

論文2002-39CI-4-3

# 역전파 알고리즘의 성능개선을 위한 학습율 자동 조정 방식

## (Auto-Tuning Method of Learning Rate for Performance Improvement of Backpropagation Algorithm)

金周雄\*, 鄭慶權\*, 嚴基煥\*

(Joo Woong Kim, Kyung Kwon Jung, and Ki Hwan Eom)

### 요약

역전파 알고리즘의 성능 개선을 위해서 학습율을 자동 조정하는 방식을 제안하였다. 제안한 방식은 각각의 연결강도의 학습율을 퍼지 논리 시스템을 이용하여 자동 조정하는 방식으로 각각의 연결강도에 대해서  $\Delta$ 와  $\bar{\Delta}$ 를 구하여 퍼지 논리 시스템의 입력으로 사용하고 학습율을 출력으로 사용하였다. 제안한 방식을 N-페리티 문제, 함수 근사, 숫자 패턴 분류에 대한 시뮬레이션 결과 일반적인 역전파 알고리즘, 모멘텀 방식, Jacobs의 delta-bar-delta 방식보다 성능이 개선됨을 확인하였다.

### Abstract

We proposed an auto-tuning method of learning rate for performance improvement of backpropagation algorithm. Proposed method is used a fuzzy logic system for automatic tuning of learning rate. Instead of choosing a fixed learning rate, the fuzzy logic system is used to dynamically adjust learning rate. The inputs of fuzzy logic system are  $\Delta$  and  $\bar{\Delta}$  and the output is the learning rate. In order to verify the effectiveness of the proposed method, we performed simulations on a N-parity problem, function approximation, and Arabic numerals classification. The results show that the proposed method has considerably improved the performance compared to the backpropagation, the backpropagation with momentum, and the Jacobs' delta-bar-delta.

**Key Words:** neural network; backpropagation; fuzzy logic system; delta-bar-delta; learning rate.

### I. 서론

하나 이상의 은닉층을 가진 다층 신경회로망은 단층 퍼셉트론을 확장한 형태로서 단층 퍼셉트론의 한계를 극복할 수 있는 우수한 특성을 가지고 있어, 공학이나 과학뿐 만이 아니라 재정, 경비 등 사회 전 분야에 걸쳐 응용이 확산되고 있다. 다층 신경회로망에서 일반적으로 많이 사용하는 학습 알고리즘은 역전파 알고리즘

(BP: backpropagation algorithm)으로 이는 목표 출력과 네트워크의 실제의 출력의 차의 자승 합을 목적함수로 하여 그 목적함수의 최소치를 스텝 폭 고정의 최급강하법(steepest descent method)으로 구하는 것이다. 최소치를 계산하는 알고리즘은 이외에도 Newton's method, conjugate gradient method, Levenberg-Marquardt algorithm과 같은 간접탐색법과 nongradient인 Powell 방법과 같은 직접 탐색법으로 대분 된다.<sup>[1,2]</sup>

역전파 알고리즘의 문제점으로는 수렴에 종종 실패하고 지역 최소값에 빠질 수 있으며, 훈련 시간이 많이 소요되며, 불연속 시뮬레이션에서 항상 수렴하는 것은 아니다. 즉 초기의 상태를 어떻게 선택하느냐에 따라

\* 正會員, 東國大學校 電子工學科

(Dept. of Electronic Eng., Dongguk University)

接受日字: 2002年1月29日, 수정완료일: 2002年7月4日

진동하거나 발산하기도 한다. 이러한 문제점의 해결 및 성능 개선을 위한 연구는 지금도 계속되고 있으며, 이는 일반적으로 두 개의 부류(category) 즉 경험적(heuristic) 기술과 수치 최적화기술로 구분할 수 있다. 경험적 기술로는 학습율을 가변화하는 방법, 모멘텀법, 변수들의 재 스케일링, 다층 신경회로망의 구조 즉 은닉층의 층수 및 각 층의 뉴런 수를 조절하는 방법 등이 있다.<sup>[2~6]</sup> 모멘트법은 오차합수가 2차 함수로 충분히 근사할 수 있는 영역에서는 비선형 최적화수법을 이용하는 방법보다 수렴에 시간이 걸리는 단점을 가지고 있지만 알고리즘이 간단하고, 설정하는 파라미터가 적은 특징을 가지고 있어 많은 응용 분야에 이용되고 있다. 그러나 모멘트법에 있어서도 적용하는 문제에 적절한 파라미터가 서로 다르므로 시행착오적인 파라미터의 설정이 필요하다.<sup>[6]</sup> 학습율의 가변화를 이용하는 방법에는 2차 보간법 등의 직접 탐색을 넣는 방법, 학습율을 선형적으로 증가시키다가 지수적으로 감소시키는 Jacobs등에 의한 delta bar delta법칙, 학습 반복수와 방향에 의해 학습율을 계산하는 방법, 역학 시스템을 이용하는 방법 등이 있다.<sup>[2,3,6]</sup>

수치 최적화 기술로는 conjugate gradient algorithm, Levenberg-Marquardt method, inverse gradient method, 비선형 최적화법을 이용하는 방법, 변형된 오차함수를 이용하는 방법 및 확률적 방식을 이용하는 방법 등이 있다.<sup>[7,8]</sup> 이러한 방법들은 고속으로 수렴하고, 정밀도가 좋은 해가 얻어지는 것으로 알려지고 있으나 파라미터의 수가 많고, Hessian Matrix의 계산등 알고리즘이 복잡하다는 문제점이 있다.

