

퍼지 신경망을 이용한 로보트 매니퓰레이터 제어

°김성현*, 김용호*, 심귀보**, 전홍태*

*중앙대학교 전자공학과, **중앙대학교 계어계측공학과

Control of The Robot Manipulators using Fuzzy-Neural Network

°Seong-Hyun Kim*, Yong-Ho Kim*, Kwee-Bo Sim**, and Hong-Tae Jeon*

*Dept. of Electronics Engineering, **Dept. of Control & Instrumentation Engineering
Chung-Ang University, Seoul, KOREA

ABSTRACT

As an approach to design the intelligent controller, this paper proposes a new FNN(Fuzzy Neural Network) control method using the hybrid combination of fuzzy logic control and neural network. The proposed FNN controller has two important capabilities, namely, adaptation and learning. These functions are performed by the following process. Firstly, identification of the parameters and estimation of the states for the unknown plant are achieved by the MNN(Model Neural Network) which is continuously trained on-line. And secondly, the learning is performed by FNN controller. The error back propagation algorithm is adopted as a learning technique. The effectiveness of the proposed method will be demonstrated by computer simulation of a two d.o.f. robot manipulator.

1. 서 론

일반적으로 기존의 제어 알고리즘은 프로세스의 수학적 모델링을 바탕으로 발달하였다. 그러므로 복잡한 동특성을 갖는 시스템의 전달함수, 상태방정식 형태의 정확한 수학적 모델링이 어렵거나 시스템의 파라미터의 변동, 또는 부하 외란이 존재하는 변하는 환경에서는 기존의 제어 이론으로 강건한 제어 기구성이 용이하지 못하다. 이러한 어려움을 해결하기 위해 서 최근에는 인간의 사고 능력과 적응 능력을 갖는 지능형 제어기가 제안되고 이를 응용한 제어기 구성의 연구가 활발히 진행되고 있다. 이러한 방향으로서 퍼지 이론을 이용한 퍼지 논리 제어기(Fuzzy Logic Controller)와 신경회로망 기법을 이용한 신경회로망 제어기(Neural Network Controller)를 들 수 있다.

퍼지 제어는 전문가의 경험을 소속함수(membership function)나 제어 규칙으로 표현하여 원하는 제어량을 퍼지 추론(Fuzzy inference)에 의해 결정한다. 그러므로 정확한 수학적 모델링을 필요치 않는다. 또한, 기존의 제어기에 비해 강건하고, 병렬형, 논리형, 그리고 언어적 제어의 특징을 가

지고 있으며 부정확하고 애매한 정보를 다룰 수 있는 능력을 갖고 있다. 이러한 장점들로 인하여 비선형시스템에 효과적으로 적용되었다[1][2].

그러나 퍼지 논리 제어기는 전문가에의한 퍼지 규칙 베이스 구성을 주관적이고 경험에 의존한다. 예로서, 각 퍼지 변수의 소속함수의 위치와 형태는 경험적 설계 파라미터들이다. 또한, 전문가라 할지라도 경험적 지식을 퍼지 규칙 베이스(fuzzy rule base)로 구성하기 어려운 경우가 있으며 이러한 퍼지 규칙 베이스를 구성하였다 하더라도 규칙 베이스를 생성하는데 많은 시간 소비와 제어 규칙의 최적화 문제가 제시된다.

한편, 신경망 제어는 다층 신경망과 비선형 적응 가중치를 갖는 적응제어의 한 분야로 주목되고 있다. 또한, 입력과 출력의 정보로부터 입·출력 관계를 학습함으로써 자동적으로 지식 습득(knowledge acquisition)이 가능하므로 정확한 수학적 모델링이 필요치 않으며 정보의 분산 처리에의한 오차 보간 능력과 외란에대한 강건성 및 적응 능력등의 장점을 갖는다. 이러한 특성으로 인해서 최근에 많은 성공적인 응용사례가 발표되었다[3][4].

