

## 大規模 4 層ニューラルネット “Comb NET”

正 員 岩田 彰<sup>†</sup>      准 員 當麻 孝志<sup>†</sup>

正 員 松尾 啓志<sup>†</sup>      正 員 鈴村 宣夫<sup>†</sup>

### A Large Scale Neural Network “Comb NET”

Akira IWATA<sup>†</sup>, *Member*, Takashi TOHMA<sup>†</sup>, *Associate Member*,  
Hiroshi MATSUO<sup>†</sup> and Nobuo SUZUMURA<sup>†</sup>, *Members*

**あらまし** これまでに行われたニューラルネットワークに関する研究は、分類カテゴリー数の少ない比較的小規模なニューラルネットを取り扱っており、実用的で大規模なニューラルネットにこれらの成果をそのまま拡張できるかは疑問である。本論文は、従来のネットワークモデルでは困難であった多数のカテゴリーを分類するための大規模ニューラルネットワークの構築手法について一つの手法を提案する。提案するネットワーク Comb NET は、前段に入力データを大分類するためのベクトル量子化ニューラルネットを配置し、後段にはグループ内のデータを細分類する階層型ニューラルネットを多数並列に配置したくし型の構成をとる。このニューラルネットの学習は、前段のベクトル量子化型ニューラルネットの形成を Kohonen の自己組織化アルゴリズムにより行い、後段の階層型ニューラルネットの学習はバックプロパゲーション法を用いて行う。このネットワークの利点は学習の容易さと結合数の少なさにある。ここでは、Comb NET を JIS 第 1 水準の印刷漢字の識別に適用し、更に第 1 層と第 4 層の出力を結合するネットワークを追加して、未学習パターンについて 99.5% の識別率を得た。

## 1. ま え が き

3 層以上の階層型ニューラルネットワークによって、任意の  $N$  次元空間から任意の  $M$  次元空間への連続写像が存在することが数学的に証明されている<sup>(1)</sup>。階層型ニューラルネットの学習は、Rumelhart らによるバックプロパゲーションが多く用いられており<sup>(2)</sup>、文字認識や音声認識などに適用されある程度の成果が得られている<sup>(3)</sup>。しかしながら、これまでに行われたニューラルネットワークに関する研究は、分類カテゴリー数の少ない比較的小規模なニューラルネットを取り扱っており、実用的で大規模なニューラルネットにこれらの成果をそのまま拡張できるかは疑問である。

例えば JIS 第 1 水準の漢字を認識するような大規模なニューラルネットを単純なバックプロパゲーションアルゴリズムによって構築することは実際には多くの困難を伴う。そのような大規模なネットワークの学習では、ローカルミニマムに陥る可能性も高く、たとえ

収束するにせよ膨大な計算量を費やすことになる。大規模なニューラルネットを実用的な計算時間で構築するには、一つにはニューラルネットのシミュレーションを高速に実行できるプロセッサを用いることであるが、ネットワークを学習を行いやすい小規模なネットワークに分割し、それらの統合として大規模なネットワークを構築することも必要となる。森らは、多数の小規模なニューラルネットとそれらの出力を統合するニューラルネットによって大規模なネットワークを構築する手法を提案し、これを手書き文字認識に適用しある程度の成果を得ている<sup>(4)</sup>。

本論文では、このような大規模ニューラルネットワークの構築手法に関して一つの手法を提案する。これは前段に入力データを大分類するためのベクトル量子化ニューラルネットを配置し、後段にはグループ内のデータを細分類する階層型ニューラルネットを多数並列に配置したものである。これによって前段で大まかなグループ分けを行い、後段でグループ内での識別を行うネットワークを構築する。この大規模 4 層ニューラルネットを Comb NET と名づける。

以下、本手法の詳細と JIS 第 1 水準の印刷漢字の認

<sup>†</sup> 名古屋工業大学電気情報工学科, 名古屋市  
Faculty of Engineering, Nagoya Institute of Technology,  
Nagoya-shi, 466 Japan

