

# 新しいネオコグニトロン型ネットワークとICA・PCAを用いた学習法

下村 正夫<sup>†a)</sup>      佐藤 俊治<sup>††b)</sup>      三宅 章吾<sup>†††c)</sup>      阿曾 弘具<sup>†d)</sup>

New Neocognitron-Type Network and Its Learning Method Based on  
ICA and PCA

Masao SHIMOMURA<sup>†a)</sup>, Shunji SATOH<sup>††b)</sup>, Syogo MIYAKE<sup>†††c)</sup>,  
and Hirotomo ASO<sup>†d)</sup>

あらまし ネオコグニトロンは、高い認識率と拡張性をもつパターン認識用の階層型ニューラルネットワークであるが、その性能を引き出すためには多数存在するパラメータを認識対象に応じて適切に調整する必要があった。そこで本論文では、ネオコグニトロンの各階層で行われている処理が次元圧縮である点に着目し、統計的な次元圧縮法である主成分分析 (PCA)、独立成分分析 (ICA) 及び部分空間法をネットワークの学習法として導入することで、パラメータ数の削減とパラメータ変動への頑健性向上を図る。また、これらの手法を導入するためにネオコグニトロンを簡略化したネットワークを提案する。手書き数字及び顔画像データベースを用いた認識実験により、提案する学習法がパラメータの変動に頑健で、かつ認識対象によらず同じパラメータで適切な学習が行えることを検証した。

キーワード ネオコグニトロン, 階層型ニューラルネットワーク, パターン認識, ICA, PCA

## 1. ま え が き

Hubel と Wiesel による階層仮説 [1] に基づいた視覚神経系のニューラルネットワークモデルとして、ネオコグニトロン [2] が Fukushima によって提唱された。ネオコグニトロンは、入力画像中の局所的情報を階層的に統合していくことで高い認識率を達成し、その後多くの研究 [3] ~ [5] の基礎として使われている。

ネオコグニトロンは、S 層と C 層が交互に階層的に配置されたネットワークであり、S 層では画像中の局所的領域内での特徴抽出を、C 層では S 層で検出された特徴の空間的な統合処理を、それぞれ行っている。

このような階層的な情報処理機構を継承した視覚神経系のニューラルネットワークモデルは多数提案されている。例えば Wallis と Rolls が提案した、S 層と C 層の明確な区別をなくした VisNet [6] や、Riesenhuber と Poggio が主に C 層での情報処理機構を改良して提案した Max-operation モデル [7]、実環境下での三次元物体認識を実現した Wersing と Körner のモデル [8] などがある。

しかしながら、これらのモデルには認識率を左右するパラメータが数多く存在し、その調整は専ら作成者の経験に頼る方法が主流であった。この発見的なパラメータ設定方法では特に、異なる認識対象に対して新たに適切なパラメータを設定することが困難であり、実用上大きな問題となっていた。更に、いずれのモデルにおいても、ネットワークの各階層間での伝搬式における非線形性が高い性能の獲得に寄与していたものと考えられるが、そのために、ネットワーク内部でどのような処理が行われているのかという解析は困難であった。

そこで本研究では、ネオコグニトロンの各 S 層で行われている特徴抽出処理が、基本的には高次元の入力データを低次元空間に射影するという処理であることに着目し、統計的な次元圧縮手法である独立成分分

<sup>†</sup> 東北大学大学院工学研究科電気・通信工学専攻, 仙台市  
Department of Electrical and Communication Engineering,  
Graduate School of Engineering, Tohoku University, Sendai-shi,  
980-8579 Japan

<sup>††</sup> 東北福祉大学情報福祉学科, 仙台市  
Department of Information Science for Human Welfare,  
Tohoku Fukushi University, Sendai-shi, 980-8579 Japan

<sup>†††</sup> 東北大学大学院工学研究科応用物理学専攻, 仙台市  
Department of Applied Physics, Graduate School of Engineering,  
Tohoku University, Sendai-shi, 980-8579 Japan

a) E-mail: masao@aso.ecei.tohoku.ac.jp

b) E-mail: shunji@m.ieice.org

c) E-mail: miyake@nlap.apph.tohoku.ac.jp

d) E-mail: aso@aso.ecei.tohoku.ac.jp

析 (ICA), 主成分分析 (PCA) 及び部分空間法をネオコグニトロン型ネットワークの学習方法として導入する. これにより, モデル中のパラメータ数の大幅な削減を図ると同時に, モデル内における信号処理過程の理論的な解析が容易になると期待される. また本論文では, これらの統計的手法を導入するために, ネオコグニトロンの局所的・階層的な情報処理機構を継承しつつ信号伝搬式を線形化した, 新しいネオコグニトロン型ネットワークを提案する.

本論文の構成は以下のとおりである. まず, 2. で, ネオコグニトロンの伝搬式を線形化した, より単純な階層型ニューラルネットワークを導入し, ネオコグニトロンの特徴抽出原理と比較する. 3. で, ICA 及び PCA を用いた教師なし学習法を提案し, 4. では最終層における部分空間法を用いた教師あり学習を説明する. 5. では, 手書き数字及び顔画像データベースを用いた認識実験を行い, 提案する学習法がデータベースの種類によらずパラメータの調整なしで高い認識率を保つことを実証する. また, 学習時における次元圧縮法の組合せ方の違いにより認識率が変化する理由について考察する. 6. はまとめである.

