

論 文

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吉川 雅博[†] 三河 正彦[†] 田中 和世[†]Real-Time Hand Motion Classification Using EMG Signals
with Support Vector MachinesMasahiro YOSHIKAWA[†], Masahiko MIKAWA[†], and Kazuyo TANAKA[†]

あらかし 本論文では筋電義手を制御するための、筋電位を利用して意図する手の動作をリアルタイムで識別する手法を提案する。本手法では特徴量に積分筋電位信号と筋電位信号のケプストラム係数を用い、サポートベクターマシン (SVM) により学習と動作識別を行う。SVM は様々なパターン認識問題に有効であることが分かっているが、筋電位を利用した動作識別においても有効かどうかは明らかになっていない。8名の被験者によるオフライン動作識別実験の結果、SVM を用いた提案手法は線形判別分析、 k -最近傍法、ニューラルネットワークを用いた手法よりも優れた識別性能を示した。また、リアルタイム動作識別実験を行った結果、動作識別が精度よく行われ、動作開始タイミングに遅れがなく応答性がよいことが示された。

キーワード 筋電位 (EMG), サポートベクターマシン (SVM), 動作識別, 義手

1. ま え が き

脳で発した運動指令により、筋繊維上に筋収縮を誘発する筋電位が発生する。筋電位は皮膚表面に電極を貼り付けて非侵襲に計測可能であり、筋電位から得られる動作情報を制御信号に変換し機械を制御する試みがなされてきた。中でも前腕切断者が使用する筋電義手は実用化に至っている。最も普及している Otto Bock 社の筋電義手は、前腕に残存する屈筋と伸筋より計測したそれぞれの筋電位の大きさに応じて手先の開閉を行う。筋電義手は従来の能動義手のような拘束感がなく、自然な感覚で制御できる点が優れている。しかし、本来の手の機能を回復するためには手先の開閉だけでは十分ではなく、多自由度を制御可能な筋電義手の開発が期待されている [1]。

多自由度筋電義手を実現する上で、構造や制御機構などのハードウェアと筋電位から制御信号を取り出すソフトウェアが欠かせない。後者で核となるのは、使

用者が意図する手の動作を筋電位から推定する技術であり、これを実現するために主にパターン認識手法が用いられてきた。前腕切断者の場合、実際に動作を行う代わりに動作イメージ (通常は幻肢) をもとに残存する筋肉を収縮させ、このとき発生する筋電パターンから意図する動作の識別を行う。従来の研究においてパターン認識手法が用いられてきたのは、(1) 用いる電極数よりも多くの動作数を識別したい、(2) 筋電位の個人差に適応することで訓練の負担を減らしたい、(3) 個人内でも動作のたびに変動する筋電位から安定した動作識別をしたい、などの理由による。

従来の研究ではこれまでに様々なパターン認識手法が用いられてきた。1970年から1980年代にかけては線形判別分析などの初期のパターン認識手法が用いられた [2]~[5]。1990年代になるとニューラルネットを用いて筋電パターンと動作間の非線形写像を学習する研究が行われるようになった [6], [7]。西川らは筋電位の周波数特徴を用いて手の10動作の識別を試みている [8]。辻と福田らのLLGMN (Log-Linearized Gaussian Mixture Network) を用いた研究では、ニューラルネットに混合正規分布モデルに基づいた事後確率推定を組み合わせた動作識別法を報告している [9]~

[†] 筑波大学大学院図書館情報メディア研究科, つくば市
Graduate School of Library, Information and Media Studies,
University of Tsukuba, 1-2 Kasuga, Tsukuba-shi, 305-8550
Japan

[11]. 最近では, Chu らは筋電位をウェーブレット変換し更に主成分分析による次元削減と自己組織化マップによる非線形マッピング後の特徴量をもとに動作識別を行っている [12]. ニューラルネットのほかにもファジー [13], 隠れマルコフモデル [14], 混合正規分布に基づく動作識別 [15] が提案されている.

一方, 1990 年代に提案された比較的新しいパターン認識手法にサポートベクターマシン (SVM) がある [16]. SVM は, (1) 大局的最適解が保証される, (2) 未観測のパターンに対する識別能力が高い, (3) ハイパラメータ探索が容易, (4) 識別時の計算量が少ない, (5) 学習を効率良く行うアルゴリズムがある, などの特長をもつ. SVM はバイオインフォマティクス [17] や画像認識 [18], テキスト分類 [19] などの分野で有効性が明らかになってきているが, 筋電位を用いた動作識別に利用する試みはいくつかの論文で報告されているのみである. Shenoy ら [20] は SVM を用いて手の動作識別を試みているが, 使用する電極数が 7 個と多く, SVM の中では識別能力の低い線形 SVM を用いている. また, 被験者が健常者 3 名と少なく, 他の識別器との比較も行われていないため, 筋電位を利用した動作識別における SVM の有効性を十分に明らかにできていないと考えられる. そこで, 本論文では筋電義手を制御するための, 筋電位を利用して意図する手の動作をリアルタイムで識別する手法を提案し, 8 名の被験者による動作識別実験を行って他の識別器と比較することにより有効性を検証する. これまでも筆者らは SVM を用いた手法を報告しており [21]~[23], 本論文はその最新の報告である.

以下, 2. では SVM による手の動作識別法について提案する. 3. では提案手法による手の動作識別実験について述べ, 4. では本論文のまとめを行う.

2. 筋電位を利用した手の動作識別法

本論文が提案する筋電位を利用した SVM による手の動作識別法の概要を図 1 に示す. まず, 信号計測部では前腕より筋電位信号 (以降 EMG 信号) を計測し, この信号をもとに積分筋電位信号 (以降 IEMG 信号) を生成する. 次に, 特徴抽出部では EMG 信号と IEMG 信号から特徴ベクトルを抽出する. 特徴ベクトルは EMG 信号のケプストラム係数と IEMG 信号をもとに構成する. 学習部では動作クラスを付与した学習データから SVM のハイパラメータを求め, 識別関数を事前に構成する. 動作識別部では識別関数をもとに特徴ベクトルを識別し, 動作クラスを決定する.

図 2 に本手法で識別する動作を示す. 手首屈曲 (Flexion), 手首伸展 (Extension), 握る (Grasp), 開く (Open), 前腕回内 (Pronation), 前腕回外 (Supination) の 6 動作である. これら 6 動作に力を抜いて動作をしていない状態の中立位 (Neutral) を加え, 7 クラスを識別する. 手の動作の中で切断者が

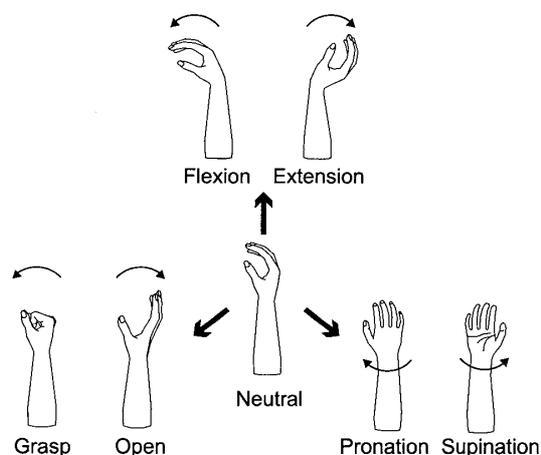


図 2 識別対象の 6 動作と中立位

Fig. 2 Six hand motions and neutral position classified by our method.

