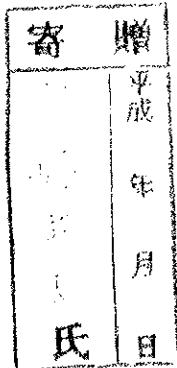


光学的並列アーキテクチャに関する研究

上野義之

早稲田大学



博士（工学）学位論文

光学的並列アーキテクチャに関する研究

筑波大学大学院博士過程

工学研究科 物理工学専攻

早崎 芳夫

平成 5年 3月

95003840

目 次

1. 序 論	1
1.1 研究の背景	1
1.2 研究の目的	3
1.3 研究の概要	4
2. 光コンピューティングシステム	8
2.1 はじめに	8
2.2 システム構成	10
2.3 システムの処理の流れ	13
2.4 まとめ	16
3. 光デジタルシステム	17
3.1 はじめに	17
3.2 空間可変論理演算法	18
3.3 空間符号化	21
3.3.1 空間符号化の原理	21
3.3.2 XORとANDの空間符号化の原理	25
3.3.3 空間光変調管による並列光演算	27
3.3.4 実験光学系	29
3.3.5 演算実験	30
3.3.6 考察	30
3.4 時間符号化	33
3.4.1 時間符号化の原理	33
3.4.2 時間符号化のシステム構成	36
3.4.3 演算実験	38
3.5 空間符号化と時間符号化の比較	39
3.6 まとめ	42
4. 光ニューラルシステム	45
4.1 はじめに	45

4.2 ニューラルネットワークモデル	48
4.2.1 基本モデル	48
4.2.2 相互結合型ネットワーク	51
4.2.3 階層型ネットワーク	51
4.3 学習	53
4.3.1 学習と自己組織化の基本モデル	53
4.3.2 誤差逆伝播学習	53
4.4 光学的実現法	55
4.4.1 光ニューラルモジュール	55
4.4.2 光ベクトル・マトリクス演算器	57
4.4.3 多重結像光学系	59
4.4.4 非線型素子の実現	61
4.4.5 荷重の表現法	62
4.4.6 荷重の更新法	67
4.4.7 反転入力重ね合わせ法	71
4.5 3層光ニューラルシステム	74
4.5.1 システム概要	74
4.5.2 システム構成	75
4.5.3 学習実験	77
4.5.4 考察	80
4.6 多重結像光ニューラルシステム	86
4.6.1 システム概要	86
4.6.2 2次元構造のニューラルネットワーク	87
4.6.3 実験システム	88
4.6.4 ニューラルネットワークの実験とその結果	88
4.6.5 システムの評価	93
4.6.6 考察	93
4.7 反転入力重ね合わせ法システム	96
4.7.1 システム概要	96
4.7.2 システム構成	96
4.7.3 液晶テレビによる反転パターンの発生	98
4.7.4 動作実験	99
4.7.5 考察	102
4.8 意味ネットワークシステム	105

4.8.1 システム概要	105
4.8.2 意味ネットワーク	105
4.8.3 連想による意味ネットワーク	108
4.8.4 実験システム	111
4.8.5 実験	115
4.8.6 考察	117
4.9 まとめ	118
 5. 画像認識システム	 126
5.1 はじめに	126
5.2 システム	126
5.2.1 システムの概要	126
5.2.2 システムの処理	127
5.3 システムの動作	130
5.3.1 シミュレーション	130
5.3.2 光学実験	135
5.4 まとめ	135
 6. 結論	 139
 謝辞	
 発表論文リスト	
 付録	
A 空間光変調管(MSLM: Microchannel Spatial Light Modulator)	
B 電子ビームアドレス型空間光変調管	
(EBSLM: Electron Beem Addressed Spatial Light Modulator)	
C BSO空間光変調素子(PROM: Pockels Readout Optical Modulator)	

第1章 序 論

1.1 研究の背景

近年、デジタルコンピュータ技術の発展に伴い、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更に高度な処理、膨大な量のデータの情報処理へと高まる一方でありますことを知らない。特に、時間的・空間的に情報が分布している音声や画像情報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への応用範囲は拡大している。さらに、コンピュータは、人と機械、人と社会、人と人の関係の変革を起ししている。機械は人から与えられる不完全で曖昧な情報を許容し、人は異なる形態の時間・空間に隔てた大量の情報をコンピュータを介し瞬時に取り入れることができる。

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、データ処理の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世代コンピュータや人工知能の研究は、このアプローチを選択した。もう一つのアプローチは多数の要素プロセッサと各プロセッサ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。この情報処理システムは、大量の計算や高度な論理的操作には適しているとは言えないが、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として、現在のデジタルコンピュータがある。デジタルコンピュータは誕生して40年ほどであり、その構成はvon Neumannが提案して以来、今日に至るまで大きな変化はない。これはデジタル的に情報を表現し、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。この様な逐次的処理を基本とするアルゴリズムは、必ず正解に行き着ける。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決では、おのずと限界が見える。そこで並列的な情報処理を考えるのは当然であるが、アルゴリズム的手法に対し、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。

このような背景のもと、コンピュータの開発の流れは、第二のアプローチである並列情報処理に向かっている。それは、单一の超大型のコンピューティングシステムではない。多くの異なるシステムを通じて結合し、全体を統合して動作する超並列分散システムであると考えられる。超並列分散システムは、多くの要素システムから構成される。その要素システムも並列情報処理に基づくもの

あると考えられ、1万から100万個ものプロセッサを格子状に並べたような超並列システムや生物の脳を模倣したニューラルシステムである。そこで、ハードウェア、ソフトウェアを含む新しい概念に基づくコンピュータ技術の開発の必要性が叫ばれている。

さらに、デジタルコンピュータの発展を支えているマイクロエレクトロニクス技術も論理素子の高速化、集積密度の向上により、論理素子間の配線遅延や過度の集積化による電磁ノイズに対する耐性の減少、さらに大規模集積回路の2次元的配線からくる配線領域の拡大と設計の困難さ等の問題が浮上してきている。これらの問題は、本質的な問題であり、既存技術の延長だけではもはや対処できないと考えられている。

光技術は、以上の問題を解決する手段の一つとして注目されている。情報媒体としての光は、膨大な情報伝送容量と超並列性と柔軟な接続性等の特徴を有していて、以下にその特徴をまとめるとする。

(1) 大規模並列性・高密度情報伝送能力

空間並列性による面情報の処理と波長多重化による大容量情報伝達を実現でき、自由空間中の情報伝達ができるため、3次元的な回路の構成が容易である。それ故に、配線の再構成も容易である。

(2) 高速・アナログ処理性

光は超高速であり、その速度は媒質のみに依存し、原理的に光デバイスは高速動作する。実際、ピコ秒程度の高速光スイッチングやフェムト秒のパルスの発生などが実現されている。

(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、電磁誘導ノイズは無い。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。

(4) 画像処理の直接処理

画像情報の並列入力、並列処理、並列出力が可能である。

光技術は、これらの特徴を利用したハードウェアをデジタルシステムやニューラルシステムに提供する。そして、光デジタルシステムや光ニューラルシステムを含む光コンピューティングシステムを構成することを可能とする。光コンピューティングを含む光情報処理は、Gaborのホログラムの原理[1]に始まるといえる。レーザー光とレンズのフーリエ変換作用によるコヒーレント光学系は、空間周波数フィルタリング[2]やホログラムによる画像修正、画像認識[3][4]などの研究に関して大きな成果を

上げ、一部実用化がなされている。これは光情報処理の第1世代といえ、光並列アナログ演算と呼ばれている。しかし、演算精度や適応性の不足、汎用性の少ない単機能性などの欠点があり、これらを解決するためにマトリクス演算法[5]や剩余演算[6]を光学的に実現する方法が提案された。その後、並列デジタル演算を導入した"lseコンピュータ"[7]が提案され、光並列演算法[8][9]の提案や並列アーキテクチャであるニューラルネットワークが導入された[10][11]。

現在、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、光コンピューティングシステムを含む光情報処理において、その並列情報処理及び大容量情報伝送に置ける潜在的能力は極めて高く、その姿は多数の単純な動作を行う演算素子と高密度な光インターフェクション[12]による大規模な並列処理システムが見えてくる。

1.2 研究の目的

情報処理システムの発展の流れは逐次処理から並列処理に向かっている。その流れの中、光技術はその特徴を生かして有用なハードウェアを提供し、光コンピューティングシステムを構築する。光コンピューティングシステムは、光デジタルシステムと光ニューラルシステムが光インターフェクションを介して高密度に接続されたシステムの姿を確立しつつある。光デジタルシステムは、多数のデータの2次元的集合体である画像に対し2次元的に配列した光論理ゲートによる基本演算の繰り返し操作とゲート間の接続により所望の処理を高速度・高精度に行うものである。光デジタルシステムを構築するためには、その基本演算である論理演算をどのように実行するということとその論理演算を接続してどのように論理回路を構成するかが重要である。

光ニューラルシステムは、膨大な数の単純なニューロンが、それらの間にさらに膨大な相互接続（インターフェクション）を有する生物の脳のハードウェアをモデル化したニューラルネットワーク[13][14]を光の高密度かつ可変配線技術により実現したものである。ニューラルシステムを構築する際は、多数のニューロンと相互接続をどのような手法・技術で実現するかが鍵となる。またニューラルネットワークは、デジタルコンピュータにおける論理とアルゴリズムによる計算を記述するプログラムのかわりに、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ことに大きな特徴を持つ。この学習と自己組織化は、ニューロン間の結合の強度（結合荷重）を外界（入力）に応じて、適応的に変化・更新することである。光インターフェクションは、光デジタルシステムや光ニューラルシステムの内部配線やシステム間の配線に使われる。光デジタルシステムや光ニューラルシステムの基本演算は、可変な光配線技術に支えられていて、システムの並列度が進むにつれてその高密度化は重要である。光インターフェクションによるシステム間の情報を

通信するスループットは電気バスのそれと比較してその性能は大きく向上する。

本研究の目的は大きく3つの目的に分けることができる。

第1の目的は、光の特徴を生かした光コンピューティングシステムのアーキテクチャの構築である。

光コンピューティングシステムは、光デジタルシステムと光ニューラルシステムの要素システムで構成され、それらは大容量の信号を高速に伝送する光インターフェクションによって結合されている。光デジタルシステムでは大容量の計算と高度の論理的処理、光ニューラルシステムでは曖昧性や適応性を有する処理と、個々の要素システムの特徴を生かした処理が行われ、システム全体としては、相互に情報を交換しあいながら処理が進んで行く。ここでは、個々の要素システムの動作とそれらをいかに効率的に効率良く統合するかが鍵である。

第2の目的は、光コンピューティングシステムの要素システムである光デジタルシステムの実証的な構築とその基本演算を行う並列光論理演算技術の確立である。実際、生体情報処理の最高の発展形態である人間の脳が、記号操作を用いて言語を使い、論理的推論により数学まで使っている。しかし、論理や記号操作による推論等は、デジタルシステムの得意とするところであり、ニューラル的ハードウェアよりも効率的な構成が可能であると考えられる。また、情報の表現がデジタルであるため、既存のコンピュータとの整合性も良いと考えられる。

第3の目的は、もう1つの要素システムである光ニューラルシステムの構築である。光技術とニューラルネットワークのハードウェア構成上の整合性の良さを考え、その整合性から得られる新しいアーキテクチャを提案し、実現することである。光ニューラルシステムの導入によって、光コンピューティングシステムは、ニューラルネットワークの持つ学習性や自己組織性、曖昧で不完全な処理等の既存の情報処理システムにはない特徴を獲得する。

1.3 研究の概要

本論文は、光デジタルシステムと光ニューラルシステムを統合した新しい光情報処理システムである光コンピューティングシステムと、その要素システムである光デジタルシステム及び光ニューラルシステムを構成する手法や技術について述べる。そして、いくつかの実証的なシステムを構成し、それらから得られる知見及び成果をまとめたものである。第2章以降は、以下に示す各章で構成されている。

第2章においては、光学的に並列処理を行う光コンピューティングシステムについて述べる。このシステムは、要素システムである光デジタルシステムと光ニューラルシステムが光インターフェクションを介し高密度に接続された情報処理システムである。これらの要素システムは、それぞれの特徴を生かして被処理データに対して独立あるいは協調して種々の操作を行う。

第3章においては、光コンピューティングシステムの要素システムである光デジタルシステムを構成する上で鍵となる並列光論理演算について述べる。特に、ここでは並列光論理演算法の一つである空間可変論理演算法[9]について、その原理と有効性について述べる。そこでは、谷田貝によって提案された空間符号化による方法に加え、時間符号化による方法を提案する。そして、それらの原理確認のため、具体的な実験システムを構成し演算実験を行った[15][16]。その演算実験や性能の解析を通して両方法を比較し利点と欠点を明確にし、それぞれ方法に応じたデバイスが必要であることを示す。

第4章においては、もう一つの要素システムである光ニューラルシステムについて述べる。ここでは、ニューラルネットワークの基本モデルとその光技術による表現手法と構成技術について述べ、ニューラルネットワークの光学的実現に適したモデルとアーキテクチャを提案する。それらは、光の本質的な性質である無極性より負値の表現が困難であるためのニューラルネットワークの荷重の表現法とその更新法[17][18]や反転入力重ね合わせ法[19]等の新しい実行モデルである。さらに、提案した表現法、モデル、アーキテクチャ等を検証するための実験ニューラルシステムについて示す。そこでは、今まで提案のみであった3層構造のニューラルネットワークの光学的実現[20]や多重結像系の利用した光ニューラルシステム[21]において学習実験を行い、学習の収束を確認したことを報告する。また、光学的実現に適した反転入力重ね合わせ法の実験的検証、意味ネットワーク等の知識処理を導入した光ニューラルシステム[22]についても述べる。さらに、光学実験や計算機シミュレーションを通して、光ニューラルシステムに用いられる荷重素子や入力素子のデバイスに対して要求される性能を考察した。

第5章においては、第2章で述べた光コンピューティングシステムの一つの実現例として、光デジタルによる入力画像の処理と光ニューラルシステムによる処理画像の判断を行うシステムについて述べる。光デジタルシステムでは並列光演算を組み合わせ用いて、入力画像の特徴抽出を得るために一つであるエッジ検出を行う。光ニューラルシステムでは、エッジ検出から特微量を算出して入力とし、そこから入力画像が何であるかを判断する。光デジタルシステムによる特徴抽出によって、計算の高速化、ニューラルシステムサイズの縮小化を行っている。また、判断にニューラルネットワークを用いているためアナログ的判断が可能であり、学習によって得られた知識より、多少の入力の変動に対しても正しい判断結果が得られた。

第6章においては、本論文を総括し、今後の研究課題について述べる。

参考文献

- [1] D. Gabor, "A new microscope principle," *Nature* **161**, 777 (1948).

- [2] L. J. Cutrona, E. N. Leith, C. J. Palermo, and L. J. Percello, "Optical data processing and filterinf systems," IRE Trans. Inform., Theory **IT-6**, 386-400 (1960).
- [3] D. Gabor, "Character Recognition by Holography," Nature London **206**, 422 (1965).
- [4] A. W. Lohmann and H. W. Werlich, "Holographic Production of Spatial Filters for Code Translation and Image Restoration," Phys. Lett. **A25**, 570 (1967).
- [5] R. P. Bocker, "Matrix multiplication using incoherent optical technique," Appl. Opt. **13**, 1670 (1974).
- [6] A. Tai, I. Cindrich, J. R. Fienup, and C. C. Aleksoff, "Optical residual arithmetic computer with programmable computation modules," Appl. Opt. **18**, 2812-2823 (1975).
- [7] D. H. Schfer and J. P. Strong III, "Tse computer," Proc. IEEE **65**, 129-138 (1977).
- [8] J. Tanida and Y. Ichioka, "Optical Logic Array Processor Using a Shadowgrams", J. Opt. Soc. Amer. **73**, 800-809 (1983) .
- [9] T.Yatagai, "Optical Space-Variant Logic Gate Array Based on Spatial Encoding Technique," Opt. Lett. **11**, 260-262 (1986).
- [10] N. Farhat and D. Psaltis, "New Approach to Optical Information Processing Based on Hopfield Model," J.Opt.Soc.Am. **A1**, 1296 (1984).
- [11] A. D. Fisher, C. L. Giles, and J. N. Lee, "Associative Processor Architectures for Optical Computing," J. Opt. Soc. Am. **A1**, 1337 (1984).
- [12] J. W. Goodman, "Optical interconnections for VLSI systems," Proc. IEEE **72**, 850-866 (1984).
- [13] 甘利俊一, "神経回路網の数理—脳の情報処理様式ー", 産業図書 (1978).
- [14] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, "Parallel Distributed Processing," (MIT Press,Cambridge,1986).
- [15] Y. Hayasaki, M. Ikeda, T. Yatagai, S. Ishihara and Y. Mitsuhasi, "Space-Variant Logic Operation Using Micro-Channel Spatial Light Modulator", SPIE **963**, Optical Computing 88 , 607 (1988).
- [16] 早崎,谷田貝, "並列光論理演算法の一方法," 第39回応用物理学会学術講演会, 講演予稿集3, 29p-B-1(習志野, 1992).
- [17] I. Tohyama, Y. Hayasaki, T. Yatagai, M. Mori, and S. Ishihara, "Renewal Method of Weight Matrix in Optical Neural Network," to be published in SPIE **1806**, (1992).
- [18] M. Mori, S. Ishihara, I. Tohyama, Y. Hayasaki, and T. Yatagai, "Optical neural networks

based on an electron-beam addressed spatial light modulator," SPIE 1812 Optical Computing and Neural networks, 57-63 (1992).

[19] 早崎,遠山,谷田貝,森,石原, "光ニューラルネットワークのための反転入力重ね合わせ法," 第53回応用物理学会学術講演会, 講演予稿集 3,(大阪, 1992).

[20] N. Kasama, Y. Hayasaki, T. Yatagai, M. Mori and S. Ishihara, "Experimental Demonstration of Optical Three-Layer Neural Network," Jpn. J. Appl. Phys. **29**, 1565 (1990).

[21] Y. Hayasaki, I. Tohyama, T. Yatagai, M. Mori, and S. Ishihara, "Optical Learning Neural Network Using Selfoc Microlens Array," Jpn. J. Appl. Phys. **31**, 1689-1693 (1992).

[22] Y. Hayasaki, N.Kasama, T. Yatagai, M. Mori, and S. Ishihara, "Optical Implementation of Semantic Networks Based on Association," Jpn. J. Appl. Phys. **29**, L1321-L1324 (1992).

第2章 光コンピューティングシステム

2.1 はじめに

光技術によって並列処理システムを構成することを考える場合、並列度と並列処理のレベルを考える必要がある。並列度とは同時に扱う処理の数であり、並列処理のレベルとは並列処理がゲートレベル、またはレジスタレベル（演算器レベル）、それともプロセッサレベルで実現されるかということである。光の特徴を考慮すると、並列度という観点からは高速で非常に高い情報伝送容量や接続の柔軟性があり、並列処理のレベル（処理単位の複雑性）という観点からは相互作用が小さく、波動性が強いため大きな非線型性を得るために大きなサイズと高いエネルギーが必要であるから、1つの処理単位は小さく、それらを大規模な配線でつなぐようなシステムの姿が見えてくる。光コンピューティングシステムは、並列度が大きく、並列処理のレベルがゲートレベルまたはレジスタレベルということである。プロセッサレベルを基本とする現在のコンピューターと比較すると、処理単位の複雑性から、処理単位間の配線の複雑性へ、情報処理の本質を変えるものである。光コンピューティングシステムの本質の1つがこの配線の複雑性にあるといえる。

並列処理の演算方式は、大きく分類して、アナログ演算方式とデジタル演算方式がある。元来、光は、1枚のレンズによる2次元フーリエ変換や2つの2次元データへの積和演算である2次元相関演算等のアナログ演算を高速に実現することができる[1]。しかし、デジタル演算方式と比較すると、処理の精度や柔軟性は乏しい。高精度や高い柔軟性を光コンピューティングシステムに求める場合、電子計算機のアナログからデジタルへの進歩と同様に、デジタル演算方式を導入することは当然である。デジタル演算方式とは、情報を離散的な信号で表現し、それらに対し各種の処理を行うものであり、通常、情報は0、1の2値で表され、ビット数の増大により高い精度の演算を実現できる。また、情報は常に離散的に表されているので、信号の誤差が後の処理に伝播することはない。処理は、2値で表現されたデータに対し論理演算を組み合わせることによって行われ、その組み合せを目的に応じ変更することによって高範囲の問題に対応できるという柔軟性を有する。したがって、光学的にデジタル演算方式を実現するためには、論理演算の実現する手法と並列処理のための論理演算を組み合わせる手法を確立することは不可欠である。

光コンピューティングシステムには、これらのデジタル処理の特徴に加えて、既存のデジタルシステムが苦手とする不完全で曖昧さを含む情報を総合的かつ直感的に有意な時間内に適切な処理する機能や必要な情報や知識を能動的に獲得し、具体例から一般的な知識を機能的実時間に学習する機能、多様な利用者や環境の変化に対してシステムが自ら適応する機能を可能にするような能力を要求される。これは、まさしく人間の情報処理であり、そのソフトウェアおよびハードウェアであるニューラ

ルネットワーク[2][3]を並列処理に取り入れることによって、今までの電子計算機の苦手な部分を補おうと考える。このニューラルネットワークは、簡単言うと、比較的単純な素子が膨大な配線で連結されているという構造を持つ、これは先に述べた光の特徴や光技術と高い整合性を有する。

本章では、光デジタルシステムと光ニューラルシステムを統合した光コンピューティングシステムの概念について説明する。光デジタルシステムと光ニューラルシステムは光インターフェクションを介して、情報をやり取りし、それぞれのシステムでの処理の特徴を生かし、分散的協調的に情報処理を行う。

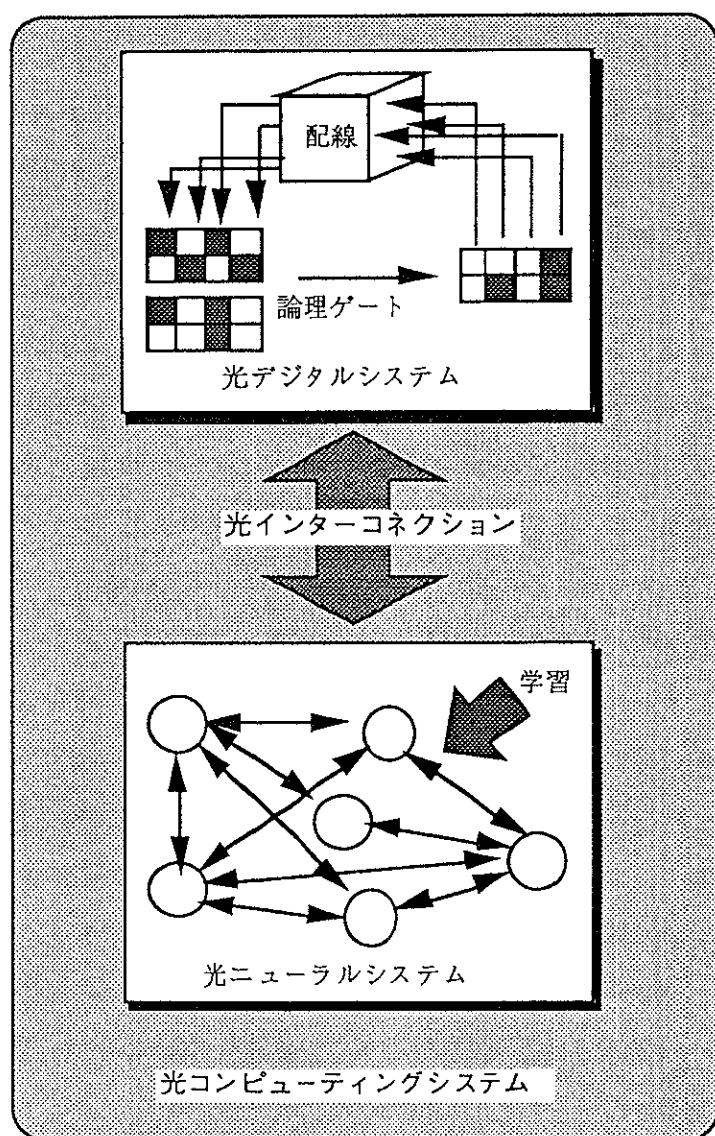


Fig.2.2.1 光コンピューティングシステムの構成概念

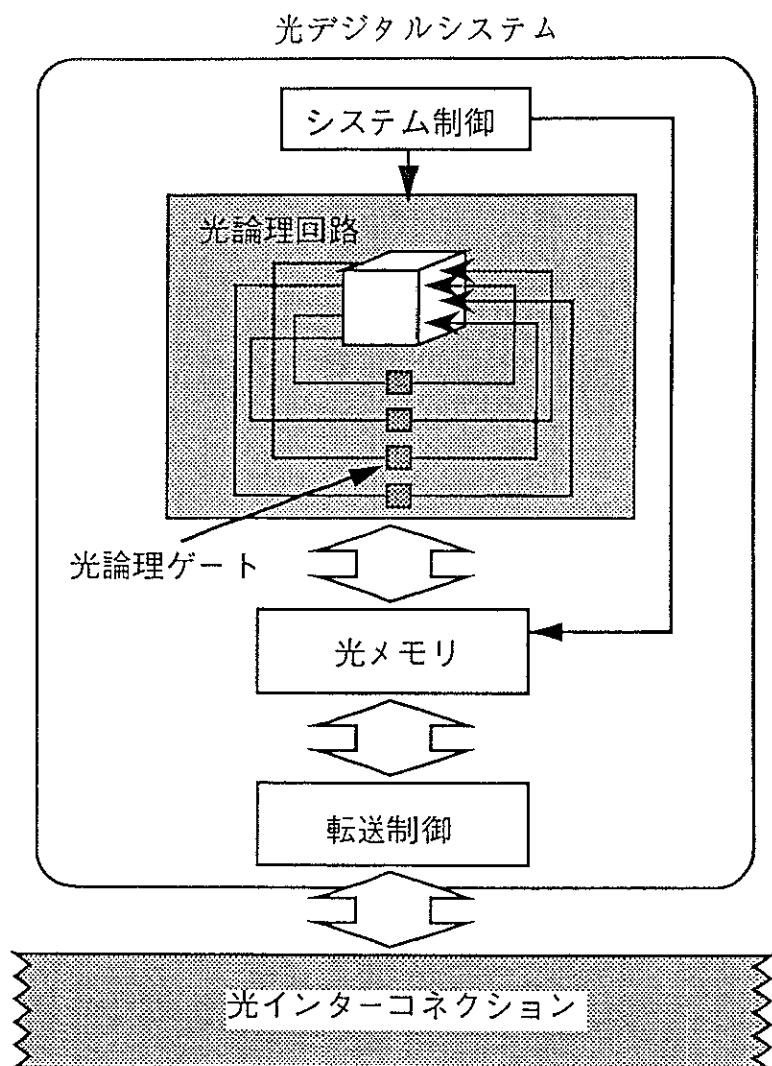
2.2 システム構成

Fig.2.2.1は、光コンピューティングシステムの基本的な構成の概念を示したものです。このシステムは、光デジタルシステムと光ニューラルシステムの要素システムがあり、それら要素システムの間は光インターフェクションによって相互に結合している。光デジタルシステムと光ニューラルシステムの間は情報がやり取りされ、光デジタルシステムから光ニューラルシステムへ、光ニューラルシステムから光デジタルシステムへと情報は流れる。また、光学的2次元情報が、画像入力システムから取り込まれ、光デジタルシステムまたは光ニューラルシステムに光インターフェクションを介し送られる。個々の光デジタルシステムや光ニューラルシステムにおいて、制御はシステムごとにおこなわれる。Fig.2.2.2はそれぞれを要素システムさらに詳しく示す図である。

光デジタルシステムは、光論理ゲート[4][5]を基本素子として構成されるゲートレベルの並列性を有するシステムであり、Fig.2.2.2(a)はシステムの基本構成である。光論理ゲートは、Fig.2.2.1に示されるような光学的な白黒の2値を有する一組の画像中の対応する画素に対し、2変数2値の論理関数を実現したものである。並列光論理演算は、その光論理ゲートを2次元的に配置し、2値画像に対して論理関数を実現する手法である。また、光論理ゲートは光インターフェクション[6]によって接続され、光論理回路を構成する。被処理データは論理回路中を繰り返し通過させることにより所望の処理を実行する。光デジタルシステムは、既存のコンピューターと同様にアルゴリズムに基づいたプログラミングによって動作し、各画素に対する論理演算の種類の選択と光インターフェクションの接続がプログラムによって変更される。光メモリは転送制御系を通して送られた被処理データやプログラムを格納し、光論理回路と並列にアクセスし、プログラムを実行する。

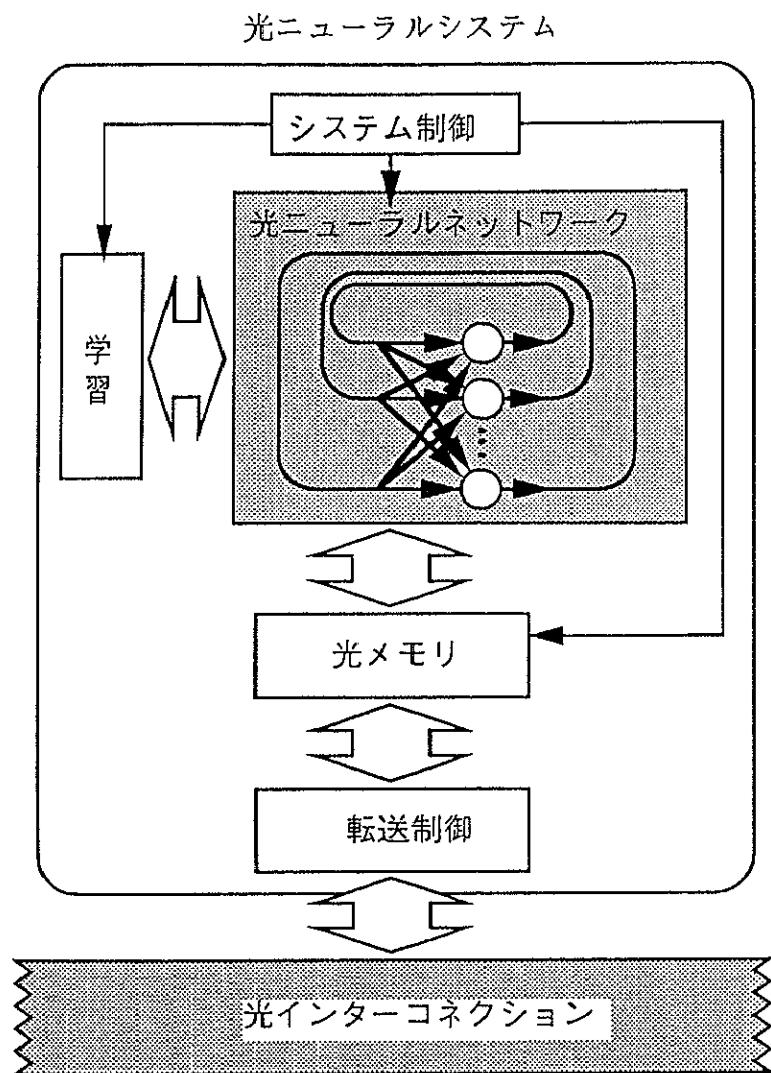
光ニューラルシステムは、基本演算単位である光ニューロンが密に結合している光ニューラルネットワークと学習や自己組織化[3][7]をコントロールする系、光メモリ、転送制御系からなる。その基本的構成をFig.2.2.2(b)に示す。光ニューロンは、入力情報を時間的・空間的に荷重し、それらを時間的・空間的に加算し、非線型処理を施すニューロンの機能を光学的に実現したものである。画像入力システムから得られる外界の状況や与えられる教師入力によって学習または自己組織化により動的に成長する。ニューラルネットワークの構造や学習の方法は用途に応じ選択される。例えば、連想メモリ[8]的使用に対しては密な結合のネットワーク、最適化問題やパターン認識に対しては疎な結合のネットワークを用いる。

実際のシステムは、Fig.2.2.2に示されるように、種々の周辺システムから構成されるが、本研究では、光デジタルシステムと光ニューラルシステムの中で最も重要であると考えられる光論理回路と光ニューラルネットワークの研究を行った。第3章では光論理回路の基本演算である空間可変論理演算について述べ、第4章では光ニューラルネットワークについて述べる。



(a)

Fig.2.2.2 光コンピューティングシステムの要素システム



(b)

Fig.2.2.2 光コンピューティングシステムの要素システム

2.3 システムの処理の流れ

光コンピューティングシステムは、光デジタルシステムと光ニューラルシステムで構成される。光デジタルシステムは、処理の対象となる入力情報の質があらかじめ解っていて、処理の手順（アルゴリズム）も明らかである場合に使われる。これは、現在のコンピュータによって行われている処理で、粒子や流体などの物理現象のシミュレーション、画像処理、画像や自然言語理解、知識工学のAI分野などである。光ニューラルシステムは、処理対象となる入力情報に多くの不完全性・曖昧性を含んでいたり、効率の良い処理の手順が解らない場合に用いられる。また、得られる結果も完全性を要求しないときに用いられ、近似解を素早く出す必要がある応用に対しては有効である。以上をTable 2.3.1にまとめる。

Table 2.3.1 光デジタルシステムと光ニューラルシステムの特徴

	光デジタルシステム	光ニューラルシステム
処理対象	性質が明らか	不完全性、曖昧性を含む
処理	手順が明らか 高精度を要求する	効率の良い手順を知らない 結果の完全性を要求しない
基本素子	論理ゲート	ニューロン
情報表現	デジタル	アナログ

光コンピューティングシステムにおいて、両システムが共同もしくは協調して処理を行う場合、画像等の入力情報に対して、その情報処理の流れは、大きく分けて以下のようないつつの流れがある。

- (a) 入力情報は、はじめに光デジタルシステムで処理され、その出力結果を光ニューラルシステムの入力情報として処理を行い、結果を得る流れ(Fig.2.3.1(a))。
- (b) 入力情報は、はじめに光ニューラルシステムで処理され、その出力結果を光デジタルシステムの入力情報として処理を行い、結果を得る流れ(Fig.2.3.1(b))。
- (c) 入力情報を光デジタルシステムと光ニューラルシステムに同時に投入し、それらの出力を統合して結果を得る流れ(Fig.2.3.1(c))。

(d) 光デジタルシステムと光ニューラルシステムが相互作用を行いながら処理を実行し、結果を得る流れ(Fig.2.3.1(d))。

(a)は、入力情報の性質があらかじめ知られていて、そこから必要な情報を得るために手順が明確であり、その得られた情報を総合的かつ適応的に処理する必要がある場合に用いられる。一般に画像情報などは多くの情報量を持っているため、高速な処理を行うためには、必要な情報だけを効率良く取り出す必要がある。情報量を減少させる有効な手順が解っている場合、光デジタルシステムに置いてその処理を行う。光デジタルシステムによって処理された出力データを光ニューラルシステムによつてさらに処理する必要がある場合は、入力情報のノイズ等によりデジタルシステムの出力が変動し、かつそれが解析的でない場合においても同様な結果が要求されたり、時間的に変化する入力情報に適応的に対応し処理を行う必要があるときなどに使われる。例えば、手書き文字認識や自然画像認識など、情報の特徴量を得るために処理を光デジタルシステムにおいて行い、その特徴量を光ニューラルシステムにおいて総合的に判断する。それに伴い新しい入力情報に対しても同様な処理を行うために、学習によって新しい入力情報に対する処理をシステムに形成する。

(b)は、(a)の処理とは対照的であり、入力情報が多数の連続値の組み合せによって表現されていて、その表現に曖昧さや不完全さがある中で、その情報の表現が持っている位相（近さ）を学習や自己組織によりシステム内に取り込むことによって、処理に利用する必要がある場合に、はじめに光ニューラルシステムにより処理が実行される。このようにして獲得した連続的な位相をもつ情報を光デジタルシステムは、過去のデータとの比較や記号操作的な処理を行い、離散的な位相を持つ情報に変換する。

(c)は、光デジタルシステムと光ニューラルシステムでの処理が並列的に行われる場合であり、入力情報を分配する処理、また、それぞれのシステムでの処理結果を同じレベルで統合する処理が重要である。

(d)は、(a),(b),(c)の処理に光デジタルシステムと光ニューラルシステムの相互作用が加わる場合である。例えば、光デジタルシステムが、光ニューラルシステムの学習のパラメータを変化させることや与える教師入力を選択すること、また、光ニューラルシステムが、光デジタルシステムのプログラミングを行うことである。

本研究ではこれらの4つの処理の流れのうち(a)について検討した。第5章では(a)の処理の流れを画像認識に適用し、その実験システムの構成について述べる。また、簡単な画像認識の実験結果について報告する。

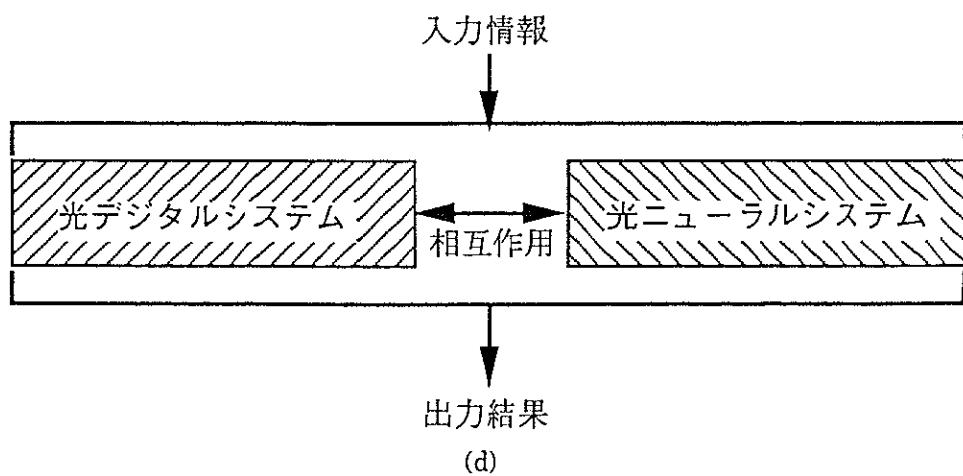
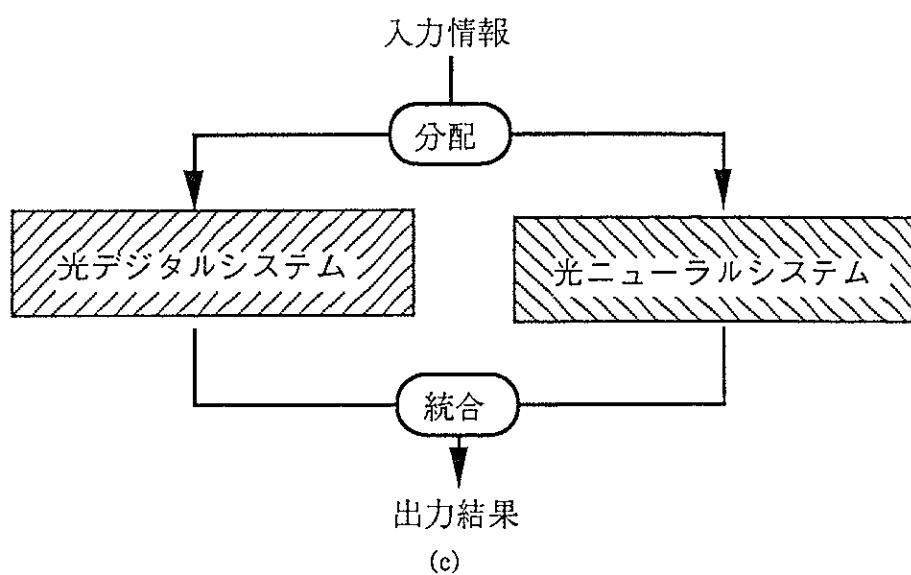
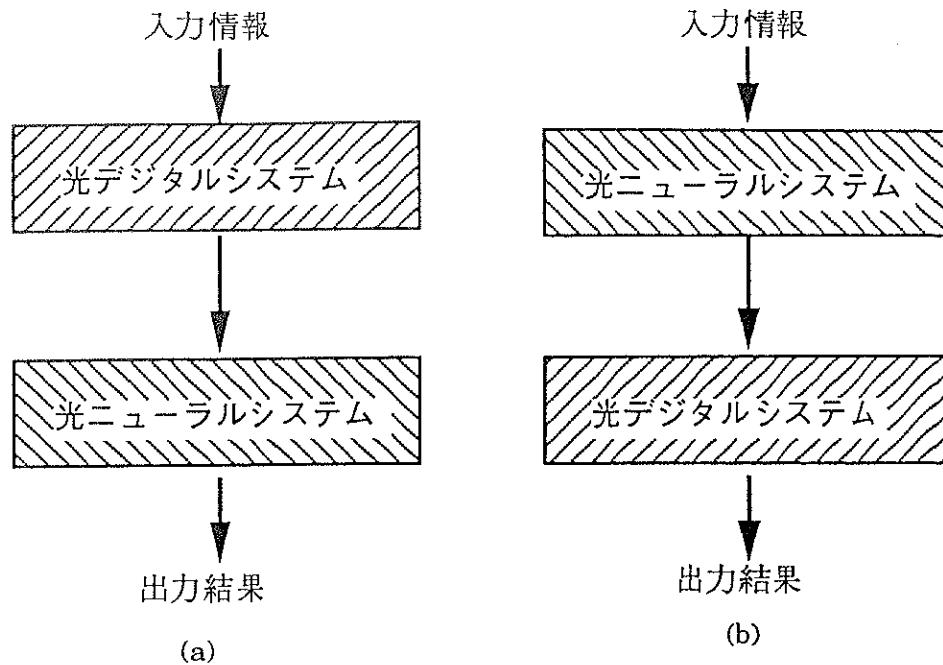


Fig.2.3.1 光コンピューティングシステムにおける処理の流れ

2.4 まとめ

光コンピューティングシステムは、光デジタルシステムと光ニューラルシステムを統合したシステムであり、それぞれの要素システムの特徴を利用して処理が進んでいく。光デジタルシステムはデジタル的に情報を表現し、明確なアルゴリズムに基づいて処理を行い、光ニューラルシステムは、アナログで情報を表現し、曖昧なデータに対し学習や自己組織化に基づく適応的な処理を行う。ここでは、これらの要素システムの基本的構成と特徴を述べ、それらを統合するために、いくつかの処理の流れについて検討した。本研究は、光デジタルシステムの並列演算技術とその光学的構成、光ニューラルシステム中の光ニューラルネットワークの光学的実現手法と構成技術等の確立であり、光コンピューティングシステム全体の中でどの部分が研究の中心であるかを示した。

参考文献

- [1] J. W. Goodman, "Introduction to Fourier Optics," (McGraw-Hill, 1968).
- [2] 甘利俊一, "神経回路網の数理—脳の情報処理様式—", 産業図書 (1978).
- [3] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, "Parallel Distributed Processing," (MIT Press, Cambridge, 1986).
- [4] J. Tanida and Y. Ichioka, "Optical Logic Array Processor Using a Shadowgrams", J. Opt. Soc. Amer. **73**, 800-809 (1983).
- [5] T. Yatagai, "Optical Space-Variant Logic Gate Array Based on Spatial Encoding Technique," Opt. Lett. **11**, 260-262 (1986).
- [6] J. W. Goodman, "Optical interconnections for VLSI systems," Proc. IEEE **72**, 850-866 (1984).
- [7] 福島邦彦, "神経回路網と自己組織化", 共立主版 (1979).
- [8] T. Kohonen, "Self-Organization and Associative Memory," (Springer-Verlag, New York, 1984).

第3章 光デジタルシステム

3.1 はじめに

光デジタルシステムとは、光により情報を離散的な信号として表し、その信号に対する種々の処理を実行する計算システムである。現在、電子計算機に代表される計算システムは、0, 1の2値で表現された情報に対して、ブール代数に基づく2値論理関数の組み合わせを基礎に構成されている。電子計算機が非常に発達したのは、情報を離散的に表現するが故に、計算精度が高く、回路構成が容易であり、処理に柔軟性があるためである。これらの特徴を有するデジタルシステムを光学的に実現する場合、既存の電子計算機と同様な処理の時間方向の展開だけでなく、光の並列及び高速処理性と高密度情報伝送性を利用して、処理を空間方向または周波数方向に展開する方法が考えられるため、光学的に情報を2値で表し、その2値情報に対し論理関数を並列に実行する方法を開発する必要がある。近年、多くの具体的なシステム提案され構成されている[1-8]。

光学的に論理演算を実行する方法は、数多く提案され、その実行方法は大きく分けて2つのタイプがある。1番目のタイプは、非線型光学素子の機能を利用するものであり、2番目のタイプは、入力データに対する非線型操作によるものである。前者は、液晶デバイス(LCD: Liquid Crystal Device)[9]や空間光変調管(MSLM: Microchannel Spatial Light Modulator)[10]、BSO空間光変調素子(PROM: Pockels Readout Optical Modulator)[11]、MQW素子[12]等の空間光変調素子や面入出力光融合素子(VSTEP: Vertical to Surface Transmmision Electrophotonic Effect Device)[13]等の光機能素子を利用する方式である。空間光変調素子は、デバイス中の光学非線型媒質への印加電圧や書込光を制御することにより、入力光の偏光状態や位相状態を変調した出力光を得る機能素子である。これらの空間光変調素子は、偏光子、検光子との組み合せによって強度変調を行うことができるため、素子の非線型応答を利用するといくつかの論理演算が実現でき、さらに素子を多段に接続することにより任意の論理演算が実現できる[14][15]。また、MSLMのように素子自体に演算機能を有し、印加電圧の組み合せにより論理演算を実行できる空間光変調素子もある。これらの方針における論理演算の性能は、空間光変調素子の解像度や応答速度などに制限される。

2番目のタイプは、入力データを画素ごとに分割し、各画素をその値に応じて変調するを行い、マスキングやフィルタリング処理により各種論理演算を実行するものである。 θ 変調法[16]は、画素を格子の方向・周期の格子に変調することにより、並列光論理演算法[17][18]は、画素を特定の空間符号化パターンに変換することにより、それぞれ並列論理演算を実行する。これらの論理演算法は、入力データの値に応じた符号化(encoding)や出力データの復号(decoding)が必要となる。

また、論理回路を構成するためにはシフトなどの近傍画素間の演算が必要であり、数値演算やパターン処理などの目的に応じ、回路を設計する必要がある。回路設計法としてレギュラー接続[19]や記号置換論理[20]、光アレイロジック[21]、計算折り紙[5]、画像論理代数[8]などがある。さらに、実用レベルまで高めるためには、光学定盤上の技術を安定かつ信頼性高く実装する技術が必要であり、3次元的に光集積回路を実現する技術が開発され、積層プレーナー光学系[22]やプレーナー光学系[23]、OBIS(Optical bus interconnection system)[24]等がある。

本章では、光デジタルシステム構築に必要な並列光論理演算の一つである空間可変並列演算法の原理を説明し、その光学的実現について述べる。空間可変論理演算法は、谷田、一岡らによって提案された並列光論理演算法[17]を谷田貝が空間可変型の演算法に拡張したものである[18]。そこでは、空間符号化の方法が提案され、その後、干渉計やホログラムによる光学的実現がなされた[25]。ここでは、空間可変並列演算法の空間符号化の光学的構成法の一つである空間光変調管の非線型機能を利用した方法[26]について述べる。また、空間可変論理演算法の実行法として、時間符号化による方法を考案したので、その原理について述べ、その原理確認のための実験システムについて示す。

3.2 空間可変論理演算法

空間可変論理演算法は、並列論理演算を光学的に実現する技術の1つであり、異なる論理演算を同時に実行できる特徴を有する。まずその原理について説明する。

Table3.2.1 2変数2値論理演算

INPUT	OUTPUT																
	a	b	ab	a ̄ b	a	̄ a ̄ b	b	a⊕b	a+b	̄ a ̄ b	̄ a⊕b	̄ b	a+b	̄ a	̄ a+b	̄ a+b	1
0 0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
0 1	0	0	0	0	1	1	1	1	1	0	0	0	0	1	1	1	1
1 0	0	0	1	1	0	0	1	1	1	0	0	1	1	0	0	1	1
1 1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	1

	AND	XOR	OR	NOR	EQU	NAND

処理対象は、2値（0または1）の情報を持つ、 $N \times N$ (N は自然数) の矩形領域（画素と呼ぶ）で構成される2値離散画像である。ここで、その画像をAとし、その (i,j) 画素の値を a_{ij} ($i, j = 1, 2, \dots, N$) で表すと、画像Aは、論理変数 a_{ij} の集合体と考えることができる。また、別の画像Bを考え、その (i,j) 画素の論理変数を b_{ij} ($i, j = 1, 2, \dots, N$) とする。並列論理演算は、これら2つの画像AとBの同一位

置にある画素 a_{ij} と b_{ij} を入力変数として、論理演算を実行した結果、出力 c_{ij} が得られる過程である。各画素の出力 c_{ij} の集合体は、画像Cを構成する。各画素に対する論理演算は、Table3.2.1に示す2変数2値論理演算の中から任意に選択される。適用される論理演算は各画素異なり、(i,j)画素の論理演算を f_{ij} とし、論理演算の集合体をFとする。この並列論理演算法は、同じ平面内で異なる演算を実行できることから、空間可変(space-variant)と呼ばれ、画像の空間的な位置の変化の対し出力が異なる。よって、この演算法は空間可変論理演算と呼ばれ、多数の入力データに対し多数の命令を介し演算が実行されるのでMIMD形式の演算法である。以上の演算を数式で表すと、次のようになる。

$$c_{ij} = f_{ij}(a_{ij}, b_{ij}) \quad i, j = 1, 2, \dots, N \quad (3.2.1)$$

ここで、 $f_{ij}(a, b)$ は a, b を入力変数とする(i,j)画素の論理関数である。また、画像形式で書くと、

$$C = F(A, B) \quad (3.2.2)$$

となり、入力画像AとBに対し論理演算の集合体Fを実行し、出力画像Cが得られることを示している。

Fig.3.2.1はその概念図であり、2入力1出力の論理演算が2次元平面上に並んでいることを示す。

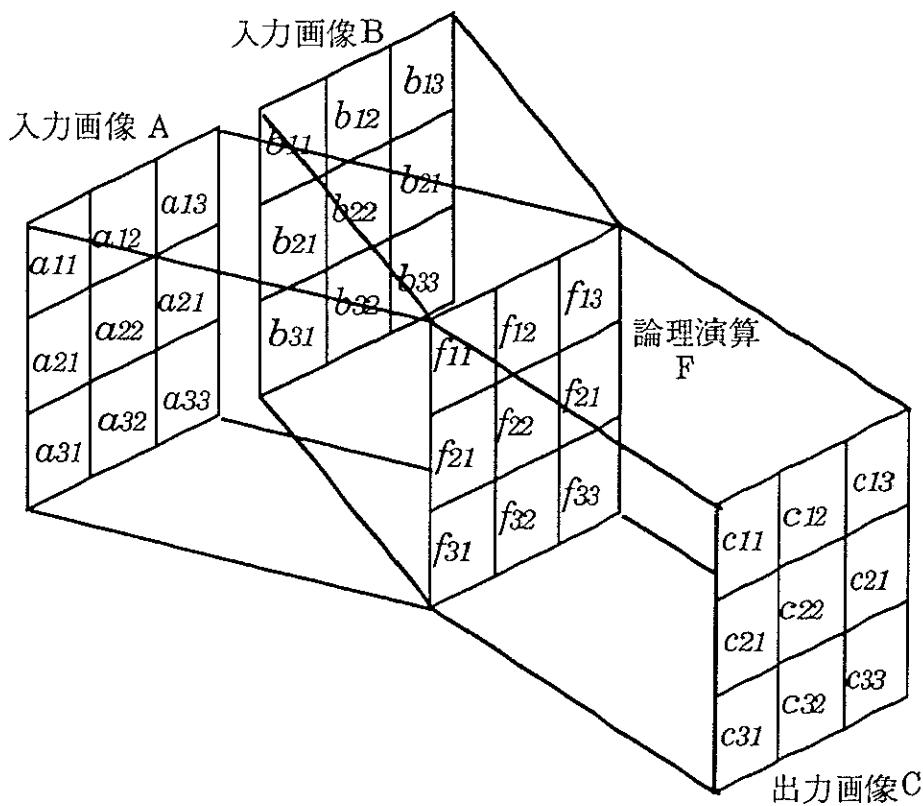


Fig.3.2.1 並列論理演算の概念

空間可変論理演算法の特徴を次に示す。

1. 2つの2値画像の全ての画素に対し論理演算を並列に実行する。
2. 画素ごと論理演算は任意に選択できる。
3. プログラム可能であり、任意の論理回路を実現できる。
4. 同時に異なる論理演算を実行できるため回路規模は小さくなる。

この空間可変論理演算法は、次の三連の操作によって実行される(Fig.3.2.2)。

- 1) 符号化またはコード化(encoding)
- 2) 演算(operation)
- 3) 復号またはデコード(decoding)

1)の符号化は、入力画像AとBの情報を光学処理系によって取り扱い可能な形に変換する操作であり、一組の入力画像AとBに対し任意の論理演算を実行するために必要な操作である。しかし、ある特定の演算しか行わない場合にはその操作は必要なくなる。2)の演算は、符号化された画像を与えられた論理関数Fに基づいて選択することにより必要な出力を得る操作である。3)の復号は、演算後の出力を入力画像と同じ形式し、繰り返しの演算を実行するために必要な操作である。

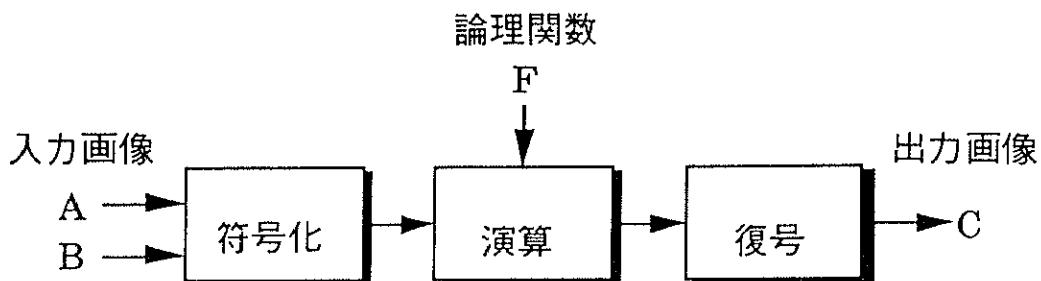


Fig.3.2.2 空間可変論理演算法の操作の流れ

例えば、2入力に対する論理演算を考えるとき、入力の組は(0,0)、(0,1)、(1,0)、(1,1)の4通りがあり、符号化はこの4通りの入力の組を何らかの形式で表現することであり、空間的な位置で表現する方法と時間で表現する方法がある。それぞれ方法は、

- a. 空間符号化
- b. 時間符号化

と呼ばれ、その符号化の方法に伴い、演算、復号も変わる。これらは、空間可変論理演算を実現する手法であり、3.3では空間符号化による方法について、3.4では時間符号化による方法について述べる。

3.3 空間符号化

3.3.1 空間符号化の原理

空間可変論理演算法において、任意の論理演算を行うために、入力画像の各画素に対し符号化を行う必要がある。ここではその一つ方法として空間符号化について示す。入力画像AとBは画素に対応する入力変数 a_{ij} および b_{ij} の集合体であり、画素ごと論理値0または1の2値を有している。論理値を光学的に表現するとき、発光素子と非発光素子では異なる。論理値0の時は発光素子では暗、非発光素子では不透過で表現し、論理値1の時はそれぞれ明および透過で表し、それらの対応をTable3.3.1に示す。これらを光学的情報処理に有効な情報形態にするために、Fig.3.3.1の符号化テーブルに基づいて、入力画像の各画素を符号パターンに変換する。符号パターンは、透過部分（図中の白）と不

Table3.3.1 論理値の光学的実現

論理値	発光素子	非発光素子
0	暗 (dark)	不透過 (opaque)
1	明 (bright)	透過 (transparent)

透過部分（図中の黒）で構成される。入力画像Aの各画素は、その値が0の場合、上半分は透過、下半分は不透過の水平方向に長い長方形のパターンに置換し、1の場合、上半分は不透過、下半分は透過の水平方向に置換する。また、入力画像Bの各画素は、その値が0の場合、左半分は透過、右半分は不透過の垂直方向に長い長方形のパターンに置換する、1の場合、左半分は不透過、右半分は透過の水平方向に置換する。この操作を入力画像AとBの全画面にわたって行う。これらの操作は、一方 向に対して符号化を行っていることより一次元符号化と呼び、その得られた画像を一次元符号化画像と呼び、A'・B'を表す。また、一次元符号化画像A'・B'の(i, j)画素は a'_{ij} と b'_{ij} で表す。

次に、得られた一次元符号化画像A'・B'は、対応する画素が同じ位置にくるように重ね合わせられる。その結果、各画素は1/4画素が明となるようなパターンとなり、空間符号化パターン $a'_{ij} \cdot b'_{ij}$ と呼ぶ。その1/4画素の明の空間的位置によって、対応画素 a_{ij} と b_{ij} の値の組み合せた情報を表す (Fig.3.3.2)。2入力画像AとBから最終的な空間符号化画像A'・B'を得るまでの操作を空間符号化と呼び、空間可変論理演算の一連の操作の中で最も重要な操作であり、この操作をいかに実現するかが鍵となる。

a_{ij}	0	1
a'_{ij}		
b_{ij}	0	1
b'_{ij}		

Fig.3.3.1 符号化テーブル

a_{ij}	0	1
b_{ij}	0	1
b'_{ij}		

Fig.3.3.2 空間符号化

得られた空間符号化画像 $A' \cdot B'$ に各画素異なる論理演算を実行するために、特殊な空間的構造を持ち、論理演算マスク f_{ij} と呼ばれる。論理演算マスクは、論理値 1 を出力する入力の組に対応する 1/4-画素を透過するもので、Fig.3.3.3 に 2 变数 2 値の 16 個の論理演算に対応する論理演算マスクを示す。例えば、論理演算 XOR は、入力の組 (0,1)、(1,0) に対応する右上、左下の 1/4 画素が透過（通過）、入力の組 (0,0)、(1,1) に対応する左上、右下の 1/4 画素が不透過（遮断）となっている。各画素の論理演算マスク f_{ij} は目的に応じて選択され、全体の論理演算マスク F を構成する。この論理演算マスク F と空間符号化画像 $A' \cdot B'$ を重ね合わせることにより演算画像 $F \cdot A' \cdot B'$ が得られる。

演算画像 $F \cdot A' \cdot B'$ は、空間符号化画像と同様に、画素の 1/4 が明であるような画像である。復号は、演算出力の 1/4 画素が明である場合論理値が 1 であるので、入力画像と同様に画素全体を明にする操作である (Fig.3.3.4)。これは、空間可変論理演算を繰り返し実行するときに必要な操作である。Fig.3.3.5 は、2 入力画像 A と B に対する空間可変論理演算の一連の操作を示したものである。

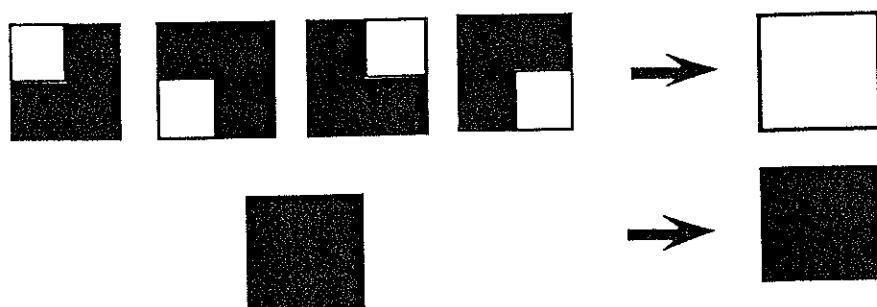


Fig.3.3.4 復号

a_{ij}	b_{ij}	f_{ij}	F	AND	XOR	OR
0	0					
0	1					
1	0					
1	1					
			NOR		NAND	T
						
