

신경회로망을 이용한 학습퍼지논리제어기

◦ 김 병섭 류 근배 민 성식 이 규찬 김 창업 조 규복

효성중공업(주) 기술연구소

A Learning Fuzzy Logic Controller Using Neural Networks

◦ B.S.Kim, K.B.Ryu, S.S.Min, K.C.Lee, C.E.Kim and K.B.Cho

R & D Institute, Hyosung Industries Co., Ltd.

ABSTRACT

In this paper, a new learning fuzzy logic controller(LFLC) is presented. The proposed controller is composed of the main control part and the learning part. The main control part is a fuzzy logic controller(FLC) based on linguistic rules and fuzzy inference. For the learning part, artificial neural network(ANN) is added to FLC so that the controller may adapt to unknown plant and environment. According to the output values of the ANN part, which is learned using error back-propagation algorithm, scale factors of the FLC part are determined. These scale factors transfer the range of values of input variables into corresponding universe of discourse in the FLC part in order to achieve good performance. The effectiveness of the proposed control strategy has been demonstrated through simulations involving the control of an unknown robot manipulator with load disturbance.

1. 서론

퍼지집합이론(Fuzzy Set Theory)이 인간의 사고나 그 표현언어의 모호성 처리에 대한 이론적 바탕을 제공하면서 이 이론을 여러 분야에 응용하고자 하는 시도가 활발히 이루어지고 있다. 자동제어에 인간의 지능 또는 사고방식을 도입하려는 의도로 연구되고 있는 퍼지논리제어(Fuzzy Logic Control)는 기존의 제어알고리즘에서는 필수적인 수학적 모델이 잘 정의되지 않는 공정에 대해서 매우 효과적인 방법이다.

퍼지논리제어기(Fuzzy Logic Controller; FLC)를 설계할 때에는 제어하고자 하는 플랜트에 대한 전문가의 지식을 기반으로 하여 주관적으로 설계하지만, 제어대상에 대한 정보가 충분치 않을 경우 임의의 설계로는 좋은 성능을 기대하기 어렵다는 단점이 있다.

한편, 널리 알려진 바와 같이 신경회로망(Artificial Neural Network; ANN)은 성능을 향상시키기 위한 방향으로 연결가중치(weight)들을 변화시키는 적응성 및 학습기능을 갖고 있다. 따라서, 신경회로망의 학습능력과 퍼지논리제어기의 언어적 추론능력을 서로 상호 보완적으로 합성(combination) 혹은 융합(fusion)하여 인간의 사고 능력에 가까운 지능제어기

를 구현하고자 하는 시도가 이루어지고 있다. 두 이론의 합성은 적응력과 학습 능력을 갖는 퍼지논리제어기를 구성하기 위하여 기존의 신경회로망과 퍼지논리제어기를 하이브리드(hybrid) 형태로 합성하는 방식이라 할 수 있고 융합은 두 이론의 유사한 특성들을 이용해 새로운 fuzzy-neuron model을 얻어 지능제어기를 구성하는 방식이라 할 수 있다. 합성과 융합에 관한 연구방향은 퍼지논리에 신경망의 학습능력을 부여하는 방향과 신경망의 학습에 퍼지논리를 부여하는 방향으로 크게 나눌 수 있다[1][2][3].

이에 본 논문에서는 신경회로망을 이용하여 퍼지논리제어기에 미지의 플랜트 및 주위환경의 변화에 적응할 수 있도록 하는 새로운 학습퍼지논리제어기(Learning Fuzzy Logic Controller)의 구조 및 알고리즘을 제안한다. FLC는 언어적인 표현을 이용하여 여러가지 기존의 제어기에 비해 많은 장점을 가지고 있으나 입력변수의 범위를 모르는 경우, 좋은 성능을 얻기위한 설계가 어려운 결점으로 남는다. 따라서, 본 논문에서는 기존의 FLC의 입력변수범위를 설정된 universe of discourse 내로 적절히 mapping 시키는 scale factor를 온라인(on line)으로 찾기위해, 신경회로망의 학습 능력을 이용한 새로운 알고리즘을 제안하였다. 제안된 학습퍼지논리제어기는 주된 제어기능을 담당하는 FLC(주제어부)와, 주어진 환경에 대해 적응학습하는 ANN(학습부)로 구성되어, 그 구성이 간단하다.

