

Sparse Code Learning in Hyper-Column Model to Enhance Reconstructed Image Quality

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

<http://hdl.handle.net/2324/5947>

出版情報 : 画像の認識・理解シンポジウム, pp.489-494, 2006-07
バージョン :
権利関係 :



ハイパーコラムモデルの選択的注意機構における 再構成画像の精度向上のためのスパースコード学習

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

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

あらまし 人工神経回路網ハイパーコラムモデル(HCM)におけるスパースコード学習法を提案する。HCM内のハイパーコラム間に興奮性結合を持たせることで、学習時に各ハイパーコラムで活性化するニューロンの組み合わせを学習することができる。認識時は、興奮性結合により活性化するニューロンに制約を設け、学習時と似た活性化パターンを作り出すことが可能である。HCMの選択的注意機構で再構成する画像は、ハイパーコラムの受容野が小さいほど精度は高い一方で認識率が低下してしまう問題があったが、興奮性結合を用いることで認識率の低下を抑えることができることが実験により明らかになった。

キーワード パターン認識, 人工神経回路網, 対象物体の切り出し, 選択的注意機構, 逐次的画像認識

Sparse Code Learning in Hyper-Column Model to Enhance Reconstructed Image Quality

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

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

Abstract In this paper, we propose a new learning method with excitatory lateral connections. HCM can learn patterns of winner neurons which are activated in each HSOM by updating the excitatory connections, which improves the recognition accuracy. In recognition phase, HCM imposes constraints on the neurons which are activated in each HSOM by using the excitatory connections. We call this learning method “Sparse Code Learning” from the viewpoint that an entire activation pattern is described as multiple neurons. Excitatory lateral connections solve a problem that as a receptive field of a hyper column becomes smaller, the quality of reconstructed images are better, but the recognition accuracy drops down.

Key words Pattern recognition, Artificial neural networks, Object segmentation, Selective attention, Sequential image recognition

1. はじめに

近年、カテゴリの抽象度が高く、かつシーンが複雑な分野へ、画像認識を応用しようとする要求が強まってきており、逐次的画像認識は一般的なシーンでの応用を考えたときには欠かせない問題である。人工神経回路網の中には、選択的注意機構を有するモデルがいくつか存在し、逐次的画像認識に应用することができる。選択的注意とは、目的に応じて能動的に入力情報を取捨選択するための機構である。選択的な注意を働か

せるためには、人工神経回路網の中を流れるボトムアップの信号とトップダウンの信号の相互作用が必要不可欠である。例えば、多層パーセプトロンにおける選択的注意は、学習に用いる誤差逆伝播法の原理をそのまま利用し、結合荷重を更新する代わりにニューロンの活性値を修正することで、任意のカテゴリに属するパターンを1つ想起させることができる[1],[2]。また、ネオコグニトロン(Neocognitron:NC)は一旦画像を認識しておいて、その時の最上位層における最大活性化ニューロンに対応したパターンを再生している[3],[4]。上位の層から下位

の層へトップダウンに最大活性化ニューロンを辿り、最大活性化ニューロンの結合荷重をそのまま再生パターンとしてみなせばよい。しかしながら、ネオコグニロンでの選択的注意は、予め対象の切り出しが適切に行われていることが前提としているため、複雑背景下に対象物が存在している場合などには、認識能力が不十分なためパターンの再生がうまくできない。

一方で、鶴田らが提案しているハイパーコラムモデル (Hyper-Column Model: HCM) は、NC の特徴抽出層と位置ずれ吸収層を、階層型自己組織化マップ (Hierarchical Self-Organizing Map: HSOM) [5] で置き換えたモデルであり、NC と同様に選択的注意機構を備えている [6], [7]。HCM と NC の決定的な違いは、HSOM の自己組織化能力および特徴空間の再量子化能力を利用することで、各層で学習する特徴を「自動的に」学習することができるという点である。NC は、各層がどのような特徴抽出を行うべきかの学習データを人手で作成する必要があり、一般性に欠けていた。さらに、特徴空間の再量子化が行われず、対象の変形に関する十分な次元の縮小が行われていない。また、HCM は選択的注意についても工夫がなされている。対象物の内部領域のみからなる対象物モデルを記憶しているため、複雑背景下に対象物が存在していても、その対象物だけに注意を向けることが可能である。また、複数の対象物が存在している場合は、1 つの物体の認識が終了した後に選択的注意機構を用いて対象領域を切り出し、切り出した対象領域を排除して残りの背景部分を新たな認識のための入力とすることで逐次的な認識を行っている。