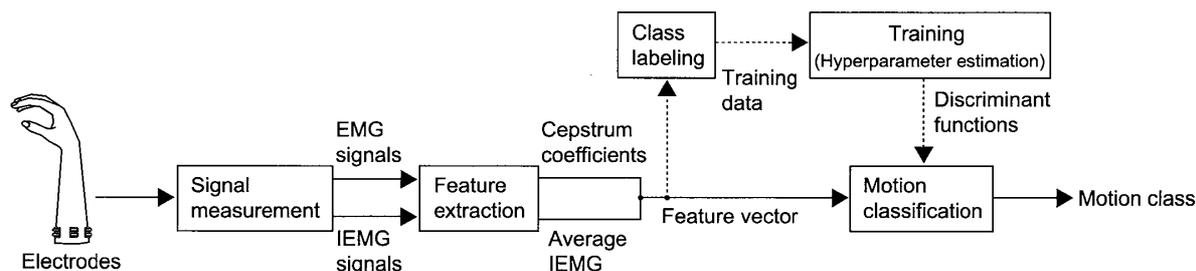


図 1 提案手法のブロックダイアグラム

Fig. 1 Block diagram of proposed method.

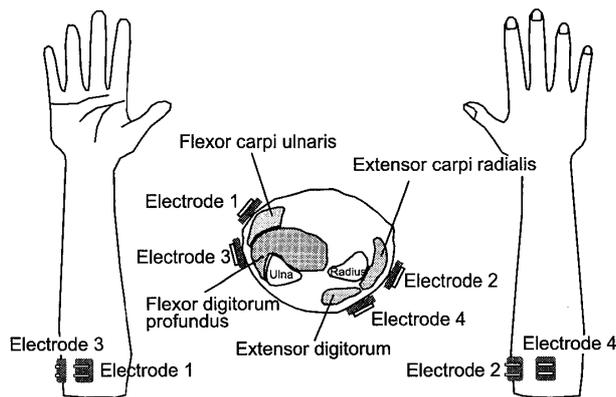


図3 4電極の前腕への貼り付け位置

Fig. 3 Positions of four electrodes placed on operator's forearm.

比較的イメージしやすく、主に前腕の筋肉で制御する動作であり、従来の研究においても識別対象となっている基本動作である。以下の節では各部について詳細に説明する。

2.1 信号計測部

筋電位の計測には実用化されている筋電義手と同様、乾式の表面電極（乾式センサ, (有) 追坂電子機器）を用いる。電極で検出した筋電位に対して、筋電位計測装置（Personal EMG, (有) 追坂電子機器）内蔵の帯域フィルタ（10～995.2 [Hz]）をかけ、1000倍に増幅してEMG信号を計測する。更に、EMG信号を全波整流、遮断周波数2.4 [Hz]の低域フィルタで平滑化を行いIEMG信号を計算する。IEMG信号は筋活動量の指標として広く使われている信号である。計測装置が出力するEMG信号とIEMG信号は、A-D変換器（PCI-3176, (株) インタフェース）を用いて、サンプリング周波数2000 [Hz]、量子化ビット数16 [bit]でサンプリングする。

図3に電極の装着位置を示す。動作に関与する前腕の筋肉直上に装着し、各動作に対して特徴的な信号パターンが得られるように配置する。筋肉の位置は、解剖学的な知見に基づき決定した[24]。電極1は尺側手根屈筋（手首屈曲）、電極2は橈側手根伸筋（手首伸展）、電極3は深指屈筋（握る）、電極4は総指伸筋（開く）の直上に配置する。前腕回内と回外はそれぞれ回内筋と回外筋が関与するが、義手ソケット内へ設置する電極数は少ないことが望ましいため、4個の電極で得られる筋電位を使用して動作識別を行う。アース電極は4電極を装着した腕の筋のない肘部に装着する。

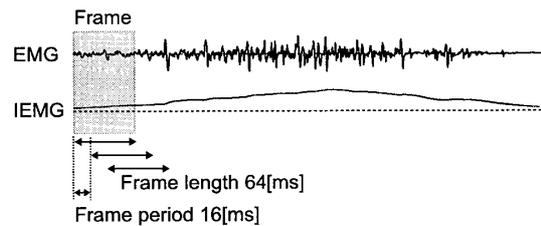


図4 特徴抽出フレーム

Fig. 4 Feature extraction frame.

2.2 特徴抽出部

特徴抽出部では動作識別に用いる特徴量をフレーム単位で抽出する。特徴抽出に必要なサンプル数を確保しつつ、60 [Hz]周期の動作識別を実現するため、図4に示すように、フレーム長64 [ms]（128サンプル）、フレーム周期16 [ms]（62.5 [Hz]）でフレームをシフトしながら、フレームで切り出したEMG信号とIEMG信号より特徴抽出を行う。EMG信号に対してはハミング窓による窓処理を行う。

各フレームでは、フレーム内平均IEMG（Average IEMG: AIEMG特徴）、EMG信号のケプストラム係数（Cepstrum coefficient: CC特徴）の2種類の特徴量を抽出し、特徴ベクトルを構成する。これらの特徴量は文献[25]を参考に、時間領域と周波数領域の特徴をシンプルな処理で抽出できることを基準に選択した。以下では2種類の特徴について述べる。

2.2.1 AIEMG特徴

AIEMG特徴はIEMG信号のフレーム内時間平均であり、EMG信号の振幅の大きさを表す。第 p ($p = 1, \dots, P$)番フレーム内で、 n 点目のIEMG信号サンプルを $IEMG_l(n)$ ($n = 0, \dots, N-1; l = 1, \dots, L$)とする。ここで、 N は1フレーム内のサンプル数を、 L は電極数を示し、本論文では前述したように $N = 128$ 、 $L = 4$ である。 l 番目の電極から得たAIEMG特徴 $AIEMG_l(p)$ は次式で計算する。

$$AIEMG_l(p) = \frac{1}{N} \sum_{n=0}^{N-1} IEMG_l(n) \quad (1)$$

AIEMG特徴やこれと同等の特徴量（例えば、Integrated Absolute Value: IAVなど）は、従来の研究でも他の特徴量とともに用いられる基本的な特徴量である[25]。

2.2.2 CC特徴

CC特徴はフレーム内のEMG信号に対するケプストラム分析により求める。第 p 番フレーム内の n 点目のEMG信号サンプルを $EMG_l(n)$ とし、 $EMG_l(n)$

のフーリエ変換 $X_l^k(p)$ ($k = 0, \dots, N-1$) を,

$$X_l^k(p) = \sum_{n=0}^{N-1} EMG_l(n) e^{-j2\pi kn/N} \quad (2)$$

で表すと、ケプストラム係数 $CC_l^n(p)$ は次式で計算される。

$$CC_l^n(p) = \frac{1}{N} \sum_{k=0}^{N-1} \log |X_l^k(p)| e^{j2\pi kn/N} \quad (3)$$

