

## パターン認識における特徴抽出法の比較実験

市村 直幸      竹内 倶佳      永井 豊

電気通信大学 電子工学科  
〒182 東京都調布市調布ヶ丘 1-5-1  
Tel:0424-83-2161(内 3453)      Fax:0424-80-3801

あらまし：パターン認識において特徴抽出は、識別率の向上等のための重要な過程である。本報告では、カラー画像から得られるパターンベクトルに対し、多層パーセプトロンで実現される非線形性の利用可能な特徴抽出手法をはじめ、線形手法、学習型識別指向手法を適用し、比較、検討を行った。その結果、以下のことが確認された。(1) カテゴリ情報および非線形性を利用可能な手法が、他の方法に比較し、学習および評価データの両方に対して、安定した識別率を与える。(2) 識別指向型 MLP は、カテゴリの競合状態を反映した出力を与える。

キーワード：特徴抽出、多層パーセプトロン、識別指向的手法、画像認識

## A Comparative Study of Feature Extraction Methods of Pattern Recognition

Naoyuki Ichimura      Tomoyoshi Takeuchi      Yutaka Nagai

Department of Electronics Engineering, The University of Electro-Communications,  
1-5-1, Chofugaoka, Chofu-shi, Tokyo, 182, JAPAN  
Tel:0424-83-2161(Ex.3453)      Fax:0424-80-3801

Abstract: A comparative study of feature extraction methods of pattern recognition is discussed here. We applied nonlinear feature extraction method using Multi-Layered Perceptrons(MLP), and compared its effectiveness with linear method and learning type discrimination oriented one as a front end of image recognition. The following points were confirmed in this experiment. (1)the methods that can utilize category information and nonlinear mapping are superior to the others on recognition rate. (2)the competitive state between categories affects the discrimination oriented MLP outputs.

Key Words : Feature Extraction、Multi-Layered Perceptrons、Discrimination Oriented Method、Image Recognition

# 1 まえがき

一般にパターン認識は、特徴抽出、認識の2段階から構成される。特徴抽出は、与えられたパターンベクトルを、特徴ベクトルへ写像する過程である。以下、パターンベクトルから特徴ベクトルへの写像を特徴抽出写像と呼ぶ。特徴抽出を行うことは、識別率の向上につながるだけでなく、パターンの次元を圧縮するため、識別に必要な計算時間を減少させるものと考えられ、その役割は重要なものと言えよう。

本報告では、著者らが画像認識を目的としていることから、領域分割後の画像の各領域から得られる、色、テクスチャ等についての測定量から構成されるパターンベクトルに対し、多層パーセプトロン（以下、MLP）で実現される、特徴抽出写像を非線形写像に拡張した手法をはじめ、線形手法、学習型識別指向的手法を適用し、比較、検討を行った結果について述べる。

以下、まず2. および3. において特徴抽出法について述べる。次に、4. において、実際の画像から得られたパターンベクトルを用いた特徴抽出および識別の実験について述べる。そして、5. において、その結果についての比較、検討を行う。

## 2 特徴抽出手法

ここでは、K-L 展開<sup>[4][7]</sup>、線形判別写像<sup>[7]</sup>の2つの線形特徴抽出法、および、MLPで実現される恒等写像モデル<sup>[2][3]</sup>、最小2乗非線形判別写像<sup>[7]</sup>の2つの非線形性を利用可能な手法について述べ、学習型識別指向的手法については、3. で述べる。以下における各記号の意味は、次の通りである。

- $C_i$ : カテゴリ ( $i = 1, \dots, m$ )
- $p(C_i)$ : 各カテゴリの先験確率
- $N_i$ :  $i$  番目のカテゴリの学習パターン数
- $\mathbf{x}_j^i$ : パターンベクトル
- $\mathbf{x}_j^i = (x_{j1}^i, \dots, x_{jk}^i, \dots, x_{jn}^i)^T \in R^n$   
 $i = 1, \dots, m, j = 1, \dots, N_j, k = 1, \dots, n$
- $\boldsymbol{\mu}_i$ :  $i$  番目のカテゴリの平均ベクトル
- $\boldsymbol{\mu}_i$ : 全パターンベクトルの平均ベクトル
- $\Sigma_i$ :  $i$  番目のカテゴリの共分散行列 ( $n \times n$ )

