

ハイパーコラムモデルにおける教師あり学習とその効果

島田, 敬士
九州大学システム情報科学研究院知能システム学部門

鶴田, 直之
九州大学システム情報科学研究院知能システム学部門

谷口, 倫一郎
九州大学システム情報科学研究院知能システム学部門

<https://hdl.handle.net/2324/5946>

出版情報 : 画像の認識・理解シンポジウム, pp.1021-1028, 2005-07
バージョン :
権利関係 :

ハイパーコラムモデルにおける教師あり学習とその効果

島田敬士[†] 鶴田直之^{††} 谷口倫一郎^{†††}

[†] 九州大学大学院 システム情報科学府 〒 816-8580 福岡県春日市春日公園 6-1

^{††} 福岡大学工学部 〒 814-0180 福岡市城南区七隈 8-19-1

^{†††} 九州大学大学院 システム情報科学研究院 〒 816-8580 福岡県春日市春日公園 6-1

E-mail: [†]{atsushi,rin}@limu.is.kyushu-u.ac.jp, ^{††}tsuruta@tl.fukuoka-u.ac.jp

あらまし 本論文では、ハイパーコラムモデルにおける教師あり学習法を提案する。ハイパーコラムモデルは階層型自己組織化マップとネオコグニトロンとを統合した画像認識モデルであり、それぞれの欠点を補完しつつ両者の利点を継承する。しかし、ハイパーコラムモデルの学習方式は自己組織化マップで用いられる競合近傍学習を利用した教師なし学習であるため、一般の画像認識には適さないという問題があった。そこで、自己組織化マップの連想記憶を用いることで、ハイパーコラムモデルを教師あり学習が可能なモデルへと拡張した。従来のハイパーコラムモデルとの比較実験を行い、教師あり学習を導入したハイパーコラムモデルの方が高い認識能力を持つことと、学習に必要なニューロンの数を削減できることが明らかになった。

キーワード 画像認識, 人工神経回路網, ハイパーコラムモデル, 階層型自己組織化マップ, ネオコグニトロン

Supervised Learning in Hyper-Column Model

Atsushi SHIMADA[†], Naoyuki TSURUTA^{††}, and Rin-ichiro TANIGUCHI^{†††}

[†] Department of Intelligent Systems, Kyushu University
Kasuga-koen 6-1, Kasuga, Fukuoka, 816-8580 Japan

^{††} Department of Electronics Engineering and Computer Science, Fukuoka University
Nanakuma 8-19-1, Jonan-ku, Fukuoka, 814-0180 Japan

^{†††} Department of Intelligent Systems, Kyushu University
Kasuga-koen 6-1, Kasuga, Fukuoka, 816-8580 Japan

E-mail: [†]{atsushi,rin}@limu.is.kyushu-u.ac.jp, ^{††}tsuruta@tl.fukuoka-u.ac.jp

Abstract In this paper, we propose a supervised learning method in Hyper-Column Model(HCM). HCM is a model to recognize images, which consists of Hierarchical Self-Organizing Map(HSOM) and Neocognitron(NC). HCM complements disadvantages of HSOM and NC, and inherits advantages from them. There is a problem, however, that HCM does not suit general image recognition in HCM since its learning method is an unsupervised one with competitive learning which is used by Self-Organizing Map(SOM). Therefore, we extended HCM to a supervised learnable model with an associative memory of SOM. We found that an ability of HCM with supervised learning is superior to the one with unsupervised learning.

Key words Image Recognition, Neural Network, Hyper-Column Model, Hierarchical Self-Organizing Map, Neocognitron

1. はじめに

人工神経回路網は、入力データの次元数が比較的少ない文字認識やリモートセンシングにおける画素単位のクラスタリングなどで多く利用されてきた。近年では、顔画像認識をはじめとする一般の画像認識への人工神経回路網の応用が広がってきている。そこでの課題として次の3点が挙げられる。

【課題1】 一般の画像は次元数が高いが、多くの冗長性を含むので、画像空間に対して自然に得られる画像が分布する領域は小さい。この冗長性を取り除き、実際に画像が分布する領域を符号化することによって、入力データの次元数を減らす必要がある。

【課題2】 画像は、対象物の位置や照明条件など多くの独立した要因によって変化するので、実際に画像が分布する領域だ

けを符号化しても、その次元数は大きい。この次元数の本質的な増加に対して、システムの大きさが現実的な規模に収まるように、システムを構造化する必要がある。

【課題3】 認識対象の概念的な抽象度が高くなるので、画像空間におけるカテゴリ間の境界が複雑な形状になる。そのような場合、人工神経回路網では非常に多くの隠れニューロンを必要とするため、原理的には万能な人工神経回路網を用いたとしても、誤差逆伝播法など学習結果が結合係数の初期状態に大きく依存してしまう学習方式では安定した学習が行えない。従って、そのような場合でも安定した認識を可能にする学習方式を用いる必要がある。

