

神經回路網 制御機을 이용한 볼-빔 시스템의 安定化 位置制御

탁 한 호* · 추 연 규*

Stabilization Position Control of a Ball-Beam System Using Neural Networks Controller

Han-Ho Tack · Yeon-Gyu Choo**

〈목 차〉	
Abstract	3. 볼-빔 시스템의 모델링
1. 서론	4. 제어시스템의 설계
2. 신경회로망	5. 시뮬레이션 결과
2.1 출력층의 가중치 적응	6. 결론
2.2 은닉층의 가중치 적응	참고문헌

Abstract

This research aims to seek active control of ball-beam position stability by resorting to neural networks whose layers are given bias weights. The controller consists of an LQR (linear quadratic regulator) controller and a neural networks controller in parallel.

The latter is used to improve the responses of the established LQR control system, especially when controlling the system with nonlinear factors or modelling errors. For the learning of this control system, the feedback-error learning algorithm is utilized here.

While the neural networks controller learns repetitive trajectories on line, feedback errors are back-propagated through neural networks. Convergence is made when the neural networks controller reversely learns and controls the plant.

The goals of learning are to expand the working range of the adaptive control system and to bridge errors owing to nonlinearity by adjusting parameters against the external disturbances and change of the nonlinear plant.

The motion equation of the ball-beam system is derived from Newton's law. As the system is strongly nonlinear, lots of researchers have depended on classical systems to control it. Its applications of position control are seen in planes, ships, automobiles and so on.

* 진주산업대학교 전자공학과

However, the research based on artificial control is quite recent. The current paper compares and analyzes simulation results by way of the LQR controller and the neural network controller in order to prove the efficiency of the neural networks control algorithm against any nonlinear system.

1. 서 론

각종 산업기기에서 제어요소로 널리 사용되는 제어 시스템은 대부분 일정이득을 갖는 비례·적분·미분(PID)방식을 채택하고 있어 외란이 인가되거나, 부하특성이 비선형적으로 변할 때에는 적절한 이득과 성능을 얻기 어렵다. 그러므로 최근에는 지능제어 이론인 퍼지이론이나 신경회로망 등을 이용하여 비선형 제어에 많이 적용하고 있다.

따라서 고전적인 제어문제에 대한 어려움을 극복하기 위하여 컴퓨터를 이용하여 기존의 수학적 해석기법과는 다르게 신경회로망(neural networks) 이론을 응용한 제어기법이 많은 연구가들에 의해 병렬처리, 학습, 비선형 사상(mapping), 패턴인식, 정보처리, 산업응용 등에 연구가 진행되고 있다^{[1],[2]}. 그리고 신경회로망은 그 특징으로써 비선형 함수의 근사화, 학습능력, 최적화능력 및 고장진단을 쉽게 확인할 수 있는 점 등을 가지며, 이들의 특징을 이용하여 미지의 시스템이나 비선형성이 강한 플랜트의 비선형제어 및 적응제어 등에 적용되어 시뮬레이션 결과 좋은 성과를 거두고 있다^{[2],[4]}.

이 논문에서는 신경회로망을 이용하여 불-빔의 위치안정화를 능동적으로 제어하는 것을 목적으로 한다. 신경회로망의 구조는 하나의 은닉층을 가지며, 각 층에는 바이어스 가중치를 주었다. 그리고 제어기의 구성은 LQR(Linear Quadratic Regulator) 제어기와 신경회로망 제어기가 병렬로 구성되었다. 그러므로 신경회로망을 기존의 LQR 제어기와 같이 사용하는 방법은 기존의 제어시스템의 응답을 개선하는데 이용되고 있으며, 주로 불-빔과 같이 시스템이 비선형 요소를 포함하고 있거나 모델링 오차가 존재하는 시스템을 제어하는데 이용되고 있다^{[5],[6]}.

이와 같이 신경회로망과 기존의 LQR 제어기와 함께 이용한 제어시스템을 학습하기 위해 이 논문에서는 케환오차학습(feedback-error learning) 알

고리즘을 이용하였다. 그리고 신경회로망 제어기는 원하는 궤적을 반복에 의해 온라인으로 학습하며, 케환오차는 신경회로망을 통해 역전파된다. 또한 수렴은 신경회로망 제어기가 플랜트를 역으로 학습하면서 이루어지고, LQR 제어기의 중요성이 제거되면서 신경회로망 제어기가 플랜트를 제어한다.

그리고 학습의 목적은 비선형 플랜트의 변화와 외부잡음에 대해 제어기 매개변수를 잘 조절하여 적응 제어시스템의 동작영역을 폭넓게 하는 것과 비선형성에 의한 오차를 줄이도록 하는 것이다.

