

解説

光ニューラルコンピューティングの展望

早崎 芳夫・谷田貝豊彦

筑波大学物理工学系 〒305 つくば市天王台 1-1-1

(1991年6月21日受理)

Optical Neural Computing, a Perspective

Yoshio HAYASAKI and Toyohiko YATAGAI

Institute of Applied Physics, University of Tsukuba,
1-1-1, Tennoudai, Tsukuba 305

1. はじめに

近年、デジタルコンピューター技術の発展により、情報処理の対象は複雑かつ大容量なものとなってきている。情報処理に対する能力向上への要請は、さらに高度な処理、膨大な量のデータの処理へと高まる一方であり、とどまることを知らない。特に、時間的・空間的に情報が分布している音声や画像などのパターン情報処理、エキスパートシステムなどの知的情報処理、流体力学等での数値計算、大容量高速コンピューターへの応用範囲は拡大している。

高度大容量情報処理を実現するアプローチには、二つの流れがある。一つは現在の主流であるアプローチで、論理演算と記号操作を基にしたデータ処理を精密な手続きの指令であるアルゴリズムの形で実現する“直列情報処理”である。第5世代コンピューターや人工知能は、このアプローチを基にしたハードウェアによって実現されている。もう一つのアプローチは多数の要素プロセッサーと各プロセッサー間の接続と通信により、同時に並列な相互作用で実現する“並列情報処理”である。生物はこのアプローチを選択し、並列情報処理の一つの形態として、人間のような優れた情報処理システムを実現した。このアプローチは、大量の計算や高度な論理的操作には適しているとはいえないが、曖昧で不完全な情報を柔軟に処理し、近似的な解をすばやく得ることを得意とする。

第一のアプローチである“直列情報処理”はその発展の一端階として、現在のデジタルコンピューターがあ

る。デジタルコンピューターは誕生して40年ほどであり、その構成はフォン・ノイマンが提案して以来、今日に至るまで大きな変化はない。これはデジタルで情報を表現し、線形番地の記憶装置の記憶情報を一つずつ呼び出し、計算し、論理的な判断を行い、次の命令を実行する逐次的処理を基本とするアルゴリズムで記述でき、必ず正解に行き着くことができる。しかし、効率のよい計算法を知らない場合、アルゴリズムの万能性に頼ったしらみつぶし的解法では、おのずと限界が見える。そこで、第二のアプローチである“並列情報処理”を考えるのは当然である。しかし、アルゴリズム的手法で、単純に処理の並列化を行うと、その分割と統合の負担が並列度に対して大きくなってしまう。このように、第二のアプローチである並列情報処理において、新しい概念に基づくコンピューター技術の開発への必要性が叫ばれている。そこで、生物の脳を模倣したニューラルネットワーク¹⁻⁷⁾や光の特徴を利用する光コンピューティング⁸⁻¹⁵⁾への関心が高まっている。

ニューラルネットワークモデルは、生物の脳の情報処理である生体情報処理を模倣した並列情報処理モデルであり、膨大な数の単純なユニット（ニューロン）が、それらの間にさらに膨大な配線（インターコネクション）を有している。ニューラルネットワークシステムを構築する際は、多数のユニットと配線を実現する手法・技術が鍵となる。またニューラルネットワークは、デジタルコンピューターにおける論理とアルゴリズムによる計算をプログラムで記述するかわりに、学習と自己組織化によりシステム自身を改善し、情報処理のダイナミックス

を外界に適合できる。以上のように、ニューラルネットワークの重要な特徴は、「大規模並列処理性」と「学習・自己組織化」である。

光コンピューティングは電子に代わって光を情報媒体として用いることで、並列性・高速性・無誘導性などの優れた特徴を利用した並列情報処理システムの実現の一形態である。光本来の持つ並列性は、光学系の結像・回折・散乱特性を利用することにより、二次元的並列可変な配線が容易に実現できる。現在の半導体を中心としたマイクロエレクトロニクス技術による電子デバイスと比較して、光デバイスの能力は必ずしも高くない。しかし光ニューラルネットワーク¹⁶⁻²⁷⁾を含む光コンピューティングの姿は、光並列演算^{8,11,13)}および光配線技術¹²⁾の潜在的能力が極めて高いため、多数の単純な動作をする演算ユニットと高密度な光配線による大規模な並列処理システムが見えてくる。これは、まさしくニューラルネットワークの演算構造が要求しているものと一致している。

図1は、並列情報処理における、デバイスレベルから応用レベルの階層構造をまとめたものであり、それらに関連したニューラル技術や光技術が左右に示してある。上記のことから本稿では、「並列計算システム」と「並列計算実行モデル」の技術的関係に関し、ニューラルネ

