

選択的不感化ニューラルネットによる表面筋電位からの 手首関節角速度推定

堀江 和正^{†a)} 末光 厚夫^{††} 丹野 智博[†] 森田 昌彦[†]

Estimation of Wrist Angular Velocities from Surface Electromyogram
Using a Selective Desensitization Neural Network

Kazumasa HORIE^{†a)}, Atsuo SUEMITSU^{††}, Tomohiro TANNO[†],
and Masahiko MORITA[†]

あらまし 表面筋電位 (sEMG) から手の動作を認識する実用的な手法が提案されているが、手の関節角速度を sEMG 信号から直接推定するのは、特にひねる動作の場合に難しく、精度や使いやすさの点で実用的な方法はまだない。本研究では、優れた関数近似能力を有する選択的不感化ニューラルネット (SDNN) を用い、多チャンネルの sEMG 信号から手首関節の角速度を推定する方法を提案する。これは、各チャンネルの積分 EMG 信号とその過去 300 ms の平均値を SDNN に入力し、各時刻における関節角速度との対応関係を学習させるというものであり、センサの位置調整や特徴量の選択などの事前準備が不要で、計算コストが比較的低く、サンプル取得にかかる時間も短いという特徴がある。実験の結果、本提案手法は既存の推定手法や関数近似器を用いた場合よりも推定精度が高く、手首のピッチ軸、ロール軸周りの角速度を最大値の 10% 以下の誤差で推定可能であった。また、現在の 24 ms 先の関節角速度を同程度の精度で予測できた。これらの結果は、本手法によって sEMG 信号から動作意図に関するより多くの情報を捉えられることを示しており、時間遅れの全くない筋電入力インタフェースなどの開発への応用が期待できる。

キーワード 表面筋電位, 角速度推定, 関数近似, 選択的不感化ニューラルネット

1. ま え が き

表面筋電位 (surface electromyogram: 以下, sEMG) は、筋肉の収縮に対応して発生する皮膚表面の電位変化であり、人間の動作や動作意図に関する情報を含んでいる。また、筋電位は実際の動作の 30~100 ms 前に発生する [1] ため、カメラ画像や角度センサなどを用いた場合に比べて、より早く利用者の運動意図を捉えることができる。

sEMG 信号から動作意図を捉えるこれまでの研究

は、大部分が「動作種類の識別」を目的としている。可能な動作の種類が多い手の動作識別についても、近年では認識精度の高い実用的な手法が提案されている [2]~[4]。しかし、これにより得られるのは現在の動作が事前に定めた動作のどれに該当するのかという情報だけであり、動作の大きさや速さなどを通じて利用者がそれ以上の意図を伝えることはできない (むしろ、誤認識しないよう、なるべく一定の動きをすることが求められる)。また、高精度で識別できる動作の数は 6~8 種類程度であり、動作種類を増やすほど認識精度が下がるため、実用上の用途は数種類の選択肢から選ぶことに限られる。

動作意図ではなく、sEMG 信号から関節の角度や手先の位置を推定する手法も多数提案されている [5]~[9]。これによって動作の種類よりも多くの情報を得ることができ、マニピュレータの位置操作などに用いることが可能である。しかし、これらの手法は基本的に、屈筋と伸筋がつりあって静止しているとき、その筋張

[†] 筑波大学大学院システム情報工学研究科, つくば市 Graduate School of Systems and Information Engineering, University of Tsukuba, 1-1-1 Tenodai, Tsukuba-shi, 305-8573 Japan

^{††} 北陸先端科学技術大学院大学情報科学研究科, 能美市 School of Information Science, Japan Advanced Institute of Science and Technology, 1-1 Asahidai, Nomi-shi, 923-1292 Japan

a) E-mail: horie@bcl.esys.tsukuba.ac.jp
DOI:10.14923/transinfj.2015JDP7081

力の大きさによって関節角度が決まる [10] ことを利用している。関節が動いている最中は屈筋と伸筋のバランスが崩れるため、角度を正確に推定することはできない。実際 Jiang らの実験 [9] では、速い動作の途中でしばしば非常に大きな推定誤差が生じている。また、手をひねる（ロール軸回転）動作の場合、筋張力と回転角の関係が単純ではなく、静止時には筋電位がほとんど発生しないため、正確な推定が困難である。

このほか、sEMG 信号を制御入力、関節を制御対象としてモデル化し、カルマンフィルタ (Kalman Filter, 以下 KF) や拡張 KF を用いてモデルのパラメータを同定することによって、関節の角度と角速度を同時に推定する手法が提案されている [11], [12]。

しかし、これまでこの手法が適用されているのは、肘や肩の関節周りの比較的ゆっくりした（角速度が 30 deg/s 程度の）運動の場合であり、角速度が最大 1000 deg/s 以上にもなる手首について適用した例はない。また、特にロール軸周りの運動は、KF で用いる線形モデルでは十分に記述できない可能性があるし、どのような非線形モデルが適切なのか不明なため、拡張 KF の適用も困難である。

そこで、本研究では、多チャンネルの sEMG 信号と手首の関節角速度の関係を、関数近似器を用いてモデル化し、前者から後者を推定することを考える。これによって、利用者の意図をより多く捉えられるだけでなく、運動中の関節角度の推定精度の向上にも役立つと考えられる。

このとき用いる関数近似器は、次のような性質をもつことが実用上望ましい。

(1) 複雑な入出力関係を表現できる

関節角速度は、sEMG 信号に含まれる筋張力の差や神経筋接合部とセンサの位置関係の変化等の情報を利用して推定するが、これらの関係は一般に非線形かつ複雑である。特に、ロール軸回転に関しては、多数の筋肉が関係するため非常に複雑になると考えられる。もちろん、入出力関係の複雑さは、どのような特徴量を用いるかにも大きく依存する。もし極めて優れた特徴量を見つければ、特徴量ベクトルと角速度の関係をほぼ線形にすることも可能であり、その場合線形近似器で十分であろう。しかしながら、sEMG 信号は個人差やセンサの取り付け位置による影響が大きいいため、そのような特徴量を見つけないことは非常に困難であるし、それが常に有効とは限らない。

(2) 汎化誤差が小さい

使用者の負担を考えると、なるべく少ないサンプルで学習する必要があるため、関数近似器には高い汎化能力が求められる。しかし、放射状基底関数ネットワーク (RBFN) のような局所的関数近似手法の場合、高い汎化能力を得るためには表現能力を落とす必要がある。また、多層パーセプトロン (MLP) や多項式近似のような非局所的手法を用いた場合、表現能力を必要以上に高めると過剰適合が生じて汎化能力が低下しやすい。そのため、既存のどの関数近似器でも、関数の複雑さやサンプル数に応じて表現能力に関わるパラメータを適切に設定する必要があった。このとき、入力空間の領域によって関数の複雑さやサンプルの密度が異なっていると対応が困難である。例えば推定誤差が大きな動きを多くサンプリングした場合、そのような状況が生じる。したがって、パラメータ依存性が少なく、常に一定以上の汎化能力をもつ関数近似器が望まれる。

