

순방향 모델링과 간접학습에 의한 신경망제어기

* 이 부 환, 이 인 수, 전 기 준

경북대학교 공과대학 전자공학과

A Neural Network Controller Based on Forward Modeling and Indirect Learning

Boo Hwan Lee, In Su Lee, Gi Joon Jeon

Department of Electronics, Kyungpook National University

ABSTRACT

This paper describes a learning method of neural network controllers. The learning method improves the performance of indirect learning mechanism in the neuro-control of nonlinear systems. To precisely identify dynamic characteristics of the plant by utilizing a limited prior information we propose a new energy function which takes advantage of the proportional relationship between outputs of the plant and those of neural networks.

1. 서 론

제어시스템이 복잡하고 다양해짐에 따라 보다 향상되고 단 순화된 제어기법이 요구되고 있다. 고전적 제어이론은 플랜트 모델에 근거해서 수학적으로 제어 알고리즘을 설계하여 단계적 계산을 거쳐 제어하므로 제어대상에 대한 수학적 모델링이 필 요하다. 그러나, 실제로는 측정 불가능하거나 생략된 파라미 터들과 외란 혹은 잡음 등과 같은 불확정성으로 인해 플랜트를 정확하게 모델링 한다는 것은 매우 어렵다. 최근에 신경회로 망을 제어시스템에 적용함으로써 고전적 제어이론의 한계성 극 복에 커다란 가능성을 보이고 있다[1-3].

신경회로망을 이용한 제어의 경우에는 플랜트의 입출력 정 보를 이용한 비선형 대응을 통하여 플랜트나 주위환경의 변화 혹은 잡음 등에 대해서도 학습할 수 있는 능력을 가지며, 제어 법칙을 구하는데 있어서 복잡한 수학적 해석을 필요로 하지 않 는다. Wang등[4]은 플랜트의 입출력 관계를 이용해서 최적인 제어입력을 구하는 학습구조를 보였고, Semani등[5]은 역전 달 학습 알고리즘에서 사용하는 에너지함수 대신 확률값을 최 대로 하는 새로운 에너지 함수를 이용해서 학습성능을 개선시 키는 알고리즘을 제시하였다. Psaltis등[6]은 일반학습구조, 특정학습구조 및 간접학습구조의 3가지 방법을 제시했는데, 일 반학습구조는 플랜트의 제어입력을 광범위하게 바꿔가며 그에 상응하는 출력을 신경회로망의 입력으로 하여 학습시킨 후 이 신경회로망을 제어기로 사용되는 구조로서 실시간 학습을 할

수 없으며, 특정학습방법은 원하는 동작범위에서 훈련이 가능 하고 실시간 학습도 가능하지만 플랜트의 자코비안을 구하는 것이 문제가 된다. 그리고, 간접학습구조는 목표값을 바꿔가 며 플랜트를 구동하는 동안 신경회로망을 플랜트의 역전달함 수로서 학습시킨다. 이와같이 학습된 신경회로망과 동일한 구조의 신경회로망을 간접제어기로 사용할 경우 원하는 동작범 위에서 학습시킬 수 있는 대신 플랜트의 출력과 목표값의 차를 극소화하지 못하는 문제점으로 인해 정상상태에서 양호한 제어 성능을 얻을 수 없다.

본 연구에서는 간접학습구조에 플랜트의 순방향 특성을 모 사한 인식신경망을 플랜트와 병렬로 연결한 후, 제어값에 대 한 인식신경망의 출력과 목표값의 차를 극소화하는 최선의 제 어값을 인식신경망의 정보를 이용하여 반복적으로 찾아 제어기 를 학습시킴으로써 간접학습구조가 갖는 문제점을 해결하고자 한다. 또한, 플랜트로부터 얻을 수 있는 제한적인 선형정보 를 이용하여 플랜트의 동특성을 보다 정확하게 모사하기 위해 플랜트의 출력과 신경망 출력값과의 비례관계를 이용한 새로운 에너지함수를 제시한다. 그리고, 제한한 알고리즘을 환경의 변화가 심하고 비선형성이 존재하는 시스템에 적용하여 타당성 을 확인하고자 한다.

