

特徴検出細胞の自己形成モデル

鳥 岡 豊 士*

A Self-Organizing System of Feature Detecting Nerve Cells

Toyoshi TORIOKA

Abstract

We show that a two layer random nerve net has a function of pattern transformation favorable for formation of feature detecting cells.

Then, we give a self-organizing system of feature detecting nerve cells having the two layer nerve nets as pre-processing system. We also give two theorems on formation of feature detectors and consider the behavior of the model through compute-rsimulated experiments. As the result, this model works well in a general environment.

1. まえがき

生物の神経系は環境から入力を受けながら、環境からの情報を処理する情報処理系を自己組織的に形成する。このことは多くの生理学実験によって裏付けされている^{2), 5)~7)}。しかし、この自己組織能をもたらす生理学的な機構はほとんど明らかにされていない。現在のところ、神経シナップスの可塑性によってもたらされるというのが大方の意見である。

神経シナップスの可塑性を基に、自己組織機構の解明を試みた工学の立場からの研究もある^{3), 4), 8), 11)}。しかし、これらの研究では、特徴パターンに直交性^{4), 10)}、発火率の一定性^{1), 4), 9)}、あるいはシナップス荷重和の一定性^{3), 8)}といった厳しい条件が特徴パターンに課せられている。このため、これらのモデルの多くは、条件の課せられていない入力パターンからなる環境（一般的な環境）のもとでは、うまく動作しなくなる。

本文では、抑制接続を有す二層からなる層状ランダム回路網が、特徴検出細胞の自己形成に有利なパターン変換機能を持つことを示す。この事実をもとに、層状ランダム回路網を前処理系として持つ特徴検出細胞の自己形成システムを提案する。また、特徴検出細胞の自己形成に関する定理を与える。次に、この定理をもとに、入力パターンに共通に含まれる特徴を検出す特徴検出細胞の形成を試みる。その結果として、システムが一般的な環境のもとでうまく動作することを

示す。

2. 抑制結合を有す層状ランダム回路網

抑制結合を有す二層からなる層状ランダム回路網のパターン変換について考察する。

2.1 層状ランダム回路網

Fig. 1 は抑制結合を有す二層からなる層状ランダム回路網を示す。第1層、第2層はそれぞれ n, N 個の細胞（閾値素子）からなる。ここに、 n, N は十分大きいものとする。第2層の各細胞は第1層から R (整数) 本の興奮性入力を受ける。また、第2層の細胞の閾値

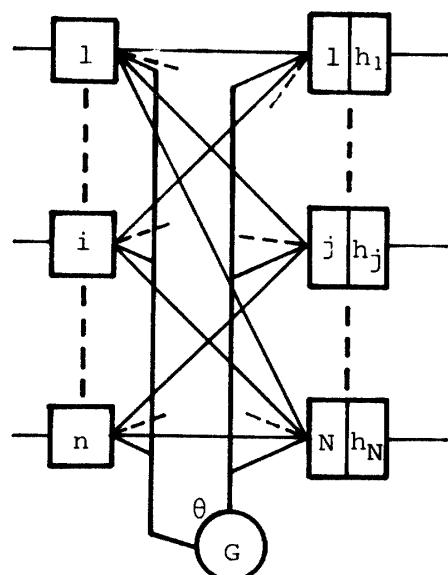


Fig.1 Two-layer random nerve net

* 工業短期大学部情報処理工学科

は一定の分布に従うものとする。細胞 G は抑制性の細胞である。この細胞は第 1 層の素子の全てから興奮性の入力を受け、この入力に対応した抑制出力 θ を第 2 層の全素子に送る。この結果として、第 2 層の発火率を一定値に制御する。

2.2 記号

ここで用いる記号を説明する。第 2 層の細胞の閾値分布は正規分布、

$$f(h) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(h-\bar{h})^2}{2\sigma^2}\right\} \quad (1)$$

に従うものとする。ここに、 \bar{h} は平均値、 σ^2 は分散である。第 1 層に与えられる 0, 1 要素からなる n 次元の入力パターン、およびこれに対応する第 2 層の 0, 1 要素からなる N 次元パターンを、

$$\begin{aligned} x_\alpha &= (x_{\alpha 1}, x_{\alpha 2}, \dots, x_{\alpha N}) \\ X_\alpha &= (X_{\alpha 1}, X_{\alpha 2}, \dots, X_{\alpha N}) \end{aligned} \quad (2)$$

