

막대부하 시스템의 간접 신경망제어

(Indirect Neuro-control of a Bar Load System)

張俊五*, 全琪準*

(Jun Oh Jang and Gi Joon Jeon)

요 약

본 논문에서는 비선형시스템의 신경망 식별과 신경망제어기 설계방법을 제안한다. 신경망제어기는 선형제어기와 신경회로망으로 구성되며, 신경회로망은 간접 신경망 제어방식에 의해 학습된다. 제안한 제어방식을 IBM 컴퓨터상에 구현하고 직류모터에 의해 구동되는 막대부하 시스템의 속도제어에 적용한다. 신경회로망의 식별능력과 제안한 제어기의 성능을 실험결과로서 살펴보고 기존의 선형제어기와 비교함으로써 제안한 제어기의 우수함을 확인한다.

Abstract

This paper represents identification and control designs using neural networks for a class of nonlinear dynamic systems. A proposed neuro-controller is a combination of a linear controller and a neural network, and is trained by indirect neuro-control scheme. The proposed neuro-controller is implemented and tested on an IBM PC-based bar system, and is applicable to many dc-motor-driven precision servo mechanisms. The ideas, algorithm, and experimental results are described. Experimental results are shown to be superior to those of conventional control.

I. 서 론

비선형 시스템제어에 아직은 일반적으로 적용되는 방법은 없고 단지 부분적으로 적용되는 방법만 있다. 따라서 비선형시스템의 해석 및 제어에 선형 제어이론을 그대로 적용하거나 이의 확장적용이 주종을 이룬다. 최근에 비선형함수를 학습에 의해 표현할 수 있는 다층 신경회로망을 비선형 시스템제어에 응용하는 방법이 등장하였다. 이는 신경회로망에 내재된 뉴런에 의해 병렬분산처리, 비선형 함수의 학습, 환경변화에 대한 적응성을 가능케 함과 적은 비용의 고속 계산용 하드웨어로 구현이 가능하다는 장점으로 인해 비선형 시

스템의 모델링 및 제어에 많은 관심을 불러일으키고 있다. 예를 들면, Kawato 등^[1]은 선형제어기와 오차 제환 학습 신경회로망을 로봇제어에 적용하여 기존 선형제어기 보다 향상된 실험결과를 발표하였고, Lewis 등^[2]은 로봇제어에 향상된 추적성능이 보장되는 신경망 제어방식을 발표하였다. 위와같이 선형제어기와 신경회로망을 병렬로 사용하는 방법은 신경회로망만을 이용하여 제어하는 방법 보다 시스템을 초기에 안정되게 온라인으로 학습시킬 수 있는 장점을 가진다. 그러나 신경회로망을 학습시킬 때 시스템의 자코비안을 필요로하지만 비선형 시스템의 충분한 사전정보 없이는 자코비안을 구하기는 매우 힘들다. 따라서 위의 예^[1, 2]에서는 자코비안에 관한 정보없이 출력오차 정보만을 이용하여 신경회로망을 학습시켰고, Saerens 등^[3]은 신경망 학습시 시스템의 근사적인 자코비안 부호를 이용하였고, Jordan 등^[4]은 신경망모사기(emulator)를 이용하여 off-line으로 시스템을 모사한

* 正會員, 慶北大學校 電子電氣工學部

(School of Electronic and Electrical Eng., Kyungpook Nat'l Univ.)

接受日字: 1997年10月7日, 수정완료일: 1997年12月10日

후에 제어기 학습시 신경망모사기를 오차역전달 통로(channel)로 이용하였다. 그러므로 신경망을 제어기로 사용할 때 시스템 자코비안의 추정치를 용이하게 구하는 방법이 필요하다.

