

論文2003-40SC-5-1

CMAC 신경망 외란관측기를 이용한 유연관절 로봇의 강인 추적제어 (Robust Tracking Control of a Flexible Joint Robot System using a CMAC Neural Network Disturbance Observer)

金 殷 泰 *

(Euntai Kim)

要 約

CMAC 신경망은 지역적 구조로 비선형제어에 적용 시 좋은 성능을 보이는 것이 잘 알려져 있다. 본 논문에서는 CMAC 신경망 외란관측기와 제어기를 제안하고 이를 유연관절 로봇의 강인 추적제어에 적용하도록 한다. 이때 CMAC 신경망 외란관측기는 기계시스템에서 발생하는 파라미터의 불확실성과 외부 외란을 상쇄하는 역할을 한다. 컴퓨터 보의 실험을 통하여 본 논문에서 제안한 CMAC 외란관측기를 유연관절 로봇의 제어에 적용하고 그 성능을 확인하도록 한다.

Abstract

The local structure of CMAC neural networks (NN) results in better and faster controllers for nonlinear dynamical systems. In this paper, we propose a CMAC NN based disturbance observer and its corresponding controller for a flexible joint robot. The CMAC NN based disturbance observer compensates for the parametric uncertainties and the external disturbances throughout the entire mechanical system. Finally, a simulation result is given to demonstrate the effectiveness of proposed design method's robust tracking performance.

Keyword :CMAC신경망, 유연관절, 피드백선형화**I. 서 론**

지난 10년간, 로보틱스 분야에서 로봇의 유연한 관절이 로봇의 성능에 어떠한 영향을 미치는가에 대하여 많은 연구가 진행되었다. 이는 기계적 토오크가 주로 하모닉 드라이브와 같은 기어 장치를 통해서 로봇에

전달되기 때문에 로봇의 제어성능을 높이기 위해서 유연관절이 로봇의 제어에 미치는 영향에 대한 연구가 필요했기 때문이다. 이러한 유연관절 로봇의 제어를 위해서는 이를 잘 표현할 수 있는 모델이 필요했는데 Spong에 의하여 제안된 유연관절 로봇 모델은 전역적 피드백 선형화가 가능하고 탄성이 무한대가 되면 일반 비유연 (rigid) 로봇이 되는 특징으로 많은 로봇 학자들이 이 모델을 이용하여 제어 알고리즘을 개발하고 있다^[1].

이러한 유연관절 로봇의 제어기 설계에 있어서 외란이나 로봇의 불확실성의 영향을 줄이는 것은 대단히

* 正會員, 延世大學校 電氣電子工學部
(Yonsei University, School of Electrical and Electronic Engr.)

接受日字:2002年1月17日, 수정완료일:2003年7月30日

중요한 일이고 이를 위해 일반적으로 높은 이득의 제어기나 스위칭형태의 제어기를 이용한 연구가 보고되고 있다. Slotine등은 로봇의 불확실성을 극복하고 제어기의 이론적 안정도 보장을 위하여 이 같은 제어기를 사용하였고^[2], Lim^[3]과 Su^[4]등도 비슷한 이유로 높은 이득의 제어기나 스위칭 슬라이드 제어기를 사용하였다. 그러나 유연로봇과 같이 탄성이 강한 기계 시스템의 경우 이러한 방식의 제어기는 진동이나 공진을 일으킬 수 있고 고주파 모드를 여기시킬 수 있다는 것이 잘 알려져 있다^[5, 6].

본 논문에서는 CMAC 신경망을 이용한 외란관측기를 이용하여 외란의 영향을 감소시키는 방식을 제시하고 유연관절 로봇의 추적제어에 적용하여 타당성을 확인한다. 본 논문에서 제안하는 방식은 CMAC 신경망의 일반근사성을 이용하여 외란관측기를 설계하는 방식으로 높은 이득의 스위칭형 제어기 등을 이용하지 않고 외부의 외란과 내부의 파라미터 불확실성을 모두 감쇄시키는 특성을 갖는다. 본 논문에서 제안하는 방식은 Wang^[7], Passino^[8]등에 의해 제안된 적응 퍼지/신경망 제어기를 대신할 수 있으며 그들에 비해 몇 가지 장점을 가지고 있는데 이에 대해서는 뒤에서 설명하도록 한다.

본 논문의 구성은 다음과 같다. II장에서는 CMAC 신경망과 문제의 구성에 대하여 간단히 설명하고 CMAC의 일반근사성에 대하여 설명한다. III장에서는 CMAC 신경망을 이용한 외란관측기를 설계하고 그 특성을 분석한다. IV장에서는 모의실험을 통하여 CMAC 신경망 외란관측기를 유연관절 로봇제어에 적용한 결과를 확인하고 V장에서는 결론을 이끌어 낸다.

