

로봇 매니퓰레이터의 불확실성 보상을 위한 퍼지-뉴로 제어

박세준* · 양승혁** · 황문구* · 양태규*

A Fuzzy-Neural Control for Uncertainty Compensation of Robot Manipulator

Se-jun Park* · Seung-Hyuk Yang · moon-gu Hwang · Tae-Kyu Yang

요약

본 논문에서는 로봇 매니퓰레이터의 궤적 추종 제어에 관한 연구를 위하여 뉴로-퍼지 제어기를 제안하였다. 궤적 추종 제어기를 설계할 경우, 주로 이용되는 효과적인 방법은 토크 계산 제어방식이다. 그러나, 로봇 매니퓰레이터에 의한 불확실성문제로 인하여 토크 계산 제어방식만으로는 좋은 궤적 추종 성능을 얻을 수가 없다. 그러므로, 본 논문에서는 로봇 매니퓰레이터에서 발생한 불확실성을 보상하기 위하여 제안된 뉴로-퍼지 제어기를 이용하였다.

뉴로-퍼지 제어기에서의 퍼지 규칙의 수를 49개로 설정하였으며, 2관절 로봇 매니퓰레이터를 이용한 컴퓨터 시뮬레이션을 통해 제어기의 효율성을 입증하였다. 그 결과, 제안된 뉴로-퍼지 제어기의 출력이 로봇 매니퓰레이터에서 발생한 불확실성을 효과적으로 감소시킬 수 있음을 확인할 수 있었다.

ABSTRACT

This paper proposes a neuro-fuzzy controllers for trajectory tracking control of robot manipulators. The computed torque method is an effective means for trajectory tracking control. However, the tracking performance of this method is severely affected by the uncertainties of robot manipulators. Therefore, the proposed controller is used to compensate the uncertainties of robot manipulators.

In the neuro-fuzzy controllers, the number of fuzzy rules used forty-nine. The effectiveness of the proposed controllers is demonstrated by computer simulations using two-link robot manipulator. As a result, it is confirmed that the output of the proposed neuro-fuzzy controllers can efficiently decrease the uncertainties of robot manipulator.

키워드

neuro-fuzzy, tracking, compensate, uncertainties

I. 서 론

로봇 매니퓰레이터는 산업이 발전함에 따라서 다양한 분야에 적용되고 있으며, 그 중에서도 공장 자동화 시스템에서 사용되는 대부분의 로봇 매니퓰레이터는 고정된 작업환경에서의 반복적인 작업이 대부분이다. 반복적인 작업은 움직일 수

있는 공간에 대해서 궤적을 형성하게 되며, 로봇 매니퓰레이터는 형성된 궤적을 따라서 움직이게 된다. 그러므로, 얼마나 더 정확하고 더 빠르게 궤적을 따라서 움직여 주느냐 하는 것이 생산성과 질을 높이는데 크게 작용한다. 따라서, 이를 뒷받침해 줄 수 있는 제어 분야의 발전이 무엇보다도 중요하게 요구된다.

