


認識細胞の自己形成とその応用

池田 信彦



①

認識細胞の自己形成とその応用

池 田 信 彦

目次

	頁
第1章 序論	1
1.1 本研究の目的	1
1.2 本研究の意義と歴史的背景	1
1.3 本論文の構成	3
第2章 神経回路網の数理的基礎理論	5
2.1 緒言	5
2.2 神経細胞の学習	5
2.2.1 シナプス結合の可塑性	5
2.2.2 学習環境の情報構造	6
2.2.3 シナプス学習の学習方程式	7
2.2.4 学習の収束	9
2.2.5 Hebbの学習法	12
2.3 一次元神経場における興奮パターン力学	14
2.3.1 神経場の方程式	14
2.3.2 一様入力に対する局在興奮の力学	16
2.4 基本競合系	21
2.4.1 モデル	21
2.4.2 基本競合系の平衡状態	22
2.4.3 競合過程	26
2.5 結言	27
第3章 認識細胞の自己形成	28
3.1 緒言	28
3.2 認識細胞の自己形成モデル	29
3.2.1 甘利-竹内のモデル	29
3.2.2 学習	30
3.2.3 自己形成の理論	32
3.2.4 モデルの能力	36
3.3 モデルの改良	37
3.3.1 モデル	37
3.3.2 認識細胞の自己形成	39

	頁
3.4 計算機実験	42
3.5 結言	44
第4章 認識細胞のトポグラフィ的配列構造	45
4.1 緒言	45
4.2 理論	46
4.2.1 モデルの概略	46
4.2.2 細胞の入出力関係	48
4.2.3 神経場の平衡状態	49
4.2.4 シナプス荷重の学習	50
4.3 認識細胞領域の形成	51
4.3.1 制約条件	51
4.3.2 必要条件の導出	53
4.3.3 認識細胞領域幅の収束先	58
4.4 計算機実験	59
4.4.1 実験 I	59
4.4.2 実験 II	64
4.5 結言	65
第5章 認識細胞形成系の連想記憶への応用 (I)	67
5.1 緒言	67
5.2 学習過程	68
5.2.1 モデルの概略	68
5.2.2 認識細胞の形成系	69
5.2.3 多重連合系	72
5.2.4 自己連合系	73
5.3 想起過程	74
5.3.1 相互想起	75
5.3.2 自己想起	76
5.4 計算機実験	76
5.5 結言	79
第6章 認識細胞形成系の連想記憶への応用 (II)	80
6.1 緒言	80

	頁
6.2 学習過程	81
6.2.1 モデルの概略	81
6.2.2 認識細胞の自己形成系	82
6.2.3 統合細胞形成系	84
6.2.4 自己連合系	86
6.3 想起過程	87
6.3.1 想起の流れ	87
6.3.2 想起の具体例	88
6.4 計算機実験	92
6.4.1 連想の順次移行	92
6.4.2 連想の分岐	94
6.5 結言	98
第7章 認識細胞形成系の回転パターン表現への応用	99
7.1 緒言	99
7.2 誤差逆伝播学習	100
7.3 回転パターン学習システム	101
7.3.1 形状検出システム	103
7.3.2 回転角検出システム	106
7.3.3 その他の学習システム	107
7.4 連想・思考過程	107
7.5 計算機実験	108
7.6 結言	112
第8章 結論	114
謝 辞	116
参考文献	117
付録1 音声波形入力に対する実験結果	124
付録2 50個の特徴パターンに対する実験結果	128

第1章 序論

1. 1 本研究の目的

脳は生体の情報処理機能をつかさどる大規模かつ複雑な神経回路網である。脳は環境の変化に適応できる学習能力、自己組織能力がきわめて優れている。その学習、自己組織は神経細胞間のシナプス効率の変化(可塑性)に基礎を置いている。この学習や自己組織機能は生体が環境に適応していくうえで本質的に重要である。

神経生理学は神経回路に関する実証的なデータを積み重ね、神経回路網の可塑性を明らかにしてきた。また、最近では脳の情報処理の観点から、可塑性に基づく学習や記憶の研究が精力的に行われている。しかし、高次の情報処理機能を直接に調べる生理学的手段は見あたらない。

一方、工学の立場からは、脳の情報処理様式を明らかにするための神経回路網モデルの提案、その動作のコンピュータ・シミュレーションによる研究、更にこうしたモデルに含まれる原理を数学的に体系化する研究が行われてきた。これは構成的方法と呼ばれ、脳の原理を実証的に調べる代わりに、脳と同じような動作を行うモデルを実際に構成してその動作を調べると共に、そこにある原理を数理的に体系化しようとするものである。この構成的方法により、神経系に可能な高次機能を見つけ出し、これをもとに生理実験に方向を与えることが現在望まれている。これはまた脳の並列の情報処理、学習や自己組織能力、記憶方式などの原理を探ることであり、情報工学の観点からは、それらの原理に基づくコネクシオン・マシンなどの並列コンピュータの試作や光コンピュータなどへの応用が試みられている。

本研究は、構成的方法の立場から、神経回路網を抽象化したモデルをもとに、認識機構の自己形成理論を与える。またそれを基礎として、連想記憶の機構、回転パターン脳の脳内表現の機構など脳の高次の情報処理様式について考察する。

1. 2 本研究の意義と歴史的背景

脳の並列情報処理、学習や自己組織機能、記憶方式などは未来のコンピュータの参考となる興味ある情報原理を内包している。神経回路網の構成的方法は、それらの原理を解明する糸口を与えるための一つの有効な手段である。この方法は甘利によってその基礎が体系化されている^(5,2)。そこでは基本的な機能モデルをもとにその原理が数学的に定式化され、それらの情報処理機構が明らかにされている。ここでは、その数理理論を基礎として、認識細胞さらには認識機構の自己形成理論を与える。更に、

それを連想記憶の機構、情報の脳内表現の機構に応用し、脳の高次の情報処理様式について考察する。

認識細胞の自己形成機構の研究は、Hubel and Wiesel⁽²⁵⁾、(26)、Blakemore and Cooper⁽⁹⁾らの視覚系に関する生理学的実験をきっかけに始まる。それらの実験は視覚領における特定の特徴に選択的に反応する特徴抽出細胞の存在、そのような機能形成の視覚体験への依存性、細胞のトポグラフィの配列構造など視覚領の微細構造が自己組織的に形成されることを明らかにしたものである。このような細胞の自己形成機構の解明を目的として、Malsburgのモデル⁽³⁵⁾をはじめ、多くのモデルが提案されている⁽⁵⁾、⁽¹⁵⁾、⁽¹⁷⁾、⁽¹⁸⁾、⁽²⁰⁾、⁽³⁶⁾、⁽³⁸⁾、⁽⁴⁰⁾、⁽⁷⁷⁾、⁽⁸¹⁾。しかし、モデルには入力パターンやシナプス荷重などに対するいくつかの制約条件が課せられている。一方、トポグラフィ構造形成に関して、Willshaw-Malsburg⁽⁵⁰⁾、甘利⁽⁴⁾、⁽⁶⁾、⁽⁷⁾、⁽⁴⁴⁾、⁽⁸⁴⁾、Kohonen⁽³²⁾、⁽³³⁾らの研究がある。これらの研究は自己形成の学習の論理を神経場に組み込み、神経場間の位相連続的な神経結合の形成を論じている。また、興味あるシミュレーション結果を示している。しかし、これらのモデルに関してこれから検討すべき点が多くあり、研究は未だに不十分であるといえる。それゆえ、トポグラフィ構造形成も含めた認識細胞の自己形成に関して、制約条件が少なく、より一般化されたモデルを構築する必要があると思われる。

生体の連想記憶において、記憶過程でのパターン間の連合はあらかじめ決っているのではなく、自己組織的に形成されると考えられる。また、連想過程では種々の観点から分析された情報を再び統合してパターン化するような機構を通して、学習時に形成された連合をたどりながら、連想が順次移行していくなどの機能が実現されていると考えられる。このように、生体の連想記憶には、入力を種々の観点から分析する認識細胞のような分析機構とそれらを再び統合し、パターン化するような統合機構が何らかの形で関与しているものと思われる。このことを示唆する生理学的な報告⁽¹⁰⁾もある。この意味から、認識細胞の自己形成機構が連想記憶機構とどのような関わりをもち、いかなる役割を果たしているかを考察してみることは興味深い。

連想記憶に関する研究は、1972年頃までに、中野⁽³⁷⁾、⁽⁷⁴⁾、Kohonen⁽³⁸⁾らによってその原理が独立に提唱された。その後、相関学習連想記憶モデルの能力評価や学習方式に関する研究、また連想の機能を追求した研究が行われた。能力評価に関するものに、上坂一尾岡⁽⁶⁷⁾、甘利⁽²⁾、Palm⁽³⁹⁾らの理論がある。学習方式に関して、直交学習⁽³⁾、一般化逆行列⁽³¹⁾、パターン分離機能⁽⁴⁹⁾、⁽⁷³⁾を用いたモデルなどがある。また機能を追求したものに、動的連想⁽²⁾、⁽¹⁰⁾、⁽⁷⁵⁾や多重連想⁽²¹⁾を可能にし

たモデル、夢の解釈と関連した学習と反学習とを組み合わせたモデル⁽¹³⁾、⁽²³⁾、⁽²⁴⁾などがある。最近では、想起順序が確率的に決まるモデル⁽⁸⁾や生体の記憶機能と深い関わりをもつといわれる海馬のモデル⁽⁸⁰⁾などが提案されている。しかし、従来の連想記憶モデルでは認識細胞の自己形成機構などを連想記憶過程に直接結びつけた考察はなされていない。また、記憶過程におけるパターン間の連合は環境から事前に与えられていて、パターン間連合の自己組織的な形成やそれによる連想の順次移行、更に連想の分岐などの機能についても議論されていない。そのような機能を実現する機構を明らかにすることは、生体の連想機能を解明する上で意義があると思われる。

生体の神経系において、外界情報がどのような形式で脳内に表現され、思考過程でどのような変換が行われるかなどを考察することは興味ある問題である。特に、回転パターンなどに対する恒常性、不変性の問題、思考中のパターンの表示とその表示に対して回転や移動などの操作をほどこす原理的な可能性の問題などがある。これらの問題を考察することは、神経回路網による知識獲得や概念形成等の情報処理原理を探るうえで重要である。しかし、このような問題に関して、従来ほとんど考察されていない。

以上のことから、神経回路網の構成的方法による研究の一つの方向として、認識細胞の自己形成の問題、また認識細胞を用いて分析した種々の観点からの情報を再び統合してパターン化し、連想記憶過程と結びつける問題、更に回転パターンの脳内表現や思考過程に関する問題などを考察することは有意義である。これが本論文の主要な目標であり、このことはまた、脳におけるより高次の情報処理機構の解明への一助をなすと思われる。

1.3 本論文の構成

第2章では、甘利によって体系化された神経細胞の学習理論、神経場の興奮パターン力学、更に競合、協調の数値モデル(基本競合系)について概説する。これらの理論およびモデルは本論文の数理的基礎として重要である。

第3章では、まず甘利一竹内によって提案された認識細胞の自己形成モデルとその自己形成理論について述べる。またモデルの能力について考察する。次いで、その改良として、甘利一竹内のモデルに非線形特性をもつ1個の抑制性細胞を付加することによって、その機能を拡張できることを示す。更に、1個の学習パラメータのみを変化させることによって、入力パターン間の類似度に応じた認識細胞を形成することができ、類似度による種々のパターン分類が行えて、モデルが連想記憶、パターン認識

等の情報処理機能にとって都合のよい特性をもつことを明らかにする。

第4章では、側抑制型相互結合を有する神経場における認識細胞のトポグラフィ的配列構造（認識細胞領域）の形成について考察する。

第5章では、認識細胞形成と上位概念の形成とを直接結びつけることによって、認識細胞形成系を連想記憶へ応用し、上位概念の連合を介した多重連想機能について考察する。

第6章では、第5章で提案したモデルをもとに、統合機構とフィードバック機構を取り入れた連想記憶モデルを提案し、記憶過程でのパターン連合の自己組織的な形成、またその連合を介した連想の順次移行、更に連想の分岐機能を考察する。

第7章では、誤差逆伝播学習の教師信号の自己形成に認識細胞の形成系を適用することによって回転パターンを学習、表現する神経回路モデルを提案し、回転パターンの脳内表現形式や思考過程について考察を加える。

第8章では、第2章から第7章までの結果を要約するとともに、今後の研究課題について述べる。

なお、本論文は電子情報通信学会論文誌、Biological Cybernetics、および IEEE Transactions on Systems, Man, and Cybernetics に掲載された論文^{(28), (29), (59), (62), (64), (66)}に基づいて作成されたものである。

第2章 神経回路網の数理的基礎理論⁽⁵²⁾

2. 1 緒言

神経回路網は、学習を通して種々の情報処理機能を実現する。その論理を探るには、学習の基礎となる神経細胞の学習法則を明らかにしなければならない。

また、神経回路網は多数の神経細胞からなり、それらが複雑に結合したいわゆる神経場を構成している。神経場において、興奮がどのように起こり、それがどのように保持されるかを明らかにすることも、情報処理機能を解明する上で重要である。

さらに、神経回路網の並列情報処理機能において、競合と協調が重要な役割を果たしていると考えられている。これは、相互に結合した回路網の内部で、決定をめぐる情報が競合するとともに協調し合い、回路網の力学過程を通して結論を出すというものである。

本章では、甘利によって体系化された神経細胞の学習理論、神経場の興奮パターンの力学、さらに競合、協調の数理モデル（基本競合系）について概説する。これらの理論およびモデルは本論文の数理的基礎として重要である。

2. 2 神経細胞の学習

2. 2. 1 シナプス結合の可塑性

脳の神経回路網はその形成の過程で自己組織性を有し、環境との相互作用で適応的に神経構成を変えていく能力をもつと考えられている。これは神経細胞が入出力信号に応じて自己の特性を適応的に変えることができる自己組織能力によっている。この自己組織は、神経細胞のシナプス結合の荷重の変化、すなわちシナプス結合の可塑性により実現されるという考えが一般的である。生理学的立場からも、中枢神経系が生後間もない発達のある時期に急速に成長し、神経細胞の間の結合が密になること、またこの時期に形成される結合は入力情報によって左右されること、さらに、脳の多くの場所で神経細胞の入力の一部が損傷を受けると、その近傍の健全な入力から発芽とよばれる新しいシナプス接続の形成が起こることなどからシナプス結合の可塑性が明らかになってきた。

神経細胞のシナプス荷重の変化に関して、Hebbのシナプス強化法則⁽¹⁹⁾がある。それは、神経細胞が興奮したときに、その細胞へ入力されたシナプスの結合荷重が強化され、増大するというものである。この仮説は多くの学習系モデルで用いられている。




図 2. 1 神経細胞のモデル

2. 2. 2 学習環境の情報構造

図 2. 1 に神経細胞のモデルを示す。神経細胞は、与えられた入力信号 $x = (x_1, \dots, x_n)$ にもとづいてシナプス荷重 $w = (w_1, \dots, w_n)$ を適応的に修正することによって、自己組織化する。この学習の結果、神経細胞がどのような特性をもつようになるかは、与えられる学習用入力信号に依存している。

時間 t に入力される信号を $x(t)$ とする。自己組織化の過程は入力信号の系列 $\{x(t)\}$ に依存する。入力信号は、神経細胞のおかれた環境の情報構造を反映したものであり、神経細胞はこれにより外界環境を学び、自己をこれに適用させる。入力信号系列は、外界の情報構造を十分に反映した定常的な確率過程であるとする。

最も簡単な環境情報構造として、 L 個の入力信号 $x_1, \dots, x_1, \dots, x_L$ が確率 $p_1, \dots, p_1, \dots, p_L$ で発生するものを考える。ここで、一つの入力信号 x は一定時間 ΔT の間入力し続けるものとし、しかも、入力信号は ΔT 時間ごとに、与えられた確率に従って、 L 個の信号から独立に選ばれるものとする。このような環境の情報構造を

$$E = \begin{pmatrix} x_1 \cdots x_1 \cdots x_L \\ p_1 \cdots p_1 \cdots p_L \end{pmatrix} \quad (2.1)$$

で表す。E から選ばれた入力系列 $\{x(t)\}$ を学習することにより、神経細胞は E の情報構造を学習し、これに適応することができる。

2. 2. 3 シナプス学習の学習方程式

神経細胞の学習は、その形式によっていくつかの型に分類されるが、学習信号という概念を導入することにより統一的に議論できる。学習信号 γ は、一般に入力信号 x 、シナプス荷重 w に依存して定まる信号で

$$\gamma = \gamma(x, w)$$

と表せる。この学習信号を用いて、Hebb のシナプス強化法則を一般化した次の仮説を採用する。

神経細胞の基本仮説：シナプス荷重 w_j は、そのシナプスへの入力信号の強さ x_j とその細胞の学習信号 γ との積 γx_j に比例して増加する。

このように仮定すると、Hebb の仮説は、神経細胞が興奮したときのみ強化が起こるといふものであるから、学習信号 γ としてその細胞の出力 z を採用することに相当する。すなわち、この仮説は Hebb の仮説を包含する。また、学習信号 γ として、どのような関数を用いるかで異なった型の学習を説明できる点で、より一般的なものになっている。

この基本仮説をもとに、学習方程式を導く。それは離散時間で考えると、次のようになる。

$$w(t+1) = w(t) + C \gamma(t) x(t) \quad (2.2)$$

ここに、 C は学習の効率を表す比例定数、また

$$\gamma(t) = \gamma[x(t), w(t)]$$

は時間 t の学習信号である。簡単のため、 w の初期値を 0 とすると、式 (2. 2) より

$$w(t+1) = C \sum_{t'=1}^t \gamma(t') x(t') \quad (2.3)$$

が得られる。入力信号の系列は、エルゴード的な定常環境E(式(2.1))から選ばれたサンプルである。したがって、この時間平均を、定常環境Eについてのアンサンブル平均(2.2.4参照)でおき換えて考えれば、wはEの情報構造を十分に反映することが期待される。しかし、このままでtを無限大にすると、右辺は限りなく増大する。そこで、数学的な取扱いを簡単にするため、w(t)は学習によって増加するとともに少しずつ減衰するものとして、式(2.2)の代わりに

$$w(t+1) = a w(t) + C r(t) x(t) \quad (2.4)$$

という学習方程式を考える。aは $0 < a < 1$ を満たす定数である。このとき、式(2.3)は

$$w(t+1) = C \sum_{t'=1}^t a^{t-t'} r(t') x(t') \quad (2.5)$$

となる。すなわち、 $w(t+1)$ は $r(t') x(t')$ に $a^{t-t'}$ を掛けた重みつき和であり、重みは、時間 t' が過去にさかのぼるに従って指数的に小さくなる。しかし、aが十分に1に近いならば、これはやはり $r(t') x(t')$ のEについてのアンサンブル平均の整数倍に近づく。

学習の収束を議論するには、時間tを連続的に扱った方が便利である。そこで、式(2.4)の代わりに

$$\tau \dot{w}(t) = -w(t) + C r(t) x(t) \quad (2.6)$$

という微分方程式を考え、これを学習方程式と呼ぶ。τは時定数である。式(2.6)を積分すると

$$w(t) = C \int_{-\infty}^t \frac{1}{\tau} \exp\left\{-\frac{t-t'}{\tau}\right\} r(t') x(t') \quad (2.7)$$

と書ける。w(t)は、離散的な場合と同様に $r(t') x(t')$ の重みつき平均になる。

2.2.4 学習の収束

学習方程式(2.6)の収束理論について述べる。x, wの関数R(x, w)が存在して、これをwで微分すると、学習方程式の右辺

$$\frac{\partial R(x, w)}{\partial w} = w - C r(x, w) x \quad (2.8)$$

が得られる場合を考える。ここに、 $\partial R / \partial w$ はRのwについての勾配で、 $\partial R / \partial w_j$ を成分とするベクトル

$$\frac{\partial R}{\partial w} = \left(\frac{\partial R}{\partial w_1}, \frac{\partial R}{\partial w_2}, \dots, \frac{\partial R}{\partial w_n} \right)$$

である。関数Rを用いると、学習方程式(2.6)は

$$\tau \dot{w} = - \frac{\partial R [x(t), w(t)]}{\partial w} \quad (2.9)$$

と書ける。学習方程式がRを用いて書ける場合を、ポテンシャル関数をもつ学習という。Rを学習のポテンシャル関数という。とくに、学習信号rが $w^T x$ の関数 $r = k(w^T x)$ で与えられる場合、そのポテンシャル関数は

$$R(w, x) = \frac{1}{2} |w|^2 - C K(w^T x)$$

ただし、

$$K(\eta) = \int r(\eta) d\eta$$

で与えられる。

学習方程式(2.6)において、入力x(t)は各時間ごとに、Eから独立に選ばれる。

学習によってwの変化する方向は $-\partial R / \partial w$ であるが、これはxとしてEの中から何が選ばれるかに依存する。そこで、 $-\partial R / \partial w$ をEの中の全信号について平均した値、すなわちアンサンブル平均を考える。Eについての平均（アンサンブル平均）を $\bar{\cdot}$ で表すと、一般にxの関数A(x)のE（式(2.1)）での平均は

$$\overline{A(x)} = \frac{1}{L} \sum_{i=1}^L p_i A(x_i) \quad (2.10)$$

である。wを固定してxについてとったR(x, w)のアンサンブル平均は、

$$\overline{L(w)} = \overline{R(x, w)} = \frac{1}{L} \sum_{i=1}^L p_i R(x_i, w) \quad (2.11)$$

である。 $\partial R / \partial w$ のアンサンブル平均は

$$\overline{\frac{\partial R}{\partial w}} = \frac{\partial \overline{L(w)}}{\partial w} \quad (2.12)$$

と書ける。L(w)はwのみに依存し、信号xには依存しない。これを損失関数と呼ぶ。学習方程式(2.9)をEについて平均すると、

$$\dot{\overline{w}} = - \frac{\partial \overline{L(w)}}{\partial w} \quad (2.13)$$

$\dot{\overline{w}}$ は、現在の荷重がwであるときの、学習によるwの変化方向の期待値を表す。したがって、学習過程において、wは平均としてL(w)が減少する方向に動いていき、結局L(w)の値は減少する。L(w)が w_a で最小値をとり、ほかに極小値をもたないゆるやかな関数であるとする、wは学習によって w_a に近づく。方程式(2.9)のような確率過程の数学的性質は、確率近似法で詳細に研究されている。それによれば、Eのもとでの学習によって、wの期待値 \overline{w} は w_a に収束し、その w_a からのず

れを表す分散は、 $\Delta T / \tau$ が小さくなるにつれて、いくらでも小さくなる。したがって、これからは、情報構造Eの環境での学習に対しては、学習方程式(2.9)の代わりに、これを平均化した平均学習方程式

$$\dot{\overline{w}} = - \frac{\partial \overline{L(w)}}{\partial w} \quad (2.14)$$

を考えればよい。これは、x(i)の個々の選択に依存せず、情報構造Eを直接に反映する方程式である。

学習により、wは

$$\frac{\partial \overline{L(w)}}{\partial w} = 0$$

を満たすw、すなわち

$$w - C \overline{\gamma(x, w)} x = 0 \quad (2.15)$$

を満たすwに収束する。これは

$$w = C \frac{1}{L} \sum_{i=1}^L p_i \gamma(x_i, w) x_i \quad (2.16)$$

と書ける。

ポテンシャル関数Rをもたない学習の場合にも、学習方程式を平均した平均学習方程式

$$\dot{\overline{w}} = -w + C \overline{\gamma} x \quad (2.17)$$

が得られるから、wが収束するときは、これは式(2.15)を満たすwに収束する。この場合も、wの平均値からのゆらぎは、 $\Delta T / \tau$ が小さければいくらでも小さくで

きる。したがって、学習の収束先については、式(2.14)あるいは式(2.17)の平均学習方程式を考えればよい。

2.2.5 Hebbの学習法⁽¹⁹⁾

Hebbの学習法では、神経細胞は自分が興奮したとき、このときのみ学習する。すなわち、出力値が0, 1の二値の場合、学習信号 η として細胞の出力

$$z = 1 (w^T x - h)$$

を用いるもので、

$$\eta = z$$

である。ここに、 h は神経細胞のしきい値、 T はベクトルの転置を表す。いま、

$$g(u) = \int_0^u 1(\eta) d\eta = \begin{cases} u & u > 0 \\ 0 & u \leq 0 \end{cases}$$

としよう。このとき、Hebb学習のポテンシャル関数は

$$R(x, w) = \frac{1}{2} |w|^2 - C g(w^T x - h) \quad (2.18)$$

になる。Rを環境情報Eについて平均すると、損失関数は

$$L(w) = \frac{1}{2} |w|^2 - C \sum_l p_l g(w^T x_l - h) \quad (2.19)$$

となる。Hebbの学習法に従えば、シナプス荷重はこのL(w)の極小値に収束する。この極小値は

$$\frac{\partial L}{\partial w} = 0$$

すなわち

$$\begin{aligned} w &= C \sum_{l=1}^L p_l 1(w^T x_l - h) x_l \\ &= \begin{cases} C \sum_{l=1}^L p_l x_l & (w^T x_l - h > 0) \\ 0 & (w^T x_l - h \leq 0) \end{cases} \quad (2.20) \end{aligned}$$