II. 문제의 구성

1. CMAC 신경회로망 시스템

기본적인 CMAC 신경회로망은 <그림 1>과 같이 입력 벡터 $x = (x_1, x_2, \dots, x_n)^T \in X \subset R^n$ 을 출력값 $y \in Y \subset R$ 에 대응시키는 비선형 함수의 역할을 한다. <그림 1>에서 보는 바와 같이 CMAC 알고리즘은 두 단계 함수로 구성된다.

$$\begin{aligned} R : X &\rightarrow A \\ P : A &\rightarrow Y \end{aligned}$$

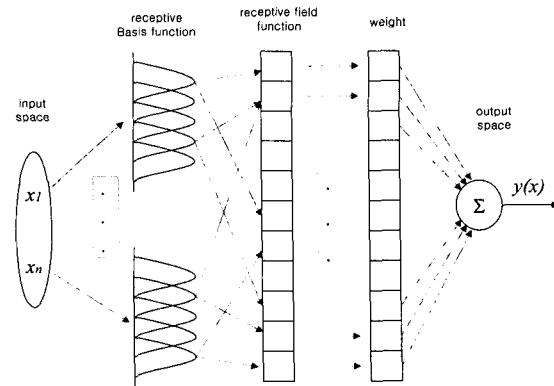


그림 1. CMAC 신경회로망
Fig. 1. CMAC neural networks.

여기서 X 는 n 차원 입력공간이고 A 는 h 차원 부공간이고 Y 는 1차원 출력공간이다. $\xi = R(x)$ 는 입력공간을 부공간에 대응시키는 고정된 함수이고 $y = P(\xi)$ 는 식 (1)과 같이 부공간을 웨이트에 투영하여 출력을 계산하는 함수이다.

$$y = P(\xi) = W^T \xi \quad (1)$$

여기서 ξ 를 다차원 수용함수 (receptive field function)이라 한다. 각 차원에서 수용함수로는 삼각형 함수나 사다리꼴 함수, 가우시안 함수^[9]를 사용할 수 있지만 CMAC의 경우 B-스프라인 (B-spline)함수를 사용하는 것이 가장 일반적이다^[10]. 스프라인 함수는 중간점(break point)에서 원하는 수준의 부드러운 특성을 갖는 다차항으로 이루어진 함수이다. B-스프라인 함수를 사용한 CMAC 신경망의 출력은 다음과 같이 B-스프라인 함수의 선형 결합으로 나타나게 된다.

$$f(x) = \sum_{j=1}^n w_j B_{j,k}(x) \quad (2)$$

여기서 $B_{j,k} = B(\cdot | t_j, \dots, t_{j+k})$ 는 매듭점 (knot points) $t_1 \leq t_2 \leq \dots \leq t_{n+k}$ 에서 정의된 차수 k 의 j 번째 B-스프라인 함수이다. B-스프라인 함수는 다음의 정규화 특성을 갖고 식 (4)의 재귀적 관계식에 의해서 구해낼 수 있다.

$$\sum_j B_{j,k}(x) = 1 \quad (3)$$

$$B_{j,k}(x) = \frac{x - t_j}{t_{j+k-1} - t_j} B_{j,k-1}(x) + \frac{t_{j+k} - x}{t_{j+k} - t_{j+1}} B_{j+1,k-1}(x) \quad (4)$$

이러한 B-스프라인 함수의 벡터곱이 다차원 수용함수 (receptive field function) ξ 를 나타내며 CMAC는 다차원 수용함수 ξ 과 가중치 W 를 이용하여 식 (1)과 같이 나타낼 수 있다.

이러한 CMAC 신경망은 비선형 함수를 원하는 수준 까지 정확히 표현할 수 있는 것이 알려져 있다^[11]. x 가 콤팩트 집합 M_x 에 소속된 경우, 최적의 신경망 웨이트는 식 (5)와 같이 주어진 비선형 함수와 CMAC 신경망과의 차이를 최소화하는 값으로 정의할 수 있다.

$$W^* = \arg \min_{W \in M_w} [\sup_{x \in M_x} |\Omega_x(x) - \widehat{\Omega}_x(x|W)|] \quad (5)$$

여기서 $\Omega_x(\cdot)$ 는 미지의 비선형 함수를 나타내고 $\widehat{\Omega}_x(\cdot)$ 는 CMAC 신경망을 나타내며 M_w 는 신경망의 웨이트 추정치가 존재하는 영역이다. 이러한 성질을 CMAC의 일반근사성이라 하며 최적의 웨이트를 갖는 신경망을 이용하면 비선형 함수는 다음과 같이 표현할 수 있다.

$$\Omega_x(\cdot) = \widehat{\Omega}_x(\cdot | W^*) + \varepsilon(\cdot) \quad (6)$$

여기서 $\varepsilon(\cdot)$ 는 신경망의 복원 오차이며 CMAC의 중간 노드 수를 늘임으로서 충분히 작게 할 수 있다.

2. 유연관절 로봇과 피드백 선형화

<그림 2>와 같은 1축 유연관절 로봇은 다음의 식으로 표현할 수 있다.

$$J_1 \ddot{q}_1 + MgL \sin q_1 + k(q_1 - q_2) = 0 \quad (7-1)$$

$$J_2 \ddot{q}_2 - k(q_1 - q_2) = u \quad (7-2)$$

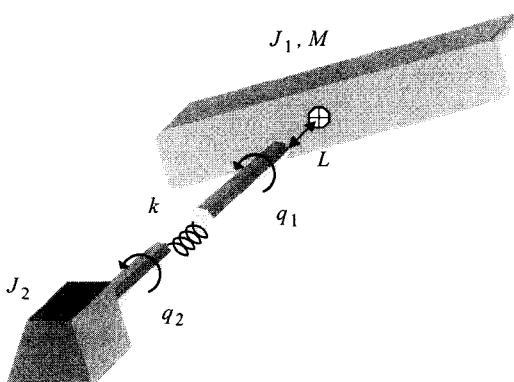


그림 2. 유연관절 로봇

Fig. 2. Flexible joint robot.