						
						
						
						
						
						

Fig. 3.3.3 2値2変数論理演算マスク

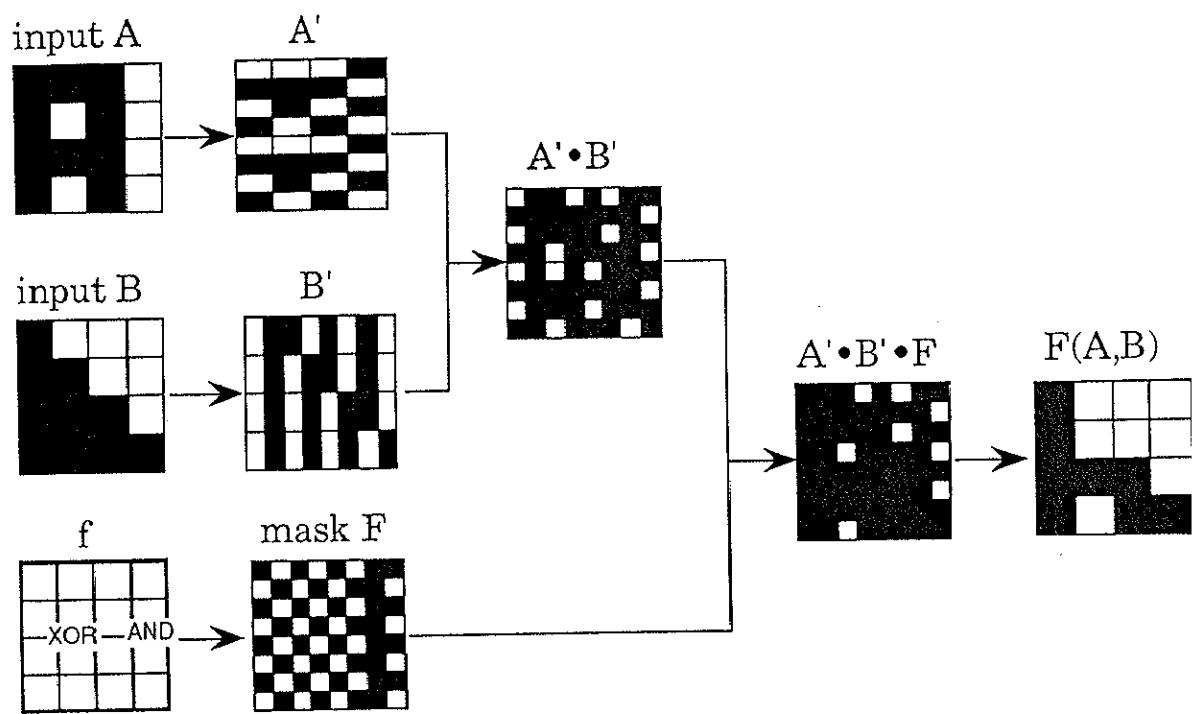


Fig. 3.3.5 空間可変論理演算

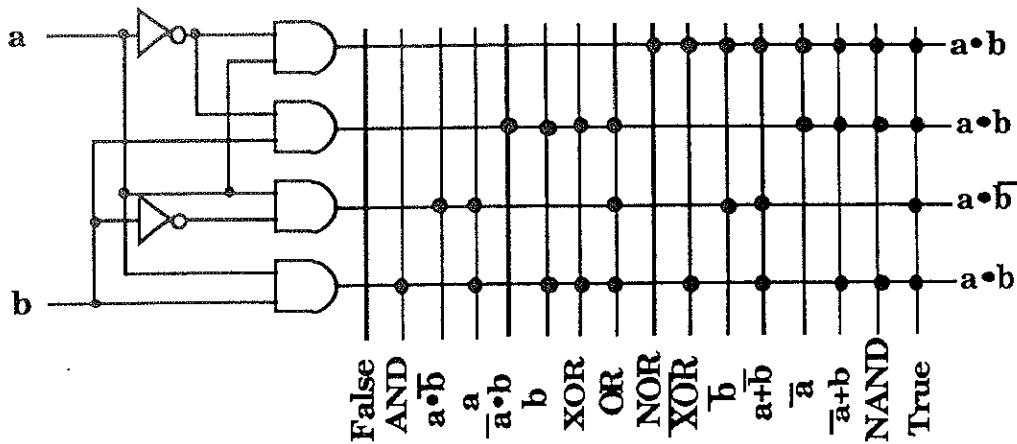


Fig.3.3.6 2ビットデコーダ

この空間可変論理演算をデジタル回路(Fig.3.3.6)の機能と対応させると次のようになる。空間符号化は、正方画素の4等分した画素の内、2変数の値の組に応じて、そのうちの一つを透過にすると考えられる。すなわち、2ビットデコーダの出力信号を光学的情報（透過、不透過）の空間的な配置によって表現したものと考えることができる。また、論理演算マスクは、どのデコード線から信号を選択するかということで、復号はそこに線を引いて信号を取り出すことに対応する。

3.3.2 XORによる空間符号化の原理

空間可変論理演算は、MIMD形式の演算であり、同時に異なる演算の流れを持つ。これを空間的に均質な SIMD 形式の演算（干渉、回折、重ね合わせ等）である光学的手法を利用して実行する。空間可変論理演算において符号化は重要な概念であり、いかに光学的に実現するかによって、並列演算の性能を決定してしまう。空間符号化は、2つの入力画像AとBの各画素に対し、その論理値の組を画素の光学的パターンによって表現する手法である。今まで、その光学的実現として、干渉計による方法が提案され、実験的検証がなされている。ここでは、SIMD形式の並列演算の組み合せにより実現する方法について述べる。

まず、前節と同様に、入力画像Aの画素 a_{ij} を一次元符号化することを考える。ここで、符号化マスク g_a と呼ぶ画素の上半分が1（明）、下半分が0（暗）であるパターンを用意する。画素 a_{ij} と符号化マスク g_a で排他的論理和(XOR)を実行すると、画素の論理値が0の時は、画素の上半分が1、下半分が0のパターン、画素の論理値が1の時は、画素の上半分が0、下半分が1のパターンになり、一次元符号化パターン a'_{ij} であることが解る(Fig.3.3.7(a))。入力画像Bの画素 b_{ij} に対しても、左半分が1、右半分が0である符号化パターン g_b を用意し、同様な操作を行うと一次元符号化パターン b'_{ij} が得られる

$\begin{bmatrix} 0 \\ 0 \end{bmatrix}$	\oplus	$\begin{bmatrix} 1 \\ 0 \end{bmatrix}$	$=$	$\begin{bmatrix} 1 \\ 0 \end{bmatrix}$		$\begin{bmatrix} 1 \\ 0 \end{bmatrix}$
$\begin{bmatrix} 1 \\ 1 \end{bmatrix}$	\oplus	$\begin{bmatrix} 1 \\ 0 \end{bmatrix}$	$=$	$\begin{bmatrix} 0 \\ 1 \end{bmatrix}$		$\begin{bmatrix} 0 \\ 1 \end{bmatrix}$
(a) 入力 a_{ij} に対する符号化						
$\begin{bmatrix} 0 & 0 \end{bmatrix}$	\oplus	$\begin{bmatrix} 1 & 0 \end{bmatrix}$	$=$	$\begin{bmatrix} 1 & 0 \end{bmatrix}$		$\begin{bmatrix} 1 & 0 \end{bmatrix}$
$\begin{bmatrix} 1 & 1 \end{bmatrix}$	\oplus	$\begin{bmatrix} 1 & 0 \end{bmatrix}$	$=$	$\begin{bmatrix} 0 & 1 \end{bmatrix}$		$\begin{bmatrix} 0 & 1 \end{bmatrix}$
(b) 入力 b_{ij} に対する符号化						

Fig.3.3.7 符号化マスク g_a , g_b とのXORによる符号 \oplus : XOR

(Fig.3.3.7(b))。入力画像AとBに対しはそれぞれ、 g_a と g_b を2次元的に配置した符号化マスク G_A と G_B を用意し、XORを実行すると一次元符号化画像A' と B' が得られる(Fig.3.3.8)。空間符号化画像A'・B'は、一次元符号化画像A' と B' で、論理和(AND)を実行することにより得られる(Fig.3.3.9)。

A	\oplus	G_A	$=$	A'
(a)				
B	\oplus	G_B	$=$	B'
(b)				

Fig.3.3.8 XORによる符号化 \oplus : XOR

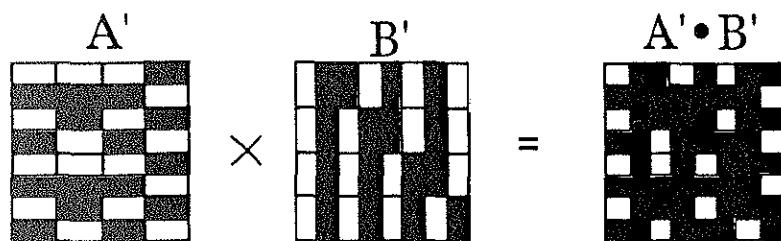
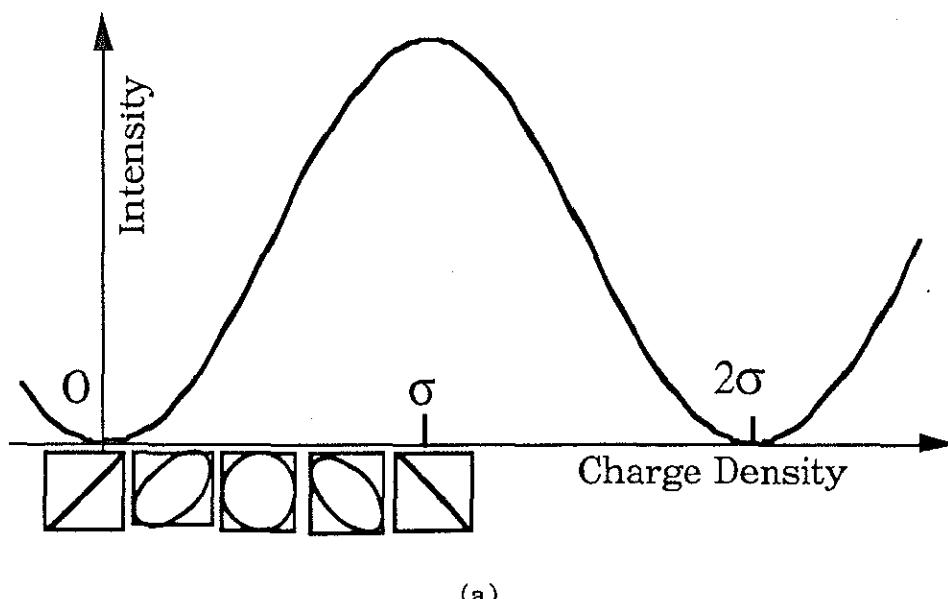


Fig.3.3.9 ANDによる空間符号化 \times : AND

3.3.3 空間光変調管による空間符号化

空間光変調管(MSLM: Microchannel Spatial Light Modulator)は、光入力光出力の空間光変調素子であり、論理演算機能を有する（付録Aを参照）。この機能を利用して、3.3.2で述べたXORとANDによる符号化を実現することができる。ここでは、MSLMについて簡単に説明する。



Input	Region	Mode
A	$0 \sim \sigma$	POSITIVE
G_A	$\sigma \sim 2\sigma$	NEGATIVE

(b)

Fig. 3.3.10 MSLMによる演算の原理 (a)電荷密度と出力光強度の関係 σ : 1/4波長の電荷密度

(b) 電荷蓄積モード(positivemode)と電荷引き抜きモード(negative mode)

MSLMに組み込まれている電気光学結晶(55°カット LiNbO³)は、結晶の両端にかかる電位差にて、出力光の偏光状態を変化させる。その電位差は、入力光強度と印加電圧によって制御される電荷密度に依存する。入射光の偏光状態はその電荷蓄積密度に応じて変化され(Fig.3.3.10(a))左出力側に検光子を置くと電荷蓄積密度と出力光強度は \sin^2 の関係があり(Fig.3.3.10(a))、電圧をさせながら入力画像を入れ換えると、空間的に強度変調された光が出力される。符号化パートを得るために必要なXORは、入力画像Aと符号化マスク G_A を電荷蓄積モード(positive mode)と引抜モード(negative mode)の異なる電荷制御モードで書き込むと実行できる(Fig.3.3.10(b))。またANDは2つの画像を同じ電荷制御モードで書き込むことによって実行できる。

空間可変並列演算を3台のMSLMを用いたシステムを Fig.3.3.11に示す。まず、MSLM1において入力画像Aと符号化マスク G_A を順次提示してXORを実行する。同時に、MSLM2において、入力画像Bと符号化マスク G_B を対しても同様にXORを実行する。MSLM1の出力であるAの符号化画像で、MSLM2のBの符号化画像 B' を読み出すと、空間符号化画像の $A' \cdot B'$ の重ね合わせ(AND)が実行される。MSLM3には、演算マスクFが入力され、空間符号化画像 $A' \cdot B'$ と重ね合わせられ、算出力 $F \cdot A' \cdot B'$ となる。

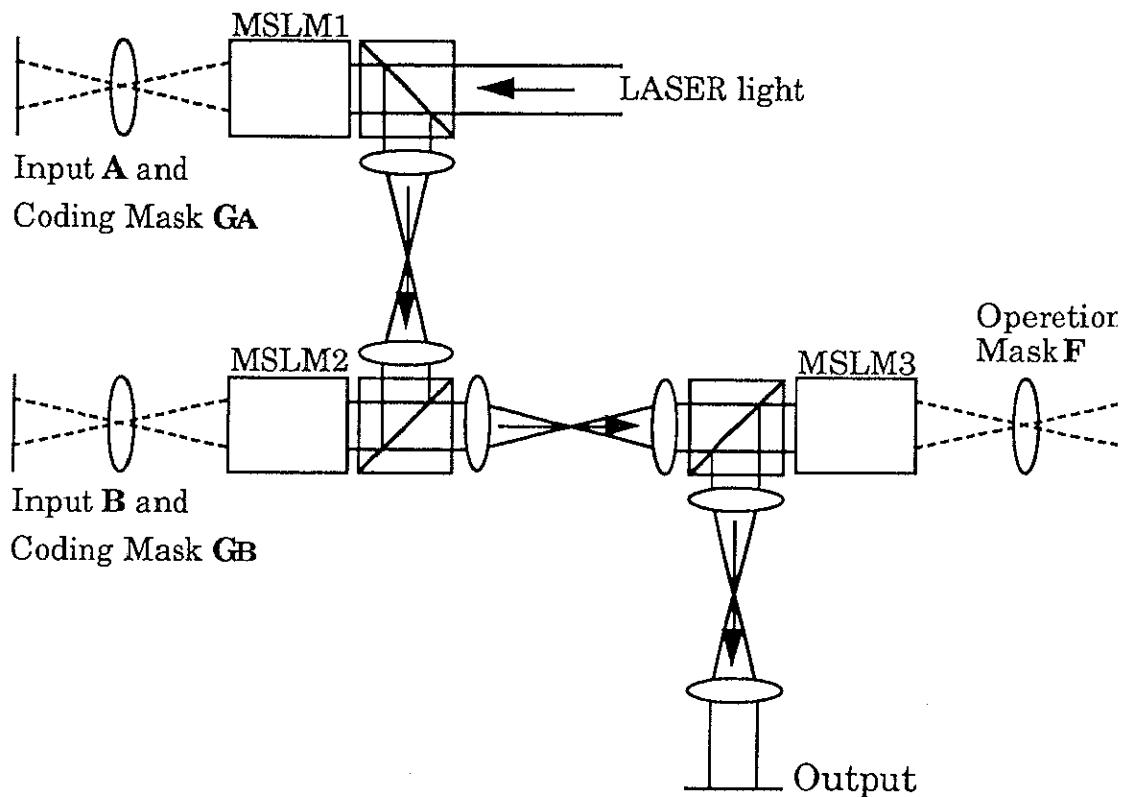


Fig.3.3.10 3台のMSLMによる空間可変論理演算の光学系

3.3.4 実験光学系

ここでは、MSLMの演算機能を利用した空間符号化による空間可変論理演算の実験的検証のための実験光学系について述べる。その実験光学系を Fig.3.3.12にしめす。これは、Fig.3.3.11の3台のMSLMのシステムを1台のMSLMで実現する光学系である。この光学系において、MSLMの読み出し用の光源に15mWのヘリウムネオンレーザーを用い、対物レンズとコリメートレンズとで直径50mm程度の平面波にし、中心付近の直径15mmを使う。また読み出し光は、垂直方向にセットされた偏光子(polarizer)により垂直方向の直線偏光にされ、MSLMの出力側の検光子(analyzer)は水平方向にセットされる。スリットはMSLMからの不必要的反射光を取り除くためのものであり、出力はスクリーン上で観測される。MSLMの入力画像は白色光で照明したスライドであり、MSLMの入力面に結像される。

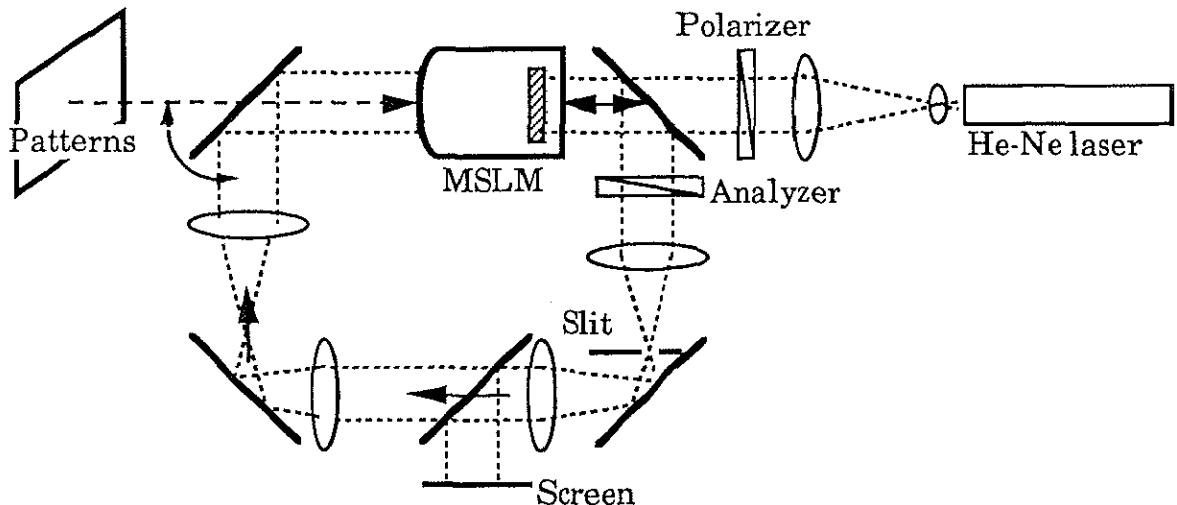


Fig.3.3.11 実験光学系

MSLMは、入力面の上半分を1次元符号化をXORを行うために使われ、下半分を空間符号化のANDを行うために使われる。その概念図を Fig.3.3.13に示す。はじめに、入力面の上半分に入力画像A、Bと空間符号化マスク G_A 、 G_B を順番に入力し、XORを実行し、符号化画像 G_A 、 G_B が得られる。それらをMSLMの入力面の下半分にミラーを動かしながら順番に入力し、ANDを実行する。その結果得られた空間符号化画像 $A' \cdot B'$ を演算マスクを通過させることにより演算結果を得る。

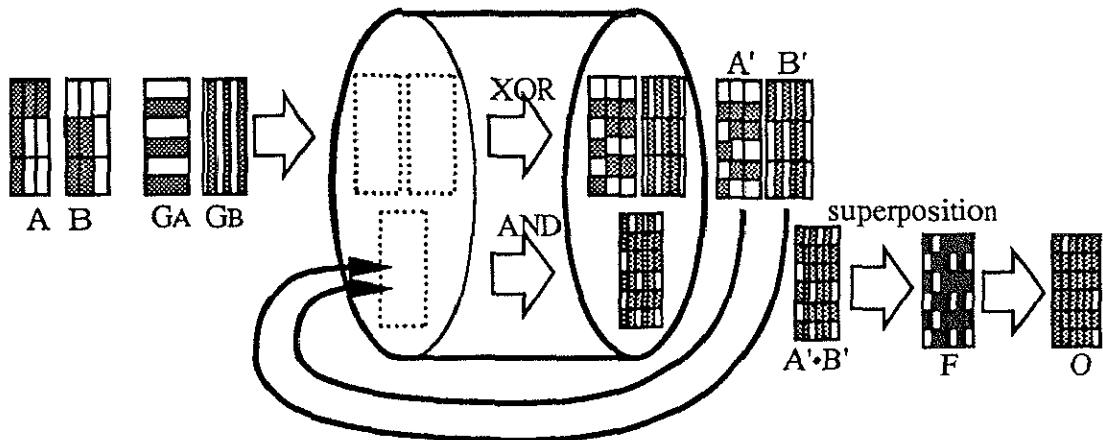


Fig. 3.3.13 処理の流れの概念図

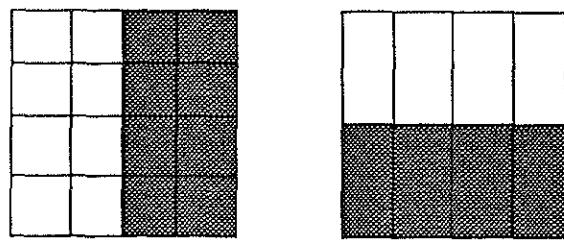
3.3.5 演算実験

MSLMの入力面の上半分に入力画像AとBを並べたスライド(Fig.3.3.14(a))を投影し書き込む。入力画像AとBは、それぞれ、大きさ $4 \times 4 \text{mm}^2$ に 4×4 の画素を有する。次に、同じ大きさで同じ画素数を有する符号化マスク G_A と G_B を並べたスライド(Fig.3.3.14(b))を入力画像AとBに重ねて投影し書き込む。この時、入力画像は電荷蓄積モードで、符号化マスクは電荷引き抜きモードでMSLMに書き込むことによりXORを実行し、Fig.3.3.14(c)に示すように符号化画像 A' と B' を得る。これはMSLM上の符号化画像を読み出した時の写真であり、右上の輝点はMSLM上の欠陥である。

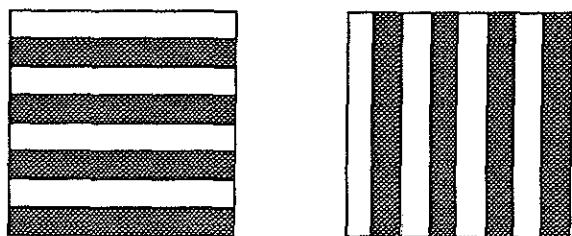
符号化画像 A' と B' は、順番にMSLMの入力面の下半分に重ねて書き込む。この場合、両画像が併に電荷蓄積モードで書き込み、ANDが実行される。画像の重ね合わせはMSLMの入力面の前のミラーを調整して行う。Fig.3.3.14(d)は、MSLMの出力画像である空間符号化画像 $A' \cdot B'$ である。得られた空間符号化画像 $A' \cdot B'$ は、Fig.3.3.14(e)に示す演算マスクを透過させ、Fig.3.3.14(f)に示す出力画像を得る。

3.3.6 考察

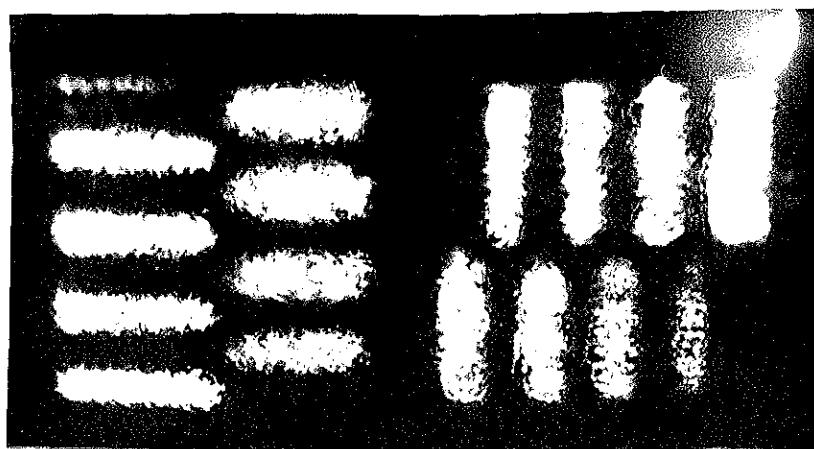
この演算実験に用いられているMSLMは、プロトタイプの機種であり、付録Aで示されている性能に比べてかなり低い。特に、大きな性能の差は空間解像度であり、 2lp/mm 以下であった。そのため、演算実験の結果において、パターンの空間周波数の高い部分である角がとれてしまう。特に、MSLMの電荷引き抜きモードでは、光が照射された部分だけでなく、その周辺部からも電荷を引き抜いてしまうため、得られた符号化画像 A' と B' は、パターンの角が滑らかになっている。空間符号化画像 $A' \cdot B'$ では2回書き込みがあるため、出力画像はさらに悪化する。



(a) 入力画像

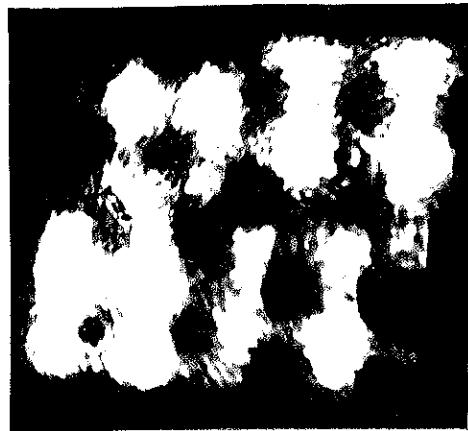


(b) 符号化マスク

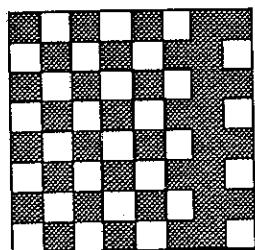


(c) 符号化画像

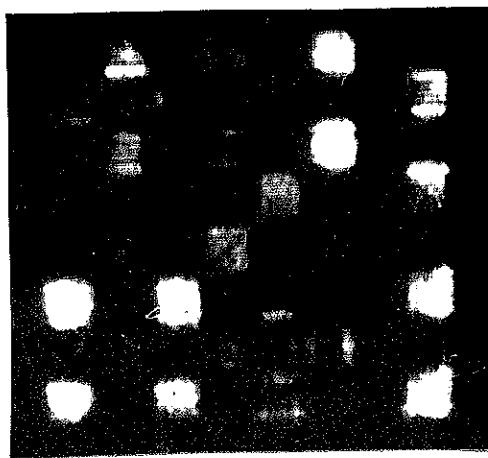
Fig. 3.3.14 空間符号化による演算実験の結果



(d) 空間符号化画像



(e) 演算マスク



(f) 演算出力

Fig. 3.3.14 空間符号化による演算実験の結果

3.4 時間符号化

3.4.1 時間符号化の原理

空間可変論理演算を実行するもう一つの方法として、時間符号化による方法がある。時間符号化は入力画像AとBの対応する画素 a_{ij} と b_{ij} の2つの論理変数の組を時間的に表現する符号化法であり、符号化画像を時間的に展開する方法である。2値2変数の論理演算を考えるとき、4つの論理変数の組は時間的な4ステップ($s=1,2,3,4$)で実行される。時間符号化による空間可変論理演算の原理をFig.3.4.1に示す。符号化は入力(AとB)またはその反転(\bar{A} と \bar{B})を生成し、それらのパターンを重ね合わせることにより、各ステップ s において時間符号化画像 $C(s)$ を得る操作である。時間符号化画像 $C(s)$ の(i,j)画素値は $c_{ij}(s)$ である。演算はその時間符号化画像 $C(s)$ を各画素で通過(open)、遮断(close)することにその一時的出力 $T(s)$ を選択する操作である。図中には、XORとANDの論理演算の場合について示している。復号は4ステップの一時的出力を時間的に加算する操作であり、その操作はADDと表現されている。

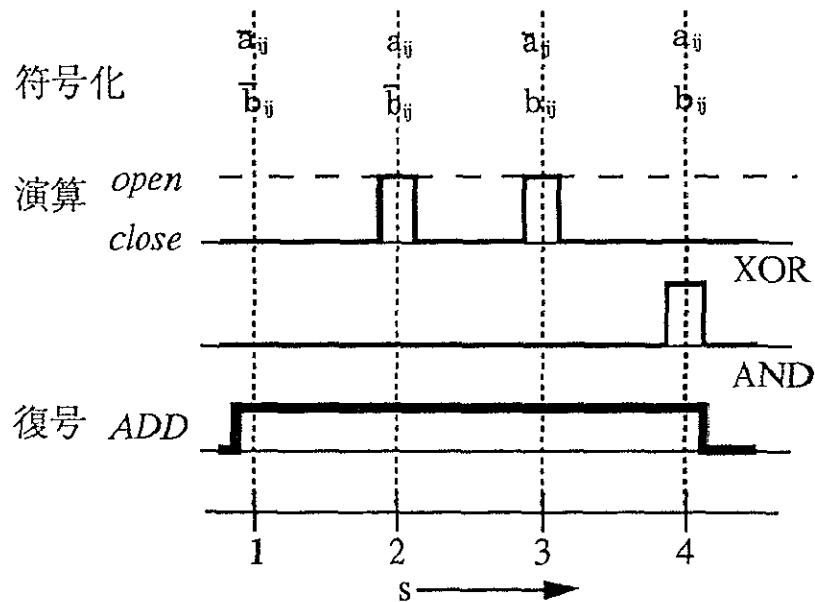


Fig.3.4.1 時間符号化による空間可変論理演算の原理

符号化の操作において、時間符号化画像 $C(s)$ の(i,j)画素値 $c(s)_{ij}$ は以下のように得られる。

$$\begin{aligned}
 c(1)_{ij} &= \bar{a}_{ij} \cdot \bar{b}_{ij}, \\
 c(2)_{ij} &= a_{ij} \cdot \bar{b}_{ij}, \\
 c(3)_{ij} &= \bar{a}_{ij} \cdot b_{ij}, \\
 c(4)_{ij} &= a_{ij} \cdot b_{ij},
 \end{aligned} \tag{3.4.1}$$

画像の形式で表現すると、

$$\begin{aligned}
 C(1) &= \overline{A} \cdot B, \\
 C(2) &= A \cdot \overline{B}, \\
 C(3) &= \overline{A} \cdot \overline{B}, \\
 C(4) &= A \cdot B.
 \end{aligned} \tag{3.4.2}$$

となる。時間符号化画像 $C(s)$ の画素値 $c(s)_{ij}$ は、入力の論理値の組に応じて、 $(a_{ij}, b_{ij}) = (0, 0)$ の時ステップ1で、 $(a_{ij}, b_{ij}) = (0, 1)$ の時ステップ2で、 $(a_{ij}, b_{ij}) = (1, 0)$ の時ステップ3で、 $(a_{ij}, b_{ij}) = (1, 1)$ の時ステップ4で、それぞれ明となります。Fig.3.4.2は時間符号化テーブルを示していて、横軸に時間、縦軸に画素の値の組を示している。

演算の操作において、論理演算マスクを時間的に展開した論理演算セレクタ $F(s)$ が時間符号化の実行と同期して発生され、時間符号化画像 $C(s)$ に重ね合わせされる。論理演算セレクタ $F(s)$ の (i, j) 画素を $f(s)_{ij}$ 、ステップ s での一時的出力画像 $T(s)$ の (i, j) 画素の出力を $t(s)_{ij}$ とすると、一時的出力 $t(s)_{ij}$ は、

$$t(s)_{ij} = f(s)_{ij} \cdot c(s)_{ij} \quad s = 1, 2, 3, 4 \tag{3.4.3}$$

と書け、画像の形式で表現すると、

$$T(s) = F(s) \cdot C(s) \quad s = 1, 2, 3, 4 \tag{3.4.4}$$

となる。Fig.3.4.3は16個の論理演算セレクタを示したものであり、openは一時的出力の通過、close-は遮断を表す。論理演算セレクタは各画素に対して任意に選択できる。

	s →			
	1	2	3	4
(a_{ij}, b_{ij})	$\overline{a}_{ij} \cdot \overline{b}_{ij}$	$\overline{a}_{ij} \cdot b_{ij}$	$a_{ij} \cdot \overline{b}_{ij}$	$a_{ij} \cdot b_{ij}$
(0,0)				
(0,1)				
(1,0)				
(1,1)				

Fig.3.4.2 時間符号化テーブル

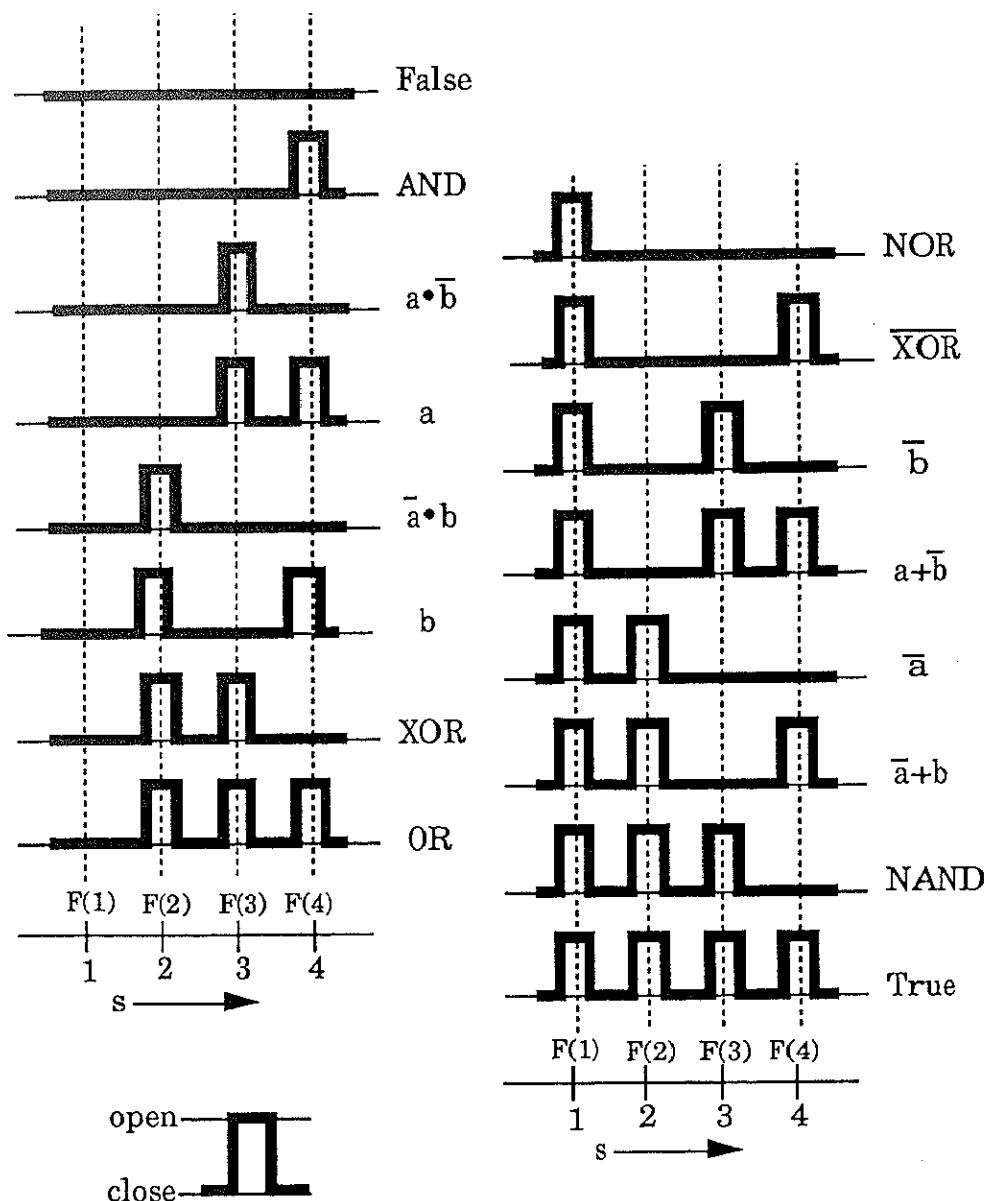


Fig.3.4.3 論理演算セレクタ

復号の操作において、演算出力画像Oは4ステップの一時的出力画像T(s)を時間的加算することのより得られ、その(i,j)画素値を o_{ij} と表すと、

$$o_{ij} = t(1)_{ij} + t(2)_{ij} + t(3)_{ij} + t(4)_{ij}, \quad (3.4.5)$$

となる。+は時間的な加算を表していて、復号の操作全体はADDと表す。同様に画像形式で書くと、

$$O = T(1) + T(2) + T(3) + T(4), \quad (3.4.6)$$

となる。(3.4.1)と(3.4.3)を用いて(3.4.5)を書き直すと、

$$o_{ij} = f(1)_{ij} \cdot \bar{a}_{ij} \cdot \bar{b}_{ij} + f(2)_{ij} \cdot a_{ij} \cdot \bar{b}_{ij} + f(3)_{ij} \cdot \bar{a}_{ij} \cdot b_{ij} + f(4)_{ij} \cdot a_{ij} \cdot b_{ij}, \quad (3.4.7)$$

となる。また、画像形式の(3.4.2)と(3.4.4)を用いて(3.4.6)を書き換えると、

$$O = F(1) \cdot \bar{A} \cdot B + F(2) \cdot A \cdot \bar{B} + F(3) \cdot \bar{A} \cdot \bar{B} + F(4) \cdot A \cdot B \quad (3.4.8)$$

となる。Fig.3.4.4は時間符号化による空間可変並列演算の画像に対する一連の操作を示す。

3.4.2 時間符号化のシステム構成

時間符号化の基づく空間可変論理演算を実行するためには、4つのSLMが必要であり、Fig.3.4.5はそのシステムの概念図を示している。システムは3つの透過型SLMと1つの時間的加算を行うSLMから構成されている。1番目のSLMは入力画像Aまたはその反転 \bar{A} を表示し、2番目のSLMは入力画像Bまたはその反転 \bar{B} を表示し、3番目のSLMは演算セレクタF(s)を表示する。4番目のSLMは復号の時間的加算を行い、しきい値特性を有するデバイスが理想的である。

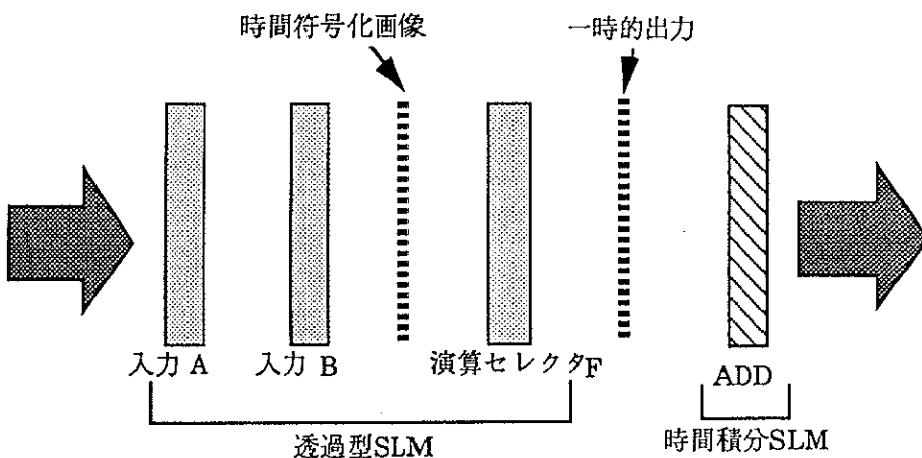


Fig.3.4.5 時間符号化による空間可変論理演算システムの概念図

Fig.3.4.6は、空間可変論理演算の基本的な実験的検証のためのシステムの概念図である。実験システムは、LEDアレイ、液晶テレビ(LCTV)、CCDカメラ、そして、パーソナルコンピュータ等から構成され、図中では、レンズ、偏光子は省略されている。実験システムは 4×4 の16素子を持っている。実験システムにおいて、時間符号化における処理の各ステップsは、2回のサブステップに分けて実行される。1回目のサブステップにはLEDアレイに入力画像Aを表示し、LCTVに入力画像Bを表示し、時間符号化画像C(s)を得る。2回目のサブステップには、LEDアレイに時間符号化画像を表示し、LCTVに演算セレクタF(s)を表示し、一時的出力画像T(s)を得る。LEDアレイはコンピュータにより制御され、LCTVへの信号、CCDカメラからの信号は、イメージプロセッサーを通してコンピューターと通信される。復号のための時間加算SLMは、実際の素子の特性を想定して、コンピューターの中で仮想的に実現する。そこでは、Fig.3.4.6(b)に示したような飽和特性を有する入出力

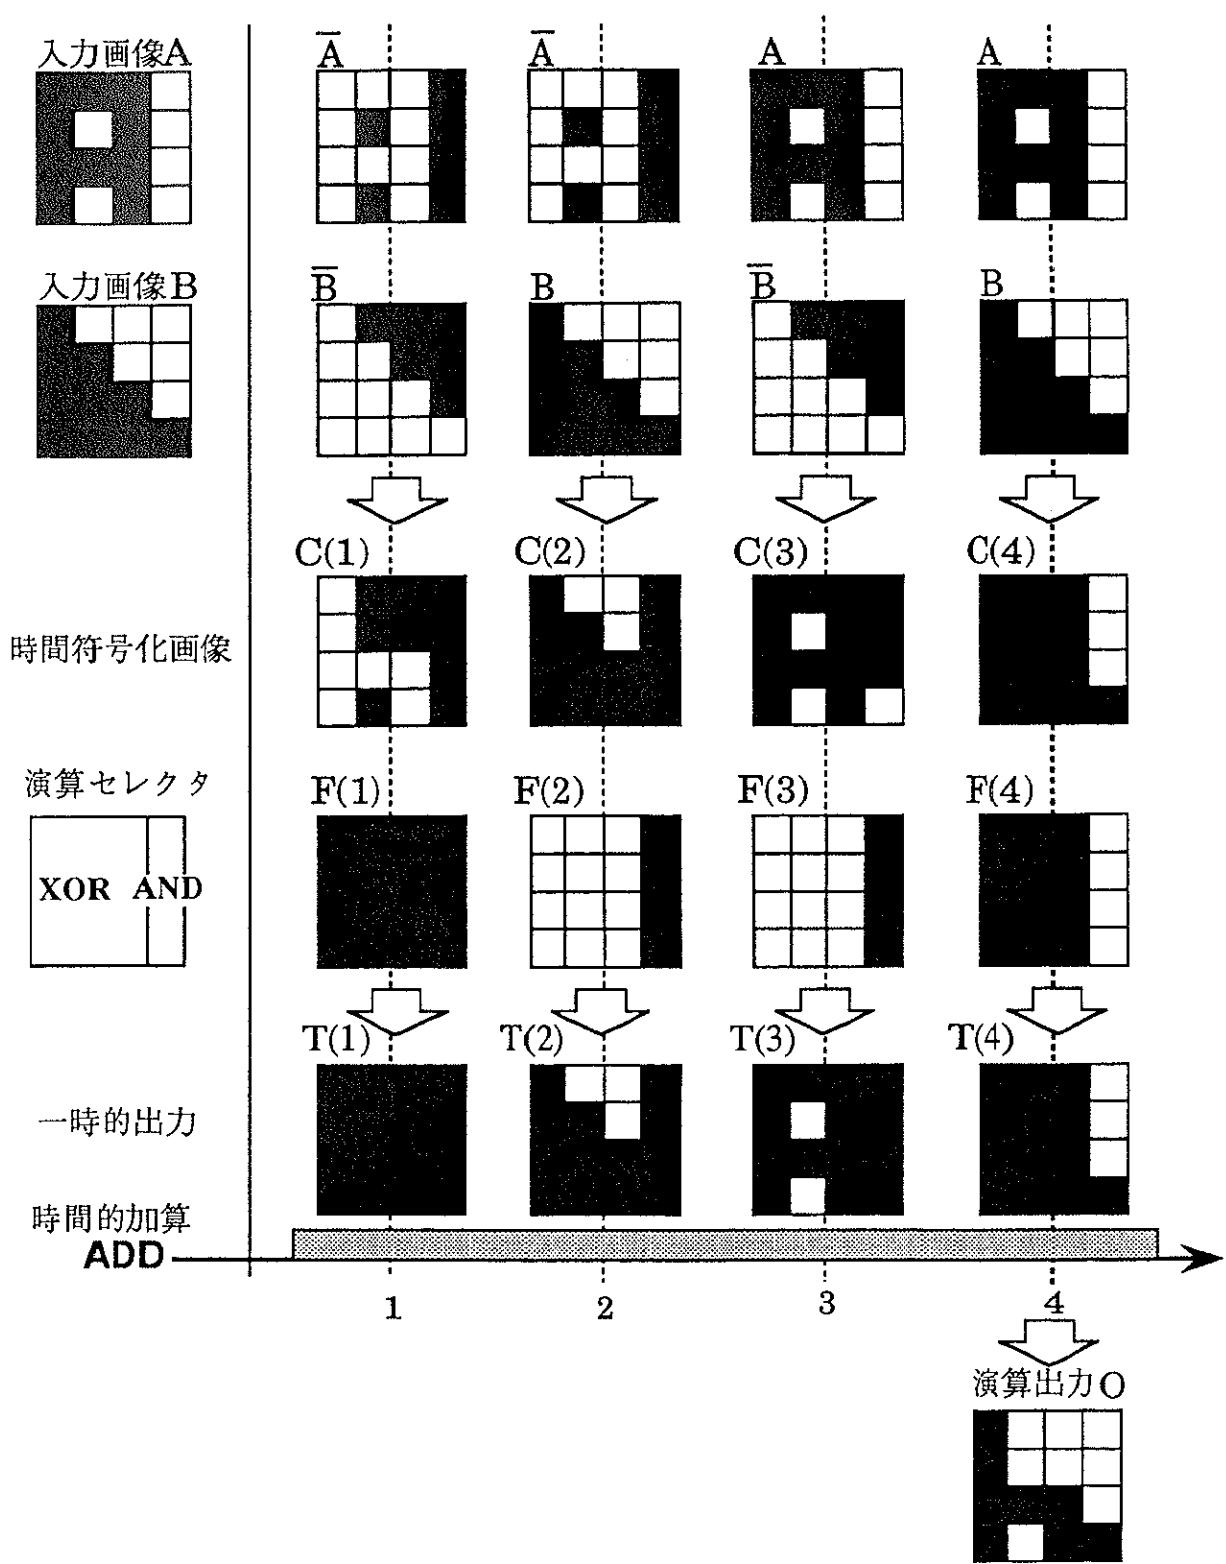
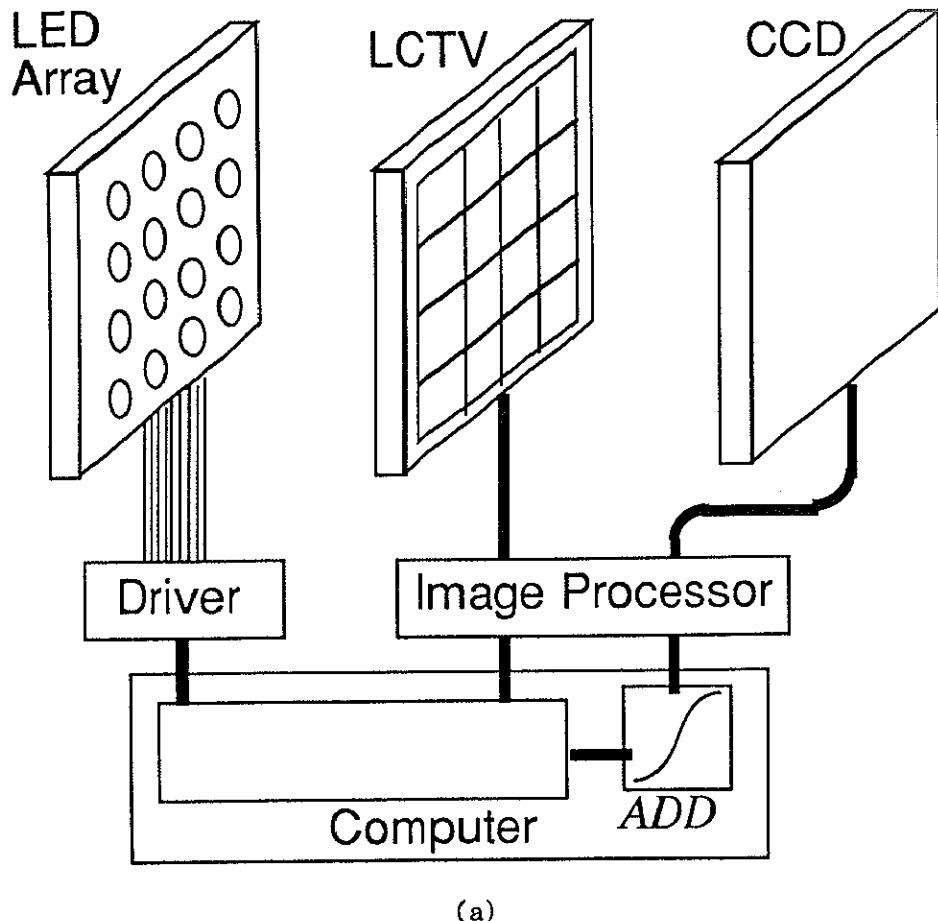
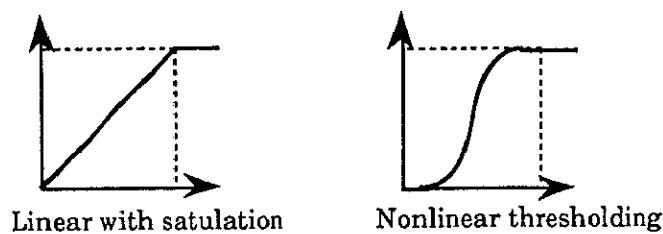


Fig.3.4.4 時間符号化による空間可変論理演算（画像の場合）

が線型素子と非線型のしきい値素子を実現している。



(a)



(b)

Fig.3.4.6 時間符号化のによる空間可変論理演算の実験システム

(a) 時間符号化に基づく実験システム

(b) 2つの加算素子の特性

3.4.3 演算実験

Fig.3.4.7は、実験システムにおける並列演算の実験結果である。2つの入力画像と演算セレクタは、Fig.3.4.4に示した例と同様である。全ての写真はCCDカメラ上での出力である。Fig.3.4.7(a)、(b)

、(c)、(d)は、入力画像Aと入力画像Bを重ね合わせる1回目のサブステップの出力で、各ステップの時間符号化画像である。Fig.3.4.7(e)、(f)、(g)、(h)は、時間符号化画像と演算セレクタを重ね合わせる2回目のサブステップの出力で、各ステップの一時的演算出力である。Fig.3.4.7(i)、(j)、(k)、(l)は、コンピューターの中で計算した時間加算の出力である。Fig.3.4.7(l)は正しい演算出力である。この場合、コンピューターの中で計算されたデバイスの特性はFig.3.4.6に示したような飽和特性を持つ線型を仮定した。Fig.3.4.8は、コンピューター内の想定したデバイスの特性を非線型しきい値特性を想定した場合の出力である。

Fig.3.4.7(e)において、出力が暗であるべきところがかすかに明になっていることがわかる。これは、LCTVのコントラストが30程度であるためであり、Fig.3.4.8の非線型しきい値特性のデバイスを用いた場合においては消失していることがわかる。

3.5 空間符号化と時間符号化の比較

これまで、空間可変論理演算を実行する方法として、空間符号化による方法と時間符号化による方法についてその原理を述べ、光学的な実験結果について述べた。実験システムは非常に小さいシステムであるが、同じデバイス構成で大規模なシステムが構築できる。その場合、それぞれの方法によるシステムが持っている特徴を考慮して、それに応じたデバイス構成が必要になる。ここでは、2つの方法をいくつかの点で比較して、要求するデバイスについて考える。また既存のデバイスによってシステムを構成した場合の演算速度について示す。

演算の並列度を考える場合、必要な素子数は重要である。空間符号化は演算単位を 2×2 の4素子によって構成されるので、時間符号化に比べて4倍の素子が必要となる。またシステムの速度を考える場合、1回の演算で必要な時間について考える必要があり、これは構成するデバイスの機能によって大きく異なる。画像のメモリへのアクセス時間を含むデバイスの画像書き換え時間Tw、光の通過時間をTop、デバイスの加算時間Ta、符号化の時間Tc、復号の時間Tdとすると、空間符号化の演算時間Tsは、2入力と演算マスクを書き込む時間とシステム内の光の通過時間と復号の時間が必要であり、

$$Ts = Tc + 3Tw + Top + Td \quad (3.5.1)$$

と書ける。時間符号化の演算時間Ttは、2入力と演算セレクタを書き込む時間とシステム内の光の通過時間と加算の時間が4回必要であり、

$$Tt = (3Tw + Top + Ta) \times 4 \quad (3.5.2)$$

と書ける。さらに、2入力と演算マスクまたは演算セレクタを同期させて書き込むと、それぞれの時間は、

$$Ts = Tc + Tw + Top + Td \quad (3.5.3)$$

$$Tt = (Tw + Top + Ta) \times 4 \quad (3.5.4)$$

となる。

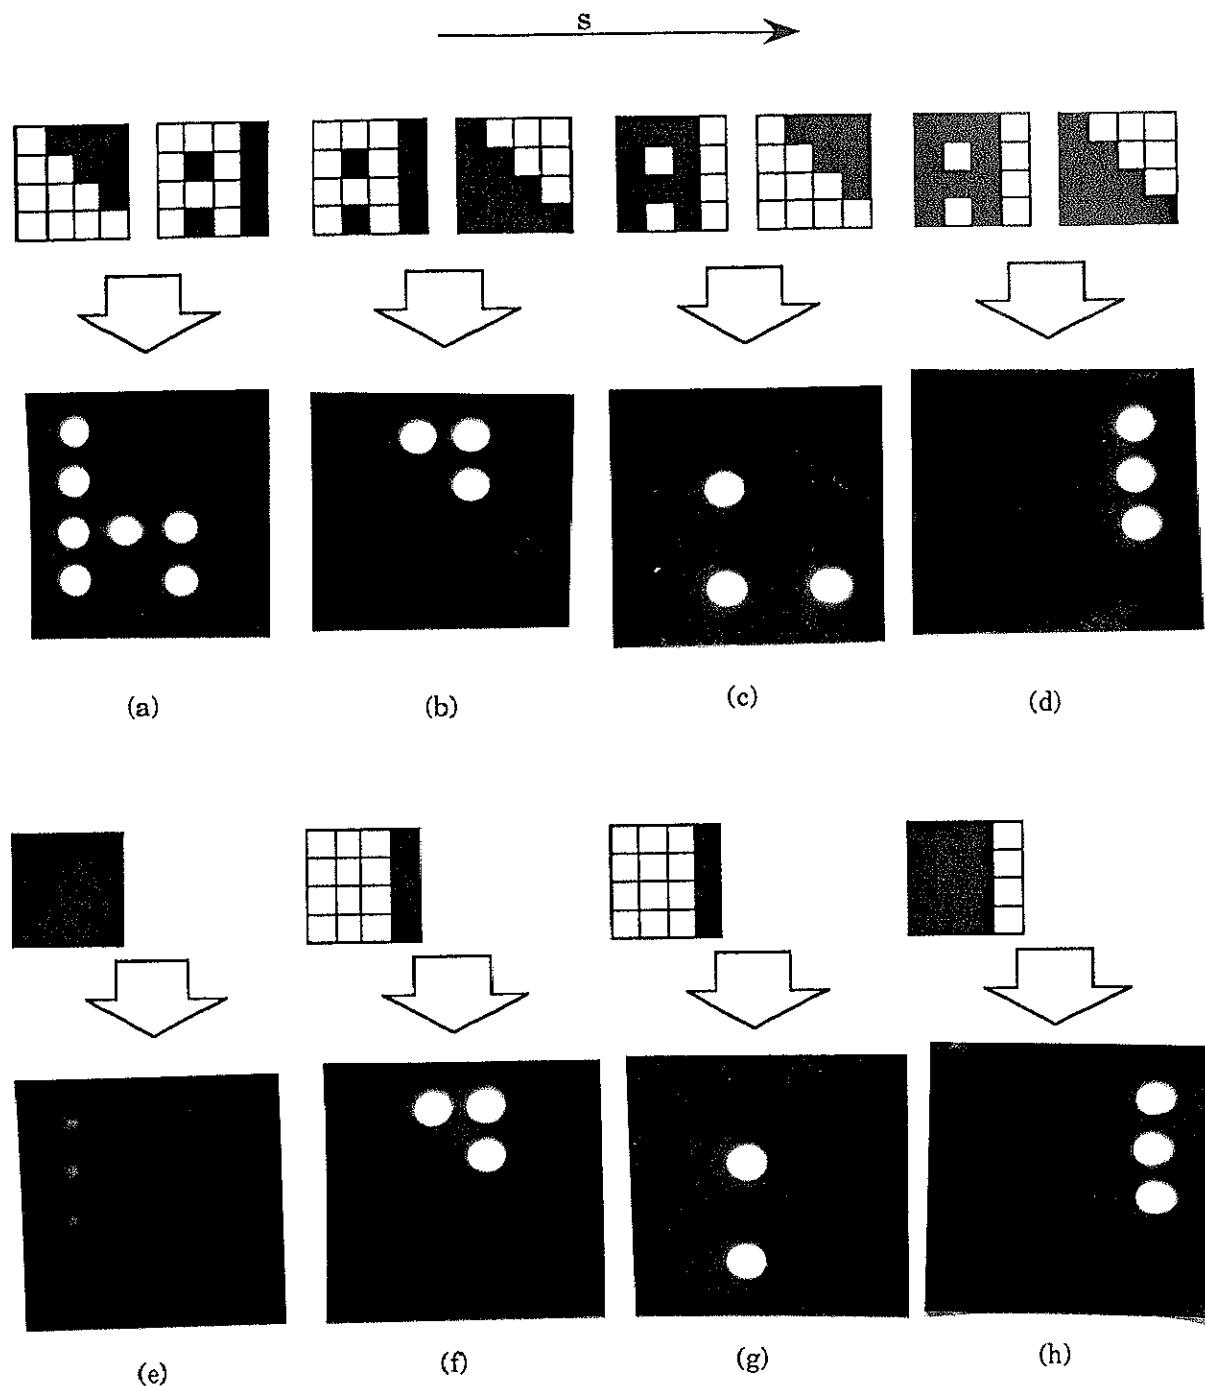


Fig.3.4.7 実験システムにおける並列演算の実験結果

- (a), (b), (c), (d) 各ステップの時間符号化画像（1回目のサブステップ）
- (e), (f), (g), (h) 各ステップの一時的演算出力（2回目のサブステップ）