제안된 학습퍼지제어기의 유용성을 보이기 위해 2자유도를 갖는 로봇 매니퓰레이터에 대한 적용시켜, 시뮬레이션 결과를 통해 좋은 출력특성과 외란에 대한 강인성을 입증한다.

2. 퍼지논리제어기(주제어부)

본 논문에서 제안하는 제어기의 주제어부(main control part)는 기존의 퍼지논리제어기(Fuzzy Logic Controller; FLC)를 사용한다. FLC의 일반적인 구조를 그림 1에 나타내었다.

FLC의 설계에 있어서 중요한 설계요소가 되는 것은

- 1) 퍼지화(fuzzification) 방법
- 2) 지식베이스(knowledge base)의 구성
- 3) 퍼지추론(fuzzy inference) 방법
- 4) 비퍼지화(defuzzification) 방법

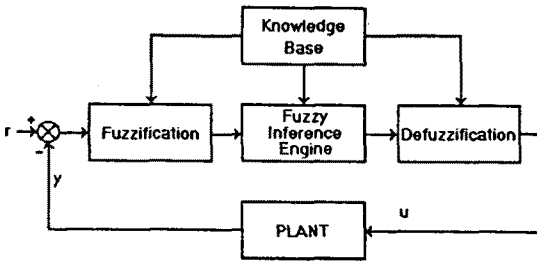


그림 1. 퍼지 논리 제어기의 기본구성
Fig. 1. Basic Configuration of FLC

동이다[4].

본 논문에서는 퍼지싱글톤(fuzzy singleton)법으로 퍼지화를 행한다. 이 방법은 crisp 한 입력을 입력 universe of discourse 내의 퍼지싱글톤으로 간주하는 것으로, 구현하기 쉽다는 장점때문에 퍼지제어의 응용에서 가장 널리 사용되는 방법이다. 이 때 입력변수의 값이 사전에 설정한 universe of discourse 내의 범위로 알맞게 변환되도록 scale factor 를 채용, scale mapping 하는 과정이 필요하다.

지식베이스는 데이터베이스(data base)와 규칙베이스(rule base)로 구성된다. 데이터베이스는 제어과정에 필요한 각종 설계요소들을 사전에 정의·설계하여 구성한다. 본 논문에서는 입력변수로서 오차와 오차의 시간변화율을 사용하며, 다음과 같이 정의한다.

$$e(k) = r(k) - y(k), \Delta e(k) = e(k) - e(k-1) \quad (1)$$

여기서, $r(k)$ 는 k 번째 샘플링에서의 기준입력(reference input), $y(k)$ 는 k 번째 샘플링에서의 플랜트 출력이며, $e(k)$ 는 오차, $\Delta e(k)$ 는 오차변화율이다. 만일, 플랜트의 속도출력이 센싱되는 경우에는 오차변화율대신 $\dot{e}(k) = \dot{r}(k) - \dot{y}(k)$ 이 입력변수로 사용될 수 있다.

측정계산된 이들 입력변수들은 퍼지화과정에서 scale mapping 되어 언어적 변수(linguistic variable) E 와 DE 로 변환되며, 이들 언어적 변수를 이용하여 다음과 같은 IF-THEN 형태의 제어규칙이 구성된다.

$$R_1 : \text{if error}(E) \text{ is } A_1 \text{ and change in error}(DE) \text{ is } B_1, \text{ then output of controller}(U) \text{ is } C_1. \quad (2)$$

여기서, A_1, B_1, C_1 는 언어적 값(Linguistic Value)을 말하며, 다음과 같은 용어집합(Term Set)으로 정의된다.

$$\{ NB, NM, NS, ZO, PS, PM, PB \} \quad (3)$$

여기서, N은 negative, P 는 positive, S 는 small, M 은 medium, B 는 big 을 의미한다. 이들 언어적 값들은 universe of discourse 위에서 퍼지집합(fuzzy sets)을 이루게 되며, 본 논문에서는 그림 2 와 같이 -6 과 6사이의 연속적인 universe of discourse 내로 소속함수(membership function)를 할당하였다.




