

인공 신경회로망을 이용한 추적 제어기의 구성 및 최적 추적 제어기와의 비교연구

박 영문 이 규원^{*} 최 면송

서울대학교 전기공학과

Design of tracking controller Using Artificial Neural Network & comparison with an Optimal Tracking Controller

Young-Moon Park Gue-Won Lee Myoen-Song Choie
Seoul National University

ABSTRACT This paper proposes a design of the tracking controller using artificial neural network and the compare the result with a result of optimal controller. In practical use, conventional Optimal controller has some limits. First, optimal controller can be designed only for linear system. Second, for many systems state observation is difficult or sometimes impossible. But the controller using artificial neural network does not need mathematical model of the system including state observation, so it can be used for both linear and nonlinear system with no additional cost for nonlinearity. Designed multi layer neural network controller is composed of two parts, feedforward controller gives a steady state input & feedback controller gives transient input via minimizing the quadratic cost function.

From the comparison of the results of the simulation of linear & nonlinear plant, the plant controlled by using neural network controller shows the trajectory similar to that of the plant controlled by an optimal controller.

1. 서론

기존의 제어이론은 제어 대상이 되고 있는 플랜트의 수학적 모델에 기초하여 발전되어 오고 있다. 동적 시스템의 수학적인 표현은 선형이나 비선형의 미분/차분 방정식으로 표현이 되는데 대부분의 경우 적당한 단순화를 통하여 선형의 미분/차분 방정식으로 근사화 하여 사용되고 있다. 그러나 그러한 근사화된 모델을 통하여 비선형의 정도가 심한 플랜트를 제어하는 것에는 많은 어려움이 있다.

비선형 시스템을 제어하는 새로운 시도의 하나로 인공신경회로망을 이용한 제어이론이 발전되고 있다[2]-[4],[6]-[10],[12]. 인공신경회로망을 이용한 동적 시스템의 제어는 인공신경회로망이 시스템을 학습하고 제어규칙을 학습하는 과정에서 수학적인 모델을 필요로 하지 않기 때문에 선형 비선형에 관계없이 사용될 수 있다는 장점을 가지고 있다. 최근에는 신경회로망을 이용한 비선형 시스템의 제어에 있어서 최적 제어 이론을 응용한 여러 연구가 발표되고 있다[4],[11]-[13]. 그러나 현재까지 신경회로망을 이용한 최적 제어방법은 목표값이 일정한 값으로 수렴하는데 중점을 두었기 때문에 목표값이 수시로 변하는 추적 문제는 직접하게 다루지 못하고 있다.

본 논문에서는 선형 시스템 이론을 활용하여 인공신경회로망을 이용한 제어기의 정상상태의 출력에 대한 정상상태의 입력을 내어주는 Feedforward제어기와 정상상태에 이르기까지의 추적 오차를 입력으로 받아 과도상태의 동태를 안정화 시키는 Feedback 제어기의 두 부분으로 구성하여 추적 제어를 하였다[18].

또한, 신경회로망을 이용한 제어기를 선형 및 비선형 플랜트의 추적 제어에 적용하여 그 결과를 최적 추적 제어기와 비교하였다. 비선형 시스템에 대한 최적 추적 제어기와의 비교를 위해서는 동작점이 변함에 따라 파라미터의 값이 변하는 비선형 플랜트를 시간에 따라 파라미터가 변해 나가는 플랜트로 파악을 하고, 파라미터 적용 제어에 최적 제어기법을 사용한 제어기를 사용하였다.

2. 문제의 정의

본 논문에서 다루고자 하는 제어 목적은 다음과 같다.

- 1) 변하는 목표값에 플랜트 출력을 따라가게 한다.
- 2) 과도 상태에서의 플랜트 출력과 목표값과의 추적오차 차승과 플랜트 입력과 정상상태 입력간 오차의 차승의 가중합을 가장 최소화 되도록 한다.
- 3) 정상 상태에서의 입력과 출력의 편차를 모두 영으로 한다.

