

적응 뉴럴 컴퓨팅 방법을 이용한 동적 시스템의 특성 모델링

Characteristics Modeling of Dynamic Systems Using Adaptive Neural Computation

김 병 호*
(Byoung-Ho Kim)

Abstract : This paper presents an adaptive neural computation algorithm for multi-layered neural networks which are applied to identify the characteristic function of dynamic systems. The main feature of the proposed algorithm is that the initial learning rate for the employed neural network is assigned systematically, and also the assigned learning rate can be adjusted empirically for effective neural learning. By employing the approach, enhanced modeling of dynamic systems is possible. The effectiveness of this approach is verified by simulations.

Keywords : dynamic system modeling, adaptive neural computation, dynamic learning rate.

I. 서론

첨단 산업의 발전에 따라 보다 정밀한 작업이 요구될 뿐만 아니라, 다양한 형태의 아주 위험한 작업들을 수행해야 하는 과제가 대두되고 있다. 이러한 요구를 만족시키기 위하여 최근에는 인간의 기능을 대신 수행할 수 있도록 하기 위한 로봇에 관한 연구가 활발하게 이루어지고 있다[1,2]. 이러한 연구에 있어서 인간과 로봇간의 상호작용을 현실적으로 모델링하고, 모델링된 함수특성을 로봇이 원만하게 구현하도록 하는 것은 매우 중요한 과제로 알려져 있다. 또한, 로봇이 인간의 기능을 대신하기 위해서는 인간이 사물을 인식하고 판단하는 과정을 체계적으로 알고리즘화하는 것이 매우 중요하다. 이러한 과정에는 단순한 함수 관계의 근사화 능력뿐만 아니라, 복잡한 정보를 분석하여 핵심적인 관계를 나타내어 주는 기능 함수의 모델링이 필수적으로 요구된다. 이러한 목적을 위하여 인공적으로 구현한 다층 신경망은 유용하게 활용될 수 있다[3,4].

현재까지 다양한 연구결과에 의해, 다층 신경망은 어떤 동적 시스템의 특성 모델링, 복잡한 함수 패턴 인식 및 제어 분야 등에 다양하게 응용될 수 있는 것으로 알려져 있다[5-10]. 이러한 신경망을 이용하여 어떤 시스템의 특성을 확인하거나 적절히 근사적으로 모델링함에 있어서 빠른 학습에 의한 입출력 함수 특성 구현은 매우 중요한 과제중의 하나이다. 이러한 신경망의 학습을 위하여 오차역전달 학습 알고리즘이 널리 적용되고 있는데, 신경망의 빠른 학습을 위해서는 적절한 학습율 설정이 중요한 관건이 된다. 대부분의 경우, 경험적으로 학습율을 임의의 값으로 선정하여 설정하여 고정시켜 놓고, 학습을 수행하는 경우가 많다. 이러한 경우, 학습 패턴에 따라 한번에 적절한 학습율을 선정하기가 쉽지 않다. 또한, 고정된 학습율을 학습전반에 걸쳐서 사용하게 되기 때문에 정적인 학습이 이루어지게 된다. 따라서 신경망의 학

습율이 너무 크게 선정된 경우에는 지나친 학습 효과가 나타날 수 있고, 너무 작게 설정된 경우에는 신경망의 수렴 속도가 너무 늦게 되는 경향이 있다[5].

