

상용 LCTV의 편광 특성을 이용한 Perceptron 학습 모델의 광학적 구현

(Optical Implementation of Perceptron Learning Model using the Polarization Property of Commercial LCTV)

韓鍾旭*, 龍相淳*, 金東勳*, 金城培*, 朴一鍾**, 金恩洙**

(Jong Wook Han, Sang Soon Yong, Dong Hoon Kim, Sung Bae Kim,
Ihl Jong Park, and Eun Soo Kim)

要 約

본 논문에서는 상용 LCTV 공간 광 변조기를 이용하여 아라비아 숫자의 짝·홀수를 판별할 수 있는 단층 perceptron을 광학적으로 구현하였다.

상용 LCTV를 이용한 perceptron의 실제 광학적 구현에서 문제가 되는 낮은 gray 레벨을 해결하는 방법으로 perceptron 연결 강도에 비선형 양자화방법을 도입한 새로운 모델을 제시하여, 컴퓨터 시뮬레이션을 통해 원래모델에 비해 훨씬 빠른 수렴속도와 적은 gray레벨로 perceptron의 광학적 구현을 가능케하였다. 또한 perceptron의 연결강도에서 나타나는 음과 양의값 처리는 상용 LCTV 자체의 편광 특성인 polarization encoding 방법을 이용함으로써 비선형 양자화된 새로운 단층 perceptron 학습모델의 광학적 구현을 실현하였다.

Abstract

In this paper, optical implementation of single layer perceptron to discriminate the even and odd numbers using commercial LCTV spatial light modulator is described.

In order to overcome the low dynamic range of gray levels of LCTV, nonlinear quantized perceptron model is introduced, which is analyzed to have faster convergent time with small gray levels through the computer simulation. And the analog weights containing positive and negative values of single layer perceptron is represented by using the polarization-based encoding method. Finally, optical implementation of the nonlinear quantized perceptron learning model based on polarization property of the commercial LCTV is proposed and some experimental results are given.

I. 서 론

*準會員, **正會員, 光云大學校 電子工學科
(Dept. of Elec. Eng., Kwangwoon Univ.)
接受日字: 1990年 6月 26日

신경 회로망은 기존 디지털 컴퓨터 구조와는 달리 비교적 간단한 정보처리소자인 수 많은 신경세포(neuron)들이 상호 고밀도로 연결된 구조를 갖는데

이런 구조적 차이에 의해 신경 회로망의 방대한 계산 및 정보처리 능력이 나타나며, 특히 연상, 학습, 최적화 및 fault tolerance 등과 같은 collective한 특성을 이용, 지금까지 알고리즘이 알려지지 않았거나 계산이 방대한 random한 문제에 이를 응용하고자 많은 연구가 이루어지고 있다.^{1,2)}

신경 회로망에 대한 연구는 1943년 McCulloch & Pitts에 의해 처음으로 인간의 두뇌를 하나의 컴퓨터 시스템으로 해석한 이후, Rosenblatt의 Perceptron, Widrow의 Adaline 등과 같은 고전적 신경 회로망 모델들이 이미 1960년 부터 이루어지기 시작했으며, 1982년 Hopfield가 신경회로망의 연상기억에 관한 2진 모델로서 Hopfield 모델을 제시함으로써 신경회로망에 대한 실질적인 연구가 활발하게 이루어지게 되었다.³⁾

Rosenblatt에 의해 제안된 단층 perceptron은 임의의 입력패턴을 구별하여 그 패턴이 어떤 class에 속하는 가를 분류하는 것으로 실제 출력이 기대출력과 다른 경우에 perceptron의 학습법칙에 따라 입력과 출력간에 연결 강도 값을 반복 수정함으로써, 최종적으로 모든 입력 패턴을 올바르게 식별할 수 있는 학습이 가능한 패턴 분류기이다.⁴⁾

단층 perceptron은 1989년 J. H. Hong⁵⁾등이 체적홀로그래프를 이용하고, K. M. Johnson⁶⁾등은 상용 LCTV를 이용하여, 각각 광학적으로 구현하였으나 상용 LCTV를 이용한 perceptron의 광학적 구현의 경우, 낮은 gray 레벨의 한계로 실질적인 응용이 크게 제한되고 있다.