とする。また、これらのパターンの発火率をそれぞれ

$$\phi_\alpha = \frac{1}{n} x_\alpha \cdot x_\alpha, \quad \Phi_\alpha = \frac{1}{N} X_\alpha \cdot X_\alpha \quad (3)$$

但し、 $0 < \phi_\alpha, \Phi_\alpha < 1$ とする。ここに、 \cdot は内積を意味する。パターン x_α とこれとは別の入力パターン x_β 、パターン X_α と x_β に対応する第 2 層のパターン X_β 間の共通発火率、および重なり率をそれぞれ

$$\psi_{\alpha\beta} = \frac{1}{n} x_\alpha \cdot x_\beta, \quad \Psi_{\alpha\beta} = \frac{1}{N} X_\alpha \cdot X_\beta \quad (4)$$

$$\tau_{\alpha\beta} = \frac{\psi_{\alpha\beta}}{\sqrt{\phi_\alpha \phi_\beta}}, \quad T_{\alpha\beta} = \frac{\Psi_{\alpha\beta}}{\sqrt{\Phi_\alpha \Phi_\beta}} \quad (5)$$

とする。ここに、重なり率 $\tau_{\alpha\beta}$ 、 $T_{\alpha\beta}$ は各層でのパターン間の類似性を表わす。第 2 層の入出力関係は

$$X_i = 1(u_i)$$

但し、

$$u_i = \sum_{\alpha \in S} X_i - \theta - h_i, \quad 1(\alpha) = \begin{cases} 0 & u \leq 0 \\ 1 & u > 0 \end{cases} \quad (6)$$

となる。ここに、 S は第 2 層の i 番目と結合する第 1 層の素子の集合、 h_i は第 2 層の i 番目の素子の閾値である。

2.3 パターン変換

層状ランダム回路網のパターン変換機能について考察する。しかし、一般に、パターン変換機能が接続本数 R 、閾値分布の標準偏差 σ 等によって左右されるため、これを統一的に考察することは困難である。ここでは、パターン変換機能を統一的に考察することのできる場合に注目する。

第 1 層に与えられる入力パターンの最小発火率を

ϕ_{\min} とする。閾値分布の標準偏差は十分小さいものとする。また、第 2 層の発火率は一定値 ϕ に制御されるものとする。この制御は、閾値が一定の分布に従っているので、閾値分布の平均値を抑制出力 θ によって適当に移動することによっておこなうことができる¹²⁾。ここに、閾値分布の形は変えないものとする。以上の条件のもとで、 ϕ が範囲 $(0, \phi_{\min}^R]$ 内の一定値に制御される場合、 $T_{\alpha\beta}$ はパターン x_α, x_β の発火率 ϕ_α, ϕ_β とパターン x_α, x_β 間の重なり率 $\tau_{\alpha\beta}$ の関数、

$$T_{\alpha\beta} = \tau_{\alpha\beta} R \sqrt{\left(\frac{\phi_\beta}{\phi_\alpha}\right)^R} \quad (7)$$

但し、

$$\phi_\alpha \geq \phi_\beta, \quad 0 \leq \tau_{\alpha\beta} \leq \sqrt{\frac{\phi_\beta}{\phi_\alpha}}$$

となる^{11), 12)}。ここに、 $0 \leq \tau_{\alpha\beta} \leq 1, 0 \leq \phi_\beta/\phi_\alpha \leq 1$ 故、 $T_{\alpha\beta} \leq 1$ となる。すなわち、重なり率の意味でパターン分離される。また、 $T_{\alpha\beta}$ は重なり率 $\tau_{\alpha\beta}$ 、および発火率の比 ϕ_β/ϕ_α に関する単調増加関数である。それ故、発火率の比の大きい、しかも大きな重なり率をもつ良く似たパターンは大きな重なり率を持つ良く似たパターンに変換される。逆に、発火率の比の小さい、しかも小さな重なり率を持つパターンはより小さな重なり率を持つ似ていないパターンに変換される。Fig.2 は $\tau_{\alpha\beta}$ と $T_{\alpha\beta}$ の関係を示す。パラメータは ϕ_α/ϕ_β である。この Fig.2 は上に述べた事実をうまく表わしている。

更に、式(7)から分かるように、 $T_{\alpha\beta}$ は R の増大と共に小さくなる。それ故、 R が大きな値を取る場合、発火率の比、および重なり率の大きいパターンであっても、小さな重なり率をもつパターンにパターン分離されることになる。従って、パターン変換機能を応用する際には、接続本数を目的に合ったものとする必要がある。

