

로봇 매니퓰레이터의 실시간 적응 제어

이민중*, 최영규, 김성신
부산대학교, 전기공학과

On-line Adaptive Control for Robot Manipulators

Min-Jung Lee*, Young-Kiu Choi, Sungshin Kim
Dep. of Electrical Eng. Pusan National University

Abstract - In this paper, we propose an adaptive controller using RBFN(radial basis function network) for robot manipulators. The structure of the proposed controller consists of a RBFN and a fixed gain PD controller. On the basis of the Lyapunov stability theorem, we guarantee the UUB (uniformly ultimately boundedness) for the total system. And the learning law of RBFN is established by the Lyapunov method.

Finally, we apply the proposed controller to tracking control for the 2 link SCARA type robot manipulator.

1. 서 론

산업용 로봇은 비선형성이 강한 시스템으로 기존에 사용되고 있는 제어기는 부하가 변동하는 경우나 외란이 존재할 때에 좋은 성능을 기대하기 어렵다. 그래서 부하변동이나 외란이 존재할 경우에도 만족스러운 성능을 얻기 위한 목적으로 적응 제어 (adaptive control) 기법이 제안되었다[1,2]. 그러나 적응 제어는 로봇 매니퓰레이터의 알 수 없는 파라미터(unknown parameter)에 관한 선형성 (linearity)과 역대칭(skew-symmetry) 특성 등의 사전 지식을 필요로 하고, regression 행렬 계산에 많은 시간이 소요된다. 위와 같은 문제점을 해결하기 위해서, 최근, 지능 제어 기법을 이용하여 실시간 적응 제어기 설계에 관하여 많은 연구가 되고 있다[3-8].

지능제어 기법의 한 종류인 신경회로망은 학습능력을 가지고 있으므로 시스템 동조, identification-based (indirect) 제어기, 그리고 direct closed-loop 제어기로 많이 사용되고 있다. 최근에는 RBFN 구조가 다층 신경회로망에 비해 구조가 간단하고, 빠른 수렴성의 특징을 갖고 있기 때문에 시스템의 동조와 제어기로 많이 사용되고 있다.

본 논문에서는 RBFN의 장점을 이용하여 플랜트의 불확실성과 외란이 존재할 때 로봇 매니퓰레이터의 성능을 향상시키기 위해서 적응제어기를 설계하고자 한다. 본 논문에서 제안된 제어기의 구조는 고정 이득 PD 제어기와 RBFN 제어기를 병렬로 연결한 구조를 사용하였다. 그리고 Lyapunov 안정도 이론을 근거로 하여 외란과 RBFN의 모델링 오차가 존재하는 상황하에서 궤적 추종 오차의 UUB를 보장하였다. 또한 본 논문에서는 로봇 매니퓰레이터를 제어하는 동안의 전체 안정도를 보장하면서 RBFN의 파라미터들을 실시간으로 학습시키기 위해서 Lyapunov 안정도 방법으로 학습규칙을 세웠다.

그리고 시뮬레이션을 통하여 제안된 제어기 성능의 우수성과 강인성을 확인하였다.

2. 로봇 매니퓰레이터

n 자유도 로봇 매니퓰레이터의 Euler-Lagrangian 동

역학식은 다음과 같다.

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

여기서 $q \in R^n$ 은 일반화된 좌표축(각 링크의 위치)을 나타내고, $D(q) \in R^{n \times n}$ 은 대칭이고, 양의 한정인 관성 행렬이다. 그리고, 벡터 $C(q, \dot{q}) \in R^n$ 은 코리올리력과 원심력을 나타내고, $G(q) \in R^n$ 은 중력 성분을 나타낸다. 또한 $\tau_d \leq b_d \in R^n$ 과 $\tau \in R^n$ 은 각각 외란 토크와 각 링크에 인가되는 토크를 나타낸다.

로봇 매니퓰레이터의 동역학은 다음과 같은 구조적인 성질을 가지고 있다.

성질 1 : 관성행렬 D는 대칭(symmetric)이고, 양의 한정(positive definite)이다.

