

論文98-35C-6-11

비선형 시스템의 직접제어방식을 위한 다층 신경회로망

(The Multi-layer Neural Network for Direct Control Method of Nonlinear System)

崔光淳*, 鄭盛夫**, 嚴基煥*

(Kwang-Soon Choi, Sung-Boo Chung, and Ki-Hwan Eom)

요약

본 논문에서는 비선형 시스템의 직접제어방식을 위한 다층 신경회로망을 제안하였다. 제안한 방식은 신경회로망이 플랜트의 역 모델을 학습하는 방식으로 플랜트의 사전지식을 시스템의 입출력 정보를 이용하여 추정하고, 플랜트의 역 모델을 선형부분과 비선형 부분의 직렬연결로 구성하고 선형부분과 비선형부분의 모델을 신경회로망을 이용하여 구성된 직접제어방식이다. 제안한 제어기의 선형부분은 선형 시스템의 시스템동정을 위해 이용되었던 반복최소자승법을 이용하여 구하여진 플랜트의 선형입력으로 학습을 수행하고, 비선형부분은 기준 궤적과 실제 출력의 오차를 이용해 학습을 수행한다. 단일 관절 매니퓰레이터를 이용하여 추종제어에 대한 시뮬레이션과 실험을 하여 기존의 다층신경회로망을 이용한 직접제어방식과 제어성능을 비교 검토한 결과 신경회로망 구성의 간단함과 정밀성 등의 우수함을 확인하였다.

Abstract

In this paper, we proposed a multi-layer neural network for direct control method of nonlinear system. The proposed control method uses neural network as the controller to learn inverse model of plant. The neural network used consists of two parts; one part is for identification of linear part, and the other is for identification of nonlinear part of inverse system. The neural network has to be learned the linear part with RLS algorithm and the nonlinear part with error of plant. From the simulation and experiment of tracking control to use one link manipulator as plant, we proved usefulness of the proposed control method to comparing to conventional direct neural network control method. By comparing the two methods, from simulation and experiment, we were convinced that the proposed control method is more simple and accuracy than the conventional method. Moreover, number of weight and bias to be controller parameter are small, and it has smaller steady state error than conventional method.

I. 서론

최근들어 점점 더 복잡하고 비선형성이 강해지는 플

랜트에 대한 제어방식은 고전적인 선형화 제어방식으로는 적용의 한계가 존재하므로 이에 대처하는 제어방식으로 적응제어 방식이나 H_{∞} 등의 강인제어 방식등이 있다^{[1][2][3][4]}. 그러나 이러한 방식도 제한된 불확실성 내에서 적용가능하며, 비선형성이 강하거나 동작점의 범위가 넓은 경우에는 적용하는데 문제점이 있다. 그러므로 최근에는 지능제어방식으로 전문가 법칙에서 경계의 불확실성을 해결하고자하는 퍼지제어나

* 正會員, 東國大學校 電子工學科

(Dept. Electronic Eng. Dongguk Univ.)

** 正會員, 瑞逸專門大學校 電子科

(Dept. Electronics Seoil Junior College)

接受日字:1998年1月22日, 수정완료일:1998年5월14일

생물학적 신경계통을 모방한 신경회로망제어등이 많이 이용되고 있다^[5].

1980년대 중반에 발표된 하나 이상의 은닉층을 갖는 다층신경회로망 이론은 출력층의 오차를 역전파 형식으로 전파하여 신경회로망의 연결강도를 조정하므로서 비선형 시스템을 모형화 할 수 있는 학습력이 있어 시스템동정에 성공적으로 적용되고 있다. 기존의 자기동조 적응제어방식에서 시스템동정을 위해 이용되었던 반복최소자승법은 선형 시스템에 유용한 방식이나, 신경회로망에 의한 시스템동정은 비선형 시스템에서도 우수한 동정특성으로 자기동조 적응제어방식에 잘 적용될 수 있었다. 이러한 신경회로망을 이용한 시스템동정은 기존의 비선형 제어기 설계에 직접 적용될 수 있으며, 신경회로망 제어기의 초기 학습력을 보상할 수 있어 신경회로망제어는 복잡하고, 시변특성이 있거나 비선형특성이 강한 시스템에 활용할 수 있다^{[5] [6]}.

신경회로망 제어방식으로는 신경회로망 자체를 제어기로 사용하는 직접 제어방식과 시스템 모델을 동정하고 동정된 정보를 제어기에 활용하는 간접제어 방식등이 있다^{[5] [6] [7]}. 신경회로망 자체를 제어기로 사용하는 직접 제어방식은 온라인으로 전방향 제어기로 사용하는 동안에 학습을 수행하고, 원하는 기준계적을 입력으로 사용하기 때문에 관심을 갖는 입력공간에서 학습을 수행할 수 있다는 장점과 직접 역동제어방식이므로 사용하기가 아주 편리하다^{[7] [8]}. 직접 제어방식은 신경회로망 제어기에 대하여 특별히 안정도 조건이 확립되어 있지 않아 은닉층의 수나 각 은닉층의 뉴런 수를 몇개로 구성하는 것이 적합한지에 대한 문제점이 있다. 또한, 플랜트의 다이내믹 모델이 추가적인 층으로 고려되어, 역전파 알고리즘을 제어에 적용하기 위하여는 플랜트의 야코비안과 같은 사전지식을 이용하여야 하며, 신경회로망이 단독으로 직접 플랜트를 제어하기 때문에 제어대상인 플랜트는 초기 학습과정에서 불안정할 수 있는 문제점도 있다^[9]. 이러한 직접 제어방식은 은닉층의 수나 각 은닉층의 뉴런 수를 최소화 하면서 플랜트의 사전지식을 이용하지 않고서도 초기의 불안정한 상태를 빠르게 안정한 상태로 도달하게 하는 방향으로 연구가 진행되고 있다^[9].