(3) 冗長入力に対してロバストである

手首の運動には、多くの筋肉が関わるため、角速度を推定するためには多数の EMG センサが必要である。この際、センサの数や位置を最適化した上で毎回そこに正確にセンサを配置するよりも、多めのセンサを大体の位置に配置する方が実用的である。また、最適な特徴量を選択するのは困難であり、動かし方や時間（動き始めと終わりなど）によって有効な特徴量が変わる可能性もあるため、特徴量の数もある程度多めにならざるをえない。しかし、そうすると、幾つかのセンサ入力や特徴量が不要となる場合がある。例えば、前腕をひねる際に軽く手を握ってしまうことがあるが、手を握る力に応じて発生する EMG 信号は、ひねる速さを推定する際には不要であり、ノイズとして働く。このような入力情報の冗長性による悪影響を受けにくいことが望ましい。

(4) 計算コストが低い

推定のための計算量が大きすぎると、実時間推定ができない。また、センサ装着後にサンプルを取得し、その場で速やかに学習できるようにしないと実用的とは言えないため、学習やパラメータサーチに要する時間の短さも重要である。

一般的によく用いられる関数近似器は、これらの性質の幾つかを満たしていない。そこで、本研究では、選択的不感化ニューラルネットワーク (Selective Desensitization Neural Network, 以下 SDNN) [13] を関数近

似器として用いることによって、実用性の高い手首関節角速度の推定手法を提案する。

以下では、まず SDNN の概要と特徴について説明する。次に、提案手法について述べた上で、既存の手法や関数近似器との比較を含めた評価実験を行う。

2. 選択的不感化ニューラルネット

SDNN は、分散表現された複数の情報を統合する手法である「選択的不感化」を導入した階層型ニューラルネットである [13]。SDNN を関数近似に用いる場合、パターンコーディングの後に選択的不感化を行い、それを並列パーセプトロンの入力とするのが一般的な構成である。

本研究で用いる SDNN の構造は **3**. で述べるが、そこで用いられる各要素と SDNN の一般的な特徴について説明する。

2.1 パターンコーディング

関数近似のように入力変数がアナログ値をとる場合、それらを多次元の 2 値パターンに変換することをパターンコーディングと呼ぶ。具体的には、アナログ値の取りうる範囲を q 個に分割し、各区間に対応するコードパターン P_1, \dots, P_q によって量子化したアナログ値を表現する。この際、分割数 q が大きいほど量子化による誤差が減少するが、必要な素子数は多くなる。

ここでは、同数の 1 と -1 からなる n 次元 (n は偶数) の 2 値パターンをコードパターンとして用いる。コードパターンは、近い値を表すものほどパターン間の相関が高く、遠いほど減少して 0 に近づくことが望ましいが、以下の手順はそのようなコードパターンを生成する一つの方法である。

まず、1 と -1 が半分ずつになるパターンをランダムに作成して P_1 とする。 P_1 の成分の中から 1 及び -1 をとるものをそれぞれ r 個ずつランダムに選び、それらの符号を反転して得られるパターンを P_2 とする。同様に、 P_2 の成分のうち $2r$ 個の符号を反転して P_3 とする。以下同様に、 P_{k-1} の $2r$ 個の成分を反転することによって順次 P_k を作成する。

パターンの次元 n 、分割数 q 、反転数 r の値は SDNN の性能に影響を与えるが、特に qr/n の値が汎化性能に影響する [14]。また、 qr/n の値が同じ場合、一般に q と n の値が大きいほど表現能力が向上する。ただし、これらの値が多少違って、それほど大きな性能差が生じるわけではない。本研究では、最初に (q, n, r) の組み合わせを数通り試した後は、全て同一のコードパ

ターンを用いている。

2.2 選択的不感化

選択的不感化は、分散表現された二つのパターンがあるとき、一方のパターンに応じて他方の一部の要素を中立値に変えることによって、両者が表す情報を統合する手法である。

具体的に 2 種類の n 次元の 2 値 (± 1) パターン $S = (s_1, \dots, s_n)$ 及び $C = (c_1, \dots, c_n)$ があり、それぞれ成分のうち 1 と -1 が同数であるとしよう。また、 S と C を構成する要素 (ニューラルネットの素子) 間には、あらかじめランダムに決められた 1 対 1 の対応付けがあるとする。このとき、 S の i 番目の要素の値を

$$s'_i = \frac{1+c_j}{2}s_i \quad (1)$$

に変える。ここで、 c_j は s_i に対応する C の要素の値であり、これが 1 のとき $s'_i = s_i$ であるが、 -1 のときには $s'_i = 0$ となる。この結果、半数が 0 で残りが ± 1 の 3 値パターン (s'_1, \dots, s'_n) が得られる。このパターンのことを「 C によって修飾された S 」といい、 $S(C)$ で表す。同様に、 S によって修飾された C を考えることもできる。

入力変数が μ 個あり、そのコードパターンが X_1, \dots, X_μ である場合、基本的に全ての組合せについて相互に修飾を行う。その結果、二つずつの変数の情報を統合した $\mu(\mu-1)$ 個のパターンが得られる。ただし、どの変数同士の組合せが重要か (あるいは重要でないか) という事前知識があれば、パターンの数を削減することも可能である。

2.3 並列パーセプトロン

選択的不感化の結果得られたパターンは、並列パーセプトロンに入力される。並列パーセプトロンは、 $\{0, 1\}$ の 2 値を出力する単純パーセプトロンを並列に並べ、各出力素子の出力値の合計に応じて最終的な出力を決定する一種の関数近似器である。出力素子、すなわち単純パーセプトロンの数は、関数値を目的の精度で表現するのに必要な個数 (例えば $[0, 1]$ の範囲を 0.01 刻みで表現する場合は 101 個) より大きくした方が表現力が高まる [15]。

学習には誤り訂正学習を用いるが、出力した関数値と正解との誤差から、誤っているとみなす素子を決める方法には幾つかある [15]。ここでは、次のような方法を用いる。

ある入力に対して、 m 個の出力素子のうち l 個が 1

を出力すべきなのに、実際に 1 を出力したのは $k (< l)$ 個だけだったとする。このとき、0 を出力した $m - k$ 個の素子の中で、内部電位が最もしきい値に近いものから順に $l - k$ 個を選び、これらについて誤り訂正学習を行う。 $k > l$ の場合には、1 を出力した素子の中で内部電位がしきい値に近いもの $k - l$ 個について学習を行う。

