

論文

不等号条件を考慮した相互結合形 NNによる対応付け形状認識

富川 義弘^{*} 中山 謙二^{††} 東野 裕一^{†††}

Shape Pattern Recognition Using a Recurrent Neural Network Including Inequality Conditions

Yoshihiro TOMIKAWA^{†*}, Kenji NAKAYAMA^{††}, and Yuuichi HIGASHINO^{†††}

あらまし 入力画像中に含まれる特徴と記憶を構成する特徴を、相互結合形ニューラルネットワーク（相互結合形 NN）を用いて対応づけることにより、対象物を認識する対応付け形状認識モデルは、位置ズレ・回転に無関係な認識処理や多重認識処理を実現できる。しかし、従来の相互結合形 NN を利用した対応付け認識モデルでは、特徴同士が 1 対 1 対応するような問題しか扱っておらず、多くの情報が混在する入力画像から特定の形状のみを認識したり、同じ画像に対して異なる認識を行うといった処理は実現できない。本論文では、対応付け形状認識モデルを、形状パターンと記憶パターンの構成特徴間の対応関係を記憶した連想記憶モデルとして定義する。次に、相互結合形 NN に不等号条件を取り入れる処理を導入し、特徴間の、0 対 1, 1 対 0 の対応関係を許容するモデルを提案する。また、シミュレーションにより、提案モデルが、複合形状からの選択的パターン抽出、分離認識などの能力を有することを示す。

キーワード 相互結合形ニューラルネットワーク、対応付け、形状認識、不等号条件、ゆう度推定

1. まえがき

人間の形状認識は、網膜細胞によって得られる視覚情報から、脳細胞の処理によって導き出される一つの結果である。脳細胞を模倣したニューラルネットワーク（NN）を利用して、文字認識や 3D 立体視などの人間の形状認識能力を工学的に実現しようとする研究は、数多く行われている。本論文では、すべてのニューロンが相互に結合した相互結合形 NN を利用して、以下の認識処理を実現するための一手法を提案する。

- (1) 位置ズレ・回転に無関係な形状認識処理
- (2) 同じ入力から異なる認識結果を得る多重認識処理

位置ズレ・回転に無関係な認識処理を実現する従来方法として、認識のための形状特徴の抽出に、自己相関関数やフーリエ変換などを利用して、位置不变な特徴に置き換える方法が、古くから提案されている [6], [7], [14]。また、判断手法として、パラメータ間

のユークリッド距離やマハラノビス距離に着目する方法やペイズ推定を用いる方法 [1]~[3]、多変量データ解析 [6] を利用する方法なども提案されている。更に、これらの従来手法と学習能力をもつ NN と組み合わせることによって、汎用性のある形状認識処理を実現しようとする研究も進められている [7], [14]。

従来手法の多くは、入力データに関する線形変換と、変換結果に対する非線形処理によって実現でき、その処理をニューロンで置き換えることは可能である。ニューラルネットワークの観点からみれば、これらの従来手法を結合係数が既知として与えられた階層形 NN とみなすことができる。

福島ら [5] は、特徴抽出から判断までのすべての処理を階層形 NN で構成したネオコグニトロンモデルを提案した。このモデルは、単純細胞（S 細胞）と複雑細胞（C 細胞）の組合せによるパターンのばかし効果を利用して、位置ズレに無関係な形状認識を実現する。また、ニューロンの結合係数も競合学習により、自己組織的に学習する。

しかし、フィードフォワード結合しかもたない階層形 NN で、(2) の多重認識処理を実現することは原理的に難しい。福島らは、認識層から入力層への大規模

[†] 金沢大学大学院自然科学研究科、金沢市

^{††} 金沢大学工学部電気・情報工学科、金沢市

^{†††} 金沢大学大学院電気・情報工学専攻、金沢市

Kanazawa University, 2-40-20 Kodatsuno, Kanazawa-shi, 920
Japan

* 現在、YKK 株式会社研究開発本部

なフィードバックを構成することによって、ネオコグニトロンモデルに選択的注視などの多重認識能力を付加した。しかし、ネットワークの大規模化が問題点として挙げられる。

一方、抽出された特徴の対応付けにより、位置ズレ・回転に無関係な認識処理を実現する研究も行われている。構文解析[2]、エキスパートシステム[2]、DPマッチング[11]、弛緩整合法[12]などの対応付けによる認識手法は、よく知られている。

この対応付け形状認識に、相互結合形 NN を利用する研究も行われている。平井[13]は、相互抑制結合をもつ NN を用いた特徴パターン照合によって、形状を認識する方法を提案した。更に、敷ら[8]は、Hopfield ら[17]の提案した組合せ最適化問題の解法を利用して、入力線分情報と記憶線分情報の対応付けを求める手法を提案した。Sako ら[9]、Lin ら[10]は、同様な処理を 3D 物体視に応用した。また、Chua ら[22]、[23]は、Hopfield ら[17]の全結合の相互結合形 NN に対し、部分的な結合だけからなるセルラ形 NN を用いて、形状認識処理が実現できることを示した。

相互結合形 NN は、連想記憶モデルに利用されるように、ネットワーク内部に複数のパターンを埋め込み、初期値を変えることで、異なるパターンを検出できる。相互結合形 NN は、ネットワーク自体にフィードバック構造をもっており、福島[5]の方法よりも簡単な構造で、(2) の多重認識処理を実現できる。Rumelhart ら[4]は、ネッカーキューブの多重知覚の問題に、相互結合形 NN を利用している。

しかし、相互結合形 NN には、複数の局所安定状態が存在する。この局所安定状態は、認識の多重性を実現する反面、その制御方法は確立されてはおらず、誤認識を発生させる要因にもなっている。この誤認識が、相互結合形 NN の形状認識への応用への障害となる。

局所安定状態による誤認識を回避するために、初期状態を入力に応じて制御する方法[13]や、対応関係に関する制約条件を結合荷重に加える方法[8]が提案されている。本論文では、後者の方法をより一般的な問題に拡張する。

従来の制約条件を与える方法では、基本的に、入力画像中の特徴と認識対象物の特徴が、1 対 1 対応するような問題しか扱っていない。1 対 1 の対応付け問題は、Hopfield ら[17]が巡回セールスマントロード問題で利用した等号制約条件と同じように、相互結合形 NN に与えることができる。

しかし、多くの情報が混在する画像から、特定の形状を認識したり、同じ画像から異なる認識を行うといった認識を実現するためには、1 対 0、0 対 1 の対応関係を許容した対応関係を与える必要がある。このような制約条件は、不等号条件として表現できる。

富川ら[15]、Gee ら[18]は、相互結合形 NN を用いた最適化問題の解法において、不等号条件を相互結合形 NN に取り込む方法を提案した。これは、線形不等式にニューロンを割り当てる方法で、富川ら[15]は、このニューロンを制約ニューロンと称している。この方法は、対応付け形状認識モデルにも適用できる。

本論文では、まず、2. で、対応付け認識モデルを、形状そのものではなく、入力形状の特徴と記憶形状の特徴の対応関係を記憶した連想記憶モデルとして定義する。3. で、0 対 1、1 対 0 の対応関係を許容する相互結合形 NN を提案し、対応付け形状認識モデルをこの相互結合形 NN に置き換える。4. で、シミュレーションにより、提案手法を取り入れた対応付け形状認識モデルの能力を示す。

