

# Hebb의 학습 법칙과 화소당 가중치 최적화 기법에 의한 적응학습 및 그의 전기광학적 구현

(Adaptive Learning Based on Bit-Significance Optimization with  
Hebbian Learning Rule and Its Electro-Optic Implementation)

李壽永\*, 沈昌燮\*\*\*, 高相鎬\*\*, 張珠錫\*, 申相永\*

(Soo Young Lee, Chang Sup Shim, Sang Ho Koh, Ju Seog Jang and Sang Yung Shin)

## 要 約

Hopfield 모델에 화소당 가중치를 도입하고 이를 최적화하여, 서로간에 상관관계가 높은 “0”에서 “9”까지의 10가지 숫자를 성공적으로 기억, 재생시킬 수 있는  $6 \times 8$  nodes 연상기억 시스템을 소개한다. 다른 많은 신경회로와는 달리, 이 모델은 “6”, “8”, “3”, “9”와 같이 상관관계가 매우 큰 영상에 대해서도 높은 오차 교정 능력을 가짐을 볼 수 있다. 화소당 가중치의 최적화 문제는 최소자승평균 오차 알고리즘에 기초한 적응학습 과정으로 볼 수 있으며, 이는 또한 Widrow-Hoff 신경회로로 구현할 수 있다. 가중치 최적화 회로의 전기·광학적 구현을 위한 설계도 소개한다.

## Abstract

Introducing and optimizing bit-significance to the Hopfield model, ten highly correlated binary images, i.e., numbers “0” to “9”, are successfully stored and retrieved in a  $6 \times 8$  node system. Unlike many other neural network models, this model has stronger error correction capability for correlated images such as “6”, “8”, “3”, and “9”. The bit significance optimization is regarded as an adaptive learning process based on least-mean-square error algorithm, and may be implemented with Widrow-Hoff neural nets optimizer. A design for electro-optic implementation including the adaptive optimization networks is also introduced.

## I. 서 론

Hopfield 모델에 기초한 연상기억 장치는 정보의 저장과 재생에 사용될 수 있으며, robustness와 오차 교정 능력을 지닌다.<sup>[1]</sup> 이 모델은 저장된 데이터의 양이 neuron의 숫자에 비해 훨씬 적고, 각 데이터들 간의 직교성(orthogonality)이 있을 때에만 성공적인 저장, 재생이 가능하다.<sup>[2]</sup> 그러나 숫자나 문자의 인식

\*正會員, \*\*準會員, 韓國科學技術院 電氣 및 電子  
工學科

(Dept. of Electrical Eng., KAIST)

\*\*\*正會員, 韓國電子通信研究所

(Electronics and Telecommunications Research  
Institute)

接受日字: 1989年 4月 8日

등에서 볼 수 있는 바와 같이 실제적인 상황은 각 데이터간의 직교성을 만족시키지 못한다.

이러한 한계를 극복하고, 성능을 개선시키기 위하여 더 복잡한 모델들이 제안되어 있다.<sup>[4~7]</sup> 참고문헌<sup>[8]</sup>에서 우리는 데이터의 각 bit마다 상대적인 중요도 (또는, 영상의 각 화소당 가중치)를 준 개선된 Hopfield 모델을 소개하였으며, 데이터의 각 bit의 상대적인 중요성에 대한 선행지식이 시스템의 오차 교정 능력을 개선시킨다는 것을 보였다.

여기서 우리는 화소당 가중치의 최적화를 통해서 저장된 각 영상간의 직교성 조건이 완화되고, 저장능력이 향상됨을 보이고자 한다. 또 참고문헌<sup>[8]</sup>에 소개된 광 곱셈과 벡터외적의 개념을 사용하여, 본 모델의 전기광학적 구현을 제안하였다.

