

論文94-31B-9-17

성능개선과 하드웨어구현을 위한 다층구조 양방향연상기억 신경회로망 모델

(A Multi-layer Bidirectional Associative Neural Network with Improved Robust Capability for Hardware Implementation)

鄭 東 奎, 李 壽 永

(Dong-Gyu Jeong and Soo-Young Lee)

要 約

본 논문에서는 하드웨어구현에 용이한 다층구조 신경회로망모델을 제안하고자 한다. 제안된 모델은 이진 패턴을 다루는 것으로 신경회로망의 응용과 구현이 용이하며, 자체의 성능개선 특성을 갖고 있다. 시냅스 weight에 제한을 가하여 시스템 complexity를 줄이는 기존의 방식과는 달리, 이 모델은 은닉층의 오차라는 새로운 개념을 도입하여 은닉층의 뉴런값(activation)에 제한(restriction)을 가함으로써 네트워크 자체의 성능을 개선하는 기능을 갖는다. 본 모델은 각 층에서 이진 형태를 갖는 메모리패턴이 존재하며, 시냅스 weight는 인접층간의 메모리패턴으로부터 Hebb 법칙에 의해 구해진다. 입력과 출력층의 메모리패턴은 Kosko의 양방향연상기억메모리와 같이 M개의 학습패턴으로 주어지며, 각 은닉층에서는 2M 수 많은 이진메모리패턴이 존재한다. 이 중 M개는 바로 위층의 메모리패턴과 작용하여 위부분의 시냅스 weight 매트릭스를 얻는데 기여하며 나머지 M개는 바로 아래층의 메모리패턴과 작용하여 위부분의 시냅스 weight 매트릭스를 얻는데 기여한다. 이들 은닉층의 메모리패턴은 초기의 랜덤한 이진패턴으로 시작하여 입력, 출력, 그리고 은닉층에서 정의되는 오차들의 함으로 구성된 전체오차를 감소하는 방향으로 유전알고리즘(genetic algorithm)에 의해 학습되어진다. 학습이 이루어진 후 recall은 양방향성을 갖는다. 패턴인식에 대한 시뮬레이션 결과가 MBANN 네트워크의 성능을 다층구조 형식인 BAM의 성능과 함께 상대적으로 설명해 주며, 아울러 양방향성에 의한 인식률의 향상을 설명해 준다.

Abstract

In this paper, we propose a multi-layer associative neural network structure suitable for hardware implementation with the function of performance refinement and improved robust capability. Unlike other methods which reduce network complexity by putting restrictions on synaptic weights, we are imposing a requirement on hidden layer neurons for the function. The proposed network has synaptic weights obtained by Hebbian rule between adjacent layer's memory patterns such as Kosko's BAM. This network can be extended to arbitrary multi-layer network trainable with Genetic algorithm for getting hidden layer memory patterns starting with initial random binary patterns. Learning is done to minimize newly defined network error. The newly defined error is composed of the errors at input, hidden, and output layers. After learning, we have bidirectional recall process for performance improvement of the network with one-shot recall. Experimental results carried out on pattern recognition problems demonstrate its performance according to the parameter which represents relative significance of the hidden layer error over the sum of input and output layer errors, show that the proposed model has much better performance than that of Kosko's bidirectional associative memory (BAM), and show the performance increment due to the bidirectionality in recall process.