を満たす。これは、 w が、この細胞を興奮させるような入力 x_l の平均値に収束することを意味する。

L(w)は一般に、いくつかの極小点をもつ。各極小点が学習方程式の安定平衡点になる。したがって、Hebb学習ではシナプス荷重の学習は多安定になり、一つの細胞がどの平衡点へ収束するかは一意的には決まらず、wの初期値に依存する。したがって、それぞればらばらな初期値をもつ多数の神経細胞が共通な環境Eから入力を受けた場合に、各細胞はそれぞれどれかの極小点に収束していく。このような多安定学習は、特徴抽出機構の形成、概念形成などの教師なし学習において本質的な役割を果たす。

2. 3 一次元神経場における興奮パターン力学

2. 3. 1 神経場の方程式

図2. 2 に一次元神経場のモデルを示す。神経場の方程式は甘利によって、次式のように入えられている。

$$\tau \frac{\partial u(\xi, t)}{\partial t} = -u(\xi, t) + \int v(\xi, \xi') f[u(\xi', t)] d\xi' + s(\xi, t) - h(\xi, t) \quad (2.21)$$

ここに、各変数の意味は次の通りである。

$u(\xi, t)$: 時刻 t における神経場上の位置 ξ にある神経細胞の膜電位 (興奮度を示す量)

$v(\xi, \xi')$: 神経場上の位置 ξ' にある細胞から ξ にある細胞への結合の重みを示す関数

$f[\cdot]$: 神経細胞の膜電位とその細胞の出力の関係を与える関数 (出力関数)

$s(\xi, t)$: 位置 ξ にある細胞への時刻 t における入力




図2. 2 一次元神経場のモデル

$h(\xi, t)$: 位置 ξ にある細胞の時刻 t におけるしきい値に相当する量
ここで、更に次のことを仮定する。

1) 場は一様で、かつ等方的である。

これにより、細胞相互間の結合の重みはその間の距離のみに依存し、

$$v(\xi, \xi') = v(|\xi - \xi'|) \text{ となる。}$$

2) 神経細胞間の結合は相互抑制型である (図2. 3 参照)。

3) 出力関数 f として単位階段関数

$$f[u] = 1[u] = \begin{cases} 1 & (u > 0) \\ 0 & (u \leq 0) \end{cases}$$

を用いる。

4) しきい値 h は一定の値をとる。

以上の仮定のもとで、場の方程式 (2. 21) は次のようになる。

$$\tau \frac{\partial u(\xi, t)}{\partial t} = -u(\xi, t) + \int v(\xi - \xi') 1[u(\xi', t)] d\xi' + s(\xi, t) - h \quad (2.22)$$




図2. 3 相互抑制結合の結合荷重関数

2. 3. 2 一様入力に対する局在興奮の力学

入力 s が定数であるとき、場の一區間に起こった興奮がその後どのような振舞いをするのかを調べる。時刻 t における場の膜電位の分布を $u(\xi, t)$ とする。 $u(\xi, t)$ が正になっている部分を場の興奮領域と呼ぶ。膜電位が u であるときの興奮領域を

$$R[u] = \{ \xi \mid u(\xi, t) > 0 \} \quad (2.23)$$

と表す。

興奮領域は一般に、いくつかの区間の和になっている。興奮領域の一つの区間を局在興奮と呼ぶ。とくに、局在興奮が一つしかないとき、すなわち興奮領域が $\lambda_1 < \xi < \lambda_2$ と書ける単一の区間

$$R[u] = (\lambda_1, \lambda_2)$$

であるとき、これを孤立局在興奮という。

いま、膜電位の分布 $u(\xi, t)$ があって、これが孤立局在興奮を表しているとする。興奮している区間は時間とともに変化していく。時刻 t の興奮領域を $\xi_1(t)$ から $\xi_2(t)$ まで、すなわち

$$R[u(\xi, t)] = (\xi_1(t), \xi_2(t)) \quad (2.24)$$

とすると、興奮領域の幅は

$$\lambda(t) = \xi_2(t) - \xi_1(t) \quad (2.25)$$

である。また、興奮領域の境界 $\xi_i(t)$ ($i=1, 2$) における波形 $u(\xi, t)$ の勾配の絶対値を

$$c_1 = \frac{\partial u(\xi_1, t)}{\partial \xi}, \quad c_2 = -\frac{\partial u(\xi_2, t)}{\partial \xi} \quad (2.26)$$

とする。このとき、興奮領域の幅の変化に関して次の二つの定理が成立する。

[定理 2. 1]

一様入力 s のもとで、孤立局在興奮の幅 $\lambda(t)$ は次の方程式に従って変化する。

$$\frac{d\lambda(t)}{dt} = \frac{1}{\tau c} [V(\lambda) + s - h] \quad (2.27)$$

ここに、

$$V(\lambda) = \int_0^\lambda v(\eta) d\eta, \quad (2.28)$$

c は

$$\frac{1}{c} = \frac{1}{c_1} + \frac{1}{c_2}$$

により定まる正の数（時間 t に依存する）である。

(証明)

時間 t における $u(\xi, t)$ の興奮領域の区間を

$$R[u(\xi, t)] = (\xi_1(t), \xi_2(t))$$

とする。これは時間と共に変化していく。時間が t から $t + d t$ に微小に変化したとき、興奮領域の境界が $d \xi_1$, $d \xi_2$ だけ変化したとしよう。すると

$$\xi_i(t + d t) = \xi_i(t) + d \xi_i \quad (i = 1, 2)$$

である。 ξ_1 , $\xi_1 + d \xi_1$ はそれぞれ時間 t , $t + d t$ での興奮領域の境界であるから

$$u(\xi_1, t) = 0$$

$$u(\xi_1 + d\xi_1, t + dt) = 0$$

が成立する。後者をTaylor展開すると

$$\frac{\partial u(\xi_1, t)}{\partial \xi} d\xi_1 + \frac{\partial u(\xi_1, t)}{\partial t} dt = 0$$

が得られる。これを変形すると

$$\frac{d\xi_1}{dt} = - \frac{\partial u(\xi_1, t)}{\partial t} / \frac{\partial u(\xi_1, t)}{\partial \xi}$$

となる。これは興奮領域の境界 ξ_1, ξ_2 の移動速度を表す方程式になっている。ここで、 $\partial u(\xi_1, t) / \partial t$ を求める。場の方程式(2.22)より

$$\tau \frac{\partial u(\xi_1, t)}{\partial t} = -u(\xi_1, t) + \int v(\xi_1 - \xi') I [u(\xi', t)] d\xi' + s - h$$

が成り立つ。ここで、 $u(\xi_1, t) = 0$ 、また $R[u(\xi, t)] = (\xi_1, \xi_2)$ であるから

$$\tau \frac{\partial u(\xi_1, t)}{\partial t} = \int_{\xi_1}^{\xi_2} v(\xi_1 - \xi') d\xi' + s - h$$

が得られる。

v についての積分の項は、式(2.28)と $v(\xi)$ が偶関数であることを用いると

$$\int_{\xi_1}^{\xi_2} v(\xi_1 - \xi') d\xi' = \int_0^{\xi_2 - \xi_1} v(\xi') d\xi' = V(\xi_2 - \xi_1)$$

$$\int_{\xi_1}^{\xi_2} v(\xi_2 - \xi') d\xi' = \int_{\xi_1 - \xi_2}^0 v(\xi') d\xi' = V(\xi_2 - \xi_1)$$

と書ける。したがって

$$\frac{\partial u(\xi_i, t)}{\partial t} = \frac{1}{\tau} \{V(\xi_2 - \xi_1) + s - h\} \quad (i = 1, 2)$$

一方、 $\partial u(\xi_i, t) / \partial x$ は波形の勾配であるから、式(2.26)を代入して

$$\frac{d\xi_1}{dt} = - \frac{1}{\tau c_1} [V(\xi_2 - \xi_1) + s - h]$$

$$\frac{d\xi_2}{dt} = \frac{1}{\tau c_1} [V(\xi_2 - \xi_1) + s - h]$$

が得られる。興奮領域の幅 $\lambda(t)$ の変化速度は

$$\frac{d\lambda(t)}{dt} = \frac{d\xi_2(t)}{dt} - \frac{d\xi_1(t)}{dt}$$

であるから、上式を差し引くと、式(2.27)が得られる。

(証明終り)

[定理2.2]

一様入力 s のもとで、幅 λ の孤立局在興奮は、 $V(\lambda) + s - h$ が正のときにその領域が拡大し、負のときに縮小する。平衡状態にある局在興奮の幅 λ は

$$V(\lambda) + s - h = 0 \quad (2.29)$$

を満足する。平衡状態にある幅 λ の孤立局在興奮は、結合の荷重 $dV(\lambda) / d\xi = v$

(λ)が正のときは不安定、負のときは安定になる。

(証明)

局在興奮の興奮領域の幅を λ とすると、 $d\lambda/dt$ の正負に応じてその領域は伸縮する。とくに、平衡状態のときは

$$\frac{d\lambda}{dt} = 0$$

すなわち、式(2.29)を満足する。また、式(2.29)を満足する λ が $\delta\lambda$ だけ変化すると、 $V(\lambda+\delta\lambda)=V(\lambda)+v(\lambda)\delta\lambda$ であるから、 $d(\delta\lambda)/dt=v(\lambda)\delta\lambda/\tau c$ となる。

$$\frac{dV(\lambda)}{d\xi} = v(\lambda) < 0$$

が成立しているときはこの解は安定で、興奮幅が λ から少しずれた場合に、時間がたつにつれて幅はもとに戻る。しかし、 $v(\lambda) > 0$ の場合は、ずれはますます増大する。すなわち、この局在興奮は不安定である。

(証明終り)

2.4 基本競合系

2.4.1 モデル

n 個の素子 E_1, E_2, \dots, E_n が互いに競合する基本競合系を考える。系は図2.4に示すように、 w_1 の結合荷重で自己フィードバック結合をもつ n 個の素子からなる。系はこのほかに一つの抑制性素子 I をもち、各素子の出力は結合荷重 1 で抑制性素子に入る。逆に抑制性素子の出力は、結合荷重 w_2 で各素子を抑制する。素子 E_i への入力を s_i 、しきい値を h_i 、抑制性素子のしきい値を h_2 とする。各素子は連続時間で動作するものとする。系の方程式は

$$\dot{u}_i = -u_i + w_1 f(u_i) - w_2 g(v) - h_i + s_i \quad (i = 1, 2, \dots, n)$$

$$\tau \dot{v} = -v + \sum_{i=1}^n f(u_i) - h_2 + s_a \quad (2.30)$$




図2.4 基本競合系

と書ける。ここに、 $\dot{}$ は時間微分、 $f(u)$ は興奮性素子の出力関数、 $g(v)$ は抑制性素子の出力関数、 s_a は抑制性素子への入力で通常は0におく。

解析を簡単にするため、出力関数を次のように定める。

$$f(u) = 1 [u] = \begin{cases} 1 & (u > 0) \\ 0 & (u \leq 0) \end{cases} \quad (2.31)$$

$$g(v) = \begin{cases} v & (v > 0) \\ 0 & (v \leq 0) \end{cases} \quad (2.32)$$

2. 4. 2 基本競合系の平衡状態

入力 s_1, s_2, \dots, s_n を受けて、 n 個の興奮性の素子は互いに競合する。一つの素子が興奮すると、その興奮は共通の抑制性素子を介してほかの素子の興奮を妨げる。いま、 $0 \leq s_i < s_{max}$ とする。また、系が次の動作をもつものとする。

(1) すべての入力が一定値 s_{min} 以下であるときには、どの素子も興奮せず、系は静止の状態のままである。

(2) s_{min} を越える入力 s_i が多数ある場合には、最大の s_i を受ける素子ただ一つが興奮し、ほかの素子は興奮しない。

(3) 一度ある素子が競合に打ち勝って興奮すると、入力 s_i が消失したあとでも、系の状態をリセットしないかぎり、この素子は安定に興奮を保持する。

上記の性質をもつためには、系のパラメータ、 h_1, h_2, w_1, w_2 はどのような値でなくてはならないかを考える。

まず、静止状態を考える。この状態は、すべての入力 s_i が一定値 s_{min} を越えないとき、系の安定平衡状態である。静止状態では、 $f(u_i) = 0$ であるから、抑制性素子の方程式は、

$$\tau \dot{v} = -v - h_2$$

となる。すなわち、抑制性素子の状態は

$$v = -h_2$$

に収束する。抑制性素子も静止状態にあるから、

$$h_2 > 0$$

である。また、

$$g(v) = g(-h_2)$$

であるから、興奮性素子の方程式

$$\dot{u}_i = -u_i - h_1 + s_i \quad (i = 1, \dots, n)$$

より、 $u_i = s_i - h_1$ が得られる。したがって、

$$h_1 = s_{min} > 0 \quad (2.33)$$

に選んでおけば、すべての s_i が s_{min} より小さいとき、このときに限り、 $u_i < 0$ ($i = 1, \dots, n$) となり、静止状態は系の安定平衡状態である。

次に、系の興奮状態を考える。いま、どれか一つの素子が興奮し、ほかの $n-1$ の素子は興奮しないとする。一般性を失うことなく、興奮している素子は E_1 であると仮定する。このとき、抑制性の素子 I は E_1 からの入力 $f(u_1)$ をもらうので、その方程式は

$$\tau \dot{v} = -v + 1 - h_2$$

となる。したがって、 I の状態は

$$v = 1 - h_2$$

に収束する。競合の相互作用が働くためには、このときに抑制性素子が興奮し、ほか

の素子を抑えなければならない。すなわち、

$$h_2 < 1 \quad (2.34)$$

が必要である。このとき、抑制性素子からの出力は

$$g(v) = 1 - h_2$$

となるから、興奮性素子 E_i の方程式は

$$u_i = -u_i + w_1 - w_2(1 - h_2) - h_1 + s_i$$

$$u_i = -u_i - w_2(1 - h_2) - h_1 + s_i \quad (i \neq 1)$$

となるはずである。この方程式の平衡状態は

$$u_i = w_1 - w_2(1 - h_2) - h_1 + s_i$$

$$u_i = -w_2(1 - h_2) - h_1 + s_i \quad (i \neq 1)$$

である。したがって、

$$w_1 - w_2(1 - h_2) - h_1 > 0 \quad (2.35)$$

$$-w_2(1 - h_2) - h_1 + s_{max} < 0 \quad (2.36)$$

が成立していれば、一度競合に勝った E_1 は s_1 の値がたとえ0になろうとこのまま興奮を保持するし、ほかの E_i はたとえ s_i が最大値 s_{max} になっても、もはや E_1 に打ち勝つことはできない。この状態は系がリセットされて再び静止状態に戻るまで続く。

競合の結果勝ち残って興奮する素子はどれか一つでなくてはならない。そこで、いま仮に、二つの素子(E_1 と E_2 とする)がともに興奮を保持したと仮定する。そのとき抑制性素子は2の入力を受け、その出力は

$$g(v) = 2 - h_2$$

になる。したがって、 u_1 と u_2 の方程式は

$$\dot{u}_i = -u_i + w_1 - w_2(2 - h_2) - h_1 + s_i \quad (i = 1, 2)$$

であり、その平衡状態は

$$u_i = w_1 - w_2(2 - h_2) - h_1 + s_i \quad (i = 1, 2)$$

となる。もし、

$$w_1 - w_2(2 - h_2) - h_1 + s_{max} < 0 \quad (2.37)$$

が満たされていれば、 s_1 、 s_2 の値が何であろうと、 E_1 、 E_2 の二つが興奮したままである状態は起こらないことは明かである。

以上の条件、式(2.31)～(2.37)をまとめると、系のパラメータの満たすべき条件は

$$(1) \quad h_1 = s_{min} > 0 \quad (2.38)$$

$$(2) \quad 1 > h_2 > 0 \quad (2.39)$$

$$(3) \quad w_2 > \frac{s_{max} - h_1}{1 - h_2} \quad (2.40)$$

$$(4) \quad (2 - h_2)w_2 + h_1 - s_{max} > w_1 > (1 - h_2)w_2 + h_1 \quad (2.41)$$

となる。これらの条件を満足する範囲を図2.5に示す。

以上をまとめると、次の定理が得られる。

[定理2.3]

上記の(1)～(4)を満たす基本競合系は次の性質をもつ。




図 2. 5 基本競合系のパラメータの範囲

- (1) 入力 s_1 がすべて h_1 より小さいとき、このときのみ静止状態は安定平衡状態である。
- (2) どれか一つの素子のみが興奮している状態は、 s_1, \dots, s_n の値のいかんによらず安定平衡状態である。
- (3) 二つまたはそれ以上の素子が興奮する状態は安定平衡状態にならない。

2. 4. 3 競合過程

基本競合系は、 s_{min} より大きい入力が入った場合に、ただ一つの素子が興奮状態で生き残る。実際に生き残る素子は、最大の入力を受ける素子であることを示す。いま、すべての素子の初期値 $u_i(0)$ が等しいとしよう。そして、 E_1 と E_2 が受ける入力は

$$s_1 > s_2$$

としよう。このとき、

$$U(t) = u_1(t) - u_2(t)$$

とおくと、式(2. 30)より

$$\dot{U}(t) = -U(t) + w_1 \{ f[u_1(t)] - f[u_2(t)] \} + s_1 - s_2$$

が得られる。 f は単調増加関数であり、 $s_1 - s_2 > 0$ であるから、 $U(t)$ の初期値が

$$U(0) \geq 0$$

であれば、以後

$$U(t) > 0$$

すなわち、

$$u_1(t) > u_2(t)$$

のみである。すなわち、競合過程を通じて、 $u_1(t)$ の大小関係は s_1 の大小関係に従う。最終的に興奮状態で残れる素子はただ一つであるから、結局最大入力を受ける素子のみが興奮したままで残る。

競合の途中では、いくつもの素子が興奮することがあるが、最終的には最大入力を受ける素子が生き残る。

2. 5 結言

この章では、甘利によって与えられた神経回路網の数理理論の中から、とくに本論文に関連が深く、その基礎となる神経細胞の学習理論、神経場の興奮パターン力学理論、および基本競合系の数理モデルを抜粋して概説した。神経細胞の学習理論（とくに多安定学習）、興奮パターン力学理論は認識細胞の自己形成（第3章、4章）の基礎となるものである。また、基本競合系は連想記憶における連想の分岐機能（第6章 計算機実験）で用いられる。

3. 1 緒言

大脳の視覚野には、直線やエッジなどの基本的な図形の特徴に選択的に反応する多数の神経細胞(特徴抽出細胞)が多数存在することが知られている^{(25), (26)}。これらの神経細胞は、視覚野の中にでたらめに置かれているのではなく、一定の規則にしたがって整然と配列され、いわゆるコラム構造をなしている。すなわち、同じ傾きのスリットやエッジに対して反応する細胞が皮質の表面から垂直に柱状に並んでいる。この細胞の柱は方位コラムと呼ばれる。たとえば、垂直の方位コラムには垂直のスリット、エッジ、角に反応する細胞が含まれている。その隣には垂直より約 10° 傾いたスリットやエッジに反応する細胞を含む方位コラムがある。この方位コラムと直交する形で眼優位コラムがある。眼優位コラムは右眼優位と左眼優位という二つのコラムからなっている。右眼優位コラムの中心部の細胞は右眼からの、左眼優位コラムの中心部の細胞は左眼からの、境界部の細胞は両眼からの視覚入力に反応する。左右の優位コラムと $0^\circ \sim 180^\circ$ の18個の方位コラムが一組となって超コラムを形成している。

視覚野で分析された単純な線などの局所的な情報は階層構造を通して、視覚前野などのより高次のレベルで総合され、大局的に判断される。感覚系の最も高次のレベルでは、顔に反応する顔細胞や角に反応する三角細胞など、単純な線や角ではなくて、より複雑な図形に特異的に反応する細胞が見いだされている。

反応選択性をもつ特徴抽出細胞は先天的にできあがったものでも、その後のある特定の期間の視覚体験に大きな影響を受けることが、生理学実験によって明らかにされている^{(9), (11), (22), (27)}。とくに、異常な視覚体験の場合には、その異常環境に適合する新たな特徴抽出細胞が形成されることが知られている。このように、視覚体験は特徴抽出細胞の形成に大きな役割を果たしている。このことは、より高次の情報処理過程にも共通する、神経系の普遍的な性質であると考えられる。

ここでは、特定の入力刺激あるいはその集合にのみ反応して興奮する細胞を認識細胞と呼ぶことにする。そのような細胞が、環境から与えられる入力刺激に対してどのように自己形成されるか、その自己形成機構を明らかにすることは脳の情報処理機能を解明する上で重要である。

認識細胞の自己形成に関して、甘利一竹内⁽⁵⁾は興奮性シナプスと抑制性シナプスの両者の可塑性を考慮し、学習による認識細胞の形成理論を与えている。しかし、これ

には特徴パターンの発火率がほぼ一定という条件が課せられていて、包含関係にあるパターンを分離する機能はない。包含関係にあるパターンの認識細胞の形成に関して平井のモデル⁽²⁸⁾があるが、学習時における同一パターンの繰返し提示、シナプス荷重の最小和の保存性の条件が課せられている。福島^{(15), (81)}はコグニトロンに2乗平均抑制細胞を採用することによって、ある程度合理的なパターン選択特性をもつことを示している。他にも、認識細胞の自己形成に関して多くのモデル^{(17), (18), (35), (36), (38), (40), (77)}が提案されているが、いずれも特徴パターンの直交性、提示順序の指定、発火率の一定性、シナプス荷重和の一定性等の制約条件のうちのいくつかを課せられている。これらの制約条件を取り除き、また高次機能にとって都合のよい特性をもつ、より一般化されたモデルをつくる必要がある。

この章では、まず甘利一竹内によって提案された認識細胞の自己形成モデルについて述べる。また、その能力について考察する。次に、そのモデルに非線形特性をもつ1個の抑制性細胞を付加した改良モデルを提案し、これによって甘利一竹内のモデルに課せられた特徴パターンの発火率の一定性の条件を取り除き、包含関係にあるパターンの場合にも個々のパターンに対する認識細胞が形成できることを示す。更に、1個の学習パラメータのみを変化させることによって、類似度による種々の基準でのパターン分類が都合よく行えて、モデルが連想記憶、パターン認識等の情報処理機能にとって具合のよい特性をもつことを明らかにする。

3. 2 認識細胞の自己形成モデル

3. 2. 1 甘利一竹内のモデル

図3. 1に自己形成モデルを示す。第1層は n 個の入力からなる入力層であり、第2層は認識細胞層である。第2層の各細胞は第1層のすべてから修正可能なシナプス荷重を介して興奮性入力を受ける。同時に、外部から大きさ一定の抑制性入力 x_0 を修正可能なシナプス荷重を介して受ける。

第2層の細胞は、この入力をもとに、シナプス荷重を修正することによって、環境内の一つ、あるいはいくつかの特徴パターンからなる特定の集合にのみ反応する認識細胞になっていく。図は第2層の細胞 j と入力との結合関係を示している。ここに、 w_{ji} は細胞 j と興奮性入力 i との結合荷重、 w_{j0} は細胞 j と抑制性入力 x_0 との結合荷重である。

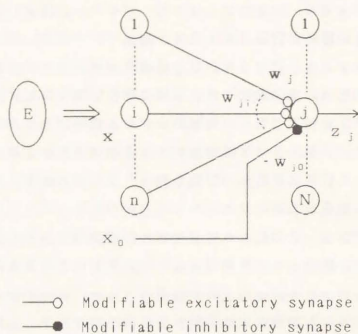


図 3. 1 認識細胞の自己形成モデル

3. 2. 2 学習

モデルはエルゴード的な常環境,

$$E = \begin{bmatrix} x_1 & \dots & x_1 & \dots & x_L \\ p_1 & \dots & p_1 & \dots & p_L \end{bmatrix} \quad (3.1)$$

ただし,

$$x_1 = (x_{11}, \dots, x_{1l}, \dots, x_{1n})^T$$

から入力を受けるものとする。ここに、 x_1 は特定の特徴を表す特徴パターン、 p_1 は x_1 の出現確率である。モデルの入力は、確率 p_1 でランダムかつ独立に選ばれた x_1 からなる時系列 $x(t)$ として与えられる。ここに、 $x(t)$ は時刻 t における特徴パターンを意味する。また、選ばれた特徴パターンは一定時間表示される。それゆえ、 $x(t)$ は

環境Eの情報構造を反映するエルゴード的な時系列となる。

第2層の細胞 j は、入力 $x(t)$ 、 x_a をもとに、結合荷重 w_{ji} 、 w_{ja} を適応的に修正することにより、認識細胞となる。その学習は学習方程式

$$\begin{aligned} \tau \dot{w}_j(t) &= -w_j(t) + C \gamma x(t) \\ \tau_a \dot{w}_{ja}(t) &= -w_{ja}(t) + C_a \gamma x_a \end{aligned} \quad (3.2)$$

ただし,

$$\begin{aligned} w_j &= (w_{j1}, \dots, w_{ji}, \dots, w_{jn})^T \\ \gamma = 1(u_j) &= 1(w_j^T x(t) - w_{ja} x_a) \end{aligned}$$

にもとづいて行われる。ここに、 $\dot{w}_j(t)$ は $w_j(t)$ の時間微分、 γ は学習信号、 C 、 C_a は学習定数、 τ 、 τ_a は時定数である。平均学習方程式は

$$\begin{aligned} \tau \dot{w}_j(t) &= -w_j(t) + C \overline{\gamma x(t)} \\ \tau_a \dot{w}_{ja}(t) &= -w_{ja}(t) + C_a \overline{\gamma x_a} \end{aligned} \quad (3.3)$$