일반적으로 어떤 동적 시스템의 입출력 또는 센서 신호 관찰을 위하여 신경망을 활용하는 경우에는 학습 패턴이 다양하게 나타날 수 있다. 따라서 효과적인 동특성 모델링을 위해서는 학습 패턴에 따라 신경망의 크기와 학습율을 보다 유연하게 결정하는 것이 필요하다. 특히, 보다 효과적인 학습을 유도하고, 신경망의 학습속도를 향상시키는 관점에서 학습율을 조정하는 연구가 진행되고 있다[11,12]. 이러한 연구의 특징을 살펴보면, Hsin[11] 등은 학습이 진행됨에 따라 신경망의 모든 뉴런(neuron)간 연결강도의 방향 코사인을 참조하여 매 순간 학습율을 다르게 적용하는 방법을 제안하였다. 이 방법은 과거 연결강도의 변화량을 근거로 하여 현재 학습율을 결정하는 방법으로서, 신경망의 출력 오차의 변화가 크면 클수록 큰 학습율이 구해지게 된다. 그러나 오차가 증가하는 방향인 경우, 가능하면 학습율을 줄여서 신중한 학습을 유도하는 것이 바람직한데, Hsin의 방법에 있어서는 큰 학습율이 적용되기 때문에 신경망의 학습을 오히려 방해할 가능성을 내포하고 있다. 또한, 물리적인 관점에 있어서는 연결강도의 변화량을 기억해야 하기 때문에 기억용량이 증가하는 단점이 있다. Jin[12] 등이 제안한 알고리즘은 계산과정이 너무 복잡한 단점이 있다. 그럼에도 불구하고, 이러한 연구의 기본 방향은 괄목할 만 하다. 즉, 학습율의 크기를 적절히 조정함으로써 신경망의 학습효과를 향상시킬 수 있기 때문이다. 이와 관련된 정보처리는 사실상 애매한 정보처리 관점에서 접근하는 것이 효과적일 수 있다고 판단된다. 즉, 어느 정도 정보의 흐름을 관찰할 필요가 있다는 것이다.

본 논문에서는 동적 시스템의 특성 모델링에 사용된 신경망의 출력을 지속적으로 관찰하여 신호의 변화 정도를 찾아내고, 이를 바탕으로 지능적인 판단을 내린 다음, 이를 근거로 다층 신경망의 학습율을 조정하는 방법을 제시하고자 한다. 먼저, 효율적인 학습을 위한 초기 학습율은 신경망의 초기 학습 결과를 근거로 결정하는 방법을 제안한다. 그리고 학습이 진행되는 동안 신경망의 출력에 나타난 오차의 변화

* 책임저자(Corresponding Author)

논문접수 : 2007. 1. 25., 채택확정 : 2007. 2. 17.

김병호 : 경성대학교 전기전자메카트로닉스공학부(kimbh@ks.ac.kr)

※ 이 논문은 2006학년도 경성대학교 학술지원연구비에 의하여 연구되었음.

를 관찰하여 지능적으로 판단한 후, 학습율을 크게 하거나 작게 조정하도록 하여 궁극적으로 신경망의 학습 효과를 향상시킬 수 있는 알고리즘을 제안한다.

II. 적응 뉴럴 컴퓨팅 방법

1. 일반적인 다층 신경망의 학습 방법

본 논문에서는 일반적인 다층 신경망의 학습 관계식을 설명하기 위하여 그림 1과 같은 신경망을 고려한다.

그림 1에서 주어진 시스템의 입력층을 i 번째 입력뉴런(input neuron) $x_i(t)$ 와 입력층 바이어스(bias)를 조합하여 $z_i(t)$ 로 정의하면, t 순간에 정의되는 신경망의 입력은 다음과 같이 나타낼 수 있다.

$$z_i(t) = \begin{cases} 1.0, & i = 0, \\ x_i(t), & i = 1, \dots, L. \end{cases} \quad (1)$$

각 학습 입력에 대한 은닉층(hidden layer)의 출력 $h_j(t)$ 는 다음과 같이 정의할 수 있다.

$$h_j(t) = \begin{cases} 1.0, & j = 0, \\ \frac{1}{1 + e^{-s_j I_j(t)}}, & j = 1, \dots, M. \end{cases} \quad (2)$$

여기서 $I_j(t) = \sum_{i=0}^L w_{ji} z_i(t)$.

