

EMG 信号を利用した 手動制御型人間支援マニピュレータ

福田 修* 辻 敏夫* 金子 真*

A Human Supporting Manipulator Based on Manual Control Using EMG Signals

Osamu Fukuda*, Toshio Tsuji* and Makoto Kaneko*

This paper discusses an EMG based control method of a robotic manipulator as an adaptive human supporting system, which consists of an arm control part and a hand and wrist control part. The arm control part controls joint angles of the manipulator's arm according to the position of the operator's wrist joint measured by a 3D position sensor. The hand and wrist control part selects an active joint out of four joint degrees of freedom and controls it according to EMG signals measured from a human operator. A distinctive feature of our method is to use a statistical neural network for EMG pattern classification. This network can acquire stochastic representation of measured EMG patterns through learning based on the log-linearized Gaussian mixture model, so that it can adapt changes of the EMG patterns according to the differences among individuals, different locations of the electrodes, time variation caused by fatigue or sweat, and so on. It is shown from the experiments that the EMG patterns during hand and wrist motions can be classified sufficiently by using the network. It may be useful as an assistive device for handicapped persons.

Key Words: Human-Robot Interface, Human Support, Neural Network, EMG

1. ま え が き

これまでロボットは主に工場や危険な作業空間などの特定の領域で使われることが多かったが、将来の高齢化社会や障害者問題などについて考えると、高齢者や障害者を含む人間を支援するために、作業空間を一般の生活領域まで広げていくことが必要であろう。もし、高度に知能化されたロボットが開発され、そのようなインテリジェントロボットが障害者の生産活動を支援したり、日常生活における身の回りの補助をできれば、多くの障害者にとって有益であることは間違いない[1]。

人間の運動能力には様々なレベルが存在するし、障害にもその度合いに大きな個人差がある。また、一人の人間に関しても加齢効果やリハビリテーション訓練等により、運動能力が大きく変化する場合がある。ロボットを用いてそのような様々な人間を支援することを考える場合、運動能力レベルに柔軟に対応可能な高度の適応機能が必要であろう[2]。本論文では、このような人間に対する適応機能を有し、労働や生産活動を支援することが可能なマニピュレータシステムの構築を目的としている。

今までにもロボットによる人間支援に関する研究が数多く行われている[3]~[9]。この分野の研究は、ロボットを利用して人

間の機能を拡張するタイプの研究と、何らかの原因で低下した/失った人間の機能を回復させる/補助するタイプの研究に大別することができる。例えば、機能拡張に関する研究として、Kazerooni [3] は人間の力を増幅するために Extender と呼ばれるロボットを人体に装着することを提案しており、Extender と人間と環境からなる閉ループシステムが十分な安定性を有することをシミュレーションや実験により確かめている。また、物体を運ぶ際などの人間とロボットの協調作業についても、Al-Jarrah ら [4] や Kosuge ら [5] のコンプライアンス制御を利用した方法が提案されている。

機能回復/補助に関する研究としては、障害者のリハビリテーションにロボットを利用する試みが数多くなされてきた[6]~[9]。例えば Salter [6] は手術後の関節に装着して受動的な関節屈曲伸展運動を持続的に行う CPM (Continuous Passive Motion) 装置を提案した。Noristugu ら [7] は、生体の筋と類似した特性を有するゴム人工筋を利用して、身体への負担が少なく安全なリハビリテーション支援ロボットを構成した。Krebs ら [8] は、インピーダンス制御されたロボットを利用して運動感覚の神経機能を訓練するリハビリテーションシステムを開発した。また、Ouerfelli ら [9] は障害者の生活支援を目的として車椅子に空気圧駆動式のロボットアームを取り付けることを提案している。しかしながら、従来研究で提案された人間支援ロボットの多くは、操作者の特性に学習的に適応するような機構

原稿受付 1999年3月29日

*広島大学工学部

*Faculty of Engineering, Hiroshima University



Fig. 1 Picture of the human supporting manipulator

を備えておらず、特に障害者支援に関するロボットの場合には、はじめから各障害者個人に合わせて設計されていることも多い。またこれらのロボットの多くは、上肢や下肢への装着や接触を前提としており、長時間にわたって使用する場合には重量や大きさが負担となることも考えられる。

一方、体肢を切断した障害者の動力義肢の制御手段として、あるいはほとんど身動きができない重度障害者の外部環境へのインタラクションの手段として、脳波 (EEG) や筋電位 (EMG) などの生体信号の利用が近年試みられている。例えば、人間の筋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、運動の柔らかさはどの程度かなどの有益な情報を数多く含んでおり、それらを利用して自然な感覚で操作可能なヒューマン・インタフェースを構築できる可能性がある [10] ~ [16]。この問題に対し我々は先に、ニューラルネットを用いた生体信号のパターン識別を行い、その識別結果をロボットマニピュレータなどの制御手段として用いることを検討してきた [13] ~ [16]。

