

01三R-011

新情報処理技術に関する総合的調査研究

— 学習 W・G 報告書 —


平成 2 年 3 月

JIPOEC

財団法人 日本情報処理開発協会



この報告書は、日本自転車振興会から競輪収益の一部である機械工業振興資金の補助を受けて平成元年度に実施した「新情報処理技術に関する総合的調査研究」の成果をとりまとめたものであります。



序

過去30余年にわたる情報処理技術の進歩は著しく、その成果を支えに社会の情報化も急速に進展し、コンピュータは今やわれわれの社会活動にとって不可欠のものとなった。しかしながら、その利用範囲の拡大や多様化にともてい、情報処理機能の一層の高度化が求められ、特に最近では、固定化した逐次処理型の情報処理機能から、人間にとって親和性に富む、より柔軟性の高い知的情報処理機能への変革が、強く期待れるようになった。

このため、従来のコンピュータが不得手とする、人間の脳が行っているような、高度かつ多彩な情報処理の実現に向けて、必要とされる機能、計算原理および実装技術、さらには、革新的な情報処理技術と社会の係わり等を含めた総合的な調査研究を、平成元年度から開始した。

本年度は、通商産業省における新情報処理技術調査研究委員会の下部機構として、当協会に基礎技術、新機能、社会応用の3分科会および超並列・超分散処理、学習、光技術・新デバイス、3次元情報処理、認識・理解、自律・協調の6ワーキンググループを設置して調査研究を実施するとともに、大学・研究所への研究委託、海外調査等により、21世紀を目指す革新的な情報処理技術がいかにあるべきかを、ニーズ、シーズの両面から追求し新しいナショナルプロジェクトとしての可能性を検討した。

最後に、本調査研究に多大のご協力を頂いた各分科会およびワーキンググループ委員各位に厚く御礼申し上げる次第である。

平成2年3月

the first of these is the fact that the
the second is the fact that the
the third is the fact that the
the fourth is the fact that the
the fifth is the fact that the
the sixth is the fact that the
the seventh is the fact that the
the eighth is the fact that the
the ninth is the fact that the
the tenth is the fact that the

the first of these is the fact that the
the second is the fact that the
the third is the fact that the
the fourth is the fact that the
the fifth is the fact that the
the sixth is the fact that the
the seventh is the fact that the
the eighth is the fact that the
the ninth is the fact that the
the tenth is the fact that the

the first of these is the fact that the
the second is the fact that the
the third is the fact that the
the fourth is the fact that the
the fifth is the fact that the
the sixth is the fact that the
the seventh is the fact that the
the eighth is the fact that the
the ninth is the fact that the
the tenth is the fact that the

「学習WG」委員名簿

(順不同)

	氏 名	役 職
主査	鈴木 良次	東京大学工学部計数工学科教授
幹事	仁木 和久	工業技術院電子技術総合研究所 情報科学部認知科学研究室主任研究官
幹事	西村 和夫	(株)東芝 システム・ソフトウェア技術研究所 研究第二部システム第二担当主任研究員
委員	合原 一幸	東京電機大学工学部 電子工学科助教授
	安西祐一郎	慶応義塾大学理工学部 電気工学科教授
	市川 伸一	東京工業大学工学部 教育心理学研究室助教授
	小田 洋一	大阪大学基礎工学部 生物工学科講師
	川村 貞夫	立命館大学理工学部 機械工学科助教授
	米谷 忠篤	三洋電機(株)研究開発本部筑波研究所 知能システム研究室主任研究員
	下原 勝憲	日本電信電話(株) NTTヒューマンインタフェース研究所 ヒューマンインタフェース方式研究部主幹研究員
	田中 繁	日本電気(株) 基礎研究所 探索研究部主任
	永野 俊	法政大学工学部経営工学科教授
	福田 尚行	シャープ(株) 技術本部中央研究所 第四研究部研究員
	松本 元	工業技術院電子技術総合研究所 超分子部長
	宮下 保司	東京大学医学部 生理学第一講座教授

目 次

1. 序文	1
1.1 新情報処理において実現したい機能	1
1.2 新情報処理における学習の位置づけ	1
1.3 調査検討項目	2
2. 調査検討経過	3
3. 調査検討結果	5
3.1 学習の体系	5
3.1.1 工学における学習の定義	5
3.1.2 その他の学習の定義	13
3.2 学習の数理モデルと応用	13
3.2.1 学習理論	13
3.2.2 認識処理における学習の利用	20
3.2.3 知識処理における学習の利用	26
3.2.4 運動制御における学習の役割	37
3.2.5 ロボットの運動学習	43
3.2.6 大脳皮質におけるコラム形成の理論	54
3.3 心理学・認知科学における学習・記憶	61
3.3.1 心理学における学習・記憶研究	61
3.3.2 学習の認知科学的研究 —PDPモデル—	65
3.4 神経科学・遺伝における学習・記憶	69
3.4.1 神経生理学における学習・記憶の研究	69
3.4.2 大脳側頭葉における認知記憶・学習	79
3.4.3 海馬神経回路網と学習の基礎過程	85
3.4.4 計算論的神経科学	104
3.4.5 遺伝と学習	108
3.5 まとめ	112

3.5.1 現状技術の限界	112
3.5.2 研究課題	117
4. 新情報処理技術としてとりあげるべき研究課題	119
4.1 学習課題の展望	119
4.2 超並列・超分散システムの学習機構の開発	120
4.2.1 新学習アルゴリズムの開発	120
4.2.2 学習チップ／プロセッサ	122
4.2.3 学習用新計算機構の開発	126
4.3 超並列・超分散システムの構成技術	130
4.3.1 構造化手法の開発	130
4.3.2 自律分散形階層制御システム	133
4.4 シンボル処理との融合システム技術	136
4.4.1 分散形シンボル処理システムの開発	136
4.4.2 シンボル処理とパターン処理との融合システムの開発	137
4.5 発達・分化の工学的実現に向けて	139
4.5.1 生物における発達・分化	139
4.5.2 発達・分化システムの設計について	142
4.6 学習の認知科学的及び心理学的解明	150
4.7 学習の生理学的解明	152
4.8 新情報処理プロジェクトのあり方	154
5. むすび	157

1. 序 文

1. 序 文

新情報処理の実現に不可欠な学習機能の工学的実現技術の開発を目的として、学習機能の工学的利用の現状と将来の研究課題について調査・検討を行った。学習機能は従来のコンピュータでは不得意な、人間の脳が行う高度な処理に属し、その解明と工学的利用のために新しい計算アーキテクチャとりわけ超並列・超分散計算アーキテクチャに注目した。そして、このアーキテクチャにおける学習の基礎技術について調査するとともに、学習や記憶の生理学的解析やそれらの心理学的観察や認知科学的な分析についても総合的な調査を行った。

1. 1 新情報処理において実現したい機能

新情報処理において実現したい機能は、人間の行うような柔軟な情報処理機能であり、その目的は、従来のフォン・ノイマン型コンピュータにおける次のような問題を解消することにある。

- (1) 高速計算及び実時間処理
- (2) 計算量の爆発の解消
- (3) 複雑な実世界の認識機能
- (4) 不良設定問題解決
- (5) 多数制約の解決
- (6) 環境への適応機能
- (7) 知識獲得機能（学習）

これらの問題を解決するための一つの方法として、超並列・超分散計算アーキテクチャおよび、学習機能の導入が現在注目されている。これらは、従来の逐次型の計算アーキテクチャと全く異なり、人間の脳構造の超並列・超分散性を参考にし、従来のコンピュータにない情報処理を実現することを目指している。

1. 2 新情報処理における学習の位置づけ

新情報処理は人間の脳構造を参考にした超並列・超分散計算アーキテクチャに注目する

ものであるが、多彩な入力情報を総合的に処理するものであり、群情報処理システムとも呼べる情報処理を目指すものである。

新情報処理システムの構築では、一般にシステム規模が巨大となることが予想されるため、始めからすべての情報処理（あるいは制御）の構造を詳細に与えることは不可能である。初期設計では構造の概略を規定し、その後の状況に合わせて適応的に機能を変更する「学習システム」として新情報処理システムを設計しておく必要がある。このようなシステムの構成法は、例えば個人の癖に適応する柔軟なインタフェースの設計や、あらかじめ十分に性質の分かっていない対象の認識システムを含む新情報システムの構成等に不可欠である。このための基盤技術として学習機能が必要となる。

上述の学習機能実現のための理論的な基礎は確立されているとはいえず、その確立が急務である。このため超並列・超分散システムにおける学習の数理工学的立場からの解明を、新情報における重要な研究テーマ（キーコンセプト）にすえる。そのために、新学習アルゴリズムの開発、大規模な超並列・超分散システムの構成法、発達理論を含めた学習アルゴリズムの開発、学習の統一理論化と学習能力の評価などを行う必要がある。

学習システムを工学的アイデアだけで、ある程度構成することは可能である。しかし、このテーマに関しては学際的に神経生理学や心理学、認知科学の成果を取り入れたほうが結局は早道であるといわれている。しかも、この分野では新情報で開発する情報処理技術の成果を計算モデル的アプローチに活かし、生理・心理の分野に積極的にフィードバックすることが期待できる。新情報の研究では、この研究の相互作用により、学習システムの新しい工学的実現が達成できる研究体制を取るべきである。

1.3 調査検討項目

新情報処理技術の中での学習WGの位置づけの議論を経て、次の項目の調査検討を進めた。

- 1) 現状技術の限界と新情報処理技術で実現したい機能
- 2) 新情報処理技術実現の上での学習の役割
- 3) 新情報処理技術の開発のあり方
- 4) 新情報処理技術実現のための検討課題の明確化

2. 調査検討経過

2. 調査検討経過

第1回学習WG (1989. 9. 14)

新情報処理技術に関する調査の趣旨説明、学習WGの趣旨説明、委員紹介、基本方針の説明。

第2回学習WG (1989. 10. 9)

WGの進め方についての説明・検討

- (1) 確認事項： 新情報処理技術には、工学以外の多くの知見の活用が必要であるが、学習に関する研究の目標は新情報処理に必要な学習機能の工学的実現技術の開発である。
- (2) 学習WG進め方の具体的方法： 現在、学習機能が期待されているコネクショニズム関係の調査を足掛かりにして、認知・心理学、神経科学、数理科学、人工知能等の学問分野への問題提起をする。そのために、超並列・超分散アーキテクチャに関する最新の研究事例を専門の委員が幾つか紹介し、現状技術の限界と新情報処理技術で検討すべき項目、及び上記の学問分野への期待項目を明らかにする。上記の学問分野の専門委員はこれらの問題提起に対応する研究の現状を紹介するとともに、逆にこれらの分野から新情報処理への問題提起をする。

第3回学習WG (1989. 10. 20)

学習WGの進め方に関する補足と超並列・超分散アーキテクチャ研究に関する事例紹介

- (1) 学習WGの進め方について： 研究事例紹介と並行して、各委員に対して新情報処理技術開発のための検討課題等についてアンケート調査をする。
- (2) 研究紹介： 電力系統状態評価への超並列・超分散アーキテクチャの適用（西村幹事）
- (3) 研究紹介： 超並列・超分散アーキテクチャの認識処理への応用（下原委員）

第4回学習WG (1989. 11. 1)

アンケート中間報告と事例紹介続き

- (1) アンケート中間報告： 結果紹介と議論
- (2) 研究紹介： 運動制御への超並列・超分散アーキテクチャの応用（鈴木主査）

第5、6、7回学習WG(合宿 1989.11.19～20)

アンケートまとめ、事例紹介のまとめ、研究紹介

- (1) アンケートまとめ： 意見調査最終報告およびまとめ
- (2) 超並列・超分散アーキテクチャ研究事例紹介のまとめ
- (3) 研究紹介： 認知科学における学習（安西委員）
- (4) 研究紹介： ロボットの学習制御と生体への応用（川村委員）
- (5) 研究紹介： シナプスからニューロコンピュータへ（松本委員）
- (6) 研究紹介： 脳における記憶現象（宮下委員）

第8回学習WG(1990.1.16)

- (1) 学習WG第1回中間報告について
- (2) NIPS'89報告（仁木幹事）
- (3) 研究紹介： 神経回路の発達・自己組織化（田中委員）
- (4) 情報ネットワーク社会の発展について

第9回学習WG(1990.1.30)

- (1) 学習WG報告書目次案の説明と役割分担

第10回学習WG(1990.2.23)

- (1) 学習WG報告書案の検討

3. 調査検討結果

3. 調査検討結果

学習WGでは、人間の脳が行っているような高度な情報処理技術の実現を目指して、ここでの学習機能について調査した。WGの検討では、新しい情報処理パラダイムに挑戦するために超並列・超分散計算アーキテクチャに注目すること、特にその学習機能や学習原理の多元的な解明とその工学的実現手法の確立が、新情報処理において必要な研究課題であることを確認した。

学習機能の解明にあたっては、現在注目されている超並列・超分散アーキテクチャで行われているシナプス結合強度の調整としての学習だけでなく、演算システム構造の外界への適応的变化を伴う自己組織化の側面から統一的にとらえ、数理工学的原理を明らかにすること、また、大規模な問題をモジュール的に扱えるように、「発達概念」をモジュール間の構造決定や調整の為に取り入れた新しい自己組織化原理の究明の必要性を議論した。

また、学習の基本原則を明らかにするためには、学習機能のソフト面の探求のために認知科学や心理学の研究が、学習機能を実現する自己組織化のハード（ウェットウェア）面の探求のために生理学的研究が不可欠であるため、新情報処理の工学的技術開発の立場からも基礎科学の側への積極的な問題提起を行える研究体制の重要性が指摘された。

以下、調査検討結果の詳細について述べる。

3.1 学習の体系

環境への適応機能や自律的な知識獲得機能を実現する上で学習機能の研究は不可欠であるが、学習という言葉は極めて広く用いられており、その定義は心理学、認知科学、神経生理学など、各学問領域によって異なるだけでなく、一つの分野でも種々の意味に用いられている。そこで、ここでは新情報処理との関係という観点から、主に工学において学習と呼ばれる機能の調査をした。

3.1.1 工学における学習の定義

工学的な意味での学習を極めて一般的に定義をすれば「機能の獲得」と考えられるが、機能の種類によって、あるいは機能獲得の仕方によって学習に多くのバリエーションが発生する。例えば運動制御機能の獲得や認識機能の獲得、更には、より高次の論理的機能の

獲得などによって学習が色分けされる。また、脳のモジュール構造を獲得する自己組織化の仕組みも学習の形態に関係する。


工学では、外界への適応や外界からの知識獲得のための次のような機能の形態が学習と呼ばれる。

- a. 制御パラメータの適応的調整
- b. 構造パラメータの適応的調整
- c. 構造の適応的調整
- d. Machine Learning (論理的知識獲得)

(1) 制御パラメータの適応的調整

これらは、適応制御システムなど、変化を続ける外界の状態を常時観測し、その時点での環境に最も適した制御が可能になるように制御系のパラメータを更新し続けるものである。

この例として、電圧の分散制御システムを図表3.1-1に示す。これは、従来の電圧制御システムと異なり、電力系統内に分散配置された各無効電力補償装置がエキスパートシ



図表3.1-1 分散電圧制御システム (工学的な学習の一例)

テムを用いた強力な推論機能を持ち、さらに装置群は自律分散協調制御系を構成している。これらは通常は自己の接続点の電圧のみを観測して独立に電圧制御を行っているが（無効電力注入量を変えることによって電圧調整をすることができる）、予想を越える重負荷などで個別の装置が単独で電圧回復が不可能な場合など、緊急時には、エキスパートシステム群が交信し、連係動作によって電圧安定性を保つ。このシステムでは、ある装置が無効電力を注入したときに他の装置の端子電圧にどの程度の支援効果を与えることができるかは、装置群から見て外部環境である電力系統内の変化などで時々刻々変化するため、ある装置が無効電力注入を行うごとに他の装置と実際に発生した効果を教え合うことによって常時自分の影響力を更新し（これを学習と呼んでいる）、それによって電圧制御のためのパラメータを変化させるものである。


このような学習は、生物での学習とは全く意味が違うが、固定的な制御装置や、人間が判断してパラメータを更新する装置と異なり、次のような特徴により学習という言葉が用いられていることが分かる。

- a. 外界の変化にダイナミックに追随する
- b. 追随のため手続きを内部に持ち、自律的にパラメータが変化する

(2) 構造パラメータの適応的調整

これは、現在超並列・超分散アーキテクチャとして注目されているニューラルネットにおけるシナプス変化を意味している。このシナプス結合変化のための学習アルゴリズムとして現在最も有名なのがバックプロパゲーション法と呼ばれる手法であるが、この手法は3層のニューラルネットに適用されている例が多い。図表3.1-2に3層のニューラルネットを示すが、これはユニットが入力層、中間層、出力層と呼ばれる3つの層をなすように並んだものであり、図ではそれぞれ l , k , j のインデックスで区別されている。信号は入力層から中間層を通して出力層へと一方向に伝えられる。入力層から中間層への結合には重み w_{kl} が、中間層から出力層への結合には w_{jk} が定義される。バックプロパゲーション法では、この3層ニューラルネットの出力層において、誤差関数を次のように定義する。

$$E = \frac{1}{2} \sum_j (t_j - v_j)^2 \cdots \cdots (3.1.1)$$



図表3.1-2 3層ニューラルネット

ここで、 t_j と v_j はそれぞれ出力層のユニット j の教示データ（望ましい出力）と実際の出力である。 v_j は次式によって記述される。

$$v_j = f_j \left(\sum_{i \neq j} w_{ji} v_i - \theta_j + I_j \right) \quad \dots (3.1.2)$$

ここで、 v_i は他のユニット i の出力、 w_{ji} はユニット i の出力がユニット j に及ぼす影響の度合いを示す重み係数、 θ_j はしきい値、 I_j は外部からの刺激である。 f_j はユニット j の入出力特性を示す。これは生体において、あるニューロンが他のニューロンから刺激を受け、その総和があるしきい値を超えたときに活性化されるというプロセスに対応している。

バックプロパゲーション法は、 E を小さくするように出力層と中間層との結合の重み係数 w_{jk} 、中間層と入力層との結合の重み係数 w_{kl} を変えてゆくものであり、次式に従って重み係数の修正量 Δw_{jk} 、 Δw_{kl} を求め、これがある値以下になるまで修正を繰り返す。

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} \quad \dots (3.1.3)$$

$$\Delta w_{kl} = -\eta \frac{\partial E}{\partial w_{kl}} \quad \dots (3.1.4)$$

ここで係数 η は、重み係数の修正速度と計算の安定性との兼ね合いから決められる定数

である。この手法の著しい特徴は、複数の入力パターンと出力パターンとを関連づけることができることである。学習では、ある入出力パターン対について重み係数を若干修正し、次に別の入出力パターンについて重み係数をさらに若干修正するというように、入出力パターン対を変えながら重み係数を修正して行くと、最終的には与えられた複数のパターン対が関連づけられる。すなわち、学習済みのニューラルネットに、学習させた入力パターンの1つを入力すると、それと対にして教示したパターンに非常に近いパターンが出力される。以上の学習によって入出力事例として与えられた知識（多くは専門家などの経験的かつ非言語知識）がニューラルネットに移入されたことになる。

層状のニューラルネットは入出力パターンを関係づけるという点では伝達関数モデルの拡張と見ることもできる。すなわち、伝達関数モデルにおいて、与えられた入出力特性に近くなるようにゲインや時定数などのパラメータを決めるのと同様に、ニューラルネットでは与えられた入出力特性を実現するためにパラメータとしての重み係数を調整する。但し、ニューラルネットのモデルの方がパラメータ数が多いため自由度が高く、通常の伝達関数モデルに比べて遥かに複雑な入出力特性を実現することができる。又、伝達関数モデルではパラメータの決定方法もその関数形に依存するのに対してニューラルネットでは上述のように学習と呼びうる統一的なパラメータ決定方法が得られる。これらの比較を図表3.1-3に示す。このような見方をすれば、現在のニューラルネットの学習は(1)に述べた制御パラメータの適応的調整の考え方が、超並列・超分散システムの外部適応として一般化されたものと見ることもできる。

図表3.1-3 ニューラルネットと伝達関数モデルの比較

	ニューラルネット	伝達関数モデル
構造	単純、一様	特徴的
パラメータ数	大	小
パラメータ決定法	統一的（学習）	個別
入出力関係	複雑	単純
パラメータ計算時間	大	小

(3) 構造の適応的調整

上述の学習ではニューラルネットの構造は不変であるが、多数のシナプス結合強度（重み係数）が変化することによって外界や外部要求に適応する。しかしながら、脳に限らず多くの生体の機能は、単なる既存構造の適応だけでなく、何等かの規則に従い、新しい構造を発達させる能力があるように思われる。

構造が不変の場合にはおのずとその適応能力に限界があると考えられるため、新情報処理技術の実現のためには、従来コネクショニズムで扱ってきたシナプス結合強度の調整としての学習の他、発達や記憶のメカニズムの知見をもとにコンピュータ上でのニューラルネットモジュール群の自己組織化なども取り込んで行く必要がある。工学的には自己組織化という言葉は、学習とほとんど同義に構造パラメータ群の適応（シナプス変化）を指す場合もあるが、構造そのものを変える適応や発達のみを意味する場合が多いと考えられる。すなわち、工学的には超並列・超分散アーキテクチャ上での学習は、ユニット結合強度の調整と自己組織化とからなると考えられる。

(4) Machine Learning –主に論理的知識獲得について–

ここでは、計算機科学や人工知能(AI)の分野で今までに取り扱われてきた学習研究(Machine Learning ; MLと略す)に焦点を当てる。

ML学習は、計算機上に「学習機能」をいかに実現するかといった観点で開発が進められてきたので、数学や論理学の範囲で学習の機能の実現を計ろうという傾向がある。しかし、一方では、最近のニューロコンピュータの研究もこの分野で盛んに研究されているので、それらも含めて列挙し、どのような種類の学習が、どのようなMLパラダイムとして実現されてきているかを概観する。

現在のML学習は、次のような4つの主要なパラダイムに分類することが出来る[1]。

1) 帰納学習 (inductive-learning)

: 正と負の例の集合からの概念の獲得。

2) 解析的学習 (analytative-learning)

: 説明に基づく学習、類推学習、事例に基づく学習

3) 遺伝アルゴリズム (genetic-algorithms)

: 遺伝アルゴリズムに基づく分類システム

4) コネクショニスト学習法

- : 中間層を含む非線形関数の写像も形成できる学習
- : PDP

1)、2)の伝統的なAIアプローチに対し、3)、4)では、シンボル操作でないメカニズムの導入により、学習問題を取り扱っている。

3)の遺伝パラダイム(分類システム)は、Holland等により推進されており、遺伝メカニズムの導入による発達機構を学習原理に導く研究であると位置づけられる。生物的遺伝機構であるクロスオーバー、ポイントミューテーションとダーウィンの自然選択との類推から着想されている。概念記述の沢山の變形がプールされており、遺伝アルゴリズムによって生成されたそれらの概念の變形と組合せが、自然淘汰の客観的選択機構によってテストされる。原理的に、遺伝概念空間内の並列探索を、粗い粒度の山登り法で試みていると解釈できる。

4)のコネクショニストパラダイムは、ニューラルネットの学習パラダイムと同じであり、また本章の分類では「構造パラメータの適応的調整」に分類されている。超並列・超分散アーキテクチャ上での学習に伴う信用供与問題(credit assignment)が一応解決されていること、制約充足計算や分散表現、連想性の実現など従来のAI技術を補完する優れた性質を備えている。

3)と4)の最近の研究パラダイムに対し、1)2)は、伝統的にAIが研究対象としてきたシンボルレベルでのパラダイムである。1)の帰納学習では、概念の正と負の(記述)例から一般的な概念記述を帰納する。多くの例が、学習のために必要で、また一般的に誤った例の提示等に脆い性質がある。一方、2)の解析パラダイムの学習では、数個の例と豊富な領域知識(理論)とに基づく解析学習を行う。解析パラダイムの学習研究の焦点としては、説明に基づく学習、多レベルのチャンキング、反復マクロオペレータ、誘導的類推等がある。

シンボル記述の操作による学習は、学習環境によって提供される情報の水準によって分類することもできる。学習で使われる情報のレベルによって、学習の内容が、具体的にはシステムが生成しなければならない仮説の種類が決定する。次の4つの基本となる学習状況が存在する。

1) 暗記学習 (Rote learning)

環境は実行タスクの水準で情報を正確に提供する。従い、どんな仮説も必要でない。

2) 言われるがままの学習 (Learning by being Told)

環境によって提供された情報は、余りに抽象的あるいは一般的なので、学習は失われた詳細情報を仮説化しなければならない。

3) 例題からの学習 (Learning by examples)

環境から与えられる情報が余りに固有かつ詳細なので、学習部はより一般的な規則を仮説形成化しなければならない。

4) 類推による学習 (Learning by analogy)

環境により提供される情報は類似の実行タスクに対しても適切である。

学習システムは、現在の実行タスクに対し、ある類推を発見し、かつ類似の規則を仮説形成しなくてはならない。

このように学習のタイプにより、最適の学習パラダイムが異なることが分かる。

たとえば、「信号—シンボル写像」や「連続パターンの認識」には、コネクショニズム学習が優れており、「離散パターンの認識」に対しては様々な学習が可能であるが、決定木の帰納学習がよい。「新しい概念記述の獲得」つまり例からの一般記述の獲得には、記述的概念記述の帰納学習がよい。「エキスパートシステムのためのルールの獲得」には、もし領域理論があるなら類推学習や説明に基づく学習(EBL)が、もし領域理論がなければ遺伝アルゴリズムや帰納学習が適している。「ルールベースシステムの効率の向上」の手法としては、マクロオペレータ、チャンキングから EBL、類推までの解析的アプローチが適している。しかし、解決手法手順を記憶する表現としてコネクショニズム学習が有効に使える可能性もある。「教示と共生的推論」で、単独システムというよりは協調問題解決システムを考えたとき、帰納システム(文字による概念記述を持った)や解析的システムのレベルを考える必要がでる。

このような考察からの結論は、学習の多様さを反映して、学習パラダイムも多用なもの

が必要になるという事である。従って、多様な学習パラダイムを反映した多様な学習システムは、統合された「統合的推論アーキテクチャ」を形成しているであろうということである。

3.1.2 その他の学習の定義

心理学においても学習の定義は研究者間で必ずしも一致しているわけではないが、「経験による比較的永続的な行動の変容」という定義が一般的と考えられる。歴史的には、20世紀前半の行動主義の盛んな時代には「記憶」という言葉の代わりに「学習」という言葉が用いられたことがあるため、1970年代の認知心理学では学習を「知識獲得」と言い替え、「学習」という言葉は技能習得という要素の強い学習にかなり限定して用いている。最近では、認知心理学ではごく日常的な意味で「学習」という用語を使うようになっている。このように「学習」という言葉の定義は時代によっても変わってきているが、近年の認知心理学は人工知能など、コンピュータによる学習の研究と密接に関連し合っている。1950年代からは神経回路をモデルとした並列処理の工学的研究が始まるが、1980年代では心理学者もこのようなモデルを大きくとりあげるようになり、現在のコネクショニズムやニューラルネットの学際的研究の流れに合流している。このように3.1.1項で述べた工学における学習の定義と心理学や認知科学における定義との差は減少しつつある。

〔参考文献〕

- [1] Carbonell, J. G. ;Introduction: Paradigms for Machine learning, Artificial Intelligence 40, p.1-9, (1989).

3.2 学習の数理モデルと応用

3.2.1 学習理論

(1) 学習理論

学習の数理的な理論は古くから心理学の分野で幾つかのものが提唱されている。これらを含めた心理学における学習理論は「3.3 心理学・認知科学における学習・記憶」で詳述されるので、ここでは1950年代後半以降、工学の分野で研究されているいわゆるニューラルネットにおける学習の理論に限定して話を進める。

ニューラルネットにおける学習は教師付学習と教師無学習（自己学習ともいう）に大別される。教師付学習とは、ニューラルネットの入出力関係を逐一外部から指定することにより望ましい機能の形成を行うものである。これに対し、教師無学習とはニューラルネットに入力データを供給するだけで、ネットワーク自体がもつ学習規則に従って組織化が進行し、機能の形成が行われるものである。

① 古典的教師付学習

ニューラルネット研究は1950年代の終りからの約10年間の第1期と1980年代前半から今日までの第2期とに大別して考えることができる。第1期に提案された教師付学習方法はすべてニューロン毎に直接教師情報が与えられるものである。これらのなかに代表的なものとしてパーセプトロンの誤り訂正法[1]とアダラインの δ ルール[2]を紹介する。

単一ニューロンの入力パターンとその重みを列ベクトル X と W で表し、そのポテンシャルを $u (=W \cdot X)$ 、出力関数を $g(u)$ （通常＝値関数）で表す。ニューロンに与えられる教師情報を $d(X)$ として、誤り訂正法は、

$$g(u) = d(X) \text{ のとき } W(t+1) = W(t)$$

$$g(u) \neq d(X) \text{ のとき } W(t+1) = W(t) + \eta dX \quad (\eta > 0)$$

で与えられる。これに対し δ ルールは

$$W(t+1) = W(t) + Ct (d(X) - u) X \quad (2 > Ct > 0)$$

で与えられる。即ち、誤り訂正法はニューロンの出力が教師情報に一致するように重みを改変するのに対して、 δ ルールではニューロンのポテンシャルと教師情報が一致するように重みを改変するものである。両学習方法とも学習過程の収束条件が理論的に求められている。その詳細は紙面の都合で省略するが、誤り訂正法では入力パターンが線形分離可能即ち、

$$W \cdot X > 0 \quad \forall X \in C^+ \quad (d(X) = +1 \text{ のカテゴリ})$$

$$W \cdot X < 0 \quad \forall X \in C^- \quad (d(X) = -1 \text{ のカテゴリ})$$

を満たす W が存在することが学習過程が収束するための必要十分条件である。 δ ルールについては W は $(d(X) - u)^2$ の X についての期待値を最小にする W に収束することが示されている。

但し Ct が、

$$\sum_{t=0}^{\infty} Ct = \infty \quad \sum_{t=0}^{\infty} Ct^2 < \infty$$

を満たすことが条件となる。

② 確率降下法による学習

前節で述べた学習方法は教師情報が学習するすべてのニューロンに与えられていることを前提としている点で、極めて限定された場合にしか用いることができない。この制約を解消した学習の一般理論が甘利によって示されている [3]。

2つのパターン発生源 X 、 Y を考え、 $X \in X$ が与えられたとき、 Y から発生するパターン Y を推定するシステムを考える。このシステムにより推定される Y からのパターンを $\tilde{Y}(W, X)$ とし、 Y を $\tilde{Y}(W, X)$ と推定したことによる損失関数を $\gamma(\tilde{Y}(W, X), Y)$ とする。

W はシステムのパラメータである。このとき損失の期待値は、 Y の条件付確率密度を $P(Y|X)$ 、 X の周辺分布の確率密度を $P(X)$ として

$$R = \iint \gamma(\tilde{Y}(W, X), Y) P(Y|X) dY P(X) dX$$

で与えられる。この R を最小 (極小) にする関数 $\tilde{Y}(W, X)$ を求めるアルゴリズムは次のように与えられることが示されている。一回の学習における W の変化分を ΔW 、 ε を正の定数、 C を正定値行列として

$$\Delta W = -\varepsilon C \nabla \gamma(\tilde{Y}(W, X), Y)$$

損失の期待値 R が W 以外に未知の要素を含まない場合には R の最小値 (極小値) は R を W で微分して得られる gradient 方向に W を改変していく通常の最急降下法により求まる。しかしこの場合は $P(Y|X)$ と $P(X)$ が未知である。上記の理論はこのような場合でも上式に従ってパラメータを変更してゆくことにより、平均的に R の減少が実現されることを示したものである。

この理論は X を入力パターン発生源、 Y を教師情報発生源、 W をニューラルネットの重みや閾値と考えることにより極めて一般的なニューラルネットの学習方法となっていることが理解されよう。 $Y(W, X) = W \cdot X$ 、 $\gamma(\tilde{Y}(W, X), Y) = (Y(W, X) - Y)^2$ とすれば①に示したアダラインの δ ルールにおいて W が 2 乗誤差を最小にする値に収束することを示していることになる。

③ 誤差逆伝播学習

可変な重みで結ばれた feedforward 型の多層ニューラルネットにおいて、最終層のニューロンにのみ教師信号を与えるだけで、ネットワーク全体を組織化する学習方法を誤差逆伝播学習方法 [4] (error back propagation、BP と略す) という。この方法は第 2 期ニューラルネット研究の代表的成果の一つである。

第 $(k-1)$ 層の i 番目のニューロンから第 k 層の j 番目のニューロンへの時刻 t における結合の重みを $\omega_{ij}^{k-1k}(t)$ 、

第 k 層 j 番目のニューロンの出力を $v_j^k = g(u_j^k)$ として、

$$\omega_{ij}^{k-1k}(t+1) = \omega_{ij}^{k-1k}(t) + \eta \varepsilon_j^k v_i^{k-1}$$

に従って重みを改変する。ただし η は正の定数である。

また、 ε_j^k は教師情報あるいは学習完了後の各ニューロンの出力と学習中の各ニューロンの出力との誤差を表すもので、次の式で定義される。

k が最終層を表す場合は、最終層の j 番目のニューロンに与えられる教師情報を d_j とすると、

$$\varepsilon_j^k = (d_j - v_j^k) \frac{dg(u_j^k)}{du_j^k}$$

k が中間層を表す場合は、

$$\varepsilon_j^k = \frac{dg(u_j^k)}{du_j^k} \times \sum_l w_{jl}^{kk+1} \varepsilon_l^{k+1}$$

となる。

この学習方法は教師情報が直接与えられない中間層の重みの修正方法を具体的に与え、その有効性を示した点で画期的なものであると言えよう。この方法は第 k 層を最終層として前節に示した確率降下法において、

$$\gamma(\tilde{Y}(W, X), Y) = \sum_j (v_j^k(W, X) - d_j)^2$$

としたものに他ならないので、②項の一般理論に含まれるものである。

④ ボルツマンマシンの学習

ボルツマンマシン[4] はニューロンに確率的動作とその動作の制御パラメータとしての「計算温度」を導入した点が第 1 期のニューラルネットにない特徴である。このニューラルネットは以下に示す学習方法により外界から指定される入出力関係を習得できる、すなわち外界の確率構造をモデル化できることが示されている。

