

퍼지제어 시스템을 위한 인공신경망 설계

장 문 석* 장 덕 철**

요 약

퍼지 시스템 모델링에 있어서, 퍼지 규칙을 인식하고 퍼지 추론의 소속함수를 조정하기란 매우 어렵다. 본 논문에서는 인공신경망을 이용함으로써, 자동으로 퍼지 규칙을 인식하고 동시에 퍼지 추론의 소속함수를 조정할 수 있는 퍼지신경망 모델을 제시하고, 인공신경망의 수렴도를 향상시키기 위해 개선된 역전파 알고리즘을 사용하여 학습에 사용하였다. 이 방법의 타당성을 로봇트 매니퓰레이터를 통해 검증한다.

Design of Artificial Neural Networks for Fuzzy Control System

Moonsuk Jang * Duk Chul Chang **

ABSTRACT

It is very hard to identify the fuzzy rules and tune the membership functions of the fuzzy inference in fuzzy systems modeling. We propose a fuzzy neural network model which can automatically identify the fuzzy rules and tune the membership functions of fuzzy inference simultaneously using artificial neural networks, and modify backpropagation algorithm for improving the convergence. The proposed method is verified by the simulation for a robot manipulator.

1. 서 론

1943년 McCulloch와 Pitts의 Neural Model [1], 1949년 Hebb의 Neural system[2], 1950년대 Rosenblatt의 Perceptron 이후로 인공신경망(artificial neural network)에 관한 연구가 진행되어 왔다. 한편, 1965년 Zadeh가 Fuzzy 집합 [3] 이론을 발표한 이후로 이에 관한 연구도 활발히 진행되어 왔다. 이들 인공신경망과 퍼지 시스템은 서로다른 분야에서 독립적으로 많은 발전이 있었다.

인공신경망과 퍼지 시스템 두 가지 모두가 인간 사고 및 인식과 관련된 현상들을 모델링하기 위한 강력한 도구이며, 또한 인공신경망과 퍼지

시스템의 내부 구조가 비슷하여 결합가능하다는 점에 착안하여, 최근에는 Neurofuzzy system 또는 Fuzzy Neural Network라는 용어가 탄생하기에 이르렀는데, 이는 인공신경망과 퍼지 시스템의 장점들을 결합하여 좀더 강력한 시스템을 개발하기 위한 연구라고 할 수 있다.

인공신경망은 병렬성, 학습(learning) 능력, robustness, fault tolerance 등의 장점을 갖고 있으며, 한편, 퍼지 이론에는 인간의 사고와 같은 불확실성을 내포한 정보를 처리하고 추론할 수 있는 등 논리적인 면에 장점이 있다.

이들 두 시스템을 결합하려는 연구로는 예를 들면, 인공신경망을 퍼지 집합의 소속함수(membership function)의 학습에 사용하는 연구[4, 5], 인공신경망의 학습 기법들을 퍼지 추론 규칙 [6] 또는 퍼지 제어 규칙의[7] 학습에 적용하는 연구, associative memory에서 퍼지 지식을 습

* 정 회 원 : 순천대학교 전자계산학과 부교수
** 정 회 원 : 광운대학교 교수, 광운대학교 전산대학원장
논문접수 : 1995년 6월 29일, 심사완료 : 1995년 10월 30일

특하기 위한 fuzzy cognitive map에 관한 연구 [8], 퍼지논리를 인공신경망의 동작에 대한 감시 및 제어에 적용하는 연구[9], 퍼지 뉴런의 설계에 관한 연구[10,11] 등이 있다.

인공신경망을 이용하여 퍼지 규칙을 생성하고 소속함수를 조정하려는 연구는 Takagi 등 여러 연구 팀에서 시도되어 퍼지 모델링과 제어에 적용되었다[12]. 그 후에 Horikawa 등은 퍼지 규칙에 대한 자동 인식과 소속함수의 조정을 동시에 수행할 수 있는 Fuzzy Neural Networks를 제안하였는데, 이 FNN은 조건부(premise)와 결론부(consequence)를 인공신경망으로 구성함에 있어서 출력이 상수, 선형함수, 퍼지변수 인가에 따라 다른 모델을 제시했다[13]. 진홍태 등은 출력이 선형함수인 경우를 개선한 연구를 발표하였다[14].