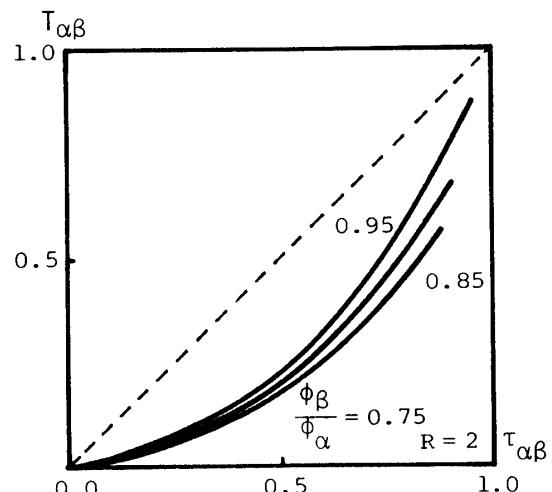


Fig.2 Relation between $\tau_{\alpha\beta}$ and $T_{\alpha\beta}$

3. パターン変換機能の応用

Amari and Takeuchi¹⁾ は多くの自己組織の問題に適用できる特徴検出細胞のモデルと自己形成の理論を与えており、しかし、このモデルは特徴パターンの発火率が一定でなくなるとうまく動作しなくなる。また、このモデルは大きさ一定の抑制入力を必要とする。

ここでは、大きな一定の抑制入力を容易に実現できる。しかも、特徴パターンの発火率に関係なくうまく動作する特徴検出細胞の自己形成モデルを与える。また、特徴検出細胞の形成に関する基本定理を与える。更に、定理のもとに、入力パターンに共通に含まれる特徴を検出する特徴検出細胞の形成を試みる。

3.1 特徴検出細胞の自己形成システム

Fig. 3 は層状ランダム回路網を前処理系として持つ特徴検出細胞の自己形成システムである。システムの第1層と第2層が前処理層としての層状ランダム回路網を形成する (Fig. 1 参照)。従って、発火率一定のパターンが得られる。第3層は自己組織化の能力を持つ K 個の細胞 (閾値素子) からなる。細胞 I は抑制性の細胞である。この細胞は第2層の発火率に等しい興奮性の入力を受け、この入力に比例した抑制性の出力 X_0 を出す。ここに、第2層の発火率は、素子 G によって一定値に制御される故、 X_0 は一定となる。それ故、大きさ一定の抑制入力を得ることができる。第3層の細胞は第2層の全細胞から可塑性の重みを介して興奮性入力と細胞 I から可塑性の重みを介して抑制性入力を受ける。Fig. 3 は第3層の細胞 i を中心とした結合状態を示している。 w_{ij} は第3層の細胞 i と第2層の細胞 j 間の重みである。第3層の細胞 i と第2層の細胞間の重みを

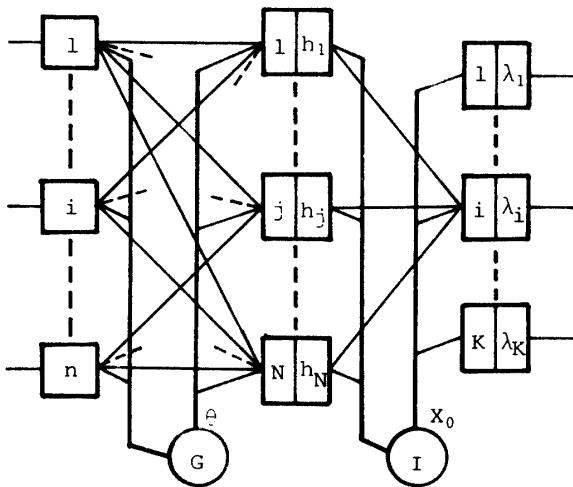


Fig.3 Self-organizing model

$$w_i = (w_{i1}, w_{i2}, \dots, w_{iN})$$

と表わす。 w_{i0} は第3層の i 細胞と細胞 I 間の重みである。 λ_i は細胞 i の閾値である。ここでは、 $\lambda_i = 0$ とする。 $\lambda_i \neq 0$ の場合はこれを w_{i0} に含めることによって $\lambda_i = 0$ の関係を満足することができる。それ故、パターン X_α が与えられたときの細胞 i の入出力関係は