鶴田ら[1]は、これらの課題を解決するために、Lampinenらの階層型自己組織化マップ[2] (Hierarchical Self-Organizing Map: 以下 HSOM) と福島らのネオコグニトロン[3], [4] (Neocognitron: 以下 NC) を統合したハイパーコラムモデル (Hyper-Column Model: 以下 HCM) を提案している。HCMの学習方式はKohonenらの自己組織化マップ[5], [6] (Self-Organizing Map: 以下 SOM) を利用した教師なし学習であるため、結合係数の初期状態に依存することなく、HCMの構造上の利点を十分に引き出すことができる。また、HCMは、HSOMとNCの欠点を克服すると同時に、利点をそのまま継承できるので、一般の複雑な画像空間を極めて効果的に符号化することができ、HSOMやNCに比べて高い画像認識能力を持つ。しかし、非常に似通ったカテゴリを認識する場合など、カテゴリ間の境界がさらに複雑なものになる場合、HCMの教師なし学習方式では、十分な認識能力が得られないことがある。

そこで、本論文では、HCMにSOMの連想記憶を用いることでHCMを教師あり学習可能なモデルへと拡張する方法を提案する。以下では、まず2章でHCMの構造について述べ、3章でHCMの教師あり学習法を提案する。4章では画像の認識実験により、教師あり学習を用いたHCMと従来の教師なし学習によるHCMとの比較を行い、教師あり学習を導入した場合の方が優れた認識能力を持つことを示す。

2. 階層型自己組織化マップとネオコグニトロンを統合したハイパーコラムモデル

2.1 自己組織化マップ (SOM)

Kohonenが提案したSOMは、中間層の無い2階層型の教師なし競合近傍学習モデルである[5], [6]。図1にSOMの構造を示す。入力層の入力ベクトル I はマップ層のニューロン ($1 \dots u \dots N$) すべてと結合している。各ニューロン u は、入力ベクトルと同じ次元の結合係数ベクトル W_u を持ち、式(1)を満足するニューロン c が活性化する。

$$\|I - W_c\| = \min_u (\|I - W_u\|) \quad (1)$$

学習時には、学習データが入力されるたびに、式(1)により、最大活性化ニューロン c を求め、式(2)により結合係数を更新する。

$$W_u(t+1) = W_u(t) + h_{cu}(I(t) - W_u(t)) \quad (2)$$

$$h_{cu} = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_u\|^2}{2\sigma^2(t)}\right) \quad (3)$$

SOMの特徴は、ニューロン間にも距離が定義されていることである。式(3)の $\|r_c - r_u\|$ は、ニューロン c とニューロン u の距離である。学習時の繰り返し処理の各フェーズでは、最大活性化ニューロンの結合係数だけを更新するのではなく、最大活性化ニューロンの近傍のニューロンも同様の学習を行う。 $\sigma^2(t)$ は、最大活性化ニューロンと同時に学習する近傍範囲を制御するためのパラメータである。 $\alpha(t)$ は学習レートで、学習の過程で徐々に0に近づく。

2.2 階層型自己組織化マップ (HSOM)

Lampinenらが提案したHSOMは、SOMを二つ重ねた多層の人工神経回路網である[2]。HSOMの構造を図2に示す。まず、十分な数のニューロンからなるSOM(マップ第1層)に入力ベクトルを入力し、入力空間を量子化する。次に、マップ第1層のニューロンの“添え字”をマップ第2層の入力とし、マップ第1層を再量子化する。Lampinenらは、類別問題に対して従来のSOMやK-means法よりもHSOMが優れていることを示している。

HSOMの利点は次の二つに要約でき、画像認識に極めて有効であると考えられる。

【利点1】 入力データの連続的な変化に対して十分に密なサンプルデータが得られる場合には、入力データの複雑な分布への柔軟な対応が可能である。

【利点2】 データの分布領域の次元数がデータ空間の次元数よりも低い場合に、パターン認識の前処理として、入力データの次元を縮小する効果を持つ。

しかし、HSOMをそのまま一般の画像認識に応用する場合、次の三つの欠点を持っている。

【欠点1】 HSOMによる認識は、基本的にメモリベースの手法であると考えられるので、データの分布領域の次元数が増え、空間のサイズが大きくなるため、ネットワークサイズが大きくなってしまふ。

【欠点2】 マップの形成は、テンプレートマッチングによる画像間の距離で定義される空間におけるサンプルデータの分布の連続性に基づいて行われる。従って、対象物の位置ずれと拡大縮小に対して画像間の距離が十分に滑らかに変化しない場合は、マップに形成が困難である。このような場合は、画像をあらかじめぼかすなどの前処理を行うか、十分に滑らかな画像間距離が得られる程度にサンプル数を増やす必要がある。

【欠点3】 認識方法も、テンプレートマッチングによる画像間距離によるもので、自己組織化により得た標本点を用いた最近傍法を位置づけることができる。従って、画像をあらかじめぼかすなどの前処理を行うか、非常に高い精度の対象領域の切り出しと位置や大きさの正規化を行う必要がある。

