

신경 회로망을 이용한 무감독 학습제어

· 장 준 오 배 병 우 전 기 준
경북 대학교 공과대학 전자공학과

Unsupervised Learning Control using Neural Networks

Jun-Oh Jang Byeong-Woo Bae Gi-Joon Jeon
Dept. of Electronics Eng., Kyungpook National University

Abstract

This paper is to explore the potential use of the modeling capacity of neural networks for control applications. The tasks are carried out by two neural networks which act as a plant identifier and a system controller, respectively. Using information stored in the identification network control action has been developed. Without supervising control signals are generated by a gradient type iterative algorithm.

I 서론

수학적으로 모델링이 어려운 플랜트 혹은 플랜트의 동적특성의 변화가 심한 경우 고전적 제어 이론으로 풀기 힘드나 최근에 신경회로망의 도입은 문제 해결에 커다란 가능성을 보이고 있다. 신경회로망의 모델은 학습과 대규모 병렬 처리가 가능하고 정보의 분산 처리에 의한 에러 보정효과를 가지며 주어진 입력에 대해 원하는 출력을 연산 시키는 기능으로 인해 영상인식, 음성인식, 로보틱스 등의 분야에 널리 이용되고 있다. 특히, 비선형 대응을 통해 시스템 특성을 학습할 수 있는 능력으로 제어이론 응용에 큰 성과를 보이고 있다.

현대 제어 이론의 경향은 많은 문제에 일반적으로 접근할 수 있는 방법을 모색하고 있으며 그 예로 적용제어는 정확성에도 불구하고 계산상의 복잡성이 미지의 변수를 기하급수적으로 크게 증가시키는 기본적인 제한이 있다. 또한 모델의 불확실성, 시간지연, 비선형성 시변수 시스템 등은 제어 이론에 문제점으로 된다.

신경회로망 분야의 급속한 전개는 재래의 문제점을 해결할 가능성을 보이며 신경회로망을 이용한 제어기는 공정의 상태와 이에 대한 적절한 조작 변수상태를 학습에 의해 각 노드의 연결행렬값에 저장한 후 외부로부터 입력된 신호 형태에 따라 제어를 수행하고 플랜트의 모델을 몰라도 학습에 의해 스스로 성능향상이 되며 플랜트 특성변화에 잘 적응되며 오류(fault)에 강건하고 병렬처리를 함으로써 속도가 빠르다는 장점이 있다.

정보를 미리 알 수 없는 역진자(inverted pendulum), 로봇, 억 기구학 등에 신경회로망을 이용하여 제어하는 연구가 발표되고 있으나 신경회로망을 학습시킬 목표치가 필요하고 적용제어에서 변수추정을 하여 제어법칙을 세우는 반면 신경회로망에서는 학습시 연결행렬의 변화를 이용하여 제어법칙을 만들수 있다. 또한 신경회로망 사용시 학습속도가 모델에 따라 차이가 있기 때문에 학습속도 개선을 위한 연구가 활발히 진행되고 있다.

본연구에서는 오차역전달(error backpropagation) 학습알고리즘을 사용하여 학습속도 개선 및 시스템 식별을 하여 제어기를 구성하는데 있어 직전적인 목표치 없이 시스템 식별 시에 학습된 자료를 이용 제어량 및 제어보상량을 계산하여 미지의 비선형 시스템을 제어하는 방법을 제안한다.

II. 신경회로망

신경망구조는 그림 1과 같이 입력층과 출력층 그리고 하나 이상의 비선형 처리층으로 구성되어 다층 신경망을 구성하는 각 뉴런의 입력과 관계는 출력단 k번째 뉴런을 예로들면 다음과 같다.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

$$\text{net}_k = \sum_j (w_{kj} \cdot \text{OUT}_j) \quad (2)$$

$$\text{OUT}_k = f(\text{net}_k) \quad (3)$$

OUT_j 는 중간층에서 뉴런 j 의 출력이며, w_{kj} 는 출력층의 뉴런 k 와 중간층의 뉴런 j 사이의 가중치(weight)를 나타내고 $f(x)$ 는 활성함수이다.

