

# 論 文

## 義手制御を目的とした多チャンネル EMG 動作識別法

非会員 辻 敏夫<sup>†</sup> 正員 伊藤 宏司<sup>†</sup> 非会員 長町 三生<sup>†</sup>

### A Limb-Function Discrimination Method Using EMG Signals for the Control of Multifunctional Powered Prostheses

Toshio TSUJI<sup>†</sup>, Nonmember, Koji ITO<sup>†</sup>, Member  
and Mitsuo NAGAMACHI<sup>†</sup>, Nonmember

あらまし 本論文では EMG から切断者の意図した動作を推定する方法について述べる。これは、多機能動力義手の人間一義肢インターフェースが備えねばならない重要な機能の一つである。このインターフェースを切断者にとって使い易いものにするためには、EMG の測定をできるだけ簡単にする必要がある。従来、表面 EMG を用いた動作識別法が試みられているけれども、その多くは電極位置として特定の筋を指定している。これは、電極を取り付ける際のわざらわしさを伴うだけでなく、動作識別能力にも重大な影響を与える。

そこで本論文では、EMG の振幅、周波数情報、更に電極間のクロス情報を利用することにより、電極位置を比較的自由に設定できる識別法の開発を試みる。提案する手法は多次元 AR モデルと判別関数法を組み合わせたものである。3 名の被験者、4 種類の電極位置に対する実験から、本手法は、4 対の電極、動作発生後 100 msec の EMG を用いて、前腕、手の 6 動作を 93 % 以上の確度で正確に識別できることが明らかにされた。従って、本論文で提案する動作識別法は、電極を取り付ける際のわざらわしさを軽減し、かつ、高い識別能力を実現することが可能となる。

### 1. まえがき

動力義手の開発において、その制御信号の獲得は最も重要な問題のひとつである。理想的には、脳波や遠心性神経から直接、制御信号を取りだせれば、切断者の中枢運動制御系と整合のとれた義肢制御系を構成することができる。しかし、その実現が困難である現時点では、筋電位 (EMG) が最も有力な制御信号源である。EMG は神経一筋系の電気的活動のあらわれである。従って、切断者の残存筋から得られる EMG を利用すれば、自然肢に近い “natural” な制御感覚を実現できる可能性がある。特に表面筋電位は、安全で手軽に測定することができるという長所をもっている。

しかしながら、EMG は多数の筋線維の活動電位が複合したものであり、かなりの高周波数成分まで含まれている<sup>(1)</sup>。従って、EMG を義手の制御信号として用いるためには、何らかの信号処理を行う人間一義肢インターフェースが必要である。たとえば、多機能動力義手における人間一義肢インターフェースの一例を図 1

に示す。まず、切断者の残存筋から採取した EMG を用いて、切断者の意図した動作を識別する。屈曲、伸展、回内、回外などの動作である。同時に義手を駆動・制御するための信号 (筋力に相当する) を EMG から得る。そして、識別した動作をこの操作信号で比例的に制御する<sup>(2)(3)</sup>。一方、義手側からは、位置、速度、力感覚などの情報が視覚、触覚あるいは電気刺激などにより切断者にフィードバックされる。

本論文では動作識別の問題を取り上げる。動作識別に利用できる EMG 情報には、振幅情報、周波数情報がある。EMG の振幅パターンは、動作によって、活動する筋とその収縮の度合が変化するため、動作ごとに異なった特徴を示す。一方、周波数情報は、筋がそれぞれ異なる周波数特性を持つこと<sup>(4)(5)</sup>、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という事実<sup>(1)</sup>によって、やはり動作ごとに異なった特徴をもつ。従来、これらの EMG 情報を利用した動作識別法がいくつか報告されている<sup>(6)~(10)</sup>。

Graupe らは、一対の電極で測定した EMG を AR モデルとしてモデル化し、動作によりモデルのパラメータが異なることを利用して動作識別を行った<sup>(6)</sup>。これは、主に EMG の周波数情報を利用する方法であ

† 広島大学工学部、東広島市

Faculty of Engineering, Hiroshima University, Higashi-Hiroshima-shi, 724 Japan

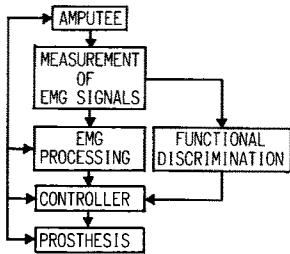


図1 人間—義肢インターフェース  
Fig. 1 Amputee-prostheses interface.