鶴田らの手法では、逐次的画像認識を行う上で、選択的注意機構を用いて先に認識した対象領域の画像を再構成し、その領域を次の認識対象から除外している。このときに再構成される画像の精度が高いほど、対象領域の切り出し精度は向上する。鶴田らによれば、再構成画像の精度は HCM の下位の層と上位の層の特徴統合率に大きく依存し、特徴統合率が高いほど精度も向上することと、再構成画像の精度と認識率はトレードオフの関係があることが報告されている [8]。

我々は、HCM を用いた逐次的画像認識の研究を行なっている。我々がこれまでに行なった実験で、再構成画像の精度は特徴統合率以外に、HCM 内のハイパーコラムが持つ受容野の大きさにも依存することがわかった。また、ハイパーコラムの受容野が小さいほど再構成画像の精度は向上するが、認識率が低下してしまうという関係が明らかになった。そこで、本稿では HCM の学習にスパースコード学習という新たな学習法を導入し、再構成画像の精度を保ちつつ、認識率を向上させる方法を提案する。スパースコード学習とは、HCM の各コラムから最大活性化ニューロンとして発火する組み合わせを、コラム間に設けた興奮性結合で記憶するための学習法である。ハイパーコラムの受容野が小さいときに誤認識する主な原因として、受容野から得られる信号の情報量が小さいために、カテゴリの特徴を捉えた密な特徴空間を作成できないことが挙げられる。スパースコード学習により、最大活性化ニューロンの組み合わせを記憶しておくことは、このような疎な特徴空間を持つ特徴マップから誤って活性化してしまうニューロンを抑制する働き

があるため、受容野が小さい状態であっても認識率の向上が期待できる。以下では、2 章で HCM とその学習法ならびに選択的注意による再構成画像の生成法について述べる。また、3 章では HCM のスパースコード学習法を紹介する。4 章では、コラム間に設けた興奮性結合が再構成画像を生成するに当たって効果的であることを実験の結果とともに示す。

2. ハイパーコラムモデル (HCM)

2.1 階層型自己組織化マップ (HSOM) とネオコグニロン (NC)

HSOM は、図 1 に示すように、自己組織化マップ (Self-Organizing Map: SOM) [9] を 2 つ重ねた多層の人工神経回路網である。入力層の入力ベクトル I はマップ第 1 層のニューロン ($1 \cdots u \cdots N$) 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。

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

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

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。

マップ第 2 層のニューロン ($1 \cdots v \cdots M$) は、マップ第 1 層と結合を持ち、マップ第 1 層のニューロンの“添え字”がマップ第 2 層の入力となる。マップ第 2 層のニューロンの数 M はマップ第 1 層のニューロンの数 N に比べ非常に小さいものとなっているため、マップ第 1 層で抽出された特徴が少数のニューロンにより再量子化される。

NC は、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 [10], [11]。HSOM 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 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、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。

2.2 HCM の構造

HCM は、HSOM と NC を統合したモデルで、その構造は、




図 1 HSOM の構造

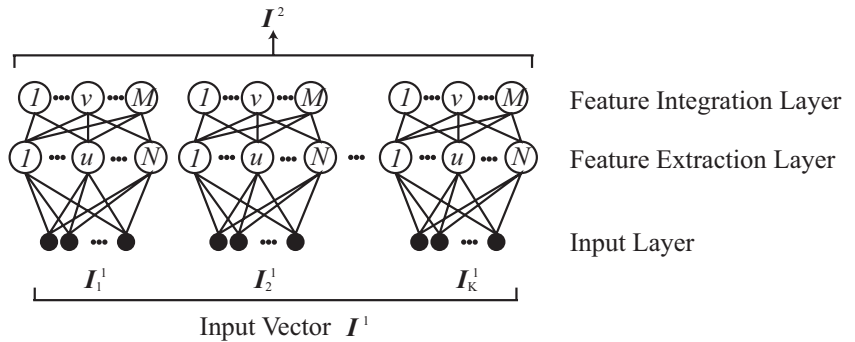


図 2 HCM 内に配置された HSOM ネットワーク

図 2 に示すように HSOM 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。1 つの HSOM の第 1 層（特徴抽出層）の入力領域も NC と同様に、図 2 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。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、HSOM 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。

