

非単調ダイナミクスを用いた構造をもつパターンの連想記憶

正 員 森田 昌彦^{†*} 正 員 吉澤 修治[†] 正 員 中野 馨[†]

Associative Memory for Correlated Patterns Using Nonmonotone Dynamics

Masahiko MORITA^{†*}, Shuji YOSHIZAWA[†] and Kaoru NAKANO[†], *Members*

あらまし 相互結合のある神経回路網で、細胞の入出力特性を非単調にしたダイナミクスを用いると、自己相関型連想記憶モデルの能力が大きく向上し、従来の問題点の多くが克服される。本論文では、残された大きな問題である情報表現上の制約について議論する。これまで自己相関モデルにとって不可欠だと考えられていた記憶パターン間の直交性の条件は、非単調ダイナミクスを用いたモデルでは必要ない。しかも、記憶パターン間の相関を積極的に利用することで、想起能力をより高めることが可能となる。また、学習の際に非単調ダイナミクスを用いると、従来の相関学習が改善され、情報表現に対する制約を更に緩和することができる。

キーワード 神経回路網, 連想記憶, 非単調ダイナミクス, 情報表現, 相関学習の改良

1. ま え が き

自己相関型の連想記憶モデル⁽¹⁾は、その長い研究の歴史にもかかわらず、少ない記憶容量や想起能力の低さ、いわゆる偽の記憶の存在といった問題点を抱えたままであった。しかし、最近になって、想起のダイナミクスの改良によって、性能が大幅に向上することが示されている⁽²⁾。特に、アナログ型の神経回路網で、非単調な出力関数(非単調ダイナミクス)を用いると、従来の問題のほとんどが解決または著しく改善される。

しかし、まだ一つの重要な問題が残されている。それは、記憶パターンの直交性の条件である。

自己相関連想記憶では、記憶するパターンを S^1, S^2, \dots, S^m (± 1 を成分とする n 次元の縦ベクトル)としたとき、荷重行列として自己相関行列

$$W = \frac{1}{n} \sum_{\mu=1}^m S^{\mu} S^{\mu T} \quad (1)$$

を用いる(上添字 T は転置を表す)。そして、ある記憶パターン、例えば S^1 を W の右から掛けたとき、その値

$$WS^1 = S^1 + \frac{1}{n} \sum_{\mu=2}^m (S^{\mu T} S^1) S^{\mu} \quad (2)$$

が近似的に S^1 と等しくなることを基本原理としている。従って、 $S^{\mu T} S^{\nu}$ ($\mu \neq \nu$)が n に比べて十分に小さい、すなわち記憶パターンが相互にほぼ直交していることが不可欠であった。

しかしながら、このような条件は、記憶の情報表現を強く制約する。例えば、ある二つの事物がどれだけ近い関係にあっても、別の記憶項目である限り全く相関のないパターンとして表現されなければならない。つまり、記憶情報をもつ構造(多くの場合、それは複雑な階層構造である)を無視しなければならないのである。このことは、神経回路網による分散型の情報処理の大きな利点を捨てるようなものであり、極めて深刻な問題だと言える。

この制約から逃れる一つの手段は、別の荷重行列を採用することである。例えば、一般逆行列モデル(2.3参照)では、すべての μ に対して $WS^{\mu} = S^{\mu}$ が厳密に成立するように W を構成する。しかし、後述のように、このような方法では記憶パターンに含まれている構造を生かすことができない。自己相関モデルを修正したモデル⁽³⁾も提案されているが、人為的な操作が必要であり、性能もあまり良くない。情報をもつ構造をうまく利用するには、やはりダイナミクスの本質的な改良が

[†] 東京大学工学部計数工学科, 東京都
Faculty of Engineering, The University of Tokyo, Tokyo, 113
Japan
^{*} 現在, 筑波大学電子・情報工学系

必要なのである。

では、前記のようなダイナミクスの改良法は、この問題に対して有効なのであろうか。本論文では、非単調ダイナミクスを用いたとき、記憶パターン間の相関が自己相関モデルの動作にどう影響するかを検討する。また、情報表現上の制約を更に緩める方法として、細胞の非単調特性を利用した結合荷重の学習法を提案する。

