

論文94-31B-3-12

영점 보상 Sigmoid-prime 함수에 의한 역전파 알고리즘

(Back-propagation Algorithm with a zero compensated Sigmoid-prime function)

李旺國*, 金正燁**, 李駿宰**, 河永浩**

(Wang Gug Lee, Jeong Yeop Kim, Jun Jae Lee and Yeong Ho Ha)

要 約

역전파 알고리즘이 가지는 일반적인 문제점으로는 학습의 수렴속도 및 국부최소로 인한 오 분류를 일으킬 수 있다는 것이다. 본 논문에서는 이런 문제점을 해결하기 위해 제시된 기존의 변형 역전파 학습 알고리즘을 살펴보고 실제 뉴런의 출력이 0이나 1에서 sigmoid-prime 함수가 0이 되는 것을 보상하는(영점 보상) 새로운 학습방법을 제안한다. 제안한 방법은 학습속도가 기존의 방법들에 비해 빠를 뿐만 아니라 학습률(η) 등의 변화에 대하여 가장 넓은 범위에서 최적 학습의 결과를 보여주기 때문에 적절한 변수값의 설정이 쉽고, 하드웨어 구현시 선형소자로만 구성할 수 있는 장점이 있다.

Abstract

The problems in back-propagation(BP) generally are learning speed and misclassification due to local minimum. In this paper, to solve these problems, the classical modified methods of BP are reviewed and an extension of the BP to compensate the sigmoid-prime function around the extremity where the actual output of a unit is close to zero or one is proposed. The proposed method is not only faster than the conventional methods in learning speed but has an advantage of setting variables easily because it shows good classification results over the vast and uncharted space about the variations of learning rate, etc.. And it is simple for hardware implementation.

I. 서 론

패턴인식은 그 실용성에 대한 기대감으로 많은 연

* 正會員, 國防科學 研究所。

(Agency for Defense Development)

** 正會員, 慶北大學校 電子工學科

(Dept. of Elec. Eng., Kyungpook Nat'l Univ.)

接受日字 : 1993年 1月 27日

구가 되어 왔다. 최근에는 기존의 원형정합(template matching), 통계적(statistical) 및 구문론적(syntactic) 접근방법에 비해 인간의 두뇌구조를 모방한 신경회로망이 적용되는 경우, 기존의 방법들이 잘 해결하지 못하는 여러 분야에서 좋은 성능이 발휘되고 있다.¹⁾ 패턴인식을 위한 신경회로망 학습알고리즘에는 Hebbian Learning Rule, Perceptron 학습 알고리즘, Delta Rule, Competitive Learning Rule, Back-propagation Rule, Counter Propagation Rule, Simulated

Annealing 등²⁾이 있으며, 이들 중 역전파(Back-propagation) 알고리즘이 일반적으로 많이 사용되고 있다.

역전파 알고리즘은 지도학습(supervised learning) 알고리즘으로서, 학습시켜야 할 모든 패턴들의 각각에 대한 기대 출력값과 실제 출력값 사이의 평균 제곱 오차에 해당하는 비용함수를 최소화 하기 위한 회로망의 연결강도를 구하기 위하여 일반화된 델타룰(generalized delta rule)을 사용하며, 다층 구조를 갖는 신경회로망에 적용된다. 학습의 첫 단계는 회로망에 입력 패턴을 제시하고 각 노드에 대해서 활성함수로부터 출력을 산출하는 전향단계이며, 두번째 단계는 기대 출력과 실제 출력의 차이 값을 역전파 시키면서 층(layer)과 층 사이의 연결강도를 조절하는 후향단계로서, 입력패턴에 대해 회로망의 동작이 안정화 될 때까지 즉, 출력에서의 비용함수 값이 기준치를 넘지 않을 때 까지 이 두 단계를 반복해서 수행한다.

역전파 알고리즘에 의한 학습 방법이 가지는 일반적인 문제점으로는 최적 조건을 만족하는 지점에 도달하는 수렴속도를 들 수 있는데, 기울기 값이 작은 구간에 존재하는 협곡 부근에서 개신되는 연결강도가 발산하게 되어 학습에 많은 시간이 소요되기 때문이다. 또한, 국부 최소(local minima)에 빠질 경우 학습능력을 잃게 되어 입력패턴을 오 인식하게 된다. 그리고, 학습에 필요한 변수값의 변화가 적음에도 불구하고 학습시간에 많은 차이를 가져오게 되어 최적의 변수 값을 선택하기가 매우 어려운 문제점이 있다. 근본적으로 동일한 학습 알고리즘에 소량의 변화를 주어 수렴속도가 향상된 알고리즘들에 있어서 동일한 문제를 학습하기 위한 속도에 큰 차이가 나기가 어려우며, 학습률 등의 변수 값의 존재 범위가 넓지만 기존의 발표된 알고리즘들이 각기 몇가지의 최적 변수값에 대해서만 성능이 확인되어 있어 그 장단점을 논의하기가 어렵다. 또한, 각 알고리즘 별로 문제 해결을 위한 최적 변수값이 서로 달라 변수값 설정에 어려움이 있다.