그러나 신경망에서는 최적의 뉴런과 층의 수를 결정하기가 힘들며 신경망 구조에서는 언어적 제어가 아니라 수치적 제어로 인한 제어 능력의 저해 요인을 쉽게 찾아서 항상시킬 수 없고 학습시 지역적 최소치(local minimum)에 빠질 수 있다는 문제점을 갖는다.

최근에는 이러한 신경망 이론과 퍼지 이론의 보상적인 성격에 대한 연구가 활발하다[5][6]. 각각의 단점을 보완하고 장점을 강화하기 위해 논리 및 추론의 특성을 갖는 퍼지 이론과 신경회로망과의 합성(Hybrid) 및 융합(Fusion) 기법에 관한 연구가 시도되고 있다. 즉, 인간의 제어 능력에 접근하는 지능 제어기의 구현이 최근에 연구되고 있다.

본 논문에서는 퍼지 이론과 신경망을 합성한 새로운 FNN 제어 방식을 제안하고 이를 응용 비선형 동특성을 갖는 로보트 매니퓰레이터의 제어기를 구성한다. 제안된 제어 시스템에서는 고정된 소속함수를 갖는 전건부를 효율적으로 구성하기 위해서 클러스터링 방법(clustering method)이 사용된다. 그리고 후건부는 적응적으로 추론되는 제어입력으로 시변 소속함

수(time-varying membership function)를 갖으며 오차함수가 최소가 되도록 추정된다. 또한, FNN 제어기의 적응성과 학습능력을 부여하기 위해서 모르는 플랜트의 동특성을 실시간 학습하는 모델 신경회로망(Model Neural Network)을 도입한다. 학습 과정은 역전파 학습알고리즘으로 수행된다. 제안된 방법은 2 d.o.f. 로보트 매니퓰레이터의 위치 제어에 적용된다.

2. 퍼지 신경망 제어기 (FUZZY-NEURAL NETWORK CONTROLLER)

본 절에서는 FNN 제어기의 설계 과정에 대해서 설명되어 진다. 일반적으로 기존의 FLC에서 퍼지시스템의 동적 특성은 전문가의 경험을 바탕으로한 언어 규칙의 집합으로 특징지어 진다. 이러한 언어 규칙은 다음과 같이 전건부와 후건부로 표현된다.

$$R_i: \text{IF } (x_1 \text{ is } A_{i1}) \text{ and } \dots \text{ and } (x_n \text{ is } A_{in}) \text{ THEN } (y \text{ is } B_i)$$

전건부
후건부

for $i=1, \dots, m$ (1)

여기서, $x_j (j=1, \dots, n)$ 와 y 는 입력변수(input variables) 및 제어변수(control variable)이다; A_{ij} and B_i 는 전체집합 U^1, \dots, U^n , 그리고 V 에서 퍼지 소속함수 $\mu_{A_{ij}}(x_j)$ 와 $\mu_{B_i}(y)$ 에 의해서 결정되는 퍼지변수(fuzzy variables)이다.

한편, 퍼지 추론방법에서 많은 다른 방법들이 있는데 예를 들면 Mandami's min-max method, Mizumoto's product-sum method 등이 있다[7]. 본 논문에서는 product-sum method[8]의 특별한 경우에 해당하는 단순화된 추론방법(the simplified reasoning method)을 사용한다. 추론과정을 다음과 같이 표현된다.

$$\mu_{B^o}(y) = \bigvee_{i=1}^m (\alpha_i \otimes Y_i) \quad (2)$$

$$\alpha_i = \bigwedge_{j=1}^n \mu_{A_{ij}}(x_j) \quad (3)$$

여기서, 기호 ' \otimes ' 와 ' \wedge ' 대수합 및 대수곱 연산자이고 α_i 는 퍼지 제어입력에 해당하는 i-번째 제어규칙의 전건부의 진리값(truth value)이며 Y_i 는 퍼지집합이 아니라 V 상에서의 실제 값이다.