## 2. ネオコグニトロン型ネットワーク

本論文で提案するモデルは, ネオコグニトロン [2] と同様に, S 層と C 層が交互に階層的に配置されたネットワークである (図 1).  $l$  段目の S 層を  $U_{Sl}$ , C 層を  $U_{Cl}$  と記す.  $l$  段目の各層は,  $K_l$  個の細胞面をもつ. 細胞面は, 細胞が平面上に配置されたもので, 個々の細胞面は空間的位置情報を保ちつつ異なる特徴を抽出する機能をもつ.

$U_{Sl}$  層には, 特徴抽出を行う S 細胞が配置されてお

り, S 細胞は, 前段の  $U_{Cl-1}$  層内の C 細胞と, 重みベクトルを介して結合している. この重みベクトルを適切に計算 (学習) することで, 様々な特徴の抽出が可能となる. 以後, この重みベクトルを特徴ベクトルと呼ぶ. 学習によって獲得した特徴ベクトルのパターンと, 前段である  $U_{Cl-1}$  層の発火パターンの類似度が高い場合,  $U_{Sl}$  層の S 細胞は強く発火する.  $U_{Cl}$  層に含まれる各 C 細胞の発火パターンは,  $U_{Sl}$  層の発火パターンを空間的に統合 (縮小) したものである.

以下,  $U_{Sl}$  層の S 細胞の出力を  $u_{Sl}(n, k)$ ,  $U_{Cl}$  層の C 細胞の出力を  $u_{Cl}(n, \kappa)$  と記す. ただし, 位置ベクトル  $n = (n_x, n_y)$  は細胞面中の細胞位置を表し,  $k$  及び  $\kappa$  は細胞面を区別する番号である. また,  $U_{Sl}$  層及び  $U_{Cl}$  層内の  $K_l$  個の各細胞面に含まれる細胞数は  $N_{Sl} \times N_{Sl}$  個及び  $N_{Cl} \times N_{Cl}$  個とする. なお, 本論文では 3 段構成 ( $l = 1, 2, 3$ ) のネットワークを扱うこととし, 入力層  $U_0$  を  $U_0 = U_{C0}$  層として扱う. すなわち,  $K_0 = 1$  となる.

### 2.1 $U_{Sl}$ 層における特徴抽出

$U_{Sl}$  層中の S 細胞  $U_{Sl}(n, k)$  は, 結合重み  $a_l(\nu, \kappa, k)$  を介して結合範囲  $A_l$  内の前段の C 細胞  $U_{Cl-1}(n + \nu, \kappa)$  ( $\nu \in A_l$ ) と結合している. ここで, 結合範囲  $A_l$  は  $A_l \times A_l$  の領域とする.

S 細胞  $U_{Sl}(n, k)$  の出力を式 (1) で与える.

$$u_{Sl}(n, k) = \left| \sum_{\kappa=1}^{K_{l-1}} \sum_{\nu \in A_l} \frac{a_l(\nu, \kappa, k)}{\|a_l(k)\|} \cdot \frac{u_{Cl-1}(n + \nu, \kappa)}{\|u_{Cl-1}(n)\|} \right|, \quad (1)$$

$$\|a_l(k)\| = \sqrt{\sum_{\kappa=1}^{K_{l-1}} \sum_{\nu \in A_l} a_l(\nu, \kappa, k)^2}, \quad (2)$$

$$\|u_{Cl-1}(n)\| = \sqrt{\sum_{\kappa=1}^{K_{l-1}} \sum_{\nu \in A_l} u_{Cl-1}(n + \nu, \kappa)^2}. \quad (3)$$

式 (1) はベクトルの内積とみなせる. すなわち, 結合重み  $a_l(\nu, \kappa, k)$  を要素としてもつベクトルを  $a_l(k)$ , 前段の出力値  $u_{Cl-1}(n + \nu, \kappa)$  を要素としてもつベクトルを  $i_l(n)$  と定義すると, 式 (1) は次式の内積表現で表すことができる.

$$u_{Sl}(n, k) = \frac{(a_l(k), i_l(n))}{\|a_l(k)\| \cdot \|i_l(n)\|}. \quad (4)$$




図 1 提案ネットワークの概要  
Fig. 1 An overview of the proposed network.

以後、 $a_l(k)$  を特徴ベクトル、 $i_l(n)$  を入力ベクトルと呼ぶ。 $\nu \in A_l$  であり、 $\kappa = 1, 2, \dots, K_{l-1}$  であるので、各ベクトルの次元は  $D_l = A_l^2 K_{l-1}$  である。式 (4) は、 $U_{Sl}$  層における S 細胞の出力を与えるが、これは、入力ベクトル  $i_l(n)$  を、 $K_l$  個の特徴ベクトル  $a_l(k)$  で張られる  $K_l$  次元の部分空間へ射影した結果に対応することを意味している。

特徴ベクトル  $a_l(k)$  は、3. で述べる学習法により、適切な部分空間を形成するように決定する。

## 2.2 $U_{Cl}$ における情報統合

前述のように、 $U_{Cl}$  の各細胞面の発火パターンは  $U_{Sl}$  の対応する細胞面の発火パターンを空間的に縮小した発火パターンとする。本モデルでは計算の単純化のため結合を用いた表現を使わずに、画像縮小アルゴリズムである縮小元領域内平均値法 [9] を用いて、 $U_{Cl}$  層の各細胞について出力値の計算を行った。

