

特徴検出機構を有する連想記憶について

池田 信彦*・鳥岡 豊士**

An Associative Memory Based on Feature Detecting Systems

Nobuhiko IKEDA and Toyoshi TORIOKA

Abstract

The vertebrate self-organizes feature detecting neural cells in the neural net through an adaption to his environment. The feature detecting cells play an important role in neural information processing. Therefore, it seems to us that the feature detecting cells take part in the brain memory in some form or other.

In the paper, we give an adaptive associative memory model based on the formation of the feature detecting neural cells. We explain the association mechanism of the model and consider the ability of the recall through computer-simulated experiments. As the result, it is shown that the model works well under the general environment.

1. まえがき

生体の連想記憶では、外界で起った事象(パターン)をそのままの形で記憶・保持するのではなく、パターンの特徴を自己組織的に捕え、それを骨組にして記憶しているものと考えられている。このことから、記憶には特徴検出機構が何らかの形で関係しているものと考えられる¹⁰⁾。

連想記憶に関して、自己組織的な考えを取り入れた報告がいくつかある。Fukushima²⁾は可変シナプスにより制御されるフィードバック機構をもつ連想モデルを与え、時空間パターンに対する連想能力を調べている。Wigström³⁾は興奮性シナプスのみに可塑性をもたせた学習モデルを与え、そのモデルと連想のメカニズムとの関係を考察している。Kohonen et al.^{4),5)}は擬逆行列を用いた直交化学習による適応システムを与え、それが最適な連想記憶として動作することを示している。Amari⁶⁾は連想と概念形成の神経モデルを与え、直交化学習と共分散学習のもとでのモデルの性能、特に noise immunity, を解析している。しかし、これらのモデルでは特徴検出細胞の形成と連想記憶とを結びつけた検討はほとんどなされていない。

特徴検出細胞の形成については、すでにいくつかの

*徳山工業高等専門学校情報電子工学科

**工業短期大学部情報処理工科

研究がなされている。Malsburg⁷⁾, Nass and Cooper⁸⁾が視覚領における方位選択性をもつ細胞の自己組織化のメカニズムの解明を試みている。永野等⁹⁾は単純、複雑、超複雑型の細胞の機能形成のモデルを提案し、シミュレーション結果を与えている。Amari and Takeuchi¹¹⁾は興奮性シナプスだけではなく抑制性シナプスにも可塑性を導入し、特定の特徴あるいは特徴集合にのみ反応する特徴検出細胞の自己形成を理論的に説明している。

本稿では、Amari and Takeuchi によって提案された特徴検出細胞の自己形成理論を基に特徴検出機構を取り入れた一つの連想記憶モデルを提案し、その動作、性質を明らかにする。また、計算機によるシミュレーション実験を通して、このモデルがうまく動作することを示す。

2. 特徴検出細胞の自己形成

Amari and Takeuchi の特徴検出細胞形成理論を基に、特徴検出細胞の形成過程を説明する¹¹⁾。図1に特徴検出細胞形成のモデルを示す。図中、第1層はN次元の入力層、第2層はn個の細胞からなる特徴検出細胞層、Iは抑制性細胞である。第2層の各細胞は修正可能な興奮性シナプス荷重を介して第1層から入力を受ける他に、細胞Iから修正可能な抑制性シナプス荷重を介して抑制性入力 x_0 (一定値) を受ける。ここでは、入




Fig.1 Network for formation of feature detecting cells

力層と i 細胞間のシナプス荷重を

$$w_i = (w_{i1}, w_{i2}, \dots, w_{ij}, \dots, w_{in}) \quad (1)$$

抑制性入力 x_0 と i 細胞とのシナプス荷重を $-w_{i0}$ とする。また、第 1 層には情報源

$$E = \begin{bmatrix} X_1 & \dots & X_s & \dots & X_k \\ P_1 & \dots & P_s & \dots & P_k \end{bmatrix} \quad (2)$$