본 연구에서는 비선형 시스템의 신경망제어기와 신경회로망의 학습방법을 제안하고 실험적 적용 예를 살펴본다. 제안한 신경망제어기는 선형제어기와 신경회로망으로 구성되며, 신경회로망의 학습방법은 식별신경망으로 시스템을 off-line으로 사전학습을 한 다음, on-line으로 식별하면서 식별된 정보로서 신경망을 학습시키는 간접 신경망제어(indirect neuro-control)방식이다. 제안된 제어방식의 특징은 병렬로 구성된 제어기에 on-line 간접 신경망 제어방식이다. 실험적 적용 대상은 직류모터에 의해 구동되는 막대부하 시스템(bar load system)이고 제어목적은 동작범위 내에서 원하는 속도신호를 잘 추종하는 것이다. 제안한 제어기의 타당성을 입증하기 위하여 신경회로망의 시스템 식별능력과 제안한 신경망제어기의 성능을 막대부하 시스템에 적용한 실험결과로 살펴보고 기존 선형제어기의 성능과 비교한다. 실험내용은 막대부하 시스템의 단위계단응답과 정현파 기준신호에 대한 응답이고 실험결과에 대한 고찰과 결론 그리고 앞으로의 연구방향이 서술된다.

II. 막대부하 시스템

일반적인 비선형 시스템 $\dot{X}(t) = F_1[X(t), U(t), t]$, $Y(t) = F_2[X(t), U(t), t]$ 의 한 종류인

$$\begin{aligned} G(X(t), \dot{X}(t)) &= U(t) \\ Y(t) &= H(X) \end{aligned} \quad (1)$$

가 있다. 여기서, $X \in R^n$ 는 상태변수, $U \in R^m$ 는 입력, F_1, F_2, G, H 는 비선형함수, Y 는 출력이다. 본 연구에서는 식 (1)과 같은 시스템에 G 와 H 가 비선형일지라도 신경망 식별 및 제어방법을 제안하고 실제적인 시스템을 구축하여 적용하려고 한다.

실제적인 시스템의 한 예로서 그림 1의 직류모터에 의해 구동되는 막대부하 시스템(bar load system)은

$$\begin{aligned} T(t) &= (CA2 + J_m) \ddot{\theta}_2(t) + CO2 \dot{\theta}_2^2(t) + (B_m + B_l) \dot{\theta}_2(t) \\ &+ CT2 + T_{cm} + T_{cl} + T_d + F[\theta_2(t), \dot{\theta}_2(t)] \end{aligned} \quad (2)$$

또는

$$T(t) = \overline{CA2} \ddot{\theta}_2(t) + CO2 \dot{\theta}_2^2(t) + \overline{CT2} + \overline{F}[\theta_2(t), \dot{\theta}_2(t)] \quad (3)$$

로 표현된다. 여기서 $CA2$ 는 관성항, $CO2$ 는 중심력과 코리올리항, B_m 과 B_l 은 점성마찰력, $CT2$ 는 중력을 의미한다. 또한 T 는 모터토크이고 $\overline{F}[\theta_2(t), \dot{\theta}_2(t)]$ 는 마찰력과 외란 그리고 불확실성을 의미한다. T_{cm} 과 T_{cl} 은 모터와 부하에 존재하는 쿨롱마찰력이고 T_d 는 외란이다. 그림 2는 시스템에 존재하는 마찰에 대한 모델로서 정지마찰력, 점성마찰력, 쿨롱마찰력, stick-slip 마찰력 등으로 이루어진다^[5-7]. 시스템 제어의 목적은 $\dot{\theta}_2(t)$ 가 원하는 속도신호 $\dot{\theta}_{2d}(t)$ 를 추종하는 것이다. 시스템의 시변특성으로 θ_2 가 $[0, 2\pi]$ 의 범위에 있을 때 계수 $CA2$ 값이 100% 변화됨을 알 수 있다. 계수 $CO2$ 와 $CT2$ 도 이와 유사하다. 막대부하 시스템의 중요한 특징은 주기적 비선형 시변시스템(periodically time-varying system)으로 속도가 일정한 경우에 주기성을 갖고 있다.