I. 서론

아날로그 시냅스를 저장하는 신경회로망보다는 이진메모리(binary storage) 패턴을 저장하여 사용하는 것이 하드웨어구현에 매우 용이하다. 아울러, 신경회로망의 각층의 뉴런값(activation)이 이진형태인 경우에는 하드웨어구현이 더욱 유리하다. 그 장점을 보면, 첫째로 이진형태의 출력을 갖는 네트워크는 일단 학습이 이루어지면 threshold 출력기능을 갖는 단위(뉴런)는 아날로그방식보다 디지털방식이나 복합방식으로 구현하는 것이 저렴한 가격으로 편리하게 구현될 수 있으며, 둘째로 메모리패턴이 이진형태인 경우에는 SRAM(static RAM)^[1]과 같은 간단한 이진메모리소자로 쉽게 구현이 가능하다. 그리고, Hebb법칙으로부터 얻어지는 경우에는 내적구현이 가능하다. 특히, 시냅스가 Hebb법칙으로부터 얻어지고 이진형태의 뉴런값을 가질 때는 이진소자(VLSI 구현의 예)를 사용하여 내적 구현형식으로 대규모의 집적도를 갖는 하드웨어의 설계가 가능하다.^[2,3] Kosko의 BAM^[4]과 Hopfield 모델^[5]은 이러한 특성들을 갖춘 대표적인 신경회로망모델이다. 그러나, 이 모델들은 단층구조로 많은 성능의 제한을 받고 있다. 한편, 연상시에 one-shot recall 특성을 주는 신경회로망모델들은 잡음이 끼인 입력이 들어 와서 출력층의 메모리로 mapping 될때 약간의 잡음이 오류를 발생시킬 가능성이 많다.

본 논문에서는 단층구조의 문제점을 극복하고, Hopfield나 BAM 모델처럼 디지털 형식의 내적구현 특성을 살리면서, 아울러 one-shot recall 기능을 갖는 모델들의 문제점을 극복할 수 있는 다층구조 양방향신경회로망(Multi-layer Bidirectional Neural Network : MBANN)모델을 제안하고자 한다. 더우기, 이 모델에서는 기존의 방법들과는 다른 은닉층의 오차라는 새로운 개념을 도입하여 네트워크 자체의 성능개선(performance refinement and/or robust capability)을 하고자 시도하였다. 각 층에는 이진 형태의 메모리패턴이 주어지며, 시냅스 weight는 인접층의 메모리패턴에 의해 Hebb 법칙으로 구해진다. 이 모델에서는 출력층에서만 오차가 정의되는 기존의 방법들과는 달리 입력, 출력, 그리고 은닉층에서 정의되는 각 오차의 합인 전체오차를 감소하는 방향으로 유전알고리즘(genetic algorithm)^[6,7]에 의해 은닉층의 메모리패턴들이 최적화되는 학습법칙을 가진다. 출력층에서 정의되는 오차는 기존의 다층구조퍼셉트론에서 정의되는 형식과 같으며, 은닉층에서 정의되는 오차는 제안된 모델 자체의 성

능개선을 위해서 각 weighted sum이 Gaussian 함수를 거친값들의 합으로 얻어진다. 여기서, 자체의 성능개선이란 오차가 임출력층에서만 정의되었을 경우에 대해 성능의 개선을 의미한다. 그리고, 입력층에서의 오차는, 출력층 오차와 마찬가지로, 양방향특성을 주기 위해 출력층 학습패턴을 역전파시켰을때 입력층에서의 activation과 입력층 학습패턴과의 차의 자승으로 얻어진다. 이들 메모리패턴들로부터 Hebb법칙에 의해 시냅스 weight가 구해진다. 학습이 이루어진 후 recall은 양방향성을 갖는다. 패턴인식에 대한 시뮬레이션 결과가 MBANN 네트워크의 성능을 단층구조 형식인 BAM의 성능과 함께 상대적으로 보여주며, 아울러 양방향성에 의한 인식률의 증가 상태를 보여준다.

II. 네트워크 구조

MBANN 신경회로망 모델은 일반적으로 임의의 다층구조로 확장이 가능하다. 여기에서는 설명의 편의를 위해, 임의의 다층구조에서도 동일한 방법으로 적용될 수 있도록 일반성을 잃지 않는 범위내에서 2층의 구조(1 개의 은닉층 포함)를 갖는 MBANN에 대해 설명하기로 한다.

시냅스 weight가 Hebb 법칙으로 얻어지는 구조에서는 내적형태로 표현이 가능하다. 그림 1은 2층의 구조를 갖는 MBANN을 내적형태로 도시하였다.