学習のアルゴリズムは極めて複雑であるが、おおよそ次のように説明される。まずネットワークの入出力関係が外界から規定されている状態（外界に拘束されている状態）について、ニューロン i とニューロン j が共に 1 である確率 P_{ij}^+ をその頻度から計算する

(正の学習)。次に入出力関係が外界から規定されない状態(外界の拘束を断った状態)でニューロン i とニューロン j が共に 1 である確率 P_{ij}^+ を同様に計算する(負の学習)。

この P_{ij}^+ と P_{ij}^- は計算温度 T を高い値から徐々に下げてある低い値まで下げ、ネットワークが平衡状態に落ち着いた段階で計算される。この T の操作は“焼きなまし (annealing)”と呼ばれ、モデルが最適学習や最適状態探索を行うために不可欠なものである。

焼きなましの後、ニューロン間の重みの変化分 $\Delta \omega_{ij}$ を次式、

$$\Delta \omega_{ij} = \alpha (P_{ij}^+ - P_{ij}^-)$$

ここで、 α は定数から計算し、 $\Delta \omega_{ij}$ だけニューロン間の重みを変える。焼きなましとニューロン間の重みの更新を繰り返すことにより、ボルツマンマシンの学習が進み最適状態に収束してゆく。

⑤ 線形ニューロンにおける教師無学習

線形ニューロンすなわちその出力、

$$g(u) = u$$

で与えられるモデルにおいて、 W の学習方程式を一般的に

$$dW/dt = \phi(\cdot) X - \gamma(\cdot) W$$

で表した場合 $\phi(\cdot)$ と $\gamma(\cdot)$ の与え方とニューロンの動作の関係が Kohonen により一般的に論じられている [5]。このうち教師無学習で興味深い動作を生ずる場合の代表例として

$$\phi(\cdot) = \alpha u \quad (\alpha < 0), \quad \gamma(\cdot) = 0$$

を考える。

今入力パターン集合を $S = \{X_1, X_2, \dots, X_m\}$ ($m < n$) とし、これらがランダムに繰り返し呈示されるとする。このとき $t \rightarrow \infty$ における $W(t)$ を $\tilde{W}$ とすれば、 $\tilde{W}$ は S に含まれるすべてのパターンに直交するベクトルに収束する。即ち S を学習した線形ニューロンは $X_1 \sim X_m$ で張られる空間に属さないパターンに対してのみ出力することになる。このような機能をもつ線形ニューロンは novelty detector とよばれる。

このニューロンをパターンの次元数に等しい数だけ並列に並べ、各ニューロンの出力を可変重みを介して他のニューロンにフィードバックするシステム (novelty filter) を考える。すなわち出力を表す列ベクトルを U 、可変重みマトリクスを M として

$$U = X + MU = (I - M)^{-1} X$$

$$\frac{dM}{dt} = -\alpha U U^T$$

なるシステムを考える。このシステムに S を学習させたとき、任意の入力パターン X の出力は $X_1 \sim X_m$ で張られる空間の直交補空間への X の射影成分で与えられることが示されている。即ち入力パターンの未知部分が出力されることになる。

この他トポグラフィックマッピングを形成する学習方法も Kohonen により提唱されているが、この種の話は 3.2.6 項で詳しく述べられる。

⑥ その他の教師無学習 [6]

非線形な入出力関係をもつニューロンにおける教師無の学習方法は教師付学習方法に比べ数理的な理論展開が進んでいない。これはこの方法が入力系列とネットワーク自身の内部状態を手がかりとして自動的に組織化を行うため、その動作が重みなどのパラメータの初期値や入力の方に大きく依存することによる。現在までに提唱されている方法としては、Hebb 型学習方法と最大値検出型学習方法（競合学習法）が著名である。

Hebb 型学習方法はニューロン i から j への結合の重み ω_{ij} の変化がニューロン i 、 j の状態によってのみ規定される。すなわち極めて局所的な誘因によって重みの変化が決まるものである。一般的には

$$\Delta \omega_{ij} \propto g(u_i) \cdot g(u_j) - f(u_i, u_j, \omega_{ij})$$

と書き表されるが、よく用いられるのは $g(\cdot)$ が 1、0 の 2 値閾値関数で $f(\cdot)$ が一定又は ω_{ij} に比例するものである。この方法の概念は心理学の分野で古くに提唱され、最近神経科学の分野で脳におけるその実在が検証されたものである。

最大値検出型学習方法はニューロン群の層状結合において、前段の層で発火しているニューロンと次段のある領域で最大ポテンシャルをもつニューロンとが結合を強めるというものである。これは神経系が情報圧縮を行っていく場合に有用な学習方法であり、この方法によりいわゆる“grandmother cell”の機能形成等をニューラルネットで説明することができる。なおこの方法では一つのニューロンにおける重みの総和を一定にするという制約がしばしば付与される [7]。これにより動作の改善を計ることができることが知られている。

⑦ 時系列情報の学習[8]

言語や運動の学習においては時系列情報の学習が不可欠である。時系列情報を学習するニューラルネットはその問題の性質上構成要素のニューロン間に回帰的な結合をもつ。最も典型的なものは、BP法を学習方法にもつニューラルネットにおいて、中間層の出力の copy を context を表す情報として入力の一部に戻す方法である。この種のニューラルネットはその回帰的結合を取入れた点に新しさはあるが学習方法としてはBP法を採用しており学習方法として特に新しい点はない。

これに対し3層ニューラルネットの中間層に回帰結合を設けその重みを改変する方法が提案されている。このようなニューラルネットでは、中間層ニューロンは無数の経路を経て最終層のニューロンへ影響を与えるので一般的に厳密な学習方法を導くことは困難である。しかし、最終層への入力が中間層から最終層への直接経路による信号で近似できるという仮定を設けると、feedforward 型のニューラルネットにおけるBP法と等価な学習方法で学習が可能であることが示されている。

以上は教師付学習であるが、教師無学習によっても context を学習により習得することが可能であることが示されている [9]。これは同一層内の回帰結合の重みの改変にHebbの学習則と類似のもの、即ちシナプス前後のニューロンの相次ぐ発火により重みを増やすという規則を用いたものである。

[参考文献]

- [1] Rosenblatt, F. Principles of Neurodynamics - Perceptrons and the Theory of Brain Mechanisms. Washington, D.C. : Spartan, (1961).
- [2] Widrow, B. Generalization and information storage in network of adaline "neurons". In Self-Organizing Systems-1962, M.C.Yovits, G.T. Jacobi, and G.T.Goldstein eds. 435-462. Spartan Books, (1962).
- [3] Amari, S. A theory of adaptive pattern classifiers. IEEE Trans. EC-16, 279-307, (1967).
- [4] Rumelhart, D.E., McClelland, J.L., and The PDP Research group. Parallel Distributed Processing - Explorations in the Microstructure of Cognition Volume 1 : Foundations. Cambridge, MA : MIT Press, (1986).
- [5] Kohonen, T. Self-organization and Associative Memory. Springer-Verlag, (1984).

- [6] 福島邦彦, 神経回路と情報処理, 産業図書, (1989).
- [7] Malsburg, C. von der 1973. Self-organization of orientation sensitive cells in the striate cortex. Kybernetik 14[2], 85-100.
- [8] 銅谷賢治, “ニューラルネットワークによる振動パターンの記憶”, コンピュータロ
ールNo.29, (1990).
- [9] Nagano, T. “A Learning System Able to Grasp Its Situation” IEEE Trans. on
SMC Vol. SMC-5 No.1, (1975).

3.2.2 認識処理における学習の利用

(1) 学習利用の背景

人工的神経回路網モデル(ニューラルネット)の適用領域として、音声認識・画像認識に代表されるパターン処理は現在最も盛んに研究されている分野の一つである。それらのパターン処理において、ニューラルネットに期待されている点は、一つはその高並列性による高速処理と事例学習に基づく適応性の二つに代表される。

例えば、N個の要素で表現される入力パターンをM個のクラスに分類する問題を考えると、従来の統計的手法に基づくパターン処理では、まず入力パターンの各クラスに対するマッチングスコアを計算し次に最も高いスコアが得られたクラスを選択するよう処理される。入力パターンの発生には確率モデルが用いられ、マッチングスコアは入力パターンとM個のクラスの標本パターンとの尤度計算により行われる(通常、マッチングスコアの計算アルゴリズムが簡略化できる多変量ガウス分布が用いられる)。このように従来のパターン処理では、分布パラメータに関して強い仮定がなされ、基本的には適応型ではない。

一方、ニューラルネット(N個の入力ユニット、適当な数の中間ユニット、各クラスに対応するM個の出力ユニットから成るニューラルネットを想定)では、上記の例でのマッチングスコアの計算がM個のクラスに対して並列に行われ、出力ユニットがマッチングスコアをそのまま表すことになる。さらに、従来の統計的手法に比べて分布の形に対して強い仮定をすることもなく、入力パターンに対する正しいクラス出力が得られるように、学習アルゴリズムに基づいて、ユニット間の結合の重みが適応的に変えられる。

以上のように、並列処理による高速化のみならず、処理結果に適応して結合の重みを変化させ自らの能力を改善してゆくニューラルネットの学習機能への期待が、これらパター

ン処理の分野でのニューラルネット研究の活発化の背景としてある。

(2) 認識処理における学習の適用

認識処理へのニューラルネットの適用に際し、そこで想定されている利用形態と課題を整理する。

利用形態の第1は、上で挙げたような入力パターンを幾つかのクラスに分類する識別問題。第2は連想メモリ、すなわち部分的な情報からあるクラスの標本そのものを再生成するものである。通常、最も確度の高いクラスを決定した後、その標本を再生成する処理を上記の識別処理に付加することで実現される。第3はN個の入力からM個の出力を得るベクトル量子化などの場合で、情報量の圧縮や削減に用いられる。

また、ニューラルネット適用上の課題は、元々の情報構造を学習によってネットワークに獲得させようとするものであるから、どのような情報表現により効率的な学習が可能となるか、また、既存の知識や知見をネットワークの構造や処理にいかにより有効に生かすかがポイントとなる。

以下、学習能力を有するニューラルネットの認識処理への適用事例として、音声認識と画像処理・認識について述べる。

(3) 音声認識への適用事例とその現状と課題

音韻や音節といった言語の基本構成単位の認識から単語音声認識、さらに連続音声認識へというのが音声認識のシナリオである。しかし、話者の違いによる変動（個人差）や前後のコンテキストによるパターン変動（調音結合）、同一話者・内容の発声でも生ずる時間軸上でのパターン変動（時系列パターンの時間軸上での非線形伸縮）のために、音韻・音節の認識でさえも容易ではないというのが実状である。

このような音声パターンの変動に対する現状技術としては、DPマッチング（時系列パターンの時間軸上での非線形伸縮を許すパターン照合アルゴリズム）、HMM（隠れマルコフモデル：個人差や調音結合によるパターン変動を確率モデルとしてとらえる方法）があり、現在の音声認識研究の主流をなしている。

ニューラルネットの音声認識への適用事例を以下に挙げる。

【音韻・音素認識】

- ・TDNN+サブネットの統合学習による音素認識；

3 フレームの時系列スペクトルを入力としTDNN(Time-Delay Neural Network: 遅延素子を有するNN) から成るサブネットワークを音素グループごとに適用・学習させ、その後再学習により全体を統合化する。

- ・グループ分割型バックプロパゲーション (BP) による音節認識;

LPC ケプストラム係数を入力に、母音および従来の音声学の知見に基づき分類された子音グループごとにサブネットを構成し、各グループを選択するためのサブネットとともにBPで学習させる。

- ・ボルツマン・マシン(BM)による母音認識;

FFT 処理されたスペクトルを入力とした母音認識及び母音の調音場所の認識など。

- ・その他、学習ベクトル量子化による音素のクラスタリングなど。

【単語音声】

- ・BPによる数字音声認識

- ・DPマッチングとNNを併合したネットワークによる数字音声認識など。

【連続音声】

- ・BMによる連続単語認識;

BMに1時刻前の出力ベクトルをコンテキストとして入力層にフィードバックする機構を付加。

以上は、ニューラルネットの利用形態としては分類・識別を主としたものである。その他、これまでの音声認識研究の知見を背景として、NNの特徴抽出機能の解明を目指し、母音認識を対象に自己相関関数、LPC ケプストラム、基底膜振動パターンなどの各種入力情報表現法を比較した研究がある。また、中間層の素子出力が入力空間内の点(基準点)からの距離を表すように構成し(例えば RDF: Radial Basis FunctionsやSPAN: Saturated Projection Algorithmなど)、音声パターンの分布に関する既存の知識をネットワークの構造に直接反映し学習の効率化を図った報告などがある。

ニューラルネットの音声認識への適用の現状と今後の課題をまとめると以下のようなになる。

- ・限られたデータあるいは問題に対して認識率の改善が報告されているが、オーバオールでDPマッチングやHMMなど現状技術を越えていない。
- ・同様に、問題・対象が限定されており、音韻・音節から単語音声、連続音声へとトータルなシステム化への展望が見られない。

- ・大語彙化と不特定話者への適用という現状技術の2大課題は、ニューラルネットにとっても未だ手つかずの問題として残っている。

従って、今後の課題としては、トータルなシステム化の観点に立ちトップダウン処理を導入した構造化手法、並列処理と学習機能などニューラルネットの利点を有効に活かしつつ、現状技術との、差分を明らかにするための統合化法(ex. NN+HMM, NN+知識処理)、さらに音声など時系列パターン処理の本質的な取扱いに向けた情報表現法やネットワーク構成法(例えばリカレントネットワークなど)の研究が必要となる。

(4) 画像処理・画像認識への適用事例とその現状と課題

画像情報は一般にデータの量が多いのが特徴であり、学習機能のみならずニューラルネットの並列性に基づく高速処理に期待が寄せられている。また、画像情報の重要な特徴としては、基本的に2次元情報であり局所的な連続性あるいは逆に不連続性(エッジ)があること、また、画像の認識においては物体の平行移動・回転・拡大／縮小などといった幾何学的な変換に対して不変でなければならない点が挙げられる。

従って、画像処理・画像認識では、局所的な部分画像に対するローカル処理を並列に適用し次に統合化する基本戦略が一般にとられる。なお、ここで画像処理とは画像強調や特徴抽出フィルタなどのように処理結果も画像である処理、画像認識とは画像の分類や画像中からの物体の認識などの処理を指すものとする。(2)に示したニューラルネットの利用形態に対応させると、画像処理は第2(連想メモリ)、第3(ベクトル処理)に、文字認識も含め画像認識は第1の分類・識別処理に対応させられる。

ニューラルネットの画像処理・画像認識への代表的な適用事例を以下に挙げる。

【画像処理】

- ・相互抑制型競合学習モデルによる特徴(エッジ)抽出の自己組織化
- ・連続性を有する局所的な画素処理にラインプロセスを導入、エネルギーの最小化による雑音除去／画像修復
- ・自己想起型ニューラルネットによる画像圧縮／符号化
- ・BPによる曲率と方向検出
- ・BPによるステレオ画像からの視差抽出など

【画像認識】

- ・ネオコグニトロン(相対的な位置関係の集積による文字認識及び選択的注意のモデル

化)

- ・注視点移動モデル（統計的な情報の収集に基づく図形の認識）
- ・BPによる顔画像の認識など

ニューラルネットの画像処理・画像認識への適用の現状と今後の課題をまとめると以下ようになる。

- ・ローカル処理を並列実行できるコネクションマシンなど並列計算機の利用による高速化の成果は出ているがニューラルネットの学習機能を有効に活かした例は少ない。
- ・文字認識では学習機能による性能向上が報告されているが、現状では認識文字数が限定されており、実用に供するにはネットワークの大規模化と効率的な再学習法が課題である。
- ・画像認識では、エッジ、コントラスト、カラー、奥行き抽出などの各画像処理の複合化・統合化に基づく認識方式や物体の運動情報を利用して幾何学的不変性に対処する方式の創出が重要課題である。

(5) 認識処理におけるニューラルネット研究の現状と課題（まとめ）

ニューラルネットの高並列性に基づく高速処理性と適応化を可能とする学習機能への期待が大きいですが、認識処理におけるニューラルネット研究の現状は、未だ機能的には単機能、ネットワーク構成としては小規模・単純構造に限定されているのが実状である。総合性能、実用的な意味でも現状技術を超えるには至らず、本格的な研究がこれから始まる、進められつつあるというのが現状である。

課題としては、計算学習理論的アプローチによるニューラルネットの理論的可能性と限界の明確化や情報表現法など理論的研究とともに、実用的な工学システムの構築に向けた

- ・機能の複合化、処理の統合化、ネットワークの大規模化を図る構造化手法の開発
- ・上記の構造化、システム化の鍵となるシンボル処理との統合化・融合化の検討

さらに、

- ・ニューラルネットの特徴を十分に活かす魅力ある応用分野・適用領域の開拓
- などが重要となる。

音声認識

認識のシナリオ

音韻／音節 → 単語音声 → 連続音声

個人差、調音結合
時間軸上の非線形伸縮

.....従来技術.....

- ◇ マルチテンプレートDPマッチング
- ◇ HMM (隠れマルコフモデル)

- TDNN + sub-netの統合学習による音素認識
- グループ分割型BPによる音節認識
- BMによる母音認識
- 学習ベクトル量子化による音素のクラスタリング
- BPによる数字音声認識
- DPマッチング+NNによる数字音声認識
- BMによる連続単語認識 (BM + FB)

NNによる応用事例

NN適用の現状・課題

- ◇ オーバオールのパフォーマンスで従来技術を超えていない。
- ◇ 再学習の不要なサブネットの統合化
- ◇ 時系列パターンの取扱い Recurrent Network
- ◇ Total なシステム化への展望が見えない。
- ◇ Top-down 処理の導入
- ◇ 従来手法との統合化 NN + HMM, NN + 知識処理 (ES)

図表3. 2-1 音声認識のNN適用の現状・課題

画像処理／認識

画像情報の特徴

2次元情報
(局所的な連続性、エッジの存在)
幾何学的な不変性

基本戦略：ローカル処理 + 複合化

NN応用事例

画像処理


画像認識

- 特徴抽出フィルタの自己組織化 (相互抑制による競合学習モデル)
- 画素の連続性+ラインプロセスに基づくエネルギー最適化による雑音除去／画像修復
- 自己想起NWによる画像圧縮／符号化
- BPによる曲率と方向検出
- ※ ローカル処理の複合化
- ネオコグニトロン (相対的な位置関係の集積)
- 注視点移動モデル (統計的な情報の収集)
- ステレオ画像からの視差抽出 (BP)
- 顔画像の認識 (BP)

NN適用の現状・課題

- ◇ 計算時間大 並列計算機の利用
- ◇ 適用範囲が限定されている。
- ◇ 本質的な解決策が見えない 各処理の統合化
- ◇ 特に学習機構については生体系からの知見が必須

図表3. 2-2 画像処理／認識のNN適用の現状・課題



図表3.2-3 ニューラルネット研究の現状と今後の課題

3.2.3 知識処理における学習の利用

(1) まえがき

近年、従来の逐次型計算機を強化・補完する計算機システムとして、単純な素子の集合体によって並列演算を行う考え方が脚光を浴びている。特に、生体の神経網を模擬した超並列・超分散演算装置であるニューラルネット（neural-net、神経回路網演算装置）は、従来の逐次型計算機にない特徴が指摘されており、従来型計算機を補完するものとして期待を集めている。

従来の逐次型計算機にない特徴としては、高速性や耐雑音性なども挙げられるが、特に注目されているのは事例による学習能力であり、これが、超分散型のアーキテクチャの大きな特徴となっている。この学習能力はパターン認識や運動制御など、様々な分野で使われ始めているが、ここでは知識処理における学習の利用について述べる。特に、電力系統の状態評価システムを学習によって構築した例を説明し、現状技術の問題点と将来の課題を挙げる。

(2) 知識処理における学習の意義

現在、知識情報処理技術として最も良く知られているのは、知識工学技術であるが、これは、数式として記述しにくい知識をルールとして記述することによって知識の利用範囲を拡大したものであり、ルールとして記述可能な断片的知識の積み重ねによって高度な認識や制御を可能にする技術である。しかしながら、知識工学技術では、知識の記述様式がルールという形で厳密に定められており、また知識の自律的な獲得機能もないので、システム作成には人間が知識を陽に表現できる形で持っていなければならない。その結果、人間が知識の獲得や編集に多大の労力を投入しなければならない。

従来の知識情報処理技術としては、ファジー論理も最近多くの分野で利用され始めている。これは、厳密な定式化が困難な対象をあいまいなまに残して扱うために、人間の価値判断の重みづけを定量化した知識記述方法を与えるものであるが、知識の定量化と記述は人間が行わなければならない。

このように、従来の代表的な知識情報処理手法は学習能力の欠如が利用上の大きな制約となっている。これに対して、ニューラルネットは学習能力を持つため、単に事例を教示するだけで知識の移入を行うことができ、定式化やルール化などの困難な知識をも利用することができる。従来の知識情報処理手法では、次のような場合に定式化が困難になることが知られている。

- ① 少数の一般性の強いルールでは記述できず、個別的な例外事象が多く、それらに対処するための細かいルールが必要な場合には知識工学的手法だと煩雑になり、システム構築が困難になることが経験的に知られている。
- ② 多くのデータや一群の知識全体の特徴から何らかの判定を行うようなシステムの場合、パターンとしての微妙な特徴をルールの形で指定することは困難である。
- ③ 知識処理に論理的な推論だけでなく、長い経験によって育まれた直感や洞察など、言語によって表現することが難しい知識を含む場合、あるいは論理構造が解明されていない知識の処理を要する場合、ルール化は困難である。

このような対象に対して、ニューラルネットの学習能力は大きな効果を持つことが知られている。例えば文字認識は文字パターンを入力し認識結果を出力する知識情報処理と考えることもできるが、認識の論理構造は解明されていないため、これをルールによって行うことは極めて困難である。また、運動制御も、ある目的が入力として与えられた時に、制御出力の合成する情報処理と考えられるが、人間が行っているような微妙な制御の規則

が解明されていないために、従来の知識情報処理を用いるのは簡単ではない。これらの目的に対し、ニューラルネットは、その学習能力によって大きな効果を挙げている。また、ニューラルネットによる学習では、事例を学習することによって未知の入力にたいしても反応することが出来るようになるという大きな特徴があり、これも従来の情報処理技術には見られない特徴である。更に、ニューラルネットの学習では、パターンの全体的な特徴に反応するようになるので、事例間に細かな知識の矛盾があっても、それを残したままで学習ができ、無矛盾性に対する要求も従来の知識工学等に比べて緩いといえる。

本項では、推論の論理を記述しにくい場合の知識処理の例として、電力系統の状態を評価するシステムを題材として、それをニューラルネットによって構築する場合について述べる。

(3) 電力系統の状態評価システム


現在の大規模かつ複雑化した電力系統では、その運用効率や信頼性の一層の向上には経験的知識の活用が極めて重要なものとなっている。このため、例えば事故時の系統復旧や需要予測などへの知識工学の利用が試みられている。本研究では、電力系統の状態を表す状態変数群のパターンから、その系統が安定度等において危険な状態にあるか否か等、系統状態の評価を行うシステムを考え、それに対するニューラルネットの適用について検討する。

これと類似のシステムとして、系統の緊急時に大量に発生するアラームの内容を整理して、操作員が系統状態を把握することを支援する装置（アラームプロセッサ）が考えられており、これを知識工学に基づいて実現しようという試みがある。提案するシステムは、このようなシステムと同様の目的を持つものである。異なる点は、提案するシステムではアラーム情報を整理するのではなく、状態量のパターンから直接評価内容を与える。また、このシステムは、系統の安定度などを、緊急時のみならず常時監視することも目的としている。なお、系統の状態量としては、電圧、通過電力、相差角等考えられるが、本検討では電圧のみ対象としている。


(3.1) 代表パターンと評価結果の学習

本検討では35ノードから成るモデル系統を仮定し、その系統で14個の代表的電圧パターンを仮定する。図表3.2-4にその一部を示す。電圧は1.0puからの偏差で示してある。そ

して、これら14パターンに対する評価結果を図表3.2-7のように仮定する。電圧パターンは潮流計算で作成したが、実際の系統では、代表的な電圧パターンは系統の運用実績から求める必要があり、またそれらのパターンに対する評価も系統解析と経験的蓄積から行う必要がある。




(a) Pattern 1




(a) Pattern 4

図表3.2-4 代表電圧パターンの例

ニューラルネットは図表3.2-5に示す3層のものを用いた。電圧パターンの入力方法としては、電圧を0.01[pu]幅で離散化してノード番号とこの電圧範囲でメッシュを作り、このメッシュ1個にニューロン1個を割り当てる。ノードは、全35ノードから発電機ノードを除く25ノードを対象としており、入力ユニット数は250個となる。図表3.2-6にデータの入力形式を示す。電圧のパターンの波形を人間の目の網膜に写し取るような形で入力する。中間ユニット数は20、出力ユニット数は12である。出力ユニットは図表3.2-7の12個の評価項目に対応する。図表3.2-7の評価項目のうち、成立するものは1.0、不成立は0.0として教示パターンを作り、パターン1からパターン14の順でバックプロパゲーション法によって教示を繰り返した。学習後のニューラルネットは事例として与えられた電圧パターンが与えられると、図表3.2-7に示した専門家の評価を出力する能力を持つようになる。図表3.2-8出力例を示す。このように学習能力によって、図表3.2-7の論理構造を明らかにすることなく、専門家の知識を事例学習によって獲得することができる。




図表3.2-5 ニューラルネットワークの構成 (BP)



図表3.2-6 データ入力形成

図表3.2-7 代表電圧パターンに対する評価内容

評価 パターン	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1. 昼間	○	○	○	○	○	○	○	○	○	○	○	○	○	○
2. 夜間														
3. 健全電圧	○													
4. やや低下		○												
5. 低下			○		○	○	○	○						
6. 異常低下				○					○	○	○	○	○	○
7. 北東部							○				○			
8. 北西部								○				○		
9. 南東部						○				○				○
10. 南西部					○				○				○	
11. 重負荷													○	○
12. 全域	○	○	○	○										



図表3.2-8 ニューラルネットワークの出力側(BP)

(3.2) 未知パターンに対する反応

ニューラルネットは人間の場合と同じように、代表パターンを学習することによって、未知パターンに対してもある程度の判定を下す能力を持つようになる。これは、ニューラルネットの学習の大きな特徴の一つであり、従来の知識情報処理技術には見られないものである。未知パターンに対する反応特性は3つのレベルに分けて考えることができる。

- ① 引込み能力
- ② 補間能力
- ③ 類推能力

引込み能力は、例えば、雑音等で入力パターンが事例パターンから少し変歪されたものである場合でも、その事例パターンとして判定する能力である。この能力はニューラルネ

ットの構造や学習方法によって異なるが、ニューラルネットでは入力パターンはその全体的な特徴によって判定されるので、引込み能力は容易に実現される。

補間能力は、事例として与えられるパターンの中間的な入力パターン、例えば任意の2つの代表パターンを混合したものや、それに近いパターンに対して適切な判定を行う能力を指す。これは、引込み能力で扱うよりも大きな変歪を扱っているが、学習パターンから著しくかけ離れていない範囲を扱う。この能力は現状のニューラルネット構築手法では必ずしも保証されず、適切な補間が行われる場合もあれば、そうでない場合もある。

類推能力は、学習パターンと関連性の小さい任意のパターンに対して適切な判定をする能力であるが、これは現状では難しい。これが可能になるためには、学習事例から一般的な規則を抽出して、それに照らして判定する機能が必要であるが、現状のニューラルネットはこうした機能を持たない。人間でも、教えられたパターン以外のパターンを分析するには、教えられた知識から一般的な規則を見い出さなくては類推はできず、学習や判定にたいする論理的知識の影響など、生理学においても未解決の問題を検討しなければならない。

今回の例では、補間能力までを検討の対象としており、以下それについて述べる。


(3.3) 補間機能

補間機能を調べるために、本研究では2つの代表的パターンをある比率で混合させたパターンを作り、それに対してニューラルネットがどのように応答するかを調べた。混合パターンとしては次の代表パターンによるものを用いた。


- ① 全域やや低下（パターン2）と異常低下（パターン4）
- ② 北東部低下（パターン7）と北西部低下（パターン8）

(3.3.1) 全域電圧やや低下と異常低下


パターン2「全域電圧やや低下」とパターン4「全域電圧異常低下」の混合パターンに対する出力を図表3.2-9に示す。電圧低下の大きさを示す出力ユニット4, 5, 6は、4から6へ出力の大きさが連続的に移行しており、人間の感覚と一致する良好な補間性能となっている。




(a) mixing ratio 1 : 0




(d) mixing ratio 2 : 3




(b) mixing ratio 4 : 1



(e) mixing ratio 1 : 4



(c) mixing ratio 3 : 2



(f) mixing ratio 0 : 1


mixing ratio=(slightly low):(abnormally low)

図表3.2-9 電圧低下程度に関する補間特性

(3.3.2) 北東部低下と北西部低下

この例ではパターン8「北西部電圧低下」にパターン7「北東部電圧低下」を混合し、パターン8の特徴が次第に薄れて行くときのニューラルネットの応答に着目する。この時のニューラルネットの入出力を図表3.2-10に示す。この場合には、前の例ほどは補間性能は良くない。図表3.2-10に示す混合比率2:3の場合にはパターン1「健全」への引き込みが見られ、パターンの類似性という点では不適切な引き込みではないが、意味的には不適切である。今回の代表パターンの中では、パターン8を除けばこの混合パターンに一番近いものはパターン1であり、また、人がこれらを見た場合も、この混合パターンをパターン1に近いのか8に近いのか決め難いと思われる。しかしながら、電力系統制御の専門家であ

れば、全体的には健全状態に近いパターンではあっても、重大な結果が引き起こされるかも知れない北西部の電圧低下と言う事実に着目して、一応パターン8との類似性に着目すると考えられる。そしてこのような判断には、単なる形状的な類似性のみならず、論理的な知識から認識へのフィードバックをとまなう。この点において現在のニューラルネットは完全なものとは言えない。



図表3.2-10 場所に関する補間特性

(3.4) まとめ

以上、電力系統における電圧パターンの認識を題材として、定式化の困難な知識の処理に、ニューラルネットの学習能力が有用であることを示した。

学習能力によって、事例からの専門家知識の獲得や、入力情報の変歪に対する強靱さ、補間性能などが得られ、従来の知識処理技術にない様々な特徴が得られる。しかしながら、事例学習では、膨大な教示の繰り返しが必要であり、学習に要する時間が極端に長くなる傾向がある。それゆえ、現在多用されているバックプロパゲーションよりも高速な学習手法の開発が今後の大きな課題である。又、補間機能については、ある程度妥当な補間が出来ることが示されたが、現状ではパターンの形状的な類似性のみに基づいた判定をしているため、人間が無意識のうちに行っている視点の切り替えなど、現在のニューラルネットにはない高度な情報処理を可能とするためのニューラルネット構造や学習アルゴリズムの開発が必要となる。

(4) 現状技術の問題点と他の学問領域への期待

(4.1) 現状技術の課題

上述の研究により、現状のニューラルネットの学習には、以下のような点が主要な問題があることが明らかになった。

- ① 学習に膨大な時間がかかる傾向がある。
- ② パターン認識と論理的知識との関連が考慮されていない。

まず、①の学習時間の問題は実用上大きな障害となりうる。今回示した研究はモデル系統を対象としているのでニューラルネットの規模は小さいが、実際の系統を扱うと必要なニューラルネット規模はかなり大きくなり、学習時間の問題が大きくなる。完全に工学的な観点から学習時間の問題を解決する方法の一つは、学習アルゴリズムを改良することである。もう一つの方法は構造化である。構造化とは、一つの大きなニューラルネットを作る代わりに、幾つかの小さなネットワークを作り、それらの出力を統合することである。現在は工学的な観点からの解決方法について研究しているが、人間の脳における実際の仕組みから遊離したものでは新しい超分散システムの追求という点では意味がないので、生体との対応については目を向けていたい。この時、次のような疑問が生じる。

- a) そもそも、人間の脳において学習に関係するのはシナプス荷重の変化だけなのか。人間の場合には、運動制御の学習には時間がかかるが、論理的知識を含むような学習には

それほど学習時間はかからないように思える。論理的知識は学習にどのように関係するのか（認知・心理学への期待）、また、そのような学習は人間の脳ではどうなっているのか（神経科学への期待）。

b) 話をパターン認識能力に限っても、生物では本当にバックプロパゲーションのような学習が行われるのか。バックプロパゲーションでは出力誤差を小さくするという制約条件のみでリンク荷重変更が行われるが、リンク荷重の変更にはもっと違った規則があるのではないかと（神経科学への期待）。

c) 人間の脳内の情報処理も、低次情報から高次情報へと処理の流れは階層を持ち、神経網は構造化されているように思えるが、現在ニューラルネットを構造化する場合には、適用分野ごとに個別的に研究者が組み立てている。これでは事例のみを与えれば良いというニューラルネットの利点が失われてしまう。一方、人間の脳は構造化されているらしいにもかかわらず、学習能力は失われていない。この点は人間の脳ではどうなっているのか（神経科学への期待）。

②のパターン認識と論理的知識との関連については、上述の構造化が解決法の一つになりうる。しかしながら、それは単に可能性として考えられるだけであり、論理性の導入を実現するには、次の疑問が明らかにされる必要がある。

d) パターン認識に論理的知識がどのように作用するか（認知・心理学への期待）、それは脳内でどのように実現されるか（神経科学への期待）。

(4.2) 他の学問領域への期待

① 数理的扱いの改良に対する期待項目

現状アルゴリズムの神経科学との整合性の検討

神経科学等の現状の知見を取り入れた学習アルゴリズムの開発

② 認知・心理学への期待項目

論理的知識の学習における役割

論理的知識のパターン認識における役割

③ 神経科学への期待項目

脳内知識表現

論理的知識に依存する学習の神経網上での実現形態

事例からの学習能力を保持した脳内構造化機構

④ 人工知能等との融合に対する期待項目

上記の内、認知・心理学への期待項目が明らかになった場合には、神経科学に遡ることなく、一部をエキスパートシステムなどで置き換えることも可能となるので、その場合の適切な結合方法。

3.2.4 運動制御における学習の役割

(1) 随意運動の計算理論

随意運動の例として、テーブルの上のコーヒーカップに手を伸ばしてとり、口に運んでコーヒーを飲む動作を考えよう。

まず、視覚でカップの位置やほかに置かれているものを確かめる。障害物を避けながら手先をカップに近づけ、カップの取っ手をうまく握めるように手のかまえをつくる。うまくカップをとることが出来たら、コーヒーをこぼさないように手の感覚も利用して力やカップの姿勢を調節しながら口に運ぶ。