2.3 ネオコグニトロン (NC)

福島らが提案したNCは、図3に示すようにLampinen型のHSOMに類似したネットワークをピラミッド型に結合した構造になっている[3], [4]。Lampinen型のマップ第1層がNCの特徴抽出層 U_S に、マップ第2層がNCの位置ずれ吸収層 U_C

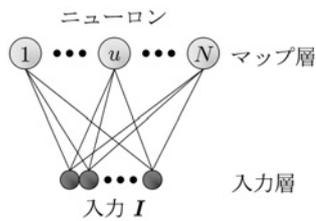


図 1 SOM の構造

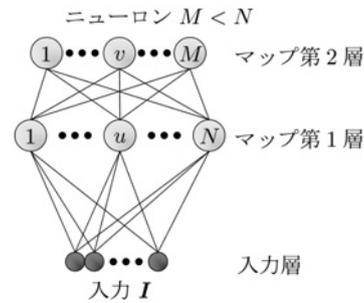


図 2 HSOM の構造

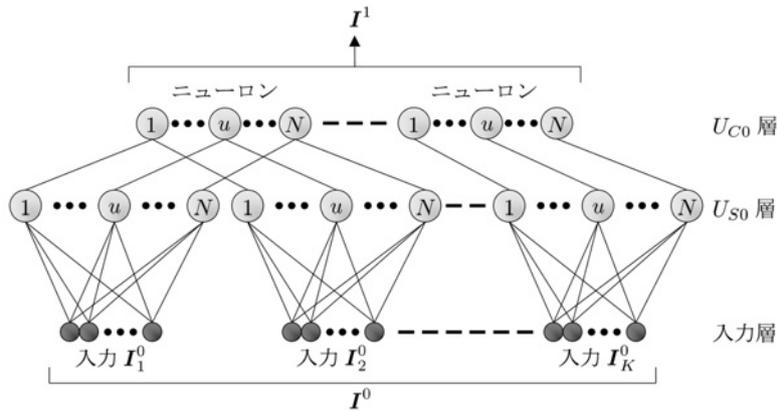


図 3 NC の構造

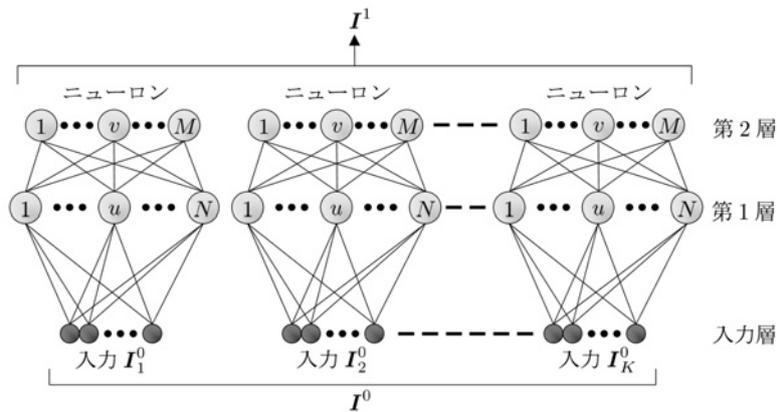


図 4 HCM の構造

に相当する。ひとつの HSOM に相当した部分は、特徴抽出層 U_S に複数のマップを持ち、 U_S 層の入力領域は、図 3 の I_1^0 から I_K^0 のようにそれぞれ独立しているのではなく、1 画素あるいは 1 ニューロンずつずれるように重なりを持った構造になっている。位置ずれに不変な認識を実現するために、同一層のマップはその位置に関係なく同じである。

NC の構造上の利点は、次の二つに要約でき、HSOM の欠点を解消するものとなっている。

【利点 1】 分割統治型の階層構造になっているため、各層におけるマップは比較的小さいものとなる。これは、HSOM の欠点 1 を解消する。

【利点 2】 HSOM の欠点 2 および欠点 3 に対して、NC は位置ずれを吸収する機能を持っているため、ぼかしなどの前処理

や精度の高い位置や大きさの正規化を必要としない。また、自己組織化の際に必要なサンプル数を軽減できる。

しかし、オリジナルの NC は、そのまま一般の画像認識に応用する場合、次の二つの欠点を持っている。

【欠点 1】 NC では、近傍学習を行わない単純な競合学習を用いて特徴抽出層を学習するため、学習結果が各ニューロンに与える結合係数の初期状態に大きく依存し、十分な特徴抽出が行えない場合が頻繁に起こる。これは HSOM の利点 1 によって解消できる。

【欠点 2】 位置ずれ吸収層は、局所特徴の位置ずれだけを吸収するものであり、HSOM のような特徴空間の再量子化は行わない。そのため、対象の変形に関しては十分な次元の縮小が行えていない。これは HSOM の利点 2 によって解消できる。

2.4 ハイパーコラムモデル (HCM)

