

特 集 3
研 究 解 説

フォトリフラクティブ光導波路を用いた光学習 可能ニューラルネットワークモデル

An Optically Learnable Neural Network Model
using Photorefractive Waveguides

的 場 修*・志 村 努*・黒 田 和 男*

Osamu MATOBA, Tsutomu SHIMURA, and Kazuo KURODA

学習能力を有する光ニューラルネットワークモデルの一つとして、フォトリフラクティブ光導波路を用いた光接続法をニューロン間の接続に適用したニューラルネットワークモデルを紹介する。フォトリフラクティブ光導波路を用いた光接続は、接続経路の形成と状態更新を光のみで行うことが可能である。学習アルゴリズムとして、局所的な信号のみで重みの修正量を計算することが可能なアルゴリズムを用いる。本稿では、実験結果に基づく重みの変化モデルを示し、モデルの学習能力を計算機実験で検証した結果を紹介する。

1. はじめに

近年、一瞬の判断や認識等の情報処理を実現するために、人や生物が行う情報処理機構を模倣したニューラルネットワークの研究が活発に行われている。ニューラルネットワークは学習可能な超並列分散処理系である。ニューロンと呼ばれる素子が多数相互結合し、接続には重みが存在する。この重みによって情報の記憶や多機能な処理を実行することができる。学習は、望ましい入出力関係が得られるように、ニューロン間の重みを適切に変化させることで実現される。ニューラルネットワークのハードウェア化では膨大な数の配線と可変な重みが必要なことから電子技術では大規模化が困難である。光ニューラルネットワーク¹⁾⁻⁷⁾は、光のもつ並列性を活かした光接続により、ニューロン間の大規模な信号接続を実現する試みである。光で学習を実行するためには、光信号によって重みを変化させることのできる光接続方法またはデバイスが必要不可欠である。これまでに提案されている光学習可能なニューラルネットワークモデルでは、フォトリフラクティブ効果を利用した体積ホログラムを用いる方法²⁾⁻⁵⁾、空間光変調素子を用いる方法⁶⁾⁻⁷⁾が提案されている。フォトリフラクティブ結晶を用いると、ホログラムの記録本数の理論的上限は、波長 $1\ \mu\text{m}$ の光を用いた場合に、 $1\ \text{cm}^3$ の結晶で 10^{10} 本となる。しかし、今のところそれ程高い記録密度は達成されていない。

筆者らは、新しいアプローチとして、フォトリフラクティブ (PR) 光導波路を用いる動的な光接続法を提案し




図1 PR光導波路の作製原理図。

た⁸⁾⁻¹²⁾。この方法では、図1に示すように、レーザー光をPR材料中に集光し、それを走査することによって光導波路を作製する。走査した部分では、PR効果によって屈折率が上昇した細長い領域が形成される。この領域は光導波路として働き、この光導波路をPR光導波路と呼んでいる。PR光導波路は、まず信号伝達経路として利用される。光導波路の屈折率分布は入射する光パワーに対して導波できる光パワーの比率を決定する。この比率を重みとして扱う。PR光導波路では、導波する信号光自体による屈折率変化によって構造の変化が生じ、比率を更新させることが可能である⁹⁾。本稿では、PR光導波路を用いた光接続法をニューロン間の接続に適用したニューラルネットワークモデル¹³⁾を紹介する。実験結果に基づく重みの変化モデルを構築した後、提案したネットワークモデルの学習能力を計算機実験により検証した結果を示す。

*東京大学生産技術研究所 第1部

2節ではPR光導波路を用いた光学習可能なニューラルネットワークについて紹介する。まずはじめに、ネットワーク構造を示し、その後並列処理に適した学習法について述べる。3節では、ニューロン間の重みつき接続として働くPR光導波路の信号光強度変化の統計的変動を測定した結果を示す。4節では、3節で得られた結果を基に接続重みの変化モデルを構築し、計算機実験により提案したネットワークモデルの学習能力を評価した結果を示す。

