

事象駆動型作業モデルを利用した EMG 信号のパターン識別

辻 敏夫^{*1} 高橋 恒介^{*1} 福田 修^{*2} 金子 真^{*1}

Pattern Classification of EMG Signals Using an Event-Driven Task Model

Toshio Tsuji^{*1}, Kousuke Takahashi^{*1}, Osamu Fukuda^{*2} and Makoto Kaneko^{*1}

Electromyogram (EMG) has been often used as a control signal of a prosthetic arm, which includes information on not only muscle force but operator's motor intention and mechanical impedance of joints. Most of previous researches, however, adopted the control methods of the prosthetic arms based on the EMG pattern discrimination and/or the force estimation from the EMG signals, and did not utilize any knowledge on tasks performed by amputees such as a grasping-an-object task and a spooning-soup task. In this paper, a new EMG pattern discrimination method is proposed using a statistically organized neural network and an event-driven task model. The neural network outputs *a posteriori* probabilities of motions depending on the EMG signals. The task model is represented using a Petri net to describe the task dependent knowledge, which is used to modify the neural network's output. Experimental results show that the use of the task model significantly improves the accuracy of the EMG pattern discrimination.

Key Words: EMG Signal, Neural Network, Prosthetic Arm, Human Interface, Task Model

1. ま え が き

安全管理や事故予防の重要性が十分認識されている現代社会においても、労働災害や交通事故などで手足を切断する人が後を絶たない。このように切断を余儀なくされた人々は国内外に数多く存在し、切断部位によっては自分一人の力で労働や生産活動、さらには日常の生活すら十分に行えない場合がある。したがって、このような障害者の生産活動を支援し、日常生活における身の回りの補助を行うことが可能なロボットが開発されれば、多くの人々にとって有益であることは間違いない。

人間の運動能力には様々なレベルが存在するし、また障害にもそのレベルに大きな個人差がある。さらに、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などにより、運動能力が大きく変化する場合がある。ロボットを用いて様々な人間の支援をする場合、使用者の運動能力に柔軟に対応可能な高度な適応機能が不可欠であろう。本研究では、人間に対する適応能力を有し、日常生活や労働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最終目的としている。

切断者の活動を支援するロボットや動力義手の制御には、生体信号の一つである EMG 信号を利用する方法が一般によく用いられる。EMG 信号は人の運動意思を反映しており、力の大き

さや筋インピーダンスに関する情報を含んでいる [1] [2]。この EMG 信号を利用して、赤澤らは、指の屈筋・伸筋から計測した EMG 信号から筋張力を推定し、電動義手の制御入力として利用することを提案した [3]。Ito らは全波整流平滑後の EMG 信号から筋力を推定し、超音波モータ駆動型の前腕義手の制御を試みた [4]。また、Abul-haj and Hogan は、インピーダンス制御に基づいて動力義手の制御系を構成し、その特性を解析している [5]。

一方、動力義手制御を目的とした EMG 信号パターン動作識別に関する研究も活発に行われてきた。1970~80 年代には Graupe らの AR モデル [6] や辻らによる多次元 AR モデル [7] を用いた手法など、数多くの方法が提案されている。しかしながら、これらの研究では非線形性の強い EMG 信号を線形モデルにあてはめていたため、その識別能力に限界があった。そこで、非線形写像を学習的に獲得できるニューラルネットワークを利用する方法が Kelly ら [8] をはじめとして数多く行われている [9] [10]。これらの従来研究のほとんどが良く知られた誤差逆伝播型ニューラルネット (以下、BPNN と略記) [11] を単に利用しているのに対して、Tsuji ら [12] は混合ガウス分布モデルと対数線形モデルに基づいた Log-Linearized Gaussian Mixture Network (以下、LLGMN と略記) を新しく提案し、連続した 6 動作 (握り、開き、背屈、掌屈、回内、回外) を高い精度で識別することに成功した [14]。しかしながら、例えば食事中などによく見られるように、コップを握ったまま回内、回外動作を行うといった日常生活に必要な動作については、姿勢変化に伴って EMG パターンが大きく変化してしまうため安定した識

原稿受付 2001 年 12 月 12 日

^{*1}広島大学大学院工学研究科

^{*2}独立行政法人 産業技術総合研究所

^{*1}Graduate School of Engineering, Hiroshima University

^{*2}National Institute of Advanced Industrial Science and Technology

別を実現することは難しく、また、操作者には高い熟練度や作業への集中といった過度の負担をかけてしまう。このような問題に対して、ニューラルネットの学習機能のみで対応しようとすると、ニューラルネットの規模が膨大になり、また学習時間が大幅に増加するなどといった問題が生じる。

そこで、本論文では、動作識別に伴うすべての処理をニューラルネットだけで行うのではなく、LLGMN を利用した動作識別法に事象駆動型の作業モデルを導入することを考える。人間が行う作業は、いくつかの動作の系列に分解できる場合が多い。したがって、日常生活においてよく生じる作業については、動作系列で構成した作業モデルを用意すれば、計測した EMG 信号に基づいて操作者の作業状態を推定できると考えられる。本論文では、このようにして推定した作業状態に応じて、LLGMN を用いて計算した各動作に対する事後確率を修正し、動作を決定するという方法を提案する。これにより、対象とする作業に関する領域依存の知識を陽に表現することができ、ニューラルネットだけでは難しかった、姿勢変化に伴うあいまいな動作の識別が安定的に実現できることを示す。以下、2 章で具体的な識別方法と作業支援モデルについて説明する。そして、3 章で人間支援マニピュレータシステム [14] を用いて義手制御実験を行い、本手法の有効性を検証する。

