

論文94-31B-12-14

## 변형하이브리드 학습규칙의 구현에 관한 연구

### (A Study on the Implementation of Modified Hybrid Learning Rule)

宋道善\*, 金錫東\*\*, 李幸世\*\*\*

(Do Sun Song, Seok Dong Kim and Haing Sei Lee)

#### 要約

본 논문에서는 패턴 분류기능(Classifier)이 우수한 BP알고리듬과 입력의 특징추출기능(Feature Extractor)이 우수한 Hebbian을 변화 시킨 변형 Hebb학습규칙을 결합한 변형하이브리드 학습규칙(Modified Hybrid Learning Rule)을 제안한다.

다층구조에 오차역전파 학습규칙과 변형된 Hebb학습규칙이 동시에 적용된 변형하이브리드학습규칙은 제안되었던 하이브리드 학습규칙과 같이 학습시에 입력층과 은닉층 사이의 연결강도 계산에만 변형하이브리드(변형 Hebbian + BP) 학습규칙을 적용하고 은닉층에서 출력층까지는 BP 학습규칙으로 구현하였다.

성능 평가를 위하여 몬테카로 방법으로 BP와 하이브리드 및 변형된 하이브리드로 시뮬레이션 한 결과 인식률에서 BP보다는 하이브리드가, 하이브리드 보다는 변형하이브리드가 우수함을 나타내었다. 학습속도는 하이브리드와 변형하이브리드가 유사하였고 BP는 매우 느리다.

#### Abstract

A modified Hybrid learning rule(MHLR) is proposed, which is derived from combining the Back Propagation algorithm that is known as an excellent classifier with modified Hebbian by changing the orginal Hebbian which is a good feature extractor.

The network architecture of MHLR is multi-layered neural network.

The weights of MHLR are calculated from sum of the weight of BP and the weight of modified Hebbian between input layer and hidden layer, and from the weight of BP between hidden layer and output layer.

To evaluate the performance, BP, MHLR and the proposed Hybrid learning rule(HLR) are simulated by Monte Carlo method.

As the result, MHLR is the best in recognition rate and HLR is the second. In learning speed, HLR and MHLR are much the same, while BP is relatively slow.

\* 正會員, 中京工業専門大學 電子計算機科  
(Dept. of Computer Eng., Jungkyung College)

\*\* 正會員, 湖西大學校 電子計算機科  
(Dept. of Computer Science, Hoseo Univ.)

\*\*\* 正會員, 亞州大學校 電子工學科  
(Dept. of Elec. Eng., Ajou Univ.)

接受日字：1994年 6月 22日

## I. 서 론

컴퓨터가 인간과 같은 지적활동을 할 수 있도록 하는 연구는 오래전부터 연구되어져 왔고 지금도 연구 되는 어려운 과제중의 하나이다. 그 중에서 인간의 뇌의 신경 구조와 유사한 신경망을 이용한 음성인식이나 문자인식이 미래에 우수한 인식 방법의 한 종류가 될 것이라 예견되어 이 분야에 대한 많은 연구<sup>[1,2]</sup>가 되어져 왔다.

신경망을 이용한 음성 및 문자인식은 대부분 지도 학습인 오차역전파(BP : Back-Propagation)기법을 이용한 것으로 BP알고리듬은 입력패턴을 분류하는 기능(Classifier)은 매우 우수하나 학습시간이 느린 단점<sup>[3,4]</sup>이 있다.

자율학습인 Hebb학습법의 알고리듬을 신경망에 적용한 Hopfield Net.와 B. Kosko가 제안한 BAM(Bidirectional Associative Memory)등<sup>[5,6,7]</sup>이 있다. 그러나 위의 두 신경망모델은 단층 구조(Single Layer)로 구성되므로 학습속도나 특징 추출 기능(Feature Extractor)은 우수하지만 학습패턴의 저장능력이 매우 제한되고 선형적 분리가 되지 않는 문제에는 적응할 수 없는 단점<sup>[8,9,10,11]</sup>이 있다.

최근에는 BP와 Hebb 학습법을 결합한 하이브리드 학습법으로 BP학습시의 우수한 패턴 분류능력과 Hebb학습시의 특징 추출 기능의 장점을 동시에 살리기 위하여 연구가 되어지고 있으며 R.J. Wood가 제안한 하이브리드 학습규칙은 실험결과가 만족할 만한 정도가 아니며 특히 출력층까지 하이브리드규칙이 적용<sup>[12]</sup>되어 있다.

이러한 단점을 보완하고 인식률을 향상시키는 새로운 하이브리드 학습알고리듬을 제안하고 구현하여 하이브리드 학습법의 우수성<sup>[13,14]</sup>을 입증하였고 이 학습 법은 입력층과 은닉층들에서는 패턴의 분류기능과 특징추출기능이 수행되게 하고 마지막 은닉층과 출력층에서는 분류기능을 수행하게하여 성능을 향상되게 하는 것이다. 그러나 제안되었던 하이브리드규칙은 헤브 룰이 일반적으로 적은값( $0 < \alpha \leq 0.1$ )이므로 최적의 성능이 나타나는 Hebb룰의 범위가 제한되기때문에 헤브룰이 크고 최적의 헤브룰의 범위도 크며 인식률도 더 향상된 하이브리드 학습법이 요구되었다.