신경망의 최종 출력 $y_k(t)$ 는 다음과 같이 나타낼 수 있다.

$$y_k(t) = \sum_{j=0}^M w_{kj} h_j(t), \quad k = 1, \dots, N. \quad (3)$$

일반적으로, 신경망의 학습을 위하여 출력층에서의 오차를 역전달하는 학습방법을 사용하는데, 오차함수 $J(t)$ 는 다음과 같이 정의할 수 있다.

$$J(t) = \frac{1}{2} \sum_{k=0}^N \{e_k(t)\}^2 \quad (4)$$




그림 1. 다층 신경망.
Fig. 1. A multi-layered neural network.

여기서 $e_k(t) = y_k(t) - o_k(t)$. 그러면, 은닉층과 출력층 사이의 연결강도에 대한 오차함수의 변화성분은 다음과 같이 나타낼 수 있다.

$$\frac{\partial J(t)}{\partial w_{kj}} = e_k(t) h_j(t). \quad (5)$$

또한, 입력층과 은닉층 사이의 연결강도에 대한 오차함수의 변화성분은 다음과 같다.

$$\frac{\partial J(t)}{\partial w_{ji}} = \sum_{k=0}^N e_k(t) w_{kj} s_j e^{-s_j I_j(t)} \cdot \left\{ \frac{1}{1 + e^{-s_j I_j(t)}} \right\}^2 z_i(t). \quad (6)$$

위에서 기술한 다층 신경망의 연결강도와 미분식을 각각 벡터형태로 나타내면, 각 층의 새로운 연결강도 벡터 w^{new} 는 다음과 같이 학습될 수 있다.

$$w^{new} = w^{old} - \eta \nabla_w J(t). \quad (7)$$

여기서

$$w = [w_{ji} \quad w_{kj}]^T, \\ \nabla_w = \left[\frac{\partial}{\partial w_{ji}} \quad \frac{\partial}{\partial w_{kj}} \right]^T,$$

그리고 η 는 신경망의 연결강도 학습을 위한 학습율을 나타낸다.

일반적인 다층 신경망을 위하여 오차역전달 학습 방법을 사용할 때, 학습율 η 는 고정된 상수값으로써 설정하여 사용하는 경우가 대부분이다. 즉, 학습율을 임의로 설정하여 고정시켜 놓고, 전체 학습패턴에 대한 학습을 반복적으로 수행하게 된다. 이러한 경우 학습 패턴에 따라 한번에 알맞은 학습율을 선정하기가 어렵다. 또한, 정적인 학습으로 인하여 신경망의 학습율이 너무 크게 설정된 경우에는 지나친 학습 효과로 인하여 신경망의 출력이 불안정해질 수 있고, 너무 작게 설정된 경우에는 신경망의 학습 속도가 너무 늦게 되어 원하는 실시간 학습이 곤란하게 되는 경향이 있다. 따라서 초기 학습율을 적절히 설정하는 문제는 신경망의 활용차원에서 매우 유용하게 다루어 질 필요가 있다. 또한, 보다 빠른 신경망의 학습을 위해서는 학습율이 적절히 조정될 수 있는 방법에 관한 연구가 필요하다.

2. 다층 신경망을 위한 적응 학습 방법

일반적인 다층 신경망의 학습을 보다 효율적으로 수행하기 위하여 본 논문에서는 비교적 간단하면서도 지능적인 방법에 착안하여 다음과 같은 두 가지 문제를 고려하였다. 첫째, 신경망의 초기 학습율을 적절히 설정하는 방법을 제시한다. 둘째, 설정된 학습율을 적절히 조정하는 방법을 제안한다. 이러한 관점에서, 다층 신경망을 위한 적응 학습 방법의 핵심 아이디어는 학습의 정도에 따라 보다 효과적인 학습이 이루어질 수 있도록 학습율을 조정하는 것이다. 이러한 방법에 의하면, 다양하게 설계된 신경망을 위한 적응학습이 가능해질 뿐만 아니라 학습 성능이 한층 더 개선될 수 있다는 장점이 있다.

