

別刷

計測自動制御学会 論文集

年 第 卷 第 号

(P. ~P.)



社團 法人 計測自動制御学会

生 EMG 信号による電動義手の制御

福田 修*・ト 楠**・辻 敏夫**

Control of an Externally Powered Prosthetic Forearm Using Raw-EMG Signals

Osamu FUKUDA*, Nan BU** and Toshio TSUJI**

This paper proposes a new motion discrimination method using raw EMG signals to improve control performance of a prosthetic forearm. This method uses a novel recurrent neural network based on a well developed hidden Markov model. The proposed network can model a time sequence of EMG signals using recurrent connections, and different two processes such as filtering and a pattern discrimination are unified together and realized in a single network. Weight coefficients of the network are regulated by the back-propagation through time algorithm.

In the experiments, five subjects which include two amputees performed control of the prosthetic forearm. We confirmed that the proposed method could cope with time-varying characteristics of EMG signals and could achieve considerably high discrimination accuracy compared with the previous methods. Response of the discrimination result to the input EMG pattern was also improved using the proposed method.

Key Words: Raw EMG signals, prosthetic forearm, recurrent neural network, Hidden Markov model

1. はじめに

交通事故や災害、あるいは埋設された対人地雷などによって腕を失う人々が国内外で後を絶たない。一般的に切断者は、何らかの義手を腕に装着することになるが、そのほとんどは装飾を目的とするものや内部に動力を持たない体内力源型のものであり、アクチュエータを内蔵して能動的に駆動するものは、現状ではほとんど使用されていない。しかしながら、失った腕と同等に機能する能動型の義手を開発できれば、彼らの日常生活においてたいへん意義深いのはいうまでもなく、その開発が期待されている。文献 1), 2) では、最近の電動義手開発の動向とその普及への展望が報告されている。

電動義手のインターフェース信号としては、古くから EMG 信号が着目されており、その識別に関する数多くの研究が試みられてきた^{3)~11)}。切断者の残存筋から計測可能な EMG 信号は、運動意図に関するさまざまな情報を含んでいることから、これらを精度良く識別することができれば、失った腕と近い制御感覚を実現できる可能性がある。

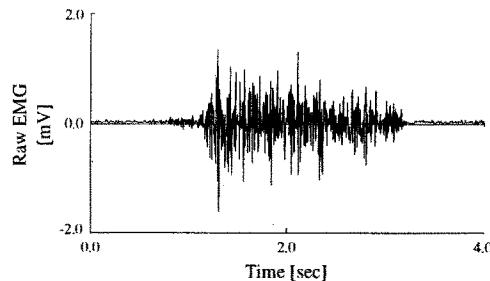


Fig. 1 An example of the raw EMG signal

Fig. 1 に切断者から記録した EMG 信号の生波形を示す。このような EMG 信号を効率よく利用するためには、一般的に以下の 3 つの点に留意しなければならない。

(1) EMG 信号は高周波成分を多く含むため、適切な特徴抽出処理、特に低域通過フィルタによる平滑化処理が必要。

(2) EMG 信号から切断者の運動意思を推定し、制御装置に命令を送るためには、高精度のパターン識別処理が必要。

(3) 個人差や環境の電気的な条件に左右されない頑強な信号処理を実現するためには、システムに高い適応能力が必要。

従来研究では、特に(2), (3)の実現を目的として学習能力を備えたニューラルネット（以下、NN と略記）を利用するところ多かった。たとえば Hiraiwa ら³⁾は、誤差逆伝搬型 NN（以下、BPNN と略記）を利用して EMG 信号の周波数情報

* 独立行政法人産業技術総合研究所人間福祉医工学研究部門
つくば市並木 1-2-1

** 広島大学大学院工学研究科 東広島市鏡山 1-4-1

* National Institute of Advanced Industrial Science and Technology, Institute for Human Science and Biomedical Engineering, Tsukuba

** Graduate school of Engineering, Hiroshima University, Higashi-hiroshima

(Received August 29, 2003)

(Revised September 6, 2004)