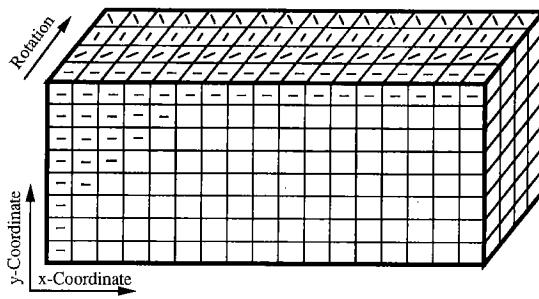
2. 対応付け形状認識モデル

位置ズレ・回転によるパターン変形を許容し、多様な認識を行う生物の認識処理の実現は、視覚情報処理の大きな目標である。本章では、入力画像（入力情報）中に存在するいくつかの要素（特徴）と記憶（記憶情報）を構成する要素（特徴）の対応付けにより、認識を行うという観点から、対応付け形状認識モデルを定義する。

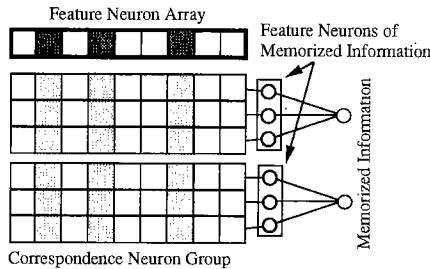
2.1 モデルの構成

図 1 に、対応付け形状認識モデルの概略を示す。本論文では、入力側の特徴を線分と考える。図 1(a) は、入力情報となる特徴ニューロンの配列を示している。線分は、位置（x 座標、y 座標）と方向（回転）の情報をもつ。入力中に線分が与えられた場合、その線分の位置・方向に対応した特徴ニューロンが反応すると考える。

図 1(b) が、対応付け形状認識モデルである。図上の太い枠で囲まれた部分が、図 1(a) の特徴ニューロンの配列を示している。図 1(a) では、特徴の空間的位置関係を示すために、特徴ニューロンを 3 次元配列で表したが、図 1(b) では、対応付けの概念を示すために 1 次元配列で表す。図中央のマトリクスの四角の各々が、対応付けを表すニューロンに相当し、まとめて対応付けニューロン群と呼ぶ。この対応付けニュ



(a) Feature Neuron Array



(b) Feature Correspondence Model

図 1 対応付け形状認識モデル
Fig. 1 A feature correspondence model.

ロン群が、検出された入力側特徴ニューロンの反応を図右の記憶側特徴ニューロンに関連づける働きをする。記憶側の特徴ニューロンは、特徴間の相対的位置関係に基づいて反応すると考える。

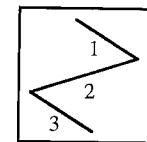
対応付けニューロン群は、ニューロンが相互に結合した相互結合形 NN になっている。対応付けニューロン群は、入力側の特徴ニューロンの反応によって、図 1(b)に陰として示されるような部分だけが動作し、他の部分の活性は抑制されるものと考える。相互結合形 NN の活性制御は、3. で述べる制約ニューロンを導入することで制御できるが、相互結合形 NN において、活性が抑制されたニューロンは、ネットワークから除外して考えることができる。

このモデルの問題点は、絶対位置に依存した入力側の情報と相対位置に依存した記憶側の情報を、相互結合形 NN を利用して、どのように関連づけるかにある。本論文では、議論の単純化のために、入力中に存在する特徴に関係した部分だけの相互結合形 NN を考える。

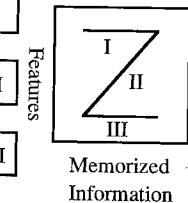
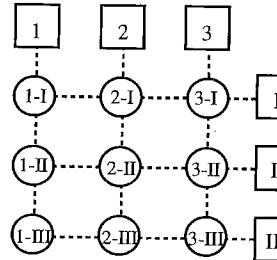
2.2 対応付け確信度

対応付け形状認識モデルを説明するために、図 2 のような Z 形の線分として、入力情報が与えられ、記憶

Input Information



Features



Memorized Information

図 2 入力情報と記憶情報の対応付け
Fig. 2 Correspondence between input information and memorized information.

情報としての Z 形に対応づけるものとする。

目的は、特徴間のもっともらしい対応付けを見つけることであるが、入力が与えられた段階で、この対応関係は全くの未知である。そこで、特徴間のすべての対応関係に対し、対応付け確信度 p_{iI} を定義する。本論文では、入力情報側の特徴に関しては、小文字の添字、記憶情報側の特徴に対しては、大文字の添字を使用する。確信度は、対応関係が成立する場合は 1、成立しない場合は 0 の値の 2 値をとる。

対応付け形状認識モデルでは、この対応付け確信度に対して、ニューロンを割り当て、対応付けニューロン群を構成する。

更に、対応付け確信度からなる確信度ベクトルを、次式のように定義する。

$$\mathbf{p} = \{p_{iI} | i = 1, 2, \dots, I = I, II, \dots\} \quad (1)$$

ゆう度推定という観点から、この確信度ベクトル \mathbf{p} は、確率変数と考える。

2.3 対応付け確信度間の相関行列

入力情報が与えられた段階では、特徴間の対応付け自体は未知であるが、対応付け確信度の間には相関性があると考える。つまり、ある特徴間の対応付けが正しいとすれば、同じ相対的位置関係にある特徴間の対応付けも正しいはずである。これは、次式の相関行列として定義できる。

$$\mathbf{R} = [r_{jJ|iI}] \quad i, j = 1, 2, \dots, I, J = I, II, \dots \quad (2)$$

ここで、要素 $r_{jJ|iI}$ は、入力情報の i 番目の特徴が記憶情報の I 番目の特徴に対応しているという仮説と入力情報の j 番目の特徴が記憶情報の J 番目の特徴に対応しているという仮説との相関関係を、実数値として表す。

もし、この相関行列が決定できれば、入力情報が与えられたときの確信度ベクトル \mathbf{p} の値は、この相関行列を結合行列とする相互結合形 NN で決定することができる。

2.3.1 既知情報がある場合

図 2 のような Z 形の場合、シミュレーションにおける図 5 の検出結果に示すような、2通りの対応関係がある。もし、情報が入力される以前に、入力側の全特徴と記憶側特徴との正しい対応関係がわかっている場合は、これらのパターンの積和行列として、相関行列を定義しておくことができる。

$$\mathbf{R} = \sum_{p=0} \mathbf{P}_{(p)} \mathbf{P}_{(p)}^t \quad (3)$$

ここで、 $\mathbf{P}_{(p)}$ は、既知の対応関係を 2 値で表したベクトルである。

式 (3) は、連想記憶モデルにおける相関学習と同じである。つまり、対応付け形状認識モデルは、形状そのものではなく、形状を構成する特徴の対応関係を記憶した連想記憶モデルと考えることができる。

2.3.2 既知情報がない場合

式 (3) は、記憶情報と入力情報との対応関係がわかっている場合の相関行列の作成法である。実際の応用では、この対応関係を事前に把握できない場合が多い。しかし、入力情報と記憶情報が与えられた段階で、この相関行列を近似的に作成する方法が、いくつか提案されている [8]～[10]。

ここでは、図 3 に示すような、記憶情報と入力情報との重ね合せにより、相関行列を作成する方法を示す。まず、ある対応付けが正しいものと仮定して、他の構成要素の重なりを評価する。もし、他の構成要素が重なる場合、仮定した対応付けの確信度と重なった対応付けの確信度の間には、相関性があると考え、相関行列の対応する値を +1 に設定する。逆に重ならない場合、-1 に設定する。この操作を全対応付けに対して行えば、表 1 に示す相関行列 \mathbf{R} を作成できる。

実際のシミュレーションでは、式 (33) に従って、プログラミングにより相関行列 R を作成した。

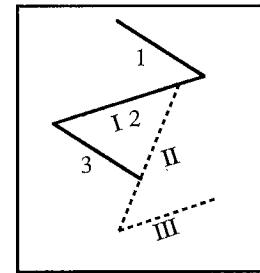


図 3 重ね合せによる相関行列の決定

Fig. 3 Production of a correlation matrix by piling up images.