음성인식을 다루는 경우에는 전처리를 할지라도 방대한 데이터의 양을 처리해야하므로 신경망에서 학습 데이터로 이용할 때는 학습시간과 인식률에 많은 관심이 주어진다. 특히 음성인식시는 LPC나 PAR-COR 계수로 나타나는 특징값을 대부분 인식 데이터로 한다. 이 계수들도 모음이나 단음을 인식이 잘 되

지만 잡음이 있거나 연속음성시는 시간에따라 전체적인 특징은 비슷하지만 인식이 잘 되지 않으므로 이 계수들에서 또다시 특징추출을 신경망으로 흡수 하여 인식할려고 하는 것이 본 연구를 하는 목적이다.

따라서 본 연구는 잡음이 있는 음성인식과 연속음성 인식을 하기위한 기초 연구로서 학습시간은 제안되었던 하이브리드와 유사하고 인식률은 하이브리드보다 우수한 변형된 하이브리드학습의 알고리듬을 제안하는 것으로서 II장에서는 제안되었던 하이브리드 학습규칙을 서술하고 변형하이브리드 학습규칙을 제안 한다.

실험및 결과에서는 제안되었던 하이브리드학습과같이 몬테칼로(Monte Carlo)방법으로 랜덤함수에서 발생되는 좌표점이 어떤 영역에 존재하는지를 인식하는 문제로서 두개의 원이 조금 겹치게 한 후 겹치는 영역과 나머지 영역을 구분하는 문제와 삼각형 4개의 영역을 구분하는 문제 및 두개의 사각형이 겹치게 한 후 영역을 구분하는 문제를 설정하여 BP와 하이브리드 및 변형하이브리드의 성능을 각각 분석 비교하였다. 본 논문에서 표 1과 2의 (a)의 실험결과는 논문<sup>[13]</sup>과 같다. 제안된 학습법 구현은 학습시 입력층과 은닉층 사이의 연결강도 계산에만 변형하이브리드(변형Hebbian + BP)학습규칙을 적용하고 은닉층에서 출력층까지는 BP학습규칙을 구현 하였으며 이것은 Hebb규칙이 출력층에 적용될경우 학습시의 수렴성에 어려움을 줄 가능성도 있기 때문이다.

## II. 변형하이브리드 학습법(Modified Hybrid Learning Rule)

R.J. Wood가 제안한 하이브리드 알고리듬은 식 (8)<sup>[15]</sup>이며 과정은 다음과 같다. 오차역전파(BP) 알고리듬의 weight수정은 식 (1)로 된다.

$$W_{ji}(n+1) = W_{ji}(n) + \Delta W_{ji} \quad (1)$$

식 (1)의  $\Delta W_{ji}$ 는 식 (2)와 같고 식 (3) 및 식 (4)를 이용하여 출력층 및 은닉층의  $\Delta W_{ji}$ 를 계산한다.

$$\Delta W_{ji} = \eta \delta_j O_i \quad (2)$$

여기서  $\delta_j$ 는 식 (3)과 같다.

$$\delta_j = O_j(I - O_j)E_j \quad (3)$$

식 (2)에서  $E_j$ 는 식 (4.1)과 식 (4.2)로 나누어 진다.

$$E_j = t_j - O_j \quad (4.1) \quad (\text{출력총})$$

$$E_j = \sum_k \delta_k W_{kj} \quad (4.2) \quad (\text{온닉총})$$

식 (2)는 BP알고리듬의 Update에 관한 것이며 식 (4.1)을 식 (3)에 대입할 경우 출력총에 대한 델타식이고 식 (4.2)를 대입하면 온닉총에 대한 델타식이다. 또  $O_i, O_j$ 는 뉴런  $j, i$ 의 실제 출력값이며 식 (4.1)의  $t_j$ 는  $j$ 가 출력총일때 뉴런  $j$ 의 목표값이다.  $\Delta W_{ji}$ 는 뉴런  $i$ 에서 뉴런  $j$ 사이의 연결강도의 변화량이며  $\eta$ 은 학습계수이다.  $E_j$ 는 뉴런  $j$ 에서의 오차를 나타내며 식 (4.2)에서  $j$ 가 온닉총을 나타낼때  $K$ 는 출력총을 의미한다. Hebb학습법은 식 (5)로 정의된다.

$$\Delta W_{ji} = K_a + K_b(O_i - \theta_i)(O_j - \theta_j) \quad (5)$$

여기서  $O_i, O_j$ 는 뉴런  $j, i$ 의 출력이며  $K_a, K_b, \theta_i, \theta_j$ 는 상수다.  $\Delta W_{ji}$ 는 Hebbian규칙에서 Update시킬 값이다. 식 (5)에  $K_a = 0, K_b = \eta, \theta_i = \theta_j = 0$ , 식 (2)에  $\delta$ 를 적용하면 각각 식 (2)은 식 (6)로, 식 (5)는 식 (7)로 된다.