識に適用した結果について述べる。

## 2. 大規模4層ニューラルネット (Comb NET)

Comb NET は、図1に示すように、第1層にベクトル量子化型ニューラルネットを配置し、後段の第2, 3, 4層には小グループ内のデータを分類する小規模な階層型ニューラルネットを多数並列に配置したネットワークである。第1層をくしの幹、第2, 3, 4層をくしの歯とみなすと、ちょうどくしのような構造をもっているため、くし型ネットワークという意味から Comb NET と名づけた。

Comb NET の学習は、まず、第1層のベクトル量子化型ニューラルネットから行う。各ニューロンは2次元格子状に配置され、自己組織化過程において、シナプス結合の適応変化は Hebb の法則と忘却効果に基づいて行われる。また、近隣のニューロンがメキシカンハットタイプの相互フィードバック結合をもち、シナプス結合の適応変化が最適のマッチングをしたニューロンの近傍でのみ行われるとすると、ニューロンのシナプス結合によって決まる参照ベクトルの形成は次の手順によって行われる<sup>(5)</sup>。

ここで、

$$\mathbf{x}_k = (x_{k1}, x_{k2}, \dots, x_{kj}, x_{kn})$$

(第  $k$  番目の入力ベクトル,  $k=1, 2, 3, \dots, K$ )

$$\mathbf{m}_i(t) = (m_{i1}(t), m_{i2}(t), \dots, m_{ij}(t), \dots, m_{in}(t))$$

(ニューロン  $i$  の参照ベクトル)

$n$ : 入力ベクトルの次元数

$K$ : 入力データ個数




図1 Comb NET の構成

Fig. 1 The network structure of Comb NET.

$t$ : 学習回数

である。

[step 0] 各ニューロンの参照ベクトル  $\mathbf{m}_i(t)$  を初期化する。

$\mathbf{m}_i(t)$ : randomize,  $t=0$

各入力ベクトル  $\mathbf{x}_k$  ( $k=1, 2, 3, \dots, K$ ) について順次 step 1, step 2 を繰り返す。

[step 1] 入力ベクトルと最も高い整合度を示す最適整合ニューロン  $c$  を求める。

$t=t+1$

$$\text{sim}(\mathbf{x}_k, \mathbf{m}_c(t)) = \max\{\text{sim}(\mathbf{x}_k, \mathbf{m}_i(t))\} \quad (1)$$

(ニューロン  $c$ : 最適整合ニューロン)

ここで、整合度は次のように求める。

$$\text{sim}(\mathbf{x}_k, \mathbf{m}_i(t)) = \frac{\sum_j (x_{kj} \times m_{ij})}{\sqrt{\left(\sum_j x_{kj}^2\right) \left(\sum_j m_{ij}^2\right)}}$$

[step 2] 最適整合ニューロン  $c$  の周りのニューロンの集合  $N_c(t)$  について、参照ベクトルを入力ベクトルの方向に若干修正する。

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + \alpha(t)(\mathbf{x}_k(t) - \mathbf{m}_i(t)) \quad (2)$$

for  $i \in N_c(t)$

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t)$$

for  $i \notin N_c(t)$

(3)

ここで  $\alpha(t)$  は学習係数であり、 $N_c(t)$  は最適整合ニューロン  $c$  の近傍にあるニューロンの集合を表す。これらは学習回数  $t$  の関数であり、一般に、 $\alpha(t)$  は単調減少関数とし、 $N_c(t)$  も学習回数と共にその半径を小さくしていく。

このような自己組織化を行うと、各ニューロンの参照ベクトルは入力ベクトルの集合の統計的性質を反映した値となる。ここで、入力ベクトルのカテゴリー数に対してニューロン数を少なく制限してこの自己組織化を行うと、類似した入力ベクトルについて同じニューロンが最適整合ニューロンとなり、類似したパターンが同じニューロンに焼き付けられるので、そのニューロンの参照ベクトルにはそのカテゴリーを代表する共通パターン(テンプレート)が成長する。認識時には、互いに類似した入力ベクトルについて同一のニューロンが最適整合ニューロンとなり、多数のカテゴリーをもつ入力集合を、類似性のあるデータごとに有限数のグループに分割することができる。