本論文では、操作者の生活を支援可能なインテリジェントロボットの構築を目的とし、生体信号を利用した手動制御型のロボットマニピュレータ制御システムを試作した。このシステムは、ニューラルネットを利用した EMG パターンの学習・識別機能を有しており、操作者に関する個人差、電極位置や疲労、発汗などに伴う EMG 信号の時間変動に適應できる。

2. 手動制御型人間支援マニピュレータの構成

ロボットマニピュレータの制御を行っている様子を Fig. 1 に示す。マニピュレータのアームには Move Master RM-501 ((株)三菱電機製)、エンドエフェクタには超音波モータ駆動型動力義手 (今仙技術研究所製) [12] を用いた。大きさは最大回転半径が 60 [cm] 程度で非常にコンパクトである。エンドエフェクタは簡単に着脱が可能であり、前腕部切断者が屋外で使用する場合は、これを断端部に装着して使用することも可能である。

Fig. 2 (a), (b) にマニピュレータ全体、および前腕部のリンクモデルを、(c) に上腕制御における操作者とマニピュレータの関係を示す。マニピュレータは全体で 7 自由度を有しており、第




Fig. 2 A link model of the manipulator




Fig. 3 Components of the system

1 リンクから第 3 リンクまでを上腕部、それより先を前腕部とする (Fig. 2 (a))。関節角度 $\theta_1, \theta_2, \dots, \theta_7$ の定義は Fig. 2 (a), (b) に示すとおりで、これらの姿勢のときに全関節角が 0° になるものとする。制御システムは、Fig. 3 に示すように上腕制御部と前腕制御部から構成され、上腕制御部が Move Master の 3 関節 (J_1, J_2, J_3)、前腕制御部が Move Master の 1 関節 (J_4) および動力義手の 3 関節 (J_5, J_6, J_7) を制御する。操作者は、3D センサと EMG 測定用電極を装着し、自身の手首位置を移動することや筋収縮レベルを調節することで直感的にマニピュレータを操作する。

2.1 上腕制御部

上腕制御部では磁気を利用した三次元位置センサ ISOTRACK II (POLHEMUS 社製) を入力装置として用いる。この装置は、センサ自身の位置 $(x_0, y_0, z_0)^T$ を位置精度 ± 2.4 [mm] で計測することができる。環境磁場には弱いもののカメラシステムで問題になるオクルージョンなどがなく操作者が自由に腕の姿勢をとれることは大きな利点である。

操作者は、このセンサを手首に装着する。そして、得られる計測値 $(x_0, y_0, z_0)^T$ に対応して、マニピュレータの第 4 関節の目標位置 $(X_1, Y_1, Z_1)^T$ (J_4 : Fig. 2 (c) 参照) を次式により計算する。

$$\begin{pmatrix} X_1 \\ Y_1 \\ Z_1 \end{pmatrix} = c \begin{pmatrix} x_0 \\ y_0 \\ z_0 \end{pmatrix} \quad (1)$$

ただし, $c = \text{diag}[c_x, c_y, c_z]$ はゲイン行列で, これにより操作者の動作に対するマニピュレータの動作感を調節できる. 次に, この第 4 関節の目標位置に対応する上腕の各関節角度 ($\theta_1, \theta_2, \theta_3$) を計算し, それを実現するように PID 制御を行う. 操作者の手首の運動とエンドエフェクタの運動を対応させることにより直感的な上腕制御が可能となる.

2.2 前腕制御部

Fig. 4 にエンドエフェクタとして利用した超音波モータ駆動型義手 [12] の写真を, Table 1 にその仕様を示す. 大きさは成人の手とほぼ同サイズであり, 重量は約 1 [kg] である. この義手は, 3 関節 (J_5, J_6, J_7 : 手首の回内/回外, 尺屈/橈屈, 手の開閉) を有しており, 各軸に超音波モータ ((株) 新生工業製) を 1 個ずつ使用している. また, J_5 軸にはエンコーダ, J_6, J_7 の 2 軸にはポテンショメータが角度センサとして取り付けられている. 超音波モータのドライバは電圧/周波数コンバータを内蔵しており, 電圧指令値を変化させることで駆動速度を制御することが可能である. 超音波モータは, その駆動周波数領域から駆動音がほとんど人の耳に聞こえないため, 操作時の不快音を減少することができる. また低回転で高トルクを発生できることや, 駆動電力の供給を停止すると自己保持トルクにより駆動軸をロックできることなど, 優れた特性を有する.




