

Perceptron 신경회로망에 근거한 광 패턴인식 시스템의 구현

準會員 韓 鍾 旭* 準會員 龍 相 淳* 準會員 李 震 浩*
正會員 李 基 西** 正會員 金 恩 洙*

Implementation of Optical Pattern Recognition System Based on Perceptron Neural Network

Jong Wook HAN*, Sang Soon YONG*, Jin Ho LEE*, Key Seo LEE**,
Eun Soo KIM** *Regular Members*

要 約 본 논문에서는 단층 퍼셉트론 모델의 학습 능력과 신경회로망 인장메모리의 오류정정 능력이 서로 보완적으로 결합된 새로운 적응 패턴인식 시스템의 광학적 구현을 실현하였다.

여기서, 단층 퍼셉트론 모델은 2차원 LCTV 공간 광 변조기를 이용하여 편광 인코딩 방법과 비선형 양자화 방법으로 구현하였으며, Hopfield 인장메모리는 2차원 모델로 확장되고 multifocus hololens를 이용하여 광학적으로 구현하였다.

아라비아 숫자 식-홀수 판별에 관한 광학적 실험 결과, 오류 및 부분 입력에 대한 정확한 패턴 분류가 됨을 확인함으로써, 본 논문에서 제시한 새로운 적응 광 패턴인식 시스템이 실제로 영상 처리, 패턴인식 등의 분야에서 그 응용 가능성을 제시하였다.

ABSTRACT In this paper, we discuss optical implementation of new optical adaptive pattern recognition system based on single layer perceptron with learning capability and associative memory model having error corrective capability.

The single layer perceptron is optically implemented by using 2 D LCTV spatial light modulators through the non-linear quantization and polarization encoding methods, and 2 D Hopfield associative memory is also implemented by using multifocus holographic lens.

From some experimental results on classification of Arabic numbers into even & odd numbers, it is shown that the proposed system can classify the patterns to the right classes correctly even for the partial and erroneous input patterns.

Accordingly, the proposed optical adaptive pattern recognition system can be suggested for practical application in the fields of image processing and pattern recognition

I. 서 론

신경회로망은 기존 디지털 컴퓨터 구조와는 달리 비교적 간단한 정보처리 소자인 수 많은 신경세포(neuron)들이 상호 교밀도로 연결된 구조를 갖는데 이런 구조적 차이에 의해 신경회로망의 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 분해에 이를 응용하고자 많은 연구가 이루어지고 있다.⁽¹⁾⁽²⁾⁽³⁾

신경회로망에 대한 연구는 1943년 McCulloch & Pitts에 의해 처음으로 인간의 두뇌를 하나의 컴퓨터 시스템으로 해석한 이후, Rosenblatt의 Perceptron, Widrow의 Adaline 등과 같은 고전적 신경회로망 모델들이 이미 1960년부터 이루어지기 시작했으며, 1982년 Hopfield가 신경회로망의 연상기억에 관한 2진 모델로서 Hopfield 모델을 제시하여 신경회로망의 실질적인 연구가 활발하게 이루어지게 되었다.⁽⁴⁾⁽⁵⁾

Rosenblatt에 의해 제안된 단층 퍼셉트론은

* 光云大學校 電子工學科
Dept. of Electronic Eng., Kwangwoon Univ.
** 光云大學校 制御計測工學科
Dept. of Control & Instrumentation Eng., Kwangwoon Univ.
論文番號 : 91-52 (接受 1991. 4. 12)

실제 출력이 기대 출력과 다를 경우에 학습 법칙에 따라 입력과 출력간에 연결강도 값을 반복 수정함으로써, 임의의 입력 패턴이 어떤 class에 속하는가를 분류하는 학습이 가능한 패턴 분류기이다.⁶⁾

그러나, 단층 퍼셉트론의 경우 학습 기능을 갖는 장점이 있으나 오류가 존재하는 입력 패턴에 대해서는 잘못 인식할 수 있으므로, 본 논문에서는 단층 퍼셉트론의 오류정정 능력을 강화시키 줄 수 있는 방안으로 연상메모리인 Hopfield 모델을 단층 퍼셉트론에 도입하여 연상메모리의 오류정정 능력과 단층 퍼셉트론의 학습 기능을 결합시킨 새로운 광 패턴인식 시스템을 제안하고 광학적으로 구현하고자 한다.

특히, 본 논문에서는 단층 퍼셉트론의 2차원 패턴 입력 장치 및 연결소자로 범용성 있는 상용 LCTV 공간 광 변조기를 사용하고, 연결 강도에서 나타나는 음과 양의 값 처리는 LCTV의 편광 상태를 이용한 편광인코딩(polarization encoding) 방식⁷⁾으로, 상용 LCTV의 제한된 gray 레벨의 한계는 비선형 양자화(nonlinear quantization)⁸⁾ 방법으로 해결하여 광학적으로 구현하고자 한다.

또한, Hopfield 연상메모리 모델을 2차원 모델로 확장, 상용 LCTV와 multifocus holens를 이용하여 광학적으로 구현함으로써 본 논문에서 새로이 제시된 적응 광 패턴인식 시스템에 대한 이론적 분석과 실험 결과에 대해 논의하고자 한다.

