

統計的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

正員 辻 敏夫 (広島大)
非会員 森 大 一 郎 (広島大)
正員 伊 藤 宏 司 (豊橋技科大)

Motion Discrimination Method from EMG Signals Using Statistically Structured Neural Networks

Toshio Tsuji, Member, Daiichiro Mori, Non-member (Hiroshima University), Koji Ito, Member
(Toyohashi University of Technology)

The present paper proposes a method to estimate the motion intended by a human operator from his EMG signals using the statistically structured neural network. EMG signals gradually appear at the beginning of the motion and begin to vanish at the end of the motion. Therefore they should be regarded as non-stationary signals and only weak assumptions are made about the probability density functions. In order to classify such non-stationary signals, the neural network presented here is statistically structured using a Gaussian mixture model which can approximate an unknown probability density function by a finite mixture of multivariate Gaussian component densities. The experimental results for non-stationary EMG signals show that the network can learn the unknown densities of the EMG signals and it can discriminate six motions of forearm and hand based on Bayesian rule from unlearned EMG patterns with the accuracy above 90%.

キーワード：ニューラルネット，EMG，動作識別，ベイズ識別，Gaussian Mixture モデル

1. ま え が き

我々の四肢の運動では、動作によって活動する筋やその収縮パターンが変化する。従って、運動中に発生するEMG(表面筋電位)パターンの特徴から、逆に、人間の意図している動作を推定することができれば、仮想現実空間やロボットのテレオペレーションなどの分野において、EMGは操作者の運動意志を讀取る有効な手段となり得る。特に、これらの分野で動作情報採取に用いられているデータグローブなどに比較して、EMG採取用の電極は小型であることから、EMGは、ヒューマンインタフェースの手段として、最近、注目を集めている信号源である⁽¹⁾。

これまでも、このようなEMG信号を用いて、義肢などの操作信号を得るための研究が幾つか報告され

ている⁽²⁾⁻⁽⁵⁾。操作者の動作とEMGパターンの関係は、脊髄反射系、筋の種類、付着位置、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。ところが、従来提案されている方法のほとんどは、EMG信号を線形モデル(例えば、ARモデル⁽²⁾⁽⁵⁾や判別関数⁽³⁾など)に当てはめて動作を識別するという方法が採用されている。そこで、本論文では、ニューラルネットを用いて学習的に動作を推定する方法について検討する。

ニューラルネットによるEMGパターンの動作識別法として、これまでに誤差逆伝搬型ニューラルネットによる方法が報告されている⁽¹⁾⁽⁶⁾⁽⁷⁾。誤差逆伝搬型ニューラルネットは、非線形写像を獲得できる学習則をもつことから、人間の運動意志とEMGとの関係を表現できる可能性がある。しかしながら、誤差逆伝搬型

ニューラルネットは、その構造が一樣であるため、例えば、対象とする動作数が増加したり、非定常性を含んだEMGや同時に複数の動作を行ったEMGを識別する場合など、画像の複雑さが増せば、それに応じて必要な教師サンプル数、学習時間、ネットワークの規模が増大してしまう。

最近、誤差逆伝搬型ニューラルネットのもつこの問題を解消するため、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が注目されている。本論文では、動作識別を統計的なパターン識別問題としてとらえ、EMGの統計的特性をニューラルネットに組み込むことを考える。統計的な構造をもつニューラルネットとしては、Kochらの緩和型ニューラルネット⁽⁸⁾や土屋らの確率場のベイズ推定を行うニューラルネット⁽⁹⁾がある。例えば土屋らは、特徴空間における母集団に対して局所コーシー分布を仮定し、事後確率のゆわ度を最大にするように動作するニューラルネットを構成している⁽⁹⁾。このように通常、母集団に、ある確率分布を仮定して問題を解くことが多い。しかし、学習対象によっては、特徴空間において母集団を完全に記述する確率分布を見いだすことが困難な場合がある。

そこで本論文では、母集団の確率分布に Gaussian Mixture モデル⁽¹⁰⁾を仮定する。Gaussian Mixture モデルでは、ガウス分布に従う有限個のコンポーネントを用い、母集団の確率分布を各コンポーネントの分布の線形和で表現する。Perlovskyら⁽¹¹⁾は、この Gaussian Mixture モデルにおける最ゆう推定法をネットワークになぞらえて、繰返しの各コンポーネントの分布パラメータを求める方法を示している。Traven⁽¹²⁾や Specht⁽¹³⁾もほぼ同等な手続きを階層ネットワークによる更新ルールによって解いている。本論文では、これらの研究を踏まえて、EMGから動作識別を行うニューラルネットの構築を目指す。