그림 1. 2층 구조의 양방향연상기억 신경회로망 모델의 예

Fig. 1. 2-layer bidirectional associative neural network.

여기서, 은닉층에서는 학습패턴수 만큼의 메모리패턴쌍 ($V_s^{(1)}, U_s^{(1)}$), $s = 1, 2, \dots, M$, 이 존재하게 된다. 구체적으로 살펴보면, 입력의 메모리패턴 $U_s^{(0)}$, 은닉층의 메모리패턴쌍 ($V_s^{(1)}, U_s^{(1)}$), 그리고 출력층

의 메모리패턴 $V_s^{(2)}$ 가 그림 1과 같이 주어진다. 은닉층의 메모리패턴 $V_s^{(1)}$ 은 입력의 메모리패턴 $U_s^{(0)}$ 와 작용하여 아래쪽의 시냅스 weight $W^{(1)}$ 을 얻는데 기여하고, $U_s^{(1)}$ 은 출력층의 메모리패턴 $V_s^{(2)}$ 와 작용하여 위쪽의 시냅스 weight $W^{(2)}$ 를 얻는데 기여한다. 이들 시냅스의 성분 $w_{ij}^{(l)}$, $l = 1, 2$, 는 이들 메모리패턴을 사용하여 다음과 같이 Hebb 법칙에 의해 구해진다.

$$w_{ij}^{(l)} = \sum_s u_{s,i}^{(l-1)} v_{s,j}^{(l)}, \quad l = 1, 2 \quad (1)$$

여기서 $u_{s,k}^{(l)}$ 와 $v_{s,k}^{(l)}$ 은 각각 s번째 메모리패턴 $U_s^{(l)}$ 와 $V_s^{(l)}$ 의 k번째 뉴런에 대응되는 성분이다. 그리고, 입력과 출력층의 메모리패턴 $U_s^{(0)}$ 와 $V_s^{(2)}$ 는 각각 입력층 학습패턴 x^* 와 출력층 학습패턴 y^* 로 고정되어진다. 신호의 전파는 순방향과 역방향 모두 일어나며, 각 층의 뉴런값(activation)은 양방향 상태에서 다른값을 가진다. 예로써, 입력층의 s번째 학습패턴 x^s 가 순방향으로 전파될 때 j번째 은닉층 뉴런값 $h_{f,j}^s$ 과 i번째 출력층 뉴런값 $y_{f,i}^s$ 는 각각 다음과 같이 얻어진다.

$$\begin{aligned} h_{f,j}^s &= \text{sign}\left\{\sum_k w_{jk}^{(1)} x_k^s\right\}, \\ y_{f,i}^s &= \text{sign}\left\{\sum_j w_{ij}^{(2)} h_{f,j}^s\right\} \end{aligned} \quad (2)$$

한편, 출력층의 s번째 학습패턴 y^s 가 역방향으로 전파될때 대응되는 j번째 은닉층의 뉴런값 $h_{b,j}^s$ 와 k번째 입력뉴런의 값 $x_{b,k}^s$ 는 각각 식(3)과 같다. 여기서, x_k^s 와 y_i^s 는

$$\begin{aligned} h_{b,j}^s &= \text{sign}\left\{\sum_i w_{ij}^{(2)} y_i^s\right\}, \\ x_{b,k}^s &= \text{sign}\left\{\sum_j w_{jk}^{(1)} h_{b,j}^s\right\} \end{aligned} \quad (3)$$

각각 학습패턴 x^s 의 k번째 뉴런과 y^s 의 i번째 뉴런에 대응되는 성분이며, $\text{sign}\{t\}$ 은 sign 함수로 $t \geq 0$ 일때 1이고 그 이외의 t 값에 대해서는 -1의 값을 갖는다.

