

# 論文

## ニューラルネットによる時系列脳波パターンの識別

福田 修<sup>†</sup> 辻 敏夫<sup>†</sup> 金子 真<sup>†</sup>

Pattern Classification of a Time-Series EEG Signal Using a Neural Network

Osamu FUKUDA<sup>†</sup>, Toshio TSUJI<sup>†</sup>, and Makoto KANEKO<sup>†</sup>

あらまし 本論文では、時系列パターンの識別をニューラルネットを用いて精度良く行うために、以下の2点に着目してネットワークを構成する。第1は、脳波パターンが従う統計的特性を利用することで、ネットワーク内に混合正規分布に基づく統計構造を導入する。第2は、脳波パターンの時系列的つながりを考慮することで、ディジタルフィルタをネットワーク内に構造として用意する。そして提案するネットワークの学習アルゴリズムを導出すると共に、Mランダム時系列に従って被験者に視覚刺激を与え、そのとき測定した脳波の時系列パターンから刺激の有無を識別した。その結果、かなり高い精度で脳波パターンの識別ができる、脳波信号が有する周波数情報を利用することにより識別率が向上することなどを明らかにする。

キーワード 脳波、パターン識別、ニューラルネット、混合正規分布モデル、ディジタルフィルタ

### 1. まえがき

脳波や筋電位、皮膚電気反射などの生体信号は、人間の生理的な内部状態を反映しており、この信号をインターフェースの手段として利用することにより、自然な操作感覚や、特別な訓練をしなくとも操作可能なマン・マシンインターフェースを実現できる可能性がある。

本研究では生体信号のうち脳波に注目する。脳波とは頭皮上から記録される脳内部の活動電位であり、その信号成分は音・光などの外的刺激や意思・状態などの内的要因によって変化し、操作者の内部状態を強く反映している。この脳波信号の特徴から、人間の意志や活動をある程度推定できれば、障害者の意思伝達の手段や、仮想現実空間・テレオペレーションなどのインターフェースとして利用できる可能性がある。特に、操作に動作を伴わないことから、重度の障害者、寝たきりの老人や入院患者等にとっても利用できるという特徴を有している。

従来から行われている脳波解析は、主に臨床における検査が目的であり、測定した脳波の生波形やパワースペクトルを医師が主観的に分析・判断していた。従つてこれまでの研究は、睡眠・てんかん等の自動診断に

関するものが多く[1], [2]、インタフェース応用を考慮した研究はほとんど見られない。

1960年代末に、随意運動に伴う準備電位が発見・報告され、以来そのパターン識別に関する研究がいくつか報告されるようになった。脳波パターンの分類・識別法としては、例えばPeltorantaらが比較を行っているように、自己組織化特徴マップ、学習ベクトル量化法、K-平均、誤差逆伝搬型ニューラルネットなどが挙げられる[3]。中でもニューラルネットを利用した識別法は、(1)複数の要因が複雑に絡み合った非線形関係を表現することが可能、(2)学習的に写像を獲得でき、時間の経過に伴う発汗や疲労などの環境の変化に適応できるなどの点から有効な方法である。そこで、本研究でもニューラルネットを識別法として採用した。

ニューラルネットを用いたパターン識別の研究としては、平岩らの誤差逆伝搬型ニューラルネットによる随意運動準備電位パターンの識別等が報告されている[4]。しかしながら、非定常性が強い脳波信号を識別する場合、通常の誤差逆伝搬型ニューラルネット[5]では、その構造が一様であるため、写像の複雑さが増すにつれて、多量の教師サンプル数や学習時間、大規模なネットワークが必要となる。更に、識別の際、脳波の時間的な変動を考慮することも難しい。

本論文では、時系列脳波パターンを精度良く識別するため、次の2点に注目してニューラルネットを構

<sup>†</sup> 広島大学工学部、東広島市

Faculty of Engineering, Hiroshima University, Higashi-Hiroshima-shi, 739 Japan

成した。まず第 1 は、統計構造の導入である。脳波パターンが従う統計分布の特性を、ネットワークの構造として獲得するために、Log-Linearized Gaussian Mixture Neural Network [6] (以下 LLGMN) を利用した。第 2 は、各時刻で識別をする際、脳波パターンの時系列的つながりを考慮することである。ここではリカレント型の Neural Filter [7] (以下 NF) を、ネットワーク内に組み込んだ。以下、提案するネットワーク構造・学習アルゴリズムを説明し、時系列脳波パターンの識別を行った結果について述べる。

