

## 퍼지 논리를 이용한 로보트 매니퓰레이터의 신경 제어기

·김 종 수\*, 이 흥 기\*\*, 전 흥 태\*

\*중앙대학교 전자공학과, \*\*중앙대학교 제어계측공학과

## Neuro Controller of The Robot Manipulator Using Fuzzy Logic

·Jong-Soo Kim\*, Hong-Gi Lee\*\*, Hong-Tae Jeon\*

\*Dept. of Electronics Engineering, Chung-Ang Univ.

\*\*Dept. of Control & Instrumentation Eng. Chung-Ang Univ.

### ABSTRACT

The multi-layer neural network possesses the desirable characteristics of parallel distributed processing and learning capacity, by which the uncertain variation of the parameters in the dynamically complex system can be handled adaptively. However the error back propagation algorithm that has been utilized popularly in the learning procedure of the multi-layer neural network has the significant limitations in the real application because of its slow convergence speed.

In this paper, an approach to improve the convergence speed is proposed using the fuzzy logic that can effectively handle the uncertain and fuzzy informations by linguistic level. The effectiveness of the proposed algorithm is demonstrated by computer simulation of PUMA 560 robot manipulator.

### 1. 서론

일반적으로 로보트 매니퓰레이터의 신경망 제어방식은 역기구학의 모델링에 의한 기구학적 방식과 역동학적 모델링하는 동력학적 방식으로 대분되고 있다. 역동학적 방식은 기구학적 방식보다 복잡하고 어려우나 로보트의 비선형과 중첩(coupled)된 동적 특성을 고려하기 때문에 많은 연구자들에 의해 선호되고 있다.

로보트 매니퓰레이터의 제어 시스템을 개발하기 위한 본 논문에서는 제어 대상의 동적 특성과 환경 모델링이 불 필요하고, 제어 성능을 자체 학습에 의해 항구적으로 개선할 수 있으며 병렬 계산 처리를 할 수 있는 동력학적 신경 제어 기법을 도입한다. 그리고 제안된 로보트 매니퓰레이터의 신경제어기는 다음과 같은 특징을 갖도록 한다.

- 1) 로보트의 동적 특성에 대한 정확한 사전 정보 없이도 제어가 가능한 제어 시스템
- 2) 최소 위치 오차에로의 빠른 수렴성을 보장할 수 있는 신경 제어 시스템

신경 제어기 설계에 있어 활용할 수 있는 신경망 구조들은 Hopfield network을 포함한 여러 형태들이 있으나 최근 불확실한 플랜트 제어에 많이 활용되는 다층 신경 회로망 구조를 본 로보트 매니퓰레이터의 제어기 설계에 이용 한다. 그리고 훈련 방법으로 대표적인 오차 역전파 (error back propagation) 학습 알고리즘을 채택하고 있다[4][6][11]. 그러나 역전파 학습 알고리즘은 느린 학습 수렴속도로 실제 응용시 그 효용 가치를 잃게되는 중대한 문제점을 갖는다 [1][2][6].

다층 신경 회로망의 느린 학습 속도는 주로 부적절한 가중치(weight)들의 설정으로 인해 발생하는 각 뉴런의 조기 포화

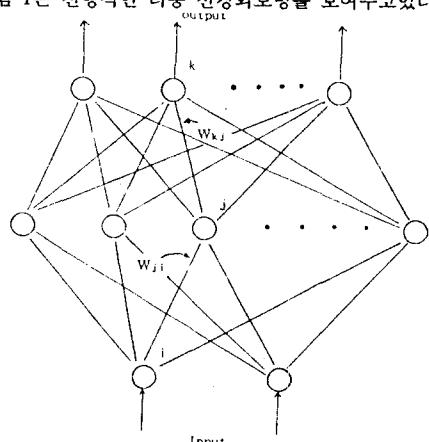
상태(premature saturation)에 기인되고 있다. 즉, 신경망을 구성하는 어느 한 뉴런이라도 조기포화상태에 있을 경우 가중치의 큰 변화에도 불구하고 실제 오차의 변화량은 미미하게 된다. 따라서 빠른 학습 수렴 속도를 얻기 위해서는 뉴런의 조기 포화 상태를 감지하고, 조기 포화 상태에서 활성화 함수(activation function)의 기울기들을 적절히 변화 시켜 그 상태를 벗어나게 해야 한다.

