

신경회로망을 이용한 평행링크 DD로봇의 위치제어

(A Study on the Position Control of the parallelogram link DD Robot Using Neural Network)

金 聖 大 *

(Sung-Dae Kim)

요 약

본 논문에서는 DD(Direct-drive)의 기구로서 2자유도 평행링크 기구를 사용하였다. 평행링크 기구는 2개의 모터가 각각 기저부에 설치되어 있기 때문에 모터 자체의 질량이 다른 모터에 부하가 되지 않고, 링크의 수는 증가하지만 arm의 질량이 가볍게 되어, 링크 파라미터의 설정에 의하여 원심력 등의 비선형력이 없어지며 동시에 모터사이의 비간섭화를 실현할 수 있다. 그리고 평행링크 DD로봇 매니플레이터의高精度 운전의 실현을 위하여 신경회로망을 이용한 학습제어계를 설계하여 학습속도의 개선과 함께 변화한 작업대상에의 적응력을 개선하기 위하여 신경회로망과 피드백제어기로 학습제어 알고리즘을 구성한다.

Abstract

In this paper, two degree of freedom parallelogram link mechanism is used as DD(Direct-drive) robot mechanism. In parallelogram link mechanism, two motors being established in each base frame, the mass of motor itself is not loaded to another motor; the number of links are increased, the mass of arm being lighter; with the establishment of link parameter, nonlinearity such as the centrifugal force disappears; at the same time anti-interference between motors can be realized. And to realize highly-accurate drive of parallelogram link DD robot manipulator, to improve the learning speed through the design of learning control system using neural network, to raise adapting power to the varied work objects; the learning control algorithm is composed of neural network and feedback controller in this paper.

I. 서 론

로봇의 활용 분야가 확대됨에 따라 高速, 高精度, 多技能을 겸비한 로봇의 연구 개발에 대한 요구가 높아지고 있다. 이러한 요구에 부응하기 위해서는 로봇의 기구, 액츄에이터, 센서, 제어용 컴퓨터 등 하드웨어의

설계를 근본적으로 재검토하여 새로운 아이디어를 창출할 수 있는 지속적인 연구 개발이 필요하다. 특히, 액츄에이터와 傳達系는 로봇의 精度 및 속도를 직접적으로 좌우하기 때문에 과감한 개선이 필요하다.

본 논문에서는 기어에 감속기를 사용하지 않기 때문에 Backlash나 Hysteresis가 없고, 마찰이나 토크의 변화도 매우 작은 Direct-drive(이하 DD)모터를 이용한 DD로봇을 제어대상으로 하였다. 이 DD로봇은 高精度의 위치 혹은 힘제어가 가능하고 구조가 간단하기 때문에 부정확한 요인이나 모델링이 어려운 파라미터가 적으므로 비교적 정확한 모델을 얻을 수 있다.^[1-3]

그러나 DD로봇은 자세나 운동에 의한 링크의 간섭,

* 正會員, 東明大學 情報電子科

(Dept. of Information · Electronics, Tongmyong college)

※ 본 논문은 동명대학 학술연구조성비로 연구되었음.

接受日字 : 1999年8月9日, 수정완료일 : 1999年9月13日

코리올리력 및 원심력, 중력 등 비선형특성이 나타나므로 신경회로망 같은 제어대상의 정확한 모델링이 불필요한 제어법이 필요하다.^[4-7] 학습기능을 지닌 제어계로서 신경생리학의 신경세포(Neuron)를 모델화한 신경회로망에 의한 학습제어법이 널리 알려져 있으며, 이것을 이용한 연구가 여러 분야에 걸쳐 활발히 진행되고 있다.^[8-10] 그 중에서도, 목표신호와 실제출력과의 자승오차를 평가함수로 하여, 이것을 최소로 하는 학습방법으로 오차역전파(Error backpropagation)알고리즘^[8]이 제안되어, 계층형 신경회로망에 의한 여러 가지 패턴학습이 가능하게 되었다. 특히 로봇공학에의 응용분야에 있어서도 신경회로망을 오차학습법으로 오차를 최소화하기 위한 역시스템의 구현^[11], 최적궤도 생성^[12] 등 많은 연구가 계속되고 있다.