## 2. 時系列パターンの識別を目的とした ニューラルネット構造

### 2.1 ネットワーク構造

図 1 に本論文で提案するネットワークの構造を示す。測定した脳波信号  $S(t)$  は前処理され、入力ベクトル  $x(n) \in \mathbb{R}^d$  ( $n = 1, \dots, N$ ) として、次々と LLGMN 部に入力される。ここで  $d$  は入力ベクトルの次元数を表す。LLGMN 部は、個々のパターンが  $K$  個の事象のうち、どの事象に属するか、その事後確率を計算する。 $Y(n) \in \mathbb{R}^K$  ( $n = 1, \dots, N$ ) は LLGMN の出力ベクトルである。

次に、このベクトルの各要素  $Y_k(n)$  ( $k = 1, \dots, K$ ) をそれぞれ NF 部へ入力する。NF 部では、時系列パターンの変動に応じて事後確率を修正する。識別判定部では、各 NF 部からの出力を、その総和が 1 となるように正規化する。そして、各々の値を確率変数とみなし、最も確率の高い事象を、入力パターンに対する識別結果とする。

このネットワーク構造のポイントは、入力データの統計的性質と時系列的性質の二つの性質を考慮するために、LLGMN 部と NF 部を組み合わせて処理を分割している点である。LLGMN 部では統計モデルに基

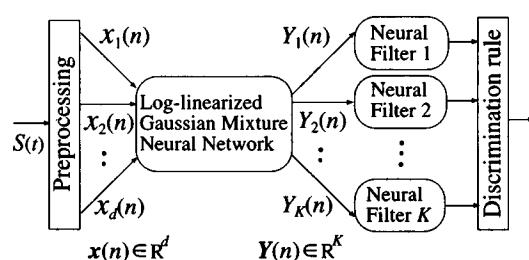


図 1 ネットワーク構造

Fig. 1 Structure of the proposed network.

づいて各時刻での入力ベクトルの事後確率を出し、NF 部ではこの出力を時間的なつながりを考慮して修正する。この二つのネットワークを組み合わせることで、高精度の識別が期待できる。

以下、LLGMN 部、NF 部の詳細を説明する。

#### 2.1.1 LLGMN 部

辻ら [6] は、混合正規分布モデル (Gaussian mixture model 以下 : GMM) の各コンポーネントの事前確率と生起確率を一つにまとめ、これに対数線形モデルを適用した LLGMN を提案した。このニューラルネットは学習的に獲得した確率分布に基づいて事後確率を計算することができ、ユニットの入出力関数、層の数、ユニットの数などのネットワーク構造も混合正規分布モデルに基づいて決定することができる。また、通常の誤差逆伝搬学習則と同様に、こう配を利用して重みの修正を行うことができる。

LLGMN 部の構造を図 2 に示す。まず、入力ベクトル  $x(n) \in \mathbb{R}^d$  を次式に従って変換し、新たな入力ベクトル  $X(n) \in \mathbb{R}^H$  ( $H = 1 + d(d+3)/2$ ) とする。

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

この変換は、GMM の各コンポーネントに対応するガウス分布を、 $X(n)$  の線形演算で表現するために行う。ニューラルネットの第 1 層はこの入力ベクトル  $X(n)$  の次元数  $H$  に合わせて  $H$  個のユニットからなり、ユニットの入出力関数には恒等関数を用いる。

第 2 層は、第 1 層の出力を重み  $w_h^{(k,m)}$  を介して受け取る。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  ${}^{(2)}O_{k,m}(n)$  とすれば、

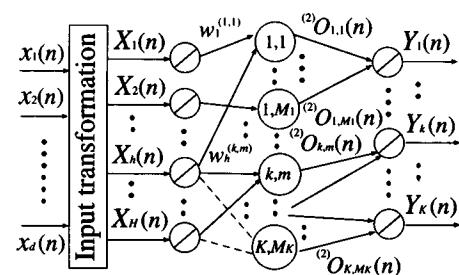


図 2 LLGMN 部の構造

Fig. 2 Structure of the LLGMN.

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

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

となる。但し、 $w_h^{(K,M_K)} = 0$  ( $h = 1, 2, \dots, H$ ) である。

第3層のユニット  $k$  は、第2層の  $M_k$  個のユニット  $\{k, m\}$  ( $m = 1, \dots, M_k$ ) と結合している。入出力関係は、

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

$$Y_k(n) = {}^{(3)}I_k(n) \quad (5)$$

である。

LLGMN 部では、第2層のユニットが、混合正規分布におけるコンポーネントに対応している。従って、第2層のユニットの数は混合正規分布の総コンポーネント数に等しく、ユニットの出力は各コンポーネントの事後確率に対応する。また、第3層の各ユニットの出力は、事象  $k$  の事後確率を表現している。このニューラルネットでは、第1層と第2層の間の結合の重み  $w_h^{(k,m)}$  を学習的に推定することで、各事象の事後確率を計算することができる。