## 2.3 ネオコグニトロンでの特徴抽出との比較

Fukushima による、ネオコグニトロンの S 層における動作解析 [10] を 2.1 での表記法で記述すると、S 細胞の出力  $u_{Sl}(n, k)$  は次式で与えられる。

$$u_{Sl}(n, k) = (1 + r_l) \varphi \left[ \frac{(a_l(k), i_l(n))}{\|a_l(k)\| \cdot \|i_l(n)\|} - \frac{r_l}{1 + r_l} \right]. \quad (5)$$

ただし、関数  $\varphi[\ ]$  は

$$\varphi[x] = \begin{cases} x & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (6)$$

で定義される非線形関数である。 $r_l$  はしきい値と呼ばれる、S 細胞の発火頻度を制御するパラメータである。これらのことから、式 (4) は、式 (5) においてしきい値  $r_l = 0$  とした特殊な場合に対応する。

一般に、学習終了後のネオコグニトロンでは、(入力ベクトルの次元数  $D_l$ ) > (細胞面数  $K_l$ ) となることが実験的に示されている [11]。よって、特徴ベクトルの各要素である結合重み、すなわち部分空間の基底の要素  $a_l(\nu, \kappa, k)$  は、学習に用いたパターンベクトル空間が最もよく近似される低次元部分空間を構成するように学習すればよい。その一つの方法が、シードセル生成面を用いた学習法 [12] であった。

## 3. 特徴ベクトルの学習法

本論文では、適切な低次元部分空間を構成する手法

として、次の二つの統計的な次元圧縮手法を考える。

- 独立成分分析 (ICA)
  - 基底間の相互情報量が最小な部分空間を構成
- 主成分分析 (PCA)
  - 分散最大基準に基づいて部分空間を構成

学習は 1 段目から順に行い、1 段目の学習が終了した後に 2 段目の学習を開始する。今、 $l$  段目において学習用パターン  $\mu$  を提示したときの入力ベクトルを列ベクトルとしてもつ  $D_l \times N_{Sl}^2$  サンプル行列  $X_l^{(\mu)}$  を導入する。

$$X_l^{(\mu)} = \left[ \frac{i_l(0)}{\|i_l(0)\|}, \dots, \frac{i_l(n)}{\|i_l(n)\|}, \dots \right]. \quad (7)$$

列の数は  $U_{Sl}$  層中の細胞面内の細胞数に一致し、 $N_{Sl}^2$  である。

更に、すべての学習用パターンに対するサンプル行列  $X_l$  を次式で与える。全学習パターン数を  $n$  とすると、

$$X_l = \left[ X_l^{(1)}, \dots, X_l^{(n)} \right]. \quad (8)$$

すなわち、 $X_l$  は  $D_l \times nN_{Sl}^2$  行列である。

### 3.1 PCA を用いた学習

PCA を用いた学習では、まずサンプル行列  $X_l$  の共分散行列  $\Sigma_l$  を次式に従い算出する。

$$\Sigma_l = \frac{1}{N} \sum_{i=1}^N (x_{l,i} - \widetilde{m}_l)(x_{l,i} - \widetilde{m}_l)^T, \quad (9)$$

ただし、 $N = nN_{Sl}^2$  であり、ベクトル  $x_{l,i}$  は行列  $X_l$  の  $i$  番目の列ベクトルを表す。 $\widetilde{m}_l$  は次式で計算される平均ベクトルである。

$$\widetilde{m}_l = \frac{1}{N} \sum_i x_{l,i}. \quad (10)$$

次に、 $D_l \times D_l$  行列である  $\Sigma_l$  を固有値展開することで、固有値  $\lambda_{l,k}$  ( $\lambda_{l,k} > \lambda_{l,k-1}$ ) 及び固有ベクトル  $e_{l,k}$  を求め、そのうち固有値の大きいもの  $K_l$  個を特徴ベクトルとして採用する。すなわち、

$$a_l(k) = e_{l,k} \quad (k = 1, 2, \dots, K_l), \quad (11)$$

とする。式 (11) で得る  $a_l(k)$  が、PCA を用いた学習によって得られる特徴ベクトルとなる。

### 3.2 ICA を用いた学習

ICA を用いた学習では、まずサンプル行列  $X_l$  に対して  $D_l \times D_l$  白色化行列  $W_{pl}$  を作用させ、次式で

白色化を行う．

$$\tilde{x}_{l,i} = W_{pl}(x_{l,i} - \tilde{m}_l), \quad (12)$$

ただし，白色化行列  $W_{pl}$  は

$$W_{pl} = E_l D_l^{-\frac{1}{2}} E_l^T, \quad (13)$$

で与えられる． $E_l$ ， $D_l$  はそれぞれ  $\Sigma_l$  の固有ベクトル行列及び固有値行列である．

続いて，白色化された  $\tilde{x}_{l,i}$  から得られるサンプル行列  $\tilde{X}_l$  が，次式に従い統計的に独立な信号源  $S_l$  とその混合行列  $C_l$  から生成されると仮定する．