2. 신경회로망의 학습 알고리즘

신경회로망은 입력층과 출력층 그리고, 하나이상의 중간계 층을 가지며 신경회로망 출력층에서의 에너지 함수는 각 뉴런 의 출력과 목표값과의 차들의 합으로 다음과 같이 정의한다.

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

여기서 T_k 는 출력단 k 번째 뉴런의 목표값이며, O_k 는 출력단 k 번째 뉴런의 출력값이다. 신경회로망 학습방법은 신경회로망 출력과 목표값 사이의 오차를 최소화 하기 위하여 최경사사 법의 한 종류인 오차 역전달 학습 알고리즘[7]을 사용하여

가중치를 변화 시킨다. 출력단에서의 가중치 변화는 다음과 같다.

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj} + a \cdot (W_{kj}(t) - W_{kj}(t-1)) \quad (2)$$

$$\begin{aligned} \Delta W_{kj} &= -\eta \frac{\partial E}{\partial W_{kj}} \\ &= \eta \cdot \delta_k \cdot O_j \end{aligned} \quad (3)$$

$$\delta_k = (T_k - O_k) \cdot f'(net_k) \quad (4)$$

여기서 W_{kj} 는 출력층의 k 번째 뉴런과 중간층의 j 번째 뉴런사이의 가중치를 나타내고 δ_k 는 역방향으로 전달되는 오차이다. $f(\cdot)$ 는 시그모이드 형태의 지수함수이고 net_k 는 출력층의 k 번째 뉴런의 입력이다. O_j 는 중간층의 j 번째 뉴런의 출력, η 는 학습률, 그리고 a 는 학습속도 개선을 위해 가중치 변화가 같은 방향이면 학습량을 증가시키는 모멘텀이다. 중간층에서의 가중치 변화는 출력단과는 달리 다음과 같다.

$$V_{ji}(t+1) = V_{ji}(t) + \Delta V_{ji} + a \cdot (V_{ji}(t) - V_{ji}(t-1)) \quad (5)$$

$$\begin{aligned} \Delta V_{ji} &= -\eta \frac{\partial E}{\partial V_{ji}} \\ &= \eta \cdot \delta_j \cdot Z_i \end{aligned} \quad (6)$$

$$\delta_j = f'(net_j) \cdot \sum_k (\delta_k \cdot W_{kj}) \quad (7)$$

여기서 V_{ji} 는 중간층의 j 번째 뉴런과 입력층의 i 번째 뉴런사이의 가중치를 나타내며 Z_i 는 입력층의 i 번째 뉴런의 출력이다. 그리고, net_j 는 중간층의 j 번째 뉴런의 입력이다. 전체 알고리즘은 크게 각각의 뉴런이 자신의 출력을 구하는 순방향 계산과정과 출력층에서의 오차를 구한후 이를 역전달 시키면서 뉴런간의 가중치를 조절하는 역방향 계산과정으로 구분된다.

3. 시스템의 제어구조

3.1 간접학습구조

그림 1과 같이 목표값 $dk+1$ 을 바꿔가며 플랜트를 구동하는 동안 신경회로망을 플랜트의 역전달함수로 학습시킨다.




그림 1. 간접 학습 구조
Fig. 1. Indirect learning architecture

이와같이 학습되는 신경회로망과 동일한 구조의 신경회로망을 간접제어기로 사용하므로 원하는 동작범위에서 학습시킬 수 있으나 $e_1 = u_k - \hat{u}_k$ 을 극소화한다고 해서 플랜트의 출력과 목표값의 차를 극소화하지 못하기 때문에 정상상태에서 양호한 제어성능을 얻을 수 없어 실제 적용에 많은 제약이 있다.