## II. 화소당 가중치의 최적화

Hopfield 모델의 재생 알고리즘은 화소당 가중치를 도입한 경우,

$$\hat{v}_i^s = \sum_{j=1}^N T_{ij} w_j (2v_j^s - 1) \quad (1)$$

으로 입력  $v^s$ 에 의한 출력을 예측하고, 이를

$$v_i^s = \begin{cases} 1 & \text{if } \hat{v}_i^s > 0 \\ 0 & \text{otherwise} \end{cases}$$

로 thresholding하여 새로운 입력으로 재환하게 된다. 여기서 입력벡터  $v^s$ 는 각 요소가 +1 또는 0의 값을 갖는 unipolar binary vector이며,  $w_j$ 는 입력벡터의  $j$  번째 bit, 즉  $v_j^s$ 의 중요성을 나타내는 가중치 값이며, 모든  $w_j$ 는 0보다 큰 값으로 놓는다. 0을 기준치로 하는 thresholding에 의해,  $w_j$ 값의 절대적 크기는 문제되지 않고, 상대적 크기만이 중요하다.  $N$ 은 neuron의 수이며,  $T$ 는

$$T_{ij} = \sum_{s=1}^M (2v_i^s - 1)(2v_j^s - 1)$$

로 주어지는 연결 행렬이다.  $v^s (s=1, 2, \dots, M)$ 는 연상기억 하고자 하는  $M$ 개의 벡터이다. 표준 Hopfield 모델과는 달리  $T$ 의 대각선 성분을 0으로 놓지 않는 데, 이것은 연상기억 성능에 큰 변화를 주지 않는 것이 알려져 있다.<sup>[9]</sup>

만약 입력벡터  $v^s$ 가 저장된 어느 하나의 벡터와 같다면, 위 식(1)은

$$\hat{v}_i^s = (2v_i^s - 1) \sum_{j=1}^N w_j + \sum_{s \neq t} [(2v_i^s - 1)$$

$$\sum_{j=1}^N w_j (2v_j^s - 1)(2v_j^t - 1)] \quad (2)$$

과 같이 된다. 여기서 오른쪽 두번째 항은 입력벡터  $v^t$ 와 저장된 벡터  $v^s (s \neq t)$ 와의 상관관계에 따른 상관잡음(correlated noise)에 해당한다. 화소당 가중치  $w_j$ 에 대해서는  $(N-1)$ 개의 선택의 자유도가 있으므로, 아래와 같이 오차 최소화방법에 의해 주어진 저장벡터에 따른 상관잡음을 최소화 시킬 수 있게 된다. 즉 화소당 가중치 벡터  $w = [w_1, w_2, \dots, w_N]^T$ 가 모든 서로 다른  $(v^s, v^t)$ 쌍 ( $s, t=1, 2, \dots, M$ )에 대해 아래 관계식을 만족시킨다면

$$\sum_{j=1}^N (2v_j^s - 1)(2v_j^t - 1)w_j = 0, \quad (3)$$

식(2)에서의 상관잡음 항은 사라지고, thresholding을 통해서 재생기능을 성공적으로 수행하게 된다.

$M$ 개의 저장된 영상에 대해서, 서로 다른  $(v^s, v^t)$ 쌍의 수는  $L = M(M-1)/2$ 가 되며, 따라서  $L < N$ 이고, 각각의  $(v^s, v^t)$ 쌍에 대한 식(3)이 선형 독립(linearly independent)이라면, 식(3)을 만족시키는  $w$ 의 정확한 해를 구할 수 있게 된다. 만약 그렇지 않다면 최소자승평균 오차 알고리즘에 기초한 pseudo-inverse technique을 사용하여야 한다.<sup>[9]</sup>

최소자승평균 오차 알고리즘에 따라, 오차  $E(w)$ 는

$$E(w) = \sum_{s=1}^M \sum_{t=1}^{s-1} [ \sum_{j=1}^N (2v_j^s - 1)(2v_j^t - 1)w_j ]^2 / \left( \sum_{j=1}^N w_j \right)^2 \quad (4)$$

과 같이 정의되고, 오차를 최소화 시키는  $w$ 를 구하게 된다. 여기서  $E(w)$ 는  $\sum \sum$ 에 의해 모든  $(v^s, v^t)$ 쌍에 대한 상관잡음 오차를 구하여 합하고,  $N_w^2 = (\sum w_j)^2$ 로 normalize 시켰다.