以下、第2章では Gaussian Mixture におけるベ

イズ識別とそのニューラルネットによる表現について述べる。第3章では、第2章に基づいたEMG動作識別法を示し、第4章で、本手法の動作識別能力を評価する。最後に、第5章では、本手法が強い非定常性を示すEMGに対しても有効であることを明らかにする。

2. 統計構造を組み込んだニューラルネット

〈2・1〉 Mixture モデルにおけるベイズ識別

Mixture モデルでは、ある特定の確率分布を有する有限個のコンポーネントを用いて、母集団の確率分布を表現する。このとき、各コンポーネントのパラメータが推定できれば、母集団の分布を近似的に推定できたことになる。特に、各コンポーネントにガウス分布が用いられる場合、このモデルを Gaussian Mixture モデルと呼ぶ。

いま、 d 次元の特徴ベクトル $X \in R^d$ を K 個のクラスに識別する問題を考えよう。よく知られているように、識別に伴う損失を最小にするためには、ベイズ決定ルールを用いればよい⁽¹⁰⁾。

$$\text{decide } k \text{ if } p(k|X) > p(l|X) \dots\dots (1)$$

ただし、 $k, l=1, 2, \dots, K$, $l \neq k$ で、 $p(k|X)$ は事後識別確率である。各クラス k が M 個のコンポーネントから構成されていると仮定すると

$$p(k|X) = \sum_{m=1}^M p(k, m|X) \dots\dots (2)$$

である。ベイズの定理を用いて、 $p(k, m|X)$ は、

$$p(k, m|X) = \frac{p(k, m)p(X|k, m)}{p(X)} \dots\dots (3)$$

となる。ここで、 X の密度関数 $p(X)$ は、

$$p(X) = \sum_{k=1}^K \sum_{m=1}^M p(k, m)p(X|k, m) \dots\dots (4)$$

で与えられる。ただし、 $p(X|k, m)$ は各コンポーネントの確率密度関数である。事前確率 $p(k, m)$ を α_{km} と書き、 θ_{km} をコンポーネント km の確率密度関数のパラメータとして、 $p(X|k, m)$ を $\psi(X, \theta_{km})$ と書くと、




図1 統計的構造を組み込んだニューラルネットによる動作識別法

Fig. 1. A motion discrimination method using the statistically structured neural network.

(3)式は,

$$p(k, m|X) = \frac{\alpha_{km} \Psi(X, \theta_{km})}{\sum_{k'=1}^K \sum_{m'=1}^M \alpha_{k'm'} \Psi(X, \theta_{k'm'})} \dots (5)$$

となる。従って、パラメータ α_{km}, θ_{km} を各コンポーネントについて求めることができれば、(1), (2), (5)式を用いて特徴ベクトル X の識別が可能となる。

〈2・2〉 ネットワークの構成 (2), (5)式の後識別確率の計算は、図1のニューラルネット部に示す3層の階層ニューラルネットに展開することができる。

第1層は $K \times M$ 個のユニットからなり、各コンポーネントの確率密度関数に従って、このネットワークへの入力である特徴 X のクラス k , コンポーネント m のもとでの条件つき確率を出力する。ここで、各コンポーネントの確率密度関数に、平均 $M_{km} \in R^d$, X の各要素が独立で等分散 σ_{km}^2 をもつ d 次元ガウス分布を仮定すると、第1層の入出力関係は、

$$o_{ij}^{(1)} = (2\pi)^{-d/2} \sigma_{ij}^{-d} \times \exp\left[-\frac{1}{2\sigma_{ij}^2} (X - M_{ij})^T (X - M_{ij})\right] \dots (6)$$

と表すことができる。ここで、 $i=1, 2, \dots, K, j=1, 2, \dots, M$ で、 $o_{ij}^{(1)}$ は、第1層のユニット ij の出力を表す。

第2層のユニットは、第1層の出力を重み係数 α_{km} を介して受取り、(5)式に従って、 X のもとでのクラス k , コンポーネント m の事後確率を計算する。

$$o_i^{(2)} = \frac{\alpha_{ij} o_{ij}^{(1)}}{\sum_{k=1}^K \sum_{m=1}^M \alpha_{km} o_{km}^{(1)}} \dots (7)$$

ただし、 $i=1, 2, \dots, K, j=1, 2, \dots, M$ である。また、第3層のユニットは線形ユニットで、(2)式に従い、 X のもとでのクラス k の事後識別確率を計算する。

$$o_i^{(3)} = \sum_{m=1}^M o_{im}^{(2)} \dots (8)$$

従って、ネットワークのパラメータ $\alpha_{km}, M_{km}, \sigma_{km}$ を学習的に獲得できれば、特徴 X の K 個のクラスへの識別が可能になる。