2.4.1 HCM の構造

鶴田らが提案した HCM は, HSOM と NC を統合したモデルで, 2.2 節および 2.3 節で述べた HSOM と NC の欠点を互いの利点で補完しあう関係にある [1]. HCM の構造は, 図 4 に示すように Lampinen 型のネットワークを NC と同様にピラミッド型に結合したものである. 一つの HSOM の第 1 層 (特徴抽出層) の入力領域も NC と同様に, 図 4 の I_1^0 から I_k^0 のようにそれぞれ独立しているのではなく, 1 画素あるいは 1 ニューロンずつ重なりを持つ構造になっている. さらに, 位置に不変な認識を実現するため, 同一層のマップはその位置に関係なく同じである. HCM と NC の異なる点は, Lampinen 型の第 2 層 (HCM では特徴統合層と呼ばれる) で, マップの再量子化と位置ずれの吸収を同時に行っていることである. これにより, NC よりも更に大幅な次元縮小が可能となり, 大きな変形に対して不変な認識が可能である.

この構造により, HCM は HSOM と NC の欠点を克服すると同時に, 利点をすべて継承することができるので, HCM による画像認識は「対象物の位置と大きさ, 変形, 照明条件などの連続的な変化により画像空間中に張られる画像データの分布領域を効果的に階層的に量子化し, 量子化によって得られた標本点を用いて最近傍法により認識する手法」と位置づけられている.

2.4.2 HCM の学習方法

HCM は, 下位の層から順に 1 層ずつ学習する. 同一層内ではその位置に関係なくマップは同じであるので, 学習の際に用いるマップは各層で一つだけである. 第 L 層の各特徴抽出層では, 第 $L-1$ 層からのデータを入力として, 式 (1) を用いて最大活性化ニューロンを一つ求める. その後, 式 (2) により, 結合係数を更新する.

特徴統合層では, Lampinen らが示したように, 特徴抽出層で最大活性化ニューロンとして選択されたニューロンの添え字を入力として特徴抽出層と同様の学習を行う.

3. HCM の教師あり学習

3.1 HCM の問題点

2.4 節で述べたように, HCM の構造は NC とよく似ているが, その学習法は自己組織化による教師なし学習法を採っている. 一般には, 教師あり学習の方が教師なし学習による認識よりも優れた認識ができることが知られており, NC の場合もそのことが報告されている [7]. 従って, HCM の認識能力を更に向上させるためには, 教師あり学習が必要である. また, 教師なし学習を用いているために, これまでの HCM で認識を行うためには入力したカテゴリに対して最上位層のどのニューロンが活性化したのかという対応付けをカテゴリ毎に“人手で”行う必要があった.

3.2 教師あり学習の導入

3.1 節で述べた課題 1 を解消するために, 一木らが提案した SOM の教師あり学習法 [8] を導入する. この学習法では, SOM の入力層に与える学習データを式 (4) のように, 従来の SOM

の入力信号 I とその入力に対する教師信号 T とに分割して考えることで, 教師あり学習と見なすことができる.

$$X = a \begin{bmatrix} I \\ 0 \end{bmatrix} + \begin{bmatrix} 0 \\ T \end{bmatrix} \quad (4)$$

パラメータ a の値が大きいくほど, I の特徴がマップに反映されるようになる. また, 各ニューロン u の結合係数の入力ベクトル W_u は, 式 (5) のように表される.

$$W_u = \begin{bmatrix} W_u^I \\ W_u^T \end{bmatrix} \quad (5)$$

入力ベクトルを式 (4), 結合ベクトルを式 (5) として考える以外は, SOM と同様の学習を行えばよい.

認識時には, 入力信号 I を入力し, 最大活性化ニューロン c を求める. その後, 式 (6) により出力信号 O (認識結果) が計算される.

$$O = W_c^T \times v \quad (6)$$

$$v = \frac{\sqrt{a^2 \|I\|^2 + \|T\|^2}}{u} \quad (7)$$

4. 実験

4.1 実験の条件

図 5 に示す 10 カテゴリから成る手形状を学習させる. 各カテゴリ 10 枚ずつの学習用画像と 500 枚ずつの検証用画像を用意した. 画像は 100×100 画素の大きさで, 256 階調の濃淡画像とした. いずれの画像も手の位置, 大きさ, 照明の条件をほぼ同じとした. 次に, 実験で用いた HCM の構成を表 1 に示す. 各特徴抽出層のニューロンは 1 次元のリング状に配置する. 学習データは次の二通りの方法で学習を行う.

【実験 1】 カテゴリ 1~5 までの学習データを学習させる.

【実験 2】 カテゴリ 1~10 までの学習データを学習させる.

実験 1, 実験 2 ともに同じ HCM の構成で教師なし学習と教師あり学習の両方で学習を行う. また, 教師あり学習を適用するのは最上位層のマップのみとする. 認識には, 各カテゴリ 10 枚ずつの学習画像を使ってニューロンにカテゴリのラベル付けを行った HCM に対して, 各カテゴリ 500 枚ずつの検証用画像を入力し, HCM が正しいカテゴリのニューロンを最大活性化ニューロンとして選択する割合を認識率として評価する. 実験には, Intel Pentium 4 Processor 3.2GHz の CPU と 1GB のメモリを搭載した計算機を用いた.