여기서 q_1 과 q_2 는 링크의 위치와 액츄에이터의 위치를 나타내며 J_1 은 링크의 관성, J_2 는 액츄에이터의 관성을 나타낸다. 또 k 는 탄성계수, M 는 링크의 중량, g 는 중력가속도, L 은 무게 중심을 나타내며 u 는 액츄에이터의 입력 토오크를 나타낸다.

이를 $z = (z_1 \ z_2 \ z_3 \ z_4)^T = (q_1 \ q_1 \ q_2 \ q_2)^T$ 인 상태 공간으로 나타내면 다음과 같다.

$$\begin{aligned} \dot{z}_1 &= z_2 \\ \dot{z}_2 &= -\frac{MgL}{J_1} \sin z_1 - \frac{k}{J_1} z_1 + \frac{k}{J_1} z_3 \\ \dot{z}_3 &= z_4 \\ \dot{z}_4 &= \frac{k}{J_2} (z_1 - z_3) + \frac{1}{J_2} u \end{aligned} \quad (8)$$

이러한 유연관절 로봇은 전역적으로 입력-상태 피드백 선형화(input-state feedback linearizable)가 가능하며 이를 이용한 피드백 선형화 제어기가 설계 가능하다는 것이 알려져 있다^[12]. 즉 다음 식 (9)와 같은 비선형 상태변환을 고려하면

$$\begin{aligned} x_1 &= x_1 \\ x_2 &= x_2 \\ x_3 &= -\frac{MgL}{J_1} \sin z_1 - \frac{k}{J_1} (z_1 - z_3) \\ x_4 &= -\frac{MgL}{J_1} z_2 \cos z_1 - \frac{k}{J_1} (z_2 - z_4) \end{aligned} \quad (9)$$

유연관절의 로봇 식은 다음과 같이 표현된다.

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= x_3 \\ \dot{x}_3 &= x_4 \\ \dot{x}_4 &= \alpha(x) + \beta(x) u. \end{aligned} \quad (10)$$

여기서 $x^T = (x_1 \ x_2 \ x_3 \ x_4)^T$ 이고

$$\begin{aligned} \alpha(x) &= \frac{MgL}{J_1} \sin x_1 (x_2^2 + \frac{MgL}{J_1} \cos x_1 + \frac{k}{J_1}) \\ &+ \frac{k}{J_1} (x_1 - x_3) (\frac{k}{J_1} + \frac{k}{J_2} + \frac{MgL}{J_1} \cos x_1), \\ \beta(x) &= \frac{k}{J_1 J_2} \end{aligned} \quad (11)$$

3. 불확실한 유연관절 로봇 모델링

유연관절 로봇에 내부 파라미터 섭동과 외란이 있는

경우 다음의 식으로 표현될 수 있다.

$$\dot{x}_4 = [\alpha(\mathbf{x}) + \Delta\alpha(\mathbf{x})] + [\beta(\mathbf{x}) + \Delta\beta(\mathbf{x})]u + d \quad (12)$$

여기서 $\alpha(\cdot)$ 과 $\beta(\cdot)$ 는 공칭 (nominal) 함수이고 $\Delta\alpha(\cdot)$ 과 $\Delta\beta(\cdot)$ 는 그 파라미터 섭동을 나타내며 d 는 외부 외란이다. 로봇 제어의 목적은 관절의 위치 x_1 이 원하는 궤적 q_d 를 추적하는 것이다. 본 논문에서는 내부 파라미터 섭동과 외부 외란을 다음의 식과 같이 하나의 외란으로 다룬다. 즉

$$\begin{aligned} \dot{x}_4 &= [\alpha(\mathbf{x}) + \Delta\alpha(\mathbf{x})] + [\beta(\mathbf{x}) + \Delta\beta(\mathbf{x})]u + d \\ &= \alpha(\mathbf{x}) + \beta(\mathbf{x})u + \Omega_x(\mathbf{x}, u) \end{aligned} \quad (13)$$

여기서 $\Omega_x(\mathbf{x}, u) \equiv \Delta\alpha(\mathbf{x}) + \Delta\beta(\mathbf{x})u + d$ 는 내부 파라미터 섭동과 외부 외란을 포함한 전체 외란을 나타내며 일반적으로 수학적인 식으로 표현할 수 없다.

III. CMAC 외란관측기를 이용한 제어시스템

CMAC 외란관측기는 CMAC 신경망의 일반근사성에 이론적 근거를 둔 것으로 <그림 3>과 같이 유연관절 로봇의 입출력 정보를 이용하여 미지의 전체 외란 $\Omega_x(\cdot)$ 을 CMAC 신경망 $\widehat{\Omega}_x(\cdot)$ 로 근사하는 것이다.

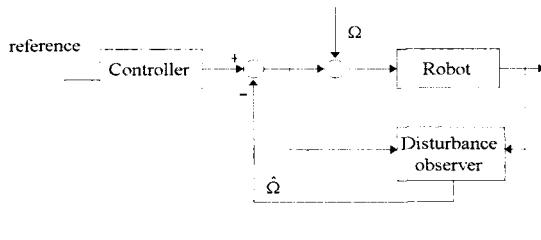


그림 3. 외란관측기 구조

Fig. 3. Disturbance observer.