본 논문에서는 이러한 포화상태를 미리 감지할 수 있고 동시에 포화상태에서 기울기의 적절한 변화를 통해 다층 신경망의 빠른 수렴성을 보장할 수 있는 방식을 제시한다. 제안하는 방식은 논리 및 추론(inference)의 잇점들을 갖는 퍼지 논리(fuzzy logic) 기법을 응용하여 뉴런의 활성화 함수의 기울기를 가변시키는 방식이다. 그리고 이 퍼지-뉴럴 기법을 이용 기존의 신경 제어기보다 학습 수렴속도가 크게 개선된 로보트 매니퓰레이터의 위치 제어시스템을 최종적으로 개발 한다.

한편 본 논문의 구성은 다음과 같다. 2장에서는 다층 신경회로망 구조와 대표적인 학습방법인 오차 역전파 학습 규칙(error back propagation learning rule)의 수렴성에 관한 문제점을 파악하고, 수렴속도를 개선하기 위한 퍼지-뉴럴 기법을 3장에서 제안한다. 그리고 4장에서는 3장에서의 퍼지-뉴珥 기법을 이용한 로보트 매니퓰레이터의 위치 제어기를 구성하고 5장에서는 컴퓨터 모의 실험과 그 결과를 보여준다. 끝으로 6장에서는 본 논문의 결론을 기술한다.

### 2. 다층 신경망의 역전파 학습 알고리즘과 문제점

그림 1은 전형적인 다층 신경회로망을 보여주고 있다.



$w_{kj}$  : 출력층 뉴런  $k$  와 중간층 뉴런  $j$  사이의 가중치  
 $w_{ji}$  : 중간층 뉴런  $j$  와 입력층 뉴런  $i$  사이의 가중치

그림 1. 다층 신경회로망의 구조

Fig. 1 Structure of multi-layer neural network

상기 다중 신경망을 구성하는 각 뉴런의 입. 출력 특성(그림 2 참조)은 출력단의 k번째 뉴런을 예를 들면 다음의 수학적 모델링을 갖는다[11].

$$f(a, net_k) = \frac{1}{1 + \exp(-a \cdot net_k)} \quad (1a)$$

$$net_k = \sum_j (W_{kj} \cdot OUT_j) \quad (1b)$$

$$OUT_k = f(net_k) \quad (1c)$$

여기에서,  $OUT_j$ 는 중간층에서 뉴런  $j$ 의 출력이며  $W_{kj}$ 는 출력층의 뉴런  $k$ 와 중간층의 뉴런  $j$  사이의 가중치(weight)를 나타낸다. 그리고  $a$ 는 뉴런 활성화 함수의 기울기를 나타내는 계수이다.

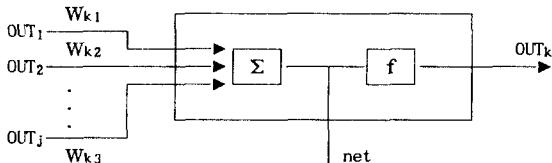


그림 2. 인공 뉴런의 계산 구조  
Fig.2 Computational structure of artificial neuron

그림 1의 다중 신경망 출력단에서 전체 오차는 각 뉴런의 출력과 목표치와의 차이들의 합으로 다음과 같이 구할 수 있다.

$$E = \frac{1}{2} * \sum_k (D_k - OUT_k)^2 \quad (2)$$

여기서,  $D_k$ 는 출력단  $k$ 번째 뉴런의 목표값이며,  $OUT_k$ 는 출력단  $k$ 번째 뉴런의 출력값을 나타낸다.

식 (2)의 오차  $E$ 를 감소 시키기 위한 출력단 가중치들의 변화량은 Gradient descent 방법에 의해 다음과 같이 구할 수 있다.

$$\Delta W_{kj} = -\eta \cdot \frac{\partial E}{\partial W_{kj}}$$

$$= -\eta \cdot \frac{\partial E}{\partial net_k} \cdot OUT_j$$

$$= \eta \cdot \delta_k \cdot OUT_j \quad (3a)$$

$$\delta_k = (D_k - OUT_k) \cdot f'(net_k) \quad (3b)$$

여기에서,  $f'(net_k) = \frac{\partial f(x)}{\partial x}$  그리고  
 $net_k = \sum_k W_{kj} \cdot OUT_j$  이다.

