

ニューラルネットによる連続動作 EMG パターンの識別

非会員 福田 修
正員 辻 敏夫
非会員 金子 真

電気学会論文誌 C

(電子・情報・システム部門誌)

平成 9 年 10 月 号 技術

Trans. IEE of Japan, Vol. 117-C, No. 10, Oct., 1997

ニューラルネットによる連続動作EMGパターンの識別

非会員 福田 修 (広島大学)

正員 辻 敏夫 (広島大学)

非会員 金子 真 (広島大学)

Pattern Classification of EMG Signals Using Neural Networks during a Series of Motions

O. Fukuda, Non-member, T. Tsuji, Member and M. Kaneko, Non-member (Hiroshima University)

This paper proposes a pattern classification method of time series EMG signals using neural networks in order to estimate a motion intended by a human operator. To achieve successful classification for non-stationary EMG signals, a new network structure that combines a common back-propagation neural network with recurrent neural filters is used. This network is suitable to express time-varying characteristics of time-series EMG signals. Also dynamics of a terminal attractor is incorporated in the learning rule in order to regulate convergence time. The convergence time is always less than the upper limit of a specified time, so that mental stress of the operator for waiting the convergence of learning can be reduced. In the experiments, the EMG signals measured from four subjects during a series of six motions are used. It is shown from the results that the proposed network can achieve a relatively high classification performance and the learning converges within a specified time.

キーワード：筋電位、パターン識別、ニューラルネット、ディジタル・フィルタ、ターミナルアトラクタ

1. まえがき

人間がある動作を行う時、上位中枢からの指令に応じて各筋が収縮し目的の動作が実現される。したがって、筋の収縮レベルに応じて発生するEMG信号は、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を反映していることになる。このEMG信号パターンの特徴から、人間の意図する動作を推定することができれば、特別な訓練をしなくとも自然な感覚で操作可能なヒューマンインターフェースを構築できる可能性があり、動力義手の制御、ロボットのテレオペレーション、仮想現実空間などの分野で期待が持たれている。

人間の動作とEMG信号パターンの関係は、脊髄反射系、筋の種類、皮膚組織の伝達特性などが複雑に絡み合った非線形写像である。しかしながら、従来から行われているEMG信号識別は、このEMG信号にARモデルなどの線形モデルをあてはめて識別する場合が多かった^{(1),(2)}。この場合、複雑で線形分離不可能なEMGパターンを正確に識別することは難しく、また時間の経過に伴う発汗や疲労などの環境の変化にも適応できない。

最近これらの問題に対し、非線形写像を学習的に獲得できるニューラルネットが用いられるようになってきた⁽³⁾⁻⁽⁷⁾。特に、Rumelhartらが提唱した誤差逆伝播学習アルゴリズム⁽⁸⁾はニューラルネットの研究の中でも中心課題の一つであり、これまでのEMG信号識別の研究もほとんどがこの誤差逆伝播型のニューラルネットを用いたものであった⁽³⁾⁻⁽⁶⁾。しかしながら、誤差逆伝播型ニューラルネットの識別

能力については幾つかの問題点がある。例えば、ネットワークの各パラメータの設定に関しては、まだ多くの理論的疑問が残されている。つまり、層数、ユニット数、教師サンプル数、学習率などをどのように設定すればよいかを明確に説明することはできない。また通常は、時間的な要素を含むパターン識別問題に応用することも難しい。したがって、連続動作時などに激しく変動するEMG信号を識別する場合、写像の複雑さが増すにつれて、多量の教師サンプル数や学習時間、大規模なネットワークが必要となり、学習が極めて困難となることが予想される。

誤差逆伝播型ニューラルネットが持つこの問題点を解消するため、辻ら⁽⁷⁾は学習対象に関して既知な特性を構造としてネットワークに組み込むことを提案している。このネットワークは、EMG信号の統計特性を学習により獲得し、信号の時間的変動が激しい場合でも高い識別率を得ることができる。また、ユニットの入出力関数、層の数、ユニットの数などのネットワーク構造も統計モデルに基づいて決定することができる。しかしながら、この統計モデルは各動作についての静的な特性のみしか考慮されておらず、複数の動作を連続して行うような場合については言及されていない。これに対して、我々は先にこのような統計モデルを内包したネットワークとリカレント型のニューラルフィルタを組み合わせて、時系列脳波信号の識別を行った⁽⁹⁾。この方法は、ニューラルフィルタを用いて時系列特性を考慮することで高い識別精度を実現している。しかしながらこの研究では、開眼時か閉眼時あるいは闪光刺激時か平常時といったわずか2状態についての識別しか行われておらず、

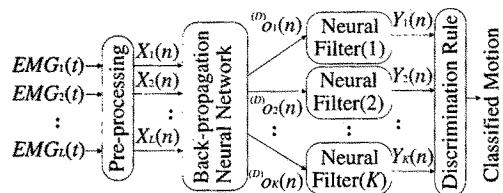


図 1 ネットワーク構造
Fig. 1 Structure of the proposed network.

多数の状態についての識別実験はなされていない。また、ネットワーク構造が複雑になることにより学習が困難になるという問題点も有している。

そこで本論文では、連続動作時において激しく変動する時系列 EMG 信号を精度良く識別するために、新しいネットワークの構造とその学習アルゴリズムを提案する。提案手法では時系列 EMG 信号のパターン識別を、各時刻における静的なパターン処理と時系列的つながりを考慮するためのフィルタリング処理に分割することを考えた。そして、各処理を行うために、通常の誤差逆伝播型ニューラルネット⁽⁸⁾（以下 BPN と略記）と、リカレント型のニューラルフィルタ⁽¹⁰⁾（以下 NF と略記）を組み合わせたネットワーク構造を用意した。