Fig. 4 Picture of the end effector

Table 1 Specifications of the end effector

Joint	Motions	Movable range	Holding force	Gear ratio
J_5	Spination/pronation	360°	6.9 [kg·cm]	5.8
J_6	Radial flexion/ulnar flexion	60°	9.0 [kg·cm]	7.5
J_7	Grasp/Open	120°	9.0 [kg·cm]	30.1




Fig. 5 Forearm control part

前腕制御部の構成を Fig. 5 に示す. ここでは, 操作者の EMG 信号から意図する動作とその力を推定し, それらの情報に基づいて前腕部の各関節角度 ($\theta_4, \dots, \theta_7$) を制御する. ここで θ_4 は Move Master の J_4 関節角度に, $\theta_5 \sim \theta_7$ は義手の $J_5 \sim J_7$ 関節角度にそれぞれ対応する.

EMG 信号は筋線維が発生するスパイク電位の総和であり, ある統計分布に従う確率信号と考えることができる. そこで, この信号の識別には, 辻らが提案したフィードフォワード型ニューラルネットの一種である Log-Linearized Gaussian Mixture Network [17] (以下 LLGMN と略記) を用いた. このネットワークは, 混合正規分布モデル (Gaussian mixture model: 以下 GMM と略記) をネットワーク構造に展開しており, 統計的パターン識別の考え方に基づいて EMG 信号から動作識別を行うことができる (付録参照). また, この混合正規分布モデルは, 複雑な形状の統計分布に対しても複数の正規分布の線形和で近似することができ, 高いモデル化能力を有する.

2.2.1 特徴抽出処理

まず, L 対の電極から測定した EMG 信号を各チャンネルごとにアナログの全波整流回路および二次のパワースフィルタ回路 UAF42 (カットオフ f_{cut} [Hz], BURR-BROWN 社製) に通す. そして平滑した信号をサンプリング周波数 100 [Hz] で採取し, n 番目のサンプルを $EMG_l(n) (l = 1, \dots, L)$ とする. 次に, この $EMG_l(n)$ を全チャンネルの和が 1 となるように正規化し, パターン識別に用いる第 n 番目の入力ベクトル $x(n) \in \mathcal{R}^L$ の各要素 $x_l(n) (l = 1, \dots, L)$ を求める.

$$x_l(n) = \frac{EMG_l(n) - \overline{EMG}_l^{st}}{\sum_{l'=1}^L (EMG_{l'}(n) - \overline{EMG}_{l'}^{st})} \quad (l = 1, \dots, L) \quad (2)$$

ただし, $\overline{EMG}_l^{st}$ は安静時に測定した $EMG_l(n)$ の平均値である. また, 入力ベクトル $x(n)$ に対する筋力情報として,

Table 2 Structure of the LLGMN

The 1st layer	Number of units	H
	Input	$X_h(n)$
	Output	$^{(1)}O_h(n)$
	I/O function	Identity function
The 2st layer	Number of units	$\sum_{k=1}^K M_k$
	Input	$^{(2)}I_{k,m}(n) = \sum_{h=1}^H ^{(1)}O_h(n)w_h^{(k,m)}$
	Output	$^{(2)}O_{k,m}(n)$
	I/O function	Generalized sigmoid function [see (6)]
The 3st layer	Number of units	K
	Input	$^{(3)}I_k(n) = \sum_{m=1}^{M_k} ^{(2)}O_{k,m}(n)$
	Output	$Y_k(n)$
	I/O function	Identity function
Weight coefficients from 1st layer to 2nd layer		$W_h^{(k,m)}$
Weight coefficients from 2nd layer to 3rd layer		1

$$F_{EMG}(n) = \frac{1}{L} \sum_{l=1}^L \frac{EMG_l(n) - \overline{EMG}_l^{st}}{\overline{EMG}_l^{max} - \overline{EMG}_l^{st}} \quad (3)$$

を定義する．ここで $\overline{EMG}_l^{max}$ は，最大随意筋収縮時の $EMG_l(n)$ の平均値である．

2.2.2 パターン識別処理

パターン識別処理には LLGMN を用いる．各層における信号の入出力関係・ウェイト変数などを Table 2 に示す．まず，GMM の各コンポーネントに対応する正規分布を線形演算で表現するために，入力ベクトル $x(n)$ を次式に従って変数変換する．

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

ニューラルネットの第 1 層はこの新たな入力ベクトル $X(n)$ の次元数 $H = 1 + L(L+3)/2$ に合わせて H 個のユニットから構成される．各ユニットの入出力関数には恒等関数を用いており，第 1 層のユニット h は入力 $X_h(n)$ をそのまま $^{(1)}O_h(n)$ として出力する．