〈2・3〉 ネットワークの学習則 ネットワークは、 N 個の観測サンプル $X_n (n=1, \dots, N)$ をもとに学習を行う。

まず、与えられた観測サンプルに対して、最尤法を用いてパラメータ $\alpha_{km}, M_{km}, \sigma_{km}$ を求めることを考えよう。すなわち、サンプル全体の対数尤度

$$L(\alpha_{km}, M_{km}, \sigma_{km}) = \sum_{n=1}^N \log p(X_n) \dots (9)$$

を制約条件,

$$\sum_{k=1}^K \sum_{m=1}^M \alpha_{km} = 1, \alpha_{km} \geq 0 \dots (10)$$

のもとで最大にするようなパラメータ $\alpha_{km}, M_{km}, \sigma_{km}$ を求めるのである。

それぞれのパラメータの最尤推定量は、よく知られているように、

$$\hat{\alpha}_{km} = \frac{1}{N} \sum_{n=1}^N W_{nkm} \dots (11)$$

$$\hat{M}_{km} = \sum_{n=1}^N \frac{W_{nkm} X_n}{N_{km}} \dots (12)$$

$$\hat{\sigma}_{km}^2 = \frac{1}{d} \sum_{n=1}^N \frac{W_{nkm} (X_n - \hat{M}_{km})^T (X_n - \hat{M}_{km})}{N_{km}} \dots (13)$$

$$N_{km} = \sum_{n=1}^N W_{nkm} \dots (14)$$

で与えられる⁽¹⁴⁾。ただし、 $W_{nkm} \equiv \hat{p}(k, m|X_n)$ である。従って、 W_{nkm} の初期値 $W_{nkm}^{(0)}$ が与えられれば、(11)~(14)式の手続きを繰返し適用すればよい。

この繰返しアルゴリズムは、一種の教師なし学習とみなすことができる⁽¹¹⁾。学習の収束判定には、例えば、事後識別確率の Bhattacharyya 距離⁽¹⁵⁾

$$B = \sum_{n,k,m} (\sqrt{W_{nkm}^{(t)}} - \sqrt{W_{nkm}^{(t-1)}})^2 \dots (15)$$

を用いればよい。ただし、 t は学習回数を表す。この距離 B が ϵ 以下となった時点で学習を終了すれば、ネットワークの動作に必要なパラメータ $\hat{\alpha}_{km}, \hat{M}_{km}, \hat{\sigma}_{km}$ がネットワーク内に獲得されたことになる。

問題は、観測サンプル X_n に与えられるクラス k , コンポーネント m への割当てに関する知識 (教師信号) を上記の教師なし学習に組み込む方法である。本論文では、この教師信号が、事後識別確率 $p_r(k, m|X_n)$ として与えられる場合を想定し、事後識別確率の誤差

$$J = \frac{1}{2} \sum_{n,k,m} \{W_{nkm} - p_r(k, m|X_n)\}^2 \dots (16)$$

を定義する。このとき、教師信号を用いて各サンプルの事後識別確率 W_{nkm} を、誤差 J の最急降下方向

$$\Delta W_{nkm} = -\eta \{W_{nkm} - p_r(k, m|X_n)\} \dots (17)$$

に修正する。ここで、 η は $0 \leq \eta \leq 1$ の学習定数で、これによってゆう度最大と誤差最小の度合いが調節されることになる。例えば、 $\eta=0$ のときは、教師なし学習に等しく、 η が大きくなるにつれて(16)式の教師信号の影響が大きくなる。適切な η は、観測サンプルに依存する。この学習定数 η の選び方については、〈4・3〉および〈5・2〉節で議論する。

(17)式を用いると、教師信号はすべてのサンプルに対して与えられる必要はなく、一部のサンプルについ

てのみ与えることもできる。また、クラスへの割当てに関する教師信号 $p_T(k|X_n)$ については、

$$W_{nkm} = p(k|X_n)p(m|k, X_n) \dots\dots\dots (18)$$

と分解して、同様に修正すればよい。

以上、Mixture モデルに基づくパターン識別法とそのニューラルネットによる実現法について述べた。この方法は、教師信号の有無に応じた最適なパターン識別を学習的に実現することができる。また、複数のコンポーネントを用いれば、任意の母集団の確率分布を近似的に表現できるため、母集団の分布に関する事前知識を必要としない。次章では、この方法に基づいた EMG 動作識別法を示す。

3. EMG 動作識別法

図 1 に本研究で提案する動作識別法の概要を示す。操作者に取付けた L 対の電極から採取した EMG 信号 $y(t) \in R^L$ を整流平滑部、ニューラルネット部で順に処理し、ニューラルネット部の出力値により動作識別を行う。以下、各部について説明する。