2.3 学習法

HCM の学習データは背景は除去された状態（画素値を 0 とする）の画像を用いている。HCM は下位の層から上位の層へと順々にコラムで自己組織化学習を進めていく。複雑背景下での認識に対応するために学習データの背景領域の扱いを次のようにしている。

(1) ハイパーコラムの受容野の中心が背景である場合は、全ての特徴抽出ニューロンの活性値を 0 にする。このようなハイパーコラムの状態を BB 状態と呼ぶ。この学習により背景領域に対応するハイパーコラムが BB 状態にあるような対象物モデルが形成できる。

(2) 一旦学習を終えた特徴抽出ニューロンの結合係数が十分に 0 に近い閾値よりも小さい時、全ての係数を 0 とする。この追加手続きにより、対象物の輪郭付近では、背景と対象領域の両方を含む特徴抽出が可能となる。

2.4 認識法ならびに選択的注意機構

入力画像と HCM 内の対象物モデルとの照合が対象領域の内部に対してのみ行なわれるようにする。すなわち、BB 状態にあるコラムと入力データとの照合を行なわない。従って、入力側と結合係数側が共に BB 状態でないときのみ、以下の類似度 U を用いて両者の照合を行う。

$$U = 1 - \frac{\left(\sum_{I \neq BB} \mathbf{W}_{\neq BB} (\mathbf{I} - \mathbf{W})^2\right)^{1/2}}{\sqrt{L}} \quad (4)$$

ここで、 L は BB 状態でないニューロンの数である。

HCM における選択的注意機構は、NC の場合と同様に上位の層から下位の層へトップダウンに最大活性化ニューロンを辿

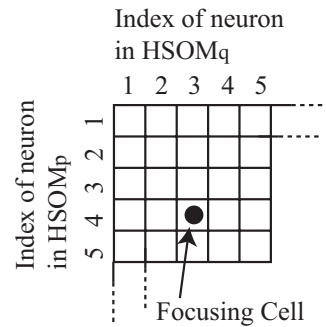


図 3 HSOM_p, HSOM_q 間のニューロンの結合テーブル

ることで達成される。ただし、BB 状態にあるニューロンもしくはハイパーコラムについては、下層のハイパーコラムも BB 状態とする。これにより、現在認識している対象領域以外の部分を背景として BB 状態にした画像が生成される。

3. スパースコード学習

HCM 内のハイパーコラム (HSOM) は、各々が入力層との結合しか持っていない。そのため、認識時は個々の HSOM の受容野からの入力信号だけを参考にして活性化するニューロンが決定されてしまう。そのため、ハイパーコラムの受容野が小さく、入力データから十分な情報を得ることができない場合は、HSOM から活性化するニューロンに誤りが生じてしまう。そこで、我々はこの問題を解決する新たな学習法を提案する。ハイパーコラム間に新たに興奮性結合を導入することで、これまでのように入力層との結合のみではなく HSOM 間の結合も考える。学習フェーズでは、HCM はこれらの興奮性結合を用いて各 HSOM から活性化するニューロンの組み合わせを学習する。ある HSOM からひとつのニューロンが活性化したときにその他の HSOM からどのようなニューロンが活性化したかという全体的な活性化パターンを記憶することができる。認識フェーズでは、興奮性結合を用いて各 HSOM から活性化するニューロンに制約を設けることで、HSOM 全体の活性化パターンを学習時の活性化パターンに近づけることができるようになる。このように各 HSOM からひとつだけ活性化するニューロンの全体の組み合わせを学習するという観点から、提案する学習法を「スパースコード学習」と呼ぶことにする。以下では、スパースコード学習の設計、学習法、認識法について述べる。

