

퍼지 제어기와 퍼지 신경망제어기의 응답 특성에 관한 연구

김 형 수[†] · 이 상 부[†] · 김 흥 기^{††}

요 약

본 논문은 순수 퍼지 제어기와 신경망을 도입한 퍼지 신경망 제어기의 응답 특성에 대해 연구 고찰하였다. 퍼지 제어기는 초기치에서 과도 응답 특성이 우수하고 외란에도 강한 장점을 가지고 있지만 목표치에서 약간의 오차가 항상 있다. 이러한 정상 상태의 오차를 제거하기 위한 여러 방법이 소개되고 있다. 이런 관점에서 본 논문은 학습 능력이 있는 신경망(neural network)을 응용한 퍼지 신경망 제어기(fuzzy neural network controller)을 제안하였다. 이 퍼지 신경망제어기는 목표치에서 오차가 발생하는 기존 퍼지 제어기의 단점을 보완하여 오차없이 목표치에 정확하게 수렴하여 정밀 제어가 가능하게 된다. 이와같은 두 제어기 간의 목표치에 수렴하는 응답 특성은 모의 실험을 통해 비교하였다.

A study on the Response Characteristics of Fuzzy Controller & Fuzzy Neural Network Controller

Hyung Soo Kim[†] · Sang Boo Lee[†] · Hong Gi Kim^{††}

ABSTRACT

This study examines the response characteristics of the fuzzy controller and the fuzzy neural network controller. The former is excellent in terms of the overshoot at its initial values and has great advantages on the disturbance. But there exist some errors in its desired output. Many methods have been introduced that remove the errors of the desired state. This study is in more favor of the fuzzy neural network controller using the neural network than any other method. The fuzzy neural network controller complements the shortcomings of fuzzy controller and can be an accurate controller by being well-without any disturbance or error-converged to the desired output. And it is through simulation that the comparison of the two controllers is carried out in this study.

1. 서 론

퍼지 제어기는 미지의 플랜트 또는 수학적 모델링이 불가능한 복잡한 시스템에 있어서도 퍼지 추론에 의해 적절한 제어량을 얻을 수 있다. 그러나 이 퍼지 제어기는 초기치에서 큰 과도 응답(overshoot)없이 목표치에 잘 수렴하지만 정상상태에서의 편차, 즉 목표점의 주위에서 약간의 오차가 항상 존재하는 문제점이 있다. 이러한 문제점은 성능 결정표(look-up table)

† 종신회원: 한라전문대학(Halla Junior College) 전산정보처리과 교수

†† 정회원: 충북대학교(Chungbuk National Univ) 컴퓨터과학과 교수

논문접수: 1996년 3월 20일, 심사완료: 1996년 6월 17일

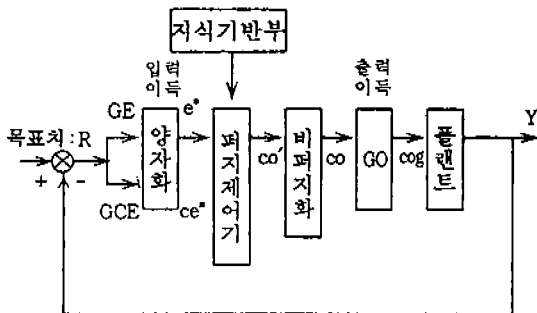
의 제어 입력값들이 이산적(discrete)이기 때문이다. 그래서 목표치 부근에서 제어 입력이 진동하여 목표치 값에 정확하게 수렴하지 못하므로 결과적으로 정밀 제어가 사실상 어렵게 된다. 반면에 학습 능력을 가지고 있는 신경망[1]을 도입한다면 이러한 퍼지 제어기의 문제점은 해결할 수 있다[2][3]. 즉 퍼지제어기[4]의 결론부 언어항에 대한 소속함수(membership function)의 모양은 고정시키고, 조건부 언어항만을 조정함으로써 목표치에 정확한 수렴을 기대 할 수 있다.

이런 관점에서 본 논문은 순수 퍼지 제어기의 한계성을 제거하여 정밀제어가 가능한 퍼지 신경망제어기(fuzzy neural network controller)를 제안하고 있는데, 모의 실험(simulation)을 통하여 퍼지 제어기와 제안된 퍼지 신경망제어기 간의 응답특성(response characteristics)을 서로 비교하였다.