### 2.1.2 NF 部

NF 部では、LLGMN 部では考慮できない入力データの時系列的な変動に対処する。LLGMN 部から出力される事後確率は、非定常な時系列信号となることが予想される。この信号に対し NF は、学習により適切なフィルタ特性を獲得し、事後確率の修正を行う。この学習能力が既存のデジタルフィルタにはない大きな利点である。

NF のネットワーク構造は、時系列信号を処理できるものでなければならない。これにはいくつかのネットワーク構造が考えられるが、NF の処理が、1 入力 1 出力であることから比較的シンプルな構造が望ましい。

Lo [7] は、非線形信号のフィルタリングを行なうために、図 3 に示されるような中間層にリカレント結合をもつ NF を提案した。簡単な非線形信号に対するシミュレーション実験の結果、この NF はカルマンフィルタよりも優れた処理能力を有することが示されてい

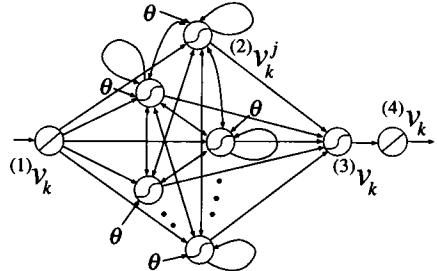


図 3 NF 部の構造  
Fig. 3 Structure of the NF.

る。本手法では、この構造を NF として採用することにした。

今 LLGMN 部に、入力ベクトル  $x(n)$  が与えられ、 $k$  番目の出力ユニットに  $Y_k(n)$  が出力された場合を考える。NF 部の第1層のユニットはこの出力を入力  ${}^{(1)}r_k(n)$  として受け、この値をそのまま  ${}^{(1)}v_k(n)$  として出力する。

第2層は  $J$  個のユニットからなる。各ユニットには、第1層のユニットの出力と1時刻前の第2層のユニットの出力が、重みを介して伝えられる。この同層内の相互・自己結合により、順次変化するネットワーク内部の情報を保持することができる。また、この層にはバイアス入力 ( $\theta = 1$ ) を附加している。第2層のユニット  $j$  への入力  ${}^{(2)}r_k^j(n)$ 、および出力  ${}^{(2)}v_k^j(n)$  は、

$$\begin{aligned} {}^{(2)}r_k^j(n) &= \sum_{i=1}^J {}^{(2,2)}u_k^{i,j} {}^{(2)}v_k^i(n-1) \\ &\quad + {}^{(1,2)}u_k^j {}^{(1)}v_k(n) + {}^{(\theta)}u_k^j \end{aligned} \quad (6)$$

$${}^{(2)}v_k^j(n) = g({}^{(2)}r_k^j(n)) \quad (7)$$

となる。但し、 ${}^{(2,2)}u_k^{i,j}$  は第2層内でのユニット  $i$  からユニット  $j$  への結合荷重、 ${}^{(1,2)}u_k^j$  は、第1層のユニットから第2層のユニット  $j$  への結合荷重を示す。また、 ${}^{(\theta)}u_k^j$  はバイアスから第2層のユニット  $j$  への結合荷重である。 $g(x)$  はシグモイド関数とする。

第3層のユニットは、第2層のすべてのユニットと結合しており、入出力関係は、

$${}^{(3)}r_k(n) = \sum_{i=1}^J {}^{(2,3)}u_k^i {}^{(2)}v_k^i(n) \quad (8)$$

$${}^{(3)}v_k(n) = g({}^{(3)}r_k(n)) \quad (9)$$

となる。但し、 ${}^{(3)}r_k(n)$  は第3層のユニットへの入力、 ${}^{(2,3)}u_k^i$  は第2層のユニット  $i$  から第3層のユニットへ

の結合荷重である。 $(^{(3)}v_k(n))$  は第 3 層ユニットの出力を表す。

第 4 層の出力関数は恒等関数であり、第 4 層ユニットの出力を  $(^{(4)}v_k(n))$  とすると、

$$(^{(4)}v_k(n)) = (^{(3,4)}u_k)(^{(3)}v_k(n)) \quad (10)$$

となる。 $(^{(3,4)}u_k)$  は第 3 層から第 4 層への結合荷重で、ゲインの役割を果たす。

## 2.2 学習アルゴリズム

ここでは、ネットワークの学習アルゴリズムについて説明する。もし、ネットワーク全体を同時に学習させるのであれば、NF 部の出力層に教師信号を与え、そこでの誤差を LLGMN 部の入力層へと逆伝搬する方法が考えられる。しかし、この方法では 2 種類のネットワークを直列に結合した構造となっているため、NF 部から LLGMN 部へ適切な誤差が伝搬されるとは限らない。

