

신경회로망을 이용한 로보트 매니퓰레이터의 하이브리드 위치/힘 제어기 설계

(Hybrid Position/Force Controller Design of the Robot Manipulator Using Neural Networks)

趙 兇 譚*, 全 洪 兑**, 李 鴻 奇***

(Hyun Chan Cho, Hong Tae Jeon, and Hong Gi Lee)

要 約

고도의 비 선형이며 결합된 동적 특성을 갖는 로보트 매니퓰레이터의 하이브리드(hybrid) 위치/힘 제어는 그 운동특성상 난해한 문제로 인식된다. 특히 정교한 제어를 위한 매니퓰레이터의 동적 매개 변수의 정확한 추정은 이런 어려움을 가중시킨다. 본 논문에서는 역 동력학으로 구성된, 신경회로망을 이용한 새로운 하이브리드 위치/힘 제어기를 제안한다. 제시된 제어기에서는 요구되는 위치, 속도 및 힘 성분들이 신경 회로망에 입력되어 매니퓰레이터에 필요한 토오크를 공급한다. 이때 발생한 오차 토오크를 이용하여 신경 회로망의 가중치를 조절하는 학습이 이루어 진다. 완전한 학습 후에는 오차에 의한 귀환 루프(feedback loop)는 사용되지 않고 오직 최적 상태의 가중치를 갖는 신경 회로망에 의해 매니퓰레이터는 구동된다. 본 논문의 효용성은 3자유도만을 갖는 PUMA 560 매니퓰레이터를 이용한 컴퓨터 시뮬레이션으로 입증되었다.

Abstract

In this paper we propose a hybrid position/force controller of a robot manipulator using feed-back error learning rule and neural networks. The neural network is constructed from inverse dynamics. The weighting value of each neuron is trained by using a feedback force as an error signal.

If the neural networks are sufficiently trained well, it does not require the feedback-loop with error signals. The effectiveness of the proposed hybrid position/force controller is demonstrated by computer simulation using PUMA 560 manipulator.

*正會員, 韓國產業技術大學 電子工學科
(Dept. of Elec. Eng., KIIT)

**正會員, 中央大學校 電子工學科
(Dept. of Elec. Eng., Chungang Univ.)

***正會員, 中央大學校 制御計測工學科
(Dept. of Cont. Inst. Eng., Chungang Univ.)
接受日字: 1990年 9月 15日

(※ 본 연구는 1991년도 한국과학재단 목적기초
연구비 지원으로 수행되었음).

I. 서 론

일반적으로 산업용 로보트(industrial robot)는 생산 제품의 다양화와 작업의 융통성으로 인해 공장자동화(FA)에 있어서 중추적인 역할을 담당하는, 컴퓨터로 프로그래밍 가능한 기계적 시스템으로 인식되고 있다. 보통 이 시스템을 이용한 생산작업은 크게 두가지로 대분된다. 첫번째로는 매니퓰레이터의 핸드(hand)가 공간상에서 궤적을 따라가며 작업을 하

는 경우이고, 두번째로는 핸드가 주변 환경과 접촉하며 작업을 수행하는 경우이다.^{[8][9][10]}

전자의 경우는 단순히 매니퓰레이터의 위치 제어(position control)만으로도 작업 수행이 가능하나, 후자의 경우처럼 매니퓰레이터의 핸드가 외부 환경으로부터 일정치 않은 힘을 받게되는 조립 작업, 베인팅 작업, 표면가공 등과 같은 정밀 작업에서는 위치 제어만이 아닌 힘 제어(force control)까지 동시에 복합적으로 병행되어야 한다.^{[8][10][11]} 따라서 이와같은 매니퓰레이터의 하이브리드(hybrid) 위치/힘 제어는 매니퓰레이터의 제어시 지정된 궤적의 주행에 외부 힘까지 가중된 어려운 문제로 인식된다. 대표적인 연구 결과로는 Mason^[8]과 Raibert^[11]에 의해 제안된 방식들이다. Mason^[8]과 Raibert^[11]는 매니퓰레이터의 핸드가 컴플라이언트(compliant) 운동을 할때 존재하는 제한 조건을 인위적 제한(artifical constraints)과 자연적 제한(natural constraints)으로 분리하여 인위적 제한에 대해서만 하이브리드 위치/힘 제어를 하였다.