$p$ : 特徴空間の次元数

$\Lambda$ : 固有値行列 (ラグランジュ乗数行列)

$$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$$

### 2.1 線形手法

#### 2.1.1 K-L 展開

$\mathbf{x}_j^i$  を正規直交系  $\{\mathbf{u}_i\}$  ( $i = 1, \dots, p$ ) を用いて、特徴ベクトル  $\mathbf{y}_j^i$  へ写像することを考える。

$$\mathbf{y}_j^i = U^T \mathbf{x}_j^i \quad (1)$$

$$U = [\mathbf{u}_1, \dots, \mathbf{u}_p], \mathbf{u}_i \in R^n \quad (2)$$

$\mathbf{x}_j^i$  から  $\boldsymbol{\mu}_i$  を引き、平均を0に正規化したパターンベクトルを  $\mathbf{z}_j^i$  とする。正規直交系  $\{\mathbf{u}_i\}$  の張る部分空間  $L(U)$  への射影ベクトル  $\hat{\mathbf{z}}_j^i$  は、直交射影子  $P_U = UU^T$  を用いて、

$$\hat{\mathbf{z}}_j^i = U \mathbf{y}_j^i = UU^T \mathbf{z}_j^i \quad (3)$$

$$= P_U \mathbf{z}_j^i \quad (4)$$

となる。ここで、次の平均2乗誤差

$$\varepsilon^2(U) = E \left\| \hat{\mathbf{z}}_j^i - \mathbf{z}_j^i \right\|^2 \quad (5)$$

を最小とする正規直交基底  $U$  は、次の固有値問題の固有ベクトルを正規化したものとして得られる。

$$\Sigma_x U = U \Lambda \quad (6)$$

$$\text{ただし、} \Sigma_x = E \left( \mathbf{z}_j^i \mathbf{z}_j^{iT} \right) \quad (7)$$

このとき、平均2乗誤差  $\varepsilon^2(U)$  は、

$$\varepsilon^2(U) = \text{tr} \Sigma_x - \text{tr} \Lambda \quad (8)$$

となることから、 $U$  として、上位  $p$  番目までの大きさを持つ固有値に対応する固有ベクトルを選択すれば、上記の平均2乗誤差を最小にする特徴ベクトルが得られる。

#### 2.1.2 線形判別写像

パターンベクトル  $\mathbf{x}_j^i$  を

$$\mathbf{y}_j^i = A^T \mathbf{x}_j^i \quad (9)$$

$$A = [\mathbf{a}_1, \dots, \mathbf{a}_p], \mathbf{a}_i \in R^n \quad (10)$$

の線形変換によって、特徴ベクトル  $\mathbf{y}_j^i$  へ写像することを考える。2クラスの場合の Fisher の判

別関数の考えに従い、評価基準として次式を用いる。

$$J(A) = \frac{A^T \Sigma_B A}{A^T \Sigma_W A} \quad (11)$$

ここで、 $\Sigma_B, \Sigma_W$  は、それぞれ、 $\mathbf{x}_j^i$  のカテゴリ間共分散行列、カテゴリ内共分散行列であり、次式で与えられる。

$$\Sigma_B = \sum_{i=1}^m p(C_i) (\boldsymbol{\mu}_i - \boldsymbol{\mu}_t) (\boldsymbol{\mu}_i - \boldsymbol{\mu}_t)^T \quad (12)$$

$$\Sigma_W = \sum_{i=1}^m p(C_i) \Sigma_i \quad (13)$$

(11) 式を最大にする  $A$  は、次の一般化固有値問題の固有ベクトルとして得られる。

$$\Sigma_B A = \Sigma_W A \lambda \quad (14)$$

この固有値問題は  $p \leq \min(m-1, n)$  個の固有値を持ち、通常  $n > m$  なので  $m-1$  個の固有値を持つ。上位  $p$  個の固有値に対応する固有ベクトルを用いて、特徴ベクトルを得る。

## 2.2 非線形手法

### 2.2.1 MLP による恒等写像モデル

この方法では、まず、最低一つの隠れ層（圧縮層と呼ぶ）のユニットの数を入力層のユニットの数（測定値ベクトルの次元）より小さくした MLP において、誤差逆伝播学習則（以下、BP）<sup>[1]</sup> により、与えられたパターンベクトルを出力とする恒等写像を形成する。そして、パターンベクトルを入力したときの圧縮層の出力を特徴ベクトルの要素とし、特徴抽出を実現している。

