



ニューロコンピュータ

太田 淳・久間 和生

三菱電機(株)中央研究所 〒661 尼崎市塚口本町 8-1-1

(1988年7月8日受理)

Neurocomputer

Jun OHTA and Kazuo KYUMA

Central Research Laboratory, Mitsubishi Electric Corp.,
8-1-1, Tsukaguchi-Honmachi, Amagasaki 661

1. はじめに

最近、生物の脳の優れた情報処理能力を模倣したニューロコンピュータ（神経回路網模擬計算機）の研究が盛んである¹⁻⁴⁾。ニューロコンピュータは、多数のニューロン（神經細胞）と呼ばれる素子で構成されたネットワークの結合パターン（ニューロン間結合強度の時間的・空間的パターン）に着目した学習能力をもつ超並列コンピュータで、現行のコンピュータが苦手とする処理能力、たとえば音声、手書き文字、画像などのパターン認識や連想機能等を潜在的にもっている。逆に、数値演算のような精度を要求する分野には不向きであり、現行のコンピュータと相補関係にあるとも言える。

ニューロコンピュータの研究には、生物の脳のモデル化や学習アルゴリズムの研究、現行のコンピュータを用いた仮想ニューロシステムのロボティクスなどへの応用研究、LSIや光技術を用いた専用ハードウェアの研究がある⁵⁾。本稿では、まず代表的なニューラルネットワークモデルについて述べ、次にハードウェア化の例として筆者らが研究を進めている光技術を用いたニューロコンピュータの特長、原理、システム構成等について述べる^{4,5)}。最後に、今後の研究課題について述べる。

2. ニューラルネットワークモデル

2.1 ニューロンの機能とモデル

脳の中で情報処理を担っている基本素子はニューロン（神經細胞）である^{1,3)}。ニューロンは図1に示すように、多入力/1出力型の閾値特性をもつ飽和型非線形素

子とみなせる。すなわち、ニューロンはその膜電位（各ニューロンからの入力の重みづけ加算値） u_i がある一定値（閾値）以下のときは出力がゼロであるが、閾値以上になるとパルスを発生し他のニューロンに信号を送る。一つのニューロンはシナプスを介して $10^3 \sim 10^4$ もの他のニューロンと結合している。ニューロンを式でモデル化する場合、各ニューロンの出力は、その興奮の度合に応じて $-1 \sim +1$ のアナログ値を取りえるものとする。このとき i 番目のニューロンの出力状態 v_i は、これに接続されている N 個のニューロンの出力状態 v_j ($j=1, \dots, N$) とシナプス結合強度 T_{ij} との積 $T_{ij}v_j$ の総和、および自己固有の閾値 h_i を用いて次式で近似される。

$$v_i = g(\sum_j T_{ij}v_j - h_i) \quad (1)$$

ここで、 j 番目のニューロンが i 番目のニューロンに及ぼす程度を表わす T_{ij} は、その値が正のときに興奮性、負のときは抑制性シナプス結合に対応する。また、 g は単調飽和関数、たとえば sigmoid 関数で表わされ、

$$g(x) = \tanh(x/x_0) \quad (2)$$

で与えられる。 (2) 式において $x_0 \rightarrow 0$ とすれば $g(x)$ は符号関数（ハード・スレショルド）に漸近する。

2.2 Feedback モデル

図2に示されているように、ネットワークに含まれるニューロンが互いに接続されており、各ニューロンの出力信号がフィードバックして再び他のニューロンに入力するモデルを、ここでは feedback モデルと呼ぶことにする。このモデルを用いた代表例として、連想メモリを考える^{1,8)}。