그림 2. 소속함수
Fig. 2. Membership Functions

규칙베이스는 플랜트에 대한 전문가의 지식과 경험을 바탕으로 언어적인 제어규칙을 설계하여 구성한다. 본 논문에서 제어기의 범용성을 고려하여 설계한 퍼지규칙은 표 1 과 같다.

표 1. 퍼지규칙
Table 1. Fuzzy Rules
Change in Error

	NB	NM	NS	ZO	PS	PM	PB
NB	NB	NB	NM	NM	NS	NS	ZO
NM	NB	NM	NM	NS	NS	ZO	PS
NS	NM	NM	NS	NS	ZO	PS	PS
ZO	NM	NS	NS	ZO	PS	PS	PM
PS	NS	NS	ZO	PS	PS	PM	PM
PM	NS	ZO	PS	PS	PM	PM	PB
PB	ZO	PS	PS	PM	PM	PB	PB

퍼지추론은 Mamdani의 최소연산법(Minimum Operation Rule)을 응용하며, crisp 한 제어기출력을 얻기위한 비퍼지화 방법으로 면적중심법(Center of Area; COA)을 사용한다[5].

$$\begin{aligned} W_{11} &= \min(\mu_{NB}(e), \mu_{NB}(\dot{e})) \\ W_{12} &= \min(\mu_{NB}(e), \mu_{NM}(\dot{e})) \\ &\vdots \\ W_{77} &= \min(\mu_{PB}(e), \mu_{PB}(\dot{e})) \end{aligned} \quad (4)$$

$$u = \frac{\sum_{i=1}^7 \sum_{j=1}^7 CG_{ij} W_{ij}}{\sum_{i=1}^7 \sum_{j=1}^7 W_{ij}} \quad (5)$$

(5)식은 면적중심법의 수정된 형태[6]로 계산시간이 절약되는 잇점이 있어 제어응용에서 널리 사용되고 있다. 여기서, CG_{ij} 는 ij 번째 규칙에서 출력 언어적 값의 중심값이다.

비퍼지화된 값은 다시 출력 scale factor 에 의해 적절한 범위이내로 mapping 된 후 플랜트에 가해진다. 따라서, 입력변수와 출력변수의 관계는 다음식으로 표현할 수 있다.

$$K_3[u(k)] = F [K_1 \cdot e(k), K_2 \cdot \dot{e}(k)] \quad (6)$$

여기서, F 는 퍼지규칙과 추론을 나타내며, K_1, K_2 는 입력 scale factor, K_3 는 출력 scale factor 이다.

3. 신경회로망을 이용한 학습부

일반적으로, 퍼지논리제어에서 플랜트에 대한 정보가 부족하거나 미지인 경우, 적절한 입출력 범위를 알 수 없으므로 입출력 scale factor의 선정은 쉽지 않은 일이며, 임의의 값으로 선정할 때 좋은 성능을 기대하기 어렵다. 그러므로, 미지의 플랜트 및 주위환경의 변화에 따라, scale factor 를 자동으로 tuning 하며 적응할 수 있는 기능이 요구된다. 본 논문에서는 신경회로망(Artificial Neural Network; ANN)의 학습기능을 이용하는 학습부(learning part)를 주제어부에 추가함으로써, 학습퍼지논리제어기(Learning Fuzzy Logic Controller; LFLC)를 구성하고, 적응능력을 최대화하는 새로운 알고리즘을 제안한다. 제안된 LFLC 의 구조는 그림 3 과 같다.