2. 퍼지 제어기의 기본 구조

2.1 퍼지 제어기의 구성

퍼지 논리는 인간의 사고나 자연어의 특성과 많은 유사성을 가지고 있어서 실제계의 근사적인 불확실한 현상을 기술 하는데 유용하게 이용된다. 퍼지제어기는 주로 전문가의 경험을 언어적 규칙을 통해 추론함으로써 구해지며[5], 플랜트(plant)를 제어하는 퍼지 제어기의 구성은 (그림 1)과 같다.



(그림 1) 퍼지제어기의 구성
(Fig. 1) Block diagram of fuzzy logic controller

퍼지 제어기는 크게 입력 변수를 받아 양자화하는 입력 부분, 규칙을 추론하는 제어기 부분 그리고 추론된 값을 비퍼지화하는 출력 부분으로 구분된다. 본

논문에서는 입력 목표치로 부터의 오차(error)와 전 샘플링(sampling)으로 부터의 오차변화량(change in error)의 형태가 사용되어지고 있다.

퍼지제어기 (그림 1)에서 오차(e) 및 오차변화량(ce)을 계산하는 수식은 다음과 같다.

$$e = R - Y, ce = e_2 - e_1 \tag{1}$$

단, Y: 플랜트 출력

R: 목표치

e : 오차(목표치-플랜트 출력치)

ce : 오차 변화량

e₁ : 현재보다 1 샘플링 이전의 오차

e₂ : 현재의 오차

2.2 퍼지화

2.2.1 소속 함수

매대한 정보를 정량적으로 표현하기 위해서 소속 함수를 정의하는 것이 필요하다. 소속 함수는 보통 전문가의 경험이나 주관적인 지식에 의해 정의되며, 그 형태로는 범종형, 삼각형, 사다리꼴 형태가 있지만 삼각형 형이 주로 많이 사용된다. 본 논문에서는 제어공학자의 지식과 경험을 통하여 제시된 이산적인 삼각 소속 함수를 사용하였다. 이 이산적인 삼각 소속 함수는 연속적인 함수값으로 표현되는 것이 아니라, 이산적인 함수값을 가지므로써 규칙의 행렬 표현이 간단해지고 데이터의 메모리를 축소시킬 수 있는

〈표 1〉 소속 함수

〈Table 1〉 Membership function

	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6
NB	1.0	0.7	0.3	0	0	0	0	0	0	0	0	0	0
NM	0.3	0.7	1.0	0.7	0.3	0	0	0	0	0	0	0	0
NS	0	0	0.3	0.7	1.0	0.7	0.3	0	0	0	0	0	0
ZO	0	0	0	0	0.3	0.7	1.0	0.7	0.3	0	0	0	0
PS	0	0	0	0	0	0	0.3	0.7	1.0	0.7	0.3	0	0
PM	0	0	0	0	0	0	0	0	0.3	0.7	1.0	0.7	0.3
PB	0	0	0	0	0	0	0	0	0	0	0.3	0.7	1.0

PB: positive big

PM: positive medium

PS: positive small

ZO: zero

NS: negative small

NM: negative medium

NB: negative big

장점이 있다. 본 논문에서 사용한 이산적인 삼각 소속 함수의 값은 <표 1>과 같다.

2.2.2 양자화

퍼지 제어기에서 입력 변수인 오차(e) 및 오차의 변화량(ce)에 대한 양자화(quantization)의 값은 13단계 (-6 ~ +6)로 양자화하는데 다음과 같은 이산 집합으로 표현할 수 있다.

$$E = \{e\} = \{-6, -5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6\}$$

$$CE = \{ce\} = \{-6, -5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6\}$$

(2)

(1) 입력 이득

일반적으로 제어기의 변수들은 정규화된(normalized) 전체 집합이 사용되기 때문에 (식 3)에서 처럼 측정된 입력값에 이득(gain)을 곱한 후 대응되는 전체 집합에 사상(mapping) 시킨다.

$$ge = e \times GE$$

$$gce = ce \times GCE$$

(3)

단, GE : 오차의 입력 이득

GCE : 오차 변화량에 대한 입력 이득

(2) 비선형 양자화

제어기의 변수에 대한 전체 집합이 이산 집합(discrete set)인 경우는 입력 이득에 의해 구해진 입력 변수는 다시 양자화 되어야 하는데 양자화된 값 e^*, ce^* 는 (식 4)와 같다.

$$e^* = (ge)q$$

$$ce^* = (gce)q$$

(4)

단, q: 양자화

결과적으로 입력을 위한 비선형 양자화 단계 및 대 집합 범위는 <표 2>와 같다.

2.2.3 퍼지 제어 규칙

제어 규칙은 IF-THEN 형식으로 조건부와 결론부가 언어 변수(linguistic variable)인 퍼지 집합으로 표현되는데 다음과 같다.

