

PD 기반의 퍼지제어기로 제어된 로봇의 새로운 신경회로망 보상 제어 기술

A Novel Neural Network Compensation Technique for PD-Like Fuzzy Controlled Robot Manipulators

송 덕 희, 정 슬*
(Deok-Hee Song and Seul Jung)

Abstract : In this paper, a novel neural network compensation technique for PD like fuzzy controlled robot manipulators is presented. A standard PD-like fuzzy controller is designed and used as a main controller for controlling robot manipulators. A neural network controller is added to the reference trajectories to modify input error space so that the system is robust to any change in system parameter variations. It forms a neural-fuzzy control structure and used to compensate for nonlinear effects. The ultimate goal is same as that of the neuro-fuzzy control structure, but this proposed technique modifies the input error not the fuzzy rules. The proposed scheme is tested to control the position of the 3 degrees-of-freedom rotary robot manipulator. Performances are compared with that of other neural network control structure known as the feedback error learning structure that compensates at the control input level.

Keywords : 3 degrees-of-freedom rotary robot, fuzzy logic controller, neural network controller, RCT, FEL

I. 서론

오늘날 'Intelligence'란 말은 정보 및 시스템, 특히 사이버네틱스 공학분야에서 가장 인기가 있고 중요하며 가치 있는 말이 되었다. 특히 로봇 분야에서는 '지능 시스템' 이 휴먼 로봇인 'ASIMO'의 출현이후, 다음세대 실행해야 할 로봇의 연구 과제가 되었다. 우리나라에서도 지능로봇을 국가 프로토콜 사업으로 추진하고 있는 실정이다.

지능 시스템의 연구분야로는 크게 퍼지 제어와 신경망제어가 있다. 퍼지 제어는 동적 시스템의 수적인 표현을 인간의 언어로 표현하는데 있어 매우 유용한 방법으로 알려져 있다[1-3]. 인간의 경험이나 전문기술 같은 통찰력인 언어적인 표현을 수적인 표현으로 바꿔줌으로써 동적 시스템을 제어 할 수 있다. 실제로 인간의 경험이나 직관력은 동적 시스템을 원하는 대로 제어하는데 있어 시스템 성능을 판단하는 주요인이 된다. 따라서, 퍼지 제어의 초보자는 잘못된 퍼지 규칙을 작성함으로써 조작자의 경험에 의지하는 퍼지 제어의 성능을 저하 시킬 수 있다. 이 점이 신경망 제어기와 비교하면 퍼지 제어기의 큰 단점이 될 수 있다.

본 논문에서는 퍼지 초보자도 사용할 수 있는 일반적인 PD 또는 PI 제어기를 사용한 퍼지제어기에 신경회로망을 사용하여 보상하는 제어시스템 방식을 제안 한다[3,4]. 일반적인 퍼지 제어기가 어떤 시스템에서는 잘 작동하지만, 대부분의 시스템의 경우 시스템 성능에 맞춰 보다 나은 결과를 얻기 위해서는 제어기의 규칙을 변형시키거나 새로 작성하는 것이 필요하다. 그러나 이러한 일은 쉽지 않아 실행하는데 많은 어려움이 있다. 또한 최적의 규칙을 작성하더라도 항상

좋은 성능을 보이는 것은 아니다. 시스템의 변수 값이 변하거나 외부의 외란 등에 의해 시스템의 성능이 저하되는 경우 등이 발생한다. 따라서 퍼지 규칙의 작성은 매우 어려운 일이다[3]. 이것은 퍼지 제어의 단점으로 작용한다.

이 문제를 해결하기 위해 퍼지 제어 시스템의 구조를 조직화하여 변수를 최적화하는 적응기법이 소개되었다. 시스템의 요소와 외란에 의해 적응할 수 있도록 조정된 퍼지 규칙이 제안되었다[5]. 소속 함수의 형태는 전체적인 오차가 최소가 되도록 소속 함수의 중앙값과 끝 값을 보상하도록 설계 되었다. 최근에는 퍼지 규칙을 작성하는 보다 지능적인 방법으로 퍼지 제어의 구조를 신경망의 구조로 완전히 개조하는 훌륭한 뉴로-퍼지 방법이 제안되었다[6]. 뉴로-퍼지 제어의 구조는 다층 신경망 구조를 모방한 형태의 퍼지 제어로 제안 되었다. 다층 신경망의 각 층은 퍼지 제어기의 퍼지화, 퍼지 추론, 비퍼지화 등으로 작용한다.