초기 학습이 끝나고 연상시에는 고정 시냅스 weights 상태에서 양방향 특성을 가진다. 이것은 입력층에 잡음이 끼었을 때 정확하게 출력층 메모리로 mapping 되지 않을 경우에 네트워크가 잘못 연상할 수 있는 one-shot recall 메모리의 단점을 극복하기 위해서이다. 즉, 초기 학습이 끝났을 때 학습으로 인한 메모리패턴 주위에 basin of attraction이 형성되는데, 이 때 입력신호가 잡음이 끼인 상태로 네트

워크에 인가되더라도 basin of attraction 내에 떨어지는 경우에는 모두 순방향과 역방향을 오가면서 잡음이 제거되어 자신의 메모리 패턴들을 올바르게 연상하게 된다. 그러나, 양방향 연상시에 우리가 원하지 않는 무한진동 사이클(unlimited cycle)이나 가짜메모리(spurious memories)가 생길 수 있으나 이 경우에는 뒤에서 설명될 은닉층의 오차함수 도입에 따라 학습된 메모리패턴들로 부터 어느정도 멀리 떨어져 있게 될 것이다.

III. 학습법칙 및 성능개선

MBANN 각층의 뉴런값은 weighted sum 으로 부터 그림 2와 같이 hard-limit 함수를 거쳐 취해진다.




그림 2. 하드리미트 함수
Fig. 2. Hard-limit function.

만약, 기존의 오차정의 방식처럼 출력층에만 오차가 정의된다면 학습이 끝나고 난 뒤 학습패턴을 네트워크에 인가했을 때 임의의 weighted sum 으로 부터 hard-limit 되어진다. 이러한 경우 네트워크의 학습은 학습패턴 자신에 대해서 입력층에서 출력층으로 mapping이 되도록 행하여지며, 잡음이 인가되었을 때에는 잡음의 정도에 따라 성능이 고르지 못한 원하지 않는 상태가 될 수도 있다. 즉, 잡음의 강도에 따라 인식률 (recall probability)의 매끄러운 정도(smoothness)가 일반적으로 고르지 못하는 특성을 보일 수도 있다. 더우기, 학습후 각 층의 뉴런값이 threshold 값 θ (여기서는 $\theta = 0$) 근처의 weighted sum 으로 부터 얻어진다면 잡음에 민감한 특성을 보일 것이다. 따라서, 학습이 끝난 후 학습시킨 패턴을 인가시켰을 때 weighted sum 이 threshold 값으로 부터 어느정도 멀리 떨어진 곳에 존재하도록 학습이 되어진다면 성능개선(perfor-

mance refinement and/or improved robust capability)이 이루어 질 것이다. 이러한 점을 고려하여 여기에서는 새로운 개념의 은닉층 오차를 도입하여 은닉층의 뉴런에 제한(restriction)을 가하여 성능을 개선시키는 MBANN 모델을 설명하고자 한다. 이러한 제한은 θ 값 부근에서 얻어지는 weighted sum을 θ 값으로부터 떨어지게 한다는 점에 강한 비중을 두고자 한다.

모든 은닉층의 메모리패턴 ($\mathbf{V}_s^{(1)}, \mathbf{U}_s^{(1)}$), $s = 1, 2, \dots, M$, 은 초기의 이진랜덤패턴으로 시작하여 전체 오차 E를 최소화하는 방향으로 학습을 통해 최적화되어진다. 즉, 입력층의 학습패턴(training pattern)을 순방향으로 전파시켰을 때의 출력층오차 E_f , 출력층의 학습패턴을 역방향으로 전파시켰을 때의 입력층 오차 E_b , 그리고 순방향과 역방향의 전파에 따른 은닉층의 오차 γE_h 의 합으로 식(4)와 같이 정의되는 전차오차 E를 최소화하는 방향으로 은닉층의 메모리패턴이 최적화되어진다.

$$E = E_f + E_b + \gamma E_h$$

$$= \sum_i E_i^f + \sum_s E_s^b + \gamma \left\{ \sum_i E_i^h + \sum_s E_s^h \right\}, \quad (4)$$