또한  $\delta_k$ 는 학습률을 나타내고  $\delta_k$ 는 역 방향으로부터 전달되어오는 오차이다. 식 (3)에 의한 출력단에서 가중치 변화와는 달리 중간층에서의 가중치 변화량  $\Delta W_{ji}$ 는 다음식에 의해 구할 수 있다.

$$\Delta W_{ji} = -\eta \cdot \frac{\partial E}{\partial W_{ji}} \quad (4a)$$

$$= \eta \cdot \delta_j \cdot OUT_i \quad (4a)$$

$$\delta_j = f'(net_j) \cdot \sum_k (\delta_k \cdot W_{kj}) \quad (4b)$$

식 (3)과 (4)를 이용 각 층에서의 새로운 가중치들은 최종적으로 다음식에 의해 조정된다.

$$W_{kj}(t+1) = W_{kj}(t) + \alpha [W_{kj}(t) - W_{kj}(t-1)] \quad (5a)$$

$$W_{ji}(t+1) = W_{ji}(t) + \Delta W_{ji}(t) + \alpha [W_{ji}(t) - W_{ji}(t-1)] \quad (5b)$$

여기서,  $\alpha$ 는 운동량 항(momentum term)이다.

식 (5)를 출력단에서 입력단까지 반복하면 각 뉴런의 출력오차가 감소하도록 가중치가 변하게 되며, 마지막에는 오차가 없게되는 완전한 오차 역전파(error back propagation)학습이 이루어진다.

그러나 식 (3)과 (4)에서  $\delta_k$ 와  $\delta_k$ 값을 결정할 때 오차의 크기에 상관없이 가중치들의 합이 부적절하게 위치하면 활성화 함수의 미분 출력값이 0에 가깝게 되는 이를바 조기포화상태(premature saturation)에 빠지게된다(그림 3 참조). 조기 포화 상태에서 가중치들의 변화량은 매우 작게되며 전체적인 학습 속도에 큰 영향을 미치게된다.

따라서 이러한 조기포화 상태를 미리 감지할 수 있고 그 포화 상태에서 활성화 함수의 기울기를 조절해 주면 용이하게 문제의 조기포화 상태를 벗어나게 할 수 있다. 그림 3은 활성화 함수  $f(a, x)$ 에서 기울기 계수  $a$ 의 변화에 따른 활성화 함수들과 그 일차 미분값, 즉 기울기 변화를 보여주고 있다.

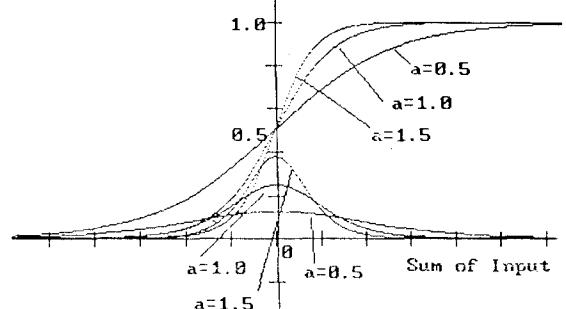


그림 3. 뉴런의 활성화 함수와 기울기

Fig.3 Activation function of the neuron and its slope.

### 3. 퍼지 기법에 의한 개선방법

조기 포화 상태를 감지하여 활성화 함수의 기울기를 변화시켜주는 방법으로 언어적인 표현이 가능한 퍼지논리(fuzzy logic)를 사용한다. 그림 4는 본 논문에서 제안하는 뉴런 활성화 함수의 기울기 변화를 조절하기 위한 퍼지 제어기의 기본 구조도를 보여주고 있다.

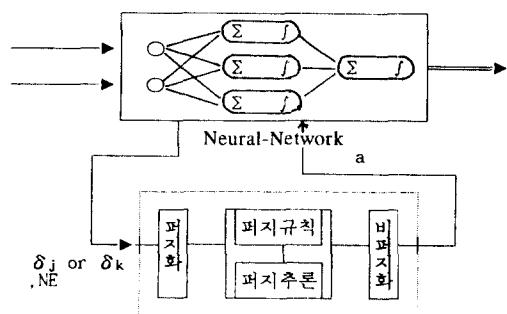


그림 4. 활성화 함수의 기울기 변화를 위한 퍼지 제어기

Fig.4 Fuzzy-neural controller for adjusting the slope of activation function.