3. 신경회로망을 이용한 제어기의 구성

선형 시스템이론에의 추적제어 이론을 응용해서 신경회로망을 이용한 추적 제어기를 구성을 할 수 있다. 다음은 일반적인 이산 시간 형태로 표현된 선형 시스템이다.

$$\begin{aligned} x_{k+1} &= Ax_k + Bu_k \\ y_k &= Cx_k \end{aligned} \quad (1)$$

선형 시스템 이론에서 추적 제어기를 구성하기 위해서는 플랜트 출력의 목표값을 y_{ref} 로 정하였을 때 출력을 이 목표값에 유지시키기 위해 정상 상태의 출력에 대응하는 정상상태의 입력이 있어야 한다.

플랜트가 정상상태에 도달했을 때는 다음과 같은 식을 만족한다.

$$\begin{aligned} y_{ref} &= C(k)x_0 \\ x_0 &= A(k)x_0 + B(k)u_0 \end{aligned} \quad (2)$$

식 (1),(2)를 이용하면 추적 문제가 목표값이 항상 영이 되는 regulating 문제로 상태 방정식을 얻을 수 있다. [11] 따라서 이동된 입력, 이동된 출력, 이동된 상태변수를 다음과 같이 정의 하면, 다음과 같은 식이 성립한다.

$$y_k' = y_k - y_{ref}, \quad u_k' = u_k - u_0, \quad x_k' = x_k - x_0 \quad (3)$$

$$x_{k+1}' = A(k)x_k' + B(k)u_k' \quad (4)$$

$$y_k' = C(k)x_k'$$

이 식을 다시 정리하면 다음과 같이 나타내어질 수 있다.

$$\begin{aligned} u_k' &= -F(k)x_k' \\ u_k &= -F(k)x_k + u_0 - F(k)x_0 = -F(k)x_k + u_{ref} \\ (u_{ref}) &= u_0 - F(k)x_0 \end{aligned} \quad (5)$$

잇 식에서 볼 수 있듯이 제어기의 제어입력을 feedforward 입력과 feedback 입력의 두 부분으로 나누어진다. 신경회로망을 이용한 제어기로 구성하는데 있어서, 선형 시스템과 유사하게 제어 입력이 정상상태에서의 제어 입력과 과도상태의 제어 입력의 합으로 이루어져 있다고 보면, 인공신경회로망을 이용한 제어 입력은 다음과 같은 형태로 표시된다. $u(k) = u_f(k) + u_b(k)$ (6)

Feedforward 입력 $u_f(k)$ 은 외부임 없이 원하는 목표값에 대응하는 정상상태의 입력을 내어주는 역할을 하고, $u_b(k)$ 는 추적 오차를 입력으로 받아 들여, 목표값에 도달하기까지의 과도상태의 동태를 안정화 시키는 역할을 한다. [18]

본 논문에서는 인공신경회로망을 이용한 식별기를 Neural Network Identifier (NNI) 라 하고, 입력 u_f 를 내어주는 제어기를 Feedforward 제어기(FFNC), u_b 를 내어주는 제어기를 Feedback 제어기 (FBNC) 라 한다. 본 논문에서는 신경회로망을 이용하여 위에 제시된 제어 목적을 만족하는 제어기를 다음과 같이 구성하였다.

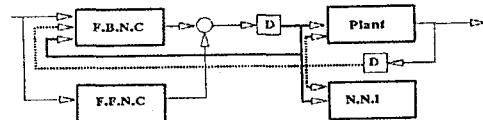


그림 1. 인공신경회로망을 이용한 제어기의 블록도

신경회로망 식별기는 다음과 같이 식별기에서 나오는 출력과 실제 플랜트의 출력과의 오차를 줄여 나가도록 학습시킨다. 다음은 학습에 사용한 목적 함수이다.

$$J = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} (y_{k+1} - \hat{y}_{k+1}) \quad (8)$$

N : 학습 자료의 수

신경회로망 식별기는 플랜트 특성을 학습하여 모의 플랜트의 역할을 할뿐 아니라, 제어기들의 학습에 필요한 동적오차를 전파하는 역할을 한다.

