

## 신경회로망을 이용한 산업용 매니플레이터의 견실성 해석

### ( Robustness Analysis of Industrial Manipulator Using Neural-Network )

이 진

경남대학교 기계공학부 , 경남 마산시 월영동 449번지 631-701

#### Abstract

In this paper, it is presents a new approach to the design of neural control system using digital signal processors in order to improve the precision and robustness. Robotic manipulators have become increasingly important in the field of flexible automation. High speed and high-precision trajectory tracking are indispensable capabilities for their versatile application. The need to meet demanding control requirement in increasingly complex dynamical control systems under significant uncertainties, leads toward design of intelligent manipulation robots. The TMS320C3x is used in implementing real time neural control to provide an enhanced motion control for robotic manipulators. In this control scheme, the networks introduced are neural nets with dynamic neurons, whose dynamics are distributed over all the network nodes. The nets are trained by the distributed dynamic back propagation algorithm. The proposed neural network control scheme is simple in structure, fast in computation, and suitable for implementation of robust control.

#### 1. 서 론

신경회로망을 이용한 제어기법은 종래의 제어기법에서 볼 수 없었던 병렬형 및 학습 기능에 그 우월성이 나타난다고 할 수 있다. 즉 신경 제어는 모든 계산이 각 뉴런에서 독립적으로 병렬

처리되므로 실시간 제어가 가능하고, 학습된 제어정보가 분산 저장되므로 입력 정보에 잡음이 섞이는 경우에도 안정된 동작을 한다(2)(3). 따라서 시스템의 특성이 불확실한 경우에서도 신경망 학습 원리를 통하여 전체 시스템에 많은 영향을 미치는 제어 이득을 보상해 주는 가변 제어 이득의 역할을 하여 전체 제어 시스템의 빠른 수렴성을 보장하면서 간단한 구조로 설계될 수 있는 제어기법이라 할 수 있다(1)(5). 이러한 특성에 따라 근래에 들어 신경망에 대한 연구 활성화되고 있다.

본 연구에서 채택한 신경 제어 기법은 제어 대상체인 매니플레이터의 근사화된 모델링이 가능하여 신경 제어기반으로는 늘어날 수 있는 목표 학습까지의 시간을 단축하면서, 운동 상태에 따라 변화되는 관성 파라미터 및 마찰항등을 추정하는 오차 역동역학 기법으로 유도된 신경 제어 알고리즘을 사용한다.

지금까지 발표된 많은 신경회로망 모델중 제어 문제에 가장 많이 적용되는 모델은 다층 퍼셉트론이다. 이러한 다층 신경 회로망에서 원하는 기능을 수행하기 위한 적절한 가중치를 구하는 방법으로 오차 역전파학습이 많이 사용되고 있다. 이것은 다층구조에서의 학습법으로써 오차 역전파학습이 가장 효율적이라는 것을 반증하는 것이라 할 수 있다. 그러나 기존의 일반화된 역전파 학습법은 정적 뉴런에 의한 학습으로 환경이 다양하게 변화하는 동적 상태의 로봇 매니플레이터(4)의 동적 특성에 적절히 학습 할 수 없다는 단점이 있다. 그래서 본 논문에서는 이러한 단점을 보완하는 다이내믹뉴런으로 구성된 개선된 역전파 학습척을 제안한다.

제안된 제어기와 학습 방식을 시뮬레이션을 통해서 그 타당성을 확인하고 실제 로봇을 통해서 제안한 제어기의 신뢰성을 입증하였다. 이를 위해, 4자유도 스카라 로봇 매니퓰레이터의 신속하고 정밀한 위치 및 속도 제어를 위하여 32 bits 마이크로 프로세서 역할을 하는 고속 수치 전용 칩인 TI사의 TMS320C31 디지털 신호 처리기를 이용하여 실시간 제어가 가능한 2축 동시 제어용 관절 제어기를 설계하였다. 또한 제안된 신경 제어 알고리즘에 대한 어셈블러 S/W를 개발하여 설계된 관절 제어기를 이용한 실제 스카라 로봇의 위치 및 속도에 대한 성능 시험을 실험을 통하여 불확실성 및 비선형을 내포하고 있는 로봇 시스템의 실시간 제어의 가능성을 여러 가지 조건에 대한 실험을 통하여 입증하고자 한다.