このように、随意運動は、状況に応じて時間的・空間的な運動のパターンをプログラムし、知覚的な情報によって、意識的に制御しながら実行する運動である。

随意運動の計算理論とは、運動の実行にあたって脳はどのような問題を解かなければならないかを示し、その計算の手順を明らかにすることである。

Saltzman(1979)、Hollerbach(1982)らの研究に続いて、Kawatoら(1987)は問題を次の3つの段階に分けた。すなわち、①軌道計画、②座標変換、③制御トルクの計算である。先の例でいえば、カップをとるには手先をどのように移動させたらよいかを決めることが軌道計画である。軌道は、手先が運動する(あるいは作業する)空間の上で記述される。これを作業座標での表現という。ところで、手先は、手首、ひじ、肩の関節を回転させることによって運動する。そこで、脳としては、作業座標上で与えられた軌道を、各関節が回転すべき角度(これを身体座標上の表現という)に変換しなければならない。関節角度から手先の位置を求める関係をキネマティクスというが、ここでは、逆キネマティクス問題を解くことになる。さらに、運動を実行するには、関節を目標どうりに回転させるためのトルクの計算が必要である。関節に与えるトルクから角度を求めるには、腕の運動のダイナミクスを用いるが、ここで行う逆の計算を逆ダイナミクス問題という。

ここでは、①の軌道計画と③の逆ダイナミクス問題について、ニューラルネットの学習能力を利用した研究について紹介する。

(2) Reaching運動での軌道計画

手先を目標点に移動させるには、無数の軌道があり得るが、人はその中で、比較的一定の軌道を選んでいる。そこには、何か選択の基準があると考えられる。

この問題については、Flash, Hogan (1985) による躍度最小モデルが提案されていた。これは、手先の座標の時間に関する3回微分値を運動時間について積分した値が最小になるように軌道が決定されるとするものである。このモデルに従うと、軌道はすべて直線となる。人について行われた実験結果によると、体の前面で行われる手先の自由運動では、ほぼ直線となり、モデルとよい一致を示した。

しかし、躍度最小モデルは、最適軌道が制御対象である手のダイナミクスにまったく依存しないというもので、そのこと自体は興味ある考えではあるが、疑問視せざるを得ない。しかも、手を真横に伸ばした状態から体の正面に移動させる運動や経由点を指定した運動などの結果は説明できない。そこで、Uno ら(1986)は、制御対象のダイナミクスを取り込んだトルク変化最小モデルを提案した。これは、関節に与えるトルクの時間変化が最小になるように、従って、筋肉への運動指令の変化が最小になるように軌道が決定されるというものである。

関節*i*へのトルクを τ_i としたとき、最小にすべき評価関数 C_τ は、次式で与えられる。すなわち、


$$C_\tau = 1/2 \int_0^{t_f} \sum_i (\dot{\tau}_i)^2 dt$$

ここで、 t_f は運動の所要時間である。この評価関数を最小にする軌道を解析的に求めるのは、制御対象の非線形性などから困難であり、Uno は、Euler-Lagrange方程式に広義ニュートン法を適用して、数値計算によって最適軌道を求めた。しかし、このような計算が生体で使われている可能性は少ないので、次いで、ニューラルネットを用いて、並列的に計算する方法を提案した。


ここで提案されているモデルは、時間的に2つの過程からなっている。一つは、制御対象のダイナミクスを表すモデルを神経回路内に形成する。これを制御対象の順ダイナミクスモデルの学習過程と呼ぶ。2つ目は、学習した順ダイナミクスモデルを用いて最適軌道を生成する過程である。

順ダイナミクスの学習は、図3.2-11(a) に示すように、制御対象と並列に置かれた多層神経回路を用いる。すなわち、制御対象および神経回路に共通のトルク入力を与え、両者の出力を比較する。もし、神経回路が制御対象のよいモデルとなっていれば、2つの出力は一致する筈である。違いがあれば、その誤差を教師信号として、神経回路に与え、層間の結合係数を誤差が減少するように変化させる。この学習には、誤差逆伝播法が用いられた。なお、運動は、一定時間で行われるので、時間を量子化して、縦に並んだ神経細胞に割り振っていることに注意。

次に、最適軌道の生成は、順ダイナミクスを学習したニューラルネットを用いて行う。すなわち、図3.2-11(b) に示すように、トルク入力は遮断し、最終時刻での手先の位置を表す神経細胞の出力と目標点との差を第二層の神経細胞の入力として加える。この時、第二層の神経細胞間には電氣的結合があると仮定する。



(a) 学習期



(b) 軌道生成期

表3.2-11 最適軌道生成の神経回路モデル

このシステムで第二層の j 番目の神経細胞の出力は、次式に従って変化することが分かる。すなわち、

$$dy_j/dt = S_j + g(y_{j+1} - y_j + y_{j-1})$$

ここで g は電気的結合係数。 y が上式に従って変化するとき、次の評価関数 L が最小になることが分かる。すなわち、

$$L = (\theta - \theta_d)^2 + g \sum_j (y_{j-1})^2$$

これは、第一項が、手先の目標への到達を、第二項が、トルク変化の最小化を要請するものである。

上に提案されたモデルがうまく最適軌道を生成出来るか否かが、自由運動のみならず、経由点を指定した運動、障害物回避運動についても計算機シミュレーションによって調べられ、広義ニュートン法による軌道と比較した結果はよい一致を示していた。このモデルは、力制御や手の構えを必要とする運動にも拡張できる。現在、この点についての検討が進められている。

(3) フィードバック誤差学習法による逆ダイナミクスモデルの形成と制御


Ito(1970) は、「人間の運動は、未熟なときは感覚系を通してフィードバックされる誤差信号に応じて、運動指令が修正されるフィードバック制御が行われているが、練習を重ねるにつれて、小脳内に運動系の内部モデルが形成され、このモデルを用いたフィードフォワード制御に移行する。その結果、運動は円滑になる。」という考えを提案した。

ここでは、それを発展させたKawatoら(1987, 1988) のフィードバック誤差学習法による逆ダイナミクスモデルの形成とそれによる制御システムについて紹介する。

図表3.2-12にモデルの概要を示す。

これはフィードバック制御系と逆システムの内部モデルによるフィードフォワード制御系を階層的に組合せたものである。フィードバック制御系は実際の軌道 x と目標軌道 x_d の差に基づく制御信号 u_f を出力する。一方、逆システムは目標軌道を入力として受けて、システム特性に従って計算された制御信号 u_i を出力する。そして u_f と u_i の和 u が制御信号として制御対象に送られる。制御開始の時点では、フィードバック制御だけが働くようにモデルの構造を指定しておく。学習の目標は、フィードバック制御からフィードフォワード制御へ移行させることであるから、 $u_f = 0$, $u = u_i$ となればよい。そこで、 u_f を誤差信号として内部モデルに与え、これが 0 になるように学習を行わせれば、制御

を繰り返す内に、 u_i が働き始め、逆に u_f にとって代わるようになる。この時、内部モデルには、運動系の逆ダイナミクスが習得されたといえる。



図表3.2-12 フィードバック誤差学習法による運動系の
逆ダイナミクス獲得と制御の神経回路モデル

内部モデルとしては、入力層、中間層、出力層の3層からなるニューラルネットを用いた。各層は、幾つかの神経細胞からなり、入力層の神経細胞は中間層の神経細胞に、また、中間層の神経細胞は出力層の神経細胞にシナプス結合している。各細胞は前の層から入ってくる信号にシナプス結合係数を乗じたものの総和を入力として受けて、ある種の非線形変換（例えば、s字形の関数）を施した後、次の層へ出力として送り出す。従って、入力層に目標軌道が与えられたとき、出力層から得られる制御信号（運動指令） u_i は、シナプスの結合状態を反映したものになる。もし、 u_i が目標軌道と異なる軌道を制御対象にとらせるものであれば、フィードバック制御系が働いて軌道を修正しようとする。すなわち、ニューラルネットが逆ダイナミクスモデルに正しくなっていないときは、フィードバック制御による指令信号 u_f が0にならないことになる。そこでこれを誤差信号として、3層間の神経細胞間のシナプス結合係数を修正する。この修正の手続きとして、誤差逆伝播学習を用いた。

さて、逆伝播法によって、実際に、3関節マニピュレータロボットの制御実験を行った。1回6秒つづく運動を600回繰り返したところ、逆ダイナミクスの内部モデルが形成され、フィードバック制御がフィードフォワード制御に移行し、初めは、大きかった誤差も急速

に減少し、円滑な運動が実現できている。

さらに興味深いことは、学習後は、訓練に用いなかった運動に対しても円滑な制御が可能なことである。これは、運動パターンそのものを学習したのではなく、運動系の特性を学習した結果である。子供が、一つのことで手の使い方を訓練すると、自分の手の特性（癖）が分かって、他のこともうまくできるようになることに対応している。

(4) 随意運動計算理論の今後の課題

上の2つの例は、ニューラルネットによって制御対象のダイナミクスを学習し、それを用いて、制御を行うというものであった。ニューラルネットを用いる方法は、3.2.5項で紹介される表参照形に比べて、記憶容量は少なくてすむが、学習に要する時間の長いのが欠点である。適応制御の他の方法としては、制御対象の特性をあらかじめモデルに取り込んでおくものもある。この方法によれば、制御対象毎にモデルを用意する必要があり、ニューラルネットに比べ、柔軟性に欠けるが、学習に要する時間を大幅に短縮できる。

脳の学習が、遺伝情報の枠組みの中で行われることを考えると、完全な白紙状態から始まるとは思われず、何らかの予備知識を前提とした学習という方法は妥当なものといえる。

しかし、学習アルゴリズムとしては、実時間制御に適用できる高速化されたものを開発することも必要である。

これも含めて、今後検討すべき課題を列記すると以下ようになる。

①高速学習アルゴリズムの開発

②自動運動と随意運動との連関：生体は、自動運動の仕組みの上に随意運動の機能を重ねて発達させたと考えられるので、4.3.2項でとりあげる自律分散形階層制御システムの設計理論を構築する上での示唆が期待される。

③自律分散形階層制御を実現する上でのニューラルネットの超並列・超分散性のメリットの検討

④意識的制御と無意識的制御の相互作用：意識的制御の無意識的制御への移行及び本来無意識的に行われている制御の役割の検討

⑤運動の表現の問題：シンボル化された運動とニューラルネットによるその表現形式の検討

3.2.5 ロボットの運動学習

(1) はじめに

(1.1) 対象依存型学習メカニズム

大空を自由に飛ぶたいという人類の夢は現在では飛行機によって実現されている。飛行機を作るために人類が鳥の飛び方を観察し、鳥の飛行メカニズムを模擬した機械から製作し始めたことは言うまでもない。しかしながら、安定に、効率良く飛行するために、飛行機能は同じでありながら鳥の飛行メカニズムとは異なるメカニズムを人類は作り上げている。その際数多くの飛行メカニズムや飛行機の形状が提案されたが空気抵抗や飛行効率などの制約から最適形状に収束していったものと思われる。そこには生物の進化との類似性を感じさせる。この事実は我々が人工的な学習機械を作るときに2つの教訓を与えるように思われる。まず第一に、生体のメカニズムを完全に模擬するのではなく、その機能を実現できる機械を作ること、第二にどの学習方式が効率的かを評価できること、そのために目的をあまり一般的にし過ぎないこと、すなわちある特定の対象について最も効率的な方法を考えることである。つまり、現在においても鳥のような飛行メカニズムを持つ飛行機は実現されていないが、ある特定の目的、即ち大量に、高速に、安全に人や物を輸送するという観点からは鳥よりも遥かに優れた人工物を作ることができた事実注目すべきなのである。もちろん、対象毎に作られた方式を統合し、より一般的な形式に洗練していくことも将来の課題として考えられる。

幸いにして運動制御の分野で学習を論じる場合、問題の定式化は厳密に行うことができ、性能の評価は物理法則に照らしてみれば明らかとなる場合が多い。従って、このような分野では学習メカニズムを考案するために、対象とする問題を限定しその問題について最も効率的な方式を求めることも人工的な学習機械を作る一つの方法論と考えられる。さらに、推測の域を出ないかもしれないが、人類が運動機能を習得し、その後知的な能力を身につけてきた人類の進化を考えると、運動を効率的に学習できるメカニズムは判断、認識、意思決定などの高次情報処理における学習を解明する糸口を与えたとの期待もある。

(1.2) メモリベース制御 (Memory Based Control)

学習を工学的に定義すれば「目標実現のためのデータ（メモリ）の書換え」とも表現できよう。現在、データを大量にかつ高速に処理するためには計算機を利用することが最も自然である。従って、計算機内のメモリをどのように書き換えるかが問題となる。運動

制御という分野では対象をモデル化しそのモデルに基づく方式、モデルベース制御(Model Based Control)が従来の中心的方法であった。ところが、近年の急速な計算機科学の発達により大量のメモリを手軽に取り扱えるようになってきたために、システムの入出力関係をモデル化せずに、そのままメモリすることも可能となった。このようなメモリを利用する方法はモデルベース制御とまったく逆の考え方であり、メモリベース制御 (Memory Based Control) と呼ばれるべきものである。ただし、データを効率的に構造化しなければメモリ容量が膨大になることや、アクセスタイムが長くなり実用化できないと予想される。従って、メモリを基本として効率的に入出力可能な学習システムを構成する必要がある。

(1.3) ロボットの運動学習

本報告では、前述の対象依存型の学習メカニズムの考え方に基づいて、ロボットの運動学習の2つのタイプを説明する。第一の方式はロボットが実現すべき運動パターンがあらかじめ与えられているときに、そのパターンを正確に実現する入力トルクを求める問題に利用される。第二の方式は移動運動や組み立て作業など外界との接触が目的の成否に大きく影響する場合に最も効率よく目的を達成する運動パターンを学習するものである。いずれの方式も入出力関係をメモリし、目的を実現するために、あるルールに従ってメモリ内容を修正することにより学習を実行している。

(2) 目標運動の高精度実現のための学習制御

(2.1) 学習制御の枠組み

人間の腕のようなリンク構造の運動は各リンクが剛体であると仮定すると一般に次のような微分方程式によって記述できる。

$$M(q(t)) \frac{d^2 q(t)}{dt^2} + h(q, \frac{dq(t)}{dt}) + D \frac{dq(t)}{dt} + g(q) = v(t) \quad \text{①}$$

但し、 $q(t)$: 関節角座標、 $q(t) = (q_1, q_2, \dots, q_n)^T$

$M(q(t))$: $n \times n$ 慣性行列、

$h(q, dq/dt)$: $n \times 1$ 非線形項 (コリオリ力、遠心力)

D : $n \times n$ 粘性摩擦係数行列、 $g(q)$: $n \times 1$ 重力項、

$v(t)$: $n \times 1$ 入力

である。このようなダイナミクスに対しての学習アルゴリズムの導出にあたり、以下に示すような問題設定をする。

(a) 有限時間区間にわたる理想的な運動パターンがあらかじめ与えられている。即ち、有限時間区間 $[0, T]$ で定義された制御対象の目標出力 Y_d (①式のダイナミクスに対しては出力を速度とする) が前もって与えられているとする。またこの目標出力には、ある滑らかさを仮定する。

(b) 人間の練習過程に対応した制御対象の駆動は、繰り返しのたびに有限時間区間 $[0, T]$ にわたって実行される。

(c) 各試行ごとに、初期条件は一致させる。即ち、 k 回目の試行時における対象システムの初期状態 $q_k(0)$ に対して

$$\begin{aligned} q_k(0) &= q_0, \\ d q_k(0)/d t &= p_0, \quad \text{for } k=1, 2, \dots \end{aligned} \quad (2)$$

が成り立つとする。ただし、 q_0 、 p_0 は各々初期位置ベクトル、初期速度ベクトルである。この仮定は、学習の対象を運動再現能力の優れた産業用ロボットとするとき十分に満足される。

(d) 対象システムのダイナミクスは、練習中変化しない。

(e) 各試行時において出力 $y_k(t)$ が測定できる。即ち、次の試行時の制御入力を決定するのに、誤差信号

$$e_k(t) = y_d(t) - y_k(t) \quad (3)$$

が利用できるものとする。

(f) $(k+1)$ 回目の試行時の制御入力 $u_{k+1}(t)$ は、 k 回目の試行に基づき、次のようなアルゴリズムによって更新される。

$$u_{k+1}(t) = F(u_k(t), e_k(t)) \quad (4)$$

関数 F をいかに与えるかについては後で詳しく述べるが、実用的には学習効果が保証され、複雑な計算処理を要しない関数を選ぶ。

(g) 更新された入力 $u_{k+1}(t)$ は前回の入力 $u_k(t)$ に変えて記憶される。

(h) 学習によって制御性能が改善されたことを、数学的に次のように記述する。

$$\|e_{k+1}\| \leq \|e_k\| \quad \text{for all } k=1, 2, \dots \quad (5)$$

あるいは、より強い意味で、

$$\|e_{k+1}\| \leq \theta \|e_k\| \quad \text{for all } k=1, 2, \dots \quad 0 \leq \theta < 1 \quad (6)$$

と表現することもある。

(2.2) 具体的な学習制御構成例

前節で述べたアルゴリズムにおいて、繰り返しごとに誤差が減少することを保証する必要がある。入力の修正法によって誤差の減少を保証できる制御対象システムが若干異なる。ここでは、具体的にいくつかの構成例について入力の修正法とその方式の適用可能な対象システムについて述べる。

(A) 加速度信号を用いる場合

ロボットの運動制御に関して加速度信号を用いる場合には次に示される学習則を適用することができる。そのアルゴリズムについて簡単に述べる。まず、対象システムを

$$\begin{aligned} dx/dt &= f(x) + Bu \\ y &= Cx \end{aligned} \quad (7)$$

$x, f(x) : r \times 1, \quad v, y : m \times 1, \quad B : r \times m, \quad C : m \times r$

とする。ただし、非線形関数 $f(x)$ については次のリプシッツ条件を満足するものとする。

$$\|f(x_i) - f(x_j)\|_\infty \leq k \|x_i - x_j\|_\infty \quad \forall i, j, k : \text{正定数}$$

次に、目標出力を

$$y_d(t) : m \times 1, \quad t \in [0, T] \quad (8)$$

と与え、C1級の滑らかさをもつものとする。このとき入力の修正を

$$\begin{aligned} u_{k+1}(t) &= u_k(t) + \Gamma(d/dt)e_k(t) \\ e_k(t) &= y_d(t) - y_k(t) \end{aligned} \quad (9)$$

する。ただし、 u_1 はC1級の滑らかさを持つものを与える。ここで、誤差収束の条件

$$\|I - CB\Gamma\|_{\infty} < 1 \quad (10)$$

が成立すれば、

$$\|de_{k+1}/dt\|_{\lambda} < \rho \|de_k/dt\|_{\lambda}, \quad 0 \leq \rho < 1 \quad (11)$$

が保証される[1]。但し、

$$\|e_k\|_{\lambda} = \max_{0 \leq t \leq T} (\exp - \lambda t) \|e_k\|_{\infty} \quad \|e\|_{\infty} = \max_i |e_i|, \\ e = (e_1, e_2, \dots, e_m)_T$$

$$\|M\|_{\infty} = \max_{0 \leq t \leq T} \sum_j |m_{ji}|, \quad m_{ij}: \text{行列} M \text{の各要素}$$

である。①式で与えられるロボットについては、条件式⑩を成立させるために $x = (q, T, dq/dt)_T$, $u = v$ とし、出力を速度信号とする必要がある。従って、⑨式は入力修正に加速度信号を利用することを意味している。ロボットダイナミクスを⑦式の形式で表現すると行列CまたはBは定数行列とはならず、慣性行列の逆行列を含むため上の定理を直接適用出来ない。しかしながら、慣性行列は正定対称行列であり、各行列の要素には三角関数 $\sin q$, $\cos q$ 等を含むために

$$\alpha \leq M(q) \leq \beta \quad (\alpha, \beta \text{は正数}) \quad (12)$$

と考えられ、また状態量の有界性を仮定すると⑩式に代わって、

$$\|I - \Gamma M^{-1}\|_{\infty} < 1 \quad t \in [0, T] \quad (13)$$

であれば同様に⑪式が成立することが示される[1]。

(B) 速度信号を用いる場合

対象システムを

$$R(t) d^2 x(t)/dt^2 + Q(t) dx(t)/dt + P(t)x(t) = u(t) \quad (14)$$

$$y(t) = dx(t)/dt$$

$R(t)$, $Q(t)$, $P(t)$: $m \times m$ 、各行列の要素はC1級、

$R(t)$: 正定対称行列 $0 \leq t \leq T$

とする。このとき入力修正を

$$u_{k+1}(t) = u_k(t) + \Phi e_k \quad (15)$$

$$e_k = y_d(t) - y_k(t)$$

とする。ただし、目標出力 $y_d = x_d$ はC1級、 u_1 はC0級とする。ここで、

$$\Phi > 0 \quad (16)$$

であれば、誤差 e_k は時間区間 $[0, T]$ でゼロに収束することが保証される。

ロボットダイナミクスは①式に示されるように、一般には非線形微分方程式となるために⑭式で表される線形方程式では表現出来ない。しかしながら通常は目標運動 q_d に対して、フィードバックループを構成し、重力補償を加えた入力

$$v = K_p (q_d - q) + K_d (dq_d/dt - dq/dt) + g(q) \quad (17)$$

を与えれば、実際の運動は目標運動の近傍にあると考えられる。従って、目標運動の軌道まわりで線形化することが可能となり[2]、結果的に⑭式と同様の時変線形システムとして表現することが出来る。時間区間 $[0, T]$ で出来るだけ一様に誤差を収束させるという実用上の観点からは

$$2K_d - \Phi > 0 \quad (18)$$

が良いと推奨されている[2]。

(C) PID学習制御、PI学習制御

上で述べた方式以外に入力修正を⑨式に代わって

$$u_{k+1}(t) = u_k(t) + [\Phi + \Psi \int dt + \Gamma (d/dt)] e_k(t) \quad (19)$$

とすることも可能である。構造的には、サーボシステムでよく用いられるPIDフィードバック則に似ていることから、このような学習制御方式を特にPIDタイプの学習制御則と呼ぶ。ゲイン行列 Φ 、 Ψ 、 Γ は学習方式によって制御性能が改善されるか否かを左右する重要なファクタであり、制御対象の性質を十分に考慮して設定すべきものである。収束の条件はこの場合も⑨式によって与えられる。幸い、剛体リンクによってモデル化されるロボットマニピュレータなどに対しては、かなり広い範囲のゲインで学習の収束性が保証される。また、 $\Gamma = 0$ （加速度信号が入力の修正に加えられない場合）では、入力修正法も⑮式に代わって

$$u_{k+1}(t) = u_k(t) + [\Phi + \Psi \int dt] e_k(t) \quad (20)$$

とすれば良いことが示されている[3]。ただし、この場合は対象システムは⑭式で表現されるタイプに限る。この方法も同様にPIDタイプの学習制御と呼ばれる。

(3) 運動パターン形成のための学習方式

(3.1) 力学的環境学習の概要

現在、実用化されているロボットの多くは、工場内での産業用ロボットのように、一定の環境下で決められた作業を、正確かつ短時間で行うものである。そのため、ロボットと

その運動環境を解析的にモデル化し、それに基づいてロボットの制御を考えるという Model Based Control が有効であった。しかし、運動環境が複雑になると、モデル化が難しくなり制御は困難な問題となる。そこで、ここでは環境が複雑な場合においても、適用可能な制御方法について述べる。

この制御方法では、まず未知の環境に置かれたロボットにテストモーションを実行させる。その際、ロボットの形状を決める状態量と共に、ロボットが外界に作用する物理量をメモリしておく。これを繰り返し行うことにより、運動環境を表現するデータができる。そこで、このデータを利用して目的に応じた運動パターンを構成させるというものである。ロボットの制御において、このような Memory Based Control を行えば、ロボット自身が環境を学習し、自ら運動パターンを構成するという、より自律的な制御が実現できると期待される。

(3.2) 環境の認識


ある環境の中で、ロボットが最適な運動パターンを形成するには、まず、その運動環境を認識しなければならない。そこで次のような運動環境マップを利用する。

【運動環境マップ】

ロボットの状態量 Z の空間内において、 Z を内力 U によって微小変化させたとき、ロボットが発生する外力を τ とする。この τ が関数 $\tau = N(Z, U)$ によって表現されるとき、この関数 N を与えるメモリの内容を運動環境マップと定義する。

以下に示される 3 自由度ロボットの例では、取り扱いを簡単にするために、状態量 3 変数として動的な要素（速度、加速度など）は考慮せず、ロボットの形状を表す変数のみを状態量とする。一般に $n (> 3)$ 自由度で速度や加速度を考慮した場合も類似のマップを構成できることに注意されたい。3 関節型ロボットを考える場合、ロボットの姿勢が各関節角 q_1, q_2, q_3 で表されるとすると、状態量 Z は $Z = (q_1, q_2, q_3)$ となり、運動環境マップは図表 3.2-13 のような 3 次元空間で構成される。ただし、実際にはロボットの運動精度やコンピュータのメモリ容量等による制限があり、この 3 次元空間は適当な大きさ d によって離散化される。従って、ある姿勢から各関節を微小変化させるというテストモーションは、26通り考えられる。 $Z_1 = (\theta_1, \theta_2, \theta_3)$ から隣接する $Z_2 = (\theta_1 + d, \theta_2,$

$\theta_3 - d$ へのテストモーションを実行するために、 Z_2 の状態を目標値としたアクチュエータへのフィードバック入力によって構成し、内力 U を発生させる。その結果、ロボットに外力 τ が生じ、その外力の最大値を測定し Z_1 点にメモリする。さらに、他の隣接点へのテストモーションも同様に行い、方向別に Z_1 点にメモリする。運動環境マップは、この3次元空間上のすべての点において、上記のようなテストモーションを実行させて作成されたデータベースである。




図表3.2-13 マップの概念図

ただし、図中の円はメモリ値の大きさを表すものとする。

(3.3) 運動環境マップの補間と環境認識の学習

前述の環境マップを作成するために、すべてのマップ上の点についてテストモーションを行うことは、膨大な時間とメモリを費やすことになる。そこで、テストモーションによりメモリしたマップ値をもとにして、未実行領域の補間を行う。例えば、図表3.2-14にあるように、中央の部分が未実行領域でありその部分を補間する時、周囲のマップ値の平均を未実行領域のマップ値として考える。周囲にマップ値がない場合には、さらに外側のマ

マップ値の平均を未実行領域のマップ値として考える。これは運動環境を推測することに対応している。また、このような補間法によって一応形成されたマップを新たにテストモードによりテスト未実行領域のメモリ値を正しい値に修正することが環境認識の学習と考えらる。



図表3.2-14 補間の例

(3.4) 動作計画 (パスプランニング)

ここでは、運動環境マップを利用して、最適な運動パターンを決定する方法について述べる。運動環境マップ上の点は、ロボットのある姿勢を表すので、点から点への移動を繰り返すことは、ロボットの姿勢を次々と変えることに相当する。すなわち、マップ上でのパス（経路）は、ロボットがある運動パターンを実行することに対応する。その運動パターンの中から、望ましい外力を生み出すものを選ぶことが、ロボットの動作計画（パスプランニング）となる。このようなパスプランニングについて、マップ全体を考慮した最適解を求めることは一般に困難であるので、ここでは以下に示す評価関数を用いて、マップ上の各ポイントでの局所最適解を求めることとする。

【評価関数】

$$P I = \text{Map} + \theta \times W$$


②

ただし、Map：隣接点に移る時のマップ値（＝ τ ）

θ ：現在の点から見た目標点への方向と
隣接点への方向とのなす角

W：重み

例えば、3次元のマップの場合を考えると、前節で述べたように、マップ上の点から隣接点に向かう方向は26方向ある。そこで、パスを形成する際に、次の1ステップはこれらの中から、上記の評価関数を用いて最適な方向を選ぶ。(図表3.2-15参照)



図表3.2-15 パスプランニングの例

(3.5) 移動運動のためのパスプランニング

移動運動においては、移動体の内力を如何にして効率よく外力(ここでは移動推進力)に変換するかが問題である。一般にロボットの移動運動は、人間を含めた生物の移動運動のように、1つの運動パターンを繰り返すことによって構成されると考えられる。したがって、運動環境マップを利用して、ロボットの移動運動パターンを形成することは、マップ上で1つのループ状のパスを見つけることに対応する。すなわち、ある点から出発したパスは、再びその点に戻らなければならない。パスをループ状にするために、パスを往路と復路に分けて考える。以下に、移動運動パターンを決定するまでのパスプランニングの手順を示す。

- ①ループパスのスタート点を設定する。
- ②往路は、重み $W=0$ とする。即ち26近傍のうちでマップ値の最も大きな方向の点に移動する。これを n_1 ステップ行う。
- ③復路は、重み $W \neq 0$ とする。即ち26近傍のうちで評価関数PIの値の最も大きな方向の点に移動する。なお、評価関数における目標点はスタート点とする。このときに要するステップ数を n_2 ステップとする。

この手順において、往路ステップ数 n_1 と復路での評価関数の重み W を変化させると様

々なパスが現れる。それらのパスの中から、移動運動に最適なパスを求めるが、そのとき、次のような性能評価を用いる。

【性能評価】

$$E = \frac{1}{n} \sum_{i=1}^n M_i \quad (22)$$

ただし、 n : ループパスの全ステップ数 ($= n_1 + n_2$)

M_i : i ステップにおけるマップ値

(3.6) 運動パターンの学習

パスを見つけるための評価関数の重み W を変化させ多くの値でパスを探索することや、多くのスタート点についてパスを求めることは、実用上大変な手数が必要である。そこで、実際はいくつかの限定した値によってパスを見つけ出し、その後、より効率的なパスを発見するというような学習方式が利用できる。即ち、重み W 、スタート点、ステップ数 n_1 などを変化させたときに、性能評価値が高いものがあればそのパスを選ぶというものである。

(4) おわりに

前半で述べた学習方式については、同じ方式で力目標値を実現できること[4] やより非線形性が強い場合[5]、初期値に誤差が含まれる場合にも有効であることが示されている[6]。後半の方式を用いた移動ロボットの実験結果なども既に報告されており、実用的有効性も示されている[7]。またこの方法と類似のメモリベース制御の考え方には、AlbusのCMAC(Cerebellar Model Arithmetic Computer)[8],[9]や、KohonenのACAM(Associative Content Addressable Memory)がある[10],[11]。CMACは基本的には入出力関係をすべてメモリするものであるが、膨大なメモリ量を圧縮するためにハッシュ法を用いていることが特徴である。またACAMでは、(3.3)で述べられた方式と同様にメモリ値を学習することによって正しい値に修正する方式が用いられている。

【参考文献】

- [1] 川村貞夫, 宮崎文夫, 有本 卓「動的システムの学習的制御法(Betterment Process

の提案)」計測自動制御学会論文集 Vol.22 No.1

- [2] 川村貞夫, 宮崎文夫, 有本 卓「ロボットマニピュレータの運動学習制御」計測自動制御学会論文集 Vol.22、No4
- [3] 有本 卓, 玉城史朗, 川村貞夫, 宮崎文夫「線形時変メカニカルシステムに対する学習制御系の収束性」システムと制御、Vol. 30, No. 4「1」S
- [4] 川村貞夫, 松森正史, 松林成彰, 宮崎文夫, 有本 卓「学習による位置と力のハイブリッド制御」日本ロボット学会誌 5 巻 2 号
- [5] J.E.Hauser" Learning Control for a Class of Nonlinear System"Proc. of the 26th Conference on Decision and Control, Los Angels, CA. (December 1987).
- [6] S.Arimoto" Robustness of Learning Control for Robot Manipulators"Proc. of the 1990 IEEE International Conference on Robotics and Automation, Cincinnati, Ohio, (May 1990).
- [7] S.Kawamura and M.Nakagawa"A Biological Locomotion Model: Environment Recognition and Locomotion Strategy"Proc. of the 11th Annual International Conference of the IEEE Engineering in Medicine & Biology Society, Seattle, Washington, (November 1989).
- [8] J.S.Albus" Brains, Behavior, and Robotics" McGraw Hill, (1981).
- [9] W.T.Miller, F.H.Glanz, and L.G.Kraft" Application of a General Learning Algorithm to the Control of Robotic Manipulators"The International Journal of Robotics Research, Volume 6, Number 2, (Summer 1987).
- [10] T.Kohonen"Content-Addressable Memories" Springer-Verlag, New York (1980).
- [11] C.G.Atkenson and D.J.Reinkensmeyer"Using Associative Content-Addressable Memories To Control Robots" Proc. of the 1989 International Conference on Robotics and Automation, Scottsdale, Arizona, (May 1989).