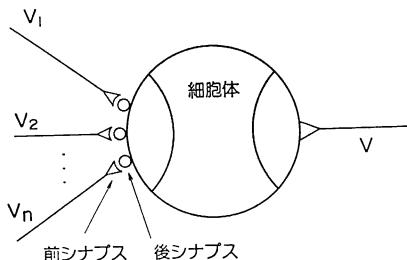


図 1 ニューロンのモデル

いま、 N 個のニューロンで構成されるネットワークにおいて、記憶する完全情報の数を M 、また、 m 番目の完全情報に対するニューロンの状態を 2 値 ($-1, 1$) の列ベクトル $v^{(m)}$ で表現する。次に、シナプス結合行列 T_{ij} を $v^{(m)}$ の外積により

$$T = \sum_m v^{(m)} v^{(m)\top}, \text{ただし } T_{ii} = 0 \quad (3)$$

で定義する。 \cdot は転置を表す。これは、分散多重記憶の一例で、他の代表例としてはホログラムがある。次に、この結合行列からの情報の取出しを考える。今、蓄積情報の一つ $v^{(p)}$ にハミング距離が近い $v^{(p0)}$ を入力する。このとき、

$$v^{(p)} v^{(p0)\top} = N \cos \theta \quad (4)$$

ここで θ は $v^{(p)}$ と $v^{(p0)}$ のなす角である。膜電位 u は

$$u = T v^{(p0)} \approx N v^{(p)} \cos \theta + \sum_{m \neq p0} v^{(m)} \{ v^{(m)\top} v^{(p0)} \} \quad (5)$$

となり、 θ が 0 に近く、蓄積情報ベクトル間の直交性が強ければ、(5)式 2 項の干渉項は第 1 項に比べて小さくなる。そこで(2)式の閾値処理をすれば、干渉項は消えて $v^{(p)}$ が取り出せる。

Hopfield はこのモデルをスピニ系と対応させて考え、記憶されたという現象がネットワークの安定状態、すなわち、次式で与えられるエネルギー E の極小値となることに対応することを示した⁸⁾。

$$E = -(1/2) \sum_{i,j} T_{ij} v_i v_j - \sum_j h_j v_j \quad (6)$$

したがって、記憶情報を完全情報と考えると、任意の不完全情報がニューロンの状態ベクトルとして入力されたとき、(2)式で与えられる非線形閾値処理およびフィードバック作用により、ニューロンの状態ベクトルは入力情報に最も類似した記憶情報に自発的に変化して、結局安定状態に達したときのベクトルを完全情報として出力することになる。しかし、連想機能を精度よく得るために、ニューロン数 N は記憶する情報の数 M に比べて十分大きいこと、また各記憶状態ベクトル間に直交性

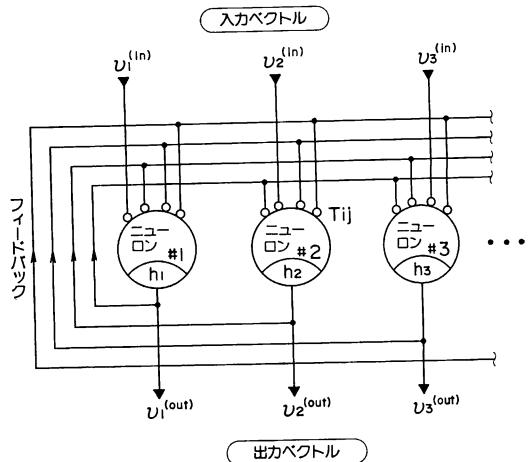


図 2 Feedback モデル

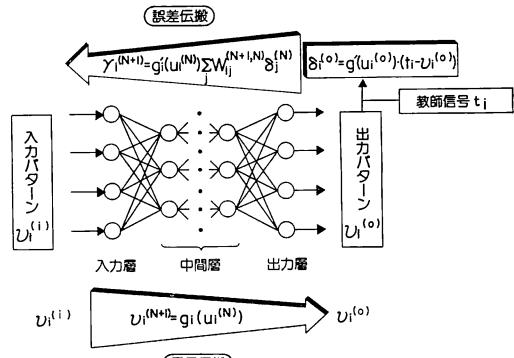


図 3 バックプロパゲーションモデル

が成り立つことが望ましい。これらの条件が満足されている場合でも、非線形処理によって、一般的にエネルギー関数 E は、 N 次元ベクトル空間において、記憶情報に対応する極小点（グローバルミニマと呼ぶ）のほかにも、望ましくないローカルミニマと呼ばれる多くの浅い谷底が存在して、初期条件によっては、これらのローカルミニマにトラップされてしまうことも示されている。