먼저, 신경망의 초기 학습율은 주어진 학습 패턴에 대한 다층 신경망의 초기 학습 결과를 근거로 다음과 같이 설정한다.

$$\eta(t) = -\{\log_{10} \beta\} \max |e_k(t)|, t = 0. \quad (8)$$

여기서, $e_k(t)$ 는 k 번째 출력단의 오차이고, β 는 초기 학습율의 크기를 조정하는 계수로서 0보다 크고 1보다 작은 실수로 정한다. 즉, 이 방법은 행위기반 최적값 발견 방법으로 널리 알려져 있는 시뮬레이티드 어닐링(simulated annealing)기법 [13]을 응용한 것으로서, 주어진 학습 패턴에 대해 신경망의 출력층에서 초기 오차 성분의 절대 최대값을 찾아 내고, 이 값을 이용하여 신경망의 초기 학습율을 설정하며, 가능한 작은 값으로 설정되도록 할 수 있는 장점이 있다.

다음으로, 학습이 진행되는 과정에서 설정된 학습율을 적절히 조정하는 방법은 다음과 같다.

과정 1: 각 샘플링(sampling) 시간 t 에서 주어지는 학습 패턴에 대한 절대오차의 합 $S_e(r)$ 과 이것에 대한 변화성분 δ 를 각각 다음과 같이 구한다.

$$S_e(r) = \sum_n |e_n(t)|, r = 1, 2, \dots \quad (9)$$

$$\delta = S_e(r+1) - S_e(r) \quad (10)$$

여기서 $S_e(0) = 0$, r 은 학습회수이다.

과정 2: $\delta \leq 0$ 인 경우가 연속적으로 P 번 계속되거나, $\delta \leq 0$ 인 경우와 $\delta > 0$ 인 경우가 불규칙적으로 Q ($Q \geq P > 0$)번 나타날 경우에는 확률변수 ξ ($0 < \xi < 1$)를 랜덤(random)하게 선택한다. 그리고 이것에 대하여 (11)을 만족하면,

$$e^{-\frac{\eta(t)}{\delta}} < \xi \quad (11)$$

학습율을 다음과 같이 증가시킨다.

$$\eta(t+1) = (1 + \alpha)\eta(t) \quad (12)$$

여기서, $\alpha = K \log_{10}(1 + \delta)$, K 는 양의 실수으로써 학습율의 증감폭을 미세하게 조정하는 역할을 한다.

과정 3: 한편, $\delta \geq 0$ 인 경우가 연속적으로 P 번 계속되거나, $\delta \geq 0$ 인 경우와 $\delta < 0$ 인 경우가 불규칙적으로 Q 번 나타날 경우에는 랜덤하게 선택된 확률변수 ξ ($0 < \xi < 1$)에 대하여 (13)이 만족되면,

$$e^{-\frac{\eta(t)}{\delta}} < \xi \quad (13)$$

다음과 같이 학습율을 감소시킨다.

$$\eta(t+1) = (1 - \alpha)\eta(t). \quad (14)$$

과정 4: 위의 조건이 모두 만족되지 않으면, 학습율은 갱신하지 않고, 과정 1로 돌아가서 다음 학습을 수행한다. 이러한 과정을 반복하여 원하는 신경망의 출력오차 범위에 들어갈 때까지 학습을 수행한다.

결과적으로, 위에서 제시한 적응 학습 방법의 특징은 학습

이 진행되는 과정에서 신경망의 출력에 나타나는 오차의 변화를 체크한다. 그리하여 신경망의 출력 오차의 변화가 지속적으로 감소하는 경향이면 학습율을 증가시키고, 반대로 증가하는 경향이면 학습율을 감소시킨다. 따라서 다양한 형태의 다층 신경망에도 유연하게 적용이 가능하다.

III. 시뮬레이션 및 결과 검토

그림 2는 어떤 시스템의 동특성을 모델링하기 위한 블록 다이어그램을 나타낸다. 주어진 시스템 모델링은 II장에서 제시한 신경망의 적응학습에 의해 이루어지며, 변화되는 학습율을 사용하는 것이 특징이다.