2. PR光導波路を用いた光学習可能なニューラルネットワークモデル

2.1 ネットワーク構造

階層型ニューラルネットワークにおいて必要な演算は、重みつき入力総和、閾値処理、非線形処理である。重みつき入力総和は、ベクトル-マトリックス乗算で計算される。この計算は光を用いることにより瞬時に実行される。図2(a)はN入力、1出力の場合の典型的な光学系を示している。この系では、入力信号ベクトルと重みベクトルの内積を実行する。重みは、マスクパターンの強度透過率で表される。強度透過率は負の値をもたないため、2チャンネルで差分をとることによって負の重みを実現している。出力信号は電気的に差分をとることによって得られるが、光で行うことも可能である。各マスクの透過率が変化するとニューロ

ンの出力値が変化する。学習では、入力信号に対する出力値が所望の値になるように重みを調節する。可変透過率を実現するマスクとして空間光変調器が用いられているが、現在の技術では、ネットワークの大規模化は困難である。

本稿で紹介する学習可能なニューラルネットワークモデル¹³⁾では、マスクパターンの代わりにPR光導波路を用いる。PR光導波路を用いた場合のN入力、1出力の配置での入力信号と重みベクトルの内積を計算する原理図を図2(b)に示す。PR光導波路は、PR材料中に光照射によって作製される。重みは、PR光導波路中を伝播する信号光の入射光パワーに対する出力光パワーの比(以下、強度透過率と呼ぶ)で表される。PR光導波路では、高強度の導波光(以下制御光と呼ぶ)によって内部構造を変化させることが可能である。これまでの研究成果からPR光導波路の強度透過率は、制御光の露光量に対して単調減少することがわかっている⁹⁾。学習では重みの値を増加、減少させることが必要なことから、1つのニューロン間の接続に2本のPR光導波路を用い、出力信号は各光導波路の出力の差分とする。この系では、図2(a)と同様に負の重みも表現することが可能になる。学習時には、重みの増加は負の符号を示す光導波路に制御光を照射することで達成される。逆に重みの減少は正の符号を示す光導波路に制御光を照射することで達成される。

2.2 学習法

ニューラルネットワークでは膨大な数の配線が必要であり、学習時には各配線の重みを調節する機能が必要である。学習可能なハードウェアを構築するためには、重みを修正するアルゴリズムとして並列処理に向けた方法が望ましい。並列処理に適した学習法として反ヘップ学習則(Anti-Hebbian Local Learning: ALLアルゴリズム)¹⁴⁾がある。ALLアルゴリズムは誤差逆伝播法(Backpropagation: BPアルゴリズム)¹⁵⁾を修正したものであるが、重みの修正量の計算を局所的な信号だけを用いて実行することができる。ここでは、ALLアルゴリズムの紹介と我々のモデルにおいて光学的実現が容易な方法に修正した点について述べる。




図2 入力ベクトルと重みベクトルの内積を計算する光学系、(a)マスクによる重み、(b)PR光導波路による重み。

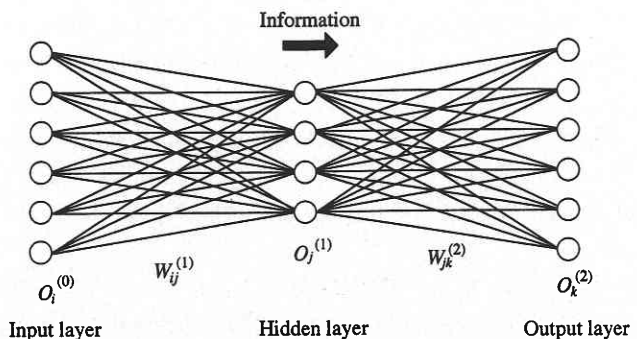


図3 3層階層型ニューラルネットワーク。

ALL アルゴリズムの適用は、図3に示す3層階層型ネットワークに限定される。(n+1) (n=0, 1) 層のj番目のニューロンの重みつき入力総和は、

$$s_j^{(n+1)} = \sum_i^{N^{(n)}} W_{ij}^{(n+1)} O_i^{(n)} \quad (1)$$

で与えられる。(1)式で、 $N^{(n)}$ はn層のニューロン数、 $W_{ij}^{(n+1)}$ は(n+1)層のj番目のニューロンとn層のi番目のニューロン間の重みである。 $O_i^{(n)}$ は、n層のi番目のニューロンの出力信号である。ただし、 $O^{(0)}$ は入力信号である。(n+1)層のj番目のニューロンの出力信号は、非線形関数fを用いて、