次に，この第 1 層の出力 $^{(1)}O_h(n)$ に重み $w_h^{(k,m)}$ が掛け合わされ第 2 層に伝えられる．第 2 層は， $\sum_{k=1}^K M_k$ (M_k : 前腕動作 k に対する GMM のコンポーネント数) 個のユニットで構成され，ユニット $\{k, m\}$ の入出力を $^{(2)}I_{k,m}(n)$ ， $^{(2)}O_{k,m}(n)$ とするとそれらの関係は，

$$^{(2)}I_{k,m}(n) = \sum_{h=1}^H ^{(1)}O_h(n)w_h^{(k,m)} \quad (5)$$

$$^{(2)}O_{k,m}(n) = \frac{\exp[^{(2)}I_{k,m}(n)]}{\sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \exp[^{(2)}I_{k',m'}(n)]} \quad (6)$$

となる．上式は，混合正規分布モデルに含まれる各正規分布が，入力ベクトル $X(n)$ ($= ^{(1)}O(n)$) と第 1, 2 層間の重みベクトル $w^{(k,m)}$ の線形計算 (式 (5)) と一般化シグモイド

関数 (式 (6)) で表現できることを示している [17]．ただし， $w_h^{(K, M_K)} = 0$ ($h = 1, 2, \dots, H$) とする．

第 3 層は，識別対象の前腕動作数と同じ K 個のユニットから構成される．ユニット k は，第 2 層の M_k 個のユニットと結合しており，それらのユニットから出力される $^{(2)}O_{k,m}(n)$ の和を $Y_k(n)$ として出力する．この第 3 層ユニットの出力値は各前腕動作に対する事後確率に対応している．

次に，このネットワークの学習法について説明する．いま， n 番目の入力ベクトル $x(n)$ に対して，教師信号ベクトル $T(n) = [T_1(n), \dots, T_K(n), \dots, T_K(n)]^T$ が与えられた場合を考える． $T_k(n)$ は，事象が k であるときに 1，それ以外のときは 0 をとる．LLGMN 部は， N 個のサンプルデータ $x(n)$ ($n = 1, \dots, N$) を用いて，対数尤度を最大化するように学習を行う [17]．LLGMN 部の出力値 $Y_k(n)$ が事後確率 $P(k|x(n))$ に対応することを考慮すると，評価関数 J としては，

$$J = - \sum_{n=1}^N \sum_{k=1}^K T_k(n) \log Y_k(n) \quad (7)$$

を用い，これを最小化するように学習を進めればよい．ここでは，学習の収束時刻を待つことになる操作者の精神的負担を少しでも軽減することを目的として，Zak [18] が提案したターミナルアトラクタ (Terminal Attractor: 以下 TA と略記) を学習則に導入し，収束時間の上限値を指定できるようにした [14] ~ [16]．

学習には，マニピュレータの制御開始前に行うオフライン学習と制御中に行うオンライン学習の 2 種類がある．オフライン学習では，制御前にあらかじめ対象とする各動作を順番に行い，その際に得られるパターンベクトル $x(n)$ について学習を行う．また，オンライン学習は，制御中の EMG 信号の変化に適應するために行う．

2.2.3 識別判定処理

マニピュレータの制御を行う際に誤動作が生じてしまったら，目的の動作が達成できないばかりか危険な事故にもつながりかねない．このような誤動作を防止するために，LLGMN の出力のエントロピーを利用して識別判定処理を行う．エントロピー

は、情報のあいまいさを表す評価値であり、この値を利用することで、あいまいな識別を防ぐことができ、誤動作をソフト的に抑えることができる [13]。

まず、LLGMN の出力層ユニットの各出力が前腕部の各動作に対する事後確率を示していることから、次式よりエントロピーを計算する。

$$H(n) = - \sum_{k=1}^K Y_k(n) \log_2 Y_k(n) \quad (8)$$

そして、このエントロピーに基づく識別保留を行うために、 $H(n)$ を設定したしきい値 H_d と比較する。このとき $H(n) < H_d$ であれば、出力 $Y_k(n) (k=1, \dots, K)$ が最大となるユニットに対応する動作を識別動作とし、もし $H(n) \geq H_d$ であれば、あいまいな識別として識別を保留する。また、動作発生タイミングを調べるために、各チャンネルの $EMG_i(n)$ の自乗和を設定したしきい値 M_d と比較する。そして、しきい値を超えて動作発生と判定された場合には識別動作を実行する。この際、特徴抽出処理で抽出した筋力情報 $F_{EMG}(n)$ の大きさに従ってモータの駆動速度を比例的に制御する。各軸の最高駆動速度は J_7 軸が $0.5 [\text{rad/sec}]$ 、 $J_4 \sim J_6$ 軸が $1.0 [\text{rad/sec}]$ である。