表 1 Z 形の相関行列
Table 1 Correlation matrix of a Z pattern.

	相関行列								
仮説	1-I	1-II	1-III	2-I	2-II	2-III	3-I	3-II	3-III
1-I	+1	-1	-1	-1	+1	-1	-1	-1	+1
1-II	-1	+1	-1	-1	-1	-1	-1	-1	-1
1-III	-1	-1	+1	-1	+1	-1	+1	-1	-1
2-I	-1	-1	-1	+1	-1	-1	-1	-1	-1
2-II	+1	-1	+1	-1	+1	-1	+1	-1	+1
2-III	-1	-1	-1	-1	-1	+1	-1	-1	-1
3-I	-1	-1	+1	-1	+1	-1	+1	-1	-1
3-II	-1	-1	-1	-1	-1	-1	-1	+1	-1
3-III	+1	-1	-1	-1	+1	-1	-1	-1	+1

2.4 対応付け確信度の制約条件

対応付け形状認識モデルでは、特定の特徴は、対応するものがいる場合があっても、複数の特徴に対応することはあり得ないと仮定する。これらの対応関係は、次式の不等号条件で与えることができる。

$$0 \leq \sum_I p_{iI} \leq 1 \quad (i = 1, 2, \dots) \quad (4)$$

$$0 \leq \sum_i p_{iI} \leq 1 \quad (I = I, II, \dots) \quad (5)$$

ここで、式 (4) は、入力側の i 番目の特徴に対応する記憶側の特徴が、1 または 0 であることを示し、式 (5) は、記憶側の I 番目の特徴に対応する入力側の特徴が、1 または 0 であることを示している。

対応付け形状認識モデルに、この制約条件を取り入れることができれば、相互結合形 NN のもつスプリアスな収束を抑制し、正しい対応関係の探索効率を高めることができる。従来の対応付けモデルでは、等号の制約条件しか考慮されておらず、入力側と記憶側の特徴が 1 対 1 対応する問題しか扱われていない。不等号制約条件を取り入れることにより、選択的注視や選択的認識のような認識処理を対応付けモデルで行うこと

ができるようになる。

2.5 確信度ベクトルの確率密度関数と推定

対応付け形状認識モデルは、相互結合形 NN を利用して、対応付け確信度間の相関行列に埋め込まれた正しい対応付けを検出する。しかし、相互結合形 NN のパターン検出と認識との関係に関しては、明確に議論する必要がある。この節では、認識とはゆう度推定であると考え、確信度ベクトル \mathbf{p} のとり得る状態を統計的に考察する。相互結合形 NN のパターン検出との関係に関しては、3.3 で議論する。

平均 \mathbf{u} 、分散行列 \mathbf{V} をもつ連続値の確率変数ベクトル \mathbf{x} の確率密度分布の推定値 $p(\mathbf{x})$ は、最大エントロピー定理より、次式で与えられる。

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n |V|}} e^{\{-\frac{1}{2}(\mathbf{x}-\mathbf{u})^t \mathbf{V}^{-1} (\mathbf{x}-\mathbf{u})\}} \quad (6)$$

確信度ベクトル \mathbf{p} は 2 値の離散値であり、相関行列 \mathbf{R} が非正則となる場合もあるので、その確率密度関数が、式 (6) のように与えられるという保証はない。しかし、ここでは 2 値変数であっても、その確率密度が、近似的に式 (6) で与えられると仮定しておく。また、相関行列 \mathbf{R} が、式 (3) のような相関学習によって与えられる場合は、行列の非負定性が成り立つので、次式の関係が成立するものとする。

$$\mathbf{V} = \kappa \mathbf{R} \quad (7)$$

また、確信度ベクトルの平均値 \mathbf{u} は 0 としておく。

これらの仮定のもとで、確率密度関数 $p(\mathbf{p})$ は、次式で定義できる。

$$p(\mathbf{p}) = \frac{1}{\sqrt{(2\kappa\pi)^n |\mathbf{R}|}} e^{\{-\frac{1}{2\kappa} \mathbf{p}^t \mathbf{R}^{-1} \mathbf{p}\}} \quad (8)$$

この確率密度関数 $p(\mathbf{p})$ は、確信度ベクトル \mathbf{p} のとる状態のもっともらしさを表している。つまり、2.4 で与えられた制約条件を満足する 2 値の確信度ベクトル \mathbf{p} の中で、この確率密度関数のある程度高いものが、もっともらしい対応付けの推定値（ゆう度推定）とみなすことができる。

そこで、確信度ベクトル \mathbf{p} として、どのような状態が、式 (8) の確率密度関数を高くするかを、相関行列 \mathbf{R} の固有値解析により考察する。

相関行列 \mathbf{R} の固有値を $\lambda_i > 0 (i = 1, 2, \dots)$ 、固有ベクトルを $\phi_i (i = 1, 2, \dots)$ とする。相関行列 \mathbf{R} が対称行列であれば、固有ベクトル ϕ_i は正規直交する。

確信度ベクトル \mathbf{p} は、次式のように、固有ベクトルごとの成分に分解できる。

$$\mathbf{p} = \sum_i a_i \phi_i \quad (9)$$

$$a_i = \mathbf{p}^t \phi_i \quad (10)$$

ここで、変数 a_i は、固有ベクトル ϕ_i が、確信度ベクトル \mathbf{p} に及ぼす寄与を表している。これを、固有成分と呼ぶことにする。

確信度ベクトル \mathbf{p} を式 (9) で置き換えると、相関行列の行列式 $|\mathbf{R}|$ と指數関数の指數項 $\mathbf{p}^t \mathbf{R}^{-1} \mathbf{p}$ は、次式のように固有値と固有成分で表すことができる。

$$|\mathbf{R}| = \lambda_1 \lambda_2 \lambda_3 \dots \quad (11)$$

$$\mathbf{p}^t \mathbf{R}^{-1} \mathbf{p} = \sum_i \frac{a_i^2}{\lambda_i} \quad (12)$$

これらの関係を用いて、式 (8) の確率密度関数を固有値分解すれば、次式のように、各固有成分ごとのガウス分布の積として表すことができる。

$$p(\mathbf{p}) = \prod_{i=1}^n \frac{1}{\sqrt{(2\kappa\pi)\lambda_i}} e^{\{-\frac{1}{2\kappa} \frac{a_i^2}{\lambda_i}\}} \quad (13)$$