*목원대학교 IT공학과

접수일자 : 2003. 9. 1

** 도담시스템즈(주) 서브시스템 H/W 엔지니어

기존 제어 방법의 하나로, 시스템의 근사 모델을 구해서 제어하는 계산된 토크 방식(Computed Torque method: CTM)이 있다[1]. 특히, CTM 제어 방식은 궤적 추종 제어기를 설계할 경우 주로 적용되는 제어 방법이다. 그러나 고속 운전을 할 경우, 로봇 매니퓰레이터에 의한 불확실성 문제가 발생하기 때문에 CTM 제어 방식만으로는 좋은 결과를 얻을 수가 없다. 이러한 불확실성이 존재하는 로봇 시스템의 제어를 위하여 적응 제어기를 이용한 제어 방식들이 제안되었다[2-3]. 적응제어 기법은 로봇 매니퓰레이터의 가변적 동특성에 적절히 대처할 수 있고, 특히 부하의 변동이나 다양한 작업 도구의 변화를 요하는 작업 환경 하에서 고전적 제어 방식 보다 나은 작업 성능을 얻을 수 있고 로봇 매니퓰레이터에 대한 사전적 지식이 없더라도 사용할 수 있는 장점이 있으나, 이를 위한 실시간 로봇 파라미터들의 동정화에 많은 시간과 계산이 필요하게 된다. 더욱이 이러한 적응 제어 방식들은 측정 잡음에 매우 민감하고 구조화되지 않은 불확실성이 있는 경우에는 효과적이지 않은 단점이 있다. 근래에는 이러한 문제점을 해결하기 위해서 학습 능력, 추론 능력을 갖는 지능형 제어 기법이 개발, 적용되어 좋은 실행 특성을 보여주고 있다. 지능형 제어 기법 중에서도 대표적인 이론은 퍼지 제어시스템[4-5]과 신경회로망[6-7]이라 할 수 있다.

신경회로망은 병렬 구조를 가지고 있어서 병렬 분산 처리가 가능하며, 처리 속도가 빠르므로, 실시간 제어가 가능하다. 또한, 다중 입출력을 가지므로 다중 입출력 변수 시스템에 적합하며, 학습을 통해 제어 능력을 향상시킬 수도 있다. 그러나 궤적의 뉴런과 층의 수를 결정하기가 힘들며 학습 시, 지역적 최소치에 빠질 수 있다는 것이다.

퍼지 제어시스템은 전문가의 경험을 언어적인 변수를 바탕으로 퍼지 논리의 형태로 표현하고 언어 규칙들로 이루어진 제어기를 구성하기 때문에 제어 대상의 플랜트의 정확한 수학적 모델을 알지 못하더라도 좋은 제어 성능을 얻을 수 있다[8]. 그러나 퍼지 제어기의 설계는 시행착오적으로 이루어지며, 이러한 경험적 방법은 시스템이 복잡해지거나 돌발적인 문제를 해결하지 못했을 경우 제어

성능이 떨어지기 쉽다.

최근에는 퍼지시스템과 신경회로망의 장점을 이용, 단점을 상호 보완한 퍼지-뉴로 제어기의 연구가 활발히 진행되고 있다[9-11]. 퍼지-뉴로 제어는 퍼지 논리에서의 규칙 베이스 생성의 전문성 및 최적화 문제를 신경 회로망의 학습 능력을 이용하여 생성하고 개선하며, 신경회로망의 해석하기 어려운 수치적 제어를 퍼지논리의 언어적 제어를 이용하여 제어기 설계나 고장 추적 문제를 쉽게 해결할 수 있다.

본 논문에서 제안한 퍼지-뉴로 제어시스템은 Wang[12]이 제안한 퍼지 시스템을 신경회로망으로 표현한 기본 모델을 근거로 하여 설계되었다. 본 논문의 목적은 궤적을 추종하기 위한 것임으로, 궤적 추종 제어에 적합한 CTM 제어 방식을 이용하였으며, 로봇 매니퓰레이터에 의한 불확실성을 보상하기 위하여 CTM 제어기에 제안한 퍼지-뉴로 제어시스템을 추가시켰다. 또한, 본 논문에서는 구조화된 불확실성으로 부하 질량의 변화 값을 주었고, 구조화되지 않은 불확실성으로는 마찰력 값을 주었다.

