



Title	ネオコグニトロンの認識能力の拡張に関する研究 : 高感度S細胞の提案
Author(s)	畠山, 康博; Hatakeyama, Yasuhiro; 嘉数, 侑昇 他
Citation	北海道大學工学部研究報告, 155, 61-71
Issue Date	1991-05-24
Doc URL	<a href="https://hdl.handle.net/2115/42282">https://hdl.handle.net/2115/42282</a>
Type	departmental bulletin paper
File Information	155_61-72.pdf



## ネオコグニトロンの認識能力の拡張に関する研究 —— 高感度 S 細胞の提案 ——

畠山 康博 嘉数 侑昇

(平成 2 年 12 月 22 日受理)

### Expansion of the Ability of the Neocognitron in Pattern Recognition —— Constructing a Highly Sensitive S-cell ——

Yasuhiro HATAKEYAMA and Yukinori KAKAZU

(Received December 22, 1990)

#### Abstract

The purpose of this study is to improve the pattern recognition ability of the Neocognitron. Since, in the Neocognitron system, local feature detection (S-cell) seems to play an important role in pattern recognition, how to construct a highly sensitive S-cell is regarded as one of the major problems of improving the ability of pattern recognition of it. For this purpose, properties of the conventional S-cell are revealed by experimental analyses. From the results, the highly sensitive S-cell is proposed as the new one. The performance of feature detection of the proposed S-cell is compared with that of the conventional S-cell, which shows the effectiveness of the proposed one. The experimental results of recognizing patterns of arabic numerals show that the performance of the system which adopts the highly sensitive S-cell is better than that of the conventional S-cell.

#### 1. 緒 言

ネオコグニトロンはパターン認識のための階層型ニューラルネットワークであり、位置ずれ・変形パターンに対する高い認識能力については福島らの研究<sup>1)2)</sup>によって広く知られている。しかし、その認識能力に関する特性については未知のところが多いのが実状であり、認識過程における細胞モデルの挙動やネットワーク全体の認識能力についての解析は他のニューラルネットに比べてその研究は少ないように思われる。

著者らの研究目標は、ネオコグニトロンのネットワーク全体におけるパターン処理の数理的メカニズムを明らかにしつつ、認識能力の向上、さらには認識能力の拡張を試みることにある。

基本的にはネオコグニトロンは階層構造を成しており、パターン処理はフィードフォワードに行われる<sup>3)</sup>。フィードバック経路をもち連想機能を加えたネオコグニトロン<sup>1)</sup>もあるが、ここではフィードフォワードのみで構成されるタイプのネオコグニトロンをとりあげ、基本的なネオコグニトロンの認識能力の解析に焦点を定める。

ネットワーク構成上、ネオコグニトロンが他のニューラルネットワークと根本的に異なっている特徴は、層間における素子の結合が全結合ではなくて局所的である点である。ここでは、局所的処理における素子の数理モデルをベクトル演算によって表現し、その解析がすすめられている。

素子には特徴抽出機能を有するS細胞とほけの作用を持つC細胞がある。特に、学習により可塑性を持つS細胞はパターン認識における要として非常に重要なものであり、本研究では、S細胞についての性能解析を行う。この解析結果はS細胞の特徴抽出としての性質が多くのパラメータに依存して非常に不安定であることを明らかにしている。これはS細胞の解析で考慮されていなかった細胞モデルへのバイアスに起因する。そこで、バイアスについて考慮した高感度S細胞を提案する<sup>4)</sup>。この高感度S細胞の性質はパラメータに依存しない安定したもので、高感度S細胞を用いることで学習効率・認識能力が向上することを実験的に示す。また実際の数字データ認識において従来型S細胞を用いた場合と認識能力の比較・検証を行う。

## 2. 局所的パターン処理の数理モデル

ネオコグニトロンの各層は複数の面からなり、各面はある特定の特徴に反応する素子集合から形成されている。素子は前層に対し各面に結合を持つが、このとき結合は局所領域に限られる。素子の受容野としての局所領域を決めるために素子集合には距離Dが必要であり、一般に、素子集合を $U \subset \mathbf{R}^n$ とし、第 $\ell$ 層を $(U_1^\ell, \dots, U_{K_\ell}^\ell)$ と表すことができる。ただし、以下では $U$ を有限かつ離散な素子集合として扱う。また、 $K_\ell$ は $\ell$ 層を構成する面の数であり、2次元パターンの認識であれば $U$ は2次元となる。よって $\ell$ 層の素子 $u^\ell$ は、

$$u^\ell = (\mathbf{x}, k)_\ell, \mathbf{x} \in U_k^\ell, 1 \leq k \leq K_\ell \quad (1)$$