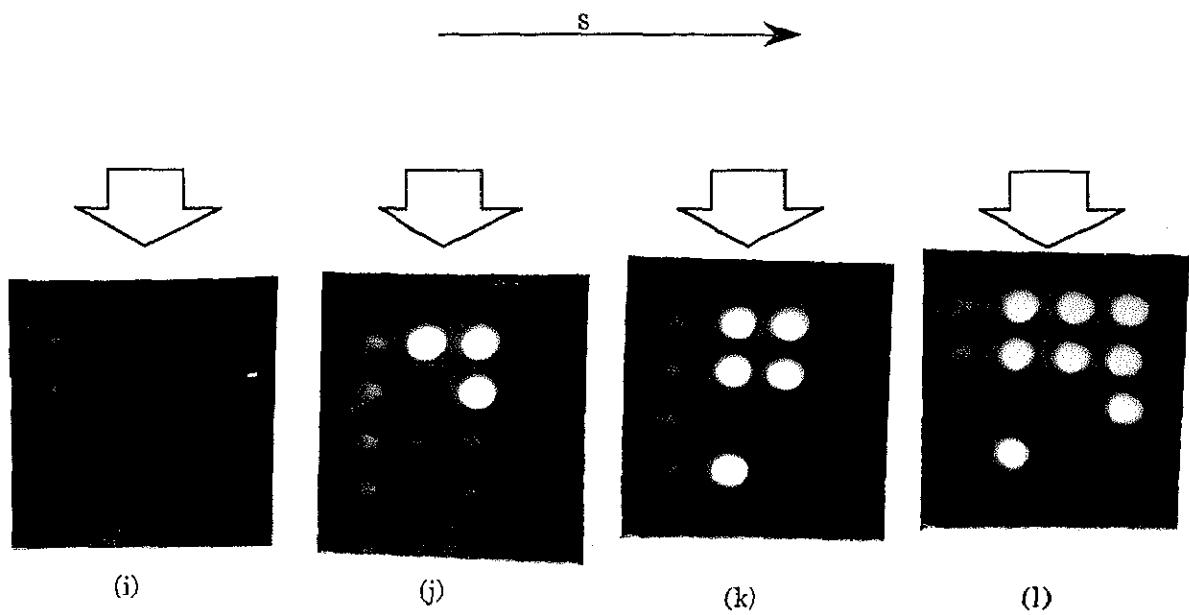


Fig.3.4.7 実験システムにおける並列演算の実験結果

(i), (j), (k), (l) 加算素子の出力 (飽和を持つ線型の加算素子)
 (l) 演算出力

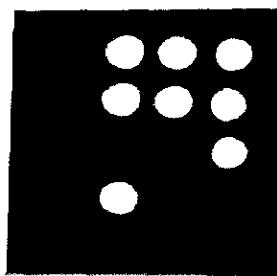


Fig.3.4.8 並列演算の出力結果 (非線型特性)

符号化と復号の操作において、空間符号化の場合パターンの変換であり、それぞれの操作は非線型な処理が必要であり、構成するデバイスは論理演算機能等の非線形な処理を行えるような高い機能が必要である。それに比べて、時間符号化の場合画像の反転と時間的な加算であり、どちらも線型な操作である。そのため、必要なデバイスは単純な機能のデバイスでよい。また、空間符号化に用いられるデバイスは記憶機能は必要でないが、時間符号化において、加算素子は記憶機能が必要である。

以上の2つの方法の比較をTable 3.5.1にまとめ、必要なデバイスについてまとめると、空間符号化では4倍の素子と演算機能などの高機能性、時間符号化では反転画像が得られ、高速な書き換え速度が必要である。

ここで、演算速度を既存の液晶SLMを用いてシステムを構成した場合について概算してみる。液晶SLMは、有効径25mm、解像度115lp/mm、クロックスピード~2.5kHzである。これは素子数は 2000×2000 に相当し、一回の演算で10回SLMを書き換えるとすると、1秒間に 10^9 回程度の論理演算が実行できる。

Table 3.5.1 空間符号化と時間符号化の比較

	空間符号化	時間符号化
素子数	$P \times 4$	P
演算時間	$T_w + T_c + T_{op} + T_d$	$(T_w + T_{op} + T_a) \times 4$
符号化、復号の操作	パターン変換	パターン反転 + 時間的加算
特徴	<ul style="list-style-type: none"> ・演算全体が一度の操作で実行 ・入力画像の4倍の画素数 ・高機能なデバイス 	<ul style="list-style-type: none"> ・入力画像と同じ素子数 ・単純な機能のデバイス ・4回の画像の書き換えが必要

3.6 まとめ

光デジタルシステム構築に必要な並列光演算の一つである空間可変論理演算法の原理を説明し、その光学的実現法について述べた。空間可変論理演算法を実現する方法は、空間符号化の方法と時間符号化の方法があり、それぞれの原理について示し、原理確認のための基本的な実験システムを構成した。空間符号化ではMSLMの演算機能を使う方法、時間符号化ではLEDアレイとLCTVによるシステムであり、それぞれ演算実験を行い、その結果を示した。実験システムは 4×4 と小さなシステムであるが、基本的に同じデバイス構成により大規模なシステムが構成できることが特徴である。両方法の特徴の比較から、大規模なシステムを構築する際に、空間符号化では演算機能などの高い機能、時間符号化では反転画像が得られる必要であることを示し、現状のデバイスで並列演算システムを構成

した場合、 10^9 operations/sec程度の性能が得られることを明かにした。

参考文献

- [1] K. S. Huang, A. A. Sawchuk, B. K. Jenkins, P. Chavel, J. M. Wang, A. G. Weber, C. H. Wang, and I. Glaser, "Implementation of a prototype digital optical cellular image processor (DOCIP)," Proc. SPIE **963**, 687-694 (1988).
- [2] F. Kiamilev, S. C. Esener, R. Paturi, Y. Fainman, P. Mercier, C. C. Guest, and S. H. Lee, "Programmable optoelectric multiprocessors and their comparison with symbolic substitution for digitaloptical computing," Opt. Eng. **28**, 396-409 (1989).
- [3] J. Tanida, J. Nakagawa, E. Yagyu, M. Fukui and Y. Ichioka, "Experimental verification of parallel processing on a hybrid optical parallel array logic system," Appl. Opt. **29**, 2510-2521 (1990).
- [4] M. E. Prise, N. C. Craft, M. M. Downs, R. E. LaMarche, L. A. D'Asaro, L. M. F. Chirovsky, and M. J. Murdocca, "Optical digital processor using arrays of symmetric self-electronic effect devices," Appl. Opt. **30**, 2287-2296 (1991).
- [5] A. Huang, "Comutational Origami - The folding of circuits and systems," Technical Digest, Optical Computing 89, 198-201 (1988).
- [6] P. S. Guilfoyle and W. J. Eiley, "Combinational logic based digital optical computing," Appl. Opt. **27**, 1661-1673 (1988).
- [7] G. Stuke, "Parallel architecture for a digital optical computer," Appl. Opt. **28**, 363-370 (1989).
- [8] M. Fukui and K. Kitayama, "Image logic algebra and its optical implementations," Appl. Opt **31**, 581-591 (1992).
- [9] 例えば、間多均, "液晶空間光変調素子", 光学 **18**, 350 (1989). や"液晶空間光変調素子の応用", "光学 **21** (1992).
- [10] T. Hara, M. Sugiyama, and Y. Suzuki, "A Spatial Light Modulator," Adv . Electron Phys. **64B**, 637(1985).
- [11] 例えば、J. Feinleib and D. S. Oliver, "Reusable Optical Image Storage and Processing Device," Appl Opt **11**, 2752-2759 (1972). やT. Minemoto, K. Okamoto, and K. Miyamoto, "Optical parallel logic gate using spatial light modulators with the Pockels effect," Appl. Opt. **24**, (1985) 2055. や峯本工, 陳婧, "光学結晶を用いた空間光変調素子," 光学 **18**, 337-342 (1989).
- [12] D. A. B. Miller, "The quantum well self-electro-optic effect device: Optoelectronic bistability and oscillation , and self-linearized modulation," IEEE J. Quautum Electron **QE-21**, 1462-1476 (1985).
- [13] K. Kasahara, Y. Tashiro, H. Hamao, M. Sugimoto and T. Yanase, "Double

- Heterostructure Optoelectronic Switch as a Dynamic Memory with Low-power Consumption," Appl. Phys. Lett. **52**, 679-681(1988).
- [14] M. T. Fatehi, K. C. Wasmundt, and S. A. Collins, Jr., "Optical logic gates using liquid crystal light valve, implementation and application example," Appl. Opt. **20**, 2250(1981).
- [15] S. Fukushima and T. Kurokawa, " Optical Parallel Processor for Binary Images with Cascaded Bipolar-Operational Spatial Light Modulators," IEEE Photo. Tech. Lett. **3**, 682-684 (1991).
- [16] H. Bartelt, A. W. Lohmann, and E. E. Sicre, J. Opt. Soc. Am. **A1**, 944(1984).
- [17] Y. Ichioka and J. Tanida, "Optical Parallel Logic Gates Using a Shadow-Casting System for Optical Digital Computing," Proc. IEEE **72**, (1984).
- [18] T. Yatagai, "Optical Space-Variant Logic Gate Array Based on Spatial Encoding Technique", Opt. Lett. **11**, 270-272(1987) .
- [19] M. Murdocca, "A Digital Design Methdology for Optical Computing," (MIT Press, Cambridge, 1990).
- [20] K. H. Brenner, A. Huang, and N. Steibl, "Digital optical computing with symbolic substitution," Appl. Opt **25**, 3054-3060(1990).
- [21] J. Tanda And Y. Ichioka, "Optical-logic-aray processor using shadowgrams. III. Parallel neighborhood operations and an architecture of an optical digital computing syetm," J. Opt. Soc Am. **A2**, 1245-1253 (1985).
- [22] K. Iga, M. Oikawa, S. Misawa, J. Banno, and Y. Kokubunn, "Stacked planer optics: an application of the planar microlens," Appl. Opt. **21**, 3456-3460(1982).
- [23] J. Jahns and A. Huang, " Planar integration of free-space optical components," Appl. Opt. **28**, 1602-1605 (1989).
- [24] K. Hamanaka, "Optical bus interconnection system by using Selfoc Lenses," Opt. Lett. **16**, 1222-1224 (1991).
- [25] M. Ikeda, T. Yatagai, S. Ishihara and Y. Mitsuhasi, "Interferometric Pattern Encoding for Parallel Logic Operation", Technical Digest, Topical Meeting on Optical Computing **87**, 237 (1987).
- [26] Y. Hayasaki, M. Ikeda, T. Yatagai, S. Ishihara and Y. Mitsuhasi, "Space-Variant Logic Operation Using Micro-Channel Spatial Light Modulator", SPIE **963** Optical Computing **88** (1988) 607.

第4章 光ニューラルシステム

4.1 はじめに

ニューラルネットワークモデルは、人間の脳の神経生理学の研究を基にして、その物理的な構造、情報処理様式を参考にし、工学的にモデル化したものであり、非常に簡単なモデルの研究から、実際のニューロンの複雑な特性を取り入れたモデルの研究とかなり多岐にわたっている[1-9]。こうした中、現在、比較的単純化したニューロンモデルを層状に結合したモデルや相互に結合したモデル等の研究が大変盛んである。このニューラルネットワークモデルは、既存の電子計算機と比較した場合、主に2つの重要な特徴を持つ。

1) 大規模並列処理性

2) 学習と自己組織化

1)の大規模並列処理性は、基本構成単位であるニューロンが多数結合していて、シナプス結合の興奮性・抑制性に対応する正の結合・負の結合を介しながら、並列的に処理が進行することである。実際のニューロンの応答作度は高々数ミリ秒と半導体デバイスに比べて遅いが、応答速度や情報表現の多様性をネットワークの超並列性により補っている。そして、最適解に近い解を比較的短時間で求める処理を行っている。基本演算単位としてのニューロンは、簡単にまとめると次のような特徴を持つ。

- a) 比較的単純均一な情報の処理を行う。
- b) ニューロン間は単純な情報しか伝達しない。
- c) ニューロン間の結合荷重によってネットワーク全体の動作を制御する。
- d) それぞれのニューロンは原則として非同期に動作する。

2)の学習と自己組織化は、ネットワーク内のダイナミクスを外界（入力）に応じて、適応的に形成、変更するものであり、これはニューロンの結合荷重を変更することによるものである。

ニューラルネットワークモデルの構造をハードウェアにより、本質的に実現するためには、1つ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く、1)から4)の特徴により、個々のユニットは単純で、ユニット間の大規模な配線を含めた演算機構の全てを並列処理にする必要がある。これは、ユニットの複雑性からユニット間の配線の複雑性へ、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して、大規模並列処理において、その本質の一つがこの配線の複雑性にあるといえる。更に、ニューラルネットワーク実現のためには、ニューロンの増加にともない、増加するファンイン・ファンアウトを確保する必要がある。

近年、このような技術的な要請のもと、半導体技術に支えられる電子回路技術を用いてアナログ回

路やデジタル回路により多くのハードウェア化がなされている。それらは、C.Meadらによるシリコン網膜[10]やGrafらによる連想記憶チップ[11]をはじめとするアナログ回路を用いたものやプロードキャストバスを用いたWSI(Wafer Scale Integration)ニューラルネットワークシステム[12]やリンクバスを用いたシステム[13][14]などのデジタル回路を用いたものもある。また、実際のニューロンと同様なパルス密度用いて情報表現行ったニューロチップも開発されている[15]。電子回路によるニューラルネットワークの実現は、いかに半導体技術が発展しようと本質的に2次元平面上の技術であり、ニューロン数の増大とともに配線の問題がでてくる。実際、電子回路のニューラルネットワークシステムでは、1つのニューロンに対する配線数を制限したり、プロードキャストバスやリングバスを用いて配線の問題を避けている。

この配線の問題を含め、光技術の特徴を利用してニューラルネットワークシステムを構成しようという研究が盛んである。その基本構成に光ベクトルマトリクス演算器[16]を用いて、FarhatやPsaltisらによるホップフィールドモデル[17]の光学システム[18-21]や、FisherらによるWidrow-Hoff[22]の連想構造を持つシステム[23-25]、Koskoらによる双方向連想モデル[26][27]、Farhatによるシミュレーテッドアニーリングによる自己組織モデルのシステム[28]等、多くの光ニューラルネットワークが提案され、実現された。他の構成として、フォトリフラクティブ結晶の体積ホログラムによる荷重配線を実現[29][30]や、バンドルファイバー[31]やファイバーネット[32]による光ニューラルネットワークも実現されている。また、光の並列性を有効に利用できる2次元的な構造のアーキテクチャが提案され、石川らはその構造を導入した直交学習により荷重の最適化を行う光アソシエーションと呼ばれる光ニューラルシステムを構成し、学習または想起実験を通して、学習がハードウェアの不均一を吸収できることを実験的に示した[33][34]。さらに、2次元構造を実際に光学的に実現したシステムもあり、Luらによるレンズアレイによる局所加算光学系による光ニューラルシステム[35][36]や筆者らによる多重結像光学系による光ニューラルシステム[37]がある。さらに、久間らによってフォトダイオードとフォトディテクタをスタック状に集積した光ニューロチップも実現されている[38][39]。また、ホログラフィック連想記憶[40-43]とニューラルネットワークの原理や連想性の相似性は興味深く、多くのシステムが構築された[44-49]。

これら多くの光ニューラルシステムは序論で示した光の特徴、(1)大規模並列性・高密度情報伝送能力、(2)高速・アナログ処理性、(3)無誘導性、(4)画像処理の直接処理、がニューラルネットワークの要求する大規模可変配線に対し、配線の並列化・大容量化・高密度化の点で相性が良いと考えられる。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。

本章では、光ベクトルマトリクス演算器またはその拡張である多重結像光学系を基本構成として実

現する光ニューラルシステムについて述べる。まず、それらのシステムについて知るために、ニューラルネットワークの基本モデルと学習についてそれぞれ4.2と4.3で述べる。さらにニューラルネットワークの光学的実現の為の手法について4.4で述べる。そこでは、筆者らが提案している光ニューラルモジュールについて述べる。次に、既存の構成法である光ベクトルマトリクス演算器と新しい構成法である多重結像光学系について述べる。また、ニューロンの非線型出力関数のMSLMによる実現、新しい荷重の表現法とその更新法や筆者らの考案した光学的実現に適した反転入力重ね合わせ法の実行モデルについて述べる。最後に、いくつかの実際構成した光ニューラルシステムの実験システムと動作実験について報告する。それらのシステムの実験結果を通して、光ニューラルネットワークの用いられるデバイスについて評価する。

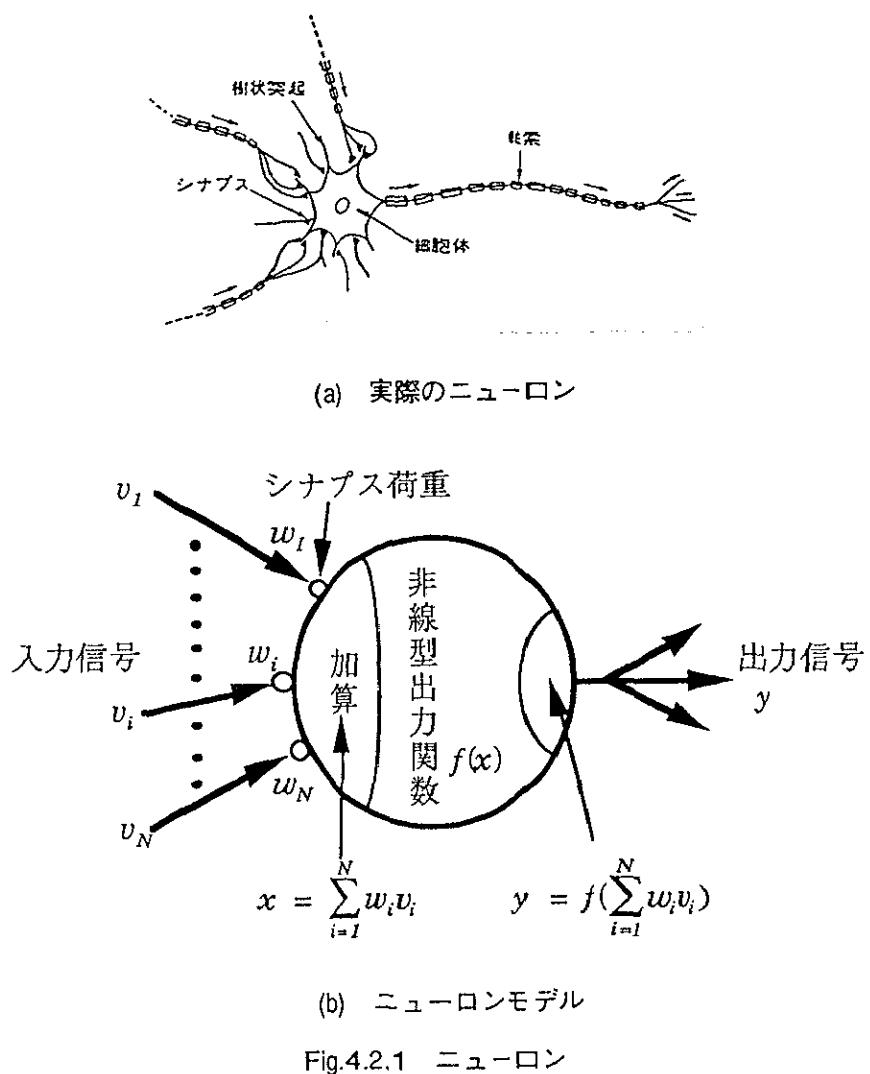


Fig.4.2.1 ニューロン

4.2 ニューラルネットワークモデル

4.2.1 基本モデル

ニューラルネットワークモデル[1]-[9]は、Fig.4.2.1(a)に示すニューロンを工学的にモデル化し、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。この機能を模倣したニューロンの基本モデルをFig.4.2.1(b)に示す。これは、多入力/1出力の非線型演算素子と考えられる。

ここで、 N 個の入力信号を受けるニューロンの離散時間モデルを考える。入力信号を $\mathbf{V} = (v_1, \dots, v_p, \dots, v_N)$ とし、そのときの出力信号を y とし、しきい値（オフセット）を h 、出力関数を f とする。更に、 i 番目の入力のシナプス荷重を w_i とすると、入力信号の線形荷重和 x は、

$$x = \sum_i w_i v_i - h \quad (4.2.1)$$

であり、これを空間荷重和演算と呼び、 x は荷重和または膜電位と呼ぶ。更に、出力関数 f を施す出力関数演算により、ニューロン出力は、

$$y = f(x) \quad (4.2.2)$$

となる。一般に、出力関数 f は、

$$f(u) = 1 / (1 + \exp(-u/\epsilon)) \quad (4.2.3)$$

のシグモイド関数が用いられ、 ϵ は出力関数の非線型性を決定する正の定数であり、個々の ϵ の値に関する関数を Fig.4.2.2 に示す。 $\epsilon \rightarrow 0$ にすると出力関数 f はステップ関数となる。

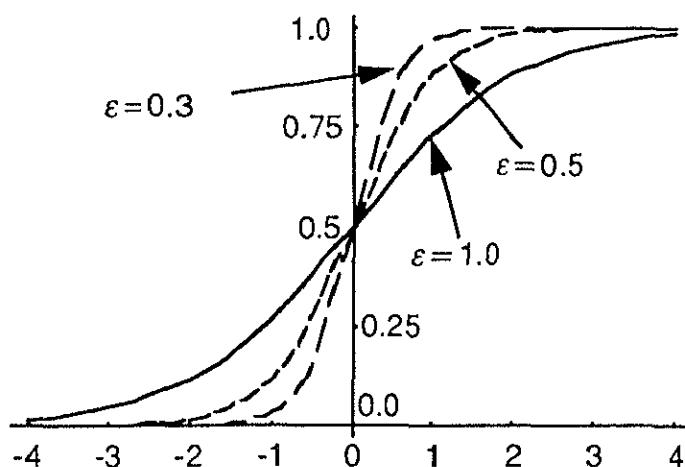


Fig.4.2.2 シグモイド関数

以上のモデルは、最も簡単なニューロンモデルであり、入力信号の時間的加算や出力と次の刺激に対する不応性、疲労、軸索伝播による波形整形作用を考慮したモデルもある[1][4][50]。ニューラルネットワークは式(4.2.1)、(4.2.2)のニューロンモデルを多数結合したものであり、ここではFig.4.2.3に示すような N 個の入力信号 $\mathbf{V} = \{v_1, \dots, v_i, \dots, v_N\}$ を受ける N 個の出力 $\mathbf{Y} = \{y_1, \dots, y_j, \dots, y_N\}$ を得る単層ニューラルネットワークを考える。これは入力信号を入力ニューロンの出力信号と考え、2層のニューラルネットワークと呼ぶ場合もある。 i 番目の入力の j 番目の出力ニューロンのシナプス荷重（結合荷重） w_{ji} 、 j 番目の出力ニューロンのオフセットを h_j とすると、 j 番目ニューロンの荷重和 x_j は、

$$x_j = \sum_i w_{ji} v_i + h_j \quad (4.2.4)$$

であり、 j 番目のニューロンの出力は、

$$y_j = f(x_j) \quad (4.2.5)$$

である。また入力信号を要素とする入力ベクトル \mathbf{V} と出力信号を要素とする出力ベクトル \mathbf{Y} とシナプス荷重 w_{ji} を要素とする荷重マトリクス \mathbf{W} とから、荷重和 x_j を要素とする荷重和ベクトル \mathbf{X} は、式(4.2.4)から

$$\mathbf{X} = \mathbf{W} \cdot \mathbf{V} - \mathbf{H} \quad (4.2.6)$$

のベクトルマトリクス演算で書け、 \mathbf{H} は h_i を要素とするしきい値ベクトルである。

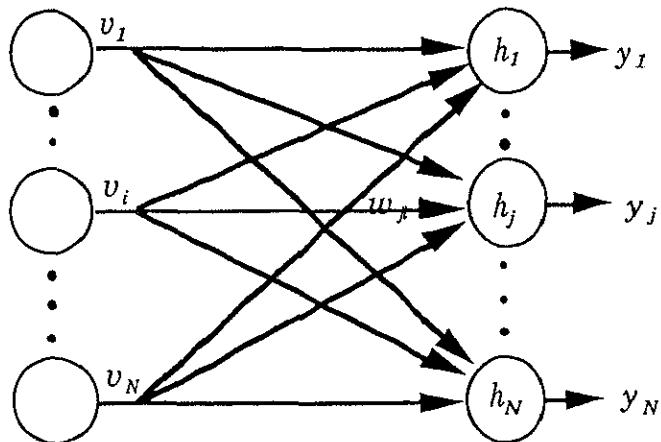


Fig.4.2.3 単層のニューラルネットワーク

以上のモデルは、最も簡単なニューラルネットワークであり、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、相互結合型ネットワークモデル(Fig.4.2.4(a))と階層型ネットワークモデル(Fig.4.2.4(b))との二つがある。式(4.2.4)と式(4.2.5)を相互結合型と階層型にあわせて添え字を書き直す、相互結合の場合、時刻 t の出力 $y(t)$ は時刻 $t+1$ の入力 $v(t+1)$ に戻されるので、

$$x_j = \sum_i w_{ji} y_i(t) - h_j \quad (4.2.7)$$

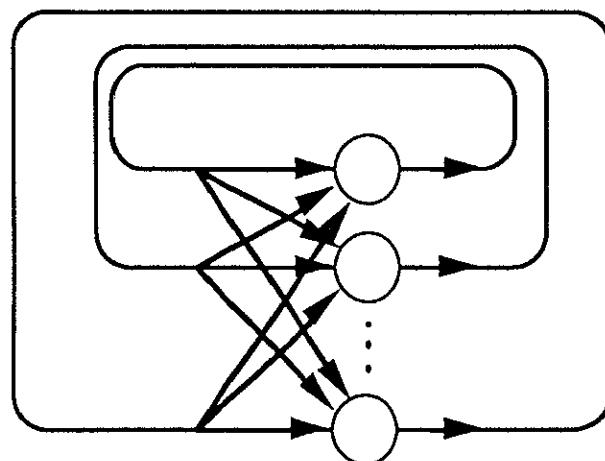
$$v_j(t+1) = y_j(t) = f(x_j) \quad (4.2.8)$$

となる。階層型の場合、(k)番目の層から(k+1)番目の層の結合を考えると、

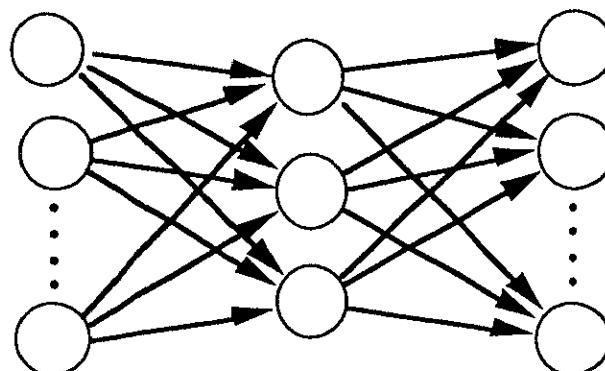
$$x_j^{(k)} = \sum_i w_{ji}^{(k+1,k)} y_i^{(k)} - h_j^{(k)} \quad (4.2.9)$$

$$y_j^{(k+1)} = f(x_j^{(k)}) \quad (4.2.10)$$

となる。ここで、 $y_i^{(k)}$ 、 $x_j^{(k)}$ 、 $h_j^{(k)}$ は、それぞれ、(k)層のニューロンの出力、荷重和、しきい値で、 $w_{ji}^{(k+1,k)}$ は(k)層と(k+1)層間の結合荷重である。



(a)



(b)

Fig.4.2.3 ニューラルネットワークの分類

(a) 相互結合型ネットワーク

(b) 階層型ネットワーク

4.2.2 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の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、その平衡状態は、ネットワークの性質よって、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。これは、連想記憶[51]や組み合わせ最適化問題[52]に用いられる。

相互結合型ネットワークの代表例として、ホップフィールドモデル[17]がある。このネットワークは、結合の対称であるネットワークの動作が、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。このネットワークは、巡回セールスマン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[52]。ここでは、離散時間2値のホップフィールドモデルについて示す。

P 個の N 次元2値ベクトル $\mathbf{V}_{(p)} = \{v_{(p)1}, v_{(p)2}, \dots, v_{(p)N}\}$ を記憶する結合荷重 $\mathbf{W} = [w_{ji} : i, j = 1, \dots, N]$ は、

$$w_{ji} = \sum_p (2v_{(p)j} - 1) \times (2v_{(p)i} - 1) \quad i \neq j \\ = 0 \quad \quad \quad i = j \quad (4.7.1)$$

で定義される。記憶ベクトルは、部分や間違った入力ベクトル $\mathbf{V} = \{v_1, v_2, \dots, v_N\}$ から以下のような式に基づいて回復される。

$$x_j = \sum_i w_{ji} v_i \quad (4.7.2)$$

出力ベクトルは、

$$v_j = 1 \quad x_j \geq 0 \\ = 0 \quad x_j < 0 \quad (4.7.3)$$

のしきい値関数で得られ、出力が定常状態になるまで新しい入力ベクトルとしてフィードバックされる。この入力ベクトル \mathbf{V} から記憶ベクトル $\mathbf{V}_{(p)}$ を想起する過程が、連想記憶の基本原理である。このモデルにおける記憶可能なベクトル数 M はニューロン数 N に依存し、近似的に、

$$M = N / (2 \log N \cdot \log \log N) \quad (4.7.4)$$

であらわされ[51]、ホップフィールドは経験則により、

$$M = 0.15N \quad (4.7.5)$$

を求めた[52]。しかし、得られた解は必ずしも最適解ではなく局所解であるため、十分に満足できる解である場合とそうでない場合がある。そのため、局所解を避けるためにシミュレーテッド・アニーリング[53]などの方法が提案されている。

4.2.3 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て、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、情報の流れは一方向で、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、どの様な変換を行うかであり、そのための各層のニューロンの結合やニューロンでの処理を決定する方法である。これは、学習や自己組織化と呼ばれ、代表的なものとして、誤差逆伝播学習則[6]がある。この学習則について簡単に言うと、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。詳しくは、4.3.2 で述べる。

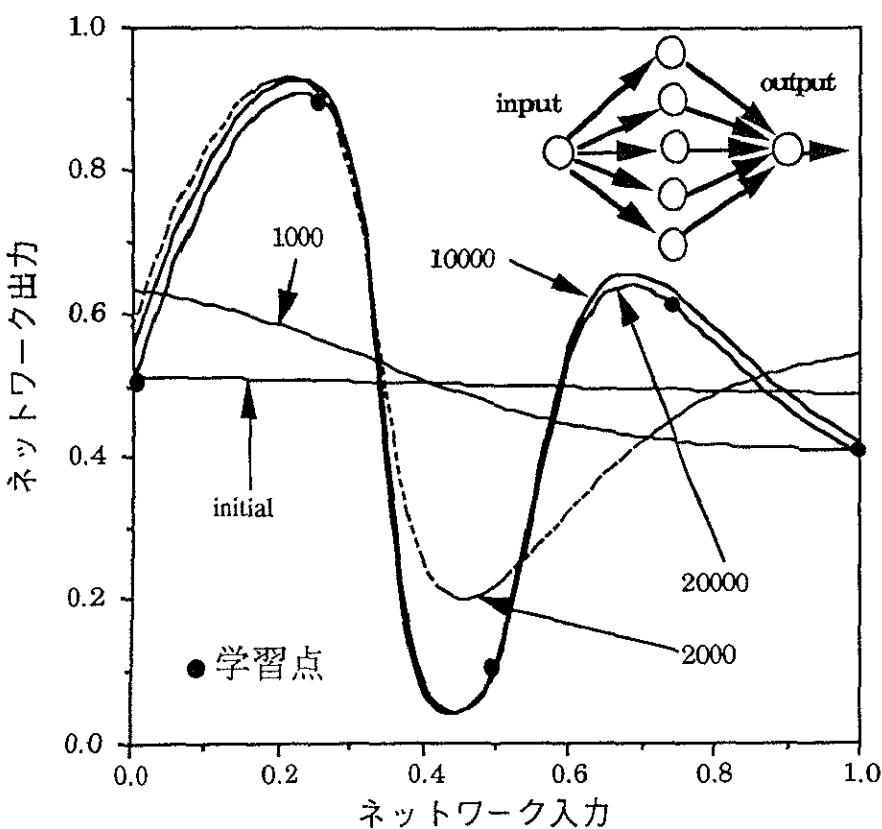


Fig.4.2.5 階層型ネットワークの任意関数生成機能

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 (Fig.4.2.5)。これは図中の1-5-1のニューラルネットワークに5つの点を学習させたときの各学習回数におけるネットワークの入出力特性を示している。これを見方を変えると、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[54][55]。

4.3 学習

4.3.1 学習と自己組織化の基本モデル

ニューラルネットワークの特徴の一つである学習及び自己組織化は、ニューロンの結合荷重を適応的に修正し、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。時刻tにおける、 j 番目のニューロンの*i*番目のニューロンから入力 $v_i(t)$ に対する結合荷重を $w_{ji}(t)$ とする時、その離散時間の学習方程式を以下に示す。

$$w_{ji}(t+1) = \alpha w_{ji}(t) + \eta \delta_j(t) v_i(t) \quad (4.3.1)$$

ここで、 α は $0 < \alpha < 1$ で、荷重の減衰度(忘却係数)であり、 η は学習係数、 $\delta_j(t)$ は学習信号である。結合荷重の変化は、入力信号の強さ v_i と学習信号 δ の積に比例する。学習信号 $\delta_j(t)$ は、入力信号 $v_i(t)$ 、結合荷重 $w_{ji}(t)$ 、出力信号 $y_j(t)$ 、教師信号 $d_j(t)$ に依存し、Hebbの学習則[56]では $\delta_j = y_j$ 、相関学習則[1]では $\delta_j = d_j$ 、直交学習則(デルタルール)[7]では $\delta_j = d_j - y_j$ である。

4.3.2 誤差逆伝播学習

4.2.2で述べた階層型ネットワークの学習法は、1958年のRosenblattにより提案されたバーセプトロンに端を発する[57]。1960年代の多くの研究からいくつかの問題点が報告された[58]。その後、それらの問題を解決するための一つの方法として、甘利により一般的な定式化のもと理論的な考察が行われ[59]、1986年Rumelhartらによって誤差逆伝播学習(Error Back Propagation)として提案された[6]。ここでは、現在広く用いられ、実際光ニューラルシステムに用いたニューラルネットワークの学習法として、誤差逆伝播学習のアルゴリズムについて述べる。

Fig.4.2.3(b)の階層型ネットワークに、 K 個の訓練パターンが与えられるものとする。ここで、学習とは、パターンえた入力パターンから得られた出力パターンと目標出力パターンの下記の自乗誤差の和 E が最小になるよう結合荷重を調整することである。

$$E = \sum_p E_p = 1/2 \sum_p \sum_i (y_{(p)i} - d_{(p)i})^2 \quad (4.3.2)$$

ただし、 E_p は p 番目の訓練パターンに対する自乗誤差の和、 $y_{(p)i}$ は訓練パターン p に対する出力ニューロン*i*の出力値、 $d_{(p)i}$ はその目標出力値である。

誤差逆伝播学習は、最急降下法の一種であり、 E_p の偏微分を用いる方法と E を偏微分を用いる方法がある。前者は、訓練パターン p に基づいて荷重を修正する逐次修正法に相当し、後者は全ての訓練パターン提示した後荷重を修正する一括修正法に相当している。修正量が小さいとき両者の差は小さいので、ここでは、アルゴリズムが単純な逐次修正法について示す。

(k)層から(k+1)層間の結合荷重の変化量 $\Delta w_{ji}^{(k+1,k)}$ は結合荷重 $w_{ji}^{(k+1,k)}$ で E_p を偏微分値に比例する（以後、(k+1,k)は省略する）。

$$\Delta w_{ji} = -\eta \frac{\partial E_p}{\partial w_{ji}} \quad (4.3.3)$$

ただし、 η は偏微分にかかる係数で学習係数と呼ばれる。上式の偏微分は合成関数の微分により、次のように表現できる。

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial x_{(p)j}^{(k)}} \frac{\partial x_{(p)j}^{(k)}}{\partial w_{ji}} \quad (4.3.4)$$

ここで、 $x_{(p)i}^{(k)}$ はニューロン*i*の荷重和（活性値）である。式(4.3.4)の右辺第2項は式(4.2.9)より、

$$\frac{\partial x_{(p)j}^{(k)}}{\partial w_{ji}} = y_{(p)i}^{(k)} \quad (4.3.5)$$

ただし上式での $y_{(p)i}^{(k)}$ は $x_{(p)j}^{(k)}$ の前の層のニューロン*i*の出力値である。次に、式(4.3.4)の右辺第1項を

$$\delta_{(p)j}^{(k)} = -\frac{\partial E_p}{\partial x_{(p)j}^{(k)}} = \frac{\partial E_p}{\partial y_{(p)j}^{(k)}} \frac{\partial y_{(p)j}^{(k)}}{\partial x_{(p)j}^{(k)}} \quad (4.3.6)$$

と置く。 $\delta_{(p)j}^{(k)}$ はニューロン*j*の誤差と呼ぶ。右辺第2項は式(4.3.4)より

$$\frac{\partial y_{(p)j}^{(k)}}{\partial x_{(p)j}^{(k)}} = f'(x_{(p)j}^{(k)}) \quad (4.3.7)$$

となる。右辺第1項は、出力値 $y_{(p)j}^{(k)}$ が、出力ニューロンの場合と中間層ニューロンの場合、別々に考
える必要がある。出力ニューロンの場合、式(4.3.2)を偏微分すると、

$$-\frac{\partial E_p}{\partial y_{(p)j}^{(k)}} = (d_{(p)j} - y_{(p)j}) \quad (4.3.8)$$

となり、誤差は

$$\delta_{(p)j} = (d_{(p)j} - y_{(p)j})f'(x_{(p)j}) \quad (4.3.9)$$

となる。中間層ニューロンの場合、

$$\frac{\partial E_p}{\partial y_{(p)j}^{(k)}} = -\sum_j \frac{\partial E_p}{\partial x_{(p)j}^{(k)}} \frac{\partial x_{(p)j}^{(k)}}{\partial y_{(p)j}^{(k)}} = \sum_j \delta_{(p)j}^{(k)} w_{ji} \quad (4.3.10)$$

であるため、式(4.3.6)(4.3.7)(4.3.10)より、中間層の誤差は次式で表される。

$$\delta_{(p)j}^{(k-1)} = f'(x_{(p)j}) \sum_i \delta_{(p)j}^{(k)} w_{ji} \quad (4.3.11)$$

これは、1つ後の層から逆伝播された誤差 $\sum_i \delta_{(p)j}^{(k)} w_{ji}$ によってその層の誤差が求められる。

以上をまとめると、結合荷重の更新量は、

$$\Delta w_{ji} = \eta \delta_{(p)j}^{(k)} y_{(p)i}^{(k-1)} \quad (4.2.19)$$

となる。また、オフセットの学習は、常に出力1をとる仮想的なニューロンを考えると結合荷重と同
様に考えることができる。一般に、学習に際して、振動を減らすために慣性項が与えられる。

$$\Delta w_{ji} = \eta \delta_{(p)}^{(k)} y_{(p)}^{(k-1)} + \gamma \Delta w_{ji-1} \quad (4.2.19)$$

ここで、 Δw_{ji-1} は1回前の結合荷重の修正量で、 γ は $0 < \gamma < 1$ で、モーメンタム（慣性係数）と呼ばれる。また、以上では、学習は荷重のみについて考えたが、オフセットやシグモイドの傾きに関しても同様に考えることができるがここでは省略する。

4.4 光学的実現法

4.4.1 光ニューラルモジュール

ニューラルネットワークを光技術によって実現するためには、その構造上の特徴であるシナプス荷重の機能である可変配線や出力関数の機能である非線型処理を実現する必要があり、その他、荷重の保持や情報の表現も考慮する必要がある。ニューラルネットワークの光学的に実現するために必要な機能を以下の6つである。

1. 入出力情報の表現
2. 荷重と入力の積
3. シナプス荷重の保持
4. 空間荷重
5. 時間荷重
6. 出力関数

入出力情報は、光強度によって表現される。直接的なデータ表現によって、負値を表現することは困難であるので、ニューロンの状態が0から1の値で表される[0,1]モデルを採用する。ニューロンの空間荷重和演算は、荷重と入力の積・シナプス荷重の保持・空間荷重により実行され、配線素子・荷重素子・加算素子の組み合せにより実現される。時間荷重と出力関数は、非線型素子の特性を調整することにより実現できる。Fig.4.4.1は光ニューラルネットワークの基本的構成であり、筆者らが提案する光ニューラルモジュールである。これは、配線素子、荷重素子、加算素子、そして非線型素子がスタッカ上に構成され、Fig.4.2.2に示される単層のニューラルネットワークを実現し、図中左から入力信号を受け右に出力信号をする。大規模な光ニューラルネットワークは、これを1モジュールとして多数結合することにより構成される。1モジュールは N 個の入力を持つ N 個のニューロンからなる場合、他のモジュールから来た N 個の入力は、それぞれ配線素子により N 個に分配される。その時、荷重素子により $N \times N$ 個の荷重と入力の乗算が実行され、加算素子により局所的な加算が実行される。そして、非線型素子による処理の後、次のモジュールへと N 個のニューロンの出力が送られる。

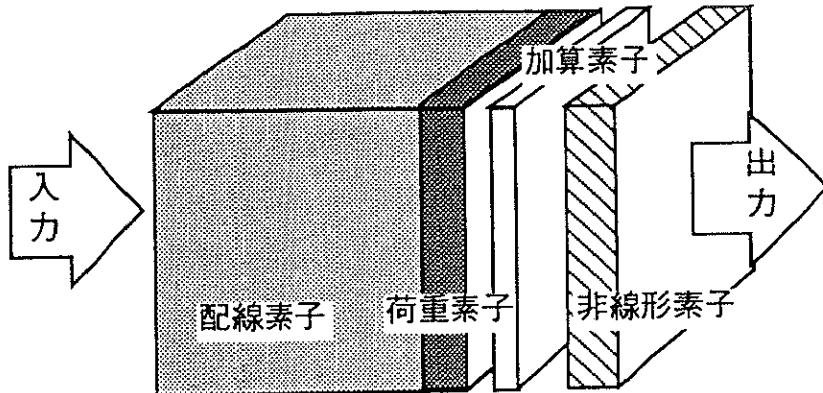


Fig.4.4.1 光ニューラルネットワークの基本的構成（光ニューラルモジュール）

配線素子は、導波路やファイバーによる配線[31][32]が可能であるが、光の並列性を十分に活かすことのできる自由空間伝播型の配線を考える。1対多の配線を行う光の分岐による円筒レンズを含む非対称光学系やレンズアレイによる多重結像光学系[60]がある。また、ホログラムを用いた配線もある。これは、ホログラム中に多数の回折格子を作つておくと入力面の任意の一点からの光を任意の点に荷重配線ができる[61]。その概念図をFig4.4.2に示す。

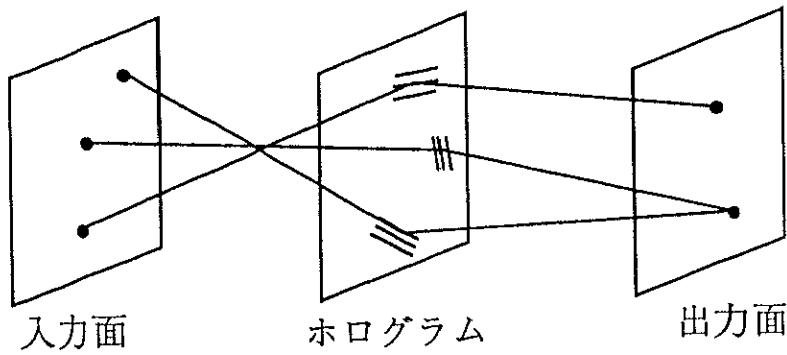


Fig.4.4.2 ホログラムによる配線の概念図

荷重素子は、その荷重が固定の場合、写真フィルムやホログラムなどが用いられる。また、学習によって、荷重を変化させる必要がある場合、空間光変調素子(SLM)[62][63]によって実現される。空間光変調素子は、2次元的に光の強度や偏光を変調する機能を持つ素子で、反射型SLMと透過型SLMがあり、それぞれ、荷重の値は反射率または透過率によって表現される。反射率または透過率の変化量、いわゆる変調度は電気信号または光信号によって変化される。光書き込み透過型SLMの使用の概念をFig4.4.3に示す。反射率または透過率で表現される荷重の値は本質的に非負であるため、抑制性の結合荷重（負の結合荷重と表現される）を実現するためには、その表現法や更新法を含む演

算構造を工夫する必要がある。これらについては、4.5.5でその表現法、4.5.6でその更新法、4.5.7で正のみの荷重で負の荷重を等価的に実現する演算構造について述べる。

加算素子は、レンズの光の合波の機能を利用して実現される。これは配線素子と対応して、その構成が決定される。加算素子含む配線素子を実現する光学系である光ベクトルマトリクス演算器と多重結像光学系は、4.4.2と4.4.3で詳しく述べる。

非線型素子は、空間光変調素子の非線型入出力特性を用いて実現され、4.4.4において空間光変調管を用いて、ニューロンの出力関数を実行した簡単ニューラルネットワークの実験について示す。

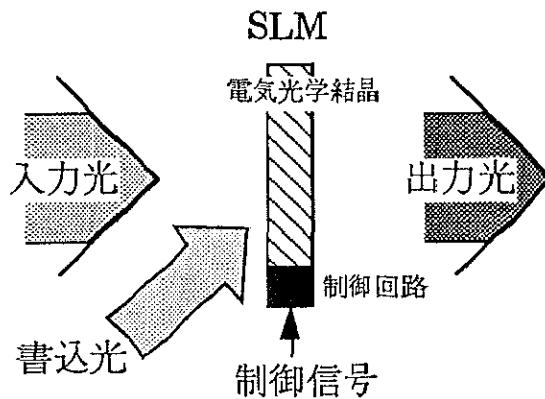


Fig4.4.3 透過型SLMの使用の概念

4.4.2 光ベクトル・マトリクス演算器

ニューラルネットワークの基本演算の一つである荷重和演算を実現する光ベクトル・マトリクス演算器の概念図をFig.4.4.4に示す。これは1次元の発光素子アレイと受光素子アレイの間に2次元マトリクス状の空間光変調素子を置いた構成で、入力 V をその要素 v_i の大きさに応じた光強度を発光素子に与える。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空間光変調素子を通すことにより、入力光強度と透過率を乗じた光となる。更に、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る。実際の光学系は円筒レンズを用いて構成し、そのレンズ配置をFig.4.4.5(a)に示す。また、マトリクス前後の円筒レンズはストライプ状の発光素子、受光素子で置き換えることにより必要ななくなる(Fig.4.4.5(b))。さらに、ストライプ状の発光・受光素子と荷重素子の空間光変調素子をスタック状に集積すれば光学系は必要ななくなる(Fig.4.4.5(c))。光ベクトル・マトリクス演算器は、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、入力出力の大きさには関係なく、とても高速な演算器が構成できる。

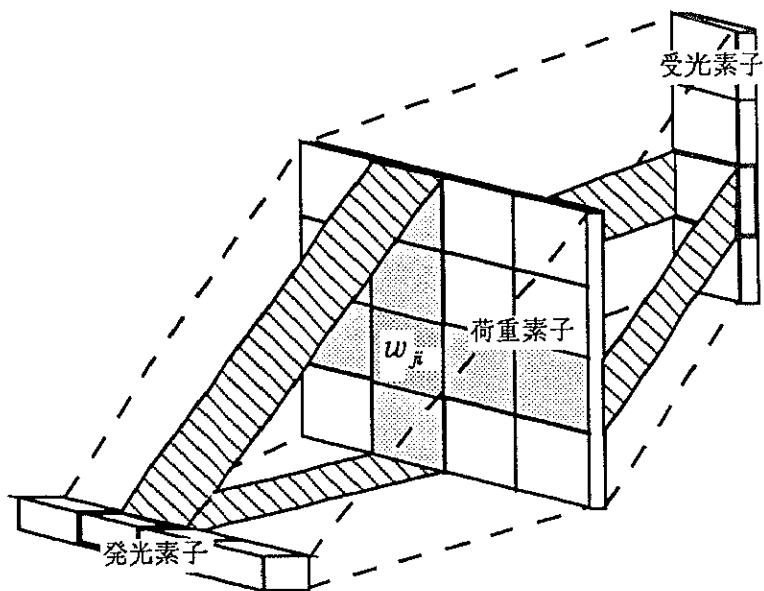
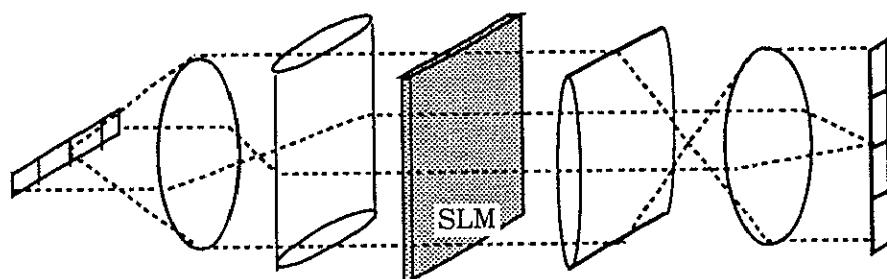
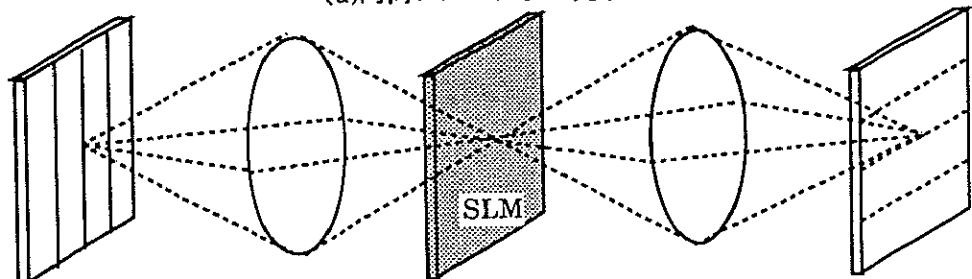


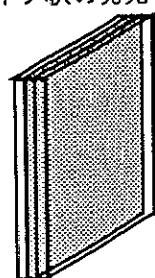
Fig.4.4.4 光ベクトル・マトリクス演算器の概念図



(a)円筒レンズによる光学形



(b)ストライプ状の発光・受光素子



(c)スタック構成

Fig.4.4.5 光ベクトルマトリクス演算器

4.4.3 多重結像光学系

多重結像(Mulatiple Imaging)光学系[60]とは、入力画像の微小複製画像を多数個形成し、個々の複製画像に異なった画像処理を同時並列に実行することができる光学系であり、多くの光情報処理への応用に期待できるがここでは、光ニューラルシステムへの適用について述べる。Fig.4.4.6は多重結像光学系の光ニューラルシステムへの適用の概念図である。ニューロンの入力は画像により表現され、多重結像光学系により複製画像をつくり、荷重素子の結合荷重と乗算が行われ、局所加算(Local accumulation)光学系によりニューロンの加算が行われる。多重結像光学系は、レンズアレイと通常のレンズの組み合せにより構成でき、インコヒーレント照明下及びコヒーレント照明下においては異なるレンズ配置となる。局所加算はレンズアレイにより実行でき、また複製画像と同じ大きさの2次元的に配列した受光素子を用いても実行できる。

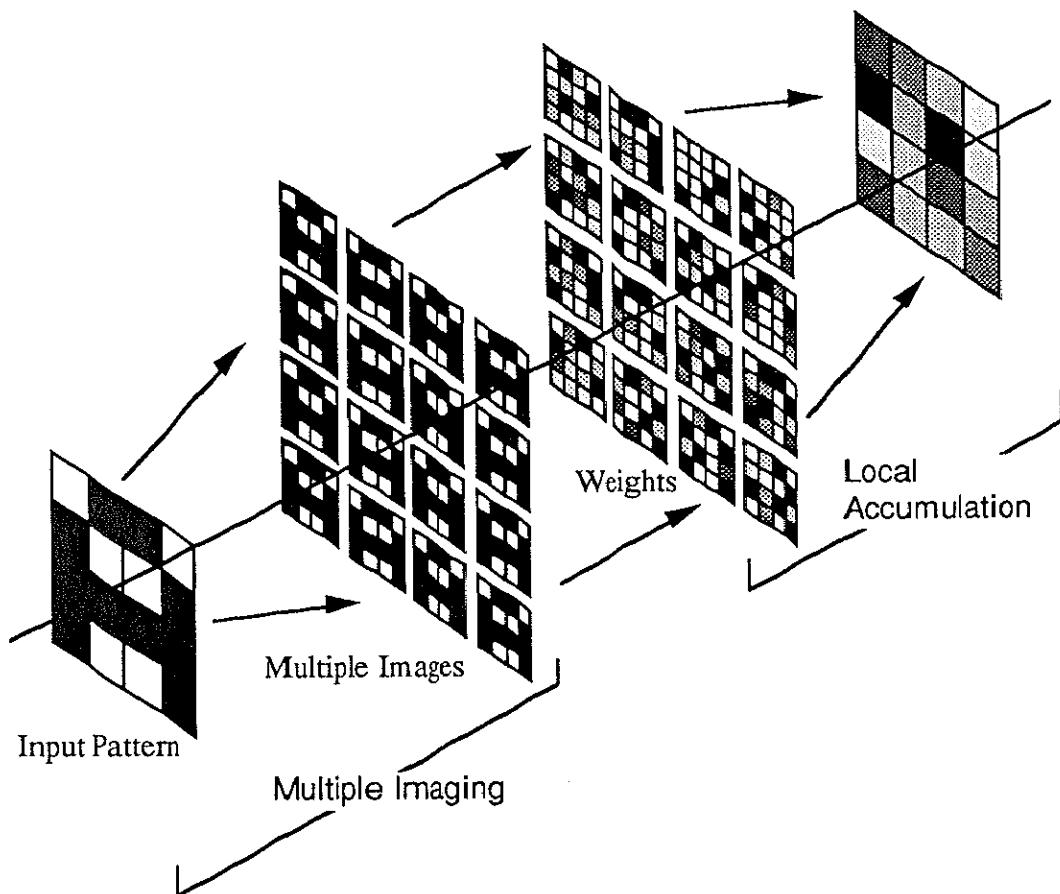


Fig.4.4.6 多重結像光学系の光ニューラルネットワークへの適用の概念図

Fig.4.4.7は、インコヒーレント照明下における多重結像光学系である。入力面(M_1)上の入力画像は、出力面(M_2)上に複製画像が作られる。それぞれの複製画像の明るさのばらつきは照明に指向性

によってきまり、解像度のばらつきは、各マイクロレンズの波面収差のばらつきとコリメーターレンズ L_1 の球面収差が主要因となる。

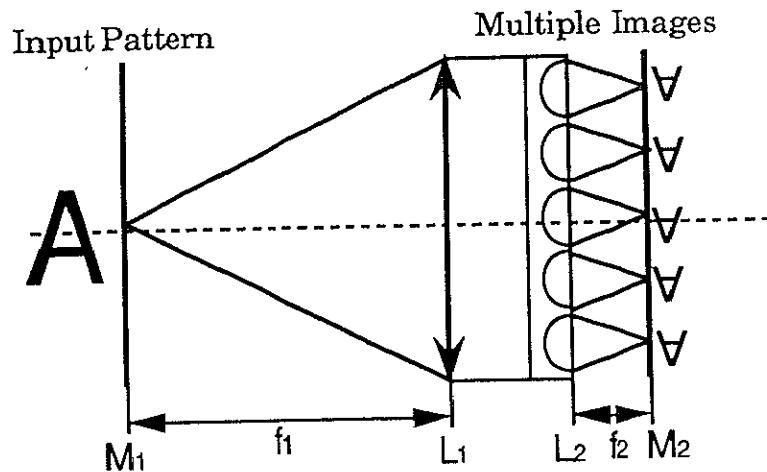


Fig.4.4.7 インコヒーレント照明下における多重結像光学系

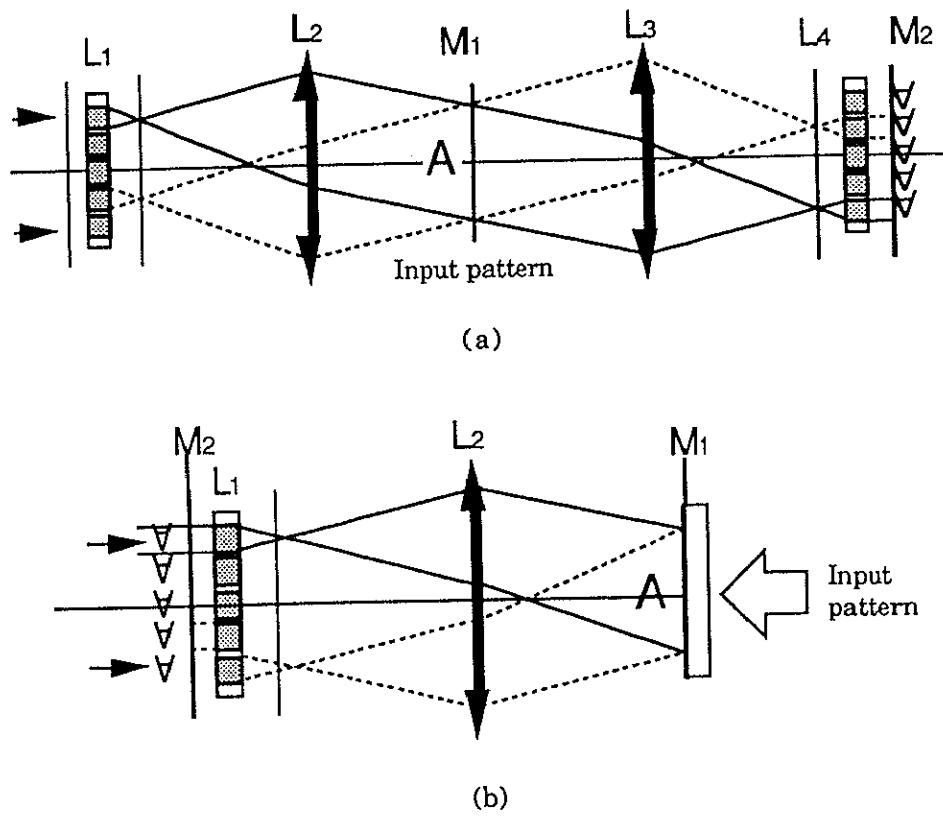


Fig.4.4.8 コヒーレント照明下における多重結像光学系

(a) 透過型入力素子 (b) 反射型入力素子

コヒーレント照明下における多重結像光学系は、それぞれ複製画像のスペクトル分布を等しくするために、インコヒーレントの場合の光学系に比べて多少複雑になる。Fig.4.4.8は、入力画像が透過型の場合(a)と反射型の場合(b)の光学系である。マイクロレンズ L_1 とコリメータレンズ L_2 のアフォーカルな配置によって、 M_1 上の入力画像を様々な方向からコリメート照明する。個々のコリメート照明光は、入力画像により振幅変調され、レンズ L_3 とレンズアレイ L_4 （反射型の場合レンズ L_2 とレンズアレイ L_1 ）により、 M_2 上に複製画像を作製する。

荷重素子は、インコヒーレント照明下及びコヒーレント照明下ともに、 M_2 上に配置され、その後のマイクロレンズを置くことにより、局所加算が実行される(Fig.4.4.8)。