2.4 SDNN の特徴

SDNN は非常に優れた関数近似能力をもつ [14], [16] が、ここでは特に本研究において重要な特徴について述べる。

a) 関数表現能力

SDNN は、並列パーセプトロンの場合と同様に、理論上の万能性（十分多くの素子があれば、任意の連続関数を任意の精度で表現できる）をもつが、実際にサンプル学習によって非常に複雑な関数を精度良く近似することが可能である。つまり、サンプルの学習誤差が非常に小さい。そのため、特徴量として比較的単純で一般性のあるものを用いても、それらと関節角速度との関係を表現することができる。

b) 汎化誤差

SDNN は、素子数を増やせば増やすほど表現能力が高まるが、過剰適合が生じないので、それによって汎化誤差が増大することはない。そのため、計算コストが許す範囲で多数の素子数を用意することにより、サンプルが少なくてもそれなりの精度で、多ければそれだけ正確に近似することができる。また、パラメータ依存性が小さいため、なだらかな（関数値の変化が少ない）領域と入り組んだ（関数値が複雑に変化する）領域が混在する関数であっても、後者からより多くのサンプルを取得することによって効率的な近似が可能である。

c) 冗長入力に対するロバスト性

SDNN では、選択的不感化の効果によって出力値が変化しない領域において特に強力な汎化が生じる。そのため、出力値に関係ない冗長入力による影響をほとんど受けない。これにより、センサを多めに配置することができ、特徴量を選択する手間も不要である。

d) 計算コスト

SDNN の計算コストは、ほぼ入力次元の 2 乗オーダーである。RBFN のような局所的近似手法を用いた場合（指数オーダー）に比べると、入力次元が大きくなっても計算コストの爆発は生じない。求める近似精度などにもよるが、入力変数が数十個程度であれば、

一般的な PC でも十分高速に計算可能である。また、MLP のように中間層の学習を行わないため、学習の収束もかなり早い。更に、パラメータが少なく、性能のパラメータ依存性も小さいため、細かくパラメータを設定をする必要がない。

3. システムの構成

提案手法に基づいて構成した関節角速度推定システムは、腕から sEMG 信号を計測する「表面筋電位計測部」、信号処理を行い特徴量を抽出する「信号処理部」と、特徴量と関節の角速度の関係を推定する「関数近似部」から成り立っている（図 1）。以下では次章の評価実験で用いた手法を例にとり、各部の詳細について述べる。

3.1 表面筋電位計測部

表面筋電位計測部では手首の動作に関わる筋肉から sEMG 信号をサンプリング周波数 1 kHz で取得する。計測装置として、2 台の追坂電子製 Personal-EMG を、電極（1 チャンネルにつき 2 個、及び全チャンネルに共通の参照用 1 個）には Ambu 製ブルーセンサ M-00-S を使用した。電極は、ひじ周りを取り囲むように 6 カ所、手首の周りに 3 カ所、上腕二頭筋に 1 カ所の計 10 カ所にそれぞれ 1 対を配置した（図 2）。

本システムは、sEMG センサをやや多めに配置する

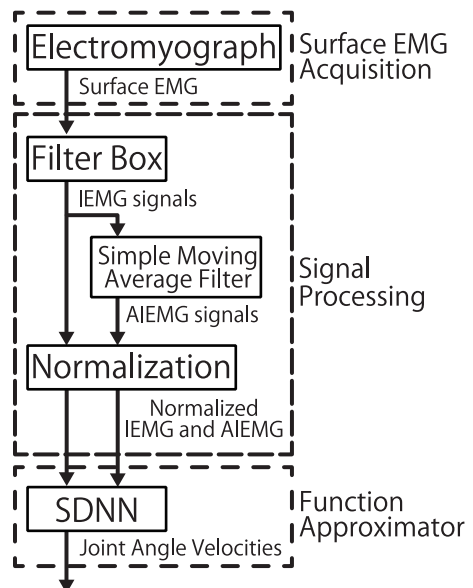


図 1 提案システムの構成

Fig. 1 Structure of the proposed system.

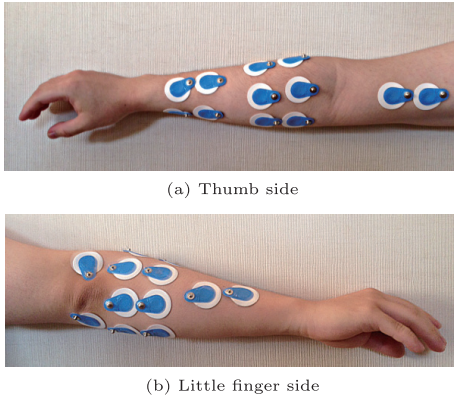


図 2 EMG センサの配置
Fig.2 Arrangement of EMG sensors.

代わりに、センサ配置の最適化という手間のかかる作業を省ける点に一つの特徴がある。そこで、実験の際には、実用場面を想定し、あえて厳密な位置決めをせず、大まかな位置だけ指定して短時間でセンサを取り付けるようにした。

3.2 信号処理部

計測した sEMG 信号を関節の角速度推定に適した特徴量へ変換するのが信号処理部である。本システムでは、個人や動作ごとに最適な特徴量を探索したり、大きな計算コストや遅延を伴う複雑な特徴量を用いたりせず、比較的単純で一般性のある特徴量である積分筋電位 (Integrated EMG: IEMG) 信号及びその過去平均値である平均積分筋電位 (Averaged IEMG: AIEMG) 信号を利用する。

IEMG 信号は、sEMG 信号に対して全波整流平滑化を行ったもので、sEMG 信号の振幅の大きさを表している。筋張力と線形的な相関関係があり [10]、フィルタ回路等で容易に得られることから、先行研究においても用いられている [3], [4]。IEMG 信号は関節角速度を直接反映してはいない (両者の間に必ずしも一定の対応関係はない) が、時間遅れがほとんどなく、リアルタイム性が求められる入力インタフェースに適した信号である。

AIEMG 信号は、過去の一定期間に渡る IEMG 信号の平均値であり、本研究で新たに導入する特徴量である。筋張力と線形的な関係にある IEMG 信号を一定期間積分したものに相当するため、筋収縮速度との相関が高いと考えられる。ただし、AIEMG 信号の変化は IEMG 信号に比べてかなり遅れるため、これだけ

では関節角速度をリアルタイムに推定するのは困難である。そこで本手法では、IEMG と AIEMG の 2 種類の信号を同時に利用することによって、高精度かつ無遅延の角速度推定を図る。