但し、 $X_s = (X_{s1}, X_{s2}, \dots, X_{sj}, \dots, X_{sn})$, $X_{sj} \in \{0, 1\}$ (3) からランダムに選ばれた特徴パターン $X_s \in E$ が与えられるものとする。ここに、E はエルゴード的定常環境、 X_s は N 次元の (0, 1) パターン、 P_s は X_s の出現頻度。パターン X_s が入力されたときの第 2 層の i 細胞の出力は

$$Z_i = 1 (w_i \cdot X_s - w_{i0}x_0) \quad (4)$$

但し、 $1(a) = \begin{cases} 0 & (a \leq 0) \\ 1 & (a > 0) \end{cases}$

となる。但し、ここでは i 細胞の閾値は 0 としている。

細胞 i はシナプス荷重 (w_i, w_{i0}) の学習を通して、自己組織的に特定の一個の特徴パターンの検出細胞となっていく。ここでは、(w_i, w_{i0}) の学習は学習方程式、

$$\begin{aligned} \tau \dot{w}_i &= -w_i + CZ_i X \\ \tau' \dot{w}_{i0} &= -w_{i0} + C' Z_i x_0 \end{aligned} \quad (5)$$

によってなされるものとする。ここに、 \dot{w} は時間微分、X は E に属するパターン。このとき、平均学習方程式は

$$\begin{aligned} \tau \dot{w}_i &= -w_i + C \langle Z_i X \rangle_E \\ \tau' \dot{w}_{i0} &= -w_{i0} + C' \langle Z_i x_0 \rangle_E \end{aligned} \quad (6)$$

と書ける。ここに、 $\langle \rangle_E$ は情報源 E に関する平均、C, C' は学習の定数、 τ, τ' は時定数であり、十分大きいものとする。

平衡状態のシナプス荷重 (w_i, w_{i0}) は式(6)より

$$\begin{aligned} w_i &= C \langle Z_i X \rangle_E \\ w_{i0} &= C' \langle Z_i x_0 \rangle_E \end{aligned} \quad (7)$$

となる。

第 2 層の細胞は特定の一個の特徴パターンにのみ興奮して反応するとき、そのパターンの安定な検出細胞となる。このための必要十分条件は、特徴パターン間の最大重なり率、特徴パターンの発火個数のそれぞれを t_0, L とすると、

$$\frac{1+t_0}{2} < \frac{C' x_0^2}{CL} < 1 \quad (8)$$

となる。すなわち、学習パラメータ C, C' が式(8)を満足するように決定されるとき、情報源 E に属する各特徴パターン X_s に対応するシナプス荷重の安定平衡状態はこれを (w_i^s, w_{i0}^s) とすると、

$$\begin{aligned} w_i^s &= CP_s X_s \\ w_{i0}^s &= C' P_s x_0 \end{aligned} \quad (9)$$

となる¹⁾。

ところで、生体は外界に現われるパターンをそのままの形で記憶・保持しているのではなく、種々のパターンの特徴を自己組織的に捕え、それを骨組にして記憶しているものと考えられる。すなわち、特徴検出細胞が生体の連想記憶に何らかの関わりをもっていると考えられる。そこで、特徴検出細胞の形成理論を連想記憶に適用したモデルを提案し、その動作、性質を明らかにする。

3. 連想記憶

3.1 学習過程

図 2 に特徴検出細胞の形成理論を適用した連想記憶




Fig.2 A model of associative memory (Model 1) based on the feature detecting system

