

## TDNN 다층 신경회로망을 사용한 로봇트 매니플레이터에 대한 궤적 제어

正會員 安 德 煥\* 正會員 梁 兌 奎\*\* 正會員 李 相 孝\*\*\* 正會員 柳 彦 茂\*

### Trajectory Control of a Robot Manipulator by TDNN Multilayer Neural Network

Deug Hwan Ahn\*, Tae Kyu Yang\*\*, Sang Hyo Lee\*\*\* Yeon Moo Ryu\* *Regular Members*

#### 要 約

본 논문에서는 로봇트 매니플레이터 제어를 위하여 시간 지연이 있는 다층 신경회로망(TDNN)의 학습 알고리즘으로 매니플레이터의 역동력학 모델을 학습시키고 이것을 앞먹임(Feedforward)제어기로 사용하는 궤적 제어 방법을 새로이 제시하였다. TDNN 구조는 뉴런이 현재 및 과거의 입력 신호로부터 더 많은 정보를 추출할 수 있고 보다 효율적으로 학습할 수 있는 유리한 특징을 가지고 있다.

TDNN 신경회로망은 기준 궤적 입력 신호와 비례 미분 제어기의 오차 신호를 각각 정규화하여 받아들인다. TDNN 신경회로망으로 입력되는 정규화 신호는 TDNN 신경회로망의 학습 효율을 향상시키는 것으로 입증되었다.

제안된 제어 방법을 두개의 관절을 가진 평면 로봇트 매니플레이터에 대하여 적용하고 컴퓨터 시뮬레이션으로 고찰하였다.

#### ABSTRACT

In this paper a new trajectory control method is proposed for a robot mainpulator using a time delay neural network (TDNN) as a feedforward controller with an algorithm to learn inverse dynamics of the mainpulator. The TDNN structure has so favorable characteristics that neurons can extract more dynamic information from both present and past input signals and perform more efficient learning.

The TDNN neural network receives two normalized inputs, one of which is the reference trajectory signal and the other of which is the error signals from the PD controller. It is proved that the normalized inputs to the TDNN neural network can enhance the learning efficiency of the neural network.

The proposed scheme was investigated for the planar robot manipulator with two joints by comuter simulation.

\*馬山專門大學 電子計算機科

\*\*牧園大學校 電子工學科

\*\*\*光云大學校 制御計測工學科

論文番號 : 93-64

## I. 서 론

현재의 급속한 산업 변화와 더불어 공장 자동화 등과 같은 여러분야에서 산업 로봇트의 활용이 많아지고 있다. 특히 반복적인 작업과 작업 환경 개선에 있어서의 산업 로봇트의 역할은 상당하다.

현재까지 발표된 신경회로망을 이용한 매니플레이터의 동특성 제어는 별로 많지 않다. Miyamoto (1988)[2]의 단층 신경회로망을 사용한 로봇트 매니플레이터 제어 방법, Guez(1989)[3]의 2축 매니플레이터에 대한 다층(Multilayer) 신경회로망을 이용한 제어 방법, 그리고 Miller(1990)[6]의 CMAC(Cerebellar Model Articulation Control) 방식 등이 있다.

CMAC 방법은 Table Lookup 방식으로 많은 기억용량이 필요하며, Miyamoto 및 Guez의 방법은 매니플레이터 동특성에 대한 사전 지식을 어느 정도 알아야 한다는 단점이 있다.

본 논문에서는 TDNN(Time Delay Neural Network) 다층 신경회로망을 사용한 새로운 로봇트 매니플레이터의 관절 궤적 제어 방법을 제시한다. 이러한 신경회로망의 구조는 두번째 은닉층(Hidden Layer) 뉴런들이 첫번째 은닉층 뉴런들의 시간 지연된 벡터를 받아들인다.

TDNN의 뉴런은 원래의 주어진 입력 벡터 신호뿐만 아니라 그 신호의 지연된 벡터 신호를 입력으로 받아서 앞 뒤사이의 신호에 대한 동적인 시간 정보를 추출하여 보다 적응력이 있는 학습을 할 수 있다.

로봇트 매니플레이터에 대한 제어기는 기존의 비례 미분(PD: Proportional Derivative) 되먹임 제어기와 매니플레이터의 역동력학 모델을 학습하는 TDNN의 출력을 되먹임 제어기로 사용하여 관절 궤적을 제어한다.