となる。細胞 j は特定の特徴集合 A ($\in E$)に属する特徴パターンにのみ反応するとき、 A の認識細胞といわれる。このとき、シナプス荷重(w_j, w_{ja})は、学習方程式が多数の平衡状態をもつことから、そのうちの一つに収束する。特徴集合 A に対応する平衡状態を(w_j^A, w_{ja}^A)とすれば、

$$\begin{aligned} w_j^{A^T} x_1 - w_{ja}^A x_a &> 0 & (x_1 \in A) \\ w_j^{A^T} x_1 - w_{ja}^A x_a &\leq 0 & (x_1 \notin A) \end{aligned} \quad (3.4)$$

となることから、 w_j^A, w_{ja}^A は式(3.3)より

$$w_j^a = C \sum_{l \in A} p_l x_l = C p(A) x^a$$

$$w_{ja}^a = C a \sum_{l \in A} p_l x_a = C a p(A) x_a \quad (3.5)$$

となる。ここに、

$$x^a = \sum_{l \in A} p_l x_l / p(A), \quad p(A) = \sum_{l \in A} p_l$$

である。また、 $l \in A$ は $x_l \in A$ 、 $p(A)$ はAに属する特徴パターンの出現確率を示す。平衡状態 (w_j^a, w_{ja}^a) の近傍での変分方程式は、 γ の変分が

$$\delta \gamma = \delta [1(w_j^T x - w_{ja} x_a) = 0 \quad (w_j^T x - w_{ja} x_a \neq 0)$$

となることから、式(3.2)より

$$\tau \delta \dot{w}_j = -\delta w_j, \quad \tau a \delta \dot{w}_{ja} = -\delta w_{ja}$$

となる。それゆえ、 (w_j^a, w_{ja}^a) は安定な平衡状態となる。逆に、細胞jは、平衡状態 (w_j^a, w_{ja}^a) のとき、式(3.4)を満足する。したがって、細胞jは、平衡状態 (w_j^a, w_{ja}^a) で、特徴集合Aの安定な認識細胞になる。

3.2.3 自己形成の理論

第2層の細胞はシナプス荷重の学習を通して特定の特徴集合の認識細胞になっていく。なかには反応しないまま残る細胞もある。どの細胞がどの特徴集合の認識細胞になるかはシナプス荷重の初期値に依存する。荷重の初期値が適当に広く分布していれば、どの特徴集合に対しても認識細胞が形成されるようになる。そこで、どのような性質をもつ特徴集合の認識細胞が形成されるかを考える。

特徴パターン x_l と x_a の内積、およびAに属する特徴パターン x_l と x_a 間の内積のA上での平均を、それぞれ

$$g_{1a} = x_l^T x_a, \quad g_a^a = \frac{1}{p(A)} \sum_{l \in A} p_l x_l^T x_a \quad (3.6)$$

とする。この場合、細胞jがAの認識細胞であれば、細胞jへの入力和 u_j は x_a に対して、

$$u_j = \begin{cases} w_j^a x_a - w_{ja}^a x_a > 0 & (x_a \in A) \\ w_j^a x_a - w_{ja}^a x_a < 0 & (x_a \notin A) \end{cases} \quad (3.7)$$

が成立している。この入力和 u_j は、式(3.5)、(3.6)より、

$$u_j = C p(A) (g_a^a - C a x_a^2 / C) \quad (3.8)$$

となる。ゆえに、任意の x_a に対して式(3.7)が成立するための条件は

$$\max_{m \in A} x \{g_m^a\} < \phi < \min_{m \in A} \{g_m^a\} \quad (3.9)$$

ただし、

$$\phi = \frac{C a}{C} x_a^2$$

となる。逆に、式(3.9)が満たされるとき式(3.7)が成立し、 (w_j^a, w_{ja}^a) は学習方程式の安定な平衡状態となる。それゆえ、細胞jはAの認識細胞となる。この際、細胞jがどのようなAの認識細胞になるかは学習パラメータ ϕ に依存する。

ϕ の選び方によって、どのような認識細胞が形成されるかをみてみよう。ここに、特徴パターンの発火個数は一定で、

$$g_{11} = x_l^T x_l = a \quad (3.10)$$

とする。また、Aに属する x_1 と x_m 、およびAに属する x_1 と属さない x_m との内積は、

$$\begin{aligned} g_{1m} &= x_1^T x_m \geq a s_1 \quad (x_1, x_m \in A) \\ g_{1m} &= x_1^T x_m \leq a s_2 \quad (x_1 \in A, x_m \notin A) \end{aligned} \quad (3.11)$$

ただし、

$$0 \leq s_1 < s_2 \leq 1$$

を満たすものとする。この場合、Aに属する特徴パターンは同じ集合に属するすべての特徴パターンと $a s_1$ 以上の内積をもち、集合に属さないパターンとは $a s_2$ 以下の内積をもつことになる。このAに対して、

$$\begin{aligned} p(A) \min_{m \in A} \{g_m^a\} &= \min_{m \in A} \left\{ \sum_{l \in A} p_l g_{lm} \right\} \\ &\geq \min \{p_m(a - a s_1)\} + a s_1 \\ &> a s_1 \end{aligned}$$

$$\begin{aligned} p(A) \max_{m \in A} \{g_m^a\} &= \max_{m \in A} \left\{ \sum_{l \in A} p_l g_{lm} \right\} \\ &\leq a s_2 \end{aligned}$$

が成立する。それゆえ、 ϕ が

$$a s_2 < \phi < a s_1 \quad (3.12)$$

を満たすのであれば、Aにのみ反応する認識細胞が形成されることになる。

特徴集合Aが一つの特徴パターンからなる場合を考えよう。この場合、 $A = \{x_1\}$ ゆえ、

$$\begin{aligned} g_{1m} &= x_1^T x_m = a \quad (x_m \in A) \\ g_{1m} &= x_1^T x_m \leq a s_2 \quad (x_m \notin A) \end{aligned} \quad (3.13)$$

$$p(A) = p_1$$

となる。これより、

$$\min_{m \in A} \{g_m^a\} = g_{11} = a$$

$$\max_{m \in A} \{g_m^a\} = g_{1m} \leq a s_2$$

が成り立つ。ここで、Aが二つ以上の特徴パターンからなると仮定すると、 $p(A) g_m^a$ は、式(3.6)より

$$p(A) g_m^a = p_m g_{mm} + \sum_{\substack{l \neq m \\ l \in A}} p_l g_{lm} \leq p_m a(1 - s_2) + a s_2 p(A)$$

となる。Aが二つ以上の特徴パターンを含むことから、 $p_m / p(A) \leq 1/2$ となる $x_m \in A$ が存在する。それゆえ、

$$\min \{g_m^a\} \leq \frac{1}{2} a(1 + s_2) \quad (3.14)$$

となる。したがって、一つの特徴パターンのみに反応する認識細胞を形成するためには、

$$\frac{a(1 + s_2)}{2} \leq \phi < a$$

となるように ϕ を選べばよい。

3. 2. 4 モデルの能力

すべてのパターンが一定の発火個数をもつ場合、一定の性質を有すAに対する認識細胞は、 ϕ を適当に選ぶことにより形成できる。しかし、一般に特徴パターンの発火個数は種々の値を取る。このため、 ϕ を適当に選ぶことができない場合が生じる。その結果モデルはうまく動作しなくなる。簡単な例で考えてみよう。

いま、環境は4個の特徴パターン、

$$E = \begin{pmatrix} x_1 & x_2 & x_3 & x_4 \\ 1/4 & 1/4 & 1/4 & 1/4 \end{pmatrix}$$

からなるものとする。さらに、特徴パターン間には、

$$g_{11} = x_1^T x_1 = \begin{cases} a & (l=1, 2) \\ b & (l=3, 4) \end{cases}$$

$$g_{12} = x_1^T x_2 = c, \quad g_{34} = x_3^T x_4 = d,$$

$$d < b < c < a$$

の関係が成り立っているものとする。この場合、個々の特徴パターンのみに反応する認識細胞が形成されるためには、 ϕ は少なくとも次の関係、

$$\frac{a+c}{2} < \phi < a, \quad \frac{b+d}{2} < \phi < b$$

を同時に満足する必要がある。しかし、両者を同時に満たす ϕ は存在しない。このため、 ϕ が前者の式を満たす場合には、 x_3 あるいは x_4 に対する認識細胞は形成されなくなる。逆に、 ϕ が後者の式を満足する場合には、 x_1 あるいは x_2 に対する認識細胞が形成されなくなる。

特徴パターンが包含関係にある場合、いま x_3 が x_1 に包含されている場合を考えよう。式(3.9)の $\max_{m \in A} \{g_m^a\}$ 、 $\min_{m \in A} \{g_m^a\}$ は、 $A = \{x_3\}$ とすれば、

$$g_{13} = x_1^T x_3 = b$$

ゆえ、

$$\max_{m \in A} \{g_m^a\} = g_1^a = g_{13} = b$$

$$\min_{m \in A} \{g_m^a\} = g_3^a = g_{33} = b$$

となる。それゆえ、式(3.9)を満たす ϕ は存在せず、 x_3 に対する認識細胞は形成できない。

3. 3 モデルの改良

3. 3. 1 モデル

図3.2に甘利-竹内のモデルに改良を加えた自己形成モデルを示す。モデルは第1層(特徴パターン層)、第2層(認識細胞層)、および非線形特性をもつ抑制性細胞Gからなる。この抑制性細胞Gが、甘利-竹内のモデルに新しく付加したものである。細胞Gは第1層のすべてから固定シナプス1を介して入力を受け、それに応じた抑制出力を第2層の各細胞に送る。第2層の細胞j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、修正可能な抑制性シナプス荷重 $-w_{j0}$ を介して細胞Gからの入力を受ける。第1層には、エルゴード的定常環境(式(3.1))から選ばれた特徴パターン x_1 が確率 p_1 にしたがって一定期間与えられる。特徴パターン x_1 が与えられたとき、細胞Gの出力 z_{10} 、および第2層の細胞jの出力 z_{1j} は、それぞれ


$$z_{10} = g(u_{10}), \quad z_{1j} = f(u_{1j}) \quad (3.15)$$

但し、

$$u_{10} = \sum_{i=1}^n x_{1i}, \quad g(u_{10}) = \sqrt{u_{10}},$$

$$u_{1j} = w_{j1}^T x_1 - w_{j0} z_{10}$$

とする。ここに、 x_{1i} は x_1 のi要素を示す。各細胞の出力関数の形を図3.3に示す。



- Modifiable excitatory synapse
- Modifiable inhibitory synapse
- Unmodifiable excitatory synapse

図 3. 2 認識細胞の自己形成モデル




図 3. 3 細胞の出力関数

3. 3. 2 認識細胞の自己形成

第2層の細胞jの修正可能なシナプス荷重 $w_{j1}, -w_{j0}$ は、式(3. 2)と同様に環境Eから与えられる特徴パターン x_1 をもとに、学習方程式

$$\begin{aligned} \tau \dot{w}_{j1} &= -w_{j1} + C_j \gamma_j x_1 \\ \tau_0 \dot{w}_{j0} &= -w_{j0} + C_j' \gamma_j z_{j0} \end{aligned} \quad (3.16)$$

但し、

$$\gamma_j = 1(z_{j1}),$$

に従って修正されるものとする。ここに、 \dot{w} は w の時間微分、 C_j, C_j' は細胞jの学習定数、 γ_j は細胞jの学習信号、 τ, τ_0 は時定数で十分大きいものとする。このとき、平均学習方程式は

$$\begin{aligned} \tau \dot{\bar{w}}_{j1} &= -\bar{w}_{j1} + C_j \overline{\gamma_j x_1} \\ \tau_0 \dot{\bar{w}}_{j0} &= -\bar{w}_{j0} + C_j' \overline{\gamma_j z_{j0}} \end{aligned} \quad (3.17)$$

であり、細胞jのシナプス荷重の平衡状態は

$$\begin{aligned} \bar{w}_{j1} &= C_j \sum_{1 \in \psi} p_1 x_1 \\ \bar{w}_{j0} &= C_j' \sum_{1 \in \psi} p_1 z_{j0} \end{aligned} \quad (3.18)$$

となる。

第2層の細胞がどのようなパターン集合の認識細胞になるかは、その学習パラメータ $\phi_j (= C_j' / C_j)$ に依存する。以下に、認識細胞の自己形成に関する定理を与える。ここで、パターン x_1, x_m の類似度を

$$\rho(x_1, x_n) = \frac{x_1^T x_n}{\sqrt{\mu_1} \sqrt{\mu_n}} \quad (3.19)$$

但し,

$$\mu_1 = \sum_{i=1}^n x_{1i}$$

と定義する。このとき、次の定理が成立する。

[定理 3. 1]

$\phi_j = \rho_a$ は、細胞 j が互いに ρ_a より大きい類似度をもつ特徴パターンからなる集合 ψ_a の安定な認識細胞になるための必要十分条件である。ここに、 ϕ_j は細胞 j の学習パラメータである。

(証明)

細胞 j が ψ_a の安定な認識細胞であるとき、 $x_n \in \psi_a$ 、 $x_n \notin \psi_a$ に対して

$$\begin{aligned} \bar{w}_j x_n - \bar{w}_{j0} \sqrt{\mu_n} &> 0 & (x_n \in \psi_a) \\ \bar{w}_j x_n - \bar{w}_{j0} \sqrt{\mu_n} &\leq 0 & (x_n \notin \psi_a) \end{aligned} \quad (3.20)$$

が成立する。ここで、細胞 j は ψ_a の認識細胞であるから、 \bar{w}_j 、 \bar{w}_{j0} は

$$\bar{w}_j = C_j \sum_{l \in \psi_a} p_l x_{1l}^T, \quad \bar{w}_{j0} = C_j' \sum_{l \in \psi_a} p_l \sqrt{\mu_l} \quad (3.21)$$

を満足する。これを式(3. 20)に代入することによって

$$C_j \sum_{l \in \psi_a} p_l \sqrt{\mu_l} \sqrt{\mu_n} (\rho(x_1, x_n) - \phi_j) > 0 \quad (x_n \in \psi_a) \quad (3.22)$$

$$C_j \sum_{l \in \psi_a} p_l \sqrt{\mu_l} \sqrt{\mu_n} (\rho(x_1, x_n) - \phi_j) \leq 0 \quad (x_n \notin \psi_a)$$

を得る。これより、 $\phi_j = \rho_a$ が成立する。したがって、 $\phi_j = \rho_a$ は細胞 j が ψ_a の認識細胞になるための必要条件である。

逆に、 $\phi_j = \rho_a$ であるとする。 $x_1 \in \psi_a$ とするとき、任意の $x_n \in \psi_a$ 、 $x_n \notin \psi_a$ に対して、 $\rho(x_1, x_n) \leq \phi_j < \rho(x_1, x_n)$ であることから、

$$C_j \sum_{l \in \psi_a} p_l x_{1l}^T x_n - C_j' \sum_{l \in \psi_a} p_l \sqrt{\mu_l} \sqrt{\mu_n} > 0 \quad (x_n \in \psi_a) \quad (3.23)$$

$$C_j \sum_{l \in \psi_a} p_l x_{1l}^T x_n - C_j' \sum_{l \in \psi_a} p_l \sqrt{\mu_l} \sqrt{\mu_n} \leq 0 \quad (x_n \notin \psi_a)$$

が成立する。ここで、

$$C_j \sum_{l \in \psi_a} p_l x_{1l} = \bar{w}_j^T, \quad C_j' \sum_{l \in \psi_a} p_l \sqrt{\mu_l} = \bar{w}_{j0} \quad (3.24)$$

とおくと、式(3. 23)は

$$\begin{aligned} \bar{w}_j^T x_n - \bar{w}_{j0} \sqrt{\mu_n} &> 0 & (x_n \in \psi_a) \\ \bar{w}_j^T x_n - \bar{w}_{j0} \sqrt{\mu_n} &\leq 0 & (x_n \notin \psi_a) \end{aligned} \quad (3.25)$$

となる。これは細胞 j がシナプス荷重 \bar{w}_j 、 \bar{w}_{j0} のとき、パターン集合 ψ_a の認識細胞であることを示す。更に、式(3. 24)の \bar{w}_j 、 \bar{w}_{j0} は ψ_a に対する平衡状態である。したがって、 $\phi_j = \rho_a$ は細胞 j が ψ_a の認識細胞になるための十分条件である。

(証明終り)

この定理より、学習パラメータを変えることによって、大分類から細分類まで、分類の粗きを変えた種々のパターン分類の仕方が可能であることがわかる。特に、環境 E 内の異なった二つのパターン間の類似度の最大値を ρ_{max} で表すと、

$$\rho_{max} < \phi_j < 1 \quad (3.26)$$

なる学習パラメータを選ぶことによって、包含関係にあるパターンに対しても、個々

のパターンの認識細胞を重ねりのない形で形成でき、すべてのパターンを分離できる。これらの性質は連想記憶やパターン認識等の情報処理機能にとって都合のよい特性であると考えられる。また、このモデルは制約条件が少ない点で、従来のモデルに比べ一般的なものになっている。

3. 4 計算機実験

計算機によるシミュレーション実験を通して、類似度に依存した認識細胞が形成され、種々のパターン分類が行われることを示す。実験では、第1層、および第2層の細胞数を

$$n = 64, N = 25$$

とした。また、学習における時定数を

$$\tau = \tau_0 = 1.0$$

とした。すべてのシナプス荷重の初期値は $[0, 1]$ 上の一様分布から決定した。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次元ベクトルに変換することによって作成した。環境Eは、5個の2値パターンからなる




図3.4 特徴パターン

表3.1 特徴パターン間の類似度

	x_1	x_2	x_3	x_4	x_5
x_1	1.00	0.86	0.68	0.58	0.53
x_2	0.86	1.00	0.80	0.67	0.47
x_3	0.68	0.80	1.00	0.85	0.39
x_4	0.58	0.67	0.85	1.00	0.35
x_5	0.53	0.47	0.39	0.35	1.00

$$E = \begin{pmatrix} x_1 & x_2 & x_3 & x_4 & x_5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \end{pmatrix}$$

とした。図3.4に $x_i (i = 1 \sim 5)$ に対応する2次元図形を示す。また、式(3.19)から求めた各パターン間の類似度を表3.1に示す。図3.5に学習結果を示す。第2層の細胞の学習パラメータはすべて等しくした。すなわち $\phi_j (j = 1 \sim n) = \phi$ (一定)とした。図3.5(a), (b), (c)はそれぞれ学習パラメータ $\phi = 0.54, 0.83, 0.95$ とした場合の結果である。図において、第2層の細胞は 5×5 の配列で示した。細胞上の数字(1~5)は、学習の結果、その細胞がその番号を添字として持つ特徴パターンの認識細胞になったことを示している。図から、 $\phi = 0.54$ のときは、特徴パターンの類似度に応じて2個のパターン集合 $\psi_1 = \{x_1, x_2, x_3, x_4\}$ と $\psi_2 = \{x_5\}$ の認識細胞が形成されていることがわかる。同様に、 $\phi = 0.83$ のときは3個のパターン集合 $\psi_1 = \{x_1, x_2\}$, $\psi_2 = \{x_3, x_4\}$, $\psi_3 = \{x_5\}$ の認識細胞が形成されている。特に、 $\phi = 0.95$ のときは、 $\psi_1 = \{x_1\}$, $\psi_2 = \{x_2\}$, $\psi_3 = \{x_3\}$, $\psi_4 = \{x_4\}$, $\psi_5 = \{x_5\}$ のようにすべてのパターンに対してその認識細胞が形成されている。このように学習パラメータの値に応じて、類似度による種々の基準でのパターン分類が行われていることがわかる。更に、包含関係にあるパターンに対しても認識細胞が重ねりのない形で形成でき、パターンを分離できることがわかる。

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

(a) $\phi=0.54$

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

(b) $\phi=0.83$

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

(c) $\phi=0.95$

図 3. 5 認識細胞

3. 5 結言

甘利一竹内によって提案された認識細胞の自己形成モデルについて述べ、そのモデルの能力について考察した。次いで、そのモデルに非線形特性をもつ1個の抑制性細胞を付加することによって、その機能を拡張し、包含関係にあるパターンに対する認識細胞を形成できることを示した。更に、1個の学習パラメータを変化することによって、特徴パターンの類似度に応じて認識細胞が形成され、種々の基準のもとでパターン分類が行えることを示した。これによって、モデルが高次機能にとって都合のよい特性をもち、更に制約条件が少ない点で一般的なモデルであることを明らかにした。

第4章 認識細胞のトポグラフィー的配列構造^{(29), (69), (102)}

一側抑制型相互結合を有する神経場一

4. 1 緒言

認識細胞の自己形成については、第2章で述べたように多くの研究がなされているが、(0, 1)パターンを入力として取り扱ったものが多い。連続値パターンに対する認識細胞の形成についてもいくつかの考察^{(69), (76)}があるが、十分な議論はなされていない。認識細胞の形成に関するもう一つの重要なことはそのトポグラフィー的配列構造である。トポグラフィー構造の形成に関するいくつかの研究がある。

Willshaw-Malsburg⁽⁵⁹⁾は自己形成の学習の論理と神経場とを結合し、神経場における受容野の構造が外界の位相構造と一致するいわゆるソマトトピーの自己形成を論じている。一方、甘利^{(4), (6), (7), (44)}は場理論の立場から、二つの神経場間のトポグラフィー構造形成の論理を解明している。また、その理論をもとに、丸山-甘利⁽⁸⁴⁾は単位円上の一点を表す2次元の連続値ベクトルを入力とし、自己組織によって神経場上にこの信号空間を離散的に表現するようなコラム構造が形成されることを数学的に解析するとともに、興味あるシミュレーション結果を与えている。しかし、この場合の入力は一つのパラメータ θ (角度)によって特徴づけられる2次元信号空間であり、より一般的な信号空間に対する考察が重要である。Kohonen^{(32), (33)}は入力信号の位相構造を神経場に写像する抽象的なモデルを提案し、自己組織によってフィンランド語の音韻が2次元神経場にどのように配置されるか、その様子をシミュレーション実験により調べている。しかし、学習の際入力信号が与えられるごとに最大出力素子の検出が必要なことや、各素子が特定の入力信号のみに反応する認識素子になっていない点で、認識細胞のトポグラフィー的配列構造の形成モデルとして十分なものであるとは言い難い。また、入力信号の集合に対する認識細胞の自己形成についても十分な考察を行っていない。

この章では、 n 次元連続値パターンに対して認識細胞領域(認識細胞のトポグラフィー的配列構造)を自己形成する基本的な自己組織モデルを提案する。そのモデルは、側抑制型の相互結合を有する神経細胞層とフィードフォワード形にそれを抑制する抑制性細胞からなっている。ここでは、 n 次元連続値パターンからなる環境のもとで、そのモデルが特定のパターン集合に対する認識細胞領域を自己形成するための必要条件を求め、モデルの性質を調べる。これにより、一定の条件のもとで、入力パターン




図 4. 1 認識細胞領域の自己形成モデル

間の類似度に依存したパターン集合の認識細胞領域が形成できること。また形成される認識細胞領域の幅が入力パターンの出現確率やそのノルムに依存することを示す。次いで、その条件のもとで計算機によるシミュレーション実験を行い、モデルの動作を確かめる。更に、実験を通して認識細胞のトポグラフィ的配列を形成できること、すなわち類似度の高いパターン同士は神経場の互いに近い場所にその認識細胞領域を形成できることを示す。

4. 2 理論

4. 2. 1 モデルの概略

図 4. 1 に神経場における認識細胞領域の自己形成モデルを示す。モデルは第 1 層（入力パターン層）、第 2 層（神経細胞層）、および抑制性細胞 G からなる。第 1 層には一定の環境 E からの n 次元入力パターン x が与えられる。第 2 層は、1 次元 (ξ 軸上) に密に並んだ多数の神経細胞からなる一様かつ等方的な神経場とする。第 2 層の神経細胞は第 1 層のすべてから修正可能な興奮性シナプス荷重を介して入力を受け、その際第 2 層の位置 ξ (ある点を原点として) にある細胞と第 1 層とのシナプス




図 4. 2 側抑制型相互結合 $v(\xi, \xi')$

荷重を、

$$w(\xi) = (w_1(\xi), \dots, w_i(\xi), \dots, w_n(\xi))^T$$

と表す。抑制性細胞 G は第 1 層のすべてから固定シナプス 1 を介して入力を受け、それに応じた抑制性出力を第 2 層の細胞に送る。第 2 層の位置 ξ にある細胞と抑制性細胞 G との抑制性シナプス荷重を $w_0(\xi)$ と表す。第 2 層の位置 ξ にある細胞は第 1 層にパターンが与えられると、その入力を興奮性シナプス荷重 $w(\xi)$ を介して受ける。また、抑制性細胞 G からの出力を抑制性シナプス荷重 $w_0(\xi)$ を介して受ける。更に、第 2 層の位置 ξ にある細胞と位置 ξ' にある細胞とは結合荷重 $v(\xi, \xi')$ で表される側抑制型の相互結合をもつ。ここに、場の一様性と等方性から、 $v(\xi, \xi')$ は細胞間の距離 $|\xi - \xi'|$ のみに依存し、 $v(\xi, \xi') = v(|\xi - \xi'|)$ である。また、側抑制結合は図 4. 2 に示すように、 $\xi' = \xi$ ($|\xi - \xi'| = 0$) でただ一つの極大値をとり、 $v(\xi, \xi') < 0$ の領域が無限大まで続いている、すなわち

$$\lim_{\xi' \rightarrow \infty} v(\xi, \xi') = \lim_{\xi' \rightarrow \infty} v(|\xi - \xi'|) = v(\infty) \neq 0$$