ケプストラム分析はスペクトルの包絡形状と微細構造を分離可能であり、低次係数には包絡形状の特徴が、高次係数には微細構造の特徴が表れる。本手法では $n=0$ から $n=W-1$ までの W 個の低次係数を CC 特徴として採用し、包絡形状を特徴に利用する。ケプストラム係数は高速フーリエ変換を用いて計算するため、リアルタイムでの計算にも適している。

最終的に各電極に対して一次元の AIEMG 特徴、 W 次元の CC 特徴を抽出し、合計で $L(1+W)$ 次元の特徴ベクトル $\mathbf{x}(p)$ を計算する。

$$\begin{aligned} \mathbf{x}(p) = & (AIEMG_1(p), \dots, AIEMG_L(p), \\ & CC_1^0(p), \dots, CC_1^{W-1}(p), \dots, \\ & CC_L^0(p), \dots, CC_L^{W-1}(p))^t \end{aligned} \quad (4)$$

W の最適値については、3.1.1 で検討する。

2.3 学習部と動作識別部

2.3.1 学習データの作成

特徴ベクトルに動作クラスを付与し、学習データを作成する方法について述べる。関節角度センサなどで別途計測した動作情報をもとに動作クラスを付与する方法は、手の動きを直接計測できない前腕切断者へは適用が難しい。そこで、あらかじめ定めた順序で動作を行ったときの筋電位計測データのみを使用して動作クラスを付与することとする。このために、動作意図をもって筋収縮している時間区間（以降、動作区間）を検出する必要がある。本研究では、一定の基準で自動的に動作区間を決定した後、決定した動作区間をデータ作成者が確認し、明らかな誤りがあると判断した場合に手動で調整を行う。

まず 6 動作をあらかじめ定めた順序で連続して行ったときの筋電位計測データを用意し、特徴ベクトル $\mathbf{x}(p)$ を計算する。各動作では中立位の状態から関節を自動関節可動域まで動かした後、力を抜いて再び中立位に戻す。次に、EMG 信号の零交差数をもとに動作

区間の検出を行う。次式に示す零交差の定義に基づいて、各電極で計測した EMG 信号をその最大値で正規化した EMG_l^s のフレーム内零交差数 $ZC_l(p)$ を算出する。

$$\begin{aligned} EMG_l^s(n)EMG_l^s(n-1) < 0 \quad \text{and} \\ |EMG_l^s(n) - EMG_l^s(n-1)| > 0.01 \end{aligned} \quad (5)$$

次に、 $ZC_l(p)$ の総和 $ZC_{sum}(p)$ を計算し、更に移動平均で平滑化する。

$$ZC_{ma}(p) = \frac{\sum_{m=-M}^M ZC_{sum}(p+m)}{2M+1} \quad (6)$$

ここで $M=10$ とした。 $ZC_{ma}(p)$ がしきい値 R 以上のフレームが連続する区間を動作区間とみなし、それぞれの動作区間内の特徴ベクトルに対して同一の動作クラスを付与する。 R は $ZC_{ma}(p)$ の平均値とする。ただし、データ作成者が図 5 に示すようなグラフにより EMG 信号の立上り位置を判断し、動作区間の開始位置が EMG 信号の立上り位置に対して 6 フレーム（約 100 [ms]）以上遅れた場合には、1.0 単位で R を増減し、適切な開始位置になるように手動で調整する。

図 5 に上記手順で付与した動作クラスの例を示す。上から四つのグラフは 4 電極の EMG 信号の波形を示し、次の三つのグラフは上から、手首関節角度、人差し指 MP 関節（人差し指の付け根関節）角度、前腕の回内/回外角度を関節角度センサで計測した実測値であり、手首屈曲、手首伸展、握る、開く、前腕回内、回外の順に動作を行っていることを示している。付与した動作クラスと比較すると、実際の動作開始タイミングとほぼ一致していることが分かる。ただし、動作終了時付近の動作区間は、筋収縮が弱く筋電位がほとんど発生していないため実際の動作よりも短くなっている。前腕切断者の場合にも、動作イメージをもとに筋収縮を行うことにより、同様の方法で学習データの作成が可能であることを確認している。

2.3.2 SVM による学習と動作識別

ここでは、学習データをもとに SVM を用いて識別関数を構成する方法について述べる。未知パターンの特徴ベクトル $\mathbf{x}(p)$ （以降 \mathbf{x} とする）を 2 クラスのいずれかに識別する識別関数を次式で表す。

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^D \lambda_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right) \quad (7)$$

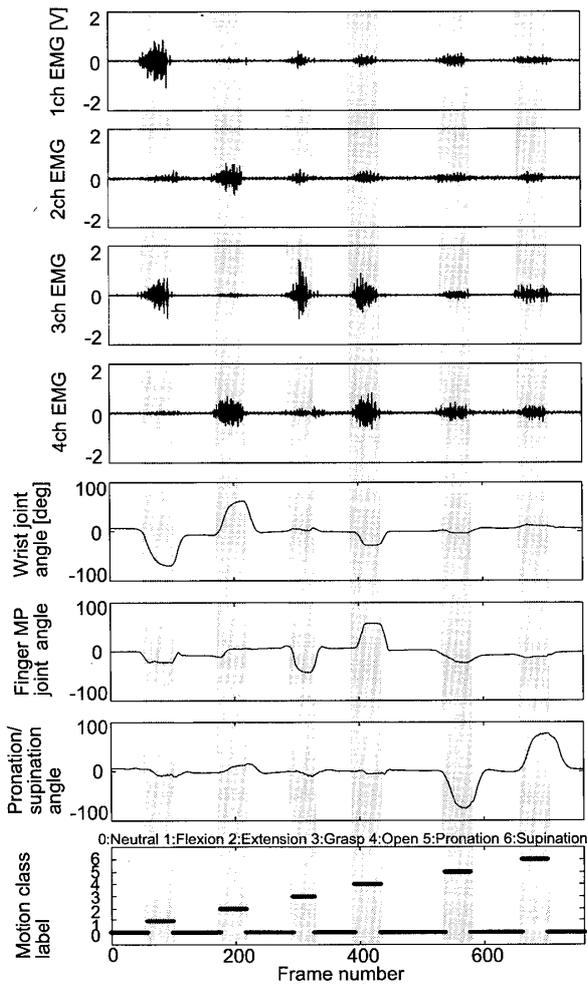


図5 動作クラスラベル付与の例

Fig. 5 An example of motion class labeling.

ここで y_i は i 番目の学習サンプル \mathbf{x}_i に対応するクラスラベルであり, λ_i はラグランジュの未定乗数, b はバイアス項である. $K(\mathbf{x}_i, \mathbf{x})$ はカーネル関数であり, 本手法では決定すべきカーネルパラメータが一つで求めやすく, 予備実験ではシグモイドカーネル, 多項式カーネルよりも識別性能が良好だったので, 次式で表す Radial basis function (RBF) カーネルを用いる.

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2) \quad (8)$$

ここで γ はカーネルパラメータである. カーネル関数は線形分離不可能な学習データを, 高次元の特徴空間に写像し, 写像先の特徴空間において線形分離可能にする. そのため, 線形分離不可能な分布になりやすい筋電パターンへの識別に適している.