그림 1. 막대부하 시스템
Fig. 1. A bar load system.




그림 2. 마찰모델
Fig. 2. Different friction models.

III. 비선형 시스템의 간접 신경망제어

이 장에서는 비선형 시스템의 속도제어를 위한 신경망 식별과 신경망제어기의 설계에 관한 내용이 기술된다.




그림 3. 제안된 신경망제어기
Fig. 3. A proposed neuro-controller.

그림 3은 제안된 신경망제어기의 구조로서 선형제어기와 신경회로망이 병렬로 구성된다. 시스템의 제어 입력은

$$T(k) = T_1(k) + T_2(k) \tag{4}$$

이다. 여기서 T_1 은 선형제어기의 출력이고 T_2 는 신경회로망(NNC)의 출력이다.




그림 4. 신경회로망의 구조 (a) 제어신경망(NNC) (b) 식별신경망(NNI)
Fig. 4. Structure of the neural network (a) NNC (b) NNI.

NNC는 그림 4(a)와 같은 삼층구조의 신경회로망으

로 입력층, 중간층, 출력층으로 구성된다. NNC의 입력층에서 출력층까지의 노드수는 3-5-1이고 출력은

$$T_2 = \sum_{j=1}^5 [w_{j1}^c \cdot \sigma^c(\sum_{hi=1}^3 v_{hi}^c \cdot x_{hi}^c)] \tag{5}$$

이다. 여기서 $\sigma^c(\cdot)$ 는 hyperbolic tangent 함수, v_{hi}^c 는 입력층에서 중간층 사이의 가중치, w_{j1}^c 는 중간층에서 출력층 사이의 가중치, 첨자 c는 NNC를 의미한다. 시스템의 비선형성분에 의한 성능저하를 보상하기 위한 NNC의 입력은 각속도 오차 ($e = \hat{\theta}_{2d} - \hat{\theta}_2$)와 오차의 적분으로 한다. 또한 마찰에 관한 사전정보는 연기가 용이하지 않을 뿐만 아니라 비선형성을 가지므로 학습에 의해 특성을 알아내는 것이 효과적이다. 마찰에 따른 성능 저하의 한 요소인 콜롱마찰을 보상하기 위하여 NNC의 입력으로 signum 함수를 추가한다. 즉, NNC의 입력은 $x^c = [x_1^c, x_2^c, x_3^c]^T = [e(k), \int e(k), \text{sgn}(\hat{\theta}_2(k))]^T$ 이다.

NNC의 학습방법으로 간접 신경망제어방식을 이용한다^[8]. 간접 신경망제어는 식별신경망(NNI)이 시스템의 입력에 따라 출력이 발생되도록 NNI의 가중치를 수정하는 시스템의 동특성 모사과정과 식별된 정보를 NNC로 역전달시켜 식별된 출력오차 ($\hat{e}_c = \hat{\theta}_{2d} - \hat{\theta}_2$)가 최소가 되게 하는 NNC의 가중치 수정과정으로 이루어진다. NNI를 사용하는 이유는 시스템 자코비안에 관한 정보를 구하기가 어려우므로 NNI를 이용하여 시스템을 모사함으로써 얻어지는 정보 ($\frac{\partial \hat{\theta}_2}{\partial T}$)를 NNC의 학습에 반영하기 위함이다. NNI의 학습은 NNC의 가중치 수정에 필요한 $\frac{\partial \hat{\theta}_2}{\partial T}$ 가 시스템 derivative와 유사하게 하므로, NNC 학습의 좋은 초기조건을 만족시킬려면 NNI가 시스템 모사 능력을 가져야 한다. 시스템의 동특성을 모사하기 위한 과정으로 식 (3)과 같은 시스템이 이산시간 시스템으로 표현 가능하다고 가정하면 시스템의 동특성은 NNI로 나타낼 수 있다^[9]. NNI는 그림 4(b)와 같은 삼층구조의 신경회로망으로 입력층에서 출력층까지의 노드수는 4-5-1이고, 출력은

$$\hat{\theta}_2 = \sum_{m=1}^5 [w_{m1}^i \cdot \sigma^i(\sum_{im=1}^4 v_{im}^i \cdot x_i^i)] \tag{6}$$