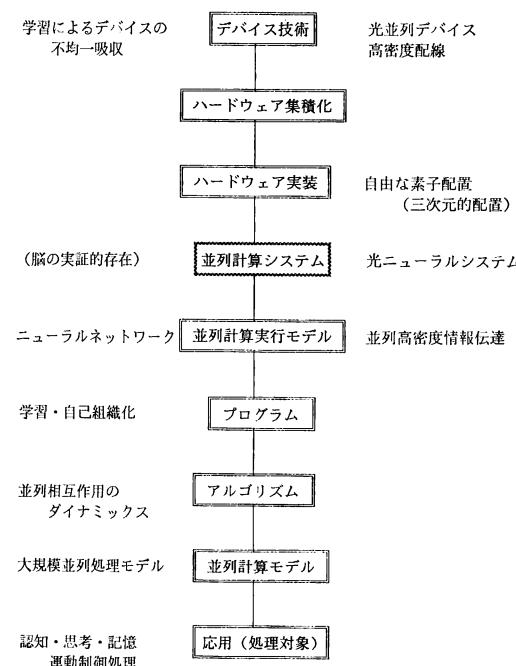


図1 並列情報処理の階層構造と関連する光技術とニューラル技術

ットワークの光技術による実現の意義、整合性、そしてその構成法を中心に述べる。2節において「並列計算モデル」から「アルゴリズム」の階層について、基本的なニューラルネットワークの演算原理とその機能を述べている。3節では、光の利点・欠点とを再確認し、「並列計算実行モデル」であるニューラルネットワークモデルの光システムとこれを構成するデバイスに要求される性能について議論する。そこから、光ニューラルネットワークにおいて、開発が必要な技術について考える。4節では、ケーススタディとして、われわれが開発中の三層構造の光ニューラルネットワークシステムについて述べ、これらをもとに実用化に向けての具体的な技術課題をまとめる。

2. ニューラルネットワークモデル

2.1 基本モデル

ニューラルネットワークモデルは、ニューロンを工学的にモデル化して、それを多数結合したものである。ニューロンの機能は、他のニューロンからの情報を受け取るシナプス荷重の機能とこの情報を基にして、新たな情報を軸索に出力する細胞体の機能である。ニューロンの基本モデル³⁻⁶⁾を図2に示す。これは、多入力-1出力の非線形演算素子と考えられる。

ここでは、 M 個のニューロン出力 $\mathbf{x} = \{x_1 \dots x_M\}$ を受けて、ニューロン出力 \mathbf{y} に変換する単純な離散時間モデルを考える。 i 番目にニューロンからの結合荷重を w_i とするとき、ニューロンの荷重和 u は、

$$u(t) = \sum_i w_i(t) x_i(t) \quad (1)$$

であり、時刻 $t+1$ におけるニューロン出力 y は、

$$y(t+1) = f[u(t) - h(t)] \quad (2)$$

である。ただし、 f は非線形関数、 h はニューロンのオフセット値（しきい値）である。

非線形関数は、ロジスティック関数

$$f(u) = 1/(1 + \exp(-u/\varepsilon)) \quad (3)$$

がよく用いられる。 ε は出力関数の非線形性を決める正

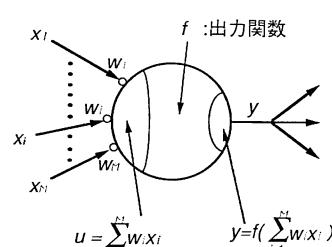


図2 ニューラルネットワークモデル

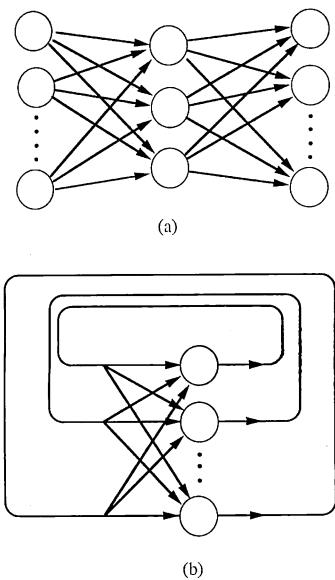


図3 ニューラルネットワークの分類
(a)階層型ネットワーク、(b)相互結合型ネットワーク

のパラメーターである。

以上のモデルは、最も簡単なニューロンモデルであり、実際のニューロンは大変複雑な機能がみられ、時間的加算、不応性、疲労等を考慮したモデルもある³⁾。ニューラルネットワークモデルは、このニューロンモデルを多数結合したもので、そのネットワーク構成を情報処理のタイプで大きく分類すると、階層型ネットワークモデル(図3(a))と相互結合型ネットワークモデル(図3(b))の二つがある。前者は誤差逆伝播学習則³⁾を用いたネットワークを中心に、後者はホップフィールドネットワーク²⁶⁾を中心にそれぞれのモデルの機能について簡単に述べる。

2.2 階層型ネットワーク

階層型ネットワークは、層状にニューロンが結合していく、各層は前の層からしか入力が与えられず、相互の結合を持たない。そのため、情報の流れは一方で、ダイナミクスは比較的単純である。入力層に与えられた情報は順々に、中間層または隠れ層と呼ばれる各層間の結合により変換を受けながら出力層に達する。このような階層型ネットワークの情報処理は、入力パターンを各層間の結合による線形変換と各ニューロンの非線形処理によるパターン変換である。階層型ネットワークで重要なことは、どのような変換を行うかであり、そのための各層間の結合やニューロンでの処理を決定することであ

る。これは、学習や自己組織と呼ばれ、代表的なものとして、誤差逆伝播学習則がある。この学習則は簡単にいって、入力に対するネットワークの実際の出力と望ましい出力である教師信号との二乗誤差を減少するように、出力層から入力層に向かって、誤差を逆方向に伝播させながら、結合荷重を修正していくものである。

階層型ネットワークの機能は、汎化機能とパターン識別機能に分けられる。汎化機能の一つとして、任意関数生成機能があり、与えられた離散的なデータを連続的に結合し補間する機能である。これは見方を変えると、与えられたデータ(知識)から、そのデータ(知識)間を推論していると見ることができる。パターン識別機能とは、既知のパターンを学習した後、未知のパターンがどのパターンなのか判断する機能であり、ネットワークの階層数が2では線形識別、3では凸領域の識別が可能であり、中間層のニューロン数を十分にとれば、いかなる識別も可能となる。また、階層数を4にすると少ない中間層のニューロン数で複雑な識別が可能となる^{4-6,27,28)}。