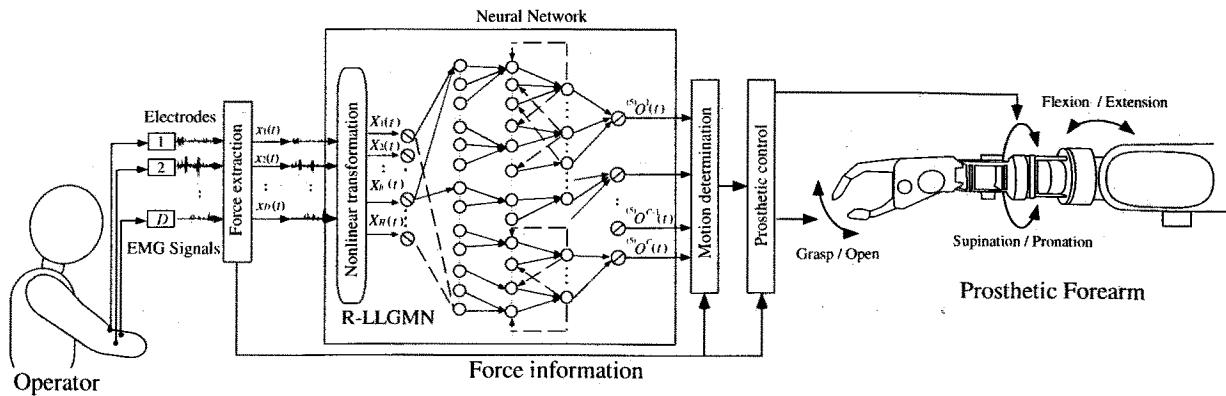


Fig. 2 Structure of the proposed method

から動作識別を実現している。Kelly ら⁴⁾は、ホップフィールド型 NN と BPNN を組み合わせて前腕 4 動作の識別を行なっている。辻ら⁵⁾は、BPNN の出力信号から計算されるエントロピーを利用して、誤識別を回避する方法を提案している。Farry ら⁶⁾は、EMG 信号の周波数スペクトルパターンを識別し、ロボットハンドを遠隔操作する手法を提案している。Huang and Chen⁷⁾は、EMG 信号の積分値、Zero-crossing、分散値などから特徴ベクトルを作成し、BPNN を用いて 8 つの手先動作の識別を行なっている。Yu, Nishikawa ら^{8), 9)}は、BPNN を利用して Gabor 変換した EMG 信号から 10 動作の識別に成功している。また、多自由度電動義手の開発も行なっている。しかしながら、これらの従来研究で利用されている BPNN には、一般的に構造決定が困難、学習がローカルミニマに陥りやすいなどの多くの問題点も指摘されている。

これに対して辻らは、統計構造に基づいたニューラルネットを新たに構築し、それを用いた動作識別法をこれまでに提案してきた^{10)~12)}。たとえば、Log-Linearized Gaussian Mixture Network (以下、LLGMN と略記) は、ネットワークの構造が混合ガウス分布モデルと対数線形モデルに基づいて構成されており、これらのモデルに含まれるパラメータを学習的に推定することができる。さらに、この LLGMN に時系列的つながりを考慮可能なリカレント型の Neural Filter¹³⁾を組み合わせれば、連続動作時などの激しく変動する時系列 EMG 信号についても高精度の識別が実現できる。

しかしながら、一般的に従来のパターン識別法では、識別精度の向上のために EMG 信号の特徴抽出処理やニューラルネットの構造が複雑になる傾向があり、それらに含まれるすべてのパラメータを同時に最適化するのは非常に困難であった。EMG 信号を利用した電動義手が、人腕に近い自然な動作を実現するためには、これらの信号処理をトータルに最適化する新たなパターン識別法を開発する必要がある。

本論文の目的は、生の EMG 信号から動作識別を実現すること、および操作者の EMG 信号発生に対する識別処理の応答特性を向上することにある。この目的を実現するため、本論文では、辻らが提案したリカレントニューラルネットである

Recurrent Log-Linearized Gaussian Mixture Network (以下、R-LLGMN と略記)¹⁴⁾を利用する。R-LLGMN は、動的確率モデルの一つである隠れマルコフモデル（以下、HMM と略記）¹⁵⁾に基づいた構造を有しており、EMG 信号に含まれる時系列特性をこれに従ってモデル化できる。学習には通常的誤差逆伝播アルゴリズム¹⁶⁾が適用可能で、最急降下法による重み係数の調節を行なう。本手法は、従来手法では独立した 2 つのプロセスとして処理されていた EMG 信号の特徴抽出処理とパターン識別処理を 1 つのニューラルネットで実現し、両処理に関するパラメータを同時に最適化する。これにより、連続動作などにともなう変動の激しい EMG 信号に対しても、高い識別精度が実現できる。

以下 2 章では、生 EMG 信号による前腕動作識別について説明する。3 章では切断者による電動動力義手の制御実験を実施する。4 章では本論文のまとめを示す。

2. 生 EMG 信号による前腕動作識別

厳密な意味での「生 EMG 信号」とは、アンプによる増幅やハムフィルタ処理さえも施さないものであり、同じく厳密には、これらの処理は「前処理」に該当すると考えられる。ここでは、本論文における「生 EMG 信号」と「前処理」について定義する。

従来研究の多くでは、特微量抽出処理として、EMG 信号に平均処理や平滑化処理などを施すか^{4), 5)}、一定時間窓内の周波数成分を計算している^{3), 6), 7)}。しかしながらこれらの処理には、フィルタリングや時間窓などに起因する位相遅れの問題や、使用者による意図的なパラメータ決定の問題（カットオフ周波数や窓関数のサイズなど）が生じる。すなわち、より有効で扱いやすい特徴を抽出する対価として、位相遅れなどにともなう情報の損失や、試行錯誤的なパラメータ設定の手間が発生する。そこで本論文では、このような問題を含む特微量抽出処理全般を「前処理」、これらを施さず直接サンプリングした信号を「生 EMG 信号」と定義し議論を進める。