$$Z = 1(u_i) = 1(w_i X_\alpha - w_{i0} X_0) \quad (8)$$

となる。

3.2 システムの環境

システムは環境から入力を受けながら入力に共通に含まれる特徴にのみ反応するようになる。ここでは、 L 個の特徴パターン x_α からなる定常なエルゴード的な環境

$$E = \{(x_\alpha, P_\alpha), \alpha = 1, 2, \dots, L\} \quad (9)$$

を考える。ここに、 P_α は x_α の出現確率である。システムには確率 P_α でランダムかつ独立に選ばれた入力パターンが順次一定期間呈示される。従って、入力は時系列 $x(t)$ となる。ここに、 $x(t)$ は t 時に呈示された特徴パターンを意味する。 $x(t)$ は、エルゴード的な時系列故、環境 E の情報構造を反映する。環境 E は層状ランダム回路網によって、第2層のパターンからなる環境

$$E_I = \{(X_\alpha, P_\alpha), \alpha = 1, 2, \dots, L\} \quad (10)$$

に変換される。パターン X_α は x_α に対応したパターン故、環境 E の情報構造は E_I に保たれる。ここでは、 E_I を E の内部表現と呼ぶ。また、時系列 $x(t)$ に対応した第2層の時系列を $X(t)$ とすると、この時系列もエルゴード的なものとなる。この時系列入力 $X(t)$ は発火率一定である。また、大きさ一定の抑制入力は素子 I の出力として得られる。それ故、従来のモデルの制約は取り除かれる。

第3層の細胞 i に注目してみよう。細胞 i は、入力 $X(t)$ をもとに、重み (w_i, w_{i0}) を自己組織的に修正することにより特徴検出細胞となっていく。この際、修正は学習方程式

$$\begin{aligned} \tau \dot{w}_i(t) &= -w_i(t) + CZX(t) \\ \tau_0 \dot{w}_{i0}(t) &= -w_{i0}(t) + C_0 ZX_0(t) \end{aligned} \quad (11)$$

に従っておこなわれる¹⁾。ここに、 $w(t)$ は t 時の重み、 $\dot{w}(t)$ は w の時間微分、 τ, τ_0 は時定数、 C, C_0 は学習定数である。この式から分かるように、重み (w_i, w_{i0}) は入力 $X(t)$ に依存する。しかも、 $X(t)$ はランダム変数である。従って、式 (11) の期待値

$$\begin{aligned} \overline{\tau \dot{w}_i} &= -\overline{w_i} + \overline{CZX} \\ \overline{\tau_0 \dot{w}_{i0}} &= -\overline{w_{i0}} + \overline{C_0 ZX_0} \end{aligned} \quad (12)$$

但し、

$$ZX = \sum_{\alpha=1}^k P_\alpha \mathbf{1}(w_i X_\alpha - w_{i0} X_0) X_\alpha \quad (13)$$

$$ZX_0 = \sum_{\alpha=1}^k P_\alpha \mathbf{1}(w_i X_\alpha - w_{i0} X_0) X_0$$

を考えることができる。ここに、 $w(t)$ は t 時における w の期待値を意味する。この式において、 τ , τ_0 が十分大きい場合、 $\overline{w_i(t)}$, $\overline{w_{i0}(t)}$ はほとんどの場合において、小さな変動を除けば $w_i(t)$, $w_{i0}(t)$ と一致する¹⁾。それ故、 $w_i(t) = \overline{w_i(t)}$, $w_{i0}(t) = \overline{w_{i0}(t)}$ とすれば、式(12)は

$$\begin{aligned} \tau \dot{\overline{w_i}} &= -\overline{w_i} + CZX \\ \tau_0 \dot{\overline{w_{i0}}} &= -\overline{w_{i0}} + C_0 ZX_0 \end{aligned} \quad (14)$$

と書き改められる。

3.3 特徴検出細胞

一般に、幾つかのパターンは共通の特徴を含む。ここでは、この共通の特徴を含むパターン集合（特徴集合）を A 、特徴を Y_a と表わす。 Y_a は A のパターンに共通に含まれることから、

$$Y_a = (Y_{a1}, Y_{a2}, \dots, Y_{aN}) = \sum_{\alpha \in A} P_\alpha X_\alpha \quad (15)$$