2.3 相互結合型ネットワーク

相互結合型ネットワークは、ニューロン間に相互結合があるネットワークで、与えられたある初期状態から状態変化を繰り返すうちに平衡状態に達する。初期状態から平衡状態への過程は、連想と見ることができ、その平衡状態には、ネットワークの性質によって、安定平衡状態、周期状態、準周期状態そしてカオス状態がある。相互結合型ネットワークの代表例として、ホップフィールドネットワークがある。このネットワークは、任意の2個のニューロンの結合が対称的である。その動作は、リアブノフ関数に対応するエネルギー関数を極小にする過程として、きわめて簡単に特徴づけられることが示された²⁶⁾。このネットワークは、巡回セールスマント問問題等の最適化問題の高速近似解法として有効であることが示された。しかし、得られた解は最適解ではなく局所最適解であるため、これを避けるためにシミュレーデッド・アニーリング²⁹⁾などの方法が提案されている。

2.4 ニューラルネットワークの学習と自己組織化

ニューラルネットワークの特徴の一つである「学習・自己組織化」は、結合荷重やオフセット値を適応的に修正し、自己組織することであり、与えられる入力信号や教師信号によって、ネットワークの特性が決定されることである。その離散時間の学習方程式を(4)式に示す。

$$\mathbf{w}_i(t+1) = \alpha \mathbf{w}_i(t) + c \delta_i(t) \mathbf{x}_i(t) \quad (4)$$

ここで、 α は $0 < \alpha < 1$ を満たす定数、 c は学習係数、 δ は学習信号である。結合荷重の変化は、入力信号の強

さ x_i と学習信号 δ の積に比例する。学習信号は、入力信号 x 、結合荷重 w 、出力信号 y 、教師信号 d に依存し、Hebb の学習則では $\delta = y - d$ 、相関学習では $\delta = d - y$ 、直交学習では $\delta = d - y$ である^{1~3,7)}。

3. 光ニューラルネットワーク

3.1 光技術の特徴

ニューラルネットワークの特徴である「大規模並列処理性」「学習・自己組織機能」をハードウェアにより実現するためには、個々のユニットが複雑な直列的処理を基本とする現在のコンピューターでは、適合性が悪い。個々のユニットは単純で、ユニット間の大規模な結線を含めた演算機構すべてが、並列処理であるハードウェアが必要である。これは、ユニットの複雑性から、ユニット間の結線の複雑性へ、情報処理の本質を変えるものである。ニューラルネットワークをはじめとする大規模並列処理において、その本質の一つがこの結線の複雑性にあるといえる。ここでは、光技術の利点と欠点を整理し、そこから、光ニューラルネットワークについて考え直す必要がある。また、光技術が解決しなくてはいけない問題も見えてくるであろう。まずはじめに光の原理的利点について列挙する。

1) 並列性：空間並列性による面情報の処理と波長多重性による大容量情報伝達を実現できる。また、自由空間中の情報伝達ができるため、一対多、多対一の結線が容易であり、さらに結線の再構成が容易である。

2) 高速性：光は超高速であり、その速度は媒質のみに依存する。またフェムト秒の超短パルスが発生可能である。

3) 無誘導性：荷電および質量を持たない光は無誘導であるため、電磁誘導ノイズはない。そのため、高速なスイッチング、アースが不要であること、そして交差配線による高密度な配線が可能である。

このような光の利点は、ニューラルネットワークの大規模可変配線に対し、結線の並列化・大容量化・高密度化の点で相性がよいと考えられる。例えば、ニューロンの大きなファンイン・ファンアウトの確保、ニューロン間のプログラマブルな光配線である。次に、現時点での光の欠点および不利な点についてまとめておく。

1) 低相互作用：相互作用が小さいため、十分な非線形性を得るには、素子の大型化や高エネルギー供給が必要であり、その相互作用に電子が介在するため、電子の応答速度限界によりスピードが制限される。

- 2) 波動性：電子と比べ波動性が強いので、光配線の制御性（分岐、結合）や波長の長さによるデバイスの小型化が困難である。
- 3) 極性がない：負値が効率的に表現できない。
- 4) 光デバイスの欠点：光デバイスは周囲の温度や波長の影響を受けやすいため、高い信頼性・再現性・安定性が得られにくい。特性にも不均一が存在する。
- 5) 光システムの欠点：光システムは振動に対して弱く、持ち運びがしにくい。定盤を抜け出す明確なアイデア、技術が少ない。

これらの光の特徴をみると、有用な光ニューラルネットワークシステムを構築するための技術的課題が見えてくる。それらは、「光ニューラルネットワークモデルの進化」、「定盤上技術のハード化（実装技術）」、「光デバイスの信頼性・耐環境性」である。既存のニューラルネットワークを単純に光で置き換えるものではなく、光の欠点である波動性を逆に利用するモデルや負の表現を自然な形で表現できるモデル、振動等を含む位置ずれに強いモデルなどがある。これらのモデルのように、利点（低雑音、高速高密度情報伝達能力、自由空間伝播など）を効果的に利用し、欠点（波動性、無極性、耐環境性など）を克服する計算構造を持つネットワークを開発する“光よりのモデルの進化”が重要である。現在、実用的な性能を持つ光デバイスも登場してきて、デバイスの信頼性・安定性・耐環境性の向上と共に、防振・恒温技術を含む実装技術やシステムとして動作させるためのオペレーティング・システム（的なもの）も考える時期にきているのではないだろうか。