3.2 신경회로망을 이용한 Feedforward 제어기의 구성

플랜트의 출력이 임의의 영이 아닌 목표값을 추적하도록 추적 제어기를 설계하는데 있어서, 정상상태 출력 오차를 영으로 하기 위해서는 플랜트의 정상상태의 출력에 대응하는 정상상태의 입력이 필요하다. 본 논문에서는 이와같이 feedback 없이 플랜트의 정상상태에 대응하는 입력을 내어주는 제어기를 Feedforward 제어기라 정의 한다. 플랜트 정상상태의 출력에 대응하는 정상상태의 입력을 구하기 위해서 Feedforward 제어기는 다음과 같이 풀랜트의 역동학을 학습시킨다.

풀랜트가 정상상태일 때 풀랜트의 역동학을 학습시킨다. 풀랜트가 정상상태일 때 풀랜트의 역동학을 나타내는 상태방정식은 다음과 같이 표시된다.

$$y_{ref} = f(y_{ref}, y_{ref}, \dots, y_{ref}, u_{ref}, u_{ref}, \dots, u_{ref}) \quad (9)$$

인공신경회로망을 이용한 식별기가 플랜트의 동력학을 완전히 학습했다면, $y_{k+1} = f(\vec{X}_k) \approx \hat{y}_{k+1} = F(\vec{X}_k, \vec{W})$ 가 된다. 따라서, Feedforward 제어기가 플랜트의 역동력학 G를 학습하도록 하면 정상상태의 입력 u_f 는 다음과 같이 구해진다.

$$\begin{aligned}\hat{y}_{ref} &= F(y_{ref}, y_{ref}, \dots, y_{ref}, u_f, u_f, \dots, u_f) \quad (10) \\ u_f &= G(y_{ref}, \vec{W})\end{aligned}$$

Feedforward 제어기를 학습시키기 위해 오차 역전파 학습 알고리즘에서 사용한 목적함수는 다음과 같다.

$$J = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} (y_{ref} - \hat{y}_{ref}(u_f))^2 \quad (11)$$

N : 학습 자료의 수

3.3 신경회로망을 이용한 Feedback 제어기의 구성

Feedback 제어기는 추적 오차를 입력으로 받아들여 파도상태에서의 동태를 안정화시키는 역할을 한다. Feedback 제어기를 학습시키는데 있어서 오차 역전파 알고리즘을 활용하여, 최적 제어 이론에서 사용하는 목적함수를 최소로 하도록 Feedback 제어기를 학습시킨다. 단, 여기서는 문제를 풀기위해 우리가 관심이 있는 유한개의 N스텝까지 고려한 목적함수를 잡도록 한다. 다음은 feedback 제어기를 학습시킬때 사용하는 목적함수이다.

$$J = \sum_{k=1}^N [(y_{ref} - y_{k+1})^T Q (y_{ref} - y_{k+1}) + (u_{ref} - u_k)^T R (u_{ref} - u_k)] \quad (12)$$

(12)의 목적함수를 최소로 함으로써 상기한 제어목적을 만족시킬수 있다 [10]. 위에서 $u_{ref} \approx u_f$ and $u_k = u_f + u_{pk}$ 이므로 위의 목적함수를 다음과 같이 변형하였다.

$$J = \sum_{k=1}^N [(y_{ref} - y_{k+1})^T Q (y_{ref} - y_{k+1}) + (u_{pk})^T R (u_{pk})] \quad (13)$$

Feedback제어기의 특성은 아래의 같은 비선형 방정식으로 표시된다.

$$u_{pk} = H(y_k, y_{k-1}, \dots, y_{k-n+1}, u_{k-1}, u_{k-2}, \dots, u_{k-m+1}, \vec{W}) \quad (14)$$