$$\Delta W_{ji} = \eta O_i O_j (1 - O_j) E_j \quad (6)$$

$$\Delta W_{ji} = \eta O_i O_j \quad (7)$$

식 (6)과 식 (7)을 결합하면 식 (8)이 된다.

$$\Delta W_{ji} = \eta O_i O_j [(1 - \beta) + \beta E_j (1 - O_j)] \quad (8)$$

식 (6)과 식 (8)에서  $E_j$ 는  $E_j$ 이며 이것은 식 (2)의 계산식 온닉총이면 식 (4.2)가 출력총이면 식 (4.1)이 사용된다. 식 (8)은 R.J.Wood가 제안한 하이브리드 학습규칙이며 온닉총과 출력총에 모두 사용되어 있고  $\beta$ 는 하이브리드 학습시 사용되어지는 BP와 Hebbian의 크기를 결정해준다. 여기서 하이브리드 학습규칙이란 신경망의 학습규칙 2개를 결합한 것을 의미한다.

식 (8)의 문제점은  $W_{ji}$ 가 발산할 수 있으므로  $W_{ji}$ 를 유한값으로 제한 해야 하고, 또  $\beta$ 에 의하여 BP의 크기가 임의적으로 억제된다. 위와 같은 결과로 R.J.Wood의 연구논문에서 서술된 바와 같이 학습속도 및 인식률이나 패턴분류기능이 BP보다 우수하지 못한결과로 나타난다. 이러한 문제점을 세기하기 위해서 식 (9)을 제안하였다.<sup>[1][4]</sup>

$$\Delta W_{ji} = \Delta W_{ji} = \Delta W_{BP} + \Delta W_{Hebb} = \eta O_i f'(o_j^k) E_j + \alpha O_i O_j \delta_j \quad (9)$$

식 (9)에서  $\Delta W_{ji}$ 는 제안되었던 하이브리드 학습법이며,  $\eta O_i f'(o_j^k) E_j$ 는 BP학습법을,  $\alpha O_i O_j \delta_j$ 는 Hebb학습법을 나타낸다. 또  $\alpha$ 는  $\Delta W_{BP}$ 에대한  $\Delta W_{Hebb}$ 의 비를 나타내는 상수로 해브률(Hebb rate)이라하자. 식 (9)의 Hebb항에서  $O_i$ 는 입력총뉴런의 출력을  $O_i$ 는 온닉총뉴런의 출력을 의미하며  $\delta_j = |f'(o_j^k)| E_j$ 이며  $E_j$ 는 온닉총의 오차다. BP항에서  $f'(o_j^k)$ 는 온닉총 뉴런의 비선형함수 미분이고  $o_j^k$ 은  $j$ 번재 뉴런의 net값이다. 식 (9)는 온닉총에만 사용된다. 식 (9)의 비선형 함수는  $f(x) = (2/(1 + e^x) - 1)$ 을 사용한다.

하이브리드 학습시 BP항은 오차가 적어지는 방향으로 학습되고 오차가 적어지면  $\delta_j$ 도 적어진다. 따라서  $W_{ji}$ 가 발산하지 않고 수렴한다. 또 입력과 출력의 상관관계에 따라  $W_{ji}$ 가 자연스럽게 결정된다. 즉 BP 학습은 사면하강법(gradient descent)을 사용하기 때문에 BP학습의 출력총은 항상 출력오차가 적어지는 방향으로 학습되며 각 온닉총도 BP학습법과 Hebbian을 결합한 하이브리드 학습법으로 학습함으로 출력총에서는 수렴을 항상 보장하고 온닉총에서는 수렴과 특징추출기능이 동시에 이루어진다. 이러한 결과로 Hybird학습법은 BP의 학습속도 보다 빠르며 인식률도 BP보다 우수한 것으로 나타났다.

식 (9)는 논문[13]에서 나타났듯이 해브률  $\alpha$ 의 값이 적으므로 최고빠른 수렴속도나 최고의 인식률을 가질수 있는 최적의 범위가 너무 제한된다. 본 연구에서는  $\alpha$ 의 범위가 크고 인식률이 향상될수 있는 변형된 하이브리드 즉 식 (10)을 제안한다.

$$\Delta W_{ji} = \Delta W_{ji} = \Delta W_{BP} + \Delta W_{Hebb} = \eta O_i [(1 - O_j) E_j + \alpha (O_i + \theta_j) (O_i + \theta_j) \delta_j] \quad (10)$$

식 (10)의 Hebb항에서  $\delta_j = O_j (1 - O_j) E_j$ 이며  $\theta$ 는 바이어스항이다. 또 식 (10)의 비선형 함수는  $f(x) = 1/(1 + e^{-x})$ 를 사용한다.

식 (9)는 Hebb항이 두 뉴런의 상관관계를 델타의 절대치를 취함으로서 크기만 자연스럽게 제어하지만 식 (10)의 델타가 두 뉴런의 상관관계를 크기뿐만 아니라 위상까지도 출력총의 오차 크기의 관계에 따라 자연스럽게 제어하며 이것때문에 학습속도는 식 (9)보다 저조 할수도 있으나 인식률은 개선될수 있다. 또 식 (10)의 Hebb항의 크기를 BP에서 전이되는 절대치 델타가 아니고 전이되는 델타로만 제어하기 때문에 징통 Hebbian이라 할 수 없어 식 (10)을 변형

하이브리드라고 하자.