3.2 光技術とニューラルネットワーク

光ニューラルネットワークシステムを構成する上で問題となる点は、ニューラルネットワーク自体発展途上であるため、構成すべきシステムが不明確であり、必要な光デバイスはさらに不明確であることである。しかし、どのような発展があろうとも、基本的に重要な性質「並列処理」「非線形」「多層構造」「学習・自己組織」があり、これらを実現する光デバイスは必要不可欠である。特に「大規模可変配線」「非線形素子」「自己組織性素子」の機能を持つデバイスがなくしては、この性質は実現できない。また、発光素子・受光素子、光メモリなども必要である。現段階では、既存のコンピューターを含む電子機器と独立に存在することは考えにくいので、光-電気、電気-光変換デバイスも必要である。これらのデバイスの期待される特性は、電子技術との競争や社会的 requirement から、「高並列集積 (1,000 × 1,000/cm²)」「低消費エ

エネルギー(素子当り $1\mu\text{W}$)」「小型化(素子当り $1\mu\text{m}$)」
「高速性(1 ps)」程度は最低限必要であると考えられている^{14,17)}。

ニューラルネットワークの最も重要な機能である「大規模可変配線」は、電子技術における最大のネックで、光技術の最も得意とするところであり、そこに光ニューラルネットワークの存在意義がある。光配線技術のうち、第一に空間光変調器(SLM)^{30,31)}による自由空間配線が考えられ、光の利点を活かすためには、光アドレス方式をとる必要があり、その制御法も重要である。現在、SLMは比較的入手しやすい(価格は高い)ので、主に可変結合荷重記憶用として用いられているが、ニューロンの出力の表示や非線形性、そして2次元アレイ光源の代用にも用いられている。望まれる性能としては、並列度(解像度) $1,000 \times 1,000$ 、フレームレート $10\text{ kHz} \sim 1\text{ MHz}$ 、コントラスト $100:1 \sim 1,000:1$ 、ダイナミックレンジ100以上であり、集積性も考慮しなくてはいけない¹⁷⁾。SLMの場合、可変な完全結合が実現できるが、部分結合や固定結合(荷重は別のデバイス)に対しては、平面レンズアレイ³¹⁾やホログラム、導波路

等も利用できる。

発光素子・受光素子は、2次元アレイ状で¹⁶⁾、SLM等の配線素子と同等の性能が必要である。1光源を1ニューロンに対応させれば、1,000個、1結合荷重に対応させれば、 $1,000 \times 1,000$ 個の集積が必要である。将来的には、多段従属接続(多層ネットワーク)を考えて、光入力-光出力、さらに光制御であれば、なお望ましい。発光素子は、ニューロン出力表示用やSLMの結合荷重変更用として使用され、LDやLEDがある。しかし発熱が大きいため、高密度集積に際しては、他の全デバイスの高感度化を図る必要がある。受光素子のPDやCCDは、ニューロンへの荷重入力信号の和をとることが主な用途であり、ネットワークの大きさ以上のダイナミックレンジは必要である。さらに高感度、低雑音、集積性はもちろんのこと、制御可能な非線形性があることが望ましい。

非線形素子の役割は、ニューロンの非線形性の実現にあるので、どのようなニューロンを作るかで、非線形素子に必要な特性は大きく変わる。また、ニューラルネットワークにおいて重要なアノログをどのようにア-

表1 光ニューラルシステム用デバイスの機能、特性、用途

機能	デバイス	主な使用法	期待される特性・用途
光配線	空間光変調器(SLM)	可変な結合荷重記憶 (自由空間配線) ニューロン出力表示 ニューロンの非線形 多重・局所結合 (固定配線)	受光・発光素子との集積化 光制御(光アドレス) 解像度($1,000 \times 1,000/\text{cm}^2$) SLM等と同時使用
	平面レンズアレイ		
	光導波路網		
発光素子	LD(面発光)	ニューロン出力表示	光入力-光出力 (多層ネットワーク用)
	LED	SLMへの入力光 電気光変換	光制御 波長多重 ビーム偏向
受光素子	PD	ニューロン入力の加算機能	光入力-光出力 非線形特性制御
	CCD	光電気変換	高ダイナミックレンジ
非線形素子	LD	ニューロンの非線形	2次元アレイ化
	MQWエタロン	光演算	非線形特性の制御
	非線形光学素子 位相共役鏡	ホログラム型連想記憶で しきい値処理・利得調整	光入力-光出力 光増幅機能
その他	ホログラム	連想記憶 固定配線 光メモリ	高速書き換え可能 (光メモリ、可変配線)

キテクチャーに反映させるかはシステム設計者次第である。高速化のためには、アナログ処理を素子の過渡状態に閉じ込める方法もある。非線形素子として掲げられるのは、しきい特性・双安定特性の LD、非線形エタロンがあり、2次元アレイ化、非線形特性の制御、光入力-光出力等の機能が必要である。

ニューラルネットワークシステムに「学習・自己組織性」を与えるには、大きく分けて二つの方式が考えられる。それらは、ネットワークの外部に別のネットワークが存在し、そこから学習や自己組織を制御する方式とネットワークを構成する素子自体に自己組織能力が存在する方式である。前者は、ニューロン系と学習実行系が別で、学習を実行するネットワークにより計算された荷重変更信号で、SLM 等により実現されている結合荷重を変更する方式である。この場合、学習を実行するネットワークも並列でないと、高速性が得られないで、荷重変更信号を並列的に計算する光並列演算システムが必要である。後者の場合、ニューロン系が自分自身を制御する方式で、自己組織機能を有する素子が必要であり、本来自己組織能力を持つ LD などいかに利用するかで、興味深いネットワークが構成できる。