なる関数形である。この側抑制型の相互作用は認識細胞のトポグラフィ的配列形成において重要な役割を果たす。第 2 層は第 1 層からの入力パターンをもとに、シナプス荷重 $w(\xi)$ 、 $w_0(\xi)$ を自己組織的に修正することにより、入力パターンに対する認

識細胞領域を形成する神経場である。

4. 2. 2 細胞の入出力関係

モデルの第1層には、前と同様にエルゴード的定常環境(式(3.1))から独立に選ばれたn次元入力パターン x_i が一定期間与えられる。ただし、入力パターン x_i は連続値を成分としてもつベクトルで、その成分 x_{ij} は正の値である。第1層に x_i が与えられたときの抑制性細胞Gの出力 z_{ig} は

$$z_{ig} = g(u_{ig}) \quad (4.1)$$

但し、

$$u_{ig} = \|x_i\|^2 \\ g(u_{ig}) = \sqrt{u_{ig}}$$

であるとする。ここに、 $\|x_i\|$ は x_i のノルムであり、入力**の強さを意味する**。この抑制性細胞Gは、入力パターン間の類似度に依存した認識細胞領域を形成する上で重要な役割を果たす。パターン x_i を入力したときの第2層の位置 ξ にある神経細胞の時刻 t における膜電位を $u(\xi, x_i, t)$ と表す。ここでは、その細胞が第1層のすべての素子と細胞Gからシナプス荷重を介して入力を受けると同時に、相互結合による入力を受けることから、 $u(\xi, x_i, t)$ は次の方程式に従うものとする(2.3.1参照)

$$\tau_u \dot{u}(\xi, x_i, t) = -u(\xi, x_i, t) + w(\xi)^T x_i - w_g(\xi) z_{ig} \\ + \int v(\xi - \xi') h[u(\xi', x_i, t)] d\xi' \quad (4.2)$$

ここに、 \dot{u} は u の時間微分、 τ_u は時定数、 T はベクトルの転置を表す。また、 $u(\xi, x_i, t)$ は位置 ξ' の細胞の膜電位、 $h[u(\xi', x_i, t)]$ はその細胞の出力で、ここでは、

$$h[u(\xi', x_i, t)] = 1 [u(\xi', x_i, t)]$$

$$= \begin{cases} 1 & (u(\xi', x_i, t) > 0) \\ 0 & (u(\xi', x_i, t) \leq 0) \end{cases} \quad (4.3)$$

とする。

4. 2. 3 神経場の平衡状態

入力パターン x_i が与えられているとき、 $u(\xi, x_i, t) > 0$ なる ξ の領域を興奮領域とよぶ。その興奮領域は一般にはいくつかの局在興奮領域(単に局在興奮ともいう)からなる。特に、興奮領域が $\lambda_1 < \xi < \lambda_2$ と書ける単一の区間であるとき、これを孤立局在興奮という。孤立局在興奮の振舞いについては、そのパターン力学が調べられていて、2.3.2で示したように、孤立局在興奮の幅入(= $\lambda_1 - \lambda_2$)の安定性に閉じて、側抑制結合荷重 v が

$$v(\lambda) < 0 \quad (4.4)$$

を満たすとき、 λ は安定であり、

$$v(\lambda) > 0$$

のとき、 λ は不安定であることがわかっている。

x_i が与えられたときの平衡状態の膜電位は、式(4.2)において $\dot{u}(\xi, x_i, t) = 0$ としたものとなるゆえ、これを $\bar{u}(\xi, x_i)$ とすると、

$$\bar{u}(\xi, x_i) = w(\xi)^T x_i - w_g(\xi) z_{ig} \\ + \int v(\xi - \xi') 1[\bar{u}(\xi', x_i)] d\xi' \quad (4.5)$$

となる。式(4.5)のシナプス荷重の学習の結果(4.2.4参照)、神経場(第2層)に、平衡状態において特定のパターン集合みに属するパターンにのみ反応する安

定な孤立局在興奮が形成されるとき、すなわち、学習を通して

$$\begin{aligned} \bar{u}(\xi, x_1) &> 0 & (x_1 \in \psi) \\ \bar{u}(\xi, x_a) &\leq 0 & (x_a \in \psi) \end{aligned}$$

なる ξ の安定な領域が形成されるとき、その領域にある細胞を、パターン集合 ψ の認識細胞領域とよぶ。なお、認識細胞領域の幅は孤立局在興奮の幅 λ と一致する。

4. 2. 4 シナプス荷重の学習

第1層と第2層の位置 ξ にある細胞間の修正可能な興奮性シナプス荷重 $w(\xi)$ 、および抑制性細胞Gと第2層の位置 ξ にある細胞間の修正可能な抑制性シナプス荷重 $w_0(\xi)$ は環境Eから与えられる入力パターン x_i ($i=1 \sim L$)をもとに、学習方程式、

$$\begin{aligned} \tau \dot{w}(\xi) &= -w(\xi) + C \gamma(\xi) x_1 \\ \tau_0 \dot{w}_0(\xi) &= -w_0(\xi) + C' \gamma(\xi) z_{10} \end{aligned} \quad (4.6)$$

但し、

$$\begin{aligned} \gamma(\xi) &= 1 [u(\xi, x_1)], \\ 1 [u] &= 1 (u > 0), 0 (u \leq 0) \end{aligned}$$

に従って修正されるものとする。ここに、 \dot{w} は w の各成分の時間微分、 C 、 C' は学習定数、 τ 、 τ_0 は学習の速度を決める時定数で、膜電位における時定数 τ_0 に比べて十分大きいものとする。これにより、次の入力パターンが与えられるときには、式(4.2)における膜電位はすでに平衡状態に達しているものとみなすことができる。平均学習方程式は、

$$\begin{aligned} \tau \dot{\bar{w}}(\xi) &= -\bar{w}(\xi) + C \overline{\gamma(\xi) x_1} \\ \tau_0 \dot{\bar{w}}_0(\xi) &= -\bar{w}_0(\xi) + C' \overline{\gamma(\xi) z_{10}} \end{aligned} \quad (4.7)$$

と書ける。

シナプス荷重 $w(\xi)$ 、 $w_0(\xi)$ の学習により、一定の条件のもとでは、第2層に特定のパターン集合の認識細胞領域が形成される。そのとき、シナプス荷重 $w(\xi)$ 、 $w_0(\xi)$ は学習方程式の平衡解のうちの一つに収束する。その平衡状態を $\bar{w}(\xi)$ 、 $\bar{w}_0(\xi)$ と表すと、それは

$$\begin{aligned} \bar{w}(\xi) &= C \overline{\gamma(\xi) x_1} = C \sum_{i \in \psi} p_i x_i \\ \bar{w}_0(\xi) &= C' \overline{\gamma(\xi) z_{10}} = C' \sum_{i \in \psi} p_i z_{10} \end{aligned} \quad (4.8)$$

となる。ここに、 i はパターンの種類を示し、 ψ は特定のパターン集合を示す、 $i \in \psi$ は $x_i \in \psi$ を意味する。また、 p_i は x_i の出現確率を示す。

4. 3 認識細胞領域の形成

どのような条件のもとで、特定の入力パターン集合に対する認識細胞領域が形成されるかを考える。どのような認識細胞領域が形成されるかは、学習定数 C 、 C' 、細胞間の側抑制結合のパラメータ、および入力パターン間の類似度等に依存する。まず、モデルに関する制約条件を仮定する。次に、類似度に依存したパターン集合に対して認識細胞領域が形成されるための必要条件を導く。

4. 3. 1 制約条件

モデルにおけるパラメータやパターンに関して次の制約条件を仮定する。

(I) 学習定数の比 C'/C を学習パラメータ ϕ と表し、それは

$$0 < \phi < 1 \quad (4.9)$$

の範囲内に選ぶものとする。

(II) 側抑制結合 $v(\xi, \xi')$ ($= v(|\xi - \xi'|)$)は、 $\xi - \xi' = 0$ でただ一つの極大値をとり、 $|\xi - \xi'| > \xi_0$ の所では $v(\infty) = \text{const.}$ (< 0)が続いている関数形である(図4.2参照)。ここで、 $|\xi - \xi'|$ を η とおいたときの $v(\eta)$ の積分関数 $V(\xi)$ が

$$V(\xi) > v(\infty)\xi \quad (4.10)$$

を満足するものとする。ここに、

$$V(\xi) = \int_0^{\xi} v(\eta) d\eta$$

但し、

$$\eta = |\xi - \xi'|$$

である。\$V(\xi)\$は0から上昇し、最大値に達したのち減少し、そのこう配は\$\xi\$が大きくなるにしたがって\$v(\infty)\$に漸近していき、最終的に\$\xi \ge \xi_0\$では一定値\$v(\infty)\$になる。すなわち、\$y = V(\xi)\$のグラフは最終的に\$y = v(\infty)\xi\$のグラフと平行になる。式(4.10)は\$y = V(\xi)\$のグラフが\$y = v(\infty)\xi\$のグラフより常に上に位置する形をしているという条件である。図4.3にこの条件を満たす\$V(\xi)\$の形を示す。この条件は認識細胞領域を形成する上で重要な役割を果たす。




図4.3 積分関数\$V(\xi)\$の例

(III) パターン \$x_1, x_2\$ 間の類似度を

$$\rho(x_1, x_2) = \frac{x_1^T x_2}{\|x_1\| \|x_2\|} \quad (4.11)$$

と定義するとき、パターン集合 \$\psi\$ は次の条件を満たすものとする。

(1) \$\psi\$ に属する二つのパターン \$x_1, x_2\$ 間の類似度は

$$\rho(x_1, x_2) \geq \rho_0 \quad (4.12)$$

(2) \$\psi\$ に属するパターン \$x_1\$ と属さないパターン \$x_2\$ 間の類似度は

$$\rho(x_1, x_2) \leq \rho_0 \quad (4.13)$$

すなわち、\$\psi\$ はそれに属するパターン同士は \$\rho_0\$ 以上の類似度を持ち、\$\psi\$ に属するパターンと属さないパターン同士は \$\rho_0\$ 以下の類似度をもつようなパターン集合である。

(IV) パターン集合 \$\psi\$ に属するパターンの出現確率およびノルムは

$$p_1 \leq p_i \leq p_2 \quad (4.14)$$

$$d_1 \leq \|x_i\| \leq d_2 \quad (4.15)$$

とする。

このようなパターン集合の認識細胞領域が存在するためにはどのような条件が必要であるかを考える。ここでは、各パターン集合に対して孤立局在興奮が形成されるとする。この孤立局在興奮は、たとえば入力パターンが学習の初期段階において、第2層の電位分布 \$u\$ をある一点において最大とする性質をもつとき、適当な側抑制作用によって実現できる(孤立局在興奮の実際の形成については4.4で示される)。

4.3.2 必要条件の導出

パターン集合 \$\psi\$ に対して一つの認識細胞領域が形成されるための必要条件を求める。いま、平衡状態において、パターン集合 \$\psi\$ の孤立局在興奮(一つの認識細胞領域)が第2層の位置 \$\xi_0\$ を中心に幅入で存在し、それ以外の領域には別の任意のパターン集合 \$\psi'\$ の孤立局在興奮(認識細胞領域)が存在すると仮定する。そのとき、パターン \$x \in \psi\$ に対する第2層の膜電位 \$u(\xi, x \in \psi)\$ は、\$|\xi - \xi_0| \leq \lambda/2\$ の領域で、

$$\bar{u}(\xi, x \in \psi) = \bar{w}(\xi)^T x - \bar{w}_0(\xi) z_0$$

$$\begin{aligned}
& + \int v(\xi - \xi') \bar{u}(\xi', x) d\xi' \\
= & C \sum_{l \in \psi} p_l x_l^T x - C' \sum_{l \in \psi} p_l z_{l0} z_0 \\
& + \int_{\xi_a - \lambda/2}^{\xi_a + \lambda/2} v(\xi - \xi') d\xi' \\
= & s(x) + V(\xi - \xi_a + \lambda/2) - V(\xi - \xi_a - \lambda/2) \quad (4.16)
\end{aligned}$$

$|\xi - \xi_a| > \lambda/2$ の領域で,

$$\begin{aligned}
\bar{u}(\xi, x \in \psi) = & C \sum_{n \in \psi'} p_n x_n^T x - C' \sum_{n \in \psi'} p_n z_{n0} z_0 \\
& + \int_{\xi_a - \lambda/2}^{\xi_a + \lambda/2} v(\xi - \xi') d\xi' \\
= & s'(x) + V(\xi - \xi_a + \lambda/2) - V(\xi - \xi_a - \lambda/2) \quad (4.17)
\end{aligned}$$

但し,

$$s(x) = C \sum_{l \in \psi} p_l x_l^T x - C' \sum_{l \in \psi} p_l z_{l0} z_0 \quad (4.18)$$

$$s'(x) = C \sum_{n \in \psi'} p_n x_n^T x - C' \sum_{n \in \psi'} p_n z_{n0} z_0 \quad (4.19)$$

となる。

ここで、 $|\xi - \xi_a| \leq \lambda/2$ の領域は ψ の孤立局在興奮ゆえ、膜電位 $u(\xi, x \in \psi)$ は ψ に属するすべてのパターンに対して正である。ゆえに、式(4.16)より、

$$-s(x) < V(\lambda/2 + (\xi - \xi_a)) + V(\lambda/2 - (\xi - \xi_a)) \quad (4.20)$$

が成立する。

一方、 $|\xi - \xi_a| > \lambda/2$ の領域では、 $u(\xi, x \in \psi)$ は ψ に属するすべてのパターンに対して非正である。ゆえに、式(4.17)より

$$-s'(x) \geq V(\lambda/2 + (\xi - \xi_a)) + V(\lambda/2 - (\xi - \xi_a)) \quad (4.21)$$

が成立する。

ここで、 $V(\xi)$ の関数の性質 (式(4.10)) により、 $|\xi - \xi_a| \leq \lambda/2$ を満たすすべての ξ に対して、

$$V(\lambda) \leq V(\lambda/2 + (\xi - \xi_a)) + V(\lambda/2 - (\xi - \xi_a)) \quad (4.22)$$

また、 $|\xi - \xi_a| > \lambda/2$ を満たすすべての ξ に対して、

$$V(\lambda) \geq V(\lambda/2 + (\xi - \xi_a)) + V(\lambda/2 - (\xi - \xi_a)) \quad (4.23)$$

が成立する。ここに、等号は両式ともに $\xi - \xi_a = \lambda/2$ のときである。したがって、式(4.20)、(4.21)は、

$$-s(x) < V(\lambda) \quad (4.24)$$

$$-s'(x) \geq V(\lambda) \quad (4.25)$$

となる。ゆえに、式(4.24)、(4.25)より、 ψ に属するすべての x に対して

$$-s(x) < -s'(x) \quad (4.26)$$

が成立する。このとき、 $-s(x)$ 、 $-s'(x)$ が正負両方の値を取り得るため、

$$(1) -s(x) < 0 \quad \text{かつ} \quad -s'(x) < 0$$

$$(2) -s(x) < 0 \quad \text{かつ} \quad -s'(x) \geq 0$$

$$(3) -s(x) \geq 0 \quad \text{かつ} \quad -s'(x) > 0$$

の三つの場合が考えられる。まず、(1)の場合は、 $-s'(x) < 0$ より、

$$-s'(x) = \sum_{n \in \psi} p_n z_{n0} z_0 (C' - C\rho(x_n, x)) < 0$$

となり、すべての $x \in \psi$ に対して、

$$C' - C\rho(x_n, x) < 0$$

を満足しなければならない。ここで、

$$\min_x \{\rho(x_n, x)\} = 0$$

ゆえ、

$$\phi = C' / C < 0$$

となり、制約条件(式(4.9))に反する。

(3)の場合も同様に、 $-s(x) \geq 0$ より

$$\phi \geq 1$$

となり、制約条件(式(4.9))に反する。

ゆえに、(2)が常に成立する。(2)は式(4.18)、(4.19)により、

$$\begin{aligned} -s(x) &= C' \sum_{l \in \psi} p_l z_{l0} z_0 - C \sum_{l \in \psi} p_l x_l^T x \\ &= \sum_{l \in \psi} p_l z_{l0} z_0 (C' - C\rho(x_l, x)) < 0 \end{aligned} \quad (4.27)$$

かつ

$$\begin{aligned} -s'(x) &= C' \sum_{n \in \psi} p_n z_{n0} z_0 - C \sum_{n \in \psi} p_n x_n^T x \\ &= \sum_{n \in \psi} p_n z_{n0} z_0 (C' - C\rho(x_n, x)) \geq 0 \end{aligned} \quad (4.28)$$

となる。これにより、

$$C' - C\rho(x_l, x) < 0$$

かつ

$$C' - C\rho(x_n, x) \geq 0$$

が成立する。ここで、

$$\max_x \{\rho(x_n, x)\} = \rho_0$$

$$\min_x \{\rho(x_l, x)\} = \rho_0$$

であることから、

$$\rho_0 \leq \phi < \rho_0 \quad (4.29)$$

が成立する。ここに、 \max_x 、 \min_x はそれぞれ x に関する最大値、最小値を示す。

以上のことより、式(4.29)は $u(\xi, x \in \psi)$ がパターン集合 ψ に対して幅入の孤立局興奮平衡解をもつための必要条件であることがわかる。

また、パターン集合 ψ に対して、幅入の孤立局興奮が存在するとき、その λ は安定平衡解であるから、

$$\min_x \{-s'(x)\} < V_{max} \quad (4.30)$$

が成立する(図4.3参照)。ここに、 V_{max} は $V(\xi)$ の最大値である。これは

$$\begin{aligned} \min_x \{-s'(x)\} &= \min_x \left\{ \sum_{n \in \psi} p_n z_{n0} z_0 (C' - C\rho(x_n, x)) \right\} \\ &= p_l d_l^2 (C' - C\rho_0) \end{aligned} \quad (4.31)$$

ゆえ、

$$p_1 d_1^2 (C' - C \rho_0) < V_{max} \quad (4.32)$$

となる。ここに、 p_1 はパターンの出現確率の最小値、 d_1 はノルムの最小値である。式(4.32)も $u(\xi, x \in \psi)$ がパターン集合 ψ に対して幅 λ の孤立局在興奮平衡解をもつための必要条件である。したがって、パターン集合 ψ に対して、一つの認識細胞領域が形成されるための必要条件は式(4.29)、(4.32)ということになる。しかし、逆は成立しないことから、式(4.29)、(4.32)は一つの認識細胞領域が形成されるための十分条件ではない。

次に、パターン集合が一つのパターンからなる場合を考える。この場合も同様な議論によって必要条件を求めることができる。各パターンに対して一つの認識細胞領域が形成されるための必要条件は

$$\rho_0 \leq \phi < 1 \quad (4.33)$$

$$p_1 d_1^2 (C' - C \rho_0) < V_{max} \quad (4.34)$$

となる。ここに、 ρ_0 は異なる二つのパターン間の類似度の最大値である。

4.3.3 認識細胞領域幅の取束先

パターン集合 ψ に対して形成された認識細胞領域の幅 λ がどのような値に落ち着くかをみてみよう。 λ は ψ に属するすべての x に対して、式(4.24)、(4.25)を満たす。ここで、

$$\begin{aligned} \max_x \{-s(x)\} \\ &= \max_x \left\{ \sum_{1 \in \psi} p_1 z_{10} z_0 (C' - C \rho(x_1, x)) \right\} \\ &= p_1 d_1^2 (C' - C \rho_0) \end{aligned} \quad (4.35)$$

となり、また

$$\min_x \{-s'(x)\} = p_1 d_1^2 (C' - C \rho_0)$$

であることから、幅 λ は

$$p_1 d_1^2 (C' - C \rho_0) < V(\lambda) \leq p_1 d_1^2 (C' - C \rho_0) \quad (4.36)$$

を満たす範囲内 $[\lambda_0', \lambda_0]$ に落ち着くことになる(図4.3参照)。ここに、 p_1 はパターンの最小出現確率、 d_1 はパターンの最小ノルムである。逆に、式(4.36)を満たす λ を一つとってくれば、それに基づく解は学習の平衡状態である。このような平衡状態は式(4.36)からわかるように、連続的に多数あるから、安定性に関しては中立安定である。ゆえに、この近くの初期値から出発して学習すれば、このどれかの平衡状態に落ち着くことになり、興奮幅は一定の値になる。この他に平衡状態はあるかもしれない。しかし、4.4のシミュレーションではそこに示すような形に落ち着く。

パターン集合が一つのパターンからなる場合も同様の議論によって求めることができる。パターン x に対する認識細胞領域の幅は

$$p d^2 (C' - C) < V(\lambda) \leq p d^2 (C' - C \rho_0) \quad (4.37)$$

を満たす一定値に落ち着く。ここに、 p は入力パターン x の出現確率、 d はそのノルムである。式(4.37)は出現確率が大きい入力パターンほど、またノルム $d (= \|x\|)$ が大きい入力パターンほど幅 λ の範囲が広がること、すなわち神経場の広い領域に渡って認識細胞領域が形成される可能性があることを示している。

4.4 計算機実験

4.4.1 実験 I

前節で導かれた必要条件をもとに、計算機によるシミュレーション実験を行い、 n 次元入力パターンからなる環境下でのモデルの動作を確かめる。これにより、入力パターンの類似度に応じたパターン集合に対して認識細胞領域が神経場に形成されることを確かめる。また、実験により認識細胞のトポグラフィの配列が実現されることを示す。実験では、入力パターンとして、 $[0, 1]$ 上の一様分布からランダムに取り出した値をその成分として m 個の 10次元ベクトル $x_1(1.2)$, $x_2(1.3)$, $x_3(1.6)$, $x_4(1.9)$, $x_5(1.6)$ を用いた。ここに、括弧内の数字は各パターンのノルムを




図 4. 6 認識細胞領域の形成 (神経場の膜電位分布)
 $\phi = 0.90$

パターン集合 $\psi_1 = \{x_1, x_2, x_3\}$, $\psi_2 = \{x_4, x_5\}$ に対する認識細胞領域が形成されるための必要条件, 式(4. 29)より 0. 75 ($C' = 0.75, C = 1.0$) に設定した。また, v のパラメータの値は, 必要条件, 式(4. 32)より

$$b_1 = 2. 0, h_1 = 0. 14, b_2 = 1. 0, h_2 = 0. 1$$

とした。なお, パラメータ b_1 は形成される認識細胞領域幅の下限 (V_{min} を与える値) に, b_2 は抑制作用が神経場の全範囲に及ぶように設定した。この b_1 , b_2 の設定方法は以下の実験でも同様である。図 4. 6(a)での学習パラメータは, 各入力パターンに対して認識細胞領域が形成されるための必要条件, 式(4. 33)より 0. 90 ($C' = 0.90, C = 1.0$) に設定した。 v のパラメータの値は図 4. 5(a)と同じにした。これらのパラメータ値は必要条件, 式(4. 34)を満足する。これらの学習結果により, 学習パラメータの値によって, 類似度に依存したパターン集合あるいは各入力パターンに対する認識細胞領域を形成できることが確かめられた。図 4. 5(b), 図 4. 6(b)は側抑制型相互結合がない場合の学習結果を示す。図における数字はその位置の細胞がどのパターンの認識細胞であるかを示している。ここに, 数字はその数字を添字とする入力パターンを意味する。 C' , C の値は図 4. 5(a), 図 4. 6(a)と同じである。この結果が示すように, この場合には認識細胞は領域をなさない, このことは, 側抑制型相互結合が認識細胞領域の形成において重要な働きをすることを示している。また, 図 4. 6(a)より, 類似度の高いパターン同士は, 神経場の互いに近づく場所とその認識細胞領域を形成していることがわかる。このことは認識細胞のトポグラフィ的配列が実現されたことを示している。

次に, 入力パターンとして, 母音の音声データ ('ア', 'イ', 'ウ', 'エ', 'オ') を用いて実験を行った。その音声波形を付図 1 に示す。これは周波数 8 kHz でサンプリングしたものであり, $-1000[mV] \sim +1000[mV]$ の電圧レベルで表示されている。この実験では, 各波形の一周期の電圧レベルを 20 次元ベクトルで表現した入力パターンを用いた。その際, 各要素が負の値を取らないように $1000[mV]$ のバイアスを加えた。式(4. 11)から求めた各入力パターン間の類似度を付表 1 に示す。各入力パターンの出現確率はすべて等しく $1/5$ とした。また, 第 2 層の細胞数 N は 51 とした。学習パラメータ ϕ は, 式(4. 33)より 0. 97 ($C' = 0.97, C = 1.0$) とした。側抑制型相互結合 v のパラメータは, 式(4. 34)より

$$b_1 = 2.0, h_1 = 0.2, b_2 = 2.3, h_2 = 0.04$$

とした。付図2に学習結果（平衡状態における第2層の細胞の膜電位分布）を示す。

この結果からわかるように、各入力パターンに対して認識細胞領域が形成されている。また、波形として類似している‘ア’、‘エ’、‘オ’と‘イ’、‘ウ’の認識細胞領域が神経場において互いに隣接した状態で形成されている。このことから、入力におけるトポグラフィ構造の神経場への写像が実現されていることがわかる。