Feedback 제어기를 학습시키기 위한 입력역행은 인공신경회로망을 이용한 식별기를 통해 얻는다. Feedback 제어기를 학습시키기 위한 알고리즘으로서는 BTT 알고리즘을 위해 주어진 목적함수를 학습시킬수 있도록 변형하여 사용한다[6]. 각각의 노드에서의 등가 오차가 목적함수의 음의 민감도임을 이용하면 BTT 알고리즘을 변형하는 것은 어렵지 않다. 사용한 등가오차와 민감도는 아래식과 같다.

$$\delta_u^k = -\frac{\partial J}{\partial u_{pk}}, \quad \delta_y^k = -\frac{\partial J}{\partial y_k} \quad (15)$$

민감도를 계산하는데는 플랜트의 동력학을 아는 것이 필요하다. 그러나 실제 플랜트의 동력학을 알 수가 없기 때문에 학습된 식별기를 통하여 근사화된 플랜트의 동력학을 이용한다. 식별기로부터 받아들인 등가 오차와 민감도로부터 δ_u^k 가 계산될 수 있음을 다음의 방정식에서 볼수 있다.

u_{pk} 가 Feedack 제어기로부터의 출력이므로 오차 역전파 알고리즘에서 $\delta_u^k = \delta_y^k$ 로 근사화해서 사용한다.

$$\begin{aligned}\delta u^k &= \sum_{l=k+1, l \neq N}^{k+m-1} \left(\frac{\partial J}{\partial u_{kl}} \frac{\partial u_{kl}}{\partial u_{pk}} \right) \\ &\quad - \sum_{l=k+1, l \neq N+1}^{k+m} \left(\frac{\partial J}{\partial \dot{y}_l} \frac{\partial \dot{y}_l}{\partial u_{pk}} \right) - \frac{\partial J_k}{\partial u_{pk}} \\ &\approx - \sum_{l=k+1, l \neq N}^{k+m-1} (\delta_u^l \cdot \frac{\partial H_l}{\partial u_{pk}}) - \sum_{l=k+1, l \neq N+1}^{k+m} (\delta_y^l \cdot \frac{\partial F_l}{\partial u_{pk}}) \\ &\quad - 2 \cdot R \cdot u_{pk} \quad (16)\end{aligned}$$

$$\begin{aligned}\delta_y^k &= \sum_{l=k+1, l \neq N}^{k+m-1} \left(\frac{\partial J}{\partial u_{kl-1}} \frac{\partial u_{kl-1}}{\partial u_{pk}} \right) - \sum_{l=k+1, l \neq N+1}^{k+m} \left(\frac{\partial J}{\partial \dot{y}_l} \frac{\partial \dot{y}_l}{\partial u_{pk}} \right) \\ &\quad - \frac{\partial J_{k-1}}{\partial u_{pk}} \\ &\approx - \sum_{l=k+1, l \neq N}^{k+m-1} (\delta_u^l \cdot \frac{\partial H_l}{\partial \dot{y}_k}) - \sum_{l=k+1, l \neq N+1}^{k+m} (\delta_y^l \cdot \frac{\partial F_l}{\partial \dot{y}_k}) \\ &\quad + 2 \cdot Q \cdot (y_{ref} - \dot{y}_k) \quad (17)\end{aligned}$$

위의 식 (16)과 (17)에 의해 계산된 등가오차를 이용하는 일반화된 BTT 알고리즘을 단계별로 요약하면 다음과 같다.