그림에서 볼 수 있는 바와 같이 제안된 LFLC 는 FLC 가 주제어부가 되며 신경회로망이 FLC 의 입력 scale factor(SF)를 학습하는 구조를 가진다. FLC 의 출력이 미지플랜트의 입력으로 인가되고 그 플랜트의 출력은 주기적으로 센싱되어 피드백된다. 이 출력을 기준입력과 비교하여 그 오차값이 FLC 의 입력변수가 되며, 이 오차값과 한 샘플링 이전의 SF 값을 이용하여 신경회로망의 학습신호를 전처리 단계(preprocedure)에서 계산한다. 신경회로망은 오차값과 그 시간 변화율에 따른 적절한 입력 SF값을 출력하기 위해 온라인(on line)으로 학습한다.

신경회로망 모델은 제어분야에서 많이 이용되고 있는 다층퍼셉트론(multilayer perceptron)을 사용하며, 학습알고리즘으로 오차역전달 알고리즘(Error Backpropagation Algorithm; EBPA)을 응용한다[7]. 학습알고리즘의 입력으로 오차값과 오차의 시간변화율(또는 속도오차)이 인가된다. EBPA 는 입력들과 출력 그리고 학습에 필요한 학습신호(learning signal)가 필요하다. 학습신호는 주로 학습하고자 하는 목표치(target)와 실제 신경망회로의 출력의 차가 되는데 위의 문제에서는 SF 값의 목표치를 알 수 없으므로 학습신호를 발생시키기 위한 알고리즘이 필요하다. 이에 관한 기본 아이디어는 FLC의 입력으로 들어가는 오차정보와 SF의 곱이 주어진 universe of discourse(UD)내의 값을 가지면 FLC 에 대한 적절한 입력이 구성되고, 퍼지추론을 거쳐 알맞은 제어기출력이 발생할 것이라는 점이다. 결국 신경회로망의 학습신호를 구하기 위해 위의 정보를 가지고 전처리 과정을 거쳐야 한다.

전처리 알고리즘의 기본개념은 다음과 같다.

- 1) 만약 오차와 SF의 곱이 UD 범위보다 클 경우 UD 범위 내로 들어오게 하기 위해서는 SF 값이 작아져야 한다. 그러므로 신경회로망의 학습 신호로 (-)값을 인가해야 한다.
- 2) 오차와 SF의 곱이 UD 범위보다 약간 작을 경우 원하는 UD 범위이므로 SF 값은 변하지 말아야 한다. 그러므로 신경회로망의 학습 신호를 ZERO(0) 값을 인가해야 한다.
- 3) 오차와 SF의 곱이 UD 범위보다 너무 작을 경우 UD 적당한 범위 내로 들어오게 하기 위해서는 SF 값이 커져야 한다. 그러므로 신경회로망의 학습 신호를 (+)값을 인가해야 한다.

오차가 계속 작아질 경우 신경회로망은 학습을 하게 되고

SF 는 계속 증가하게 될 것이다. 그렇게 될 경우 FLC 에 의해 작은 오차 입력의 경우에도 큰 출력이 나올 수 있으므로 진동이 생길 수가 있다. 이를 방지하기 위해서 원하는 오차값을 미리 전처리 단계에서 제공함으로써 주어진 오차값에 도달할 때까지만 학습을 하고 원하는 오차범위를 유지할 수 있도록 하였다. 즉, 먼저 오차를 원하는 오차 범위에 있는가를 확인한 후 범위에 있으면 학습알고리즘을 동작시키고 범위내에 있으면 신경회로망의 학습신호를 ZERO로 하고 전처리 단계를 끝내는 것이다. 이를 수식으로 표시하면 Box 1 과 같다.

Box 1. 전처리 과정(Preprocedure)

```
If(|error*SF| > UD) then NNerror = - value,
else if(|error*SF| < UD) then NNerror = 0,
else if(|error*SF| << UD) then NNerror = + value.
```

error : 오차정보

UD : universe of discourse 최대범위

NNerror: 신경회로망의 학습신호

전처리기(preprocessor)로부터 학습신호를 받은 신경회로망은 이 오차를 출력측에서부터 입력쪽으로 역전달(backpropagate)하면서 가중치(weights)들을 변화시킨다. 출력층의 가중치들과 은닉층(hidden layer)의 가중치 변화를 위해 제안한 알고리즘은 Box 2 와 같다.