<표 2> 비선형 양자화 단계
<Table 2> Level of nonlinear quantization

양자화 단계 e^*, ce^*	대집합 범위
-6	$X \leq -80$
-5	$-80 < X \leq -15$
-4	$-15 < X \leq -9$
-3	$-9 < X \leq -2$
-2	$-5 < X \leq -2$
-1	$-2 < X \leq -1$
0	$-1 < X \leq +1$
1	$+1 < X \leq +2$
2	$+2 < X \leq +5$
3	$+5 < X \leq +9$
4	$+9 < X \leq +15$
5	$+15 < X \leq +80$
6	$+80 < X$

IF e is 'positive big' and ce is 'negative small'
THEN co is 'positive medium'

여기서 '안은 언어적 퍼지 변수로 <표 1>의 소속 함수의 값이고 co는 퍼지 제어기의 출력이다. 퍼지 제어기에서 제어 규칙은 플랜트에 대한 퍼지 모델의 설정이라든지, 전문가의 지식이나 경험 또는 조작자의 제어 기능 등을 통해 추출한다. 본 논문에서는 첫 번째의 전문가의 지식 또는 경험에 의해 제어 규칙을 얻었는데, 작은 과도 응답(overshoot)과 빠른 응답 특성을 얻기 위한 플랜트 출력을 제어 규칙은 <표 3>과 같다.

<표 3> 제어 규칙
<Table 3> Control rule

c/ce	NB	NM	NS	ZO	PS	PM	PB
NB	-	-	-	NB	NM	-	-
NM	-	-	-	NM	-	-	-
NS	-	-	-	NS	ZO	-	PM
ZO	NB	NM	NS	ZO	PS	PM	PB
PS	NM	-	ZO	PS	-	-	-
PM	-	-	-	PM	-	-	-
PB	-	-	PM	PB	-	-	-

2.3 추론

퍼지 제어기에 있어서 퍼지 제어 규칙은 복수개의 퍼지 규칙이 곱(and)과 합(also)의 형태로 구성된다. 이러한 퍼지 규칙은 제어 입력값이 되는 데 제어기의 정확한 출력값을 추론하기 위해서, 1974년 E. H. Mamdani가 제안한 Max-Min 방법[5]을 많이 이용한다. 이 추론 방법은 근사 추론의 합성 규칙을 이용한 것으로써 추론의 식은 다음과 같다.

$$\mu_R(e, ce, co) = \text{Min}(\mu_E(e), \mu_{CE}(ce), \mu_{CO}(co))$$

$$\mu_{CO}(co) = \text{Max} - \text{Min}(\mu_E(e'), \mu_{CE}(ce'), \mu_{CO}(co)) \quad (5)$$

단, e' , ce' : 제어기 입력의 퍼지 집합
 co' : 추론된 제어기 출력값
 μ : 소속 함수값

측정된 제어기 입력은 언어적 값이 아니고 실수값이다. 이러한 실수값을 퍼지화한 다음 이 입력값으로 추론하여 결과값을 계산하는 데는 복잡함과 많은 시간이 요구된다. 그래서 e 와 ce 에 대해서 특정 측정값 e' 와 ce' 가 입력 되면 그 값에 대한 퍼지 집합의 소속 함수를 모두 표현하지 않고 그때 그 부분 값만을 취하는 결정론적인 입력 형태 e^o 와 ce^o 를 제시한다.

$$\mu_E(e^o) = \begin{cases} 1 & e^o = e' \\ 1 & \text{그외} \end{cases}$$

$$\mu_{CE}(ce^o) = \begin{cases} 1 & ce^o = ce' \\ 1 & \text{그외} \end{cases} \quad (6)$$

그러면 식(5)는 식(6) 의해 식(7)과 같이 된다.

$$\mu_{CO}(co) = \text{Max} - \text{Min}(\mu_E(e^o), \mu_{CE}(ce^o), \mu_{CO}(co)) \quad (7)$$

또한 규칙이 n 개 있을때 각 규칙간은 합의 형태로 연결되어 있어 n 개의 추론 결과 $\mu_{CO}(co)$ 를 얻기 위해서는 각 규칙의 소속 함수의 값에 대해 다음과 같이 Max 연산을 수행하여 얻는다.

$$\mu_{CO}(co) = \text{Max}(\mu_{CO_1}(co_1), \mu_{CO_2}(co_2), \mu_{CO_3}(co_3), \dots, \mu_{CO_n}(co_n)) \quad (8)$$

본 논문에서 언어 변수들의 제어 규칙과 Max-Min 추론 규칙에 적용하여 출력값을 구하는 과정은 다음과 같다. 실제 제어기에서 측정된 오차는 10V, 오차 변화량은 -6V, GE, GEC는 각각 1로 한다. 이때 (식 4)와 <표 2>에 의해서 양자화값 e^* 는 +4이고 ce^* 는 -3이다. 이 양자화 값에 대한 규칙은 <표 3>에 의해 다음 2가지 규칙이 적용된다.