実際に式 (7) に示した識別関数を求めるためには, マージン最大化基準によって次式を最大にする λ_i を求める.

$$\begin{aligned} \max \quad & \sum_{i=1}^D \lambda_i - \frac{1}{2} \sum_{i,j=1}^D \lambda_i \lambda_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (9) \\ \text{subject to} \quad & \sum_{i=1}^D \lambda_i y_i = 0, 0 \leq \lambda_i \leq C \end{aligned}$$

上式は凸二次計画問題であり, 大域的最適解が保証される. 求めた λ_i のうち, 非 0 の λ に対する学習サンプルはサポートベクターと呼ばれ, 識別関数は学習サンプル中の少数のサポートベクターのみで構成されるため識別に必要な計算量は少なくなる. C はどの程度の誤識別を許すかを決定するペナルティパラメータであり, 学習時にあらかじめ求めておくハイパパラメータは, この C とカーネルパラメータ γ の二つのみである. これにより, ハイパパラメータの探索が容易となっている. C と γ の最適値は, 3.1.1 で述べる.

2.3.3 マルチクラスへの拡張

SVM は原理的に 2 クラスを識別する手法であるため, マルチクラスを識別するために one-against-one 法を用いる. この方法では, O 個のクラスのすべての組合せ, すなわち $O(O+1)/2$ 個の識別関数を構成し, 各識別関数を用いて特徴ベクトルの識別を行う. すべての識別結果を集計し, 最も多く識別された動作クラスをフレームにおける最終的な識別結果とする. マルチクラスへ拡張する方法にはほかに, one-against-all 法がある. Hsu らによる二つの方法の比較実験から, 学習時間と識別精度に関して, one-against-one 法が優れていることが示されている [26]. そのため, 本提案手法では one-against-one 法を採用した.

3. 実験

3.1 オフライン動作識別実験 (実験 1)

まず, 学習データを用いて特徴量パラメータと SVM パラメータの最適値を求め, 提案手法によるオフラインでの動作識別実験を行った. 実験条件は以下のとおりである.

(1) 被験者

被験者は 20 代~30 代の健常な男性 4 名 (A, B, C, D), 女性 4 名 (E, F, G, H), 全員右利きである. 被験者 A, B, E については, 予備実験により筋電位計測に習熟しているが, その他の被験者は初めての計測であった.

(2) 実験システム

筋電位の計測は 2.1 で説明したとおりとし, 被験者の右前腕に乾式電極を貼り付けた. 信号計測部と特徴

抽出部は、Visual C++ 2005 (マイクロソフト (株)) で、学習部と動作識別部は MATLAB2006b (MathWorks 社) を用いて開発した。SVM の学習・識別アルゴリズムは、SVM ライブラリである LIBSVM [27] を用いて実装した。以上のプログラムは、パーソナルコンピュータ (CPU: Core 2 Duo 2.4 GHz, メモリ: 1024 MByte, OS: WindowsXP) 上で実行する。なお、被験者には関節角度モニタ用に関節角度センサを装着した。手首関節と人差し指 MP 関節を計測するシェイプセンサ (shapeseenor S720, Measurand 社) と前腕回内/回外角度を計測する加速度センサ (3 軸加速度センサ, (有) 浅草技研) の装着位置を図 6 に示す。

(3) 動作課題

被験者はコンピュータディスプレイの前に置かれた椅子に自然な姿勢で座る。本論文では机上での作業や腰の高さほどにある対象を操作することを想定し、肘を体幹から 15 cm ほど離し 80 度ほど曲げ、肘と手先がほぼ同じ水平位置になるようにした。前腕と手は机などに接触していない。ディスプレイ上には図 7 に示す 3 自由度をもった三次元コンピュータグラフィックス (3DCG) ロボットハンドが表示され、被験者はロボットハンドが行う動作に合わせて同じ動作を行う。1 試行は 60 [s] であり、手首屈曲、手首伸展、握る、開く、前腕回内、回外の順に 5 セット、計 30 動作を行う。各動作では中立位の状態から関節を自動関節可動域まで動かした後、力を抜いて再び中立位に戻し、次の動作を行う。各動作の開始から完了までおよそ 1 [s] とする。

(4) 学習・評価方法

以上の実験条件で各被験者につき 20 試行 (総動作回数 600 回) を行い、すべての特徴ベクトルに対して 2.3.1 の方法で動作クラスを付与した。第 1 と第 2 試行を学習データとし、残り 18 試行のデータで評価を行った。中立位は 6 動作に比べてデータ点数が多いため、10 分の 1 に間引いてアンバランスを解消して学習を行った。

評価には動作識別率と総識別率を用いる。動作識別率は以下の式で定義し、動作ごとの識別率とする。

$$\text{動作識別率} = \frac{\text{正しく識別された特徴ベクトル数}}{\text{同一動作クラスの特徴ベクトル総数}} \times 100$$

同一動作クラスの特徴ベクトル総数は、被験者・動作により異なるが 18 試行全体で 3500 点 (中立位は 45000 点) 前後である。総識別率は中立位と 6 動作の動作識別率の平均値と定義した。

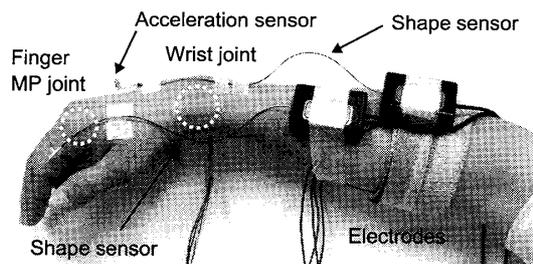


図 6 関節角度センサの装着位置

Fig. 6 Positions of three joint angle sensors.

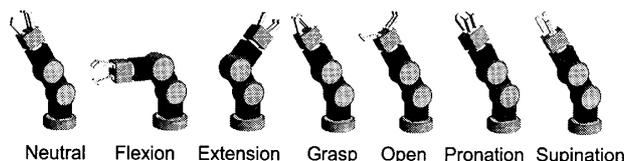


図 7 被験者に動作を教示する 3DCG ロボットハンド

Fig. 7 3DCG robohand that directs subjects the next motion to be performed.

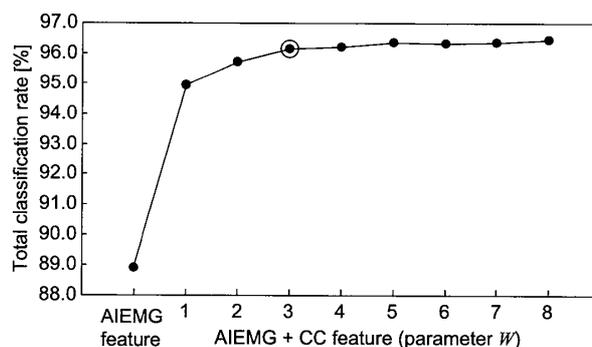


図 8 特徴量パラメータ W による総識別率への影響

Fig. 8 Effects of feature parameter selection on the total classification rate.