한편, van Ooyen 등은 3-계층 신경망에서의 수렴도 향상에 관한 연구를 하였으며[15], Uehara 등과 Xu 등은 뉴로퍼지 시스템에서의 학습 능력향상에 관한 연구를 하였다[16,17].

본 논문에서는 인공신경망을 이용하여 자동으로 퍼지 규칙을 인식하고 동시에 퍼지 추론의 소속함수를 조정할 수 있는 인공신경망 모델을 제시하고, 수렴도를 향상시키기 위해 역전파(back-propagation) 알고리즘[18]의 오차함수를 수정하여 개선한 학습 알고리즘을 사용하였다. 이 방법의 타당성을 로봇트 매니플레이터를 통해 검증한다.

본 논문의 2장에서는 퍼지 시스템을 기술하고, 3장에서는 퍼지 신경망 추론 시스템의 모델과 학습 알고리즘을 기술하고, 4장에서 시뮬레이션 결과를 제시한다.

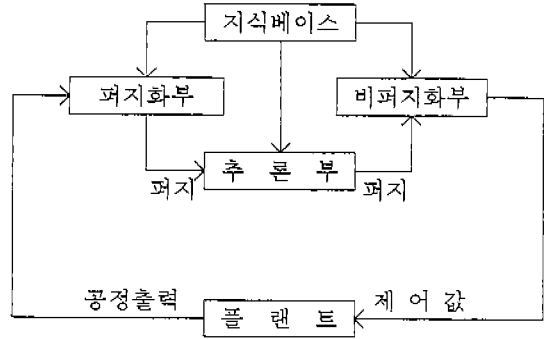
2. 퍼지 시스템

2.1 퍼지 시스템의 구성

시스템의 복잡성이 어느 정도 이상 증가하면 정량적인 방식으로는 시스템의 거동에 대해 정확하고 의의가 있는 기술이 불가능하게 되는데, 퍼지 추론은 시스템의 특성이 복잡하여 기존의 정량적인 방법으로는 해석할 수 없거나, 정보가 정성적, 부정확, 불확실한 경우에 기존의 추론 방

식보다 우수하다고 할 수 있다[19].

본 퍼지 시스템은 (그림 1)과 같이 퍼지화부(fuzzifier), 지식베이스(knowledge base), 추론부(inference engine), 그리고 비퍼지화부(defuzzifier)로 구성된다.




(그림 1) 퍼지 시스템의 구조
(Fig. 1) A structure of fuzzy system

2.2 퍼지화

퍼지화부는 명확한(crisp) 입력 영역으로 부터 이에 상응하는 전체 집합(universe of discourse) 상의 퍼지 집합으로 대응시킨다. 퍼지화는 시스템의 도입부에서 이루어져야 하는데, 측정된 값의 영역을 그대로 입력부의 퍼지 변수의 영역으로 사용하기 보다는 이를 퍼지 연산에 편리하도록 미리 정해 놓은 입력 퍼지 변수의 전체 집합으로 맞추어 주는 것이 편리하다. 또한, 이들 명확한 값들을 퍼지 값으로 바꾸어 주어야 한다.

퍼지 변수의 전체 집합 영역은 데이터베이스 설정시에 결정된다. 따라서, 퍼지화의 작업은 전체 집합에 따라서 적절히 크기 변환(scale map-



(그림 2) 퍼지 변수의 소속 정도
(Fig. 2) Membership degree of fuzzy variable


ping)을 수행하는 작업이 된다[20, 21]. 또한 입력 정보의 특성에 따라 여러 가지 방법으로 퍼지 화하게 된다.

본 논문에서는 (그림 2)와 같이, 입력이 x_j 인 경우 퍼지 변수 A_{ij} 의 소속 정도가 $A_{ij}(x_j)$ 로 나타나도록 하였다.


2.3 데이터베이스

지식베이스는 퍼지 데이터를 조작하고 규칙을 정의하는데에 필요한 사항들을 정의하는 데이터베이스와 전문가의 처리 방침을 나타낸 규칙부로 구성된다. 퍼지 규칙에서 조건부와 결론부의 언어적 변수는 퍼지 집합에 대응된다. 이 집합은 각각 한 전체 집합 내에서 정의된 퍼지 집합을 나타내는데, 이들은 각각 고유의 소속함수를 가진다. 본 논문에서의 퍼지 변수는, (그림 3)에서 나타낸 것과 같은 연속형의 소속함수를 갖는다.

