

次元圧縮機能を有するリカレント確率ニューラルネットの提案と 時系列脳波パターン識別への応用

島 圭介*・高田 大輔**
ト 楠***・辻 敏夫**

A Recurrent Probabilistic Neural Network with Dimensional Reduction and Its Application to Time Series EEG Discrimination

Keisuke SHIMA*, Daisuke TAKATA**,
Nan BU*** and Toshio TSUJI**

This paper proposes a novel reduced-dimensional recurrent probabilistic neural network, and tries to classify electroencephalography (EEG) during motor images. In general, a recurrent probabilistic neural network (RPNN) is a useful tool for pattern discrimination of biological signals such as electromyograms (EMGs) and EEG due to its learning ability. However, when dealing with high dimensional data, RPNNs usually have problems of heavy computation burden and difficulty in training. To overcome these problems, the proposed RPNNs incorporates a dimension-reducing stage based on linear discriminant analysis into the network structure, and a hidden Markov model (HMM) and a Gaussian mixture model (GMM) are composed in the network structure for time-series discrimination. The proposed network is also applied to EEG discrimination using Laplacian filtering and wavelet packet transform (WPT). Discrimination experiments of EEG signals measured during calling motor images in mind were conducted with four subjects. The results showed that the proposed method can achieve relatively high discrimination performance (average discrimination rates: $84.6 \pm 5.9\%$), and indicated that the method has possibility to be applied for the human-machine interfaces.

Key Words: pattern discrimination, neural network, biological signals, linear discriminant analysis, electroencephalogram

1. はじめに

筋電位 (Electromyogram; 以下, EMG) や脳波 (Electroencephalography; 以下, EEG) 信号などの生体信号は, 筋細胞や脳内の神経細胞の活動時に発生する電位的変化を計測したものであり, 人間の内部状態や意図を強く反映している¹⁾. EMG 信号や EEG 信号を用いて制御するインタフェースは従来より数多く研究が進められており, たとえば, Kato ら²⁾や

Fukuda ら³⁾の EMG 信号を利用した筋電義手や, Wolpaw ら⁴⁾の EEG 信号を入力とした Brain-Computer Interface (BCI) などが代表的である. これらは生体信号から人間の意図を正しく推定することが必要であるため, 高性能なインタフェースの実現問題は生体信号のパターン識別問題に帰着する.

生体信号のパターン識別には線形判別分析やサポートベクターマシン, ニューラルネットワーク (Neural Networks; 以下, NN) などがよく用いられる⁵⁾. 特に, NN は学習的に任意の非線形写像を獲得でき, 個人差などの特徴の変化に対応できるため, Kelly ら⁶⁾や Farry ら⁷⁾, Haselsteiner ら⁸⁾などによって誤差逆伝播型 NN を用いた EMG 信号や EEG 信号の識別が試みられている. しかしながら, 一般的に用いられている誤差逆伝播型 NN には, ネットワーク構造の決定が難しいことに加え, 学習が極小解に陥りやすく, 高精度な識別が困難になるなど多くの問題点が指摘されている.

これに対して Tsuji らは統計構造を内包したニューラルネットを構築し, 生体信号の識別法をこれまでに提案してきた^{9)~11)}. たとえばネットワークに混合正規分布モデルを内

* 広島大学大学院医歯薬学総合研究科 広島市南区霞 1-2-3

** 広島大学大学院工学研究院 東広島市鏡山 1-4-1

*** 熊本高等専門学校制御情報システム工学科
合志市須屋 2659-2

* Graduate School of Biomedical Sciences, Hiroshima University, Kasumi 1-2-3, Minami-Ku, Hiroshima

** Graduate School of Engineering, Hiroshima University, 1-4-1 Kagamiyama, Higashihiroshima

*** Department of Control and Information Systems Engineering, Kumamoto National College of Technology, 2659-2 Suya, Koshi

(Received February 15, 2011)

(Revised November 4, 2011)

包した Log-Linearized Gaussian Mixture Network (以下, LLGMN)⁹⁾や, LLGMN に隠れマルコフモデルを導入した Recurrent Log-Linearized Gaussian Mixture Network (以下, R-LLGMN)¹⁰⁾は, ネットワークに含まれるモデルパラメータを学習的に推定可能である. これらのネットワークを用いることで, EEG 信号や EMG 信号を高精度に推定でき, さまざまな機器の制御が可能である.

しかしながら, これらの方法では計測に用いる電極数を増加させたり, 周波数スペクトル情報などの高次元の特徴量を抽出して識別に用いようとすると, NN への入力である特徴ベクトルが高次元化してしまうという問題がある. 一般に NN への入力ベクトルが高次元化すると, ネットワークの構造が複雑化してパラメータの学習が困難となったり, 学習に莫大な時間が必要となってしまう. 生体信号を実用的なインタフェースに利用するためには, 高次元化した情報を効率よく利用する新たなパターン識別法が必要である.

これに対し, Bu ら¹²⁾は単一のニューラルネットで次元圧縮と識別が可能となる NN を提案し, 筋電信号の識別に応用した¹³⁾. この NN は次元圧縮機能を有しており, 学習により圧縮に必要なパラメータを重み係数として獲得できる. しかしながら, 入力パターンの時系列特性を考慮することはできず, 非定常性の強い EEG 信号などの識別は検討されていない.

そこで本論文では, 次元圧縮機能と時系列信号識別機能を有する確率ニューラルネットとして, リカレント構造を有する Reduced-Dimensional Recurrent Log-Linearized Gaussian Mixture Network (以下, RD-RLLGMN) を提案する. この NN は次元圧縮部と時系列パターン識別部から構成され, 次元圧縮部では線形判別分析 (Linear Discriminant Analysis; 以下, LDA)¹⁴⁾に基づき, 多変量時系列データの次元圧縮が可能である. また時系列パターン識別部には混合正規分布モデルと隠れマルコフモデルを内包したリカレント構造を有する確率ニューラルネットを構成し, 圧縮した時系列信号の識別を行なう. 提案する NN により, 高次元の時系列パターンを低次元に圧縮して識別することが可能となり, 学習や識別に伴う計算時間の短縮が期待できる.