信号処理部で行われる具体的な処理は以下のとおりである。まず、チャンネルごとに取得した sEMG 信号を、ノイズ除去のため 10 Hz ハイパスフィルタと 50 Hz ノッチフィルタに通した後、Personal-EMG に備え付けられたアナログフィルタ (周波数特性 2~15 Hz) によって全波整流平滑化を行う。得られた信号を Interface 製 CSI-320312AD ボード (量子化 12 bit) を用い計算機へ入力し、窓 8 ms の移動平均フィルタを用いて更にノイズの除去を行って IEMG 信号とする。更に、IEMG 信号の過去 300 ms の平均値を求めて AIEMG 信号とする (この 300 ms という時間長は、予備実験により決定した)。なお、チャンネルごとの信号強度のばらつきの影響を抑えるため、各信号は、同チャンネルで観測された信号の最大値で割ることにより、 $[0, 1]$ の範囲に正規化している。

3.3 関数近似部

関数近似部は、特徴量ベクトルと関節の角速度の関係をサンプルデータの学習によってモデル化し、入力された特徴量ベクトルから推定される関節角速度を出力する。このとき、学習の際に与える特徴量と関節角速度の関係を時間的にずらすことにより、現在の特徴量から未来の関節角速度を予測することも可能である。

関数近似器として MLP, RBFN やサポートベクター回帰 (epsilon-SVR, 以下 SVR) など、既存のものを利用することもできるが、本提案手法では図 3 に示す SDNN を用いる。

SDNN の第 1 層には、正規化された 20 の特徴量 (10 チャンネルの IEMG 及び AIEMG 信号) を入力する。各特徴量は、2.1 で述べたパターンコーディングにより、第 2 層で 2 値パターンとして表現される。パターンコーディングのパラメータは、予備実験により $n = 96$, $q = 96$, $r = 1$ とした。

次に IEMG 信号同士、及び IEMG 信号と同チャンネルの AIEMG 信号の組み合わせで相互に選択的不感化を行い、110 個の 3 値パターンに変換する (第 3 層)。一般的な SDNN では、全ての入力変数の組合せについて選択的不感化を実施するが、特徴量が 20 個あると 380 個のパターンが生成されるため、計算量が大きくなりすぎてしまう。また、AIEMG 信号の変化は IEMG 信号に比べて遅いため、これをあまり重視

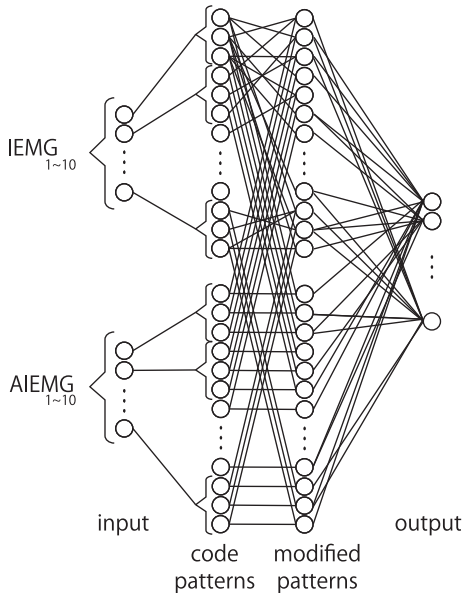


図3 提案手法で用いる SDNN の構成

Fig. 3 Structure of the SDNN used in the proposed method.

すると、速度変化への追従性が悪くなる恐れがあることから、AIEMG 信号同士、及び異なるチャンネルの IEMG 信号と AIEMG 信号の組合せは除外している。

第4層は、140個の出力素子によって、推定した関節角速度（利用者と関節ごとに $[0, 1]$ に正規化したもの）を表現する。具体的には、1を出力した出力素子数を k としたとき、SDNN の出力値は $0.01k - 0.2$ で与えられる。この値を $[\text{deg/s}]$ の単位に変換したものが、推定した関節の角速度である。

4. 実験

開発した関節角速度システムの評価を行うため、sEMG 信号から手首関節のピッチ軸周り（屈曲伸展方向）とロール軸周り（回内回外方向）の角速度を推定する実験を行った。ヨー軸周り（橈屈尺屈方向）は、稼動域が狭く関節角速度の変化幅が小さいため、本研究では対象からはずした。この際、実用場面を想定し、同じ姿勢で同じ動作を繰り返すのではなく、ある程度の姿勢変化があり、かつ動作の大きさや速さが多様となるようにした。

本提案手法は、推定対象が関節角速度であること以外に、特徴量として AIEMG 信号を加えた点、及び関数近似器として SDNN を用いた点に大きな特徴があ



図4 3軸ジャイロセンサ取り付け位置

Fig. 4 Arrangement of a 3-axis gyroscope.

る。そこで、これらの有効性について検証するために、AIEMG 信号を用いない場合や、他の関数近似器を用いた場合との比較実験を行った。また、筋電位が実際の動作よりも早く発生するという利点を生かして、どの程度先の関節角速度まで推定することが可能か確認する実験も行った。

4.1 データの計測

被験者は、20代の男性8名（全て右利き）である。各被験者には、肘を机に付けた状態で、屈曲伸展または回内回外の動作を10秒間、早さや動きのパターンをなるべく変えながら行ってもらった。これを1セットとするが、これを各動作について、肘の角度を約60度から150度の範囲でランダムに変化させながら9回繰り返すことによって、計18セット分のデータを取得した。

角速度の計測は、MicroStone 製三軸ジャイロセンサ MP-G3-2000B を手の甲に取り付けることによって行った（図4）。本製品は計測可能な角速度の幅が $-2000 \sim 2000 \text{ deg/s}$ と広く、手首の速い動作であっても十分に対応できる。

計測した18のデータセット（各動作9）のうち、6セット（各動作3）を学習、残り12セット（各動作6）をテスト用とし、3分割交差検定を行った。各セットは10000点（ $1 \text{ kHz} \times 10 \text{ 秒}$ ）のサンプルを含むが、角速度が0付近のものが大半を占める。そのため、学習セットについてはそのようなサンプルを約 $1/8$ 程度に間引くことによって計算量を削減した。

4.2 提案システムの評価

最初に、提案システムの評価実験を行った。

SDNN の学習は300回を上限とし、学習サンプルの総数を N 、サンプル i に対する出力（正規化された

表 1 推定角速度の 2 乗平均平方根誤差 (deg/s)
Table 1 Root mean square error among the estimated angular speeds.