본 논문에서는 신경회로망을 이용한 비선형 시스템의 직접제어방식을 제안한다. 제안한 방식은 신경회로망이 플랜트의 역 모델을 학습하는 방식으로 플랜트의 사전지식을 시스템의 입출력 정보를 이용하여 추정하

고, 플랜트의 역 모델을 선형부분과 비선형 부분의 직렬연결로 구성하고 선형부분과 비선형부분의 모델을 신경회로망을 이용하여 구성된 직접 적응제어방식이다. 제안한 제어기의 선형부분은 선형 시스템의 시스템동정을 위해 이용되었던 반복최소자승법을 이용하여 구하여진 플랜트의 선형입력으로 학습을 수행하고, 비선형부분은 기준 계적과 실제 출력의 오차를 이용해 학습을 수행한다. 제안한 제어방식의 유용성을 입증하기 위하여 제어대상으로 단일 관절 매니퓰레이터를 이용하여 추종제어에 대한 시뮬레이션과 실험을 하여 기존의 다층신경회로망을 이용한 직접제어방식^[9]과 제어 성능을 비교 검토한다.

II. 기존의 다층신경회로망을 이용한 직접 제어방식

단일입력 단일출력(single input single output : SISO)을 갖는 제어대상을 비선형함수 $s(\cdot)$ 를 사용하여 표현하면 식(1)로 된다^[11].

$$y(k+1) = s(y, y(k-1), \dots, y(k-m+1), u(k), u(k-1), \dots, u(k-n+1)) \quad (1)$$

여기서, $u(k)$ 와 $y(k)$ 는 각각 k 번째 샘플링시간에서 제어대상의 입·출력을 나타내고, k 번째의 입력 데이터를 현재의 입력 $u(k)$ 로 취급하고 과거의 입력 데이터 $y(k-1), y(k-2), \dots, y(k-m+1)$ 와 현재의 출력 $y(k)$ 와 과거의 출력 $y(k-1), y(k-2), \dots, y(k-m+1)$ 가 비선형함수 $s(\cdot)$ 의 입력이 되어 한 스텝 앞선 미래의 출력을 낸다. 식 (1)의 비선형 특성을 갖는 제어대상에 다층신경회로망을 이용하여 온라인으로 동작하는 직접 제어기를 설계하기 위하여, 식 (1)을 현재의 입력 $u(k)$ 를 종속변수로 하여 비선형함수 $g(\cdot)$ 로 표현하면 식 (2)로 된다.

$$u(k) = g(y(k+1), y(k), y(k-1), \dots, y(k-m+1), u(k-1), \dots, u(k-n+1)) \quad (2)$$

식 (2)에서 $y(k+1), y(k), y(k-1), \dots, y(k-m+1), u(k-1), \dots, u(k-n+1)$ 의 입·출력 데이터를 이용하여 현재의 입력 $u(k)$ 를 구하려고 할 때 $y(k+1)$ 은 다음 순간의 출력이므로 직접 이용할 수

없고 대신에 미리 설계된 원하는 기준값 $y_d(k+1)$ 로 대체하여 사용한다. 따라서 식 (2)는 식 (3)으로 나타낼 수 있다.

$$u(k) = g(y_d(k+1), y(k), y(k-1), \dots, y(k-m+1), u(k-1), \dots, u(k-n+1)) \quad (3)$$

식 (3)의 비선형함수 g 를 다층신경회로망을 이용하여 학습하고, 그 신경회로망의 출력을 제어기로 사용하여 구성한 전체 제어시스템은 그림 1과 같다.^[9]




그림 1. 다층 신경회로망을 이용한 직접 제어시스템
Fig. 1. A direct control system using multilayer neural networks.

신경회로망의 출력이 직접 제어입력으로 제어대상에 가해지고, 이 입력에 대응한 출력이 제어대상에서 나오면 제어대상의 출력과 원하는 기준입력과 비교되어 이 오차의 지승을 목적함수로 하여 이 목적함수가 최급하강되도록 신경회로망의 연결강도를 조절한다. 이러한 목적으로 사용되는 목적함수는 식 (4)이다.

$$J(k+1) = \frac{1}{2} (y_d(k+1) - y(k+1))^2 \quad (4)$$

신경회로망의 초기 연결강도는 랜덤하게 주어지고, k 번째 샘플링순간에 연결강도 $W(k)$ 가 식 (4)의 목적함수가 $W(k)$ 에 대해 최소화되도록 gradient descent 법을 이용하여 조정한다.

이때 전체 시스템의 출력은 식 (5)로 표현된다

$$u = f(W_1 f(W_0 \Psi + b_0) + b_1) = f(W_1 z + b_1) \\ y = g(u) = g(f(W_1 f(W_0 \Psi + b_0) + b_1)) = g(f(W_1 z + b_1)) \quad (5)$$

식 (5)에서 Ψ 는 $\Psi = [y_d(k+1) \ y(k) \ y(k-1) \ \dots \ u(k) \ u(k-1) \ \dots]$ 로 입력 벡터, u 는 신경회로망의 출력으로 시스템의 입력, z 는 신경회로망의 중간출력, y 는 시스템의 출력으로 시스템의 상태이다.

