

신경회로망을 이용한 시스템 식별

이영석 서보혁

*경북대학교 전기공학과

Identification of system Using Neural Network

Young - Seog Lee Bo - Hyeok Suh

Dept. of Electrical Eng. Kyung-Pook Nat. Univ.

ABSTRACT

In this paper, Neural-Network Identifier that has time-delay element, error limit and small weighting factor is proposed. A proposed identifier has good performance to identify non-linear system with noise. To test the effectiveness of the algorithm presented above, the simulation for output tracking of non-linear system is implemented.

1. 서 론

신경 회로망은 학습[1]하는 능력이 있으므로, 외부환경이나 시스템의 구조를 알지 못하더라도 시변하는 환경에 잘 적응할 수 있다.

또한, 병렬 분산 처리가 가능하여 임의의 입력 출력 데이터 맵핑을 수행하기 때문에 실시간 처리가 가능하다. 이러한 특성으로 인해 패턴인식, 화상처리, 음성인식[4] 등의 어려운 해석문제를 다룰 수 있다.

시스템의 고전적인 식별문제는 수학적인 모델링에 근거하였지만, 시스템이 비선형 요소를 많이 포함하고 있는 경우에는 수학적 모델링이 어렵고, 정확한 식별이 불가능하다.

신경 회로망은 이와 같은 수학적 모델링 없이도, 비선형 함수의 학습능력과 시변 파라메타에 대해 강연하기 때문에 비선형 시스템 같은 복잡한 시스템을 학습시켜 식별[1][2]에 이용할 수 있다.

그러나 신경 회로망은 학습도중 국부적 최소치(Loal minimum)[3]에 빠지기 쉽고, 학습시간[3][5]이 길다는 단점을 가진다.

따라서, 본 논문에서는 신경 회로망의 학습속도를 높이기 위해 세 가지 방법을 연구 조사한다. 먼저, 오차한계를 두고, 오차가 한계 안에 들어오면 학습을 하지 않고 다음 패턴을 학습한다. 두 번째 방법으로는 초기 가중치 크기에 의한 신경 회로망의 조기포화를 막기 위해 작은 난수를 발생 하며, 마지막으로, 시간지연 소자를 이용해서 시스템의 현재의 입력과 출력뿐만 아니라 과거의 데이터도 입력으로 이용하는 신경 회로망을 구성해서 이러한 신경 회로망이 비선형 시스템의 식별에 잘 적용함을 보이고자 한다.

2. Back-Propagation 학습 알고리듬

Back-Propagation 학습 알고리듬은 1986년에 Rumelhart에 의해

제안된 교사신호가 있는 학습방법으로서, 이 학습방법은 최급강하법의 형태를 가진다. BP 알고리듬은 구성하기가 용이하고, 학습률에 따른 수렴성이 우수하여 신경회로망의 학습알고리듬으로서 가장 널리 알려져 있다.

다중 퍼셉트론은 입력층 뉴런과 출력층 뉴런 사이에 하나 이상의 뉴런을 가지는 은닉층이 있는 Feed-Forward 연결 구조로 된 신경회로망으로 그림 1 과 같다.

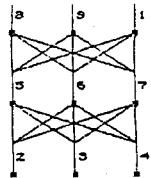


그림 1. 신경 회로망의 구조.

단층 퍼셉트론의 제한된 기능을 다층 구조 퍼셉트론으로 개선 할 수 있다는 사실과 최근 이러한 다층 구조 퍼셉트론을 보다 효과적으로 학습시킬 수 있는 새로운 학습 알고리듬의 개발로 이를 이용한 응용이 활발히 진행되고 있다. 일반적으로, 다층 퍼셉트론에서의 입력 분포는 매우 복잡하다.

이렇게 복잡한 분포를 갖고 있는 패턴들을 분류할 수 있는 일반적인 다층 퍼셉트론(multilayer perception)의 학습 알고리듬인 BP(back propagation) 알고리듬은 지도 학습으로 학습시켜야 할 모든 입력들 각각에 대해 원하는 출력과 실제 출력과의 차이인 오차가 최소화되도록 연결 강도값을 변화시키는 학습 알고리듬으로 기본 원리는 LMS(Least Mean Square)의 오차 목적 함수를 Gradient Descent 방법을 뉴런과 같은 비선형 신경회로망에 적용하는 것이다. 이를 위해서는 회로망의 어떤 한 연결강도값에 대해서도 오차함수의 도함수를 쉽게 구할 수 있어야 한다.