입력 퍼지 변수가 결정되고 그 변수의 갯수에 따라 설계할 수 있는 제어 규칙의 최대 갯수가 결정되면, 입력 공간이 정의된다. 본 논문에서는,



(그림 3) 조건부의 소속함수
(Fig. 3) Membership function in antecedent



(그림 4) 조건부의 퍼지 부공간
(Fig. 4) Fuzzy subspace of antecedent

2개의 입력과 3개의 소속 함수로, 입력공간을 (그림 4)와 같이 9개의 퍼지 부공간으로 분할한다.

2.4 퍼지 규칙

퍼지 시스템의 동특성은 전문가의 제어 지식을 언어적인 형태로 나타낸 규칙에 의해 결정되는데, 다음과 같은 퍼지 조건문들로 이루어진다.

If (만족해야할 일련의 조건)
then (추론된 일련의 결론)

If 다음을 조건부(antecedent) 그리고 then 다음을 결론부(consequent)라 하고 정성적인 언어로 표현된다. 조건부와 결론부에는 각각 여러 개의 퍼지 변수들이 도입될 수 있으며, 전체 규칙은 여러 개의 퍼지 조건문들로 구성될 수 있다. 본 논문에서는 다음과 같은 상태평가형 퍼지 규칙을 사용한다.

- R_1 : If x is A_1 and y is B_1 then z is C_1
- R_2 : If x is A_2 and y is B_2 then z is C_2
- ...
- R_n : If x is A_n and y is B_n then z is C_n

여기에서 x 와 y 는 입력, z 는 출력 변수이고, A_i, B_i 그리고 C_i 는 전체 집합 U, V, W 에서 정의된 x, y, z 의 퍼지 값을 나타낸다. 또한, 개별적인 퍼지 조건문들은 R_i 라는 퍼지 관계로 대변될 수 있으며, 이들이 모여서 퍼지 규칙 집합을 이룬다.

일반적으로 퍼지 시스템에서 전문가가 자신의 경험과 지식으로 규칙을 생성하기란 상당히 어려운 것이 현실이며, 일단 결정된 규칙은 환경의 변화에 적용할 수 없다는 문제점이 있다. 이러한 문제점을 해결하기 위해, 본 논문에서는 인공신경망을 이용하여 퍼지 규칙을 생성하고 퍼지 추론의 소속함수를 조정할 수 있도록 한다.

2.5 추론 및 비퍼지화

본 논문에서는 인공신경망의 학습 방법을 이용하여 추론한다. 입력이 두 개이고 출력이 하나인 선형함수인 경우에 추론은 3장의 식 (6), (7), (8) 과 같이 수행된다.

퍼지 시스템의 출력은 입력 전체 집합에 정의

된 퍼지 집합으로 출력되는데, 제어에서는 퍼지 집합을 플랜트의 조작량으로서 출력하면 플랜트를 움직이게 할 수 없다.

따라서 출력부 전체집합에서 정의된 퍼지 제어 조작량을 명확한 비퍼지 제어 조작량으로 변환시켜주는 작업을 비퍼지화라 한다. 본 논문에서는 무게중심 방법을 이용하여 비퍼지화한다. 일반적으로 무게중심 방법이 다른 방법들에 비해서 우월한 성능을 보이는 경향이 있다[20].

3. 퍼지 신경망 추론 시스템

3.1 시스템의 구성

일반적으로 퍼지 시스템에서 전문가가 자신의 경험과 지식으로 규칙을 생성하기란 상당히 어려운 것이 현실이며, 일단 결정된 규칙은 환경의 변화에 적응할 수 없다는 문제점이 있다.

이러한 문제점을 해결하기 위해, 본 논문에서는 인공신경망을 이용하여 퍼지 규칙을 생성하고 퍼지 추론의 소속함수를 조정할 수 있는 모델을 제시하고자 한다. 일반적으로 인공신경망을 복잡하게 하면 학습 패턴에 대해서는 잘 처리할 수 있지만 문제의 성질을 일반화시키기에는 어려운 문제점이 있다. 특히 학습 패턴에 노이즈가 포함되어 있는 경우에는 본질적이지 못한 패턴까지도 학습된다. 따라서 복잡도를 줄일수 있는 방법도

모색되어야 한다.