그림 4의 각 뉴런에서  $\delta_k$  와  $\delta_j$ 는 위에서 정의한 값이고 뉴런의 출력에서는 다음과 같은 오차 값을 정의한다.(이후  $\delta_k$  혹은  $\delta_j$ 는  $\delta$ 로 정의한다)

$$NE = \frac{1}{2} * (\delta_k - OUT_k)^2 \quad (6)$$

기본 구성도 그림 4의 퍼지화(fuzzification) 과정은 각 뉴런에서 구한 crisp한 수치  $\delta$ 값과 NE(Network Error)값들을 각각 5단계의 퍼지집합으로 변화하여, 여러 퍼지화 방법중 singleton방법을 이용하고 있다(그림 5 참조). 이 퍼지화 과정은 다음식에 의해 표현된다.

$$x = \text{fuzzifier}(NE), y = \text{fuzzifier}(\delta) \quad (7)$$

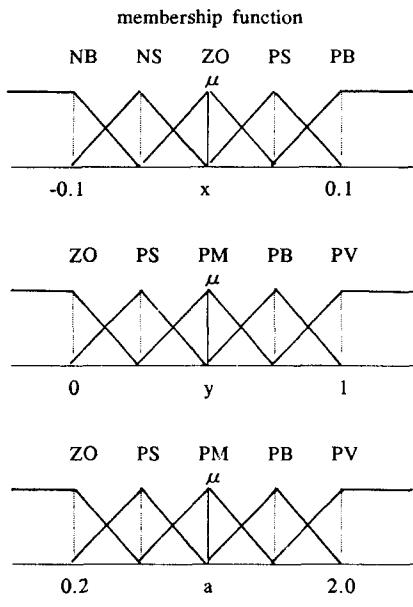


그림 5. x,y,a의 소속함수

Fig.5 Membership function of x,y,a

퍼지화 과정후 추론에 필요한 rule base는 다음과 같은 "IF - THEN" 형식의 규칙들로 구성된다.

$$\text{if } x \text{ is } d_i \text{ and } y \text{ is } e_i \text{ then } a \text{ is } a_i \quad (8)$$

$$i = 1, 2, 3, \dots, 25$$

여기에서  $x, y$ 는 퍼지화된 입력값이며  $d_i, e_i$  그리고  $a_i$ 는 그림 5의 소속함수를 갖는 퍼지집합들이다. 표 1은 그 규칙들을 요약하여 설명하고 있다. 상기 풀 베이스를 이용, 어느 입력에 대한 추론 과정은 Mamdani의 직접 추론법을 이용하였다. 직접 추론과정은 다음과 같다.

$$\mu_i(a) = \min \{ \mu_{d_i}(x), \mu_{e_i}(y), \mu_{a_i}(a) \} \quad (9a)$$

$$\mu(a) = \max \{ \mu_i(a) \} \quad (9b)$$

$$i=1,2,3,4$$

기울기 수정을 위한 퍼지집합  $a_i$ 로부터 crisp한 값을 선정하는 방법으로는 식 (10)을 이용, 비교적 계산이 간단한 무게 중심법(Center of Gravity)을 사용하여 비퍼지화 한다.

$$a^* = \text{Defuzzifier}(\mu(a))$$

$$= \frac{\int \mu(a) a da}{\int \mu(a) da} \quad (10)$$

	x					
	ZO	PS	PM	PB	PV	
NB	PV	PV	PB	PM	PM	NB:Negative Big
NS	PB	PB	PM	PS	PS	NS:Negative Small
ZO	PM	PS	PS	ZO	ZO	ZO:Zero
PS	PB	PB	PM	PS	PS	PS:Positive Small
PV	PV	PV	PB	PM	PM	PV:Positive Very big
PB	PV	PV	PB	PM	PM	PB:Positive Big

표 1. 퍼지 룰 베이스  
Table 1. Fuzzy rule base

#### 4. 로보트 매니퓰레이터 퍼지-뉴럴 제어기

로보트 매니퓰레이터는 highly nonlinear하고 coupled된 동적 특성을 갖고 있으며 내부 및 외부의 작업 조건에 따라 그 특성이 변하는 매우 복잡한 시스템이다. 이에 제어기 설계에 관한 많은 연구들이 이루어져 왔지만 최근에는 좀 더 강건한 제어 시스템을 설계하기 위해 학습능력을 갖고 있으며 병렬 계산처리등의 잇점을 갖는 신경 제어기법을 이용하고 있다. 그러나 대부분의 신경회로망 제어기들은 그 학습 속도에 많은 문제점을 갖고 있다. 이에 본 절에서는 앞서 제안한 퍼지-신경망 기법을 이용한 새로운 형태의 위치 제어 시스템을 제시한다.