식(4)는

$$E(w) = \frac{1}{N_w^2} w^T S w \quad (5)$$

과 같이 간소화 될 수 있으며, 여기서  $S$ 는  $N \times N$ 의 positive semi-definite matrix로서, 다음과 같다.

$$\begin{aligned} S_{ij} &= \sum_{s=1}^M \sum_{t=1}^{s-1} (2v_i^s - 1)(2v_i^t - 1)(2v_j^s - 1)(2v_j^t - 1) \\ &= \frac{1}{2} \left[ \sum_{s=1}^M \sum_{t=1}^M (2v_i^s - 1)(2v_j^s - 1)(2v_i^t - 1)(2v_j^t - 1) \right. \\ &\quad \left. - \sum_{s=1}^M (2v_i^s - 1)^2 (2v_j^s - 1)^2 \right] \\ &= \frac{(T_{ij}^2 - M)}{2} \end{aligned} \quad (6)$$

즉  $\sum_{s=1}^M \sum_{t=1}^M$ 으로 표시되는  $M^2$ 개 ( $\mathbf{v}^s, \mathbf{v}^t$ ) 쌍의 합에서,  $s=t$ 인  $M$ 개의 ( $\mathbf{v}^s, \mathbf{v}^s$ ) ( $s=1, 2, \dots, M$ ) 쌍을 뺀 것은,  $M(M-1)/2$ 개의 ( $\mathbf{v}^s, \mathbf{v}^t$ ) 쌍이 2번씩 들어 있는 경우가 되며,  $(2v_i^s - 1)^2$ 은 모든  $s, i$ 에서 1이 된다. 따라서  $\mathbf{S}$  matrix는  $\mathbf{v}^s$ 을 몰라도  $\mathbf{T}$  matrix로 부터 쉽게 구할 수 있음을 알 수 있다.

최대 경사법(steepest descent method)을 사용한 iterative minimization 과정에 따라  $\mathbf{w}$ 를 다음과 같이 update 시킨다.

$$\mathbf{w}^{k+1} = \mathbf{w}^k - \alpha \mathbf{g}^k \tag{7}$$

여기서  $k$ 는  $k$ 번째 iteration을 의미하며,  $\mathbf{g}$ 는 오차의 기울기로서,

$$\begin{aligned} \mathbf{g} &= \nabla E = \left( \mathbf{I} - \frac{\mathbf{w}}{N_w} \right)^T \mathbf{S} \mathbf{w} \times \frac{2}{N_w} \\ &= (\mathbf{S} \mathbf{w} - \mathbf{I} E N_w) \times \frac{2}{N_w} \end{aligned} \tag{8}$$

이며,  $\mathbf{I} = [1, 1, \dots, 1]^T$ 인 identity vector를 나타내고,  $N_w$ 는 앞에서  $\sum_{j=1}^N w_j$ 로 정의된 normalization factor이다. 그리고 scaling 계수  $\alpha$ 는 상수나, 또는 최적으로 계산된 값으로 놓을 수 있다. 위의 iteration은  $\alpha$ 값의 적당한 선택에 따라 수렴하게 된다. 최적의  $\alpha_{opt}$  값은  $E(\mathbf{w} - \alpha \mathbf{g})$ 의 최소화를 통해서 계산할 수 있으며, 다음과 같이 근사화 시킬 수 있다.

$$\alpha_{opt} = \mathbf{g}^T \mathbf{S} \mathbf{w} / \mathbf{g}^T \mathbf{S} \mathbf{g} \tag{9}$$

위 식에서 분모항은  $\mathbf{g}=0$ 가 아닌한 절대로 0이 되지 않으며, 모든 non-optimum  $\mathbf{w}$ 에 대해  $\alpha_{opt}$  값이 존재한다.