본 논문에서는 두 가지 시뮬레이션을 수행하여 제시한 학습 방법의 효용성을 보인다.

1. 시뮬레이션 I

첫 번째 시뮬레이션의 목적은 다층신경망을 이용하여 어떤 동적 시스템 함수의 모델링에 있어서 본 논문에서 제시한 적응 학습 방법을 활용할 경우에 예상할 수 있는 학습율의 변화 과정 및 수렴성을 보이교자 하는 것이다.

시뮬레이션 I에서 사용된 동적 시스템의 모델은 다음과 같다.

$$y(t) = \sin t \cos 3t + (t/3), t = 0, \dots, 3.2.$$

그림 2에서 다층 신경망은 그림 1과 같은 형태의 4층 신경망으로서 입력층은 입력 뉴런(neuron) 1개와 바이어스(bias) 뉴런 1개, 첫 번째 은닉층의 뉴런은 10개, 두 번째 은닉층의 뉴런은 5개, 출력층은 1개의 뉴런으로 구성하였으며, 바이어스 뉴런은 모든 은닉층의 뉴런에 연결되어 있다. 여기서 신경망의 입력층은 입력을 그대로 내보내고, 모든 은닉층의 활성화 함수는 시그모이드(sigmoid) 특성을 가지고 있으며, 출력층은 들어온 입력의 합을 출력한다. 시뮬레이션을 위하여 신경망의 바이어스는 1.0, 시스모이드 함수의 기울기는 1.0, $\beta = 0.995$, $P=3$, $Q=5$, $K=0.01$ 이 사용되었다. 그리고 학습을 위한 샘플링 시간은 5ms로 설정하였다.

그림 3(a),(b),(c)는 시뮬레이션 I의 학습과정에 따른 신경망의 출력을 나타내며, 그림 4는 출력층에서의 절대오차합의 변화를 나타낸다. 그림 5는 학습 과정에서 조정되면서 적용된 학습율의 변화 동향을 보이고 있다. 결과적으로, 초기 학습 구간에서 출력층의 절대오차합의 변화가 크게 일어남으로써 학습율의 변화가 큰 폭으로 진행되고 있다. 이는 그림 3(a)에

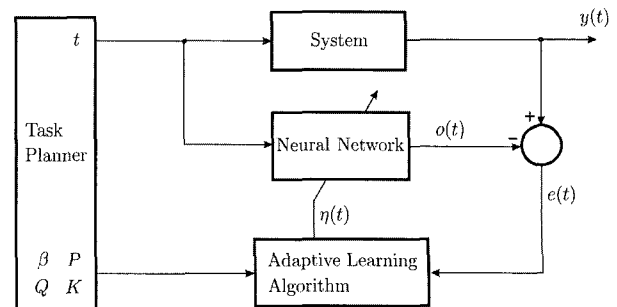
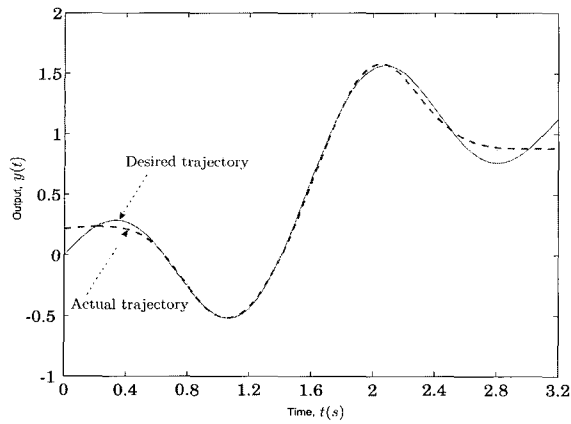



그림 2. 시스템 모델링 블록다이어그램.