そこで、本論文では、ネットワークの学習を LLGMN 部と NF 部とで分担して行うことを考え、学習を二つのステップに分割した。

まずははじめに、LLGMN 部のみを学習させる。このとき、LLGMN 部は入力層に入力ベクトル  $\mathbf{x}(n) \in \mathbb{R}^d$  が与えられる。また、同時に入力ベクトルが属する事象に対応して、教師ベクトル  $\mathbf{T}(n) = [T_1(n), \dots, T_k(n), \dots, T_K(n)]^T$  が、LLGMN 部の出力層に与えられる。この学習が終了すれば、学習データの統計情報が LLGMN 部内に獲得される。

次に、LLGMN 部の結合荷重を固定した状態で、LLGMN 部の学習に用いたパターンとは別の入力ベクトル  $\mathbf{x}(n) \in \mathbb{R}^d$  を与える。学習後の LLGMN 部は、各出力ユニットから  $Y_k(n)$  ( $k = 1, \dots, K$ ) を出力し、この時系列が各 NF 部に入力される。このとき、各 NF 部の出力層に教師信号  $T_k(n)$  ( $k = 1, \dots, K$ ) を与え、NF 部の学習を行う。

### 2.2.1 LLGMN 部の学習

LLGMN 部の学習則について説明する[6]。今、 $n$  番目の入力ベクトル  $\mathbf{x}(n)$  に対して、教師信号ベクトル  $\mathbf{T}(n) = [T_1(n), \dots, T_k(n), \dots, T_K(n)]^T$  が与えられた場合を考える。 $T_k(n)$  は、事象が  $k$  であるときは 1、それ以外のときは 0 をとり、他の事象と同時に 1 にはならない。

LLGMN 部は、 $N$  個のサンプルデータ  $\mathbf{x}(n)$  ( $n = 1, \dots, N$ ) を用いて、対数ゆう度を最大化するように学習を行う。LLGMN 部の出力値  $Y_k(n)$  は事後確率

$P(k|\mathbf{x}(n))$  に対応することを考慮すると、評価関数  $J$  としては、

$$J = \sum_{n=1}^N J_n = - \sum_{n=1}^N \sum_{k=1}^K T_k(n) \log Y_k(n) \quad (11)$$

を用い、これを最小化するように学習を進めればよい。

例えば、入力ベクトル  $\mathbf{x}(n)$  が入力されたときの重み  $w_h^{(k,m)}$  ( $h = 1, \dots, H$ ) の修正量  $\Delta w_h^{(k,m)}$  は、 $\eta_1 > 0$  を学習率とすると、一括修正法に基づいて、

$$\Delta w_h^{(k,m)} = -\eta_1 \sum_{n=1}^N \frac{\partial J_n}{\partial w_h^{(k,m)}} \quad (12)$$

$$\begin{aligned} & \frac{\partial J_n}{\partial w_h^{(k,m)}} \\ &= \frac{\partial}{\partial w_h^{(k,m)}} \left( - \sum_{k=1}^K T_k(n) \log Y_k(n) \right) \\ &= (^{(2)}O_{k,m}(n) - \frac{(^{(2)}O_{k,m}(n)}{Y_k} T_k(n)) X_h(n) \end{aligned} \quad (13)$$

となる。式(13)は、事象に対して与えられた教師信号を、各コンポーネントの事後確率  $(^{(2)}O_{k,m}(n))$  が事象  $k$  の事後確率  $Y_k(n)$  に占める割合に応じて分配した形になっていることがわかる。

### 2.2.2 NF 部の学習

次に、NF 部の学習則について説明する[5]。第  $k$  番目の NF 部の出力層に、教師信号として  $T_k(n)$  が与えられた場合、このとき最小化すべき評価関数は、

$$E^k = \frac{1}{2} \sum_{n=1}^N (^{(4)}v_k(n) - T_k(n))^2 \quad (14)$$

と 2 乗誤差和の形で表される。第 4 層から第 2 層までの層に対しては、この誤差が、通常の誤差逆伝搬学習則に従って伝搬され、結合荷重が修正される。但し、第 2 層以下の層に対しては、相互・自己結合をもつことから、通時の誤差逆伝搬学習アルゴリズム(back-propagation through time)を適用した。本論文中では、4 ステップ時間までさかのぼって学習則を適用した。

このアルゴリズムに従うと、第 2 層内の結合荷重の修正値  $\Delta^{(2,2)}u_k^{i,j}$ 、および第 1 層から第 2 層への結合荷重の修正値  $\Delta^{(1,2)}u_k^j$  は次式で与えられる。

$$\Delta^{(2,2)}u_k^{i,j} = -\eta_2 \sum_{p=n-4}^n (^{(2)}\delta_k^j(p)) (^{(2)}v_k^i(p-1)) \quad (15)$$

$$\Delta^{(1,2)} u_k^j = -\eta_2 \sum_{p=n-4}^n {}^{(2)}\delta_k^j(p) {}^{(1)}v_k(p) \quad (16)$$