## 2 뉴런 네트워크의 구조

본 연구에서 제안되는 신경망회로의 기본 구조에서의 최종 출력 벡터는 다음과 같이 정의된다.

$$\tau_{nn} = \sum W_{jk} f(\sum W_{ij} X - \theta_j) - \theta_k \quad (1)$$

여기서,  $X$ 는 입력 벡터를 나타내고,  $\theta_j$  및  $\theta_k$ 는 각각  $j$  및  $k$ 층의 임계 상수를 나타낸다. 그리고  $f(\cdot)$ 는 출력함수로서 시그모이드 함수를 나타낸다. 식 (1)의 각 변수는 다음과 같이 정의된다.

$$X = [ \ddot{a}_d \quad \dot{a}_d \quad a_d ]^T$$

$$\theta_j = \theta_j + \beta \delta_j, \quad \theta_k = \theta_k + \beta \delta_k$$

$$f(u) = \frac{1}{1 + \exp(-u)}, \quad \dot{f}(u) = f(u)(1 - f(u))$$

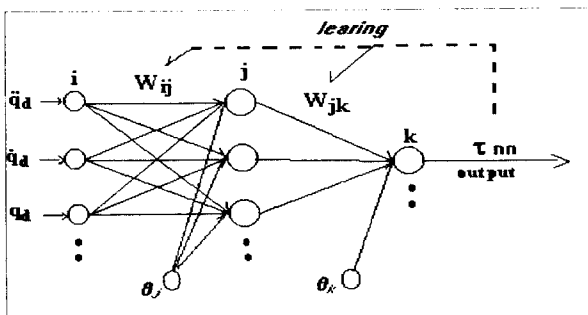


Fig. 1. Neural Network Structure

Fig. 1. 은 제안한 신경망의 구조를 나타내는 것으로, 입력층과 비선형 은닉층 그리고 선형 출력층 뉴런으로 이루어진 다층 뉴런 구조로 구성된다. 매니퓰레이터 동적 방정식은 다음과 같은 다층 구조의 신경망으로 모델링 될 수 있다.

$$n_k = \sum_{j=1}^{N_j} w_{jk} y_j \quad (2)$$

$$\dot{x}_k = -m_k(x_k) [ l_k(x_k) + n_k ] \quad (3)$$

$$y_k = f(x_k) \quad (4)$$

여기서,  $y_k, y_j$ 는 각각  $k$  및  $j$ 층의 출력을 나타내고,  $x_k$ 는  $K$ 층에서의 뉴런 동적 상태변수로 정의한다. 그리고  $m_k$ 와  $l_k$ 는 각각 상수 및 선형함수로 정의되고,  $w_{jk}$ 는  $k$ 층과  $j$ 층사이의 연결강도를 나타낸다. 또한  $N_k, N_j$ 는 각각  $k$ 층 및  $j$ 층에서의 뉴런의 총 갯수를 나타낸다.

식 (2)에서의 연결강도의 갱신은 다음과 같이 정의된다.

$$\dot{w}_{jk}(t) = -\eta \frac{\partial E}{\partial w_{jk}(t)} \quad (5)$$

$$\dot{\theta}_k(t) = -\eta \delta_k y_j \quad (6)$$

여기서, 오차 함수  $E$ 는 식 (7)과 같이 정의되고, 그리고 오차 신호  $\delta_k$ 는 식 (8)과 같이 정의된다.

$$E = \frac{1}{2} \sum (d_k - y_k)^2 \quad (7)$$

$$\delta_k = \frac{\partial E}{\partial n_k} \quad (8)$$

따라서, 식 (5)로부터 각층 사이의 오차 신호를 다음과 같은 방법으로 계산 할 수 있다.

i) 출력층에서의 연결강도의 갱신.

체인룰에 따라 오차 신호  $\delta_k$ 을 정리하면 다음과 같다.

$$\delta_k = \frac{\partial x_k}{\partial n_k} \frac{\partial y_k}{\partial x_k} \frac{\partial E}{\partial y_k} \quad (9)$$

여기서,

$$\frac{\partial E}{\partial y_k} = -(d_k - y_k) = -e_k \quad (10)$$

$$\frac{\partial y_k}{\partial x_k} = f(x_k) \quad (11)$$

$$\frac{\partial x_k}{\partial n_k} \frac{\partial n_k}{\partial t} = \dot{x}_k \quad (12)$$

$$\begin{aligned} \frac{\partial n_k}{\partial t} &= \frac{\partial (\sum_{j=1}^{N_j} (w_{jk} y_j))}{\partial t} = \sum_{j=1}^{N_j} (w_{jk} \frac{\partial y_j}{\partial x_j} \dot{x}_j) \\ &= \sum_{j=1}^{N_j} (w_{jk} f(x_j) [ -m_j(x_j) [ l_j(x_j) + n_j ] ]) \quad (13) \end{aligned}$$

ii) 은닉층에서의 연결강도의 갱신.