이제 CMAC 신경망 $\widehat{\Omega}_x(\cdot)$ 이 전체 $\Omega_x(\cdot)$ 을 잘 표현하면 다음의 식 (14)로 표현되는 제어기를 사용할 수 있다.

$$u = \frac{v - \alpha(\mathbf{x}) - \widehat{\Omega}_x(\mathbf{x}, \widehat{\mathbf{W}})}{\beta(\mathbf{x})} \quad (14)$$

1. CMAC 외란관측기

유연관절 로봇 (13)의 전체 외란을 관측하기 위하여 다음과 같은 1차 시스템을 설계한다.

$$\dot{\mu} = -\sigma\mu + p(\mathbf{x}, u, \widehat{\mathbf{W}}) \quad (15)$$

여기서 $p(\mathbf{x}, u, \widehat{\mathbf{W}}) = \sigma\mu + \alpha(\mathbf{x}) + \beta(\mathbf{x})u + \widehat{\Omega}_x(\mathbf{x}, u, \widehat{\mathbf{W}})$ 이고 σ 는 양수이다. 이 때 새로운 변수

$$\xi \equiv x_4 - \mu$$

를 정의하면 식 (13)과 식(15)로 부터 $\xi \rightarrow 0$ 는 CMAC 신경망 $\widehat{\Omega}_x(\mathbf{x}, u, \widehat{\mathbf{W}})$ 가 미지의 전체 외란 $\Omega_x(\mathbf{x}, u)$ 에 접근하는 것을 의미하게 된다. 즉 새로운 변수 ξ 는 CMAC 신경망이 외란을 얼마나 잘 관측하는 가를 나타내는 척도가 되며 본 논문에서는 ‘외란 관측 오차’라고 부른다. 따라서 외란 관측 오차가 0인 경우 ($\widehat{\Omega}_x(\mathbf{x}, u, \widehat{\mathbf{W}})$ 가 $\Omega_x(\mathbf{x}, u)$ 를 잘 관측하는 경우), 식 (14)의 제어기를 설계하여 유연관절 로봇을 제어할 수 있다.

2. 제어기

식 (14)의 제어기를 실제 구현하는 경우 제어 입력 u 가 식의 좌우변에 모두 있으므로 직접 구현은 어려워 보인다. 그러나 식 (14)에서 결국 제어 신호 u 는 상태변수 \mathbf{x} 의 함수여야 하므로 로봇의 전체 외란 $\Omega_x(\cdot)$ 은 결국 상태변수 \mathbf{x} 만의 함수여야 하고 CMAC 신경망 $\widehat{\Omega}_x(\cdot | \widehat{\mathbf{W}})$ 도 \mathbf{x} 만의 함수로 만들어도 된다. 이제 다음과 같은 제어기를 설계한다.

$$u = \frac{v - \alpha(\mathbf{x}) - \widehat{\Omega}_x(\mathbf{x} | \widehat{\mathbf{W}})}{\beta(\mathbf{x})} \quad (16-1)$$

$$v = q_d^{(4)} - \mathbf{K}^T \tilde{\mathbf{x}} \quad (16-2)$$

여기서 $\tilde{\mathbf{x}} = (\tilde{x}_1 \ \tilde{x}_2 \ \tilde{x}_3 \ \tilde{x}_4)^T = (x_1 - q_d \ x_2 - q_d \ x_3 - q_d^{(2)} \ x_4 - q_d^{(3)})^T$ 는 추적제어 오차이고 $\mathbf{K} = (k_4 \ \dots \ k_1)^T$ 는 제어기 이득으로 $d(s) = s^4 + k_1 s^3 + \dots + k_4$ 의 근이 좌반면 안정한 영역에 있도록 설정한다. 식 (16)의 제어기를 이용하는 경우 전체 제어 오차는 다음의 식으로 표현된다.

$$\dot{\tilde{x}}_4 = -\mathbf{K}^T \tilde{\mathbf{x}} + \Omega_x(\mathbf{x}) - \widehat{\Omega}_x(\mathbf{x} | \widehat{\mathbf{W}}) \quad (17)$$

행렬방정식으로는

$$\dot{\tilde{x}} = \Lambda \tilde{x} + b(\mathcal{Q}_x(x) - \widehat{\mathcal{Q}}_x(x|\tilde{W})), \quad (18)$$

여기서 $\Lambda = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -k_4 & -k_3 & -k_2 & -k_1 \end{pmatrix}$, $b = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \end{pmatrix}$ 이다.

3. CMAC 신경망의 학습

<그림 3>과 같이 유연관절 로봇과 외란관측기, 제어기로 구성된 전체 시스템의 안정성을 보장하기 위하여 다음과 같은 확장 오차를 고려한다.

$$\dot{\Xi} = \Pi \Xi + B(\mathcal{Q}_x(x) - \widehat{\mathcal{Q}}_x(x|\tilde{W})) \quad (19)$$

여기서 $\Xi = \begin{pmatrix} \tilde{x} \\ \xi \end{pmatrix}$, $\Pi = \begin{pmatrix} \Lambda & 0_{4 \times 1} \\ 0_{1 \times 4} & -\sigma \end{pmatrix}$, $B = \begin{pmatrix} b \\ 1 \end{pmatrix}$ 이고

Ξ 는 확장오차로 외란 관측 오차와 제어 오차를 모두 포함하는 오차이다. CMAC 신경망은 외란 관측 오차와 제어 오차를 모두 줄이는 방향으로 학습을 한다. 다음의 정리는 CMAC 신경망의 학습방법을 나타낸다.