但し、 $Y_{ai} \in \{0, 1\}$

となる。ここに、 $\alpha \in A$ は $X_\alpha \in A$, A は A に属するパターンの論理積を意味する。

細胞 i は学習を通して集合 A に含まれる特徴 Y_a にのみ反応する特徴検出細胞となる。このとき、重み (w_i , w_{i0}) は、学習方程式が多数の平衡状態を持つ故、そのうちの一つに収束する。その平衡状態を (w, w_0) と表わす。この平衡状態 (w, w_0) は細胞 i が特徴 Y_a を含むパターンにのみ反応することから、

$$w = C \sum_{\alpha \in A} P_\alpha X_\alpha = CP(A) X^A \quad (16)$$

$$w_0 = C' X_0 \sum_{\alpha \in A} P_\alpha = C' X_0 P(A)$$

但し、

$$P(A) = \sum_{\alpha \in A} P_\alpha, \quad X^A = \sum_{\alpha \in A} P_\alpha X_\alpha / P(A)$$

となる。 $P(A)$ は A に属する入力パターンが出現する確率である。平衡点 (w, w_0) の近傍での変分方程式は、 $w X_\alpha - w_0 X_0 = 0$ の場合を除き、

$$\delta \mathbf{1}(w X_\alpha - w_0 X_0) = 0$$

故、

$$\begin{aligned} \tau \delta \dot{w} &= -\delta w \\ \tau_0 \delta \dot{w}_0 &= -\delta w_0 \end{aligned} \quad (17)$$

となる。それ故、平衡状態 (w, w_0) は安定である。逆に、 (w, w_0) が安定な平衡状態であるとき、細胞 i は特徴検出細胞となる¹⁾。従って、細胞 i は平衡状態 (w, w_0) で特徴 Y_a の安定な特徴検出細胞となる。

3.4 特徴検出細胞の自己形成に関する定理

第3層の検出細胞は環境 E_I のもとでの学習を通して特定の特徴にのみ反応する特徴検出細胞になる。なかには反応しないまま残る細胞もある。どの細胞がどんな特徴の特徴検出細胞になるかは重みの初期値の依存する。重みが適当に広く分布されていれば、いすれの特徴に対しても特徴検出細胞が形成されるようになる。そこで、どのような特徴検出細胞が形成されるかみてみよう。第2層の発火率は $(0, \phi_{\min}^R]$ 内の一一定値に制御されるものとする。また、特徴集合 A に属するパターンとパターン X_β および特徴 Y_a 間の重なり率の A 上での確率平均を

$$\begin{aligned} T_\beta^A &= \frac{\sum_{\alpha \in A} T_{\alpha\beta}}{P(A)} = \frac{\sum_{\alpha \in A} P_\alpha X_\alpha \cdot X_\beta}{P(A) \cdot L} \\ T_a^A &= \frac{\sum_{\alpha \in A} T_{\alpha a}}{P(A)} = \frac{\sum_{\alpha \in A} P_\alpha X_\alpha \cdot Y_a}{P(A) \cdot L} \end{aligned} \quad (18)$$

但し、 $L = \phi N$

とする。これらの仮定のもとで、次の定理が得られる。定理 1、検出細胞 i は次なる関係を満たすとき特徴 Y_a の特徴検出細胞となる。

$$\max_{\alpha \in A} T_\beta^A < \lambda < T_a^A \quad (19)$$

$$\text{但し, } \lambda = \frac{C' X_0^2}{CL}$$

証明：細胞 i が特徴 Y_a の特徴検出細胞であるとき、細胞 i の入力和 u_i は

$$u_i = \begin{cases} w X_\beta - w_i X_0 > 0 & (\beta \in A) \\ w X_\beta - w_i X_0 < 0 & (\beta \notin A) \end{cases} \quad (20)$$

となる。更に、細胞 i は特徴 Y_a が与えられるとも反応する。それ故、式(20)は

$$u_i = \begin{cases} w Y_a - w_i X_0 > 0 & (\text{for } Y_a) \\ w Y_a - w_i X_0 < 0 & (\beta \notin A) \end{cases} \quad (21)$$

となる。入力和 u_i は式(18), (21)より、

$$u_i = \begin{cases} CP(A) L (T_a^A - \lambda) & (\text{for } Y_a) \\ CP(A) L (T_\beta^A - \lambda) & (\beta \notin A) \end{cases} \quad (22)$$

