

## 다층 신경회로망을 사용한 로보트 매니퓰레이터의 궤적제어

正會員 安 德 煥\* 正會員 李 相 孝\*\*

### Trajectory Control for a Robot Manipulator by Using Multilayer Neural Network

Deug Hwan AHN\*, Sang Hyo LEE\*\* Regular Members

**要 約** 본 논문에서는 신경회로망을 사용한 로보트 매니퓰레이터의 곡선 궤적 제어 방법을 제안하였다. 매니퓰레이터에 가해지는 토크는 신경회로망의 출력인 feedforward 토크와 보조제어 기로 사용되는 비례 미분 제어기(PD 제어기)의 출력인 feedback 토크의 합이다. 제안된 신경회로망은 다층 신경회로로서 시간 지연 요소를 가지며 PD 제어기의 오차 토크를 사용하여 매니퓰레이터 역동학 모델을 학습한다. error backpropagation(BP) 학습 신경회로 제어기를 사용함으로서 매니퓰레이터 동특성에 대한 정보를 미리 필요로 하지 않으며, 연결 가중치 값에 따라 한정된다. 제안된 신경회로망의 특성을 컴퓨터 시뮬레이션을 통하여 입증한다.

**ABSTRACT** This paper proposed a trajectory controlmethod for a robot manipulator by using neural networks. The total torque for a manipulator is a sum of the linear feedback controller torque and the neural network feedforward controller torque. The proposed neural network is a multilayer neural network with time delay elements, and learns the inverse dynamics of manipulator by means of PD(propotional-derivative) controller error torque. The error backpropagation (BP) learning neural network controller does not directly require manipulator dynamics information. Instead, it learns the information by training and stores the information at connection weights. The control effects of the proposed system are verified by computer simulation.

### I. 서 론

최근 신경 회로망은 인공 지능 방법에 도전하여 패턴 인식, 사무 및 공장 자동화 등 여러분야에서 활발히 연구되고 있다. 기존 디지털 컴퓨터 구조와 달리 비교적 간단한 정보 처리 소자인 수많은 신경들이 고밀도로 상호 연결된 구조를 갖는데, 이러한 구조적 차이에 의해서 random problem에서 중요한 영상, 초해상력 및 학습(learning)등과 같이 collective한 특성이 나타난다.<sup>(1)</sup>

1960년대 후반에 Minsky, Papert에 의해 정체

되어 있었던 뇌의 정보처리메카니즘을 모델로 한 신경회로망(Neural Network)의 실현을 위한 연구가 다시 활기를 띠게 되었다. 즉 1980년대 들어서 미국을 중심으로 연결주의(Connectionism), PDP(Parallel Distributed Processing), 신경회로망정보처리, 인공신경망(Artificial Neural Network), 고도병렬성분처리 등의 이름으로, 생체의 뇌 신경계가 같은 고도의 정보처리기능이나 원리를 인공적으로 실현하고자 하는 이를바 신경회로망 메카니즘에 의한 정보처리의 연구가 활발히 진행되고 있다. 이와 같은 신경회로망에 의한 정보처리 메카니즘은 간단한 유니트들을 대량으로(massively) 연결하여 구조적으로 병렬 처리가 가능하도록 만든 모델이며 또한 인간의 두뇌와 비슷하게 자기조직화(self organization)

\*馬山看護保健專門大學 電子計算機課

\*\*光云大學校 制御計測工學科

論文番號: 91-112 (接受1991. 8. 13)

에 의한 자발적 생성(spontaneous generation), 고장허용(fault tolerance, graceful degradation) 및 기존의 컴퓨터와 같이 복잡한 소프트웨어 코딩이 필요 없다는 등의 많은 특징을 가지고 있다.

기존의 로보트 동력학 제어는 적당한 동력학 모델에 대한 수치적 계산으로 제어하기 때문에 정확한 제어가 어려워지고, 로보트의 정확한 파라미터를 구하는 것도 불가능하므로 제어하기에 어려운 점이 많다. 이러한 문제를 해결하기 위하여 신경 회로망을 이용한 제어가 많이 연구되고 있는데 이러한 신경 제어는 다음과 같은 특징이 있다.