퍼지 제어 시스템의 성능을 향상하기 위한 다른 방법은 신경망을 이용한 오차의 보상이다[7-10]. 이미 알려진 신경망 보상기로는 FEL(feedback-error learning)방식이 있다[11]. 이 방식은 시스템의 제어입력 신호를 보상해 줌으로써 퍼지 제어기의 성능을 보상해주게 된다. 이는 퍼지 제어기에서 비퍼지화된 값을 보상해 준다. 일반적으로 출력의 비퍼지화 과정에서 어떤 상수값을 곱하는데 이 값을 정확하게 아는 것은 쉽지 않다. 따라서 비퍼지화 후에 곱해지는 상수값은 각 시스템마다 다르다.

이 논문은 로봇 제어를 위한 퍼지 제어를 신경망으로 보상하는 기법을 제안한다. 이미 제안한 논문의 연장으로[12,13], 신경망 제어기로 입력 오차를 수정하는 것이 퍼지 규칙을 수정하는 것과 같은 효과를 얻을 수 있음을 보인다. 제안된 신경망 퍼지 제어의 구조는 시스템의 비선형성을 보상할 수 있는 효과가 있다. 궁극적인 목표는 뉴로-퍼지 제어 구조 또는 퍼지 규칙을 수정하여 최소의 오차를 얻는 것과 같다.

* 책임저자(Corresponding Author)

논문접수 : 2004. 7. 14., 채택확정 : 2005. 1. 28.
송덕희, 정슬 : 충남대학교 메카트로닉스공학과
(hui314@yahoo.co.kr/jungs@cnu.ac.kr)

시뮬레이션을 통하여 제안된 방식을 3자유도 로터리 로봇의 위치 제어에 적용하여 검증하고자 한다. 또한 제안된 제어 구조 RCT(Reference compensation technique)와 FEL 구조를 서로 비교하여 그 성능을 검증한다.

II. 로봇 동력학

사용된 로봇의 모델은 그림 1과 같다. 3축으로 구성된 조인트 형태의 로봇으로 카테시안 공간에서의 움직임을 모두 표현할 수 있다.

일반적인 n축 로봇의 동력학 모델은 다음과 같다.

$$D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) + f_f(\dot{q}) = \tau \quad (1)$$

여기서, q 는 $n \times 1$ 벡터의 조인트, τ 는 $n \times 1$ 벡터의 토크, $D(q)$ 는 $n \times n$ 관성 행렬, $C(q, \dot{q})\dot{q}$ 은 $n \times 1$ 벡터의 Coriolis 힘과 원심력, $G(q)$ 는 $n \times 1$ 벡터의 중력, $f_f(\dot{q})$ 은 $n \times 1$ 벡터의 마찰력을 나타낸다.

로봇의 안정성을 보장하는 PD제어의 경우 제어 규칙은 다음과 같다.

$$\tau = K_p e + K_D \dot{e} \quad (2)$$

여기서 $e = q_d - q$ 이고 $\dot{e} = \dot{q}_d - \dot{q}$ 이다.

(1),(2)를 등식으로 놓고 양변에 $D(q)\ddot{q}_d$ 를 더한 후 정리하면 다음과 같은 페루프 오차 방정식을 얻을 수 있다.

$$\ddot{e} + D^{-1}K_D\dot{e} + D^{-1}K_p e = D^{-1}(D\ddot{q}_d + C + G + f_f) \quad (3)$$

(3)에서 보면 로봇의 자세에 따라 식이 변하게 되며, 대각 행렬의 K_p 와 K_D 의 개인 값은 크게 하면 각 조인트를 더욱 분리시켜 제어하는 효과가 커짐을 알 수 있다. 하지만 아무리 이득값을 크게 한다고 해도 (3)의 오른쪽 항의 불확실성을 없애지 않는 한 위치 오차는 영이 될 수 없다.

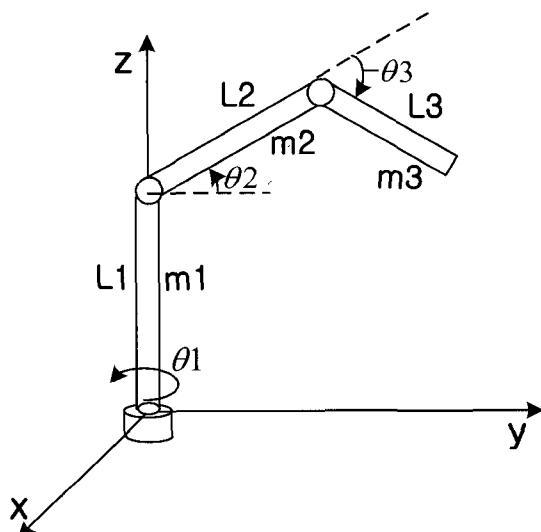


그림 1. 3자유도 로봇.

Fig. 1. 3 degrees-of-freedom robot manipulator.

III. PD 형태의 퍼지 제어

퍼지 제어기의 입력으로는 각도와 각속도가 사용되고 출력은 시스템의 입력 토크가 된다. 입력과 출력의 소속 함수는 그림 2와 같이 $[-1, 1]$ 구간으로 정규화 시킨 값을 사용한다.