성질 2 : $D - 2C$ 는 역 대칭이다. 그러므로 식(1)에 $D(q)$ 와 $C(q, \dot{q})$ 의 관계는 다음을 만족한다.

$$x^T(D - 2C)x = 0, \forall x \in R^n$$

성질 3 : 식(2)와 같이 로봇 매니퓰레이터의 파라메터들(질량 등)에 의존하는 벡터 $\theta \in R^r$ 이 존재한다.

$$D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = Y(q, \dot{q}, \ddot{q})\theta = \tau \quad (2)$$

여기서 $Y(q, \dot{q}, \ddot{q}) \in R^n \times r$ 은 시간의 함수인 regressor이고, θ 는 파라메터 벡터이다.

3. 적응 제어기 설계

3.1 RBFN

RBFN은 Moody, Darken, Powell, Broomhead, 와 Lowe 등이 제안하였으며, 다층 신경회로망에 비하여 빠른 수렴속도를 갖고 있으므로 비선형 함수의 근사에 많이 사용하고 있다. 또한 RBFN은 FIS(fuzzy inference system)과 구조적으로 3가지의 비슷한 특징을 가지고 있다. 첫 번째 특징은 RBFN의 출력값은 퍼지의 Sugeno 방법과 비슷한 가중치 합과 가중치의 평균 형태로 구할 수 있다. 두 번째 특징은 RBFN의 은닉층은 FIS의 if-then 규칙에 해당된다. 그리고 세 번째 특징은 radial basis function은 FIS의 멤버쉽 함수와 유사하다[9]. 그림 1은 RBFN의 구조를 나타낸다.

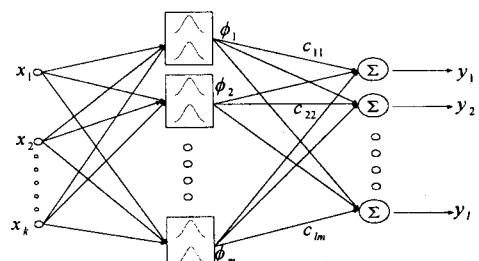


그림 1. RBFN의 구조

RBFN의 은닉층과 출력층으로 구성되어 있으며, 은닉층의 뉴우런 수는 제어기 설계자에 의해서 결정된다. 그리고 일반적으로 은닉층의 기저함수는 Gaussian 함수를 많이 사용한다.

본 논문에서도 기저함수로 Gaussian 함수를 사용하였고, RBFN의 출력은 가중치 합을 사용하여 식(3)과 같이 구하였다.

$$y_i = \sum_{j=1}^m c_{ij} \phi_j, \quad i = 1, 2, \dots, l \quad (3)$$

$$\phi_j(x) = \exp\left(-\frac{\|x - u_j\|^2}{\sigma^2}\right)$$

여기서 m 과 l 은 각각 은닉층 뉴우런의 수와 출력의 수를 나타낸다. 그리고 c_{ij} 는 j 번째 은닉층 뉴우런에서 i 번째 출력사이의 가중치를 나타내고, $\phi_j(x)$ 는 j 번째 기저함수이다. $\sigma \in R^n$ 은 j 번째 표준편차이다.

은닉층에 m 개의 뉴우런을 갖고 있는 RBFN을 이용하여 비선형 함수를 근사화 하면 식(4)와 같이 나타낼 수 있다.

$$f = \Phi(x)c + \varepsilon \quad (4)$$

여기서

$$f = [f_1 \ f_2 \ \dots \ f_l]^T, \quad \Phi = [\phi_1 \ \phi_2 \ \dots \ \phi_m]$$

$$c = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1m} \\ c_{21} & c_{22} & \dots & c_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ c_{l1} & c_{l2} & \dots & c_{lm} \end{bmatrix}$$

그리고 식(4)에서 ε 은 최소 근사 오차(minimum approximation error) 나타낸다. 근사 이론에서 ε 은 0이 아니지만 매우 작은 값을 갖는다. 그러므로 이미 알고 있는 값으로 근사 오차의 upper bound를 다음과 같이 설정할 수 있다[5,6].

$$\|\varepsilon\| < \varepsilon_N \quad (5)$$

3.2 RBFN을 이용한 적응 제어기

본 논문에서 제안된 제어기는 PD 제어기와 RBFN이 병렬로 연결된 구조를 가지고 있다. 그림 2는 제안된 제어기의 구조를 나타낸다.