TDNN의 학습 방법은 BP(Back-Propagation) 학습 알고리즘을 사용하므로 매니플레이터 동특성에 대한 아무런 사전 지식도 없이 단지 원하는 위치, 속도 및 가속도 신호를 TDNN 신경회로망의 입력으로 하고 학습에 필요한 오차 신호는 PD 되먹임 제어기의 토크를 이용하므로써 매니플레이터 역동력학 모델을 학습함과 동시에 제어도 하는 On-Line 제어 방법을 제시한다. 이 때 TDNN 신경회로망에 필요한 각각의 신호들은 진폭 정규화(Normalization)된 신호를 사용한다. 또한 매니플레이터의 부하 변화에 대한 적응성 및 학습이 완료된 후 미소한 기준 궤적의

변화에 대한 TDNN 신경회로망의 적응성을 제시한다.

## II. 다층 신경회로망 구성

다층 신경회로망은 입력층과 출력층 사이에 PE (processing element)들이 한개 이상의 중간층을 갖는 feed-forward 연결 구조를 갖는 그림 1과 같다.




그림 1. 다층신경회로망 구조  
Fig 1. Multilayer Neural Network

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

$$O_i = f(\text{net}_i) \quad (1)$$

$$\text{net}_i = \sum_{j=1}^n (W_{ji} O_j) \quad (2)$$

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

여기서,  $n$ 는  $i$  층의 PE의 수이고  $O_j$ 는 PE<sub>j</sub>의 출력으로서  $O_i$ 와 마찬가지로 구한다. 다층 신경회로 학습 방법의 기본 원리는 LMS(least mean square)의 오차 목적 함수를 Gradient Descent 방법을 PE과 같은 비선형 신경회로망에 적용하는 것이다.

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 실제출력이다. PE간의 연결강도 변화는 출력층 PE와 중간층 PE에서 각각 다르게 정의된다.

출력층에서 PE<sub>k</sub>와 PE<sub>j</sub>간의 연결강도 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,  $\eta$ 는 학습율 (learning rate)이다.

중간층 PE의 연결강도 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 연결강도 변화는 chain rule을 이용하여 다음식으로 된다.

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

여기서, n는 반복횟수를 나타내고,  $\alpha$ 는 chain rule의 운동량(momentum)을 나타낸다.

### III. 제안된 TDNN 다층 신경회로망을 사용한 로봇 궤적 제어

시간 지연을 갖는 신경회로망 구조(TDNN : Time Delay Neural Network)는 일반적인 신경회로망 구조의 변형으로 그림 2과 같다.




그림 2. 시간 지연을 갖는 신경회로망 구조  
Fig 2. Time Delay Neural Network Construction

학습 과정은 일반적인 다층 신경회로망 구조 학습 알고리즘을 사용하며, 학습 성능이 일반적인 다층 신경회로망 보다 우수하여 패턴 인식에 상당히 많이 응용된다.[13] TDNN의 뉴런은  $f_j(t)$  뿐만 아니라 K 만큼 지연된 벡터들을 입력으로 받는다. 이것은 신경회

로망의 뉴런이 현재의 입력 신호와 시간 지연된 입력들을 받아 현재의 입력 신호와 앞 뒤 사이의 신호에 대한 동적인 시간 정보를 추출하여 보다 적응력이 있는 학습을 할 수 있다.

본 장에서 적용할 TDNN 다층 신경회로망 구조는 2개의 은닉층을 가지는 그림 3과 같으며 두번째 은닉층 뉴런이 시간 지연 요소를 가지는 것으로  $net_{pi}$ 는 다음식으로 표시된다.

$$net_{pi} = \sum_{j=1}^n \{ W_{ij}(t)O_j(t) + W_{ij}(t-1)O_j(t-1) + W_{ij}(t-2)O_j(t-2) + W_{ij}(t-3)O_j(t-3) \} + bias_i(t) \quad (8)$$

