

# 시스템의 시변성을 보상하기 위한 신경회로망을 이용한 적응제어

\* 이영태    장준오    천기준

경북대학교 공과대학 전자공학과

## Adaptive Neural Control for Compensation of Time Varying Characteristics

Young Tae Lee    Jun Oh Jang    Gi Joon Jeon

Dept. of Electronics Eng., Kyungpook National University

### ABSTRACT

We investigate a neural network as a dynamic system controller when system characteristics are abruptly changing. The shape of sigmoid functions are determined by autotuning method for the optimum sigmoid function of the neural networks. By using information stored in the identifying network a novel algorithm that can adapt the control action of the controller has been developed. Robustness can be seen from its ability to adjust large variations of parameters. The potential of the proposed method is demonstrated by simulations.

회로망에 관한 연구는 주로 패턴인식, 음성인식, 화상처리등의 분야에 집중되어 왔으며 최근에 비선형 플랜트의 제어에 많이 응용되고 있다. 신경회로망을 이용한 플랜트의 제어기법은 시스템의 전달함수를 가중치에 학습시켜 플랜트의 동특성을 학습한 후 그 정보를 이용하여 제어기를 구성하는 것인데 병렬처리로 인하여 파라미터의 증가에 따른 복잡성을 해결하는 동시에 실시간 처리 및 시스템변화에 강한 적응성을 가진다[1]. 이와 같은 장점을 이용하여 Chen[2]은 비선형 시스템의 제어문제를 해결하는데 있어서 자기동조 제어기법을 이용하여 좋은 결과를 얻었다. 이는 현대 제어기법에 비해 시스템의 파라미터를 추정하는데 복잡한 수식이 필요없으며 비선형성이 강한 플랜트에 대해서도 좋은 제어성능을 가지지만 플랜트의 구조를 알고 있어야 하는 단점을 가진다. Kawato[3]는 로보트(robot) 동특성을 안정화 하기위하여 비례 미분 역궤환 제어기와 병렬로 신경회로망을 사용하여 신경회로망이 학습이 되었을 경우 제어의 주체가 학습된 신경회로망이 되는 방법을 제안했으나 특정 로보트 동특성을 위한 제어방법이다. 또한 Nguyen 과 Widrow[4], Narendra 와 Parthasarathy[5]는 두 개의 신경회로망을 사용하여 한 개의 신경회로망은 에블레이터로 사용하고 다른 하나는 제어신경망으로 사용하는 간접학습구조를 제안하였다. 이와같은 제어기법은 먼저 에블레이터를 플랜트의 동특성을 포함 하도록 학습시킨후 제어 성능지수를 만족하도록 제어 신경망을 학습시킨다. 그러나 오차를 감소 시키기위해 최대경사법을 이용한 역전달 학습 알고리즘을 사용함으로써 해석적으로 국부최소점에 수렴할 수 있다[6]. 이는 온라인 수행시 초기 가중치의 잘못된 선택으로 조기 포화 현상이 발생하여 학습이 정체를 되거나 학습시간이 매우 오래 걸린다[7]. 이러한 문제를 해결하기위하여 학습률, 모멘텀, 중간계층의 노드수, 그리고 활성화함수의 기울기 등의 최적 결정 방법에 대한 연구가 계속되고 있으나 아직 일반성이 있는 방법은 없다. 또한 시스템의 불확실성, 외란등으로 인해 시스템의 특성이 갑자기

### I. 서론

수학적인 시스템이론을 바탕으로 하는 시스템의 식별 및 제어는 지난 수 십년 동안 선형 플랜트에 대해서는 만족할만한 성과를 이룩하였으나 비선형 플랜트에 대해서는 그 안정도를 보장하지 못하였다. 제어시스템 구성의 기본은 제어 대상인 시스템의 특성을 수학적으로 모델링하고 이를 이용하여 제어기를 구성하는 것인데 실제 플랜트는 본질적으로 대부분 비선형 특성을 가지며 시스템의 파라미터가 지속적으로 변화하므로 고전적인 시스템이론을 이용한 수학적인 모델링은 매우 어렵다. 또한 시스템의 규모가 증가함에 따라 파라미터의 수가 기하학적으로 증가함으로써 시스템이 복잡해지는 문제를 가지며 잡음 및 시스템의 시변성등으로 불확정성의 특성을 가짐으로 고전적인 제어이론으로는 만족할만한 성과를 얻을 수 없었다. 이러한 한계를 극복 하기위하여 기존의 접근 방법과 다른 새로운 지능 제어기법을 모색하게 되었으며 전문가시스템, 퍼지제어 및 신경회로망을 이용한 제어 등이 그 예라 할 수 있다. 신경