본 시스템에서 사용한 모델은 (그림 5)와 같이 조건부([A]~[D]층)와 결론부 ([E]~[H]층)로 구성된다. 학습 방법으로는 역전파 알고리즘을 사용한다[19]. 그리고 복잡도를 줄이기 위해 이 모델은 다른 뉴로퍼지 모델들에 비해 중간 유닛의 수를 줄이고 대칭성을 높였다.

(그림 5)에서, [A]층부터 [D]층까지는 조건부로서 두 개의 입력 x_1 과 x_2 가 있다.

W_{c1} , W_{c2} , W_{c3} , W_{c4} 및 1은 연결 가중치를 의미하며, [B]층과 [C]층의 입력 및 출력은 각각 다음과 같다.

여기에서 i_j 와 o_j 는 각 층에서의 j 번째 유닛의 입력과 출력이고, w_{jk} 는 이전 층의 k 번째 유닛과 현재 층의 j 번째 유닛 사이의 연결 강도이며, o_k 는 이전층 k 번째 유닛의 출력이다.

$$\Sigma : \begin{cases} i_j = \sum_k w_{jk} o_k \\ o_j = i_j \end{cases} \quad (1)$$

$$f : \begin{cases} i_j = \sum_k w_{jk} o_k \\ o_j = f(i_j) \end{cases} \quad (2)$$

[C]층의 출력인 $f(i_j)$ 는 다음과 같은 sigmoid 함수로 표현될 수 있다.

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

[G]층의 입력 및 출력은 각각 다음과 같다.

$$i_j = \prod w_{jk} o_k \quad (4)$$

$$o_j = \frac{i_j}{\sum_k i_k} \quad (5)$$

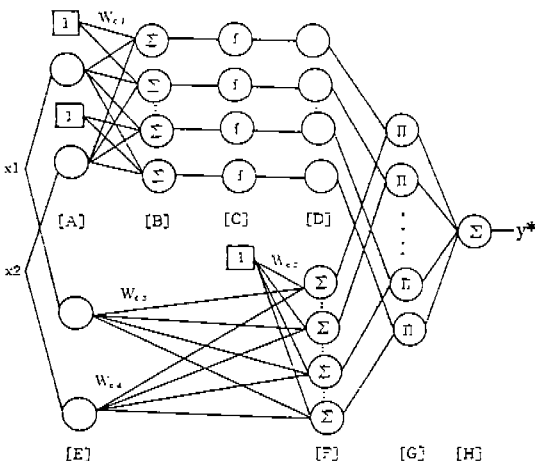
입력이 두 개이고 출력이 하나의 선형함수인 경우에 추론은 다음과 같이 수행된다.

$$R^i = \text{If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{12} \text{ then}$$

$$y_i = f_i(x_1, x_2) \quad (i = 1, 2, \dots, n) \quad (6)$$

$$f_i(x_1, x_2) = a_{i0} + a_{i1}x_1 + a_{i2}x_2$$

$$a_{ij} \quad (j = 0, 1, 2) : \text{상수} \quad (7)$$



(그림 5) 퍼지 신경망 추론 모델

(Fig. 5) A fuzzy neural network inference model

$$y^* = \sum_{i=1}^n w_i f_i(x_1, x_2) \quad (8)$$

이 때, R'는 i번째 퍼지 규칙이고, A_{ii}와 A_{ij}는 퍼지 변수이고, y*는 추론 값이다.

3.2 학습 알고리즘

기존의 역전파 알고리즘에서는, 출력값 o_j가 극한값에 접근할 때 오차 신호가 매우 작아질 수 있다. 이는 연결강도를 상당히 조정할만한 오차 신호를 생성하지 못함으로써 오차에서의 최소치 탐색을 지연시킨다. 이는 일부 출력 유니트들이 잘못된 극한값으로 진행될 때, 오차 신호를 증가시키는 것이 아니라 감소시키는 현상으로 나타날 수도 있다는 것이다.

이러한 수렴 지연 현상은 활성 함수의 미분에 기인한 것으로써, 기존의 퍼지 신경망들과는 달리, 본 논문에서는 역전파 학습 알고리즘의 오차 함수를 수정하여 오차 신호가 목표값과 실제값 간의 차이에 직접 비례하도록 하여 수렴도를 향상시키고자 한다.