- 1) feedback 신경회로망 제어기의 가중계수들의 초기치를 작은 난수 값으로 설정한다.
- 2) 플랜트 운전영역 범위에서 임의의 초기치와 목표값을 정한다.
- 3) 신경회로망 제어기들이 난수로 설정된 목표값과 초기치에서 신경 회로망 식별기를 N시간 만큼 운전시킨다.
- 4) 3)의 운전되어진 결과로 식 (17),(18)을 이용하여 등가오차를 모든 시간 구역으로 역전파시킨다.
- 5) 역전파되어진 등가오차 δ_u^k 와 BPA를 이용하여 모든 시간 구간에서 feedback 신경회로망 제어기의 가중계수 조정량을 구한다.
- 6) 전 시간구간에서 가중계수의 평균으로 가중계수를 조정한다.
- 7) 단계 2)로 돌아간다.

4. 사례 연구

사례 1. 선형 시불변 시스템

선형 시불변 플랜트에 대한 시뮬레이션을 위해서 다음과 같은 이산 시간 선형 시불변 플랜트를 생각하였다.

$$y(k+1) = 2.83 y(k) - 2.8125 y(k-1) + 0.9809 y(k-2) + 1.544 u(k) - 1.539 u(k-1) \quad (18)$$

신경회로망과 최적 제어기에 사용하는 목적함수는 아래와 같다.

$$J = \sum_{k=1}^{15} [(y_{ref} - y_{k+1})^T Q (y_{ref} - y_{k+1}) + (u_{pk})^T R (u_{pk})] \quad (19)$$

목적함수에 사용한 Q와 R은 각각 1.0, 0.4이다.

a. 인공신경회로망을 이용한 제어

위에서 제시한 신경회로망 제어기를 이용하여 선형 시불변 시스템에 대하여 제어를 하였다.

신경회로망 식별기는 각각 35, 20개의 노드를 갖는 두개의 온니층을 갖는다. 입력층은 6개의 노드, 출력층은 1개의 노드를 갖는다. 학습시간은 486 DX-2를 이용하여 40분이 소요되었다.

Feedforward 제어기는 각각 2개의 노드를 갖는 입력층, 30개의 노드를 갖는 하나의 온니층, 1개의 노드를 갖는 출력층으로 구성되었다. 학습의 완료까지 486DX-2를 이용하여 20분이 소요되었다.

Feedback 제어기는 6개의 노드를 갖는 입력층, 각각 35개와 20개의 노드를 갖는 2개의 온니층, 출력층으로 구성하였다. 이미 학습 완료된 식별기와 Feedforward 제어기를 통해 학습을 한다.

본 논문에서 사용한 신경회로망은 모두 다층 신경회로망이며, 시뮬레이션에 사용한 신경회로망의 층수와 노드 수는 실험적인 방법에 의해서 결정하였다. 학습 방법으로는 학습과정중 가중계수의 값이 전동하는 것을 줄이기 위해 15개의 학습자료를 이용하는 학습에서 계산된 가중계수 조정량의 평균으로 가중계수를 한 번 조정하는 배치학습방법을 사용하였다. 다음은 신경회로망 제어기를 이용해서 선형 플랜트를 제어한 결과이다.

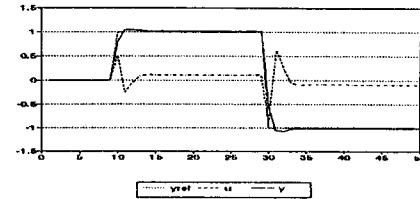


그림 2. 신경회로망 제어기를 이용한 제어결과

b. 최적 제어기를 사용한 제어

동작구간의 변화에 따라 최적 제어기의 구성은 플랜트의 파라메터를 정확히 알고 있는 상태에서 목적함수를 최소로 하는 Gain을 구하여 최적 제어를 하였다. 정확한 플랜트의 파라메터에 의해 계산된 Optimal Gain은 다음과 같다.

$$F = [1.0239, 0.4906, 0.1192]$$

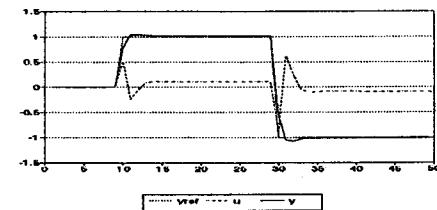


그림 3. 최적 제어기를 이용한 제어결과

그림 2는 신경회로망 추적 제어기를 이용해서 선형 플랜트를 제어한 결과이고, 그림 3은 같은 시스템에 대해 최적 제어기를 사용해 제어한 결과이다. 두 제어기를 사용해 제어한 결과는 거의 같은 궤적을 나타내고 있다.