그러나 매니퓰레이터의 동적 특성은 고도로 비 선형적으로 결합(highly nonlinear coupled)되어 있으므로 기존의 비적응(nonadaptive) 제어 방식에 의한 제어로는 매니퓰레이터의 동적 특성의 부정확한 수학적 모델링(modelling)과 부하에 따른 특성의 변화등에 높은 강인성(robustness)을 만족치 못하는 등의 문제점들을 갖는다. 또한 적응(adaptive) 제어방식들로서도 이들이 외란(perturbation) 학습 방식들이므로 공식 유도가 복잡하고, 미지의 매개변수 수의 증가에 따라 복잡성(complexity)이 기하학적으로 증가하며, 광범위한 불확실성(uncertainty)에 대해 장인하지 않고 조건적으로만 안정한 문제점들이 있다.^{[1][7]} 최근 이런 문제를 해결하고자 신경 회로망을 이용한 매니퓰레이터의 제어에 관한 연구가 활발히 진행되고 있다.^{[2][3][4][5][6][9][12][13]}

신경 회로망을 이용한 매니퓰레이터의 제어는 역 전파(back-propagation) 회로망^[2], Topology-Conserving Map 방식^[12], Hopfield 회로망^[13], CMAC(cerebellar model articulation control) 방식^[9] 그리고 귀환 오차(feedback-error) 학습법^{[4][5][6]}등 여러가지가 있으나 본 논문에서는 병렬처리 기능을 가지며 온-라인(on line) 처리가 가능하도록 귀환 오차 학습법을 이용한 하이브리드 위치/힘 제어기를 구성한다. 특히 하이브리드 위치/힘 제어에서는 매니퓰레이터 핸드의 움직임이 중요시되므로 기존의 조인트(joint) 공간에서의 귀환 오차 학습법에 의한 신경 회로망으로는 만족스런 핸드의 동적 응답을 얻을 수 없다. 따-

라서 본 논문에서는 기존의 조인트 공간에서의 귀환 오차 학습법을 카르테시안(cartesian) 공간으로 확장시켜 매니퓰레이터의 핸드를 직접 제어할 수 있도록 신경 회로망을 구성한다.

제시된 하이브리드 위치/힘 제어기는 명령단의 카르테시안 위치, 속도 및 힘 성분들이 운동의 실행 시간동안 역 동력학(inverse dynamics)으로 구성된 신경 회로망에 입력되어 요구되는 토크를 공급한다. 이때 발생한 오차 신호로써 신경 회로망의 가중치(weighting value)를 조절하는 학습을 한다. 완전한 학습후 매니퓰레이터는 귀환 루프가 필요치 않는, 매니퓰레이터의 미지의 물리적 매개변수를 동정(identification)한 최적 상태의 가중치를 갖는 신경 회로망에 의해서만 구동된다.

II. 하이브리드 위치/힘 운동의 해석

1. 매니퓰레이터의 동적 특성

매니퓰레이터가 그림1과 같이 작업 환경과 접촉하면서 궤적을 주행하는 하이브리드(hybrid) 위치/힘 운동을 할 경우 그 동적 특성은 매니퓰레이터의 핸드가 카르테시안 궤적을 따라가기 위한 힘/토오크와 외부 힘에 의한 힘/토오크 성분의 합성으로 생각할 수 있다.

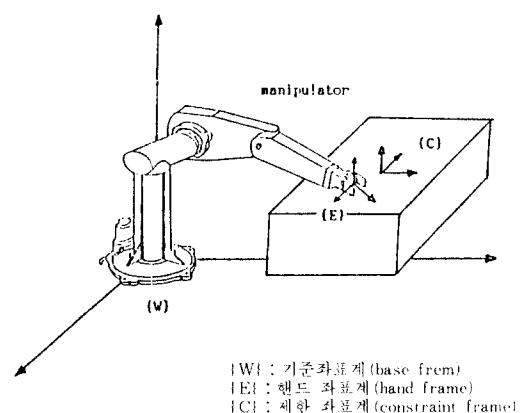


그림 1. 매니퓰레이터의 하이브리드 위치/힘 운동
Fig. 1. Hybrid position/force motion of the manipulator.