시뮬레이션에서는 제안한 제어기를 이용하여 로봇 매니퓰레이터에 의한 다양한 불확실성을 보상하고, 그에 따라서 원하는 궤적을 정확하게 추종할 수 있는 가를 확인하고자 하였다

II. 계산 토크 제어방식

그림 1은 2관절 로봇 매니퓰레이터의 모델을 보여준다. 또한, 로봇 매니퓰레이터의 동역학은식 (1)과 같이 나타낸다.

$$\begin{aligned}\tau &= M(\theta) \ddot{\theta} + N(\theta, \dot{\theta}) + F \\ N(\theta, \dot{\theta}) &= V(\theta, \dot{\theta}) + G(\theta)\end{aligned}\quad (1)$$

여기서, $\tau(n \times 1)$: 관절 토크 벡터

$M(n \times n)$: 관성 행렬

$N(n \times 1)$: Coriolis 원심력과 중력 벡터

F : 구조화되지 않은 불확실성 벡터항

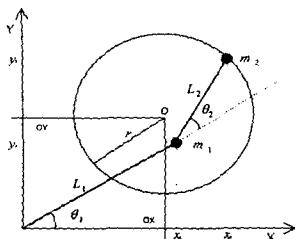


그림 1. 2관절 로봇
매니퓰레이터 Fig. 1 Two joint robot manipulator

본 논문에서는 궤적 추종을 목적으로 하기 때문에 적합한 계산 토크 제어방식을 이용하였다. 그림 2는 계산 토크 제어기를 보여주며 비선형보상부분 식(2)와, 서보부분 식(3)과 같이 나타낸다.

$$\tau = \hat{M}(\theta)\mu + \hat{N}(\theta, \dot{\theta}) \quad (2)$$

$$\mu = \theta_d + K_v \dot{e} + K_p e \quad (3)$$

여기서, $e = (\theta_d - \theta)$ 은 추종 각도 오차
 $\dot{e} = (\dot{\theta}_d - \dot{\theta})$ 은 추종 속도 오차

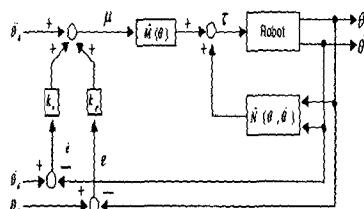


그림 2. 계산 토크 제어방식
Fig. 2 Computed Torque Method(CTM)

식(2)와 식(3)을 식(1)에 대입하고, \ddot{e} 을 $\ddot{\theta}_d - \ddot{\theta}$ 로 하여 정리하면 다음과 같다.

$$\ddot{e} + K_v \dot{e} + K_p e = \hat{M}^{-1}(\theta)(\Delta M \ddot{\theta} + \Delta N + F) \quad (4)$$

여기서, K_p, K_v 는 $(n \times n)$ 비례미분 이득 대각

행렬이며 양의 값을 가진다. 또한 ΔM 과 ΔN 은 구조적인 불확실성을 나타내며 다음과 같이 나타낸다.

$$\begin{aligned} \Delta M &= M - \hat{M} \\ \Delta N &= N - \hat{N} \end{aligned} \quad (5)$$

\hat{M} 과 \hat{N} 은 실질적인 파라미터 값이고, M 과 N 은 내부 구조에 의해서 변화될 수 없는 추정값이다. 만약, 구조적 불확실성이 ΔM 과 ΔN 이 존재하지 않고 구조화되지 않은 불확실성인 F 도 존재하지 않는다면, 식(4)의 우변은 0이 되어 식(6)과 같이 나타낼 수 있다.

$$\ddot{e} + K_v \dot{e} + K_p e = 0 \quad (6)$$

그래서, K_p 와 K_v 의 값을 잘 선택하면 오차는 점근적으로 영이 되어 로봇이 정확한 궤적을 추종하게 될 것이다. 그러나, 일반적으로 불확실성은 항상 존재하기 때문에 정확한 궤적을 추종하기는 어렵다.

III. 퍼지-뉴로 제어시스템

퍼지-뉴로 제어시스템은 퍼지 제어시스템과 신경회로망이 결합된 형태로, 본 논문에서 제안한 퍼지-뉴로 제어시스템의 구조는 그림 3에서 보여준다.