퍼지 규칙은 위 소속 함수를 바탕으로 다음의 규칙에 의해 작성된다.

$$R: If \ e \ is \ A_i, \ \dot{e} \ is \ B_i, \ then \ \tau_i \ is \ C_i$$

위 규칙을 바탕으로 작성된 일반 PD형태의 규칙은 표 1과 같이 작성된다.

그림 3은 퍼지 제어의 블록 다이아그램을 보여주고 있다. PD제어 기반의 퍼지 제어의 제어 규칙은 다음과 같이 나타난다.

$$\tau = \tilde{K}_P e + \tilde{K}_D \dot{e} \quad (4)$$

여기서 \tilde{K}_P , \tilde{K}_D 는 퍼지 제어기에 의해서 결정되는 이득 값이다.

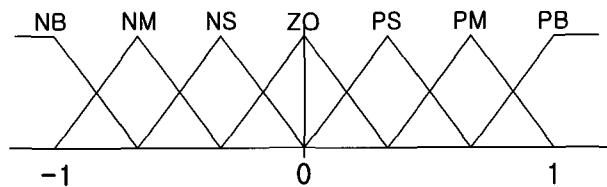


그림 2. 소속 함수.

Fig. 2. Membership functions.

표 1. 일반적인 PD형태의 제어규칙 테이블.

Table 1. Standard PD-like fuzzy rule table.

e	\dot{e}						
	NB	NM	NS	ZO	PS	PM	PB
NB	PB	PB	PM	PM	PM	PS	ZO
NM	PB	PM	PM	PM	PS	ZO	NS
NS	PM	PM	PM	PS	ZO	NS	NM
ZO	PM	PM	PS	ZO	NS	NM	NM
PS	PM	PS	ZO	NS	NM	NM	NM
PM	PS	ZO	NS	NM	NM	NM	NB
PB	ZO	NS	NM	NM	NM	NB	NB

ZO : Zero

PS(NS) : Positive(Negative) Small

PM(NM) : Positive(Negative) Medium

PB(NB) : Positive(Negative) Big

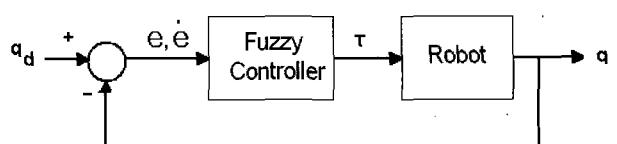


그림 3. 퍼지 제어 블록 다이아그램.

Fig. 3. PD like fuzzy controlled block diagram.

IV. 퍼지 제어시스템을 위한 신경망 보상기

1. FEL 방식의 신경망 보상기

FEL방식의 퍼지 제어구조는 그림 4와 같이 표현된다. 이 방식은 퍼지 제어기의 출력 값에 신경망의 출력 값을 더해줌으로써 시스템의 제어 입력 오차를 줄이는 방식이다[11].

FEL 기반의 신경회로망과 퍼지 제어 방식의 경우 목적 함수는 제어기의 오차로 구성 한다.

$$E = \frac{1}{2} \tau_c^T \tau_c \quad (5)$$

제어 입력 τ 는 퍼지 제어기의 출력 τ_c 와 신경망의 출력 τ_N 의 합으로 다음과 같이 나타난다.

$$\tau = \tau_c + \tau_N \quad (6)$$

따라서 역전파 알고리즘에 적용하기 위해 (6)은 $\tau_c = \tau - \tau_N$ 이 된다. 이를 사용하여 목적함수 E 를 기준치 w 로 편미분하면 다음과 같다[11].

$$\begin{aligned} \frac{\partial E}{\partial w} &= \frac{\partial E}{\partial \tau_c} \frac{\partial \tau_c}{\partial w} \\ &= \tau_c \frac{\partial(\tau - \tau_N)}{\partial \tau_N} \frac{\partial \tau_N}{\partial w} \\ &= -\tau_c \frac{\partial \tau_N}{\partial w} \end{aligned} \quad (7)$$

이 그래디언트를 역전파 알고리즘에 적용한다. 여기서 $\frac{\partial \tau_N}{\partial w}$

는 미분이 가능하므로 자코비안이 필요 없이 역전파 알고리즘에 적용할 수 있다. 하지만 이 경우에 비퍼지화 부분의 상수값에 보상하므로 퍼지 규칙을 바꾸어 사용하기 보다는 비퍼지화 부분에서 정량화된 값에 더해주어 보상하는 효과를 얻게 된다. 이는 오차를 줄이는데 있어서 상수값 만을 보상하는 제한적인 보상방식이 된다.

