



液晶テレビを用いた2層型光ニューラルネット

景 虹・峯 本 工

神戸大学工学部計測工学教室 〒657 神戸市灘区六甲台町 1-1

(1991年5月7日受付, 1991年8月5日受理)

Optical Two-Layer Neural Net Using a Liquid-Crystal Television

Hong JING and Takumi MINEMOTO

Department of Instrumentation Engineering, Faculty of Engineering,
Kobe University, Rokkodai, Nada-ku, Kobe 657

(Received May 7, 1991; Accepted August 5, 1991)

A two-layer optical neural net based on the delta-rule-learning algorithm is constructed by an LED array, a CCD camera, and a conventional liquid-crystal television (LCTV). The synaptic weight matrix interconnecting between the layers is developed on the screen of LCTV by dividing it into square subcells and the weights are determined by the widths and the positions of opening windows in the subcells. By this method, wide dynamic range of the synaptic weight is achieved. Learning and recognition of binary patterns in the neural net are described.

1. はじめに

ニューラルネットは多数のニューロンにより構成される並列処理ネットワークであり、そのハードウェア化に関する研究が盛んに行われている。なかでも、光連想メモリに代表されるように、光の持つ情報伝達に関する並列性を利用したものは数多く提案され、実現されつつある¹⁻⁷⁾。しかし、ニューロン間の結合重みは連続でかつ広い範囲に分布する値を持つことが多いため、これを光学的に実現するのは困難である。このため、光ニューラルネットの主流は必ずしも広範囲な結合重みを必要としないホップフィールドモデル^{1,2)}や空間コーディング法を利用した直交学習法³⁻⁵⁾を学習則とするものになっている。それに対して、正と負を含む変化範囲の広い結合重みが必要なバックプロパゲーションアルゴリズム、あるいはデルタルールを学習則とするモデルはあまり実現されていない。

従来、光学素子を利用したニューラルネットはニューロン間の結合重みを液晶テレビや空間光変調素子などの透過率を変化させることによって実現してきたが、現状では、これらの素子のダイナミックレンジが広く取れな

いため、ニューラルネットは結合重みの変化範囲が少ないモデルに制限されてきた。

本研究では、LED アレイ・液晶テレビ・CCD カメラを用いた簡単な光学系で2層型のニューラルネットを構成し、デルタルールによる教育を行った。幅広く分布するニューロン間の結合重みを実現するために、液晶テレビの画面を結合の数に対応して分割し、分割された各領域（以後セルと呼ぶ）に LED アレイからの入力光を透過させる開口を設け、結合重みの大きさを開口の面積で実現した。結合重みの正と負については開口の空間的な位置で区別する手法を採用した。結合重みをこのように定義することによって、正と負を含む広い範囲に分布する結合重みが実現できた。また、実験では、出力層ニューロンの自己固有閾値が学習に及ぼす効果を調べた。その結果、ネットワークを構成する各ニューロンの特性が揃っていない場合では、自己固有閾値を持つ時のニューラルネットは、持たない時に比べて学習が速く終了することが実証された。

以下では、システムの構成および学習の原理を述べた後、8種類の2値パターンに対する学習結果について検討を加える。

2. システムの構成

本研究で構成したニューラルネットは n_1 個のニューロンを持つ入力層と n_2 個のニューロンを持つ出力層の 2 層からなるものである。そのモデルを Fig. 1 に示す。

2.1 デルタルール学習則

上記の 2 層型のネットワークにおけるデルタルール学習則の原理^{8,9)}を以下に示す。学習とは、結合重みを学習パターンに対する出力と教師信号との差の平均 2 乗誤差が最小となるように変化させていく過程である。

