

01-R 010

新情報処理技術に関する総合的調査研究

—超並列・超分散処理WG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

「超並列・超分散処理WG」委員名簿

(順不同)

	氏 名	役 職
主 査	弓 場 敏 嗣	工業技術院電子技術総合研究所 知能システム部長
幹 事	大 津 展 之	工業技術院電子技術総合研究所 情報科学部情報数理研究室長
幹 事	小 池 誠 彦	日本電気(株)C & Cシステム研究所 コンピュータ・システム研究部長
委 員	石 井 光 雄	(株)富士通研究所 システム研究部長
	上 坂 吉 則	東京理科大学理工学部 情報科学科教授
	小 柳 滋	(株)東芝 総合研究所 情報システム研究所主任研究員
	島 田 俊 夫	工業技術院電子技術総合研究所 計算機方式研究室長
	竹 内 彰 一	三菱電機(株) 中央研究所 システム研究部主事
	長 島 重 夫	(株)日立製作所 中央研究所 第六部長
	平 井 有 三	筑波大学電子・情報工学系助教授
	村 岡 洋 一	早稲田大学理工学部 電子通信学科教授
	山 崎 晴 明	沖電気工業(株)総合システム研究所 知識システム研究室長
	吉 澤 修 治	東京大学工学部計数工学科助教授
	米 澤 明 憲	東京大学理学部情報科学科教授

Vol. 71, Part 1, 1941

Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

Subscription price, 10s. 6d. per annum in advance (including postage)

Single parts, 3s. 6d. each (including postage)

Advertisements accepted on the usual conditions

Printed and Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

Subscription price, 10s. 6d. per annum in advance (including postage)

Single parts, 3s. 6d. each (including postage)

Advertisements accepted on the usual conditions

Printed and Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

Subscription price, 10s. 6d. per annum in advance (including postage)

Single parts, 3s. 6d. each (including postage)

Advertisements accepted on the usual conditions

Printed and Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

Subscription price, 10s. 6d. per annum in advance (including postage)

Single parts, 3s. 6d. each (including postage)

Advertisements accepted on the usual conditions

Printed and Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

Subscription price, 10s. 6d. per annum in advance (including postage)

Single parts, 3s. 6d. each (including postage)

Advertisements accepted on the usual conditions

Printed and Published by the Royal Anthropological Institute, 21, BEDFORD SQUARE, LONDON, W.C.1

目 次

1. 序文	1
2. 調査研究項目と経緯	3
2.1 調査研究項目	3
2.2 調査検討経過	4
3. 研究開発の現状	7
3.1 基本原理と基礎理論	7
3.1.1 並列分散情報処理の基礎（パターン認識の再認識）	7
3.1.2 ニューラルネットと学習	18
3.2 基本機能とそのモデル	26
3.2.1 ニューラルネットワークモデル	26
3.2.2 AIにおける並列処理	38
3.3 システムアーキテクチャ／ソフトウェア	44
3.3.1 超並列システムアーキテクチャ	44
3.3.2 超並列計算モデル／ソフトウェア	65
4. 今後の動向と目指すべき方向	69
4.1 基礎理論とモデル	69
4.1.1 統合学習型情報処理	69
4.1.2 学 習	73
4.1.3 超並列最適解探索	75
4.1.4 超並列・分散協調のモデル	79
4.2 システムアーキテクチャ	82
4.2.1 超並列アーキテクチャ (Billion Processor Machine)	82
4.2.2 ニューラルネットワーク	89
4.2.2.1 大規模ニューラルネット	89
4.2.2.2 仮想ニューロコンピュータ	92

4.2.3	統合型アーキテクチャ(Brain Simulator)	95
4.3	応用の展望	100
4.3.1	学習・自己組織型データベース	100
4.3.2	高次認識モデル	102
4.3.2.1	相転移に基づく認識モデル	102
4.3.2.2	多形態情報の認識	104
4.3.3	最適化および支援システム	105
5	4.3.3.1 組合せ問題、各種大規模システムの最適化	105
	4.3.3.2 超並列超分散アーキテクチャの応用による予測・計画・決定支援システム	108
4.3.4	自律・成長システム	111
4.3.4.1	自律システム	111
4.3.4.2	成長システム	112
4.3.5	大規模シミュレーション	115

1. 序 文

1. 序 文

情報処理技術の究極の目標は、人間の情報処理機能を人工的に実現することである。そうした観点で21世紀の高度に情報化された社会を展望するとき、情報処理技術の現状は極めて重大な技術課題を抱えている。現在のコンピュータは計算能力、記憶能力において人間をはるかに超えている。しかし、置かれている状況を学習的に理解し、不完全な情報をもとに総合的に判断して、それなりに適切な行動をおこすといった「柔らかな情報処理」能力において著しく人間に劣っている。

一方、新しい情報処理技術の確立を目指した研究開発を進める中で、様々の分野に共通したもう一つの技術課題は超並列超分散情報処理の枠組みに関するものである。人間の情報処理機能を考えるとこれら二つは密接な関係があり、その接点を探ることによって新たな情報処理の展開が期待される。そこで得られる知見こそが現在のコンピュータの限界を打ち破るものであり、21世紀を展望した新情報処理技術の基盤をなすものである。

こうした認識のもとで、「新情報処理技術に関する総合的調査研究」の一環として、柔軟で高度な知的情報処理の基盤技術としての超並列超分散情報処理技術について総合的に調査を行い、本報告書を取りまとめた。調査にあたっては、工学的、構成的な立場にたって、ニューロコンピューティングなどの新情報処理の原理、数理的基礎理論、基本機能モデル、システムアーキテクチャ、それらの適用分野の各側面から検討を行った。

報告書の構成は大きく2つに分かれる。すなわち、当該分野の研究開発の現状を調査した部分と、今後の動向と目指すべき方向を考察した部分である。前者については、本ワーキンググループ委員が各自専門としている理論、技術分野の現状について行った本委員会での報告と討論を基調としている。後者については、分野別に各委員に提案いただいた研究開発課題を取りまとめたものとなっている。時間的な制約から、提案された個々の課題については十分な議論が尽くされている訳ではない。従って、内容的にも、実現のアプローチが示されていないなど不十分な研究開発課題提案に留まっているものもある。結果的に、担当した委員の個性が表面に現れた報告書となっている。

報告書の作成にあたっては、本調査研究にたずさわる他のワーキンググループ委員にも合同の委員会開催などを通じて、多大のご協力をいただいた。また、(財)日本情報処理開発協会には事務局をお願いするなど多くのご援助をいただいた。ここに厚く感謝の意を表するとともに、本報告書が21世紀を目指した新情報処理技術の指針を与えるものとして、

関係各方面に広く利用されることを念願する。

平成2年3月

超並列・超分散処理ワーキンググループ

主査 弓場敏嗣

2. 調査研究項目と経緯

2. 調査研究項目と経緯

2.1 調査研究項目

本WGでは、工学的構成的な立場に立って、脳の情報処理機能の実現を目指したニューロコンピューティング等の新情報処理の原理（数理的基礎理論）、基本機能のモデル、システムアーキテクチャ等の様々な側面から、柔軟で高度な知的情報処理の基礎としての超並列・超分散情報処理について総合的な調査検討を行う。

新しい情報処理パラダイム（方式）としての超並列・超分散情報処理に関して、基礎からシステムまでの以下の3項目に対して、それぞれ研究開発の現状、今後の研究・技術動向、目指すべき研究開発方向について調査するとともに、特に、「並列分散」の2つの意味：従来型計算機の並列分散化（高速性能のための新しい方式）とニューロ型の並列分散計算（新しい計算原理と情報処理方式）、それらの対照および統合・融合の可能性、さらに応用の展望といった観点から調査検討を行う。

(1) 基本原理と基礎理論

並列分散情報処理の基本原理と基礎理論について、神経回路網理論、パターン認識と学習の理論、多変量データ解析理論、並列アルゴリズムなどの関連分野の研究も広く視野に入れて、より高い原理的な視点から調査する。

(2) 基本機能とそのモデル

従来の並列情報処理モデルを調査し分類整理するとともに、連想記憶、パターン判別、推定、逆問題、最適化など、超並列・超分散情報処理の基本的な機能（新しい情報処理機能）を洗い出し、対応する基本モデルおよび学習方式について調査する。また、より高次の複合機能（基本機能の組合せ、階層化、記号情報との統合化）とそのモデルについても、その自己組織化の可能性も含めて、調査する。

(3) システムアーキテクチャおよびソフトウェア

ニューロコンピュータを含む新しい超並列・超分散情報処理の基本的なシステムアーキテクチャについて調査する。また、ハイパーキューブ、データ並列、データフロー、シス

トリックアレーなどの現在の並列コンピュータのアーキテクチャを含めて、機能複合システムのアーキテクチャを調査するとともに、さらには従来型計算機との統合システムのアーキテクチャについても調査する。また同時に、OS、言語を含む並列ソフトウェア、シミュレータソフトウェアおよび環境、新しい超並列・超分散情報処理システムのソフトウェア（メタな制御、インタフェースなど）について調査する。

2.2 調査検討経過

本年度は合宿を含めて9回のWG委員会を行い、モデル、システムアーキテクチャ／ソフトウェア、基礎理論の各々の立場からの議論、及び各々の委員の新情報処理への立場、具体的なテーマなどについて討議を行った。

(1) 第1回WG（1989年9月13日）

テーマ：本WGの趣旨説明、委員紹介、調査計画、基本方針、WGの進め方についての討議。

(2) 第2回WG（1989年10月4日）

調査項目の分担：調査責任分担を決め、各々の立場から調査検討を行うこととした。

テーマ討論：「基本機能とそのモデルの立場からの議論」と題してニューロ／非ニューロの各々の立場からのプレゼンテーション及び議論。

- ・平井委員より「ニューラルネットワークは何を指向しているか？」と題して講演及び討議。
- ・竹内委員より「AIにおける並列処理」と題して従来計算機の延長、AIの分野での並列処理についての講演及び討議。

(3) 第3回WG（1989年10月26日）

テーマ討論：「システムアーキテクチャ／ソフトウェア」と題してニューロ／非ニューロの立場からの講演及び討議。

- ・小池委員より「システムアーキテクチャ／ソフトウェア」と題して、計算機システムの技術動向、ニューロチップの技術動向についての講演及び討議。
- ・長島委員より「10億ニューロン／プロセッサの実現について」と題し、これからのシリコン技術をふまえて、ウェハスケールインテグレーションによるニューロ／マイクロプ

ロセッサの実現性について講演及び討議。

(4) 合宿（第4, 5, 6回WG）（1989年11月24日～25日）

WG合同討議：3次元、光、超並列超分散のWG合同で検討会を開き、

- ・安永氏（長嶋委員代理）より「10億ニューロン／プロセッサの実現について」
- ・島田委員より「光伝送による接続について」

話題提供のための講演が行われ、討議された。

テーマ討論：「基本原理／基礎理論の立場から」と題してニューラルネットワーク周辺の基本原理／基礎理論の講演及び討議。

- ・大津委員より「ニューロコンピューティングの基礎：パターン認識の再認識」と題して、多変量データ解析、パターン認識、推論、ニューロコンピューティングなどの並列情報処理の基礎をなす「柔らかな論理」について講演及び討議。
- ・上坂委員より「ニューラルネットと学習について」と題して、現在提案されている種々のニューラルネットワークのモデルの分類、学習の種類、関数近似としての誤差逆伝播法、汎化性、学習可能性などについて講演及び討議。

新情報処理に対する各委員の考え：各委員より、提出資料に基づき、立場、テーマの提案、新情報処理への期待などについて説明、討議が行われた。

(5) 第7回WG（1989年12月22日）

- ・米澤委員より「超並列計算モデルについて」と題して、超並列計算モデルの目標と種／並列オブジェクトに基づく計算・情報処理についての講演及び討議。
- ・報告書の構成（案）と執筆分担（案）の検討。

(6) 第8回WG（1990年1月31日）

- ・各委員会からの報告書執筆担当部会の説明と検討。

(7) 第9回WG（1990年2月21日）

- ・報告書（案）の検討。

3 . 研究開発の現状

3. 研究開発の現状

3.1 基本原理と基礎理論

3.1.1 並列分散情報処理の基礎（パターン認識の再認識）

(I) 背景（情報処理の2つの側面）

そもそも情報処理とは、人間（生体）が環境の中でしなやかに生存していくために、長い進化の過程で形成した脳の機能である。それは、状況を認識し判断し、そして予測し行動を行うといった多面的で階層的かつ統合的な機能であるが、しいて2分化すれば、

A. 意識上の論理的情報処理（分析的、演繹的、直列集約的、デジタル的）

B. 意識下の直観的情報処理（総合的、帰納的、並列分散的、アナログ的）

の2つの側面に分けて考えることができる。

情報処理技術は、本来、そうした脳の情報処理機能を機械化する試みであるが、技術的に実現しやすくまた理論的にも追求しやすい一方の側面Aを、チューリングモデル、フォンノイマン型計算機の上にデジタルな逐次手続き的情報処理方式として展開し、その後のハードウェア技術の驚異的發展に支えられて飛躍的に発達した。数値計算や人工知能・知識工学における記号処理はその流れに沿っている。

一方、Aを支えるBの側面は、本来、並列分散的な情報処理であるが、そうした従来型の逐次手続き的情報処理方式の枠内で、パターン認識や多変量解析における数値処理として研究されてきた。

しかし近年、従来の逐次情報処理方式の枠を越えて、並列分散情報処理方式へと大きくパラダイムが変わろうとしている。そこには次の2つの方向がある。

C. 従来の逐次手続き方式の高速化・高度化としての並列分散化（Aの発展）

D. 新しい計算原理としての並列分散情報処理の可能性（Bの追求）

Cは、フォンノイマンボトルネックの解消、スーパーコンピュータの実現を目指し、また高度化する計算機ネットワークの時代の流れに対する主に計算機科学的方向である。一方、

Dは、従来の形式化された「固い論理」（2値論理）と逐次処理に基づく閉じた世界での、理詰めの情報処理方式に対する反省（事実、記号と論理に基礎を置く従来の逐次方式の限界は、ソフトウェア危機や固いマンマシンインタフェースへの不満、多機能で融通性を持ったシステムやより人間的で柔軟な知的情報処理へのニーズの形で現れている）、また発達したハードウェア技術からのサポートの現実性（実現技術の下地）にも支えられて、これまで「面倒、良く分からない」ということで切り捨てられたきた情報処理のもう一つの可能性、すなわち直観的・並列分散的な情報処理の側面（B）をもう一度再検討する新たな流れである。これは、今日のニューロブーム、ひいては新しい並列分散学習型情報処理パラダイムを求める方向である。

以下本節では、このような並列分散型の知的情報処理の基本原則と基礎理論について考察する。ニューラルネットワーク、またCの方向での並列アルゴリズム、AIの分野については、他節にも詳しいので、ここではより原理的な視点から主にパターン認識の理論、多変量データ解析理論、そしてそれらの根底をなす「柔らかな論理」について概観する[1]、[2]。

(2) 知的情報処理研究の現状と課題

知能のモデル化とその工学的実現（機械化）を目指す現在の知的情報処理技術は、高次の「思考」レベルに関する人工知能や知識工学における質的（記号的、論理的）情報処理と、低次の「認識」レベルに関するパターン認識や多変量データ解析、またニューロコンピューティングにおける量的（数值的、位相的）情報処理とに分極化（分業化）している。両者の間には未だ大きなギャップがあり、統合的ではない。以下、それぞれの研究の現状と課題を概説する。

【人工知能・知識工学】（思考の形式化、top-down）

記号表現と形式論理（固い論理）の決定論的な立場から、主に知的推論の機械化の問題を追求し、論理の演繹的側面と知識表現の一部に成功したが、その下部を支える曖昧な帰納的側面（知識獲得と学習、いわばパターン認識の問題）の形式化に苦慮している。最近では、不確かな状況での確率的（ベイズ）推論や、曖昧な命題を操作するファジィ推論（論理）も再考されているが、帰納的側面からの一貫性のある議論が乏しい。また近年、高次の記号処理レベルでの並列分散化の傾向として、並列推論、分散AI、エージェント指向が

あるが、従来の逐次手続的な（形式論理と記号处理的な）方式の延長だけでは困難であり、パラダイムの変換が必要と思われる。

【パターン認識】（認識と理解の原型、bottom-up）

初期の理論において確率・統計は重要な役割を果たした。特に統計的決定理論の応用（流用）は、誤り最小識別（ベイズ識別）のための理論として成功したが、本来、論理の問題意識は少ない。ただ、渡辺は、パターン認識におけるベイズ公式の意味について深い哲学的考察行っていて、帰納と演繹の確率論的解釈、非ブール論理としての量子論理を考えている[3]。その後、研究は個別専門化して、実際的な手法、特に特徴抽出の技法と実験的な評価が中心となり、パターン認識全体としての理論的枠組みの意識は希薄となっていった。最近では、知識の利用など、人工知能の手法との結合も試みられているが、なかなかしっくりとは行かないでいる。

【多変量データ解析】（情報の要約手法）

対象に対して観測された多数の特性値データを個別に解析するのではなく、相互関係（相関）を考慮に入れて同時に統合的に取り扱い、データの持つ情報を効率よく要約し、我々の的確な評価、直観的総合的な判断に有用な形にまとめるデータ解析法である[4]。主に曖昧な対象を扱う人文・社会科学において発達してきたが、柔軟な知的情報処理に積極的な形で組み込んで工学的な応用を図る立場が重要であろう。特に質的（記号的、2値論理的）なデータを量的（数值的、位相的）なデータに変換して取り扱う数量化理論は、質的パターンを量的パターンに還元する過程、また高位記号レベルでのパターン認識や理解のモデル・手法として利用できよう。しかし、手法の多くは線形モデルでの定式化のため、相互の関係や本質的な意味の理解が乏しい。

【ニューロコンピューティング】（並列分散処理、constructive）

近年、ハードウェア技術の飛躍的發展にも支えられ、コネクショニズム、ニューラルネットなど、並列分散情報処理（PDP）の実際的で応用的な研究が盛んである[5]。これは現在のところ、過去のパターン認識、特に学習の研究（パーセプトロン、連想記憶など）の実践レベルでの再燃、また記号論理的認知研究の限界に対する反動と見るべきであろう。人間に近い柔軟な情報処理の可能性を示すものとして興味深いのが、解析の困難な並列非線

形の相互作用による情報処理は、結果の解釈や何が本質的であるかの理解を困難としていて、またパターン認識理論（特に確率・統計的理論）との関係の理解の欠如も見受けられる。ニューラルネットの情報処理機能に関する体系的な理論研究としては、既に甘利の研究がある[6]。

このように知的情報処理研究の現状は、本来トータルな知能の側面としての「認識」と「思考」、そして「学習」を、分断的にそれぞれの方法論でモデル化していて、そのことがそれぞれの展開の限界をなし、統合化を困難にしている。従って、今後、知的情報処理技術の応用範囲の拡大と高度化を図るためには、分極化された量的情報処理の体系と質的情報処理体系とのギャップを補間し統合するような、統一的な立場からの新しい基礎付けが望まれている。

(3) パターン認識の再認識

そのためには、原点に立ち戻って、人間の持つ柔軟な知的情報処理の基礎をなす「認識」の問題を再検討する必要がある。いわば「パターン認識の再認識」（温故知新）が必要である。パターン認識は、情報処理の入口として重要であるばかりでなく、連続的分散の情報表現（パターン）と離散的局所的情報表現（概念、記号）との接点にあって、本来、並列的な総合判断を特色とする。またパターン情報の持つ曖昧さや不確かさを扱わねばならない。その意味では、柔軟な情報処理の今日的な基本課題を含んでいる。また論理の基本的な側面も含んでいる。帰納的側面としての知識の獲得：事例（データ、経験）から、個々のパターンの特徴と概念との確率統計的な対応関係を学習することと、演繹的側面としての識別：未知パターンに対し、その特徴と知識から概念を推定することである。

従って、単に既存の確率論の応用としてパターン認識を考えるのではなく、パターン認識を特徴抽出を含めたトータルな枠組みにおいて理論的に考察し、背後に内在する「柔らかな論理」の現れとしての確率・統計的な論理構造を考察することが重要である。このような柔らかな論理構造を明らかにすることは、知識の学習形成、認識と推論、並列処理、総合判断といった、柔軟な知的情報処理の統合化の基礎として重要である。

(3)－1 パターン認識の諸側面

パターン認識とは、外界の多様な対象（パターン）を類に分類要約して、概念に対応づけて認識することである。通常、一般に次のようにモデル化される。

$$\begin{array}{ccccccc} \text{パターン} & \rightarrow & \text{観測} & + & \text{特徴抽出} & + & \text{認識} & \rightarrow & \text{概念} \\ f & & \underline{x} & & \underline{y} & & c_k \end{array}$$

個々のパターンは、空間的（文字）もしくは時間的（音声）に分布し、表現として一般に関数 f で表される。実際には、観測（標本化など）により、 f は有限次元ベクトル $\underline{x}$ で近似的に捕らえられ表される。これらは一般に極めて高次元の連続位相空間をなし、パターンの忠実な表現空間（パターン空間）ではあるが、必ずしも認識に好都合ではない。事実極めて冗長である。

従って、そのような多くの情報を持ったパターンから、認識に本質的に有効な情報を抽出し（特徴抽出）、それらを座標として次元を縮小した効率の良い空間（特徴空間）でパターンを捕えることになる（特徴ベクトル $\underline{y}$ ）。情報の圧縮（次元の縮小）としての特徴抽出においては、類の分離と集塊化を図るための特徴の選択と評価が重要な課題となる。

一方、概念はそれぞれ記号 c_k で表され、有限個の離散集合である。従って認識とは、特徴空間から概念集合への不連続な写像であり、特徴空間を、そこにおける類の集塊を切り出す有限個の領域に分割し量子化して、各領域にそれぞれ概念を対応させることになる。

ここで、認識は大きく2つの場合に分けられる。類が未知の場合と既知の場合である。前者は類別とよばれ、未分化な対象の集合を何らかの意味で類似し合ったものどうし類としてまとめ要約して理解する過程である（概念形成）。外から類を教えられないという意味で、教師無し（unsupervised）学習、自己学習とよばれる。類が既知の場合は、狭義の意味でのいわゆるパターン認識である。既知の類に関する知識に基づいて、与えられた未知の対象をいずれの類に属するか判定（決定）する場合で、識別とよばれる。学習過程において外から類を教えられると言う意味で、教師有り（supervised）学習とよばれる。また判別（discrimination）と言う言葉は、しばしば混用されるが、これはむしろ識別しやすいように類の分離を強調し区別をつけるというニュアンスで用いる。類別の場合は類の分離具合のもっともらしさに関する評価が、また識別の場合には誤識別をできるだけ少なくすることが、それぞれ重要な課題となる。

(3) - 2 パターン認識の理論手法

確率・統計理論（特に、分布の型を仮定するパラメトリックな理論）は、曖昧さや不確かさを扱うパターン認識の理論（特に識別理論）の中心的な役割を演じてきた。ノンパラメトリックな手法（特に類別や特徴抽出の手法）としては、多変量解析手法がある[4]。

多変量解析では、教師有り（無し）を、外的規準の有る（無い）場合という。以下、主な理論・手法をあげる。

【識別の理論】の中心は、統計的決定理論の応用としてのベイズ識別理論である。パターン f が特徴ベクトル $\underline{y}$ で表されるとき、誤識別率最小の意味で理論的に最適な識別は、良く知られたようにベイズ識別方式

$$f \in C_j, \text{ if } P(C_j | \underline{y}) = \max_k P(C_k | \underline{y}) \quad (1)$$

で与えられる。ここに

$$P(C_k | \underline{y}) = P(C_k)P(\underline{y} | C_k) / p(\underline{y}) \quad (2)$$

は、ベイズ事後確率であり、 $P(C_k)$ と $p(\underline{y} | C_k)$ は、それぞれ各類の事前確率（先験確率）と条件付き確率密度分布、 $p(\underline{y}) = \sum_k P(C_k)p(\underline{y} | C_k)$ は全確率密度分布である。

【判別の理論】としては、多変量解析・数量化理論（外的規準の有る場合の理論・手法）におけるFisherの判別関数、線形判別分析（DA）、数量化Ⅱ類、などがある。

【類別の理論】としては、最尤推定によるパラメトリックな方法や、多変量解析における各種クラスタリング手法がある。また、類別のための特徴抽出法としては、多変量解析・数量化理論（外的規準の無い場合の理論・手法）における主成分分析（PCA）（K-L展開に同じ）、数量化Ⅲ類、Ⅳ類、などが考えられる。

【学習の理論】としては、統計的なパラメータ学習やベイズ学習理論、ノンパラメトリックな方法としては、誤り修正方式による識別関数の学習としてのパーセプトロン、最小2乗規準に基づく Widrow-Hoffの判別関数の学習方式、また対応関係の学習（線形重回帰分析）としてのKohonenの連想記憶方式、などがある。

(4) 特徴抽出の理論と論理

特徴抽出は、認識のための情報圧縮として離散概念に接する重要な過程であるが、従来の理論においてはあまり体系立った理論となっていない。主に多変量解析手法があるが、線形モデルによる定式化のため、個々の手法の本質的な意味や相互の関係についてはほとんど注意が払われていない。また、識別との関係も不鮮明である。特徴抽出は確かに個別の問題に依存する面も強く、統一的な理論展開が困難と思われるが、パターン認識全体の

枠組みの中で理論的に深く考察を押し進め、その論理を明らかにする必要がある。このような観点から、大津は特徴抽出について体系的な理論的研究を行っている[7]。

特徴抽出には対立する条件が要請される。認識に本質的な情報の抽出と無関係な情報の捨象、そして類内の同一視（統合）と類間の区別（分離）である。後者を数量的に評価したものが判別分析における判別規準である。これらの要請を満たす形で、2段階からなる特徴抽出、すなわち幾何学的側面としての「不変特徴抽出」と確率統計的側面としての「判別特徴抽出」が考えられ、それぞれ理論化される。