2.3 Feedforward モデル

本項では、feedforward モデルの一つであり最近注目を集めているバックプロパゲーション（逆伝播）モデル³⁾について述べる。このモデルは多層構造ニューラルネットワークにおける学習則を与えるものである。ここでの学習は教師有りの学習で、外界からの教師信号と出力信号との 2 乗誤差を最小にするように結合シナプス強度を変えていくことである。

図 3 に示すように、入力情報は入力層→中間層→出力層と一方向に進む (feedforward)。次層への出力信号は、

膜電位をたとえば sigmoid 関数で非線形処理した 0~1 のアナログ信号である。一方、学習は、誤差信号 $\gamma_i^{(k)}$ を用いて行なわれ、 $\gamma_i^{(k)}$ は次式のように再帰的に定義される。

$$\gamma_i^{(k+1)} = g'(u_i^{(k)}) \sum_j W_{ij}^{(k+1,k)} \gamma_j^{(k)} \quad (7)$$

ここで $g'(x)$ は $g(x)$ の微分を表わす。初期誤差信号としては、教師信号 t_i と出力層信号 $v_i^{(0)}$ を用いて

$$\gamma_i^{(0)} = g'(u_i^{(0)})(t_i - v_i^{(0)}) \quad (8)$$

とする。このように誤差信号が逆に出力層→中間層→入力層へと伝播するので、逆伝播モデルの呼び名がある。この誤差信号により結合シナプス強度の変化を

$$\Delta W_{ij}^{(k+1,k)}(t+1) = \epsilon \gamma_i^{(k)} v_j^{(k+1)} + \xi \Delta W_{ij}^{(k+1,k)}(t) \quad (9)$$

に従って更新する。ここで t は学習段階で、 ϵ は学習速度を決める定数、 ξ は学習速度を大きくしても安定に動作するために導入された安定化定数である。

このバックプロパゲーション法では、外界の構造が自発的に中間層に表現されるという興味深い現象が見られる。たとえば、漢字の認識において、学習後中間層に「へん」と「つくり」を認識するユニットが自発的に形成されることが報告されている⁹⁾。

3. 光技術によるハードウェア化の例 (光ニューロコンピュータ)

3.1 光ニューロコンピュータの特長

光ニューロコンピュータは、LSI を利用したものと比較して、次のような潜在的な利点をもっている。(1)光は空間並列性を有しているので、本質的に、完全並列コンピュータであるニューロコンピュータとの整合性が良い、すなわち、ホログラムや空間光変調器などを用いた空間光配線技術により、膨大な数のニューロン間の配線が可能である。また、ニューロン間の結合（シナプス結合）の強さを動的（ダイナミック）に制御・変更可能である。(2)光波は互いにクロストークをうけることなく伝播し、またその伝送容量も大きい。(3)超高速演算が期待される。

これらのなかでも、(1)の特長は以下に述べる理由により、重要である。ニューロコンピュータは、ニューロン数が多くなるとニューロン間配線数が天文學的に増大するという問題点がある。たとえば、 10^4 個のニューロンで構成されるネットワークでは、最大 10^8 個の配線数が必要になる。このような膨大な配線数は、現在の LSI 技術を用いても実現が困難である。また、学習機能をもつニューロコンピュータでは、シナプス結合強度が修正

信号によって可変の動的ネットワークが必要とされる。このような動的ネットワークを LSI で作製すると、集積されるニューロン数が急激に減少してしまう。これに対して、光技術を用いれば、このような膨大な数のニューロン間配線を、空間配線技術によって動的にかつ超高速に行なえる可能性がある。

