

研究

特徴抽出光ニューロン素子を用いた手書き文字 認識光ニューラルネットワーク

蔵富 靖規・瀧本 昭雄・秋山 浩二・小川 久仁

松下電器産業(株)中央研究所 〒570 守口市八雲中町 3-1-1

(1992年7月3日受付, 1992年10月8日受理)

An Optical Neural Network Using Feature Extracting Optical Neuron Device for Hand-Written Character Recognition

Yasunori KURATOMI, Akio TAKIMOTO, Koji AKIYAMA and Hisahito OGAWA

Central Research Laboratories, Matsushita Electric Industrial Co., Ltd.,
3-1-1, Yagumo-nakamachi, Moriguchi 570

(Received July 3, 1992; Accepted October 8, 1992)

A novel spatial light modulator (feature extracting optical neuron device: FEOND) has been developed. It has been experimentally confirmed that the FEOND can correctly extract four kinds of line segments included in optical patterns. On the basis of the line segment extraction performed by the FEOND, an optical neural network model (vector feature extracting optical neuron device: V-FEONN) has been proposed. The V-FEONN can recognize hand-written letters by means of a vector feature extracted with only positive synaptic weight. Using the FEOND combined with a lenslet array, a memory mask, and a maximum detector, an all optical V-FEONN can be implemented. The necessary characteristics of the optical devices for the implementation of all optical system have been made clear by computer simulation.

1. はじめに

光ニューラルネットワーク (optical neural network: ONN) は, 情報の媒体として光を用いてニューラルネットワークを実現する大規模並列情報処理方式である¹⁻⁴⁾. ONN の高性能化には, 光デバイスと ONN モデルとが一体となった開発が不可欠である. 現在の光デバイスは, 演算精度, 集積度, 均一性などの点で, SiLSI を中心とした電子デバイスに比べてまだ未成熟である. さらに, 光学的アライメント調整技術, 負値の取扱い技術など, 光システムを構成する上での課題も多い.

このような現状のもとで, ONN モデルとしては, 光学的実現性の高さが要求されている. 光学的実現性の高いモデルとは, 実在のあるいは近未来に開発が予想される光デバイスを用いて容易に構成され, 光のもつ並列演算機能を十分にいかせるモデルである.

ネオコグニトロン^{5,6)} のような既存のニューラルネッ

トワークモデルは高い認識能力を持つが, 現在の光技術で実現することは難しい. なぜならそれらのモデルでは負値の演算を用いて情報を処理することに加え, ニューロン間の結合が複雑すぎるからである.

そこで, 実現可能な光デバイスの特徴を見極め, それに最適な ONN モデルを新しく構築することが不可欠となる. すなわち, 光デバイスがもつ機能に注目し, その機能を最大限にいかして高い能力をもつ独自の ONN モデルを開発するアプローチがぜひ必要であると考えられる. なぜなら光デバイスの機能を考慮して開発されたモデルは光学的実現性が高いことに加え, モデルを開発するプロセスにおいて, 光デバイスに対して必要な特性, 機能を具体的に明示できるからである.

本論文ではまず始めに, 入力パターンに含まれている特定の線分だけを抽出できる特徴抽出光ニューロン素子 (feature extracting optical neuron device: FEOND) について述べる. 次に, この FEOND を用いて実現さ

れる線分抽出の結果をいかした、手書き文字認識が可能なベクトル特徴抽出光ニューラルネットワークモデル (vector feature extracting optical neural network: V-FEONN) について述べる. 最後に, FEOND を用いて構成した光-電子融合型の V-FEONN の認識能力を実験的に示す. さらに, その能力を向上させ, 全光演算方式へ拡張するために要求される光デバイスの演算精度について言及する.

2. 特徴抽出光ニューロン素子

筆者らは, 光和算および閾値処理機能により, 2次元光パターンに含まれている特定方向の線分だけを抽出し, その結果を2次元光パターンで出力できる特徴抽出光ニューロン素子 (feature extracting optical neuron device: FEOND) を開発した⁷⁾. 以下では, FEOND の構造および動作原理について述べる.