정리 1.

유연관절 로봇 (13)에 외란관측기가 식 (15)과 같이 설치되어 있고 식 (16)의 제어기를 사용하여 제어를 하는 경우를 생각한다. CMAC 신경망 웨이트 다음의 식 (20)과 같이 학습하고 이것이 유계되어 있는 경우 외란 관측 오차 ξ 과 제어 오차 \tilde{x} 를 포함하는 확장오차는 콤팩트한 집합으로 수렴하며 ($\xi, \tilde{x} \in L_\infty$) 그 집합의 크기는 임의로 작게 할 수 있다.

$$\dot{\tilde{W}} = \gamma \Xi^T P B \xi(x) \quad (20)$$

(증명)

식 (6)을 이용하여 확장오차식을 다음과 같이 표현할 수 있다.

$$\begin{aligned} \dot{\Xi} &= \Pi \Xi + B \{ \widehat{\mathcal{Q}}_x(x|W) - \widehat{\mathcal{Q}}_x(x|\tilde{W}) \} + B \varepsilon(x) \quad (21) \\ &= \Pi \Xi + B \tilde{W}^T \xi(x) + B \varepsilon(x). \end{aligned}$$

Π 는 안정한 행렬이므로 임의의 양한정 행렬 Q 에 대하여 식 (22)을 만족하는 양한정 행렬 P 가 존재한다.

$$\Pi^T P + P \Pi = -Q \quad (22)$$

이제 다음과 같은 리아프노프 후보함수를 생각한다.

$$V = \frac{1}{2} \Xi^T P \Xi + \frac{1}{2\gamma} \tilde{W}^T \tilde{W} \quad (23)$$

식 (23)을 미분하여 식 (21)에 넣으면

$$\begin{aligned} \dot{V} &= \Xi^T P \dot{\Xi} + \frac{1}{\gamma} \tilde{W}^T \tilde{W} \\ &= \Xi^T P \Pi \Xi + \Xi^T P B \tilde{W}^T \xi(x) + \frac{1}{\gamma} \tilde{W}^T \tilde{W} + \Xi^T P B \varepsilon(x) \\ &= \frac{1}{2} \Xi^T (\Pi^T P + P \Pi) \Xi + \tilde{W}^T \left\{ \Xi^T P B \xi(x) + \frac{1}{\gamma} \tilde{W} \right\} \\ &\quad + \Xi^T P B \varepsilon(x) \\ &= -\frac{1}{2} \Xi^T Q \Xi + \tilde{W}^T \left\{ \Xi^T P B \xi(x) + \frac{1}{\gamma} \tilde{W} \right\} + \Xi^T P B \varepsilon(x) \end{aligned}$$

여기서

$$\tilde{W} = -\gamma \Xi^T P B \xi(x),$$

즉

$$\dot{\tilde{W}} = \gamma \Xi^T P B \xi(x) \quad (24)$$

로 하면,

$$\begin{aligned} \dot{V} &\leq -\frac{1}{2} \Xi^T Q \Xi + \Xi^T P B \varepsilon(x) \leq -\frac{1}{2} \lambda_{\min}(Q) \|\Xi\|^2 \\ &\quad + \left\{ \frac{\lambda_{\min}(Q)}{4\lambda_{\max}(P)} \Xi^T P \Xi + \frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)} B^T P B \varepsilon^2(x) \right\} \\ &\quad - \left\{ \frac{\lambda_{\min}(Q)}{4\lambda_{\max}(P)} \Xi^T P \Xi + \frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)} B^T P B \varepsilon^2(x) \right\} \\ &\quad + \Xi^T P B \varepsilon(x) = -\frac{1}{2} \lambda_{\min}(Q) \|\Xi\|^2 \\ &\quad + \left\{ \frac{\lambda_{\min}(Q)}{4\lambda_{\max}(P)} \Xi^T P \Xi + \frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)} B^T P B \varepsilon^2(x) \right\} \\ &\quad - \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(Q)}{\lambda_{\max}(P)}} \Xi - \sqrt{\frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)}} B \varepsilon \right)^T \\ &\quad P \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(Q)}{\lambda_{\max}(P)}} \Xi - \sqrt{\frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)}} B \varepsilon \right) \\ &\leq -\frac{1}{2} \lambda_{\min}(Q) \|\Xi\|^2 \\ &\quad + \left\{ \frac{\lambda_{\min}(Q)}{4\lambda_{\max}(P)} \Xi^T P \Xi + \frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)} B^T P B \varepsilon^2(x) \right\} \\ &\leq -\frac{1}{4} \lambda_{\min}(Q) \|\Xi\|^2 + \frac{\lambda_{\max}^2(P)}{\lambda_{\min}(Q)} \|B \varepsilon(x)\|^2 \end{aligned} \quad (25)$$

· 따라서 \dot{V} 는 콤팩트 집합

$$\|\mathcal{E}\| < 2 \frac{\lambda_{\max}(P)}{\lambda_{\min}(Q)} \|B\| \bar{\epsilon} \quad (26)$$