2.1 筋力情報抽出処理

本システムにおける電動義手の制御は、Fig. 2 に示す

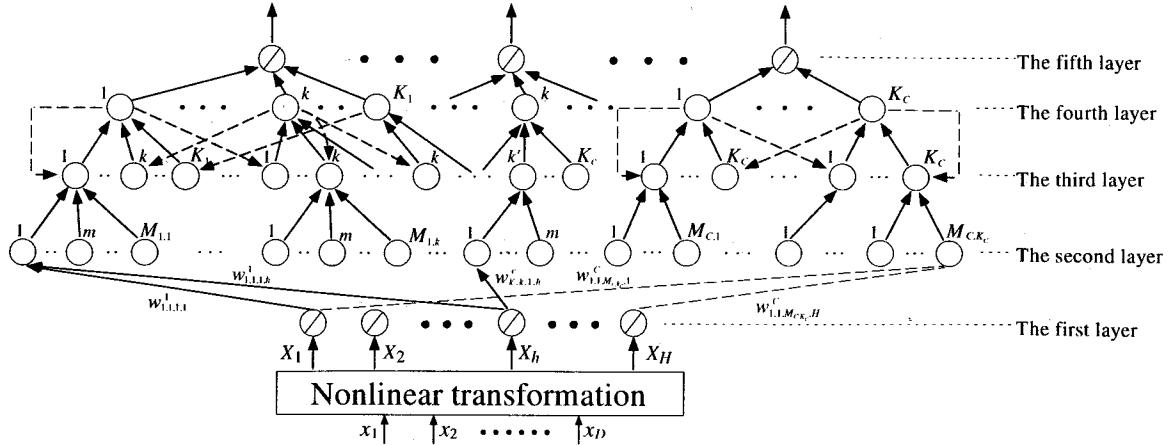


Fig. 3 Structure of R-LLGMN

ように筋力情報抽出処理、ニューラルネット処理、識別判定処理、義手制御処理を経て実現される。まず動作発生のタイミングや駆動トルクを決定するための筋力情報の抽出を行なう。EMG信号をマルチテレメータ(Web5000: (株)日本光電製)にて増幅・低域ろ波(100Hz)し、A/Dボードを介してサンプリング周波数200[Hz]でコンピュータ内部に取り込む。この D チャンネル分のEMG信号を $EMG_d(s)$ ($d = 1, \dots, D$; $s = 1, \dots, S$)とする。ここで s は、サンプルNo.を示し、 S は全データ数を示す。サンプリング周波数を200[Hz]と設定したのは、本システムの推定処理や制御処理に5[msec]程度の時間を要するためであり、これにともなって情報として抽出できない100Hz以上の高周波成分は除去するものとする。ただし、この100[Hz]というタイミングは、人間の運動に比べてほぼ遅れを感じることのないもので、本システムの目的には必要十分である。もちろん、将来的に推定処理の計算速度などが向上すれば、さらに高周波領域での処理を実現できる可能性があり、今後の課題として非常に興味深い。

つぎに、 $EMG_d(s)$ を全波整流し、学習データ長 T_l で移動平均をとることにより、積分EMGレベル $\alpha(s)$ を計算する。

$$\alpha(s) = \frac{1}{D} \sum_{d=1}^D \frac{\overline{EMG}_d(s)}{\overline{EMG}_d^{max}} \quad (1)$$

$$\overline{EMG}_d(s) = \frac{1}{T_l} \sum_{j=0}^{T_l-1} |EMG_d(s-j)| \quad (2)$$

ただし、 T_l は制御時に操作者が位相遅れをほとんど感じない程度の十分短い間隔(100[msec]程度)とする。 \overline{EMG}_d^{max} はあらかじめ計測しておいた最大随意筋収縮時の $EMG_d(s)$ の平均値を示している。ただし、 $s-j < 0$ のときは、 $EMG_d(s-j) = 0$ とする。

2.2 ニューラルネット処理

ニューラルネット処理には、隠れマルコフモデルに基づくリカレントニューラルネットであるR-LLGMN¹⁴⁾を用いる。従来手法の多くでは、EMG信号の特徴抽出処理とパターン

識別処理を独立に実行していたが、R-LLGMNはこれらの両処理を一つのネットワークで同時に実行する。ネットワークは、Fig. 3に示すような5層構造で、第3層と第4層の間にフィードバック結合を有しており、この構造の中に、クラス数 C 、各クラスの状態数 K_c ($c = 1, \dots, C$)の連続型隠れマルコフモデルを含んでいる¹⁵⁾。各状態における出力確率の密度関数は、 $M_{c,k}$ ($c = 1, \dots, C$; $k = 1, \dots, K_c$)個のガウス分布コンポーネントで近似する¹²⁾。

ニューラルネットへの入力ベクトル $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_D(t)]^T$ ($t = 1, \dots, T_l$)には、 $EMG_d(t)$ を $\alpha(T_l)$ で正規化した

$$x_d(t) = \alpha^{-1}(T_l) EMG_d(t) \quad (3)$$

を用いる。ここで、添字 t はサンプルNo.を示す。ただし、この t は、R-LLGMNへの入力について議論する際に用いるものであり、動力義手の制御について議論する際は、前述の添字 s をサンプルNo.として用いる。そして、この入力ベクトルを次式にしたがって非線形変換する。

$$\begin{aligned} \mathbf{X}(t) = & [1, \mathbf{x}(t)^T, x_1(t)^2, x_1(t)x_2(t), \dots, \\ & x_1(t)x_D(t), x_2(t)^2, x_2(t)x_3(t), \dots, \\ & x_2(t)x_D(t), \dots, x_D(t)^2]^T \end{aligned} \quad (4)$$

この変換は、R-LLGMNに導入された隠れマルコフモデルの各状態における事後確率密度関数を、新たな入力ベクトル $\mathbf{X}(t) \in \mathbb{R}^H$ と第1, 2層間の重み係数の線形計算で表現するために行なう¹⁴⁾。なお、(3), (4)式の正規化処理、非線形変換は、使用者が意図的にパラメータなどを調節する必要がなく、また(4)については、導入した隠れマルコフモデルにより必然的に発生する処理であることから、本論文が定義する「前処理」にはあたらないものと考える。

