

신경회로망을 이용한 로보트 매니퓰레이터의 Resolved Motion 제어기의 설계

Resolved Motion Control of the Robot Manipulator using Neural Network

宋 文 哲* · 趙 錦 讚** · 李 鴻 奇*** · 全 洪 兑§
 (Moon-Cheol Song · Hyun-Chan Cho · Hong-Gi Lee · Hong-Tae Jeon)

요 약

본 논문에서는 신경 회로망을 이용한 로보트 매니퓰레이터의 resolved motion 제어기를 제안한다. 신경 회로망에 의한 neural identifier는 오차 신호에 의한 feedback 힘/토오크를 이용하여 설계된다. 이 identifier는 시스템의 입·출력 관계로 부터 미지의 비선형 시스템의 출력을 근사화한다. 만약 신경 회로망의 완전한 학습이 이루어지면, 이때는 매니퓰레이터의 완전한 모델링이나 매개변수의 추정이 필요치 않다. 제안된 제어기의 효용성은 2링크 평면 로보트를 사용하여 입증하였다.

Abstract- In this paper we propose the resolved motion controller using a neural network for a robot manipulator. Neural identifier designed by a neural network is trained by using a feedback force as an error signal. The identifier approximates the output of a unknown nonlinear system by monitoring both the input and the output of this system. If the neural network is sufficiently trained well, it does not require either strict modelling of the manipulator or precise parameter estimation. The effectiveness of the proposed controller is demonstrated by computer simulation using a two-link planar robot.

1. 서 론

공장 자동화에 있어서 중추적인 역할을 담당하

는 산업용 매니퓰레이터는 컴퓨터로 제어되는 기계적 시스템이다. 제어의 관점에서 볼 때 로보트 매니퓰레이터는 고도의 비선형적으로 결합된 다변수 시스템(highly nonlinear coupled and multivariable system)이며 그 특성은 시변 비선형 2계 미분 방정식(time-varying nonlinear second-order differential equation)으로 표현된다.

기존의 매니퓰레이터의 제어에 관한 연구들은 크게 전형적인 비적응 제어(non adaptive control)

*正會員：國際電子研究2室勤務

**正會員：中央大 大學院電子工學科 博士課程

***正會員：中央大 工大 制御計測工學科 助教授·工博

§正會員：中央大 工大 電子工學科 助教授·工博

接受日字：1989年 12月 20日

1次修正：1990年 4月 18日

방정식과 적응 제어(adaptive control) 방정식등으로 나누어진다. 전자의 방법들 중 대표적인 것으로 “Computed Torque Method”[12]등을 들 수 있으나 매니퓰레이터의 동력학에 대한 수학적인 모델의 사전 정보와 물리적 매개 변수(physical parameter)의 정확한 추정(precise estimation)을 필요로 하는 문제점이 있다. 후자의 경우에는 “Model Reference Adaptive Control(MRAC)”[4], “Betterment Process”[2], “Table Look up Method”[1]등이 있다. 그러나 이 방식들은 Perturbation-learning 방식들로써 공식 유도가 복잡하고, 미지의 파라미터 수의 증가에 따라 complexity가 기하학적으로 증가하며, 광범위한 uncertainty에 대해 강건하지 않고, 조건적으로만 안정한 문제점들이 있다. 이런 문제를 해결하기 위해 최근 신경 회로망을 이용한 제어에 관한 연구가 활발히 진행되고 있다.[5][6][7][8][13][14]

신경 회로망을 이용한 매니퓰레이터의 제어는 CMAC(cerebellar model articulation controller) 방식, Back propagation 회로망 학습법, 흡필드(Hop-field)회로망 학습법, 그리고 feedback-error 학습법등이 있다. Miller[11]은 매니퓰레이터를 움직일 때마다 가해준 토오크(torque)와 출력의 관계를 이용해 컴퓨터 메모리(memory)에 상호간의 가중치를 저장하는 방식인 CMAC방식을 제안하였다. 그러나 CMAC방식은 환경의 변화에 따라 메모리의 크기가 늘어 난다는 단점을 내포하고 있다. 그리고 Guez[6], Josin[7]과 Sobajic[13]는 역 기구학(inverse kinematics)모델을 얻기 위해 Back propagation 학습법에 의한 신경 회로망을 구성하여 각각 2축과 3축 매니퓰레이터에 적용하였다. 또한 Elsley [5]는 Back propagation 신경 회로망을 이용해 역 자코비안(inverse jacobian)의 모델을 유도하였으며 Tsutumi [14]는 흡필드 신경 회로망을 이용 8축 평면 로보트의 Collision avoidance scheme을 제안하였다. Kawato[8][9][10]는 최근에 feedback-error 학습법을 이용 매니퓰레이터의 역 동력학(inverse-dynamics)모델을 얻는 신경 회로망을 제안하였다. 그러나 이 방법은 조인트 공간(joint space)에서 동적 모델을 얻으므로 비록 각 조인트에서의 동적 응답이 만족스럽다해도 매니퓰레이터 움직임의 실체인 end-effector의 동적 응답과는 무관하다. 이는 Kawato의 방식이 카르테시안 공간(Cartesian space)에서의 효율적인 제어에 어려움이 있음을 의미한다.