본 논문에서는 역전파 알고리즘의 성능 개선을 위해서 학습율을 자동 조정하는 방식을 제안한다. 제안한 방식은 각각의 연결강도의 학습율을 펴지 논리 시스템을 이용하여 자동 조정하는 방식으로, 각각의 연결강도에 대해서  $\Delta$ 와  $\bar{\Delta}$ 를 구하여 펴지 논리 시스템의 입력으로 사용하고, 학습율을 출력으로 사용한다. 제안한 방식의 유용성을 확인하기 위하여 N-패티리 문제, 험수 근사, 숫자 패턴 분류를 대상으로 일반적인 역전파 알고리즘, 모멘텀 방식, delta-bar-delta 방식과 시뮬레이션을 통해서 성능을 비교 검토한다.

## II. Delta-bar-delta 알고리즘

다층 신경회로망의 학습 알고리즘으로는 역전파 알

고리즘이 주로 사용되고 있으며, 이 알고리즘의 성능 개선을 위한 방식 중에 Jacobs등에 의해 제안된 delta-bar-delta 알고리즘이 있다.<sup>[6]</sup> 그림 1은 다층 신경회로망의 구조이다.<sup>[1]</sup>

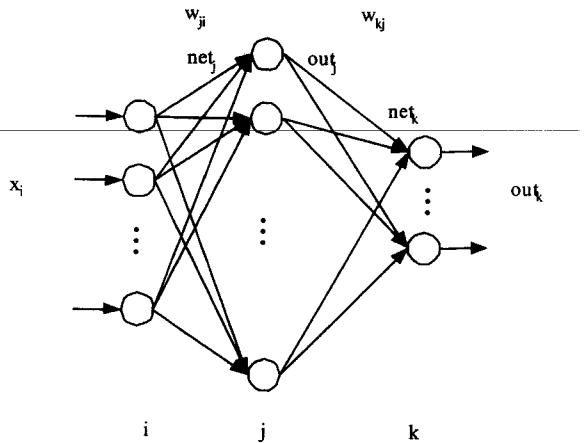


그림 1. 다층 신경회로망  
Fig. 1. Multi-layer neural network.

그림 1과 같은 구조의 다층 신경회로망이 입력층  $i$ , 은닉층  $j$ , 출력층  $k$ 로 구성될 때, delta-bar-delta 알고리즘은 아래의 식과 같은 연결강도(weight)의 변화를 갖는다.<sup>[1,6]</sup>

$$\begin{aligned} w_{kj}(t+1) &= w_{kj}(t) - \alpha_{kj}(t+1) \frac{\partial E}{\partial w_{kj}} \\ &= w_{kj}(t) - \alpha_{kj}(t+1) \delta_k z_j \end{aligned} \quad (1)$$

여기서  $\alpha_{kj}$ 는 학습율,  $\delta_k$ 는 출력층 오차이며,  $z_j$ 는 은닉층 뉴런의 출력이다. 각 출력층 뉴런에서 delta는 식 (2)와 같으며, 각 은닉층 뉴런에서 delta는 식 (3)과 같다.

$$\Delta_{kj} = \frac{\partial E}{\partial w_{kj}} = -\delta_k z_j \quad (2)$$

$$\Delta_{ji} = \frac{\partial E}{\partial w_{ji}} = -\delta_j x_i \quad (3)$$

Delta-bar-delta 규칙은 각 출력 뉴런에 대하여 현재의 정보와, 다음과 같이 delta-bar를 형성하기 위하여 파생된 과거의 정보를 조합하여 이용되며

$$\bar{\Delta}_{kj}(t) = (1-\beta)\Delta_{kj}(t) + \beta\bar{\Delta}_{kj}(t-1) \quad (4)$$