3.1.1 特徴量と SVM のパラメータの検討

まず、動作識別実験に用いる CC 特徴のパラメータ W を決定した。AIEMG 特徴と CC 特徴の組合せを特徴ベクトルとする学習データを用い、 W を変えて 5 重交差確認法により総識別率を求めた。ここで SVM パラメータは $\gamma = 0.5$, $C = 1$ に固定している。図 8 に、 W の値を 1 から 8 まで変化させた総識別率の被験者平均を示す。 $W = 3$ での識別率は 96.2% となり、以降は識別率が大きく向上しない。特徴ベクトルの次元数増加による計算量と識別率のバランスを考慮し、以降の実験では AIEMG 特徴と $W = 3$ の CC 特徴を組み合わせた特徴ベクトルを用いることとする。なお、AIEMG 特徴に $W = 3$ の CC 特徴を加えた場合、AIEMG 特徴単独の場合に比べて 7.3% 識別率が向上し、CC 特徴が有効であることも確認できた。

表 1 各識別器のハイパパラメータ
Table 1 Hyperparameter of each classifier.

Subject	SVM		k-NN	BPNN
	γ	C	k	# of unit
A	2^{-1}	2^4	5	19
B	2^{-3}	2^6	4	12
C	2^{-2}	2^4	5	12
D	2^{-1}	2^4	4	19
E	2^{-4}	2^7	4	20
F	2^{-5}	2^7	4	16
G	2^{-1}	2^1	6	23
H	2^{-1}	2^4	4	15

次に、被験者ごとに最適な SVM のハイパパラメータ γ と C を、学習データを用いて格子探索により決定した。 γ と C の探索範囲は予備実験によりある程度狭め、 $\gamma = \{2^{-5}, 2^{-4}, \dots, 2^0\}$, $C = \{2^1, 2^2, \dots, 2^8\}$ の 48 通りの組合せとした。各格子点では 5 重交差確認法を用いて、最も高い総識別率を示す γ と C の組合せを探索した。以上の方法で決定した各被験者の γ と C を表 1 に示す。最適な組合せと最も低い識別率を示す組合せの差は最大で 6% であったが、最適な組合せから極端に離れない限り大きな識別率の低下はなかった。また、ハイパパラメータの探索と識別関数の学習にかかる時間は、被験者平均で 29.9 [s] であった。

3.1.2 動作識別精度

前項で求めた SVM のハイパパラメータを用いて学習を行い、18 試行分の評価データを識別したときの動作識別率と総識別率（最右列）を表 2 に示す。総識別率は全被験者で 91% 以上となり、被験者平均は 94.6% であった。特に筋電位計測に習熟した被験者 A, B, E の総識別率が高く、初めて計測を行った C, D に関しても 95% 以上の識別精度が得られた。一方、動作識別率の被験者平均を見ると、手首屈曲と手首伸展、握る、開くについては、95% 以上の識別率が得られているが、回内と回外に関しては 95% を下回っている。特に G, H に関しては 90% を下回った。この原因として、回内と回外に関与する筋肉を直接計測していないために、他の動作と分離可能な筋電パターンが検出できない場合があることが推測される。

そこで誤識別の詳細を調べるため、表 3 に示すコンフュージョンマトリックスを作成した。行は動作識別により推定された動作クラスを、列は実際の正解動作クラスを表し、各セルは該当する特徴ベクトル数で被験者平均である。この表より、回内と回外は他の 6 動作と誤識別するケースが多いことが分かる。ただし、全体的には 6 動作間で相互に誤識別するよりも、中立位

表 2 SVM による各動作の識別結果
Table 2 Classification results for each motion.

Sub.	NE	FL	EX	GR	OP	PR	SU	Total
A	90.6	99.6	99.8	98.7	98.8	97.2	94.6	97.0
B	90.9	98.9	95.9	97.5	95.6	90.0	97.7	95.2
C	87.3	97.4	98.6	99.1	94.4	96.3	94.0	95.3
D	93.8	95.3	97.4	93.2	97.2	95.1	93.2	95.0
E	89.7	98.6	98.5	98.1	97.6	96.8	98.5	96.8
F	94.6	90.5	93.0	90.7	96.0	93.3	96.6	93.5
G	91.8	98.2	91.7	90.7	93.1	88.6	83.2	91.1
H	90.7	97.5	97.2	92.5	94.9	97.6	81.1	93.1
Mean	91.2	97.0	96.5	95.1	96.0	94.4	92.4	94.6

NE:Neutral FL:Flexion EX:Extension GR:Grasp OP:Open PR:Pronation SU:Supination

表 3 誤識別の分析
Table 3 Analysis of misclassification.

		Estimated class						
		NE	FL	EX	GR	OP	PR	SU
Actual class	NE	42066	486	583	784	532	964	734
	FL	79	3434	0	11	1	16	1
	EX	79	0	3490	7	11	20	8
	GR	119	12	0	3333	16	13	7
	OP	65	0	5	32	3491	30	14
	PR	95	18	5	18	40	3435	31
	SU	129	3	12	14	22	62	3120

NE:Neutral FL:Flexion EX:Extension GR:Grasp OP:Open PR:Pronation SU:Supination

と 6 動作との間で誤識別が起こっているケースが多い。すべての被験者について正解動作クラスと推定された動作クラスを図 12 の最上段のグラフ（詳細は後述）のように時系列にプロットして比較し、誤識別の位置を確認したところ、誤識別の多くは動作開始と終了時に集中しており、筋電位の振幅が小さい中立位と動作区間の境界での識別が難しいことが分かった。

3.1.3 他の識別器との比較

SVM の有効性を検証するため、線形判別分析 (LDA)、 k -最近傍法 (k -NN)、バックプロパゲーションニューラルネットワーク (BPNN) との比較を行った。 k -NN は k の値を 1 から 10 まで変えて、学習データに対して 5 重交差確認法を用いて被験者ごとに最適値を選んだ。BPNN は 3 層ネットワークで入力層 16、出力層 7、中間層のユニット数を 10 から 33 まで変えて最適値を選択した。伝達関数は双曲線正接シグモイド関数、学習率 0.01、学習終了条件は二乗誤差 0.01 以下とした。実験に用いた k -NN の k と BPNN の中間層のユニット数を表 1 に示す。以上の識別器を用いて学習し、評価データの識別を行ったときの総識別率の被験者平均と標準偏差を図 9 に示す。BPNN に関しては、局所最適解を考慮して乱数で生成した

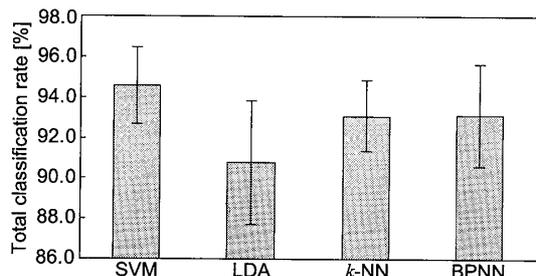


図 9 他の識別器との総識別率の比較

Fig. 9 Comparison of total classification rate achieved with different classifiers.