식 (9)와 식 (10)에서 헤브를  $\alpha$  가 0이면 BP 학습이 되고  $\alpha$  가 너무크면 Hebb학습만 된다. 따라서 BP학습도 아니고 Hebb학습도 아닌 최적의 성능이 나타나는 Hebb률의 선택이 요구된다.

### III. 실험 및 결과 분석

#### 1. 신경망 구성

식 (2)의 BP학습 및 식 (9), 식 (10)에서 제안된 하이브리드 학습을 구현하기 위한 신경망의 구조는 MLP이며 입력층·은닉층·출력층으로 하였다.

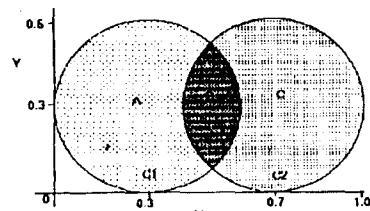
Structure는 입력 뉴런은 2개, 은닉 뉴런은 10개, 출력 뉴런은 3개 및 4개이고 비선형함수는 하이브리드는 bipolar 함수이고 변형하이브리드는 unipolar 함수를 사용했다.

학습시 입력층과 은닉층은 하이브리드학습 및 변형하이브리드 학습을 적용하고, 출력층은 BP만 적용하였고 학습은 전체패턴의 누적오차( $1/2\sum E^2$ )가 허용오차 범위에 있으면 학습된 것으로 하였다.

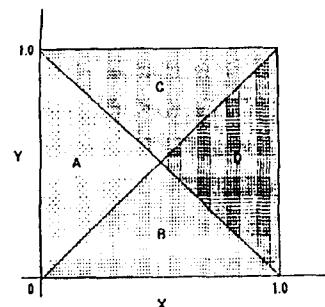
#### 2. 실험 데이터 구성

신경망에 적용할 실험 데이터는 두개의 랜덤 함수에서 생성되는 두수를  $X = \text{RAND}(\text{seed}1)$ 과  $Y = \text{RAND}(\text{seed}2)$ 라 하며 두개의 랜덤 함수에서 발생되는  $X, Y$ 의 두수를 좌표좌표의 좌표점( $X, Y$ )이라 하자. 랜덤함수를 연속적으로 사용하여 좌표점{( $X_0, Y_0$ ), ( $X_1, Y_1$ ), ..., ( $X_n, Y_n$ )}를 산출한다. 랜덤함수에서 산출되는 좌표점을 A, B, C, D그룹으로 분류하여 신경망의 학습데이터로 산출한다. A, B, C, D그룹으로 분류하는 경계조건은 그림 1의 (a), (b), (c)와 같다.

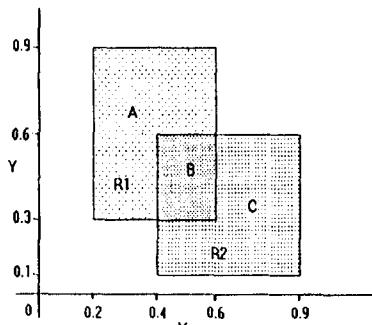
그림 1의 (a)는 두개의 원을 각각 C1, C2라 하고 겹치게 하였다. 원의 중심점의 좌표가 C1는 (0.3, 0.3)이고 C2는 (0.7, 0.3)이며 반지름은 0.3이다. 원 C1과 원 C2가 겹치는 부분을 B영역이라 하고 나머지는 각각 A, B영역으로 하였다. (b)는 가로와 세로가 1인 정사각형으로서 4개의 삼각형 영역 구분은 좌표(0,0)에서 좌표(1,1)로 그린 대각선과 좌표(1,0)에서 좌표(0,1)로 그린 대각선으로 구분된 A, B, C, D의 영역이다. (c)는 가로 세로의 길이가 다른 두개의 사각형으로 구성되며 사각형 R1은 4개의 좌표가 각각 (0.2, 0.3), (0.2, 0.9), (0.6, 0.3), (0.6, 0.9)이고 사각형 R2는 (0.4, 0.1), (0.4, 0.6), (0.9, 0.1), (0.9, 0.6)으로 이루어지며 두개의 사각형이 겹치는 부분을 B 나머지를 A와 C로 구분하였다. 그림 1의 (a), (b), (c)의 영역구분시 선 및 곡선위에 나타나는 좌표점은 제외했다.



(a)



(b)



(c)

그림 1. A, B, C, D영역 구분을 위한 경계 조건  
(a) 원의 경계 조건 (b) 삼각형의 경계 조건 (c) 사각형의 경계 조건

Fig 1. Boundary Conditions for the A, B, C, D Groups. (a) Boundary Condition of the Circle (b) Boundary Condition of the triangular (c) Boundary Condition of the Rectangle

#### 3. 구현 및 결과 분석

식 (2) 및 식 (9)의 성능과 제안된 식 (10)의 성능을 비교하기 위해 그림 1의 A, B, C, D영역 구분을

위한 본데칼로 방법은 다음과 같다.