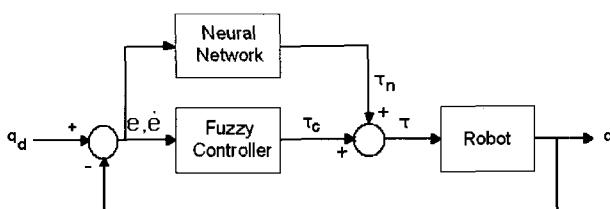


그림 4. FEL 기반의 신경회로망과 퍼지 제어방식.

Fig. 4. FEL based neural network and fuzzy control.

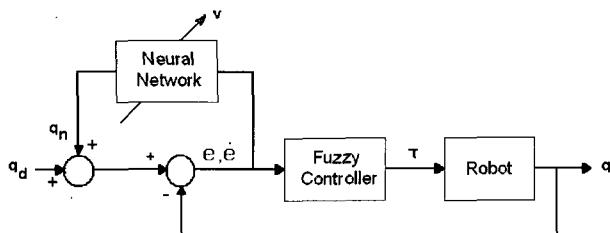


그림 5. RCT 기반의 신경회로망과 퍼지 제어방식.

Fig. 5. RCT based neural network and fuzzy control.

2. RCT 방식의 신경망 보상기

2.1 RCT 구조

RCT(Reference compensation technique)방식은 신경망 학습을 위한 또 다른 온라인 학습 알고리즘으로 알려져 있다[12-13]. 이 방식의 이점은 제어기의 내부를 수정하지 않고, 외부에서 신경망으로 오차를 보상해 줄 수 있다는 점이다. 그림 5는 RCT방식의 블록 다이아그램을 보여주고 있다.

이 방식의 요점은 신경망 보상기로 기준 입력 값을 수정해 줌으로써 퍼지 규칙을 수정하여 제어 입력을 보상한다는 데 있다. 이러한 신경망 제어기는 뉴로-퍼지 제어기의 이점과 그에 더하여 비선형 효과의 보상에도 사용할 수 있다.

2.2 퍼지 규칙의 보상

그렇다면 RCT 구조에서 시스템 변수가 바뀔 때 어떻게 퍼지 규칙이 바뀌는 효과를 얻게 되는지 살펴보자. 그림 6에는 간단한 예로 하나의 퍼지규칙을 나타낸다. 원래 퍼지 규칙과 시스템 변수의 변화에 따른 바뀐 퍼지 규칙이 있다. 일반적인 방법으로는 μ^* 가 최적의 소속 함수 값이라 할 때, 퍼지 규칙을 수정해 줌으로써 e_1 으로부터 그 값을 얻을 수 있다.

이 방법 외에도 퍼지 규칙의 수정 없이 똑 같은 결과를 얻을 수 있는데, 이 경우에 입력 오차의 값을 변화 시킴으로써 변화된 퍼지규칙의 결과를 얻게 된다. 우선 기준 규칙에 e_1 의 오차 값이 입력으로 들어오면 최적의 소속 함수 값과 오차가 발생하므로 이 e_1 값에 Δe 값을 더하여 e_2 를 만들어 줌으로써 원하는 소속 함수 값 μ^* 을 얻을 수 있다. 즉,

$$e_2 = e_1 + \Delta e \quad (8)$$

오차 \dot{e} 에 대해서도 마찬가지이다. 따라서 RCT구조에서는 이 오차 보상 값인 Δe 를 신경망을 통해 얻을 수 있다. 이 값을 보상해 줌으로써 퍼지 규칙을 바꾼 것과 같은 효과를 얻게 되는 것이다.

이 시스템에서의 오차 신호는 그림 5에 의해 다음과 같이 구성 된다.

$$e = q_d - q + q_N \quad (9)$$

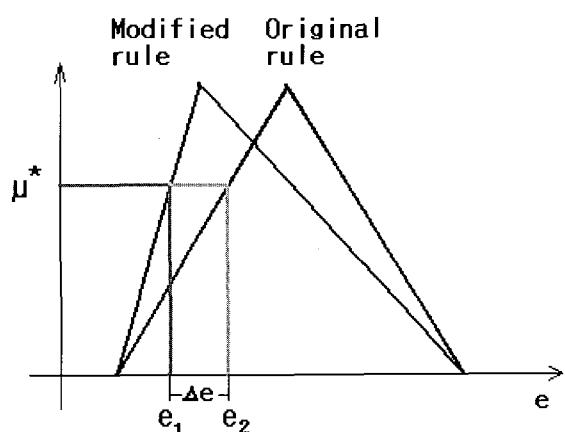


그림 6. 소속 함수의 수정.

Fig. 6. Modified membership function.