그림 6은 퍼지-신경망기법을 이용한 로보트 매니퓰레이터의 제어 시스템을 보여주고 있다. 이 구성도에서  $\theta_d, \dot{\theta}_d$ 는 제어 계획기(trajecotry planner)로부터 명령된 조인트 위치와 속도를 나타내며  $\theta_a, \dot{\theta}_a$ 는 로보트에서 실제 측정한 조인트 위치와 속도들이다. 이들 값으로부터 조인트의 위치 및 속도 오차들은 다음과 같이 정할 수 있다.

$$e(\in R^n) = \theta_d - \theta_a \quad (11a)$$

$$\dot{e}(\in R^n) = \dot{\theta}_d - \dot{\theta}_a \quad (11b)$$

여기에서  $n$ 은 매니퓰레이터의 조인트 갯수를 나타낸다. 로보트 위치 제어기는 상기 오차들을 감소 시키기 위한, 즉 로보트가 명령된 궤적을 정확하게 수행하도록 하는데 그 목표가 있다. 그림 6에서 하단의 PD제어 기법은 오차를 감소시키기 위한 새로운 보정입력  $t_f$ 를 다음식에 의해 정하는 고전적인 제어기법이다.

$$t_f(\in R^n) = k_p(\theta_d - \theta_a) + k_v(\dot{\theta}_d - \dot{\theta}_a) \quad (12)$$

여기에서  $k_p$ 와  $k_v$ 는 각각 위치 및 속도의 계란 이득들이다.

그러나 상기 PD기법만을 이용 복잡하고 가변 가능성을 갖는 로보트 매니퓰레이터의 제어기를 구성하는 일이 매우 어렵다. 이에 로보트의 동적특성을 하나의 'black-box'로 보고 제어를 가능케하는 신경 회로망 제어기의 필요성이 요구된다. 그림 6에서 상단에 다층 신경회로망 구조를 갖는 신경 제어기를 보여주고 있다.

한편, 신경회로망 제어의 가중치들은 오차들에 기인된 PD제어기의 보정입력  $t_f$ 를 감소 시키는 방향으로 조절된다. 역전파 학습 알고리즘에 의해 완전한 학습이 이루어지면 오차 보정입력  $t_f$ 는 0이 되고 신경회로망은 로보트의 동적 특성을 정확하게 투영하게 된다. 이후 로보트의 입력  $t$ 는 오직 신경회로망의  $t_n$ 에 의해 결정된다.

그러나 앞서 설명한 것처럼 다층 신경회로망 제어기의 큰 문제점은 역전파 학습시 그 수렴속도이다. 이에 역전파 학습 속도를 크게 향상시키기 위해 앞 절에서 제안한 퍼지 기법을 도입한다. 이때 식(3),(4)의  $\delta$ 값과 NE값은 다음과 같이 바뀌게 된다.

$$\delta_k = \tau_f \cdot f'(a, net_k) \quad (13a)$$

$$\delta_j = f'(a, net_j) \cdot \sum (\delta_k \cdot W_{kj}) \quad (13b)$$

$$NE = \frac{1}{2} * (\tau_f)^2 \quad (13c)$$

오차 보정 입력  $\tau_f$ 에 의해 얻어진 식 (13)을 이용하여 식 (7)에 의해 퍼지화(defuzzification)를 한후 식 (9) 및 표 (1)의 rule base를 통해 다음상태의 기울기를 추론하게 되고, 식 (10)에 의해 새로운 기울기 값을 구하게 된다.

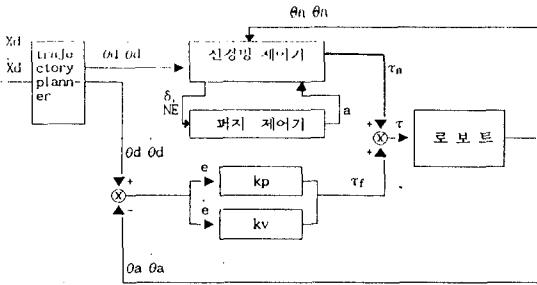


그림 6. 로보트의 퍼지-신경망 위치 제어기의 구성  
Fig.6 The fuzzy-neural position controller of the robot manipulator.

### 5. 컴퓨터 시뮬레이션

PUMA 560 로보트의 3축만을 제어대상으로 하였으며, 시뮬레이션에 사용된 다중 신경망은 입력층에 12개의 뉴런과 2개의 중간층(각각 20개) 그리고 출력층에 3개의 뉴런을 갖는 12-20-20-3의 다중 신경망구조를 갖는다.