본 논문에서는 DD로봇의 기구로서 2자유도 평행링크 기구를 사용한다.^[13] 평행링크 DD로봇 매니플레이터의 高精度 운전의 실현을 위하여 신경회로망을 이용한 학습제어계를 설계하여 학습속도의 개선과 함께 변화한 작업대상에의 적응력을 개선하기 위하여 신경회로망과 피드백 제어기(Feedback controller)로 학습제어 알고리즘을 구성한다. 이 알고리즘을 평행링크 DD로봇 매니플레이터의 위치제어에 적용하여 컴퓨터 시뮬레이션을 통해 알고리즘의 유효성을 확인하였다.

II. DD로봇의 동특성

1. 평행링크 로봇 매니플레이터




그림 1. 평행링크 로봇 매니플레이터
Fig. 1. Parallelogram link robot manipulator.

평행링크 기구는 2개의 모터가 각각 기저부에 설치되어 있기 때문에 모터 자체의 질량이 다른 모터에 부하가 되지 않으므로 링크 수는 증가하지만 암의 질량을 가볍게 할 수 있다. 또한 링크 파라미터를 적당하게 설정하여, 관성행렬을 대각화하므로 원심력 등의 비선형력이 없어지며 동시에 각각의 모터의 반토크는 다른 한편의 모터에 직접 작용하지 않는다(비간섭화). 그러므로 각 모터마다 선형 1입력 1출력계로서 다룰 수 있도록 된다. 이상이 평행링크 기구의 장점이며 평행링크 기구를 사용하는 이유의 하나이다.

2. 동역학방정식

매니플레이터의 동특성방정식을 유도하기 위해, 본 논문에서는 Lagrangian 운동방정식을 이용한다. 매니플레이터의 전체 운동에너지를 K , 위치에너지를 P 라 하면, Lagrangian L 은 다음과 같이 정의된다.

$$L = K - P \quad (1)$$

또한, 모터내의 발생 토크를 τ 라 할 때, τ 와 L 과의 관계는 다음과 같다.

$$\tau = \frac{d}{dt} \frac{\partial L}{\partial \dot{\theta}} - \frac{\partial L}{\partial \theta} \quad (2)$$

회전관절을 갖는 다자유도 매니플레이터의 동특성방정식은 식(1), (2)를 이용하면 다음과 같이 나타낼 수 있다.

$$\tau_i = \sum_j H_{ij} \ddot{\theta}_j + \sum_j \sum_k \left[\frac{\partial H_{ij}}{\partial \theta_k} - \frac{\partial H_{jk}}{\partial \theta_{ij}} \right] \dot{\theta}_j \dot{\theta}_k + \frac{\partial P}{\partial \theta_i} \quad (3)$$

여기서 $i, j, k = 1, 2, \dots, N$ (N 은 매니플레이터의 자유도)이며, H_{jk} 는 관성행렬을 나타낸다. 또한, 우변 제 1항은 관성모멘트, 제 2항은 원심력과 코리올리력, 제 3항은 중력이다. 식 (3)을 다자유도계로 기술하여 정리하면 다음과 같다.

$$\tau = H(\theta) \ddot{\theta} + f_0(\theta, \dot{\theta}) \quad (4)$$

여기서, $f_0(\theta, \dot{\theta})$ 는 식 (3)의 우변 제 2항과 제 3항의 합, 즉 원심력, 코리올리력, 중력의 합으로서 비선형항을 나타낸다. 따라서 2자유도 평행링크 매니플레이터의

동특성방정식은 다음과 같다.

$$\tau_1 = H_{11} \ddot{\theta}_1 + H_{12} \ddot{\theta}_2 + \frac{\partial H_{12}}{\partial \theta_2} \dot{\theta}_2^2 + \frac{\partial P}{\partial \theta_1} \quad (5)$$

$$\tau_2 = H_{12} \ddot{\theta}_1 + H_{22} \ddot{\theta}_2 + \frac{\partial H_{12}}{\partial \theta_1} \dot{\theta}_1^2 + \frac{\partial P}{\partial \theta_2} \quad (6)$$

3. 운동학 함수와 역운동학 함수

그림 1의 DD로봇 매니플레이터에서, 링크 4의 팔끝 위치를 x , 관절각도를 θ 라 하면, x 는 운동학함수 $A(\theta)$ 를 이용하여 다음과 같이 나타낼 수 있다.

