

홀로그램 렌즈 배열을 이용한 단층 인식자의 광학적 구현

신상길\*, 신상영, 이수영  
한국과학기술원 전기 및 전자공학과

Optical Implementation of Single-Layer Perceptron  
Using Holographic Lenslet Arrays

Sang-Gil Shin, Sang-Yung Shin, and Soo-Young Lee  
Department of Electrical Engineering, KAIST

Abstract

A single-layer Perceptron with  $4 \times 4$  input neurons and one output neuron is optically implemented. Holographic lenslet arrays are used for the programmable optical interconnection topology. The hologram is bleached in order to increase the diffraction efficiency. It is shown that the performance of Perceptron depends on the learning rate, the inertia rate, and the correlation of input patterns.

I. 서 론

신경회로망은 생물학적 두뇌의 병렬적이며, 분산적인 정보처리 능력을 흉내낸 회로망이다. 신경회로망의 특징은 높은 병렬처리 방식과 적용학습으로 요약된다. 즉, 신경소자간의 많은 상호연결에 의한 분산기억과 병렬처리에 의해 단시간내에 오차보정능력이 높은 신호처리를 할 수 있고, 학습법칙에 의해 스스로 새로운 것을 배워나갈 수 있다. 특히 신경회로망의 학습능력 또는 적용능력에 주안점을 둔 학습모델을 전기광학적으로 구현하려는 연구가 초보적 수준이지만 활발히 진행되고 있다[1,2].

신경간의 연결을 통한 정보처리의 가장 기본적인 형태는 행렬-벡터곱셈이다. 행렬-벡터곱셈을 광학적으로 구현하는 방법으로는 여러 가지가 보고되었다. 첫째로는 원통형 렌즈와 연결세기기를 저장한 공간광변조기를 이용한 스팸포드 행렬-벡터곱셈기가[4] 있다. 이는 연결세기를 변화시킬 수 있기 때문에 학습이 가능하지만, 고차원 행렬-행렬곱셈으로의 확장이 어렵다. 두 번째로는 고차원 연결세기를 훌로그램에 기록하여 행렬-행렬곱셈을 구현하는 방법이[5] 있다. 이 방법은 렌즈가 필요없으므로 시스템의 크기가 작아지는 잇점이 있으나, 연결세기를 변화시킬 수가 없으므로 학습이 불가능하다. 다음으로는 훌로그램 렌즈 배열을 이용한 방법이[2] 있다. 이 방법은 고차원 연결세기기를 공간 광변조기에 저장하고, 훌로그램 렌즈 배열과 렌즈를 이용하여 연결 구조를 구성하는 방법이다. 이 방법은 고차원 행렬-행렬곱셈도 구현할 수 있으며, 연결세기도 변화 시킬 수 있으므로 학습이 가능한 신경회로 모델의 구현에 사용될 수 있다.

이 논문에서는 신경회로망의 광학적 구현에 있어서 중요한 행렬-벡터곱셈 또는 맨서-행렬곱셈을 훌로그램 렌즈 배열(Holographic lenslet array: HLA)을 이용하여 구현하였다. 이러한 HLA를 이용하여 단층 인식자(Perceptron) 학습모델을[3] 구현하였다.

논문의 내용을 간단히 살펴 보면 다음과 같다. 제 1장에서는 훌로그램 렌즈 배열을 이용한 상호연결방법,

홀로그램 제작 및 표백과정, 상호연결 실험 및 결과에 대하여 서술한다. 제 2장에서는 단층 인식자의 학습이론을 살펴보고, 이를 훌로그램 렌즈 배열을 이용하여 구현하였다. 또한 이를 학습시킨 결과를 보였다. 제 3장에서는 실험 결과에 대한 고찰이 있고, 제 4장에서는 이 논문에 대한 전체적인 결론을 맺는다.

II. 훌로그램 렌즈 배열

신경회로망의 학습능력(또는 적용능력)은 신경간의 연결세기를 변화시킴으로서 가능하다. 이를 구현함에 있어서 행렬-벡터곱셈이 중요한 역할을 한다. 행렬-벡터곱셈을 구현한 예로는 원통형 렌즈와 공간광변조기(Spatial Light Modulator: SLM)를 이용한 스팸포드 행렬-벡터곱셈기[4], 훌로그램을 이용한 방법[5], 그리고 HLA를 이용한 방법[2] 등이 있다. 그런데 2차원적으로 배열된 신경돌사이의 상호연결을 구현하기 위해서는 HLA를 이용하는 것이 편리하다. 즉, 상호연결 구조를 위한 HLA와 상호연결세기를 저장하는 SLM을 사용하여 프로그램이 가능한 고차원 광학적 상호연결을 구현할 수 있다[2]. 이러한 상호연결 방법을 사용하여 맨서-행렬곱셈이 이루어짐을 실험적으로 보였다. 이 장에서는 HLA의 제작과정 및 원리를 대하여 서술한다.