여기서 파라미터  $\beta$ 의 값은  $0 < \beta < 1$  사이의 고정된 상수이다. Delta와 delta-bar 변화에 대한 학습율의 변화는 다음과 같다. 만약 연결강도의 변화가 연속된 학습과정에서 같은 방향으로 이루어진다면 학습율은 증가하여야 한다. 이것은  $\bar{\Delta}_{kj}(t-1)$ 과  $\Delta_{kj}(t)$ 가 같은 부호에서 발생하며, 이 때 학습율은 증가하여야 한다. 또한 만약  $\bar{\Delta}_{kj}(t-1)$ 과  $\Delta_{kj}(t)$ 의 부호가 반대 부호를 가지면 학습율은 현재값의  $(1-\gamma)$ 의 비율로 감소한다. 이러한 가변 학습율은 각 층에 대하여 아래의 식으로 표현할 수 있다.<sup>[6]</sup>

$$\begin{aligned}\alpha_{kj}(t+1) &= \alpha_{kj}(t) + \kappa && \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) > 0 \\ &= (1-\gamma)\alpha_{kj}(t) && \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) < 0 \\ &= \alpha_{kj}(t) && \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) = 0\end{aligned}\quad (5)$$

$$\begin{aligned}\alpha_{ji}(t+1) &= \alpha_{ji}(t) + \kappa && \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) > 0 \\ &= (1-\gamma)\alpha_{ji}(t) && \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) < 0 \\ &= \alpha_{ji}(t) && \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) = 0\end{aligned}\quad (6)$$

여기서 파라미터  $\kappa$  와  $\gamma$ 는 지정될 상수이다.

식 (5), (6)과 같이 delta-bar-delta 규칙은 학습율이 초기값에 따라  $\kappa$ ,  $\gamma$  등의 파라미터에 의해 좁은 범위에서 변화되므로, 좀 더 좋은 성능을 가지기 위해서는 초기 학습율에 상관없이 넓은 범위에서 자동으로 조정하는 것이 좋다.

### III. 제안하는 학습율 자동 조정 방식

본 논문에서는 역전파 알고리즘의 성능을 개선하기 위해서 연결강도 조정에 사용되는 학습율을 퍼지 논리 시스템을 이용하여 자동으로 조절하는 방식을 제안한다.

표 1. 퍼지 제어 규칙  
Table 1. Fuzzy control rules.

$\bar{\Delta}$	N	Z	P
N	B	M	S
Z	M	M	M
M	N	M	B

출력층과 은닉층의 학습율 변화를  $\Delta$ 와  $\bar{\Delta}$ 의 부호 관계를 식(5) 와 (6)의 관계를 이용하여 표 1과 같은 퍼

지 규칙을 구성하였다. 여기서 N(Negative), Z(Zero), P(Positive), S(Small), M(Medium), B(Big)는 퍼지 소속 함수이다.

표 1의 출력을 이용하여 학습율의 조정은 식 (7), (8)과 같이 나타낼 수 있다.

$$\alpha_{kj}(t+1) = \text{Fuzzy}(\Delta_{kj}, \bar{\Delta}_{kj}) \quad (7)$$

$$\alpha_{ji}(t+1) = \text{Fuzzy}(\Delta_{ji}, \bar{\Delta}_{ji}) \quad (8)$$

$\Delta$ 와  $\bar{\Delta}$ 의 소속 함수는 Jacobs의 delta-bar-delta 법칙의 시뮬레이션 결과를 바탕으로 그림 2와 3과 같이 구성한다.

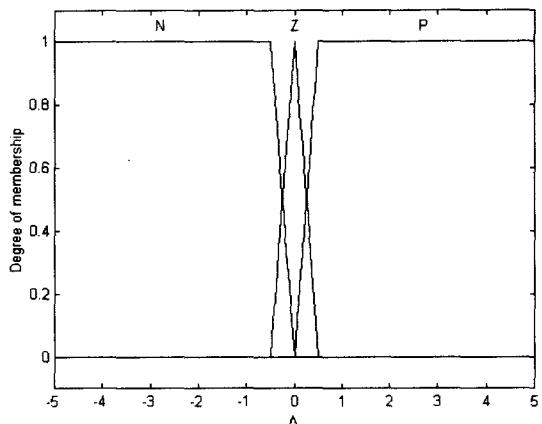


그림 2.  $\Delta$ 의 소속 함수

Fig. 2. The membership functions of  $\Delta$

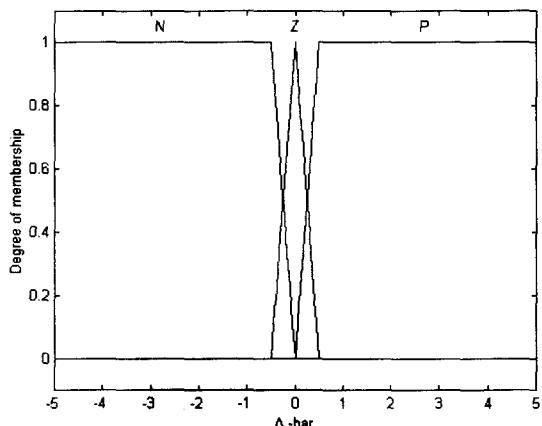


그림 3.  $\bar{\Delta}$ 의 소속 함수

Fig. 3. The membership functions of  $\bar{\Delta}$

출력의 소속 함수는 그림 4와 같다.