$$x = A(\theta) \quad (7)$$

여기서 x , θ , $A(\theta)$ 는 다음과 같이 정의된다.

$$x = [x \ y]^T, \quad \theta = [\theta_1 \ \theta_2]^T$$

$$\begin{bmatrix} x \\ y \end{bmatrix} = A(\theta) = \begin{bmatrix} l_1 \cos \theta_1 + l_3 \cos(\pi - \theta_2) \\ l_1 \sin \theta_1 - l_3 \sin(\pi - \theta_2) \end{bmatrix} \quad (8)$$

임의의 xy 평면상에서 매니플레이터의 팔끝위치 x 가 주어졌을 때, 각 링크의 관절각도를 구하는 역운동학함수(운동학방정식의 해)는 다음과 같이 구할 수 있다.

$$\theta = A^{-1}(x) \quad (9)$$

일반적으로 다자유도 매니플레이터의 운동학방정식의 해를 구하는 것은 쉬운 일이 아니나, 2자유도인 경우 기하학적인 관계를 이용하면 다음과 같이 비교적 간단하게 그 해를 구할 수 있다.

$$\theta_1 = \tan^{-1} \frac{y}{x} + \cos^{-1} \left[\frac{l_1^2 + x^2 + y^2 - l_3^2}{2 l_1 (x^2 + y^2)^{1/2}} \right] \quad (10)$$

$$\theta_2 = \cos^{-1} \left(\frac{l_1^2 + l_3^2 - x^2 - y^2}{2 l_1 l_3} \right) + \theta_1 \quad (11)$$

4. DD모터의 동특성 방정식

DD모터 관성행렬을 J_M , 점성마찰계수를 B_0 , 쿨롱마찰을 f_c , DD모터발생 토크를 τ 라 하면 DD모터의 동특성 방정식은 일반적으로 다음과 같이 나타낼 수

있다.

$$\tau(t) = J_M \ddot{\theta}(t) + B_0 \dot{\theta}(t) + f_c[\dot{\theta}(t)] \quad (12)$$

여기서 J_M 및 B_0 는 다음과 같이 정의된다.

$$J_M = \begin{bmatrix} J_{M1} & & 0 \\ & \ddots & \\ 0 & & J_{MN} \end{bmatrix} \quad (13)$$

$$B_0 = \begin{bmatrix} B_{0,1} & & 0 \\ & \ddots & \\ 0 & & B_{0,N} \end{bmatrix} \quad (14)$$

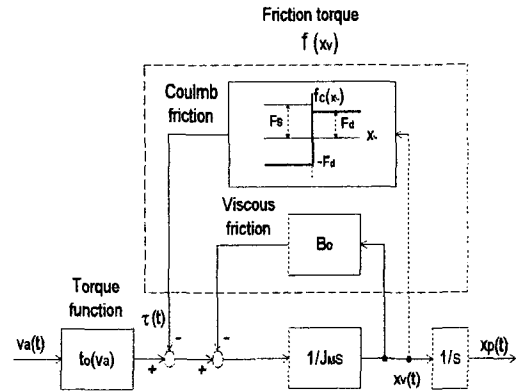


그림 2. 간략화한 DD 모터

Fig. 2. Simplified DD motor.

또한, 모터의 쿨롱마찰 f_c 는 동마찰토크를 F_d , 최대정지마찰토크를 F_s 라 하면, 다음과 같이 나타낼 수 있다.

$$f_c[\dot{\theta}(t)] = \begin{cases} F_d & (\dot{\theta} > 0) \\ -F_d & (\dot{\theta} < 0) \\ \tau(t) & (\dot{\theta} = 0 \text{ and } \tau \leq F_s) \end{cases} \quad (15)$$

III. 신경회로망의 구성

인간의 뇌는 수 백억 개의 신경세포로 구성된 일종의 정보처리 기관이다. 이처럼 막대한 수의 신경세포는 서로 복잡하게 결합된 회로망을 형성하여, 고도의 병렬 처리 시스템을 실현하고 있다. 신경회로망은 반복훈련과 과거의 경험을 통해 보다 빠르고 정확하게 명령을 내릴 수 있게 되며, 환경의 변화에 대해서도 적절히 적응할 수 있는 능력을 가지고 있다.