ここで、 $\eta_2$  は学習率とする。また、 ${}^{(2)}\delta_k^j(p)$  は、2乗誤差和の入力値  ${}^{(2)}r_k^j(p)$  に対する感度を表す。これらの値は、次に示す式(17)を初期値として、式(18), (19)より再帰的に求められる。

$${}^{(2)}\epsilon_k^j(n) = {}^{(2,3)}u_k^j {}^{(3)}\delta_k(n) \quad (17)$$

$${}^{(2)}\delta_k^j(p) = g'({}^{(2)}r_k^j(p)) {}^{(2)}\epsilon_k^j(p) \quad (18)$$

$${}^{(2)}\epsilon_k^j(p-1) = \sum_{i=1}^J {}^{(2,2)}u_k^{i,j} {}^{(2)}\delta_k^i(p) \quad (19)$$

但し、 ${}^{(3)}\delta_k(n)$  は、2乗誤差和の入力値  ${}^{(3)}r_k(n)$  に対する感度を、 ${}^{(2)}\epsilon_k^j(n)$  は、2乗誤差和の出力値  ${}^{(2)}u_k^j(n)$  に対する感度を表す。また、 $g'(x)$  は出力関数の導関数である。

### 3. 実験

#### 3.1 実験装置

本論文では、実用的な環境下での脳波計測を可能にする簡易小型脳波計 (IBVA, ランダムエレクトロニクスデザイン製) を使用した。概形は  $93\text{ mm} \times 51\text{ mm} \times 25\text{ mm}$  と非常にコンパクトあり、従来法に比べて被験者の負担は極めて小さい。測定された脳波信号は、high-pass (3 Hz) および low-pass (40 Hz) のアナログフィルタを通された後、増幅される。そして、その信号は A-D コンバータ (サンプリング周波数 120 Hz・量子化ビット数 8 bit) によってデジタル化される。電極はヘッドバンドに固定されていて、国際 10-20 電極法に基づく Fp1 と Fp2 に装着される。双極導出による脳波の差分をとることで大部分の測定ノイズを排除することができる。

#### 3.2 時系列脳波パターンの測定

本論文では以下の 2種類の条件で脳波を測定した。

##### (1) 開眼/閉眼

被験者は通常の計算機室内でいすに座り、安静にしておく。この状態で開眼/閉眼時の時系列脳波パターンを測定する。まず、開眼 (60 秒), 閉眼 (60 秒), 開眼 (30 秒), 閉眼 (30 秒) の合計 180 秒間、学習データ作成用に測定する。次に  $M$  系列により作成したランダムな時間間隔を用いて被験者に瞼の開閉を行わせ 450 秒間の識別用脳波を測定した。

表 1 実験で用いた周波数帯域  
Table 1 Frequency range used in the classification experiments.

$d$	Frequency range (Hz)					
	0~8	9~35	-	-	-	-
3	0~8	9~20	21~35	-	-	-
4	0~8	9~12	13~20	21~35	-	-
5	0~4	5~8	9~12	13~20	21~35	-
6	0~2	3~4	5~8	9~12	13~20	21~35
	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$

$d$  : Dimension of the input vector

#### (2) 光刺激

被験者は暗くした計算機室内でいすに座り、安静にしておく。この被験者の眼から約 50 cm 離した位置にフラッシュライト (光源: クセノン、エネルギー量: 1.76[J]) を設置し、光刺激 (4 Hz で点滅) を与える。測定時間などは、開眼/閉眼のときと同様に設定した。

前処理として、測定した脳波  $S(t)$  を 128 点ごとに FFT (高速フーリエ変換) し、周波数スペクトルを計算する。次に、周波数スペクトルにおいて識別に有効と見られる帯域 (0~35 Hz) を、臨床脳波学における  $\delta$  波、 $\theta$  波、 $\alpha$  波、 $\beta$  波などを基準にして分割する。そして、それぞれの帯域ごとにパワースペクトルの平均値を計算し、平均値の時系列を作成した。このとき、帯域ごとに時系列の範囲が [0,1] になるように標準化した。入力データ ( $x_1, x_2, \dots, x_d$ ) を作成するため用いた周波数帯域を表 1 に示す。ここで  $d$  は、入力データにおける周波数帯域の数を示す。

### 4. 時系列脳波パターンの識別

本論文では、比較のため 4種類のニューラルネットによる識別を行った。用いたニューラルネットは、提案するニューラルネット、LLGMN、混合正規分布の理論をほぼそのままニューラルネットに展開した MLANS (Maximum Likelihood Artificial Neural System) [8]、および誤差逆伝搬型ニューラルネット [5] (BPN) である。