2. 作業モデルを利用した EMG 動作識別法

本論文で提案する動作識別法の構成を Fig. 1 に示す。この方法は、EMG 信号処理部、ニューラルネット部、作業モデル部、動作決定部の四つのブロックから構成される。EMG 信号処理部は計測した EMG 信号を整流、平滑し筋力情報を推定するとともに、正規化したパターンをニューラルネット部に送る。ニューラルネット部は前処理後の EMG パターンを入力として各動作の事後確率を算出する LLGMN により構成される。作業モデル部では、ペトリネットで記述した事象駆動型モデルを用いる。このモデルは対象とした作業に応じてあらかじめ用意したもので、操作者の作業状態に応じて修正ベクトルを出力する。そして、動作決定部では、ニューラルネット部の出力である事後確率と作業モデル部の出力である修正ベクトルに基づき動作を決定する。以下、各部の詳細を述べる。

2.1 EMG 信号処理部

まず、 L 対の電極から測定した EMG 信号を A/D 変換する。そして、チャンネルごとに全波整流した後、二次のデジタルバタワースフィルタ（カットオフ周波数 f_c [Hz]）により平滑化する。このフィルタからの出力信号をサンプリング周波数 f_s [Hz] で再サンプリングし、この時系列信号を $E_l(n)$ ($l = 1, \dots, L$) とする。前腕の推定筋力としては、この信号のチャンネル平均 $E_a(n)$ を用いる。

$$E_a(n) = \frac{1}{L} \sum_{l=1}^L (E_l(n) - E_l^{st}) \quad (1)$$

ここで、 E_l^{st} は動作識別前に計測した安静時の $E_l(n)$ の時間平均である。動作識別は、全チャンネルの和が 1 となるよう正規化した特徴パターンベクトル $\boldsymbol{x}(n) = [x_1(n), x_2(n), \dots, x_L(n)]^T \in \mathcal{R}^L$

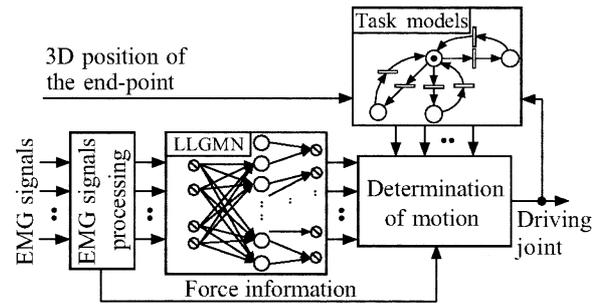


Fig. 1 EMG pattern classification

$$x_l(n) = \frac{E_l(n) - E_l^{st}}{LE_a(n)} \quad (2)$$

を用いる。

また、動作の発生を判断するために、EMG 信号の二乗和 $E_p(n)$

$$E_p(n) = \sum_{l=1}^L (E_l(n) - E_l^{st})^2 \quad (3)$$

を計算する。

2.2 ニューラルネット部

LLGMN は混合ガウス分布モデル (Gaussian mixture model: 以下、GMM と略記) を対数線形化してネットワークに展開したもので、サンプルデータが従う統計分布を学習的に推定し、 L 対の電極より抽出した EMG 信号のパターンに対応する動作の事後確率を出力する [12]。まず、GMM の各コンポーネントに対応する正規分布をニューラルネットの重み係数として表現するために、時刻 n における入力ベクトル $\boldsymbol{x}(n)$ を次式のように変数変換する。

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

ネットワークの第 1 層はこの新たに生成された入力ベクトル $\boldsymbol{X}(n)$ 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。各ユニットは恒等関数を入出力関数として用いており、入力 $X_h(n)$ をそのまま出力する。この第 1 層の出力に重み $w_h^{(k,m)}$ が掛け合わされ第 2 層に伝えられる。第 1 層の出力を ${}^{(1)}O_h(n)$ 、第 2 層のユニット $\{k, m\}$ への入力を ${}^{(2)}I_{k,m}(n)$ とし、出力を ${}^{(2)}O_{k,m}(n)$ とすると、

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

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

となる。ただし、 $w_h^{(K,M_K)} = 0$ ($h = 1, 2, \dots, H$) で、 $k = 1, 2, \dots, K$ 、 $m_k = 1, 2, \dots, M_k$ である。 K は対象とする動作の数、 M_k は動作 k に対応するコンポーネント数を表す。さらに第 3 層のユニット k は第 2 層の M_k 個のユニットと結合

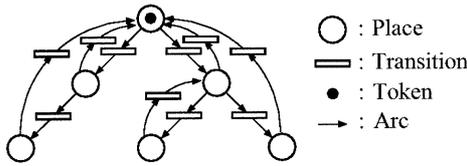


Fig. 2 Task model represented by a Petri net

しており、その入出力関係は、

$${}^{(3)}I_k(n) = \sum_{m=1}^{M_k} {}^{(2)}O_{k,m}(n) \quad (7)$$

$$Y_k(n) = {}^{(3)}I_k(n) \quad (8)$$

と表される。この第 3 層のユニットの出力値は、動作が発生したという仮定のもとでの各前腕動作に対する事後確率を与える [14]。本論文ではこの値を条件付き事後確率と呼ぶ。