여기서 q_N 은 신경망의 출력 값이다. 만약 오차변수 $\varepsilon = q_d - q$ 로 정의하면 (9)는 다음과 같다.

$$e = \varepsilon + q_N \quad (10)$$

이는 (8)과 비교해 보았을 때 신경망의 보상 신호가 $e = e_2, \varepsilon = e_1$ 그리고 $q_N = \Delta e$ 로 되는 것을 알 수 있다. 따라서 RCT 방식에서는 그림6에서 보여진 것처럼 소속함수를 변화시키는 것을 알 수 있다.

퍼지 값은 e, \dot{e} 에 의해 결정되므로 퍼지 제어기의 출력 τ_c 는 다음과 같다.

$$\begin{aligned} \tau_c &\cong k_1 e + k_2 \dot{e} \\ &= k_1(q_d - q + q_N) + k_2(q_d - q + q_N) \\ &= k_1\varepsilon + k_2\dot{\varepsilon} + k_1q_N + k_2q_N \end{aligned} \quad (11)$$

여기서 k_1, k_2 는 퍼지 규칙에 의해 결정되는 퍼지 상수 값이다.

로봇의 동역학 토크를 τ 라 하면, (11)로부터 다음과 같은 식을 얻게 된다.

$$k_1\varepsilon + k_2\dot{\varepsilon} + k_1q_N + k_2q_N = \tau \quad (12)$$

여기서 좌향에 PD 제어 입력을 놓고 나머지를 우향으로 옮기면 다음과 같다.

$$v = k_1\varepsilon + k_2\dot{\varepsilon} = \tau - (k_1q_N + k_2q_N) \quad (13)$$

신경망의 학습 신호를 다음과 같이 PD 제어기의 값으로 정의 한다.

$$v = k_1\varepsilon + k_2\dot{\varepsilon} \quad (14)$$

결국 신경망의 목적 함수는 이 오차를 줄이는 것이므로

$$E = \frac{1}{2}v^T v \quad (15)$$

가 된다.

역전파 알고리즘을 구하기 위해서는 다음의 가중치의 그래디언트값을 구해야 한다.

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (16)$$

목적함수를 가중치로 편미분 하면 다음과 같다.

$$\begin{aligned} \frac{\partial E}{\partial w} &= \frac{\partial E}{\partial v} \frac{\partial v}{\partial w} \\ &= -v \left(k_1 \frac{\partial q_N}{\partial w} + k_2 \frac{\partial \dot{q}_N}{\partial w} \right) \end{aligned} \quad (17)$$

이 값을 역전파 알고리즘에 적용한다. 여기서 $\frac{\partial q_N}{\partial w}, \frac{\partial \dot{q}_N}{\partial w}$

는 각각 편미분이 가능하므로 자코비안이 필요 없이 역전파 알고리즘에 적용할 수 있다.

RCT방식의 구조는 신경망의 출력개수에 의해 결정되는데

q_N 또는 q_N, q_N 을 모두 사용하는 하는 구조로 나눌 수 있다.

V. 시뮬레이션 결과

1. 시뮬레이션 환경

이 시뮬레이션은 그림 7과 같이 로봇이 xy평면상에서 z축으로 약 14도 기울어진 원을 그리는 것이다. 로봇의 각 변수는 다음과 같이 $m_1 = 15kg, L_1 = 0.7m, m_2 = 10kg, L_2 = 0.6m, m_3 = 5kg, L_3 = 0.5m$ 이다.

시뮬레이션은 PD제어, 퍼지제어, FEL방식, RCT 방식1(보상) 및 RCT 방식2(q, \dot{q} 보상)의 5가지의 경우에 대해 실험 하였다. 그리고 샘플링 시간은 0.01s로 하였으며, 로봇의 초기 위치는 (0m, 0.8m, 0.7m)로 하였다. 그리고 로봇의 최대 토크는 $-250 < link1 \leq +250, -200 < link2 \leq +200, -150 < link3 \leq +150$ 로 각각 제한하였다. 이때 각각의 경우에 대한 시뮬레이션 결과는 다음과 같다.

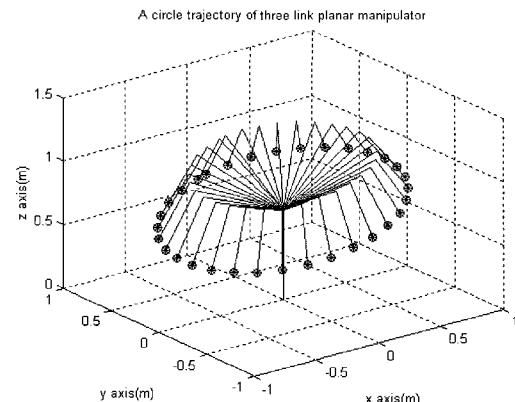


그림 7. 로봇의 원경로.

Fig. 7. The desired robot trajectory.