10通りの初期重みで識別した平均値とした。グラフを見ると、SVMが最も識別率が高いことが確認できる。個人差の影響を分離するため二元配置分散分析を行った結果、各識別器による識別率の差は有意であった ($p < 0.01$)。更にscheffe法による多重比較を行ったところ、SVMの識別率は他のすべての識別器に比べて有意に高かった ($p < 0.05$)。

3.1.4 筋電パターンの経時変化に対する頑健性

疲労や発汗、電極ずれなどの理由により、筋電位の性質は時間とともに変化する。例えば、筋疲労により振幅が増大し[28]、低周波数側へシフトする[29]ことが知られている。筋電パターンの経時変化に対する頑健性を検証するため、最も識別率の高い被験者Aを対象として約90分間の動作識別実験を行った。約2分間隔で42試行を行い、第1と第2試行で学習を行っている。このときの総識別率の変化を図10に示す。全識別器とも22試行(約45分)あたりから徐々に識別率が低下する傾向があるが、SVMは90分間にわたって92%以上の識別率を維持しており、平均値は96%、最大値と最小値の差は5.9%であった。一方、LDAとk-NNの平均値はそれぞれ92.9%と92.7%、最大値と最小値の差はそれぞれ10.1%と8.5%であり、最終的に90%以下に識別率が低下した。BPNNは平均値が94.9%、最大値と最小値の差は6.1%であり、SVMよりもすべての試行において識別率が低いことが分かる。SVMは最初の学習において、他の識別器よりも経時変化する筋電パターンをうまく識別できるモデルを獲得していることが示唆される。

実験1の結果をまとめると、SVMはLDAに比べ明らかに識別精度が高く、k-NNに対しても識別精度が優れ、特に長時間実験で顕著であった。BPNNの識別性能はSVMに若干劣る程度であるが、局所最適解に陥りやすく、またハイパラメータを決定するのに試

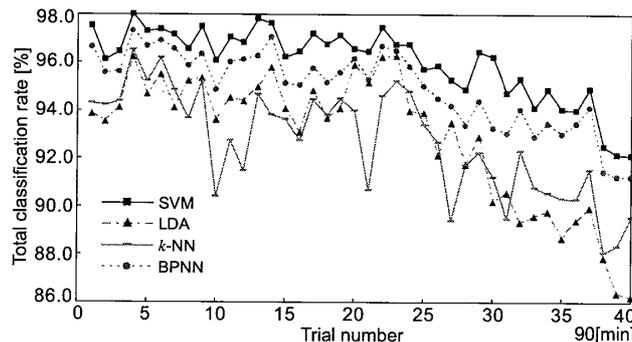


図 10 長時間実験での総識別率の変化

Fig. 10 Variations of total classification rate over long experimental period.

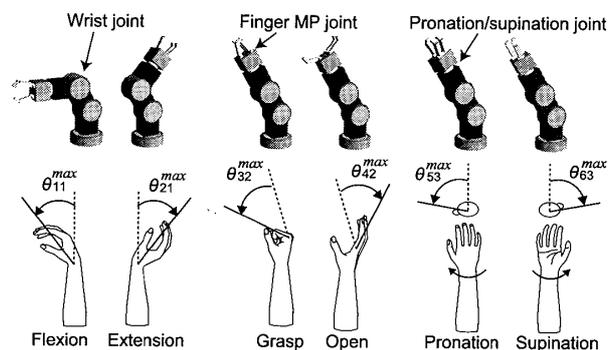


図 11 被験者とロボットハンドの関節の関係

Fig. 11 Relation between joint angles of the subject and the robot hand.

行錯誤を要し学習時間がかかるため、更に工夫の必要がある。一方、SVMはハイパラメータを求めるのが容易で短時間に学習を完了でき、四つの識別器の中で最も高い識別性能を示した。福田と辻のLLGMN[11]やR-LLGMN[30]など、ニューラルネットに独自の拡張を行い識別性能の向上を図っている手法もあるため、共通のデータセットと評価方法を用いて今後それらと比較検討する必要性はある。しかし筋電位を利用した動作識別において、現段階でもSVMは特別な工夫なしに高い識別性能を発揮できる優れた識別器であるといえる。SVMの学習の容易さは、識別率が低下した際の再学習においても有利であると考えられる。

3.2 リアルタイム動作識別実験 (実験2)

次に、提案手法を用いてリアルタイムに動作識別が行えるかを確認するため、リアルタイム動作識別実験を行った。本実験では、動作識別結果に基づき図11に示す3DCGロボットハンドの関節を駆動した。このため、AIEMG特徴の全電極平均 $E(p)$ を次式の簡易的なモデルでロボットハンドの関節角度に変換する。

$$\theta_{ca}^*(p) = \frac{E(p) - E_c^{min}}{E_c^{max} - E_c^{min}} \theta_{ca}^{max} \quad (10)$$

論文／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

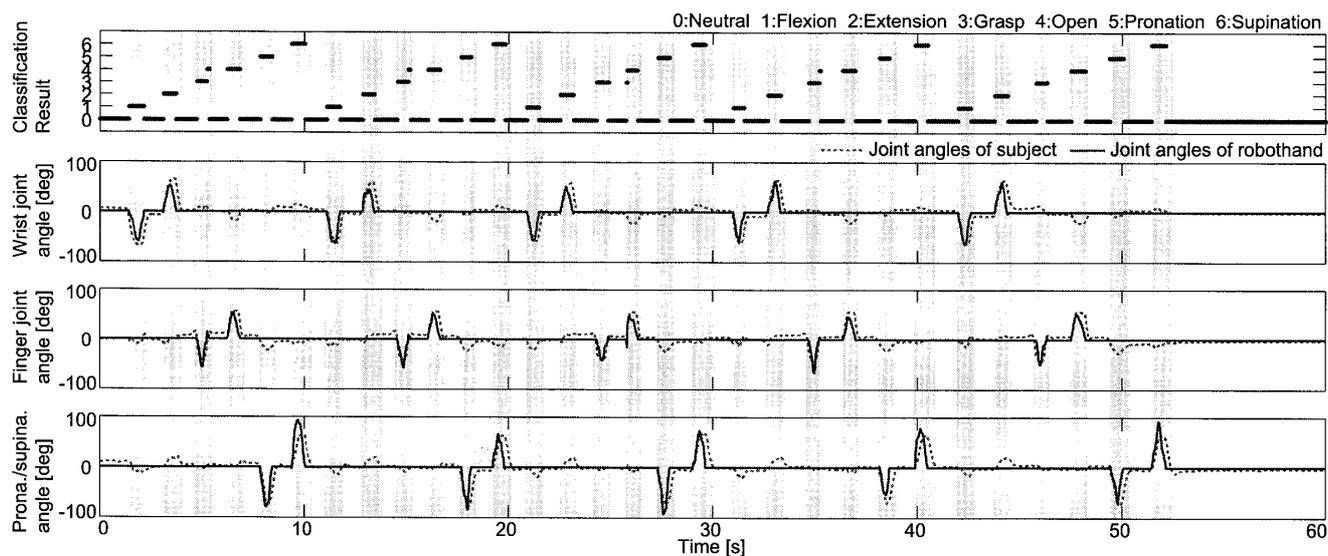


図 12 被験者 A のリアルタイム動作識別の例

Fig. 12 An example of real-time motion classification for subject A.