と表され、パターンは状態値 $f(u^\ell)$ によって表現される。

以下、S細胞、C細胞の数理モデルをベクトル表現を用いて記述していく。

### 2.1 ベクトル表現の導入

素子 $u^\ell$ は $\ell-1$ 層の各面の $u^{\ell-1}$ に対応する局所領域から入力を得る。 $\ell-1$ 層の $k$ 面で、実数 $\nu_\ell$ によって定まる局所的パターンは、適当な順序付けにより特徴ベクトル $\mathbf{p}_k$ として、

$$\mathbf{p}_k = (f(u_{i_1}^{\ell-1}), \dots, f(u_{i_2}^{\ell-1}), \dots, f(u_{j_1}^{\ell-1}), \dots, f(u_{m_1}^{\ell-1})), \\ u_{i_1}^{\ell-1}, u_{j_1}^{\ell-1} \in U_k^{\ell-1}, D(\mathbf{x}_i, \mathbf{x}_j) \leq \nu_\ell \quad (2)$$

と表現できる。すなわち、 $\mathbf{p}_k$ は距離 $\nu_\ell$ 内の素子の状態値からなる $m$ 次元ベクトルとなる。

以上、 $\mathbf{p}_k$ を用いて素子 $u^\ell$ に対する入力パターン $\mathbf{P}(u^\ell)$ は(3)式のように $m \times K_{\ell-1}$ 次元ベクトルで表すことができる。

$$\mathbf{P}(u^\ell) = (\mathbf{p}_1, \dots, \mathbf{p}_k, \dots, \mathbf{p}_{K_{\ell-1}}) \in \mathbf{R}^{m \times K_{\ell-1}}, \mathbf{p}_k \in \mathbf{R}^m, 1 \leq k \leq K_{\ell-1}. \quad (3)$$

### 2.2 S細胞・C細胞の数理モデル

S細胞、C細胞は、機能は異なるが入力パターンに対する処理構成は類似している。その概要は図1で示されている。

ここで、二つの $n$ 次元ベクトル $\mathbf{a} = (a_1, \dots, a_n)$ 、 $\mathbf{b} = (b_1, \dots, b_n)$ に対する演算 $(\cdot)$ と $(,)$ を定義しておく。すなわち、 $(\mathbf{a} \cdot \mathbf{b}) = (a_1 \times b_1, \dots, a_n \times b_n)$ 、 $(\mathbf{a}, \mathbf{b}) = a_1 \times b_1 + \dots + a_n \times b_n$ とする。

いま、S細胞 $u = (\mathbf{x}, k)$ の数理モデルを記述する上で、 $u$ への入力パターンを $\mathbf{P} = \mathbf{P}(u)$ とし、 $\mathbf{a}_k$ 、

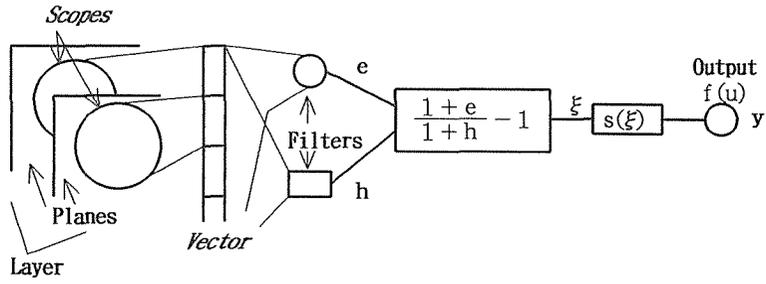


図1 ユニットにおける局所パターン処理

$b_k$ を結合係数とする。また、その閾値は実数 $r$ により設定され、 $\mathbf{P}$ に対する空間的な重み付けとし $\mathbf{g}_s$ を用いる。ここに、 $\mathbf{g}_s$ は各面上の小領域に対する2次元ガウス分布から、 $\mathbf{P}$ と同様に行ベクトルに展開したものである。以下に示す(4)、(5)式はS細胞の初期的処理となる。

$$e_k = (\mathbf{P}, \mathbf{a}_k), \tag{4}$$

$$h_k = (\mathbf{g}_s, (\mathbf{P} \cdot \mathbf{P}))^{1/2} \cdot b_k \cdot r', \tag{5}$$

ただし、 $r' = r/(r+1)$ .