즉, 신경 제어는 각각의 뉴온들이 모든 계산을 독립적으로 병렬 처리하고 간단한 학습을 통해서 제어치를 알게된다. 그래서 시스템을 모델링할 필요가 없으며 대단히 복잡한 비선형 시스템도 학습을 통해 쉽게 제어치를 알게 된다. Miller는 CMAC(Cerebellar Model Articulation Controller) 신경 회로망을 사용한 로보트 제어 방법을 제안 했고,<sup>(2)</sup> Miyamoto는 단층 신경회로망을 이용한 3축 로보트 제어 방법을 제안하였다.<sup>(3)</sup> 그리고 Guez는 2축 로보트의 동력학 모델을 Backpropagation Network이 학습을 통해 알아내는 제어방식을 보였다.<sup>(4)</sup> CMAC 방법은 많은 기억 용량을 가져야 하고 Miyamoto 및 Guez의 방법은 매니퓰레이터의 동특성에 대한 지식을 어느 정도 알아야 한다.

본 연구에서는 제어 분야에 많이 응용되는 다층 신경회로망을 이용한 로보트 매니퓰레이터의 동특성 제어에 관하여 연구하였다. 제안된 다층 신경회로망은 중간 계층의 상태가 시간 지연 요소를 가지므로서 보다 효과적인 학습을 할 수 있다.

## II. 다층 신경회로망 구성

다층 신경회로망은 입력층과 출력층 사이에 PE(processsing element)들이 한개 이상의 중간층

을 갖는 feed forward 연결 구조를 갖는 그림 1과 같다.

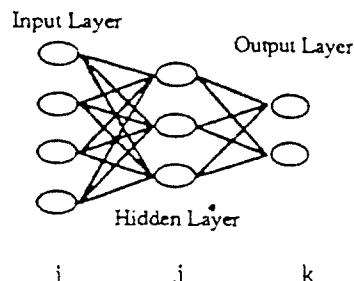


그림 1. 다층 신경회로망 구조  
Fig 1. Multilayer Neural Network.

$W_{ji}$  PE<sub>i</sub>에서 PE<sub>j</sub>로의 연결강도라고 하면 PE<sub>j</sub>의 출력  $O_j$ 는 다음식으로 구해진다.

$$O_j = f(\text{net}_j) \quad (1)$$

$$\text{net}_j = \sum_{i=1}^n (W_{ji} O_i) \quad (2)$$

$$f(x) = \frac{1}{1+\exp(-x)} \quad (3)$$

여기서, n는 i층의 PE의 수이고  $O_i$ 는 PE<sub>i</sub>의 출력으로서  $O_j$ 와 마찬가지로 구한다. 다층 신경회로 학습 방법의 기본 원리는 LMS(least mean square)의 예리 목적 함수를 Gradient Descent 방법을 PE과 같은 비선형 신경회로당에 적용하는 것이다. 이를 위해서는 회로망의 어떠한 연결 강도에 대해서도 예리 함수의 도함수를 쉽게 구할 수 있어야 한다. 가장 많이 사용되는 학습 방법은 BP방법으로 어떤 입력패턴에 대한 신경회로의 출력을 외부에서 가르쳐주는 지도(supervised) 학습방법이다. 즉, 신경회로 출력이 원하는 출력값이 되도록 PE간의 연결강도를 조절한다. 오차함수를 (4)식으로 정의한다.

$$E = 1/2 \sum (d_k - o_k)^2 \quad (4)$$

여기서,  $d_k$ 는 출력층 PE<sub>k</sub>의 원하는 출력이고,  $O_k$ 는 출력층 PE<sub>k</sub>의 실제 출력이다. PE 간의 연결 강도 변화는 출력층 PE와 중간층 PE에서 각각 다르게 정의된다. 출력층에서 PE<sub>k</sub>와 PE<sub>j</sub> 간의 연결 강도 변화는 (5)식으로 된다.

$$\Delta W_{kj} = \eta \delta_k O_j \quad (5)$$

여기서,  $\delta_k = (d_k - o_k) f'(net_k)$ 이고,  $\eta$ 은 학습율(learning rate)이다. 중간층 PE의 연결 강도 변화는 (6)식으로 된다.

$$\Delta W_{ji} = \eta \delta_j O_i \quad (6)$$

여기서,  $\delta_j = f'(net_j) \sum_k \delta_k W_{kj}$ 이다.

