

論文2001-38SC-5-3

비선형 다변수 시스템의 간접신경망제어

(Indirect Neuro-Control of Nonlinear Multivariable Servomechanisms)

張俊五*, 李平基*

(Jun Oh Jang and Pyeong Gi Lee)

요약

본 논문에서는 비선형 다변수 시스템의 신경망 식별과 신경망제어기 설계방법을 제안한다. 신경망제어기는 독립된 여러 개의 선형제어기와 하나의 신경회로망으로 구성되며, 신경회로망은 간접 제어방식에 의해 학습된다. 제안한 제어방식을 IBM 컴퓨터 상에 구현하고 물체를 공유한 막대부하 시스템의 속도제어에 적용한다. 신경회로망의 식별능력과 제안한 제어기의 성능을 실험결과로서 살펴보고 기존의 선형제어기와 비교함으로써 제안한 제어기의 우수함을 확인한다.

Abstract

This paper presents identification and control designs using neural networks for a class of multivariable nonlinear servomechanisms. A proposed neuro-controller is a combination of linear controllers 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 two 2-bar systems holding an object, and is applicable to many dc-motor-driven precision multivariable nonlinear servomechanisms. The ideas, algorithm, and experimental results are described. Moreover, experimental results are shown to be superior to those of conventional control.

I. 서론

통상적으로 제어시스템은 종종 다수의 부 시스템이나 다수의 서보 축으로 구성되는 예가 많다. 예를 들면, 조준경 안정화 시스템^[1] 혹은 CNC 공작기계^[2] 등이다. 이러한 비선형 다변수 시스템에서는 서보축 사이의 상호작용(interaction)과 상호결합(cross-coupling)이 존재하므로 제어가 용이하지 않고, 시스템의 동적 특성이 변할 때에도 안정한 동작특성이 요구되는 경우가 많다. 다변수 시스템을 제어하는 방법으로 선형제어이론을

바탕으로 한 집중제어^[3] 비집중제어^[4] 등이 발표되었으나, 비선형 요소가 존재하거나 이의 영향이 큰 경우에는 제어 성능개선에 한계를 보였다. 이는 시스템 변수 간에 상호 연결을 가지는 경우에 정확한 수학적 모델을 얻기 어렵고, 시스템의 복잡성과 불확실성으로 인하여 기존의 선형제어이론으로는 시스템의 파라미터 변화나 외란에 효과적으로 대처하는 제어법칙도출이 어렵기 때문이다.

최근에 시스템의 모델이 불확실하거나 비선형성이 큰 시스템을 제어하는 새로운 방법으로 퍼지로지과 신경회로망을 이용한 기법이 활발하게 연구되고 있다^[5~6]. 그 중에 신경회로망은 병렬분산처리, 비선형 함수의 학습, 환경변화에 대한 적응성, 적은 비용의 고속 계산용 하드웨어로 구현이 가능하다는 장점으로 인해 비선형 시스템의 모델링 및 제어에 많은 관심을 불러일으키고 있다. 예를 들면, Kawato 등^[7]은 선형제어기와 오차 캐

* 正會員, 威德大學校 컴퓨터制御工學科
(Department of Computer Control Engineering, Uiduk University)

接受日字:2000年3月6日, 수정완료일:2001年6月12日

환 학습 신경회로망을 로봇제어에 적용하여 기존 선형 제어가 보다 향상된 실험결과를 발표하였고, 비선형 다변수 시스템에의 적용 예로, 정 등^[8]은 상호 연결된 다변수 시스템에서 상태공간 모델을 부분적으로 알 수 있는 경우에 편차벡터를 보상하는 신경회로망 조정기와 지역 선형제어기로서 시스템을 제어하는 방법을 제안하였다. Karakasoglu 등^[9]은 다 축 로봇 매니플레이터의 여러 축을 제어하기 위하여 각축을 단일 입출력 시스템으로 나누고 각 시스템을 두 개의 신경회로망으로 인식하여, 인식된 신경회로망을 간접제어기로 사용하였다. 그러나 각 신경회로망의 입력으로 전체시스템의 입출력신호를 사용하므로 지역제어기 상호간의 연결이 복잡하고 지역시스템이 다입력 다출력인 경우에는 적용하기 어렵다. Cui 등^[10]은 상용 PID제어기에 의해 각각 제어되는 두 대의 로봇 매니플레이터가 공동 작업을 할 때 생기는 시스템 상호작용과 시스템 파라미터 변화에 의한 성능저하를 상호 독립된 제어기와 NN-coordinator를 이용하여 시스템의 성능을 향상시키는 방법을 제안하였다. 그러나 NN-coordinator를 학습 시 전체시스템의 입출력 특성을 나타내는 방향성 행렬을 이용함으로써 시스템의 자코비안 정보를 대신하였다. 이와같이 다변수 시스템에 신경회로망을 적용한 예로서 시스템의 방향성 행렬을 사전정보로서 가지거나 상태공간 모델을 부분적으로 알 수 있는 경우에만 적용되는 등 아직은 일반적인 방법은 없다.

