


展 望

コネクショニズムの展望

(I) 概 論†



石川 真 澄††

1. はじめに

最近、並列分散処理、コネクショニズム、PDP (Parallel Distributed Processing)、ニューラルネットなどの用語が巷にあふれている。これらはいずれも、逐次の記号処理に基づく伝統的人工知能に対して、並列的パターン処理に基づく古くて新しいパラダイムを指し示すものである(古いとは後述のパーセプトロンに始まる研究を指している)。コネクショニズムは神経科学にヒントを得て、それぞれは単純な機能しかもたない多数のユニットをネットワーク状に構成することにより、全体として複雑な機能を有する人間の認知・思考のモデルを狙おうとするものである。

5回のシリーズでコネクショニズムの展望が述べられる予定であり、本稿は全体の序論となっている。まずコネクショニズムの歴史的背景、および全体像を把握するための簡単な概要・特徴を述べる。次に最近の研究動向を三つに分類して紹介する。最後に、コネクショニズムの限界・批判・展望に関する私見を簡単に述べたい。

2. 歴史的背景

人工知能研究は、人間の思考の本質が記号操作であるというサイモンらの考え方を基礎にしている。計算手順を記したプログラムとそれに必要なデータとを記憶させこれを逐次実行させるというチューリングマシンで人間の思考をとらえようといういわゆるコンピュータメタファがそこでは採用されている。そしてプロダクションシステムが人間の認知過程のモデルと考えられた¹⁾。なぜならば、プロダクションシステムがチューリングマシンと同等な能力をもち、ルールの生成・追加が随時可能であり、人間の長期記憶と短期記憶に対応づけられる部分を有するからである。

1970年代に人工知能応用としてのエキスパートシステムが構築され、限られた範囲では成功を納めたといえよう。しかし、学習・連想・類推を始めとする人間らしいより高度な機能に関しては現在研究が進行中であり、たとえば専門家のもつ知識をルールの形でいかに抽出するかという知識獲得問題は依然としてボトルネックである。

他方、記号処理ではなくパターン処理が人間の思考の本質であるとする研究の流れがある。1960年前後にローゼンブラットらによって盛んに研究がなされたパーセプトロンがその典型例である。このパーセプトロンの能力をミンスキーらが詳細に検討した結果、当時の二層のパーセプトロンではパリティ・連結性などすら困難であるという限界が指摘された²⁾。この指摘と初期の記号主義的人工知能研究の成功のためパーセプトロンの研究は衰退した。この間に甘利が3層以上のネットワークにも適用できる学習アルゴリズムを提案しているが³⁾、3層以上になるとローカルミニマムへの収束の問題が避けられないため、理論的見地からはそれほど注目されなかった。

80年代に入り、パターン処理の流れの中でホップフィールドネット⁴⁾、ボルツマンマシン⁵⁾などの新しい提案がなされ、また甘利の学習アルゴリズムがバックプロパゲーションアルゴリズム⁶⁾という形で再発見された。これらの提案が現在のコネクショニズムの流行をもたらした要因として、以下のようなことが考えられる。

第一には、これらのアルゴリズムの学習能力がパーセプトロンのそれよりも大きかったことである。二層のパーセプトロンでは困難とされたパリティ・連結性なども容易にできたが、これは外界と直接つながっていない隠れユニットを導入したためである。隠れユニットがあると一般にネットワーク学習時に、誤りの責任をどのユニットに帰属するかというクレジット付与問題が困難になるが、上記学習アルゴリズムがその解答を与えている。

† Perspectives on Connectionism 1: Introduction by Masumi ISHIKAWA (Computer Systems Division, Electrotechnical Laboratory).