3.1 設 計

HCM に配置された HSOM の数を H とする．このとき，新たに作成される興奮性結合の数 M は以下の式で表される．

$$M = {}_H C_2 \times N^2 = \frac{H(H-1)}{2} \times N^2 \quad (5)$$

ここで， N は HSOM 内のニューロンの数である．例えば， $H = 400$ で各 HSOM 内に 100 個のニューロンが存在する場合，新たに作成される興奮性結合の数は $M \approx 8 \times 10^8$ となる．同条件下での入力層との結合数は約 1×10^6 であるため， 8×10^8 という結合数は非常に莫大なものである．そこで，結合数を削減することを考える．上記の方法は，ある HSOM 内のニューロンに対して，その他の全ての HSOM 内のニューロンとの間に結合を設けている．これを小グループに分割された HSOM 内で考えると結合数を削減することができる．実際に小グループ数を G ，小グループ内の HSOM の数を H' とすると，興奮性結合の数 M は以下の式で表される．

$$M = {}_{H'} C_2 \times G \times N^2 = \frac{H'(H'-1)}{2} \times G \times N^2 \quad (6)$$

先ほどの例では，グループ数 G を 16 としたとき， $M \approx 5 \times 10^7$ となり約 94% の結合数を削減することができる．

3.2 学 習 法

ここでは，スパースコード学習法について述べる．2 つの HSOM (HSOM_p and HSOM_q ($1 \cdots p, q \cdots H'$ and $p < q$)) 間の結合を図 3 の結合テーブルを用いて表すことにする．例えば，同図中の黒丸が描かれたセルは， HSOM_p の 4 番目のニューロンと HSOM_q の 3 番目のニューロン間の結合を表すことになる．以下， HSOM_p の i 番目のニューロンと HSOM_q の j 番目のニューロン間の結合を $\mathcal{W}_{i,j}^{p,q}$ と書き表すことにする．

全 HSOM で従来の自己組織化の学習終了後，各 HSOM で学習データに対する勝利ニューロンが活性化される．学習データ k に対して HSOM_p で活性化したニューロンを w_p^k ， HSOM_q で活性化したニューロンを w_q^k とするとき，興奮性結合 $\mathcal{W}_{w_p^k, w_q^k}^{p,q}$ の結合係数を更新する．このとき活性化ニューロン w_p^k, w_q^k の近傍の興奮性結合の結合係数も以下の式で更新する．

$$\mathcal{W}_{w_p^k, w_q^k}^{p,q} = \mathcal{W}_{w_p^k, w_q^k}^{p,q} + \beta \cdot \exp\left(-\frac{D^2}{2\sigma^2(t)}\right) \quad (7)$$

ここで， D は w_p^k と w_q^k からの距離である．以下に学習法の疑似コードを示す．学習前に全ての $\mathcal{W}_{i,j}^{p,q}$ は 0 に初期化されているものとする．また， K は学習データの数を表す．

```

1: for  $g = 1$  to  $K$  do
2:   for  $k = 1$  to  $G$  do
3:     for all  $p, q$  such that  $p < q$  and  $p, q < H'$  do
4:       Weights are Updated by Eq. (7)
5:     end for
6:   end for
7: end for

```

上記学習後，全ての興奮性結合の結合係数はシグモイド関数により最大値 1，最小値 0 に正規化される．

$$\mathcal{W}_{i,j}^{p,q} = \frac{1}{1 + \exp(\theta - \mathcal{W}_{i,j}^{p,q})} \quad (8)$$

ここで， θ は活性化を決定するための閾値である． θ が大きくなるにつれて，高い活性化を持つ興奮性結合の数は減少する．

3.3 認 識 法

ここでは，スパースコード学習結果を用いた認識法について述べる．テストデータ k に対して，各 HSOM から活性化したニューロンはあらかじめ求まっているものとする．このとき，小グループ内でテストデータ k に対する活性化 S_k を以下の式で定義する．

$$S_k = \frac{\sum_{p,q(p < q)}^{H'} \mathcal{W}_{w_p^k, w_q^k}^{p,q}}{U} \quad (9)$$