본 논문에서는 학습시 연결강도의 수렴속도를 개선하고 국부최소에 빠지는 문제점 해결을 위해 제시된 기존의 변형된 역전파 학습 알고리즘들의 특징을 알아 본다. 다음으로, 학습 과정에서 연결강도의 개신을 위해 출력에서의 오차를 역전파하는 과정상의 sigmoid-prime 함수 값을 임의의 변수를 도입해 변형한 새로운 학습 방법을 제안한다. 역전파 학습 알고리즘의 단점을 보완한 기존의 방법으로는 이득항을 활성함수의 입력에 포함시켜 학습시 연결강도 및 이

득값을 함께 조절하는 방법³⁾, 비용 함수를 변형하여 국부최소로 부터 벗어나는 방법⁴⁾, 그리고 회로망의 연결강도를 계산하는 과정에 hyperbolic arctangent 함수를 도입하고, sigmoid 함수의 미분치에 DC 항을 추가하는 방법⁵⁾ 등이 있다. 이러한 방법들에 비해 제안한 방법은 연결강도의 개신을 위해 출력에서의 오차를 역전파 하는 과정에서 sigmoid-prime 함수 값을 임의의 변수를 도입해 변형함으로써, 학습속도 및 결과가 함수의 변형에 관련된 변수값의 변화에 무관하게 거의 유사하고, 학습률(η) 등의 변수값 변화에 대하여 가장 넓은 범위에서 최적 학습의 결과를 보임으로써, 최초 문제가 주어졌을 때 변수설정이 쉬운 장점이 있다. 실험에서는 기존의 변형된 역전파 학습 알고리즘과 제안한 학습방법에 대해 동일한 학습조건을 주어 실험한 결과를 비교 분석하였다.

II. 기존의 역전파 학습 알고리즘(BP)

역전파 학습 모델은 입력층, 은닉층(hidden layer) 및 출력층으로 구성되어 있는 다층 구조를 이루고 있으며, 각 층은 여러개의 노드로 구성되어 있다. 각 층의 노드는 자신이 위치하는 층의 바로 위층에 존재하는 모든 노드들과 연결되어 있으며, 연결부는 양수 혹은 음수의 가중치를 가지고 있다. 각 층의 노드 출력은 연결부의 가중치를 통해 상위층으로 전달되며, 각 노드의 출력은 자신에게 연결된 아래층 노드의 출력과 가중치의 곱의 합수로 주어지며, 노드 i 의 출력 o_i 는 식(1)과 같이 주어진다.

$$o_i = f(\text{net}_i) \quad (1)$$

여기서, net_i 는 노드 i 의 입력으로 가중치가 주어진 아래층 노드들의 출력을 더한 값이며, 식(2)와 같다.

$$\text{net}_i = \sum_j w_{ij} o_j + \theta_i \quad (2)$$

여기서, w_{ij} 는 서로 다른 층에 존재하는 노드 i 와 노드 j 사이의 연결강도, o_j 는 아래층에 위치하는 노드 j 의 출력이며, θ_i 는 노드 i 에서의 외부 바이어스 성분이다. 활성 함수로는 식(3)과 같이 sigmoid 함수를 사용하며,

$$o_i = \frac{1}{1 + \exp[-(\text{net}_i + \theta_i) \cdot \theta_o]} \quad (3)$$

미분이 가능하고 단조 증가 함수이며, 출력값의 범위는 $0 \leq o_i \leq 1$ 이다. 결국, 역전파 학습 모델은 식

(3)으로부터 비선형 분류(classification) 문제로 생각할 수 있다 역전파 학습 알고리즘은 식(4)로 주어지는 비용함수 값을 최소로 하는 노드간의 가중치를 구하기 위한 반복 과정^[5]으로, 회로망 출력에서의 총 오류합이 기준치를 넘지 않을 때 까지 출력에서의 오차를 역전파하면서 연결 노드간의 가중치를 갱신하며 전향 및 후향 단계를 반복 수행한다.

