

木構造を有する階層型確率ニューラルネットの提案と指形状識別への応用

岡本 勝*・村上樹里*

柴建次*・辻敏夫*

A Tree-based Hierarchical Probabilistic Neural Network and Its Application to Hand Shape Discrimination

Masaru OKAMOTO*, Juri MURAKAMI*,
Kenji SHIBA* and Toshio TSUJI*

This paper proposes a new pattern classification method using probabilistic neural networks with hierarchical structure. In this method, a log-linearized Gaussian mixture network¹⁾ as a probabilistic neural network is used at each node of a hierarchical classification tree. The method proposed here automatically constructs a tree of neural networks from given data, and can achieve suitable discrimination. Also, Cross-validation for a constructed neural tree can improve the generalization ability for discrimination of unlearned data. Validity of the proposed method is demonstrated with discrimination of hand shape.

Key Words: probabilistic neural network, tree structure, hand shape discrimination

1. まえがき

筋電位信号や脳波信号などの生体信号は人間の生理的な内部状態に関する有益な情報を含んでおり、関節角度や角速度、角加速度、力、トルクなどの信号は人間の運動に関する情報を反映している。したがって、これらの人間の身体から計測できる信号からその人間の何らかの意図を抽出することができれば、直感的な操作が可能なインターフェースを構築できる可能性がある。また、これらの信号は高齢者や障害者からも計測できるため、対象者を限定しないインターフェースが実現できる可能性もあり、近年、これらの信号を用いたヒューマンインターフェースに関する研究が盛んに行なわれている^{2)~4)}。

人間の身体から計測した信号をインターフェースの入力手段として利用するためには、計測した信号から操作意図を識別する必要がある。パターン識別法には、あらかじめ用意した標準パターンと一致するかで判断するパターンマッチング法⁵⁾などに加えて、人間の身体から計測できる信号の個人差や再現性を考慮したニューラルネットワーク（Neural Network、以下 NN と略記）を用いた方法がある。NN は、任意の非線形写像を獲得できる学習機能を有しているという特徴があり、人間の身体から計測される信号の個人差や再現性を考慮した

パターン識別が可能である。NN の学習方法として Rumelhart らによって提案された誤差逆伝播法が広く用いられており⁶⁾、平岩らや Kelly らは誤差逆伝播型 NN を用いて生体信号の識別を行なった^{7), 8)}。また、辻らは確率ニューラルネット（Probabilistic Neural Network、以下 PNN と略記）の一種である Log-Linearized Gaussian Mixture Network (以下 LLGMN と略記) を提案し、筋電位信号などの識別に対する有効性を実験的に確認している¹⁾。LLGMN は混合正規分布モデルを対数線形化してネットワークに展開したもので、人間の動作パターンに対する事後確率を高い精度で出力できる。この LLGMN を用いたインターフェースシステムとしては、筋電位信号によるマニピュレータ操作システムやマウスポインタ操作システムなどが実現されている^{9)~11)}。しかしながら、一般に識別対象となるクラス数が増加すると、動作のパターンが類似し、データの分布が複雑化するため、高精度な識別が困難になるという問題がある。

一方、Sirat らは NN を複数組み合わせて段階的に識別する手法として、Neural Tree (以下 NT と略記) を提案している¹²⁾。NT では NN を木構造的に組み合わせ、1 つの NN では高精度な識別が困難な場合、段階的に識別を行なう。まず、すべてのクラスを含んだデータを NN を用いて識別し、識別が困難であると判断したクラスに対し、別の NN を用いて識別を行なう。最終的に、すべてのクラスが終端ノードになった場合に識別を終了する。このように段階的に識別を行なうことで、1 つの NN では識別できない複雑なパターンの場合でも識別できる。しかしながら、従来の NT ではノードに用

* 広島大学大学院工学研究科 東広島市鏡山 1-4-1

* Hiroshima Univ., Faculty of Engineering, Kagamiyama 1-4-1, Higashi-Hiroshima

(Received June 26, 2006)

(Revised November 21, 2006)

いる識別子として、構造が単純なバーセプトロンモデルを用いたものが多く、構築される階層が深くなった場合には、学習データへの依存度が高まるため汎化能力が低下してしまう。

そこで、本論文では、NTの識別子として、確率分布を内包したPNNを用いる方法を提案する。PNNには確率分布を高い精度で推定可能なLLGMNを用い、NTにLLGMNを導入したHierarchical Log-Linearized Gaussian Mixture Network(以下、H-LLGMNと略記)を提案する。提案手法ではLLGMNを階層的に用い、サブクラスへの識別を段階的に繰り返すことで、1つのLLGMNでは識別が困難な動作のパターン識別を行なうことができ、また、識別子にLLGMNを用い動作のパターンの確率分布を高い精度で推定することで、生体信号などの人間の身体から計測される信号の個人差や再現性を考慮した識別が実現できる可能性がある。また、階層構築におけるサブクラス構築にクロスバリデーションを導入することにより、汎化性も考慮することができる。