〈3・1〉 整流平滑部 L 対の電極から採取した EMG 信号 $y(t) \in R^L$ を全波整流し、カットオフ周波数 1 Hz の一次バターフースフィルタで平滑化する。そして、この整流平滑 EMG を等間隔でサンプリングする。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、

$$x_i = \frac{y_i}{\sum_{i=1}^L y_i} \dots\dots\dots (19)$$

として規格化を行う。ただし、 y_i はサンプリングした整流平滑 EMG の第 i 要素を表す。そして、 x_i ($i=1, 2, \dots, L$) のうち、一次独立な $L-1$ 個の要素により整流平滑 EMG パターン $x=(x_1, x_2, \dots, x_{L-1})^T$ を構成し、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への入力としては、EMG パターンを構成する各要素が必ずしも一次独立である必要はないが、本論文では冗長な入力パターンが識別に与える影響を除外するため、 $d=L-1$ として入力パターンを構成することにする。

〈3・2〉 ニューラルネット部 ニューラルネット部は、整流平滑 EMG パターン x のもとでの、動作 i の事後識別確率を計算する。

電極装着後、まず、操作者に対象とする K 種類の動作を行わせ、各動作 p パターン、すなわち $N=K \times p$ 個の学習用データを用いて、ニューラルネット部を学習する。事後識別確率 W_{nkm} ($n=1, 2, \dots, N$: $k=1, 2, \dots, K$: $m=1, 2, \dots, M$) の初期値には

$0 < W_{nkm}^{(0)} < 1$ の一様乱数を、また教師信号には、

$$p_T(k|x_n) = \begin{cases} 1.0 & (\text{対応する動作}) \\ 0.0 & (\text{それ以外}) \end{cases} \dots\dots\dots (20)$$

を用いる。これによって動作識別に必要なパラメータがネットワーク内に獲得されることになる。なお、このニューラルネット部の学習は、操作者、電極位置ごとに行う必要がある。

〈3・3〉 動作決定部 動作決定部では、(1)式のベイズ決定ルールに基づき、推定動作を決定する。ニューラルネット部の出力 $o_i^{(3)}$ ($i=1, 2, \dots, K$) は、入力された EMG パターン x が動作 i に属する確率を表している。そこで、ある一つの動作 k に対して、 $o_k^{(3)}$ が a 以上で、かつ他のすべての動作 j に対して $o_j^{(3)}$ が b 以下のとき、 a 以上の確率を与えた動作 k を識別動作とする。ただし、 $0 \leq b < a \leq 1$ である。そして、この条件を満たさない出力が得られたときには、識別保留とする。この決定ルールは(1)式のベイズ決定ルールより厳しい条件である。このように識別保留を導入することにより、曖昧な識別を防止でき、また操作者が対象とする K 個以外の動作を行った場合にも対応することが可能となる。

以上、本研究で提案する動作識別法について述べた。以下では、動作識別実験を行い、本手法の動作識別能力を検討する。

4. 動作識別能力の評価

〈4・1〉 実験条件 対象とする動作は、手首の掌屈、背屈、回内、回外、手の握り、開きの 6 動作で、被験者の肘関節から約 7 cm の前腕部に乾式表面電極(今仙技術研究所製)を 4 個取付けた。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する。学習用データは被験者に識別対象の各動作を 1 回ずつ行わせ、各動作 2 秒間のほぼ定常な EMG を採取することによって得る。そして、整流平滑後の 2 秒間の EMG を等間隔にサンプリングし、各動作 10 個の整流平滑 EMG パターン $x_n \in R^3$ ($n=1, 2, \dots, 60$) を抽出した。この 6 動作 \times 10 個のデータを学習用に用いた。また、学習用データとは別に、各動作について 100 試行の整流平滑 EMG を採取し(未学習データ)、動作識別に用いた。なお被験者は、健康者 2 名、切断者 1 名の計 3 名である。

〈4・2〉 EMG パターンのクラスタリング まず、EMG パターンの母集団の確率分布を近似するのに必要な総コンポーネント数 ($K'=K \times M$) を推定するため、教師なし学習を用いて EMG パターンのクラスタ

リングを行った。クラスタリングに用いたデータは、健常者から採取した学習用データ（6動作×10個）である。対象動作数は6であるが、それ以上のコンポーネント数は必要ないであろうか。教師なし学習の場合には、観測サンプルを各クラス、コンポーネントに割当てるための外部情報が与えられていないため、クラスとコンポーネントとの意味的な相違がなくなる。ここでは、必要な総コンポーネント数 K' を評価するために、便宜上、総コンポーネント数 K' をクラス数 $K=K'$ 、コンポーネント数 $M=1$ として、事後識別確率の明確さを表すクラス間エントロピー E_K を定義する。

$$E_K = - \sum_{n=1}^N \sum_{k=1}^{K'} p(k|x_n) \log p(k|x_n) \dots \dots (21)$$

ただし、 $M=1$ であるから、 $p(k|x_n) = p(k, 1|x_n)$ である。エントロピー E_K は、事後識別確率 $p(k|x_n)$ がすべて0または1になったとき、最小値をとる。すなわち、 E_K を最小にする総コンポーネント数 K' を用いれば、最も明確に EMG パターンをクラスタリングできることを意味する。