본 논문에서는 비선형 다변수 시스템에 적합한 새로운 신경망 제어를 제안한다. 제안한 신경망 제어기는 서로 독립된 여러개의 선형제어기와 한 개의 제어신경망(NNC)으로 구성되며 신경망 제어기의 학습방법은 식별신경망을 이용하여 시스템을 학습한 후에 식별된 정보로서 제어신경망을 학습시키는 간접신경망 제어방식이다. 이는 장 등^[6]이 제안한 단입력 단출력 시스템에 적용한 방식을 비선형 다변수 시스템으로 확장 적용한 것으로 상호 간섭이 일어나는 비선형 다변수 시스템에 적합하게 제안된 제어기이다. 제안한 제어방식의 타당성을 살펴보기 위하여 물체를 공유하는 두 개의 막대부하 시스템에 막대의 속도를 제어하는데 적용한다. 비선형 다변수 시스템의 신경망 식별능력 실험결과와 제안한 제어방식과 기존제어 방식에 의한 속도제어 실험결과를 비교함으로써 제안한 제어방식이 우수함을 입증한다.

II. 물체를 공유하는 두 개의 막대부하 시스템

실제적인 비선형 다변수 시스템의 한 예로서 그림 1 과 같이 물체를 공유하는 두 개의 막대 시스템의 동적 방정식은 막대 시스템의 구조가 동일하다고 가정하면

$$T_j(t) = J\ddot{\theta}_j(t) + C\dot{\theta}_j^2(t) + G + T_c + T_a + F_j[\theta_j(t), \dot{\theta}_j(t)] \quad j=1,2 \quad (1)$$

로 표현된다.^[11] 여기서 J 는 관성항, C 는 중심력과 코리올리항, G 는 중력을 의미한다. 또한 T_j 는 모터토크이고 $F_j[\theta_j(t), \dot{\theta}_j(t)]$ 는 마찰력과 외란 그리고 불확실성을 의미한다. 여기서 불확실성은 공유된 물체의 동적 특성이 막대시스템 상호간에 연결됨을 포함된다. T_c 는 모터와 부하에 존재하는 쿨롱마찰력이고 T_a 는 외란이다,




그림 1. 물체를 공유한 두 개의 막대부하 시스템
Fig. 1. Two 2-bar systems holding an object.




그림 2. 마찰모델
Fig. 2. Friction models.

그림 2는 시스템에 존재하는 마찰에 대한 모델로서 정지마찰력, 점성마찰력, 쿨롱마찰력, stick-slip 마찰력 등으로 이루어진다^[12~14]. 시스템의 두 번째 관절은 고정되어 있고, 첫 번째 관절(θ_1)에 제어입력이 가해진다. 시스템 제어의 목적은 각속도 $\dot{\theta}_j(t)$, $j=1,2$ 가 원하는 속도신호 $\dot{\theta}_{jd}(t)$ 를 추종하는 것이다. 시스템의 시변특성으로 $\theta_j(t)$ 가 $[0, 2\pi]$ 의 범위에 있을 때 계수 J 값이 변화한다.

III. 비선형 다변수 시스템의 간접신경망 제어

이 장에서는 비선형 다변수 시스템의 속도제어를 위한 신경망 식별과 신경망제어기의 설계에 관한 내용이 기술된다. 그림 3은 물체를 공유한 두 개의 막대부하 시스템에 제안된 신경망제어기의 구조로서 각각의 선형제어기와 상호연결된 시스템의 동적 특성의 영향을 보상하기 위한 신경회로망(NNC)이 병렬로 구성된다. 시스템의 제어입력은

$$T_j = T_{j1} + T_{j2}, j=1,2 \quad (2)$$

이다. 여기서 T_{j1} 은 선형제어기의 출력이고 T_{j2} 는 신경회로망(NNC)의 출력이다.