그래서 각 PE들 간의 연결 강도 변화는 chain rule을 이용하여 다음과으로 된다.

$$\Delta W(n+1) = \eta \delta O + \alpha \Delta W(n) \quad (7)$$

여기서,  $n$ 는 반복 횟수를 나타내고,  $\alpha$ 는 chain rule의 운동량(momentum)을 나타낸다. 본 연구에서는 2개의 중간층을 가지는 것으로서 첫 번째 중간층이 시간 자연 요소를 가지는 것으로 PE<sub>j</sub>에 대한 net<sub>j</sub>는 다음과으로 표시된다.

$$net_j = \sum_{i=1}^n \{ w_{ji}(t)O_i(t) + a_1 w_{ji}(t-1)O_i(t-1) + a_2 w_{ji}(t-2)O_i(t-2) \} \quad (8)$$

$a_1, a_2$ 는 시뮬레이션 시 0.1로 설정하였다. 이것은 신경회로망의 뉴런이 현재의 입력신호와 시간 지연된 입력들을 받아 현재의 입력신호와 앞 뒤 사이의 신호에 대한 동적인 시간정보를 추출하여 보다 적응력이 있는 학습을 할 수 있다.

### III. 다층신경회로망을 이용한 매니퓰레이터 동특성 제어

제안된 다층 신경회로망을 이용한 로보트 매니퓰레이터 동특성에 대한 전체적인 제어 시스템은 그림 2와 같다.

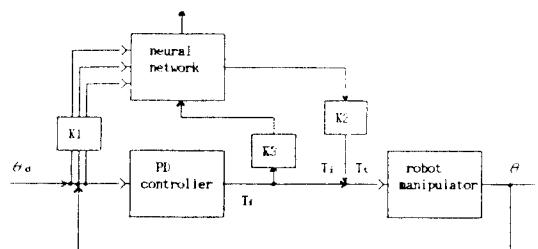


그림 2. 신경회로망을 사용한 매니퓰레이터 제어기  
Fig. 2. Manipulator controller by using neural network

그림 2에서  $T_f$ 는 바레 미분 제어기의 feedback 세이기 출력 토크를 나타내고,  $T_c$ 는 신경회로망을 사용한 세이기의 feedforward 제어기 출력 토크를 나타낸다.

그리고  $T_c$ 는 feedback 토크  $T_f$ 와 feedforward 토크  $T_f$ 의 합을 나타낸다. 매니퓰레이터의 움직임을 제어하는 실제 토크는  $T_t$ 에 의해서 이루어진다. 신경회로망 세이기는 학습 초기에는 로보트의 동특성을 모르기 때문에 임의의 작은 연결 강도 값을 가지며 PD제어기의 오차 출력을 감소시키는 방향으로 학습한다. 학습을 하기 전인 초기 상태에서의 주된 세이기는 선형 세이기가 되지만 학습을 충분히 하고난 후에는 신경회로망 세이기가 주된 세이기가 된다. 신경회로망의 입력은 원하는 관절 각, 각속도, 각각속도를  $K1$ 에 의해 +1과 -1 사이로 정규화시켜서 입력하고 신경회로망의 출력 토크는  $K2$ 에 의해 +35와 -35 사이로 정규화하고, 신경회로망의 학습오차로 사용되는 feedback 토크는  $K3$ 에 의해 +1과 -1 사이로 정규화 시켰다.

## IV. 시뮬레이션 및 결과고찰

### 4.1 제안된 로보트 매니퓰레이터 모델

본 논문에서 제안된 신경회로망 학습 채어기의 성능을 평가하기 위하여 그림 3의 2 자유도를 갖는 매니퓰레이터에 학습 채어기는 적용하였다.

샘플링 시간은 0.03초, 관절 길이  $L_1=0.5(m)$ ,  $L_2=0.5(m)$ , 관절의 끝점 질량  $M_1=4.6(kg)$ ,  $M_2=2.3(kg)$ 으로 설정하였으며 매니퓰레이터의 동력학 방정식은 다음식으로 표현된다.

$$T(t) = M(\ddot{\theta})\dot{\theta} + V(\theta, \dot{\theta}) + G(\theta) \quad (11)$$

여기서,  $M(\theta)$ 는 관성 행렬,  $V(\theta, \dot{\theta})$ 는 원심력 및 코리올리력 벡터,  $G(\theta)$ 는 중력 벡터를 나타낸다.