은닉층과 출력층사이의 연결강도 갱신은 다음과 같이 정의된다.

$$\dot{w}_{ij}(t) = -\eta \delta_j y_i$$

여기서,

$$\delta_j = \sum_{k=1}^{N_k} \left( \frac{\partial E}{\partial n_k} \frac{\partial n_k}{\partial y_j} \right) \frac{\partial y_j}{\partial x_j} \frac{\partial x_j}{\partial n_j} \quad (14)$$

$$= \frac{\sum_{k=1}^{N_k} [ (\delta_k w_{jk}) f(x_j) ] [ -m_j(x_j) [ l_j(x_j) + n_j ] ]}{\sum_{i=1}^{N_j} (w_{ij} f(x_i) [ -m_i(x_i) [ l_i(x_i) + n_i ] ] )}$$

Fig. 2. 는 전체 제어계의 구성을 나타내는 블록선도이다.

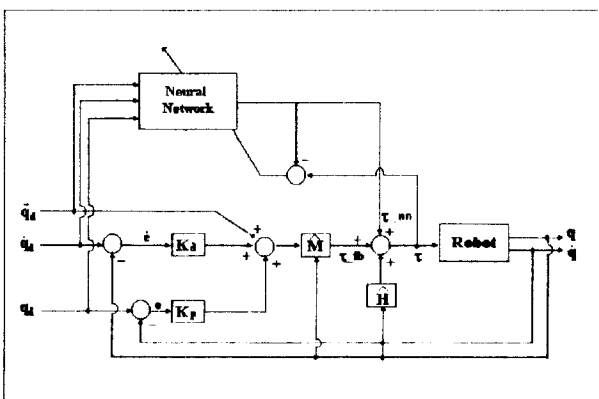


Fig. 2 The block diagram of proposed neural control Structure for robot manipulator

구조 불확실성 및 비 구조적 불확실성으로부터 발생하는 오차를 보상하기 위한 뉴럴 피드포워드 제어신호 및 피드백 제어신호를 이용하여 전체제어기의 오차 방정식을 유도하면 다음과 같다.

$$\begin{aligned} \hat{M}(q)u^* + \hat{h}(q, \dot{q}) + \tau_{nn} \\ = M(q)\ddot{q} + h(q, \dot{q}) + F(\dot{q}) \quad (15) \end{aligned}$$

$$u^* = \ddot{q}_d + K_d(\dot{q}_d - \dot{q}) + K_p(q_d - q) \quad (16)$$

이를 다시 표현하면 다음과 같다.

$$\begin{aligned} \ddot{e} + K_d\dot{e} + K_p e = \hat{M}(q)^{-1} [ \Delta M(q)\ddot{q} \\ + \Delta h(q, \dot{q}) + F(\dot{q}) - \tau_{nn} ] \quad (17) \end{aligned}$$

여기서, 우변의 항은

$$\Delta M(q)\ddot{q} + \Delta h(q, \dot{q}) + F(\dot{q}) = \tau_{learning} \quad (18)$$

로 정의하여, 신경망의 학습 신호로 적용하면 점진적으로 우변이 영으로 수렴하게 되어 이상적인 시스템에 접근하게 된다.

만약,  $\Delta M = \Delta h = 0$  그리고  $F = 0$ 이 되는 것과 같은 결과가 되도록 제어 입력 값이 갱신되어 진다면 가장 이상적인 상태로서 우변 항은 영이다, 그러나 이상적인 상태가 되지 않는다면 학습하여 갱신되어야 할 오차 신호는 다음과 같이 정의된다.

$$\begin{aligned} \tau - \tau_{nn} &= [ \Delta M(q)\ddot{q} + \Delta h(q, \dot{q}) + F(\dot{q}) ] - \tau_{nn} \\ &= \hat{M}(q)^{-1} [ \ddot{e} + K_d\dot{e} + K_p e ] \quad (19) \end{aligned}$$

### 3. 시뮬레이션

시뮬레이션은 3개의 회전관절과 1개의 병진 관절로 이루어진 스카라 로봇을 대상으로 한다.

Fig. 3. 은 스카라 로봇의 기본 구조를 나타낸다.