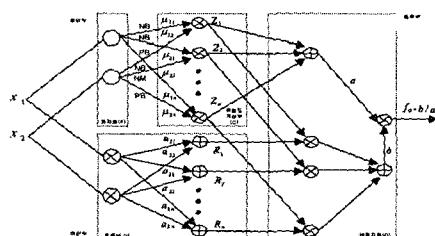


그림 3. 퍼지-뉴로 제어시스템의 구조
Fig. 3. Structure of fuzzy-neuro control system

설계한 제어시스템의 구조는 상단부, 하단부 그리고 출력부로 나뉜다. 상단부는 퍼지화(Fuzzifier : F)와 적합도 계산부분(Compatibility : C)으로 구성되며, 하단부는 추론부(Inference : I)로, 그리고 출력부는 비퍼지화(Defuzzifier : D)로 구성되었다. 본 논문에서 제안한 퍼지-뉴로 제어시스템과 기존의 신경회로망의 차이를 살펴보면, 신경회로망에서의 각 층 사이의 연결 강도는 임의의 값으로 설정 한데 비해서 퍼지-뉴로 제어시스템의 연결 강도로 주어지는 값들은 퍼지 시스템의 소속 함수와 퍼지 규칙에 관련하게 된다. 그러므로 기존의 신경 회로망보다도 구조적인 면에서 보다 체계적이라 할 수 있다. 본 논문에서 사용된 퍼지 제어 규칙은 다음과 같다.

Rule (1):

If x_1 is A_{11} and x_2 is A_{12} , then y_1 is R_1

Rule (2):

If x_1 is A_{21} and x_2 is A_{22} , then y_2 is R_2

...

Rule (n):

If x_1 is A_{n1} and x_2 is A_{n2} , then y_n is R_n

여기서, n : 퍼지 규칙의 수,

x_i : 퍼지시스템의 입력변수 ($i=1, 2$)

y_j : 퍼지시스템의 출력변수 ($j=1, 2, \dots, n$)

$A_{1j}, A_{2j} : j$ 번째 규칙의 입력 언어변수

$R_j : j$ 번째 규칙의 출력 언어변수

입력 소속 함수의 형태는 식(8)과 같이 가우시안 함수로 나타낸다.

$$\mu_{ij} = \exp\left(-\frac{1}{2}\left(\frac{x_i - c_{ij}}{w_{ij}}\right)^2\right) \quad (8)$$

여기서, x_i : 퍼지 입력변수 값

c_{ij} : 소속 함수의 중심 위치

w_{ij} : 소속 함수의 폭

제어 입력 값의 크기에 의해 결정된 퍼지 언어

변수는 같은 진행 과정에서의 소속 함수를 통해서 곧 바로 적합도를 결정하게 된다. 바로 이 적합도 값이 연결 강도에 해당하는 값이다. 최적 적합도 계산을 위해 Max-product 법을 이용하였으며, 이를 적용해서 상단부의 j 번째 최적 적합도값을 계산하면 다음과 같다.

$$Z_j = \prod_{i=1}^2 \mu_{ij} \quad (j=1, 2, \dots, n) \quad (9)$$

다음으로 j 번째 출력 언어변수에 해당하는 하단부의 추론값(R_1, R_2, \dots, R_n)을 계산하면 다음과 같이 선형 관계식으로 나타낸다.

$$R_j = a_{1j} \cdot x_1 + a_{2j} \cdot x_2 \quad (j=1, 2, \dots, n) \quad (10)$$

여기서, a_{1j}, a_{2j} : 추론값을 결정하는 선형계수값

계산된 적합도 값(Z_1, Z_2, \dots, Z_n)과 추론값(R_1, R_2, \dots, R_n)을 이용하여 퍼지-뉴로 제어시스템의 최종출력 f_o 를 구하면 식(13)과 같다. 이 값은 퍼지 시스템의 비퍼지화와 같으며 여러 가지 방법 중 무게중심법을 이용하였다.

$$b = \sum_{j=1}^n Z_j \cdot R_j \quad (11)$$

$$a = \sum_{j=1}^n Z_j \quad (12)$$

$$f_o = \frac{b}{a} \quad (13)$$

퍼지시스템과 원하는 출력 사이의 오차는 다음과 같이 정의한다.