(4)－1 不変特徴抽出の理論（幾何学的側面）

不変特徴抽出理論は、パターン f の受ける幾何学的な変換 $T(\lambda)$ （平行移動、拡大縮小など）に不変な認識のためには、如何なる特徴量を観測し抽出すべきかを与える理論であり、リー群論、作用素解析、偏微分方程式論に基づいている[7]、[8]。またこの理論により、逆にパターンがどれだけ変換を受けているかを測る特徴量も与えられ、形と運動の認識の基礎理論となる[9]。

ニューラルネットによるパターン認識の研究においては、この不変特徴抽出の側面があまり配慮されていないように思う。中心的な学習方式である誤差逆伝播（Error Back-Propagation）法に頼り過ぎるあまり、初期特徴としての不変特徴に関する考察がおろそかになりがちである。

(4)－2 判別特徴抽出の理論（統計的側面）

一方、判別特徴抽出理論は、実際のパターンの不規則な変形による不変特徴の統計的な分布のもとで、識別のために最適に類を判別するには、さらに如何なる特徴を抽出すべきかを与える理論である[7]。この理論は、曖昧さを扱うパターン認識の背後の本質的な構造を示していて、多変量解析とベイズ識別との密接な関係、認識と理解の「柔らかな論理」を示唆しているので、以下その概略を示しておく。

【非線形判別分析】[10] 初期表現（不変特徴ベクトルなど）を $\underline{x} \in R^M$ 、類の確率構造を

$\{\omega_k = P(C_k), p(\underline{x} | C_k)\}_{k=1}^K$ とする。 $\underline{x}$ から $\underline{y}$ （パターンの判別的特徴）への一般の非線形写像（特徴抽出） Ψ を考え、 W_y 、 B_y を、それぞれ $\underline{y}$ の類内、類間の共分散行列とする。

このとき Ψ の汎関数としての判別規準

$$J[\Psi] = \text{tr} (W_Y^{-1} B_Y) \rightarrow \max$$

のもとで最適な線形特徴抽出 Ψ_L が、従来の線形判別分析であり、 $\underline{x}$ の行列 $W_X^{-1} B_X$ の固有値問題で与えられる。一方、最適な非線形特徴抽出は、変分法により次の簡素な解 Ψ_N で与えられ、ベイズ事後確率、従って識別と密接な関係を持つ。

$$\underline{y} = \Psi_N(\underline{x}) = \sum_{k=1}^K P(C_k | \underline{x}) \underline{c}_k \quad (3)$$

ベイズ識別境界は、明らかに、 $\{\underline{c}_k\}$ を頂点とする単体の重心分割面となる。ここに、 $\{\underline{c}_k\}$ (類の代表ベクトル) は、類間の確率的な関係を要約した次の推移確率行列

$$S = [s_{ij}], \quad s_{ij} = \int P(C_j | \underline{x}) p(\underline{x} | C_i) d\underline{x} \quad (4)$$

の固有値問題から定まる。 s_{ij} は、ベイズの公式(2)を用いて、また次のようにも書ける。

$$s_{ij} = \gamma_{ij} / \omega_i, \quad \Gamma = [\gamma_{ij}], \quad \gamma_{ij} = \int P(C_i | \underline{x}) P(C_j | \underline{x}) p(\underline{x}) d\underline{x} \quad (5)$$

【最小2乗非線形判別】[11] 類の代表ベクトル $\{\underline{c}_k\}$ を、教師の与える答え(理想出力)として、それぞれの回りに各類のパターン $\underline{x}$ を集中させる最小2乗判別規準

$$\varepsilon^2[\Psi] = \sum_{k=1}^K \omega_k \int \|\Psi(\underline{x}) - \underline{c}_k\|^2 p(\underline{x} | C_k) d\underline{x} \rightarrow \min$$

のもとでの最適な非線形特徴抽出を変分法で解くと、やはり式(3)と同じ形 Ψ_N となる。

この場合 $\{\underline{c}_k\}$ は与えられているが、これらの配置をさらに最適化したのが非線形判別分析である。

一方、最適線形解は、

$$\underline{y} = \Psi_L(\underline{x}) = \sum_{k=1}^K L(C_k | \underline{x}) \underline{c}_k \quad (6)$$

となり、同様な形をとる。ここに $L(C_k | \underline{x})$ はベイズ事後確率 $P(C_k | \underline{x})$ の線形近似であり、

$$L(C_k | \underline{x}) = \omega_k [(\underline{x}_k - \underline{x})' \Sigma_X^{-1} (\underline{x} - \underline{x}_k) + 1] \quad (7)$$

で与えられる。 $\bar{x}_k$ と $\bar{x}$ は、それぞれ類 C_k の平均と全平均のベクトル、 Σ_k は全共分散行列である。この最小2乗判別は、多変量解析の立場からみると、各類の特徴ベクトル $\underline{x}$ で類の代表ベクトル $\underline{c}_k$ を重回帰していることが分かる。

(4) - 3 多変量解析手法の統一的基礎理論

このように、モデル(Ψ)を一般の非線形に拡張し、究極の最適解を変分法を用いて直接求めることによって、特徴抽出手法としての多変量解析各手法の本質的な構造(論理)が明らかにされる。この観点から、多変量解析・数量化手法の統一的基礎理論の展開を行った[12]、[13]、[14]。各手法は、究極の非線形の場合、上述のベイズの確率的構造を背後の本質的な一的な構造として持ち、それぞれ密接に関係していること、また確率行列 S (または Γ)がデータから得られる確率・統計的な知識として重要な役割を担っていることが明らかにされた。そして従来の線形手法は、その線形近似として統一的な解釈が与えられた。

(5) 柔らかな論理

(5) - 1 帰納的確率論理

前述の判別特徴抽出の理論において、確率・統計的な知識として重要な役割を演じる行列 S と Γ は、確率論理の観点から見ると、それぞれ類間の含意(条件付き確率) $s_{ij}=Q(C_j|C_i)$ ($C_j \vdash C_i$)連言(同時確率) $\gamma_{ij}=Q(C_i \wedge C_j)$ を表していると考えられる。このことは、経験としての一般的な「確からしさ」の上に統計的期待値として帰納的に構成される曖昧確率に基づく帰納的確率論理(柔らかな論理)の形成を示唆している[15]。この論理は γ_{ij} から分かるように、一般には非ベキ等で排中律の成り立たない論理となり、従来の確率論理を特殊な場合として含むより一般的な論理となっている。

(5) - 2 判別と推論(柔らかな推論)

推論は人工知能の中心的な問題である。証拠と仮説の関係が知識(規則)として与えられていて、証拠に基づいて仮説の推定を行う論理の演繹的な側面である。知識、証拠ともに確定的な(2値論理的な)場合には、古典論理の固い形式推論でよく、プロダクションルールによる推論システム(現在の多くのエキスパートシステムの基盤)が盛んである。しかし、各種の故障診断や医療診断など実際の多くの応用場面では、得られる知識、

証拠とも不確かで、しかも不完全な場合が多い。従って、そのような状況をも包含し得る柔らかな論理の枠組みと、それに基づく柔軟な推論方式の必要性が高い。PROSPECTOR（主観的ベイズ推論）やMYCIN（確信度）は、エキスパートシステムへの確率の導入の例であり、またファジィ推論（論理）も提案されている。しかしながら、これらのアプローチにおいては、そのような曖昧な知識の獲得（学習、形成）という帰納的側面（基礎基盤）についての一貫性のある議論が乏しい。

前述の判別特徴抽出の理論は、この点についても重要な示唆を与えている[16]、[17]。初期特徴ベクトル $\underline{x}$ を証拠、類 C_k を仮説、類の代表ベクトル $\underline{c}_k$ を仮説の空間表現（正規直交基底）とみたときに、判別特徴 $\underline{y}$ は証拠 $\underline{x}$ のもとでの仮説の推定（柔らかな推論）を表していて、そこで利用される知識が上述の帰納的確率論理である。最適非線形解(3)の場合は、ベイズの確率的推論そのものとなり、最適線形解（線形重回帰）(6)は、その近似的な線形推論方式（並列方式）を与えている[1]。

(5)ー3 ニューロ学習（EBP）と柔らかな論理

前節で示した最小2乗判別規準は、 $\{\underline{c}_k\}$ を教師の答え（理想出力）とするフィードフォワード型ニューラルネット（拡張パーセプトロン）の識別（または連想）学習における最小2乗規準でもある。従って、最適線形解(6)と最適非線形解(3)は、それぞれ最も簡単な線形ネットと最も一般的な非線形ネットが逐次学習（誤差逆伝播学習）によって収束する最適な解を理論的に与えている。通常のニューラルネットは、ある特殊な場合の非線形であるから、収束解はそれら最適線形解と究極の最適非線形解の間にあって、究極の最適非線形解をその制約のもとで最良に近似していることになる[1]。

このように、パターン判別の「柔らかな論理」はニューラルネットや並列分散情報処理による柔らかな認知の本質的な枠組みを与えていて、逐次学習によって変化する結合係数が、全体として何を近似しようとしているかを示している。この理論的基盤に立って、脳のモデルとしてのネットワークメカニズムによる並列的・分散的・階層的情報処理を考え、その基本的な機能と原理的な能力を数理的に解析し明らかにしていくことは、重要な研究方向の一つと思われる。

(6) 応用の展望と今後の研究課題

以上見てきたように、パターン認識に示唆される「柔らかな論理」は、実際のデータか

らどのような情報が抽出され認識や推論にどのように利用されるかを、一般化された確からしさの計算の枠組として与えている。この立場から柔軟な知的情報処理への様々な応用が考えられる。まず学習機能を持った柔軟な視覚認知システムへの応用がある[18], [19]。また、質的データへの応用としては、柔らかな知識ベースと推論システムが考えられる。

今後の研究課題としては、「柔らかな論理」に基づく柔らかな情報処理の理論の展開を図るとともに、多形態情報の統合、さらには逐次記号レベルとの統合など、分極化した知的情報処理研究分野の相互のギャップを埋め、統合化を押し進めることが重要な課題である。

[参考文献]

- [1] 大津：“認識と理解のための柔らかな論理”，電子情報通信学会誌，71，11，pp.1231-1240 (1988).
- [2] N.Otsu: "Toward soft logic for the foundation of flexible information processing", Bul. ETL, 53, 10, pp.75-95 (1989).
- [3] S.Watanabe: "Knowing and Guessing", John Wiley & Sons (1969).
- [4] 林，桶口，駒沢：“情報処理と統計数理”，産業図書 (1970).
- [5] D.E.Rumelhart, J.L.McClelland, et al.: "Parallel Distributed Processing", Vol. I, II, MIT Press (1986).
- [6] 甘利：“神経回路網の数理”，産業図書 (1978).
- [7] 大津：“パターン認識における特徴抽出に関する数理的研究”，電総研研究報告，第818号，210頁 (1981).
- [8] 大津：“不変特徴抽出の理論 I～IV”，信学誌，69，5～8 (1986).
- [9] N. Otsu: "Recognition of shape and transformation: An invariant-theoretical foundation", in Science on Form, ed. S. Ishizaka, KTK Reidel Pub. (1986).
- [10] N. Otsu: "Nonlinear discriminant analysis as a natural extension of the linear case", Behaviormetrika, 2, pp.45-59 (1975).
- [11] N. Otsu: "Optimal linear and nonlinear solutions for least-square discriminant feature extraction", Proc. 6th ICPR, pp.557-560 (Munich, 1982).
- [12] N.Otsu, T.Kurita & H.Asoh: "A unified study of multivariate analysis methods by nonlinear extensions and underlying probabilistic structures", in Recent

Developments in Clustering and Data Analysis, Diday et al. Eds, Academic Press (1988).

- [13] 麻生, 栗田, 大津: “正準相関分析および判別分析の非線形の定式化による解釈について”, 行動計量学, 14, 2, pp.1-9 (1987).
- [14] 栗田, 麻生, 大津: “数量化手法の背後確率による解釈について”, 信学論, J70-D, 4, pp.760-769 (1987).
- [15] 大津: “帰納的確率論理の下部構造について”, 信学全大, No.1594 (1986).
- [16] 麻生, 大津: “確率的知識と推論について”, 信学技報, A186-22 (1986).
- [17] 大津, 麻生: “最小2乗判別と確率的推論”, 信学全大, No.1523 (1987).
- [18] N.Otsu and T.Kurita: “A new scheme for practical, flexible, and intelligent vision systems”, Proc. IAPR Workshop on Computer Vision, pp.431-435 (Tokyo, Oct. 1988).
- [19] 大津: “適応学習型汎用画像計測認識システム”, 映像情報, 21, No.5 (1989).

3.1.2 ニューラルネットと学習

(1) ニューラルネットによる学習機械

情報処理の観点から人間が行う“学習”を考えたとき、それは次の3つのタイプに分類することができる:

1° 物や事柄の間の関係を記憶するタイプ。例えば、各都道府県の県庁所在地を記憶学習する、種々の歴史的事件に関連した人名や年代を記憶学習する、・・・などである。

2° アルゴリズムを記憶するタイプ。例えば、四則算法や因数分解の仕方や関数の微分や積分の仕方を記憶学習する、・・・などである。

3° ある事柄に関して幾つかの例が与えられて、その背後にある一般的規則を知らず知らずのうちに発見し、身につけてしまうタイプ。例えば、子供が母国語や文字パターンを学習する、・・・などである。

1°、2°のタイプの学習は比較的容易に機械化できる。しかし、3°のタイプの学習をする機械を作るには、学習によって汎化能力を獲得させる方法など研究すべき課題は少なくない。

一方、ニューラルネットによる学習機械として古くからパーセプトロンと呼ばれる層状回路が知られている[1]。これは2値の入出力信号を扱うデジタル型のニューロンモデルから成るニューラルネットであって、ニューロン間の結合係数を学習パターンによって更新修正しながら学習が進行する。しかし、更新のルールは最終層の結合係数にしか適用できないという致命的な欠点をもっている。

ところが1980年代に入って、パーセプトロンのニューロンモデルをデジタル型からアナログ型（入出力の信号が実数値をとるタイプ）にすり替えることによって、この難点を回避する学習法が提案された[2]。いわゆる“誤差逆伝搬学習法”がそれである。

パーセプトロンにおける誤差逆伝搬学習法はループを持たないフィードフォワード型のあらゆるニューラルネットに適用でき、しかも回路のすべての結合係数を更新できるという意味で強力な学習法である。それに加えて学習をシミュレートするコンピュータハードウェアが発達したことから、従来の文字・音声・画像といったパターン認識における伝統的な対象だけではなく、金融・証券などビジネス分野でのさまざまな対象に関する認識学習の試みが展開されるようになってきている。今日ニューロコンピュータないしはニューラルネットの学習といえば、そのほとんどがこの種の学習機械を指していると考えてよい。

(2) 誤差逆伝搬学習法の問題点

ニューラルネットのすべての結合係数を更新できるという意味で、きわめて強力であるといえる誤差逆伝搬学習法にも次のような難点のあることが指摘されている：

- 1° 学習に要する時間がかかりすぎる、
- 2° 学習目標との誤差が最小ではなく、極小に陥り易い、
- 3° 学習結果が汎化性をもつことは一般に保証されていない。

誤差逆伝搬学習法は、数値解析の立場からみれば、目標との誤差を最小にするための一種の最急降下法である。したがって誤差の等高線が偏平な楕円状になっていると降下速度が急激に低下する。これが学習速度を鈍らせている主な原因である。また、最急降下法では誤差の最小点に到達するには初期値の設定がものをいう。初期値をどのように設定すれば最小値が得られるかは一般論を展開するのが難しい。これら1°、2°の問題点については数値解析における弛緩法の手法を援用するなどして解決に迫る研究が盛んに行われている。

一方、学習機械に最も期待されるのは、教えたパターンだけではなく、それまでに教え

なかったパターンに対しても正しいあるいは適切な反応をしてくれるという“汎化”の能力である。

パーセプトロンなどのループを持たないフィードフォワード型の学習ニューラルネットは、数学的にみれば、多変数の関数に過ぎない。したがって学習とは、この関数の定義域に属する有限個の点とそれらに対する関数値が与えられたとき、これらを用いて目標とする関数を近似ないしは補間することに他ならない。この意味で汎化能力とは与えられなかった点における関数値をも目標関数のそれと一致させる能力だといえる。しかし、与えられた点（学習パターン）において目標関数の値を通る関数は無限にあるわけだから、ニューラルネットによる学習機械に汎化能力を期待することは原理的に不可能であるといわざるを得ない。

それにもかかわらず、汎化能力を誇示する実験が多く報告されているのは、パーセプトロンが作る関数の多くがある種の“滑らかさ”を持っていることによるのであろう。このことは、言い替えば、パーセプトロンが（結合係数をいろいろ変えることによって）実現できる関数の族に、いま学習しようとしている目標関数が含まれていると暗に仮定していることを意味する。

パーセプトロンが実現可能な関数の族はその結線の様相、すなわち、アーキテクチャに依存する。この意味で学習の結果、汎化性が得られるかどうかはひとえに学習対象の性質にマッチしたアーキテクチャを選んだかどうかによる。つまり、学習目標の関数とそのアーキテクチャで実現できる関数の族に含まれていれば、汎化性はある程度期待できる。しかし、そうでないときはお手上げである。

それではというので、ほとんどどんな関数も含むような巨大な族を実現できるようなアーキテクチャ（これは層の数と素子の数を十分大きくとれば可能であることが知られている[3]）を選んだとしよう。そうすると今度はアーキテクチャに関数表現の能力があり過ぎるために、どんなに多くの学習パターンを用いて学習しても汎化能力はほとんど期待できなくなる[4]。

このようにニューラルネットのアーキテクチャが定める実現可能な関数の族と学習パターンの間には密接なトレードオフがある。したがって学習機械に最も期待される性質である汎化性を目指すには、両者の関係を注意深く議論することが本質的に重要な課題となる。以下ではこの問題に論点を絞ることとする。

(3) 汎化の問題への種々のアプローチ

ニューラルネットにある種のアーキテクチャを定め、それによって実現できる関数の族に目標関数が含まれていると考えることは、言い替えれば、目標関数に対してある種の“モデル”を設定することに他ならない。この意味で学習機械における汎化の問題は学習目標を推定するのにどのようなモデルを用い、学習パターン（学習サンプル）をどのように活用すればよいかという、古いけれども難しい推定・推測の問題と機を一にするものである。

しかしながら、ニューラルネットによる学習機械をターゲットにしたこの種の研究は、残念ながら、ほとんど見当たらない。そこでもう少し枠を広げて、推定の問題という観点から汎化の問題に関する研究を展望することとする。

(a) 統計的推定 この種の問題に関する研究は、入力（パターン）が確率的に発生すると考えるアプローチとそうでないアプローチにまず分けることができる。前者では、例えば、各カテゴリ内で入力が共分散行列の等しい（異なる）正規分布に従うときには、線形（2次）の識別関数が最良であることが知られている[5]。したがってモデルとしてこのような識別関数の族をとれば、学習は平均や分散などの母数の統計的推定問題に帰着される。

(b) AIC (Akaike's Information Criterion: 赤池の情報量規準) 上の問題で線形の識別関数と2次のそのいずれを用いたらよいかを判定するにはどうしたらよいか？ 2次は線形を含んでいるから、大は小を兼ねるというわけにはいかない。本来線形で十分な学習データに対しても、2次の方が見掛け上よく分離するかも知れないのである。このようなときには赤池の提案した AIC（情報量基準）を用いることができる[6]。

k 個のパラメータで記述されるモデル（確率分布の族）の族を考え、 k をこの族の自由度という。このとき、学習データから得られる量：

$$AIC = -2 \ln L(\hat{\theta})$$

AIC は 最大対数尤度 - モデルの自由度

が平均対数尤度のサンプルに関する期待値の不偏推定量になっていることに着目して、これを最大にする自由度をもつモデルが妥当と結論する。これは現在手にしているデータから得られたモデルが将来やってくる未知のサンプルに対しても妥当なものになっていることを保証しており、学習の汎化性と密接な関連がある。上の AIC の最大対数尤度は現在のデータに対する適合の良さを表しているから、それが同じならモデルは簡単な方（自由度が小さい方）がよいわけで、いわゆる“ケチの原理”にも沿っていて興味深い。

(c) 万能学習機械 統計的推定ではモデルとして確率分布を考えるが、識別関数の族 F をモデルとして扱う議論もある。 F の中の、与えられた学習サンプルを最もよく識別する関数を f とし、そのときの誤認識率を p とする。また、将来やってくるであろうすべてのパターンも含めての誤認識率の F の中での最小値を q とする。 p と q の差が小さいことが大きな汎化能力を持つことになるが、この差がモデル F の自由度と密接に関係していることを Vapnik & Cervonenkis が明らかにしている [7]。つまり、 p と q の差を小さくしようとすると自由度の小さいモデルを用いなければならず、そうすると真の識別関数はこのモデルから漏れてしまう。逆にモデルを大きくとれば、学習の汎化性が損なわれる。というわけで、万能学習機械の存在が確率的枠組みの中で否定されてしまうのである。

(d) モデルの自由度と回路の複雑さ このように学習の結果得られる汎化性あるいは学習可能性を論じるのにモデルの自由度という概念が重要な意味をもってくる。これを認識機械としてのニューラルネットの立場からみれば、その回路がどれくらい複雑なパターン分布を（例えば、ニューロン間の結合係数をうまく設定することによって）識別できるかということになる。その意味で自由度を回路の“容量”ともいう。

Cover は多項式識別関数で実現できる分割の数を調べ、それによって汎化が成立する確率を計算した [8]。パターンの次元を無限に大きくしたとき、この確率があるパターン数を境として 0 と 1 に不連続に分かれることを見だし、この値をこの識別関数の族の“容量”と名付けた。特に線形の場合には十分な汎化性を得るには学習サンプルの数はこの容量より十分大きくなければならないことを示している。

こうした考察はアナログ型のニューロンから成る層状回路（いわゆる誤差逆伝搬学習法で使われる学習機械）の研究に最近引き継がれ [9]、例えば、学習によって十分な汎化性を得ようとすれば素子と結合係数の個数（これは回路の自由度に相当する）と汎化の度合から決まるある定数以上の学習サンプルが要求されることが示されている。

(e) 極限における学習可能性 これまでに述べてきたアプローチとは異なった、アルゴリズムの立場からの議論もある。学習すべき対象を帰納的関数 f とし、学習のためのサンプルを貰うごとに f の推定としての帰納的関数 f_k を出力する機械 M があるとする。このとき、ある n が存在してすべての $k \geq n$ に対して $f_k = f$ が成り立つとき、 M は f を“極限において学習できる”という [10]。この定義によれば、十分豊富に関数を生成できる M を用意すれば、万能学習機械が作れるように思われるが、実はどんな帰納的関数をも極限において学習できるような機械は存在しないことが示されている。この線に沿った学

学習可能性の定義はこの他にも種々考えられており、興味深い理論が作られつつある[11]。

(f) 学習可能性の位相的性質 これまでに述べてきた学習可能性の議論ではモデルとして確率分布や識別関数や帰納的関数の族を扱ってきたが、もっと抽象的なあるいは一般的なモデルを対象として論じることでもある。

上坂らは可算集合の上の任意の関数の族を対象とする学習可能性を論じ、学習可能性のある種の位相的性質としてとらえ得ることを示している[12]、[13]。つまり、関数の族にある種のトポロジーを導入し位相空間と見なす。このとき、学習の目標関数に関するモデルはこの空間の部分空間 S としてとらえることができ、目標関数が完全な汎化性をもって学習できるためのモデル S に関する条件は、目標関数が部分空間 S の孤立点であるという形で与えられる。また、この定理は古典パーセプトロン[14]の学習可能性などに応用されている[15]。

(4) 今後の研究課題

宝くじを買ったとする。その番号が 111111 や自分の生年月日だったりするとまず当たらないと思いがちである。デタラメな番号には淡い期待が持てる。ずいぶん前のことであるが、「昭和55年5月5日5時55分55秒」というタイトルでこの時刻が何か特別の意味を持っているかのような新聞記事が載ったことがある。これらの例から分かるように、人間はパターンのある種の規則性に特に関心があるようである。

ある規則を決めてトランプを裏返しに並べる。それを一枚ずつめくりながら、その規則をできるだけ早く言い当てるというゲームがある。そんなときトランプがランダムに並んでいたらお手上げである。推定者は比較的単純な規則の族(モデル)を想定してゲームに臨むのが普通である。

このように学習の可能性はモデルの複雑さとも深い関わりがある。この複雑さは上に述べた自由度と関係しており、人が複雑さを避けるのは“ケチの原理”を好むからである。複雑さの一般論に関しては Chaitin によって精力的に展開されていることを指摘しておく[16]、[17]。

このように見てくると、“モデル”・“自由度”・“複雑さ”・“学習可能性”という概念に行き着く。問題の設定状況や論じられる分野の違いから異なった名前では呼ばれているが、実は学習の本質の異なった側面をとらえる概念なのである。したがってこれらを結ぶ何かの糸を手繰ることが、ニューラルネットによる学習機械の最も重要な課題である

汎化と学習可能性の本質に迫ることだと言えよう。

汎化や学習可能性の問題は、力任せにむやみとコンピュータを動かしてシミュレーションをしたり、ハードウェアを開発したりすることによってだけ解決されるものではない。地道ではある深い論理的思考に支えられた理論研究から初めて大きな成果が期待される。その意味でも若手の理論研究者を育成し、わが国におけるこの方面の層の薄さを解消することが肝要である。ちなみにこの種の研究の多くが外国の研究者によって展開されていることを終わりに記して注意を喚起しておきたい。

〔参考文献〕

- [1] Rosenblatt, F.: Principles of Neurodynamics, Spartan Books(1962).
- [2] Rumelhart, D. E. et al : Learning Representations by Back-Propagating Errors, Nature, 323, 9, 533-536 (1986).
- [3] Funahashi, K.: On the Approximate Realization of Continuous Mappings by Neural networks, Neural Networks, 2, 3 (1989).
- [4] 上坂 : ニューラルネットと学習可能性、電子情報通信学会技術報告、CAS89-103; NLP89-47, 69-74(1989).
- [5] 上坂 : パターン認識と図形処理、文一総合出版 (1984).
- [6] 坂元他 : 情報量統計学、情報科学講座、共立出版 (1983).
- [7] Kovalevsky, V. A : Recent Advances in Statistical Pattern Recognition, Proc. 4-th Int'l Joint Conf. on Pattern Recognition, 1-12 (1978).
- [8] Cover, T. M. : Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition, IEEE Trans. on Electronic Computers, 326-334 (1965).
- [9] Baum, E. B. & Haussler, D. : What Size Net Gives Valid Generalization?, Neural Computation, 1, 151-160 (1989).
- [10] Gold, E. M. : Language Identification in the Limit, Information and Control, 10, 447-474(1967).
- [11] 大須賀・佐伯編 : 知識の獲得と学習、オーム社 (1987).
- [12] Uesaka, Y. et al : A Theory of Learnability, Kybernetik, 13, 123-131 (1973).
- [13] Uesaka, Y. et al : Sur l'Espace Topologique lie a une Nouvelle Theorie de

l'Apprentissage, Kybernetik, 14, 141-149 (1974).