변한다면 식별신경망을 다시 학습시켜야 하므로 제어신경망은 시스템의 변화에 즉시 적용하기 힘들다.

본 연구에서는 역전달 학습 알고리즘의 조기 포화현상을 해결하기 위해 중간층 노드에서는 각각 다른 기울기의 활성화 함수를 사용하며 출력층 노드에서는 기울기를 자동으로 보정하는 알고리즘을 제시한다. 또한 플랜트의 시변성으로 인한 식별오차를 보상하여 플랜트의 효율적인 제어 및 제어성능의 개선을 가능하도록 하였다. 제안한 제어시스템은 식별신경망의 입출력 정보를 이용하여 목표치와 식별신경망의 출력과의 차이를 역전달하여 제어 성능지수를 만족 하도록 제어신경망을 학습시킨다. 그리고 이러한 제어신경망의 출력과 플랜트의 시변성으로 인한 식별오차에 적응하는 제어보정량을 더하여 플랜트를 제어한다. 이로 인하여 제어시스템은 시스템의 변화에 강건하고 신속한 적응을 가능하도록 한다.

## II. 식별신경망의 구조 및 학습방법

플랜트의 동특성을 학습하는 식별신경망의 구조는 다음과 같다.




그림 1. 다층 신경 회로망의 블록 선도

Fig. 1. A block diagram of neural network

식별신경망은 중간층을 한개 가지는 다층 신경 회로망으로 퍼셉트론에 비해 패턴 인식에 더욱 효과적이며 각 층의 가중치들의 상호작용으로 강한 비선형 함수에도 매핑능력을 가지고 있다[8]. 그림1에서  $X_i(k)$ 는  $i$ 번째 뉴우런의  $k$ 번째 입력 벡터,  $W1$  과  $W2$ 는 중간층 및 출력층에서의 가중치 행렬,  $F1$  과  $F2$ 는 기울기가 서로 다른 활성화함수를 나타낸다. 그리고  $out_k$ 는 출력층에서  $net_k$  에 비선형 매핑함수인 활성화함수를 통과시킨 값이며,  $net_k$ 는 중간층의 각 뉴우런 입력벡터와 출력층의 가중치 행렬과의 상호 작용으로 다음과 같이 표현된다.

$$OUT_k = f(net_k) \quad (1)$$

$$net_k = \sum_j (W_{jk} \cdot OUT_j) \quad (2)$$

$$f(x) = \frac{1 - e^{-mx}}{1 + e^{-mx}} \quad (3)$$

식(3)의 활성화함수의 출력은 -1과 1사이의 값을 가지며  $m$ 은 기울기 변화분으로 0보다 크고 8보다 작은 값을 가진다. 활성화함수의 기울기가 신경망의 학습에 미치는 영향은 다음절에서 자세히 설명한다. 그리고 플랜트의 사전 정보가 없는 경우에 식별신경망의 입력 벡터를 결정하는데 최적의 방법은 없으나 비선형 이산시간 플랜트는 일반적으로 다음과 같이 표현 되어 지므로 본 연구에서는  $u(k)$ 와  $y(k)$ 를 사용한다.

$$y_p(k+1) = G [y_p(k), y_p(k-1), \dots, y_p(k-n), u(k), u(k-1), \dots, u(k-m)] \quad (4)$$

식별신경망의  $k$ 번째 입력은 제어기의 출력인  $u(k)$ 와 플랜트의  $k$ 번째 출력 인  $y_p(k)$ 를 사용하며 이때 식별신경망의 출력은  $y_n(k+1)$ 이다. 가중치를 보정 하기위한 식별신경망의 성능지수는 플랜트와 식별신경망의 출력 오차를 최소로 하는것으로 다음과 같이 정의 한다.