となる。ここに、 Y_a は集合 A のすべてのパターンに含まれる故、 $T_\beta^A > T_a^A$ ($\beta \in A$) となる。従って、式(21)と(22)より、式(19)が導びかれる。逆に λ が式(21)を満たすとき式(22)が成り立ち、重み (w, w_0) は安定平衡状態となり、細胞 i は特徴検出細胞となる。従って、特徴 Y_a および特徴集合 A が式(21)を満たすものであれば、集合 A に反応する特徴検出細胞が形成されることになる。この際、細胞 i がどのような特徴集合の検出細胞になるかパラメータ λ に依存する。

4. シミュレーション実験

計算機によるシミュレーション実験を通して、シス

テムが特徴パターンの発火率に関係なく、特徴検出細胞を形成することを示す。環境 E での特徴集合 a をと表わす。 a は E_I の特徴集合 A に対応するものとする。また、特徴集合 a 内のパターンは特徴集合 A のパターンが共通に含む特徴 Y_a に対応する特徴 y_a をもつものとする。

この実験では第 1 層、第 2 層、第 3 層の細胞数を $n=64$, $N=220$, $K=25$

とした。第 1 層と第 2 層間の接続本数 R は 1 とした。細胞 I の出力関数の比例定数は $X_0=1$ となるように $1/\Phi$ とした。特徴パターンは一定の特徴を表わす 8×8 の要素からなる 2 値図形を 64 次元ベクトルに変換することによって作成した。Fig.4 はその変換方法を示している。

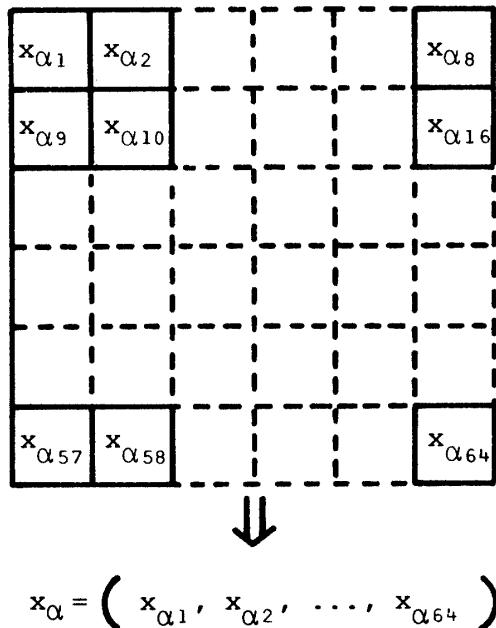


Fig.4 Method for transformation of a two dimensional figure

x_1	x_2	x_3	x_4
1 1 1 1 1 1 1 1	1 1 1 1 1 1 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
1 1 1 1 1 1 1 1	1 1 1 1 1 1 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 0 0 0 0 0 0	0 0 0 0 0 0 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 1 1 1 1 1 1	1 1 1 1 1 1 1 1

x_5	x_6	x_7	x_8
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	1 1 1 1 1 1 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	1 1 1 1 1 1 1 1
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	0 0 0 0 0 0 0 0	0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 1 1 1 1 1 1	0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	1 1 0 0 0 0 0 0	1 1 1 1 1 1 1 1	0 0 0 0 0 0 0 0

Fig.5 Feature patterns

システムの環境は

$$E=\{(x_\alpha, P_\alpha) | \alpha=1, 2, \dots, 8\}$$

とした。ここに、 $P_\alpha=1/8$ である。Fig.5 は x_α に対応した 8×8 要素からなる 2 次元図形を示す。この図から分かるように、パターン x_1, x_3, x_7 、パターン x_2, x_4, x_8 、パターン x_1, x_4, x_6 がそれぞれ共通の特徴、上横棒、左縦棒、下横棒、右縦棒をもっている。これらの特徴集合、および特徴パターンを

$$a_1=\{x_1, x_2, x_8\}, y_{a1}$$

$$a_2=\{x_1, x_4, x_5\}, y_{a2}$$

$$a_3=\{x_3, x_4, x_7\}, y_{a3}$$

$$a_4=\{x_2, x_3, x_6\}, y_{a4}$$

と表わす。表 1 は入力パターン x_α の発火率 ϕ_α を示す。 $\phi_{\min}=1/4$ 故、 Φ を $(0, \phi_{\min}]$ を満たすように $5/22$ とした。それ故、第 2 層の細胞は 50 個発火する。

Table 1 Firing rates of feature Patterns

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8
$\frac{7}{16}$	$\frac{7}{16}$	$\frac{7}{16}$	$\frac{7}{16}$	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$