本手法の NF 部の学習率  $\eta_2$  は 0.001 とした。MLANS の学習は、繰返し学習に伴う事後確率の変化が Bhattacharyya 距離 [8] で 0.0001 以下になるまで学習を行わせた。また、BPN については 2乗誤差が 0.1 以下となったときに学習終了とした。しかし、2乗誤差が、5万回の繰返し計算の後に 0.2 以下とならない場合は収束不能とし学習を打ち切った。

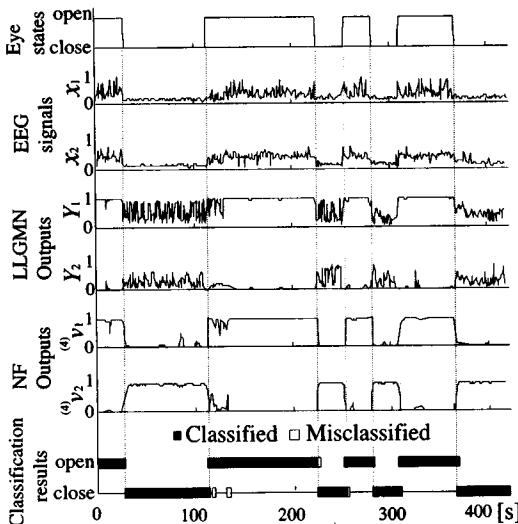


図 4 識別結果の一例（被験者 A）  
Fig. 4 An example of the classification result.

#### 4.1 開閉眼に伴う時系列脳波パターンの識別

##### 4.1.1 識別能力

まず、5人の被験者（A, B, C, D:男性, E:女性）に対して各ネットワークの識別能力を調べた。このとき、学習には  $N = 100$  の教師データ（各事象 50 組）を用いた。但しニューラルフィルタについては  $N = 168$  の時系列データを用いた。この教師データは、開眼/閉眼状態における局所定常区間、および開眼/閉眼の各状態間を遷移した直後の区間を含んでおり、この2種類の時系列変動に対して学習を行う。その後、未学習の時系列データ（データ数 422）に関して識別を行った。

入力データは、表 1 の  $d = 2$  のベクトルを用いた ( $d = 2, H = 6, K = 2$ )。本手法の LLGMN 部、および LLGMN の入力層のユニットは 6 個、出力層のユニットは事象数に合わせて 2 個、第 2 層のユニットは MLANS の総コンポーネント数に合わせて 6 個（各事象 3 個）とした。また、NF 部の第 2 層のユニット数は 8 とした。BPN は入出力層のユニットを 2 個とし、中間層が 1 層のものと 2 層のもの（いずれもユニット数 15）を用いた。

識別結果の一例（subject A）を図 4 に示す。図 4 は本手法の識別結果で、上から、開眼・閉眼の状態を切り換えたタイミング、LLGMN 部への入力パターン ( $x_1, x_2$ )、LLGMN 部の出力 ( $Y_1, Y_2$ )、NF 部の出力 ( $^{(4)}v_1, ^{(4)}v_2$ )、識別結果の時系列を表す。開/閉

表 2 開眼/閉眼時の識別結果  
Table 2 Classification results of eye states.

Subject	Performance	BPN with 1 hidden layer	BPN with 2 hidden layers	MLANS	LLGMN	Proposed network
A (male)	$R_{cla}$	72.6	84.3	85.5	91.1	94.5
	$R_{sd}$	12.1	3.4	2.1	0.4	0.3
B (male)	$R_{cla}$	76.2	84.4	83.7	83.3	90.4
	$R_{sd}$	6.1	3.1	0.7	0.6	0.8
C (male)	$R_{cla}$	81.6	88.7	89.9	88.6	93.8
	$R_{sd}$	5.4	2.7	0.4	1.4	1.1
D (male)	$R_{cla}$	80.0	83.3	100.0	100.0	100.0
	$R_{sd}$	7.4	7.84	80.6	81.3	89.7
E (female)	$R_{cla}$	56.7	60.0	100.0	100.0	100.0
	$R_{sd}$	6.7	3.1	1.6	0.6	0.1
E (female)	$R_{con}$	56.7	60.0	100.0	100.0	100.0
	$R_{sd}$	6.7	3.1	1.6	0.6	0.1

$R_{cla}$ : Classification rate(%),  $R_{con}$ : Convergence rate(%)

$R_{sd}$ : Standard deviation(%)

眼の各定常区間および各状態の遷移区間の両区間で、LLGMN だけの出力に基づいた識別よりも NF を導入した場合の方が、識別精度が向上していることがわかる。この場合の識別率は 95.3 % でかなり高い精度を実現することができた。これは LLGMN から出力される事後確率を時系列変動を考慮して修正した効果である。

表 2 に識別結果を示す。各値は、それぞれのネットワークについて、30通りの異なる重み初期値で実験を行った平均値と標準偏差である。収束率の定義は実験回数に対して、学習が終了した回数の割合とした。