また、効率良く学習を行うことと、各ネットワークの役割を明確に分割することを意図し、学習は 2 段階に分割した。さらに各ネットワークの学習則には、ターミナルアトラクタ⁽¹¹⁾を導入し、変動が激しい EMG 信号に対しても指定した時間内でネットワークの学習を終了できるようにした。学習収束時間の上限を指定できることは、オンラインでネットワークを学習する場合などに操作者の精神的負担を軽減することができ、実際にヒューマンインターフェースとして利用する際に大きな利点となる。

以下、提案するネットワーク構造・学習アルゴリズムを説明し、時系列 EMG パターンの識別を行った結果について述べる。

2. 時系列 EMG パターンの識別

<2・1> ネットワーク構造

提案するネットワーク構造を図 1 に示す。ネットワークは、前処理部、ニューラルネット部（以下 NN 部と略記）、ニューラルフィルタ部（以下 NF 部と略記）、識別判定部の 4 部から構成される。測定した EMG 信号は前処理部にて処理され、入力ベクトルとして、次々と NN 部に入力される。NN 部は、個々のパターンが K 個の動作中どの動作に属するかを計算し、その結果を出力する。次に、この識別結果をそれぞれ NF 部へ入力する。NF 部では、時系列パターンの変動に応じたフィルタリングを行い識別結果を修正する。識別判定部では、まず各 NF 部からの出力を、その総和が 1 となるように正規化する。そして、各々の値を確率変数とみなし、最も確率の高い事象を入力パターンに

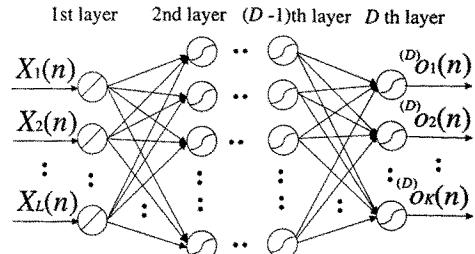


図 2 誤差逆伝播型ニューラルネットの構造
Fig. 2 Structure of the back propagation neural network.

に対する識別結果とする。

このネットワーク構造のポイントは、BPN と NF を組み合わせた点にある。これら二つのネットワークで処理を分割することで、連続動作時における EMG パターン識別を精度良く行うことが可能となる。以下、各部の詳細について説明する。

<2・1・1> 前処理部

前処理部では、 L 対の電極を使って測定した EMG 信号から NN 部への入力ベクトルを生成する。まず各電極で測定した EMG 信号 $EMG_i(t)$ ($i = 1, \dots, L$) を全波整流し、その後 1 次のバタワースフィルタ（カットオフ周波数： $f_{cut}[\text{Hz}]$ ）を用いて平滑化する。この平滑化 EMG 信号を t_d 秒ごとに抽出し、さらに L 個のチャンネル和が 1 となるように正規化したものを NN 部への入力ベクトル $X(n) = [X_1(n), X_2(n), \dots, X_L(n)]^T$ とする。ここで T は転置、 n は各時刻を表す。

この前処理部におけるバタワースフィルタのカットオフ周波数によって、NN 部への入力ベクトルの信号特性が変化し、ネットワークの学習や識別に大きく影響する。連続動作中の EMG 信号の変化を適切に抽出できるように、カットオフ周波数を設定する必要がある。一般にカットオフ周波数を下げると、EMG 信号の変動は抑えられ、ネットワークの学習は容易になるが、同時に連続動作に伴う EMG 信号の変化も抑えられてしまう。逆にカットオフ周波数を上げると、動作による EMG 信号の変化は保存されるが、信号の変動が大きくなるためにネットワークの学習や識別は困難となる。

<2・1・2> NN 部

NN 部には、図 2 に示すような D 層の BPN を用い、各時刻における入力ベクトルのパターン処理を行う。入力層から出力層までの各層のユニット数は、それぞれ M_1, M_2, \dots, M_D で、入出力層については $M_1 = L, M_D = K$ とする。各入力ユニットは、出力関数に恒等関数を用いており、前処理部において生成した $X_i(n)$ を第 1 層の入力 $(1)s_i(n)$ として受け、そのまま第 1 層の出力 $(1)o_i(n)$ として出力する。第 2 層以降の入出力については以下のように定義する。

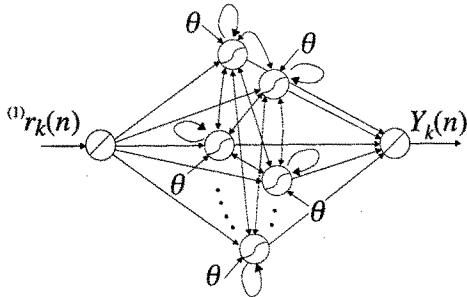


図3 ニューラルフィルタの構造
Fig. 3 Structure of the neural filter.

$${}^{(d)}s_i(n) = \sum_{j=1}^{M_{d-1}} {}^{(d-1,d)}W_{ij} {}^{(d-1)}o_j(n) \quad (1)$$

$${}^{(d)}o_i(n) = \frac{1}{1 + \exp(-{}^{(d)}s_i(n))} \quad (2)$$

ここで ${}^{(d)}s_i(n)$ と ${}^{(d)}o_i(n)$ ($d = 2, 3, \dots, D$) は第 d 層の i 番目のユニットの入力と出力を表わす。また、 ${}^{(d-1,d)}W_{ij}$ は、第 $d - 1$ 層の j 番目のユニットと第 d 層の i 番目のユニット間の重みである。なお、図2の第 D 層における ${}^{(D)}O_i(n)$ は、対象とする K 個の動作のうち i 番目の動作に属する度合いを表わすことになる。

<2・1・3> NF部

NF部では、NN部では考慮できない入力データの時系列的な変動に対処する。NN部からの出力は、変動の激しい時系列信号となることが予想される。この信号に対しNFは、学習により適切なフィルタ特性を獲得し、NN部からの出力を修正する。この学習能力が既存のデジタルフィルタには無い大きな利点である。