以下、2では各非終端ノードにてノードの分類に用いるLLGMNの基本構造を説明し、3で提案手法の説明を行なう。そして、4で曲率が計測可能なシェイプセンサを用いた応用実験を行ない、提案手法の有効性を示す。

2. LLGMN¹⁾

LLGMNは混合正規分布モデル(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、学習データのもつ事後確率を学習によって推定できる。本手法では、LLGMNを階層型識別の各非終端ノードにおける分類識別子として用いる。以下に、LLGMNについて構造、学習則に分けて説明する。

2.1 構造

LLGMNのネットワーク構造をFig.1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ネットワークの重み係数として表現するために、入力ベクトル $x \in \mathbb{R}^D$ を次式のように非線形変換する。

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

ネットワークの第1層は、変換された入力ベクトル \mathbf{X} 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、各ユニットは入力 X_h をそのまま出力する。第1層の出力は重み $w_h^{(k,m)}$ を掛け合わせて第2層に伝えられる。ただし、 $h = 1, 2, \dots, H$; $k = 1, 2, \dots, K$; $m = 1, 2, \dots, M_k$ である。 K は出力ユニット数、 M_k は出力 k に対応するコンポーネント数を表わす。第1層の出力を $(1)O_h$ 、第2層のユニット $\{k, m\}$ の入力を $(2)I_{k,m}$ 、出力を $(2)O_{k,m}$ とすると、

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

$$(2)O_{k,m} = \frac{\exp[(2)I_{k,m}]}{\sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \exp[(2)I_{k',m'}]} \quad (3)$$

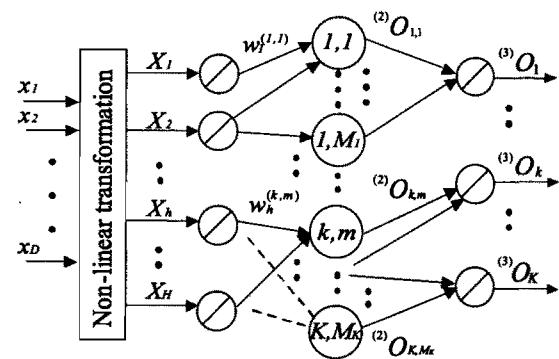


Fig. 1 The structure of LLGMN

となる。ただし、 $w_h^{(K,M_K)} = 0$ である。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しており、第3層のユニット k の入力 $(3)I_k$ と、出力 $(3)O_k$ は、

$$(3)I_k = \sum_{m=1}^{M_k} (2)O_{k,m} \quad (4)$$

$$(3)O_k = (3)I_k \quad (5)$$

で与えられる。第3層の出力 $(3)O_k$ は、入力ベクトルが対応するクラス k に分類される事後確率 $P(k|x)$ であり、分類結果の曇昧性を評価する指標として用いることが可能である。

このネットワークはデータのもつ統計的特性に応じて高い適応学習能力をもち、混合正規分布モデルを内包しているため、従来のパラメータが制限された正規分布を利用した手法¹³⁾と比較して複雑な分布構造をもつデータの識別が可能である。

2.2 学習則

入力ベクトルの集合 $(x^{(1)}, \dots, x^{(N)})$ に対して、教師信号 $T^{(n)} = (T_1^{(n)}, \dots, T_k^{(n)}, \dots, T_K^{(n)})$ ($n = 1, \dots, N$) が与えられた場合を考える。 $x^{(n)}$ がクラス k のときは $T_k^{(n)} = 1$ とし、それ以外は $T_k^{(n)} = 0$ ($k \neq k$) とする。ここで学習データ数を N とすると、ネットワークは次式の評価関数を最小化、つまり各学習データが教師信号の示すクラスに識別される尤度を最大化するように学習を行なう。

$$J = - \sum_{n=1}^N \sum_{k=1}^K T_k^{(n)} \log (3)O_k \quad (6)$$

このとき、重みの修正量 $\Delta w_h^{(k,m)}$ は

$$\Delta w_h^{(k,m)} = -\eta \sum_{n=1}^N \frac{\partial J_{SV}^n}{\partial w_h^{(k,m)}} \quad (7)$$

$$\begin{aligned} \frac{\partial J^n}{\partial w_h^{(k,m)}} &= \frac{\partial}{\partial w_h^{(k,m)}} \left(- \sum_{k=1}^K T_k^{(n)} \log (3)O_k \right) \\ &= (2)O_k - \frac{(2)O_k}{(3)O_k} T_k^{(n)} X_h^{(n)} \end{aligned} \quad (8)$$