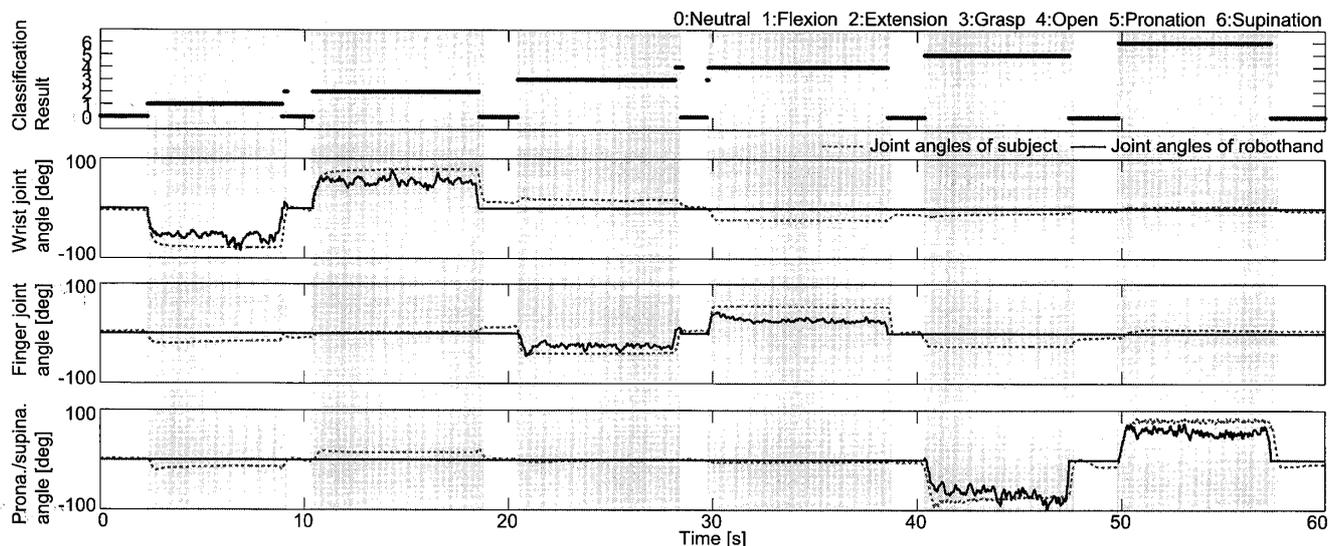


図 13 自動関節可動域で筋収縮を維持したときの動作識別の例

Fig. 13 An example of real-time motion classification when the subject kept muscle contraction at active range of motion.

ここで、 θ_{ca}^{max} は動作 c ($k = 1, \dots, 6$) における関節 a ($k = 1, \dots, 3$) の自動関節可動域の角度である。人間の関節とロボットハンドの関節の関係は図 11 に示した。 E_c^{max} と E_c^{min} は、それぞれ動作 c を行ったときの動作区間内の $E(p)$ の最大値と最小値を動作回数で平均した値であり、学習データより求める。このように求めたロボットハンドの関節角度と被験者の実際の関節角度を一つのグラフ上に時系列でプロットして比較することで、動作識別が正しく行われ、動作識別タイミングに遅れがないか確認できる。また、被験者にロボットハンドの動作を表示することで、遅れを感

じないか被験者自身も確認できる。

実験システムのハードウェア構成は実験 1 と同様であり、学習部以外は Visual C++ 2005 で実装した。動作識別と関節角度の計算は、62.5 [Hz] 周期で現時点より 1 フレーム過去、すなわち 16 [ms] 前の特徴ベクトルを用いて行われる。なお、動作識別ではある動作で識別されている連続フレーム中に、筋電位の揺らぎやノイズなどの原因により突発的に別の動作として誤識別される場合がある。このような誤識別を避けるために、現在のフレームと過去 5 フレームの計 6 フレームで識別結果の投票を行い、投票数の最も多い動作ク

ラスを現在のフレームにおける動作クラスとしている。

実験 1 と同様に学習を行い、リアルタイムで動作識別を行った被験者 A の実験結果を図 12 に示す。最上段のグラフは動作識別の結果である。次の三つのグラフの破線は上から手首関節角度、人差し指 MP 関節角度、前腕回内/回外角度を関節角度センサで計測した実測値であり、手首屈曲、手首伸展、握る、開く、前腕回内、回外を繰り返し行っていることを示している。実線はロボットハンドの関節角度である。網掛け部分は関節角度センサの値に基づく動作区間を示す。グラフより、動作識別が精度良く行われ、動作開始タイミングに遅れがなく応答性がよいことが分かる。被験者も自身の動作に対してロボットハンドの動作に遅れがないと評価した。“握る”の後に短い区間“開く”で識別されているのは、実際に“開く”に関連した筋電位が発生しており、被験者のくせによるものと考えられる。

次に、同じ学習モデルを用いて、各動作に対応する関節の自動関節可動域で 7 秒程度筋収縮を維持した場合の動作識別結果を図 13 に示す。動作開始と終了時に若干の誤識別が見られるものの、動作を維持した場合にも安定した動作識別が可能であった。

本実験では被験者の実際の動きと比較できるように $E(p)$ をロボットハンドの関節角度へ変換した。この方式では、筋電位が発生しない区間ではロボットハンドの関節角度が初期位置に戻ってしまう。そこで、実際に筋電義手へ応用する際には、ある動作で識別される区間では対応する義手の関節を 1 方向にのみ変位させ、変位した状態で次に中立位や別の動作が識別された場合には変位した関節をそのままの状態を維持するようにすると、動作の維持や手首屈曲しながら握るなどの複合動作が容易となる。

4. む す び

本論文では筋電義手を制御するための、筋電位を利用して意図する手の動作をリアルタイムで識別する手法を提案した。本手法では特徴量に積分筋電位信号と筋電位信号のケプストラム係数を用い、SVM により学習と動作識別を行う。SVM を用いることによりハイパラメータを決定しやすく、大局的最適解も保証され、短時間で学習できる。8 名の健常者によるオフライン動作識別実験の結果、SVM を用いた提案手法は LDA, k -NN, BPNN よりも優れた識別性能を示した。また、提案手法をシステムに実装し、リアルタイムで動作識別実験を行った結果、動作識別が精度良

く行われ、動作開始タイミングに遅れがなく応答性がよいことが示された。

現在、筋電義手への応用に向けて、提案手法の有効性を 7 名の前腕切断者の協力により検証中であり、別途報告を行う予定である。今後は、複数フレームにまたがる動的な特徴量など、筋電位の時系列情報を利用して識別精度の向上を図る。また、提案手法の電動義手への組み込みを行う。学習と動作識別処理をすべて組み込むのは処理速度・小型化の面で難しいが、学習処理を外部のコンピュータで行い、識別関数による動作識別処理のみをマイクロコンピュータなどへ実装するのは実現可能であると考えられる。