제안한 제어 시스템의 효율성을 살펴보기위해 먼저 조인트 공간에서의 컴퓨터 시뮬레이션을 수행하였다. 각 조인트들의 경로는 식 (14)와같이 주어 졌으며 샘플링 시간은 10ms로 하였다. 퍼지제어기에서의 x값의 범위는 -0.1에서 0.1사이의 값을 취하였고, y는 0에서 1사이의 값을 적절히 택하여 퍼지 변수로 설정하였다. 기울기 값은 0.2에서 2.0사이값으로 하였다.

$$\theta_1 = -\frac{\pi}{4} \times \cos\left(\frac{\pi}{6}\right) \times t \quad (14a)$$

$$\theta_2 = \frac{\pi}{8} + \frac{\pi}{8} \times \cos\left(\frac{\pi}{3}\right) - \frac{\pi}{8} \times \cos\left(\frac{\pi}{1.5}\right) \times t \quad (14b)$$

$$\theta_3 = \frac{\pi}{4} + \frac{\pi}{4} \times \cos\left(\frac{\pi}{3}\right) - \frac{\pi}{4} \times \cos\left(\frac{\pi}{1.5}\right) \times t \quad (14c)$$

또한 카르테시안 공간에서 본 알고리즘의 효용성을 입증하기위해 다음과 같은 카르테시안 궤적을 설정하였다.

$$X_d(t) = \begin{bmatrix} P_x(t) \\ P_y(t) \\ P_z(t) \end{bmatrix} = \begin{bmatrix} 0.2 + 0.1 \cos(t) \\ 0.2 + 0.05 \sin(t) \\ 0 \end{bmatrix} \quad (15a)$$

$$\dot{X}_d(t) = \frac{dX_d(t)}{dt} \quad (15b)$$

그림 7과 그림 8는 단순 신경망 제어기의 첫번째 학습과 17번째 학습에서 각 조인트들의 NE오차값을 표시하였고, 그림 9은 100번째 학습에서의 조인트들의 NE오차 값이다.

그림 10은 퍼지-신경망 제어기를 사용하여 첫번째의 학습에서의 조인트 NE 오차이고, 그림 11은 퍼지-신경망 제어기의 23번째 학습에서의 NE 오차 값이다. 이를 결과를 비교해볼때 단순 신경망 제어 방법은 100번째의 학습에서야 수렴되지만 본 연구에서는 제안하는 퍼지 신경망 제어 방식은 23번째 학습에서 수렴이 끝나는 것을 알 수 있다. 퍼지-신경망 제어기를 사용하여 보다 빠른 학습이 이루어짐을 보인다. 그리고 그림 12 ~ 16로부터 카르테시안 공간에서도 조인트 공간에서와 마찬가지로 본 방식이 기존 신경 제어 방식보다 학습 수렴속도가 매우 빠르다는 것을 확인할 수 있다.

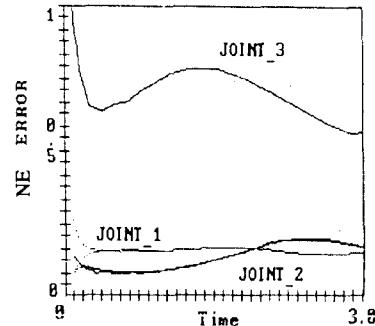


그림 7. 기존 신경 제어기 첫번째 학습에서의 조인트 오차  
Fig.7 Joint error of the conventional neural controller at the 1st learning trial

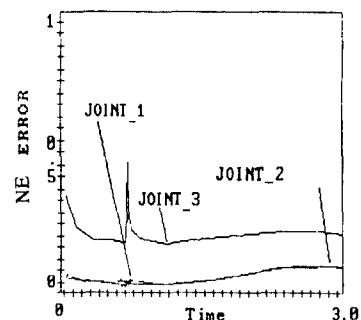


그림 8. 기존 신경 제어기 17번째 학습에서의 조인트 오차  
Fig.8 Joint error of the conventional neural controller at the 17th learning trial.

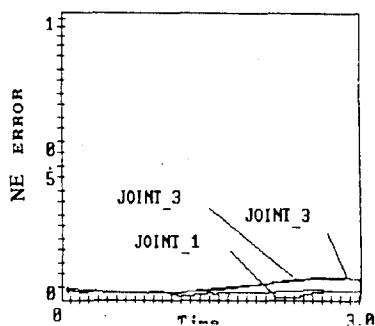


그림 9. 기존 신경 제어기 100번째 학습에서의 조인트 오차  
Fig.9 Joint error of the conventional neural controller at the 100th learning trial.

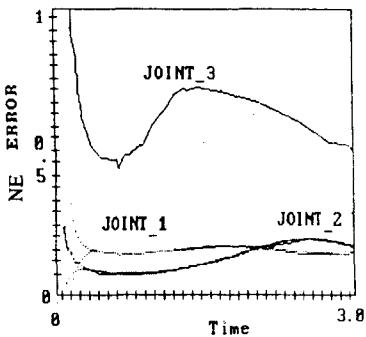


그림 10. 퍼지-신경 제어기 첫번째 학습에서의 조인트 오차  
Fig.10 Joint error of the fuzzy-neural controller at the 1st learning error.