モデル (モデル1) を示す。系(I)は特徴検出細胞の形成系を示す(図1参照)。ここに、 E_x は検出細胞が受ける入力の情報源である。この系の*i*細胞は興奮性シナプス荷重 α_i を介して、入力 X ($\in E_x$, キーパターン), 抑制性シナプス荷重 $-\alpha_{i0}$ を介して入力 x_0 (一定値) を受けるものとする。また、シナプス荷重 $\alpha_i, -\alpha_{i0}$ は E_x のもとで学習され、その学習は学習方程式,

$$\tau_\alpha \dot{\alpha}_i = -\alpha_i + C_\alpha X_i^f X \tag{10}$$

$$\tau'_\alpha \dot{\alpha}_{i0} = -\alpha_{i0} X_i^f x_0 \tag{11}$$

但し,

$$X_i^f = 1 (\alpha_i \cdot X - \alpha_{i0} x_0)$$

によって行われるものとする。ここに、 X^f は X に対する検出細胞の出力パターン、 X_i^f は X^f の *i* 要素、 C_α, C'_α は学習の定数、 $\tau_\alpha, \tau'_\alpha$ は時定数。また、細胞の閾値は 0 としている。この場合、*i* 細胞は、 $C=C_\alpha, C'=C'_\alpha, t_0=t_x$ とした式(8)は

$$\frac{1+t_x}{2} < \frac{C_\alpha x_0^2}{C_\alpha L} < 1 \tag{12}$$

を満たすとき、特定のキーパターンの検出細胞となっていく。ここに、 t_x は E_x に属するキーパターン間の最大重なり率。

記憶は検出細胞層の出力パターン X^f (キーパターンに対応する) と系(III)の各細胞とのシナプス荷重を、系(II)が与える特徴パターン Y ($\in E_y$, 記憶パターン) を教師信号として学習することにより行われる。この場合、 Y_i (Y の *i* 要素) が *i* 細胞の教師信号となる。ここでは、検出細胞層の *j* 番目の要素と *i* 細胞間の修正可能なシナプス荷重を γ_{ij} とし、 γ_{ij} の学習、すなわち記憶が学習方程式

$$\tau_\gamma \dot{\gamma}_{ij} = -\gamma_{ij} + Y_i X_j^f \tag{13}$$

によって行われるものとする。ここに、 τ_γ は時定数。この式はベクトル・行列表現すると、

$$\tau_\gamma \dot{[\gamma]} = -[\gamma] + Y(X^f)^T \tag{14}$$

となる。ここに、 $[\dot{\gamma}]$ は行列 $[\gamma]$ の各要素の時間微分、 T はベクトルの転置を意味する。

ここで、記憶が特徴検出細胞の形成後に起るものとする。ここで、 $\tau_\alpha, \tau'_\alpha$ と τ_γ の関係は、 $\tau_\alpha, \tau'_\alpha < \tau_\gamma$ と置くことができる。そこで以下では、 γ_{ij} の学習が α_i, α_{i0} の学習後になされるものとして解析を行う。キーパターンの情報源が

$$E_x = \begin{bmatrix} X_1 & \dots & X_s & \dots & X_k \\ P_1 & \dots & P_s & \dots & P_k \end{bmatrix} \tag{15}$$

である場合、シナプス荷重 α_i, α_{i0} は、 C_α, C'_α が式(12)を満足するとき、安定平衡状態となり、系(I)の細胞層に各キーパターンの検出細胞が形成される。それ故、

キーパターン X_s のみに反応する検出細胞 *i* のシナプス荷重 α_i, α_{i0} の安定平衡状態 ($\alpha_i^s, \alpha_{i0}^s$) は式(7)より

$$\begin{aligned} \alpha_i^s &= C_\alpha P_s X_s \\ \alpha_{i0}^s &= C'_\alpha P_s x_0 \end{aligned} \tag{16}$$

となる。

シナプス荷重 $[\gamma]$ の学習を考えてみよう。記憶パターン Y はキーパターン X を条件とする条件付確率

$$P(Y|X) = \begin{array}{c|cccc} & Y & & & \\ \hline X & Y_1 & \dots & Y_t & \dots & Y_k \\ X_1 & P_{11} & \dots & P_{1t} & \dots & P_{1k} \\ \vdots & \vdots & & \vdots & & \vdots \\ Y_s & P_{s1} & \dots & P_{st} & \dots & P_{sk} \\ \vdots & \vdots & & \vdots & & \vdots \\ X_k & P_{k1} & \dots & P_{kt} & \dots & P_{kk} \end{array} \tag{17}$$