연결강도 행렬 W_0 , W_1 , 바이어스 벡터 b_0 , b_1 의

변화량은 식 (6), (7), (8), (9)로 계산된다.

$$\Delta W_1 = -\eta \frac{\partial J}{\partial W_1} = \eta(y_r - y) \frac{\partial y}{\partial W_1} = \eta(y_r - y) \cdot \frac{\partial g(f(W_1 z + b_1))}{\partial f(W_1 z + b_1)} \cdot \frac{\partial f(W_1 z + b_1)}{\partial (W_1 z + b_1)} \cdot (f(W_0 \Psi + b_0))^T \quad (6)$$

$$\Delta b_1 = -\eta \frac{\partial J}{\partial b_1} = \eta(y_r - y) \cdot \frac{\partial g(f(W_1 z + b_1))}{\partial f(W_1 z + b_1)} \cdot \frac{\partial f(W_1 z + b_1)}{\partial (W_1 z + b_1)} \quad (7)$$

$$\Delta W_0 = -\eta \frac{\partial J}{\partial W_0} = \left[\left(\eta(y_r - y) \cdot \frac{\partial g(f(W_1 z + b_1))}{\partial f(W_1 z + b_1)} \cdot \frac{\partial f(W_1 z + b_1)}{\partial (W_1 z + b_1)} \right)^T \cdot W_1^T \right] \cdot \frac{\partial f(W_0 \Psi + b_0)}{\partial (W_0 \Psi + b_0)} \cdot \Psi^T \quad (8)$$

$$\Delta b_0 = -\eta \frac{\partial J}{\partial b_0} = \left[\left(\eta(y_r - y) \cdot \frac{\partial g(f(W_1 z + b_1))}{\partial f(W_1 z + b_1)} \cdot \frac{\partial f(W_1 z + b_1)}{\partial (W_1 z + b_1)} \right)^T \cdot W_1^T \right] \cdot \frac{\partial f(W_0 \Psi + b_0)}{\partial (W_0 \Psi + b_0)} \quad (9)$$

식 (6), (7), (8), (9)에서 $\frac{\partial g(f(W_1 z + b_1))}{\partial f(W_1 z + b_1)}$ 는 시스템의 감도 함수이며, 제어대상의 다이내믹 방정식으로부터 직접 계산할 수 있다.

식 (6), (7), (8), (9)를 이용하여 출력층으로부터 입력층으로 오차신호가 역전과 되면서 신경회로망의 연결강도와 바이어스항을 조정하게 되며, 이들은 제어기의 파라미터가 된다.

III. 제안한 신경회로망 직접제어방식

제어대상을 비선형 함수로 표현한 식 (1)은 식 (10)과 같이 선형 부분과 비선형 부분으로 나누어 표현할 수 있다.

$$z(k) = \sum_{i=1}^{m_1} A_i y(k-i) + \sum_{i=1}^{m_2} B_i u(k-i) + b_0 \\ y(k+1) = p(z(k)) \quad (10)$$

식 (10)에서, $u(k)$ 와 $y(k)$ 는 각각 k 번째 샘플링 시간에서 비선형 시스템의 입 출력 벡터, $z(k)$ 는 비선형 시스템의 중간 출력으로 선형 부분에 대한 출력 벡터, A_i , B_i 는 선형 부분의 상수 행렬, b_0 는 바이어스 벡터이고, 함수 $p(\cdot)$ 는 비선형 함수이다.

식 (1)의 비선형 함수 $s(\cdot)$ 가 입력 $u(k)$ 에 대해 역이 존재할 수 있다면, 시스템의 입력은 식 (11)로

표현할 수 있다.

$$w(k) = A_0 y_d(k) + \sum_{i=1}^{n_1} A_{1i} y(k-i) + \sum_{i=1}^{n_2} B_{2i} u(k-i) + b_0 \quad (11)$$

$$u(k) = q(z(k))$$

식 (11)의 선형부분은 입력층과 출력층만 있고 출력층의 뉴런의 함수가 선형 합인 신경회로망으로 표현될 수 있고 비선형 함수 $q(\cdot)$ 는 하나의 은닉층을 갖는 신경회로망으로 표현 될 수 있으므로 식 (11)은 식 (12)가 될 수 있다.

$$w(k) = W_0(k)\Psi(k) + b_0 \quad (12)$$

$$u(k) = f(W_2 f(W_1 w(k) + b_1) + b_2)$$

식 (12)에서 Ψ 는 입력벡터로 $\Psi = [y(k) \ y(k-1) \ \dots \ y(k-n_y) \ u(k) \ u(k-1) \ \dots \ u(k-n_u)]$, W_0 는 선형 부분의 상수 행렬로 신경회로망의 연결강도 행렬, b_0 는 바이어스 벡터, W_1, W_2 는 비선형 부분을 표현하기위한 신경회로망의 연결강도 행렬, b_1, b_2 는 비선형 부분을 표현하기위한 신경회로망의 바이어스 벡터이고, $f(\cdot)$ 는 신경회로망의 뉴런의 함수이다.

식 (12)를 이용하여 제안한 신경회로망 직접제어방식의 블록선도는 그림 2 이다.