ネットワークの第1層はこの入力ベクトルの次元数 $H = 1 + D(D+3)/2$ にあわせて H 個のユニットから構成される。各ユニットは恒等関数を入出力関数として用い

ており、入出力関係は、

$$(1) I_h(t) = X_h(t) \quad (5)$$

$$(1) O_h(t) = (1) I_h(t) \quad (6)$$

となる。ここで、 $(1) I_h(t)$ と $(1) O_h(t)$ は h 番目のユニットの入出力を表わす。

第2層のユニット $\{c, k, k', m\}$ ($c = 1, \dots, C$; $k, k' = 1, \dots, K_c$; $m = 1, \dots, M_{c,k}$) は、第1層のユニットの出力に重み係数 $w_{k',k,m,h}^c$ を掛け合わせたものを受け取る。第2層の入出力関係は、

$$(2) I_{k',k,m}^c(t) = \sum_{h=1}^H (1) O_h(t) w_{k',k,m,h}^c \quad (7)$$

$$(2) O_{k',k,m}^c(t) = \exp((2) I_{k',k,m}^c(t)) \quad (8)$$

となる。

第3層のユニット $\{c, k, k'\}$ への入力は、第2層のユニット $\{c, k, k', m\}$ ($m = 1, \dots, M_{c,k}$) の出力を統合したものである。また、この入力に1時刻前の第4層の出力を乗じた値が第3層の出力となる。第3層の入出力関係は、

$$(3) I_{k',k}^c(t) = \sum_{m=1}^{M_{c,k}} (2) O_{k',k,m}^c(t) \quad (9)$$

$$(3) O_{k',k}^c(t) = (4) O_{k'}^c(t-1) (3) I_{k',k}^c(t) \quad (10)$$

となる。ただし、初期状態において $(4) O_{k'}^c(0) = 1.0$ とする。

第4層は、第3層のユニット $\{c, k, k'\}$ ($k' = 1, \dots, K_c$) の出力を統合したものを受け取る。入出力関係は、

$$(4) I_k^c(t) = \sum_{k'=1}^{K_c} (3) O_{k',k}^c(t) \quad (11)$$

$$(4) O_k^c(t) = \frac{(4) I_k^c(t)}{\sum_{c'=1}^C \sum_{k'=1}^{K_{c'}} (4) I_{k'}^c(t)} \quad (12)$$

で与えられる。

最後に、第5層のユニット c への入力は、第4層の K_c ユニット $\{c, k\}$ ($k = 1, \dots, K_c$) の出力を統合したものである。入出力関係は、

$$(5) I^c(t) = \sum_{k=1}^{K_c} (4) O_k^c(t) \quad (13)$$

$$(5) O^c(t) = (5) I^c(t) \quad (14)$$

となる。以上、R-LLGMN の構造について説明した。このネットワークは、第1層と第2層の間の重み係数 $w_{k',k,m,h}^c$ を学習的に調節することで、入力パターンに対する各クラスの事後確率を隠れマルコフモデルに基づいて計算することができる。

ニューラルネット処理を実施する前には、学習サンプルデータによる R-LLGMN の学習が必要である。いま、時刻 T_l において、 n 番目の入力ベクトル $x(t)^{(n)}$ に対する教師ベ

クトル $T^{(n)} = (T_1^{(n)}, \dots, T_c^{(n)}, \dots, T_C^{(n)})^T$ ($n = 1, \dots, N$) が与えられる場合について考える。 $T_c^{(n)}$ は観測された事象が c であるときは 1、それ以外は 0 をとり、複数のクラスが同時に 1 になることはない。R-LLGMN は、 C 個のクラスそれぞれに用意された L 個の時系列信号 ($N = L \times C$) を学習サンプルデータとして学習を行なう。学習の評価関数 J は、

$$J = \sum_{n=1}^N J_n = - \sum_{n=1}^N \sum_{c=1}^C T_c^{(n)} \log (5) O^c(T_l)^{(n)} \quad (15)$$

と定義し、これを最小化するように学習を行なう。これは対数尤度を最大化することに相当する。ただし、 $(5) O^c(T_l)^{(n)}$ は入力ベクトル $x(t)^{(n)}$ に対する時刻 T_l での出力を意味している。重み $w_{k',k,m,h}^c$ の修正量 $\Delta w_{k',k,m,h}^c$ は、

$$\Delta w_{k',k,m,h}^c = -\eta \sum_{n=1}^N \frac{\partial J_n}{\partial w_{k',k,m,h}^c} \quad (16)$$

で計算される。 $\eta > 0$ は学習率である。R-LLGMN はリカレント結合を有するため、この計算には通時の誤差逆伝播アルゴリズム¹⁶⁾を用いる。また、本論文ではターミナルラーニング¹²⁾の概念を学習則に取り入れ、指定した有限時間内にニューラルネットの学習を平衡点に収束できるようにした。これにより、使用者が学習の収束を待つ精神的な負担を大幅に軽減することができる。