る。また山田らは、複数個の電極で採取した筋電位の整流積分値を特徴ベクトルとし、判別関数により動作を決定する方法を提案している<sup>(8)</sup>。この方法は帯域フィルタを用いることにより、EMGの振幅情報、周波数情報をともに利用しているといえる。しかしながら、これらの手法は、電極位置として特定の筋を指定しているため、電極位置の厳密な設定が必要である。実際の義手の使用においては、電極装着時の電極位置のずれ、切断者の断端の形状による筋特性の違いなどの問題は避けられないものであり、これらの影響をできるだけ少なくすることが必要である。

以上の観点から本論文では、EMGの振幅情報、周波数情報、更に電極間のクロス情報を利用することにより、電極位置を比較的の自由に設定できる動作識別法の開発を目的とする。提案する手法は、多次元ARモデルと代表的なパターン識別法のひとつである判別関数を組み合わせたものである。多次元ARモデルにより電極間のクロス成分を含む周波数情報が、判別関数によりEMGの振幅パターンが識別に利用できる。

以下、2.では識別アルゴリズムについて述べ、3.ではEMG測定時間、ARモデルの次数などが識別能力に与える影響について実験的に考察する。4.では義手制御の模擬実験を行い、電極位置の影響、被験者による違いなどに注目して本手法の評価を行う。

## 2. 多チャンネルEMG動作識別法

### 2.1 多次元ARモデル

EMGの周波数情報が動作ごとに異なることに着目し、複数個の電極で採取したEMGを多次元ARモデルとしてモデル化する<sup>(11)</sup>。いま、EMGは、平均値0の定常不規則信号であると仮定し、ある動作 $m$  ( $m=1, 2, \dots, M$ :  $M$ は対象とする動作数)を行ったときに発生するEMG信号 $X_m(t)$ を、

$$X_m(t) = -\sum_{k=1}^p A_m(k) X_m(t-k) + e_m(t) \quad (1)$$

とする。ここで、電極数を $L$ とすると、 $X_m(t)$ は $L$ 次列ベクトル、 $p$ はARモデルの次数、 $A_m(k)$ は $k$ 次のAR係数行列( $L \times L$ )、 $e_m(t)$ は予測誤差である。 $e_m(t)$ は $L$ 次元白色ガウスベクトルで

$$E[e_m(t)] = 0 \quad (2)$$

$$E[e_m(t) \cdot e_m^T(s)] = V_m \delta_{ts} \quad (3)$$

ただし、

$$e_m(t) = [e_{m1}(t) \ e_{m2}(t) \cdots e_{mL}(t)]^T$$

$$V_m = \begin{bmatrix} E[e_{m1}(t)e_{m1}(t)] & \cdots & E[e_{m1}(t)e_{mL}(t)] \\ \vdots & \ddots & \vdots \\ E[e_{mL}(t)e_{m1}(t)] & \cdots & E[e_{mL}(t)e_{mL}(t)] \end{bmatrix}$$

$$\delta_{ts} = \begin{cases} 1 & (t=s) \\ 0 & (t \neq s) \end{cases}$$

を満たす。添字<sup>T</sup>は転置を表す。EMG信号 $X_m(t)$ が持つ情報は、AR係数行列 $A_m(k)$ と予測誤差共分散行列 $V_m$ にすべて含まれる。特に、 $A_m(k)$ 、 $V_m$ の非対角成分は電極間のクロス情報を表している。

AR係数行列 $A_m(k)$ は予測誤差の二乗平均値、

$$E_m = E[e_m^T(t)e_m(t)] = \text{trace } V_m \quad (4)$$

を最小にするように推定する。従って、 $E_m$ はARモデルのEMGへの適合度を示すことになる。

### 2.2 判別関数

ARモデルの予測誤差 $e_m(t)$ の分散は、EMG波形の振幅特性を反映している。EMGの振幅特性は動作により異なるから、 $e_m(t)$ も動作ごとに異なった特徴を持つことになる。そこで各電極に対する予測誤差の分散 $E[e_m^2(t)]$ を特性値として判別関数を構成する。ただし、筋力レベルによるパターン変動の影響をなくすため、

$$S_i^{(m)} = E[e_m^2(t)] / E_m \quad (i=1, 2, \dots, L) \quad (5)$$

$$\sum_{i=1}^L S_i^{(m)} = 1.0$$

として規格化を行う。一般に動作数が $M$ であるとき、判別関数は $M(M-1)/2$ 個必要であり、 $M$ が大きくなると計算時間が長くなるという問題が生じる。そこで、少数個の判別関数で $M$ 個の動作を識別する手法を用いる<sup>(12)</sup>。

いま、各動作について $n_1, n_2, \dots, n_M$ 回のデータを得たとする。動作 $m$ の $n$ 回目の特性値を $S_{ni}^{(m)}$  ( $n=1, 2, \dots, n_m$ ;  $i=1, 2, \dots, L$ ) とすると、1動作内のばらつきを表す群内平方和・積和行列 $W = (W_{ij})$

と、動作間のばらつきを表す群間平方和・積和行列  $\mathbf{B} = (B_{ij})$  は、

$$W_{ij} = \sum_{m=1}^M \sum_{n=1}^{n_m} (S_{ni}^{(m)} - \bar{S}_i^{(m)})(S_{nj}^{(m)} - \bar{S}_j^{(m)}) \quad (6)$$

$$B_{ij} = \sum_{m=1}^M n_m (\bar{S}_i^{(m)} - \bar{S}_j^{(m)}) (\bar{S}_j^{(m)} - \bar{S}_j^{(m)}) \quad (7)$$

ここで、 $\bar{S}_i = \sum_{m=1}^M n_m \bar{S}_i^{(m)}/N$  : 総平均

$$N = \sum_{m=1}^M n_m \quad : \text{総データ数}$$

となる。目的は互いに直交する  $K$  個の判別関数  $Z_l (l=1, 2, \dots, K)$  を求めることである。

$$Z_l = \sum_{i=1}^L a_{li} (S_i - \bar{S}_i) \quad (l=1, 2, \dots, K) \quad (8)$$