相関行列 \mathbf{R} が非正則のとき、固有値 λ_i が 0 となる場合もある。しかし、次式のダイラックのデルタ関数 $\delta(x)$ を導入すれば、相関行列 \mathbf{R} が非正則な場合でも、式 (13) の表現を拡張できる。

$$\lim_{\lambda_i \rightarrow 0} \frac{1}{\sqrt{(2\kappa\pi)\lambda_i}} e^{\{-\frac{1}{2\kappa} \frac{a_i^2}{\lambda_i}\}} = \delta(a_i) \quad (14)$$

相関行列の固有値は正値をとるので、式 (13) より、小さな固有値に対応する固有成分 a_i が大きいほど、その確率密度関数が小さくなることがわかる。特に、固有値が 0 となる場合、その固有成分が、0 以外の値をとる状態 \mathbf{p} は存在しないことになる。

従って、制約条件を満たす確信度ベクトル \mathbf{p} のとり得る状態の中で、小さな固有値 λ_i に対応する固有成分 a_i をもたない対応付け確信度ベクトル \mathbf{p} が、入力情報と記憶情報を対応させるもっともらしい推定値であると結論できる。

3. 相互結合形 NN と形状認識モデル

相互結合形 NN は、その状態変化により、固有のエネルギー関数を減少させ、準最適な解を検出する。ま

た，その初期状態を変えることで，異なる複数の解を検出できる。この相互結合形 NN の多値性を応用して，多重性をもつ形状認識を実現できる。

本章では，対応付け形状認識モデルを相互結合形 NN に置き換える方法を示す。

3.1 相互結合形 NN の状態変化とエネルギー関数

相互結合形 NN には，2 値状態しかとらない離散値モデルと状態変化の途中で連続値を許容する連続時間モデルがある。本論文の対応付け形状認識モデルには，連続時間モデルを使用する。

連続時間モデルの状態変化は，次式の時間微分で与えられる。

$$\frac{dx}{dt} = D\{\mathbf{Wx} + \theta\} \quad (15)$$

ここで， \mathbf{x} は，ネットワークのニューロンの活性値を示す状態ベクトル， \mathbf{W} は，ニューロンの結合係数を示す結合行列， θ は，しきい値ベクトルである。 \mathbf{D} は，ニューロンの飽和特性を示す対角行列で，次式で定義される。

$$\mathbf{D} = Diag[x_i(1 - x_i)|i = 1, 2, \dots] \quad (16)$$

ニューロンの活性値は，この行列の作用により，0 と 1 で飽和する。

式 (15) の状態変化は，次式で与えられるエネルギー関数を単調に減少させる。

$$E(\mathbf{x}) = -\frac{1}{2}\mathbf{x}^t \mathbf{W} \mathbf{x} - \theta^t \mathbf{x} \quad (17)$$

このエネルギー関数は，ニューロンの状態ベクトル \mathbf{x} に対して，2 次形式をとっている。相互結合形 NN は，エネルギー関数を極小化する 2 値解を検出する。

3.2 対応付け形状認識モデルの置き換え

対応付け形状認識モデルを相互結合形 NN に置き換えるために，確信度ベクトル \mathbf{p} に関する次式の 2 次形式目的関数 $F(\mathbf{p})$ を，2.4 で述べた制約条件に従って極小化するものと考える。

$$F(\mathbf{p}) = -\frac{1}{2}\mathbf{p}^t \mathbf{R} \mathbf{p} \quad (18)$$

ここで，行列 \mathbf{R} は，2.3 で定義された相関行列である。なぜ，式 (18) の極小化を行うかに関しては 3.3 で考察する。

2.4 の式 (4)，(5) の制約条件は，確信度ベクトル \mathbf{p} に関する線形不等式である。ここでは，富川ら [15] の方法に従って，この不等号制約条件を相互結合形 NN に取り込む方法について述べる。

3.2.1 不等号制約条件と制約ニューロン

式 (4)，(5) の制約条件は不等式であるが，意味としては，一方の情報の特定の要素に着目して，他方の情報の中に対応する要素があるかないかを示しており，ある場合には 1，ない場合には 0 をとる。従って，この条件も 2 値の変数として表現できる。そこで，各々の条件を次式の変数 $q_k (k = 1, 2, \dots, I, II, \dots)$ で置き換える，これらを制約変数と呼ぶ。

$$\sum_I p_{iI} = q_i (0 \leq q_i \leq 1) \quad (i = 1, 2, \dots) \quad (19)$$

$$\sum_i p_{iI} = q_I (0 \leq q_I \leq 1) \quad (I = I, II, \dots) \quad (20)$$

制約変数の導入は，相互結合形 NN では，ニューロン数を増加させることに相当する。このニューロンを制約ニューロンと呼ぶ。

ここで，式 (19)，(20) を，確信度ベクトル \mathbf{p} と制約変数を要素とする制約変数ベクトル $\mathbf{q} = \{q_k | k = 1, 2, \dots, I, II, \dots\}$ を用いて，行列表記しておく。

$$\mathbf{Cp} = \mathbf{q} \quad (21)$$

ここで，行列 \mathbf{C} は，式 (19)，式 (20) の各 p_{iI} の係数を並べた係数行列である。

制約変数ベクトル \mathbf{q} の導入により，変数ベクトル \mathbf{p} の張る状態空間は，変数ベクトル \mathbf{p} と変数ベクトル \mathbf{q} を合わせたベクトル $\mathbf{r} = \{\mathbf{p}, \mathbf{q}\}$ の張る状態空間上に変換できる。この変換は，非正方行列 $\mathbf{T} = [\mathbf{I} \ \mathbf{C}^t]^t$ を用いて，次式で定義される。

$$\mathbf{r} = \begin{Bmatrix} \mathbf{p} \\ \mathbf{q} \end{Bmatrix} = \begin{bmatrix} \mathbf{I} \\ \mathbf{C} \end{bmatrix} \mathbf{p} = \mathbf{Tp} \quad (22)$$

ここで， \mathbf{I} は，単位行列を表す。

この変換により状態変数の次元が上がるが，式 (22) によって変換される空間は，あくまで，ベクトル $\mathbf{r} = \{\mathbf{p}, \mathbf{q}\}$ の張る空間中の部分空間である。この部分空間は，次式の等号制約条件を満たしている。

$$\mathbf{Cp} - \mathbf{q} = [\mathbf{C} \ -\mathbf{I}] \mathbf{r} = \mathbf{C}' \mathbf{r} = \{0\} \quad (23)$$

ここで， $\mathbf{C}' = [\mathbf{C} \ -\mathbf{I}]$ である。

式 (22) の逆変換は，ベクトル \mathbf{r} が，式 (23) の等号制約条件を満たす場合にのみ，一般化逆行列 $(T^* = (T^t T)^{-1} T^t)$ を用いて，次式のように定義できる。

$$\mathbf{p} = \mathbf{T}^* \mathbf{r} \quad (24)$$

式(24)を式(18)に代入すれば、目的関数 $F(\mathbf{p})$ をベクトル \mathbf{r} の関数として、再定義することができる。

$$F(\mathbf{p}) = F'(\mathbf{r}) = -\frac{1}{2}\mathbf{r}^t \mathbf{T}^{*t} \mathbf{R} \mathbf{T}^* \mathbf{r} \quad (25)$$