그림1에서 보듯이 n -자유도를 갖는 ($n \leq 6$) 매니퓰레이터의 하이브리드 위치/힘 운동은 제한 좌표계(여기서 제한 좌표계라 함은 물체의 표면에 주어진 기하학적 좌표계를 의미함) $\{C\}$ 상에서 실행되며 이 때 $\{C\}$ 에서 요구되는 위치 $X_d^c(t)$ ($\in \mathbb{R}^n$), 속도 $\dot{X}_d^c(t)$

$(\in \mathbb{R}^n)$ 성분은 매니퓰레이터의 조인트 위치 $\theta(t)$ ($\in \mathbb{R}^n$), 속도 $\dot{\theta}(t)$ ($\in \mathbb{R}^n$)와 각각 다음과 같은 관계를 갖는다.

$$\dot{X}_d^c = \mathbf{J}(\theta) \dot{\theta}(t) \quad (2)$$

여기서, $\mathbf{K}(\cdot)$ 는 매니퓰레이터의 조인트 공간에서 제한 좌표계 $\{C_i\}$ 로의 정방향 기구 벡터 방정식이고, $\mathbf{J}(\cdot)$ ($\in \mathbb{R}^{nxn}$)는 자코비안 행렬이다. 한편 제한 좌표계 $\{C_i\}$ 에서 요구되는 위치 및 속도와 힘 / 토크는 상호간에 직교성 (orthogonality)이 있으므로 매니퓰레이터는 다음과 같은 선택 행렬을 이용하여 하이브리드 위치/힘 운동시 위치 제어와 힘 제어를 독립적으로 실행할 수 있다.^[11]

$$\mathbf{S} = \begin{bmatrix} S_1 & 0 & \cdots & 0 \\ 0 & S_2 & 0 & \cdots & 0 \\ 0 & 0 & S_3 & \cdots & 0 \\ \vdots & & & \ddots & \\ 0 & \cdots & 0 & \cdots & S_n \end{bmatrix} \quad (3)$$

상기의 선택 행렬에서 i 번째 요소 S_i ($i=1, 2, \dots, n$)는 각각 힘 제어를 위해서는 1로, 위치 제어를 위해서는 0으로 선택된다. 식(1), (2) 그리고 (3)을 이용해 매니퓰레이터의 하이브리드 위치/힘 운동을 위한 카르테시안 좌표계에서의 동적 방정식은 다음과 같이 구할 수 있다.

$$\mathbf{F}(t) = \mathbf{D}_x(\theta(t))[\mathbf{I} - \mathbf{S}] \cdot \ddot{X}_d^c + \mathbf{C}_x(\theta(t), \dot{\theta}(t)) + \mathbf{G}_x(\theta(t)) \mathbf{S} \cdot \mathbf{F}_d^c(t) \quad (4)$$

여기서, $\mathbf{F}(t)$ ($\in \mathbb{R}^n$)는 하이브리드 위치/힘 제어 운동을 위한 힘/토크 벡터, $\mathbf{D}_x(\theta(t))$ ($\in \mathbb{R}^{nxn}$)는 카르테시안 질량 행렬, $\mathbf{C}_x(\theta(t), \dot{\theta}(t))$ ($\in \mathbb{R}^n$)는 비 선형 코리올리 (Coriolis) 힘과 원심력 벡터, 그리고 $\mathbf{G}_x(\theta(t))$ ($\in \mathbb{R}^n$)는 중력 벡터이다. 또한 $\mathbf{F}_d^c(t)$ ($\in \mathbb{R}^n$)는 제한 좌표계에서 요구되는 힘/토크이다.

식(4)로부터 매니퓰레이터의 하이브리드 위치 / 힘 운동은 제한 좌표계 $\{C_i\}$ 상에서 실행됨을 알 수 있다. 식(4)에 자코비안의 전치 행렬을 이용하면 하이브리드 위치/힘 운동을 위해 매니퓰레이터의 구동기에 인가되는 토크 \mathbf{U} ($\in \mathbb{R}^n$)를 구할 수 있다.

$$\begin{aligned} \mathbf{U}(t) &= \mathbf{J}^T(\theta) \mathbf{F}(t) \\ &= \mathbf{J}^T(\theta) [\mathbf{D}_x(\theta(t))[\mathbf{I} - \mathbf{S}] \cdot \ddot{X}_d^c + \mathbf{C}_{xx}(\theta(t), \dot{\theta}(t)) + \mathbf{G}_x(\theta(t))] + \mathbf{J}^T(\theta) \mathbf{S} \cdot \mathbf{F}_d^c(t) \end{aligned} \quad (5)$$

상기식 우변의 첫번째 항은 매니퓰레이터가 요구되는 궤적을 따라 주행하기 위한 토크이고, 두번쨰 항은 제한 좌표계에서 요구되는 힘/토크를 얻기위

한 조인트 토크이다.