識別を容易にするためには、 $Z_l$  の群内平方和が小さく、群間平方和が大きい方が望ましい。そこで、係数  $a_{li}$  は群間平方和の群内平方和に対する比を最大にするという条件のもとで求める。 $Z_l$  についての群内平方和を  $S_{wl}$ 、群間平方和を  $S_{Bl}$  とすると、

$$\begin{aligned} S_{wl} &= \sum_{m=1}^M \sum_{n=1}^{n_m} (Z_{nl}^{(m)} - \bar{Z}_l^{(m)})^2 \\ &= \sum_{i=1}^L \sum_{j=1}^L a_{li} a_{lj} W_{ij} \end{aligned} \quad (9)$$

$$\begin{aligned} S_{Bl} &= \sum_{m=1}^M n_m (\bar{Z}_l^{(m)} - \bar{Z}_l^{(m)})^2 \\ &= \sum_{i=1}^L \sum_{j=1}^L a_{li} a_{lj} B_{ij} \end{aligned} \quad (10)$$

となる。従って、 $\theta = S_{Bl}/S_{wl}$  を  $a_{li}$  で偏微分して 0 とおくと、

$$(\mathbf{B} - \theta \mathbf{W}) \mathbf{a}_l = 0 \quad (11)$$

を得る。これが  $\mathbf{a}_l = 0$  以外の解をもつためには、

$$|\mathbf{B} - \theta \mathbf{W}| = 0 \quad (12)$$

あるいは、

$$|\mathbf{W}^{-1} \mathbf{B} - \theta \mathbf{I}| = 0 \quad (13)$$

が成立しなければならない。よって、 $\theta$  は行列  $\mathbf{W}^{-1} \mathbf{B}$  の固有値となる。ここで、 $\mathbf{W}$ 、 $\mathbf{B}$  はともに  $L \times L$  行列で、 $\mathbf{W}$  は正則、 $\mathbf{B}$  のランクは群間の自由度  $M-1$  を越えないから、 $\mathbf{W}^{-1} \mathbf{B}$  のランクは  $\min\{L, M-1\}$  以下である。判別関数の係数ベクトル  $\mathbf{a}_l$  は、固有値の大きい方から順にとり、それらに対応する右固有ベクトルを用いればよい。このとき、固有値  $\theta_i \neq \theta_j$  ならば、対応する右固有ベクトル  $\mathbf{a}_i$ 、 $\mathbf{a}_j$  は互いに直交し、 $Z_i$  と  $Z_j$  は群内で無相関になる<sup>(12)</sup>。

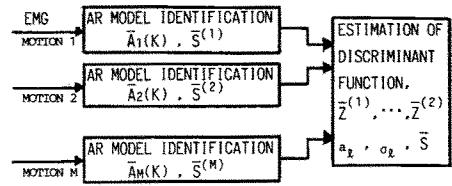


図 2 モデル同定部  
Fig. 2 Procedure of model identification.

### 2.3 識別アルゴリズム

識別アルゴリズムはモデル同定部と動作識別部から成る。まず、モデル同定部で対象とする各動作に対して識別に必要なパラメータを求めておく。次に動作識別部では制御者が行った動作は対象とする動作のうちの一つであると仮定し、その EMG を各動作のモデルにあてはめる。そして、最もよくあてはまる動作を選択する。

#### (1) モデル同定部

制御者に對象とする  $M$  個の動作をそれぞれ  $n_m$  回行わせ、EMG を採取する。そして、多次元 AR モデル ((1)式) の AR 係数行列  $A_m(k) (m=1, 2, \dots, M; k=1, 2, \dots, p)$  および、予測誤差共分散行列  $V_m (m=1, 2, \dots, M)$  を推定する。次に、各電極に対する予測誤差の分散  $S_i^{(m)}$  ((5)式) を特性値として判別関数を求める。

$$Z_{jl}^{(m)} = \sum_{i=1}^L a_{li} (S_{ij}^{(m)} - \bar{S}_i^{(m)}) \quad (14)$$

$$(j=1, 2, \dots, n_m, l=1, 2, \dots, K)$$

そして、各動作ごとに  $Z_{jl}^{(m)}$  の平均値  $\bar{Z}_l^{(m)}$ 、および群内分散  $\sigma_l$ 、

$$\bar{Z}_l^{(m)} = \frac{1}{n_m} \sum_{j=1}^{n_m} Z_{jl}^{(m)} \quad (15)$$

$$\sigma_l = \frac{1}{n_m M - 1} \sum_{m=1}^M \sum_{j=1}^{n_m} (Z_{jl}^{(m)} - \bar{Z}_l^{(m)})^2 \quad (16)$$

$$(l=1, 2, \dots, K)$$

を計算する。各動作に対する AR 係数行列の平均値  $\bar{A}_m(k)$ 、特性値の総平均  $\bar{S}_i (i=1, 2, \dots, L)$ 、変換ベクトル  $\mathbf{a}_l$ 、判別関数の平均値  $\bar{Z}_l^{(m)}$ 、判別関数の群内分散  $\sigma_l$  は計算機内に記憶し (図 2 参照)、次の動作識別部で用いる。