この目的関数の変換により、目的関数 $F(\mathbf{p})$ をベクトル \mathbf{r} の部分空間上で評価できる。つまり、式(23)の等号制約条件下で式(25)の関数を極小化すれば、式(4), (5)の不等号制約条件下での式(18)の極小化問題を解くことになる。

3.2.2 線形等号制約条件

この項では、Geeら[18]の手法に基づいて、式(23)の等号制約条件

$$\mathbf{C}'\mathbf{r} = \{0\}$$

を、連続時間の相互結合形 NN に付加する方法を示す。

任意の状態ベクトル \mathbf{r} は、制約条件を満たす部分空間（制約空間）成分と制約条件にあてはまらない制約空間の直交補空間成分に分解することができる。これらの成分は、係数行列 \mathbf{C}' を用いた射影行列 $\mathbf{C}'^t (\mathbf{C}'\mathbf{C}'^t)^{-1} \mathbf{C}'$ を用いて、次式で定義される。

$$\text{制約空間成分: } (\mathbf{I} - \mathbf{C}'^t (\mathbf{C}'\mathbf{C}'^t)^{-1} \mathbf{C}')\mathbf{r} \quad (26)$$

$$\text{補空間成分: } \mathbf{C}'^t (\mathbf{C}'\mathbf{C}'^t)^{-1} \mathbf{C}'\mathbf{r} \quad (27)$$

状態ベクトル \mathbf{r} が制約条件を満たすためには、その補空間成分が 0 になればよい。式(27)の 2 乗ノルムは、状態ベクトル \mathbf{r} の 2 次形式になるので、式(25)に式(27)の 2 乗ノルムを加え合わせた次式の関数も状態ベクトル \mathbf{r} の 2 次形式となる。

$$\begin{aligned} G(\mathbf{r}) &= -\frac{1}{2}\mathbf{r}^t \mathbf{T}^{*t} \mathbf{R} \mathbf{T}^* \mathbf{r} \\ &\quad + \frac{1}{2}\beta \|\mathbf{C}'^t (\mathbf{C}'\mathbf{C}'^t)^{-1} \mathbf{C}'\mathbf{r}\|^2 \end{aligned} \quad (28)$$

ここで、係数 β を十分大きな正定数とすれば、 $G(\mathbf{r})$ を極小化することで、まず、式(28)第2項の 2 乗ノルムが極小化され、その後、式(25)の目的関数 $F'(\mathbf{r})$ を極小化することになる。従って、等号制約空間上で目的関数 $F'(\mathbf{r})$ を極小化する解を求めることができる。

最後に、相互結合形 NN のエネルギー関数(17)と式(28)が等しくなると考え、ニューロンの活性値 \mathbf{x} を変数ベクトル \mathbf{r} に置き換え、次式のように、結合係数行列 \mathbf{W} としきい値ベクトル θ を決定すれば、式(4), (5)の不等号条件下での式(18)の目的関数 $F(\mathbf{p})$ の極小化問題を相互結合形 NN を用いて解くことができる。

$$\mathbf{W} = \mathbf{T}^{*t} \mathbf{R} \mathbf{T}^* - \beta \mathbf{C}'^t (\mathbf{C}'\mathbf{C}'^t)^{-1} \mathbf{C}' \quad (29)$$

$$\theta = \{0\} \quad (30)$$

3.3 相互結合形 NN によるゆう度推定

2.5 で述べたように、相関行列が与えられている場合の対応付け確信度ベクトルのもっともらしい推定値は、式(8)の確率密度関数を大きくするものである。この観点からみれば、式(18)の目的関数 $F(\mathbf{p})$ を極小化するより、次式の関数を最小化する方が望ましいようと思える。

$$\frac{1}{2}\mathbf{p}^t \mathbf{R}^{-1} \mathbf{p} \quad (31)$$

しかし、相関行列 \mathbf{R} の正則性は保証されないので、逆行列は必ずしも定義されない。また、相互結合形 NN が複数の局所解をもち、目的関数の最小解への収束を保証しないことは証明されている[16]。従って、目的関数を式(31)に一致させることは、あまり意味がない。

そこで、相互結合形 NN によって探索される式(18)の関数 $F(\mathbf{p})$ の極小解と 2.5 で議論した対応付け確信度ベクトルの推定値との関係について、固有値解析の観点から考察する。

関数 $F(\mathbf{p})$ は、2.5 の式(12)と同様に、相関行列 \mathbf{R} の固有値 λ_i と固有成分 a_i で分解できる。

$$F(\mathbf{p}) = -\sum_i \lambda_i a_i^2 \quad (32)$$

この式から、関数 $F(\mathbf{p})$ を小さくするためには、大きな固有値 λ_i に対応する固有成分 a_i を大きくとる必要があることがわかる。また、Gee[19]らは、線形理論解析により、相互結合形 NN が、大きな固有値 λ_i に対応する固有成分 a_i の大きな解を検出しやすいことを示している。

制約条件により、確信度ベクトル \mathbf{p} のノルムは有限である。従って、大きな固有値に対応する固有成分の大きな解は、小さな固有値に対応する固有成分を含まないと見える。2.5 では、小さな固有値に対応する固有成分を含まない確信度ベクトルが、入力情報と記憶情報を対応させるもっともらしい推定値であることを述べた。つまり、式(18)の関数 $F(\mathbf{p})$ を極小化する相互結合形 NN であっても、式(8)の確率密度関数を大きくする確信度ベクトルが検出できる。

更に、ゆう度確率が高い解の探索効率を高めるためには、小さな固有値に対応する固有成分への収束を抑制した方がよい。Gee ら[19]の線形解析では、ネットワークの状態変化が、負の固有値に対応する固有成分を減少させることを述べている。また、相関行列 R の

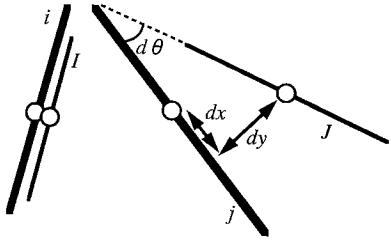


図 4 dx , dy , $d\theta$ の評価
Fig. 4 Estimation of dx , dy , $d\theta$.

全対角成分から、適当な値を引くことにより、固有ベクトルを変えずに全固有値の値を均等に下げることができる。

従って、この対角項の操作により、相関行列 \mathbf{R} の 0 近傍の固有値を負にすれば、小さな固有値に対応する固有成分をもつ解への収束を抑制できるので、もっともらしい解への探索効率を高めることができる。

4. シミュレーション

不等号条件を考慮した提案形状認識モデルの効果をいくつかのシミュレーションで示す。

4.1 相関行列 \mathbf{R} の決定

シミュレーションでは、与えられた入力情報と記憶情報から、位置情報と線分間の角度の違いを考慮して、次式の計算で相関行列 \mathbf{R} を作成した。

$$r_{iI|jJ} = 2e^{(-\frac{dx^2}{D_1} - \frac{dy^2}{D_2} - \frac{d\theta^2}{D_3})} - 1 \quad (33)$$