최종적으로 추론되는 출력 y^* 은 다음과 같이 결정된다.

$$y^* = \frac{\sum_{i=1}^m \alpha_i \cdot Y_i}{\sum_{i=1}^m \alpha_i} \quad (4)$$

이때, 상기의 추론과정은 구조적인 신경망으로 구현될 수 있다. 또한 퍼지 규칙의 전건부와 후건부는 비선형성과 학습능력을 갖는 다층 신경망으로 구성된다. 그림 1은 제안되는 FNN 제어기의 구성을 보여준다. 다음은 FNN 제어기의 구성에 대해서 상세히 설명되어 진다.

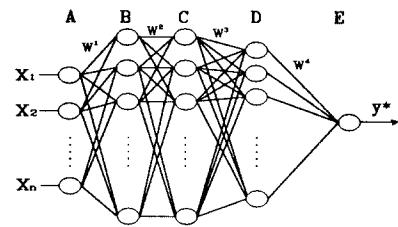


그림 1. FNN 제어기
Fig. 1. FNN controller

X_1					
$\Delta e \setminus e$	NB	NM	ZR	PM	PB
PB	ZR	PS	PM	PB	PB
PM	NS	ZR	PS	PM	PB
ZR	NM	NS	ZR	PS	PM
NM	NB	NM	NS	ZR	PS
NB	NB	NB	NM	NS	ZR

X_2					
$\Delta e \setminus e$	NB	NM	ZR	PM	PB
PB	ZR	PS	PM	PB	PB
PM	NS	ZR	PS	PM	PB
ZR	NM	NS	ZR	PS	PM
NM	NB	NM	NS	ZR	PS
NB	NB	NB	NM	NS	ZR

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

2.1 다층 신경망에 의한 전건부 구성

그림 1에서 원하는 퍼지 규칙의 전건부를 (A)~(D)층에 서 구현된다. 이때 전건부의 소속함수를 효율적으로 구성하기 위해서 클러스터링 기법(clustering method)이 사용된다. 표 1은 x_1 와 x_2 에 각각 5개의 퍼지변수와 y 에는 7개의 퍼지변수를 선택했을 때 전형적인 퍼지 제어 규칙을 보여주고 있다. 이 때 입력공간은 25개의 퍼지공간(fuzzy space)으로 나누어 진다. 그리고 같은 제어동작을 갖는 규칙이 같은 입력공간으로 클러스터링될 수 있다면 입력공간은 7개의 클러스터로 줄어들 수 있다. 7개의 퍼지 규칙으로 줄인 후, 각 클러스터에 대응하는 규칙은 전문가에 의해 재구성되고 신경망으로 구현되어 진다. 이것은 데이터의 분할 갯수 만큼 퍼지 규칙을 정한다고 가정하면 플랜트의 관찰에서 얻어진 입력 정보를 r-차원으로 클러스터링하고 클러스터링된 데이터를 신경망으로 학습함으로서 구현되어질 수 있다. 이러한 클러스터링 기법에 의해서 퍼지 제어 규칙의 수를 줄일 수 있으며, 뉴런의 시그모이드 특성에 의해서 비선형 소속함수를 구성할 수 있고, 입력 공간을 퍼지하게 분할할 수 있다.

한편, (D)층의 출력은 각 부공간(subspace; $R^r (r=1, \dots, 7)$)의 퍼지 규칙의 진리값(the truth value)이고 식(2)에서의 i-번째 규칙의 전건부의 진리값 α_i 에 해당된다.

전건부에 해당하는 상기의 FNN을 구성하였다. 다음은 FNN을 학습시키는 과정이다. 학습 목적은 FNN에서 줄어든 7개의 제어규칙이 표 1에서 25개의 제어규칙과 같은 효과를 얻도록 하기 위함이다. 학습후 (D)층의 출력값은 (A)층의 입

력값이 각 그룹에 소속 정도(the degree of membership function)를 나타내어 주게 되므로 퍼지 추론 형태를 갖는다. 역전파 학습 알고리즘을 바탕으로 한 학습과정은 다음과 같다.