以下, 2章で提案するネットワーク構造と学習則について述べ, 3章で提案する NN を用いた脳波識別法について説明する. 4章では識別実験により提案法の有効性を検討する. そして, 最後にまとめを示す.

2. 高次元時系列パターンを識別するニューラルネット

2.1 ネットワーク構造

Fig. 1 に提案する RD-RLLGMN のネットワーク構造を示す. ネットワークは, 次元圧縮部, 時系列パターン識別部から構成される. 図中の \odot は入力信号に対する線形和ユニットを, \otimes は入力信号に対する積ユニットを表わしている. また, 第1層と第2層の間, および第3層と第4層の間に重み係数が存在し, 第5層と第6層の間にリカレント結合を有する. このネットワークを用いることで, 多変量時系列パター

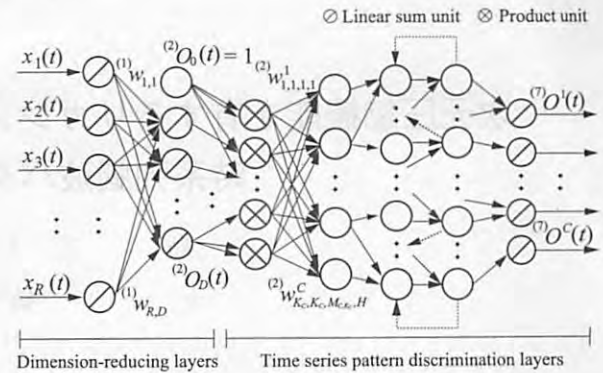


Fig. 1 Structure of the proposed network

ンに対する事後確率を算出できる. 以下, 各部について詳細を説明する.

2.1.1 次元圧縮部

まず次元圧縮部では, 長さ T の特徴ベクトル $\mathbf{x}(t) \in \mathbb{R}^R$ ($t = 1, 2, \dots, T$) を入力とし, 以下に示す (1)~(3) 式の処理により新たな特徴ベクトル $(2)O_d(t)$ ($d = 0, 1, 2, \dots, D$) を出力する.

第1層は恒等関数に基づく R 個のユニットからなり, r 番目のユニットへの入力と出力をそれぞれ $(1)I_r(t)$, $(1)O_r(t)$ とすると, 入出力関係は,

$$(1)O_r(t) = (1)I_r(t) = x_r(t) \quad (1)$$

となる. ここで $x_r(t)$ ($r = 1, 2, \dots, R$) は $\mathbf{x}(t)$ の各成分である.

つぎに第2層では, 第1層の出力に対して重み係数 $(1)\mathbf{W} = [(1)w_{r,d}] \in \mathbb{R}^{R \times D}$ ($r = 1, 2, \dots, R; d = 1, 2, \dots, D$) を掛け合わせて特徴ベクトルの次元圧縮を行なう. 第2層は圧縮後の次元数に1を加えた $D+1$ 個のユニットからなり, 各ユニットの入力を $(2)I_d(t)$, 出力を $(2)O_d(t)$ としたとき, 入出力関係は,

$$(2)I_d(t) = \sum_{r=1}^R (1)O_r(t) (1)w_{r,d} \quad (2)$$

$$(2)O_d(t) = \begin{cases} 1 & d = 0 \\ (2)I_d(t) & d = 1, 2, \dots, D \end{cases} \quad (3)$$

となる. ただし, 第3層 (時系列パターン識別部, (8)~(10)式参照) で行なう非線形変換¹⁰⁾を積ユニットを用いて実現するため, 第2層には常に1を出力する0番目のユニットを設けている.

2.1.2 時系列パターン識別部

つぎに時系列パターン識別部に $(2)O_d(t)$ を入力し, 各クラス c ($c = 1, \dots, C$) の事後確率を計算する. 時系列パターン識別部には R-LLGMN¹⁰⁾を導入する. R-LLGMN は, 混合正規分布型の連続確率密度分布をもつ隠れマルコフモデル (Fig. 2) をネットワークに内包しており, 入力の時系列的なつながりに対してクラス c に対する事後確率を出力できる.




Fig. 2 A continuous density hidden Markov model with Gaussian mixture state observation densities¹⁰⁾

いま、たとえば D 次元ベクトル時系列 $\mathbf{X}(t) \in \mathbb{R}^D$ に対してクラス c の事後確率 $P(c|\mathbf{X}(t))$ を算出する場合を考える。このとき、各クラス c が K_c 個の状態から構成されるとすれば、事後確率は

$$P(c|\mathbf{X}(t)) = \sum_{k=1}^{K_c} P(c, k|\mathbf{X}(t)) \quad (4)$$

$$P(c, k|\mathbf{X}(t)) = \frac{a_k^c(t)}{\sum_{c'=1}^C \sum_{k'=1}^{K_{c'}} a_{k'}^{c'}(t)} \quad (5)$$

$$a_k^c(t) = \sum_{k'=1}^{K_c} a_{k'}^c(t-1) \gamma_{k',k}^c b_k^c(\mathbf{X}(t)) \quad (1 < t \leq T) \quad (6)$$

$$a_k^c(1) = \pi_k^c b_k^c(\mathbf{X}(1)) \quad (7)$$

として算出可能である¹⁰⁾。ただし、 $\gamma_{k',k}^c$ はクラス c において状態 k' から状態 k への遷移確率、 $b_k^c(\mathbf{X}(t))$ は $\mathbf{X}(t)$ に対応したクラス c における状態 k の事後確率を表わしている。また、事前確率 π_k^c は $P(c, k)|_{t=0}$ と等しい。時系列パターン識別部では、上記の処理 (4)~(7) 式をネットワーク内部で行なうために、各層の計算を以下に示すように構成する。