あるパターンが与えられた時、入力層にある i 番目のニューロンと出力層にある j 番目のニューロンの間の結合重みの変化量 ΔW_{ji} は、出力層における誤差 δ_j と入力層の出力 y_{1i} の積

$$\Delta W_{ji} = \eta \cdot \delta_j \cdot y_{1i} \quad (1)$$

$$(i=1, 2, \dots, n_1, j=1, 2, \dots, n_2)$$

で表される。上式の中で、 η は学習レートを表す正の比例定数であり、また、

$$y_{1i} = f_1(v_i) \quad (2)$$

$$\delta_j = (t_j - y_{2j})f'_2(net_j + th_j) \quad (3)$$

ただし、

$$y_{2j} = f_2(net_j + th_j) \quad (4)$$

$$net_j = \sum_{k=1}^{n_1} W_{jk} \cdot y_{1k} \quad (5)$$

ここで、

y_1, y_2 : 入、出力層ニューロンからの出力

f_1, f_2 : 入、出力層ニューロンの入出力関数

f'_2 : f_2 の微分

v : 入力層ニューロンへの入力

t : 出力層ニューロンへの教師信号

net : 出力層ニューロンへの入力

th : 出力層ニューロンの自己固有閾値

ニューロンの入出力関数に通常シグモイド関数が用いられるが、本研究では、簡単化のため、入力層のニューロン

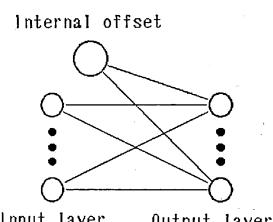


Fig. 1 Two-layer neural net with n_1 inputs, an input for internal offsets in output nodes, and n_2 outputs.

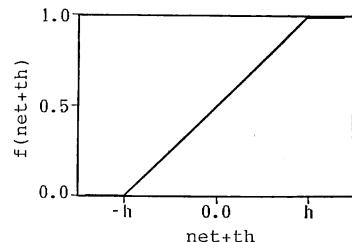


Fig. 2 Input-output relation (unity slope saturation nonlinearity) used in output nodes.

については線形関数

$$y_1 = f_1(x) = x \quad (6)$$

を入出力関数として採用し、出力層についてはシグモイド関数に近似した Fig. 2 に示すような関数形

$$y_2 = f_2(x) = \begin{cases} 0 & -h \leq x \leq h \\ x/2h + 1/2 & -h > x \\ 1 & x > h \end{cases} \quad (7)$$

を選んだ。このような部分線形関数を用いることで、将来的には簡単な limited linear amplifier でも入出力関数を実現できると考えられる。

式(3)、(6)および(7)を用いると式(1)は次のようにになる。

$$\Delta W_{ji} = \eta(t_j - y_{2j})v_i/2h \quad (8)$$

ここで、 $\eta/2h$ を改めて η と定義すると、

$$\Delta W_{ji} = \eta(t_j - y_{2j})v_i \quad (9)$$

となる。

正確には式(9)は $|net_j + th_j| \leq h$ の範囲内のみで成り立ち、 $|net_j + th_j| > h$ の領域においては $f'_2 = 0$ であるため、 $\Delta W_{ji} = 0$ となり、 W_{ji} の修正ができなくなる。しかし、式(7)の定義によれば、教師信号に 0 と 1 の 2 値信号を用いた場合、 $|net_j + th_j| > h$ では、出力層における誤差 $(t_j - y_{2j})$ が 0、あるいは ± 1 となることがわかる。誤差が 0 であれば、 W_{ji} を修正する必要がなく、つまり、 $\Delta W_{ji} = 0$ が成り立つ。また、誤差が ± 1 である場合、式(9)に従って W_{ji} が最も大きく修正されることになる。このような観点から、 $(net_j + th_j)$ の全領域に対して式(9)が一般性を失うことなく成り立つと考えられる。

また、式(4)の自己固有閾値 th_j として、式(5)における net_j を計算するための要素と同様にして

$$th_j = W_{j0} \cdot v_0 \quad (10)$$

とおくことができる¹⁰⁾。この時、Fig. 1 からわかるように、 W_{j0} は固有閾値を決定するための入力層ニューロンと出力層ニューロン間の結合重みであり、 v_0 はこの入力層ニューロンからの出力信号である。固有閾値の決