2. 構造をもったパターンの連想記憶

2.1 非単調ダイナミクス

次のような n 個のアナログ型細胞からなる神経回路網を考えよう。すなわち、 i 番目の細胞の出力を y_i 、平均膜電位を u_i 、 j 番目の細胞から i 番目の細胞への結合荷重を w_{ij} としたとき、系のダイナミクスが

$$\tau \frac{du_i}{dt} = -u_i + \sum_{j=1}^n w_{ij} y_j \quad (3)$$

$$y_i = f(u_i) \quad (4)$$

で表されるようなモデルである (τ は時定数)。但し、細胞の自己結合はない ($w_{ii}=0$) もとする。

式(4)の $f(u)$ は出力関数であるが、ここでは

$$f(u) = \frac{1 - e^{-cu}}{1 + e^{-cu}} \cdot \frac{1 + \kappa e^{c'(|u|-h)}}{1 + e^{c'(|u|-h)}} \quad (5)$$

を用いる (c, c', h はいずれも正の定数)。これは、 $\kappa=1$ のときシグモイド型の単調増加関数であるが、 $\kappa < 1$ のときには図1に示すような非単調な関数となる。以下、 $\kappa=1$ の場合を従来のダイナミクス、 $\kappa < 0$ とした場合を非単調ダイナミクスと呼ぶ。

ある時刻におけるこの系の状態は、厳密にはベクトル $U=(u_1, \dots, u_n)^T$ によって記述される。しかし、以下のように連想記憶モデルとして動作させる際には、最終的に u_i の符号が意味をもつ。そこで、 $x_i = \text{sgn}(u_i)$ ($\text{sgn}(u)$ は $u > 0$ のとき 1 、 $u < 0$ のとき -1 とする関数)




図1 非単調出力関数

Fig. 1 Nonmonotone output function.

を考え、 $X=(x_1, \dots, x_n)^T$ を回路網の状態と呼ぶことにする。従来のダイナミクスで x_i が y_i とほぼ等しいのに対して、非単調ダイナミクスでは、 $|u_i|$ が大きいとき両者の符号が異なる点に注意が必要である。

2.2 記憶パターンの生成

上記のモデルに m 個の n 次元のパターン $S^\mu=(s_1^\mu, \dots, s_n^\mu)^T$ ($\mu=1, 2, \dots, m$) を記憶させるとしよう。但し s_i^μ は 1 または -1 とするものとする。

従来は、 S^μ として可能な 2^n 個のパターンの中からランダムに選んだものを記憶パターンとすることが多かった。このとき、 n が十分大きければ、二つの異なる記憶パターンはすべて近似的に直交する。別の言い方をすれば、 S^μ はパターン空間の全域にほぼ一様に分布する。

それに対して、記憶パターンの間になんらかの特殊な構造があると、 S^μ は一様には分布しない。ここでは特に、全体が l 個ずつクラスタを成して分布しているような場合を考える。具体的には、以下のように生成したパターンを記憶させる。

まず、 k 個のパターン C^1, C^2, \dots, C^k を独立かつランダムに選ぶ。次に、 $C^\mu=(c_1^\mu, \dots, c_n^\mu)^T$ とある相関 a (≥ 0) をもつパターンの中から l 個をランダムに選び、 $S^{\mu 1}, S^{\mu 2}, \dots, S^{\mu l}$ とする (但し $kl=m$)。すなわち、すべての μ, ν に対して

$$\frac{1}{n} \sum_{i=1}^n c_i^\mu c_i^\nu = a \quad (6)$$

が成り立つようにする。実際には、 C^μ の要素のうち $n(1-a)/2$ 個をランダムに選んで符号を反転すれば、 $S^{\mu \nu}$ が得られる。

a がある程度大きいとき、これらのパターンは C^μ を中心にクラスタをなして分布する。また、一つのクラスタに属するすべてのパターンは、相互に約 a^2 の相関をもつ。