Box 2. 오차역전달 알고리즘(EBPA)

$$\Delta W_{p,q,k}(n+1) = \eta \cdot \delta_{q,k} \cdot \text{OUT}_{p,j} + \alpha \cdot \Delta W_{p,q,k}(n)$$

$$W_{p,q,k}(n+1) = W_{p,q,k}(n) + \Delta W_{p,q,k}(n+1)$$

$$\delta_{q,k} = \text{NNerror}_{q,k} \cdot f'(\text{NET}_{q,k})$$

은닉층의 경우

$$\delta_{p,j} = \left(\sum_q \delta_{q,k} W_{p,q,k} \right) f'(\text{NET}_{p,j})$$

α : Momentum 상수

η : 학습율(learning rate)

$W_{p,q,k}(n)$: 은닉층의 뉴런 p로부터 출력층의 뉴런 q를 연결해 주는 가중치값 (첨자 k는 이 가중치의 목표가 되는 층을 나타냄)

$W_{p,q,k}(n+1)$: step n+1(조정후)에서의 가중치값

$f'(\cdot)$: 활성화함수(Activation Function)의 미분

$\delta_{q,k}$: 출력층의 뉴런 q에 해당하는 δ 값

$\text{OUT}_{p,j}$: 은닉층의 뉴런 p에 해당하는 OUT값

$\text{NET}_{q,k}$: 출력층의 뉴런 q에 해당하는 NET값

가중치를 나타내기 위한 첨자 중에서 p,q는 해당층의 특정 뉴런이고 j,k는 층을 표현한다.

결국, 신경회로망은 오차신호를 학습하여 오차신호에 따른 적절한 SF 값을 출력하게 된다. 오차신호가 클 경우 신경회로망의 출력뉴런은 작은 값을 출력하고 오차신호가 작을 경우에는 큰 값을 출력하게 된다. 학습이 이루어 질수록 오차에 대한 SF의 특정 값으로 수렴을 하게된다.

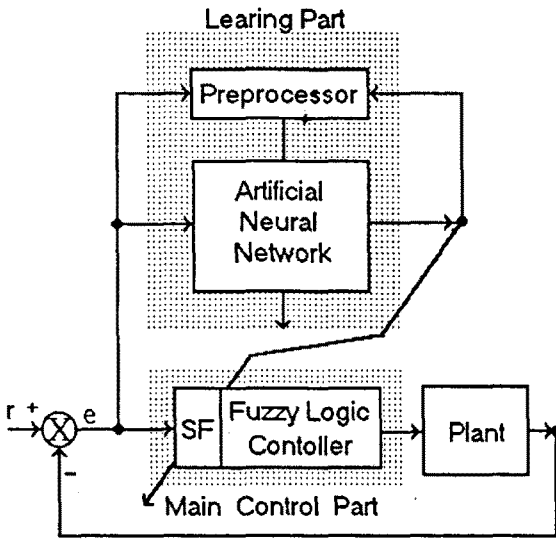


그림 3. 제안된 학습퍼지논리제어기
Fig. 3. Proposed Learning FLC (LFLC)

4. 시뮬레이션

로봇 시스템(robot system)은 비선형(nonlinear)이며 highly coupled 하여 제어가 어려운 시스템 중에 하나이다. 본 논문에서 제안된 LFLC의 효용성을 증명하기 위해 2 자유도(2 degrees of freedom)를 갖는 로봇 매니퓰레이터(robot manipulator)를 대상으로 컴퓨터 시뮬레이션하였다.