밖에서는 음이며, 확장오차는 \hat{W} 가 유계된 경우 콤팩트 집합의 안으로 수렴한다. 또 식 (26)에서 $\lambda_{\min}(Q)/\lambda_{\max}(P)$ 는 II시스템의 최대 감쇄율 (maximal decay rate)을 나타낸다. 즉 $\lambda_{\min}(Q)/\lambda_{\max}(P)$ 는 II의 고유치중에서 우세극점 (dominant pole)의 실수부의 반대 부호 값이다. 따라서 이 값은 K 과 σ 을 조절하여 원하는 만큼 크게 할 수는 있다. $\|B\|$ 과 $\bar{\epsilon}$ 는 고정되어 있으므로 $\lambda_{\min}(Q)/\lambda_{\max}(P)$ 을 크게 하여 확장오차는 원하는 수준으로 줄일 수 있다.

주의 1

(1) 정리 1의 CMAC 신경망 웨이트 학습 규칙 (20)을 다음의 식 (27)과 같이 투사규칙 (projection rule)^[7]을 이용하여 수정하면 학습오차 역시 유계되고 관련된 모든 신호는 유계된다.

$$\begin{aligned} \dot{\hat{W}} = P[\gamma \mathcal{E}^T PB \xi(x)] &= \gamma \mathcal{E}^T PB \xi(x) \\ &- I_W \gamma \frac{\mathcal{E}^T PB \hat{W}^T \xi(x)}{\|\hat{W}\|^2} \hat{W} \end{aligned} \quad (27)$$

여기서

$$I_W = \begin{cases} 0, & \text{if } \|\hat{W}\| < M_W \text{ or} \\ & \|\hat{W}\| = M_W \text{ and } \mathcal{E}^T PB \hat{W}^T \xi(x) \leq 0 \\ 1, & \text{if } \|\hat{W}\| = M_W \text{ and } \mathcal{E}^T PB \hat{W}^T \xi(x) > 0 \end{cases}$$

(2) 위의 식 (25)에서 양변을 시간 $t=0$ 에서 $t=T$ 사이로 적분하면

$$\begin{aligned} \int_{t=0}^T \|\mathcal{E}(t)\|^2 dt &\leq \frac{4}{\lambda_{\min}(Q)} [V(0) - V(T)] \\ &+ \left\{ \frac{2 \lambda_{\max}(P)}{\lambda_{\min}(Q)} \right\}^2 \int_0^T \|B\xi(t)\|^2 dt \end{aligned} \quad (28)$$

이고 즉 확장 오차의 확장 L_2 놈은 ϵ 의 확장 L_2 놈의 차원에 유계된다. $\epsilon \in L_2$ 인 경우, 식 (28)에 의해 $\mathcal{E} \in L_2$ 이고, 식 (21)에 의해 $\dot{\mathcal{E}} \in L_\infty$, $\mathcal{E} \in L_\infty$ 이고 $\hat{W} \in L_\infty$ 이므로 Barbalat의 정리에 의해

$$\lim_{t \rightarrow 0} \|\mathcal{E}(t)\| = 0. \quad (29)$$

4. CMAC 외란관측기와 기존의 적응퍼지/신경망 제어기와의 비교

기존의 적응퍼지/신경망 제어기는 크게 직접방식과 간접방식으로 나눌 수 있다. 우선 CMAC 외란관측방식을 간접방식과 비교하면, 간접방식의 경우 $a(x)$ 과 $\beta(x)$ 를 표현하기 위해 2개의 적응퍼지/신경망 시스템을 요구하였으나 제안된 CMAC 외란관측방식은 하나의 CMAC만을 필요로 한다. 또 직접방식과 비교하면 직접방식에서는 $\beta(x)$ 가 미지의 상수^[13]이거나 이미 정확한 함수^[13]어야 한다. 그러나 제안한 CMAC 외란관측기 방식은 $\beta(x)$ 에 대한 이러한 제약을 요구하지 않는다. 또 직접방식과 간접방식 모두와 비교할 때 제안한 CMAC 외란관측방식은 오차의 충분히 작은 집합으로의 수렴을 보이기 위해서 추가적인 교시제어기 (Supervisory controller)를 필요로 하지 않는다. 반면 기존의 적응퍼지/신경망 제어 방식은 수렴성을 보장하기 위해서 H^∞ 제어기^[13]나 슬라이딩 모드 제어기^[8], 포화형 제어기^[7]를 사용하였다.

IV. 컴퓨터 모의실험

본 장에서는 제안한 CMAC 외란관측시스템을 이용하여 유연관절 로봇을 제어하고 기존의 피드백 선형화 제어기와 제어성능을 비교하여 타당성을 보인다. 본 모의실험에 사용된 파라미터는 다음과 같다.

k (탄성계수) = 10 (Nm/rad)

M (링크의 질량)

g (중력가속도) = 9.8 (rad/sec²)

L (무게 중심) = 1 (m)

J_1 (링크의 관성) = ML^2

J_2 (액추에이터의 관성) = 0.2 (Kg · m²)

이때 유연관절 로봇이 추적하고자 하는 궤적은 다음과 같다고 한다.

$$q_d(t) = 0.5 \cos(2t) \quad (30)$$

본 모의실험에서는 사용한 외란관측기는 CMAC 신경망의 경우 각 변수 당 7개의 B-스프라인 함수를 이

용하여 중간노드를 형성하였고 학습률 γ 는 200, 외란관측기 파라미터 σ 는 50으로 하였고 $Q = diag(1, 1, 1, 1, 10)$ 으로 선정하였다. 또 제어기의 경우 $v = q_d^{(4)} - k_1(x_4 - q_d^{(3)}) - k_2(x_3 - q_d^{(2)}) - k_3(x_2 - \dot{q}_d) - k_4(x_1 - q_d)$ 을 사용하였고 $k_1 = 8$, $k_2 = 24$, $k_3 = 32$, $k_4 = 16$ 을 이용하였다. 제안한 CMAC 외란관측기의 강인한 추적 성능을 보이기 위하여 다음의 두 가지 경우를 고려 한다.