ここで， U は小グループ内の HSOM の組み合わせ数である．活性化 S_k が大きいほど，小グループ内で活性化しているニューロンのパターンは学習時のものに似ていることになる．活性化 S_k が小さい場合は， $\mathcal{W}_{w_p^k, w_q^k}^{p,q}$ よりも高い活性化を持つ興奮性結合を探す．これは，図 3 の注目セルをシフトさせることと等価である．高い活性化を持つ興奮性結合が見つかった場合，HCM は活性化しているニューロンのラベルを強制的に書き換える．例えば，図 3 で注目セルをひとつ右にシフトさせた場合，活性化ニューロンのラベルは 3 から 4 に変更される．以下に認識法の疑似コードを示す．

```

1: for  $g = 1$  to  $K$  do
2:   for  $k = 1$  to  $G$  do
3:     Activation Value  $S_k$  is Calculated by Eq. (9)
4:     while  $S_k < TH_s$  and  $Area < TH_a$  do
5:       Search Neighbor Connection
6:       if Found Larger Activation Value then
7:         Change Index of Winner Neuron
8:         Recalculate  $S_k$ 
9:       end if
10:       $Area \leftarrow Area + offset$ 
11:    end while
12:   end for
13: end for

```

ここで， $Area$ は探索範囲， TH_s は活性化 S_k に対する閾値， TH_a は $Area$ に対する閾値である．

選択的注意機構を用いて再構成画像を生成する際には，興奮性結合を参照して活性化ニューロンのラベルが書き換えられた後のニューロンを辿ることとする．

4. 実 験

4.1 目的と方法

HCM 最下位層のハイパーコラムの受容野の大きさと再構成画像の精度およびスパースコード学習による興奮性結合を用いた場合の認識精度の関係を明らかにする．

認識精度だけを考えると受容野は大きい方が，認識率は高くなる．受容野が小さいと，カテゴリの特徴を識別するための十分な情報が得られないため，誤りニューロンが活性化してしま




図 4 実験で用いた手形状画像

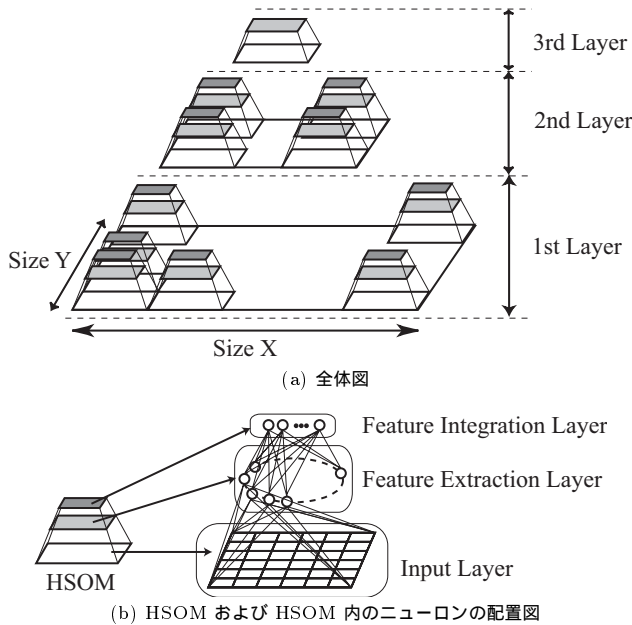


図 5 実験で用いた HCM の構造図および HSOM の詳細図

うことが頻繁に起こり、認識率は低下する。一方、画像の再構成を目的とすれば、受容野が小さいほどニューロンが細かな部分画像を記憶しているため、精度は向上する。そこで、スパースコード学習によるハイパーコラム間の興奮性結合により、誤活性化ニューロンの数を減少させ、高品質な再構成画像が生成できることが可能であるかどうかを調べる。