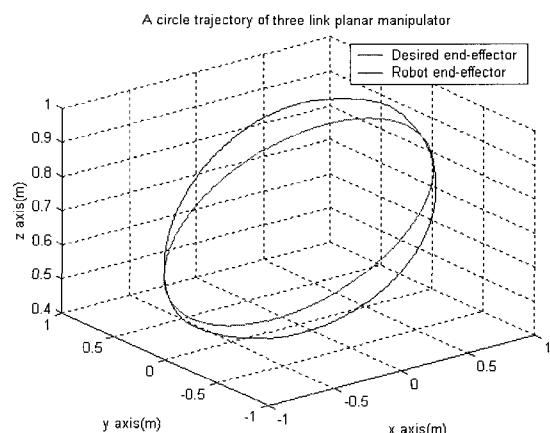


그림 8. PD제어 결과.

Fig. 8. Tracking performance of PD control.

2. 시뮬레이션 결과

2.1 실험 1 : PD 제어기

실험 1에서는 PD 제어기만을 사용한 경우로 그림 8은 로봇 팔 끝의 원 경로를 나타낸다. 이때 P 이득값과 D 이득값은 각각 $K_P = 500$, $K_D = 50$ 으로 설정 하여 상대적으로 큰 값을 설정하였다.

실험 1의 결과를 보면 PD 제어기만을 사용하였을 경우 오차가 크게 나타나는 것을 확인 할 수 있다. 이는 시스템이 비선형이므로 PD제어만으로는 제어가 어렵다는 것을 알 수 있다.

2.2 실험 2 : PD 형태의 퍼지 제어기

실험 2 에서는 퍼지 제어기만을 사용한 경우로 그림 9는 로봇 팔 끝의 원 경로를 보여주고 있다. 퍼지 제어에서 출력 scaling factor값은 링크 1에서부터 링크 3까지 각각 200, 150, 100의 크기로 하였다.

퍼지 제어기만을 사용한 경우에는 PD제어기를 사용한 경우보다 오차가 크게 줄어든 것을 볼 수 있다. 그러나 이 경우에도 오차가 만족할 만큼 줄어들지 않는 것을 알 수 있다.

2.3 실험 3 : FEL 방식의 퍼지 제어기

앞의 퍼지제어에서 나타난 오차를 보상하기위해 실험 3의 경우는 퍼지 제어기에 신경망 제어기를 FEL 방식으로 사용하며, 신경망을 제외한 나머지 부분은 실험 2의 경우와 같은 조건을 사용하였다. 신경망의 학습 율은 0.3으로 하였으며, 모멘텀 상수는 0.9로 하였다. 그리고 신경망의 출력 값은 각각 링크1에서 링크3까지 50, 40, 30의 값을 곱하였다.

그림 10은 로봇팔 끝의 원 경로 추종 결과를 나타낸다. 실험 3에서는 실험 2에 비해 오차가 크게 줄어든 것을 확인 할 수 있다.

2.4 실험 4 : RCT 방식(q 보상)의 퍼지 제어기(1)

이 실험은 퍼지 제어기에 신경망 제어기를 RCT 방식으로 사용한 경우로, 이 때 신경망의 출력은 q_N 이며, 역시 신경망을 제외한 나머지 조건은 실험 2와 동일하다. 신경망의 학습율은 0.1이며, 모멘텀 상수는 0.1로 하였다. 그리고 신경망의 출력 값은 각각의 링크를 1/20축소 시켜서 사용하였으며, 관절 i 의 학습 신호 $v_i = 10 * e_i$ 로 하였다.

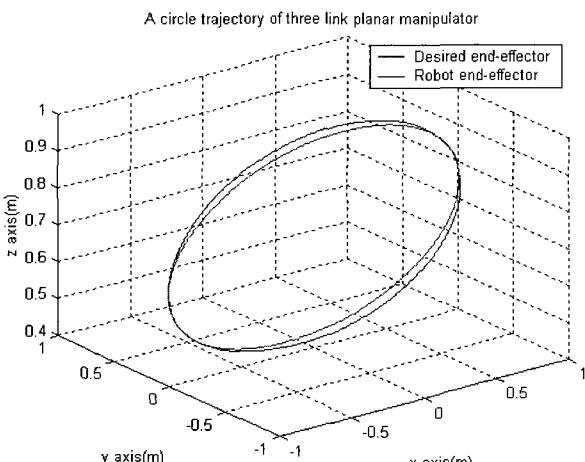


그림 9. 퍼지 제어 결과.

Fig. 9. Tracking performance of PD like fuzzy control.