4.4.2 実験II

ここでは、認識細胞領域幅のパターンの出現確率（ p ）とパターンのノルム（ $\|x\|$ ）への依存性を確かめる。まず、出現確率（ p ）への依存性を明らかにするために、2個のパターン x_1 、 x_2 をもとに、ノルム（ $\|x\|$ ）を1に正規化したパターン x_1' 、 x_2' を用いた。パターンの出現確率をそれぞれ $9/10$ 、 $1/10$ とした。学習パラメータは、式(4.33)より $\phi = 0.90$ ($C' = 0.90, C = 1.0$) とした。 v のパラメータ




図4.7 認識細胞領域の形成（出現確率が異なる場合）
 $\phi = 0.90$



図4.8 認識細胞領域の形成（ノルムが異なる場合）
 $\phi = 0.90$

は前実験（図4.6）と同じにした。その学習結果を図4.7に示す。図において、○は神経細胞の興奮領域を示す。これは図4.8でも同様である。これより、出現確率が大きいパターンほど、神経場の広い領域に渡って認識細胞領域が形成されていることがわかる。

次に、パターンのノルム（ $\|x\|$ ）への依存性を明らかにするために、パターン x_1 の各成分の値を10倍したパターン x_1'' とパターン x_2' を用いた。出現確率は等しく $1/2$ とした。学習パラメータは、式(4.33)より $\phi = 0.90$ ($C' = 0.90, C = 1.0$) とした。 v のパラメータの値は、式(4.34)より

$$b_1 = 2.0, h_1 = 0.80, b_2 = 1.0, h_2 = 0.28$$

とした。その学習結果を図4.8に示す。この結果からわかるように、ノルムの大きい入力パターンほど、神経場の広い領域に渡って認識細胞領域が形成されている。

4.5 結言

神経場における認識細胞領域の自己形成に関する基本的な自己組織モデルを提案し、 n 次元連続値パターンからなる環境のもとで、特定のパターン集合の認識細胞領域を

自己形成するための必要条件を明らかにした。次いで、その必要条件のもとで計算機によるシミュレーション実験を行い、モデルの動作を確かめた。その結果として、一定の条件のもとで、入力パターン間の類似度に依存したパターン集合に対する認識細胞領域を形成できることが確かめられた。また、入力パターンの出現確率やノルムに依存した幅の認識細胞領域が形成されることが確かめられた。更に、計算機実験を通して、入力におけるトポグラフィー構造の神経場への写像を実現できること、すなわち類似度の高いパターン同士は、神経場の互いに近い場所に認識細胞領域が形成されることを示した。また、このことは母音の音声データを入力パターンとして用いた場合にも確かめられた。このような性質は外界情報の脳内表現の機構を示唆するものとして興味深い。しかし、ここでは、各パターン集合に対して一つの局在興奮（孤立局在興奮）が形成される場合のみを取り扱っている。また、導かれた条件は必要条件であるが十分条件ではない。複数個の局在興奮（認識細胞領域）が形成される場合も含めた詳しい解析が必要である。更に、モデルを神経系におけるより高次の機能と結びつけて考察することが、脳の情報処理機構を解明する上で必要である。

— 上位概念の連合を介した多重連想機能 —

5. 1 緒言

生体は環境から受ける入力（下位概念）をそのままの形で記憶、保持するのではなく、その特徴を自己組織的に捕らえ、それを骨組にして記憶を構造的に形成していく。すなわち、各入力を総合して上位概念を形成し、いくつかの上位概念を複雑に連合させることによって、個々の入力をこの枠組の中に記憶すると考えられる。連想機能もこの上位概念の連合を介して行われるのではないかと考えられる。一方、生物の神経系は、環境から多くの入力を受けると、特定の特徴集合のみに反応する認識細胞を自己組織的に形成していく。このことから、記憶には認識細胞が何らかの形で関与していると考えられる。このことを示唆する生理学的な報告もある⁽¹⁹⁾。この意味から、認識細胞と連想記憶との関わりを考察してみることは興味深い。

連想記憶に関しては、1972年頃までに、中野^{(37), (74)}、Kohonen⁽³⁸⁾らによってその原理が独立に提唱された。それ以来その原理にいろいろな工夫を加えた多くのモデルが提案されている。代表的なものに、相関行列の概念や直交学習、一般化逆行列の概念^{(3), (31)}を用いたモデル、パターン分離機能を用いたモデル^{(49), (54), (55), (81), (73)}などがある。更に、CrickらやHopfieldらの夢の解析と関連した学習と反学習を組み合わせたモデル^{(13), (23), (24)}、ホルツマン・マシンと呼ばれる自己想起形のモデル^{(1), (68)}、多重連想機能を実現した平井のHASPモデル^{(21), (78)}など興味あるものが提案されている。その他にも、自己組織的な考えを取り入れた連想記憶モデル^{(43), (48), (78)}があるが、いずれも上位概念の連合を介した高次の連想機能を追求めたものとはいえない。また、認識細胞と連想記憶を直接結びつけた検討は行っていない。

この章では、認識細胞に基礎をおく連想記憶モデルを提案する。これは第3章に示した認識細胞の形成と上位概念の形成とを直接結びつけることによって、認識細胞形成系を連想記憶に応用したものである。各キーパターンに複数個の記憶パターンが連合する多重連合環境下でモデルの動作を調べる。その結果、このモデルでは、従来区別されてきた相互想起と自己想起を統合した形で取り扱えること、また相互想起、自己想起両方において、記憶パターンの順次想起が比較的簡単に行えることを示す。これにより、認識細胞の果たす連想記憶への一つの役割を示唆するとともに、このモデ

ルが上位概念の連合を介する高次の連想機能を説明するための手がかりとなり得ることを明らかにする。

5. 2 学習過程

5. 2. 1 モデルの概略

図5. 1に認識細胞に基づく連想記憶モデルを示す。モデルは認識細胞の形成系(系-(I), 系-(II))と多重連合系(系-(III)), および自己連合系(系-(IV))からなる。認識細胞の形成系では、環境から与えられる特徴パターン(下位概

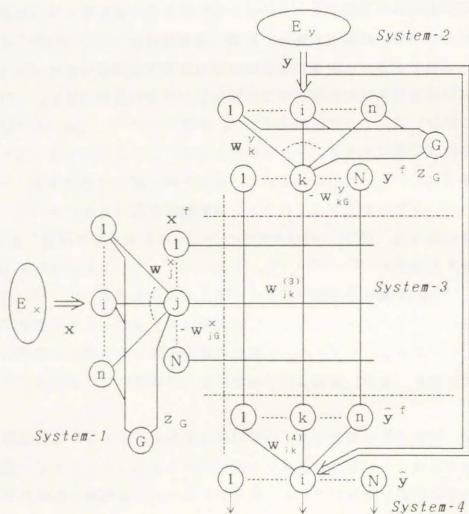


図5. 1 認識細胞に基づく連想記憶モデル

念)をもとに、特定のパターン集合のみに反応する認識細胞を自己組織的に形成し種々のパターン分類を行う。ここでは、系-(I)、および系-(II)に与えられる特徴パターン x, y がそれぞれキーパターンと記憶パターンに、また、認識細胞の出力パターン x', y' がそれぞれ x, y の上位概念に対応する。

多重連合系では、系-(I)と系-(II)によって形成されるキーパターンと記憶パターンの上位概念を多重に連合して、その関係を記憶していく。

自己連合系では、記憶パターン(下位概念)とその上位概念との関係を記憶していく。以下に、各系について説明する。

5. 2. 2 認識細胞の形成系

系-(I)、系-(II)は第3章で述べた認識細胞の形成系(図3. 2参照)である。系-(I)において、キーパターン x の情報源 E_x 、各細胞の入出力関係、第2層の細胞 j のシナプス荷重 w_{jk}^x 、 $-w_{jk}^x$ の学習方程式はそれぞれ式(3. 1)、(3. 15)、(3. 16)と同様に

$$E_x = \begin{bmatrix} x_1 & \dots & x_1 & \dots & x_L \\ p_1 & \dots & p_1 & \dots & p_L \end{bmatrix} \quad (5.1)$$

$$z_{j0} = g(u_{j0}), \quad x'_{ij} = f(u_{ij}) \quad (5.2)$$

$$\begin{aligned} \tau \dot{w}_{jk}^x &= -w_{jk}^x + C_j \gamma_j x_j \\ \tau \dot{w}_{jk}^{x0} &= -w_{jk}^{x0} + C_j' \gamma_j z_{j0} \end{aligned} \quad (5.3)$$

但し、

$$x_j = (x_{j1}, \dots, x_{j1}, \dots, x_{jn})^T$$

$$x_{ji} \in \{0, 1\}$$

$$u_{j0} = \sum_{i=1}^n x_{ji}, \quad g(u_{j0}) = \sqrt{u_{j0}}$$

$$u_{ij} = w_{ij}^T x_i - w_{j0}^T z_{i0}$$

$$r_j = 1 (x^T r_j)$$

で与えられるものとする。ここに、 $x^T r_j$ はキーパターン x_i に対する細胞 j の出力である。系-(II)も系-(I)と同様に情報源 E_v のもとで、記憶パターン y の認識細胞を形成する。ここで、記憶パターン y はキーパターン x が与えられたときに、次の条件付確率

$$p(y|x) = \begin{array}{c|cccc} & y_1 & \dots & y_t & \dots & y_{L'} \\ \hline x_1 & p_{11} & \dots & p_{1t} & \dots & p_{1L'} \\ | & | & & | & & | \\ x_i & p_{i1} & \dots & p_{it} & \dots & p_{iL'} \\ | & | & & | & & | \\ x_L & p_{L1} & \dots & p_{Lt} & \dots & p_{LL'} \end{array} \quad (5.4)$$

で x と連合するものとする。そのとき、記憶パターンの情報源 E_v は、式(5.1)と式(5.4)より

$$E_v = \begin{pmatrix} y_1 & \dots & y_t & \dots & y_{L'} \\ q_1 & \dots & q_t & \dots & q_{L'} \end{pmatrix} \quad (5.5)$$

但し、

$$q_t = \sum_{i=1}^L p_i p_{it}$$

$$y_t = (y_{t1}, \dots, y_{tk}, \dots, y_{tL'})^T$$

$$y_{tk} \in \{0, 1\}$$

で表される。第2層の細胞 k の修正可能なシナプス荷重 w^*_{jk} 、 $-w^*_{k0}$ は、記憶パターン y_t ($t \in E_v$)をもとに、式(5.3)と同様に、学習方程式

$$\begin{aligned} \dot{r} w^*_{jk} &= -w^*_{jk} + D_k \beta_k y_t \\ \dot{r} w^*_{k0} &= -w^*_{k0} + D_k' \beta_k z_{t0} \end{aligned} \quad (5.6)$$

但し、

$$\beta_k = 1 (y^T r_k)$$

に従って修正される。ここに、 $y^T r_k$ は記憶パターン y_t に対する細胞 k の出力、 D_k 、 D_k' は細胞 k の学習定数である。なお、各細胞の入出力関係は系-(I)と同様である。系-(I)、系-(II)において、第2層の細胞は式(5.3)、(5.6)の学習により、環境 E_x 、 E_v のもとで、特定のパターン集合に反応する認識細胞になっていく。ここでは、1個のパターンのみに反応する認識細胞が形成される場合を考える。系-(I)、系-(II)において、そのための条件は式(3.23)より、

$$\begin{aligned} \rho_k < \phi_j &= C_j' / C_j < 1, \\ \rho_v < \Omega_k &= D_k' / D_k < 1 \end{aligned} \quad (5.7)$$

但し、

$$\rho_k = \max_{i, i' \in E_x} \rho(x_i, x_{i'}), \quad \rho_v = \max_{t, t' \in E_v} \rho(y_t, y_{t'})$$

で与えられる。すなわち、学習パラメータ ϕ_j 、 Ω_k が上式を満足するとき、各パターンに対して互いに異なる1個の上位概念が形成される。そのとき、キーパターン x_i の認識細胞 j (系-(I))、および記憶パターン y_t の認識細胞 k (系-(II))のシナプス荷重の安定平衡状態をそれぞれ $(\bar{w}^*_{ij}, \bar{w}^*_{j0})$ 、 $(\bar{w}^*_{jk}, \bar{w}^*_{k0})$ と書くと、それは

$$\bar{w}_{x_j} = C_j p_i x_i, \quad \bar{w}_{x'_j} = C'_j p_i \sqrt{\mu^{x_i}} \quad (5.8)$$

$$\bar{w}_{y_k} = D_k q_i y_i, \quad \bar{w}_{y'_k} = D'_k q_i \sqrt{\mu^{y_i}}$$

但し、

$$\mu^{x_i} = \sum_{j=1}^n x_{ij}, \quad \mu^{y_i} = \sum_{k=1}^n y_{ik}$$

となる。それゆえ、 x_i 、 y_i に対する細胞の出力 x'_{ij} 、 y'_{ik} は、

$$\begin{aligned} x'_{ij} &= p_i C_j (1 - \phi_j) \mu^{x_i} \\ y'_{ik} &= q_i D_k (1 - \Omega_k) \mu^{y_i} \end{aligned} \quad (5.9)$$

となる。簡単のために以下では、 $C_j = C$ 、 $C'_j = C'$ 、 $D_k = D$ 、 $D'_k = D'$ ($j, k = 1 \sim n$)とする。

5. 2. 3 多重連合系

系-(III)はキーパターン、記憶パターンをもとに系-(I)、系-(II)で形成された上位概念を多重に連合してその関係を記憶していく。系-(III)の細胞 k は系-(I)のすべての認識細胞から入力を受ける。同時に、系-(III)の細胞 k は系-(II)の認識細胞 j からの入力を受ける。系-(III)の細胞 k と系-(I)の認識細胞 j との修正可能なシナプス荷重を $w^{(3)}_{kj}$ とする。この $w^{(3)}_{kj}$ はキーパターン、記憶パターンの上位概念 x' 、 y' をもとに学習するが、その際 y' が系-(III)の細胞の教師信号となる。すなわち、学習は

$$\tau^{(3)} [\dot{\bar{w}}^{(3)}] = - [w^{(3)}] + C^{(3)} y' (x')^T \quad (5.10)$$

に従うものとする。ここに、 $\tau^{(3)}$ は時定数、 $C^{(3)}$ は学習定数である。また、 $[\dot{\bar{w}}^{(3)}$

]は行列 $[w^{(3)}]$ の各要素の時間微分、 T はベクトルの転置を意味する。なお、ここで系-(III)の細胞の教師の役割を果たす系-(II)の認識細胞は、後に述べる自己想起においては系-(III)への入力を形成する。

さて、認識細胞が記憶に関与するとすれば、記憶は系-(I)、系-(II)において各パターンに対する認識細胞(上位概念)が形成されたのちに行われると考えられる。そこで、上位概念 x' 、 y' の対が形成する系-(III)(式(5.10))の環境はこれを E_3 とすると、式(5.1)と式(5.4)の関係より、

$$E_3 = \begin{bmatrix} (x'_{i1}, y'_{i1}) \cdots (x'_{i1}, y'_{i1}) \cdots (x'_{iL}, y'_{iL'}) \\ p'_{i11} \cdots p'_{i1t} \cdots p'_{iL'L'} \end{bmatrix} \quad (5.11)$$

但し、

$$p'_{i1t} = p_i p_{1t}$$

と表せる。ここに、 p'_{i1t} は x_i と y_i の同時確率を示す。この環境のもとで、式(5.10)の $[w^{(3)}]$ は

$$\begin{aligned} [\bar{w}^{(3)}] &= C^{(3)} y' (x')^T \\ &= C^{(3)} \sum_{j=1}^L \sum_{t=1}^{L'} p'_{i1t} y'_{it} (x'_{i1})^T \end{aligned} \quad (5.12)$$

に収束する。すなわち、 $[\bar{w}^{(3)}]$ にはキーパターンと記憶パターンの同時確率構造が含まれることになる。

5. 2. 4 自己連合系

系-(IV)には、記憶パターン(下位概念)とその上位概念の関係を記憶していく。系-(IV)の細胞 i と系-(III)の細胞 k との修正可能なシナプス荷重を $w^{(4)}_{ik}$ とする。この $w^{(4)}_{ik}$ は記憶パターンと系-(III)の細胞の出力パターンをもとに学習するが、その際記憶パターンが系-(IV)の細胞の教師信号となる。すなわち、学習は

$$\tau^{(4)} [\dot{\bar{w}}^{(4)}] = -[w^{(4)}] + C^{(4)} y (\hat{y}^t)^T \quad (5.13)$$

に従うものとする。ここに、 τ_4 は時定数、 C_4 は学習定数、 \hat{y}^t は系-(III)の細胞の出力パターンを示す、 y^t は \hat{y}^t に対応することから、 y と \hat{y}^t が形成する系-(IV) (式(5.13))の環境は、これを E_4 とすると、式(5.5)より

$$E_4 = \begin{bmatrix} (y_1, \hat{y}_1^t) \cdots (y_t, \hat{y}_t^t) \cdots (y_{L'}, \hat{y}_{L'}^t) \\ q_1 \quad \quad \quad q_t \quad \quad \quad q_{L'} \end{bmatrix} \quad (5.14)$$

となる。この環境のもとで、 $[w^{(4)}]$ は

$$\begin{aligned} [\bar{w}^{(4)}] &= C^{(4)} y (\hat{y}^t)^T \\ &= C^{(4)} \sum_{t=1}^{L'} q_t y_t (\hat{y}^t)^T \end{aligned} \quad (5.15)$$

に収束する。すなわち、 $[\bar{w}^{(4)}]$ は y_t の出現確率構造を含む。

以上のように、外界で起こったパターンは上位概念の形成系(認識細胞の形成系)、多重連合系、および自己連合系での学習を通して記憶されていく。次に、学習後の想起について述べる。

5.3 想起過程

このモデルでは二つの想起過程、すなわち相互想起と自己想起とを考えることができる。相互想起では、特定のキーが系-(I)に与えられると、学習時にそのキーと連合した記憶パターンを連合確率の大きい順に順次想起する。自己想起では、雑音を含んだ不完全パターンがキーとして系-(III)に与えられると、記憶したパターンのうちでそれと類似したパターンを完全な形で順次想起する。これらの連想動作は上位概念の連合を介して行われる。

5.3.1 相互想起

特定のキーパターン x_r が与えられたとしよう。このとき、 x_r の上位概念 x^r (認識細胞の出力)が多重連合系へのキー入力となる。この結果、系-(III)の各細胞はすでに学習されているシナプス荷重 $[\bar{w}^{(3)}]$ を介して入力を受ける。系-(III)の細胞 k ($k=1 \sim N$)への入力を N 次元ベクトル S で表すと、 S は式(5.12)より

$$\begin{aligned} S &= [\bar{w}^{(3)}] x^r \\ &= C^{(3)} \left\{ \sum_{l=1}^L \sum_{t=1}^{L'} p_{l,t} y^t (x^r)^T \right\} x^r \end{aligned} \quad (5.16)$$

となる。これは認識細胞の関与により、 $(x^r)^T x^{l'} = 0$ ($l \neq l'$)ゆえ、

$$S = C^{(3)} \|x^r\|^2 \sum_{t \in A} p_{r,t} y^t \quad (5.17)$$

と書き直される。ここに、 $\| \cdot \|$ はベクトルのノルム、 A は x_r と連合した記憶パターンの集合を表す。更に、認識細胞の関与により、 $(y^t)^T y^{t'} = 0$ ($t \neq t'$)である。従って、比較的簡単な機構、たとえば、疲労特性(1つの細胞の興奮が続くと、その細胞の出力が減衰していく)を有する抑制性細胞が系-(III)のしきい値効果として働くような機構と、系-(III)の細胞に対して一次遅れ要素を含む自己抑制機構を設けることによって、系-(III)の細胞のうちで大きい入力を受ける細胞から順番に順次興奮するようにできる。このことは、 x_k と連合した記憶パターンの上位概念に対応するパターンが系-(III)からの出力パターンとして順次現れることに他ならない。系-(III)からの出力パターンが今度は自己連合系(系-(IV))への入力となる。この結果、すでに学習されているシナプス荷重 $[\bar{w}^{(4)}]$ によって、入力されたパターンに対応する記憶パターンが系-(IV)からの出力パターンとして順次想起される。このようにして、 x_k と学習時に連合したすべての記憶パターンが順次想起されることになる。なお、系-(III)における順次想起の機構は、系-(III)の細胞間で基本競合系(2.4参照)を構成することによっても実現できる。

5. 3. 2 自己想起

キーとして雑音を含んだ不完全パターン \tilde{y} が系-(II)に与えられたとしよう。その際、すでに記憶したパターン中に \tilde{y} と Ω (学習パラメータ)より大きい類似度をもつものがあるとき、その記憶パターンの認識細胞が反応する。この結果、系-(III)の細胞はそれらの上位概念を入力として受ける。この場合、式(5.16)のベクトルSは

$$S = \sum_{t \in B} Q_t y^t; \quad (5.18)$$

但し、

$$Q_t = \frac{(\tilde{p}_t - \Omega) \sqrt{\tilde{\mu}^t}}{(1 - \Omega) \sqrt{\mu^t}}$$

となる。ここに、Bは \tilde{y} と Ω より大きい類似度をもつ記憶パターンの集合、 \tilde{p}_t は y_t と \tilde{y} との類似度、 $\tilde{\mu}^t$ は \tilde{y} の発火個数を表す。この場合も相互想起の場合と同様にして、 \tilde{y} と Ω より大きい類似度をもつすべての記憶パターンが順次想起される。しかし、 \tilde{y} がすでに記憶したどのパターンとも Ω より大きな類似度をもっていない場合には、系-(II)においてどの認識細胞も反応しない。それゆえ、何らの想起も起こらない。従来の相関型連想記憶においては、無意味なパターンが想起されることがある。

5. 4 計算機実験

この実験では、認識細胞に基礎をおく連想記憶システムが多重連合環境下でうまく動作することを確かめる。環境 E_x 、 $p(y|x)$ を

$$E_x = \begin{bmatrix} x_1 & x_2 & x_3 & x_4 \\ 1/4 & 1/4 & 1/4 & 1/4 \end{bmatrix}$$

$p(y x) =$	y_1	y_2	y_3	y_4
x_1	4/10	3/10	2/10	1/10
x_2	0	1	0	0
x_3	2/6	1/6	3/6	0
x_4	3/8	0	0	5/8

とした。図5.2にキーパターン x_i ($i=1\sim 4$)と、それと連合する記憶パターン y_i ($i=1\sim 4$)に対応する2次元図形を示している。これより、1個のパターンのみに反応する認識細胞が形成されるための条件を求めると、式(5.7)より

$$0.42 < \phi < 1, \quad 0.73 < \Omega < 1$$

となる。ここでは、この不等式を満足するように、

$$\phi = 0.50, \quad \Omega = 0.80$$




図5.2 キーパターンと記憶パターン

とした。また、

$$C^{(3)} = 4, 0, \quad C^{(4)} = 1, 0$$

とした。図5.3に、学習後におけるキーパターン x_1 による相互想起の結果を示す。図はキーパターン x_1 が与えられたとき、記憶パターン y_1, y_2, y_3, y_4 がこの順番に1つずつ順次想起されたことを示している。また、キーパターン x_2 に対しては、 y_2 だけが想起されたことを示している。この結果から、各キーパターンに対して、学習時にそれと連合したすべての記憶パターンが順次想起されることがわかる。図5.4に不完全パターン \tilde{y} による自己想起の結果を示す。これも図5.3と同様に、キー \tilde{y} に対して記憶パターンが順番に1つずつ想起されたことを示している。ここに、想起された記憶パターンはすべて \tilde{y} と Ω より大きい類似度をもつパターンである。このことから、不完全パターン \tilde{y} に対しても、すでに記憶されているパターンのうちで \tilde{y} と Ω より大きい類似度をもつすべての記憶パターンが順次完全な形で想起されることがわかる。このように、モデルは相互想起、自己想起どちらにおいても、キー入力に対




図5.3 相互想起の結果




図5.4 自己想起の結果

応するパターンを完全な形で1つずつ順次想起する。また、キー入力が学習されたどのパターンにも類似していない場合には何ら想起しない。これらの点で、モデルは生体のもつ連想機能の一面に似た性質をもつ。

5.5 結言

ここでは、認識細胞形成系の一つの応用として、認識細胞に基礎をおく基本的な連想記憶モデルを提案し、モデルが多重連立下でうまく動作することを示すことにより、認識細胞の果たす連想記憶への一つの役割を示唆した。これはまた、上位概念の連合を介する高次の連想機能を説明するための一つの手がかりを与えるものである。ここでは、すべての認識細胞は同じ学習定数をもち、かつ学習の期間中その値は変化しないとしている。いくつかの細胞集団が異なった学習定数をもつ場合とか、学習パラメータの環境に応じた適応的变化等を考慮することによって、より高次の連想記憶システムが得られると思われる。

—パターン間連合の自己形成とそれを介する順次想起, 分岐機能—

6. 1 緒言

前章でも述べたように, 連想記憶に関して多くのモデルが提案されている。連想機能を追求する研究の中で, 想起を順次繰り返していく動的な連想機能に関するものに, 甘利^{(2)・(8)}, 中野⁽⁷⁵⁾, 森田⁽⁸⁶⁾, 福島^{(16)・(80)・(83)}らの考察がある。これらの考察はそれぞれに興味深い成果を与えている。