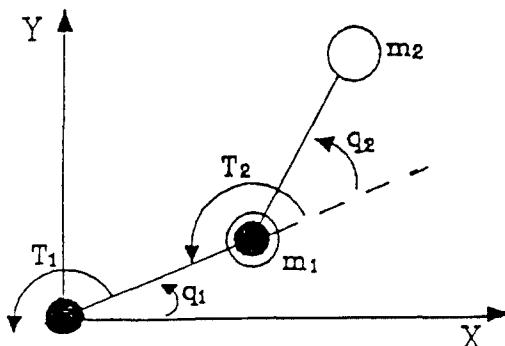


그림 3. 로보트 매니퓰레이터  
Fig. 3. Robot manipulator.

그림 4,5는 원하는 관절각, 각속도 및 각가속도를 나타낸다.

선형 PD제어기는 다음식으로 표현된다.

$$T_f = K_p(\theta_d - \theta) + K_d(\dot{\theta}_d - \dot{\theta}) \quad (12)$$

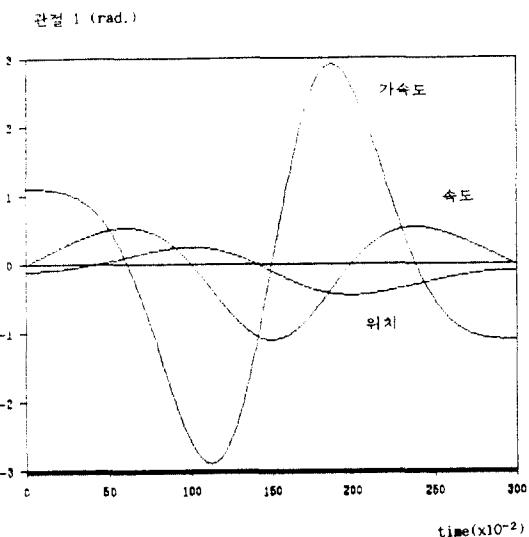


그림 4. 관절 1의 원하는 캐적  
Fig. 4. Desired trajectory of joint 1.

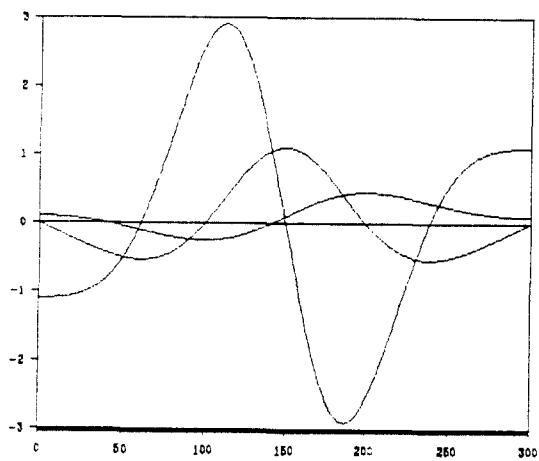


그림 5. 관절 2의 원하는 캐적  
Fig. 5. Desired trajectory of joint 2.

여기서, 비례 채어기 이득  $K_p=300$ , 미분 채어기 이득  $K_d=30$ 으로 설정하였다.

그림 6은 신경회로망이 학습을 하기 전인 단지 선형 PD 채어기만 사용시의 추종 캐적을 나타낸다.

### 4.2 다중 신경회로망을 이용한 채어

신경 회로망 채어기의 모든 연결 강도의 초기치는 -1과 1 사이의 임의의 값으로 주었다. 입력 충

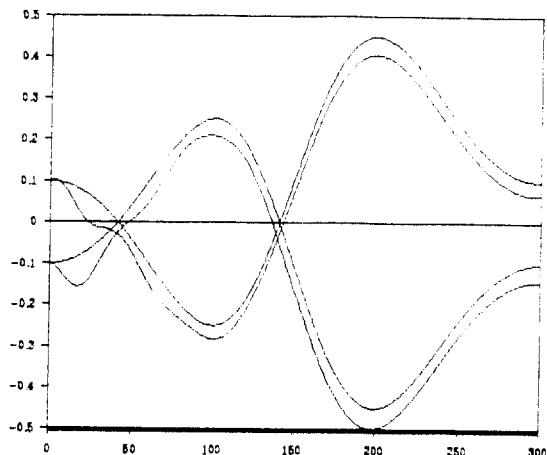


그림 6. PD제어기의 사용시 추종 캐적  
Fig. 6. Tracking trajectory in PD controller.