第1層の学習後、入力データの各カテゴリーが第1層のどのニューロンと最適整合になるかを調べ、各ニュー

ロンの分担すべきカテゴリーを求め、全カテゴリーを第 1 層のニューロン数と同数のグループに分割する。次に、その分割されたグループごとにその中にあるカテゴリーを識別するための階層型ニューラルネットの学習をバックプロパゲーション法を用いて行う。

識別は次のようにして行われる。まず、第 1 層のネットワークによって、入力データがどのニューロンと最適整合となるかを求める。次に、最適整合となったニューロンが担当するカテゴリーグループを分割する後段の階層型ネットワークに入力データを入力し、最も強く発火したニューロンに対応するカテゴリーに入力データを識別する。

このネットワークの利点は学習の容易さにある。バックプロパゲーション法による学習は小規模なネットワークについては収束も容易であるが、大規模なネットワークになるとローカルミニマムに陥る可能性も高く、たとえ収束するにせよ膨大な計算量を費やすことになる。本方式は、第 1 層のベクトル量子化型ニューラルネットによって大分類をしてからバックプロパゲーションによる学習を行うため、第 2, 3, 4 層の規模は小さく

なり、従って、学習は容易になる。また、後段のネットワークは相互には結合のない独立したネットワークであるから、大規模なネットワークであっても全体の結合数を少なく抑えることができる。




図 2(a) イメージスキャナによる入力イメージ  
(b) 16×16 の小領域にまとめた濃度正規化したパターン  
Fig. 2(a) An image of Chinese character acquired by an image scanner.  
(b) A shrunk image with 16×16 matrix with normalized gray levels.

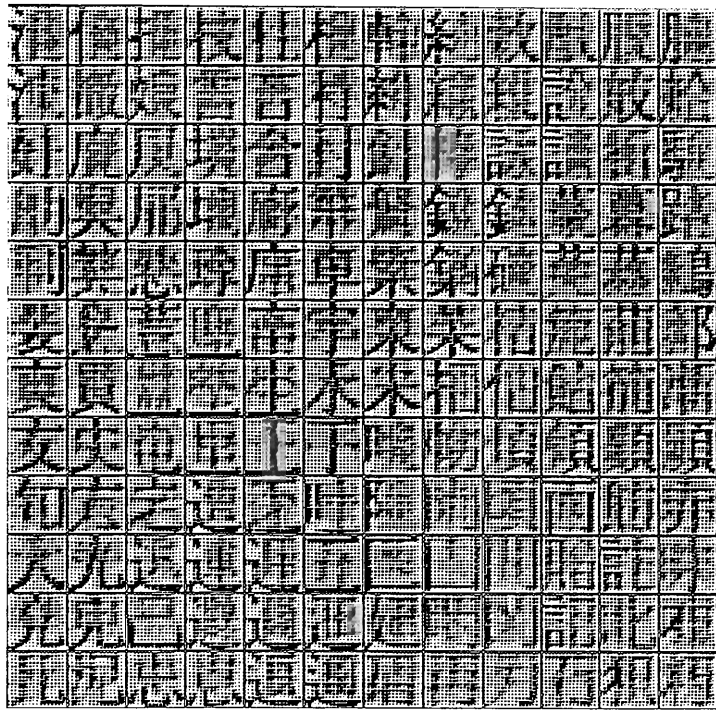


図 3 JIS 第 1 水準印刷漢字識別のための第 1 層ニューロンの参照ベクトル  
Fig. 3 The reference vectors of the VQ network constructed by Kohonen's self organizing process, which are used for recognizing Chinese character of the 1st level of Japanese Industrial Standard (JIS).