3.2 순방향 모델링과 간접학습에 의한 제어기

제안하는 제어시스템은 간접학습구조를 기본으로 해서 플랜트의 특성을 순방향으로 모델링하기위한 인식신경망, 제어기로 동작하는 제어신경망 그리고, 제어신경망과 인식신경망사이에 제어값을 반복적으로 찾아 개선시키는 제어량 보정 부분으로 구성된다. 제어시스템의 구조도는 그림 2와 같다. 여기서 인식신경망은 제어기를 학습하기전에 사전정보로 부터 플랜트의 동특성을 포함하도록 오프라인으로 학습을 진행한다. 제어신경망 입력단의 스위치 SW1과 SW2는 항상 반대로 작동하면서 제어기의 입력요소를 선택한다.

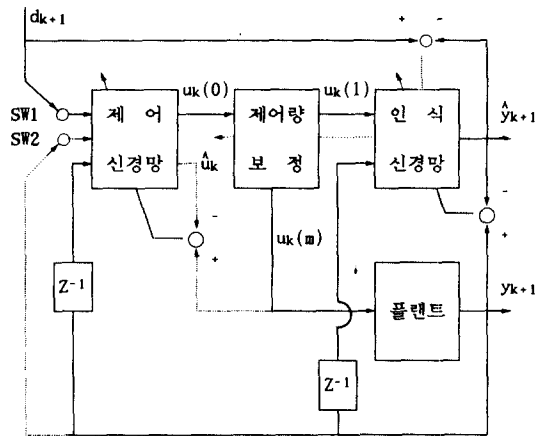


그림 2. 제어 시스템 구조도
Fig. 2. Architecture of the control system

SW1이 작동되어 목표값 $dk+1$ 과 플랜트의 한 단계 전 출력 y_k 의 제어신경망 입력에 대한 초기제어값 $u_k(0)$ 로 제어량 보정 부분에서 인식신경망의 정보를 이용하여 최선의 제어값 $u_k(m)$ 을 구해 플랜트와 인식신경망의 입력으로 사용하여 플랜트 출력 y_{k+1} 과 인식신경망 출력 \hat{y}_{k+1} 의 차로 인식신경망을 학습시키며, 이때 SW2가 작동되어 플랜트의 출력과 한 단계 전 출력이 제어신경망의 입력으로 들어와 발생한 제어값 \hat{u}_k 과 $u_k(m)$ 의 차로 제어신경망을 학습시키게 된다.

3.3 인식신경망의 오프라인 학습

제어신경망은 인식신경망의 정보를 이용하여 학습하므로 제어성능을 향상시키기 위해서는 인식신경망이 플랜트에 대해 얻

을 수 있는 제한적인 입력력 정보로써 플랜트의 동특성을 정확하게 포함하도록 학습이 되어야 한다. 학습을 위한 구조는 그림 3과 같다.




그림 3. 인식신경망의 오프라인 학습구조
Fig. 3. Off-line learning architecture of the identification neural network

그림 3에서 신경회로망은 시그모이드함수로 $f(x)=1/(1+e^{-x})$ 을 사용하며 인식신경망의 학습을 위해 플랜트 출력과 인식신경망 출력값과의 비례관계를 이용한 새로운 에너지함수를 제시한다.

인식신경망의 출력층에서 각 뉴런의 출력과 플랜트의 출력값에 대한 비례값들의 곱은 플랜트의 출력값이 영이 아니고, 신경망의 출력값보다 크거나 같을 경우는 다음과 같다.

$$P = \prod_k \left(\frac{\hat{y}_k}{y_k} \right) \quad , \quad y_k \neq 0 \text{ 이고 } y_k \geq \hat{y}_k \quad (8)$$

여기서 y_k 는 플랜트의 출력값으로서 출력단 k번째 뉴런의 목표값이 된다. \hat{y}_k 은 출력단 k번째 뉴런의 출력값이다. 플랜트의 출력값이 신경망의 출력값보다 작을 경우에는 다음과 같다.

$$P = \prod_k \left(\frac{1-\hat{y}_k}{1-y_k} \right) \quad , \quad y_k < \hat{y}_k \quad (9)$$

식(8) 과 식(9)를 각각 로그를 취하면 다음과 같다.

$$L = \log P$$

$$= \begin{cases} \sum_k \log \left(\frac{\hat{y}_k}{y_k} \right) & , \quad y_k \neq 0 \text{ 이고 } y_k \geq \hat{y}_k \end{cases} \quad (10)$$

$$= \begin{cases} \sum_k \log \left(\frac{1-\hat{y}_k}{1-y_k} \right) & , \quad y_k < \hat{y}_k \end{cases} \quad (11)$$