(i) 링크의 실제 질량은 1.3 Kg이지만 그 공칭값은 1Kg으로 한다.

(ii) 링크의 실제 질량은 1.3 Kg이지만 그 공칭값은 1Kg이며 외부에서 각주파수가 1 rad/sec이고 진폭이 10인 외란 ($d(t) = 10\text{sign}(\cos(t))$)의 영향을 준다.

<그림 4>와 <그림 5>는 (i)의 경우에 대한 결과이다. <그림 4>는 피드백 선형화 제어기를 이용한 로봇 제어 성능을 보이고 있다. 여기서 점선은 원하는 궤적을 나타내고 실선은 실제 제어 결과를 나타낸다. 링크 중량의 불확실성에 의해서 제어 궤적이 실제 원하는 궤적과 큰 차이가 있음을 알 수 있다. <그림 5>는 CMAC 외란관측기를 이용한 로봇의 제어 결과이다. 점선은 원하는 궤적을 나타내고 실선은 실제 제어 결과를 나타낸다. 이 경우도 실제 로봇의 궤적과 원하는 궤적과는 오차가 있지만 <그림 4>의 피드백 선형화 제어기와 그 결과를 비교할 때 제어 성능이 크게 향상되는 것을 볼 수 있다.

<그림 6>과 <그림 7>은 (ii)의 경우에 대한 결과이

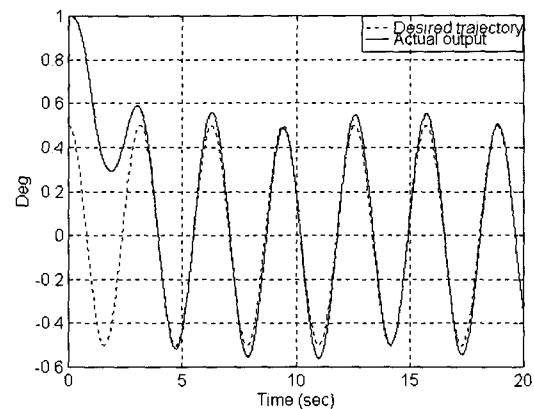


그림 5. CMAC 외란관측기 제어 결과((i)의 경우)
Fig. 5. Control result of CMAC disturbance observer (case (i)).

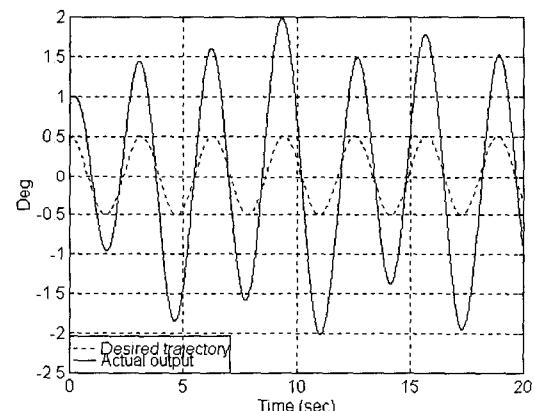


그림 6. 피드백 선형화 제어기의 제어 결과((ii)의 경우)
Fig. 6. Control result of feedback linearization controller(case (ii)).

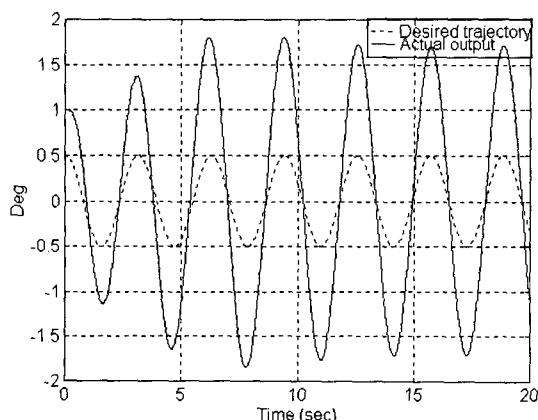


그림 4. 피드백 선형화 제어기의 제어 결과((i)의 경우)
Fig. 4. Control result of feedback linearization controller(case (i)).

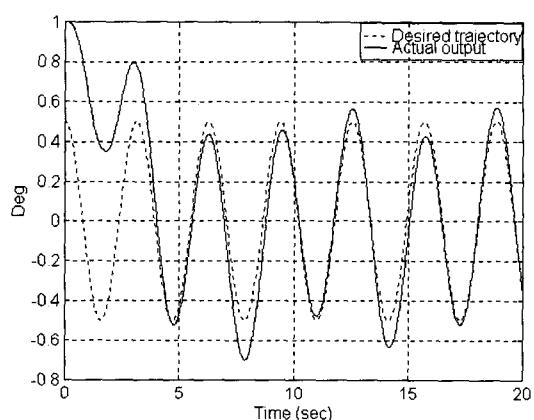


그림 7. CMAC 외란관측기 제어 결과((ii)의 경우)
Fig. 7. Control result of CMAC disturbance observer (case (ii)).