1. 신경회로망의 모델

신경회로망은 외부환경에 맞도록 자기자신의 내부구조를 변화시켜 조절하는 학습능력을 가지고 있다. 이와 같은 신경세포의 특성을 살려 그림 3에 표시한 것과 같은 신경세포를 모델화 하여, 이것을 계층적으로 결합한 것이 인공 신경회로망이다. 본 논문에서 이용한 신경회로망은 그림 4에 표시한 것처럼 입력층, 중간층, 출력층의 3층형으로 구성되어있다.




그림 3. 신경 모델
Fig. 3. Neuron model.

신경회로망의 각층 내부에서의 뉴론(Neuron)사이의 결합은 존재하지 않는 것으로 하며, 뉴론은 입력층으로부터 출력층을 향하여 한쪽 방향으로만 결합되는 것으로 한다.

또한 입력층의 입출력 관계는 선형이며, 중간층과 출력층의 출력은 시그모이드(Sigmoid)함수를 통과시킨 것으로, $-1 < f(x) < 1$ 의 범위의 값을 취하는 것으로 한다. 입력층, 중간층, 출력층의 뉴론 수를 각각 L, M, H라 놓으면, 각 층의 입출력 관계는 그림 4와 같이 표시할 수 있다.




그림 4. 신경 회로망
Fig. 4. Neural network.

2. 신경회로망에 의한 학습

신경회로망에 의한 제어계의 학습 알고리즘으로써 오차 역전파법을 이용하였다. 오차 역전파법은 입력층의 각 뉴론에 입력신호가 주어지면, 이 신호는 입력층과 중간층 사이의 결합하중 w_{ij} 에 의해 변환되어 중간층에 전달되고, 또다시 중간층과 출력층 사이의 결합하중 w_{jm} 에 의해 변환되어 출력층의 y_n 으로 출력하게 된다. 이 출력값과 원하는 목표값을 비교하여, 그 차이를 줄여나가는 방향으로 각 결합하중의 값을 역순으로 조절, 즉 중간층과 출력층 사이의 결합하중을 조절한 후, 이것을 토대로 입력층과 중간층 사이의 결합하중을 조절하는 것이다.

입력층과 중간층 사이의 결합하중의 변화량 Δw_{ij} 는 다음과 같이 정의한다.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \delta_j y_i \quad (16)$$

$$\delta_j = -\frac{\partial E}{\partial x_j} = f'(x_j) \sum_{n=1}^H \delta_n w_{jn} \quad (17)$$

그러므로 각층 사이의 결합하중은 식 (16), (17)로부터 다음과 같이 조절된다.

$$w_{jn}(m+1) = w_{jn}(m) + \sum_{i,n} \eta \delta_n y_i \quad (18)$$

$$w_{ij}(m+1) = w_{ij}(m) + \sum_{i,j} \eta \delta_j y_i \quad (19)$$

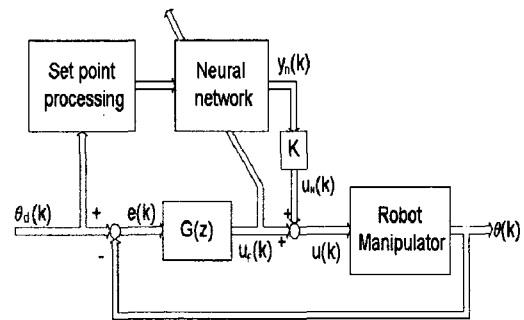


그림 5. 로봇 매니플레이터의 학습제어 시스템
Fig. 5. Learning control system of robot manipulator.

본 논문에서 제안하는 제어계의 구조는 그림 5와 같다. 본 제어계에서 로봇 매니플레이터의 조작량(토크) u는 실제의 응답과 목표값에 기초를 둔 피드백 제어기

로봇의 출력 u_F 와 신경회로망으로부터의 출력 u_N 의 합으로서 다음과 같이 주어진다.

$$u = u_F + u_N \quad (20)$$

또한 피드백 제어기 $G(z)$ 를 다음과 같이 정의한다.

$$G(z) = K_P + K_D(1 - z^{-1}) \quad (21)$$

학습의 초기단계에서는 오차가 크므로 피드백 제어기가 주 제어기가 되며, 따라서 신경회로망으로부터의 출력은 거의 0에 가깝다. 그러나 학습이 진행됨에 따라 오차가 작게 되며, 신경회로망에 의한 제어기가 주 제어기로 바뀌게 된다. 그러므로 피드백 제어기로부터의 출력이 0이 되었을 때는 신경회로망의 내부에 역시스템이 구축되었음을 뜻하며, 신경회로망의 입력신호를 이용하여 작업대상어의 조작량을 직접 산출하게 된다.