で与えられる。 $\eta > 0$ は学習率である。

3. 階層識別

提案手法では、入力データはルートノードに対応する LLGMN で識別を行ない、識別されたクラスがサブクラスである場合は、そのサブクラスに対応する LLGMN で識別を行なう。各ノードにおける識別を段階的に繰り返し、入力データは終端ノードに対応するクラスへと識別されていく。以下、識別に用いる階層木構築、およびサブクラス構築について説明する。

3.1 階層木構築

階層木は、すべてのクラスデータを含むルートノードに対し LLGMN で学習し、識別精度が低いクラスをサブクラスとし、LLGMN で再学習を行なうことで構築される。この階層木構築を繰り返すことにより、最終的にすべての終端ノードがクラスに対応する階層木を構築できる。以下に階層木構築アルゴリズムを示す。

- (1) 提案手法で構築する階層木の初期構成として、ルートノードを用意する。
- (2) ルートノードに対応する学習データを用いて、LLGMN を学習する。
- (3) 学習精度と汎化性という 2 つの評価基準に基づき、サブクラスを構築する。
- (4) サブクラスに識別されたクラスに対し、ノードに対応するデータを用いて LLGMN の学習を行ない、(3) の評価基準に基づきサブクラスを構築する。
- (5) すべての終端ノードがサブクラスでなくなるまで (4) を繰り返す。

以上のように階層木構築を行なうことで、単独の LLGMN では識別困難なパターンに対して、複数の LLGMN を用いて詳細な識別を行なう NT が構築できる。以下、(3) のサブクラス構築の詳細について説明する。

3.2 サブクラス構築

提案手法ではサブクラス構築を、学習精度と汎化性に基づいて行なう。以下に、サブクラス構築アルゴリズムを示す。

ここで、対象とするクラス数を K 、クラスの集合 \mathcal{G} を、

$$\mathcal{G} = \{C_1, C_2, \dots, C_K\} \quad (9)$$

とする。さらに、クラス C_i に属するデータの集合を $D(C_i)$ 、クラス C_i に属するデータのうち、クラス C_j に識別されたデータの集合を $D(C_i, C_j)$ と定義する。

まず、LLGMN の学習に用いた学習データが正確に識別されない場合は、正しいクラスと間違えて識別されるクラスが類似していると考え、これらを 1 つのサブクラスとする。この識別精度を検証するために、次式の評価関数を定義する。

$$F_t(i) = \frac{\sum_{i \neq j, j=1}^K |D(C_j, C_i)|}{|D(C_i, C_i)|} \quad (10)$$

ただし、 $|D(C_j, C_i)|$ は、 $D(C_j, C_i)$ に属するデータの総数を

表わす。 $F_t(i)$ が閾値 Th_t より大きくなる場合、クラス C_i に識別されたデータをサブクラスとする。このとき、構築されたサブクラス $SC_i = \bigcup_{j=1}^K D(C_j, C_i)$ を \mathcal{G} に追加し、 \mathcal{G} から C_i を取り除く。すべてのクラスに対して $F_t(i)$ が閾値 Th_t より小さくなるまでサブクラスの構築を繰り返す。このように、学習データを用いたサブクラスを構築することにより、単独の LLGMN において学習が困難なクラスをサブクラスとし、サブクラスのデータを LLGMN で識別していく。

以上のようにして構築された階層木に対して、その汎化性を考慮するため、つぎに、学習データとは異なる検証データを用いてサブクラスの統合を行なう。検証データが高い精度で識別できない場合は、識別時に汎化性が低下する可能性があると考え、検証データがまちがいとして識別されたクラスと真のクラスを 1 つのサブクラスに統合する。このとき、汎化性を検証するために、次式の評価関数を定義する。

$$F_v(i, j) = \frac{|D(C_i, C_j)|}{|D(C_i)|} \quad (11)$$

$F_v(i, j)$ が閾値 Th_v より大きくなる場合、クラス C_i, C_j をサブクラスに統合する。このとき、構築されたサブクラス $SC_{ij} = D(C_i) \cup D(C_j)$ を \mathcal{G} に追加し、 \mathcal{G} から C_i と C_j を取り除く。汎化性を考慮して構築されたサブクラスを含むすべてのクラスに対して、 $F_v(i, j)$ が閾値より小さくなるまでサブクラスの構築を繰り返す。このように、検証データを用いてクロスバリデーションを行なうことにより、汎化性を考慮する。

以上の学習精度と汎化性を考慮した 2 種類のサブクラス構築を行なうことにより、データの特性を考慮した学習を行なうことができる。

4. 実験

提案する NN の有効性を検証するために、指形状を用いた 2 種類の実験を行なった。手話や指文字などのハンドジェスチャ識別に関する研究は、NN やファジー推論、ペイジアンネットワークを利用したものなど数多く行なわれている^{15)~17)}。本論文では、これらのアプローチのうち NN に注目し、提案法と従来の LLGMN や多層パーセプトロン (Multi Layered Perceptron, 以下 MLP と略記) などの NN と比較し、提案法の有効性を示す。はじめに、シェイプセンサを用いた指形状の識別実験について説明し、1 つの LLGMN では識別困難なクラスに対して階層木を構築し、段階的に識別を行なうことで多クラス識別が可能であることを示す。つぎに、指形状を利用した家電操作実験について述べ、提案手法を用いた応用例を示す。