まず、学習画像として背景部分を除去した手形状画像を用意した。画像のサイズは 100×100 でグレースケール画像を用いた。図 4 に示す 10 種類の手形状画像を各形状毎に 10 枚ずつ用意した。手形状には、ほとんどの部分は同じ形をしているが、指が 1 本だけ突起しているなど局所的に異なっているものがある。このようなカテゴリ個別の特徴とカテゴリ共通の特徴をうまく切り分けた自己組織化学習ができると認識率は向上すると考えられる。

実験に用いた HCM は図 5(a) に示す 3 層のネットワークで、ニューロンの数は HCM 各層の特徴抽出層で 100、特徴統合層で 10 とした。また、HCM の最上位層には HSOM の代わりに SOM を配置している。各層のニューロンは 1 次元上に配置され、特に、特徴抽出層のニューロンは図 5(b) に示すように環状に配置した。ハイパーコラムの受容野の大きさは、 3×3 (HCM1)、 5×5 (HCM2)、 7×7 (HCM3) と変化した 3 つのタイプの HCM を用いた。スパースコード学習は、HCM 最下位層の特徴抽出層でのみ適用し、HCM1、HCM2、HCM3



図 6 データ C のサンプル：背景が除去されていない画像

での小グループ数 G (3.1 節参照) はそれぞれ、36、16、9 とした。認識精度および再構成画像の精度を検証するために、学習に用いた画像 100 枚 (データ A)、背景が除去された未学習画像 100 枚 (データ B)、図 6 に示す背景が除去されていない未学習画像 100 枚 (データ C) の計 300 枚を用いた。学習後の HCM を用いて、原画像 $I(x, y)$ から画像 $I'(x, y)$ を再構成し、その精度を以下の歪みエネルギー E を用いて評価する。

$$E = 10 \log_{10} \frac{\sum (I'(x, y) - I(x, y))^2}{\sum I(x, y)^2} \quad (10)$$

歪みエネルギーの値が小さいほど精度が良いことになる。

背景を含んだ検証画像 (データ C) については、原画像中の対象領域の面積 S_1 に対する再構成画像との不一致領域の面積 S_2 との比 $S = S_2/S_1$ についても評価する。 S の値が小さいほど原画像に近い画像を再構成できたことになる。

4.2 結果

3 つの HCM によるテスト画像に対する認識率は、ハイパーコラム間の興奮性結合を用いなかった場合と用いた場合それぞれ表 1、2 のようになった。HCM は学習時に最上位層の SOM の 1 つのニューロンが 2 つ以上のカテゴリに対して活性化しなければ、学習データに対しては 100% の認識率を誇る。背景が除去された未学習画像 (データ B) ならびに背景が除去されていない未学習画像 (データ C) に対しては、興奮性結合を用いる方が認識率は向上し、さらに受容野が小さいほどその伸び率は高かった。

表 1 興奮性結合を用いないときの受容野の大きさと認識率の関係

受容野 \ データ	データ A	データ B	データ C
HCM1	100%	79%	64%
HCM2	100%	80%	72%
HCM3	100%	84%	77%

表 2 興奮性結合を用いたときの受容野の大きさと認識率の関係

受容野 \ データ	データ A	データ B	データ C
HCM1	100%	84%	71%
HCM2	100%	82%	74%
HCM3	100%	84%	79%

次に、原画像と再構成画像の歪みエネルギーを計算した結果を表 3、4 に示す。学習画像 (データ A) に対する歪みエネルギーは、興奮性結合の有無によらず同じ値であった。これは、興奮性結合を用いても活性化ニューロンが変更されなかったことを意味している。また、データ B、データ C に関しては、興奮性結合を用いると若干ではあるが歪みエネルギーの値が大きくなっている。これは、本来であればハイパーコラムが受容す




図 7 データ C の再構成画像

る部分画像と一番良く似た部分画像を記憶しているニューロン（ベストマッチニューロン）が選ばれていたのに対して、興奮性結合を用いることで、それには近いが類似度ではベストマッチニューロンには劣るニューロンが選択されるようになったことが原因と考えられる。また、データ C に対して $S = S_2/S_1$ を計算したところ、HCM1 の場合が 0.23、HCM2 の場合が 0.28、HCM3 の場合が 0.31 であった。この値は、興奮性結合の有無にかかわらず同値であった。受容野が大きくなるにつれて S の値も大きくなっていることから、受容野が大きいほど精度は低いと言える。