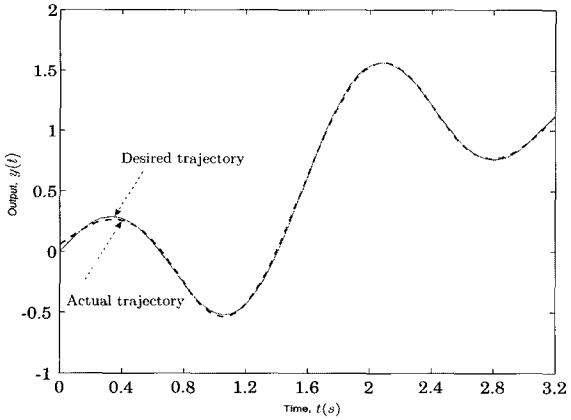
Fig. 2. Block diagram for system modeling.



(a) 5000번 학습



(b) 10000번 학습



(c) 15000 번 학습

그림 3. 학습과정에 따른 신경망의 출력.

Fig. 3. Output of neural network as learning process.

서 볼 수 있듯이, $y(1.055) = -0.517$ 및 $y(2.05) = 1.579$ 와 같은 큰 동적 변화에 대응하기 위한 것으로 해석할 수 있다. 그림 5로부터 일단 이러한 동적 학습이 어느 정도 진행된 다음에는 즉, 학습회수 700번 이후 구간부터 신중한 학습이 이루어지고 있음을 확인할 수 있으며, 10000번 이후 구간에서는 학습율이 미세하게 조정되고 있으며, 사실상 수렴된 것으로 볼 수 있다.

2. 시뮬레이션 II

두 번째 시뮬레이션의 목적은 다층신경망을 이용 어떤 동




그림 4. 절대 출력오차합의 변화.

Fig. 4. Change of the absolute error sum in output layer.

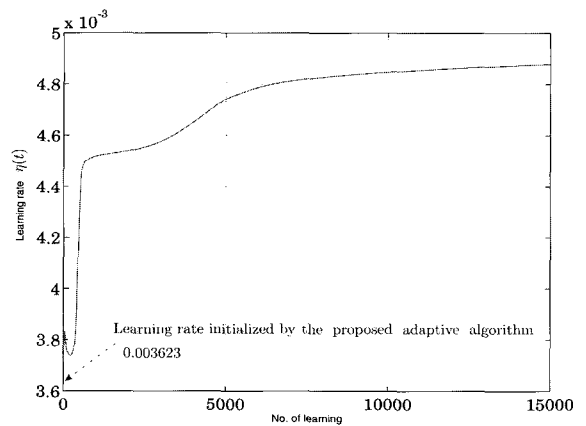


그림 5. 학습율 동정.

Fig. 5. Dynamic learning rate.

적 시스템 함수의 모델링에 있어서 본 논문에서 제시한 적응 학습 방법과 비교적 접근 방법이 유사한 기존의 Hsin[11]에 의해 제시된 방법을 비교 분석함으로써 제안한 방법의 유용성을 보이고자 하는 것이다.

시뮬레이션 II에서 사용된 동적 시스템의 모델은 다음과 같다.

$$y(t+1) = 0.6y(t) + \sin(2\pi t/25) + \sin(2\pi t/10),$$

$$t = 0, \dots, 25.$$

여기서 $y(0) = 0$ 이다.

시뮬레이션 II에서 사용된 다층 신경망은 시뮬레이션 I에서 사용된 것과 동일한 형태의 4층 신경망이며, 첫 번째 은닉층의 뉴런은 20개, 두 번째 은닉층의 뉴런은 20개로 바뀌었고, 시뮬레이션을 위하여 $P=15, Q=20$ 이 사용되었다.