본 논문에서는 Kawato가 제시한 feedback-

error 학습법을 직교 좌표계로 확장시켜 매니퓰레이터의 end-effector를 직접 제어할 수 있는 신경 회로망을 제시한다. 즉 매니퓰레이터의 resolved motion control을 위한 신경회로망을 구성하고자 한다. 이때 신경 회로망은 feedback force을 오차 신호로 이용하여 매니퓰레이터의 카르테시안 역 동력학(inverse-dynamics)를 학습한다.

한편, 본 논문의 구성은 다음과 같다. 2장에서는 매니퓰레이터의 resolved motion을 위한 카르테시안 동적 방정식이 유도된다. 3장에서는 neural identifier와 feedback-error 학습법이 설명되고 resolved motion과 결합해 카르테시안 공간상의 제어기가 구성된다. 그리고 제안된 방법의 컴퓨터 모의 실험과 결과가 4장에서 제시되며, 끝으로 5장에서 결론 및 앞으로의 연구 방향을 제시한다.

2. 매니퓰레이터의 카르테시안 운동 방정식

매니퓰레이터가 작업 공간상에 주어진 궤적을 따라 움직이기 위해서는 각 조인트에 있는 모터들에 힘/토오크들을 인가해야 한다. (힘과 토오크는 각각 조인트의 병진운동, 회전 운동을 위한 구동력이다.)

이때 필요한 힘/토오크들을 계산하기 위해서는 매니퓰레이터의 동적 특성이 일련의 수학적인 방정식으로 정식화(formulation)되어야 한다. 일반적으로 Lagrange-Euler, Newton-Euler, recursive Lagrange-Euler, 일반화된 d'Alembert이론 등, 여러 가지 정식화 방법들이 있으나 제어의 관점에서 볼 때 폐-형식으로 구성되어 있는 Lagrange-Euler 형태가 매우 바람직하다.[12] n-자유도를 갖는 매니퓰레이터의 Lagrange-Euler 방정식은 다음과 같다.

$$\tau(t) = \mathbf{D}(\theta(t)) \ddot{\theta}(t) + \mathbf{C}(\theta(t), \dot{\theta}(t)) + \mathbf{G}(\theta(t)) \quad (1)$$

윗 식에서, $\tau(t)(\in R^n)$ 는 조인트에 가해지는 일반화된 토오크 벡터, $\theta(t)(\in R^n)$ 는 매니퓰레이터의 조인트 위치 벡터, $\dot{\theta}(t)(\in R^n)$ 는 조인트 속도 벡터, $\ddot{\theta}(t)(\in R^n)$ 는 조인트 가속도 벡터이다. 그리고 $\mathbf{D}(\theta(t)) (\in R^{n \times n})$ 는 대칭 관성 행렬, $\mathbf{C}(\theta(t), \dot{\theta}(t)) (\in R^n)$ 는 비선형 코리올리스(Coriolis) 힘과 원심력 벡터, $\mathbf{G}(\theta(t))(\in R^n)$ 는 매니퓰레이터에 작용하는 중력 벡터이다.

식(1)은 매니퓰레이터의 궤적 정보(θ , $\dot{\theta}$ 그리고 $\ddot{\theta}$)들로 부터 각 조인트의 입력 힘/토오크를 구

하는 역 동력학 방정식이며 역으로 힘/토오크로부터 발생하는 θ , $\dot{\theta}$ 그리고 $\ddot{\theta}$ 를 구하는 정 동력학(forward dynamics) 방정식은 다음과 같다.

$$\ddot{\theta}(t) = [\mathbf{D}^{-1}(\theta) [\tau(t) - \mathbf{C}(\theta, \dot{\theta}) - \mathbf{G}(\theta)] \quad (2)$$

한편 non-redundant 매니퓰레이터인 경우 기준 좌표계에 대한 매니퓰레이터 hand의 위치 벡터 $\mathbf{P}(t) (\in R^n)$ 과 속도 벡터 $\dot{\mathbf{P}}(t) (\in R^n)$ 은 조인트 변위 벡터 $\theta(t) (\in R^n)$, 조인트 속도 벡터 $\dot{\theta}(t) (\in R^n)$ 과 각각 다음과 같은 관계를 갖는다.

$$\mathbf{P}(t) = \mathbf{K}(\theta(t)) \quad (3)$$

$$\dot{\mathbf{P}}(t) = \mathbf{J}(\theta) \dot{\theta}(t) \quad (4)$$

여기에서 함수 $\mathbf{K}(\cdot)$ 은 비 선형 특성을 갖는 정방향 기구 방정식(forward kinematic equation)이며, $\mathbf{J}(\theta) (\in R^{n \times n})$ 는 자코비안(jacobian) 행렬식이다.