		(a) ピッチ軸周り (around a pitch axis)								
		Subject								
		A	B	C	D	E	F	G	H	Ave.
Method	SDNN	63.9	60.0	84.8	89.5	76.3	60.4	113.3	89.6	79.7
	KF	91.7	43.1	137.1	142.5	108.7	49.9	127.3	81.4	97.7
	IEMG	79.6	70.5	108.2	106.2	83.4	83.3	141.4	118.7	98.9
	SVR	75.4	73.6	88.8	103.1	94.2	65.5	124.6	91.7	89.6

		(b) ロール軸周り (around a roll axis)								
		Subject								
		A	B	C	D	E	F	G	H	Ave.
Method	SDNN	115.3	105.7	122.4	140.1	124.3	133.6	134.8	100.5	121.9
	KF	243.3	150.9	265.8	247.9	220.5	272.0	285.0	176.7	232.8
	IEMG	143.6	126.8	145.4	192.3	149.5	205.2	185.4	159.5	163.5
	SVR	143.1	121.1	127.9	178.4	135.2	152.1	167.3	104.9	141.3

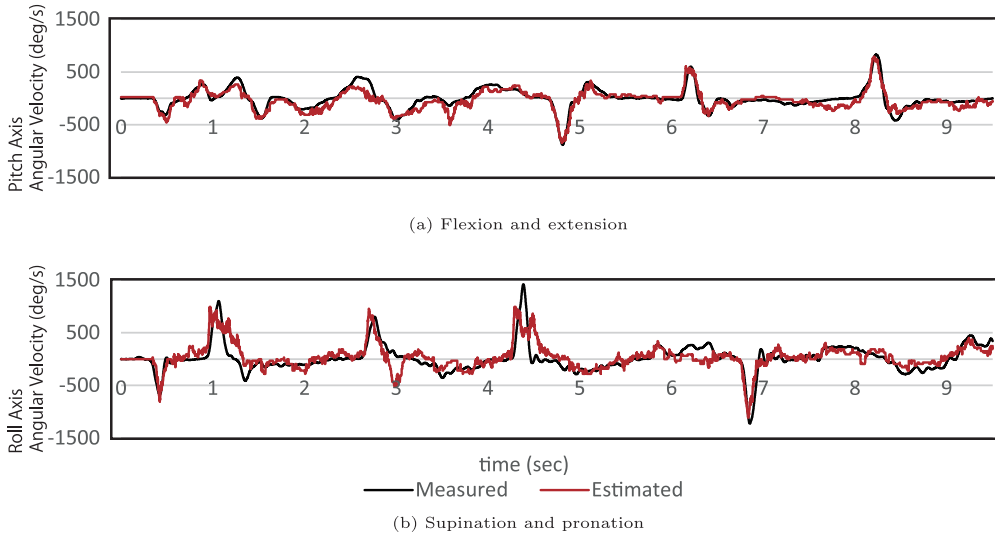


図 5 提案システムによる関節角速度の推定例

Fig. 5 Example of joint angular velocities estimation with the proposed method.

関節角速度) を $O(i)$, 目標値を $T(i)$ としたとき,

$$\frac{\sum_i (O(i) - T(i))^2}{N} < 0.0005 \quad (2)$$

を満たすまで, 学習を繰り返した.

学習後の評価は全てのテスト用サンプルを用いて行った. 具体的には, 各サンプルの sEMG 信号を入力し, システムが推定した角速度と実際の角速度の差から 2 乗平均平方根誤差 (RMSE: Root Mean Square Error) を求め, これを推定精度の評価尺度とした.

各被験者に関する 2 乗平均平方根誤差を表 1 の SDNN 行に示す. ピッチ軸周りの平均誤差は 79.7 deg/s, ロール軸周りは 121.9 deg/s であった. 最大の

関節角速度は, ピッチ軸周りで約 1440 deg/s, ロール軸周りで約 1920 deg/s であったことを考えると, 全体としてまずまずの推定精度であるといえる.

具体的な推定結果の一部を図 5 に示す. これは, 誤差が最も平均値に近かった被験者 E について, 関節角速度の実測値及び推定値の時間変化をプロットしたグラフである. それぞれ, 屈曲伸展動作を行ったときのピッチ軸周り (屈曲方向を + とする), 及び回内回外動作を行ったときのロール軸周り (回内方向を + とする) の角速度を表す.

図からわかるように, 本提案システムは, 速い動きに対する推定精度は比較的良好である. 一方, 実際の角速度が 0 に近いとき, 誤差が大きい場合が見られた.

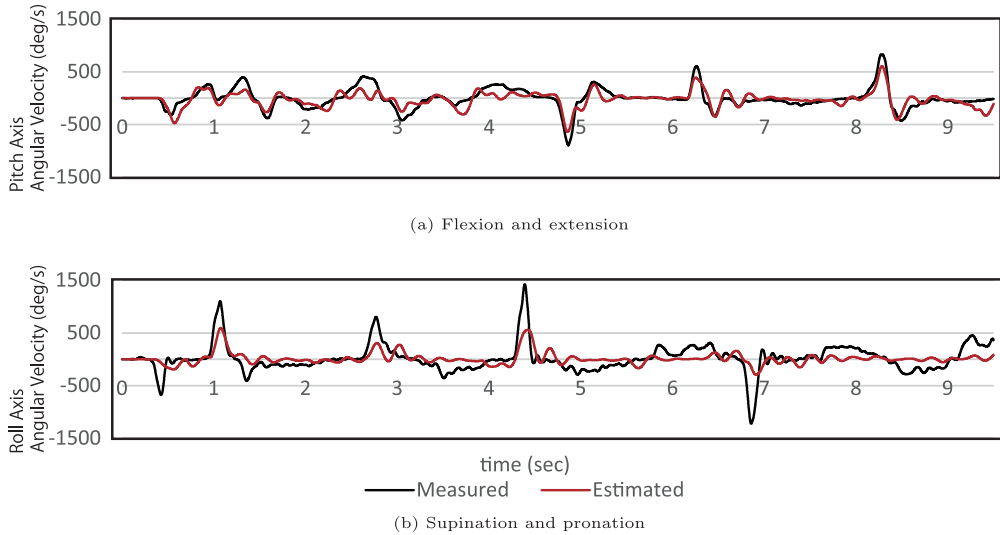


図 6 KF による関節角速度の推定例
 Fig. 6 Example of joint angular velocities estimation with the KF.

特に、屈曲伸展動作時にロール軸周りに角速度がほぼ 0 であるにもかかわらず、ロール軸周りの推定値がかなり大きな値になってしまうことがある。これは、屈曲伸展動作と回内回外動作で、同じ筋肉や近くに位置する筋肉を使用するので、前者を行ったときに、後者をゆっくり行ったときと類似した sEMG 信号が発生するためだと考えられる。

4.3 KF との比較

従来手法である KF による関節角速度推定を本課題に適用した場合の推定精度について調べた。入力には各チャンネルからの IEMG 信号 (10ch)、出力はピッチ軸周りロール軸周りの関節角速度とした。AIEMG 信号は、IEMG 信号との間に 150ms もの遅延があること、急しゆんな動作速度の変化に対応できないことなどから有効な特徴量とはならなかった。