表 3 興奮性結合を用いないときの受容野の大きさと再構成画像の精度の関係：数値は歪みエネルギーの平均 (dB)

受容野 \ データ	データ A	データ B	データ C
HCM1	-15.55	-12.55	-14.02
HCM2	-13.74	-10.63	-11.95
HCM3	-12.17	-9.21	-10.89

表 4 興奮性結合を用いたときの受容野の大きさと再構成画像の精度の関係：数値は歪みエネルギーの平均 (dB)

受容野 \ データ	データ A	データ B	データ C
HCM1	-15.55	-12.26	-13.89
HCM2	-13.74	-9.52	-11.27
HCM3	-12.17	-8.93	-9.92

4.3 考 察

受容野が大きいほど認識率が高いが再構成画像の精度は低下することが明らかになった。精度の低下は、図 7 を見ても明らかである。精度という点では HCM1 が最も良いが、どの HCM においても背景が含まれた画像（データ C）に対して対象領域を切り出すことはできている。また、認識率については HCM1 が最も低かったが、提案手法の興奮性結合を用いることで、認識率を引き上げることができた。以上のことから、「ハイパーコラム間に興奮性結合を設けることで、再構成画像を高精度化するために受容野を小さくしても認識率の急激な低下を抑えることができる」と言える。

5. おわりに

本稿では、人工神経回路網ハイパーコラムモデル (HCM) にスパースコード学習という新たな学習法を提案した。HCM 内のハイパーコラム間に興奮性結合を設けることで、学習データに対して各ハイパーコラムから活性化するニューロンの組み合わせを学習することができる。これまではハイパーコラムの受

容野が小さくなるにつれて認識精度が低下していたが、興奮性結合を用いることで、認識率を低下を抑えることができた。選択的注意機構により、画像を再構成する際には、受容野は小さいほど精度は向上するため、スパースコード学習は有効な学習法であることが確認できた。今後は、実時間処理への対応や逐次的画像認識の検討を行なう予定である。

謝 辞

本研究の一部は、文部科学省 21 世紀 COE プログラム「システム情報科学での社会基盤システム形成（九州大学大学院システム情報科研究院）」における平成 17 年度若手研究者助成「画像認識のための汎化能力と分化能力を兼ね備えた人工神経回路網に関する研究」の補助を受けた。

文 献

- [1] 山田敬嗣, 天満勉. “多層ニューラルネットによる意識の想起方法と想起学習の検討”. 電子情報通信学会 信学技法 NC90-22, pp. 69-76, 1990.
- [2] K. Yamada. “Learning of category boundaries based on inverse recall by multilayer neural network”. *International Joint Conference on Neural Networks (IJCNN)*, Vol. 2, pp. 7-12, 1991.
- [3] 福島邦彦. “視覚パターン認識における選択的注意機構の神経回路モデル”. 信学論, Vol. J69-D, No. 6, pp. 993-1003, 1989.
- [4] K. Fukushima. “A neural network model for selective attention in visual pattern recognition”. *Biological Cybernetics*, Vol. 55, No. 1, pp. 5-15, 1986.
- [5] 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.
- [6] 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.
- [7] Naoyuki Tsuruta, Rin-ichiro Taniguchi, and Makoto Amamiya. “Hypercolumn Model: A Combination Model of Hierarchical Self-Organizing Maps and Neocognitron for Image Recognition”. *Systems and Computers in Japan*, Vol. 31, No. 2, pp. 49-61, 2000.
- [8] Naoyuki Tsuruta, Rin-ichiro Taniguchi, and Makoto Amamiya. “Image Reconstruction Using High-Level Constraints”. *13th International Conference on Pattern Recognition (ICPR'96)*, Vol. 4, pp. 401-405, 1996.
- [9] T. Kohonen. “Self-Organizing Maps”. *Springer Series in Information Science*, 1995.
- [10] 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.
- [11] 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.