또한 불-빔 시스템의 운동방정식은 뉴턴법칙에 의해 유도되었으며, 그 특징이 비선형성이 매우 강하므로 많은 연구가들에 의해 여러 가지 고전적인 제어기를 이용하여 제어되었다. 응용범위는 비행기, 배, 자동차 등의 자세제어에 응용되고 있으나 지능제어이론을 적용한 연구는 최근에 간간히 발표되고 있다. 논문에서는 이러한 비선형 시스템에 적용된 신경회로망 제어 알고리즘의 효율성을 입증하기 위해 LQR 제어기와 케환오차학습에 의한 신경회로망 제어기를 설계하여 시뮬레이션을 통하여 그 결과를 비교 분석하였다.

2. 신경회로망

다층 퍼셉트론(Multilayer Perceptron) 즉 신경회로망은 분류와 제어를 하기 위하여 자주 사용되는 신경회로망이다. 이것은 다층 구조와 단극 또는 양극성 시그모이드 활성화함수를 가진 선형 합성함수로 구성된 뉴론이고, 신경회로망이 어떤 바라는 정밀도에 대해 함수를 근사화하는 능력을 나타낸 것이다. 그림 1은 다층 신경회로망의 구조를 나타낸 것이다.

그림 1에서 O_k , O_j , O_i 는 각각 출력층, 은닉층, 입력층의 출력값이고, W_{kj} 는 출력층의 유니트 k

에서 은닉층의 유니트 j 로부터 가중치이며, W_{ji} 는 은닉층의 유니트 j 에서 입력층의 유니트 i 로부터 가중치이다. 그리고 δ_j, δ_k 는 각각 은닉층과 출력층의 바이어스이다. 여기서 출력층의 출력은 다음과 같이 계산된다.

$$O_k = f(net_k), \quad k=1,2,\dots,n \quad (1)$$

$$net_k = \sum_j W_{kj} O_j + \delta_k, \quad j=1,2,\dots,n \quad (2)$$

그리고 은닉층의 출력은 다음과 같이 계산된다.

$$O_j = f(net_j) \quad (3)$$

$$net_j = \sum_i W_{ji} O_i + \delta_j, \quad i=1,2,\dots,n \quad (4)$$

여기서 $f(x)$ 는 시그모이드 함수로 다음과 같다.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (5)$$




그림 1. 다층 신경회로망의 구조

그리고 다층 신경회로망의 가중치를 결정하는 해석방법이 없기 때문에, 가중치는 반복적인 학습 과정에서 얻어진다. 이런 학습방법을 학습 또는 매개변수 적응이라 한다. 그리고 다층 신경회로망에 대해 잘 알려진 학습규칙은 역전파 학습알고리즘이다. 이것은 2차 평가함수의 최소화를 기반으로 한다. 이 학습규칙은 다음과 같다.

$$W_{ji}(n+1) = W_{ji}(n) + \Delta W_{ji}(n) \quad (6)$$

위 식을 델타규칙이라 부른다. 평가함수는 데이터 집합 D 가 주어진 신경회로망의 평균 오차자승으로 다음 식으로 정의된다.

$$E_{av} = \frac{1}{N_D} \sum_{n=1}^{N_D} E(n) \quad (7)$$

여기서 $E(n)$ 는 신경회로망에서 주어진 학습 샘플 수 n 의 오차자승의 순간 합이고, 다음 식과 같다.

$$E(n) = \frac{1}{2} \sum_{n=1}^{M_1} e_n^2(n) \quad (8)$$

신경회로망의 매개변수에 대한 학습방법은 원하는 출력과 실제 출력값 사이의 오차를 구하여 이 오차를 최소화시키는 방향으로 가중치를 조절하고, 학습을 위해 사용된 평가함수는 원하는 출력 r_n 과 실제 출력인 O_n 사이의 오차함수로 다음과 같다.

$$e_n = r_n - O_n \quad (9)$$

$$E_n = \frac{1}{2} \sum_n (r_n - O_n)^2 \quad (10)$$

그리고 신경회로망의 가중치는 현재샘플 또는 어떤 학습 샘플오차의 축적 후에 적용된다. 패턴학습 절차에서 가중치는 오차자승의 순간 합에 대한 음의 경사방향으로 적용되므로 다음과 같다.

$$W_{ji}(n+1) = W_{ji}(n) - \eta \frac{\partial E(n)}{\partial W_{ji}(n)} \quad (11)$$

여기서 η 는 학습 매개변수로써 학습율이라 하고, 반복학습에 대한 단계의 크기를 제어하는데 사용된다. 이것을 경사하강법이라 하며, 출력뉴런의 가중치 적응과 은닉뉴런의 가중치 적응이다.