Table 2 は入力パターン間の重なり率 $\tau_{\alpha\beta}$ を示す。式 (7) および表 1, 2 より、 $\max_{\beta \in A_i} T_{\beta}^{A_i}$, $T_{\alpha}^{A_i}$ ($i=1, 2, 3, 4$) は

$$\max_{\beta \in A_i} T_{\beta}^{A_i} = \frac{\sum_{\alpha \in A_i} P_\alpha X_\alpha \cdot X_\beta}{LP(A)} \quad (X_\alpha \in A_i, X_\beta \notin A_i)$$

$$= \frac{12 + \sqrt{7}}{42}$$

$$T_{\alpha}^{A_i} = \frac{\sum_{\beta \in A_i} P_\alpha X_\alpha \cdot X_\beta}{LP(A)} = \frac{5}{7} \quad (X_\alpha \in A_i)$$

となる。ここに、 A_i は a_i に対応する第 2 層の特徴集合である。従って、式 (19) は

$$\frac{12 + \sqrt{7}}{42} < \lambda < \frac{5}{7} \quad (23)$$

となる。ここでは、 $\lambda=3/5$ とした。学習定数 C, C' は $\lambda=C' X_0^2 / CL$ の関係より、 $C=1.0$, $C'=30.0$ とした。

また、細胞に相互抑制結合を持たせることにより、特徴検出細胞を空間的にも個数についても釣合のとれた状態で形成できることが知られている^{1), 3)}。そこで、検出細胞間の相互抑制結合がある場合の実験をおこなった。このため、

Table 2 Overlapping rates among feature patterns

	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8
x_1	1	$\frac{4}{7}$	$\frac{1}{7}$	$\frac{4}{7}$	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{4}{7}}$
x_2		1	$\frac{4}{7}$	$\frac{1}{7}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{4}{7}}$
x_3			1	$\frac{4}{7}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{1}{28}}$
x_4				1	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{1}{28}}$	$\sqrt{\frac{4}{7}}$	$\sqrt{\frac{1}{28}}$
x_5					1	0	$\frac{1}{4}$	$\frac{1}{4}$
x_6						1	$\frac{1}{4}$	$\frac{1}{4}$
x_7							1	0
x_8								1

第3層の検出細胞を 5×5 の枠目に規則正しく並ぶように置きかえ、一つの細胞が近傍の8個の細胞から一定の重み- q を介して- $q_1(u)$ の抑制入力を受けるようにした。ここに、1 (u)は検出細胞の出力である。尚、端の細胞は rap-around 方式で結合することにより外の細胞と同様の相互抑制結合を持つようにした。重み (w_{ij}, w_{i0})の初期値は区間 [0, 1] および [0, 20] 上の一様分布から決定した。

Table 3 は結果を示す。ここに、 $q=0.3$ である。初期条件では特徴 y_{ai} に反応する特徴検出細胞はなかった。22個の細胞が2つ以上の特徴集合に反応し、3個が無反応のまま残った。学習後には7個の特徴検出細胞が形成された。また、12個は a_i とは別の y_{ai} を共通に含む2個の入力パターンに反応する特徴検出細胞となった。残り6個のうち、1個は入力パターン x_3, x_6, x_7 の3つの入力パターンに反応する特徴検出細胞となり、残り4個は無反応のまま残った。Table 4 は y_{ai} を共通に含む2個の入力パターンに反応する12個の特徴検出細胞の内訳を示す。

特徴 y_{ai} を持つパターンからなる集合 a_i とは別の特徴集合のパターンに含まれる y_{ai} に反応する特徴検出細胞が形成される理由を考えてみよう。 y_{ai} を共通に含む2個のパターンからなる特徴集合は12個であるこれらの特徴集合は

Table 3 The number of feature detectors ($q=0.3$)

	feature detectors				sub-total	non responsive cells	cells responsive to not a_i	total
	y_{a_1}	y_{a_2}	y_{a_3}	y_{a_4}				
initial	0	0	0	0	0	3	22	25
final	2	2	1	2	7	3	14	25