$$E_1 = \frac{1}{2} (y_p - y_n)^2 \quad (5)$$

여기서  $y_p$  와  $y_n$ 는 각각 플랜트 및 식별신경망의 출력 이다. 식별신경망의 전체 성능을 개선하기 위한 학습방법은 식(5)의 성능지수를 만족하도록 최대경사법의 한 종류인 오차 역전달 학습 알고리즘을 사용하여 가중치를 변화시킨다. 식별신경망의 출력층에서 가중치 변화는 다음과 같다.

$$W_{jk}(t+1) = W_{jk}(t) + \Delta W_{jk} + \alpha \cdot (W_{jk}(t) - W_{jk}(t-1)) \quad (6)$$

$$\Delta W_{jk} = -\eta \frac{\partial E_1}{\partial W_{jk}} \quad (7a)$$

여기서  $\eta$ 는 학습속도를 개선하기 위한 학습률이며  $\alpha$ 는 모멘텀이다. 식(7a)를 전개하면 출력층에서의 가중치 변화는 다음과 같다.

$$\Delta W_{jk} = \eta \cdot \delta_k \cdot OUT_j \quad (7b)$$

여기서  $\delta_k$ 는 출력층에서 가중치를 보정하기 위한 역전달 오차 이다.

$$\delta_k = \eta \cdot (y_p - y_n) \cdot f'(net_k) \cdot OUT_j \quad (8)$$

여기서  $f'(net_k)$ 는 활성화 함수의 미분치이다. 같은 방법으로 중간층의 가중치 변화는 다음과 같다.

$$\begin{aligned} \Delta W_{ij} &= \eta \cdot f'(net_j) \cdot \sum_k (\delta_k \cdot W_{jk}) \cdot OUT_i \\ &= \eta \cdot \delta_j \cdot OUT_i \end{aligned} \quad (9)$$

여기서  $\delta_j$ 는 중간층에서 가중치를 보정하기 위한 역전달 오차이다.

$$\delta_j = f'(net_j) \cdot \sum_k (\delta_k \cdot W_{jk}) \quad (10)$$

식별신경망은 플랜트와 출력을 비교하여 오차 역전달 방법으로 가중치를 변화 시켜서 플랜트의 동특성을 학습하게 된다.

### III. 활성화함수 기울기의 자동 조정

다층 신경회로망을 학습시키는데 일반적으로 사용되고 있는 오차 역전달 알고리즘들은 몇가지 단점을 가지고 있다. 이 알고리즘의 수렴은 초기 가중치에 매우 민감하다는 것이다[7]. 이것은 오차를 감소시키기위해 최대경사법을 사용함으로써 해석적으로 국부최소점에 수렴할 수 있기 때문이다. 따라서 목표치에 수렴하는 속도가 어느정도의 오차까지는 빠른 속도로 감소하지만 그 이후에는 수렴 속도가 현저히 떨어지거나 정체하는 현상이 나타난다. 이와같은 문제는 활성화함수의 기울기가 미리 고정되어 비포화 범위가 변하지 않기 때문이다. 그림 2는 가장 많이 사용되고 있는 활성화함수이다.




그림 2. 활성화함수

Fig. 2. Activation function

앞절에서 설명했듯이 출력층에서 가중치를 보정하기 위해 역전달되는 오차는 식(8)과 같이 목표치와 신경망 출력의 차 그리고 활성화함수의 미분치의 곱이다. 여기에서 신경망의 출력이 목표치와 오차가 크더라도 활성화함수가 포화영역에 있으면 활

성화함수의 기울기가 매우 작으므로 역전달 되는 오차는 매우 작다. 따라서 가중치의 보정은 거의 일어나지 않는다. 이러한 문제를 해결 하기위해서 비포화영역을 능동적으로 변화시켜 기울기를 보정하는 것이다. 활성화함수의 기울기는 함수값이 -0.9 에서 0.9 까지는 일정하지만 그밖의 영역은 매우 작다. 따라서 플랜트의 특성마다 모두 다른 활성화함수의 정의구역에서 최대값이 0.9 의 함수값을 가지도록 기울기를 보정하면 활성화함수의 활동영역을 증대시키거나 감소시켜 학습속도를 개선 할 수 있다. 활성화 함수값이 0.9 일때의 함수의 기울기  $m$  은 식(3)에서 다음과 같이 구해진다.

$$m = -\frac{1}{2} \ln(1/19) \quad (11)$$

여기서  $\ln$  은 자연로그를 의미한다. 이와같이 활성화함수의 기울기를 성능지수를 만족하는 오차율  $\epsilon$  보다 작을때까지 능동적으로 보정하여 가중치의 조기 포화현상을 막을 수 있다.