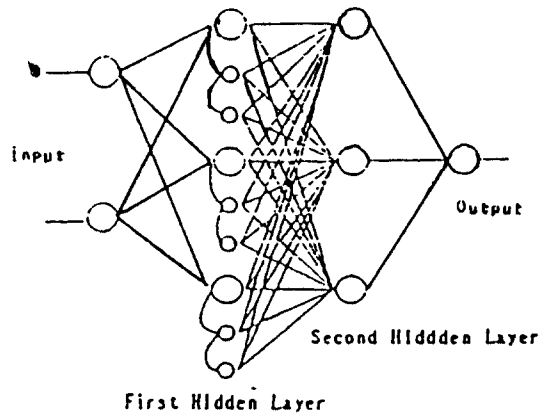


그림 3. 시간 지연을 가지는 다층 신경회로망  
Fig 3. Time Delay Neural Network

그림 3과 같이 두 번째 은닉층 뉴런이 시간 지연 요소를 가지는 제안된 TDNN 다층 신경회로망 학습 알고리즘을 이용한 로봇 매니플레이터 동특성에 대한 전체적인 제어기 구성은 그림 4와 같다.

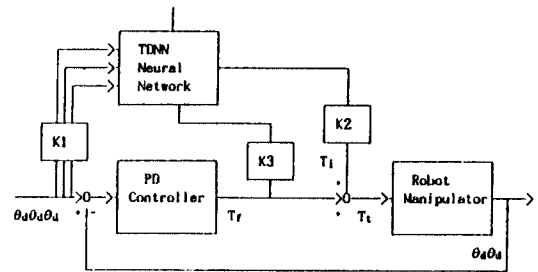


그림 4. 신경 회로망을 사용한 매니플레이터 제어기  
Fig 4. Manipulator controller by using neural network

그림 4에서  $T_1$ 는 비례 미분 제어기의 되먹임 제어기 출력 토크를 나타내고,  $T_2$ 는 신경회로망을 사용한 제어기의 앞먹임 제어기 출력 토크를 나타낸다. 그리고  $T_3$ 는 되먹임 제어기 토크  $T_1$ 와 앞먹임 제어기 토크  $T_2$ 의 합을 나타낸다. 매니플레이터의 궤적을 제어하는 실제 토크는  $T_3$ 에 의해서 이루어진다.

신경회로망 제어기는 학습 초기에는 로봇트의 동특성을 모르기 때문에 임의의 작은 연결 정도값을 가지며 PD 제어기의 오차 출력을 감소시키는 방향으로 학습한다. 학습을 하기 전인 초기 상태에서의 주된 제어기는 선형 제어기가 되지만 학습을 충분히 하고 난 후에는 신경회로망 제어기가 주된 제어기가 된다. 신경회로망의 입력은 원하는 관절각, 각속도, 각가속도를  $K1$ 에 의해  $+1$ 과  $-1$  사이로 정규화시켜서 입력하고 신경회로망의 출력 토크는  $K2$ 에 의해 주어진 궤적에 따른 토크값 사이로 정규화 하고, 신경회로망의 학습 오차로 사용되는 되먹임 토크는  $K3$ 에 의해  $+1$ 과  $-1$  사이로 정규화 시켰다. 또한 이러한 PD 제어기는 신경회로망 학습시 필요한 오차 신호로 사용될 뿐만아니라 매니플레이터의 갑작스런 부하 변화에 대한 강건한 제어기로도 사용된다.

이러한 TDNN 다층 신경회로망 제어기는 매니플레이터의 동역학 모델을 사전에 알 필요가 없이 단지 주어진 기준 입력 궤적과 되먹임 PD 제어기의 출력 토크만으로 매니플레이터의 역동역학 모델을 학습한다.

#### IV. 시뮬레이션 및 결과고찰

제안된 TDNN 다층 신경회로망 학습 제어기의 성능을 평가하기 위하여 2 자유도를 갖는 매니플레이터에 학습 제어기를 적용하였다.

샘플링 시간은 0.01초, 관절 길이  $L_1=0.5(m)$ ,  $L_2=0.5(m)$ , 관절 끝점질량  $M_1=2.3(kg)$ ,  $M_2=2.3(kg)$ 으로 설정하였으며, 부하는 0.1, 0.2, 0.3, 0.5, 1(kg)으로 변화시켰다.

다층 신경회로망 학습 알고리즘에 사용되는 학습율  $\eta$ 는 0.5, 운동량  $\alpha$ 는 0.1로 설정하였으며, 학습에 사용되는 원하는 출력과 실제 출력의 차이가 되는 오차는 식 (9)의  $T_1$ 가 사용된다.