신경회로망의 입력신호로서 목표각도 θ_d , 각속도 $\dot{\theta}_d$, 각가속도 $\ddot{\theta}_d$ 와 출력 θ 를 입력한다. 신경회로망의 출력 y_n 을 제어대상의 조작량으로 조절하기 위해 정수 K 를 이용한다.

$$u_N = Ky_n \quad (22)$$

입력신호 중 $\dot{\theta}_d(k)$, $\ddot{\theta}_d(k)$ 는 목표각도 $\theta_d(k)$ 를 이용한 수치미분을 나타내며, 샘플링 주기를 T 라 놓고, 다음과 같이 정의한다.

$$\dot{\theta}_d(k) = \frac{\theta_d(k) - \theta_d(k-1)}{T} \quad (23)$$

$$\ddot{\theta}_d(k) = \frac{\dot{\theta}_d(k) - \dot{\theta}_d(k-1)}{T} \quad (24)$$

연산지연의 영향을 고려하여 1샘플링 주기 미래의 값 $\theta_d(k+1)$, $\dot{\theta}_d(k+1)$, $\ddot{\theta}_d(k+1)$ 을 신경회로망의 실제 입력신호로 이용한다.

IV. 시 물 레 이 선


제어대상은 그림 1에 나타난 평행링크 DD 로봇 매니퓰레이터를 사용하였다. 직교좌표계에서 매니퓰레이터의 팔끝좌표가 (x, y) 로 주어졌을 때, 관절각도

θ_1, θ_2 는 각각 식 (10)과 (11)를 이용하여 계산한다.


매니퓰레이터의 팔 끝에서 원과 정삼각형 및 정사각형 궤적을 추종하는 것을 시물레이션 대상으로 하였다. 목표궤도의 생성에는 가속도를 일정 값으로 취하는 사다리꼴 속도제어 방식을 이용하였다.

시물레이션에서는 샘플링 주기 $T = 5[ms]$, 최대 속도 $v = 0.28[m/s]$, 최대가속도 $a = 1.3[m/s^2]$, 링크길이 $l_1 = 0.3[m]$, $l_2 = 0.3[m]$ 의 값을 사용하였다. 신경회로망의 학습은 각 샘플링 주기마다 수행하도록 하였으며, 매니퓰레이터의 팔 끝에서 반경 $R = 0.08[m]$ 인 원과 높이 $H = 0.12[m]$ 인 정삼각형과 한 변의 길이 $L = 0.08[m]$ 인 정사각형을 2초 동안에 그리도록 하였다. 입력층에의 입력신호는

$$\begin{aligned} &\theta_1(k), \theta_{a1}(k+1), \dot{\theta}_{a1}(k+1), \ddot{\theta}_{a1}(k+1), \\ &\theta_2(k), \theta_{a2}(k+1), \dot{\theta}_{a2}(k+1), \ddot{\theta}_{a2}(k+1) \end{aligned}$$



(a)



(b)

그림 6. 원궤적 추종(1회)

(a) 각응답

(b) 제어입력


Fig. 6. Learning of circle trajectory(1st).

(a) Angle response.


(b) Control input.

합계 8개를 이용하였으며, 중간층 및 출력층의 뉴런 수는 각각 10개, 2개이다. 결합하중의 초기값은 -0.1에서 0.1 사이의 임의(Random)의 값으로 지정하였으며, 학습률 $\eta = 0.1$ 로 하였다. 피드백 제어기의 게인(Gain)은 학습효과를 나타내기 위해 대략적인 값으로 $K_P = 55, K_D = 15$ 로 하였다.

그림 6은 원궤적을 PD제어기만 이용하여 1회 추종했을 때의 응답을 나타낸다. 그림 6(a)의 종축은 목표각도 θ_{d1}, θ_{d2} 와 실제출력 θ_1, θ_2 (초기값 $\theta_d(0) = \theta(0) = 0$)를 나타내며, 횡축은 시간을 각각 나타낸다. 그림 6(b)의 종축은 제어대상의 조작량 u_1, u_2 신경회로망으로부터의 출력 u_{N1}, u_{N2} 를 나타낸다.