사례 2. 비선형 시스템의 제어

비선형 시스템의 제어에로서 다음과 같은 추의 균형 문제를 다루도록 하겠다. 이 문제는 불안정하고 심한 비선형성을 가진 플랜트의 예로서 널리 사용되고 있다. 본 논문에서는 추가 주어진 임의의 각도를 유지하도록 하는 문제를 다루고 있다. 전통적인 제어 결과와 수식은 [12],[13]에서 찾아 볼수 있다.

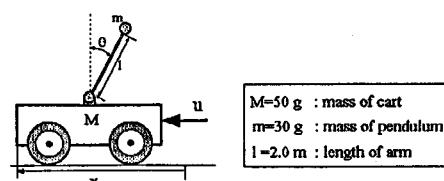


그림 4. Inverted Pendulum

이 플랜트의 동태 방정식은 다음과 같이 나타내어 진다.

$$(M+m)\ddot{x} + ml \cos\theta \dot{\theta} - ml \sin\theta \dot{\theta}^2 = u \quad (20)$$

$$m\cos\theta \ddot{x} + ml \dot{\theta} = mg \sin\theta$$

이산 시간 입출력쌍을 얻기 위해 변형 오일러 방법을 사용하였으며, 시간 구간은 0.13초이다. 목적함수는 식(19)과 같으며, Q와 R은 각각 1.0, 0.3의 값으로 설정했다.

a. 신경회로망 제어기를 이용한 제어

신경회로망 식별기는 각각 50개의 노드를 갖는 두개의 은닉층을 갖는다. 입력층은 6개의 노드, 출력층은 1개의 노드를 갖는다. 학습시간은 SUN Workstation을 이용하여 2시간이 소요되었다.

Feedforward 제어기는 입력층, 2개의 은닉층, 출력층으로 구성되었다. 이미 학습된 신경회로망 식별기를 이용하여 제어기를 학습시켰다. 학습의 완료까지 SUN Workstation으로 2시간이 소요되었다.

Feedback 제어기는 입력층, 2개의 은닉층, 출력층으로 이루어져 있으며, 각각의 은닉층의 노드수는 30개이다. 이미 학습 완료된 식별기와 Feedforward 제어기를 통해 학습을 한다. 학습의 완료까지 SUN Workstation으로 약 3시간이 소요되었다.

b. 최적 추적 제어기를 사용한 제어

본 논문에서는 비선형 시스템에 대해 최적 제어 기법을 사용하기 위해 매 시간마다 파라메터를 추정하고, 추정된 파라메터에 의해 제어 입력을 계산하였다. 파라메터는 다음의 목적함수를 줄이는 방향으로 추정하였다.

$$J(\theta) = \sum_{k=1}^n \lambda^{n-k} [y(k) - \phi^T(k)\theta]^2 \quad (21)$$

λ : 망각계수(forgetting factor), φ : 과거의 입출력쌍
θ : 추정된 파라메터

다음과 같은 식을 반복 계산함으로서 과거의 입출력쌍으로부터 파라메터를 추정할 수 있다[19].

$$\begin{aligned} \hat{\theta}(k+1) &= \hat{\theta}(k) K(k)[y_{k+1} - \phi^T(k+1)\hat{\theta}(k)] \\ K(k) &= P(k)\phi(k+1)[\lambda + \phi^T(k+1)P(k)\phi(k+1)]^{-1} \\ P(k+1) &= \frac{[I - K(k)\phi^T(k+1)]P(k)}{\lambda} \end{aligned} \quad (22)$$

시뮬레이션에 사용한 forgetting factor는 0.95이다.