2.3 識別判定処理

誤識別による不適切な動作は、目的を達成できないばかりか作業中には危険な事故につながる可能性もあり、電動義手の使用を遠ざける大きな要因となってしまう。日常生活においては、複数の動作を連続して実行する場面や、上肢の姿勢が著しく変化する場面なども容易に想像され、そのような際に EMG 信号が不安定になりやすいことから、誤識別を誘発する可能性が心配される。そこで本論文では、このような誤動作を防止するために R-LLGMN が output する事後確率に基づいて次式のエントロピー $H(s)$ を定義し、その値を利用した識別判定処理を行なう⁵⁾。

$$H(s) = - \sum_{c=1}^C (5) O^c(s) \log_2 (5) O^c(s) \quad (17)$$

ここで $(5) O^c(s)$ は、 $(s - T_l + 1, \dots, s)$ の区間のサンプルに基づいて計算する。エントロピーは情報のあいまいさを示す評価値である。そこで、この $H(s)$ をあらかじめ設定したしきい値 H_d と比較し、もし $H(s) < H_d$ であれば出力 $(5) O^c(s)$ ($c = 1, \dots, C$) が最大となるユニットに対応する動作を識別結果とし、逆に $H(s) \geq H_d$ であれば、あいまいな識別として識別を保留することにする。なお、動作発生のタイミングは $\alpha(s)$ (2.1 参照) に基づいて判断する。この値があらかじめ設定した動作発生判定閾値 α_d を越えて、かつ識別が保留にならない場合に動作が発生しているものとみなされる。

2.4 義手制御処理

操作者にとって違和感のない自然で滑らかな義手の動作を実現することは、制御処理において考慮すべき重要な課題である。現在市販されている多くのEMG義手は、識別結果に応じた駆動関節の選択とモータのON/OFF制御のみを実施しているが¹⁷⁾、この方法では義手の動作が人工的・機械的になるだけでなく、僅かな誤識別の際にも、不自然な関節の動作を生じてしまう。

そこで本論文では、制御系に人腕の関節インピーダンスモデルを導入し、EMG信号から抽出した筋力情報 $\alpha(s)$ (2.1 参照)に基づいた関節角の制御を行なう¹¹⁾。このモデルに含まれる関節の粘弾性パラメータやトルクなどは、すべてこの筋力情報を利用してリアルタイムに算出することが可能であり、これらに基づいた制御を実行することで、人腕の運動に近い制御特性が実現できる。また、このインピーダンスモデルは、入力信号に対して一種の低域通過フィルタとして作用するため、僅かな誤識別を生じてしまった際などに、動作を滑らかに修正する効果が期待できる。なお、本処理の詳細に関しては文献¹¹⁾を参照されたい。

3. 前腕動作識別実験

提案手法の有効性を検証するために、EMG信号による電動動力義手の制御実験を行なった。被験者は5名（切断者2名、健常者3名）で、使用電極数は6ch、識別する動作は6動作とした。R-LLGMNのパラメータは、クラス数 $C = 6$ 、各クラスの状態数 $K_1, \dots, K_6 = 1$ 、コンポーネント数 $M_{1,1}, \dots, M_{6,1} = 1$ 、学習データ長 $T_l = 20$ (100[msec]に相当)、学習データ数 $L = 8$ とした。システムの有効性を示すには、多くの切断者で検証することが望ましいが、著者らの周辺でそれを実現することが難しいため健常者を含めた構成とした。ただし、本論文の主な目的は、生EMG信号による識別処理の実現、および識別応答特性の向上を示すことにある、以降の実験結果はこの目的を達するのに十分であると考える。R-LLGMNのパラメータは、理論的には値が大きいほど複雑なモデルを表現可能となるが、実際には計算時間の増大やローカルミニマ問題などを発生することから必要最小限にすることが望ましい。本論文ではこの点を踏まえ、予備実験の結果から試行錯誤的に設定した。

3.1 識別精度

Fig.4に実験結果の一例を示す。被験者はA(男性、44才)で、約3年前に事故のため手首から3cm程の部位で右前腕部を切断しており、日常生活においては装飾義手を使用している。実験前には2日間、各日とも約2時間の訓練を行なった。電極は切断した右前腕部に5ch、右上腕部に1chを装着した。Fig.4は、上から義手の動作写真(握り、開き、背屈、掌屈、回内、回外)、EMG信号の生波形、積分EMGレベル $\alpha(s)$ 、R-LLGMNの出力から計算したエントロピー $H(s)$ 、識別結果を表わしている。図中グレーで示すエリアは、積分EMGレベル $\alpha(s)$ が設定した閾値を越えないため