NNC는 그림 4(a)와 같은 삼층구조의 신경회로망으로 각층의 노드수는 4-4-2이다. 출력은

$$T_{j2} = \sum_{q=1}^4 [w_{qj}^c \cdot \sigma^c(\sum_{p=1}^4 v_{pq}^c \cdot x_p^c)], \quad j=1,2 \quad (3)$$

이다. 여기서 $\sigma^c(\cdot)$ 는 hyperbolic tangent 함수, v_{pq}^c 는 입력층에서 중간층 사이의 가중치, w_{qj}^c 는 중간층에서 출력층 노드 j 사이의 가중치, 첨자 c 는 NNC를 의미한다. 두 개의 막대 시스템 사이의 상호작용에 의한 성능저하를 보상하기 위한 NNC의 입력은 $x^c = [x_1^c, x_2^c, x_3^c, x_4^c]^T = [e_1(k), \text{sgn}(\dot{\theta}_1(k)), \text{sgn}(\dot{\theta}_2(k)), e_2(k)]$ 이다. 여기서, $e_j(k) = \dot{\theta}_{jd} - \dot{\theta}_j$, $j=1,2$ 이고, signum 함수 $\text{sgn}(\cdot)$ 은 마찰보상을 위해 사용된다. NNC의 학습방법으로 간접 신경망 제어방식을 이용한다.^[15] 간접 신경망제어는 식별신경망(NNI)이 시스템의 입력에 따라 출력이 발생되도록 NNI의 가중치를 수정하는

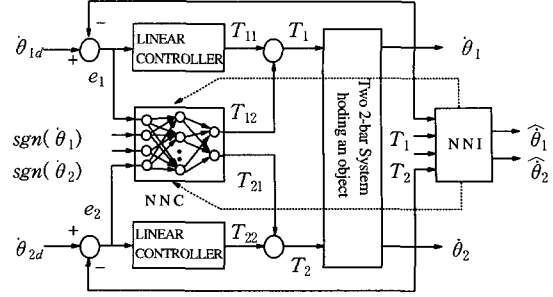


그림 3. 물체를 공유한 막대시스템의 간접신경망제어
Fig. 3. Indirect neuro-control scheme of two 2-bar systems holding an object.

시스템의 동특성 모사과정과 식별된 정보를 NNC로 역전달시켜 식별된 출력오차 $\hat{e}_j^c(k) = \dot{\theta}_{jd} - \hat{\theta}_j$ 가 최소가 되게 하는 NNC의 가중치 수정과정으로 이루어진다. NNI를 사용하는 이유는 신경망 제어기 학습시 필요한 시스템 자코비안에 관한 정보를 구하기가 어려우므로 NNI를 이용하여 시스템을 모사함으로써 얻어지는 정보 ($\frac{\partial \hat{\theta}_j}{\partial T_j}$)를 NNC의 학습에 반영하기 위함이다. NNI의

학습은 NNC의 가중치 수정에 필요한 $\frac{\partial \hat{\theta}_j}{\partial T_j}$ 가 시스템 derivative와 유사하게 하므로, NNC 학습의 좋은 초기 조건을 만족시킬려면 NNI가 시스템 모사능력을 가져야 한다. 시스템의 동특성을 모사하기 위한 과정으로 식(1)과 같은 시스템이 이산시간 시스템으로 표현 가능하다고 가정하면 시스템의 동특성은 NNI로 나타낼 수 있다.^[16] NNI는 그림 4(b)와 같은 삼층구조의 신경회로망으로 노드수는 4-4-2이고, 출력은

$$\hat{\theta}_j = \sum_{m=1}^4 [w_{mj}^i \cdot \sigma^i(\sum_{l=1}^4 v_{lm}^i \cdot x_l^i)] \quad j=1,2 \quad (4)$$

이다. 여기서 v_{lm}^i 는 입력층에서 중간층 사이의 가중치, w_{mj}^i 는 중간층에서 출력층 노드 j 사이의 가중치, 첨자 i 는 NNI를 의미한다. 시스템을 모사하기 위한 NNI의 입력은 시스템의 입력과 출력으로 구성할 수 있다.^[17] 따라서 NNI의 입력을 $x^i = [x_1^i, x_2^i, x_3^i, x_4^i]^T = [\dot{\theta}_1(k-1), T_1(k-1), T_2(k-1), \dot{\theta}_2(k-1)]^T$ 로 하였다. NNI의 가중치 수정을 위한 성능평가함수는

$$E_j^i(k) = \frac{1}{2} e_j^i(k)^2 = \frac{1}{2} [\dot{\theta}_j(k) - \hat{\theta}_j(k)]^2, j=1,2 \quad (5)$$




그림 4. 신경회로망 구조 (a) 제어 신경망(NNC) (b) 식별신경망(NNI)
 Fig. 4. Structure of the neural network (a) NNC (b) NNI.