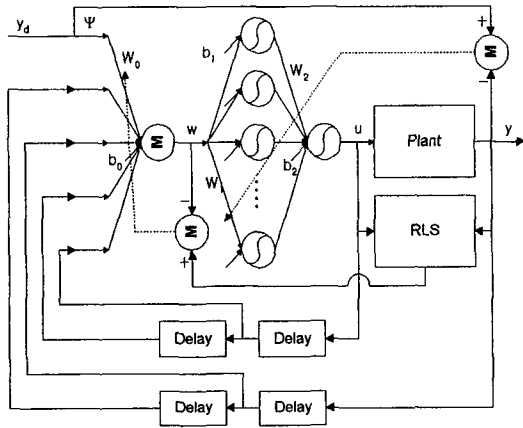


그림 2. 제안한 직접제어방식의 블록선도
Fig. 2. Block diagram of proposed direct control method.

그림 2에서 제어기로 사용된 신경회로망은 전체적으로는 입력층, 2개의 은닉층과 출력층으로 구성된 4층 구조로 되어있고, 이는 다시 선형 부분과 비선형 부분으로 나뉘어져 있다. 비선형 부분을 추정 제어하는 부분은 기준계적과 플랜트의 실제 출력의 오차에 의해

학습을 하고, 선형 부분을 추정 제어하는 부분은 플랜트를 반복최소자승법으로 추정하여 얻어진 선형입력과 신경회로망의 선형부분출력의 오차에 의해 학습을 한다. 선형 부분을 반복최소 자승법으로 추정하여 얻어진 선형입력을 비선형 부분의 입력으로 사용하지 않고 신경회로망의 선형 출력의 학습에 사용한 이유는 반복최소 자승법으로 추정하여 얻어진 선형입력은 시스템이 비선형일 경우 순간적으로 큰 오차가 생길 수 있기 때문에 신경회로망의 선형 출력의 학습을 작게 하여 학습을 시키면 이를 보상할 수 있기 때문이다.

제안한 신경회로망 직접제어방식의 전체적인 수식은 식 (13)과 같다.

$$w(k) = W_0(k)\Psi(k) + b_0$$

$$u(k) = f(W_2 f(W_1 w(k) + b_1) + b_2) \quad (13)$$

$$y(k) = h(u(k))$$

선형 부분의 학습을 위한 목적함수는 식 (14)이고 비선형 부분의 학습을 위한 목적함수는 식 (15)이다.

$$E = \frac{1}{2} (\hat{w} - w)^2 \quad (14)$$

$$E = \frac{1}{2} (y_d - y)^2 \quad (15)$$

식 (14)에서 \hat{w} 는 플랜트의 반복최소자승법의 선형 추정에 의해 구해진 선형입력이다.

선형 부분의 학습에 사용된 신경회로망의 초기 연결강도는 랜덤하게 주어지고, k 번째 샘플링순간에 연결강도 $W(k)$ 는 식 (14)의 목적함수가 $W(k)$ 에 대해 최소가 되도록 gradient descent법을 이용하여 조정한다.

식 (13)에서 선형 부분에 대한 식은 식 (16)이다

$$w(k) = W_0(k)\Psi(k) + b_0 \quad (16)$$

식 (16)에서 Ψ 는 $\Psi = [y_d(k+1) \ y(k) \ y(k-1) \ \dots \ u(k) \ u(k-1) \ \dots]$ 로 신경회로망의 입력, w 는 선형 부분을 추정 제어하는부분의 출력이다.

연결강도 행렬 W_0 , 바이어스 벡터 b_0 의 변화량은 식 (17), (18)으로 계산된다.

$$\Delta W_0 = -\eta \frac{\partial E}{\partial W_0} = \eta (\hat{w} - w) \frac{\partial w}{\partial W_0} = \eta (\hat{w} - w) \cdot \frac{\partial (W_0 \Psi + b_0)}{\partial W_0} = \eta (\hat{w} - w) \cdot \Psi \quad (17)$$

$$\Delta b_0 = -\eta \frac{\partial E}{\partial b_0} = \eta(\hat{w} - w) \frac{\partial w}{\partial b_0} = \eta(\hat{w} - w) \cdot \frac{\partial(\mathbf{W}_0 \Psi + b_0)}{\partial b_0} = \eta(\hat{w} - w) \quad (18)$$

플랜트의 반복최소자승법의 선형추정에 의해 구해진 선형입력 \hat{w} 를 구하기 위해 식 (1)을 식 (19)의 이산 시간 차분모델로 선형화 표현한다.

$$y(k+1) = \hat{a}_0(k)y(k) + \hat{a}_1(k)y(k-1) + \dots + \hat{a}_{n_y}(k)y(k-n_y) + \hat{b}_0(k)u(k) + \hat{b}_1(k)u(k-1) + \dots + \hat{b}_{n_u}(k)u(k-n_u) \quad (19)$$

식 (19)에서 $\hat{a}_0(k), \hat{a}_1(k), \dots, \hat{a}_{n_y}(k), \hat{b}_0(k), \hat{b}_1(k), \dots, \hat{b}_{n_u}(k)$ 는 식 (20)의 반복최소자승법으로 추정된 시스템 파라미터이다.

