

Neuro-Adaptive Control of Robot Manipulator Using RBFN

金 正 大^{*} · 李 敏 中^{**} · 崔 榮 奎^{***} · 金 成 信^{\$}
 (Jung-Dae Kim · Min-Jung Lee · Young-Kiu Choi · Sung-shin Kim)

Abstract – This paper investigates the direct adaptive control of nonlinear systems using RBFN(radial basis function networks). The structure of the controller consists of a fixed PD controller and a RBFN controller in parallel. An adaptation law for the parameters of RBFN is developed based on the Lyapunov stability theory to guarantee the stability of the overall control system. The filtered tracking error between the system output and the desired output is shown to be UUB(uniformly ultimately bounded). To evaluate the performance of the controller, the proposed method is applied to the trajectory control of the two-link manipulator.

Key Words : Adaptive Control, Radial Basis Function Network, Uniformly Ultimately Bounded

1. 서 론

산업용 로봇은 비선형성이 강한 시스템이므로 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]. 그러나 적용 제어는 로봇 매니퓰레이터(robot manipulator)의 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, 최근에는 신경 회로망 등의 지능제어기법을 이용하여 시스템 동역학(dynamics)에 대한 자세한 사전 지식 없이도 시스템의 부하변동이나 외란 등에 강인한 제어기에 대한 연구를 많이 하고 있다 [2-8].

로봇 매니퓰레이터의 궤적 제어에 적용되고 있는 RBFN (radial basis function networks)은 기존의 다층 신경 회로망 (multi-layer neural networks)에 비해서 구조가 간단한 특성을 가지고 있고, FIS (fuzzy inference system)과 비슷한 구조를 가지고 있다. 그러나 기존의 RBFN을 사용한 제어기는 안정성을 보장할 때 외란과 RBFN의 모델링 오차를 고려하지 않고, RBFN의 세 가지 파라미터(가중치, 중심값, 표준편차) 중 가중치만을 학습하고 있다 [9-13].

본 논문에서 제안하는 제어기는 고정 이득 PD 제어기와

RBFN 제어기를 병렬로 연결한 구조를 가지고 있다. PD 제어기는 RBFN이 초기 학습되는 시간동안 시스템을 적절히 제어하기 위해 사용되며, RBFN이 학습되고 난 후에는 그 역할은 줄어들게 된다. 그리고 외란과 RBFN의 모델링 오차가 존재하는 상황下에서 전체 제어 시스템의 안정성과 궤적 추종 오차의 UUB(uniformly ultimately boundedness)를 보장한다.

그리고 본 논문에서는 RBFN이 파라미터 불확실성 (parameter uncertainty)등에 대해 적응하도록 실시간으로 학습되며, 학습되는 동안 전체 제어 시스템의 안정도(stability)를 보장하기 위해서 Lyapunov 안정도 이론에 근거하여 가중치 (weight) 와 basis function의 중심값(center)과 표준 편차 (standard deviation)의 학습 규칙을 구하였다.

본 논문은 다음의 순서로 구성하였다. 2절에서는 로봇 동역학이 가지는 특성들에 대해 논하였고, 3절에서는 논문에서 사용하고 있는 RBFN을 소개하고, 제안된 제어기인 신경망 적응 제어기를 설계하였다. 그리고 제어기의 효율성을 입증하기 위해서 4절에서는 2 자유도를 가지는 로봇 매니퓰레이터의 궤적 추적 제어에 적용하여 그 성능을 보였다. 마지막으로 5절에서는 결론을 내렸다.

2. 로봇 동역학

n 자유도를 가지는 로봇 매니퓰레이터의 동역학은 Euler-Lagrange 방정식을 통하여 다음과 같이 표현된다 [14,15].

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

여기서 $\boldsymbol{q}(t) \in \mathbb{R}^n$ 는 관절의 각(joint angle), $D(\boldsymbol{q}) \in \mathbb{R}^{n \times n}$ 는 관성 행렬(inertia matrix), $C(\boldsymbol{q}, \dot{\boldsymbol{q}}) \dot{\boldsymbol{q}} \in \mathbb{R}^n$ 는 Coriolis force

* 正會員 : (주)코웨일 시스넷 개발부

** 正會員 : 釜山大 電氣工學科 博士課程

*** 正會員 : 釜山大 電子電氣情報컴퓨터工學部 教授 · 工博

§ 正會員 : 釜山大 電子電氣情報컴퓨터工學部 助教授 · 工博

接受日字 : 2000年 3月 13日

最終完了 : 2000年 12月 5日

와 원심력(centripetal force), 그리고 $G(\dot{q}) \in R^n$ 는 중력(gravity)이다. 또한 $\tau_d \in R^n$ 는 외란(disturbance), $\tau \in R^n$ 는 토크(torque)를 나타낸다. 식(1)의 동역학은 다음과 같은 유용한 특성을 가지고 있다.

특성 1 : 관성 행렬 $D(\dot{q})$ 는 대칭(symmetric)이며 양의 한정(positive definite) 행렬이다.