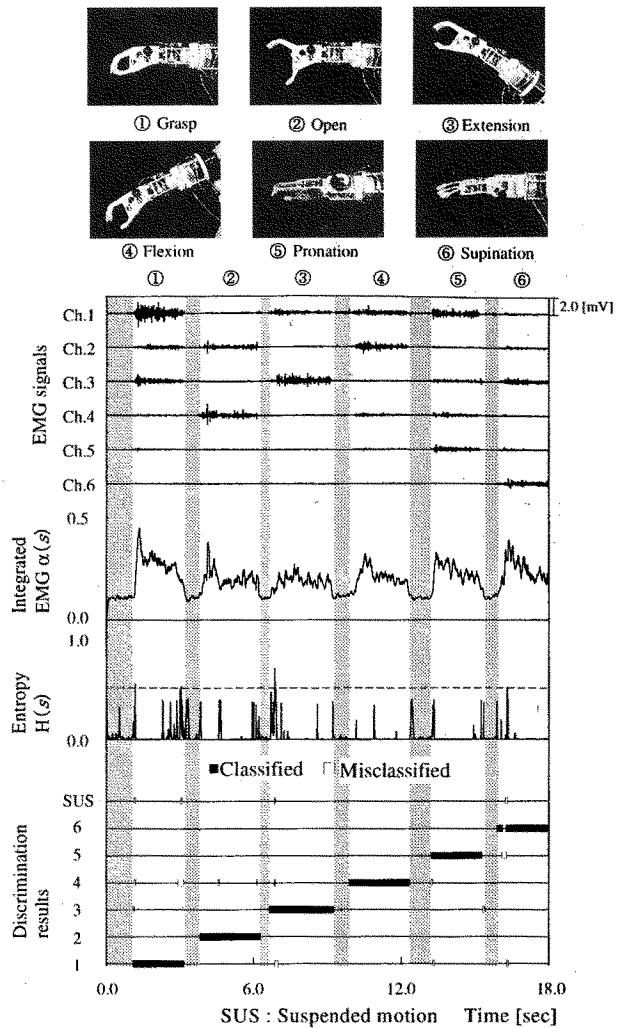


Fig.4 An example of the discrimination result for non-stationary EMG signal

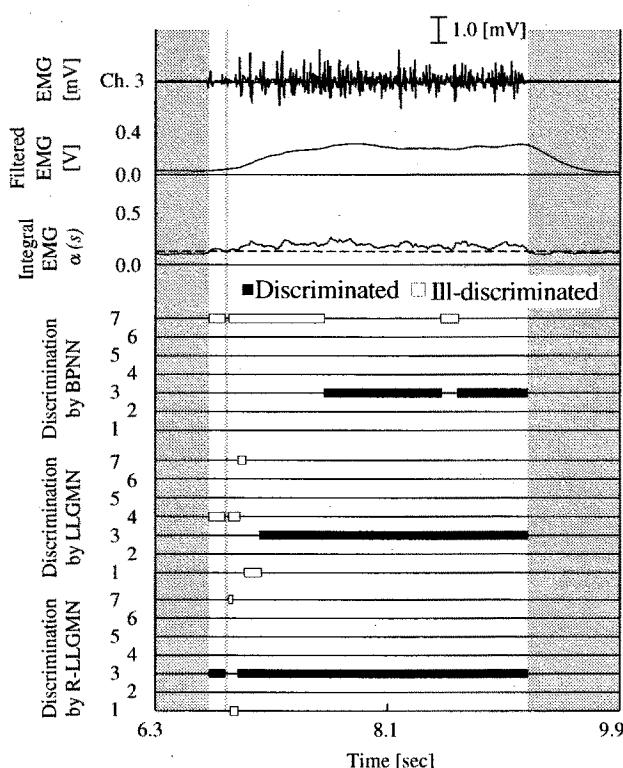
に動作なしと判別されたことを示す。写真の番号は識別結果の番号と一致している。図より、若干のばらつきが見られるものの比較的安定した識別結果が得られていることがわかる。エントロピーも比較的低く、識別率はトータルで95.5%であった。なお、ほかの被験者の結果についても、誤識別の数に若干の個人差が見られるものの、応答性などの一般的な傾向には差がなかった。

つぎに、5人の被験者(A, B: 切断者, C, D, E: 健常者)に対して同様の実験を行なった結果を示す。比較のために5種類の識別法を用いた。用いた方法は、整流平滑EMG信号を入力信号とするBPNN, LLGMN¹²⁾, Elman's network¹⁸⁾, R-LLGMN, およびEMG信号の生信号を入力とする提案手法である。提案手法と同様の入力をBPNN, LLGMN, Elman's networkで識別する方法も試みたが、学習・識別がきわめて困難となり、十分な結果は得られなかつた。EMG信号の整流平滑には、デジタルローパスフィルタ(特性: Butterworth, 次数: 2, カットオフ周波数: 1.0[Hz])を用いた¹³⁾。LLGMNのコンポーネント数は、R-LLGMN

Table 1 Discrimination results for five subjects

Type of the methods		BPNN (Filtered EMG)	LLGMN (Filtered EMG)	Elman (Filtered EMG)	R-LLGMN (Filtered EMG)	Proposed method
Subject A (Amputee)	DR	66.1	89.8	89.4	96.1	93.8
	SD	14.0	0.0	6.3	0.0	0.0
Subject B (Amputee)	DR	70.1	89.3	88.8	92.5	91.2
	SD	10.8	0.0	2.0	0.0	1.3
Subject C (Normal)	DR	80.5	82.9	83.8	94.2	94.1
	SD	8.1	0.0	1.1	0.0	0.4
Subject D (Normal)	DR	78.9	88.3	73.7	97.4	90.4
	SD	4.1	0.0	0.8	0.0	0.9
Subject E (Normal)	DR	75.8	85.9	74.9	90.7	91.0
	SD	4.5	0.0	5.6	0.0	1.8
Total	DR	74.3	87.2	83.7	94.2	92.1
	SD	8.3	0.0	2.9	0.0	0.9

DR : Discrimination rate [%], SD : Standard deviation [%]



Motion (c) : Grasp (1), Open (2), Extention (3), Flexion (4), Pronation (5), Supination (6), Suspended motion (7)

Fig. 5 Changes of the discrimination results by three types of neural networks

と同数の1に設定し、学習データ数を180(各動作30)とした。また、BPNNは入出力層のユニットが6個、中間層が2層でいずれもユニット数が10個とした。Elman's networkは3層で、入出力層のユニットが6個、中間層のユニット数は150個とした。BPNNとElman's networkのパラメータは、識別精度が高くなるように試行錯誤的に設定した。EMG信号時系列の識別区間は、 $\alpha(s)$ に基づいた区間(Fig. 4参照)とし、全手法で共通とした。なおエントロピーに基づく識別保留は実施しなかった。