로 정의한다. 여기서 $e_j^i(k)$ 는 시스템 각속도 $\theta_j(k)$ 와 NNI의 출력 $\hat{\theta}_j$ 와의 차이로서 식별오차라 한다. 성능평가함수를 최소화하기 위하여 NNI의 가중치 수정에 오차역전달 학습알고리즘^[18]을 이용한다. NNI의 중간층과 출력층 사이의 가중치 w_{mj}^i 의 학습법칙은

$$\begin{aligned} w_{mj}^i(k+1) &= w_{mj}^i(k) - \eta \cdot \frac{\partial E_j^i(k)}{\partial w_{mj}^i(k)} \\ &= w_{mj}^i(k) + \eta \cdot \frac{\partial \hat{\theta}_j(k)}{\partial w_{mj}^i(k)} \cdot e_j^i(k) \\ &= w_{mj}^i(k) + \eta \cdot \sigma^i \left(\sum_{l=1}^4 v_{lm}^i(k) \cdot x_l^i(k) \right) \cdot e_j^i(k), \quad j=1,2 \end{aligned} \quad (6)$$

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

$$\begin{aligned} v_{lm}^i(k+1) &= v_{lm}^i(k) - \eta \cdot \frac{\partial E_j^i(k)}{\partial v_{lm}^i(k)} \\ &= v_{lm}^i(k) + \eta \cdot \frac{\partial \hat{\theta}_j(k)}{\partial v_{lm}^i(k)} \cdot e_j^i(k) \\ &= v_{lm}^i(k) + \eta \cdot x_l^i(k) \cdot \sigma^i \left(\sum_{m=1}^4 v_{lm}^i(k) \cdot x_m^i(k) \right) \cdot w_{mj}^i(k) \cdot e_j^i(k), \quad (7) \\ & \quad j=1,2 \end{aligned}$$

이다. 여기서 $\sigma^i(\cdot)$ 는 $\sigma^i(\cdot)$ 의 시간 미분이다. NNC의 가중치 수정을 위한 성능평가함수는

$$\hat{E}_j^c(k) = \frac{1}{2} \hat{e}_j^c(k)^2 = \frac{1}{2} [\theta_{jd}^c(k) - \hat{\theta}_j(k)]^2, \quad j=1,2 \quad (8)$$

로 정의한다. 여기서는 원하는 각속도 $\theta_{jd}(k)$ 와 NNI의 출력 $\hat{\theta}_j(k)$ 와의 차이로 식별된 출력오차로 정의한다. NNC의 입력층과 중간층 사이의 가중치 w_{aj}^c 의 학습법칙은 간접 신경망 제어방식에 따라 유도하면

$$\begin{aligned} w_{aj}^c(k+1) &= w_{aj}^c(k) - \eta \cdot \frac{\partial \hat{E}_j^c(k)}{\partial w_{aj}^c(k)} \\ &= w_{aj}^c(k) + \eta \cdot \left(\frac{\partial T_{j2}(k)}{\partial w_{aj}^c(k)} + \frac{\partial T_{j1}(k)}{\partial w_{aj}^c(k)} \right) \cdot \frac{\partial \hat{\theta}_j(k)}{\partial T_j(k)} \cdot \hat{e}_j^c(k) \\ &= w_{aj}^c(k) + \eta \cdot \sigma^c \left(\sum_{p=1}^4 v_{pa}^c(k) \cdot x_p^c(k) \right) \cdot \sum_{m=1}^3 [v_{j+1m}^i(k) \cdot \sigma^i \left(\sum_{j=1}^2 v_{jm}^i(k) \cdot x_j^i(k) \right) \cdot w_{mj}^i(k)] \cdot \hat{e}_j^c(k), \quad j=1,2 \end{aligned} \quad (9)$$

가 된다. 여기서 $\frac{\partial T_{j1}(k)}{\partial w_{aj}^c(k)} = 0$ 임이 명백하고 $\frac{\partial T_{j2}(k)}{\partial w_{aj}^c(k)} =$

$\sigma^c \left(\sum_{p=1}^4 v_{pa}^c(k) \cdot x_p^c(k) \right)$ 는 식 (3)로 부터 유도할 수 있다.