오차 함수는 다소 임기응변적으로서, 여러 가지 함수를 적절히 사용할 수 있다. 기존의 역전파 알고리즘에서의 출력과 목표출력의 차이에 대한 제곱을 최소화하는 대신에, 본 논문에서는 다음과 같은 오차 함수를 사용한다.

$$E = - \sum_{j=1}^n [t_j \ln o_j + (1-t_j) \ln (1-o_j)] \quad (9)$$

여기에서, t_j는 목표출력값이고, o_j는 실제출력값이다. E를 최소화하기 위해 최급하강법에 따라 연결강도 w_{ji}에 대한 E의 미분은 다음과 같다.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial o_j} \cdot \frac{\partial o_j}{\partial w_{ji}} \quad (10)$$

이때,

$$\begin{aligned} \frac{\partial E}{\partial o_j} &= - \left\{ t_j \frac{1}{o_j} + (1-t_j) \frac{-1}{1-o_j} \right\} \\ &= \frac{1-t_j}{1-o_j} - \frac{t_j}{o_j} \\ &= \frac{(1-t_j)o_j - (1-o_j)t_j}{(1-o_j)o_j} \\ &= \frac{o_j - t_j}{(1-o_j)o_j} \end{aligned} \quad (11)$$

이며,

$$\frac{\partial o_j}{\partial w_{ji}} = o_j(1-o_j)y_i \quad (12)$$

이므로,

$$\begin{aligned} \frac{\partial E}{\partial w_{ji}} &= \frac{o_j - t_j}{(1-o_j)o_j} o_j(1-o_j)y_i \\ &= (o_j - t_j)y_i \end{aligned} \quad (13)$$

가 된다. 기존 역전파 알고리즘에서 출력과 목표 출력의 차이에 대한 제곱을 최소화하는 오차 함수를 사용할 때의 연결강도 w_{ji}에 대한 E의 미분이 (o_j-t_j)o_j(1-o_j)y_i으로 되는 것에 비해 o_j(1-o_j) 항이 없으므로, 오차 신호는 목표값과 실제값 간의 차이에 직접 비례하게 될 수렴도가 향상된다. 연결 가중치의 변화량은 다음과 같으며,

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad (14)$$

가 되며, 학습시 연결 가중치는 다음과 같이 수정된다.

$$\Delta w_{ji}(n+1) = -\eta \frac{\partial E}{\partial w_{ji}} + \alpha \Delta w_{ji}(n) \quad (15)$$

η와 α는 상수로서, 각각 학습률과 모멘텀 항(momentum term)이다.

4. 시뮬레이션


본 퍼지 신경망 모델의 타당성을 검증하기 위해 로보트 매니플레이터에 대해 시뮬레이션하였다. 사용한 로보트는 자유도가 4인 수평다관절형으로서, 링크의 길이는 각각 250과 180mm이다.

로보트 매니플레이터는 환산 계수 GE와 GC를 입력받는데, GE와 GC는 식 (16)과 같이 실제 입력 공간 X1' × X2'를 퍼지 입력 공간 X1 × X2으로 변환시킨다.

$$X_1 = X_1' \cdot GE \quad (16a)$$

$$X_2 = X_2' \cdot GC \quad (16b)$$

제어 성능을 향상시키기 위해서는 환산계수도 역시 역전파 알고리즘으로 조정하고 학습시켜야 한다. 따라서, 환산 계수의 변화량은 다음과 같다.



(그림 6) 첫번째 시도 결과
(Fig. 6) The first trial

〈표 1〉 로봇트 매니퓰레이터의 초기 가중치
(Table 1) Initial weights of robot manipulator

(a) Initial weights of joint 1

W_{c1}	W_{c2}	W_{c3}	W_{c4}
1.000	0.006	-0.008	-0.008
1.000	-0.009	-0.008	-0.002
1.000	0.005	0.006	0.003
1.000	0.009	0.009	-0.010
1.000	-0.001	-0.010	-0.005
1.000	-0.010	0.004	-0.001
1.000	0.006	0.005	-0.006
1.000	-0.000	-0.001	-0.009
1.000	0.000	-0.003	-0.005