本実験で用いた KF は、時刻 k における内部状態を $\mathbf{x}_k \in \mathbb{R}^d$ 、入力を $\xi_k \in \mathbb{R}^{10}$ 、出力を $\mathbf{z}_k \in \mathbb{R}^2$ としたとき、内部状態の遷移行列 \mathbf{A} 、入力と内部状態の関係行列 \mathbf{B} 、観測行列 \mathbf{C} と二つの雑音 $\mathbf{w}_k \sim N(\mathbf{0}, \Psi)$ 、 $\mathbf{v}_k \sim N(\mathbf{0}, \Gamma)$ を用いて、

$$\begin{aligned} \mathbf{x}_{k+1} &= \mathbf{A}\mathbf{x}_k + \mathbf{B}\xi_k + \mathbf{w}_k \\ \mathbf{z}_k &= \mathbf{C}\mathbf{x}_k + \mathbf{v}_k \end{aligned} \tag{3}$$

と表される。

本実験では、Matlab と System Identification Toolbox を使い、 \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 Ψ 、 Γ と内部状態次元 d を学習

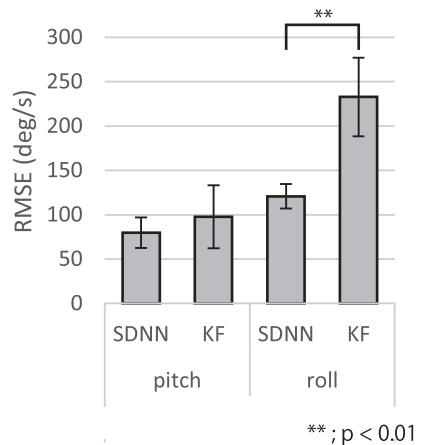


図 7 提案手法と KF の比較
 Fig. 7 Comparison between the proposed method and the KF.

サンプルから推定した。なお、学習サンプルの間引きは行わなかった。

図 6 に、図 5 と同じデータに関する推定結果を示す。(a) のピッチ軸回転については、おおむね正しく推定ができていますが、SDNN の場合と比べると、やや誤差が大きい部分が何箇所も見られる。一方、(b) のロール軸回転については、正しい推定がほとんどできていない。

8 名の被験者についての平均誤差を SDNN と比較したのが図 7 である。ピッチ軸周り、ロール軸周り

も SDNN の方が小さいが、前者の差は小さく、統計的に有意でない ($p > 0.05$: ウィルコクソン符号付順位検定) のに対して、後者は 2 倍以上であり、統計的にも有意である ($p < 0.01$)。

被験者ごとの推定誤差は、表 1 の KF 行に掲載した。ピッチ軸周りについては、被験者によって大きなばらつきがあり、提案手法 (SDNN 行) よりも誤差が 1.5 倍程度大きい者が 4 名いる一方で、誤差が小さい者も 3 名いた。これに対して、ロール軸周りの場合は全員 1.5 倍以上の誤差であった。

このような結果になったのは、KF の性能が、制御対象 (筋電位と手首の動きの関係) を線形システムとしてモデル化できるかどうか大きく依存するためと思われる。ロール軸回転は多数の筋肉を同時複合的に利用して行っていることから、制御対象の非線形性が高い。ピッチ軸回転は、筋肉と動きとの関係が単純であり、近似的に線形システムとして扱えるが、センサの位置が少しずれたり、動かし方が激しかったりすると、線形システムから大きく外れる可能性がある。実際、ピッチ軸周りの誤差が小さかった 3 名は、全員やせ型 (皮下脂肪が少ないので筋肉の真上にセンサを配置しやすい) で、かつ最大の関節角速度が 700 deg/s 程度であった。

この問題は、制御対象を非線形システムとしてモデル化して拡張 KF を用いれば、原理的には解決可能である。しかし、手首の場合、10 以上の筋肉が同調して動くことで複雑な動作を実現している。また、個人差がある上に、センサの取り付け位置の違いの影響も大きいことから、モデル化は相当に困難だと思われる。したがって、拡張 KF を用いる方法は現実的でない。

以上のことから、手首の関節角速度推定に関して、本提案手法の方が明らかに優れていると言える。

4.4 AIEMG 信号の効果

AIEMG 信号を用いる効果を検証するために、AIEMG 信号を利用しない場合の推定精度を求め、利用した場合と比較した。具体的には、AIEMG 信号に関係する第 3 層の素子の出力を全て 0 (中立値) とし、それ以外については全て 4.2 と同じ設定で実験を行った。

推定結果の 2 乗平均平方根誤差を表 1 の IEMG 行に掲載した。また、図 8 は、8 名の被験者に関する誤差の平均値を棒グラフで示したものである。

表 1 SDNN 行 (AIEMG と IEMG 両方とも利用) と比べると、ピッチ軸周り、ロール軸周り共に 8 名全




図 8 AIEMG 特徴量の有無の比較
Fig. 8 Comparison between with and without AIEMG signals.

ての被験者について AIEMG 信号を用いた方が誤差が小さいことがわかる。この差は、統計的にも有意である ($p < 0.01$: ウィルコクソン符号付順位検定)。

一般に特徴量を増やすことは、入力情報を増やす一方で入力空間の次元を増やすため、汎化誤差は減少するとは限らない。また、前節で述べた KF を用いる手法では、AIEMG 信号を追加してもほとんど効果は見られなかった。しかし、提案手法では、AIEMG 信号の追加によって誤差が大幅に減少した。

その理由としてまず考えられるのは、筋張力や関節トルクとほぼ線形関係にある IEMG 信号の積分値である AIEMG 信号は、関節角速度をより直接的に反映している、ということである。しかし、関節の角速度が減少しているときでも AIEMG 信号は必ずしも減少しないことから、角速度との関係はそれほど単純ではない。また、IEMG 信号の過去 300 ms の平均値であり、ゆっくりとした変化しかしないが、図 5 から分かるように速い動きにもほとんど遅れずに推定ができていたので、AIEMG 信号だけから推定がなされているわけでもない。

誤差が減少する別の大きな理由として、AIEMG 信号と IEMG 信号が相補的に機能していることが挙げられる。IEMG 信号は、大きな筋力が発生する動き出しの直後に比べて、速度が一定または減少しているときには比較的小さな値しか出さない。そのため、多

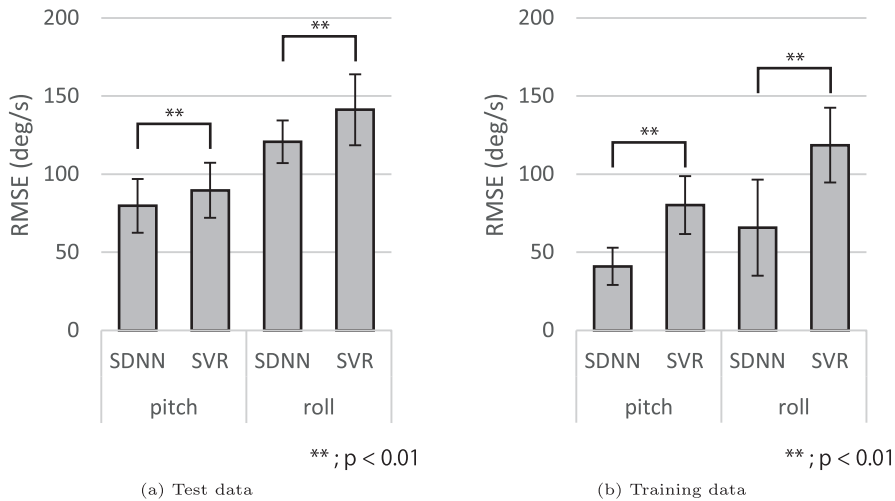


図9 関数近似器間の比較
Fig.9 Comparison between function approximators.