(a)



(b)

그림 7. 원궤적 추종(10회)


- (a) 각응답
- (b) 제어입력

Fig. 7. Learning of circle trajectory(10st).


- (a) Angle response.
- (b) Control input.

그림 7은 원궤적을 10회 추종했을 때의 응답으로서 출력각도는 목표각도에 일치하고 있으며, 그림 7(b)에서 신경회로망으로부터의 출력 u_{N1} 및 u_{N2} 가 조작량

u_1 및 u_2 에 거의 일치하고 있다는 것은, 신경회로망이 주 제어기로서의 역할을 하고 있다는 것으로서, 이것은 피드백제어기로부터의 출력 u_{F1} 및 u_{F2} 가 0에 가깝다는 것을 의미한다.



(a)



(b)

그림 8. 학습 시행횟수와 원궤적

- (a) 학습오차
- (b) 추종결과

Fig. 8. Learning process and circle trajectory.

- (a) Learning process
- (b) Trajectory

그림 8(a)의 종축은 각도의 지승오차의 평균 \bar{e}_1^2, \bar{e}_2^2 이며, 횡축은 원궤적 추종학습의 시행 횟수를 나타낸다. \bar{e}_1^2, \bar{e}_2^2 는 총 샘플링 수를 N 이라 놓고, 다음과 같이 정의한다.

$$\bar{e}_i^2 = \frac{\sum_{k=1}^N (\theta_{di}(k) - \theta_i(k))^2}{N} \quad (i = 1, 2) \quad (25)$$

그림 8(b)회 및 10회 추종했을 때, 원의 목표궤적과 실제 궤적을 나타낸다.

그림 9(a)는 원궤적을 10회 반복 추종한 후, 그때의 결합하중을 이용하여 정삼각형과 정사각형을 그렸을 때의 응답을 나타낸다. 원궤적과의 비교를 위해 삼각형 궤적과 정사각형 궤적을 10회 추종시켰으나 그림 9(a)

에서 보는 바와 같이 1회 시행했을 때와 10회 시행시켰을 때의 평균 자승오차의 차이가 거의 없으므로, 원 궤적에서와 같이 변화된 새로운 작업대상에 대한 빠른 적응력이 있음을 알 수 있다.

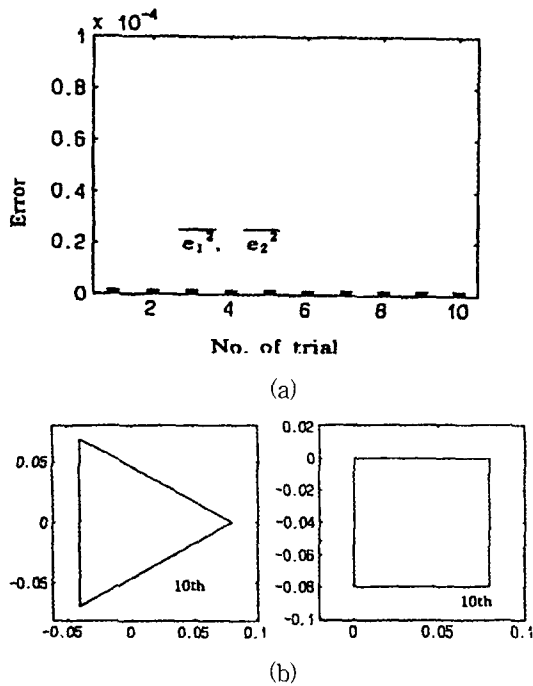


그림 9. 정삼각형과 정사각형 궤적의 추종결과
(a) 학습오차
(b) 추종결과

Fig. 9. Learning result of triangle and square trajectory(after learning circle trajectory)
(a) Learning process
(b) Trajectory

V. 결론

본 논문에서는 DD로봇 매니플레이터를 신경회로를 이용하여 로봇 매니플레이터의 위치제어를 위한 학습 제어 알고리즘을 구성하였다.