만약 $\mathbf{J}^{-1}(\theta)$ 이 존재한다면 $\dot{\mathbf{P}}(t)$ 와 $\ddot{\theta}(t)$ 로부터 θ , $\dot{\theta}(t)$ 를 다음 식들에 의해 얻을 수 있다.

$$\dot{\theta}(t) = [\mathbf{J}^{-1}(\theta)] \dot{\mathbf{P}}(t) \quad (5)$$

$$\begin{aligned} \ddot{\theta}(t) &= [\mathbf{J}^{-1}(\theta)] \dot{\mathbf{P}}(t) \\ &\quad - [\mathbf{J}^{-1}(\theta)] [\dot{\mathbf{J}}(\theta, \dot{\theta})] [\mathbf{J}^{-1}(\theta)] \dot{\mathbf{P}}(t) \end{aligned} \quad (6)$$

그리고 조인트에 인가되는 힘/토오크 벡터와 end-effector에 작용하는 힘/토오크 벡터 $\mathbf{F} (= [f_{x,y}, f_{z,n_x, n_y, n_z}]^T)$ 는 다음과 같은 자코비안 관계를 갖는다.

$$\tau = \mathbf{J}^T(\theta) \mathbf{F} \quad (7)$$

식(5)와 (6)을 식(1)에 대입하고 식(7)을 이용하면 다음과 같은 카르테시안 동적 방정식을 얻는다.

$$\mathbf{F} = \mathbf{D}_x(\theta) \ddot{\theta} + \mathbf{C}_x(\theta, \dot{\theta}) + \mathbf{G}_x(\theta) \quad (8)$$

$$\mathbf{D}_x(\theta) = \mathbf{J}^{-T}(\theta) \mathbf{D}(\theta) \mathbf{J}^{-1}(\theta)$$

$$\mathbf{C}_x(\theta, \dot{\theta}) = \mathbf{J}^{-T}(\theta) (\mathbf{C}(\theta, \dot{\theta}) - \mathbf{D}(\theta) \mathbf{J}^{-1}(\theta))$$

$$\mathbf{J}(\theta) \dot{\theta}$$

$$\mathbf{G}_x(\theta) = \mathbf{J}^{-1}(\theta) \mathbf{G}(\theta)$$

여기에서 $\mathbf{D}_x(\theta)$ 는 카르테시안 질량 행렬이고 $\mathbf{C}_x(\theta, \dot{\theta})$ 는 카르테시안 속도에 의존하는 항, 그리고 $\mathbf{G}_x(\theta)$ 는 카르테시안 공간 상에서의 중력 벡터이다. 식(8)은 resolved motion 제어에 널리 이용되는 방정식으로 신경망을 구성하는데 이용된다.

3. Resolved Motion Feedback-Error Learning 제어기

3.1 Neural Identifier

임의의 비선형 시스템은 신경 회로망으로 구현시킬 수 있으며, 이 신경 회로망을 미지 시스템의 역 동력학의 identifier로 생각할 수 있다. (그림 1 참조)

그림 1에서 가중치를 갖는 neuron은 미지의 비선형 시스템의 입력 $u(t)$ 와 출력 $z(t)$ 의 관계를 이용하여 neuron의 출력 $y(t)$ 를 $z(t)$ 에 근사시킨다. 그 과정은 비선형 시스템의 입력 $u(t)$ 가 n 개의 subsystem으로 입력되어 n 개의 변수 $x_i(t) (i=1, \dots, n)$ 로 비선형적으로 변환되며, $0|X_i(t)$ 가 neuron의 입력이다. 만약 Wl 을 l 번째 입력에 대한 가중치라고 하면 neuron의 출력 $y(t)$ 는 입력 $x_i(t)$ 와 가중치 w_l 가 곱해진 값의 합으로 다음과 같이 표현된다.

$$\begin{aligned} X(t) &= [x_1(t), x_2(t), \dots, x_n(t)]^T \\ W(t) &= [w_1(t), w_2(t), \dots, w_n(t)]^T \\ y(t) &= W(t)^T X(t) = X(t)^T W(t) \end{aligned} \quad (9)$$

neuron으로의 두 번째 입력은 오차 $s(t)$ 이다. 그리고 오차 $s(t)$ 는 neuron의 출력 $y(t)$ 와 비선형 시스템의 출력 $z(t)$ 사이의 차이로 식(10)과 같이 주어진다.