図2に総コンポーネント数 K' を、4から12まで増やしたときのエントロピー E_K の値とそれに要した学習回数を示す。ただし、ネットワークの収束判定には、(15)式の Bhattacharyya 距離を用い、 $\epsilon=10^{-4}$ とした。図中のエントロピーは、20種類の W_{nkm} の初期値による最小値である。図から、エントロピー、学習回数とも、対象動作数と等しい総コンポーネント数 $K'=6$ で最小となっていることがわかる。このときのクラスタリングの結果を表1に示す。教師信号、事前分布として情報を全く与えていないにもかかわらず、各コンポーネントが動作に対応し、完全なクラス

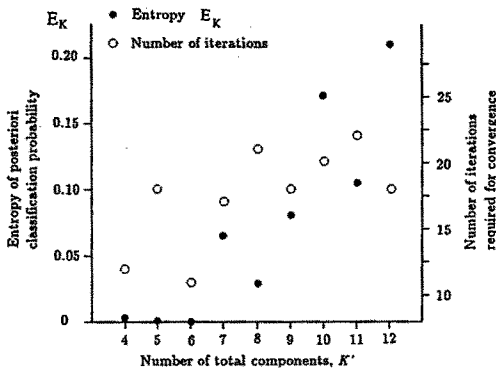


図2 EMGパターンに対するクラスタリング

Fig.2. Unsupervised learning for EMG patterns.

タリングが行われている。このクラスタリング能力は採取した EMG にどの程度、動作の情報が含まれているかを評価する有効な手段となり得る。

〈4・3〉 未学習データに対する動作識別能力

まず、ニューラルネットの学習定数 η と未学習データに対する動作識別能力の関係を調べた。図3に、学習定数 η [(17)式] を0.01から1.0まで変化させたときの、未学習データに対する識別率（600試行）と学習終了時のクラス間エントロピー E_K [(21)式, $N=60$] を示す。なお、各動作に対応するコンポーネント数は前節の実験結果より $M=1$ とし、動作決定部のパラメータは、 $a=0.5$, $b=0.3$ とした。図は、10通りの W_{nkm} の初期値に対する平均値と標準偏差である。図から、未学習データに対する識別能力を、学習時のクラス間エントロピー E_K を用いて評価できることがわかる。 E_K が事後識別確率の明確さを表現しているためである。従って、学習定数 η は、エントロピー E_K が小さくなるように設定すればよい。

表2に、健常者A(右利き)、健常者B(左利き)、切断者(左手首より約6cmの部位で前腕部を切断：右利き)の3名の被験者によって行った動作識別実験の結果を示す。電極位置は3種類とし、健常者Aの右腕、健常者B、切断者の左腕から採取した EMG パターンによる600試行の動作識別結果である。学習定数 η は、エントロピー E_K の最小値を用いて

表1 クラスタリング結果
Table 1. Clustering results.

| Component Motion | Component | | | | | |
|---------------------|-----------|----|----|----|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 |
| Flexion | 10 | 0 | 0 | 0 | 0 | 0 |
| Extension | 0 | 10 | 0 | 0 | 0 | 0 |
| Pronation | 0 | 0 | 10 | 0 | 0 | 0 |
| Supination | 0 | 0 | 0 | 10 | 0 | 0 |
| Grasping | 0 | 0 | 0 | 0 | 10 | 0 |
| Hand-opening | 0 | 0 | 0 | 0 | 0 | 10 |




図3 学習定数 η に対する識別率とクラス間エントロピー E_K

Fig.3. Discrimination rates and between-class entropies for learning constant η .

表 2 動作識別実験結果
Table 2. Results of motion discrimination experiments.

| Experiment | | No.1 | No.2 | No.3 | No.4 | No.5 |
|--------------------------------------|----------------------------|----------|----------|----------|----------|---------|
| Subject | | Normal A | Normal A | Normal B | Normal B | Amputee |
| Electrode location | | | | | | |
| Proposed method | Discrimination rate(%) | 99.3 | 98.2 | 84.0 | 91.2 | 91.3 |
| | Ill-discrimination rate(%) | 0.7 | 1.6 | 15.0 | 8.1 | 6.7 |
| | Suspended rate(%) | 0.0 | 0.2 | 1.0 | 0.7 | 1.0 |
| Back-propagation type neural network | Discrimination rate(%) | 95.9 | 91.9 | 82.4 | 80.6 | 79.2 |
| | Ill-discrimination rate(%) | 0.0 | 1.6 | 6.1 | 3.6 | 9.6 |
| | Suspended rate(%) | 4.1 | 7.5 | 11.5 | 15.8 | 11.2 |