단,

$$E_i^f = \sum_j \left\{ y_j^f - f \left(\sum_k w_{jk}^{(2)} h_{kj}^s \right) \right\}^2, \quad E_s^b = \sum_i \left\{ x_i^s - f \left(\sum_j w_{ij}^{(1)} h_{ij}^s \right) \right\}^2,$$

$$E_i^h = \sum_j G \left\{ \sum_k w_{jk}^{(1)} x_k^s; 0, \sigma \right\}, \quad E_s^h = \sum_i G \left\{ \sum_j w_{ij}^{(2)} y_j^f; 0, \sigma \right\}.$$

여기서, γ 는 입력층과 출력층의 오차 ($E_f + E_b$)와 은닉층의 오차 E_h 의 상대적 중요도를 나타내는 상수이며, $f(\cdot)$ 는 비선형시그모이드 함수이며, 그리고 $G(t; \theta, \sigma)$ 는 평균이 θ 이고 표준편차가 σ 인 Gauss 함수이다.




그림 3. 은닉층의 각 뉴런에서 weighted sum 과 은닉층 오차와의 관계

Fig. 3. The contribution of each weighted sum to hidden error.

그림 3은 $t = 0$ 에서 $G(0; 0, 0.5) = 1$ 을 갖는 정규화된 Gauss 함수의 한 예로 은닉층의 각 뉴런에서 weighted sum의 은닉층 오차에 대한 기여도를 나타내 보인다. 여기서 σ 는 weighted sum이 θ 로부터 떨어진 정도에 따라 weighted sum 의 은닉층 오차에 대한 상대적 기여도를 말해 준다.

그런데, 각 층의 시냅스 weight는 M 개의 이전 메모리패턴으로 부터 Hebb 법칙에 의해 구해지므로 $-M \leq w_{ij}^{(l)} \leq M$, $l = 1, 2$, 사이의 한 정수값을 가지게 되므로, 은닉층 오차와 입출력층 오차에 대한 상대적 중요도를 나타내는 γ 를 너무 큰 값으로 주면 학습에 어려움을 주게 된다. 따라서, 학습이 잘 되도록 적절한 작은 γ 값을 주면 잡음에 민감한 특성은 보이지 않을 것이므로 성능개선의 효과를 가져올 것이다.

MBANN에서 은닉층의 메모리패턴은 초기의 이진랜덤패턴으로 시작하여 유전알고리즘에 의해 오차 E를 최소화되도록 선택되어진다. 학습절차는 아래와 같다.

- Generate initial population corresponding to initial hidden memory patterns, $G(0)$;
- evaluate $G(0)$;
- $n = 0$;
- repeat
 - $n = n + 1$;
 - generate $G(n)$ using $G(n-1)$;
 - evaluate $G(n)$;
- until condition of the learning is satisfied.

유전알고리즘에서 하나의 population은 임의의 개수를 갖는 chromosome이라는 구성인자들을 갖는다. 여기서, 각 chromosome은 그림1에서 은닉층의 모든 메모리 패턴을 포함하는 한 쌍의 시냅스 매트릭스 ($\mathbf{W}^{(1)}, \mathbf{W}^{(2)}$) 의 정보를 갖고 있으며, 서로 다른 chromosome은 서로 다른 쌍의 시냅스 매트릭스에 대한 정보를 갖고 있다. 각 chromosome은 서로 다른 적합도(fitness)를 갖게 되는데, 여기서 그 적합도는 n 개의 chromosome 각각이 메모리패턴으로 작용했을 때 MBANN에서 나오는 오차에 따라 오차가 가장 작은 chromosome 일수록 좋은 적합도를 갖도록 되어 있다. 초기에는 임의의 개수의 chromosome으로 시작하여, 새로운 chromosome의 생성을 위해서 population내의 모든 chromosome들 중에서 두 chromosome이 부모(parents)로 선택되어진다. 이 선택은 적합도가 좋은 chromosome에 높은 확률을

주어 랜덤하게 이루어진다. 선택된 parents에 유전 알고리즘의 기본요소인 mutation, cross over, inversion 등의 작용에 의해 새로운 후손 chromosome(child)이 생성된다. 새로 생성된 후손 chromosome은 기존의 chromosome에 포함되어 적합도를 따지게 된다. 이들 중 적합도가 가장 낮은 chromosome은 소멸되며, 이러한 반복작업은 population 중에 적합도가 가장 좋은 chromosome이 원하는 임계의 적합도를 가질 때 까지 계속된다. 이 과정이 학습과정으로 population 중에 임계값의 적합도를 갖는 chromosome이 얻어지면 학습은 끝나고 이것이 MBANN 은닉층의 최종 메모리패턴으로 사용되며, 나머지의 chromosome들은 버려진다.