이다. 여기서 v_{hi}^i 는 입력층에서 중간층 사이의 가중치,

w_{i1}^i 는 중간층에서 출력층 사이의 가중치, 첨자 i 는 NNI를 의미한다. 시스템을 모사하기위한 NNI의 입력은 시스템의 입력과 출력 그리고 이들의 시간지연항으로 구성할 수 있다^[10]. 따라서 NNI의 입력을 $x^i = [x_1^i, x_2^i, x_3^i, x_4^i]^T = [T(k-1), T(k-2), \hat{\theta}_2(k-1), \hat{\theta}_2(k-2)]^T$ 로 하였다. 즉, 그림 3에서 $Z1(z) = [z^{-1}, z^{-2}, 0, 0]$, $Z2(z) = [0, 0, z^{-1}, z^{-2}]$ 이다. NNI의 가중치 수정을 위한 성능평가함수는

$$E_i(k) = \frac{1}{2} e_i(k)^2 = \frac{1}{2} [\hat{\theta}_2(k) - \widehat{\theta}_2(k)]^2 \quad (7)$$

로 정의한다. 여기서 $e_i(k)$ 는 각속도 $\hat{\theta}_2$ 와 NNI의 출력 $\widehat{\theta}_2$ 과의 차이로서 식별오차라 한다. 성능평가함수를 최소화하기 위하여 NNI의 가중치 수정에 오차역전달 학습알고리즘^[11]을 이용한다. 따라서 NNI의 중간층과 출력층 사이의 가중치 w_{m1}^i 의 학습법칙은

$$\begin{aligned} w_{m1}^i(k+1) &= w_{m1}^i(k) - \eta \cdot \frac{\partial E_i(k)}{\partial w_{m1}^i(k)} \\ &= w_{m1}^i(k) + \eta \cdot \frac{\partial \widehat{\theta}_2(k)}{\partial w_{m1}^i(k)} \cdot e_i(k) \\ &= w_{m1}^i(k) + \eta \cdot \sigma^i \left(\sum_{m=1}^4 v_{im}^i(k) \cdot x_m^i(k) \right) \cdot e_i(k) \end{aligned} \quad (8)$$

이다. 여기서, η 는 학습률이다. 입력층과 중간층 사이의 가중치 v_{im}^i 의 학습법칙은 위와 유사한 방법으로 유도할 수 있다. 즉,

$$\begin{aligned} v_{im}^i(k+1) &= v_{im}^i(k) - \eta \cdot \frac{\partial E_i(k)}{\partial v_{im}^i(k)} \\ &= v_{im}^i(k) + \eta \cdot \frac{\partial \widehat{\theta}_2(k)}{\partial v_{im}^i(k)} \cdot e_i(k) \\ &= v_{im}^i(k) + \eta \cdot x_m^i(k) \cdot \sigma^i \left(\sum_{m=1}^4 v_{im}^i(k) \cdot x_m^i(k) \right) \cdot w_{m1}^i(k) \cdot e_i(k) \end{aligned} \quad (9)$$

이다. 여기서 $\sigma^i(\cdot)$ 는 $\sigma(\cdot)$ 의 시간 미분이다.