2. 하이브리드 뉴럴 동정기

앞절과 같은 동적 특성을 갖는 매니퓰레이터의 하이브리드 위치/힘 운동을 위해서는 외부 조건의 불확실성에 대하여 강인한 제어기가 설계되어야 한다. 이를 위한 방법은, 매니퓰레이터의 물리적 매개변수의 추정을 위한, 신경 회로망으로 구성된 뉴럴 동정기 (neural identifier)를 이용하는 것이다. 본 논문에서는 다음과 같은 몇 가지 제어 전략 하에 하이브리드 위치/힘 제어를 위한 하이브리드 뉴럴 동정기를 구성한다. (그림2참조)

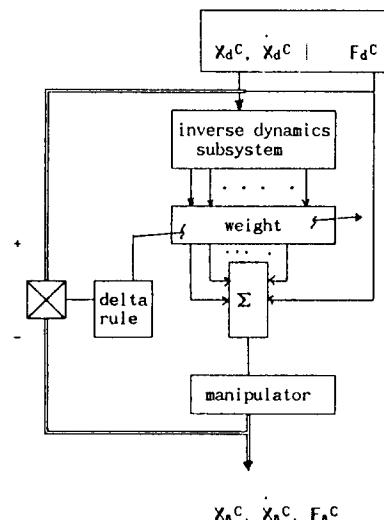


그림 2. 매개변수 추정을 위한 뉴럴 동정기

Fig. 2. Neural identifier for the parameter estimation.

[전략 1] 불확실한 매니퓰레이터의 기계적 매개변수 (링크 질량, 마찰계수 등)의 동정 (identification)을 위한 동정기를 신경 회로망을 이용해 구성한다.

[전략 2] 전략1을 위해 매니퓰레이터의 역 동력학을 병렬처리 가능한 신경 회로망으로 구성하고, 그 가중치들을 매니퓰레이터 매개변수의 추정을 위한 학습 대상 가변 요소로 정의한다.

[전략 3] 가중치의 조절은 델타 규칙 (delta rule)을 이용하여 신경 회로망과 병렬 구성된 귀환루프의 오차 신호로써 조절한다. [5]. 오차

신호는 다음과 같이 정의한다.

$$\mathbf{X}_e^c = \mathbf{X}_d^c = \mathbf{X}_a^c \quad (6a)$$

$$\dot{\mathbf{X}}_e^c = \dot{\mathbf{X}}_d^c = \dot{\mathbf{X}}_a^c \quad (6b)$$

$$\mathbf{F}_e^c = \mathbf{F}_d^c = \mathbf{F}_a^c \quad (6c)$$

여기서, \mathbf{F}_a^c 는 핸드의 센서를 이용해 측정된 \mathbf{F}_a^c 와 변환 행렬 \mathbf{T}_E^c 를 이용해 구한다.

즉,

$$\mathbf{F}_a^c = \mathbf{T}_E^c \cdot \mathbf{F}_a^c \quad (7a)$$

$$\mathbf{T}_E^c = \begin{bmatrix} \mathbf{R}_E^c & 0 \\ \mathbf{P} \times \mathbf{R}_E^c & \mathbf{R}_E^c \end{bmatrix} \quad (7b)$$

이다.

여기서, \mathbf{R}_E^c 는 {E}부터 {C}까지의 방위 행렬이고 \mathbf{P} 는 {C}의 원점부터 {E}의 원점까지의 거리를 {C}에서 표현한 벡터이다. 또한 “ \times ”는 벡터 적(cross product)이다.

III. 하이브리드 위치/힘 제어기의 설계

그림3에서 매니퓰레이터의 3자유도만을 고려했을 경우 제어 순서는 다음 단계로 요약된다.

[단계 1] 명령단의 카르테시안 위치 $\mathbf{X}_d^c(t)$ ($\in R^3$), 속도 $\dot{\mathbf{X}}_d^c(t)$ ($\in R^3$) 및 가속도 $\ddot{\mathbf{X}}_d^c(t)$ ($\in R^3$)들이 선택 행렬 $I - S$ ($\in R^{3 \times 3}$)를 통하여 신경 회로망에 입력된다.