ここで、 dx と dy は、図 4 に示すように、線分 i と線分 I を各々の線分の中心で重ね合わせ、線分 j の中心と線分 J の中心の位置関係を、線分 j に沿った座標軸で表したときの水平方向の距離と垂直方向の距離である。また、 $d\theta$ は、そのときのこう配差である。相関係数 $r_{iI|jJ}$ は、線分の位置と方向性が一致したときに 1 となる。線分の重ね合せ方には、2通りあるので、両者の最大値を代表値とした。 D_1 , D_2 , D_3 は、 dx , dy , $d\theta$ の許容幅を表す定数である。線分の水平方向のズレは、垂直方向のズレより甘く評価できる。そこで、 D_1 は、 D_2 より大きく設定する。シミュレーションでは、 300×300 の座標空間に対し、 $D_1 = 100^2$, $D_2 = 50^2$ 程度に設定した。また、 D_3 に関しては、許容幅を 5 度として、 $D_3 = 5^2$ となるように設定した。

4.2 適用例

提案モデルを図 5～図 7 の、Z 形、ピラミッド形、家形の認識問題に適用した。このモデルの調整項目は、

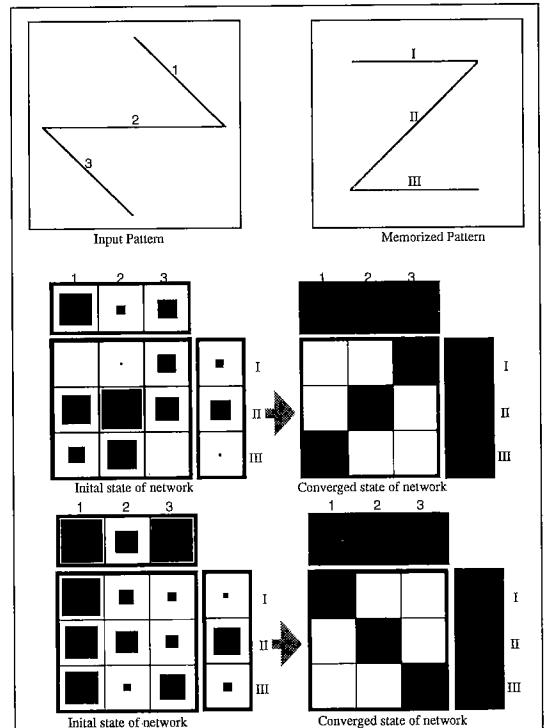


図 5 Z 形の検出
Fig. 5 Recognition of a Z pattern.

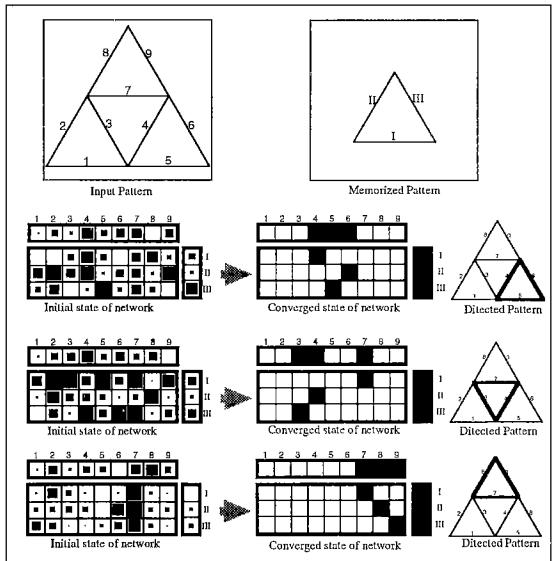


図 6 ピラミッドからの三角形検出
Fig. 6 Recognition of a triangle from a pyramid pattern.

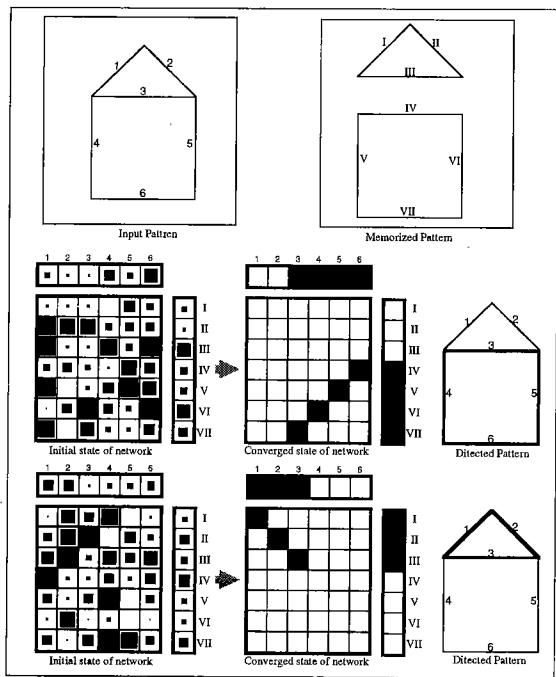


図 7 家形からの四角形・三角形の認識
Fig. 7 Recognition of a triangle and a rectangle from a house pattern.

3.3 で述べた結合行列の対角項のみである。対角項の影響に関しては、4.4 で考察するが、図 5～図 7 のシミュレーションは、すべて、あらかじめ誤認識がなくなるよう対角項を調整した後で行った。誤認識とは、相互結合形 NN を、区間 [0,1] の任意の初期状態から動作させて、収束後の状態が、入力側の特徴と記憶側の特徴の正しい対応付けにならない場合を言う。今回のシミュレーションでは、対角項の調整により、すべての問題で誤認識をなくすことができた。

また、問題の難易度を示すために、相互結合形 NN の 2 値状態数と式 (4) と式 (5) の制約条件を満足する確信度ベクトルの 2 値状態数を定義しておく。相互結合形 NN が、検出する状態は、これらの状態数の中のごく一部であり、状態数が多いほど問題の難易度が高いと考えられる。

相互結合形 NN の 2 値状態数は、2 のニューロン数乗で決定される。入力側から抽出される特徴数を N_i 、記憶側の特徴数を N_I とすれば、対応付けニューロン群のニューロン数は、 $N_i N_I$ 個になる。また、制約ニューロン数は、 $N_i + N_I$ となる。従って、ネットワークの全状態数 N_{net} は、次式で定義される。

$$N_{net} = 2^{N_i N_I + N_i + N_I} \quad (34)$$

また、不等号制約条件を満足する確信度ベクトルの 2 値状態数は、入力側の特徴数 N_i と記憶側の特徴数 N_I の可能な全対応付けを評価すればよい。仮に、両者の特徴のうち r 個が対応しているとすれば、対応付けの方法は、 $r! N_i C_r N_I C_r$ 通りある。対応個数は、両側の特徴数の小さい方に依存するので、最大で $\min(N_i, N_I)$ である。全対応付けは、可能な対応個数 r に対しての $r! N_i C_r N_I C_r$ の総和となる。従って、確信度ベクトルの 2 値状態数 N_{prob} は、次式で定義できる。

$$N_{prob} = \sum_{r=0}^{\min(N_i, N_I)} r! N_i C_r N_I C_r \quad (35)$$

ここで、 $N C_r$ は、 N 個から r 個を取る組合せの数である。

4.2.1 Z 形の検出

図 5 は、図 2 の Z 形の検出に対応付け形状認識モデルを適用した結果である。この場合、入力情報と記憶情報の特徴数は同じであり、入力情報は、記憶情報に対して 45 度傾いている。