$$s(t) = z(t) - y(t) \quad (10)$$

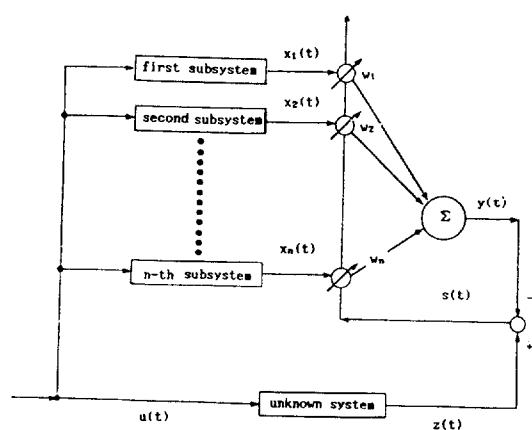


그림 1 비선형 system의 Neural Identifier

Fig. 1 A neural identifier of the nonlinear system

여기서 i 번째 가중치 w_i 은 i 번째 입력 $x_1(t)$ 과 오차 $s(t)$ 의 발생 시에 변화되고 그 변화는 다음과 같다.

$$\alpha \frac{dW_i(t)}{dt} = X(t) s(t) \\ = X(t) [z(t) - X(t)^T W(t)] \quad (11)$$

여기서 a 는 가중치 변화의 시상수 (time constant)이다.

만약 가중치 조절의 시상수가 아주 길다면 가중치가 비선형 시스템에 균사되는 최적치로 수렴한다는 것이 증명되었다.[8] 그리고 식(11)의 평균화된 식은 steepest descent method를 제공하고 수렴이 global해 진다.[8]

3.2 Resolved Motion Feedback-Error Learning 제어기

다면수 비선형 시스템인 매니퓰레이터의 역동력학 관계는 앞서와 같이 신경 회로망으로 구현이 가능하며, 이를 이용해 본 논문에서 제시된 카르테시안 공간상의 Feedback-Error Learning 제어기의 블록도는 그림 2와 같다.

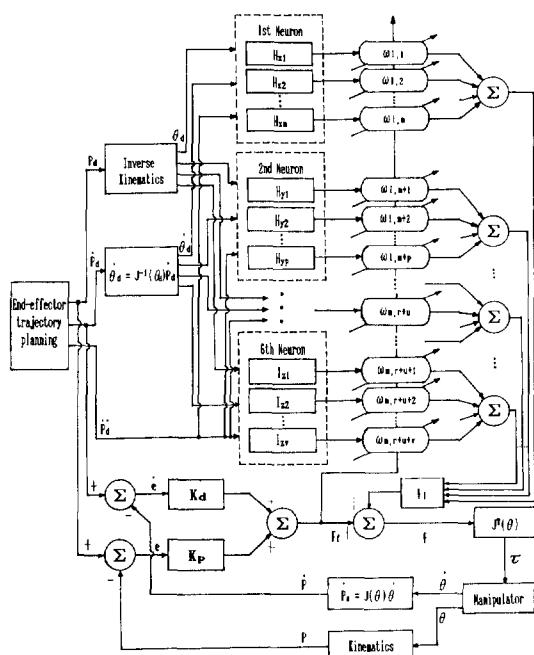


그림 2 Resolved motion의 Feedback-Error learning 제어기

Fig. 2 Feedback-error learning controller of the resolved motion

그림 2의 신경망 회로에서 각 neuron의 subsystem들은 식(8)의 카르테시안 동적 방정식으로부터 운동 특성과 계산 측면을 고려하여 구성된다. 즉, 힘/토오크 벡터 $\mathbf{F} (= [f_x, f_y, f_z, n_x, n_y, n_z]^T)$ 의 성분들 중 선형 힘 벡터 성분 (f_x, f_y, f_z)과 토오크 벡터 성분 (n_x, n_y, n_z)에 관련된 항을 각각 6개의 neuron으로 하고 각 neuron의 계산항들을 세분하여 subsystem으로 구성한다. 따라서 선형 힘 벡터 성분에 관련된 각 neuron은 각각 H_{xi} ($i=1, 2, \dots, m$), H_{yj} ($j=1, 2, \dots, p$), 그리고 H_{zk} ($k=1, 2, \dots, q$)의 subsystem들을 갖는다. 또한 토오크 벡터 성분의 neuron은 각각 I_{xi} ($i=1, 2, \dots, r$), I_{yj} ($j=1, 2, \dots, u$), I_{zk} ($k=1, 2, \dots, v$)의 subsystem들을 갖는다.