本研究の一部は、科学研究費補助金 (19500377) の助成を受けて実施した。

文 献

- [1] 東原孝典, “今日の筋電義手,” 日本義肢装具学会誌, vol.17, no.4, pp.228-233, 2001.
- [2] 鈴木良次, 末松辰美, “LINC-8 を用いた筋電流パタンの学習識別,” ME 誌, vol.7, no.1, pp.47-50, 1969.
- [3] D. Graupe and W.K. Cline, “Functional separation of EMG signal via ARMA identification methods for prosthetic control purposes,” Trans. Syst., Man, Cybern., vol.5, no.2, pp.252-259, 1975.
- [4] G.N. Saridis and T.P. Gootee, “EMG pattern analysis and classification for a prosthetic arm,” IEEE Trans. Biomed. Eng., vol.29, no.6, pp.403-412, 1982.
- [5] 辻 敏夫, 伊藤宏司, 長町三生, “義手制御を目的とした多チャンネル EMG 動作識別法,” 信学論 (D), vol.J70-D, no.1, pp.207-215, Jan. 1987.
- [6] M.F. Kelly, P.A. Parker, and R.N. Scott, “The application of neural networks to myoelectric signal analysis: A preliminary study,” IEEE Trans. Biomed. Eng., vol.37, no.3, pp.221-230, 1990.
- [7] B. Hudgins, P.A. Parker, and R.N. Scott, “A new strategy for multifunction myoelectric control,” IEEE Trans. Biomed. Eng., vol.40, no.1, pp.82-94, 1993.
- [8] 西川大亮, 兪 文偉, 横井浩史, 嘉数侑昇, “表面筋電位からの動作識別システムにおけるオンライン型学習データ管理機構,” 信学論 (D-II), vol.J84-D-II, no.12, pp.2634-2643, Dec. 2001.
- [9] 辻 敏夫, 重吉宏樹, 福田 修, 金子 真, “EMG 信号に基づく前腕動力義手のバイオミメティック制御,” 日本機械学会論文集 C, vol.66, no.648, pp.2764-2771, 2000.
- [10] 福田 修, 辻 敏夫, 金子 真, “EMG 信号を利用した手動制御型人間支援マニピュレータ,” 日本ロボット学会誌, vol.18, no.3, pp.387-394, 2000.
- [11] O. Fukuda, T. Tsuji, M. Kaneko, and A. Otsuka, “A human-assisting manipulator teleoperated by EMG signals and arm motions,” IEEE Trans. Robot. Autom., vol.19, no.2, pp.210-222, 2003.
- [12] J.U. Chu, I. Moon, and M.S. Mun, “A real-time

- EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand," *IEEE Trans. Biomed. Eng.*, vol.53, no.11, pp.2232-2239, 2006.
- [13] F.H.Y. Chan, Y.S. Yang, F.K. Lam, Y.T. Zhang, and P.A. Parker, "Fuzzy EMG classification for prosthesis control," *IEEE Trans. Rehabil. Eng.*, vol.8, no.3, pp.305-311, 2000.
- [14] A.D.C. Chan and K.B. Englehart, "Continuous myoelectric control for powered prostheses using hidden Markov models," *IEEE Trans. Biomed. Eng.*, vol.52, no.1, pp.121-124, 2005.
- [15] Y. Huang, K.B. Englehart, B. Hudgins, and A.D.C. Chan, "A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses," *IEEE Trans. Biomed. Eng.*, vol.52, no.11, pp.1801-1811, 2005.
- [16] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol.20, pp.273-297, 1995.
- [17] S. Hirose, K. Shimizu, S. Kanai, Y. Kuroda, and T. Noguchi, "POODLE-L: A two-level SVM prediction system for reliably predicting long disordered regions," *Bioinformatics*, vol.23, no.17, pp.2046-2053, 2007.
- [18] M. Pontil and A. Verri, "Support vector machines for 3d object recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol.20, no.6, pp.637-646, 1998.
- [19] H. Lodhi, C. Saunders, J. Shawe-Taylor, N. Cristianini, and C. Watkins, "Text classification using string kernels," *J. Machine Learning Res.*, vol.2, pp.419-444, 2002.
- [20] P. Shenoy, K.J. Miller, B. Crawford, and R.P.N. Rao, "Online electromyographic control of a robotic prosthesis," *IEEE Trans. Biomed. Eng.*, vol.55, no.3, pp.1128-1135, 2008.
- [21] M. Yoshikawa, M. Mikawa, and K. Tanaka, "Real-time hand motion estimation using EMG signals with support vector machines," *Proc. SICE-ICASE Int. Joint Conf.* 2006, pp.593-598, 2006.
- [22] M. Yoshikawa, M. Mikawa, and K. Tanaka, "A myoelectric interface for robotic hand control using support vector machine," *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS2007)*, pp.2723-2728, 2007.
- [23] M. Yoshikawa, M. Mikawa, and K. Tanaka, "Hand pose estimation using EMG signals," *Proc. Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC2007)*, pp.4830-4833, 2007.
- [24] A.O. Perotto (著), 栢森良二 (訳), *筋電図のための解剖ガイド：四肢・体幹*, 西村書店, 1997.
- [25] M. Zecca, S. Micera, M.C. Carrozza, and P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal," *Crit. Rev. in Biomed. Eng.*, vol.30, no.4-6, pp.459-485, 2002.
- [26] C.W. Hsu and C.J. Lin, "A comparison of methods for multi-class support vector machines," *IEEE Trans. Neural Netw.*, vol.13, no.2, pp.415-425, 2002.
- [27] C.C. Chang and C.J. Lin, *LIBSVM: A Library for Support Vector Machines*, 2001, Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- [28] O.C.J. Lippold, J.W.T. Redfearn, and J. Vuco, "The electromyography of fatigue," *Ergonomics*, vol.3, pp.121-131, 1960.
- [29] K.R. Mills, "Power spectral analysis of electromyogram and compound muscle action potential during muscle fatigue and recovery," *J. Physiology*, vol.326, pp.401-409, 1982.
- [30] 福田 修, ト 楠, 辻 敏夫, "生 EMG 信号による電動義手の制御," *計測自動制御学会論文集*, vol.40, no.11, pp.1124-1131, 2004.

(平成 20 年 5 月 16 日受付, 8 月 1 日再受付)



吉川 雅博 (学生会員)

2005 筑波大・図書館情報専門学群卒。現在、同大学院図書館情報メディア研究科博士後期課程在学中。生体信号を用いたヒューマンインタフェースとその福祉応用の研究に従事。計測自動制御学会、IEEE 各学生会員。



三河 正彦

1994 大阪大学大学院機械工学分野修士課程了。同年 NTT アクセス網研究所入所。2003 筑波大学図書館情報学系講師。2006 同大学院図書館情報メディア研究科助教授。博士 (工学)。ロボットビジョンや遠隔作業支援システム等の研究に従事。日本ロボット学会、計測自動制御学会、日本知能情報ファジィ学会、IEEE 各会員。



田中 和世 (正員：フェロー)

1970 横浜国大・工・電気卒。1971 電子技術総合研究所入所、同所音声研究室長、総括主任研究官などを経て、2001 年 4 月 (独) 産業技術総合研究所、2002 年 4 月 図書館情報大学教授、同年 10 月より筑波大学教授。工博。この間、主として音声情報処理の研究に従事。日本音響学会、人工知能学会、IEEE 各会員。