下図のマトリクスは、各々、中央が対応付け確信度を表す対応付けニューロン群、上側が、入力側の制約ニューロン、右側が、記憶側の制約ニューロンの活性値を示したものである。黒い四角の大きさが、活性値の度合を示している。

この問題の相互結合形 NN の状態数は、 $2^{15} = 32768$ 通り、また、不等号制約条件を満足する確信度ベクトルの状態数は、34 通りである。これに対し、Z 形は点対称なので、正しい対応付けは 2 通りある。

各ニューロンの初期値を乱数で与えておき、相互結合形 NN を動作させると初期値によって異なるパターンに収束する。この例では、2 通りのパターンがほぼ半々に検出された。

4.2.2 ピラミッドからの三角形検出

図 6 は、三角形で構成されるピラミッド形の入力情報から、同じ三角形の記憶情報を認識させた結果である。この場合、記憶情報と一致する三角形は、入力情報中に複数存在する。これらの三角形は、初期値を変えることによって検出できる。

この問題の相互結合形 NN の状態数は、 $2^{39} = 5.4e+11$ 通り、また、制約条件を満足する確信度ベクトルの状態数は、748 通りである。これに対し、

入力情報中には正三角形が四つあり、各々に対して 3 通りの対応付けが存在するので、正しい対応付けは $4 \times 3 = 12$ 通りある。

図 6 には、3 通りの初期値に対しての収束パターンが示されているが、実際には、正しい対応付けが、ほぼ均等な確率で検出された。

この認識処理は、一種の選択的注視能力ともみることができる。これは、0 対 1 の対応関係を許容したことによって得られる特性であり、従来の対応付け形状認識モデルでは実現できない。

4.2.3 家形からの分離認識

図 7 は、対応付け形状認識モデルが、単に、入力情報と記憶情報の対応付けを行うだけではなく、複数の記憶情報の中から、選択的な認識処理も行えることを示したものである。このような認識処理も、0 対 1, 1 対 0 の対応関係を許容することによって、初めて実現できる。

入力情報は家形である。これは、一部の線分が共有された三角形と四角形で構成されている。記憶情報として、四角形と三角形の二つがあるものとする。

この問題の相互結合形 NN の状態数は、 $2^{55} = 3.6e + 16$ 通り、また、制約条件を満足する確信度ベクトルの状態数は、37633 通りである。これに対し、四角の対応付けが 4 通り、三角の対応付けが 1 通りで、正しい対応付けは $4 + 1 = 5$ 通りある。

この場合、対応付け形状認識モデルは、三角形と四角形を分離して認識する。これは、線分の共有によって、他方の認識を抑制するためである。各々の認識比率は、初期値を変えた 10 回の試行で、三角が 3 回、四角が 7 回であった。この認識比率の差は、ネットワークの引込み領域の問題であり、今後の課題である。

4.3 結合欠損による認識能力の変化

相互結合形 NN を利用した形状認識モデルにおいて、対応付けニューロン群、制約ニューロンは、すべて全結合している。この結合数は、ネオコグニトロンのような階層形のモデルに比較してかなり多い。しかし、山本ら [12] は、全特徴間の相関性を評価しなくとも、近傍の特徴の関係のみから、全対応付けが行えることを報告している。この場合、近傍の対応関係だけに結合をもてばよいので、結合数を大幅に削減できる。

また、図 8 は、図 6 のピラミッド形のシミュレーションにおいて、結合をランダムに切ったときのネットワークの引込み領域の変化を示したものである。このシミュレーションでは、真中の三角形の収束パター-

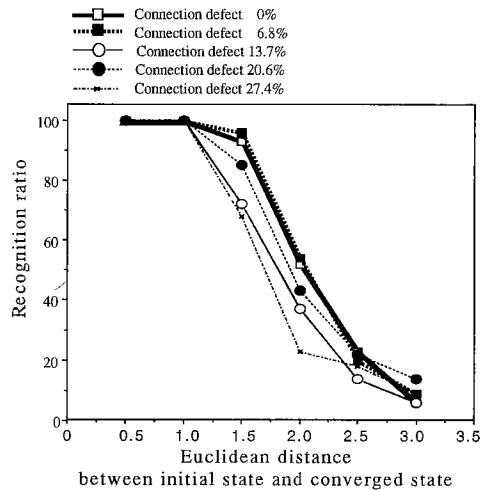


図 8 結合欠損による引込み領域の変化
Fig.8 Change of attractive region by connection defects.

ンを基準とし、そこから横軸に相当する距離の変動を与え、もとのパターンに収束する確率を評価したものである。一般的に距離が大きくなると他のパターンへ収束するので、もとのパターンへの収束確率は低下する。

このシミュレーションでは、30% ぐらい結合数を切っても、引込み領域には、ほとんど変化がなかった。つまり、結合の多くは冗長であることがわかる。このシミュレーション結果から、対応付け形状認識モデルの結合数は確かに冗長であるが、逆に結合欠損を補う能力をもたせていると考えることができる。

4.4 対角項による認識能力の変化

表 2 は、提案モデルによる認識率を、図 6 のピラミッド形に対し、初期値のばらつき、相関行列の対角項を変化させて示したものである。括弧内の数は、ピラミッド内の四つの三角のうち、三角をいくつ検出したかを示している。

このシミュレーションで、ネットワークの初期値は、次式に従って発生させた。

$$p_{iI} = 0.5 + \alpha RAND \quad (36)$$

ここで、RAND は、区間 $[0,1]$ の一様乱数とした。また、認識率は、ネットワークの初期値を変えた 100 回の試行を行い、正解数を試行回数で割った値とした。正解数とは、100 回の試行のうち、ネットワークの収束後の状態が、入力情報の特徴と記憶情報の特徴の正

表 2 対角項操作による認識率（括弧内は、検出三角数）
Table 2 Transition of recognition ratio by controlling diagonal elements.

初期値のばらつき (α)	対角項調整量			
	0.0	-1.2	-1.3	-1.4
0.1	100% (1)	100% (1)	100% (1)	100% (1)
0.45	88% (4)	94% (4)	99% (4)	100% (4)

表 3 不等号条件モデルと等号条件モデルの比較
Table 3 Comparison between a inequality condition model and a equality condition model.

モデルによる認識正解数 (100 回の試行中)			
	非制約モデル	等号条件モデル	不等号条件モデル
Z形	0	100	100
ピラミッド形	0	0	100

しい対応関係になっている場合の数である。

上坂[21]は、初期値を状態空間中心 $\{0.5, 0.5, \dots\}$ 近傍に設定することを提案している。しかし、このシミュレーションにおける試行結果では、状態空間の中心近傍で変化する初期値に対して、確かにすべて正しい対応関係を得ているが、すべて同じパターンに収束してしまった。これに対し、初期値のばらつきを大きくすると、四つの三角形のパターンをすべて検出できたが、誤認識もいくつか発生した。

3.3 で述べたように、相関行列の対角成分を調整することで、もっともらしい解への探索効率を高めることができる。このシミュレーションでは、対角成分を 1.4 下げることで、誤認識することなく、全三角形が検出できるようになった。

4.5 等号条件モデルとの認識能力の比較

表 3 は、従来の等号条件の相互結合形 NN を用いた場合と、不等号条件を考慮した場合の認識正解数を、Z 形とピラミッド形の問題で比較したものである。また、制約条件を考慮しない場合の認識正解数も示してある。認識正解数は、ネットワークの初期値を区間 [0,1] の乱数で与え、100 回の試行で評価した。