각 neuron의 가중치 $W_{i,j}$ ($i=1, 2, \dots, m+p+q$)와 W_{m+j} ($j=1, 2, \dots, r+u+v$) 각각 선형 힘 벡터 성분 (H_{xi}, H_{yj}, H_{zk})과 토오크 성분 (I_{xi}, I_{yj}, I_{zk}) subsystem에 설정되어 불확실한 매니퓰레이터의 기계적 매개변수(링크(link)의 질이, 조인트의 질량, 무게 중심, 마찰 계수 등)들을 learning을 통하여 추정한다. 즉, 가중치들은 신경망 회로가 실제 매니퓰레이터의 동적 특성을 정확하게 모델링하게 하는 학습 대상 가변 요소이다.

한편 자코비안 계산을 통해 매니퓰레이터의 구동기에 입력되는 힘/토오크 벡터 $\mathbf{F}(t)$ 는 다음과 같이 feedback 힘/토오크 벡터 $\mathbf{F}_f(t)$ 와 feed-forward 힘/토오크 벡터 $\mathbf{F}_i(t)$ 의 합으로 얻어진다.

$$\mathbf{F}(t) = \mathbf{F}_i(t) + \mathbf{F}_f(t) \quad (12)$$

여기서 feedforward 힘/토오크 벡터 $\mathbf{F}_i(t)$ 는 유연한 제어에 있어서 필수적이며 신경 회로망의 훈련을 통하여 얻어진다. 그리고 feedback 힘/토오크 벡터 $\mathbf{F}_f(t)$ 는 학습 초기 단계에서 강건한 제어를 하며 계적 오차 $\mathbf{P}_d - \mathbf{P}$ 와 $\dot{\mathbf{P}}_d - \dot{\mathbf{P}}$ 로부터 다음과 같이 유도 된다.

$$\mathbf{F}_f(t) = K_p(\mathbf{P}_d - \mathbf{P}) + K_d(\dot{\mathbf{P}}_d - \dot{\mathbf{P}}) \\ = K_p e + K_d \dot{e} \quad (13)$$

상기식에서 오차항이 zero인 경우, 즉, $\mathbf{F}_f(t) = 0$ 일 경우 매니퓰레이터는 오직 $\mathbf{F}_i(t)$ 에 의해서만 구동된다. 이것은 신경망 회로의 완전한 학습을 의미한다. 이를 위해 신경망 회로의 각 가중치들은 다음의 학습 법칙에 의해 조정된다.

$$\alpha \frac{dW_{i,j}}{dt} = H_{xi}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times f_{fx} \quad (i=1,$$

$$2, \dots, m) \quad (14a)$$

$$a \frac{dW_i}{dt} = H_{iy}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times f_{fy} \quad (j=1,$$

$$2, \dots, p) \quad (14b)$$

$$a \frac{dW_i}{dt} = H_{zk}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times f_{fx} \quad (k=1,$$

$$2, \dots, q) \quad (14c)$$

$$a \frac{dW_i}{dt} = I_{xi}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times n_{fx} \quad (i=1,$$

$$2, \dots, r) \quad (14d)$$

$$a \frac{dW_i}{dt} = I_{yj}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times n_{fy} \quad (j=1,$$

$$2, \dots, u) \quad (14e)$$

$$a \frac{dW_i}{dt} = I_{zk}(\mathbf{P}_d, \dot{\mathbf{P}}_d, \ddot{\mathbf{P}}_d) \times n_{fx} \quad (k=1,$$

$$2, \dots, v) \quad (14f)$$

4. 모의 실험 및 결과

본 논문에서 제안한 카르테시안 좌표계 상의 feed back-error learning 제어기는 표 1과 같은 매개 변수를 갖는 2자유도 평면 매니퓰레이터를 대상으로 컴퓨터 모의 실험을 실행하였다(그림 3 참조). 이때 입력 궤적(trajecory)은 식 (15)와 같이 주어졌다.

$$\mathbf{P}(t) = \mathbf{P}_o + \lambda(\mathbf{P}_f - \mathbf{P}_o) \quad (15a)$$

$$\dot{\mathbf{P}}(t) = \frac{d\mathbf{P}(t)}{dt} \quad (15b)$$

여기서 λ ($0 \leq \lambda \leq 1$)는 normalized time 값이며 \mathbf{P}_o 와 \mathbf{P}_f 는 각각 카르테시안 공간상에서 매니퓰레이터 경로의 출발점과 도착점을 나타낸다.