한편, 같은해 A. V. Lehmen⁷⁾ 등은 광학적 구현을 위한 모델로서 기존의 perceptron 연결강도를 선형 양자화시켜주는 방법을 제안하였으나 선형적으로 양자화할 경우 local minimum에 빠져 수렴하지 못하는 경우가 생길 수 있으며, 또한 상용 LCTV 자체의 투과특성이 비선형이므로 선형양자화 방법에는 여러 가지 문제점을 가지고 있다.⁸⁾

따라서, 본 논문에서는 더욱 효율적인 광학적 구현 및 학습 수렴성을 얻을 수 있는 비선형 양자화 방법을 새로이 제안하여 새로운 단층 perceptron의 광학적 구현시스템을 실현하고자 한다. 즉, 범용성있는 새로운 공간 광변조기로서 상용 LCTV를 perceptron의 2차원 패턴 입력 장치 및 연결 소자로 사용하고, 연결 강도에서 나타나는 음과 양의 값처리는 LCTV의 편광상태를 이용한 polarization encoding 방식을 이용하였으며, 상용 LCTV의 제한된 gray레벨의 한계를 극복하는 방법으로 비선형 양자화 방법 도입한 새로운 perceptron 모델에 근거한 광 패턴

인식 시스템에 대한 컴퓨터 시뮬레이션 및 실험결과에 대해 논하고자 한다.

II. 단층 Perceptron 모델

Rosenblatt에 의해 제안된 perceptron은 입력패턴들을 두개의 class 중에서 어느 한 class로 분류하는 기능을 가진 feed-forward 연결구조의 간단한 패턴 분류기이다. Perceptron의 각 입력은 입·출력 단자간의 연결강도에 의해서 출력단과 연결되는데, 그림 1과 같이 출력단자에 대한 입력은 적절하게 가중치가 부여된 모든 입력의 합이 된다.⁴⁾




그림 1. 단층 perceptron의 기본 모델
Fig. 1. Basic model of single layer perceptron.

이 단층 perceptron은 입력패턴에 대한 실제출력이 기대출력과 다를 경우에 두 출력간의 차를 피드백시켜 최종적으로 그 오차가 0이 될때까지 반복적으로 연결강도를 보정하는 학습법칙을 가지고 있다.

학습을 시킬 입력 패턴을 2진벡터 $X^t = \{x_1, x_2, \dots, x_{n+1}\}$ 연결강도를 $W^t = \{w_1, w_2, \dots, w_{n+1}\}$ 이라고 하면 단층 perceptron의 출력 Y는 활성 함수 (activation function) 가 hard limiting 함수이므로

$$Y = \text{Th}[W^t X] = \begin{cases} 1 & \text{if } W^t X > 0 \\ 0 & \text{if } W^t X < 0 \end{cases} \quad (1)$$

와 같다. 윗식에서 t는 transpose를, Th는 thresholding을 의미한다.

입력패턴을 두개의 class ω_1, ω_2 로 분류한다면, 입력패턴이 ω_1 일때는 $Y = +1$, ω_2 일때는 $Y = 0$ 의 출력을 갖게 된다. 만일 학습시킬 입력패턴이 m개인 입력행렬 x에 대한 기대출력을 $T^t = \{t_1, t_2, \dots, t_m\}$ 이라고 하면 기대출력과 실제출력이 다를 경우 perceptron 학습법칙은 m번째 패턴에 대한 k번째 반복과정에서 다음식과 같이 주어진다.

$$W_m(k+1) = W_m(k) + \alpha [T_m - Y_m(k)] X_m(k) \text{ for all } m \quad (2)$$

여기서 α 는 학습속도로 $0 < \alpha \leq 1$ 의 값이 된다.

$T_m - Y_m(k)$ 값은 기대출력과 실제출력간의 차이 오차량이 되며 이 양이 0이 될때까지 연결강도를 식(2)와 같이 반복 보정하여 주게 된다.⁶⁾ 기대출력이나 실제출력은 +1 또는 0이 되므로 식(2)는 식(3)과 같이 표현될 수 있으며 이하에서는 수식적 편리를 위해 m 을 생략하였다.

$W(1)$ 은 random한 초기의 연결강도가 되며, k 번째 학습 단계에서 $X(k) \in \omega_1$ 이면 $W^t(k) X(k) > 0$, $X(k) \in \omega_2$ 이면 $W^t(k) X(k) < 0$ 일때

$$\begin{aligned} W(k+1) &= W(k) + \alpha X(k), \text{ if } X(k) \in \omega_1 \text{ and } W^t(k) X(k) \leq 0 \\ W(k+1) &= W(k) - \alpha X(k), \text{ if } X(k) \in \omega_2 \text{ and } W^t(k) X(k) \geq 0 \\ W(k+1) &= W(k) \quad , \text{ otherwise} \end{aligned} \quad (3)$$

이 된다.