生体の記憶過程において, 環境から与えられるパターン間の連合はあらかじめ定まっているのではなく, 自己組織的に形成されていくと考えられる。更に連想過程においては, 種々の観点から分析された情報を再び統合してパターン化するような機構を通して行われ, 学習時に形成された連合をたどりながら, あるパターンから次のパターンへと次々と連想が移行していくなどの機能が実現されていると考えられる。すなわち生体の連想記憶においては, 人力を種々の観点から分析する認識細胞のような分析系とそれらを再び統合し, パターン化するような統合機構が何らかの形で関与している⁽⁵³⁾ものと思われる。これらの機構を明らかにすることは脳の高次の情報処理機構を解明する上で重要である。

しかし, 従来のほとんどの連想記憶モデルでは, パターン間の連合は学習時に環境から事前に与えられていて, パターン間連合の自己組織的な形成やそれによる連想の順次移行, 更に分岐などの機能についてはあまり議論されていない。前章で提案した認識細胞に基礎をおく連想記憶モデルは同じ学習定数をもつ1種類の認識細胞からなっていて, 統合機構も備えていないため, そのような機能はもっていない。

この章では, 前章で提案した連想記憶モデルに異なった学習定数をもつ認識細胞層とそれによって分析された情報を統合する機構, 更に想起時に機能するフィードバック機構を付加したモデルを提案し, その動作, 性質を調べる。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の動作を確かめる。また, 連想の分岐の機能について考察する。その結果として, このモデルでは, 学習過程において, 特徴パターンが認識細胞層で異なった基準のもとで分類され, 統合機構を通してその分類に応じたパターン間の連合が自己組織的に形成されること, 更に想起過程において, フィードバック機構によりその連合を介した連想の順次移行や分岐の機能が実現できることを示す。

6. 2 学習過程

6. 2. 1 モデルの概略

図6. 1に認識細胞を用いた連想記憶モデルを示す。このモデルは, 他の学習パターンの一つの列を順次想起していくことによって, 最終的にある特定の学習パターンを想起する自己組織モデルである。また, その際想起されるパターン列は学習時に事前に定められているのではなく, 自己組織的に作り出される。モデルは認識細胞形成

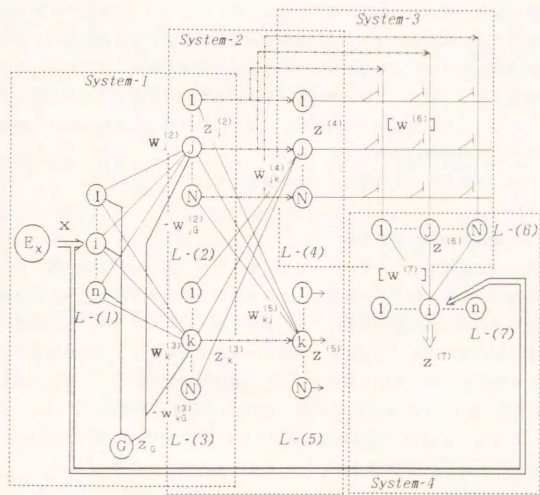


図6. 1 連想記憶システム

系(系I), 統合細胞形成系(系II), 自己連合系(系III, 系IV)からなる。認識細胞形成系は特徴パターン層(層1)と, 異なる学習定数をもつ認識細胞層(層2, 層3)からなり, 層1に与えられる特徴パターンを類似度の異なる基準のもとでパターン分類する。統合細胞形成系は認識細胞層(層2, 層3)と統合細胞層(層4, 層5)からなり, 統合細胞層は各認識細胞層の興奮パターン間の関係を統合することによって, パターン間の連合を自己組織的に形成する。これによって, 類似度に応じたパターン間の連合が実現される。自己連合系における系IIIは層2, 層4, 層6からなる。層6の細胞は統合細胞層4と認識細胞層2の興奮パターン間の関係を記憶する。また, 系IVは層6と層7からなる。層7の細胞は層6の出力パターンとそのときに環境から与えられている特徴パターンとの関係を記憶する。この自己連合系によって, 層6に想起されたパターンは対応する特徴パターンに変換される。この他に, モデルは認識細胞層(層2, 層3)と統合細胞層(層4, 層5)との間にフィードバック機構をもっている。これは想起時のみ機能し, 連想の順次移行の機能において重要な役割を果たす。この機構については後に述べる。

以下の節では, 各系における学習過程について説明する。

6. 2. 2 認識細胞の自己形成系

認識細胞の自己形成系は, 特徴パターン層(層1)と, 異なる学習定数をもつ2つの認識細胞層(層2, 層3)からなる。これらの形成系は第3章で述べた認識細胞の自己形成系(図3. 2参照)である。この系では層1の特徴パターンを類似度の異なる基準のもとでパターン分類する。特徴パターン層(層1)と認識細胞層 s ($s=2, 3$)の細胞 j とのシナプス荷重を $w_j^{(s)}$, 抑制性細胞 G とのシナプス荷重を $-w_{j0}^{(s)}$ とする。層1には, 環境 E (式(3. 1))から選ばれた特徴パターン x_1 が与えられる。ただし, x_1 は正の連続値をその成分としてもつ。層2, 層3の細胞のシナプス荷重 $w_j^{(s)}$, $w_{j0}^{(s)}$ は特徴パターン x_1 をもとに, 学習方程式

$$\begin{aligned} \tau^{(s)} \dot{w}_j^{(s)} &= -w_j^{(s)} + C^{(s)} \gamma_j^{(s)} x_1 \\ \tau_0^{(s)} \dot{w}_{j0}^{(s)} &= -w_{j0}^{(s)} + C'^{(s)} \gamma_j^{(s)} z_{j0} \end{aligned} \quad (6.1)$$

但し, $\gamma_j^{(s)} = z_{j1}^{(s)}$ ($s=2, 3$), $z_{j0} = \|x_1\|$

に従って修正される。ここに, $z_{j1}^{(s)}$ はパターン x_1 に対する層 s ($s=2, 3$)の細胞 j の出力である。また, $\tau^{(s)}, \tau_0^{(s)}$ は時定数で十分大きいものとする。更に, $C^{(s)}, C'^{(s)}$ は各層の学習定数である。層2, 層3の各細胞は, 式(6. 1)の学習により, 環境 E のもとで特定のパターン集合のみに反応する認識細胞になる。すなわち, 各層は学習パラメータ $\phi^{(s)} = C'^{(s)} / C^{(s)}$ ($s=2, 3$)の値によって異なる基準のもとでパターン分類を行うことになる。このとき, パターン集合 ϕ の認識細胞 j のシナプス荷重の安定平衡状態を $(\bar{w}_j^{(s)}, \bar{w}_{j0}^{(s)})$ と書くと,

$$\begin{aligned} \bar{w}_j^{(s)} &= C^{(s)} \sum_{1 \in \phi} p_1 x_1 \\ \bar{w}_{j0}^{(s)} &= C'^{(s)} \sum_{1 \in \phi} p_1 z_{j0} \end{aligned} \quad (6.2)$$

となる。また, 特徴パターン x_1 に対する層 s ($s=2, 3$)の細胞の出力 $z_{j1}^{(s)}$ は

$$z_{j1}^{(s)} = 1 (\bar{w}_j^{(s)})^T x_1 - \bar{w}_{j0}^{(s)} z_{j0} \quad (6.3)$$

となる。

ここで, 環境から選ばれる L 個の特徴パターン間の類似度を

	x_1	\dots	x_n	\dots	x_L
x_1	ρ_{11}	\dots	ρ_{1n}	\dots	ρ_{1L}
\vdots	\vdots		\vdots		\vdots
x_L	ρ_{L1}	\dots	ρ_{Ln}	\dots	ρ_{LL}
\vdots	\vdots		\vdots		\vdots
x_L	ρ_{L1}	\dots	ρ_{Ln}	\dots	ρ_{LL}

(6.4)

とする。ここに, $\rho_{1n} = \rho_{n1}$ である。また,

$$\max_{\substack{1, m \\ l \neq m}} \{\rho_{lm}\} = \rho_{max}, \quad \min_{\substack{1, m \\ l \neq m}} \{\rho_{lm}\} = \rho_{min}$$

とする。このとき層2の細胞の学習パラメータ $\phi^{(2)}$ は

$$\rho_{max} < \phi^{(2)} < 1 \quad (6.5)$$

を満たすように選ばれるものとする。このとき、式(3.23)からわかるように層2では学習により各特徴パターンの認識細胞がすべて分離した形で形成される。すなわち、学習後の、各特徴パターンに対する層2の細胞の出力パターンは直交する。

層3の細胞の学習パラメータ $\phi^{(3)}$ は

$$\rho_{min} < \phi^{(3)} < \rho_{max} \quad (6.6)$$

を満たすように選ばれるものとする。このとき層3の細胞は環境Eのもとでの学習により、 $\phi^{(3)}$ より大きい類似度をもつパターン集合の認識細胞になる。すなわち、ここでは特徴パターンがその類似度と学習パラメータに応じていくつかのパターン集合に分類される。

このように層2、層3の認識細胞層ではその学習パラメータに応じて環境から与えられる特徴パターンの細分類、大分類が自己組織的に行われる。

6.2.3 統合細胞形成系

系II(層4、層5)は層2、層3の認識細胞により分類されたパターンを再び統合することによって、パターン間の連合を自己組織的に形成する。層4の細胞jは層3の全ての細胞から入力を受ける。層4の細胞jと層3の細胞kとのシナプス荷重を $w_{jk}^{(4)}$ とする。パターン x_1 が与えられたとき、 $w_{jk}^{(4)}$ はそのときの層3の細胞kの出力 $z_{1k}^{(3)}$ と層2の細胞jの出力 $z_{1j}^{(2)}$ をもとに学習される。その際、層2の細胞jの出力 $z_{1j}^{(2)}$ が層4の細胞jの教師信号となる。すなわち、 $w_{jk}^{(4)}$ は $z_{1j}^{(2)} = 1$ のときのみ $z_{1k}^{(3)}$ に比例して強化される。その学習方程式は、ベクトル・行列で表すと、

$$\tau^{(4)} [\dot{w}^{(4)}] = -[w^{(4)}] + C^{(4)} z_1^{(2)} z_1^{(3)T} \quad (6.7)$$

となる。ここに、 $z_1^{(2)}$ 、 $z_1^{(3)}$ はパターン x_1 に対する層2、層3の出力パターンで、

$$z_1^{(2)} = (z_{11}^{(2)}, \dots, z_{1j}^{(2)}, \dots, z_{1n}^{(2)})^T$$

$$z_1^{(3)} = (z_{11}^{(3)}, \dots, z_{1k}^{(3)}, \dots, z_{1n}^{(3)})^T$$

である。 $[w^{(4)}]$ は $w_{jk}^{(4)}$ を要素とする行列である。また、 $[\dot{w}^{(4)}]$ は行列 $[w^{(4)}]$ の各要素の時間微分を意味する。 $\tau^{(4)}$ は時定数、 $C^{(4)}$ は学習定数である。これらの記号は以下の式においても同じ意味で用いられる。ここで、層2、層3の出力パターン $z_1^{(2)}$ 、 $z_1^{(3)}$ の対が形成する式(6.7)の学習の環境はこれを E_4 とすると、

$$E_4 = \begin{bmatrix} z_1^{(2)} z_1^{(3)} & \dots & z_1^{(2)} z_1^{(3)} & \dots & z_L^{(2)} z_L^{(3)} \\ p_1 & \dots & p_1 & \dots & p_L \end{bmatrix} \quad (6.8)$$

となる。この環境のもとで式(6.7)の $[w^{(4)}]$ は

$$\begin{aligned} [\bar{w}^{(4)}] &= C^{(4)} \overline{z_1^{(2)} z_1^{(3)T}} \\ &= C^{(4)} \sum_{l=1}^L p_l z_l^{(2)} z_l^{(3)T} \end{aligned} \quad (6.9)$$

に収束する。

同様に、層5の細胞kは層3の細胞kの出力 $z_{1k}^{(3)}$ を教師信号とし、層2の細胞jとのシナプス荷重 $w_{jk}^{(5)}$ を学習する。学習方程式およびその環境は式(6.7)、(6.8)と同様な式で表され、 $[w^{(5)}]$ は

$$[\bar{w}^{(5)}] = C^{(5)} \overline{z_1^{(3)} z_1^{(2)T}}$$

$$= C^{(5)} \sum_{l=1}^L p_l z_l^{(3)} z_l^{(2)T} \quad (6.10)$$

に収束する。このように統合細胞形成系では、認識細胞形成系によって異なった分類がなされたパターン間の関係を学習することによって、その連合が自己組織的に形成される。

6. 2. 4 自己連合系

層6の細胞jは層4の全ての細胞から入力を受ける。層6の細胞と層4の細胞間のシナプス荷重を $[w^{(6)}]$ で表す。 $[w^{(6)}]$ は層4の出力パターン $z_l^{(4)}$ と層2の出力パターン $z_l^{(2)}$ をもとに学習されるが、その際、 $z_l^{(2)}$ が教師信号となる。尚、層4の学習の際層2の細胞の出力がその教師信号となっていることから、学習時には $z_l^{(4)} = z_l^{(2)}$ である。

層7の細胞は層6の全ての細胞から入力を受ける。層7の細胞と層6の細胞間のシナプス荷重を $[w^{(7)}]$ で表す。 $[w^{(7)}]$ は層6の細胞の出力パターン $z_l^{(6)}$ と特徴パターン x_l をもとに学習するが、その際、特徴パターン x_l が層7の教師信号となる。尚、層6の学習においては層2の細胞出力が教師信号となっているので、学習時には $z_l^{(6)} = z_l^{(2)}$ である。層6、層7における学習方程式、環境も式(6. 7)、(6. 8)と同様な式で表され、 $[w^{(6)}]$ 、 $[w^{(7)}]$ はそれぞれ

$$\begin{aligned} [\bar{w}^{(6)}] &= C^{(6)} \overline{z_l^{(2)} z_l^{(4)T}} \\ &= C^{(6)} \sum_{l=1}^L p_l z_l^{(2)} z_l^{(2)T} \end{aligned} \quad (6.11)$$

$$\begin{aligned} [\bar{w}^{(7)}] &= C^{(7)} \overline{x_l z_l^{(6)T}} \\ &= C^{(7)} \sum_{l=1}^L p_l x_l z_l^{(6)T} \end{aligned} \quad (6.12)$$

に収束する。このように、層6では層2の認識細胞出力パターン（内部表現パターン）

の自己相関が、層7では特徴パターンとその内部表現パターンとの関係が学習される。

以上のように、学習時においては、外界で起った特徴パターンは認識細胞形成系によって異なった基準のもとで分類される。また、統合細胞形成系を通してそれらの情報が統合され、その分類に応じたパターン間の連合が自己組織的に形成される。更に自己連合系で、特徴パターンとその内部表現パターンとの関係が記憶される。

6. 3 想起過程

6. 3. 1 想起の流れ

時刻tに層1にキーパターン $x(t)$ が与えられる。そのとき、認識細胞層（層2、層3）の各細胞は、既に学習されているシナプス荷重 $\bar{w}_j^{(2)}$ 、 $-\bar{w}_j^{(2)}$ 、 $\bar{w}_j^{(3)}$ 、 $-\bar{w}_j^{(3)}$




図6. 2 想起時のフィードバック機構

$z_r^{(3)}$ を介して入力を受ける。その結果、層2、層3はパターン $z^{(2)}(t)$ 、 $z^{(3)}(t)$ を出力する。これらの出力パターンがそれぞれ今度は統合細胞層への入力（層2→層5、層3→層4）となる。層4、層5はそれぞれシナプス荷重 $[\bar{w}^{(4)}]$ 、 $[\bar{w}^{(5)}]$ を介してその入力を受け、パターン $z^{(4)}(t)$ 、 $z^{(5)}(t)$ を出力する。このうちの $z^{(4)}(t)$ が自己連合系（系-Ⅲ）への時刻 t における入力となる。

ここで、統合細胞層の出力は認識細胞層にフィードバック（層4→層2、層5→層3）しており（図6、2参照）、次の時刻 $t+1$ における層2、層3の出力パターン $z^{(2)}(t+1)$ 、 $z^{(3)}(t+1)$ は（但し、このとき層1のパターンは既に消滅しているものとする）、

$$z^{(2)}(t+1) = 1(z^{(4)}(t)), \quad z^{(3)}(t+1) = 1(z^{(5)}(t))$$

となるものとする。その結果、層3の出力パターン $z^{(3)}(t+1)$ を入力として受ける層4の出力パターン $z^{(4)}(t+1)$ が時刻 $t+1$ における系-Ⅲへの入力となる。このように、

層6の細胞への入力は刻々変化する。層6の細胞はシナプス荷重 $[\bar{w}^{(6)}]$ を介して層4からの入力を受け、特定のパターンに対応する認識細胞層2のパターンを出力する。

その結果、層7の細胞はシナプス荷重 $[\bar{w}^{(7)}]$ を介して層6からの入力を受け、その入力に対応する特定の特徵パターンを想起する。なお、層6の細胞は想起の際、一度興奮したら自己抑制機構によってそれ以後一定時間は興奮しないと仮定する。

6. 3. 2 想起の具体例

想起の際、認識細胞層（層2、層3）の各細胞は記憶時の学習により、特定のパターン集合のみに反応する認識細胞になっている。すなわち、層2では、学習パラメータ $\phi^{(2)}$ （ $> \rho_{max}$ ）により、ただ1つの特徴パターンからなるパターン集合の認識細胞になっている。層3はその学習パラメータ $\phi^{(3)}$ より大きい類似度をもつパターンからなるパターン集合の認識細胞になっている。層4～層7の細胞のシナプス荷重 $[w^{(4)}]$ 、 $[w^{(5)}]$ 、 $[w^{(6)}]$ 、 $[w^{(7)}]$ は記憶時の学習によりそれぞれ式(6. 9)、(6. 10)、(6. 11)、(6. 12)に収束している。ここで、時刻 t において層1にキーパターン x_r が与えられたとしよう。そのときの層2、層3の出力パターンを $z_r^{(2)}$ 、 $z_r^{(3)}$ で表す。そのとき、層4の出力パターン $z_r^{(4)}(t)$ は

$$\begin{aligned} z_r^{(4)}(t) &= [\bar{w}^{(4)}] z_r^{(3)} \\ &= (C^{(4)} \sum_{l=1}^L p_l z_l^{(2)} z_l^{(3)T}) z_r^{(3)} \end{aligned} \quad (6.13)$$

となる。ここで、層3において異なるパターン集合に属するパターン同士はその出力パターンが直交するので、 $z_l^{(3)T} z_r^{(3)} = 0$ （ $x_l \in \phi_r$ 、 $x_r \in \phi_r$ ）となる。故に、式(6. 13)は

$$\begin{aligned} z_r^{(4)}(t) &= C^{(4)} \sum_{q \in \phi_r} p_q z_q^{(2)} z_q^{(3)T} z_r^{(3)} \\ &= C^{(4)} \sum_{q \in \phi_r} p_q h_{qr} z_q^{(2)} \end{aligned} \quad (6.14)$$

但し、 $h_{qr} = z_q^{(3)T} z_r^{(3)}$

となる。ここに、 ϕ_r はパターン x_r が属するパターン集合を示す。また、 $q \in \phi_r$ は $x_q \in \phi_r$ を示す。式(6. 14)からわかるように、層4では層3でパターン x_r と同じパターン集合 ϕ_r をなすパターン x_q の認識細胞が興奮する。層5の出力パターン $z_r^{(5)}(t)$ は

$$\begin{aligned} z_r^{(5)}(t) &= [\bar{w}^{(5)}] z_r^{(4)} \\ &= (C^{(5)} \sum_{l=1}^L p_l z_l^{(3)} z_l^{(4)T}) z_r^{(4)} \end{aligned} \quad (6.15)$$

となる。ここで、層2では各特徴パターンの認識細胞が重ならない形で形成されているので、 $z_l^{(2)T} z_r^{(2)} = 0$ （ $l \neq r$ ）である。故に、式(6. 15)は

$$z_r^{(5)}(t) = C^{(5)} p_r \| z_r^{(2)} \|^2 z_r^{(3)} \quad (6.16)$$

となる。層4、層5の出力パターンのうち $z_r^{(4)}(t)$ が時刻 t における系-Ⅲへの

入力となる。層6の細胞j (j = 1, N)への入力をN次元ベクトルSで表すと、Sは

$$\begin{aligned}
 S &= [\bar{w}^{(6)}] z_r^{(4)}(t) \\
 &= (C^{(6)}) \sum_{l=1}^L p_l z_l^{(2)} z_l^{(2)T} C^{(4)} \sum_{q \in \psi_r} p_a h_{ar} z_a^{(2)} \\
 &= C^{(6)} C^{(4)} \sum_{q \in \psi_r} p_a^2 h_{ar} \|z_a^{(2)}\|^2 z_a^{(2)} \quad (6.17)
 \end{aligned}$$

となる。ここで、 $z_l^{(2)T} z_a^{(2)} = 0$ ($l \neq m$)であるから比較的簡単な機構⁽⁵⁸⁾を用いることによって、層6の細胞のうちで大きい入力を受ける細胞から順番に順次興奮するようにできる。このことは、 ψ_r に属するパターン x_a の認識細胞出力 $z_a^{(2)}$ を層6の出力パターンとして順次取り出せることを意味している。このパターンが今度は層7の細胞への入力となる。その結果、層7では $[\bar{w}^{(7)}]$ を通して、層6で順次取り出された $z_a^{(2)}$ に対応した特徴パターン x_a が順次想起される。

一方、認識細胞層と統合細胞層間のフィードバックにより、次の時刻t+1の層4、層5への入力は

$$z_r^{(2)}(t+1) = 1(z_r^{(4)}(t)) = \sum_{q \in \psi_r} z_q^{(2)} \quad (6.18)$$

$$z_r^{(3)}(t+1) = 1(z_r^{(5)}(t)) = z_r^{(3)}$$

となる。よって、層4、層5の出力パターンは

$$\begin{aligned}
 z_r^{(4)}(t+1) &= [\bar{w}^{(4)}] z_r^{(3)}(t+1) \\
 &= C^{(4)} \sum_{q \in \psi_r} p_a h_{ar} z_a^{(2)} \quad (6.19)
 \end{aligned}$$

$$\begin{aligned}
 z_r^{(5)}(t+1) &= [\bar{w}^{(5)}] z_r^{(2)}(t+1) \\
 &= C^{(5)} \sum_{q \in \psi_r} p_a \|z_a^{(2)}\|^2 z_a^{(3)}
 \end{aligned}$$

となる。すなわち、時刻t+1では時刻tのときと同じく、パターン x_r と同じパターン集合に属するパターン x_a の認識細胞出力 $z_a^{(2)}$ が層4の出力パターンとなり系(III)への入力となる。同様にして時刻t+2での層4、層5の出力パターンは

$$\begin{aligned}
 z_r^{(4)}(t+2) &= C^{(4)} \sum_{q \in \psi_r} p_a \left(\sum_{q' \in \psi_r} h_{aq'} \right) z_a^{(2)} \\
 &+ C^{(4)} \sum_{q \in \psi_r} \sum_{m \in \psi_a} p_m h_{mq} z_m^{(2)} \quad (6.20)
 \end{aligned}$$

$$z_r^{(5)}(t+2) = C^{(5)} \sum_{q \in \psi_r} p_a \|z_a^{(2)}\|^2 z_a^{(3)}$$

となる。すなわち、層6への入力として、パターン x_r と層3で同じパターン集合 ψ_r をなすパターン x_a の認識細胞出力 $z_a^{(2)}$ と、その x_a とさらに別のパターン集合 ψ_a を




図6.3 形成されるパターン集合とパターン集合間の連合

形成しているパターン x_n の認識細胞出力 $z_n^{(2)}$ が現れる。同様に、フィードバックにより想起が進んでいくと、時刻 $t+4$ にはその x_n とさらに別のパターン集合を形成するパターン x_n の認識細胞出力 $z_n^{(2)}$ が現れる。先に仮定したように、想起過程において一度興奮した層 6 の細胞はそれ以後一定時間は興奮しないので、新しく現れたパターンの認識細胞出力だけが順次取り出され、層 7 よりそれに対応する特徴パターンが想起される (図 6. 3 参照)。このようにして、ある特定のキーパターンが与えられ、学習により統合細胞層で形成されたパターン間の連合に従い、共通なパターンを媒介して連想が順次移行する。このような機能は生体のもつ連想機能に似た面をもっている。

6. 4 計算機実験

6. 4. 1 連想の順次移行

計算機によるシミュレーション実験を通して、モデルの連想動作を確かめる。実験では、各層の細胞数を

$$n = 10, N = 25$$

とし、すべてのシナプスの初期値は $[0, 0.5]$ 上の一様分布から決定した。また、各層の細胞の学習時における時定数は、

$$\begin{aligned} \tau^{(2)} = \tau^{(3)} &= 1.0, \\ \tau^{(4)} = \tau^{(5)} = \tau^{(6)} = \tau^{(7)} &= 2.0 \end{aligned}$$

とした。環境 E から与えられる特徴パターンは、 $[0, 1]$ 上の一様分布からランダムに取り出した値をその成分として 5 個の 10 次元ベクトル x_1, x_2, x_3, x_4, x_5 を用いた。また、5 個の特徴パターンの出現確率はすべて等しく $1/5$ とした。表 6. 1 に式 (4. 11) から求めた特徴パターン間の類似度を示す。層 2、層 3 の細胞の学習パラメータ $\phi^{(2)}, \phi^{(3)}$ はそれぞれ式 (6. 5)、(6. 6) を満足するよう

$$\phi^{(2)} = 0.90, \phi^{(3)} = 0.70$$

とした。層 s ($s = 4 \sim 7$) の細胞の学習定数は、

$$C^{(4)} = C^{(5)} = C^{(6)} = C^{(7)} = 1.0$$

表 6. 1 特徴パターン間の類似度

	x_1	x_2	x_3	x_4	x_5
x_1	1.00	0.75	0.49	0.47	0.57
x_2	0.75	1.00	0.83	0.60	0.47
x_3	0.49	0.83	1.00	0.78	0.56
x_4	0.47	0.60	0.78	1.00	0.84
x_5	0.57	0.47	0.56	0.84	1.00