은닉층의 뉴런값이 이진형태를 취할 경우 오차역전파기법은 학습법칙으로 적용될 수 없으므로, 본 연구에서는 최근에 활발한 연구가 진행되고 있는 유전알고리즘을 사용하였다. 시뮬레이티드 어닐링방식^{6,7)}도 이진패턴을 다룰 수 있으나, 이 방식은 초기에 랜덤하게 주어진 하나의 구성인자로부터 온도감소법(temperature reduction)을 사용하여 랜덤방식으로 전역최소치(global minima)를 찾아가는 방식이다. 반면에, 유전알고리즘은 초기의 많은 다른 환경에 랜덤하게 존재하는 여러 구성인자들로부터 전역최소치가 얻어질 때까지 효율적으로 재생과 도태의 과정을 거친다. 이 과정은 순수한 랜덤한 방식이 아니라 여러 인자들 사이에 우수한 성능을 갖는 인자에 많은 비중을 두어 진행되어지는 것으로, 마지막에 하나의 최우수 인자만이 선택되어진다. 따라서, 시뮬레이티드 어닐링 보다 더욱 일반적인 global search방식이라 할 수 있다.

IV. 시뮬레이션결과

제안된 MBANN 모델을 연상기억용으로 적용하여 보았다. 그림 4 ~ 그림 6은 입력력에서 각각 서로 다른 7개의 이진 랜덤패턴을 학습시키고 난 후 MBANN의 성능을 Kosko의 BAM의 성능과 함께 보여준다. [부록참조] 사용된 네트워크의 구조는 2개의 층(1개 은닉층 포함)을 갖는 것으로 입력, 은닉층, 출력층의 뉴런이 각각 35, 45, 35 개이다.

시뮬레이션에 사용된 이진랜덤패턴은 컴퓨터에 의해 발생되었다. 일반적으로 랜덤패턴이라 할지라도 발생된 패턴에 따라 학습후 약간의 성능 차이가 있으나, 본 논문에 제시된 것은 5번의 서로 다른 랜덤패턴세트에 대해 학습후 성능을 조사하였는데 수 % 정도의 오차차이를 보였으나 전체를 대표할 수 있다고

생각되는 중간 정도의 성능을 주는 패턴세트를 사용한 결과이다. 사용된 7개의 입력층 학습패턴 각각에 대한 Hamming 거리가 [표 1]에 보여지며, 대응되는 7개의 출력층 학습패턴 각각에 대한 Hamming 거리가 [표 2]에 보여진다. [부록] 각각의 표에서 대각선 부분은 자기자신과의 Hamming 거리이므로 영(zero)이 되며, 대각선 부분으로부터 대칭되는 부분에 있는 값은 동일한 값을 가지게 된다.