[14] Minsky, M. & Papert, S. : Perceptrons, MIT Press(1969).

[15] 上坂 : パターン識別関数の学習可能性、電子通信学会論文誌、58-D, 10, 633-640 (1975).

[16] Chaitin, G. J. : Algorithmic Information Theory, Cambridge University Press (1987).

[17] 上坂 : 情報量・パターン・乱数、“伊理・野崎・野下編「計算の効率化と限界」、日本評論社” pp. 152-154(1980).

3.2 基本機能とそのモデル

3.2.1 ニューラルネットワークモデル

現在世の中で行われているニューラルネットワークに関する研究課題を、キーワードとして列挙すると図表3.2-1のようになる。以下では、各項目について、概説する。

[キー項目] パターン分類	記憶と拘束処理
◎学習回路	◎記憶の分類
○パーセプトロン型学習回路 △単純パーセプトロン △バックプロパゲーション ○自己組織化(競合学習) △特徴抽出回路 △ネオコグニトロン ○マルチプルテンプレート △LVQ、LVQ2 △RCE △直交化回路	◎意味ネットワーク
◎時間・空間的非線形歪の除去	○連想記憶モデル △アソシアトロン △相関行列型連想記憶モデル △HASP ○コネクショニストモデル △Massively Parallel Parsing
○時間・空間的窓のシフト △ネオコグニトロン △TDNN ○DPマッチング △ダイナミックニューラルネット ワーク △ニューロパターンマッチング ○確率有限状態機械 △ボルツマンマシン △HMM	◎手続き記憶
◎トップダウン処理の統合	○連想記憶モデル △アソシアトロン(石取りゲーム) △HASP(足し算過程) ○コネクショニストモデル △PDP(三目並べ)
○単語情報 △Rumelhart and McClellandのモデル	◎知識獲得
	○連想記憶モデル △HASP(数字系列の獲得) ○コネクショニストモデル △PDP(動詞の過去形)
	拘束処理と最適化問題
	◎組合せ問題
	◎Structure from X
	○変分問題の枠組みによる視覚の逆問題
	◎統計的画像処理
	◎ロボティクスと逆問題
	○Inverse Kinematics and Dynamics

図表3.2-1 ニューラルネットワークに関する研究課題(キーワード)

(a) はじめに

バックプロパゲーション型学習アルゴリズムが提案されて以来、工学的なニューラルネットワークによるパターン認識に関する研究が盛んに行われている。従来のパターン認識機械より高い認識率が得られるとの研究結果が報告されており、その有効性が注目されている。しかしながら、パターン認識に有効な学習アルゴリズムは他にもある。また、バックプロパゲーションだけでは片づかないパターン認識の問題は数多くある。

数字列など個々の要素間に意味的な制約のない場合は別として、言語情報を積極的に利用することにより、パターン認識能力は飛躍的に頑健になる。個々の文字や音韻が識別できなくても、周りの文字列からそれがなんであるかを推定することができる。言語情報をオンラインで利用するためには、適切な情報を高速に検索できる記憶のメカニズムが必要になる。意味的制約を表現できる連想記憶が重要になる。

本項では、以上に述べた点に焦点を当てて、パターン認識と記憶に関するニューロコンピューティングの流れを概観するとともに、今後の研究課題について考えてみることにする。

(b) パターン認識のニューラルネットワーク

パターン認識に必要となる機能には、


- ① 特定の特徴の組合せに選択的に反応する素子、すなわち鋳型照合回路の学習による構成、
- ② 音声や手書き文字のように、特徴の組合せに侵入する時間的、空間的な非線形歪に強いパターン照合法、
- ③ ボトムアップの処理だけでは原理的に特定できない音声や文字を、前後の情報や文法的制約、意味的制約を用いてトップダウン的に処理する機能、などが考えられる。以下これらの機能に焦点を当てて、これまでの研究を概観する。

(1) 鋳型照合回路の学習











① パーセプトロン型学習回路

ニューラルネットワークによるパターン認識の原点は、パーセプトロンにある [1]。パーセプトロンは、入力パターンを幾つかのクラスに分類することを学習できるが、その限界はクラス間が線形分離でなければならないことにあった。パーセプトロン（正確には単

純パーセプトロン) は図表3.2-2に示したような3層構造の階層型学習回路であったが、学習するのは中間層と出力層の間の結合だけであり、本質的には2層の学習回路である。2層構造の学習回路は超平面による線形分離可能な決定領域しか表現できないが、層を増やすことによってどのようなことが可能になるのであろうか。層数とクラス分類能力の関係を図表3.2-3に示した〔2〕。3層構造にすれば凸決定空間が、4層にすれば任意の決定空間が構成できることになる。決定空間を構成する線分一本一本が、中間層の一つの素子によって決められる線形分離平面になる。それらの平面の論理積で決定空間が構成されることになる。



図表3.2-2 パーセプトロン型学習回路

構 造	識別領域	XOR問題	網 か け	領域の形
2層 	半平面			
3層 	凸面			
4層 	任意			

図表3.2-3 パーセプトロン型学習回路の階層数とそのパターン識別能力(Lippmann)

多層にすればクラスの識別能力が上がるが、さてどの様にしてこれらの層間の結合を学習させればよいのであろうか。それに答えたのが、Rumelhart らが提案したバックプロパゲーション型学習アルゴリズムである [3]。出力層で計算された誤差を中間層に順次逆伝搬（バックプロパゲート）させることによって、何層でも学習させることができる。

しかしながら問題がある。バックプロパゲーションは出力層に与えられる教師信号と実際の出力との差の 2 乗を最小にするよう各層間の結合を変更していくアルゴリズムである。この過程は、最急降下法により誤差の 2 乗の極値を求めることに対応している。最急降下法の問題点は、局所的な極小値に落ち込んで、学習が進まなくなることである。この場合の極小値は、複数の決定領域が一つになって分離できない状態に相当する。層数が多くなるほど問題は深刻になる。学習速度をゆっくりとし、異なった初期値を用いて複数回学習させることが問題を避ける一つの方法であるという。しかし学習に時間がかかりすぎてしまう。

② 自己組織型学習回路

パーセプトロン型学習回路は、教師の指示にしたがって入力パターンの分類法を学習する回路である。教師の指示なしに適当な出力素子が特定の特徴の組合せに反応するようにできる回路を、自己組織型学習回路という。出力素子の選択に競合回路が使用されるので、競合型学習アルゴリズムとも呼ぶ。競合回路により、最大入力を受けている素子が他の素子の反応を抑え、その素子が鋳型を獲得する。

自己組織型学習回路の原点は、von der Malsbergの研究にある [4]。彼の研究はパターン認識そのものではなかったが、競合という概念を学習に導入した点で高く評価できる。福島は、多層回路を競合原理により自己組織的に学習させ、ネオコグニトロンを提案した [5]。入力パターンの位置ずれを吸収するために各層の素子が獲得した前段の層との間の結合パターンを、視野全体をカバーするように位置をずらしながらコピーする。また、特徴間の位置的歪を吸収するために各層間にボケ回路を入れている。最近は出力層からのフィードバック回路を組み入れることにより、複数の入力パターンが同時に与えられた場合でも一つずつ分離するセグメンテーション機能を実現している [6]。


③ マルチプルテンプレート学習回路

パーセプトロンは線形分離平面の組合せでクラスを分類することは先に述べた。その組

合せを学習によってうまく作り出すことが長所であり、場合によってうまく行かないことがあることや時間がかかることが欠点であった。

最近この欠点をなくした認識回路が提案されている。2種類あるが、一つのクラスのパターン空間を複数の鋳型（マルチプルテンプレート）でカバーするという意味で、考え方は似ている。一つは、Kohonenが提案したLVQ（Learning Vector Quantization）であり、パターン空間を複数の参照ベクトル（鋳型）がボロノイ図（Voronoi Map）、図表3.2-4（a）を構成するように学習を行う[7]。ボロノイ図とは、各参照ベクトルが張る領域内の全てのベクトル（入力パターン）が、その参照ベクトルと最も近い距離になるように構成された地図である。彼はこの考え方を音声認識に適用している[8]。

もう一つは、Cooperによって提案されたRCE（Restricted Coulomb Energy）である[9]。複数の参照ベクトルでパターン空間をカバーすることは同じである。同じクラスに属する入力パターンが、既に獲得した参照ベクトルの張る空間に入らなければ、その入力パターンを新しい参照ベクトルとして採用する。その参照ベクトルが張る空間の半径を最初は大きくしておき、間違えたら半径を小さくするというきわめて単純なアルゴリズムで学習する（図表3.2-4（b））。



（a）Kohonen のLVQ によるボロノイ図型学習回路。

- クラス1の参照ベクトル、
- クラス2の参照ベクトル。

（b）CooperのRCE. 間違えたら領域を小さくすればよい。

図表3.2-4 マルチプルテンプレート型学習回路

(2) 時間・空間的非線形歪の除去

音声認識では発話時間が伸縮するので、この伸縮に影響されない入力パターンと鋳型との照合機構が必要になる。Waibelらは、連続した複数フレームの音声スペクトル情報を1フレームずつずらしながら多層パーセプトロン型認識回路に入力することにより、時間伸縮に強い有声破裂音認識を行った(TDNN: Time-Delay Neural Network と呼ばれている) [10]。また、マクダーモットらは、LVQと組合せることにより99%程度の認識率が得られたことを報告している [11]。

音声認識にはDP (Dynamic Programming) マッチングが有効であることは以前から知られていた。迫江らは、DP マッチングにより時間伸縮の正規化を行った後に多層パーセプトロン型認識回路で認識する、ダイナミックニューラルネットワークを提案している [12]。DP マッチングは、入力パターンと候補の鋳型との累積距離を求め、最小の累積距離を持つ鋳型を選択する。したがって、候補の鋳型がN個あれば、N回累積距離を計算する必要がある。最近平井は、両眼立体視の対応検出の考え方を利用して、時間軸や空間的な非線形歪を含む入力パターンとN個の鋳型とを並列的に照合できるニューラルネットワークを提案した(ニューロパターンマッチングと呼んでいる) [13]。また、最近音声認識で脚光を浴びているHMM (Hidden Markov Model) とニューラルネットワークを統合する試みもある [14]。

視覚パターン認識では、先に述べたように福島の新コグニトロンが空間的正規化能力を持っている。


(3) トップダウン処理の導入

パターン認識をボトムアップ処理のみで行うことには無理がある。例えば図表3.2-5に示した「A」は、現われる文脈によってAと解釈しなければならない場合もあるし、Hと解釈しなければならない場合もある。同様の状況は音声認識についても生じることが知られている。さらに単語の意味の認識となると、その単語が現われる文法的な位置(名詞か動詞かなど)、何について語られているのかなどの情報が必要となる。

THE CAT

図表3.2-5 ボトムアップ処理だけではどうしようもない例

McClellandとRumelhartは、文字列の認識に関するボトムアップ処理と単語の情報によるトップダウン処理を併合したモデルを提案した（図表3.2-6）[15]。単語の情報を用いることにより、文字列内の文字が同定できなくてもそれが何の文字か判断することができる。このモデルは、パターン認識におけるトップダウン情報処理をニューラルネットワーク（彼らはコネクショニストモデルと呼んでいる）の枠組みで表現したものであり、高く評価できるモデルである。




図表3.2-6 ボトムアップ処理とトップダウン処理（意味的拘束）の統合例
(Rumelhart & McClelland)

(c) 記憶のニューラルネットワーク

通常の意味でのパターン認識は、音声や文字の形の識別を目的としている。しかしながら、形が識別できてもその文字列の意味するところが分からなければ、認識できたとは言えないであろう。文字列から単語へ、単語列から文章へと理解のレベルを上げて行くためには、記憶に蓄えられている適切な意味情報をオンラインで検索できる必要がある。


人間の記憶には、大きく分けて2種類ある。現在起きている事象を短時間保持する短期記憶と、起こった事柄や単語の意味などの知識を長期にわたって記憶する長期記憶に分類されている。長期記憶には車の運転法やワープロの使い方などに関する諸々の手続きに関する知識の記憶も含まれる。これらの知識が脳内の異なった場所に記憶されているという証拠もある[16]。記憶の分類を図表3.2-7に示した。本稿では長期記憶、その中でも特に意味記憶と手続き的知識の記憶に関するニューラルネットワークに焦点を当てることにする。



図表3.2-7 記憶の分類

(1) 意味記憶のモデル

ニューラルネットワークによる意味記憶のモデルは、連想記憶モデルが原点である。1970年代のはじめにAnderson[17]、Nakano[18]、Kohonen [19]らによって提案された。連想記憶モデルには2種類ある。図表3.2-8 (a) に示した回路を相互想起型連想記憶モデルという。Xから入力されたキーパターンとYから入力された連合項目との間の連合を、回路内の結合係数 W_{ij} を学習させることにより記憶する。次にキーパターンを入力することにより、それと連合して記憶された項目がZの出力として求められる。例えば、「バラの花の色は」というキー入力により「白」を得ることができる。Xを入力層、Yを教師入力、Zを出力層と考えれば、パーセプトロン型の学習回路はこの回路と類似しているので、パターンアソシエータとも呼ばれている。



図表3.2-8 連想記憶モデルの基本回路

もう一つの回路は、図表3.2-8(b)に示した自己想起型連想記憶モデルである。この回路では、「バラの花」、「色」、「白」を表すパターンをYから同時に入力してそれらの間の関係を記憶する。次に「バラの花」と「色」だけを入力することにより、「白」もそれらと同時に出力として検索することができる。部分を入力することで全体を取り出せることから、パターン完成と呼ばれる。

「バラの花の色」が幾つもあるように、言葉の意味も幾つもある。パターン認識の究極の目的が音声や文字列で表された文章の意味の同定にあるのであれば、記憶モデルも複数の意味が表現でき、かつ文脈などの情報を用いて複数の意味の中から適切なものをオンラインで選択できなければならない。平井のH A S P (Human Associative Processor) は、積集合検索により複数の意味の中から適切なものをオンラインで選択できるようにした連想記憶モデルである[20]。ニューラルネットワークの並列処理が生かされているモデルである。

文章理解を目指した試みもある。Waltz らのMassively Parallel Parsingがよく知られている[21]。一つの言葉が持つ複数の意味は、一つの文章の中で同時に生起することはない。同時には生起しない意味を表すノードの間には、一つの意味が選択されたら他の意味を抑えるような相互抑制結合が仮定されている。文法情報と文脈情報を用いて適切な意味を選択できるようになっている。

(2) 手続き的知識の記憶モデル

車の運転でギアを切り替える時のことを考えてみよう。まずアクセルを離し、クラッチを踏んでギアを切り替え、クラッチを徐々につなぎながらアクセルを踏み込む。次の動作への移行は、前の動作を実行したことと、エンジン音や速度変化などの条件が成立した後に行われる。このような過程はプロダクション規則によって表現することができる。ニューラルネットワークでこのような手続きの系列的な実行過程を表現した例としては、平井らの足し算過程のモデルがある[22]。足し算の実行に必要な意味記憶、手続き記憶、作業記憶をH A S Pの枠組みの中でモデル化し、それらを統合したモデル構成になっている。プロダクションシステムに見られる実行管理者は不要であり、自律的に動作する。

(3) 知識獲得過程のモデル

知識獲得過程で生じる現象は、記憶モデルの妥当性に関する重要なデータを与えてくれ

る。Rumelhart らは、子供が動詞の過去形を獲得する過程に関して興味深いモデルを提案している[23]。子供たちがまず出会う基本動詞には不規則変化するものが多い。ところが規則変化する動詞を獲得していくうちに、既に獲得した不規則変化する動詞が規則変化するに引きずられてしまうという。彼らは相互想起型連想記憶モデルを用いてこの過程を見事に再現している。


最近Maと平井は、子供が数字の系列を獲得していく過程で生じる幾つかの現象を、やはりHASPを用いた記憶モデルで再現している[24]。

(d) 拘束処理と最適化問題

ニューラルネットワークで巡回セールスマン問題のような組合せ最適化問題が解けることを、Hopfieldらが示して以来、この種の研究が盛んになっている。MITのPoggioらのグループは、変分法の枠組みで視覚の初期過程の問題を統一的に体系付ける試みを行っている[25]。また、Geman & Geman による統計的最適化手法による画像の復元も、大きなインパクトを与えている[26]。ロボティクスに関しては、ATRの川人等の研究がある[27]。

(e) 今後の課題

ニューラルネットワークに関する研究を概観した。パターン認識の究極の目的が、パターンの分類にとどまらず文章の理解やそれに基づく推論にまであるとするならば、それらを統合したニューラルネットワークに関する研究が必要である。頑健なパターン認識を行うためには、絶対に必要な研究である。最後に図表3.2-9にニューラルネットワークの各種アプリケーションに必要なニューロン数とシナプス数を示した。人間並の能力を実現するためには、ハードウェア的に見れば少なくとも 10^{10} 個のニューロンが必要となる。このような大規模並列処理系の構成は、国家プロジェクトでなければできない魅力的なテーマであると考えられる。



図表3.2-9 ニューラルネットワークのアプリケーションと
その実現に必要なニューロン数とシナプス数

[参考文献]

- [1] F. Rosenblatt: "Principles of Neurodynamics", Spartan Books (1962).
- [2] R. P. Lippmann: "An introduction to computing with neural nets", IEEE ASSP Magazine, Vol. 4, No. 2, pp. 4-22 (1987).
- [3] D. E. Rumelhart, J. L. McClelland and the PDP Research Group: "Parallel Distributed Processing", Vol. 1 and Vol. 2, The MIT Press (1986); 甘利俊一監訳「PDPモデル」産業図書(1989).
- [4] C. von der Malsberg: "Self-organization of orientation sensitive cells in the striate cortex", Kybernetik, Vol. 14, pp. 85-100 (1973).
- [5] K. Fukushima: "Neocognitron: A self-organizing neural network model for a

- mechanism of pattern recognition unaffected by shift in position",
Biological Cybernetics, Vol.36, pp.193-202 (1980).
- [6] K.Fukushima: "A neural network model for selective attention in visual pattern recognition", Biological Cybernetics, Vol.55, pp.5-15 (1986).
 - [7] T.Kohonen: "Self-organization and Associative Memory", 2nd. ed. Springer-Verlag (1988).
 - [8] T.Kohonen: "The 'neural' phonetic typewriter", IEEE Computer, Vol.21, No.3, pp.11-22 (1988).
 - [9] L.Cooper: "Adaptive pattern recognition", Tutorial in IJCNN'89 (1989).
 - [10] A.Waibel, T.Hanazawa, G.Hinton, K.Shikano and K.Lang: "Phoneme recognition- neural networks vs. Hidden Markov Model", Proc. of ICASSP, S3.3, pp.107-110 (1988).
 - [11] エリック・マクダーモット、片桐滋: "学習ベクトル量子化を用いた時間窓位置変動に強い音韻認識", 信学技報、SP88-84, pp.703-711 (1988).
 - [12] 迫江博昭、磯健一: "ダイナミックニューラルネットワークの検討", 信学技報、SP87-101, pp25-30 (1987).
 - [13] 平井有三: "神経回路によるパターン照合", 信学論、Vol. J72D-II, No.1, pp.148-156 (1989).
 - [14] 中川聖一: "確率モデルによる音声認識" 第6章、電子情報通信学会(1988).
 - [15] J.L.McClelland and D.E.Rumelhart: "An interactive activation model of context effects in letter perception: Part 1 An account of basic findings", Psychological Review, Vol.88, No.5, pp.375-407 (1981).
 - [16] L.R.Squire: "Memory and Brain", Oxford University Press (1987).
 - [17] J.A.Anderson: "A memory storage model utilizing spatial correlation functions", Kybernetik, Vol.5, PP.113-119 (1968).
 - [18] K.Nakano: "Associatron: A model of associative memory", IEEE Trans. on SMC, Vol.SMC-2, No.3, 380-388 (1972).
 - [19] T.Kohonen: "Correlation Matrix Memories", IEEE Trans. on Computers, Vol.C-21, No.4, pp.353-359 (1972).
 - [20] Y.Hirai: "A model of human associative processor (HASP)", IEEE Trans. on

SMC, Vol.SMC-13, No.5, pp.851-856 (1983).

- [21] D.L.Waltz and J.B.Pollack: "Massively parallel parsing; A strongly interactive model of natural language interpretation", Cognitive Science, Vol.9, No.1, pp.51-74 (1985).
- [22] Y.Hirai and Q.Ma: "Modeling the process of problem-solving by associative networks capable of improving the performance", Biological Cybernetics, Vol.59, pp.353-365 (1988).
- [23] D.E.Rumelhart and J.L.McClelland: "On learning the past tenses of English verbs", 文献(3)の第18章.
- [24] Q.Ma and Y.Hirai: "Modeling the acquisition of counting with an associative network", Biological Cybernetics, Vol.61, pp.271-278 (1989).
- [25] T.Poggio, et al.: "Computational vision and regularization theory", Nature, Vol.317, pp.314-319, (1985).
- [26] S.Geman and D.Geman: "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images", IEEE Trans. on PAMI, Vol.PAMI-6, No.6, pp.721-741, (1984).
- [27] H.Miyamoto, M.Kawato, T.Setoyama and R.Suzuki: "Feedback-error-learning neural network for trajectory control of a robotic manipulator", Neural Networks, Vol.1, pp.251-265, (1988).

3.2.2 AIにおける並列処理

(1) はじめに

超並列超分散処理の基本機能とそのモデルについて従来の計算機科学、特に人工知能研究(AI)の立場から述べる。AIの中にニューラルネットを含める立場もあるが、ここではAIを記号処理と等価なものと考えて議論する。まず出発点として計算機のハードウェア、ソフトウェアを以下のようにモデル化する。

・基本モデル[ハードウェア]

とりあえず非常に粗く、 $N \text{ cpu} \times M \text{ mu}$ とする。ただしmuはメモリユニットである。cpu、muの内部構造、両者の結合形態などについては特に規定せずオープンとする。

・基本モデル[ソフトウェア]

以下の階層を持つものとする。

- ① 計算の理論……チューリングマシン、論理、ラムダ計算、・・・
- ② プログラム理論……手続き型、論理型、関数型、オブジェクト指向型、・・・
- ③ アルゴリズム
- ④ 問題……問題の厳密な記述

・ニューラルネットの基本モデル[ソフトウェア]

例えば以下のようなモデルを考えることもできる。

- ① 計算の理論……力学系、・・・
- ② ネットワーク設計
- ③ 学習素材準備
- ④ 問題……修練でしか獲得できないもの

両モデルの比較で分かることは両者が情報処理の機構として全く異なるものをベースとしていることである。ベースが異なる以上、両者の基本機能は異なる。しかし計算可能性というレベルで比較したときに差があるのかどうかは定かではない。ただ理論的計算可能性の差が現実的な両モデルの機能の差を良く表現できるかどうかは疑問である。

実際問題として両モデルの適用可能な問題も異なるはずである。例えば惑星探査衛星の軌道計算などはニューラルネットには不向きなものであろう。また近年のニューラルシステムの具体的応用で示されてきたのは、数学的に厳密に記述できないような問題、例えば、パターン認識などでは学習能力のあるニューラルシステムが性能において従来システムと比べ遜色なく、また開発期間に関してははるかに優ることもあるということであった。

両モデルの能力的あるいは計算量的差異を明らかにすることは理論研究に期待するとして、基本機能・モデルという立場では両者は相補的であるということをいわばテーゼとして先に進む。具体的には以下のような相補的関係を想定する：方法、アルゴリズム、計算、制御 (control) $\longleftrightarrow$ 記憶、認識、連想、データ。ここで左側は従来の計算モデル、右側はニューラルネットの計算モデルである。

(2) スケールアップ

従来の計算モデルをベースに超並列超分散へと至る道筋について考えてみる。なお元来、

並列と分散はそれぞれ異なるものを意味する用語として用いられている。従って、ここで超並列超分散という場合それが何なのかを明確にしておかなければならないが、ここではこれを主に超並列としてとらえていることを注意しておく。

ハードウェアの側面から考えると超並列超分散とは巨大な cpu 数 N と μ 数 M を意味する。またソフトウェアの側面から考えると次のような問題がある。すなわち超並列超分散度を内包した問題とはどのようなものか、またその超並列超分散処理とはどのような性質を持っているか。ここでは主にこのソフトウェアの側面について考える。

まず最初に、期待される超並列超分散度はどのようにもたらされるのかについて考察する。

ここでは静的、動的という分類を試みる。

[静的] 超並列超分散度は最初に問題の中に陽に現れている。

このような問題としては多体問題のような大規模シミュレーション問題や、遺伝子を扱うような大規模データ処理問題などがある。

[動的] 超並列超分散度は問題を解く過程で出現する。

このような問題としては従来から人工知能で研究されている探索、学習、発見、類推などがある。これらの問題では調べるべき場合の数が問題解決中に組合せ的に増大する。処理内容からは次のような分類ができる。

[均一] 超並列超分散に実行される処理がすべてほぼ同一である。

いわゆる data parallelism であり、大規模データの処理を核とする問題が該当する。

[不均一] 多様な処理が同時に行われる。

いわゆる control parallelism である。これに関してはさらに次のような分類もできる。

- 決定的アルゴリズム ⇒ 静的超並列問題
- 非決定的アルゴリズム ⇒ 動的超並列問題

(3) 応用から

ここでは人工知能分野の応用問題においてどのような処理に超並列超分散処理が求められるか具体的事例を基に調べる。上の議論を反映して期待される超並列度に関しては、データやメモリに関連する処理 [M] と制御や cpu に関連する処理 [C] に分けて調べる。

【自然言語処理】

自然言語処理には理解や翻訳などの高レベルの処理から、構文解析、辞書引きといった低レベルの処理まで様々な処理がある。

[M] 大規模辞書の扱い、文脈依存の辞書引き、...