다. <그림 6>은 피드백 선형화 제어기를 이용한 로봇 제어 성능을 나타내며 <그림 7>은 CMAC 외란관측기를 이용한 제어 성능을 나타낸다. 이 경우도 CMAC 외란관측기를 이용한 제어가 완벽하지는 않지만 피드백 선형화 제어기와 비교할 때 강인한 추적제어의 성능을 보이는 것을 알 수 있다.

V. 결 론

이러한 유연관절 로봇의 제어기 설계에 있어서 외란이나 로봇의 불확실성의 영향을 줄이는 것은 대단히 중요한 일이고 이는 로봇의 제어 성능에 직접적인 영향을 미치는 중요한 문제이다. 본 논문에서는 CMAC 외란관측기를 이용하여 유연관절 로봇의 장인 추적 제어 알고리즘을 제안하였다. 우선 CMAC 신경망이 미지의 외란을 관측하도록 설계하였고 이를 제어에 적용하여 전체 폐루프 시스템의 제어 성능을 향상시켰다. 또 제안한 CMAC 외란관측시스템의 안정성을 이론적으로 보였다.

제안한 CMAC 외란 관측 방식은 제어오차와 외란관측오차를 모두 원하는 수준까지 줄일 수 있는 방식으로 유연관절 로봇 시스템의 제어 이외에도 비슷한 구조를 갖는 다른 시스템의 제어에도 사용될 수 있다.

참 고 문 헌

- [1] M. Spong, "Modeling and control of elastic joint robots," *J. Dynamic Syst., Meas., Contr.*, vol. 109, pp. 310-319, Dec. 1987.
- [2] J. J. E. Slotine and S. S. Sastry, "Tracking control of nonlinear systems using sliding surface with application to robot manipulator," *Int. J. Control.*, vol. 38, pp. 465-492, 1983.
- [3] S. Lim, D. Dawson and K. Anderson, "Re-examining the Nicosia-Tomei robot observer-controller from a backstepping perspective," *IEEE Trans. Contr. Sys. Tech.*, vol. 4, no. 3, pp. 304-310, 1996.
- [4] C. Y. Su, T. P. Leung, and Y. Stepanenko, "Real-time implementation of regressor-based sliding mode control algorithm for robotic manipulator," *IEEE Trans. Ind. Electron.*, vol. 40, no. 1, pp. 71-79, 1993.
- [5] B. Brogliato, R. Ortega and R. Lozano, "Global tracking controller for flexible joint manipulators: A comparative study," *Automatica*, vol. 31, no. 7, pp. 941-956, 1995.
- [6] T. Umeno, T. Kaneko and Y. Hori, "Robust servosystem design with two degrees of freedom and its application to novel motion control of robot manipulators," *IEEE Trans. Ind. Electron.*, vol. 40, no. 5, pp. 473-486, 1993.
- [7] L.-X. Wang, *A Course in Fuzzy Systems and Control*, NJ: Prentice-Hall, 1997.
- [8] R. Ordóñez and K. M. Passino, "Stable multi-input multi-output adaptive fuzzy/neural control," *IEEE Trans. Fuzzy Systems*, vol. 7, no. 3, pp. 345-353, Jun., 1999.
- [9] C. T. Chiang, and C. S. Lin, "CMAC with general basis functions," *Neural Networks*, vol. 9, no. 7, pp. 1199-1211, 1996.
- [10] S. H. Lane, D. A. Handelman, and J. J. Gelfand, "Theory and development of higher-order CMAC neural networks," *IEEE Contr. Syst. Mag.*, pp. 23-30, 1992.
- [11] Y. Kim and F. L. Lewis, "Optimal design of CMAC neural-network controller for robot manipulators," *IEEE Trans. Sys. Man and Cyber.-Part C: Appl. and Rev.*, vol. 30, no. 1, pp. 22-31, 2000.
- [12] M. Spong and M. Vidyasagar, *Robot Dynamics and Control*, Wiley:NY, 1989.
- [13] B. S. Chen, C. H. Lee and Y. C. Chang, " H^∞ tracking design of uncertain nonlinear SISO systems: adaptive fuzzy approach," *IEEE Trans. Fuzzy Systems*, vol. 4, no. 1, pp. 32-43, Feb., 1996.

저자소개



金 殿 泰(正會員)

1992년 2월 : 연세대학교 전자공학
과 졸업(공학사). 1994년 2월 : 연
세대학교 전자공학과 석사과정 졸
업(공학석사). 1999년 2월 : 연세대
학교 전자공학과 박사과정 졸업
(공학박사). 1999년 3월 ~ 2002년 2
월 : 국립한경대학교 제어계측공학과 조교수. 2002년 3
월 ~ 현재 : 연세대학교 전기전자공학부 조교수. 1998
년 ~ 현재 : IEEE TFS, IEEE SMC, IEEE CAS, FSS 등
에서 심의위원으로 활동중. <주관심분야 : Computa-
tional intelligence, 지능형 서비스로보틱스>