恒等写像を実現する際、層数をいくつにするかが問題となるが、本論文では、3層ニューラルネットワーク（以下、NN）をパターンの特徴抽出および再構成に用い、線形手法より高い識別率を期待できる5層砂時計型 NN に基づく特徴抽出法を検討する。

### 2.2.2 最小2乗非線形判別手法

最小2乗判別基準は、あらかじめ決められた各カテゴリの代表ベクトル  $\mathbf{c}_i$  ( $i = 1, \dots, m$ ) の周りに、各カテゴリに属するパターンベクトル

を集中させた場合の平均2乗誤差を最小にしようとするものである。変分法の慣習に従い<sup>[13]</sup>、判別関数  $\mathbf{y}$  を  $\mathbf{y} = \mathbf{y}(\mathbf{x})$  の形で書くと、平均2乗誤差  $\varepsilon^2[\mathbf{y}]$  は次式のようになる。

$$\varepsilon^2[\mathbf{y}] = \sum_{i=1}^m p(C_i) E \|\mathbf{y} - \mathbf{c}_i\|^2 \quad (15)$$

変分法より、上式を最小とする最適写像関数  $\hat{\mathbf{y}}(\mathbf{x})$  は、次式で与えられる。

$$\begin{aligned} \hat{\mathbf{y}}(\mathbf{x}) &= \sum_{i=1}^m \frac{p(C_i) p(\mathbf{x}|C_i)}{p(\mathbf{x})} \mathbf{c}_i \\ &= \sum_{i=1}^m p(C_i|\mathbf{x}) \mathbf{c}_i \end{aligned} \quad (16)$$

上の写像を最小2乗非線形判別写像と呼ぶ。

この写像において、各カテゴリの代表ベクトルを  $p$  次元単位ベクトルとおくと、 $\hat{\mathbf{y}}$  の要素は、ベイズの事後確率そのものとなり、 $\hat{\mathbf{y}}$  の要素の最大値を選んで  $\mathbf{x}$  のカテゴリを決定することは、理論上最小誤識別率を与えるベイズの決定則と等価である。

大津<sup>[8]</sup>、Asoh ら<sup>[9]</sup> は、教師信号として各カテゴリに対応した単位ベクトルを与え、BP を用いて学習を行った MLP で実現される写像は、最小2乗非線形判別写像を、与えられた構造（3層なら中間層のユニットの数）の制約下で近似していることを明らかにしている。すなわち、この場合には、MLP はベイズの決定則を近似し、ネットワークの出力は事後確率の近似値を与えることになる。このことから、本研究でも、最小2乗非線形判別写像の実現を MLP によって行っている。

## 3 学習型識別指向的手法

ここでは、カテゴリ情報を利用して、識別を明示的に意識した識別指向的手法<sup>[7]</sup> に学習過程を導入し、性能の向上を図った手法について述べる。このような手法を、本論文では学習型識別指向的手法と呼ぶ。これらの手法の特徴は、識別規則を固定し、識別結果を直接特徴抽出写像の構成の際の基準として、その識別規則の下で最大の識別率を得られるように特徴抽出写像を構成する点にある。以下、平均学習部分空間法<sup>[10]</sup> と識別指向型 MLP について述べる。

### 3.1 平均学習部分空間法

部分空間法は、各カテゴリに対し  $m_i$  個 ( $m_i < n$ ) の基底ベクトル  $w_j^i \in R^n$  ( $i = 1, \dots, m$ ,  $j = 1, \dots, m_i$ ) を与え、これらによって張られる部分空間と未知パターンベクトルの近さを調べ、最も近い部分空間に対応するカテゴリに未知パターンベクトルを識別する方法である。この方法では、どのようにして部分空間を張る基底ベクトルを決定するかが最大の問題となるが、その方法の1つとして、Watanabeの提案したK-L展開に基づくCLAFICと呼ばれる方法<sup>[10]</sup>がある。