첫째, A, B, C, D영역으로 분류되는 데이터 400개씩을 산출 한다.

둘째, A, B, C, D영역에서 각각 100개의 데이터를 A, B, C, D영역구분을 위한 신경망의 학습 데이터로 한다.

셋째, 학습된 데이터를 이용하여 학습에 참여하지 않은 각 영역의 300개 데이터로 인식한다.

위의 방법을 실현하기 위한 학습법은 BP와 하이브리드 및 변형하이브리드이며 각표의 (a)는 단 한대의 컴퓨터로만 수행했다.

실험조건은 하이브리드구현시  $\alpha$ 는 0.001, 0.01, 0.02로 제한했으며 제안된 학습법 구현시는  $\alpha$ 를 0.5, 1, 2, 3으로 제한했다. 전체실험에서 출력허용 오차는 0.1, 최대 학습회수(iteration)는 30000으로 하였으며 연결강도(weight)의 초기치는 같고 인식률은 소수점 3째자리 이하는 생략하였다.

각 표의 (a)는 비선형 함수  $f(x) = (2/(1 + e^{-x}) - 1)$ 를 사용한 BP와 하이브리드 실험결과이며 (b)는 비선형함수는  $f(x) = 1 / (1 + e^{-x})$ 을 사용한 BP 와 변형하이브리드 실험결과이다.

첫번째로  $\eta = 0.1$  일때 BP와 하이브리드 및 변형하이브리드를 평가한 실험 결과는 표 1과 같다.

각표에서 학습회수는 학습을 하기 위한 iteration이며 자기인식은 학습데이터의 자기인식 결과이고 인식률 및 인식갯수는 학습에 참여하지 않은 데이터를 인식한 결과이다.

인식시 "/" 의 윗숫자는 인식한 데이터 갯수, 아래숫자는 인식에 참여한 데이터 갯수를 의미한다. 학습시간은 컴퓨터에서 S/W적으로 시뮬레이션하는 결과이며 컴퓨터의 성능에따라 차이가 있으므로 H/W로 실현할때 소요되는 학습회수만 학습속도로 서술한다.

표1의 (a)에서 하이브리드의 최저 학습속도나 최고 인식률이 BP보다 우수하며 (b)에서 원의 학습속도는 변형하이브리드가 BP보다 우수하지만 최고 인식률은 같으며 삼각형과 사각형은 제안된 학습법의 성능이 더 우수하다.

BP의 성능은 하이브리드 보다 우수하지 못하므로 하이브리드와 변형하이브리드만 비교 서술한다.

표1에서 원의 학습시 최저 학습회수는 제안된 학습법이 더 빠르고 헤브롭의 크기에 비례하여 학습 속도가 빨라지므로 헤브롭을 더 크게 하면 더 빨라질 수 있다. 그러나 최고 인식률은 하이브리드보다 0.111% 떨어지지만  $\alpha$ 의 변화가 있을때 학습속도는 하이브리드보다 개선되고 인식률은 같다.

삼각형에서 최저 학습회수는 하이브리드가 더 빠르며 변형하이브리드에서 수렴 범위는 Hebb률이 약 1정도까

지이고 최고 인식률은 제안된 학습법이 0.834%더 우수하다. 특히 제안된 학습법에서  $\alpha$ 가 2일때에는 학습이 완료되지 않았고 자기인식도 한개가 인식을 못했지만 인식률은 하이브리드의 최고 인식률보다 0.417% 높다.

표 1.  $\eta = 0.1$ 일때 BP와 하이브리드 및 변형하이브리드의 실험결과 (a) BP와 하이브리드의 실험결과 (b) BP와 변형하이브리드의 실험결과

Table 1. The Result of Experiment for BP and Hybrid and modified Hybrid ( $\eta = 0.1$ ).  
(a)The Result of Experiment for BP and Hybrid (b)The Result of Experiment for BP and modified Hybrid

구분	학습법	BP	Hybrid		
			$\alpha=0.001$	$\alpha=0.01$	$\alpha=0.02$
원	학습 시간	18m 03s	18m 48s	13m 43s	13m 32s
	학습 횟수	5184	5469	3990	3970
	자기 인식	300/300	300/300	300/300	300/300
	인식 갯수	896/900	897/900	897/900	896/900
삼각	인식율	99.555	99.666	99.666	99.5555
	학습 시간	2h 36m 23s	2h 33m 57s	38m 36s	1h 13m 50s
	학습 횟수	30001	29698	7391	14156
	자기 인식	897/400	400/400	400/400	400/400
사각	인식 갯수	1185/1200	1187/1200	1187/1200	1181/1200
	인식율	98.75	98.916	98.916	98.416
	학습 시간	1h 43m 34s	1h 34m 45s	36m 33s	48m 43s
	학습 횟수	30001	27354	10579	14099
삼각형	자기 인식	299/300	300/300	300/300	300/300
	인식 갯수	877/900	876/900	884/900	867/900
	인식율	97.444	97.333	98.222	96.333

(a)