3.2 ベクトル・行列乗算による光ニューロコンピュータ

Psaltis らは、2.2 項で述べた feedback 型モデルに基づいた連想メモリを光学的に実現することを提案し、その基礎実験を行なった¹⁰⁾。また、筆者らのグループでは、途中の浅い谷底（ローカルミニマ）にトラップされることなく記憶情報に対応した極小点に収束するよう、外部から雑音を加えてニューロンの状態を確率的に遷移させていく、一種の simulated annealing の考え方を導入した光連想メモリを試作した¹¹⁾。筆者らの試作したシステムを図 4 に示す。光学的な行列-ベクトル乗算器を基本構造に用いたニューロン数 $N=32$ 、記憶状態ベクトル $M=3$ のシステムである。ニューロンは、図 5 に示されているように、フォトダイオード (PD) と比較器および LED で構成されている。各ニューロンの興奮状態は、一列に並べられた LED の点滅状態に対応している。各発光素子からの出力、たとえば $v_i (i=1, 2, \dots, N)$ はレンズ系（図中では省略されている）を用いて扇状ビームとなるように波面変換され、行列 T に対応する光学マスクの j 列成分のみを一様に照射する。 T の (i, j) 成分 T_{ij} の大きさを光透過率として与えておくと、その出力光強度は $T_{ij} v_i$ に比例する。次に、この光学マスクからの出力光はレンズ系によって、今度はすべての i 行成分が受光素子アレイの一つに集光される。したがって、 i 番目の受光素子出力 u_i は、

$$u_i = \sum_j T_{ij} v_i \quad (10)$$

となり、受光素子出力に行列-ベクトル積が得られることがわかる。ここで重要なことは、光学的手法を用いると、上述の演算がきわめて高速に並列に実行されることである。PD アレイで光電変換された信号は、比較器で閾値処理され、LED アレイにフィードバックされる。この繰返し演算によって、不完全入力 A に対して、蓄積された完全情報 A, J, E のなかで最も類似した A を選択し、完全出力が得られる。

ただし、行列 T_{ij} は興奮性、抑制性シナプス結合に対応する、正負の成分を有する双極性である。したがって、実際のシステムでは T_{ij} の正成分のみを集めた $T_{ij}^{(+)}$ と負成分のみを集めた $T_{ij}^{(-)}$ に対応した 2 チャ

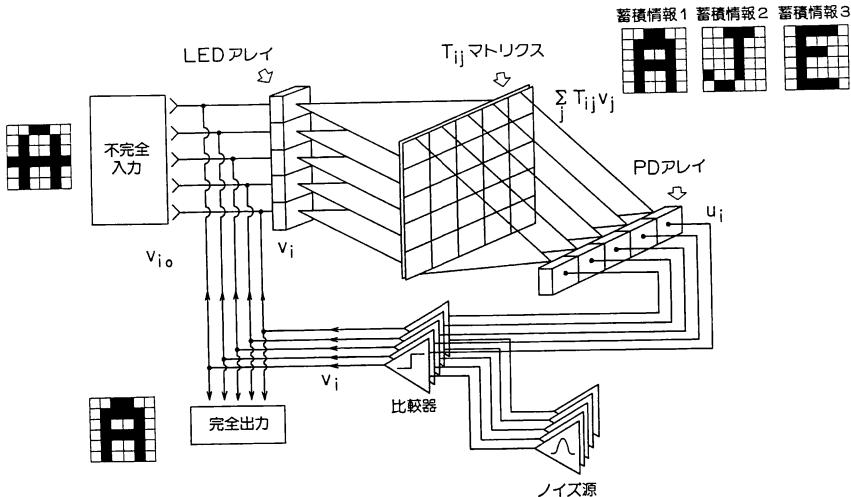


図 4 ニューラルネットワークモデルに基づいた光連想メモリ

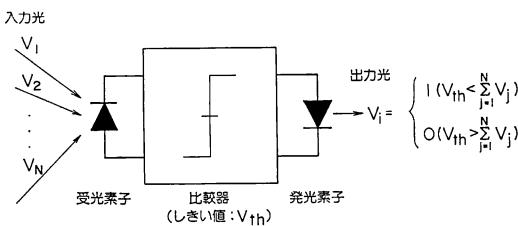


図 5 光電子ハイブリッド型ニューロンモデル

ンネルの光学系を構成している。

また、前述したローカルミニマにトラップされなく完全情報に相当するグローバルミニマに収束するよう、互いに相関のない雑音源を比較器の参照端子に与えている。その結果、図 6 に示すように、文字認識率が大幅に向上了した。

3.3 画像情報連想メモリ

Feedback モデルで画像情報などの 2 次元情報を処理するためには、(1) 2 次元画像情報を何らかの方法で 1 次元化する、(2) ホログラムによる相関演算を用いる、等の方法がある。ここでは前者の方法について述べる。