4.2 実験 1

4.2.1 学習結果

図 6 は, カテゴリ 1~5 までの画像を学習させたときの, 各学習データと HCM の最上位層で最大活性化したニューロンとの関係を表したものである. 図の横軸は学習データの番号で 10 個ずつのデータがそれぞれカテゴリ 1~5 までに対応している. 一方, 縦軸はニューロンの番号である. 教師なしで学習を行った場合も, 教師ありで学習を行った場合も, 各カテゴリの学習データに対して連続したニューロンの集合 (クラスター) が対応

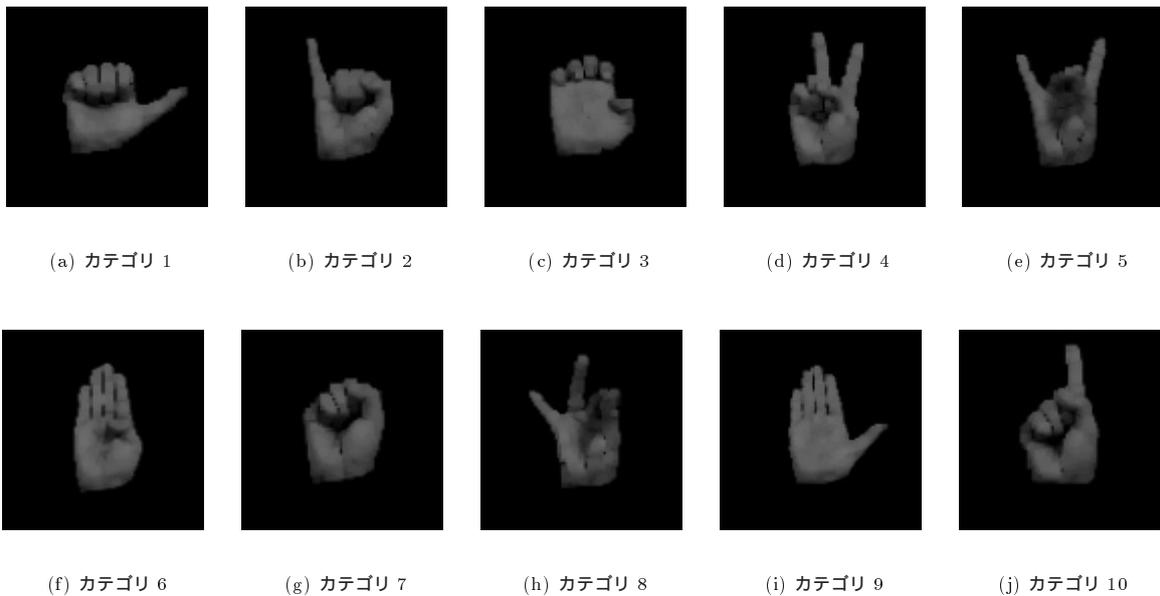


図 5 学習に用いた手の画像

表 1 実験で用いた HCM の構成

		HSOM	シフト数	シフト幅		結合領域の大きさ	ニューロンの数	学習の繰り返し回数
第 1 層 (最上位層)	縦	1	0	0	特徴統合層	-	-	-
	横	1	0	0	特徴抽出層	8 × 8	100	100
第 2 層	縦	8	1	1	特徴統合層	-	10	100
	横	8	1	1	特徴抽出層	5 × 5	100	100
第 3 層 (最下位層)	縦	20	3	1	特徴統合層	-	5	100
	横	20	3	1	特徴抽出層	5 × 5	100	100

付けられていることがわかる。尚、学習に要した時間は、教師なしの場合、教師ありの場合ともに約 30 分であった。

4.2.2 認識精度

各カテゴリ 500 枚ずつの検証用画像を、学習後の HCM に入力したときの認識結果を表 2 に示す。参考として、最近傍法を用いた場合と 3 層パーセプトロンを用いた場合での認識率も挙げておく。教師なし学習の場合の認識率は平均で 93.7%，教師あり学習の場合の認識率は平均で 97.1% というように、両方の場合で高い認識率を示している。