II. 신경회로망 모델 분석

1. 단층 Perceptron 학습 알고리즘⁶⁾

단층 퍼셉트론은 1959년 Rosenblatt에 의해 제안된 모델로서 feedforward 연결 구조를 가지며 학습에 의해서 패턴 분류의 기능을 갖는 간단한 형태의 신경회로망 모델이다.

그림 1은 단층 퍼셉트론의 기본 모델로서 출력 단자에 대한 입력은 적절하게 가중치가 부여된

모든 입력의 합이된다.

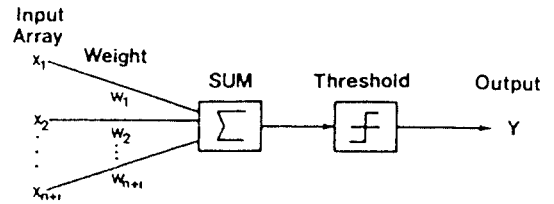


그림 1. 단층 퍼셉트론의 기본 모델
Fig. 1. Basic model of single layer perceptron

이 단층 퍼셉트론은 주어진 입력 패턴에 대한 실제 출력이 기대 출력과 다를 경우에 그 차이 오차를 퍼이드 백시키 오차량이 0이될때까지 반복적으로 연결강도를 보정하는 학습 법칙을 가지고 있다.

학습시킬 입력 패턴을 2진벡터 $X^t = \{x_1, x_2, \dots, x_{n+1}\}$ 로, 연결강도를 $W^t = \{w_1, w_2, \dots, w_{n+1}\}$ 이라고 하면 SUM 단자에서의 총입력은 입력 패턴과 단층 퍼셉트론 연결강도 값의 곱에 합으로 표현된다.

$$SUM = \sum_{i=1}^{n+1} W_i X_i = W^t X \quad (1)$$

그리고, 단층 퍼셉트론 출력 Y는

$$Y = Th[SUM] = \begin{cases} 1 & \text{if } SUM > 0 \\ 0 & \text{if } SUM < 0 \end{cases} \quad (2)$$

와 같이 주어지는데 잊식에서 t는 transpose를, Th는 hard limiting 함수를 의미한다.

즉, 단층 퍼셉트론은 입력 패턴을 두개의 class ω_1, ω_2 로 분류하는 것으로 입력 패턴이 class ω_1 일 경우는 $Y = +1$, class ω_2 일 경우는 $Y = 0$ 의 출력을 내게된다.

만일 학습시킬 입력 패턴이 m개인 입력 벡터 x에 대한 기대 출력을 $T^t = \{t_1, t_2, \dots, t_m\}$ 이라고 할때 기대 출력과 실제 출력이 다를 경우

연결강도 보정을 위한 퍼셉트론 학습법칙은 m 번째 패턴에 대해 k번째 반복 과정에서 다음 식과 같이 주어진다.

$$W_m(k+1) = W_m(k) + \alpha [T_m - Y_m(k)] X_m(k),$$

for all m (3)

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

식(3)에서 $T_m - Y_m(k)$ 는 기대 출력과 실제 출력의 차로서 오차를 나타내는 값으로 이 오차량이 0이 될때까지 연결강도 W 를 반복적으로 오차에 비례하여 변화시켜 최종적으로 안정된 연결강도를 구하는 단층퍼셉트론의 학습 법칙을 나타낸 것이다.

오차가 0이 되면 연결강도는 변화가 없게 되는데 이는 학습이 끝난 상태로 입력 패턴에 대해서 기대 출력을 얻을 수 있는 최종 연결강도 값을 나타내는 것이다.

2. Hopfield 연상메모리 모델

Hopfield 모델은 신경 세포들이 상호 연결되어 일련의 단일 소자를 형성하고 이 소자들은 McCulloch & Pitts thresholding 법칙에 따라 all or none(1 혹은 0) 상태로 동작하도록 모델화한 것이다.

이와같은 (1, 0) 상태의 벡터들인 N비트의 입력이 M개 주어지면 다음의 식(4)와 같이 Hebbian 학습 법칙에 근거한 외적(outer-product) 알고리즘에 의해 M개의 벡터들이 메모리에 연결 행렬(synaptic matrix)로 저장된다.⁽⁹⁾⁽¹⁰⁾ ($m=1,2,\dots,M$)

$$T_{ij} = \begin{cases} \sum_{m=1}^M (2V_i^{(m)} - 1)(2V_j^{(m)} - 1) & \text{if } i \neq j \\ 0 & \text{if } i = j \end{cases} \quad (4)$$

여기서 $i, j=1,2,\dots,N$ 이고, $V_i^{(m)}$ 은 m번째 저장된 벡터의 상태를 나타내는 것이다.

이 메모리 행렬 T_{ij} 는 오류 및 부분 벡터가

입력으로 사용되더라도 updating 법칙의 반복에 의해 원래의 저장 벡터에 가장 유사한 최종 안정 상태로 찾아가는 연상 능력이 있다. 즉, 메모리에 상태 벡터중의 하나인 $V_i^{(m)}$ 가 입력된다면 식(5)와 같은 결과가 된다.

$$\hat{V}_i^{(m)} = \sum_{j=1}^N W_{ij} V_j^{(m)} \quad (5)$$

$$= (N-1)V_i^{(m)} + \sum_{m \neq i}^M \alpha_{m-m_0} V_i^{(m)}$$

여기서 $\alpha_{m-m_0} = \sum_{j=1}^N V_j^{(m)} V_j^{(m)}$ 으로 주어진다.