$$\tilde{X}_l = C_l S_l, \quad (14)$$

$S_l$  は  $K_l \times nN_{Sl}^2$  行列であり， $C_l$  は  $D_l \times K_l$  行列である．このとき，サンプル行列  $\tilde{X}_l$  から信号源  $S_l$  を推定するために，混合行列の一般化逆行列  $W_l = C_l^{-1}$  を FastICA アルゴリズム [13] を用いて推定する．FastICA アルゴリズムを採用した理由は，圧縮次元数（この場合  $K_l$ ）を任意に指定でき，かつ計算が比較的高速なためである．FastICA アルゴリズムで推定された  $W_l$  と白色化行列  $W_{pl}$  の積が，ICA で求められる特徴ベクトルとなる．すなわち，

$$a_l(k) = w_{l,k}^T \quad (k = 1, 2, \dots, K_l), \quad (15)$$

ただし  $w_{l,k}$  は行列積  $W_l W_{pl}$  の第  $k$  行ベクトルである．

この  $a_l(k)$  による式 (4) の値は， $i_l(n)$  の独立成分を与える．

#### 4. $U_3$ 層におけるパターン判別法

最終段である  $U_3$  層では，パターンを判別するための教師付き学習の手法として部分空間法 [14] を適用する．

$U_{S3}$  層には入力パターンのカテゴリー数に対応した  $J$  個の層を設ける（図 1 を参照のこと）． $j$  番目の層を  $U_{S3}^j$  と記す． $U_{S3}^j$  層には細胞面として  $K_3^j$  個の細胞を一次元的に配置し， $k$  番目の細胞の出力値を  $u_{S3}^j(k)$  とする．

3. での学習と同様に， $U_{S3}^j$  における特徴ベクトル  $\alpha_3^j(k)$  をサンプル行列  $X_3^j$  ( $U_{C2}$  層の出力) を用いて計算する．ただし， $X_3^j$  はカテゴリー  $j$  に属する学習用パターンのみから構成されるサンプル行列である．まず， $X_3^j$  の自己相関行列  $P_3^j$  を次式に従い計算

する．

$$P_3^j = \sum_i x_{3,i}^j x_{3,i}^{jT}, \quad (16)$$

$P_3^j$  を固有値展開することにより得られた固有ベクトル  $e_{3,k}^j$  が，カテゴリー  $j$  を区別するための特徴ベクトル  $\alpha_3^j(k)$  に対応する．すなわち，

$$\alpha_3^j(k) = e_{3,k}^j \quad (k = 1, 2, \dots, K_3^j). \quad (17)$$

出力層である  $U_{C3}$  には  $J$  個の細胞が配置され， $U_{C3}$  層の  $j$  番目の細胞  $U_{C3}(j)$  と  $U_{S3}^j$  層の細胞とは全結合をもつ．細胞  $U_{C3}(j)$  の出力を次式で与える．

$$\begin{aligned} u_{C3}(j) &= \sum_{k=1}^{K_3^j} u_{S3}^j(k) \\ &= \sum_{k=1}^{K_3^j} \sum_{\kappa=1}^{K_2} \sum_{\nu \in A_3} [a_3^j(\nu, \kappa, k) \cdot u_{C2}(\nu, \kappa)]^2. \end{aligned} \quad (18)$$

最終的な認識結果はカテゴリー  $\hat{j} = \operatorname{argmax}_j u_{C3}(j)$  とする．

#### 5. 実 験

ETL1 手書き数字データベース [15] 及び HOIP 顔画像データベース [16] を用いて本モデルの有効性を確認する．モデルの構造は両実験で共通のものとし，パラメータを表 1 に記す．なお，ETL1 データベースの学習画像を PCA を用いて固有値の累積寄与率が 95% になるまで次元圧縮したところ 233 次元だったのに対して，HOIP データベースの学習画像では 55 次元であった．すなわち特徴数を基準とする定量評価により，本章で用いる二つのデータは異なる性質をもつことが分かる．実験では，1, 2 段目において PCA 学習及び ICA 学習の組合せを変え，計 4 通りの手法で認識率を比較する．

また他手法との比較のため，最新のネオコグニトロノ [11] 及び部分空間法 [14] による認識率も求めた．

提案する学習法においては，パラメータである細胞

表 1 ネットワークにおける構造決定パラメータ  
Table 1 Structural parameters of the network.

	$U_0$	$U_{S1}$	$U_{C1}$	$U_{S2}$	$U_{C2}$	$U_{S3}$	$U_{C3}$
$N_l$	33	27	17	13	5	1	1
$A_l$	-	7	-	7	-	5	-

面数  $K_1, K_2$  をいろいろ変化させて実験し、最も認識率が高くなる値を決定した。最終段の部分空間法による学習及び部分空間法単独で用いた場合における圧縮後の次元数は、固有値の累積寄与率が 98% を超える次元数に設定した。ネオコグニトロンにおけるパラメータは論文 [11] 中のものを使用した。

### 5.1 ETL1 手書き数字データベースでの実験

実験に使用したデータは、最新のネオコグニトロンによる認識実験 [11] で用いられたものと同一サンプルの手書き数字データセットとし、学習用に 300 セット（計 3000 文字）、認識用に学習用とは異なる 300 セット（計 3000 文字）を使用した。各サンプルは、文字の大きさの正規化や細線化処理を一切行っていないグレースケール画像であり、サイズは各文字  $64 \times 63$  [pixel] である。提案モデルへの入力時には各文字を  $33 \times 33$  [pixel] に縮小して入力した。図 2 にサンプルの一例を示す。

各手法による認識結果及びそのときの細胞面数  $K_1, K_2$  を表 2 に示す。表 2 から、提案手法では初段に ICA、中間段に PCA を用いる方法が最適であることが分かる。認識率では最新のネオコグニトロン [11] に若干劣っているが、このネオコグニトロンでは文字認識に特に有効とされている、画像中の端点の情報を明示的に検出させる等の工夫を加えて認識率を高めている。これらの工夫を本モデルに施すことは可能であり、そうすることで認識率の向上が期待される。




図 2 ETL1 手書き数字データベースの画像例  
Fig. 2 Examples of digit images in ETL1 database.