BP 알고리듬의 학습 단계는 각 입력 패턴에 대해 출력을 산출하는 전향(Feed-Forward) 단계와 원하는 출력과 실제 출력 사이에서 발생하는 오차를 역으로 진행시켜 이 오차를 최소화하는 쪽으로 충과 충사이의 연결 강도를 변화, 조절하는 후향(Feed-Backward) 단계로 나눌 수 있다.

2-1 전향 단계

그림 1 과 같은 2층 구조 퍼셉트론 신경회로망 모델에서 i 번째 입력층 뉴런의 값을 $I_{i,j}$ 번째 은닉층 뉴런의 값을 $H_{i,j}$, k 번째 출력층 뉴런의 값을 O_k 라 하고, W_{ij} 를 i 번째 입력층 뉴런과 j 번째 은닉층 뉴런 사이의 연결 강도, w_{kj} 를 j 번째 은닉층 뉴런과 k 번째 출력층 뉴런 사이의 연결강도라고 하면 입력층 뉴런으로부터 들어오는 j 번째 은닉층 뉴런의 총 입력 값은 식 (1)로 나타낼 수 있다.

$$H_j(in) = \sum_i I_i W_{ij} + \theta_j \quad (1)$$

위의 식 (1)에서 θ_j 는 j 번째 은닉층 뉴런의 출력 바이어스(Bias)이고, 은닉층 뉴런의 출력값은 다음 식 (2)과 같이 비선형적 활성 함수에 의해 임계(Thresholding)된다.

$$H_j(out) = f(H_j(in)) \quad (2)$$

즉, 식 (2)에서 $f(x)$ 는 비선형 활성 함수인 시그모이드 함수를 나타내는 것으로 다음식 (3)과 같은 관계를 갖는다.

$$f(x) = 1/(1+exp(-x)) \quad (3)$$

이와 유사하게 은닉층 뉴런으로부터 k 번째 출력층 뉴런에 입력되는 값은 식 (4)와 같이 주어지게 된다.

$$O_k(in) = \sum_j H_j(out) W_{kj} + \theta_k \quad (4)$$

식(4)에서 θ_k 는 k 번째 출력층 뉴런의 출력 바이어스이고 출력층 뉴런이 출력값은 식 (5)와 같다.

$$O_k(out) = f(O_k(in)) \quad (5)$$

또한, 식 (5)의 $f(x)$ 는 식 (3)과 같은 관계를 갖는 비선형 활성 함수로 시그모이드 함수를 나타낸다.

2-2 후향 단계

입력 패턴에 대한 출력층 뉴런 각각의 원하는 출력을 T_k 라 할 경우, 앞의 전향 단계에서 계산된 실제 출력과의 입력 패턴 전체에 대한 전체 자승 오차의 합 E 는 식 (6)와 같으며,

$$E = \frac{1}{2P} \sum_p \sum_k (T_k - O_k(out))^2 \quad (6)$$

식 (6)의 P 는 입력 패턴 수를 의미하며, 이러한 오차로부터 학습을 지속할 것인가를 결정하며, 이 오차를 최소값이 되도록 하기 위해 오차에 비례하는 값으로 입력층 뉴런과 은닉층 뉴런 사이의 연결 강도와 은닉층 뉴런과 출력층 뉴런 사이의 연결 강도를 역으로 수정해 가는 일반화된 Delta-Rule을 이용하면서 식 (7)과 식 (8)의 과정을 거쳐 계산된 W_{kj} 성분으로 연결 강도 W_{kj} 를 변화시켜 준다.

$$\delta_k = f'(O_k(in)) (T_k - O_k(out)) \quad (7)$$

$$W_{kj}(n+1) = \eta_1 \delta_k H_j(in) + \alpha_1 \Delta W_{kj}(n) \quad (8)$$

식 (7)의 δ_k 는 Delta-Rule에 의해 나타나는 성분으로 W_{kj} 를 변화시켜주는 오차량이며 $f'(O_k(in))$ 에 대한 미분을 나타내고, 식 (8)의 η_1 은 학습 속도이고, α_1 은 운동량(Momentum) 성분이며, n 은 반복(Iteration) 수를 나타낸다.