출력 $\hat{V}_i^{(m)}$ 은 두항의 합으로 이루어 지는데 첫번째항은 (N-1)항만큼 증폭된 입력 벡터이고 두번째항은 나머지 저장된 벡터들의 선형 조합으로 원하지 않는 잡음항을 나타낸다.⁽¹¹⁾

따라서 N이 M보다 상당히 크다면, 식(6)과 같은 updating 법칙에 의해 그 상태가 결정된다.

$$V_i^{(m)} = \text{Th}[\hat{V}_i^{(m)}] = \begin{cases} 1 & \text{if } \hat{V}_i^{(m)} \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

즉, 식(6)과 같은 updating 법칙에 의해서 계속된 반복적 피드백에 의해 오류나 부분 입력에 대해서도 완전한 저장 벡터로 수렴이 가능하게 되므로, 결국 이 Hopfield 연상메모리 모델은 오류 정정 능력을 가지게 되는 것이다.

그러나, 실제로 위식과 같은 1차원 벡터를 이용한 광 정보처리에는 한계가 있으며, 2차원 영상 처리를 필요로 하는 패턴인식, machine-vision 등과 같은 실제 응용 분야에서는 필연적으로 2차원적으로 입력영상을 직접 처리해야 할 필요가 있으므로 본 논문에서는 2차원으로 확장시킨 모델을 이용하여 구현하고자 한다.⁽¹²⁾

이러한 2차원 모델에 대한 4차원 메모리 행렬은 임의의 2차원 입력패턴 $V^{(m)}$ 의 외적으로 주어지므로 식(7)과 같이 나타낼 수 있으며

$$T_{ijkl} = \sum_{m=1}^M V_{ij}^{(m)} V_{kl}^{(m)} \quad (7)$$

즉, 임의의 입력 $V_{ki}^{(m)}$ 와 4차원 행렬간의 곱셈은 식(8)와 같다.

$$\hat{V}_{ij}^{(m)} = \sum_k T_{ijk} V_{ki}^{(m)} \quad (8)$$

(i, j, k, 1=1, 2, 3, ..., N)

여기서, 4차원 행렬 T_{ijk} 은 2차원 부분행렬(submatrix)로 2차원적으로 배열되도록 구성하였으며, 입력 $V_{ki}^{(m)}$ 은 T_{ijk} 의 2차원 부분행렬에 각각 곱해진 다음 합해져 출력 $\hat{V}_{ij}^{(m)}$ 을 얻고 이 출력은 저장된 정확한 결과를 출력할때까지 thresholding 되어 재환되는 동작을 반복하게 되어 에너지 변화는 항상 감소하여 안정한 상태로 가므로 결국 부분 정보면으로도 재생이 가능한 오류정정 능력을 지니게 된다.

즉, 2차원 신경회로망의 광학적인 수행을 위한 구성은 4차원 행렬과 2차원 행렬간의 곱셈 각각 수행한 다음 합해수는 형태로 상용 LCTV와 multifocus holens를 이용한 2차원 광 인식메모리 시스템⁽¹⁰⁾등도 보고된 바 있다.

III. 적응 패턴인식 시스템

1. 새로운 적응 패턴인식 시스템

본 논문에서는 다층 퍼셉트론 모델의 학습기능과 신경회로망 인식메모리의 오류정정 능력이 서로 보완적으로 결합된 새로운 적응 패턴인식 시스템을 제안하였다.⁽¹¹⁾

신경회로망에 근거한 인식메모리는 오류 정정 능력이 뛰어나나 학습이 불가능한 단점이 있고, 다층 퍼셉트론 모델은 학습을 가능하나 오류 정정 능력이 떨어지는 단점이 있게 되므로 상호 보완적으로 두 모델의 장점을 이용한 하나의 시스템으로 구성하면 오류가 존재하는 입력 패턴에 대해서도 정확하게 패턴을 분류할 수 있는 새로운 패턴 분류기가 될 수 있다.

즉, 다층 퍼셉트론에는 기본 입력 패턴만을 학습시킨 후에 오류 또는 부분입력이 들어올

때는 인식메모리 시스템에 의해서 원래의 기본 입력 패턴이 재생되어 정확한 결정을 가능하게 하는 것이다.

이 시스템은 기본 입력 패턴외에 오류가 존재하는 모든 경우를 학습시킬 필요가 없으므로 학습시간 입력 패턴 개수의 감소로 인한 학습시간을 줄일 수 있다는 장점을 지니게 된다.

그림 2는 본 논문에서 구성한 새로운 적응 패턴인식 시스템의 블록 구조를 나타낸 것이다.