식(3)은 기대출력과 실제 출력이 다를 경우 연결강도인 W 를 반복적으로 오차에 비례하여 변환시켜 최종적으로 안정된 W 를 구하는 perceptron의 학습법칙을 표현한 것이다. 식(3)의 마지막식은 오차가 0이 되어 학습을 통해 각각의 입력 벡터에 대한 기대출력을 얻을 수 있는 perceptron의 최종 연결강도를 의미하는 것이다.

III. Perceptron 연결 강도의 비선형 양자화

일반적으로 상용 LCTV가 가질 수 있는 최대의 gray 레벨수가 약 50레벨 정도로 제한되므로 기존의 perceptron 모델을 상용 LCTV를 이용하여 광학적으로 실현하는데는 문제가 있다.^{6,10)}

1989년 Lehmen은 이러한 문제점을 해결하기 위해 연결강도를 선형 양자화 시켜주는 방법을 제안하였으나¹¹⁾ 일반적으로 상용 LCTV는 컴퓨터 그래픽에 의한 gray 레벨과 각 편광성분간의 투과 특성곡선이 비선형적으로 나타나며, 또한 선형적으로 양자화할 경우 local minimum에 빠져 수렴하지 못할 경우가 생

길 수 있으므로, 본 논문에서는 더욱 효율적이며 완전한 학습 수렴성을 얻을 수 있는 비선형적 양자화 방법을 새로이 제안하여 gray 레벨을 줄여 줌으로써 상용 LCTV를 이용한 perceptron의 광학적 구현을 가능하게 하였다.⁸⁾ 즉, 양자화 레벨을 $Q_n(n=0, 1, 2, \dots)$ 이라고 하면 식(3)의 오차량이 감소하는 과정에서 나온 연결강도 값은 다음식과 같이 쓸 수 있다. ($j=0, 1, 2, \dots, n-1$)

$$\begin{aligned} Q_j &\leq |W(k+1)| < Q_{j+1} \\ W(k+1) &= \begin{cases} Q_j, & \text{if } 0 \leq W(k+1) < Q_n \\ -Q_j, & \text{if } -Q_n < W(k+1) < 0 \\ Q_n, & \text{if } W(k+1) \geq Q_n \\ -Q_n, & \text{if } W(k+1) \leq -Q_n \end{cases} \quad (4) \end{aligned}$$

컴퓨터 시뮬레이션을 통해 기존 perceptron 모델을 학습시킨 후, 학습과정에서 나오는 연결강도 값들의 분포를 분석하여 비선형 양자화 레벨을 정해 식(4)와 같이 양자화 시켜주게 된다. 즉, k 번째 반복 과정에서 수정된 연결강도의 절대값 $|W(k+1)|$ 이 $-Q_n, \dots, 0, \dots, Q_n$ 사이의 양자화 레벨인 Q_j, Q_{j+1} 의 사이에 존재할 때 $W(k+1)$ 이 양수이면 $W(k+1) = Q_j$ 가 되고 음수이면 $W(k+1) = -Q_j$ 가 된다. 만일 $|W(k+1)|$ 이 최대 양자화 레벨인 Q_n 보다 크다면, $W(k+1)$ 이 양수이면 $W(k+1) = Q_n$ 이 되고, 음수이면 $W(k+1) = -Q_n$ 이 된다.

이와 같이 연결강도를 인위적으로 일정한 값을 갖게 하여 연결강도가 가질 수 있는 최대치를 $\pm Q_n$ 으로 제한하므로, gray레벨 값은 최대 $2n+1$ 개로 정의할 수 있다.

그림 2와 같은 $0 \dots 9$ 까지의 2차원 입력패턴에 대해 짝수일 경우는 +1, 홀수일 경우는 0의 기대출력을 내는 단층 perceptron을 구현하기 위한 비선형 양자화 레벨을 찾기 위해 컴퓨터 시뮬레이션 하였다.

컴퓨터 시뮬레이션을 통해 가장 알맞은 gray 레벨수를 찾아내는데에는 초기의 연결강도 값, 학습시키는 입력패턴의 순서, 학습 속도등이 중요한 영향을 미치게 된다.

일반적으로 perceptron에서 결정되는 최종 연결강도 값은 입력 패턴의 class를 분류하는 절대해가 아니라 일반해 중의 하나이므로 이 세가지 변수에 따라서 여러 일반해가 나올수가 있으므로 입력패턴의 순서는 그림 2와 같이 고정시키고 학습속도와 초기 연결강도 값만을 변화시켜며 효율적인 양자화레벨을 찾기 위한 컴퓨터 시뮬레이션을 하였다.