#### (2) 動作識別部

制御者が行った動作 (対象とする  $M$  個の動作のうちの一つとする) の EMG 信号  $X(t)$  を採取し、モデル同定部で求めた各動作の AR モデルにあてはめる。 $X(t)$  の予測値  $\hat{X}_m(t)$  は、行列  $\bar{A}_m(k)$  を用いて、

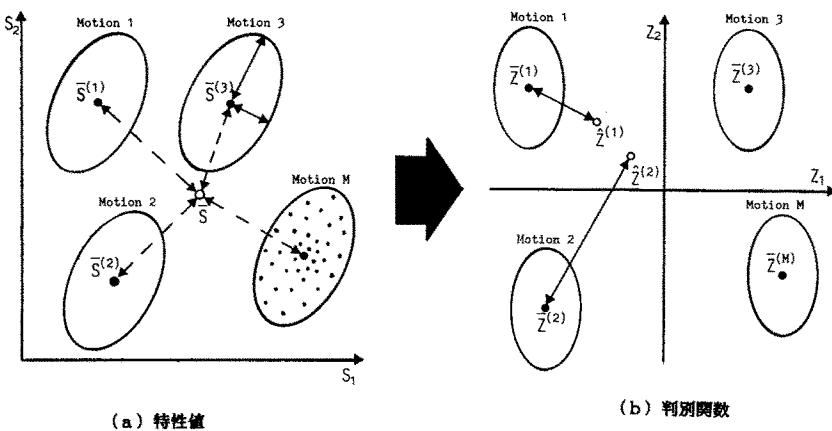


図3 判別関数の概念図  
Fig. 3 Schematic representation of discriminant function method.

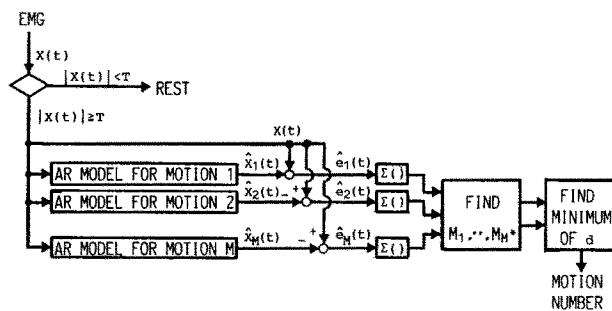


図4 動作識別部  
Fig. 4 Procedure of limb-function discrimination.

$$\hat{X}_m(t) = -\sum_{k=1}^p \tilde{A}_m(k) X(t-k) \quad (m=1, 2, \dots, M) \quad (17)$$

と表すことができる。予測誤差  $\hat{e}_m(t)$  は

$$\hat{e}_m(t) = X(t) - \hat{X}_m(t) \quad (18)$$

$$\hat{e}_m(t) = [\hat{e}_{m1}(t) \hat{e}_{m2}(t) \cdots \hat{e}_{mL}(t)]^T$$

となる。データ数を  $N$  とすると予測誤差の二乗和  $\hat{E}_m$  は、

$$\hat{E}_m = \sum_{i=1}^L \sum_{t=p+1}^N \hat{e}_{mi}^2(t) \quad (19)$$

で与えられる。ここで、各動作の AR 係数行列は予測誤差の二乗平均値を最小にするように推定していることから、 $\hat{E}_m$  が小さいほどモデルへのあてはまりが高いと考えられる。そこで、採取した EMG 信号  $X(t)$  を用いて、各動作モデルに対する予測誤差の二乗和  $\hat{E}_m$  を計算し、対象とする動作を  $\hat{E}_m$  の小さい  $M^*$  個の動作に絞って、次に判別関数を計算する。

ここまで処理では、EMG の周波数特性が筋力レベルによらずほぼ一定であることから<sup>(13),(14)</sup>、EMG の振幅レベル（制御者の力の入れ具合）には依存しない。また、これら一連の処理は、各動作モデルに対して並列に行うことができ、計算時間の短縮をはかることが可能である。

$\hat{E}_m$  の小さい  $M^*$  個の動作の特性値  $\bar{S}_i^{(m)}$  ( $i=1, \dots, L; m=M_1, M_2, \dots, M_{M^*}$ ) を用いて判別関数値  $\bar{Z}_i^{(m)}$ 、

$$\bar{Z}_i^{(m)} = \sum_{i=1}^L a_{li} (\bar{S}_i^{(m)} - \bar{S}_i) \quad (l=1, 2, \dots, k) \quad (20)$$

を計算する。そして、各動作の平均パターン  $\bar{Z}_i^{(m)}$  とのマハラノビス距離  $d$  が最小になる動作を選択する。ここで、マハラノビス距離とは判別関数のチャンネルごとの分散を考慮した距離であり、次式で定義される。

$$d^{(m)} = \sum_{i=1}^K [(\hat{Z}_i^{(m)} - \bar{Z}_i^{(m)})^2] / \sigma_i^2 \quad (21)$$