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \Gamma(k-1)\Phi(k-1) \cdot [y(k) - \hat{\theta}(k-1)^T \Phi(k-1)]$$

$$\Gamma(k) \frac{1}{\lambda_1} = \left[\Gamma(k-1) + \frac{\Gamma(k-1)\Phi(k-1)\Phi(k-1)^T \Gamma(k-1)}{\lambda_2 + \Phi^T(k-1)\Gamma(k-1)\Phi(k-1)} \right]$$

$$(0 < \lambda_1(k) \leq 1 \quad 0 \leq \lambda_2(k) < 2 \quad \Gamma(0) > 0)$$

$$\Phi^T(k-1) = [y(k-1) \quad y(k-2) \dots y(k-n_y) \quad u(k-1) \quad u(k-2) \dots u(k-n_u)] \quad (20)$$

$$\hat{\theta}^T(k) = [\hat{a}_0(k) \quad \hat{a}_1(k) \dots \hat{a}_{n_y}(k) \quad \hat{b}_1(k) \dots \hat{b}_{n_u}(k)]$$

식 (20)에서 $\lambda_1(k)$ 와 $\lambda_2(k)$ 는 반복최소자승법의 추정 속도를 높이기 위한 적응이득 이고, $\Gamma(0)$ 는 반복최소자승법의 추정이득 매트릭스 초기값이다.

식 (20)으로 추정된 파라미터를 식 (21)로 플랜트의 반복최소자승법의 선형추정에 의해 구해진 선형입력 \hat{w} 를 구할 수 있다.

$$\hat{w}(k) = \frac{1}{\hat{b}_0(k)} \cdot [y_d(k+1) - \hat{a}_0(k)y(k) - \hat{a}_1(k)y(k-1) - \dots - \hat{a}_{n_y}(k)y(k-n_y) - \hat{b}_1(k)u(k-1) - \dots - \hat{b}_{n_u}(k)u(k-n_u)] \quad (21)$$

비선형 부분의 학습에 사용된 신경회로망의 초기 연결강도는 랜덤하게 주어지고, k 번째 샘플링순간에 연결강도 $\mathbf{W}(k)$ 는 식 (15)의 목적함수가 $\mathbf{W}(k)$ 에 대해 최소화되도록 gradient descent법을 이용하여 조정한다.

식 (13)에서 비선형 부분에 대한 식은 식 (22)이다

$$u(k) = f(\mathbf{W}_2 f(\mathbf{W}_1 w(k) + b_1) + b_2) \quad (22)$$

$$y(k) = h(u(k))$$

식 (22)에서 w 는 선형 부분을 추정 제어하는부분의 출력으로 비선형 부분을 추정 제어하는 부분의 입

력, u 는 신경회로망의 출력으로 시스템의 입력, y 는 시스템의 출력으로 시스템의 상태이다.

연결강도 행렬 $\mathbf{W}_1, \mathbf{W}_2$ 바이어스 벡터 b_1, b_2 의 변화량은 식 (23), (24), (25), (26)으로 계산된다.

$$\Delta \mathbf{W}_2 = -\eta \frac{\partial E}{\partial \mathbf{W}_2} = \eta(y_r - y) \frac{\partial y}{\partial \mathbf{W}_2} = \eta(y_r - y) \cdot \frac{\partial h(f(\mathbf{W}_2 z + b_2))}{\partial f(\mathbf{W}_2 z + b_2)} \cdot \frac{\partial f(\mathbf{W}_2 z + b_2)}{\partial (\mathbf{W}_2 z + b_2)} \cdot (f(\mathbf{W}_1 w + b_1))^T \quad (23)$$

$$\Delta b_2 = -\eta \frac{\partial E}{\partial b_2} = \eta(y_r - y) \cdot \frac{\partial h(f(\mathbf{W}_2 z + b_2))}{\partial f(\mathbf{W}_2 z + b_2)} \cdot \frac{\partial f(\mathbf{W}_2 z + b_2)}{\partial (\mathbf{W}_2 z + b_2)} \quad (24)$$

$$\Delta \mathbf{W}_1 = -\eta \frac{\partial E}{\partial \mathbf{W}_1} = \left[\left(\eta(y_r - y) \cdot \frac{\partial h(f(\mathbf{W}_2 z + b_2))}{\partial f(\mathbf{W}_2 z + b_2)} \cdot \frac{\partial f(\mathbf{W}_2 z + b_2)}{\partial (\mathbf{W}_2 z + b_2)} \right)^T \cdot \mathbf{W}_2 \right]^T \cdot \frac{\partial f(\mathbf{W}_1 w + b_1)}{\partial (\mathbf{W}_1 w + b_1)} \cdot w^T \quad (25)$$

$$\Delta b_1 = -\eta \frac{\partial E}{\partial b_1} = \left[\left(\eta(y_r - y) \cdot \frac{\partial h(f(\mathbf{W}_2 z + b_2))}{\partial f(\mathbf{W}_2 z + b_2)} \cdot \frac{\partial f(\mathbf{W}_2 z + b_2)}{\partial (\mathbf{W}_2 z + b_2)} \right)^T \cdot \mathbf{W}_2 \right]^T \cdot \frac{\partial f(\mathbf{W}_1 w + b_1)}{\partial (\mathbf{W}_1 w + b_1)} \quad (26)$$

IV. 시뮬레이션

제 III장에서 제안한 제어방식의 유용성을 입증하기 위하여 식 (27)로 표현되는 단일 관절 매니퓰레이터에 대하여 IBM-PC Pentium 상에서 MATLAB언어를 사용하여 시뮬레이션을 한다.