특성 2 : 행렬 $D(\dot{q}) - 2C(\dot{q}, \ddot{q})$ 는 역대칭(skew-symmetric)이며 $x^T(D(\dot{q}) - 2C(\dot{q}, \ddot{q}))x = 0$ 이다.

특성 3 : 동역학식은 로봇 매니퓰레이터의 파라메터에 대해 선형관계가 있다. 그러므로 식(1)은 다음과 같이 다시 표현할 수 있다.

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

여기서 $Y(\dot{q}, \ddot{q}, \ddot{q}) \in R^{n \times r}$ 는 regressor라고 불리는 알고 있는 시간 함수이며, $\theta \in R^r$ 는 알 수 없는 파라메터로 이루어진 벡터이다.

3. 제어기 설계

3.1 Radial Basis Function Networks

RBFN은 Moody, Darken, Powell, Broomhead와 Lowe등에 의해 제안되었으며, 오차 역전파 학습 규칙(error back-propagation algorithm)을 사용하는 다층 퍼셉트론(multi-layer perceptron)에 비해 수렴 속도가 빠르고 간단한 구조를 가지고 있다. 그리고 RBFN은 FIS와 다음과 같은 면에서 유사한 특징을 가지고 있다. 첫째, RBFN과 FIS는 출력을 얻기 위한 방법으로 가중치 합이나 가중치 평균 방법을 사용한다. 둘째, RBFN의 은닉층 노드 수는 FIS에서의 if-then 규칙(rule)의 수와 같다. 셋째, RBFN의 은닉층 노드에 사용되는 radial basis function은 FIS의 퍼지 규칙 전건부(premise part)의 소속 함수(membership function)와 동일하다 [16].

그림 1은 4개의 노드(node)를 가지는 RBFN의 구조를 나타내었다. 그림 1에서 알 수 있는 것과 같이 RBFN은 은닉층(hidden layer)과 출력층(output layer)의 두 개의 층으로 구성되어 있으며, 은닉층의 노드 수는 사용자에 의해서 결정된다. 일반적으로 사용되는 basis function은 Gaussian 함수, Triangular 함수, Trapezoidal 함수 등이 있으며, Gaussian 함수를 많이 사용하고 있다.

본 논문에서는 basis function으로 Gaussian 함수를 사용하였고, 가중치 합(weighted sum)의 방법을 사용하여 RBFN의 출력을 구하였다. RBFN의 j 번째 출력은 다음과 같다.

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

$$\phi_i(x) = \exp\left(-\frac{\|x - u_i\|^2}{\sigma_i^2}\right) \quad (4)$$

여기서 m 은 노드 수, l 은 출력 수, y_j 는 출력층 j 번째 노드에서의 출력이며, c_{ij} 는 RBFN의 가중치, 그리고 $\phi_i(x)$ 는 은닉층 i 번째 노드에서의 출력이며, $u_i \in R^n$ 는 중심 벡터, $\sigma_i \in R^1$ 은 표준 편차이다.

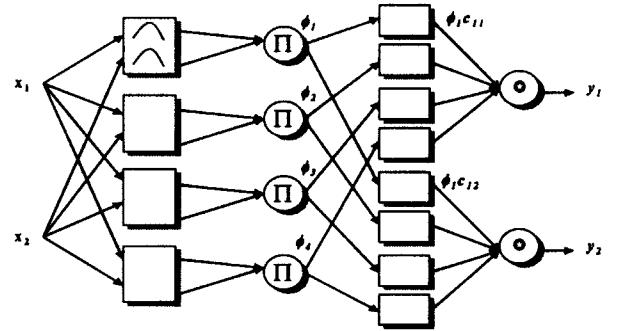


그림 1 RBFN의 구조

Fig. 1 Structure of RBFN

m 개의 노드를 가지는 RBFN을 사용하여 입력이 $x \in R^n$, 출력이 $y \in R^l$ 인 시스템을 모델링한 결과는 다음과 같다.

$$y = c^T \phi + \epsilon \quad (5)$$

여기서 $y = [y_1 \ y_2 \ \dots \ y_l]^T$, $\phi = [\phi_1 \ \phi_2 \ \dots \ \phi_m]^T$,

$$\epsilon = [\epsilon_1 \ \epsilon_2 \ \dots \ \epsilon_l]^T, \quad c^T = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ c_{l1} & c_{l2} & \dots & c_{lm} \end{bmatrix}$$

식(5)에서 ϵ 은 RBFN을 사용하여 시스템을 근사화(approximation) 할 때 근사 오차를 나타낸다. 그리고 approximation theory에 의하면 ϵ 은 0이 아니지만 일반적으로 매우 작은 값을 갖는다[17,18].

3.2 신경망 적용 제어기

본 논문에서는 Lyapunov 안정도 이론을 이용하여 전체 제어시스템의 안정도를 보장하였고, RBFN의 파라메터들을 실시간으로 학습시키기 위해 학습규칙을 설계하였다.