ネットワークの前向き計算では、まず第3層で入力ベクトル $(2)O_d(t)$ の非線形変換を行なう。第3層は $H = 1 + D(D+3)/2$ 個の積ユニットから構成されており、2つの入力 $(3)I_{h,1}(t)$, $(3)I_{h,2}(t)$ の積を出力する。第3層のユニットの出力を $(3)O_h(t)$ とすると、入出力関係は、

$$(3)I_{h,1}(t) = (2)O_d(t) \quad (8)$$

$$(3)I_{h,2}(t) = (2)O_d'(t) \quad (9)$$

$$(3)O_h(t) = (3)I_{h,1}(t)(3)I_{h,2}(t) \quad (10)$$

となる。ただし $d \geq d'$ ($d, d' = 0, 1, 2, \dots, D$) である。また、 $h = 1, 2, \dots, H$ で、 h は $h = -\frac{1}{2}d^2 + (D + \frac{1}{2})d' + d + 1$ で与えられる。

つぎに第4層のユニット $\{c, k, k', m\}$ ($c = 1, \dots, C$; $k, k' = 1, \dots, K_c$; $m = 1, \dots, M_{c,k}$) は、第3層のユニットの出力に重み係数 $(2)w_{k',k,m,h}^c$ が掛け合わされたものを入力として受け取る。ただし、 $(2)w_{k',k,m,h}^c$ は隠れマルコフモデルと混合正規分布モデルの各パラメータに相当し¹⁰⁾、 K_c は隠れマルコフモデルの状態数、 $M_{c,k}$ はクラス c 、状態 k に対応する混合正規分布モデルのコンポーネント数を表わす。各ユニットへの入力を $(4)I_{k',k,m}^c(t)$ 、出力を $(4)O_{k',k,m}^c(t)$ とし

て、第4層の入出力関係は次式で表わされる。

$$(4)I_{k',k,m}^c(t) = \sum_{h=1}^H (3)O_h(t) (2)w_{k',k,m,h}^c \quad (11)$$

$$(4)O_{k',k,m}^c(t) = \exp\left((4)I_{k',k,m}^c(t)\right) \quad (12)$$

第5層のユニット $\{c, k, k'\}$ への入力 $(5)I_{k',k}^c(t)$ は、第4層のユニット $\{c, k, k', m\}$ ($m = 1, \dots, M_{c,k}$) の出力を統合したものである。また、入力に状態 k' に対応する1時刻前の第6層の出力を乗じた値が第5層の出力 $(5)O_{k',k}^c(t)$ となる。入出力関係は、

$$(5)I_{k',k}^c(t) = \sum_{m=1}^{M_{c,k}} (4)O_{k',k,m}^c(t) \quad (13)$$

$$(5)O_{k',k}^c(t) = (6)O_{k',k}^c(t-1) (5)I_{k',k}^c(t) \quad (14)$$

となる。ただし、初期状態は $(6)O_{k',k}^c(0) = 1.0$ とする。

さらに第6層の入出力 $(6)I_k^c(t)$, $(6)O_k^c(t)$ は、

$$(6)I_k^c(t) = \sum_{k'=1}^{K_c} (5)O_{k',k}^c(t) \quad (15)$$

$$(6)O_k^c(t) = \frac{(6)I_k^c(t)}{\sum_{c'=1}^C \sum_{k'=1}^{K_{c'}} (6)I_{k'}^{c'}(t)} \quad (16)$$

と与えられる。

最後に、第7層のユニット c への入力 $(7)I^c(t)$ は第6層の K_c 個のユニット $\{c, k\}$ ($k = 1, \dots, K_c$) の出力を用いる。入出力関係は、

$$(7)O^c(t) = (7)I^c(t) = \sum_{k=1}^{K_c} (6)O_k^c(t) \quad (17)$$

となる。この出力 $(7)O^c(t)$ がクラス c に対する事後確率に相当する。

以上のように、提案する NN は第5層と第6層の間にリカレント結合を有しており、1時刻前の出力を考慮することができる。提案する NN を用いることで、各パターンの時系列的なつながりを情報として利用でき、時系列信号の識別が可能となる。

2.2 ネットワークの学習

つぎに、ネットワークの学習則について説明する。教師あり学習では、教師信号とネットワークの出力の誤差を評価関数とし、これを最小にするようにネットワーク全体の重み係数の修正を行なうのが望ましい。しかしながら時系列パターン識別部から次元圧縮部に適切な誤差が伝播される保証はなく、各部を同時に学習することは難しい。そこで、本論文ではネットワークの学習を2つのステップに分けて行なう。以下、各ステップについて詳細を示す。なお、ここでは学習データとして、長さ T の時系列信号を各クラス N サンプルずつ用意することとし、クラス c に対応する n 番目 ($n = 1, 2, \dots, N$) の学習サンプルを $\mathbf{x}_c^{(n)}(t) \in \mathbb{R}^M = [x_{1,c}^{(n)}(t), \dots, x_{M,c}^{(n)}(t)]^T$ ($t = 1, 2, \dots, T$)

とする。ただし $[\cdot]^T$ はベクトルの転置を表わす。

2.2.1 次元圧縮部の学習

まず、次元圧縮部の学習を行なう。次元圧縮部の出力 $(2)O_d(t)$ は各クラス間でデータが分離し、クラスごとに異なる時系列特性をもつ信号が望ましいと考えられる。そこで本論文では、LDA¹⁴⁾に基づいて重みパラメータ $(1)W$ を決定することを考える。このとき、学習データに対する出力 $(2)O_d(t)$ の分離度を評価関数として次式のように定義し、これを最大化するように $(1)W$ を決定する。

$$E_1 = \frac{\det((1)W^T S_b (1)W)}{\det((1)W^T S_w (1)W)} \quad (18)$$

ここで、 $\det(\cdot)$ は行列式を表わす。また、 S_b 、 S_w はそれぞれ時刻 1 から T までのクラス間分散共分散行列、クラス内分散共分散行列の総和であり、以下のように定義する。

$$S_b = \frac{1}{C} \sum_{t=1}^T \sum_{c=1}^C (\bar{x}_c(t) - \bar{x}(t)) (\bar{x}_c(t) - \bar{x}(t))^T \quad (19)$$