$$\varepsilon = \frac{1}{2}(d - f_o)^2 \quad (14)$$

오차를 최소화시키는 방향으로 조정된 각각의 조정량들은 식 (15~17)과 같이 소속함수의 위치

와 폭 및 추론부 입출력 선형 관계식의 변수들을 변화시킨다.

$$c_{ij}(t+1) = c_{ij}(t) + \Delta c_{ij}(t) \quad (15)$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (16)$$

$$a_{ij}(t+1) = a_{ij}(t) + \Delta a_{ij}(t) \quad (17)$$

IV. 불확실성 보상을 위한 퍼지-뉴로 제어기

본 논문에서는 CTM 제어기와 제안한 퍼지-뉴로 제어시스템을 결합한 구조로 설계하였다. 이미 앞에서도 언급한 바와 같이, 고속 운전의 경우 로봇 매니퓰레이터에 의한 불확실성 문제가 발생하여 CTM 제어기만으로는 좋은 결과를 얻을 수가 없다.

그림 4는 본 논문에서는 제안한 퍼지-뉴로 제어기를 나타낸다. 퍼지-뉴로 제어시스템의 출력력을 τ_n 이라 하면, 다음과 같은 오차 방정식을 구할 수 있다.

$$\begin{aligned} & \hat{M}(\dot{\theta}_d + K_v \dot{e} + K_b e) + \hat{N} + \tau_n \\ &= M\ddot{\theta} + N + F \end{aligned} \quad (18)$$

식(18)을 정리하면 식(19)와 같이 나타낼 수 있다.

$$\begin{aligned} & \ddot{e} + K_v \dot{e} + K_b e \\ &= \hat{M}^{-1}((M - \hat{M})\ddot{\theta} + (N - \hat{N}) + F - \tau_n) \quad (19) \\ &= \hat{M}^{-1}(\Delta M\ddot{\theta} + \Delta N + F - \tau_n) \end{aligned}$$

만약, 퍼지-뉴로 제어기가 식(20)과 같은 학습 신호를 목표치로 사용한다면, 식(19)의 우변은 0이 될 것이며 오차는 점근적으로 감소하게 된다.

$$\tau_n = \Delta M\ddot{\theta} + \Delta N + F \quad (20)$$

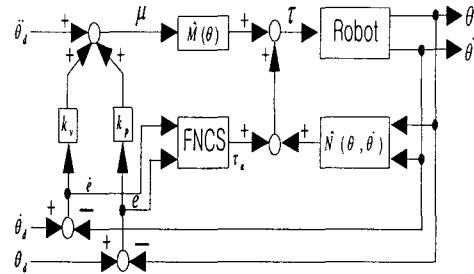


그림 4. 제안한 퍼지-뉴로 제어기
Fig. 4 Proposed fuzzy-neural controller

V. 시뮬레이션 및 결과

제안된 제어기의 효율성을 입증하기 위하여 본 논문에서는 2관절 로봇 매니퓰레이터의 궤적추종에 적용하였다. 로봇 매니퓰레이터가 추종해야 할 궤적은 식(21)과 같다.

$$\begin{aligned} ta &= -\pi \cdot \cos(\pi \cdot i/3) + \pi \\ c_x &= ox - r \cdot \cos(ta) \\ c_y &= oy - r \cdot \sin(ta) \end{aligned} \quad (21)$$

여기서, O_x, O_y : 원의 중심 좌표로 각각(0.2, 0.2)

r : 원의 반지름(0.075)

i : 샘플링 시간(0에서 3으로 0.01초씩 증가)

퍼지-뉴로 제어시스템과 CTM 제어기의 입력으로 설정해야 하는 것들은 궤적의 성분이 아니라 각 관절의 각도 오차와 속도 오차, 가속도 성분이어야 한다. 각 관절의 각도 변화는 식(22)과 식(23)에서와 같이 궤적과 각 링크의 길이만으로도 쉽게 구해진다.