2.3 作業モデル部

作業モデル部では、現在の作業状態を過去の動作履歴から推定し、作業状態に応じた修正ベクトルを出力する。本論文ではこの作業モデルを事象駆動型モデルで表現することにし、ペトリネット [13] を用いて記述する。

例えば、コップの水を飲むという作業を考えよう。この作業は、待機状態 コップを把持する コップを把持している状態 コップを傾け、水を飲む 飲んでいる状態 コップを放す 待機状態というように三つの動作と三つの状態を用いて表現することができる。そこで、これらの動作をトランジション、状態をプレース、そして作業の流れをアークとしてペトリネットを構成する。したがって作業モデルは、トランジションの集合 $T = \{t_0, t_1, \dots, t_T\}$ 、プレースの集合 $P = \{p_0, p_1, \dots, p_P\}$ 、アークの集合 $F \subseteq (P \times T) \cup (T \times P)$ 、初期マーキングの集合 $M : P \rightarrow \mathbb{N} \cup \{\omega\}$ を用いて、 $N = (P, T; F, M)$ と書くことができる [13]。ただし \mathbb{N} は非負の整数の集合、 ω は無限大を意味する記号である。また、 T, P はそれぞれトランジション、プレースの数で、本論文では初期マーキング $m_0 \in M$ は待機状態を表現するプレース p_0 にトークンを一つ置いただけの状態とする。

作業モデルの一般形を Fig. 2 に示す。図中、トークンが存在するプレースが動作の待機状態を表し、このプレースに接続した枝状の各サブネットがそれぞれの作業内容を表している。例えば、食事作業を考えると、コップで水を飲む、箸でご飯を食べるといった具体的な一連の動作系列がサブネットに対応する。このように、作業モデルをサブネットからなる樹形図状に構成することで、作業の修正や追加といった操作を比較的容易に行うことができる。

作業モデル部では、作業モデル上でトークンを移動することによって操作者の作業状態を表現し、その作業状態に応じた修正ベクトル γ_m を動作決定部へ出力する。

$$\gamma_m = [\gamma_{m0}, \gamma_{m1}, \dots, \gamma_{mK}, \gamma_{m(K+1)}]^T \quad (9)$$

$m \in \{0, 1, 2, \dots, P\}$ は作業モデル中のプレースを表す添え字で、 $\gamma_{m1}, \dots, \gamma_{mK}$ は各動作に対する修正値、 $\gamma_{m0}, \gamma_{m(K+1)}$ はそれぞれ、後述する無動作確率、動作保留確率に対する修正値を表す。

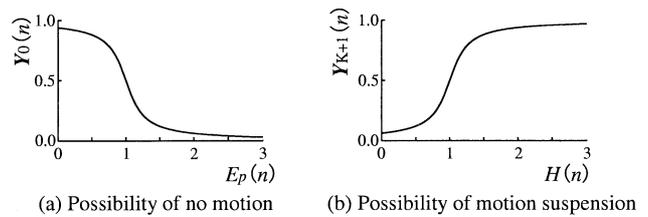


Fig. 3 Membership functions for no motion and motion suspension ($\alpha_1 = \alpha_2 = 5, \beta_1 = \beta_2 = 1$)

2.4 動作決定部

動作決定部では、ニューラルネット部と作業モデル部の出力、および EMG 信号の二乗和である $E_p(n)$ をもとに動作を決定する。ここで、ニューラルネット部で扱う各動作に加えて無動作と動作保留も対象動作として扱うことにする。

まず、無動作確率 $Y_0(n)$ を、EMG 信号処理部で推定した EMG 信号の二乗和 $E_p(n)$ を用いて以下のメンバシップ関数により定義する。

$$Y_0(n) = -\frac{1}{\pi} \tan^{-1} \{ \alpha_1 (E_p(n) - \beta_1) \} + 0.5 \quad (10)$$

ここで、 α_1, β_1 は正の定数である。筋レベル $E_p(n)$ が 0 に近い場合は、無動作確率 $Y_0(n)$ は 1 に近い値となる。逆に、 $E_p(n)$ が高い値をとると $Y_0(n)$ は 0 に近づく (Fig. 3 (a))。

一方、動作保留確率 $Y_{K+1}(n)$ は、ニューラルネット部から出力される各動作の条件付き事後確率 $Y_k(n) (k = 1, 2, \dots, K)$ から計算したエントロピー $H(n)$ を用いて以下のように表現する。

$$Y_{K+1}(n) = \frac{1}{\pi} \tan^{-1} \{ \alpha_2 (H(n) - \beta_2) \} + 0.5 \quad (11)$$

$$H(n) = -\sum_{k=1}^K Y_k(n) \log Y_k(n) \quad (12)$$

ただし、 α_2, β_2 は正の定数である。エントロピー $H(n)$ が 0 に近い場合は $Y_{K+1}(n)$ は 0 に近い値となり、逆に識別があいまいな場合のように $H(n)$ が大きくなると $Y_{K+1}(n)$ は 1 に近づく (Fig. 3 (b))。これにより、動作保留確率はニューラルネット部での動作識別の信頼性を表す指標と考えることができる。