본 논문에서는 출발점과 도착점을 다음과 같이 설정하였다.

$$\mathbf{P}_o = \begin{bmatrix} 0.1 \\ 0.1 \end{bmatrix} \quad \mathbf{P}_f = \begin{bmatrix} 0.4 \\ 0.4 \end{bmatrix} \quad (16)$$

그림 3의 매니퓰레이터의 카르테시안 동적 방정식은 다음과 같이 얻어진다.

$$\begin{aligned} \mathbf{F} = & \begin{bmatrix} M_2 + M_1/S_2^2 & 0 \\ 0 & M_2 \end{bmatrix} \begin{bmatrix} \ddot{P}_x \\ \ddot{P}_y \end{bmatrix} \\ & + \begin{bmatrix} -(M_2 L_1 C_2 + M_2 L_2) \dot{\theta}_1^2 - M_2 L_2 \dot{\theta}_2^2 - \\ (2M_2 L_2 + M_2 L_1 C_2 + M_1 L_1 C_2/S_2^2) \dot{\theta}_1^2 \dot{\theta}_2^2 \\ M_2 L_1 S_2 \dot{\theta}_1^2 + L_1 M_2 S_2 \dot{\theta}_1 \dot{\theta}_2 \end{bmatrix} \\ & + \begin{bmatrix} M_1 g C_1/S_2 + M_2 g S_{12} \\ M_2 g C_{12} \end{bmatrix} \quad (17) \end{aligned}$$

여기에서 S_i ($i=1, 2$), C_j ($j=1, 2$), S_{12} , 그리

표 1 동적 방정식의 매개 변수

Table 1 Parameters of dynamic equation

	Mass(kg)	Length(m)
link 1	$M_1 = 0.5$	$L_1 = 0.5$
link 2	$M_2 = 0.5$	$L_2 = 0.5$

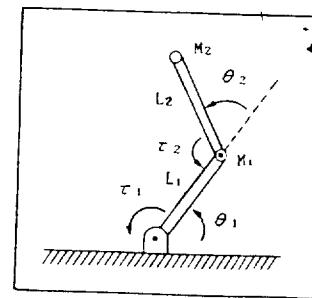


그림 3 2 자유도 평면 로보트 매니퓰레이터

Fig. 3 Two degree of freedom planar manipulator

고 C_{12} 는 각각 $\sin\theta_i$ ($i=1, 2$), $\cos\theta_j$ ($j=1, 2$), $\sin(\theta_1 + \theta_2)$ 및 $\cos(\theta_1 + \theta_2)$ 를 의미한다. 그리고 g 는 중력 상수이다.

상기식으로부터 2자유도 평면 매니퓰레이터의 신경 회로망의 subsystem을 표 2와 같이 구성할 수 있다.

표 2에서 보듯이 2자유도 평면 매니퓰레이터의 neuron의 갯수는 2개이고, 첫 번째와 두 번째 neuron의 subsystem들의 갯수는 각각 10개와 4개이다. subsystem H_{x1} , H_{x2} 및 H_{y1} 은 관성에 관련된 성분이고, subsystem $H_{x3} \sim H_{x8}$ 과 $H_{y2} \sim H_{y3}$ 는 속도에 의한 성분이다. 그리고 subsystem H_{x9} , H_{x10} , H_{y4} 은 중력에 의한 성분이다.

가중치의 초기치는 표 1의 매개 변수를 기초로 하였으나 첫 번째 subsystem의 코리올리스(Coriolis)와 원심력 항, 그리고 중력항에 관련되는 가중치는 임의로 주었다. 부하는 매니퓰레이터의 end-effector에 1kg이 가산되었다고 가정하였다. 또한 가중치 변화의 시상수는 100으로 하여 학습을 시켰다. 그림 4와 그림 5는 앞서의 조건 외에 feedback gain Kp와 Kd를 각각 2.0과 20으로 하여 학습을 시킨 결과이다(그림 4.5 참조). 그림 4는 Kp=200, Kd=20일 경우 첫 번째 학습에서 위치 오차의 수렴성을 보이고 있고, 그림 5는 700번 학습을 시킨 위치 오차의 수렴 결과이다. 학습을 거

표 2 2-자유도 매니퓰레이터의 14개의 subsystems

Table 2 14 subsystems of the 2 degree of freedom manipulator

i-th, j-th	Hxi	Hyj
1	\ddot{P}_x	\ddot{P}_y
2	$\ddot{P}_x / \sin(\theta_2)^2$	$\sin(\theta_2) \dot{\theta}_1^2$
3	$-\cos(\theta_2) \dot{\theta}_1^2$	$\sin(\theta_2) \dot{\theta}_1 \dot{\theta}_2$
4	$\dot{\theta}_1^2$	$\cos(\theta_1 + \theta_2)$
5	$-\dot{\theta}_2^2$	
6	$-\dot{\theta}_1 \dot{\theta}_2$	
7	$-\cos(\theta_2) \dot{\theta}_1 \dot{\theta}_2$	
8	$-\cos(\theta_2) / \sin(\theta_2)^2 \dot{\theta}_1 \dot{\theta}_2$	
9	$\cos(\theta_1) / \sin(\theta_2)$	
10	$\sin(\theta_2 + \theta_1)$	