$$E = \frac{1}{2P} \sum_p \sum_k (t_{pk} - o_{pk})^2 \quad (4)$$

여기서, t_{pk} 와 o_{pk} 는 회로망의 입력으로 가해지는 패턴 p의 기대 출력과 실제 출력이다. 역전파 학습 과정에서 갱신되는 가중치의 변화율은 각 노드가 출력 층, 혹은 은닉층에 존재하는가에 따라 각각 식(5) 및 식(6)의 δ_{pk} 와 δ_{pj} 에 비례한다.

$$\delta_{pk} = (t_{pk} - o_{pk})o_{pk}(1 - o_{pk}) \quad (5)$$

$$\delta_{pj} = o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} W_{kj} \quad (6)$$

여기서, k와 j는 각각 출력층 및 은닉층의 노드를 나타낸다.

일반적인 역전파 학습 알고리즘의 단점으로는 학습하는데 시간이 너무 많이 걸린다는 것인데, 이는 식(5) 및 식(6)에 포함되어 있는 sigmoid-prime 함수에서 출력이 0 혹은 1인 경우, 노드간의 연결강도가 갱신이 되지 않아 더 이상 학습이 되지 않으며 때로는 국부 최소에 빠지게 되어 오분류를 하게 된다. 또한, 학습률을 등의 학습 관련 변수가 주어진 문제의 특성에 따라 상이할 수 있어 패턴인식 문제가 주어졌을 때 최적 변수값을 결정하는데 어려움이 따르게 된다.

III. 기존의 변형된 역전파 학습 알고리즘

1. 이득항을 회로망의 입력에 포함한 역전파 알고리즘^[3]

일반적인 역전파 학습 알고리즘은 적당한 수렴속도와 새로운 입력에 대하여 보편적으로 잘 동작하는 장점이 있으나, 간혹 수렴속도가 아주 느리거나 학습 결과가 좋지 않은 경우가 발생한다. 이를 개선하기 위해 회로망의 입력에 이득(gain) 항을 추가함으로써 학습의 수렴속도가 빠르게 되고, 입의의 새로운 입력에도 잘 동작하는 회로를 구성할 수 있다 각 노드의 출력은 이득항이 추가되어 식(7)과 같다.

$$o_i^s = f(g_i^s net_i^s) \quad (7)$$

여기서, s는 각 노드가 위치하는 층을 나타낸다. 노드간의 갱신되는 가중치의 변화율을 구하기 위해 비용함수를 가중치에 대해 편미분하여 체인룰을 적용하면 식(8)과 같이 주어진다.

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}^s} &= \frac{\partial E}{\partial net^{s+1}} \times \frac{\partial net^{s+1}}{\partial o_i^s} \times \frac{\partial o_i^s}{\partial net^{s+1}} \times \frac{\partial net^{s+1}}{\partial w_{ij}^s} \\ &= [-\delta_1^{s+1} \dots \delta_n^{s+1}] \begin{bmatrix} w_{1j}^{s+1} \\ \vdots \\ w_{nj}^{s+1} \end{bmatrix} f'(g_i^s net_i^s) g_i^s o_j^{s-1} \end{aligned} \quad (8)$$

식(8)에서 앞의 편미분 3개항을 δ_{si} 로 두면

$$\delta_i^s = \left(\sum_k \delta_k^{s+1} w_{ki}^{s+1} \right) f'(g_i^s net_i^s) g_i^s \quad (9)$$

이고, 갱신되는 연결강도의 변화율은 식(10)과 같다.

$$\Delta w_{ij}^s = \eta_w \delta_i^s o_j^{s-1} \quad (10)$$

여기서, η_w 는 가중치의 학습률이다. 또한, 학습과정에서 갱신되는 이득의 변화율을 구하기 위해 비용함수를 이득에 대해 편미분하고 체인룰을 적용하면 식(11)과 같이 주어지며.

$$\frac{\partial E}{\partial g_i^s} = \left(\sum_k \delta_k^{s+1} w_{ki}^{s+1} \right) f'(g_i^s net_i^s) net_i^s \quad (11)$$

이득의 변화율은 식(9) 및 식(11)로 부터 식(12)와 같이 주어진다.

$$\Delta g_i^s = \eta_g g_i^s net_i^s / g_i^s \quad (12)$$

여기서, η_g 는 이득에 대한 학습률이다.

이 알고리즘은 노드간의 가중치를 갱신할 때 이득을 함께 갱신하여, 가중치 변화율의 방향 벡터 크기를 결정할 때 이득항을 고려하므로 더욱 빨리 비용함수를 줄이게 되어 수렴속도를 향상하게 된다.