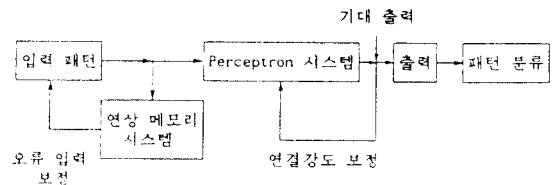


그림 2. 새로운 적응 패턴인식 시스템 구조
Fig. 2. Block diagram of new adaptive pattern recognition system

때로 주어질 학습 패턴인식 시스템은 학습 및 동작의 두가지 단계로 구성된다. 우선 학습 단계에서는 학습시키코자 하는 입력패턴을 다층 퍼셉트론의 입력으로 하여 “+1”과 “0”의 기대출력을 갖게 하여 최종적으로 실제 출력과의 오차가 0이 되도록 입력과 출력사이의 연결강도를 수정해 나가는 다층 퍼셉트론의 학습 알고리즘으로 학습시킨다.

그러나 다층 퍼셉트론 자체는 학습 기능은 있으나 인식메모리의 오류정정 능력이 없으므로 다음 단계인 동작 단계에서는 오류가 실린 입력 패턴이 그림 2의 패턴인식 시스템에 입력되면 인식메모리의 오류정정 능력에 의해 완전한 입력으로 재생되어 전 단계에서 이미 학습이 끝난 다층 퍼셉트론의 입력으로 주어지므로 정확한 패턴 분류를 수행하게 된다.

2. 컴퓨터 시뮬레이션

실함에 앞서 본 논문에서 구성한 적응 패턴인식 시스템의 효율성을 알아 보기 위해 컴퓨터 시뮬레이션을 하였다.




그림 3. 5×4의 2차원 배열의 입력 패턴
Fig. 3. 5×4 input patterns in two dimensional array

그림 3은 짝수는 +1, 홀수는 0의 기대출리를 내는 단층 퍼셉트론의 구현을 위하여 본 논문에서 사용한 2차원 입력패턴을 나타내고 있다.

일반적으로 Hopfield 모델에 있어서 메모리의 저장용량 M은 저장할 입력 패턴의 비트수 N에 대하여 $M \leq 0.15N$ 의 관계가 있으므로 본 논문에서는 $N=20$ 이므로 $M=3$ 인 입력 패턴을 저장하였다.⁽⁶⁾

따라서, 그림 4와 그림 5는 그림 3의 아리마하 숫자 입력 패턴중 '1', '4', '6' 입력 패턴의 HD (Hamming Distance)를 1부터 7까지 변화시키면서 얻은 오류 및 부분 입력을 사용하여 컴퓨터 시뮬레이션한 결과로 그림 4에는 학습 속도(α)를 0.7로 고정하여 학습시킨 단층 퍼셉트론의 입력으로 오류 및 부분 입력 패턴을 주었을 경우에 대한 분류 확률을, 그림 5는 연상메모리 모델을 도입한 새로운 적응 패턴인식 시스템에 위에 주어진 '1', '4', '6'에 대한 3개의 패턴의 오류 및 부분입력을 주었을 경우에 대한 분류 확률을 나타낸 것이다.

그림 4와 그림 5의 결과에서 입력 패턴의 HD가 커질수록 기존의 학습된 단층 perceptron 모델은 분류 능력이 크게 떨어지는 반면 새로운 적응적 패턴인식 시스템을 이용할 경우 연상메모리에 의해 높은 오류정정 능력이 나타나게 되고 이러한 정정된 패턴을 단층 퍼셉트론의 입력으로

HD	1	2	3	4	5	6	7
PATTERN							
1	73%	71%	67%	60%	27%	20%	26%
4	100%	87%	83%	70%	61%	53%	18%
6	85%	81%	71%	67%	50%	41%	12%

그림 4. 단층 퍼셉트론의 오류 입력에 대한 분류율
Fig. 4. Classification probability of single layer perceptron for erroneous inputs.

HD	1	2	3	4	5	6	7
PATTERN							
1	100%	100%	97%	90%	87%	81%	80%
4	100%	100%	100%	100%	97%	90%	82%
6	100%	100%	100%	100%	100%	100%	100%

그림 5. 새로운 적응 패턴인식 시스템의 분류율
Fig. 5. Classification probability of new adaptive pattern recognition system

사용할 수 있어, 결과적으로 오류 및 부분 입력에 대한 분류능력이 개선될 수 있으므로 본 논문에서 제안한 새로운 적응 패턴인식 시스템의 효율성을 컴퓨터 시뮬레이션을 통해 확인할 수 있다.

그리고 그림 5에서 HD가 커질수록 각 패턴의 분류율이 다소 감소되는 것을 볼수 있는데 이는 연상메모리에 저장된 3개의 입력 패턴들이 서로

완전한직교성(orthogonality)을 가지고 저장되지 않았기 때문에 나타난 결과이다.

IV. 적응 패턴인식 시스템의 광학적 구현

1. 적응 광 패턴인식 시스템 구성

본 논문에서는 이상의 이론적 분석 및 컴퓨터 시뮬레이션 결과를 토대로 아라비아 숫자의 짝·홀수를 판별할 수 있는 단층 퍼셉트론에 근거한 새로운 적응 광 패턴인식 시스템을 구현하였다.

그림 6은 본 논문에서 제안한 전체 시스템도를 나타낸 것이다.