†† 電子技術総合研究所電子計算機部

第二に、隠れユニットが学習能力の増大に貢献しただけにとどまらず、ここに問題の規則性・構造性が抽出されることが期待された。これは、パターンを分節化して記号を生成するという人間の認知・思考にとっての根源的な問題と関連している。

第三に、単なるネットワークの数理的研究にとどまらず、人間の認知・思考のモデルとしてとりあげられ、心理学・人工知能・神経科学・言語学・計算機科学などからの学際的研究が行われた。このように複数の視点をもったことが大きな発展につながったと考えられる。

これと関連して第四に、パーセプトロンの衰退期の状況とは逆に、ウイノグラードが人工知能の根底にある合理主義的伝統を批判したように⁷⁾、一部で伝統的人工知能の限界が認識され始めたことから、違ったパラダイムとしてのコネクショニズムへの潜在的期待が大きかった。

第五に、ハードウェアの進歩によりネットワークのシミュレーションが手軽に行えるのみならず、並列実行さえも実現が容易となった。隠れたユニットがあり、多くの非線形性を有するネットワークの数理的解析はきわめて困難であり、シミュレーションが欠かせない。しかもこの学習には一般に膨大な計算量を必要とする。この状況ではハードウェアの進歩が必須だったといえよう。

第六に、ソフトウェアがハードウェアほどめざましく進展しないことから、労働集約的なプログラミングに代わり、例から学習可能でプログラミングが不要なコネクショニズムに対する甘い期待があった。しかし、筆者の考えでは、特殊な領域ではこのようなことが有りえないわけではないが、ソフトウェア産業全体にインパクトを与えるような大きな効果は期待薄であろう。

3. コネクショニストモデルの概要と特徴

コネクショニストモデルは、コンピュータメタファに代わり、例を与えてネットワークに学習させるというブレインメタファによる人間の認知・思考のモデルを狙ったものである。ここではプログラムが明示的に与えられず、ネットワークの中にプログラムとデータとが混然一体と埋め込まれている。

ここではコネクショニストモデルの典型例として、ボルツマンマシンとバックプロパゲーションアルゴリズムについて簡単に触れた後、これらの特徴を整理し

てみよう。

ボルツマンマシンは、ノード（ユニットともいう）が双方向性リンクで結合されたネットワークである。ユニットは仮説を表し1あるいは0のいずれかの値をとる。これらをつなぐリンクには各方向別に実数値の重みが付与されており、しかも対称である。このリンクは二つの仮説間の弱い制約を表している。したがって、ボルツマンマシンは多くの弱い制約を含んだ制約満足問題の解を求めるのに適している。解がどの程度制約をうまく満足しているかが、解釈のもっともらしさを反映している。

ネットワークには下記に示すエネルギーと呼ばれる関数 E が定義され、外界につながっているユニット（可視ユニット）の値がクランプされているという制約の下でエネルギーの値を最小にするようリンクの重みが調整される。

$$E = -\sum w_{ij}s_i s_j + \sum \theta_i s_i \quad (1)$$

ここで重み行列 $\{w_{ij}\}$ は対称行列である。


これから、 k 番目の仮説を採択したときと棄却したときのエネルギーの差は、

$$\Delta E_k = \sum w_{ki}s_i - \theta_k \quad (2)$$

であり、この式から、他のユニットおよび外界からの入力との総和が閾値 θ を越えたときに仮説 k を採択すればよいことが分かる。ただこのような決定的アルゴリズムではローカルな極小値問題が避けられない。そこでボルツマンマシンでは、これを回避するため、

$$p_k = 1/(1 + \exp(-\Delta E_k/T)) \quad (3)$$

の確率でユニット k の値を 1 にするという確率的決定規則を用いる。ここで、 T は熱力学での温度に相当している。図-1 に示すように $T=0$ とすると(2)式の決定的アルゴリズムに帰着し、数学的にはホップフィールドネットに相当している。図-1 から分かるように、低温ではエネルギーの小さい状態になるような強いバイアスが働くが、平衡状態に到達するまでの時間が長い。一方、高温ではバイアスはそれほど強くないが時間が短くてすむ。このトレードオフをはかる良い方