그림 4는 학습이 이루어진 후 인식률(recall probability)을 Hamming 거리의 함수로 도시되었는데, Hamming 거리는 학습패턴과 테스트패턴 사이에 몇 비트가 다른가를 나타내는 것이다. 사용된 테스트패턴은 7개의 학습패턴 각각에 대해 100개씩 랜덤하게 발생되었으며, 모든 랜덤패턴은 Hamming 거리를 만족하도록 구성되었다. 즉, 7개의 이진 랜덤패턴이 학습패턴으로 사용되었으며, 각 Hamming 거리에 대해 700 개의 테스트패턴이 랜덤하게 발생되어 테스트되어 졌다. 은닉층의 오차가 없는 경우($\gamma = 0$)에는 은닉층 오차가 고려된 경우보다 연상능력이 약하며 고르지 못하다. 비록, 테스트패턴에 잡음이 많이 끼인 경우에 해당되는 Hamming 거리가 큰 쪽에서는 γ 에 관계 없이 인식률을 낮고 은닉층의 오차 도입효과가 없으나, 실제로 우리가 사용할 때는 이 부분은 사용되지 않으며 관심이 없는 분야이다. 즉, 공학적인 측면에서 생각해 볼 때는 오인식률이 높은 분야는 별 쓸모가 없다. 오인식률이 낮은 부분에서는 은닉층의 오차도입이 오인식률을 감소시켜 주고, Hamming 거리에 따라 은닉층오차를 도입하지 않는 경우보다 smooth한 성능을 주고 있다. 그런데, 큰 γ 값을 주면 학습시간이 상당히 오래걸리거나 학습이 잘 안되는 일이 생기므로 일반적으로 작은 값이 유효하다. 이것은 시냅스 weight 값이 임의의 아날로그 값을 취하는 것이 아니라 네트워크구조상 M에서 -M 사이의 어느한 정수값으로 제한되기 때문으로 생각된다.

그림 5는 7개의 랜덤패턴쌍(입력층, 출력층)을 제안된 MBANN과 Kosko의 BAM 모델에 동일하게 적용했을 때의 인식률을 보이고 있다. 여기서, BAM은 단층구조로서 자신의 패턴(Hamming 거리 = 0)에 대해서도 제대로 인식을 못하고 있는 반면에, MBANN 모델은 자신들을 올바르게 인식할 뿐만 아니라 BAM 보다 훨씬 우수한 성능을 보여주고 있다.

그림 6은 그림 5에서 학습된 MBANN($\gamma = 0.1$)의 연상시에 양방향특성을 나타낸 것으로, 학습이 끝난 후 테스트패턴을 인가하였을 때 순방향과 역방향을 오가는 과정에서 인식률의 증가상태를 나타내 보이고

있다. 즉, 테스트패턴을 인가하여 순방향으로 한번 전파 시켜 출력측에서 나타나는 인식률을 기준으로, 역방향과 순방향을 1회째 더 왕복했을 때의 인식률 향상분, 2회째 인식률 향상분, 그리고 3회째 인식률 향상분, 그리고 이들의 합인 양방향성에 기인한 인식률 향상분을 도시하고 있다. 이 결과는 one-shot recall (순방향으로 한번 전파되었을 때 인식률) 특성을 갖는 네트워크에 비해 성능의 향상을 가져옴을 설명해 주고 있다.

V. 결론

제안된 MBANN 모델은 구조상 이진화 storage 를 가지므로 하드웨어구현시에 SRAM과 같은 간단한 이진소자로 처리가 가능하고, 이진화 상태의 뉴런 값을 가지므로 구현이 용이하다. 그리고, 이진신호 처리와 함께 시냅스 weight가 Hebb법칙으로부터 얻어지므로, 내적구현방법으로 대규모 집적도를 갖는 신경회로망 하드웨어의 구현이 가능하다. 학습법칙으로는 최근에 활발히 연구되고 있는 global search 방식인 유전알고리즘을 사용하였다. 아울러, 단층구조가 갖는 성능의 제한성을 다층구조로 해결해 줌과 동시에 은닉층의 오차라는 새로운 개념을 도입하여 네트워크 자체의 성능향상을 꾀하였다.

부록




그림 4. 은닉층 오차의 상대적 중요도를 나타내는 γ 를 파라메타로 Hamming 거리에 따른 MBANN 의 인식률. 여기서, "o", "●", 그리고 "x" 는 각각 $\gamma = 0.0, 0.05, 0.1$ 일 때 Hamming 거리에 따른 인식률을 나타냄
Fig. 4. Recall probabilities of the MBANN to Hamming distance according to the parameter γ . Here "o", "●", and "x" denote the recall performances with $\gamma = 0.0, 0.05, 0.1$, respectively.