で X と連合されるものとする。この状況は多くの場合において起り得るものと考えられる。この場合、キーパターン X ($\in E_x$) に対応する出力パターン X^f と記憶パターン Y ($\in E_y$) の対が形成する系(III)の環境は、これを E とすると、式(15), (17)の関係より

$$E = \left[\begin{array}{cccc} (X_1^f, Y_1) & \dots & (X_s^f, Y_t) & \dots & (X_k^f, Y_k) \\ P_{11}^* & \dots & P_{st}^* & \dots & P_{kk}^* \end{array} \right] \tag{18}$$

但し、 $P_{st}^* = P_s \cdot P_{st}$

と表わすことができる。この環境のもとでの学習により、 $[\gamma]$ は

$$[\gamma] = \langle Y (X^f)^T \rangle_E \tag{19}$$

$$= \sum_{s=1}^k \sum_{t=1}^k P_{st}^* Y_t (X_s^f)^T$$

に収束する。尚、 E はキーパターンが複数個の記憶パターンと連合することを許す環境となっている。この点で、キーパターンと記憶パターンの連合が1対1である従来の環境より一般的なものになっている。

3.2 想起過程

記憶パターン Y_r の想起を考えてみよう。図2で細胞 I_r は想起の時のみ動作し、系(I)の検出細胞の発火に比例した抑制出力を系(III)の各細胞へ送るものとする。ここでは、その比例係数を $-\theta$ ($0 \leq \theta \leq 1$) とする。

キーとしてパターン X_r が与えられたとき、これに対応する出力パターン X_r^f が系(III)の各細胞への入力となる。この結果、系(III)の細胞の出力パターン (想起パターン) \hat{Y}_r は、式(19)より

$$\hat{Y}_r = 1 ([\gamma] X_r^f - \theta X_r^f)$$

$$= 1 \left(\sum_{t=1}^k P_{rt}^* Y_t - \theta \right) = 1 \left(P_{rr}^* Y_r + \sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^* Y_t - \theta \right) \tag{20}$$

となる。但し、細胞の閾値は0としている。ここで、 Θ は全ての要素が θ であるn次元ベクトル、 $\|X\|$ はベクトルXのノルムを表わすものとする。また、 $1(a)$ は単位階段関数でベクトルの全ての要素に対して作用するものとする。

これより、 $\sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^* < P_{rr}^*$ ($\frac{1}{2} < P_{rr}$) の場合は

$$\sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^* < \theta < P_{rr}^*$$

を満たす θ を選べば、 $\hat{Y}_r = Y_r$ となりモデルは Y_r をうまく想起することができる。しかし、 $P_{rr}^* < \sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^*$ ($P_{rr} < \frac{1}{2}$) の場合は他の記憶パターンの干渉により、 Y_r だけを想起することができなくなる。このことは、従来提案されてきた連想記憶モデルに対しても言えることである。そこで、後者の場合にもうまく想起できるようにするために、記憶パターンYもキーパターンXと同様に、特徴検出機構によって処理される連想記憶モデルを与える。

4. 一般的な環境に適応する連想記憶モデル

より一般的な環境にも適応できる連想記憶モデル(モデル2)を図3に示す。このモデルは図2のモデルの系(II)を特徴検出細胞の形成系としたものである。系




Fig.3 A model of associative memory based on feature detecting systems (Model 2)

(II)の β_i, β_{i0} は入力層とi細胞間の修正可能なシナプス荷重であり、これらの荷重の学習は、式(10), (11)と同様に学習方程式、

$$\tau_{\beta} \dot{\beta}_i = -\beta_i + C_{\beta} Y_i^f Y \quad (21)$$

$$\tau_{\beta} \dot{\beta}_{i0} = -\beta_{i0} + C'_{\beta} Y_i^f y_0 \quad (22)$$