以上の無動作確率 $Y_0(n)$ 、動作保留確率 $Y_{K+1}(n)$ 、およびニューラルネット部の出力である各動作の条件付き事後確率 $Y_k(n) (k = 1, 2, \dots, K)$ を用いて、確率 $Z_k(n) (k = 0, 1, \dots, K, K+1)$ を計算し、この $Z_k(n)$ に作業モデル部から出力される修正ベクトル γ_m を掛ける。そして最も高い値 $O_k(n)$ を示した動作を現在の動作として決定する。

$$O_k(n) = \frac{\gamma_{mk} Z_k(n)}{\sum_{j=1}^{K+1} \gamma_{mj} Z_j(n)} \quad (13)$$

$$Z_k(n) = \begin{cases} Y_k(n) & (k = 0) \\ (1 - Y_0(n))(1 - Y_{K+1}(n))Y_k(n) & (k = 1, \dots, K) \\ (1 - Y_0(n))Y_k(n) & (k = K + 1) \end{cases} \quad (14)$$

以上、ニューラルネットによる学習型の動作識別法と作業モデルで表現した領域固有の知識を統合した階層型の EMG 動作識別法を提案した。次節では識別実験により本手法の有効性を示す。

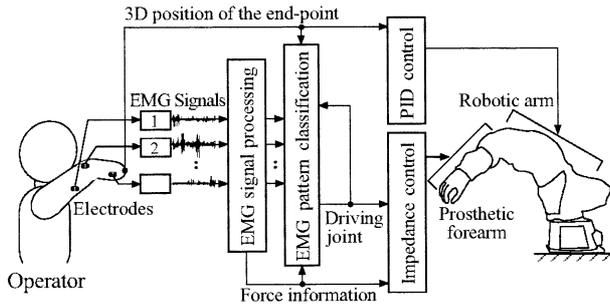


Fig. 4 Control system of a human assistive manipulator

3. 実 験

3.1 実験装置

Fig. 4 に実験に使用した人間支援マニピュレータの制御システムを示す [14]. このシステムは、腕全体の大きな動きを制御するアーム制御部と手首、手先運動の制御を行う義手制御部からなる. アーム部には Move Master RM-501 ((株)三菱電機製)を、義手部には超音波モータ駆動型義手 [4] を用いている. 各関節には、エンコーダ、あるいはポテンショメータが備えられており、フィードバック制御が可能である. アーム部は、操作者の手首関節に装着した三次元位置センサ (ISOTRACK II: POLHEMUS 社製) により検出した手首位置を目標軌道とし、PID 制御を用いてアーム部の先端を操作者の手首の軌道に追従させるよう制御を行った.

義手部は 3 自由度を有し、手先の開き、握り、手首の回内、回外、背屈、掌屈の計 6 動作 ($K = 6$) を実験で扱う対象動作とした. 操作者には、前腕部に 4 対、上腕部に 2 対 ($L = 6$) の表面電極を取り付け、EMG 信号を計測した. 前処理は整流後、カットオフ周波数 $f_c = 1.0$ [Hz] のパワースフィルタで平滑化を行った. そして、サンプリング周波数 $f_s = 27$ [Hz] で再サンプリングし、本論文で提案した動作識別法を用いて動作識別を行った. なお、LLGMN の学習法については文献 [12], [14] を、義手部のインピーダンス制御については文献 [15] を参照されたい.

3.2 実験結果

本論文では、積み木作業と簡単な食事作業を取り上げ、提案する EMG 信号動作識別法の有効性を検討した. ただし、本論文の主な目的は、事象駆動型作業モデルを利用したパターン識別法の提案、および提案した識別法によるマニピュレータ制御の実現性を示すことであるので、被験者、マニピュレータ、作業対象物の位置関係などについては、被験者と相談の上で試行錯誤的に決定した. 被験者は男子大学生 5 名 (健康者) である. 被験者 5 名のうち、2 名 (A, E) は熟練者であり、3 名 (B, C, D) は練習期間 6 日以内の非熟練者である.

A. 積み木作業

机の上に置かれた二つの積み木に対して、一方を他方の上に積む作業を考える. この作業に必要な動作と状態は、 p_0 : 待機状態, t_0 : 積み木をつかむ動作, p_1 : 積み木を把持した状態, t_1 : 積み木を放す動作の 2 動作 2 状態となる (Fig. 5 参照). 式 (9) の修正ベクトルは $\gamma_0 = [1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0]^T$, $\gamma_1 = [0.1, 0.1, 1.0, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1]^T$, そして各パラメータ