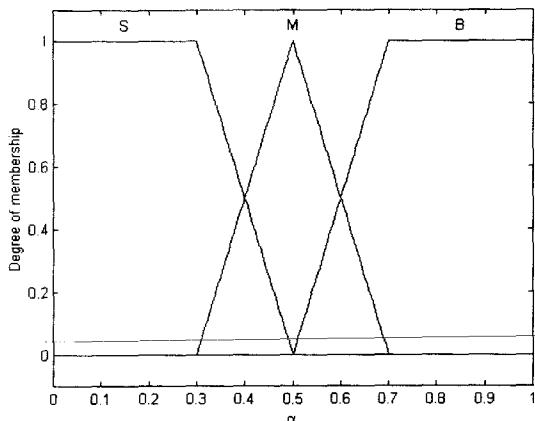
그림 4. 출력  $\alpha$ 의 소속 함수Fig. 4. The membership functions of output  $\alpha$ .

표 1의 9개의 퍼지 제어 규칙을  $If \sim Then$  형식의 퍼지 관계로 표현한 것이 식 (9)이다.

$$\begin{aligned}
 R^{(1)} &: If \Delta \text{ is } N, \bar{\Delta} \text{ is } N \text{ Then } \alpha \text{ is } B \\
 R^{(2)} &: If \Delta \text{ is } N, \bar{\Delta} \text{ is } Z \text{ Then } \alpha \text{ is } M \\
 R^{(3)} &: If \Delta \text{ is } N, \bar{\Delta} \text{ is } P \text{ Then } \alpha \text{ is } S \\
 R^{(4)} &: If \Delta \text{ is } Z, \bar{\Delta} \text{ is } N \text{ Then } \alpha \text{ is } M \\
 R^{(5)} &: If \Delta \text{ is } Z, \bar{\Delta} \text{ is } Z \text{ Then } \alpha \text{ is } M \\
 R^{(6)} &: If \Delta \text{ is } Z, \bar{\Delta} \text{ is } P \text{ Then } \alpha \text{ is } M \\
 R^{(7)} &: If \Delta \text{ is } P, \bar{\Delta} \text{ is } N \text{ Then } \alpha \text{ is } S \\
 R^{(8)} &: If \Delta \text{ is } P, \bar{\Delta} \text{ is } Z \text{ Then } \alpha \text{ is } M \\
 R^{(9)} &: If \Delta \text{ is } P, \bar{\Delta} \text{ is } P \text{ Then } \alpha \text{ is } B
 \end{aligned} \tag{9}$$

식 (9)의 퍼지 제어 규칙을 이용하여 퍼지 추론에는 min-max 방법을 사용하고, 비퍼지화는 무게 중심법을 사용한다.<sup>[9]</sup>

그림 5는 퍼지 논리 시스템의 입출력 평면을 나타낸 것이다.

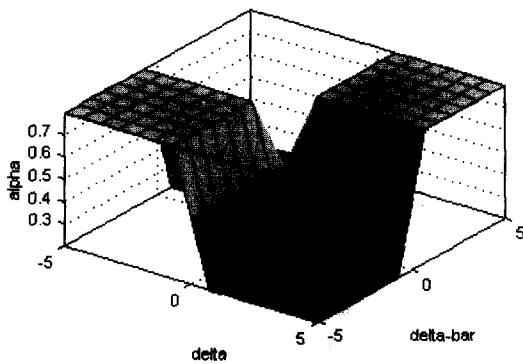


그림 5. 퍼지 논리 시스템의 입출력 평면

Fig. 5. Input-output surface of fuzzy logic system.

그림 5에서와 같이 제안한 방식은 학습율이 초기값에 상관없이  $\delta$ ,  $\delta$ -bar에 의해서만 폭넓게 자동 조절될 수 있으므로 성능을 개선 할 수 있다.

#### IV. 시뮬레이션

N-페리티, 함수 근사화 및 숫자 패턴 분류 시뮬레이션 조건으로 초기 연결강도와 바이어스는  $[-0.1, 0.1]$  사이에서 랜덤하게 선택하고 활성화 함수는 식 (10)과 같은 시그모이드 함수를 모두 동일하게 사용한다.

$$f(\text{net}) = \frac{1}{1 + e^{-\text{net}}} \tag{10}$$

##### 1. N-페리티 문제

###### (1) N=2 (XOR)

$N=2$ 인 경우의 신경회로망의 구성은 2개의 입력 뉴런, 한 개의 은닉층에 2개의 뉴런, 1개의 출력 뉴런으로 하였다. 시뮬레이션의 수령 판정은 5000번의 epoch의 수행에서 0.04 이하의 오차 제곱 합으로 하고, 100회 시뮬레이션을 수행하였다.