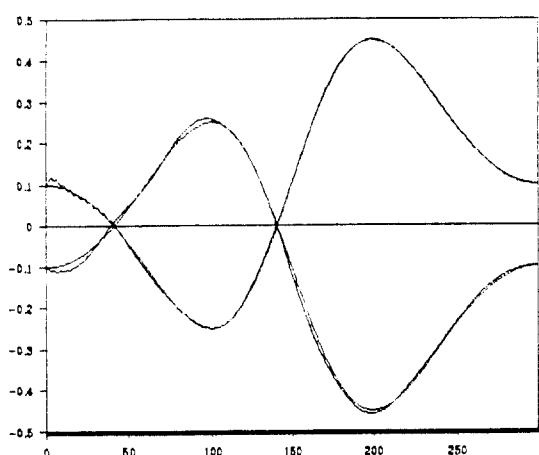


그림 7. 1번 학습시 추종 캐적  
Fig. 7. Tracking trajectory on 1 iteration.

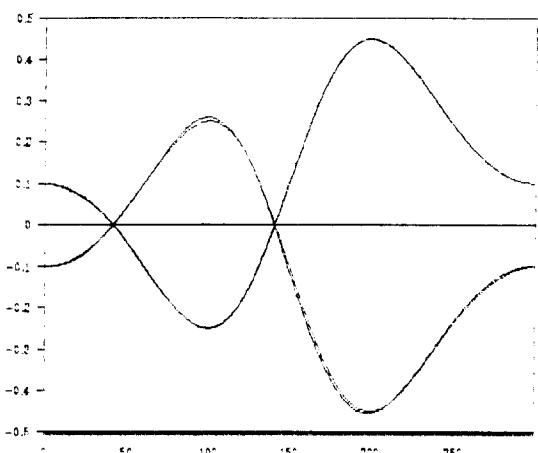


그림 8. 5번 학습시 추종 캐적  
Fig. 8. Tracking trajectory on 5 iteration.

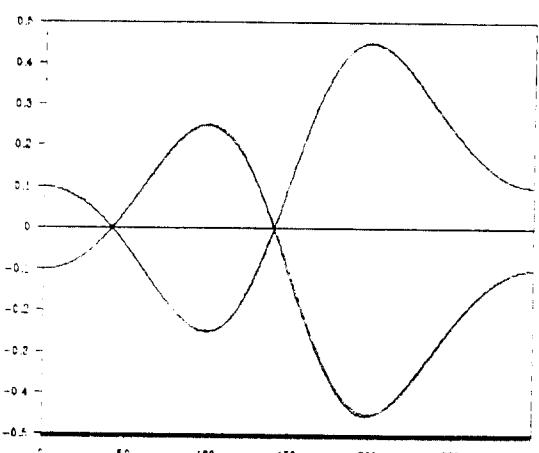


그림 9. 50번 학습시 추종 캐적  
Fig. 9. Tracking trajectory on 50 iteration.

은 각 관절의 원하는 관절각, 각속도, 각각속도를 일어서 인가한다. 이때 정규화시키는  $K_1$ 의 값은  $1/3$ 로 설정하였다. 두개의 중간계층을 사용하였으며 각각 20개와 15개의 PE를 사용하였다. 출력층은 2개의 PE를 사용하였다. 신경회로망의 출력토크를 정규화시키는  $K_2$ 의 값은 35로 설정하였으며, 학습오차로 사용되는 feedback 토크에 대한  $K_3$ 의 값도 35로 설정하였다. 학습율은 0.5, 운동량은 0.1로 하였다.