Lo (10)は、非線形信号のフィルタリングを行うために、図3に示すような中間層にリカレント結合をもつNFを提案した。簡単な非線形信号に対するシミュレーション実験の結果、このNFはカルマンフィルタよりも優れた処理能力を有することが示されている。本手法では、この構造をNFとして採用することにした。

NFはNN部の各出力ユニットに並列に結合し、入力ユニット1個、中間ユニット B 個、出力ユニット1個の構造を持つ。いまNN部に、入力ベクトル $\mathbf{X}(n)$ が与えられ、 k 番目の出力ユニットに ${}^{(D)}o_k(n)$ が 出力された場合を考える。NF部の第1層のユニットはこの出力を入力 ${}^{(1)}r_k(n)$ として受け、この値をそのまま ${}^{(1)}v_k(n)$ として出力する。

第2層の各ユニットには、第1層のユニットの出力と一時刻前の第2層のユニットの出力が、重みを介して伝えられる。この同層内での相互・自己結合により、順次変化するネットワーク内部の情報を保持することができる。また、この層にはバイアス入力 ($\theta = 1$) を付加している。第2層の b 番目のユニットへの入力 ${}^{(2)}r_k^b(n)$ 、および出力 ${}^{(2)}v_k^b(n)$ は、

$$\begin{aligned} {}^{(2)}r_k^b(n) &= \sum_{a=1}^B {}^{(2,2)}u_k^{ab} {}^{(2)}v_k^a(n-1) \\ &\quad + {}^{(1,2)}u_k^{b(1)} v_k(n) + {}^{(\theta)}u_k^b \end{aligned} \quad (3)$$

$${}^{(2)}v_k^b(n) = \frac{1}{1 + \exp(-{}^{(2)}r_k^b(n))} \quad (4)$$

となる。ただし、 ${}^{(2,2)}u_k^{ab}$ は第2層内での a 番目のユニットから b 番目のユニットへの結合荷重、 ${}^{(1,2)}u_k^{b(1)}$ は、第1層のユニットから第2層の b 番目のユニットへの結合荷重を示す。また、 ${}^{(\theta)}u_k^b$ はバイアスから第2層の b 番目のユニットへの結合荷重である。

第3層のユニットは、第2層の全てのユニットと結合しており、入出力関係は、

$${}^{(3)}r_k(n) = \sum_{b=1}^B {}^{(2,3)}u_k^b {}^{(2)}v_k^b(n) \quad (5)$$

$$Y_k(n) = \frac{1}{1 + \exp(-{}^{(3)}r_k(n))} \quad (6)$$

となる。ただし、 ${}^{(3)}r_k(n)$ は第3層のユニットへの入力、 ${}^{(2,3)}u_k^b$ は第2層の b 番目のユニットから第3層のユニットへの結合荷重である。 $Y_k(n)$ は第3層のユニットの出力を表す。

<2・1・4> 識別判定部

各NFの出力は識別する各動作に対応しているので、各出力の総和が1となるように正規化し、各動作の出力確率のように取り扱うことができる。識別判定部では、この出力確率からエントロピーを計算し、それに基づいて識別を行なう(6)。

例えば、NN部にある入力ベクトル $\mathbf{X}(n)$ が与えられ、各NFが $Y_k(n)$ ($k = 1, 2, \dots, K$) を出力したとする。このときエントロピー $H_{nf}(n)$ は

$$H_{nf}(n) = - \sum_{k=1}^K p(k|\mathbf{X}(n)) \log_2 p(k|\mathbf{X}(n)) \quad (7)$$

$$p(k|\mathbf{X}(n)) = \frac{Y_k(n)}{\sum_{k'=1}^K Y_{k'}(n)} \quad (8)$$

と計算される。

エントロピーは、情報のあいまいさを表す評価値である。ので、識別判定しきい値を θ_d とし、エントロピーがこの値より大きい場合は識別保留、小さい場合は出力が最大となるユニットに対応する動作を識別動作とする(6)。この方法であいまいな識別を防ぐことができ、誤識別を抑えることができる。

<2・2> 学習アルゴリズム

ここでは、ネットワークの学習アルゴリズムについて説明する。もし、ネットワーク全体を同時に学習させるのであれば、NF 部の出力層に教師信号を与え、そこで誤差を NN 部の入力層へと逆伝播する方法が考えられる。しかし、この方法では 2 種類のネットワークを直列に結合した構造となっているため NF 部から NN 部へ適切な誤差が逆伝播されるとは限らない。そこで本論文では、効率良く学習を行うことと、NN 部と NF 部の各ネットワークの役割を明確に分割することを意図し、学習を 2 つのステップに分割した⁽⁹⁾。

また、実際にインターフェースとして利用することを想定すると、オンラインで学習する際などに、操作者はネットワークの学習収束を待つことになる。この場合、通常の誤差逆伝播学習則のように最急降下法に基づいた学習則では、その終了時刻を予想することはできない。そこで、各々のネットワークの学習が指定した時間以内で終了するように、学習則にターミナルアトラクタ⁽¹¹⁾を導入した。これにより、変動が激しい EMG 信号に対しても指定した時間内でネットワークの学習を終了できる。学習収束時間を予想できることは、操作者の精神的負担を大きく軽減する。また並列結合されている全ての NF について、学習の収束を同期させることができとなる。

<2・2・1> 学習のスケジューリング

まずははじめに、NN 部のみを学習する。学習用データとしては、学習が安定して行えるように動作を一定に維持した状態で抽出した EMG パターンを用いる。各動作に対応する NN 部の各出力ユニットには、教師ベクトル $\mathbf{T}_{nn}(n) = [T_{nn}^1(n), \dots, T_{nn}^k(n), \dots, T_{nn}^K(n)]^T$ を与える。この際、学習を高速化するために正解動作に対応するユニットには 1.1、それ以外には -0.1 を与えた。