제안한 학습제어 알고리즘은 신경회로망과 피드백 제어기로 되어 있으며, 매니플레이터의 위치제어를 위한 학습이 진행됨에 따라 피드백 제어기로부터의 출력은 0에 가깝게 되었고, 신경회로망에 의한 제어가 주제가 되어 조작량을 직접 출력하게 된다는 것을 알 수 있었다. 또한 신경회로망의 입력신호로서 목표값의 수치미분값을 이용하므로 빠른 학습 효과를 낼 수 있

었으며, 반복학습 후의 신경회로망을 변화한 작업대상에 적용시킨 결과, 고도의 적응력을 갖고 있음을 알 수 있었다.

일반적으로 신경회로망에 의한 학습은 많은 횟수의 반복학습과 계산시간을 요구한다는 지적이 있다. 따라서 본 연구에서 사용된 학습 알고리즘은, Off-line 학습을 통해 습득한 지식을 On-line제어기에 적용시킴으로써 학습횟수를 단축시킬 수 있을 것으로 기대된다.


앞으로 평행링크 DD로봇 매니플레이터를 직접 설계 제작하여, 사용한 학습제어 알고리즘의 실효성을 확인하기 위한 연구를 계속하고자 한다.

참고 문헌

- [1] 高瀬國克, "DD로봇의 제어", 日本ロボット學會誌, Vol. 5, No. 1, pp. 55-60, Feb. 1987.
- [2] K. Otsuka, A. Uchiyama, "DD로봇과 고속화", 日本ロボット學會誌, Vol. 5, No. 1, pp. 67-71, Feb. 1987.
- [3] 김두형, 최동엽, 최형식, "4자유도직접 구동식 로봇의 제작 및 힘/운동제어의 기초실험", 대한기계학회 춘계학술대회논문집(1) pp. 781-784, 1994.
- [4] 市川, "뉴럴네트워크에 의한教師なし學習制御", 第29回計測自動制御學會學術講演豫稿集, pp. 397-398, 1990.
- [5] 稿本秀紀, "뉴럴네트워크로봇에의應用", 日本機械學會誌, Vol. 93, No. 856, pp. 218-222, March, 1990.
- [6] 김성대, 한창훈, 최부귀, "CMAC 매핑 알고리즘의 학습능력에 관한 연구", 동아대학교 공과대학 부설 정보통신연구소 논문집, Vol. 3, No. 1, pp. 69-79, 1995.
- [7] 김성대, 박재형, 김태수, "신경회로망과 유전알고리즘에 의한 PID제어기", 동명대학 논문집, Vol. 20, No. 1, pp. 287-294, 1998.
- [8] Rumelhart D.E., Hinton, G.E. and Williams, R.L., "Learning internal Representation by Error Propagation", *Parallel Distributed Processing*, Vol. 1, MIT Press, pp. 318-362, 1986.
- [9] Kuperstein, M. and Rubinstein, J., "Implementation of an adaptive Neural Controller for Sensory-Motor Coordination", *IEEE control System Magazine*, Vol. 9, No. 3, pp.

- 25-30, 1989.
- [10] Passino, K.m., Sartori, M.A. and Antsaklis, P. J., "Neural Computing for Nematic-to-Symbolic Conversation in control Systems", *IEEE Control System Magazine*, Vol. 9, No. 3, pp. 44-52, 1989.
- [11] Kawato, M., Furukawa, K. and Suzuki, R., "A Hierarchical Neural-Network Model for Control and Learning of Voluntary Movement", *Biol Cybern.* 57, pp. 29-37, 1987.
- [12] 宇野. 遠藤. 中村. 鈴木, "カスケード構造の神経回路モデルによる多関節マニピュレータの最適軌道制御", 第29回計測自動制御學會學術講演會豫稿集, pp. 281-282. 1990.
- [13] H. Asada and K. Y. Toumi. "Analysis and Design of a Direct-Drive Arm with a Five-Bar-Link Parallel Drive Mechanism", *ASME Journal of Dynamic Systems, Measurement and Control*, Vol. 106, pp. 225-230, September, 1984.

 저 자 소 개



金 聖 大(正會員)

1984년 2월 동아대학교 물리학과 졸업. 1986년 2월 동아대학교 대학원 전자공학과 졸업(공학석사). 1996년 2월 동아대학교 대학원 전자공학과 졸업(공학박사). 1991년~현재 동명대학 정보전자과 부교수. 주관 심분야는 로봇틱스, 지능제어 등