R1: IF e is 'PB' and ce is 'NS' THEN co is 'PM'
 R2: IF e is 'PS' and ce is 'NS' THEN co is 'ZO'

이 규칙에서 입출력에 대한 언어적 값의 소속 함수는 <표 1>에 정의 되어있다. (식 5)에 의한 출력은 다음과 같이 구하며 여기서 / 오른쪽은 대집합을 의미하고, 왼쪽은 소속 함수를 의미한다.

$$R1: [0.3/4, 0.7/5, 1.0/6] \wedge [0.3/-4, 0.7/-3, 1.0/-2, 0.7/-1, 0.3/0] \wedge [0.3/2, 0.7/3, 1.0/4, 0.7/5, 0.3/6]$$

$$R2: [0.3/0, 0.7/1, 1.0/2, 0.7/3, 0.3/4] \wedge [0.3/-4, 0.7/-3, 1.0/-2, 0.7/-1, 0.3/0] \wedge [0.3/-2, 0.3/-1, 1.0/0, 0.7/1, 0.3/2] \quad (9)$$

소속 함수로 표현된 규칙은 (식 6)에 의해 다음과 같이 쓸 수 있다.

$$R1: 0.3 \wedge 0.7 \wedge [0.3/2, 0.7/3, 1.0/4, 0.7/5, 0.3/6] = [0.3/2, 0.3/3, 0.3/4, 0.3/5, 0.3/6]$$

$$R2: 0.3 \wedge 0.7 \wedge [0.3/-2, 0.7/-1, 1.0/0, 0.7/1, 0.3/2] = [0.3/-2, 0.3/-1, 0.3/0, 0.3/1, 0.3/2] \quad (10)$$

(식 8)에 의해 최종 결과 값은 다음과 같다.

$$co' = [0.3/-2, 0.3/-1, 0.3/0, 0.3/1, 0.3/2, 0.3/3, 0.3/4, 0.3/5, 0.3/6] \quad (11)$$

2.4 비퍼지화

제어규칙에 의해서 추론된 출력값은 퍼지값이므로 이 값을 플랜트의 입력값으로 하기 위해서는 결정론적인 값으로 바꾸어야 한다. 이처럼 퍼지값을 결정론

적인 값 즉, 비퍼지 값으로 바꾸는 과정을 비퍼지화(defuzzification)라 한다. 이러한 비퍼지화 방법으로는 Mean of maxima, Average of maxima, Center of gravity 방법이 있는데 본 논문에서는 무게 중심법(center of gravity)을 이용하였다. 앞 절의 예를 무게중심법에 의거 결정론적인 비퍼지 값을 구하는 식은 다음과 같다.

$$co = \frac{\sum(\text{소속 함수값을 갖는 대집합}) \times (\text{해당 대집합의 소속 함수값})}{\sum \text{소속 함수값}} \quad (12)$$

(식 12)에 대입하여 계산한 비퍼지화 값 co의 결과는 2이다.

2.5 출력 이득

비퍼지화한 후의 결정론적인 값은 (식 13)에 나타낸 것처럼 출력이득 Go를 곱함으로써 정규화된(normalized) 값에서 실제적인 제어기 출력값, 곧 플랜트의 입력으로 된다.

$$Cog = Go \times co \quad (13)$$

2.6 성능 결정과 영향대

2.6.1 성능 결정표

어떤 입력이 주어졌을때 제어 규칙에서 비퍼지화 과정까지 매우 복잡한 과정을 거쳐 원하는 출력값을 얻기 때문에, 미리 모든 입력의 경우를 가산하여 비퍼지화 값을 구해서 13×13 크기의 배열로 만들어 놓은 표를 성능 결정표(look-up table)라 한다.


2.6.2 영향대

영향대(zone of influenc)는 성능 결정표에서 출력값을 보다 안정된 출력을 구하기 위하여, 성능 결정표의 입력에 해당된 출력값을 출력시키지 않고 그 주위에 있는 영향도 고려한다. 이것을 사용하는 방법은 먼저 그때 입력되는 e와 ce의 상태에 따른 양자화 값을 알고 성능 결정표에서의 e와 ce의 양자화 값을 중심으로 제어 규칙 5×5의 배열 형태인 영향대를 위치시켜 무게 중심법으로 결정론적인 비퍼지값을 구해 출력한다.