Table 4 The number of features detectors for a feature which exist in two input patterns in common ($q=0.3$)

feature detectors				total
y_{a_1}	y_{a_2}	y_{a_3}	y_{a_4}	
4	4	3	1	12

$$\begin{aligned} a_{11} &= \{x_1, x_2\}, a_{12} = \{x_1, x_8\}, a_{13} = \{x_2, x_8\}; y_{a_1} \\ a_{21} &= \{x_1, x_4\}, a_{22} = \{x_1, x_5\}, a_{23} = \{x_4, x_5\}; y_{a_2} \\ a_{31} &= \{x_3, x_4\}, a_{32} = \{x_3, x_7\}, a_{33} = \{x_4, x_7\}; y_{a_3} \\ a_{41} &= \{x_2, x_3\}, a_{42} = \{x_2, x_6\}, a_{43} = \{x_3, x_6\}; y_{a_4} \end{aligned}$$

と表わされる。ここに、 a_{ij} の添字 i は特徴 y_{ai} を含むことを意味する。 a_{ij} の添字 j は y_{aj} を含む特徴集合を識別するためのものである。これらの集合に対する $\max_{\beta \in A_{ij}} T_{\beta}^{A_{ij}}, T_{ai}^{A_{ij}}$ は

$$\max_{\beta \in A_{ij}} T_{\beta}^{A_{ij}} = \frac{4}{7}, \quad T_{ai}^{A_{ij}} = \frac{11}{14}$$

それ故、 A_{ij} のパターンに共通に含まれる特徴 y_{ai} にのみ反応する特徴を形成するにはパラメータ λ を

$$\frac{4}{7} < \lambda < \frac{11}{14} \quad (24)$$

とすればよい。ところが、この λ の範囲は式 (23) の範囲と共通の範囲 [4/7, 5/7] を持つ。しかも、 $\lambda = 3/5$ は範囲 [4/7, 5/7] 内にある。従って、細胞は重みの初期状態により、 a_i のパターンが共通に含む特徴検出細胞にも a_{ij} のパターンが共通に含む y_{ai} の特徴検出細胞にもなり得る。パターン x_6 のみに反応する特徴検出細胞、 x_3, x_6, x_7 の3つのパターンに反応する特徴検出細胞が形成される理由も同様に考えることができる。

以上の実験結果、および考察から分かるように、種々の特徴検出細胞が形成されるものの、パラメータ λ を式 (19) を満たす値とするより、 a_i のパターンに共通に含まれる特徴を検出する特徴検出細胞を形成できる。また、このシステムでは、前処理層としての層状ランダム回路網のパターン変換機能により、入力パターンの発火率に関係なく特徴検出細胞を形成することができる。

5. 結論

ここでは、層状ランダム回路網が従来の特徴検出細胞の自己形成モデルに課せられた厳しい条件を取り除く、パターン変換機能を持つことを明らかにした。次に、層状ランダム回路網を前処理系として持つ特徴検

出細胞の自己形成に関する基本定理を導びいた。更に、計算機によるシミュレーション実験結果を通して、このシステムが一般的な環境のもとで特徴検出細胞を形成できることを示した。

今後の課題として、層間の接続本数 R が特徴検出細胞の形成に及ぼす影響を調べることが残されている。また、システムをパターン認識に応用することも興味ある問題として残されている。

謝 辞

最後にこの研究の手掛りとなる有意義な助言を頂いた東京大学工学部甘利俊一助教授に深く感謝する。

参考文献

- 1) Amari, S., Takeuchi, A.: Biol. Cybernetics, **29**, 127 (1978)
- 2) Blakemore, C., Sluysters, R.C.: J. Physiol., **248**, 663 (1975)
- 3) Csernai, L.P., Zimanyi, J.: Biol. Cybernetics, **34**, 43 (1979)
- 4) Hall, R., Yau, S.S.: Biol. Cybernetics, **21**, 113 (1976)
- 5) Hirsch, H.V.B., Spinelli, D.N.: Exp. Brain Res., **13**, 509 (1971)
- 6) Hubel, D.H.: The Physiologist, **10**, 17 (1967)
- 7) Hubel, D.H., Wiesel, T.N.: J. Physiol., **206**, 419 (1970)
- 8) Malsburg, C.: Biol. Cybernetics, **14**, 85 (1973)
- 9) Nagano, T.: Biol. Cybernetics, **26**, 45 (1977)
- 10) Nass, M.M., Cooper, L.M.: Biol. Cybernetics, **19**, 1 (1975)
- 11) Spinelli, D.N.: Academic Press (ed. Pribram, K.H., and Broad, D.F.), 293 (1970)
- 12) Torioka, T.: Biol. Cybernetics, **34**, 53 (1979)
- 13) Torioka, T.: Traos. IECE., Japan, **E63**, 8, 590 (1980)

(昭和56年10月15日 受理)