4.1 指形状識別実験

本実験では、提案手法の有効性を示すために、小型関節角度センサ（シェイプセンサ、Measurand 社）から指の曲率を計測し、指形状の識別実験を行なった。被験者は健常者 3 名 (A : 23 歳, B : 23 歳, C : 23 歳)、指形状は Fig.2 に示す

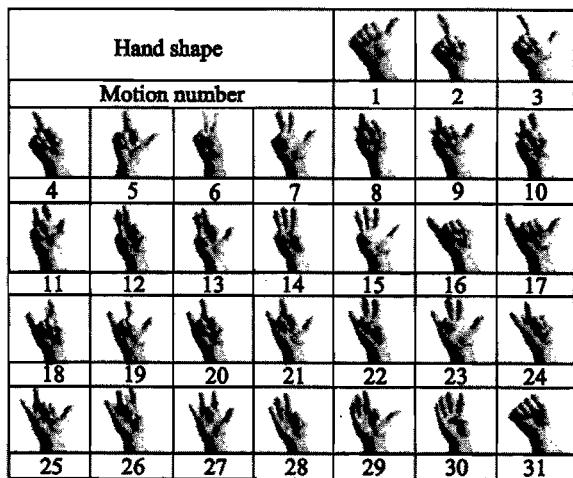


Fig. 2 The 31 patterns of hand shape

31 パターンとし、センサを右手各指第 2 関節部に装着し、サンプリング周波数 167 [Hz] で計測した。各ジェスチャの試行回数は 3 とした。装着した $L = 5$ 本のシェイプセンサから測定した計測信号 $S_l(n)$ ($l = 1, \dots, L$) に対し、次式のように最大値が 1 になるように各チャネルごとに正規化を行ない $N_l(n)$ を求める。

$$N_l(n) = \frac{S_l(n) - S_l^{st}}{S_l^{max} - S_l^{st}} \quad (12)$$

ここで、 S_l^{st} は、安静時に取得した $S_l(n)$ の平均値、 S_l^{max} はあらかじめ計測した各チャネルの最大値である。正規化した信号のいずれかのチャネルが、設定した閾値 M_d を超えた場合にジェスチャ発生とし、H-LLGMN で識別を行なう ($M_d = 0.5$)。識別には、各チャネルの値が小さい場合でも安定した信号を得るために、次式で示すように全チャネルの総和が 1 になるように正規化した信号 $x_l(n)$ を用いた。

$$x_l(n) = \frac{N_l(n)}{\sum_{l=1}^L N_l(n)} \quad (13)$$

LLGMN への入力数は $D = 5$ 、各クラスに対応するコンポーネント数は $M_k = 1$ ($k = 1, \dots, 31$)、出力ユニット数は $K = 31$ とした。

また、H-LLGMN のサブクラス決定における閾値は $Th_t = 1.0$ 、 $Th_v = 0.5$ と設定した。学習および階層木構築には各ジェスチャごとに学習データ 20 サンプル、検証データ 20 サンプルずつ用いた。

Fig.3 に被験者 3 人の平均識別率および標準偏差を示す。なお、識別に用いたデータ数は 1 セットにつき、ジェスチャ 300 サンプル \times 31 動作 (計 9300 サンプル) で、いずれの場合も信号が M_d を越えてから連続で計測したものを使い、各被験者とも 3 セットの識別率の平均値と標準偏差を求めた。構築された H-LLGMN の階層木に含まれる LLGMN の数は、それぞれ被験者 A が 1、B が 3、C が 8 であった。また、提案手法との比較のため、NN に MLP を用いて同様の

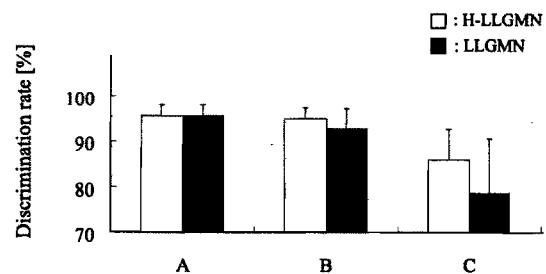


Fig. 3 A discrimination result for three subjects

Table 1 Discrimination accuracies of LLGMN, H-LLGMN and MLP

Subjects		A	B	C
Single NN	LLGMN	95.6±2.48	92.7±4.46	78.6±12.0
	MLP	82.1±2.90	52.1±8.36	56.0±9.12
NT	H-LLGMN	95.6±2.48	95.0±2.36	86.0±6.69
	MLP	88.9±3.22	78.6±8.53	73.2±8.17