그림 5, 6, 7는 관절 1의 기준 관절각, 각속도 및 각가속도를 나타낸다.

그림 8, 9, 10는 관절 2의 기준 관절각, 각속도, 각가속도를 나타낸다.




그림 5. 원하는 관절각(관절 1)  
Fig 5. Desired Joint Angle(Joint 1)




그림 6. 원하는 각속도(관절 1)  
Fig 6. Desired Angle Velocity(Joint 1)




그림 7. 원하는 각가속도(관절 1)  
Fig 7. Desired Angle Acceleration(Joint 1)




그림 8. 원하는 관절각(관절 2)  
Fig 8. Desired Joint Angle(Joint 2)




그림 9. 원하는 각속도(관절 2)  
Fig 9. Desired Angle Velocity(Joint 2)




그림 10. 원하는 각가속도(관절 2)  
Fig 10. Desired Angle Acceleration(Joint 2)

선형 PD 제어기는 다음식으로 표현된다.

$$T_f = K_p(\theta_d - \theta) + K_d(\dot{\theta}_d - \dot{\theta}) \quad (9)$$

여기서, 비례 제어기 이득  $K_p = 300$ , 미분 제어기 이득  $K_d = 30$ 으로 설정하였다. 이러한 PD 제어기의 이득 파라미터 값은 설정된 오차 방정식의 안정도를 따져서 결정하였다. 그림 11은 신경회로망이 학습을 하기전인 단지 선형 PD 제어기만 사용시의 관절 1의 추종 궤적을 나타내고, 그림 12은 관절 2의 추종 궤적을 나타낸다.




그림 11. PD 제어기만 사용시 추종 궤적(관절 1)  
Fig 11. Tracking Trajectory on PD Controller(Joint 1)




그림 12. PD 제어기만 사용시 추종 궤적(관절 2)  
Fig 12. Tracking Trajectory on PD Controller(Joint 2)

신경회로망 제어기의 모든 연결 강도의 초기치는 -1과 1 사이의 임의의 값으로 주었다. 입력층 뉴런의 수는 각 관절의 원하는 관절각, 각속도, 각가속도로 6개이며, 이때 정규화시키는 K1의 값은 1/3로 설정하였다. 두개의 은닉 계층을 사용하였으며 각각 15개와 15개의 뉴런을 사용하였다.

출력층은 매니플레이터의 관절 1, 2의 토크로서 2개의 뉴런을 사용하였다.

신경회로망의 출력 토크를 정규화시키는 K2의 값은 관절 1에 대해서는 35로, 관절 2에 대해서는 30으로 설정하였으며, 학습 오차로 사용되는 되먹임 토크에 대한 K3의 값은 관절 1에 대해서 1/35로, 관절 2에 대해서는 1/30으로 설정하였다.

그림 13은 1번 학습시의 관절 1의 추종 궤적을 나타내고, 그림 14은 관절 2의 추종 궤적을 나타낸다. 그림 15는 30번 학습시의 관절 1의 추종 궤적을 나타내고, 그림 16은 관절 2의 추종 궤적을 나타내며, 거의 원하는 궤적을 잘 추종함을 알 수 있다.

그림 17, 18은 1번 학습시 관절 1, 2에 대한 속도 추정 궤적을 나타내고 그림 19, 20은 30번 학습시 관절 1, 2에 대한 속도 추종 궤적을 보인 것으로 비교적 잘 추종하고 있음을 알 수 있다.

그림 21는 30번 학습시 추종 궤적의 평균 자승 오차를 나타낸다.

그림 22은 일반적인 다층 신경회로망 제어기와 제안된 TDNN 다층 신경회로망 제어기의 30번 학습시




그림 13. 1번 학습시 추종 궤적(관절 1)  
Fig 13. Tracking Trajectory on 1 Learning(Joint 1)




그림 15. 30번 학습시 추종 궤적(관절 1)  
Fig 15. Tracking Trajectory on 30 Learning (Joint 1)




그림 14. 1번 학습시 추종 궤적(관절 2)  
Fig 14. Tracking Trajectory on 1 Learning(Joint 2)




그림 16. 30번 학습시 추종 궤적(관절 2)  
Fig 16. Tracking Trajectory on 30 Learning (Joint 2)




그림 17. 1번 학습시 속도 추종 궤적(관절 1)  
Fig 17. Velocity Tracking Trajectory on 1 Learning (Joint 1)




