	79.1
3	90.3
4	93.4
5	96.4
6	97.3

Table 7 A relationship between recognition rate and kernel parameters (linear SVM, subject B)

The Number of Channel	C Parameter	Recognition Rate[%]
1	1.005217017	5.56
2	1.005217017	37.00
3	165.7215030	77.44
4	3.264350566	89.78
5	16.67244749	96.33
6	4568.985029	95.89

Table 8 A relationship between recognition rate and kernel parameters (non-linear SVM, subject B)

The Number of Channel	C Parameter	γ Parameter	Recognition Rate[%]
1	0.000289103	0.000385206	30.78
2	0.002619500	0.001092593	75.09
3	0.004748287	0.003345731	80.14
4	0.859155991	0.001631888	79.81
5	0.090471675	0.000159232	83.88
6	0.038983623	6.29514E-05	87.03

Table 9 A relationship between recognition rate and kernel parameters (CDA, subject B)

The Number of Channel	Recognition Rate[%]
1	27.60
2	56.20
3	77.80
4	84.90
5	90.20
6	93.40

Table 10 A relationship between recognition rate and kernel parameters (linear SVM, subject C)

The Number of Channel	C Parameter	Recognition Rate[%]
1	1.002325781	5.56
2	2.234240933	38.00
3	7.357165269	74.89
4	4.944682884	89.00
5	4725432.668	94.44
6	127709711.9	95.33

Table 11 A relationship between recognition rate and kernel parameters (non-linear SVM, subject C)

The Number of Channel	C Parameter	γ Parameter	Recognition Rate[%]
1	1.419527699	1.965272000	37.78
2	0.035879983	0.018585702	65.56
3	0.023665726	0.000121650	71.44
4	0.000264457	0.000584923	88.44
5	0.004846967	0.002116030	91.22
6	0.223104420	1.09642E-03	91.89

Table 12 A relationship between recognition rate and kernel parameters (CDA, subject C)

The Number of Channel	Recognition Rate[%]
1	37.00
2	65.00
3	84.40
4	89.40
5	94.00
6	96.00

4. 考察

Table 4 から Table 12 までの表は、選択チャンネル数の変化に伴う動作識別率の変化とその時のパラメータ値を示したものである。結果から、すべての被験者において、4チャンネル以上を選択した場合には、線形 SVM が非線形 SVM の識別率を上回る結果を示し、被験者 A については90%以上、被験者 B,C においては90%近くの識別率を示した。だが、チャンネル数が3チャンネル以下になると、非線形 SVM の識別率が上回った。これは、SVM は学習にて得た識別面と、未知データとの最大マージンを取るという手法であるため、特徴量となるデータが少なく分散の大きい粗な空間の場合の学習においては、線形 SVM では上手く識別面が構成できないためであると考えられる。非線形 SVM の場合は最良のものではないが識別面が構成できるため、それなりの識別率を示すものと考えられる。線形 SVM を利用する場合には、チャンネル数を多く取る必要があるとわかったが、識別速度は非線形に比べて高速なため、チャンネル数が増えたことによる計算

コストの増大は無視できるものと考えられる。

これらの結果を以下の Fig.9 から Fig.11 のグラフに被験者ごとにまとめて示す。




Fig.9 The relationship between recognition rates and the number of electrodes (Subject A)




Fig.10 The relationship between recognition rates and the number of electrodes (Subject B)




Fig.11 The relationship between recognition rates and the number of electrodes (Subject C)

これらのグラフでは、被験者ごとの識別率とチャンネル数の関係を線形 SVM、非線形 SVM、従来の CDA の場合と比較している。この図からは、CDA と非線形 SVM の結果が似通っているという結果が見て取れる。ここからいえるのは、我々の予想したように、単純な識別器であり、線形分離器である CDA によって、SEMG は分類可能であるということである。この結果を受け、さらにいえるのは、個人ごとに最適なチャンネル位置を導出することの重要性である。SEMG を導出する際には、解剖学的知見に則り、識別対象動作に対応する筋肉上に当たりをつけて、電極配置を行うことが一般的である¹⁴⁾。だが、我々が開発した手法により、解剖学的知見に依ることな

く、処理系にてランダムに算出した指定チャンネル数分の組み合わせから最適な電極配置を選択することが可能であると考える。今回の実験においても被験者毎に選択チャンネル位置が異なっており、被験者個人にとって最も最適なチャンネル位置が選択されている。以下に被験者ごとに選択されたチャンネル位置を示す。