### 3. JIS 第1水準印刷漢字の識別

Comb NET のパターン識別能力を検討するために、JIS 第1水準の印刷漢字 2,965 字種を識別するニューラルネットの構築を試みた。

学習データは次のように作成した。まず、JIS 第1水準漢字を印刷したものを解像度が 400 dot/inch のイメージスキャナで読み込む。ここでは、原稿は A4 縦置き、横書きとした。そして、イメージスキャナで読み込んだ画像から、

(1) 横(行)方向に画素値を積分した濃度プロファイルから、しきい値処理により行を切り出し、

(2) 縦方向に画素値を積分した濃度プロファイルから文字を切り出した。

1文字の大きさは 4 mm 程度であり、これをイメージスキャナで読み取り切り出すと縦横がおおよそ 64 ドット×64 ドット程度の 2 値画像が得られる(図 2(a))。これを 16×16 の小領域にまとめて、濃度正規化したパターンを作成した(図 2(b))。今回、これを 5 セット作成し、そのうちの 4 セットの平均パターンを学習データにした。また、4 セットのうちの 1 セット(学習パターン)と、残り 1 セット(未学習パターン)を用いてネットワークのパターン識別能力の評価を行った。

第1層のニューロン数は 144 個(12×12)とした。参照ベクトルの初期値は一樣乱数で与え、学習回数は 1 字種当り 100 回の学習を行った。ここで、学習係数  $\alpha(t)$  と最適整合ニューロンの近傍ニューロンの集合  $N_c(t)$  の半径  $r(t)$  は次のような学習回数の単調減少関数とした。

$$\alpha(t) = 0.2 \left( 1.0 - \frac{t}{t_{\max}} \right) \quad (4)$$

$$r(t) = 5 \left( 1.0 - \frac{t}{t_{\max}} \right) \quad (5)$$

ワークステーション SUN4/260 を用いてこの自己組織化を行ったところ、要した時間は約 24 時間であった。その結果得られた各ニューロンの参照ベクトルを図 3 に示す。

この結果は非常に興味深いものが得られた。図 3 には、参照ベクトルの値を 16×16 の 2 次元マトリックス状のパターンで示したので、各参照ベクトルがどのようなテンプレートを形成しているかが明らかとなっている。各参照ベクトルには、漢字の「へん」、「つくり」、「かまえ」が形成されている。例えば、左上のニューロンには「彳」、「イ」、「扌」などの「へん」を表す参照

ベクトルが得られている。表 1 に各ニューロンが最適整合となる漢字の一覧表の一部を示す。このようにすべての漢字がその「へん」、「つくり」、「かまえ」などの特徴によって分類されている。自己組織化によって図 3 に示すような参照ベクトルが自律的に形成されたことは注目に値する。

次に、後段のニューラルネットについて、各ニューロンに割り当てられた漢字のグループごとに、バックプロパゲーション法を用いて学習を行った。各グループの字種数は最大でも 91 個であり、比較的小規模なニューラルネットとなるため、すべてのグループについて容易に学習が収束した。

このように形成されたニューラルネットのパターン識別能力を評価した。結果を表 2 に示す。このように学習に用いたパターンでは 98.5 % の識別率が得られたが、未学習パターンでは、96.9 % の識別率にとどまった。誤識別は第1層の参照ベクトルの中にもともとよく適合するものがなく、第1層でのパターン選択性の劣っている字種について発生しており、このような字種についてパターンの若干の変動でもって最適整合ニューロンが変化して誤識別となっている。これらの字種では第1層ニューロンの出力値である適合度が低く 0.5 程度となっている。