[단계 2] 매니퓰레이터의 동적 특성과 계산 측면을 고려하여 구성된 신경 회로망의 $1+m+n$ 개의 부 시스템(subsystem)들은 이를 입력으로 비 선형 계산 후 각각 3개의 뉴런의 입력 $\mathbf{Y}_1(t)$ ($\in R^1$), $\mathbf{Y}_2(t)$ ($\in R^m$) 및 $\mathbf{Y}_3(t)$ ($\in R^n$)을 출력한다.

[단계 3] 각 뉴런(neuron)은 각각 가중치 $\mathbf{W}_1(t)$ ($\in R^1$), $\mathbf{W}_2(t)$ ($\in R^m$) 그리고, $\mathbf{W}_3(t)$ ($\in R^n$)을 갖고 있으며 i번째 뉴런의 출력 $F_{oi}(t)$ ($i=1, 2, 3$)는 단지 입력 $\mathbf{Y}_i(t)$ 와 가중치 $\mathbf{W}_i(t)$ 의 내적(dot product)으로 식(8)와 같이 얻는다. 이때 $F_{oi}(t)$ 는 매니퓰레이터의 위치 제어를 위한 카르테시안 힘 벡터 $\mathbf{F}_o(t)$ ($\in R^3$)의 i번째 성분이다.

$$F_{oi}(t) = \mathbf{Y}_i(t)^T \mathbf{W}_i(t) = \mathbf{W}_i(t)^T \mathbf{Y}_i(t) \quad (8)$$

for $i=1, 2, 3$.

[단계 4] 단계3의 $\mathbf{F}_o(t)$ 와 제한좌표계에서 요구되는 힘 벡터 $\mathbf{F}_d^c(t)$ ($\in R^3$)로써 매니퓰레이터의 하이브리드 운동을 위한 입력 $\mathbf{F}_i(t)$ ($\in R^3$)

을 다음과 같이 얻는다.

$$\mathbf{F}_i(t) = \mathbf{F}_o(t) + \mathbf{S} \cdot \mathbf{F}_d^c(t) \quad (9)$$

여기서, \mathbf{S} ($\in R^{3 \times 3}$)는 선택 행렬이다.

[단계 5] 제어기의 귀환 힘 $\mathbf{F}_r(t)$ ($\in R^3$)는 채적 오차 $\mathbf{X}_e^c(t)$ 힘 오차 $\mathbf{F}_e^c(t)$ 로부터 다음과 같이 얻는다.

$$\begin{aligned} \mathbf{F}_r(t) &= K_s \mathbf{S} \cdot \mathbf{F}_e^c(t) + K_{Jn} / \mathbf{S} \cdot \mathbf{F}_e^c(t) dt + K_p [I - \mathbf{S}] \\ &\quad \mathbf{X}_e^c(t) \\ &+ K_d [I - \mathbf{S}] \mathbf{X}_e^c(t) + K_i / [I - \mathbf{S}] \cdot \mathbf{X}_e^c(t) dt \\ &= [F_{Jn} \ F_{Jn} \ F_{Jn}]^T \end{aligned} \quad (10)$$

[단계 6] 매니퓰레이터의 구동기에 입력되는 토오크 벡터 $\mathbf{U}(t)$ ($\in R^3$)는 단계4의 식(9)과 단계 5의 식(10)으로부터 자코비안 전치 행렬을 이용하여 식(11)과 같이 얻는다.

$$\mathbf{U}(t) = \mathbf{U}_1(t) + J^T \cdot [\mathbf{F}_i(t) + \mathbf{F}_r(t)] \quad (11)$$

단계6에서 오차항이 zero인 경우, 즉 식(11)에서 $\mathbf{F}_r(t) = 0$ 인 경우 매니퓰레이터는 오직 신경 회로망의 출력 $\mathbf{F}_i(t)$ 에 의해서만 구동된다. 이것은 신경 회로망의 완전한 학습이 이루어 졌음을 의미한다. 이를 위해 신경 회로망의 가중치들은 다음의 학습 법칙에 의해 조절된다.