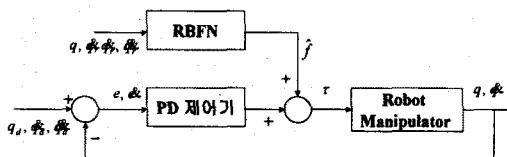


그림 2. 제안된 제어기의 구조

그리고 본 논문에서는 RBFN의 파라미터들을 실시간으로 학습을 시키기 위해 Lyapunov 안정도 방법을 사용하였다.

기준제적 $q_d(t) \in R^n$ 이 주어졌을 때 궤적오차는 다음과 같다.

$$\tilde{q} = q_d(t) - q(t) \quad (6)$$

그리고 필터링(filtering)된 궤적오차와 로봇 매니퓰레이터의 제어입력을 각각 식(7)과 (8) 같이 정의하였다.

$$s = \dot{q} + \Lambda \tilde{q} = \dot{q}_r - \dot{q} \quad (7)$$

$$\tau = \Phi(x) \hat{c} + K_s \quad (8)$$

$$\text{여기서 } \dot{q}_r = q_d + \Lambda \tilde{q}, \quad \Lambda = \Lambda^T > 0, \quad K_s > 0$$

전체 시스템의 안정성을 보장하기 위해서 Lyapunov 후보함수를 다음과 같이 정의하였다.

$$V = \frac{1}{2} (s^T D s + \tilde{c}^T \Gamma^{-1} \tilde{c}) \quad (9)$$

여기서 \tilde{c} 는 최적의 파라미터 c^* 와 추정된 파라미터 \hat{c} 사이의 오차를 나타낸다.

식(9)을 미분하여, 로봇 매니퓰레이터의 성질 2를 이용하여 정리하면 다음과 같다.

$$\dot{V} = s^T D s + \frac{1}{2} s^T D s + \hat{c}^T \Gamma^{-1} \tilde{c}$$

$$= s^T [D \ddot{q}_r + C \dot{q}_r + G + \tau_d] - \varepsilon + \hat{c}^T \Gamma^{-1} \tilde{c} \quad (10)$$

식(10)에서 로봇 매니퓰레이터의 성질 3을 이용하면 다음과 같이 나타낼 수 있다.

$$\dot{V} = s^T [Y(q, \dot{q}, \ddot{q}_r, \ddot{q}_d) \theta - \varepsilon + \tau_d] + \hat{c}^T \Gamma^{-1} \tilde{c} \quad (11)$$

식(11)에서 $Y(q, \dot{q}, \ddot{q}_r, \ddot{q}_d) \theta$ 를 실시간으로 추종하기 위해서 RBFN을 사용하고자 한다. 그래서 regressor를 식(12) 같이 정의한다.

$$Y(q, \dot{q}, \ddot{q}_r, \ddot{q}_d) \theta = \Phi(x) c^* + \varepsilon \quad (12)$$

식 (8)과 (12)를 이용하여 식 (11)을 정리하면 다음과 같다.

$$\dot{V} = s^T [\Phi(x) c^* + \varepsilon - \{\Phi(x) \hat{c} + K_s\} + \tau_d] + \hat{c}^T \Gamma^{-1} \tilde{c}$$

$$= s^T \Phi(x) \tilde{c} + s^T (\varepsilon + \tau_d) + \hat{c}^T \Gamma^{-1} \tilde{c} - s^T K_s \quad (13)$$

그리고 식(13)에서 RBFN 파라미터들의 학습규칙을 식(14)와 같이 정의하면, 식(13)은 식(15)이 된다.

$$\hat{c} = -\Gamma \Phi^T s \quad (14)$$

$$\dot{V} = s^T (\varepsilon + \tau_d) - s^T K_s \quad (15)$$

식 (15)에서 근사오차를 식 (5)과 같이 대치하고, 외란의 upper bound b_d 로 대치하면

$$\begin{aligned} \dot{V} &= s^T (\varepsilon + \tau_d) - s^T K_s \\ &\leq (\varepsilon_N + b_d) \|s\| - K_{\min} \|s\|^2 \end{aligned} \quad (16)$$

$$\text{여기서 } K_{\min} = \lambda_{\min}(K)$$

식 (16)에서 $\varepsilon_N + b_d$ 의 값이 상수이기 때문에 부등식(17)을 만족하면 항상 부등식 (18)이 성립된다.

$$\|s\| > (\varepsilon_N + b_d)/K_{\min} \quad (17)$$

$$\dot{V} \leq 0 \quad (18)$$

식 (18)은 필터링된 궤적 추종 오차 s 는 UUB(uniformly ultimately bounded)된다.