2 링크 로봇 매니퓰레이터의 운동방정식은 다음과 같은 2차 미분방정식으로 표현된다[8].

$$\tau = D(q)\ddot{q} + C(q, \dot{q}) + h(q) \quad (7)$$

여기서,

$$\tau = \begin{bmatrix} \tau_1 & \tau_2 \end{bmatrix}^T, \quad q = \begin{bmatrix} q_1 & q_2 \end{bmatrix}^T$$

$$D(q) = \begin{bmatrix} (\frac{1}{2}m_1+m_2)l_1^2+m_2l_1l_2C_2+\frac{1}{2}m_2l_2^2 & \frac{1}{2}m_2l_1l_2C_2+\frac{1}{2}m_2l_2^2 \\ \frac{1}{2}m_2l_1l_2C_2+\frac{1}{2}m_2l_2^2 & \frac{1}{2}m_2l_2^2 \end{bmatrix}$$

$$C(q, \dot{q}) = \begin{bmatrix} -m_2l_1l_2S_2(\dot{q}_1\dot{q}_2 + \frac{1}{2}\dot{q}_2^2) \\ \frac{1}{2}m_2l_1l_2S_2\dot{q}_1^2 \end{bmatrix}$$

$$h(q) = \begin{bmatrix} (\frac{1}{2}m_1+m_2)g l_1 C_1 + \frac{1}{2}m_2 g l_2 C_2 \\ \frac{1}{2}m_2 g l_2 C_2 \end{bmatrix}$$

이다. C_1 은 $\cos(q_1)$, C_2 는 $\cos(q_2)$, C_{12} 는 $\cos(q_1+q_2)$ 이며, S_2 는 $\sin(q_2)$ 를 의미한다. m_1 과 l_1 ($i = 1, 2$) 는 i 번째 링크의 질량과 길이이며, 본 시뮬레이션에서는 $m_1 = 5[\text{Kg}]$, $m_2 = 3[\text{Kg}]$, $l_1 = l_2 = 1[\text{m}]$ 로 선정하였다. 이러한 운동방정식과 설정 파라미터들은 미지의 것으로 가정한다.

Cartesian 공간에서 매니퓰레이터의 end-effector가 추종(tracking)해야할 기준궤적(desired trajectory)은 다음과 같이 중심좌표 $(1 \text{ m}, 1 \text{ m})$, 반지름 $1[\text{m}]$ 의 원궤적을 설정하였다.

$$x_d = 1 + 0.5 \cos(-2\pi t / T)$$

$$y_d = 1 + 0.5 \sin(-2\pi t / T) \quad (8)$$

여기서, T 는 원궤적을 그리는 회전주기로 5 sec로 설정하였고, 1 msec의 주기로 샘플링하여 set point를 발생시킨다.

기준속도(desired velocity)는 위의 기준궤적을 시간에 대해 미분하여 간단히 설정하였으며, end effector의 초기위치는 $(1.5 \text{ m}, 1 \text{ m})$ 이다.

Cartesian 공간에서의 기준위치와 기준속도에 역기구학(inverse kinematics)과 자코비안행렬(Jacobian Matrix)[8]을 적용하여 좌표변환하면, 관절공간(joint space)에서의 기준궤적 q_d , \dot{q}_d 가 구해진다. 이 기준궤적과 피드백되는 관절각 q , \dot{q} 의 차이가 e 와 \dot{e} 로 FLC의 입력변수가 되며, 추론과정을 거쳐 FLC는 이 추종오차(tracking error)들을 최소화하기 위한 관절토크 τ_1, τ_2 를 발생시킨다. 두개의 토크를 발생시키기 위해 각 링크당 하나의 FLC 구조가 필요하므로, 조정해야할 입력 scale factor는 K_{11}, K_{21} ($i=1,2$)로 총 4개이다. 따라서, 학습부의 신경회로망은 4개의 출력뉴런을 갖게되며, 각각 10개의 뉴런으로 구성된 두 은닉층을 갖는 3층 퍼셉트론으로 구성하였다(입력층 제외). 또한, 오차정보로서 e_i, \dot{e}_i ($i=1,2$)가 쓰이므로, 총 4개의 입력뉴런을 갖는다. EBPA의 학습률 η 는 0.5, 모멘텀 상수 α 는 0.3이다. 또한, 그림 2의 형태로 소속함수를 할당하므로 UD는 6이다. 출력 scale factor K_{31}, K_{32} 는 모두 30으로 고정시켰고, 따라서 토크의 발생범위는 $-180 \sim 180[\text{N.m}]$ 이다.