BP 알고리즘에서는 실제 출력과 원하는 출력 사이의 오차에 비례하여 역 방향으로 연결 강도를 변화시키므로, 이 과정 중에 은닉층 뉴런 각각에 대한 원하는 출력이 없으므로 오차 값은 식 (9)에서처럼 실제 출력과 원하는 출력 사이의 차와 전단의 연결 강도 W_{kj} 의 곱의 합으로 주어지므로 연결 강도 W_{kj} 의 수정 성분인 ΔW_{kj} 는 학습 속도 η_2 와 운동량 성분 α_2 를 갖는 식 (10)로 나타낼 수 있으며, 또한 식 (9)의 δ_j 는 식 (11)의 δ_k 와 같은 성분이며, $f'(H_j(in))$ 도 $H_j(in)$ 에 대한 미분을 의미한다.

$$\delta_j = f'(H_j(in)) \sum_k W_{kj} \delta_k \quad (9)$$

$$W_{ji}(n+1) = \eta_2 \delta_j I_i + \alpha_2 \Delta W_{ji}(n) \quad (10)$$

그러므로, 입력 I_i 에 대한 원하는 출력이 T_k 일 때 오차를 역으로 진행시키는 후향 단계에 의해 n 번째 반복 과정으로부터 수정된 연결 강도는 식 (11), (12)과 같이 주어져 식 (6)의 오차가 최소가 되도록 학습을 수행하게 된다.

$$W_{ji}(n+1) = W_{ji}(n) + \Delta W_{ji}(n+1) \quad (11)$$

$$W_{kj}(n+1) = W_{kj}(n) + \Delta W_{kj}(n+1) \quad (12)$$

3. 수정된 학습 알고리듬

이상과 같은 종래의 Back-Propagation 학습 알고리듬은 Local Minimum과 학습시간 지연이라는 단점을 가지고 있다. 따라서, 학습시간을 단축하기 위해 오차한계를 두어서 오차가 한계(error limit)보다 적으면 역방향 진행(back-propagation)을 하지 않게 한다. 이렇게 함으로써 허용할 수 있는 오차에 의해 신경회로망의 가중치(weighting factor)값들이 엉뚱한 값으로 변하지 않게 한다. 시스템의 특성을 더욱더 잘 파악하기 위해 시스템의 입.출력에 시간 지연소자(Time Delay element)를 연결해서 과거의 시스템의 입.출력값과 현재의 시스템 입력을 신경회로망의 입력으로 사용한다. 이렇게 하면 신경 회로망은 더 많은 뉴런에 의해 학습을 많이 하게 되지만 시스템의 특성을 더 잘 파악하므로 오차를 더욱더 빠르게 줄일 수 있고 속도를 향상 시킬 수 있다. 그리고 신경 회로망의 초기화과정에 있어서 가중치의 값이 크면 각종의 출력값이 커지면서 출력층의 시그모이드함수의 값이 포화되어버린다. 이를 막기 위해 가중치의 값을 작은값으로 해서 신경 회로망의 각종의 출력값이 조기포화 되지 않게 한다.

4. 시스템 식별기

본 연구에서 사용한 신경 회로망 식별기는 시스템의 현재의 입력과 단위시간 지연된 입력을 신경 회로망의 입력으로 하고 잡음이 첨가된 시스템의 출력과 신경회로망의 출력의 차를 가지고 학습을 행하게 된다. 이를 그림2에 나타내었다.

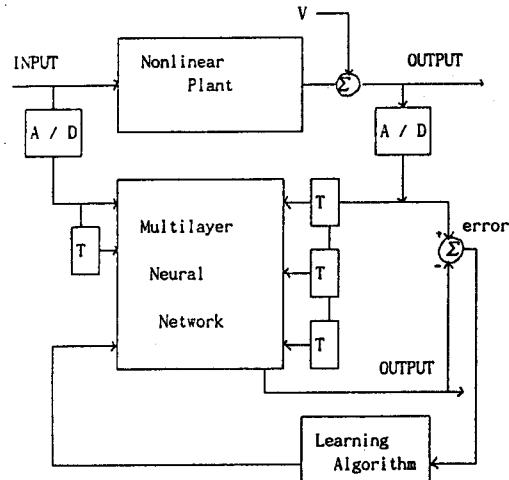


그림 2. 신경회로망 식별기의 구조

5. 시뮬레이션

본 연구에 사용한 시스템은 식(13)과 같다.

$$X_1 = 1.2X_2 + 0.1X_1$$

$$X_2 = 4U - 3.3X_2 - 0.7X_2^2 - 4.2X_1 - 1.2\sin(3X_1)$$

$$Y = X_1$$

$$U = 0.5\sin(3t) + 0.3\sin(5t) + 0.5\sin(3.3t) + 1.5\sin(5.5t) - 2.5\sin(7.5t) + \sin(2.3t) + 0.25\sin(t) \quad (13)$$

여기서 샘플링 시간 $T = 0.05$ 로 두었다.