[C] パラグラフ、文、単語、各レベルの並列処理

Connection Machine で実験されている構文解析時の単語の辞書引きにおいては1プロセッサ当たり1単語を割り当て次のような処理を行っている。

① テキストと各辞書項目をそれぞれプロセッサに割り付ける。

② それらをソートする。

テキスト中の単語と対応する辞書項目が横に並ぶ。

③ 辞書項目の内容を単語に移す。

④ もう一度初めの順に並べ戻す。

64,000単語辞書を使って約70msecで処理を行うと報告されている。

【文献検索】

大量の文献集合の中から欲しいものを捜し出す問題である。

[M] 大規模文献ベースの扱い、大量のデータを同時に高速にスキャンする部分的特徴によるパターンマッチング

[C] Connection Machineで実験されている文献検索システムでは、ロイターの記事15,000件を題材に200項目のキーワードを用意している。各記事はその特徴を500バイトにエンコードされ、Connection Machineの1プロセッサに割り付けられる。検索においては次のような処理を行っている。

① キーワードを全プロセッサにスコアつきでブロードキャストする。

② 各プロセッサはそのキーワードが自分の記事にあればスコアを加える。

③ スコアの高い文献を順に取り出す。

約40msecで検索すると報告されている。

【事例推論】

良く似た過去の事例を参考にして現在の問題を解決するという手法である。

[M] 大規模事例ベースの扱い、大量のデータを同時に高速にスキャンする部分的特徴によ

るパターンマッチング

[C] Connection Machineで実験されている事例推論システムでは、患者のカルテをベースにした医療診断が行われている。事例であるところのカルテには、年齢、性別、症状、病歴、診断、検査結果、処方などが記されている。Connection Machineでは1プロセッサ当たり1事例を割り当てる。この事例推論でキーとなる操作は、重み付きの連想サーチというもので、これは記憶中（プロセッサ群中）にある事例で現在問題となっている事例と良く似ているものを搜し出すのに使われる。処理は以下のように進む。

- ① 新しい患者の特徴データを全プロセッサにブロードキャストする。
- ② 各プロセッサは特徴の近さを数値で表して全体のスコアに加える。
- ③ 全体のスコアの高いものを選ぶ。

4,096 事例で8.9sec、32,768事例で10.7sec かかったと報告されている。また一般に事例推論では事例の数が多ければ多いほど誤推論の可能性が減るとも述べている。

【学習、類推、発見】

文献検索や事例推論では基礎となるデータがあらかじめ整形してあった。いわば特徴抽出済みのデータを初めから持っていたわけである。これに対し学習、類推、発見などにおいては意味のある特徴抽出や一般化を行うことが重要な課題となる。この場合大量のデータをベースに様々なデータの組合せを考え、暫定的に特徴の定義や一般化手法を定義しては実データでそれを評価するという試行錯誤的アプローチをとる。

[M] 大規模事例の扱い、特徴抽出、部分的特徴によるパターンマッチング

[C] 探索

【大規模シミュレーション】

オブジェクト指向に基づく大規模シミュレーションでは対象モデルを構成するオブジェクトの数が巨大になる。また単位時間当たりのイベントの数も巨大になる。

[M] 大規模のオブジェクトベースの管理

[C] 多数のイベントの同時処理

(4) まとめ

従来の計算機科学の計算モデルとニューラルネットの計算モデルの両者を比較しつつ、

両者の基本機能は基本的に相補的であるという認識に立ち、従来の計算機科学の延長上でどのような超並列超分散処理があり得るかについて、特に人工知能の分野を手がかりに検討した。

幾つかの分野の調査を通じて、例えば

- ① メモリインテンシブな処理
- ② 大規模オブジェクトシステム

などでは超並列超分散処理が期待できることが分かった。

前者は文献検索、事例推論に代表されるような記憶中の大規模データを対象にした検索を基本演算とする。学習、類推、発見などの処理で行う高次の分類処理などもメモリインテンシブな処理といえる。このような処理はメモリ中のデータ間の演算が中心であり、またメモリ中のデータが大量であることが特徴である。このような処理を高速に行わせる場所として記憶装置を超並列演算機構として見直すことは一つの可能性としてあり得る。その際、その新しい記憶装置は内容指向の高次の store/retrieve を通じて外界（従来の計算機も含む）とインタフェースをとり、また絶えず格納データの特徴抽出をしたり、分類をしたり、統計的相関をとったりという自己組織化機能を備えることも考えられる。

後者は大規模シミュレーションに代表されるような処理であり、問題対象モデルの規模に応じた超並列超分散度が得られる。

〔参考文献〕

- [1] David Waltz, "Applications of the Connection Machine", IEEE Computer, January, pp. 85-97(1987).

3.3 システムアーキテクチャ／ソフトウェア

3.3.1 超並列システムアーキテクチャ

計算機の適用分野が拡大し、従来の科学技術計算・記号処理中心の分野から、扱う対象が非構造・非定型で定式化が困難な問題への適用が望まれている。この様な分野ではパターン照合や連想処理といった処理が要求され、ベクトル型やパイプライン型のスーパーコンピュータではベクトル構成の特徴が十分に生かされず、大きな高速化は期待できなくなっている。さらに、今までの速度向上は主に素子性能の向上によるところが大であったが、スイッチング動作が回路の伝播速度で押えられるまでに回路技術の進歩が飽和段階に来つつあり、今後飛躍的な速度向上が望めない状況にある。この様な中で、並列処理、特に超並列処理への期待が高まっている。超並列処理を可能とするためには従来のノイマン型の計算モデルとは異なる超並列向きの計算モデルが重要となる。生物の脳・神経回路網の機能・構造から学び考え出された人工神経回路網が超並列処理の計算モデルとして近年注目されている。

本節では並列計算機システムの動向、神経回路網を模したニューロコンピュータへの期待と課題、及びシステムとした場合のソフトウェアも含めた課題についてまとめる。


3.3.1.1 並列計算機システムの動向

並列処理の考え方は図表3.3-1に示すとおり、計算機の誕生とほぼ同時期から、その研究は開始されており、30年以上の歴史を持っていることになる。これまでは主としてハード面の制約で高並列な計算機の開発が困難であったが、VLSI/ULSIの発達で超並列マシンの開発も夢でなくなりつつある。1ビット計算機ではあるが6万4千台の商用マシンが開発されるまでになっている。原理的には計算機の台数を増せばそれにほぼ比例して性能向上が見込まれることになるが、実際の問題に並列処理を適用すると並列度がそれほど上がらず性能向上が頭打ちになることが多い。逐次処理部分の影響と速度向上の関係を簡潔に示した経験則が“アムダールの法則”として知られている。逐次処理部分をs、プロセッサ数をnとすると速度向上度Pは下式で得られる。

$$P = 1 / (s + (1 - s) / n) < 1 / s$$

上式ではプロセッサをいくら増やしても $1/s$ より速度が上がらないことを示している。

例えば $s=0.1\%$ の場合、1,000倍より速くならないことになる。これまでに各種の分野で並列



図表3.3-1 コンピュータシステムの発展

処理の適用が試みられているが、画像処理などの特殊な分野を除いては数万から数百万台もの計算機を有効に活用できるほど十分な並列性の開拓が進んでいるとはいえない。多数の計算機がメモリ資源へのアクセスが競合して、逐次アクセスとアクセス遅延のためにCPUが遊んでしまう、いわゆる“フォンノイマンボトルネック”が最大の問題となっている。このフォンノイマンボトルネックの解消が超並列システムアーキテクチャの課題と言える。このボトルネックを克服する計算モデルとして、問題に含まれる自然な並列性を模したオブジェクト指向や、データ並列処理と共にニューラルネットワークが期待される。

ここで言う神経回路網は実際の生物における神経回路網をさすのではなく、その動作を電子回路などで模擬するものである。両者の違いを明確にする意味で後者を人工神経回路網(Artificial Neural Network)と呼ぶこともある。人工神経回路網の立場は脳の構造や情報処理機構にヒントを得て従来型の計算機と異なる新しい計算機(ニューロコンピュータ)の実現を目指しているが、実現された計算機構は必ずしも生物の機構と同じである必要はない。神経回路網の機能の解明という科学的な観点よりは、神経回路モデルを用いた時どのような計算能力が得られるか、また並列処理の枠組みとしてどのような適性があるかを考える工学的な観点が強いと言える。

人工神経回路網とは簡単な関数計算を行う計算ユニットが互いに重み付きの方向性リンクで結合されてネットワークを構成し、各々の計算ユニットは出力値をリンクを介し伝播しながら情報処理を行うものである。ネットワークのふるまいは結合形態(トポロジー)、重み、計算ユニットの関数形式によって定められる。ニューロコンピュータは従来の計算機のように蓄積されたプログラムによって動かすのではなく、ネットワークの結合形態に知識が蓄積され、神経回路網が自ら環境に適応して動く情報処理システムである。そこでは環境からの収集データにより、連想・変換・マッピング・推論を行い、結果を得て環境に働きかける。その間に新たに得た情報から学習し、自らの神経回路網を環境に適合するように自己組織化を行う。人間の脳には 10^{11} 個もの神経細胞があるとされているので、現在のLSI技術をもってしても人間に匹敵するような高度な人工神経回路網を実現することは困難である。しかし、最近になって音声認識、文字認識、組合せ最適化問題や学習方式などの分野で、現実的なニューロン数でもかなりの処理能力が実現出来る見通しが出ている。


3.3.1.2 ニューロコンピューティングの技術領域

問題解決のために用いられるアプローチは各々の問題領域に大きく依存する。考えられるアプローチとして、①解析的・アルゴリズム的アプローチ、②A I・エキスパートシステムのアプローチ、③ファジィ推論的アプローチ、④ニューラルネットワーク的アプローチ、の4つがある。対象が良構造で数理モデル化ができたり、あるいはアルゴリズムが与えられ、決定的な知識を用いて計算をすれば解ける場合は解析的手法あるいは最適化手法が適している。しかし、対象領域のモデル化が困難であったり、また仮にモデル化できたとしても解法が有効で無い場合にはA I手法、ファジィ手法あるいはニューラルネットワークのアプローチが向いていると考えられる。A I手法（エキスパートシステム）／ファジィ手法とニューラルネットワークのアプローチと比べると、前者のエキスパートシステムのアプローチは記号処理が主体となり、人の知的な高次の認知過程・行動を良く表現し、意識的処理・逐次的処理であり、後者のニューラルネットワークのアプローチは非シボルの処理が主体となり、生のデータから結論を学習するもので、連想的・自動的・並列的処理である。各々のアプローチの有効な分野、特徴、問題点をまとめると図表3.3-2のとおりである。

図表3.3-2 問題解決のアプローチ

アプローチ種別	有効な分野・特徴	問題点
解析的 アルゴリズム的 アプローチ	問題の特性が既知 論理・解析モデルが有る 良構造問題向き 計算が確実・高速	環境変化・雑音に弱い モデルの変更が困難
エキスパート システムの アプローチ	開いた問題分野向き 論理的な関係で事象が説明可 経験則で解を探索する分野 知識のモジュール化 複雑な知識表現・推論 逐次計算向き	知識獲得・学習の負担大 ルールの適用が離散的 ルールの変更に敏感 パターン処理・連想処理が苦手
ファジィ推論的 アプローチ	問題が定式化困難な問題向き 専門家の経験則のコード化 制御対象の非線形性が強い 曖昧さを定量化 生データを入力	多段の推論で曖昧さが蓄積 大規模システムへの適用性 ルールが因果関係的でない
ニューラル ネットワーク的 アプローチ	問題の定式化困難な問題向き 雑音を含む生データの処理 連想・類推処理に向く 訓練による自動的学習	学習結果が取り出せない 動作を説明出来ない 構造データの扱い困難 記号処理が苦手

ニューラルネットワークのアプローチでは生体情報処理の解明から応用、モデル、計算機まで幅広い分野から多角的な技術検討が行われている。それぞれの領域では目的・課題も、それぞれ異なり独自に研究が行われていた感がある。しかし、次の世代の情報処理の一翼を担うためには技術の相互利用・協調した研究が必要である。図表3.3-3に技術分野と技術項目を整理した。技術分野は大きく分けて、ニューロ基礎／モデル、ハードウェア／アーキテクチャ、応用の3つの領域に分けて見ることができる。



図表3.3-3 ニューロコンピューティングの技術マップ

ニューロ基礎／モデル領域では生体情報処理系の解明、そのモデル化および数理的な動作の解析等が主目的となる。生体の題材として線虫、アメフラシ、ヤリイカ、ナメクジ、猿などを用いた基礎的な研究が行われている。モデル化では多くのモデルが提案され、それらの適用性、学習方式、数理的な解析・計算可能性などが研究されている。

応用領域では音声認識、文字認識、画像処理などのパターン認識や制御分野、AIの分野でその適用が進められている。

ハードウェア／アーキテクチャ領域ではVLSI、WSI、超並列処理の計算モデルとして、また応用領域、基礎領域におけるツールとして、高速処理方式、開発環境の高度化の研究

が盛んである。

3.3.1.3 ニューロコンピューティングのためのハードウェア

従来型の計算機は数値計算・記号処理を得意としているが、本質的に並列に動作している神経回路網のような単純な計算ユニットの集合体を処理するには粒度が細かすぎ並列性も生かされず遅くなってしまう。そこで、神経回路の持つ並列性を生かし、計算アルゴリズムを専用のハードウェアなどで実現した専用ハードウェアが開発されるようになってきた。

神経回路モデルを実際のハードウェアで実現する場合、必要な機能は以下の通りである。

- ① 乗算演算：各ニューロンから来る出力値と重みを乗算する（シナプス毎）。
- ② 加算演算：重み付けされた入力値の累計をとる（ニューロン毎）。
- ③ 閾値関数計算：内部状態値からシグモイド関数などを適用し出力値を求める（ニューロン毎）。
- ④ 状態値伝播：出力値を接続先のニューロ素子に伝播する（シナプス分）。
- ⑤ 重みの記憶：各々のニューロンとの接続情報及び荷重の値を記憶しておく（シナプス毎）。

これまでは必須とも言える機能であったが、以下のものは誤差逆伝播の学習機能をハードウェアで実現する場合に必要となるものである。

- ⑥ 誤差の計算：各々のニューロンで誤差の逆伝播。
- ⑦ 重み修正：出力値と誤差の積をとり荷重を修正。

神経回路網を高速に処理するハードウェアを考える場合、次の点を考慮する必要がある。

- ①神経回路ユニットの専用ハードウェア／LSI化
- ②計算アルゴリズムの専用化・ハードウェア／LSI化
- ③部分ネットワークの並列性の開拓
- ④学習に対応したシナプス／構造の可変性

以上の点を考えて各種の実現形態が考えられている。アーキテクチャの選択上考えるべき第1点は、1つ1つのニューロンを各々別個のハードウェアで実現する実ニューロン方式か、1つのハードウェアが複数のニューロを分担する仮想ニューロン方式かである。前者はアナログ、光電気、デジタル方式の各種のものが提案されている。ハードウェアも比較的単純で処理も早いが集積度の面とモデルの柔軟性の面で問題がある。後者の仮想方式

はほとんどデジタル方式で実現されている。時分割処理となるので処理時間は遅くなるが、現在の計算機、LSI技術と相性が良く現実的と言える。


各々のニューロンを実現するために必要な機能を挙げると、次の5つである。

- ①シナプス荷重の乗算
- ②加算
- ③シグモイド関数の発生
- ④値の伝播
- ⑤荷重の記憶方法

アナログ型で荷重の乗算は、抵抗や容量の値を荷重に対応させ、通過する電流や電荷を入力値として乗算を実現する例が多い。また、続く加算は乗算結果を単に線を結び、ワイヤード加算する例が多い。光型では荷重を光のフィルタに、また照射光量を入力に対応させる。パルス密度型では値の表現をパルス密度で表し、シナプス荷重に応じてパルス密度を変化させるもので、アナログとデジタル方式が考えられる。アナログ方式ではパルスを歯抜けにするレートマルチプライヤを乗算に、またコンデンサで累積を行なう。一方デジタル方式ではカウンタを加算に用いる。

シグモイド関数の発生はアナログ型ではMOSトランジスタの飽和特性を単に利用したものから、オペアンプを組み合わせた高級なアナログ関数発生器などが用いられる。デジタル方式では予めメモリに計算結果を入れておき、テーブルを参照するテーブル駆動方式と、毎回数値計算を行なうものがある。光方式では一旦電気信号に変換してからアナログ／デジタル処理で求めることが多い。

シナプス荷重の記憶方式では、図表3.3-4に示すようにアナログ値をそのまま記憶するアナログ型のものと、デジタルで記憶し、デジタル／アナログ変換してアナログ値を得る(D/A型)ものがある。アナログ型ではEPROM風にフローティングゲートの電荷量で指定するものがあり、D/A型ではDRAM風にゲートにダイナミックに蓄積された電荷量を定期的に外部からリフレッシュするものが考えられている。図表3.3-4の(D)に示したのがDRAM式にアナログ荷重を記憶し、外部のデジタルメモリからD/Aを経て定期的にリフレッシュする方式を示している。さらにアナログ型では、絶縁膜にトラップされた電荷量でCCDのポテンシャル井戸の深さを制御してアナログ荷重を実現する方式も提案されている。光型では液晶フィルタや、CRTディスプレイで光量を制御するものが開発されている。



図表3. 3-4 シナプス荷重の記憶／設定方式

3. 3. 1. 4 システム例

人工神経回路網の処理を指向し、今までに開発／製品化されたマシンの事例をネットワーク構造とハードウェアの実現レベルによって整理すると図表3. 3- 5の通りである。表からもわかる通り、シミュレータのレベルでは汎用性をめざし各種のネットワークモデルが扱えるのに対し、LSI チップ／光のレベルではハードウェアを専用化している分、対象の

のネットワークモデルが限定されている。

提案されたマシンの中からアーキテクチャの特徴的ないくつかのシステムについて以下に紹介する。

図表3.3-5 Neuro-Chips/Neuro-Hardware


	Associative Memory	Layered Structure	Pre-Wiring	Organ
Simulators/ Emulators	←-----	ANZA Plus, SAIC/Delta NEURO-07, Mark III, GCN Odyssey, Warp, CM-2,	-----> NeuM NEP, Sandy/8	
Neuro-Chips	AT&T, CalTech, JPL, MIT, Digital Neuro Chip (Hirai), WSI Chip (Hitachi)	UCLA, JPL, ANP		CalTech
Opto-Electric	CalTech, Opto-Electric Chip (Mitsubishi)	AT&T VSTEP	RUBICON	

(1) アナログ実ニューロン方式

神経回路モデルを直接アナログLSIなどで実現したもので1ニューロンモデルに1回路ブロックが対応する。ホップフィールドらはディスクリート回路で実現、AT&T、CalTech、JPL、MIT、UCLAなどは連想メモリ型を（一部）LSIで実現した。（Mead/CalTech）らは網膜モデルをLSIで実現している。ANP/富士通、UCLAは層構造型を指向したチップを開発している。


AT&Tのベル研ではアナログ回路により連想記憶型のLSIの開発に積極的であり、今までに、いくつかのチップが実際に開発されている。図表3.3-6は連想メモリの構成例を示している。54個のニューロン素子を含み、素子間の任意の抵抗（トランジスタ）接続がプログラム可能な54×54の接続マトリックス、接続を制御する54×54各2ビットのRAMセル及び外部インタフェースで構成されている。アナログ部分は接続マトリックスの抵抗アレイの加算部分だけでアンプユニットで閾値処理により2値化され、興奮性と抑圧性の2つの信号が接続マトリックスに返される。各RAMセルの2ビットによりその信号が選択される。動作としては、参照したい54ビットまでのベクトルがデータ入力よりバッファに入り、次にその値がアンプユニットに初期値としてセットされ連想動作が開始される。

記憶されていたベクトルのいずれかに回路が落ち着くと、バッファを介して外部に読みだされる。実験例では、10個の安定状態（40ビット長）をセットしておき回路が安定するまでに50から600 n 秒を要したと言う。



図表3.3-6 連想メモリチップ (AT&T)

富士通の ANPは層構造型のネットワークを指向したアナログ型のチップであり、1チップに1ノードを実現している。図表3.3-7に示すとおり、入力信号を基準電圧とし重みをデジタル値として与えるDA型アナログ乗算器、出力を累積する積分器、シグモイド関数を発生するオペアンプ型関数発生器で構成される。入出力はアナログ値で授受し、同時に重みデータを外部のメモリから読みだしシリアルに供給する。多数のニューロン素子を実現するために入出力はアナログ式のバスでチップ間を接続し各々のアナログ値を時分割式（13μ秒ごと）にブロードキャストする。ニューロン数を増した時アナログバスの特性変化、時分割転送が問題となりうる。



図表3.3-7 アナログニューロチップ (ANP)の構成 (富士通)


(2) 光・電気実ニューロ方式

計算素子として光技術を用いて2次元平面処理と光演算の高速性をいかした光連想メモリの研究が行われている。また神経回路網が大規模になると配線の問題が深刻となるので、物理配線の不要な光伝播による通信が期待されている。光・電気回路による連想メモリ型やプロダクションシステムの開発例がある。三菱は発光アレイ／光マスク／受光アレイの3層構造を持つLSIを開発している。AT&Tでは光で重みを変化させる光プログラム式のデバイスを用いて連想型及び層構造型のシステムを開発している。

ペンシルヴェニア大学のFarhatらは図表3.3-8に示すとおり、1次元の発光素子アレイをニューロン群の出力とし、直行する1次元の受光素子アレイをニューロン群の入力とする自己連想型あるいは階層型のネットワークを実現する。発光素子と受光素子の間に2次元の光マスクと方向性発散レンズと集光レンズを配置し、任意のニューロン間の重みをプログラムする。光の発光／マスク／受光素子を3次元的に正しく配置する必要があるので機械的な精度の確保が難しい点とニューロンが1次元に配置されるので大容量化の点で課題が多い。

上記の例では光が1次元配列をとるのでニューロン数がそれほど多くない。そこで、Psaltisらは、発光・受光素子を2次元状に配列し光による2次元処理をめざし、重みマスク部分を3次元の体積（ボリューム）ホログラムを用いた実験を行っている。さらに、Psaltisらは光・電気系による自己連想メモリ型の実験も行っている。2次元の不完全な

画像から、記憶されている画像を連想するもので、半欠け画像や回転画像から正しい画像を連想することができる。




図表3.3-8 空間伝播型光・電気ニューラルネットワーク（ペンシルヴェニア大学）

連想記憶型では重みマトリックスのプログラム可能性が重要である。従来の例では、マスクプログラム方式でチップ製作時にのみプログラム可能であったり、重みの指定が粗くなってしまうものが多い。それに対しKornfeldらはアモルファスシリコン光センサアレイを接続重みマトリックスとして用い 120ニューロン分のマトリックスを1チップに実現している。光マスクを介してチップに光を照射し重みをプログラムするので重み設定のための配線、外部ピン、重み用 RAM等が不要となる特徴がある。それでも光マスクは固定されてしまうので使い難かったが、最近では発光源として CRTを用いることにより動的にプログラム可能なシステムが作られている。図表3.3-9は層構造型ネットワークの実現例を示している。


三菱の久間らは図表3.3-10に示すとおり、GaAs基板上に発光素子アレイ、光学マスク、受光アレイの3層のサンドウィッチ構造の光ニューロチップを開発している。32ニューロンの連想型・層構造型が実現できる。先のFarhatらの例のような機械的位置合わせが不要で小型となる特徴があるが、光のマスクが製造時に固定されることが制約と言える。

Meadらは今までの神経回路モデルとは異なり、網膜の視覚系の細胞をモデル化し L S I 化を行っている。空間的あるいは時間的な変化に応答する視覚系を図表3.3-11に示すと


りフォトトランジスタ、蜂の巣状抵抗網およびオペアンプで実現している。フォトトランジスタから入力した光は近傍の光のレベルと比較され物体のエッジ部分などの空間的な変化による差を検出する。また、入力部分の容量により時間的な変化も検出する。



図表3. 3-9 光プログラム層構造型ネットワーク



図表3. 3-10 密着型光連想メモリチップ (三菱電機)




図表3.3-11 視覚系のシリコン化 (CalTech)


(3) デジタル実ニューロン方式

筑波大・日立の平井らは図表3.3-12に示すとおり活性度をパルス密度として、重み付けをパルス間の積で、また累算をアップダウンカウンタで実現し6ニューロンを収容するデジタル連想型チップを開発している。各々のニューロンは6入力（及び外部入力1）の各々に興奮性／抑圧性入力を持つ。入力したパルス列は加重レジスタで指定された積レートマルチプライヤによって歯抜けにされ、出力はデジタル的にワイヤードORされる。完全なパルス列の加算でないでパルスの衝突でカウントミスを起こすが、ここではその点を逆手にとって出力関数の飽和特性を実現している。本チップはデジタル式であるので拡張出力を介し複数チップのワイヤードORが容易であり、1,000ニューロン程度まで拡張可能としている。