ここで、 $\mathbf{g}_s = (\mathbf{g}'_s \cdot \mathbf{g}'_s)$ となる $\mathbf{g}'_s$ を用いると、(5)式は以下になる。

$$\begin{aligned} h_k &= (\mathbf{g}_s, (\mathbf{P} \cdot \mathbf{P}))^{1/2} \cdot b_k \cdot r' \\ &= ((\mathbf{g}'_s \cdot \mathbf{P}), (\mathbf{g}'_s \cdot \mathbf{P}))^{1/2} \cdot b_k \cdot r' \\ &= \|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot b_k \cdot r'. \end{aligned} \tag{6}$$

すなわち、素子は局所的パターンに対し、 $h_k$ では $\mathbf{g}'_s$ で重み付けされたパターンのノルムに関する量を算出し、 $e_k$ では局所的パターンと結合係数 $\mathbf{a}_k$ の内積を算出している。これらの本質的な意味は結合係数 $\mathbf{a}_k$ 、 $b_k$ の学習について述べるときに明らかとなる。

さらに、S細胞の出力は(7)、(8)、(9)、(10)式より得られる。

$$\xi_k = \frac{1 + e_k}{1 + h_k} - 1, \tag{7}$$

$$s_k = r \cdot \xi_k, \tag{8}$$

$$f(u) = \phi(s_k), \tag{8}$$

$$\phi(z) = \begin{cases} z & ; \text{if } z \geq 0, \\ 0 & ; \text{otherwise.} \end{cases} \tag{10}$$

以上がS細胞の数理モデルである。以下に、C細胞の数理モデルを示す。ただし、 $\mathbf{g}_c$ は $\mathbf{g}_s$ と同様な局所領域に対する重み付けである。

$$e_k = (\mathbf{g}_c, \mathbf{P}^k), \tag{11}$$

$$h_k = (\mathbf{g}_c, \mathbf{P}) \cdot (1/K), \tag{12}$$

$$\text{ここに、} \mathbf{P}^k = (0, \dots, 0, p_k, 0, \dots, 0). \tag{13}$$

$\xi_k, f(u)$ はそれぞれ(7)、(9)式と同一であるが $s_k$ は(14)式となる。

$$s_k = \frac{\xi_k}{\xi_k + 1}. \quad (14)$$

### 2.3 S細胞の特徴抽出能力

S細胞の結合係数の学習は、入力パターン $\mathbf{P}_k$ にしたがって興奮性結合として $\mathbf{a}_k$ が(15)式、抑制性結合として $b_k$ が(16)式で強化される。ただし、 $q$ は学習に関する非負の強化係数である。

$$\Delta \mathbf{a}_k = q \cdot (\mathbf{g}_s \cdot \mathbf{P}_k), \quad (15)$$

$$\begin{aligned} \Delta b_k &= q \cdot (\mathbf{g}_s, (\mathbf{P}_k \cdot \mathbf{P}_k))^{1/2} \\ &= q \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\|. \end{aligned} \quad (16)$$

以下では、競合学習に基づく自己組織化によって形成されるS細胞について考察する。

いま、競合学習の中で $u' = (x, k)$ を最大値検出で得られた学習の対象となった素子とし、 $\mathbf{P}_k$ は $u'$ の入力パターンとする。この面 $k$ について $n$ 回の学習が $\mathbf{P}_k$ のみで行われたとき、すなわち最も理想的な学習が成された場合、興奮性結合 $\mathbf{a}_k$ 、抑制性結合 $b_k$ は、

$$\mathbf{a}_k = n \cdot q \cdot (\mathbf{g}_s \cdot \mathbf{P}_k), \quad (17)$$

$$b_k = n \cdot q \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\|, \quad (18)$$

となる。よって $k$ 面の素子において入力パターン $\mathbf{P}$ に対し(19)、(20)式が得られる。

$$\begin{aligned} e_k &= (\mathbf{P}, \mathbf{a}_k) \\ &= n \cdot q \cdot (\mathbf{P}, (\mathbf{g}_s \cdot \mathbf{P}_k)) \\ &= n \cdot q \cdot ((\mathbf{g}'_s \cdot \mathbf{P}), (\mathbf{g}'_s \cdot \mathbf{P}_k)), \end{aligned} \quad (19)$$

$$\begin{aligned} h_k &= \|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot b_k \cdot r' \\ &= n \cdot q \cdot \|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\| \cdot r'. \end{aligned} \quad (20)$$