$$O_j^{(n+1)} = f_a(s_j^{(n+1)}), \quad (2)$$

$$f_a(x) = \frac{1 - \exp(-ax)}{1 + \exp(-ax)}, \quad (3)$$

で表させる。aは非線形関数の傾きを調節する正の定数である。出力層での現在の出力と教師信号との誤差関数は、(4)式のように対数関数を用いて表されるものとする。

$$E = \sum_k^{N^{(2)}} \left[(1 + t_k) \ln \frac{1 + t_k}{1 + O_k^{(2)}} + (1 - t_k) \ln \frac{1 - t_k}{1 - O_k^{(2)}} \right]. \quad (4)$$

t_k は出力層でのk番目のニューロンに対する教師信号である。

誤差関数Eを最小にするように各重みを修正する。ALL アルゴリズムでは、各層の重みの修正式は次式のように与えられる¹⁴⁾。

$$\Delta W_{jk}^{(2)} = \eta \delta_k O_j^{(1)}, \quad (5)$$

$$\Delta W_{ij}^{(1)} = \eta \alpha \gamma \frac{O_j^{(1)}}{1 - [O_j^{(1)}]^2} O_j^{(0)}, \quad (6)$$

$$\gamma = \sum_k^{N^{(2)}} \delta_k s_k^{(2)}. \quad (7)$$

ここで、 η は正の学習係数、 $\delta_k = a(t_k - O_k^{(2)})$ は出力層でのk番目のニューロンの誤差信号、 γ は教師信号と現在の出力信号の符号の一致度を表す量である。(5)、(6)式から重みの修正量は接続に直接関係するニューロンの局所的な信号のみを用いて計算できることがわかる。

次にALL アルゴリズムを我々のモデルにおいて光学的実現が容易な方法に修正した点について述べる。重みの修正は下記の条件で行う。(5)、(6)式から算出される重みの修正量が $|\Delta W| \geq \phi_{th}$ のときに一定の露光量 τ の制御光を正または負の符号を示す光導波路に照射する。この修正方法

では、アルゴリズムに従った厳密な重みの修正はできないが、システムが非常に簡略化される。また学習の反復とともに誤差が積み重なることもない。修正したアルゴリズムをS-ALL アルゴリズムと呼び、4.2で評価する。

3. PR 光導波路における信号光強度変化の不均一性の測定

3.1 実験方法

これまでの研究成果から、PR 光導波路では制御光の露光量の増加とともに信号光の出力強度が指数関数的に減少することがわかっている⁹⁾。ここでは、可変重みとして働くPR 光導波路のもつ統計的変動を実験で調べる。図4に光学系を示す。PR 材料としてニオブ酸リチウム(LN)結晶を用いる。PR 光導波路作製用光源として波長514.5 nmのアルゴンイオンレーザーを用いる。レーザー直後にある半波長板はPR 光導波路の作製中は取り除かれ、レーザー光は結晶中で常光線として伝播する。常光線を用いることで、誘起された屈折率変化の影響を最も小さくした状態で光導波路の作製を行うことができる。PR 光導波路の作製は、アルゴンイオンレーザーからの光をレンズL1で集光し、集光点を走査させることで行われる。結晶中での露光は離散的に行われ、移動中には露光は行わない。露光が行われる集光点の位置は結晶中で等間隔になるようにする。このように結晶中で離散的に露光を行うことにより良好な光導波路を作製することができる¹⁰⁾。作製条件としては、露光間隔と各点での露光量の2つである。

PR 光導波路の作製後、制御光と信号光を導波させる。制御光としてアルゴンイオンレーザー光を用い、信号光にはヘリウムネオンレーザー光を用いる。2つのレーザー光の偏光は屈折率変化量を大きく読み出すために、結晶中で異常光線となる方向の直線偏光とする。また、制御光は強

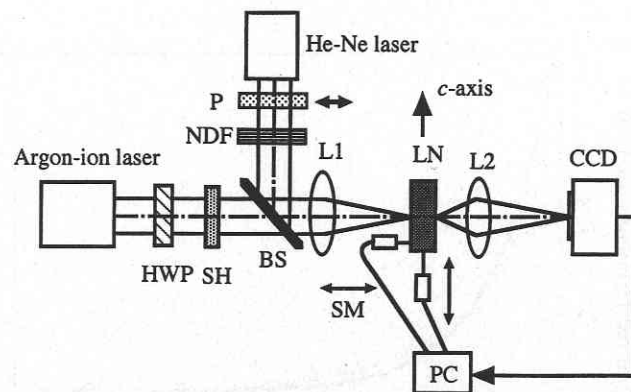


図4 光学系；HWP、半波長板；SH、シャッター；BS、ビームスプリッター；P、偏光子；NDF、NDフィルター；L1 and L2、レンズ；SM、移動ステージ；PC、パーソナルコンピュータ。半波長板は、PR 光導波路作製中は取り除かれる。