3.2.6 大脳皮質におけるコラム形成の理論

(1) はじめに

哺乳動物の大脳皮質感覚入力系には、末梢の感覚器で受け取った外界からの信号に内在する特徴を、ある種の規則に従って皮質上の神経細胞に割り当てる、という特異的な神経投射がある。このことは感覚器の担う情報に関して一種の地図が皮質上にコラムを単位と

して構成されていることに対応する。

外界から受け取る感覚信号に内在する特徴を抽出・統合するなど、一連の情報処理過程において、このような地図構造が重要な役割を演じていることは容易に想像できる。

この地図構造は、発達におけるある特定期間（臨界期）の神経活動に依存して形成されることが知られている[1]。

(2) 理論的枠組み

機能的シナプスの形成に対して、次のような3つのメカニズムを前提として理論を展開する。

(a) 標的神経細胞の樹状突起から放出され、さらに近傍の機能的シナプスにより取り込まれた何らかの因子によって、機能的シナプスが形成される。このとき、単位時間に放出される栄養因子の量に制限があると仮定すれば、機能的シナプスの密度が高いほど一つ当たりの機能的シナプスが吸収できる量が減るため、シナプス密度に上限が設定される。

(b) 近傍の機能的シナプスにおける伝達物質の放出と、後膜における脱分極との同時生起によって、シナプスの密度は増加する。これは、神経系の可塑性にかかわる分子レベルのメカニズムとして最近注目を集めているNMDAレセプタの作用機序[2]に基づくものである。すなわち、「シナプス前終末からの伝達物質の放出とシナプス後膜の脱分極との同時生起によってそのシナプスが強化される」という局所的Hebb則である。

(c) (a)、(b)のメカニズムとは別に、自発的に機能的シナプスは形成される。これは、シナプス前側の細胞体又は近傍のグリア細胞で合成された何らかの因子が、軸索輸送によってシナプス部位まで送られ、そこでシナプスの安定化に寄与するものと考えられることができる。

上記の仮説に基づいて得られる機能的シナプスによる結合密度に対する時間発展方程式を書き下すことができ、この方程式の安定性および安定解への緩和過程を数学的に論ずることができる[3]。その安定解の性質から、自発的安定化による寄与が十分小さいときには、(a)のメカニズムによってシナプス間に競合効果が働きうる微小な領域内ではただ一種の機能的シナプスだけが生き残り、他のものは消失してしまうことが分かる。これは、いわゆるWinner-Take-Allの過程を表す。また、緩和過程に関する議論からシナプスの安定

化に要する時間が評価でき、これが、前シナプス性の因子に依存して決まることが分かる。

この平衡解は、一種のスピン変数を用いて表現できる。

さらに、入力刺激を確率変数とすれば、機能的シナプスによる結合のパターンは熱力学的平衡状態として取り扱うことが可能である[3]。

次に、上記の理論に基づいて、眼優位性コラムの形成について議論しよう[4], [5], [6]。

(3) 眼優位性コラム形成への適用

1) 眼優位性コラムのハミルトニアン

視覚一次野入力層における眼優位性コラム形成を記述するハミルトニアンを求めるためには、まず、外側膝状体神経活動に対する相関関数をモデル化する必要がある。

外側膝状体は、網膜と大脳皮質を結ぶ中継核として知られているが、ただ単に、中継核としての機能しか持たないと仮定するならば、そこでの相関関数を網膜でのそれに置き換えることは悪い近似ではないはずである。そこで、以後外側膝状体神経細胞の発火に対する相関関数としては網膜神経節細胞のそれに置き換えて考えることにする。

ここで、網膜神経節細胞の発火について幾つかの仮定をおくことによって、相関関数のモデルを得ることができる。

本来はレチノトピーの形成過程についても同時に議論すべきであるが、簡素化するため既にある程度完成しているものとする。実際レチノトピーの自由度を考慮したシミュレーションから、レチノトピーの乱れは眼優位性コラムの形成にほとんど影響を及ぼさないことが確認されている。このとき、結果的に得られる眼優位性コラムのハミルトニアンはIssingスピン s_i を用いて以下のように与えられる。

$$H = -\alpha \sum_i s_i - \frac{1-r}{2} \sum_{i,j} V_{i,j} \cdot s_i s_j$$

2) 計算機シミュレーションの結果

Metropolis のアルゴリズムに従って行った眼優位性コラムに対する計算機シミュレーション結果を要約する[6]。


① 左右眼における神経活動の相関強度(r) が小さくなるとある値を境にストライプ模様が析出してくる(図表3.2-16)。

(a)



(一様相 : $r = 0.90$, $\alpha = 0.0$)

(b)



(転移点近傍 : $r = 0.82$, $\alpha = 0.0$)

(c)




(ストライプ相 : $r = 0.40$, $\alpha = 0.0$)

図表3.2-16 眼優位性コラムの空間的模式

- ② 右目に強い視覚刺激を与え左眼に弱い刺激を与えると、右眼優位の領域の幅が広くなり左眼優位の領域の幅は狭くなる。さらに、この不均衡 (α) を大きくするとS相からB相へと一次相転移を起こし、非対称なストライプ模様からブロッグ格子模様に変化する。
- ③ 特定の波長をもって同側由来と対側由来のシナプスが棲み分けた構造を呈する秩序相

(S : ストライプ相, B : ブロップ格子相) と、特定の波長を持たない無秩序相 (U : 一様相) とが存在する (図表3.2-17)。



(S) : ストライプ相、(B) : ブロップ格子相、(U) : 一様相
 N : 正常環境, SES : 視神経の同期的電気刺激, S : 斜視, BD : 両眼性視覚奪取,
 SMD : 短期的単眼性視覚奪取, LMD : 長期的単眼性視覚奪取

図表3.2-17 眼優位性コラムの相図

3) 生理学的データとの比較

相図 (図表3.2-17) 用いて、既存の生理学的データを整理してみよう。

生まれる直前には、両眼への視覚刺激が与えられないが、網膜神経節細胞の自発発火によってストライプの形成が促されることが予想される。実際、サルにおいては母胎内で既に眼優位性コラムの周期的パターンが形成され始めているという報告がある[7]。このとき、左右眼での発火には何ら同期する理由がないので、相関強度 r は、0 と考えられる。生後は、外界からの視覚刺激によって神経節細胞の発火は同期するため、相関強度は r は 0 と 1 の間のある値をとる。ここで、 r が臨界値 r_c よりも小さければやはりストライプが形成され、大きければ特定の周期を持たない一様なパターンが得られるはずである。正常な視覚環境 (N) で飼育された動物では $0 < r < r_c$ 。という条件が満たされていることが予想される。それゆえ、眼優位性のストライプ模様が形成されるのであろう。また、Stryker[8] は、幼若ネコを用い、網膜の電氣的活動をテトロドトキシンで完全に抑えた上で次のような実験を試みた。すなわち、視交叉に電極を埋め込み、右眼由来の軸索と左目由来の軸索

とに同期した電氣的パルスを送りながら育てることによって視覚野細胞の眼優位性の発達を調べた(SBS)。その結果、ほとんどの視覚野細胞は両眼への刺激に対して同程度の応答を示した。すなわち、この実験は左右眼での相関が大きい度合いには眼優位性コラムは形成されないことを示した。このことは、理論的には $r > r_c$ と考えることによって説明できる。

動物を暗室で飼育したり、両眼の瞼を縫合して育てたりといった両眼性視覚奪取(BD)の実験[9]においては、基本的には生まれる直前の状態とほとんど同じパラメータ領域($r \sim 0, \alpha = 0$)にあると考えられ、やはりストライプが形成される。ただし、長期にわたってそのような状態におかれると、正常環境で育てた場合よりもストライプ模様は明瞭になる。このことは、人工的斜視の実験[10]および視覚奪取を施す眼球を一日おきに左右取り替える場合[11]と共通の現象であると考えられ、実験的にも両眼に応答する視覚野の細胞に著しい減少又は完全な消失があることが報告されている[12]。

短期的および長期的な単眼性視覚奪取に関して議論する場合には、シナプス形成の動的過程が関与してくるので若干注意を要する。

可塑的な期間を長期にわたり単眼性視覚奪取の状態に置いた場合(LMD)には、ストライプ模様は析出せず、一様なパターンが得られる。実際、視覚奪取されていた眼球への視覚刺激に対応する応答は著しく減少することが知られている[13], [14]。一方、パラメータ値は長期的な単眼性視覚奪取のものと同一であっても、視覚を奪取する時期が遅ければ一様な構造に変化する前に臨界期を脱してしまい、非対称なストライプの状態に取り残されることが考えられる(SMD)。

(4) おわりに

本理論の主題である「神経活動に依存した皮質地図構造の形成」という考え方にはMalsburg[15]以来の歴史があり、この考え方を発展させた形で多くのモデルが提唱されてきた。しかしながら、こういったモデルは特定の地図構造を説明できるように個別的に構築されているため、別の地図構造の形成に対してはモデルを再構築しなければならないという問題点がある。さらに、それらのモデルに現れるパラメータの生理学的な意味付けが必ずしも明らかでない。そのため、期待した構造が形成されるか否かという単純な問には答えることができて、異なる環境において形成されるべき構造の相違、又は種間における構造の相違といった問題については論じることが困難である。

このように考えると、本理論の意義は次のように要約される。

- (a) さまざまな地図構造形成を統一的な立場から説明できるような数学的枠組みを提示した。
- (b) そこに現れるパラメータは明確な生理学的意味をもつ。
- (c) 眼優位性コラムを始めとする様々な地図構造の形成が説明できる[16]。

〔参考文献〕

- [1] In: From Neuron to Brain (Kuffler, S. W. Nicholls J. G. and Martin, A. R., ed), Sinauer Associates Inc. Publishers, Sunderland, Massachusetts, 537 (1984).
- [2] Collingridge, G. L. and Bliss, T. V. : TINS 10, 288 (1987).
- [3] Tanaka, S. : to be appeared in Neural Networks.
- [4] 田中 繁 : 信学会予稿 MBE 87-153 : 385, (1988).
- [5] Tanaka, S. : The Proceeding of SICE'88 ESS 2-5:1069 (1988).
- [6] Tanaka, S. : IN: Advances in Neural Network Information Processing System (Touretzky, D. S. , ed) Morgan Kaufmann Publishers, Inc., 451 (1989).
- [7] Rakic, P. : Phil. Trans. R. Soc. Lond. B278, 245 (1977).
- [8] Stryker, M. P. : In : Developmental Neurophysiology, Jones Hopkins Preass: in press.
- [9] Wiesel, T. N. and Hubel, D. H. : J. Comp. Neurol. 158, 307 (1974).
- [10] VAN Sluyters, R. C. & Levitt, F. B. : J. Neurophysiol. 43:686, (1980).
- [11] Hubel, D. H. & Wiesel, T. N. : J. Neurophysiol. 28 : 1041, (1965).
- [12] Movshon, J. A & Van Sluyters, R. C. : Ann. Rev. Physiol. 322:477, (1981).
- [13] Hubel, D. H. & Wiesel, T. N. : J. Physiol. 206:419, (1970).
- [14] Levay, S. et al. : J. Comp. Neurol. 191:1, (1980).
- [15] Von der Malsburg, C. : Kybernetik 14:85, (1973).
- [16] 田中 繁 : 信学会予稿 MBE 88-138 : 107, (1989).

3.3 心理学・認知科学における学習・記憶

3.3.1 心理学における学習・記憶研究

(1) 学習と記憶の定義

心理学における「学習learning」と「記憶memory」の定義は、研究者間で必ずしも一致しているわけではない。また、それらの包含関係に対する理解も異なっている。しかし、伝統的かつ最も一般的な定義によれば、学習とは「経験による、比較的永続的な行動の変容」である。ここで、「経験による」ということで、「成熟」と区別し、「比較的永続的な」ということで、薬物や疲労による一時的な変化と区別をしているわけである。なお、この定義に従い、生体にとって適応上都合の良いことも悪いことも、学習に含めて考えている。一方、記憶の定義は学習に比べると、はるかにまちまちである。狭義には、記憶とは「経験を再現する機能」であり、記銘、保持、想起（再生、再認）という3つの過程に分けて考える。（なお、「記銘」のことを、狭義の「学習」ということがある。）また、広義では、「経験の影響の残存」であり、学習とはほぼ同義といってよい[1], [2], [3]。

歴史的には、行動主義の盛んであった時代（20世紀前半）には、「記憶」という主観的色彩の強い用語を避け、すべて「学習」と呼ぶようにしていた。（「言語学習verbal learning」、「機械的暗記学習rote learning」など）。このことは、ややもすれば、「学習」という用語のもとで行われる研究は、行動主義的学習理論に基づいているかのような印象を与えてしまうこととなった。そこで、1970年代の認知心理学では、学習を「知識獲得」と言い換え、外的な行動の変容より、内的な知識構造の変化が強調される傾向があった。このころの認知心理学では、「技能の習得」という要素の強い学習（「タイプライターの学習」、「自動車の運転の学習」など）にかなり限定して学習と呼んでいる。さらに最近では、認知心理学が現実的な状況を題材としてとりあげることが多くなり、学校の教科の学習のように、ごく日常的な意味での「学習」という用語が広く使われるようになってきている。

(2) 学習の分類と研究動向

人間の学習を、その機構に基づいて分類したものとして、図表3.3-1のようなガニエ[4]の階層的分類がある。これは、あくまでも条件反応を基礎と考えている点で、認知論的立場からの批判はあるが、低次から高次にいたる学習の諸相を概観する上では、分かりやす

いものといえるだろう。

図表3.3-1 ガニエの学習の分類

1. 信号学習	古典的条件づけ（信号刺激と無条件刺激の反復対提示）
2. 刺激・反応学習	道具的条件づけ（刺激に対する適切な反応を強化）
3. 運動連鎖	刺激・反応結合の単位の系列化
4. 言語連合	言語的な連合の形成
5. 弁別学習	複数の刺激に対する分化的反応の形成
6. 概念学習	カテゴリーの形成、ラベル付け、分化的反応
7. ルール学習	一般的法則や原理の獲得や具体物への適用
8. 問題解決	ルールを再生し適用することで高次のルールを構成

また、19世紀末からの科学的心理学における学習・記憶研究の動向については、図表3.3-2にまとめた。ここでは、学習・記憶研究の中で中心的であったテーマ、知覚や思考などの近接領域で学習に関連するテーマ、学習・記憶に関連する理論やモデルを併記している。

この表から、心理学における「学習観」の変化が見て取れるであろう。すなわち、20世紀前半には、強化学説（刺激・反応の連合が報酬によって強まるという考え方）に基づく、行動主義的学習研究が中心である [1]。ゲシュタルト理論やピアジェの認知発達理論のような認知論（内的な知識の体制化や操作を重視する考え方）は、存在していたものの、主流を占めるにはいたっていなかった。

20世紀後半になり、コンピュータの発達、普及にともない、人間を一種の「情報処理システム」とみなして、その内部における処理過程を明らかにしようとする認知心理学が台頭するようになる。認知心理学は、人間の情報処理のモデルを積極的に作ろうとするのが大きな特徴である。その中には、人工知能研究と影響し合いながら、コンピュータ・シミュレーションという形で、精緻なモデル化を行うものもある。また、扱う現象が、実験室的もしくは人工的な課題から、日常の現実的な課題に移ってきていることが、特にここ10年ほどの特徴である [5], [6], [7], [8], [9]。

図表3.3-2 心理学における学習・記憶研究とその近接領域の動向

年代	← 知覚 ——— 学習・記憶 ——— 思考 →	理論／モデル
1880	暗記学習	
	試行錯誤学習	
1900	古典的条件づけ	交換機モデル
	道具的条件づけ	強化理論
1920		
	洞察学習	ゲシュタルト理論
1940	弁別学習	ピアジェ理論
1950	観察学習	
	パターン認識 概念学習	特徴抽出モデル
	発見学習	L T、G P S
1960	有意味受容学習	パーセプトロン
	感覚記憶	E P A M
	短期記憶／長期記憶	貯蔵庫モデル
1970	イメージ記憶 イメージ操作	2重コード説
		処理水準説
	意味記憶	意味ネットワーク
	エピソード記憶	H A M、A C T
	文章記憶	スキーマ理論
1980	帰納的推論	連想記憶モデル
	アナロジー推論	メンタルモデル
		マラーの計算理論
		定性推論モデル
	日常的記憶・問題解決	P D P

(3) コンピュータによる学習との関連

前述したように、近年の認知心理学は、人工知能等、コンピュータによる学習の研究と密接に関連し合っている。認知心理学が台頭した頃、まず注目されたのは思考や問題解決のような高次の認知過程のシミュレーション・モデルであった。定理証明を行うLT (Logic Theorist)、パズルやゲームを解決するGPS (General Problem Solver) は、認知心理学と同時に人工知能の萌芽的研究でもある。これらのプログラムは、一般的方略による問題解決をめざすものであったが、1960年代後半から、問題解決における知識の役割が重視されるようになり、知識表現の技法 (意味ネットワーク、スキーマ、プロダクション・ルールなど) が中心的なテーマとなる [5], [7], [8]。

学習・記憶の領域では、1960年ごろ、EPAM (Elementary Perceiver and Memorizer) という暗記学習のシミュレーション・モデルが作られた [10]。これは、心理学における実験室的なデータを説明するものであり、長期記憶内の知識構造が本格的にモデル化されるのは、1960年代後半以降である [5], [6]。上述した、意味ネットワークやスキーマといった考え方は、記憶研究の中から生まれてきて、問題解決の領域にも適用されていったものと見ることができるだろう。なお、これらの記号処理的な記憶モデルの流れと異なり、分布型の「連想記憶モデル」が1970年代から研究されるようになった点も注目される [11]。

一方、知覚における学習は、パターン認識の分野で特に盛んであった。1950年代は、ボトムアップの特徴抽出を重視した考え方が主流であり、これは神経生理学的な研究とも相互に影響し合って展開された。工学的な文字認識装置も、特徴抽出の考え方に沿って作られていた。しかし、一方では文脈や経験に依存するトップダウン的な処理の重要性も指摘されており、知覚においても経験的知識の役割が重視された [12]。なお、やはりこのころ、知覚学習を行う並列分散型モデルとして「パーセプトロン」が提案されている [13]。その後、1970年代にも神経回路をモデル化した並列処理の工学的研究が継続されるわけであるが、これらは心理学とは直接の関連をもっていなかった。1980年代になって「PDP (Parallel Distributed Processing) モデル」として、再び心理学者が大きくとりあげるようになり、知覚以外の領域をも巻き込みながら、現在の「コネクショニズム」、「ニューラルネット」の学際的研究の流れに合流したといえるだろう [14], [15], [16]。

[参考文献]

- [1] 本吉良二 (編) 講座心理学 6 学習 東京大学出版会 (1968)

- [2] 梅本堯夫(編)講座心理学7 記憶 東京大学出版会(1969)
- [3] 梶田正巳・太田信夫(編)学習心理学 福村出版(1985)
- [4] Gagne, R.M. The Conditions of Learning. 吉本二郎・藤田統(訳)学習の条件文
理書院(1965)
- [5] Anderson, J.R. Cognitive Psychology and Its Implication, 富田達彦他(訳)
認知心理学概論 誠信書房(1980)
- [6] 小谷津孝明(編)認知心理学講座2 記憶と知識 東京大学出版会(1985)
- [7] 波多野誼余夫(編)認知心理学講座4 学習と発達 東京大学出版会(1982)
- [8] 市川伸一・伊東裕司(編). 認知心理学を知る<第2版> ブレーン出版(1989)
- [9] Neisser, U. (Ed.) Memory Observed. 富田達彦(訳)観察された記憶誠信書房(1982)
- [10] Feigenbaum, E.A. & Feldman, J. (Eds.) Computers and Thought. McGraw-Hill,
(1963)
- [11] Kohonen, T. Associative Memory: A System-Analytical Analysis. 中谷和夫(訳)
システム論的連想記憶(1977)
- [12] Lindsey, P.H. & Norman, D.A. Human Information Processing. 中溝幸夫他(訳)
情報処理心理学入門I サイエンス社(1977)
- [13] Rosenblatt, F. Principles of Neurodynamics. New York: Spartan. (1962)
- [14] Rumelhart, D.E. & McClelland, J.L. (Eds.) Parallel Distributed
Processing: Explorations in the Microstructure of Cognition. Vol. 1-2.
甘利俊一(監訳)PDPモデル——認知科学とニュー論回路網の探索——産業図書(1986)
- [15] 麻生秀樹 ニューラルネットワーク情報処理——コネクショニズム入門、あるいは
柔らかな記号に向けて——産業図書(1988)
- [16] 甘利俊一 神経回路網モデルとコネクショニズム 東京大学出版会(1989)

3.3.2 学習の認知科学的研究 —PDPモデル—

(1) PDP モデル

知識表現には、知識を局所的な情報で表す記号的表現(局所表現)と、多数のノードとリンクの上に分散した情報で表す分散表現とがある。分散表現では、多くの場合、ノードやリンクに関する計算を並列的に行うことができる。また、この並列計算を、適切なパラメータを見い出すための学習に利用できる場合が多い。このような、知識の分散表現を用

い、学習並列計算を行うような知識表現のモデルを、PDP モデル(Parallel Distributed Processing models)という。PDP モデルは、一般的な名称というよりは、米国カリフォルニア大学サンディエゴ校において、David Rumelhart、Gooffrey Hinton、Jay McClelland、Donald Norman 及びその同僚たちのグループによって、1970年代の後半から考案されてきた、上のような特徴を持つ知識表現モデルの呼称であるが、現在では、心理学的な目的のための神経回路網類似モデルの総称としても通用するくらい有名な用語になっている。

学習の認知科学的研究としては、記号処理モデルによるものもあるが、PDP モデルのような並列分散処理モデルによる研究は、工学的にも超並列・超分散処理と密接に関係がありきわめて重要であると考えられるので、ここではPDPモデルに絞って述べる。

(2) PDP モデルの特徴

ここでは、PDP モデルの持つ重要な特徴であるGraceful Degradation、並列分散処理、及び学習について述べる。

(2.1) Graceful Degradation

知識表現の研究は1960～70年代に多く行われ、プロダクションルール、意味ネットワーク、フレーム表現などの成果が得られた。これらの表現法は、記号処理システムに合った表現法として用いられ、認知心理学だけでなく人工知能技術に対しても多くの応用が試みられた。

しかし、これらの記号的表現には、意味の「硬さ」という難点があった。例えば意味ネットワークにおいては、「リンゴ」という概念の意味は、“リンゴ”ノードとそれに結合しているリンク及び他のノードとトポロジーで決まる。このとき、そのうちの一つのリンクがなくなっただけで、「リンゴ」の意味は大きく変わってしまう。このように、記号的表現には、その意味が、記号の置かれている状況が変わるとガタッと変化してしまうという「硬さ」がある。

記号の表現のこのような難点を克服するには、分散的表現を用いればよい。つまり、多くのノードやリンクに意味を「分散」させ、その全体によって、ある概念を表現すればよい。このことは、例えばあるネットワークNの各ノードやリンクに数値パラメータを対応させ、それらのパラメータに対して、特定の数値を並べたベクトルごとに一つの概念を対応させれば、いろいろな概念の「分散表現」を、N上に表現することができる。このような

応させれば、いろいろな概念の「分散表現」を、N上に表現することができる。このような表現法では、数値が少し違っても、ある意味で「似たような」概念を表現することができる。分散表現のこのような特徴を、Graceful Degradationという。Graceful Degradationは、工学的にみても、fault tolerantな知的機械を持つべき重要な性質であり、PDPモデルもこの性質を有する。

(2.2) 並列分散処理

分散表現による計算モデルでは、記号的表現に比べて並列計算がしやすいアルゴリズムで構成することができる。特に、各ノードに対して一つのプロセッサを割り当てることができる。それらのプロセッサを並列的に動かす超並列計算アルゴリズムを定式化することができる。そして、このようなアルゴリズムを実行する超並列計算機が作られれば、分散表現モデルを高速に実行することが可能になる。

(2.3) 学習

外界からはどのような情報が得られるか前もっては分からない。従って、どのような状況にも対応できるような知識を前もって完全な形で表現しておくのは困難であり、表現の「学習」が必要である。このことは、記号的表現にも分散表現にも言えるが、分散表現では、Graceful Degradationと並列分散処理の両方の特性を保ちつつ学習が行える点で、記号的表現よりも優れている。

(2.4) 記憶

PDPモデルは知識表現の分散モデルであるから、記憶のモデルと密接な関係がある。現在は、分散記憶のモデルが神経科学的な立場から考えられているが、今後認知科学における記憶のモデルとの融合が重要になると考えられる。

(3) 研究の動向

(3.1) 学習アルゴリズム

既に示したような特徴をもつ知識表現モデルを構成するには、Graceful Degradationと並列分散処理の特徴を持った学習アルゴリズムが必要である。このようなアルゴリズムとして最近最もよく研究されたのは、誤差逆伝播学習アルゴリズム(Backpropagation error

learning algorithm) である。誤差逆伝播学習アルゴリズムは、フィードバックを持たない階層型ネットワークに対して、理想出力値と実際の出力値の誤差が最小になるようにリンクの重みパラメータを決めるアルゴリズムであり、局所的最小値に収束することが証明できる。1960年代の甘利俊一教授の定式化と収束証明を経て、1980年代にDavid Rumelhartらによって認知科学の諸問題への応用を目指した研究が行われ、実際には大域的最小値に収束する場合が多いことが示された。その後、計算効率の改良が世界的に進められ、時間遅れ項や粘性項の導入が効果を持つことが分かってきている。

一方、確率的環境で動く学習アルゴリズムとして、ボルツマンマシン (Boltzmann Machines) がGeoffrey Hinton らによって開発された。ボルツマンマシンのアルゴリズムでは、理想出力値の確率分布と実際の出力値の確率分布の違いがある意味で局所的に最小になるようなリンクのパラメータを決定することができる。このようなパラメータ値は、ネットワークを n 個の粒子からなる統計熱力学的な系とみなしたとき、状態エネルギーに関するマックスウェル-ボルツマン分布の平衡状態分布を与える。このためボルツマンマシンの名がある。アルゴリズムは大域的最小値を保証していないが、模擬焼きなまし (simulated annealing) の手法を応用すると、大域的最小値に収束させることが理論的には可能になる。このため、模擬焼きなましのための効率的な手法が、ボルツマンマシンの研究とともに発展している。

上にあげた誤差逆伝播学習やボルツマンマシンのアルゴリズムは教師あり学習アルゴリズムであるが、教師信号のない場合の学習アルゴリズムとして、競合学習のアルゴリズムが研究されている。競合学習では、ネットワークのノードをクラスタに分け、一つのクラスタ内の各ノード間には抑制性の結合があるとし、また一つのクラスタからは最大値検出のような競合的な方法で一つのノードだけから出力が出るものとする。このようなネットワークにおける学習アルゴリズムを考えると、教師信号なしで入力信号のクラスタ化を行うことができる。競合学習のアルゴリズムとして著名なものには、福島らのネオコグニロンがある。

(3.2) 最近の動向

認知科学においては、例えば文書の理解のように、並列処理だけでなく逐次的に入力される情報の処理も重要である。上に述べたようなPDPモデルを逐次処理に用いることができることを示すには、時系列信号を受理するオートマトンのような能力をモデルが持てる

かどうかを調べればよい。実際、PDPモデルによって時系列信号を識別する研究が最近多く行われており、gradedな処理の行える特別なオートマトンの能力を持つPDPモデルがMcClellandらによって報告されている。

また、このような方向の研究として、文法の学習だけでなく、ロボットの行動計画の学習なども研究されており、その中から、フィードバック結合を持つ階層型ネットワークによる学習モデルとして、Michael Jordanらのplan nodeを持つモデルが提案されている。さらに、隠れノード(hidden unit)の表現のコピーを文脈ノード(context unit)によって持てるようにしたElmanのモデルもある。このElmanモデルは収束性がよく、McClellandらのオートマトンの学習にも応用されている。

一方、認知科学における複雑な認識情報処理においては、幾つものPDPモデルが統合されたモデルを考える必要がある。このような複合モデルは、一つのモデルが一つの機能を分担した機能局在モデルとなるが、神経科学においても多くの知見が得られているように、視覚系、運動系、その他多くの認知系は局在化した機能が複雑に働く系であり、複合的なPDPモデルを考えることはきわめて重要と考えられる。現在、このような研究としては、制御のモデル、視覚系のモデルなどが研究されている。

最後に、最近連想記憶のモデルに関して多くの新しい成果が得られている。特に、与えられたノードの数に対して、記憶できる情報の数をアトラクタの数を推定することによって推定する研究が進んでいる。このような研究はまだ認知情報処理とはあまり結びついていないが、今後の重要な方向であると考えられる。

3.4 神経科学・遺伝における学習・記憶

3.4.1 神経生理学における学習・記憶の研究

(1) 3つの戦略


我々が体験によって認識や行動を変化させる「学習」が、脳のどこでどのように起こり、学習によって獲得された情報「記憶」はどこにどのように蓄えられているかという問いは、脳の機能のなかで最も興味深いものの一つである。学習と記憶の神経メカニズムに関する研究には長いチャレンジと挫折の歴史があったが、過去10数年間に目覚ましい発展が見られた。第1は、動物を用いた幾つかの学習モデル標本が開発され、学習・記憶を担う神経部位と学習・記憶の成否に対応した神経活動が記録されたことである（この研究の詳細に

については3.4.2項を参照)。第2は、神経回路網の伝達特性を変化させるシナプス(ニューロンとニューロンのつなぎ目)の可塑性について、細胞レベルから分子レベルに至る研究が著しく発展したことである。この研究は脳辺縁系の海馬でのシナプス伝達の長期増強を対象としたものが世界的に最も良く解析されている(詳しくは3.4.3項を参照)。第3は、単純な神経回路をによって学習を再現させ、学習・記憶部位を同定し、その細胞レベル・分子レベルの解析に至る研究があげられる。ここでは、第3の研究の戦略と成果について報告する。

(2) 単純神経回路を用いた学習・記憶の研究

KandelとSpencerは、1968年「学習の細胞生理学的アプローチ」のなかで、2つのアプローチを提唱した[1]。1つは、実験材料に神経回路の単純な軟体動物を選び、微小技術を駆使して定量的に可塑性の問題を扱おうというものであり、もう1つは、可塑性シナプスが豊富に存在する高等動物の高次中枢の特定シナプスを詳細に研究して、シナプスの可塑的变化を検出しようというものである。Kandel自身は前者の戦略をとった。彼らは海産軟体動物のアメフラシを用いて、侵害反射である「えら(または水口)引っ込め反射」の感作(sensitization)について調べた。この反射は感覚ニューロンと運動ニューロンの2ニューロン群からなる。頭部又は尾部からのニューロンが2ニューロン間のシナプスの上にシナプスを作り(synapse on synapse)、頭部又は尾部の刺激(促通刺激)により感覚ニューロン-運動ニューロン間のシナプス伝達が促進される。1回の促通刺激によって起こる短期感作(short-term sensitization)は、促通ニューロンから放出されるセロトニンが感覚ニューロンのシナプス終末部のカリウムチャンネルを閉じ、その結果カルシウムがより多く終末部に流入して、伝達物質の放出量が増えることによって起こるとされている。ここ数年の彼らの研究で注目されるものは、この感作現象が感覚ニューロンと運動ニューロンの培養標本(co-culture preparation)で再現されたことと、長期感作のメカニズムの解析である。培養標本では培養液にセロトニンを1回与えると、感覚ニューロンの活動電位が短期間(～数分間)増大し、シナプス伝達が増強(短期感作)される。更に興味深いことに、5回セロトニンを与えると、24時間後にもシナプス伝達の増強が保たれる(長期感作)。この長期感作の成立には、セロトニン投与後数時間におけるタンパク質合成が必要であり(図表3.4-1:[2])、ニューロンの構造変化を伴うことが明らかになった。すなわち、感覚ニューロンが運動ニューロンに沿ってシナプス終末に相当するバリコシティ構

造を作って伸長するのである。この構造変化は全動物標本でも報告された（図表3.4-2 : [3], [4]）。数週間続く長期感作に対応して、感覚ニューロン終末構造に変化が見い出された。




図表3.4-1

アメフラシの感覚ニューロンと運動ニューロンの共培養標本における長期増強[2]

セロトニンを培養液中に5回与えると、感覚ニューロンから運動ニューロンへのシナプス伝達が24時間以上増強される。

- A : セロトニン(5-HT)と蛋白合成阻害剤(Anisomycin, Emetine, Actinom-D, α -Amanitin)を与えるタイミング。
- B : セロトニンを5回(5X 5-HT) 与えると、感覚ニューロン(LE)を刺激したとき運動ニューロン(L7)で記録されるシナプス電位が24時間後にも増大している。セロトニンを1回与えた場合(1X 5-HT) やコントロール(Control) では24時間後の増大はない。
- C : セロトニンと同時に蛋白合成阻害剤を加えると長期増強は阻害される。



図表3.4-2 アメフラシの長期感作における感覚ニューロンの形態変化

4日または10日間感作刺激を与えるとその後数週間えらまたは水口の引き込め反射が長期増強されるが、これに対応して感覚ニューロンのバリコシティはコントロールの2倍にニューロン分枝の長さは3倍になる[3], [4]。

(3) 学習・記憶におけるシナプス新生

シナプス結合の構造変化は、過去には多くの場合、高等哺乳動物の脳の損傷を補償する機構としてとらえられていた。典型的なものは、脳損傷後に生き残ったニューロンの軸索から側枝が発芽(sprouting)し、新たなシナプスを作るというものである。中枢神経系では、中脳の赤核での側枝発芽・シナプス新生が最も系統的に調べられている。赤核ニューロンには大脳皮質と小脳核より入力がありそれぞれ樹状突起と細胞体にシナプス結合するが、小脳核破壊後に大脳-赤核線維が発芽して新たなシナプスを赤核ニューロンの細胞体近傍に形成する。この大脳-赤核シナプスの新生は、学習に伴っても起こることが示された。小田らは、赤核を介して起こる前肢屈曲応答の古典的条件付け(図表3.4-3:[5])に

において、条件付けの部位は脳-赤核シナプス部であり、脳-赤核シナプスによるシナプス電位の形状変化から、脳-赤核シナプスが赤核ニューロンの細胞体及びその近傍に新たに形成されたことを見いだした(図表3.4-4、図表3.4-5 : [6])。この結果は、電子顕微鏡像を用いた形態学的研究によっても確認された[7]。Purvesらはニューロンの樹状突起とシナプスの形態が、外から一切操作を与えなくても生体内で一種のターンオーバーとして変化していることを報告している(図表3.4-6 : [8], [9])。彼らはラットの末梢神経節ニューロンの形態をを数カ月にわたって観察する顕微鏡システムを開発し、ニューロンの樹状突起の形状とシナプスの分布が週のオーダーで変化していることを見出した。生体内で自然に起こっているこのようなシナプスの形態変化は特に長期間維持される記憶のメカニズムとして注目される。今後はレーザー顕微鏡などの光学記録系の発達によって新たな事実が発見されるであろう。




図3.4-3 ネコの赤核を介する古典的条件付け[5]

- A : 脳-赤核線維の刺激を条件刺激(CS)とし、前肢の皮膚刺激(無条件刺激: US)と1週間組み合わせると前肢の屈曲応答が条件付けられる。
- B : 条件応答の主要経路を脳-赤核脊髄路に限定する目的で、皮質遠心路を赤核の尾側で切断した。
- C : CSの100ミリ秒後にUSを組み合わせるとき(Paired)条件付けは成立。CSのみ与えたり(CS alone)、2つをランダムな間隔で組み合わせても(Random)、条件付けは成立しない。




図3.4-4 古典的條件付けにおける赤核ニューロンの発火応答の変化[6]

Paired (A)、Random (B)、CS alone (C) の訓練を1週間行った後の、条件刺激 (大脳-赤核線維の刺激; 矢印) に対する赤核ニューロンの発火応答の例。D: 条件刺激後11ミリ秒間の発火頻度 (全記録細胞の平均) はPaired群が有意に高い。




図3.4-5 古典的條件付けによる大脳-赤核シナプス電位(EPSP)の形状変化[6]