XOR 문제는 식(11)의 패턴으로, 그림 6과 같이 2진 입력과 0과 1의 목표값으로 구성한다.

$$\{p_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, t_1 = 0\}, \{p_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, t_2 = 1\}, \{p_3 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, t_3 = 1\}, \{p_4 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, t_4 = 0\} \tag{11}$$

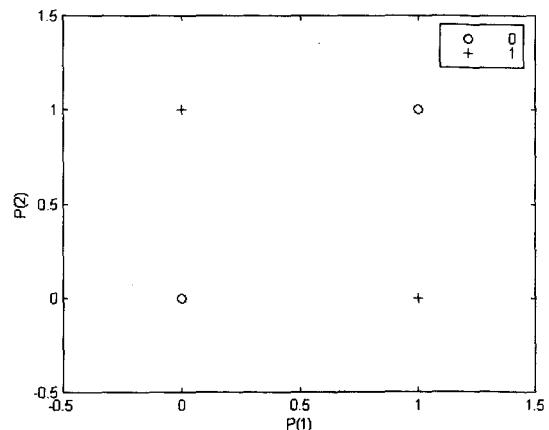


그림 6. 입력 벡터와 목표값

Fig. 6. The input vectors and target values.

본 논문의 시뮬레이션에서 사용한 각 학습방식의 과

라미터는 표 2와 같으며 이는 시행 착오법에 의해 가장 우수한 성능을 갖는 값으로 선택하였으며, 시뮬레이션 결과는 표 3과 같다.

표 2. 파라미터

Table 2. Parameters.

학습방식	파라미터	$\alpha$	$\mu$	$\kappa$	$\gamma$	$\beta$
BP	BP	0.1				
BP with momentum	BP with momentum	0.75	0.9			
Delta-bar-Delta	Delta-bar-Delta	0.8		0.035	0.333	0.7
Proposed method	Proposed method					0.7

여기서  $\alpha$ 는 학습율,  $\mu$ 는 모멘텀 계수이고  $\kappa$ ,  $\gamma$ ,  $\beta$ 는 delta-bar-delta의 상수이다.

표 3. 시뮬레이션 결과

Table 3. The simulation result of the N=2

학습방식	Simulations	Successes	Average Epochs
BP	100	79	3873.23
BP with momentum	100	84	1297.35
Delta-bar-Delta	100	87	271.02
Proposed method	100	100	147.34

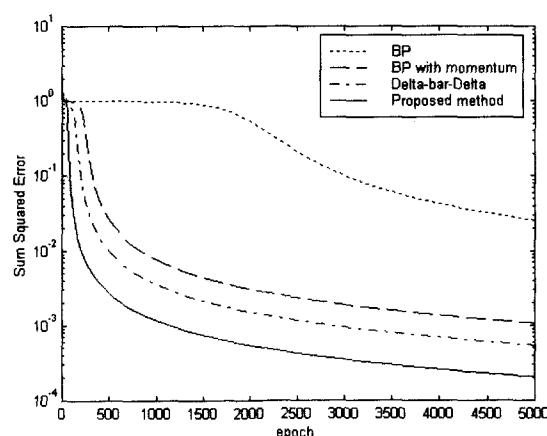


그림 7. 오차 제곱 합 곡선

Fig. 7. The sum squared error curves.

제안한 방식의 결과가 100번의 실행에서 100번 XOR 패턴을 정확하게 분류하였고, 평균 학습 횟수도 다른 학습 방식보다 현저히 감소함을 확인하였다.

그림 7은 동일한 값의 초기 연결강도를 시작으로 5000번 수행을 했을 때 학습 방법에 따른 오차 제곱합의 그림으로, 제안한 방식은 다른 방식보다 초기의 수렴 속도가 빠르고 오차 제곱 합도 적은 것을 확인하였다.

(2) N=5

N=5인 경우에도 N=2인 경우와 같은 신경회로망의 구성으로 하고 시뮬레이션 조건도 동일하며, 학습패턴은 32개이고 입력 패턴에 대해서 1의 개수가 홀수 개이면 출력을 '1'로, 그렇지 않으면 '0'을 가지는 목표값을 정하였다. 시행착오법에 의해 선택한 가장 성능이 우수한 파라미터는 표 4와 같으며, 표 5는 시뮬레이션 결과이다.

표 4. 파라미터

Table 4. Parameters.

학습방식	파라미터	$\alpha$	$\mu$	$\kappa$	$\gamma$	$\beta$
BP	BP	0.3				
BP with momentum	BP with momentum	0.7	0.5			
Delta-bar-Delta	Delta-bar-Delta	0.8		0.035	0.333	0.7
Proposed method	Proposed method					0.7

표 5. 시뮬레이션 결과

Table 5. The simulation result of the N=5.

학습방식	Simulations	Successes	Average Epochs
BP	100	76	4830.11
BP with momentum	100	85	1574.63
Delta-bar-Delta	100	92	729.09
Proposed method	100	100	231.55

제안한 방식의 결과가 100번의 실행에서 100번 모두 정확하게 성공하였고, 평균 학습 횟수도 다른 학습 방식보다 현저히 작으며, 그림 8의 오차 제곱 합 곡선에서도 가장 학습 속도도 우수하고 오차 제곱 합도 적은 것을 확인하였다.

이상과 같이 N 패러티 문제에서는 N=2나 N=5에서 유사한 결과를 얻었으므로 N에 수의 관계없이 제안한 방식의 성능이 우수함을 알 수 있다.