2.2.4 オンライン学習処理

ここでは、マニピュレータ制御時に行うオンライン学習について説明する。長時間にわたって制御を行っているとき、操作者の疲労や発汗および電極のずれなどにより EMG パターンが変化してしまう場合がある。そのため、制御開始時にオフライン学習を行っただけでは時間が経過するとともに誤識別を生じやすくなる。そこで徐々に変化する EMG パターンに適応するために、制御を行っている間も一定時間を経過するごとにオンラインの学習を実行する [13]。

しかしながら、マニピュレータ制御中は操作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ができない。そこで、次々と与えられる 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操作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の重み係数の修正を行う。

ここで、この識別結果の明確さを計る尺度として式 (8) のエントロピー $H(n)$ を利用した。EMG パターン識別時のネットワーク出力のエントロピー $H(n)$ に対し、オンライン学習しきい値 H_o を設定し、 $H(n)$ がこの値より小さいとき、その EMG パターン $x(n)$ を学習用データの集合に加える。対応する教師信号としては明確に識別された動作に 1 を、他の動作に 0 を与える。そして、その動作に対応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。ただし、重み係数の急激な変化を避けるため、再学習は TA を用いない通常の誤差逆伝播法で行い、10 回の繰り返し学習の後に評価関数 J が減少しない場合は、重み係数の修正や学習データの更新は行わなかった。

3. 実験

構築したシステムを用いたマニピュレータの制御実験を行った。電極は前腕部に 4 対、上腕部に 2 対装着 ($L=6$) し、アナログ

パワースフィルタ回路のカットオフ周波数を $f_{cut} = 1.0 [\text{Hz}]$ 、動作発生の判定しきい値を $M_d = 0.3$ とした。上腕制御部の制御周期は、三次元位置センサのサンプリング周期と同じ $60 [\text{Hz}]$ で、前腕制御部の制御周期は $100 [\text{Hz}]$ である。被験者は男子大学生の健常者で 4 人 (A, B, C, D) とした。ただし、A, B はすでに何度か本システムの制御経験を有しており、特に A は制御の習熟度が高い。一方 C, D は本システムの制御経験がまったくなく、今回が初めての実験であった。C, D に関しては実験開始前に 5 分程度の簡単な制御練習を行い、その後データを採取した。

3.1 EMG 制御実験

まず、EMG 信号に基づく動作識別能力の検証実験を行った。被験者は A で、対象動作数を Fig. 6 に示す 8 動作 ($K=8$)、学習データ数を $N=160$ 、識別判定しきい値およびオンライン学習しきい値をそれぞれ $H_d = 0.55$ 、 $H_o = 2.0$ と設定した。Fig. 7 はこのときの前腕制御部における信号処理の様子を示しており、上から EMG 信号、筋力情報 $F_{EMG}(n)$ 、エントロピー $H(n)$ 、識別結果を示している。グラフ最上部、および識別結果の縦軸に示したラベルは、Fig. 6 と一致している。また SUS は、識別判定処理により識別保留となったサンプルを表す。図から EMG 信号に基づく動作識別が精度よく行われていることが分かる。また動作の開始・終了時の不安定な EMG 信号パターンの識別についても、エントロピーを利用することで




Fig. 6 Forearm motions used in the experiments




Fig. 7 An example of the forearm control based on the EMG signal




Fig. 8 Improvements of motion discrimination rates by on-line adaptive learning

誤識別を回避している。

3.2 オンライン適応能力

次に、前腕制御部におけるオンライン学習や識別保留処理の効果を調べた。被験者は A で、対象動作数を $K = 8$ (Fig. 6 参照), 学習データ数を $N = 160$, 識別判定しきい値およびオンライン学習しきい値をそれぞれ $H_d = 0.55$, $H_o = 2.0$ と設定した。実験時間は約 120 分間で、その間一定の間隔で動作識別を行った。この際、被験者には識別結果を知らせなかった。これは識別結果を知らせることで、被験者自身が学習したり、誤識別を避けようとして EMG パターンを意図的に変化させる可能性を避けるためである。

Fig. 8 に識別結果を示す。ここでは図中に示すように、オンライン学習と識別保留の有無により I, II, III, IV の 4 条件で識別を行い、10 分おきに識別率と誤識別の累積を計算した。IV のオンライン学習と識別保留をとも行わない場合には、時間の経過とともに識別精度が低下することが分かる。この原因は、電極のズレや疲労・発汗などの影響が考えられる。これに対し、I と II ではオンライン学習を行うことで時間が経過しても識別率の低下が抑えられている。また、I と III ではエントロピーを利用して誤識別を回避することで識別率が向上している。特に、オンライン学習と識別保留の両方を行った I は極めて高い識別精度を実現している。