2. 단순화된 비용 함수를 이용한 역전파 알고리즘^[4]

학습시 갱신되는 가중치 변화율은 식(5) 및 식(6)의 δ_{pj} 와 δ_{pk} 에 비례하는데, 실제 출력이 기대 출력과 같은 경우 뿐만 아니라, 0 또는 1이 될 경우에도 δ_{pj} 및 δ_{pk} 가 0이 되어 가중치가 더 이상 갱신되지 않아 학습능력을 잃게 된다. 이러한 문제점을 해결하기 위해 새로운 비용함수를 사용하여 sigmoid-prime 항을 식(5) 및 식(6)으로부터 제거하여 노드에서의 실제 출력이 0 또는 1일 경우에도 가중치의 갱신이 이

루어지게 되어 국부최소에서 벗어날 수 있게 된다.

실제 출력 o_{pj} 가 주어질 때, 기대 출력 t_{pj} 에 따라 비용 함수는 다음과 같다.

$$E_p = \begin{cases} - (1 - t_{pj}) \ln(1 - o_{pj}), & t_{pj} = 0 \\ - t_{pj} \ln o_{pj}, & t_{pj} = 1 \\ - \sum_j ((1 - t_{pj}) \ln(1 - o_{pj}) + t_{pj} \ln o_{pj}), & 0 < t_{pj} < 1 \end{cases} \quad (13)$$

식(13)에서 정의된 비용 함수의 노드 출력에 대한 편미분은

$$\frac{\partial E_p}{\partial o_{pj}} = \frac{\partial}{\partial o_{pj}} \sum_p (t_{pj} \ln o_{pj} + (1 - t_{pj}) \ln(1 - o_{pj})) \quad (14)$$

이고, 각 출력노드에서 δ_{pj} 는 식(15)과 같이 주어진다.

$$\begin{aligned} \delta_{pj} &= -\frac{\partial E_p}{\partial net_j} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial net_j} \\ &= -\left(-t_{pj} \frac{1}{o_{pj}} + (1 - t_{pj}) \frac{1}{1 - o_{pj}} \right) (1 - o_{pj}) o_{pj} \\ &= (t_{pj} - o_{pj}) \end{aligned} \quad (15)$$

온느총 노드에서 δ 는 기존의 역전파 학습방법과 동일하며, 출력층 및 온느총에서 모두 $(1 - o_{pj})o_{pj}$ 항이 제거되어, 노드출력 o_{pj} 가 0 혹은 1인 경우에도 가중치의 갱신이 이루어져 국부최소에 빠지지 않고 수렴속도가 빨라지게 된다.

3. Hyperbolic arctangent 함수와 변형 sigmoid 함수를 이용한 역전파 알고리즘

일반적인 역전파 학습 알고리즘은 수렴 속도가 느리고 국부최소에 빠지기 쉬운 단점이 있으며, 원인은 활성 함수를 미분하는 과정에서 발생하게 된다. 국부최소에서 탈피하고 수렴속도를 향상하기 위한 다수의 노력이 진행되어 왔으며 이 알고리즘은 변형 sigmoid-prime 함수를 사용하여 국부최소로부터 벗어나고 hyperbolic arctangent 함수에 의한 가속 효과로써 학습 속도를 개선하였다.

식(3)을 미분하여 얻어지는 sigmoid-prime 함수는 식(16)과 같으며

$$S(o_{pj}) = \frac{\partial o_{pj}}{\partial net_{pj}} = o_{pj}(1 - o_{pj}) \quad (16)$$

식(5)에서 δ_{pj} 가 $t_{pj}=o_{pj}$ 인 경우 뿐만 아니라 o_{pj} 가 0 또는 1인 경우에도 0이 되어 국부최소에 빠지게 되므로, 아래 식(17)에서와 같이 sigmoid-prime 함수에 상수(DC) 값을 더해 줌으로써 δ_{pj} 가 0이 되더라도

연결강도의 변화가 학습중에 계속 발생하여 국부최소로부터 벗어날 수 있다.

$$S_M(o_{pj}) = o_{pj}(1 - o_{pj}) + DC \quad (17)$$

국부최소로부터 벗어나는 속도를 가속하기 위하여 Hinton⁷은 sigmoid-prime 함수가 0이 되는 영역에서 무한대의 값을 가지는 비선형 비용함수를 사용할 것을 제안 하였으며, 이 알고리즘에서는 δ_{pj} 의 계산에 사용된 $(t_{pj}-o_{pj})$ 대신에 $\tanh^{-1}(t_{pj}-o_{pj})$ 를 사용하여 수렴율을 더욱 향상 시켰다.