5人のデータに共通して、BPN よりも MLANS および LLGMN、更に本手法の識別率が上回っている。また収束率に関しては、BPN が平均して 69.3 % 程度となっているのに対して、MLANS や LLGMN、および本提案アルゴリズムは、この実験に関しては 100 % 収束している。しかも、識別率の標準偏差も非常に小さい。

##### 4.1.2 学習データによる識別率の変化

次に、学習データの数  $N$ 、ネットワークへの入力ベクトルの次元数  $d$  の違いに伴う識別率の変化について調べた。表 1 に示す各入力ベクトルに対して、学習データの数を  $N = 10, 20, \dots, 100$  に変化させた。但しニューラルフィルタについては  $N = 168$  の時系列データを用いた。

図 5 に学習データと識別能力の関係を示す。図は、未学習の時系列データ  $N = 422$  について、10通りの異なる初期重みで学習を行い、識別率の値を計算した結果である。BPN では、収束率が極めて低くなつたので、ここでは LLGMN と MLANS、および本手法の結果を示した。図 5 から、学習用データ数が多い場

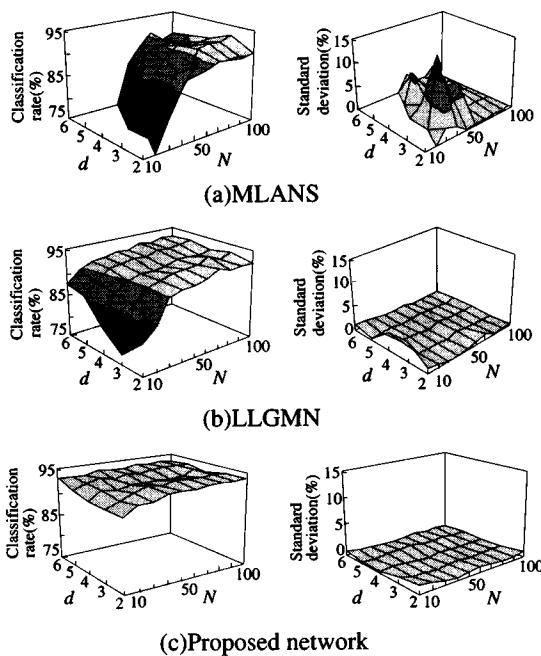


図 5 データ次元数・学習データ数に伴う識別結果の変化  
(開閉眼時)

Fig. 5 Effects of the dimension of the input vector and number of the training data on the classification results of eye opening and closing.

合はどの方法でもある程度識別できていることがわかる。しかしながら、学習用データ数が減少するにつれて LLGMN や MLANS の識別率は低下している。特に MLANS は、その傾向が強い。

MLANS は統計分布モデルをそのままニューラルネットに展開しているため、モデルのパラメータ（平均値、標準偏差）を求めるのにある程度のサンプルデータ数を必要とするからである。従って少ない学習データ数で高次元の統計分布モデルを識別する場合には識別率が低下してしまう。なお、学習用データ数が 20 個以下の場合は、MLANS に含まれる共分散行列を計算することができなかった。これは、学習用データ数が少ないとコンポーネントに含まれるデータが非常に少なくなる場合が生じるためである。

これに対し LLGMN では、混合正規分布モデルの対数線形化を行っている [6]。それによって LLGMN で推定すべきパラメータは、平均、標準偏差等の統計パラメータとは本質的に異なるものとなり、従来の統計モデルの枠組みを超えてモデルの構築ができるわけである。そのため LLGMN や本手法では、少ない学

表 3 閃光刺激時の識別結果  
Table 3 Classification results under the artificial photic stimulation.

Number of the learning data	$N = 50$		$N = 100$		
	$d = 2$	$d = 6$	$d = 2$	$d = 6$	
subject A (male)	$R_{cla}$	83.2	84.5	84.4	85.4
	$R_{sd}$	1.5	0.6	1.4	1.1
subject B (male)	$R_{cla}$	89.8	92.3	92.3	93.1
	$R_{sd}$	0.9	0.4	1.1	0.7
subject C (male)	$R_{cla}$	63.8	66.8	79.5	81.1
	$R_{sd}$	1.0	5.2	0.5	2.6
subject D (male)	$R_{cla}$	78.0	78.9	80.2	80.3
	$R_{sd}$	2.4	1.7	0.2	0.1
subject E (male)	$R_{cla}$	75.6	77.3	82.4	83.1
	$R_{sd}$	1.2	0.8	0.9	0.6

$R_{cla}$  : Classification rate(%),  $R_{sd}$  : Standard deviation(%)

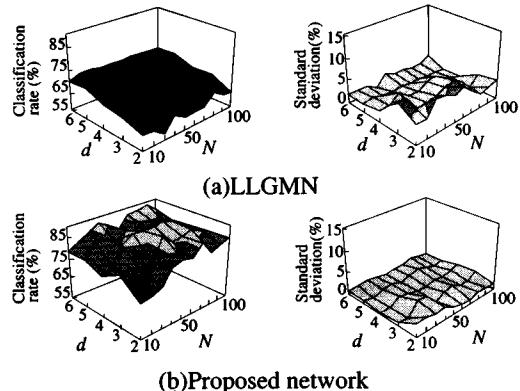


図 6 データ次元数・学習データ数に伴う識別結果の変化  
(閃光刺激時)

Fig. 6 Effects of the dimension of the input vector and number of the training data on the classification results under the photic stimulation.