度が大きく、光導波路の屈折率を変化させることが可能である。信号光強度は屈折率変化が無視できる程度に十分小さい。制御光と信号光を導光させる場合には、レンズL1の焦点を結晶の前面にセットする。信号光の光導波路からの出力光強度分布をCCDセンサーで観測する。レンズL2によって結晶後面でのニアフィールドパターンをCCDセンサー上に結像させる。

制御光の照射と信号光強度の観測を繰り返し行う。制御光の露光量は、シャッターの開放時間とアルゴンイオンレーザー光の強度で制御される。信号光強度は、ニアフィールドパターンから算出される。ここで信号光出力強度は、光検出器に入射する全光強度と定義する。本稿では、検出器の大きさは作製直後のニアフィールドパターンにおいてピーク強度の $1/e$ より大きい強度をもつ範囲とする。実験で得られる全信号光出力強度は、作製直後の信号光出力強度によって規格化されている。

3.2 実験結果

7個のPR光導波路を作製し、信号光強度変化の統計的なばらつきを調べた。作製光強度は40 mW、離散露光の間隔を $45 \mu\text{m}$ とした。制御光強度として、2.5, 5, 10 mWの3つを用いた。制御光の1回の露光時間は $1/125$ 秒とした。制御光の全露光量に対する規格化信号光出力強度の変化の一例を図5に示す。実線は、

$$P(x) = \alpha + (1 - \alpha) \exp(-\beta x), \quad (8)$$

である。 P は規格化信号出力強度、 x は制御光の全露光量、 $\alpha=0.215$, $\beta=1.710(\text{mJ})^{-1}$ である。図5から規格化信号光出力強度は制御光の全露光量に対して指数関数的に減少することがわかる。7つのPR光導波路での結果を(8)式でフィッティングを行った結果、 α と β の平均値と分散は、それぞれ、 0.215 , 4.4×10^{-5} ; $1.831(\text{mJ})^{-1}$, $1.9 \times$




図5 制御光導波路の露光量に対する規格化信号光出力強度の変化

$10^{-3}(\text{mJ})^{-2}$ となった。

4. 学習結果

4.1 重みのモデル

2節で述べたように、ネットワークは正負の重みをもつ3層型構造とする。1つのニューロン間の接続には2本のPR光導波路を用いる。2本のPR光導波路の規格化信号光出力強度をそれぞれ、

$$P_i(x_i) = \alpha_i + (1 - \alpha_i) \exp(-\beta_i x_i), \quad i = p, n \quad (9)$$

とする。ここで、 p, n はそれぞれ正、負の符号を表す。(9)式で $P_i(x_i)$ は規格化信号光出力強度であり、 x_i は制御光の全露光量である。 α_i, β_i は3.2で求めた平均値と分散をもつ正規分布に従う確率変数である。(9)式を用いると重みは、(10)式のように与えられる。

$$W = P_p(x_p) - P_n(x_n). \quad (10)$$

(9), (10)式から重みのとりうる値は、 $[-1 + \alpha_p, 1 - \alpha_n]$ の範囲に制限されることがわかる。この重みの制限がネットワークの学習能力に及ぼす影響を4.2で調べる。

より現実に近いモデルを構築するためにノイズを考慮する。ここでは、ノイズは1回の制御光の露光量 τ に含まれるものとする。 τ は平均値が $1/50 \text{ mJ}$ (この値は制御光強度 2.5 mW で露光時間 $1/125$ 秒の時の値である)、分散が $(0.5/50)^2 (\text{mJ})^2$ の正規分布に従う確率変数とする。図6はノイズを含んだ系での規格化信号光出力強度の変化の一例を示す。

4.2 学習結果

学習問題として、線形ネットワークでは学習不可能な問




図6 ノイズを含んだ系での規格化信号光出力強度の変化(数値計算)。

表1 XOR問題.