安永（日立）らはWSI技術を用いて540ニューロンを1ウエハーに実現した。図表3.3-13に示すとおり、9個のニューロンで1つのブロックを構成し、全体で60ブロックを実装する。中央を縦方向に1組のメインバスが走り、さらに横方向にニューロンブロックを結合する複数のグローバルバスが走る。各ニューロンの出力状態値は同報通信によりグローバル／メインバスを介し全ニューロンに伝えられる。各ニューロンは重みの重い順に64シナプス分記憶し所定の状態を取り込む。チップは冗長設計を考慮しWSIの欠陥にも対応可能としている。




図表3.3-12 デジタル連想メモリチップ (筑波大学 平井ら)



図表3.3-13 WS1ニューラルネットワークの構成 (日立)

(4) デジタル仮想ニューロン方式

デジタル技術で実ニューロンを実現すると、どうしてもハードウェア量が多くなりすぎる傾向があるので現在のLSI技術では多数のニューロ素子を1つのプロセッサが分担する仮想方式が現実的である。ニューロ処理に含まれる頻出処理を専用のハードウェアを用いて高速化、さらに並列処理を併用することができる。Odyssey(TI), NEP(IBM), Sandy/8(富士通)はDSPを用いて積和演算を専用化している。Delta(SAIC), ANZA Plus(HNC), NeuMan(日電)、は浮動小数点演算プロセッサを用いて積和演算その他の処理をマイクロプログラム制御により高速化している。データフローイメージプロセッサ(NEURO-07)、シストリックアレイなどの利用例もある。最近は高性能マイクロプロセッサや高並列型の汎用並列プロセッサが利用可能となっており、コネクションマシン、DAP, AAP2などはSIMD処理で、またNCUBE, Butterfly(BBN), GCN(ソニー)、TLA(シャープ)や、Computing SurfaceなどはMIMD式に並列処理でシミュレーションの高速化を実現している。



図表3.3-14 NeuManの構成（日電）

日電のNeuManは各々のプロセッサエレメントに2つの浮動小数点演算プロセッサを用い、マイクロプログラム制御によりパイプライン処理を行う。図表3.3-14のとおりNeuManは複数のプロセッサエレメントが接続ネットワークで結合され、パケットの形で出力状態値が転

送される。各々のプロセッサは到着した出力状態値を加算する累算フェーズと出力状態値に接続先の重みを掛け算しパケットとして送出する投票フェーズの2つを別のマイクロエンジンと興いて並列にパイプライン処理する。1台のプロセッサで64Kノード、440Kリンクを収容し、1Mリンク/秒の処理速度を得る。同じく日電のNeuro-07はイメージ処理用データフローチップ(Impp)を4個リング状に結合しパイプライン処理によりバックプロパゲーションアルゴリズムに頻出する積和演算などを高速化している。専用ボードをパソコンのスロットに挿入するだけでパソコンでスーパーミニクラスの速度性能が得られる。Sandy/8はDSPを256台までリング状に接続し積和演算をシストリック式に行い、500MCUPS (Million Connection Updates) (一秒間の結合の更新数)を実現する。GCN-128は128台のマイクロプロセッサ(80860)2次元状に配列し、縦および横方向の近接プロセッサ間をFIFOで結合した構成をとり1GCPS(Giga Connection Per Second)をめざしている。

3.3.1.5 ニューラルネットワークのためのソフトウェア

ニューラルネットワークのアプローチは、自動的に生のデータから非シンボリックな学習により知識を獲得し、システムの性能がインクリメンタルに改善される特徴がある。しかし、ネットワークの構造が静的で、時系列データ、意味ネットワーク、フレーム、論理構造データなどの構造データの表現力に乏しいと言う問題点がある。従って、ニューラルネットワークを用いて実用的な知識処理システムを実現する場合、問題領域のモデル化、知識・概念をいかにネットワークで表現するかが重要となる。そのためには、これまで述べたハードウェア的側面だけでなくネットワークの記述言語、開発環境などソフトウェア的な側面を含めたシステムのアプローチが必要となる。

実用的なシステムでは適切な表現形式の選択がポイントとなる。ネットワークが白紙の状態から訓練だけで学習させるのは、膨大な時間がかかり、収束する保証もない。一般的には、問題をうまくニューラルネットワークの内部表現に表せないとシステムが正しく動作しないことが多い。明示的な知識はネットワークの構造にコード化し、初めから作り込んでおくほうが得策である。人手によりネットワークを構築するという意味では、ニューラルネットワークにおいても何らかのプログラミングが必要となる。正しく構造化(モデル化)できれば膨大な時間を用する訓練によらず、複雑な構造が実現可能となる。現在の技術では、問題の構造化、抽象化の段階は人手により実現し、学習はシステムの微調整の段階で極力低いレベルで行う方が現実的である。

ニューラルネットワークを情報処理に適用するアプローチとして次の3つが考えられる。

(1) 単一構造ネットワーク型

システムの入力から出力までを一種のブラックボックスと見立て、繰り返し訓練パターンを提示し知識を獲得・学習させるものである。問題の定式化が困難、データ相互の因果関係も不明で、しかも入力データが不確実でノイズを含み相互に矛盾する様な問題に向いている。ネットワークとしては3層のバックプロパゲーション型が用いられることが多い。学習が機械的に実現され、汎用性もあるので適用例が多い。知識が系全体にかかわる重みの集合として分散表現されるので、獲得した知識を外部にルールなどの形で取り出すことが困難であり、結論を導出する過程を説明できない。

(2) 構造化ネットワーク型

明示的な知識はネットワークの構造にコード化する立場からネットワークを構成するものである。ニューラルネットワーク本来の特徴である適合性、自己組織性に加え、従来のAIが持つ強力な推論、知識表現能力が融合される。大規模なネットワークが比較的容易に実現できるので実用的であり学習時間も短縮されるが、従来のエキスパートシステムと同様に知識獲得の工数がかかる。ネットワークの構成に当たっては、いくつかの簡単な単一構造型の部分ネットワークを組み合わせ実現しても良いし、あるいは、意味ネットワークやフレーム表現、ルール表現をそのままネットワークの構造に展開しても良い。機械的な学習方式が考えにくい問題点がある。

(3) 記号処理との併用型

ニューラルネットワークを従来型の記号処理・数値処理システムと結合したハイブリッド型は互いの特徴を生かした構成が可能となる。ちょうど人が卓上計算機を計算の道具として利用しながら意思決定を行う方式と似て、パターン認識や連想・学習はニューラルネットワークが担当し、論理立てた推論やアルゴリズム的处理は従来型計算機が分担する方式が考えられる。記号への変換／逆変換の方式・インタフェースが問題となる。

ニューラルネットワークの学習は訓練パターンを繰り返し与え学習させる点では帰納的であるが、従来の記号処理的学習とのちがいは、ニューラルネットワークの学習は非シymbol的な学習であり、学習結果はルール形式の中間表現を出すのではなく、ネットワーク

の重みの調整結果として得られる点異なる。ドメインのモデルを仮定せず、直接生のデータを入力とし学習できる特徴がある。しかし、ニューラルネットワークでの学習では、いかに知識が順次的に獲得されるかの機構は実現されるが、何を学習したかを説明したり記述することが困難である。3層構造のバックプロパゲーション型のモデルで学習済みのネットワークから特徴やルールを抽出する試みが行われているが、知識が分散表現されるので、その解析は難しい。

3.3.1.6 今後の研究課題

ニューラルネットワークの研究は、以上見てきたとおり、試行錯誤的な研究開発体制の段階にあると言える。そのような研究開発を推進するためには柔軟で使いやすく、高速なシステムが不可欠である。そのためには、高速な専用ハードウェアとともにニューロ処理に向けたソフトウェアシステムとの連携が重要となる。最後に、ソフトウェアの課題を以下にまとめた。

- ① ネットワークモデル定義、実行環境
- ② 資源管理、制御ソフトウェア
- ③ 開発環境、ネットワーク入力システム
- ④ 並列性の指定、開拓
- ⑤ ネットワーク記述言語
- ⑥ 問題のマッピング（入出力の表現形式、正規化、データ変換法）
- ⑦ ネットワークインタプリタ／コンパイラ
- ⑧ 記号処理系との結合

〔参考文献〕

- [1] Hopfield, J.J. and Tank, D.W. : "Computing with Neural Circuits : A Model", SCIENCE, 8 AUGUST, Vol.233, pp.625-633(1986).
- [2] Tank, D.W. and Hopfield, J.J. : "Concentrating Information in Time : Analog Neural Networks with Application to Speech Recognition", ICNN, pp.IV-455-468 (1987).
- [3] Graf, H.P., et al : "VLSI implementation of a neural network memory with several hundreds of neurons", Neural Networks for Computing, AIP Conf.Proc.151,

- pp.182-187(1986).
- [4] Graf, H.P., Jackel, L.D. and Hubbard, W.E. : "VLSI Implementation of a Neural Network Model", IEEE COMPUTER, pp.41-49(March 1988).
 - [5] Sage, J.P., Thompson, K. and Withers, R.S. : "An Artificial Neural Network Integrated Circuit Based on MNOS/CCD Principles", Neural Networks for Computing, AIP Conf. Proc. 151, pp.381-385(1986).
 - [6] Mead, C.A. and Mahowald, M.A. : "A Silicon Model of Early Visual Processing", Neural Networks, Vol.1, pp.91-97(1988).
 - [7] Hecht-Nielsen, R. : "Neurocomputing Picking the Human Brain", IEEE SPECTRUM, pp.36-41(March 1988).
 - [8] Cruz, C.A., Hanson, W.A., and Tam, J.Y. : "Neural Network Emulation Hardware Design Considerations", ICNN, pp. III-427-434(1987)
 - [9] Penz, P.A., and Wiggins, R. : "Digital Signal Processor Accelerators for Neural Network Simulations", Neural Networks for Computing, AIP Conf. Proc.151, pp.345-355
 - [10] Feldman, J.A., et al : "Computing with Structured Connectionist Networks", Comm. of the ACM, Vol.31, No.2, pp.170-187(Feb.1988).
 - [11] Belloch, G.E., : "CIS: A Massively Concurrent Rule-based System", AAAI, pp.735-741, (1986).
 - [12] 梶原, 中田, 松下, 小池, ; "ニューラルネットワークシミュレーションマシン: NeuMan", 情報処理学会コンピュータアーキテクチャシンポジウム予稿集, pp.27-35 (昭和63年5月).
 - [13] 久間, 田井, 太田, 高橋, : "ニューラルネットワークモデルによる光連想メモリ", 情報処理, 計算機アーキテクチャ研究会, 71-8, pp.53-60(1988).
 - [14] "鳴動するニューロチップ", 日経マイクロデバイス, pp.43-89(1988 7月).
 - [15] Körnfeld, C.D., et al. : "An Optically Programmed Neural Network", Proc. ICNN, pp. II-357-364(1988).
 - [16] 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", Proc. ICNN, pp. II-143-150(1988).

- [17] Works, G.A. : "The Creation of Delta : A New Concept in ANS Processing", Proc. ICNN, pp. II-159-164(1988).
- [18] 小池, 梶原 : "専用ハードウェアによるニューロ・コンピューティング, 情報処理学会誌, Vol. 29, No. 9 (1988).
- [19] Farhat, N.H., and Shae, Z.Y. : "Bimodal Stochastic Optical Learnig Machine", Proc. ICNN, pp. II-365-372(1988).
- [20] 久間 : "光ニューロシステム", bit, Vol. 21, No. 11, pp. 1502-1519 (1989).
- [21] 秋山 : "ニューロチップ", bit, Vol. 21, No. 11, pp. 1520-1536 (1989).
- [22] Sugihara, T., et al : "An Analog Neuron Processor and Bi-CMOS ASIC Thechnology", Proc. 2nd ASICT'89, pp. 105-108 (April 1989).
- [23] Holler, M. et al : "An Electrically Trainable Artificial Neural Network (ETANN) with 10240 "Floating Gate" Synapses", Proc. IJCNN pp. II-191-196(1989).
- [24] 平井ら : "完全ディジタルニューロチップの構成", 電子情報通信学会研究会資料, ICD88-130, pp. 89-96(1989).
- [25] Furman, B., et al : "CMOS Analog IC Implementing the Back Propagation Algorithm", Proc. INNS, pp. 381(1988).
- [26] Yasunaga, M., et al : "A Wafer Scale Integration Neural Network Utilizing Completely Digital Circuits", Proc. IJCNN, pp. II-213-217('89).
- [27] Hiraiwa, A., et al : "A Two Level Pipeline RISC Processor Array for ANN", Proc. IJCNN Winter, pp. II-137-140(1990).
- [28] Fukda, N., et al : "A Transputer Implementation of Troidal Lattice Architecture for Parallel Neurocomputing", Proc. IJCNN Winter, pp. II-43-46(1990).
- [29] Kato, H., et al : "A Parallel Neurocomputer Architecture towards Billion Connection Updates Per Second", Proc. IJCNN Winter, pp. II-47-50(1990).
- [30] Frye, R.C., et al : "An Investigation of Adaptive Learning Implemented in An Optically Controlled Neural Netork", Proc. IJCNN, pp. II-457-463(1989).
- [31] Cater, J.P. : "PFANNS: Pulse-Frequency Activated Neural Networks", Proc. INNS, pp. 540 (1988).
- [32] Morishita, T., et al : "A BiCMOS Analog Neural Network with Dynamically Updated Weights", IEEE ISSCC(1990).

3.3.2 超並列計算モデル／ソフトウェア

(1) はじめに

この項では、システムアーキテクチャ／ソフトウェアからのアプローチの一つとして、超並列計算に関する計算モデルあるいはそれに伴うソフトウェアの研究開発の現状について述べる（この項で「超並列計算」と呼ぶものは、いわゆる「ニューロネットワーク」を指すのではなく、並列度の極めて高い数値／記号計算一般を指すものであることを、あらかじめ断っておく）。

(2) モデル

超並列の計算モデルとして、これまで国内外で提案されている代表的なものには、次の4つのモデルがあり、いずれも6，7年から10数年の歴史をもつ。

- ① ACTOR モデル
- ② データフローモデル
- ③ ABCMモデル
- ④ CCS モデル

①のACTORモデルは、MITの人工知能研究所でC. Hewittを中心とし1970年代前半から研究が続けられてきたもので、数学的基礎についても、G. Agha等によって整備されてきた[1]。このモデルではアクタと呼ばれる、データと手続きを統合した自律的な計算エージェントが中心的な役割を果たす。アクタはメッセージを受理することにより活性化され、指定された仕事をする。多数のアクタが並列に活性化され、並列にメッセージをやりとりし合うことによって、計算／情報処理が進行する。

②のデータフローモデルはMITの計算機科学研究所にいたJ. Dennisによって、やはり1970年代の前半から研究が始められたものである[2]。通常の逐次計算では、演算は指定された順序で一つ一つ実行されるが、その際ある演算に必要なデータはその演算を実行するずっと以前に既に準備されている場合が多い。これと対比的に、データフローモデルに基づく計算では、計算の要素となる演算子が、「それによって演算を施されるデータ群の準備が整い次第、実行が開始される」というものである。

③のABCMモデルは、東大の米澤[3]を中心に研究されてきたもので、ACTORモデルのアクタという概念を、ソフトウェアモジュールの概念として一般化した「並列オブジェクト」と呼ばれるものを基礎とした計算モデルである。このモデルではメッセージのやりとりの

形態やモードに関して ACTORモデルに比して、より豊富な構造をもつと同時に、並列オブジェクトに明示的な「状態」概念を許している。

④のCCS モデルは、Edinburgh 大学のR.Milner [4]により、やはり1970年代の初期から始められた並列計算モデルである。モデルの基礎となるものは、エージェントと呼ばれる計算主体で、このようなエージェント群が互いに通信をしながら計算が進行する。コミュニケーションは同期的に行われる点が、ACTOR モデルやABCMモデルと著しく異なる点である。また、このモデルに付随する代数系や、エージェントの挙動の同値性の概念などが詳しく調べられている。

(3) 言語とソフトウェア

上述の計算モデルのうち①、②、③については、それぞれのモデルに基礎を置くプログラミング言語が設計され、その処理系も実働している。さらに、これらの計算モデルや言語を念頭に置いているアーキテクチャも設計・開発されつつある。以下、言語とアーキテクチャについて簡単に触れておく。

ACTOR モデルに関しては、MIT のC.Hewitt等によるAcore 言語、W.Dally 等によるConcurrent Smalltalk 言語 [5]があり、特にConcurrent SmalltalkについてはJ-Machine というアーキテクチャが設計され現在開発中である。また、ABCMモデルに関しては、東大の米澤によるABCL/1言語 [3]やCaltech のW.Athas 等によるCantor [6]などが設計されている。このモデルについては、Caltech で現在進行中のアーキテクチャプロジェクトの中心であるMOSAICマシン[7]が対応する。

さらに、データフローモデルについては、わが国では電総研の島田等が、世界最高速のデータフローマシンプロジェクトSIGMA のもとにDFC 言語を設計・開発している。

〔参考文献〕

- [1] G.Agha, Actors: A Model of Concurrent Computation in Distributed Systems, MIT Press (1986).
- [2] J.B.Dennis, First Version of a Data Flow Language, Tech. Mem No.61, Lab. for Comptr.Sci., MIT(1973).
- [3] A.Yonezawa, ABCL: An Object-Oriented Concurrent System —Theory, Language, Implementation and Application —, MIT Press(1990).

- [4] R. Milner, Communication and Concurrency , Prentice Hall(1989).
- [5] W. J. Dally and A. A. Chien, Object-Oriented Concurrent Programming in CST, SIGPLAN Notices, Vol. 24, No. 4(1989).
- [6] W. Athas, Cantor Reference Manual, Tech. Mem., Comptr. Sci. Dept., CalTech (1987).
- [7] W. Athas and C. L. Seitz, Multicomputers: Message-Passing Concurrent Computers, IEEE Computer Magazine(August 1988).

4. 今後の動向と目指すべき方向

4. 今後の動向と目指すべき方向

4.1 基礎理論とモデル

4.1.1 統合学習型情報処理

(1) 背景


第3章の「3.1.1 並列分散情報処理の基礎」において、我々は分極化した情報処理研究の現状を概観するとともに、以下のことを指摘した。

- ・情報処理技術は、本来統合的な脳の情報処理機能（知能）の工学的実現を目指すこと。
- ・現行の情報処理技術は、AIや知識工学に代表される意識上の論理的情報処理の側面を、逐次手続型情報処理パラダイムのもとに「固い」情報処理技術として展開してきたこと。
- ・一方、パターン認識やニューロコンピューティングに代表される脳の情報処理機能のもう一つの側面としての意識下の直観的情報処理の可能性を追求する新たな流れがあり、新しいパラダイムとしての並列分散情報処理の計算原理の究明と、より人間的な「柔らかな」情報処理技術への展開が望まれていること。

そして、基礎をなすパターン認識の再認識の立場から、そのような柔らかな情報処理の根底にある論理として示唆される「柔らかな論理」を示した。

情報処理技術の今後の動向を考えると、従来の逐次手続型情報処理の流れは、分散と協調といった並列化・柔軟化の方向に進むと思われる。一方、並列分散学習型情報処理としてのニューロコンピューティングの研究は、現在の単一な機能から、モジュール化・階層化を押し進め、推論機能といった逐次的な機能の実現方向へと向かうと思われる。そして両者の流れは、統合化に向けて近づいて行くであろう（図表4.1-1参照）。

本項では、これらを受けて今後の情報処理の目指すべき方向として「統合学習型情報処理」をあげ、その基本的なコンセプトと解決すべき重要な研究課題、そして基礎となる理論について考察する。



図表4.1-1 統合学習型情報処理を目指して

(2) 従来技術の問題点とニーズ

そのためにはまず、従来の逐次手続型情報処理の問題点と今後の情報処理に求められるニーズを明確にしておく必要がある。

従来型逐次情報処理方式は、与えられた課題に対して、問題をモデル化し、情報を数値／記号（＝概念）で集約的に表現し、それらの関係を決定論的な構造（方程式／論理＝知識）として記述し、解法のための逐次手順（アルゴリズム）を陽にプログラムとして与えて行う情報処理方式である。原理的には、問題が厳密にモデル化でき、情報が完全に与えられ、かつアルゴリズムが存在し（well-defined）、また計算時間を無視すれば、チューリングの言うようにコンピュータは計算可能で万能であり、答えはいつも正しいであろう。

しかし、情報処理の応用範囲を拡大し取り扱う情報の質と量、そして「情報処理」そのものの意味を広げて「本来、広く人間の行う情報処理の機械化」と考えるならば、「固い論理」に基づく上記の従来パラダイムの限界は明かである。限られた状況（閉じた世界）での特殊な情報処理方式であり、一見無駄がなく効率的だが、余裕がなく柔軟性に欠ける。そのような逐次処理方式が実際に効率を含めて有効な範囲は意外と狭いことがわかる。従来方式の単なる延長（並列化・分散化）と計算パワーの増大では解決困難な情報処理の多くの問題、従って今後の新情報処理の扱うべき問題領域は、

- ・問題や情報自身が曖昧性や不完全性を含む
- ・アルゴリズム（解法）がよく分からない、従って定式化（プログラム化）出来ない
- ・たとえ出来ても、逐次方式では膨大な時間が掛かる（組合せの爆発）
- ・厳密な最適解でなく近似解でよいから高速（実時間）に得たい
- ・条件や状況が時間とともに変化し、自律的な適応性が必要
- ・不測の事態に対しても、ダウンすることなくそれなりに対処できること

といった性格のものであり、ill-defined な極めて多くの問題領域を含んでいる。

従来方式がこれらに対して抱える基本的な問題点は、次の3点に要約されよう（〔 〕内には、対応して認識すべき情報の性質を示す）。

- 1) 曖昧あるいは不完全な情報の表現（および処理）の欠如〔情報の部分性・不完全性〕
- 2) 多数の要因が相互に複雑・ダイナミックに絡み合った問題の（記述および）処理原理の欠如〔情報の相互関連性・並列性〕
- 3) 適応性や汎化性の欠如〔情報の変容性・変動性〕

そして、これらはさまざまなレベルでの評価と近似の概念の欠如に起因している。

(3) 統合学習型情報処理に求められるもの

前記の従来型逐次情報処理方式の抱える問題点に対処し、情報処理技術の枠を広げてより豊かな展開を図るためには、そうした情報の部分性・不完全性、相互関連性・並列性、そして変容性・変動性の認識にたつて情報の記述の枠組と処理原理を拡大し、曖昧性・不完全性を許容する頑健（ロバスト）な並列分散・学習型の新しい柔軟な情報処理方式へとパラダイムをシフトさせる必要がある。このような新しい情報処理を、ここでは「統合学習型情報処理」と呼ぶことにする。これは、3.1.1 項の情報処理の側面Bに対応して、並列分散情報処理の新しい可能性の追求と実践（原理・道具・応用）の立場から、人間に近い柔軟な知性を持った新しい統合的な情報処理技術を展開することと位置づけることができよう。

統合学習型情報処理方式を特徴づける大きな2つキーコンセプトは、「柔らかな情報処理」、そして「超並列超分散情報処理」である。

「柔らかな情報処理」とは、情報の部分性・不完全性そして変容性・変動性に対処して、情報の曖昧さ・不確かさ・不完全さを許容する記述と評価・近似の枠組において、多種多様な情報を総合的かつ柔軟に処理し、またその枠組の上に学習機能を持つといった、人間

に近い柔軟性と適応性を持った情報処理をいう。これは情報処理の応用機能的側面を表す軸での従来の固い方式の拡張方向である。

「超並列超分散情報処理」とは、情報の相互関連性・並列性に対処して、上記の多種多様な多数の情報を、従来方式のように個別逐次的に処理するのではなく、超並列超分散的に統合的に処理することをいう。超並列超分散という用語は、従来方式の延長（処理速度の向上）としての並列分散方式を越え、単に規模のみではなく、新しい計算原理としてのパラダイムの変化を含む。これは情報処理の計算方式的側面を表す軸での拡張方向である。

統合学習型情報処理を新しい情報処理技術体系として大きく育てるためには、記述の枠組と処理原理を究明し新技術の理論的な基盤の確立を目指すとともに、超並列超分散処理のための計算基盤を開発・整備して、その上に新技術の基本要素となる新機能を実現し、広く実应用的応用の展開を図ることが重要である。新機能としては、多形態情報の統合機能（パターン情報と記号情報の統合も含む）、曖昧情報の処理機能（不完全情報処理機能、意味情報処理機能も含めて）、そしてそれらを基礎に認識理解機能（高次、能動的）、問題解決推論機能（予測、柔らかな推論、連想、類推機能）、自律協調制御機能（柔らかな制御）、さらにそれらを処理対象とするメタな機能としての学習・自己組織化機能（適応化、分業化、階層化を含む）が考えられる。

(4) 研究課題と基礎理論

このような統合学習型情報処理の実現にあたっては、まず情報処理の基礎となる表現と評価について「柔らかな枠組」を構築することが重要な研究課題となる。

- ・記号情報とパターン情報を含む多形態情報の統合のための柔らかな表現の枠組

（例えば、分散的表現、空間的・位相的な枠組）

- ・柔らかな評価の理論的枠組（近似の良さ、価値や感性も含む）

次に、このような枠組みにおいて種々の処理機能を柔軟かつ統合的に実現するための基本原理と基礎モデルの研究が主要な課題となる。

- ・多形態情報の統合と情報抽出（要約）（認識、総合判断、理解）
- ・最適化や最適解探索
- ・制約充足や正則化による ill-posed 問題（不完全問題、逆問題）の処理（解法）
- ・協調と競合
- ・知識とデータの柔らかな統合による柔らかな推論・連想・類推