그림 20. 30번 학습시 속도 추종 궤적(관절 2)  
Fig 20. Velocity Tracking Trajectory on 30 Learning (Joint 2)




그림 18. 1번 학습시 속도 추종 궤적(관절 2)  
Fig 18. Velocity Tracking Trajectory on 1 Learning (Joint 2)




그림 21. 30번 학습시 평균 자승 오차 수렴도(관절 1, 2)  
Fig 21. Convergence of Error Mean Square on 30 Learning (Joint 1, 2)




그림 19. 30번 학습시 속도 추종 궤적(관절 1)  
Fig 19. Velocity Tracking Trajectory on 30 Learning (Joint 1)




그림 22. 30번 학습시 평균 자승 오차 수렴도(관절 1)  
Fig 22. Convergence of Error Mean Square on 30 Learning (Joint 1)

의 평균 자승 오차의 수렴도를 나타내는 것으로 TDNN 다층 신경회로망 제어가 더욱 효율적인 것임을 알 수 있다.

그리고 매니플레이터의 동특성 변화에 따른 제안된 신경회로망의 적응성을 고찰하기 위하여 매니플레이터의 외란으로 작용하는 부하를 0, 0.2, 0.3, 0.5, 1(Kg)으로 각각 설정하여 신경회로망이 15번째 반복 학습시에 변화시켰다. 이러한 경우에는 신경회로망이 이미 학습한 것을 기초로하여 새로운 변화를 극복하도록 학습한다.

그림 23은 매니플레이터의 부하를 0, 0.2, 0.3(Kg)




그림 23. 부하 변화시 평균 자승 오차 수렴도(관절 1)  
Fig 23. Convergence of Error Mean Square on Load Changing(Joint 1)




그림 24. 부하 변화시 평균 자승 오차 수렴도(관절 1)  
Fig 24. Convergence of Error Mean Square on Load Changing(Joint 1)

으로 각각 변화시켰을 때의 관절 1에 대한 평균 자승 오차 수렴도를 나타내고, 그림 24는 부하를 0, 0.5, 0(Kg)으로 각각 변화시켰을 때의 관절 1에 대한 평균 자승 오차 수렴도를 보인 것으로 제안된 TDNN 다층 신경회로망이 제어 환경의 변화에 따른 매니플레이터의 동특성 변화에 잘 적응하고 있음을 알 수 있다.

### V. 결 론

본 논문에서는 TDNN 다층 신경회로망 학습 알고리즘을 이용하여 로봇트 매니플레이터의 역동력학 모델을 학습하여 이것을 매니플레이터의 앞먹임 제어기로 사용하여 관절 궤적을 제어하는 방법을 제시하였다.

매니플레이터의 제어기는 TDNN 다층 신경회로망을 앞먹임 제어기로, 기존의 PD 제어기를 되먹임 제어기로 사용하여 이들 두 제어기의 출력의 합은 매니플레이터의 추종 오차를 감소시키도록 설계하였다. TDNN 다층 신경회로망은 두번째 은닉층 뉴런이 첫번째 은닉층의 시간 지연된 요소를 받아들여 매니플레이터의 역동력학 모델을 학습하는 구조를 사용하였다.

제안된 제어기는 복잡한 동역학 모델 표현식을 알 필요가 없이 원하는 기준 궤적을 입력으로 사용하므로서 제어기 설계가 간단하고 제어 성능도 우수하였다. 그리고 다층 신경회로망에 비하여 학습 시간은 많이 필요하지만 학습 효율은 보다 향상되었음을 보였다.

제안된 제어기의 적응성을 고찰하기 위하여 15번째 반복 학습이 끝난 직후에 부하를 변화시킨 결과 매니플레이터 동특성에 잘 적응함을 확인하였다.

이러한 신경회로망 제어기는 비교적 간단하게 제어칙을 학습할 수 있으므로 반복적인 작업을 계속해서 수행하는 산업용 로봇트에 효과적으로 응용할 수 있으리라 기대된다.

### 참 고 문 헌

1. D. E. Rumelhart, G. E. Hinton, and J. L. McClelland, Eds., Parallel Distributed Processing, MIT Press, Vol.I, 1968.
2. M. Miyamoto, M. Kawato, etc, "Feedback error learning neural network for trajectory con-