$\eta=0.25$ と設定した。表 2 の上段は本手法による動作識別結果で、下段は入力層 (電極数に対応した 4 ユニット), 中間層 (10 ユニット), 出力層 (対象動作数に対応した 6 ユニット) の 3 層からなる誤差逆伝搬型ニューラルネットによる識別結果を示している⁽⁷⁾。表 2 から, 本手法が, 非線形識別を可能とする誤差逆伝搬型ニューラルネットとほぼ同等な識別結果を得ていることがわかる。なお, 本手法では, 動作決定ルールに事後識別確率 $p(k|x_n)$ を用いているため, 識別保留率は誤差逆伝搬型ニューラルネットのそれに比べて低い。このため, 誤識別率がやや増加している。今後, より有効な動作決定ルールを検討する必要がある。

5. 非正常 EMG に対する動作識別実験

動作中の EMG は, その発生から動作持続時にかけて (立上り時), あるいは動作持続時から静止への移行の際 (減衰時) などに, パターンが変動し, 強い非正常性を示す。Doerschuk らは, この非正常性を静止, 立上り, 動作維持, 減衰の四つのフェイズに分けて動作識別を試みているが, この方法は対象とする動作数 (パターン識別の際のクラス数) を増加させたにすぎない⁽²⁾。これに対して, 本手法では Gaussian Mixture モデルを用いているため, 母集団の確率分布を構成する各コンポーネントにより EMG の非正常性を自然な形で表現できる可能性がある。ここでは, 非正常 EMG パターンに対して行った動作識別実験の結果を示す。

〈5・1〉 実験条件 データ採取方法は前節と同様である。ただし, 被験者は健常者 2 名で, 電極は前腕部に 90° ずつ離して取付けた (表 2 実験番号 1, 3 参照)。




図 4 回内動作における EMG 信号 $y(t)$ の一例

Fig. 4. An example of measured EMG signals $y(t)$ during wrist supination.

学習用データは, 被験者に識別対象の各動作を 1 回ずつ行わせ, 各動作 4 秒間 (静止, 立上り, 動作維持, 減衰, 各約 1 秒) の非正常性を EMG を採取することによって得る。そして, 採取した EMG がしきい値を超えた時点で, 動作開始, 動作終了を判断する。

図 4 に採取した EMG 波形の一例を示す。図は, 手首の回内動作を行った際の EMG で, 動作の開始時, 終了時にその振幅が大きく変化しており, 強い非正常性を示していることがわかる。このような EMG を, 図 4 に示すように 3 区間 (それぞれ立上り, 動作維持, 減衰に対応) に分割する。そして, 各区間内で等間隔にサンプリングし, 各動作ごとに 3×5 個の整流平滑 EMG パターン $x_n \in R^3$ ($n=1, \dots, 90$) を抽出した。この 6 動作 \times 15 個のデータを学習用に用いた。また, 学習用データとは別に, 各動作について 10 試行の整流平滑 EMG パターンを採取し (未学習データ), 動作識別に用いた。動作識別用のデータ数は 6 動作 \times 150 個になる。

〈5・2〉 非正常 EMG の確率分布 非正常な

EMG に対しては、各動作に複数のコンポーネントを割り当てて学習することになる。このとき与えられる教師信号は、クラスに対する割り当てのみを指定し、コンポーネントへの割り当ては指定しないという部分的なものである〔(18)式参照〕。従って、高い識別能力を実現するためには、EMG パターンの確率分布を精度良く近似するようにクラス内の各コンポーネントが自己組織化されねばならない。そこで、クラス間エントロピー E_K に加えて、クラス内エントロピー E_M を以下のように定義する。

$$E_M = - \sum_{n=1}^N \sum_{k=1}^K \sum_{m=1}^M p(k, m | x_n) \log p(k, m | x_n) \dots\dots\dots (22)$$

E_M は、事後識別確率 $p(k, m | x_n)$ の明確さを表している。

図 5 に、学習定数 η を 0.01 から 1.0 の間で変化させたときの E_K, E_M を示す ($N=90, K=6, M=3$)。図から、 η が 0.1 から 0.125 の範囲で E_K, E_M とも、小さくなっていることがわかる。従って、この範囲の学習定数 η を用いれば、未学習データに対する高い識別率が期待される。以下では、エントロピー E_K の




図 5 学習定数 η に対するクラス間エントロピー E_K とクラス内エントロピー E_M

Fig. 5. Between-class entropies E_K and within-class entropies E_M for learning constant η .