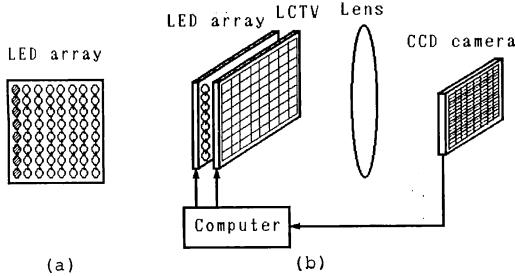


Fig. 3 Concept for optical implementation of two-layer neural net. (a) Structure of LED array. The hatched column shows LEDs used for internal offsets in output nodes. (b) Schematic diagram of optical system.

定に際して、常に $v_0=1$ と考えて結合重み W_{j0} の変化に従って変えていけばよい。この時、式(4)は次のように簡単になる。

$$y_{2j} = f_2 \left(\sum_{k=0}^{n_1} W_{jk} \cdot v_k \right) \quad (11)$$

デルタルールによる学習過程は以下のように進む。

- 1) 学習用のデータを入力して結果を出力する。
- 2) 結果に対する誤差を減らすように式(9)に従って結合重みを変える。
- 3) 誤差が所望の値以下になるまで 1) と 2) を繰り返す。

2.2 実験システム

システムの主要部分は LED アレイ・液晶テレビ・CCD カメラからなり、それぞれニューラルネットの入力層・結合器・出力層に対応する。**Fig. 3** にシステム構成を示す。縦 1 列の LED を入力層にある一つのニューロンからの出力信号端子に対応させる。LED アレイの 1 列目は前記の固有閾値を決定するために設けられたもので、学習の過程において、この列の LED は常に on の状態を取る。出力層ニューロンへの入力信号の線形和は液晶テレビを透過していく横 1 列の LED の光の強度の和で表される。ニューロン間の結合重みを表すために、液晶テレビの画面を **Fig. 4** に示すようなセルに分割し、一つのセルに一つの結合を対応させる。この時、各セル内で LED からの光を透過させるための開口を設け、開口の幅 W_{ji} で結合重みの大きさを表し、セル内の開口の空間的な位置（セルの上部にあるか下部にあるか）で結合重みの正と負を表す。

3. 実験結果と検討

3.1 システムの基礎特性

本研究で構成したニューラルネットは 7 入力と 8 出力

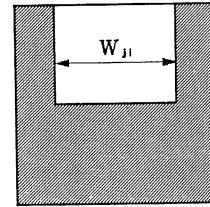


Fig. 4 Structure of (j, i) cell in interconnection weight matrix on LCTV. The cell has an opening with width proportional to W_{ji} on its upper- or lower-half region. The opening on the upper-half region represents the positive interconnection weight and that on lower-half region the negative one.

Table 1 Eight learning patterns. Input signals in the first column show those for determination of internal offsets of output nodes.

Input patterns	Teaching patterns
1 0 0 1 1 0 0 0	1 0 0 0 0 0 0 0
1 1 1 0 0 1 1 1	0 1 0 0 0 0 0 0
1 0 0 0 0 1 1 1	0 0 1 0 0 0 0 0
1 1 1 1 1 0 0 0	0 0 0 1 0 0 0 0
1 0 1 0 1 0 1 0	0 0 0 0 1 0 0 0
1 1 0 1 0 1 0 1	0 0 0 0 0 1 0 0
1 0 0 0 1 1 1 0	0 0 0 0 0 0 1 0
1 1 1 1 0 0 0 1	0 0 0 0 0 0 0 1