但し、 $Y_i^f = 1 (\beta_i \cdot Y - \beta_{i0} y_0)$ によって行われるものとする。ここに、 Y^f はYに対する検出細胞の出力パターン、 Y_i^f は Y^f のi要素、 C_{β}, C'_{β} は学習の定数、 $\tau_{\beta}, \tau'_{\beta}$ は時定数。また、細胞の閾値は0としている。

記憶は、節3・1と同様にキーパターンXに対する検出細胞の出力パターンと系(III)の各細胞とのシナプス荷重を学習することによって行われるが、ここでは、 Y_i^f (Y^f のi要素)がi細胞の教師信号となる。それ故、学習後想起されるパターンは記憶パターンYではなく、そのYに対応する検出細胞の出力パターン Y^f となる。この場合、学習後のシナプス荷重行列 $[\gamma]$ は、 $\tau_{\beta}, \tau'_{\beta} \ll \tau_{\gamma}$ とおけば

$$[\gamma] = \sum_{s=1}^k \sum_{t=1}^k P_{st}^* Y_t (X_s^f)^T \quad (23)$$

となる。キー X_r が与えられた時の想起パターン \hat{Y}_r^f は、

$$\hat{Y}_r^f = 1 (P_{rr}^* Y_r^f + \sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^* Y_t - \Theta) \quad (24)$$

となる。ここに、 $Y_s^f \cdot Y_t^f = 0 (s, t=1, \dots, k, s \neq t)$ 。

それ故、 $P_{rr}^* < \sum_{\substack{t=1 \\ t \neq r}}^k P_{rt}^*$ ($P_{rr} < \frac{1}{2}$) の場合にも

$$P_{rt}^* < \theta < P_{rr}^* \quad (t=1, \dots, k, t \neq r)$$

を満たす θ を選べば、 $\hat{Y}_r^f = Y_r$ となりモデルはキー X_r と一番高い確率で連合した Y_r^f (Y_r に対応する)を想起することができる。

連想記憶において、モデルの雑音に対する許容能力を調べることは重要である。そこで、ここではキーパターンに許される雑音の範囲について調べよう。キーとして、キーパターンに雑音があった不完全なパターン \hat{X}_r が与えられたとしよう。ここに、 \hat{X}_r と X_r との重なり率 T_r は \hat{X}_r と $X_s (s=1, \dots, k, s \neq r)$ 間の最大重なり率 T_m よりも大きいものとする。また、雑音 \hat{N}_r を

$$\hat{N}_r = 1 - T_r \quad (25)$$

但し、 $T_r = X_r \cdot \hat{X}_r / L$

と定義する。この場合、雑音パターン \hat{X}_r に対して系(I)の検出細胞層で X_r の検出細胞のみが興奮して反応するならば、 X_r をキーとした場合と同じ想起結果が得られる。そこで、 \hat{X}_r に対して X_r の検出細胞のみが興奮して反応するための条件を求めると、

$$\alpha_i^r \hat{X}_r - \alpha_{i0}^r x_0 > 0$$

$$\alpha_i^s \hat{X}_r - \alpha_{i0}^s x_0 \leq 0 \quad (s=1, \dots, k, s \neq r) \quad (26)$$

となる。この式は、式(16), (25)より

$$\hat{N}_r < 1 - \frac{C_a' x_0^2}{C_a L} < \hat{N}_m \quad (27)$$

となる。すなわち、この範囲内の雑音までは、モデルは不完全なキーパターン \hat{X}_r に対して Y_r を想起することができる。

5. シミュレーション実験

計算機シミュレーション実験を通して、モデル1が不完全なキーパターンに対してうまく動作することを示す。更に、モデル1ではうまく適応できない環境においてもモデル2はうまく動作することを示す。

実験では、キー及び記憶パターンの次元 N 、検出細胞数 n を

$$N=64, n=25$$

とした。また、学習における時定数と I_x, I_y の抑制出力を

$$\tau_\alpha = \tau'_\alpha = \tau_\beta = \tau'_\beta = 1.0, \tau_\gamma = 2.0, x_0 = y_0 = 1$$