こうして得られた $k \times l$ 個のパターンに関する自己相関行列を式(1)に従って構成し (但し、 $S^{11}=S^1, S^{12}=S^2, \dots, S^{kl}=S^m$ とおく)、これを荷重行列とする。

2.3 数値実験

$n=1000, k=50, l=4$ ($m=200$) の場合について数値実験を行った。式(5)のパラメータは、 $c=50, c'=15, h=0.5$ である。

まず、想起しようとするパターン (S^{11} とする) と回路網の状態 X との重なり率 (overlap)

$$p = \frac{1}{n} \sum_{i=1}^n x_i s_i^{11} \quad (7)$$

を定義する。 $p=1$ は $X=S^{11}$ であることを意味する。




図2 従来のダイナミクスを用いた場合の重なり率 p の時間変化
 Fig. 2 Time courses of the overlap p for conventional dynamics.




図3 非単調ダイナミクスを用いた場合の重なり率 p の時間変化
 Fig. 3 Time courses of the overlap p for nonmonotone dynamics.

この p の時間的な推移を、従来のダイナミクスおよび非単調ダイナミクスを用いた場合について、それぞれ図2および図3に示す。いずれも(a)は $a=0$ 、すなわちパターン間に相関がない場合、(b)は $a=0.6$ の場合である。初期状態 X_0 が S^{11} と p_0 の相関をもつとき、(b)では X_0 と $S^{1\nu}$ ($\nu=2, \dots, l$) との間にも約 $0.36p_0$ の相関があることを注意しておく。

従来のダイナミクスを用いると、 a の値に関係なく想起がうまくできない(図2)。これは m が記憶容量(約 $0.15n$) を超えているからであるが、(a)と(b)を比べると、後者では初期状態での重なり率 p_0 が1に近いとき、 p が0.6付近まで急速に減少していることがわかる。このことは、 a が大きくなると、 S^{11} の周辺には安定な平衡状態がなくなり、クラスタの中心 C^1 の近くに偽の記




図4 臨界重なり率 p_c の相関 a による変化
 Fig. 4 Changes in the critical overlaps of (a) the autocorrelation model with nonmonotone dynamics and of the pseudoinverse models with (b) conventional and (c) nonmonotone dynamics, as a function of the correlation a .

憶(記憶パターンとは異なる平衡状態)が集まることを示唆している。

一方、非単調ダイナミクスを用いると、 p_0 がある臨界値 p_c より大きければ、パターン間に相関があっても $p=1$ となる(図3)。 p_c はモデルの想起能力を表す一つの指標であるが、意外なことに、その値は $a=0$ のときより $a=0.6$ のときの方が小さい。つまり、パターン間に相関があるときの方が想起能力が高いのである。

これについてもう少し詳しく調べた結果を図4(a)に示す。このグラフからわかるように、 a が約0.65以下のとき、 p_c は a の増加と共に減少する。しかし a がそれより大きくなると、 p_c は急激に増大する[†]。また、 a が約0.75を超えると、記憶パターンに対応する状態が不安定になり、 p_0 の値によらず想起ができなくなる。

比較のため、一般逆行列モデル⁽⁴⁾について同じ実験を行った。一般逆行列モデルとは、荷重行列として

$$W = \Sigma(\Sigma^T \Sigma)^{-1} \Sigma^T \quad (8)$$

を用いたものである。ここで、 Σ は $n \times m$ の行列 (S^1, \dots, S^m) である。従来のダイナミクスおよび非単調ダイナミクスを適用した場合の p_c の変化を、それぞれ図4の(b)および(c)に示した。

このグラフから、どちらのダイナミクスを用いても、 p_c の値は a によって変化せず、 $a < 0.7$ では(a)よりも想起能力が劣ることがわかる。これは、式(8)の荷重行列を使うのは、すべての記憶パターンを他と直交するパターン(共役ベクトル)に変換することに相当するからだと考えられる。従って、一般逆行列モデルは、非常に強い相関をもつパターンでも記憶できるが、その反面、記憶パターンがもつ構造を利用していないと言




図5 非単調ダイナミクスを用いた自己相関モデルの想起の過程
 Fig. 5 A process of recollection of the autocorrelation model with nonmonotone dynamics.

