

別 刷

計測自動制御学会 論文集

年 第 卷 第 号

(P. ~P.)



社団 法人 計測自動制御学会

エントロピーを用いた誤差逆伝搬型ニューラルネットによる EMGからの前腕動作の識別

辻 敏夫*・市 延 弘 行*・伊 藤 宏 司**・長 町 三 生*

Discrimination of Forearm Motions from EMG Signals
by Error Back Propagation Typed Neural Network Using Entropy

Toshio TSUJI*, Hiroyuki ICHINOBE*, Koji ITO** and Mitsuo NAGAMACHI*

The present paper proposes a method to estimate the motion intended by a subject from his EMG signals using error back propagation typed neural networks. Estimation of the motion from the EMG signals is useful for means of human interface in such fields as control of multi-functional powered prosthesis, teleoperation of robot manipulators, virtual reality.

The neural network used in the method can learn a mapping from the EMG patterns measured from four pairs of electrodes to six motions of forearm and hand intended by the subject. The experimental results for several subjects including an amputee show the following: 1) the method can discriminate six motions with the accuracy about 90 percent for several electrode locations, 2) ill-discrimination can be decreased by suspending discrimination using entropy of network output, 3) the neural network can adapt to some dynamic variations of the EMG patterns using on-line learning, and 4) utilizing frequency characteristics as well as amplitude characteristics of the EMG signals reduces the number of iterations required for learning convergence.

Key Words: neural networks, EMG signal, motion discrimination, entropy, on-line learning

1. まえがき

人間がある動作を行うとき、上位中枢からの運動指令により必要な筋が収縮し、目的の動作が実現する。したがって運動中に発生するEMG(表面筋電位)は、どのような動作を、どのくらいの力で行うかという運動意思に関する情報を反映していることになる。このEMGパターンの特徴から人間の意図した動作を推定することができれば、EMGは動力義手の制御信号源やロボットのテレオペレーション、仮想現実感などの分野におけるヒューマンインターフェースの手段として利用できる可能性がある。

これまでに、このようなEMG信号を用いた動作推定法がいくつか提案されている^{1)~6)}。これらの動作推定法の多くは、EMG信号を線形モデル(たとえば、ARモ

ル^{1)~3),5)}や判別関数法^{4),6)}など)に当てはめて動作識別を行うという線形推定法である。しかも、電極装着時に同定した動作モデルをもとに動作識別を行っているため、発汗や疲労、環境変化に伴うEMG特性の時間的な変動に適応できない。

そこで本稿では、非線形写像を学習的に獲得できるニューラルネットを用いて動作推定を行うことを考える。いままでにも、ニューラルネットを用いた動作識別法は、いくつか提案されている^{7)~9)}。たとえば、Kellyら⁷⁾はホップフィールド型ニューラルネットと誤差逆伝搬型ニューラルネットを組み合せた方法を提案した。彼らは、切断者の上腕部に取り付けた1対の電極から、肘の屈曲、伸展、手首の回内、回外の4動作を学習した結果、約2700回で学習が収束したと報告している。この方法は誤差逆伝搬法を用いているため、線形分離可能でないEMGパターンに対しても正しく識別できるが、学習に極端に時間がかかるため、実際にヒューマンインターフェースの手段として利用することは難しい。また、識別用データ(識別対象とするクラスの一つに属するが、ニューラルネットの学習用データの集合には含まれていないサンプル)

* 広島大学工学部第2類 東広島市鏡山1-4-1

** 豊橋技術科学大学 豊橋市天伯町雲雀ヶ丘1-1

* Faculty of Engineering, Hiroshima University,
Higashi-Hiroshima

** Toyohashi University of Technology, Toyohashi
(Received January 25, 1993)
(Revised April 5, 1993)

に対して、どの程度の識別能力が実現できるかという点が最も重要であるにもかかわらず、この点については触れていない。一方、平岩ら⁸⁾は、誤差逆伝搬型ニューラルネットを用いて EMG 特性の周波数情報を利用した動作推定法を提案している。彼らは被験者(健常者)の手首に電極を取り付け、EMG から指の 5 種類の曲げ動作、トルク、関節角度を認識できることを示した。特に動作識別に関しては、識別用データに対して 1 対の電極で 67%，2 対の電極で 86% の識別率を実現している(学習回数 1000 回)。また、小池ら⁹⁾は、4 層のニューラルネットを用いて、時系列 EMG と腕の位置から人腕のフォワードダイナミクスモデルを構築している。

これらに対して本稿では、前腕部に装着した 4 対の電極から採取した EMG を用いて、誤差逆伝搬型ニューラルネットによる動作識別を試みる。そして、誤差逆伝搬型ニューラルネットの識別用データに対する識別能力、ニューラルネットの出力に対して定義したエントロピーによる誤識別の回避法、EMG 特性の時間的な変動に適応するためのオンライン学習法などについて検討し、前腕と手の六つの動作を良い精度で識別できることを明らかにする。以下、2 章では、本稿で提案する動作識別法について説明し、3 章でその動作識別能力を実験的に検討する。4 章では、EMG の振幅情報を加えて周波数情報を利用することにより学習回数が軽減できることを示す。