さらに、ほかの 3 人の被験者 (B, C, D) に対してもこれらの効果を確かめた。ただし、被験者 C, D にとって今回が初めての制御体験であることを考慮して、対象動作数は Fig. 6 から UF: ulnar flexion, RF: radial flexion を除く $K = 6$ に限定し、学習データ数を $N = 120$ とした。また、識別判定しきい値とオンライン学習しきい値はそれぞれ $H_d = 0.47$, $H_o = 1.7$ と設定した。被験者は任意のタイミングで対象動作を繰り返し実行し、900 試行分のデータを採取した。この際、被験者には識別結果を知らせていない。実験結果を Fig. 9 (a) (b) に示す。識別条件は I, IV とし、100 試行ごとに計算した識別率をプロットしている。実験に要した時間は、被験者 B, C, D それぞれ 41.3, 64.4, 75.6 [min] であった。この図から、実験開始直後は 3 人とも高い識別精度を実現していることが分かる。特に、オンライン学習と識別保留を行わない場合 (b) よりも、それら両方を行う場合 (a) が極めて識別率が高い。また (b) では時間が経過するにつれて識別率が低下する傾向にあるが、(a) ではその低下が抑制されており、高い識別精度が保たれている。




Fig. 9 Classification results for three subjects




Fig. 10 Motion pictures while controlling the manipulator

3.3 三次元位置センサの効果

前節では、EMG 信号に基づく前腕動作識別能力を明らかにした。しかしながら、マニピュレータのアーム全体を三次元空間内に位置決めすることを考えると、EMG 信号だけでアームを制御することは現状では難しい。これに関して本論文では、EMG 信号に加えて三次元位置センサの情報を利用する制御法を提案した。このセンサを導入することで、特別な制御技術が必要としない直感的な操作が実現できる。

ここでは、三次元位置センサ情報に基づくマニピュレータの上腕制御実験を行った。Fig. 10 (a) (b) に、その際の連続写真を示す。三次元位置センサは操作者の手首関節に取り付け、入力ゲインを $c_x = c_z = 1.0$, $c_y = 0.5$ とした。(a) では、上腕部のみの制御、(b) では上腕部の姿勢を一定に制御しながら EMG 信号に基づく前腕部の制御を行っている。○印は、操作者の手

首関節位置と J_4 関節位置の移動軌跡を 0.1 [sec] ごとにプロットしたものである。(a) では、操作者の手首関節位置に対応してマニピュレータの J_4 関節が移動しており、上腕部全体の大きな動きを実現している。(b) では、EMG 信号による前腕制御を行いながらも、操作者の手首位置を一定に保つことで上腕部の姿勢を維持している。マニピュレータの動作が操作者の動作に対してわずかに遅れているのは、PID 制御のフィードバックゲインをやや小さめに設定したためである。

4. 結 言

本論文では操作者の生活支援などに利用可能なロボットマニピュレータを構築することを目的とし、生体信号を利用した制御システムを試作した。EMG パターン識別には LLGMN を利用し、その動作識別能力を実験により確かめた。実験の結果、LLGMN の出力から計算されたエントロピーに基づく識別保留が誤識別の回避に有効なことや、オンライン学習が長時間の識別精度維持に効果的であることが示された。また、この動作識別結果と 3D 位置センサからの情報を利用したマニピュレータ制御を提案し、自然で直感的な制御感覚を確認することができた。

構築したシステムの最も有用な使用例としては、上肢切断者が家庭内において義手の代わりとして使用することが考えられる。切断者にとって、自身の意のままに操れるマニピュレータは、日常生活を向上させるのに大変有効であろう。本システムでは、義肢や装具を身体に装着する必要がないため、一般の義肢装具に比べて負担が少なく、比較的長時間の作業にも有効である。

今後は、本システムの有効性を確かめるために切断者を対象としたフィールドテストを計画している。また、本システムを応用したリハビリテーションシステムの構築についても検討していく予定である。なお、本研究の一部は(財)大川情報通信基金、および文部省科学研究費補助金(11555113, 11650450)によるものでここに改めて謝意を表します。