FEOND の構造を Fig. 1 に示す. FEOND は, 光導電層 (pin 構造のアモルファスシリコン: 膜厚約 1.7 μm), ニューロン電極 (アルミニウム薄膜: 膜厚約 500 \AA), 配向膜 (導電性ポリイミド: 膜厚約 200 \AA), 光変調層 (強誘電性液晶: セルギャップ約 1 μm) を透明電極付きのガラス基板で挟んだ構造である.

FEOND の駆動方法および基本的動作は, 既に報告した光ニューロン素子^{8,9)} と同一であるが, 入力パターンに含まれる特定方向の線分を抽出するために, ニューロン電極の形状および配置を以下に述べる線分抽出型に変えている.

「縦」線分を抽出するためのニューロン電極の形状, およびその配置を Fig. 2 (a) に示す. 破線で囲まれた領域が一つのニューロンに相当する. 一つのニューロン電極は, 縦に並んでいる二つのニューロンにまたがり, その電極面積を二分するように配置される.

入力パターンは, Fig. 2 (b) に示したような 8×8 個




Fig. 1 Schematic view of feature extracting optical neuron device (FEOND).




Fig. 2 Operation of the line segment extraction. (a) An arrangement of the neuron electrodes for the extraction of the vertical line segment, (b) Two-dimensional input image, (c) Output pattern of FEOND.

の画素から構成される2値化パターン (各画素は1またはゼロ) である. この入力パターンは, Fig. 2 (a) の破線で囲まれた一つのニューロンに一つの画素が対応するように光導電層側から入力する. ここで, 1個のニューロン電極を二分した面積を S , 入力パターンの“1”の画素の光強度を I , “0”の画素の光強度を 0 とする. 「縦」線分が存在する場合には, 上下に並ぶ二つの画素が同時に“1”を出力するので, それらの画素に対応するニューロン電極には, 合計 $2SI$ の光量に相当する光電流が集められる. 一方, 一つの画素が“1”であり, 他の画素が“0”の場合, それらの画素に対応するニューロン電極には, SI の光量に相当する光電流しか集められない. したがって素子の閾値 θ に対して, 式(1)を満たすように入力光の強度 I を調整すれば, 「縦」線分が存在している場合に限り, FLC は off 状態から on 状態へ変化することになる.

$$SI < \theta < 2SI \quad (1)$$

Fig. 2 (c) に, FEOND を用いて, 正確に「縦」線分だけが選択的に抽出できている実験結果を示す.

破線で囲まれた一つのニューロンは, 上方と下方の境界線上にニューロン電極を有している (素子の最上部, 最下部は一つ). あるニューロンが, 「縦」線分を構成していない画素に対応する場合には二つの電極上の FLC は共に off 状態であり, 縦線分の端点に位置する場合には, 片方の電極上だけが on 状態になる. 「縦」線分の中で端点以外に位置するニューロンでは, 上下二つの電極上が共に on 状態である. この一つのニューロンに含まれる on 状態の FLC の個数を, そのニューロンの出力と定義する.

「横」, 「左斜め」, 「右斜め」の線分も同じ原理で抽出する. ただし, 「左斜め」, 「右斜め」線分の場合には, ニューロン電極を二つの単位電極 (面積: S) に分離し, 面積が無視できる程度の微小電極で結合することによって, 斜めにならぶ画素間の出力を光和算する.

以上の原理に基づき試作した FEOND を Fig. 3 に示した. この FEOND は, 四つの線分抽出面を持つ. 入力パターンに含まれる 4 方向の線分を同時に独立して抽出するためには, レンズアレイで多重展開した入力パターンを各線分抽出面に同時に入力すればよい. Fig. 4 に 1 個のニューロン電極に光信号を与えた場合の出力特性を示す. 入力光量が $2\mu\text{W}$ を超えると FLC が off 状態から on 状態に変化する急峻な閾値特性が得られており, 式(1)を満たすための十分な特性であることがわかる. 最大出力光強度の 50% の出力が得られる入射光量を閾値と定義して, 各ニューロン電極の閾値を測定したところ, 約 6% ばらついていた.