チャンネルの IEMG 信号からなる特徴量ベクトルは角速度が大きく違うにもかかわらず互いに類似する場合があります, これが大きな誤差を生む可能性がある. これに対して, AIEMG 信号は動作初期には小さく, 中期以降に大きな値をとる. そのため, AIEMG 信号を加えた特徴量ベクトルは, 異なる関節角速度に対して十分に分離したものとなり, より正確な推定が可能となったと考えられる.

4.5 SVR との比較

SDNN の有効性を検証するために, 関数近似器として SVR を用いた場合との比較実験を行った. SVR は, 汎化性能が優れている上にカーネルを適切に選ぶことによってある程度高い表現能力をもたせることができ, 計算コストも低いので, 既存の関数近似器の中では本課題に最も適していると考えられる. なお, RBFN や MLP, ロジスティクス回帰など, 他の主な関数近似器についても試してみたが, 少なくとも学習時間や計算コストの点で現実的な条件下では, いずれも誤差が SVR よりも明らかに大きかったため, SVR のみを比較対象とした.

SVR の実装には, LIBSVM ライブラリ [17] を用い, カーネルにはガウス関数を使用した. パラメータは, ϵ を学習計算量と精度のバランスから 0.07 とし, γ と C は被験者ごとに最適値をグリッドサーチにより決定した. $\gamma = \{2^{-3}, 2^{-2}, \dots, 2^7\}$, $C = \{2^{-7}, 2^{-6}, \dots, 2^3\}$ の 121 通りのパラメータについて 6 分割交差確認法を用いて探索を行った.

推定結果の 2 乗平均平方根誤差を表 1 の SVR 行, 図 9(a) に示す. 表 1 の SDNN 行と比較して, SVR を用いたときの 2 乗平均平方根誤差は, ピッチ軸周りで平均 9.9 deg/s, ロール軸周りで平均 19.4 deg/s ほど大きいことがわかる. この差は, 統計的に有意である ($p < 0.01$: ウィルコクサン符号付順位検定). また, 全ての被験者について SDNN のほうが SVR よりも誤差が少ないが, 特にロール軸周りに関して, SDNN の方が被験者間のばらつきが小さく, 性能が安定していると言える.

SDNN と SVR の差がどこに由来するのか調べるために, 学習データを入力した際の 2 乗平均平方根誤差を比較した結果を図 9(b) に示す. SDNN の学習誤差はピッチ軸周りが 40.9 deg/s, ロール軸周りが 58.6 deg/s であり, SVR (ピッチ軸周り 80.2 deg/s, ロール軸周り 118.5 deg/s) の半分程度であった.

このことは, SVR は SDNN に比べて表現能力が不足していることを示している. もちろんガウスカーネルのパラメータを調整してサポートベクターの数を増やせば, 表現能力が高まり学習誤差を減らすことができるが, 汎化誤差はむしろ増加してしまう. SVR の学習誤差が, SDNN の汎化誤差と同程度であることを考えると, 学習データをこれ以上増やしても, 推定精度の向上はあまり期待できない.

これに対して, SDNN の場合は過剰適合が生じないため, 素子数を増やして表現能力を高めても, 汎化誤差は増加しない. そのため, 汎化誤差が大きい (すな




図 10 将来の関節角速度の予測精度

Fig. 10 Prediction accuracy of future angular speeds.

わち関数が複雑になる) 姿勢や速さを中心に学習データを増やせば、推定精度が更に向上すると考えられる。

また、SVR の学習は非常に早いですが、被験者ごとに最適パラメータがかなり異なっており、それを探索するのに SDNN の学習と同程度以上の時間を要する。かといって被験者ごとにパラメータサーチを行わず固定パラメータを用いると、推定精度が低下し、被験者によっては誤差が大きく増加する可能性もある。

4.6 関節角速度の予測

一般に、筋電位の発生は実際の筋収縮に 30~100 ms 程先行するため、皮下脂肪やフィルタリングによる遅延を考慮しても、時間的に少し先の関節角速度を sEMG 信号から予測できる可能性が高い。そこで、どの程度先の関節角速度をどの程度の誤差で予測可能かを調べるために、sEMG 信号と関節角速度の対応を時間的にシフトした上で、4.2 と同じ実験を行った。

結果を図 10 に示す。縦軸は回転方向ごとの 2 乗平均平方根誤差、横軸は時間のシフト量、すなわち何 ms 先の関節角速度を予測させたかを示す。

グラフから分かるように、ピッチ軸周りロール軸周り共に、24 ms までシフトしても、誤差の増加はごくわずかしかなかった。したがって、現在の角速度とほぼ同等の精度で、24 ms 先の関節角速度を予測可能である。

このように、動作よりも先に推定できることは大きな利点であり、ロボットハンドを全く時間遅れなく操作するシステムや、手の動きをパワーアシストするシステムなどへの応用が可能である。また、予測値に移

動平均フィルタをかけることで図 5 に見られる推定値の細かな変動を時間遅れなく平滑化することができ、これにより推定誤差を減らすことも可能と考えられる。

5. む す び

選択的不感化ニューラルネット (SDNN) の優れた関数近似能力を利用し、多チャンネルの表面筋電位 (sEMG) 信号から手首関節の角速度を実時間推定する方法を提案した。

手首のピッチ軸周り及びロール軸周りの運動を対象に評価実験を行ったところ、現実的な量のサンプルデータから、各軸周りの角速度を、最大値の 10% 以下の 2 乗平均平方根誤差で推定可能であった。また、既存の KF を用いた手法に比べ、特にロール軸周りの推定精度が圧倒的に高く、より汎用的な手法であることがわかった。また、特徴量として AIEMG 信号を追加したこと、関数近似器として SDNN を用いたことが、共に推定精度の向上に大きく貢献していることが確認された。更に、現在までの筋電位から、少なくとも 20 ms 程度先の角速度までは、現在とほとんど同じ精度で予測できることが判明した。