그림 7은 한번 학습시의 추종 캐적을 나타내고 그림 8은 5번 학습을 하고난 후의 추종캐적이다. 그림 9는 50번 학습시의 추종캐적을 나타낸다. 그림 10은 1번 학습시의 관절 1에 대한 각 세이기의 토크를 나타내고, 그림 11은 관절 2에 대한 토크를 나타낸다. 그림 12는 50번 학습시의 관절 1에 대한 토크를 나타내고, 그림 13은 관절 2에 대한 토크를 나타내며, 이때의 주된 세이기는 신경회로망 세이기가 됨을 알

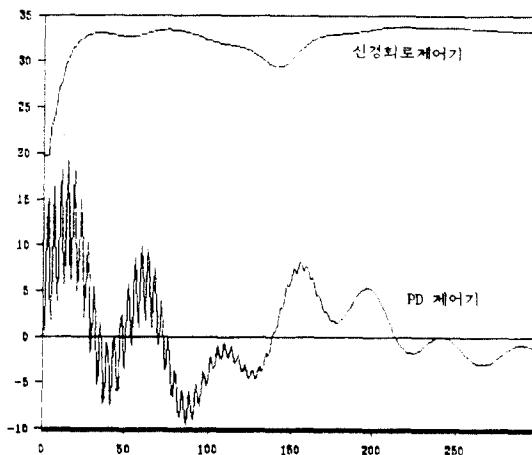


그림 10. 1번 학습시 관절 1의 토크  
Fig 10. Joint 1 torque on 1 iteration.

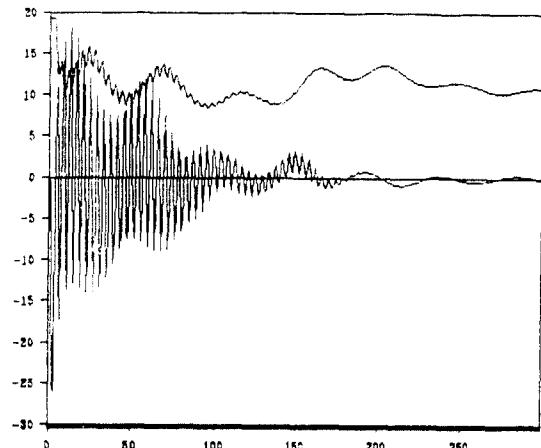


그림 11. 1번 학습시 관절 2의 토크  
Fig 11. Joint 2 torque on 1 iteration.

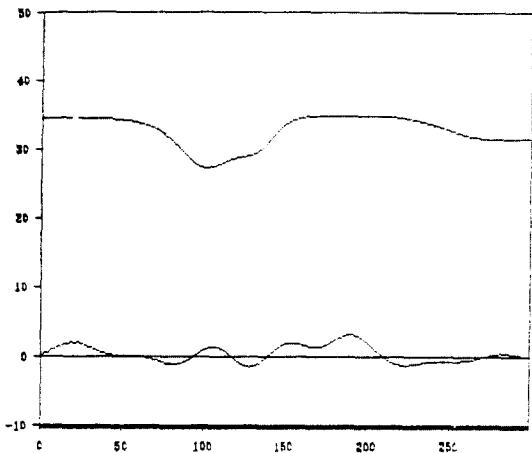


그림 12. 50번 학습시 관절 1의 토크  
Fig 12. Joint 1 torque on 50 iteration.

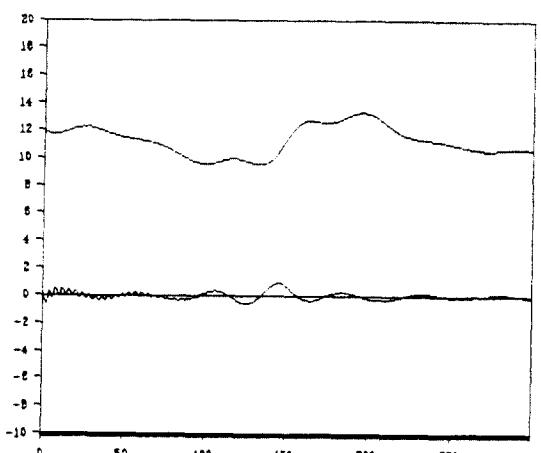


그림 13. 50번 학습시 관절 2의 토크  
Fig 13. Joint 2 torque on 50 iteration.

수 있다.