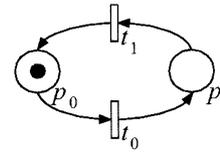


Fig. 5 Task model for gripping an object

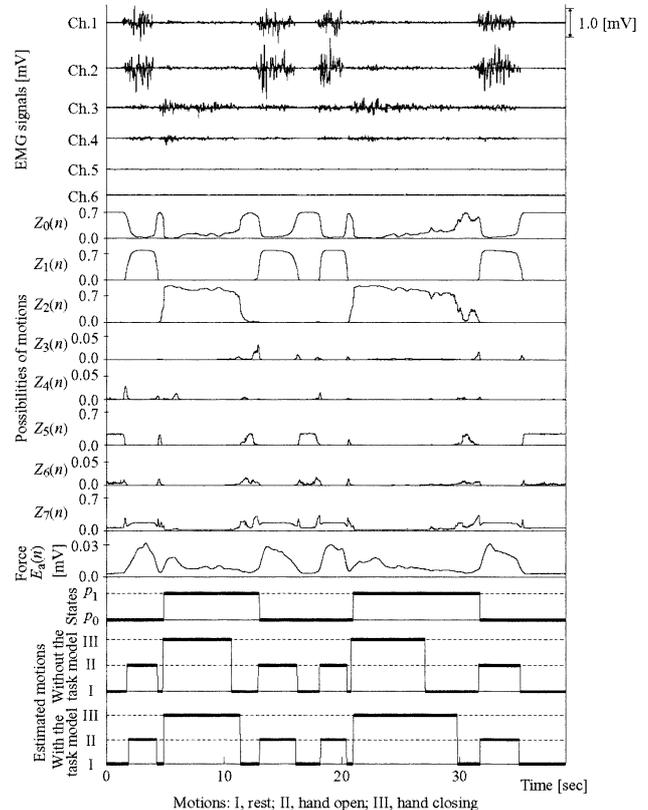


Fig. 6 An example of the EMG pattern discrimination for putting a building block

は、 $\alpha_1 = \alpha_2 = 4.0$, $\beta_1 = 0.1$, $\beta_2 = 0.2$ と設定した. これにより、待機状態 (p_0) にトークンがある場合はニューラルネット部の出力をそのまま採用し、操作者の作業状態を物体の把持中 (p_1) と推定した場合は握る動作を優先することになる. ただし、修正ベクトルの要素を 0 にしない限り、どの状態においてもすべての動作が選択可能であることに注意されたい. したがって、物体を把持したまま、回内、回外といった動作を行うことや、空中で物体を離すことも可能である.

Fig. 6 に実験結果の一例を示す. 被験者は A (熟練者) である. 図は上段より EMG 信号 (6 チャンネル), 各動作発生確率 $Z_0(n), Z_1(n), \dots, Z_{K+1}(n)$, 推定筋力 $E_a(n)$, 作業モデル部で推定された作業状態, 作業モデルを利用しない場合の識別結果, そして作業モデルを利用した識別結果である. ただし、実際のマニピュレータは作業モデルを利用した制御法で動作しており、作業モデルを利用しない場合の識別結果は、参考のために実験後に計算した結果である. 事前に作業モデルを利用しない制御法も実施したが、誤識別が多く作業を最後まで遂行することができなかった. 図より、作業モデルによる修正を加えない場合は握り動作 (動作 III) が早いタイミングで中断する危険性

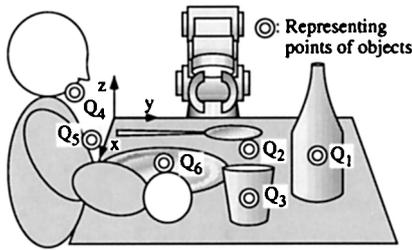


Fig. 7 Experimental setup for meal assistance



Fig. 8 View of eating

が示唆される．これは操作者が積み木を把持した後，滑り落とさない程度に力を抜いて作業を遂行したためであり，EMG 信号の振幅の減少により動作が行われていないと識別されるためである．なお，図中の EMG 信号，動作発生確率，推定筋力などのパターンは，個人差，電極位置などによって変化する．熟練・非熟練による差異は，非熟練の方が，動作保留確率 $Z_{k+1}(n)$ の値が若干大きくなる傾向があるが，識別精度に関してはほとんど差は見られなかった．

B. 食事作業

PET ボトルからコップに水を注ぐ，コップの水を飲む，スプーンを使ってスープを飲むという三つの場面を含む簡単な食事作業を考える．Fig. 7, 8 に実験環境の設定および実験の様子を示す．被験者には以下に示す一連の動作を行うよう指示した．

- (1) テーブルに置かれた PET ボトルをマニピュレータでつかむ (Fig. 8 (b)) .
- (2) つかんだ PET ボトルを卓上のコップ上方に移動させ，回外動作を行うことで PET ボトルを傾け，水を注ぐ (Fig. 8 (c)) .
- (3) PET ボトルを机の上に置く．
- (4) コップをマニピュレータでつかみ (Fig. 8 (d)) , 口元まで移動する．
- (5) 回内動作を行い，コップを傾けて水を飲む (Fig. 8 (e)) .
- (6) コップを置く．

Table 1 Places and transitions

Places		Transitions	
p_0	Standby	t_0	Opening
p_1	Grasping a bottle	t_1	Grasping in Q_1
p_2	Pouring	t_2	Supinating in Q_2
p_3	Grasping a cup	t_3	Grasping in Q_3
p_4	Drinking water	t_4	Pronating in Q_4
p_5	Grasping a spoon	t_5	Grasping in Q_5
p_6	Spooning up	t_6	Supinating in Q_6
p_7	Eating soup	t_7	Pronating in Q_4