3. 다층 신경망

3.1 구 조

다층 신경망(multi neural network)은 (그림 2)에 나타낸 것처럼 입력층, 은닉층, 출력층 방향으로 네트워크(network)가 구성된다. 각 층 내에서의 신경세포(neuron)들과 그리고 출력층과 입력층 간의 직접적인 연결은 없다. 이 다층 신경망은 중간층과 각 유니트의 입출력 특성을 비선형화 함으로써 단층 신경망을 보완한 것으로 제어 분야에서 광범위하게 사용되는 대표적인 신경망 구조이다. 다층 신경망의 학습 알고리즘으로는 인스타(instar)규칙 등의 무감독 학습방법과 오차역전파(error back propagation)의 감독 학습방법으로 구분되는데 일반적으로 오차역전파 알고리즘을 많이 사용한다.



(그림 2) 다층 신경망 구조
(Fig. 2) Multi-layer neural network

3.2 오차 역전파 학습알고리즘

감독학습(supervised learning)의 하나인 오차 역전파 학습알고리즘(error back-propagation learning algorithm)은 학습시켜야 할 모든 패턴들에 대하여 각각의 기대되는 출력(desired output)과 신경망의 실제출력(actual output) 사이의 오차가 최소화 되도록 신경망의 연결가중치(connection weight)들을 조정하는 알고리즘이다.

각 층마다의 연결 가중치의 변화량을 산출할 수 있는데 신경망의 입력층의 신경세포 i에서 은닉층의 신경세포 j로의 연결 강도 변화량(\$\Delta W_{ji}\$)은 (식 14)와 같이 표현된다.

$$\Delta W_{ji} = \eta (T_j - O_j) i_i = \eta \delta_j i_i \quad (14)$$

단, \$T_j\$: 신경세포 j의 목표출력

- O_j : 신경세포 j의 실제출력
- i_j : 입력층 신경세포 i에 주어지는 입력
- δ_j : 목표출력과 실제출력의 차($T_j - O_j$)
- η : 학습률(learning rate)

또한 오차 역전파 학습 알고리즘에서의 출력층의 에너지 함수는 (식 15)와 같이 정의되며 각 층의 활성화 함수(activation function)는 (식 16)으로 시그모이드 함수의 입력력 특성을 갖는다.

$$E = 1/2 \sum_j (T_j - O_j)^2 \tag{15}$$

$$O_j = f(net_j) = \frac{1}{1 + \exp(-net_j)} \tag{16}$$

단, $net_j = \sum_i W_{ji} O_i$ 으로 신경세포 j의 입력 총합

출력층의 에너지 함수 (식 15)가 최소화 되도록 최급하강법(gradient descent rule)을 이용하여 연결강도를 수정한다. 이때 상위층 j와 하위층 i와의 연결강도 변화는 다음과 같다.

$$\begin{aligned} \Delta W_{ji} &= -\eta \frac{\partial E}{\partial W_{ji}} \\ &= -\eta \frac{\partial E}{\partial net_j} \cdot \frac{\partial net_j}{\partial W_{ji}} \\ &= -\eta \frac{\partial E}{\partial net_j} \cdot O_i \\ &= \eta \delta_j O_i \quad (\delta_j = \frac{\partial E}{\partial net_j}) \end{aligned} \tag{17}$$

한편, $f'(net_j) = O_j(1 - O_j)$ 으로 정의하면 j가 출력층인 경우 (식 17)의 δ_j 는 다음과 같이 구한다.

$$\begin{aligned} \delta_j &= \frac{\partial E}{\partial net_j} \\ &= \frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \\ &= (T_j - O_j) f'(net_j) \end{aligned} \tag{18}$$

그리고 j가 은닉층일 경우 δ_j 는 (식 19)에 의해 정해진다.

$$\delta_j = f'(net_j) \sum_k \delta_k W_{kj} \tag{19}$$

결과적으로 신경망에서 상위층 j와 하위층 i와의 연결 강도의 변화 ΔW_{ji} 는 다음과 같이 요약된다.

$$\Delta W_{ji} = \eta \delta_j O_i \tag{20}$$

위의 학습 과정에서 은닉층의 경우에 있어서는 재귀적(recursive) 연산이 이루어지며 일반적으로 많이 쓰이는 연결 가중치 변화에 대한 식은 다음과 같은데 특히, 모멘텀(momentum)항 α 는 바로 전의 연결강도 변화량을 얼마만큼 적용시킬 것인가를 결정하여 수렴 속도를 빨리하기 위해 첨가한 항이다.