図3は電極数  $L$  が2の場合の判別関数を模式的に示したものである。図(a)は、ARモデルの予測誤差から求めた特性値をプロットしたものである。各動作について  $n_m$  回試行を行うと、各動作は特性値の平面上に群を形成する。群内分散((6)式)は、各動作内の試行のばらつきを示し、群間分散((7)式)は動作間のばらつきを示している。そこで、各群の判別を容易にするため、群間分散の群内分散に対する比を最大にするという条件で求めた直交変換ベクトル  $a_t$  を用いて、特性値を判別関数値に変換する(図(b))。ここで  $\bar{Z}^{(m)}$  は各動作の平均値を表す。 $\hat{Z}^{(1)}$ ,  $\hat{Z}^{(2)}$  はそれぞれ、ARモデルによくあてはまっていた動作の判別関数値である。この場合は動作1の平均値  $\bar{Z}^{(1)}$  との距離が近いから、動作1が制御者が行った動作として選択される。ここで、注意すべき点は、各動作の判別関数の群内分散は動作によらず一定と仮定していることである。この点については次章で触れる。

図4は動作識別部のプロック線図である。動作の発生は、EMGの振幅がある閾値レベル  $T$  を越えたときに起こったと判断し、動作識別を開始することにする。ただし、静止状態を一つの動作とみなし、対象動作に含めることも可能である。

### 3. 動作識別能力とパラメータの影響

本章では前章で述べた多チャンネルEMG動作識別法がどの程度の識別能力を持つかを明らかにするため、基礎実験を行う。本手法はいくつかのパラメータを含むが、ここではそのうち動作識別部のデータ数、ARモデルの次数、モデル同定部の試行回数をとりあげる。これらのパラメータは識別率が高く、かつ、識別に要する時間が短いという基準を満足する必要がある。一般にデータ数、次数、試行回数を大きくすると、推定精度が増し、識別率は向上すると考えられるが、逆に識別時間は大幅に増加する。従ってこれらのパラメータをむやみに大きくすることはできず、どこかで妥協せざるを得ない。そこで、識別能力とパラメータの関係を実験的に明らかにするとともに、ある程度の実用性を考慮してこれらの値を決定する。

#### 3.1 実験条件

実験条件は次のとおりである。

##### 1) 対象動作

手首の掌屈、背屈、回内、回外、手の握り、開きの

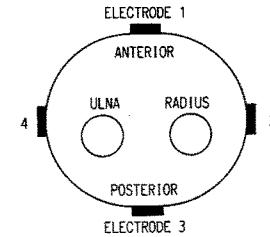


図5 電極位置  
Fig. 5 Electrode locations.

6 動作とする。

##### 2) 測定部位

4対の電極を、肘関節から7cmの前腕部に90°ずつ離して1対ずつ取り付ける(図5)。電極は直径1.5cmの同心円使い捨て電極(日本光電製)で、双極誘導(電極間隔2cm)とした。各チャンネルのEMGは、医用テレメータ(日本光電製)を介して增幅し、低域通過フィルタ(1次アナログフィルタ:カットオフ周波数1kHz)を通したのち、サンプリング周波数2kHzでA/D変換する。そして、データファイルとしてディジタル計算機の固定ディスクに記憶する。

##### 3) 被験者

被験者は成人男子1名(健常者)とする。

##### 4) モデル同定部パラメータ

データ数は、1チャンネル当たり2000個、ARモデルの次数  $k$  は2, 4, 6, 8の4種類とし、各動作の試行回数  $n_m$  は5, 10, 15回( $m=1, 2, \dots, 6$ )の3種類とした。データ採取時間は1秒(2000×0.5msec)である。モデル同定部のデータ数を比較的大きな値としたのは、予備実験を行った結果、データ数を少なくするとモデルの推定精度が低下し、後の動作識別に影響を与えることが明らかになったためである。

##### 5) 動作識別部パラメータ

データ数  $N$  は1チャンネル当たり100, 200, 300, 400, 500の5種類(データ採取時間はそれぞれ50, 100, 150, 200, 250 msecとなる)とし、各動作について50試行のEMGを採取する。そして予測誤差の二乗和  $E_m$  を用いて対象動作を2動作に絞り、判別関数を計算する。

上記の条件のもとでEMGを採取し、動作識別を試みた。なお、ARモデルの推定には、LWR算法<sup>(11)</sup>を、(13)式の固有値問題の解法にはエバーライン法<sup>(14)</sup>を用いた。

#### 3.2 実験結果および解析

図6に動作識別部のデータ数と識別能力との関係を

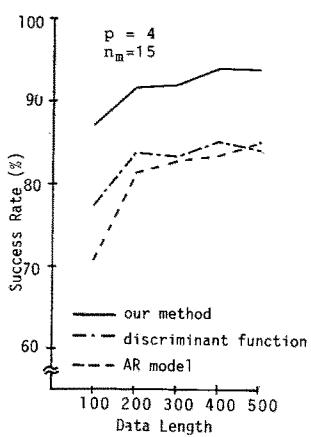


図 6 データ数と識別率

Fig. 6 The effect of data length on success rate.