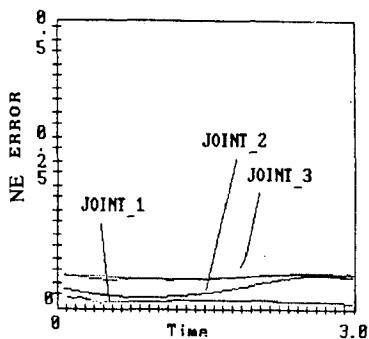


그림 11. 퍼지-신경 제어기 23번째 학습에서의 조인트 오차  
Fig.11 Joint error of the fuzzy-neural controller at the 23th learning trial.

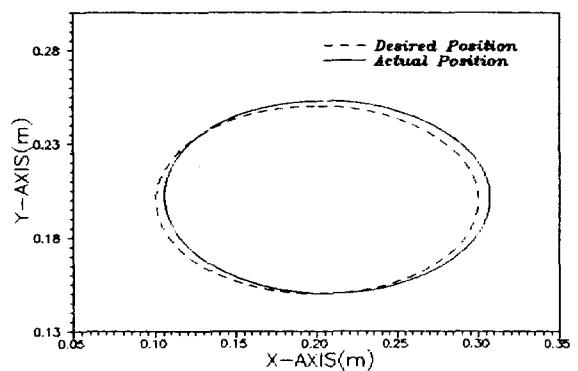


그림 13. 카르테시안 공간에서  
기존 신경제어기의 20번째 학습  
Fig.13 The 20th learning trial of the conventional  
neural controller in the Cartesian space.

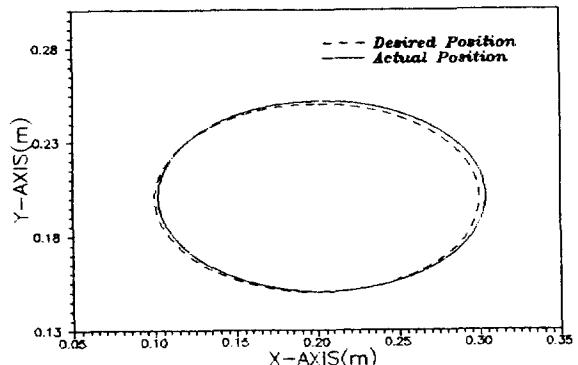


그림 14. 카르테시안 공간에서 기존 신경제어기의  
100번째 학습  
Fig.14 The 100th learning trial of the conventional  
neural controller in the Cartesian space.

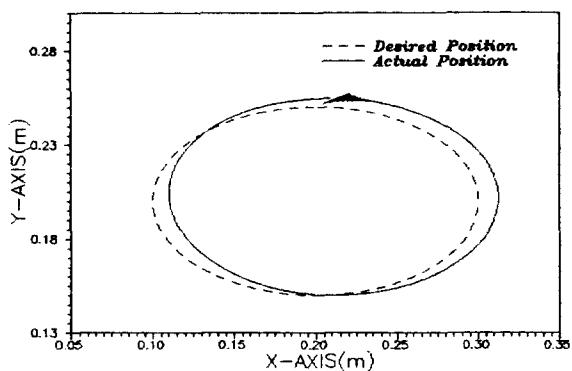


그림 12. 카르테시안 공간에서 기존 신경제어기의 첫번째 학습  
Fig.12 The first learning of the conventional  
neural controller in the Cartesian space.

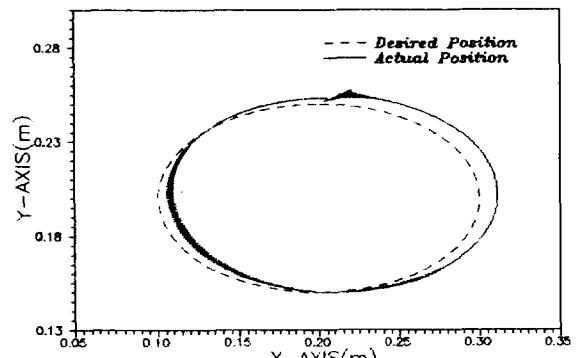


그림 15. 카르테시안 공간에서  
퍼지-신경제어기의 첫번째 학습  
Fig.15 The first learning trial of the fuzzy-neural  
controller in the Cartesian space.