[%]

実験を行なった。使用した MLP のパラメータは、入力層、隠れ層 2、出力層の計 4 層で、入力層のユニット数はセンサチャネル数 $L = 5$ 、隠れ層のユニット数はそれぞれ 10、出力層は識別パターン数 31 とした。入出力関数にはシグモイド関数を利用した。学習則には誤差逆伝搬法を用い、誤差閾値を 0.01、学習率を 0.01 とした。Table 1 に単一の NN で識別した結果、および NT で識別した被験者 3 人の平均識別率を示す。表より、いずれの場合も単一の NN よりも NT のほうが平均識別率が向上した。また、NN に MLP を用いるよりも LLGMN を用いるほうが平均識別率が高くなっている。

つぎに、被験者 C について H-LLGMN により構築された階層木を Fig.4 に示す。非終端ノード内の文字は各サブクラスに含まれるクラスを示し、添え字はジェスチャ番号を表わしている。非終端ノードにおける C_1 と C_{31} は学習データによって構築されたサブクラス、 C_4 と C_5 、 C_8 と C_9 、 C_{10} と C_{11} 、 C_{12} と C_{13} 、 C_{18} と C_{19} 、 C_{26} と C_{27} は検証データにより構築されたサブクラスである。このとき学習データにより構築されたサブクラスのパターンを Fig.5 に示す。図は、 C_1 と C_{31} に属する学習データの平均値および標準偏差を示している。この 2 つのジェスチャは類似したパターンとなり、結果的にサブクラスと判定された。同様に、検証データにより構築されたサブクラスに属するクラスのパターンの例を Fig.6 に示す。図は、 C_8 と C_9 に属する検証データの平均値および標準偏差を示している。この 2 つのジェスチャのパターンは学習を精度良く行なえている。しかしながら、生体信号の個人差や再現性の不確かさにより C_9 が C_8 に含まれるようなパターン分布になっており、汎化性が低く学習データ以外のデータの識別を行なった場合、誤識別が生じサブクラスと判定され、階層木に新たなノードが追加された。

Fig.7 に、被験者 C の H-LLGMN および単一の LLGMN

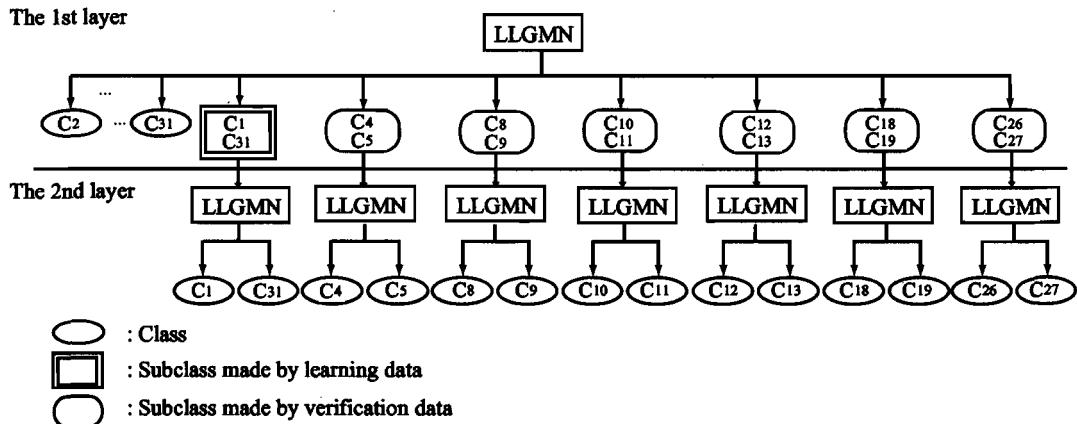
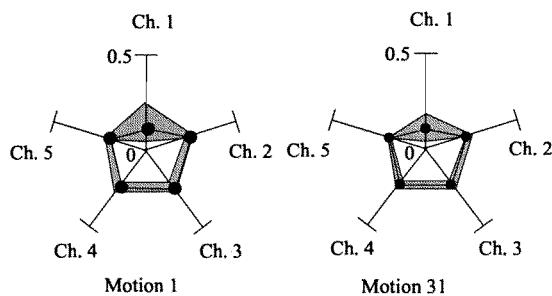
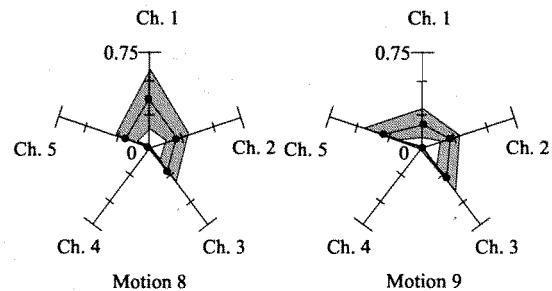


Fig. 4 A constructed tree structure for subject C

Fig. 5 Rader charts of hand gesture patterns of gesture 1 and gesture 31 for subject C. The line indicates the mean value of each channel, and the regions of shade imply ± 1 S.D.Fig. 6 Rader charts of hand gesture patterns of gesture 8 and gesture 9 for subject C. The line indicates the mean value of each channel, and the regions of shade imply ± 1 S.D.