しかし、CLAFICでは、各カテゴリ独立に特徴抽出を行うため、各カテゴリ間の関係を表現していないという問題がある。この問題を解決する学習に基づく手法として、Kohonenによる学習部分空間法 (Learning Subspace Method: LSM)<sup>[10][11]</sup>、および、LSMをさらに改良したOjaによる平均学習部分空間法 (Averaged Learning Subspace Method: ALSM) が提案されている。ALSMは、条件付相関行列の推定値の修正を行い、修正の結果得られる条件付相関行列の固有ベクトルを新しい部分空間の基底とする方法である。本報告では、ALSMについて実験を行った。

### 3.2 多層パーセプトロンを用いた学習型識別指向的手法

前節で述べたALSMは、K-L展開に基づいているため線形手法の一種である。ここでは、LSMやALSM、LVQ (Learning Vector Quantization)<sup>[11]</sup> などのように、直接識別結果を利用して学習を進めていく方法を非線形写像の利用可能なMLPへも適用することを考える。

実験では、非常に単純に、通常のBPによって学習を行う際に、入力される学習パターンが正しく識別された場合には、学習 (誤差の逆伝搬) を行わず、誤って識別された場合のみ通常の学習を行うという形でこの方法を実現した。

教師信号としては、各カテゴリに対応する単位ベクトルを与えておき、上記のような学習を行うと、学習後のMLPの出力が、学習パターンを入力しても教師信号に近い値をとらず区間  $[0,1]$

の値、例えば、(0.3,0.1,0.6) のような値を出力するようになると考えられる。このことは、各カテゴリの教師信号 (最小2乗非線形判別手法における代表ベクトルに対応) を各学習パターン毎に変化させ、さらに、その各要素を  $[0,1]$  の値で与えることに対応する。教師信号を  $[0,1]$  の値で与える方法は、小森ら<sup>[12]</sup> によって提案され、音声認識で教師信号を単位ベクトルで与える場合よりも高い認識率が得られることが確認されている。この方法では、主として、MLPの出力で未知入力パターンの各カテゴリとの近さを表現することを目的としているため、教師信号を、パターンベクトル間の距離から得られる類似度である  $[0,1]$  の値で与えている。

また、通常の学習は、2乗誤差を評価基準として行われるが、Ojaも指摘しているように<sup>[10]</sup>、2乗誤差を基準とすると、本来識別率の向上において注目しなければならない、誤識別を起しやすい、カテゴリの中の非典型的のパターンに対して、誤差が大きくなってしまふ場合がある。上記のように誤識別率を基準として学習を行うと、誤識別を起すパターンに対して学習が集中して行われることになる。以下、便宜上この方法を識別指向型MLPと呼ぶ。

## 4 画像パターンの特徴抽出実験

野外の自然シーンを撮像したカラー画像を認識対象として選び、2. および3. で述べた特徴抽出方法を適用した。

### 4.1 パターンベクトルの構成

入力されたカラー画像に領域分割を施し、各領域について、次の量を計算した。まず、色、輝度について、領域を構成する各画素の値 ( $R, G, B$ ) から、 $r/b, r/g, \theta, s, I, Q, Y, Y/Y_a$  を求める。ここで、 $T=R+B+G$  として、 $r = R/T$ ,  $g = G/T$ ,  $b = B/T$  であり、 $\theta, s$  はそれぞれ、色相と彩度である。また、 $Y, I$  および  $Q$  は  $R, G, B$  からの線形変換によって得られる量である。 $Y_a$  は、画像全体についての  $Y$  の平均である。

テクスチャについては、同時生起行列  $P_\delta(i, j)$  ( $\delta$ : 注目画素からの方向、 $i$ : 注目画素の輝度、

$j$ :  $\delta$  の位置の画素の輝度) を利用し、テクスチャの一様性、コントラストおよび方向性を表す量を求めた<sup>[5]</sup>。実験では、 $\delta$  は (1,0),(0,1),(1,1) および (1,-1) の 4 方向を用いた。また、位置についての特徴量として、領域の重心の垂直方向の座標を用いた。

以上で述べた量の各領域での平均値を用いて、12次元のパターンベクトルを構成した。認識対象のカテゴリは {道路、木、芝生、空} の 4 つを選んだ。測定値ベクトルは、計 41 枚の画像から抽出し、全カテゴリ合わせて学習用に 654 個、評価用に 657 個用意した。

## 4.2 実験方法

前述の特徴抽出法を用いて 12 次元のパターンベクトルを、2、3 および 4 (最小 2 乗非線形判別写像および識別指向型 MLP については 4 のみ) の各次元の特徴ベクトルに写像した結果について述べる。