2. 誤差逆伝搬型ニューラルネットによる動作識別法

2.1 動作識別法の構成

Fig. 1 に本論文で提案する動作識別法の概要を示す。被験者の前腕部に取り付けた L 対の表面電極から測定した EMG を、整流平滑部で全波整流し、カットオフ周波数 1 Hz の 1 次バタースフィルタによって平滑化する。ここで、筋力レベルによるパターン変動の影響を少なくするために、各整流平滑 EMG のチャンネル和が 1 になるよう正規化を行う¹⁰⁾。そしてこの正規化整流平滑 EMG をサンプリングした特徴ベクトル $X = [X_1, X_2, \dots, X_L]^T$ をニューラルネット部への入力とする。

ニューラルネット部は、3 層のフィードフォワード型ネットワークである。入力ユニットは電極数に対応して L 個、出力ユニット(動作ユニット)は動作数に対応して M 個で、中間層は K ユニットとする。ここで、各ユニットの入出力 u_i, o_i をつぎのように定義する。

$$u_i = \begin{cases} X_i & (\text{入力ユニット}) \\ \sum_j W_{ij} o_j & (\text{中間, 出力ユニット}) \end{cases} \quad (1)$$

$$o_i = f_i(u_i) \quad (2)$$

各ユニットは、一つ前の層のユニットの活性値 o_j を重み係数 W_{ij} をとおして受け取り、出力関数 f_i に従って活性値を出力する。ただし、入力ユニットに関しては、整流平滑部からの出力 X_i をそのままユニットへの入力とする。各ユニットの出力関数は、入力ユニットのみ恒等関数とし、中間ユニットおよび出力ユニットではシグモイド関数を用いる。

$$f_i(u_i) = \begin{cases} u_i & (\text{入力ユニット}) \\ \frac{1}{1+e^{-u_i}} & (\text{中間, 出力ユニット}) \end{cases} \quad (3)$$

これにより、動作ユニットの出力値は [0, 1] の範囲の実数値となる。

2.2 ニューラルネットの学習法

いま、ある正規化整流平滑 EMG パターン $X^p = [X_1^p, X_2^p, \dots, X_L^p]^T$ をニューラルネット部へ入力したとき、出力ベクトル $O^p = [O_1^p, O_2^p, \dots, O_M^p]^T$ が得られたとする。このとき、エントロピー H^p を

$$H^p = - \sum_{k=1}^M p(k|X^p) \log p(k|X^p) \quad (4)$$

$$p(k|X^p) = \frac{O_k^p}{\sum_{j=1}^M O_j^p} \quad (5)$$

のように定義する。このエントロピー H^p は、ある一つの動作に対応する出力値がほかに比べて相対的に大きくなるにつれて 0 に近づく性質をもち、ネットワーク出力の明確さを表現している。そこで、本稿ではニューラルネット部の学習収束判定および動作識別判定は、このエントロピー H^p を用いて行うこととする。

ニューラルネットの学習法、動作識別法は以下のとおりである。

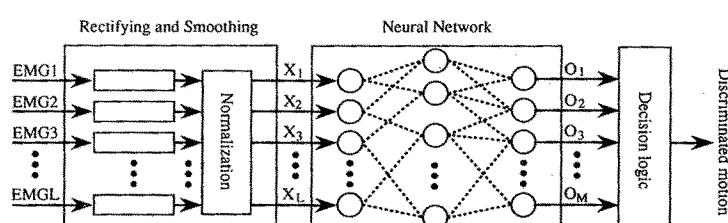


Fig. 1 Motion discrimination method using error back propagation typed neural network

【オフライン学習】

被験者に対象とする M 種類の動作を行わせ、各動作ごとに定常な正規化整流平滑 EMG を 10 個測定する。そして、この $M \times 10$ 個の学習用データ(ニューラルネットへの入力である EMG パターンとそれに対する教師信号の対)を用いて、誤差逆伝搬法によりニューラルネットの学習を行う。ここでは、逐次修正アルゴリズムを採用し、また学習過程での振動を防ぐため慣性項を用いることとする¹⁰⁾。

ニューラルネットの出力 O^p に対する教師信号を $T^p = [T_1^p, T_2^p, \dots, T_M^p]^T$ 、誤差関数 E を

$$\begin{aligned} E &= \frac{1}{2} \sum_{p=1}^{M \times 10} E^p \\ &= \frac{1}{2} \sum_{p=1}^{M \times 10} \sum_{j=1}^M (T_j^p - O_j^p)^2 \end{aligned} \quad (6)$$