$$\Delta W_{ji}(n+1) = \eta \delta_j O_i + \alpha \Delta W_{ji}(n) W_{ji}(n) \tag{21}$$

단, n: 학습 회수, η : 학습률, α : 모멘텀항

4. 퍼지신경망 제어기

4.1 퍼지신경망의 구성

학습 능력을 가지고 있는 신경망을 이용하여 목표치에서 오차가 있는 퍼지 제어기의 단점을 보완한 퍼지 신경망제어기(fuzzy neural network)[6][7][8]의 구성은 (그림 3)과 같다.




(그림 3) 퍼지 신경망의 구성
(Fig. 3) Structure of fuzzy neural network

퍼지추론 방법에 의해서 입력 언어항에 대한 소속 정도를 계산하는 곳은 Box A에서 이루어진다. 신경망의 함수 근사화 능력을 이용하여 비퍼지화 연산은 Box B에서 실행되어 Y에 대응하는 기대값 δ_j 를 구한다. (그림 3)에서 각 층에 대한 기능은 다음과 같고 층과 층사이의 연결 강도는 1이다.

- k 층:결론부에 가지고 있는 퍼지규칙들의 소속정도를 MAX 연산에 의해서 합성한다. 노드의 수는 출력변수에 정의된 언어항의 개수와 같다.
- l 층:퍼지규칙의 조건부에 해당하고 m층에서 계산된 소속정도를 MIN 연산으로 합성을 한다.
- m 층:입력의 언어항에 대한 소속정도는 (식 22)에서 계산하며[4] x는 입력 값이다.

$$\mu_{C^m, S_L^m, S_R^m}(x) = \begin{cases} 1 - \frac{x - C^m}{S_R^m} & x \in [C^m, C^m + S_R^m] \\ 1 + \frac{x - C^m}{S_L^m} & x \in [C^m - S_L^m, C^m] \\ 0 & \text{그 외} \end{cases} \quad (22)$$

단, C^m, S_L^m, S_R^m :삼각 퍼지함수의 중앙점, 좌측폭 및 우측폭



(그림 4) 조건부 언어항의 삼각퍼지 소속함수

(Fig. 4) Triangle fuzzy function of conditional linguistic term

n 층: 입력변수를 받는다.

4.2 평가 절차 및 모의 실험 결과

4.2.1 신경망의 에러 수정

Box A의 소속함수를 수정하기 위한 방법으로 최급하강법을 사용하는데 Box B의 학습오차를 역전파 시

켜서 입력과 각 규칙의 소속정도에 대한 오차값을 간접적으로 계산한다. k층의 뉴런에 역전파되는 오차값 e_k 는 (식 19)에 의해 (식 23)과 같다.

$$e_k = -\frac{\partial E}{\partial net_j} = \sum_j e_j W_{kj} \quad (23)$$

또한 k층에서의 기대 출력값을 t_k , 실제 출력값을 O_k 라 하면 시스템의 오차 E'는 (식 24)과 같다[9].

$$E' = 1/2 \sum (t_k - O_k)^2 \quad (24)$$

한편, Box A의 학습을 위하여 $-\frac{\partial E'}{\partial O_k} = (t_k - O_k)$ 대신에 k층의 오차값 e_k 를 사용하는데 chain rule [9][10]에 의해서 m층의 C^m, S_L^m, S_R^m 가 (식 25), (식 26), (식 27)과 같이 수정된다[10].

$$\begin{aligned} \Delta C^m &= -\eta \frac{\partial E'}{\partial C^m} \\ &= -\sum_j \frac{\partial E'}{\partial O_k} \cdot \frac{\partial O_k}{\partial C^m} \\ &= -\eta \sum_k \frac{\partial E'}{\partial O_k} \sum_l \frac{\partial O_k}{\partial O_l} \frac{\partial O_l}{\partial O_m} \frac{\partial O_m}{\partial C^m} \\ &= \eta \sum_k e_k \sum_l \frac{\partial O_k}{\partial O_l} \frac{\partial O_l}{\partial O_m} \frac{\partial O_m}{\partial C^m} \end{aligned} \quad (25)$$

$$\begin{aligned} \Delta S_L^m &= -\eta \frac{\partial E'}{\partial S_L^m} \\ &= \eta \sum_k e_k \sum_l \frac{\partial O_k}{\partial O_l} \frac{\partial O_l}{\partial O_m} \frac{\partial O_m}{\partial S_L^m} \end{aligned} \quad (26)$$