그림 4는 제안된 LFLC를 매니퓰레이터의 제어에 적용하여 cartesian 좌표궤적을 추종시킬 때, 학습초기와 충분한 학습이 on line으로 이루어진 후의 결과를 비교해 보이고 있다. 그림에서 볼 수 있듯이 초기에는 만족할 만한 궤적추종이 이루어지지 못하나, 5분후에는 기준궤적과 실제 매니퓰레이터의 궤적이 거의 일치함을 알 수 있다. 그림 5에서는 관절공간에서의 추종오차를 학습초기와 학습후를 비교하여 보이고 있다. 그림 6은 제안된 알고리즘을 통해 신경회로망이 FLC의 SF를 학습하여 적절한 값으로 수렴시키는 과정을 보이고 있다.

제안된 학습퍼지논리제어기가 외란의 대한 강인성(robustness)을 증명하기 위해, 매니퓰레이터 링크 2의 질량을 증가시켜 갑작스런 부하변동 또는 파라미터 변동에 대한 적응능력을 살펴보았다. 학습후 2초에서 link 2의 질량을 3 Kg에서 6 Kg으로 100% 증가시켰다. 그림 7(a)는 신경회로망이 SF 값을 출력시키는 본 논문의 경우이고, (b)는 학습후 SF 값을 고정시킨 경우의 FLC에 의한 결과이다. 그림에서 비교해 볼 수 있는 바와 같이 제안된 LFLC는 임의의 외란 인가에도 신경회로망이 적절한 SF 값을 출력시켜 기존의 FLC에 비해 적은 진동으로 안정된 출력을 보이고 있다. 따라서, 본 논문에 제안된 LFLC는 미지의 플랜트의 외란인가에도 좋은 학습 및 적응능력을 보이고 있다.


5. 결론

추론기능을 갖는 퍼지논리제어기에 학습능력을 갖는 신경회로망을 도입하여, 미지의 플랜트 및 환경변화에 대해 강인한 특성을 갖는 학습퍼지논리제어기가 제시되었다. 기존의 퍼지논


리제어의 scale factor를 가변하여 결정하기 위한 신경회로망의 학습알고리즘이 제안되었고, 제안된 학습퍼지논리제어 구조의 유용성을 증명하기 위해 2 자유도를 갖는 로봇 매니퓰레이터에 적용, 시뮬레이션 하였다. 제안된 알고리즘은 기존의 FLC 에서 결정하기 어려웠던 scale factor를 on line 학습을 통해 적절한 값으로 변화시켰다. 시간이 경과하고 학습이 충분히 이루어짐에 따라 좋은 출력특성을 보였고, 급격한 외란인가에도 강한 적응능력을 보였다.

제안된 알고리즘의 장점은 제어기 설계자가 직접 퍼지는 리제어의 소속함수나 scale factor 를 구하여야 하는 번거로움이 없고, 오차에 관한 scale factor의 함수를 학습하는 것이므로 범용 제어시스템으로 응용이 가능하며, 신경회로망의 학습 능력의 장점과 퍼지시스템의 추론 능력의 장점을 결합하여 상호 보완을 하므로써 지능제어(Intelligent Control)에 보다 가까이 접근했다고 볼 수 있다.

FLC의 출력축 scale factor도 변화시킨다면 더욱 개선된 결과를 보일 것으로 예상되므로, 이를 위한 학습알고리즘의 개발이 연구될 것이며, 또한 궁극적으로 퍼지규칙베이스의 자동생성을 위한 학습알고리즘도 향후연구과제로 남는다.