つぎに、NN 部の学習終了後、NN 部の結合荷重を固定した状態で NF 部の学習を行う。まず NN 部の学習に用いたパターンとは別の連続動作時の入力パターンを NN 部に与え、出力される時系列を各 NF に入力する。そして各 NF の出力層に NN 部の学習と同様に教師信号 $T_{nf}^k(n)$ を与える。この際、出力ユニットが正解動作に対応している場合には 1.0 を、そうでない場合には 0.0 を与える。

<2・2・2> ターミナルアトラクタ

一般に相互結合型の非線形ニューラルネットはリプシツ条件、すなわち初期値問題に対する解の一意性を保証する条件を満足する。このリプシツ条件が満足されると、それぞれの初期値問題に対して一意な解が存在し、その解軌道は漸近的に平衡点に近づく。すなわち、軌道は平衡点に近づくだけで、有限時間内で平衡点に到達できない。

Zak はこのリプシツ条件を破るという考えに基づき、解の一意性を破ることにより、有限時間内でニューラルネットが平衡点に収束することを示した⁽¹¹⁾。このような安定平衡点をターミナルアトラクタ（以下 TA と略記）と呼ぶ。

本論文ではこの TA をネットワークの学習則に利用し、評価関数が最終的に 0 にならない場合についても、収束時間の上限値を指定できるようにした。

<2・2・3> TA を利用した NN 部の学習

いま、時刻 n での入力ベクトル $\mathbf{X}(n)$ に対して、教師信号ベクトル $\mathbf{T}_{nn}(n) = [T_{nn}^1(n), \dots, T_{nn}^k(n), \dots, T_{nn}^K(n)]^T$ が NN 部の出力ユニットに与えられる場合を考える。このとき最小化すべき評価関数は、

$$E_{nn} = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^K ((D)o_k(n) - T_{nn}^k(n))^2 \quad (9)$$

と自乗誤差和の形で表わされる。この全パターンに対する評価関数 E_{nn} を考えたとき、平衡点が漸近安定であるためには E_{nn} がリニアノフ関数であればよい。そこで、重み $(d-1,d)W_{ij}$ の時間微分を

$$(d-1,d)\dot{W}_{ij} = -\eta_{nn}\gamma_{nn} \frac{\partial E_{nn}}{\partial (d-1,d)W_{ij}} \quad (10)$$

$$\gamma_{nn} = \frac{E_{nn}^\alpha}{\sum_{d=2}^D \sum_{i=1}^{M_d} \sum_{j=1}^{M_{d-1}} \left(\frac{\partial E_{nn}}{\partial (d-1,d)W_{ij}} \right)^2} \quad (11)$$

とおくと、 E_{nn} の時間微分は

$$\begin{aligned} \dot{E}_{nn} &= \sum_{d=2}^D \sum_{i=1}^{M_d} \sum_{j=1}^{M_{d-1}} \left(\frac{\partial E_{nn}}{\partial (d-1,d)W_{ij}} \right) (d-1,d)\dot{W}_{ij} \\ &= -\eta_{nn}E_{nn}^\alpha \leq 0 \end{aligned} \quad (12)$$

となる。ただし、 $\eta_{nn} > 0$ は学習率、 α は $0 < \alpha < 1$ を満たす。 E_{nn} は時間とともに単調減少し、平衡点は漸近安定となることがわかる。このときの収束時間 t_{fnn} は、

$$\begin{aligned} t_{fnn} &= \int_0^{t_{fnn}} dt = \int_{E_{nn}(0)}^{E_{nn}(t_{fnn})} \frac{dE}{E} \\ &= \frac{E_{nn}(0)^{1-\alpha} - E_{nn}(t_{fnn})^{1-\alpha}}{\eta_{nn}(1-\alpha)} \\ &\leq \frac{E_{nn}(0)^{1-\alpha}}{\eta_{nn}(1-\alpha)} \end{aligned} \quad (13)$$

で与えられ、有限時間内で収束することが分かる。 $E_{nn}(0)$ は重みの初期値を使って計算した E_{nn} の初期値で、 $E_{nn}(t_{fnn})$ は平衡点での E_{nn} の値である。 $E_{nn}(t_{fnn}) = 0$ の場合、式 (13) の等号が成立する。そこで学習率 η_{nn} を、

$$\eta_{nn} = \frac{t_{fnn}(1-\alpha)}{E_{nn}(0)^{1-\alpha}} \quad (14)$$

とすると収束時間を指定できる。一方、 $E_{nn}(t_{fnn}) > 0$ の場合でも式 (13) で与えられる収束時間の上限値よりも速く学習が平衡点に到達することを保証できる。実際の重みの修正は (10) 式を離散化した次式に従って行う。

$$(d-1,d)W_{ij}(t + \Delta t_{nn}) = {}^{(d-1,d)}W_{ij}(t) + \frac{\Delta t_{nn}}{2}({}^{(d-1,d)}\dot{W}_{ij}(t) + {}^{(d-1,d)}\dot{W}_{ij}(t + \Delta t_{nn})) \quad (15)$$

ここで Δt_{nn} は学習のサンプリング間隔を示す。

さらに本論文では、NN 部の学習を短時間で打ち切るために、NN 部の出力から計算されるエントロピーを収束判定に利用した⁽⁶⁾。識別判定部での計算と同様にエントロピー $H_{nn}(n)$ を

$$H_{nn}(n) = - \sum_{k=1}^K p(k|\mathbf{X}(n)) \log_2 p(k|\mathbf{X}(n)) \quad (16)$$

$$p(k|\mathbf{X}(n)) = \frac{{}^{(D)}O_k(n)}{\sum_{k'=1}^K {}^{(D)}O_{k'}(n)} \quad (17)$$