(b) Initial weights of joint 2

W_{c1}	W_{c2}	W_{c3}	W_{c4}
1.000	-0.010	-0.006	0.008
1.000	0.008	-0.004	0.003
1.000	0.003	0.002	0.009
1.000	0.009	-0.001	-0.002
1.000	0.005	-0.000	0.002
1.000	-0.004	0.007	0.001
1.000	0.004	0.008	0.007
1.000	-0.005	0.002	0.005
1.000	-0.009	-0.003	0.006


$$\Delta GE = -\eta \frac{\partial E}{\partial GE}$$

$$\Delta GC = -\eta \frac{\partial E}{\partial GC} \tag{17a}$$


첫번째 시뮬레이션으로, 로봇트 매니퓰레이터가 타원 궤적을 추적하도록 하였다. (그림 6)은 첫번째 수행 결과로서, 실선은 원하는 궤적이고, 점선은 로봇트의 추적 경로이다. 〈표 1〉은 초기 가중치로서, 학습전의 조건부의 규칙 및 퍼지 부공간의 중요도는 모두 같다고 보고 W_{c1} 은 1로 설정하였으며, 결론부의 가중치들은 -0.01 부터 $+0.01$ 사이에서 임의로 설정하였다.

첫번째 수행 결과는 매우 큰 오차가 나타났으나, (그림 7)에서 보는바와 같이 두번째 시도부터 오차가 급격히 줄어들었음을 알수 있다. (그림 8)은 10번째 수행 결과로서, 학습이 반복됨에 따라 오차가 줄어들어 10번째 수행시에는 원하는 궤적을 거의 오차없이 추적하였다. 〈표 2〉는 10번째 학습 후의 가중치 변화로서, 학습을 거듭하면서 안정상태로 접어들어 적절한 규칙이 생성되었음을 볼 수 있다.

로봇트 매니퓰레이터가 다른 운동에도 적응하는가를 보여주기위해 본 시스템의 수정없이 (그림 9)와 같은 곡선을 추적하도록 하였다. 보는바와 같이, 오차없이 추적하였으며, 또한 적절한 규칙 생성도 확인 할 수 있었다.



(그림 7) 두번째 시도 결과
(Fig. 7) The Second trial



(그림 8) 열번째 시도 결과
(Fig. 8) The tenth trial


〈표 2〉 10회 학습 후의 가중치 변화
 (Table 2) Identified weights after 10th learning

(a) Identified weights of joint 1

W_{c1}	W_{c2}	W_{c3}	W_{c4}
1.041	-0.242	0.091	0.144
1.267	-0.748	0.240	0.021
1.018	-0.161	0.068	-0.091
1.087	-0.334	0.203	0.203
1.288	-0.129	0.831	0.131
1.013	-0.061	0.176	-0.049
1.002	0.061	0.018	-0.030
1.083	0.411	0.078	0.003
1.005	0.092	0.021	0.044

(b) Identified weights of joint 2

W_{c1}	W_{c2}	W_{c3}	W_{c4}
1.255	-0.587	0.293	0.407
1.983	-1.571	0.711	0.030
1.113	-0.391	0.193	-0.244
1.118	-0.240	0.442	0.175
1.892	0.169	1.636	0.143
1.086	0.070	0.450	0.047
1.082	0.338	0.161	-0.195
1.983	1.588	0.665	0.048
1.162	0.467	0.229	0.303



(그림 9) 시뮬레이션 2
 (Fig. 9) Simulation 2

5. 결 론

본 논문에서는 인공신경망을 이용하여 퍼지 규칙을 생성하고 퍼지 추론의 소속함수를 조정할 수 있는 모델을 제시하였으며, 역전과 알고리즘의 수렴도를 향상시키기 위해 알고리즘을 수정하여 적용하였다.

본 시스템의 타당성을 간단한 로봇 매니퓰레이터를 통해 검증하였다. 본 시스템은 충분한 학습 후에는(약 10회 정도) 만족할 만한 결과를 얻을 수 있었다. 그러나, 충분한 학습 전의 상태 즉, 완전한 규칙 베이스를 얻기 전까지의 상태에 적용할 수 있는 방법들에 대한 연구가 뒤따라야 하리라 사료된다.