$$S_w = \frac{1}{CN} \sum_{t=1}^T \sum_{c=1}^C \sum_{n=1}^N (\bar{x}_c(t) - x_c^{(n)}(t)) (\bar{x}_c(t) - x_c^{(n)}(t))^T \quad (20)$$

$$\bar{x}_c(t) = \frac{1}{N} \sum_{n=1}^N x_c^{(n)}(t) \quad (21)$$

$$\bar{x}(t) = \frac{1}{CN} \sum_{c=1}^C \sum_{n=1}^N x_c^{(n)}(t) \quad (22)$$

ここで、 $\bar{x}_c(t)$ は各クラスの学習データ $x_c^{(n)}(t)$ の平均値、 $\bar{x}(t)$ は全学習データの平均値とする。このとき、この評価関数 E_1 を最大化する重みパラメータ $(1)W$ を求める問題は行列 $S_w^{-1} S_b \in \mathbb{R}^{M \times M}$ の固有ベクトルを求める問題に帰着し、固有値の大きい順に D 個の固有ベクトルを並べることで $(1)W$ が計算できる¹⁴⁾。ここで、 D は行列 $S_w^{-1} S_b$ のランクで、圧縮後の次元数となる。 S_b 、 S_w はそれぞれクラス間分散共分散行列、クラス内分散共分散行列の総和であり、クラス数が C の場合は行列のランクは近似的に $C-1$ になる。以上のように、本論文では各時刻におけるデータの分離を考慮しているため、多変量データのパターンが時間的に変化する場合でも、その時系列特性を $(2)O_d(t)$ に反映した次元圧縮が期待できる。

2.2.2 時系列パターン識別部の学習

つぎに、次元圧縮部の重みを固定した状態で、時系列パターン識別部の学習を行なう。ここで、クラス c に対応する学習データ $x_c^{(n)}(t)$ に対して、教師信号 $T_c^{(n)} = [T_{1,c}^{(n)}, \dots, T_{c',c}^{(n)}, \dots, T_{C,c}^{(n)}]^T$ が与えられた場合を考える。ただし、 $c' = c$ のとき $T_{c',c}^{(n)} = 1$ とし、それ以外 ($c' \neq c$) は $T_{c',c}^{(n)} = 0$ とする。学習データに対するネットワークの評価関数 E_2 を、

$$\begin{aligned} E_2 &= - \sum_{n=1}^N \sum_{c=1}^C \sum_{c'=1}^C T_{c',c}^{(n)} \log^{(7)} O^c(T)^{(n)} \\ &= - \sum_{n=1}^N \sum_{c=1}^C T_{c,c}^{(n)} \log^{(7)} O^c(T)^{(n)} \end{aligned} \quad (23)$$

と定義し、これを最小化、すなわち対数尤度を最大化するように学習を行なう¹⁰⁾。ただし、 $(7)O^c(T)^{(n)}$ は入力ベクトル $x_c^{(n)}(t)$ に対する時刻 T での出力を意味している。重みの更新には、通時誤差逆伝播学習法 (BPTT)¹⁵⁾ を用いる。さらに、学習を決められた学習回数で収束させるために Zak が提案したターミナルアトラクタ¹⁶⁾ を学習則に導入し、学習回数の上限值を設定可能とした¹⁰⁾。以上により、次元圧縮部の出力の時系列特性を学習により獲得でき、時系列特性の違いに対応した識別が期待できる。

3. 脳波識別への応用

本論文では、提案する RD-RLLGMN の識別能力を検証するため、EEG 信号を対象として Fig. 3 に示す識別法を提案する。提案手法では特徴抽出処理として、空間ラプラシアンフィルタ¹⁷⁾ とウェーブレット変換¹⁸⁾ を使い、計測した各チャンネルの EEG 信号を周波数成分ごとに分割し、RD-RLLGMN への入力としてパターン識別を行なう。

まず、計測部位に装着した L 個の電極と、 l 番目 ($l = 1, 2, \dots, L$) の電極を囲むように装着した U_l 個の電極から得られる EEG 信号をそれぞれ $EEG_l(t)$ ($l = 1, 2, \dots, L$)、 $EEG_{u_l}(t)$ ($u_l = 1, 2, \dots, U_l$) とし、次式の処理を行なう¹⁷⁾。

$$EEG'_l(t) = EEG_l(t) - \frac{1}{U_l} \sum_{u_l=1}^{U_l} EEG_{u_l}(t) \quad (24)$$

なお、計測部位は識別対象とするタスクと脳の活動領域を考慮し決定する。(24) 式により、EEG 信号に混入する筋電信号、眼電信号などのアーチファクトを軽減でき、EEG 信号の精度を高めることができる¹⁷⁾。

つぎに、 $EEG'_l(t)$ に対して次式よりウェーブレット変換を行ない、各信号を周波数成分ごとに分割する¹⁸⁾。

$$W_l(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} EEG'_l(t) \overline{\psi_{a,b}(t)} dt \quad (25)$$

$\overline{\psi_{a,b}(t)}$ はウェーブレット関数 $\psi_{a,b}(t)$ の複素共役、 a は周波数、 b は時間に対応しており、ウェーブレット係数 $W_l(a, b)$ より EEG 信号の各周波数成分の時間的な変化を連続的に捉えることができる。本論文では演算時間を考慮し、ウェーブレットパケット展開を用いる¹⁸⁾。この手法では、まず (25) 式の a, b をレベル j 、シフト v を用いて $a = 2^j$ 、 $b = 2^j v$ とおく。そして、次式により漸次的にレベル 1 から事前に設定した最大分解レベル J まで分解を繰り返すことで、ウェーブレット係数 $W_l^{(j,i)}(v)$ ($i = 1, 2, \dots, 2^j$) を求めることができる¹⁸⁾。

$$W_l^{(0,i)}(v) = EEG'_l(v) \quad (26)$$




Fig. 3 EEG discrimination method

$$W_l^{(j,2i-1)}(v) = \sum_s p(s-2v)W_l^{(j-1,i)}(s) \quad (27)$$

$$W_l^{(j,2i)}(v) = \sum_s q(s-2v)W_l^{(j-1,i)}(s) \quad (28)$$

ここで、 $p(v)$ 、 $q(v)$ はそれぞれウェーブレット関数、スケーリング関数を表わす数列であり、ウェーブレット関数に応じてあらかじめ与えられる。本論文では、Daubechie の関数¹⁸⁾を用い、4 個の数値で構成される数列とした。また、 $W_l^{(j,i)}(v)$ の添字 i は i 番目の周波数域を表わしており、最大分解レベル J まで分解すると 2^J 個のウェーブレット係数を得ることができる。