表1 各ニューロンと最適整合する漢字一覧表

| ニューロン番号 | 漢 字 種   |
|---------|---|
| 0       | 溢渦沿冲温海濁活濁滑漠汲漁況潔洪浩港溝混<br>濟滋台温洪淑清消澄滑滑滑滑龍沢濁濁濁濁<br>滴濁濁濁濁濁濁濁濁濁濁濁濁濁濁濁濁濁濁<br>涌溶谷洛澄溜淋漣漣漣            |
| 1       | 渥淫浦泳洩液演河涯湮汙汽泣溪決滅江濠漣沙<br>汐漆汁滓淨淨淨深淺洗汰淹淡池注沈津添渡沌<br>澣汝波派浮沫滅洋沃淀流涼淚浪                              |
| 2       | 娃外蛙鯉肝鯉好靜呀娃匙姉雌殊醇升酢醉姓靜<br>駐貯虹姪姪分妹魅妙   |
| 3       | 姻羽珣珣助動期劫脚動期凶湖胡胡胡胡胡胡<br>酌洲初助相制則即朝潮動動動動動動動動動動<br>油幼幼幼幼  |
| 4       | 劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃劃<br>飼飼飼飼飼飼飼飼飼飼飼飼飼飼飼飼飼飼飼<br>剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝<br>剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝剝 |
| 5       | 愛委會義策架公裝餐受裳裳製裝裝裝裝裝裝裝<br>裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝裝  |

表2 識別結果

| パターン  | 学習パターン  | 未学習パターン |
|-------|---------|---------|
| 識 別 率 | 98.48 % | 96.93 % |

(第1層ニューロン数:144個)

表 3 第 1 層のニューロン数を増やした識別結果

| ニューロン数 | 識 別 率       |         |
|--------|-------------|---------|
|        | 学 習 パ タ ー ン | 未学習パターン |
| 144    | 98.48 %     | 96.93 % |
| 324    | 99.16 %     | 97.88 % |
| 576    | 99.43 %     | 98.68 % |

この現象に対処するため、第 1 層のニューロン数を増加させたと表 3 に示すようにニューロン数を 324 (18×18), 576 (24×24) 個の増加させるにつれて識別率が向上した。これはニューロン数の増加により、第 1 層でのパターン選択性が向上した結果である。しかしニューロン数の増加は学習時間や結合数の増加を伴うため、できるだけ少ないニューロン数で識別率を更に向上する手法を検討した。

4. 第 1 層と第 4 層出力の結合

先に示したように、Comb NET の第 1 層のベクトル量子化ニューラルネットは汎化能力が比較的弱く、パターンが変動すると最適整合ニューロンが変わってしまうことがある。一方、BP による学習を行った階層型ニューラルネットは、比較的パターン変動に強い性質をもつ。そこで、次のようにして第 1 層の汎化能力の弱さを階層型ネットワークの優れた汎化能力によって補う方式を考案した。

すなわち、第 1 層に入力パターンを通し、適合度の高いものから 3 番目までのグループを選び、次に選ばれたグループの階層型ネットワークに入力パターンを通し、出力層の中で最も高い発火レベルになったものの出力値を調べる。そして、

$(\text{適合度})^\alpha (\text{出力値})^\beta$

の値が最も高くなったものを識別結果として選ぶ。こうして、後段の複数の階層型ネットワークの出力と競合させることで識別能力を高めることを目指した。このように変更したネットワークの構成を図 4 に示す。この方法を第 1 層のニューロン数が 144 個 (12×12) の Comb NET でさまざまな  $\alpha, \beta$  の値を用いて識別を行った結果を表 4 に示す。 $\alpha/\beta$  が 5 程度のところで未学習パターンについても 99.5 % の正当率を得られることがわかる。適合度や出力値はともに 0～1 の間の値であるから、 $\alpha/\beta=5$  というのは第 1 層の適合度の結果よりも、第 4 層の出力値をより強く考慮して判断していることを表している。これは BP 学習による階層型ニューラ




図 4 第 1 層と第 4 層の出力を結合した Comb NET  
Fig. 4 The network structure of modified Comb NET.