Table 1に結果を示す。表中の各値は、10通りの初期重み乱数を使って計算した識別率の平均値と標準偏差である。この表より、整流平滑EMG信号を入力とする場合は位相遅れのために識別精度が低下することがわかる。特にBPNNは、識別精度が低い。これは、識別開始時のEMG信号の立ち上がりに入力パターンの変化が比較的大きいためと推察される。LLGMNやElman's networkは、内包した統計モデルやリカレント結合により識別精度が多少向上しているが、十分な識別精度には至っていない。Elman's networkの場合は、標準偏差も大きい。これに対し、R-LLGMNはEMG信号が整流平滑した場合と生の場合のいずれの場合においても、比較的高い識別率を達成している。R-LLGMNの結果では、整流平滑EMG信号を入力としたほうが識別精度が高くなっているが、動作開始に対する識別処理の応答性は、生EMG信号を利用するほうが優れている点を付記しておく。つまり、平滑化によるパターンの安定化と識別処理の応答性には、トレードオフの関係がある。ただし、義手制御処理に導入したインピーダンスモデルは、一種の低域通過フィルタとして作用するため、生EMG信号の識別で僅かな誤識別を生じた場合でも、動作をある程度滑らかに維持することが可能である。したがって、結果的には本手法により応答特性を優先させたほうがシステムの操作性は向上する傾向がある。Table 1において、LLGMNやR-LLGMNの標準偏差が0.0となっている欄では、識別結果が10試行とも全く同じであった。著者らが提案したLLGMNやR-LLGMNは、混合ガウス分布モデルや隠れマルコフモデルを導入したことにより、異なる学習の初期重み乱数に対してもほぼ同じ解に収束する。

なお、従来手法においてもセンサ数の増加や周波数情報の利用で、ある程度の精度向上が見込まれると考えられるが、今回は検討しなかった。これはわれわれの研究グループが、これまでニューラルネットの高度化による識別能力向上を主たるテーマとし、前処理については、実用化コストを下げるために安価なハードウェアを利用して経緯からである。もちろん、周波数解析を行なう場合でも、窓関数のサイズにと

Table 2 Discrimination results for five subjects

Type of the methods		BPNN	LLGMN	R-LLGMN
Subject A (Amputee)	DR	30.3	57.6	89.4
	SD	27.3	45.9	21.6
Subject B (Amputee)	DR	67.6	68.2	77.1
	SD	29.5	36.9	35.3
Subject C (Normal)	DR	52.8	58.3	91.3
	SD	51.5	51.5	17.5
Subject D (Normal)	DR	48.7	50.0	80.7
	SD	41.5	52.2	34.1
Subject E (Normal)	DR	55.6	58.3	86.7
	SD	49.4	51.5	25.3
Total	DR	51.0	58.5	85.0
	SD	39.9	47.6	26.8

DR : Discrimination rate [%], SD : Standard deviation [%]

もうう時間遅れや、試行錯誤的なパラメータ設定の問題は残るため、処理の一括化や高い識別応答性という観点から本手法の有効性は非常に高いと考える。

3.2 応答性

つぎに、入力信号に対する識別の応答性について解析した。Fig. 5は、Fig. 4の6.3[sec]~9.9[sec]までの信号を拡大した図である。上から、EMG信号の生波形(チャンネル3)、全波整流したEMG信号にデジタルローパスフィルタ(特性: Butterworth、次数: 2、カットオフ周波数: 1.0[Hz])を施した整流平滑EMG信号、積分EMGレベル $\alpha(s)$ 、整流平滑EMG信号を入力としたBPNN、LLGMNの識別結果、生のEMG信号を入力としたR-LLGMNの識別結果を表わしている。図中グレーで示すエリアは、積分EMGレベル $\alpha(s)$ が設定した閾値を越えないために動作なしと判別されたことを示す。各ネットワークのパラメータは、Table 1の実験と同様に設定した。動作は背屈で、チャンネル3はこの動作時に最もEMGが発生したチャンネルである。図より、整流平滑EMG信号を入力としたBPNNやLLGMNは、識別開始に時間遅れが生じており、誤識別も多いことがわかる。一方、生のEMG信号を入力とした本手法の場合は、EMG信号発生とほぼ同時刻から正しい識別が行なわれており、位相遅れがきわめて小さいことがわかる。

つぎに、連続動作における動作開始・終了時の識別精度に着目した。5人の被験者(A, B: 切断者, C, D, E: 健常者)に対してFig. 4と同様な実験を行ない、各動作の開始後100[ms]と終了前100[ms]のEMG信号に対する識別率を算出した。比較のために整流平滑EMG信号を入力信号としたBPNN、LLGMN、提案する手法の3種類について実験した。Table 2に結果を示す。表中の各値は、10通りの初期重み乱数を使って計算した識別率の平均値と標準偏差である。表より、R-LLGMNが最も高い識別率を示していることがわかる。提案手法は、操作者が発生するEMG信号に対して応答良く識別処理を実行できることがわかる。