4. 시뮬레이션 및 결과

본 연구에서 제안하는 제어기의 우수성을 보이기 위해 그림 3과 같은 수평 다관절 매니퓰레이터(SCARA type)에 적용한다.

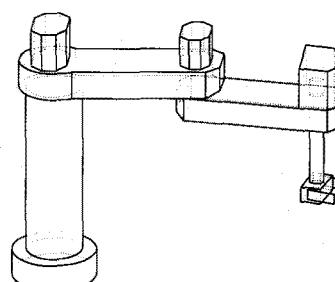


그림 3. SCARA 로봇 매뉴플레이터

시뮬레이션을 위해 로봇 매니퓰레이터의 1축과 2축에 대한 동력학 방정식을 Lagrangian formulation을 이용하여 구하면 식(13)과 같다. 그리고 로봇 매니퓰레이터

이터의 파라메터 값은 $m_1 = 10.71[\text{kg}]$, $m_2 = 9.65[\text{kg}]$, $l_1 = 0.35[\text{m}]$ 그리고 $l_2 = 0.26[\text{m}]$ 이다. 토오크의 최대값은 1축과 2축 각각 $\tau_{1\max} = 80[\text{Nm}]$ 그리고 $\tau_{2\max} = 50[\text{Nm}]$ 이다.

$$\tau = D(\theta) \dot{\theta} + C(\theta, \dot{\theta}) \quad (19)$$

$$\text{단. } \tau = \begin{bmatrix} \tau_1 \\ \tau_2 \end{bmatrix}, \quad \dot{\theta} = \begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix}$$

$$C(\theta, \dot{\theta}) = \begin{bmatrix} -m_2 l_1 l_2 \sin \theta_2 \dot{\theta}_1 - \frac{1}{2} m_2 l_1 l_2 \sin \theta_2 \dot{\theta}_2^2 \\ \frac{1}{2} m_2 l_1 l_2 \sin \theta_2 \dot{\theta}_2^2 \end{bmatrix}$$

$$D(\theta) = \begin{bmatrix} \frac{1}{3} m_1 l_1^2 + \frac{1}{3} m_2 l_2^2 + m_2 (l_1^2 + l_1 l_2 \cos \theta_2) & \frac{1}{3} m_2 l_2^2 + \frac{1}{2} m_2 l_1 l_2 \cos \theta_2 \\ \frac{1}{3} m_2 l_2^2 + \frac{1}{2} m_2 l_1 l_2 \cos \theta_2 & \frac{1}{3} m_2 l_2^2 \end{bmatrix}$$

그림 4는 로봇 매니퓰레이터의 기준궤적을 각각 $q_{d1} = \sin(0.5t)[\text{rad}]$ 과 $q_{d2} = \sin(0.5t)[\text{rad}]$ 으로 주었을 때 궤적 추종 오차를 나타내었다. 그림 4에서 제안된 제어기의 경우, 학습 초기에는 궤적 오차 값이 진동한다. 그러나 학습이 진행되는 동안 오차 값이 PD 제어기에 비해 작은 값을 갖는 것을 볼 수 있다.

그리고 그림 5는 기준궤적의 주파수를 2배 빠르게 하였을 때 궤적 추종 오차를 나타내었다. 그림 5에서 실시간으로 학습을 함으로써 제안된 제어기의 궤적 오차 값이 PD 제어기의 궤적 오차보다 값이 작음을 알 수 있다.

마지막으로 그림 6은 외란을 인가하였을 때 궤적 추종 오차를 나타내었다. PD 제어기의 경우 궤적 추종오차의 값이 외란의 영향을 많이 받고있다. 그러나 제안된 제어기의 경우 외란이 인가 되었을 때 RBFN의 학습에 의해서 예의 값이 작아지는 것을 보여준다.