$$\alpha \frac{dW_{1i}}{dt} = Y_{1i}(\theta_d, \dot{\theta}_d, \ddot{\mathbf{X}}_d^c) X \ F_{Jn} \quad (i=1, 2, \dots, l) \quad (12a)$$

$$\alpha \frac{dW_{2j}}{dt} = Y_{2j}(\theta_d, \dot{\theta}_d, \ddot{\mathbf{X}}_d^c) X \ F_{J2} \quad (j=1, 2, \dots, m) \quad (12b)$$

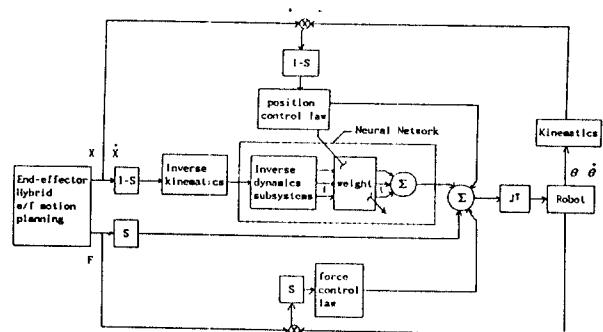


그림 3. 신경 회로망을 이용한 하이브리드 위치/힘 제어기

Fig. 3. Hybrid position/force controller using neural networks.

$$\alpha \frac{dW_{3k}}{dt} = Y_{3k}(\theta_d, \dot{\theta}_d, \ddot{\mathbf{X}}_d^c) X F_{j3} (k=1, 2, \dots, n) \quad (12c)$$

여기서, α 는 시상수이고 Y_{ij} 는 벡터 \mathbf{Y}_i 의 j 번째 성분이다.

상기와 같은 델타 규칙에 의한 학습은 만약 가중치 조절의 시상수가 아주 길다면 가중치가 비선형 시스템에 근사되는 최적치로 수렴한다는 것이 증명되었다.^[5]

IV. 컴퓨터 시뮬레이션

본 논문에서 제안한 하이브리드 위치/힘 제어기는 PUMA 560 매니퓰레이터의 3자유도만을 대상으로 컴퓨터 시뮬레이션을 행하였으며, 대상으로 한 작업 형태는 그림1과 같이 평면으로서 핸드의 좌표계, 제한 좌표계, 그리고 기준 좌표계의 방위는 모두 일치한다고 가정하였다. 이때 세한 좌표계에서 요구되는 궤적은 식(13)과 같이 {C} 상의 X-축과 Y-축으로 주어졌고 힘은 Z-축으로 식(14)와 같이 주어졌다.

$$\mathbf{X}_d^c(t)[m] = \begin{bmatrix} x(t) \\ \sqrt{0.43182 - x(t)} \\ -0.43307 \end{bmatrix} \quad (13a)$$

단, $x(t) = -0.4 + 0.2\lambda$

$$\mathbf{F}_d^c(t)[m/sec] = \frac{d\mathbf{X}_d^c(t)}{dt} \quad (13b)$$

$$\mathbf{F}_d^c[Nm] = [0 \quad 0 \quad -5.0]^T \quad (14)$$

여기서, λ ($0 \leq \lambda \leq 1$)는 정규화된 시간이다.

상기의 요구되는 궤적과 힘을 수행하기 위해 구성된 신경 회로망은 역 동력학의 동정을 위해 3개의 뉴런과 51개의 부 시스템을 갖는다. 가중치의 초기 값은 매니퓰레이터의 물리적 매개변수를 기초로 설정되었으며 51개의 가중치 모두 초기값을 0.1로 하였다. 또한 가중치 변화의 시상수는 $\alpha = 15000$ 으로 하여 학습을 시켰다. 총 학습 횟수는 10000번을 실행하였습니다. 한편 귀환 이득 K_p, K_d, K_i, K_r 및 K_n 는 다음과 같이 설정하였다.

$$K_p = \begin{bmatrix} 200 & 0 & 0 \\ 0 & 1000 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (15a)$$

$$K_d = \begin{bmatrix} 10 & 0 & 0 \\ 0 & 20 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (15b)$$

$$K_i = \begin{bmatrix} 1.0 & 0 & 0 \\ 0 & 1.0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (15c)$$

$$K_r = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.3 \end{bmatrix} \quad (15d)$$

$$K_n = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.8 \end{bmatrix} \quad (15e)$$

그림4와 그림5는 각각 첫번째와 5000번째 학습에서의 위치 오차의 수렴성을 보이고 있다. 이때 5000 번째 학습은 첫번째에 비해 전반적으로 약 10배정도