그림 5. MBANN($\gamma = 0.1$)과 Kosko의 BAM과의 인식률 비교. 여기서, "o"와 "x" 는 각각 MBANN과 BAM의 Hamming 거리에 따른 인식률을 나타냄
Fig. 5. Comparison of the recall probabilities to Hamming distance between MBANN($\gamma = 0.1$) and Kosko's BAM. Here "o" and "x" denote the recall probabilities of the MBANN and the BAM, respectively.




그림 6. 연상시 MBANN($\gamma = 0.5$)의 양방향연상 특성. 여기서 "●", "x", "□", 그리고 "o" 는 각각, 테스트패턴을 입력하여 순방향으로 한번 전파되었을 때의 성능을 기준으로 1회째 더 순방향과 역방향을 왕복하였을 때의 인식률 증가분, 2회째 왕복하였을 때 증가분, 3회째 왕복하였을 때의 증가분, 그리고 이들의 합인 양방향성에 의한 총 인식률 증가분을 나타내고 있다.
Fig. 6. Incremental performances of MBANN($g=0.5$) due to the bidirectionality with reference recall probability due to the first feedforward propagation in recall process. Here "●", "x", "□", and "o" indicate performance improvements by one back-and-forth recall, twice back-and-forth recall, triple back-and-forth recursive recall, and total performance improvement, respectively.

표 1. 입력층에 인가된 학습패턴 상호간의 Hamming 거리

Table 1. Hamming distance between training patterns in input layer.

패턴No 패턴No	1	2	3	4	5	6	7
1	0	17	13	18	14	17	22
2	17	0	19	12	16	22	18
3	13	19	0	14	24	15	18
4	18	12	14	0	17	14	15
5	14	16	24	17	0	12	21
6	17	22	15	14	12	0	18
7	22	18	18	15	21	18	0

표 2. 출력층에 인가된 학습패턴 상호간의 Hamming 거리

Table 2. Hamming distance between training patterns in output layer.

패턴No 패턴No	1	2	3	4	5	6	7
1	0	17	17	13	21	12	16
2	17	0	19	19	19	22	18
3	17	19	0	17	21	18	22
4	13	19	17	0	15	24	20
5	21	19	21	15	0	20	16
6	12	22	18	24	20	0	17
7	16	18	22	20	16	17	0

參 考 文 獻

[1] N. H. E. Weste, K. Eshraghian, *Principles of CMOS VLSI Design : A systems Perspective*, Addison-Wesley Pub. Comp., pp. 351 - 353, 1988.

[2] 최윤경, 정동규, 이수영, "내적구현 신경회로망 chip을 이용한 확장가능한 다층구조양방향 연상기억메모리 Board 설계," 제1회 신경망 및 퍼지시스템 종합학술대회 및 전시회, 1991. 11. 7

[3] 최윤경, 정동규, 이수영, "다층구조 양방향연상기억 메모리의 집적회로구현," 제2회 신경회로망연구회 연차총회 및 학술대회 논문집, pp. 54 - 58, 1991. 6. 1

[4] B. Kosko, "Bidirectional associative memories," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 18, No. 1, pp. 49 - 60, 1988.

[5] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proc. of the National Academy of Sciences* 79:2554 - 2558, 1982.

[6] D. E. Goldberg, *Genetic Algorithm in Search, Optimization, and Machine Learning*, Addison-Wesley, Pub. Comp., New York, 1989.

[7] L. Davis, *Handbook of Genetic Algorithms*, Van Nostrand Reinhold, New York, 1989.

[8] E. Aarts, J. Korst, *Simulated Annealing and Boltzmann Machines*, John Wiley & Sons, New York, 1989.

[9] P. D. Wasserman, *Neural computing : Theory and Practices*, Van Nostrand Reinhold, New York, Chap. 5, 1989

著 者 紹 介

鄭 東 奎(正會員) 第 30卷 B編 第 6號 參照
한국과학기술원 박사과정

李 壽 永(正會員) 第 30卷 B編 第 6號 參照
한국과학기술원 교수