### III. 반복 적응 학습(recursive adaptive learning)

( $N-1$ )개의 영상이 이 연상기억 모델에  $\mathbf{T}(M-1)$ ,  $\mathbf{S}(M-1)$ 과 함께 저장되어 있고,  $M$ 번째의 영상인  $\mathbf{v}^M$ 을 추가로 저장하고자 한다고 가정한다. 그러면 Hopfield 모델의 Hebb의 학습 법칙에 따라  $\mathbf{T}(M)$ 과  $\mathbf{S}(M)$ 은

$$T_{ij}(M) = T_{ij}(M-1) + (2v_i^M - 1)(2v_j^M - 1) \tag{10}$$

$$S_{ij}(M) = S_{ij}(M-1) + (2v_i^M - 1)(2v_j^M - 1) T_{ij}(M-1) \tag{11}$$

과 같이 된다.  $\mathbf{T}$ 와  $\mathbf{S}$ 의 초기상태는

$$T_{ij}(0) = S_{ij}(0) = 0 \tag{12}$$

이며, 식(6)으로 부터  $S_{ij}(M)$ 은  $T_{ij}(M)$ 과  $M$ 으로 부터 쉽게 계산할 수 있다. 따라서 새로운 가중치 벡터

$\mathbf{w}(M)$ 은  $\mathbf{w}(M-1)$ 을 초기상태로 하여, 식(5), (7), (8)로 부터 구할 수 있다. 여기서 사용된 recursive learning algorithm은 다른 신경회로에서 사용되는 적응 학습 알고리즘과는 달리, 이미 학습된 영상에 대한 정보를 필요로 하지 않는다. 식(6)에 따라  $\mathbf{S}$ 를 계산하는 한  $\mathbf{T}$ 와  $M$ 만 알고 있으면 충분하다. 따라서 이 알고리즘은 학습시간과 계산에 필요한 메모리 용량을 대폭 줄일 수 있게 된다.

### IV. 시뮬레이션 결과

이 가중치 최적화 모델에 있어서 향상된 연상기억 능력을 컴퓨터 시뮬레이션을 통하여 설명하고자 한다.

그림 1에서 보인 매우 높은 상관관계를 가지는 10개의 영상을  $6 \times 8$  nodes를 가지는 우리의 모델에, "0"에서 부터 "9"까지 차례대로 위 3절에서 제시한 학습방법에 따라 학습시킨다.

그림 2는 식(5)에 따라 정의된 오차를 저장된 영상의 수에 대한 함수로 나타내었는데, 표준 Hopfield 모델과 가중치 최적화 모델에 대해 각각 나타내었다. 올바른 재생을 위해서는 오차의 값이 1보다 너무 커서는 안되므로, 그림 2로 부터 표준 hopfield 모델은 4개 이상의 영상은 기억할 수 없는데 비하여 가중치 최적화 모델은 10개 이상의 영상기억에도 충분히 사용될 수 있음을 알 수 있다.

그림 3~5는 각각의 저장된 영상에 대해, 요구되는 Hamming distance(서로 다른 bit의 수)를 만족시키는 1000개의 영상들을 무작위로 생성시켜서 각각의 연상기억 모델들에 입력시키고, 그 수렴하는 결과들을 수집한 것이다. 그림 3은 3개의 영상이 저장된




그림 1. 시뮬레이션을 위한 10개의 영상  
Fig. 1. Ten highly correlated images for simulation.

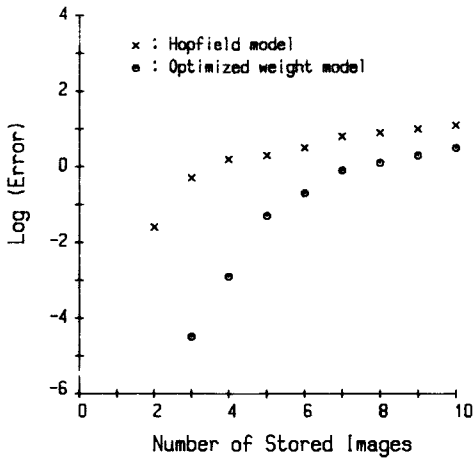


그림 2. “0”에서 “9”까지의 영상이 학습될 때, 저장되는 영상의 수와 오차와의 관계  
 Fig. 2. Error vs. number of stored images when images “0” to “9” are learned recursively.