- A: 正常ネコでは大脳皮質からの線維は赤核ニューロンの遠位樹状突起上にシナプス結合するため、大脳-赤核EPSPは立ち上がり時間の長い形をしているが、組合せ条件付け(Paired)をしたネコでは大脳-赤核EPSPに立ち上がり時間の短い成分が重畳する。
- B: 条件付けをしない(Naive) ネコでは正常ネコと同様長い立ち上がり時間を持つEPSPが記録される。
- C、D: 大脳-赤核EPSPの立ち上がり時間。C: Paired、D: Naive。




図3.4-6 マウス上頸神経節ニューロンの樹状突起の形態変化[8], [9]

同一のニューロンに数日～数カ月の間隔をあけて蛍光物質を注入し形態を比較する。
2～3週間で樹状突起の一部に伸展・縮退がみられ、1～3カ月間にその差は顕著になる。

(4) 小脳制御系におけるシナプス可塑性

伊藤らは小脳皮質のシナプスの可塑性について研究を行っている。彼らは小脳皮質に関するMarr and Albusの数理モデルをもとに、前庭動眼反射の適応制御における小脳皮質の重要性を示し、可塑的变化部位が小脳皮質の平行線維とプルキンエ細胞間のシナプスに起こることを見出した。彼らの発見した変化は、平行線維－プルキンエ細胞間のシナプスと苔状線維－プルキンエ細胞間のシナプスの活動が重なったとき、平行線維－プルキンエ細胞間のシナプス伝達が長期間（実験では数時間）減弱するという長期抑圧（Long-term Depression）である（図表3.4-7 : [10], [11]）。平行線維－プルキンエ細胞間の伝達物質候補はグルタミン酸であり、キイカル酸型の受容器がこの可塑性の発現に寄与することが示されている（図表3.4-8 : [12]）。この系では、プルキンエ細胞に入力する2つの興奮性シナプス間で異シナプス性に変化が起こることと、変化の方向が脳－赤核シナプスや脳辺縁系の海馬体シナプスの場合とは逆になっている点が興味に深い。可塑的变化の差が各々の部位の可塑的機能の差を反映していると考えられることもできる。




図3.4-7 小脳皮質プルキンエ細胞における長期抑圧[10], [11]

A : 平行線維と登上線維の刺激（4Hz, 25ミリ秒間）を組み合わせると、平行線維によるシナプス電位(EPSP)の振幅が長期間減少する（数字は図Bの各時点に対応する）。
B : 長期抑圧の時間経過。




図3.4-8 プルキンエ細胞での長期抑圧におけるキスカル酸型

グルタミン酸受容体の寄与[12]

平行線維刺激の代わりにグルタミン酸やそのアゴニストの1つであるキスカル酸を与え、これと登上線維の刺激を組み合わせると、平行線維-プルキンエ細胞間のシナプス伝達が長期間抑圧される。

(5) 今後の課題と提言

以上のように、限定された神経回路によって学習が再現されその変化部位と学習に伴う可塑的变化の実態が幾つかの系で明らかにされた。今後ほかの学習・記憶標本が開発され、それらの共通点と系における特異性（大脳と小脳の差など）が議論されるであろう。また、解析が進んでいない学習・記憶の一例に、非常に著しい現れ方をする刷り込み(imprinting)がある。水鳥のヒナが孵化直後に見たものを終生追いかけるというもので、これは学習の感受性期あるいは臨界期というべきものが存在すると解釈でき、生体の各発達段階における学習・記憶の質的な差を研究する上で重要な標本であろう。

ここまでの研究は、学習が脳システムを形成する1つのニューロンや1ヶ所のシナプスの機能的変化にとらえられるという立場でなされてきたものである。今後は各要素で見出された可塑性が限定された神経系におよび脳全体の機能に実際どの様な寄与をしているかを明らかにせねばならないであろう。

[参考文献]

- [1] Kandel, E.R. and Spencer, W.A. : Cellular neurophysiological approaches in the study of learning, *Physiol. Rev.*, 48, 65-134 (1968)
- [2] Montarolo, P.G., Goebel, P., Castellucci, V.F., Morgan, J., Kandel, E.R. and Schacher, S. : A critical period for macromolecular synthesis in long-term

- heterosynaptic facilitation in *Aplysia*, *Science*, 234, 1249-1254 (1986)
- [3] Bailey, C.H. and Chen, M. : Long-term memory in *Aplysia* modulates the total number of varicosities of single identified sensory neurons, *Proc. Natl. Acad. Sci. USA*, 85, 2373-2377 (1988)
- [4] Bailey, C. and Chen, M. : Time course of structural change at identified sensory neuron synapses during long-term sensitization in *Aplysia*, *J. Neurosci.* 9, 1774-1780 (1989)
- [5] Tsukahara, N., Oda, Y. and Notsu, T. : Classical conditioning mediated by the red nucleus in the cat, *J. Neurosci.* 1, 72-79 (1981)
- [6] Oda, Y., Ito, M., Kishida, H. and Tsukahara, N. : Formation of new corticorubral synapses as a possible mechanism for classical conditioning mediated by the red nucleus in cat, *J. Physiol., Paris*, 83, 207-216 (1988)
- [7] Murakami, F., Higashi, S., Katsumaru, H. and Oda, Y. : Formation of new corticorubral synapses as a mechanism for classical conditioning in the cat, *Brain Res.*, 437, 379-382 (1987)
- [8] Purves, D., Hadley, R.D. and Voyvodic, J.T. : Dynamic change in the dendritic geometry of individual neurons visualized over periods of up to three months in the superior cervical ganglion of living mice, *J. Neurosci.*, 6, 1051-1060 (1986)
- [9] Purves, D., Voyvodic, J.T., Magrassi, L. and Yawo, H. : Nerve terminal remodeling visualized in living mice by repeated examination of the same neuron, *Science*, 238, 1122-1126 (1987)
- [10] Ekerot, C.-F. and Kano, M. : Long-term depression of parallel fiber synapses following stimulation of climbing fibers, *Brain Res.*, 342, 357-360 (1985)
- [11] Sakurai, M. : Synaptic modification of parallel fiber-Purkinje cell transmission in *in vitro* guinea-pig cerebellar slices, *J. Physiol.*, 394, 463-480 (1987)
- [12] Kano, M. and Kato, M. : Quisqualate receptors are specifically involved in cerebellar synaptic plasticity, *Nature*, 325, 276-279 (1987)

3.4.2 大脳側頭葉における認知記憶・学習

ヒトの認知記憶はほとんど無限の容量を持っている。連想をたどって瞬時に過去の経験を読み出すことができる。しかし極めて忘れっぽいこともまた事実である。これらは我々が日常生活の中で繰り返し経験していることであり、また番地(address)貯蔵方式の現在のコンピュータ記憶には及びもつかない能力でもある。では記憶は脳の 10^{10} 以上ものニューロンのどれにどのようにして蓄えられるのだろうか？そしてメモリーニューロンのどのような性質によって連想が可能になるのだろうか？ここでは図形についての視覚記憶を例にとり、記憶・学習における大脳側頭葉の機能について報告する。

(1) 記憶の座はどこにある？

「記憶は脳のどこに蓄えられるのか」との素朴な問いの歴史は古い——中世の「精神＝霊気」説でも、大脳の3つの脳室のうち一番後ろの脳室に記憶を司る霊気が蓄えられると考えられた程に。しかし今世紀中途、ラシュレイ(Lashley)の集団作用則(mass action law)では「記憶痕跡は脳内のどこにも存在しない、脳の全てのニューロンの活動パターン以外には」との全体論が主張される。しかしその後、ヒトの知的機能全般とはある程度独立した認知記憶システムが脳内に存在し、側頭葉がことに重要な役割を果たしていることが解ってきた。以下(1-1)、(1-2)参照)に述べる2つの重要な臨床観察がこの記憶システムの局在論的構造を明らかにするキーストーンとなった。

視覚記憶システムにおいて、大脳一次視覚野に入力した視覚信号は次の視覚前野の 10 以上のサブフィールドで情報の異なった側面について処理を受ける——例えば、直線運動ならMT野、回転運動ならMST野、色の恒常性ならV4野等々。下側頭回では、視覚前野で分析された各属性が対象物に特有の構成に再合成されるとともに、その対象物の記憶表現のニューロンアンサンブル(D. O. Hebbの意味で)として貯蔵されると仮定されている。この下側頭回と海馬、そしてこの2つの部位の相互作用にこそ、並列・分散処理系としてのヒト認知記憶系の秘密がある。超並列・超分散システムとしての将来のニューロコンピュータ設計には、この相互作用の解明が必須である。

(1-1) 大脳側頭葉皮質における視覚記憶痕跡の局在

第一の臨床実験は、視覚記憶痕跡が大脳側頭葉皮質に局在することを示唆するペンフィールド(Penfield)の研究である。1963年に発表された論文[1] (The brain's record of

auditory and visual experience との表題が冠されている) には、脳外科手術時に大脳皮質に加えた電気刺激が、局所麻酔下覚醒状態の被験者に、過去の視覚・聴覚体験を想起させた40余りの事例が要約されている。刺激部位によって想起される経験 (experiential response) は異なっており、視覚体験が起こる部位と聴覚体験が起こる部位にははっきりした分布の違いがある。さらに側頭葉刺激520例中40例でexperiential response が観察されているが、他の大脳皮質領域刺激 612例においては一例も観察されていない。こうした事実からペンフィールドは、ヒトでは視覚経験は大脳皮質側頭葉ニューロン群に貯えられ、その意識上への想起はこのニューロン群の電気的活性化によってもたらされる、と結論している。被験者の内的想起体験を言語化して報告させる研究方法では、記憶の体制化・再構成による変容が不可避であるとはいえ、側頭葉における視覚記憶貯蔵庫 (memory storehouse) 局在仮説を示唆するには十分である。

(1-2) 海馬と前向性健忘

第二は、大脳辺縁系ことに海馬の損傷が、計算力や判断力といった知的能力をあまり損なうことなしに、新しい情報を学習・貯蔵する働きの障害 (前向性健忘) のみを引き起こす事実の発見である。スコヴィル (Scoville) とミルナー (Milner) によって報告された患者 H. M. では [2]、重度の癲癇治療の為に海馬を含む内側側頭葉の手術を受けた後、会った人の顔——主治医すら——やトイレに行く道順も含めてその日その日の出来事を全く覚えられなくなってしまった。ウェクスラーの知能指数は 112 であり、言語機能検査・5～7 けたの数字系列の復唱容量で示される即時記憶検査の結果は正常であった。ゾラモルガン (Zola-Morgan) 等によって報告された患者 R. B. では [3]、全身虚血によって海馬 CA1 領域にほぼ限局した細胞の脱落を受けたところ、類似の前向性全健忘を起こした。H. M. でも R. B. でも、海馬損傷を受ける以前に起こった出来事の記憶の喪失 (逆行性健忘) の範囲は約 1 年ほどに限定されていた。こうした一連の事実は、海馬自身が記憶貯蔵庫ではないが、海馬と密接な神経結合を有する大脳側頭葉皮質部位にこそ「メモリーニューロン」を求めるべきことを教えている。

(2) サルの視覚記憶をテストする

日常の経験からの干渉を排除した中立な記憶対象を用意するのが実験の第一歩である。ヒトの言語的記憶を調べるのにはアルファベットをランダムに並べた「無意味綴り」が用いられる。視覚記憶をテストするために、フラクタルアルゴリズムを応用してコンピュー

タにより人工的図形を多数作り出した（図表3.4-9の例を参照）。これらのフラクタルパターンをサルが覚えている時の、下部側頭葉皮質ニューロンの反応を解析する。微小電極（先端の長さ5 μm 以下、先端直径1～2 μm 位の金属針電極）を用いることによって、大脳皮質の単一ニューロンの活動を記録することができる。サルにフラクタルパターンを記憶させるために、遅延見本合わせ(delayed matching-to-sample)課題を用いる[4]。この課題では、サルがレバーを引くと各々の試行が開始され、眼前30cmにあるテレビモニタに一つのフラクタルパターンが0.2秒間提示される（見本図形）。見本図形はすぐに消え、16秒の遅延期間の後、0.2秒間比較図形がモニタ上に提示される。見本図形と比較図形が同一であるか異なっているか、正しく答えると報酬のフルーツジュースがもらえる。サルが正解するためには、遅延期間の間、見本図形を頭の中で覚えていなくてはならないわけである。フラクタルパターンは無数に作り出すことができるが、課題のトレーニングには各々のサルに100枚のフラクタルパターンを定めて、サルがこれらのフラクタルパターンを長期記憶に蓄えるようにした（ちょうど日本人が「あいうえお48文字」を習って長期記憶に蓄えるのと同じように）。

(3) 下部側頭回の図形記憶ニューロン

遅延見本合わせ課題遂行中のサル下部側頭回に、サルがある特定のフラクタルパターンを頭の中にイメージしているときにだけ活発に活動するニューロンが発見された[4]。具体的な記憶内容は、このニューロンの図形選択性に表現されている。下部側頭回の異なるニューロンでは最適図形は各々異なっており、記録された約100個のニューロンの最適図形全体では、テストされた100枚のフラクタル図形すべてをカバーしていた。これらのニューロンは、各フラクタルパターンを単純に一对一でコードしているわけではない。つまり、いわゆる「お婆さん細胞grandmother cell」ではない（「お婆さん細胞説」とは、「X氏のお婆さん」のような個々の概念が、脳の中では一つのニューロンによって表現されるとのモデルであり、概念表現が多数のニューロン群の活動パターン全体に分散されとの考えと対立する）。分散コードの例として、最近「スパースな相関型連想記憶モデル」が提案されている[5]。スパース符号化とは、 n 個の要素のうち活性化されている要素が $\log n$ 程度で、あとの要素が不活性状態をとる符号化方式である。この方式の情報容量は、ほぼ n^2 に比例し、スパースでない場合は約0.15 n であるのに比べて、非常に効率のよい符号化であることが分かる。

では、このニューロン群は図形のどのような属性をコードしているのだろうか。各々の原図形に変換を施して、反応の不変性を調べるのが一つの方法である。例えば、大脳視覚一次野の複雑型細胞(complex cell)は、刺激線分の受容野上の位置の変化に対して反応を不変に保つが、線分の向きの変化に対しては高い選択性を示すことで特徴づけられる。この記憶ニューロン群の図形選択性に対して、次の4つの変換の影響が調べられた。

- (a) 大きさを変える
- (b) 図形を90度回転する
- (c) 色情報を捨ててモノクロにする
- (d) ビデオモニタ上の提示位置を変える

実験の結果によれば、TE野ニューロンでは、サルが見本図形を覚えている遅延期間におけるニューロン活動は、このような変換の影響をほとんど受けない。このニューロン群がコードしているのは、大きさ・向き・色・位置などの物理的属性に依存しない抽象化された「形の概念」とでも言うべきものである、と考えられるのである。

(4) ニューロンの図形選択性は学習によって獲得される

ここで、刺激として用いたフラクタルパターンが、数学的アルゴリズムで生成され、実験以前にはサルが見たことのない図形であることを思い出していただきたい。これらのニューロンは、実験以前から脳の中に存在して、いつか使われるのを待っていたのだろうか(仮説A)。それとも、実験の中でサルが学習したフラクタルパターンの記憶が、これらのニューロンの図形選択性によって表現されているのだろうか(仮説B)。こうした疑問に実験的に答えることができる[6]。もし仮説Aが正しいとすれば、脳の中には一生の間に出会うであろうほとんどすべての「形」に対応するニューロンが遺伝的に用意されていることになる。その場合には、これらのニューロンに対する最適図形は様々であっても、一つのニューロンをとればbestとsecond bestのパターンは幾何学的に類似しているはずである。多くのニューロンでは100枚のうち2、3枚の図形に対してのみ強い遅延発火を示す。この2枚の最適図形は幾何学的に類似しているだろうか。図表3.4-9に、6個のニューロンに対する最適図形2枚を示した。少なくともこれらのニューロンでは、最適図形は相互に幾何学的に似ていない。これは仮説Aに反する証拠である。

逆にもし仮説Bが正しいとすれば、実験的にテスト可能などんな予言が引き出せるだろうか。




図3.4-9 メモリニューロンの反応選択性は学習に依存している

A-Fの6個のニューロンの各々で、一番及び二番目に強い遅延期の活動を引き起こしたフラクタルパターンが示されている。各ニューロンで二つの最適図形は幾何学的には似ていない。

(5) 連想記憶のニューロン表現

ヒトの長期記憶では、概念やイメージは学習によって獲得された連想関係で互いに結び合わされている。知識を構成する意味ネットワーク (semantic network) 構造もこうした連想関係を基礎にして成立すると考えられる。では図表3.4-9のような各単一ニューロンの最適フラクタルパターン群が、こうした意味的連想関係をコードしている可能性があるだろうか。

上記仮説Bをこうした観点からさらに積極的にテストするために、訓練期間中に 100枚のフラクタルパターンを一定の順序で提示し、サルにパターン間の連合関係を学習させた。下部側頭葉ニューロンの活動を微小電極で記録するときには、これらのパターンをランダムに提示する。もし仮説Bが正しければ、訓練期間中に覚えた連合関係がニューロンの反応に反映されるはずである。図表3.4-10a, b は二つのニューロンで訓練期間中のパターンの順序を横軸に取り、各パターンを見本図形としたときの遅延期間の平均発火頻度を縦軸にプロットしたものである。記録時にはパターンを横軸の順序とは無関係に提示したにもかかわらず、最適図形群が訓練期間中に覚えた順序関係に沿って集まっていることが分か

る。記録したニューロン全体でもこの傾向は明らかである（図表3.4-10c）。つまり、これらのニューロンは、図形パターン間の学習した連合関係を反応特性として刻印しており、図形についての長期連想記憶がこれらのニューロンに蓄えられている可能性がきわめて高いと考えられる。その記憶が想起されるときにはこれらのニューロンが活性化され、個々のニューロンにコードされた連想関係を並列処理的に辿ることによって、現在のコンピュータには及びもつかない柔軟かつ高速の記憶読み出しが可能になるのであろう。




図3.4-10 学習されたフラクタルパターン同士の刺激-刺激連合

- a ; 記録時の遅延発火頻度（縦軸）と、学習時に提示された順序(serial position number : SPN) の関係。ドット印は、刺激-刺激連合を学習した 100枚のパターン、黒は新しい未経験の 100枚のパターンに対する反応。
- b ; a と同様にして別のニューロンから得られたデータ。
- c ; SPN に沿って計算した遅延発火の自己相関関数。
 - ▲ ; 刺激-刺激連合を学習した 100枚のパターンに対する自己相関の、57個のニューロンについての平均値。各々のニューロンでテストすると57個のうち28個が隣接パターンについて有意の相関を示した。
 - ; この28個のニューロンについての自己相関関数の平均値。
 - ; 新しい 100枚のパターンに対する自己相関。

(6) 結語

現在のシンボル演算型コンピュータ上に構築された人工知能研究では、知識を構成する意味ネットワーク構造を実現するために、その基礎となる連想関係をアドレス間のポイントの構造体として表現する事が多い。しかし、脳における連想記憶のニューロン表現は、上述のように各ニューロンの反応選択性の組合せとして多数のメモリニューロン間に並列的に分散されてコードされている。側頭葉皮質における記憶貯蔵庫(memory storehouse)の構造がこのようなものであるとすれば、大容量並列型連想記憶装置たる大脳皮質の記憶過程を制御する海馬システムはどのような機能を果たしているのだろうか[7]。宮下は、大脳皮質と海馬システムの計算原理・アルゴリズムの実験的・理論的追求にはこうした視点が重要であると考えている。

[参考文献]

- [1] Penfield, W. & Perot, P. : Brain, 86, 595-696 (1963).
- [2] Scoville, W. B. & Milner, B. : J. Neurology, Neurosurgery and Psychiatry, 20, 11-21 (1957).
- [3] Zola-Morgan, Squire, L. R. & Amaral, D. G. : J. Neuroscience, 6, 2950-2967 (1986).
- [4] Miyashita, Y. & Chang, H. S. : Nature, 331, 68-70 (1988).
- [5] Amari, S. : Neural Networks, in press (1989).
- [6] Miyashita, Y. : Nature, 335, 817-820 (1988).
- [7] Miyashita, Y. et al. : J. Neurophysiol., 61, 669-678 (1989).

3.4.3 海馬神経回路網と学習の基礎過程

(1) 序

海馬と学習能力との関連については、宮下(3.4.2項参照)が詳しく進めている様な実験系を研究することによって、さらにこの系に対しここで述べる無侵襲多点同時光計測法を適用するなどによって、明らかにされるものと思われる。ここでは、海馬の神経細胞と神経回路網の働きを、学習の生理的基礎過程としてのシナプス可塑性に着目して研究している松元(電総研)等の研究を紹介する。

ここでは、現在のプログラム駆動型コンピュータとは質的に異なる「学習によって知識を獲得し情報処理を行い得るコンピュータ」の実現イメージを明らかにすることを目指し、

脳での学習アルゴリズムを細胞あるいは細胞下レベルで解明する研究を行っている。このため、

- ① 学習能と直接関係する海馬神経回路網を対象とし、
- ② 神経回路の活動を多点(104-105点)同時に無侵襲計測できるシステムを開発し、
- ③ ここでの神経活動が学習の前後によってどう変化するかなど詳しく研究することにより脳での学習アルゴリズムを解明することを目指す。



(2) 研究手法とその特徴

〔多点同時無侵襲光計測システムの開発〕

脳の神経細胞を膜電位感受性色素で染色し神経細胞活動に伴う膜電位変化を光変化（吸光度変化あるいは蛍光強度変化）として脳の各所から多点同時に計測することによって、神経活動の無侵襲計測を行えるシステムの開発である。本研究の範囲は膜電位感受性色素の開発は将来の課題とし購入使用できるものに留め、脳の各所からの神経活動に伴う光変化を多点同時に高速且つ高感度にとらえるシステムの開発とする。


(2-1) 256点同時無侵襲光計測システムの開発

神経活動に伴う光変化量は入射光量の $10^{-3} \sim 10^{-4}$ の程度で、且つ最も早い神経活動はミリ秒の時間オーダーであるので、光電変換素子としてダイナミックレンジの大きくとれるフォトダイオードを 16×16 の2次元アレイ状に配し、電気出力は256箇所並列出力した。 16×16 の2次元フォトダイオード外観図ならびにフォトダイオードと各ピクセルからの引き出し線の様相を図表3.4-11に示す。各ピクセルの大きさは $1.5 \times 1.5 \text{ mm}$ 、従って2次元アレイの外形は $23.8 \times 23.8 \text{ mm}$ である。各ピクセルからの電気出力は線幅 $5 \mu \text{ m}$ のAlをレジストで配し、開口率75%を得た。フォトダイオードからの電気出力データを256点同時にパーソナルコンピュータ（例えばNEC PC-98XL）に入力する（図表3.4-12）。フォトダイオードアレイの各出力は、各ピクセル毎に独立にヘッドアンプ（仮想接地増幅器）に入力し、次に各プリアンプに入力する。プリアンプの増幅度は330から9,000倍まで可変である。これらのマルチチャンネルの出力は、マルチプレクサでまとめ、1台のA/Dコンバータ（12ビット、 $1 \mu \text{ sec}$ ）でデジタル信号に変換される。デジタル処理部は2Mバイトのアドレス付きウェーブメモリで主として構成する。マルチプレクサのアドレスはRAMで指定する。従って、マルチプレクサチャンネルとメモリの物理的地址はユーザ側で自由




図表3. 4-11 256チャンネル・フォトダイオードの外観図（上図）およびダイオードピクセルと引き出し線の拡大図（下図）

に設定できるので、これによってフォトダイオードアレイの任意のチャンネルからのデータ取り込みを可能にしている。刺激パルスをコンピュータ側より発生し、その応答をフォトダイオードアレイで観測するように、12ビットD/A コンバータを内蔵した外部トリガーは1 μ sec の時間遅れで作動する。コンピュータへのデータ転送は DMA (Direct Memory Access) で64Kバイトを1ブロックに転送する。ソフトウェアはMS-DOS上のマクロアセンブラを用い、ハードウェアコントロールと画像表示のための高速処理サブルーチンなども備えた。



図表3.4-12 256チャンネル・フォトダイオードアレイシステム

こうして海馬などの脳スライス標本を膜電位依存性色素で染色し、光学顕微鏡を利用し、その神経活動を256点同時に(256 μ sec の時間分解能で)光計測するシステムを開発した(図表3.4-13)。



図表3. 4-13 脳スライス標本神経回路の電気的活動を多点同時に無侵襲計測するための光学システム


(2-2) 16,000点同時無侵襲光計測システムの開発へむけて

256 チャンネル光計測システムの神経活動計測の空間分解能は、図表3. 4-13のシステムで光学顕微鏡の対物レンズの倍率を40倍にして、 $30 \times 30 \mu\text{m}^2$ である。脳の神経細胞の細胞体の大きさは典型的に $10 \mu\text{m}$ 立方程度であるので、一つの細胞あるいは細胞下レベルの活動を計測するには、さらに空間分解能を向上できるようにもっと多チャンネル（例えば、 $128 \times 128 = 16,384$ ）2次元アレイの開発が必要とされる。このとき、時間分解能と感度は256チャンネル2次元アレイの場合と同様に保たなくてはならない。


このような多チャンネルのシステムを現在と同様の方法で作り上げることは極めて困難である。そこで我々は発想を転換し、フォトダイオードと同一の半導体基板上にスイッチングトランジスタを集積したイメージセンサを応用したシステムの開発に着手した。完成すれば、本システムは $128 \times 128 (= 16,384)$ 点からの光記録を0.5msec のフレームレートで取得することができる。しかも、感度も従来型と同様に保つことができ、且つ小型で、製

造コストも安い。従来の方法は、図表3.4-14(a)に示すように1個のフォトダイオードに1台の増幅器を取り付け、それぞれの信号を1,000倍以上に増幅した後にマルチプレクサで時分割に多重化し、A/Dコンバータでデジタルデータに変換してウェーブメモリ等にデータを格納するものである。この方式での最大の問題は、チャンネル数が増えるとフォトダイオードからの信号引出し線の数が増し、内側のフォトダイオードの配線が困難になることである(32×32=1,024チャンネル程度が限界だろう)。その点を解決するためには、図表3.4-14(b)のようにフォトダイオードの横にスイッチングトランジスタ(以後FET-SWという)を置き、フォトダイオードからの出力を時分割で取り出す方法を採用する。FET-SWがOFFのとき、光によって生じた電荷は、フォトダイオード自身の持つ接合容量に蓄えられる。FET-SWがONになると、この電荷は信号読出し線を通り出力される。FET-SWは縦にスキャンするものを各フォトダイオードの側に置き、横にスキャンするものを最上段に置く。これらのFET-SWは縦横のシフトレジスタで順々にONとなり、全面の光電荷は1本の出力線に時分割に多重化される。ここで注目すべき点は、このセンサ内の配線は左右に走るFET-SWのゲート線と上下に走る読出し線だけで、どんなにチャンネル数が増えてもフォトダイオード間を通る配線は縦横各々1本であることである。このため128×128程度のものが容易に作れる。神経活動の記録にもちいるセンサとしては、TVカメラ用の素子では、

(a) 従来からの独立方式
増幅器が独立に1チャンネルに1個接続する。



(b) マルチプレックス方式
フォトダイオードとスイッチングトランジスタを集積したセンサーとして一体化する。
FET-SW; スwitchングトランジスタ, PH.D.; フォトダイオード, I-V; 電流-電圧変換器, INTG; 積分器, S/H; サンプルホールド回路, DAC; D/Aコンバータ, ADC; A/Dコンバータ, REFF. MEM.; 参照信号記憶メモリ。



図表3.4-14 マルチチャンネルフォトダイオード光計測システムの二つの方式


1 ピクセルの大きさが $10\mu\text{m}$ 角ほどで必要なダイナミックレンジを得ることができず、また読出し速度も不足なので、専用のセンサを開発する。センサの出力は I-Vコンバータ、積分、サンプルホールドのプリアンプで増幅するディジタル信号処理回路に導かれる。この回路の動作は次のとおりである。測定の前に、入力信号をA/Dコンバータで参照信号に再現して差動増幅器で測定信号の参照信号からの変化分を1,000 倍以上に増幅する。これらの信号処理系は、チャンネル数が多い場合、従来方式に比べはるかにコンパクトに構成できる。

現在、試験用のプロトシステムを作製し、基本的な性能評価を行っているが、問題となるようなデメリットはなく、電子技術上の問題もすべて解決し、順調に稼動している。このプロトシステムは $25 \times 28 (=700)$ チャンネルのセンサ（フジフィルムFS4351）が使用されており、センサ受光面は $4.5 \times 5.1\text{mm}$ 、ピクセルサイズ $180\mu\text{m}$ 角である。センサユニットは $5 \times 5 \times 12\text{cm}$ ほどで、処理系も家庭用VTRなみの大きさである。このプロトシステムの結果を元に、 128×128 のシステムを平成2年度に完成させる予定である。

(3) 海馬神経回路の活動の空間・時間パターン


(3-1) 光計測システムによる脳海馬スライス神経回路活動の時空間パターンの計測とその生理的意味

海馬での学習アルゴリズムの解明を目指して光計測システムを海馬スライス標本に適用し、神経回路網解析と学習前後での神経回路網活動の時空間パターンを計測した。海馬は脳の奥深い両側にあって、大脳皮質を除くとピーナッツ状に見える(図表3.4-15A)。海馬を長軸に輪切りにして内部を模式的にあらわすと層構造の神経回路である(図表3.4-15B)。海馬体内で、内嗅野→(貫通枝)→顆粒細胞→(苔状線維)→CA4,3→(Schaffer側枝)→CA2,1→海馬台と一巡する主要な回路を形成する。この主要な回路のシナプスはすべて次の細胞と興奮性シナプスを形成する。もち論、海馬には錐体細胞の軸索から同じ細胞の細胞体へとフィードバック入力する抑制性の顆細胞や外部入力を錐体細胞に抑制をかける介在ニューロンなどの抑制シナプスも形成する。海馬の構造の著しい特徴はピーナッツの軸に対して層状構造をとる、ということである。この事は、海馬スライス標本に対する光計測の優位性を示している。膜電位感受性色素で染色した海馬スライス下面より光を照射して、海馬神経回路の活動を計測するとき、各ピクセルがおおう海馬領域に含まれる神経細胞の特性が均質であることが望まれる。この条件がほぼ満たされていることは、各ピクセ



図表3.4-15 モルモット脳と海馬

- A : モルモット脳と海馬の存在部位を示す。
 B : 海馬の黒く塗った箇所(A) の神経回路網。矢印の向きに情報は伝播し処理される。海馬への入力の内嗅野より貫通線維を通してのものと、海馬采その他のものがある。海馬からの出力は海馬采および海馬台よりがある。



図表3.4-16 海馬スライス標本のCA1部位における神経活動の多点同時記録

Schaffer線維を電気刺激。256チャンネルのうち、CA1 錐体細胞と同軸の11ピクセルの記録を示した。各ピクセルは $60 \times 60 \mu\text{m}$ の領域の活動をとらえている。ピクセル5、6、7の記録には顕著なEPSP成分とpopulation spikeがみえる。ピクセル4は細胞体層に位置し、これより上部のピクセルでは活動電位成分のみ認められる。

%表示のキャリブレーションは光シグナルの背景光強度に対する変化分(fractional change)を示す。


ルで計測した光学信号（図表3.4-16）のうちで細胞体層からの信号と同一領域の単一神経細胞の細胞体からも分かる。こうして一般的に哺乳動物の脳のように神経細胞は一つ一つは小さいが、層構造をとっていて、ある空間的広がりのある領域が特性のよく揃った均質の神経細胞から成る場合、光計測の手法は極めて強力な神経回路解析の手段となりえることを見い出した。

（3-2）神経回路網解析


神経回路の構造的結合関係は連続切片を作製しての電子顕微鏡観察、ある特定の細胞とその周辺の細胞との結合をみる色素（Lucifer Yellow など）注入による光学顕微鏡観察などの手法があり、その適用には極めて辛抱と忍耐のいる作業をとまなうが明らかにする手法は確立している。しかし、神経回路の機能的結合関係を明らかにする手段は、従来手法として存在しなかった、と言っても過言ではなかろう。もち論、細胞内電極刺入により細胞間の機能的結合関係を辛抱強く逐一明らかにすることにより神経回路の機能が明らかにされてきたし、また伝達物質の抗体を用いての免疫電顕観察によっても細胞間の機能的結合関係について重要な知見を得てきた。しかし、光計測による神経回路活動の空間時間パターンから神経回路の機能解析が極めて容易に行えることが見い出された。図表3.4-16の場合と同様に、一つの海馬CA1 錐体細胞に沿って光計測した信号の時間波形を計測した位置毎に並べてみると図表3.4-17の様になる。記録Aはコントロール、Bは100Hz1秒間条件刺激を加え長期増強（LTP）を誘導した後、Cは LTP誘導が飽和した後さらにホルボールエステル処理した後、テストパルスに対するそれぞれの応答の空間時間パターンを示す。まず、いずれの場合にも細胞体層に顕著な谷がみられるのが著しい特徴である。これは、CA1 錐体細胞の軸索枝から簗（バスケット）細胞がCA1 細胞に抑制性のフィードバック（反回抑制）をかけている構造的知見（図表3.4-15）と一致する。LTP を誘起し、さらにホルボールエステル処理などで神経細胞の活動を高めると抑制性入力量も増加するため、谷の深さがさらに深くなること（図表3.4-17記録BとC）は CA1細胞体層への反回抑制性入力をさらに裏づけるものである。

さらに海馬スライス神経回路の局所をレーザー光などにより微細に傷害し回路結線を切って、活動の空間時間パターンの変化を計測することにより、これらの比較から神経回路の機能的結合関係を解析することができる。この為、光計測システムと連動するレーザー光によるマイクロサージェリーのシステムを開発した。レーザー光としては、Nd:YAGレーザー光


($1.06\mu\text{m}$) の第3高周波 (波長 353nm : 試料面への最大照射エネルギー $10\mu\text{J}/\text{パルス}$) を用いた。試料を動かすことなくコンピュータコントロールの光ガルバノメータによって任意の形の傷害を加えることができる。レーザ光の試料面でのスポット径は20倍の倍率の顕微鏡の対物レンズを用いたとき、 $5\mu\text{m}$ 以下にすることができる。レーザ光により神経回路への光傷害は蛋白質の 353nm 波長光の吸光に伴う光傷害であるのでスポット径外部位への傷害の程度を極めて小さく抑えることができる。このレーザ光マイクロサージェリーシステムを用いて CA1錐体細胞の先端樹状突起部に直交して $100\mu\text{m}$ ほど傷害した後、