NNC의 가중치 수정을 위한 성능평가함수는

$$\widehat{E}_c(k) = \frac{1}{2} \widehat{e}_c(k)^2 = \frac{1}{2} [\hat{\theta}_{2d}(k) - \widehat{\theta}_2(k)]^2 \quad (10)$$

로 정의한다. 여기서 $\widehat{e}_c(k)$ 는 원하는 각속도 $\hat{\theta}_{2d}(k)$ 와 NNI의 출력 $\widehat{\theta}_2(k)$ 과의 차이로 식별된 출력오차로 정의한다. NNC의 입력층과 중간층 사이의 가중치 w_{i1}^c 의 학습법칙은 간접 신경망제어방식에 따라 유도하면

$$\begin{aligned} w_{i1}^c(k+1) &= w_{i1}^c(k) - \eta \cdot \frac{\partial \widehat{E}_c(k)}{\partial w_{i1}^c(k)} \\ &= w_{i1}^c(k) + \eta \cdot \left(\frac{\partial T_2(k)}{\partial w_{i1}^c(k)} + \frac{\partial T_1(k)}{\partial w_{i1}^c(k)} \right) \cdot \frac{\partial \widehat{\theta}_2(k)}{\partial T(k)} \cdot \widehat{e}_c(k) \\ &= w_{i1}^c(k) + \eta \cdot \sigma^c \left(\sum_{h=1}^2 v_{hi}^c(k) \cdot x_h^c(k) \right) \cdot \sum_{m=1}^4 [v_{im}^c(k) \cdot \sigma^i \left(\sum_{m=1}^4 v_{im}^i(k) \cdot x_m^i(k) \right) \cdot w_{m1}^i(k)] \cdot \widehat{e}_c(k) \end{aligned} \quad (11)$$

가 된다. 여기서 $\frac{\partial T_1(k)}{\partial w_{i1}^c(k)} = 0$ 임이 명백하고 $\frac{\partial T_2(k)}{\partial w_{i1}^c(k)} = \sigma^c \left(\sum_{h=1}^2 v_{hi}^c(k) \cdot x_h^c(k) \right)$ 는 식 (5)로 부터 유도할 수 있다.

NNC의 입력층과 출력층 사이의 가중치 v_{hi}^c 의 학습법칙은

$$\begin{aligned} v_{hi}^c(k+1) &= v_{hi}^c(k) - \eta \cdot \frac{\partial \widehat{E}_c(k)}{\partial v_{hi}^c(k)} \\ &= v_{hi}^c(k) + \eta \cdot \frac{\partial T_2(k)}{\partial v_{hi}^c(k)} \cdot \frac{\partial \widehat{\theta}_2(k)}{\partial T(k)} \cdot \widehat{e}_c(k) \\ &= v_{hi}^c(k) + \eta \cdot x_h^c(k) \cdot \sigma^c \left(\sum_{h=1}^2 v_{hi}^c(k) \cdot x_h^c(k) \right) \cdot w_{i1}^c(k) \cdot \sum_{m=1}^4 [v_{im}^i(k) \cdot \sigma^i \left(\sum_{m=1}^4 v_{im}^i(k) \cdot x_m^i(k) \right) \cdot w_{m1}^i(k)] \cdot \widehat{e}_c(k) \end{aligned} \quad (12)$$

이다. NNI와 NNC의 가중치 수정과 제어입력은 한 샘플링 시간내에 계산이 이루어지며 시스템은 실시간 제어된다. 또한, NNI의 off-line 학습이 가능하며 on-line 학습은 플랜트 모사를 더욱 정밀하게 한다. NNC의 학습은 오차역전달 학습 알고리즘에 기반을 두므로 NNC가 학습영역에 있으면 시스템은 안정적으로 동작한다.