本論文では、以上より求めた 2^J 個のウェーブレット係数から脳波の周波数帯域に対応するウェーブレット係数 I 個 ($I \leq 2^J$) を用いる。この $L \cdot I$ 個のウェーブレット係数を EEG 信号と同じ時間軸で扱うため、シフト v に基づいて時系列的に並べ再サンプリングした信号を $W_l^{(j,i)}(t)$ ($i = 1, 2, \dots, I; l = 1, 2, \dots, L$) とする。そして、それぞれをカットオフ周波数 f_c [Hz] の低域通過フィルタを用いて平滑化し、事前に取得したデータの最小値を 0、最大値を 1 とする正規化処理を施した信号を $\bar{W}_l^{(j,i)}(t)$ とする。ここで得られた信号を NN への入力ベクトル $\mathbf{x}(t) \in \mathbb{R}^R$ ($R = L \cdot I$) として脳波パターンの識別を行なう。

4. 実験

提案法の有効性を検証するために複数の被験者から EEG 信号を計測し、パターン識別実験を行なった。被験者は健康な男子大学生 4 名 (A~D: 22~24 歳) とした。被験者には事前に実験の目的を十分に説明し、同意を得た上で実験を行なった。EEG 信号の計測にはマルチテレメータ (NEC 三栄 MT-11)、電極には Ag/AgCl 電極 (GE marquette 製 SEB120) を用いた。なお本論文では、以下に示す 2 つ条件で EEG 信号の計測を行なった。

(1) 左右の第 2 指の屈伸動作

被験者は通常の計算機室の椅子に座り、安静状態でつぎの 3 種類のタスク (Fig. 4(a) 参照) を行なっているときの EEG 信号を計測する。それぞれ (a) 右手第 2 指の屈曲と伸展の繰り返しを 10 秒間行なった後、10 秒間動作を行なわない (以下、右手動作)、(b) 左手第 2 指の屈曲と伸展の繰り返しを 10 秒間行なった後、10 秒間動作を行なわない (以下、左手動作)、(c) 20 秒間動作を行なわ

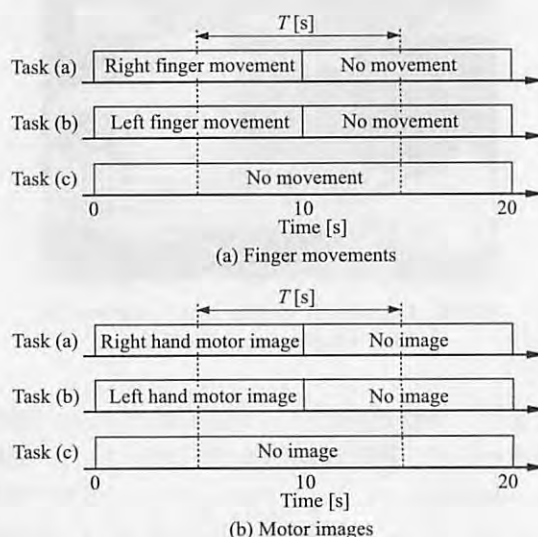


Fig. 4 Experimental paradigm used in this paper

ない (以下、動作なし) である。各 20 秒間を 1 サンプルとし、各タスク 30 サンプル分の EEG 信号を計測した。

(2) 左右の手の運動イメージ

(1) で対象とした指の屈伸運動の代わりに、左右の手の第 2 指の屈曲と伸展を繰り返す運動を頭の中でイメージする (実際には指は動かさない) タスクを対象とする。(a) 右手運動イメージを 10 秒間行なった後、10 秒間何もイメージしない (以下、右手イメージ)、(b) 左手運動イメージを 10 秒間行なった後、10 秒間何もイメージしない (以下、左手イメージ)、(c) 20 秒間何もイメージしない (以下、イメージなし) という 3 種類のタスクを被験者に行なわせた (Fig. 4(b) 参照)。各 20 秒間を 1 サンプルとし、各タスク 30 サンプル分の EEG 信号を計測した。

計測した 20 秒間の信号のうち、Fig. 4 に示す中間時刻である 10 秒を中心として前後 T 秒間 (図中の点線間) の EEG 信号を学習、識別に用いる。これにより、動作もしくはイメージ終了時に生じる時系列変化を特徴として利用できる可能性がある。各被験者は、30 分間程度の簡単な練習を行なった後、計測を行なった。また、サンプリング周波数は 1 kHz とした。

計測に用いる電極は、運動野との対応を考慮し、国際 10-20 電極法に基づいて Fig. 5 に示すように装着した。本論文では装着時間や使用者の負担を少しでも軽減するため電極数は 9 個とした。そして C3、Cz、C4 の 3 個 ($L = 3$) の電極か