記 録 A




記 録 B



記 録 C

図表3. 4-17 CA1錐体細胞に沿っての神経活動の空間時間パターンと神経回路の機能解析

Schaffer側枝部を電流刺激したときの CA1細胞の応答を図表3.4-18に示す。



図表3.4-18 CA1錐体細胞部の細胞体層下部を100 μm にわたり(cutの横線部)、
Schaffer側枝を電流刺激して得た。CA1細胞部の応答の空間パターン

この図から傷害部(Cutの横線部)では先端樹状突起部に興奮性後シナプス電位(EPSP)が生じるが基底樹状突起部での活動電位の発生がみられず(従って電気緊張的に伝わる先端樹状突起部での活動電位もみられず)、従って Schaffer 側枝からの入力主として各CA1細胞の先端樹状突起に配分され基底樹状突起部より出力されるという回路の機能結線が確認された。こうしてレーザー光マイクロサージャリーシステムによる神経回路の局所的傷害による加工と光計測システムを用いた神経活動の空間・時間パターンの計測を組合せることにより神経回路の機能解析がさらに強力に行えることが実証された。

(3-3) 長期増強現象に伴う神経回路の活動の空間・時間パターンの変化

(A) 長期増強(LTP)に伴うCA1野の活動パターン変化

CA1野での LTPは、Schaffer側枝部にテタヌス刺激(100HZ、1秒間)を加え誘導した。

図表3.4-19上部にその結果を、図表3.4-16の右側挿入図にCA1実験領野を示す。AはLTP前

のコントロール、BはLTP誘起後のそれぞれCA1野の活動の空間時間パターンである。この結果から、ここでの測定領域左側部の各ピクセルで LTP前後の活動パターンを比べてみると、各応答の最初のピークには変化がみられないのに対し LTP誘導後に単相から2相性への活動の時間パターンが変化しているのがみられる。また、LTP 誘導後では各ピクセルで応答の立ち上がりが顕著に増加して、応答の出現に至る潜時 (Latency)が短縮している。さらに、活動の空間・時間パターンをもとに応答の最大振幅の大きさの空間分布を色表示すると、LTP前後で図表3.4-19下部のようになる(下部A、BにそれぞれLTP前および後を示す)。さらに活動の空間・時間パターンの差の大きさの空間分布を色表示すると B-Aのようになる。この場合、引き算値が正のものに暖色、負のものに寒色、0のものに黒で色付けした。これから分かるように長期増強(LTP)を誘起されたCA1野のすべて領域で増強が生じている訳でなく、刺激部に近い CA1細胞体層とそれに隣接する基底樹状突起部層に抑制が起ることが見い出された。これはSchaffer側枝から CA1細胞への入力の際に簞細胞の介在細胞が存在し、Schaffer側枝と簞細胞間のシナプスに長期抑制(フィードフォワード抑制)が生じたと考えたと解釈できるかも知れない。


図表3.4-19のCA1野の活動の空間・時間パターンを用いてCA1野の活動の空間パターンの時間変化を求めることができる(図表3.4-20)。これはLTP前後でCA1野の活動を動画としてTV画面上でみることができ大変印象的である。この図で一对の画面が縦に2組ならんでいるが、ともに左がLTP前(コントロール)で右がLTP後CA1野の活動の空間パターンの時間変化である(左上の数字がSchaffer側枝刺激後からの時間(単位msec)である。この図から、それぞれの時間における各ピクセルでの興奮の大きさを白丸で表している。この結果、

①LTP後では興奮の大きさも伝播速度もともに大きくなっており、


②さらに、刺激後12-18msec後のLTP後の空間パターンにみられるように興奮の抑まりが細胞体層から始まることが判る。

前者①については図表3.4-19からも明らかであるが、後者②については図表3.4-20にして顕著になったものでCA1 錐体細胞の軸索(出力)から抑制性介在ニューロン(簞細胞)を介して(図表3.4-15) CA1細胞体層へのネガティブフィードバック回路によるものと考えられよう。


A: Control



B: LTP



1.81E-03
64msec




A

B

B - A


図表3. 4-19 CA1野のLTP前後での活動の空間・時間パターン変化



図表3.4-20 CA1野のLTP前後での活動の空間パターンの時間変化

(B) 長期増強にともなう海馬神経回路一巡の変化

海馬における主要な神経回路は、貫通線維→顆粒細胞→苔状線維→CA3錐体細胞→Schaffer側枝→CA1 錐体細胞である（図表3.4-15）。そこで苔状線維をテタヌス刺激して、苔状線維とCA3錐体細胞のシナプスにLTPを誘導したとき、その後のこの一巡する回路にどのような変化が生じるかを調べた（図表3.4-21挿入図）。ここでは海馬の広い領域を同時に調べるので、各ピクセルは $120 \times 120 \mu\text{m}^2$ の海馬領域からの応答を計測する。記録Aはコントロールである。苔状線維に加えた刺激によりCA3 細胞が応答する（応答の大きさが小さいのは色素RH155とこの細胞との結合性に依存するものと考えられる）と同時にCA4細胞と



図表3.4-21 苔状線維(Mos)を刺激したときの海馬神経回路の活動の空間・時間パターン

A:コントロール、B:テタヌス刺激後、C:テタヌス刺激後にホルボールエステル投与、D:テタヌス刺激ホルボールエステル投与にBicuculin処理。
挿入図(下段)は海馬の測定部位と刺激位置を示す。

顆粒細胞に大きな興奮が生じるのがみられる。顆粒細胞へは逆行性に興奮が伝えられたことになる。記録Bはテタヌス刺激（100HZ、1秒間）後のテストパルスに対する応答パターンである。テタヌス刺激後ではCA3野（☆印領域）の応答の大きさも大きくなり、また、CA1野の応答も顕著である。この状態は1時間以上にわたって持続したので、

①CA3野にLTPが誘起され、


②これに引き続きCA1野にもLTPが誘起された、

と考えられる。この後この標本にホルボールエステル（5 μ M、20分間）を投与し、その応答を調べたのが記録Cである。ホルボールエステル投与によって、

CA1野の応答の大きさは極めて大きくなるが、それと同時に応答の大きさは極めて大きくなるが、それと同時に応答の時間波形も大きく変化する（☆印に注目）。これはホルボールエステルによってSchaffer側枝→CA1細胞のシナプスがさらに強化され、CA1細胞の応答が大きくなると同時に反回抑制のフィードバック量も増えたこと（図表3.4-17参照）による。この事を検証する為 Bicucullin（抑制性伝達物質GABAのリセプターをブロックする薬剤、1 μ M）を投与して後の応答を調べた（記録D）。CA1野での過分極方向への応答が著しく減少しているのが分かる。

苔状線維刺激後の海馬神経回路活動の空間パターンの時間変化の様相は、図表3.4-19より図表3.4-20を得たときとまったく同じ手法によって、図表3.4-21より得た（図表3.4-22）。ここでも一対の記録によって LTP前後の空間パターンの時間変化の違いを示す。各一対の記録のうち、左はコントロール（図表3.4-21記録A）、右はテタヌス刺激後さらにホルボールエステルを投与したときの応答記録（図表3.4-21記録Cと同じもので、LTP 記録と略記する）である。左肩の数字は最初の空間パターンを得たときを0ミリ秒としたときのミリ秒単位での時間経過を示す。図表3.4-22から、まず苔状線維が興奮し（0-2ミリ秒の記録）、逆行性にCA3細胞が興奮するのがみられる（4-6ミリ秒の記録）。ここで、LTP記録の方で一般的に興奮の反応の大きさが小さいのが注目される。とくに顆粒細胞の興奮がコントロールに比べ小さくなっているのが注目される。これは LTP標本でテストパルス刺激によって発火する苔状線維の数が少なく（0-2ミリ秒の記録）、従ってこの為に興奮する顆粒細胞の数が大幅に減少しているのかも知れない。コントロール標本では順行性に伝播する興奮が8-10ミリ秒以後 CA3野に留まってさらに伝播しないのに対し、LTP 標本では CA3野の興奮（4-6ミリ秒）からCA2野に興奮があらわれ（6-8ミリ秒）さらにCA1野に及ぶ（8ミリ秒以降）こうして LTP誘起によって海馬を一巡する主要な神経回路で伝達効率が上昇しその上昇が

維持されて、苔状線維からの興奮が回路を一巡して出力されるように回路機能が変化しこの状態が持続することを明らかにした。



図表3. 4-22 苔状線維から刺激を加えたときの海馬神経回路活動の
空間パターンの時間変化

図表3. 4-21のAとCの記録を計算機処理して得たもの。
コントロールがAに、LTPがCにそれぞれ相当する。

(c) 連合刺激による増強と抑制


Hebbの学習側では連合 (Association) が本質的に重要である。そこで、Schaffer側枝より条件付け入力 (Conditioning input)、また貫通線維よりテスト入力 (test input) を加え (図表3.4-23(A))、海馬神経回路の応答パターンを光計測手法で研究した。条件付けは10ミリ秒間隔の5つのパルスを一群として、この各群を200ミリ秒毎に10回加えることで行い、テスト入力は200ミリ秒毎に10回行う。条件付けとテスト入力と同相 (条件付け入力パルスの各群の中心時間とテスト入力パルスとが一致したもの) のとき (図表3.4-23(B))、CA1野にLTPが、また条件付けとテスト入力が逆相 (条件付け入力パルスの隣接群間の丁度真中にテストパルス入力を与えられる場合) のとき (図表3.4-23(B))、LTD (long-term depression : 長期抑制) がそれぞれ誘導されていることが、1本の電極刺入の生理実験により最近見いだされている (Stanton, P.K. & Sejnowski, T.J.: Nature 339 (1989) 215-218)。

Schaffer側枝からの入力での応答の空間パターン (図表3.4-23(C)左)と貫通線維からの入力の応答の空間パターン (図表3.4-23(C)右)とが同相あるいは逆相に加えられたとき、果してLTP, LTDがどのように空間的に引き起こされるだろうか。ここで図表3.4-23(c)は興奮の大きさを図表3.4-19下の場合と同じように色表示で示したものである。条件付け入力とテスト入力を同相→逆相→同相→逆相に交互にして得たCA1野および歯状回顆粒細胞部では増強と抑制がこれに応じてそれぞれ交互にあらわれることが観測された (図表3.4-24)。すなわち、


①CA1野で同相、逆相連合刺激に伴って長期増強と長期抑制があらわれる。増強はSchaffer側枝からと貫通線維からの応答が重なるCA1細胞の全域で生じるが、抑制はCA1細胞体から軸索に至る部分に主として生じ先端樹状突起部には生じない。

②顆粒細胞にも、同相・逆相連合刺激に応じて、CA1野とまったく相を逆にし抑制・増強が生じることを発見した。これは顆粒細胞は貫通線維から入力を得ているだけと考えて連合刺激による応答性の変化は期待していなかっただけに思いがけない発見である。



(A)



(B)



(C)



図表3.4-23 連合刺激による長期増強・長期抑制の誘導の実験構成


(4) 今後の課題

①海馬スライス神経回路のLTP 前後での空間・時間パターン変化の生理的意味を明らかにし、海馬神経回路の基本特性を理解する。このために、光計測手法、レーザ光によるマイクロサージェリーの手法を開発し、これらがこの研究の極めて有力な手法となり得ることを確認したので、これを大いに活用し行う。

②光計測の手法は海馬スライスのみならず脳活動が無侵襲に多点同時計測を行える手法として今後ますます発展するものと思われる。現在の 256点より16,000点同時(0.5ミリ秒以内)の手法を平成2年度に開発し神経回路の機能解析をさらに詳細につきつめる。

③脳の学習・記憶機能における海馬の機能的役割をさらに明らかにする為、スライス標本などの in vitro の系から in vivoの系へ移行することが重要と考え、生理研究の対象を in vivo系に移してゆく。

④以上のような段階をへて海馬の学習に対する役割を解明し脳での学習の行われ方に対するアルゴリズムを明らかにする。これをもとに学習によって知識を蓄え情報処理を行う新情報処理システムの提案を行うことを目指す。



図表3.4-24 連合刺激による長期増強と長期抑制

3.4.4 計算論的神経科学

(1) 計算論的神経科学と神経科学、新情報との関連

計算論的神経科学 (Computational-Neuroscience) のアタックが始まった。このテーマは、古くから提案されていたが、神経科学と計算機の進歩により最近再び注目を浴びている。しかも、この分野の研究は、脳の学習メカニズムを含む柔軟な情報処理メカニズムの解明を計ることと密接な関連があり、その工学的な実現を目指す新情報と深い関係がある。また、膨大な神経の結合からなる神経系の大規模な動作解明には、従来の計算機上での実現に困難があることが指摘されているが、この面でも、大規模な超並列の計算論的モデルを構築できる新情報システムがこの分野の研究に果たす役割は非常に大きい。

(2) 計算論的神経科学

計算論的神経科学は、Sejnowski[1]によれば、神経の情報処理（情報を脳内で処理表現するために、電氣的／科学的信号がどのように実際使われているか？）を解明することが

究極の目的である。すなわち、最近の神経生理の新しい知見と、同じく最近進歩が目覚ましい計算機の計算能力を利用して、神経系の現実に近いシミュレーションを行い、大規模神経システムの構成的研究、各レベルの関係を橋渡しするモデルによる研究等により、新しい示唆を得て、脳で使われているアルゴリズムを発見することが目的である。

D. Mar [2]が神経回路から脳の情報処理を直接推測することの危険性を指摘したように、脳研究においては計算論的アプローチに従った3つのレベルの研究が必要である。

① 情報処理の計算理論

② ①を実行するための脳内情報表現とアルゴリズムの研究

③ アルゴリズムを実行する実際のハードウェアの構造に関する研究

計算理論では、システムで行われている計算の入出力関係や制約条件、その計算の存在理由等が問題とされる。研究手法として従来の神経科学が、③のレベルを主としたボトムアップ手法であったのに対し、計算論的神経科学では、「脳で何が計算されているか」を、① → ② → ③と①の問題を意識しつつトップダウンに展開する。


Sejnowski 等の最近の仕事は、Mar の主張の神経科学における具体的実践であると捕らえることができる。つまり、神経科学が対象とする脳システムは、大規模で複雑なシステムであるため直接必要なデータを全て直接測定し、評価することが困難である。また、分子レベルや細胞レベルの微視的なレベルに始まり、行動等のシステムレベルまでの多階層に渡るレベル間の関連をつけるためには、「脳のモデル」等のモデル論的アプローチが必要になる。このように、計算論的神経科学のアプローチによるモデル研究が利用できる実験データに基づいてきちっと出来ていれば、モデルの予測に基づいて将来の研究方向を決定することが出来る。現在、計算論的神経科学アプローチは、実験的検証との協調的な取り組みによって、神経生理現象の解明を計りうる有力な研究アプローチとなっている。

(3) 計算論的神経科学のモデル例

神経科学の現場で、実験と共に計算論的神経回路モデルを精力的に開発している研究グループとしては、カルテックのBowerのグループとソーク研究所のSejnowskiのグループが知られている。日本でのこの方面の研究としては、伊藤正男らの小脳の学習実験に対応して開発された、藤田昌彦の小脳適応フィルタモデルが有名である。ここでは、一例として、Sejnowski が示した計算論的神経回路モデルの研究を紹介する[1]。

視覚野単純細胞における方位選択性のメカニズムの研究をその例とする。この研究でノ

ーベル賞を授賞した HubelとWieselが提唱した、単純細胞の入力野の細胞の配列の形に依存しているという単純な仮説（図3.4-25(b)）は、その後単純細胞の記録によりそんなに単純でないことが分かり、様々な新しいモデルの提唱がこの25年間になされた（図表3.4-25(c), (d)）。




図表3.4-25 方位特異性を実現する結合のモデル [1]

- (a) 視覚野(VI)では方位特性があるが、そこに繊維を送っている外側膝状体(LGN)の細胞の受容野は方位特性がない。
- (b) Hubel, Wieselの提唱したモデル. LGNの細胞の配列が方位特性を決定する。結合は全て興奮性である。
- (c) 一つの興奮性結合と多くの非方向選択性の抑制結合とからなるモデル。非方向選択性の細胞が実験的に見つかっていない（猫）。
- (d) 折衷モデル。Hubel タイプの興奮性結合と、同方位性で空間的にずれた部位からと、直交方位性の細胞からとの沢山の抑制性結合を持ったモデル。


25年間の生理学的研究で決着がつかなかった「どのモデルが方位選択性を実現している回路であるか？」といった問題に決着をつけるために、図表3.4-26の実際の神経回路に近いレベルでの大規模シミュレーションが行われ、各モデルの長所と短所を調べられた。図表3.4-26は、図表3.4-25(d)のような多くの抑制を含んだ相互作用のある神経回路の振る舞いを示している。この検討により、モデルと実験的測定値との一致が確かめられ、神

経の反応特性の生成過程が説明された。また、検討の過程で、様々のコントラストの視覚刺激に対するゲイン制御に対する興味深い予測がなされた。このような予期せぬ予測が、検討課題として提出されるところがモデル論の良いところである。



図表3.4-26 方位特異性を実際の回路に近いモデルでシミュレートした例[1]

しかし、ここでは方位性だけに注目したが、同じ細胞が空間周波数グレーティングやテクスチャにも反応することから、細胞の本当の機能を推論することは困難である。そのような例として、Sejnowski は曲率の検出を学習させた細胞が、同時に、方位検出細胞の特性を持つことで示した (図表3.4-27)。



図表3.4-27 曲率の検出細胞の形成モデル[1]

これらの一連の計算論的神経科学の試みは、システムが複雑なため実験的には直接の検証が不可能なシステムの機能の解明に、これらの手法が役立つことを示している。

〔参考文献〕

- [1] Terrence J. Sejnowski, Christof Koch and Patricia S. Churchland ; Computational Neuroscience, Science, Vol. 241, p. 1299-1306 (1988)
- [2] D. Mar, Vision, Preman, (1982)

3.4.5 遺伝と学習

(1) はじめに

生物の情報獲得は学習が基本である。脳はその代表として良く知られる(3.4.3及び3.4.4項)。生物の情報機能としてこれとともに代表的なものは遺伝情報である。遺伝情報の獲得機構からコンピュータ創出へのヒントが得られる可能性も考えられるので、ここでは遺伝情報においても情報獲得が学習(あるいは自己組織)によってなされることを注意し、学習の時間を 10^8 倍程度速めて工学的利用を探る研究を紹介する。


(2) 分子進化のプロセス

遺伝情報はDNAの塩基(A, G, C, T)の配列によって表現される。この配列決定(プログラム化)はダーウィン進化というプロセスでなされる。このプロセスは2つの段階からなる。第1の段階は塩基配列に変化(突然変異)が生じることである。この変化はDNAの複数ミスで生じる。DNA複製はDNAポリメラーゼが行う。このポリメラーゼは2つの部分(DNA鋳型合成活性とDNA分解活性)から成る。すなわち、DNAをコピーする部分とミスコピーしたときその箇所を加水分解によって消す部分から成る。従って、DNA複製時のミスが極めて低い率に通常抑えられている。第2の段階はDNAの塩基配列によって表現される生物機能が自然によって選択(自然淘汰)され、最適化されたものが生き残るプロセスによって情報が獲得される。すなわち、この情報獲得過程は複製のゆらぎと自然選択から成る。ゆらぎがまずあって変化し、その中から環境に適応したものが選ばれるのである。これが進化の分子過程である。

(3) 分子進化の要因

ダーウィン進化の要因として、上記の自己増殖に伴うDNA複製とゆらぎの他に、Eigen[1]はDNA分子系が非線形非平衡系(開放系)[2]である(図表3.4-28)ことが必要とされること示した。これは開放系におけるGlansdorffとPrigogine[2]の安定性の条件と関係してい

る。自己複製系はゆらぎによる内部エントロピー生産率変化が負になるような不安定性の生じる系であり[2]、このような不安定性の存在が進化のための必要条件[1]である、というのである。生体が非線形非平衡系であることの重要性は、細胞レベルより上階層の生理現象の体系的理解においても指摘できる[3]。例えば、神経線維での電氣的興奮発現（インパルス発生）という典型的な生理現象は非線形非平衡系での転移現象としてとらえることができる[4], [5]。このようにして、情報を獲得（プログラム化）する進化というプロセスで、突然変異で散逸する情報の中から自然淘汰が新しい情報を獲得し得るのは、開放系であることによっている[6]。



図表3.4-28 開放系（非線形非平衡系）

開放系は少なくとも二つの異なる外界と同時に接する。このためどちらの環境とも平衡に達することができず、外界との間に物質またはエネルギーの流れ J_1 、および J_{11} ができる。このためこの系は開放系であるという。開放系の中での物質の流れを J_0 とすると、 $J_0 = J_1 = J_{11}$ となったとき外界と系のどこにも物質またはエネルギーの滞貨が起きず、系は定常であるという。


(4) 分子進化の速度を早める

遺伝情報の最適化に36億年という膨大な長年月を生物は要してきた。この進化の速度を決める要因は何なのであろうか。進化の要因が明らかになってきたとすると（(3)参照）、進化の速度を著しく（例えば 10^8 - 10^9 倍）速くすることはできないのだろうか。進化の速度が著しく速い場合があることは現在良く知られている。

例えば、伏見[7] は次の様な例を掲げている。一つは大阪大学の岡田弘輔らが発見したナイロンを分解資化する細菌の存在である。ナイロン工場の排水中から単離されたある種の細菌はナイロンオリゴマー分解酵素を合成するプラスミドを持っていた。DNA を分析してみると、祖先タンパク質に数個の点突然変異が起こったことにより非天然化合物を分解する機能を獲得したことが分かった。この種のプラスミドはかなり頻繁に取れるという。また米国のA. M. Chakrabarty らはある種の有機塩素化合物を分解資化するプラスミドを持つ土壌細菌を連続培養槽ケモスタットで、除草剤2, 4, 5-T存在下で10ヵ月間培養したところ、この非天然化合物を分解するプラスミドが進化してきたと報告している。さらに身近なところでは、インフルエンザウイルスが頻繁に変異して、人間の攻撃を回避していることは有名である。さらに、分子進化の現場を見るという意味での直接的証拠は、RNA 分子の試験管内ダーウィン進化という研究で得られた。米国のS. Spiegelmann らはバクテリオファージQ β の RNA複製酵素を用いてそのRNA を試験管の中で継代複製する実験を行った。この環境条件下ではウイルス粒子を作らずともRNAは増殖可能である。RNA 分子が持つべき機能はQ β RNA複製酵素によって認識され複製されるということだけである。その結果、進化が進むと RNAの長さは短くなって行く。Eigen らはこれと逆の実験を行った。初期に試験管の中にいっさい RNAを投入しなくても、長さが 200ヌクレオチド程度の分子種が進化してくるのである。またSpiegelmann のグループはRNA 結合性色素であるエチジウムプロミド存在下に継代複製を行うと、そういう新しい環境条件に適応した点突然変異体 RNAが10~20世代後に試験管内を占めるようになることを発見した[7] (図表3. 4-29)。これらはすべて日のオーダの進化過程である。キリンの首が長くなる現場を目撃した人はいないが、分子進化の現場を目撃した人は結構いるのである。

それでは進化速度を決定する要因は一体何なのだろうか[7]。その最も支配的な要因は自己複製する DNAの長さである。上の例でみるようにプラスミドやウイルスの進化速度が速いのは自己複製すべき DNAの長さが短いためである。この他、進化速度を決める要因として伏見[7] が掲げているものは、突然変異率とその変化速度、自己複製速度、個体群の

大きさ、塩基配列空間上の淘汰値の地形とその変化速度及び初期条件である。こうして、小さな特定遺伝子をバクテリオファージに組み込むことによって突然変異体のスクリーニング効率を実験室で 10^8 倍近く大きくすることが可能であると結論される[7]。



a) 突然変異RNA (○)と野生RNA (●)の
エチジウムブロミド溶液中でのRNA合成速度

b) 点突然変異によるRNA合成速度の変化

長さ 221ヌクレオチドのMDV-RNAを試験管の中で複製させる。その一部を新しい試験管に移して複製させるということを繰り返す。このときエチジウムブロミドが存在すると点突然変異が三カ所で生じたRNA (図bの a, b, cの矢印は、それぞれRNAの87番目のグアニンがアデニンに、86番目のシトシンがウラシルに、178番目のグアニンがアデニンへの異変を示す)のほうが複製速度が速いため、試験管内で突然変異体RNAが次第に多数を占めるようになる。ダーウィン進化のメカニズムで、分子が新しい環境に適応したといえる。

図表3.4-29 Spiegelmann らの試験管内RNA 進化実験の一例[7]

(5) おわりに

進化による情報獲得のプロセスはニューラルネットワークでの学習プロセスに似ている。ニューラルネットワークでは開放系の考えがとり込まれていない。開放系の2次元的なネットワークは容易に非線形振動が生じ、収拾つかなくなるのを知っているからである。実際、Hopfieldは人工ニューロン間結合 T_{ij} を対称化してこの困難を避けている。しかし、初代培養神経細胞が作るネットワークは容易に自励発振するのに対し、脳のin vivo 神経回路は秩序を保ち、特定の機能を発現する。従って、自励発振を目的によって制御する機構・環境が整備・調節され、学習能などの高次脳機能がそれぞれの特異的な神経回路と神経細胞によって担われていると、考えられる(3.4.1項参照)。これに対し、DNA情報は1次元構造によって担われている。進化による情報の自己組織化の機構がこれだけ体系的に理解されているので、これを学習型コンピュータ創出の基礎にした工学的発展を考えてい

きたい。

〔参考文献〕

- [1] Eigen, M : Naturwissenschaften 58, 465-523 (瀬川新一、伏見譲訳 ; 日本生物物理学会編「自己組織化」学会出版センター P. 163-184), (1971).
- [2] Glansdorff, P. and Prigogine, I. : Thermodynamic Theory of Structure, Stability and Fluctuations (Wiley Intersci., London, 1971). (松本元・竹山協三訳「構造・安定性・ゆらぎ、その熱力学的理論」みすず書房, (1977) .
- [3] 松本元 : 生体とゆらぎ (石井、小林、清水、村上編「生命現象のダイナミズム」中山書店, P. 87-113, (1984)
- [4] 松本元 : 神経興奮の現象と実体、上 (丸善), (1981).
- [5] 松本元、市川道教、羽生義郎、高橋信行 : 神経興奮の生物物理 (日本物理学会編「生物物理のフロンティア、蛋白質／筋収縮／脳・神経」培風館、P. 191-221(1989).
- [6] 伏見譲 : 科学朝日 50 P. 18-23, (1990)
- [7] 伏見譲 : 現代化学 P. 38-44 (3月号, 1988)

3. 5 ま と め

3. 5. 1 現状技術の限界

現状技術の限界は2つのレベルに分けられる。一つは従来の計算アーキテクチャであるフォンノイマン型コンピュータにおける問題である。もう一つはこれらの問題を解消する一つの有力な手段として注目される超並列・超分散アーキテクチャの現状での問題点である。

(1) 従来の計算アーキテクチャの限界

a. 高速計算及び実時間処理

従来のコンピュータは数値計算などには非常に有効であるにもかかわらず、認識や意思決定などについては、人間が非常に簡単に行う情報処理であっても困難な場合がある。これは、コンピュータの性能が低かった時代には、素子の性能が十分ではなく、また、メモリ容量も小さいためと考えられた。しかしながら、近年のコンピュータの進歩は著しく、

素子の動作速度やメモリ容量共に人間の脳を上回っている。それにもかかわらず、やはり上のような問題の処理は、人間の方が高速である。この事実は、現在のコンピュータの問題が、逐次型アーキテクチャそのものに関係があることを示しており、これを解決するには、人間の脳のような超並列・超分散アーキテクチャに注目する必要があることが指摘されている。

b. 計算量の爆発の解消

計画問題や最適化問題は逐次型の数理アルゴリズムでこれを解析しようとする、大量の計算を必要とする場合がある。これは、この種の解析が、原理的には考えられる全ての選択枝について解析し、最適なものを選び出す性格のものであるからである。計画問題においてよく知られたダイナミックプログラミングはこの選択枝を絞り込む手法と考えられるが、それでも選択枝の数が多い場合には、計算量が非現実的な計算時間を要するまでに至ってしまう。これに対して人間は、このような場合でも経験などをうまく用いて、完全に最適な解ではなくとも比較的良好な解を容易に見つけ出してしまうことがある。このような人間の脳の情報処理には、経験などの総合的知識利用が関係しているが、同時に脳の超並列・超分散アーキテクチャが密接に関係していると考えられている。

c. 複雑な実世界の認識機能

コンピュータに人間の行う高度な情報処理を行わせる試みの代表的なものはパターンの認識であるが、文字や刻印の認識など人工的な対象物だけでなく、実世界を対象とした認識、例えば無人の自動走行車などの外界認識装置等を考えた場合、その対象は極めて複雑で変化に富んでいる。このような認識はやはり、数理的な処理では限界があり、知識利用などのソフトウェア面での解決方法の他に、ハードウェア面として新しいアーキテクチャの検討が必要である。

d. 不良設定問題解決

実世界を扱う問題では、一意的には解が求められない場合がある。例えば、人間が腕を動かす場合でも、可能な軌跡は幾通りもあるが、従来の逐次型コンピュータによる解析のように、可能な軌跡について解析を行い、そのうちの最適なものを選択するような判断を人間が行っているようには見えない。数理的には幾通りもの可能性の中から一つを選び出

す機能は、実際の動作と同時的かつ並列的に行われていると考えられ、ここでも従来の逐次型のコンピュータを越えるものとして、人間の脳の実時間並列処理を可能にしている超並列・超分散アーキテクチャが注目される。

e. 多数制約の解決

多数の制約条件の下である解を求めることは工学的な領域ではしばしば見られる問題である。例えば、コストの最小問題等を線形計画法で解くことが例として挙げられるが、このような問題も制約条件が多数ある場合には従来のコンピュータでは計算量の問題を生じる。しかしながら人間は、上述の計画問題や最適化問題における場合と同様に、完全に最適解ではなくとも、制約条件群の重要度の違いをうまく考慮したり、条件を一時的に緩めたり強めたり、ダイナミックに試行をうまく行い、適切な解を高速に求める場合がある。これは、従来の数理的なアプローチによる解決の他に、人間の情報処理をまねた解決方法が有効であることを示しているが、ここでもその基礎としての超並列・超分散アーキテクチャが注目される。

f. 環境への適応機能

学習の体系に関する議論において説明したように、従来も環境への適応は行われてきた。しかしながら、従来の適応制御などは、従来のコンピュータを含むシステムの外部特性に学習と呼びうる調整機能を設計者が意図的に構築したものであり、コンピュータ自体が環境に適応するわけではない。これに対して人間の脳は、その構造自体に適応機能があり、それは脳の超並列・超分散アーキテクチャに密接な関係があると考えられている。

g. 知識獲得機能（学習）

人間が知識を獲得してゆく機能、すなわち学習機能も上述の環境への適応のように、人間の脳の超並列・超分散アーキテクチャと密接な関係があると考えられる。特にこの関係は、現在活発化しているニューラルネットの研究でもある程度明らかにされている。すなわち、現在の提案されているニューラルネットは生体の神経回路網と比較すると遥かに単純化されているにもかかわらず、従来の逐次型コンピュータに見られない特徴をもっており、その最大のものが、入出力事例による学習である。このような研究の成果は、より高度な学習機能の実現には、人間の脳のアーキテクチャの研究とモデル化が不可欠であることを示している。

以上のように、従来のコンピュータの問題の多くは、人間の脳で行われているような超並列・超分散処理形態に着目せず、逐次型の処理方式を採用していることと密接な関係がある。これは既に1950年代より指摘され始め、コネクショニズムの考え方が提案されるようになった。しかしながら、大規模な分散演算ネットワークの動作をシミュレートすることは当時のコンピュータでは難しかったこともあり、理論的な研究のみが行われてきた。それに対して近年のマイクロエレクトロニクスの発達で1980年代後半より超並列・超分散アーキテクチャとりわけニューラルネットの実用化研究が急加速するに至った。それゆえ、今後の研究課題としては、上記の従来アーキテクチャの問題を解消する方法として、超並列・超分散アーキテクチャの、種々の分野における適用可能性を検証するようなものが挙げられる。

(2) 超並列・超分散計算アーキテクチャの現状での限界

ニューラルネットに関する事例の紹介では、現状のニューラルネットでも、定式化の困難な知識利用や人間の認識機構、制御規則が学習によって実現出来ることや、超並列性に高速性等の利点があることが示されたが、同時に現状の超並列・超分散アーキテクチャは未だ完全なものとは言えず、今後更に高度化した超並列・超分散アーキテクチャを目指す研究課題が存在することが明らかになった。現状の超並列・超分散アーキテクチャは今後解決すべき次のような限界を持つ。

a. 学習性能の限界

現状の学習アルゴリズムは、事例学習という従来にない特徴があるが、一般にはその学習には膨大な回数の繰り返しが必要で、学習時間は非常に長くなる傾向がある。これが、現状のニューラルネットの実用化の大きな制約となっている。また、実用化のためには人間では簡単に行っている追加学習能力なども重要になる。また、人間では論理的な知識が学習に大きく関与しているが、そのような機構も現状の学習手法には含まれていない。

b. 認識性能の限界

ニューラルネットによるパターン知識の処理は、現状ではパターンの形状的な類似性のみに基づいているため、処理結果が極めて幼稚になる場合がある。人間では論理的な知識とパターン認識に影響を及ぼし合い、適切な処理を行っているが、現状のニューラルネッ

トにはこのような高度なメカニズムが含まれておらず、それが認識性能の限界となっている。

c. 大規模なネットワークの構築手法が確立していない

単一のニューラルネットは、ある限定された適用範囲では従来にはない長所を持つものの、大規模な機能全体を単一のニューラルネットで置き換えようとする、従来技術による制御装置や知識処理装置の性能を上回れない場合が多い。これを解決するためには小規模のニューラルネットを組合せて大規模のものを作ることが考えられるが、現状の学習アルゴリズムでは、事例のみによる学習が出来なくなるなど、人間の脳のような柔軟性が失われる。人間の脳も一様な神経回路網で出来ている訳ではなく、様々な神経回路網のモジュールによって構成されているにもかかわらず、知識獲得などに高い柔軟性を保持しており、その知見を反映したニューラルネットの構築方法がないと、大規模なネットワークが構築できない。

d. 利用技術の開発が不十分

超並列・超分散アーキテクチャの利用は始まったばかりであり、現状ではニューラルネットの適用はかなり限定された範囲のパターン認識、運動制御、あるいは知識処理などに限られている。分散制御システムなど、より大規模な適用対象での検討がなされていない現状では、超並列・超分散アーキテクチャの可能性や適用範囲が狭い範囲にとどまっている。