$$\begin{aligned} c_k &= (c_x^2 + c_y^2 - L_1^2 - L_2^2) / (2 \cdot L_1 \cdot L_2) \\ \theta_2 &= \arccos(c_k) \end{aligned} \quad (22)$$

$$\begin{aligned} k_1 &= L_1 + L_2 \cdot \cos(\theta_2) \\ k_2 &= L_2 \cdot \sin(\theta_2) \\ \theta_1 &= \arctan2(c_y, c_x) - \arctan2(k_2, k_1) \end{aligned} \quad (23)$$

각 관절의 속도와 가속도는 쉽게 얻을 수 있으므로 로봇 매니퓰레이터의 역 운동학 모델로 관절 속도과 가속도를 구한다. 그림 1에서 로봇 매니퓰레이터 손끝의 위치를 관절각으로 나타내면 다음과 같다.

$$\begin{aligned} x &= L_1 \cdot \cos(\theta_1) + L_2 \cdot \cos(\theta_1 + \theta_2) \\ y &= L_1 \cdot \sin(\theta_1) + L_2 \cdot \sin(\theta_1 + \theta_2) \end{aligned} \quad (24)$$

식(24)를 미분하여 속도를 구하여 간단히 정리하면 다음과 같다.

$$\dot{x} = J(\theta) \cdot \dot{\theta} \quad (25)$$

여기서, $J(\theta)$: 자코비안 행렬

식(25)를 미분하여 가속도를 구하면 다음과 같다

$$\ddot{x} = J(\theta) \cdot \ddot{\theta} + J(\theta) \cdot \dot{\theta}^2 \quad (26)$$

식(25)와 식(26)을 이용하여 역 운동학 모델을 구하면 다음과 같다.

$$\dot{\theta} = j(\theta)^{-1} \cdot \dot{x} \quad (27)$$

$$\ddot{\theta} = J(\theta)^{-1} [x - J(\theta) \cdot \dot{\theta}] \quad (28)$$

시뮬레이션에서 구조화되지 않은 불확실성을 마찰력으로 주었다.

$$f_1 = 3 \cdot \text{sgn}(\theta_1) \quad (29)$$

$$f_2 = 3 \cdot \text{sgn}(\theta_2) \quad (30)$$

그리고, 구조화된 불확실성을 위해 부하 질량의 변화를 주었다.

$$\widehat{m_1} = 0.8 \cdot m_1 \quad (31)$$

$$\widehat{m_2} = 0.8 \cdot m_2 \quad (32)$$

컴퓨터 시뮬레이션에서 사용된 각각의 파라미터 값은 표 1과 같이 나타낸다. 퍼지 규칙은 49개로 구성하였고, 신경망의 학습율은 0.001이며 샘플링타임은 1ms로 하였다.

표 1. 파라미터 값

Table 1. Value of parameters

파라미터 정의	파라미터 값	단위
링크의 길이	$L_1 = 0.25$ $L_2 = 0.16$	m
링크의 질량	$M_1 = 3$ $M_2 = 1$	kg
궤환 이득	$K_v = 28$ $K_p = 196$	

그림 5는 불확실성이 발생했을 경우 궤적의 변형이 발생하는 상황을 나타내고 있다. 불확실성이 존재하면 원하는 궤적을 추종하기가 어렵다는 것을 보여준다.