4.3 実験 2

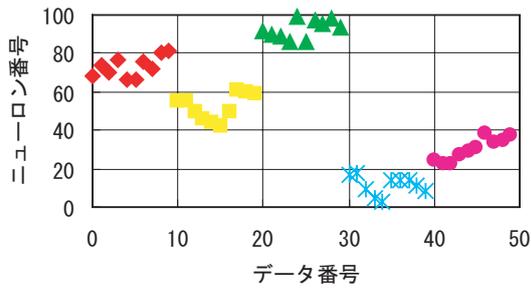
4.3.1 学習結果

図 7 は、カテゴリ 1~10 までの画像を学習させたときの、各学習データと HCM の最上位層で最大活性化したニューロンとの関係を表したものである。図 6 と同様、図の横軸は学習データの番号で 10 個ずつのデータがそれぞれカテゴリ 1~10 までに対応しており、縦軸はニューロンの番号である。教師なし学習を行った HCM では、各カテゴリに対して連続したニューロンの集合（クラスタ）が対応付けられない場合（カテゴリ 1、カテゴリ 2、カテゴリ 6、カテゴリ 7、カテゴリ 8）が出てきた。これは、実験 1 よりも学習するカテゴリ数が増えたため、教師なしでクラスタを生成するために必要なニューロンの数が足りなかったことが原因と考えられる。一方、教師あり学習を行った HCM では、ほとんどのカテゴリにおいて、クラスタが生成

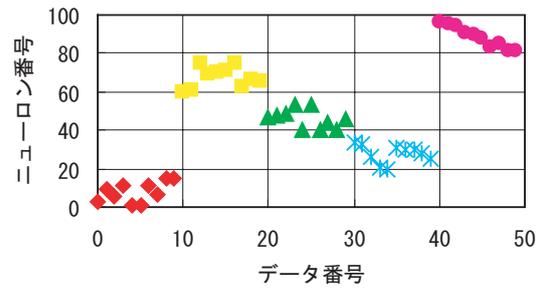
されていることがわかる。学習データには教師信号が含まれているため、うまくクラスタが生成されたと考えられる。尚、学習には教師なしの場合、教師ありの場合ともに約 1 時間を要した。

4.3.2 認識精度

各カテゴリ 500 枚ずつの検証用画像を、学習後の HCM に入力したときの認識結果を表 3 に示す。教師なし学習の場合の認識率は平均で 72.5% であった。5 カテゴリを学習した実験 1 の認識率と比べて、約 20% 近く認識率が低下している。また、最近傍法や 3 層パーセプトロンよりも認識率は劣っていた。表 4 は、教師なし学習を行った場合の誤認識率を示している。例えば、カテゴリ 1 は 10.4% がカテゴリ 2 として誤認識されたことになる。また、表中で背景が塗りつぶされたセルは正しく認識された割合である。誤認識が多かった場合のサンプル画像を図 8 に示す。図 8(a) は、カテゴリ 7 の画像がカテゴリ 2 として誤認識されたときの画像である。一見すると明らかにカテゴリ 7 に属する画像であるが、図 7(a) から分かるように、カテゴリ 7 とカテゴリ 2 に対応するニューロンのクラスタが重なり合っているためこのような誤認識が起こったと考えられる。また、図 8(b) に示すカテゴリ 9 がカテゴリ 6 として誤認識されたとき、ほとんどの場合は親指が掌側に寄っていることが多かった。これは教師なし学習を行ったため、カテゴリ 6 に近いものとして学習されたと考えられる。



(a) 教師なし学習（従来手法）

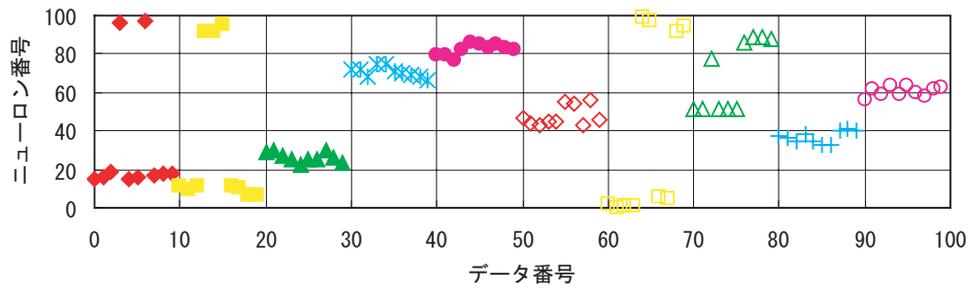


(b) 教師あり学習（提案手法）

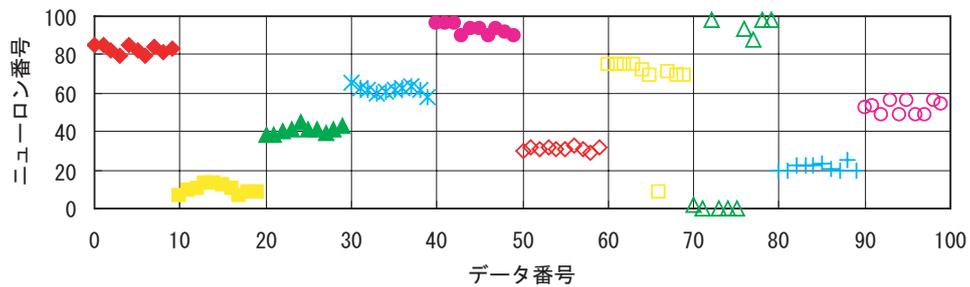
図 6 カテゴリ 1~5 を学習した後の HCM の最上位層のニューロンと学習データの関係

表 2 カテゴリ 1~5 のテストデータに対する認識率 (%)