2 次元画像情報 (s 行 t 列) を列ベクトルを並べることにより N ビット長 ($N=s \times t$) の列ベクトルと考える。ベクトル-行列乗算は内積演算の繰返しであるから、ニューロン状態ベクトル (N ビット長) と結合シナプス行列 ($N \times N$ ビット長) の第 1 行成分のベクトル (N ビット長) との内積演算を行なえば膜電位 u_i の第 1 成分が求められる。この内積演算を結合シナプス行列の各行成分ベクトルごとに行なえば、膜電位 u_i が求められる。内積演算は図 7 に示す光学系で実現できる。

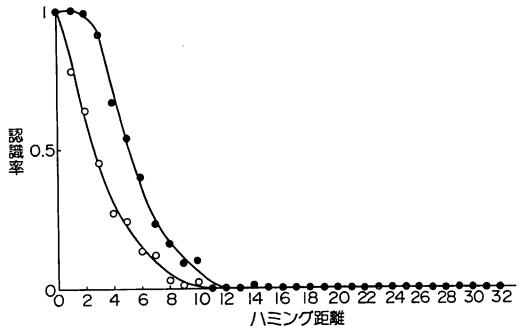


図 6 確率的手法の導入による連想精度の改善
○: ノイズを加えない場合, ●: ノイズを加えた場合

Jang らは、ホログラムに結合行列の各行成分を多重記録して上述のモデルを実現している¹²⁾。また、筆者らは液晶ディスプレイを用い時系列に各行成分を出現されることにより、上述のモデルを実現している¹³⁾。

これまでのモデルでは、蓄積情報と入力との内積演算によって完全情報を取り出していたが、ホログラフィによる連想メモリの場合相関演算によりこれを行なう。したがって、ホログラムが分散多重記憶された結合シナプスに相当する。ホログラフィによる連想メモリに関しては文献 14) に詳しい。

4. 今後の研究課題

4.1 動的ニューラルネットワーク（空間光変調素子）

実時間で、2 次元並列光情報のパターン（光強度、位相、偏光分布などのパターン）を変調する機能を有する

表1 種々の空間光変調素子の特性比較

素子	光学効果	コントラスト比	スイッチング速度(s)	アドレス方式	ピクセルサイズ	アレイサイズ
CCD-液晶	複屈折	10^2	10^{-1}	電気	$20\text{ }\mu\text{m}$	256×256
強誘電液晶	複屈折	10^2	$10^{-4} \sim 10^{-6}$	電気	$17\text{ }\mu\text{m}$	64×64
CCD-QCSE	吸収	10^1	10^{-10}	電気/光	$70\text{ }\mu\text{m}$	16×16
磁性体薄膜(ファラデー効果)	複屈折	10^3	10^{-7}	電気	$76\text{ }\mu\text{m}$	128×128
マイクロチャンネルプレート	複屈折	10^3	10^{-2}	光	10 lp/mm	$16\text{ mm}\phi$