Table 2 Modification vectors used in the experiments

m	Motion	Modification vector ($\gamma_{p_m k}$)
0	Standby	{1.0,1.0,1.0,1.0,1.0,1.0,1.0,1.0}
1	Grasping a bottle	{0.1,0.1,1.0,0.1,0.1,0.1,0.1,0.1}
2	Pouring	{0.1,0.1,0.1,0.1,0.1,1.0,0.1,0.1}
3	Grasping a cup	{0.1,0.1,1.0,0.1,0.1,0.1,0.1,0.1}
4	Drinking water	{0.1,0.1,0.1,0.1,0.1,0.1,1.0,0.1}
5	Grasping a spoon	{0.1,0.1,1.0,0.1,0.1,0.1,0.1,0.1}
6	Spooning up	{0.1,0.1,0.1,0.1,0.1,1.0,1.0,0.1}
7	Eating soup	{0.1,0.1,0.1,0.1,0.1,0.1,1.0,0.1}

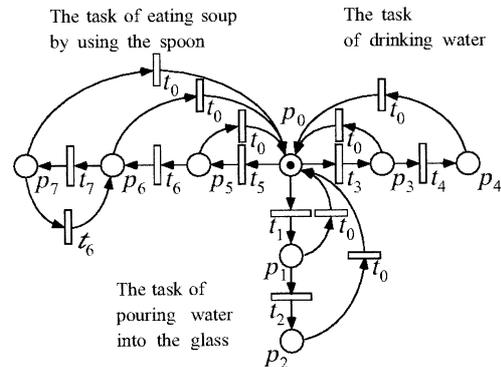


Fig. 9 Task model for having a meal

- (7) 胸元でマニピュレータに柄を太くしたスプーンを握らせる (Fig. 8 (f)) .
- (8) スプーンをスプーン皿手前上方に移動し，回外動作を行うことでスプーンを傾ける (Fig. 8 (g)) .
- (9) スプーンを水平に戻すと同時にスプーンをすくう．
- (10) スプーンを口元まで移動し回内動作によりスープを飲む (Fig. 8 (h)) .
- (11) 胸元でスプーンを放して食事作業を終了する．

以上の作業に必要な動作と状態を Table 1 に，また，8 動作 8 状態からなる作業モデルを Fig. 9 に示す．

ここで，トランジションの条件部には，マニピュレータの手先位置情報を追加した．これは，例えば，「スプーンを握った状態でスプーン皿に近づくとスプーンをすくう動作が発生しやすい」というような場所依存の知識を記述するためである．そのため，作業空間には六つの領域を定義した．この領域は，ボトル，コップ上方，コップ，スプーン皿に設定した代表点，および操作者の口と胸元の位置，計六つの位置 $Q_i (i = 1, 2, \dots, 6)$ を中心とした半径 $r_i (i = 1, 2, \dots, 6)$ の球とした．各代表点の位置は Fig. 7 に示す．各球の半径は，PET ボトル $r_1 = 0.08$ [m]，コップ上方 $r_2 = 0.08$ [m]，コップ $r_3 = 0.08$ [m]，口 $r_4 = 0.08$ [m]，胸

Table 3 Classification rates for motions included in the task

(a) The proposed method using the task model					
Motions	Subject A (%)	Subject B (%)	Subject C (%)	Subject D (%)	Subject E (%)
Grasping a bottle	98.8 ± 0.8	92.1 ± 7.3	89.8 ± 10.2	94.0 ± 3.7	96.0 ± 3.7
Pouring	99.4 ± 0.4	91.9 ± 7.9	97.0 ± 3.6	97.0 ± 2.8	96.4 ± 4.2
Grasping a cup	92.6 ± 8.6	97.2 ± 2.5	94.5 ± 6.7	80.1 ± 12.7	92.1 ± 7.0
Drinking water	91.1 ± 6.5	95.4 ± 4.2	96.3 ± 4.8	81.1 ± 8.6	94.8 ± 8.7
Grasping a spoon	97.1 ± 2.6	92.4 ± 11.5	95.5 ± 3.6	96.2 ± 3.2	86.5 ± 5.9
Spooning up	97.9 ± 1.8	96.7 ± 1.4	98.9 ± 1.2	97.7 ± 1.7	90.6 ± 4.3
Eating soup	95.5 ± 3.5	92.6 ± 4.7	98.7 ± 1.0	88.6 ± 9.1	98.1 ± 1.6

(b) The previous method not using the task model					
Motions	Subject A (%)	Subject B (%)	Subject C (%)	Subject D (%)	Subject E (%)
Grasping a bottle	51.3 ± 16.6	88.2 ± 8.6	81.9 ± 9.8	74.4 ± 13.7	93.1 ± 3.5
Pouring	94.3 ± 1.9	83.8 ± 10.5	90.8 ± 9.8	78.0 ± 5.0	54.7 ± 17.3
Grasping a cup	47.4 ± 22.3	93.7 ± 3.8	85.4 ± 9.2	64.5 ± 10.2	88.5 ± 6.0
Drinking water	79.3 ± 4.0	81.3 ± 12.4	66.0 ± 24.2	61.3 ± 9.8	83.9 ± 22.9
Grasping a spoon	59.9 ± 11.2	87.6 ± 11.2	80.3 ± 9.6	60.5 ± 14.6	83.1 ± 6.9
Spooning up	87.2 ± 6.2	68.2 ± 15.2	94.3 ± 4.3	64.5 ± 8.2	59.4 ± 9.7
Eating soup	73.8 ± 11.7	75.7 ± 9.3	77.1 ± 13.0	76.4 ± 16.8	78.9 ± 29.2