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

$$\begin{aligned} v_{pa}^c(k+1) &= v_{pa}^c(k) - \eta \cdot \frac{\partial \hat{E}_j^c(k)}{\partial v_{pa}^c(k)} \\ &= v_{pa}^c(k) + \eta \cdot \frac{\partial T_{j2}(k)}{\partial v_{pa}^c(k)} \cdot \frac{\partial \hat{\theta}_j(k)}{\partial T_{j2}(k)} \\ &= \hat{e}_j^c(k) v_{pa}^c(k) + \eta \cdot x_p^c(k) \cdot \sigma^c \left(\sum_{p=1}^4 v_{pa}^c(k) \cdot x_p^c(k) \right) \cdot w_{aj}^c(k) \cdot \sum_{m=1}^3 [v_{j+1m}^i(k) \cdot \sigma^i \left(\sum_{j=1}^2 v_{jm}^i(k) \cdot x_j^i(k) \right) \cdot w_{mj}^i(k)] \cdot \hat{e}_j^c(k), \quad j=1,2 \end{aligned} \quad (10)$$

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

IV. 실험 및 고찰

이 장에서는 제안된 신경망제어기를 비선형 다변수 시스템의 한 예인 물체를 공유하는 막대부하 시스템(bar load system)의 속도제어에 적용하여 제안된 방식의 타당성을 확인한다. 그림 5는 물체를 공유하는 막대부하 시스템의 실험장치 구성도로서 각 막대시스템은 직류모터에 의해 구동되고 각 막대시스템의 양단에 물체가 서로 연결되어 있다. 한편, 각 막대 시스템은 엔코더와 카운터, Digital-to-Analog (D/A) converter와 서보증폭기, Interface card가 장착된 컴퓨터와 연결되어 있다. 각 모터의 각속도는 엔코더와 카운터에 의해 측정된 신호로부터 얻고, 제어입력 신호는 D/A converter와 10V의 전압에 $\pm 0.6A$ 의 전류를 공급하는 서보증폭기를 거쳐 각 모터로 전송된다. 실험장치의 주요 제어알고리즘은 486DX-66 마이크로 프로세서가 장착된 컴퓨터에 의해 구현되고 시스템의 한 주기 계산 시간은 10ms이고 사용된 언어는 C이고 변수는 $m_1 = 0.5 [Kg]$, $m_2 = 0.5 [Kg]$, $m_3 = 1 [Kg]$, $l_1 = 10 [cm]$, $l_2 = 10 [cm]$, $l_3 = 15 [cm]$ 이다.

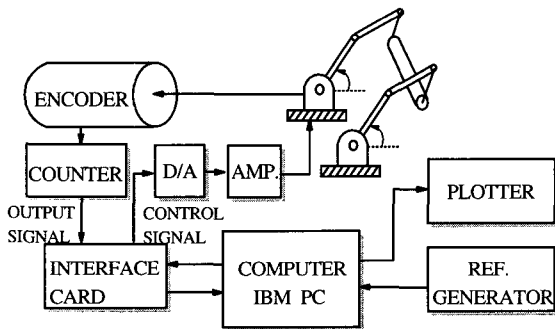


그림 5. 실험장치
Fig. 5. Experimental setup.

제안된 신경망 제어기의 한 부분인 선형제어기의 설계가 먼저 이루어져야 하므로, 주파수 응답과 curve fitting을 이용하여 각 막대 시스템의 근사화 된 선형모델

$$G_1(s) = \frac{1}{0.0144s + 0.9149},$$

$$G_2(s) = \frac{1}{0.0143s + 0.9385} \quad (11)$$

를 구하였다. 이 식을 이용하여 성능평가함수 $J = \int_0^{\infty}$

$[(\hat{\theta}_j(t) - \theta_{j,d}(t))^2 + \gamma(\frac{dT_j}{dt})^2] dt$, $j=1,2$ 가 최소가 되도록 페루프 시스템의 비례-적분(PI)제어기를 설계하였다. 여기서 γ 는 시스템의 단위계단응답에서 서보증폭기가 비포화 영역에서 구동되도록 설정하였고, 성능비교를 위하여 PI 제어기와 신경망 제어기의 선형부분이득은 각각 동일($K_p = 5$, $K_I = 2.5$)하게 하였다. 그림 6은 원하는 속도신호가 구형파이고 물체를 공유하지 않은 경우, 즉 상호작용이 없는 경우의 실험응답이다. 그러나 물체를 공유할 경우의 응답인 그림 7에서 증가된 시스템의 비선형성과 시스템간의 상호작용에 의해 시스템의 성능이 저하되었음을 볼 수 있다. 또한, 성능저하를 보상하기 위한 시스템 모델링과 PI 제어기의 재조정은 쉽지 않다.