試作した FEOND に Fig. 2(b)に示した入力パターンを各抽出面に同時に入力した. このときの出力結果




Fig. 3 Surface pattern of feature extracting optical neuron device.




Fig. 4 Optical output characteristics as a function of the incident light power at a neuron electrode.




Fig. 5 An example of optical output pattern of FEOND.

を Fig. 5 に示す. このように FEOND は入力パターンに含まれる 4 方向の線分を正しく抽出できることを確認した.

3. 光ニューラルネットワークモデル

一般にパターン認識では, どのような特徴を用いるかにより認識能力は大きく左右される. ここでは, FEOND により抽出される線分情報をもとにパターンの構造的な特徴 (ベクトル特徴) を抽出して, 手書き文字の認識が可能な光ニューラルネットワークモデル¹⁰⁾を提案する.

3.1 モデルの構造

ベクトル特徴抽出光ニューラルネットワーク (vector feature extracting optical neural network: V-FEONN) の構造を Fig. 6 に示す. V-FEONN は階層型 4 層構造であり, ベクトル特徴を抽出する特徴抽出部 (入力層-中間層 1-中間層 2) と, 認識部 (中間層 2-出力層) とで構成される.

ベクトル特徴とは, 3.1.3 で述べるように入力パターンを構成する特定方向の線分が存在する位置とその長さを表す特徴量で, 線分抽出, 局所的な線分加算のプロセスを経て抽出される. V-FEONN はこの二つのプロセスを非負値の信号の和算, 閾値処理だけで実行する. また, 認識部のパーセプトロンは筆者らがすでに示したように全光演算方式で実現できる^{8,9)}. つまり V-FEONN は全光演算方式で実現できる可能性を持つ光ニューラルネットワークモデルである. この V-FEONN に 2 種類の手書き文字 "C" を入力した時の各層の出力状態を示した Fig. 7 を参照して各層の動作を以下に述べる.

3.1.1 入力層

入力層 ($n_i \times n_i$ ニューロン: 図では $n_i=8$) は, 入力




Fig. 6 Schematic diagram of vector feature extracting optical neural network (V-FEONN).




Fig. 7 Recognition process of V-FEONN: (a) hand-written letter (input pattern), (b) output of input layer (mesh feature), (c) output of the hidden layer 1, (d) output of the hidden layer 2, (e) output of the output layer.

パターンのメッシュ特徴を出力する。このメッシュ特徴 (Fig. 7 (b)) は、入力面 (Fig. 7 (a)) を $n_i \times n_i$ のメッシュに分割し、入力パターンを一部でも含むメッシュの値を 1 とする変換により作成されたものである。

3.1.2 中間層 1

中間層 1 は、線分抽出面 u^l ($l=1 \sim 4$: 各面は $n_i \times n_i$ ニューロン) を四つ並べた構造で、各面が四つの線分、すなわち「縦」($l=1$)、「横」($l=2$)、「左斜め」($l=3$)、「右斜め」($l=4$) 線分を抽出する。この線分抽出は 2 節で述べた原理にもとづいており、数学的には以下のように表現できる。

入力層の i 行 j 列に位置するニューロンを $x(i, j)$ 、その出力を x_{ij} とし、同様に u^l 面の i 行 j 列に位置するニューロンを $u^l(i, j)$ 、その出力を u^l_{ij} とする。このとき $x(i, j)$ が線分 l を構成している場合に限り $u^l_{ij} > 0$ となるように、入力層と線分抽出面とのシナプス結合、および $u^l(i, j)$ の出力関数を設定する。

u^l 面のニューロンと、入力層のニューロンの結合は

次式で表される。

$$u^l_{ij} = \Phi \left[\sum_{m, n \in \Omega^l} w^l_{mn} x_{i+m, j+n} \right] \quad (2)$$