元 $r_5 = 0.08$ [m], スープ皿 $r_6 = 0.08$ [m] とした。

PET ボトルを使った作業では握りと回外, コップを使った作業では握りと回内, そしてスプーンを使った作業では, 握り, 回外, 回内を維持しやすくするために, Table 2 に示す修正ベクトルを用意した, また式 (10), (11) に含まれる各パラメータは, $\alpha_1 = \alpha_2 = 4$, $\beta_1 = 0.1$, $\beta_2 = 0.2$ と設定した. 各ベクトルの要素は予備実験の結果から試行錯誤的に決定した.

食事作業を各被験者に 5 回ずつ行かせたときの平均識別率と標準偏差を Table 3 に示す. Table 3 (a) は本稿で提案した作業モデルを用いた場合の識別結果, (b) は作業モデルを利用せず LLGMN のみで識別を行った結果である. いずれも式 (13) の $O_0(n)$ が $O_0(n) \leq 0.4$ のとき動作中と判断し, 必要な動作 (例えば, PET ボトルを把持している状態のときは握る) 以外の動作を識別した場合を誤識別とした. また, $O_0(n) > 0.4$ の場合は, 動作を行っていないとみなし, 無動作以外の識別結果を誤識別とした. そして, 待機状態を除いた作業中に正しく動作識別を行った割合を識別率と定義した. 識別結果より, 本稿で提案した作業モデルを用いた識別では全体的に高い識別率が実現されていることが分かる. 特にコップや PET ボトルをつかむ動作において作業モデルの効果が顕著である. これらの作業は, 上肢全体を前方にのばしてつかむなど, かなり大きな姿勢変化を伴う動作を含んでいる. なお, 熟練者 (A, E) と非熟練者 (B, C, D) の識別精度に関しては, 動作間にばらつきがあるものの, 平均では大きな差異は認められなかった. LLGMN の適応学習能力およびエントロピーを利用した動作決定法により, 練習期間 6 日以内の非熟練者でも熟練者と同レベルの識別精度が達成可能であることが分かる.

作業中に計測した波形の一例を Fig. 10 に示す. 被験者は A (熟練者) である. 図は上から EMG 信号 (6 チャンネル), 推定筋力 $E_a(n)$, 作業モデルを用いない場合の識別結果, 作業モデルを用いた識別結果, 作業モデル部で推定された作業状態, 義手手先部の関節角度, そして義手の手首関節角度である. ただし, 作業モデルを利用しない場合の識別結果は, Fig. 6 と同様に実験後に計算したものである. 図から, 作業モデルを用いない場合は, PET ボトルやコップを操作する際に誤識別の危険

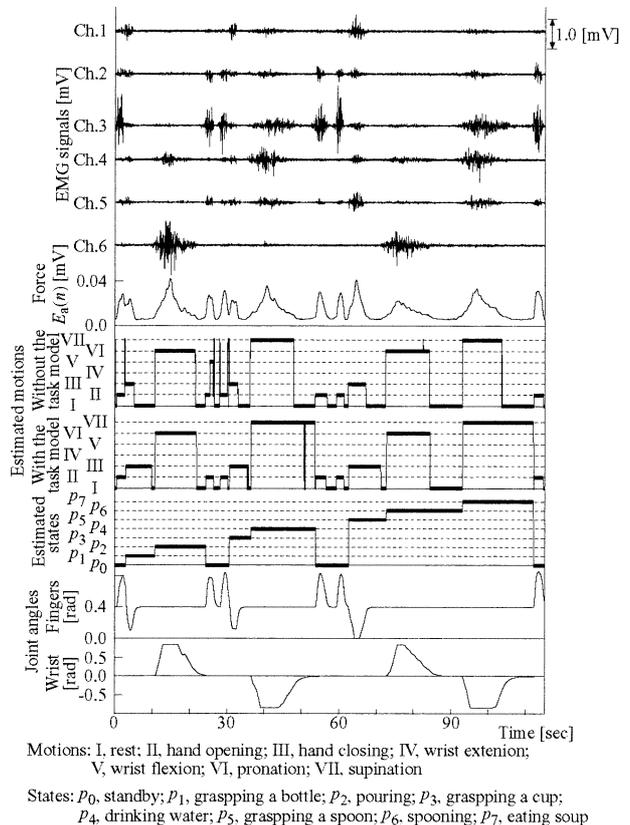


Fig. 10 An example of the EMG pattern discrimination for a having-a-meal task

性が示唆される. これはニューラルネットの学習時とは異なる EMG パターンが計測されたためである. しかし, 作業モデルを用いることにより, 誤動作は減少し, 正しい識別が増加している. 作業モデルを用いることにより, EMG パターンの変動に対しロバストな動作識別が実現できるのである.