以上、学習が十分進んだとして $n \cdot q \gg 1$ と仮定すると $\xi_k$ は以下の式となる。

$$\begin{aligned} \xi_k &\doteq \frac{e_k}{h_k} - 1 = \frac{n \cdot q \cdot ((\mathbf{g}'_s \cdot \mathbf{P}), (\mathbf{g}'_s \cdot \mathbf{P}_k))}{n \cdot q \cdot \|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\| \cdot r'} - 1 \\ &= \frac{1}{r'} \cdot \frac{((\mathbf{g}'_s \cdot \mathbf{P}), (\mathbf{g}'_s \cdot \mathbf{P}_k))}{\|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\|} - 1 \\ &= (1/r') \cdot \delta - 1, \end{aligned} \quad (21)$$

$$\text{ただし, } \delta = \frac{((\mathbf{g}'_s \cdot \mathbf{P}), (\mathbf{g}'_s \cdot \mathbf{P}_k))}{\|(\mathbf{g}'_s \cdot \mathbf{P})\| \cdot \|(\mathbf{g}'_s \cdot \mathbf{P}_k)\|}. \quad (22)$$

さらに、 $s_k$ について(23)式を得る。

$$s_k = r \cdot \xi_k = r \cdot ((1/r') \cdot \delta - 1) = (r+1) \cdot \delta - r. \quad (23)$$

この(23)式より素子の出力値である $f(u)$ は図2のようになる。

以上のようにベクトル表現の導入から、S細胞が学習によって形成されるテンプレートとしての特徴ベクトルと入力ベクトルとのなす角の余弦を算出していることを直接見ることができる。

この時、上述の $n \cdot q \gg 1$ の仮定にあるように $q$ の設定が問題となる。なぜなら、 $\|\mathbf{P}\|$ は未知であり、それを補償する適当な $q$ は事前にはわからないからである。(14)式のようにC細胞の出力は1以

下であり、 $\|(g'_s \cdot P)\|$ は1よりかなり小さくなる。さらに、 $a_k, b_k$ の形成に参与する特徴ベクトル $P_k$ についても $\|P_k\|$ は異なってくる。以下では、 $\|P\|$ のばらつきに対するS細胞の性能に関して考察する。

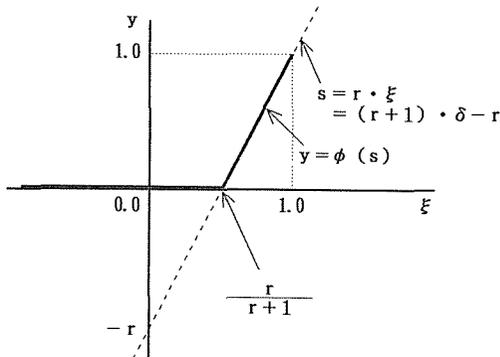


図2 閾値 $r$ におけるS細胞の出力

### 3. S細胞の性能

特徴抽出細胞としてのS細胞は、十分学習が進んだ状態の近似的な、すなわち単純化に基づいたモデルによって解析的に性質が明らかにされている<sup>2),5)</sup>。以下では実験的アプローチによってS細胞の特徴抽出能力についてより詳細な考察を行う。

いま、 $k$ 面上のS細胞 $u$ の出力 $y=f(u)$ を以下のように書く。ただし、入力パターン $S=(g'_s \cdot P)$ 、結合荷重 $T=n \cdot q \cdot (g'_s \cdot P_k)$ とする。

$$y = \phi \left( r \cdot \left( \frac{1 + (S, T)}{1 + r \cdot \|S\| \cdot \|T\|} - 1 \right) \right) \tag{24}$$

テンプレートである $T$ が理想的な学習の下で形成されたならば、 $g'_s$ の各要素の逆数を要素とする $g''_s$ を用いると、

$$\|(g''_s \cdot a_k)\| = b_k, \tag{25}$$

となる。この時、

$$(S, T) = \|S\| \cdot \|T\| \cdot \cos \theta, \tag{26}$$

と書けて、 $\theta$ に関する出力 $y$ の変化をグラフにすると図3のようになる。ここで、S細胞の最大出力はテンプレートのノルムに影響されることがわかる。ネオコグニロンでは競合学習により学習パターンに応じてテンプレートが自己組織化されるので、各テンプレートのノルムは異なってくる。すなわち図3は、各テンプレートの性能の安定性が保証され得ないことを示している。図3点線は閾値 $r$ をパラメータとして出力 $y$ の特性を示しているが、 $r$ に関しても安定した性能が保証されないことを示している。