習データ数で高次元の統計分布モデルを識別する場合でも、高い識別結果が得られている。更に、本手法では NF 部で時系列性を考慮して LLGMN から出力される事後確率の変動を修正することにより、より高い識別精度を実現している。

#### 4.2 閃光刺激に伴う時系列脳波パターンの識別

次に 5 人の被験者に対して、光刺激を与えたときの脳波信号のパターン識別を行った。結果を表 3 に示す。用いたデータの次元数は  $d = 2, 6$  とし、学習データ数は  $N = 50, 100$  とした。但しニューラルフィルタについては  $N = 168$  の時系列データを用いた。開閉眼時の脳波のパターン識別結果と比べて、識別率が低下しているものの、8割程度の識別が実現できている。

更に、表 3 の被験者 A について詳しく傾向を調べた。その結果を図 6 に示す。LLGMN のみで識別した場合

に比べて、本手法で識別した結果が大きく上回っている。識別率の標準偏差も小さな値に抑えられている。

## 5. むすび

本論文では、脳波パターンをマン・マシンインタフェースの一手段として利用することを目的とし、簡易小型脳波計で測定した脳波パターンの識別を行った。また、時系列パターンの識別問題にニューラルネットを適用するために、ネットワーク構造に LLGMN 部と NF 部を組み込んだ。その結果、実用的な環境下において、ある程度の精度で時系列脳波パターン識別することができた。今後は、動的な確率モデルをニューラルネット内に組み込む方法について検討していく予定である。

**謝辞** 本研究の一部は、(財)立石科学技術振興財団の援助により行われました。ここに深く感謝の意を表します。

## 文献

- [1] F.Y. Wu, J.D. Slater, L.S. Honih, and R.E. Ramsay, "A neural network for event-related potential diagnosis," Computer in biology and machine, vol.23, no.3, pp.251-264, 1993.
- [2] N. Schaltenbrand, R. Lengelle, and J.P. Macher, "Neural network model: Application to automatic analysis of human sleep," Computer and biomedical research, vol.26, no.2, pp.157-171, 1993.
- [3] M. Peltoranta and G. Pfurtscheller, "Neural network based classification of non-averaged event-related EEG responses," Med and Biol. Eng. and Comput., vol.32, pp.189-196, 1994.
- [4] 平岩 明, 内田典佳, 下原勝憲, 曽根原登, "随意運動発生直前の頭皮電位分布パターンのニューラルネットによる認識," 信学論 (D-II), vol.J79-A, no.2, pp.408-415, Feb. 1996.
- [5] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation," in Parallel Distributed Processing I, pp.318-362, MIT Press, 1986.
- [6] 辻 敏夫, 市延弘行, 金子 真, "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," 信学論 (D-II), vol.J77-D-II, no.10, pp.2093-2100, Oct. 1994.
- [7] J.T.H. Lo, "Synthetic approach to optimal filtering," IEEE Trans. Neural Networks, vol.5, no.5, pp.803-811, 1994.
- [8] L.I. Perlovsky and M.M. McManus, "Maximum likelihood neural networks for sensor fusion and adaptive classification," Neural Networks, vol.4, pp.89-102, 1991.

(平成 7 年 11 月 6 日受付, 8 年 8 月 26 日再受付)

福田 修 (学生員)



1993 九工大・情報・機械システム卒。同年、九州日本電気ソフトウェア（株）勤務。現在広島大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。計測自動制御学会等会員。日本学術振興会特別研究員。

辻 敏夫 (正員)



1985 広島大大学院工学研究科博士課程前期了。同年同大学工学部助手、1994 同助教授、現在に至る。この間、1992~1993 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、日本ロボット学会、電気学会等各会員。工博。

金子 真



1981 東大工学系研究科機械工学専門課程博士課程卒。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、現在に至る。ロボットハンドやアクティブセンシングなどの研究に興味をもつ。1984 日本機械学会奨励賞、1994 日本ロボット学会論文賞、1996 計測自動制御学会論文賞。IEEE Trans. on Robotics and Automation, Associate Editor (90-94). IEEE Robotics Magazine, Editorial Member (97-)。工博。