カテゴリ番号	1	2	3	4	5	平均
最近傍法	98.8	88.8	99.0	90.2	93.4	94.0
3層パーセプトロン	83.2	78.6	86.8	85.6	81.0	83.0
教師なし HCM	94.8	87.2	99.2	98.2	85.6	93.7
教師あり HCM	99.6	93.0	99.6	100	93.2	97.1



(a) 教師なし学習（従来手法）



(b) 教師あり学習（提案手法）

図 7 カテゴリ 1~10 を学習した後の HCM の最上位層のニューロンと学習データの関係

一方で、教師あり学習の場合の認識率は平均で 93.3%であった。実験 1 の場合と比較しても、認識率はさほど低下すること

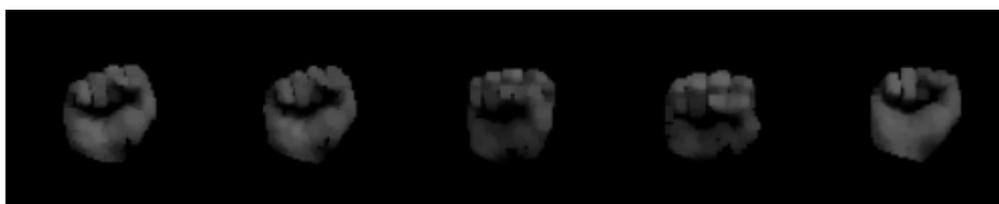
なく、良い結果が得られている。教師あり学習を行った場合の誤認識率を表 5 に示す。カテゴリ 9 がカテゴリ 6 として誤認識

表 3 カテゴリ 1～10 のテストデータに対する認識率 (%)

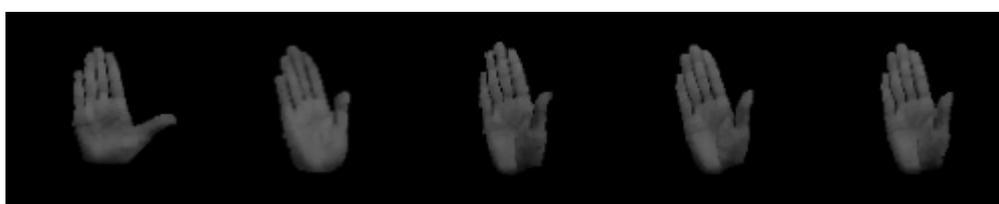
カテゴリ番号	1	2	3	4	5	6	7	8	9	10	平均
最近傍法	92.2	73.8	97.8	68.4	79.4	95.8	96.8	93.2	60.6	84.8	84.3
3 層パーセプトロン	76.8	73.2	82.8	79.0	76.2	83.6	81.2	79.2	67.4	75.6	77.5
教師なし HCM	75.4	63.4	91.6	72.4	80.2	89.0	57.2	51.4	62.4	82.2	72.5
教師あり HCM	98.4	91.4	98.4	98.2	89.2	90.4	98.2	97.2	80.8	91.0	93.3

表 4 教師なし学習を行った場合のカテゴリ毎の認識率と誤認識率 (単位%)

カテゴリ番号	1	2	3	4	5	6	7	8	9	10
1	75.4	10.4	1.2	0	0	0	12.8	0.2	0	0
2	1.8	63.4	2.4	2.0	1.8	2.0	11.6	13.4	0.2	1.4
3	0.6	1.8	91.6	0.2	0.4	2.6	0.6	0.4	0.8	1.0
4	0	0.8	0	72.4	2.0	7.4	0	3.4	0	14.0
5	0.2	0.2	0	4.2	80.2	3.0	0.8	9.2	0	2.2
6	0	0.8	0.2	5.2	0.4	89.0	0	2.2	0	2.2
7	5.6	28.0	0.2	1.0	1.0	0.6	57.2	4.6	0	1.8
8	0	4.6	0.4	2.8	25.4	12.4	0.8	51.4	0	2.2
9	0	2.6	3.2	0.6	0	28.2	0.4	0.4	62.4	2.2
10	0	0	0	2.0	2.0	11.2	0.2	2.4	0	82.2



(a) カテゴリ 7 をカテゴリ 2 に誤認識した場合



(b) カテゴリ 9 をカテゴリ 6 に誤認識した場合

図 8 教師なし学習で誤認識したサンプル画像

される割合が、その他の場合に比べて高かった。このときの誤認識画像を図 9 に示す。親指が掌からしっかりと開いたものを学習データとして与えたため、親指の位置が極端に掌に近いものが誤認識される傾向にあった。学習データを工夫すればこの問題は解決できると思われる。

4.4 考 察

実験 1 では、従来の教師なし学習を行った HCM と教師あり学習を行った HCM の両方で、高い認識率が得られた。各カテゴリの学習データに対応付けられた最上位層のニューロンを見ても、ニューロンのクラスタが適切に生成されており、十分な学習が行われたことがわかった。一方、実験 2 では、教師なし学習を行った HCM では認識率が著しく低下した。これは、学