実線: $T=1.0$ 破線: $T=4.0$ 点線: $T=0.25$

図-1 ボルツマンマシンにおける確率的決定規則

法は高い温度からスタートして徐々に温度を下げることである。これを焼き鈍し (simulated annealing) と呼んでいる。

ボルツマンマシンはドメインに依存しない学習アルゴリズムを与える。すなわち、ユニット間の結合の強さを調整することにより外界の構造を写しとる内部モデルを生成する。詳細は省略するが、ネットワークが外界を写しとるためには、

$$\Delta w_{ij} = -\eta(p_{ij} - p'_{ij})/T \quad (4)$$

に従って重み w_{ij} を調整してゆけばよい。

ただし、 η は重みを一度にどの程度修正するかの係数、 p_{ij} は外界制約のある場合にユニット i, j がともに1である平均確率、 p'_{ij} は外界制約のない場合にユニット i, j がともに1である平均確率。

ここで重み w_{ij} を修正するのに、ユニット i, j というローカルな情報だけでよいことに注意しよう。

バックプロパゲーションのための典型的なネットワーク例として、図-2にあるような入力層・隠れ層・出力層からなる階層的ネットワークを考えよう。各層のユニットには活性度が、各リンクには実数値の重みが付与されている。ここで入力層は外界から入力パターンが与えられ、出力層はその目標パターンが外界から与えられる。一方、隠れ層は外界と直接的つながりをもたない。隠れ層・出力層の各ユニットには下位の階層 (必ずしも隣接の階層でなくてよい) から複数個のリンクが入力として入っている。

入力層以外のユニットの活性度は次のようにして定まる。いま入力パターン p がネットワークに加えられているとき、ある階層の j 番目のユニットの活性度を O_{pj} とし、下位階層の i 番目のユニットの活性度を O_{pi} とすると、

$$O_{pj} = f_j(\sum w_{ji} O_{pi}) \quad (5)$$

ただし、

w_{ji} : 下位階層の i 番目ユニットから当該階層の j 番目ユニットへのリンクの重み

$$f_j(x) = \frac{1}{1 + \exp\{- (x + \theta_j)\}} \quad (6)$$




図-2 階層的ネットワークの例




図-3 ロジスティック関数

θ_j : 当該階層の j 番目ユニットのバイアス

(6)式のような出力関数 f は、図-3 に示すように飽和特性を有しており、ロジスティック関数と呼ばれる。この飽和は実際のニューロンの不応期によるパルス密度の上限に対応するという意味をもつ。

このようなネットワークに入出力パターンのペアを学習させるわけである。この学習はネットワーク上ではリンクの重みを修正することに相当している。学習アルゴリズムとしてラメルハートらによって提案されたバックプロパゲーションアルゴリズムは、与えられた入力パターンに対応する出力パターンと目標出力パターンとの差である誤差が小さくなるように、リンクの重みを逐次修正してゆくものである。直感的には目標よりも実際が大きい出力ユニットに対してはそれへの入力リンクの重みを小さくし、逆に実際のほうが小さければ出力ユニットへの入力リンクの重みを大きくする。問題は出力層と直接つながっていないリンクの重みをどう修正するかである。出力層での誤差から順次逆算して隠れ層の各ユニットに誤差をどのように割り当てるかを与えるバックプロパゲーションアルゴリズムがこれに対する回答を与えている。

以上にコネクショニストモデルの典型的な二例についてその概要を示したが、以下これらの特徴を述べよう。第一の大きな特徴はその並列性である。単にネットワーク上の信号の伝達が並列であるにとどまらず、音声における調音結合のように本来逐次的な動作が実は大きな並列性を有しているといったことをネットワークを用いてごく自然に表現できる⁸⁾。

第二に、各ユニットが一つのことを表現するという局所表現ではなく、複数のユニットで一つのパターンを表現するという分散表現を多くの場合用いている。このため新しい入力パターンが与えられても新しいユニットやリンクを追加せずにリンクの重みを修正することで学習が行える。ただし、このことはネットワー