そのほか、光配線・光メモリとしてのホログラムも実時間で読み書きが可能となれば極めて重要な素子になると考えられ、ホログラムを用いた光連想記憶とニューラルネットワークとの原理・機能の相似性も興味深い³³⁻³⁵⁾。以上の議論を表 1 にまとめておく。

3.3 光ニューラルネットワークの構成

表 2 は、光デバイスの占める割合で構成するシステムを分類したものである。右にいくほど光デバイスの占める割合が多いシステムであり、五つのレベルに分けて、それぞれに対する概念と最低限必要なデバイスの機能を示した。その五つのレベルとは、“光素子によるニューロンの結合荷重” “光素子によるニューロンの非線形処理” “全ネットワークの光接続” “光素子による学習・自

己組織化” “全システムの光素子化” であり、ここでは、「光シナプラス荷重型」「光ニューロン型」「光ネットワーク型」「光学習型」「全光型」と呼んでいる。また、今までに発表された光ニューラルネットワークを構成で分類すると、ベクトル・マトリクス演算方式とホログラム方式、機能で分類すると、連想方式と学習方式がある。ベクトル・マトリクス演算方式では、実験的には、主に「光シナプラス荷重型」が多く^{18-21,23,25)}、ホログラム方式では、「光学習型」も提案されている³⁵⁾。

ここでは、それらの一例として、「光シナプラス荷重型」ベクトル・マトリクス演算-学習方式を実現する最も単純直接的なシステムを図 4 に示しておく。式(1)のニューロン出力 x_i の要素 x_i の大きさに応じた光強度が、発光素子に与えられる。この光は、円筒レンズを含む非対称光学系により、縦方向に拡大、横方向には結像され、結合荷重の値に応じた透過率を持つ SLM を通させることにより、入力光強度と透過率を乗じた光となる。さらに、入力側と直交した同様な非対称光学系を用いて、横方向に集光、縦方向に結像し、受光素子で受けれる。これは、横方向に光を加算していることになる。

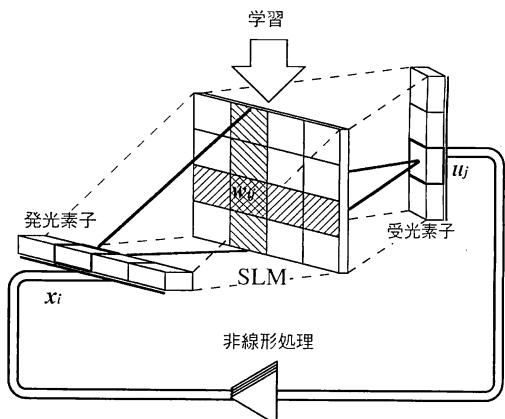


図 4 ベクトル・マトリクス演算-学習方式

表 2 光ニューラルシステムの構成上の分類

光シナプラス荷重型	光ニューロン型	光ネットワーク型	光学習型	全光型
ニューロンの結合荷重のみ光で実現。ニューロンの非線形は電子素子で行う。	ニューロンの結合荷重・非線形は光で実現。フィードバックや異なるネットワーク間の結合は電子素子で行う。	ネットワーク全体を光で結線し、情報伝達を行う。学習やネットワークの制御は電子素子で行う。	光素子または光回路により学習を行い、荷重を変更する。光素子が自己組織を行う。	光素子のみで構成する。エネルギーの供給もできる限り光で行う。
SLM 等の結線素子 光-電気変換素子 非線形電気回路	結線素子 光-電気非線形素子	結線素子 光-光非線形素子	光制御結線素子 光制御非線形素子 光学習素子(回路)	左記の素子に加え、光コンピュータ

SLM の結合荷重は、学習によって変更される。この方式は、発光素子、受光素子の応答速度のみにその演算速度が決定され、ネットワークの大きさに依存しない。ここでは、式(2)のニューロンの非線形処理は、非線形特性を持ったアンプ等の電気回路で行なっており、ニューロン数だけ電気回路を用意すればよいので、ニューロン間の結線ほどシステム構成上の問題とはならず、受光素子・発光素子の応答速度が十分に早ければ、有効な方式といえる。

この光ベクトル・マトリクス演算方式の延長線上の方式として、SLM 上の領域を分割して、多層ネットワークを構成する方式^{23,25)}や正負の荷重を構成する方式^{20,25)}がある。また、この構成方式の変形改良として、実際に、非対称光学系で構成するとシステム全体が大きくなってしまうためにストライプ状の発光素子や受光素子を用いる方式^{20,24)}や拡大・多重・局所結像系を利用し、光を自然な面の情報として取り扱える空間コーディング法^{21,22)}などがある。

ホログラム方式は、光ニューラルネットワークの代表的な構成例であり、多くの提案・実験がある。例えば、完全入力が角度多重露光されたホログラムに不完全入力を入れ、その相関を非線形光学素子を利用し、最大ピークだけを分離し、必要なパターンだけを得る連想記憶システム³³⁾や位相共役鏡を用いファブリ-ペロー共振器を構成し、フィードバック型の連想記憶システム³⁴⁾がある。さらに、誤差逆伝播学習を行うシステムも提案されている³⁵⁾。

4. ケーススタディー—三層光ニューラルネットワーク

4.1 システム構成

前節で述べたベクトル・マトリクス演算-学習方式のケーススタディとして、バックプロパゲーション学習則³⁾による三層構造の光ニューラルネットワークシステム(図5)について述べる。