그림 6은 시뮬레이션 II에서 18000번 학습후에 얻은 신경망의 출력을 나타낸다. 그림 7은 학습과정에서 나타나는 신경망의 출력층에서의 최대 학습오차의 변화를 보여주고 있다. 그림 8은 학습 과정에서 조정되면서 적용된 학습율의 변화 동향을 나타낸다. 결과적으로, 그림 6에서 볼 수 있듯이, 제안한 방법에 의한 최종 신경망의 출력이 Hsin의 방법에 비해 더 근사한 출력을 보여주고 있음을 확인할 수 있다. 또한,

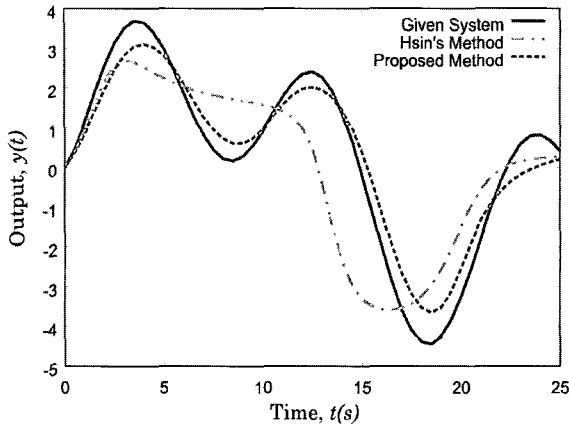


그림 6. 신경망의 출력.

Fig. 6. Output of the neural network.




그림 7. 신경망의 최대 학습오차 동정.

Fig. 7. Maximum learning error of the neural network.

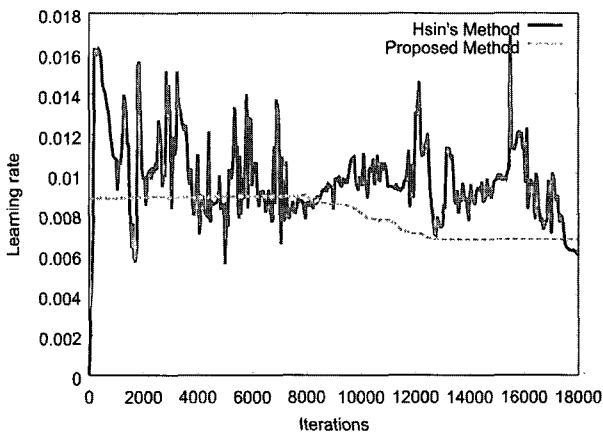


그림 8. 조정되는 학습율.

Fig. 8. Dynamic learning rate adjusted.

제안한 방법을 이용할 경우, 신경망의 학습오차가 보다 더 안정적으로 수렴해 가는 것을 그림 7에서 알 수 있다. 이러한 결과는 그림 8에서 확인할 수 있듯이, 보다 안정된 학습율의 조정과정을 통하여 입증된다. 즉, 신경망의 학습을 개선하기 위하여 학습율을 조정할 때, 안정적인 조정이 바람직하며, 급격한 변화는 오히려 신경망의 학습을 어렵게 만들 수

있다는 분석이 가능하다. 이러한 관점에서 본 논문에서 제안된 방법은 비교적 안정적인 학습을 조정에 의해 신경망의 학습을 한층 더 빠르게 유도할 수 있는 장점이 있다.

IV. 결론

본 논문에서는 동적 시스템의 특성 모델링에 이용된 다층 신경망의 빠른 학습을 유도하기 위한 적응 학습 방법을 제안하였고, 시뮬레이션 예를 통하여 제안된 학습 방법의 효용성을 보였다. 제안된 방법의 특징은 신경망의 학습을 위해 흔히 겪게 되는 초기 학습율을 설정하는 방법을 제시한 것과 설정된 학습율이 신경망의 학습과정에서 적절히 조정되는 것이다. 이를 통하여 주어진 시스템의 동특성과 사용하는 신경망의 크기에 따라 유연한 학습이 가능한 장점이 있다. 결론적으로, 제안된 학습 방법을 이용하면, 다양한 구조의 다층 신경망을 위한 초기 학습율 설정이 효율적으로 가능해지고, 신경망의 학습 정도에 따라 학습율이 적절히 조정되어 한층 더 빠른 학습효과를 얻을 수 있다.