Fig. 5 Location of electrodes




Fig. 6 Developed system and overview of EEG signals discrimination

ら計測する EEG 信号に対し、周辺 4 個 ($U = 4$) の電極から計測する EEG 信号を利用しラプラシアンフィルタ処理を施す。事前実験より、ウェーブレットパケット展開の最大分解レベルは $J = 7$ 、低域通過フィルタのカットオフ周波数は $f_c = 0.1$ Hz とし、NN への入力ベクトルには $\tilde{W}_l^{(j,i)}(t)$ を 5 Hz にダウンサンプリング処理した信号を用いることにした。また、各 EEG 信号から得られる $2^7 = 128$ 個のウェーブレット係数から、脳波の周波数帯域 0~40 Hz に対応する 10 個 ($I = 10$) を入力ベクトルとし ($R = 30$)、 $N = 15$ 、 $T = 12$ とした。時系列パターン識別部のパラメータは、各クラスの状態数 $K_c = 2$ ($c = 1, 2, \dots, C$)、コンポーネント数 $M_{c,K_c} = 2$ ($c, \acute{c} = 1, 2, \dots, C$)、ターミナルアトラクタの学習回数の上限値は 1000 回とし、次元圧縮部の出力次元数は $D = 1$ とした。

Fig. 6 の写真は提案法を用いて運動イメージ時の EEG 信号を計測・識別している風景の一例である。このように、提案法はリアルタイムで脳波を識別し、被験者の意図した運動イメージを識別する。

4.1 EEG 信号識別実験

4 名の被験者から計測した EEG 信号の識別実験を行なった。動作時の EEG 信号の処理結果の一例を Fig. 7 に示す。図は、左右の第 2 指の動作時 ($C = 2$; クラス 1: 右手動作, クラス 2: 左手動作) の EEG 信号の処理結果であり、計測開始から 10 秒を中心として $T (= 12)$ 秒間のデータをプロットしている。被験者は A である。図 (a) は上から各チャネルから計測した EEG 信号、次元圧縮部の出力 ${}^{(2)}O_1(t)$ で、(b) は次元圧縮部の出力を複数試行分示したものであり、(a) に示した ${}^{(2)}O_1(t)$ を含めて記載している。また、陰影をつけた領域は第 2 指の動作を行なった区間を表わす。図より、計測した EEG 信号には大きな変化はみられないが、圧縮後の信

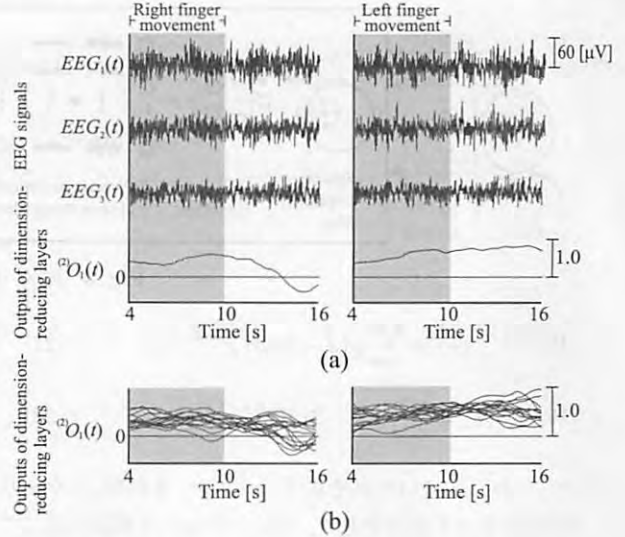


Fig. 7 Examples of the measured EEG on finger movements (subject A)

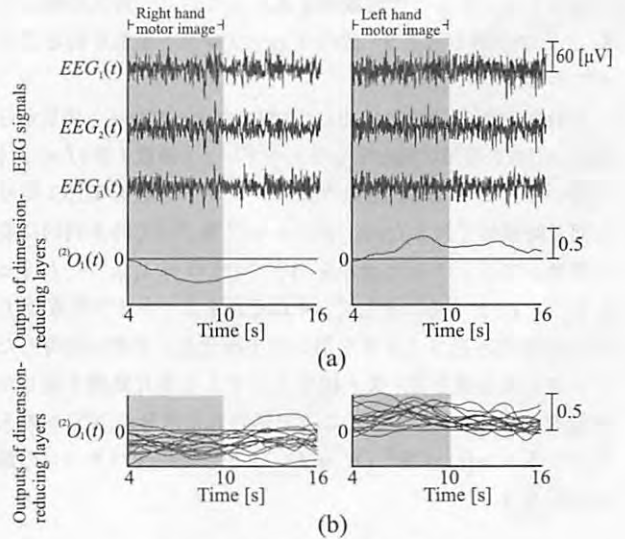


Fig. 8 Examples of the measured EEG on motor images (subject A)

号 ${}^{(2)}O_1(t)$ には右手動作後に緩やかな減少がみられる。これは、右手動作の終了に起因して EEG 信号に変化が現れたためと考えられる。

Fig. 8 に運動イメージ時の処理結果の一例を示す。図は、左右の手の運動イメージ時 ($C = 2$; クラス 1: 右手イメージ, クラス 2: 左手イメージ) の EEG 信号の処理結果で、被験者は A である。なお、図の見方は Fig. 7 と同様である。図では、圧縮後の時系列信号 ${}^{(2)}O_1(t)$ が右手運動イメージ中から終了後にかけておおむね 0 を下回る負の値をとっている。それに対し、左手運動イメージ中から終了後にかけては、 ${}^{(2)}O_1(t)$ がおおむね 0 を上回るような傾向がみられる。このように、左右の運動イメージによって発生する EEG 信号を、提案法を用いて異なる特徴を有する時系列信号に圧縮できることが明らかになった。

つぎに、各被験者の識別率を Table 1 に示す。各識別率

Table 1 Discrimination rates

Sub.	Finger movements			
	Right - Left	Right - No	Left - No	Right-Left-No
A	73.2 ± 5.8	89.8 ± 8.0	95.2 ± 3.2	66.4 ± 8.1
B	94.5 ± 3.3	93.9 ± 4.9	85.9 ± 5.6	86.0 ± 4.8
C	72.1 ± 7.1	65.1 ± 10.4	74.2 ± 9.5	63.2 ± 7.5
D	70.4 ± 7.5	71.3 ± 7.3	57.3 ± 9.2	52.4 ± 7.4
Sub.	Motor images			
	Right - Left	Right - No	Left - No	Right-Left-No
A	86.4 ± 4.8	86.1 ± 4.7	99.6 ± 1.2	78.9 ± 7.4
B	66.4 ± 8.5	73.5 ± 10.1	81.4 ± 6.6	65.2 ± 8.1
C	64.2 ± 7.3	74.5 ± 8.9	70.6 ± 8.5	53.3 ± 11.0
D	73.1 ± 6.7	82.8 ± 6.7	50.6 ± 3.4	50.5 ± 5.7