### IV. 제어시스템의 구조 및 학습 방법

제어시스템의 구조는 그림 3과 같이 학습된 식별신경망의 정보를 이용하여 샘플링 단계마다 온라인으로 수행된다.

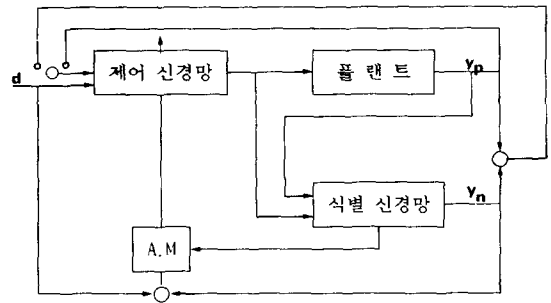


그림 3. 제어시스템의 구조

Fig. 3. Architecture of control system.

그림 3에서  $(k+1)$ 번째 단계에서 플랜트를 제어하는 제어량은 다음과 같다. 제어신경망의 입력  $d(k+1)$  와  $y_p(k)$  에 의해 제어신경망의 출력인  $u'(k+1)$ 가 나온다. 이  $u'(k+1)$ 는 플랜트와 식별신경망의 입력으로 들어가서 플랜트의 출력인  $y_p(k+1)$  와 식별신경망의 출력인  $y_n(k+1)$ 를 발생한다. 플랜트를 묘사하는 식별신경망에서는 성능지수 식(5)를 만족하도록 식별신경망의 가중치를 보정한다. 이러한 식별신경망의 가중치를 이용하여 A.M(Adaptive Mechanism)에 의해 제어신경망을 학습한다. 제어신경망을 학습하는데 있어서 성능지수는 다음과 같이 정의된다.

$$E_2 = \frac{1}{2} (d - y_n)^2 \quad (12)$$

제어신경망의 출력층에서 가중치 보정은 다음과 같다.

$$\begin{aligned} \Delta v_{mn} &= -\eta \frac{\partial E_2}{\partial v_{mn}} \\ &= \eta \cdot \delta_n \cdot \text{OUT}_m \end{aligned} \quad (13)$$

여기서  $\delta_n$ 은 제어신경망의 출력층에서 가중치 보정을 위하여 역전달되는 오차이다.

$$\delta_n = \sum_j W_{ij} \cdot f'(net_n) \quad (14)$$

같은 방법으로 제어신경망의 중간층에서 가중치를 보정하기 위하여 역전달되는 오차 및 가중치 변화는 다음과 같다.

$$\delta_m = \sum_n \delta_n \cdot W_{mn} \cdot f'(net_m) \quad (15)$$

$$\begin{aligned} \Delta v_{lm} &= -\eta \frac{\partial E_2}{\partial v_{lm}} \\ &= \eta \cdot \delta_m \cdot \text{OUT}_l \end{aligned} \quad (16)$$