구분	학습법	BP	Modified Hybrid			
			$\alpha=0.5$	$\alpha=1$	$\alpha=2$	$\alpha=3$
원	학습 시간	2h 16s	20m 17s	9m 11s	16s 17s	15s 45s
	학습 횟수	19643	3258	2840	2641	2256
	자기 인식	300/300	300/300	300/300	300/300	300/300
	인식 갯수	896/900	896/900	896/900	896/900	896/900
삼각	인식율	99.555	99.555	99.555	99.555	99.555
	학습 시간	9h 16m 2s	4h 16m 52s	1h 49m 44s	5h 8m 28s	5h 45m 21s
	학습 횟수	30001	22960	17336	30001	30001
	자기 인식	399/400	400/400	400/400	399/400	399/400
사각	인식 갯수	1186/1200	1196/1200	1197/1200	1192/1200	1177/1200
	인식율	98.833	99.666	99.75	99.333	98.083
	학습 시간	1h 42m 10s	2h 13m 52s	38m 52s	31m 48s	1h 12m 19s
	학습 횟수	30001	21328	11025	9153	11609
삼각형	자기 인식	299/300	300/300	300/300	300/300	300/300
	인식 갯수	879/900	870/900	881/900	884/900	887/900
	인식율	97.666	96.666	97.888	98.222	98.555

(b)

사각형에서 최저 학습횟수는 제안된 학습법이 더 빠르며 헤브룰의 범위는 3보다 더 크며 인식률은 헤브룰의 크기에 비례하기 때문에 인식률도 더 개선될 수 있다. 최고 인식률도 하이브리드보다 0.333% 더 우수하다.

표 2.  $\eta$  가 0.05일때 BP와 하이브리드 및 변형 하이브리드의 실험결과 (a) BP와 하이브리드 의 실험결과 (b) BP와 변형하이브리드의 실험결과

Table 2. The Result of Experiment for BP and Hybrid and modified Hybrid. (a) The Result of Experiment for BP and Hybrid (b) The Result of Experiment for BP and modified Hybrid.

구분	학습법	BP	Hybrid		
			$\alpha=0.001$	$\alpha=0.01$	$\alpha=0.02$
원	학습 시간	45m:13s	42m:48s	28m:37s	12m:38s
	학습 횟수	13039	12609	8473	3759
	자기 인식	300/300	300/300	300/300	300/300
	인식 갯수	895/900	897/900	895/900	896/900
	인식률	99.444	99.666	99.444	99.555
삼각형	학습 시간	2h:36m:12s	1h:34m:42s	1h:12m:30s	54m:45s
	학습 횟수	30001	18428	13976	10504
	자기 인식	397/400	400/400	400/400	400/400
	인식 갯수	1186/1200	1190/1200	1182/1200	1189/1200
	인식률	98.833	99.166	98.5	99.083
사각형	학습 시간	1h:44m:1s	1h:31m:49s	1h:34m:27s	1h:40m:2s
	학습 횟수	30001	26813	27320	29067
	자기 인식	289/300	300/300	300/300	300/300
	인식 갯수	874/900	870/900	871/900	886/900
	인식률	97.111	96.666	96.777	98.444

(a)

구분	학습법	BP	Modified Hybrid			
			$\alpha=0.5$	$\alpha=1$	$\alpha=2$	$\alpha=3$
원	학습 시간	1h:35m:6s	17m:25s	16m:06s	15m:14s	15m:07s
	학습 횟수	30001	5662	5235	4944	4902
	자기 인식	300/300	300/300	300/300	300/300	300/300
	인식 갯수	896/900	896/900	896/900	896/900	896/900
	인식률	99.555	99.555	99.555	99.555	99.555
삼각형	학습 시간	2h:43m:4s	2h:27m:03s	2h:08m:18s	2h:25m:13s	2h:27m:46s
	학습 횟수	30001	30001	26377	30001	30001
	자기 인식	400/400	400/400	400/400	399/400	399/400
	인식 갯수	1186/1200	1196/1200	1195/1200	1185/1200	1187/1200
	인식률	98.833	99.666	99.583	98.75	98.916
사각형	학습 시간	1h:31m:48s	1h:06m:34s	51m:23s	50m:13s	59m:45s
	학습 횟수	30001	21136	16397	16042	19080
	자기 인식	299/300	300/300	300/300	300/300	300/300
	인식 갯수	879/900	883/900	884/900	884/900	887/900
	인식률	97.666	98.111	98.222	98.222	98.555

(b)

두번째로  $\eta = 0.05$  일때 BP와 하이브리드 및 변형 하이브리드를 평가한 실험 결과는 표 2와 같다.

표 2의 (a)에서 하이브리드의 최저 학습속도나 최고 인식률이 BP보다 우수하며 (b)에서 원의 학습속도는 변형하이브리드가 BP보다 우수하지만 최고 인식률은 같으며 삼각형과 사각형은 제안된 학습법의 성능이 더 우수하므로 하이브리드와 변형하이브리드만 비교 서술한다.

표 2에서 원의 최저 학습속도와 최고 인식률을 0.111% 가 제안된 학습법보다 하이브리드가 우수하다. 헤브룰의 크기에 비례해서 두 학습법의 학습 속도가 개선되므로 표에 제시된 헤브룰의 크기보다 더 큰 범위에서 더 빨리 수렴될수 있다.