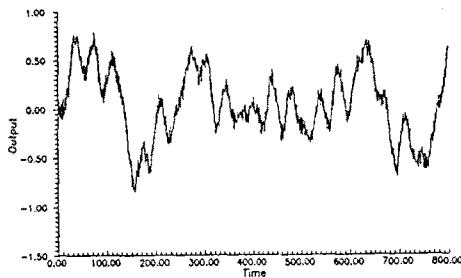


그림 3. 잡음이 첨가된 시스템의 출력

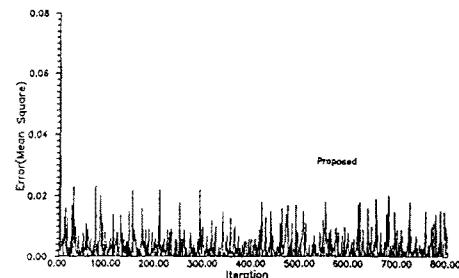


그림 6. 학습후의 오차

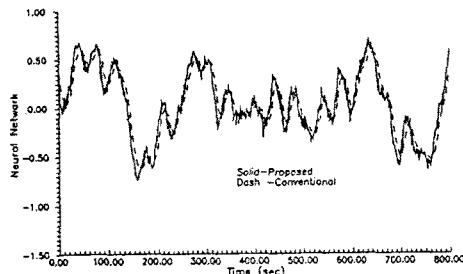


그림 4. 학습후의 신경 회로망의 출력

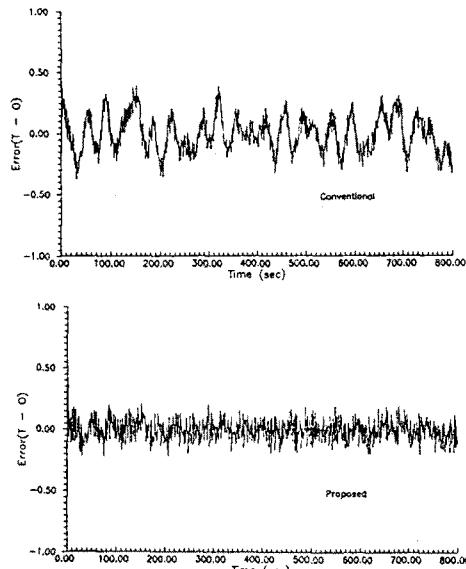
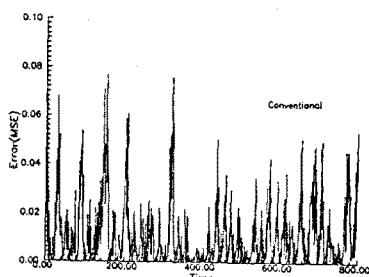


그림 5. 학습후의 출력 오차



6. 결과

본 논문에서는 신경 회로망의 학습 속도를 높이고 회로망의 조기포화를 막기위해 오차의 한계를 두었고 회로망의 가중치의 초기치를 작은값으로 설정 하였으며, 시스템의 특성을 잘 파악하기위해 시간지연회로망(TDNN)을 구성 하였다.

학습속도가 빨라지고 오차가 줄어듬으로서 이러한 신경 회로망의 구성이 미지의 시스템을 파악하는데 유용함을 보였다.

본 알고리듬의 특성을 컴퓨터 시뮬레이션을 통해 입증하였지만, 향후 병렬 프로세서에 의한 실현과 각 층들의 뉴런수 설정, 그리고 초기 학습 개수의 최적화등에 관한 연구가 따라야 할 것으로 사료된다.

7. 참고문헌

1. K. S. Narendra and K. Parthasarathy : "Identification and Control of Dynamical Systems Using Neural Networks," IEEE Trans. Neural NET. vol. NN-1 NO.1 pp.4-27 MAR. 1990.
2. J. G. Kuschewski, S. Hui and S. H. Zak : "Application of Feedforward Neural Network to Dynamical System Identification and Control," IEEE Trans. Contr. sys. tech vol 1. NO.1 pp.37-49 MAR. 1993.
3. B. Widrow and M. A. Lehr : "30 years of adaptive neural network:Perceptron, madaline, and backpropagation," proc IEEE, vol.78, pp.1415-1442, Sept.1990
4. J. M. Zurada : "Artificial Neural system," West.1992.
5. B. Muller and J. Reinhardt, "Neural Networks : Springer-verlog,1990.
6. S. I. Gallant, "Perceptron-based Learning Algorithms :" IEEE Trans vol. NN-1,pp.179-191,no. 2, June 1990.
7. M. Fukumi and S. Omatsu : "A New Back-Propagation Algorithm with Coupled Neuron," IEEE Trans. vol. NN-2 no. 5, pp. 535-538 Sep.1991.