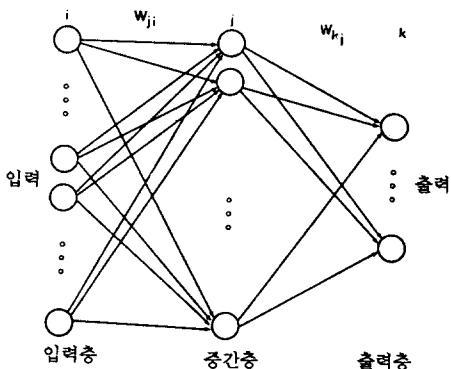


그림 1. 신경회로망 구조

Fig. 1. Structure of neural network.

다중 신경망 출력단에서의 전체성능은 각 뉴런의 출력과 목표치와의 차이들의 합으로 다음과 같이 정의한다.

$$E = \frac{1}{2} \sum_k (T_k - \text{OUT}_k)^2 \quad (4)$$

T_k 는 출력단 k 번째 뉴런의 목표값이며 OUT_k 는 출력단 k 번째 뉴런의 출력값이다.

전체성능을 개선하기 위한 신경회로망 학습 방법은 신경회로망 출력과 목표치 사이의 오차를 줄이는 최대경사법(steepest descent method)의 한 종류인 오차 역전달 알고리즘을 사용하여 가중치를 변화 시킨다.

출력단에서의 가중치 변화는 다음식과 같이 정의된다.

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj} + \alpha \cdot (w_{kj}(t) - w_{kj}(t-1)) \quad (5)$$

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (6)$$

$$= \eta \cdot (T_k - \text{OUT}_k) \cdot f'(\text{net}_k) \cdot \text{OUT}_j \quad (6)$$

$$= \eta \cdot \delta_k \cdot \text{OUT}_j \quad (6)$$

$$\delta_k = (T_k - \text{OUT}_k) \cdot f'(\text{net}_k) \quad (7)$$

여기에서 δ_k 는 역방향으로 전달되는 오차이고 $f'(\text{net}_k)$ 는 활성함수의 미분치이다. 그리고 η 는 학습률이고 α 는 학습속도 개선을 위해 가중치 변화가 같은 방향이면 학습량을 증가시키는 모멘텀(momentem)이다.

중간층 가중치 변화는 출력단과는 달리 다음식과 같이 정의된다.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha \cdot (w_{ji}(t) - w_{ji}(t-1)) \quad (8)$$

$$\Delta w_{ji} = \eta \cdot \delta_j \cdot \text{OUT}_i \quad (9)$$

$$\delta_j = f'(\text{net}_j) \cdot \sum_k (\delta_k \cdot w_{kj}) \quad (10)$$

III. 학습제어

시스템 제어에 쓰이는 신경회로망은 시스템 식별과 제어기 예 각각 쓰고 그림 2에 전체 구조를 보여준다.

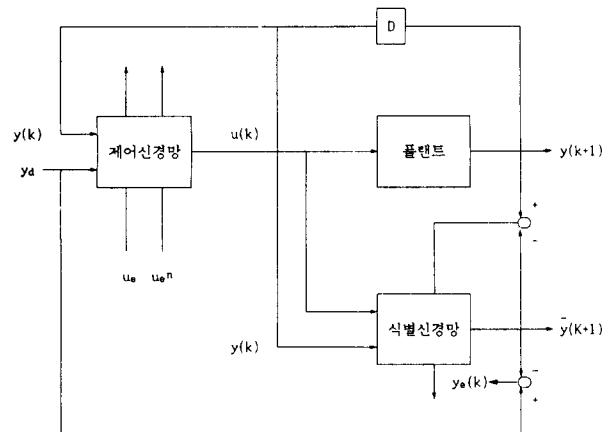


그림 2. 신경회로망을 이용한 시스템 제어구조도

Fig. 2. Architecture of unsupervising neural network and control

시스템 식별시 플랜트에 들어오는 입력은 제어신경망의 출력인 제어량 $u(k)$ 이고, 식별 신경망에 들어오는 입력은 플랜트의 한단계 전 출력 $y(k)$ 과 제어량이다. 플랜트의 출력 $y(k+1)$ 과 식별 신경망 출력을 비교하여 오차가 발생하면 오차가 역전달되어 식별신경망의 가중치를 변화시킨다. 식별된 자료를 이용하여 제어량을 구하는데 있어 그림 3과 같은 신경회로망 구조의 n 번째 입력 $u_n(k)$ 에 대하여 m 번째 출력 $y_m(k+1)$ 의 변화량은 다음과 같이 얻을 수 있다.