大規模なシステムへの適用を考えた場合には、すべてを超並列・超分散アーキテクチャで実現する必要はなく、従来技術との融合があっても良いが、そのための技術、特に、知識を扱う技術として共通性のあるAIなどとの融合技術が十分に発展していない。

e. シンボル処理の方法が未開発

人間の脳は超並列・超分散アーキテクチャであるにもかかわらず、論理処理やシンボル処理ができる。これは、現状のニューラルネットがパターン認識処理に限られているのに比べて大きな違いとなっているが、現状では、人間の脳内の知識表現形式も明確になっていない状況である。

f. 自己組織化能力が開発されていない

超並列・超分散アーキテクチャの学習は、現状ではネットワーク構造は一定でそのパラメータが調整される形態に限定されている。しかしながら、より柔軟性のある学習が行われるためには、構造そのものを発達あるいは増殖するような形態、すなわち自己組織化機能の開発が必要である。

3.5.2 研究課題

新情報処理技術としてとりあげるべき研究課題は、大規模な自己組織化原理に関する研究開発、すなわち、モジュール化とその調整を可能にする発達過程までを含めた自己組織化原理の工学的、認知科学・心理学的研究、生理学的研究である。

a. 超並列・超分散システムの学習機構の開発

(1) 新学習アルゴリズムの開発

(2) 学習用新計算機構の開発

(3) 学習チップ／プロセッサ

b. 超並列・超分散システムの構成技術

(1) 構造化構築手法の開発

(2) 自律分散形階層制御システム

c. シンボル処理との融合システム技術

(1) 分散形シンボル処理システムの開発

(2) シンボル処理とパターン処理との融合システムの開発

d. 発達・分化の工学的実現に向けて

(1) 生物における発達・分化

(2) 発達・分化システムの設計について

e. 学習の認知科学的及び心理学的解明

f. 学習の生理学的解明

これらのうち、「学習の認知科学的及び心理学的解明」と「学習の生理学的解明」については、従来のコネクショニズムの事例調査などから、工学的立場より今後の研究課題として次のような期待が寄せられた。

(認知科学及び心理学に対して)

- (1) 論理的知識の学習における役割
- (2) 論理的知識のパターン認識における役割
- (3) 出力誤差最小以外の荷重変化規則性
- (4) 意識的制御と無意識制御の関係

(生理学に対して)

- (1) 脳内知識表現
- (2) 論理的知識に依存する学習の神経網上での実現形態
- (3) 事例からの学習能力を保持した脳内構造化機構
- (4) 論理的知識に依存するパターン認識の神経網上での実現形態
- (5) リズム運動（自動運動）と随意運動との連関
- (6) 神経回路の構造とシンボル化された運動表現との関係

4. 新情報処理技術として とりあげるべき研究課題

4.1 学習課題の展望

学習に関する工学技術としては、シンボル世界を対象としたAI学習、パターン認識に関する学習、適応制御での対象モデル依存型学習など種々のものが研究されている。そこでは、学習内容のレベル、従って、方法論的にも大きな違いがある。

ここでは、これらの学習研究との関係で、超並列・超分散システムの学習がどのように位置づけられるか、そして、新情報処理技術で何が目標とされるのかを展望する。

学習対象を抽象度に従って分類すると、①状況認識・意思決定・戦略計画・判断などのための論理的知識の獲得、②パターン認識・パターン発生のための学習、③単純な刺激と単純な応答による条件づけ学習に大別される。①は、シンボル世界を対象に、AI的手法によって研究されてきた。また、心理学・認知科学によってとりあげられてきた対象であり、トップダウン的戦略が中心になっている。②のパターン認識に関しては、いかにして有効な特徴を抽出するかという問題はあるが、工学的には、特徴空間での識別関数の学習として研究されてきた。また、適応制御の分野でも、制御対象の入出力特性の学習というパラダイムでの研究が行われてきた。一方、生理学の対象ともなり、特に、視覚パターンの認識に関する神経機構はかなり明らかにされている。③の条件づけ学習は、②の基礎となるもので、要素的研究あるいは単純化された場合での研究とみることができる。特に、神経系の学習において想定されているシナプス結合の可塑性については、数理的なモデルも幾つか提案され、それに基づく学習能力の研究が行われている。必然的に②及び③では、ボトムアップ的戦略が中心であるが、②に関しては、それだけでは解決困難な問題があり、トップダウン的戦略との結合が必要とされている。

では、超並列・超分散システムの学習では、何を目標として研究課題を設定すべきか。

新情報処理技術での学習の役割は、大規模な超並列・超分散システムに、必要な機能をもたせるための構造を「自己組織」させることにある。


すでに、パーセプトロンから始まり、最近でのバックプロパゲーション法による多層神経回路の学習に見られるように、シナプス荷重という構造パラメータの適応的調節というパラダイムでの研究は進んでいる。それらによって、単純な条件づけ学習や、比較的単純

なパターン認識や運動制御の問題などは解決されている。

それに対し、新情報処理技術では、構造そのものの適応的調整、構造化、モジュール化を取り込んだ自己組織の原理を明らかにする必要がある。さらに、シンボル世界とつなぐには、シンボル化された情報が超並列・超分散システムによってどのように表現されるかを明らかにしなければならない。

そのためには、認知科学や生理学との密接な連携が必要である。

これらの関連を図表4.1-1に示した。



図表4.1-1 学習課題の展望

4.2 超並列・超分散システムの学習機構の開発

4.2.1 新学習アルゴリズムの開発

入力の時系列性を考慮しないシステムの学習については、甘利の学習理論、ボルツマンマシンの学習理論など一般性に富む理論が既に提唱されている。従って今後の主たる課題

4. 新情報処理技術として とりあげるべき研究課題

は実現を目指すべき機能とそれを実現するニューラルネットの構造の具体化であると考えられる。脳の神経系は一見ランダムな、あるいは一様な結線をもつシステムのように見えるが、実は高度に構造化されたシステムであることが最近の神経科学的研究により明らかになっている。従って人間の脳がもつ種々の高度な機能の実現にはそれらの機能の実現に適合した構造をもつニューラルネットの開発が必要であると考えられる。また学習理論自体における今後の課題としては甘利理論ではlocal minimumの回避、ボルツマンマシンでは非対称結合を含む理論への発展、学習時間の短縮等があると考えられる。

人間の脳の情報処理における最大の特徴の一つは、入力情報のcontextの巧みな利用であると考えられる。従ってこのcontextの形成と利用を具体的に実現するシステムを開発することにより、きわめて高度な情報処理機能の実現が期待できる。ニューラルネットにおいて時系列情報を学習し、contextを使って認識、連想等の機能を実現する試みは幾つかあるが、本格的に追求されているとは言えず、特に音声の理解や運動の発生など連続的な信号に対する学習の研究は最近になって研究が着手されたばかりである。この種の課題を解決するニューラルネットの構造と学習方法の開発、学習の理論的裏付け等が今後追求されるべきである。

シナプスの可塑性は長い間仮説の域を出なかったが、3.4.1項に記述されているように最近運動機能の習得に深く関係していると考えられる小脳や記憶の座の一つと考えられている海馬などでその存在を裏付ける知見が数多く報告されるようになった。脳の神経系におけるその実在はもはや動かし難い事実であるといえよう。更にごく最近では、脳の神経系における可塑シナプスは機能的にはすべてHebb型であることが明らかになってきた。従ってHebb型の学習方法を用いて望ましい機能形成を行うニューラルネットを開発して行くことも、高度な機能をもつニューラルネット開発の有力な手段であると考えられる。Hebb型の学習方法はその理論的な検討もなされてはいるが、未だ十分とはいえない。この学習方法の能力に関する一般理論も今後解決されるべき重要課題であるといえよう。

最後にニューロンは現在は多入力一出力のアナログ閾素子としてモデル化されているが実際にはそれ程単純なものではなく、時空間的な入出力関係、局所部分における演算機能などが存在すると考えられている。また化学物質によるグローバルな状態制御もモデルの中に取り込まれる必要があると考えられる。このような点を踏まえたニューロンモデルの開発とそのモデルにおけるシナプスの可塑性の問題の解決、すなわち学習方法の開発も今後の重要な課題となると考えられる。

4.2.2 学習チップ／プロセッサ

現在、ネットワークに結合荷重を与えて情報処理を行わせることが主なチップ化研究である。また、結合荷重を変更するシステムが研究されている。これから高度な情報処理のかなりの部分を学習で実現しようとするとき、サブシステムでの自律的な制御が必要になる。これに答えるようなチップを考える。

(1) チップが学習機能を持つ効果と必要性

①大規模な構造化ネットワーク形成の支援

チップが組合された大規模システムでは、多種類の入力を各機能群で並列的に学習する必要がある。この学習を外部の学習計算機で集中して負担を大きくすることは、学習計算の高速化を妨げる。各機能群で、より分散が進めば群内の各チップで学習することにより、より高度な並列処理レベルが達成され、学習が高速化され、柔軟な対応がより容易に達成されるようになるために、学習チップが必要である。

②チップの不良率の低下

従来のチップは製作時の結線不良やデバイスの不良により、一部のネットワークの動作が不良であると使用不可能であり、また、並列・分散型のチップとすることで急激な機能低下を防いできている。ここに、学習機能を付加することで、周りのネットワークに機能が学習により分担され、機能の回復が可能となるのである。処理の流れがチップの構造的不良部分を自動的に回避するようになるためには、学習チップが必要である。

構造的な不良が機能的な不良に大きく結び付かない状況の出現は、ULSIの不良品率を低下させるのに大きく貢献するのであり、学習付加技術は超微細加工技術の発展を促すのに必要な技術である。

③通信時の制約の緩和

学習機能を外付けにすると、チップとの配線が物理的な制約を受け、情報電送路の容量が小さくなるために、学習の高速化が妨げられ、ひいては一群の処理能力が小さくなるのである。このような制約は学習機能を組み込み対処することにより制約を緩和する必要がある。


また、学習機能を組み込むため、機能モジュールとして大規模ネットワークのデザインを容易にする必要がある。

④自律的に機能形成するチップへの展開

プログラミングパワーを大きく削減するには、自律的な機能形成が必要であり、入出力に応じてネットワークの使用領域を自動的に決めて、使用中での使用条件の変更にも自動的に対応する学習チップが必要である。

(2) 学習機構の基本的な考え方


入力を目的に沿って整理してルール、すなわち情報処理機構を自動形成することを学習チップに求める。情報処理過程には明解にレベル、群が存在するものがあるが、現実の世界ではディスクリートのに区別がつかないものが多い。また、整理を容易にするために人為的に区別を設けてきたものも多い。そこで、得ようとする出力はすべて平等に扱い、処理過程を特に意識しない様に扱うことを考えるのである。ルール形成において、以前に取り込んだ入出力（知識）のルールでは処理しきれないが、関連した知識が加われば、先のルールを利用して新たなルールを構築するのが有効である。チップでは、固定された大きさのネットワークが用意されており、このネットワークの一部エリアの一部の元素に入力、他の一部の元素に出力をつなぎ、ルールを作るのである。次に、このエリア外の出力と入力の元素を含むより大きなエリアでルールを作るのである。



図表4. 2-1 ルール形成における入出力

以上のように部分的な知識を与えてルールを順次付加していくシステムでは、学習の進行が途中で中止するローカルミニマムに入ることある程度回避できると考えられる。

このような学習を可能とするには、チップの学習機能を持つネットワークを制御することが必要である。あるエリア内で、入力（希望する出力も含める）と学習ルールに従って作られたネットワーク構造を評価し、この評価と入力の変化に伴ってエリアを変更するのである。



図表4.2-2 情報処理ネットワーク

以上のことを可能にする学習チップを考えていくことにより、大規模ネットワークの構築を支援するのである。

①ネットワーク構造の選択

学習チップであっても、最も柔軟性のある往路と復路の結合を持つ全結合型のネットワークを用いるのが適しており、また、最も汎用性に富んでいる。この一部のエレメントに入力、一部のエレメントに出力が付けられるのである。

チップ間の情報伝達はチップ内に比べて物理的な制約もあり、配線が限定され、伝達容量は少なくなる。このために、チップ内は密に結合を準備しておくことが望まれる。

②ネットワークの制御を全て外部から行う場合


以上の考えに基づくチップとして、次の様な構成が考えられる。ネットワーク部分、結合荷重の記憶部分、この結合荷重を計算する部分、ネットワークの使用エリアを設定する部分の4機能部より構成される。外部からのコントロールとしては、中間部のエレメントの指定、入出力部のエレメントの指定ができなければならない。また、結合荷重の計算に多くの空間を用いない様にする事が望まれる。このため、命令したエレメントに入る結合荷重だけを計算するような制約が必要になると考えられる。

③ネットワークの評価系を組み込んだチップ

多数のチップを用いる大規模ネットワークにおいては、多数のチップのネットワークの制御を同時に行わなければならない、先のチップの構成では、ネットワークの評価と制御の計算の負荷の問題が出現する。チップにのみ依存して計算できる部分を組み込んだよりコントロールフリーのチップが、大規模化すれば要求される。

このチップでは、基本的には入力と希望する出力を与えると、チップ内エレメントが入

出力に応じて自動的に設定されることが望まれるのである。これにより、チップ内で、ローカルミニマムの回避、また、必要以上のエレメント数での過剰学習効果を防ぐことが可能となるのである。チップの構成としては、先のチップの入出力に応じたエレメント数の設定や学習の進行状況を把握したエレメント数の増減などの判断を行うネットワークの高層評価部分が付加されるのである。外部からは、異なる入力であること、異なる出力を希望することを示す必要があり、入出力エレメントの変更ができるようにするのである。



図表4.2-3 チップの構成

(3) 研究課題

①エレメント使用のルール

学習の状況进行评估して、順次必要なエレメントだけを開く、又は閉じる規則を考える必要がある。また、この中で情報処理だけに使用する固定結合荷重のエレメントと学習により結合荷重を変動することのできるエレメントの決め方を研究する必要がある。

②ネットワークの選択

チップ内のネットワークとして、全結合型を汎用性の観点から提示したが、機能が特化すれば、結合が整理されたネットワークが組み込まれることになる。機能からの構造を調べるためにも、全結合型のネットワークを用いて、機能と構造の関係を調べていく必要がある。

③エレメント入力部に論理を組み込んだ時の学習

小型で高機能化を目指す、プリワイヤリングに相当する論理機能を組み込む必要がある。この場合に、機能に応じた論理パターンを持ったエレメントの入力を用いる必要がある。

論理組み込み型では各入力端子は区別され、各端子が全エレメントに結合できる全結合型のネットワークでは、結合数を減らすために、交換機的な結合が考えられるが、この時、学習に伴う交換規則をどうするのかを考えなければならない。

④入出力間の時間差の解消

学習計算のための遅れ、エレメント間伝達の遅れが存在する。このために、入力と希望する出力間での遅れをどの様に設定するかが問題であり、これをどう自動的に調整するかを考える必要がある。特にループのあるネットワークでは顕著に現れる。

このために、結合荷重変更の計算ルールと手順を考える必要があり、同期して全体の計算を行う方法での限界とローカルルールを使用する非同期の方法を検討する必要がある。

⑤結合荷重変更の計算量の制限

全エレメントの結合荷重を常に可変にすると、学習機能のために多くのデバイスが必要となり、また、学習が不安定になる。そこで、限定したエレメントでのみ学習を行わせることを示した。この時、一度に学習を行わせるのに必要なエレメント数をいくらに設定すれば良いか、全エレメントに対して何パーセントに設定すれば良いのかを調べる必要がある。

4.2.3 学習用新計算機構の開発

デジタルニューラルネットワークの応用において必要となるハードウェアは、デジタル信号処理の応用の場合に非常に類似している。シミュレータは次の構成要素[1]を持つ必要がある。

- ・主たる計算は積和演算。
- ・積和演算ごとに概ね2つのメモリアドレスが必要。
- ・メモリのアドレッシングは規則的で予測可能。

これらの性質はデジタル信号処理におけるFFTの計算、デジタルフィルタや相関関数の要求と似ている。ニューラルネットワーク独自のものにシグモイド関数の計算があるが、これもデジタル信号処理における三角関数の補間関数に類似している。デジタルシグナル

プロセッサは商用システムとしての重要な役割もあり、すでに多くのプロセッサが開発されている。

プロセッサの演算能力のほかにニューラルネットワークにとっての要求は高速のメモリがある。この要求はニューラルネットワークの構造が、規則的で予測可能なメモリのアドレッシングを行う性質上、メモリのインタリーブ化やキャッシュ構造の利用で実現できる。デバイスでは ECLやGaAsメモリで高速化できる。従ってこれまでもデジタルシグナルプロセッサを用いたシミュレータは多く発表されている[2], [3], [4]。ニューラルネットワークの実現のための要素の1つである計算パワーは、このようにすでに存在しており、さらに高速化される見込みである。

ニューラルネットワークを実現するときに提案されるもう一つの重要な技術は超並列の計算構造の利用技術である。これは互いに接続された数多くのSISD方式やMIMD方式プロセッサで構成される。デジタルの電氣的な結合では超並列構造はプロセッサの通信方法によって制限され、この制限はニューラルネットワークの実現を制約する。従って並列プロセッサ間の通信を効率よく行うために、プロセッサの接続方法を工夫しなければならない。並列プロセッサを用いてニューラルネットワークの実現を行っている例に次のようなものがある。

- ・プロセッサを1次元配置しリング状に接続してパイプラインで積和演算を行う[5], [6], [7]。
- ・プロセッサを2次元配置し同期式又は非同期式に各プロセッサ間の通信を行う[8], [9], [10]。

ここで一般的なニューラルネットワークのシミュレーションを考える。入出力ベクトル間は完全に結合しており、Nのベクトルの要素があるとする。CPUにはWのビット幅を持つアドレス空間がC ($C=N*N$) のメモリがあるとする。分散メモリをとるモジュール通信の考え方は、各々のモジュールの処理速度をできるだけ劣化させないようにデータ通信を高速化することにある。モジュールの計算速度 R_m とシステムの計算速度 R_s は次式で与えられる[1]。

$$R_m = W / (L * C * T)$$

$$R_s = M * W / (L * C * T)$$

ここで、パラメータは次の意味を持つ。

T : 1 インストラクションの実行を行うためのCPUの所要時間

M : 用いるCPUの数

L : 積和演算を実行するためのインストラクション数

システムの性能を大きく劣化させないように、通信速度は計算速度の100倍要するとする。すなわち通信速度が計算速度の1%であるとする。これは $(L \cdot C \cdot T)$ の時間内に $(M \cdot W \cdot N)$ のデータ伝送をすることに相当し、このシステムのバス速度 R_b は、この100倍以上が必要である。従って、

$$R_b = 100 \cdot (M \cdot W \cdot N) / (L \cdot C \cdot T)$$

$$= 100 \cdot M \cdot W / (L \cdot N \cdot T)$$

$$= 13 \text{ Mbit/sec}$$

$$(T = 200 \text{ nsec}, L = 3, W = 32)$$

本評価は、 $N = 800$ までのネットワークに対して、プロセッサ規模が $M = 1$ のときから $M = 16$ までを考慮したものである。専用のシミュレータのように $M = N$ で各メモリが行列の行と列を格納するシストリックなシステムでは、データの伝送速度は毎秒ギガビットとなり、現在用いているバス方式の限界が現れる。これは単純な分散メモリ方式では、1つのネットワークに対して用いるプロセッサの数が多くなるほど、プロセッサ間の通信の負荷が大きくなるということで重要な問題である。

このようにニューラルネットワークに対して十分多くの並列プロセッサを用いると、データ伝送に要する時間を無視できない。ただし、この議論はすべてのニューロンが結合された場合であり、スパースなネットワークや限定された結合を持つネットワークでは、処理速度を保ったまま M を減少することができる。このとき単純にネットワークを分割するとプロセッサ間の計算負荷が偏り、全体の稼働効率が低下するため、プロセッサに割り付けるネットワークの規模をほぼ均等にして、負荷をできるだけ一様にする方法も提案されている[10]。

音声認識や画像認識などの実用のニューラルネットワークを構築するためには、ニューロン数が数億程度の大規模なネットワークをシミュレート可能である必要がある[1]。1次元配置のアーキテクチャに比べて、2次元配置のアーキテクチャはウェハスケールで実現することを前提としており、実装に非常に適した構造である。ところが、現状のプロセス技術では将来精密化されても、2次元の実装では、ニューロン数が数億のものは実装が不可能になる恐れがある。従ってニューラルネットワークの大規模化を前提とするとデジタルの電氣的な結合では、3次元アーキテクチャが必要になると考えられる。実際の脳

のモデル化としての観点からも3次元アーキテクチャは適当であると思われる。大規模なニューロン数を用いるニューラルネットワークであっても、1ニューロン当たりの結合数は1000程度が現実的であり、このような拘束条件のある結合を3次元アーキテクチャでどのように実現するかという点を解決する必要がある。

以上述べてきたように、大規模な超並列・超分散システムの計算機構に必要な点は、計算速度を向上させることと通信の負荷の解消である。これを実現するには、プロセッサ間の負荷が均等になるように負荷配分をしてプロセッサの稼働効率を高めることと、2次元もしくは3次元配置のアーキテクチャを採用して通信の容量を大きくすることで対応するのがよいと考えられる。局所的な結合が存在する場合やスパースな結合のネットワークでは、超並列の構造が乱れて、一様で予測可能なメモリアドレッシングができなくなるので、これを補うプログラミングが必要となる。

〔参考文献〕

- [1] "Algorithm and Solution Requirements", DARPA NEURAL NETWORK STUDY, 291-332, AFCEA International Press, (1988).
- [2] Works, G. A., "THE CREATION OF DELTA: A NEW CONCEPT IN ANS PROCESSING", Proceedings of IEEE ICNN88, 2, 159-164, (1988).
- [3] Hecht-Nielsen, R., "Neurocomputing: picking the human brain", IEEE SPECTRAUM, 25(3), 36-41, (1988).
- [4] Soucek, B., and Soucek, M., "Artificial Neural Systems or Neurocomputers", NEURAL and MASSIVELY PARALLEL COMPUTERS, 245-276, Wiley Interscience, (1988).
- [5] Pomerleau, D. A., Gusciora, G. L., Touretzky, D. S., and Kung, H. T., "Neural Network Simulation at Warp Speed: How We Got 17 Million Connections Per Second", Proceedings of ICNN88, 2, 143-150, (1988).
- [6] Kung, S. Y. and Hwang, J. N., "Parallel Architectures for Artificial Neural Nets", Proceedings of IEEE ICNN88, 2, 165-172, (1988).
- [7] Kato, H., Yoshizawa, H., Iciki, H., and Asakawa, K., "A Parallel Neurocomputer Architecture towards Billion Connection Updates Per Second", Proceedings of IJCNN90, 2, 47-50, (1990).
- [8] Bluelloch, G. and Rosenberg, C. R., "Network Learning on the Connection Mac

- hinc", Proceedings of IJCAI87, 323-326, (1987).
- [9] Cerf, G., Shea, D.G., Wilcke, W. W., and Zukowski, D. J., "Parallelizing Back Propagation on IBM's Victor V32 Multiprocessor," IBM Research Report RC13788 (#61147), (1988).
- [10] 藤本好司, 福田尚行, 赤羽俊夫, "大規模ニューラルネットワークのシミュレーションのための高度並列処理アーキテクチャ-TLAの提案", 電子情報通信学会研究報告, NC89-28, (1989).

4.3 超並列・超分散システムの構成技術

4.3.1 構造化手法の開発

人工的神経回路網（ニューラルネット）研究の現状は、機能的には単機能、ネットワーク構成としては小規模・単純構造に限定されているのが実状であり、実用的な工学システムの実現に向けて、ネットワークの大規模化に対処するとともに機能や処理を複合化・統合化する構造化手法の開発が望まれる。

ニューラルネットは、ユニットとユニット間を結ぶ荷重付きコネクションという共通の構成要素を用いて、異なる機能や処理を同一の学習アルゴリズムによって実現できる。その意味において、ニューラルネットは異なる機能や処理を有機的に結びつける構造的な利点を有している。しかしながら、機能・処理の複合化・統合化のために、単純にネットワークを大規模化するのは、

- ・学習の収束性が悪くなる、あるいは、
- ・そのための計算時間が増大する、さらに、
- ・機能の追加や拡張時全体の再学習が必要となる、

など、かえって欠点の方が強調される結果となる。

従って、ニューラルネットの利点を活かしつつ大規模化に伴う上記の欠点を回避できる構造化手法がますます重要となる。

(1) 構造化手法開発の基本的な考え方

最も有力と思われる構造化手法の考え方は、モジュール化である。すなわち、比較的小規模なニューラルネットをモジュールとして、それら複数のモジュールを用いて全体の系

あるいはシステムを構成する考え方である。以下に、モジュールベースの構造化手法の特徴ならびに考慮すべき点を挙げる。

- ・各機能ごとにあらかじめ学習したニューラルネットをモジュールとして系を構成し全体の調整を図る方法であるため、効率的・迅速なシステム構成が可能となる。また、機能の追加・拡張に伴う系全体への影響を最低限にとどめることができる。
- ・各モジュールは比較的小規模なネットワークなので、LSI によるニューラルネットの具現化が容易である（ある意味での部品化）。
- ・モジュールのネットワーク構成を幾つかに規格化し、さらに学習後の重み情報を一種の獲得された知識としてデータベース化すれば、さらに効率的なシステム設計が可能となりニューラルネット利用製品の開発を加速できる。
- ・モジュール間のつながりや関係の記述、モジュールの起動・同期制御などにシンボル処理を導入して、学習やシステム状態の制御など透明性の高いシステム構成が可能となる。

(2) 検討課題


モジュールベースの構造化手法の検討課題は、モジュール化そのものに関するものとシステム構成に関するものとに大別できる。

モジュール化そのものに関する課題は、単機能・小規模・単純構造のネットワークを対象とした現在の研究課題と基本的には同一であり、入出力情報の表現方法、学習の収束性・安定性・般化性、計算量、既存知識／知見のネットワーク構成への活用方法、さらにはLSI化技術との整合性などに関するものである。さらに、モジュール化の観点からは、モジュール外から内部での学習を制御できる学習アルゴリズムやネットワーク構造、重み情報をアップロード、ダウンロードできる回路構成などが重要となる。


システム構成上の課題は、モジュールで構成された系の学習法・全体調整法、モジュール間結合方法、同期制御法、また、モジュール間の機能分担などである。モジュール間の結合方法としては、特定ユニットの出力をコンテキスト情報として他モジュールへ与えたり、重みを修飾するなどの方法も一部報告されている。しかし、前述したように、システム構成上はシンボル処理の利用は必須であり、ニューラルネットでの処理とシンボル処理をいかにうまく組合せ機能させるかが重要となる。

以上は、工学的な観点から、全体系の機能構成をトップダウンに与え各々の機能をモジュール化する考え方を示したものであるが、全体系の機能設計や機能間で授受される情報

表現などに関して生理学的知見を大いに活用することも当然必要である。構造化という点では、生体は長い進化の過程で機能の分化と構造化を達成した。純粋な形で機能の分化と構造化を工学的に実現するのは当分先の話であるが、分散・独立化した機能モジュールを前提に外界とのインタラクションを通してモジュール間の結合を自己組織的に学習・形成するモデルなど近未来の課題として検討できよう。



図表4.3-1 モジュール・ベースの構造化手法の考え方



図表4.3-2 ニューラルネットワークモジュールで構成された情報処理モデル

4.3.2 自律分散形階層制御システム

(1) 自律分散形階層制御システムとは

戦後の技術の流れの特徴は、大規模化、集中化にあり、それによって効率のよい生産体制、経済体制が組み立てられてきた。情報制御システムも例外ではなく、大型計算機をベースとする集中制御方式が主流であった。しかし、システムが大規模で複雑になるに従い、集中形の問題点が指摘されるようになり、自律分散形制御が注目されるようになった。

集中制御がセンター一ヶ所に情報を集め、それに基づいて制御を行うのに対し、分散形制御は、複数のサブセンターを用意し、それぞれに集められたサブシステムの情報をもとに、サブシステム毎の制御を行うとともに、サブシステム間の情報を交換して、全体として目的にかなった制御を行おうというものである。

なお、自律分散制御というときは、各サブシステムが自律性を与えられているということであるが、ここでいう自律性とは、各サブシステムには、それぞれの入力情報に基づいて制御信号を出力できる判断能力が与えられていると、とりあえず定義しておく。とりあえずと書いたのは、システムとして興味ある機能をもたすには、サブシステムのこの入出力特性に何等かの制限を加える必要があるからである。

このように、情報処理および制御を、自律性を持った複数のサブセンターに分担させる方式が自律分散形システムであるが、次に問題となるのは、サブシステム間の協調の仕方、サブセンター間の通信ネットワークの張り方である。

サブシステムの数が少ないときは、相互結合形（いわゆるネットワーク形）をとり得るが、多くなると、階層構造の導入が必要になる。すなわち、全体を幾つかの部分的なネットワークに分け、各ネットワークで集約された情報を交換する通信ネットワークをその上に構築する。この構造を必要な階数だけ積み上げるのである。これを自律分散形階層制御システムという。完全な分散ネットワークおよび一極集中システムは、その両極端な場合である（図表4.3-3）。


ムが一旦分解され、新たなシステムが形成されるときは、他の役割を分担させることが可能となる。これは、従来の工学システムではとられていない設計原理である。

自律分散形制御システムの設計に当たっては、生物の採用しているこの原理が参考になる。この原理を理論化するには次のことを明らかにする必要がある。

すなわち、どのような①自律性、②相互作用があれば、他の要素との相互作用の結果として、構造的あるいは機能的に意味のあるものを作り出し得るか。特に、ボトムアップ的に階層構造を形成するには、要素間の相互作用の結果として生成される上位システムが、さらに上位のシステムのサブシステムとして自律的に機能するものでないといけない。そのような可能性をもつ①自律性、②相互作用とはどんなものを理論的に考察する必要がある。

ところで、①自立性と②相互作用を規定すれば、ある境界条件のもとに、一つのシステムや構造が自己組織されるわけであるが、ここでの学習の役割について付言しておこう。

生物系もそうであるが、工学システムには目的があり、システムは合目的々に自己組織化されなければならない。そこで、何らかの評価関数を決めて、それを最大にするように自律性や相互作用の性質を修正するという手続きが考えられる。もし、この手続きが局所的な性質のものであれば、超並列・超分散のアーキテクチャとよい整合性をもつので、新情報処理システムの設計原理として期待される。どのような評価関数・どのような学習手続きをとるべきかは、今後の明らかにすべき課題である。



図表4.3-4 自律分散システムの自己組織

4.4 シンボル処理との融合システム技術

4.4.1 分散形シンボル処理システムの開発

(1) 研究の現状

ニューラルネットは従来の逐次型計算機が不得意であったパターン認識などに優れるが、現状ではシンボル処理は余り得意でない。しかしながら、人間の脳は分散形システムである神経回路網によってシンボル処理や論理処理も行っている。工学的には、現状のニューラルネットと人工知能などを結合することによって、パターン処理とシンボル処理とを行うことも考えられるが、人間の脳と同様に、分散システムでシンボル処理をも行うシステムが考えられる。シンボル処理をも分散システムで行うのは、それによって、人間の脳の高い柔軟性を解明し、また、それを工学的に実現する手段を知る道が開かれることを期待するものである。この問題には、人間の脳内知識表現など、生理学でも未解明の事柄が密接に関係するため、現状では研究は活発とはいえないが、次のような研究が見られる。

(a) コネクショニストエキスパートシステム

Northeastern大学のS. I. Gallant 氏によって提案されているMACIE(MATRIX Controlled Inference Engine)は知識ベースとしてコネクショニストネットワークを用いたものである。このシステムは従来の逐次型のエキスパートシステムのボトルネックとなっていた知識獲得の問題に対し、コネクショニストモデルの学習能力を利用しようとするものである。学習にはポケットアルゴリズムと呼ばれるアルゴリズムを用いている。これは出来るだけ多くの事例に対して矛盾のない回答を出すようにユニット間結合の強度を調整するものである。生体との対応は特に意識していないが、各ユニットは概念に対応しており、脳内知識表現の立場からは、集中表現に属する。

(b) 並列推論システム

これは、MITのG. E. Blelloch氏によって提案されているものでCIS(Concurrent Inference System)と呼ばれるものである。これは if-thenルールベースをネットワーク化したものであり、Connection Machineによって計算する。前向き推論と後向き推論、および、あいまいさを含む推論が可能であり 100,000ルールで1回の推論時間は2秒以下であるとされているが、やはり、生体との対応は薄い。特にこのシステムでは学習が含まれない。

(c) 記号推論アーキテクチャ

これは、CMU の D. S. Touretzky氏とG. E. Hinton氏によって提案されているものである。人間の脳内知識表現については、一つ概念が一つの神経細胞に対応すると考える集中表現と、多くの神経細胞群の活性化パターンに対応すると考える分散表現の考え方があるが、この研究は後者の可能性を探求したものである点が興味深い。但し、この研究も知識表現として if-thenルールベースを採用しており、生体に照らして不自然である。

(2) 研究課題

このように現状では、分散型システムによる演算を対象とはしていても、人間の脳の仕組みを十分に参考にしたものはなく、今後の研究に期待するところが大きい。このような現状に対処するために、次のような研究課題が考えられる。

・大規模コネクションコンピュータの開発

ニューラルネット構造で論理的な知識処理も一部あるいは全部を行い、パターン認識的処理と論理処理とが高度に融合したシステムであり、ハードウェアとしては、人間の脳に近くなっているため、知能シミュレータとしての位置づけがされる。このようなシステムでは、外部から与えられる事例パターンに対するシナプス強度の修正といった形態の学習だけでなく、ネットワーク構造の変更を伴う自己組織化なども含める必要がある。個別的な研究テーマとしては、(1)データ表現および処理技術、(2)自己組織化技術、(3)統合システム開発、などが挙げられる。このような研究には、生理学的な知識の蓄積に加え、適当な工学モデルを仮定し、そのシミュレーションを行ってモデルの妥当性を検討するといった計算論的なアプローチが重要となる。

4.4.2 シンボル処理とパターン処理との融合システムの開発

(1) アプリケーションの立場から見た融合システムの研究

上述の分散形システムによるシンボル処理の研究は、現状では完全には解明されていない、多くの学問領域の知識が必要であり、基礎研究の範疇に属する。しかしながら、工学的な応用では、すべての処理を分散形システムで行わなくともよい場合も多い。そこで、本課題では、ニューラルネットモジュール群とデジタルコンピュータとを結合し、パターン認識的処理はニューラルネット、論理的処理はデジタルコンピュータという分担をする

ようなシステム、すなわち、複合形コンピュータとも呼べるシステムの構築技術を開発する。このような簡単な考え方に基づく場合でも、従来の計算機に無い柔軟性を追求すれば、解決すべき幾つかの課題が生まれる。すなわち、モジュールを結合したシステムではあってもニューラルネットの持つ事例教示による知識獲得という利点が極力保持される必要があり、①事例学習方法の確立、②ニューラル・デジタル統合技術、等の研究が必要である。

(2) 科学の立場から見た融合システムの研究

シンボル処理とパターン処理との融合システムを考える際、3つの構成手法が考えられる。現在行われているのは、シンボル処理アーキテクチャの枠内でパターン処理のシミュレーションを行い、パターン処理結果をシンボル処理で使う図式である。本質的な大規模パターン処理を行えない欠点を持つ。第2の近未来的に実現されそうな構成法は、シンボル処理アーキテクチャと超並列・超分散処理アーキテクチャを結合し、シンボル処理結果とパターン処理結果を相互にやり取りする図式である。第3の図式は、超並列・超分散アーキテクチャの下で全てはパターンとして処理されるが、シンボル処理も近似的にしるパターン処理で実現され、両者が見え隠れしながら同時に存在する処理様式である。

この第3の融合システムの図式では、人間が行っているであろう処理様式として、非常に興味のある特性を持った情報処理系が構成できる。本質的に新しい情報パラダイムとも関連している。例えば、人間的な問題解決を可能にする柔軟な知識表現や記憶、あるいは推論機構などは、超並列・超分散アーキテクチャの処理構造の上に構成されたパターンの性質を持ったシンボル情報処理であると理解できる。

しかし、この方面の研究は余り行われておらず、例えばルール解釈を超並列・超分散システム上で実現するための理論的研究やパターンとシンボルの関係についての考察等は最近始まったばかりである[1]。

このように、第3の図式の融合システムは、非常に面白いものであり、融合システムの構成や融合のための厳密な理論の開発自体が今後の研究課題となっていることを指摘しておく。

〔参考文献〕

- [1] Paul Smolensky, On the Connectionist Reduction of Conscious Rule Interpretation, Proceedings of 11th Cognitive Science Society (1989).