삼각형에서 최저 학습속도는 하이브리드가 더 빠르지만 인식률은 제안된 학습법이 0.5% 더 우수하다. 하이브리드의 학습 속도는 헤브룰에 비례하지만 제안된 학습법은 헤브룰이 1일때가 가장 빠르다.

사각형에서 제안된 학습법이 최저 학습속도도 하이브리드보다 더 빠르고 최고 인식률도 0.111% 더 빠르다. 하이브리드에서는 학습 속도가 헤브룰의 크기에 비례하여 개선되며 변형하이브리드에서는 헤브룰이 2일때가 가장 빠르다.

온닉총 뉴런갯수를 10개에서 15개로 변화시킨 실험과 모우멘텀 0.6을 사용했을때의 실험결과를 표 3에 나타내었다. 실험패턴은 BP와 변형하이브리드의 학습이 다같이 잘되는 원에만 제한하였다. 나머지 실험조건은 표 1의 (b)와 같다.

표 3. 모우멘텀을 사용한 실험 결과

Table 3. The Result of Experiment using Momentum.

구분	학습법	BP	Modified Hybrid (온닉총뉴런 = 15개)			
			$\alpha=0.5$	$\alpha=1$	$\alpha=2$	$\alpha=3$
원	학습 시간	3h:51m:10s	16m:6s	13m:48s	13m:7s	13m:29s
	학습 횟수	22205	3455	2960	2807	2891
	자기 인식	300/300	300/300	300/300	300/300	300/300
	인식 갯수	895/900	896/900	896/900	896/900	896/900
	인식률	99.444	99.555	99.555	99.555	99.555
삼각형	학습 시간	1h:4m:41s	6m:29s	5m:42s	6m:15s	6m:37s
	학습 횟수	8932	1407	1239	1351	1432
	자기 인식	300/300	300/300	300/300	300/300	300/300
	인식 갯수	895/900	896/900	896/900	896/900	896/900
	인식률	99.444	99.555	99.555	99.555	99.555
사각형	학습 시간	1h:31m:48s	1h:06m:34s	51m:23s	50m:13s	59m:45s
	학습 횟수	30001	21136	16397	16042	19080
	자기 인식	299/300	300/300	300/300	300/300	300/300
	인식 갯수	879/900	883/900	884/900	884/900	887/900
	인식률	97.666	98.111	98.222	98.222	98.555

표 3에서 ( $M=0.6$ )이란 모우멘텀 0.6을 사용했다는 것을 의미한다. 표 3에서 온닉총 뉴런을 증가 시킬때 제안된 학습법의 최저 학습횟수는 표 1의 (b)보-

다 조금 크지만 인식률은 같다. BP의 최저 학습횟수는 표 1의 (b)보다 매우 증가 하며 인식률은 적어진다. 모우멘텀을 사용하면 BP와 변형하이브리드는 학습속도는 개선되지만 인식률은 모우멘텀을 사용하지 않는것과 같다.

표 1과 2에서 제안된 학습법이 하이브리드 보다 인식률이 우수하며 학습속도는 거의 유사하다. 원과 같이 학습속도가 헤브률에 비례하여 빨라지면 표에서 주어진 헤브률보다 더 큰 범위에서도 수렴되며 수렴속도가 개선 된다.

하이브리드 학습시는 헤브률  $\alpha$  가 적은 범위이지만 제안된 학습법은  $\alpha$  의 범위가 매우 크다는 것을 알 수 있다.  $\alpha$  의 범위가 크면 최소 학습속도나 최고 인식률을 표에 나타난 결과 보다 더 향상시킬 수 있는 적정  $\alpha$  가 있을 수 있다.

표 3에서 BP는 은닉층 뉴런개수가 증가하면 인식률이 저하되므로 잡음에 약하다는 일반론적인 개념에 부응하지만 제안된 학습법은 인식률이 같으므로 잡음에 강할 수 있다. 그러나 제안된 학습법과 하이브리드 학습법은 헤브률의 값에 따라 학습속도가 빨라지더라도 반드시 학습속도에 비례하여 인식률이 향상되지 않는다. 원이나 삼각형의 결과에서와 같이 빠른 학습속도와 최고 인식률이 반드시 동시에 만족되지 않는다.

#### IV. 결 론

본 연구에서는 변형 Hebb학습규칙과 오차역전파기법을 동시에 적용하는 새로운 변형하이브리드학습법을 제안하였다.

몬테칼로방법으로 제안된 학습법을 MLP구조에 적용하여 컴퓨터 시뮬레이션 한 결과를 BP 학습법 및 하이브리드 학습법으로 시뮬레이션 한 결과와 비교하는 실험을 하여 보았다. BP알고리듬이 적용된 기존의 MLP에 변형하이브리드 학습규칙을 적용하였을 때 BP보다 학습속도 및 인식률 즉 성능이 매우 우수하며 잡음에도 우수할 가능성을 보여 주었다. 제안되었던 하이브리드 학습과 비교할 때 학습속도는 유사하지만 인식률이 개선되었다. 이것은 Hebb규칙에 의한 입력의 특징 추출기능이 멜타향의 영향으로 크기와 위상변화가 되어서 하이브리드보다는 높은 인식률을 보였다고 생각된다. 특히, Hebb학습규칙에 도입되는 학습률 가 하이브리드보다는 제안된 학습법이 더 크기때문에 적정 헤브률의 범위도 넓으므로서 인식률이 더 높아질 것이다.