본 장에서는 기존의 역전파 알고리즘의 특성 및 이의 문제점을 해결하기 위하여 제안된 변형된 역전파 학습 알고리즘 들에 대하여 기술하였으며, 다음 장에서는 학습에 필요한 변수값의 선택폭을 개선한 영점 보상 sigmoid-prime 함수에 의한 역전파 알고리즘을 제안한다. 이와 같이 변형된 알고리즘들의 학습속도는 기존의 역전파 알고리즘보다 훨씬 빠르며, 국부최소에 빠지는 경우가 거의 발생하지 않아 분류결과에 오류가 없게 된다.

IV. 영점보상 sigmoid-prime 함수에 의한 역전파 알고리즘

이상에서 소개된 기존의 변형 역전파 학습 알고리즘들은 국부최소로부터 벗어나 수렴속도를 상당히 향상하였으나, 학습시 선정해야 할 학습률 등 학습 관련 변수값을 선택하는데 있어서 최적변수 영역이 좁기 때문에 적절한 값을 선정하기에 어려움이 있다. 본 장에서는 이와 같이 문제가 주어질 경우, 최적의 학습조건과 유사한 학습결과를 얻기에 유리하고, 변수값의 선택에 융통성이 있는 학습방법을 제안한다.

식(16)으로 주어지는 sigmoid-prime 함수는 o_{pj} 가 0 혹은 1인 경우에 0이 되어 연결강도가 갱신되지 않는 영점이 존재한다. 제안한 알고리즘은 이러한 영점들을 o_{pj} 가 각각 0보다 작고 1보다 큰 지점으로 이동시킴으로 o_{pj} 가 0 혹은 1인 경우에도 연결강도가 갱신되는 효과(영점보상)를 가져오게 하였다. 식(16)의 sigmoid-prime 함수의 기울기를 α 배 스케일한 새로운 함수는 식(18)과 같이 된다.

$$S_o(o_{pj}) = -\alpha(o_{pj} - 0.5)^2 + 0.25 \quad (18)$$

식 (18)의 최대값은 sigmoid와 같고 스케일 인자 α 에 의해 기울기가 변한다. 그림 1은 제안된 함수를 $\alpha=0.6$ 일 때와 식(17)에서 $DC=0.1$ 일 때, 그리고

sigmoid-prime 함수와 비교하였다.

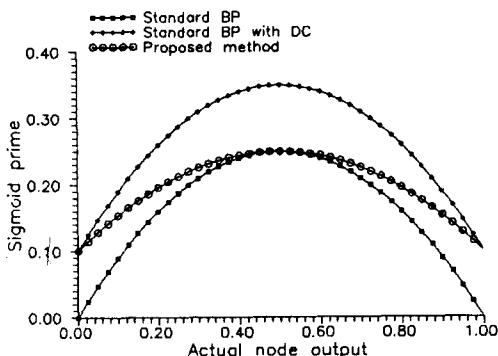
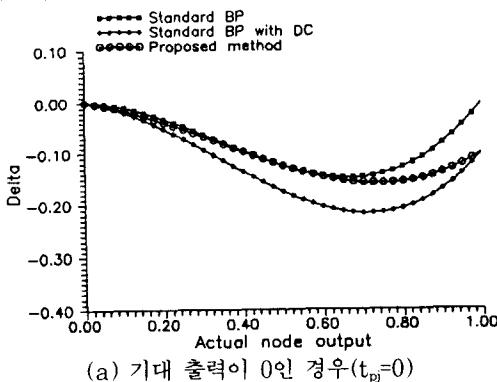


그림 1. 영점보상 및 기존 sigmoid-prime 함수 비교

Fig. 1. The comparison of sigmoid-prime functions with DC and zero compensation.

이 함수의 타당성을 보이기 위해 기대 출력 값이 주어질 때 회로망의 연결강도의 변화율에 비례하는 δ_{pj} 의 값을 각 알고리즘 별로 구해 보면 그림 2와 같다. 그림 2(a)에서 제안된 영점보상 sigmoid-prime 함수는 기대 출력이 0인 경우에 실제 출력이 1에서는 DC 항을 더한 것과 같으나 실제 출력이 1에서 멀어질수록 즉, 0 근처로 갈수록 sigmoid 함수에 더 근접한다. DC 항을 더한 sigmoid-prime에 hyperbolic arctangent를 적용한 경우도 값이 작은 부분에서는 거의 선형이기 때문에 DC 항을 그림에서 0.1로 작게 한 경우 경우와 크게 차이가 나지 않으므로 생략하였다. 만일 스케일 인자 a 를 점점 더 작게 하면 delta 함수가 선형에 가까워지고 $a=0$ 인 경우 sigmoid-prime = 0.25로 상수가 되어 delta는 완전 선형이 된다. 그러나 이렇게 되면 sigmoid의 비선형 특성이 사라진다.