と定義する。学習収束判定しきい値を θ_ϵ とし、全ての学習サンプルに対するエントロピーがこの値より小さくなり、かつ識別結果がすべて正解の場合、学習を終了する。

<2・2・4> TA を利用した NF の学習

次に、TA を利用した NF の学習則について説明する。NF 部では動作数に対応して K 個の NF を学習する必要がある。この学習は動作間で独立に実行できるので並列計算が可能であるが、通常の誤差逆伝播学習では学習終了時刻に大きなばらつきが生じる。TA を導入することで、複数の NF の学習収束をある程度同期させることができくなる。ここでは第 k 番目の NF の出力層に、教師信号として $T_{nf}^k(n)$ が与えられた場合について考えよう。このとき最小化すべき評価関数は、

$${}^{(k)}E_{nf} = \frac{1}{2} \sum_{n=1}^N (Y_k(n) - T_{nf}^k(n))^2 \quad (18)$$

と自乗誤差和の形で表される。第 3 層から第 2 層に対しては、この誤差が誤差逆伝播学習則にしたがって伝播される。重み ${}^{(2,3)}\dot{u}_k^b$ の時間微分を (10), (11) 式と同様の方法で、

$${}^{(2,3)}\dot{u}_k^b = -\eta_{nf}\gamma_{nf} \frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,3)}u_k^b} \quad (19)$$

$$\gamma_{nf} = \frac{{}^{(k)}E_{nf}^\beta}{\psi} \quad (20)$$

とおく。ここで η_{nf} は学習率を表わす。ただし ψ は、

$$\begin{aligned} \psi &= \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,3)}u_k^b} \right)^2 + \sum_{a=1}^B \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,2)}u_k^{ab}} \right)^2 \\ &+ \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(1,2)}u_k^b} \right)^2 + \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(\theta)}u_k^b} \right)^2 \end{aligned} \quad (21)$$

とする。第 2 層以下の層に対しては、相互・自己結合を持つことから、通時的誤差逆伝播学習アルゴリズム (back-propagation through time, 以下 BPTT と略記)⁽⁸⁾ に TA を導入した。第 2 層以下の重みの時間微分を次式のように定義する。

$${}^{(2,2)}\dot{u}_k^{ab} = -\eta_{nf}\gamma_{nf} \frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,2)}u_k^{ab}} \quad (22)$$

$${}^{(1,2)}\dot{u}_k^b = -\eta_{nf}\gamma_{nf} \frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(1,2)}u_k^b} \quad (23)$$

$${}^{(\theta)}\dot{u}_k^b = -\eta_{nf}\gamma_{nf} \frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(\theta)}u_k^b} \quad (24)$$

ただし、 $\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,2)}u_k^{ab}}$, $\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(1,2)}u_k^b}$, $\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(\theta)}u_k^b}$ の計算については C ステップ時間の遡りを考慮して行った。このとき、 ${}^{(k)}E_{nf}$ の時間微分は (12) 式と同様に、

$$\begin{aligned} {}^{(k)}\dot{E}_{nf} &= \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,3)}u_k^b} \dot{u}_k^b \right) \\ &+ \sum_{a=1}^B \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(2,2)}u_k^{ab}} \dot{u}_k^{ab} \right) \\ &+ \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(1,2)}u_k^b} \dot{u}_k^b \right) \\ &+ \sum_{b=1}^B \left(\frac{\partial {}^{(k)}E_{nf}}{\partial {}^{(\theta)}u_k^b} \dot{u}_k^b \right) \\ &= -\eta_{nf} E_{nf}^\beta \leq 0 \end{aligned} \quad (25)$$

と表わされ、TA が成立している。このときの学習収束時間 t_{fnf} は、(13) 式と同様にして求められる。また、実際の重みの修正は (15) 式と同様に (19), (22), (23), (24) 式を離散化して学習のサンプリング間隔 Δt_{nf} 毎に行った。

3. 時系列 EMG パターン識別実験

<3・1> 実験条件

実験は切断者を含む男子大学生 4 人の被験者に対して行った。切断者は、手首関節近くの前腕部を切断して約 6 カ月経過している。まず被験者の前腕部に $L = 4$ 対の乾式電極 (今仙技術研究所) を 90° 間隔で取り付け、サンプリング周波数 1[kHz] で EMG 信号を測定した。前処理部では、この信号から $t_d = 10[\text{msec}]$ 毎に入力ベクトルを抽出する。実験に用いた BPN は、 $D = 3$ 層で中間層のユニット数は $M_2 = 10$ 、NF の中間層のユニット数は $B = 8$ とした。また式 (7), (16) の計算は常用対数を用いて行い、NN 部の学習収束判定しきい値は $\theta_\epsilon = 0.2$ に設定した⁽⁶⁾。TA のパラメータについて $t_{fnf} = 1.0$, $\Delta t_{nn} = \Delta t_{nf} = 0.001$, $\alpha = \beta = 0.7$ とした。

比較のため EMG 信号は、動作を一定に維持した際の定常動作 EMG 信号と、比較的短時間 (4 秒間) に連続動作を

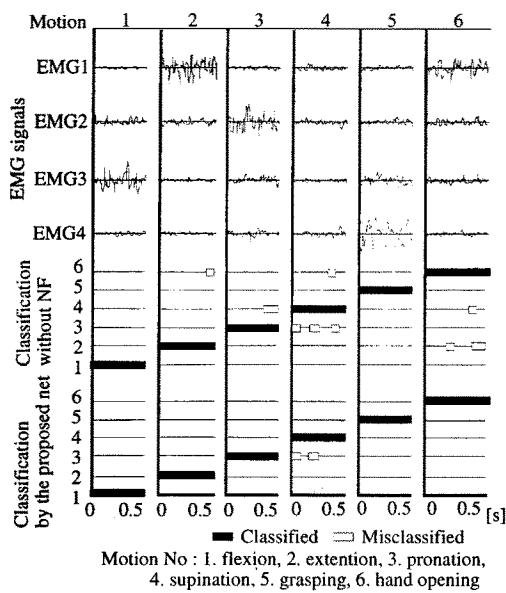


図4 定常動作EMG信号に対する識別結果の一例

Fig. 4 An example of the classification result for stationary EMG signals.