Fig. 3. Coordinates frame of SCARA robot.

실험 대상인 스카라 로봇의 작업 특성을 고려하여 대상 기준 위치 함수를 부하하중 2.0kg 상태 하의 정현파함수로 선택하고, 기준 속도 함수는 사다리꼴 파형을 적용하였으며, 학습 반복 횟수는 실제 실험 대상 로봇의 원점복귀 시간을 기준으로 제한하여 결정하였다. 실험 대상 함수는 2사이클을 기준으로 2초동안 수행하는 것으로 학습 횟수를 4회를 기준으로 하여, 적정 범위의 추종 성능안에 포함되도록 하였다. 학습비 및 인계 상수는 0.04 및 0.01을 중심으로 변화시켜 시뮬레이션을 수행하였다.

Fig. 4. 는 정현파 함수에 대한 궤적 추적 결과를 나타낸다. Fig. 5. 는 부하하중 2.0kg 상태하에서 매 학습마다의 추적 오차에 대한 RMS(root mean square)로 적용한 학습성능 평가 결과를 나타낸다. Fig. 6. 은 위치 - 속도 오차공간에서의 궤적추적에 대한 집근적인 수렴성을 나타내는 해석결과이다.



(a) joint 1.



(b) joint 2.

Fig. 4. Simulation result of position and velocity trajectory tracking for joint 1 and joint 2 with 2.0 kg payload




Fig. 5. Tracking error for iterating using RMS.

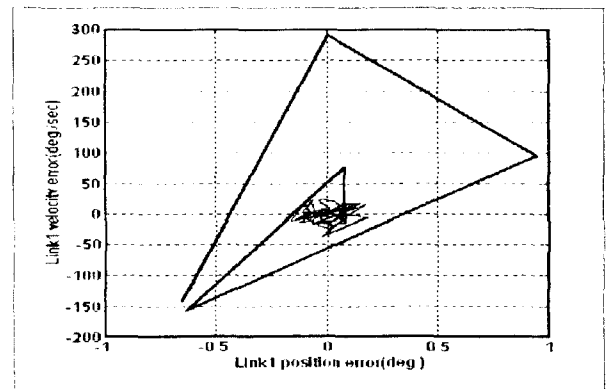


Fig. 6. Performance analysis at error state space.

제어기의 진제 구조는 INTEL 80486 프로세서를 기반으로 하고 real-time OS 사용하여 제어기와 주변기기를 동시 제어하도록 하고 있다. 본 실험에서 사용한 Joint 제어기의 CPU는 TI사의 DSP TMS320C31를 채용하였다. TMS320C31은 33MHZ clock으로 동작하고 1 instruction 수행

시간이 60ns에 이르는 32bit 고속 CPU로, 이를 토대로 1ms의 샘플링 time으로 프로그램을 실행하도록 하였다.

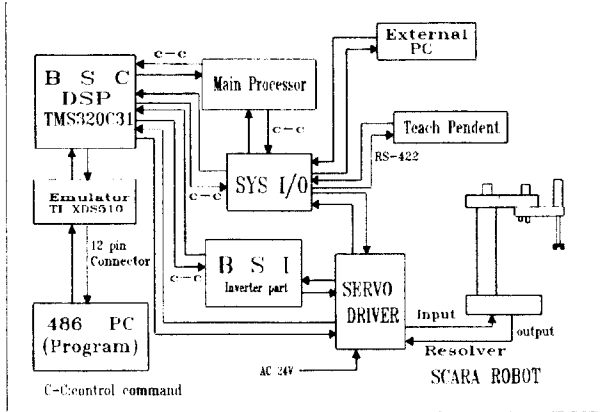


Fig. 7. The block diagram of control system.

Fig. 7. 은 제어기의 전체 구조를 나타낸다. 전체 제어기의 구성은 power supply, servo BSI, noise filter 및 각각의 역할을 수행하는 보드들로 구성되어 있다. 각 구성체간의 통신은 주제어기가 주(host)가 되고 BSC등 나머지는 종(slave)이 되어 명령을 수행한다.




Fig. 8. Experimental set-up.

#### 4. 결과 및 검토

실제된 디지털 뉴럴 제어기의 성능 실험을 위하여 스카라 로봇의 각 관절에 대한 위치 및 속도 추종 제어 성능 실험을 수행하였다. 각 관절 제어기는 디지털 신호 처리기인 TMS320C31

을 사용한 관절 제어기를 설계하였으며, 제어 알고리즘으로는 TMS320C3x의 어셈블리로 직접 개발한 S/W를 사용하였다.