본 연구에서 제안한 BP학습 기능을 사용한 다중 신경회로망의 성능을 비교, 분석하기 위하여, 그림 14에 관절 2에 대한 일반적인 신경 회로망 방식에 의한 결과와 비교하여 나타내었다. 그림 14에서 보는 바와 같이 제안된 신경회로망 방식이 평균 자승오차가 더 적고 결과적으로 보다 효율적인 학습 성능을 보이고 있다.

그리고 단층 신경회로망은 Delta Rule 학습

방법을 사용하는 선형 유닛에 적용되므로 매니퓰레이터의 동특성의 각각의 항에 대한 사전 지식이 필요한 반면, 제안된 다중 신경회로망은 BP 학습 방법을 사용하는 비선형 유닛에 적용되므로 매니퓰레이터 동특성을 완전히 모르는 상태에서 역동력학 모델을 학습할 수 있다. 표 1은 이들 두 가지 방법에 대한 비교를 나타내었다. 또한 그림 4,5에서 주어진 테스트 케이스으로 이미 학습된 역동력학 모델을 이용하여 그림

표 1. 단층, 다층 신경회로망 세이어기 비교

Table 1. Comparison of single and multi layer neural network controller

단층신경회로망 세이어기 (Miyamoto)	다층신경회로망 세이어기
동역학 모델의 각항의 O를 포함한 학수를 입력변수로 선택	원하는 궤적을 입력변수로 선택
동역학 모델 표현을 알아야 함	몰라도 됨
학습방법은 계화오차 사용 (delta rule)	학습방법은 계화오차 사용 (BP rule)
PD 제어기를 보조제어기로 사용	PD 제어기를 보조제어기로 사용
온-라인 세이어	온-라인 세이어
사용된 연결강도 수 : 13개	사용된 연결강도 수 : 450개

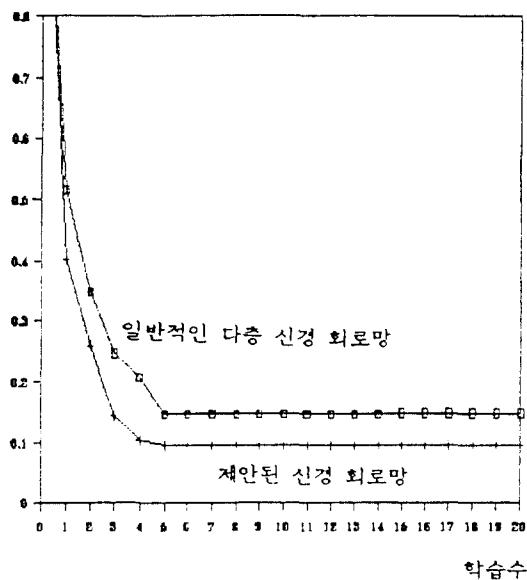
평균자승오차( $\times 10^{-2}$ )

그림 14. 제안된 세이어기 효과

Fig 14. Proposed controller effect.

그림 15와 같은 다른 테스트 케이스에 적용하였다. 이때 그림 15는 PD 세이어기만 사용시 케이스 추종을 나타내고 그림 16은 단 2번만 학습시킨 후의 케이스 추종을 나타낸다. 이것은 학습시키지 않은

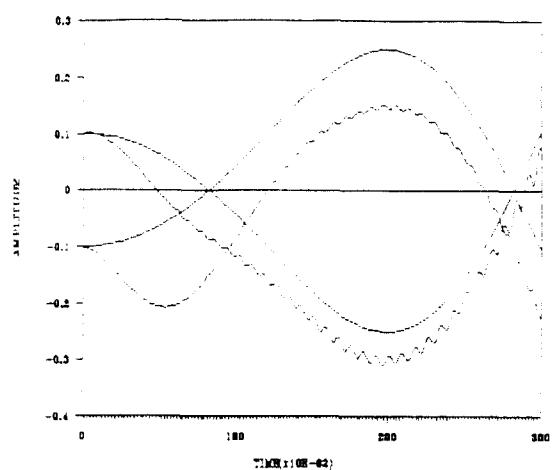


그림 15. PD세이어기만 사용시 추종 궤적  
Fig 15. Tracking trajectory in PD controller.