最小値を与える $\eta=0.125$ を用いて実験を行った。

まず、EMG パターンの確率分布を調べるため、動作識別用に採取した EMG パターン (未学習データ) のヒストグラムを求めた。図 6 は手の握り動作の EMG パターン $x_n \in R^3$ の第 2 要素に対するヒストグラムで、(a) 図は全データ (150 個) を用いた場合、(b) 図は動作を維持している間のほぼ定常な EMG パターン (50 個) を用いた場合の結果である。なお、横軸は 0.0125 刻みで、縦軸はそれぞれのデータ数で規格化した後、1/0.0125 倍している。(b) 図では平均値の近傍に EMG パターンが分布し、ほぼガウス分布に従っていることがわかるが、(a) 図では EMG の立上り、減衰時のパターンが含まれているため、分布の形状は乱れている。

一方、図 7 は学習用に採取した EMG パターン ($N=6$ 動作 \times 15 個) を用いてニューラルネットを学習し、その結果得られた握り動作に対する EMG パターンの確率密度関数 $\iint p(x|k') dx_1 dx_3$ である。

$$\iint p(x|k') dx_1 dx_3 = \sum_{m=1}^M p(m|k') \iint p(x|k', m) dx_1 dx_3 \dots\dots\dots (23)$$

$$p(m|k') = \frac{p(m, k')}{\sum_{m=1}^M p(m, k')} \dots\dots\dots (24)$$

図 7 (a) は各動作のコンポーネント数を $M=3$ とした場合、(b) 図は $M=1$ とした場合で、(a) 図の破線は各コンポーネントの重み付き確率密度関数 $p(m|k') \iint p(x|k', m) dx_1 dx_3$ を表す。また、(c) 図は動作を維持している間のほぼ定常な EMG (図 4 参照) に対して $M=1$ で同様にニューラルネットの学習を行った結果である。すなわち、(a)、(b) 図は非定常な EMG パターンに対する学習結果、(c) 図は定常な




図 6 握り動作における EMG パターンの正規化度数分布
Fig. 6. Normalized frequency histogram of EMG patterns during grasping.




図 7 ニューラルネットによって推定された握り動作の確率密度関数
Fig. 7. Probability density functions learned by neural networks during grasping.

EMG パターンに対する学習結果と考えることができ、それぞれ図 6 (a)と(b)に対応する。

図 7 と図 6 を比較すると、ほぼ定常な EMG パターンに対してはコンポーネント数 1 で精度良く確率密度関数が推定できている[図 6 (b), 図 7 (c)]が、動作の立上り、減衰時の EMG パターンを含めた非定常性の強いデータに対してはコンポーネント数 1 では大きな誤差を生じている[図 6 (a), 図 7 (b)]。これに対して複数のコンポーネントを用いると、非定常性の強い EMG パターンの分布を精度良く推定しており、[図 6 (a), 図 7 (a)], 本論文で用いた Gaussian Mixture モデルが EMG の非定常性に対して有効であることがわかる。

〈5・3〉 識別能力 次に、図 7 で学習したニューラルネットを用いて未学習パターンに対する動作識別実験を行った。図 8 に手首の回外動作に対する識別結果の一例を示す。使用したニューラルネットは非定常 EMG に対して学習した $M=3$ のモデル[図 7 (a)]である。

図 8 は、上から各電極の EMG 波形、識別時刻と識別結果で、最下段に識別結果が属するコンポーネント番号を示す。図から、複数のコンポーネントの働きによって、高い識別率を実現していることがわかる。また、動作を維持している間の識別は、ほぼ同一のコンポーネントによって行われ、動作の立上り、減衰時を他の二つのコンポーネントで受け持っていることがわかる。

表 3 は 6 動作×150 パターンに対する識別率である。使用したニューラルネットは、図 7 (a)~(c) に対応して、モデル 1：非定常 EMG に対して学習したニューラルネット ($M=3$)、モデル 2：非定常 EMG に対して学習したニューラルネット ($M=1$)、モデル 3：定常 EMG に対して学習したニューラルネット ($M=1$) の 3 種類で、動作の立上り時、維持時、減衰




図 8 回内動作に対する識別結果の一例
Fig. 8. A example of discrimination results for wrist supination.