POSITION ERRORS ON LEARNING TRIAL 1st

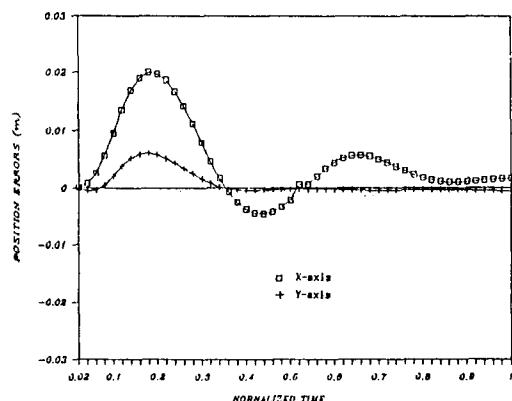


그림 4. 첫번째 학습에서의 위치 오차

Fig. 4. Position errors of the first learning trial.

POSITION ERRORS ON 5000th LEARNING

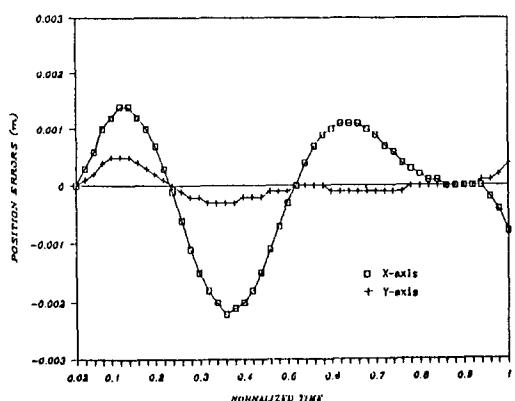


그림 5. 5000번째 학습에서의 위치 오차

Fig. 5. Position errors of the 5000th learning trial.

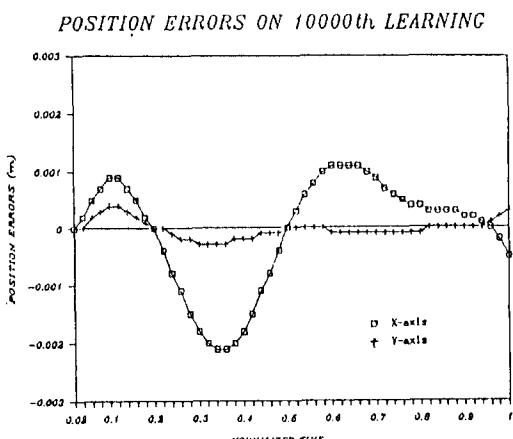


그림 6. 10000번쨰 학습에서의 위치 오차

Fig. 6. Position errors of the 10000th learning trial.

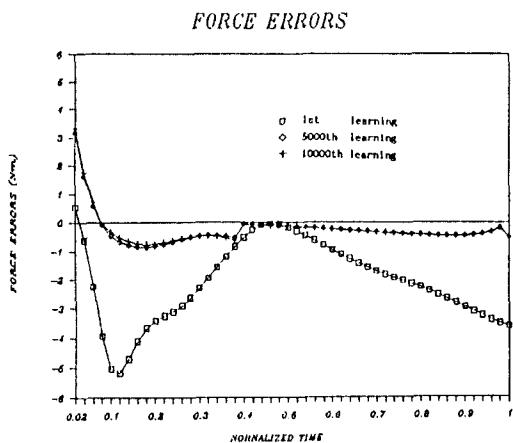


그림 7. 첫번째, 5000번째, 1000번쨰 학습에서의 힘 오차

Fig. 7. Force errors of the 1st, 5000th, and 10000th learning trial, respectively.

오차가 감소하였다. 또한 그림6은 10000번쨰 학습에서의 위치 오차의 수렴 결과이다. 한편 그림7은 첫 번째, 5000번째, 그리고 10000번쨰 학습에서의 힘 오차의 수렴 결과들이다. 그림들에서 보듯이 본 논문에서 제안한 하이브리드 위치/힘 제어기는 학습을 거듭할수록 전 구간에서 오차가 비교적 훌륭히 수렴한다는 것을 알 수 있다.