とした。図 6. 4 に、層 2、層 3 における学習結果を示す。図では各層の細胞を 2 次元に配列して示している。細胞上の数字はその細胞がどの特徴パターンの認識細胞になっているかを示す。これより、層 2 では特徴パターンの類似度による細分類がなされ、すべての特徴パターンの認識細胞が重なりのない形で形成されていることがわかる。層 3 では、細胞の学習パラメータ $\phi^{(3)} (= 0.70)$ より大きい類似度をもつ特徴パターンからなる種々のパターン集合 ($\phi_1 = \{x_1, x_2\}, \phi_2 = \{x_2, x_3\}, \phi_3 = \{x_3, x_4\}, \phi_4 = \{x_4, x_5\}$) の認識細胞が形成され、特徴パターン間の類似度に応じて大まかな分類がなされていることがわかる。図 6. 5 に層 3 で形成されたパターン集合と、統合細胞層で形成されたパターン間の連合の様子を示す。次に、学習後 5 個の特徴パターンをそれぞれキーパターンとして層 1 に与え、モデルの連想実験を行った。その結果、キーとして x_1 が与えられたとき、特徴パターン x_1, x_2, x_3, x_4, x_5 が順次想起されることが確認された。これは、キーパターン x_1 とは類似度が小さく、大まかな分類でも x_1 と同一のパターン集合に属さないパターン x_3 がパターン集合 ϕ_1 と ϕ_2 に共通なパターン x_2 を介して想起され、今度はパターン集合 ϕ_2, ϕ_3 に共通なパターン x_3 を介して x_4 が想起されるというぐあいに、連想が、共通なパターンを介してパターン集合を渡り歩きながら移行したことを示している。このような想起動作は、学習時における統合機構、更に想起時におけるフィードバック機構によるものである。

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

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

(a) $L-(2)$ ($\Phi^{(2)}=0.90$) (b) $L-(3)$ ($\Phi^{(3)}=0.70$)

図 6. 4 層 2, 層 3 に形成された認識細胞




図 6. 5 形成されたパターン集合
とパターン集合間の連合

6. 4. 2 連想の分岐

計算機によるシミュレーション実験を通して、層 5 に基本競合系 (2, 4 参照) を構成することにより、連想の分岐機能が実現できることを示す。実験では、

$$n = 10, N = 64$$

とした。また、特徴パターンとして 10 個の 10 次元ベクトル $x_k (k=1, 10)$ を用い、その出現確率はすべて等しく $1/10$ とした。各パラメータの値は前実験と同じにした。表 6. 2 に式 (4. 11) から求めた特徴パターン間の類似度を示す。図 6. 6 に層

表 6. 2 特徴パターン間の類似度

	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}
x_1	1.00	0.80	0.59	0.40	0.56	0.52	0.60	0.43	0.37	0.33
x_2	0.80	1.00	0.80	0.59	0.55	0.54	0.58	0.59	0.53	0.58
x_3	0.59	0.80	1.00	0.71	0.45	0.37	0.27	0.59	0.56	0.58
x_4	0.40	0.59	0.71	1.00	0.71	0.55	0.26	0.79	0.53	0.30
x_5	0.56	0.55	0.45	0.71	1.00	0.74	0.40	0.57	0.56	0.40
x_6	0.52	0.54	0.37	0.55	0.74	1.00	0.75	0.21	0.16	0.22
x_7	0.60	0.58	0.27	0.26	0.40	0.75	1.00	0.20	0.14	0.16
x_8	0.43	0.59	0.59	0.79	0.57	0.21	0.20	1.00	0.82	0.48
x_9	0.37	0.53	0.56	0.53	0.56	0.16	0.14	0.82	1.00	0.74
x_{10}	0.33	0.58	0.58	0.30	0.40	0.22	0.16	0.48	0.74	1.00

		8	5			8	
10		9		10	5	4	
4		4	5	2	6		
		1	9	8	4	9	
4	7	8	6	5	1	5	
9	1	3			10	3	
3	6	9			8	9	5
8		10	4		4	4	

4	5	9		4	8	4	5	7											
				9	10				5	6	1								
				6	7	5	6	1	2	9	4	8	6	7					
				1	2	3	4	8	9	9	10	1	10	1	2	8	9		
				10	5	6	1	7	5	6	8	9	4	5					
								2	3			1	2	9	10				
								4	8		4	6	7	5	6	4			
								10	1	2	5	6		10	6	9	1	8	9

(a) $L-(2)$ ($\Phi^{(2)}=0.90$)

(b) $L-(3)$ ($\Phi^{(3)}=0.70$)

図 6. 6 層 2, 層 3 に形成された認識細胞




図 6. 7 形成されたパターン集合
とパターン集合間の連合

Key	Sequence of recalled patterns
x_1	$x_1 \rightarrow x_2 \rightarrow x_3 \rightarrow x_4 \rightarrow x_8$ $\rightarrow x_5 \rightarrow x_9 \rightarrow x_{10}$
x_7	$x_7 \rightarrow x_6 \rightarrow x_5 \rightarrow x_4 \rightarrow x_8$ $\rightarrow x_9 \rightarrow x_{10}$
x_{10}	$x_{10} \rightarrow x_9 \rightarrow x_8 \rightarrow x_4 \rightarrow x_5$ $\rightarrow x_6 \rightarrow x_7$

図 6. 8 想起結果

2, 層3における学習結果を示す。これより, 層2では各パターンに対する認識細胞が重ならない形で形成され, 層3ではパターン間の類似度に応じて種々のパターン集合の認識細胞が形成されていることがわかる。図 6. 7に学習により形成されたパターン集合とその連合の様子を示す。図 6. 8にキーとしてそれぞれ x_1, x_7, x_{10} を与えた場合の想起結果を示す。これにより, 連想が途中で分岐し, 順次移行していることがわかる(図 6. 7矢印参照)。

付図3に50個の特徴パターンを用いて行った実験結果を示す。各層の細胞数は

$$n = 20, N = 400$$

とした。各特徴パターンは, $[0, 1]$ 上の一様分布から生成した。また, 各特徴パターンの出現確率はすべて等しく $1/50$ とした。層2, 層3の細胞の学習パラメータ $\phi^{(2)}, \phi^{(3)}$ はそれぞれ

$$\phi^{(2)} = 0.90, \phi^{(3)} = 0.80$$

とした。また学習時の他のパラメータの値は前実験と同じにした。付図における縦と横の数字(1~50)は各特徴パターンの番号を示している。図における*印は縦と横の番号をもつ特徴パターン間の連合が学習によって形成されたことを示している。これにより, 学習を通して種々のパターン間連合が形成されていることがわかる。数字の上あるいは横の+印はパターンNo. 1(*印)をキーパターンとして与えた場合に, 層7から順次想起された35個のパターンを示す。また大文字の数字はその順番を示す。すなわちパターンNo. 1をキーとした場合, パターンNo. 50 \rightarrow No. 26 \rightarrow No. 4 $\rightarrow \dots \rightarrow$ No. 27 \rightarrow No. 8 \rightarrow No. 24の順に35個のパターンが順次想起されたことを示している。また図中 \uparrow, \leftarrow 印は学習時に形成された連合のうち想起の際に選択された連合を示す。これにより, 認識細胞形成系, 統合細胞形成系によって学習時に形成された種々の連合を介した複雑な連想の順次移行や分岐の機能が実現されていることがわかる。

以上のような連想の順次移行や分岐の機能は中野のモデル⁽⁷⁵⁾の動的な連想機能と似た面をもっているが, 認識細胞を基礎として学習によりパターン分類を行い, その分類に応じたパターン間の連合が自己組織的に形成される点, 更にその連合を通して連想が移行していく点で異なる。

6. 5 結言

認識細胞の自己形成機構を基礎として、それに統合機構、フィードバック機構を付加した連想記憶モデルを提案し、その動作、性質を調べた。また、計算機によるシミュレーション実験を通してモデルの動作を確かめた。また、連想の分岐の機能について考察した。その結果、このモデルでは、学習過程において、特徴パターンが認識細胞層で異なった基準のもとで分類され、統合機構を通してその分類に応じたパターン間の連合が自己組織的に形成されること、更に想起過程において、統合機構、フィードバック機構によりその連合を介した連想の順次移行や分岐の機能が実現できることを示した。これらの機能に関する更に詳しい検討や生理学的知見との関連性の検討が残されている。

第7章 認識細胞形成系の回転パターン表現への応用^{(65), (66)}

7. 1 緒言

連想記憶以外にもパターン認識や外界情報の脳内表現に関する多くのニューラルネットワークモデル^{(14), (34), (45), (46), (47), (79), (82)}が提案され、神経系の情報処理機能が考察されている。しかし、回転パターンの内部表現や思考過程に関する考察などはほとんどなされていない。また、心的回転の機能に関しては理論的考察⁽¹²⁾があるが、ニューラルネットワークでの検討はほとんどなされていない。生体の神経系において、回転パターンがどのような形で表現され、どのようにして回転操作が行われるかなどを考察することは興味深い。最近、階層型ニューラルネットワークにおける誤差逆伝播学習^{(41), (42)}が提案され、その学習能力が注目されている。この学習法を適用した例^{(71), (72), (85)}も多く提案されている。しかし、この学習法においては、入力パターンに対する望ましい出力(目標パターン)がその教師信号として与えられなければならない。先に第4章で認識細胞領域の自己形成モデルを提案し、入力パターンの類似度によるパターン分類を自己組織的に進めることを示した。このモデルを誤差逆伝播学習のニューラルネットワークの教師信号形成に適用することは興味深いと考えられる。

この章では、認識細胞形成系のもう一つの応用として、回転パターンを学習、表現するニューラルネットワークモデルを提案する。これは認識細胞領域形成システムを階層型3層ニューラルネットワークにおける誤差逆伝播学習の教師信号形成に適用したものである。モデルは形状検出システム、回転角検出システム、自己連合システムおよび形状-回転角連合システムからなる。種々の回転パターン入力のもとでこのモデルの動作を調べる。その結果、モデルは認識細胞領域形成システムによる類似度に応じた分類のもとに、回転パターンを回転に依存しない基本形状と基本形状に対する回転角という形で表現できることを示す。また、自己連合システム、形状-回転角連合システムによって回転パターンの順次想起(思考過程における回転操作)の機能を実現できることを示す。このような動作、性質を計算機によるシミュレーション実験によって確かめる。これによって、モデルが回転パターンの表現に有効であることを示す。更に、モデルがニューラルネットワークによって心的回転の機能を説明する一つの手がかりになり得ることを示す。

input layer hidden layer output layer




図 7. 1 階層型 3 層ニューラルネット

7. 2 誤差逆伝播学習^{(41), (42), (51)}

図 7. 1 に 3 層の階層型ニューラルネットを示す。これは第 1 層（入力層）、第 2 層（隠れ層）、第 3 層（出力層）からなる。第 k 層の第 i ユニットの入力 $s^{(k)}$ は、第 k 層の第 i ユニットの総和、およびその出力をそれぞれ $s^{(k)}$ 、 $o^{(k)}$ と表す。また、ユニットの出力関数を f で表す。各層のユニットは前の層のすべてのユニットから入力を受ける。ここで、 k 層の第 i ユニットの結合荷重を $w^{(k,k+1)}_{ij}$ と表す。更に、 $k+1$ 層の第 j ユニットの結合荷重 $w^{(k,k+1)}_{0j}$ を介して、常に -1 の入力を受ける。この入力は $k+1$ 層の各ユニットのしきい値に対応する。学習用の入出力パターンの組として、入力パターンとその望ましい出力（目標パターン）の組の集合 $\{(x_p, t_p)\}$ ($p=1, L$) が用意されているとする。いま、適当な入力パターン x を入力したとき出力層の第 m ユニットの出力を $o^{(3)}_m$ とし、対応する目標パターン t の第 m 成分を t_m とする。このとき、誤差逆伝播学習では次の式に従って各結合荷重が修正される。

$$w^{(23)}_{jm} = w^{(23)}_{jm} + \eta \delta^{(3)}_m o^{(2)}_j \quad (7.1)$$

$$w^{(12)}_{ij} = w^{(12)}_{ij} + \eta \delta^{(2)}_j o^{(1)}_i$$

ここに、 η は学習の速度を決めるパラメータで小さな正数、 $o^{(2)}_j$ 、 $o^{(1)}_i$ はそれぞれ第 2 層の第 j ユニットの出力、第 1 層の第 i ユニットの出力である。また、 $\delta^{(3)}_m$ 、 $\delta^{(2)}_j$ は

$$\delta^{(3)}_m = (t_m - o^{(3)}_m) f'(s^{(3)}_m) \quad (7.2)$$

$$\delta^{(2)}_j = f'(s^{(2)}_j) \sum_m w^{(23)}_{jm} \delta^{(3)}_m$$

で与えられる。ここに、 $s^{(3)}_m$ は第 3 層の第 m ユニットの総和、 $s^{(2)}_j$ は第 2 層の第 j ユニットの総和である。また、 f はロジスティック関数

$$f(s) = 1 / (1 + \exp(-s))$$

で、 f' はその微分を示す。

この学習は、ネットワークが学習に用意されたパターンの組 $\{(x_p, t_p)\}$ ($p=1, L$) に関して、その 2 乗誤差の総和

$$R = \sum_p (t_p - o^{(3)}(x_p))^2 \quad (7.3)$$

を極小にするものであることが知られている⁽⁴¹⁾。すなわちネットワークでは入力パターン x_p に対して、その目標パターン t_p を出力するように各層間の結合荷重が学習される。

7. 3 回転パターン学習システム

図 7. 2 に回転パターンを学習するニューラルネットモデルを示す。モデルは形状検出システム (form-detecting system)、回転角検出システム (angle-detecting system)、自己連合システム (self-associative system) および形状-回転角連合システム

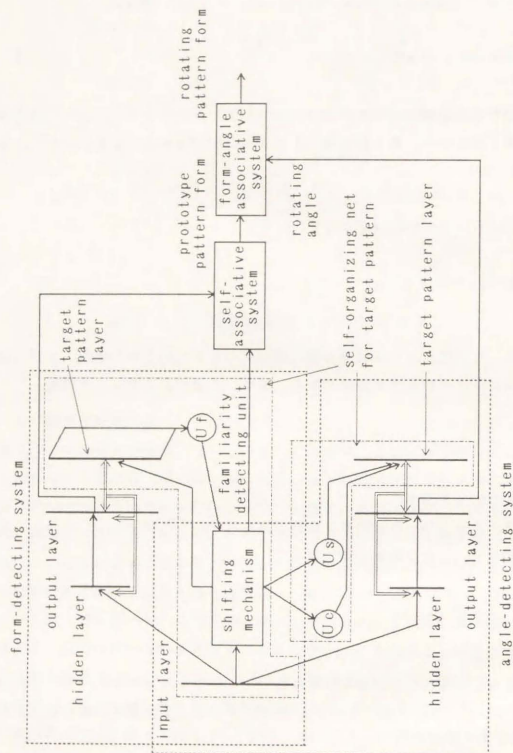


図7-2 回転パターン学習ニューラルネットワーク

(form-angle associative system)からなる。以下、各システムについて説明する。

7. 3. 1 形状検出システム

このシステムは、入力される回転パターンから、回転の基本となる形状（基本形状：回転角検出の基準となる回転角 0° に対応する形状）を検出し、学習を通して回転パターンを基本形状の類似度のもとで分類することによって、同じ基本形状をもつ回転パターンの集合に対して回転に依存しない一つの安定な興奮パターン（基本形状の内部表現パターン）を作り出すものである。このシステムは階層型の3層ニューラルネットと目標パターン形成ネットからなる。3層のニューラルネットは7.2で述べたニューラルネットと同じ構造である。目標パターン形成ネットは、入力層、シフト機構、目標パターン層、および親近性検出ユニット U_f からなる。また、シフト機構出力→目標パターン層のネットは第4章で述べた認識細胞領域形成システムと同じ構造をもつ。入力層には、図7.3に示すように、2次元パターンに含まれる極座標形式の格子点から作られる入力パターン $x(i, j)$ (i :半径方向成分, j :角度方向成分)が与えられる。回転パターンが与えられる場合の回転中心は固定されているものとする。入力パターンはシフト機構を通り、目標パターン層に与えられる。シフト機構には4個のブロック（半径方向成分の数）がある。図7.4にその第 i ブロック（半径方向成分 i に対応する）の構造を示す。他のブロックも同じ構造をもつ。第 i ブロックの第1層には、入力パターンの半径方向第 i 成分 $x(i, j)$ ($j=1, 8$)が入力される。第2層のユニットはその入力を受け、最初に入力パターンをそのまま出力する。次に、フィードバックにより、第2層のユニット j の出力はユニット $j+1$ への入力となる。このとき、第1層への入力は既に消滅しているものとする。これにより、次の時刻には1時刻前の第2層の発火部分が角度方向へ1ユニット分シフトする。他のブロックもすべて同時に同じ動作を行う。これによって、入力パターンは角度方向へ1つシフトしたパターンに変換される。シフト機構の各ブロックは親近性検出ユニットからの抑制信号を受けない限りこの動作を一定時間繰り返す。第2層の出力パターンが順次目標パターン層への入力を形成する。親近性検出ユニットは目標パターン層のすべてのユニットから一定の結合荷重を介して入力を受け、ある一定のしきい値を越えたと興奮し、シフト機構に抑制信号を送ることによって、シフト動作を停止させる。

以下に、目標パターン形成ネット内に入力パターンの基本形状が取り込まれ、学習される過程を説明する。ある入力パターンが入力層に与えられると、それはシフト機




図7-3 極座標形式による入力パターン

構を通り、最初は入力パターンそのものが目標パターン層への入力になる。目標パターン層の各ユニットは修正可能な結合荷重を介してその入力を受け、出力を出す。このとき、すべてのユニットの出力の総和（発火量）が一定のしきい値をこえると、親近性ユニットが興奮し、シフト機構へ抑制性信号を送る。その結果、シフト動作が停止する。同時に目標パターン層へ与えられている入力パターンが基本形状としてネット内に取り込まれ、一定時間学習される（第3章参照）。最初の入力に対する発火量がしきい値を越えない場合は、シフト機構によって角度方向へ1ユニット分シフトしたパターンが今度は目標パターン層への入力になる。このシフトは発火量がしきい値を越えるまで繰り返され、ある時点で発火量がしきい値を越えると、そのとき目標パターン層に与えられているパターンが、入力層に与えられている入力パターンの基本形状として取り込まれ、学習される。このとき、どのパターンが基本形状として取り込まれるかは結合荷重の状態と親近性検出ユニットのしきい値に依存する。このよう

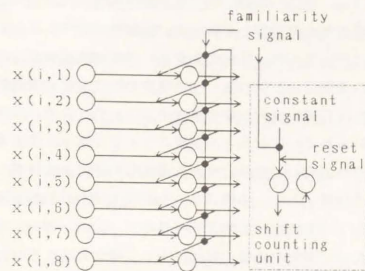


図7-4 シフト機構（第iブロック）

な過程が各入力パターンに対して実行される。過去に取り込まれた基本形状に回転が加わった形状をもつ入力パターンに対しては、シフトを繰り返すうちに、目標パターンへの入力が過去に取り込まれた基本形状と一致するので、発火量は一定のしきい値を越える。その結果、その入力パターンに対しては、過去に学習された基本形状と同じ基本形状が取り込まれ、学習される。それと同時に、基本形状からの角度方向のずれ（基本形状に対する回転角）が回転角検出システム（後述）に並列的に取り込まれ、学習される。一方、過去に取り込まれた基本形状とは異なった基本形状をもつ入力パターンに対しては、ある時点での発火量がしきい値を越えれば、そのとき目標パターン層に与えられているパターンが新しい基本形状として取り込まれ、学習される。シフトを一定時間繰り返しても発火量がしきい値を越えない場合は、シフト機構はその動作を停止し、そのときのパターンが入力パターンの基本形状として新しく目標パターン形成ネット内に取り込まれる。このような過程を繰り返すことによって、異なっていくつかの基本形状が取り込まれる。目標パターン形成ネットはそれらの基本形状のもとでの学習を通して、個々の基本形状に対する認識細胞領域を目標パターン層に形成していく。言い換えれば、目標パターン層には同じ基本形状をもつ回転パターンの集合に対して安定な認識細胞領域（興奮パターン）が形成されていく。ここに、学

習パラメータは式(4.33)に従って、適当な値が取られるものとする。

目標パターン形成ネットの学習と並行して、3層ニューラルネットでの学習も同時に進行する。3層ニューラルネットでの学習は、誤差逆伝播学習(7.2参照)に従って、入力層-隠れ層間および隠れ層-出力層間の結合荷重を修正するものである。この学習においては、目標パターン層の興奮パターンが、入力パターンに対する目標パターンとして用いられる。すなわち、3層ニューラルネットの各層間の結合荷重は入力パターンと、それに対して取り込まれた基本形状に対する目標パターン層の興奮パターンに基づいて学習される。目標パターン形成ネットの学習過程からわかるように、3層ニューラルネットにおける学習途中段階で、入力パターンに対する目標パターンは刻々変化するが、最終的には、目標パターン層に各基本形状の安定な認識細胞領域が形成されるので、同じ基本形状をもつ回転パターンの集合に対する目標パターンは一つの安定な興奮パターンに収束する。その結果、3層ニューラルネットは学習を通して同じ基本形状をもつ回転パターンに対して同一の興奮パターン(基本形状の内部表現パターン)を出力するようになる。すなわち、入力パターンは、それに対して取り込まれた基本形状の類似度に基づいて分類される。

このように、形状検出システムは、回転パターンのもつ1つの特徴として「回転に依存しない基本形状」を表現する。

7.3.2 回転角検出システム

このシステムは、入力される回転パターンが、それに対して形状検出システムで取り込まれた基本形状から角度方向にどの程度ずれているか、すなわち基本形状に対する回転角を学習するものである。また、その学習を通して、入力される回転パターンを回転角の類似度のもとで分類することによって、類似した回転角をもつ回転パターンの集合に対して一つの安定な興奮パターン(回転角の内部表現パターン)を作り出すものである。このシステムも形状検出システムと同様に、階層型の3層ニューラルネットと目標パターン形成ネットからなる。シフト機構にはシフト度数検出ユニット(図7.4)があり、これは入力パターンに対して、形状検出システムにその基本形状が取り込まれるまでにどの程度のシフトが行われたか、すなわち基本形状からの角度方向のずれの度合を検出するユニットである。このユニットはシフトの度数に応じた出力(回転角 θ)を、異なった出力特性($f_c(\theta)=\cos\theta$, $f_s(\theta)=\sin\theta$)をもつ二つのユニット U_c , U_s に送る。二つのユニットはシフト度数検出ユニットからの入力 θ に対して、それぞれ $\cos\theta$, $\sin\theta$ を出力する。この出力が目標パターン形成ネット

への入力を形成する。このような機構を通して回転角検出システムには、形状検出システムと並行して、いくつかの回転角が取り込まれる。目標パターン形成ネットはそれらの回転角のもとでの学習を通して、類似した回転角からなる集合の認識細胞領域を目標パターン層に形成していく。言いかえれば、目標パターン層には、類似した回転角をもつ回転パターンの集合に対して安定した認識細胞領域(興奮パターン)が形成されていく。

これと並行して、3層ニューラルネットの学習も形状検出システムにおけると同様に行われる。その結果、3層ニューラルネットは最終的に、類似した回転角をもつ回転パターンに対して同一の興奮パターン(回転角の内部表現パターン)を出力するようになる。すなわち、回転パターンは基本形状に対する回転角の類似度に基づいて分類される。このように、回転角検出システムは、形状検出システムと並行して、回転パターンのもつもう1つの特徴として「基本形状からの回転角」を表現する。

以上のように、回転パターンは形状検出システム、回転角検出システムを通して、2つの特徴(「回転に依存しない基本形状」と「基本形状からの回転角」)によってニューラルネット内に表現される。

7.3.3 その他の学習システム

回転パターン学習システムには、上に述べた学習システムの他に自己連合システムと形状-回転角連合システムがある。自己連合システムでは、形状検出システムに取り込まれる基本形状とその内部表現パターン(出力層の出力パターン)とが相関学習により連合される。その際、基本形状が教師の役割を果たす。形状-回転角連合システムは7.3.2で述べた3層ニューラルネットと同じ構造をもち、自己連合システムの出力(基本形状)と回転角検出システムの出力(回転角の内部表現パターン)とを入力として、誤差逆伝播学習に従って各層間の結合荷重が修正される。その際、入力層に与えられている入力パターンが学習の目標パターンになる。これらの二つの連合システムは形状検出システムおよび回転角検出システムで形成された内部表現パターンから、基本形状、更に、回転角に応じた回転パターンを作り出す役割を果たす。

7.4 連想・思考過程

以上の学習システムを通して学習が行われた後、入力層に特定のパターンが与えられるとする。このとき、入力パターンは目標パターン形成ネットを媒介することなく、形状検出システムおよび回転角検出システムの3層ニューラルネットによって処理さ