2.1 출력층의 가중치 적응

경사하강법에 따라 출력층에 대한 가중치의 변화량은 다음과 같이 표현된다.

$$\Delta W_{kj} = -\frac{\partial E_n}{\partial W_{kj}}, \quad \eta > 0 \quad (12)$$

여기서 ΔW_{kj} 는 가중치의 변화량으로 다음과 같다.

$$\Delta W_{kj} = W_{kj}(new) - W_{kj}(old) \dots\dots\dots (13)$$

그리고 일반화된 오차신호 ζ_k 를 다음 식과 같이 정의된다.

$$\zeta_k = -\frac{\partial E_p}{\partial net_k} \dots\dots\dots (14)$$

연쇄법칙을 사용하면 다음과 같이 표현된다.

$$\frac{\partial E_n}{\partial W_{kj}} = \frac{\partial E_n}{\partial net_k} \frac{\partial net_k}{\partial W_{kj}} = -\zeta_k \frac{\partial net_k}{\partial W_{kj}} \dots\dots\dots (15)$$

여기서 $\frac{\partial E_n}{\partial W_{kj}}$ 는 네트워크에 대한 유니트 변화의 함수로써 오차의 변화를 반영하고, 네트워크에 접속된 가중치 변화의 효과를 표현한다. 식 (2)로부터 $\frac{\partial net_k}{\partial W_{kj}}$ 는 다음과 같다.

$$\frac{\partial net_k}{\partial W_{kj}} = \frac{\partial(\sum_j W_{kj} O_j + \delta_k)}{\partial W_{kj}} = O_j \dots\dots\dots (16)$$

그러므로

$$\Delta W_{kj} = \eta \zeta_k O_j \dots\dots\dots (17)$$

이고, ζ_k 의 값은 연쇄법칙의 적용으로 다음 식을 얻는다.

$$\zeta_k = -\frac{\partial E_n}{\partial net_k} = -\frac{\partial E_n}{\partial O_k} \frac{\partial O_k}{\partial net_k} \dots\dots\dots (18)$$

이 ζ_k 는 유니트의 출력에 관계되는 오차의 변화와 네트워크의 변화에 관계되는 출력의 변화를 표현하고, 식 (10)으로부터

$$\frac{\partial E_n}{\partial O_k} = -(r_n - O_n) \dots\dots\dots (19)$$

와 식 (1)로부터 다음 식을 얻는다.

$$\frac{\partial O_k}{\partial net_k} = f'(net_k) \dots\dots\dots (20)$$

여기서 $f'(x)$ 는 x 에 관한 $f(x)$ 의 미분이며, 식 (5)로부터 다음과 같다.

$$f(x) \frac{e^{-x}}{(1+e^{-x})^2} = \frac{1}{(1+e^{-x})} \left(1 - \frac{1}{1+e^{-x}}\right) = f(x)(1-f(x)) \dots\dots\dots (21)$$

그리고

$$\frac{\partial O_k}{\partial net_k} = O_k(1-O_k) \dots\dots\dots (22)$$

이다. 그러므로 출력층의 가중치 변화량은 식 (17) 과 같고, 식 (17)에서 ζ_k 는 다음과 같다.

$$\zeta_k = O_k(1-O_k)(r_k - O_k) \dots\dots\dots (23)$$

2.2 은닉층의 가중치 적응

은닉층의 뉴런에 대해 원하는 응답이나 목표값은 없다. 은닉층의 뉴런에 대한 오차신호는 신경회로망의 출력오차를 역전파하는 것으로 결정된다. 그러므로 은닉층의 가중치에 대한 학습규칙의 유도는 다음과 같은 경사하강법을 사용하여 구해진다.

$$\Delta W_{ji} = -\eta \frac{\partial E_n}{\partial W_{ji}} \dots\dots\dots (24)$$

앞에서와 같이 연쇄법칙을 사용하면 다음과 같다.

$$\frac{\partial E_n}{\partial W_{ji}} = \frac{\partial E_n}{\partial net_j} \frac{\partial net_j}{\partial W_{ji}} \dots\dots\dots (25)$$

그리고 ζ_j 는 다음 식 (26)과 같이 정의한다

$$\zeta_j = -\frac{\partial E_n}{\partial net_j} \dots\dots\dots (26)$$

식 (4)로부터 다음을 얻을 수 있다.