クがパターンを無制限に学習できることを意味するわけではない。

この分散表現を用いるメリットとして第三に、一般化が自然に実現できる。また第四に、ユニットが欠落したり過大な学習をさせようとした場合のパフォーマンスの低下がゆるやか (graceful degradation と呼ばれている) である。

第五に、外界とつながっていない隠れユニットのため、複雑な制約を表せたり、対象に内在する規則性・構造性が出現したりする。この重要性は 2. で指摘したとおりである。

第六に、コネクショニストネットワークは、複数の制約を満足する解が自然に浮かびあがってくる。制約が外乱のため多少ずれたり、制約が多少矛盾していても致命的な影響を与えない。しかもこの解がどの程度これらの制約を満足しているかが、エネルギー値あるいはユニット活性度の大きさで表される。

第七に、不完全なパターンが与えられると完全なパターンが想起できる。このようなパターンの連続性のため、たとえば情報検索などの場で正しいキーが分からなくてもそれなりの応答をしてくれるなど、不完全な情報の下でも柔軟な処理が期待できる。

4. 最近の研究動向

コネクショニズム研究の最近の動向を概観すると、大別して三つに分類できよう。第一は、ダイナミクスをネットワークでどう実現するか、あるいはサイクルやループのようなリカレントなネットワークの学習をどう実現するかといったネットワークモデルに関する理論的研究である。通常はネットワークの入出力パターンの提示順序は意味をもたない。ところがパターン時系列のようにパターンの出現順序そのものに意味がある場合をダイナミクスと呼んでいる。

ジョルダン⁹⁾ は出力ユニットの履歴を保持するために図-4 に示すような状態ユニットを導入した。ここでは時間的に近い状態ユニットは類似しているので、




図-4 ジョルダンのネットワーク

時間軸上での一般化が行われ、パターンの時間的変化を扱うことが可能となる。またプランユニットを用いて複数系列の学習も可能となる。同図の構造はダイナミクスを扱うコネクショニストモデルの典型例である。ジョルダンはこのネットワークを用いて、たとえば手足の運動・スピーチなど逐次の行動と見えるものも、良く見ると並列性を有しているという人間のふるまいのモデル化を行った。このような考えに基づく調音結合のモデルを作成し並列性を巧く説明している。伝統的モータプログラムアプローチで並列性や相互作用を説明するには特別のメカニズムを用意しなければならないのに対し、ここでのモデルでは状態という概念を導入することにより、内在する自由度が並列性を自然に作りだしている。ここでは逐次性は制約が多い場合の極限のケースに相当している。

宮田¹⁰⁾ は、ジョルダンのネットワークを二段に積み重ねることにより、実行が逐次的にしかできない初心者から並列的に行えるエキスパートへの遷移をうまく表現できるネットワークを作成した。またチャンキング、キーストローク間の時間が頻度の高い場合のほうが低い場合よりも所要時間が短いという頻度効果、人間の誤りでよく見られる獲得誤りをこのネットワーク上で実現している。

短期記憶の実現は活性度の時間的変化で表現するものとリンクの重みの短期的変化で表現するものがある¹⁰⁾。脳のなかで短時間形成される閉ループが短期記憶に対応する可能性が示唆されており、これによると短期記憶はループ状ユニットによる活性度の保持に対応する。この活性度は時間とともに減衰するので、同時に活性でありうるループ数には限界があるものと考えられる。

ジョルダンのネットワークの他にも、遅れ要素などを用いたリカレントなネットワークが提案されている。本来のバックプロパゲーション学習はフィードフォワード形のネットワークに対するものであるが、リカレントなネットワークの場合も学習の理論的研究¹⁹⁾ がなされ、さまざまな近似学習も行われている。