多重結像光学系は、光ベクトルマトリクス演算器と比較すると入力を2次元の画像のまま取り扱えるという利点を持つ。

4.4.4 非線型素子の実現

ニューロンモデルの出力関数は、ニューロンの荷重和（内部状態）を出力に変換する非線型関数で、式(4.2.3)に示されるようなシグモイド関数が多く用いられる。この関数は単調増加の関数であり、空間光変調素子の非線型入出力特性を用いることにより実現できる。ここでは、空間光変調素子の1つである空間光変調管(MSLM)で出力関数のための非線型素子を実現した。Fig.4.4.9は実験光学系であり、LEDアレイでMSLMに書き込み、CCDカメラによって読み出す光学系とパーソナルコンピュータにより構成されている。このシステムには、4ニューロンのニューラルネットワークが実現されていて、ニューロンの出力関数のみ光学的に実行し、その他はパーソナルコンピューターにより実行される。LEDアレイにはニューロンの内部状態がLEDアレイへの印加電圧として表現され、各LEDはその印加電圧に応じて発光する。ここで使用したLEDは、順電圧が0Vから1.5V前後まで発光せず、1.5Vから電圧の増加と発光強度は比較的線型な特性を持つ。

Fig.4.4.10は、LEDの印加電圧が5Vの時のMSLMの書き込み時間と出力光強度の関係である。それぞれの測定値は、4ニューロンに対応していて、それらのばらつきは、LEDの発光強度のばらつきとMSLMの経時劣化やシェーディングによるばらつきを含んでいる。Fig.4.4.11はMSLMの書き込み時間を300ms、400ms、500ms、600msとえたとき、LEDの印加電圧と正規化した出力光強度の関係である。これは、シグモイド関数と同様に単調増加であり、シグモイド関数のパラメーター ε が小になるとMSLMの書き込み時間を大にすることに対応している。

このシステムに、

$$\begin{aligned} X1 &= (1, 1, 1, 0) \\ X2 &= (0, 1, 1, 1) \end{aligned} \quad (4.4.1)$$

の2つのベクトルを直交学習を用いて学習させる。Fig.4.4.12は、計算機シミュレーションと光学実験の学習過程における4ニューロンの出力変化である。これは、学習係数は0.2、結合荷重の初期値はランダムで、計算機シミュレーションにおいてパラメーター ε は0.8、実験において、MSLMの書き込み時間は400ms、オフセットは2.1Vに設定した場合である。(a)と(b)は計算機シミュレーションと光学実験における X_1 を入力したときの各学習ステップでの出力で、(c)と(d)は X_2 を入力したときの各学習ステップでの出力である。光学実験と計算機シミュレーションの4つのニューロンは全く同様な振舞いをしていることがわかる。

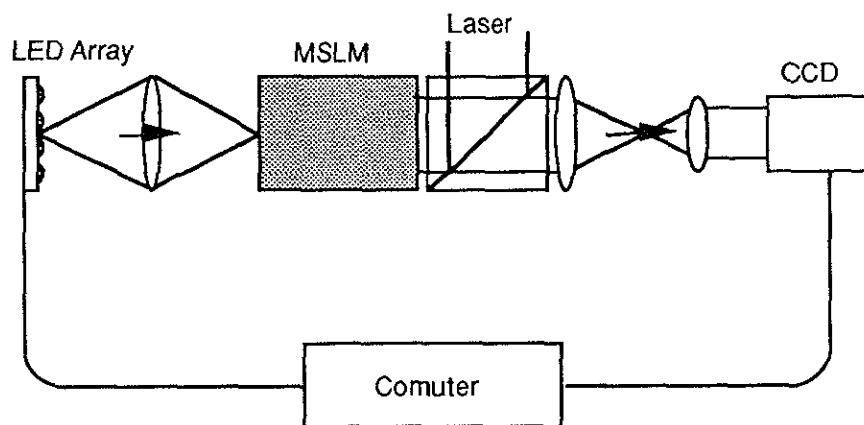


Fig.4.4.9 ニューロンの非線型出力関数を実現する光学系

4.4.5 荷重の表現法

一般に、ニューロンのシナプス荷重は興奮性荷重と抑制性荷重を有し、それらは正と負の荷重に対応している。光によって本質的に負の荷重を実現できないため、荷重の符号は位置表現(Spatial Position Encoding)法[18][64][65]や偏光表現(Polarization Encoding)法[66]-[68]を用いて実現される。位置表現法は、荷重の符号を記憶する位置で表現する手法であり、1つの結合荷重 $W = [w_{ij}]$ に対し、正の荷重 $W^+ = [w_{ij}^+]$ と負の荷重 $W^- = [w_{ij}^-]$ を用意し、入力との乗算結果の差を取り出力関数を施すことにより実行される。式(4.2.4)の荷重和演算と(4.2.5)と非線型演算を位置表現法にそって書き直すと、

$$\begin{aligned} x_j^+ &= \sum_i w_{ji}^+ y_i \\ x_j^- &= \sum_i w_{ji}^- y_i \end{aligned} \quad (4.4.1)$$

と

$$y_j = f(x_j^+, x_j^-) \quad (4.4.2)$$

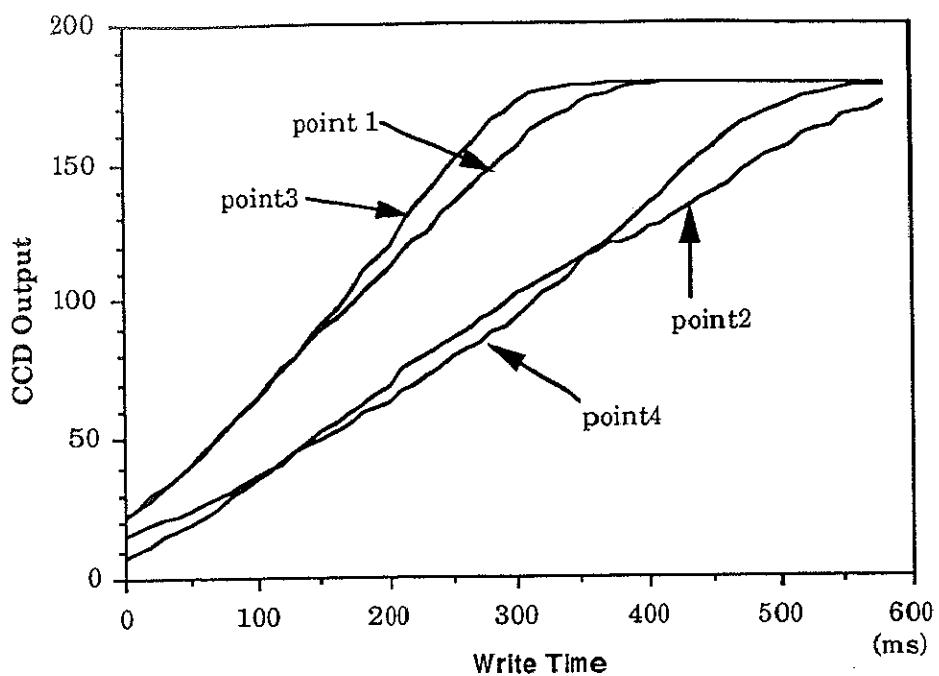


Fig.4.4.10 MSLMの書き込み時間と出力光強度の関係(LED印加電圧5V)

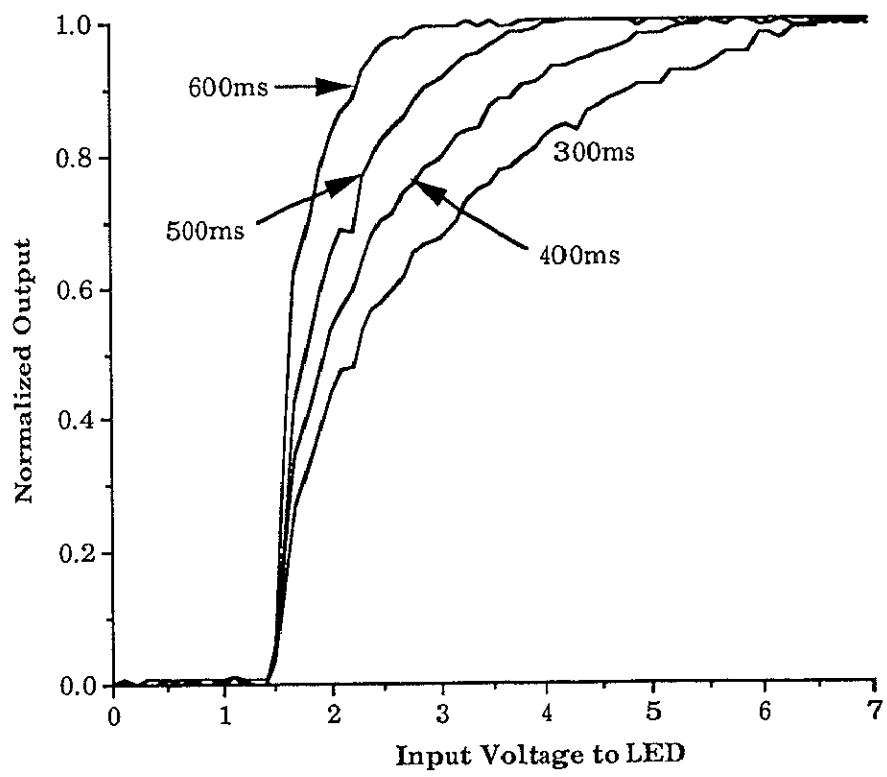
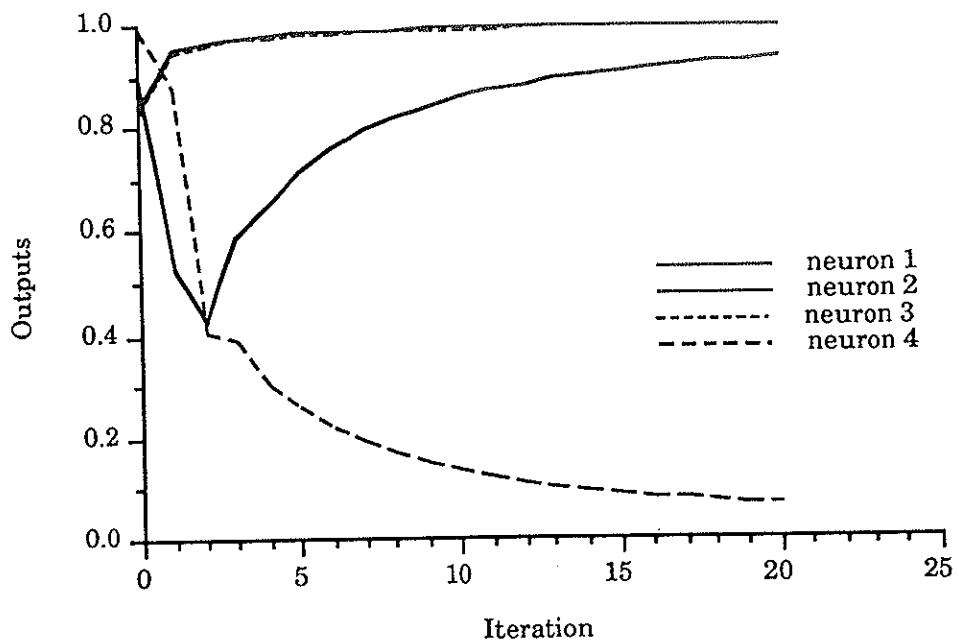
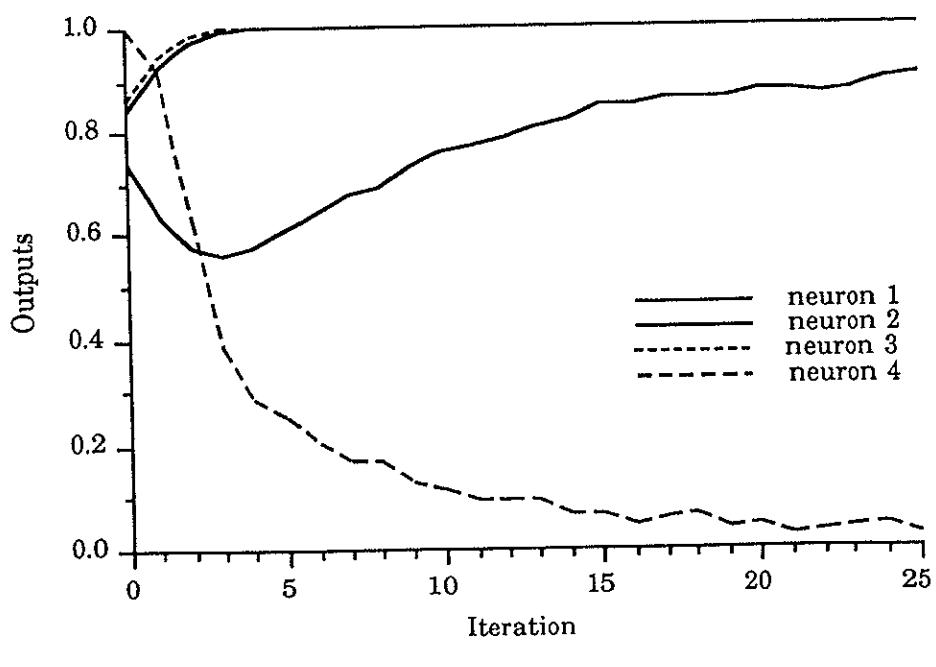


Fig.4.4.11 MSLMの書き込み時間を300ms、400ms、500ms、600msと変えたとき、LEDの印加電圧と正規化した出力光強度の関係



(a)



(b)

Fig.4.4.12 $X1 = \{1, 1, 1, 0\}$ を入力したときのニューロンの出力
 (a) 計算機シミュレーション (b) 光学実験

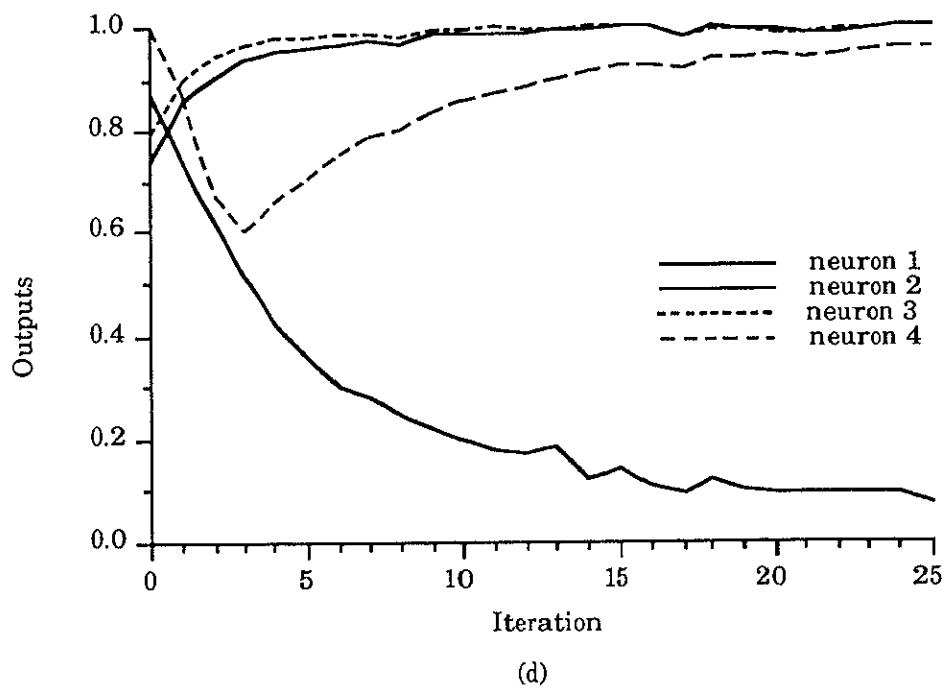
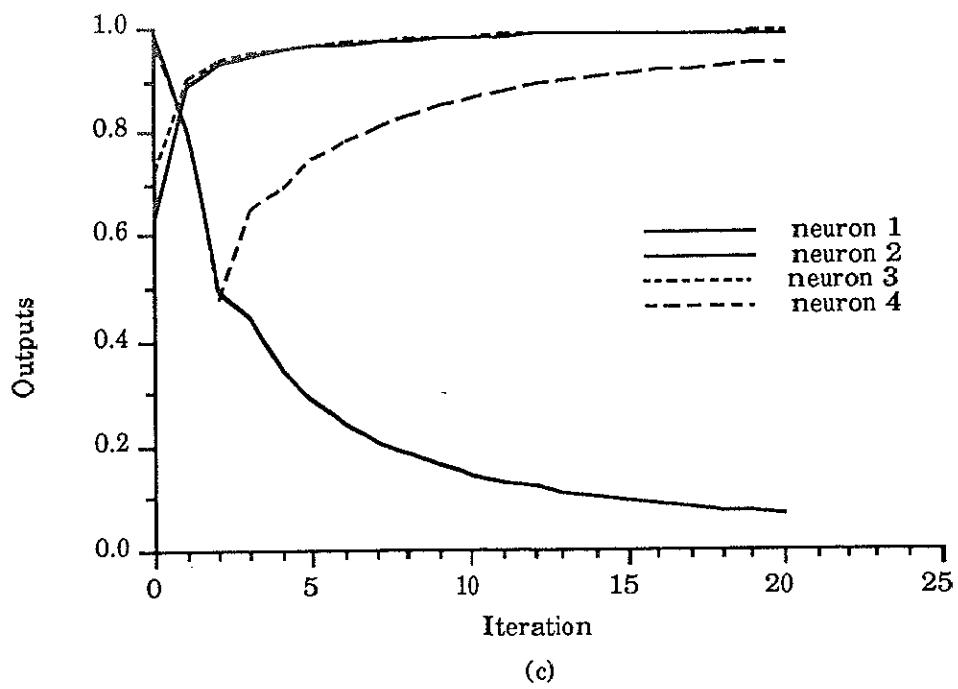


Fig.4.4.12 $\mathbf{X}_2 = \{0, 1, 1, 1\}$ を入力したときのニューロンの出力
(c) 計算機シミュレーション (d) 光学実験

になり、 x^+ と x^- は正と負の荷重和である。ここで、しきい値は省略している。この方法は、配置の仕方で2通りあり、それぞれ遠配置(far distribution)と近配置(near distribution)と呼ばれる[37]。Fig.4.4.13(a)の遠配置は、正の荷重全体と負の荷重全体は分離していて、対応する正負の荷重は隣接していない。Fig.4.4.13(b)の近配置は、正負の荷重は混在していて、対応する結合荷重が隣接している。これらは、9個の入力信号を受ける6個のニューロンの場合の多重結像系に関し示したものであり、多重結像の数は、遠配置で12個、近配置で6個必要であることがわかる。電気的な加算を行う場合、近配置の方が、対応する荷重が近いため、引算を行うための回路の配線が単純になるために有効であると考えられる。しかし、遠配置では正負の荷重が混在していないため、局所加算が光学的に実現できるため、純光学的実現を行う場合は有効であると考えられる。

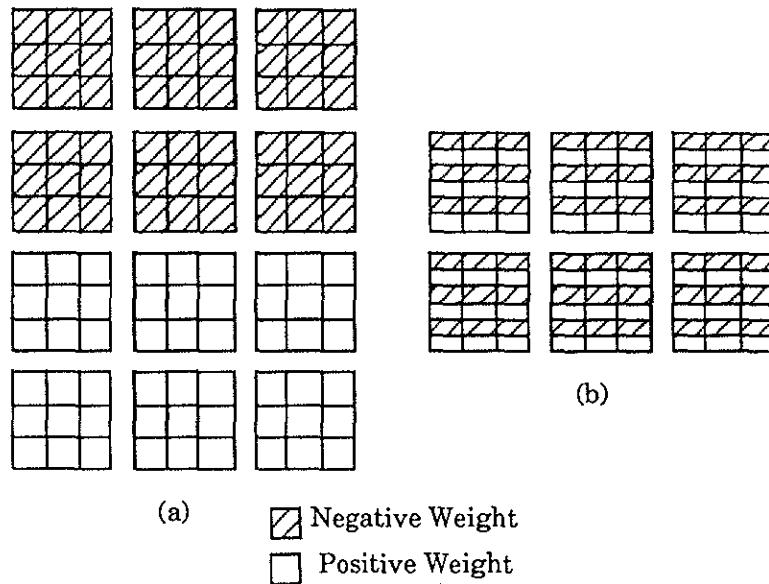


Fig.4.4.13 位置表現法の荷重配置

(a) 遠配置(Far distribution) (b) 近配置(Near distribution)

位置表現法において、1つの荷重に対して正負の荷重を用意するため、2倍の荷重素子が必要である。これはそれぞれの荷重が正になるか負になるかあらかじめ解っていないからである。そこで、荷重を正になるか負になるかを前もって決める方法によって、荷重素子の個数を元のニューラルネットワークと同じにした場合のシミュレーションを行ったので、その結果について示す。Fig.4.4.14(a)は、入力層ニューロン2、出力層ニューロン1で、中間層ニューロン数を変えてXORをBP法を用いて学習させたときの横軸に中間層のニューロン数、縦軸に荷重の初期値を100通り変えたときの収束個数を

示す。また、Fig.4.4.14(b)は平均収束回数を示す。このシミュレーションにおける各パラメーターおよび条件を以下に示す。

学習係数 $\eta = 1.0$

慣性係数 $\gamma = 0.5$

シグモイドの非線型係数 $\epsilon = 1.0$

荷重の初期値範囲 $|w_{ij}| < 1.0$

収束条件 $RMS/2 < 0.01$

条件は、以下の5つについて行う。

条件A 荷重の値に条件を加えない。

条件B 各層の荷重の1/2がそれぞれ正の荷重と負の荷重、オフセットも同様。

条件B' 条件Bにおいてオフセットに条件を加えない。

条件C 各ニューロンの荷重の1/2がそれぞれ正の荷重と負の荷重、オフセットも同様。

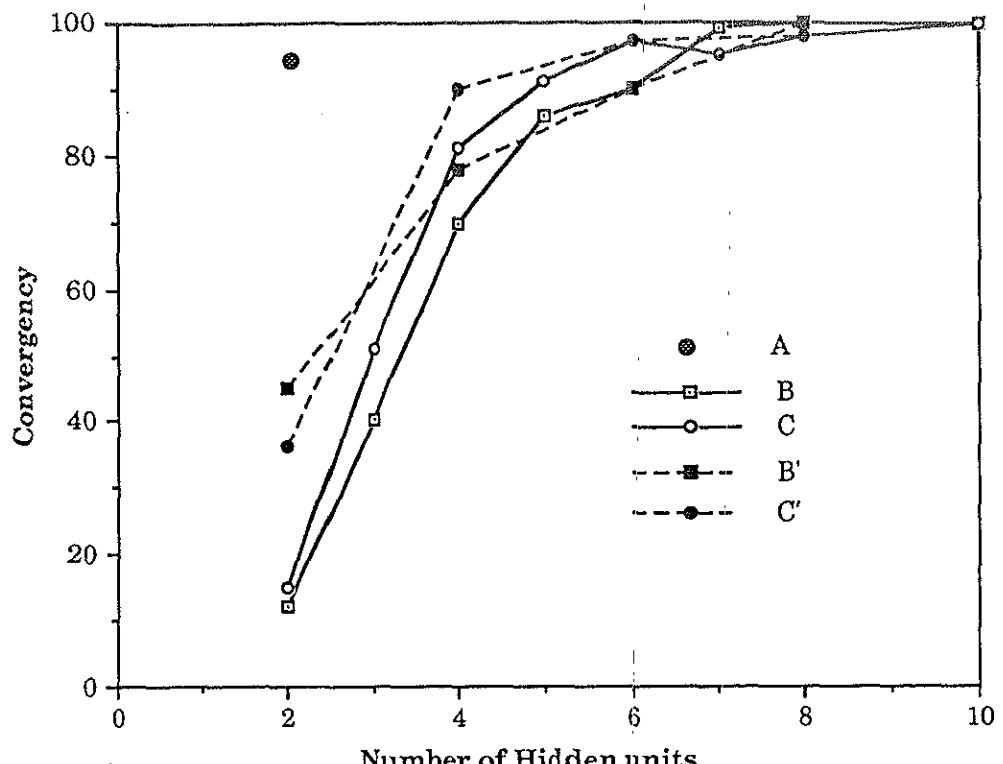
条件C' 条件Cにおいてオフセットに条件を加えない

BとCを比較した場合、Cの方が収束率が高く、学習回数は少ない。しかし、ニューロン数2の場合にはそれらはほとんど変わらない。これは、XORを学習可能な中間層ニューロン数は2であるため、収束する荷重の初期値は、収束後の荷重の値と正負が同じ場合のみ収束するためである。それは、中間層ニューロン数2の場合の収束回数が極端に低いことからも解る。また、B'やC'をBやCと比較した場合、中間層ニューロン数が少ない（4以下）時、収束率は高くなる。これは、学習が主にオフセット（シグモイド関数のシフト）によって行われていることを示す。CがAと同じ能力になるためには、中間層ニューロン数6程度必要であり、これは元のニューロン数の2.5倍である。荷重の正負を前もって決める方法は、ニューロン数を少なくするという点においてはあまり有効でない。しかし、実際のニューロンが抑制性と興奮性の荷重には同時になり得ないという相似性とニューロン数は十分に多いという場合この方法は有効であると考えられる。

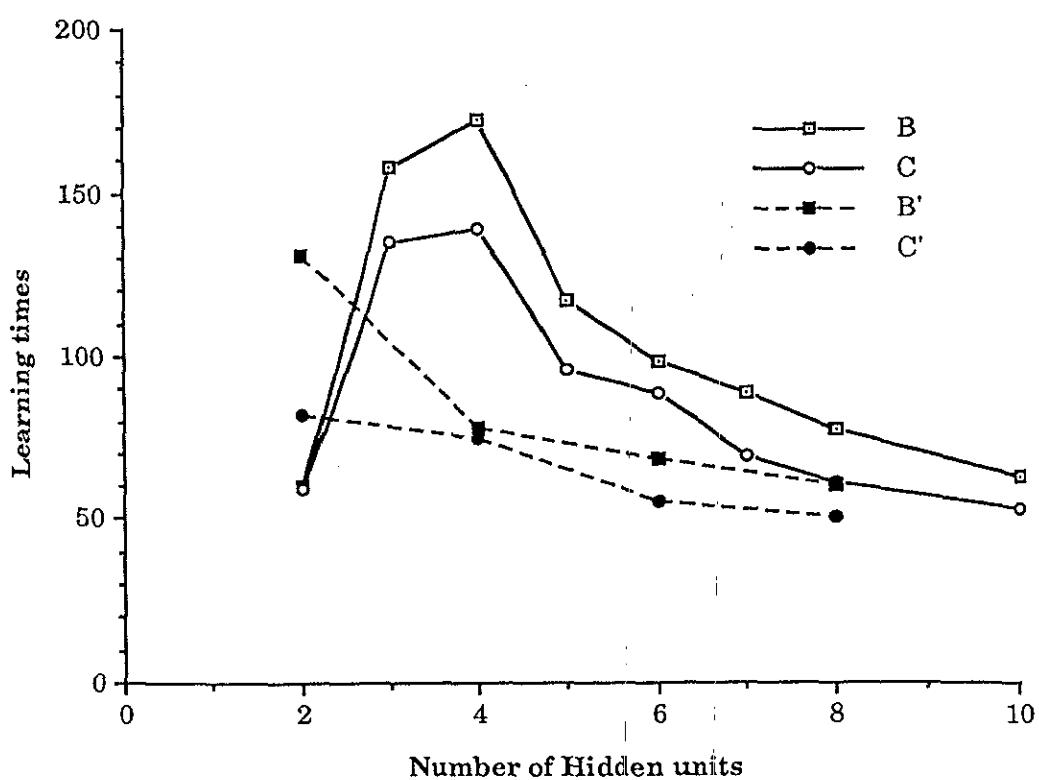
4.4.6 荷重の更新法

4.4.5で示した荷重の位置表現法によって、荷重 $\mathbf{W} = \{w_{ij}\}$ を正の荷重 $\mathbf{W}^+ = \{w_{ij}^+\}$ と負の荷重 $\mathbf{W}^- = \{w_{ij}^-\}$ に分ける。そのため、BP法などの学習アルゴリズムによって計算された荷重の更新値を正の荷重と負の荷重に分配する必要がある。ここでは、その分配の方法として我々が提案した単方向更新法と双方向更新法について示す[64][69]。

ここで、ある学習アルゴリズムによって、荷重 $\mathbf{W} = \{w_{ij}\}$ の更新値 $\Delta\mathbf{W} = \{\Delta w_{ij}\}$ が与えられた時、正の荷重の更新値と負の荷重の更新値を $\Delta\mathbf{W}^+ = \{\Delta w_{ij}^+\}$ と $\Delta\mathbf{W}^- = \{\Delta w_{ij}^-\}$ とすると、単方向更新法の場合、そ



(a)



(b)

Fig. 4.4.14 荷重の正負をあらかじめ決めておく方法

- (a) 中間層ニューロン数に対する収束率
- (b) 平均収束回数

それぞれの荷重の更新値は、

$$\begin{aligned}\Delta w_{ij}^+ &= \Delta w_{ij} & (\Delta w_{ij} \geq 0) \\ \Delta w_{ij}^- &= -\Delta w_{ij} & (\Delta w_{ij} < 0)\end{aligned}\quad (4.4.3)$$

であり、正と負の荷重は増加するだけで、単方向の変化である。双方向更新法の場合、

$$\begin{aligned}\Delta w_{ij}^+ &= r\Delta w_{ij} & \Delta w_{ij}^- = -(1-r)\Delta w_{ij} & (\Delta w_{ij} \geq 0) \\ \Delta w_{ij}^+ &= (1-r)\Delta w_{ij} & \Delta w_{ij}^- = -r\Delta w_{ij} & (\Delta w_{ij} < 0)\end{aligned}\quad (4.4.4)$$

であり、正の荷重と負の荷重は増減する。ここで、 r は、 $0 < r < 1$ の正の定数であり配分率と呼ぶ。

単方向更新法は $r=1$ の場合の相当する。

これらの更新法は、配分率 r の値に対し数学的には等価であるが、実際に用いられる荷重素子は、非線型性や飽和、増減(正負)方向の特性の差があるため、配分率 r の設定によってニューラルネットワークの動作は大きく異なり、性能に影響する。特に、素子の飽和は荷重のとり得る最大値を決定するため、荷重がその最大値になると学習が進行しないという現象が起こる。実際の光ニューラルネットワークにおける荷重素子の最大値は、素子が飽和したときの光強度と荷重の変更可能な最小の光強度に関連するダイナミックレンジによって決定される。

ここでは、BP学習則を用いて入力層ニューロン数2、中間層ニューロン数2、出力層ニューロン数1の3層のニューラルネットワークにXORの学習を行う。学習は、以下に示すパラメーターで、異なる条件下で計算機シミュレーションを行った場合の結果について示す。

荷重の学習係数 $\eta = 0.7$ または $\eta = 0.1$

オフセットの学習係数 $\beta = 0.3$

慣性係数 $\gamma = 0.0$

シグモイドの非線型係数 $\epsilon = 0.5$

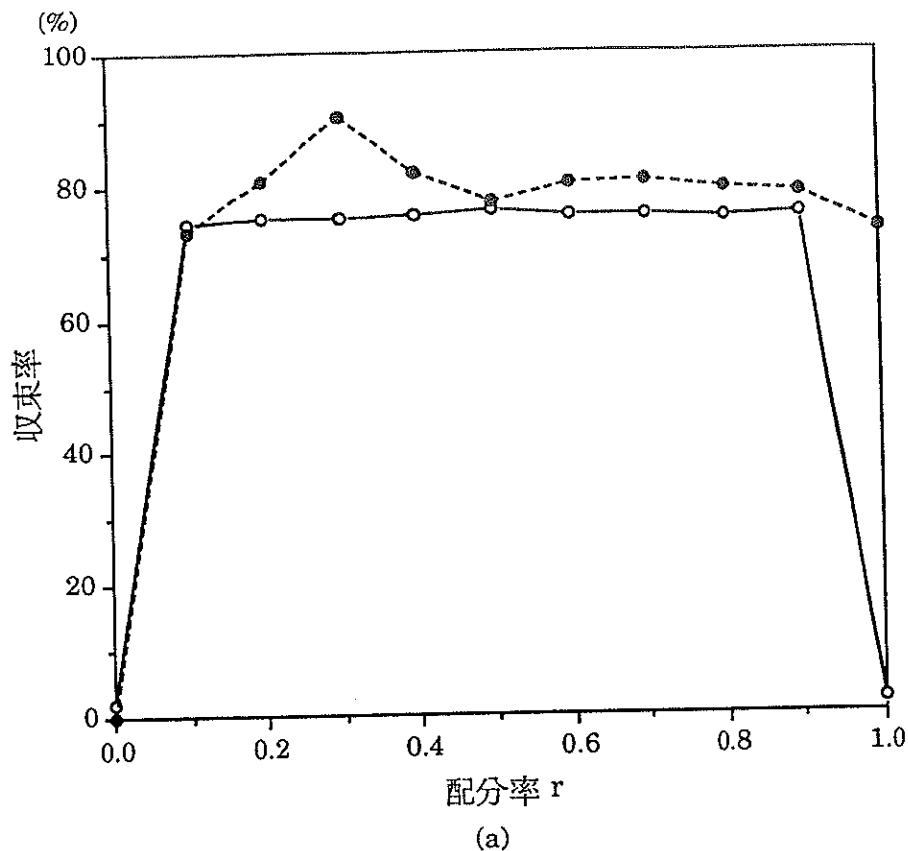
収束条件 $RMS/2 < 0.01$

Fig.4.4.15は、荷重の最大値が5の場合の配分率 r に対する収束率(a)と平均収束回数(b)を示す。正と負の荷重の初期値の条件を以下の二つの場合で比較している。

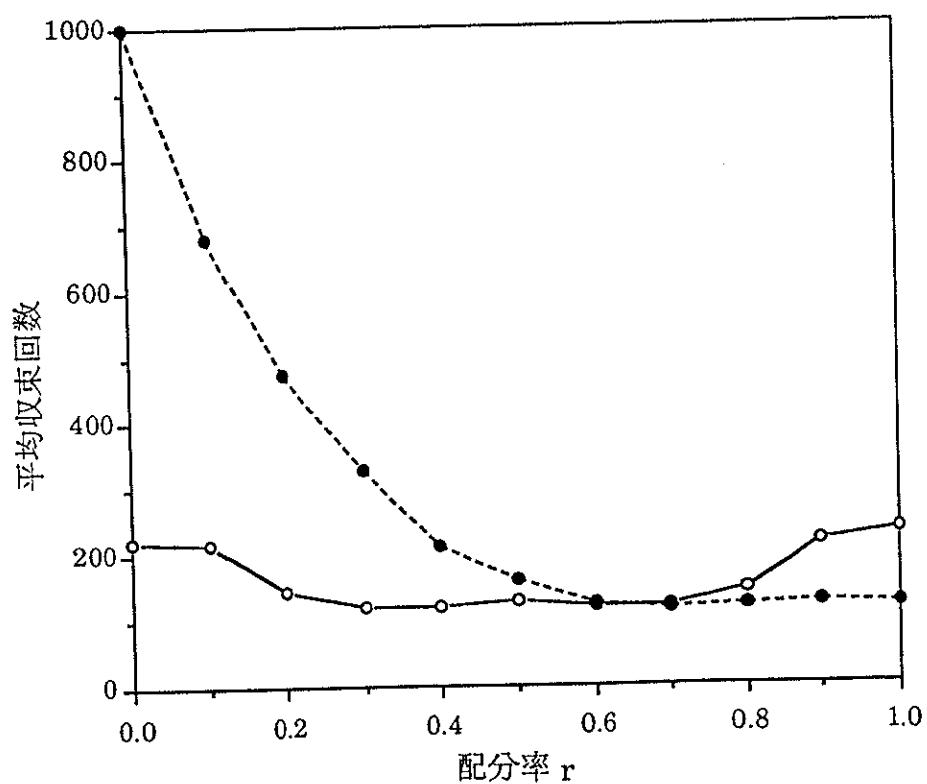
条件A 荷重の最大値の1/2を中心とした乱数(実線)

条件B 荷重の初期値を0近辺の乱数

Fig.4.4.15(a)の収束率を見ると、条件Aの場合、 $r=0.5$ で収束率が最大となり、 $r=0.5$ を中心として能力的には対称であり、単方向更新法に対応する $r=1.0$ では、収束率は0%である。これは、荷重の最大値(ダイナミックレンジ)が半分になることに相当するためである。条件Bの場合 $r=0.3$ で収束率が最大、条件Aと比較して、全体的に収束率は高くなる。 $r=1.0$ では収束率は73%であり、条件Aに比べて高くなる。Fig.4.4.15(b)の平均学習回数を見ると、条件Aの場合、 $r=0.5$ で平均学習回数が最小



(a)



(b)

Fig. 4.4.15 荷重の最大値が5の場合の配分率 r に対する収束率(a)と平均収束回数(b)
 実線 条件A 荷重の最大値の1/2を中心とした乱数
 点線 条件B 0近辺の乱数

となり、同様に $r=0.5$ を中心として能力的には対称である。条件Bの場合、单方向更新法の $r=0.0$ で最小、分配率 r の減少とともに増大する。これは、荷重が負の値を持たないため、配分率が少ないとところでは、減算に分配される更新量が増し、等価的に学習係数が低くなるためである。Table.4.4.1は、学習係数が小さい場合($\eta = 0.1$)と大きい場合($\eta = 0.7$)について、学習を荷重の初期値をかえて1000回の試行で、以下の3つの場合についてその収束した数を比較した表です。

1. 荷重の制限がない場合
2. 荷重の最大値3で单方向更新法($r=1.0$)で荷重の初期値を0近辺
3. 荷重の最大値3で双方向更新法($r=0.5$)で荷重の初期値を1.5近辺

学習係数が小さい場合、すなわち学習の過程において振動が起こりにくい場合は、両方法ともその収束率は変化ないが、学習係数が大きい場合、振動が起こり易い場合は、双方向更新法の方がかなり収束率が高いことがわかる。

結論としては、双方向更新法は、单方向更新法に比べて、振動の多い場合には、収束率及び収束回数の結果は良くなる。その場合、分配率 $r=0.5$ の場合が最も良い結果が得られる。しかし、ダイナミックレンジが半分になるため、学習係数が小さく振動を少ない場合、収束率が悪化する場合がある。

Table.4.4.1 荷重の最大値3の場合について、学習係数の大きさに対する单方向更新法と双方向更新法の収束性の比較。制限なしは荷重の制限がない場合。

	学習係数小（振動なし）	学習係数大（振動あり）
制限なし	767	762
单方向更新法	747	47
双方向更新法	767	754

4.4.7 反転入力重ね合わせ法[69]

a. 反転入力重ね合わせ法の原理

ニューラルネットワークの光学的実現は、4.4.1に示したような光ニューラルモジュールによって実現できるが、そこには2つの問題がある。1つは、4.4.5で示した光が本質的に負の値が実現できなければならぬため、荷重は正と負の荷重が必要であり、元のニューラルネットワークの2倍の素子が必要なこと

である。正負のニューロンを用意して、この問題を回避するモデルもあり、位置表現法[70]や偏光表現法[71]によって光学的に実現されている。これらは、ニューロン数の2倍の素子を用意すれば良いので、ニューロン数の増加に伴い2乗のオーダで増加する荷重素子を2倍にするよりも必要な素子数は減少するが、素子が元のニューラルネットワークより多くなることは変わらない。もう1つは、入出力の情報表現を光強度を用いているため、光学的に減算を行うのは容易でない。また、減算はコヒーレント光の位相差[72]を使うことによって実現できるが、その光学系は高い精度と高い定常性を要求する。

反転入力重ね合わせ法は、これらの問題を解決するための光学的実行モデルで、その特徴を以下に示す。

1. ニューロンの状態や荷重の値は全て非負値
2. 正の加算と乗算で全ての計算が実行可能
3. 荷重やニューロンに2倍の素子を必要としない

これらの特徴から、その光学的実現において、光学素子の単純な配置により実行でき、電気的減算を必要としないため全光学的構成が可能である。この方法は、バイアスのかけられた荷重と入力の荷重和に入力の反転を重ね合わせると、減算は定数となり、全て出力関数のオフセットとすることが可能であるというモデルであり、その原理を示す。

式(4.2.4)と(4.2.5)のニューラルネットワークの基本式を説明のためにもう一度示すと、

$$x_j = \sum_i w_{ji} v_i - h_j, \quad (4.4.5)$$

$$y_j = f(x_j), \quad (4.4.6)$$

である。結合荷重 w_{ji} と荷重和 x_j は一般に有限の実数である。入力 v_i と出力 y_j は、多くのモデルで0から1の実数である。ここで、2つの定数 α と β を導入して、(4.4.5)を書き直すと、

$$x_j = \sum_i (w_{ji} + \alpha) v_i + \alpha \sum_i (\beta - v_i) - N \alpha \beta, \quad (4.4.7)$$

ここで、 N はニューロン数である。また、ニューロンのしきい値である h_j は荷重と同様に取り扱うことができるため省略されている。定数 α は荷重のバイアスであり、以下のように決定される。

$$\alpha > -\min(w_{ji}), \quad (4.4.8)$$

ここで、 $\min(w_{ji})$ は荷重 $\mathbf{W} = \{w_{ji}\}$ の最小値である。バイアス荷重 $\mathbf{W}^b = \{w_{ji}^b\} = \{w_{ji} + \alpha\}$ は必ず正の実数である。定数 β は式(4.4.7)の第2項が正となるために導入され、以下のように設定される。

$$\beta > \max(v_i), \quad (4.4.9)$$

ここで、 $\max(v_i)$ は入力 $\mathbf{V} = \{v_i\}$ の最大値を示す。式(4.4.7)の第2項の $\nabla = \{\bar{v}_i\} = \{\beta - v_i\}$ はすべて正であり、 $\beta = 1$ とすると入力の反転信号になる。式(4.4.7)の第2項の第3項 $N \alpha \beta$ は、定数 α と β が前もって決定されるので非線型出力関数のオフセットとして取り扱うことができる。よって、式(4.4.5)、

(4.4.6)は、

$$\bar{x}_j = \sum_i w_{ji}^b v_i + \alpha \sum_i \bar{y}_i \quad (4.4.10)$$

$$y_j = g(\bar{x}_j), \quad (4.4.11)$$

ここで、

$$g(x) = f(x - N\alpha\beta). \quad (4.4.12)$$

と書き換えることができる。式(4.7.10)の $\mathbf{X} = \{\bar{x}_j\}$ は、荷重和 $\mathbf{X} = \{x_j\}$ に定数 $N\alpha\beta$ を加えた正の実数であり、入力とバイアスされた荷重による荷重和 $\sum_i w_{ji}^b v_i$ と入力の反転の和 $\alpha \sum_i \bar{y}_i$ の加えたものである。このことから、この実行モデルを反転入力重ね合わせ法と呼ぶ。

Fig.4.4.16は式(4.7.10)を光学的に計算するブロックダイアグラムである。これは、第1項を計算する荷重配線(Weighted interconnections)と第2項を計算する反転パターン発生器(Reversal pattern generator)で構成される。ニューロンの入力信号 \mathbf{V} は入力面(Input plane)上に発生され、PATH1で入力の荷重 $\mathbf{W}^b \mathbf{V}$ が計算され、PATH2で反転入力 \mathbf{V} が発生され、それらは出力面(Output plane)で重ね合わされる。

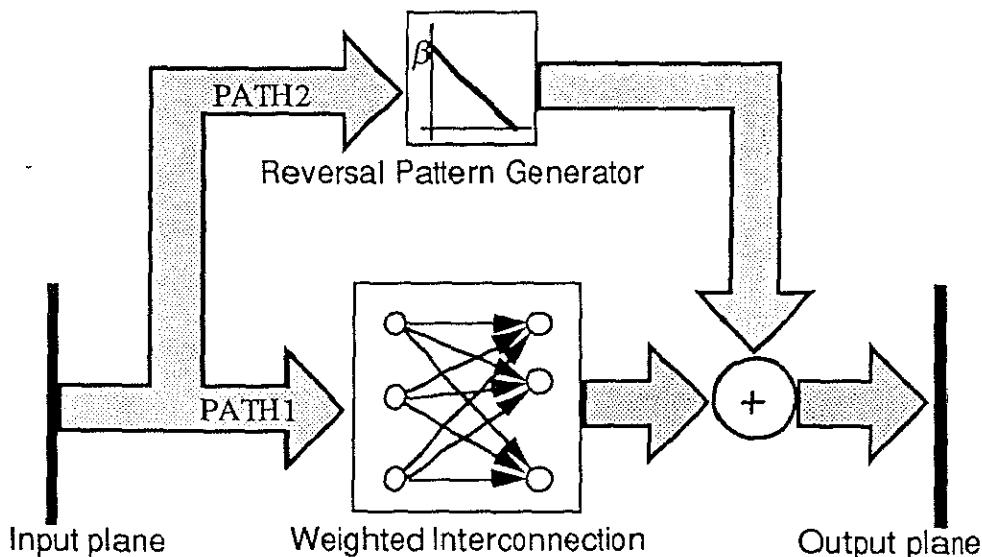


Fig.4.4.16 反転入力重ね合わせ法のブロックダイアグラム

b. 同時発生法—入力パターンと反転パターンのを同時に発生させる方法

反転入力重ね合わせ法は、入力パターンと反転パターンが同時に必要とする。これは、入力信号を偏光パターンに変調する偏光コード化法(Polarization encoding procedure)[67]を用いることによつ

て実現できる。この入力パターンと反転パターンを同時に得る手法は同時発生法(Parallel Generating Method)と呼ばれ、Fig.4.4.17はその原理を示している。まず、入力信号は偏光パターンに変調される。入力信号が0の場合、垂直方向に関し偏光角0°の偏光パターンに変調され、入力信号が1の場合、垂直方向に関し偏光角90°の偏光パターンに変調される。0から1の中間的な値は、0°から90°の間の偏光角の偏光パターンに変調される。その偏光パターンはビームスプリッターによって2つの光に分けられる。それぞれの光を垂直方向(0°)および水平方向(90°)にセットした検光子に通過させることにより入力パターンと反転パターンが同時に得られる。図中で、ビームスプリッターの代わりに偏光ビームスプリッターを用いることにより、2枚の検光子は必要なくなる。

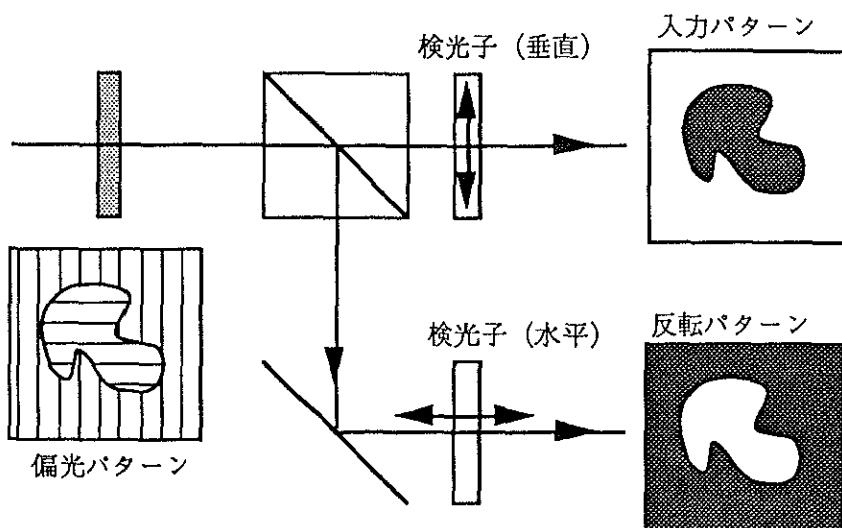


Fig.4.4.17 同時発生法の概念図

偏光コード化法を用いて入力パターンと反転パターンを同時に得る方法

4.5 3層光ニューラルシステム

4.5.1 システム概要

本節では、入力層、中間層、出力層の3層を持つニューラルネットワークを実現した光ニューラルシステムについて報告する。入力層、中間層、出力層のニューロン数は、それぞれ、2、2、1であり、そのニューラルネットワークに論理関数XORの入出力関係をBP学習則[6]を用いて学習させた。2層のニューラルネットワークでは、線型識別機能を持っているため、線型分離でないXORは識別不可能である。3層のニューラルネットワークは、凸領域の識別が可能であるため、XORなどの非線型識

別が可能である。

3層光ニューラルシステムは荷重の正と負の値の対し、正の荷重と負の荷重を用意する位置表現法 [18]が適用される。その荷重の更新法である単方向更新法と双方向更新法を光ニューラルシステムにおいて実行された。また、3層構造のニューラルネットワークを実現するためにマトリクス分割法 [28]を用いた。この方法はマトリクス状に配置した荷重をサブマトリクスに分割して、入力層から中間層と中間層から出力層の荷重をそのサブマトリクスに配置する方法である。これら、位置表現法とマトリクス分割法を融合して3層構造の光ニューラルネットワークの学習実験を行ったはじめての試みである。また、BP学習を光学的に実現する多くの提案[29][73]はあったが、はじめてシステムとして動作させ、学習実験を行った。さらに学習実験を通して、提案した荷重の更新法の実験的検証と実際のシステムにおけるパラメーターの評価と各デバイスの評価を行った。

4.5.2 システム構成

入力層、中間層、出力層、それぞれのニューロン数が2、2、1である3層構造のニューラルネットワーク(Fig.4.5.1)に論理関数XORの入出力関係(Fig.4.5.2)を学習させることを考える。これは、XORが学習可能な最小数のニューロン数である。このネットワークにおいて、入力層ニューロンの出力（中間層ニューロンへの入力）を $\mathbf{I} = \{i_1, i_2\}$ 、中間層ニューロンの出力（出力層ニューロンへの入力）を $\mathbf{H} = \{h_1, h_2\}$ 、出力層ニューロンの出力を $\mathbf{O} = \{o_1\}$ 、中間層ニューロンの結合荷重を $\mathbf{W} = [w_{11}, w_{12}, w_{21}, w_{22}]$ 、出力層ニューロンの結合荷重を $\mathbf{V} = [v_{11}, v_{12}]$ とする。

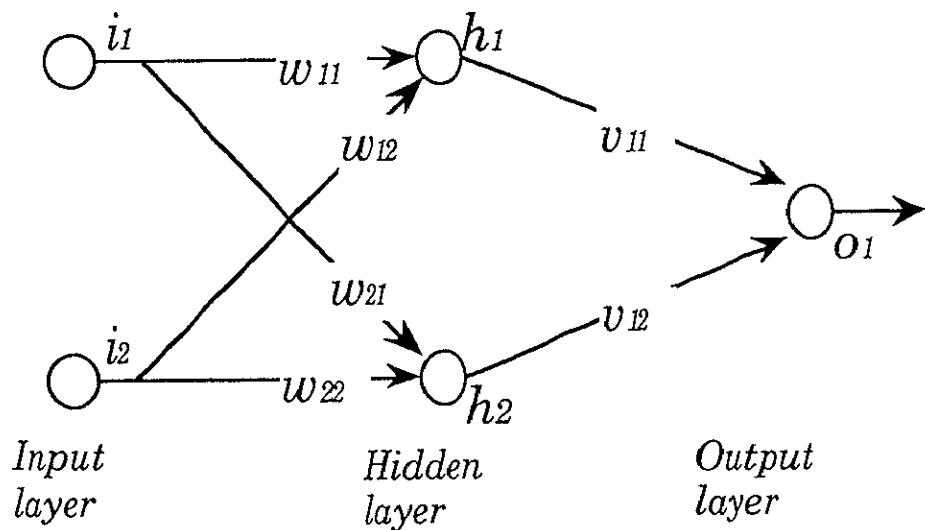


Fig.4.5.1 3層構造のニューラルネットワーク

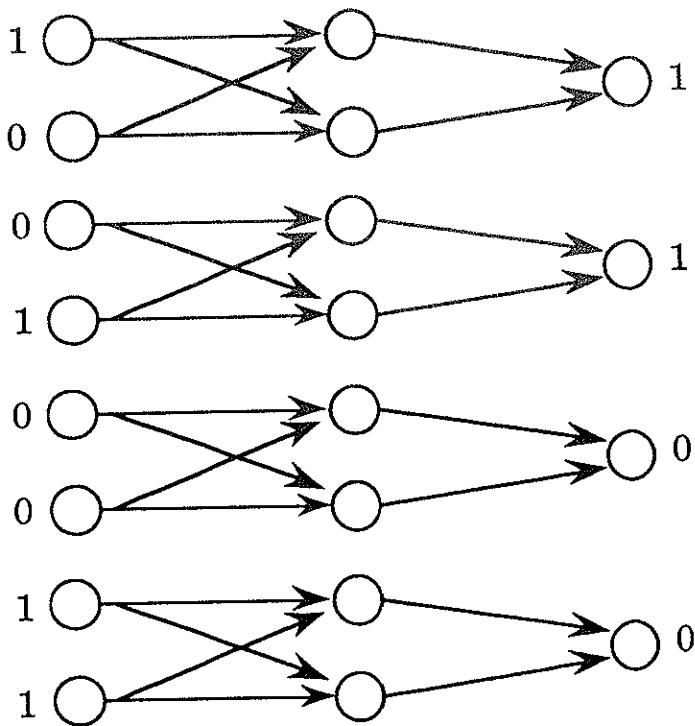


Fig.4.5.2 学習したXORの入出力関係

結合荷重は位置表現法を用いて実現しているため、正の荷重 $\mathbf{W}^+ = \{w_{1p}^+, w_{2p}^+, w_{1p}^+, w_{2p}^+\}$ と $\mathbf{V}^+ = \{v_{1p}^+, v_{2p}^+\}$ 及び負の荷重 $\mathbf{W}^- = \{w_{1p}^-, w_{2p}^-, w_{1p}^-, w_{2p}^-\}$ と $\mathbf{V}^- = \{v_{1p}^-, v_{2p}^-\}$ は、Fig.4.5.3(a)に示すように配置される。また、ニューロンへの入力はストライプ状に表現され、中間層ニューロンへの入力 $\mathbf{I} = [i_1, i_2]$ と出力層ニューロンへの入力 $\mathbf{H} = [h_1, h_2]$ は、Fig.4.5.3(b)に示されるように表現され、入力と荷重の積が実行される。さらに、Fig.4.5.3(c)で示した領域でそれぞれの加算を行い、正と負の荷重に対して別々にベクトルマトリクス演算を行う。そして、対応する加算出力を差を求めニューロンの荷重和とする。

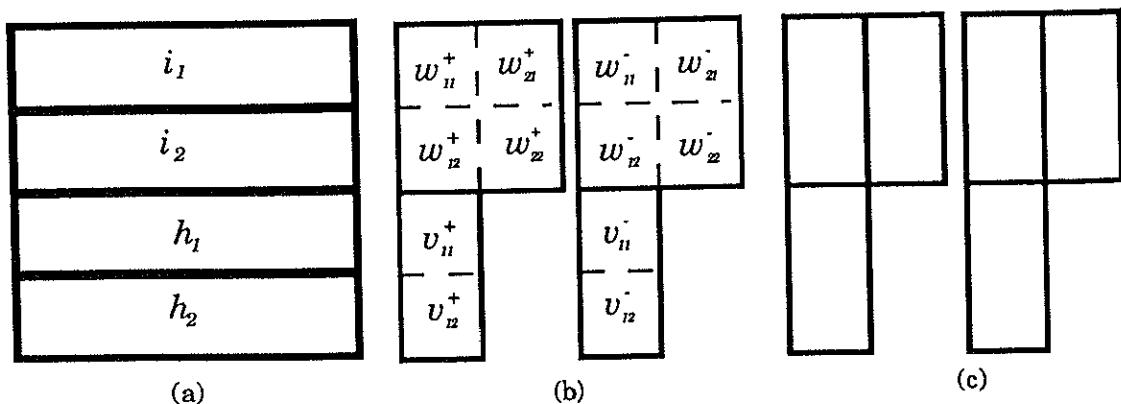


Fig. 4.5.3 演算構造 (a)ストライプ状の入力 (b)荷重の配置 (c) 加算領域

3層構造のニューラルネットワークを実現するために、まず入力層から中間層の荷重和演算と中間層の非線型演算を行い、その結果から中間層から出力層の荷重和演算と出力層の非線型演算を行うことによって実現される。

3層構造のニューラルネットワークを実現する光ニューラルシステムの図(a)と写真(b)をFig.4.5.4に示す。このシステムは、CRT、LCTV、MSLM、CCDカメラ、コンピュータ、レンズなど光学素子から構成されている。光源はHe-Neレーザーを用いる。MSLMはこのシステムのキーデバイスであり、結合荷重を記憶する荷重素子として用いられている。MSLM上の結合荷重は、CRTによってコンピュータで計算された初期値と更新値が与えられ、学習係数はMSLMへの書き込み時間で制御する。LCTVはニューロンへの入力を表示する透過型の変調素子であり、入力は横方向のストライプ状のベクトルで表示される。CCDカメラで受けたMSLMの結合荷重とLCTVの入力の積は、イメージプロセッサーを通してコンピュータに送られる。その後、光ニューラルシステムの結合荷重とその更新用のMSLMとCRTは、より解像度の高いEBSLM(Electron beam addressed spatial light modulator) (付録B) に変更される。EBSLMは、その原理、機能ともMSLMと全く同様であり、MSLMにおいて解像度を制限していた光電子の増幅を行うMCP(Microchannnel Plate)の変わりに、電子ビームでアドレスすることにより解像度を向上させたSLMである。

コンピュータは、縦方向の加算と非線型出力関数、荷重の更新値の計算を実行する。また、コンピュータは、MSLMの電圧の制御等も行う。カメラは結合荷重を記録するためにセットしてある。