그림 3은 시뮬레이션을 통해 얻은 몇개의 일반해로서 수렴속도와 전체 자승오차 합(total sum of sq-






그림 2. 5×4의 2차원 배열의 입력패턴
Fig. 2. 5×4 input patterns in two-dimensional array.




$\alpha=0.5$, gray 레벨 (95 \Rightarrow 19)
양자화 레벨 (0, ± 0.1 , ± 0.2 , ± 0.6 , ± 0.7 , +1.2)

(a)




$\alpha=0.6$, gray 레벨 (120 \Rightarrow 18)
양자화 레벨 (0, ± 0.1 , +0.2, ± 0.8 , ± 0.9)

(b)



$\alpha=0.7$, gray 레벨 (168 \Rightarrow 20)
양자화 레벨 (0, ± 0.1 , ± 0.3 , ± 0.4 , +1.0)

(c)



$\alpha=0.8$, gray 레벨 (144 \Rightarrow 26)
양자화 레벨 (0, ± 0.3 , ± 1.1 , ± 1.3)

(d)

그림 3. 비선형 양자화 레벨에 따른 perceptron의 학습곡선

Fig. 3. Perceptron learning curves dependent on nonlinear quantized levels.

uared error)와의 관계를 나타낸 그래프이다.

초기 연결강도 값은 그림 3의 (a)와 (d)에서는 1010101010101010을 (b)의 경우에는 00000000000000000000을, 그리고 (c)에서는 10101100010101101010을 각각 random하게 주었다. 여기서 α 는 학습속도를 말한다.

그림 3에 나타난 컴퓨터 시뮬레이션 결과와 같이 비선형 양자화 방법에 의해 수정된 모델은 원래모델에 비해 훨씬 빠른 수렴 속도를 갖을뿐만 아니라 적은 gray레벨을 갖게 되므로, 현재 낮은 gray 레벨의 한계점으로 그 응용이 크게 제한되고 있는 상용

LCTV를 이용한 perceptron의 광학적 구현이 가능하게 된다. 특히 (c)의 경우는 비선형 양자화 레벨의 최대값이 1이 되어 연결강도 값을 정규화시킨 개념으로 볼 수 있기 때문에 가장 실험하기에 적합한 결과이므로 이하에서는 그림 3의 (c)를 예를 들어 설명하겠다.

그림 4는 원래 모델과 양자화 방법에 의해 수정된 모델을 비교한 것이다.

그림 4에서와 같이 원래 모델은 gray 레벨수가 168개이나 비선형 양자화 방법을 사용했을 경우는 20개로 1/8이상 적어졌으며, 수렴 속도 또한 23 step에서

| | 원래 모델 | 수정된 모델 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|--------------------|--|--|------|-----|---|------|-----|-----|------|------|-----|-----|-----|------|-----|-----|------|------|-----|-----|---|--|------|------|-----|------|------|-----|-----|------|------|-----|------|-----|-----|-----|-----|------|-----|-----|-----|------|
| 최초의 연결강도 | 10101100010101101010 | 10101100010101101010 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 학습 속도 (α) | 0.7 | 0.7 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 반복 횟수 | 23 | 5 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 양자와 어댑 | | 0, ± 0.1 , ± 0.3 , ± 0.4 , ± 1.0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| Gray 레벨 갯수 | 168 | 20 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 최종 연결강도 | <table border="1"> <tr><td>-4.6</td><td>0</td><td>1.0</td><td>0</td></tr> <tr><td>-1.1</td><td>1.0</td><td>1.4</td><td>-0.7</td></tr> <tr><td>-4.9</td><td>1.7</td><td>0.7</td><td>2.4</td></tr> <tr><td>11.2</td><td>1.0</td><td>2.4</td><td>-0.7</td></tr> <tr><td>-3.9</td><td>2.1</td><td>4.5</td><td>0</td></tr> </table> | -4.6 | 0 | 1.0 | 0 | -1.1 | 1.0 | 1.4 | -0.7 | -4.9 | 1.7 | 0.7 | 2.4 | 11.2 | 1.0 | 2.4 | -0.7 | -3.9 | 2.1 | 4.5 | 0 | <table border="1"> <tr><td>-1.0</td><td>-0.3</td><td>0.3</td><td>-0.3</td></tr> <tr><td>-0.3</td><td>1.0</td><td>1.0</td><td>-0.3</td></tr> <tr><td>-1.0</td><td>0.3</td><td>-0.1</td><td>0.3</td></tr> <tr><td>1.0</td><td>1.0</td><td>1.0</td><td>-0.3</td></tr> <tr><td>0.3</td><td>1.0</td><td>1.0</td><td>-0.3</td></tr> </table> | -1.0 | -0.3 | 0.3 | -0.3 | -0.3 | 1.0 | 1.0 | -0.3 | -1.0 | 0.3 | -0.1 | 0.3 | 1.0 | 1.0 | 1.0 | -0.3 | 0.3 | 1.0 | 1.0 | -0.3 |
| -4.6 | 0 | 1.0 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1.1 | 1.0 | 1.4 | -0.7 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -4.9 | 1.7 | 0.7 | 2.4 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 11.2 | 1.0 | 2.4 | -0.7 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -3.9 | 2.1 | 4.5 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1.0 | -0.3 | 0.3 | -0.3 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -0.3 | 1.0 | 1.0 | -0.3 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1.0 | 0.3 | -0.1 | 0.3 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.0 | 1.0 | 1.0 | -0.3 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 0.3 | 1.0 | 1.0 | -0.3 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |

그림 4. 원래 및 수정된 perceptron 모델의 비교
Fig. 4. Comparison between original and modified perceptron model.

5 step으로 낮아짐으로 상용 LCTV를 이용한 perceptron의 광학적 구현이 가능함을 알 수 있다.

IV. 상용 LCTV를 이용한 Polarization Encoding

본 논문에서는 perceptron의 입력 및 연결강도 소자로 실시간 처리가 가능하고^[11] 저렴한 twisted nematic 액정 구조의 상용 LCTV를 이용 하였으며, 신경 회로망 모델의 광학적 구현에서 큰 문제가 되었던 음과 양의 값 처리는 상용 LCTV 자체의 편광현상을 이용하여 해결하였다.^[6,12] 즉, 수직성분을 양, 수평 성분을 음의 값으로 하여 LCTV에 인가해 주는 전압의 크기로 양과 음의 값을 표현하여 주었다.

그림 5는 입력패턴이 실린 LCTV1과 입·출력간의 연결강도를 표시하는 LCTV2에 대한 설명 그림이다. LCTV1에서 5x4 2차원 배열인 0~9까지의 2진입력 패턴이 컴퓨터에 의해 차례로 주어지는데, 1 일때는 최대전압을 인가하고 0일때는 전압을 가해주지 않으므로써 뒷면 편광기를 통과한 빛은 0과 1로 표현된




그림 5. (a) 입력패턴 및 (b) 연결강도의 곱을 위한 polarization encoding 방법
Fig. 5. Polarization encoding method for (a) input pattern and, (b) interconnection multiplication.

다. 입·출력단자 사이의 연결강도를 나타내는 LCTV2는 앞에서 설명했듯이 비선형 양자화레벨인 -1.0, ... +1.0사이의 실수 값들로 표현된다. 즉 LCTV 2에 최대전압을 걸어 액정분자들이 광의 전파방향에 평행하게 되면 입사광은 회전없이 통과되어 연결강도는 +1이되고, 전압을 가하지 않으면 입사광은 액정분자들의 배열을 따라 90° 회전하여 -1이 된다. 만일 연결강도가 0이라면 최대전압의 반을 인가하여 45° 회전시킴으로 수직·수평성분의 크기가 같게된다. 그러므로 인가해주는 전압의 크기로 수직 편광성분의 회전정도를 조정하여 -1.0...+1.0사이의 실수값들을 표현해준다.

V. 상용 LCTV를 이용한 Perceptron의 광학적 구현 시스템

1. 상용 LCTV의 편광 특성 실험

본 논문에서 사용한 상용 LCTV는 CASIO TV-200으로 5.4cmx4.4cm의 화면 크기에 370μm x 370μm의 화소가 총 146x120으로 구성되어 있다. 이론적으로 전압이 인가되지 않았을때 LCTV를 통과하는 수직 편광 성분의 회전각도에 대해서 전압을 인가했을 때의 편광 성분의 회전 각도는 90°이나, 일반적으로 TV에서 필요로 되는 30Hz의 frame rate를 얻기 위해 90° 이하의 회전 각도를 갖게 된다.^[12,13] 본 논문에서 사용한 LCTV의 경우는 실험결과 편광 회전각도가 최대 68°가 되었다.

그림 6은 본 실험에서 사용한 상용 LCTV의 바이어스 전압에 대한 수직 편광 성분의 회전각도를 나타낸 것이다.