また神経科学の立場から、コネクショニズムは一種類のニューロンしか考えておらず、しかもこの機能が単純すぎるという批判がある¹¹⁾。クリックも現在のコネクショニズムは一元素からなる化学のようなものであるという指摘をしている。実際には入力との結合に関し、(5)式のような入力の加重だけでなく、入力の積和とかべき乗などの複雑なものも考えられてお

り、加重和よりも能力が大きい（同じ機能を果たすのに少ないユニット数ですむ）ことも示されている。ただ、複雑なユニットを考えると理論的解析がいつそう困難になろう。またバックプロパゲーションアルゴリズムを用いる限り自乗誤差評価の偏微分が加重和の場合のように単純にならず、直接つながっている結線情報だけで計算可能という生理的なもっもらしさがなくなってしまうという欠点がある。もっともこれは、現実のニューロンの機能が明確になった段階で学習アルゴリズムとの相性が良くなければ学習アルゴリズムのほうを変えるべきであろう。神経科学との関連についてセイノフスキは、モデル構成の結果次の新しい実験の方向が示唆され、逆に実験の結果次の世代のモデルの種ができるというような関係が望ましいと述べている²⁰⁾。

最近の動向の第二のものとして、視覚・音声などを始めとするさまざまな応用分野へのコネクショニストモデルの適用がある。たとえば音声への応用例としてNETtalk¹²⁾が有名である。これらについては本シリーズの4回目に述べられる予定であるのでここでは割愛したい。

第三は、視覚・音声などのいわゆる周辺機能ではなく、より抽象レベルの高い思考のモデル化であり、最も困難な領域である。コネクショニストモデルによる逐次的思考プロセスを実現するのに、ブロック内はコネクショニストモデルで、ブロック間が逐次的に推移するという考え方で三目並べのゲームのモデル化がなされている⁹⁾。ただブロック数が2の場合には問題が少ないが、一般にはブロック間の情報伝送、制御メカニズムをどうすればよいかなどさまざまな困難が予想される。

モーザ¹³⁾は人間の認知的行動の多くがパターン認識として捉えうるという考えから、「ロボット」という一人用ゲームの盤面の変化を訓練パターン系列としてネットワークに与えて学習させるという実験をやった。学習の結果、いろいろな局面で人間とほぼ同じ振舞いができるようになった。このようなコネクショニストネットワークの一つの欠点は説明の能力がほとんどないことである。これに対しては、プロセスを細分化することが有効であると述べているが、やはり限界がある。

5. おわりに

コネクショニズムの限界・批判に関しては本シリー

ズの5回目に詳述される予定であるので、ここでは代表的な二つの批判に対する私見を若干述べるにとどめたい。

ミンスキーとパパートは、1988年版「パーセプトロン」⁹⁾の中で、コネクショニストモデルはそのまま規模が増大すると、学習時間の増大、リンクの重みの指数的増大という困難が予想されると指摘している。このような困難の可能性は否定できないが、大規模で均質なネットワークを学習させることがそもそも適切ではないと考えられる。ミンスキーらはモデルを大きくする方法として、心が小規模の多数のエージェントから構成されているという考えを提唱しており¹⁴⁾、コネクショニズムでもそう考えるのが妥当であろう。ただパーセプトロンには前述の問題点が存在しないから優れているというのほうなげけない。パーセプトロンでは第一層の結線をアプリアリに決めているのでこのような問題が存在しないのであるが、第一層の結線をどう与えるかが問題である。PDPでは初段を学習するので隠れユニットに構造・規則性が抽出されるという期待がある。パーセプトロンと比較して学習のパワーが大きくなったことと構造が抽出されることはともにPDPの大きな長所である。ただこの二つを実現するために計算量の増大およびローカルミニマムの可能性という犠牲を払う必要が出てきたといえよう。