(a) 기대 출력이 0인 경우($t_{pj}=0$)

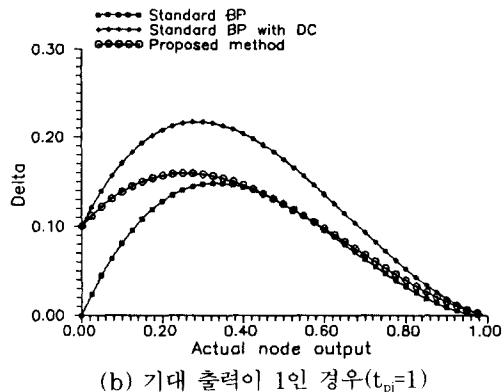


그림 2. 노드의 실제 출력 값에 따른 δ_{pj} 값

Fig. 2. The value of δ_{pj} for the actual node output.

그림 2(b)에서도 마찬가지로 기대 출력과 같은 0인 경우에도 마찬가지로 같다. 추가된 DC항에 Hyperbolic arctangent 함수를 곱해서 적용한 delta 함수는 가중치의 변화량이 아주 커지므로 학습률이 커지게 될 경우 또 다른 국부최소를 오가며 섭동(oscillation)할 수도 있게 되어 학습에 더 많은 시간이 소요될 수 있다. 반면에, 제안한 알고리즘은 실제 출력이 기대 출력과 다를 경우에 연결강도의 값을 적당한 크기로 변화 시킴으로써, 광범위한 학습률 영역에서 안정되게 수렴속도를 향상 시킬 수가 있다.

제안된 영점보상 sigmoid-prime 함수를 적용한 학습 방법은 실제 출력이 기대 출력과 다른 영역 부근에서 역전파될 때 δ_{pj} 의 값이 변형된 기존의 역전파 알고리즘과 같지만 굴곡이 완만하여 학습속도를 향상시킨다. 또한 학습시 최적변수 영역이 기존의 알고리즘보다 넓게 분포하고 있어서 학습률과 같은 변수값의 설정이 쉽고, 학습결과도 뛰어나며, 비선형 소자를 사용하는 Fahlman^[5]의 방법에 비해 하드웨어 구현이 용이한 장점이 있다.

V. 실험 및 고찰

실험에서는 각 알고리즘의 학습속도 및 분류성능을 위주로 분석하기 위하여 실험의 조건을 동일하게 주고 학습률 등의 변수값을 변화하면서 비교분석 하였다.

실험에 사용된 프로그램은 [6]의 Generalized delta rule을 이용한 역전파 알고리즘을 사용하였으며, 여러수식 부분만 각 방법에 따라 내용을 수정하고 실험의 정확성을 기하기 위하여, 수정된 내용을 초기화 하였을 때 일반적인 역전파 알고리즘과 동일한

결과를 보이는가를 확인하였다. 학습중의 연결강도 개선은 모든 입력 패턴을 회로망에 한번씩 가한 후 역전파되는 오류의 크기에 따라 한번씩 이루어지며 (epoch), 학습을 종결하는 조건(error criterion)은 0.05, 0.01 및 0.005의 세가지를 사용하였다. 입력 패턴은 순으로 쓴 13x13으로 된 2차원 이진 영문 대문자 26자이며 2차원 배열을 1차원 배열로 나열한 169개의 데이터를 사용하였으며, 은닉층의 수는 1개로 제한하고 노드수는 24, 48 및 72개의 세종류에 대하여 실험하였다.

학습의 수렴속도를 향상시키기 위해 모멘텀 (momentum)을 사용하는 것이 제안되어 있으며⁶⁾, 본 실험에서는 적절한 학습률(η)을 설정한 후(0.7을 임의로 정하였음) 최적 모멘텀 변수값을 각 알고리즘 별로 찾아서 다시 학습률을 0.1에서 2.2까지 0.1씩 증가시켜 가며 패턴 인식에 오류가 나타나지 않을 때 까지 수행하였다.

그림 3은 학습 종결조건이 0.05이며 48개의 은닉층을 가질 때의 학습률의 변화에 따른 각 알고리즘의 epoch 수이며 BP나 DC 가진 BP는 학습률이 1.2 이상에서는 학습이 불안정하여 패턴인식에 오류가 나타난다. 즉 학습률의 범위가 그 이하여야만 패턴인식에 오류가 발생하지 않는다.