図5の光ニューラルネットワークシステムは、「光シナプス荷重型」であり、ニューロン間の結合荷重のみ光で実現している。結合荷重記憶デバイスとして空間光変調管(MSLM)³⁶⁾を、ニューロン出力表示デバイスとして液晶テレビ(LCTV)を用いた。ニューロンの非線形性や学習による荷重変更信号の生成は、コンピュータを中心とする電子機器で行なっている。空間光変調管は四つの領域に分割され、入力層(**I**)・中間層(**H**)・出力層(**O**)の三層構造(図6(a))と正負の結合荷重を実現し

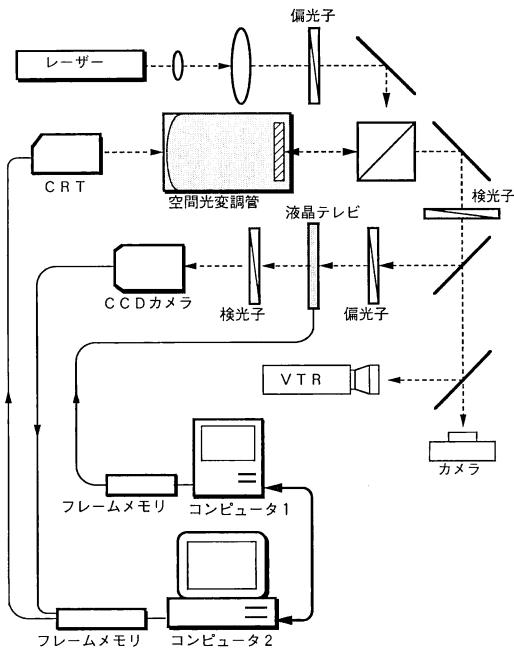
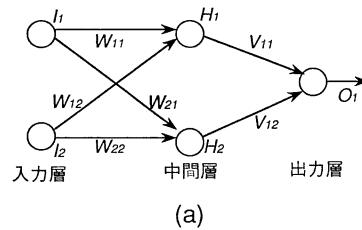
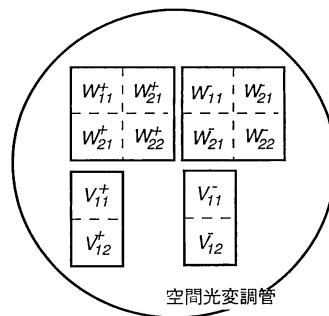


図5 光ニューラルネットワークシステム



(a)



(b)

図6 (a)三層構造のニューラルネットワーク、(b)空間光変調管上での結合荷重の配置

ている。その様子を図6(b)に示す。上の二つの領域は、入力層から中間層への正と負の結合(W^+ と W^-)、下は、中間層から出力層への正と負の結合(V^+ と V^-)である。液晶テレビは、ニューロン出力と逆伝播させる誤差を表示していて、その表示回数は、一つの学習パタ

ーンに対し、ニューロン出力の入力層から中間層と中間層から出力層、誤差逆伝播の正の誤差、負の誤差の4回である。CRTは、空間光変調管に入力する荷重変更信号を表示し、正の変化は正の荷重に、負の変化は負の荷重に表示している。コンピュータ1は、ニューロンの非線形処理と学習の計算、コンピュータ2は、コンピュータ1との通信により液晶テレビにニューロン出力を表示している。

4.2 学習実験例

ここでは、入力層、中間層、出力層の各々のニューロン数が2、2、1である三層構造のニューラルネットワークシステムにXOR演算の入出力関係を学習させた実験結果について示す。図7に初期の結合荷重(a)と177回学習時(b)の結合荷重を示す。ただし、1回の学習による荷重変化は、XORの四つの入出力関係を提示し、それらの荷重変化を足し合わせ、一度にMSLMに書き込んだものである。図8は、学習回数に対し、2乗誤差の総和の変化を示したものである。2乗誤差は、学習が100回あたりから、上下に激しく揺れながら小さくなっている。これにより、個々の荷重に対し正方向の変化と負方向の変化が現れ、図7(b)の正負の結合荷重が共に明るくなっている。

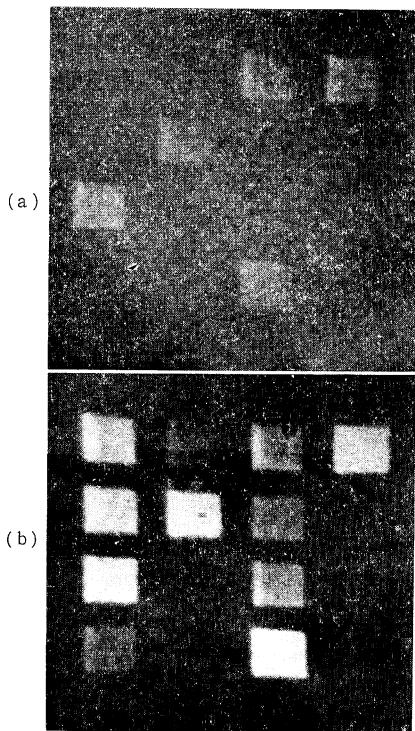


図7 初期結合荷重(a)と177回学習後の結合荷重(b)のMSLM出力

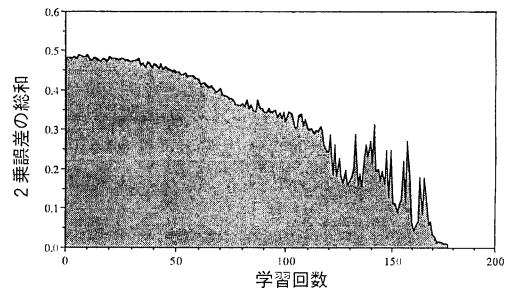


図8 2乗誤差の変化

このような荷重の変化方向に対し別の荷重を用意する方法は、学習中の振動が大きい場合、上限に達してしまう場合がある。これを解決する手段としては、学習係数の適正化やプリウエイト技術などがある。しかし、これらは学習する入出関係に依存してしまう。また、荷重に時間的効果（疲労、慣性）を与える方法や荷重の正の変化に対しては、正の荷重は増加、負の荷重は減少、負の変化に対しては、負の荷重を増加、正の荷重を減少させるといった方法もある。