制約条件を与えないネットワークでは、いずれの問題においても、100 回の試行では、正しい対応付けを検出することができなかった。また、記憶情報と入力情報の要素数が、1 対 1 対応する Z 形では、等号制約条件を考慮することで、すべて正しい対応関係を検出した。これに対し、相互結合形 NN に不等号条件を考慮することで、記憶情報と入力情報の要素数が一致しないピラミッド形に対しても、正しい対応関係を認識させることができるようにになった。

5. むすび

本論文では、不等号条件を取り入れた相互結合形 NN による対応付け形状認識モデルを提案した。また、相互結合形 NN による判断結果と認識（ゆう度推定）との関係を、相関行列の固有値解析を用いて考察した。

シミュレーションにより、不等号条件を取り入れた対応付け形状認識モデルが、選択的注視や選択的認識などの多重認識処理を実現できることを示した。福島[5]のネオコグニトロンも選択的注視能力をもつが、提案モデルは、福島のモデルに比較して、かなり単純である。

相互結合形 NN は、本来、複数のパターンを記憶しネットワークの初期値を変えることによって、異なるパターンを検出できる。提案手法は、この相互結合形 NN の多值性を多重認識に応用了したものである。この多重認識能力は、今後の形状認識処理に対して大きな長所となる。

また、対応付け形状認識は、生物の視覚認識処理を実現する有効な手法の一つとみなすことができる。しかし、生物の視覚認識処理を実現するモデルとして、相互結合形 NN を利用するためには、形状情報の学習は大きな問題となる。本論文では、入力情報と記憶情報が与えられた状態で、対応付け確信度間の相関行列（ニューロンの結合係数）を作成する方法を提案した。これは、記憶情報の特徴構成が、モデル（脳）内で確立されていることを前提としている。しかし、生物の視覚認識において、記憶情報は与えられた入力情報から自己組織的に形成されるものである。相互結合形 NN を利用した形状認識モデルにおいて、位置ズレ・回転を伴う入力情報から、記憶情報を自己組織的に形成し、結合係数をどのように学習するかに関しては、問題として残されている。この点は、今後の課題である。

謝辞 本研究にあたり、御討議頂いた金沢大学中山研究室の皆さんに感謝します。

文献

- [1] 舟久保登, “視覚パターンの処理と認識,” 啓学出版, 1990.
- [2] R.C. Gonzalez and R.E. Woods, “Digital image processing,” 1992.
- [3] M. Sonka, V. Hlavac, and R. Boyle, “Image processing, analysis and machine Vision,” Chapman & Hall, 1993.
- [4] J.L. McClelland and D.E. Rumelhart, “Parallel distributed processing,” Vol.1 & 2, The MIT Press, 1988.
- [5] 福島邦彦 “神経回路と情報処理,” 朝倉出版, 1989.
- [6] N. Otsu and T. Kurita, “A new scheme for practical

- flexible and intelligent vision system," Proc. of IAPR Workshop on CV, pp.431–435, Oct. 1988.
- [7] 勘解由哲, 大西 昇, 杉江 昇, "ニューラルネットによる回転と大きさに対して不变な手書き数字認識," 信学論 (D-II), vol.J75-D-II, no.11, pp.1900–1908, Nov. 1992.
- [8] 敷 国利, 崔 玉軍, 泉 正夫, 福永邦夫, "ニューラルネットワークを用いた画像構造に基づく物体認識," 信学論 (D-II), vol.J75-D-II, no.10, pp.1691–1700, Oct. 1992.
- [9] H. Sako and H.I Avi-Itzhak, "A neuro computational approach to the correspondence problem in computer vision," IEICE Trans. Inf. & Syst, vol.E77-D, no.4, April 1994.
- [10] W.C. Lin, F.Y. Liao, C.K. Tsao, and T Lingutla, "A Connectionist approach to multiple view based 3-D object recognition," Proc. of IJCNN at San Diego, pp.II-835–844, June 1990.
- [11] R. Bellman, "Dynamic Programming," Princeton Univ. Press, 1957.
- [12] 山本和彦, "弛緩整合法による手書き教育漢字認識," 信学論 (D-II), vol.J72-D-II, no.1, pp.148–156, Jan. 1989.
- [13] 平井有三, "神経回路によるパターン照合," 信学論 (D), vol.J65-D, no.9, pp.1167–1174, Sept. 1982.
- [14] 富川義弘, 中山謙二, "ニューラルネットを用いたフascaの形状不良解析," 信学技報, NC92-144, March 1993.
- [15] 富川義弘, 中山謙二, "相互結合形ニューラルネットワークに不等号条件を与える制約ニューロン," 信学技報, NC94-77, March 1995.
- [16] 富川義弘, 中山謙二, "結合行列の固有値解析に基づく自己フィードバックループを持つ相互結合形ニューラルネットワークの収束性の解析," 信学技報, NC95-42, July 1995.
- [17] J.J. Hopfield and D.W. Tank, "Neural computation of decision in optimization problems," Biol. Cybern., 52, pp.141–152, 1985.
- [18] A.H. Gee and R.W. Prager, "Polyhedral combinatorics and neural networks," Neural Computation 6, pp.161–180, 1994.
- [19] A.H. Gee, S.V.B. Aiyer, and R.W. Prager, "An analytical framework for optimizing neural networks," Neural Networks, vol.6, pp.79–97, 1993.
- [20] S.V.B. Aiyer, M. Nirajan, and F. Frallside, "A theoretical investigation into the performance of the hopfield model," IEEE Trans. Neural Networks, vol.1, no.2, pp.204–215, Feb. 1990.
- [21] Y. Uesaka, "Mathematical aspects of neuro-dynamics for combinatorial optimization," IEICE Trans., vol.E74, no.6, pp.1368–1372, June 1988.
- [22] L.O. Chua and L. Yang, "Cellular neural networks: Theory," IEEE Trans. Circ. & Syst., vol.35, no.10, pp.1257–1272, Oct. 1988.
- [23] L.O. Chua and L. Yang, "Cellular neural networks: Applications," IEEE Trans. Circ. & Syst., vol.35, no.10, pp.1273–1290, Oct. 1988.



富川 義弘 (正員)



中山 謙二 (正員)



東野 裕一 (正員)

昭 57 名大・理・地球科学卒。同年 YKK (株)に入社、以来、同社研究開発本部において、信号処理、数値解析、製品検査の研究に従事。平 6 金沢大学院・自然科学研究科・博士課程に入学、現在、ニューラルネットを利用した形状認識およびその理論解析の研究に従事。



昭 46 東工大・工・電子卒。昭 46~47 同大学研究生、昭 58 工博(東工大)、昭 47 日本電気(株)入社、伝送通信事業部および C&C システム研究所に勤務し、通信用各種フィルタおよびデジタル信号処理の研究に従事。昭 63 金沢大・工・電気情報工学科助教授、平 2 教授となり現在に至る。最近の研究テーマは、適応信号処理およびニューラルネットワーク。昭 62 年 9 月 IEEE Circuits & Devices Mag. 論文賞受賞。著書「SC 回路網の設計と応用」(東海大学出版会)など。IEEE シニア会員。