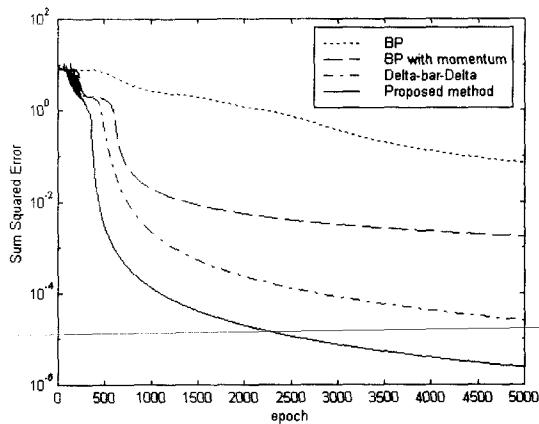


그림 8. 오차 제곱 합 곡선

Fig. 8. The sum squared error curves.

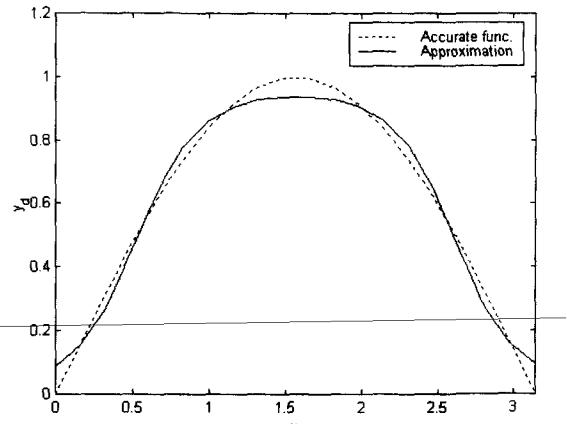


그림 9. 역전파 알고리즘 방식

Fig. 9. Backpropagation algorithm method.

## 2. 함수 근사

함수 근사 문제를 위한 신경회로망의 구성은 입력층 뉴런수는 1개, 한 개의 은닉층에 뉴런수는 10개, 출력층 뉴런수는 1개로 입력과 출력이 1:1 대응이 되는 형태이다.

목표 함수는 식 (12)과 같고, 입력은 0과 사이에서 20 개의 데이터를 샘플링하여 사용하였다.

$$y_d = \sin(x) \quad (12)$$

각 학습 방식의 시뮬레이션에서 사용한 파라미터는 시행착오법에 의해 선택하였으며 표 6과 같다.

표 6. 파라미터

Table 6. Parameters.

학습방식	파라미터	$\alpha$	$\mu$	$\kappa$	$\gamma$	$\beta$
BP		0.1				
BP with momentum		0.5	0.9			
Delta-bar-Delta		0.8		0.035	0.333	0.7
Proposed method						0.7

그림 9 - 12는 각 학습 방식에 대한 함수 근사의 결과이다.

시뮬레이션 결과 제안한 방식의 함수 근사 결과가 가장 우수함을 확인할 수 있으며, 그림 13은 오차 제곱 합 곡선으로 제안한 방식의 초기 수렴 속도나 정밀성이 우수함을 알 수 있다.

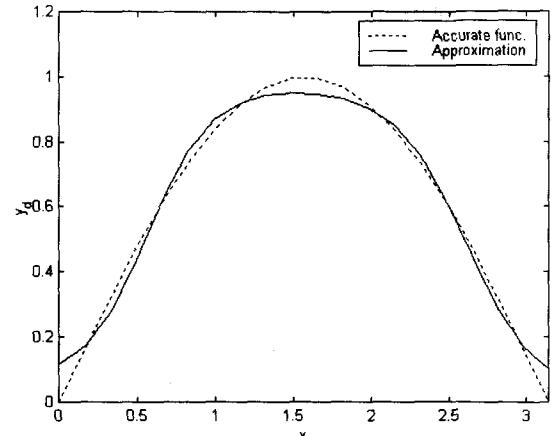


그림 10. 모멘텀 방식

Fig. 10. Momentum method.

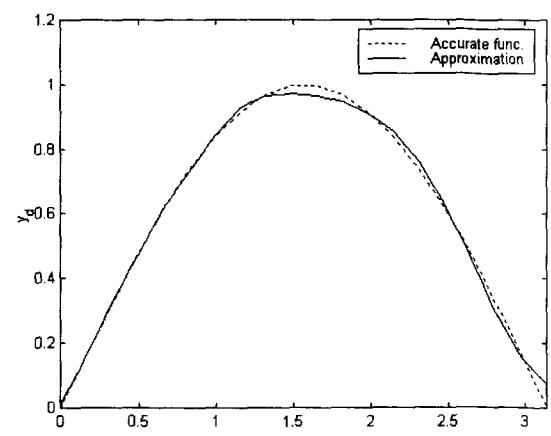


그림 11. 엘타-바-엘타 방식

Fig. 11. Delta-bar-delta method.