4.3 光システムの発展—実装と大規模化

実用的な光システムを構成するためには、実験段階の定盤上のシステムに対し、大規模化や集積化を含む実装化、システムを動かすためのソフトウェア等も考えなくてはいけない。この三層光ニューラルネットワークシステムも実験システムであり、定盤上の技術である。また、正と負の結合荷重の問題は、本質的には解決されていない。

大規模な光ニューラルネットワークシステムは、一層の光ニューラルネットワークを1モジュールとして構成し、それらを多数結合することによって、構成することができる。図9は、1モジュールの光学系である³⁶⁾。三層光ニューラルネットワークシステムを構成するためには、四つの荷重結合に対し4モジュール必要である。1モジュールは、発光素子・結線素子・受光素子・光非線

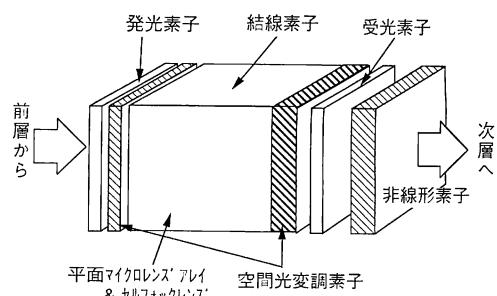


図9 光ニューラルネットワークの基本構成

表3 光ニューラルシステムの発展段階

	第一段階モデル実現	第二段階小型システム実現	第三段階実用システム実現
サイズ	$1 \times 1 \times 0.2 \text{ m}^3$	$20 \times 20 \times 10 \text{ mm}^3$	$10 \times 10 \times 5 \text{ mm}^3$
ニューロン数	~100	100~1,000	1,000~
必要な素子	レーザー レンズ (ハーフ)ミラー PDアレイ LEDアレイ 空間光変調素子 ホログラフィック素子	LDアレイ マイクロレンズアレイ 空間光変調素子 非線形素子 PDアレイ ホログラフィック素子	光ニューロチップ 光導波路型結線素子 3次元光接続素子 O(E)IC

形素子から構成される。前層からのニューロンの出力は、面型の発光素子アレイと空間光変調素子で実現され、セルフォックレンズと平板レンズアレイによる多重結像光学系で、透過型の空間光変調素子の結合荷重に多重像が結像される。荷重後の光は、受光素子で足し合わされ、光非線形素子を通過し、次層のモジュールに伝達される。また、学習による荷重変更信号は、別の同等なモジュールにより計算され、ニューロン出力と同じ発光素子から空間光変調素子に与えられる。

このモジュールによる光ニューラルネットワークシステムは、発展の第二段階である。直径3mmのセルフォックレンズと0.4mmピッチの平板マイクロレンズアレイを用いると1モジュールは $3 \times 3 \times 8 \text{ mm}^3$ 程度の大きさに21ニューロン程度実現できる³²⁾。例えば、25モジュール用意すれば、 $15 \times 15 \times 8 \text{ mm}^3$ に、525ニューロン実現できることになる。

この方式の延長線上には、集積化された光ニューロチップがあるが、ニューロンの動作などに光デバイスの独特な性質を直接使うと、システムの動作が限定されてしまうおそれがある。例えば、ホップフィールド型のネットワークを実現するためのチップやバックプロパゲーション学習を行うチップのようにハードウェアの交換によって、システムの性質を変えるやり方もあるだろう。しかし、汎用的な光ニューラルネットワークシステムを考える時、学習・非線形・ネットワーク構成がソフトウェアによって変更できる程度の柔軟性は必要であると思われる。そのため、図9に示したような単純なモジュールを多数配置し、個々のモジュールの動作やモジュール間の結線は、プログラムによって変更できる必要があるだろう。表3は上記の要件をまとめたものである。

5. おわりに

本稿では、ニューラルネットワークモデルの演算構造や機能から、その実現の技術的要請に対し、光学的実現の意義・整合性について述べた。さらに、光学的実現のために必要なデバイス機能と性能、そしてその具体的構成について述べた。

ニューラルネットワークの持つ「大規模並列処理性」や「学習・自己組織性」は、従来のコンピューターにはない、魅力的な特徴であるが、従来のコンピューターの得意とする数値計算等の大量な計算や高次の論理的処理には適していない。したがって、ニューラルネットワーク技術は、従来のコンピューター技術やAI技術と協調し合いながら、より高度なシステムへ進化していくべきものであろう。また、ニューラルネットワーク自体、光とは無関係に進化するであろうし、電子技術によるハード化も進むであろう³⁷⁾。この中、光が生き残っていくためには解決しなくてはいけない数多くの問題が存在し、電子技術との競争も避けられないであろう。