参 考 文 献

- [1] W.A. Gruver: "Intelligent Robotics in Manufacturing, Service, and Rehabilitation: An Overview," IEEE Transactions on Industrial Electronics, vol.41, no.1, pp.4-11, 1994.
- [2] K. Tsukamoto and T. Tsuji: "An Approach to Adaptive Human Support System," Proceedings of IEEE International Workshop on Robot and Human Communication, pp.195-200, 1998.
- [3] H. Kazerooni: "Human-Robot Interaction via the Transfer of Power and Information Signals," IEEE Transactions on Systems and Cybernetics, vol.20, no.2, pp.450-463, 1990.
- [4] O.M. Al-Jarrah and Y.F. Zheng: "Arm-Manipulator Coordination for Load Sharing Using Compliant Control," Proceedings of IEEE International Conference on Robotics and Automation, pp.1000-1005, 1996.
- [5] K. Kosuge, Y. Fujisawa and T. Fukuda: "Control of Mechanical System with Man-machine Interaction," Proceedings of the IEEE International Conference on Intelligent Robots and Systems, vol.1, pp.87-92, 1992.
- [6] R.B. Salter: "Clinical application of Basic Research on Continuous Passive Motion for Disorders and Injury of Synovial Joints. A Preliminary Report of a Feasibility Study," J. Orthop. Res., no.1, pp.325-342, 1984.
- [7] T. Noritsugu, T. Tanaka and T. Yamanaka: "Application of Rubber Artificial Muscle Manipulator as a Rehabilitation Robot," Proceedings of IEEE International Workshop on Robot and Human Communication, pp.112-117, 1996.
- [8] H.I. Krebs, N. Hogan, M.L. Aisen and B.T. Volpe: "Application of Robotics and Automation Technology in Neuro-Rehabilitation," Proceedings of Japan/USA Symposium on Flexible Automation, vol.1, pp.269-275, ASME, 1996.
- [9] M. Ouerfelli, V. Kumar and W. Harwin: "An Inexpensive Pneumatic Manipulator for Rehabilitation Robotics," Proceedings of IEEE International Conference on Robotics and Automation, pp.636-641, 1993.
- [10] 小池, 川人: "表面筋電信号を入力とするダイナミクスモデルを用いたヒューマンインタフェース", 電子情報通信学会論文誌 A, vol.79, no.2, pp.363-370, 1996.
- [11] 平岩, 内田, 下原, 曾根: "筋電操作ハンドの制御のための皮膚表面筋電信号のニューラルネットによる認識", 計測自動制御学会論文集, vol.30, no.2, pp.216-224, 1994.
- [12] 伊藤(宏), 永岡, 辻, 加藤, 伊藤(正): "超音波モータを用いた 3 自由度前腕筋電義手", 計測自動制御学会論文集, vol.27, no.11, pp.1281-1289, 1991.
- [13] 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.
- [14] 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, vol.29, no.1, pp.60-72, 1999.
- [15] 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, vol.117-C, no.10, 1997.
- [16] O. Fukuda, T. Tsuji and M. Kaneko: "An EMG Controlled Robotic Manipulator Using Neural Networks," Proceedings of IEEE International Workshop on Robot and Human Communication, pp.442-447, 1997.
- [17] 辻, 市延, 金子: "混合正規分布モデルを用いたフィードフォワード型ニューラルネット", 電子情報通信学会論文誌 D-II, vol.77, no.10, pp.2093-2100, 1994.
- [18] M. Zak: "Terminal Attractors for Addressable Memory in Neural Networks," Physics Letters A, vol.133, pp.18-22, 1988.
- [19] J.H. Wolfe: "Pattern clustering by multivariate mixture analysis," Multivariate Behav. Res., vol.5, pp.329-350, 1970.

付録 LLGMN について

ここでは、混合正規分布モデル、およびそれを内包した LLGMN によるパターン識別について説明する [17]。一般にパターン識別で用いられる入力データは、ある確率分布に従う確率変数である。この場合、入力データが従う事後確率分布を精度よく求めることができればパターン識別が実現できるので、パターン識別問題は通常、確率分布同定問題に帰着できる。ここで紹介する混合正規分布モデルは、正規分布に従う有限個のコンポーネントの線形和で、データが従う確率分布を近似するセミパラメトリック法の一つである [19]。

例として、特徴ベクトル $x \in \mathcal{R}^d$ を K 種類の動作に識別する問題を考えよう。ここで複数の動作が同時に起こることはないとする。事後確率が最大となる動作を識別動作として選択することでパターン識別が実現できる。特徴ベクトル x が入力されたもとで動作 k が生起する事後確率 $P(k|x)$, $k = 1, \dots, K$ は、生起確率密度関数に混合正規分布を用いれば、

$$P(k|x) = \sum_{m=1}^{M_k} P(k, m|x) \quad (9)$$




Fig. 11 Gaussian Mixture Model

$$P(k, m|x) = \frac{\alpha_{k,m} g(x; \mu^{(k,m)}, \Sigma^{(k,m)})}{\sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \alpha_{k',m'} g(x; \mu^{(k',m')}, \Sigma^{(k',m')})} \quad (10)$$