による各ジェスチャの識別率を示す。図より、H-LLGMN は $86.0 \pm 6.69 [\%]$ 、LLGMN は $78.6 \pm 12.0 [\%]$ となり、提案手法のほうが高い識別率が得られた。また、Fig.8 は各ジェスチャにおける識別率の比を示しており、特に C_5 , C_{13} , C_{19} , C_{27} において顕著に識別率が向上していることがわかる。以上より、サブクラス構築を行ない、段階的に識別を繰り返すことで識別率の向上が確認できた。

4.2 家電操作実験

提案手法を用いて応用実験を行なった。本稿では、応用実験の1例として、4.1と同様の指形状を用いて、Bio-Remote¹⁴⁾

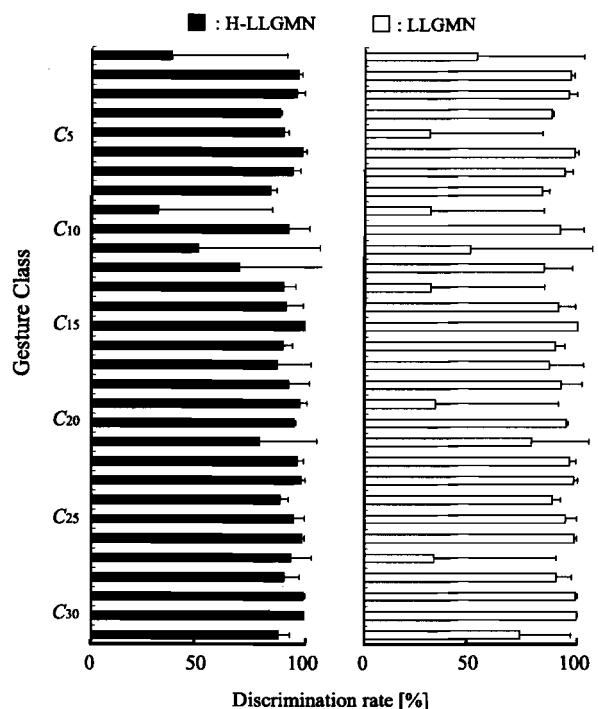


Fig. 7 A discrimination result of each motion for subject C

を用いた家電製品の操作実験を行なった。Fig.9 に実験装置、センサ装着図、および実験風景を示す。

被験者は4.1の被験者C(23歳)で、入力手段にはシェイプセンサを用い、信号を計測したのち、4.1と同様の信号処理を行ない、識別を試みた。従来のBio-Remoteでは、各ジェスチャに対し「選択」・「決定」を操作コマンドとして割り当て、これらのコマンドを段階的に繰り返すことにより、家電操作を実現していたが、本論文では、H-LLGMNの多クラス識別能力を利用し、各ジェスチャを家電製品の操作コマンドに直接割り当て、操作を行なう方式を新たに実現した。これにより、家電操作に要する時間の短縮が期待できる。本実験では、Fig.2の指形状をTable2に示すように家電製品の操作コマンドに割り当て、操作を行なった。識別における各

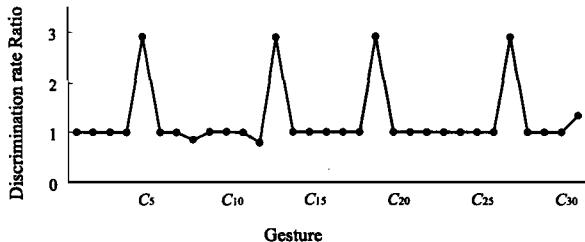


Fig. 8 A discrimination ratio of each motion for subject C

Table 2 Example of command allocation for home electric devices

Motion number	Object	Command
1	Light	On
2		Off
3	TV	Switch
4		CH up
5		CH down
6		Power on/off
7	CD player	Play
8		Stop
9		Volume up
10		Volume down
:	:	:

種パラメータの設定は 4.1 と同様とした。H-LLGMN の識別結果が 30 回連続して同じクラスとなった場合に、その操作コマンドに対応した赤外線を送信する。

Bio-Remote を用いた家電製品の操作結果の一例を Fig.10 に示す。上から順に、正規化した計測信号、識別結果、決定操作コマンドを示している。各チャネルのいずれかがジェスチャ発生判定閾値 M_d を超えた場合にジェスチャ発生とし、H-LLGMN で識別を行なった。陰影部では無動作と判定された区間を示している。図より、ジェスチャ発生直後は誤識別されやすいが、その後は精度よく識別できている。このように、ジェスチャの識別パターン数を増やすことで、直接家電製品の操作を行なうことが可能である。