개발한 어셈블리 프로그램은 16ms 마다 goal position를 받아, 1ms 마다 interpolation 하여 위치 루프로 보내도록 구성되었으며, 학습을 위한 반복 시간을 원점 복귀 이행 시간안에 최자의 학습비로 연결강도를 갱신도록 하였다.

실험에 사용한 ROBOT는 스카라형 로봇인 FARA SM5 모델을 이용하였다, 각 관절의 감속기로는 1축과 2축은 하모닉드라이브, 3축과 4축은 볼스큐류 및 타이밍벨트가 사용되었으며, 각각 감속비가 1축과 2축은 50 대 1, 3축과 4축은 각각은 45 대 1 과 12 대 1로 되어 있다.

본 실험에서 적용하여 사용한 에뮬레이터는 TI XDS510 으로 486 PC와 통신하도록 하여, 실험된 data를 각각 1축과 2축, 3축과 4축 별로 동시에 두축의 data를 2ms 마다 메모리 순환 저장방식으로 저장하고, 이를 intel hex object format file로 전환하여 10진수로 데이터를 분석할 수 있도록 하였다. 형에 대한 데모 실험을 수행하였다.

Fig. 9. 은 반복 정밀도 실험을 위한 공간 좌표상의 기구학적 형상을 도식화한 것이며, 이를 바탕으로 실험한 결과를 Fig.10. 와 Fig. 11.에 나타내었다. 실험 결과 기존의 제어기에 비하여 제안된 뉴럴제어기의 성능이 정밀도 및 견실성 면에서 크게 향상된 사실이 입증되고 있다.




Fig. 9. Kinematic configuration of repeating precision.

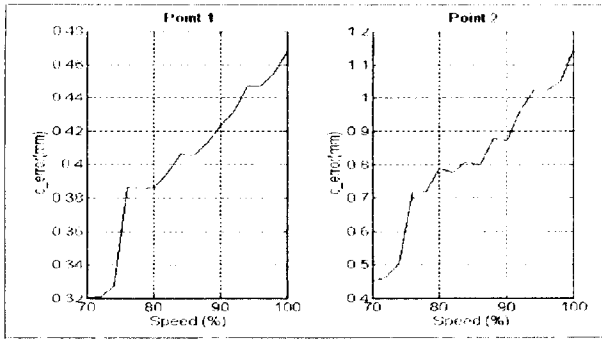


Fig. 10. Experimental results of neural controller for repeating precision at cartesian coordinates.




Fig. 11. Experimental results of existing controller (PID) for repeating precision at cartesian coordinates.

## 5. 결론

제안된 뉴런 제어 네트워크를 이용한 시스템의 특징은 궤적 추적 성능을 향상시키기 위한 뉴런피드포워드 제어신호 및 피드백 제어신호를 이용하여 속응성을 향상시켜 줌으로서, 제안된 뉴런 제어 시스템은 다관절 로봇트 매니플레이터와 같이 시스템이 복잡하여 동작상태의 물리적인 파라미터가 정확하게 측정될 수 없거나 혹은 부하 질량이 실질적으로 매우 많이 변화되는 경우에서도 실시간 제어가 가능한 제어 방법이라 할 수 있다. 또한 제안된 학습방법인 다이내믹 뉴런으로 구성된 개선된 오차 역전파 학습 모델이 실제 로봇트 작동에서도 적절한 학습을 수행하고 있음을 확인할 수 있었다.

## 참고문헌

- (1) K.Guglielmo and N. Sadch, " Experimental evaluation of a new robot learning controller", Proc. 1991 IEEE Int. Conf. on robotics and Automation, pp.734-739, Sacramento,CA, April 1991.
- (2) T.Poggio and F.Girosi, " Networks for approximation and learning " proceeding of the IEEE, vol. 7, No.9, pp.1481-1497, 1990.
- (3) D. Psaltis, A. Sidoris, and A. Yamamura, "A Multilayered Neural Network controller", IEEE Control Systems Magazine, pp.17-21, April, 1988.
- (4) H.Seraji, " An Approach to Multivariable Control of Manipulator," ASME J. Dyn. Syst., Meas., Contr., Vol.109, pp.485-493, 1987.
- (5) K.Watanabe and S.G. Tzafestas, "Learning Algorithms for Neural Networks with the Kalman Filters", J. Intelligent and Robotic Systems, Vol.3, No.4, pp305-319, 1990.