### 4.2.1 K-L 展開

実験では、(13) 式に示すカテゴリ内共分散行列を用いた。この場合は、

$$\varepsilon^2(U) = \sum_{i=1}^m p(C_i) E \left\| \hat{z}_j^i - z_j^i \right\|^2 \quad (17)$$

が最小化される。

### 4.2.2 線形判別手法

(14) 式の一般固有値問題を解き、固有ベクトルを得て、特徴ベクトルを求めた。この方法では、理論上特徴空間の次元は最大 3 になる。

### 4.2.3 5 層砂時計型ニューラルネットワーク

MLP の構造は、12-8-p-8-12(p=2,3,4) とし、ユニットの出力関数は第 2 層および第 4 層はシグモイド関数、他は線形関数とした。また、学習には BP を使い、パターンの提示法は逐次提示法<sup>[2]</sup>を用いた。

### 4.2.4 最小 2 乗非線形判別写像

MLP の構造は、12-x-4(x=2,3,4) とし、ユニットの出力関数は、第 2、3 層ともシグモイド関

数とした。教師信号は、カテゴリに対応した 4 次元の単位ベクトルとした。学習には BP を使い、 $6 \times 10^4$  epoch で打ち切った。

### 4.2.5 学習型識別指向的手法

MLP を用いた方法では、MLP の構造を最小 2 乗非線形判別写像の場合と同一にした。教師信号は、カテゴリに対応した 4 次元の単位ベクトルとした。学習は、3.2 で述べた方法で行い、 $6 \times 10^4$  epoch で打ち切った。

## 5 実験結果とその考察

### 5.1 識別率

K-L 展開、線形判別写像および 5 層砂時計型 NN の各方法で得られた特徴ベクトルを、条件付き確率密度関数として正規分布を仮定したベイズの方法 (Bayes) と LVQ で識別した。最小 2 乗非線形判別写像および学習型識別指向型 MLP は出力の最大値を選択することによって識別結果を得た。また、ALSM では、各部分空間への射影成分の最大値を選択することによって識別を行った。LVQ において、各カテゴリの参照ベクトルの数は 50 個とし、また、参照ベクトルの初期位置の設定には、LBG アルゴリズム<sup>[6]</sup>を用いた。各特徴抽出法における識別率を表 1 に示す。また、特徴抽出を行わない場合の同一の方法による識別率も表 1 にまとめておく。

### 5.2 識別率に対する考察

識別結果について、次のような 4 つの観点から考察を行う。

#### 5.2.1 unsupervised vs. supervised

この場合は、K-L 展開と線形判別写像および 5 層砂時計型 NN と最小 2 乗非線形判別写像の組合せの比較となる。前者の比較では、supervised な手法、すなわち、線形判別写像の方が高い識別率を与える。後者では、5 層砂時計型 NN は LVQ において比較的高い識別率を示すが、最小 2 乗非線形判別写像は学習および評価データの両方に対し、それを上回る識別率を示す。

### 5.2.2 識別指向 vs. 非識別指向

この場合は、ALSM と線形判別写像および識別指向型 MLP と最小 2 乗非線形写像の組合せの比較となる。前者の比較では、ALSM は特徴空間が 2 次元のとき評価パターンに対し、線形判別写像を上回る識別率を示す。しかし、特徴空間の次元数の変化に対する識別率の安定性に欠ける点が見受けられ、特徴空間の次元数の選択には注意を払う必要がある。後者の比較では、中間層のユニットの数が 4 のときに識別指向型 MLP が評価データに対し、高い識別率を示す。この両者の比較については、5.3 でより詳しく述べる。

### 5.2.3 線形 vs. 非線形

この場合は、K-L 展開と 5 層砂時計型 MLP、線形判別写像と最小 2 乗非線形判別写像および ALSM と識別指向型 MLP の組合せの比較となる。最初の比較では、非線形を導入することによる識別率の向上が見られる。2 番目の比較では、線形判別写像は特徴空間が 3 次元のとき、かつ、ベイズの方法によって認識した場合に、評価データに対し高い識別率を示すが、学習および評価データの両方に対して高い識別率を示すのは非線形性を導入した方法である。最後の比較では、ALSM では特徴空間が 2 次元のときに、また、識別指向型 MLP では中間層のユニットの数が 4 のときに高い識別率を示す。しかし、この場合でも、学習および評価データの両方に対して高い識別率を示すのは非線形性を導入した方法である。