示す。横軸はデータ数、縦軸は300試行のうち正しく識別した割合を識別率として表している。図中、実線が本手法の識別率であり、破線はARモデルのみで動作識別を行った場合、1点鎖線はEMGの各チャンネルごとの二乗和を特性値として判別関数のみで動作識別を行った場合の識別率である。ただし、モデル同定部での試行回数は1動作につき15回で、ARモデルの次数は4次とした。

本手法は、ARモデル、判別関数をそれぞれ単独で用いた場合に比べて、10~15%程度識別率が向上している。これは、ARモデル、判別関数がそれぞれEMGの周波数情報、振幅情報を利用しているのに対し、本手法はその両方を利用しているためであると考えられる。また、EMG採取時間の短縮という観点から、データ数は少ない方が望ましい。図より、データ数が多いほど識別率は向上する傾向にあるが、データ数200以上では大きな識別率の向上は見られない。従ってデータ数は200程度まで下げができる。これは、EMG採取時間としては100 msecに対応する。しかしながら、データ数を100個とすると識別率は急激に低下している。これには二つの理由が考えられる。一つはデータ数の低下による予測誤差の二乗和  $E_m$  の推定精度の低下である。もう一つは動作発生直後のEMGの非定常性である。データ数を少なくすると、動作発生直後のごく短時間のEMGを用いることになり、ARモデルで用いた定常性の仮定が満たされなくなる。従って、データ数をこれ以上少なくすることは難しいことがわかる。

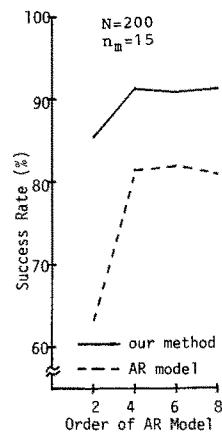


図 7 AR モデル次数と識別率

Fig. 7 The effect of model order on success rate.

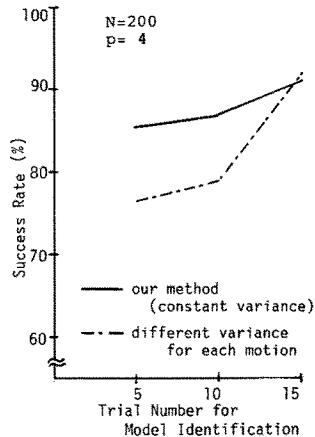


図 8 モデル同定部試行回数と識別率

Fig. 8 The effect of trial numbers for model identification on success rate.

図7は、ARモデルの次数を2, 4, 6, 8とした場合の識別率である。実線が本手法の識別率、破線がARモデルのみを用いた場合である。データ数は200、モデル同定部の各動作の試行回数は15としている。

図より、次数を上げるにつれて識別率は向上する傾向にある。しかし4次以上にしても識別率の向上は見られず、次数は4次程度で十分であることがわかる。

一般にARモデルの次数決定にはAICが用いられる場合が多い。EMGの場合、AICによる次数は20以上となるが、EMGとARモデルによる予測値との重相関係数は、4次程度で飽和することが報告されて

いる<sup>(7)</sup>。多次元 AR モデルの場合の AIC は、

$$AIC(p) = \ln[\det V(p)] + 2pL^2/N \quad (22)$$

で与えられる<sup>(11)</sup>。ここで  $p$  は AR モデルの次数、 $V$  は予測誤差の共分散行列、 $N$  はモデル同定部でのデータ数、 $L$  はチャンネル（電極に対応する）数である。いま、 $N = 2000$ 、 $L = 4$  であるから、上式右辺第 2 項はかなり小さい値となり、AIC に与える影響は小さくなる。本手法のように AR 係数よりも予測誤差を主に利用する場合には、右辺第 1 項に対応する重相関係数を次数決定基準として用いることが可能であると言える。

図 8 は、モデル同定部での試行回数と識別率の関係を示している。動作識別部でのデータ数は 200、AR モデルの次数は 4 としている。実線が本手法の識別率で、試行回数が少ないと識別率は下がる傾向にある。これは、各動作モデルの推定精度の低下が原因である。

ところで本手法では、判別関数の群内分散は動作によらず一定と仮定した（2.3 参照）。しかし、実験結果から群内分散は動作により若干異なることが明らかになった。そこで、各群の分散の違いを考慮して、判別関数のマハラノビス距離を求める方法を試みた。図中、破線でその識別率を示す。モデル推定を各動作 15 試行で行った場合には、分散の違いを考慮した方が若干良い識別率を得られることがわかる。しかしながら、モデル推定の試行回数を減らすと、この方法は分散一定を仮定した場合に比べて、大幅に識別率が低下している。これは試行回数の減少による分散の推定精度の低下が原因である。つまり、試行回数が 5 回の場合を考えると、分散一定を仮定した方法では、30 個（6 動作 × 5 回）の特性値から分散を推定している。これに対して、分散の違いを考慮すると、各動作ごとに 5 個の特性値で分散を求めざるを得ない。

モデル同定部での試行回数は、動作識別部での識別時間には影響を与えないけれども、実用上はできるだけ少なくする必要がある。従って、群内分散一定として識別を行う方が高い識別率を実現できることになる。

以上の実験結果から、本稿で提案する動作識別法は、モデル同定部での試行回数 5 回 / 動作、AR モデル次数 4、動作識別部でのデータ数 200 / ch. で、86 % 程度の識別率を示すことが明らかになった。次章では、実際の義手制御を想定した実験を行い、本手法の有効性を確認する。

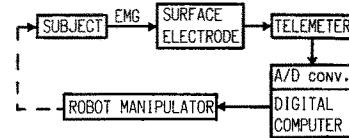


図 9 実験装置  
Fig. 9 A block diagram of experimental arrangements.