$$m l^2 \ddot{\theta} + B \dot{\theta} + m g l \cos(\theta) = \tau \quad (27)$$


여기서, $\theta, \dot{\theta}, \ddot{\theta}$ 는 각각 매니퓰레이터의 각변위, 각속도, 각가속도를 나타내고, τ 는 매니퓰레이터의 입력력으로서 관절에 가해지는 토크이며, m, l, B, g 는 각각 매니퓰레이터 링크의 질량, 길이, 마찰계수, 중력가속도를 나타내며, 값은 각각 $m=0.1[\text{kg}], l=1[\text{m}], B=0.4[\text{kg} \cdot \text{m}^2/\text{s}], g=9.8[\text{m}/\text{s}^2]$ 이다. 식 (27)은 입력 τ 에 대해 식 (11)과 같이 선형부분 $m l^2 \ddot{\theta} + B \dot{\theta}$ 과 비선형 부분 $m g l \cos(\theta)$ 로 표현되므로 제안한 제어기를 사용할 수 있다. 식 (27)의 시스템에서 $(\theta \quad \dot{\theta})^T = (x_1 \quad x_2)^T$ 로 상태변수를 정의하면 식 (27)은 식 (28)의 비선형 상태공간 모델로 된다.

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= -\frac{g}{l} \cos(x_1) - \frac{B}{m l^2} x_2 + \frac{1}{m l^2} \tau \end{aligned} \quad (28)$$


식 (28)에 대하여 Runge-Kutta fourth order 알고리즘을 이용하고, 5 [ms] 스텝사이즈 간격으로 하여 비선형시스템의 동정과 제어방식에 대하여 기존의 다층신경회로망을 이용한 직접 제어방식과 제안한 방식을 시뮬레이션 하여 제어성능을 비교 검토한다.

1. 기존의 다층신경회로망을 이용한 직접제어 방식

제안한 방식과 기존의 직접제어 방식을 비교 하기 위해 제어 파라미터가 되는 연결강도와 바이어스항의 수를 똑같이 69개로 한다. 그러나 정확하게 맞출 수가 없으므로 신경회로망을 입력 7개, 8개의 뉴런을 갖는 은닉층, 1개의 뉴런을 갖는 단일 출력층으로 구성하여 연결강도와 바이어스항의 수를 72개로 한다. 각 연결강도의 초기값은 [-0.1~0.1] 사이의 랜덤값을 사용하였다. 시스템의 감도 함수 $\frac{\partial y}{\partial u}$ 는 제어대상의 다이 나믹 방정식으로부터 직접 계산하지 않고, 1로 선정하여 학습율에 포함시킨다. 은닉층의 뉴런의 함수는 시그모이드 함수를 사용하고, 출력층의 뉴런의 함수는 선형 함수를 사용하였다. 시그모이드 함수는 식 (29)와 같다. 기준궤적을 식 (30)으로 주고, 초기상태는 위치 0, 속도 0으로 한 경우의 시뮬레이션 결과 학습율이 어떠한 값을 갖더라도 발산을 하여 제어가 불안정하게 됨을 확인하였다. 안정한 제어를 위하여 기존의 직접제어방식의 신경회로망을 입력 7개, 30개의 뉴런을 갖는 은닉층, 1개의 뉴런을 갖는 단일 출력층으로 구성하여 제어기의 파라미터가 되는 연결강도와 바이어스항의 수를 271개로 한다.



(a) 응답곡선



(b) 오차곡선

그림 3. 기존의 직접제어방식

Fig. 3. Tracking characteristics of conventional direct control method.

모든 초기조건과 기준궤적이 위의 경우와 같은 경우 시뮬레이션 결과는 그림 3과 같다. 단 학습율은 시뮬레이션 했을때 결과가 가장 좋은 값인 0.001로 선택하였다.

$$y = f(input) = \left(\frac{2}{1 + e^{(-input)}} - 1 \right) \quad (29)$$

$$y_d = \frac{1}{2} \sin\left(\frac{\pi}{12} t\right) \quad (30)$$

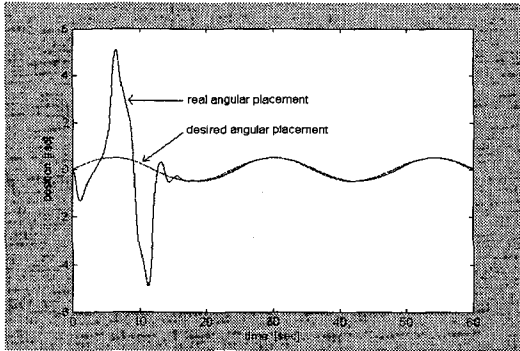
2. 제안한 제어 방식

신경회로망은 입력 7개, 1개와 20개의 뉴런을 갖는 은닉층 2개, 1개의 뉴런을 갖는 단일 출력층으로 구성하여 제어기의 파라미터가 되는 연결강도와 바이어스항의 수를 69개로 한다. 각 연결강도의 초기값은 [-0.1~0.1] 사이의 랜덤값, 반복최소자승법에 사용된 이득 매트릭스 $\Gamma(0)$ 는 $10000 \times I$, 적응이득 $\lambda_1(k)$, $\lambda_2(k)$ 는 1을 사용 하였다.


선형 부분을 추정 제어하는 부분에서의 학습율은 반복최소자승법이 학습되지않은 초기 신경회로망의 출력에 의한 잘못된 추정과 발산을 방지하기위해 0.0001로 낮게 잡고 뉴런의 함수는 선형 함수를 사용한다. 비선형 부분을 추정 제어하는 부분에서의 학습율은 반복최소자승법이 학습되지않은 초기 신경회로망의 출력에 의한 잘못된 추정을 방지하기위해 0.006으로 크게 잡고 뉴런의 함수는 식 (29)의 시그모이드 함수를 사용한다.