表 4 第 1 層と第 4 層の出力を結合した方式による  
未学習パターンに対する識別結果

| $\beta$ | $\alpha$     |              |              |              |       |       |
|---------|--------------|--------------|--------------|--------------|-------|-------|
|         | 0.50         | 0.75         | 1.00         | 1.25         | 1.50  | 1.75  |
| 0.05    | 98.89        | 98.62        | 98.41        | 98.25        | 98.01 | 97.88 |
| 0.10    | <b>99.49</b> | 99.26        | 99.89        | 98.79        | 98.62 | 98.52 |
| 0.15    | 99.43        | <b>99.49</b> | 99.33        | 99.09        | 98.89 | 98.82 |
| 0.20    | 99.33        | 99.43        | <b>99.49</b> | 99.33        | 99.26 | 99.09 |
| 0.25    | 99.29        | 99.43        | 99.43        | <b>99.49</b> | 99.39 | 99.26 |
| 0.50    | 98.58        | 99.02        | 99.29        | 99.33        | 99.43 | 99.43 |

単位：%, 太字は  $\alpha/\beta=5$  の場合

ルネットの二つの性質、一つは学習パターンについては特定の素子が強い出力を出し、未知パターンについてはどの素子も弱い出力を出す性質、もう一つは汎化能力に優れパターン変動に強いという性質をうまく利用したものになっている。

これは第 1 層における誤りを階層型ネットワークで回復していることになり、全体として汎化能力に優れたネットワークとなっている。このように、実用的な規模で実用的な識別能力をもったネットワークを構築することができた。このネットワークの結合数は約 1 M リンクとなっている。

## 5. む す び

多数のカテゴリーを識別するための大規模ニューラルネットとして、第1層にベクトル量子化型ニューラルネットを配置し、後段の第2, 3, 4層には小グループ内のデータを分類する小規模な階層型ニューラルネットを多数並列に配置したネットワーク Comb NET を提案した。このニューラルネットの学習は、まず、第1層のベクトル量子化型ニューラルネットの形成を Kohonen の自己組織化アルゴリズムにより行う。ここで、第1層のニューロン数は分類すべきカテゴリー数よりも少なく制限する。第1層の学習後、入力データの各カテゴリーが第1層のどのニューロンと最適整合となるかを調べ、各ニューロンの分担すべきカテゴリーを求め、全カテゴリーを第1層のニューロン数と同数のグループに分割する。次に、その分割されたグループごとにその中にあるカテゴリーを識別するための階層型ニューラルネットの学習をバックプロパゲーション法を用いて行う。

森らの提案した大規模ネットワーク<sup>(6)</sup>は、各グループごとの識別を行う処理を先に行い、その後でそれらの出力を統合する処理を行う統合型であるのに対して、Comb NET は、先に大分類を行い、その後でグループ内での細分類を行う選択型である。両者ともネットワークをモジュール化して全体の結合数を少なくすることにより、学習の収束性を高めている。しかし、認識時において、統合型はすべてのネットワークにおける処理を各入力データについて行う必要があるが、選択型では後段のネットワークは選択されたものだけを働かせればよく、認識時の計算量が少ない。但し、選択型は前段のネットワークでグループの選択を誤ると後段では回復できないため、前段のネットワークに高い汎化能力が必要とされる。Comb NET では、第1層と第4層の出力を結合し競合させることによって、ベクトル量子化ネットの汎化能力の弱さを補い、全体として十分なパターン識別能力をもつネットワークとすることができた。

ここでは、Comb NET を JIS 第1水準の印刷漢字の識別に適用し、更に第1層と第4層の出力を結合するネットワークを追加して、未学習パターンについて99.5%の識別率を得た。そのとき得られた第1層の参照ベクトルの値は、漢字の「へん」、「つくり」、「かまえ」などの部首が形成されていた。この結果は、特定の視覚的特徴に選択的に反応する脳細胞がかたまっ