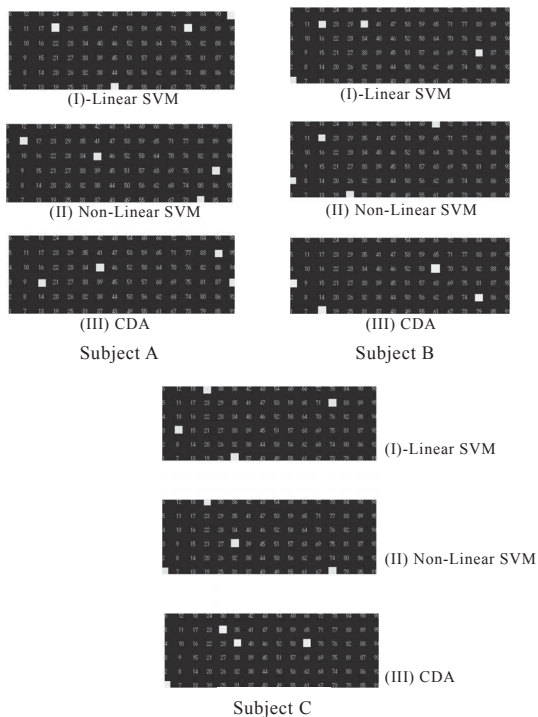


Fig.12 The relationship of discriminant analysis and select channel position

5. 結論

本研究においては SVM の識別能力の高さと、4 チャンネル以上という条件付きではあるが、前腕部特に手指の動作識別率向上という目的に対しての線形 SVM の汎化能力の高さが確認できた。また、従来のシステムで用いられている CDA の前腕部動作識別率の高さも証明できた。本実験の結果をから考えられることは、非線形 SVM に代表される複雑な非線形識別器に頼らなくても、CDA のような線形識別器を用いることにより本実験で行ったような(手指の動作を識別するための)SEMG パターンの識別は可能ではないかということである。今回の実験結果から非線形 SVM は使用するチャンネル数が少ない、言うなれば入力される情報量の少ない場合に有効な識別器として機能することが示されている。すなわちこのような複雑な非線形識別器の有用性が高まるのは識別に使用できる情報量の少ない、EEG を用いた BCI システムのような処理系においてではないかと考える。今後はここで得られた実験結果を踏まえ、SVM を EEG による BCI システムに用いる、もしくはクラス数が多くとも計算が可能であるという SVM の特徴を生かし、SEMG のより複雑な動作識別システムに用いる、等のことを実現して行き

たいと考えている。

参考文献

- 1) N.Wiener Ed:CYBERNETICS or Control and Communication in the Animal and the Machine, MIT Press (1948)
- 2) 櫛橋 康博, 本多 庸悟, 高橋 和彦, 飯沼 亮, 石黒潤 : 履歴を考慮した筋電周波数分布パターンによる前腕動作認識, 精密工学会誌 66(3), p468-472 (2000)
- 3) 松村 悠司, 福見 稔, 赤松 則男, 竹田 史章 : ニューラルネットワークを用いた手首 EMG パターン認識システムの構築. 電子情報通信学会技術研究報告. HIP, ヒューマン情報処理 103(166), p73-78 (2003)
- 4) 田中 豊 (編), 垂水 共之(編) : 統計解析ハンドブック, 共立出版, pp. 82-87 (1995)
- 5) 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, 情報・システム, J92-D(1), pp. 93-103 (2009)
- 6) 佐藤 貴哉 : SVM を用いた EMG による手指の動作認識に関する研究, 東海大学大学院 工学研究科 電気電子システム工学専攻 修士論文 (2009) (未公判)
- 7) 永田 健太郎 : 前腕部多チャンネル筋電位による手の動作認識に関する研究, 東海大学大学院, 工学研究科, 電気電子工学専攻, 博士論文 (2006)
- 8) 永田 健太郎, 安藤 啓一, 山田 雅史, 曲谷 一成 : チャンネル選択にモンテカルロ法を用いた多チャンネル EMG による手の動作認識, 生体医工学, Vol.44 No.1, 日本エム・イー学会, 138-147 (2006)
- 9) 田中 謙次 : ブレインコンピュータインタフェースのためのモデル選択に関する研究, 筑波大学大学院, システム情報工学研究科, 修士論文 (2007)
- 10) 佐藤 貴哉, 永田 健太郎, 山田 雅史, 曲谷 一成 : SEMG を用いた手指の動作認識における SVM のカーネル関数の比較, ロボティクス・メカトロニクス講演会講演概要集, "1A2-C27(1)"-"1A2-C27(3)", 日本機械学会 (2010)
- 11) 栗田 多喜夫 : サポートベクターマシン入門, 産業技術総合研究所 脳神経情報研究部門, <http://www.neurosci.aist.go.jp/~kurita/lecture/svm/svm.html> (2002)
- 12) J. Kennedy, R. Eberhart : Particle swarm optimization, IEEE International Conference on Neural Networks, 1942 - 1948 vol.4, (1995)
- 13) 高濱徹行 : 集団的降下法による最適化-差分進化と粒子群最適化-, 広島市立大学, <http://www.ints.info.hiroshima-cu.ac.jp/~takahama/documents/pdescent.pdf>
- 14) 渡辺 高弘, 巖見 武裕, 宮脇 和人, 佐々木 誠, 大日方 五郎, 島田 洋一 : 車いすの駆動条件の違いによる上肢関節への負荷の検討(OS 車いす支援システム), 福祉工学シンポジウム講演論文集, 日本機械学会, (2006)