フォーダーとピリシン¹⁵⁾は、記号操作に基づく古典的アーキテクチャとコネクショニズムとの本質的差異は、後者が組合せの構文的意味的構造を表現できないことにあり、これからコネクショニズムにおけるプロダクティビティ、システムティシティの欠如などさまざまな問題が発生していると主張している。しかし部分全体関係・含意関係をはじめとするさまざまな関係を表現するユニットを用いることにより、これらをネットワークで表現することは可能であると考えられる。ただ指摘されている問題点のすべてが解決済みではなく、今後の詳細な検討が必要である。さらにコネクショニズムの利点とされている点を列挙し、これらの利点がコネクショニズムに固有のものではなく（ルール適用の連続性など）、また認知レベルではなくインプリメンテーションレベルの議論である（スピードの問題、ダメージやノイズに強いなど）と主張している。しかし、コネクショニストモデルはインプリメンテーションレベルではなく、マーのいう表現およびアルゴリズムレベル²¹⁾に相当すると考えるべきであろう。その際、活性度の伝播・リンクの重み調整という

計算・学習のアルゴリズムを採用することから、インプリメンテーションレベルの利点、あるいはルール適用の連続的性質などがごく自然に実現されると考えたい。

今後の展望として、4. に示したネットワークモデルの理論的研究では、上で述べた以外にも、隠れ層の解釈手法²²⁾、ネットワークの構造指針、学習能力の解明など探求すべき点が多く残されている。とりわけ、ネットワークである機能が実現できるというだけでなく、なぜできるのか、あるいはその限界がどこにあるのかといったことを明確にしておくことが今後の発展のためにも必要であろう。

応用分野へのコネクショニストモデルの適用に関しても、パターン認識およびモータコントロールの分野を中心に、さまざまな分野でのいっそうの試みがなされよう。パターン認識に関しては、実用レベルで従来の方法との対比が迫られようがそれなりに進展するものと考えられる。後者のモータコントロールに関しては、運動を制御する小脳の構造およびその学習メカニズムがかなり分かかってきていることから²³⁾、ネットワーク学習にその知見を反映させることにより²⁴⁾、ロボットなどへの応用の可能性をも含めて今後の進展が期待される分野である。

思考レベルに対してどのような取組みが可能かも大きな問題である。フォーダーとピリシンの批判に対抗できるモデル化を期待したい。ミンスキーらによる心が小規模の多数のエージェントから構成されているという考えが一つのヒントを与えていよう。その際、各エージェントでの情報の表現、エージェント間の情報の伝送および制御メカニズムが重要な課題になると考えられる。

コネクショニストモデルと神経科学・認知心理学などの関係についてもいろいろな話題がある。長期増強現象をはじめとする記憶メカニズムの解明が、ネットワークモデルによる記憶・学習と結びつく可能性を有している。また視覚（特に立体視）およびモータコントロールに関しては、ニューロンレベルのモデルと実際との対応がつく可能性がある。記憶についても大脳皮質の神経科学的知見を反映させたモデル化の試みがある²⁵⁾。これらはコネクショニストモデルと神経科学との接点として興味深い分野である。さらに認知心理学との接点として、モデルの特性を認知心理実験で検証することがぜひ必要であり、今後追求すべき重要な課題である²⁶⁾。このように神経科学で得られた知見に

基づいてモデルを構成し、その振舞いを認知心理実験で検証するという枠組みを考えると、コネクショニストモデルが両者を結びつける役割を果たしうることが期待できる。

なおここでは触れなかったが、コネクショニストモデルのシミュレーションプログラムとしてさまざまなものが開発されており¹⁶⁾、また種々の並列計算機上でのシミュレーションも増えてこよう¹⁷⁾。さらにコネクショニストモデルのチップ化についても今後急速に進展するものと思われる¹⁸⁾。