$$\frac{\partial net_j}{\partial W_{ji}} = O_i \dots\dots\dots (27)$$

그러므로

$$\Delta W_{ji} = \eta \zeta_j O_i \dots\dots\dots (28)$$

이며, 연쇄법칙을 사용하면 ζ_j 의 값은 다음과 같다.

$$\zeta_j = -\frac{\partial E_n}{\partial net_j} = -\sum \frac{\partial E_n}{\partial net_k} \frac{\partial net_k}{\partial O_j} \frac{\partial O_j}{\partial net_j}$$

$$= \sum \zeta_k W_{kj} f'(net_j) = O_j(1-O_j) \sum \zeta_k W_{kj}$$

..... (29)

그러므로 각 층사이의 가중치의 변화량은 다음과 같이 조절된다.

$$\Delta W_{kj}(n+1) = \eta \zeta_k O_j + \alpha \Delta W_{kj}(n) \quad \text{..... (30)}$$

$$\Delta W_{ji}(n+1) = \eta \zeta_j O_i + \alpha \Delta W_{ji}(n) \quad \text{..... (31)}$$

여기서 α 는 모멘텀 상수이다. 신경회로망의 학습 속도를 빠르게 하기 위해 학습율 η 는 크게 해야 한다. 그러나 η 가 너무 크면 가중치 갱신은 불안정하게 되고, 발산을 하기 시작한다. 역전파 학습 규칙의 학습속도를 증가시키는 다른 방법은 모멘텀 상수 α 를 가진 모멘텀 항의 추가로 이루어진다. 모멘텀 항은 지역최소에 대한 보다 강인한 학습 규칙을 만든다.

3. 볼-빔 시스템의 모델링

볼-빔에 대한 운동방정식은 뉴턴법칙에 의해 상태방정식의 형태로 유도된다. 그림 2는 볼-빔의 운동방정식을 유도하기 위한 구조이다.




그림 2. 볼-빔의 구조

그림 2에서 관성모멘트는 다음과 같다.

$$J_P = J_{CM} + M_A d^2 \quad \text{..... (32)}$$

$$J_B = \frac{2}{5} M_B r^2 \quad \text{..... (33)}$$

중심축에 대응하는 볼의 가속도를 구할 수 있다. 이것은 볼 질량 중심의 위치를 두 번 미분한 것이다. 힘의 합은 다음과 같다.

$$M_B [\ddot{z} + h \ddot{\theta} - z \dot{\theta}^2] \hat{e}_1 + M_B [2 \dot{\theta} \dot{z} + z \ddot{\theta} + h \dot{\theta}^2]$$

$$= -F_2 \hat{e}_1 - F_1 \hat{e}_2 + M_B g [\sin \theta \hat{e}_1 + \cos \theta \hat{e}_2]$$

..... (34)

식(3)를 \hat{e}_1 과 \hat{e}_2 가 포함되도록 F_1 과 F_2 로 다시 표현하면 다음과 같다.

$$M_B [\dot{z} \dot{\theta} + z \ddot{\theta} + h \dot{\theta}^2] = -F_1 + M_B g \cos \theta$$

$$F_1 = M_B [g \cos \theta - (2 \dot{z} \dot{\theta} + z \ddot{\theta} + h \dot{\theta}^2)]$$

..... (35)

$$M_B [\ddot{z} + h \ddot{\theta} - z \dot{\theta}^2] = -F_2 + M_B g \sin \theta$$

$$F_2 = M_B [g \sin \theta - (\ddot{z} + h \ddot{\theta} - z \dot{\theta}^2)]$$

..... (36)

그리고 모멘트의 합은 다음과 같다.

$$\frac{d}{dt} \bar{H}_{BCM} = J_B \bar{\alpha}_B \quad \text{..... (37)}$$

비선형 운동방정식으로 표현하면 다음과 같다.

$$\left[M_B h + \frac{J_B}{\rho} \right] \ddot{\theta} + \left[M_B + \frac{J_B}{\rho^2} \right] \ddot{z} - M_B [z \dot{\theta}^2 + g \sin \theta] = 0$$

..... (38)

두 번째 방정식을 얻기 위해 Body A에 대해 고려한다. 관성기준점은 중심점 P로 하고 이점에 대한 모멘트는 다음과 같다.

$$\sum Moments_P = z F_1 \hat{k} + (h - \rho) f_2 \hat{k} + M_A g \sin \theta \hat{k} + T \hat{k}$$