L은 항상 영보다 작거나 같으므로, 신경회로망 출력층에서의 에너지함수는 아래와 같이 구해진다.

$$E = -L$$

$$= \begin{cases} - \sum_k \log \left(\frac{\hat{y}_k}{y_k} \right) & , \quad y_k \neq 0 \text{ 이고 } y_k \geq \hat{y}_k \end{cases} \quad (12)$$

$$= \begin{cases} - \sum_k \log \left(\frac{1-\hat{y}_k}{1-y_k} \right) & , \quad y_k < \hat{y}_k \end{cases} \quad (13)$$

식(12)와 식(13)에 정의된 새로운 에너지함수를 이용하여 인식신경망의 가중치는 다음의 식들에 의해 보정된다. 출력층 k번째 뉴런과 중간층 j번째 뉴런사이의 가중치를 보정하기 위한 식은 다음과 같이 구해진다.

$$\begin{aligned} \Delta W_{kj} &= -\eta \cdot \frac{\partial E}{\partial W_{kj}} \\ &= -\eta \cdot \frac{\partial E}{\partial \hat{y}_k} \cdot \frac{\partial \hat{y}_k}{\partial net_k} \cdot \frac{\partial net_k}{\partial W_{kj}} \\ &= \begin{cases} \eta(1-\hat{y}_k)O_j & , \quad y_k \neq 0 \text{ 이고 } y_k \geq \hat{y}_k \end{cases} \quad (14) \\ &= \begin{cases} -\eta \hat{y}_k O_j & , \quad y_k < \hat{y}_k \end{cases} \quad (15) \end{aligned}$$

중간층 j번째 뉴런과 입력층 i번째 뉴런사이의 가중치를 보정하기 위한 식은 다음과 같다.

$$\begin{aligned} \Delta V_{ji} &= -\eta \cdot \frac{\partial E}{\partial V_{ji}} \\ &= -\eta \cdot \frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \cdot \frac{\partial net_j}{\partial V_{ji}} \\ &= \begin{cases} \eta f'(net_j) Z_i \sum_k (1-\hat{y}_k) W_{kj} & , \quad y_k \neq 0 \text{ 이고 } y_k \geq \hat{y}_k \end{cases} \quad (16) \\ &= \begin{cases} -\eta f'(net_j) Z_i \sum_k \hat{y}_k W_{kj} & , \quad y_k < \hat{y}_k \end{cases} \quad (17) \end{aligned}$$

3.4 제어량 계산

인식신경망의 출력값과 목표값의 차를 줄이는 방향으로 제어량 변화분을 제어값에 더함으로써 보다 개선된 제어값을 구한다. 이와 같은 과정을 반복해서 최선의 제어값을 구한다. 그림 4와 같이 하나의 중간층을 가지고 두 개의 입력단자와 하나의 출력단자로 구성된 인식신경망에 대한 제어량 계산과정은 다음과 같다.




그림 4. 인식신경망 모델 구조
Fig. 4. Structure of the identification neural network

인식신경망 출력층에서의 에너지 함수는

$$J_{k+1} = \frac{1}{2} (d_{k+1} - \hat{y}_{k+1})^2 \quad (18)$$

와 같이 정의된다. 식(18)을 최소로 하기위한 제어량 보정식은

$$u_{k(1+1)} = u_k(1) + \Delta u_k(1) \quad (19)$$

와 같다. 여기서 제어량 변화분을 구해보면 다음과 같다.

$$\begin{aligned} \Delta u_k(1) &= -\eta \cdot \frac{\partial J_{k+1}}{\partial u_k(1)} \\ &= -\eta \cdot \frac{\partial J_{k+1}}{\partial \hat{y}_{k+1}} \cdot \frac{\partial \hat{y}_{k+1}}{\partial net} \cdot \frac{\partial net}{\partial u_k(1)} \\ &= -\eta (d_{k+1} - \hat{y}_{k+1}) f'(net) \frac{\partial net}{\partial u_k(1)} \end{aligned} \quad (20)$$