本稿の草稿に対して有益なコメントをいただいた電総研敏訪基、仁木和久、麻生英樹各氏に感謝したい。

参考文献

- 1) Newell, A. and Simon, H. A.: Human Problem Solving, Prentice-Hall (1972).
- 2) Minsky, M. and Papert, S.: Perceptrons, MIT Press (1988).
- 3) Amari, S.: A theory of adaptive pattern classifiers, IEEE Trans. of Electronic computers, Vol. EC-16, No. 3, pp. 299-307 (1967).
- 4) Hopfield, J. J.: Neural networks and physical systems with emergent collective computational abilities, Proceedings of the National Academy of Sciences USA, Vol. 79, 2554-2558 (1982).
- 5) Hinton, G. F., Sejnowski, T. J. and Ackley, D. H.: Boltzmann machines: Constraint satisfaction networks that learn, CMU-CS-84-119, Carnegie-Mellon University (1984).
- 6) Rumelhart, D. E. and McClelland, J. L.: Parallel Distributed Processing, Vol. 1 and Vol. 2, The MIT Press (1986).
- 7) Winograd, T. and Flores, F.: Understanding Computers and Cognition, Ablex Publishing (1986).
- 8) Jordan, M. I.: Serial order: a parallel distributed processing approach, ICS Report 8604, UC San Diego (1986).
- 9) Miyata, Y.: Organization of action sequences in motor learning: a connectionist approach, The Cognitive Science Society (1987).
- 10) Hinton, G. E. and Plaut, D. C.: Using fast weights to deblur old memories, The Cognitive Science Society (1987).
- 11) Matsumoto, G.: Neurocomputing—Neurons as microcomputers, European Seminar on Neural Computing, London (1988).
- 12) Rosenberg, C. R.: Revealing the structure of NETalk's internal representations, The Cognitive Science Society (1987).
- 13) Mozer, M. C.: RAMBOT: A connectionist expert system that learns by example, ICS

- Report 8610, UC San Diego (1986).
- 14) Minsky, M.: *The Society of Mind*, Simon & Schuster (1985).
 - 15) Fodor, J. A. and Pylyshyn, Z. W.: *Connectionism and cognitive architecture: A critical analysis*, *Cognition*, Vol. 28, No. 1-2, pp. 3-71 (1988).
 - 16) 石川真澄: コネクショニズムとシミュレーション, シミュレーション, Vol. 7, No. 2 (1988) 予定.
 - 17) Blelloch, G. and Rosenberg, C. R.: *Network learning on the connection machine*, *IJCAI-87* (1987).
 - 18) Treleaven, P. C.: *Parallel architectures for neurocomputers*, *European Seminar on Neural Computing*, London (1988).
 - 19) Pineda, F. J.: *Generalization of backpropagation to recurrent and higher order neural networks*, to appear in the *Proceedings of IEEE Conference on Neural Information Processing Systems*, Colorado (1987).
 - 20) Sejnowski, T. J. and Lenky, S. R.: *Neural network models of visual processing*, 1987 *Short Course on Computational Neuroscience*, *Society for Neuroscience* (1987).
 - 21) Marr, D.: *Vision*, W. H. Freeman & Co. (1982).
 - 22) 石川真澄他: 構造的コネクショニストモデルの試み, 日本認知科学会第5回大会 (1988).
 - 23) 伊藤正男: 小脳の情報処理機構—シナプス可塑性と運動学習—, 脳と情報, 第23回東京工業大学総合研究館講演会 (1987).
 - 24) 前田芳晴, 川人光男他: ヒト上肢多関節運動軌道を学習・生成する多層神経回路モデル, 電子情報通信学会技術研究報告, MBE 87-133 (1988).
 - 25) Tsuda, I., Koerner, E. and Shimizu, H.: *Memory dynamics in asynchronous neural networks*, *Progress of Theoretical Physics*, Vol. 78, No. 1, pp. 51-71 (1987).
 - 26) Mozer, M. C.: *The perception of multiple objects: A parallel distributed processing approach*, PhD thesis of UC San Diego (1987).
(昭和63年5月6日受付)
-