..... (39)

$$\frac{d}{dt} \bar{H}_{PA} = \sum Moments$$

..... (40)

$$\frac{d}{dt} \bar{H}_{PA} = [J_{CM} + M_A d^2] \ddot{\theta} \hat{k}$$

여기서 \bar{H}_{PA} 는 Body A의 중심점 P에 대한 각모멘트이고, F_1 과 F_2 에 관계되는 수식 (35), (36), (38), (39), (40)으로부터 다음을 얻을 수 있다.

$$[J_{CM} + M_A d^2] \ddot{\theta} = z \{ M_B g \cos \theta - M_B [2 \dot{z} \dot{\theta} + z \ddot{\theta} + h \dot{\theta}^2] \} + (h - \rho) \frac{J_B}{\rho} \left[\ddot{\theta} + \frac{\ddot{z}}{\rho} \right] + M_A g \sin \theta + T \quad (41)$$

그리고 비선형 상태방정식을 유도하면 다음과 같다.

$$\frac{J_B h}{\rho} \ddot{\theta} + \frac{J_B h}{\rho^2} \dot{z} \dot{\theta} - M_B h z \dot{\theta}^2 = M_B g h \sin \theta - M_B h^2 \ddot{\theta} - M_B h \ddot{z} \quad (42)$$

그러므로 비선형 운동방정식은 다음과 같다.

$$[J_{CM} + M_A d^2 + M_B(z^2 + h^2) + J_B] \ddot{\theta} + \left[M_B h + \frac{J_S}{\rho} \right] \dot{z} + 2M_B z \dot{z} \dot{\theta} - M_A g \sin \theta - M_B g [h \sin \theta + z \cos \theta] = T \quad (44)$$

불과 트랙에 대한 두 개의 비선형 운동방정식을 이용하여 비선형 상태모델로 변환하면 실제적인 비선형 상태방정식은 다음과 같다.

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \\ \dot{x}_4 \end{bmatrix} = \begin{bmatrix} x_3 \\ x_4 \\ \frac{1}{\Delta} [m_{22} f_1 - m_{12} f_2] \\ \frac{1}{\Delta} [m_{11} f_2 - m_{12} f_1] \end{bmatrix} + \frac{T}{\Delta} \begin{bmatrix} 0 \\ 0 \\ -m_{12} \\ m_{11} \end{bmatrix} \quad (45)$$

여기서 $f_1 = M_B [z \dot{\theta}^2 + g \sin \theta]$, $f_2 = M_A g \sin \theta$, $+ M_B g [h \sin \theta + z \cos \theta] - 2M_B z \dot{z} \dot{\theta}$

$$m_{11} = M_B + \frac{J_B}{\rho^2}, \quad m_{12} = M_B h + \frac{J_B}{\rho},$$

$$m_{22} = J_{CM} + M_A d^2 + J_B + M_B [h^2 + z^2],$$

$\Delta = m_{11} m_{22} - m_{12}^2$ 이고, 식 (45)를 선형화 상태방정식으로 변환하면 다음과 같다.

$$\dot{\bar{x}} = A \bar{x} = B u \quad (46)$$

즉 다음과 같은 방정식으로 주어진다.

$$\begin{bmatrix} \dot{z} \\ \dot{\theta} \\ \ddot{z} \\ \ddot{\theta} \\ \dot{i} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ a_{31} & a_{32} & 0 & a_{34} & a_{35} \\ a_{41} & a_{42} & 0 & a_{44} & a_{45} \\ 0 & 0 & 0 & a_{54} & a_{55} \end{bmatrix} \begin{bmatrix} z \\ \theta \\ \dot{z} \\ \dot{\theta} \\ i \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ \frac{K_A}{L_M} \end{bmatrix} e \quad (47)$$

여기서 $a_{31} = -\frac{m_{12L}}{\Delta_L^*} M_{BG}$, $a_{41} = \frac{m_{11L}}{\Delta_L^*} M_{BG}$,

$$a_{32} = -\frac{m_{22L}^*}{\Delta_L^*} M_{BG} - \frac{m_{12L}}{\Delta_L^*} (M_A g d + M_B g h),$$

$$a_{42} = -\frac{m_{12L}}{\Delta_L^*} M_{BG} + \frac{m_{11L}}{\Delta_L^*} (M_A g d + M_B g h),$$

$$a_{34} = \frac{m_{12L}}{\Delta_L^*} D_M, \quad a_{44} = -\frac{m_{11L}}{\Delta_L^*} D_M, \quad a_{54} = -\frac{K_M}{L_M},$$

$$a_{35} = -\frac{m_{12L}}{\Delta_L^*} K_M, \quad a_{45} = \frac{m_{12L}}{\Delta_L^*} K_M, \quad a_{55} = \frac{m_{11L}}{\Delta_L^*} K_M,$$

$$a_{55} = -\frac{R_T}{L_M} \text{ 이다.}$$

4. 제어시스템의 설계

먼저 LQR 제어를 설계하기 위해 표준 LQR의 평가함수 J 를 다음과 같이 정의한다.