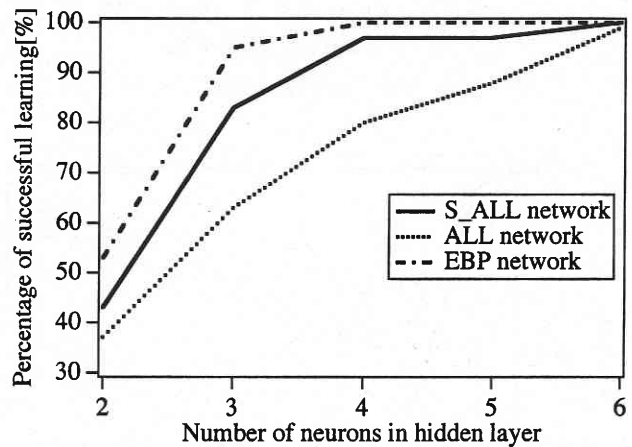
Input		Output
1	1	-1
1	-1	1
-1	1	1
-1	-1	-1

題のひとつである XOR 問題を取り扱う。XOR 問題は、表 1 に示される入出力関係を学習させる問題である。BP アルゴリズムを用いた 3 層階層型ネットワークモデルでは、重みのとる値に制限がない場合には、中間層のニューロン数が 2 個あれば、ネットワークは学習可能であることが示されている¹⁵⁾。提案するネットワークは S-ALL アルゴリズムで学習する。比較のために BP, ALL アルゴリズムで学習するネットワークも構築する。3 つのネットワークの名前をそれぞれ、S-ALL, BP, ALL ネットワークと呼ぶことにする。ノイズは BP, ALL ネットワークには存在しないものとする。3 つのモデルでは、各重みは(10)式で与えられ、重みのとりうる値は制限される。本実験では、3 つのネットワークモデルを用い、中間層のニューロン数を 2 個から 6 個まで変化させたネットワークにおいて、収束に要する学習の反復回数と学習の成功率を調べた。学習では、学習セット 4 パターンをネットワークに提示するのを 1 回と数える。ネットワークの学習は、(4)式で表される誤差 E が 1.3 以下となったとき収束したと判断する。この値は、各トレーニングセットに対する平均出力誤差が 0.2 になる値である。また E が 1.3 以下になる前に、学習の反復回数が 10,000 回に達した場合、ネットワークは学習に失敗したと判断する。初期重みとして、 $[-0.5, 0.5]$ の範囲でランダムな数値を与えた。ニューロン間の重みは、(10)式の差動重みで表現されるため、選ばれた初期重みの符号に従って、正負どちらか一方の光導波路の規格化信号光出力強度を 1.0 とした。例えば、初期重みが 0.2 の場合には、正の符号を表す光導波路の規格化信号光出力強度を 1.0 とし、負の符号を表す光導波路の規格化信号光出力強度を 0.8 とする。

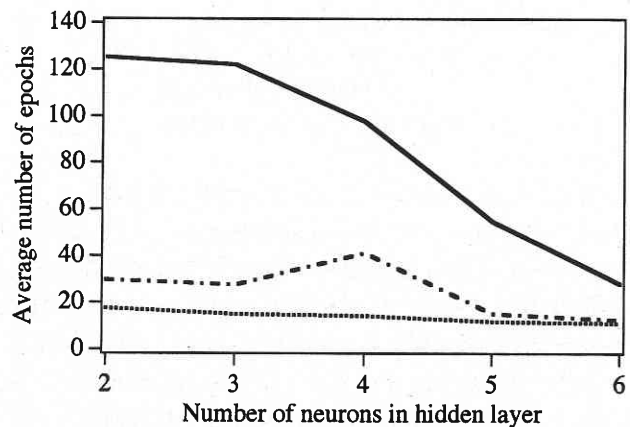
ALL, S-ALL ネットワークでは、重みの更新を行う閾値 ϕ_{th} を 0.01 とし、第 1-2 層間の重みは、10 回おきに修正することにする。3 つのネットワークモデルに対して最適な学習パラメータ η, a を選んだ結果を表 2 に示す。学習結果を図 7 に示す。図 7(a) は、中間層のニューロン数を 2 個から 6 個まで変化させた時の学習の成功率を表したグラフである。図 7(b) は、学習に要する反復回数を表したグ

表2 3つのネットワークに対するパラメータの最適値.

network	η	a
S-ALL	0.06	10
BP	0.02	4
ALL	0.06	10



(a)



(b)

図7 学習結果;(a)学習の成功率,(b)収束に要する学習の反復回数.