참 고 문 헌

- [1] W.S. McCulloch and W.H. Pitts, "A Logical Calculus of Ideas Immanent in Nervous Activity," *Bulletin of Mathematical Biophysics*, 5, pp.115-133, 1943.
- [2] D.O. Hebb, "*The Organization of Behavior*," Wiley, 1949.
- [3] L.A. Zadeh, "Fuzzy Sets," *Information and Control*, 8, pp.338-353, 1965.
- [4] H. Ishibuchi and H.Tanaka, "Identification of Real-valued and Interval-valued Membership Functions by Neural Networks," *Proc. Inter. Conf. Fuzzy Logic & Neural Networks*, pp.179-182, 1990.
- [5] Y. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley, 1989.
- [6] K. Uehara and M.Fujise, "Learning of Fuzzy Inference Criteria with Artificial Neural Network," *Proc. Inter. Conf. Fuzzy Logic & Neural Networks*, pp.193-198, 1990.
- [7] S. Horikawa, et al., "A Fuzzy Controller Using a Neural Network and Its Capability to Learn Expert's Control Rules," *Proc. Inter. Conf. Fuzzy Logic & Neural Networks*, pp.103-106, 1990.

[8] B. Kosko, "Fuzzy Associative Memories," *Fuzzy Expert Systems*, A. Kandel (ed.), Addison-Wesley, 1987.

[9] J. Yen, "The Role of Fuzzy Logic in the Control of Neural Networks," *Proc. Inter. Conf. Fuzzy Logic & Neural Networks*, pp.771-774, 1990.

[10] T. Yamakawa and S. Tomota, "A Fuzzy Neuron and Its Application to Pattern Recognition," *Proc. 3rd IFSA Congress*, pp.30-38, 1989.

[11] M.M. Gupta and J. Qi, "On Fuzzy Neuron Models," *Proc. Inter. Joint Conf. Neural Networks*, pp.II-431-436, 1991.

[12] T. Takagi and M.Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control," *IEEE Trans. Systems, Man and Cybernetics*, Vol.SMC-15, No.1, pp.116-132, 1985.

[13] S. Horikawa, et al., "A Study on Fuzzy Modeling Using Fuzzy Neural Networks," *Proc. Inter. Fuzzy Engineering Symposium*, '91, pp.562-573, 1991.

[14] 임광우 외, "뉴럴-퍼지 융합을 이용한 퍼지 제어 규칙의 자동생성에 관한 연구," 전자공학회논문지, 제29권, B편, 제11호, pp.1066-1075, 1992.

[15] A. van Ooyen and B. Nienhuis, "Improving the Convergence of the Back-Propagation Algorithm," *Neural Networks*, Vol.5, No.3, pp.465-471, 1992.

[16] K. Uehara and M. Fujise, "Learning Algorithm for Multi-Stage Fuzzy Inference by Back-Propagating Error Information," *Proc. Inter. Fuzzy Engineering Symposium '91*, pp.1035-1046, 1991.

[17] H.Y. Xu, et al., "A Fuzzy Neural Net-

works Techniques with Fast Back Propagation Learning," *Proc. Inter. Joint Conf. Neural Networks*, pp.I-214-219, 1992.

[18] D.E. Rumelhart, et al., *Parallel Distributed Processing*, The MIT Press, 1986.

[19] L. A. Zadeh, "Outline of a New Approach to the Analysis of Complex Systems and Decision Processes," *IEEE Trans. Systems, Man, and Cybernetics*, Vol.SMC-3, No.1, pp.28-44, 1973.

[20] 이광형, 오길록, 퍼지 이론 및 응용, 홍릉과학출판사, 1991.

[21] H.-J. Zimmermann, *Fuzzy Set Theory and Its Applications*, Kluwer Academic Publishers, 1990.



장 문 석

1983년 광운대학교 전자계산학과 졸업(이학사)
 1985년 광운대학교 대학원 전자계산학과 졸업(이학석사)
 1991년 광운대학교 대학원 전자계산학과 박사과정 수료
 1988년~91년 순천대학교 전자계산학과 전임강사

1991년~95년 순천대학교 전자계산학과 조교수
 1995년~현재 순천대학교 전자계산학과 부교수
 관심분야: 인공지능, 퍼지 시스템, 인공신경망



장 덕 철

1974년 고려대학교 대학원 졸업(석사)
 1982년 고려대학교 대학원 졸업(박사)
 1981년~82년 University of California at Berkeley 객원교수

1976년~현재 광운대학교 전자계산학과 교수, 광운대학교 전산대학원장
 관심분야: 의사결정지원 시스템, 소프트웨어 공학