IV. 실험 및 고찰

이 장에서는 제안된 신경망제어기를 막대부하 시스템(bar load system)에 적용하여 그 유용성을 확인한다. 그림 5는 막대부하 시스템의 실험장치 구성도로서 막대에 부하가 달린 직류모터, 엔코더와 카운터, Digital-to-Analog (D/A) converter 와 서보증폭기, Interface card가 장착된 컴퓨터로 구성되어 있다. 모터의 각속도는 엔코더와 카운터에 의해 측정된 신호로부터 얻고, 제어입력 신호는 D/A converter와 10V의 전압에 $\pm 0.6A$ 의 전류를 공급하는 서보증폭기를 거쳐 모터로 전송된다. 실험장치의 주요 제어알고리즘은 486DX-66 마이크로 프로세서가 장착된 컴퓨터에 의해 구현되고 시스템의 한 주기 계산시간은 10ms이고 사용된 언어는 C이다.





그림 5. 실험장치
Fig. 5. Experimental setup.


신경망제어기의 한 부분인 선형제어기의 설계가 먼저 이루어져야 하므로, 주파수 응답과 curve fitting을 이용하여 부하가 없는 막대 시스템 ($l_1=0 [cm], l_2=15 [cm]$)의 근사화된 선형모델

$$G(s) = \frac{1}{0.0144s + 0.9149} \quad (13)$$

를 구하였다. 이 식을 이용하여 부하가 달린 시스템 ($l_1=10 [cm], \theta_1=30^\circ, l_2=15 [cm]$)에 성능평가함수 $J = \int_0^\infty [(\hat{\theta}_2(t) - \theta_{2d}(t))^2 + \gamma (\frac{dT}{dt})^2] dt$ 가 최소가 되도록 록 페루프 시스템의 비례-적분(PI)제어기를 설계하였다. 여기서 γ 는 시스템의 단위계단응답에서 서보증폭기가 비포화 영역에서 구동되도록 설정하였고, 성능비교를 위하여 PI 제어기와 신경망제어기의 선형부분이득은 동일($K_p=5, K_I=2.5$)하게 하였다. 그림 6(a)는 속도가 일정 ($\theta_{2d}=1 [rad/sec]$)한 경우의 실험응답이다. θ_2 가 0° 에서 360° 까지 변화하므로 시스템 계수도 달라지고 응답에서도 주기적으로 변하는 특성을 보인다.



(a)



(b)

그림 6. 단위계단응답 ($l_1=10 cm$) (a) PI 제어기 (b) 신경망 제어기
Fig. 6. Experimental results with unit step reference signal (a) by the PI controller and (b) by the neuro-controller.




그림 7. 제어입력 $T(t) = 3.1 + 1.5 \sin(3\pi t) + 2.7 \sin(4\pi t)$ 에 대한 NNI의 식별결과 (NNI 출력 $\hat{\theta}_2$, 각속도 $\dot{\theta}_2$)
Fig. 7. Experimental results of the neural network identification with $T(t) = 3.1 + 1.5 \sin(3\pi t) + 2.7 \sin(4\pi t)$. (output of the NNI $\hat{\theta}_2$, angular velocity $\dot{\theta}_2$)

제안된 신경망제어기를 적용하기 위해서는 NNI의 학습이 먼저 이루어져야 하므로 2 Hz로 변하는 $[-5, 5]$ 범위의 구형파와 정현파로 구성된 제어입력에 대하여 NNI를 학습시켰다. 그림 7은 제어입력 $T(t) = 3.1 + 1.5 \sin(3\pi t) + 2.7 \sin(4\pi t)$ 를 시스템으로 인가할 때 NNI의 식별능력 실험결과이다. 여기서 NNI의 출력 $\hat{\theta}_2$ 은 모터 각속도 $\dot{\theta}_2$ 를 잘 모사함을 볼 수 있다. 이는 NNC 학습의 초기조건이 양호함을 나타낸다. 그림 6(b)는 그림 7과 같이 NNI의 off-line 학습이 된 후에 NNI와 NNC의 on-line 학습 및 제어가 수행되는 과정으로 막대부하 시스템의 단위계단응답이다. 신경망제어기에 의한 응답에서 상승

시간이 PI 제어기 보다 향상되고 진동이 감소되었음을 볼 수 있다. 그림 8(a)는 PI 제어기의 정현파 기준신호에 대한 응답으로 0 [rad/sec] 근방에서 사구간 (deadzone)이 존재함을 볼 수 있다. 이는 비선형마찰력인 쿨롱 마찰력에 의해 나타나는 현상으로 저속구간에서 성능저하의 주요원인이 된다. 신경망 제어기에 의한 응답인 그림 8(b)에서는 학습에 의해 비선형마찰에 의한 영향을 보상함으로 PI 제어기 보다 향상된 성능을 보여준다.