のモデルである。学習実験で用いられた入力パターンは 2 値のみで、**Table 1** に入出力の組を示す。入力信号の 1 と 0 はそれぞれ LED の on と off に対応する。全ての LED がほぼ同様の明るさで点灯するように LED に印加する電圧とそれに流れる電流を調整できるシステムになっている。入力にある 1 列目の信号は出力層ニューロンの自己固有閾値を求めるためのものである。入力層ニューロン数 n_1 と出力層ニューロン数 n_2 の 2 層ネットワークの結合数は、本方式の場合、 $(n_1+1)n_2$ となる。このように、本システムでは LED アレイは計 8 列となり、結合の数は 8 × 8 となった。

実験では、まず LED アレイを点灯し、結合重みを実現するために用いられる液晶テレビ上に設けた開口を変化させて、設定結合重みに対する実際の結合量の変化の様子について調べた。その結果を **Fig. 5** に示す。図には各設定開口幅に対する結合量の最高値・平均値・最小値を示した。この図から同一の開口幅に対する結合重みに最大 10% 程度のばらつきがあることがわかる。これは実験に使用した LED の輝度の最も明るいものも最も暗いものの差が平均値の数% 程度あったことが主たる原

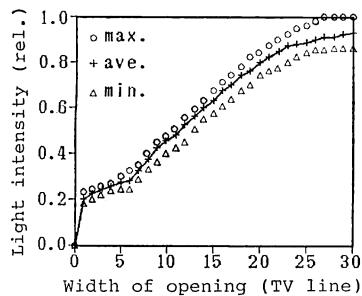


Fig. 5 Transmitted light intensity from cell in interconnection weight matrix versus opening width in the cell. Solid curve shows average value per a cell over all 8×8 cells, ○ the maximum value, and △ the minimum value.

因である。しかし、ニューラルネットはそれ自身の柔軟性によってこれらのばらつきを吸収できると考えたので、特に補正を行わなかった。

Fig. 5 から、結合重みの平均値が開口幅の変化に対応して変化するのは開口の幅が 0~26 lines の範囲であることがわかる。この範囲内では、開口幅と透過光強度の関係は単調増加関数になっており、開口幅を変化させて実現できる結合重みのダイナミックレンジは 27 段階あることがわかる。これは液晶テレビの階調のみを変化させた時に得られるダイナミックレンジ（実際では 5 段階であった）に比べて数倍高い。今回はビデオメモリ（液晶テレビ）上の開口の幅で結合重みを実現しているが、液晶テレビ自体の画素の数を利用すれば、さらに広い範囲のダイナミックレンジが得られる。

3.2 学習実験

コンピュータから初期状態としてニューロン間にランダムな結合重みを与えて、学習を開始する。まず、入力パターンに対応して LED を点灯し、結合重みに対応して液晶テレビ上の各セルに開口を開ける。そして、開口を透過してくる光の強度をニューロンごとに集計して式(11)に示す $\Sigma(W_{jk} \cdot v_k)$ を求め、出力信号を計算する。そして、この出力信号をもとに式(9)に従ってセル内開口の幅を修正する。以上が一つのパターンに対する学習過程である。そして、同じ過程をその他のパターンに対して繰り返し行い、次の式で定義される 2 乗誤差が所望の値以下になるまで学習を続ける。

$$D = \sum_{m,j=1}^8 (t_{mj} - y_{2mj})^2 \quad (12)$$

ただし、 $m(m=1, 2, \dots, 8)$ は学習パターンを区別するために付けた番号である。

実験結果の一例として、学習回数の増加に従って 2 乗

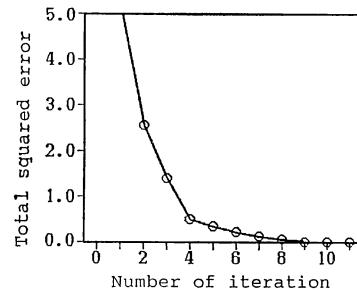


Fig. 6 Example of learning curve for eight binary patterns shown in Table 1.