ラフである。図 7 に示した結果は、初期重みを 100 パターン準備し、その平均値を求めたものである。すべてのネットワークにおいて、中間層のニューロン数が少ない場合には、学習の収束回数、成功率ともに悪化しているのがわかる。これは重みのとる値を制限していることが原因である

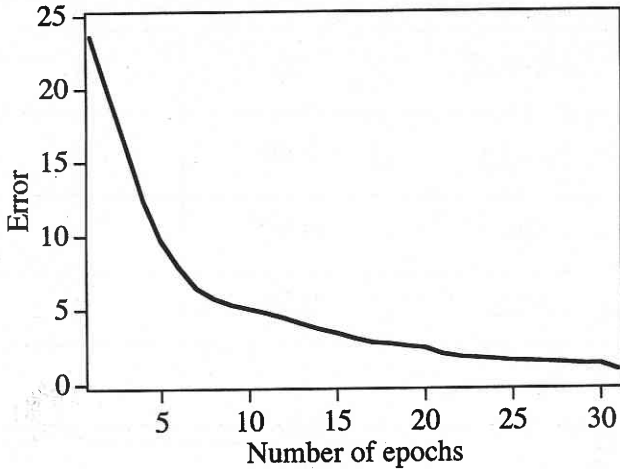


図8 誤差関数の値.

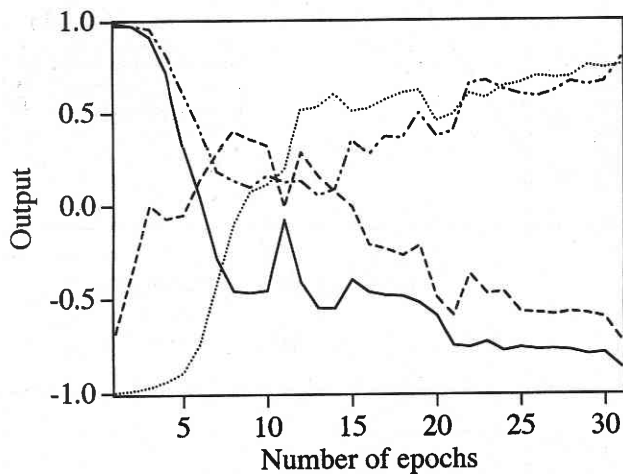



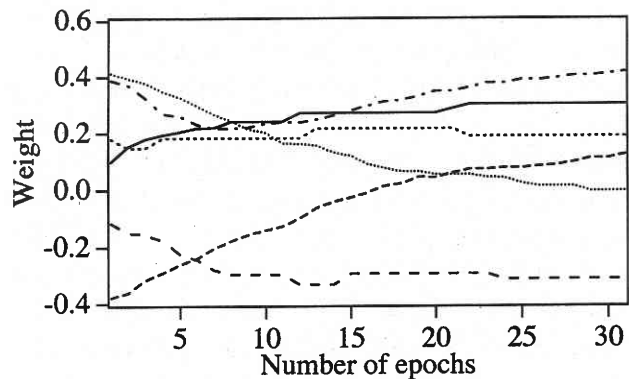
図9 出力ニューロンの出力値.

と考えられる。中間層のニューロン数が2個の場合は、S-ALL ネットワークでは約半分の初期重みパターンに対してネットワーク XOR 問題を学習することができなかった。中間層のニューロン数を6個とした場合には、S-ALL ネットワークは初期重み100パターンすべてに対して学習することができた。BP ネットワークと比較すると、S-ALL ネットワークは2.25倍以上の多くの反復回数を必要とすることがわかる。しかし、学習時に必要な計算量が S-ALL ネットワークでは BP ネットワークよりも少ないため、実質的な学習速度は、ネットワークの規模が大きくなるにしたがって S-ALL ネットワークの方が早くなるものと考えられる。また、S-ALL ネットワークは ALL ネットワークより学習の成功率が高く、ノイズにも強いシステムであることが期待できる。

中間層のニューロン数が6個の場合の S-ALL ネットワークでの学習の様子の一例を図8, 9, 10に示す。図8は、学習の反復回数に対する誤差関数の値を表したもので



(a)



(b)

図10 重みの変化:(a)入力層-中間層の重み(b)中間層層-出力層間の重み.