表 3 非定常 EMG パターンに対する識別率
Table 3. Motion discrimination rates for non-stationary EMG patterns.

| | Initiation of motions | Hold | Return to rest | Total |
|---------|-----------------------|------|----------------|-------|
| Model 1 | 84.3 | 99.0 | 99.3 | 91.9 |
| Model 2 | 48.3 | 78.0 | 71.3 | 63.6 |
| Model 3 | 63.7 | 99.7 | 94.3 | 85.3 |

(%)

時 (それぞれ 6 動作×50 個) ごとの識別率を示している。表から、モデル 1 の識別率が最も高く、特に動作の立上り時の識別率が他のモデルに比べて大幅に改善されている。これらの結果は、他の被験者に対しても同様であった。

6. まとめ

本論文では、EMG パターンの分布に Gaussian Mixture モデルを仮定し、この統計的構造を先見の知識として組込んだニューラルネットによる動作識別法を提案した。このニューラルネットは教師信号の有無に応じて、それぞれ最適なパターン識別を学習的に実現することができる。そして、動作識別実験によって、未学習の EMG パターンに対しても高い識別率

を実現できること、強い非正常性を有する EMG に対しても、複数のコンポーネントの働きにより EMG パターンの分布を精度良く表現できることを明らかにした。

動作識別に利用できる EMG 情報には、振幅情報と周波数情報がある。EMG の振幅パターンは、活動する筋とその収縮の度合いが動作によって変化するため、動作ごとに異なったパターンを示す。一方、周波数情報は筋固有の周波数成分、および筋と電極の距離によって組織の伝達特性が変化するため、やはり動作ごとに異なった特徴をもつ。本論文ではこのうち、振幅情報のみを利用して動作識別を行った。今後は、振幅情報に加えて、周波数情報を効果的に利用する方法について考察すると共に、動作決定部のアルゴリズムの改善、学習定数 η のより簡便な決定法などの問題について検討することを考えている。

なお、本研究の一部は、(財)上原記念生命科学財団、(財)立石科学技術振興財団、および文部省科学研究費(01850088)の研究助成によるもので、ここに改めて謝意を表します。(平成4年1月27日受付)

文 献

- (1) A. Hiraiwa, K. Shimohara & Y. Tokunaga: "EMG pattern analysis and classification by neural network", *IEEE International Conference on Syst., Man & Cybern.*, p. 1113 (1989)
- (2) P. C. Doerschuk, D. E. Gustafson & A. S. Willsky: "Upper extremity limb function discrimination using EMG signal analysis", *IEEE Trans. Biomedical Engineering*, BME-30, No. 1, 18 (1983)
- (3) 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」, *ME 学会誌*, 18, No. 2, 133 (昭55)
- (4) S. Lee & G. N. Saridis: "The control of a prosthetic arm by EMG pattern recognition", *IEEE Trans. Autom. Control*, AC-29, 4, 290 (1984)
- (5) 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*, J70-D, 207 (昭57)
- (6) M. F. Kelly, P. A. Parker & R. N. Scott: "The application of neural networks to myoelectric signal analysis: A preliminary study", *IEEE Trans. Biomedical Engineering*, 37, No. 3, 221 (March 1990)
- (7) K. Ito, T. Tsuji, A. Kato & M. Ito: "Limbfuction discrimination using EMG signals by neural network and application to prosthetic forearm control", *Proc. of IJCNN*, Singapore, p. 1214 (1991)
- (8) C. Koch, J. Marroquin & A. Yuille: "Analog 'neural' network in early vision", *Proc. Natl. Acad. Sci. USA*, 83, 4263 (1986)
- (9) 土屋・中西: 「神経回路網を用いた確率場のベイズ推定」, 第2回自律分散システム・シンポジウム資料, p. 85 (平3)
- (10) K. Fukunaga: *Introduction to statistical pattern recognition* (1972) New York: Academic Press
- (11) L. I. Perlovsky & M. M. McManus: "Maximum likelihood neural networks for sensor fusion and adaptive classification", *Neural Networks*, 4, 89 (1991)
- (12) H. G. C. Traven: "A neural network approach to statistical pattern classification by 'semiparametric' estimation of probability density functions", *IEEE Trans. Neural Networks*, 2, No. 3, 366 (1991)
- (13) D. F. Specht: "Probabilistic neural networks", *Neural Networks*, 3, 109 (1990)
- (14) J. H. Wolfe: "Pattern clustering by multivariate mixture analysis", *Multivariate Behavioral Res.*, 5, 329 (1970)
- (15) 竹内・柳井: *多変量解析の基礎* (昭47) 東洋経済新報社



辻 敏夫 (正員)

昭和60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。ロボット工学、生体工学、マン・マシン・システムなどの研究に従事。工学博士。計測自動制御学会、日本ロボット学会、電子情報通信学会、IEEE 会員。



森 大一郎 (非会員)

平成2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情報工学専攻在学中。ニューラルネットを用いたロボットの制御、パターン識別に関する研究に従事。



伊藤 宏司 (正員)

昭和46年名古屋大学大学院工学研究科修士課程前期修了。45年同大学工学部自動制御研究施設助手。54年広島大学工学部第二類(電気系)助教授。平成4年豊橋技科大学教授、現在に至る。生体運動制御、ロボティクス、マン・マシンインタフェースの研究に従事。工学博士。計測自動制御学会、日本ロボット学会、電子情報通信学会、IEEE 会員。