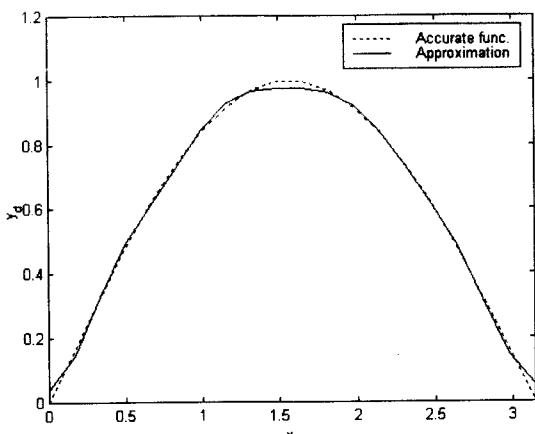


그림 12. 제안한 방식

Fig. 12. Proposed method.

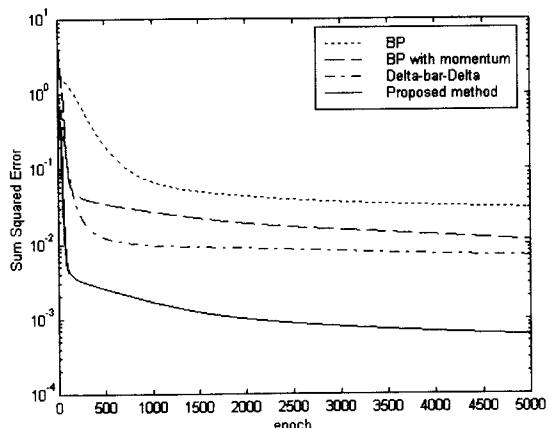


그림 13. 오차 제곱 합 곡선

Fig. 13. The sum squared error curves.

### 3. 숫자 패턴 분류

숫자 패턴 분류는 0~9까지의 그림 14와 같은 아라비아 숫자를 학습 신호로 사용하며, 0과 1로 구성된  $10 \times 10$  크기의 행렬을 그림 15와 같이  $100 \times 1$ 의 열 벡터로 변환하여 입력으로 사용하였다.

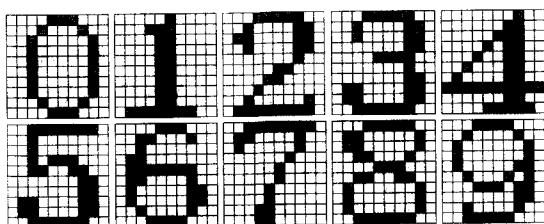
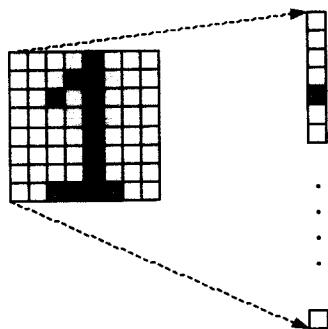
그림 14. 아라비아 숫자 패턴( $10 \times 10$ )Fig. 14. Arabic numerals ( $10 \times 10$ ).

그림 15. 입력 벡터

Fig. 15. Input vector.

출력의 목표신호는 표 7과 같이 이진부호화(binary coding) 형태의 값을 갖는다.

표 7. 목표신호

Table 7. The target signals.

숫자	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	1	1
1	0	0	0	0	1	1	1	1	0	0
2	0	0	1	1	0	0	1	1	0	0
3	0	1	0	1	0	1	0	1	0	1

신경회로망의 구성은 입력층의 뉴런수는 100개, 은닉층의 뉴런수는 10개, 출력층의 뉴런수는 4개로 하였다. 시뮬레이션의 수렴 판정은 5000번의 epoch의 수행에서 0.04 이하의 오차 제곱 합으로 하고, 100회 시뮬레이션을 수행하였다. 시뮬레이션에서 사용한 파라미터는 표 8과 같으며, 표9는 시뮬레이션 결과이다.

표 8. 파라미터

Table 8. Parameters.

학습방식 \ 파라미터	$\alpha$	$\mu$	$\kappa$	$\gamma$	$\beta$
BP	0.5				
BP with momentum	0.75	0.9			
Delta-bar-Delta	0.8		0.035	0.333	0.7
Proposed method					0.7

제안한 방식의 결과가 100번의 실행에서 100번 모두 패턴을 정확하게 분류하였고 평균 학습 횟수도 다른 학습 방식보다 현저히 감소함을 확인하였다. BP 방식에서는 수렴 조건을 만족하지 못하였다. 그림 16

은 오차 제곱 합 곡선으로 초기의 수렴 속도 및 오차 제곱 합 등에서 제안한 방식의 우수함을 알 수 있다.

표 9. 시뮬레이션 결과

Table 9. Simulation results.