える。

2.4 考 察

では、なぜ非単調ダイナミクスを適用した自己相関モデルでは、パターン間の相関が想起能力を高めるのであろうか。この問題を考えるために、まず回路網の状態 X とクラスタの中心 C^1 との重なり率

$$p' = \frac{1}{n} \sum_{i=1}^n x_i c_i^1 \quad (9)$$

を定義する。

p' の時間変化の一例を、 p の推移と共に図5に示す。これは、 p_0 がほぼ p_c に等しく、想起に長い時間がかかるような場合である。このグラフから読み取れるように、 p' は最初 p よりも速やかに増加し ($p_0 \cong 0.6 p_0$ に注意)、一時は p を超えるが、その後やや減少して $0.6 (= a)$ に落ち着く。

このことから、図6に模式的に示すような形で想起が行われているという解釈が可能である。すなわち、 X がどの記憶パターンからも十分離れているときには、クラスタ全体があたかも一つのアトラクタのように振る舞い、最も引きつける力の強いクラスタ(通常は最も近いもの)が X を引き寄せ、そして、 X がそのクラスタに近づくと、今度はその中の記憶パターンの一つが X を引き寄せ、最終的にそのパターンが想起される

[†] 但し、このとき $p_0 > p_c$ でも想起に失敗する場合や $p_0 < p_c$ で成功する場合が非常に多くなるため、 p_c の値は明確でない。




図6 非単調ダイナミクスによる想起過程の模式図

Fig. 6 Schematic recalling process of the nonmonotone dynamics model.

のである。

問題は、一つの記憶パターンが、同じクラスタ内の他の記憶パターンからどのようにして分離されるのか、という点である。そこで、出力ベクトル $Y=(y_1, \dots, y_n)^T$ と記憶パターン $S^{\mu\nu}$ の内積を正規化した量

$$d_{\mu\nu} = \frac{\sum_i s_i^{\mu\nu} y_i}{\sum_i x_i y_i} \quad (10)$$

を考えよう。 d_{11} は p と似ている ($X=S^{11}$ のとき $d_{11}=1$) が³、必ずしも等価ではない。

$d_{\mu\nu}$ を用いると、入力ベクトル $V=WY$ を

$$V = \lambda(d_{11}S^{11} + d_{12}S^{12} + \dots + d_{kl}S^{kl}) \quad (11)$$

のように表すことができる ($\lambda = \sum_i x_i y_i / n$)。この式で、右辺括弧内の第2項以降はノイズ成分に相当するが、特に $d_{1\nu}S^{1\nu}$ ($\nu \neq 1$) の項は、従来のダイナミクスを用いる限り、 p が大きくなれば必ず増大する ($Y \cong X$ より $p=1$ のとき $d_{1\nu} \cong a^2$)。

しかしながら、非単調ダイナミクスを用いると、状況はかなり変わってくる。図5には d_{11} および $d_{1\nu}$ ($\nu=2, 3, 4$) の推移も示されているが、これを見るとわかるように、 $d_{1\nu}$ は p' の減少と共に小さくなり、平衡状態ではほぼ0となる。つまり、 p が大きくなるにつれ、 X は S^{11} 以外の記憶パターンの影響をほとんど受けなくなる。

これは、 X があるクラスタに近づくと、そのクラスタ内の多数の記憶パターンに共通する ($|\sum_{\nu} s_i^{\mu\nu}|$ が大きい) 要素に対応する細胞の出力が小さくなり、それ以外の細胞の出力が支配的になるからである。もう少し詳しく言えば、 X が S^{11} に近づくにつれて、 $x_i = s_i^{11} = s_i^{1\nu}$ が多くの $\nu (\neq 1)$ に対して成り立つような細胞ほど、他の細胞から強い入力を受けて $|u_i|$ が大きくなり、その