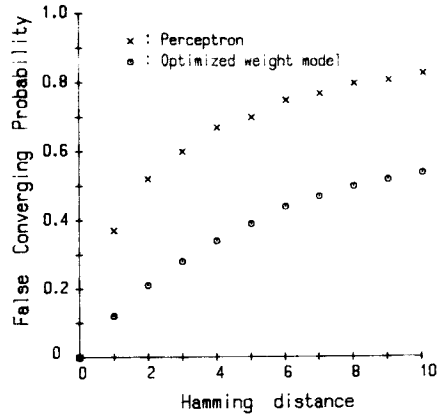


그림 4. 10개의 영상이 저장된 상태에서 그릇된 수렴 결과를 나타낼 확률과 Hamming distance와의 관계  
 Fig. 4. False converging rate vs. Hamming distance for 10 stored images.

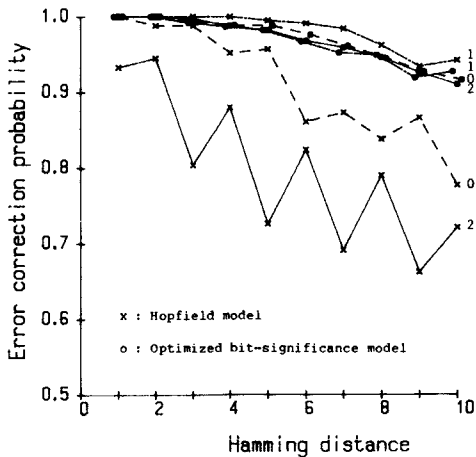


그림 3. 3개의 영상이 저장된 상태에서 오차 교정 확률과 Hamming distance간의 관계  
 x : 표준 Hopfield 모델  
 o : 가중치 최적화 모델  
 Fig. 3. Error correction probability vs. Hamming distance for 3 stored images.  
 x : Hopfield model.  
 o : Optimized bit-significance model.

상태에서 오차 교정 확률과 Hamming distance와의 관계를 나타내었다. 그림 4와 그림 5는 가중치 최적화 모델과 단층 인식자 모델 (single-layer perceptron) 사이의 연상능력을 10개의 영상이 저장된 상태에서 비교한 것이다. 그릇된 수렴결과를 나타내는 비율이 단층 인식자 모델에 비해 가중치 최적화 모델이 훨씬 낮음을 그림 4에서 알 수 있다.

그림 5에서는, 저장된 10개의 영상 각각에 대한 오차 교정 확률을 Hamming distance의 함수로 나타내었다. 이 그림에서 우리는 매우 흥미있는 결과를 발견하게 된다. 즉 상관관계가 매우 높은 “6”, “8”, “3”, “9” 같은 영상들이 상관관계가 비교적 낮은 “1”, “7”과 같은 영상들 보다 훨씬 더 많은 오차 교정 능력을 지닌다는 점이다. 반면에, 다른 많은 neural network처럼, perceptron도 서로 상관관계가 큰 영상에 대해서는 그림 5(b)에서 처럼 오차 교정 능력이 현저하게 떨어짐을 볼 수 있다. 이 점이 저장된 영상의 상관오차의 총합을 최소화시키는 가중치 최적화 모델의 가장 큰 특징이라 할 수 있다. 즉 식(4)에서 상관관계가 높은 영상에 관련된 상관오차 또한 서로 상관관계가 크게되어, 모든 상관오차의 합이 최소가 되기 위해서는 이들이 동시에 작아져야만 하기 때문이다. 같은 영상을 두번 수록한다고 하면, 그 영상 또한 매우 좋은 오차 보정 기능을 갖게 된다.





그림 5. 10개의 영상이 저장된 상태에서 오차 교정 확률과 Hamming distance간의 관계

- (a) 가중치 최적화 모델
- (b) 단층 인식자 모델

Fig. 5. Error correction probability vs. Hamming distance for 10 stored images.

- (a) Optimized-bit-significance model for the Hopfield model.
- (b) Single-layer perceptron.