Average discrimination rate ± Standard deviation [%]

Left : Left finger movement / Left hand motor image

Right : Right finger movement / Right hand motor image

No : No movement / No image

は、学習データと識別データが無作為に50通り変更し、各組み合わせで重み初期値を10回変更して学習、識別したときの平均識別率である。なお、3クラス識別では $D=2$ とした。表より、被験者によりばらつきが見られるが、これは被験者のタスクの習得度の違いが大きいと考えられる。左右の第2指の屈伸動作($C=2$; クラス1:右手動作, クラス2:左手動作)のEEG信号の4名分の平均識別率は $77.6 \pm 5.9\%$ 、左右の手の運動イメージ($C=2$; クラス1:右手イメージ, クラス2:左手イメージ)のEEG信号の4名分の平均識別率は $72.5 \pm 6.9\%$ となった。さらに、各被験者で識別率が最大になるタスクの組み合わせ(Table 1 陰影部分)の平均識別率は動作時で $83.8 \pm 5.8\%$ 、運動イメージ時で $84.6 \pm 5.9\%$ となった。結果より、被験者はわずか30分程度の簡単な練習しか行っていないものの、提案法を用いてある程度の識別率を実現できることがわかった。

4.2 識別能力・学習時間の比較

提案法の有効性を確認するため、R-LLGMN¹⁰⁾とBuらによって提案されたReduced-Dimensional Log-Linearized Gaussian Mixture Network (以下、RD-LLGMN)¹²⁾、そしてLDA¹⁴⁾と一般的な誤差逆伝播型NN (以下、BPNN)を組み合わせた識別法との比較実験を行なった。R-LLGMNは時系列信号を学習的に識別可能であるが、次元圧縮機能は備えていない。一方、RD-LLGMNは学習により次元圧縮が可能であるが、時系列信号よりも静的な入力パターンの識別に適しているという特徴を有している。またBPNNで識別を行なう場合、時系列信号の各サンプルを入力層への入力とし、ネットワークの構造は入力層60、中間層20、出力層2とした。学習は、出力誤差が0.01になるまで行なった。10000回以上学習を繰り返しても収束しなかったものはデータから除外した。

比較結果をTable 2に示す。各識別率は、学習データと識別データが無作為に50通り変更し、それぞれの組み合わせで重み初期値を10回変更して学習、識別したときの平均識別率である。比較実験では、R-LLGMNのパラメータは提案

Table 2 Discrimination rates in the comparison experiments

Sub.	Task	Proposed NN	RD-LLGMN	R-LLGMN	LDA+BPNN
A	Left - No	99.6 ± 1.2	65.5 ± 8.5	92.7 ± 4.8	70.3 ± 9.2
B	Left - No	81.4 ± 6.6	56.1 ± 10.4	84.9 ± 4.9	62.9 ± 11.2
C	Right - No	74.5 ± 8.9	51.5 ± 6.8	75.2 ± 7.7	58.3 ± 9.7
D	Right - No	82.8 ± 6.7	69.5 ± 8.1	80.5 ± 7.7	63.2 ± 10.3
Ave.		84.6 ± 5.9	60.7 ± 8.5	83.3 ± 6.3	63.7 ± 10.1

Average discrimination rate ± Standard deviation [%]

Right: Right hand motor image Left: Left hand motor image

No: No image

Table 3 Computation time for learning (subject C)

Proposed NN	RD-LLGMN	R-LLGMN
11.1 ± 1.8	38.4 ± 1.1	2565.3 ± 118.6

Average computation time ± Standard deviation [s]

するNNの時系列パターン識別部と同数に設定した。また、RD-LLGMNは圧縮次元数を3、学習率を0.001、学習回数を500回に設定した。識別処理では各時刻で事後確率が最大となるクラスを計算し、 T 秒間の時系列信号を通じて事後確率が最大となる回数が最も多いクラスを識別結果とした。また、識別にはTable 1の各被験者の識別率が最大となった運動イメージ時のタスクの組み合わせを用いた。

結果より、RD-LLGMNとBPNNの識別率が大きく低下していることがわかる。RD-LLGMNは入力パターンの時系列特性を考慮していないため、変動の大きいEEG信号の特徴パターンの学習が困難になり識別精度が低下した。また、BPNNはLDAによって次元圧縮を行なっており、さらに時系列信号の各サンプルを入力層への入力としているため、RD-LLGMNと同程度の識別精度が得られている。しかしながら、ネットワークの学習時には学習が収束しないケースが見られ、識別結果もばらつきが大きくなった。これに対し、提案するNNとR-LLGMNは同程度の識別率を示している。

識別法を生体信号を用いた機器制御のインタフェースへ応用する場合、識別器の学習はできる限り短時間で実現することが望ましい。この点から、各ネットワークの学習時間を計算した。Table 3に、被験者Cの各ネットワークの学習に要した時間を示す(CPU Pentium 4, 3.0 GHz)。ただし、BPNNについては学習時間が莫大になったため記述を省略した。表より提案するNN、RD-LLGMNと比較して、R-LLGMNでは多大な学習時間がかかっていることがわかる。R-LLGMNは次元圧縮を行っていないことから、入力次元数の増加に伴いネットワーク構造が大規模(第1層のユニット数496)になり、1回の学習にかかる時間が増加したためである。このことから、高次元化したEEG信号パターンに対しても提案NNのもつ次元圧縮能力によって短時間の学習が可能となり、非定常性の強い動作イメージ時のEEG信号を識別可能であることが示された。