V. 결 론

본 논문에서 제시된 하이브리드 위치/힘 제어기는 역 동력학과 자코비안 전치 행렬의 비선형 성분들이 부 시스템에 의해 미리 계산되고 뉴런은 단지 이들

을 선형적으로만 결합함으로써 신경 회로망의 학습 시간을 단축시킬 수 있다. 또한 학습이 진행되면서 제어의 주체가 귀환 루트에서 신경 회로망으로 대체되므로 매니퓰레이터와 같은 고도의 비 선형 시스템의 물리적 매개변수의 정확한 추정없이도 하이브리드 위치/힘 제어가 가능하다. 그리고 앞으로는 좀더 빠른 학습 시간을 위한 신경 제어 학습 알고리듬의 개발과 실제 시스템을 위한 경제적 구현 방식등이 이루어져야 할 것이다.

参考文獻

- [1] S. Dubowsky, and D.T. Des Forges, "The application of Model Reference adaptive control to robotic manipulators," *Journal of Dynamic System, Measurement and Control*, vol. 101, pp. 193-200, 1979.
- [2] R.K. Elsley, "A learning architecture for control based on Back-propagation neural network," *Proc. of the IEEE Conf. on Neural Network*, vol. 2, pp. 587-594, 1988.
- [3] G. Josin, D. Charney, and D. White, "Robot control using neural networks," *Proc. of the IEEE Inter. Conf. on Neural Networks*, vol. 2, pp. 169-185, 1988.
- [4] M. Kawato, K. Furukawa, and R. Suzuki, "A hierachical neural network model for control and learning of voluntary movements," *Biox. Cybern.*, vol. 57, pp. 169-185, 1987.
- [5] M. Kawato, Y. Uno, M. Tsobe, and R. Suzuki, "A hierachical neural network model for voluntary movement with application to robotics," *IEEE Control System Magazine*, vol. 8, pp. 8-16, 1988.
- [6] M. Kawato, H. Miyamoto, T. Setoyama, and R. Suzuki, "Feedbackerror learning neural network for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, pp. 251-265, 1988.
- [7] J.Y. S. Luh, M.W. Walker, and R.P. Paul, "Resolved-acceleration, control of mechanical manipulators," *IEEE Trans. Automatic Contr. AC-25*, pp. 468-474, 1980.
- [8] M.T. Mason, "Compliance and force control for computer controlled manipulators," *IEEE Trans. on Systems, Man, and Cybernetics SMC-11*, pp. 418-432, 1981.
- [9] W.T. Miller, E. Glanz, and L.G. Kraft, "Application of general learning algorithm to the control of robotic manipulators,"

- The International Journal of Robotics Research*, pp. 84-98, 1987.
- [10] Richard. P.C. Paul, B. Shimano, "Compliance and control," *Proc. of Joint Automatic Control Conference*, pp. 694-699, 1976.
- [11] M.H Raibert, J.J. Craig, "Hybrid position force control of manipulators," *Journal of Dynamic System, Measurement and Control*, vol. 102, pp. 126-133, 1981.
- [12] H.J. Ritter, T.M. Martinez, and K.J. Schulten, "Topology-Conserving maps for learning visuomotor-coordination," *The First INNS Meeting*, 1988.
- [13] K. Tsutumi and H. Matsumoto, "Neural computation and learning strategy for manipulator position control," *Proc. of the IEEE Int. Conf. on Neural Networks*, vol. 4, pp. 525-534, 1987.

著者紹介



趙鉉讚(正會員)

1960年 11月 20日生. 1983年 광운대 전자공학과 공학사 학위취득. 1985년 중앙대학교 전자공학과 석사학위 취득. 1991년 중앙대학교 전자공학과 박사학위 취득 1991년 9月~현재 한국 산업기술대학 전자공학과 조교수. 주관심분야는 Robocics 및 F. A., Neural Net, Optimal Control 등임.



李鴻奇(正會員)

1958年 11月 28일생. 1981年 2月 서울대학교 전자공학과 졸업 (공학사). 1983年 2月 서울대학교 대학원 전자공학과 졸업 (공학석사). 1986年 8月 Texas대학 박사학위 취득. 1986年 8月~1989年 2月 Louisiana 주립대학 조교수로 근무. 1989年 3月 이후 중앙대학교 제어계측공학과에 현재 부교수로 재직. 주관심분야는 비선형 시스템 제어이론, 로보트 공학 등임.

全洪兒 (正會員) 第26卷 第10號 參照
현재 중앙대학교 전자공학과
부교수