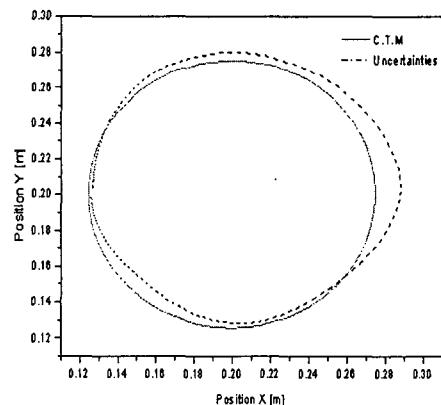


그림 5. C.T.M. 과 불확실성
Fig. 5 C.T.M. and Uncertainties

다음은 CTM 제어기의 불확실성 보상 부분에 제안한 제어기를 추가시킨 후, 반복횟수를 증가시켜 가면서 확인한 궤적 성분의 변화이다. 그림 6과 그림 7은 기준 궤적과 반복횟수의 증가로 인한 위치 X와 위치 Y의 오차를 나타내며, 반복횟수가 증가되어 가면서 오차의 범위가 점점 감소되어 감을 알 수 있다.

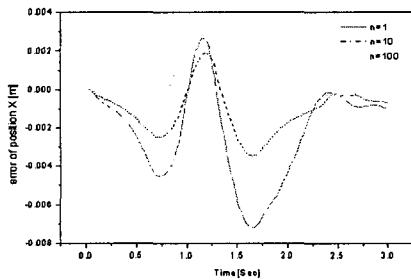


그림 6. 반복횟수에 대항 위치 x 의 오차
Fig. 6 Error of position x for iteration number

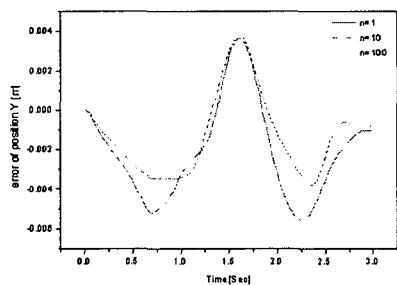


그림 7. 반복횟수에 대한 위치 y 의 오차
Fig. 7 Error of position y for iteration number

그림 8은 반복횟수에 대한 궤적을 보여주고 있다. 반복횟수가 증가할수록 기준 궤적에 점점 접근하는 것을 보여주고 있다. 이는 불확실성이 감소되어 간다는 것을 알 수 있다.

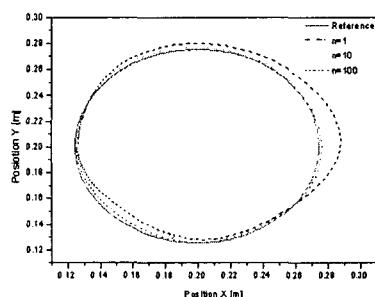


그림 8. 반복횟수에 대한 궤적
Fig. 8 Trajectory for iteration number

그림 9는 210회 반복을 했을 경우 기준 궤적과의 비교를 나타낸다. 210회 반복했을 경우 원하는 궤적과 거의 일치함을 알 수 있다.

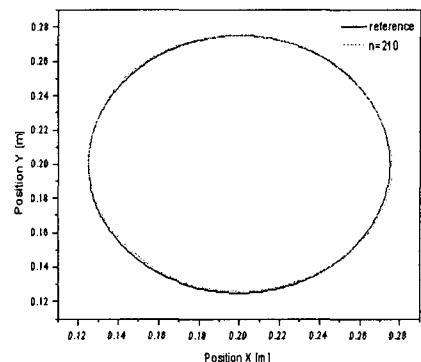


그림 9. 최종 반복 횟수
Fig. 9 Final iteration number

V. 결 론

본 논문에서는 로봇 매니퓰레이터에서 발생한 구조화된 불확실성으로는 부하 질량의 변화값을 주었으며, 구조화되지 않은 불확실성으로는 마찰력값을 주었다. 퍼지-뉴로 제어기의 성능을 시뮬레이션을 통해서 확인한 결과, 반복횟수가 증가할수록 퍼지-뉴로 제어기의 불확실성 보상 토크의 크기가 점차 커져 가는 것을 확인 할 수 있었으며, 이에 따라 궤적의 변화도 원하는 목표 궤적에 점차 가깝게 접근해 감을 알 수 있었다. 또한, CTM 제어기의 출력에 해당하는 각 관절의 각도와 속도를 통해서도 확인되듯이, 반복횟수의 증가로 인하여 추종할 각도와 속도에 근접해 감을 알 수 있었다.