行った際の連続動作EMG信号とした。いずれも動作は、掌屈、背屈、回内、回外、握り、開きの $K = 6$ 動作とする。

<3・2> 実験結果

<3・2・1> 定常動作EMG信号の識別

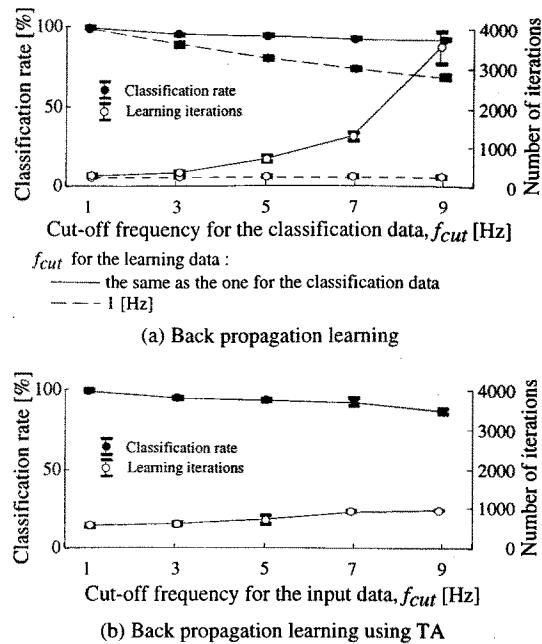
まず動作を一定に維持した際の定常動作EMG信号に対する識別結果の一例(切断者)を図4に示す。上から正解動作、EMG信号、本手法からNFを除いた場合の識別結果、本手法による識別結果で、NFを除いた場合はNN部の出力がそのまま識別判定部に入力されるものとした。また、EMG信号は各動作を十分に維持し、信号が安定している状態で0.5秒間ずつ測定した。

前処理部におけるバタワースフィルタのカットオフ周波数は $f_{cut} = 9[\text{Hz}]$ とし、NF部で考慮する遅延時間ステップ数は $C = 3$ とした。識別判定しきい値は $\theta_d = 0.35$ である。

識別率はNFを除いた場合で95.4%、本手法の場合98.8%であった。定常動作EMG信号に対しては、NFを除いたNN部だけの場合でも十分に高い識別精度が得られている。

次に、本手法におけるTAの導入効果について調べるために、(a)通常の誤差逆伝播学習則で学習したNN部と(b)TAを学習則に導入した場合のNN部について、収束に要した学習回数と識別率を比較した。前処理部のバタワースフィルタのカットオフ周波数 f_{cut} を変化させた場合に、各値がどのように変化するかを図5に示す。各値とも10通りの異なる重み初期値で実験を行い、その平均値を標準偏差付で示している。このとき識別判定しきい値は $\theta_d = 0.25$ に設定した。被験者は切断者である。

図5(a)については学習を安定して行うために、カットオフ周波数 f_{cut} を学習時のみ $1[\text{Hz}]$ に固定した場合についても実験を行い、図中に破線で示した。この場合は、学習回

図5 ニューラルネット部におけるTAの効果
Fig. 5 Effect of the TA on the neural network part.表1 ニューラルネット部による識別結果
Table 1 Classification results by the neural net part.

Experiments	No. 1	No. 2	No. 3	No. 4
Subjects	Normal A	Normal B	Normal B	Ampiee
(a.1) Back propagation learning (f_{cut} for Learning / Classification data = 1/9[Hz])				
Number of iterations	226.6 ± 26.9	231.8 ± 19.6	324.0 ± 48.5	209.5 ± 10.2
Classification rate(%)	57.9 ± 2.0	75.3 ± 1.8	83.4 ± 1.8	70.0 ± 1.4
Misclassification rate(%)	0.0 ± 0.0	0.0 ± 0.1	0.6 ± 0.8	0.1 ± 0.1
Suspended rate(%)	42.1 ± 2.0	24.7 ± 1.7	16.0 ± 1.7	29.9 ± 1.3
(a.2) Back propagation learning (f_{cut} for Learning / Classification data = 9/9[Hz])				
Number of iterations	621.5 ± 81.0	769.2 ± 56.8	760.6 ± 45.7	3488.4 ± 2201.1
Classification rate(%)	89.7 ± 0.8	95.1 ± 1.3	96.3 ± 0.8	93.4 ± 0.5
Misclassification rate(%)	0.8 ± 0.4	0.0 ± 0.0	0.1 ± 0.1	1.3 ± 0.4
Suspended rate(%)	9.5 ± 0.9	4.9 ± 1.3	3.6 ± 0.9	5.2 ± 0.7
(b) Back propagation learning using TA (f_{cut} for Learning / Classification data = 9/9[Hz])				
Number of iterations	710.7 ± 48.6	982.4 ± 26.4	990.8 ± 19.6	1000.0 ± 0.0
Classification rate(%)	90.7 ± 0.8	92.7 ± 1.0	94.3 ± 1.3	86.7 ± 1.4
Misclassification rate(%)	1.2 ± 0.4	0.0 ± 0.0	0.0 ± 0.1	0.4 ± 0.2
Suspended rate(%)	9.2 ± 0.7	7.3 ± 0.9	5.6 ± 1.3	13.3 ± 1.3

数を一定にできるが、識別データのカットオフ周波数が高くなるにつれて識別率が著しく低下している。一方、カットオフ周波数が学習時と識別時で一致している場合は、識別率の低下は抑えられるが、学習回数が極端に増加している。それに対し(b)の場合は、TAの導入により学習回数の上限値が $t_{fnn}/\Delta t_{nn} = 1000$ 回以下に抑えられている。識別率の低下も比較的少ない。