먼저 4차원 텐서  $T_{ijkl}$ 과 행렬  $A_{kl}$ 의 광학적 곱셈(즉, 행렬  $A_{kl}$ 과  $C_{ij}$ 간의 상호연결, 여기서  $T_{ijkl}$ 은  $A_{kl}$ 에서부터  $C_{ij}$ 에로의 상호연결세기이다.)을 생각해 보자.

$$C_{ij} = \sum_{k,l} T_{ijkl} A_{kl} \quad (1)$$

여기서 행렬의 크기는  $N \times N$ 이며, 모든 요소의 값은 음이 아닌 양수이다. 프로그램이 가능한 맨서-행렬곱셈인 식 (1)은 HLA와 SLM을 사용하여 구현될 수 있다. 훌로그램의 원리를[10] 이용하여 하나의 훌로그램 렌즈를 맹면과 기준광(reference beam)과 기록하고자 하는 렌즈의 총 점에서 파져나오는 물체광(object beam)을 동시에 훌로그램 진판의 일부분에 흐려서 기록한다. 훌로그램 렌즈 배열을 얻기 위해서는 하나의 훌로그램 렌즈를 기록한 후, 훌로그램 진판을 X-Y 이동기를 이용하여 옆으로(또는 위로) 적당히 움직인 후, 계속하여 훌로그램 렌즈를 기록하면 얻을 수 있다(그림 1의 a) 참조). 그림 1의 a)에서 훌로그램 진판과 마스크를 서로 밀착 시켰다. HLA의 동작 원리는 그림 1의 b)와 같다. 즉, 기준광이 HLA에 비춰지면 각 훌로그램 렌즈는 1차 회절 광에 의해 렌즈의 역할을 한다. 그리하여 그림 1의 c)에서와 같이 렌즈 L1과 함께 HLA는 각 훌로그램 렌즈 앞에 놓여 있는 폐면물을 겹치게 할 수 있다. 식 (1)을 구현

하기 위해 4차원 연결세기 텐서를 2차원 행렬때문으로 고딩하였다. 이렇게 하면,  $T_{ijkl}$ 의  $kl$ 번째 요소는 행렬이 되며, 이 행렬요소에 대한 연결패턴을 HLA의  $kl$ 번째 휴로그램 렌즈 앞에 놓는다. 그런 후, 입력 행렬  $A_{ijl}$ 을 나타내는 입력  $N \times N$  SLM을 통과하도록 빛을 흘여 주면 식 (1)이 그림 1의 c)에서와 같이 영상이 겹치는 면에서 실현 된다. 이와 같이  $A_{ijl}$ 과  $C_{ijl}$  사이의 상호연결세기  $T_{ijkl}$ 을 저장하고 있는  $N \times N$  SLM을 번조시켜줌으로써 프로그램이 가능한 광학적 상호연결 방법이 실현된다. 이러한 상호연결 방법은 학습 가능한 신경회로망의 광학적 구현에 사용될 수 있다.

휴로그램 전판으로는 Agfa 8E75HD 전판을 사용하였으며, 광원으로는 5mW He-Ne 레이저를 사용했다. 휴로그램 기록 때의 물체범과 기준범의 빛의 세기 비율은 4 : 6이 되게 하였다. 만들어진 HLA는 1×4행렬형태이며, 각 휴로그램 렌즈의 크기는 가로 4mm, 세로 3.5mm, 각 휴로그램 펜즈의 사이 간격은 1mm이다. 휴로그램의 회절효율을 높이기 위하여 휴로그램 기록 후 표백을 하였다[6]. 표백 후의 휴로그램의 회절효율은 대략 65% 정도 얻을 수 있었다. 진조한 때 회절효율을 좋게하기 위해 질소가스로 휴로그램을 불어 급속 건조 시켰다.