ため $s_i^{1\nu} y_i$ の値が小さく (または負に) なる。また、このとき $x_i y_i$ が大きい細胞について見ると、 s_i^{11} と $s_i^{1\nu}$ とは相関がほとんどなく、 $s_i^{1\nu} y_i$ を i について平均するとほぼ0となる。その結果、 Y と $S^{1\nu}$ の内積、従って $d_{1\nu}$ は0に近づき、式(11)のノイズ項が消えるわけである。

ところで、図4(a)において、 $a > 0.65$ で p_c が急増しモデルがうまく動作しなくなるのは、 $S^{1\nu}$ の影響が強すぎて、 X がどれだけ S^{11} の近くにいても C^1 の方へ引かれていってしまうからだと考えられる。このような状況では、もはや自己相関行列を用いて記憶するのは無理であり、荷重行列をある程度改良することが必要になってくる。

3. 非単調ダイナミクスを利用した学習

前章の最後に述べたように、非常に強い相関をもつパターンを安定に記憶するためには、荷重行列を改良する必要がある。しかし、式(8)のような W を用いたのでは、記憶パターンがもつ構造をうまく生かすことができない。何か、自己相関モデルと一般逆行列モデルの長所を併せもつ (a が小さいとき前者に近く、 a が大きいと後者に近くなる) ような、うまいモデルは作れないだろうか。

単純に考えれば、例えば W を式(1)と式(8)の荷重平均とし、パターン間の相関が大きいときほど後者の重みを増やせばよいように思われる。しかしながら、このようなやり方は、クラスタごとに相関の大きさが違うと使えない。しかも、一般には、記憶パターンはもっと複雑な構造をしており、適切な結合荷重を明示的な式で与えることは非常に困難である。

従って、学習によって W を適応的に構成することが望ましい。では、どのような学習則を用いるべきであろうか。また、非単調ダイナミクスを用いた神経回路網では、なんらかの意味で従来より優れた学習が可能なのであろうか。本章では、これらの問題について議論する。

3.1 相関学習と直交学習

自己相関モデルの荷重行列 W は、相関学習⁽⁵⁾ によって構成することができる。具体的には、

$$\tau' \frac{dw_{ij}}{dt} = -w_{ij} + a s_i^{\mu} s_j^{\mu} \quad (12)$$

という学習則 (τ' および a は正の定数) に従って w_{ij} を更新することを、すべての μ について十分な回数を繰り返すと、 $W=[w_{ij}]$ は式(1)の自己相関行列の定数倍にほぼ収束する。

一方，一般逆行列モデルの荷重行列は，直交学習⁽⁵⁾

$$\tau \frac{dw_{ij}}{dt} = -w_{ij} + \alpha \left\{ s_i^\mu - \sum_{j=1}^n w_{ij} s_j^\mu \right\} \quad (13)$$

によって近似的に実現される。

従って，望ましい学習則は，ある意味で相関学習と直交学習の中間に位置すると言える。但し，入力しているパターンの近傍に他の記憶パターンがあれば直交学習に近く，そうでないときは相関学習に近くなければならない。実は，非単調ダイナミクスを用いると，そのような学習が簡単に実現できるのである。以下に，その具体的な方法を示す。

3.2 学習則

まず，回路網に外部から入力を加えられるよう，式(3)を少し変え，

$$\tau \frac{du_i}{dt} = -u_i + \sum_{j=1}^n w_{ij} y_j + z_i \quad (14)$$

とする。ここで， z_i は i 番目の細胞に対する外部入力である。

さて，パターン S^1, S^2, \dots, S^m を記録する場合， $z_i = \beta s_i^\mu$ (β は正の定数) という形で外部から S^μ ($\mu = 1, \dots, m$) を順次入力し，式(14)および式(4)で記述されるダイナミクスに従って系を動作させる。それと並行して， w_{ij} の学習を

$$\tau \frac{dw_{ij}}{dt} = -w_{ij} + \alpha y_i y_j \quad (15)$$

に従って実行する。但し，時定数 τ' は τ より十分大きいものとする。

従来のダイナミクスを用いた場合， β が十分大きければ $y_i \cong s_i^\mu$ となるから，これは相関学習と同じである。しかし，非単調ダイナミクスの場合には，必ずしもそうではない。このことを定性的に説明すると，次のようになる。