LCTV를 편광변조기로 사용하기 위해서는 먼저





그림 6. 바이어스 전압에 대한 수직 편광 성분의 회전 각도
Fig. 6. Rotation angle of vertical polarized component versus bias voltage.

중간 gray 레벨이 인가되었을때 수직·수평성분이 같은 contrast 상태를 찾아야 한다. 그런데 실제로 contrast 상태를 직접 측정하기는 어렵기 때문에 LCTV에 부착된 contrast 단자의 가변저항을 이용하여 그 가변저항에 걸리는 바이어스 전압과 각 편광성분의 투과도간의 변화관계를 구했다. 본 실험에서 사용한 LCTV의 최대 바이어스 전압은 2.4V로 나타났다. 그림7의(a)의 중간 gray 레벨을 입력으로 사용하여 (b)의 그래프를 구함으로서 polarization encoding을 위한 최적의 동작점을 구할 수 있었다.

그림 7의 (a)에서 보듯이 바이어스 전압이 1V에서 수직성분과 수평성분이 같게된다. 이러한 최적의 동작상태로 LCTV의 contrast를 고정시킨후 그래픽 프로그램을 사용하여 gray 레벨 0부터 255까지 인가해 줌으로서 gray 레벨에 따른 편광 성분의 값을 구하



(a)



(b)

그림 7. (a) 최적의 동작점을 찾기 위한 입력 gray 레벨
(b) 바이어스 전압에 따른 수직·수평 성분의 투과도

Fig. 7. (a) Input gray level for searching of optimum operating point,
(b) Transmittance of vertically & horizontally polarized components dependent on bias voltage.




그림 8. Gray 레벨에 따른 수직·수평 성분의 투과도
Fig. 8. Transmittance of vertically & horizontally polarized components dependent on gray levels.

였다.

그림 8은 gray 레벨에 따른 각 편광 성분의 투과도를 나타낸 것이다. 그림 8에서 보면 실질적으로 상용 LCTV상에 약 40~50개의 gray 레벨 표현은 충분히 가능하므로 이 그래프를 이용하여 비선형 양자화 값에 적당한 gray 레벨 값을 부여함으로써 그 값에 따른 편광 성분의 값들로 각 임·출력간의 연결 강도 값들을 표현해 주었다. 실제로 실험에 필요한 gray 레벨 값은 30개 이하이므로 적절한 값의 표현이 가능하였다.

2. 실험 및 결과 고찰

앞에서 설명한 polarization encoding 방법과 상용 LCTV의 특성을 이용하여 단층 perceptron의 광학적 구현 시스템을 다음 그림 9와 같이 구성하였다.

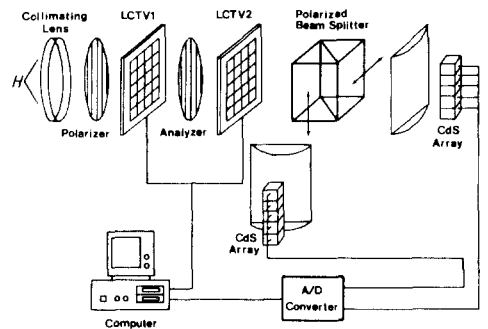


그림 9. 단층 Perceptron의 광학적 구현 시스템도
Fig. 9. System diagram of optical implementation of single layer perceptron.

LCTV1에는 5×4 2차원 배열인 0...9까지의 2진수 입력패턴이 컴퓨터에 의해서 차례로 주어진다. 입·출력 단자 사이의 연결강도 값은 양쪽의 편광기를 제거한 LCTV2에 비선형 양자화레벨의 실수값들로 표현된다. 그러므로 LCTV1을 통과한 수직성분은 LCTV2의 각 화소에 인가되는 gray 레벨 값만큼 선형적으로 회전하여 그 크기 만큼의 수평성분과 수직성분을 갖게된다. 이 과정의 수행으로 식(1)에 나타난 벡터-벡터 곱이 광학적으로 이루어지는 것이다. LCTV2에서 나온 결과는 편광된 빔 분할기 (beam splitter)를 통해서 수직·수평 성분으로 따라 분리되어 각각 광 검출기인 CdS로 받아 A/D 변환기를 통해 비교기로 비교함으로써 그 값이 양수인지 음수인지를 측정한다. 그 결과는 다시 컴퓨터로 피드백되어 식(3)의 perceptron 학습법칙에 따른 프로그램에 의해 LCTV2의 연결강도 값을 변화시켜 준다. 이런 과정을 모든 입력패턴의 실제출력이 기대출력과 같을때까지 반복하여 수행함으로써 완전한 입·출력 간의 연결강도를 구하게 된다.