V. 전기광학적 구현

신경회로의 전기·광학적 구현에는 많은 잇점이 있다.<sup>(11)</sup> 일반적으로 행렬-벡터 곱셈, 벡터 외적 등과 같은  $N^2$  order에 해당하는 연산은 광학적으로 처리하고, 복잡한 연산 과정이 요구되는 곳은 전기적으로 구현한다. 여기서는 가중치 최적화 모델의 전기·광학적 구현을 제안한다.

그림 6의 설계도에서, 광학적 부분은 참고문헌<sup>(12)</sup>의 perceptron의 광학적 구현과 매우 유사하다. Hebbian learning과 행렬-벡터 곱셈과 벡터 외적에 필요한 ADD mode<sup>(13)</sup>에는 microchannel spatial light modulator(MSLM)가 사용되었다. 그림 6에서 광학 lens는 모두 생략하였으며, 모든 SLM과 photo-detector들은 퍼스널 컴퓨터에 연결되어, 제어되는 것으로 하였다.




그림 6. 가중치 최적화 모델의 전기·광학적 구현을 위한 설계

Fig. 6. Design for electro-optic hybrid implementation of the optimized-bit-significance for the Hopfield model.

광을 이용한 행렬-벡터 곱셈의 잇점을 취하기 위해서는 음의 수에 대해 특별한 주의가 요구된다. Hopfield의 연결 강도  $T_{ij}$ 를

$$T_{ij}^* = \sum_{s=1}^M \frac{1}{2} [(2v_i^s - 1)(2v_j^s - 1) + 1] \quad (13)$$

$$T^* = \sum_{s=1}^M [v^s (v^s)^T + \bar{v}^s (\bar{v}^s)^T] \quad (14)$$

과 같이 변형시켜, 두번의 벡터 외적의 합으로 구현한다. 여기서  $\bar{v}^s$ 는  $\bar{v}^s = I - v^s$ 과 같은 관계를 가진다. 그러면  $S_{ij}$ 는

표 1. 학습과 재생과정

Table 1. Learning and recall procedures.

	MSLM	SLM1	SLM2	SLM3	SLM4	SLM5	PD1	PD2
<b>Learning</b>								
1. Calculate $\mathbf{v}^s (\mathbf{v}^s)^T$	ADD	$\mathbf{v}^s$	$\mathbf{v}^s$					
2. Calculate $\bar{\mathbf{v}}^s (\bar{\mathbf{v}}^s)^T$	ADD	$\bar{\mathbf{v}}^s$	$\bar{\mathbf{v}}^s$					
3. Calculate $\mathbf{T}^* \mathbf{w}$ and $\mathbf{S}^* \mathbf{w}$	READOUT			ON	$\mathbf{w}$	ON	$\mathbf{T}^* \mathbf{w}$	$\mathbf{S}^* \mathbf{w}$
4. Calculate $\mathbf{w}^T \mathbf{S}^* \mathbf{w}$	READOUT			ON	$\mathbf{w}$	$\mathbf{w}$	$\mathbf{T}^* \mathbf{w}$	$\mathbf{S}^* \mathbf{w}$
5. Calculate $\mathbf{g}^T \mathbf{S}^* \mathbf{w}$	READOUT			ON	$\mathbf{w}$	$\mathbf{g}$	$\mathbf{T}^* \mathbf{w}$	$\mathbf{g}^T \mathbf{S}^* \mathbf{w}$
6. Calculate $\mathbf{T}^* \mathbf{g}$ and $\mathbf{g}^T \mathbf{T}^* \mathbf{g}$	READOUT			ON	$\mathbf{g}$	$\mathbf{g}$	$\mathbf{T}^* \mathbf{g}$	$\mathbf{g}^T \mathbf{S}^* \mathbf{g}$
7. Calculate a new $\mathbf{w}$ .								
If not converged, go to step 3.								
<b>Recall</b>								
1. Calculate $\sum \mathbf{T}_{ij}^* \mathbf{w}_j \mathbf{v}_i$	READOUT			$\mathbf{v}^t$	$\mathbf{w}$			$\sum \mathbf{T}_{ij}^* \mathbf{w}_j \mathbf{v}_i$
2. Calculate a new $\mathbf{v}^t$ .								
If not converged, go to step 1.								