부하가 변하는 경우 ($l_1=10 [cm] \rightarrow l_1=15 [cm]$)의 응답특성을 살펴 보았다. 선형제어기에 의한 응답인 그림 9(a)는 부하가 변하기 전 ($l_1=10 [cm]$)의 성능보다 저하되었음을 보여준다. 이는 부하의 변화로 인해 시스템의 계수가 바뀌어짐을 나타낸다. 그러나 신경망 제어기에 의한 응답인 그림 9(b)에서는 부하가 변하더라도 학습에 의해 부하가 변하기 전의 성능을 유지함을 보여준다. 그림 10은 정현파 기준신호에 대한 응답이다. 제안된 신경망제어기에 의한 응답인 그림 10(b)에서도 비선형 마찰에 의한 영향을 보상하여 PI 제어기 응답인 그림 10(a) 보다 좋은 결과를 나타낸다.

이들의 결과로부터 제안된 제어기는 시변 비선형 시스템에 적용가능하고 기존의 제어기 보다 성능을 개선시킬 수 있음을 알 수 있다. 신경제어방식에서 수렴성과 안정성은 현재까지 명확하게 정의 되어있지 않고 일부 학습에 의해 수렴 가능한 범위에 대하여 언급한 연구결과들만 있을 뿐이다^[2, 12]. 일반적으로 다른 비선형제어이론에서도 이와 유사하므로, 신경망 제어방식은 비선형제어의 하나의 대안으로 간주될 수 있다. 계산전용 신경망 칩의 사용은 신경망 제어방식의 문제점인 계산시간적인 문제를 더욱 해결할 수 있을 것으로 본다.




그림 8. 정현파응답 ($l_1=10 cm$). (a) PI 제어기 (b) 신경망 제어기

Fig. 8. Experimental results with Sinusoidal reference signal ($l_1=10 cm$). (a) by the PI controller and (b) by the neuro-controller.







그림 9. 단위계단응답 ($l_1=15 cm$) (a) PI 제어기 (b) 신경망 제어기

Fig. 9. Experimental results with unit step reference signal ($l_1=15 cm$) (a) by the PI controller and (b) by the neuro-controller.






그림 10. 정현파응답($l_1 = 15 \text{ cm}$) (a) PI 제어기 (b) 신경망 제어기

Fig. 10. Experimental results with sinusoidal reference signal($l_1 = 15 \text{ cm}$) (a) by the PI controller and (b) by the neuro-controller.