ある。学習回数が進むにつれて誤差が単調に減少していることがわかる。図9は各出力ニューロンの出力値の様子を示したものである。初期状態では教師信号とは符号の異なる出力が出ているものもあるが、学習終了時には所望の出力値が得られている。図10は重みの変化を示したものである。各重みは、飽和することもなく、学習が進行していることがわかる。

5. おわりに

PR 光導波路をニューロン間の接続に用いた場合の学習可能なニューラルネットワークモデルを紹介し、その学習能力を計算機実験で検証した結果について述べた。計算機実験の結果から、XOR 問題に対して初期重みパターンに依存せずに学習するためには、中間層のニューロン数が6個以上必要であることがわかった。このネットワークモデルでは、重みのとりうる値を制限するため、中間層のニューロン数を多く必要とした。しかしながら、信号伝播時、学習時ともに、各層上で並列に動作することが可能な

ネットワークを構築することが容易である。我々は多数の PR 光導波路を一度に作製する方法も提案している^{11), 12)}。今後は発光・受光素子 2 次元アレイと組み合わせることにより集積化されたニューラルネットワークの構築を目指す。また PR 光導波路は光ニューラルネットワークに限らず、様々な応用が期待される。(1996年12月20日受理)

参 考 文 献

- 1) D. Psaltis and N. Farhat, "Optical information processing based on an associative-memory model of neural nets with thresholding and feedback," *Opt. Lett.* **10**, 98-100 (1985).
- 2) D. Psaltis, D. Brady, X.-G. Gu, and S. Lin, "Holography in artificial neural networks," *Nature* **343**, 325-330 (1990).
- 3) K. Wagner and D. Psaltis, "Multilayer optical learning networks," *Appl. Opt.* **26**, 5061-5076 (1987).
- 4) J.H. Hong, S. Campbakk, and P. Yeh, "Optical pattern classifier with Perceptron learning," *Appl. Opt.* **29**, 3019-3025 (1990).
- 5) H.-Y.S. Li, Y. Qiao, and D. Psaltis, "Optical network for real-time face recognition," *Appl. Opt.* **32**, 5026-5035 (1993).
- 6) M. Ishikawa, N. Mukohzaka, H. Toyoda, and Y. Suzuki, "Optical associatron: a simple model for optical associative memory," *Appl. Opt.* **28**, 291-301 (1989).
- 7) H. Yoshinaga K. Kitayama, and T. Hara, "All-optical error-signal generation for backpropagation learning in optical multilayer neural networks," *Opt. Lett.* **14**, 202-204 (1989).
- 8) K. Itoh O. Matoba, and Y. Ichioka, "Fabrication experiment of photorefractive three-dimensional waveguides in lithium niobate," *Opt. Lett.* **19**, 652-654 (1994).
- 9) O. Matoba K. Ikezawa, K. Itoh, and Y. Ichioka, "Modification of photorefractive waveguides in lithium niobate by guided beam for optical dynamic interconnection," *Opt. Rev.* **2**, 438-443 (1995).
- 10) O. Matoba K. Itoh, and Y. Ichioka, "Nonuniform and off-axis structures for photorefractive waveguides in lithium niobate," *Opt. Eng.* **35**, 2175-2181 (1996).
- 11) O. Matoba K. Itoh, and Y. Ichioka, "Array of photorefractive waveguides for massively parallel optical interconnections in lithium niobate," *Opt. Lett.* **21**, 122-124 (1996).
- 12) O. Matoba K. Kuroda, and K. Itoh, "Optical fabrication of two-dimensional array of photorefractive waveguides in LiNbO₃: Fe," *Opt. Lett.* (submitted).
- 13) O. Matoba K. Itoh, and Y. Ichioka, "Optical learnable neural network using photorefractive waveguides," *Opt. Rev.* (submitted).
- 14) Y. Qiao and D. Psaltis, "Local learning algorithm for optical neural networks," *Appl. Opt.* **31**, 3285-3288 (1992).
- 15) D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation," *Parallel Distributed Processing: Explorations in the microstructure of cognition: 1. Foundations*, eds. D.E. Rumelhart, J.L. McClelland and the PDP Research Group (The MIT Press, Cambridge, 1986) 318-362.