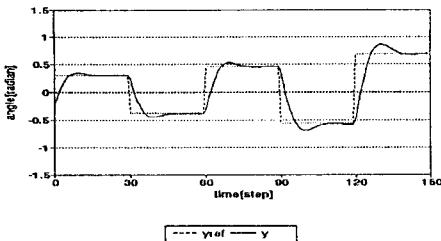


그림 5. 신경회로망 제어기를 이용한 제어결과

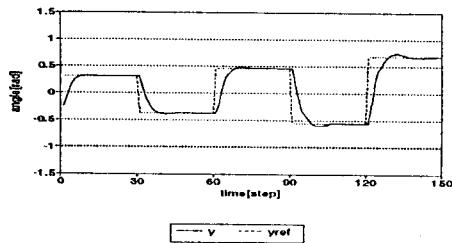


그림 6. 최적 추적 제어기를 이용한 제어결과

신경회로망 제어기와 최적 제어기를 사용해 비선형 플랜트를 제어한 결과를 그림 5, 그림 6에 나타내었다. 최적 제어기를 이용한 제어 결과가 신경회로망을 이용한 제어에 비해서 목표값에 도달하는 시간은 거의 같고, 목표값에 수렴하는 채워의 형태는 비슷하며, Overshoot는 약간 적은 결과를 보이고 있다. 그러나 최적 제어기는 동작구간내에서라도 출력값의 변화가 끊 때는 제어에 실패하는 경우가 있었다. 그림 7은 출력값의 변화가 끊 때, 플랜트 출력의 채워이 일그러짐을 보여주고 있다. 이에 비해 신경회로망을 이용한 제어기를 이용하여 제어를 하는 경우 Overshoot는 조금 크지만 동작구간내에서 출력값의 변화가 끊 경우에도 안정적인 제어 결과를 보여주었다.

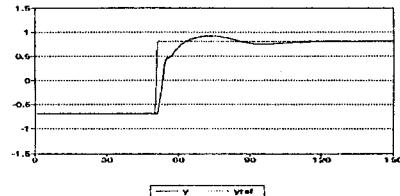


그림 7. 최적 제어기를 이용한 제어

선형 및 비선형 플랜트에 대한 시뮬레이션 결과를 통해서 신경회로망을 이용해서 구성한 추적 제어기가 플랜트의 선형 및 비선형에 관계없이 임의로 변하는 목표값에 대한 추적 제어를 할 수 있음을 보이고 있다. 또한, 신경회로망을 이용한 추적 제어에서 플랜트가 나타내는 채워이 같은 목적함수를 사용해서 최적 제어를 통해 신경회로망을 이용하는 제어 결과를 보여 준다.

신경회로망을 이용한 제어는 원하는 출력값이 동작구간 내에 있으면 출력값의 변화 크기에 관계없이 출력값을 따라 감으로써 파라메터 추정을 통한 최적 제어에 비해 안정적인 제어를 할 수 있음을 보여주고 있다.

5. 결론

본 논문에서는 선형 시스템에서의 추적 제어이론을 활용하여 신경회로망을 이용한 추적 제어기를 구성하였고, 구성된 추적 제어기가 선형 및 비선형 플랜트에 대하여 추적 제어를 할 수 있음을 사례연구를 통하여 보였다.

또한, 신경회로망을 이용한 추적 제어기를 이용해 선형 및 비선형 플랜트를 제어한 결과와 최적 추적 제어기를 이용해 제어한 결과의 비교를 통해 같은 목적함수를 사용하는 최적 제어기와 신경회로망을 이용한 제어기가 선형 시스템에 대해서는 거의 같고, 비선형 시스템에 대해서는 신경회로망을 이용한 제어결과가 Overshoot는 조금 더 크지만 안정적인 제어결과를 보여주고 있다.