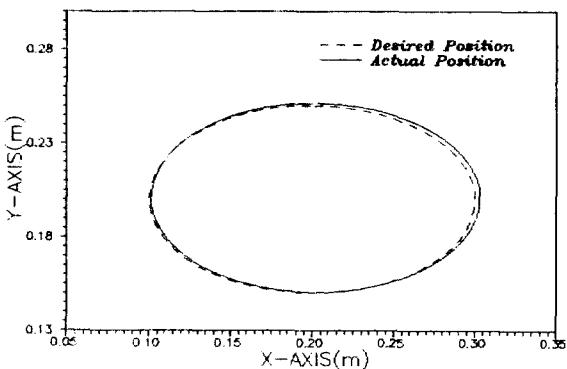


그림 16. 카르테시안 공간에서 퍼지-신경제어기의 20번째 학습  
Fig.16 The 20th learning trial of the fuzzy-neural controller in the Cartesian space.

### 5. 결론

본 논문에서는 퍼지논리를 이용하여 다중 신경회로망의 대표적인 학습 방법인 오차역전파 학습 알고리즘의 학습 속도를 개선하는 방법을 제안하였다. 제안한 학습 방법은 기존의 오차 역전파 알고리즘이 갖는 조기포화 상태등을 효과적으로 방지 할 수 있고 또한 학습시 활성화 함수의 적절한 변화를 통해 기존 방식보다 학습속도를 크게 개선하고 있다. 따라서, 이 방식은 제어이외의 다중 신경회로망 응용분야등에 광범위하게 적용 할 수 있을 것으로 판단된다.

한편, 이 기법을 이용 본 논문에서는 고도의 비선형 동적 특성을 갖는 로보트 매니퓰레이터의 퍼지 신경 제어기를 구성하였고 시뮬레이션을 통해 기존의 단순 신경 제어기보다 조인트 공간( 혹은 카르테시안 공간 )에서 제안한 위치 제어기의 효용성을 크게 향상시켰음을 입증하였다.

끝으로 본 논문에서 제안한 퍼지-신경망 기법을 흡 필드와 같은 다른 신경망에도 적용 할 수 있을 것으로 판단된다.

### 참고문헌

- [1] N. Baba, "A Hybrid Algorithm for Finding Global Minimum of Error Function of Neural Networks," Proc. Int. Joint Conf. Neural Networks pp.1585-1588 ,1990.
- [2] J. R. Chen and P. Mars, "Stepsize Variation for Accelerating the Back Propagation Algorithm," Proc. Int. Joint Conf. Neural Networks ,pp.1601 -I604, Jan 1990.
- [3] 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
- [4] A. Guez, J.L. Eilbert, and M. Kam, "Neural Network Architecture for Control," IEEE Control Systems Magazine, pp. 22-24, April, 1988.
- [5] A. Guez and J.Selinsky, "A Neuramorphic Controller with Human-Teacher," Proc. of the IEEE International Conference on Neural Networks, pp.595-602, July, 1988.
- [6] R. A. Jacobs, "Increased Rates of Convergence Through Learning Rate Adaptation," Neural networks, vol. 1,pp. 295-308, 1988.

- [7] G. Josin, D. Charney, and D. White, "Robot Control Using Neural Networks," Proc. of the IEEE International Conference on Neural Networks, pp.625-631, July 1988.
- [8] 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
- [9] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-error-learning neural network for trajectory control of a robotic manipulator," Neural Networks, vol. 1,no. 3, 1988.
- [10] A. Rezgui, et al., "The Effect of the Slope of the Activation Function on the Back Propagation Algorithm," Proc. Int. Joint Conf. Neural Networks,pp. I707-I710, Jan 1990.
- [11] David E. Rumelhart and James L. McClelland, "Parallel Distributed Processing," MIT Press, 1987
- [12] K. Tsutsumi and H. Matsumoto, "Neural computation and Learning Strategy for Manipulator Position Control," Proc. of the IEEE International Conference on Neural Networks pp.525-534, 1987.
- [13] H.J.Zimmermann, Fuzzy Set Theory and Its Application, Kluwer-Nijhoff Publishing a member of the Kluwer Academic Publishers Gro-up,1986.
- [14] 오세영, 유연식, "다중 신경회로 및 역전달 학습방법에 의한 로보트 팔의 디이나믹 제어," 대한 전기학회지, Vol.39, No.12,pp.1306-1316, 1990
- [15] 管野道夫, ファジィ制御, 日刊工業新聞社, 1988.
- [16] 三矢直城, 田中一男, C 言語による 實用ファジィブック, ルッセル社, 1989.