기준궤적은 기존의 방식과 같이 식 (30)으로 주고, 초기상태는 위치 0, 속도 0으로 한 경우의 시뮬레이션

결과는 그림 4와 같다.



(a) 응답곡선



(b) 오차곡선

그림 4. 제안한 직접제어방식의 추종 특성
Fig. 4. Tracking characteristics of proposed control method.

제안된 제어방식은 그림 3과 그림 4에서 제어기의 파라미터가 되는 연결강도와 바이어스의 수가 작음에도 15초 이후의 오차가 0.1137로 0.1653인 기존의 방식보다 정상상태오차가 작음을 확인할 수 있었다.

V. 실험 및 검토

시뮬레이션에 의한 결과를 실험상으로 확인하기 위하여 단일 링크 매니퓰레이터에 대하여 제작한 실험장치 블록선도는 그림 5와 같으며, 사양은 표 1과 같다.

그림 5에서 인터페이스 카드는 1개의 8255를 사용하여 8비트 병렬 입출력 포트가 최대 3개, 어드레스 디코딩에 변화를 줄 수 있도록 설계하였다. 전력 증폭기에서 모터 구동시 생길수 있는 노이즈가 전체회로에 전달되는 것을 방지하고 D/A 변환기의 부하를 감소시키기 위하여 D/A 변환기와 전력 증폭기 회로는 포토

커플러로 연결하였다. PWM 방식의 D/A 변환기의 입력펄스 주파수는 4 [MHz], 데이터는 8bit, 변환 전압범위는 0~10 [V], 변환시간은 64 [μs], 정밀도는 39.0625 [mV]로 설계하였다. 모터 구동 전력증폭기 회로는 FET (IRFP064)를 사용하여 설계하였고, 프리휠링 다이오드를 사용하여 역기전력을 방지할 수 있도록 하였다. 매니플레이터의 각변위를 측정하기 위한 센서로는 1회전당 1000 [pulse]의 출력을 갖는 로타리 엔코더를 사용하였다. 이와 같은 실험장치를 제작하였으며 이에 대한 실험장치도에 대한 사진은 그림 6과 같다.

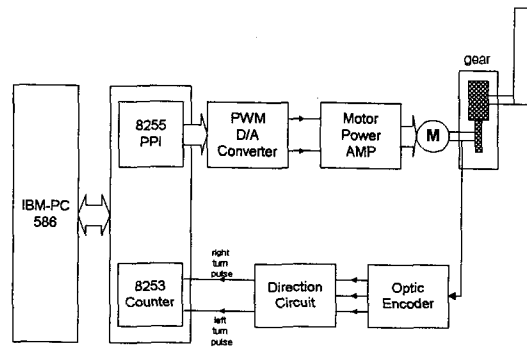


그림 5. 실험장치 블록선도
Fig. 5. Block diagram of the experiment device.

표 1. 제작된 매니퓰레이터의 사양
Table 1. Specification of the fabricated manipulator.


Actuator inertia	J_a	28×10^{-6}	Kg m ²
Back-emf constant of motor	K_b	67×10^{-3}	Kg m ²
Torque constant of motor	K_t	68×10^{-3}	V s rad ⁻¹
Motor static friction torque	B_m	10×10^{-3}	N m
Motor armature resistance	R_a	5.5	Ohms
Motor armature inductance	L_a	7.2×10^{-3}	H
Servo Amp. current limit		2	A
Gear ratio	N	1/30	
Link length	l	0.15	m
Link mass	m	0.1	Kg
Gravity constant	g	9.8	Kg m s ⁻²

그림 6의 제작된 실험장치를 사용하여 표 1의 사양을 갖는 단일 링크 매니퓰레이터를 제어대상으로 제안된 제어방식의 유용성을 확인하기 위해서 추종제어 실험을 하였다.




그림 6. 실험장치사진
Fig. 6. Photograph of experiment device.

기존의 직접제어 방식과 제안한 직접제어 방식의 실험조건을 시뮬레이션과 갖게하여 실험한 결과를 데이터 파일로 저장하여 MS Excel 프로그램을 사용하여 그래프로 나타내면 그림 7과 그림 8이다.



(a) 응답곡선




(b) 오차곡선


그림 7. 기존의 직접제어 방식의 추종특성
Fig. 7. Tracking characteristics of conventional control method.

실험 결과 제어기의 파라미터가 되는 연결강도와 바이어스항의 수를 271개인 입력 7개, 30개의 뉴런을 갖는 은닉층, 1개의 뉴런을 갖는 단일 출력층으로 구

성된 기존의 직접제어방식의 신경회로망보다 제어기의 파라미터가 되는 연결강도와 바이어스항의 수를 69개인 입력 7개, 1개와 20개의 뉴런을 갖는 은닉층 2개, 1개의 뉴런을 갖는 단일 출력층으로 구성된 제안된 제어방식이 전체적으로 약 1/2로 줄어들었음을 확인 할 수 있었다. 또한 제어기의 파라미터가 되는 연결강도와 바이어스항의 수가 약 1/4로 작아져 구성이 간단해 지고, 연산의 횟수가 감소함을 알 수 있었다. 시뮬레이션 결과와 조금 다른 실험결과가 나타난 것은 시뮬레이션상의 제어대상과 실험의 제어대상의 사양이 바뀌었고, 초기상태의 오차의 경우 매니퓰레이터 제작시 사용한 감속기가 초기의 학습이 안된 신경회로망의 출력을 감소시켰기 때문으로 생각된다.