그림10은 그림 3의 결과중에서 학습 속도 $\alpha=0.7$ 이고 비선형 양자화 레벨이 $\pm 0.1, \pm 0.3, \pm 0.4, \pm 1.0$ 인 (c)의 경우로, 아라비아 숫자의 짝·홀수를 판별할 수 있게 학습이 끝난 후 최종적으로 얻은 연결 강도 값이다.






그림10. 최종 연결강도 값
 (a) 컴퓨터 시뮬레이션 (b) 실험결과
 Fig. 10. Final interconnection values.
 (a) computer simulation and,
 (b) experimental results.

그림11은 본 논문에서 제안한 비선형 양자화방법에 의해 수정된 모델을 컴퓨터 시뮬레이션 한 경우와 실제로 실험한 경우를 비교한 것이다.


그림11과 같이 컴퓨터 시뮬레이션 및 실험 결과를 비교하면 각 학습과정에서의 전체 자승 오차만 다를 뿐 수렴 속도는 서로 동일함을 알 수 있으며, 상용




$\alpha=0.5$, gray 레벨 (95 \Rightarrow 19)
 양자화 레벨 (0, $\pm 0.1 \pm 0.2, \pm 0.6, \pm 0.7, \pm 1.2$)



$\alpha=0.6$, gray 레벨 (120 \Rightarrow 18)
 양자화 레벨 (0, $\pm 0.1, \pm 0.2, \pm 0.8, \pm 0.9$)



$\alpha=0.7$, gray 레벨 (168 \Rightarrow 20)
 양자화 레벨 (0, $\pm 0.1, \pm 0.3, \pm 0.4, \pm 1.0$)



$\alpha=0.8$, gray 레벨 (144 \Rightarrow 26)
 양자화 레벨 (0, $\pm 0.3, \pm 1.1, \pm 1.3$)

그림11. 학습곡선의 컴퓨터 시뮬레이션 및 실험 결과의 비교
 Fig. 11. Comparison between computer simulation and experimental results of perceptron learning curves.

LCTV를 이용한 광학적 구현이 가능함을 알 수 있다.

그림12는 그림 3의 (c)에 의해 학습된 연결 강도에 입의의 아라비아 숫자 패턴이 입력 되었을 경우 짝·홀수를 분류하는 단층 perceptron의 실제 광학적 실험 결과를 나타낸 것이다.

2차원 입력패턴은 상용 LCTV 공간 광 변조기를 이용하여 입력시켰으며, perceptron 출력은 피이드백 회로에 첨가한 3×3 LED 배열을 이용하여 홀수일때는 "0", 짝수일때는 "1"로 나타나게 하였다.

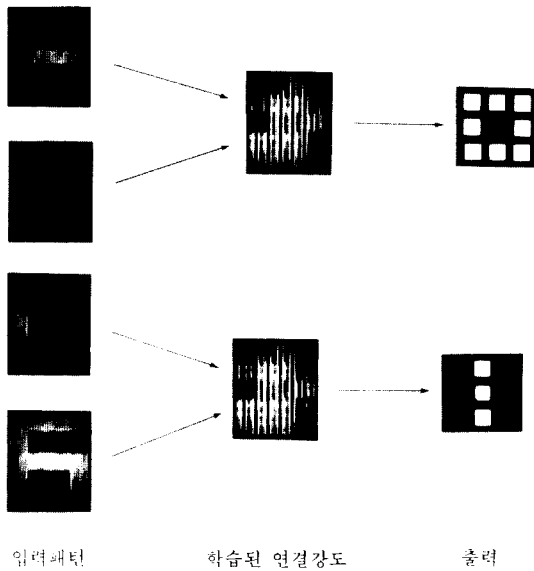


그림12. 실험 결과
Fig. 12. Experimental results.

V. 결 론

본 논문에서는 상용 LCTV 공간 광 변조기를 이용하여 아라비아 숫자의 짝·홀수를 판별할 수 있는 단층 perceptron을 광학적으로 구현하였다.