特徴抽出能力を十分に発揮しない素子の存在は、認識能力を低下させるが、さらに重要なことは学習過程で影響を与えることである。ネオコグニトロンの自己組織化、つまり教師なし学習は最大値検出型のアルゴリズムによるものであり、学習されるべきパターンは最大値として常に検

出されなければならない。図3の結果はこれを保証していない。

さて、上述のようなS細胞の性質は(25)式のようにあくまでも理想的なテンプレートとしてのものであった。実際は、必ずしも(25)式は成立せず。

$$\|(\mathbf{g}'_s \cdot \mathbf{a}_k)\| \leq b_k, \tag{27}$$

となる。これは興奮性結合 $\mathbf{a}_k$ がパターンベクトルの足し込みで、抑制性結合 $b_k$ がそのノルムの足し込みであることによる。

そこで、学習により形成されるテンプレートの性能を表す指標として学習精度Lを以下のように定める。

$$L = \|(\mathbf{g}'_s \cdot \mathbf{a}_k)\| / b_k. \tag{28}$$

完全に学習パターンのみで学習したテンプレートでは $L=1$ である。この学習精度に対する完全一致時の出力 $y$ をグラフにすると図4のようになる。明らかにLの影響は著しい。

以上、S細胞の性能が不安定であることが明らかになった。このことは、教師なし学習の自己組織化の性質から認識能力を低下させる要因となり、ネットワーク構造における素子の不安定な性能は、その構造決定のためパラメータ設定を困難にする。

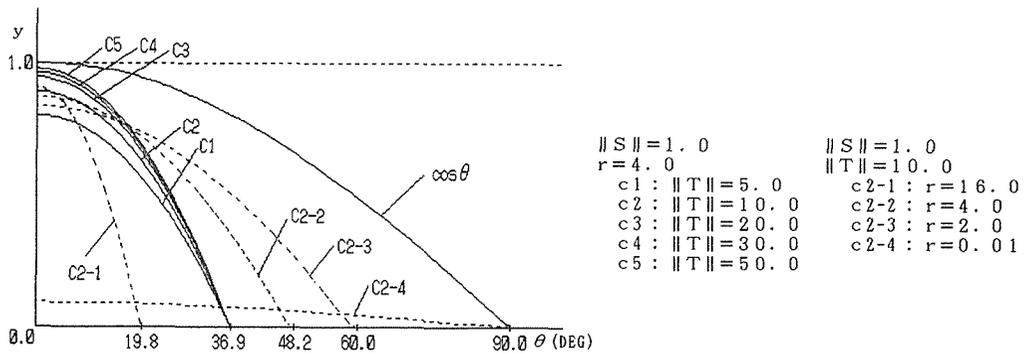


図3  $\theta$ に関するS細胞の出力

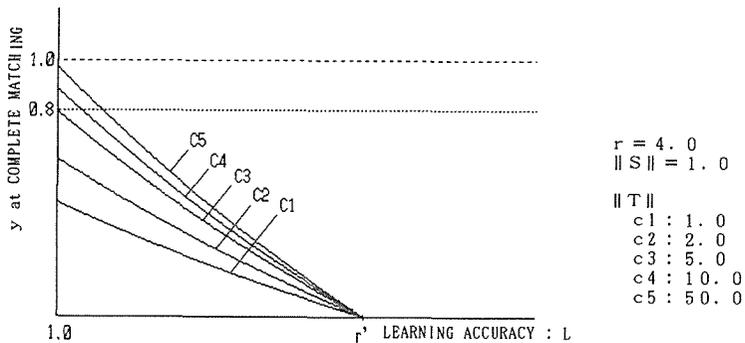


図4 学習精度Lに関するS細胞の出力

### 4. 高感度S細胞の提案

上述のS細胞の不安定な性質を改善するために、完全一致時に安定な出力を実現する高感度S細胞を提案する。着目すべき点は素子へのバイアスとして与えられている(7)式の分母・分子にみられる定数である。このバイアスは入力パターンが0の時でも(7)式が発散しないことを保証しているが、不適切なバイアスでは(21)式は必ずしも成立しない。このようにバイアスの重要性を考慮する点から、以下に示す高感度S細胞を提案する。

$$x_k = \phi \left( r \cdot \left( \frac{\tau + (\mathbf{P}, \mathbf{a}_k)}{\tau + (g_s, (\mathbf{P} \cdot \mathbf{P}))^{1/2} \cdot b_k \cdot r^r} - 1 \right) \right) \tag{29}$$