表 2 ETL1 データベースにおける認識率とそのときのパラメータ

Table 2 Recognition rates and parameters for ETL1 database.

手法 ( $U_{S1} - U_{S2}$ )	$K_1$	$K_2$	認識率 (%)
ICA - PCA	9	121	96.0
PCA - PCA	9	121	91.6
ICA - ICA	9	64	85.3
PCA - ICA	49	64	82.0
ネオコグニトロン	-	-	98.6
部分空間法	-	-	82.2

なお、表 2 中の ICA-PCA 学習に要した時間は、実験に使用したワークステーション（プロセッサ：SPARC64V 1.35 GHz、コンパイラ：gcc 3.2.3）の環境下で 14842 秒であった。

次に提案モデルのパラメータ  $K_1, K_2$ 、及びネオコグニトロンにおける 2 段目及び 3 段目の実効しきい値  $\theta_l = \frac{r_l}{1+r_l}$  ( $0 \leq \theta_l < 1$ ) を変化させた場合の認識率の変化について調査する。提案モデルとネオコグニトロンにおいて互いに共通しない重要なパラメータはそれぞれ  $K_l$  と  $\theta_l$  であり、これらの値は認識率を左右する重要なパラメータである。したがって、パラメータ  $K_l$  と  $\theta_l$  の変動が認識率に与える影響を調査することは重要である（詳細な考察は 5.3 で行う）。また、本実験で用いたネオコグニトロンの学習法であるシードセル生成面による学習法 [12] では、実効しきい値を高くすればするほど学習後の細胞面数は増加する。すなわち、実効しきい値  $\theta_l$  の大小は提案モデルのパラメータ  $K_l$  の大小に対応する。図 3 に、ICA-PCA 学習時におけるパラメータである  $K_1, K_2$  を、 $9 \leq K_1 \leq 49$ 、 $9 \leq K_2 \leq 144$  の範囲で変化させた場合の認識率の変化を図示する。なお、予備実験により  $K_2 > 144$  のときは  $K_2 = 144$  の場合と認識率に差が生じないことを確認している。ネオコグニトロンにおける 2 段目及び 3 段目の実効しきい値  $\theta_l$  を変化させた場合の認識率の変化を図 4 に示す。なお、 $\theta_2, \theta_3 < 0.45$  及び  $0.85 < \theta_2, \theta_3$  の場合には学習が収束しなかった。

図 3 より、提案モデルの認識率はパラメータ  $K_1, K_2$  の値に大きく依存しないことが分かる。一方図 4 より、ネオコグニトロンの認識率は比較的参数




図 3 ETL1 データベースにおける ICA-PCA 学習時のパラメータと認識率の変化の関係

Fig. 3 Recognition rates for several parameter sets for ETL1 database in the case of ICA-PCA learning rule.




図 4 ETL1 データベースにおけるネオコグニトロン  
のパラメータと認識率の変化の関係

Fig. 4 Recognition rates for several parameter sets  
for ETL1 database by Neocognitron.

値に依存していることが分かる．パラメータ値の変動が認識率に大きく影響を与えないという特徴は，異なる認識対象に対しても共通のパラメータ値で高い認識率が得られる可能性を示唆する．5.2 では，実際に異なる認識対象についても提案モデルがこの特徴を保持していることを確認するために，HOIP 顔画像データベースを対象とした実験を行い，5.3 で考察する．

## 5.2 HOIP 顔画像データベースでの実験

5.1 の ETL1 における認識実験で得られたものと同一パラメータ値を用いて，顔画像に対する認識率を求めた．実験には，HOIP 顔画像データベース中から 20～50 歳の男女合わせて 40 人分の画像を使用し，各人物を 21 の異なる角度から撮影した画像，計 840 枚での実験を行った．前処理として， $640 \times 480$  [pixel] の各カラー画像から座標 (120, 80) を左上とした  $400 \times 400$  [pixel] の領域を切り出し，グレースケールに変換した後， $33 \times 33$  [pixel] に縮小したものを各サンプルとして使用した．図 5 は使用したサンプルの一例である．学習時には，各人において図 5 中の黒枠で囲まれた 3 アングルの画像（合計 120 枚）を使用し，それ以外の 18 アングルの画像（合計 720 枚）を認識用を使用した．

HOIP 顔画像データベースを用いた場合の認識結果を表 3 に示す．

表 3 より，提案手法である ICA-PCA 学習法が最も高い認識率を達成したことが分かる．5.1 の手書き数字においても ICA-PCA 学習法を用いた際に最も認識率が高く，しかもパラメータ値は両実験において共通の値を用いている．すなわちこの結果は，提案モデルが，認識対象に依存しない，優れた頑健性をもつことを示している．一方ネオコグニトロンでは，部分

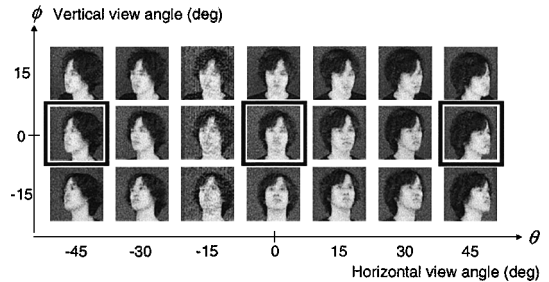


図 5 HOIP データベースでの顔画像の一例

Fig. 5 Examples of face images in HOIP database.  
Boxed images are used as training samples.