비선형 플랜트의 제어에 있어서 예 시간구간마다 파라메터를 추정하고 Optimal Gain을 구해서 최적 제어를 하는 방법은 제어할때 계산시간이 많이 필요한 단점이 있다. 이에 비해 신경회로망을 이용한 제어기는 모든 동작 구간에 대해 미리 학습을 하는 방법을 택하고 있기 때문에 계산 시간이 많이 필요한 단점을 극복할 수 있다. 따라서 브론 계산 속도가 요구되는 비선형 플랜트의 제어에 대해서 신경회로망 제어기를 이용할 수 있다.

7. 참고 문헌

- [1] T. Poggio and F. Girosi, " Networks for Approximation and Learning ", Proceedings of the IEEE, pp. 1481-1497, September, 1990
- [2] D. Nguyen and B. Widrow, " The Truck Backer-Upper : An Example of Self-Learning in Neural Networks ", IEEE Control System Magazine, pp. 18-23, 1990
- [3] F. C. Chen, " Back-Propagation Neural Networks for Nonlinear Self-Tuning Adaptive Control ", IEEE Control System magazine,pp. 44-48, 1990
- [4] Y. Iiguni and H. Sakai, " A Nonlinear Regulator Design in the Presence of System Uncertainties Using Multilayered Neural Networks ", IEEE Trans. on Neural Networks ,Vol.3 No.4, July, 1991
- [5] R. Hecht-Nielsen , Neuro Computing, Addison Wesley, 1989
- [6] W. T. Miller and R. S. Sutton and P. J. Werbos, Neural Networks for Control, The MIT Press, pp 28-65, 1990
- [7] T. Yamada and T. Yabuta, " Neuro-controller Using Autotuning Method for Nonlinear Functions ", IEEE Trans. on Neural Networks ,Vol. 3 No.4, July 1992
- [8] M. A. Sartory and P. J. Antsaklis, " Implementation of Learning Control Systems Using Neural Networks ", IEEE Control System Magazine, pp. 49-57, April, 1992
- [9] M. Khalid and S. Omatsu, " A Neural Network based Control Scheme with an Adaptive Neural Model Reference Structure ", Proc. of International Joint Conference on Neural Networks, pp 2129-2133, Singapore, 1991
- [10] K. S. Narendra and K. Parthasarathy, " Identification and Control of Dynamic Systems Using Neural Networks ", IEE Trans. on Neural Networks , Vol.1 Mar. 1990
- [11] K. F. Fong and A. P. Loh, " Discrete-Time Optimal Control Using Neural Nets", Proc. of IJCNN, pp. 1355-1360, Singapore, 1991
- [12] K. L. Moore and S. Naidu, " Linear Quadratic Regulation Using Neural Networks ", Proc. of IJCNN, pp. II-735-11739, Seattle, 1991
- [13] T. Hoshino and M . Kanø, " Optimal control with a recurrent neural network and a priori knowledge of the system "Proc. of IJCNN, pp. 226-231, Singapore, 1991
- [14] H. Kwakernaak and R. Sivan, Linear Optimal Control Systems, Wiley & Sons Inc, pp 201-319, 1972
- [15] U. diCaprio and P. P. Wang, " A Study of the Output Regulator Problem for Linear System with Input Vector ", Proc. 7-th Annual Allerton Conference on Circuits and System Theory, pp. 186-188, 1969
- [16] A. P. Wieland, " Evolving Controls for Unstable Systems ", IEEE Proc. Summer Meeting San Diago, 1991
- [17] V. Williams and K. Matsuoka, " Learning to balance the inverted pendulum using neural networks ", Proc. of IJCNN, pp. 214-219, Singapore, 1991
- [18] J. E. Slotine, Applied Nonlinear Control, Prentice-Hall International, 1991
- [19] Karl J. Astrom, Computer Controlled Systems, Prentice-Hall International, pp. 420-430, 1990
- [20] Gene F. Franklin and J. David Powell, Digital Control of dynamic systems, Addison-Wesley Publishing Company, pp. 251-259, 1980