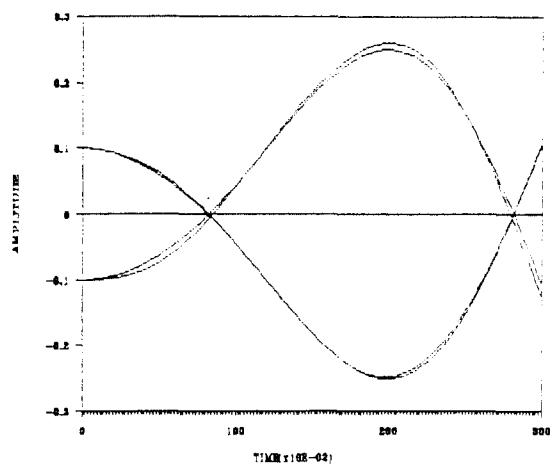


그림 16. 2번 학습시 추종 궤적  
Fig 16. Tracking trajectory on 2 iteration.

다른 테스트 케이스에 신경회로망에 적용시킬 경우에도 대체로 훌륭한 궤적 추종을 한다는 신경회로망의 일반성을 보여준다.

## I. 결 론

본 논문에서는 신경회로망을 이용한 로보트 배니풀레이터의 학습 세이어에 대해서 서술하였

다. 신경 회로망의 연결 가중치 변화는 선형 제어기의 출력 토크를 사용하여 오차를 줄이도록 학습시켰다. 첫번째 중간층이 시간지연 요소를 가지는 방법을 이용함으로서 보다 빠른 학습 효과를 얻을 수 있었다. 또한 효과적인 학습을 위한 입출력 패턴 방법에 대해서도 기술하였다. 실제로 매니퓰레이터를 제어하는 전체 토크는 선형 제어기 및 학습 제어기 토크의 합으로 되지만 학습을 충분히 하고난 후에는 학습 제어기가 주된 제어기가 된다. 앞으로 보다 빠른 학습 알고리듬을 이용하면 학습 제어기의 성능이 개선될 것이다.

### 참 고 문 헌

1. J.L.McCelland, D.E. Rumelhart, Parallel Distributed Proc., MA, MIT press, 1986.
2. W.T.Miller, R.P.Hewes, "Real time dynamic control of an industrial manipulator using a neural network based learning controller", IEEE Trans. Robotics Automat., Vol.6, no.1, pp.1-8, Feb. 1990.
3. M.Miyamoto, M.Kawato, T.etc, "Feedback error lea-

rning neural network for trajectory control of a robotic manipulation", Neural Networks, vol.1, 1988.

4. A.Guez and J.Selinsky, "Neurocontroller design via supervised and unsupervised learning", J.Intelligent and Robotics Systems, pp.307-335, 1989.
5. G.Josin, D.Chaeney, and D.White, "Robot control using neural networks", Proc. of the IEEE Int. Conf.on Neural Networks, Vol.2, pp.169-185, 1988.
6. M.Kawato, Y.Uno and R.Suzuki, "A hierarchical neural network model for voluntary movement with application to robotics", IEEE Control System Magazine, Vol.8 pp.8-16, 1988.
7. 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.
8. M.H.Raibert, J.J.Craig, "Hybrid position / force control of manipulator" Joural of Dynamic System Measurement and Control, Vol.102, pp.126-133, 1981.
9. W.T.Miller, III, "Sensor-based control of robotics manipulators using a general learning algorithm", IEEE J. Robotics Automat., Vol.RA-3, pp.157-165 Apr.1987.



**安德煥 (Deug Hwan AHN)** 正會員  
1960年10月18日生  
1984年2月：慶北大學校 電子工學科 卒業(工學士)  
1986年2月：光云大 大學院 電子工學科 卒業(工學碩士)  
1988年3月～現在：光云大 大學院 電子工學科 博士過程  
現在：馬山看護保健專門大學 電子計算機課 副任講師



**李相孝 (Sang Hyo LEE)** 正會員  
1941年5月23日生  
1969年2月：首都工科大學 電氣工學科 卒業(工學士)  
1971年2月：延世大 大學院 電氣工學科 卒業(工學碩士)  
1981年2月：延世大 大學院 電氣工學科 卒業(工學博士)  
1983～84年：U. C. Berkely客員研究員  
現在：光云大學校 制御計測工學科 教授

※이 논문은 1991년도 한국과학재단 연구조성비로 이루어졌음.