本提案手法は、実用的な場面での使いやすさという点でも優れている。例えば、電極の位置ずれに寛容なので、センサの設置が容易である (あらかじめ電極を埋め込んだバンド状の筋電計測装置を利用できる可能性もある)。また、全チャンネルについて同じ単純な特徴量を用いるため、動作の種類や個人に応じた特徴量の選択やパラメータ調整がほとんど不要である。学習用サンプルデータの取得にかかる時間も比較的短い。他の手法に比べて被験者間のばらつきが少なく、推定精度が安定していることも実用上の利点である。

以上の点から、本手法は、sEMG 信号から動作意図に関する新たな情報を抽出することを可能にし、より操作感の良い筋電入力インタフェースの開発などへの応用が期待できると言えよう。

今後の課題としては、まず推定精度の向上が挙げられる。どの程度の精度が必要かは利用目的によるが、学習データの取得方法の改良、特徴量の追加などにより、かなりの改善が可能と思われる。また、誤差のかなりの部分は、実際の角速度がほぼ 0 のときに生じている (例えば、ピッチ軸回転をしているときロール軸周りの推定角速度が 0 より大きくなる) が、これは動作種類の識別と組み合わせることによって抑えることが可能であろう。

また、既存の関節角度の推定手法は、一般に速い動きの最中は誤差が大きく、また手首のロール角度は推定自体が難しかったが、本手法により推定した角速度と組み合わせることによって精度を高められる可能性がある。そのほか、手首以外の多くの筋肉が関わる関節についても、本手法は有効だと考えられるが、これらについて検討することも重要な課題である。

謝辞 本研究の一部は、科研費基盤研究(B)(課題番号 22300079)、若手研究(B)(課題番号 24700593)及び立石科学技術振興財団研究助成(C)(課題番号 2157011)の支援を受けて行われた。

文 献

- [1] 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, バイオメカニズム学会(編), 東京電機大学出版局, 2006.
- [2] O. Fukuda, T. Tsuji, M. Kaneko, and A. Otsuka, "A human-assisting manipulator teleoperated by EMG signals and arm motions," *IEEE Trans. Robotics and Automation*, vol.19, no.2, pp.210–222, April 2003. DOI:10.1109/TRA.2003.808873
- [3] 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," *信学論 (D)*, vol.J92-D, no.1, pp.93–103, Jan. 2009.
- [4] H. Kawata, F. Takana, A. Suemitsu, and M. Morita, "Practical surface EMG pattern classification by using a selective desensitization neural network," *Neural Information Processing (Part II), Lecture Notes in Computer Science*, vol.6444, pp.42–49, 2010. DOI:10.1007/978-3-642-17534-3_6
- [5] Y. Koike and M. Kawato, "Estimation of arm posture in 3D-space from surface EMG signals using a neural network model," *IEICE Trans. Inf. & Syst.*, vol.E77-D, no.4, pp.368–375, April 1994.
- [6] 川瀬利弘, 小池康晴, 神作憲司, "筋骨格モデルを使用した表面筋電位による手先位置推定," *信学技報*, MBE2012-49, Nov. 2012.
- [7] 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," *信学技報*, vol.106, no.611, pp.7–12, March 2007.
- [8] 荒木 望, 帆足勇希, 小西康夫, 満洲邦彦, 石垣博行, "ベイズアンフィルタを用いた表面筋電信号からの動作指識別手法," *電学論 (C)*, vol.131, no.4, pp.736–741, April 2011.
- [9] N. Jiang, J.L.G. Vest-Nielsen, S. Muceli, and D. Farina, "EMG-based simultaneous and proportional estimation of wrist/hand kinematics in uni-lateral trans-radial amputees," *J. NeuroEngineering and Rehabilitation*, vol.9, no.42, June 2012. DOI:10.1186/1743-0003-9-42
- [10] O.C.J. Lippold, "The relation between integrated action potentials in a human muscle and its isometric tension," *J. Physiology*, vol.117, pp.492–499, 1952.
- [11] P.K. Artemiadis and K.J. Kyriakopoulos, "EMG-based control of a robot arm using low-dimensional embeddings," *IEEE Trans. Robotics*, vol.26, no.2, pp.393–398, 2010. DOI:10.1109/TRO.2009.2039378
- [12] Q.C. Ding, A.B. Xiong, X.G. Zhao, and J.D. Han, "A novel EMG-driven state space model for the estimation of continuous joint movements," *IEEE International Conference on Systems, Man and Cybernetics - SMC*, pp.2891–2897, 2011. DOI:10.1109/ICSMC.2011.6084104
- [13] 森田昌彦, 村田和彦, 諸上茂光, 末光厚夫, "選択的不感化法を適用した層状ニューラルネットの情報統合能力," *信学論 (D-II)*, vol.J87-D-II, no.12, pp.2242–2252, Dec. 2004.
- [14] 野中和明, 田中文英, 森田昌彦, "階層型ニューラルネットの2変数関数近似能力の比較," *信学論 (D)*, vol.J94-D, no.12, pp.2114–2125, Dec. 2011.
- [15] P. Auer, H. Burgsteiner, and W. Maass, "A learning rule for very simple universal approximators consisting of a single layer of perceptrons," *Neural Netw.*, vol.21, no.5, pp.786–795, 2008.
- [16] 新保智之, 山根 健, 田中文英, 森田昌彦, "選択的不感化ニューラルネットを用いた強化学習の価値関数近似," *信学論 (D)*, vol.J93-D, no.6, pp.837–847, June 2010.
- [17] 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>
(平成 27 年 8 月 7 日受付, 28 年 1 月 7 日再受付,
3 月 4 日早期公開)

堀江 和正 (学生員)



平 24 筑波大学・工学システム学類卒。平 26 筑波大学大学院・システム情報工学科博士前期課程終了。平 27 現在筑波大学大学院システム情報工学科博士後期課程在学中。筋電位による手の動作推定に関する研究に従事。

末光 厚夫 (正員)



平 10 筑波大学・工学システム学類卒。平 15 同大学院博士課程修了。同年産業技術総合研究所客員研究員, 平 18 鳥根大教務職員を経て, 平 20 より北陸先端科学技術大学院大学助教。生体情報処理, 特に筋電位と音声に関する研究に従事。



丹野 智博

平 25 筑波大学・工学システム学類卒. 平 27 筑波大学大学院・システム情報工学科博士前期課程終了. 平 27 現在筑波大学グローバル教育院エンパワーメント情報学プログラム在学中. 神経回路網による情報処理の研究に従事.



森田 昌彦 (正員)

昭 61 東大・工・計数卒. 平 3 同大大学院博士課程修了. 日本学術振興会特別研究員, 東京大学工学部助手を経て, 平 4 筑波大学電子・情報工学系講師. 同大機能工学系助教授などを経て, 平 19 より同大大学院システム情報工学研究科教授. 脳の情報処理機構及び神経回路網による情報処理の研究に従事. 平 5 日本神経回路学会研究賞, 平 6 同学会論文賞, 平 11 日本心理学会研究奨励賞受賞.