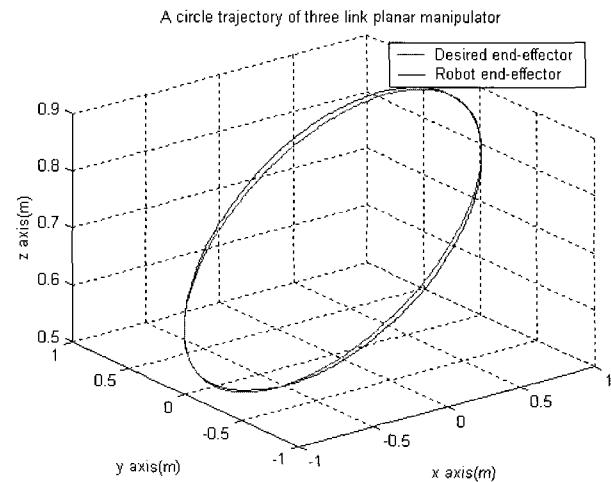


그림 10. FEL방식의 신경망 퍼지 제어 결과.

Fig. 10. Performance of fuzzy FEL scheme.

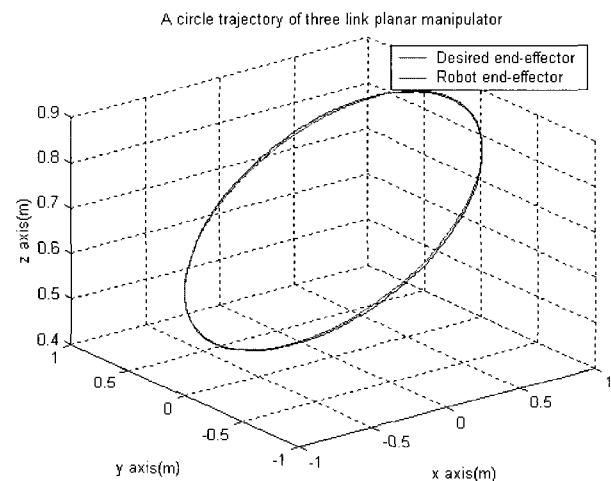


그림 11. RCT 방식(1)의 신경망 퍼지 제어 결과.

Fig. 11. Performance of fuzzy RCT scheme 1.

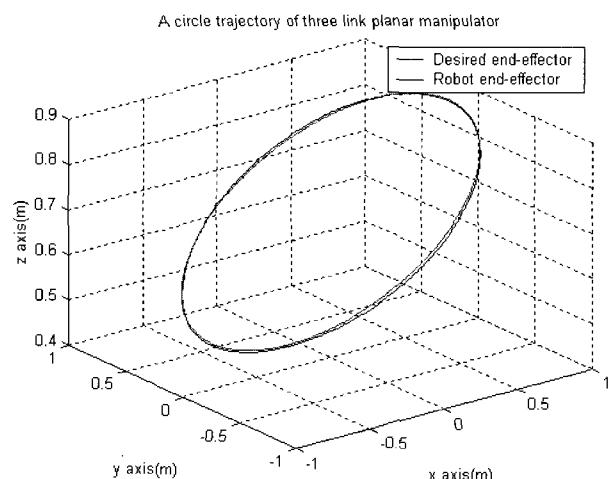


그림 12. RCT 방식(2)의 신경망 퍼지 제어 결과.

Fig. 12. Performance of fuzzy RCT scheme 2.

표 2. 각 제어기의 MSE.

Table 2. MSE for circular tracking.

	PD Control	Fuzzy Control	Fuzzy-Neuro Control (FEL)
MSE	66.6655	29.2223	20.6801
	Fuzzy-Neuro Control (RCT1)	Fuzzy-Neuro Control (RCT2)	
MSE	9.1148	9.3643	

실험 4의 경우 이전의 결과와 비교하여 오차가 크게 줄어든 것을 볼 수 있다.

2.5 실험 5 : RCT 방식($\theta, \dot{\theta}$ 보상)의 퍼지 제어기(2)

실험 5는 실험 4와 동일한 방식이며, 단지 신경망의 출력이 $q_N, q_{\bar{N}}$ 으로 2개를 사용하는 방식이다. 즉 실험 4는 제어 대상의 위치 또는 각도만을 보상해주는 방식이며, 실험 5는 각도와 속도를 모두 보상해 주는 방식이다. 신경망의 학습율은 0.01이고, 모멘텀 상수는 0.1을 사용하였다. 그리고 신경망의 출력 값은 각 링크의 각도에 *1/20, 각속도에 *1/50을 곱하여 축소된 값을 사용하였다. 또한 관절 i 의 학습 신호로는 $v_i = 20 * e_i + 0.1 * \dot{e}_i$ 을 사용하였다.

실험 5의 경우에도 실험 4와 비슷한 결과를 얻음으로써 로봇이 원하는 경로를 잘 추종하는 것을 확인 할 수 있다.

이상의 결과로부터 각각의 MSE(Mean Squared Error)를 구하면 다음의 결과를 얻을 수 있다.

위 결과를 보면 FEL 및 RCT방식이 퍼지 제어기에 비해 MSE가 줄어드는 것을 알 수 있다.