とすると、学習用データ α に対する $n+1$ 回目の重み係数の修正量 $\Delta W_{ji}^p(n+1)$ は

$$\Delta W_{ji}^p(n+1) = \eta \delta_j^p o_j^p + m \Delta W_{ji}^p(n) \quad (7)$$

$$\delta_j^p = -\frac{\partial E^p}{\partial net_j^p} \quad (8)$$

$$net_j^p = \sum_k W_{jk} o_k^p \quad (9)$$

で与えられる。 η は学習率、 m は慣性定数である。また、学習を加速するため正解動作に対応するユニットには 1.1、そのほかの動作ユニットには -0.1 の教師信号 T^p を与える。そして全ての学習用データについて(4)式のエントロピー H^p が収束判定閾値 θ_e より小さく、かつ、正解動作に対応する動作ユニットの出力値が最も大きいとき、学習収束と判定する。

【動作識別】

オフライン学習終了後、被験者がある動作を行ったときの EMG をシステムに入力する(識別用データ)。そして、得られる M 個の動作ユニットからの出力値 O_i^p を用いて、この EMG パターンに対するエントロピー H^p を計算する。このとき、エントロピー H^p が動作識別閾値 θ_d より小さければ、最大出力ユニットに対応する動作が識別動作となる。また、エントロピー H^p が動作識別閾値 θ_d より大きいときは識別保留とする。識別保留を導入することにより、曖昧な識別を回避でき、また被験者が対象としている M 種類以外の動作を行った場合にも誤識別を防ぐことが可能となる。

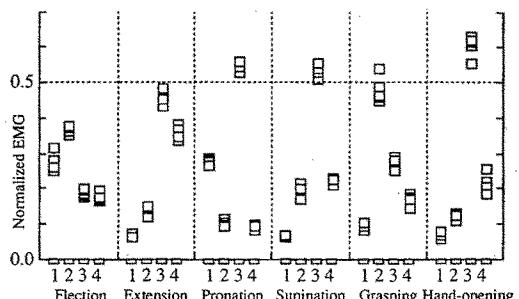
【オンライン学習】

長時間にわたって動作を行っていると、被験者の疲労や発汗、室内環境の変化などにより、EMG パターンに変動が生じる場合がある。

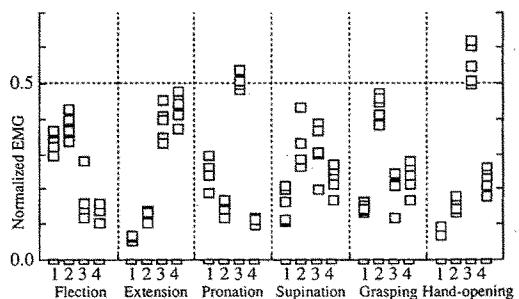
たとえば、Fig. 2 は切断者(左手首より約 6 cm の部位で前腕部を切断)の残存前腕部に、乾式表面電極((株)今

仙技術研究所製)を 4 個 ($L=4$) 取り付けた場合の正規化整流平滑 EMG パターンの時間変化である。横軸は六つの対象動作 ($M=6$)、縦軸は正規化整流平滑 EMG で、いずれも各動作 5 回のパターンを重ねてプロットしている。Fig. 2(a) はオフライン学習時(電極装着直後)の EMG パターンで、(b) は 20 分間動作を行い続けた後のパターンである。背屈、回外をはじめ各動作で、パターンが大きく変化しているのがわかる。また、被験者に動作識別結果をフィードバックしないと、EMG パターンが不安定となり識別率が低下することも報告されている⁹⁾。

したがって、長時間の動作識別を可能にするためには、EMG パターンの時間変化に応じてニューラルネット部の重み係数 W_{ij} を修正する必要がある。しかし、動作識別中は、被験者の意図した動作を知ることができないため、正しい教師信号を与えることはできない。そこで本稿では、時間とともに EMG パターンが徐々に変化していく場合を想定し、つぎつぎと与えられる識別用 EMG パターンのうち、ニューラルネットが明確な識別結果を与えた動作を被験者が意図した真の動作とみなして、動作識別中にニューラルネット部の重み係数の修正を行うこととする。



(a) just after attaching electrodes (during off-line learning)



(b) 20 minutes later (at the end of on-line learning)

Fig. 2 EMG patterns of an amputee measured from four pairs of electrodes

ここでは、この識別結果の明確さを測る尺度として(4)式のエントロピー H^p を使用し、識別用 EMG パターンに対するネットワーク出力のエントロピー H^p がオンライン学習閾値 θ_e より小さいとき、この EMG パターンを学習用データの集合($M \times 10$ パターン)に加える。このとき、対応する教師信号 T^p としてはオフライン学習の場合と同様に、明確に識別された動作に 1.1 を、ほかの動作に -0.1 を与える。そして、その動作に対する最も古い学習用データを取り除き、ニューラルネットを再学習する。再学習の方法は、オフライン学習と同じである。このとき、重み係数の急激な変化を避けるため、再学習が 5 回で収束しない場合は、ネットワークの重み係数および学習用データの更新は行わないことにする。