表 3 HOIP データベースにおける認識率とそのときの  
パラメータ

Table 3 Recognition rates and parameters for HOIP  
database.

手法 ( $U_{S1} - U_{S2}$ )	$K_1$	$K_2$	認識率 (%)
ICA - PCA	9	121	93.8
PCA - PCA	9	121	89.0
ICA - ICA	9	64	80.6
PCA - ICA	49	64	78.2
ネオコグニトロン	-	-	86.7
部分空間法	-	-	89.6




図 6 HOIP データベースにおける ICA-PCA 学習時の  
パラメータと認識率の変化の関係

Fig. 6 Recognition rates for several parameter sets  
for HOIP database in the case of ICA-PCA  
learning rule.

空間法の結果をも下回ってしまった．この原因は，手書き数字用にパラメータが調整されたネオコグニトロンでは顔画像中から特徴を拾いすぎてしまい，細胞面数が極端に増えた結果，汎化性が落ちてしまったものと考えられる．

図 6 に，ICA-PCA 学習時におけるパラメータである  $K_1, K_2$  を， $9 \leq K_1 \leq 49, 9 \leq K_2 \leq 144$  の範囲で変化させた場合の認識率の変化を図示する．また，ネオコグニトロンにおける 2 段目及び 3 段目の実効しきい値  $\theta_i$  を変化させた場合の認識率の変化を図 7 に示す．なお，プロットされていない点では認識率が




図 7 HOIP データベースにおけるネオコグニトロンのパラメータと認識率の変化の関係

Fig. 7 Recognition rates for several parameter sets for HOIP database by Neocognitron.

75%を下回るか若しくは学習が収束しなかった。

### 5.3 考 察

図 4 及び図 7 より、ネオコグニトロンではパラメータ  $\theta_2$ ,  $\theta_3$  の変動により認識率が大きく変化していることが分かる。また、異なる認識対象に対しては認識率の変化の様式も大きく異なり、パラメータの変化に対して敏感であることが分かる。このネオコグニトロンの性質は以前にも報告されている [17]。一般にしきい値  $\theta_2$ ,  $\theta_3$  を解析的に設定する方法は現時点において確立されていない。したがって適切なしきい値を決定するためにはすべての可能なパラメータ値の組に対して学習と認識を繰り返す必要があり、膨大な時間を要する。

提案モデルにおいて ICA-PCA 学習法におけるパラメータと認識率の変化の関係を図示した図 3 及び図 6 から、ETL1 データベースを用いた実験では  $K_2 = 9$  のときにのみ認識率が 90%を下回るものもあるが、他のパラメータでは 94%前後、HOIP データベースを用いた実験では 90%前後で、認識率が安定しており、提案モデルが認識対象によらずパラメータ値の変化に対して頑健であることが、実験より確認された。

一般に最適なパラメータ値は既知パターンを用いて得られる値であるため、未知パターンに対しても最適値であるという保証はない。したがって、提案モデルにおける上記の特徴は、未知パターンに対する汎化性が高いという重要な意味をもつ。ネオコグニトロンにおいてはテストパターンに対する汎化性を向上させるために、学習時で得られた最適なしきい値よりも小さいしきい値を用いる方法が提案されている [18]。しかしながら、どの程度小さな値にすればよいかを事前に知ることはできず、実際、しきい値が小さすぎると逆

に認識率が低下する。したがって、パラメータ値の変動が認識率に大きく影響を与えない性質は汎化性の観点から重要である。

また提案モデルではパラメータ  $K_1$  がネットワークの構造を決定し、 $K_1$  の変動が認識率に大きく影響しない。この性質は異なる認識対象に対しても同様に保持されている。よって、あらかじめネットワークの構造を決定できるため、ハードウェア化が容易に可能であるという利点も併せもつ。

なお、ICA-PCA 学習法の理論的解析は今後の課題であるが、ICA-PCA がどのような特徴を抽出しているのかを定性的に評価するために、提案手法において HOIP データベースを用いた場合における、ICA, PCA の各組合せによって学習後に獲得された結合  $a_i(\nu, \kappa, k)$  及び  $U_{S1}$  層における各細胞面の反応を可視化した (図 8)。図中において、グレースケールの濃度は結合強度若しくは細胞の反応強度に対応している。また、可視化にあたって  $K_1 = K_2 = 9$  とした。