상용 LCTV를 이용한 perceptron의 광학적 구현에서 문제가 되는 낮은 gray 레벨의 한계를 극복하는 방법으로 perceptron 연결강도에 비선형 양자화 방법을 도입한 새로운 모델을 제시하였으며, 컴퓨터 시뮬레이션을 통해 원래 모델에 비해 훨씬 빠른 수렴속도와 적은 gray 레벨로 그 실현이 가능함을 알 수 있었다. 또한 perceptron의 연결강도에서 나타나는 유과 양의 값 처리는 상용 LCTV 자체의 편광특성인 polarization encoding 방법을 이용하여 비선형

양자화된 새로운 단층 perceptron 학습 모델의 광학적 구현을 실현하였다.

따라서 본 논문에서 실현한 perceptron의 광학적 구현시스템은 앞으로 보다 복잡한 패턴 분류를 위한 다층 perceptron의 실현이나 패턴 인식, machine vision 등과 같은 분야에도 그 응용이 기대된다.

參 考 文 獻

- [1] Y.S. Abu-Mostafa and D. Psaltis, "Optical neural computers," *Sci. Am.*, vol. 29, pp. 88-95, 1987.
- [2] Eun Soo Kim, "Optical implementation of neural network model," *KITE Computer Technology*, vol. 6, no. 1, pp. 77-85, 1989.
- [3] D.E. Rumelhart, G.E. Hinton and J.L. McClelland, Eds., *Parallel Distributed Processing*, MIT Press, vol. 1, 1986.
- [4] M. Minsky and S. Papert, *Perceptrons*, MIT Press, 1988.
- [5] J.H. Hong and P. Yeh, "Trainable optical network for pattern recognition," *OSA Topical Meeting on Optical Computing*, 1989. *Technical Digest Series*, vol. 9, pp. 307-310, 1989.
- [6] M. Krantzdorf and K.M. Johnson, "Optical connectionist machine with polarization based bipolar weight values," *Opt. Eng.*, vol. 28, no. 8, pp. 844-848, 1989.
- [7] A. Von Lehmen and J.S. Patel, "Influence of interconnection weight discretization and noise in an optoelectronic neural network," *Opt. Lett.*, vol. 14, no. 17, pp. 928-930, 1989.
- [8] Jong Wook Han and Eun Soo Kim, "Optical implementation of nonlinear quantized perceptron," *Proc. of KITE Conference*, vol. 13, no. 1, pp. 59-61, 1990.
- [9] Y.H. Pao, *Adaptive Pattern Recognition and Neural Network*, Addison-Wesley Publishing Co., 1989.
- [10] K.M. Johnson and Garret Moddel, "Motivations for using ferroelectric liquid crystal spatial light modulators in neurocomputing," *Appl. Opt.*, vol. 28, no. 22, pp. 4888-4899, 1989.
- [11] In Ho Park and Eun Soo Kim, "Optical implementation of real-time two-dimensional hopfield neural network model using multifocus hololens," *KITE*, vol. 26, no. 10,


pp. 1576-1583, 1989.
 [12] H.K. Liu and T.H. Chao, "Liquid crystal television spatial light modulator," Appl. Opt., vol. 28, no. 22, pp. 4772-4280, 1989.

[13] N. Collings and I. Underwood, "Evolutionary development of advanced liquid crystal spatial light modulators," Appl. Opt., vol. 28, no. 22, pp. 4740-4743, 1989.


著 者 紹 介

韓 鍾 旭 (準會員) 第27卷 第7號 參照
 현재 광운대학교 대학원 전자공학과 석사과정 재학중

龍 相 淳 (準會員) 第27卷 第7號 參照
 현재 광운대학교 대학원 전자공학과 석사과정 재학중



●
 金 東 勳 (準會員)
 1968年 1月 19日生. 1990年 2月 광운대학교 전자공학과 졸업, 공학사 취득. 1990年~현재 광운대학교 대학원 석사과정 재학중. 주 관심분야는 Optical neural network, Optical Learning, 광패턴인식 등임.



●
 金 城 培 (準會員)
 1967年 3月 17日生. 1990年 2月 광운대학교 전자공학과 졸업, 공학사 취득. 1990年~현재 광운대학교 대학원 석사과정 재학중. 주 관심분야는 광정보처리, Optical neural network Optical Computing 등임.



朴 一 鍾 (正會員)
 1961年 4月 15日生. 1984年 2月 광운대학교 전자공학과 졸업, 공학사 취득, 1986年 2月 광운대학교 대학원 전자공학과 졸업, 석사학위 취득, 1988年~현재 광운대학교 대학원 박사과정 재학중. 주 관심분야는 Learning Algorithm, Optical neural network, 광정보처리, 광패턴인식 등임.

●
 金 恩 洙 (正會員) 第27卷 第7號 參照
 현재 광운대학교 전자공학과 부교수