4.5.3 学習実験

3層光ニューラルシステムで単方向更新法、双方向更新法による学習実験を行う。そのための基本的なパラメーターを以下に示す。

学習係数 $\eta = 0.4$

オフセットの学習係数 $\beta = 0.3$

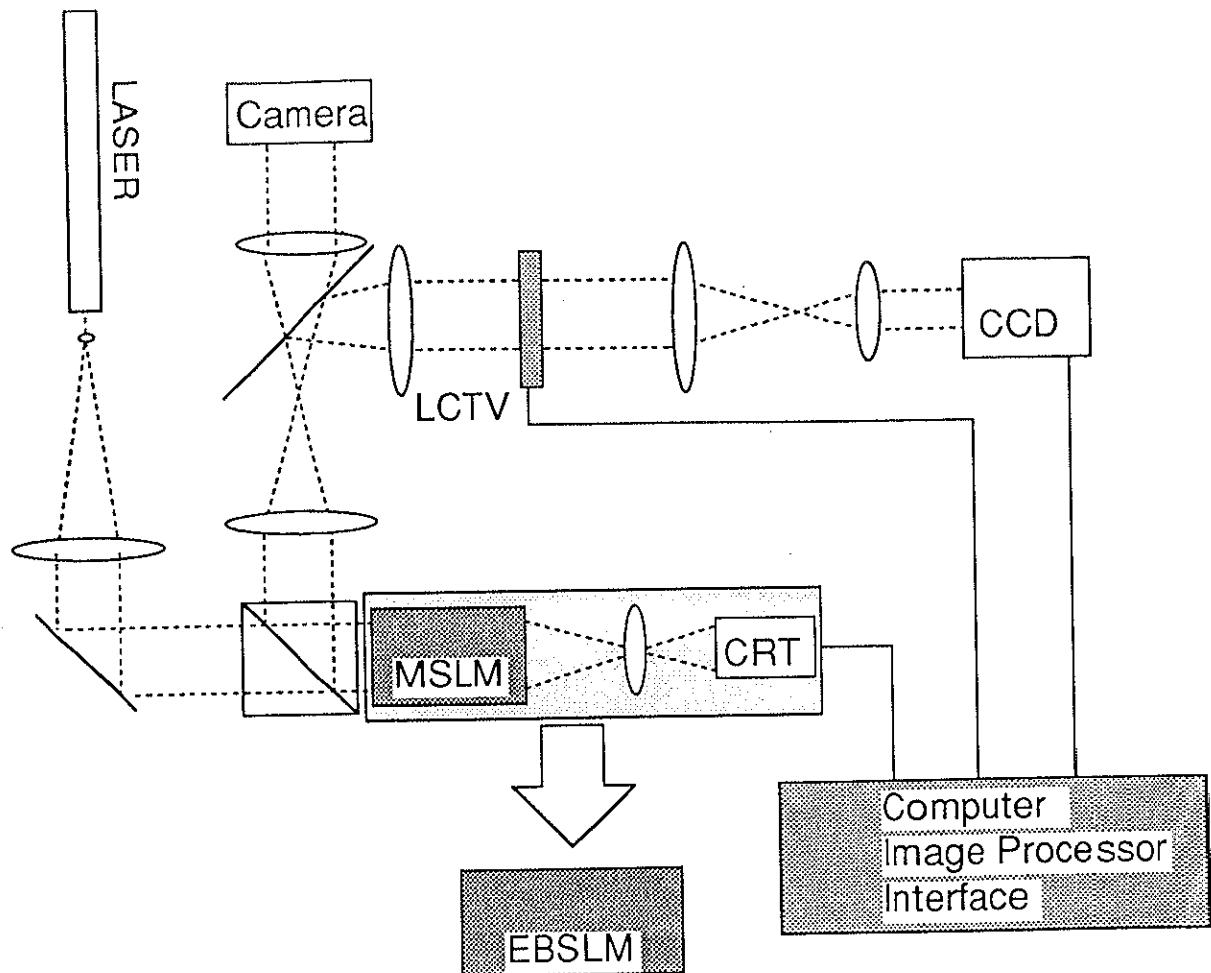
慣性係数 $\gamma = 0.0$

シグモイドの非線型係数 $\varepsilon = 0.7$

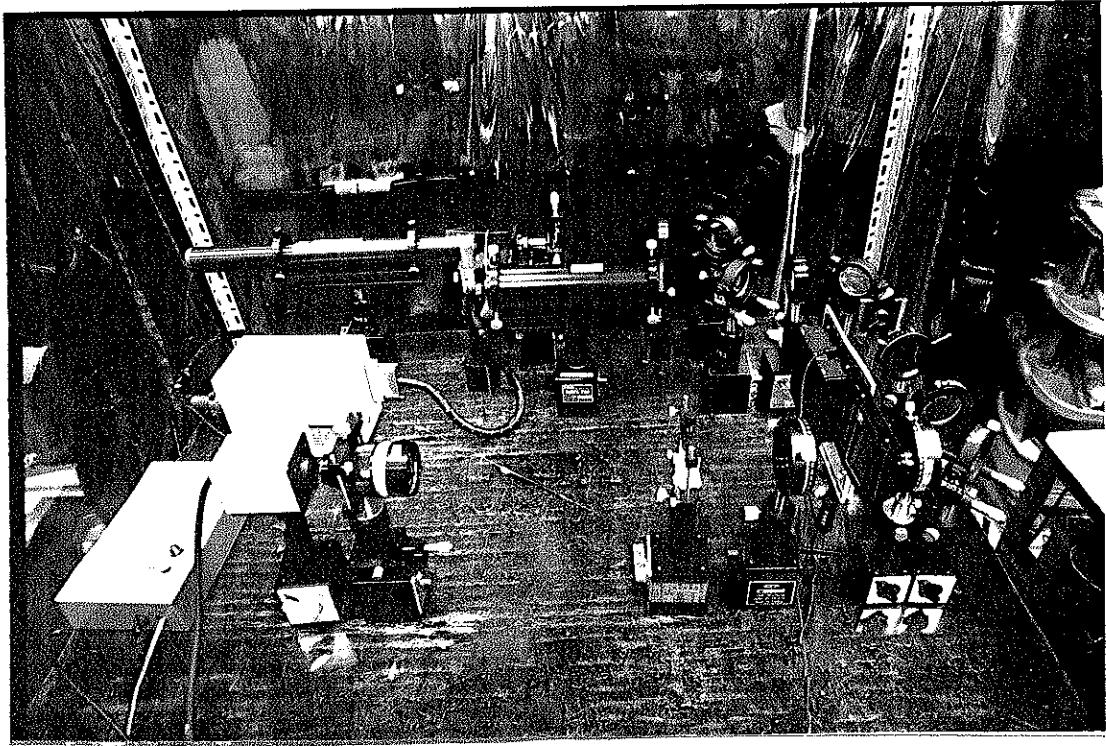
オフセットの初期値範囲 $0.0 < h_j < 0.3$

収束条件 $RMS/2 < 0.01$

光学実験において、学習係数はMSLMやEBSLMの書き込み時間で設定される。ここでは3000msで1を書き込んだ時に荷重が最大となり、その値を4にしたので、1回の学習における書き込み時間を30msに設定した結果、学習係数は0.4に相当することになる。しかし、荷重の最大は先にも述べたようにばらつきのため正確にはわからないため、正確な学習係数の値もわからない。



(a)



(b)

Fig.4.5.4 BP学習を伴う3層構造光ニューラルシステム

a. 単方向更新法の学習実験

単方向更新法の場合についてその学習実験の結果を示す。単方向更新法は、荷重素子の限られたダイナミックレンジを広く使うことができるが、学習中に振動が多い場合、荷重が素子の最大値（飽和）に達してしまう場合が多いことを4.4.5で述べた。また、荷重の初期値範囲は、0近辺の乱数が良いので、荷重はコンピュータで $|w_{ij}| < 0.3$ の初期値範囲で乱数を発生させ、書き込み時間60msで行う。ここで注意することは、MSLMを含めシステム全体に不均一を持っているため、MSLM上の荷重は、コンピュータで発生させた乱数値とは異なることである。実際、計算機シミュレーションでの学習により得られた結合荷重をMSLMに書き込んでも正しい出力は得られず、さらに数10回の学習が必要である。しかし、この場合の学習回数はランダムな初期荷重の場合に比べると少なくなることがわかった。これは、システム全体の不均一がランダムなものではなく、ある特定の傾向を持ったものであるため、荷重の全体的な傾向や大小関係は保存されるからであると考えられる。また、荷重の更新は、その量が0.04の時30msの書き込み時間に設定した。

学習実験の典型的な結果をFig.4.5.5からFig.4.5.7に示す。Fig.4.5.5は、学習過程における4つの入力に対するそれぞれの出力値の変化を示したものであり、横軸に学習回数、縦軸に出力値を示している。Fig.4.5.6は、同様に2乗誤差の変化を示したものである。出力、2乗誤差とともに、学習回数が100回を越えたあたりはげしく振動し、その後望ましい出力に近づいている。そして、学習回数177回で2乗誤差が0.01以下になり学習が終了している。Fig.4.5.7はMSLM上に記憶されている結合荷重の初期状態と学習終了後の状態を示す写真である。結合荷重は加算のみ行われるため、全ての正負の荷重が増加していることがわかる。

b. 双方向更新法の学習実験

双方向更新法の場合についてその学習実験の結果を示す。これは、荷重を記憶する荷重素子にEBSLMを用いた場合の実験結果である。双方向更新法は、その分配率を0.5にした場合、収束率や学習回数の学習能力が高くなるが、荷重素子のダイナミックレンジが狭くなる。しかし、学習係数を大きくして学習を早く終了させようとする場合、多くの場合振動が起こるので、単方向更新法に比べて収束率は高くなる。また、分配率を0.5にした場合、荷重の初期値範囲は、EBSLMで可能な荷重の最大値の1/2付近の乱数が良いこともわかった。よって、荷重の初期値ははじめに一様光で書き込み、荷重の初期値範囲 $|w_{ij}| < 1.0$ でコンピューターで乱数を発生させ、書き込み時間60msで行う。

双方向更新法の学習実験の典型的な結果をFig.4.5.8からFig.4.5.10に示す。Fig.4.5.8(a)は、学習過程における4つの入力に対するそれぞれの出力値の変化を示したものであり、横軸に学習回数、縦軸に出力値を示している。Fig.4.5.8(b)は、同様に2乗誤差の変化を示したものである。そして、

学習回数103回で2乗誤差が0.01以下になり学習が終了している。また、Fig.4.5.9は結合荷重の値の変化である。結合荷重は最大値が3であるため初期値はその中間値の1.5付近であり、双方向更新法であるために、荷重は増加または減少をしていることがわかる。Fig.4.5.10はEBSLM上に記憶されている結合荷重の初期状態と学習終了後の状態を示す写真である。写真からも荷重の初期状態が中間値付近であり、学習終了後の荷重は初期状態に比べて増加しているだけでなく減少もしていることがある。

4.5.4 考察

光ニューラルシステムを構成するデバイスは多くの非線型性やばらつきを持っている。それは、MSLMやEBSLMの読み出し用He-Neレーザー光の面発光分布のばらつき、MSLMのシェーディングや経時劣化による不均一、CRTやLCTVの非線型性、LCTVのコントラストである。実際、CRTや読み出し光の不均一を含むMSLMのばらつきは±35%程度もあり、LCTVのコントラストは50程度である。このような特性のデバイスで構成した光ニューラルシステムにおいても学習は終了する。これは、学習がデバイスのばらつきを吸収しながら進行しているということである。

Table.4.5.1は荷重素子のばらつきに対するシミュレーション結果であり、その収束率と平均収束率を示したものである。シミュレーションのパラメータは4.4.6での場合と同じである。ばらつきとは、MSLMの持っている実際のばらつきを定数倍したもので、その傾向を保存しつつ変化させたものである。ばらつきを2倍に増加させても性能は収束率は5%程度落ちるだけである。ばらつき2倍とは70%のばらつきに相当する。

Table.4.5.1 荷重素子のばらつきに対するシミュレーション結果

ばらつき(倍)	0	1/2	1	3/2	2
収束率(%)	85.8	85.9	84.6	84.4	79.6
平均収束回数	443	464	458	465	473

また、入力素子のコントラストを変化させた時のシミュレーション結果をFig.4.5.11に示す。同様に、シミュレーションのパラメータは4.4.6での場合と同じである。これは、横軸に入力素子のコントラスト、縦軸に学習回数を示したもので、3つの初期値の場合に対して示している。これから、コントラストは20程度あれば、十分であり、実験で用いたLCTVのコントラストは50なので十分な性能である。

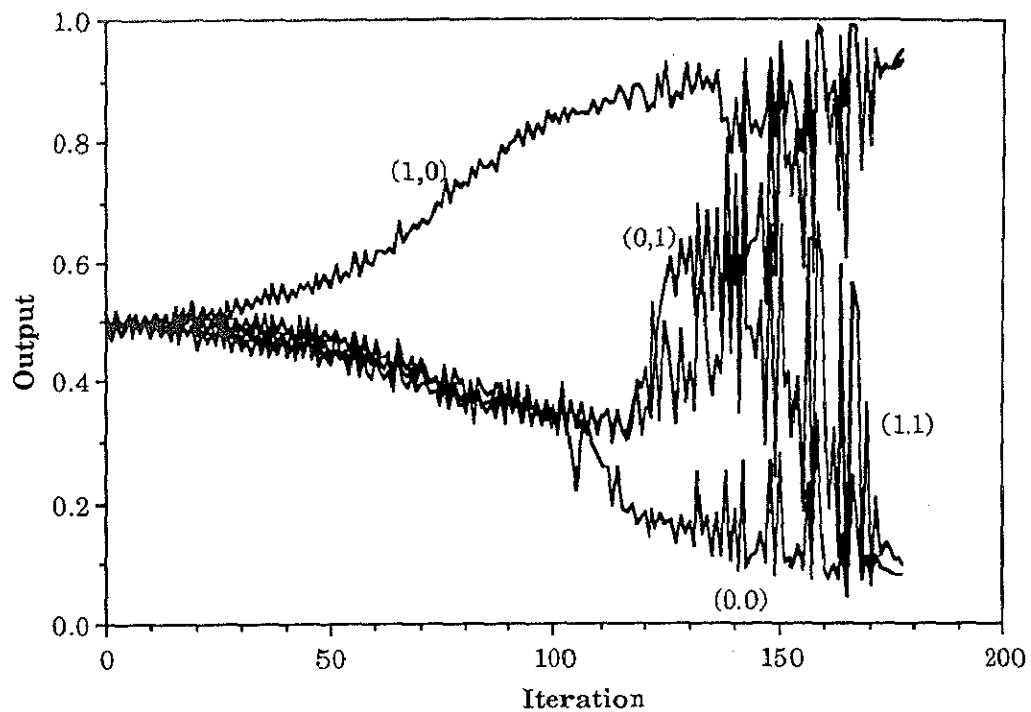


Fig.4.5.5 単方向更新法による3層光ニューラルシステムの学習過程における4つの入力に対する出力の変化

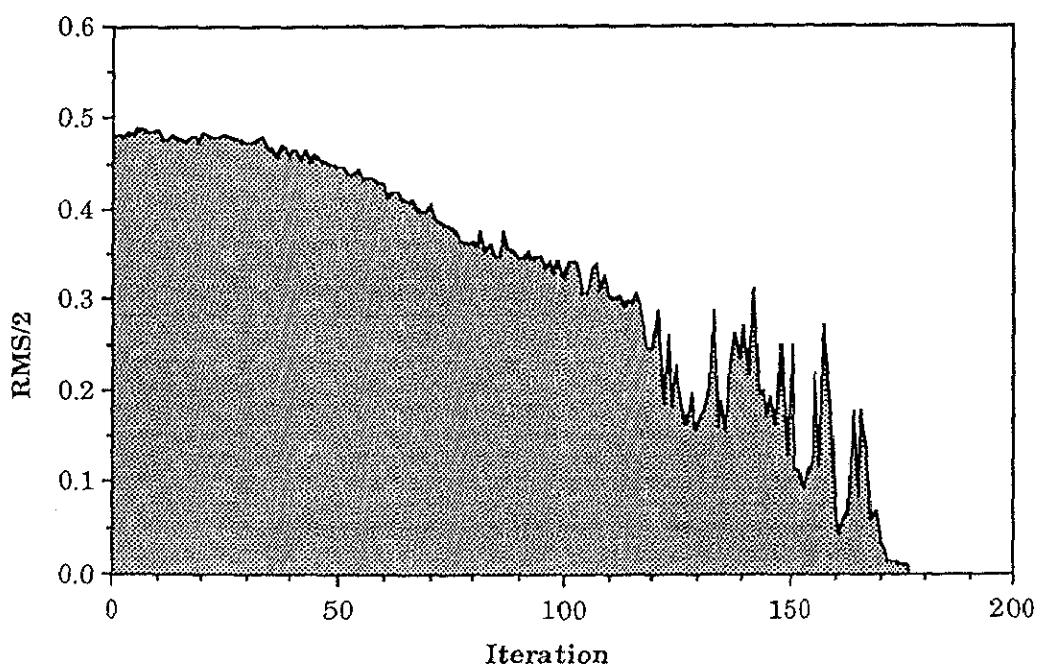
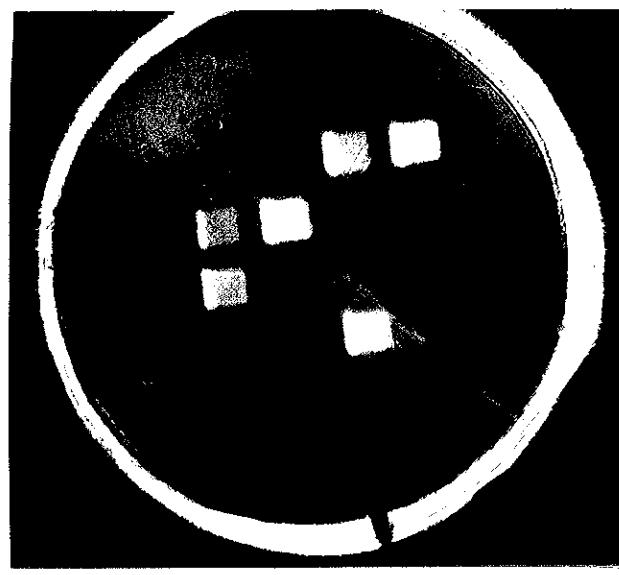
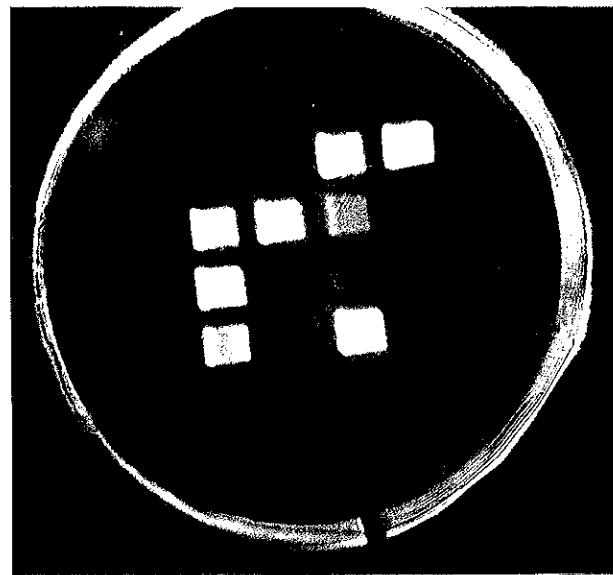


Fig.4.5.6 単方向更新法による3層光ニューラルシステムの学習過程における誤差の変化



(a)



(b)

Fig.4.5.7 MSLM上の結合荷重

(a) 荷重の初期値

(b) 学習終了時の荷重

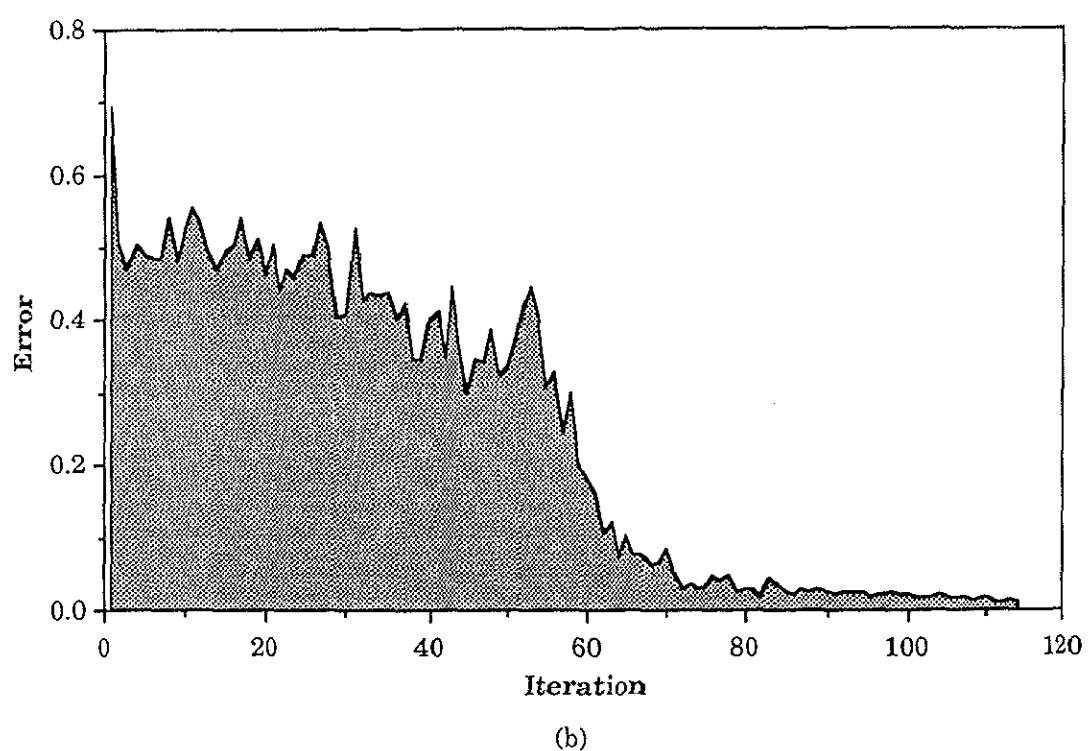
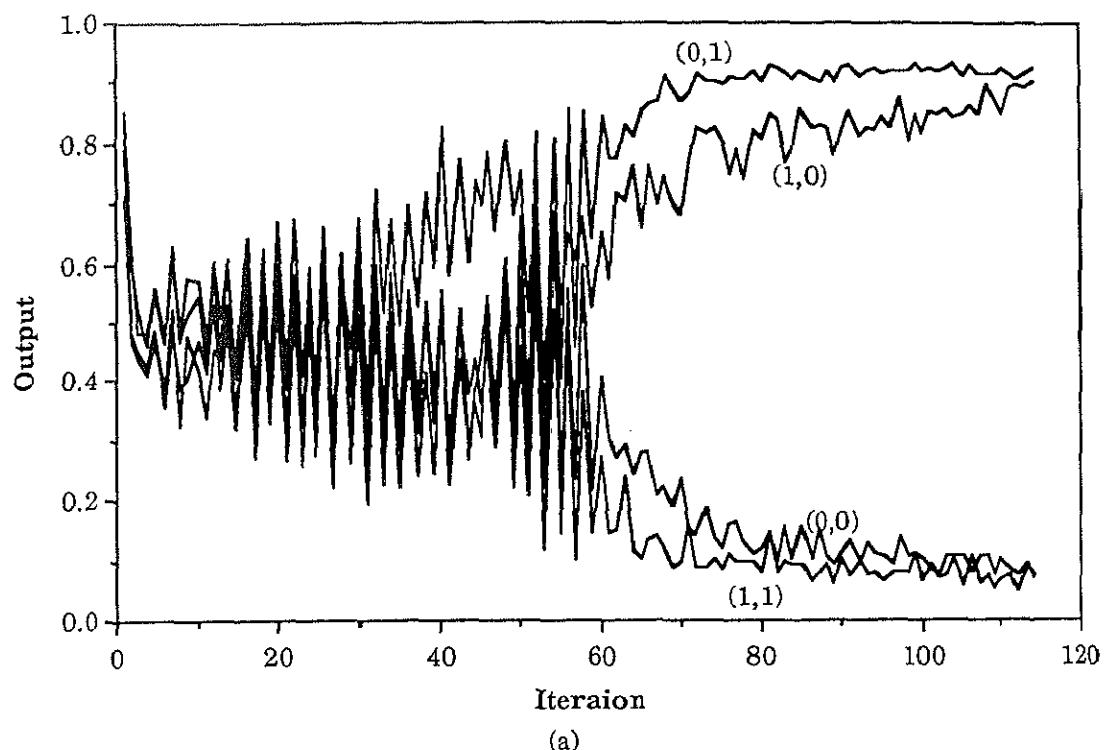
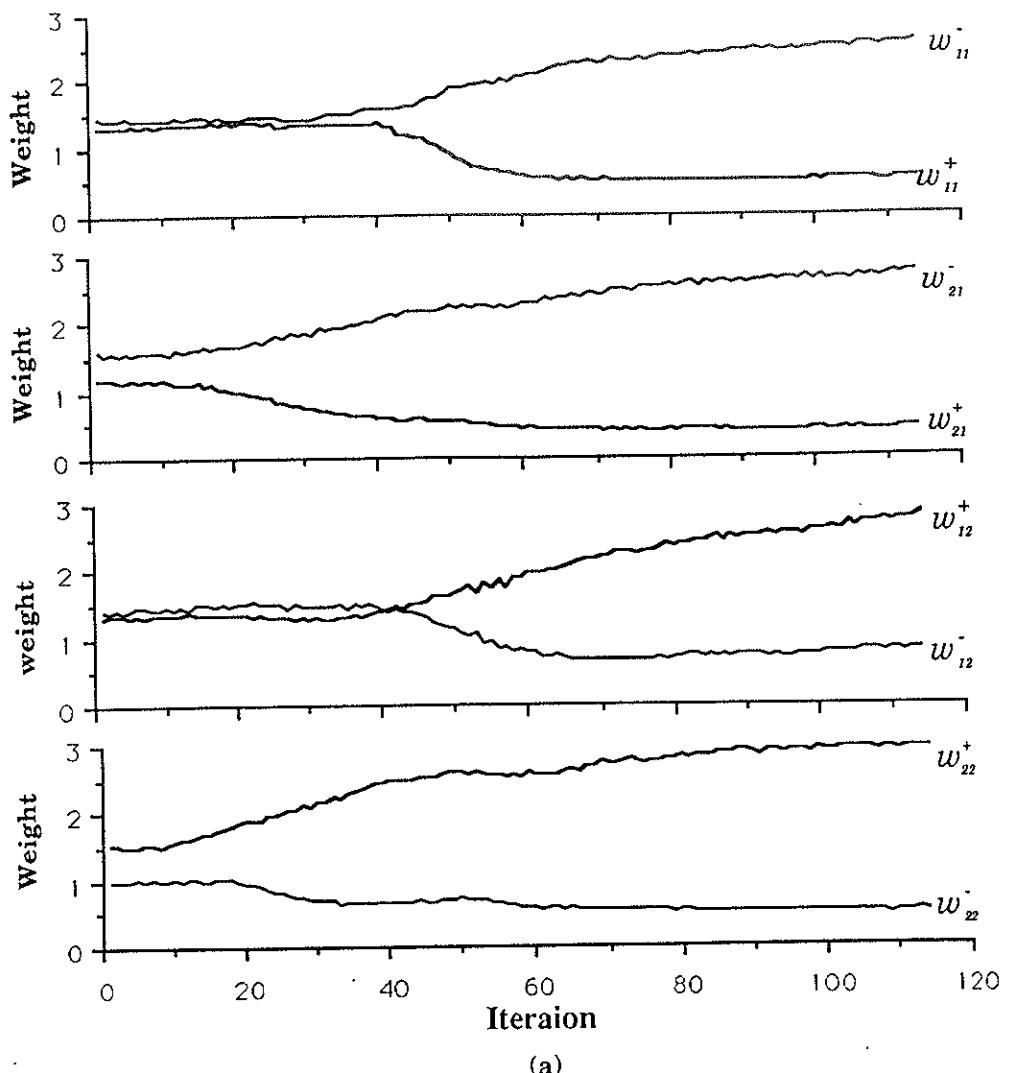
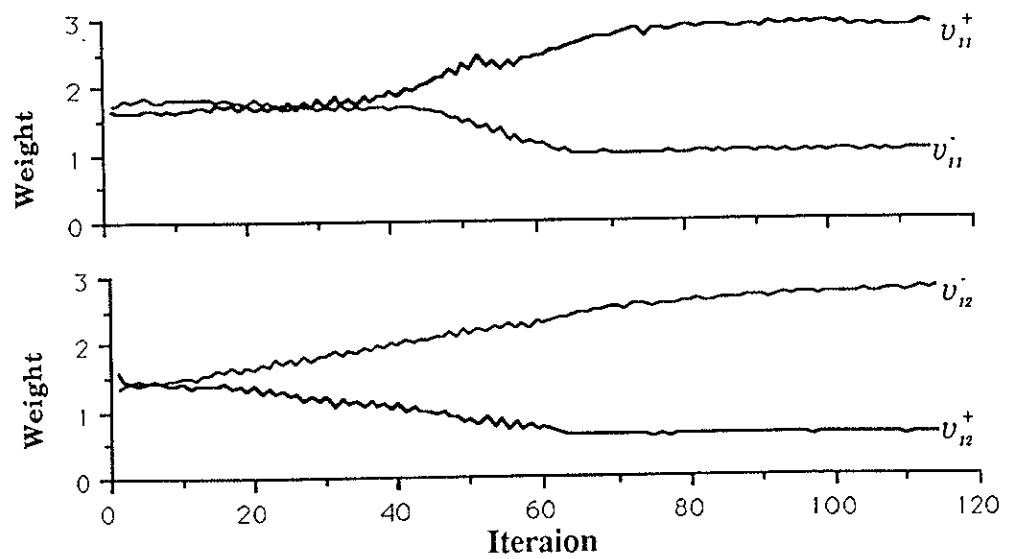


Fig.4.5.8 双方向更新法による3層光ニューラルシステムの学習過程

- (a) 4つの入力に対する出力変化
- (b) 2乗誤差の変化

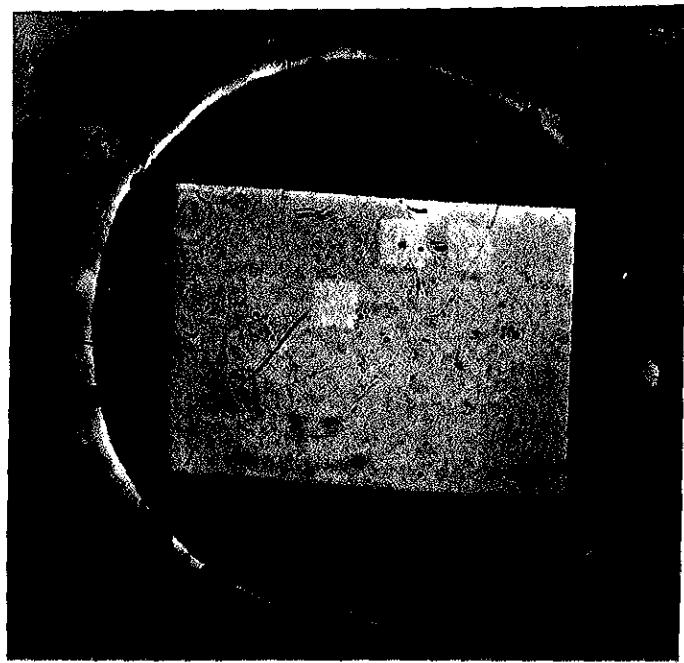


(a)

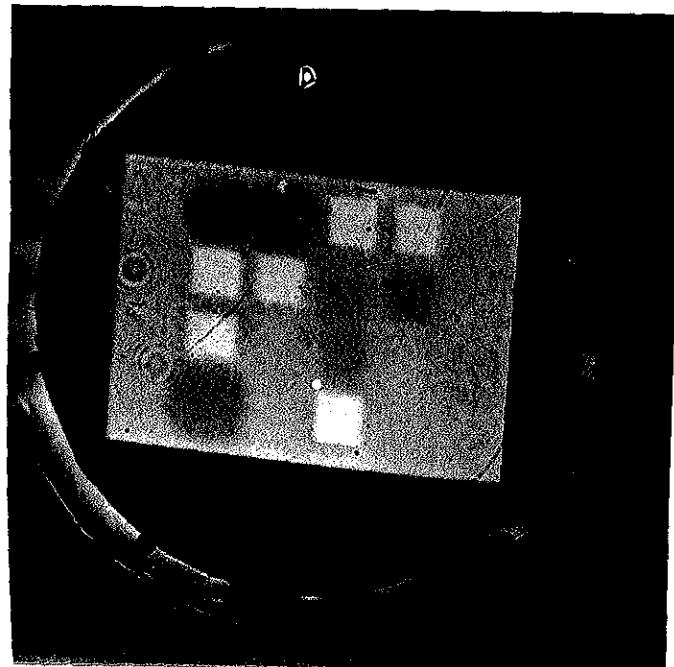


(b)

Fig.4.5.9 双方向更新法による3層光ニューラルシステムの学習過程における荷重の変化
 (a) 入力層から中間層への荷重 (b) 中間層から出力層への荷重



(a)



(b)

Fig.4.5.10 EBSLM上の結合荷重

(a) 荷重の初期値

(b) 学習終了時の荷重

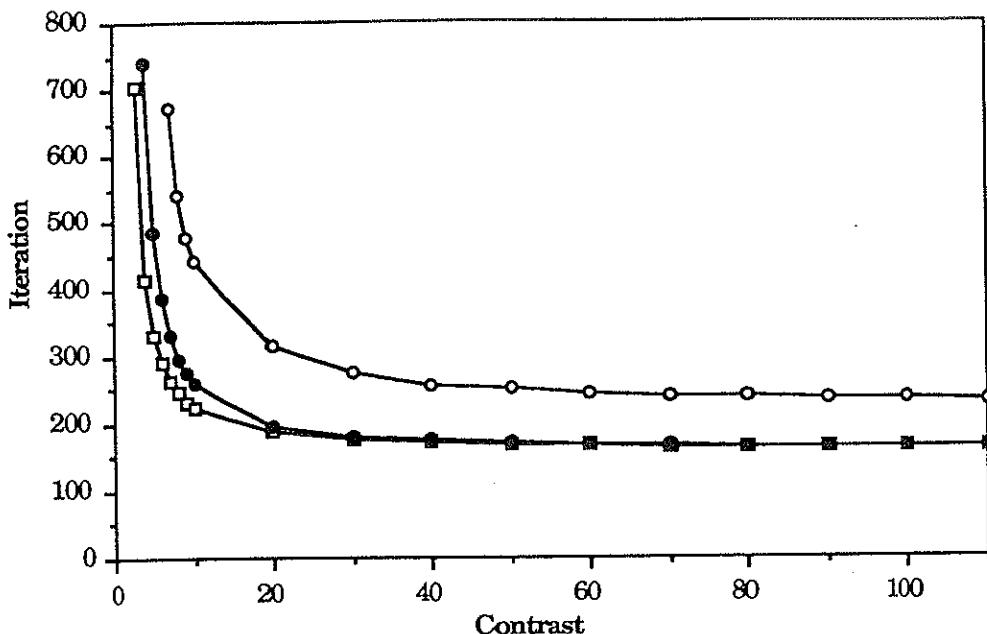


Fig.4.5.11 入力素子のコントラストに対する学習回数の変化

双方向更新法の配分率に関して、計算機シミュレーションにおいては配分率50%での場合が収束率が高く学習回数は少ないことは示した。しかし、実際のデバイスでは、正方向（加算）、負方向（減算）で特性が異なるので、配分率50%に設定しても実際は50%であるとは限らない。実際用いたMSLMでは、加算と減算応答は1対2程度であり、配分率0.7~0.8時収束率、学習回数とも良好な結果であった。単方向更新法の場合加算のみで使うので、加算と減算の特性差は関係ない。

システムのスピードに関して、実験において学習100回に1時間程度の時間を要していた。この時間のうちのほとんどの時間は、CRTやLCTVに画像を出力するための、コンピュータがイメージプロセッサを書き換える時間である。この次に時間を要すると考えられるMSLMの応答時間は、1回の学習で100ms以下で、100回の学習で要する時間は10秒程度である。より高速な光ニューラルシステムを実現するためには、個々のデバイスを高速にすることに加えて、画像を高速に転送する技術の確立も重要である。光デジタルシステムとの接点の一つがここにあると考えられる。

4.6 多重結像光ニューラルシステム

4.6.1 システム概要

ここでは学習機能を伴う2次元構造[33]-[36]を有する光ニューラルシステムについて報告する[37]。2次元構造とは2次元の画像のまま入力として与えることが可能で、多重結像と局所加算によって実現され、光ベクトルマトリクス演算器の問題点を解決するために適用された演算構造である。光ベクト

ルマトリクス演算器は、円筒形レンズを用いた光学系ではニューロン数の限界が数10程度であり、入力を1次元ベクトルとして取り扱っているため光の空間的並列性を活かしていないという問題点がある。2次元構造は、2次元情報と2次元情報を4次元のテンソルで結び、その4次元テンソルを分割したマトリクスに配置する方法で、石川らによって光アソシエーションの演算構造である空間コード化法(Spatial Coding Method)として提案され、Luらによって局所加算を行う光ニューラルネットワークが実現された。構成した光ニューラルシステムは、2次元構造を実現するために多重結像光学系を用いている。多重結像光学系は、セルフォックマイクロレンズアレイ(SMLA: SELFOC MicroLens Array)によって実現され、大規模かつコンパクトな光学系が可能である。またこの光ニューラルシステムは学習機能を得るために、光書き込み可能な空間光変調素子であるBSO空間光変調素子(PROM: Pockels Readout Optical Modulator)[74]に結合荷重が記憶される。ここでは、SMLAを用いた多重結像光学系による2次元構造を持つ光ニューラルシステムとその学習実験の結果について報告する。また、SMLAを構成するセルフォックマイクロレンズ[75]のPSF(Point Spread Function)の測定から最大ニューロン数の評価を行う。

4.6.2 2次元構造のニューラルネットワーク

2次元的に並んだ $M \times M$ 個の入力ニューロンと $N \times N$ 個の出力ニューロンが結合している場合を考える。 (i,j) 番目の入力ニューロンと (k,l) 番目の出力ニューロンの状態を v_{ij} と y_{kl} とすると、それらの間の結合荷重はテンソル W_{ijkl} で書ける。出力ニューロン状態 y_{kl} は、入力ニューロン状態 v_{ij} と結合荷重テンソル W_{ijkl} のマトリクス・テンソル積によって、以下のように書ける。

$$y_{kl} = f(\sum_j \sum_i W_{ijkl} v_{ij} - h_{kl}) \quad (4.6.1)$$

ここで、 f は非線型出力関数であり、 h_{kl} は (k,l) 番目の出力ニューロンの出力関数のオフセットである。

式(4.6.1)のマトリクス・テンソル積は、入力ニューロンの状態を表す入力パターンの $N \times N$ 個の複製パターンと出力パターンに対応する局所的な加算によって実行される。複製パターンは2次元的に配置され、多重結像パターン V_{ijkl} と呼ぶ。多重結像パターン V_{ijkl} と結合荷重テンソル W_{ijkl} はアダマール積が実行され、パターン X_{ijkl} が得られる。

$$X_{ijkl} = W_{ijkl} \times V_{ijkl} \quad (4.6.2)$$

(k,l) 番目の出力ニューロンの荷重和である x_{kl} は、パターン X_{ijkl} の局所加算によって得られる。

$$x_{kl} = \sum_j \sum_i X_{ijkl}, \quad (4.6.3)$$

出力 y_{kl} は荷重和 x_{kl} からオフセット h_{kl} を引き、非線型演算を実行し、

$$y_{kl} = f(x_{kl} - h_{kl}), \quad (4.6.4)$$

が得られる。

4.6.3 実験システム

式(4.6.2)から式(4.6.4)で与えられる演算の光学的実現において、多重結像光学系は、入力パターン v_{ij} から多重結像パターン V_{ijkl} を作るために使われている。Fig.4.6.1は、コヒーレント照明下における多重結像光学系とその多重結像に必要なレンズアレイを示している。(a)の光学系は、2つのレンズアレイと2つのレンズがアフォーカルな配置になっている。(b)は筆者らが開発したSMLAで、28mm角のアルミニウム基板に 10×10 個のセルフォックレンズが固定されている。単体のセルフォックレンズは、直径2mm、長さ2.2mm、焦点距離5mmである。(c)はSMLAを用いて、文字'A'を多重結像したときの出力写真である。

結合荷重 W_{ijkl} は位置表現法が適用されているため、正荷重 W^+_{ijk} と負荷重 W^-_{ijk} を空間的に分離して表現する。したがって、式(4.6.1)は、

$$y_{kl} = f(\sum_j \sum_i W^+_{ijkl} v_{ij} - \sum_j \sum_i W^-_{ijkl} v_{ij} - h_{kl}) \quad (4.6.5)$$

に書き換える。

Fig.4.6.2は、光ニューラルネットワークの実験システムの図と写真である。これは、SMLA、PROM、液晶テレビ(LCTV)、CCDカメラ、CRT、シャッター、そしてコンピューター等から構成されている。PROM(付録C)は、有効面積28mm角、解像度15lp/mmの透過型の空間光変調素子であり、正荷重 W^+_{ijk} と負荷重 W^-_{ijk} を記憶する。液晶テレビは、入力パターンを表示する。実験システムの光学的構成部分は、3つの光学系からなる。3つの光学系とは、多重結像系、重ね合わせ系、そして荷重更新系である。多重結像系は、アフォーカルな配置になっている2枚のSMLAと2枚のレンズから構成され、液晶テレビに表示された入力パターンの複製パターンをPROM上に結像する。重ね合わせ系では、式(4.6.2)におけるPROM上の結合荷重と個々の複製パターンを乗算を行い、その乗算結果のパターンをCCDカメラに結像している。個々の重ね合わされたパターンは、コンピュータ内において、出力ニューロンに対応する局所加算が行われる。荷重更新系では、CRT上にコンピュータで計算された荷重の初期値または更新値が表示され、PROMを書き込みモードの電圧 $V=5.0\text{kV}$ に設定することによって、PROM上の結合荷重が変更する。PROMは、読み出しモードの電圧 $V=0.0\text{kV}$ が消去モードの電圧と同じなので、書き込み側のシャッターは書き込み時以外は閉じている。またPROMはHe-Neレーザーの赤い色の光に対しても感度は低いながらも書き込まれるので、読み出し側のシャッターは読み出し時以外は閉じている。

4.6.4 ニューラルネットワークの実験とその結果

多重結像光ニューラルシステムには、Fig.4.6.3(a)に示す単純なニューラルネットワークを実現し、システムの動作を確認する。実現したニューラルネットワークは、入力ニューロン数と出力ニューロン

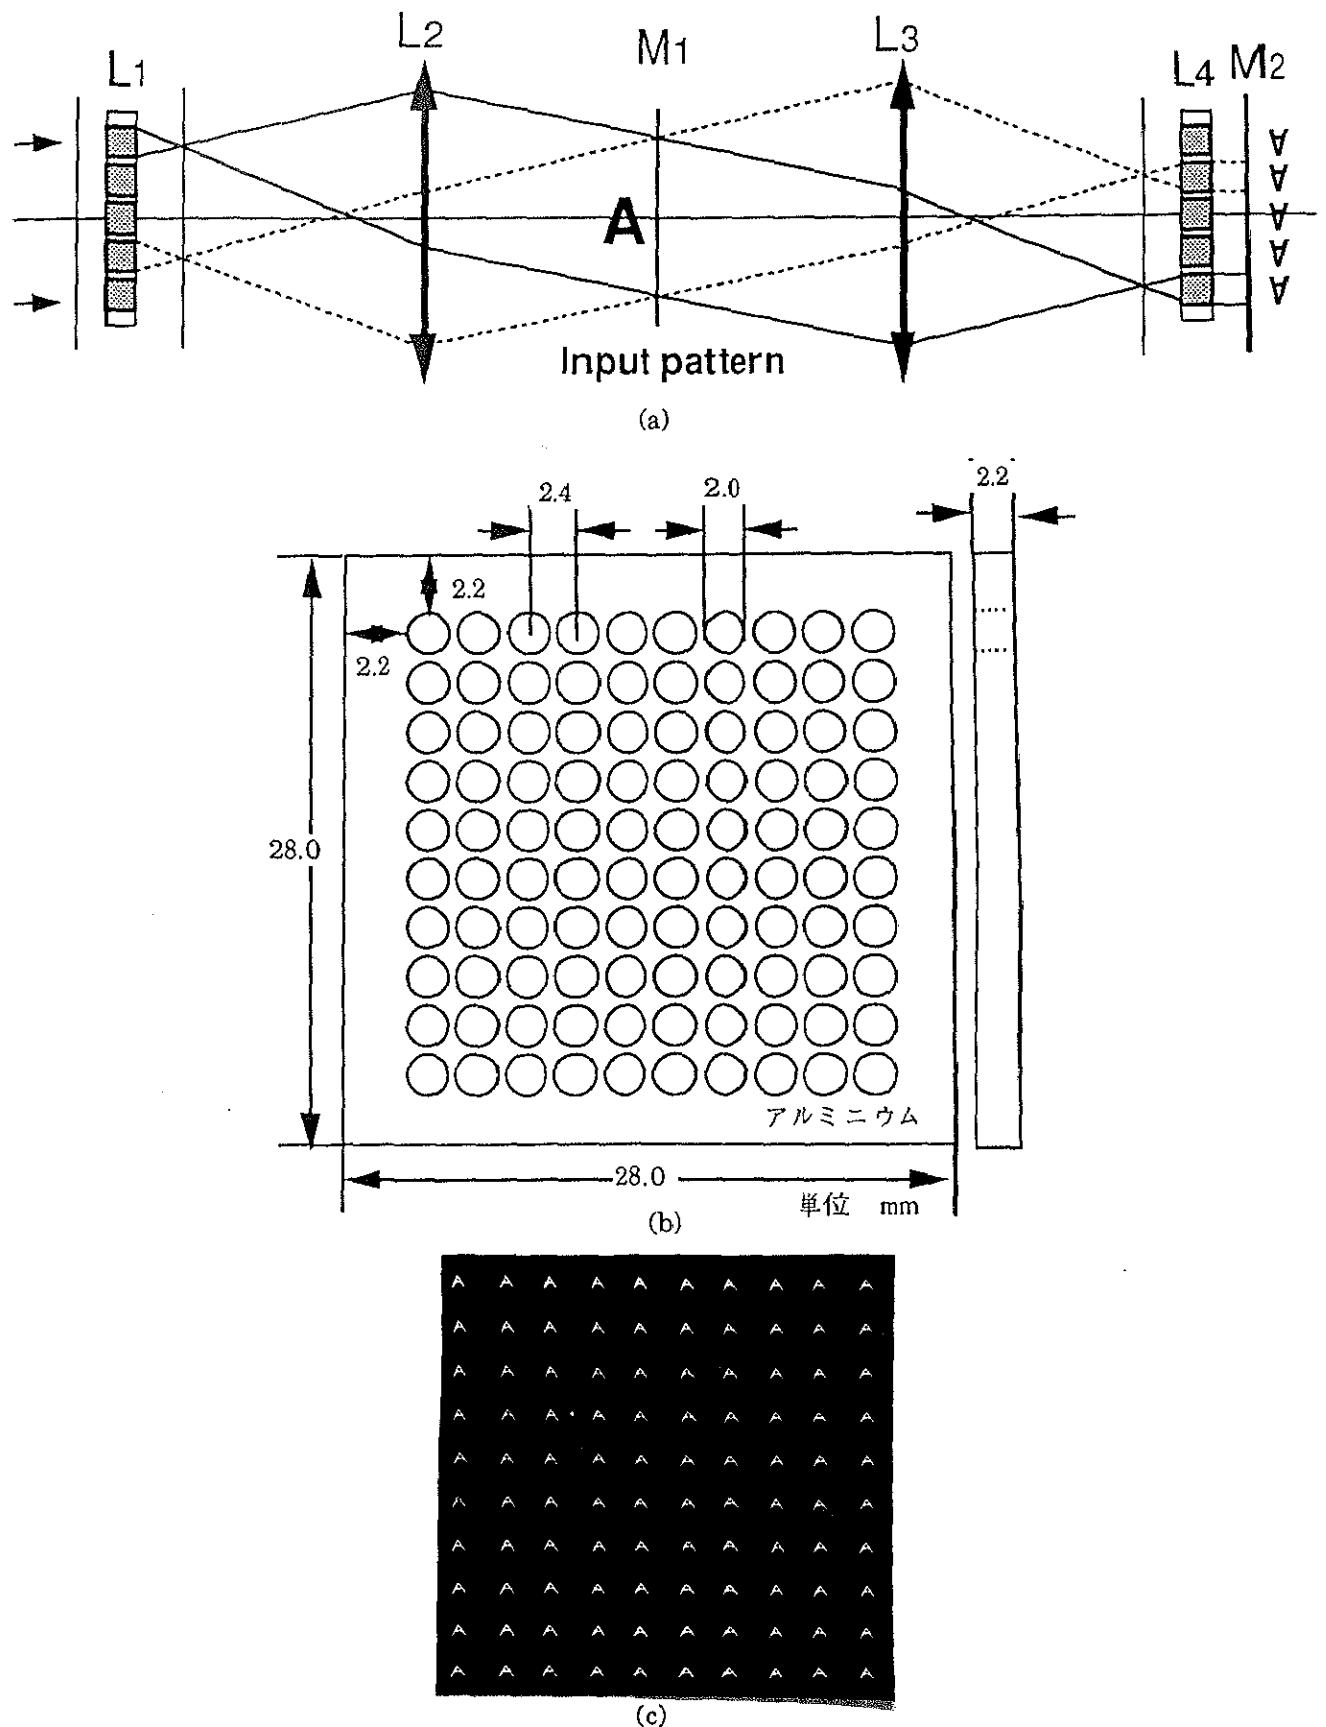
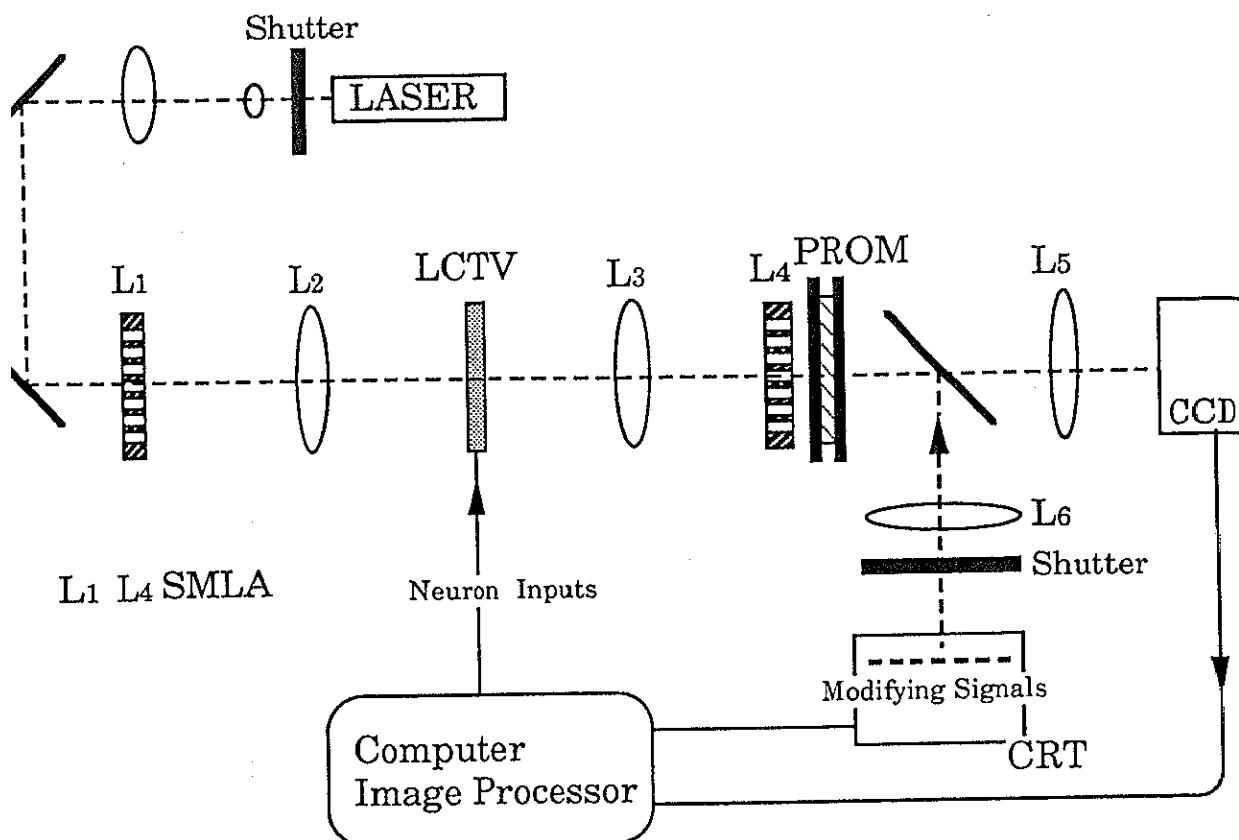
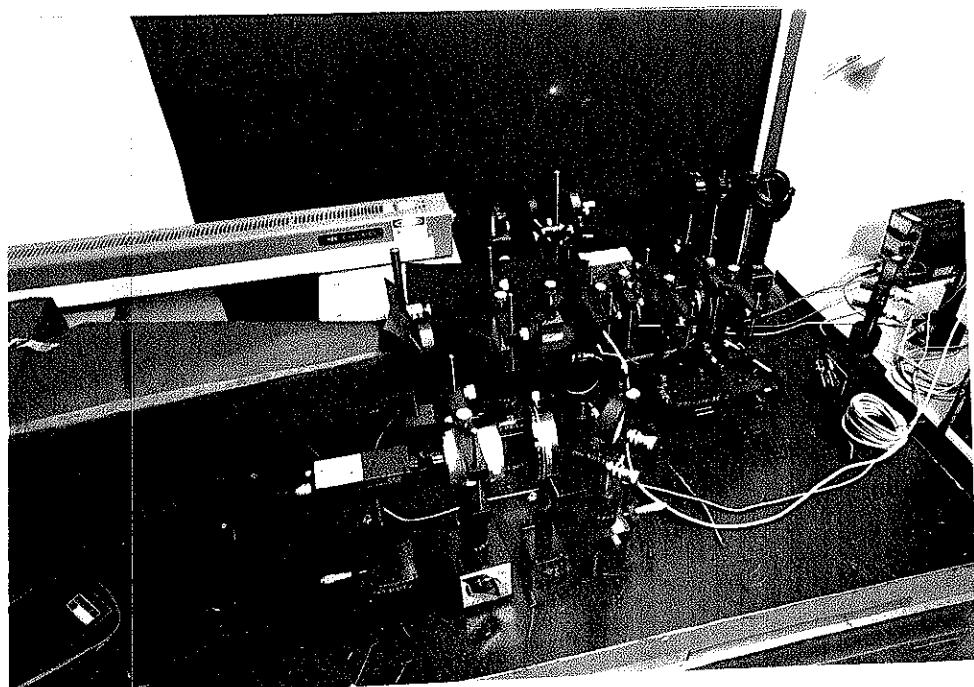


Fig. 4.6.1 多重結像光学系(a)とセルフォックマイクロレンズアレイ(b)、多重結像(c)



(a)



(b)

Fig.4.6.2 2次元構造の光ニューラルシステム

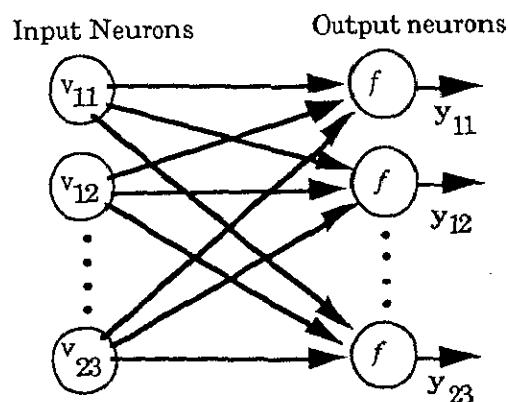
ン数が共に8個の2層のニューラルネットワークであり、出力ニューロンの出力関数は、

$$f(x) = \begin{cases} 0 & x < 0, \\ 1 & x \geq 0. \end{cases} \quad (4.6.6)$$

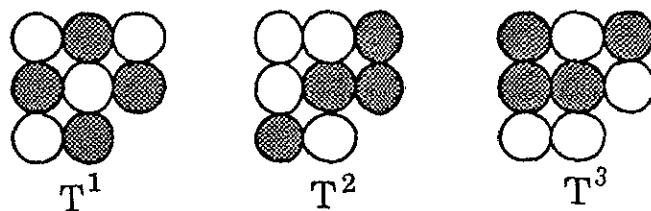
で、しきい値 h_{ki} が0のステップ関数である。8個の入力ニューロンは、以下のように2次元的に配置されている。

$$\begin{pmatrix} v_{11} & v_{12} & v_{13} \\ v_{21} & v_{22} & v_{23} \\ v_{31} & v_{32} \end{pmatrix} \quad (4.6.7)$$

Fig4.6.3(b)は、3つ学習パターンを示していて、それぞれ T^1 、 T^2 、 T^3 と呼ぶ。



(a)



(b)

Fig.4.6.3 多重結像光ニューラルシステムに実現された

(a) 8ニューロンのニューラルネットワーク

(b) 3つの学習パターン

学習は、Kohonenによって提案された直交学習[7]を採用し、2次元構造にそって書き直すと、

$$W_{ijkl}(t+1) = W_{ijkl}(t) + \eta(t^p_{kl} - y'_{kl}) v_{ij} \quad (4.6.8)$$

ここで、 η は学習ゲインであり、 t^p_{kl} はp番目の学習パターンであり、 y'_{kl} は学習過程における一時的な出力である。荷重を正負用意しているので、式(4.6.8)は、

$$\begin{aligned} W'_{ijkl}(t+1) &= W'_{ijkl}(t) + \eta(t^p_{kl} - y'_{kl}) v_{ij}, & t_{kl} - y'_{kl} > 0 \\ W'_{ijkl}(t+1) &= W'_{ijkl}(t) + \eta(t^p_{kl} - y'_{kl}) v_{ij}, & \text{その他} \end{aligned} \quad (4.6.9)$$

に書き換えられる。また、実験において、一括修正法を用いているので、全ての学習パターンを提示した後、荷重更新値の和を用いて学習を行っているため、さらに式(4.6.9)を以下のように書き換える。

$$W_{ijkl}(t+1) = W_{ijkl}(t) + \eta \sum_p (t^p_{kl} - y'_{kl}) v_{ij} \quad (4.6.10)$$

同様に、正と負の荷重へ分配するために、その更新値 $\Delta W_{ijkl} = \eta \sum_p (t^p_{kl} - y'_{kl}) v_{ij}$ が正の場合、正の荷重にを加え、負の場合、符号を反転して負の荷重に加える。

$$\begin{aligned} W_{ijkl}(t+1) &= W_{ijkl}(t) + \Delta W_{ijkl} & \Delta W_{ijkl} > 0 \text{ の時} \\ W_{ijkl}(t+1) &= W_{ijkl}(t) - \Delta W_{ijkl} & \text{その他} \end{aligned} \quad (4.6.11)$$

学習ゲイン η は、PROMの書き込み時間を調整することによって設定され、本実験で、書き込み時間は15秒にセットされる。これは学習係数 η が0.5の場合に相当する。この荷重の更新法は4.4.6で述べた単方向更新法である。

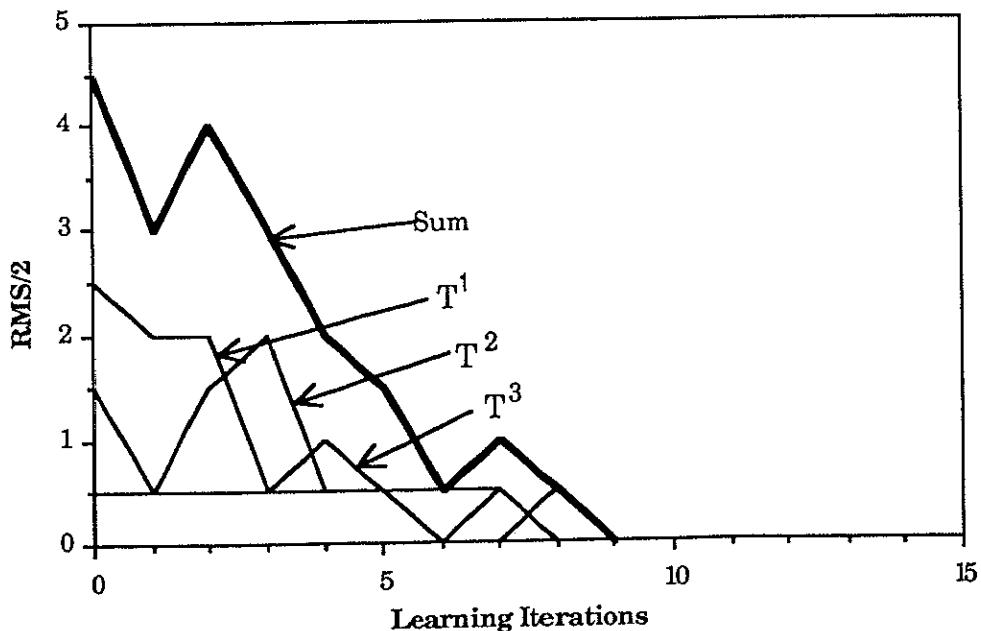


Fig 4.6.4 学習過程における2乗誤差の変化

Fig4.6.4は、学習過程における T^1 、 T^2 、 T^3 の2乗誤差変化とそれらの誤差の総和(Sum)の変化を示している。誤差の総和は学習9回で0になり、学習が終了していることがわかる。Fig4.6.5は、学習前と学習後のPROM上の結合荷重であり、すべてのニューロンの状態を1にした時の写真である。これらの荷重は上半分が負の荷重で下半分が正の荷重である。学習前の荷重の初期値は、コンピュータによって発生された乱数を正負の荷重に分けて、10秒間書き込みを行ったものです。学習後の荷重は、9回の学習により得られた結合荷重である。