### 5.2.4 特徴抽出あり vs. 特徴抽出なし

この比較については、特徴抽出を行っているほとんどの手法で、評価データに対して、特徴抽出を行わない場合の識別率より約 1 から 2 % 高い識別率を示していることから特徴抽出を行った方が有利であると言える。

## 5.3 識別指向型 MLP について

ここでは、識別指向型 MLP と最小 2 乗非線形判別写像の比較を行う。この 2 つの手法は、同

一の構造の MLP を用いて実現された。

### 5.3.1 識別率

識別率を比較すると、中間層のユニットの数が少ない時には、最小 2 乗非線形判別写像の方が高い値を示すが、中間層のユニットの数が 4 つになると、ほぼ同等の識別率を示す。中間層のユニットの数が 4 つの場合の学習終了時の総 2 乗誤差は、識別指向型 MLP で 48.9、最小 2 乗非線形判別写像で 2.5 と、誤差の点からみると前者の方がはるかに大きい。しかし、識別率については、ほぼ同等であり、評価データに対しては良い結果を与えている。このことは、2 乗誤差を基準とせず、直接識別結果に従って学習を行っても、識別という点からは、問題はないことを示している。

### 5.3.2 出力値

識別指向型 MLP の出力値が、どのような意味を持つかを調べるために、4 つのカテゴリの内 1 つのカテゴリの平均ベクトルを選び、その平均ベクトルと入力されたパターンとの間のユークリッド距離と選ばれたカテゴリに対応する出力ユニットの出力値の関係を調べた。その結果を図 1 に示す。図 1 より、識別指向型 MLP の出力値とユークリッド距離とは相関を持つことがわかる。また、どのカテゴリの平均ベクトルを選ぶかによって、出力値のばらつきに差がみられる。

各カテゴリ間の関係を考察するために、図 2 に示す 5 層砂時計型 NN によって得られる 2 次元の特徴ベクトルの散布図を用いる。この図から、{道路、木}、{木、道路、芝生}、{芝生、木}、{空、NULL} の組合せで、カテゴリ間に重なりがあることがわかる。ただし、NULL は重なりを持つカテゴリが存在しないことを意味する。

以上の各カテゴリの関係と、図 1 に示す識別指向型 MLP の出力値の分布から、多くのカテゴリと重なりを持つカテゴリの平均ベクトルを選択すると、 $[0,1]$  の中間的な値をとるパターンが多く現れることがわかる。例えば、複数のカテゴリと明らかに重なりを持つ木のカテゴリの出力

値は  $[0,1]$  の範囲で大きなばらつきを持つが、他のカテゴリとほとんど重なりを持たない空のカテゴリは、出力値が  $[0,1]$  の中間的値をとらず、ほとんど 1 か 0 の値をとっている。芝生のカテゴリの出力値にみられるように、カテゴリの平均ベクトルから大きくはなれているパターンに対しては、距離が離れていても大きな出力値が出されている。しかし、カテゴリの識別はできるような差は存在する。このことから、識別指向型 MLP は、カテゴリ間に競合関係が存在し、どちらのカテゴリともつかないような位置にあるパターンに対しては、 $[0,1]$  の値を出力する。

以上のことから、識別指向型 MLP は、外部から教師として与えなくてもカテゴリ間の競合関係を、その出力値として表現することができると考えられる。そのような情報を識別後の処理に利用したい場合には、学習パターンを単位ベクトルとして与え、通常の学習を行う場合に比べて適していると言える。

## 6 結論

以上の考察から次のことが言える。

(1) unsupervised な方法よりも、supervised な方法が安定した識別結果を与える。

(2) 学習型識別指向的手法は、識別指向的でない手法と同等の識別率を与えるが、特徴空間の次元数に対する識別率の安定性が低く、特徴空間の次元の選択の際に不利になる。識別指向型 MLP では、中間層のユニットの数に対する識別率の安定性が低い。

(3) unsupervised な方法では、非線形性の導入により識別率が向上する。supervised な方法でも、非線形性を導入すると若干の識別率の向上が見られると共に、学習および評価データの両方に対し安定した識別結果を与える。