以上、本稿で提案する動作識別法について説明した。この方法は誤差逆伝搬型ニューラルネットにより、動作と EMG パターンとの間の非線形写像を学習的に獲得することができ、またオンライン学習によって EMG パターンの時間的な変動に適応することが可能である。次章では本手法の有効性を実験的に検討する。

3. 学習パラメータと動作識別能力

3.1 学習パラメータが識別能力に与える影響

本稿で提案する動作識別法は、いくつかの学習パラメータを含んでいる。そこで、これらのパラメータが識別能力にどのように影響を与えるかを実験的に検討した。

実験条件は以下のとおりである。

- 対象動作：手首の掌屈、背屈、回内、回外、手の握り、開きの 6 動作とする($M=6$)。
- 被験者：切断者(左手首より約 6 cm の部位で前腕部を切断、切断後約 6 カ月の時点で実験を実施)，健常者 A, B の計 3 名とする。なお、切断者・健常者 A は右利き、健常者 B は左利きである。
- 測定部位：健常者 A の右腕、および切断者・健常者 B の左腕の肘関節から約 7 cm の前腕部に、乾式表面電極を 4 個($L=4$)取り付けた。電極配置は、90°ずつ離した場合(Table 1: 実験番号 1, 3, 5 参照)、尺側(Table 1: 実験番号 2)、橈側(Table 1: 実験番号 4)に偏らせた場合の 3 種類とした。そして、各チャンネルの EMG をサンプリング周波数 1 kHz で A/D 変換し、データファイルとして計算機の固定ディスクに記憶した。
- オフライン学習用データ：被験者に識別対象の各動作を 1 回ずつ行わせ、定常な EMG を採取した。切断者の場合、動作は残存感覚に基づいて行われた。したがって、実際には動作は発現しないが、対応する筋は収縮するので、このときの EMG を採取した。なお、切断者

には実験前に各動作の EMG を見せたり、両手で同じ動作を行わせたりして、十分に各動作を練習させている。EMG のデータ採取時間はいずれも各動作 2 秒である。そしてこの 2 秒間の EMG を整流平滑部で処理した後、等間隔に 10 個の正規化整流平滑 EMG パターンを抽出した。この 6 動作 × 10 個のデータをオフライン学習に用いた。

- 動作識別用データ：オフライン学習用データとは別に、各動作 100 試行の正規化整流平滑 EMG を採取し、動作識別に用いた。

このようにして採取したデータを用いて、学習収束判定閾値 θ_e 、動作識別閾値 θ_d 、中間ユニット数 K の三つのパラメータが動作識別能力に与える影響を調べた。なお、学習率 η 、慣性定数 m については、学習過程で誤差が振動しないように注意し、 $\eta=1.0, m=0.4$ に統一した。また、重み係数 W_{ij} の初期値は $|W_{ij}| < 2/3$ の一様乱数とした。

Fig. 3 は学習収束判定閾値 θ_e を 0.1 から 0.6 まで変化させたときの切断者のデータに対する識別結果で、(a) は識別保留を除いた識別率(太い実線：以下、識別率と呼ぶ)、識別保留を含めた識別率(破線：以下、実識別率と呼ぶ)、および収束に要した学習回数(点線)を、(b) は識別保留率(一点鎖線)、誤識別率(細い実線)を表す。いずれも 10 種類の重み係数の初期値に対する平均値と標準偏差で、各重み係数の初期値に対して 600 回の識別

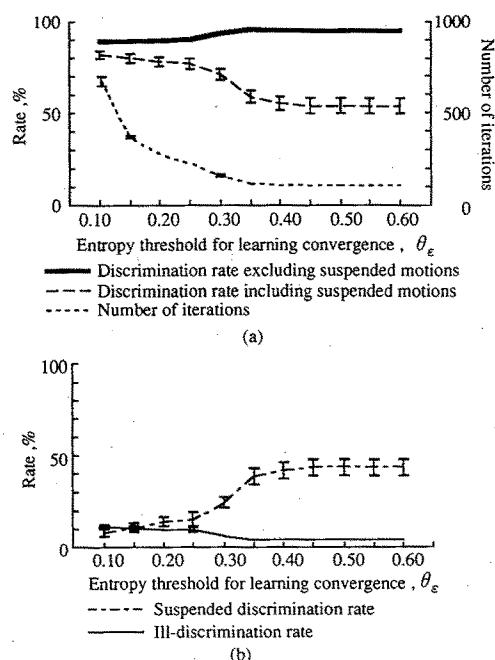


Fig. 3 Effects of entropy threshold for learning convergence, θ_e , on discrimination ability of the network