$$J = \frac{1}{2} \int_0^{\infty} [\mathbf{x}^T(t) \mathbf{Q} \mathbf{x}(t) + \mathbf{u}^T(t) \mathbf{R} \mathbf{u}(t)] dt \quad (48)$$

그리고 상태 가중치행렬 \mathbf{Q} 는

$$\mathbf{Q} = \begin{bmatrix} [q_1 \ 0] & 0 \\ 0 & I \\ 0 & [q_2 \ 0] \\ & 0 & I \end{bmatrix} \quad (49)$$

이고, 여기서 q_i 는 i 번째 최대허용 상태변수값을 의미한다.

LQR 제어를 이용한 제어시스템의 구조는 그림 3과 같이 설계했고, 그림에서 CC(Command Converter)블럭은 상태공간형으로 기준입력을 간단히 변환시키는 역할을 한다.




그림 3. LQR 제어를 이용한 제어시스템의 구조

그림 3에서 토크 τ 는 다음과 같다.

$$\tau = -K(x - x_{ref}) \dots\dots\dots (50)$$

여기서 K 는 모든 상태궤환 이득행렬이며, 적당한 레귤레이터 이득행렬 K 는 바라는 응답이 될 때까지 q_1, q_2 와 R 의 값을 변화시켜 찾는다.

그리고 신경회로망 제어기의 구조는 LQR 제어기에 기반으로 한 병렬로 구성된 신경회로망 제어 시스템을 설계하고자 한다. 제어시스템의 구조는 그림 4와 같이 신경회로망 제어기에 의한 제어 시스템으로써 전체 제어기의 구성은 출력측에서 궤환되어진 량을 LQR 제어기와 신경회로망 제어기의 입력으로 이용하는 형태의 병렬로 구성되었다.

전통적 LQR 제어기는 학습주기 동안 점근적 안정성을 보장하기 위한 것과 제어되는 플랜트의 응답에 대한 기준모델로써 사용된다. 그리고 신경회로망 제어기는 원하는 궤적을 반복에 의해 온라인으로 학습되며, 학습에 대한 수렴특성은 신경회로망이 플랜트를 역으로 학습하면서 수렴하고, LQR 제어기의 중요성이 제거되면서 신경회로망 제어기가 플랜트를 제어한다.

그림 4의 제어기 구조에서 LQR 제어기는 고정된 이득을 가지면서 외란에 대하여 전체 시스템을 안정되게 하고, 신경회로망 제어기의 내부 가중치는 플랜트의 역 모델로 이루어진 신경회로망 제어기에서 제어신호 U_N 을 생성하여 갱신한다. 초기 학습 기간동안 제어신호 U_N 는 매우 적으므로 무의미하다. 또한 LQR 제어기로부터의 제어신호 U_C 는 매우 큰 초기오차이기 때문에 중요하다. 그래서 학습의 초기단계에서 U_C 는 U_N 보다 큰 값을 가지고, 학습회수의 증가에 의해 U_C 의 값이 작

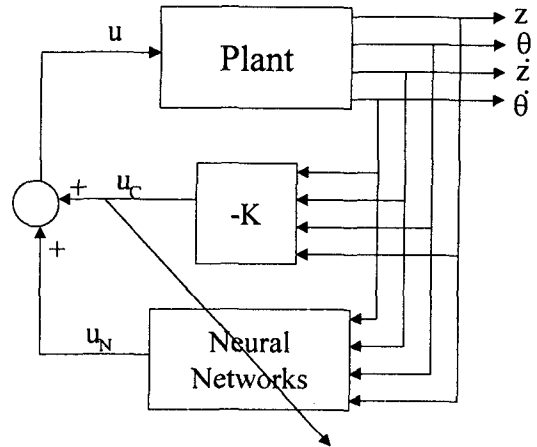


그림 4. 신경회로망 제어기를 이용한 제어시스템의 구조

아지면서 U_N 는 큰 값으로 변화된다. 그러므로 U_N 의 값이 U_C 의 값보다 크지면 신경회로망 제어기가 플랜트를 제어한다. 일반적으로 오차역전과 학습 알고리즘은 다음과 같은 잇점이 있다.