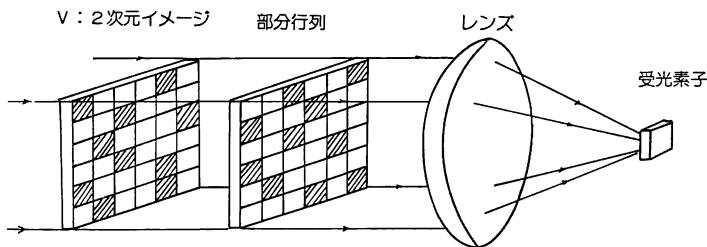


図7 光による内積演算の概念図

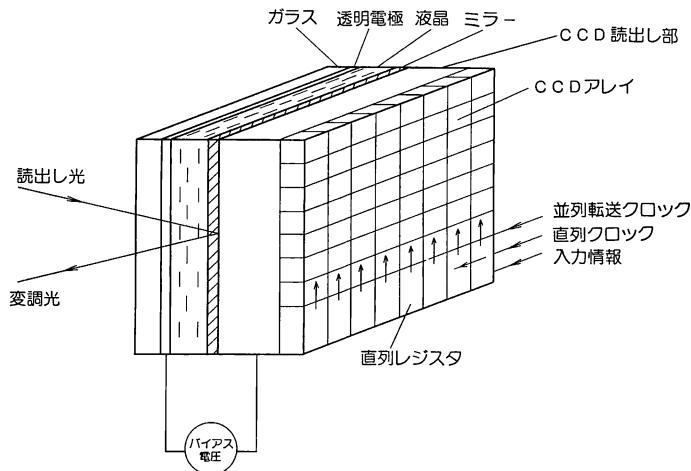


図8 CCD-液晶空間変調素子の構造模式図

空間光変調素子 (SLM) は、膨大な数のニューロン間をプログラマブルあるいは動的に配線する光インターネットワークション素子(光シナプス結合素子)として用いられている¹⁵⁾。ニューロコンピュータへの応用を前提とすると、解像度 1000×1000 、フレームレート $\sim 10\text{ kHz}$ 、コントラスト比 $100 : 1$ 程度の性能を有する SLM の開発が必要であろう。種々の SLM が報告されているが、解像度、応答速度、コスト、使いやすさなどの面で十分な性能のものが得られているとは言いがたい。表1は種々の空間光変調素子の諸特性を比較したものである。以下では、液晶を利用したもの、量子閉じ込めシャトルク効果を利用したもの、この2種類の SLM について述べる。

液晶ディスプレイは現在表示用デバイスとして広く用いられている。ここでは、液晶と CCD を組み合わせた SLM を取り上げる¹⁶⁾。図8はその構造模式図である。入力情報は CCD の直列レジスタと並列レジスタとの組合せにより CCD アレイ全面に書き込まれ、電圧分布を形成する。これにより、液晶透過光の偏光状態が空間的に制御されることになる。この偏光状態の変調を受けた読出し光は内部ミラーにより反射され検光子により光強度に変換される。現在 CCD のクロック 20 MHz , 256×256 アレイの素子が開発されている。この液晶 CCD-SLM は、通常のマトリクス電極型液晶 SLM より解像度の点で優れている。一般に用いられている液晶は応答

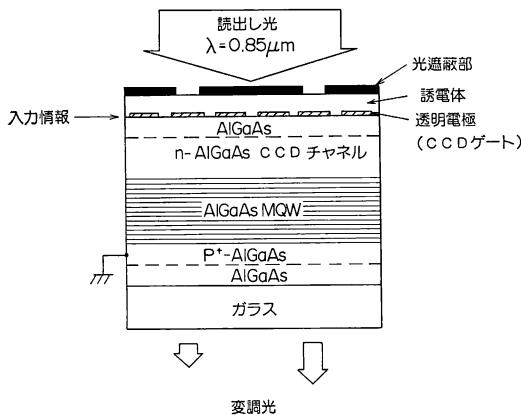


図9 CCD-QCSE 空間変調素子の構造模式図

速度が数十 ms と遅いが、近年開発された強誘電液晶は、~100 μs と比較的高速応答を示し、μs オーダーの応答速度も可能と言われている。さらに、双安定性を有することからマルチプレキシング駆動が可能である等、今後が期待される材料である。現在、64×64 アレイの素子が試作されている¹⁷⁾。

図9は、MQW（多重量子井戸）におけるQCSE（量子子閉じ込めシャトルク効果）を利用し、CCDの組み合わせたSLMである¹⁸⁾。MQWでは、量子井戸中に電子/正孔が閉じ込められているため強電界下でも励起子（電子正孔対）が解離にくく、電界印加による励起子吸収ピーク変化（シャトルク効果）を観測することができる。励起子吸収スペクトルは非常に鋭いためこの変化はかなり大きく現われ、MQW層透過光の電圧印加による光強度変調ができる。図9では、電圧印加を、前述の液晶CCD-SLM光変調素子と同じくCCDを用いて行なっている。現在、CCDのクロック500 kHz, 16×16アレイ、コントラスト比1.45:1の素子が作られている。このコントラスト比の値はニューロコンピュータへの応用には不十分であるが、QCSEを用いた他のデバイスでは8:1のコントラスト比が報告されており¹⁹⁾、この程度は改善されるであろう。応答速度に関しては、CCDのクロック1 GHz以上、QCSE自体は100 ps以下の応答速度があるとされており、超高速SLMとしての可能性は高い。