$$\frac{\partial \bar{y}_m(k+1)}{\partial u_n(k)} = \frac{\partial f(\text{net}_m)}{\partial \text{net}_m} \cdot \frac{\partial \text{net}_m}{\partial u_n}$$

$$= \frac{\partial f(\text{net}_m)}{\partial \text{net}_m} \cdot \sum_j w_{mj} \cdot \frac{\partial f(\text{net}_j)}{\partial \text{net}_j} \cdot w_{jn} \quad (11)$$

여기서 net_m 는 출력단 m 번째 뉴런의 입력이고, net_j 는 중간층 j 번째 뉴런 입력이다. w_{mj} 는 출력단 m 번째 뉴런과 중간층 j 번째 사이의 가중치이고 w_{jn} 은 중간층 j 번째 뉴런과 입력층 n 번째 사이의 가중치이다.

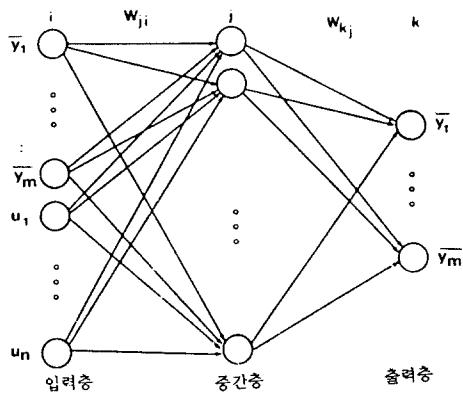


그림 3 식별 신경회로망 모델 구조

Fig. 3. Structure of identification neural network.

N 개의 입력 변화량에 대한 m 번째 출력 변화량을 나타내면 아래식과 같다.

$$G_m(y, u, W, k) = \sum_{n=1}^N \frac{\partial \bar{y}(k+1)}{\partial u_n(k)}$$

$$\stackrel{\Delta}{=} G_m(k) \quad (12)$$

전체 입력 변화량에 대한 출력변화량은 아래식과 같다.

$$G(y, u, W, k) = \begin{bmatrix} \frac{\partial \bar{y}_1}{\partial u_1} & \frac{\partial \bar{y}_1}{\partial u_1} & \dots & \frac{\partial \bar{y}_1}{\partial u_1} \\ \vdots & \vdots & & \vdots \\ \frac{\partial \bar{y}_1}{\partial u_n} & \frac{\partial \bar{y}_2}{\partial u_n} & \dots & \frac{\partial \bar{y}_m}{\partial u_n} \end{bmatrix}$$

$$\stackrel{\Delta}{=} G(k) \quad (13)$$

다음에서 정의하는 각 벡터를 이용하여 제어신경망을 학습시킬 제어량을 구하는 과정은 다음식과 같이 전개할수 있다.

$$y_e(k) = [y_{e1} \ y_{e2} \ \dots \ y_{em}]^T \quad (14)$$

$$u_e(k) = [u_{e1} \ u_{e2} \ \dots \ u_{en}]^T \quad (15)$$

$$y_d(k) = [y_{d1} \ y_{d2} \ \dots \ y_{dm}]^T \quad (16)$$

$$u(k) = [u_1 \ u_2 \ \dots \ u_n]^T \quad (17)$$

여기서 $y_e(k)$ 는 식별 신경회로망 출력과 목표치와의 오차이고 $u_e(k)$ 는 제어신경망을 학습시키기 위한 제어 오차량이다.