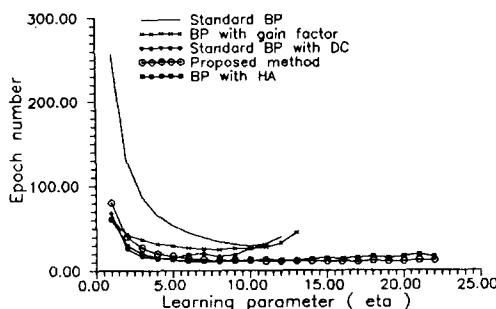


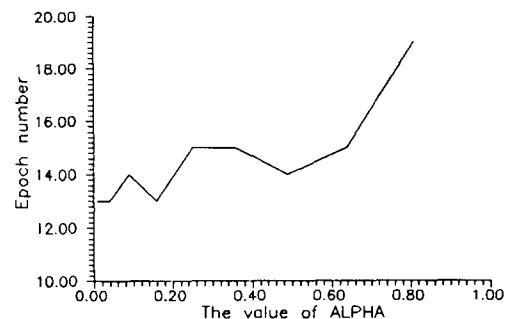
그림 3. 학습률에 대한 각 알고리즘별 학습속도

Fgi. 3. Number of epochs for five leaming algorithms.

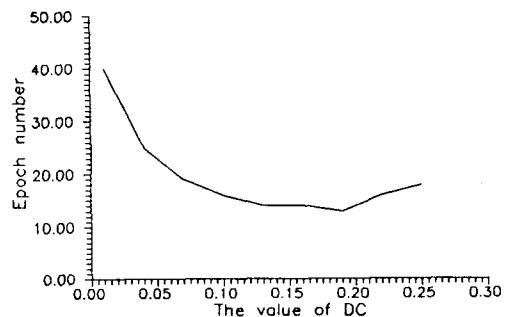
그림에서 보는 바와 같이 기존의 제안된 변형 학습 알고리즘 중 2가지는 일반적인 역전파 학습 알고리즘에 비해 일부분의 학습률 구간에서는 성능이 우수하나 학습률의 값이 증가함에 따라 성능이 급격히 떨어지게 된다. 기존의 변형 학습 알고리즘 중 가장 우수하다고 판단되는 Hyperbolic arctangent 함수를 도입하고, sigmoid 함수의 미분치에 DC항을 추가한 학습 알고리즘은 광범위한 학습률 범위에서 최적 학습조건과 유사한 학습결과를 보이나 최적조건보다 학

습률이 증가함에 따라 5회 내지 7회정도의 학습을 더 필요로 하고 있다. 이는, 가중치를 개선하는 과정에서 국부최소를 빠져 나오기 위해 DC 값을 크게 설정했을 경우, 기울기의 과도한 변화로 인하여 섭동할 수 있다.

제안한 영점보상 sigmoid-prime 함수에서는 활성 함수를 변형하기 위한 새로운 변수 α 가 학습시 추가됨으로, 최적값을 선택하는데 어려움이 있을것으로 생각되나, 그림 4 (a)에서와 같이 0.1에서 0.9까지 변하는 α 값 뿐만 아니라 은닉층의 노드 갯수에 관계없이 학습성능이 일정하여 새로운 변수의 적절한 값을 선택하는데 큰 어려움이 없다. DC항이 추가된 학습 알고리즘은 DC 값을 0.01에서 0.25까지 변화시킴에 따라 그림 4(b)에서와 같이 학습 수렴속도가 변하게 되어 최적 학습에 필요한 변수값을 선택하는데 어려움이 있으며 학습 수렴속도도 제안한 방법에 비해 조금 떨어진다.



(a) α 값의 변화에 따른 제안된 방법의 학습속도



(b) DC 값의 변화에 따른 hyperbolic arctangent 방법의 학습속도

그림 4. α 및 DC 값의 변화에 따른 각 알고리즘별 학습속도

Fgi. 4. Number of epochs for the value of α & DC.