とした。パターンは特定の特徴を表す 8×8 要素からなる2値図形を64次元のベクトルに変換することによって作成した。検出細胞は 5×5 の2次元に配列し、各キーパターンの検出細胞の個数を釣合のとれた状態で形成するために、検出細胞間に相互抑制結合をもたせた。すなわち、1個の細胞は近傍8個の細胞から一定の重み $-q$ を介して $-q1(u)$ 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。この実験では $q=0.05$ とした。

5.1 実験1

この実験では、モデル1の連想動作を試みた。環境 $E_x, P(Y|X)$ は


$$E_x = \begin{bmatrix} X_1 & X_2 & X_3 & X_4 & X_5 & X_6 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{bmatrix} \quad (28)$$

$$P(Y|X) = \begin{array}{c|cccccc} X \backslash Y & Y_1 & Y_2 & \dots & Y_6 \\ \hline X_1 & 0, 6 & * & & * \\ X_2 & * & 0, 6 & * & \dots & \\ \vdots & \vdots & * & & \vdots \\ \vdots & \vdots & \vdots & & * \\ X_6 & * & * & \dots & 0, 6 \end{array} \quad (29)$$


但し、 $*=0.08$

とした。図4はキーパターン X_s ($s=1, 6$) と、それと連合する記憶パターン Y_t ($t=1, 6$) に対応する 8×8 要素からなる2次元図形を示している。これより、キーパターン間の最大重なり率は $t_x=1/8$ となる。それ故、式(12)は

$$4.5 < \frac{C_a'}{C_a} < 8$$



(a) key patterns



(b) memorized patterns

Fig.4 Key patterns and memorized patterns

となる。ここでは、この不等式を満足するように、 $C_a=1, C_a'=4.8$ とした。荷重 α_1, α_{10} の初期値は、それぞれ区間 $(0, 1)$ 、区間 $(0, 3)$ 上の一様分布から決定した。

図5に雑音 $\hat{N}_r=0.375$ が加った不完全なキーパターン(a)による想起パターン(b)を示している。この場合、雑音 \hat{N}_r が式(27)を満足していることから、モデル1はキーパターンと一番高い確率で連合した記憶パターンをうまく想起できる。

図6は式(29)の条件付確率を

$$P(Y|X) = \begin{array}{c|cccccc} X \backslash Y & Y_1 & Y_2 & Y_3 & Y_4 & Y_5 & Y_6 \\ \hline X_1 & 0.4 & 0.2 & * & * & * & * \\ X_2 & * & 0.4 & 0.2 & * & * & * \\ X_3 & * & * & 0.4 & 0.4 & * & * \\ X_4 & * & * & * & 0.4 & 0.2 & * \\ X_5 & * & * & * & * & 0.4 & 0.2 \\ X_6 & 0.2 & * & * & * & * & 0.4 \end{array} \quad (30)$$