つぎに、3人の被験者に対して同様の実験を行った結果を表1に示す。被験者Bについては電極位置を変えて2回の実験を行った。(a.1), (a.2)は通常の誤差逆伝播学習則で学習したNN部、(b)は本手法のNN部の識別結果を示している。フィルタのカットオフ周波数は $f_{cut} = 9[\text{Hz}]$ に設定した。ただし、(a.1)については学習を安定して行うために学習時のみ $f_{cut} = 1[\text{Hz}]$ とした。識別判定しきい値は $\theta_d = 0.25$ とする。図5で示された傾向と同様に(a.1), (a.2)では識別率の低下や極端な学習回数の増加がみられる。

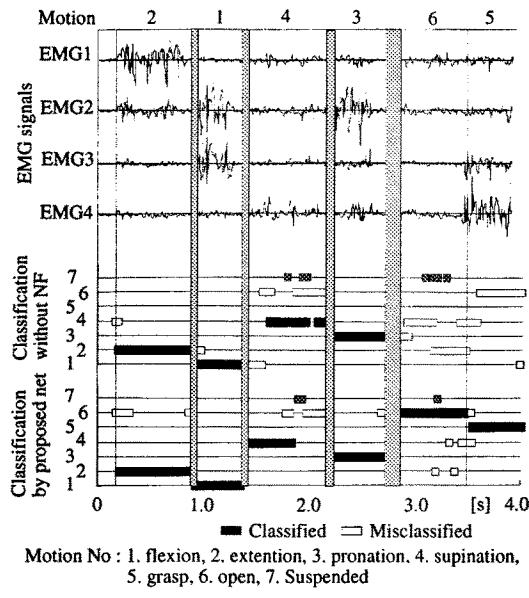


図 6 連続動作 EMG 信号に対する識別結果の一例

Fig. 6 An example of the classification result for non-stationary EMG signal.

が、本手法の NN 部の場合は学習回数の上限を超過することなく高い識別率が得られている。

<3・2・2> 連続動作 EMG 信号の識別

つぎに、比較的短時間（4秒間）に6つの動作を連続して行った際のEMG信号について識別実験を行った。識別結果の一例（切断者）を図6に示す。ただし、4対の電極から測定したEMG信号の自乗和を計算し、その値が設定したしきい値以下の時は、静止(stop)とみなし識別を行わなかった。フィルタのカットオフ周波数は $f_{cut} = 9[\text{Hz}]$ 、NFで考慮する遡り時間ステップ数は $C = 3$ 、識別判定しきい値は $\theta_d = 0.35$ とした。なお、識別保留を識別結果と並べて表示した。

定常動作EMG信号の識別結果と比べると識別精度が低下していることがわかる。特にNF部を除いた場合では、各動作が遷移した直後の区間や、連続動作の後半で誤識別がかなり多くなっている。NFの導入により、識別精度が著しく向上していることが分かる。

つぎに、前処理部のフィルタのカットオフ周波数 f_{cut} を変化させた場合の本手法の識別結果を図7に示す。識別判定しきい値は $\theta_d = 0.25$ に設定した。被験者は切断者で、NN部およびNF部における全ての重み $(^{(d-1,d)}W_{ij}, {}^{(2,3)}u_k^b, {}^{(2,2)}u_k^{ab}, {}^{(1,2)}u_k^b, {}^{(0)}u_k^b)$ について10通りの異なる初期乱数を与えて実験を行い、その平均と標準偏差を求めた。NFを除いた場合にくらべて、本手法の識別率が20%程度向上しているのが分かる。ただし、カットオフ周波数が極端に低い場合は、連続動作に伴うEMG信号の変化を適切に抽出できないため、NFを用いても識別精度はそれ程高くない。

また、NFで考慮する遡り時間ステップ数 C を変化させ

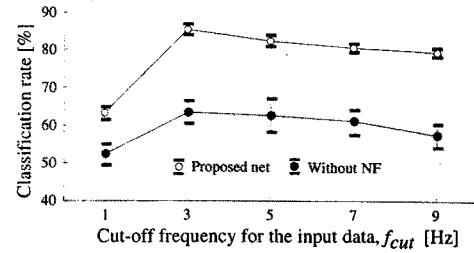
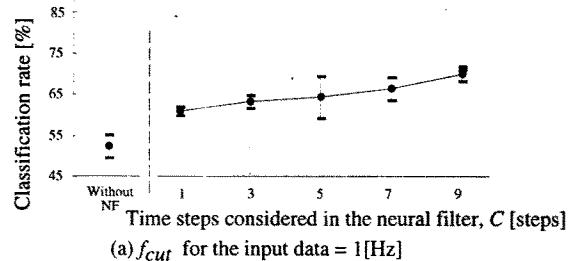
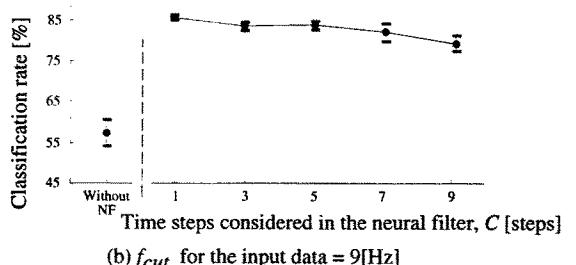


図 7 前処理部のフィルタのカットオフ周波数が識別率に与える影響

Fig. 7 Effect of the cut-off frequency of the pre-processing part on the classification rate.



(a) f_{cut} for the input data = 1[Hz]



(b) f_{cut} for the input data = 9[Hz]

図 8 BPTT における遡り時間ステップ数が識別結果に与える影響

Fig. 8 Effect of the time steps of the BPTT on the classification rate.