V. 결 론

본 연구에서는 비선형 시스템의 신경망식별과 신경망제어기 설계방법을 제안하였다. 제안한 제어기는 선형제어기와 신경회로망으로 구성되며, 신경회로망의 학습방법은 식별신경망(NNI)으로 시스템을 모사한 후에 식별된 정보로서 신경회로망(NNC)을 학습시키는 간접 신경망제어방식이다. 제안한 제어방식의 유용성을 검토하기 위하여 PC를 기반으로 한 막대부하 시스템의 속도제어에 적용하였다. 막대부하 시스템은 주기적이고 비선형적인 특징을 가지므로 선형제어기로서는 만족할만한 성능을 얻기가 어려움을 실제 실험으로 알 수 있었다. 그러나 제안된 신경망제어기를 막대부하 시스템에 적용한 단위계단 응답을 살펴본 결과로서 시스템 계수의 비선형성에 기인하는 성능저하를 학습에 의해 향상시킬 수 있음을 보였고, 정현파 응답에서는 저속구간에서 비선형 마찰에 의한 영향을 보상할 수 있음을 보였다. 또한, 부하가 변하는 경우에 기존 제어기의 성능은 저하되나 신경망 제어기는 학습에 의해 부하가 변하기 전의 성능을 유지시킴을 볼 수 있었다. 이는 신경망제어기의 학습과정으로 간접 신경망제어방식을 이용한 것이 효과적임을 보여주며, 입력의 입력에 대한 신경망 식별결과를 살펴볼 때 신경회로망의 학습능력이 매우 우수함이 이를 뒷받침하고 있다. 앞으로의 연구방향은 단일 입출력시스템의 확장적용 뿐만 아니라 다변수 제어시스템으로의 실제 적용이다.

참 고 문 헌

- [1] M. Kawato, Y. Uno, M. Isobe, and R. Suzuki, "A hierarchical model for voluntary movement and its application to robotics," *IEEE Contr. Syst. Mag.*, vol. 8, no. 4, pp. 8-15, April 1988.
- [2] F. L. Lewis, A. Yesildirek, and K. Liu, "Multilayer neural-net robot controller with guaranteed tracking performance," *IEEE Trans. on Neural Networks*, vol. 7, no. 2, pp. 388-399, March 1996.
- [3] M. Saerens and A. Soquet, "A neural controller," *Proc. ICNN*, pp. 211-215, 1989.
- [4] M. I. Jordan and R. A. Jacobs, "Learning to control an unstable system with forward modeling," in *Advances in neural information processing system*, CA: Morgan Kaufman, vol. 2, pp. 324-331, 1990.
- [5] J. W. Gilbert and G. C. Winston, "Adaptive compensation for an optical tracking telescope," *Automatica*, vol. 10, pp. 125-131, 1974.
- [6] S. C. Southward, C. J. Radcliffe, and C. R. Maccluer, "Robust nonlinear stick-slip friction compensation," *Trans. on ASME*, vol. 113, no. 4, pp. 639-645, 1991.
- [7] C. Canudas, K. J. Astrom, and K. Braun, "Adaptive friction compensation in DC-motor drives," *IEEE J. Robot. Automat.*, vol. RA-3, no. 6, pp. 681-685, Dec. 1987.
- [8] G. J. Jeon and I. S. Lee, "Neural network indirect adaptive control with fast learning algorithm," *Neurocomputing*, vol. 13, no. 3, pp. 185-199, Nov. 1996.
- [9] K. Hornik, M. Stinchcombe, and S. H. White, "Multilayer feedforward networks are universal approximator," *Neural Networks*, vol. 2, pp. 359-366, 1989.
- [10] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. on Neural Networks*, vol. 1, no. 1, pp. 4-27, March 1990.

[11] D. E. Rumelhart, G. E. Hinton, and G. E. Williams, "Learning internal representations by error propagation," in D. E. Rumelhart and J. McClelland (eds.) *Parallel Distributed processing*, Cambridge, MIT Press, vol. 1, ch 8, 1986.

[12] G. A. Rovithakis and M. A. Christodoulou "Adaptive control of unknown plants using dynamical neural networks," *IEEE trans. on System, Man, and Cybernetics*, vol. 24, no. 3, pp. 400-412, march 1994.

저 자 소 개



張 俊 五(正會員)
 1965년 11월 9일생. 1988년 2월
 경북대학교 전자공학과(학사). 1992
 년 2월 경북대학교 대학원 전자공
 학과(석사). 현재 경북대학교 대학
 원 전자공학과 박사과정. 주관심
 분야는 지능제어, 정밀모터제어 등

全 琪 準(正會員) 第 34卷 S編 第 7號 參照
 현재 경북대학교 전자전기공학부
 교수

입