ここで、 $\Phi[\xi]$ は出力関数、 Ω^l は $u^l(i, j)$ と入力層の結合を規定する (m, n) の集合、 w^l_{mn} はシナプス荷重で、各々式 (3) ~ (5) を満たす。

$$\Phi[\xi] = \begin{cases} \xi - 2 & \text{if } \xi \geq \theta \\ 0 & \text{if } \xi < \theta \end{cases} \quad (3)$$

$$\begin{aligned} \Omega^1 &= \{(m, n) | (1, 0), (0, 0), (-1, 0)\} \\ \Omega^2 &= \{(m, n) | (0, 1), (0, 0), (0, -1)\} \\ \Omega^3 &= \{(m, n) | (1, -1), (0, 0), (-1, 1)\} \\ \Omega^4 &= \{(m, n) | (1, 1), (0, 0), (-1, -1)\} \end{aligned} \quad (4)$$

$$w^l_{mn} = \begin{cases} 2 & \text{if } (m, n) = (0, 0) \\ 1 & \text{else} \end{cases} \quad (5)$$

Table 1 に入力層の出力状態と、 $u^l(i, j)$ へ入力する信号の総和 ξ との関係を示す。閾値 θ は、 $x(i, j)$ が「縦」線分を構成する場合 (Table 1 (a)) における ξ の最小値より小さく、「縦」線分を構成しない場合 (Table 1 (b)) における ξ の最大値より大きくなければならない。したがって閾値 θ は式 (6) の範囲となる。

$$2 < \theta \leq 3 \quad (6)$$

上記設定により Fig. 7 (b) のメッシュ特徴から 4 方向の線分が非負値のシナプス荷重により抽出される (Fig. 7 (c))。2 節で定義した FEOND の出力は、この中間層 1 の出力と一致する。

3.1.3 中間層 2

中間層 2 は、四つのベクトル特徴抽出面 $v^1 \sim v^4$ (各面は $n_v \times n_v$ ニューロン: 図では $n_v = 3$) で構成されている。 v^l 面の各ニューロンは、対応する u^l 面の出力を局所的に加算し、ベクトル特徴を表す。すなわち、 v^l 面の各ニューロンは、 n_v^2 個の領域に分割された u^l 面の一つの領域内のすべてのニューロンとだけ正の同一値のシナプス荷重 (例えば 1) で結合する。このとき各領域に v^l 面の 1 個のニューロンを対応させる。 v^l 面の m 行 n 列に位置するニューロンを $v^l(m, n)$ 、その出力を

Table 1 Relation between the output of neurons in the input layer and that of in the hidden layer 1.

	(a)	(b)
$1 \times x_{i-1, j}$	1 1 0	1 0 1 0 0
$2 \times x_{i j}$	2 2 2	0 2 0 0 0
$1 \times x_{i+1, j}$	1 0 1	1 0 0 1 0
ξ	4 3 3	2 2 1 1 0
u^l_{ij}	2 1 1	0 0 0 0 0

v^l_{mn} とすると、この結合は式(7)で表される。

$$v^l_{mn} = \sum_{i,j \in \Omega_p(m,n)} u^l_{ij} \quad (7)$$

ただし、 $v^l(m,n)$ の出力関数は単調増加な線形関数であり、 $\Omega_p(m,n)$ は、 $v^l(m,n)$ と結合する u^l 面内のニューロン ($v^l(m,n)$ の受容野と呼ぶ) を定める (i,j) の集合である。このような結合にすると、 $v^l(m,n)$ の出力強度は、受容野内に存在する線分 l の長さに比例する。したがって中間層2全体では、Fig. 7 (d)に示したように、入力パターンの中に、線分 l が、どの位置に、どの程度の長さで存在しているかというベクトル特徴を表すのである。