図 8 より、1 段目に ICA を用いた場合には目や頬の輪郭といった画像中の局所的な情報をとらえているのに対して、PCA を用いた場合にはシルエットのような画像の比較的全域に存在する特徴を強調していることが分かる。2 段目においても ICA を用いた場合に局所的な情報をとらえる傾向は変わらず、結果として得られた  $U_{S2}$  層の反応は前段の学習法によらずスパースなものとなっている。一方、2 段目において PCA を用いた場合でも、画像全域に共通する特徴の抽出という傾向は変わらない。したがって、1 段目に ICA を、2 段目に PCA を組み合わせた場合には、1 段目で抽出された局所的な特徴を 2 段目において広域にわたって統合するという処理を行っていると考えられる。この処理が画像の効率的な符号化につながり、高い認識率とパラメータに対する安定性を達成できた理由であると考えられる。

## 6. む す び

本論文では、ネオコグニトロン型の階層型ニューラルネットワークに統計的次元圧縮法である ICA 及び PCA を組み合わせることで、パラメータへの依存性を低くし、理論的な解析が容易である学習法を提案した。ETL1 手書き数字データベース及び HOIP 顔画像データベースを用いた認識実験では、初段に ICA、中間段に PCA を使用する場合に最も高い認識率を得ることが示された。また、パラメータを変化させた場合

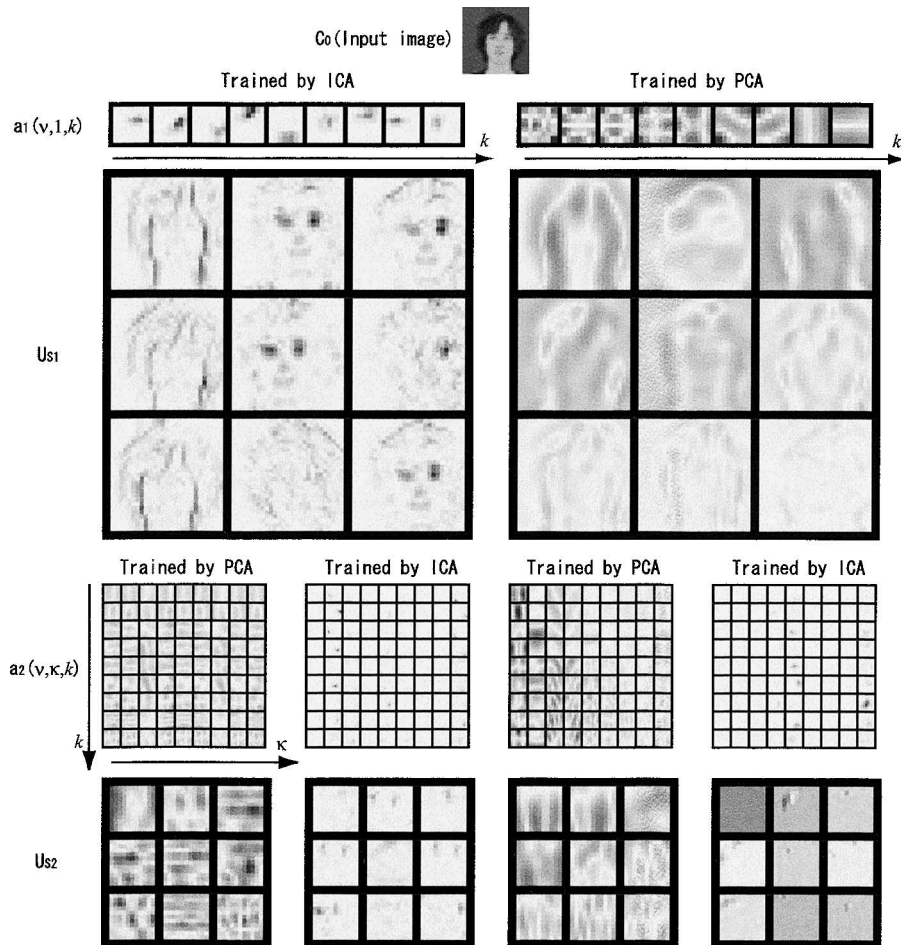


図 8 ICA 及び PCA 学習終了後の結合及びそのときの細胞面出力  
Fig. 8 Connections and outputs given by ICA rule and PCA rule.

や認識対象を変えた場合にも認識率はあまり変動せず、頑健な認識を実現した。更に、1 段を構成するために必要なパラメータ数はネオコグニトロンで 8 個であるのに対し [11]、本モデルでは  $N_{S1}$ ,  $N_{C1}$ ,  $A_1$ ,  $K_1$  の合計 4 個と大幅に削減することに成功した。すなわち、本モデルはネオコグニトロンに匹敵する認識性能をもち、かつ、より取り扱いやすいモデルであるといえる。

また、この結果は、ヒトの第一次視覚野の反応性が ICA によって再現されるという報告 [19] を裏づけるものであり、現時点ではあまり知見の得られていない高次の視覚野での情報処理原理が PCA に基づく可能性があることを示唆するものである。

本研究の枠組みを回転対応型ネオコグニトロン [3] 等のネオコグニトロン拡張モデルに適用すること、 $U_{S1}$

から  $U_{C1}$  への結合に側抑制を導入する等 C 層の情報統合の処理を拡張すること、ICA-PCA 学習時における処理の理論的解析を行うことが今後の課題である。

謝辞 本研究の一部は文部科学省科学研究補助金 #14780254 によって行われた。また、本研究の一部は東北大学電気系 21 世紀 COE プログラム“新世代情報エレクトロニクスシステムの構築”より援助を受けている。ネオコグニトロンでの実験データの詳細及びソースプログラムを提供して頂いた東京工科大学福島邦彦教授に深く感謝致します。

## 文 献

- [1] D.H. Hubel and T.N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," J. Physiol., vol.195, pp.215-243, 1968.
- [2] K. Fukushima, "Neocognitron: A hierarchical neural



network capable of visual pattern recognition,” Neural Netw., vol.1, pp.119–130, 1988.