5. 결론

본 논문은 실시간으로 동적환경변에 적응할 수 있도록 RBFN을 이용하여 제어기를 설계하였다. 본 논문에서 제안하는 제어기는 RBFN의 학습초기에는 제어입력을 보상하기 위해서 고정 이득 PD 제어기를 별별로 연결하였다. 그리고 실시간을 RBFN을 학습시키기 위해서 Lyapunov 안정도 이론을 근거하여 학습규칙을 세웠다. 또한 전체시스템의 제어가 되는 동안 필터링된 궤적오차의 값이 UUB가 됨을 보였다. 마지막으로 시뮬레이션 결과로 제안된 제어기가 명령입력이 변화된 환경 하에서도 우수한 성능을 보여주었다.

(참 고 문 헌)

- [1] J.-J. E. Slotine and W. Li, *Applied Nonlinear Control*, Prentice Hall, 1991
- [2] F.L. Lewis, C. T. Abdallah, and D. M. Dawson, *Control of Robot Manipulators*, Macmillian Publishing Company, 1993.
- [3] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. on Neural Networks*, vol. 1, no. 1, pp. 4-27, March, 1990.
- [4] A. S. Morris and S. Khemaissia, "A neural network based adaptive robot controller," *Journal of Intelligent and Robotic Systems*, vol. 15, pp. 3-10, 1996.
- [5] Frank L. Lewis, Kai Liu, and Aydin Yesildirek, "Neural Net Robot Controller with Guaranteed Tracking Performance," *IEEE Trans. Neural Networks*, vol. 6, no. 3, May, 1995.
- [6] Li-Xin Wang, "Stable Adaptive Fuzzy Controllers with Application to Inverded Pendulum

Tracking," *IEEE Trans. Systems, Man, and Cybernetics-Partb: Cybernetics*, vol. 26, no. 5, October, 1996.

- [7] R. M. Sanner and J.-J.E. Slotine, "Gaussian Networks for Direct Adaptive Control," *IEEE Trans. Neural Networks*, vol. 3, no. 6, November, 1992.
- [8] Li-Xin Wang, *Adaptive Fuzzy Systems and Control : Design and Stability Analysis*, Prentice Hall, 1994.
- [9] J.-S.R. Jang, C.-T.Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice Hall, 1997.

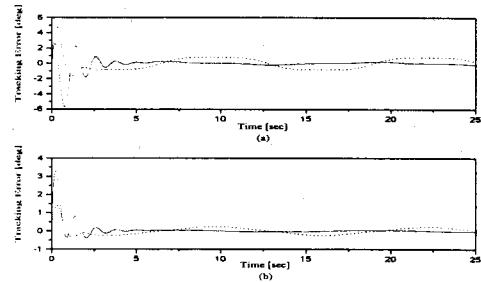


그림 4. 기준궤적이 $q_d = \sin(0.5t)$ 일 때 궤적 추종 오차. (a) 1축 (b) 2축

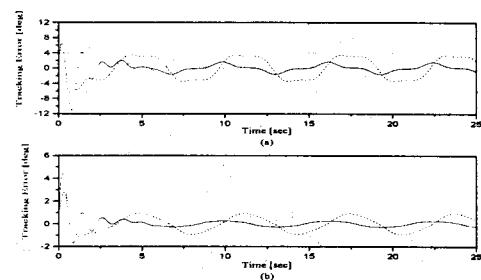


그림 5. 기준궤적이 $q_d = \sin(t)$ 일 때 궤적 추종 오차. (a) 1축 (b) 2축

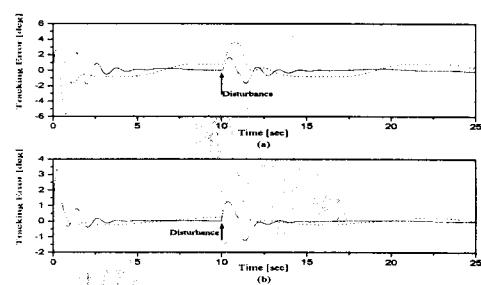


그림 6. 외란이 존재할 때 궤적 추종 오차