$$\begin{aligned} \Delta S_R^m &= -\eta \frac{\partial E'}{\partial S_R^m} \\ &= \eta \sum_k e_k \sum_l \frac{\partial O_k}{\partial O_l} \frac{\partial O_l}{\partial O_m} \frac{\partial O_m}{\partial S_R^m} \end{aligned} \quad (27)$$

$$\text{단, } \frac{\partial O_k}{\partial O_l} = \begin{cases} 1 & \text{if } O_k = O_l \text{ and } W_{lk} = 1 \\ 1 & \text{그 외} \end{cases}$$

$$\frac{\partial O_l}{\partial O_m} = \begin{cases} 1 & \text{if } O_l = O_m \text{ and } W_{ml} = 1 \\ 0 & \text{그 외} \end{cases}$$

4.2.2 성능 평가

Box B는 3층의 신경망으로 구성 되어있고 오차 역

전과 학습방법을 사용하며, 성능평가 척도 E는 (식 28)과 같다[9].

$$E = \frac{1}{2} \sum (\delta_i - O_i)^2 \tag{28}$$

i, j 층의 활성화 함수는 시그모이드(sigmoid)함수를 사용하고, i, j층의 오차값 e_i, e_j 은 (식 18), (식 19)에 의해서 (식 29), (식 30)과 같다.


$$\begin{aligned} e_i &= -\frac{\partial E}{\partial net_i} \\ &= -\frac{\partial E}{\partial O_i} \frac{\partial O_i}{\partial net_i} \\ &= (\delta_i - O_i) f'(net_i) \end{aligned} \tag{29}$$

$$\begin{aligned} e_j &= -\frac{\partial E}{\partial net_j} \\ &= -\frac{\partial E}{\partial O_j} \frac{\partial O_j}{\partial net_j} \\ &= \sum_i e_i W_{ji} f'(net_j) \end{aligned} \tag{30}$$

(그림 3)의 퍼지신경망 제어를 실험하기 위해 Box A에서는 (그림 5)와 같은 삼각형 소속함수를 사용하여 조건부의 소속함수를 수정하였다.

또한 Box B에서는 오차 역전파 신경망 규칙으로 학습을 시켰으며 각 층의 노드와 신경세포의 갯수는 다음과 같다.

- i 층: 출력층으로 1개의 신경세포를 가진다.
- j 층: 은닉층으로서 오차역전파 학습을 위해 14개의 신경세포를 할당했다.
- k 층: (그림 5)에서 사용한 7가지 퍼지라벨에 해당하는 7개의 신경세포를 가진다.
- l 층: (표 3)의 제어규칙에 해당하는 49개의 노드를 갖는다.
- m 층: (그림 5)에서 사용한 7가지 퍼지라벨에 해당하는 $7 \times 2 = 14$ 개의 노드를 갖는다.
- n 층: 목표치 R에 플랜트의 출력 Y를 뺀 오차값 e와 현재의 오차에 현재보다 1 샘플링(sampling)이전의 오차를 뺀 오차 변화량 Δe 가 입력되므로 2개의 노드를 갖는다.




(그림 5) 삼각형 소속함수 형태
(Fig. 5) Type of triangle membership function

4.2.3 모의 실험 결과

퍼지 제어기와 퍼지 신경망제어기의 응답 특성을 비교하기 위한 모의실험(simulation)에서 목표치 R은 80, 샘플링 시간은 1초, 전구간은 160 샘플(sample)로 하였다. 또한 2차 플랜트를 사용하였으며 2차 플랜트의 전달함수는 (식 31)와 같다.

$$Gp(s) = \frac{1}{s(s+1)} \tag{31}$$


(그림 6)은 퍼지 제어기에서의 응답 특성에 대한 그래프로써 정상 상태에서 항상 미세한 오차의 값을 가져서 목표치 R에는 정확히 수렴하지 못하는 것을 알 수 있다.



(그림 6) 퍼지 제어기 출력 그래프
(Fig. 6) Output graph of fuzzy controller

반면에 (그림 7)은 퍼지 신경망 제어기의 출력 응답 그래프로써 응답 특성이 (그림 6)의 퍼지 제어기의 출

력 결과보다 과도 응답 없이 목표치에 정확하게 수렴할 뿐만 아니라 퍼지 제어기보다 정상상태에 빨리 도달하고 있음을 알 수 있다.