제안된 신경망제어기를 적용하기 위해서는 NNI의 학습이 먼저 이루어져야 하므로 2 Hz로 변하는 구형파와 정현파로 구성된 제어입력 $T_j(t) \in [-5, 5]$, $j=1,2$ 에 대하여 NNI를 학습시켰다. 그림 8은 제어입력 $T_j(t) = 1 + 2.5\sin(3\pi t) + 3.5\sin(4\pi t)$ 를 시스템으로 인가할 때 NNI의 식별능력 실험결과이다. 여기서 NNI의 출력 $\hat{\theta}_j$ 는 모터 각속도 $\dot{\theta}_j$ 를 잘 묘사 함을 볼 수 있다. 이는 NNC 학습의 초기조건이 양호함을 나타낸다. 그림 9는 그림 8과 같이 NNI의 off-line 학습이 된 후에 제안된 제어방식의 NNI와 NNC의 on-line 학습 및 제어가 수행되는 과정으로 물체를 공유하는 경우의 막대부하 시스템의 실험응답이다. 신경망 제어기에 의한 응답에서 상승시간이 PI 제어기 결과 보다 향상되고 진동이 감소되었음을 볼 수 있다.

그림 10(a)는 PI 제어기의 정현파 기준신호에 대한 응답으로 0 [rad/sec] 근방에서 사구간(deadzone)이 존재함을 볼 수 있다. 이는 비선형 마찰력인 쿨롱 마찰력에 의해 나타나는 현상으로 저속구간에서 성능저하의 주요원인이 된다. 신경망 제어기에 의한 응답인 그림 10(b)에서는 학습에 의해 비선형 마찰에 의한 영향을 보상함으로써 PI 제어기 보다 향상된 성능을 보여준다. 또한 사구간(deadzone)의 크기($d_1 = 0.36 [sec]$, $d_2 = 0.27 [sec]$)가 다른 것은 공유된 물체가 상호 간섭하여 쿨롱마찰력의 크기를 다르게 하였음이고 제안된 신경망제어기는 간섭작용을 보상하여 시스템의 성

능을 향상시킬 수 있다. 표 1에서 구형파와 사인파 인가시 자승오차의 합을 각각 비교하였다.

이들의 결과로부터 제안된 제어기는 다변수 비선형 시스템에 적용가능하고 기존의 제어기 보다 성능을 개선시킬 수 있음을 알 수 있다. 신경제어방식에서 수렴성과 안정성은 현재까지 명확하게 정의되어 있지 않고 일부 학습에 의해 수렴 가능한 범위에 대하여 언급한 연구결과들이 있다.^[19,20] 일반적으로 다른 비선형 제어 이론에서도 이와 유사하므로, 신경망 제어방식은 비선형 제어의 하나의 대안으로 간주될 수 있다. 계산전용 신경망 칩의 사용은 신경망 제어방식의 문제점인 계산 시간 문제를 더욱 해결할 수 있을 것으로 본다.

표 1. 시스템의 자승오차의 합
Table 1. Sum of square errors of the 2-bar system.

제어기	구형파 기준신호	사인파 기준신호
PI 제어기	191.73(시스템1) 184.80(시스템2)	63.97(시스템1) 53.58(시스템2)
신경망제어기	133.84(시스템1) 146.28(시스템2)	18.56(시스템1) 12.26(시스템2)




그림 6. 물체를 공유하지 않은 경우의 PI 제어기에 의한 각 막대 부하시스템의 실험응답 (구형파 기준신호)

Fig. 6. Experimental results of the 2-bar system j without an object by the PI controller (rectangular reference signal).




그림 7. 물체를 공유한 경우의 PI 제어기에 의한 막대 부하시스템의 실험응답

Fig. 7. Experimental results of the two 2-bar systems holding an object by the PI controller.