今， $S = (1, 1, \dots, 1)^T$ を入力しているとしよう(こう仮定しても一般性を失わない)。また， W が自己相関行列に近い状況を考える。

S 以外の記憶パターンがすべて S から十分に離れている(相関がほとんどない)とき， $u_i (> 0)$ の大きさはどの細胞についてもだいたい同じになる。そうすると，近似的に $Y = \lambda S$ が成り立つ(λ は正の定数)から，式(15)は式(12)とほぼ等価である。すなわち，この学習則は相関学習に近い。

これに対して，もし S の近くに他の記憶パターンがあると，2.4 で述べたように，他の細胞から受ける入力 u_i の大きさにばらつきができ， u_i の分布は分散が大きくな




図7 学習後のモデルの臨界重なり率 p_c
Fig. 7 Change in the critical overlap p_c of the model after learning.

ものになる。そして， $f(u)$ の非単調性により， u_i が大きい細胞ほど出力 y_i が小さくなる。そうすると，学習によって u_i の大きな細胞への結合荷重は一般に小さくなり，その細胞が受ける入力も減少する。 u_i が小さい細胞はその逆である。

その結果，学習が進むにつれて， S を入力した際の u_i の分散は小さくなると考えられる。このことは，直交学習を行ったのと同様な効果をもつ(直交学習では， u_i の分散が0に収束することに注意)。但し， u_i の分散が小さくなるに従って y_i のばらつきも減少し，相関学習に近づくことになるから，ある程度以上 u_i の分散が減ることはない。

なお，パラメータの大きさはそれほど重要ではないが， $-x$ の値をあまり大きくしてはならない。これは， y_i が x_i と異符号で大きな絶対値をとると， $|u_i|$ が大きい細胞同士の結合荷重の増大により $|u_i|$ がますます大きくなってしまう場合があるからである[†]。

ところで，この学習法を用いると，ある程度学習したパターンに関しては，自らが想起したパターンを用いて学習を進めることができる。このとき，外部から与える入力は，完全なパターンでなくてもよいし，その大きさ β も小さいもので十分である。そのため，新たなパターンを記録する際などに必要な，過去に記憶したパターンの再学習が容易となる。これは，想起のダイナミクスを利用しない普通の教師付き学習にはない特長だと言える。

3.3 数値実験

以上のような学習法を，2.2 で述べたクラスタをなすパターンに対して適用してみた。その手順は以下のと

[†] これを避けるには，式(15)を多少変更し， $y_i y_j$ のところを $(y_i - \kappa x_i)(y_j - \kappa x_j)$ などとすればよいが，煩雑なので採用しなかった。

おりである。

まず、200個のパターン $S^{11}, S^{12}, \dots, S^{kl}$ を適当な順番で入力し、一つのパターンにつき 2τ の間学習を行う。400 τ で一巡するが、これを5回繰り返す。パラメータは $\alpha=0.4$, $\beta=0.3$, $\tau'=2000\tau$, $\kappa=-0.1$, その他は前章と同じである。

こうして学習を終えた後の回路網に関して、2.3と同様な実験を行い、臨界重なり率 p_c と相関 a との関係を調べた。結果を図7に示す。但し、図4と比較するため、 p_c を求める際には $\kappa=-1$ とした($\kappa=-0.1$ だと p_c が全体的に少し大きくなる)。

グラフから読み取れるように、 a が大きくなるにつれて想起能力が高まるが、 a が0.65を超えても p_c が下がりに続ける点で自己相関モデル(破線)と異なっている。また、 a が0.6前後のとき自己相関モデルより若干劣るものの、それ以外では他のモデルよりも優れた想起能力を示すことがわかる。

なお、 a が1に近づくにつれてパラメータの選択が急激に難しくなり、 $a>0.9$ ではうまく学習ができなかった。また、 p_c の値は、学習回数を増やしてもほとんど小さくならず、むしろわずかに増加する。このことから逆に、学習回数は一つのパターンにつき数回で十分だと言える。