- ・ implicitな意識下の直観的处理とexplicitな意識上の論理的处理との統合
- ・ 手続的知識と宣言的知識の総合

更に、これらの処理機能を処理の対象とするメタな処理機能としての適応・学習・自己組織化の研究が重要な課題となる。

- ・ 柔らかな論理に基づく帰納推論としての学習法
- ・ 柔らかな知識の形成法
- ・ 機能のモジュール化・構造化・階層化、およびその自己組織化
- ・ 情報処理の階層化による学習・自己組織化の階層化

これらの機能を総合した応用指向（システム化）の研究課題としては、次のものが考えられる。

- ・ 各種高度パターン認識（画像、文字、音声、言語、およびそれらの統合）
- ・ 統合学習型制御（multi-sensor fusion, 自動制御、ロボットの自律協調制御）
- ・ 超並列超分散システム（電力、交通、経済システム等）の最適化
- ・ 曖昧情報の処理と利用（自然言語理解、マンマシンインタフェース）
- ・ 柔軟な情報（知識）ベースと問題解決（判断・決定支援システム等）

これらの研究課題の基礎となる理論としては、

- ・ パターン認識の理論（識別の理論、類別の理論、学習の理論、特徴抽出理論（不変特徴抽出理論＋判別特徴抽出理論））
- ・ 多変量解析・数量化の理論（統一的非線形理論も含めて）
- ・ ニューロコンピューティングの理論・モデル
- ・ これらの基礎となる「柔らかな論理」（帰納的確率論理、柔軟な推論方式）と、これに基づく柔らかな情報処理の理論
- ・ 計算機科学的理論・モデル（並列計算アルゴリズム等）
- ・ 人間の情報処理、記憶・学習・自己組織化のモデル化（神経生理学的知見）

が考えられ、またこれらの更なる展開が必要である。

4.1.2 学 習

(1) 学習能力を持つ機械

「機械と生物の相違はなにか」という素朴な古くなった問いをもう一度考えてみると、機械のステレオタイプに対する生物の柔軟性をまず挙げることができよう。生物の柔軟性

は環境との相互作用を通じて自己組織化して行く適応能力によっている。これは、従来の機械の進歩がたどってきた強力化、高速化、精密化とは異なった方向である。これまでの機械の能力の限界がかすかに見え、また人間との多様な相互作用の必要性が明らかになってきた今日、機械に学習能力・自己組織化能力を付与するための基礎的理論構想を作り、それを通じて生物のもつこれらの能力の解明に何等かの寄与をなすことを目指すことは有意義であると思われる。

(2) 神経回路網モデルによる学習

学習を一般に考えるとき、神経回路網状の媒体に限る必然性はないが、誤差逆伝搬法やボルツマンマシン以来この方向にいくらかの可能性が提案され、また脳は実際にこの能力を持った実在であるので当面これに注目してよいであろう。

- ① 層状神経回路網： ある能力をもった神経回路網の存在を論ずる「学習可能性」の問題を汎化能力と回路の複雑さとの関係において捉える試みがなされており[1]、今後の理論の方向がある程度示されていると思われる。一方、ある初期状態から出発して学習によって目的の回路網に到達できるかどうか（「学習収束性」）や学習速度の問題は多自由度の非線形力学系と同様に一般的なアプローチは難しそうと思われる。
- ② フィードバック結合をもつリカレント神経回路網： 時系列を学習する能力をもつ[2]が、学習方式（誤差逆伝搬法に相当する）が定式化された段階であり、学習可能性や学習収束性に関してはこれからの展開が期待されるものである。
- ③ 連想記憶型神経回路網： 脳における多重・分散記憶のモデルとして最も有望なものと思われる。記憶容量が重要な特性であり、記憶過程とともに想起過程が重要な要因であることが最近示された[3]。また、最近の生理学実験結果との対応を調べることによって情報の脳内表現（コーディング）や神経回路の機能単位の特性に対する示唆も得られそうである。
- ④ 概念形成の神経回路網： いわゆるコネクショニストの神経回路網において「外界の関係（法則）」を表現する細胞が形成されるという概念形成のプロトタイプが示されているが、物理現象の相転移に象徴されるような、不連続な質的な変化をともなった概念形成を可能にするようなモデルの構成が望まれる。

(3) 生物研究との関係

最近の記憶に関する研究の進歩は目ざましく、記憶の分子生物学的メカニズムから生体の高次の記憶までが次第に関係付けられようとしている[4]。その結果によれば、種々のレベルの機能が相互作用を持っており、工学でしばしば用いられる計算理論、アルゴリズム、インプリメンテーションを分離して取り扱うことは妥当ではないように思われる。もっと生物研究に沿った研究手法を工学にも取り入れる必要があるだろう。

(4) 学習の研究における超並列・超分散情報処理の効用

これまで神経回路網を用いた学習の研究では種々のモデルが提案されたが、それらのモデルの能力がほんの小規模なプロトタイプによって示されたに過ぎず、スケールアップに耐えるものかどうかは明確にされたものはない。脳のカリカチュアでなく脳のモデルをまともに研究するためには pseudo-real実験が行える程度の規模・能力をもつツールとして超並列・超分散情報処理システムの開発が望まれる。

〔参考文献〕

- [1] 上坂：ニューラルネットと学習可能性、電子情報通信学会技術研究報告CAS89-103, pp. 69-74, (1989).
- [2] K. Doya and S. Yoshizawa: Adaptive Neural Oscillator Using Continuous-Time Back-Propagation Learning, Neural Networks, Vol. 2, pp. 375-385, (1989).
- [3] 森田、吉澤、中野：自己相関連想記憶の想起過程とその改良、電子情報通信学会論文誌, Vol. J73-D-II, No. 2(1990).
- [4] 例えば、Neural Models of Plasticity, ed. J. H. Byrne and W. O. Berry, Academic Press, San Diego(1989).

4.1.3 超並列最適解探索

4.1.3.1 決定論的最小値探索機械

巡回セールスマン問題など多くの組合せ的最適化問題は枚挙によるトリビアルな解法を持つが、問題のサイズが大きくなるとその計算の手間が爆発的に増加してしまうという意味で、現実的にはわれわれの手の届かないところにある難問である。ところが1980年代にニューラルネットによるこの種の問題のきわめて効率的な解法（決定論的最小値探索機械）

が提案され[1]、多くの関心を呼んでいる。

組合せ的最適化問題の多くは±1の2値をとる多変数の関数Fの最小値問題として定式化できる。このFを最適化問題の“目的関数”という。しかもこの関数Fはべき乗を含まない多項式、つまり、多重一次形式として常に書ける。そこでFをこの形に書き、その変数が実数値をとると考えた関数Eを用意し、これを与えられた最適化問題の“エネルギー関数”と呼ぶ。このとき上述の最小値探索機械は本質的には、エネルギー関数Eから導かれる次のような力学系と同値である：

$$\frac{dx_i}{dt} = -(1-x_i^2) \frac{\partial E}{\partial x_i}, \quad i=1, \dots, n$$

この連立の微分方程式系の形から分かるように、探索機械のからくりは変形された最急降下法だといってよい（通常の最急降下法にはEの偏導関数の前の因子が存在しない）。

この力学系については詳しく調べられており[2]、超立方体 $C = [-1, +1]^n$ の内部から出発すると、力学系の状態はCの頂点に漸近し、そこでは目的関数F（エネルギー関数Eではない）が極小になっている。したがって適当な初期状態から出発して上の力学系をシミュレートすれば、Fの最小値が求まり、多くの組合せ的最適化問題が解けるというわけである。

特に目的関数が2次の多項式で書ける場合には相互結合型のニューラルネットで上の力学系を実現できる。しかも組合せ的最適化問題の多くは2次でこと足りる。

というわけで、いままで手の届かなかった莫大な計算量を要する最適化問題がわれわれの現実的な射程内に入ってきたといえる。この方法で特に重要なのは上の力学系の計算が並列的に実行できる点である。このため、シミュレーション用のハードウェアが並列計算をサポートしておれば、解を求めるのに要する時間は問題のサイズによらず、常に一定だという驚くべき利点を持つことになる。したがって超並列計算可能なデバイスがあれば、これまで天文学的な計算時間を要した問題もほとんど一瞬のうちに解くことも夢ではないといえる。

しかし、この夢の探索機械にも現在のところ致命的な難点を抱えている。これについては4.1.3.3で触れることにする。

4.1.3.2 確率論的最小値探索機械

組合せ的最適化問題には可能な解を片っ端から試していく枚挙法がトリビアルな解法としてあることを前に述べた。問題のサイズが大きくなると可能な解の数が爆発的に増えることがこの解法を非現時的なものにしている。

そこでしらみつぶしは諦めるとして、可能な解をランダムに発生して最小解にぶつかるのを待つことにしてみる。いわゆるモンテカルロ法である。この場合最小解が得られる確率は理論的には1ではあるが、そこに到達するまでに要する時間は問題のサイズが大きくなるにつれて天文学的に爆発するであろう。

この難点を解消する一つの手段はそれまでに試した解の性質をつぎに試すべき解の候補を選ぶのに活用することである。1980年代に入って、この考えにしたがって考案された探索手法が“シミュレーティッドアニーリング”である[3]、[4]。

アニーリングとは高温に熱せられた物質をじょじょに冷却していくとエネルギー準位の低い結晶が得られるプロセスを指す。このとき最適化問題の目的関数をエネルギーにあてはめ、この物理現象をシミュレートすることによって最小値を得ようとするのが確率的最小値探索機械の原理である。

探索のアルゴリズムには重要な2つのステップがある。その一つはつぎに試すべき解の候補を選定することであり、他の一つは選定された候補をほんとうに受理するかどうかを決めることである。いずれも確率的に処理されるので、アルゴリズムの流れは解から解へと渡り歩く確率的过程を生み出し、したがって数学的には、有限マルコフ連鎖と等価である。

候補の受理決定は現在の解よりも候補の解における目的関数の値が小さいならば、確率1でそれを採用し、そうでなければ現在の解をある確率で保持する形で行われる。この方式は Metropolis 法と呼ばれる[5]。

一方、確率的な入出力関係をもつニューロンモデルで作られる相互結合型のニューラルネットによってもアニーリングを模擬することができる[6]。この場合は、Metropolis法とは異なった受理決定方式を用いることになり、また目的関数も2次に限定される。

シミュレーティッドアニーリングは必ずしも並列的性格をもったアルゴリズムではないが、同種の探索機械を多数並列運転することによって最小値に到達するまでの時間を飛躍的に短縮できる。この意味で、格段に効率のよい超並列的探索機械を作り得る可能性がある。

4.1.3.3 今後の研究課題

(1) 決定論的最小値探索機械は、既に述べたように、力学系のシミュレーションによってその漸近安定点を求めようとするものである。そして漸近安定点は一般に目的関数の極小点になっている。したがって、力学系の初期状態を適切に設定しなければ、最小値ではなく極小値で甘んじなければならない。このことから、最小値を与えてくれる初期値をどのようにして見いだすかということが、原理的な意味で、最も重要な課題であることがわかる。実際、初期値を粗雑に設定すると、例えば巡回セールスマン問題の場合、最小値が得られることはほとんど絶望的であることが報告されている[7]。

しかし、正しい初期値を求めることは、数学的には、非線形力学系の安定点の“たらい”を求めるという、ほとんど現実的には解くことのできない問題と実は等価である。したがって、初期値設定問題の一般解を追求するのではなくて、目的関数がある族に限定したりあるいはある同種の問題に限定してこれを研究することが現実的であろう。実際、ある種の最適化問題に対しては必ず最小値が得られるような初期値の設定方法がすでに見いだされている[8]。

(2) 確率論的最小値探索機械は、既に述べたように数学的には、有限マルコフ連鎖と等価である。特にアニーリングの過程で温度パラメータを下げていく場合は（時間的に）一様でない有限マルコフ連鎖になる。そして温度をあるスケジュールに従って適切に下げっていくと、確率1で目的関数の最小値が得られることがわかっている[9]。この場合は初期状態はまったく気にする必要はなく任意でよい。

しかし、現在までに知られている温度制御のスケジュールでは最小値に到達するまでに要する時間があまり短くないことが実験的に確認されている。したがってより速く最小値が得られるスケジュールが求めることが重要な課題となる。この場合もマルコフ連鎖の非一様性の故に一般論は難しい。個別の最適化問題や目的関数のある族に適用できる特殊な温度制御を研究することが現実的であろう。

〔参考文献〕

- [1] Hopfield, J. J. and Tank, D. W. : "Neural" Computation of Decisions in Optimization Problems, Biological Cybernetics, 52, 141-152 (1985).
- [2] 上坂 : 2 値変数の実数値関数から導かれるエネルギーを持つニューロン回路網の安定性について, 電子通信学会技術研究報告, PRU88-6 (1988).

- [3] Kirkpatrick, S., Gelatt, C. D., and Vecchi, M. P. : Optimization by Simulated Annealing, Science, 220, 4598, 671-680 (1983).
- [4] van Laarhoven, P. J. M. and Aarts, E. H. L. : Simulated Annealing, Theory and Applications, D. Reidel Publishing Company, 186pp. (1987).
- [5] Metropolis, N., Rosenbluth, A. W., Rosenbluth, M. N., Teller, A. H., and Teller, E. : Equation of State Calculations by Fast Computing Machines, The Journal of Chemical Physics, 21, 6, 1087-1092 (1953).
- [6] Ackley, D. H., Hinton, G. E., and Sejnowski, T. J. : A Learning Algorithm for Boltzmann Machines, Cognitive Science, 9, 147-169 (1985).
- [7] Wilson, G. V. and Pawley, G. S. : On the Stability of the Travelling Salesman Problem Algorithm of Hopfield and Tank, Biological Cybernetics, 58, 63-70 (1988).
- [8] 久長、山下、阿江 : ホップフィールド・ニューラルネットによる実数集合分割、電子情報通信学会技術報告、NC89-38, 33-38 (1989).
- [9] Mitra, D., Romeo, F., and Sangiovanni-Vincentelli, A. : Convergence and Finite-Time Behavior of Simulated Annealing, Advanced Applied Probability, 18, 747-771 (1986).

4.1.4 超並列・分散協調のモデル

(1) はじめに

本項では、3.3.2 項の「超並列計算モデル／ソフトウェア」における研究開発の現状を受けて、今後の研究開発の動向と我々の目指すべき方向についてその概略を述べる。

3.3.2 項では、ACTORモデル、データフローモデル、ABCMモデル、CCSモデルについて触れた。このうち、データフローモデルについては、4.2.1 項の「超並列アーキテクチャ」において、その発展したモデルを基礎にしたアーキテクチャについて述べられるので、ここでは触れないことにする。また、CCSモデルについては、今後このモデルの数学的理論がさらに細部にわたって展開されていくことが予想されるが、その展開が、超並列の計算・処理の現実的な問題に直接的に大きなインパクトを与えるとは考えにくいので、本項の(5)はでCCSモデルの問題点を幾つか指摘するにとどめる。そこで、以下では、ACTORモデルおよびABCMモデルを出発点にした計算・情報処理の並列モデルが現在どのような方向に向

かって発展されつつあるか、あるいは今後どのように発展させるべきかを示し、それによって我々の目指すべき方向を提案することにする。

(2) 並列オブジェクトモデル

従来のACTOR モデルやABCMモデルをここでは、一応「並列オブジェクトモデル」と呼び、ここでは、それらを更に発展させた今後目指すべき超並列・分散協調のモデルを、仮に「超並列オブジェクトモデル」と呼ぶことにする。超並列オブジェクトモデルは、従来の並列オブジェクトモデルを、次の2点から再検討するものである。

① 並列オブジェクト同志の制約条件

② 並列オブジェクト同志の相互作用

3.3.2 項でも示唆したように、並列オブジェクトモデルにおける並列オブジェクトとは、自律的な計算・情報処理能力及び記憶能力をもつ（ソフトウェア）モジュールである。並列オブジェクトは、メッセージを受け取ることによって活性化し、メッセージによって指定された仕事を実行する（並列オブジェクトが自律的であるゆえんは、それ自身で仕事を実行する計算力を備えている点と、指定された仕事の遂行に関し、それ自身がその遂行の方法を知っている点である）。並列オブジェクトという概念は対象にしている問題領域の各構成要素を計算主体として“モデル”化するために導入されたものである。このため並列オブジェクトとしてモデル化できるものには、その抽象度はそれぞれ異なるが、人間、計算機、問題解決器、サブルーチン、関数／手続、基本演算、データ構成、粒子、質点、剛体、天体、空間領域、ニューロン、など極めて多岐にわたる。

並列オブジェクトの枠組みによってモデル化される対象領域は、対象領域内の構成要素を並列オブジェクトとして、また構成要素間の相互作用を並列オブジェクト間のメッセージのやりとりそしてモデル化することになる。そこで、このモデル化能力をより自然で強力なものにするために、上述の2点から再検討が必要となる。

(3) 制約条件のモデル化

並列オブジェクトは、問題領域を構成する構成要素を個別に直接的にモデル化する上では極めて強力であるが、構成要素が互いに満たさなければならない拘束条件をモデル化するには、不十分な点が多い。そこで並列オブジェクトモデルの枠組を崩すことなく、オブジェクト間の拘束条件の充足を許す、新しいモデル化の枠組が必要となる。この枠組に基

づいて、モデル化のための記述言語、その言語による記述を実行するための適切なアーキテクチャ、及び与えられたアーキテクチャが効率よく実行されるコードを生成するコンパイラなどの研究開発が必須のものとなる。

(4) 相互作用のモデル化

並列オブジェクトの枠組では、構成要素間の相互作用は、単なるメッセージのやりとり
に限定され、メッセージによって伝達される情報も、並列オブジェクトの名前、基本データ型の値などに制限されていた。現在これらの点をより一般化し、“場”の概念に代表される、構成要素に作用する間接的、領域的な相互作用を適切にモデル化することが、前項
(3)の拘束条件のモデル化と同様大きな研究課題となっている。当然のことながら、この2つのモデル化は、互いに関連したもので分離して議論できない場合が多い。

(5) 基礎理論

3.3.2 項で触れた CCSモデルは、数学的理論としては、完成度の高いものであるが、この理論の基礎となっている根本的な仮定は、エージェントと呼ばれる計算主体間のコミュニケーション（相互作用）が同期的に行われるという点である。自然界や社会においてその構成要素間の相互作用は非同期的な場合が多い。よって超並列オブジェクトモデルの数学的理論を与えるためには、非同期通信の数学的扱いが十分なされなければならない。これに対して、現在なされている研究はわずかであり、今後の大きな研究課題となっている。

(6) 広義シミュレーション

超並列オブジェクトモデルを考える根底には、広範な問題領域を「超並列オブジェクト」の大規模な集まりとして、可能な限り自然な形でモデル化し、各「超並列オブジェクト」の持つ計算・情報処理能力によって、問題となる現象や対象の挙動を直接模擬実行、すなわちシミュレートしてしまうことが、問題の解決や分析にとって、今後最も強力な手法ではないかという発想がある。これは超LSI 技術の発展に支えられる、莫大な計算力の供給が、我々に与えた新たな思考手段でもある。

(7) おわりに

この項で述べた「超並列オブジェクトモデル」は、4.2.3 項で述べられる統合型アーキ

テクチャの基礎を与えるとともに、4.3.5 項の大規模シミュレーションなどに枠組を与えるものである。

4.2 システムアーキテクチャ


4.2.1 超並列アーキテクチャ (Billion Processor Machine)

(1) 目的、定式化

柔らかな情報処理は情報を分散的に表現し、並列分散的に実時間で処理することが要求される。このように複雑な処理の高速実行を可能にするためには、超並列で処理を行なうアーキテクチャの実現が不可欠である。またこのような処理を並列分散的に記述するための枠組みは、超並列アーキテクチャを前提としてはじめて実現の可能性が見えてくるのである。

柔らかな情報処理は意識下のパターン処理から意識上の記号処理まで種々の処理を行う。したがって超並列アーキテクチャの構造も、様々な実行スキーマが協調できる全体モデル像を描く必要がある。

柔らかな情報処理システムは、多層のスキーマ構成をもったサブスキーマ、概念スキーマ、物理スキーマの3層を中心とし、モデルとリアライゼーションへ展開する図表4.2-1のような立体構造をもつと考えられる。



図表4.2-1 システム全体図

サブスキーマとは、特定プログラマから見たシステムの論理構造を記述したものであり複数のサブスキーマが存在する。概念スキーマはシステムの概念構造の総体を記述したものである。物理スキーマは、計算を実行する本体の記述である。概念スキーマと物理スキーマは全システムで唯一のものである。

スキーマが「記述」であるのに比較して、スキーマの基盤を与えるものがモデルである。サブスキーマには、当該プログラマが基礎とする情報処理モデルが対応する。たとえば、ニューラルスキーマはニューラルモデルが、フォンノイマンスキーマはチューリングモデルが基礎となっている。また、概念スキーマのモデルとして、サブスキーマ全体を統括できるような全体的で単純な情報処理モデルが与えられることが望ましい。さらに、物理スキーマに対しては実行モデルが基礎づけを行なう。

各スキーマには、具体的な実現物が存在する。サブスキーマに対しては各プログラマのプログラム群が、概念スキーマに対しては基礎ソフトウェア群が、物理スキーマに対しては超並列計算機が対応する。

従来の計算システムは、サブスキーマの概念がなく、したがって単一の見方でしか情報処理システムを見通すことができなかった。また、概念スキーマと物理スキーマの関係を緊密に考えすぎていたために、概念スキーマの高機能で一般性の高い構築が困難な状態にあった。

柔らかな情報処理システムでは、各スキーマを柔軟でロバストなものとする。これを第一次の柔構造と呼ぶ。第一次の柔構造をもつサブスキーマとして、ニューラルスキーマや確率世界のスキーマがあげられる。概念スキーマは、システムで唯一のものであるが、第一次の柔構造をもつサブスキーマを概念として内包する必要から、それ自体も第一次の柔構造をもたねばならない。さらに、物理スキーマに関しても第一次の柔構造型をもつことが考えられる。

各スキーマ内の柔構造型のほかに、サブスキーマ間の融合化の柔構造型が保証されることが望ましい。例えば、フォンノイマンスキーマとデータフロースキーマが合体してハイブリッドスキーマが誕生する、という具合である。概念スキーマのたて方や物理スキーマとの整合性から、サブスキーマの融合は無限の組合せがあるわけではないが、本来サブスキーマは生成・死滅・融合といったリゾーム（リゾームは地下茎の意）的な動特性をもつものであって、システム自体もこの動特性に柔軟に対応できるように構築するのが望ましい。サブスキーマの動特性に対する柔軟性を第二次の柔構造と呼ぶ。

以上のように、各サブスキーマ内および概念スキーマ内で柔構造情報処理を想定すると同時にサブスキーマ間の統廃合関係や各スキーマ間の結合関係においても柔構造をもたせ、さらに、場合に応じては物理スキーマにも自律的な変更を許すような柔軟なシステムが、21世紀の超並列システムである。すなわち、21世紀の情報処理には、このような柔軟性のあるマルチビューの実現と、これを支える、それ自体柔軟な統合型の概念構造と物理構造が不可欠である。

(2) 超並列システム

超並列システムに要求される機能は以下のようなものである。

- ①仮想的に無限要素数のプロセッサを支援できること、
- ②ハードウェアが全体としてロバストであること、
- ③自律スケジューリングを含む動的な自己最適化ができること、
- ④個々の要素機能と全体機能との論理的レベルの落差をハードウェア的に吸収できること、

超並列システムの研究はトップダウン方向とボトムアップ方向が考えられる。トップダウン方向は、まず新しい超並列モデルを考えそれに合わせたモデル指向のアーキテクチャを構築する。このアプローチはモデルに忠実であることを主目的とし、必ずしも効率を目的としない。この場合のシステムの処理形態は、多数のオブジェクトが相互通信や環境との相互作用を行なう環境通信機能を駆使して分散協調的に処理を進めて行く。このような処理機能に適した方式モデルはまだ確立していないが、並列機能を内包するデータフロー方式と状態推移で処理を進めていくノイマン方式の融合形態をベースに並列オブジェクト指向モデルを取り込んだものが最も有望と考えられる。

ボトムアップ的なアプローチとしてはハードウェアの特性を生かしたシステムの構築を目的とする。基本的にはシリコンをベースにした超並列への挑戦である。まずキーデバイスとなるウェハレベルでのアーキテクチャを確立しなければならない。次にウェハを集積する技術としてウェハ間の通信手段を研究する。ウェハ内の通信は高速で、ウェハ間の通信はかなり遅いことが予想される。この問題を解決するため光技術や新デバイス技術を援用することが考えられる。通信時間と計算時間の比は並列計算機の性能を測る一つの尺度であり、この比があまり大きくなる場合はモデル上でこれらのギャップを埋める仕組みを考えなければならない。

現在のデバイス技術の信頼性を考慮すると10億個にも及ぶ超並列システムでは1時間に2プロセッサ、1年間では約17,000個ものプロセッサの故障が起こると予想される。ウェハスケールでは個々の部品を修理したり取り替えたりすることは困難なので、システムの一部が不完全であったとしても、その処理を続行できるロバスト性がなければならない。ハードウェアで多重系を構成し、システムが故障したプロセッサを自動的に排除できる柔軟な構造のアーキテクチャを実現する。

また多数のオブジェクトの配置をサポートするための仕組みをアーキテクチャの中に組み込んでいく必要がある。現在の並列処理計算機でもデータ分散はほとんど手が付けられていない問題であるが超並列処理の場合大きな研究課題となろう。

(3) 超並列アーキテクチャの今後の研究課題


以下に、今後研究すべき課題を示す。

- ・超並列スキーマモデル（サブスキーマの融合など）
- ・超並列アーキテクチャモデル（データフロー、コントロールフロー、オブジェクト指向の融合など）
- ・超並列プロセッサ（モデル指向、デバイス指向）
- ・結合網と通信方法
- ・負荷分散、データ分散
- ・実装技術
- ・信頼性


(4) アーキテクチャの実現可能性

ここでは10億（ 10^9 ）ニューロンと10億プロセッサのシステムについてデバイス、回路、実装などを仮定し、その実現可能性について検討する。ケーススタディに際し、以下の仮定をおいた。


- ① デバイス技術：1990年代後半に達成されるであろうシリコンCMOS技術（図表4.2-2 (a)～(c)参照）を想定した。図より、 10^8 トランジスタ/チップとし、チップサイズは1.5cm角とした。
- ② 回路・方式技術：ニューロンに関しては参考文献 [1]を、プロセッサに関しては、現在用いられている1チップマイクロコンピュータを参考にした。



(a)



(b)




(c)

図表4.2-2 デバイス、LSI技術の推移

- ③ 実装技術：高密度実装方式の一つである、WSI(Wafer Scale Integration)の3次元スタック実装を想定した。
- ④ 通信ネットワーク方式：ニューロンに関しては、チップ内を時分割による完全結合、チップ間及びウェハ間は格子及び階層ネットワークを想定した。また、プロセッサについてはプロセッサ間の格子結合とウェハ間の階層型ハイパーキューブネットワークを想定した。

以上の仮定より得られたハードウェア像を図表4.2-3と図表4.2-4に示す。



図表4.2-3 10億ニューロンハードウェア

図表4.2-4 10億プロセッサハードウェア

アプローチ	PEのデータ幅と論理規模				ネットワーク 構成	実装規模				
	データ幅 (ビット)	論理規模 (ktr)				チップ 当り PE数	ウェハ当り PE数 ($\times 10^3$)	10 ⁹ PE		
		ロジック	メモリー [容量]	合計				ウェハ枚数 ($\times 10^3$)	ウェハ スタック数	スタック モジュール数
A	1	5	25 [0.5KB]	30	PE間 格子 + ウェハ間 階層型 ハイキューブ	3000	180	6	6	0.4
B	8	12	98 [2 KB]	110		900	54	19	19	1.2
C	16	30	394 [8 KB]	424		200	12	84	84	5.3
D	32	70	1573 [32 KB]	1643		60	3.6	278	278	17.4

[注] メモリはビット当り6Trとして換算

10億ニューロンハードウェアの場合、6万ニューロン／8インチウェハとなり、これを1,000枚、3次元にスタック実装することにより、6千万ニューロン／スタックになる（高さ約50cm）。更に、16(4×4)個の3次元 WSIスタックをマザーボード上に実装することにより、約 100cm× 100cm×50cmの空間に10億ニューロンが集積される。

10億プロセッサに関しては、ニューロンと同じ3次元 WSI実装とし、データ幅を1ビットから32ビットまでふってみた。上記ニューロンハードウェアを1つのスタックモジュールとすると、プロセッサでは丁度8ビットデータ幅の時、ニューロンハードウェアとほぼ同等の物量となる。

本ケーススタディより、“10億”の物量は途方も無く、全く手のとどかないものではないなさそうなことはわかった。しかし、これはあくまでハードウェア量を第0次近似で見積った結果であり、実現のためには多くの技術課題が存在する。10億ニューロンと10億プロセッサに共通の技術課題としては、「ハードウェア化に適したネットワーク構成と WSIスタック等の超高密度実装技術」が挙げられる。時分割による完全結合、格子結合、ハイパーキューブ等のネットワーク方式を如何にうまく階層的に組合せ、超高密度実装構造とマッチングをとるかが鍵になる。また、実装技術だけをとっていても、ウェーハ間の信号伝送や電源供給、冷却技術が大きな技術課題となるであろう。

〔参考文献〕

- [1] 山田, 他 5 “完全ディジタルニューロWSI,” 信学技報, Vol. 89, No. 312, ICD89-151(1989) .