그림 8. 제어입력 $T_j(t) = 1 + 2.5\sin(3\pi t) + 3.5\sin(4\pi t)$ 에 대한 NNI의 식별결과 (NNI 출력 $\hat{\theta}_j$, 각속도 $\dot{\theta}_j$)

Fig. 8. Experimental results of the neural network identification with $T_j(t) = 1 + 2.5\sin(3\pi t) + 3.5\sin(4\pi t)$. (output of the NNI $\hat{\theta}_j$, angular velocity $\dot{\theta}_j$)




그림 9. 물체를 공유한 경우의 신경망 제어기에 의한 막대 부하시스템의 실험응답
 Fig. 9. Experimental results of the two 2-bar systems holding an object by the neuro-controller.


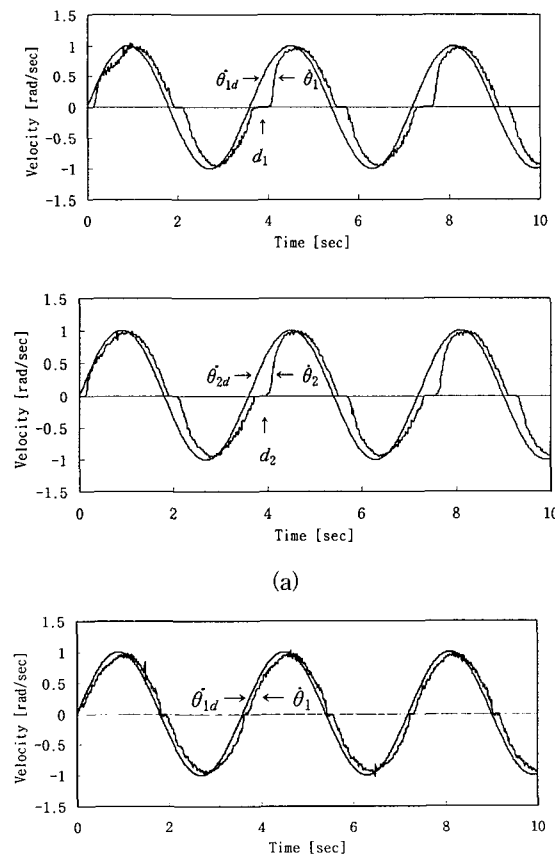


그림 10. 물체를 공유한 경우의 막대부하 시스템의 실험응답(정현파 기준신호) (a) PI 제어기 (b) 신경망 제어기
 Fig. 10. Experimental results of the two 2-bar systems holding an object by the neuro-controller(sinusoidal reference signal). (a) PI controller (b) neuro-controller.

V. 결 론

본 연구에서는 비선형 다변수 시스템의 신경망 식별과 신경망 제어기 설계방법을 제안하였다. 제안한 제어기는 각 지역 시스템을 위한 선형제어기와 하나의 신경회로망으로 구성되며, 신경회로망의 학습방법은 식별신경망(NNI)으로 시스템을 모사한 후에 식별된 정보로서 신경회로망(NNC)을 학습시키는 간접 신경망 제어방식이다. 제안한 제어방식의 유용성을 검토하기 위하여 PC를 기반으로 한 물체를 공유한 막대 부하시스템의 속도제어에 적용하였다. 물체를 공유한 막대 부하시스템은 비선형적이고 시스템간의 상호작용으로 인해 선형제어기로서는 만족할만한 성능을 얻기가 어려움을 실제 실험으로 알 수 있었다. 그러나 제안된 신경망제어기를 물체를 공유한 막대 부하시스템에 적용한 응답을 살펴본 결과로서 시스템 계수의 비선형성과 상호작용으로 인한 성능저하를 학습에 의해 향상시킬 수 있음을 보였고, 정현파 응답에서는 저속구간에서 비선형 마찰에 의한 영향을 보상할 수 있음을 보였다.

성능이 향상된 이유로서 시스템의 비선형성과 상호작용으로 인한 성능저하를 신경망 제어기의 학습에 따른 보상으로 풀이할 수 있다. 또한 신경망제어기(NNC)의 학습방법으로 식별신경회로망의 식별된 정보를 이용하는 간접 신경망 제어방식을 사용한 것이 효과적임을 알 수 있다. 본 연구에서 사용된 예가 물체를 공유한 막대 부하시스템이긴 하지만 실험 그 자체로서 의미를 가진다고 볼 수 있고, 여타의 비선형 다변수 시스템

템으로 확장 적용이 충분히 가능함을 보여 준다. 또한, 본 연구에서의 식별신경망(NNI)의 학습능력 실험결과가 이를 뒷받침하고 있다. 적용대상으로 긴 물체를 운반하는 철강공정 시스템, 항만 하역용 컨테이너 이동 시스템 등에 제안한 알고리즘이 적용 가능하다.