習後に各カテゴリに対応付けられたニューロンのクラスタが連続したニューロンから構成されていないことが一つの要因と考えられる。このようなクラスタが多く存在すると、カテゴリの境界をうまく作り出すことが難しくなるため、誤認識が増えたものと思われる。これに対して教師あり学習を行った HCM では、連続したニューロンから構成されるクラスタが生成されていた。これは、表 6 に示すクラスタの標準偏差からも分かる。教師あり学習を行った場合のほうが、全体的に標準偏差が小さくなっているため、各カテゴリの学習データが連続してまとまっているニューロンに対応付けられている。従って、教師なし学習を行った場合では、10 個のクラスタを適切に生成するために必要なニューロンの数が足りなかったのに対し、教師あり

表 5 教師あり学習を行った場合のカテゴリ毎の認識率と誤認識率（単位%）

カテゴリ番号	1	2	3	4	5	6	7	8	9	10
1	98.4	0.4	0	0	0	0	1.2	0	0	0
2	0	91.4	0.2	2.6	0.4	1.0	1.0	2.0	0	1.4
3	0.2	0.2	98.4	0	0	0	0.6	0	0.2	0.4
4	0	0	0	98.2	0	1.6	0	0	0.2	0
5	0.2	0	0.2	0.6	89.2	0.8	0.8	5.8	0	2.4
6	0	1.0	0.2	1.2	0.2	90.4	0.4	3.2	0.2	3.2
7	0.6	0	0	0.2	0	0.6	98.2	0	0.2	0.2
8	0	2.0	0	0	0	0	0.6	97.2	0	0.2
9	0	2.8	1.2	2.0	0	8.8	0	2.0	80.8	2.4
10	0	0	0	3.6	1.2	0.8	0	3.4	0	91.0



図 9 教師あり学習でカテゴリ 9 をカテゴリ 6 に誤認識したサンプル画像

表 6 カテゴリ 1~10 に対応付けられたニューロンの集合（クラスター）の標準偏差

	カテゴリ番号	1	2	3	4	5	6	7	8	9	10
実験 1	教師なし学習	5.50	6.83	4.74	4.99	6.05	-	-	-	-	-
	教師あり学習	5.22	5.38	4.99	4.76	5.70	-	-	-	-	-
実験 2	教師なし学習	8.64	8.11	2.78	2.99	2.96	5.14	4.42	18.7	2.90	2.71
	教師あり学習	2.32	2.31	2.16	2.00	2.47	1.14	20.5	4.16	1.65	3.13

学習を行った場合は、まだ十分にニューロンの数が足りていたことになる。これは、同じ学習データ量を学習する上で、ネットワークサイズを縮小できるという利点にも繋がる。

5. おわりに

本論文では、階層型自己組織化マップとネオコグニトロンとを統合した画像認識モデルであるハイパーコラムモデルにおける教師あり学習法を提案した。教師あり学習を導入することにより、従来の教師なし学習による HCM よりも高い認識率が得られた。更に学習するカテゴリの数が増えた場合にも、教師あり学習のほうが、教師なし学習に必要なニューロンの数よりも少なく済むという考察が得られた。以上のことから、HCM に教師あり学習を導入することは、認識率の向上とニューロン資源の節約という二つの効果をもたらされることが明らかとなった。今後の課題としては、更にカテゴリの数が増えたときにネットワークの構成を自動的に変更することや、追加学習が可能なモデルへ拡張することなどが挙げられる。

文 献

- [1] 鶴田直之, 谷口倫一郎, 雨宮真人. “ハイパーコラムモデル: 階層化自己組織化マップとネオコグニトロンを統合した画像認識モデル”. 電子情報通信学会論文誌 J81-D-II/10, pp. 2288-2300, 1998.
- [2] J. Lampinen and E. Oja. “clustering properties of hierarchical self-organizing maps”. *Journal of Mathematical Imaging and Vision*, Vol. 2, No. 3, pp. 261-272, 1992.
- [3] 福島邦彦. “位置ずれに影響されないパターン認識機構の神経回路モデル-ネオコグニトロン”. 信学論 (A), Vol. J62-A, No. 10,

pp. 658-665, 1979.

- [4] K. Fukushima. “neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”. *Biological Cybernetics*, Vol. 36, No. 4, pp. 193-202, 1980.
- [5] T. Kohonen. “self-organization and associative memory”. *Springer-Verlag*, 1989.
- [6] T. Kohonen. “self-organizing maps”. *Springer Series in Information Science*, 1995.
- [7] 大野通広, 岡田真人, 福島邦彦. “ネオコグニトロンの誤差逆伝播法による学習”. 電子情報通信学会 信学技法 NC92-108, pp. 105-112, 1993.
- [8] Ichiki H., Hagiwara M, and Nakagawa M. “kohonen feature maps as a supervised learning machine”. *Proc. of International Conference on Neural Networks*, pp. 1944-1948, March 1993.