- [3] 佐藤俊治, 黒岩丈介, 阿曾弘具, 三宅章吾, “回転対応型ネオコグニトロン,” 信学論 (D-II), vol.J81-D-II, no.6, pp.1365–1374, June 1998.
  - [4] 鶴田直之, 谷口倫一郎, 雨宮真人, “ハイバコラムモデル: 階層化自己組織マップとネオコグニトロンを統合した画像認識モデル,” 信学論 (D-II), vol.J81-D-II, no.10, pp.2288–2300, Oct. 1998.
  - [5] 丹内哲也, 萩原将文, “形態視系の情報処理に基づく多重構造ニューラルネットワーク,” 信学論 (D-II), vol.J82-D-II, no.4, pp.694–702, April 1999.
  - [6] G. Wallis and E.T. Rolls, “A model of invariant object recognition in the visual system,” Prog. Neurobiol., vol.51, no.2, pp.167–194, Feb. 1997.
  - [7] M. Riesenhuber and T. Poggio, “Hierarchical models of object recognition in cortex,” Nature Neuroscience, vol.2, no.11, pp.1019–1025, Nov. 1999.
  - [8] H. Wersing and E. Körner, “Learning optimized features for hierarchical models of invariant object recognition,” Neural Comput., vol.15, no.7, pp.1559–1588, July 2003.
  - [9] 昌達 K'z, “画像処理を極めるアルゴリズムラボ,” C MAG-AZINE, vol.11, no.10, pp.188–195, Oct. 1999.
  - [10] K. Fukushima, “Analysis of the process of visual pattern recognition by the neocognitron,” Neural Netw., vol.2, no.6, pp.413–420, 1989.
  - [11] K. Fukushima, “Neocognitron for handwritten digit recognition,” Neurocomputing, vol.51, pp.161–180, April 2003.
  - [12] 和家伸明, 福島邦彦, “ネオコグニトロンの新しい学習法,” 信学論 (D-II), vol.J75-D-II, no.11, pp.1892–1899, Nov. 1992.
  - [13] A. Hyvärinen, “Fast and robust fixed-point algorithms for independent component analysis,” IEEE Trans. Neural Netw., vol.10, no.3, pp.626–634, May 1999.
  - [14] S. Watanabe and N. Pakvasa, “Subspace method of pattern recognition,” Proc. 1st. IJCPR, pp.25–32, 1973.
  - [15] ETL1 database, <http://www.is.aist.go.jp/etlcbd/>
  - [16] HOIP database, [http://www.hoip.jp/web\\_catalog/top.html](http://www.hoip.jp/web_catalog/top.html)
  - [17] D.R. Lovell, T. Downs, and A.C. Tsoi, “An evaluation of the neocognitron,” IEEE Trans. Neural Netw., vol.8, no.5, pp.1090–1105, Sept. 1997.
  - [18] K. Fukushima and M. Tanigawa, “Use of different thresholds in learning and recognition,” Neurocomputing, vol.11, pp.1–17, May 1996.
  - [19] A.J. Bell and T.J. Sejnowski, “The “Independent components” of natural scenes are edge filters,” Vision Res., vol.37, no.23, pp.3327–3338, Dec. 1997.
- (平成 15 年 12 月 16 日受付, 16 年 7 月 23 日再受付)



下村 正夫 (学生員)

平 11 東北大・工・通信卒・平 13 同大学院工学研究科博士課程前期了。現在, 同博士課程後期在籍中。ブレインコンピューティング, 特に視覚情報処理の研究に従事。



佐藤 俊治 (正員)

平 7 東北大・工・通信卒・平 9 同大学院博士課程前期了。平 12 同大学院博士課程後期了。同年日本学術振興会特別研究員。平 13 東北大学大学院工学研究科助手, 平 16 東北福祉大学情報福祉学科講師, 現在に至る。視覚情報処理, 認識理論, 脳の高次機能の研究に従事。IEEE 会員。



三宅 章吾 (正員)

昭 41 東北大・理・物理卒・昭 46 同大学院博士課程了。同年同大工学部助手。平 4 同大工学部講師, 平 12 同大工学部助教授, 現在に至る。理博。現在脳の情報処理, 特に視覚情報処理と記憶の形成・想起に興味がある。日本物理学会, 日本神経回路学会各会員。



阿曾 弘具 (正員: フェロー)

昭 43 東北大・工・電気卒・昭 49 同大学院博士課程了。昭 48 東北大・工・助手, 昭 54 名大・工・講師。昭 57 同助教授, 昭 61 東北大・工・助教授を経て, 平 3 同教授。現在, 同大学院工学研究科教授。工博。その間, 学習オートマトン, セル構造オートマトン, 並行処理理論, シストリックアルゴリズム設計論, 文字認識, 音声認識, ニューラルネットワークなどの研究に従事。平 3 年度本会業績賞受賞。IEEE, ACM, EATCS, 情報処理学会, 人工知能学会, 日本認知科学会, LA 各会員。