먼저, 전체 오차 함수(global error function)은 식(5)와 같이 정의되며, 이것은 FNN이 각 입력에 대해 원하는 입력 분할의 성취여부를 결정한다.

$$E = \frac{1}{2} \sum_{i=1}^r \{(T_i - O_i)^2\} \quad (5)$$

, 여기서

$$T_i = \begin{cases} 1, & (x_1, x_2) \in R^r \\ 0, & \text{otherwise} \end{cases}$$

O_i 는 (D)층의 i-번째 뉴런이며, $r(=1, \dots, 7)$ 는 뉴런 수(또는, 클러스터 수)이다. 또한, 'Ti'는 입력데이터가 원하는 클러스터에 속하는지의 여부에 따라 결정된다.

오차함수가 정의된 후의 다음과정은 상기의 오차함수를 최소화하기 위해 역전파 학습 알고리즘을 이용해서 (A)~(D)층의 가중치를 조정한다. (n-1)층의 j-번째 뉴런과 (n)층의 i-번째 뉴런 사이의 가중치 변화량 $\Delta W_{n-1,j}^i$ 은 다음과 같이 구해진다.

$$\Delta W_{n-1,j}^i = -\eta \frac{\partial E}{\partial W_{n-1,j}^i} = -\eta \delta_{n-1}^j O_{n-1}^{i-1} \quad (6)$$

$$\delta_{n-1}^j = \begin{cases} (T_j - O_j)f'(U_{n-1}^j), & \text{출력층} \\ f'(U_{n-1}^j) \sum_k \delta_{n-1,k}^j W_{n-1,k}^j, & \text{중간층} \end{cases} \quad (7)$$

여기서, O_{n-1}^{i-1} 는 (n-1)층의 i-번째 뉴런, η 는 학습률(learning rate)이고, $f'(U_{n-1}^j)$ 는 시그모이드 활성화 함수(sigmoidal activation function)의 도함수이며, U_{n-1}^j 는 (n)층의 입력이다.

최종적으로 오차함수를 최소화하기 위해서 가중치 $W_{n-1,j}^i$ 는 다음과 같이 갱신된다.

$$W_{n-1,j}^i(t+1) = W_{n-1,j}^i(t) + \Delta W_{n-1,j}^i \quad (8)$$

2.2 다층 신경망에 의한 후건부 구성

그림 1과 같이 후건부는 신경망의 (D)~(E)층으로 구현된다. 가중치 W^4_i 는 식(2)의 Y_i 에 대응하며 그림 2와 같이 후건부 소속함수의 상수값이다.

학습과정에서 소속함수(Y_i , $i=1, \dots, 5$)는 식(9)와 같은 오차함수를 최소화하는 역전파 알고리즘으로 조정된다.

$$E^* = \frac{1}{2} \sum_{i=1}^k \{(T^p_i - O^p_i)^2\} \quad (9)$$

여기서, O^p_i 는 플랜트의 원하는 출력(desired output)이고, T^p_i 는 플랜트의 실제 출력(actual output)이다.

한편, 가중치 W^4_i 의 변화량(ΔW^4_i)은 다음과 같다.

$$\Delta W^4_i = -\eta \frac{\partial E^*}{\partial W^4_i} = -\eta \delta^c O^4_i \quad (10)$$

여기서, δ^c 는 FNN 제어기의 출력단에서의 오차 신호이며 플랜트를 통해서 역전파되어 진다. 그리고 O^4_i 는 (D)층의 출력이다. 이때, 학습과정에서 전문가의 경험으로부터 얻어진 입력 데이터가 학습데이터로 사용되며, 적당한 초기 가중치 W^4_i 는 FNN 제어기의 학습속도를 향상시키고 플랜트의 초기 안정성을 보장한다.

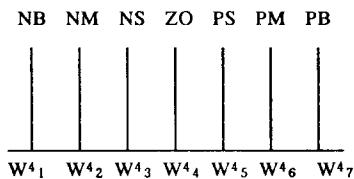


그림 2. 후건부의 소속함수.
Fig. 2. Membership function of consequence

3. 로보트 매니퓰레이트 제어에의 적용

상기의 제안된 제어기를 로보트 매니퓰레이터의 제어기 설계에 적용했을 때 FNN의 오차신호(δ^c)를 결정하는데 어려운 점이 있다. 이러한 어려움을 해결방안으로 모델 신경망(Model Neural Network:MNN)을 사용해서 로보트의 동특성을 정의하는 것이다.