4. ま と め

本論文では, 上肢切断者のための前腕筋電義手の自然な制御

と安定した動作識別の実現を目的として、ニューラルネットと作業モデルを利用した新しい EMG 信号動作識別法を提案した。この方法は、ニューラルネットによる動作識別の結果を、作業モデルを用いて修正しようというもので、ニューラルネットだけでは解決が難しかった姿勢変化や環境変化に伴う EMG パターンの変動、および操作者の操作のばらつきに対して、安定な動作識別を実現することができる。

EMG 駆動型人間支援マニピュレータを用いた検証実験の結果、(1) 積み木作業や食事作業といった従来の動作識別法では困難であった作業を実現できること、(2) 作業モデル部からの修正ベクトルにより EMG の減少に起因する誤識別の可能性を軽減できること、(3) 複雑な作業の場合でも過度の熟練度や集中力を必要としないため、操作者負担を軽減できること、などの点が明らかになった。

本論文で設定した、操作者、マニピュレータ、作業対象物の配置、およびマニピュレータの機構に関してはまだ課題が残されており、改善の余地がある。また、切断者による実験、各種パラメータの設定方法、作業モデルの自動作成などの点に関しても研究を進めていく予定である。なお、本研究の一部は日本学術振興会科学研究費補助金 (11555113, 13650488) によるものでここに改めて謝意を表します。

参 考 文 献

- [1] T. Tsuji, P.G. Morasso, K. Goto and K. Ito: "Human hand impedance characteristics during maintained posture," *Biological Cybernetics*, vol.72, pp.457-485, 1995.
- [2] T. Tsuji, K. Goto, M. Moritani, M. Kaneko and P. Morasso: "Spatial characteristics of human hand impedance in multijoint arm movements," *Proc. of IEEE International Conf. Intelligent Robots and Systems*, pp.423-430, 1994.
- [3] 赤澤堅造, 滝沢文則, 林義昭, 藤井克彦: "ヒトの運動制御機構を模擬した義手の制御方式および筋電位処理方式の開発", *バイオメカニズム*, 9, 東京大学出版会, pp.43-53, 1988.
- [4] K. Ito, T. Tsuji, A. Kato and M. Ito: "An EMG Controlled Prosthetic Forearm in Three Degrees of Freedom Using Ultrasonic Motors," *Proc. of the Annual International Conf. the IEEE Eng. in Medicine and Biology Society*, vol.14, pp.1487-1488, 1992.
- [5] C.J. Abul-haj and N. Hogan: "Functional Assessment of control systems for cybernetic elbow prostheses-Part I, Part II," *IEEE Trans. Biomedical Eng.*, vol.37, no.11, pp.1025-1047, 1990.
- [6] 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. Automatic Control*, vol.23, no.4, pp.538-544, 1978.
- [7] 辻敏夫, 伊藤宏司, 長町三生: "義手制御を目的とした多チャンネル EMG 動作識別法", *電子情報通信学会論文誌*, vol.J70-D, no.1, pp.207-215, 1987.
- [8] 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 Eng.*, vol.37, no.3, pp.221-230, 1990.
- [9] 平岩明, 内田典佳, 下原勝憲, 曽根原登: "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識別", *計測自動制御学会論文集*, vol.33, no.2, pp.216-224, 1994.
- [10] 辻敏夫, 森大一郎, 伊藤宏司: "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*, vol.112-C, no.8, pp.465-473, 1992.
- [11] D. E. Rumelhart, J.L. McClelland, R.J. Williams: "Learning internal representations by error propagation," In *Parallel Distributed Processing*. Rumelhart DE, McClelland JL, the PDP Research Group (eds). MIT Press: Cambridge, vol.I, pp.318-362, 1986.
- [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 System, Man and Cybernetics-Part C: Applications and Reviews*, vol.29, no.1, pp.1-13, 1999.
- [13] W. Reisig (長谷川健介, 高橋宏治訳) *ベトリネット理論入門*. シュプリンガー・フェアラーク東京株式会社, 1988.
- [14] 福田修, 辻敏夫, 金子真: "EMG 信号を利用した手動制御型人間支援マニピュレータ", *日本ロボット学会誌*, vol.18, no.3, pp.387-394, 2000.
- [15] 辻敏夫, 重吉宏樹, 福田修, 金子真: "EMG 信号に基づく前腕動力義手のバイオメテック制御", *日本機械学会論文集 C 編*, vol.66, no.648, pp.294-301, 2000.



辻 敏夫 (Toshio Tsuji)

1959年12月25日生。1985年3月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, 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, 計測自動制御学会, 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。(日本ロボット学会正会員)



福田 修 (Osamu Fukuda)

1969年9月30日生。2000年3月広島大学大学院工学研究科博士課程後期修了。1997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4月通商産業省工業技術院機械技術研究所入所, 2001年4月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)。障害者用インタフェース, 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, 電子情報通信学会などの会員。(日本ロボット学会正会員)



高橋恒介 (Kousuke Takahashi)

1976年7月21日生。2000年3月東京電機大学理工学部応用電子工学科卒業。2002年4月広島大学大学院工学研究科博士課程前期修了。同年4月ソニー株式会社勤務。現在に至る。広島大学在学中は, EMG 信号を利用した人間支援マニピュレータに関する研究に従事。



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卒業。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月広島大学工学部教授, 2001年4月同大学大学院工学研究科教授, 現在に至る。工学博士。超高速ロボットハンド, アクティブセンシングの医療応用などの研究に興味を持つ。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)