- (1) 교사신호가 신경회로망을 학습하기 위해 요구되지 않는다. 대신에 궤환오차신호가 학습 신호로써 사용된다.
- (2) 학습과 제어는 전통적인 학습 후 제어 (learn-then-control) 접근과는 달리 동시에 실행된다.

제어시스템에서 한 번 학습된 신경회로망 제어기는 동적 플랜트의 역 동적 모델로 표현될 수 있고, 고정된 이득의 LQR 제어기는 신경회로망 제어기에 대한 매개변수의 수렴을 충분하게 실행되게 한다. 본질적으로 LQR 제어기의 출력은 플랜트의 동역학과 신경회로망에 의해 얻어진 역 동적 모델 사이에 부적당한 짝으로 표현된다. 이것은 실제 역 동적 모델로 학습이 되었었기 때문이고, 다만 신경회로망 제어기는 원하는 궤적을 성취하기 위해 필요한 제어신호를 공급한다. 그래서 제로 궤적오차를 가지고, LQR 제어기는 출력을 산출하지 않으며, 학습은 완성되었다는 것을 의미한다.

5. 시뮬레이션 결과

본 장에서는 앞에서 제시한 신경회로망의 구조와 학습 알고리즘의 제어성능을 알아보기 위하여 볼-빔 시스템에 적용하고자 하며, 두 가지 제어기를 이용하여 시스템의 안정화 위치제어에 적용한다. 신경회로망 제어기는 초기 가중치가 난수로 주어져 온라인 학습을 행하면서 플랜트를 제어하는 방법으로 시스템의 볼의 위치 및 속도와 빔의 각도 및 각속도에 대하여 LQR 제어기와 신경회로망 제어기를 비교 조사하였고, 시스템의 매개변수는 $h=0.0965\text{ m}$, $d=0.0826\text{ m}$, $\rho=0.0086\text{ m}$, $g=9.81\frac{\text{m}}{\text{s}^2}$, $R_A=0\ \Omega$, $R_M=2.08\ \Omega$, $M_A=0.708\text{ kg}$, $M_B=0.104\text{ kg}$, $K_M=0.106\frac{\text{V}}{\text{rad/s}}$, $K_A=2\frac{\text{Volts}}{\text{Volt}}$, $L_M=6.3\text{ mH}$, $J_B=8.5\times 10^{-6}\text{ kgm}^2$, $J_{CM}=0.0114\text{ kgm}^2$, $J_M=7\times 10^{-5}\text{ kgm}^2$, $B=1.35\times 10^{-4}\frac{\text{Nm}}{\text{rad/s}}$, $D_M=0.00765\frac{\text{Nm}}{\text{rad/s}}$, $F_V=0.0076\frac{\text{Nm}}{\text{rad/s}}$ 과 같다.

이들 값들을 볼-빔 시스템의 상태방정식 (47)에 대입하여 정리하면 다음과 같다.

$$\begin{bmatrix} \dot{z} \\ \dot{\theta} \\ \dot{z} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ -3.07 & 2.79 & 0 & 0.0023 & -0.319 \\ 61.0 & 37.1 & 0 & -0.457 & 6.34 \end{bmatrix} \begin{bmatrix} z \\ \theta \\ z \\ \theta \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} u \quad (51)$$

또한 모터전류와 적분상태는 실제 실험에 필요한 항목으로 무시한다. 그리고 LQR 제어기에 대한 이득 K 는 $[88.3\ 80.0\ 38.9\ 11.4]$ 으로 하였으며, 신경회로망 제어기는 3층으로 구성되어졌고, 4개의 입력층 뉴런과, 10개의 은닉층 뉴런, 1개의 출력층 뉴런을 가진다. 입력과 은닉층에 대해 사용된 활성화함수는 양극 시그모이드 함수이고, 출력층은 선형함수이며, 은닉층과 출력층에는 각각 바이어스를 주었다. 그리고 신경회로망에 대한 입력은 시스템의 볼의 위치 z 및 속도 \dot{z} 와 빔의 각도 θ 및

각속도 $\dot{\theta}$ 이고, 출력은 U_N 이다. 제어기에 대한 가중치의 초기값은 $[1, -1]$ 사이의 난수로 하였고, 바이어스 값은 $[1, -1]$ 사이의 난수로 하였으며, 학습율은 0.75, 모멘텀함은 0.8, 샘플링 시간은 5[ms]로 하였다.

그림 5는 볼이 임의의 위치에서 정의 위치로 안정화되는 응답특성을 나타낸 것으로 신경회로망 제어기가 LQR 제어기 보다 적은 변화로 안정화됨을 알 수 있었고, 그림 7은 볼의 속도에 대한 응답특성을 나타낸 것으로 신경회로망 제어기가 LQR 제어기보다 빠름을 나타내었다.