이와같이 학습된 제어신경망은 목표치와 플랜트 출력과의 차를 최소화 하는 제어입력을 발생시킨다. 그러나 시스템의 불확실성, 시변특성 및 외란에 의해 시스템의 특성이 갑자기 변한다면 식별신경망은 이들의 특성을 다시 학습 하여야 하므로 제어신경망은 플랜트의 변화에 빨리 적응하지 못한다. 이로 인하여 제어신경망은 제어오차를 발생 시킨다. 이러한 제어오차는 (k+1)번째 단계에서 식별신경망이 플랜트의 동특성을 학습하기 위해 가중치를 보정했음에도 불구하고 식별오차가 존재하기 때문에 발생하였다. 이때 발생한 식별오차는 (k+1)번째 단계에서 제어신경망의 출력  $u'(k+1)$ 에 의해 발생한 플랜트와 식별신경망의 출력오차를 식별신경망의 가중치에 학습시키지 못한 오차이다. 이러한 오차는 (k+2)단계에서 제어오차량을 발생시킨다. 따라서 (k+2)단계에서 제어신경망의 출력에 식별오차를 제어보정량으로 환산한 제어량을 더해 주어야 한다. 제어보정량은 다음과 같이 얻을 수 있다. 제어신경망의 가중치가 (k+1)단계에서 목표치  $d(k+1)$ 과 플랜트의 출력  $y(k)$ 에 의해 목표치와의 오차를 줄이도록 학습되어있기 때문에 플랜트의 출력 대신에 식별오차를 입력으로 사용하면 제어보정량을 얻을 수 있다. 이렇게 얻은 제어보정량  $u''(k+1)$ 과 제어신경망의 출력  $u'(k+1)$ 를 더하여 플랜트를 제어하는 입력으로 사용한다.

## V. 컴퓨터 시뮬레이션 및 고찰

앞에서 제안한 활성화함수의 기울기 변화에 따른 학습속도를 비교하기 위하여 모델 1과 같은 플랜트를 사용하였다. 신경망을 학습시키기 위하여 사용된 패턴수는 100개의 쌍으로 하였고 입력은  $\sin(2\pi k/25) + \sin(2\pi k/30)$ 을 사용하였다.

$$\text{모델 1 : } y(k+1) = \frac{y(k)}{1 + y^2(k)} + u^3(k)$$

$$\text{모델 2 : } y(k+1) = C1 \cdot \sin(2 \cdot y(k)) + C2 \cdot u(k)$$

학습을 수행하는 중에는 학습률은 0.2, 모멘텀은 0.1로 고정하였으며 중간층이 하나인 다층 신경회로망을 사용하였다. 입력 뉴런은 두 개로  $u(k)$ 와  $y(k)$ 를 사용하였고 중간층의 뉴런은 10개이며 출력층은 하나의 뉴런으로 구성하였다. 그림 4는 활성화함수의 기울기를 고정한 경우와 제안한 경우와 비교한 것이며 그림 5는 반복횟수에 따른 기울기의 변화를 나타내고 있다. 시뮬레이션 결과에서 보듯이 제안한 경우가 학습속도가 빠르며 조기 포화현상이 발생하지 않았다. 그리고 4장에서 제안한 연구의 타당성을 실험하기 위해 C1이 0.6이고 C2가 0.4인 플랜트를 사용하였다. 각 신경망의 초기치는 랜덤값으로 -0.01 과 +0.01 사이의 값으로 초기화하였으며 플랜트의 초기치는  $y_p(0) = 0$ 으로 하였다. 각 신경망에 사용된 뉴런의 갯수와 학습률, 모멘텀은 표 1과 같다.

표 1. 신경회로망에 사용된 변수값

Table 1. Network parameters

	제어 신경망	식별 신경망
입력층 뉴런	2	2
중간층 뉴런	15	15
출력층 뉴런	1	1
학 습 률	0.2	0.15
모 멘 텨	0.1	0.1

그림 6 - 9에서 (a)는 제어보정량을 사용하지 않은 결과이며 (b)는 사용한 결과이다. 또한 C1 및 C2 파라미터의 변화는 60 번째 단계에서 변화한 경우이다. 그림 6은 시불변 시스템을 제어한 결과이며 제어보정량을 사용한 경우가 진동이 없는 좋은 성능을 나타내고 있다. 그림 7은 C1이 0.4로 20% 변화하였을 때 결과이며 그림 8은 C2가 0.2로 20% 변화하였을 때의 결과이다. 그리고 그림 9는 C1 및 C2가 각각 0.5, 0.3로 10%씩 변화한 경우이다. 시뮬레이션 결과에서 보듯이 제어보정량을 사용한 경우가 시스템의 변화에 보다 빨리 적응함을 알 수 있다.