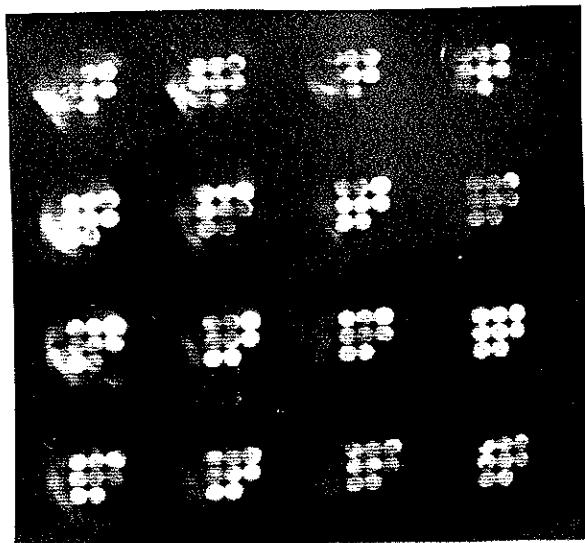
4.6.5 システムの評価

ニューラルネットワークシステムの入出力信号を2次元の画像のまま取り扱うことのできる2次元構造は、レンズアレイにより実現される。入力ニューロンの最大数は、セルフォックレンズ及びPROMの解像度に制限され、出力ニューロンの最大数は、レンズアレイのレンズの数に制限される。本実験システムで用いられているセルフォックレンズアレイは、他のマイクロレンズと比較して収差の修正が容易である。Fig.4.6.6は、入力物体高が0mm（光軸上）と0.5mm（軸外）の場合のPSFと中心光強度のプロファイルである。それぞれの半値幅は $2.53\mu\text{m}$ と $4.04\mu\text{m}$ であり、セルフォックレンズの解像度は、軸上で 395lp/mm 軸外で 247lp/mm ある。これは、システムにおいてLCTV上の入力パターンが 1cm^2 で、多重結像系の倍率が1/10なので、入力ニューロン数の最大数は 247×247 である。しかし、荷重素子のPROMの解像度は、 15lp/mm であるため、その最大数は 15×15 ニューロンに制限される。また、出力ニューロンの最大数は、セルフォックレンズの数に制限され、100ニューロンとなり、正負別々の結合荷重を用意する場合、50ニューロンとなる。

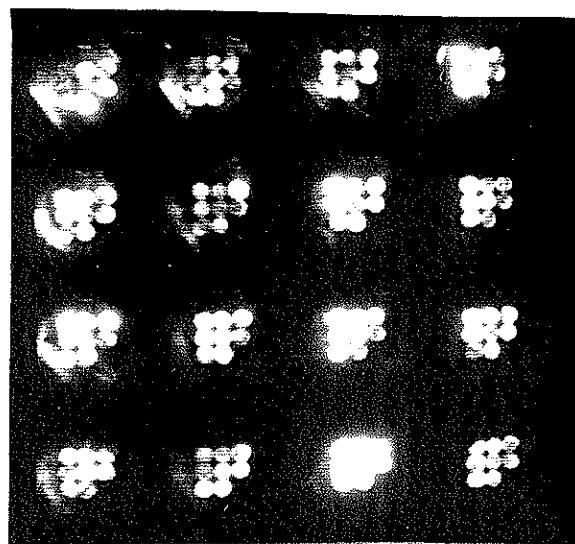
4.6.6 考察

多重結像光ニューラルシステムは、2次元構造を実現するSMLAの使用により比較的コンパクトで $5 \times 5 \times 20\text{cm}^3$ 程度である。多重結像光学系の実現可能なニューロン数は、入力ニューロンの最大数が 247×247 で、出力ニューロンの最大数が100である。入力ニューロン数は、セルフォックレンズの解像度に依存している。しかし、現在のシステムでは、その最大数はPROMの解像度 15 lp/mm に制限され、 15×15 である。そのため、セルフォックレンズの性能を十分に活かすためには、より高い解像度が必要である。現在、PROMの改良が進んでいる[76]。出力ニューロン数はレンズアレイのレンズの数に依存している。より多数のニューロン数を考える場合、屈折率分布型の平板マイクロレンズにおいて、 $\phi 8.5\text{mm}$ に330個のマイクロレンズが開発されている[77]。

システムの学習スピードはPROMの書き込み時間やシャッターの開閉時間、荷重更新量の計算時間を含むコンピューターの計算時間などによって決定される。それらの中、学習時間は、主に

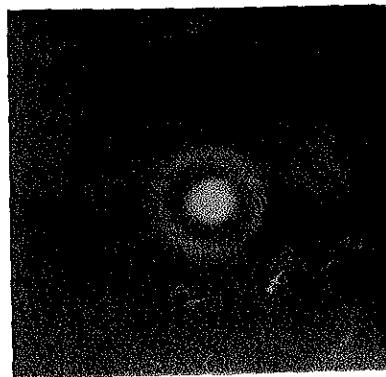


(a)



(b)

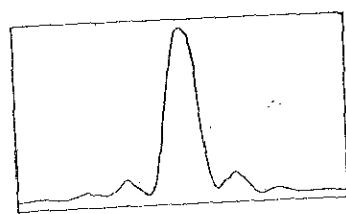
Fig.4.6.5 PROMに記憶された結合荷重、(a)初期荷重、(b)学習終了時の荷重



Point spread function

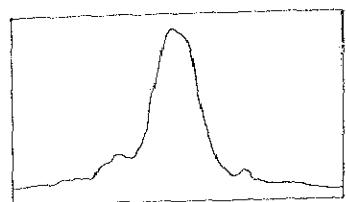


Point spread function



Light intensity profile

(a)



Light intensity profile

(b)

Fig.4.6.6 セルフォックレンズのPSFと中心光強度のプロファイル
(a)入力物体高が0mm、(b)0.5mm

PROMの書き込み時間に依存し、本実験では1回の書き込みは15秒である。これは、PROMの書き込み光源として用いているCRTの光量が不足しているためであり、レーザースキャナによる書き込みも実現され、フレームレートでの書き込みを可能としている。

4.7 反転入力重ね合わせ法システム

4.7.1 システム概要

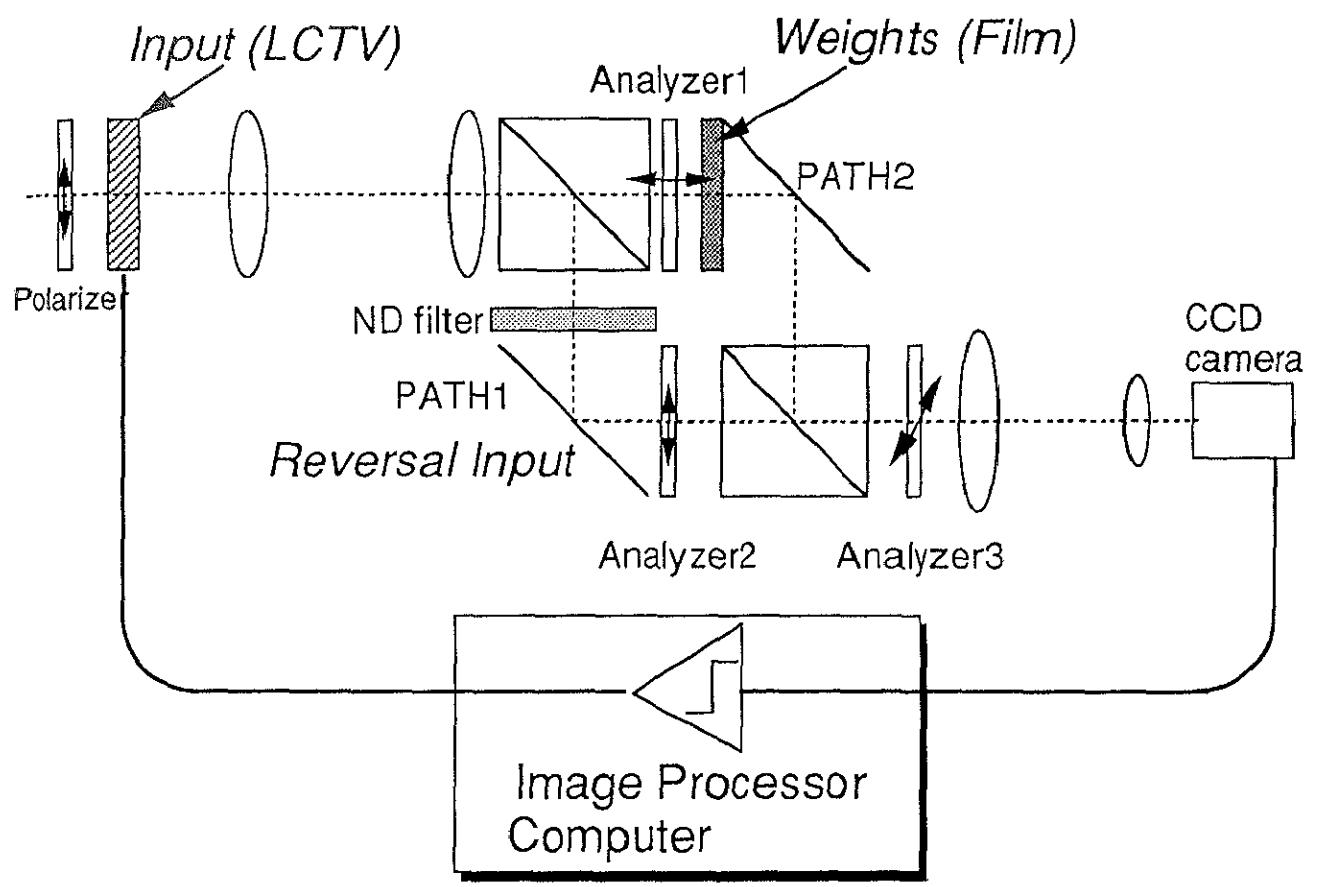
光により本質的に負の値が実現できないという問題において、荷重を正と負で表現する位置表現法で解決した。また、正と負のニューロンを導入することによって解決する方法[70][71]も提案されている。しかし、これらの方法は元のニューラルネットワークに対して2倍の数の荷重やニューロンが必要であった。また、もう一つの問題として情報の光学的表現として光強度を用いているため、減算を行うことが困難であることがある。減算はコヒーレントな光学系で実行することができる[72]が、よりロバストなシステムを構成するという観点からコヒーレントな光学系の利用は難しい。これらの問題を解決するために提案した手法が、4.4.7で示した反転入力重ね合わせ法(RIST: Reversal Input Superposing Technique)である。この方法は、正の加算と乗算で全ての計算が実行できる光学的実現に有効な演算モデルであり、荷重やニューロンに2倍の素子を必要としないという特徴を持っている。

本節では、LCTVを用いたRISTに基づく光ニューラルシステムについて述べる。LCTVはRISTに必要な入力パターンとその反転パターンを同時に得るために必要な偏光パターンを発生する。RISTの原理確認をするために、システムには25ニューロンのホップフィールドモデルを実現した。また、想起実験の結果について示す。

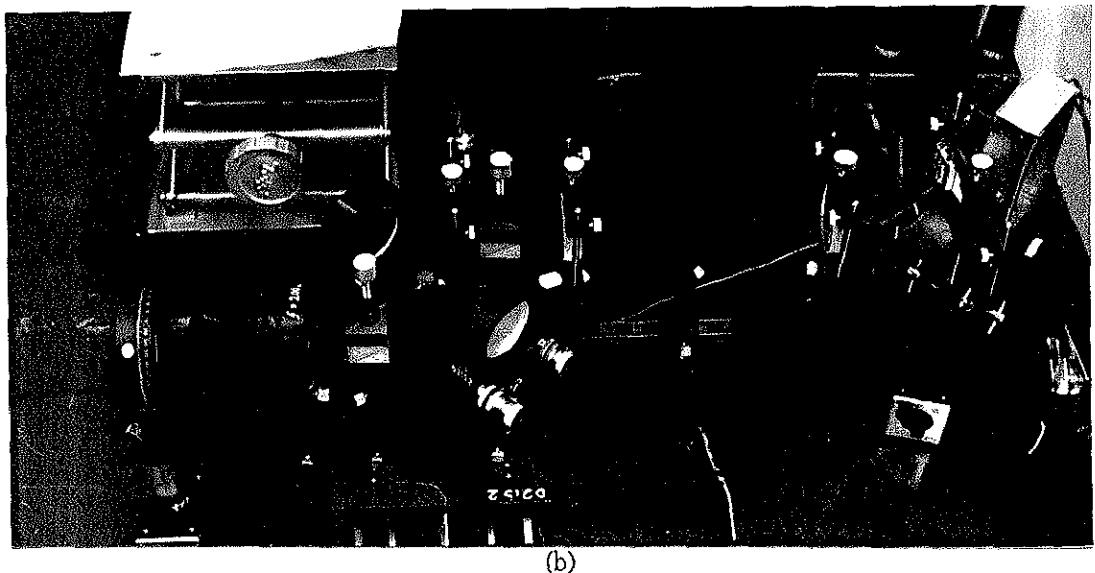
4.7.2 システム構成

Fig.4.7.1は、反転入力重ね合わせ法に基づく光ニューラルシステムの光学系(a)と写真(b)である。このシステムは、液晶テレビ(LCTV)、写真フィルム、CCDカメラ、コンピュータ、イメージプロセッサ、その他光学部品から構成されている。光源はHe-Neレーザーで図中では省略されている。光学系の中で、光は2つに分けられ、垂直方向に対し 0° にセットされた入力側(PATH1)のAnalyzer1と 90° にセットされた反転側(PATH2)のAnalyzer2によって、2つの直交する直線偏光にされる。Analyzer3は、分けられた入力側と反転側の光量の相対関係を調節するために用いられる。詳しくは4.7.3で述べる。

LCTVは入力信号を偏光パターンに変調するために用いられている。そのため、LCTVに付けられている偏光板ははずされている。写真フィルムはバイアス結合荷重を透過率として記憶している。フィ



(a)



(b)

Fig. 4.7.1 反転入力重ね合わせ法による光ニューラルシステムの光学系(a)と写真(b)

ルム上の結合荷重は固定であるため、このシステムで学習能力を得るのは困難である。学習機能は、フィルムの位置に透過型のSLMを置くことにより獲得することができる。CCDカメラは両方の光路の光を受ける。システム中の光学系部分は、式(4.4.10)を書き換えた以下の式のΣの中を計算している。

$$\bar{x}_j = \sum_i (w_{ji}^b v_i + \alpha \bar{v}_i) \quad (4.7.1)$$

反転側のNDフィルタは反転パターンの強度を調節するために使われ、荷重に与えたバイアスに応じてその透過率は決定される。例えば、結合荷重がホップフィールドモデルのように符号に関して対称である場合、定数 α は以下のように与えられる。

$$\begin{aligned} \alpha &= -\max(w_{ji}) \\ &= \max(w_{ji}^b)/2 \end{aligned} \quad (4.7.2)$$

そのため、入力側と反転側の光量の比は2:1であり、50%NDフィルターが必要である。

システム中の電気系部分のコンピュータとイメージプロセッサは、LCTVに入力信号 $V=\{v_j\}$ を送り、式(4.7.1)のΣに対応するCCDカメラからの信号の加算と非線型出力関数を計算し、ニューロンの出力を得る。

4.7.3 液晶テレビによる反転パターンの発生

実際の実験システムは、光源の面発光分布の不均一性やデバイス等の非線形性や不均一性を持つため、システムの多くの調整が必要である。特に、このシステムでは一般に広く売られているLCTVを用いて入力パターンと反転パターンを同時に発生させるという特別な利用法をしているため、システムの性能に大きな影響を与える入力側と反転側の光量の調整は重要である。Fig.4.7.2は規格化した0から1の入力に対し、入力側(PATH1)と反転側(PATH2)の出力を示している。出力は反転側の最大出力光強度で規格化している。入力側及び反転側の出力光強度は、実線と点線で示されている。反転側は、入力側に比べてコントラストが低く、光量が多い。これは、赤、緑、青の画素を持っているカラーのLCTVのカラーフィルタが取り外され、赤の画素のみが使われているため、緑と青の画素では偏光子、検光子を直交させたとき、光が透過してしまうためである。実際のシステムでは、これら2つの光路の光量比をこまかく調整するためにNDフィルタは使わずに、Analyzer3 (see Fig.4.7.2) を使い調整を行う。

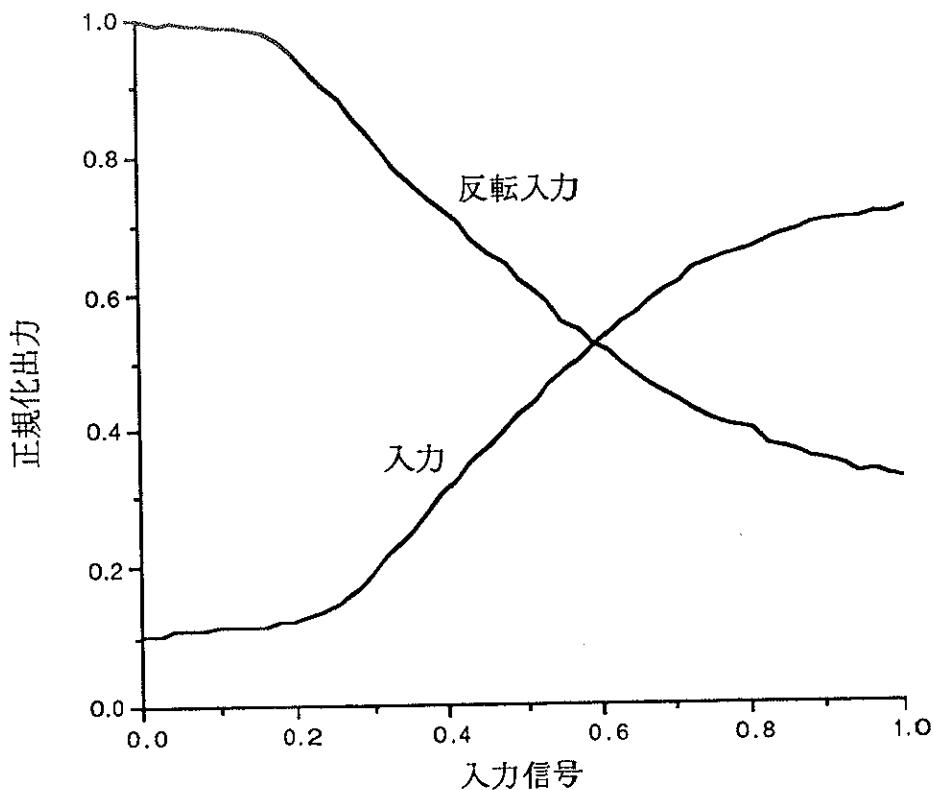


Fig.4.7.2 入力信号に対する入力側と反転側の正規化出力

4.7.4 動作実験

反転入力重ね合わせ法の基本的な原理確認のため、構成した光ニューラルシステムには25ニューロンのホップフィールドモデルを実現した。4.2.3でホップフィールドモデルについて説明した、ここでは、反転入力重ね合わせ法において必要な定数を決定するために簡単に述べておく。

a. ホップフィールド(Hopfield)モデル[17]

P個の2値ベクトル $\mathbf{V}_p = (v_{1p}, v_{2p}, \dots, v_{Np})$ を記憶するための結合荷重 $\mathbf{W} = \{w_{ji}\}$ は、

$$w_{ji} = \sum_p (2v_{jp} - 1)(2v_{ip} - 1) \quad i \neq j \\ = 0 \quad \quad \quad i = j \quad (4.7.3)$$

記憶ベクトルは、部分や間違った入力ベクトル $\mathbf{V} = (v_1, v_2, \dots, v_N)$ から以下のような式に基づいて復される。

$$x_j = \sum_i w_{ji} v_i \quad (4.7.4)$$

出力ベクトルは、

$$\begin{array}{ll}
 v_j = 1 & x_j \geq 0 \\
 = 0 & x_j < 0
 \end{array} \tag{4.7.5}$$

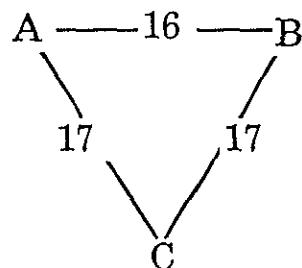
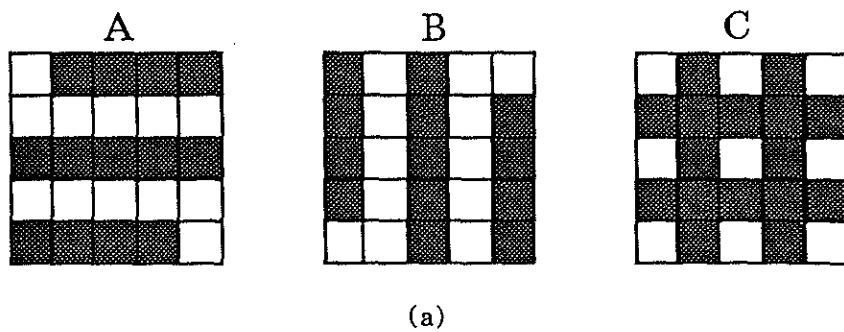
のしきい値関数で得られ、出力が定常状態になるまで新しい入力ベクトルとしてフィードバックする。

b. 動作環境

P 個の2値ベクトルを記憶する場合、式(4.7.1)から結合荷重 \mathbf{W} の最小値は $-P$ であるため、バイアス荷重 $w_{ji}^b = \{w_{ji} + P\}$ であり、定数 α は P である。よって、非線形出力関数 g は、

$$\begin{array}{ll}
 g(x) = 1 & x > NP \\
 = 0 & x \leq NP
 \end{array} \tag{4.7.6}$$

のステップ関数となる。



(b)

Fig4.7.3 3つの記憶したパターン(a)とパターン間のハミング距離(b)

Fig4.7.3は5×5の25の要素を持つ3つの記憶したパターン(a)とパターン間のハミング距離(b)が示されている。分かりやすくするために、以下にそれぞれ名前を付け、1次元ベクトルとして示す。

$$\begin{aligned}
 \mathbf{A} &= [01111 \ 00000 \ 11111 \ 00000 \ 11110], \\
 \mathbf{B} &= [10100 \ 10101 \ 10101 \ 10101 \ 00101], \\
 \mathbf{C} &= [01010 \ 11111 \ 01010 \ 11111 \ 01010].
 \end{aligned} \tag{4.7.5}$$

Fig4.7.4(a)は式(4.7.2)から計算された3つのパターンを記憶する結合荷重Wであり、 25×25 の成分を持つマトリクスである。また、3つのパターンを記憶したので最小値は-3である。Fig4.7.3(b)は、実験で用いたバイアス荷重W^bである。

```

0 -3 1 -3 -1 1 -1 1 -1 1 1 -3 1 -3 1 1 -1 1 -1 1 -1 -3 1 -3 3
-3 0 -1 3 1 -1 1 -1 1 -1 -1 3 -1 3 -1 -1 1 -1 1 -1 1 -1 1 3 -1 3 -3
1 -1 0 -1 1 -1 -3 -1 -3 -1 3 -1 3 -1 3 -1 -3 -1 -3 -1 1 -1 3 -1 1
-3 3 -1 0 1 -1 1 -1 1 -1 -1 3 -1 3 -1 -1 1 -1 1 -1 1 3 -1 3 -3
-1 1 1 1 0 -3 -1 -3 -1 -3 1 1 1 1 -3 -1 -3 -1 -3 3 1 1 1 -1
1 -1 -1 -1 -3 0 1 3 1 3 -1 -1 -1 -1 -1 3 1 3 1 3 -3 -1 -1 -1 1
-1 1 -3 1 -1 1 0 1 3 1 -3 1 -3 1 -3 1 3 1 3 1 -1 1 -3 1 -1
1 -1 -1 -1 -3 3 1 0 1 3 -1 -1 -1 -1 -1 3 1 3 1 3 -3 -1 -1 -1 1
-1 1 -3 1 -1 1 3 1 0 1 -3 1 -3 1 -3 1 3 1 3 1 -1 1 -3 1 -1
1 -1 -1 -1 -3 3 1 3 1 0 -1 -1 -1 -1 -1 3 1 3 1 3 -3 -1 -1 -1 1
1 -1 3 -1 1 -1 -3 -1 -3 -1 0 -1 3 -1 3 -1 -3 -1 -3 -1 1 -1 3 -1 1
-3 3 -1 3 1 -1 1 -1 1 -1 -1 0 -1 3 -1 -1 1 -1 1 -1 1 3 -1 3 -3
1 -1 3 -1 1 -1 -3 -1 -3 -1 3 -1 3 -1 0 -1 3 -1 -3 -1 -3 -1 1 -1 3 -1 1
-1 1 -3 1 -1 1 3 1 3 1 -3 1 -3 1 -3 1 0 1 3 1 3 -3 -1 -1 -1 1
1 -1 -1 -1 -3 3 1 3 1 3 -1 -1 -1 -1 -1 3 1 3 1 0 1 3 -3 -1 -1 -1 1
-1 1 -3 1 -1 1 3 1 3 1 -3 1 -3 1 -3 1 0 1 -1 1 -1 1 -3 1 -1
1 -1 -1 -1 -3 3 1 3 1 3 -1 -1 -1 -1 -1 3 1 3 1 0 1 0 -3 -1 -1 -1 1
-1 1 1 1 3 -3 -1 -3 -1 -3 1 1 1 1 -3 -1 -3 -1 -3 0 1 1 1 -1
-3 3 -1 3 1 -1 1 -1 1 -1 -1 3 -1 3 -1 -1 1 -1 1 -1 1 0 -1 3 -3
1 -1 3 -1 1 -1 -3 -1 -3 -1 3 -1 3 -1 3 -1 -3 -1 -3 -1 1 -1 0 -1 1
-3 3 -1 3 1 -1 1 -1 1 -1 -1 3 -1 3 -1 -1 1 -1 1 -1 1 3 -1 0 -3
3 -3 1 -3 -1 1 -1 1 -1 1 1 -3 1 -3 1 1 -1 1 -1 1 -1 1 -3 1 -3 0

```

(a)

203 21



-20A 21

(b)

Fig4.7.4 3つのパターンを記憶した結合荷重

(a) 結合荷重W

(b) バイアス結合荷重W^b

c. 想起実験

Fig4.7.5は、記憶パターンの回復を行う想起の光学実験の結果です。これらは、記憶パターンA、B、Cに対する想起率を示していて、ずれ3ビットまでの可能な全ての入力ベクトルを初期値としている。各記憶パターンに対し、ずれ1では25パターン、ずれ2では300パターン、ずれ3では2300パターンである。比較のため、計算機シミュレーションの結果を示す。これは、ずれ6ビットまでの可能な全ての入力ベクトルを初期値としている。光学実験の結果は、シミュレーションの結果より5%程度低い。正しく収束しなかったものは、シミュレーションとは異なるローカルミニマムに落ちている。

d. 想起過程

Fig. 4.7.6は想起過程の一例で、記憶パターン $C = [01010 11111 01010 11111 01010]$ から8ビットずれるあるパターン $V = [10100 11111 00111 11110 01010]$ を初期入力とした時の想起過程を示している。ここには、白黒のパターンで示されたニューロンの状態とCCD出力が示されている。(a)のパターンが初期入力であり、(b)の写真がそれを入力したときのCCD出力である。(c)のパターンは、このCCD出力を垂直方向に加算し、しきい値関数を施した結果である次のニューロンの状態である。以後、同様に、5回の状態変化の繰り返しで(k)に示される記憶パターンの1つである想起パターンCが得られていることが分かる。

4.7.5 考察

想起率の実験結果は、シミュレーションと比較した場合、5%程度の低下にとどまっている。これは、レーザー光の面発光不均一や時間的変化、LCTVの不均一、荷重を記憶するのに使用した写真フィルムの非線型性等の理想状態からのずれを考慮した場合、良好な結果であると考えられる。また、想起率の結果を見ると記憶パターンCが他のパターンに比べてその低下は大きい。これは全部で7875パターンの想起を行うために1~2時間程度必要とし、パターンCの想起実験が3つのパターンの中で最後に実行されるため、実験室内の気温の変化や電源電圧の変化によるレーザー光の時間的変化によるものと考えられる。

反転入力重ね合わせ法は、入力パターンと反転パターンが同時に必要であり、その方法として、4.4.7に示した偏光コード化法をLCTVを用いて実現している。しかし、実験ニューラルシステムで用いられているLCTVは、反転パターンを得るために設計されていないので、そのコントラストは3対1程度で非常に低い。これは、システムの能力を低下させ、より高い能力を期待する場合、専用に設計したデバイスが必要である。

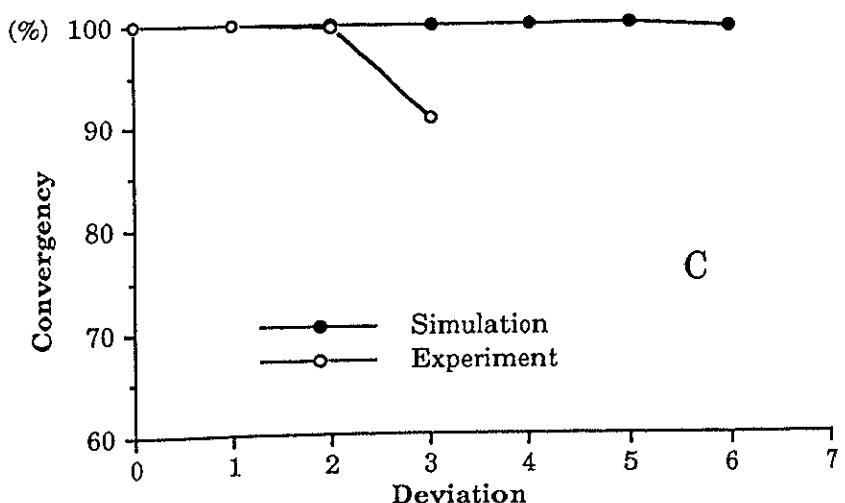
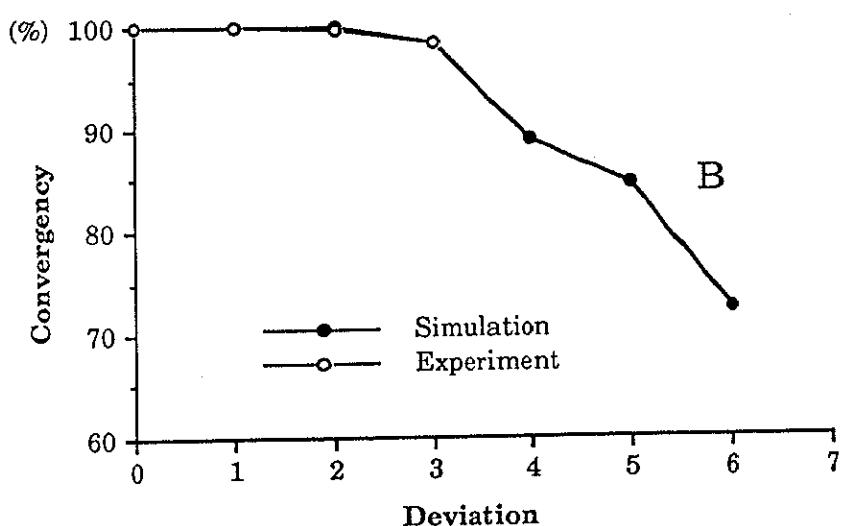
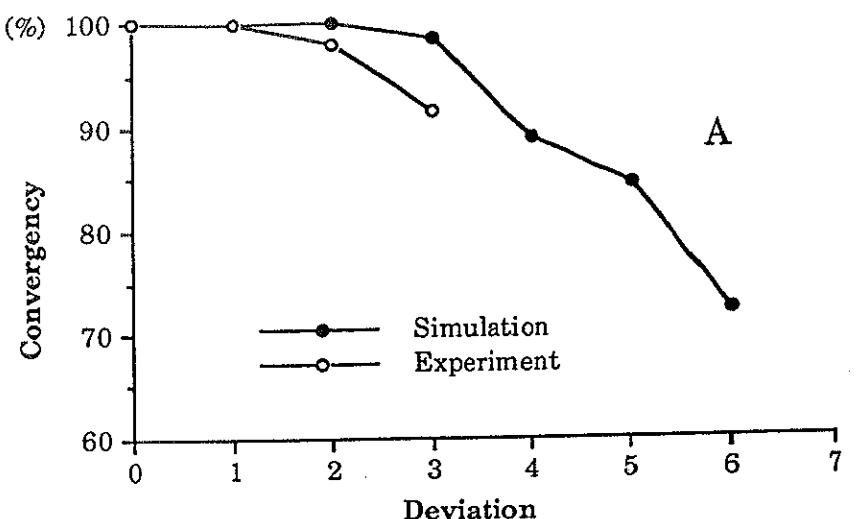


Fig. 4.7.5 ずれ3ビットまでの可能な全ての入力ベクトルを初期入力とした時の光ニューラルシステム想起率。比較のため、ずれ6ビットまでのシミュレーションを示している。

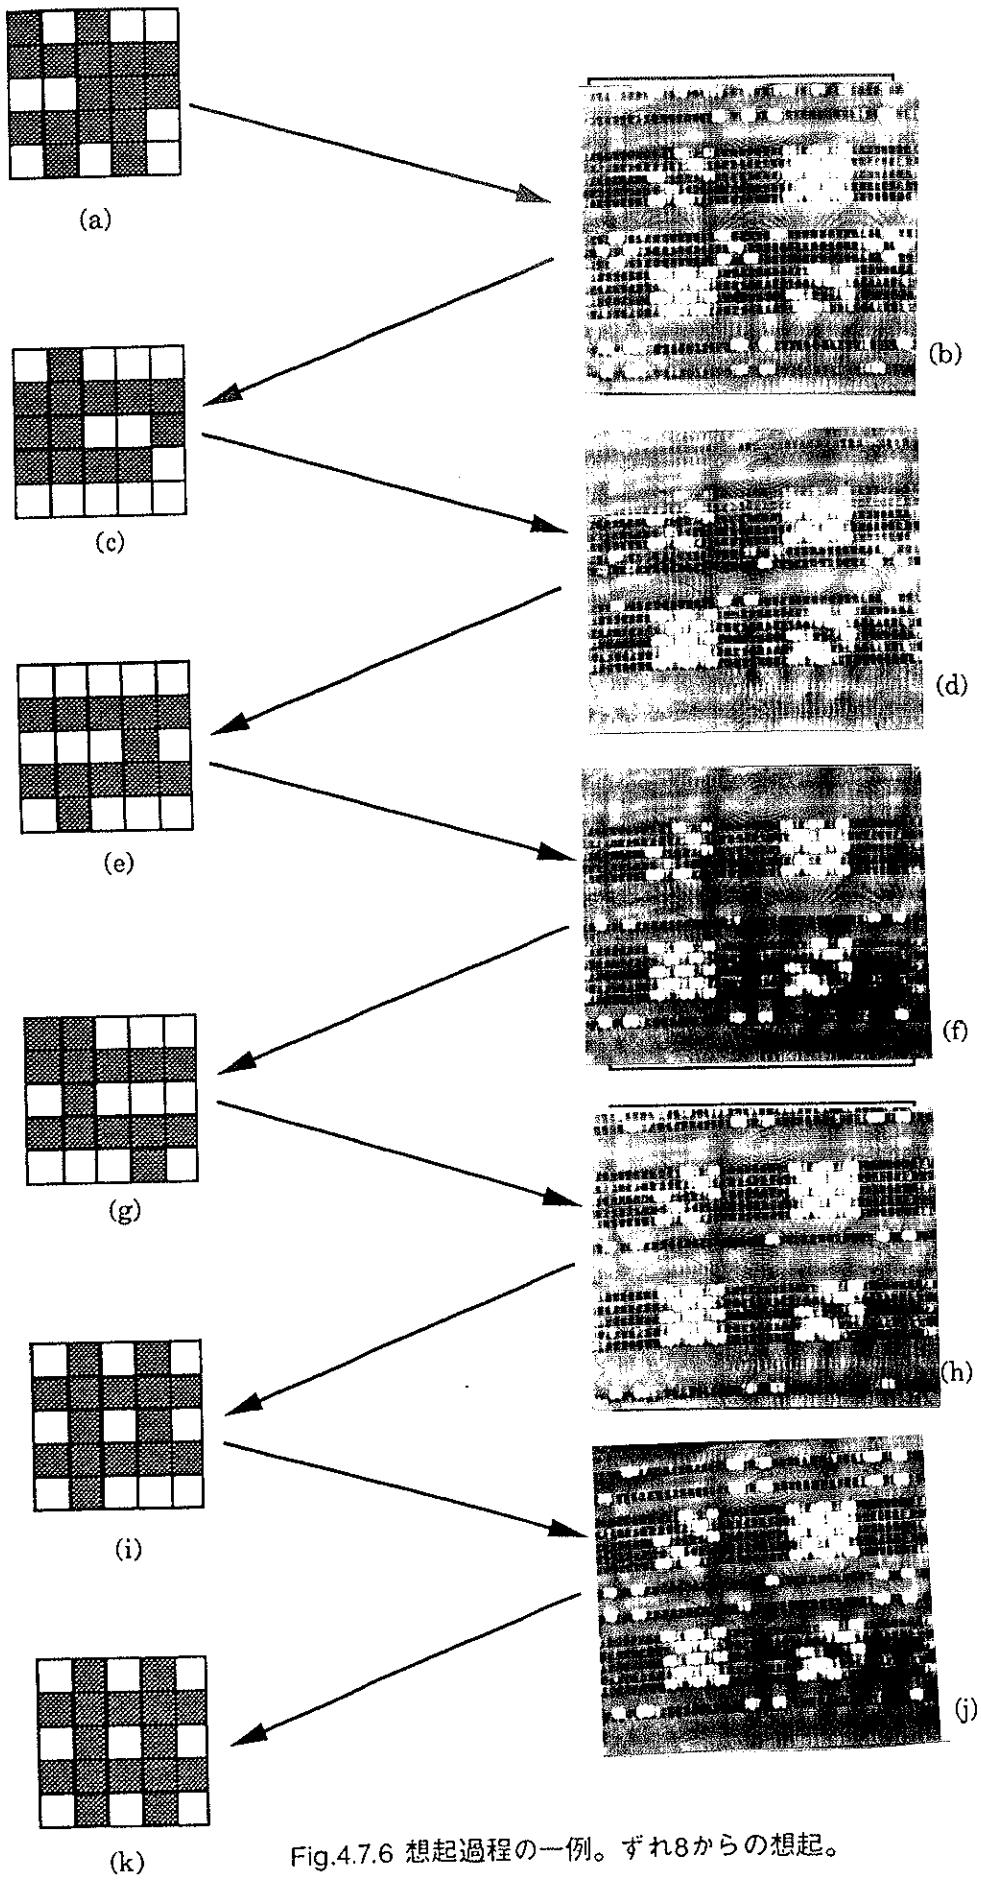


Fig.4.7.6 想起過程の一例。ずれ8からの想起。

4.8 意味ネットワークシステム

4.8.1 システムの概要

本節は光技術とニューラル技術そして知識処理の技術を融合した新しいタイプの情報処理システムについて述べる。知識処理における重要な知識表現法の1つである意味ネットワーク[78][79]は、2つの対象あるいは概念が2つのノードとそれらの関係を示す方向性を持ったアーケからなる連想ネットワークで実現できる。この意味ネットワークを個々のノードとアーケを多数のニューロンが集合したアセンブリの活性パターンにより表現する分散的表現を用いて実現する。これは、意味ネットワークをニューラルネットワークで表現することにより、学習による知識の獲得と連想性による知識の呼び出しを実現するものである。ここでは、光ニューラルネットワークの実験システムを構成し、意味ネットワークによる知識の学習と想起の実験を行った[80]。

4.8.2 意味ネットワーク

a. 意味ネットワークの基本構造

人間は、膨大な知識を持つが、深い推論をしているわけではない。人間は、持っている膨大な知識を利用して、すばやく推論を行い、その推論結果が適切なものであるかどうかを推論しつつ評価していくという、個々の人間の判断基準を持っている。これは、事実的知識が表形式で記憶される過程と推論的知識による深い推論を行う過程との中間に位置している。このような人間における知識は、どのように表現され、それに基づいてどの様な推論が行われているか、非常に興味深いことである。知識表現モデルの設計において最も重要なことは、推論に使う知識をどのような形で記憶するかということである。

知識表現手法の一つに意味ネットワーク(Semantic network)がある[78][79]。元来、意味ネットワークは、心理学における長期記憶の仮説的モデルとして考案されたものであるが、現在では知識工学における重要な知識表現モデルの一つとなった。この意味ネットワークは、知識が事実あるいは概念自体だけで存在するのではなくそれらの相互の関係において存在しているといえる。この関係性を素直に表現しようとしたモデルである。意味ネットワークは、2つの対象あるいは概念がある関係によって、結合されていることを基本とし、2つのノードとそれらを結ぶ方向性を持ったアーケから成る連想ネットワークで表現できる。意味ネットワークとは、表現された対象あるいは概念全体をさし、ネットワークにおけるノードやアーケは構成したいネットワークに応じ任意に選択する。

Fig.4.8.1は簡単な構造の意味ネットワークである。ここには、コーヒー(Coffee)という概念に対し、クラス(Class)、性質(Property)、例(Example)という関係のアーケが定義され、それぞれ飲物(Drink)、苦い(Bitter)、マンデリン(Manderine)という値が記述されている。これはそれぞれ、ク

ラスに対し飲物、性質に対し苦い、例に対しマンデリンという値が連想されていることを示す。

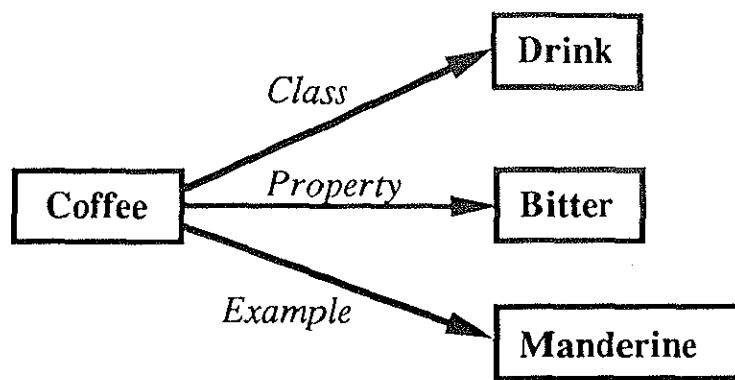


Fig.4.8.1 簡単な構造の意味ネットワーク

これらの連想ネットワークにおいて、ある種の抽象概念、ラベル的概念をタイプノード(type node)と言い、そのタイプノードと連合して定義された特定の対象をトークンノード(token node)と言う。トークンノードは、時間、場所、目的、クラス、対象物などの関係が定義される。

意味ネットワークにおいて2つの概念間の基本的な関係として、上位・下位関係と部分全体関係が上位・下位関係はisa関係と呼ばれ、包含関係または一致関係を意味する。部分全体関係は、has関係と呼ばれ、ある概念に関する部分概念を示す。それぞれの例として、

鳥 isa 動物 「鳥は動物である」 (4.8.1)

鳥 has 羽 「鳥は羽を持つ」 (4.8.2)

を示す。また、

A is B 「AはBという性質を持つ」 (4.8.3)

A causes B 「AはBの原因になる」 (4.8.4)

などの関係もあり、意味ネットワークは記述される世界に応じて、さまざまな関係を持ち、知識システムとして利用する場合、整理体系・限定が必要である。

b. 性質の継承(Property inheritance)

上位概念の対象について規定された性質は、すべて下位概念に引き継ぐという機構を性質の継承といふ。これは、一般的な性質はより上位の概念に連合させ、同一なノードの記述はできるだけ避けために導入するメカニズムである。これはisa関係が推移律を満たすことにより導入される。例えば、“鳥”の概念を表すノードにはhas関係によって“羽”的概念を表すノードがリンクされているとすると、“鳥”的下位概念である“鳩”には“羽”的ノードはリンクされない。よって、

p. 107 ~ 108

落丁

パターンの並列度が、概念間の相互作用に使われるか、また活性パターンの微視的特徴を表現するために使われるかということです。意味ネットワークは、概念間の相互作用に関して記述が粗野であり、概念を表すパターンの微視的特徴は無視している。概念間の相互作用は、意味ネットワークにおいては単純なリンクによって形成されているのに対し、ニューラルネットワークによる分散的表現を導入することによって、パターンの微視的特徴によりたくさん同時に起こりうる[5][6]。

Fig.4.8.5は人とその関係を示す簡単な構造の意味ネットワーク示している。その等価的表現の順序付き三項（トリプル）は、

(NOBU, MOTHER, TONE)
 (MIHO, MOTHER, TONE)
 (NOBU, SISTER, MIHO)
 (YOSHI, FATHER, NOBE) (4.8.9)

であり、方向性を持ったリンクとその方向の前後のノードをカッコ内の位置で表現しているものである。それぞれの項はニューロンが多数集合したアセンブリであり、ROLE、REL(Relation)、ROLE2と呼び、それらの値は2値の活性パターンにより表される。これは状態ベクトル表現という。

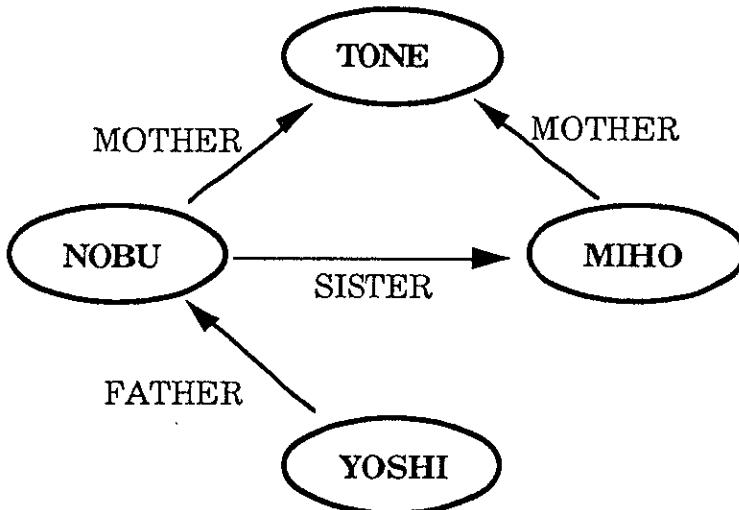


Fig.4.8.5 人とその関係の意味ネットワーク

ここで、PROP(Proposition)と呼ばれる4番目のアセンブリをトリプルに加える。トリプルを効果的に記憶するために、トリプルの2つのアセンブリ間の連想に対して、別のアセンブリが文脈として鋭敏に働く必要がある。文脈に対して鋭敏な連想を実現するためには、PROPのような第4のアセンブリが必要である。これは、単純なトリプルの結合では知識の非線形な分離、探索ができないからである。4つのアセンブリは以下のようなベクトル状に、

(ROLE1, REL, ROLE2, PROP)

(4.8.10)

と配置される。これは4つのアセンブリの状態ベクトル表現であり、それぞれビットパターンで表される。PROPは個々のトリプルに対応した状態である完全なトリプルを入力した時のPROPの状態を持ち、これを“完全PROP状態”と呼ぶ。知識の探索（想起）は、トリプルの任意の2つの成分から完全なトリプル想起することであり、PROPの次のような過程に基づいて実行される。

- 1) トリプルの任意の2つのアセンブリからPROPの状態は“完全PROP状態”に近い状態になる。
- 2) PROPの次の状態は“完全PROP状態”により近くなる。
- 3) “完全PROP状態”はトリプルを正しい状態にする。

b. 想起過程

Fig.4.8.5の意味ネットワークの中の(MIHO MOTHER TONE)、(NOBU SISTER MIHO)、(YOSHI FATHER MIHO)の3つのトリプルを記憶したときの想起過程をFig.4.8.6に示している。STOREALLとは記憶の命令であり、示した全てのトリプルを記憶する。RECALLは想起の命令を示し、この場合は(MIHO MOTHER 0)であり、「MIHOのMOTHERは?」という問い合わせに対応している。想起過程における状態ベクトルの初期入力(MIHO MOTHER 0 0)は、トリプルの任意の2つのアセンブリと3番目のアセンブリとPROPの全てのビットを0とした状態である。想起過程の2番目の状態ベクトルはトリプルには変化がなく、PROPが(MIHOMOTHERTONE4)という状態になっている。これは、“完全PROP状態”的(MIHOMOTHERTONE)から4ビットずれていることを示す。次の状態もトリプルは変化なく、PROPの状態は(MIHOMOTHERTONE2)となり、それが小さくなる。さらに次の状態では、ROLE2の状態が(TONE)となり、完全なトリプルの状態になっている。想起過程は状態ベクトルが定常状態になったら終了する。

**STOREALL (MIHO MOTHER TONE)
(NOBU SISTER MIHO)
(YOSHI FATHER MIHO)**

RECALL (MIHO MOTHER 0)

ROLE1	REL	ROLE2	PROP
MIHO MOTHER	0		0
MIHO MOTHER	0		MIHOMOTHERTONE4
MIHO MOTHER	0		MIHOMOTHERTONE2
MIHO MOTHER	TONE		MIHOMOTHERTONE
MIHO MOTHER	TONE		MIHOMOTHERTONE

Fig. 4.8.6 記憶及び想起の命令と想起過程

c. 荷重の表現

トリプルのROLE1、REL、ROLE2はビットパターンにコード化され、第4のアセンブリPROPは、そのトリプルのパターンからのランダムに写像されたパターンである。このPROPのパターンがさきに述べた“完全PROP状態”である。ランダムな写像は記憶過程において変化せず、トリプルとPROP間の結合荷重は時間的に固定なランダムである。PROPからトリプルはランダム写像の逆写像であり、時間的な変化を伴う。この逆写像の結合荷重の変化は学習によってトリプルが正しく出力されるまで続ける。PROP内の結合荷重も同様に学習によって変化し、“完全PROP状態”を記憶する自己連想的な結合変化を行う。トリプル内の個々のニューロンは自分自身に対する正の結合を持ち、想起過程において、初期状態を維持する傾向を持つ。

4つのアセンブリの結合をFig.4.8.7に示す。トリプル内の3つのアセンブリ間の結合はなく、PROPを介して結合している。このような結合により、先に示した想起過程に導く。Fig.4.8.8はFig.4.8.7を結合荷重をマトリクス状に表現したもの（荷重マトリクス）であり、16のサブマトリクスから構成されている。多くのサブマトリクスは0であり、これはトリプルの3つのアセンブリ間には結合がないことを示し、 M_{11} 、 M_{22} 、 M_{33} の対角成分のみが、トリプルのニューロン自身への結合として表現されている。トリプルからPROPへのランダムな固定結合は、 M_{14} 、 M_{24} 、 M_{34} である。学習に伴う時間的可変な結合は、PROPからトリプルへの逆写像の結合の M_{41} 、 M_{42} 、 M_{43} とPROP自身の結合の M_{44} である。

4.8.5 実験システム

a. システム構成

Fig.4.8.9は実験システムであり、MSLM、LCTV、CRT、CCDカメラ、コンピュータ等から構成され、MSLMを中心とする光学系とコンピューターを中心とする電気系のハイブリッドシステムである。光学系はニューロン間の荷重配線を実行し、電気系はニューロンの非線型出力関数と学習信号の生成、MSLMの電圧やシステム全体の制御を実行している。MSLMはFig.4.8.8の荷重マトリクスを記憶し、LCTVは状態ベクトルを水平方向に延ばしたストライプ状に表示する。結合荷重はHe-Neレーザーによって読み出され、状態ベクトルと乗算され、円筒レンズの非対称光学系によってCCD面上に水平方向に結像、垂直方向に集光（加算）される。CCD面上の光は、状態ベクトルと荷重マトリクスのベクトル・マトリクス演算の出力光となる。CRTは荷重の変更信号光を提示するためのもので、その光はMSLMの入力面に結像され、MSLMに記憶されているマトリクスを書き換える。正と負の荷重変更信号に対して、MSLMをそれぞれ加算モード、減算モードに設定することにより別々に実行される。

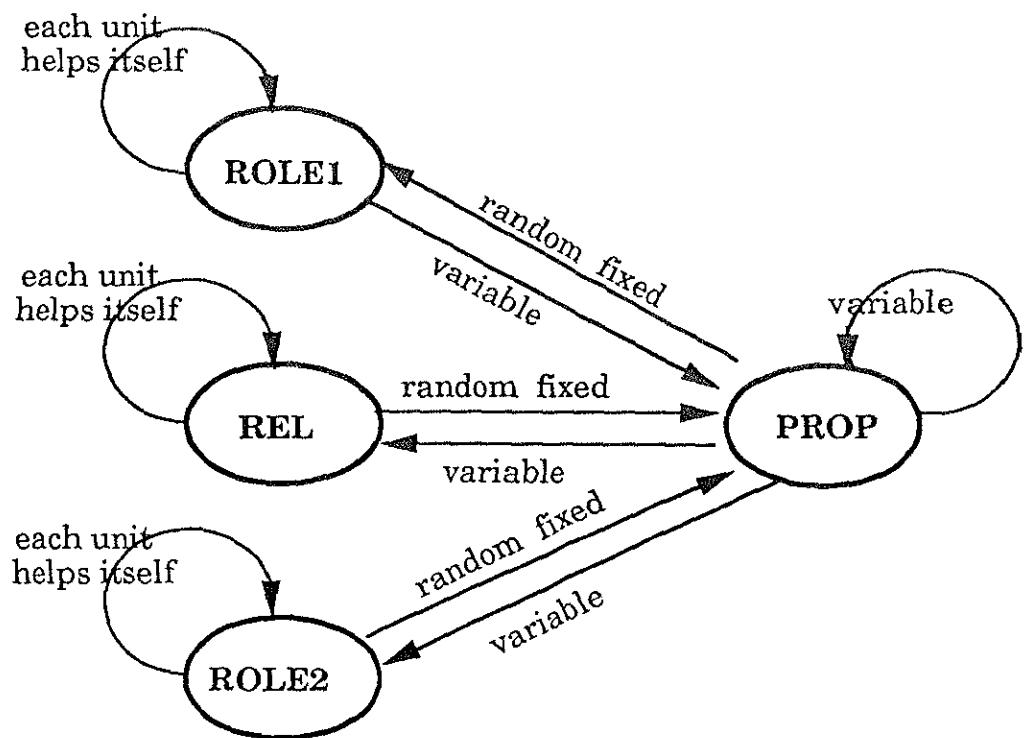


Fig.4.8.7 アセンブリ間の結合

		ROLE1	REL	ROLE2	PROP
		M ₁₁ diagonal	M ₁₂ 0	M ₁₃ 0	M ₁₄ random fixed
入力状態ベクトル	ROLE1				
	REL	M ₂₁ 0	M ₂₂ diagonal	M ₂₃ 0	M ₂₄ random fixed
	ROLE2	M ₃₁ 0	M ₃₂ 0	M ₃₃ diagonal	M ₃₄ random fixed
	PROP	M ₄₁ variable	M ₄₂ variable	M ₄₃ variable	M ₄₄ variable

出力状態ベクトル

Fig.4.8.8 荷重マトリクス

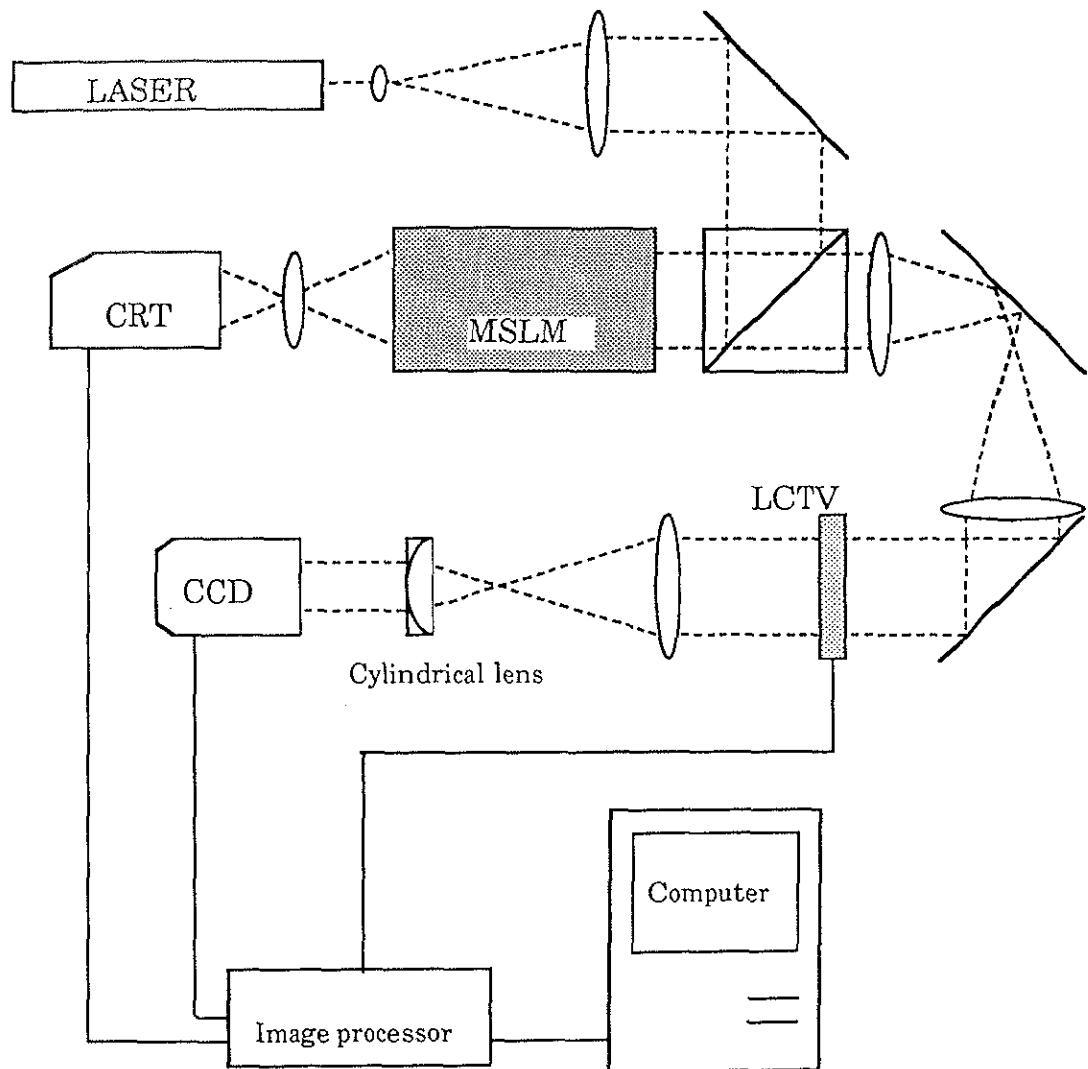


Fig.4.8.9 意味ネットワークを実現する光ニューラルシステム

b. 演算構造[5]

知識の探索過程である想起過程において、t回目の状態ベクトル $\mathbf{V}(t)$ は、4つのアセンブリの ROLE1、REL、ROLE2、PROP の状態をそれぞれ \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} で表すと

$$\mathbf{V}(t) = \{\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}\} \quad (4.8.11)$$