(a) 학습전
(a) Before Learning

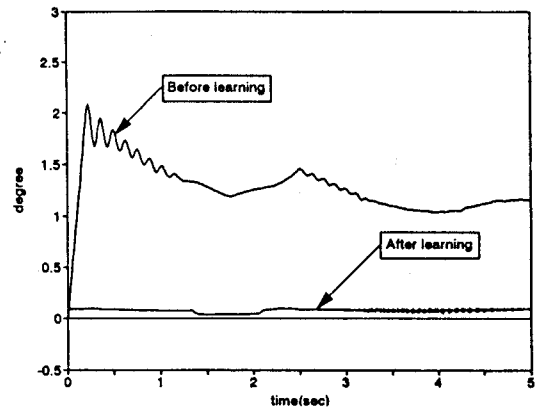


(b) 학습후
(b) After Learning

그림 4. 추종 결과(Cartesian 공간)
Fig. 4. Tracking(Cartesian Space)



(a) 링크 1의 추종오차
(a) Tracking Errors of Link 1



(b) 링크 2의 추종오차
(b) Tracking Errors of Link 2

그림 5. 추종 결과(관절 공간)
Fig. 5. Tracking(Joint Space)


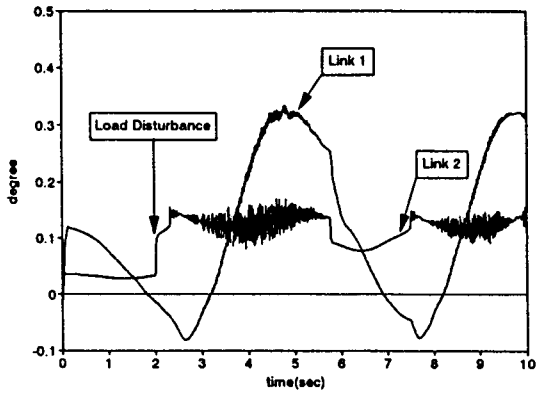



그림 6. 신경회로망의 출력
Fig. 6. Outputs of ANN

참 고 문 헌



(a) 제안된 학습퍼지논리제어기
(a) Proposed Learning FLC



(b) 기존의 퍼지논리제어기
(b) Conventional FLC

그림 7. 부하외란인가시 추종결과
Fig. 7. Tracking with Load Disturbance

- [1] H.Takagi, "Fusion Technology of Fuzzy Theory and Neural Networks-Survey and Future Directions," Proc. of International Conference on Fuzzy Logic and Neural Networks, vol.1, pp.13-26, 1990.
- [2] S.Nakanishi, T.Takagi, K.Uehara and Y.Gotoh, "Self-Organizing Fuzzy Controllers by Neural Networks," Proc. of International Conference on Fuzzy Logic and Neural Networks, vol.1, pp.187-191, 1990.
- [3] S.Horikawa, T.Furuhashi, S.Okuma and Y.Ukikawa, "Composition Methods of Fuzzy Neural Networks," Proc. of IECON'90, vol.2, pp.1253-1258, 1990.
- [4] C.C.Lee, "Fuzzy Logic in Control System: Fuzzy Logic Controller, Part I," IEEE Trans. Sys. Man Cybern., vol.SMC-20, no.2, pp.404-418. 1990.
- [5] C.C.Lee, "Fuzzy Logic in Control System: Fuzzy Logic Controller, Part II," IEEE Trans. Sys. Man Cybern., vol.SMC-20, no.2, pp.419-435. 1990.
- [6] S.Chui, S.Chand, D.Moore and A.Chaudhary, "Fuzzy Logic for Control of Roll and Moment for a Flexible Wing Aircraft," IEEE Control Syst. Mag., vol.11, no.4, JUN., pp.42-48, 1991.
- [7] P.D.Wasserman, "Neural Computing, Theory and Practice," Van Nostrand Reinhold, 1989.
- [8] R.J.Schilling, "Fundamentals of Robotics, Analysis and Control," Prentice-Hall, Inc., 1990.