た場合についても同様に実験を行い、識別率の変化を調べた。図8は、前処理部のフィルタのカットオフ周波数 f_{cut} が、1[Hz]と9[Hz]の場合で、NFを除いた識別率についても左端に示した。いずれの場合とも、NFの効果により識別率が向上している。1[Hz]の場合では、NFの遡り時間ステップを増やすことでネットワークの表現能力が増し、識別率が向上する傾向がみられる。一方、9[Hz]の場合は、遡り時間ステップを増やしても識別率は向上しなかった。これは、 $f_{cut} = 9[\text{Hz}]$ で信号の変動が激し過ぎる上に考慮する遡り時間が増加したこと、ネットワークの学習が十分に行えなかっただためと考えられる。

さらに、2人の被験者に対して電極位置を変えて同様の実験を行った。識別結果を表2に示す。前処理部におけるバタワースフィルタのカットオフ周波数 f_{cut} は9[Hz]とし、NFで考慮する遡り時間ステップは $C = 3$ とした。全ての

表2 本手法による識別結果
Table 2 Classification results by the proposed network.

Experiments Subjects	No. 1 Amptec	No. 2 Amptec	No. 3 Normal C	No. 4 Normal C
(a) Without NF				
Classification rate(%)	58.4±2.0	50.2±1.7	52.3±1.4	49.6±1.7
Misclassification rate(%)	1.1±1.7	2.1±1.5	2.2±1.6	1.9±1.6
Suspended rate(%)	40.5±1.4	47.7±1.3	45.5±2.0	48.3±1.7
Iterations (NN part)	1000.0±0.0	792.3±42.1	884.5±19.1	984.6±32.1
(b) Proposed net				
Classification rate(%)	81.6±0.9	85.2±2.0	77.8±1.4	75.2±1.7
Misclassification rate(%)	2.0±0.8	2.0±1.7	1.1±1.2	2.1±1.5
Suspended rate(%)	17.4±0.7	12.8±1.3	21.1±0.9	22.7±1.3
Iterations (NN part)	1000.0±0.0	792.3±42.1	884.5±19.1	984.6±32.1
Iterations (NF part)	1000.0±0.0	1000.0±0.0	1000.0±0.0	1000.0±0.0

実験において、指定した学習回数の上限値が $t_{fnn}/\Delta t_{nn} = t_{fnf}/\Delta t_{nf} = 1000$ 回以下に抑えられている。また、NF 部の効果でかなり識別精度が向上している。

4.まとめ

本研究では、時系列 EMG 信号のパターン識別問題に対し、2種類のニューラルネットワークを組み合わせた新しいネットワーク構造を考え、さらに効率よく学習を行うための学習スケジュールを導出した。

実験の結果、本手法により時系列 EMG パターンを十分な精度で識別することができた。また学習則に TA を導入したことで収束時間が指定できることも確かめられた。さらに前処理部のフィルタリングのカットオフ周波数パラメータや NF が考慮する遅り時間ステップのパラメータが識別率に与える影響も明らかになった。

今後は、識別結果の被験者へのフィードバック法などについても検討し、リハビリテーション応用を目指したマン・マシンシステムの構築を行う予定である。

(平成 8 年 10 月 24 日受付、同 9 年 4 月 24 日再受付)

文 献

- D. Graupe, J. Magnussen and A. A. M. Beex : "A Microprocessor System for Multifunctional Control of Upper Limb Prostheses via Myoelectric Signal Identification," IEEE Trans. Autom. Control., AC-23, No. 4, pp. 538-544 (1978)
- S. Lee and G. N. Saridis : "The control of a prosthetic arm by EMG pattern recognition," IEEE Trans. Autom. Control., AC-29, No. 4, pp. 290-302 (1984)
- M. F. Kelly, P. A. Parker and R. N. Scott : "The Application of Neural Networks to Myoelectric Signal Analysis: A preliminary study," IEEE Trans. Biomedical Engineering, Vol. 37, No. 3, pp. 211-230 (1990)
- A. Hiraiwa, K. Shimohara and Y. Tokunaga : "EMG pattern analysis and classification by neural network," IEEE International Conference on Syst., Man and Cybern., p. 1113 (1989)
- 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, pp. 107-114 (1991)
- 辻, 市延, 伊藤, 長町: 「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」, 計測自動制御学会論文集, Vol. 29, No. 10, pp. 1213-1220 (1993)

(7) 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, pp. 465-473 (1992)

(8) D. E. Rumelhart, J. L. McClelland and R. J. Williams : "Learning Internal Representations by Error propagation," in *Parallel Distributed Processing vol. I*, pp318-362, MIT Press (1986)

(9) 福田, 辻, 金子: 「ニューラルネットによる時系列脳波パターンの識別」, 電子情報通信学会論文誌, D-II, Vol. 80, No. 7, pp. 1896-1903 (1997)

(10) J. T. H. Lo : "Synthetic Approach to Optimal Filtering," IEEE Trans. Neural Networks, Vol. 5, No. 5, pp. 803-811 (1994)

(11) M. Zak : "Terminal Attractors for Addressable Memory in Neural Networks," Physics Letters A, Vol. 133, pp. 18-22 (1988)

福田 修



(非会員) 1969年9月30日生。1993年九州工業大学情報工学部機械システム工学科卒業。同年、九州日本電気ソフトウェア株式会社勤務。現在広島大学大学院工学研究科博士課程後期在学中。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。計測自動制御学会、電子情報通信学会などの会員。日本学術振興会特別研究員。

辻 敏夫



(正員) 1959年12月25日生。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、1994年同助教授、現在に至る。この間、1992~3年ジェノバ大学客員研究員。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。計測自動制御学会、日本機械学会、日本ロボット学会、電気学会などの会員。工学博士。

金子 真



(非会員) 1954年1月18日生。81年3月東京大学工学系研究科機械工学専門課程博士課程卒業。同年4月、通産省工業技術院機械技術研究所入所。90年4月、九州工業大学情報工学部助教授。93年10月、広島大学工学部教授、現在に至る。ロボットハンドやアクティブラインセンシングなどの研究に興味を持つ。84年日本機械学会奨励賞、94年日本ロボット学会論文賞、96年計測自動制御学会論文賞。IEEE Trans. on Robotics and Automation, Associate Editor (90-94). IEEE Robotics Magazine, Editorial Member (97-)。工学博士。