그림 4. 학습 오차  
Fig. 4. Learning error



(b). 제어보정량을 사용한 경우  
(b). Control using control action error

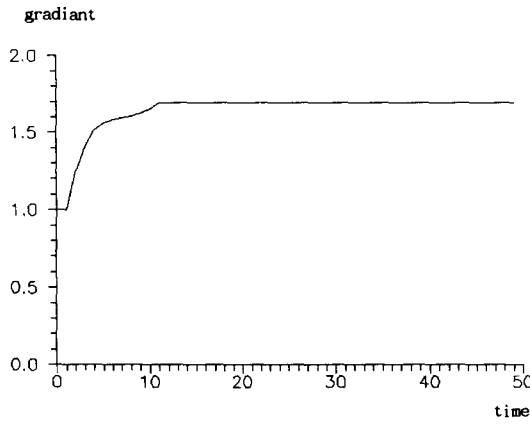


그림 5. 수정된 기울기  
Fig. 5. Modified gradient







그림 7. CI 파라미터가 변한 경우의 출력 응답  
Fig. 7. Output response for CI parameter variation



(a). 제어보정량을 사용하지 않은 경우  
(a). Control without control action error



(a). 제어보정량을 사용하지 않은 경우  
(a). Control without control action error




(b). 제어보정량을 사용한 경우

(b). Control using control action error


그림 8. C2 파라미터가 변한 경우의 출력 응답

Fig. 8. Output response for C2 parameter variation



(a). 제어보정량을 사용하지 않은 경우

(a). Control without control action error



(b). 제어보정량을 사용한 경우

(b). Control using control action error

그림 9. C1, C2 파라미터가 변한 경우의 출력 응답

Fig. 9. Output response for C1, C2 parameter variation

## VI. 결론

본 논문에서는 신경회로망을 이용하여 시스템의 불확실성, 시변특성등을 가지는 비선형 시스템을 제어하여 보았다. 또한 오차 역전달 학습 방법의 단점인 초기 포화상태를 해결하기 위하여 활성화함수의 기울기를 플랜트의 특성에 맞게 자동 조정함으로써 극부최소점에 수렴하는 것을 막을 수 있었다. 그리고 시스템의 외란등으로 인해 시스템의 특성이 갑자기 변하는 경우에 일반적으로 식별신경망을 다시 학습시켜야 하므로 제어 신경망은 시스템의 변화에 즉시 적응하기 힘들었지만 식별신경망의 입출력 변화분을 이용하여 식별오차를 제어 입력에 더해 줌으로써 플랜트의 변화에 강건함을 보여준다.

## 참고문헌

1. D.Psaltis, A.Sideris, and A. A. Yamamura, "A Multi-layered Neural Network Controller," *IEEE Contr. Syst. Mag.*, **8**, 17-21, Apr. 1988.
2. F.C. Chen, "Back-Propagation Neural Networks for Non-linear Self-Tuning Adaptive Control," *IEEE Contr. Syst. Mag.*, **10**, 44-48, Apr. 1990.
3. M.Dawato, "A Hierarchical Model for Voluntary Movement and Its Application to Robotics," *IEEE Contr. Syst. Mag.*, **8**, 573-582, Apr. 1988.
4. D.H. Nguyen and B.widrow, "Neural Networks for Self Learning Control systems," *IEEE Contr. Syst. Mag.*, **10**, 18-23, Apr. 1990.
5. K.S. Narendra and K.Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Trans. Neural Networks*, **1**, 4-27, 1990
6. N.Baba, "A New Approach for Finding the Global Minimum of Error Function of Neural Networks," *IEEE Trans. Neural Networks*, **2**, 367-373, 1989.
7. A.Rezgui et.al, "The Effect of the Slope of the Activation Function of the Backpropagation Algorithm," *Proc. Int. Joint Conf. Neural Networks*, **1**, 707-710, 1990.
8. Si-Zhao Qin et.al, "Comparison of Four Neural Net Learning Methods for Dynamic System Identification," *IEEE Trans. Neural Networks*, **3**, 122-130, 1992.
9. M.Khalid and S. Omatu, "A Neural Network Controller for Temperature Control Systems," *IEEE Contr. Syst. Mag.*, **12**, 58-64, Apr. 1992.