(그림 7) 퍼지 신경망 제어기의 출력 그래프
(Fig. 7) Output graph of fuzzy neural network controller

5. 결 론

퍼지 제어기는 외란(disturbanc)에 강하고 과도 응답특성이 우수하나, 제어입력들이 성능 평가표로 되고 오차 및 오차변화량이 양자화에 의해 설정된 범위로 사상되기 때문에 목표 지점에서 항상 정상 상태의 편차를 가지게 됨을 모의실험 결과 그래프에서 확인할 수 있었다. 이와 같은 퍼지 제어기의 단점인 정상 상태의 편차를 없애기 위하여 학습 능력을 가지고 있는 신경망을 이용한 퍼지 신경망제어기를 제안하였다. 이 퍼지 신경망제어기는 퍼지제어기의 결론부 언어항의 소속함수 모양은 고정하고, 조건부 언어항만을 조정하는 방법을 사용 함으로써 정상상태에서 편차없이 목표값에 정확히 수렴했을 뿐 만 아니라 순수 퍼지제어기보다 정상상태에 이르는 수렴속도가 빠르다는 것을 모의실험을 통해 확인되었다.

따라서 본 논문에서 제안된 퍼지 신경망제어기는 적용제어, 로봇 및 발전제어는 물론 산업체의 정밀 제어 분야에서 응용이 가능하리라 여긴다.

참 고 문 헌

- [1] 이광형, 오길록, "퍼지 이론 및 응용 I", 홍릉과학 출판사, 1991.
- [2] 이오걸, "퍼지 기법으로 구동되는 직류 서보 시스템의 위치 제어", 박사학위논문, 동아대학교 대학원, 1992.
- [3] 박민용, 최항식 역, "퍼지 제어 시스템", 대영사, 1990.
- [4] 이용노, 김태원, 서일홍, "특업 테이블을 이용한 자동학습 퍼지제어기의 설계에 관한 연구", 전자공학회 논문지 제29권 B편 제9호, pp. 76-87, 1992.
- [5] Jacek M. Zurada, "Artificial neural systems", pp. 25-43, West publishing company, 1992.
- [6] James J. Buckley, Yoichi Hayashi, "Fuzzy neural networks," Fuzzy Sets and Systems 66, pp. 1-11, 1994.
- [7] Hiroyuki Okata, Nobuo Watanabe, Akira Kawamura, Kazuo Asakawa, "Initializing Multilayer Neural Networks with Fuzzy Logic", IJCNN International Joint Conference on Neural networks, pp. I-239~I-244, June 1992.
- [8] James J. Buckley, Yoichi Hayashi, "Hybrid neural nets can be fuzzy controllers and fuzzy expert systems", Fuzzy sets and systems 60, pp. 135-140. 1993.
- [9] Saiful Akhyar, Sigeru Omatu, "Neuromorphic self-Tuning PID Controller," IEEE Trans syst. Vol. 3, pp. 552-557, July 1993.
- [10] Toshio Fukuda, Takanori Shibata, "Theory and Application of Networks for Industrial Control Systems," IEEE Trans. Indus. Elec., Vol. 39. No. 6., pp. 472-487, December 1992.



김 형 수

1981년 제주대학교 수학교육과 졸업
 1985년 성균관대학교 경영대학원 정보처리과 졸업(경영학 석사)
 1991년 숭실대학교 정보산업대학원 정보산업과 졸업(이학 석사)

1995년 충북대학교 대학원 전자계산학과 박사과정
이수

1986년~1991년 강원대, 충북대, 국민대, 카톨릭대 강사

1992년~현재 한라전문대학 전산정보처리과 교수

연구분야: 퍼지로지, 신경회로망, 유전진화알고리즘,
계산이론, 자연어처리, 지능시스템



이 상 부

1983년 동아대학교 전자공학과 졸업

1985년 동아대학교 대학원 전자
자공학과 졸업(공학석사)

1996년 동아대학교 대학원 전자
공학과 박사과정 이수

1986년~1992년 삼익전자 및 회
망전자 근무

1994년~현재 한라전문대학 전산정보처리과 교수

연구분야: 퍼지, 신경회로망, 유전진화알고리즘, 카오
스, 마이크로프로세서응용



김 홍 기

1961년 연세대학교 수학과 졸업

1985년 중앙대학교 대학원 응용
수학과(이학박사)

1986년~1987년 캘리포니아 주
립대학 교환교수

현재 충북대학교 컴퓨터과학과
교수

연구분야: 퍼지 및 카오스이론, 계산이론, 신경회로망,
유전진화알고리즘, 지능시스템, 자연어처리