(a) 응답곡선



(b) 오차곡선

그림 8. 제안한 직접제어 방식의 추종특성
Fig. 8. Tracking characteristics of proposed control method.

VI. 결 론

본 논문에서는 비선형 시스템의 직접제어방식을 위한 다층 신경회로망을 제안하였다. 제안한 방식은 신경회로망이 플랜트의 역 모델을 학습하는 방식으로 플

랜트의 사전지식을 시스템의 입출력 정보를 이용하여 추정하고, 플랜트의 역 모델을 선형부분과 비선형 부분의 직렬연결로 구성하고 선형부분과 비선형부분의 모델을 신경회로망을 이용하여 구성된 직접 적응제어 방식이다. 제안한 제어기의 선형부분은 선형 시스템의 시스템동정을 위해 이용되었던 반복최소자승법을 이용하여 구하여진 플랜트의 선형입력으로 학습을 수행하고, 비선형부분은 기준 궤적과 실제 출력의 오차를 이용해 학습을 수행한다. 제안한 제어방식의 유용성을 확인하기 위하여 단일 관절 매니퓰레이터를 이용하여 추종제어에 대한 시뮬레이션과 실험을 하여 기존의 다층신경회로망을 이용한 직접제어방식과 제어성능을 비교 검토한 결과는 다음과 같다.

1) 제어기의 파라미터가 되는 연결강도와 바이어스의 수가 작아 신경회로망의 구성이 간단하다. 2) 연산의 속도가 증가 되었다. 3) 정상상태 오차가 작으므로 정밀성이 좋아졌다.

제안한 제어기는 비선형 시스템이 입력에 대하여 역이 존재하는 시스템에 적용할 수 있다. 이 후의 연구 과제로는 초기의 불안정한 상태를 빨리 줄일 수 있는 알고리즘의 개발과 시스템의 역모델을 정확하고 빨리 추정할 수 있는 뉴런의 함수를 찾는 것이다.

참 고 문 헌

- [1] I.D.Landau, *SYSTEM IDENTIFICATION AND CONTROL DESIGN*, Prentice-Hall, Inc., 1990.
- [2] S.Debowsky and D.T.DesForges, "The Application of Model Referenced Adaptive Control to Robotic Manipulators", *Journal of Dynamic Systems, Measurement, and Control*, vol. 101, pp. 193-200, Sept. 1979.
- [3] A.E.Bryson and Y.C.Ho, *Applied Optimal Control-Optimization, Estimation, and Control*, JOHN WILEY & SONS, INC., 1975.
- [4] Bernard Widrow, Eugene Walach, *ADAPTIVE INVERSE CONTROL*, Printice hall Inc., 1996.
- [5] Madan M. Gupta, Naresh K. Sinha, *Intelligent Control Systems : Theory and Applications*, IEEE PRESS., 1996
- [6] F.C.Chen, "Back-propagation Neural Network for Nonlinear Self-tuning Adaptive Control", *IEEE International Symposium on Intelligent Control* 1989, pp. 274-279. 1989.
- [7] M.Yuan, G.S.Hong and A.N.Poo, "Neural Adaptive Controller : Application to Robot Manipulator", *The Third International Conference on Automation, Robotics and Computer Vision*, pp. 1734-1737, 1994.
- [8] Y. Hirashima, Y. Iiguni and N.Adachi, "An Adaptive Control Method using Neural Network", *SYSTEM制御情報學會論文誌*, vol. 7, no. 8, pp. 281-286, 1994.
- [9] L.Jin, P.N.Nikiforuk and M.M.Gupta, "Direct adaptive output tracking control using multilayered neural networks", *IEEE Proceedings-D*, vol. 140, no. 6, pp. 393-398, Nov., 1993.

저 자 소 개



崔 光 淳(正會員)

1996년 2월 동국대학교 전자공학과 졸업(공학학사). 1998년 2월 동국대학교 전자공학과 대학원 석사과정 졸업(공학석사). 1998년 3월 ~ 현재 동국대학교 전자공학과 대학원 박사과정. 주관심분야는 System Identification, 신경회로망 등임


System Identification, 신경회로망 등임



鄭 盛 夫(正會員)

1979년 2월 동국대학교 전자공학과 졸업(공학학사). 1981년 2월 동국대학교 전자공학과 대학원 석사과정 졸업(공학석사). 1987년 9월 ~ 현재 서일 전문대학교 교수. 1996년 3월 ~ 현재 동국대학교 전자공학과 대학원 박사과정. 주관심분야는 System Identification, 적응제어, 퍼지제어, 신경회로망 등임

System Identification, 적응제어, 퍼지제어, 신경회로망 등임



嚴 基 煥(正會員)

1972년 2월 동국대학교 전자공학과 졸업(공학학사). 1985년 2월 동국대학교 전자공학과 대학원 졸업(공학박사). 1978년 ~ 1994년 2월 유한전문대학교 정교수. 1994년 3월 ~ 현재 동국대학교 전자공학과 부교수. 주관

심분야는 System Identification, 적응제어, 퍼지제어, 신경회로망 등임