로보트의 시스템 동정을 위해서 MNN을 구성한 후에, FNN과 MNN 그림 3에서 보이는 바와 같이 연결되어 제어 시스템을 구성한다. 전체 시스템은 FNN 제어기, 플랜트(robot), 모델 신경회로망(Model Neural Network)로 구성되며 다음절에서 FNN과 MNN이 상세히 설명된다.

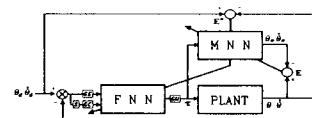


그림 3. FNN 제어 시스템
Fig. 3. FNN control system

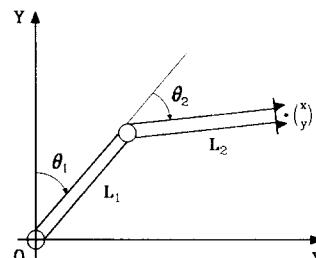


그림 4. 2 d.o.f. 평면 로보트 매니퓰레이터
Fig. 4. 2 d.o.f. planar robot manipulator

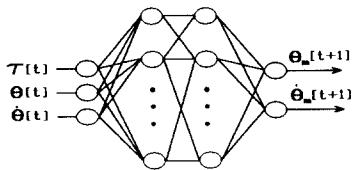


그림 5. 모델 신경망
Fig. 5. Model Neural Network

3.1 로보트 매니퓰레이터

로보트 매니퓰레이터는 고도의 비선형시스템으로 정확한 수학적 모델링이 어렵고 이를 위한 제어기 설계에 있어서 기존의 제어 이론으로는 높은 강인성을 만족하지 못하는 문제를 갖는다. 로보트 매니퓰레이터 시스템의 상태는 $\theta, \dot{\theta}$ 의 2가지 상태변수로 추정 가능하다고 가정하였다. 주행경로는 다음과 같은 카르테시안 공간에서 타원 궤적을 선정하였다.

$$\begin{aligned} X_d(t) &= \begin{bmatrix} P_x(t) \\ P_y(t) \\ P_z(t) \end{bmatrix} = \begin{bmatrix} 0.3 + 0.25 \cos(t) \\ 0.2 + 0.05 \sin(t) \\ 0 \end{bmatrix} \\ \dot{X}_d(t) &= \frac{dX_d(t)}{dt} \end{aligned} \quad (11)$$

3.2 FNN 제어기

로보트를 위한 FNN 제어기는 제 2절에서 설명된 과정에 의해서 구성된다. 두개의 입력단자와 한개의 출력과 두개 이상의 중간층으로 구성되며 입력변수로 오차 $e (= \theta_d - \theta)$ 와 오차 변화율 Δe 를 받고 로보트가 주어진 궤적상에 존재하도록 출력 토크 τ 를 발생한다.

한편 환산계수 GE와 GC는 실제 오차 e 와 오차 변화율 Δe 값들을 퍼지 변수로 변환시키기고 제어기 성능에 중요한 영향을 미친다. 그러므로 FNN의 성능을 향상시키기 위해서 FNN과 환산계수는 역전파 알고리즘으로 동시에 학습되어야 한다.

3.3 모델 신경망(Model Neural Network)

그림 5는 다층 신경망에 의해서 구성된 MNN을 보여준다. MNN를 학습시키는 오차 역전파 학습알고리즘은 로보트의 시스템 동정(system identification)을 수행할 수 있다. MNN은 로보트의 현대 상태와 FNN의 제어동작을 입력으로 받아서 로보트의 다음 상태를 추정한다.