참 고 문 헌

- [1] T. H. Lee, E. K. Koh, and M. K. Loh, "Stable adaptive control of multivariable servomechanisms, with application to a passive line-of-sight Stabilization system," *IEEE Trans. Industrial Electronics*, vol. 43, no. 1, pp. 98-105, Feb. 1996.
- [2] H. Y. Chuang and C. H. Liu, "Techniques in cross-coupled digital adaptive feedrate control for multi axes machine tools," *Control and Dynamic Systems*, vol. 72, pp. 265-301, Sept. 1996.
- [3] D. E. Kirk, *Optimal control theory*, Prentice-Hall, Englewood Cliffs, New Jersey, pp. 184-310, 1970.
- [4] C. J. Mao and W. S. Lin, "decentralized control of interconnected systems with unmodeled nonlinearity and interaction," *Automatica*, vol. 26, no. 2, pp. 263-268, 1990.
- [5] E. H. Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *Int. J. Man-machine Stud.*, vol. 7, pp. 1-13, 1975.
- [6] 장준오, 전기준, "막대부하 시스템의 간접신경망 제어" *대한전자공학회 논문지*, 제 35권, S편, 제1호, pp. 52-59, Jan. 1998
- [7] 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.
- [8] 정희태, 전기준, "신경회로망 조정기를 이용한 비선형 시스템의 비집중제어," *대한전자공학회 논문지*, 제 33권, B편, 제 6호, pp. 208-216, 1996
- [9] A. Karakasoglu, S. I. Sudharsanan, and M. K. Sundareshan, "Identification and decentralized adaptive control using dynamical neural networks with application to robotic manipulator," *IEEE Trans. Neural Networks*, vol. 4, no. 6, pp. 4-27, Nov. 1993.
- [10] X. Cui and K. G. Shin, "Direct Control and Coordination Using Neural Networks," *IEEE Trans. Systems, Man, and Cybernetics*, vol. 23, pp. 686-697, 1993.
- [11] J. J. Craig, *Introduction to Robotics. In Mechanics and Control*. Addison-Wesley, MA 1986.
- [12] J. W. Gilbert and G. C. Winston, "Adaptive compensation for an optical tracking telescope," *Automatica*, vol. 10, pp. 125-131, 1974.
- [13] S. C. Southward, C. J. Radcliffe, and C. R. Maccluer, "Robust nonlinear stick-slip friction compensation," *Trans. ASME*, vol. 113, no. 4, pp. 639-645, 1991.
- [14] 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.
- [15] J. O. Jang and G. J. Jeon, "Implementation of indirect neuro-control for nonlinear dynamic systems," *Mechatronics*, vol. 9, no. 6, pp. 675-686, Sep. 1999.
- [16] K. Hornik, M. Stinchcombe, and S. H. White, "Multilayer feedforward networks are universal approximator," *Neural Networks*, vol. 2, pp. 359-366, 1989.
- [17] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp. 4-27, March 1990.
- [18] 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.

- [19] G. A. Rovithakis and M. A. Christodoulou, "Adaptive control of unknown plants using dynamical neural networks," *IEEE Trans. System, Man, and Cybernetics*, vol. 24, no. 3, pp. 400-412, march 1994.
- [20] F. L. Lewis, A. Yesildirek, and K. Liu, "Multilayer neural-net robot controller with guaranteed tracking performance," *IEEE Trans. Neural Networks*, vol. 7, no. 2, pp. 388-399, March 1996.

저 자 소 개



張俊五(正會員)

1988년 경북대학교 전자공학과 졸업(공학사). 1992년 동 대학원 석사, 1998년 동 대학원 박사. 1999년~현재 위덕대학교 컴퓨터제어공학과 조교수, 학과장. 주관심 분야는 소프트웨어, 퍼지 뉴럴 제어시스템, 마찰

데드존 백리쉬 보상 등임



李平基(正會員)

1986년 경북대학교 전자공학과 졸업(공학사). 1989년 경북대학교 대학원 전자공학과 졸업(공학석사). 1993년 경북대학교 대학원 전자공학과 박사과정 졸업(공학박사). 1996

년~현재 위덕대학교 컴퓨터제어공학과 조교수. 주관심 분야는 퍼지시스템제어, 최적제어, 신경회로망 시스템제어 등임