4. まとめ

本論文では、EMG信号により制御される電動動力義手の

操作性の改善を目的として、生のEMG信号を入力とする新しい動作識別法を提案した。この方法は、動的確率モデルに基づく新しいリカレントニューラルネットR-LLGMNを利用しており、通常は2つの独立したプロセスとして処理されるEMG信号の特徴抽出処理とパターン識別処理を1つの信号処理として統合することができる。提案手法の有効性・妥当性を検証するために、連続動作時のEMG信号について識別実験を行なった。実験の結果からR-LLGMNは、生のEMG信号からでも十分な識別精度を実現できることが明らかになった。また、識別対象の入力信号にフィルタリングなどによる位相遅れが発生しないため、操作者のEMG信号発生に対する識別の応答性が、従来法に比べて優れていることも確認できた。なお、適応的な電動義手を評価する際には、システムへの習熟時間も考慮すべき課題と考えられるが、この時間は識別手法だけに影響されるものではなく、義手の制御特性や、学習フェーズにおける教師信号の抽出手順、あるいは使用者の能力や慣れなどさまざまな要因が複雑に絡んでいると考えられるため、今回は検討しなかった。これについての議論は改めて実施したいと考えている。

今後は、本手法をさまざまな生体信号のパターン識別に応用するために、各信号に適した特徴パターン抽出法や信号処理法を検討する予定である。なお、本研究の一部はNEDO産業技術研究助成事業(01A17001b)の助成を受けて実施したものでここに改めて謝意を表します。

参考文献

- 1) 東原孝典: 今日の筋電義手, 日本義肢装具学会誌, 17-4, 228/233 (2001)
- 2) 川村次郎: 筋電義手の普及への展望, 日本義肢装具学会誌, 17-4, 257/261 (2001)
- 3) A. Hiraiwa, K. Shimohara and Y. Tokunaga: EMG pattern analysis and classification by neural network, *Proc. of IEEE International Conference on Syst., Man and Cybern.*, 1113/1115 (1989)
- 4) M. F. Kelly, P. A. Parker and R. N. Scott: The Application of Neural Networks to Myoelectric Signal Analysis, *A Preliminary Study, IEEE Transactions on Biomedical Engineering*, 37-3, 221/230 (1990)
- 5) 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, 29-10, 1213/1220 (1993)
- 6) K. A. Farry, I. D. Walker and R. G. Baraniuk: Myoelectric Teleoperation of a Complex Robotic Hand, *IEEE Transactions on Robotics and Automation*, 12-5, 775/787 (1996)
- 7) H.-P. Huang and C.-Y. Chen: Development of a Myoelectric Discrimination System for a Multi-Degree Prosthetic Hand, *Proceedings of the 1999 IEEE International Conference on Robotics and Automation*, 2392/2397 (1999)
- 8) D. Nishikawa, W. Yu, H. Yokoi and Y. Kakazu: EMG Prosthetic Hand Controller Discriminating Ten Motions using Real-time Learning Method, *Proceedings of the 1999 IEEE/RSJ International Conference on Intelligent Robotics and Systems*, 1592/1597 (1999)
- 9) W. Yu, D. Nishikawa, Y. Ishikawa, H. Yokoi and Y. Kakazu: Multifunctional Electrical Prosthetic Hand - Development of Tendon-driven Mechanism and Controller -, *Journal of Robotics and Mechatronics*, 14-6,

557/564 2002

- 10) 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C, **112-C-8**, 465/473 (1992)
- 11) 辻, 重吉, 福田, 金子: 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編, **66**-648, 294/301 (2000)
- 12) T. Tsuji, O. Fukuda, H. Ichinobe and M. Kaneko: A log-linearized Gaussian mixture network and its application to EEG pattern classification, *IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews*, **29-1**, 60/72 (1999)
- 13) 福田, 辻, 金子: ニューラルネットによる連続動作EMGパターンの識別, 電気学会論文誌C, **117-C-10**, 1490/1497 (1997)
- 14) T. Tsuji, N. Bu, O. Fukuda and M. Kaneko: A Recurrent Log-Linearized Gaussian Mixture Network, *IEEE Trans. on Neural Networks*, **14-2**, 304/316 (2003)
- 15) L.E. Baum and T. Petrie: Statistical inference for probabilistic function of finite state Markov chains, *Ann. Math. Stat.*, **37-6**, 1554/1563 (1966)
- 16) P.J. Werbos: Backpropagation through time: what it does and how to do it, *Proceedings of the IEEE*, **78-10**, 1550/1560 (1990)
- 17) M. Näder: The artificial substitution of missing hands with myoelectrical prosthesis, *Clin Orth Reha Res*, **258**, 9/17 (1990)
- 18) J. L. ELMAN: Finding Structure in Time, *COGNITIVE SCIENCE*, **14**, 179/211 (1990)

[著者紹介]

福田 修 (正会員)



2000年広島大学大学院工学研究科博士課程後期修了。97年4月~99年3月の期間、日本学術振興会特別研究員(DC1)、2000年通商産業省工業技術院機械技術研究所入所、2001年独立行政法人産業技術総合研究所へ転任。現在に至る。博士(工学)、ニューラルネット、ヒューマンインターフェース、電動動力義手などの研究に従事。日本機械学会、日本人間工学会、電子情報通信学会、日本ロボット学会などの会員。

ト 楠



2001年中国大連理工大学大学院機械工学専攻博士前期課程修了。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、パターン識別、生体信号解析、ニューロチップなど的研究に従事。IEEE学生会員。

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。94年同助教授、2002年同大学大学院工学研究科教授、現在に至る。工学博士。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。IEEE、日本人間工学会、バイオメカニズム学会、日本機械学会、電気学会、電子情報通信学会などの会員。