$$S_{ij} = 2(\mathbf{T}_{ij}^*)^2 - 2\mathbf{T}_{ij}^* + \frac{M(M-1)}{2} \quad (15)$$

과 같이 되며, N<sup>2</sup> order의 계산, 즉  $\mathbf{T}^* \mathbf{w}$ 와  $\mathbf{S}^* \mathbf{w}$ , ( $\mathbf{S}_{ij}^* = (\mathbf{T}_{ij}^*)^2$ )가 요구된다.

또한 원활한 재생을 위해서는 식(1)을 역시 변형할 필요가 있다. 즉 모든 계산 과정이 양의 숫자만 나타나도록

$$\hat{\mathbf{v}}_i = 4 \sum_j \mathbf{T}_{ij}^* \mathbf{w}_j \mathbf{v}_i - 2 \sum_j \mathbf{T}_{ij}^* \mathbf{w}_j - 2M \sum_j \mathbf{w}_j \mathbf{v}_i + M \sum_j \mathbf{w}_j \quad (16)$$

과 같이 변형시킨다. 학습과 재생과정은 표 1에 자세히 나타내었다.

MSLM (microchannel spatial light modulator)의 반사경면(M)의 반사율에  $\mathbf{T}_{ij}^*$ 를 수록하게 된다. 새로운 벡터  $\mathbf{v}^s$ 의 학습단계에서는 먼저  $\mathbf{v}^s$ 벡터가 SLM1과 SLM2의 투과율로 수록되어, 벡터 외적 방식에 의해  $(\mathbf{v}^s)^T \mathbf{v}^s$ 을 MSLM의 ADD mode 기능에 의해  $\mathbf{T}^* + (\mathbf{v}^s)^T \mathbf{v}^s$ 가 반사경축의 반사율로 수록된다. 다음에 SLM1과 SLM2의 투과율을  $\bar{\mathbf{v}}^s$ 로 하면,  $\mathbf{T}^* + (\mathbf{v}^s)^T \mathbf{v}^s + (\bar{\mathbf{v}}^s)^T \bar{\mathbf{v}}^s$ 가 되어 식(14)에 의한 연결 행렬이 MSLM에 수록된다.  $\mathbf{w}$ 의 최적화는 식(7)과 (8)에 의하는데, 식(15)에 의해  $\mathbf{S} \mathbf{w}$ 를 위해서는  $\mathbf{T}^* \mathbf{w}$ 와  $\mathbf{S}^* \mathbf{w}$ 의 계산이 필요한데, SLM4의 투과율을  $\mathbf{w}$ 로 하면 PD1과 PD2에 각각  $\mathbf{T}^* \mathbf{w}$ 와  $\mathbf{S}^* \mathbf{w}$ 가 감지된다. PD2앞에  $\mathbf{g}$ 를 투과율로 하는 SLM5를 두면,  $\mathbf{g}^T \mathbf{S}^* \mathbf{w}$ 가 쉽게 얻어진다. 같

은 방법으로 SLM4의 투과율을  $\mathbf{g}$ 로 하면, PD1과 PD2에  $\mathbf{T}^* \mathbf{g}$  및  $\mathbf{g}^T \mathbf{T}^* \mathbf{g}$ 를 얻게 된다. 재현 부분은 더욱 간단해져서, SLM3과 SLM4에 각각 입력  $\mathbf{v}^t$ 와 가중치  $\mathbf{w}$ 를 줌으로써, PD2에 식(16)의  $\sum \mathbf{T}_{ij}^* \mathbf{w}_j \mathbf{v}_i$ 항을 얻게 된다. 식(16)의 둘째항  $\sum \mathbf{T}_{ij}^* \mathbf{w}_j$ 는 앞의 학습과정에서 이미 계산되어 컴퓨터에 수록되어 있고, 나머지 계산들은 N에 비례하는 계산량만을 요구하므로 컴퓨터에서 쉽게 계산될 수 있다.