このモデルでの特徴は、バイアスとしてパラメータ $\tau$ が埋め込まれた点である。図5に $\tau$ の効果が示されている。 $\tau=1$ つまり従来型ではテンプレートのノルムに依存して完全一致時の出力は変化している。 $\tau=0.0001$ の場合には、その立上がりは素早く、テンプレートのノルムが小さなうちで完全一致時の出力は1として得られている。

図6、図7は従来型S細胞の性質を調べたのと同時に高感度S細胞( $\tau=0.0001$ )の性質を調べたものである。これは安定した特徴抽出素子の性能が保証されることを示している。

以下では、高感度S細胞による全体的なパターン認識能力について実験により検証する。

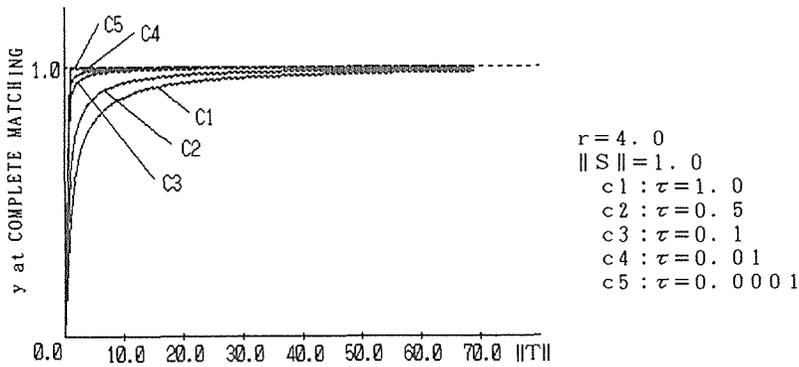


図5  $\tau$ に関する高感度S細胞の安定性

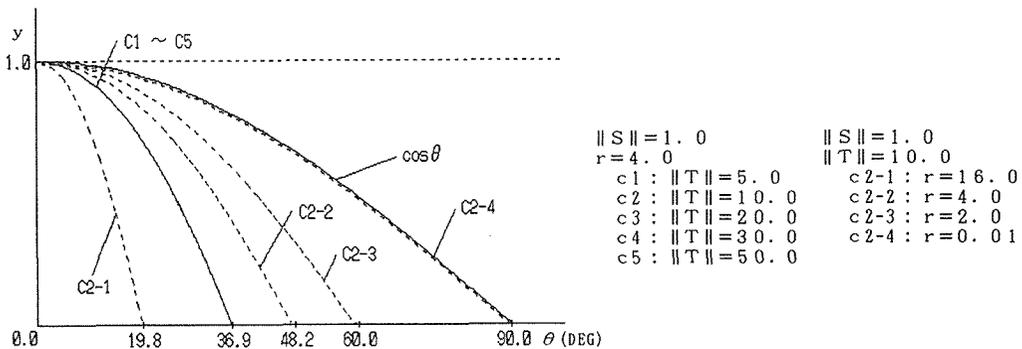


図6  $\theta$ に関する高感度S細胞の出力 ( $\tau=0.0001$ )

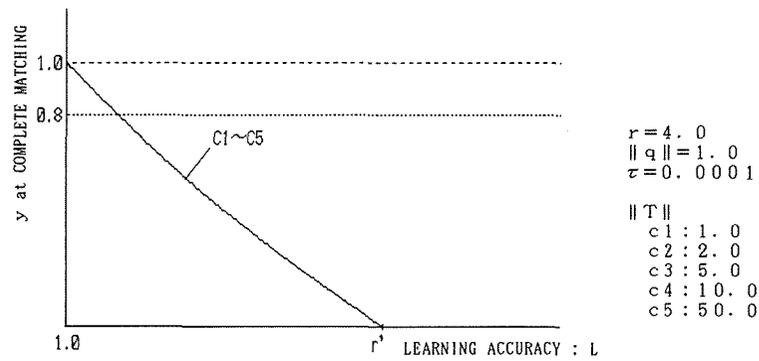


図7 学習精度 $L$ に関する高感度S細胞の出力

## 5. 実験 1

自己組織化によるS細胞の成長について調べるための実験を行った。特徴によらず、最大値検出型の自己組織化に従ったS細胞の学習精度と性能が観察できるように、ランダムパターンの提示による学習とした。ネットワークは $10 \times 10$ の入力面とただ一層のS層のみからなるものとし、学習回数500回のうちでS層においてどれだけの面がどのような学習を行うかを観察した。図8, 図9には自己組織化によって形成された従来型S細胞, 高感度S細胞の学習精度, およびS細胞同士の相関について示してある。