つぎに、提案手法による家電製品の操作法と従来法¹⁴⁾との比較を行なった。被験者に、操作開始から照明の「点灯」「消灯」、TV の「電源 ON」、オーディオの「電源 ON」「再生」の一連の操作ができる限り早く行なうよう指示した。試行回数は 5 回である。操作完了までに要した時間は、本手法では約 30 秒、従来方法では約 65 秒であった。従来の Bio-Remote¹⁴⁾に比べて、約 2 分の 1 に操作時間を短縮することができた。

5. まとめ

本論文では、生体信号の多クラス識別を行なうことを目的とし、確率ニューラルネットを NT に導入した新しいパターン識別法 H-LLGMN を提案した。提案手法を用いることにより、単独の LLGMN では識別が困難なクラスに対してサブ

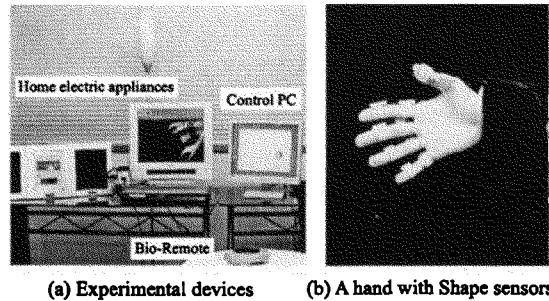


Fig. 9 Operation of home electric appliances using hand shape discrimination

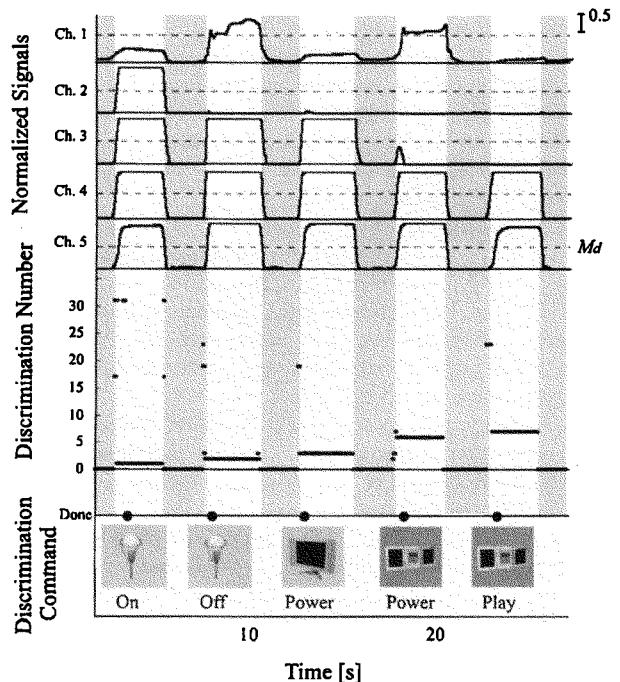


Fig. 10 Control results of home electric devices

クラスを構築し、再び LLGMN を用いて学習を行ない階層木を構築することができる。そして、シェイプセンサを用いた指形状識別実験を行ない、各 LLGMN の識別精度に応じたサブクラスが構築され、識別率が向上することを確認した。また、Bio-Remote を利用し、指形状のパターンを家電製品の操作コマンドに直接割り当てることで、家電製品の直接操作を行なえることを確認し、インタフェース応用への可能性を示した。しかしながら、この指形状識別法をヒューマン・イ

ンタフェースの手段として利用するためには、ファジー推論やペイジアンネットを利用した手法^{16), 17)}などとの比較を行ない、提案手法の特徴をより明確にする必要があると考えている。

今後は、被験者および試行回数を増加することにより、提案手法の有効性をさらに詳細に検討する予定である。そして、ほかの生体信号識別問題に対して H-LLGMN を適用しその有効性を検証するとともに、インターフェースの操作コマンドに適したジェスチャ識別の検討を行なう予定である。また、各種パラメータの調節および識別アルゴリズムの再検討を行ない、より識別率の向上を目指したいと考えている。