학습방식	Simulations	Successes	Average Epochs
BP	100	0	> 5000
BP with momentum	100	79	2781.04
Delta-bar-Delta	100	87	887.30
Proposed method	100	100	620.28

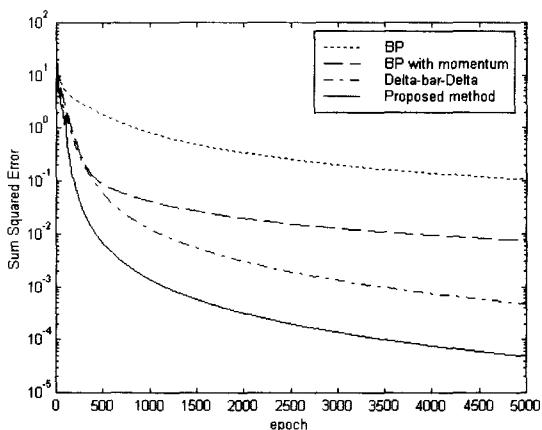


그림 16. 오차 제곱 합 곡선

Fig. 16. The sum squared error curves.

## V. 결 론

본 논문에서는 역전파 알고리즘의 성능 개선을 위해서 학습율 자동 조정 방식을 제안하였다. 제안한 방식은 각각의 연결강도의 학습율을 펴지 논리 시스템을 이용하여 자동 조정하는 방식으로 각각의 연결강도에 대해서  $\Delta$ 와  $\bar{\Delta}$ 를 구하여 펴지 논리 시스템의 입력으로 사용하고 학습율을 출력으로 사용하였다. 제안한 방식의 유용성을 확인하기 위하여 N-패리티 문제, 함수 근사, 숫자 패턴 분류를 대상으로 일반적인 역전파 알고리즘, 모멘텀 방식, Jacobs의 delta-bar-delta 방식과 시뮬레이션을 통해서 성능을 비교 검토한 결과, N-패리티 문제와 숫자 패턴 분류에서 제안한 방식은 100번의 실행으로 100번 정확하게 분류하여 100%의 성공율을 얻었으나 다른 방식들은 우수한 성공율을 갖지 못하였다. 평균 학습 횟수도 다른 학습 방식보다 현저히 감소

하였으며, 초기의 수렴 속도도 가장 빨랐으며 오차 제곱 합도 가장 적은 것을 확인하였다. 또한 함수 근사화에서도 가장 우수한 근사 결과를 확인하여 성능이 개선됨을 확인하였다.

## References

- [1] Martin T. Hagan, Howard B. Demuth, Mark Beale, Neural Network Design, PWS Publishing, Boston, 1995.
- [2] Peiman G. Maghami and Dean W. Sparks, "Design of Neural Networks for Fast Convergence and Accuracy:Dynamics and Control", *IEEE Transactions on Neural Networks*, Vol. 11, No. 11, pp. 113~123, January 2000.
- [3] Tokumitsu Fujita, Takao Watanebe and Keiichiro Yasuda, "A Study on Improvement in Learning Efficiency of Multilayered Neural Networks based on Dynamical System", *T IEE Japan*, Vol. 117-C, No. 12, pp. 1848~1855, 1997.
- [4] B.Hassibi, D.G.Stork and G.H.Wolff, "Optimal brain surgeon and general network pruning", *Proceedings of the IEEE International Joint Conference on Neural Networks*, Vol. 2, pp. 441~444, 1992.
- [5] A.K.Rigler, J.M. Irvine and T.P. Vogl, "Rescaling of variables in backpropagation learning", *Neural Networks*, Vol. 3, No. 5, pp. 561~573, 1990.
- [6] R. A. Jacobs, "Increased rates of convergence through learning rate adaptation," *Neural Networks*, Vol. 1, No. 4, pp. 295~308, 1988.
- [7] M. T. Hagan and M. Menhaj, "Training feedforward networks with the Marquardt algorithm," *IEEE Tran. on Neural Networks*, Vol. 5, No.6, 1994.
- [8] C.Charalambous, "Conjugate gradient algorithm for efficient training of artificial neural networks," *IEE Proceedings*, Vol. 139, No. 3,

pp. 301~310, 1992.

- [9] Li-Xin Wang, A Course in fuzzy systems and control, *Prentice-Hall, Inc.*, 1997.

### 저자소개



金 周 雄(正會員)

1996년 2월 동국대학교 전자공학과  
공학학사. 1998년 2월 동국대학교  
전자공학과 공학석사. 2000년 2월  
동국대학교 전자공학과 박사수료.  
1997년~현재 뉴파워전자(주) 근무.

<주관심분야: 인공지능, 의용공학,

전력전자, SMPS>



鄭 慶 權(正會員)

1998년 2월 동국대학교 전자공학과  
공학학사. 2000년 2월 동국대학교  
전자공학과 공학석사. 2000년 8월~  
현재 동국대학교 전자공학과 박사과정.  
<주관심분야: 디지털 신호처리,  
인공지능, 지능제어>

嚴 基 煥(正會員) 第38卷 SC編 第4號 參照