### III. 단층 인식자의 구현

1958년 Rosenblatt은 생체지각계(biological sensory system)와 유사한 적용 신경회로모델, 즉 인식자(Perceptron)를 제안하였다[3].

그림 2에서와 같이 인식자는 3층으로 구성 되어 있는데, 제 1층(S층)은 단순히 강지기기를 의미하고, 이를 강지기로부터 발생되는 신호는 연상요소(association element)로 불리는 제 2층(A층)에서 합해진다. 제 3층(R층)은 반응요소(response element)로 여기서 적용학습이 적용된다. 인식자는 분류(classification)를 위한 모델로, 출력  $o$ 는 0이나 1만을 가진다.

그림 2에서와 같이 R층의 한 요소를  $o$ 라 하고, A층의 값을  $I_i$  ( $i=1, 2, \dots, N_A$ )라 하자. 그러면 인식자는 학습법칙 식 (2)를 따라

$$\begin{aligned} T_i[n+1] &= T_i[n] + \eta(t[n] - o[n]) \cdot I_i[n] \\ &= T_i[n] + \Delta T_i[n] \end{aligned} \quad (2)$$

출력  $o$ 를 지도출력값(desired output value or target value)  $t$ 로 반복 수렴시킨다. 식(2)에서  $n$ 은 반복 횟수이고,  $I_i[n]$ 과  $t[n]$ 은 각각  $n$ 번째 반복에서의 입력과 지도출력값을 의미한다. 그리고  $\eta$ 는 학습율이다. 실제 출력  $\hat{o}[n]$ 은

$$\hat{o}[n] = \sum_i T_i[n] I_i[n] \quad (3)$$

이며, 이를 식 (4)와 같이 문턱함수(thresholding function)로 이진화하여

$$\begin{cases} 0, & \sum_i T_i[n] I_i[n] < \theta \\ 1, & \sum_i T_i[n] I_i[n] \geq \theta \end{cases} \quad (4)$$

로 한다. 여기서  $\theta$ 는 문턱값이다.

이러한 학습법칙에 의한 단층 인식자는 선형 분리가 가능한 (linear separable) 문제에만 적용된다는 한계점이 드러났다[8]. 그러나, 이러한 문제점은 다층 인식자(multi-layer Perceptron)를 구성하여, 오류 역전파(error back-propagation) 학습규칙에 의해 학습시키면 해결된다[7].

이 논문에서는 2차원 입력 패턴 4개를 2가지 즉, 0군과 1군으로 분류할 수 있는 단층 인식자를 구현하였다. 2차원 입력 패턴들을 나타내는 입력 신경(소자) I의 요소를  $I_{ij}$  ( $i, j = 1, 2, 3, 4$ ), 각 입력 패턴에 대한 지도출력값을  $t$ , 문턱화된 출력값을  $o$ ,  $I_{ij}$ 와  $o$ 를 연결함에 있어서 연결세기값을  $T_{ij}$ 라하면 식 (2), (3), (4)는 다음과 같이 바뀌어진다.

$$\begin{aligned} T_{ij}[n+1] &= T_{ij}[n] + \eta(t[n] - o[n]) \cdot I_{ij}[n] \\ &= T_{ij}[n] + \Delta T_{ij}[n] \end{aligned} \quad (5)$$

$$\hat{o}[n] = \sum_{i,j} T_{ij}[n] I_{ij}[n] \quad (6)$$

$$\begin{cases} 0, & \hat{o}[n] < \theta \\ 1, & \hat{o}[n] \geq \theta \end{cases} \quad (7)$$

이기서  $t$ 와  $o$ 는 0 또는 1의 값만을 가지는 이진수이며,  $\eta$ 는 학습율이고,  $\hat{o}$ 은 실제 출력,  $o$ 는 문턱화된 출력이다. 학습속도를 빠르게 하면서 인식자의 출력이 안정한 두 상태(즉, 0 또는 1)사이를 전동하지 않게 하기 위해서 식 (5)에 판성항을 덧붙여서 다음 식 (8)과 같이 학습시켰다[7].

$$\begin{aligned} T_{ij}[n+1] &= T_{ij}[n] + \eta \cdot (t[n] - o[n]) \cdot I_{ij}[n] \\ &\quad + \alpha T_{ij}[n] \\ &= T_{ij}[n] + \Delta T_{ij}[n] \end{aligned} \quad (8)$$

여기서  $\alpha$ 는 판성율이다. 한가지 주의해야 할 것은 참고문헌 [7]에서 판성율에 끔해진 것이  $\Delta T_{ij}[n]$ 이나 식 (8)에서는  $T_{ij}[n]$ 이다.