を行っている。なお、ほかの学習パラメータは動作識別閾値 $\theta_d=0.25$ 、中間ユニット数 $K=10$ とした。

図から学習収束判定閾値 θ_e が大きくなるにつれて収束に要する学習回数が減少すること、 $\theta_e=0.3$ の付近で識別保留率が増加しそのため実識別率が低下することがわかる。ただし、 θ_e を大きくしても誤識別率は増加せず、識別率はむしろよくなっている。このことは学習が不十分な場合でも誤識別が増加しないことを表わしており、エントロピーを用いた識別保留の判定がうまく働いていることを意味している。

つぎに Fig. 4 は動作識別閾値 θ_d を 0.05 から 0.6 まで変化させたときの切断者のデータに対する識別結果で、Fig. 3 と同様に 10 種類の重み係数の初期値に対する平均値と標準偏差である。またほかの学習パラメータは学習収束判定閾値 $\theta_e=0.20$ 、中間ユニット数 $K=10$ としている。動作識別閾値 θ_d を大きくすると識別保留率(一点鎖線)は減少し、 $\theta_d=0.4$ 付近で識別率(太い実線)は実識別率(破線)と等しくなる。このことは最も大きな出力を示した動作をそのまま識別動作とすることを意味しており、それだけ誤動作が増加することになる。

一方、Fig. 5 はニューラルネット部の中間ユニット数

K を 4 から 25 まで変化させたときの切断者のデータに対する識別結果で、ほかの学習パラメータは学習収束判定閾値 $\theta_e=0.20$ 、動作識別閾値 $\theta_d=0.25$ としている。本実験の場合、中間ユニット数を変化させても識別能力にはあまり変化は見られなかった。ただし、ユニット数をかなり少なくすると学習が収束しない場合があった。なお、中間層の数を増加させた場合も、収束に要する学習回数が増えるだけで、識別能力の大きな改善は見られなかった。

以上の実験結果に基づき、学習パラメータを学習収束判定閾値 $\theta_e=0.20$ 、動作識別閾値 $\theta_d=0.25$ 、中間ユニット数 $K=10$ に設定し、動作識別を行った結果を Table 1 に示す。各被験者、各電極配置に対していずれも約 90% の高い識別率が得られており、本手法により前腕・手の六つの動作をうまく識別できていることがわかる。ただし、実験番号 3, 4, 5 で識別保留率がかなり高くなり、その結果、実識別率が 70~80% まで低下している。今後、より効果的な動作識別閾値の設定法を検討する必要があろう。

3.2 動的的なパターン変動を伴うEMGの識別

本稿で提案したオンライン学習の有効性を調べるために、時間的に変動する EMG パターンに対して動作識別を試みた。

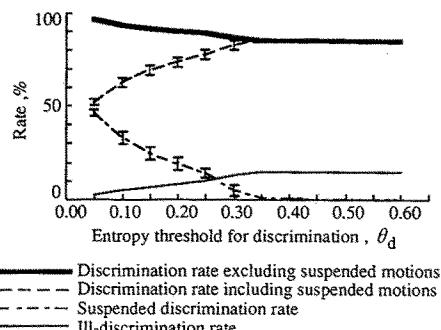


Fig. 4 Effects of entropy threshold for discrimination, θ_d , on discrimination ability of the network

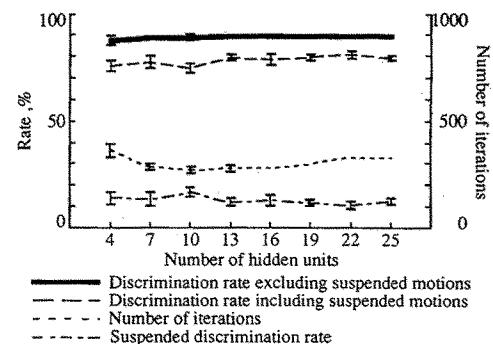


Fig. 5 Effects of number of hidden units, K , on discrimination ability of the network

Table 1 Results of motion discrimination experiments for three subjects

Experiments	No. 1	No. 2	No. 3	No. 4	No. 5
Subjects	Normal A	Normal A	Normal B	Normal B	Amputee
Electrode locations					
Number of iterations	159.0 ± 3.31	122.8 ± 3.50	90.7 ± 2.85	321.5 ± 10.44	264.5 ± 4.03
Discrimination rate excluding suspended motions(%)	99.86 ± 0.34	99.98 ± 0.05	98.65 ± 0.53	98.60 ± 0.39	88.89 ± 1.26
Discrimination rate including suspended motions(%)	93.27 ± 1.01	94.23 ± 1.26	69.17 ± 2.73	77.37 ± 1.88	77.62 ± 2.70
Suspended discrimination rate (%)	6.60 ± 1.12	5.75 ± 1.28	29.88 ± 2.90	21.53 ± 1.99	12.67 ± 3.24

Average value and standard deviation for 10 kinds of initial values of the synaptic weights