て存在するという Hubel, Wiesel の報告<sup>(7)</sup>と対応づけると興味深い。すなわち、漢字の部首などの特徴に注目して反応するニューロンがあり、更にそのニューロンの周りには似たような特徴をもつ漢字に反応するニューロンが集まっていると考えることもできる。我々が、漢字を識別するとき、いきなり特定の文字を認識するのではなく、まず、部首などの特徴に注目して識別対象候補を絞り込み、それから特定の文字を認識していると思われるが、これは、漢字の部首などの特徴に注目して反応するニューロンが発火することによって大分類を行い、その後続くニューラルネットによって細分類を行っていると考えられる。Comb NET はまさにこの形態を具現化したものと考えられ、学習も安定に行うことができることから、極めて合理的なネットワークモデルと言える。

このように、本論文では、従来のネットワークモデルでは困難であった多数のカテゴリーを分類するための大規模ニューラルネットワークの構築手法について一つの手法を提案した。

これまでの結果はエンジニアリングワークステーション (SUN4) 上で行った計算機シミュレーションであり、144個のニューロン数の第1層の学習だけでもおよそ1日かかる。そこで、我々が開発利用しているニューラルネットアクセラレータ、ニューロターボ<sup>(8)</sup>上に Comb NET を実現し学習速度を向上させ、今後更に、Comb NET をいろいろなパターン識別問題に適用し、ネットワークモデルとしてのパターン識別能力や汎化能力について詳しく検討する予定である。

## 文 献

- (1) 舟橋賢一：“ニューラル・ネットワークの capability について”，信学技報，MBE88-52 (1988)。
- (2) D. E. Rumelhart, G. E. Hinton and R. J. Williams: “Learning representations by backpropagating errors”, *Nature*, 323-9, pp. 533-536 (1986)。
- (3) 山田敬嗣, 上 博行, 溝口正典, 天満 勉：“ニューラルネットを用いた文字認識”，信学技報，PRU88-58 (1988)。
- (4) 森 吉弘：“大規模ニューラルネットの構築に向けて”，信学技報，PRU88-59 (1988)。
- (5) T. Kohonen: “Self-organization and associative memory”, Springer-Verlag (1984 and 1988)。
- (6) 森 吉弘, 城 和貴：“大規模ニューラルネットによる手書き漢字認識”，平1信学秋季大会，SD-11-5。
- (7) D. H. Hubel and T. N. Wiesel: “Receptive fields, binocular interaction and functional architecture in the cat's visual cortex”, *J. Physiol.*, 160 (1962)。
- (8) A. Iwata, Y. Yoshida, S. Matsuda, Y. Sato and N. Suzumura: “An artificial neural network accelerator

using general purpose 24 bits floating point digital signal processors”, Proc. of Int. Joint-Conf. on Neural Networks, Washington D. C., 2, pp. 171-175 (1989).

(平成元年12月22日受付, 2年3月14日再受付)



岩田 彰

昭48名大・工・電気卒。昭50同大学院修士課程了。同年名工大・情報・助手。昭57年4月より昭58年10月まで、ドイツ連邦共和国ゲーセン大学医学部医用情報研究所客員研究員。昭59名工大・情報・助教授。現在、名工大・電気情報・助教授。生体情報処理、医用画像処理、ニューラルネットワークに関する研究に従事。工博、日本ME学会、情報処理学会、IEEE各会員。



當麻 孝志

平1名工大・電気情報卒。現在、同大学院博士課程前期(電気情報工学専攻)在学中。ニューラルネットに関する研究に従事。



松尾 啓志

昭58名工大情報卒。昭60同大学院修士課程了。同年松下電器産業(株)入社。平1名工大大学院博士課程了。同年名工大・電気情報・助手。現在に至る。画像処理に関する研究に従事。工博、日本ME学会、情報処理学会各会員。



鈴村 宣夫

博。

昭28名大・工・電気卒。民間会社勤務の後、昭38名大・工・助手。以後、講師、助教授を経て、昭49名工大・情報工学科教授。学科改組により、現在、電気情報工学科教授。この間、生体信号の計測、処理、生体関連の画像処理等の研究に従事。工