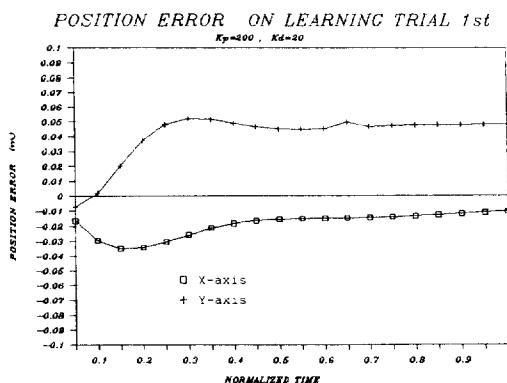


그림 4 Kp=200, Kd=20인 경우 첫번째 학습에서의 위치 오차

Fig. 4 Position error of the first learning trial with $K_p=200$, $K_d=20$

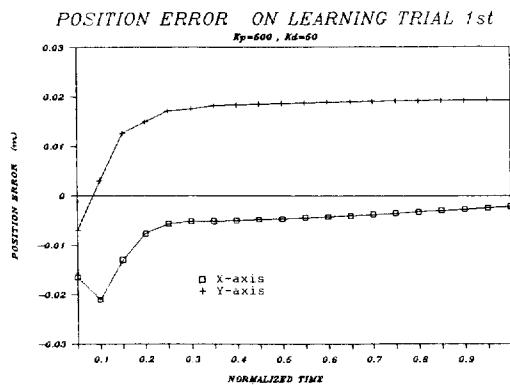


그림 6 Kp=500, Kd=50인 경우 첫번째 학습에서의 위치 오차

Fig. 6 Position error of the first learning trial with $K_p=500$, $K_d=50$

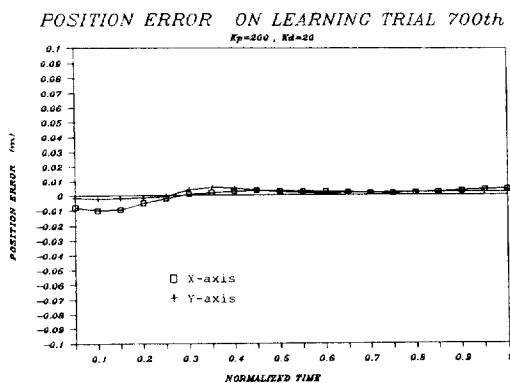


그림 5 Kp=200, Kd=20인 경우 700번째 학습에서의 위치 오차

Fig. 5 Position error of the 700th learning trial with $K_p=200$, $K_d=20$

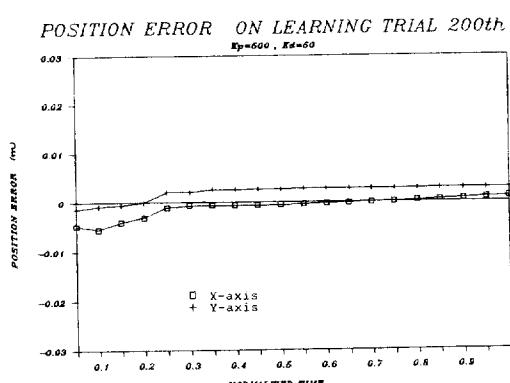


그림 7 Kp=500, Kd=50인 경우 200번째 학습에서의 위치 오차

Fig. 7 Position error of the 200th learning trial with $K_p=500$, $K_d=50$.