식 (8)에서  $\Delta T_{ij}[n]$ ,  $T_{ij}[n+1]$ 은 컴퓨터를 이용해서 구하며, 구해진  $T_{ij}[n+1]$ 은 DT2803 frame grabber를 사용하여 액정 텔레비전 위에 나타난다. 이때  $T_{ij}[n+1]$ 의 값은 0과 63사이의 정수이다. 식 (6)의 행렬 행렬 곱셈은 앞에서 설명한 HLA를 이용한 광학적 상호연결 방법으로 구현된다. 이에 의해 구해진 광 출력  $\hat{o}$ 는 광검출기의 전압으로 나타나며 이를 아나로그/디지털 변환기(ADC)를 통해 컴퓨터가 읽어 들인다. 읽혀진  $\hat{o}$ 는 컴퓨터에서 식 (7)과 같이 문턱화된 출력  $o$ 로 바뀌며, 식 (8)의  $T_{ij}[n+1]$ 의 계산에 사용된다. 식 (8)의  $T_{ij}[n]$ 은 다음과 같이 구해진다. 즉, 입력패턴을 CCD 카메라에 비춰주면, 이는 TV 화면에 비치는 동시에 DT2803 frame grabber에 저장된다. Frame grabber에 저장된 화상을 컴퓨터에서  $4 \times 4$  입력패턴으로 바꾸어서 식 (8)에 사용된다. 전체 시스템 구성도는 그림 3과 같다.

식 (6)의 행렬 행렬 곱셈이 올바로 이루어지려면 LCTV와 HLA를 통과한 빛의 세기와 광검출기에 나타나는 전압사이의 선형적인 특성의 축정이 필요하다. 축정방법은 다음과 같다. 사용한 LCTV는 삼성칼라 LCTV이며, 광검출기는 실리콘 팔다이오드와 22%의 저항을 직렬연결하여 제작하였다. 즉 정장치는 그림 3의 점선 안의 부분을 그대로 이용하였다. 40의 값을 가진  $T_{ij}$ 를 HLA중의 하나의 휴로그램 렌즈에 비춰준 후, 개속하여  $T_{ij}$ 가 쪼여지는 휴로그램 렌즈의 갯수를 늘려가면서 그 갯수와 광검출기의 출력과의 상관 관계를 측정하였다. 다음은  $T_{ij}$ 의 세기를 60으로 한 후에 똑같은 과정을 되풀이하였다. 그 결과를 그림 4에 나타내었다.

학습과정은 아래와 같다.

- 1) 학습율, 판성율을 정해준다.
- 2) 학습시키고자 하는 입력영상을 CCD 카메라에 보여준다. 그러면 컴퓨터는 frame grabber를 이용하여 입력영상을  $4 \times 4$  패턴으로 바꾼다.
- 3) 임의의(또는 바로 앞의) 연결패턴을 frame

grabber를 이용하여 LCTV에 나타낸다. 그러면 입력영상과 LCTV에 나타난 연결패턴의 곡이 LCTV, HLA를 이용한 상호연결을 통해 광검출기의 전압으로 나타난다.

- 4) 지도출력값을 컴퓨터에 입력시킨다.
- 5) 광검출기에 나타난 전압을 아나로그/디지털 변환기를 이용하여 컴퓨터가 읽어들인다.
- 6) 문턱값을 컴퓨터에 입력시킨다.
- 7) 문턱화된 출력, 지도출력값,  $4 \times 4$ 의 입력패턴을 이용하여 식 (8)에 따라  $T_{ij}[n+1]$ 을 구한 후, 이를 LCTV에 나타낸다.

8) 각 입력 영상에 대한 문턱화된 출력과 지도출력값을 비교하여 학습이 되었는지를 확인하고, 학습이 되지 않은 패턴들에 대해서 다음에 학습시킬 입력 영상을 결정한다.

9) 올바른 학습이 이루어질 때까지 3)에서 8)까지의 과정을 반복 한다.