となる。ただし $P(k, m|x)$ は、混合正規分布モデルにおけるコンポーネント (k, m) の事後確率、 $g(x; \mu^{(k,m)}, \Sigma^{(k,m)})$ は、平均ベクトル $\mu^{(k,m)} = (\mu_1^{(k,m)}, \dots, \mu_d^{(k,m)})^T$ 、共分散行列 $\Sigma^{(k,m)-1} = [s_{ij}^{(k,m)}]$ の d 次元正規分布、 $\alpha_{k,m}$ は混合度を示している (Fig. 11 参照)。ここで、式 (10) の右辺の分子の対数を取り、それを $\xi_{k,m}$ とおくと、 $\xi_{k,m} \triangleq \log \alpha_{k,m} g(x; \mu^{(k,m)}, \Sigma^{(k,m)}) = \beta^{(k,m)T} X$ となる。ただし、 $X \in \mathbb{R}^H$ 、および $\beta^{(k,m)} \in \mathbb{R}^H$ は、次式のように記述される。

$$X = (1, x^T, x_1^2, x_1 x_2, \dots, x_1 x_d, x_2^2, x_2 x_3, \dots, x_2 x_d, \dots, x_d^2)^T, \quad (11)$$

$$\beta^{(k,m)} = \left(\beta_0^{(k,m)}, \sum_{j=1}^d s_{j1}^{(k,m)} \mu_j^{(k,m)}, \dots, \sum_{j=1}^d s_{jd}^{(k,m)} \mu_j^{(k,m)}, -\frac{1}{2} s_{11}^{(k,m)}, -\frac{1}{2} s_{12}^{(k,m)}, \dots, -\frac{1}{2} s_{1d}^{(k,m)}, \dots, -\frac{1}{2} (2 - \delta_{jl}) s_{jl}^{(k,m)}, \dots, -\frac{1}{2} s_{dd}^{(k,m)} \right)^T, \quad (12)$$

このとき、 $\beta_0^{(k,m)} = -\frac{1}{2} \sum_{j=1}^d \sum_{l=1}^d s_{jl}^{(k,m)} \mu_j^{(k,m)} \mu_l^{(k,m)} - \frac{d}{2} \log 2\pi - \frac{1}{2} \log |\Sigma^{(k,m)}| + \log \alpha_{k,m}$ とする。これらはいずれも $H = 1 + d(d+3)/2$ 次元のベクトルである。すなわち、 $\xi_{k,m}$ を係数ベクトル $\beta^{(k,m)}$ と新しく定義した入力ベクトル $X \in \mathbb{R}^H$ の積の形で表現できることが分かる。

しかしながらここで、コンポーネントの事後確率 $P(k, m|x)$ には、その総和 $\sum_{k=1}^K \sum_{m=1}^{M_k} P(k, m|x)$ が 1 となる拘束条件が存在する。また、このことより事後確率のパラメータとして $\xi_{k,m}$ は冗長とも言える。そこで、新しく変数 $Y_{k,m}$ と係数ベクトル $w^{(k,m)} \in \mathbb{R}^H$ を導入し、

$$\begin{aligned} Y_{k,m} &\triangleq \xi_{k,m} - \xi_{K, M_K} = (\beta^{(k,m)} - \beta^{(K, M_K)})^T X \\ &= w^{(k,m)T} X, \end{aligned} \quad (13)$$

とおいた。ただし、 $w^{(K, M_K)} = 0$ である。これにより $w^{(k,m)}$ を無制約の重み係数とみなすことが可能になりニューラルネットの重み係数として展開できる。このとき式 (10) の事後確率 $P(k, m|x)$ は、

$$P(k, m|x) = \frac{\exp[Y_{k,m}]}{\sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \exp[Y_{k',m'}]} \quad (14)$$

となる。

ここで、本論文における式 (5) (6) の計算が、式 (13) (14) に相当している点に注意していただきたい。以上のように LLGMN は、混合正規分布モデルをそのネットワーク構造に内包している。そして学習の際には、ネットワークの重み係数である $w^{(k,m)}$ を評価関数が最小 (尤度最大) となるように更新していくことで、学習サンプルデータの混合正規分布モデルを獲得することができる。また識別の際は、前向き計算を進めることで自然に事後確率の推定が可能となる。



福田 修 (Osamu Fukuda)

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) 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。電子情報通信学会、日本人間工学会などの会員。日本学術振興会特別研究員。(日本ロボット学会学生会員)



金子 真 (Makoto Kaneko)

1954 年 1 月 18 日生。1981 年 3 月東京大学工学系研究科博士課程修了。工学博士。同年 4 月通産省工業技術院機械技術研究所入所。1990 年 4 月、九州工業大学情報工学部助教授。1993 年 10 月、広島大学教授、現在に至る。ロボットハンド、力覚センサ、触覚ベースアクティブセンシングなどの研究に興味をもつ。IEEE、計測自動制御学会、日本機械学会などの会員。(日本ロボット学会正会員)



辻 敏夫 (Toshio Tsuji)

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、1992~93 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、電気学会などの会員。工学博士。(日本ロボット学会正会員)