Fig. 6 はオンライン学習閾値 θ_o を変化させたときの実識別率の時間変化で、Fig. 2 に示した EMG パターンに対する識別結果である。被験者は前節の実験と同じ切断者(切断後約 2 年の時点で実験を実施)で、電極配置、対象動作、学習パラメータなどの実験条件はすべて前節の実験(Table 1 参照)に統一した。そして約 20 分間、一定の速さで動作識別を行った(動作回数 222 回)。なお、動作識別中、被験者には識別結果を提示していない。

Fig. 6 から、 $\theta_o=0$ すなわちオンライン学習を行わない場合は時間とともに実識別率が低下するが、オンライン学習を導入することにより実識別率が大きく改善されていることがわかる。EMG パターンの動的な変化にニューラルネットが適応し、高い動作識別能力が維持されているのである。また、オンライン学習閾値 θ_o を大きくしていくと、再学習の実行回数が増加するため実識別率はある程度向上するが、 $\theta_o=0.1$ 以上に設定しても実識別率の改善は見られなかった。

一方、Fig. 7 は 4 名の被験者による 7 種類の実験結果である。被験者は切断者(Fig. 7 : 実験番号 1, 2, 3 (左

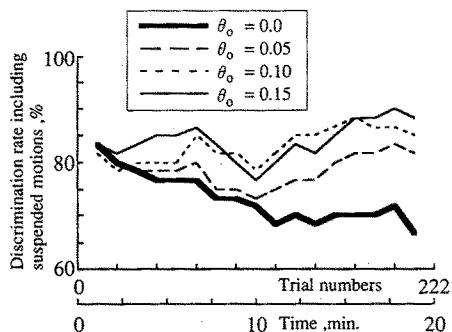


Fig. 6 Effect of entropy threshold for on-line learning, θ_o , on discrimination ability of the network for dynamic variation of EMG patterns

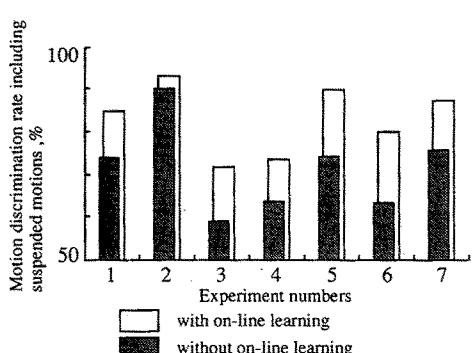


Fig. 7 Improvements of motion discrimination rates by on-line adaptive learning

腕), 健常者 C (実験番号 4 (右腕)), 健常者 D (実験番号 5 (右腕)), 健常者 E (実験番号 6 (右腕), 7 (左腕)) で、4 対の電極を肘関節から約 7 cm の前腕部にそれぞれ 90° ずつ離して取り付けた。被験者は全て右利きである。

実験番号 1 は動作識別結果を被験者に提示しなかった場合で Fig. 6 の結果に対応する。これに対して実験番号 2 は識別結果を被験者に提示した場合である。実験番号 1, 2 がいづれもオンライン学習直後の識別結果であるのに対して、実験番号 3 はオンライン学習終了後、約 90 分間安静にした後に採取したデータで、動作を行なうたびに被験者に識別結果を知らせていている。また、実験番号 4 ~ 7 では実験時間約 1 時間のうち前半 30 分は識別結果を被験者に提示し、後半 30 分は提示していない。なお、動作回数(実験時間)は、それぞれ実験番号 1 が 222 回(20 分)、実験番号 2, 3 が 192 回(20 分)、実験番号 4 が 930 回(1 時間)、実験番号 5 が 1159 回(1 時間)、実験番号 6 が 960 回(1 時間)、実験番号 7 が 600 回(1 時間)である。

Fig. 7 はオンライン学習閾値を $\theta_o=0.1$ とした場合の実識別率(白)で、いずれの実験条件に対してもオンライン学習を行なわなかった場合(黒)に比べて、実識別率が大きく向上していることがわかる。実験番号 2 ではオンライン学習による実識別率の向上がほかの実験条件に比べて小さいが、これは EMG パターンが時間にかかわらずあまり変動していないことを意味する。なお、ほかの学習パラメータはすべて前節の実験(Table 1)と統一している。

以上のように本稿で提案する動作識別法は、被験者や電極配置がある程度変化しても高い識別率を実現できること、ニューラルネット出力のエントロピーを利用した識別保留を導入することにより誤識別を抑制できること、パターン変動を伴う EMG に対してもオンライン学習により高い識別率を実現できることなどが示された。

4. EMG の周波数情報を用いた動作識別

4.1 周波数情報の利用

動作推定に利用できる EMG 情報には、振幅情報のほかに周波数情報がある。周波数情報は、筋がそれぞれ異なる周波数特性の EMG を発生すること^{11), 12)}、および筋と電極との距離によって組織の伝達特性が変化するという事実¹³⁾によって、やはり動作ごとに異なる特徴を示す。そこで本章では EMG の振幅情報に加えて周波数情報を動作識別に利用することを考える。