4.2 光閾値素子（光ニューロン）

ここでは、将来の全光ニューロコンピュータをめざして、現在筆者のグループで開発段階にある図10に示す全光方式の光閾値素子の例を紹介しよう。図の素子は²⁰⁾、10 nm程度の膜厚のGaAsとAlGaAs層とを交互に積層成長したMQW層の強い非線形光学効果を利用

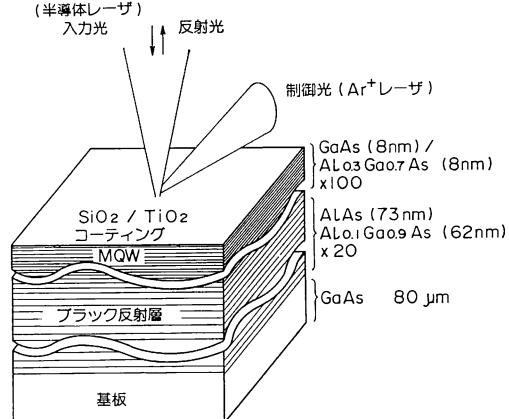


図10 光閾値素子

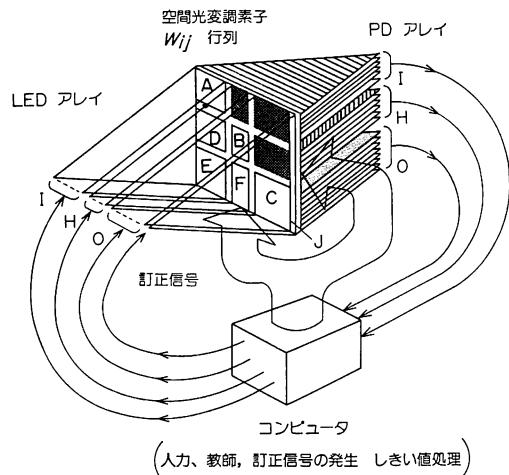


図11 Feedforward モデルに基づく学習コンピュータの概念図

用する。ここでいう非線形光学効果とは、入力光強度によって屈折率が変化する現象である。このMQW層を2枚の部分ミラーでサンドイッチ構造にした非線形光共振器を作る。この素子では、入力光強度でMQW層の屈折率をえると光共振器の特性が変わるので、プローブ光の出力状態をスイッチできる。応答速度も速く、ナノ秒以下で動作する。筆者のグループでは、直径3 μm、厚さ3 μmの非線形光共振器を作製して、入力パワー10 mW以下で動作する光閾値素子を得ている。この光共振器を、たとえば素子間隔10 μmで2次元アレイ化すると、1 cm²のウェハ状態に10⁶個の光閾値素子が得られる。

4.3 Feedforward モデルによる学習コンピュータ

2.3項で述べたfeedforwardモデルによる学習機能をもつ光ニューロコンピュータの実現も可能である。図11

に、ベクトル-行列乗算器を利用した3層構造のネットワークの構成例を示す²¹⁾。この場合にも、LEDの発光強度がニューロンの興奮状態に対応する。合計 N 個のLEDは、 N_I の I 素子群（入力層）、 N_O 個の O 素子群（出力層）、 N_H 個の H 素子群（中間層）で構成されている。SLM で実現されるシナプス行列 T_{ij} は九つの小行列からなる。 $A(N_I \times N_I)$ 、 $B(N_H \times N_H)$ 、 $C(N_O \times N_O)$ 小行列は、それぞれ I 層、H 層、O 層内の配線を行なうためのものである。また、 $D(N_I \times N_H)$ 小行列は I 層と H 層間の配線を、 $F(N_H \times N_O)$ 小行列は H 層と O 層間の配線を、 $E(N_I \times N_O)$ 小行列は I 層と O 層間の配線を行なう。LED およびシナプス行列の $(N+1)$ 列成分（小行列 J）により、各素子の閾値がグローバルに調整できるように工夫されている。学習則として、たとえばバックプロパゲーション法を用いるときには、D, F 以外の小行列は 0 行列となる。ここで、I 素子群の LED に入力信号を与えると、H 層を介して O 層から出力信号が得られる。この出力信号を閾値処理したのち、望ましい教師信号と比較して、その 2 乗誤差が小さくなるように I と H 層間 (B 小行列) および H と O 層間 (E 小行列) のシナプス結合強度を (9) 式に従って修正する。このような学習機能を有する光ニューラルネットワークは、今後パターン認識を始めとするさまざまな応用分野できわめて有力なハードウェアを提供するものと思われる。しかし、ハードウェア化の報告例は光アソシエイション²²⁾以外にはほとんどなく、SLM を始めとするキーデバイスの研究、光技術に適したアーキテクチャ、モデルの研究が必要であろう。