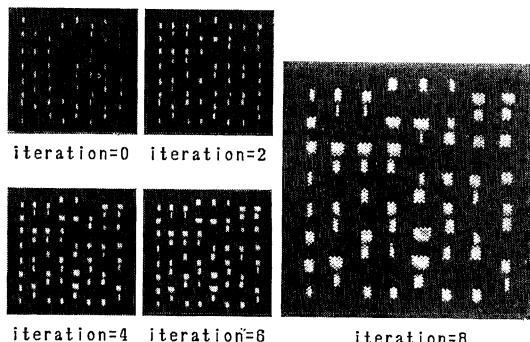


Fig. 7 Interconnection matrix patterns in the learning process shown in Fig. 6. The matrix has 8×8 cells. Corresponding to positive interconnection weight or negative one, each cell has an opening on its upper- or lower-half region.

誤差が減少する様子を Fig. 6 に示す。ここで学習回数の 1 回とは、八つのパターンが一巡して教育される過程である。Fig. 6 に示した学習途中における結合重みの変化の様子を Fig. 7 に示す。同図の写真の左端の一列は出力層ニューロンの固有閾値を表す。今回の実験では、一つのパターンが学習するのに要する時間は約 0.5 秒で、学習回数 1 回当たりの時間約 4 秒であった。式(11)で定義した 2 乗誤差が 0.08 以下になるまでは約 8 回程度の学習が必要であった。

学習レート η を決定する際に、式(9)における出力信号と教師信号との誤差の絶対値が 0.1 以上あれば結合重み ΔW が修正できるように $\eta=5$ として実験を行った。誤差が ± 0.1 である時、結合重みの修正量 ΔW は四捨五入して開口を構成する線の数を 1 line だけ増減することになる。また、出力層ニューロンの入出力関数における h を出力層ニューロンへの最大入力 ($\Sigma W_{jk} \cdot v_k$ の最大理論値) の $1/(10(n_1+1))$ に設定して、入出力関数を定義した。

また、実験では、学習して得た結合重みを持つニュ-

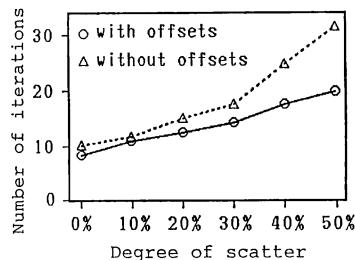


Fig. 8 Examples of the relationships between the scatter in light intensity of LED array and the number of learning cycles for the neural nets with and without internal offsets.

ラルネットに、学習に用いた0と1の信号レベルと異なるレベルを持つ信号を入力した場合の想起結果について検討した。入力信号のレベルはLEDの明るさを調整して変動させ、信号レベルの変動の程度は、学習時の2値入力信号の1に相当する明るさを基準にして百分率表示したものである。その結果、1の入力信号レベルを学習時のものから±20%の範囲内、また、0の入力信号レベルを最大20%まで変動させても、出力層における2乗誤差は0.08以下となり、正しい想起結果が得られた。

3.3 自己固有閾値が学習速度に与える影響

自己固有閾値の効果を調べるために、入力層を構成するニューロンの特性が揃っていない（各列のLEDアレイの発光状態が均一でない）場合を想定して学習を行った。実験では、各列のLEDのonの状態の明るさにランダムにばらつきを与えて、終了までの学習回数を調べた。ばらつきの程度はLEDアレイの最大と最小の輝度差をばらつきがない（3.1項で述べた数%）時のLEDの輝度で割ったものである。

Fig. 8に実験結果を示した。LEDアレイの輝度のばらつきの程度が大きくなれば、終了までに必要な学習回数も増加することがわかった。これは、ばらつきを吸収するために、より多くの学習回数を要した結果であると考えられる。また、ばらつきの程度が10%以下と小さい時、自己固有閾値を持つ時と持たない時の学習回数には殆ど差がなかったが、ばらつきの程度が大きくなるにつれてその差が著しく大きくなっていることがわかった。自己固有閾値を持たないニューラルネットでは、出力層ニューロンが持つ入出力関数のオフセットを調節できず、自己固有閾値を持つ時に比べて学習が遅くなったりと考えられる。また、自己固有閾値を持たない場合、全てのニューロンが同じ入出力関数を取ることになり、個別のニューロンの大きなばらつきを吸収できなくなったり