となり、 i 番目の成分を $v_i(t)$ と表す。Fig.4.8.8に示した荷重マトリクス全体を \mathbf{M} とすると、

$$\mathbf{M} = \begin{bmatrix} \mathbf{M}_{11}, \mathbf{M}_{12}, \mathbf{M}_{13}, \mathbf{M}_{14} \\ \mathbf{M}_{21}, \mathbf{M}_{22}, \mathbf{M}_{23}, \mathbf{M}_{24} \\ \mathbf{M}_{31}, \mathbf{M}_{32}, \mathbf{M}_{33}, \mathbf{M}_{34} \\ \mathbf{M}_{41}, \mathbf{M}_{42}, \mathbf{M}_{43}, \mathbf{M}_{44} \end{bmatrix} \quad (4.8.12)$$

となり、各成分は全て正であり、 \mathbf{M} の (j, i) 成分を m_{ji} とする。t+1回の状態ベクトルの j 番目の成分は、

$$v_j(t+1) = f(m_{ji}v_i(t) - h) \quad (4.8.13)$$

と表現できる。ここで、 h は正の定数であるしきい値を表す。非線型出力関数は、

$$\begin{aligned} f(x) &= 1 & x > 0 \\ &= 0 & x \leq 0 \end{aligned} \quad (4.8.14)$$

のステップ関数とする。状態ベクトルの初期状態は4つのアセンブリの内の2つのアセンブリであり、他のアセンブリはすべて0とする。例えば、 \mathbf{A} と \mathbf{B} から \mathbf{C} を想起する場合、

$$\mathbf{V}(0) = \{\mathbf{A}, \mathbf{B}, 0, 0\} \quad (4.8.15)$$

である。想起過程は、

$$\mathbf{V}(t+1) = \mathbf{V}(t) \quad (4.8.16)$$

となるまで繰り返される。

c. 学習

知識の記憶過程である学習過程において、その学習則は直交学習[7]が採用され、時刻 t における荷重マトリクスを $\mathbf{M}(t)$ 、記憶したいベクトルの集合から任意に選択された入力ベクトル \mathbf{V} 、その時の出力ベクトル \mathbf{V}_o 、理想的な出力ベクトル（教師ベクトル）を \mathbf{T} とすると、

$$\mathbf{M}(t+1) = \mathbf{M}(t) + \eta(\mathbf{T} - \mathbf{V}_o)\mathbf{V}^T \quad (4.8.17)$$

であり、 η は学習係数であり、任意の正の定数であり、 \mathbf{V}^T は \mathbf{V} の転置を表す。トリプル教師ベクトルは記憶したいトリプルであり、PROPの教師ベクトルはトリプルのランダム結合後のPROPの出力（完全トリプル状態）である。学習は荷重の更新がなくなるまで、言い替えると、全ての出力状態ベクトル \mathbf{V}_o と教師ベクトル \mathbf{T} のハミング距離（Hamming Distance）が0になるまで繰り返される。ハミング距離は

$$H.D. = \Sigma_p (T_p - V_o) \quad (4.8.18)$$

であり、pは記憶したい状態ベクトルを表す。

4.8.4 実験

a. 学習実験

学習は式(4.8.17)に従って実行され、学習係数 α は荷重変更光強度に対するMSLMの書き込み時間で決定されるが、MSLMは書き込みモードと消去モードの特性が異なるため、式(4.8.17)は、

$$M(t+1) = M(t) + \eta^+ T V^T - \eta^- Y V^T \quad (4.8.19)$$

のように書き換えられ、書き込みモードの学習係数 η^+ と消去モードの学習係数 η^- とし、 η^+ は0.5に設定され、 η^- は η^+ に対し2分の1程度に設定される。

Fig.4.8.10はシステムに記憶される3つのトリプルを示していて、トリプルの各アセンブリはそれぞれ3ビットであり、またPROPアセンブリは9ビットである。学習過程は3つのトリプルを順次提示し、計算した荷重の変更値の和を1度に書き込んで1回の学習とする一括修正法である。

荷重マトリクスは 18×18 の要素を持ち、Fig.4.8.11は学習過程におけるMSLMに記憶されている荷重マトリクスである。(a)は初期の荷重マトリクスであり、 M_{41} から M_{44} にあたるマトリクスの下半分には、式(5.6)による荷重マトリクスの負の変更が起きても良いように適当な値をMSLMに書き込んでいる。(b)は学習が終了したときの荷重であり、左上の対角成分は初期マトリクスから書き込まれていても良いのだが、しきい値との関係だけであり、想起過程において入力したトリプルは、必ず出力されるためである。

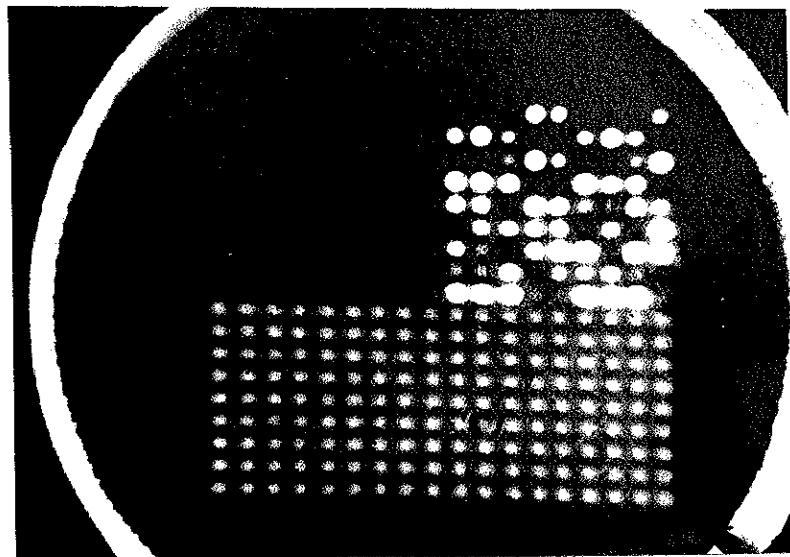
STOREALL	(Yoshi Father Nobu)
	(Tone Mother Miho)
	(Nobu Sister Miho)

ROLE	Nobu 0 1 0	REL	Sister 1 0 1
	Yoshi 1 0 1		Father 1 1 0
	Tone 1 0 0		Mother 0 1 1
	Miho 0 1 1		

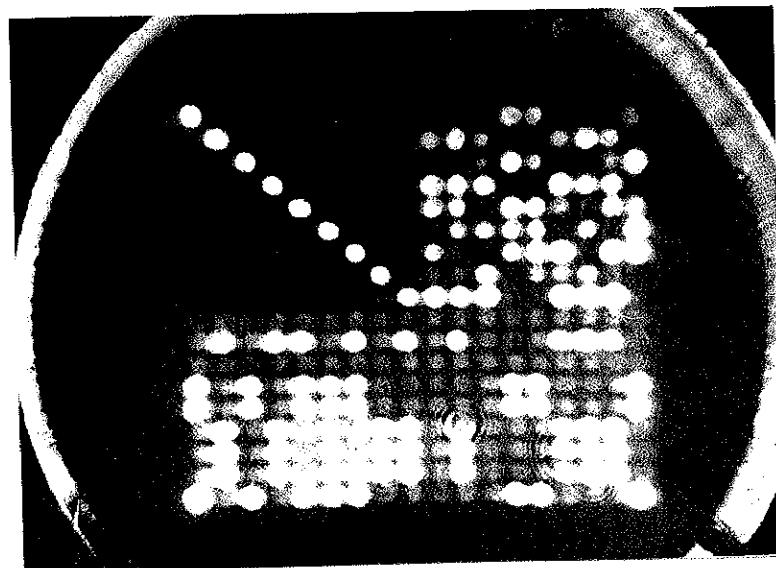
Fig.4.8.10 システムに記憶される3つのトリプルと3ビットのパターン化

b. 想起実験

想起において、1つのトリプルに対し3つの初期状態があるので、3つのトリプルを記憶した場合の



(a)



(b)

Fig.4.8.11 MSLMに記憶された結合荷重、(a)初期荷重、(b)学習終了時の荷重

想起過程における初期状態ベクトルは9つある。Fig.4.8.13はそのうちの2つの初期状態に対して、想起過程における個々のニューロンの状態変化を示したものである。それぞれ初期の状態ベクトルでは0としたアセンブリのビットパターンが正しく出力されていることが解る。Fig.4.8.12は9つの初期状態に対する想起の結果を縦軸にハミング距離、横軸に想起回数をとり示している。4つの初期状態がハミング距離が0にならず、ハミング距離が8と9になった2つの状態ベクトルは全てのニューロンが1となったものであり、他の2つの状態ベクトルは全てにニューロンが0となったものである。

Recall(Yoshio Father 0)

$V(0)=101\ 011\ 000\ 0000000000$
 $V(1)=101\ 011\ 000\ 000110001$
 $V(2)=101\ 011\ 100\ 000110001$
 $V(3)=101\ 011\ 100\ 000110001$

(Yoshio Father Nobu)

(a)

Recall(0 Sister Miho)

$V(0)=000\ 101\ 011\ 0000000000$
 $V(1)=000\ 101\ 011\ 001001110$
 $V(2)=010\ 101\ 011\ 001001110$
 $V(3)=010\ 101\ 011\ 001001110$

(Nobu Sister Miho)

(b)

Fig.4.8.12 想起の実験結果—ニューロンの状態変化

(a) Recall(Yoshio Father 0)の問い合わせに対する想起

(b) Recall(0 Sister Nobu)の問い合わせに対する想起

4.8.6 考察

実験システムはMSLMのシェーディングやレーザーの面発光分布の不均一（付録A）があるにもかかわらず、学習は終了する。これは、学習によって素子の不均一を吸収しながら正しい想起を行う荷重マトリクスを構成することである。例えば、学習を導入せず、コンピューターで計算した荷重マトリクスをそのままMSLMに書き込んだとしても正しく想起が行われない。システム全体が、個々の素子に置ける不均一を吸収していると言うことができ、ハードウェアによる大規模なシステムを構成する上で、この不均一吸収性を持つ演算構造はとても有効である。

現在用いている学習方式では固定ランダム結合に当たるトリプルからPROPへの結合に対する学習

ができないため、PROPでのパターンが効率的に作成できないので、学習が終了しない場合がある。例えばPROPにおけるパターンの直交性が悪いときや線形分離でないときである。これはPROPのニューロン数を増やすことにより解決できるが、本質的な解決法ではない。また、固定の荷重はシステムの不均一がそのまま影響してしまう。よってさらに強力な学習方式が必要である[81][82]。

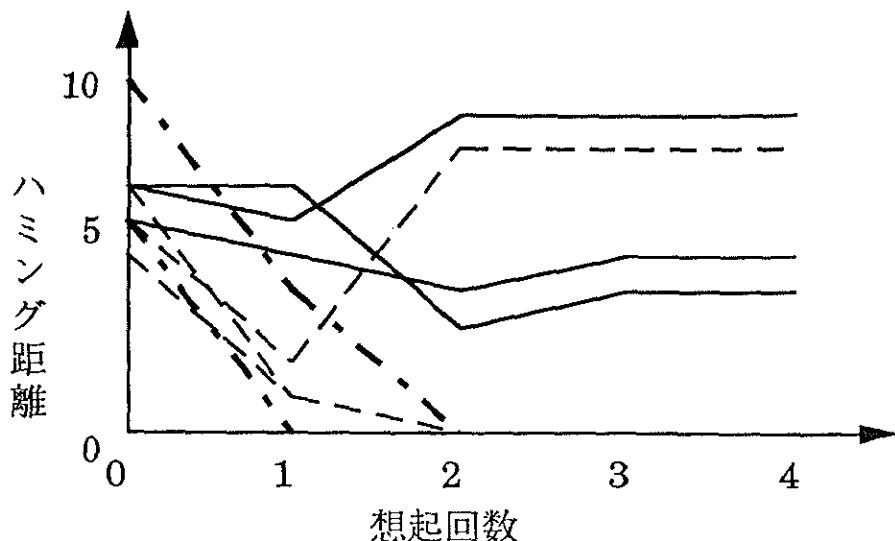


Fig.4.8.13 9つの初期状態に対する想起の結果

4.9 まとめ

本章では、筆者らが構成したいくつかの光ニューラルシステムについて述べた。これらのシステムは、光ベクトルマトリクス演算器またはその拡張である多重結像光学系を基本構成として構成されていた。はじめに、それらのシステムについて知るために、ニューラルネットワークの基本モデルと学習についてそれぞれ4.2と4.3で述べ、学習の有効性と構造の光技術との親和性について述べた。さらにニューラルネットワークの光学的実現の為の手法について4.4で述べた。そこでは、筆者らが提案している光ニューラルモジュールについて述べ、既存の構成法である光ベクトルマトリクス演算器、新しい構成法である多重結像光学系について述べた。多重結像光学系は、入力を2次元のまま取り扱えるという光の並列性を活かすことのできる演算構造をもっている。また、MSLMによってニューロンの非線型出力関数を実現する実験について示した。ここではニューロン数が4ニューロンと少ないながら、実現した非線型関数はシグモイド関数と相似であり、ニューラルネットワークの動作も計算機シミュレーションにおける動作とほとんど変わらないことを示し、光ニューラルモジュールの非線型素子として用いることができるることを示した。

また、荷重の正負を実現する位置表現法において、その新しい更新法である单方向更新法と双方向更新法を提案し、計算機シミュレーションを通してその特性を検討し有用性を明かにした。さらに、筆者の考案した反転入力重ね合わせ法はニューラルネットワークの光学的実現に適し、ニューラルネットワークの全ての計算が正の乗算と加算で表現できる実行モデルである。既存のニューラルの表現法がなんらかのかたちで元のニューラルネットワークの2倍の素子が必要であったのに対し、元のニューラルネットワークと同じ素子数で実現できることもこのモデルの利点である。

最後に4.4で述べた、光学的実現の手法、モデル、アーキテクチャを基にして、4つの具体的な光ニューラルシステムの実験システムと動作実験について報告した。1つの光ニューラルシステムは、BP学習を伴う3層の光ニューラルネットワークを実現したはじめてのシステムである。荷重は位置表現法とマトリクス分割法を用いて表現され、单方向更新法と双方向更新法を用いて学習された。そしてそれらの更新法の実験的検証を行い、その結果から、多くの場合で双方向更新法の方が学習の収束性が良いことを示した。さらにシステムで用いられるデバイスの必要な性能について考察した。

多重結像光ニューラルシステムは、入力を2次元情報のまま取り扱うことのできる2次元構造を実現するため多重結像光学系を実際に適用した学習可能なはじめての光ニューラルシステムであった。多重結像光学系は、筆者が開発したセルフォックマイクロレンズアレイ(SMLA)によって実現され、その光学系は大規模かつコンパクトな光学系が可能である。学習機能を得るために、光書き込み可能な空間光変調素子であるPROMを結合荷重の記憶に適用した。ここでは、システムの学習実験の結果について報告し、学習の収束を確認した。さらに、SMLAを構成するセルフォックマイクロレンズのPSFの測定から現システム可能な最大ニューロン数は 247×247 であり、SMLAが十分な特性を持つことを示した。

反転入力重ね合わせ法(RIST)に基づく光ニューラルシステムでは、RISTの有用性を示すため、LCTVによって偏光パターンが表示できること用いて実現されている。システムにおいて、25ニューロンのホップフィールドモデルが実現されている。想起実験において、想起率の低下は、計算機シミュレーションと比較した場合5%程度であった。これは、LCTVの特殊使用や空間的表示特性のばらつき、フィルムの非線型性を考慮すると良い性能と考えられる。この方法は、先に示したMSLMによる非線型出力関数の実現との組み合せにより、純光学的構成が可能である。

意味ネットワークを実現する光ニューラルシステムは、光技術とニューラル技術そして知識処理の技術を融合した新しいタイプの情報処理システムを提案し実現したものである。知識処理における重要な知識表現法の1つである意味ネットワークは、ニューラルネットワークの分散的表現を用いて実現が提案されていたが、筆者らはそれに基づいて光ニューラルネットワークの実験システムを構成し、意味ネットワークにおける知識の学習と想起の実験を行った。

これらのシステムは個々の技術やモデルの個々の実験的検証であるが、より大規模、より高性能な光ニューラルシステムを実現するためには、その融合適用がなされると考えられる。筆者は、反転入力重ね合わせ法の光ニューラルシステムを多重結像光学系による2次元構造を導入したシステムが最も有望であると考える。その構成において現在の個別部品を配列する光学定盤上の技術では、ニューロン数は100程度が限界であるため、効率的な実装技術が不可欠である。

参考文献

- [1] 甘利俊一, "神経回路網の数理—脳の情報処理様式ー", 産業図書(1978).
- [2] 福島邦彦, "神経回路網と自己組織化", 共立主版(1979).
- [3] 麻生英樹, "ニューラルネットワーク情報処理", 産業図書(1988)
- [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] G. E. Hinton and J. A. Anderson, "Parallel models of Associative Memory," (Erlbaum, Hillsdale, NJ 1981).
- [6] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, "Parallel Distributed Processing," (MIT Press,Cambridge,1986).
- [7] T. Kohonen, "Self-Organization and Associative Memory" (Springer-Verlag, New York, 1984).
- [8] 特集: "Artificial Neural Systems," IEEE Computer **21**, (March 1988).
- [9] 特集: "Neural Networks," Proc. IEEE 78-79, (Sep.-Oct. 1990).
- [10] M. A. Sivilotti, M. R. Emeling, and C. A. Mead,"VLSI Architectures for implementation of neural networks," In Proceedings of the AIP Conference on Neural Networks for Computing, 408-413 (1986).
- [11] H. P. Graf, L. D. Jackel, R. E. Howard, B. Straughn, B. J. S. Denker, W Hubbard, D. M. Tennat, and D. Schwartz,"VLSI implementation of a neural network memory with several hundreds of neurons," In Proceedings of the AIP Conference on Neural Networks for Computing, 182-187 (1986).
- [12] M. Yasunaga, N. Masuda,M. Asai, M. Yamada, A. Masaki, and Y. Hirai,"A wafer scale integration neural network utilizing completely digital circuits," In Proceedings of IJCNN'89 Washington D.C., Vol. II 213-217 (1989).
- [13] H. Kato, H. Yoshizawa, H. Ichiki, and K. Asakawa,"A parallel neurocomputer architecture towards Billion connection updates per second. In Proceedings of IJCNN'90

Wasington D.C., Vol. II 47-50 (1990).

- [14] Y. Shimokawa, Y. Fuwa, and N. Aramaki,"A parallel ASIC VLSI neurocomputer for a large number of neurons and billion connection per second speed. In Proceedings of IJCNN'91 Singapore, Vol. III 2162-2167 (1991).
- [15] Y. Hirai, K. Kamada, M. Yamada, and M. Ooyama,"A digital neuro-chi with unlimited connectability for large scale neural networks," In Proceedings of IJCNN'89 Wasington D.C., Vol. II 163-169 (1989).
- [16] R. P. Bocker,"Matrix multiplication using incoherent optical technique," *Appl. Opt.* **13**, 1670 (1974).
- [17] J. J. Hopfield,"Neural networks and physical systems with emergent collective computational abilities," *Proc. Natl. Acad. Sci. USA* **79**, 2554 (1982).
- [18] N. Farhat and D. Psaltis, "New Approach to Optical Information Processing Based on Hopfield Model," *J. Opt. Soc. Am. A1*, 1296 (1984).
- [19] D. Psaltis and N. H. Farhat, "Optical information processing based on an associative-memory model of neural nets with thresholding and feedback," *Opt. Lett.* **10**, 98-100 (1985).
- [20] N. H. Farhat, D. Psaltis, A. Prata and E. Peak,"Optical implementation of Hopfield model," *Appl.Opt.* **24**, 1469-1475(1985).
- [21] M. Takeda and J. W. Goodman, "Neural networks for computation, number representations and programing complexity," *Appl. Opt.* **25**, 3033-3046 (1986).
- [22] B. Widrow and M. E. Hoff, "Adaptive Switching Circuits," IREWESCON Conv. Rec. Part 4, 96 (1986).
- [23] A. D. Fisher, C. L. Giles, and J. N. Lee, "Associative Processor Architectures for Optical Computing," *J. Opt. Soc. Am. A1*, 1337 (1984).
- [24] A. D. Fisher, W. L. Lippincott, and J. N. Lee, "Optical implementations of associative networks with versatile adaptive learning capabilities," *Appl. Opt.* **26**, 5039-5053 (1987).
- [25] A. D. Fisher, R. C. Fukuda and J. N. Lee,"Implementations of Adaptive Associative Optical Computing Elements," *Appl. Opt.* **26**, 5061-5076 (1987).
- [26] B. Kosko and C. C. Guest, "Optical Bidirectional Associative Memories," *Proc. Soc. Photo-Opt. Instrum. Eng.* **698**, 15 (1987).
- [27] C. C. Guest and R. TeKolste,"Designed and devices for optical bidirectional associative memories," *Appl. Opt.* **26**, 5055-5060(1987).

- [28] N. H. Farhat,"Optoelectronic analogs of self-programming neural nets, architecture and methodologies for implementing fast stochastic learning by simulated annealing," *Appl. Opt.* **26**, 5093-5103 (1987).
- [29] K. Wagner and D. Psaltis,"Multilayer optical learning networks," *Appl. Opt.* **26**, 5061 (1987).
- [30] D. Psaltis, D. Brady, and K. Wagner,"Adaptive optical networks using photorefractive crystals," *Appl. Opt.* **27**, 1752-1759 (1988).
- [31] M. Oita, J. Ohta, S. Tai, and K. Kyuma,"Optical implementation of large-scale neural networks using a time-division-multiplexing technique," *Opt. Lett.* **15**, 227-229 (1990).
- [32] F. Ito and K. Kitayama,"Optical implementation of the Hopfield neural network using multiple fiber nets," *Appl. Opt.* **28**, 4176-4181 (1989).
- [33] M. Ishikawa, N. Mukouzaka, H. Toyoda, and Y. Suzuki,"Optical associatron, a simple model for optical associative memory," *Appl. Opt.* **28**, 291-301 (1989).
- [34] M. Ishikawa, N. Mukouzaka, H. Toyoda, and Y. Suzuki,"Experimental studies on learning capabilities of optical associative memory," *Appl. Opt.* **29**, 289-295 (1990).
- [35] T. Lu, S. Wu, X. Xin, and F. T. S. Yu,"Two-dimensional prigrammable optical neural network," *Appl. Opt.* **28**, 4908-4913 (1989).
- [36] F. T. S. Yu, T. Lu, X. Yang, and D. A. Gregory,"Optical neural network with pocket-sized liquid-crystal televisions," *Opt Lett.* **15**, 863-865 (1990).
- [37] Y. Hayasaki, I. Tohyama, T. Yatagai, M. Mori, and S. Ishihara,"Optical Learning Neural Network Using Selfoc Microlens Array," *Jpn. J. Appl. Phys.* **31**, 1689-1693 (1992).
- [38] J. Ohta, M. Takahashi, Y. Nitta, S. Tai, K. Mitsunaga, and K. Kyuma,"GaAs/AlGaAs optical synaptic interconnection device for neural networks," *Opt. Lett.* **14**, 844-846 (1989).
- [39] J. Ohta, Y. Nitta, and K. Kyuma,"Dynamic optical neurochip using variable-sensitivity photodiodes," *Opt. Lett.* **16**, 744-746 (1991).
- [40] A. W. Lohmann and H. W. Werlich,"Holographicm Production of Spatial Filters for Code Translation and Image Restoration," *Phys. Lett. A* **25**, 570 (1967).
- [41] D. Gabor, "Associative Holographic Memories," *IBM J. Res. Dev.* **13**, 156 (1969).
- [42] M. Nakajima, T. Morikawa, and K. Sakurai,"Automatic Character Reading Using a Hoographic Data Processing Technique," *Appl. Opt.* **11**, 362 (1972).
- [43] H. Akahori and K. Sakurai,"Information Search Using Holography," *Appl. Opt.* **11**, 413

(1972).

- [44] H. Mada,"Architecture for Optical Comuting Using Holographic Associative Memories," Appl. Opt. **24**, 2063 (1985).
- [45] A. Yariv, S. K. Kwong, and K. Kyuma, "Demonstration of an All-Optical Associative Holographic Memory", Appl. Phys. Lett. **48**, 1114(1986).
- [46] B. H. Soffer, G. J. Dunning, Y. Owechko, and E. Marom,"Associative Holographic Memory with Feedback using Phase-Cojugate Mirrors", Opt. Lett. **11**, 118 (1986).
- [47] G. J. Dunning, E. Marom, Y. Owechko, and B. H. Soffer, "All-Optical Associative Memory with Shift-Invariance and Multiple-Image Recall", Opt. Lett. **12**, 346(1987).
- [48] E. G. Peak and D. Psaltis,"Optical associative memory using Fourier transform holograms," Opt. Eng. **26**, 428-433 (1987).
- [49] D. Z. Anderson,"Coherent Optical Eigenstate Memory," Opt. Lett. **11**, 56 (1986).
- [50] K. Aihara, M. Takabe, and M. Toyoda,"Chaotic Neural networks," Phys. Lett A **144** 333-340 (1990).
- [51] R. J. McEliece, E. C. Posner, E. R. Rodemich, and S. S. Venkatesh,"The capacity of the Hopfield associative memory," IEEE Trans. IT **33**, 461-482 (1987).
- [52] J. J. Hopfield and D. W. Tank, "Neural computation of decisions in optmaization probrems," Bilo. Cybern. **52**, (1985), 141-152.
- [53] S. Kirkpatrick, C. D. Gelatt, Jr., and M. P. Vecchi, "Optimaization by simulating annealing," Sience **220**, 671(1983).
- [54] Rippmann , "Neural Network Classifiers for Speech Recognition," The Lincoln Lab. Journal **1**, 107 (1988).
- [55] 浅川和雄,"ニューロコンピューターとロボットの知能化," システム制情報御学会, システム／制御／情報 **34**, 7 (1990).
- [56] D. Hebb,"Organization of Behavior," (Wiley, New York,1949).
- [57] F. Rosenblatt,"Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanism," (Spartan, Wasington D.C., 1961).
- [58] M. Minsky and S. Papert,"Perceptrons," (MIT Press, 1988)
- [59] S. Amari,"Theory of adaptive pattern classifiers," IEEE Trans. EC **16**, 299-307 (1967).
- [60] K. Iga, M. Oikawa, S. Misawa, J. Banno, and Y. Kokubun,"Stacked Planar Optics: an Application of the Planar Microlens," Appl. Opt. **21**, 3456-3460(1982).

- [61] D. Psaltis, A. A. Yamamura, K. Hsu, S. Lin, X. Gu, and D. Brady, "Optical Implementation of neural Networks," IEEE COMMUNICATION MAGAZINE 27, 37-71 (1989).
- [62] 窪田, 西田, "空間光変調器", 光学 14, 19 (1985).
- [63] 原勉, 鈴木義二, "空間光変調素子" オプトロニクス 5, 73 (1985).
- [64] N. Kasama, Y. Hayasaki, T. Yatagai, M. Mori and S. Ishihara, Experimental Demonstration of Optical Three-Layer Neural Network, Jpn.J.Appl.Phys. 29, 8 (1990), 1565.
- [65] I. Shariv, O. Gila, and A. A. Friesem,"All-optical bipolar neural network with polarization-modulating neurons," Opt. Lett. 16, 1692-1694 (1991).
- [66] M. Kranzdorf, B. J. Bibner, L. Zhang, and K. M. Johnson,"Optical connectionist machine with polarization-based bipolar weight values," Opt. Eng. 28, 844-848 (1989).
- [67] A. P. Ittycheriah, J. F. Walkup, T. F. Krile, and S. L. Lim,"Outer product processor using polarization encoding," Appl. Opt. 29, 275-283 (1990).
- [68] M. G. Robinson and K. Johnson,"Noise analysis of polarization-based optoelectronic connectionist machines," Appl. Opt. 31, 263-272 (1992).
- [69] 早崎, 遠山, 谷田貝, 森, 石原, "光ニューラルネットワークのための反転入力重ね合わせ法," 第53回応用物理学会学術講演会, 講演予稿集 3, (大阪, 1992).
- [70] C. H. Wang and B. K. Jenkins,"Subtracting incoherent optical neural model, analysis, experiment, and applications," Appl. Opt. 29, 2171-2186 (1990).
- [71] I. Shariv, and A. A. Friesem,"All-optical neural network with inhibitory neurons," Opt. Lett. 14, 485-487 (1989).
- [72] S. Zhivkova and M. Miteva,"Image subtraction using fixed holograms in photorefractive $\text{Bi}_{12}\text{TiO}_{20}$ crystals," Opt. Lett. 16, 750-751 (1991).
- [73] M. Ishikawa, N. Mukohzaka, H. Toyoda, and Y. Suzuki,"Experimental studies on adaptive optical associative memory," SPIE 963, Optical Computing 88, 527-536 (1988).
- [74] T. Minemoto, K. Okamoto, and K. Miyamoto,"Optical parallel logic gate using spatial light modulators with the Pockels effect," Appl. Opt. 24, 2055 (1985).
- [75] K. Hamanaka,"Optical bus interconnection system using Selfoc Lenses," Opt. Lett. 16, 1222-1224 (1991).
- [76] Y. Osugi, A. Honda, A. Hamajima, S. Toyoda, and Y. Kozuka,"A New for Making High-Resolution Pockels Readout Optical Modulator (PROM)," 光学 21, 237-240 (1992).
- [77] K. Hamanaka, H. Nemoto, M. Oikawa, E. Okuda, and T. Kishimoto,"Multiple imaging

and multiple Fourier transformation using planar microlens arrays," *Appl. Opt.* **29**, 4064-4070 (1990).

[78] 長尾, "知識と推論," 岩波書店 (1988).

[79] 上野、石塚, "知識の表現と利用," オーム社 (1987).

[80] Y. Hayasaki, N.Kasama, T. Yatagai, M. Mori, and S. Ishihara,"Optical Implementation of Semantic Networks Based on Association," *Jpn. J. Appl. Phys.* **29**, L1321-L1324 (1992).

[81] D. E. Rumelhart, G. E. Hinton, and R. J. Williams," Learning representations by back-propagating errors," *Nature* **323**, 533-536 (1986).

[82] F. J. Pineda,"Generalization of Back-Propagation to Recurrent Neural Networks," *Phys. Rev. Lett.* **59**, 2229-2232 (1987).

第5章 画像認識システム

5.1 はじめに

第2章では、光デジタルシステムと光ニューラルシステムを要素システムとして統合した光コンピューティングシステムについて述べた。そこでは、光コンピューティングシステムの構成の概念と要素システムの特徴を考慮したシステム内の処理の流れについて述べた。第3章で述べた要素システムの1つである光デジタルシステムは、プログラムにより動作が記述され、高い精度で処理を行う計算システムである。第4章で述べたもう1つのシステムである光ニューラルシステムは、与えられた曖昧な情報に対する処理や有用な情報を能動的に獲得することができるシステムである。

本章では、光コンピューティングシステムの1つの実現形態として、与えられた入力画像を光デジタルシステムで処理し、その結果を光ニューラルシステムの入力として与え、入力画像の認識[1][2]を行う情報処理システムを提案し、その構成と動作について述べる。光デジタルシステムは、入力画像のエッジ検出を行い、そのエッジ検出の結果から4つの特徴量を計算する。ここでは、高速な処理のため入力画像の持つ多くの情報量を特徴量というより少ない情報量に変換している。光ニューラルシステムは、4つの特徴量を入力として与え、学習及び認識を行う。学習はあらかじめ与えられる入力画像のサンプルによって得られる特徴量のBP学習則を用いて行われ、認識は、学習済みのネットワークに4つの特徴量が与えられる。これは入力画像の欠損や適度な量のノイズに対して正しい出力を得る事が可能となる。特徴量は、エッジの量から計算されるので、入力画像の形状や位置の情報を持たないため、入力の移動や歪みに対しては同じ出力が得られる。これらのシステム全体の動作を計算機シミュレーションを通して示し、光学実験では、時間符号化に基づく光デジタルシステムによるエッジ検出の結果について示す。

5.2 システム

5.2.1 システムの概要

Fig.5.2.1は、入力画像が文字の場合について、画像認識システムの構成の概念図であり、2.3節システムの処理の流れで示した(a)の流れを持ったシステムである。これは与えられた入力情報がはじめに光デジタルシステムで処理され、その結果が光ニューラルシステムで処理され、出力情報を得る流れである。この処理の流れは、入力情報の中の必要な情報を得るために手順があらかじめ知られていて、その得られた情報を総合的かつ適応的に処理する必要がある場合に用いられる。一般に画像情報などは多くの情報量を持っているため、高速な処理を行うためには必要な情報だけを効率良く取り出し、情報量を減少させる必要がある。これは、人間のようにニューラルシステムのみで実行可能で

あるが、情報量を減少させる有効な手順が解っている場合、光デジタルシステムを用いて処理する方が効率がよい。さらに、光デジタルシステムによって処理された出力を光ニューラルシステムによつてさらに処理する必要がある場合は、入力情報のノイズ等によりデジタルシステムの出力が変動し、かつそれが解析的でない場合においても同様な結果が要求されたり、時間的に変化する入力情報に適応的に対応し処理を行う必要があるときに用いられる。

このシステムは、与えられた入力画像があらかじめ学習しておいた画像のうちどの画像であるかを判断する画像認識システムである。デジタル画像（一般的な入力画像は多値またはアナログ画像であり、なんらかの方法でしきい値処理した後の画像）が入力されたとき、光デジタルシステムでは、2値入力画像の特徴を抽出する処理を行い、得られたアナログの特徴量を光ニューラルシステムの入力として与え、あらかじめ学習によってコード化しておいた出力ニューロンに入力パターンが何であるかが得られる。例えば、ニューラルネットワークの出力パターンを文字のコードにしておけば、自動的に文字が検索される。

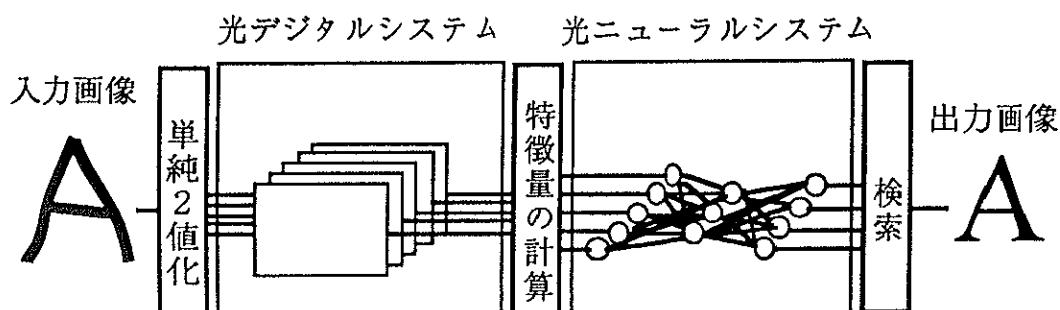


Fig.5.2.1 統合システム構成の概念図（文字認識）

5.2.2 システムの処理

a. 光デジタルシステム

画像中の対象物や現象を把握するための画像の解析において、その処理の第一段階は、画像の分割と呼ばれ、そこで抽出される画像の特徴としてはエッジと領域がある。エッジ検出と領域分割は互いに相補的であり、エッジ検出[1]により画像中の不連続部分を抽出し、閉じたエッジにより領域が求められる。領域には濃度、色、テクスチャー等の特徴があり、それらの一様な連結領域に画像を分割し、領域間の境界としてエッジが求められる。デジタル画像（パターン）では、領域は黒(0)または白(1)のみであるので、領域の特徴はない。そのため、デジタル画像の特徴とは、エッジの方向と位置によって表される。

デジタル画像のエッジ検出は、差分で表現され、x方向、y方向の差分を Δ_x 、 Δ_y とし、画像Fの(i,j)

画素値を $f(i,j)$ とすると、

$$\begin{aligned}\Delta_x f(i, j) &= f(i, j) - f(i-1, j) \\ \Delta_y f(i, j) &= f(i, j) - f(i, j-1)\end{aligned}\quad (5.2.1)$$

で表せる。

エッジ検出を光デジタルシステムの画像間の論理演算で実行するためことを考える。左エッジを得る場合についてFig.5.2.2に示す。ここで、画像の移動（シフト）を定義する。Fig.5.2.2(a)に示されたデジタル画像Fに対する右(right)、左(left)、上(up)、下(down)の1画素のシフト(shift)をそれぞれ、以下のように表す。

$$SR(F), SL(F), SU(F), SD(F), \quad (5.2.2)$$

SR(F)をFig.5.2.2(b)に示す。(5.2.1)式の差分は、-1、0、1であり、その絶対値はつぎのように画像

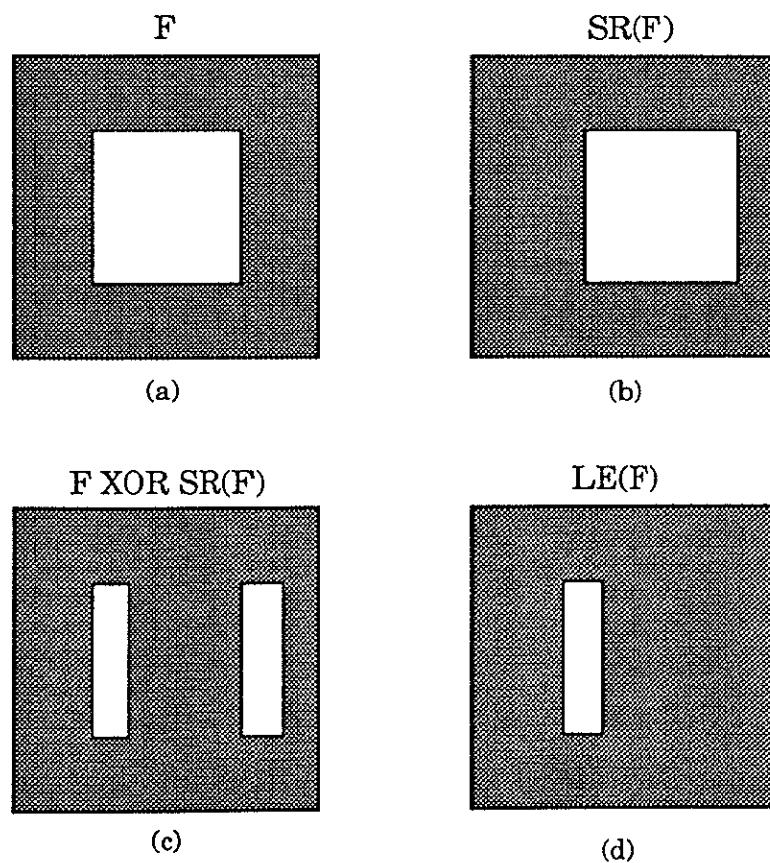


Fig.5.2.2 左エッジ画像を得る過程

(a)入力画像F (b)右シフト画像SR(F)

(c)入力画像Fと右シフト画像SR(F)とのXOR

(d)左エッジ画像LE(F)

F とその右シフト画像 $SR(F)$ と論理演算 XOR で得られる。

$$F \text{ XOR } SR(F) \quad (5.2.3)$$

論理演算 XOR によって得られたエッジ画像(Fig.5.2.2(b))は、入力画像内のエッジと入力画像外のエッジを同時に含む(Fig.5.2.2(c))。左右のエッジを白領域内のエッジに統一するために、(5.2.3)と F の論理演算 AND を実行して、左側のエッジを検出する。左エッジ画像を $LE(F)$ とすると、

$$LE(F) = (F \text{ XOR } SR(F)) \text{ AND } F \quad (5.2.4a)$$

となる(Fig.5.2.2(d))。また、右、上、下のエッジの画像を、それぞれ、 RE 、 UE 、 DE とすると

$$RE(F) = (F \text{ XOR } SL(F)) \text{ AND } F \quad (5.2.4b)$$

$$UE(F) = (F \text{ XOR } SD(F)) \text{ AND } F \quad (5.2.4c)$$

$$DE(F) = (F \text{ XOR } SU(F)) \text{ AND } F \quad (5.2.4d)$$

のようにエッジ検出できる。これらは別の論理演算の組み合わせによっても実行できる。これらのエッジ画像は全てのエッジの中からパターンの角のみの画像である角画像を得ることを考える。左上の角画像は左エッジと上エッジとの AND により得られる。左上の角画像を $LUE(F)$ とすると、

$$LUE(F) = LE(F) \text{ AND } UE(F) \quad (5.2.5a)$$

により得られ、左下、右上、右下の角画像を、それぞれ、 $LDE(F)$ 、 $RUE(F)$ 、 $RDE(F)$ とすると、

$$LDE(F) = LE(F) \text{ AND } DE(F) \quad (5.2.5b)$$

$$RUE(F) = RE(F) \text{ AND } UE(F) \quad (5.2.5c)$$

$$RDE(F) = RE(F) \text{ AND } DE(F) \quad (5.2.5d)$$

のように得られる。

以上に示した処理は、 (i,j) 画素の近隣画素間の計算なので、ノイズによる孤立点や小領域を取り除くことができず、そのままエッジ画像にノイズとして残る。また、線に関しては同様にそのまま残る。

b. 光ニューラルシステム

光デジタルシステムにおいて、デジタル画像の特徴の抽出をエッジ検出によって行った。その特徴を光ニューラルシステムに入力するためにアナログ量に変換する。その方法として、ここではエッジ画像の画素値の和、言い替えれば、値1を持つ画素の数を計算する。あわせて、入力画像の画素値の和を計算して、エッジ画像の画素値の和を割ることにより光ニューラルシステムに与える特徴量とする。以上の操作を左エッジ画像について示す。左エッジ画像の (i,j) 画素を $le(i,j)$ とすると、その特徴量 F_1 は、

$$F_1 = \sum_j le(i,j) / \sum_j \sum_i f(i,j) \quad (5.2.6a)$$

となる。これは、右エッジの特徴量と同じになる。また、上エッジの特徴量 F_2 は、下エッジの特徴量

と同値になり、上エッジ画像の(i,j)画素を $ue(i,j)$ とすると、

$$F_2 = \sum_j \sum_i ue(i,j) / \sum_j \sum_i f(i,j) \quad (5.2.6b)$$

となる。同様な操作をの角画像に対しても行う。この場合、左上と右下、左下と右上の角画像の特徴量はそれぞれ、近い量となる。左上の角画像と右上の角画像の(i,j)画素を $rue(i,j)$ と $lue(i,j)$ とすると、左上の特徴量 F_3 と右上の特徴量 F_4 は、

$$F_3 = \sum_j \sum_i rue(i,j) / \sum_j \sum_i f(i,j) \quad (5.2.6c)$$

$$F_4 = \sum_j \sum_i lue(i,j) / \sum_j \sum_i f(i,j) \quad (5.2.6d)$$

となる。これらの特徴量は位置の情報は失っている。しかし、入力デジタル画像の移動、ゆがみ、欠損、大きさの変化に対しては、同程度の量となる。これらの特徴量を光ニューラルシステムの入力とする。

光ニューラルシステムは、BP学習則を用いて学習される。入力を4つの特徴量、出力を認識したい入力画像を1を出力するニューロンでコード化する。よって、入力ニューロンと出力ニューロンの数は、それぞれ、特徴量の数4と認識したい入力画像の数である。学習終了後、認識が行われる場合、最も大きな出力のニューロンのみ1とし、他のニューロンは0とする最大値の検出を行い認識結果とする。

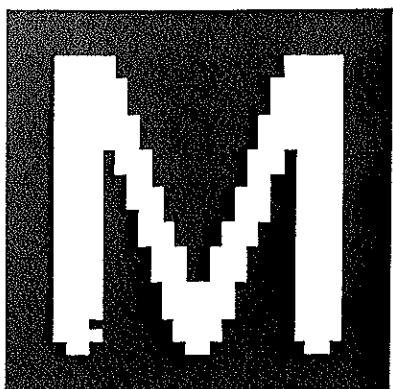
5.3 システムの動作

5.3.1 計算機シミュレーション

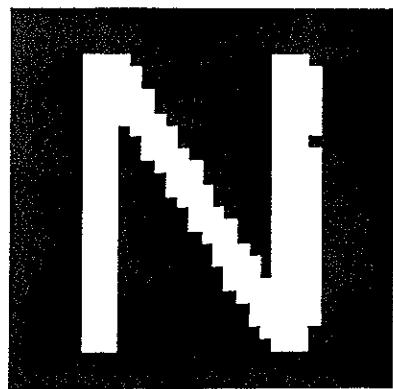
認識させたいデジタル画像はFig.5.3.1に示した5つのアルファベットM、N、T、Y、Zである。これらは 32×32 の画素を持ち、TVカメラで撮られたものを単純にしきい値処理した結果であり、一部に凸凹な部分がある。これらをそれぞれ、M、N、T、Y、Zと呼ぶ。これらを光デジタルシステム

Table5.3.1 値1を持つ画素数（画素値の総和）

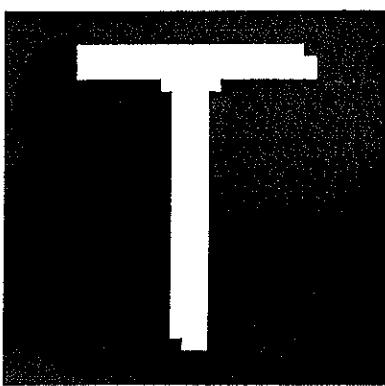
	全体	右エッジ	上エッジ	右上角	左上角
入力 画像	M	320	25	71	7
	N	243	21	63	1
	T	129	20	26	0
	Y	137	21	38	6
	Z	203	46	26	11



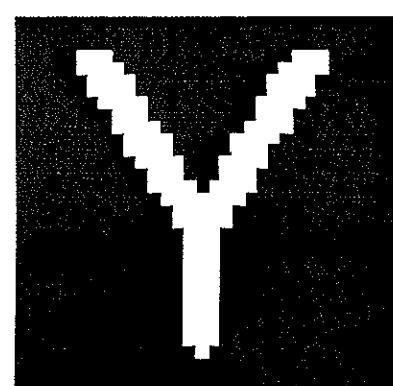
M



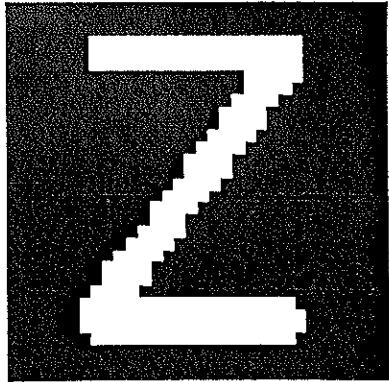
N



T



Y



Z

Fig.5.3.1 記憶した5つのデジタル画像
32×32の画素を持つ5つのアルファベットM、N、T、Y、Z

でエッジ検出を行い、それぞれの画素値の和(Table5.3.1)から特徴量を計算する。これらの特徴量の正規化値を入力とするニューラルネットワークは、入力層4、中間層4、出力層5のニューロンを持つ。以下に学習させる入出力関係である5つのアルファベットに対する特徴量を正規化した4ニューロンの入力値と5つの出力ニューロンの教師信号を示す。

$$\begin{aligned}
 M: (0.000, 0.775, 0.317, 0.341) &\rightarrow (1\ 0\ 0\ 0) \\
 N: (0.056, 0.879, 0.060, 0.985) &\rightarrow (0\ 1\ 0\ 0) \\
 T: (0.518, 0.492, 0.000, 0.000) &\rightarrow (0\ 0\ 1\ 0) \\
 Y: (0.506, 1.000, 0.847, 1.000) &\rightarrow (0\ 0\ 0\ 1) \\
 Z: (1.000, 0.000, 1.000, 0.041) &\rightarrow (0\ 0\ 0\ 0\ 1)
 \end{aligned} \tag{5.2.7}$$

これらを以下のパラメータにより学習を行った場合の2乗誤差の変化をFig.5.3.2に示す。

荷重の学習係数 $\eta = 1.0$

慣性係数 $\gamma = 0.9$

シグモイドの非線型係数 $\varepsilon = 2.0$

収束条件 $RMS/2 < 0.01$

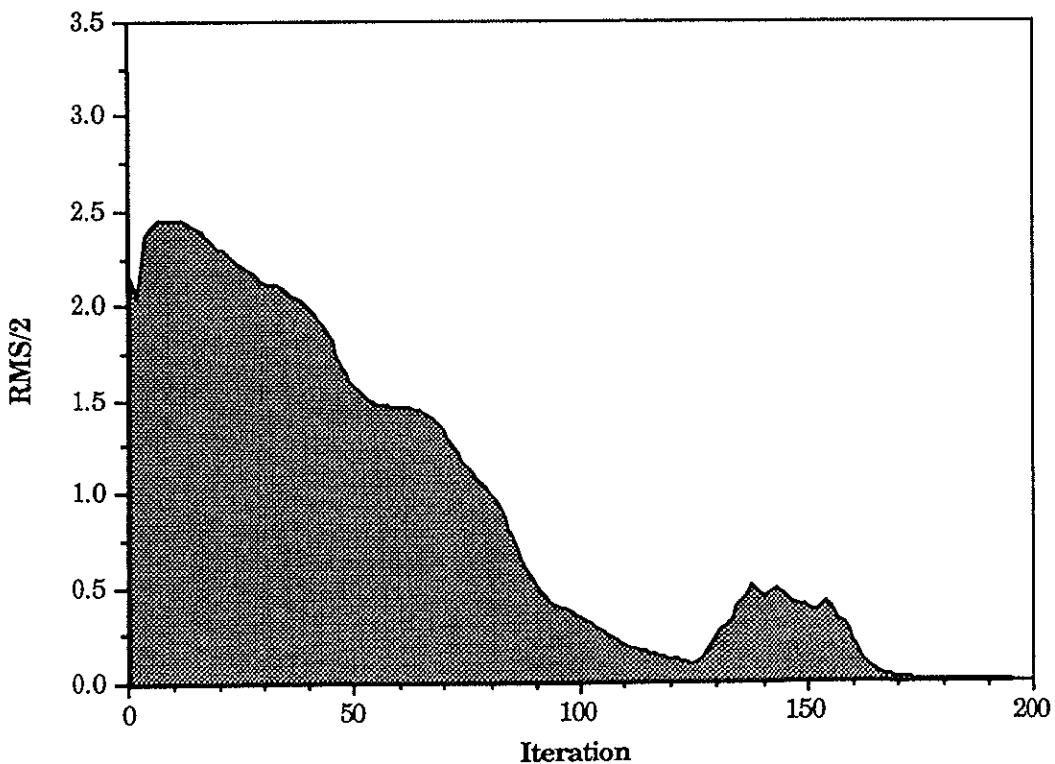


Fig.5.3.2 学習時の2乗誤差の変化

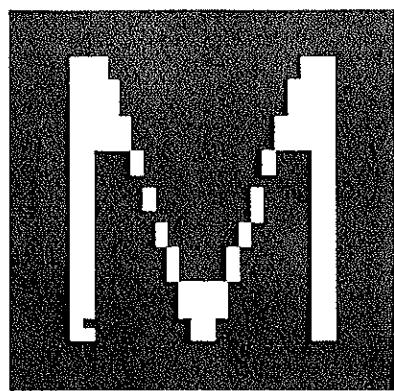
Fig.5.3.3は認識させるデジタル画像であり、それぞれM'、N'、T'、Y'、Z'と呼ぶ。M'はぼけたMのしきい値処理の結果線が細くなった画像、N'はNの一部の領域を0にした画像、T'はTを右に1シフトした画像、Y'はYを2ライン0にした画像、Z'はZを歪めた画像である。これらの画像を、記憶時同様に、光デジタルシステムに入力して、式(5.2.4)と式(5.2.5)に基づいてエッジ検出を行い、式(5.2.6)に基づいて特徴量を計算する。そして、学習済みのニューラルネットワークに入力する。その時の、それぞれの出力ニューロンの出力値である認識結果をTable5.3.2に示す。これは、それぞれのニューロンの出力で最大値を見ると正しく認識されていることがわかる。Table5.3.2をTable5.3.3の元の画像を入力したときの出力値と比較すると、M'以外は、同程度の出力をしている。M'の場合も最大出力ニューロンはコーディングした出力ニューロンである。

Table5.3.2 認識結果—M'、N'、T'、Y'、Z'の画像を入力したときのニューロンの出力

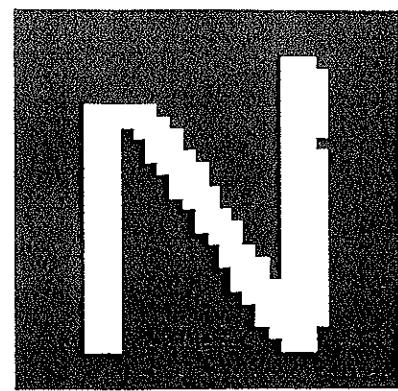
		出力ニューロン				
		1	2	3	4	5
入力 画像	M'	0.626	0.008	0.008	0.016	0.000
	N'	0.015	0.986	0.005	0.042	0.000
	T'	0.043	0.000	0.934	0.029	0.044
	Y'	0.001	0.010	0.013	0.927	0.000
	Z'	0.000	0.000	0.047	0.000	0.966

Table5.3.3 認識結果—M、N、T、Y、Zの画像を入力したときのニューロンの出力

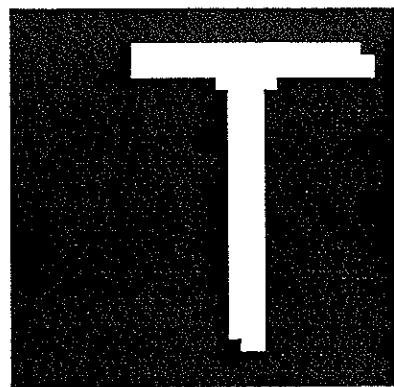
		出力ニューロン				
		1	2	3	4	5
入力 画像	M	0.963	0.046	0.004	0.000	0.000
	N	0.028	0.985	0.004	0.021	0.000
	T	0.043	0.000	0.934	0.029	0.044
	Y	0.002	0.015	0.023	0.957	0.000
	Z	0.000	0.000	0.044	0.000	0.965



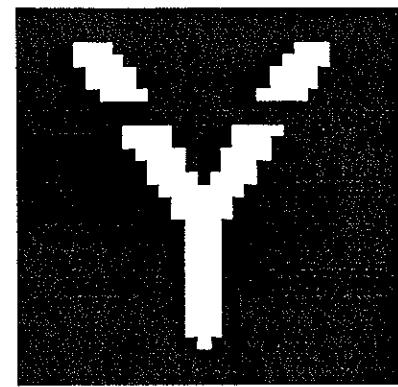
M'



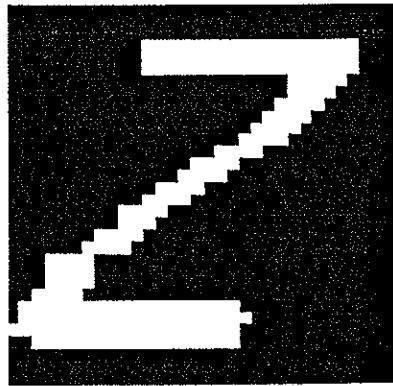
N'



T'



Y'



Z'

Fig.5.3.3 認識させたい5つのサンプル画像

M': Mの線を細めた画像

N': Nの一部の領域を0にした画像

T': Tを右に1シフトした画像

Y': Yを2ライン0にした画像

Z': Zを歪めた画像

5.3.2 光学実験

Fig.5.3.4は、光ニューラルシステムと光デジタルシステムを統合した画像認識を行う光電気ハイブリッドシステムである。このシステムは、光ニューラルシステムと光デジタルシステムがパーソナルコンピューターを介して結合している。光ニューラルシステムは、3層光ニューラルシステムと同じシステムである。光デジタルシステムは、3.4で述べた時間符号化に基づく空間可変論理演算システムであり、MSLM、LCTV、CRT、CCDカメラとその他光学部品から構成されている。CRTとLCTVは、それぞれ、時間符号化画像と演算セレクタを表示し、それらの重ね合わせ画像をMSLMの入力面に結像する。MSLMは、復号に対応する時間的加算を行うために使われる。OCDはHe-Neレーザー光により読み出されたMSLMの演算画像を受ける。繰り返しの演算は、コンピュータを介して、この光学系内で繰り返し実行される。

このシステムは、論理演算が空間的に一様な空間不变演算を実行する場合、異なる動作をする。まず、CRTとLCTVに入力画像Aと入力画像Bを表示して、MSLMの入力面に時間符号化画像を結像する。MSLMは、4つのステップで書き込みを選択することによって、演算と復号を同時に行う。この場合は、空間可変な論理演算はできないが、画像認識のためのエッジ検出は空間不变な演算であり、この動作を行うことによって、演算時間は短縮する。

Fig.5.3.5は、光デジタルシステムにおいて、エッジ検出を行った結果である。Fig.5.3.5(a)は、入力画像Mと下シフト画像のSD(M)に対してXORを実行した時の出力MXORS(M)であり、Fig.5.3.5(b)は、MXORS(M)と入力画像Mに対しANDを実行した上エッジ画像UE(M)である。

これらの出力結果は、MSLMが空間的不均一があり、理想的なしきい値素子として働いていない。そのため、XORとANDによるエッジ検出において、1回目の論理演算XORの結果にノイズがのってしまい、それが2回目の論理演算ANDに影響している。

5.4 まとめ

光コンピューティングシステムの1つの実現形態として、与えられた入力情報を光デジタルシステムで処理し、その結果を光ニューラルシステムの入力として与え、入力情報の認識を行うシステムを提案し、計算機シミュレーションによる動作とエッジ検出の光学実験の結果を示した。これは、光デジタルシステムで 32×32 画素の入力画像のエッジ検出を行った結果から、4つのアナログの特徴量を抽出している。自然画像等は膨大な情報量を持つが、その中で必要な情報はごく一部であり、高速な処理を実現するためには、その必要な情報を効率良く、最適に抽出必要がある。これらは、生物のように全てニューラル的な処理で実行可能であるが、その有用な特徴の大部分は、あらかじめその性質とそれに対する有効な処理法も良く解っている場合が多く、その処理は光デジタルシステムで行う方