5. おわりに

これまで述べてきたように、光技術は電子技術と比較して、ニューロンコンピュータをハードウェア化する手段として潜在的に魅力のある特長を有している。しかし、電子技術が VLSI という形で、その能力の限界に近付いているのに対して、光技術はようやく単体のレーザー素子が気軽に使われ始めた時代である。電子の世界にたとえれば、トランジスタの時代に相当する。したがって、光の特長を十分利用したシステムを構築するには、優れ

たニューラルモデル、学習アルゴリズムや光ニューロコンピュータのアーキテクチャの研究はもちろんのこと、本稿でも紹介した光閾値素子アレイ、空間光変調素子などの新しい光素子や、それらの材料、プロセス技術に関する研究が不可欠であろう。

文 献

- 1) 甘利俊一：神経回路網の数理（産業図書、東京、1978）。
- 2) 甘利俊一：数理科学、286 (1987) 61。
- 3) D. E. Rumelhart, J. L. McClelland and the PDP Research Group: *Parallel Distributed Processing*, vol. I, II (MIT Press, Cambridge, 1986)。
- 4) Appl. Opt., 26, No. 23 (1987) ニューラルネットワーク特集号。
- 5) 曲井支朗、米津宏雄：応用物理、57 (1988) 668。
- 6) 久間和生：bit, 20, No. 2 (1988) 155。
- 7) 久間和生、田井修市：テレビジョン学会技術報告、12 (1988) 13。
- 8) J. J. Hopfield: Proc. Natl. Acad. Sci. USA, 79 (1982) 2554。
- 9) 森吉弘、横沢一彦、梅田三千雄：昭和 63 年電子情報通信学会春季全国大会 (1988) D-436。
- 10) N. H. Farhat, D. Psaltis, A. Prata and E. Paek: Appl. Opt., 24 (1985) 1469.
- 11) 太田淳、田井修市、黒田研一、追田真也、久間和生、浜中宏一：電子情報通信学会、OQE 87-174 (1988)。
- 12) J.-S. Jang, S.-W. Jung, S.-Y. Lee and S.-Y. Shin: Opt. Lett., 13 (1988) 248。
- 13) 追田真也、太田淳、久間和生：昭和 63 年秋季応用物理学、6p-M-9 (1988)。
- 14) 久間和生：応用物理、57 (1988) 1522。
- 15) 久間和生、田井修市、太田淳、高橋正信：電子情報通信学会、CPSY 88-14 (1988)。
- 16) U. Efron, P. O. Braatz, M. J. Little, R. N. Schwartz and J. Grinberg: Opt. Eng., 22 (1983) 682.
- 17) N. Collings, W. A. Crossland and D. G. Vass: *Spatial Light Modulators and Applications*, Tech. Digest Series, Vol. 8 (Optical Society of America, Washington, D.C., 1988) p. 142.
- 18) K. B. Nichols, B. E. Burke, B. F. Aull, W. D. Goodhue, B. F. Gramstorff, C. D. Hoyt and A. Vera: Appl. Phys. Lett., 52 (1988) 1116.
- 19) G. D. Boyd, D. A. B. Miller, D. S. Chemla, S. L. McCall, A. C. Gossard and J. H. English: Appl. Phys. Lett., 50 (1987) 1119.
- 20) J. Ohta, K. Kyuma, M. Oita, K. Mitsunaga, K. Hamanaka and T. Nakayama: Electron. Lett., 24 (1988) 216.
- 21) N. H. Farhat: Opt. Lett., 12 (1987) 448.
- 22) 石川正俊、向坂直久、豊田晴義、鈴木義二：テレビジョン学会技術報告、12 (1988) 31。