但し、 $*=0.1$

とした場合の想起結果を示している。この場合、モデル1は他のパターンからの干渉により記憶パターンを

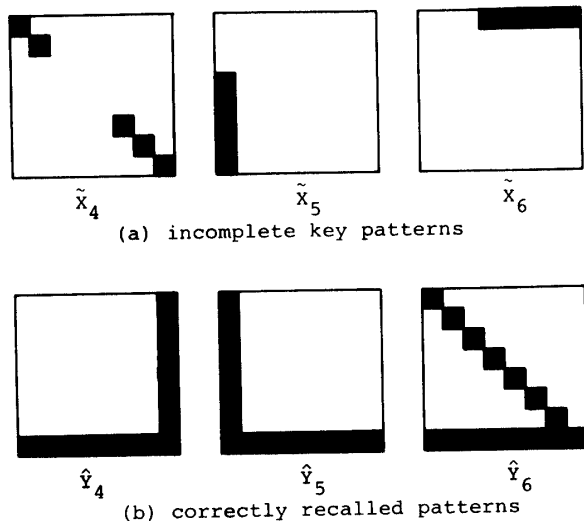


Fig.5 Result of recall in the model 1 by the incomplete key patterns




Fig.6 Result of recall in the model 1
うまく想起できなくなる。

5.2 実験2

この実験ではモデル2の連想動作を調べた。環境はモデル1がうまく動作しない式(28), (30)で与えられるものとした。また、キーパターン、記憶パターンは実験1と同じものとした。ここに、記憶パターン間の最大重なり率は $t_y=9/15$ である。それ故、式(12)で $t_x=t_y$, $C_\alpha=C_\beta$, $C'_\alpha=C'_\beta$ とした式は

$$12.5 < \frac{C'_\beta}{C_\beta} < 15$$

となる。ここでは、これを満足するように $C_\beta=1$, $C'_\beta=13$ とした。荷重 β_i, β_{i0} の初期値はそれぞれ区間 $(0, 1)$, 区間 $(0, 10)$ 上の一様分布から決定した。尚、キーパターンに対する学習の定数は実験1と同じく $C_\alpha=1, C'_\alpha=4.8$ とした。

図7に学習後の、各記憶パターンの検出細胞(a)と不完全なキーパターン(図5(a))を入力した時の想起パターン(b)を示す。図7-(a)の各細胞上の数字は、その細胞がどの記憶パターンの検出細胞であることを示している。この想起結果から、検出細胞層のパターンではあるが、モデル1では想起できなかった記憶パターンを

	2		5	1
3	4	1		
5	5	3		
4	6			1
5			6	




Fig.7 Result of recall in the model 2

うまく想起できることがわかる。

6. むすび

生体がパターンの特徴を自己組織的に捕え、それを骨組にして記憶・保持していると考えられることから、特徴検出機構を有する連想記憶モデル(モデル1, モデル2)を提案した。そして、多くの場合に起り得る、キーパターンと複数の記憶パターンが連合される一般的な環境のもとのモデルの動作を解析し、その想起能力を調べた。また、雑音に対するモデルの許容能力について考察した。更に、計算機によるシミュレーション実験を通して、モデルがうまく動作することを確かめると共に、従来の連想モデルではうまく動作しない環境においてもモデル2はうまく動作することを明らかにした。ここで注意すべき点は、モデル2で想起されるパターンは記憶パターンそのものではなく、それに対応する検出細胞層のパターンであることである。しかし、想起されたパターンが認識あるいは運動システムの入力となると考えれば、記憶パターンそのものが想起されたことと同等であると見なすことも可能であろう。今後はこのような点も考察して、単独の連想記憶モデルとしてだけでなく、他の情報処理機能との関連性も含めて検討する必要があるように思われる。

謝 辞

最後に、日頃から有意義な助言を頂いている東京大学工学部甘利後一教授に深く感謝する。

参 考 文 献

1) Amari, S., Takeuchi, A.: Biol. Cybernetics 29, 127 (1978)

- 2) Fukushima, K.: Kybenetik 12, 58 (1973)
- 3) Wigström, H.: Kybenetik 12, 204 (1973)
- 4) Kohonen, T., Rouhonen, M.: IEEE trans. Comput., 701 (1973)
- 5) Kohonen, T., Oja, E.: Biol. Cybernetics 21, 85 (1976)
- 6) Amari, S.: Biol. Cybernetics 26, 175 (1977)
- 7) Malsburg, C.: Biol. Cybernetics 14, 85 (1973)
- 8) Nass, M. M., Cooper, L. M.: Biol. Cybernetics 19, 1 (1975)
- 9) 永野, 倉田: 信学技報, MBE 79-53, 1 (1979)
- 10) 高木貞敬: 記憶のメカニズム, 岩波 (1976)
- 11) 甘利俊一: 神経回路網の数理, 産業図書 (1976)

(昭和57年10月13日受理)