## VI. 결 론

Hopfield 모델에 화소당 가중치를 도입하고, 이를 최적화 시키는 문제를 다루었다. 그리고 제안된 모델의 전기·광학적 구현을 설계하였다. 또한 컴퓨터 시뮬레이션을 통하여 이 모델이 표준 Hopfield 모델이나, 단층 인식자 모델보다 더 좋은 성능을 나타냄을 보였다. 그리고 상관관계가 매우 큰 영상에 대해서는 다른 두 모델에 비해 훨씬 더 높은 오차 교정 능력을 나타냄을 보였다.

## 参 考 文 献

[1] J.J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proc. Natl. Acad. Sci. USA* 79, 2554-2558, 1982.

[2] D. Psaltis and N. Farhat, "Optical information processing based on associative memory model of neural nets with thresholding and feedback," *Opt. Lett.* 10, 98-100, 1985.

[3] B. Macukow and H.H. Arsenault, "Modification of the threshold condition for a content-addressable memory based on the Hopfield model," *Appl. Opt.* 26(1), 34-36, 1987.

[4] B. Macukow and H.H. Arsenault, "Optical associative memory model based on neural networks having variable interconnection weights," *Appl. Opt.* 26(5), 924-928, 1987.

[5] R.A. Athale, H.H. Szu, and C.B. Friedlander, "Optical implementation of associative memory with controlled nonlinearity in the correlation domain," *Opt. Lett.* 11(7), 482-484, 1986.

[6] S.Y. Lee, J.S. Jang, S.Y. Shin, and C.S. Shim, "Optical implementation of associative memory with controlled bit-significance," *Appl. Opt.* 27(11), 1921-1923, 1988.

[7] J.S. Jang, S.Y. Shin, and S.Y. Lee, "Optical implementation of quadratic associative memory," *Opt. Lett.* 13(8), 1988.

[8] R.A. Athale and W.C. Collins, "Optical matrix-matrix multiplier based on outer product decomposition," *Appl. Opt.* 21(12), 2089-2090, 1982.

[9] G.R. Gindi, A.F. Gmitro, and K. Parthasarathy, "Hopfield model associative memory with nonzero-diagonal terms in memory matrix," *Appl. Opt.* 27(1), 129-134, 1988.

[10] T. Kohonen, *Self-organization and Associative Memory*, pp. 177-182, Springer-Verlag, Berlin 1988.

[11] N.H. Farhat, "Optoelectronic analogs of self-programming neural nets: architecture and methodologies for implementing fast stochastic learning by simulated annealing," *Appl. Opt.* 26(23), 5093-5103, 1987.


[12] A.D. Fisher, W.L. Lippincott, and J.N. Lee, "Optical implementations of associative networks with versatile adaptive learning capabilities," *Appl. Opt.* 26(23), 5039-5054, 1987.

[13] C. Warde and J.I. Thackara, "Operating modes of the microchannel spatial light modulator," *Opt. Eng.* 22, 693-703, 1983.\*

著者紹介



**高相鎬 (準會員)**  
 1961年 2月 8日生. 1987年 2月 고려대학교 전자공학과 졸업. 현재 한국과학기술원 전기 및 전자공학과 석사과정. 주관심분야는 신경 회로 등임.



**沈昌燮 (正會員)**  
 1952年 5月 6日生. 1975年 서울대학교 응용물리학과 졸업. 1987年 한남대학교 물리학과 석사학위 취득. 1988年 한국과학기술원 전기 및 전자공학과 박사과정. 현재 한국전자통신연구소 광 통신 연구실장. 주관심분야는 신경회로의 광학적 구현분야 및 coherent 광 통신분야 등임.

**李壽永 (正會員)** 第25卷 第11號 參照  
 현재 한국과학기술원 전기 및 전자공학과 부교수

**張珠錫 (正會員)** 第25卷 第11號 參照  
 현재 한국과학기술원 전기 및 전자공학과 박사과정

**申相永 (正會員)** 第25卷 第8號 參照  
 현재 한국과학기술원 전기 및 전자공학과 교수