여기서

$$net = \sum_j W_j O_j \quad (21)$$

$$\begin{aligned} \frac{\partial net}{\partial u_k(1)} &= \sum_j W_j \frac{\partial O_j}{\partial u_k(1)} \\ &= \sum_j W_j f'(net_j) V_{ji} \end{aligned} \quad (22)$$

W_j 는 출력층 뉴런과 중간층의 j 번째 뉴런사이의 가중치이다. V_{ji} 는 중간층의 j 번째 뉴런과 제어입력이 들어오는 입력층의 i 번째 뉴런사이의 가중치이고, net_j 와 O_j 는 중간층의 j 번째 뉴런의 입력과 출력이다.

4. 모의 실험

본 연구에서 제안한 방법의 타당성을 보이기위해 다음과 같은 구조의 비선형 플랜트를 가정한다.

$$y_{k+1} = \frac{y_k}{1 + y_k^2} + u^2_k \quad (23)$$

모의실험을 위해 사용된 신경회로망은 하나의 중간층을 가지며 두 개의 입력단자와 하나의 출력단자로 이루어진다. 먼저 플랜트의 순방향특성을 모사하기 위해 $(\sin(2\pi k/10) + \sin(2\pi k/25))/2$ 의 입력을 사용해서 식(23)과 같은 비선형 플랜트로 부터 얻은 입출력정보로써 인식신경망의 오프라인 학습을 하였고, 학습 테스트를 위해서 학습이 끝난 후 $\sin(2\pi k/50)$ 을 입력

으로 사용하였다. 이때 학습을 위한 에너지함수로 신경망 출력과 플랜트 출력과의 오차를 이용한 자승오차(squared error)와 본 연구에서 제안한 에너지함수로 각각의 성능을 비교해 보았는데 그 결과는 그림 5, 6에 나타나 있다. 그림 5는 자승오차를 이용했을 때이고 그림 6은 제안한 에너지함수로 학습한 결과이다. 그림 5, 6의 결과로 제안한 에너지함수를 사용했을때가 플랜트의 동특성을 보다 정확하게 학습할 수 있음을 확인할 수 있다. 인식신경망의 학습이 끝난 후 이 신경망 정보를 이용하여 제어기를 학습시키기 위해 제어신경망의 가중치는 $[-0.5, 0.5]$ 사이의 임의의 값으로 초기화하여 제안한 제어 알고리즘으로 식(23)의 비선형 플랜트를 제어해 간접학습구조가 가지는 문제점을 해결해 보고, 플랜트의 파라미터 변화 및 잡음에 대한 영향을 조사해 보았다. 그림 7은 간접학습구조로 목표치 0.7과 0.3을 따라가도록 제어한 결과로 목표치와 플랜트 출력과 오차가 많이 생김을 알 수 있다. 그림 8은 제안한 제어구조에서 0.7과 0.3을 목표치로 하는 경우의 출력응답인데 간접학습구조로 제어한 결과보다 향상된 제어성능을 보여 준다. 위의 결과로 부터 제안한 에너지함수로 인식신경망의 오프라인 학습을 했을때가 자승오차를 이용한것 보다 더 좋은 결과를 보여줌을 알 수 있다. 그림 9, 10은 97번째 순간 플랜트의 입력 및 출력 파라미터가 갑자기 변했을 경우이며 그림 11은 97번째에서 103번째 순간동안 플랜트에 0.23의 잡음이 인가 되었을때의 출력응답이다. 그 결과 파라미터의 변화와 잡음에도 신경회로망이 잘 적응함을 보여준다. 파라미터가 변한 후의 플랜트는 다음과 같다.