(4) 特徴抽出を行うことは、識別率を向上させる。

(5) 識別指向的 MLP は、通常の MLP と同等以上の識別率し、その出力値は、外部から教師として与えることなしに、カテゴリ間の競合状態を反映した  $[0,1]$  の値となる。

今後の課題としては、特徴抽出手法と識別手法の関連の解析、特に学習型識別指向的手法につ

いての解析が挙げられる。

## 参考文献

- [1] Rumelhart D.E., Hilton G.E. and Williams R.J.: "Learning representations by back-propagating errors", Nature, Vol.323, No.9, pp.533-536 (1986)
- [2] 中内茂樹、中野正恵、白井支朗: "5層砂時計型ニューラルネットワークによるマンセル色票分光反射率に対する内部表現の獲得"、信学論 (D-II), Vol.J75-D-II, No.2, pp.402-419 (1992-02)
- [3] 入江文平、川人光男: "多層パーセプトロンによる内部表現の獲得"、信学論 (D-II), Vol.J73-D-II, No.8, pp.1173-1178 (1990-08)
- [4] Tou J.T., Gonzalez R.C.: "Pattern Recognition Principles", Addison-Wesley Publishing Company (1974)
- [5] 富田文明、田村秀行: "画像処理アルゴリズムの概観 (4) - テクスタチャー解析 -", 電子技術総合研究所彙報、第4巻、第7、8号 (1980)
- [6] Linde Y., Buzo A. and Gray R.M.: "An Algorithm for Vector Quantizer Design", IEEE, Trans. on Communications, COM-28, Vol.1, pp.84-95 (1980)
- [7] 大津展之: "パターン認識における特徴抽出に関する数理的研究"、電子技術総合研究所研究報告、第818号 (1981)
- [8] 大津展之: "認識と理解のための柔らかな理論"、信学誌、Vol.71, No.11, pp.1231-1240 (1988)
- [9] Asoh H. and Otsu N.: "Nonlinear Data Analysis and Multilayer Perceptron", JICNN-89, 2, pp.411-415 (1989)
- [10] エルッキ オヤ (小川、佐藤訳): "パターン認識と部分空間法"、産業図書 (1986)
- [11] Kohonen T.: "Self-Organization and Associative Memory", Third Ed., Springer-Verlag (1989)
- [12] 小森康弘、アレキサンダー・ワイベル、嵯峨山茂樹: "ニューラルファジィ学習法による音声認識の性能向上"、信学論 (D-II), Vol.J75-D-II, No.7, pp.1101-1110 (1992-07)
- [13] 寺沢寛一: "自然科学者のための数学概論"、岩波書店 (1961)

表1 識別率 (%)

(1) K-L展開

次元	Bayes		LVQ	
	学習	評価	学習	評価
2	89.3	85.4	95.1	84.5
3	93.0	91.0	97.6	90.7
4	95.6	93.3	98.3	93.8

(2) 線形判別画像

次元	Bayes		LVQ	
	学習	評価	学習	評価
2	91.1	90.9	94.3	86.6
3	96.6	97.0	98.3	96.3

(3) 5層砂時計型ニューラルネットワーク

次元	Bayes		LVQ	
	学習	評価	学習	評価
2	93.1	92.2	95.7	89.8
3	94.3	91.6	97.6	89.5
4	96.9	96.5	98.5	96.2

(4) 最小2乗非線形判別画像

ユニット	学習	評価
2	94.5	95.0
3	99.5	96.3
4	99.5	96.8

(5) 平均学習部分空間法

次元	学習	評価
2	97.1	96.7
3	91.3	88.4
4	96.2	94.8

(6) 識別指向型MLP

ユニット	学習	評価
2	58.4	57.8
3	97.2	94.2
4	99.4	97.3

(7) 特徴抽出を行わない場合

Bayes		LVQ	
学習	評価	学習	評価
97.3	95.1	99.1	95.0




図1 各カテゴリの平均ベクトルと学習パターンとのユークリッド距離と各カテゴリに対応する出力ユニットの出力値の関係 (左から、それぞれ、道路、木、芝生、空のカテゴリの平均ベクトルを用いた場合)




図2 5層砂時計型ニューラルネットワークによって得られた2次元の特徴ベクトルの散布図