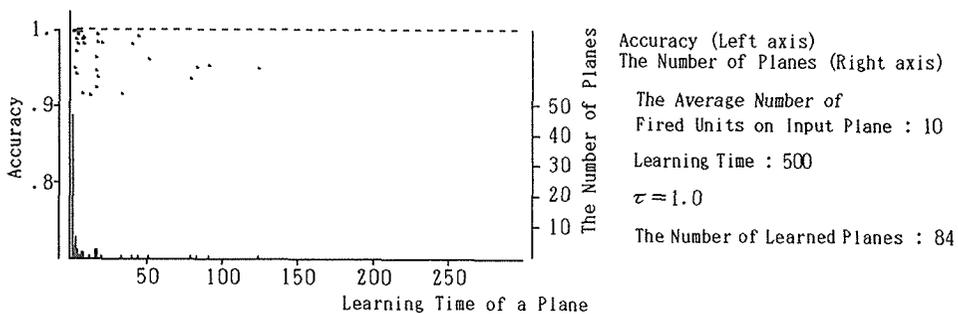
図8, 図9の(a)から, 学習回数が多いものでも学習精度をおとさないテンプレートが高感度S細胞で多く, 面数を比較しても効率的な学習が実現されていることがわかる。一方, 従来型S細胞では, 学習回数1というテンプレートが非常に多く, 非効率的な学習となっている。

学習回数が少ない時に精度が低下しているのは学習強化数 $q$ に依存し, 特に $\|P_k\|$ が小さい時は大きく学習精度に現れてくる。すなわち, 一回の学習における学習精度への影響は学習強化係数 $q$ によって決ってくる。

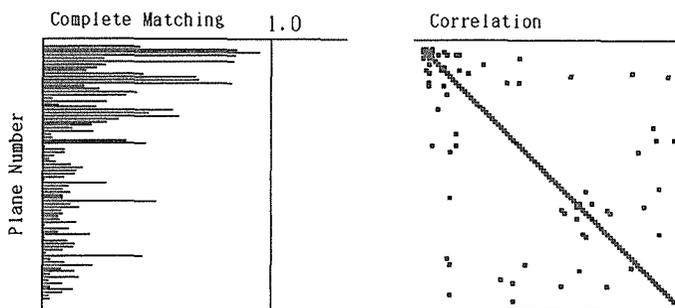
図9(b)は, 高感度S細胞の完全一致時の安定した出力と, 各テンプレートの高い独立性を示している。

## 6. 実験 2

従来型, 高感度S細胞の認識能力の違いを確かめるため, 実際に数字パターンを学習させたネオコグニトロンについて変形パターンに対する認識実験を行った。学習パターンは0, 1, 2, 3, 4の5つの数字パターンとする。これらの数字を認識できるように学習したネオコグニトロンの構造は表1に示したように, 面数について, 従来型S細胞を用いた場合と高感度S細胞を用いた場合で異なってくる。これは従来型S細胞を用いたときの学習効率が高感度S細胞を用いることで改善されたことを意味する。学習終了後のそれぞれのネオコグニトロンの認識結果は, 表2に示してある。高感度S細胞を用いることで, 認識能力の改善が見られた。さらに, 実際の学習を行う時点でパラメータの設定が高感度S細胞を用いた場合, かなり容易となる。なぜなら, 安定した性質を持つ高感度S細胞ではS層全体の出力が従来より落ち込むことがなくなり, 層ごとでばらついた処理にならないからである。

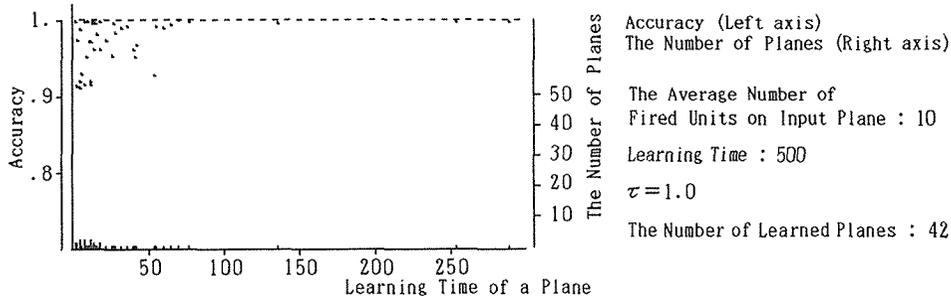


(a) 学習回数に対する学習精度と面数.