$$y_{k+1} = \frac{y_k}{1 + y_k^2} + 0.8 u^2_k \quad (24)$$

$$y_{k+1} = \frac{y_k}{1 + 0.7 y_k^2} + u^2_k \quad (25)$$

5. 결 론

본 연구에서는 간접학습구조를 사용한 제어방법의 문제점을 보였고 이러한 문제점을 해결하기 위한 제어기 학습구조를 제안하였다. 또한, 플랜트를 모사할때 플랜트의 동특성을 보다 정확하게 모사하기 위해 플랜트의 출력과 신경회로망의 출력값과의 비례관계를 이용한 새로운 에너지함수를 정의하였다. 실험을 통해 한정된 입출력 정보로써 비선형 플랜트를 모사할 때 제안한 에너지함수를 사용했을때가 플랜트 출력과 신경회로망 출력값과의 차에 대한 자승오차를 에너지함수로 사용한 경우보다 학습성능이 향상 되었음을 알 수 있었다. 그리고, 제안한 제어기 학습구조로 플랜트를 제어했을때 간접학습구조에 비해 제어성능이 개선되었고 플랜트의 비선형성, 파라미터 변화 및 잡음 등에도 좋은 특성을 보여줌을 확인할 수 있었다.

참고 문헌

- [1] K.S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical systems Using Neural Networks," *IEEE Trans. Neural Networks*, **1**, 4-27, 1990.
- [2] F.C. Chen, "Back-propagation Neural Networks for Nonlinear Self-Tuning Adaptive Control," *IEEE Contr. Syst. Mag.*, **10**, 44-48, Sep. 1990.
- [3] G.J. Wang and D.K. Miu, "Unsupervising Adaptation Neural Network Control," *Proc. IEEE Int. Conf. Neural Networks*, **3**, 421-428, 1990.
- [4] S.D. Wang and Hackerd M.S. Yeh, "Self-Adaptive Neural Architectures for Control Applications," *IEEE Int. Conf. Neural Networks*, **3**, 309-314, 1990.
- [5] S. Semnani and M.J.J. Holt, "Improving the Performance of Multilayer Perceptron through Empirical Maximum Likelihood (EML) Learning Rule," *NVA' 90 IAPR Work. Mach. Appl.*, 28-30, 1990.
- [6] D. Psaltis, A. Sideris, and A.A. Yamamura, "A Multilayered Neural Network Controller," *IEEE Contr. Syst. Mag.*, **8**, 17-21, Apr. 1988.
- [7] R. Hecht-Nielsen, "Theory of the Back-Propagation Neural Network," *IEEE Int. Conf. Neural Networks*, **1**, 593-605, 1989.

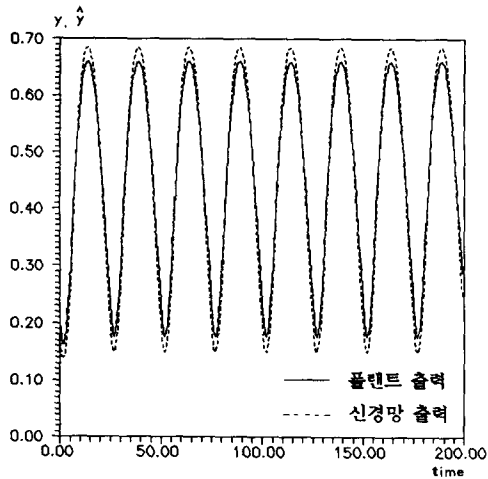


그림 5. 자승오차 에너지함수로 학습한 결과
Fig. 5. Learning result using the energy function of squared error




그림 6. 제한한 에너지함수로 학습한 결과
Fig. 6. Learning result using the proposed energy function





그림 7. 간접학습구조로 제어한 결과
Fig. 7. Control result using indirect learning architecture



- 목표값
- 인식신경망의 오프라인 학습을 제안한 에너지함수로 했을때 플랜트출력
- - - - - 지승오차 에너지함수로 했을때 플랜트출력

그림 8. 제안한 제어 알고리즘으로 제어한 결과
Fig. 8. Control result using the proposed control algorithm




그림 10. 플랜트의 출력 파라미터가 변했을때의 출력응답
Fig. 10. Output response when output parameter was changed




그림 9. 플랜트의 입력 파라미터가 변했을때의 출력응답
Fig. 9. Output response when input parameter was changed




그림 11. 잡음이 인가 되었을때의 출력응답
Fig. 11. Output response under a step noise