학습 속도 및 분류 성능면에 있어서 이득을 회로망 입력에 포함시키는 방법은 하드웨어의 구현이 복잡하고, 변수의 최적영역이 좁으며, 변형 학습 알고리즘 중 학습속도가 가장 빠다. 비용함수의 항을 변형하여 δ_p 에서 sigmoid-prime 항을 제거함으로 국부최소에 빠지지 않게 하는 방법은 다른 알고리즘에 비해 계산량이 다소 적으며, 학습률이 작은값에서 학습성능이 우수하나 최적 변수영역이 좁은 단점이 있다. 가중치의 계산과정에 Hyperbolic arctangent 함수를 도입하고, sigmoid 함수의 미분치에 DC항을 추가하는 방법은 기존의 변형 알고리즘 중 성능이 가장 우수하다. 학습률이 증가함에 따라 학습속도가 서서히 떨어지게 되지만, 제안한 방법은 실제 출력이 기대 출력과 같은 경우에는 가중치를 변화시키지 않으며 가중치의 갱신시는 변화되는 벡터성분을 고려하고 기대 출력과 실제 출력의 차이가 클수록 연결강도의 변화량을 크게 하므로 수렴속도를 향상 시킨다. 뿐만 아니라 영점보상을 위한 변수(ratio) 값의 변화에 관계 없이 학습속도 및 분류성능이 다른 알고리즘에 비해 뛰어나며 학습률의 최적영역이 넓어서 학습시 변수 설정이 쉽다.

VII. 결 론

본 논문에서는 일반적인 역전파 학습 알고리즘에 대하여 알아 보았으며 이 알고리즘이 가지는 저조한 학습 수렴속도 및 국부최소에 빠지게 되어 불완전 학습으로 인한 오 분류를 발생시키는 sigmoid-prime 함수의 특성을 분석하였다. 이와 같은 문제점을 해결하기 위하여 많은 방법들이 제시되어 있으나, 그들 중 우수하다고 평가되는 몇가지 변형 알고리즘 중 이득을 회로망 입력에 포함시키는 방법, 비용 함수의 항을 변형하여 국부최소에 빠지지 않게 하는 방법 및 가중치의 계산과정에 Hyperbolic arctangent 함수를 도입하고, sigmoid 함수의 미분치에 DC 항을 추가하는 방법에 대하여 각기 장 단점을 학습속도 및 분류성능면에서 비교분석 하였다.

기존의 변형 학습방법중 가장 우수한 것으로 판단되는 sigmoid-prime 함수에 DC 항을 추가하는 방법은 가중치를 갱신할 때 가중치의 변화하는 방향성 분을 고려하지 않으므로 가중치를 노드의 출력에 따라 과소 혹은 과다하게 갱신하게 되어 학습속도가 떨어질 가능성이 많게 되며 구현회로에 비선형 소자가

포함된다. 따라서, 회로망의 연결강도를 갱신하기 위해 출력에서의 오차를 역전파하는 과정에서 sigmoid-prime 함수의 영점을 보상함으로써, 최적학습 조건에서 학습속도가 기존의 방법에 비해 빠르고, 선형소자로만 구성되며, 학습속도 및 분류성능이 거의 유사하고 적정 학습률의 범위가 넓은 학습 방법을 제안하였다

参考文献

- [1] K. S. Fu and A. Rosenfeld, "Pattern Recognition and Computer Vision," IEEE Computer, pp. 274-282, Oct. 1984
- [2] D. E. Rumelhart, J. L. McClelland, Parallel Distributed Processing : Exploration in the Microstructure of Cognition, vol 1 : foundations, MIT press, 1986.
- [3] John K. Kruschke and Javer R. Movellan, "Benefits of Gain : Speeded Learning and Minimal Hidden Layers in Back-Propagation Networks," IEEE Trans. Sys., Man and Cyberts, Vol.21, No.1, pp. 273-280, 1991.
- [4] A. Krzyzak, W. Dai and C. Y. Suen, "Classification of Large Set of Handwritten Characters Using Modified Back Propagation Model," IJCNN SanDiego, Vol.3, pp.225-232, 1990.
- [5] Scott E. Fahlman, "Faster-Learning Variations on Back-Propagation : AN Empirical Study," in Proc., Connectionist Models Summer School, pp.38-51, 1989.
- [6] Yoh-Han Pao, Adaptive Pattern Recognition and Neural Networks, Addison Wesely, p.128, 1989.
- [7] Hinton, G. E., Connectionist Learning Procedures, Technical Report CMU-CS-87-115, Carnegie-Mellon University, Computer Science Dept., Pittsburgh, PA, 1987.

著者紹介

李 旺 國(正會員) 第 30 卷 B 編 第 6 號 參照
현재 국방과학 연구소 선임 연구원

金 正 塵(正會員) 第 30 卷 B 編 第 5 號 參照
현재 경북대학교 대학원 전자공학과
박사과정

李 駿 宰(正會員) 第 30 卷 B 編 第 6 號 參照
현재 경북대학교 대학원 전자공학과
박사과정

河 永 浩(正會員) 第 30 卷 B 編 第 5 號 參照
현재 경북대학교 전자공학과 부교수