앞으로 변형하이브리드 알고리듬의 일반적 특성에

관한 연구 및 학습속도와 인식률이 동시에 만족 될수 있는 알고리듬에 관한 연구와 여러 분야에서 응용이 기대된다.

#### 参考文献

- [1] 송도선, 김석동, 이행세, "Spatio-temporal 방법을 이용한 우리말 모음 인식에 관한 연구," 한국 음향학회지 제 12권 제 4호, 1993
- [2] K.Fukushima, S.Miyake, T.Ito, & T.Kouno, Handwritten numeral recognition by the algorithm of the neocognitron. An experimental system using a microcomputer (in Japanese) Transactions of the information Processing Society of Japan, 28(6), pp. 627-635, 1987.
- [3] D.E.Rumelhart, G.E.Hinton, and R.J.Williams, Learning Internal Representation by Error Propagation in Parallel Distributed Processing (Eds. David E.Rumelhart and Jame L.McCelland), The MIT Press, vol.1, 1986.
- [4] R.Linsker, "From basic network principles to neural architecture : Emergence of spatial -opponent cells," Proceedings of the National Academy of Sciences USA, 83, 1986.
- [5] D.O.Hebb, The Organization of Behavior. Introduction and Chapter 4. The first stage of Perception growth of the assembly, pp.xi-xix, 60-78, New York : Wiley, 1949.
- [6] J.J.Hopfield, "Neural networks and physical systems with emergent collective computational abilities," Proceedings of National academic science, Vol.79, pp.2554-2588, biophysics, April 1982.
- [7] J.J.Hopfield, "Neurons with graded response have collective computational properties like those of two-state neurons," Proceedings of National Academic Science, Vol.81, pp.3088-3092, Biophysics, May 1984.
- [8] Terence David Sanger, Optimal unsu-

- pervised learning in a single-layer linear feedforward neural network. *Neural Networks*, 2:459-473, 1989.
- [9] Terence David Sanger. Optimal unsupervised learning in feedforward neural networks. MIT AI Lab Tech. Report 1086, 1989.
- [10] T. Kohonen. Self-organization and Associative Memory. Springer-Verlag, Berlin, 1984.
- [11] T.J. Sejnowski and C.R. Rosenberg. Net talk : A parallel network that learns to read aloud. Johns Hopkins University EE & CC Technical Report JHU/EECS-86/01, Jan. 1986.
- [12] Richard J. Wood and Michale A Gennert. "A Neural Network that uses a Hebbian /Backpropagation Hybrid Learning Rule." IJCNN, Baltimore, Maryland June 7-11, 1992.
- [13] 송도선, 김석동, 이행세, "Hybrid학습규칙과 오차역전파 학습규칙의 성능비교에 관한 연구" 대한전자공학회 하계종합 학술대회 논문집, 제17권, 제1호, 94/7, PP.822-825, 7.1994
- [13] 송도선, 김석동, 이행세, "신경망의 Hybrid학습규칙을 이용한 한국어 음성인식에 관한 연구", 대한전자공학회 하계종합 학술대회 논문집, 제17권, 제1호, 94/7, PP.848-851, 7.1994

## 著者紹介



宋道善(正会員)

1956年 4月 14日生. 1977年 영남 대 전자공학과 졸업. 1981年 고려 대학 대학원 전자공학과 졸업. 1995年 아주대학교 대학원 전자공학과(공학박사). 1981年 ~ 현재 중경공업 전문대학 전자계산기과 부교수. 주관심 분야는 인공지능 및 신호 처리 등임.



金錫東(正会員)

1957年 8月 23日生. 1982年 2月 아주대학교 전자공학과(공학사). 1984年 2月 아주대학교 대학원 전자공학과(공학석사). 1993年 2月 아주대학교 대학원 전자공학과(공학박사). 1984年 3月 ~ 현재 호서대학교 전자계산학과 부교수. 주관심 분야는 음성인식, 신경회로망, 음성신호 처리 등임.

## 李幸世(正会員)

1943年 8月 29日生. 1966年 전북대학교 전기공학과(공학사). 1972年 서울대학교 전자공학과(공학석사). 1984年 고려대학교 전자공학과(공학박사). 1968年 ~ 1970年 해군사관학교 전자공학 교관. 1973年 ~ 현재 아주대학교 전자공학과 교수. 1982年 ~ 1983年 미국 Columbia Univ. (N.Y.) 객원교수. 1987年 ~ 1988年 프랑스 INRIA(Paris) 객원교수. 1992年 ~ 1994년 거세전문대학 학장. 1973年 ~ 현재 IEEE 회원. 주관심 분야는 문자 및 음성인식, 인간기계 인터페이스, 인공지능, 신경회로망, 디지털 신호처리 등임.