4.5 発達・分化の工学的実現に向けて

4.5.1 生物における発達・分化

生物は機械と異なり、自らが内在する自律分散制御システムにより、生存していくために、環境により適合して発達する。そして、連続した時間のなかで、調和を保ちながら構造を分化して、より高度な機能を作り上げている。この発達のメカニズムと機能に対する構造の分化の知見を、新たな情報処理構造の構築の参考とする。

(1) 発達・分化の基本システム（自律分散制御）

生体は常時、環境に適合して、生存しようとし、そのために、環境変化に対する適応システムが作動し続けるのである。この外部変化を取り込んで、内部に新しく適応するための回路（化学反応連鎖、細胞間の化学、電気回路）を作れるような能力、柔軟なシステムが存在するのである。このシステムは生体の特徴である自己組織性の能力によって自律分散的に制御されるのである。

生体は各レベルにおいて、多くの自律分散のサブシステムから構成され、各々が他との競合と強調により、全体として環境に適合するように学習し、発達・分化として記憶がなされているのである。

① 生物の自己組織性

生物の自律分散制御の基本となっているのがこの性質である。細胞は周り細胞などから情報を取り入れて、自ら持つローカルルールのパラメータを変更し、周りと競合と協調をして、機能的な組織を構築していくのである。神経系では、自己組織性は周りの神経細胞からの化学的シグナルなどにより細胞自らがシナプスを形成したり、このシグナル伝達率を変化させる能力である。

現在のデバイスでは、自ら構造の変化を起こすことはない。生体では、素材が不安定で、崩れようとする構造に自律分散処理制御で素早く対応しているのである。また、大規模ネットワークの形成は、自律分散制御に容易になり、自己組織化の機能を持つ素材が開発されれば、より促進されるのである。

② 生物の物理的制約—素材の不安定性

生物を構成する主な機能分子はタンパク質であり、ほとんどが非常に不安定な分子である。またこれらの組織体である細胞はある程度耐環境能力を保持しているが、不安定な物

である。この不安定性を積極的に利用して生物は進化し、環境に適合してきた。このような不安定な素材を用いるときには、個別に高速で対応する生物のように自己組織性を持ったシステムが必要である。

(2) 発達・分化の発現


生体で具体的に発現しているものとしては、生物個体の発達・分化であり、これは細胞の分化（機能と構造）と細胞数の増減（増殖と死滅）による細胞の集合（組織）での機能変化から起きるのである。

① 細胞の分化

分化を促す要因として、細胞内では、DNA を基本プログラムとしたタンパク質合成の制御、細胞内器官の偏在などが挙げられる。細胞外では、個体内と個体外の情報に分けられ、前者には細胞との接着（物理的刺激と化学的刺激）やホルモン（化学的刺激）などがある。後者では、個体外の環境（温度、湿度etc）などがある。

神経細胞では、情報入力部の樹状突起や軸索の伸展、シナプスの形成では、構造の変化（分化）が情報処理機能での変化をもたらしている。

分化を細胞と言うデバイスの情報処理として眺めると、ホルモン放出の発現の場合には以下のように、代謝制御ルールが自己組織化を助けていると考えることができる。このような2重の制御構造にすることにより、自己組織化機能に一步近づけるのである。



② 細胞数の増減

細胞分裂は細胞内の状態、細胞間の相互作用、物理的作用（温度など）によって引き起こされる。細胞数の増加により、情報処理や制御の容量が増大し、機能のバリエーション

が増大して、機能が高められるのである。

(3) 淘汰による発達

細胞、組織、個体の各レベルにおいて、置かれている環境に適合していないときには、成長が抑制され、死滅が促進される。このときに、生体はルーズな複製機能をもっているために、増殖の時にかなりのバリエーションができています。このバリエーションの一部が環境に適合して、生き残る。何世代にもわたって適合の処理の履歴を持ち、変化したDNAにより、異なるバリエーションを持つようになり、新しい環境変化に対応するのである。

・淘汰による整理と機能的進展

脳では、神経細胞の配置及び基本的な回路網構造が出産前にすでに作られている。すべての細胞の配置・構造の情報はDNA が持ちうる情報以上に大きいことが知られている。この条件を満たした構造形成を説明する現象として、胎児の脳の神経細胞が、出産前に大きく減少することが知られ、ルーズなルールによって配置させられた後に、異常な位置の細胞が死滅するためと解釈されている。

ネットワークが大規模化していくにつれ、ネットワークの構造を制御することが必要になる。強制的な淘汰の概念の導入は、この構造の制御に役立つと思われる。

(4) 機能部位の発達と分化

脳は均一な回路網構造を持っているのではなく、各種機能の分化したネットワーク、また各種形態の神経細胞から成りたっている。高等動物では脳は発達し、下等動物の脳のに相当する部分から新しい部分が分化した構造が見られる。

また、環境に適合するために特に発達した感覚を持つ動物では、脳の皮質で機能を反映する部分が相対的に大きく取られている。環境に適合するために、感覚を研ぎ済ます必要があり、このための情報処理の量と高機能化が求められ、何代にもわたって皮質での領域を広げたのである。

高次機能のコンピュータの構成法を、発達し分化した高等動物の脳が示唆している。時間をかけて調和を保ちながら徐々に細かいサブシステムに機能分化させ情報処理システムを構築していくことが必要で、また、このための学習手順と柔軟なネットワーク構造が求められるのである。

(5) 外への働きかけ

動物では、単に環境からの信号に対して受動的に反応するだけでなく、より積極的な働きかけが見られるのである。環境に適合する場合に、一面から適合するのではなく、もっと多くの面から学習し適合するのである。これにより新しい機能を作り出し、これらが組合さってより幅広い環境変化に適応するのである。

動きを伴って知識獲得を積極的に行い、学習をしていくことが発達には必要で、このことは、高次情報処理システムの大規模ネットワークを構築するのには、感覚-運動システムでの学習が必要であり、将来のコンピュータの姿を示唆している。

(6) 情報の生成

生物の特徴は、分子レベルから熱雑音などによる「ゆらぎ」を持ち、構造形成に利用していることである。このゆらぎは生体にまれにしか起こり得ない状態も作り出す。この現象の一つは、突然変異である。また、脳・神経系でもゆらぎにより新しい状態が作られ、クリエイトが行われることが示唆されている。この様な情報の生成により、適応に対して新しい状態が作られ、発達が促進されるのである。

ゆらぎにより、取り得る状態が効率的に圧縮されていると解釈できる。これから応用しようとする問題の取り得る状態数がその時の技術（メモリと呼び出し速度）を越えていなければ、この圧縮は必要がないが、ネットワークが大規模化すると必要になると思われる。

(7) おわりに

生体は単なる可塑性の情報処理系を持つのではなく、この処理系をどう維持していくかというシステムを持っている。細胞レベル以上での情報処理系に低いレベルからの維持システムがあり、これが自己組織性を構成している。学習機構の研究では、処理系の制御システムを付加する方向で研究していく必要があると思われる。

4.5.2 発達・分化システムの設計について

現在の超並列・超分散システムの学習・自己組織化は、誤差逆伝搬学習で良くみられるような数段の層状回路、あるいはボルツマンマシンのような全相互結合を持った小規模な超並列・超分散回路の学習にとどまっている。この意味での学習・自己組織化は、最初に与えられた回路構成の内部結合の調整にとどまり、回路構成を含めた最適化ができない。

この回路構成を含めた最適化の問題は、大規模な超並列・超分散システムの構成において、より重要になる。すなわち、大規模システムの設計では、始めから最適な設計が出来ないこと。さらに、大規模なシステムをそのまま学習で実現させることが困難であり、また効率的でないことがある。

本節では、このような「大規模な回路をどのように構成すべきか？」という回路構成の問題点に、「環境に適合して発達する」生物の発達・分化メカニズムを工学的に反映させることを検討する。


(1) モジュールの自己組織化によるニューロコンピュータの設計

現在、 N 個のニューロンからなるニューロコンピュータにおいて学習を考えると、ニューロン間にはあらかじめ N^2 個のランダムなシナプス結合を用意しておき、学習を通じてシナプスの伝達効率を変化させていくという方式が取られている。その結果、伝達効率がほとんど0となるシナプス結合もあり、このようなシナプス結合に対応する結線自体が不要であることを意味している。ハードウェアへのインプリメントにおける困難が配線数の顕著な増加にあることを考えると、この方式は無駄が多いうえにハード化も難しい。また、学習に多くの時間を要することも予想される。従って、初期の段階からプロセッサ自体に構造化を含めた学習を行わせるのは得策ではない。では、無駄な配線をせず、なおかつ学習速度を上げるようなニューロコンピュータを実現するためにはどのようにすれば良いのであろうか。


ところで、実際の脳におけるシナプスの可塑性は便宜上二つの範疇に分類できよう。すなわち、①構造の自己組織化における可塑性と、②学習における可塑性である。ここで、構造の自己組織化とは、おもに大脳皮質に見られる基本的な機能的モジュールであるさまざまなコラム構造の形成過程を意味する。従って、①の可塑性は大脳の発達の初期、特にいわゆる臨界期における可塑性と同義である。この時期にシナプス結合の基本的パターンがほぼ確定してしまうと考えられる。また、②の可塑性は臨界期後の可塑性またはアダルトにおける可塑性を意味している。基本的構造が①の可塑性によってだいたい確定した後に、②の可塑性によってシナプス結合における伝達効率の微調整が行われ、より柔軟に情報処理が行えるようになると思われるわけである。

上で述べた二つの可塑性の概念をニューロコンピュータの設計及び学習の過程に適用することについて以下で簡単に述べる。

入力信号における相関関数



（ 大脳皮質における
自己組織化の理論
に基づくアルゴリズム
を用いて計算 ）



モジュール およびチップ 間の
ネットワーキングに対する
設計図

ハード化

図表4.5-1 モジュールの自己組織化によるニューロコンピュータの設計

(a) ニューロコンピュータの設計について

特徴抽出および統合に適したモジュールを自己組織化のアルゴリズムに従って設計する。すなわち、チップ間の配線図を自動生成させるのである。注意しておきたいことは、プロセッサ及びモジュール自体が自己組織化するのではなく、自己組織化の理論に基づくアルゴリズムに則りチップ間及びそれらからなるモジュール間の配線を設計するということである(図表4.5-1 参照)。これは現在のCAD技術の延長線上にあり、設計図の自動生成を意味する。ここでいう自己組織化の理論については最近いくつかの提案[1], [2], [3] があるが、基本的には入力信号に内在する統計的性質(相関関数)が与えられれば、その信号からある種の特徴を抽出するようなコラム構造が自己組織化されるというものである。

(b) ニューロコンピュータの学習について


(a)の基本構造の設計図に従って構成されたプロセッサは使用目的を意識したものであるが、さらに使いやすいものにするためには実際の場面において学習させる必要がある。そのために、構成要素の最小単位であるチップには学習可能なものを使用し、ヘッブ則などの学習則に従ってシナプス接合の伝達効率に変化しうるようにする。すなわち、(a)である程度の専門的モジュールからなるプロセッサを用意しておき、(b)で現場のニーズに対応したものとなるようにモジュールを構成しているチップに学習させるわけである。

(2) 遺伝アルゴリズムによる回路構成の発達・分化[4]

生物は、環境に対する適応性を持っているが、時間レンジの異なった2種類の適応メカニズムを持っている。1つは、個体レベルの後天的な学習・自己組織化であり、もう一つは、遺伝と淘汰による発達である。前者が、遺伝で決定した大枠内での適応であるのに対し、後者は種が持つ大枠を環境により適したものに変わっていくメカニズムである。神経回路構成の大枠も、遺伝的に決定されていると考えられている。

本項では、遺伝と淘汰のメカニズムが持つこの性質を、超並列・超分散システムの回路構成の発達に利用しようとすることを検討する。

ここでは、層状の超並列・超分散システムの回路構成の枠組みが、遺伝子により図表4.5-2のように表現されているとする。遺伝子の各ブロックは、相関の結合や層内のセルの数を表現している。学習アルゴリズムと自然淘汰に従う、回路の発達過程を図表4.5-3で説明しよう。初期状態において、様々な遺伝子があり、それを反映した様々な回路構成が存在している。




図表4. 5-2 遺伝子表現と回路の表現[1]

遺伝アルゴリズムは、2つの遺伝子を切断して交換して新しいタイプの遺伝子を作る「クロスオーバー」と、遺伝子の記述の1部を書き換える「ポイントミューテーション」という遺伝子操作からなる。この遺伝子操作により、2つの親に似ており、かつ新しい回路構成が設計されることになる。

このように設定された回路をランダムに選択し、ある学習課題を行わせ、その学習の評価を行い、評価の高いものだけを親として新しい回路を再び遺伝アルゴリズムに従い生成する。この生成と評価を繰り返す。

このような環境の下では、結果として、ある学習課題に適した回路だけが、自然淘汰され残ることになり、回路構成の発達が実現される。



図表4.5-3 遺伝子アルゴリズムと自然淘汰による回路の発達過程[1]


(3) 最適負荷配分アルゴリズムによるニューロコンピュータの設計

生物の外部刺激に対する適応性を、ある試行の結果、これの評価を取り込んで最適化することによって得られるメカニズムと見なして神経回路構成を設計する。さらに、学習・自己組織化が進行して神経回路の構造が変化しても、計算速度を低下させないようにハードウェアに搭載する仮想的なニューロンやシナプスを最適に配置するアルゴリズムを用意する。この回路構成で必要となるのは、学習課題に対して試行を行う神経回路と、本試行の速度を評価する機構と、評価の結果によって内部状態を変更できる機構である。

大規模なニューロン数からなる神経回路網を工学的に実現するとき、すべてのニューロン間の結合を用意することは配線あるいはメモリの資源の観点から現実的ではない。ニューロコンピュータの設計には、1プロセッサに対して1ニューロンを割り当てる方法と複数ニューロンを与える方法があるが、ここでは、大規模な回路を処理するのにインプリメ

ントしやすい後者について考える。


脳の構成からみても、ニューロン数は変わらないで、シナプス結合の形態が変わると見なして良いので、初めに使用するニューロン数は不変にして、1プロセッサに割り当てるニューロン数はほぼ均等しておく。そしてどのニューロン間も接続可能にする一方で、各ニューロンに連結するシナプス数は上限を設けておき、初期の接続ルートは、局所的に接続を限定したランダムにしておく。プロセッサ間の接続は図表4.5-4に示すようにメッシュ構成をとる。学習が進行して、内部状態の変更が必要となったとき、ニューロン間に結合が存在していれば、結合の強度に対応するハードウェアの資源、例えば、メモリの値を変更する。学習の途中で結合値が十分小さくなり、その結合が及ぼす影響が小さくなったと見なすと、メモリを解放して、学習計算時間を短縮する。初期設定の具合で、ニューロン間に直接結合がないところでも、間接的に互いのニューロンを接続したい要求が発生すれば、メモリを空き領域から動的に配置して結合値を設定する。



図表4.5-4 プロセッサの構成

このようにニューロン間の結合関係をフレキシブルにすると、プロセッサに割り当てられているシナプス数が変化するため、初期にプロセッサを最適に配置していても、プロセッサ間の計算負荷に偏りが生じて、システムの計算効率が低下する。有限なハードウェア

資源でこの問題を解決するためには、プロセッサ間の計算負荷をできるだけ均等に保つ必要がある。このためには、プロセッサごとに計算速度を監視する機能を設け、ある学習課題を終えるごとに、速度の差が顕著なプロセッサ間では、プロセッサに割り当てられている、ニューロンやシナプスを一部交換するアルゴリズムが必要になる。ここに、ニューロンとシナプスのプロセッサ上への最適配置問題が生ずる。シミュレーテッド・アニーリング法[5]などによる解決方法を利用する他に、簡便な方法としては、図表4.5-5のように各プロセッサに割り当てられているシナプス数を均等配分する手段がある。負荷配分は計算を行いつつ、同時に実行されるのが望ましい。もしもプロセッサに障害が起こって使用不能になっても、プロセッサ間の結合がメッシュ構造をとっているため、負荷配分アルゴリズムによって、フォールトトレラントなシステムを実現できる。



図表4.5-5 負荷配分アルゴリズム

小規模なネットワークの実現では、ネットワークに対して十分なプロセッサを用意する場合、1プロセッサ当たりのニューロン数やシナプス数が少なくなると、プロセッサ間の情報伝送時間を無視できなくなる。しかし、大規模な回路においては、有限のハードウェア資源では計算時間の方が十分大きいとみなすことができ、計算負荷の効率的な配分が学習速度を劣化させない有効な戦略となる。

〔参考文献〕

- [1] S. Tanaka, Theory of Self-Organization of Cortical Maps : Mathematical Framework, to be appeared in Neural Networks.
- [2] R. Linsker, From Basic Network Principles to Neural Architecture : Emergence of Orientation Columns, Proc. Natl. Acad. Sci. USA83, 8779-8783, (1986).
- [3] K. D. Miller, Keller, J. B., and Stryker M. P., Ocular Dominance Column Development : Analysis and Simulation, Science 245, 605-615, (1989).
- [4] Harp etc., Designing Application-specific neural Networks using the Genetic Algorithm, NIPS'89 (1989)
- [5] S. Kirkpatrick, C. D. Gelatt, Jr., and M. P. Vecchi, "Optimization by simulated annealing", Science 200, 671-680, (1983).

4. 6 学習の認知科学的及び心理学的解明

(1) 新情報と認知科学、心理学との関係

新情報処理は、今までの計算機技術・情報処理技術が見過ごしていた、また取り扱うことの困難な人間的な柔らかな情報処理を可能にすることを目指している。この意味で、人間的な情報処理のソフト面の性質を明らかにする学問である認知科学や心理学への期待も大きく、新情報処理の開発という工学的目標を達成するためにも、認知科学や心理学との積極的な研究交流を行う必要がある。

しかも、新情報が超並列・超分散システム等を前提とした新しい情報処理体系の開発を従来技術と対比するものとして確立しようとしているように、認知科学や心理学でも従来の枠組みを飛び出し、新情報と同一の方向で新パラダイムを打ち立てる研究が必要になっている。具体的にここで研究が要求されている新パラダイムとは、シンボルの逐次処理パ

ラダイムに対する超並列・超分散パラダイムである。

このような状況での、新情報と認知科学との関係は単なる研究協力といった既成学問分野間の弱い協調関係以上のものとなっている。つまり、新情報で実現する機能の多くが人間の学習、認識、問題解決といった認知機能を評価基準としているため、認知機能に関する認知科学での研究成果を必要としている。また、認知科学における研究を加速するためには、新情報技術を活用する必要がある。

(2) 学習・記憶機能の解明

新情報で工学的実現を目指すため、認知科学や心理学での解明を期待する学習・記憶機能は、極論すれば「人間的な記憶機能」であり「人間的な学習機能」である。

「人間的な記憶機能」で意味するところは、新情報システムは、現在の計算機システムが仮定するVLSIメモリのような単純にビット列を蓄える単純な記憶ではなく、人間的な柔軟な記憶システムを前提とした情報処理系であることである。ここで考えられる人間的な記憶の特徴としては、知覚的表現が豊かである、時間情報（時系列）が表現できている、知覚、認識、行動の各レベルでの記憶にスキーマ的な記憶の構造がある等である。具体例としては、不完全情報からその状況に一番ふさわしい情報を想起する「連想記憶」、視覚的情報を含めた事象の時系列変化をそのまま記憶、再生できる「エピソード記憶」、各レベルでの「スキーマ記憶」等の実現がある。

これらの記憶系の性質を明らかにし、超並列・超分散アーキテクチャでの実現モデルを与えるのが認知科学と心理学の課題である。しかし、この課題の追求は、新情報システムで実現を目指す超並列・超分散アーキテクチャで具体的にサポートされる必要があり、そのため新情報プロジェクトとの協調的研究体制を構築する必要がある。

「人間的な学習機能」で解明を目指すものも、今までの学習研究で無視してきた様々な側面に、改めて焦点を当てたものになるう。

学習の心理学的な最も広い定義は、「学習とは経験による、比較的永続的な行動の変容」である。もう少し、分析的な定義は、人間の問題解決における学習等も具体的に取り扱えるように、

- ① 外界との相互交渉を通じて知識を集積していくこと、
- ② その知識を様々な仕方で構造化・再構造化すること、
- ③ 特定の状況で利用し易いように、知識表現の形式や構造化の仕方を調整すること

と等を含む多様な認知的活動である。

学習の構成要素には、多様な認知的活動が含まれている複雑な認知過程であることが分かる。また、学習に関与する認知活動にしても、実行するタスクのタイプに依存して、多様に変わる。また「理解とは何か?」、「構造化とは何か?」等多くのまだ分かっていない未定義現象を含む。そのため、心理学や認知科学での学習研究はなかなか進まなかったといわれている。

従って、具体的な研究を進める場合には、具体的な問題解決の領域を分析し、しかも上述の①～③の特定の問題に焦点を当てた学習問題を定義する必要がある。

それらの中には、本調査研究の中での指摘されたような、論理的知識の（ニューラルネット）学習における役割、論理的知識のパターン認識における役割、意識制御と無意識制御の関係などの問題の解明が含まれる。これらは、いずれも従来の逐次型のシンボル情報処理パラダイムの枠組みからだけでは解決できない問題である。

これらのことを確実に実行して行くのが、認知科学と心理学とに与えられた課題である。

しかし、この点に関しても、新情報は新パラダイムの工学的実現を認知科学と心理学研究のツールとして提供する立場にあり、協調的研究体制が取られる必要がある。

4.7 学習の生理学的解明

学習で知識を蓄え情報処理を行うシステム（学習型コンピュータ）を工学的に実現するために、このタイプの情報処理・学習記憶に注目すること（3.4節参照）は自然であろう。もちろん、このことは生物の仕組みを知ることが、学習型コンピュータの工学的実現のための必要条件であることを意味するものではないし、また、生物の仕組みを知ることが実現のための十分条件にさえなり得ないかも知れない。しかし、生物が学習型コンピュータを実現していることは、この型の実現が可能である証明を少なくとも得ている訳で、必ず工学的産物ができることを意味している。ここでは、学習型コンピュータ開発のための脳研究の必要性とその進め方について考察する。

脳そのものを研究する医学者と学習型コンピュータ開発の為に脳を研究する理工学者では研究の目指すところも進め方も当然異なる。理工学畑からの脳研究の位置づけとして、次の2点が考えられよう。

第1は純工学的側面から学習コンピュータの規範として脳の、特に学習機能に着目しての

重要性からの研究である。第2はコンピュータの人間性に及ぼす影響の強さから、人に関する理解をさらに深めて人に合ったコンピュータ開発を行う重要性の為の脳研究である。後者については、認知心理学と脳生理研究がうまくコンピュータ工学に結びつくことが望まれる。ここでは、前者に対して考察する。

生物機能のうち脳の情報処理は最も高度に分化したものであり、脳の情報処理の妙を解明することにより、ここから必ず工学的ヒントが得られることが期待される[1]。しかし、脳は巨大な情報処理システムであるので、そのすべてを完全に理解することは未だ相当な時間を要し、これを待って工学的実現をはかることはできないであろう。そこで学習型コンピュータ実現を目指す脳研究は脳の学習機能の解明に集中すべきものと考えられる。これは学習型コンピュータの先陣としてのニューロコンピュータが現在障壁としている問題の一つが新しい学習アルゴリズムの創成であることにもよる。逆誤差伝播の学習アルゴリズムは小規模ニューラルネットには効果を発揮しても大規模システムには適当でないことが実証されている。脳の学習アルゴリズムの解明は現在ニューロコンピューティング研究のかかえる学習効率の改善に大いに貢献することが期待出来る。

具体的には、学習に関与する脳として海馬が考えられるので、まず海馬の脳における役割の解明が重要と思われる。研究は2つの側面からなされるべきで、一つは海馬を構成する神経細胞とこれら神経細胞からなる特異的集団（神経回路）の性質を明らかにすることである。現在ニューロコンピューティング研究では基本構成素子として人工ニューロンという非線形（しきい値）論理素子を仮定している。しかし、脳の基本構成素子である神経細胞はそれが果たすべき情報処理・学習記憶によってそれぞれ高度に機能分化しており、いわば「ある種の記憶作用を有する超 LSI マイクロプロセッサ」にたとえることができる。もちろん、「トランジスタ」にたとえられる人工ニューロンによって、神経細胞という超 LSI マイクロプロセッサを構成することで、脳の情報処理を逐次組み上げることは可能かも知れないが、ここでまず重要なことは、どんな特性の神経細胞がどのように組合さって海馬の機能が生み出されているか、を知ることである。このために、海馬スライスの神経回路の活動を無侵襲に多点(256~10⁵点)同時に計測することが重要であろう。これは、各種の特性を持つ神経細胞からなる特異的集団の振舞いを、神経活動の時、空間パターンの学習に伴う変化を海馬全体から広範囲に計測することにより、海馬神経回路の基本的機能を初めて理解できると考えるからである。研究の第2の側面は脳の学習機能の中での海馬の役割の解明である。これは *in vivo* の海馬を中心とする脳活動に関し、学習に伴う活動の

空間・時間パターンの変化を知ることが重要であろう。このために、3.4.2項において宮下氏がすすめているような猿によるパターン学習の実験系、さらにこの系に対する無侵襲多点同時光計測の手法の適用などが今後ますます重要となろう。

〔参考文献〕

- [1] 松本、市川、バイオエレクトロニクス（松本編、丸善、アドバンスドテクノロジー電子・情報・通信編、1989年）pp. 49-101

4.8 新情報プロジェクトのあり方

新情報処理技術開発のあり方については、アンケート調査や討論を通して、あくまでも技術開発の立場に立ち、基礎科学に対して問題提起をすべきであるという認識がなされたが、新情報処理技術開発はブレークスルーを採求するプロジェクトであるから長期的視野に立ち、生理学、認知・心理学研究も含める、すなわち、ある段階では、生体を意識しない工学的研究もあり得るが、新技術開発に当たっては、生理学、認知・心理学との積極的な連携の必要性が認識された。

また、研究の具体的手順に関しては、次のような意見が出た。

- ① 超並列・超分散型情報処理システムで必要とする学習機能とは何かを明確にし、神経科学的知見とその有効性を検討する。
- ② まず、発想から出発し、トップダウン的に研究方向を検討する。
- ③ 中期的な応用研究と長期的な基礎研究とを並行させ、その進捗状況を見ながら、両研究への重きの置き方を柔軟に変更し、基礎研究成果に関するリスクを低減する。

さて、4.5節、4.6節で述べたように、新情報処理技術開発に当たって、認知・心理学や生理学に期待するところは大きい。ここでは、さらに、情報化社会にふさわしいコンピュータの開発には、脳にかかわるこれら基礎科学の研究の重要性を指摘したい。

1990年までの科学技術の進歩は、人間の行動や情報の範囲などに関する物理的拡大を目指すものであった。このことは、人間生活を改善するのに大いに役立ったが、1990年代に入ると果して、この科学技術の直線的拡大の延長上に人間としての幸福が存在するかが問われるに至った。無機的な科学技術の所産が、自然環境を破壊し、人間の存在を脅かし始めたからである。情報化社会が進展し、コンピュータが人に関する情報の介在物として、

常に使われるようになったとき、無機的なコンピュータは人間の精神に著しい害をもたらすであろう。

現在のコンピュータが人に関する情報を正確に扱えないのに、その大量かつ迅速にデータを処理し得る便利さの故に、人の情報を扱おうとすると、人の側でコンピュータに迎合しなければならない。この結果、人に無理を強いて、人の精神に著しい害を及ぼす[1]。

人は、現在のコンピュータに比べ、はるかに多面的にきめ細かな情報処理が可能である。コンピュータがもっと人に近づかなければ、これからの情報化社会を迎えることはできない。コンピュータは人の精神に直接影響し、その害が目に見えない形であらわれるだけに、その発展にはきわめて慎重でなくてはならない。このために人を知って、人の情報を扱うコンピュータを開発することが重要である。人を知るために、人の精神の座である脳の研究は、これからのコンピュータ開発に必須のことである。

そのような意味でも、新情報処理技術開発に当たっては、生理学や認知・心理学など脳に関わる基礎科学との連携が必要であり、そのことが可能な研究体制の確立が急務といえる。

〔参考文献〕

- [1] 松本：転換期における人間、1．生命とは（宇沢、河合、藤沢、渡辺編、岩波書店、岩波講座第1巻）、pp. 221-239

5. む す び

5. む す び

本報告書では、

- 1) 「学習・記憶機能」の新情報処理技術における位置づけと調査対象の範囲を明確にするとともに、
- 2) 将来の技術のブレークスルーに当たっては、基礎科学との関係のあり方が重要であるとの認識から、心理学・認知科学、神経生理学での学習・記憶の研究の現状を分析し、
- 3) 新情報処理技術における「学習・記憶」の研究課題を提言した。

すなわち、

1) 新情報処理技術では、大規模な超並列・超分散システムの構築が前提とされているが、システムの規模が巨大になると、はじめからすべての情報処理の構造を詳細に与えることは不可能であること、そこで、初期設計では構造の概要を規定し、その後の状況に合わせて適応的に機能を変更する「学習システム」として設計しておく必要があることから、「学習・記憶」の機能が新情報処理技術開発の基礎となると位置づけた。この場合、システムをモジュール構造とし、モジュール間の構造決定や調整に「発達概念」を取り入れた新しい自己組織化の原理の究明が必要であることを指摘した。

心理学においては、最も広義には、「学習とは経験による、比較的永続的な行動の変容」と定義されているが、本報告書では、次のように発達の段階に応じて、

- ① 単純な刺激と単純な応答による条件づけ学習
- ② パターン認識とパターン発生（運動学習）
- ③ 論理的知識獲得

に分類して考察するとともに、実体モデルとしては、

- ① シナプス荷重という構造パラメータの適応的調整
- ② 構造そのものの適応的調整、モジュール群の自己組織化

に分類し、②では、生体にみられる発達・分化の機能に着目し、遺伝子レベルの情報の役割を盛り込んだモデルを検討した。さらに、学習を利用した研究の現状を、

- ① パターン認識
- ② 知識処理
- ③ 運動制御
- ④ 構造形成

などにわたって検討した。

2) 基礎科学との関係では、神経生理学における学習・記憶研究の現状として、学習・記憶にかかわる部位、神経活動の同定、可塑性シナプスの細胞・分子レベルの研究、記憶システムと情報表現などが検討され、下側頭回と海馬の相互作用が並列・分散処理系としてのヒトの認知記憶系の秘密を解く鍵であり、超並列・超分散型情報処理機構の設計にとって必要であることが指摘された。また、学習の基本原則を明らかにするためには、学習機能のソフト面の探求のために認知科学や心理学の研究が、学習機能を実現する自己組織化のハード面の探求のために生理学的研究が不可欠であり、また、期待されること、さらに、新情報処理技術の開発の立場からも、基礎科学への積極的な問題的研究を行える研究体制の確立が必要であることが指摘された。

最後に、

3) 今後の研究課題として、

- ① 構造化されたネットワークでの学習、時系列情報を使つての学習、システムのグローバルな状態制御などのための新アルゴリズム、
- ② 学習チップ／プロセッサ、
- ③ 計算速度の向上と通信負荷の均等化を目指した新計算機構、
- ④ 大規模ネットワークの構造化の手法、
- ⑤ 自律分散制御システムの自己組織化のアルゴリズム、
- ⑥ 生理学的知識を利用したシンボル処理との融合技術、
- ⑦ 遺伝子レベルの情報に基づく回路構造を含めた適応・自己組織システム、
- ⑧ 意識的レベルと無意識的レベルに階層化された情報処理システムの開発

などが提案された。

これらの技術の実現に向けての、基礎研究と開発研究の発展を期待して、本報告書の結びとしたい。

本報告書をまとめるにあたり、ご尽力頂いた各位に深く感謝の意を表する。

学習ワーキンググループ

主査 鈴木 良次

—— 禁 無 断 転 載 ——

平成 2 年 3 月 発行

発行所 財団法人 日本情報処理開発協会
東京都港区芝公園 3 丁目 5 番 8 号
機会振興会館内
TEL (432) 5405 (代表)

印刷所 山陽株式会社
東京都港区虎の門 1 丁目 9 番 5 号
TEL (591) 0240 (代表)

.....

.....

.....

.....

.....

.....

.....

.....

.....

.....