3.1.4 出力層

出力層の各ニューロンは、中間層2のすべてのニューロンと結合し、出力層の中で入力信号の総和が最大のニューロンだけが発火し(最大値検出)、認識結果を表す。すなわち、出力層 k 番目のニューロンの出力を y_k とすると y_k は式(8)で表される(図ではアルファベット認識の場合であり $k=1, 2, \dots, 26$)。

$$y_k = \begin{cases} 1 & \text{if } \delta_k \text{ が最大} \\ 0 & \text{else} \end{cases} \quad (8)$$

ただし、 δ_k は k 番目のニューロンへの入力信号の総和であり、 $v^l(m,n)$ とのシナプス荷重を w^l_{kmn} とすれば式(9)で表される。

$$\delta_k = \sum_l \sum_m \sum_n w^l_{kmn} v^l_{mn} \quad (9)$$

Fig. 7 (e)では3番目のニューロンが発火し認識結果“C”を表している。

3.1.5 学習方法

V-FEONN では、中間層2と出力層のシナプス荷重のみ次式に従い学習させる。

$$w^{n+1}_{ji} = \begin{cases} w^n_{ji} + \alpha v_i & (t_j - y_j > 0) \\ w^n_{ji} - \beta v_i & (t_j - y_j < 0) \end{cases} \quad (10)$$

ただし、 v_i は中間層2のニューロンの出力(36次元の縦ベクトル)、 y_j は出力層の出力(26次元の縦ベクトル)、 t_j は教師信号(26次元の縦ベクトル)、 w^n_{ji} は n 回学習後の v_i と y_j のシナプス荷重、 α, β は学習係数である。なお、シナプス荷重を光デバイスで表現することを考慮して、学習過程で生じた負値のシナプス荷重はすべてゼロとした。出力層が最大値検出を行うので、学習の収束性は学習係数の絶対値に依存せず、比 α/β に依存する。

実験では10種類の手書き英字260文字(マトリックスサイズ 360×360)を用意し、V-FEONN に学習させた。パターンはいずれも入力面の80~100%の大きさ

であった。計算機シミュレーションの結果、V-FEONN は $1 \leq \alpha/\beta \leq 15$ の範囲で学習を収束できた。

4. 光学的システム

4.1 光-電子融合型光ニューロシステム

FEOND を用いて、光-電子融合型 V-FEONN を構成できる。システムの構成を Fig. 8 に示す。本システムは、V-FEONN の入力層-中間層1を光学的に実現し、中間層2-出力層をコンピュータにより実現するものである。

入力となる手書き文字は、タブレットを介してメッシュ特徴に変換された後、入力層である透過型液晶テレビ(liquid crystal-TV: LC-TV, $20 \text{ mm} \times 26 \text{ mm}$)上に表示される。この入力像はレンズアレイ (2×2 : レンズ径 8.4 mm , 焦点距離 30 mm)により四つの多重像に展開され、各像が FEOND 中の四つの線分抽出面に書き込み光として同時に入力する。FEOND の出力は、白色面光源からの読み出し光を、偏光子を介して FLC 側から入力し、ニューロン電極からの反射光を偏光子に対して直交する偏光軸をもつ検光子を通すことで得られる。この出力は、中間層1の線分抽出結果に相当し、CCD カメラで撮像され、コンピュータにより加算、認識の演算が実行される(中間層2, 出力層)。中間層2と出力層間のシナプス荷重は、あらかじめ計算機シミュレーションの学習により得られた値を用いた。本システムは Fig. 9 に示したような手書き文字でも正しく認識できることを確認した。

4.2 全光演算型光ニューロシステム

FEOND は、2次元並列に線分抽出を実行するので、ニューロン電極の高密度化による処理時間の増大を伴わない。しかし、光-電子融合型のシステムでは CCD カメラによる画像入力という時系列のプロセスが介在し、




Fig. 8 Opto-electronic hybrid vector feature extracting optical neural network system with FEOND.



Fig. 9 Example of patterns which were recognized correctly.