실험 결과는 다음과 같다. 그림 5와 같은 2차원 입력 패턴들을 2개의 부류(0군, 1군)로 나누는 학습을 시켰다. 여기서 0군과 1군의 지도출력값은 각각 0과 1이다. 학습율과 판성율이 각각 0.3과 0.01일 때의 학습전과, 각 학습 단계에서의 학습시킬 입력패턴 번호들을 그림 6의 a)에 나타내었다. 학습율과 판성율이 0.3, 0.1일 때는 그림 6의 b)에, 0.5와 0.1일 때는 그림 6의 c)에 나타내었다. 학습이 잘 이루어진 후의 연결세기 값을 보면 1군의 패턴들이 겹치는 부분의  $T_{ij}$ 값들은 크고, 0군의 패턴이 겹치는 부분의 연결세기값들은 작음을 알 수 있었다. 이렇게 1군의 패턴들이 겹치는 부분과 0군의 패턴이 겹치는 부분이 선형적으로 분리가 가능한(linear separable) 경우에만 단층 인식자는 학습을 잘 할 수 있다.

#### IV. 고찰

그림 6의 a)에서 보면 학습율과 판성율이 0.3과 0.01일 때 입력패턴들의 실체출력들이 문턱값 근처에 있어서 진동하기 쉽고, 아울러 본래의 입력 패턴과 조금 다른 패턴에 대한 오류보정능력이 크게 떨어진다. 오류보정능력은 학습 후에 각 입력 패턴들의 실제 출력값들이 문턱값에서 멀리 떨어져 있을수록 좋아진다. 그림 6의 b)와 같이 판성을 0.1로 해주면 학습 속도도 빠르면서 오류보정능력도 향상된다. 그림 6의 c)처럼 학습율을 0.5로 크게 하면 학습 속도는 빠르나 아울러 진동할 가능성도 커진다. 그리고 학습이 잘 된 상태의  $T_{ij}$ 들을 살펴 보면 1군으로 분류된 패턴들 사이의 상관치(correlation value)가 큰 부분의  $T_{ij}$ 값들은 커졌고, 0군으로 분류된 패턴들 사이의 상관치가 큰 부분의  $T_{ij}$ 값들은 작았다. 그리고 입력 패턴들은 서로 같은 군으로 분류되는 입력 패턴들과의 상관 관계가 좋으면서, 다른 군으로 분류되는 입력들과의 상관관계가 적을수록 학습이 잘 됨을 관찰하였다. 그럼 9에서 학습결과를 보다 좋게 하기 위하여 마지막으로 입력패턴 0번을 학습시킬 때 문턱값을 0.55보다 작게 하여 학습시켰다. 이는 문턱값의 일관성이 없음을 의미하며, 바람직한 것이 아니다. 그러나, 문턱함수를 시그모이드 함수(Sigmoid function)로 바꾸면 일관된 문턱값으로 학습시킬 수 있다. 문턱 함수를 시그모이드 함수로 한 경우의 결과를 그림 6의 d)에 나타내었다.

많은 신경을 갖는 인식자의 구현을 제한하는 주요소는 홀로그램 렌즈의 해상도이다. 정사각형의 구멍을 가진 렌즈의 해상도는 약  $f\lambda/a$ 이다[10]. 여기서  $f$ 는 렌즈의 초점거리,  $\lambda$ 는 빛의 파장, 그리고

$a$ 는 정사각형 구멍의 한 변의 길이이다. 입력이  $N \times N$  신경들이고, 출력이  $M \times M$  신경들로 이루어진 인식자의 경우 상호연결 패턴은  $(N \times M) \times (N \times M)$ 이다. 이런 경우 한번이  $a$ 인 각 홀로그램 렌즈는  $a/M$ 의 거리를 구별할 수 있어야 한다. 그러므로  $a$ 는  $(f\lambda M)^{1/2}$ 보다 커야 한다. 예를 들면,  $f = 10 \mu m$ ,  $\lambda = 1 \mu m$ ,  $M = 9$ 일 때,  $a$ 는  $0.3 mm$ 보다 커야 한다.  $N = 30$ 이면 HLA의 크기는  $(N \times a) \times (N \times a)$ 이므로,  $9 mm \times 9 mm$ 이다.