5. まとめと今後の課題

本論文では、次元圧縮機能とリカレント構造を導入した確率ニューラルネットの提案を行なった。提案するNNは次元

圧縮部と時系列パターン識別部から構成されており、多変量時系列パターンの識別が可能となる。実験では、空間ラプラスアンフィルタとウェーブレット変換を用いた特徴抽出処理と提案する NN を組み合わせ、4名の被験者から計測した EEG 信号から運動イメージを $84.6 \pm 5.9\%$ の平均識別率で識別できることを確認した。提案する NN では、入力された時系列パターンの各クラスに対する事後確率をリカレント構造に基づいて計算することができ、また次元圧縮機能により学習時間を大幅に短縮することが可能である。

今後は識別精度の向上を目指し、NN の重み係数を同時に調節可能なネットワーク構造や学習則の検討を行なっていく必要がある。さらに、提案法の特徴を生かした生体信号インタフェースへの応用を検討していく予定である。

参考文献

- 1) 佐藤, 松岡: 最新臨床脳波学, 朝倉書店 (2006)
- 2) I. Kato, E. Okazaki, H. Kikuchi and K. Iwanami: Electropneumatically controlled hand prosthesis using pattern recognition of myo-electric signals, *Dig. 7th ICMBE*, 367/367 (1967)
- 3) O. Fukuda, T. Tsuji, M. Kaneko and A. Otsuka: A Human-Assisting Manipulator Teleoperated by EMG Signals and Arm Motions, *IEEE Trans. Robot. Autom.*, 19-2, 210/222 (2003)
- 4) J.R. Wolpaw, D.J. McFarland, T.M. Vaughan and G. Schalk: The Wadsworth Center Brain-Computer Interface (BCI) Research and Development Program, *IEEE Trans. Neural Syst. Rehabil. Eng.*, 11-2, 1/4 (2003)
- 5) F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche and B. Arnaldi: A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces, *Journal of Neural Engineering*, 4-2, R1 (2007)
- 6) M.F. Kelly, P.A. Parker and R.N. Scott: Neural network classification of myoelectric signal for prosthesis control, *Journal of Electromyography and Kinesiology*, 1-4, 229/236 (1991)
- 7) K.A. Farry, I.D. Walker and R.G. Baraniuk: Myoelectric Teleoperation of a Complex Robotic Hand, *IEEE Trans. Robot. Autom.*, 12-4, 775/788 (1996)
- 8) E. Haselsteiner and G. Pfurtscheller: Using Time-Dependant Neural Networks for EEG Classification, *IEEE Trans. Rehabil. Eng.*, 8-4, 457/463 (2000)
- 9) T. Tsuji, O. Fukuda, H. Ichinobe and K. Makoto: A Log-Linearized Gaussian Mixture Network and Its Application to EEG Pattern Classification, *IEEE Trans. Syst., Man, Cybern. C*, 29-1, 60/72 (1999)
- 10) T. Tsuji, N. Bu, O. Fukuda and M. Kaneko: A Recurrent Log-Linearized Gaussian Mixture Network, *IEEE Trans. Neural Netw.*, 14-2, 304/316 (2003)
- 11) 岡本, 村上, 柴, 辻: 木構造を有する階層型確率ニューラルネットワークの提案と指形状識別への応用, 計測自動制御学会論文集, 43-2, 128/134 (2007)
- 12) N. Bu and T. Tsuji: Multivariate Pattern Classification based on Local Discriminant Component Analysis, *Proceedings of IEEE International Conference on Robotics and Biomimetics*, 924/929 (2004)
- 13) T. Tsuji, N. Bu, J. Arita and M. Ohga: A Speech Synthesizer Using Facial EMG Signals, *International Journal of Computational Intelligence and Applications*, 7-11, 1/15 (2008)
- 14) ボルチ, ファング: 応用多変量解析, 森北出版, 197/204 (1976)
- 15) P.J. Werbos: Backpropagation Through Time: What It Does and How to Do It, *Proc. IEEE*, 78-10, 1550/1560 (1990)
- 16) M. Zak: Terminal attractors for addressable memory in neural networks, *Physics Letters A*, 133-1/2, 18/22 (1988)
- 17) P. Nunez, R. Silberstein, P. Cadusch, R. Wijesinghe, A. Westdorp and R. Srinivasan: A theoretical and experimental study of high resolution EEG based on surface Laplacians and cortical imaging, *Electroencephalography and Clinical Neurophysiology*, 90-1, 40/57 (1994)
- 18) I. Daubechies: Ten Lectures on Wavelets (CBMS-NSF Regional Conference Series in Applied Mathematics), SIAM: Society for Industrial and Applied Mathematics (1992)

[著者紹介]

島 圭介 (正会員)



2005年広島大学工学部第二類卒業。2007年同大学院工学研究科博士課程前期修了。2009年同博士課程後期修了。2007~2008年日本学術振興会特別研究員(DC1)。現在、同特別研究員(PD)。博士(工学)。生体信号解析, ニューラルネット, ヒューマンインタフェース, 医療システムなどの研究に従事。IEEEなどの会員。

高田 大輔



2006年広島大学工学部第二類卒業。2008年同大学院工学研究科博士課程前期修了。在学中は EEG 信号の計測と識別法に関する研究に従事。

ト 楠



1998年中国大連理工大学機械工学科卒業。2001年同大学大学院機械工学専攻修士課程終了。2005年広島大学大学院工学研究科博士課程後期終了。2005年同大学院工学研究科研究員。2006年より産業技術総合研究所研究員。現在、熊本高等専門学校准教授。博士(工学)。ニューラルネット, パターン識別, 生体信号解析, ニューロチップなどの研究に従事。IEEE 会員。

辻 敏夫 (正会員)



1985年広島大学大学院工学研究科博士課程前期修了。同大学工学部助手, 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。計測自動制御学会学術奨励賞(86), 同論文賞(2002), バイオメカニズム学会論文賞(90), 日本義肢装具学会論文賞(2000), the K.S. Fu Memorial Best Transactions Paper Award of the IEEE Robotics (2003), 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。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の研究に従事。IEEE, 日本人間工学会, バイオメカニズム学会, 日本機械学会, 電気学会などの会員。