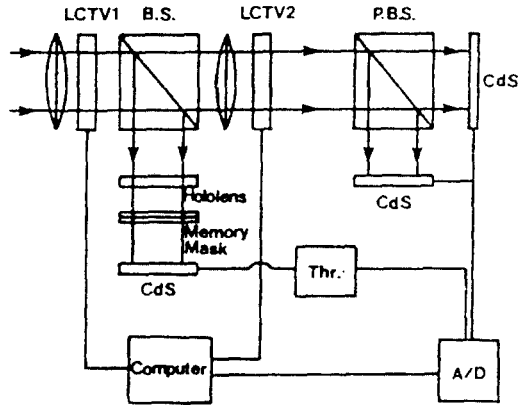


그림 6. 단층 퍼셉트론 모델에 근거한 적응 광 패턴인식 시스템

Fig. 6. Adaptive optical pattern recognition system based on single layer perceptron model

우선 그림 6으로 주어진 패턴인식 시스템의 구성에 대해서 살펴 보면 그림 6의 상단은 단층 퍼셉트론 학습 시스템으로 상용 LCTV를 이용하여 광학적으로 구현하였다.

그런데, 일반적으로 상용 LCTV가 표현할 수 있는 gray 레벨 갯수가 약 50개 정도로 제한¹⁰⁾되므로 본 논문에서는 더욱 효율적이며 완전한 학습 수렴성을 얻을 수 있는 비선형 양자화 방법

을 사용하여 원래 모델에 비해 훨씬 빠른 수렴 속도와 적은 gray 레벨을 갖게 함으로서 단층 퍼셉트론의 광학적 구현이 가능하게 되었다.¹⁰⁾

또한, 본 논문에서 사용한 상용 LCTV는 입사 광을 인가되는 전압의 크기로 편광이 가능한 twisted nematic 액정 구조를 가지고 있으므로 기존의 신경회로망 모델의 광학적 구현에서 큰 문제가 되었던 음과 양의 값 처리를 상용 LCTV의 편광특성을 이용, 수직 성분은 양, 수평성분은 음의 값으로 한 편광 인코딩 방법으로 해결하였다.¹¹⁾

또한, 그림 6의 밑분할기 하단에는 multifocus holens를 이용한 2차원 Hopfield 연상메모리 시스템으로 상용 LCTV의 제한된 크기로 인해 메모리 행렬을 고정된 마스크로 제작하여 사용하였으며, 입력 LCTV상의 입력 패턴은 5×5 multifocus holens에 의해 Hopfield 메모리 마스크상의 메모리 행렬과 thresholding 레벨에 각각 곱해서 CdS어레이로 수광된다. 그 내적 값들은 다시 전자회로적으로 thresholding되어 컴퓨터에 의해서 LCTV1으로 재 입력이 된다. 이러한 과정을 반복하는 가운데 오류나 부분 입력은 원래 저장된 입력으로 복원되는 것이다.¹³⁾

LCTV1에는 학습시키려고 하는 입력 패턴이 주어지며, LCTV2는 입·출력 단자 사이의 연결강도 값을 비선형 양자화 방법을 이용하여 gray 레벨로 나타낸다. 그러므로 LCTV1을 통과한 수직 성분은 LCTV2의 각 화소(pixel)에 인가되는 전압의 크기에 의해 선형적으로 회전된다. LCTV2에서 나온 결과는 편광된 빛 분할기를 통해서 수직, 수평 편광성분으로 분리되어 각각 수광 소자로 검출된다. 그 결과는 A/D 변환기를 통해 컴퓨터로 피드백되어 비교됨으로써 그 값이 양수인지 음수인지를 측정, 단층 퍼셉트론 학습 법칙에 따라 LCTV2의 연결강도 값을 계속 변화시키주게되어 최종적으로 아라비아 숫자의 짝·홀수를 판별할 수 있게 된다.

그런데, 만일 오류가 존재하는 입력 패턴이 LCTV1에 입력된다면 이 입력 패턴은 밑 분할기에서 반사되어 holens의 작용에 의해서 외적

알고리즘으로 구성되어 있는 연상메모리 행렬 배열과 thresholding 레벨에 곱해져 내적 계산되고, 이 결과는 수광소자인 CdS로 받아들여 thresholding 되어 컴퓨터로 피이드백 된다. 컴퓨터에 선 그 내적 값들을 thresholding 값과 비교하여 다시 LCTV1에 재입력시키게 된다.

이 과정을 몇번 반복하면 Hopfield 모델의 오류 정정 능력에 의해 처음 입력 패턴과 가장 가깝게 저장된 패턴이 재생되어 나타나므로, 이 재생된 입력 패턴은 최종 연결강도가 표현된 LCTV2를 통하여 단층 퍼셉트론에 의해서 정확한 분류가 가능하게 된다.

2. 실험 및 결과 고찰

본 논문에서 사용한 LCTV는 금성 BS-220 B/W로 3.8cm×3.0cm의 화면 크기에 250μm×250μm의 화소가 총 152×120으로 구성되어 있다.


상용 LCTV를 편광 변조기로 사용하기 위해서는 컴퓨터 그래픽 프로그램을 이용하여 상용 LCTV 상에 gray 레벨 0부터 255까지 인가해 주므로서 gray 레벨에 따른 각 수직·수평 편광 성분의 값을 구하였다.