이들은:

$$y_e(k+1) \stackrel{\Delta}{=} y_d(k+1) - \bar{y}(k+1) \quad (18)$$

$$u_e(k) \stackrel{\Delta}{=} u_d(k) - u(k) \quad (19)$$

와 같이 정의되며 $y_d(k+1)$ 은 목표치이고 $\bar{y}(k+1)$ 은 식별 신경망 출력이다. 설정되지 않은 요구된 제어량 $u_d(k)$ 는 제어 오차를 최소화하여 얻을 수 있는 값으로써 $u_e(k)$ 와 제어신경망을 학습시켜 얻을 수 있다.

$u_e(k)$ 를 구하는 과정으로 제어 변화량에 대한 신경회로망의 출력 변화량은 다음과 같이 놓을 수 있다.

$$\Delta \bar{y}(k+1) \stackrel{\Delta}{=} G(k) \cdot \Delta u \quad (20)$$

여기서 제어 변화량과 비례 변화량 $G(k)$ 로써 식별 신경망 변화량을 정의할때 다음과 같이 제어 오차량과 비례 변화량으로써 식별신경망 오차를 구할 수 있다.

$$y_e(k+1) \stackrel{\Delta}{=} G(k) \cdot u_e(k+1) \quad (21)$$

$$u_e(k+1) = G^{-1}(k) \cdot y_e(k+1) \quad (22)$$

그러므로, 제어신경망을 변화시켜 원하는 제어량을 주는 제어 오차량 $u_e(k)$ 는 출력 신경망 오차와 비례 변화량의 역자로 꼽으로 된다. 제어 오차량을 이용하여 제어신경망을 학습시킴으로써 목표치를 추정하기 위한 제어량이 발생된다. 제어 오차량만 이용한 플랜트 제어는 학습시키는데 많은 시간이 소요되고 정확한 제어량을 구하지 못하는 문제가 있기 때문에 보상하는 제어 방법은 제어신경망에서 제어량을 구해 플랜트에 입력하기 전에 식별신경망과 오차로부터 제어보상

오차량 u_{e^n} 을 구함으로써 해결할 수 있다.

결국 제어 오차량 u_e 와 제어보상 오차량 u_{e^n} 의 합 ($u_e + u_{e^n}$)이 제어 신경망을 재학습시켜 제어 신경망으로부터 새로 운 제어량을 구할 수 있다. 위와 같은 과정을 제어보상 오차량이 무시할 수 있는 값(식별신경망 출력과 목표치와의 차가 적을 경우)이 될 때까지 반복한다. 다음 단계에서 $u_d(k)$ 는 제어량 $u(k+1)$ 로 되어 식별 신경망에 입력된다.

IV. 모의 실험

본 연구에는 식별 신경회로망과 제어 신경회로망에 각각 학습률 출력층 그리고 하나의 중간층을 사용하고 학습률은 식별 신경망과 제어 신경망에 각각 0.2, 0.3로 하고 모멘텀은 0.7로 동일하게 놓았다. 학습은 오차 역전달 알고리즘을 이용하였다.

각 신경망의 가중치는 임의의 값으로 초기화 하였고, 플랜트의 초기치는 $y[0] = 0.2$ 로 하였다.

$$y[k+1] = 0.7 \sin(2 \cdot u[k]) + y[k] \quad (21)$$

식 (21)과 같은 비선형 플랜트를 제어 오차량을 이용하여 시스템을 제어한 경우와 제어보상 오차량을 이용하여 실험한 결과들은 그림 4-6과 같다.

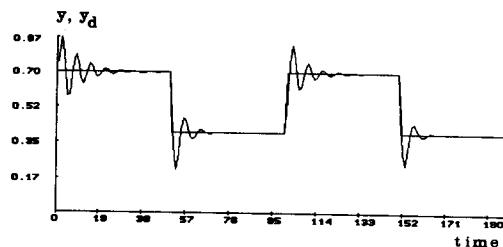


그림 4. 제어 오차량을 이용한 플랜트 제어

Fig. 4. Control method using control action error.

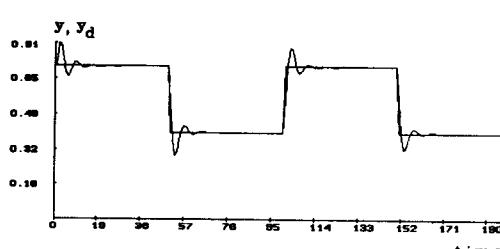


그림 5. 제어보상 오차량을 이용한 플랜트 제어

Fig. 5. Control method using compensated control

action error.