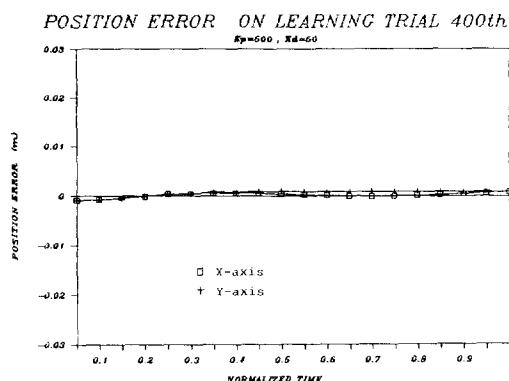


그림 8 $K_p=500$, $K_d=50$ 인 경우 400번째 학습에서의 위치 오차

Fig. 8 Position error of the 400th learning trial with $K_p=500$, $K_d=50$

듭할 수록 비교적 좋은 수렴성을 보이고 있으나 많은 학습 횟수를 필요로 한다. 한편 그림 6부터 그림 8은 K_p 와 K_d 를 각각 500과 50으로 하여 학습을 시킨 결과이다. 그림 6은 $K_p=500$, $K_d=5$ -일 경우 첫번째 학습에서의 위치 오차, 그리고 그림 7은 200번 학습을 시킨 위치 오차의 수렴성을 보이고 있다. 또한 그림 8은 400번 학습을 시킨 위치 오차의 수렴 결과인데 이 경우 전 구간에서 오차가 거의 0(zero)에 가까움을 보인다. 상기 두 경우를 비교해 볼 때 후자($K_p=500$, $K_d=50$)가 전자($K_p=200$, $K_d=20$)의 경우보다 학습 횟수가 적음을 알 수 있다. 따라서 feedback gain의 적합한 설정은 학습 제어에 많은 영향을 미친다.

그림들에서 보듯이 본 논문에서 제안한 카르테시안 feedback error learning 제어기는 학습을 거듭할 수록 오차가 훌륭히 수렴한다는 것을 알 수 있다.

5. 결 론

본 논문에서 제시된 카르테시안 feedback-error learning 제어기는 요구되는 궤적을 입력으로 받고 feedback force를 오차 신호로써 사용하여 매니퓰레이터의 역동력학 모델을 구할 수 있다. 학습이 진행되면서 신경 회로망이 feedback 제어기를 대신하여 주 제어기로서의 역할을 수행함으로써 매니퓰레이터와 같은 고도의 비선형 시스템의 정확한 정보나 매개 변수의 추정없이도 제어가 가능하였다. 그리고 앞으로는 매니퓰레이터의 부하가 갑자기 변화하는 문제, 고속의 궤적을 갖는 경우 등에

보다 효과적으로 대처할 수 있는 신경 회로망의 구조와 학습 법칙 등이 연구되어야겠다.

참 고 문 헌

- [1] J.S. Albus, "A new approach to manipulator control:the cerebellar model articulation controller (CMAC)", Trans. of the ASME, J. of Dynamic System Measurement, and Control, vol. 97, pp. 270-277, 1975.
- [2] S. Arimoto, S. Kawamura, & F. Miyazaki, "Bettering operation of dynamic systems by learning : A new control theory for servomechanism or mechatronics systems", Proc. of the 23th IEEE Conference on Decision and Control, vol. 2, pp. 1064-1069, 1984.
- [3] J.J. Craig, Introduction to Robotics, Addison – Wesley Publishing Company, 1986.
- [4] S. Dubowsky, & 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.
- [5] R.K. Elsley, "A learning architecture for control based on Back-Propagation neural network," Proc. of the IEEE Conf. On Neural Networks, vol. 2, pp. 587-594, 1988.
- [6] A. Guez and Z. Ahmad, "Solution to the inverse Kinematic problem in robotics by neural network," Proc. of the IEEE Conf. on Neural Networks, vol. 2, pp. 617-621, 1988.
- [7] G. Josin, D. Charney, and D. White, "Robot control using neural networks," Proc. of the IEEE Int. Conf. On Neural Networks," vol. 2, pp. 169-185, 1988.
- [8] M. Kawato, K. Furukawa, & R. Suzuki, "A hierarchical neural network model for control and learning of voluntary movements." Bio. Cybern, vol. 57, pp. 169-185, 1987.
- [9] M. Kawato, Y. Uno, M. isobe, & R. Suzuki, "A hierarchical neural network model for voluntary movement with application to robotics." IEEE Control System Magazine., vol. 8, pp. 8-16, 1988.
- [10] M. Kawato, H. Miyamoto, T. Setoyama, & R. Suzuki, "Feedback-error-learning neural network for trajectory control of a robotic

- mainpulator," Neural networks, vol. 1, pp. 251-265, 1988.
- [11] W.T. Miller, F.H. Glanz, & L.G. Kraft," Application of a general learning algorithm to the control of robotic manipulators," Int. J. of Robotics Research, vol. 6, No. 2, pp. 84-98, 1987.
- [12] K.S. Fu, R.C. Gonzalez, & C.S.G. Lee, Robotics : Control, Sensing, Vision, and Intelligence, McGraw-Hill Book Company, 1987.
- [13] D.S. Slobajic, J.J. Lu, and Y.H. Pao," Intelligent control of the INTELLEDEX 605T robot manipulator," Proc. of the IEEE Conf. on Neural Networks, vol. 2, pp. 633-639, 1988.
- [14] 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.
-