시뮬레이션 결과로부터 제안한 퍼지-뉴로 제어기의 불확실성 보상 토크의 변화가 로봇 매니퓰레이터에서 발생한 구조화된 불확실성과 구조화되지 않은 불확실성을 효과적으로 감소시킬 수 있음이 검증되었다.

참고 문헌

- [1] A. Ishiguro, T. Furuhashi, S. Okuma, and Y. Unchikawa, "A neural network compensator for uncertainties of robotics manipulators", IEEE Trans. Industrial Electronics, vol. 39, no.6 , pp.565-570, 1992.

- [2] J. J. Craig, P. H. su and S. S. Sadtry, "Adaptive control of machanical manipulators", Int. J. Robotics Research, vol. 6, no. 22, pp.16-28, 1987.
- [3] J. J. E. Soltion and W. Li , "Adaptive manipulator control : A case study", IEEE Trans. Automatic Control , vol. 33, no.11, pp.995-1003, 1998.
- [4] C. C. LEE. "Fuzzy Logic in Control System : Fuzzy Logic in Controller Part I", IEEE Trans. On System, Man and Cyber, vol.20, pp.404-418, 1990.
- [5] C. C. LEE. "Fuzzy Logic in Control System Fuzzy Logic in Controller Part II," IEEE Trans. On System, Man and Cyber, vol.20, pp.419-435, 1990.
- [6] D. Psaltis, A. Siders, and A. A. Yamamura, "A multilayered neural network controller", IEEE Control Systems Magazine, pp.17-21, Apr. 1988.
- [7] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback-Error-Learning neural network for trajectory control of robotic manipulator", Neural Networks, vol .1, pp.251-265, 1988.
- [8] M. Mizumoto, "Realization of PID controls by fuzzy control methods", Fuzzy Sets and System, vol.80, pp.171-182 , 1995.
- [9] Y. Lin and G. A Cunningham, "A New Approach to Fuzzy Neural System Modeling", IEEE Trans. On Fuzzy Systems, vol.3 , no.2 , pp.190-198, 1995.
- [10] C. j. Lin and C. T. Lin, "An ART-Based Fuzzy Adaptive Learning Control Network", IEEE Trans. On Fuzzy Systems, vol.5 , no.4 , pp.477-496, 1997.
- [11] J. Godjevac, and N. Steele "Neuro-fuzzy control of a mobile robot", Elsevier Science B.V, 1999.
- [12] L. X. Wang, Adaptive Fuzzy Systems and Control, Prentice Hall, 1994.

저자 소개



박세준(Se-jun Park)

1992 목원대학교 전자공학과(공학사)
1997 목원대학교 전자및컴퓨터공학과(공학석사)

2003 현 목원대학교 IT공학과 박사과정
※ 관심분야 : 로봇제어, 지능제어, 인터넷제어



양승혁(Seung-Hyuk Yang)

2001 목원대학교 전자공학과
(공학사)
2003 목원대학교 대학원 IT공학과
(공학석사)

2003 현 도담시스템즈(주) 서브시스템 H/W 엔지니어
※ 관심분야 : 로봇제어, 지능제어



황문구(Moon-Gu Hwang)

1969 광운대학교 전자공학과
(공학사)
1980 전국대학교 대학원 전자공학
과(공학석사)
2003 현 목원대학교 IT공학과 박사과정 현 한밭대학
교 전자공학과 교수
※ 관심분야 : EMI, EMC



양태규(Tae-Kyu Yang)

1982 광운대학교 전자공학과(공학
사)
1982 광운대학교 대학원 전자공학
과(공학석사)
1989 광운대학교 대학원 전자공학과(공학박사)
2003 현 목원대학교 전자정보보호공학부 교수
※ 관심분야 : 로봇제어, 지능제어, 인터넷제어