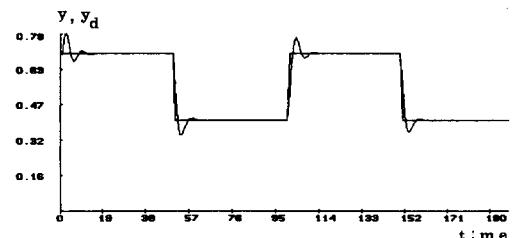


그림 6. 2회의 제어보상 오차량을 이용한 플랜트 제어

Fig. 6. Control method using compensated control

action error twice.

그림 4는 제어 오차량을 이용하여 플랜트를 제어한 경우로서 학습하는데 많은 시간이 걸릴뿐만 아니라 목표치와의 오차가 생김을 알 수 있다.

제어보상 오차량을 이용하여 플랜트 제어한 경우는 그림 5와 6에서 보여준다. 제어 오차량만 이용한 것 보다 같은 학습 시간에 비해 더 좋은 결과를 보여준다. 이는 시스템 식별 시자료를 더 많이 이용하기 때문이다.

제어보상 오차량을 2회 반복한 경우는 그림 6에서 실험 결과를 보여준다.

V. 결론

본 연구에서는 비선형 대응을 통해서 학습할 수 있는 신경회로망을 이용하여 시스템 제어를 행하는 방법을 제안한다. 제안한 신경회로망은 오차역전달 학습 알고리즘을 이용하여 학습하고 시스템 모델링에 이용된다. 오차역전달 학습 알고리즘은 감독학습(supervising learning) 제어방법으로 제어기의 신경회로망 학습을 위해서 요구된 출력값을 필요로 한다. 본 연구에서 제안한 제어 알고리즘은 식별 신경망에서 학습된 가중치를 이용하여 요구된 제어량을 구하는 무감독학습(unsupervised learning) 제어 방법이다.

또한, 요구된 제어량의 정확성과 학습속도 개선을 위해 제어보상량을 구하는 방법을 제안함으로써 전 제어 공정을 학습에 의해 스스로 성능을 향상시킨다. 플랜트의 구조를 모르며 비선형적으로 동작하는 시스템에 제안된 학습 알고리즘

을 적용하여 고전적 제어이론으로 풀기 힘든 문제를 해결할 수 있는 가능성을 시뮬레이션을 통하여 알 수 있었다.

VI. 참고 문헌

- [1] D. Psaltis, A. Sideris, and A. A. Yamamura, "A Multilayered Neural Network Controller," *IEEE Contr. Syst. Mag.*, Apr. 1988.
- [2] W. Li and J. J. E. Slotine, "Neural Network Control of Unknown Nonlinear Systems," *Proc. Amer. Contr. conf.*, pp. 1136-1141, 1989.
- [3] R. Hecht-Nielsen, "Theory of the Back-Propagation Neural Network," *Proc. IEEE, Intl. Conf. Neural Networks*, pp. I-593-605, 1989.
- [4] G. J. Wang and D. K. Miu, "UnsuperVising Adaption Neural Network Control," *Proc. IEEE Intl. Conf Neural Networks*, PP. 111-421-428, 1990.
- [5] S. Y. Kung and J. N. Hwang, "An Algebraic Projection Analysis for Optimal Hidden Units Size and Learning Rates in Back-Propagation Learning," *IEEE 1988 Intl. Conf. Neural Networks*, pp. I-363-370, 1988.
- [6] A. Guez, J. L. Eilbert and M. Kam, "Neural Network Architecture for Control," *IEEE Contr. Syst. Mag.*, pp. 22-25, Apr. 1988.
- [7] P. Werbs, "Backpropagation: Past and Future," *IEEE intl. conf. Neural Networks*, pp. I-343-353, 1988.
- [8] C. W. Anderson, "Learning to Control an Inverted Pendulum Using Neural Networks," *IEEE Contr. Syst. Mag.*, pp. 31-36, Apr. 1989.