のも学習速度が遅くなった原因の一つである。

このように、2値のパターンを教育する場合、自己固有閾値を持つニューラルネットは持たないものより学習速度が速くなり、特に入力層ニューロンの特性に大きなばらつきがある場合にその効果が顕著に現れる。

4. おわりに

簡単な光学系を用いて、デルタルールを学習則とする2層型のニューラルネットを構成した。ニューロン間の結合重みを液晶テレビ画面上に設けた開口の面積と空間位置で定義することで、正と負を含む広い範囲の結合重みを実現できた。実験では、学習が終了した光ニューラルネットに、信号レベルにある程度の変動を持つ信号を入力しても、正しい想起結果を得ることができた。また、自己固有閾値が学習に及ぼす影響について調べた。その結果、光ニューラルネットを構成するニューロンの特性にばらつきがある場合、自己固有閾値を持つニューラルネットは持たないものより学習が速くなることを実験的に証明できた。

今回のシステムは液晶テレビ画面とCCDカメラの間にレンズを用いた結像系になっているが、LEDアレイとCCDカメラの代りにそれぞれ柵状の発光素子（例えばEL素子）とrectangular photodetector array（RPA）を利用してレンズをなくし、発光素子・液晶テレビ・RPAを密着すれば、システムをさらに簡便化でき、手軽にニューラルネットを構成することができる。また、本研究でニューロンの入出力関数に用いた部分線形関数はlimited linear amplifierで実現できるため、これらを制御する簡単なコントローラと帰還量を計算する簡単な演算子を加えれば、研究実験等で簡便に利用できるニューラルネットが構成できるであろう。

本研究では2値の入力パターンのみに対して学習を行ったが、本システムでは、LEDの発光強度を変化させることができるので、多値のパターンに対しても学習が可能であると考えられる。最後に、今後の課題として、各層のニューロンの数を増やすとともにより高度な学習能力を持つ3層型のニューラルネットの光学系による構成があげられる。

文献

- 1) N. H. Farhat, D. Psaltis, A. Prata and E. Paek: "Optical implementation of the Hopfield model," Appl. Opt., **24** (1985) 1469-1475.
- 2) A. D. Fisher, W. L. Lippincott and J. N. Lee: "Optical implementations of associative networks with versatile adaptive learning capabilities," Appl. Opt.,

- 26 (1987) 5039-5054.
- 3) M. Ishikawa, N. Mukohzaka, H. Toyoda and Y. Suzuki: "Optical associatron: a simple model for optical associative memory," *Appl. Opt.*, **28** (1989) 291-301.
 - 4) T. Lu, X. Xu, S. Wu and F. T.S. Yu: "Neural network model using interpattern association," *Appl. Opt.*, **29** (1990) 284-288.
 - 5) 筒 博司, 秋山浩二, 小川 鉄, 筒井博司: "TFT-LCD を用いた光連想メモリ", 1989年 TV 学会全国大会 1-1 (1989) pp. 1-2.
 - 6) 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** (1990) 227-229.
 - 7) F. Itoh, K. Kitayama and Y. Tamura: "Optical outer-product learning in a neural network using optically stimulable phosphor," *Opt. Lett.*, **15** (1990) 860-862.
 - 8) R. L. Lippmann: "An introduction to computing with neural nets," *IEEE Trans. Acoust. Speech Signal Process.*, **4** (1987) 4-22.
 - 9) 稲葉則夫: "ニューラル・ネットをパターン認識, 信号処理, 知識処理に使う", 日経エレクトロニクス, 8月10日号, No. 427 (1987) 115-124.
 - 10) D. E. Rumelhart, J. L. McClell and the PDP Research Group: *Parallel Distributed Processing* (MIT Press, Cambridge, 1986) p. 329.