4.2.2 ニューラルネットワーク

4.2.2.1 大規模ニューラルネット

ニューラルネットワークの特徴は、多数の処理要素が密に情報交換を行いながら、「協調と競合」原理のもとに問題を解くことにある。密な情報交換を行える大規模回路構成を目標としたときに考えるべき要素は、

①大規模拡張可能なアーキテクチャ

②大規模コネクションの実現手法

である。

(1) 大規模拡張可能なニューラルネットワークのアーキテクチャ

このために必要な技術要素は、「信頼性の高い大規模なシステム構成が容易にできると」に尽きる。 10^9 個を超える処理要素をシステムとして組み上げるためには、複雑なアーキテクチャは避けるべきである。また、高密度な情報交換を可能にするアーキテクチャであるべきである。このような要請を満たす回路方式、及びシステムアーキテクチャとして、以下のものが考えられる。

(a) 回路方式：PDM(Pulse Density Modulation)型ディジタルニューラルネットワーク

特徴：


① デジタル非同期回路方式（PDM方式）

② Recursive Modular Architectureがとれる（単に接続してだけで、いく
らでも大規模化が可能）

③ 外部とのインタフェースが容易

(b) システムアーキテクチャ：Recursive Modular Architecture

チップレベル、ボードレベル、デバイスレベル、システムレベルで全く同一の回路構成で拡張が可能である（図表4.2-5 参照）



図表4.2-5 同一アーキテクチャのRecursive

(2) Recursive Modular Architectureの実現手法

- ① モジュール $M_{i,j}$ ($i=1, \dots, l$) をマイクロプロセッサ M_j で管理
- ② 全てのシナプス荷重レジスタと細胞体カウンタをマイクロプロセッサのアドレス空間にマップする
 - ◎ ニューラルネットワークはメモリに見える
- ③ ニューラルネットワークを複数に分割し、マルチタスクが実行可能
- ④ どのようなニューラルネットワーク構造も実現可能 (汎用)

(3) 回路規模の試算

将来のVLSI技術の動向を見越したときに、チップレベル、及びモジュールレベルで必要となる回路規模を試算すると、以下のようになる。

① チップ内回路規模

$$aX^2 + bX = C$$

a : シナプス回路ゲート数 (140ゲート : 8ビット)

b : 細胞体回路ゲート数 (500ゲート : 10ビット)

c : チップ当り総ゲート数 (107ゲート/チップ)

$X = 8.43 \times 10^2$ ニューロンの完全結合回路／チップ

②モジュール規模：49チップ／モジュール

$7 \times 8.43 \times 10^2 = 5.7 \times 10^3$ ニューロン／モジュール

(4) 技術課題

Recursive Modular Architectureを実現するための技術課題は、大規模コネクションの実現にある。しかしながら、

①システム全体として同期をとる必要がない

②モジュールを規則的に並べるだけでよい

という、大きな救いがある。大規模コネクション実現手法としては、

③LEDアレイ＋ファイバーバンドル＋フォトダイオードアレイ

④周波数多重化

⑤空間的なスキャン

等が考えられよう。

多形態の大規模な情報処理を効率よく高速に処理するためには、大規模なニューラルネットワーク処理計算機構の実現が重要となる。1000万ノード規模のニューラルネットワークを実時間に近く動かすためには、ニューラルネットワークの処理に向けた専用の超並列なマシンが必要となる。ニューロンの動作を実際のハードウェアに対応させる場合、実際のハードウェアモジュールが各々ニューロンに対応する実ニューロン方式と、複数のニューロンが1つのハードウェア資源を共用する仮想ニューロン方式とが考えられる。ハードウェアの開発とニューロモデル・応用などの研究が同時進行することを考えると、単一のアーキテクチャで全てを包含することは困難であり、仮想ニューロン方式／実ニューロン方式の両方のアーキテクチャを模索する必要がある。仮想ニューロン方式では部分ネットワーク分割による並列処理とプロセッサ間結合方式、及び各ニューロ処理に必要な処理手続きの専用ハードウェア化／パイプライン化が技術課題となる。また、仮想方式では、多様なニューロモデルへの適合性も重要である。実ニューロン方式ではチップ面積と実現性能の兼ね合いで、アナログ／デジタル、電気／光などの技術の選択がポイントとなる。大容量化したときに、ハードウェアが爆発しないよう、加算、乗算、出力計算・伝播などのハードウェアの適切な設計が重要である。ニューラルネットワーク処理ではどうしても通信のバンド幅が広い必要があるので、光通信／光接続及び3次元・立体配線などの技術も

確立する必要がある。

4.2.2.2 仮想ニューロコンピュータ

(1) 背景

ニューロコンピュータはニューラルネットワークを高速に処理するためのハードウェアであり、その実現法としてニューラルネットワークモデルを忠実にハードウェア化する立場（実ニューロン方式）と、ディジタル演算をベースとしてニューロ演算のシミュレーションの高速化に主眼をおく立場（仮想ニューロン方式）とがある。ニューラルネットを用いた数々の応用研究が行われているが、本質的にはニューラルネットの利用は入出力対が明確に定義できる単機能の実現に限定され、複雑／多形態な情報処理を指向するには従来情報処理との融合が不可欠である。この場合は、単に従来型アーキテクチャとニューロコンピュータとを接続するレベルでは不十分であり、両者の機能が密接に関わり合う形態が要求されている。このため、ここではより融通性のある仮想ニューロン方式を前提として考える。しかし、汎用プロセッサを多数個結合したアーキテクチャとニューラルネットワークとのギャップは大きく、従来の汎用並列アーキテクチャ上でニューラルネットを十分高速に処理することは困難である。そこで、応用から要請される機能をシステムとして効率よくアーキテクチャに反映する立場に立って、次世代ニューロコンピュータのアーキテクチャの必要とされる機能、及び展望について述べる。

(2) 専用 vs 汎用


専用マシンと汎用マシンを比較すると、現状では経済性と万能性により最新のデバイス技術の恩恵を受けた汎用マシンが有利である。しかし将来並列処理において汎用マシンの優位性がそのまま保たれるかどうか疑問である。むしろニューロのような新しい並列パラダイムを効率よく実行できる専用マシンが有利になる可能性がある。ニューロ専用の場合、パターン認識エンジン、最適化エンジンなどの形態でシステムに取り込まれる方向が考えられ、実用性を重視したコンパクトなアーキテクチャとなる利点がある。例えば、AT&Tのニューロチップは重みは3種類しか変えられないが、認識エンジンの1形態として捉えることができる。また、最適化エンジンについても2値Hopfieldモデルの効率よい実現法が提案されている。

ここでは、専用プロセッサを更に強化して汎用を指向したニューロコンピュータについ

て考える。これは、単に現在のニューロモデルの高速化だけでなく、将来の新しい並列パラダイムへの適用も想定したものである。

(3) 構成

仮想ニューロコンピュータの要素プロセッサの構成を図表4.2-6のように想定し、各々の構成要素に必要とされる機能について述べる。



図表4.2-6 仮想ニューロコンピュータの要素プロセッサの構成

①高機能メモリ

メモリにロジックを付加して高機能化するという考え方は古くからとして提案されており、その実現例として連想メモリがある。チップ内の並列性を効率よく生かすには、この考え方は重要である。

ここで提案する高機能メモリは、連想メモリを更に発展させ、ニューロ演算も同様の方式で行うことを想定する。将来IMBの高機能メモリが1チップで実現できるならば、1000ニューロンくらいはチップ内で実現可能であろう。このオーダのニューラルネットがコンパクトに実現できれば、かなり応用範囲が広がるであろう。

②高機能通信

通常デジタルシステムにおいて通信は1対1あるいは1対多のいずれかであり、アナログのように多対多の同時通信は困難である。従って、ニューラルネットのような応用では、配線の膨大化、あるいは通信ボトルネックを引き起こす。このため通信の高機能化により、この欠点を改良することが重要である。これは、アナログ通信の利点をデジタル

的に解決するメカニズムを目指しており、その方策としては、通信量の減少、通信線の多重化、通信部と演算部との間のオーバーヘッドの減少などが考えられ、そのための効率よいハードウェアメカニズムが必要となる。

③制御機能

ニューラルネットワークと従来情報処理とを効率よく融合するためには、ニューラルネットが外部から制御可能である必要がある。すなわち、ニューラルネットワークの状態を外部から監視し、内部状態の変更や動作の開始／停止などを行う制御機能が必要である。

このような機能は応用特有のものであり、汎用性を考慮するならば、汎用プロセッサの導入が必要である。しかし、超並列マシンの並列度をできるだけ上げるためには構成要素としてのプロセッサは充分シンプルなものにする必要があり、用途に応じて再検討する必要があるだろう。

(4) 展望

仮想ニューロコンピュータとして要求される機能について述べた。ニューロコンピューティングを新しい並列処理パラダイムとして捉え、その特徴をアーキテクチャに反映することが重要である。単にニューラルネットワークの専用アーキテクチャに限定するのではなく、従来情報処理との融合を前提として、各種の応用に即してハードウェア／ソフトウェアのトレードオフを工学的見地から追求するというアーキテクチャ的な考察が必要である。また、応用についても固定的に考えるのではなく、本質的な機能を抽出してアーキテクチャに反映するとともに、将来の発展についても考慮することが必要である。

また、このようなアーキテクチャからのアプローチと併せて、ハードウェアの制約を前提とした新しいモデルの研究も同時に進める必要がある。例えば、ネットワーク構造において隣接間接続を前提としたモデルの研究が必要と思われる。このように、アーキテクチャ／モデル／応用の各面から総合的に研究を進める方策が現状では重要と考える。

[参考文献]

- [1] H. P. Graf et al.: "VLSI Implementation of a Neural Network Model", IEEE Computer, Vol. 21, No. 3, pp. 41-49, (March 1988).
- [2] 鈴岡: "Hopfield モデルの並列化", 電子情報通信学会研究会資料, CPSY89-42, (Aug, 1989).

- [3] D. Hammerstrom, E. Means : "System Design for a Second Generation Neurocomputer", IJCNN-90-WASH-DC, pp. 80-83, (Jan. 1990).

4.2.3 統合型アーキテクチャ (Brain Simulator)

(1) 目的

素子技術の発展とともに、問題の解決に必要とされる計算機規模を超えるような超高性能の超並列のコンピュータの実現が可能となる時代がこよう。これまでは、計算の性能をあげるために色々の数値解析等のアルゴリズムの工夫を行ってきた。これに対して、ありあまる計算能力の利用が可能になれば、わざわざ計算アルゴリズムを考えなくても、素直な形で問題解決が可能となる。その結果、プログラムも簡単になり、またアーキテクチャも簡単ですむことになる。アーキテクチャが簡単ですめば、ますます超並列コンピュータの実現が簡単になるということになる。このような考え方を統合型シミュレータと名付ける。

超並列コンピュータの最大の応用の一つがニューロネットワークシミュレータである。分かっている範囲で、できるだけ生物に近いこうで大規模なニューロネットワークシミュレータ (Brain Simulator) が開発できれば、以下のような成果が期待できる。

- ① 超並列処理 (ニューロネットワーク) と推論処理との分散協調処理理論の実践的
確立
- ② 時・空間的に広がった超並列処理理論の確立
- ③ 生物的なニューロネットワーク研究の基礎となる大規模ニューロネットワークシ
ミュレータの開発
- ④ その他

(2) 技術的背景

シリコン技術[1]の進化を考えてみよう。 50×10^6 ゲート/インチ²。これで、1CPU = 4 PE + 2 ベクトルユニット (2GIPS + 2GFLOPS) が実現できる。ウェハスケールインテグレーション (WSI) を使って、20CPU (80PE + 40VU) / 8 インチウェハ。1000ウェハをスタック (ウェハ間光接続)。これを 200スタック使用。システム当たり 4×10^6 CPU (16×10^6 PE + 8×10^6 VU)。性能は2000テラフロップス/システムとなる。

このような技術に基づくコンピュータの設計において考えるべきキーワードは以下のと

おりである。

- ① 超並列処理： 10^7 個のプロセッサから成るシステムである。
- ② 自律的分散・協調処理：周りの環境（外界または他のコンピュータ）と「問わず・語らず」でも雰囲気で協調処理ができる。
- ③ センサ・反応能力：人間と同じ（というより、これをしのぐ）。
- ④ シミュレーション：物理現象、生物現象に学ぶ（を真似する）。

(3) コンピュータから統合型シミュレータへ

話を単純化するために、コンピュータの使用用途として、

- ① 物理現象の予測（気象予測等）
- ② 社会現象の予測
- ③ 人間の知的活動の代替（認識、判断等のAI）

等を想定しながら話を進めることにしよう。

現在のコンピュータはチューリングマシンを基礎にしている。すなわち、全ての処理は基本演算（簡単のため、4 則演算等ということにしておこう）に分解できるという原則に立っている。従って、これまでの計算アルゴリズムの研究は、どのような問題であろうと、その元の様式はさて置いて、できるだけ少ない数の演算（ここで、演算には、明示的にプログラムに現れる演算の他に、いわゆる緩和処理の収束速度等も含まれる）で済ませることを目指して来た。その結果、プログラムは、元の物理現象等とは似ても似つかぬものになっている。物理現象の予測を考えよう。物理現象は偏微分方程式で表される連続現象である。残念ながら連続の計算はできないので、まず時間と距離をそれぞれ、 Δt と Δx の微小変位でのディスクリート表現にして、その結果各時刻・位置の変数の連立方程式を得る。この連立方程式を効率良く解くために、SOR (Successive Over-Relaxation) とか色々の数値解析手法が開発されてきた訳である。これらのプログラムは、元の物理現象とは似ても似つかぬものになっていることは既に述べたとおりである。

このような手間を捨てて、元に戻ったらどうであろうか。これが、統合型シミュレータの出発点である。前記のような「計算をする」という考えから、おおもとの自然現象に戻って、これを素直に「シミュレーションしよう」。そのような「コンピュータ」に戻ろう。統合型シミュレータの基本は以下のようなものである。

① オブジェクト

物理現象・社会現象等での現象の単位のコンピュータモデル。物理現象を扱う偏微分方程式では、格子点の物理状態であろうし、沢山の玉の箱の中の運動（QCDの基本）モデルでは、それぞれの玉そのものにオブジェクトが対応する。社会現象であれば、例えば個々の人間がオブジェクト。オブジェクトは他のオブジェクトからの「影響」を受けて、自分の状態を変える。このように、オブジェクトは状態と、外部からの影響によって状態を変える自律協調機能を含む。

② 直接の相互作用と場情報の放射の2通りの作用素

大気的气象現象モデルの格子点に対応するオブジェクト間では、温度・気圧等の状態をお互いに相互作用として、影響させる。このような「影響」が相互作用のメッセージとしてオブジェクト間で授受される。このような陽に働く作用素に加えて、例えば人込みで他人を避けて歩くように、他人から陽に与えられないで、場情報として陰に受け取る作用素がある。後者は場情報として放射されている。

数学的にいえば、緩和処理を行うのに、Gauss-Seidel等の方法からJacobiの方法に戻ること示す。計算ステップとしては前者の方が後者よりも格段に性能がよい。しかし、前者は本質的に逐次処理であるために、これを並列コンピュータにのせるために、これまでプログラム上の工夫を色々こらす必要があり、これが並列処理を難しくする一因となっていた。これに対して、もし無駄にできる計算パワーがあれば、ごく並列処理に的したJacobiの方法が採用できることになる。

③ 非同期通信（非同期緩和処理）[2]

超並列処理でハイパーシミュレータを実現するには、オブジェクトをプロセッサに対応するのが素直である。この場合の最大のネックは、プロセッサ間の通信路の実現であった。これは、各オブジェクトが他オブジェクトから同期して作用素を受け取らなくてはならないという（暗黙の）制約があったからである。この制約をはずして、各オブジェクトが非同期に勝手にそのときにたまたま使える作用素メッセージを使って処理を進めることができれば、問題は簡単になる。そのための武器が、非同期緩和処理（カオテックレラギゼーション）である。非同期緩和処理は収束性が気になるが、緩和式がコントラクションであれば、収束することは分かっている。特に形式ニューロンをもとにしたニューロネットワークについては、非同期緩和処理が適用できることを証明できる。これ以外の条件の悪い非線形現象については要検討であるが、非同期緩和処理についても、色々の制約を設けてい

くことによって、その適用範囲を広げていけよう。非同期緩和処理を採用することによって、先の素直なモデリングとあいまって、格子状のプロセッサ接続等の簡単な方式の採用が可能となる。

このような統合型シミュレータは、超並列処理が手の上にのるようになって、始めて成り立つ。考え方は素直という大きなメリットに対して、収束が遅いという決定的なデメリットがある。しかし、超並列によってふんだんに計算パワーが使えるようになると、多少の計算パワーの無駄があっても、むしろ素直かつ自然な実現が可能な方式のほうが好ましくなる。

本オブジェクトは以上のように、他オブジェクトからの作用素または場情報放射を受けて、状態を変えていく。オブジェクトはそれぞれどのような作用素が自分に影響を与えるかを知っている。すなわち、オブジェクトには状態と作用素・場情報フィルタリング／状態更新／結果の送出機能がある。この結果、オブジェクトは自律的で成長可能になる。オブジェクトの追加、削除も勝手に、集めると仕事をする。

(4) 統合型シミュレータの構成

統合型シミュレータは、センサ+パターン処理等の柔らかな論理を実現する脳のシミュレータ+高速計算のための超並列シミュレータの複合体であろう。

さらに、その複雑さから次のようなクラス分けもあろう。

(ビット単位)

1ビット単位（脳のハイパーシミュレータ）から64ビットまで。

(接続)

密結合から、「雰囲気結合」まで。雰囲気結合では、人間の間のように、「なんとなく様子で状況が分かる」といったコミュニケーションができる。これは例えば電磁波でオブジェクトを結合することで実現する。


(5) 主な研究内容

以下に、主な研究内容を示す。

① ニューロネットワークシミュレータ

- ・超並列処理ネットワーク（アクタメッセージパッシング等）
- ・非同期緩和法理論

- 並列向き数値解析法
 - 例えばビット単位パイプライン等
- ② 超並列処理と推論処理の分散協調（例えばロボットの実現）
- 結合方法（例えば、超並列処理をメモリと見る）
 - 分散協調理論（例えば、トップダウンとボトムアップの競合学習等）
- ③ 知覚処理のニューロネットワーク構成の解明
- 初期視覚
 - 聴覚（時・空間にわたったニューロネットワーク）



図表4.2-7 統合型シミュレータ

〔参考文献〕

- [1] Gelsinger P.P. et al.: "Microprocessors circa 2000," IEEE Spectrum, Vol.26, No.10, pp.43-47, (Oct.1989).
- [2] Chazan D. et al.: "Chaotic Relaxation," Linear Algebra and Its Application, 2, pp.199-222, (1969).