光ニューラルネットワーク実現のための課題は、「光デバイス技術」「集積・実装化技術」「光ニューラルネットワークモデルの進化」「応用を含むソフト技術」であり、個別の進歩と共に、これらは相互に依存し合いながら進歩する必要があるだろう。それらは、光の特徴を考慮したアーキテクチャー・アルゴリズムの開発であり、空間光変調素子をはじめとして、高い光配線能力を中心とした高密度集積光デバイスの開発である。そこには、従来技術にとらわれない発想と従来技術を有効に利用する知恵が必要であり、そのためには、「光デバイス」と「光システム」の密接な対話が必要である。

文 献

- 1) M. Minsky and S. Papert: *Perceptrons* (MIT Press, 1971).
- 2) 甘利俊一: 神経回路網の数理 (産業図書, 1978).
- 3) D. E. Rumelhart, J. L. McClelland and the PDP Research Group: *Parallel Distributed Processing* (MIT Press, 1986).
- 4) 合原一幸: ニューラルコンピューター (東京電気大出版, 1988).
- 5) 麻生秀樹: ニューラルネットワーク情報処理 (産業図書, 1988).
- 6) 福島邦彦: 神経回路網と自己組織化 (共立出版, 1979).
- 7) T. Kohonen: *Self-Organization and Associative Memory* (Springer-Verlag, 1984).
- 8) 黒川隆志: “空間光変調器と並列光演算”, 光学, **19** (1990) 417.
- 9) 谷田貝豊彦: “光コンピューター”, 光学, **14** (1985) 2-10.
- 10) 谷田貝豊彦: “光コンピューター研究の現状と将来”, 応用物理, **57** (1989) 1146.
- 11) T. Yatagai: “Optical space-variant logic gate array based on spatial encoding technique,” Opt. Lett., **11** (1986) 260.
- 12) 武田光夫: “光インターネクション”, 応用物理, **56** (1987) 361.
- 13) Y. Ichioka and J. Tanida: “Optical parallel logic gates using a shadow-casting system for optical digital computing,” Proc. IEEE, **72** (1984) 787.
- 14) 石原聰: 光コンピューター (岩波書店, 1989).
- 15) 谷田貝豊彦, ほか: 光コンピュータ読本 (サイエンス社, 1989).
- 16) 太田淳, 久間和生: “ニューロコンピュータ”, 光学, **17** (1988) 550.
- 17) 久間和生, ほか: “光ニューロデバイス”, 光学, **19** (1990) 2.
- 18) N. H. Farhat, D. Psaltis, A. Prata and E. Peak: “Optical implementation of hopfield model,” Appl. Opt., **24** (1985) 1469.
- 19) A. D. Fisher, R. C. Fukuda and J. N. Res: “Implementations of adaptive associative optical computing elements,” Appl. Opt., **26** (1987) 5061.
- 20) K. Kyuma, J. Ohta, K. Kojima and T. Nakayama: “Optical neural networks: system and device technologies,” Proc. SPIE, **963**, *Optical Computing 88* (1988) 475.
- 21) M. Ishikawa, N. Mukohzaka, H. Toyoda and Y. Suzuki: “Optical associatron: A simple model for optical associative memory,” Appl. Opt., **28** (1989) 291.
- 22) 石川正俊: “並列処理システムとしての光ニューロコンピューティング”, 光学, **19** (1990) 755.
- 23) N. H. Farhat: “Optoelectronic analogs of self-programming neural nets: architecture and methodologies for implementing fast stochastic learning by simulated annealing,” Appl. Opt., **26** (1987) 5093.
- 24) 久間和生: “光ニューロシステム”, bit, **21** (1989) 1502.
- 25) N. Kasama, Y. Hayasaki, T. Yatagai, M. Mori and S. Ishihara: “Experimental demonstration of optical three-layer neural network,” Jpn. J. Appl. Phys., **29** (1990) 1565.
- 26) J. J. Hopfield and D. W. Tank: “Neural computation of decisions in optimization problems,” Biol. Cybern., **52** (1985) 141.
- 27) R. P. Lippmann: “Neural network classifiers for speech recognition,” Lincoln Lab. J., **1** (1988) 107.
- 28) 渋川和雄: “ニューロコンピューターとロボットの知能化”, システム情報制御学会, システム/制御/情報, **34** (1990) 397.
- 29) S. Kirkpatrick, C. D. Gelatt, Jr. and M. P. Vecchi: “Optimization by simulated annealing,” Science, **220** (1983) 671.
- 30) T. Hara, M. Sugiyama and Y. Suzuki: “A spatial light modulator,” Adv. Electron Phys., **64B** (1985) 637.
- 31) 間多均: “液晶空間光変調素子”, 光学, **18** (1989) 350.
- 32) K. Hamanaka and T. Kishimoto: “Multiple imaging and multiple Fourier transformation using microlens arrays,” Jpn. J. Appl. Phys., **29** (1990) 1227.
- 33) A. Yariv, S. K. Kwong and K. Kyuma: “Demonstration of an all-optical associative holographic memory,” Appl. Phys. Lett., **48** (1986) 1114.
- 34) B. H. Soffer, G. J. Dunning, Y. Owechko and E. Marom: “Associative holographic memory with feedback using phase-conjugate mirrors,” Opt. Lett., **11** (1987) 18.
- 35) K. Wagner and D. Psaltis: “Multiple optical learning networks,” Appl. Opt., **26** (1987) 5061.
- 36) K. Hamanaka: “Optical bus interconnection system by using SELFOC lenses and planar microlens arrays,” Tech. Digest, International Topical Meeting on Optical Computing (1990).
- 37) 阿江忠: “VSLI ニューロコンピューターのアーキテクチャ”, bit, **21**, 10 (1990)-**22**, 6 (1991).