#### V. 결론

신경회로망의 특징은 높은 병렬처리방식과 적응학습으로 요약된다. 이러한 신경회로망의 학습능력 또는 적응능력은 신경간의 연결강도를 변화시킴으로서 가능하다. 이 것을 구현함에 있어서 행렬-벡터곱셈이 중요한 역할을 한다. 행렬-벡터곱셈을 구현한 예로는 원통형 렌즈와 공간광변조기를 이용한 스텐포드 행렬-벡터곱셈기[4], 홀로그램을 이용한 방법[5], 그리고 HLA를 이용한 방법[2] 등이 있다. 그런데 2차원적으로 배열된 신경들 사이의 상호연결을 구현하기 위해서는 HLA를 이용하는 것이 편리하다. 그러면 프로그램이 가능한 고차원 광학적 상호연결은 상호연결 구조를 위한 HLA와 상호연결 세기를 저장하는 공간광변조기를 사용하여 구현할 수 있다.

이 논문에서는 HLA를 이용한 광학적 상호연결 방법으로 2차원 입력패턴 4개를 2개의 부류로 분류할 수 있는 단층 인식자(Percptron)[3] 구현하였다. 인식자의 성능은 학습율, 판성율, 그리고 학습해야 할 입력패턴들 사이의 상관 관계에 의존함을 실험적으로 관찰하였다. HLA를 이용한 상호연결 방법과 다중 초점 홀로그램 렌즈(multifocus hololens: MHL)를[9] 이용하면 오류역전과 학습모델의 구현도 가능하다.

#### 참고문헌

- [1] D. Psaltis, D. Brady, and K. Wagner, "Adaptive optical networks using photorefractive crystals," Appl. Opt. Vol. 27, p. 1752 (1988).
- [2] Ju-Seog Jang, Sang-Yung Shin, and Soo-Young Lee, "Programmable quadratic associative memory using holographic lenslet arrays," Opt. Lett. Vol. 14, No. 16, p. 838, (1989); 장 주석, 신상영, 이수영, "홀로그램 렌즈 어레이를 이용한 적응 2차 비선형 연산기," 제 4회 파동 및 레이저 학술 발표회 논문집 p. 99 1989. 2.
- [3] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," Psychological Review Vol. 65, p. 386 (1958).
- [4] J. W. Goodman, A. R. Dias, and L. M. Woody, "Fully parallel, high-speed incoherent optical method for performing discrete Fourier transforms," Opt. Lett. Vol. 2, p. 1 (1978).
- [5] J. -S. Jang, S. -W. Jung, S. -Y. Lee and S. -Y. Shin, "Optical implementation of the Hopfield model for two-dimensional associative memory," Opt. Lett., Vol. 13, p. 248, (1988).
- [6] 김남, 김상근, 박한규, "은염에 형성된 위상형 회절격자의 고효율에 관한 연구," 전자공학회논문지, 제 26권, 제 3호, p. 145, (1989).

- [7] D. E. Rumelhart and J. L. McClelland, Eds., *Parallel Distributed Processing, Vol. 1* (MIT Press, Cambridge, MA, 1986).
- [8] M. Minsky and S. Papert, *Perceptrons 2nd Ed.*, (MIT Press, Cambridge, MA, 1988)
- [9] Y.-Z. Liang, D. Zhao, and H.-K. Liu, "Multi-focus dichromated gelatin hololens," *Appl. Opt.* Vol. 22, p. 3451 (1983).
- [10] J. W. Goodman, *Introduction to Fourier Optics* (McGraw-Hill, New York, 1968).

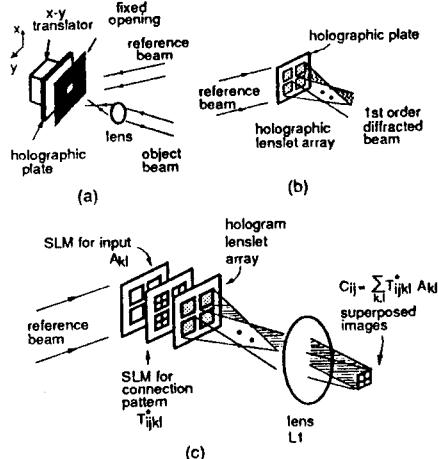


그림 1. a) HLA의 기록, b) 재생  
c) HLA를 사용한 행렬-멘서 광 채기

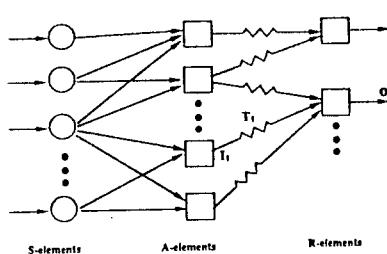


그림 2. 인식자(Perceptron)