参考文献

- 1) T. Tsuji, O. Fukuda, H. Ichinobe and M. Kaneko: A Log-Linearized Gaussian Mixture Network and Its Application to EEG Pattern Classification, IEEE Trans. on Systems, Man and Cybernetics-Part C: Applications and Reviews, **29**-1, 60/72 (1999)
- 2) 小池, 川人: 表面筋電信号を入力とするダイナミックスモデルを用いたヒューマンインターフェース, 電子情報通信学会論文誌, **J79-A-2**, 363/370 (1996)
- 3) 福本, 平岩, 曽根原: ウェアラブルコンピュータ用キーボード FingeRing, 電子情報通信学会論文誌, **J79-A-2**, 460/470 (1996)
- 4) K. Abe, H. Saito and S. Ozawa: Virtual 3-D Interface System via Hand Motion Recognition From Two Cameras, IEEE Trans. on Systems, Man and Cybernetics-Part A: System and Humans, **32**-4, 536/540 (2002)
- 5) 飯島泰蔵: 電気・電子工学大系 43 パターン認識, 168/184, 東京: コロナ社 (1973)
- 6) D.E. Rumelhart, G.E. Hinton and R.J. Williams: Learning internal representation by error backpropagation, Parallel distributed processing, **1**, 318/362, (1986)
- 7) A. Hiraiwa, K. Shimohara and Y. Tokunaga: EMG pattern analysis and classification by neural networks, Proceedings of IEEE International Conference on Systems, Man and Cybernetics, 1113/1115 (1989)
- 8) M.F. Kelly, P.A. Parker and R.N. Scott: Neural network classification of myoelectric signal for prosthesis control, ARTICLE Journal of Electromyography and Kinesiology, 1-4, 229/236 (1991)
- 9) O. Fukuda, T. Tsuji, M. Kaneko and A. Otsuka: A Human-Assisting Manipulator Teleoperated by EMG Signals and Arm Motions, IEEE Trans. on Robotics and Automation, **19**-2, 210/222 (2003)
- 10) 辻, 福田, 村上, 金子: ニューラルネットを利用した EMG 制御型ポインティングデバイス, 計測自動制御学会論文集, **37**-5, 425/431 (2001)
- 11) 福田, 藤田, 辻: EMG 信号を利用した代用発声システム, 電子情報通信学会論文誌, **J88-D-II-1**, 105/112, (2005)
- 12) J.A. Sirat and J.-P. Nadal: Neural trees: A new tool for classification, Network, **1**, 423/448 (1990)
- 13) L.I. Perlovsky and M.M. McManus: Maximum likelihood neural networks for sensor fusion and adaptive classification, Neural Networks, **4**, 89/102 (1991)
- 14) 福田, 辻, 内田, 追坂: 障害者の日常を支援するバイオリモートの開発, ロボットメカトロニクス講演会 '02 講演論文集, No.02-6, 1A1-C05 (2002)
- 15) 坂口, 岡林, 金森, 井口: 運動覚センサと筋電位センサを併用したジェスチャ認識, 電子情報通信学会論文誌, **J81-D-II-10**, 2385/2393 (1998)
- 16) E. Benoit, T. Allevard, T. Ukegawa and H. Sawada: Fuzzy Sensor for Gesture Recognition based on Motion and Shape Recognition of Hand, IEEE International Symposium on Virtual Environments, Human-Computer Interfaces and Measurement Systems, 63/67 (2003)
- 17) H. Zhou and T. S. Huang: Tracking Articulated Hand Motion with Eigen Dynamics Analysis, ICCV 2003, 1102/1109 (2003)

【著者紹介】

岡本 勝



1979年4月30日生。2004年広島大学大学院工学研究科複雑システム工学専攻博士課程前期修了。現在(株)アイピーー在職。在学中はニューラルネット; クラスタリングなどの研究に従事。

村上樹里



1981年6月3日生。2005年広島大学工学部第2類卒業。現在広島大学大学院工学研究科複雑システム工学専攻博士課程前期在学中。ニューラルネット; パターン識別などの研究に従事。

柴建次



1972年5月4日生。2000年東京理科大学大学院理工学研究科博士課程修了。博士(工学)。日本学術振興会特別研究員(PD), 東京大学大学院新領域創成科学研究科助手, 東京理科大学理工学部助手を経て, 広島大学大学院工学研究科複雑システム工学専攻助教授。医用生体電子工学の研究に従事。日本生体医工学会, 日本人工臓器学会, 電気学会, 日本機械学会, ライフサポート学会, 日本人間工学会, IEEEなどの会員。

辻敏夫(正会員)



1959年12月25日生。85年広島大学大学院工学研究科博士課程前期修了。同年広島大学工学部助手。94年同助教授を経て, 2002年より同大学大学院工学研究科教授, 現在に至る。工学博士。主として, 人間とロボットの運動制御, 生体信号解析, ニューラルネット, ヒューマン・マシンシステムなどに関する研究に従事。本会学術奨励賞(1986), 論文賞(2002), バイオメカニズム学会論文賞(1990), 日本義肢装具学会論文賞(2000), 日本医科器械学会論文賞(2003), IEEE 2003 King-Sun Fu Memorial Best Transactions Paper Award(2004), 日本機械学会ロボティクス・メカトロニクス部門学術業績賞(2004)などを受賞。