4.3 応用の展望

4.3.1 学習・自己組織型データベース

(1) 背景

情報化社会の到来とともに我々の身の回りには電子化された情報が大量に溢れはじめた。良く言われることであるが我々はこの情報の洪水の中から意味のある情報を取り出すのが困難になりつつある。こうした大量の情報を高速にかつ人間の手を一切借りず自動的に整理・分類・体系化して記憶し、質問に応じて即座に情報を取り出すことが可能なデータベースへの要求は高い。このような学習および自己組織を行なうデータベースシステムは吸収した大量の情報を基に専門家、一般人に対して情報検索サービスを行なうことができる。具体的には文献サービス、遺伝子情報サービス、医療情報サービスなどが考えられる。

またこのように人間向け情報を対象にしたデータベースに限らず、自然現象の生の計測データを対象にした学習・自己組織型データベース[注]を考えることもできる。このようなデータベースはデータ収集も含めて自動化でき、いわば自然の監視者として機能する。このようなデータベースは専門家にとって有益なものであると同時に、例えば災害予知など社会福祉的な用途も考えられる。

(2) 学習・自己組織型データベースの実現

AI研究は長年に渡り人間の主に言語化された思考について研究してきた。最近の傾向として AI の研究は、学習、類推、文脈など記憶に関連するテーマが中心になりつつある。これは裏返せば、従来の AI の記号処理的方法では記憶およびそれが内包する高次の機能の解明および実現が困難であることを示している。

これらの問題を念頭において、AI からニューラルネットを眺めて見たとき、ニューラルネットには記憶を実現するものとして次のような魅力がある。

〔注〕 大規模知識ベースと似ているが、違いは既存のデータをほぼそのまま入力し、学習・自己組織機構で意味のある情報を自動抽出するというアプローチ。また何が学習・自己組織によって獲得されたかを調べることにより重要な知見が得られる可能性を持つというのも大きな差異である。

① 概念の分散表現

② Hidden unitsの自己組織

①は AI における概念のアトム表現と対照をなすものであり、また②は AI にはない機構である。

②はまた知識処理という観点から見ると次のような意義をもつ。

(a) hidden units は過去の思考活動の統計的性質を反映して組織される。これは作業仮説の自己形成ともいえ、学習、一般化、類推等の機能の基礎的枠組をなす可能性をもつ。

(b) hidden units に形成される作業仮説の分散表現は同様に形成される他の作業仮説との関連性（統計的相関）に基づいて自己組織的に決定される。すなわち、2つの作業仮説の関連が深ければ互いに相関の高いパターンとして、そうでなければ、共通部分の少ないパターンとして自然に形成される。これは概念の修得においてはその概念のみならず、概念間の関連性についても自動的に学習されることを意味する。

学習・自己組織型データベースとは以上のようなニューラルネットの高次記憶機構を実現するものとしての優れた特質を活かして、

「大量の情報を入力し、学習・自己組織を行い、その後意味のある情報サービスを行えるようなデータベース」

を意味する。

(3) 研究課題

学習・自己組織型データベースを実現する上での技術的問題点は以下のようなものである。

① 大量の情報に関して：

情報は電子化されていると最低仮定してもその表現には様々な可能性がある。そしてその表現によってはデータベースの自己組織能力を活かしきれない恐れもある。またある程度の前処理を行うことも考えられるがその場合、行った前処理と実現される機能のトレードオフの検討も必要である。またどういう教材で何が可能になるかを明確にしておく必要もある。要するに学習・自己組織で何が可能かを理論的に明らかにする必要がある（学習可能性理論の研究）。

② 学習・自己組織:

従来計算機にとって変わるものではなく、機能としてはむしろ相補的なものとしてニューラルネットをとらえるべきである。その際ニューラルネットを学習・自己組織能力を持つメモリ(ニューロメモリ)としてみる視点は両者の統合という観点からも検討の価値がある。ここでいう学習・自己組織型データベースはまさにこのような統合の結果の産物と位置付けている。またパターンと記号という対立概念の図式をメモリとCPUという図式に重ね合わせるというのはそう無理な話ではない。とすればパターン処理的なものをニューロメモリで、記号処理的なものをCPUでというのは統合下での分業形態の一つの可能性である。

このようなアプローチをとる場合に注意しなければならないのは装置をブラックボックス化してしまうことである。これは開発中だけでなく、開発後の利用時も含めての話である。パターンと記号の統合はさまざまなレベルでインタラクティブにはかる必要があろう。そのためには装置を常に以下の状態に保っておく必要がある。

- 監視可能に (何が起きているか常に理解したい)
- 制御可能に

③ 情報サービス:

学習・自己組織型データベースはその予想される応用の性質からして従来のデータベースと同様な不特定多数に対する恒常的なサービスを想定する。このため、サービス提供をしながら内部更新も行うとか、コンピュータネットワークを介して広範囲からアクセスできるようにするといったことも検討しなくてはならない。

4.3.2 高次認識モデル

4.3.2.1 相転移に基づく認識モデル

ある図形、例えば、“A”という文字パターンを見て、それが“A”であると認識できたとしても、そのパターンを構成している個々の点がそれぞれ独立に“A”という文字の情報を少しずつ担っているわけではない。それらの画素の“配置”が全体として“A”を形成しているのである。このようにパターン認識においてはパターンを構成している個々のミクロとそれらが相互に作用を及ぼしあって作り出すマクロな状態との関係を探ることが本質的に重要である。しかしながら、この点を正面から考慮した認識モデルの研究は、残念ながら

らほとんど見当たらない。

一方、ミクロな素子の間の相互作用がマクロな現象を引き起こすという例は物理学や化学の世界で多く見いだすことができる。そしてこの現象は散逸構造やシナージェティックスの理論として精力的に研究されている[1], [2]。そればかりでなく、これらの研究は物理学や化学以外のこの種の協力現象の解明にも適用されようとしている[3], [4]。

そこではパターン認識も協力現象として扱われており、例えば、多義図形の認識は統計力学でいう相転移の一種と考えられている。すなわち、水が固体・液体・気体の各相を温度、圧力、体積と呼ばれるマクロパラメータによって移り代わって行くように、多義図形はそれぞれの図形（すなわち、相）の間を協力現象によって転移するというモデルが提案されている。ただし、図形の場合には相を規定するマクロパラメータは現在のところ定かではない。

このように認識を相転移と捉える考え方はきわめて魅力的である。認識の本質に迫る有力なモデルといえそうであるが、この線に沿った具体的な研究はまだ多くない。

相転移モデルによる認識研究のポイントはつぎのように要約することができよう：

①ミクロパラメータ（パターンを構成している部分）とマクロパラメータ（パターンとしての全体的まとまり）の関係を何らかの力学系として捉える必要がある。

②物理学におけるマクロパラメータとしては1次のモーメント、すなわち、平均を用いるのが普通であるが、具体的なパターンを相手にする認識の場合にはには2次以上のモーメントから定まるマクロパラメータが必要であろう。

③文字認識など具体的な認識現象を解明するには、パターンを形成している素子の間にどんな相互作用（力場）を想定するかが研究の決め手となる。これを、例えばニューラルネットにおける相転移として論じる場合には、どのような入出力関係を持つニューロンモデルを想定すればよいかという問題を扱うことに相当する。

④相転移が起こり得るのは理論的には素子の数が無限のときである[5]。したがって認識システムとしては素子数がアボガドロ数のオーダーぐらいある場合を議論することになる。このような超多数の素子からなるシステムを工学的に実現しようとするときは、個々の素子の全てを制御するという立場では不可能であろう。何らかの発想の転換が必要がある。

⑤例えば、アボガドロ数オーダーの微粒素子から成るミドルレベルの素子を考え、各微粒素子はマクロ的ないしは統計的にしか制御できないとする。そしてシステムはこのミドル素子の相互結合で成り立っているとする。相転移は各ミドル素子の内部で起こり、ある一

定の入出力関係を持つと考える。この意味でミドル素子はシステムにおいてはオラクル的な働きをすることになる。

⑥このような相転移オラクルシステムの情報処理機能は、本質的には、超多数微粒素子の相互作用に依存していることになる。この意味で認識の相転移モデルは“超”分散的性格を備えた情報処理の一つの形態を提示するものと言えよう。

[参考文献]

- [1] Nicolis, G. and Prigogine, I. : Self-Organization in Nonequilibrium Systems, John Wiley & Sons(1977).
- [2] Haken, H. : Synergetics- An Introduction, Springer-Verlag(1983).
- [3] Haken, H. (ed.) : Pattern Formation by Dynamical Systems and Pattern Recognition, Springer-Verlag(1979).
- [4] Haken, H. (ed.) : Neural and Synergetic Computers, Springer-Verlag(1988).
- [5] Preston, C. J. : Gibbs States on Countable Sets, Cambridge University Press (1974).

4.3.2.2 多形態情報の認識

データを入力、処理し、出力するまでの多形態情報を扱う機能モジュール群の連合した情報処理システムは、個々の処理系だけでは実現困難な、認識・識別が可能となると期待される。特に、雑音の多い環境や、欠落した不完全な情報から安定して認識を行うことが重要である。

人（その他、多くの生物）が、雑音が多く時々刻々と変化する実世界の中で自由に活動できるのは視覚、聴覚、味覚、触覚、嗅覚、等の感覚器官から入って来る多量のセンサ情報を実時間で処理、統合し、頭の中に外界のモデルを作り上げているからである。このように外界からの情報の収集を多重化するとによりどれか1つのセンサ（視覚は非常に重要なのでこれが無くなると不便であるが）が故障し、情報が失われたとしても、残った他のセンサ情報をもとに実世界を認識することができる。

ある1つのセンサからの情報は1通りの処理を受けるわけではなく並列に動作する多数の機能モジュールによって処理され、その結果が統合される。単一の処理方式だけでは検出が困難な特徴（パターン）は他の方式によって、検出できるかもしれない。また、各モ

ジョー ル単独では検出が不可能な特徴も各々の結果を統合することによって検出可能になる。

人間は、2つの目から入ってきた視覚情報をもとに3次元の世界を認識している。2次元の画像から3次元の構造を再構成する手法はいくつかある。面の明るさから面の傾きを求め、面の傾きから3次元構造を復元できる。ステレオ画像であれば、まず特徴を抽出し、2枚の画像で対応する特徴どうしを対応付けすることにより、三角測量の原理で、その特徴の3次元位置を計算できる。特徴としては、同じ明るさ、テクスチャの領域、明るさの変化点、線分等があるが、各々に長所、短所があり、1つの特徴だけでは人と同程度の認識精度を達成することは困難である。複数の特徴からの結果を統合することにより高精度の3次元構造の復元が期待できる。

音声認識でも、従来のアルゴリズム、ニューラルネットワークモデル、曖昧情報処理等、多形態の情報処理技術を併用することにより認識精度の向上が期待できる。


より知的で、高度な情報処理システムでは、我々人をはじめ多くの生物がやっているこのような、多形態の情報処理の方式を実現する必要がある。

4.3.3 最適化および支援システム

4.3.3.1 組合せ問題、各種大規模システムの最適化

(1) 背景

ワークステーションの高機能化とネットワーク（LAN等）の発達に伴い、コンピュータや各種データソースをネットワークを介して結合した現在の水平分散型のシステムは、今後各種専用コンピュータや多様なデータベースを含めた複雑多岐なシステムへと変遷していくものと思われる（図表4.3-1）。



図表4.3-1 システムの分散化

このような高度に分散化されたシステムにおいて、これらの資源をうまく協調させて全体として最大の能力を提供するためには「多数のユーザの要求に対して、各資源の能力に応じて最適に負荷分散してシステム全体で提供できる能力を常に最大にする」組合せ最適化問題を時々刻々解きながら運用していく必要がある。

これは一般にNP問題であり、システムが大規模化して組合せの数が指数関数的に増えるにつれて、最適解を有限時間に解くことが困難になってくる。しかもネットワークを介した結合のために、観測時点と動作時点の間にタイムラグが存在する最適化問題を解かなければならない。

このように、時間的要素を含んだ大規模最適化問題をどう解決していくかが今後の最も重要な課題の一つであり、超並列・超分散処理により何とか解決できないかというのが、この研究の目的である。

(2) 応用の展望

組合せ最適化問題の難しさは、考えられる組合せの数の爆発に対してどう対応するかであり、もし問題を相互に関連の薄い多数の部分問題にうまく分割することができれば、これを超並列・超分散処理によって有限時間で解を見つけることができる。したがって本質は大規模問題をいかに部分問題に分割できるかであり、これを先見的な知識がなくとも自動的に実現する方法を求めることが課題である。

現在このための方法論としてはニューラルネットが一般的であるが、ニューラルネットによって単に超並列に処理すればNP問題が解決されるわけではない。ニューラルネットの面白ろさは、むしろ学習を通じて構成を自由に変えられるという柔軟性にある。現在のホップフィールドネットワークは、構成を変化させる規則(学習機構)が入っておらず、問題向きのニューラルネットを人手で作ってやらなければならないという点で未完成である。今後、問題に対する先見的知識を教師として教えることにより、自動的に上で述べたような問題分割ができるような学習機構を組込めれば、面白い計算手段になると期待される。

以下、このような超並列処理で最適化問題を高速に解くことによって解決されると期待される応用について述べる。

①LSI 配線問題

- ・素子の集積化が進むにつれて、従来の手配線では到底対応できなくなっている。これを自動的にしかも手配線と同程度の品質で配線できるシステム

②ネットワークの最適設計

- ・ネットワークへ入るトラヒックパターンの量と性質をあらかじめ予測して、通信リンクを最適に配置するネットワーク設計問題
- ・呼損の発生が最も少なくなるような最適リンク容量割り当て問題

③通信網の最適ルーティング

- ・ネットワークに時々刻々入ってくるトラヒックを、ネットワークのどの経路を使って宛先まで運べば良いかを決定するルーティングアルゴリズム
- ・ネットワークの状態を観測してから最適解を求めるまでの時間が短い程、トラヒック密度の変動に追随できる方式となり、超並列・超分散による高速化が有効

④プロセッサ集合体の負荷分散

- ・多数のプロセッサを結合した分散処理システムにおける最適負荷分散
- ・遊休プロセッサの割合を最も少なく、レスポンスを速くするための最適タスク割り当て
- ・③と同様、時間要素が入るため、超並列・超分散による高速化が有効

⑤大規模システム的意思決定問題

- ・グループコミュニケーションでの意思決定
- ・多数のセンサから集められた情報を統合して戦略を決定する方法

(3) 研究課題

このための研究課題を以下にまとめる。

- ①大規模問題の部分問題への分解の方法
- ②部分と全体の統合の仕組み
- ③学習機能による構造の自動改変
- ④解の最適性の保証と近似精度

この際の方法論としては現状のニューラルネットはもちろんだが、さらに現在のニューラルネットを一段上から制御する仕組みや教師無学習の新しい理論を構築していくことが不可欠である。このためには、個と全体の関係を明らかにする群情報処理等の新しい自律統合理論の研究が最も重要な課題である。

4.3.3.2 超並列超分散アーキテクチャの応用による予測・計画・決定支援システム

ここでは、予測・計画・決定支援システムに対する超並列超分散アーキテクチャの適用可能性を展望する。一般に、超並列超分散アーキテクチャは、最近提示された新しい問題解決、あるいは処理のモデル（例えばニューラルネットワークモデル）を効果的に実現するものとして注目されているものである。

これに対し、科学技術計算やシミュレーション、あるいはエキスパートシステム等の処理モデルを効率よく実現するアーキテクチャとして様々なものが提案されてきた（例えば、アレイプロセッサ、推論マシン、データフローマシン等）が、前記の応用分野に限って言えば、通常のノイマン型アーキテクチャに基づく計算機によって対処しているものがほとんどである。これはこのような応用分野においては、新しいアーキテクチャを必要とするような処理モデルが適用されていなかったためといえよう。けれども最近になってこうした応用分野に対する新しい処理モデル（ニューラルネットモデル）の適用可能性が注目されるようになってきている。このためこの処理モデルを実現するための超並列超分散アーキテクチャにも大きな期待が寄せられることになるろう。

次にこの応用分野に対する処理モデルの現状であるが、これには通常のプログラミングシステムで十分対処できるもの、最近エキスパートシステムの適用領域として注目されているもの、およびニューラルネットモデルの適用可能性が大と考えられるもの、の3種がある。このうち、ニューラルネットモデルが適用可能なものの中には、実際にはニューラルネットにおける最適化問題に帰着するもの、およびニューラルネットの学習機能が中心的な役割をはたすものの2種が考えられ、この2つは同じニューラルネットモデルの適用とはいえ、扱う問題の性質が大いに異なると考えられる。

以下では処理モデルという観点からこれらの応用分野の特徴、問題点等を概説する。

(1) 既存情報処理に基づく処理

前述の応用分野における現実のシステムの多くは、通常のプログラミング言語を用いた専用ソフトウェアによってシステムが記述されている。このうち一部はエキスパートシステム化されたものもあるが、エキスパートシステムの適用領域はそれほど広いものではなく、予測や意志決定にいたる筋道が非決定的で容易にアルゴリズム化されないもの、あるいは推論実行のよりどころとなる知識が、頻繁に変更されるためプログラムによる記述では非経済的と判断されるもの等においてエキスパートシステムの適用が好ましいとされて

いる。

(2) ニューラルネットモデルに基づく最適化問題への適用

この分類に属する問題は本来非ニューラル的なアプローチ（例えばグラフ理論・線形計画法といった）によって解くことができるが、多くの場合これらはNP完全問題となり、問題の規模が大きくなると組合せ爆発を起こしてしまう。このためニューラル的手法を用いて（例えば Hopfield モデル）最小近似解を求めるものが多い。なお一般には、初期値に依存して最小値ではなく極小値に収束してしまう可能性が大きいため simulated annealing 法等を併用して、近似最適解を求めるというものも発表されている。

(3) ニューラルネットモデルに基づく学習機能への適用

この方法が適用されるものは、今までに集積された個別事実が膨大であったり、不完全なものや矛盾した事実が含まれ、従来のプログラムやエキスパートシステムでは対応が困難であるが、過去蓄積された膨大な事例データが存在するという分野である。

この事例データは、ニューラルネットの格好の学習対象となるが、通常はシンボルで表現されたこれらのデータを、どのようにしてニューラルネットの学習データとして適切な形（例えばパターンデータ）に変換するかが問題となるであろう。

したがって、(2)、(3)については、新しい処理モデルの適用可能性に伴って超並列超分散アーキテクチャの適用も大いに期待されるところとなろう。

次に以降では、これらの応用分野における現状の問題点、新しい処理モデルやアーキテクチャ適用の是非、システムイメージ等を鮮明にするため、応用例としてローン等の審査システムおよび証券投資等の相談システムを取り上げ、それらの現状と問題点、および超並列超分散アーキテクチャ適用可能性について論ずることとする。

① ローンの評価・審査システム

この応用分野は、例えば代表的なシステムでは利用する知識として 400～500 個の断片情報から成るが、これらは実際には主観的で、相互に矛盾していたり、不完全であったりする。現状では一部は数値化された評価値を用いて判定するが、残りの部分は人間の主観的判断に頼らざるを得ない。膨大な過去のデータからの経験則に基づく判断となるため通常のプログラミング手法やルールを用いた通常のエキスパートシステムでは十分な精度が

だせない。

反面、過去に蓄積された情報は膨大になるため、このデータはシステムの格好の学習対象となり、ニューラルネットのうち学習や帰納推論機構を主体とするような処理モデル (Back propagation や Boltzmann machine) およびそれを実現するための超並列超分散アーキテクチャの適用が大いに注目されることになる。ただしこの場合、記号データを (今のところ学習や帰納推論対象として扱い可能な) パターンデータにどのようにして変換するかは技術課題として残る。

② 投資、財テク等の相談

証券投資や財テクの相談システムは、一般に、特定の条件で非常によく適合したものが、条件が変わると全く適合しなくなるという難点を持つ。このためこれをエキスパートシステム化しようとする、膨大な数のルールが必要となるが、現状では、これらの条件をルール化するとき、主としてメモリ容量等の制限のため少ないルール数とならざるを得ない。またこれらのルールを更新したり、削除したり、それに対する無矛盾性をチェックしたりといった知識ベースの保守の問題もルール数が増えると深刻な問題となる。

また、一般に投資や財テク相談は、リスクを最小化し、利益のチャンスを最大化する問題であるが、現状では、この問題は非常にコストのかかる大型計算機やワークステーションの上で、複雑な線形計画法の問題を解くことになる。これを最適化問題を焦点に置くような処理モデル (Hopfield モデル等) に置き換え、超並列超分散アーキテクチャを適用した専用マシン上で実行できれば、大幅なコスト削減が可能となろう。

なお一般にニューラルネット的処理モデルでこれらの問題を解く場合、エキスパートシステムの適用時と異なり、解に至った過程の説明が困難である。しかしながら、説明機能は、これら予測、意思決定システムには不可欠の要素であり、たとえば Back Propagation を適用した場合の中間層の構造を分析、解読し、説明に用いるといったように、ニューラルネットモデル適用時においても説明機能と等価な機能の実現は必須の技術課題となろう。

なおこれらの分野において、最近発表された開発事例には次のようなものがある。

③ ニューラルネットの金融、財務における適用事例

・ Adaptive Decision System :

ローン契約における意思決定システム。家具、電機器具、エレクトロニクスの販売店に置かれたパーソナルコンピュータ上のアルゴリズムとして実現。アルゴリズムの調整は一括して実行、修正済アルゴリズムをパーソナルコンピュータへダウンロード。

27万件の過去のローン事例を学習データとして用いる。出力はローンオフィサーへの助言。バックプロパゲーションモデル、HNC社のANZAシミュレータ上で動作。

- Nestor, Inc. :

抵当保証の審査シミュレーション。

- Hecht-Nielson Corporation :

為替交換のデモシステム。日本円と米ドルのレートの推移データを学習。

米ドルに対するマルクやポンドの動きを予測。HNC社のANZAシミュレータ上で動作。

- Chase Manhattan, Inductive Inference Inc. :

ローンや抵当の信用審査システム

- 日立製作所、

ニューラルネットによるポートフォリオ分析に基づく株式銘柄選定システム。

Hopfieldモデル。

[参考文献]

[1] R. Miller et al., NEURAL NET Applications and Products, SEAI Technical Publications, (1990).


[2] 石川昭 編: ビジネス・エキスパート・システムとは何か, 有斐閣新書, 1988年10月.

4.3.4 自律・成長システム

4.3.4.1 自律システム

今後実用規模の新しい情報処理システムを構築するためには大規模なニューラルネットワーク計算機構の実現が重要となる。また、実際のニューラルネットワーク適用の場としては図表4.3-2で示す様に、多くのセンサから集められる多形態のデータを実時間で処理する自律ロボット的な情報処理システムを考える。この様なシステムでは多数の機能モジュールが並列に協調・競合しながら動作するもので、認識、計画、推論、制御などのサブシステムで構造化されたネットワークと考えられる。各々のサブネットワークはさらに個別のニューラルネットワークで構成されている。サブネットワークの中でも推論サブシステムが人間の知識処理に対応する部分で知識獲得・学習といった重要な技術課題がある。大規模で構造化されたネットワークにおいて、システム全体の機能をバックプロパゲーション

ョンなどの従来の学習方式のみで実現することは困難と考えられる。そこで、ここではネットワークはあらかじめ初期機能をプリワイヤリングによりプログラムしておいて、その後、学習により調整・適合させる方式を考える。しかし、構造化された大規模なネットワークにおける学習方式は未知の分野であり、今後の研究課題と言える。また、ネットワークを構造化するための、プログラミング技法、言語、支援環境の開発も必要となる。このように、プリワイヤリングに続く学習の方式が確立されれば、学習済みのネットワークからルール of 学習・獲得も可能となろう。



図表4.3-2 実世界で実時間動作する情報処理システム

以上述べた推論システムを中心とする大規模なネットワークの研究を推進するためには、1,000 万ノード規模のネットワークが高速に動作するシステムの開発も研究用のツールとしては勿論のこと、超並列計算機のアーキテクチャを模索する上でも重要である。ここでは、まだネットワークモデルや機能を固定する段階にないので、仮想ニューロン方式の高／超並列計算機が適していると考えられる。

4.3.4.2 成長システム

(1) 背景


システムが大規模化して、要求機能も多様化してくると、あらかじめ機能を固定して最適なシステムを設計するという従来のトップダウンな設計手法をとることが難しくなってくる。これからは、システム設計時には汎用的な機能のみ用意しておき、実際に使っていくにつれて問題に適した最適な専用システムに変化できるようなボトムアップ的な設計手法を考えていく必要がある。このためにはシステムを取り巻く環境の変化や要求機能の変

化に逐次適応して自己を改変していける能力や、障害を即座に検出して無中断で処理を続行できる自己修復能力等の生物の機能を何らかの形で機械に取り込むことが重要な課題である。

(2) 応用の展望

複雑な要求条件や環境変化を従来のシーケンシャルで論理的な処理で解析しようとしても限界がある。これらをパターンとして認識する高速な処理機構（例えばニューラルネットのような並列分散機構）をシステムに組み込み、環境を認識しながら内部の結合形態を自由に変えていけるような成長可能な構成が必要である。このような機能は下等生物等にもその例が見られ、この機構のエッセンスをプロセッサに取り入れることが考えられる。

図表4.3-3にこのような考え方に基づく、成長型プロセッサのシステムイメージを示す。



図表4.3-3 成長型プロセッサ

①通常はプロセッサ間の結合がゆるく、個々が独立に動作する状態で動作しているが〔自律〕、②要求が発生すると複数のプロセッサが相互結合したマルチプロセッサとして動作して要求を満たそうとする〔統合化〕、③さらにその機能を実現するのに最も適した形態に変化し〔機能分化〕、④システムに対する要求が満足される構成が固定化する〔実現〕、そして、⑤要求が満たされると、プロセッサ間の結合関係もリセットされて元の自律状態に戻る、というサイクルを繰り返すようなシステムである。ただし、その後同種の要求が発生したときは、学習効果により1回目より早く機能組織化されるようになる。このようなアーキテクチャ可変のマルチプロセッサにより、使うにつれて賢くなっていくような柔らかな成長システムを実現できる可能性があり、予測できない環境での最適運用シ

システムや台数効果を常に発揮できるマルチプロセッサ等への応用展望が開かれる。

(3) 研究課題

このようなシステムを実現する上で要となる研究課題を以下にまとめる。

①超分散からどうやって機能を実現するか

- ・自律⇒統合のメカニズム
- ・情報の共有のメカニズムとプロセッサ間の通知方法
- ・結合が可変なハードウェアアーキテクチャ

②成長とは何か

- ・量的成長

機能はそのまま、大きくなる、強くなる。

大量処理ができるようになる。

同一機能のものが増殖していく（プロセッサがマルチになってMIPSが増加）。

- ・質的成長

機能的に複雑なことができるようになる。

同じ過ちを繰り返さない。

パターン処理と論理処理を自由に使いわけ。

今までの経験を使って、未知の問題を解決できるようになる（類推、記憶）。

③学習機構

- ・正解を求めるのが困難な問題の学習をどうやって実現させるか（教師無学習）。
- ・経験を通じて学習していく自然界の摂理をいかに理論として確立するか（学習理論）。

(4) プロセッサにプリセットする設計図は何か。

- ・基本的な部分と可変部分をどう組合せるか。
- ・基本部分として各要素にはどういう情報が内在しているか。
- ・要素が統合するときの規則は何か。

(5) 記憶・忘却のメカニズム

- ・環境からの入力パターンを、再利用可能な整理された形でシステム内に蓄える方法
- ・システム規模に応じた記憶容量の確保
- ・高速検索、連想の実現

4.3.5 大規模シミュレーション

(1) はじめに

4.1.4 で述べられている超並列・分散協調方式の計算・情報処理モデルを基にした具体的な応用の一分野として、大規模なシミュレーション問題がある。ここでは、シミュレーション手法の新しさと、その規模の大きさを考慮して、以下で述べる方式をハイパーシミュレーション(hyper simulation)と呼ぶことにする。

(2) ハイパーシミュレーション

ハイパーシミュレーションとは、物理現象、生物現象、経済現象、社会現象、及び人間のもつ高度の認知過程などをその現象や過程に登場し、現象や過程を構成する個々の構成要素を、それぞれ能動的なエージェント（すなわち、CPU とMUを備えた仮想プロセッサのようなもの）として、モデル化することによりシミュレーションを行うことである。当面ここでいう、能動的なエージェントとして、3.3.2や4.1.4の(2)で簡単に議論されている並列オブジェクトという概念を考えてもよいが、広範な問題・応用領域に適合するためには、4.1.4 の(6)で触れられている「超並列オブジェクト」という考え方の導入が不可欠となる。

既に4.1.4 の(3)と(4)で触れたように、ハイパーシミュレーションの成功の鍵となるのは、①構成要素が互いに満たさなければならない拘束条件の適切なモデルとその記述方法、及び②構成要素間の相互作用のモデルとその記述法である。

具体的な応用例や、シミュレーションに付随する数値計算手法の問題などは、4.2.3 の(3) “「コンピュータから統合型シミュレータへ」”の部分で述べられているので参照されたい。

—— 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)

01-R 010