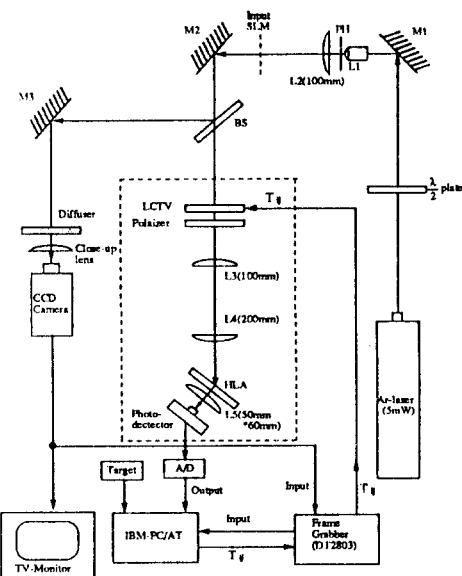


그림 3. 인식자 구현 구성도

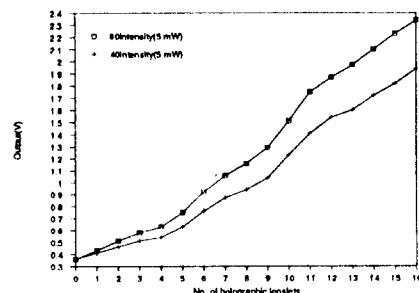


그림 4. LCTV, HLA 그리고 광 검출기의 선형 특성

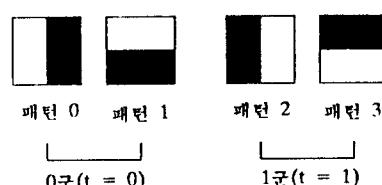


그림 5. 학습시키고자 하는 입력 패턴들

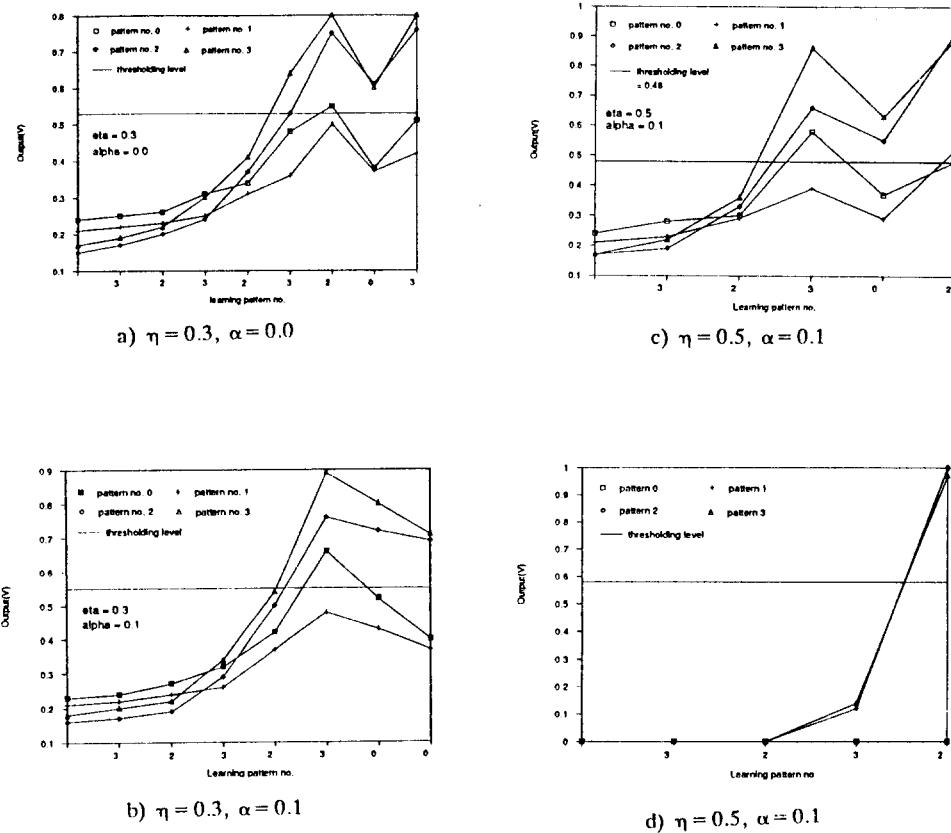


그림 6. 학습 결과