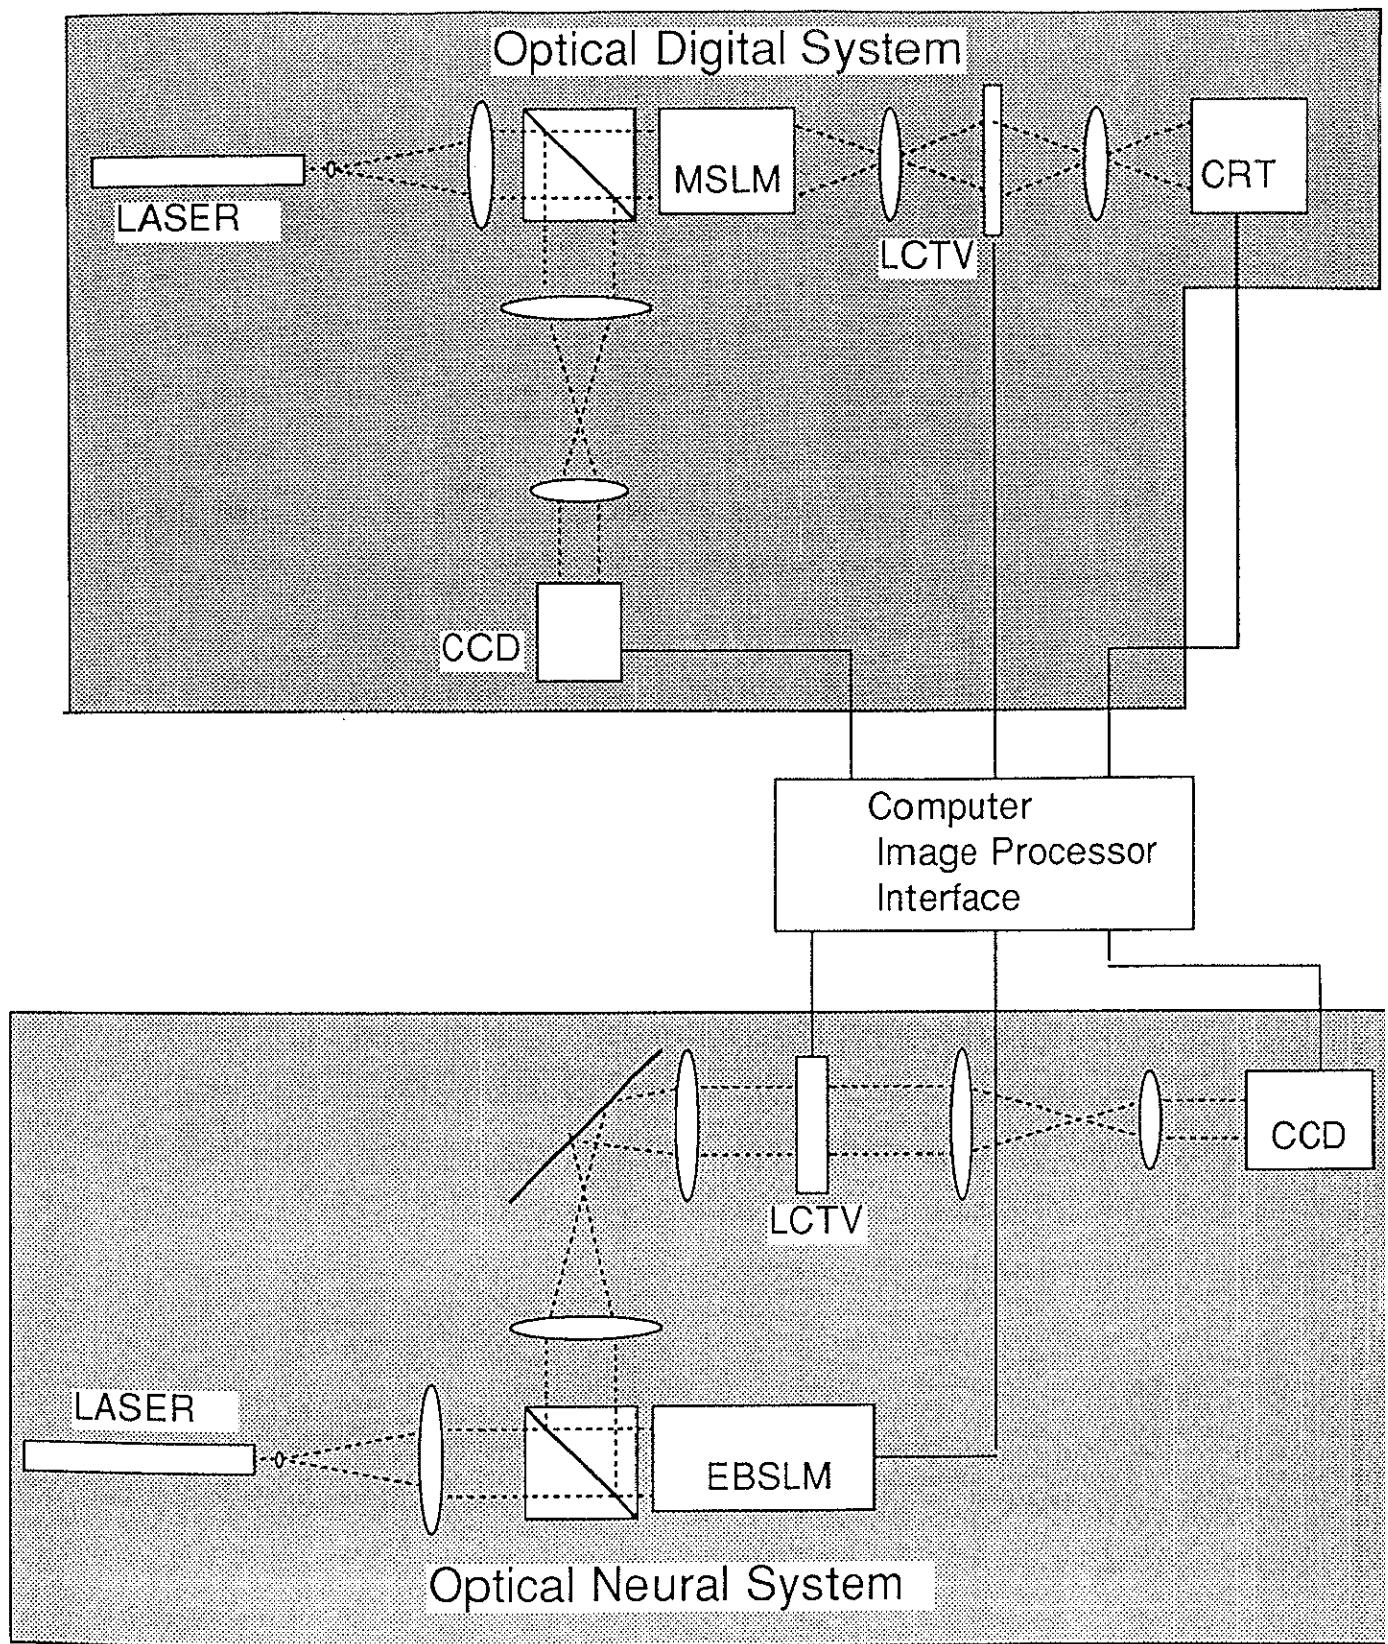
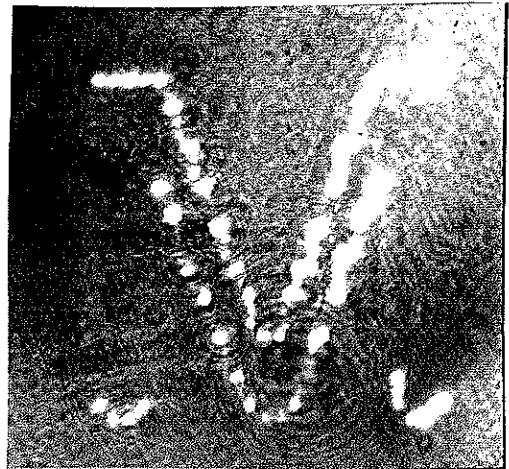
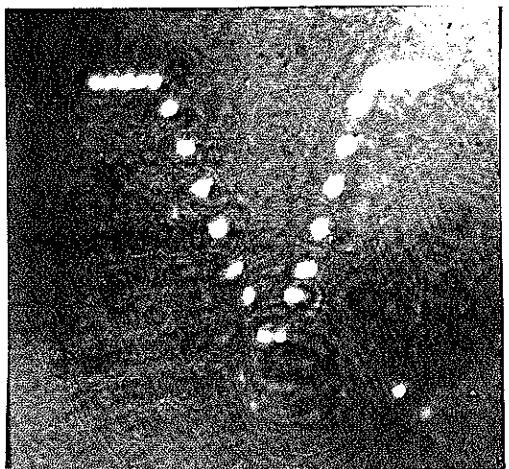


Fig.5.3.4 光コンピューティングシステム



(a)



(b)

Fig.5.3.5 Mのエッジ検出の光学実験結果

- (a) 入力画像Mと下シフト画像SD(M)のXORの結果
- (b) 画像MXORS(M)と入力画像MのANDの結果

が効率的な処理が可能である。そして、得られた特徴量は複雑な連関を持つアナログ量の情報であるためニューラルネットワークの学習によって、その位相構造をシステム内に取り込むことにより、知識として獲得する。

ここで示した実験システムは、エッジ検出という単純な処理より得られた4つの特徴量により画像の認識するシステムであるが、入力情報の移動、欠損、歪み、ほけに対しても正しい認識結果を得ることができた。しかし、位置の情報や入力画像の局所的な構造は失われており、それらの情報を別の特徴量として取り込むことによって、より能力の高い認識が可能であると考えられる。

参考文献

- [1] 田村, "コンピューター画像処理入門," 数研出版 (1985).
- [2] 長尾, "画像と言語の認識工学," コロナ社 (1989)

第6章 結 論

本研究は、光学的に並列情報処理を行うコンピューティングシステムの開発を目指し、光デジタルシステムと光ニューラルシステムを要素システムとして統合した光コンピューティングシステムを提案し、具体的な実験システムを構成することにより、提案したアーキテクチャやモデル、構成技術の原理確認をするという実証的な研究にもとづいて行われている。本研究で得られた知見及び成果を以下にまとめ、大規模システム開発へ向けての指針を示す。

光コンピューティングシステムは、光デジタルシステムと光ニューラルシステムを統合したシステムであり、それぞれの特徴を生かして被処理データに対して独立あるいは協調して種々の処理を行う。光デジタルシステムはデジタルで情報を表現し、明確なアルゴリズムに基づいて処理を行う。光ニューラルシステムはアナログで情報を表現し、曖昧なデータに対し学習や自己組織化に基づく適応的な処理を行う。ここでは、それらの要素システムの基本的構成と特徴を述べ、それらを統合するために、4つの処理の流れについて検討し、それぞれの処理を適用する対象を明かにした。

光デジタルシステムでは、その構築に必要な並列光演算の一つである空間可変論理演算法の原理を説明し、その光学的実現法について述べた。空間可変論理演算法を実現において、谷田貝により提案された空間符号化の方法に加えて時間符号化の方法を提案し、それらの原理確認のための基本的な実験システムを構成した。空間符号化ではMSLMの演算機能によるシステム、時間符号化ではLED-アレイとLCTVによるシステムであり、それぞれ演算実験の結果を示した。実験システムは 4×4 と小さなシステムであるが、基本的に同じデバイス構成により大規模なシステムが実現できることを明かにし、大規模システムの構築へ指針を示した。それは両方法の特徴の比較から、大規模なシステムを構築する際に、空間符号化では演算機能、時間符号化では画像反転が得られるデバイスが必要であることであり、現状のデバイスでシステムを構成すると、 10^9 operations/sec程度の性能が得られることを明かにした。

光ニューラルシステムでは、その構築に必要なニューラルネットワークの光学的実現の為の実行モデル、演算構造、構成法とその原理確認のための実証的に構成した4つのシステムについて述べた。そこでは、筆者らが提案している光ニューラルモジュールによって実装技術の重要性を言及し、特に、配線素子としての多重結像光学系の有用性について述べた。また、MSLMによってニューロンの非線型出力関数を実現する実験について示した。これはニューロン数が4ニューロンと少ないながら、実現した非線型関数はシグモイド関数と相似であり、ニューラルネットワークの動作も計算機シミュレーションと同様であることから光ニューラルモジュールの非線型素子として用いることができ、光ニューラルシステムの全光学的構成の一部と成り得ることを検証した。

荷重の正負を実現する位置表現法において、その新しい更新法である单方向更新法と双方向更新法を提案し、計算機シミュレーションを通してその特性を検討し有用性を明かにした。さらに、筆者の考案したニューラルネットワークの光学的実現に適した演算構造である反転入力重ね合わせ法について述べた。この方法は、ニューラルネットワークの全ての計算が正の乗算と加算で表現できるモデルである。既存のニューラルの表現法がなんらかのかたちで元のニューラルネットワークの2倍の素子が必要であったのに対し、元のニューラルネットワークと同じ素子数で実現できることもこの方法の利点である。

これらの光学的実現の手法、モデル、アーキテクチャを基にして、4つの具体的な光ニューラルシステムを構成し、その動作実験について報告した。その1つは、3層光ニューラルシステムであり、位置表現法とマトリクス分割法によって結合荷重を表現し、BP学習を伴う3層構造の光ニューラルネットワークを実現したはじめてのシステムである。このシステムにおいて单方向更新法と双方向更新法の実験的検証を行い、その結果から多くの場合で双方向更新法の方が学習の収束性が良いことを示した。さらにシステムで用いられるデバイスについて計算機シミュレーションでその必要な性能について考察した。結合荷重に用いられる荷重素子は70%程度のばらつきをも学習によって吸収されること、入力表示素子はコントラストが20以上必要であることを示した。

多重結像光ニューラルシステムでは、入力を2次元情報のまま取り扱うことのできる2次元構造を実現するため多重結像光学系を実際に適用した学習可能な光ニューラルシステムである。多重結像光学系は、筆者らが開発したセルフォックマイクロレンズアレイ(SMLA)によって実現され、その光学系は大規模かつコンパクトな光学系が可能である。学習機能を得るために、光書き込み可能な空間光変調素子であるPROMを結合荷重の記憶に適用した。ここでは、システムの学習実験の結果について報告し、学習の収束を確認した。さらに、SMLAを構成するセルフォックマイクロレンズのPSFの測定から可能な最大ニューロン数は 247×247 であり、SMLAが十分な特性を持つことを示した。

反転入力重ね合わせ法(RIST)に基づく光ニューラルシステムは、RISTの有用性を示すため、LCTVによって偏光パターンを表示できることを用いて実現されている。システムにおいて、25ニューロンのホップフィールドモデルが実現されている。想起実験において、想起率の低下は、計算機シミュレーションと比較した場合5%程度であった。この方法は、先に示したMSLMによる非線型出力関数の実現との組み合せにより、純光学的構成が可能である。

意味ネットワークを実現する光ニューラルシステムは、光技術とニューラル技術そして知識処理の技術を融合した新しいタイプの情報処理システムを提案し実現したものである。知識処理における重要な知識表現法の1つである意味ネットワークは、ニューラルネットワークの技術を用いた分散的表現を用いて実現できることについて示しされていたが、筆者らは、それに基づいて光ニューラルネッ

トワークの実験システムを構成し、意味ネットワークによる知識の学習と想起の実験を行った。

これらのシステムは個々の技術やモデルの個々の実験的検証であるが、より大規模、より高性能な光ニューラルシステムを実現するためには、その融合適用がなされると考えられる。筆者は、反転入力重ね合わせ法の光ニューラルシステムを多重結像光学系による2次元構造を導入したシステムが最も有望であると考える。その構成において現在の個別部品を配列する光学定盤上の技術では、ニューロン数は100程度が限界であるため、効率的な実装技術が不可欠である。

光コンピューティングシステムの1つの実現形態として、与えられた入力情報を光デジタルシステムで処理し、その結果を光ニューラルシステムの入力として与え、入力情報の認識を行うシステムを提案し、計算機シミュレーションと光学実験の結果を示した。これは、光デジタルシステムで 32×32 -画素の入力画像の特徴を抽出することにより、4つのアナログの特徴量に変換している。あらかじめ入力画像の性質とその処理法が解っている場合、デジタルシステムは効率的な処理が可能である。そして、得られた特徴量は複雑な連関を持つアナログ量の情報であるためニューラルネットワークの学習によって、その位相構造をシステム内に取り込むことにより獲得される。

ここで示した実験システムは、エッジ検出という単純な処理より得られた4つの特徴量により画像の認識するシステムであるが、入力情報の移動、欠損、歪み、ほけに対しても正しい認識結果を得ることができた。しかし、入力画像の位置や局所的構造の情報は失われており、それらの情報を別の特徴量として取り込むことによって、より能力の高い認識が可能であると考えられる。これは、統合システムにおける、処理内容、情報の交換、構成デバイス等に対して基本的な指針が与えた。

以上、光並列処理に対するモデル、アーキテクチャ、構成法を提案し、実証的な実験システムでの原理確認の実験を通して、モデルに対する有効な素子の提案、大規模システムへの適用可能性を示した。現在は、多くの光並列処理のためのモデルやアーキテクチャ、アルゴリズムがある中、今後、有用で大規模な並列処理システムを構成するために、基本演算素子の高性能、高集積化もさることながら、システムの安定性、信頼性を得るために効率的な実装技術が必要である。

謝辞

本論文は、筑波大学物理工学系谷田貝豊彦助教授の基本的な指針と電子技術総合研究所光技術部矢嶋弘義部長、同光情報研究室石原聰主任研究官、森雅彦研究員の御指導のもとまとめたものである。終わりに臨み、谷田貝豊彦助教授、矢嶋弘義部長、石原聰主任研究官、森雅彦研究員に深く感謝の意を表すと共に厚くお礼を申し上げます。

論文をまとめるにあたり、筑波大学物理工学系 永井啓之亮教授、筑波大学物理工学系 青木貞男助教授、筑波大学電子情報系 平井有三教授に御指導頂きました。永井啓之亮教授、青木貞男助教授、平井有三教授の御指導を深く感謝します。

筑波大学物理工学系 伊藤雅英講師、光情報研究室伊藤日出男主任研究官、同研究室渡部正信主任研究官、日頃の有益なる御討論、御助言を頂きました。

本研究は、主に電子技術総合研究所光技術部光情報処理研究室において行ったものであり、石原聰主任研究官、森雅彦研究員の御指導のもと行ったものであり、私の日頃のいい加減さとわがままにもかかわらず、有意義な研究が可能となる環境をつくって頂き、深く感謝いたします。

浜松フォトニクス株式会社 原勉氏、同社 豊田晴義氏には、空間光変調管に関する技術的な御援助を頂きました。日本板硝子株式会社 浜中賢二郎氏には、セルフックレンズに関する技術的な御援助を頂きました。日本ガイシ株式会社 大杉幸久氏には、PROMに関する技術的な御援助を頂きました。

本研究に際し、有益なる御助言を頂いた光情報研究室の皆様方並びに谷田貝研究室の皆様方に感謝します。

本研究の実験に際し、私が大学4年生当時、実験装置の使い方を教えて頂いた谷田貝研究室 池田誠氏（現日本板硝子株式会社）、計算機について教えていただき、御一緒するはずであったフランスツーロンにて悲報聞くことになってしまった故須崎圭樹氏、一緒にC言語を学び光情報研究室においてともに光ニューラルネットワークの研究を行った谷田貝研究室 笠間宣行氏（現セイコー電子工業株式会社）、光情報研究室で熱い議論を交わした東京理科大学 島田茂氏（現IBM）、共に光情報研究室において研究を行い、電総研ロビーにて有意義な時間を過ごし、先輩であるという立場を利用して多くの協力をしてくれた谷田貝研究室 遠山一郎氏、皆様に感謝します。

最後に、9年間も大学に通わしてくれた両親にこの場を借りて深く感謝します。

論文リスト

公表論文

Y. Hayasaki, M. Ikeda, T. Yatagai, S. Ishihara and Y. Mitsuhasi, "Space-Variant Logic Operation Using Micro-Channel Spatial Light Modulator", SPIE 963, Optical Computing 88, 607 (1988).

Y. Hayasaki, N. Kasama, T. Yatagai, M. Mori, and S. Ishihara, "Optical Implementation of Semantic Networks Based on Association", Jpn. J. Appl. Phys. 29, L1321 (1992).

N. Kasama, Y. Hayasaki, T. Yatagai, M. Mori, and S. Ishihara, "Experimental Demonstration of Optical Three-Layer Neural Network", Jpn. J. Appl. Phys. 29, L1563 (1992).

Y. Hayasaki, I. Tohyama, T. Yatagai, M. Mori, and S. Ishihara, "Optical Learning Neural Network Using Selfoc Microlens Array", Jpn. J. Appl. Phys. 31, 1689 (1992).

I. Tohyama, Y. Hayasaki, T. Yatagai, M. Mori, and S. Ishihara, "Renewal Method of Weight Matrix in Optical Neural Network," to be published in SPIE 1806, (1992).

M. Mori, S. Ishihara, I. Tohyama, Y. Hayasaki, and T. Yatagai, "Optical neural networks based on an electron-beam addressed spatial light modulator," SPIE 1812 Optical Computing and Neural networks, 57-63 (1992).

解説

早崎芳夫、谷田貝豊彦、解説論文「光ニューラルコンピューティングの展開」，光学 20, 664-673 (1991).

付録A 空間光変調管(MSLM)

A.1. 構造と動作原理

空間光変調管(MSLM:Microchnnel Spatial Light Modulator)は浜松フォトニクス社製の空間光変調素子であり、多くの光情報処理システムに適用されている。

MSLMは、通常のイメージインテンシファイアーの蛍光面(フォトカソード)の代わりに電気光学結晶(LiNbO_3)と結晶表面電荷を制御するためのメッシュ状の2次電子捕獲電極(メッシュ電極)を取りつけたものであり、Fig.A.1とFig.A.2にMSLMの断面図と動作原理の概念図を示す。

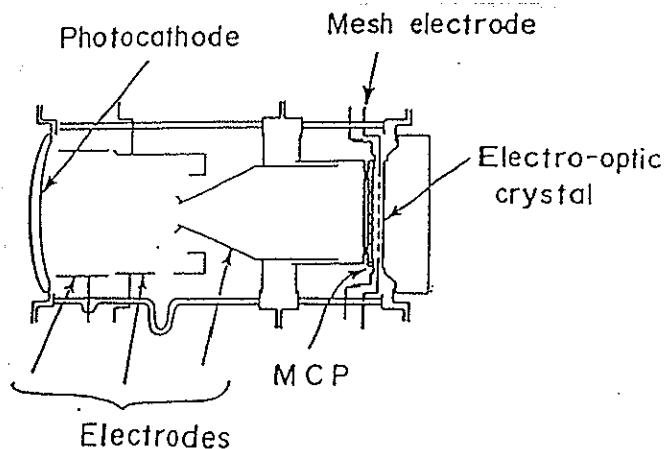


Fig.A.1 MSLMの断面図

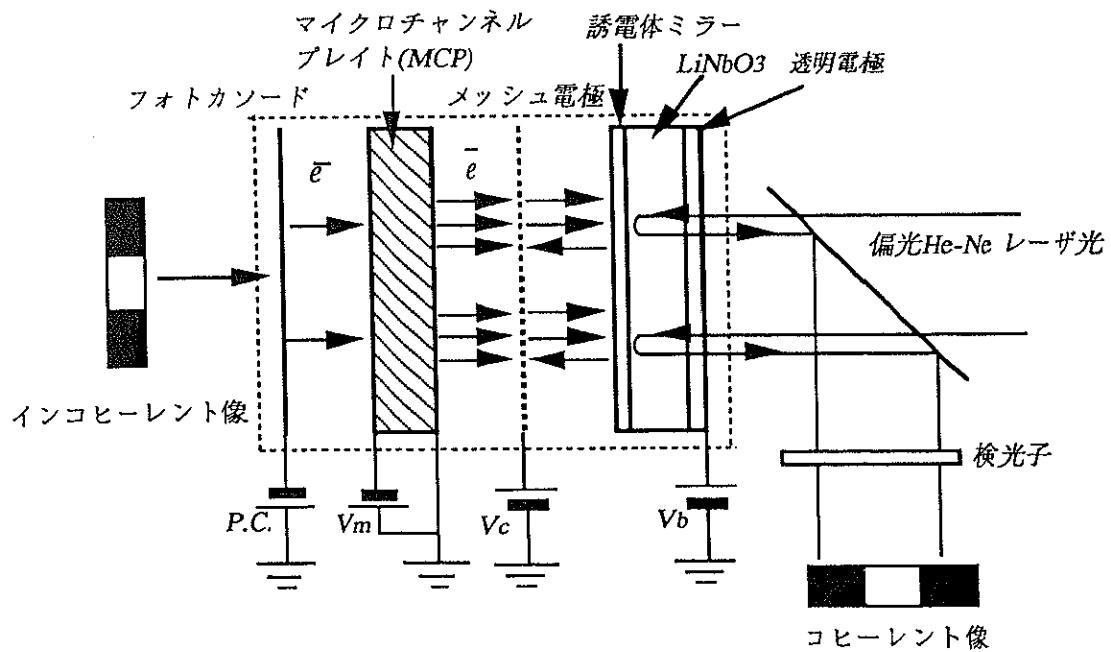


Fig.A.2 MSLMの動作原理

光電面にインコヒーレント光学像が入力されると、光電面は光電子を放出し、電子像に変換する。電子像は、加速、収束電子レンズによって、マイクロチャンネルプレート(MCP)上に結像される。MCPは直径25mm、厚さ0.48mmの薄いガラス板で、画素に相当する $12\mu\text{m}$ の細い穴（チャンネル）が無数にあいている(Fig.A.3)。結像された電子像はMCPで数千倍に增幅されて電気光学結晶に当たり、ここに電荷像を形成します。その結果、結晶を横切る電界は電荷像に応じて電気光学効果により複屈折性が変化し、結晶中を往復する光の偏光状態を変化させる。

この結晶に読み出し用の直線偏光のレーザー光を照射し、結晶内を往復した光を検光子に通すと空間的に強度変調された出力光が得られる。変調状態は結晶面の電荷によって決定され、結晶面の電荷は結晶背面電位 V_b とメッシュ電極電位 V_c を適当に設定することにより制御できる。

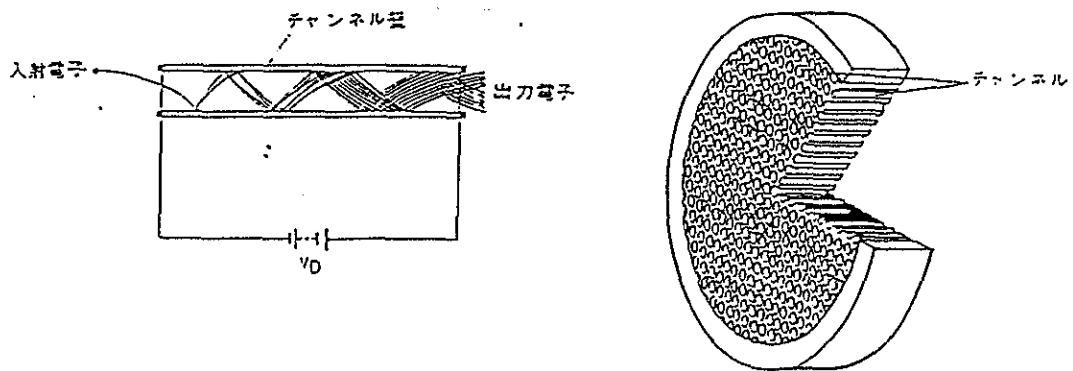


Fig.A.3 マイクロチャンネルプレート(MCP)

A.2. 仕様と機能

MSLMの仕様を以下に示す。

空間解像度	7 - 10 lp/mm
光電面有効半径	16 mm
応答時間	100 - 200 ms
コントラスト比	1000 : 1
半波長電圧	1.7 - 2.0 kV
蓄積時間	days

これらの仕様によって解ることは、空間解像度と有効半径よりMSLMに正方マトリクスを書き込んだ場合、要素の数は 70×70 から 100×100 が限界であり、応答時間より学習の1サイクルはミリセカン

ドのオーダーであることが解る。

MSLMはメッシュ電極電位と結晶背面電位を適当に制御することにより、種々の機能が実現でき、主な機能として次のようなものがある。

1) 変換機能

incoherent-coherent変換

波長変換

2) 記憶機能

画像メモリ

3) 演算機能

加減算・論理演算・コントラスト反転・輪郭強調・しきい値処理

多く機能の中で本システムにおいて用いられる機能は、荷重変更信号はインコヒーレント光であるためのincoherent-coherent変換、荷重マトリクスを記憶するための画像メモリ、荷重変更時の加減算機能である。

A.3 電圧設定と基本動作

MSLMの基本的な電圧設定は、以下の通りである。

フォトカソード電圧 P.C.=-2.97 (kV)

加速電極電圧 G1=-2.63

収束電極電圧 G1=-1.17

MCP電圧 Vm=-0.85

メッシュ電極電位 Vc=1.81

結晶背面電圧 1.20≤Vb≤2.90

結晶背面電圧 V_b が 2.90 kV の時は入力光があるとき画面が明となる電圧で、便宜上、書き込み電圧 V_{bw} と呼び、 V_b が 1.20 kV の時は入力光があるとき暗となる電圧で消去電圧 V_{be} と呼ぶ。結晶表面電位は V_s は入力光がない場合、結晶背面電位 V_b の変化と共に変化し、入力光がある場合は、メッシュ電極電位 V_c へ近づく方向に変化する。これが MSLM の動作における結晶表面電圧変化の基本である。

ここでは、MSLM の基本動作である正像及び反転像の書き込みについて示し、その動作のタイムチャートを Fig.A.4 と Fig.A.5 に示す。

a. 正像書き込み

正像書き込みは、画面全体を暗にする必要があり、画面全体に消去動作を行う。まず結晶背面電圧

V_b を消去電圧 $V_{be}=2.90\text{kV}$ にセットし、一様光を照射するとFig.A.4中の点線で示される結晶表面電位 V_s はメッシュ電極電位 V_c に等しくなり、全体は消去される。次に、 V_b を書き電圧 $V_{bw}=1.20\text{kV}$ に設定するとそれに連れて V_s も変化する。ここで入力画像を照射すると、入力光がある場所のみ V_s と V_c と等しくなり、正像が書き込まれる。これは、入力画像の照射時間や光強度を調整することにより加算動作も実行できる。

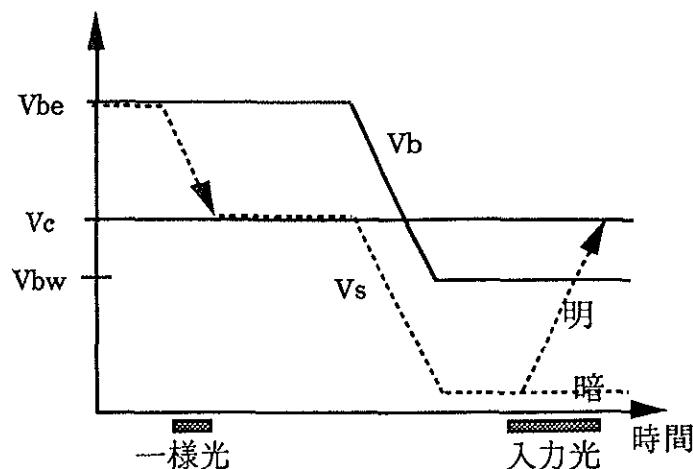


Fig.A.4 正像書き込みのタイムチャート

b. 反転像書き込み

反転像書き込み(Fig.A.5)は、はじめに画面全体を明にすることにより実行される。まず、 V_b を書き電圧 $V_{bw}=1.20\text{kV}$ に設定し、一様光を照射して画面全体を明にし、 V_b を消去電圧 $V_{be}=2.90\text{kV}$ に設定し、入力画像を照射すると、反転像が書き込める。

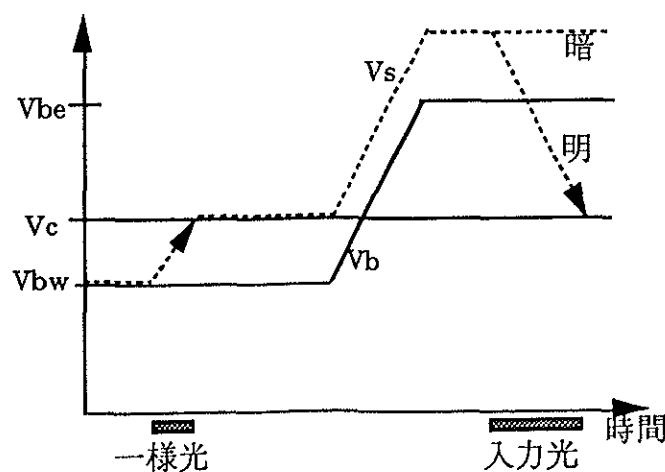


Fig.A.5 反転像書き込みのタイムチャート

A.4 基本特性の測定

a. 2次元的特性

Fig.A.6は、消去電圧 $V_{be}=2.90\text{kV}$ で一様光を照射して、全面を暗にしたときの空間的な特性である。これは、 28×28 のサンプル点について光強度をとったもので、高さ方向にその強度を示している。図中のx軸は結晶のx軸で、y'軸は結晶面内にx軸と垂直な方向である。強度を見ると、y'軸方向に手前と奥の強度が強く、中心付近の強度は弱くなっている。これは、結晶のシェーディングによるもので、電圧設定によっては、この強弱の関係は逆転する。

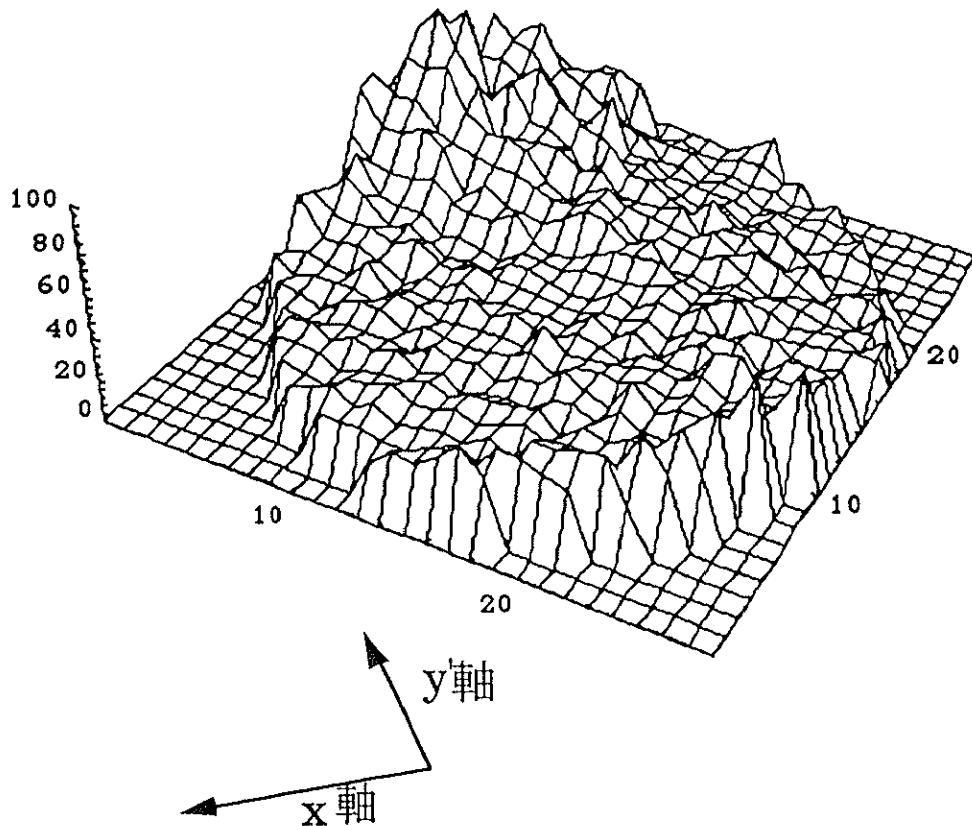


Fig.A.6 消去電圧 $V_{be}=2.90\text{kV}$ で一様光を照射して全面を暗にしたときの空間的な特性

b. 書き込み特性

ここでは、書き込み特性について示す。Fig.A.7は、MSLMの16個の点における書き込み時間と出力光強度の変化を示したものである。測定した16点は、Fig.A.7にしめす。この測定結果は、光ニューラルシステム内で測定されたものであり、書き込み光や読み出し光の空間的なばらつきを含む。最大値は点Bの178で、最小値は点Dの67である。これは、MSLMのシェーディングや経時劣化があ

るが、システム全体のばらつきも含んでいる。

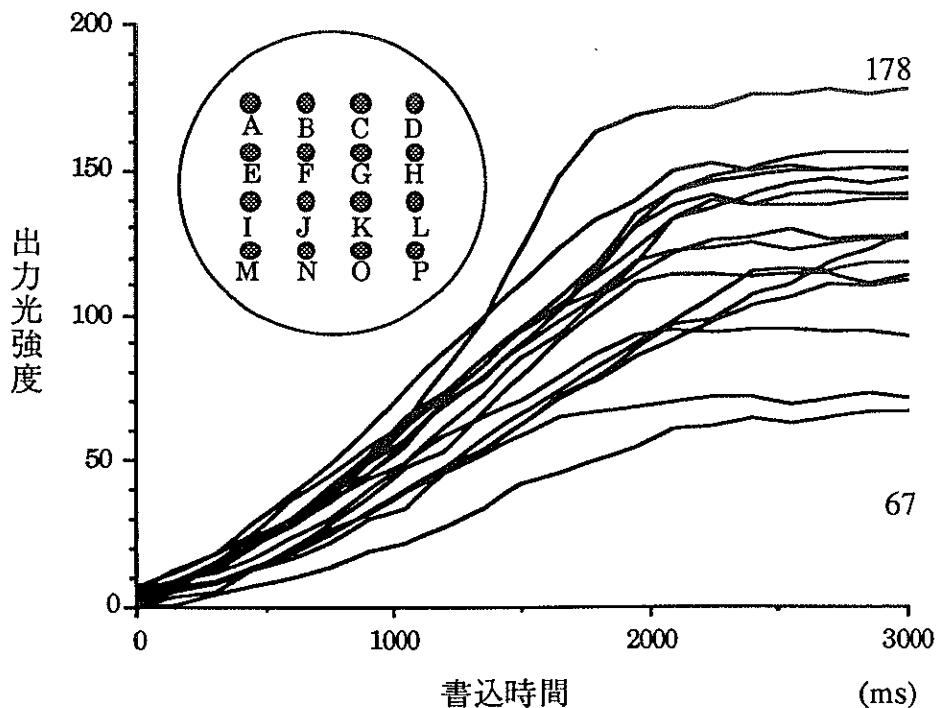


Fig.A.7 16個の点における書き込み時間と出力光強度の変化

c. 用途に応じた電圧設定

MSLMの電圧設定は、A.3で基本的な設定を示したが、用途に応じて変更する必要がある。電圧設定には、破損の可能性があるため以下の電圧の条件を満足しなくてはいけない。

$$|V_b - V_c| \leq 2.0 \text{ kV.} \quad (\text{A.1})$$

$$|V_{bw} - V_{be}| \leq 2.0 \text{ kV.} \quad (\text{A.2})$$

$$V_c \leq 2.0 \text{ kV} \quad (\text{A.3})$$

$$V_b \leq 3.0 \text{ kV} \quad (\text{A.4})$$

Fig.A.8は、メッシュ電圧 V_c を1.81kVと1.50kVの場合、結晶背面電極電圧 V_b を変えて一様光を照射して書き込んだときの出力光をフォトディオード(PD)で受け、そのPD電流を縦軸にプロットしたものである。このグラフより、暗を最小にしたい場合、

$$|V_{be} - V_c| = 1.3 \text{ kV.} \quad (\text{A.5})$$

コントラストを最大にしたい場合、

$$|V_{be} - V_{bw}| = 2.3 \text{ kV.} \quad (\text{A.6})$$

これは式(A.2)より禁止されている設定であり、通常2.3kVの変わりに2.0kVにする。

高いコントラストが必要な場合(Set1)、線型性が必要な場合(Set2)の電圧設定を示す。

$$\begin{aligned} \text{Set1} \quad & V_c = 1.70 \text{ kV} \\ & V_{be} = 3.00 \text{ kV} \\ & V_{bw} = 0.70 \text{ kV} \end{aligned} \quad (\text{A.7})$$

$$\begin{aligned} \text{Set2} \quad V_c &= 1.50 \text{ kV} \\ V_{be} &= 2.60 \text{ kV} \\ V_{bw} &= 0.80 \text{ kV} \end{aligned} \quad (\text{A.8})$$

これらは、電圧設定の一例であり、(A.1)から(A.4)の条件のもと、種々の設定がある。

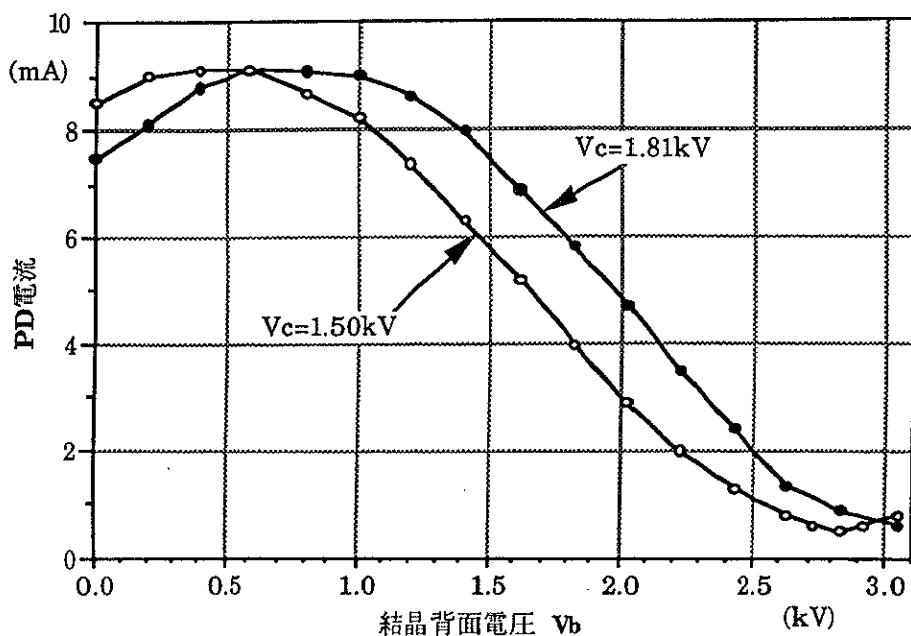


Fig.A.8 結晶背面電極電圧Vbと出力光強度の関係

付録B 電子ビームアドレス型空間光変調管(EBSLM)

B.1 動作原理

電子ビームアドレス型空間光変調管(EBSLM: Electron-Beam-Addressed Spatial Light Modulator)は時系列電気信号を光で並列処理できる2次元情報に変換することができる空間光変調素子である。EBSLMは時系列信号(ビデオ信号)を電子ビームに変調する電子銃と電気光学結晶から構成されている。Fig.B.1にEBSLMの構成を示す。

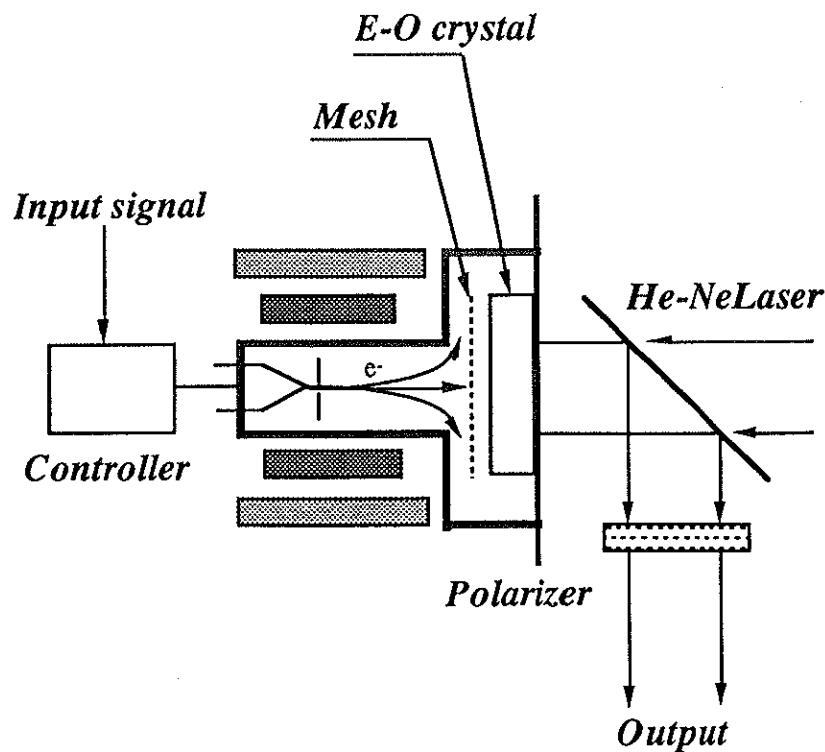


Fig.B.1 EBSLMの動作原理

ビデオ信号が電子銃によって電子ビームに変換され偏光コイルによって2次元的にスキャンされる。スキャンされた電子分布は、グリッド側の結晶表面電荷を変化させる。その結果、電荷に応じた電場が形成され、ポッケルス効果によって結晶の複屈折の状態が変わる。そして結晶中を往復した読み出し光は、偏光状態が変化する。この像を読み出すには、外部から直線偏光のレーザー光を入射させると、結晶内の屈折率に応じた梢円偏波が反射光となって現れる。この反射光を検光子を通すことによって2次元の光情報として取り出すことができる。変調状態は結晶面の電荷であるメッシュ電極電圧 V_c と結晶背面電圧 V_b を調整することで行われる。

B.2 基本特性

以下に特性を示す。

空間解像度 x軸に垂直 10 lp/mm(変調度50%)

 20 lp/mm(変調度 5%)

 x軸に平行 7 lp/mm (変調度50%)

 16 lp/mm(変調度 5%)

応答時間 電子蓄積モード 100ms

 2次電子放出モード 200ms

ガンマ特性	約3.0
半波長電圧	2400Vdc
電荷蓄積時間	24時間
コントラスト	1000:1
有効領域	9.5×12.7 mm ²

B.3 電圧設定

EBSLMの電圧設定を以下に示す。

書き込みフレーム数	1≤S1≤12
消去フレーム数	1≤S2≤12
メッシュ電極電圧	0 < Vc ≤ 2.0 kV
結晶背面電圧 書き込み	0 ≤ Vbw ≤ 3.0 kV
消去	0 ≤ Vbe ≤ 3.0 kV

メッシュ電極電圧 V_c と結晶背面電圧 V_{be} は上記の範囲で種々設定が可能であるが、実験では以下の設定で行う。

メッシュ電極電圧	$V_c=2.0\text{ kV}$
結晶背面電圧 書き込み	$V_{bw}=0.31\text{ kV}$
消去	$V_{be} = 1.6\text{ kV}$

B.4 基本特性

a. 書き込み特性

EBSLMの16個の点における空間的な書き込み特性の測定結果を Fig.B.2 に示す。横軸は、書き込みがビデオ信号のフレームレイトで書き込むため、書き込みフレーム数である。縦軸はCCDの出力値である。入出力特性における各点の強度の違いは、読み出し光の空間分布のばらつきや結晶のシェーディングによるものである。最大点は207、最小点は177である。MSLMと比較するとそのばらつきは少ない。

b. 消去特性

EBSLMの16個の点における空間的な消去特性の測定結果を Fig.B.3 に示す。消去電圧を設定値より大きくすると、勾配が緩くなるが、下限値が高くなる。一方、設定値より小さくすると、下限値は低くなるが、勾配がきつくなる。

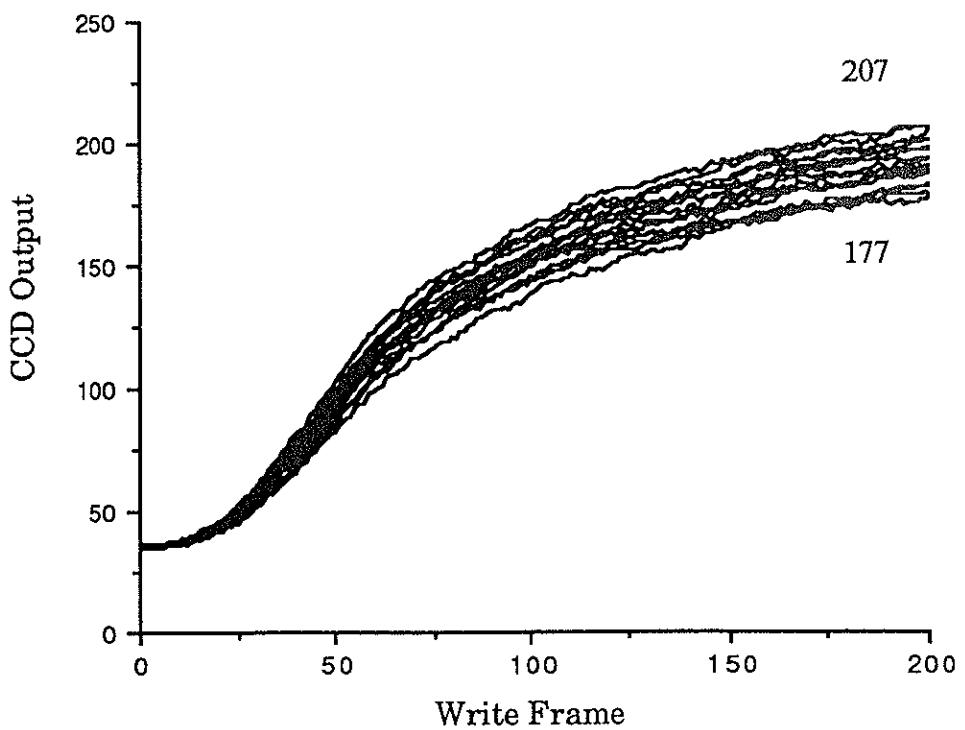


Fig. B. 2 16個の点における書き込み回数と出力光の変化

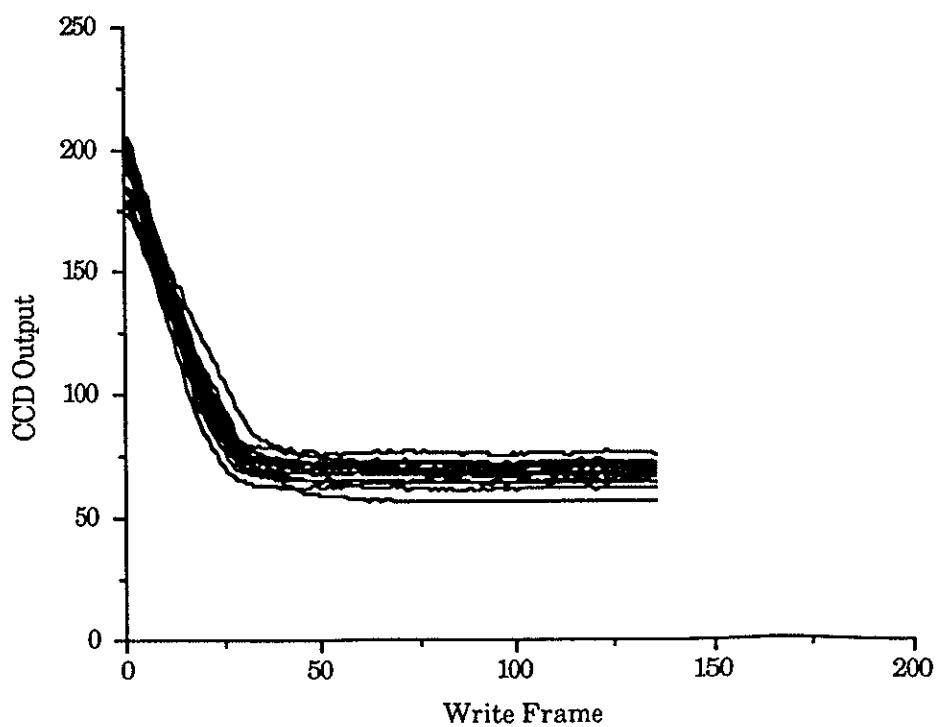


Fig. B.3 16個の点における消去回数と出力光の変化

付録C BSO空間光変調素子

C.1 素子構成

BSO空間光変調素子(PROM: Pockels Readout Optical Modulator)は、 Bi_2SiO_5 (BSO)単結晶を利用した光アドレス型の空間光変調素子の一つである。BSOは点群23に属する酸化物単結晶で、電気光学効果、光伝導効果、磁気光学効果を持つ。BSOのバンド幅は3.3eV程度であるので、青色光に強い光伝導効果を示す。

PROMの構成をFig.C.1に示す。(001)軸に垂直な面で切り出された結晶板を光学研磨し、透明な絶縁層とその外側の透明電極で構成されている。絶縁層には、パリレン薄膜。マイカ、薄板ガラスが用いられてきた。PROMの有効面積 $28 \times 28\text{mm}^2$ 、各層の厚さは、BSOが $300\text{ }\mu\text{m}$ 、絶縁層10程度であり、その主な特性をTable C.1に示す。

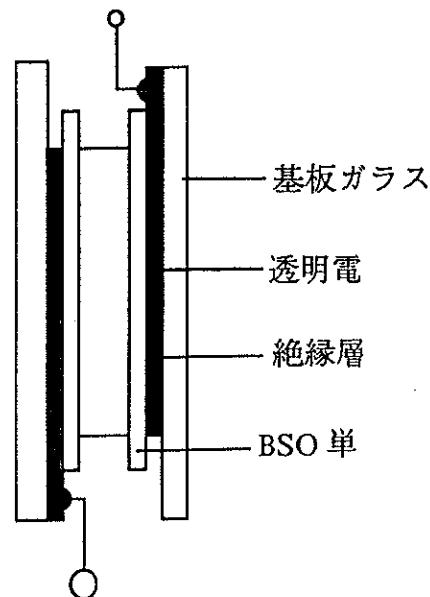


Table C.1 PROMの主な特性

BSO 単結晶	$300\text{ }\mu\text{m}$ テーパ角15'
絶縁層	$10\text{ }\mu\text{m}$ 石英ガラス
基板ガラス	石英ガラス テーパ角25'
有効面積	$28 \times 28\text{mm}^2$
半波長電圧	16kV
素子印加電圧	5kV
解像度	25 lp/mm(MTF 1/e)
コントラスト	1000:1
素子感度	$20\text{ }\mu\text{J/cm}^2$
記憶時間	hours

C.2 動作原理

動作原理は、BSO結晶の光伝導効果と電気光学効果に基づいていて、次の各過程の繰り返しで行

われる。

1) 書き込み

透明電極間に、数kVの直流電圧を印加する。青色光の書き込み像が照射されると、光伝導効果によりBSO内に電荷が形成され、外部印加電解により結晶内を移動し結晶表面に分極される。

2) 保持

分極した電荷は絶縁層に遮られそこに留まり、書き込み光を切った後も電荷分布は保持される。

3) 読み出し

分極電荷を作る電界が外部電界を打ち消し、BSO結晶内には電界の分布が形成される。このため、電気光学効果によりBSO結晶には複屈折率の分布ができる。ここで、光伝導効果が低く電荷分布を破壊しない赤色光を偏光子を通して照射すると、各点の複屈折率分布に応じた楕円偏光になりPROMを透過する。クロス状態で配置された検光子を通過した光は、書き込み光に応じた強度分布を持つ。書き込み光が照射されたところは暗くなり、ネガ像が読み出される。また、この段階で印加電圧を調整すると、画像の濃淡レベルの変更、輪郭強調等の画像処理等も可能である。

4) 消去

両電極を短絡し、素子全面に青色光を照射すると、分極電荷が再結合して、最初の状態に戻る。

C.3 基本動作と特性

PROMの基本的な動作モードは以下の4つがあり、印加電圧はそれぞれ、Table.C.2に示す。印加電圧と出力光強度関係をFig.C.2に示す。これは、オープンニコル時の光強度で規格化してある。

Fig.C.3は、ポジ動作モードとネガ動作モードにおける感度特性である。書き込み光の波長は490nm、読み出し光の波長は633nmである。読み出し光強度は5kV印加時出力で規格化してある。

Table.C.2 PROMの基本的な動作モードの印加電圧

	消去時	書込時	読出時
ポジ動作モード	0 kV	5 kV	0 kV
ネガ動作モード	0 kV	5 kV	5 kV
加算動作モード	—	5 kV	—
減算動作モード	—	0 kV	—

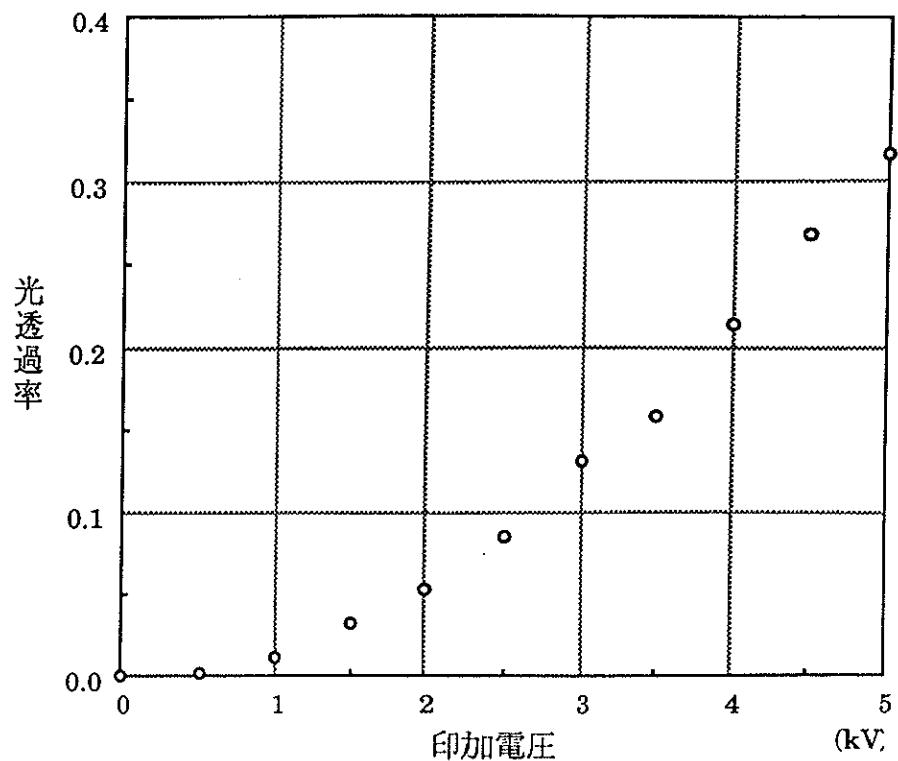


Fig.C.2 印加電圧と出力光強度関係

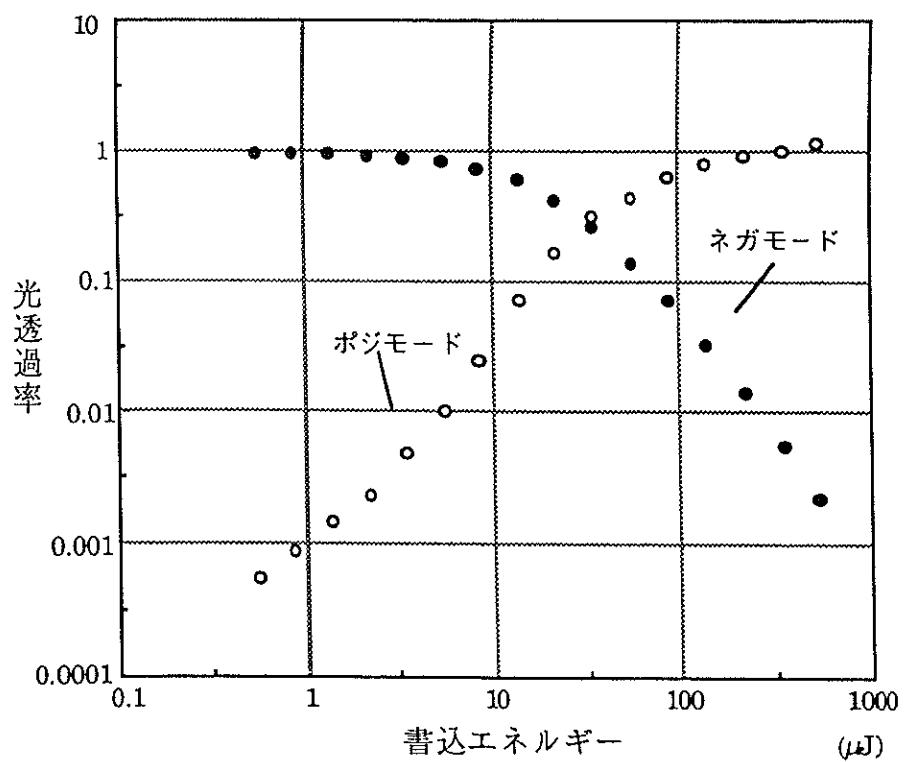


Fig.C.3 ポジ動作モードとネガ動作モードにおける感度特性

筑波大学附属図書館



1 00950 03840 2

本学関係