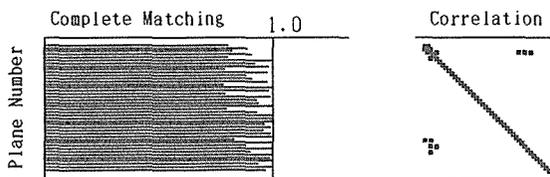


(b) 学習されたテンプレート間の相関.

図8 自己組織化後の従来型S細胞の学習精度



(a) 学習回数に対する学習精度と面数.



(b) 学習されたテンプレート間の相関.

図9 自己組織化後の高感度S細胞の学習精度

表1 5つの数字パターンを学習したネオコグニトロンの構成

層数 層番号	従来型S細胞を用いた場合								高感度S細胞を用いた場合							
	1	2	3	8層		6	7	8	1	2	3	8層		6	7	8
面の 大きさ	3	3	5	3	5	7	9	3	3	3	5	3	5	7	9	3
受容野の 大きさ	3	3	5	3	5	7	9	3	3	3	5	3	5	7	9	3
面数	3	3	12	12	19	19	5	5	3	3	11	11	11	11	5	5

表2 位置ずれ・変形パターンに対する認識結果

パターンの 種類 (パターン数)	従来型S細胞を用いた場合				高感度S細胞を用いた場合			
	正解	誤認識	複数出力	無出力	正解	誤認識	複数出力	無出力
位置ずれ (130)	62	14	4	50	67	13	2	48
欠け (50)	47			3	47			3
ノイズ (50)	50				50			
変形 (50)	37		1	12	38			12
認識率 (%)	70.0	5.0	1.8	23.2	72.1	4.7	0.7	22.5

## 7. 結 言

ネオコグニトロンの高い認識能力は素子の局所的処理によって構成される階層構造によるものである。本研究の目的はフィードフォワードのみの経路を持つネオコグニトロンの認識能力を向上させることであり、ここでは局所的処理、とりわけ特徴抽出能力に着目した。

S細胞は特徴抽出のための素子であり、ここではその数理モデルに関する詳細な性能解析を試みた。これにより、S細胞の性能は学習パターン、閾値、あるいは入力パターン、に影響され非常に不安定な性能であることが明らかになった。不安定な性能は認識能力への影響だけではなく学習精度・効率にも影響が出てくる。

そこでS細胞の数理モデルにたち戻ることにより、バイアスのモデルに対する効果を考慮した高感度S細胞を提案した。これにより、安定な性能を得ることができた。

以上、高感度S細胞における性質の改善を確かめるために実験を行った。まずランダムパターンによるS細胞の自己組織化の実験によって、従来型S細胞では学習精度が悪く特徴抽出能力も低いことを指摘し、高感度S細胞によってそれらの問題点の改善を実現できることを示した。さらに、実際の数字パターンの認識実験によって高感度S細胞の有効性を確かめた。

学習係数 $q$ に関して2.3で簡単に述べているが、S細胞の性能をより深く考察する上で $\tau$ との関係について定性的な解析が必要と考えられる。今回は局所的処理に着目した認識能力の向上を試みたが、今後は、C細胞の機能解析、さらに全体の認識能力をいかに解析できるかという点が課題になる。また、最大値検出のみに頼る学習方法についても、教師信号を用いないで自己組織化を行うときには問題があると考えられるであろう。

#### 参考文献

- 1) 福島邦彦：“神経回路と情報処理”，朝倉書店（1989）。
- 2) Fukushima, K.：“Analysis of the Process of Visual Pattern Recognition by the Neocognitoron”, Neural Networks, Vol. 2, No. 6, pp. 413~420 (1989).
- 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. J. 62-A, Oct., pp. 658—665（1979）。
- 4) 島山康博，嘉数侑昇：“オコグニトロン of 認識能力に関する研究—改良型S細胞の提案—”，平成元年度電気関係学会北海道支部連合大会講演論文集，pp. 318—319（1989）。
- 5) 福島邦彦：“コグニトロン of パターン分離能力の向上”，信学技報，MBE79-27, Sep., pp. 650—657（1978）。