Fig. 8 に周波数情報を用いた動作識別法の構成を示す。 L 対の電極から EMG を測定し、 N 帯域のバンドパスフィルタを用いて周波数成分を抽出した後、整流平滑部に入力する。そして $L \times N$ の正規化整流平滑 EMG をニューラルネット部への入力とする。ニューラルネッ

ト部の学習法、動作識別法は2章の方法と同じである。

4.2 動作識別実験

3.1節で測定した実験データを用いて、周波数情報の利用による動作識別能力の変化を調べた。

使用した5種類の帯域フィルタをTable 2に示す。通過帯域は文献4)を参考に設定し、インパルス応答(20次)のFIRフィルタはRemezのアルゴリズム¹⁴⁾を用いて求めた。

切断者による動作識別結果をFig. 9に示す。なお、各学習パラメータは前章の実験(Table 1)に統一している。図はTable 2に示した帯域フィルタの種類によって、識別率(実線)、実識別率(破線)、オフライン学習の収束に要した学習回数(点線)が変化する様子を示しており、それぞれ10通りの重み係数の初期値による結果の平均値と標準偏差である。図から、識別率、実識別率は、帯域フィルタを使用してもあまり変わらないが、学習回数は周波数情報を用いることで大きく減少していることがわかる。

一方、Table 3はほかの実験番号(Table 1参照)に対する動作識別実験の結果で、帯域フィルタの種類によって収束に要した学習回数が変化する様子を示している。どのデータに対しても周波数情報を用いることで学習回数が減少していることがわかる。EMGの振幅情報をだけでなく周波数情報をニューラルネットに入力することにより、各動作に対するEMGパターンの特徴が明確に

なったためと考えられる。

5. まとめ

本論文では、誤差逆伝搬型ニューラルネットを用いて、

Table 2 Band-pass filters used in motion discrimination experiments

	passband, Hz
Type 1	0~500
Type 2	0~500, 220~250
Type 3	0~500, 100~130, 345~375
Type 4	0~500, 55~85, 145~175, 345~375
Type 5	0~500, 55~85, 145~175, 300~330, 390~420

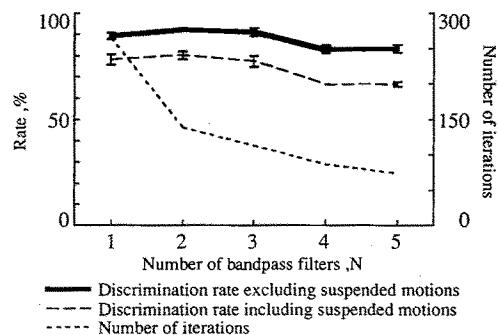


Fig. 9 Effects of number of band-pass filters on discrimination ability of the network

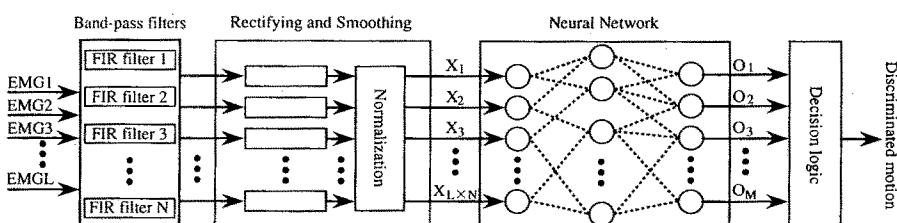


Fig. 8 Motion discrimination method utilizing frequency characteristics of EMG signals

Table 3 Number of iterations required for convergence during off-line learning utilizing frequency characteristics of EMG signals

Experiments		No. 1	No. 2	No. 3	No. 4	No. 5
Subjects		Normal A	Normal A	Normal B	Normal B	Amputee
Electrode locations						
Band-pass filters	Type 1	159.0±3.31	122.8±3.50	90.7±2.85	321.5±10.44	264.5±4.03
	Type 2	103.0±1.61	85.0±2.08	51.8±1.15	241.9±5.08	137.5±4.84
	Type 3	97.8±2.82	88.5±1.78	40.1±1.23	232.4±4.13	111.8±4.41
	Type 4	80.8±1.37	71.7±0.83	36.8±0.99	213.0±4.09	85.8±2.41
	Type 5	74.0±1.39	61.9±1.19	32.9±0.55	198.2±5.26	72.4±2.10

Average value and standard deviation for 10 kinds of initial values of the synaptic weights