大規模なシステムに拡張すると処理時間の増加を招いてしまう。そこで、すべての演算を並列に処理する全光演算方式による実現を検討した。

V-FEONN を全光演算方式で実現する場合には、シナプス荷重に空間的制限を設けることで中間層2を省くことができる。中間層2のニューロン $v^i(m, n)$ の出力は、式(7)に示したように u^i 面中の受容野内のニューロンの出力を局所的に加算した結果そのものである。したがって、 $v^i(m, n)$ と接続していた受容野内のニューロンを出力層のニューロンと直接接続し、シナプス荷重をすべて w^i_{kmn} とすることで、中間層2を省略できる。

Fig. 10 は全光演算型 V-FEONN の構成概念図である。このシステムでは、FEOND の光出力をレンズアレイにより多重展開することで中間層1と出力層間の全結合を実現する¹¹⁾。その際、シナプス荷重を透過型SLM (メモリーマスクと呼ぶ) に表示し、多重像と重ね合わせることで重み付けを実行する。重み付けされた光信号は最大値検出機に入力し、和算と最大値検出が実行される。

レンズアレイの個数は出力層のニューロン数と同数個であればよい。筆者らは 9.6 mm 角の大きさの画像を 6×6 のレンズアレイ (レンズ径 3 mm, 焦点距離 20 mm) により多重展開可能であることを既に示している^{8,9)}。以下では、全光演算方式実現の可能性を、シナプス荷重の階調数, 最大値検出精度の観点から考察する。

4.2.1 シナプス荷重の階調




Fig. 10 All-optical vector feature extracting optical neural network system with FEOND.




Fig. 11 Relation between recognition rate and gray scale of synaptic weight. (●) : type 1, (○) : type 2.

3.1.5 で用いた手書き英字 260 パターンを学習後、シナプス荷重の階調数を $2^2 \sim 2^{16}$ の範囲で制限した 2 種類の V-FEONN (type 1: $n_i=8, n_o=3$, type 2: $n_i=60, n_o=3$) の未学習文字パターンに対する認識率を調べた。

Fig. 11 に計算機シミュレーションの結果を示す。横軸はシナプス荷重の階調数で、縦軸は認識率である。認識率はいずれのネットワークでも $2^4=16$ 階調以上ではほぼ一定であることがわかった。16 階調の表示は、写真フィルム, LC-TV などの現状の SLM でも実現可能であり、書換え可能な LC-TV を用いれば、学習機能を付加できる¹²⁾。

4.2.2 最大値検出精度

出力層では、各ニューロンへの入力信号の総和 δ_k を比較することで認識結果を表す。この最大値検出精度と認識能力の関係について計算機シミュレーションを行った。Fig. 12 に結果を示す。横軸は最大値検出精度で、正規化された総和 δ_k が比較される桁数を表している。例えば 10^{-3} は、信号の小数点以下第 3 位の値の区別が可能な精度を意味する。

実験の結果、認識率は 10^{-2} 以上の精度ではほぼ一定




Fig. 12 Relation between recognition rate and accuracy of maximum detector. (●): type 1, (○): type 2.

になることがわかった。現在、このような精度を満足する最大値検出デバイスは見あたらないが、CCD カメラが8ビット以上の精度を持つことから、不可能な精度ではないと考えている。

また、この結果は FEOND の読み出し光源などの光学的不均一性も1%以内に抑える必要があることを意味している。しかし、実際の読み出し光源の光量は10数%ばらついており、1%以内の光学的均一性を確保することは現状では困難である。

そこで、計算機シミュレーションで得たシナプス荷重をそのまま用いるのではなく、光学システム上で学習を実行し、光学系の不均一性を補償することを考えねばならない¹¹⁾。メモリーマスクとして書換え可能な SLM を用い、光学システム上で、V-FEONN が用いたような閉ループ型の学習を実行すれば、±12%程度の光学的不均一性を補償できる^{12,13)}。したがって、全光演算型 V-FEONN では、メモリーマスクに書換え可能な SLM を用いて学習を実行させる必要がある。