#### 4. 動作識別実験

義手使用時には、制御者は義手の動作を確認することにより、識別結果をリアルタイムで知ることができる。そこで本章では、識別結果を逐次、制御者にフィードバックしながら実験を行う。これにより、制御者は自らの学習、適応能力を利用することができる。更に、被験者、電極位置の影響についても実験を行い、本手法の識別能力を明らかにする。

実験装置の構成を図 9 に示す。表面電極により採取した EMG を医用テレメータを介して増幅し、A/D 変換器により、ディジタル計算機に取りこむ。識別結果はミニピュレータ（MOVE MASTER II：三菱電機製）に送られ、制御者は識別結果をミニピュレータの動作により確認することができる。

実験条件については 3.1 と同様である。ただし、3. の実験結果より、モデル同定部の試行回数は 5 回 / 動作、AR モデルの次数は 4、動作識別部のデータ数は 200 とした。また、被験者は成人男子 3 名（健常者）とし、各被験者につき 2 種類の電極位置で実験を行い、識別率を求めた。

表 1 に各電極位置と識別率を示す。各被験者、各電極位置で識別率は 93 % 以上である。特に実験番号 1 の実験結果は前章の実験と同じ電極位置で行ったものである。その動作ごとの識別率を表 2 に示す。背屈を開きに、掌屈を握りに識別する傾向がみられるけれども、全体としては 96 % の識別率をあげている。前章の識別率 86 % に比べて約 10 % の向上である。これは、識別結果のフィードバックによる効果であると言える。

一方、AR モデルのみで同じ EMG を用いて識別した結果についても表 1 に示す。電極位置が接近している場合（実験番号 2, 4, 6）は、AR モデルと判別関数を組み合わせた識別法と比較して、ほぼ同程度の識別率が得られることがわかる。これは、電極位置が接近しているため各電極から得られる EMG の相関が高

表1 動作識別実験結果

実験番号	No. 1	No. 2	No. 3	No. 4	No. 5	No. 6
被験者	T	T	Y	Y	K	K
電極位置	1 4 3 2	2 3 4 1	1 4 3 2	1 2 4 3	1 4 3 2	2 1 3 4
識別率(%)	96	97	93	96	96	95
ARモデル	92	99	87	94	90	94

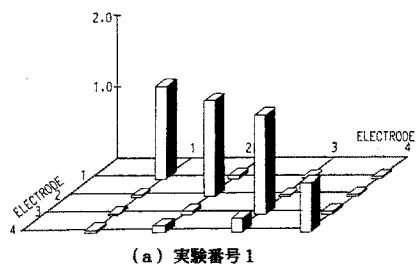
表2 各動作の識別率

実験 No.1	正解						TOTAL
	掌屈	背屈	回内	回外	握り	開き	
掌屈	46	0	0	0	0	0	
背屈	0	44	0	0	0	0	
回内	0	0	50	1	0	0	
回外	0	0	0	48	0	0	
握り	4	1	0	0	50	0	
開き	0	5	0	1	0	50	
正解率(%)	92	88	100	96	100	100	96

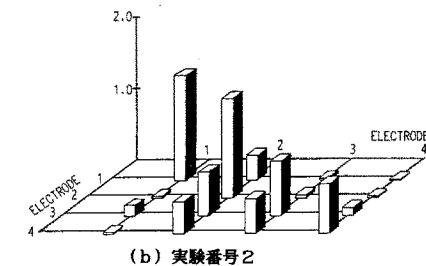
く、電極間のクロス情報が識別に有効に利用された結果と考えられる。そこで、図10にAR係数行列の絶対値を示す。これは掌屈動作の1次のAR係数行列で、(a)が実験番号1、(b)が実験番号2のモデル同定部で求めた値である。係数行列の振幅は、対角要素では同程度であるにもかかわらず、非対角要素では数倍から十数倍、実験番号2の方が大きくなっていることがわかる。ただし、電極1と電極4のクロス項は、実験番号2の方が電極間距離が大きくなるため、むしろ減少している。

ここで、図(b)のAR係数行列の非対称性に注意しよう。図からAR係数行列の(1, 2), (3, 2), (4, 2), (4, 3)要素は大きな値を示しているが(2, 1), (2, 3), (2, 4), (3, 4)要素は比較的小さな値をとっている。このことは、EMGの発生源(主に働いている筋)が電極2の近辺に存在していることを意味している。従って、この場合のAR係数行列はEMGの空間情報を非対角成分に含むことになる。

これに対して、電極位置が離れている場合(実験番号1, 3, 5)のARモデルの識別率は、電極位置が接近している場合に比べて、4~7%低くなっている。しかしながら、電極位置が離れているため、EMGの振幅パターンは各動作を行うときに活動する筋の違いをよく反映することになる。判別関数による識別能力がARモデルの識別率の低下を補う役目を果たすことになるのである。



(a) 実験番号1



(b) 実験番号2

図10 AR係数行列  $|A_1(1)|$  (掌屈動作, 1次)  
Fig. 10 Coefficient matrices of AR model (absolute values).