실질적으로 상용 LCTV에 약 40~50개의 gray 레벨 표현이 가능하므로 비선형 양자화 값에 적당한 gray 레벨 값을 부여함으로써 단층 퍼셉트론 모델의 입·출력간의 연결강도 값들을 표현하여 주었다. 실제로 단층 퍼셉트론의 광학적 구현에 필요한 gray 레벨 값은 20개 이하이므로 적절한 값의 표현이 가능하였다.

2차원 Hopfield 모델의 광학적 구현을 위하여 제작한 multifocus hololens는 초점 거리 $f=2\text{cm}$ 이고 $D_H=3.5\text{cm}$ 의 직경을 가지고 있다.

그림 7의 (a)는 본 논문에서 제작한 5×5 multifocus hololens로 아라비아 숫자 “4”를 25개 재생한 사진이고, (b)는 5×5 multifocus hololens에서 각 초점의 빛의 세기를 측정 한 것이다. 그림 7의 (b)에서 각 초점의 세기가 달라 실험상 큰 문제점이 될 수 있으나 이것은 전자회로적으로 수광소자인 CdS 어레이에 연결

된 가변 저항을 조절하여 미리 보상시킴으로써 해결할 수가 있다.



0.67	0.99	0.84	0.99	0.65
1.00	1.46	1.04	1.45	0.99
0.89	1.05	0.96	1.03	0.87
1.02	1.46	1.05	1.47	1.01
0.70	0.96	0.82	0.98	0.67

그림 7. (a) 5×5 multifocus hololens에 의해 형성된 5×5 이미지
(b) 5×5 multifocus hololens 각 초점들의 세기(단위 : 10μW)

Fig. 7. (a) The 5×5 image formed by 5×5 multifocus hololens.
(b) Each focus intensity of 5×5 multifocus hololens (unit : 10μW)

본 논문에서 사용한 5×5 multifocus hololens는 25개의 입력 패턴을 재생할 수 있으나, 5×4는 Hopfield 모델의 메모리 행렬과의 곱에, 또 3행 5열에 나타난 값은 thresholding 레벨과의 곱에 사용하였다.

이상의 이론 및 실험 결과로 본 논문에서 제안

한 새로운 적응 광 패턴인식 시스템을 광학적으로 구현하였다.

그림 8, 9는 단층 퍼셉트론 연결강도에 오류나 부분입력이 섞인 아라비아 숫자가 입력되었을 경우 잘못된 출력이 나오게 되나 연상메모리 시스템을 추가함으로써 올바른 출력을 얻을 수 있음을 보여 주는 실제 광학 실험 결과를 나타낸 것으로 단층 퍼셉트론 출력은 피이드백 회로에 첨가한 3×3 LED 배열을 이용하여 홀수일때는 "0", 짝수일때는 "1"로 나타나게 하였다.

그림 8에는 입력 패턴 '1'이나 '4'의 HD가 각각 5와 6일 경우에 Hopfield 연상메모리 시스템을 거치지 않고 학습된 단층 퍼셉트론으로 분류하였

을 경우에는 짝·홀수 패턴 분류가 정확하게 되지 않았으나 1, 4, 6으로 저장된 Hopfield 메모리로 연상된 입력을 사용하면 '1'에 대해서는 "0"로 '4'에 대해서는 "1"로 정확하게 분류가 이루어 짐을 볼 수 있다.

그림 9에는 HD가 6인 '6'의 오류 입력을 사용하였을 경우, 학습된 단층 퍼셉트론은 출력이 "0"로 패턴 분류를 정확하게 수행하지 않았으나, '6'의 입력 패턴에 대한 Hopfield 연상메모리로 복원된 입력을 단층 퍼셉트론의 입력으로 사용하면 "1"로 정확하게 분류되어짐을 보여주는 것이다.