5. む す び

空間光変調素子の光和算、閾値処理機能に注目し、2次元光入力パターンから、並列に線分抽出を実行する特徴抽出光ニューロン素子 (FEOND: 8×8 ニューロン対応) を作製し、動作を実験的に確認した。

FEOND が実現する線分抽出機能を有効に活用できる、新規光ニューラルネットワークモデル (V-FEONN) を提案した。さらに FEOND を用いて、光-電子融合型 V-FEONN を構成し、手書き英字 26 文字の認識が可能であることを実験的に示した。また、全光演算方式を実現するための課題についても検討した。

入力層のニューロン数を 30×30 以上にすることで、

認識能力はさらに向上することが計算機シミュレーションにより確認されている¹⁴⁾。今後は少なくとも 30×30 以上のニューロン数に対応する FEOND を開発する必要がある。

V-FEONN は電子システムでも容易に実現できるモデルである。今後は、光デバイス特有の機能をベースにモデルを開発することで、並列情報処理における光技術の優位性を明確にしてゆけるものと考えている。

文 献

- 1) 石川正俊: “並列処理システムとしての光ニューロコンピューティング”, 光学, **19** (1990) 755.
- 2) 早崎芳夫, 谷田貝豊彦: “光ニューラルコンピューティングの展望”, 光学, **20** (1991) 664.
- 3) M. Ishikawa, N. Mukohzaka, H. Toyoda and Y. Suzuki: “Experimental studies on learning capabilities of optical associative memory,” Appl. Opt., **29** (1990) 289-295.
- 4) N.H. Farhat, D. Psaltis, A. Prata and E. Paek: “Optical implementation of the Hopfield model,” Appl. Opt., **24** (1985) 1469-1475.
- 5) 福島邦彦: “位置ずれに影響されないパターン認識機能の神経回路モデル-ネオコグニトロン-”, 信学論 (A), **J 62-A** (1979) 658-665.
- 6) 福島邦彦, 三宅 誠, 伊藤嵩之: “ネオコグニトロンの原理を用いた数字パターン認識”, 信学論 (D), **J 66-D** (1983) 206-213.
- 7) 蔵富靖規, 瀧本昭雄, 秋山浩二, 野村幸治, 朝山純子, 小川久仁: “特徴抽出光ニューロン素子(2)-デバイス構成-”, 第52回応用物理学会学術講演会講演予稿集(1991) 9p-ZH-2.
- 8) 瀧本昭雄, 秋山浩二, 宮内美智博, 蔵富靖規, 朝山純子, 小川久仁: “全光演算方式ニューラルネットワーク”, 電学会光応用・視覚研資 (1991) LAV-91-10.
- 9) K. Akiyama, A. Takimoto, M. Miyauchi, Y. Kuratomi, J. Asayama and H. Ogawa: “A new optical neuron device for all-optical neural networks,” J. Jpn. Appl. Phys., **30** (1991) 3887-3892.
- 10) 蔵富靖規, 小川久仁: “特徴抽出光ニューロン素子(1)-ネットワークモデル-”, 第52回応用物理学会学術講演会講演予稿集(1991) 9p-ZH-1.
- 11) T. Lu, S. Wu, X. Xu and F. T. S. Yu: “Two-dimensional programmable optical neural network,” Appl. Opt., **28** (1989) 4908-4913.
- 12) 蔵富靖規, 秋山浩二, 小川久仁: “学習機能を実現した光連想メモリ”, テレビ学技報 (1990) IPU '90-54.
- 13) K. Akiyama, Y. Kuratomi, T. Ogawa, H. Tsutsui, H. Tsutsui and H. Ogawa: “Large-scale adaptive associative memory using TFT-LCD,” Proc. International Topical Meeting on Optical Computing, Kobe, Japan (1990) 10E18.
- 14) 蔵富靖規, 瀧本昭雄, 秋山浩二, 田中幸生, 朝山純子, 小川久仁: “特徴抽出光ニューロン素子(3)-認識能力向上-”, 第39回応用物理学会関係連合講演会講演予稿集(1992) 29p-B-18.