위 결과를 종합해 보면, 퍼지 제어기에 신경망을 첨가한 경우 시스템의 성능이 향상되는 것을 확인 할 수 있었다. 그 성능을 비교해 보면, FEL방식보다 RCT방식의 성능이 더욱 좋다는 것을 알 수 있다.

IV. 결론

본 논문에서는 로봇 시스템의 퍼지 제어에서 오차 보상을 위한 새로운 방법을 제안하였다. 퍼지 제어기의 초보자가 시스템에 대해 알지 못하는 경우에도 원하는 목적을 이를 수 있는 보상방식을 제안하였다. 일반적인 PD형태의 퍼지 제어기를 사용하고 시스템의 변화에 따른 퍼지 규칙의 변화의 효과를 위해 보조 제어기로서 신경망을 이용하였다. 이 방법에는 FEL과 RCT의 두 가지 방법이 있으며, FEL의 경우에는 비퍼지화 후의 제어 입력값을 보상하여 오차를 줄게 되고,

RCT의 경우에는 기존의 퍼지 규칙을 변경하는 효과를 얻게 됨으로써 오차를 줄인다는 것을 알았다. 3축 로봇을 통해 실험한 결과, 두 경우 모두 퍼지 제어기만을 사용한 것보다는 보다 나은 결과를 얻었고 RCT방식이 FEL보다 좀더 나은 결과를 얻었다.

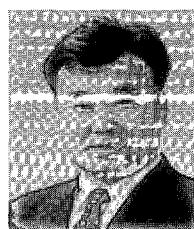
참고문헌

- [1] T. H. Lee and S. S. Ge, "Intelligent control of mechatronic systems", pp. 646-659, *IEEE Symposium on Intelligent Control*, 2003.
- [2] M. E. Magana and F. Holzapfel, "Fuzzy-logic control of an inverted pendulum with vision feedback", pp. 165-170, *IEEE Trans. on Education*, vol. 41, no. 2, May 1998.
- [3] D. Driankov, H. Hellendoorn, and M. Reinfrank, "An introduction to fuzzy control", *Springer*; 1996.
- [4] T. H. Hung, M. F. Yeh, and H. C. Lu, "A PI-like fuzzy controller implementation for the inverted pendulum system", pp. 218-222, *IEEE Conference on Intelligent Processing Systems*, 1997.
- [5] L. X. Wang, "Adaptive fuzzy systems and control", *Prentice Hall*, 1994.
- [6] J. S. Wang and C. S. Lee, "Self-adaptive recurrent neuro-fuzzy control of an autonomous underwater vehicle", pp. 283-295, *IEEE Trans. on Robotics and Automations*, vol. 19, no. 2, 2003.
- [7] L. Peng and P. Y. Woo, "Neural-fuzzy control system for robotic manipulators", *IEEE Control Systems Magazine*, pp. 53-63, vol. 22, no. 1, Feb. 2002.
- [8] W. Wei, S. Zeng, and X. Gan, "Fuzzy and neural network control system of intelligent RLED arm manipulators for dynamic obstacles", pp. 577-580, *IEEE Conference on Fuzzy systems*, 2001.
- [9] S. Pletl, "Neuro-fuzzy control of rigid and flexible joint robotic manipulator", *IEEE IECON*, pp. 93-97, 1995.
- [10] A. J. P. H. Yang, D. M. Auslander, and R. N. Dave, "Real time neuro-fuzzy control of a nonlinear dynamic system", *Biennial Conf. of North American Fuzzy Information Processing*, pp. 210-214, 1996.
- [11] M. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback error learning", *IEEE Trans. on Neural Networks*, vol. 1, pp. 251-265, 1988.
- [12] S. Jung and T. C. Hsia, "Neural network inverse control techniques for PD controlled robot manipulator", pp. 305-314, vol. 19, no. 3, *ROBOTICA*, 2002.
- [13] S. Jung and H. T. Cho, "Decentralized neural network reference compensation technique for PD controlled two degrees of freedom inverted pendulum," *International Journal of Control, Automations, and Systems*, vol. 2, no. 1, pp. 92-99, 2004.



송덕희

2002년 2월 충남대학교 메카트로닉스 공학과 졸업. 2003년 3월 충남대학교 메카트로닉스 공학과 대학원 입학. 관심 분야는 퍼지제어 및 신경망 제어, 로봇 공학.



정 슬

1964년 9월 11일생. 1988년 미국 웨인 주립대 전기 및 컴퓨터 공학과 졸업. 1991년 미국 캘리포니아대 테이비스 전기 및 컴퓨터 공학과 석사. 동 대학 박사. 1997년~현재 충남대학교 메카트로닉스공학과 부교수. 관심분야는 지능 제어 및 지능 로봇 시스템, 로봇과 인간, 무인 로봇의 위치 추정 및 제어.