以上より、本稿で提案する動作識別法は、EMGの周波数情報、振幅情報、更に電極間のクロス情報を識別に利用することにより、電極位置を比較的自由に設定できることが明らかになった。

## 5. むすび

本手法は、多次元ARモデルの予測誤差の振幅と電極によるパターンを利用して、EMG動作識別を行うものである。これは、電極位置を比較的自由に設定することができ、電極を取りつける際のわざわしさを軽減する。

実験結果から、識別に必要なEMGは動作発生直後の100 msecとすることが可能となった。しかしながら、これ以上のEMG採取時間の削減は難しい。これ

はEMGの非定常性が問題となるためである。実際の義手使用時においては、制御者は各動作を適宜切り換えて一連の動作を行う。動作切り換えに伴うEMGの非定常性は避けられない問題である。今後はこのような問題に対処するため、非定常性を考慮した適応フィルタなどの考え方を動作識別に導入することが興味深い。また、切断者による義手制御実験、識別した動作のEMGによる比例制御<sup>(2),(3)</sup>を含めた制御系設計問題などを考察する必要があると考えている。

**謝辞** 本研究を進める上で御協力頂いた本学人間工学研究室 高橋義博君、中野謙二君(現在松下電工勤務)に感謝致します。また本研究の一部は、昭和60年度文部省科学研究費(60550300)、および財団法人マツダ財団の研究助成によるもので、ここに改めて謝意を表します。

### 文 献

- (1) L.H. Lindström and R. I. Magnusson : "Interpretation of myoelectric power spectra ; a model and its application," Proc. IEEE ,65,5, pp. 653-662 (1977).
- (2) 伊藤, 辻：“筋骨格系の双線形特性と義肢制御への応用”，電学論, 105-C, 10, pp. 201-208 (昭 60).
- (3) 伊藤, 辻, 竹根, 長町：“量子化筋電を操作量とするマン・マシン制御系の動特性”，計測自動制御学会論文集, 20, 8, pp. 747-753 (昭 59).
- (4) R. N. Scott : "Myoelectric energy spectra", Med. and Biol. Eng., 5, pp. 303-305 (1967).
- (5) E. Kwanty, D. H. Thomas and H. G. Kwanty : "An application of signal processing technique to the study of myoelectric signals", IEEE Trans. Biomed. Eng., BME-17, pp. 303-313 (1970).
- (6) D. Graupe, J. Magnussen and A. A. M. Beex : "A micro-processor system for multifunctional control of upper limb prostheses via myoelectric signal identification", IEEE Trans. Autom. Control., AC-23, pp. 538-544 (1978).
- (7) P. C. Doershuk, D. E. Gustafson and A. S. Willsky : "Upper extremity limb function discrimination using EMG signal analysis", IEEE Trans. Biomed. Eng., BME -30 ,1, pp. 18-29 (1983).
- (8) 山田, 丹羽, 内山：“筋電の周波数成分と振幅成分を用いた義手制御”，ME誌, 18, 2, pp. 133-138 (昭 55).
- (9) D. Graupe and W. K. Cline : "Functional separation of EMG signal via ARMA identification methods for prosthesis control purpose", IEEE Trans. Syst., Man & Cybern., SMC-5, 2, pp. 252-259 (1975).
- (10) S. Lee and G. N. Saridis : "The control of a prosthetic arm by EMG pattern recognition", IEEE Trans. Autom. Control., AC-29 ,4, pp. 290-302 (1984).
- (11) 有本卓：“信号・画像のディジタル処理”，産業図書(昭 55).

- (12) 奥野, 久米, 芳賀, 吉沢：“多変量解析法”，日科技連(昭 46).
- (13) M. H. Sherif, R. J. Gregor and J. Lyman : "Effects of load on myoelectric signals : the ARIMA signal processing; optimal estimation applied to electromyography, part 1&2", IEEE Trans. Biomed. Eng., BME-27 ,7, pp. 382-410 (1980).
- (14) 磯田, 大野：“FORTRANによる数値計算ハンドブック”，オーム社(昭 46).

(昭和61年7月16日受付)

### 辻 敏夫



昭和34年生。60年広島大学大学院工学研究科博士課程前期システム工学専攻修了。同年同大学工学部助手、生体工学、マン・マシン・システムに関する研究に従事。電気学会、計測自動制御学会、日本人間工学会各会員。

### 伊藤 宏司



昭和19年生。44年名古屋大学大学院修士課程修了。45年同大学工学部助手、54年広島大学工学部第2類(電気系)助教授、現在に至る。工学博士。医用電子・生体工学、マン・マシン・システムの研究に従事。電気学会、計測自動制御学会、ME学会、ロボット学会各会員。昭和53年度電気学会論文賞受賞。

### 長町 三生



昭和11年生。38年広島大学大学院教育学研究科博士課程修了、文学博士。39年同大学工学部助手、43年同助教授、53年同教授。人間工学、認知科学、OA、ロボットの研究に従事。日本人間工学会、計測自動制御学会、情報処理学会、日本ロボット学会、自動車技術会各会員。