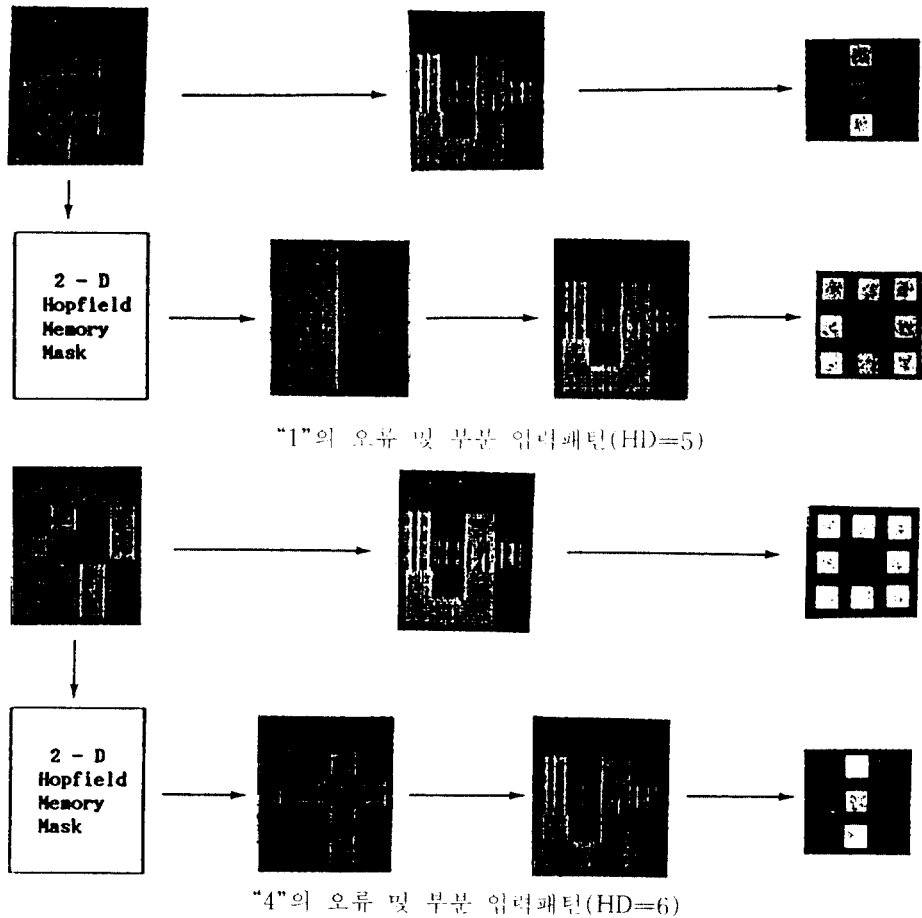


그림 8. 오류 입력에 대한 실험 결과(아라비아 숫자 패턴 1, 4)

Fig. 8. Experimental results on erroneous input patterns (Arabic number patterns 1, 4)

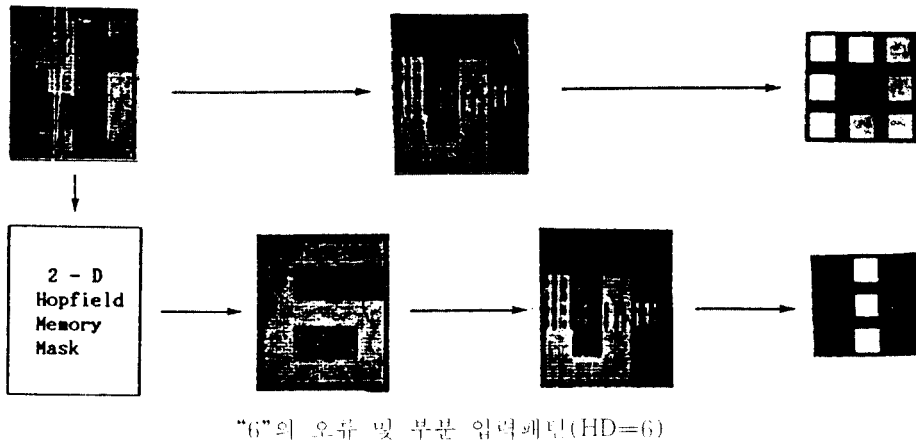


그림 9. 오류 입력에 대한 정화 결과(아라비아 숫자 패턴)
 Fig. 9. Experimental results on erroneous input patterns(Arabic number pattern 6)

이상의 실험 결과로부터 알 수 있듯이 본 논문에서 제시한 적응 패턴인식 시스템의 단층 퍼셉트론에서는 기본 입력 패턴들만을 학습시키고 그외의 오류가 존재하는 경우에 대해서는 연상메모리의 오류정정 능력을 이용하므로써 학습시킬 입력 패턴 갯수의 감소로 인해 학습 시간을 줄일 수 있고 오류 입력 패턴에 대한 분류 정확도를 개선할 수 있다.

본 논문에서는 연상메모리 모델의 제한된 메모리 저장 용량으로 몇개의 입력 패턴밖에는 저장할 수 없었으나 더욱 큰 저장 용량을 갖는 연상메모리가 구성된다면 보다 범용성 있는 응용이 가능할 것이다.

또한, 패턴인식 시스템의 입력단에 혹은 연상메모리 시스템에 왜곡 불변 시스템을 추가한다면 입력 패턴의 위치, 회전, 크기 왜곡에 관계없이 언제나 정확한 패턴 분류를 할 수 있는 새로운 왜곡 불변 패턴 분류 시스템으로 응용이 가능한 것이다.

V. 결 론

단층 퍼셉트론은 실제 출력이 기대 출력과 다를 경우에 학습 법칙에 따라 입력과 출력간에

인질강도 값을 반복 수정함으로써, 임의의 입력 패턴이 어떤 class에 속하는가를 분류하는 학습이 가능한 패턴 분류기로서, 학습 기능을 갖는 장점은 있으나 오류가 존재하는 입력 패턴에 대해서는 분류 능력이 크게 떨어지게 된다.

따라서, 본 논문에서는 단층 퍼셉트론 모델의 학습 기능과 신경회로망 연상메모리의 오류정정 능력이 서로 보완적으로 결합된 새로운 적응 패턴인식 시스템의 광학적 구현을 실현하였다.

여기서, 단층 퍼셉트론은 2차원 LCTV 공간 광 변조기를 이용하여 편광 인코딩 방법과 비선형 양자화 방법으로 구현하였으며 Hopfield 연상메모리는 2차원 모델로 확장하고 multifocus hololens를 이용하여 광학적으로 구현하였다.

본 논문에서는 아라비아 숫자 쌍·홀수 입력 패턴 분류에 대한 컴퓨터 시뮬레이션과 광학 실험을 통해 부분 또는 오류 입력에 대한 패턴분류 능력의 개선을 보임으로 새로이 제안한 적응 광 패턴인식 시스템의 효율성을 확인하였다.