複数の電極により採取したEMGから、被験者の意図した動作を識別することを試みた。そして、

- 1) 前腕部に装着した4対の電極を用いて、前腕・手の六つの動作を学習的に識別できること、
- 2) 被験者や電極配置が変化しても、識別用データに対する高い識別率が実現できること、
- 3) 識別結果の明確さの評価尺度として、ニューラルネット出力に対するエントロピーを定義し、このエントロピーを利用した識別保留を導入することにより誤識別をある程度、抑制できること、
- 4) オンライン学習を導入することで、疲労や発汗、環境変化などに伴うEMGパターンの時間的な変動に適応して動作識別を行えること、
- 5) EMGの振幅情報と周波数情報をともに用いることでニューラルネットの学習の収束に要する学習回数を軽減できること、

などの特徴を実現できることを明らかにした。

今後は、各学習パラメータのより効果的な設定法を考察するとともに、動作識別に関する知識をニューラルネットの学習に積極的に利用する方法¹⁵⁾、本手法の脳波解析への応用などについて考察する予定である。

参考文献

- 1) D. Graupe, J. Magnussen and A. A. M. Beex : A Microprocessor System for Multifunctional Control of Upper Limb Prostheses via Myoelectric Signal Identification, IEEE Transactions on Automatic Control, AC-23-4, 538/544(1978)
- 2) P. C. Doershuk, D. E. Gustafson and A. S. Willsky : Upper Extremity Limb Function Discrimination Using EMG Signal Analysis, IEEE Transactions on Biomedical Engineering, BME-30-1, 18/29(1983)
- 3) D. Graupe and W. K. Cline: Functional Separation of EMG Signal via ARMA Identification Methods for Prosthesis Control Purpose, IEEE Transactions on Systems, Man and Cybernetics, SMC-5-2, 252/259(1975)
- 4) 山田, 丹波, 内山:筋電の周波数成分と振幅成分を用いた義手制御, 日本ME学会誌, 18-2, 133/138(1980)
- 5) S. Lee and G. N. Saridis: The Control of a Prosthetic Arm by EMG Pattern Recognition, IEEE Trans., AC-29-4, 290/302(1984)
- 6) 辻, 伊藤, 長町: 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, J 70-D, 207/215(1987)
- 7) M. F. Kelly, P. A. Parker and R. N. Scott: The Application of Neural Networks to Myoelectric Signal Analysis: A preliminary study, IEEE Trans., BME-37-3, 221/230(1990)
- 8) 平岩, 内田, 下原: 筋電操作ハンドの制御のための皮膚表面筋電のニューラルネットによる認識, 第7回ヒューマンインターフェースシンポジウム論文集, 433/438(1991)
- 9) 小池, 本多, 平山, 五味, E. Vatikiotis-BATESON, 川人: 筋電信号を用いた人腕のフォワードダイナミクスモデル, 信学技報, NC91-146, 107/114(1991)
- 10) 麻生英樹:誤差逆伝播学習の数理的性質, 信学技法, PRU89-14, 54/61(1989)
- 11) R. N. Scott: Myoelectric Energy Spectra, Med. and Biol. Eng., 5, 303/305(1967)
- 12) E. Kwanty, D. H. Thomas and H. G. Kwanty: An Application of Signal Processing Technique to the Study of Myoelectric Signals, IEEE Trans., BME-17-4, 303/313(1970)
- 13) L. H. Lindstrom and R. I. Magnusson: Interpretation of Myoelectric Power Spectra: a Model and its Application, Proc. IEEE, 65-5, 653/662(1977)
- 14) 三谷政昭:ディジタルフィルタデザイン, 昭晃堂(1987)
- 15) 辻, 森, 伊藤:統計構造を組み込んだニューラルネットによるEMG動作識別法, 電気学会論文誌, 112-C-8, 465/473(1992)

[著者紹介]

辻 敏夫 (正会員)



1985年、広島大学大学院工学研究科博士課程前期修了。同年同大学工学部助手。現在に至る。人間とロボットの運動制御、ニューラルネット、マン・マシンシステムなどの研究に従事。電気学会、日本ロボット学会、IEEEなどの会員(工学博士)。

市延弘行



1992年、広島大学工学部第二類(電気系)卒業。現在、同大学大学院工学研究科博士課程前期システム工学専攻在学中。ニューラルネットを用いたパターン識別に関する研究に従事。

伊藤宏司 (正会員)



1969年、名古屋大学大学院工学研究科修士課程修了。70年同工学部助手。79年広島大学工学部助教授。92年豊橋技術科学大学情報工学系教授。生体システム、ロボティクス、マン・マシンインタフェースの研究に従事。電気学会論文賞受賞。電気学会、電子情報通信学会、日本ロボット学会、IEEEなどの会員(工学博士)。

長町三生 (正会員)



1958年、広島大学教育学部心理学卒業。63年同大学大学院博士課程修了。広島大学助手、助教授を経て現在、工学部教授。人間工学分野に広く研究しながら現在はロボティクス、AI、CAI、感性工学などのヒューマンインターフェースの研究に従事(文学博士)。