그림 5. 볼의 위치에 대한 응답특성




그림 6. 빔의 각도에 대한 응답특성




그림 7. 불의 속도에 대한 응답특성




그림 8. 빔의 각속도에 대한 응답특성

그림 6은 빔의 각도변화에 대한 안정화 응답특성으로 신경회로망 제어가 LQR 제어기 보다 빠른 안정성을 나타내며, 그림 8은 빔의 각속도에 대한 응답특성을 나타내었다.

시뮬레이션 결과에 의해 초기 응답특성을 비교해 보면 신경회로망 제어가 LQR 제어기보다는 아주 적지만 학습초기에는 오차가 약간 있음을 보여준다. 그러나 학습이 진행되었을 경우 오차가 아주 적으면서 응답도 잘 수렴함을 알 수 있었다. 그러므로 이 논문에서 제안한 인공지능형 신경회로망 제어기에 의한 불-빔의 안정화제어에 있어서는 고전적인 제어방법인 LQR 제어기보다 빠른 적응력과 제어성능이 우수함을 알 수 있었다.

그리고 제어시스템의 설계에서 LQR 제어기의 이득계수를 설정하기 위해 상당한 시행착오를 거쳐야 하지만 신경회로망 제어를 사용할 경우 이와 같은 문제는 쉽게 해결될 수 있고, 그 성능 또한 이 논문에서 제시한 결과와 같이 LQR 제어기 보다 미세한 진동이 개선됨을 보였다.

6. 결 론

이 논문은 비선형 시스템인 불-빔의 안정화제어를 위해 새로운 제어기법인 신경회로망 제어기를 적용하였다. 전체적인 제어시스템의 구성은 플랜트를 제어하기 위해 LQR 제어기와 신경회로망 제어를 사용하여 병렬로 구성하였다. 또한 이들의 제어기법에 대한 특성비교를 위하여 시뮬레이션을 행하였다.

신경회로망의 구조는 하나의 은닉층을 가지며, 가중치를 개선하기 위한 적응 학습법칙은 퀴환오차 학습알고리즘을 사용하였다.

신경회로망 제어기를 이용한 제어시스템의 구조에서 불-빔의 안정화제어를 위하여 신경회로망 제어기가 학습이 되기 전까지는 LQR 제어기로 제어되면서 학습 후에는 신경회로망 제어기만으로 제어되도록 모델링하였다.

시뮬레이션 결과에서 신경회로망 제어기가 LQR 제어기보다 원하는 위치를 변형이 적으면서 더 빠른 속도로 수렴함을 알 수 있었다.

결과적으로 이 논문에서 제안한 퀴환오차학습에 의한 신경회로망 제어기가 비선형 시스템인 불-빔의 안정화제어에 효과적이라는 것을 알았다. 그러므로 비선형성이 강한 불-빔이 고전적인 제어기보다 인공지능형 신경회로망 제어기로 효과적으로 제어됨은 비행기·배·자동차의 현가장치·기타 산업현장 등의 흔들림에 대한 안정화제어에 많은 응용범위가 있으리라 사료된다.

앞으로의 연구과제는 실제 실험적 시스템을 구성하여 시뮬레이션과 실험을 통하여 제안된 신경회로망 제어기의 효과를 제시하고자 한다.

참고문헌

- 1) A. U. Levin and K. S. Narendra, "Control of Nonlinear Dynamical Systems using Neural Networks-Part II: Observability, Identification, and Control", IEEE Trans. Neural Networks, Vol. 7, No. 1, pp. 30-42, 1996.
- 2) A. U. Levin, and K. S. Narendra, "Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization", IEEE Trans. Neural Networks, Vol. 4, No. 2, pp. 192-205, 1993.
- 3) A. U. Levin, and K. S. Narendra, "Recursive Identification using Feedforward Neural Networks", Int. J. Contr., Vol. 61, No. 3, pp. 533-547, 1995.
- 4) C. C. Ku and K. Y. Lee, "System Identification and Control Using Diagonal Recurrent Neural Networks", American Control Conf. Chicago, pp. 545-549, 1992.
- 5) Karl Johan Aström and Tore Hagglund, "Automatic Tuning of PID Controllers", Instrument Society of America, 1988.
- 6) M. Sobhani, B. Neisius, S. Jayasuriya, E. Rumler, and M. Rabins, "Some New Insights on the Classical Beam and Ball Balancing Experiment", Proce. of the American Control Conference, Chicago, IL, 1992.