따라서 제안된 학습 방법은 다양한 형태의 다층 신경망의 학습 성능을 향상시키는데 기여할 수 있는 좋은 접근방법이 될 수 있으리라 기대된다. 한편, 학습율의 변화 시점을 효과적으로 판단하기 위한 연구가 추가적으로 필요하다.

참고문헌


- [1] K. Hirai, M. Hirose, Y. Haikawa, and T. Takenaka, "The development of honda humanoid robot." *Proc. of IEEE Int. Conf. on Robotics and Automation*, pp. 1321-1326, 1998.
- [2] K. Akachi, K. Kaneko, N. Kanehira, S. Ota, G. Miyamori, M. Hirata, S. Kajita, and F. Kanehiro, "Development of humanoid robot HRP-3P," *Proc. of 2005 5th IEEE-RAS International Conference on Humanoid Robots*, pp. 50-55, 2005.
- [3] Y. Xia, J. Wang, and L-M. Fok, "Grasping-force optimization for multifingered robotic hands using a recurrent neural network," *IEEE Transactions on Robotics and Automation*, 20(3), pp. 549-554, 2004.
- [4] A. C. Smith, F. Mobasser, and K. H-Zaad, "Neural-network-based contact force observers for haptic applications," *IEEE Transactions on Robotics*, 22(6), pp. 1163-1175, 2006.
- [5] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, *Learning Internal Representations by Error Propagation*, Parallel Distributed Processing, vol. 1, MIT press, pp. 318-362, 1986.
- [6] D. Psaltis, A. Sideris, and A. Yamamura, "A multilayer neural network controller," *IEEE Control System Magazine*, pp. 17-21, April 1988.
- [7] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Transaction on Neural Networks*, 1, pp. 4-27, 1990.
- [8] T. Ozaki, T. Suzuki, T. Furuhashi, S. Okuma, and Y. Uchikawa, "Trajectory control of robotic manipulators using neural networks," *IEEE Trans. On Industrial Electronics*, 38(3), pp. 195-202, 1991.
- [9] J. G. Kuschewski, S. Hui, and S. H. Zak, "Application of feedforward neural network to dynamical system identification and control," *IEEE Trans. on Control Systems Technology*, 1(1), pp. 37-49, 1993.
- [10] M. D. Lemmon and A. N. Michel, "Neural networks in control,

identification, and decision making," *IEEE Transaction on Automatic Control*, 44, pp. 1993-1994, 1999.

- [11] H. C. Hsin, C. C. Li, and R. J. Sclabassi, "An adaptive training algorithm for back-propagation neural networks," *IEEE Trans. on Systems, Man, and Cybernetics*, pp. 512-514, March 1995.

- [12] L. Jin, P. N. Nikiforuk, and M. M. Gupta, "Fast neural learning and control of discrete-time nonlinear systems," *IEEE Trans. on Systems, Man, and Cybernetics*, pp. 478-488, March 1995.

- [13] R. H. Nielsen, *Neurocomputing*, Ch. 6, Addison-Wesley, pp. 183-191, 1990.



김 병 호

1966년 2월 18일생. 1989년 금오공과대학교 전자공학과(공학사). 1994년 동 대학원(공학석사). 2001년 한양대 전자공학과(공학박사). 1995년~2001년 한국과학기술연구원 지능로봇연구센터 학생연구원. 2002년~2004년 Ritsumeikan대학(일본)

로봇공학과 JSPS Post-Doctoral Fellow. 2004년~2005년 RIKEN 생체모방연구센터(일본) 연구원. 2005년~현재 경성대학교 전기전자메카트로닉스공학부 메카트로닉스공학전공 조교수. 관심분야는 humanoid robots, biomimetic mechanism modeling and control, multi-fingered robot/artificial hands and multiple arm control, macro/micro mechanism and intelligent control, neural network applications.