MNN이 로보트의 동특성을 학습한 후, O_p 는 O^m 로 대체된다. FNN의 가중치 W^i 를 학습하기 위해서 오차 신호 δ^c 는 식(9)으로부터 계산된다. 그리고 MNN의 (m)층의 출력단의 오차신호는 다음과 같다.

$$\delta^m_i = -\frac{\partial E^*}{\partial U^m_i} = -\frac{\partial E^*}{\partial O^m_i} \frac{\partial O^m_i}{\partial U^m_i} = (T^p_i - O^m_i) \quad (12)$$

여기서, $\frac{\partial O^m_i}{\partial U^m_i} = 1$

그리고, 중간층 ($m-1$)층은

$$\delta^{m-1}_j = f' (U^m_j) \sum_i \delta^m_i W^m_{ij} \quad (13)$$

그러므로 FNN 제어기의 출력단에서의 오차신호는 다음과 같이 정의된다.

$$\delta^c = \sum_j \delta^{m-1}_j W^{m-1}_{jk} \quad (14)$$

상기의 전체과정을 요약하면 FNN와 MNN을 갖는 제어 시스템 구성과정은 다음과 같다.

- [단계 1] 전문가의 경험에 의존해서 퍼지 규칙의 수를 결정하고 각 규칙의 속성에 속하는 입력데이터를 클러스터링한다.
- [단계 2] FNN의 전건부를 구성하기 위해서 식(5)~(8)를 사용해서 (A)~(D)층을 학습한다.
- [단계 3] 후건부의 소속함수(Y_i or W_i)를 초기화한다.
- [단계 4] MNN이 로보트의 동특성을 학습한다.
- [단계 5] FNN 제어기의 후건부를 식(9)~(14)에 의해서 학습한다.

여기서 단계 1과 3은 off-line으로 실행되며 단계 4와 5는 on-line으로 실행된다.

4. 모의 실험 및 결과

제안된 제어 시스템의 모의실험은 2 d.o.f. 평면 로보트 매니퓰레이터를 사용해서 수행되었다(그림 4). 로보트 매니퓰레이터의 매개변수는 표 2와 같다. FNN의 전건부에 해당하는 신경망은 4층 구조를 이루고 있으며 27(2-10-10-5)개의 뉴런으로 구성된다. 그리고 모델 신경망의 각 뉴런수는 26(4-10-10-2)개이다. 후건부의 초기 소속함수와 환산계수는 표 3과 같다.

상기의 과정에서 그림 6과 7의 결과를 얻었다. 그림 6에서 FNN 제어기는 초기 설정된 퍼지 제어 규칙으로 수행되었으며 MNN은 1500번째 학습후에 효과적으로 플랜트의 동특성을 추정하였다. 그러나 원하는 경로와 플랜트의 실제 경로와의 오차는 매우 크다.

또한, 그림 7에서 보여지는 바와 같이 FNN 제어기의 20 번째 학습으로 시스템 성능이 향상되었음을 볼 수 있다. 표 3은 20번째 학습후에 갱신된 소속함수와 환산계수(GE, GC)를 보여준다.

표 2. 로보트의 매개변수
Table 2. Parameters of the robot

기 호	첫번째 링크	두번째 링크
M(kg)	2.5	2.0
L(m)	0.53	0.47

표 3. 로보트를 위한 FNN 제어기의 초기치

및 수정된 가중치와 환산계수

Table 3. Initial and refined values of FNN controller for the robot

기호	첫번째 링크		두번째 링크	
	초기치	수정치	초기치	수정치
W^4_1	-0.470	-0.485	-0.310	-0.402
W^4_2	-0.100	-0.131	-0.100	-0.265
W^4_3	0.000	0.000	0.000	0.000
W^4_4	0.100	0.134	0.100	0.100
W^4_5	0.500	0.540	0.410	0.410
GE	13.120	79.669	30.160	183.376
GC	1.540	2.024	0.920	0.594
GU	70.000		70.000	

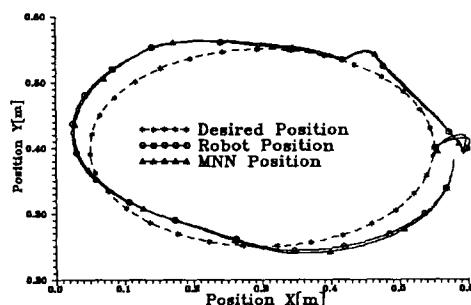


그림 6. FNN 제어기의 첫번째 수행결과 및 MNN의 추정 결과

Fig. 6. The first result of FNN controller and the estimation result of MNN.