れ、各出力層に、そのパターンの基本形状およびその基本形状に対する回転角に対応する内部表現パターンが想起される。次に、基本形状に対する内部表現パターンをもとに自己連合システムからはその基本形状が想起される。更に、形状-回転角連合システムにおいて、その基本形状に回転角に対応する内部表現パターンが作用することによって回転角に応じた回転パターンが作り出され、出力される。このことは同じ基本形状に対して種々の回転角（回転角検出システム出力層の興奮領域の移動）を作用させることによって、回転角に応じたいろいろな回転パターンが作り出されることを意味している。このような、基本形状に回転角が作用することによっていろいろな回転パターンが作り出されるという過程は生体の連想・思考過程に似た一面をもっているのではないかと考えられる。

7. 5 計算機実験

計算機によるシミュレーション実験を通してモデルの動作を確かめる。3層ニューラルネットにおける入力層、隠れ層および出力層の次元は、

$$n_1 = 32, n_2 = 5, n_3 = 51$$

とした。また、各層間の結合荷重の初期値は一様分布により決定した。学習のパラメータは0.25とした。また、目標パターン形成ネットの結合荷重の初期値は一様分布により決定した。側抑制型相互結合 v は第4章で用いた方形関数(図4.4)とした。興奮作用をおよぼす範囲とその大きさ b_1, h_1 、抑制作用をおよぼす範囲とその大きさ b_2, h_2 を適当な値に選び、学習パラメータ ϕ ($=C'/C$)は0.93($C'=0.93, C=1.0$)とした。また、親近性検出ユニットと目標パターン層の各ユニット間の結合荷重は $1/51$ とし、親近性検出ユニットのしきい値を0.3とした。入力パターンとして用いた16個のパターンを図7.5に示す。図7.5において、番号(3)、(5)、(7)、(9)、(11)、(13)、(15)のパターンは、番号(1)のパターンを回転中心を固定して回転することによって作られたものである。また、番号(4)、(6)、(8)、(10)、(12)、(14)、(16)は番号(2)のパターンを回転することによって作られたものである。図7.5のパターン番号の順番に、入力パターンを順次入力層に与え、各システムの学習を行った。図7.6に形状検出システム、回転角検出システムにおける学習結果を示す。各図の横軸(-)は出力層の各ユニットを示す。図7.6(a)は形状検出システムにおける出力層の、各入力パターンに対する興奮領域を示している。図中、Tは番号(




図7.5 入力パターン

1)、(3)、(5)、(7)、(9)、(11)、(13)、(15)の入力パターンからなる集合、Zは番号(2)、(4)、(6)、(8)、(10)、(12)、(14)、(16)の入力パターンからなる集合を表す。図は出力層の各ユニット(-)がその上に記されている集合に属するパターンに対して興奮したことを示している。この図から、入力パターンがその基本形状の類似度に基づいて、2つのパターン集合(T、Z)に分類され、各集合に対する興奮領域が重ならない形で形成されていることがわかる。すなわち、形状検出システムは、回転パターンを「回転に依存しない基本形状」によってうまく表現していることがわかる。尚、この実験において、2つのパターン集合T、Zに対して取り込まれた基本形状はそれぞれ番号(1)と(2)であることが、自己連合系の出力によって確認された。図7.6(b)は回転角検出システムにおける出力層の、各入力パターンに対する興奮領域を示している。図中、↑は形状検出システムで基本形状として取り込まれた番号(1)、(2)、(10)からなるパターン集合を表す。他の矢印は、基本形状(↑)に対する回転角が同じものとして取り込まれた入力パターンの集合を表す(図7.5矢印参照)。例えば、↘は番号(8)、(15)、(16)のパターンからなる集合である。図は出力層の各




図 7. 6 3 層ニューラルネットワークにおける学習結果

ユニットが、その上に記されている集合に対して興奮したことを示している。この図から、入力パターンが回転角の類似度に基づいて8個のパターン集合(↑, ↘, ←, ↙, ↓, ↗, →, ↖)に分類され、各々の集合に対する興奮領域が重ならない形で形成されていることがわかる。すなわち、回転角検出システムは、回転パターンを「基本形状に対する回転角」によってうまく表現していることがわかる。

以上のことから、回転パターンは2つの特徴、「回転に依存しない基本形状」と「基本形状に対する回転角」によって並列的にうまく表現されていることがわかる。尚、実験において、親近性検出ユニットのしきい値や結合荷重の初期値の変化によって、形状検出システムに異なる基本形状が取り込まれることが確かめられた。図7. 6(c)は、回転角検出システムの目標パターン形成ネットにおける結合荷重の初期値を図7. 6(b)とは別の方法で設定した場合の学習結果である。図(c)は(b)と同様に、回転角検出システムにおける出力層の、各入力パターンに対する興奮領域を示している。矢印の意味も(b)と同じである。この場合、回転角の類似度に従ってその興奮領域が順序よく配列されて形成されていることがわかる。図7. 7に、学習後入力層に特定のパターン(T)を与え、別の制御によって回転角検出システムの出力層(図7. 6(c))の興奮領域を移動した場合の、自己連合システムと形状-回転角連合システムの出力パターンを示す。この場合、自己連合系からは学習時にネットに取り込まれた




図 7. 7 想起される回転パターン

基本形状が、形状-回転角連合システムからは回転角に応じた回転パターンが回転角の類似性の順序に想起されていることがわかる。このことは、神経系において興奮領域を移動させるための別の制御機構が存在する可能性を示唆するとともに、その制御機構によって回転パターンの順次想起の機能が実現できることを示している。更に、このことはニューラルネットを用いて心的回転の機能を説明する一つの手がかりになり得ることを示唆している。

7. 6 結言

回転パターンを学習、表現するニューラルネットモデルを提案した。これは認識細胞領域の自己形成システムを階層型3層ニューラルネットにおける誤差逆伝播学習の教師信号形成に適用したものである。モデルは、形状検出システム、回転角検出システム、自己連合システムおよび形状-回転角連合システムからなる。回転パターン入力のもとでこのモデルの動作を調べられた。また、計算機によるシミュレーション実験によりその動作が確かめられた。その結果、形状検出システム、回転角検出システムが、回転パターンをそれぞれ「回転に依存しない基本形状」と「基本形状に対する回転角」の類似度に基づいて自己組織的に分類し、それぞれの3層ニューラルネット内にそれらの内部表現を並列的に形成できることを示した。また、自己連合システム、形状-回転角連合システムを通して、基本形状に回転角が作用することによって種々の回転パターンを作り出すことができ、回転パターンの順次想起の機能を実現できることを示した。これによって、このモデルが回転パターンの表現に有効であることを示した。

しかし、解決すべき問題点も多く残されている。回転角検出システムにおけるユニット U_0 、 U_1 の出力特性や3層ニューラルネットにおける結合荷重が正負の値をとり得る点で、生理学的事実とは異なっている。また、形状検出システムにおけるシフト機構の存在についてもその証拠はない。また、ここで取り扱った入力パターンは2次元パターンから作られるベクトルであり、本質的には2次元場のパターンではない。2次元場のパターンに対する検討が必要である。更に、機能的には、特定のパターンに対して形状-回転角連合システムで学習された特定の回転しか想起できない。これに比べ、神経系においては、回転という概念ができあがれば、おおまかではあってもあらゆる回転が可能であると考えられる。このことは、回転の概念が別の学習機構によって確立される可能性も示している。このような点について、今後詳しく検討していく必要がある。しかし、ニューラルネット内に回転パターンがその基本形状と基本

形状に対する回転角という形で並列的に表現される機構、また基本形状に回転角が作用することによって回転パターンを再生する機構等は回転パターンの学習、思考過程（例えば、心的回転の機能）に対する一つの手がかりを与えるものと考えられる。

第8章 結論

本研究の目的は構成的方法の観点から、認識細胞の自己形成機構の原理を明らかにし、その応用として認識細胞を結びつけた連想記憶の機構、また回転パターンの脳内表現や思考過程の機構について考察することであった。

第2章では、甘利によって体系化されている理論およびモデルの中から、特に本論文の数理的基礎となる神経細胞の学習理論、神経場の興奮パターンの力学、更に競合、協調の数理モデル（基本競合系）を抜粋して概説した。

第3章では、甘利一竹内によって提案された認識細胞の自己形成モデルの機能を拡張した。それによって、入力パターン間の類似度に基づいて種々のパターン分類が行えて、連想記憶、パターン認識等の情報処理機能にとって都合のよい特性をもつことを明らかにした。

第4章では、側抑制結合を有する神経場における認識細胞のトポグラフィの配列（認識細胞領域）の形成について考察し、 n 次元連続値パターンからなる環境のもとで、特定のパターン集合に対する認識細胞領域が形成されるための必要条件を明らかにした。これにより、学習パラメータの値によって、入力パターン間の類似度に応じた認識細胞領域が形成されること、また形成される認識細胞領域の幅が入力パターンの出現確率やノルムに依存することを明らかにした。更に、計算機によるシミュレーション実験を通して、類似度の高いパターン同士は神経場の互いに近い場所にその認識細胞領域が形成されること、すなわち認識細胞のトポグラフィ的配列構造が実現されることを明らかにした。

第5章では、認識細胞形成と上位概念の形成とを直接結びつけた連想記憶モデルを提案し、上位概念の連合を介した多重連想機能を考察した。これにより、相互想起、自己想起両方において記憶パターンの順次想起が比較的に簡単に行えることを示すと共に、認識細胞の果たす連想記憶への一つの役割を明らかにした。

第6章では、認識細胞の自己形成機構を基礎として、それに統合機構、フィードバック機構を付加した連想記憶モデルを提案し、その動作、性質を考察した。それにより、記憶過程におけるパターン間連合の自己形成、想起過程におけるその連合を介した連想の順次移行、連想の分岐機能など生体のもつ連想機能に似た動作を実現できることを明らかにした。

第7章では、誤差逆伝播学習の教師信号の自己形成に認識細胞の形成系を適用することによって、回転パターンを学習、表現する神経回路モデルを構成した。これによ

って、回転パターンは神経回路内にうまく表現され、更に思考過程における回転操作などの機能を実現できることを示した。

以上、7章のうち第3章、第4章は認識細胞の自己形成機構の原理を明らかにしたものであり、第5章から第7章はその応用として、認識細胞の自己形成機構に基礎をおく連想記憶の機構、回転パターンの脳内表現と思考過程の機構について考察したものである。それゆえ、本研究の当初の目的は一応達成されたものと思われる。しかし、解決すべき研究課題も多く残されている。たとえば、

- (1) 側抑制結合を有する神経場において、各パターン集合に対して複数個の認識細胞領域が形成される場合の解析（第4章参照）。
- (2) 認識細胞領域の形成におけるトポグラフィ構造の保持に関する詳しい解析（第4章参照）。
- (3) 認識細胞の自己形成機構に基づいた連想記憶モデルにおける連想機能の詳しい考察と、生理学的知見との関連性の検討（第5、6章参照）。
- (4) 回転パターンの学習、表現モデルにおける2次元場のパターンに対する考察と思考過程における回転操作のための学習方法を探ること（第7章参照）。などが挙げられる。

謝 辞

本論文は電子情報通信学会技術研究報告, 同学会論文誌 (A, D), Biological Cybernetics, および IEEE Transactions on Systems, Man and Cybernetics を経てようやくこの形にまとまったものである。本研究の全過程を通じて終始親切な御指導を頂いた東京大学工学部計数工学科甘利俊一教授に心から感謝します。

また, 適切な御助言を頂いた東京大学工学部計数工学科鈴木良次教授, 伏見正則教授, 吉澤修治助教授, 中野肇助教授に深く感謝します。

更に, 筆者が学生時代よりひとかたならぬ御指導と御教示を頂いた山口大学工業短期大学部鳥岡豊士教授に深く感謝します。

参 考 文 献

- (1) Ackley, D.H. and Hinton, G.E.: "A learning algorithm for Boltzman Machines", Cognitive Science, 9, pp.147-169(1985).
- (2) Amari, S.: "Learning patterns and pattern sequence by self-organizing nets of threshold elements", IEEE Trans. Comput., C-21, 11, pp.1197-1206(1972).
- (3) Amari, S.: "Neural theory and concept-formation", Biol. Cybern., 26, pp.175-185(1977).
- (4) Amari, S.: "Dynamics of pattern formation in lateral-inhibition type neural fields", Biol. Cybernetics, 27, pp.77-87(1977).
- (5) Amari, S. and Takeuchi, A.: "Mathematical theory on formation of category detecting nerve cells", Biol. Cybernetics, 29, pp.127-136(1978).
- (6) Amari, S.: "Topographic organization of nerve fields", Bull. Math. Biology, 42, pp.339-364(1980).
- (7) Amari, S.: "Field theory of self-organizing neural nets", IEEE Trans. Syst. Man & Cybern., SMC-13, 5, pp.741-748(1983).
- (8) Amari, S. and Maginu, K.: "Statistical neurodynamics of associative memory", Neural Networks, 1, pp.63-73(1988).
- (9) Blakemore, C. and Cooper, G.E.: "Development of the brain depends on the visual environment", Nature, 228, pp.477-478(1979).
- (10) Blakemore, C. and Mitchell, D.E.: "Environmental modification of the visual cortex and neural basis of learning and memory", Nature, 241, pp.467-468(1973).
- (11) Blakemore, C. and Sluysters, R.C.: "Environment factor in the development of the kitten's visual cortex", J. Physiol., 248, pp.663-716(1975).
- (12) Carlton, E.H.: "Connection between internal representation of rigid transformation and cortical activity paths", Biol. Cybern., 59, pp.419-429(1988).
- (13) Crick, F. and Mitchison, G.: "The function of dream sleep", Nature, 304, 14, pp.111-114(1983).

- (14) Frohn, H., Geiger, H. and W. Singer: "A self-organizing neural networks sharing features of mammalian visual system", *Biol. Cybern.*, 55, pp.333-343(1987).
- (15) Fukushima, K.: "Cognitron: a self-organizing multilayered neural network", *Biol. Cybernetics*, 20, pp.121-136(1975).
- (16) Fukushima, K.: "A hierarchical neural network model for an associative memory", *Biol. Cybernetics*, 50, pp.105-113(1984).
- (17) Grossberg, S.: "On the development of feature detectors in the visual cortex with applications to learning and reaction-diffusion systems", *Biol. Cybernetics*, 21, pp.145-159(1976).
- (18) Hall, R. and Yau, S.S.: "The distribution of orientation of optical stimuli for cells of striate cortex", *Biol. Cybernetics*, 21, pp.113-120(1976).
- (19) Hebb, D.O.: "The Organization of Behavior", New York: Wiley(1949).
- (20) Hirai, Y.: "A template matching model for pattern recognition: self-organization of templates and template matching by disinhibitory neural network", *Biol. Cybernetics*, 38, pp.91-101(1980).
- (21) Hirai, Y.: "A model of human associative processor(HASP)", *IEEE Trans. Syst. Man & Cybern.*, SMC-13,5, pp.851-857(1983).
- (22) Hirsch, H.V.B. and Spinelli, D.N.: "Modification of the distribution of receptive field orientation in cats by selective visual exposure during development", *Exp. Brain Res.*, 13, pp.509-527(1971).
- (23) Hopfield, J.J.: "Neural networks and physical systems with emergent collective computational abilities", *Proc. Natl. Acad. Sci. USA*, 79, pp.2554-2558(1982).
- (24) Hopfield, J.J., Feinstein, D.I. and Palmer, R.G.: "Unlearning has a stabilizing effect in collective memories", *Nature*, 304, 14, pp.158-159(1983).
- (25) Hubel, D.H. and Wiesel, T.N.: "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex", *J. Physiol.*, 160, pp.106-154(1962).
- (26) Hubel, D.H. and Wiesel, T.N.: "Receptive fields of cells in striate

- cortex of very young, visually inexperienced kittens", *J. Neurophysiol.*, 26, pp.994-1002(1963).
- (27) Hubel, D.H.: "Effect of distortion of sensory inputs of the visual system of kittens", *J. Physiol.*, 10, pp.17-45(1967).
- (28) Ikeda, N. and Torioka, T.: "Formation of segregated regions of feature detecting cells in self-organizing nerve field", *Biol. Cybernetics*, 62, pp.29-37(1989).
- (29) Ikeda, N. and Torioka, T.: "A model of associative memory based on adaptive feature detecting cells", *IEEE Trans. Syst., Man, and Cybern.* SMC-20, 2(1990).
- (30) Kohonen, T.: "Correlation matrix memories", *IEEE Trans. Comput.*, C-21, pp.353-359(1972).
- (31) Kohonen, T.: "Associative Memory", Springer(1978)
- (32) Kohonen, T.: "A simple paradigm for the self-organized formation of structured feature maps", *U.S.-Japan Seminar on Competition and Cooperation in Neural Nets*(1982).
- (33) Kohonen, T.: "Self-organized formation of topologically correct feature maps", *Biol. Cybernetics.*, 43, pp.59-69(1982).
- (34) Kurogi, S.: "A model of neural network for spatiotemporal pattern recognition", *Biol. Cybernetics*, 57, pp.103-114(1987).
- (35) Malsburg, C.: "Self-organizing of orientation sensitive cells in the visual cortex", *Kybernetik*, 14, pp.85-100(1973).
- (36) Nagano, T.: "A model of visual development", *Biol. Cybernetics*, 26, pp.45-52(1977).
- (37) Nakano, K.: "Associatron - a model of associative memory", *IEEE Trans. Syst. Man & Cybern.*, SMC-2, pp.311-318(1972).
- (38) Nass, M.M. and Cooper, L.M.: "A theory for the development of feature detecting cells in the visual cortex", *Biol. Cybernetics*, 19, pp.1-18(1975).
- (39) Palm, G.: "On associative memory", *Biol. Cybernetics*, 36, pp.19-31(1980).
- (40) Reilly, D.L., Cooper, L.N. and Elbaum, C.: "A neural model for category

- learning", Biol. Cybernetics, 45, pp.35-41(1982).
- (41) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: "Learning internal representations by error propagation", in Parallel Distributed Processing, 1, MIT Press(1986).
- (42) Rumelhart, D.E., Hinton, G.E. and Williams, R.J.: "Learning representations by back-propagating errors", Nature, 323, pp.533-536(1986).
- (43) Shinomoto, S.: "A cognitive and associative memory", Biol. Cybernetics, 57, pp.197-206(1987).
- (44) Takeuchi, A. and Amari, S.: "Formation of topographic maps and columnar structures", Biol. Cybernetics, 35, pp.63-72(1979).
- (45) Treub, A.: "Neuronal models for cognitive processes: Networks for learning, perception and imagination", J. theor. Biol., 55, pp.141-169(1977).
- (46) Treub, A.: "Associative sequential recall in a synaptic matrix", J. theor. Biol., 81, pp.569-576(1979).
- (47) Treub, A.: "Visual-cognitive neuronal networks", in Vision, Brain, and Cooperation and competition, MIT Press(1987).
- (48) Wigstrom, H.: "A neuron model with learning capability and its relation to mechanism of association", Kybernetik, 12, pp.204-215(1973).
- (49) Wigstrom, H.: "Associative recall and formation of stable mode of activity in neural network model", J. Neuro. Research, 1, pp.281-31(1975).
- (50) Willshaw, D.J. and Malsburg, C.: "How patterned neural connections can be set up by self-organization", Proc. R. Soc. Lond., B, 194, pp.431-445(1976).
- (51) 麻生英樹: "ニューロコンピューティング", 情報処理, 29, 9, pp.966-973(1988).
- (52) 甘利俊一: "神経回路網の数理", 産業図書(1978).
- (53) 甘利俊一: "脳の情報処理機構", 信学論(D), J69-D, 8, pp.1133-1144(1986).
- (54) 池田, 鳥岡: "重なり率の意味でのパターン分離機能を用いた連想記憶", 信学技報, MBE80-34, pp.9-16(1980).
- (55) 池田, 鳥岡: "パターン分離機能をもつ連想記憶のモデル", 信学論(A), J63-A, 12, pp.943-944(1980).
- (56) 池田, 鳥岡: "特徴検出細胞の自己形成について", 信学技報, MBE82-71, pp.25-32(1983).
- (57) 池田, 鳥岡: "特徴検出機構の連想記憶への応用", 信学技報, MBE83-2, pp.9-16(1983).
- (58) 池田, 鳥岡: "特徴検出細胞の形成機構に基礎をなす連想記憶モデル", 信学技報, MBE83-25, pp.39-46(1983).
- (59) 池田, 鳥岡: "特徴検出細胞に基礎をおく連想記憶モデル", 信学論(A), J67-A, 5, pp.519-526(1984).
- (60) 池田信彦: "認識細胞の自己形成について", 信学技報, MBE85-105, pp.209-216(1986).
- (61) 池田, 鳥岡: "抑制入力をもつ連想記憶モデルの基礎的考察", 信学論(D), J70-D, 10, pp.1961-1967(1987).
- (62) 池田, 鳥岡: "神経場における認識細胞群の自己形成について", 信学論(D), J71-D, 3, pp.587-595(1988).
- (63) 池田, 鳥岡: "認識細胞の自己形成系を用いた連想記憶", 信学技報, MBE87-152(1988).
- (64) 池田, 鳥岡: "認識細胞形成系を用いた連想記憶モデル", 信学論(D), J71-D, 11, pp.2433-2441(1988).
- (65) 池田, 鳥岡: "ニューラルネットによる回転パターンの一表現", 信学技報, MBE88-151, pp.185-190(1989).
- (66) 池田, 鳥岡: "ニューラルネットにおける回転パターン表現について", 信学論(D-II), J73-D-II, 1, pp.100-108(1990).
- (67) 上坂, 尾岡: "連想記憶の二, 三の性質", 信学論(D), 55-D, pp.323-330(1972).
- (68) 倉田, 甘利: "確率的に動作する自己組織神経回路網について", 信学技報, MBE85-104(1986).
- (69) 黒木, 市川: "インパルス系神経回路細胞モデルを用いる特徴抽出細胞の自己形成系", 信学論(A), J68-A, 2, pp.195-202(1985).
- (70) 黒木, 市川: "インパルス型神経細胞を用いる連想記憶系", 信学論(A),


J68-A, 12, pp.1367-1373(1985).

- (71) 迫江, 磯: “ダイナミックニューラルネットワークの提案 - 神経回路網とDPマッチングに基づく新しい音声認識モデル -”, 信学論(D), J71-D, 7, pp.1341-1344(1988).
- (72) 銅谷, 吉澤: “神経回路網における運動パターンの記憶”, 信学技報, MBE87-141, pp.293-300(1988).
- (73) 鳥岡, 池田: “パターン分離層を有する連想記憶システムの連想能力”, 信学論(D-II), J72-D-II, 11, pp.1945-1953(1989).
- (74) 中野肇: “アソシアトロンとその応用-連想記憶装置に関する研究”, 信学研資, JT69-27(1969).
- (75) 中野, 南雲: “アソシアトロンに関する新しい試み-動的連想モデル-”, 信学技報, AL74-7, pp.1-12(1974).
- (76) 長藤, 木内, 牛田: “パターン検出神経回路モデルの自己組織過程”, 信学技報, MBE85-30, pp.31-36(1985).
- (77) 仁木, 佐分利: “シナプスの長期記憶を表現する学習神経モデル - H・ニューロンによる記憶・学習・自己組織化の表現と解析 -”, 信学論(A), J64-A, 11, pp.948-955(1981).
- (78) 平井有三: “連想記憶における多重マッチ分析のための神経回路モデル”, 信学論(A), J66-A, 8, pp.733-740(1983).
- (79) 平井有三: “神経回路によるパターン照合”, 信学論(D-II), J72-D-II, 1, pp.148-156(1989).
- (80) 福島, 三宅: “連想能力をもつ自己組織回路-フィードバック形コグニトロン”, 信学論(D), J60-D, 2, pp.143-150(1977).
- (81) 福島邦彦: “コグニトロンのパターン分離能力の向上”, 信学論(A), J62-A, 10, pp.650-657(1979).
- (82) 福島邦彦: “位置ずれに影響されないパターン認識の神経回路モデル - ネオコグニトロン”, 信学論(A), J62-A, 10, pp.658-665(1979).
- (83) 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(D), J69-D, pp.993-1003(1986).
- (84) 丸山, 甘利: “神経場における情報表現細胞のトポロジカルな配置について”, 信学技報, MBE84-116, pp.271-279(1985).
- (85) 森, 横澤, 梅田: “PDPモデルによる手書き文字認識”, 信学技報, MBE87-156,


pp.407-414(1988).

- (86) 森田昌彦: “連想記憶の海馬モデル”, 信学論(D-II), J72-D-II, 2, pp.279-288(1989).


付録1 音声波形入力に対する実験結果




(a) 'ア' の波形




(b) 'イ' の波形



(c) 'ウ' の波形



(d) 'エ' の波形




(e) 'オ' の波形

付図1 入力パターンとして用いた音声波形

付表1 入力パターン間の類似度


	'ア'	'イ'	'ウ'	'エ'	'オ'
'ア'	1.00	0.80	0.78	0.91	0.90
'イ'	0.80	1.00	0.83	0.73	0.78
'ウ'	0.78	0.83	1.00	0.72	0.83
'エ'	0.91	0.73	0.72	1.00	0.81
'オ'	0.90	0.78	0.83	0.81	1.00



付図2 認識細胞領域の形成 (神経場の膜電位分布)

$$\phi = 0.97$$

付録2 50個の特徴パターンに対する実験結果



付図3 学習および想起結果