同様に、記憶パターンがより複雑な構造をもつ(クラスタが階層をなしている)場合についていくつかの実験を行ったところ、いずれも上述の学習をしたモデルが最も高い想起能力を示した。従って、非単調ダイナミクスを用いた学習法は、かなり一般的な場合に有効だと考えられる。

4. むすび

非単調ダイナミクスを用いると、自己相関連想記憶モデルに不可欠だと考えられていた直交性の条件が緩和され、構造をもつパターンであっても記憶できることを示した。また、記憶パターンが数個ずつクラスタをなすような場合について数値実験を行ったところ、パターン間に適度な相関があると想起能力が高まることわかった。更に、相関学習を自然な形で改良した学習を提案し、これによってより強い相関やより複雑な構造をもつパターンを効率良く記憶できることを確かめた。

なかでも2番目の結果は、パターンの直交性は高いほど良いという従来の常識に反しており、非常に奇妙に思える。しかし、記憶パターン全体の情報量は相関

が大きいほど減少することを考えると、これはむしろ自然なことだと言える。反対に、従来のダイナミクスや一般逆行列モデルの方が、情報量の減少、言い換えればパターンがもつ構造を無駄にしていたのである。従って、本研究の結果は、情報を分散表現して記憶することの本当の利点を生かし、連想神経回路網を工学的に応用する上で重要な意味をもつ。

最後に、実際の脳の神経回路との関係について触れておきたい。既に報告したように、脳内の少なくともある一部の領域では、フィードフォワード型の局所的な抑制回路によって、一種の非単調ダイナミクスが実現されていると考えられる⁽⁶⁾。また、非単調な入出力特性を利用した学習は、現実の脳がもつ制約の中でも十分に実行可能である。そして、もしそのような学習が実際に行われているとすれば、特に抑制性のニューロンに関して、一つの有力なシナプス強化則⁽⁷⁾が導き出せることになる。このように、本研究は生理学的な事実を無視したモデルを扱っているが、その結果は決して現実の脳と無関係ではない。

今後の課題としては、まず非単調ダイナミクスの数学的な解析が挙げられる。また、本研究の結果を、連続的に変化するパターンの連想記憶や記憶回路の自己組織化のモデルに応用することも重要な課題である。

文 献

- (1) 中野 馨：“アソシエートロンとその応用—連想記憶装置に関する研究”，信学インホメーション理論研究，IT69-27 (1969)。
- (2) 森田昌彦，吉澤修治，中野 馨：“自己相関連想記憶の想起過程とその改良”，信学論(D-II)，J73-D-II，2，pp. 232-242 (1990-02)。
- (3) Gutfreund H.：“Neural networks with hierarchically correlated patterns”，Phys. Rev. A，37，2，pp. 570-577 (1988-01)。
- (4) Kohonen T.：“Self-Organization and Associative Memory (2nd ed.)”，Springer，New York (1988)。
- (5) 甘利俊一：“神経回路網の数理”，産業図書(1978)。
- (6) 森田昌彦：“側頭葉短期記憶力学系の神経回路モデル”，信学論(D-II)，J74-D-II，1，pp. 54-63 (1991-01)。
- (7) 森田昌彦：“連想記憶の神経回路モデル”，科学，61，4，pp. 223-230 (1991-04)。

(平成4年2月13日受付)



森田 昌彦

昭 61 東大・工・計数卒，平 3 同大学院博士課程了。現在，筑波大学電子・情報工学系講師。生体情報工学，特に神経回路網および記憶機構の研究に従事。



吉澤 修治

昭 37 東大・工・応物卒，昭 39 同大学院修士課程了。同年日立製作所中研勤務。昭 41 東大工学部計数工学科勤務，現在同学部機械情報工学科教授。バイオサイバネティクス，生体工学，非線形力学の研究に関心をもつ。IEEE，INNS，計測自動制御学会，日本 ME 学会，神経科学協会各会員。



中野 馨

昭 35 東大・工・応物卒。同年(株)東京芝浦電気入社，中央研究所勤務。昭和 41 東大・工・計数助手。工博。現在，東大・工・計数助教授。脳機能のモデル化の研究に従事。