따라서, 본 논문에서 구현한 적응 광 패턴인식 시스템은 앞으로 패턴인식, machine vision 등과 같은 분야에서의 응용 가능성을 제시하였다.

“본 논문은 1990년도 문교부 학술연구조성비에 의한 자유 공모과제로 선정되어 연구되었음”

참 고 문 헌

1. D.E.Rumelhart, G.E.Hinton and J.L.McClelland, Eds., *Parallel Distributed Processing*. MIT Press, vol.1, 1986.
2. B.J.Kinoshita and N.G.Palevsky, "Computing with neural networks," *High Technology*, 00:24-47, 1987.
3. R.H. Nielson, *Neurocomputing*, Addison-Wesley Pub. Com., Inc., 1988.
4. M.A.Arbid, *Brains, machines and mathematics*, Springer-Verlag New-York Inc., 2nd Ed., 1987.
5. T.Kohonen, *Self-organization and associative memory*, 2nd ed. Springer-Verlag, Berlin, 1988.
6. M.L.Minsky and S.A.Papert, *Perceptrons*, expanded ed., MIT press, 1988.
7. M.Kranzdorf and K.M.Johnson, "Optical connectionist machine with polarization-based bipolar weight values", *Opt. Eng.*, vol. 28, no.8, pp.844-848, 1989.
8. Jong Wook Han, Sang Soon Yong and Eun Soo Kim, "Optical implementation of perceptron learning model using the polarization property of commercial LCTV" *KITE*, vol.27, no.8, pp.148-156, 1990.
9. J.J.Hopfield, "Neuron network and physical systems with emergent collective computational abilities", *Proc. Natl. Acad. Sci.USA*, vol.79, pp.2554-2558, 1982.
10. J.J.Hopfield, "Neurons with graded response have collective computational properties like those of two state neurons", *Proc. Natl. Acad. Sci.USA*, vol. 81, pp.3088-3092, 1984.
11. N.Farhat and D.Psaltis, "Optical implementation of the Hopfield model", *Applied Optics*, vol.24, no.10, pp.1469, 1985.
12. N.Farhat and D. Psaltis, "Optical signal processing : Optical implementation of associative memory based on models neural networks", *Academic Press Inc.*, pp.129-164, 1987.
13. Woo Sang Lee, Jong Wook Han, Eun Soo Kim, "Optical implementation of associative memory based on two dimensional neural network model", *KICS*, vol.15, no.8, p.667-677, 1990.
14. Jong Wook Han, Sang Soon Yong and Eun-Soo Kim, "Optical adaptive patternrecognition system having association capability", *Proc. of KITE*, vol. 13, no.2, pp.591-593, 1990.
15. H.K.Liu and T.H.Chao, "Liquid crystal television spatial light modulator", *Appl. Opt.*, vol.28, no.22, pp.4772-4280, 1989.



韓 鍾 旭 (Jong Wook HAN) 準會員
 1965年 9月 17日生
 1989年 2月 : 光云大學校 電子工學科 卒業 (工學士)
 1991年 2月 : 光云大學校 大學院 電子工學科 卒業 (工學碩士)
 1991年 3月 ~ 現在 : 韓國電子通信研究所 符號技術部 研究員
 ※主關心分野는 Optical Neural Network, 光情報處理, 光패턴認識 等임.




龍 相 淳 (Sang Soon YONG) 準會員
 1966年 12月 15日生
 1989年 2月 : 光云大學校 電子工學科 卒業 (工學士)
 1989年 8月 ~ 現在 : 光云大學校 大學院 碩士課程 在學中
 ※主關心分野는 Optical computing, Optical Neural Network, 光패턴認識 等임



李 震 浩 (Jin Ho LEE) 準會員
 1968年 1月 9日生
 1990年 2月 : 光云大學校 電子工學科 卒業 (工學士)
 1991年 8月 : 光云大學校 大學院 碩士課程 卒業豫定
 1991年 6月 ~ 現在 : 韓國航空宇宙研究所 研究員
 ※主關心分野는 Optical Neural Network, 光패턴認識 等임



李 基 西 (Key Seo LEE) 正會員
 1951年 4月 15日生
 1977年 2月 : 延世大學校 電氣工學科 卒業 (工學士)
 1986年 8月 : 延世大學校 大學院 電氣工學科 卒業 (工學博士)
 1988年 : Yale University 交換 教授
 1981年 ~ 現在 : 光云大學校 制御計測工學科 副教授
 ※主關心分野는 Neural Network 學習 알고리즘, 디지털 制御 等임



金 恩 洙 (Eun Soo KIM) 正會員
 1955年 8月 1日生
 1978年 2月 : 延世大學校 電子工學科 卒業
 1980年 2月 : 延世大學校 大學院 電子工學科 卒業 (工學碩士)
 1984年 2月 : 延世大學校 大學院 電子工學科 卒業 (工學博士)
 1987年 2月 ~ 1988年 8月 : Caltech 電氣工學科 客員教授
 1981年 3月 ~ 現在 : 光云大學校 電子工學科 副教授
 ※主關心 分野는 Optical Neural Network, 光情報處理, Learning Algorithm, Optical Computing, 光패턴認識 等임