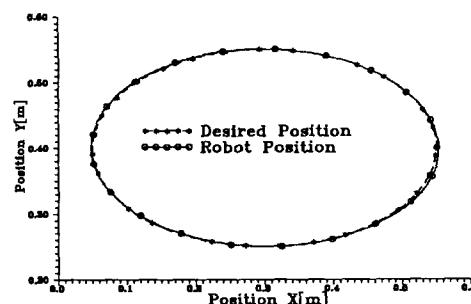


그림 7. 20 번째이후의 FNN 제어기 수행 결과

Fig. 7. Performance result of FNN after 20 iterations

5. 결 론

본 논문에서 논리 및 추론의 장점을 갖는 퍼지 제어기와 학습능력을 부여하는 신경회로망 기법의 합성을 시도한 새로운 FNN 제어기를 제안하였다. FNN 제어기와 MNN을 사용함으로서 제어 시스템은 모르는 로보트의 동특성을 다룰 수 있도록 구성되었으며 제안된 방식의 효율성은 모의 실험에 의해 입증되었다. 또한 MNN는 실제 플랜트에서 얻어진 입력공간의 클러스터링에 의해 보다 적은 규칙을 가지고 로보트 매니퓰레이터를 제어할 수 있었다. 또한 FNN 제어기에 적용성을 부여하는 모델 실증망은 로보트 매니퓰레이터의 잘모르는 동특성을 동정할 수 있었고 FNN 제어기의 후건부 소속 함수를 자동적으로 조정할 수 있었다.

참고 문헌

- [1] M. Sugeno, M. Nishida, "Fuzzy control of model car," *Fuzzy Sets Syst.*, vol. 16, pp.103-113, 1985.
- [2] B. P. Graham, R. B. Newell, "Fuzzy identification and control of a liquid level rig," *Fuzzy Sets Syst.*, vol. 26, pp.255-273, 1988.
- [3] Teruo Fujii, Tamaki Ura, "SONCS:Self-Organizing Neural-Net-Controller System for Autonomous Under Water Robots," *IJCNN'91*, vol.3, pp.1973-1982, 1991.
- [4] A Guez, J. Eilbert, and M. Kam, "Neuromorphic Architecture for Fast Adaptive Robot Control," *IEEE International Conference on Neural Networks*, vol.,pp., 1987.
- [5] H. Takagi, "Fusion Technology of Fuzzy Theory and Neural Network-Survey and Future directions," *Int. Conf. on Fuzzy Theory & Neural Network(IIZUKA-90)*, vol.1, pp.13-26, 1990.
- [6] Y. Dote, "Fuzzy and Neural Network Controller," *Proc. of IECN'90*, vol. 2, pp.1315-1343, 1990.
- [7] C. C. Lee, "Fuzzy logic in control systems: Fuzzy logic controller-Part 1, II," *IEEE Trans. Syst. Man. Cybern.*, vol. 20, no. 2, pp.408-435, Mar./Apr. 1990.
- [8] H. Mizumoto, "Realization of PID controls by Fuzzy control methods," *IEEE Int. Conf. on Fuzzy Systems*, pp. 709-715, 1992.
- [9] H. Takagi, "Neural Network Designed on Approximate Reasoning Architecture and its Pattern Recognition," *Int. Conf. on Fuzzy Theory & Neural Network(IIZUKA-90)*, vol.2, pp.671-674, 1990.
- [10] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation," *Parallel Distributed Processing*, the MIT press, pp.318-362, 1986.
- [11] S. H. Kim, Y. H. Kim, K. B. Sim, and H. T. Jeon, "Control of the Robot Manipulators using Fuzzy-Neural Network," *Proc. of ConFuSE '92*, pp.195-201, 1992.