기준입력 $q_d \in R^n$ 가 주어지고 궤적추종오차를 식(6)과 같이 정의하였을 때

$$e = q_d - q \quad (6)$$

필터링된 궤적오차는 다음과 같다.

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

여기서 $\dot{q}_r = \ddot{q}_d + \Lambda e$, $\Lambda = \Lambda^T > 0$.

그리고 본 논문에서 제안된 제어입력과 Lyapunov 안정도 이론에 근거한 학습규칙은 다음과 같다.

$$\tau = \hat{c}^T \phi + K_d s \quad (8)$$

$$\hat{c} = \Gamma_1 \phi s^T \quad (9)$$

$$\hat{u} = -\alpha \Gamma_2 \|s\| \hat{u} \quad (10)$$

$$\hat{\sigma} = -\beta \Gamma_3 \|s\| \hat{\sigma} \quad (11)$$

여기서 K_d 와 $\Gamma_1, \Gamma_2, \Gamma_3$ 는 대각, 대칭인 양의 한정 행렬이며, α, β 는 양의 실수이다. 그리고 식(9), (10), (11)은 각각 RBFN의 파라메터 가중치, 중심값, 표준 편차의 학습 규칙이다.

본 논문에서 제안하는 전체 제어기구조는 그림 2에서 나타내었다.

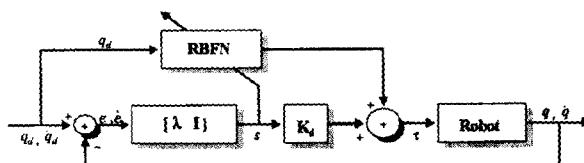


그림 2 제안된 제어기의 구조

Fig. 2 Structure of the proposed controller

전체 제어 시스템의 안정도를 보장하고, RBFN의 파라메터 가중치, 중심값, 표준 편차의 학습 규칙을 구하기 위한 Lyapunov 후보 함수를 다음과 같이 정의한다.

$$V = \frac{1}{2} s^T D s + \frac{1}{2} \text{tr}(\hat{c}^T \Gamma_1^{-1} \hat{c}) + \frac{1}{2} \text{tr}(\hat{u}^T \Gamma_2^{-1} \hat{u}) + \frac{1}{2} \text{tr}(\hat{\sigma}^T \Gamma_3^{-1} \hat{\sigma}) \quad (12)$$

여기서 $\tilde{c} = c^* - \hat{c}$ 은 최적의 가중치 c^* 과 추종한 가중치 \hat{c} 과의 오차이고, $\tilde{u} = u^* - \hat{u}$, $\tilde{\sigma} = \sigma^* - \hat{\sigma}$ 는 basis function의 중심값 오차와 표준편차 오차이다.

로봇 동역학 식(1)은 다음과 같이 유도된다.

$$D\dot{s} = D\ddot{q}_r - D\dot{q} = D\ddot{q}_r + C\dot{q}_r + \tau_d - \tau - Cs \quad (13)$$

식(12)를 시간에 대해 미분한 뒤 식(13)을 대입하여 정리하면 아래와 같다.

$$\begin{aligned} \dot{V} &= s^T (D\ddot{q}_r + C\dot{q}_r + \tau_d - \tau) - \text{tr}(\hat{c}^T \Gamma_1^{-1} \hat{c}) \\ &\quad - \text{tr}(\hat{u}^T \Gamma_2^{-1} \hat{u}) - \text{tr}(\hat{\sigma}^T \Gamma_3^{-1} \hat{\sigma}) \end{aligned} \quad (14)$$

식(14)에서 $y = D\ddot{q}_r + C\dot{q}_r$ 을 RBFN으로 근사화 시키면 $y = c^* \phi + \epsilon$ 와 같이 나타낼 수 있다. 그리고 신경망 적용 제어기의 제어입력을 식(8)과 같이 설계하면 다음과 같다.

$$\begin{aligned} \dot{V} &= -s^T K_d s + \text{tr}(\hat{c}^T (\phi s^T - \Gamma_1^{-1} \hat{c})) \\ &\quad + s^T (\tau_d + \epsilon) - \text{tr}(\hat{u}^T \Gamma_2^{-1} \hat{u}) - \text{tr}(\hat{\sigma}^T \Gamma_3^{-1} \hat{\sigma}) \end{aligned} \quad (15)$$

여기서, RBFN의 파라메터 가중치 \hat{c} , 중심값 \hat{u} , 그리고 표준 편차 $\hat{\sigma}$ 를 식(9), (10), (11)과 같이 변화시키면 식 (15)는 다음과 같다.

$$\begin{aligned} \dot{V} &= -s^T K_d s + s^T (\tau_d + \epsilon) + \alpha \|s\| \text{tr}(\hat{u}^T (u^* - \hat{u})) \\ &\quad + \beta \|s\| \text{tr}(\hat{\sigma}^T (\sigma^* - \hat{\sigma})) \end{aligned} \quad (16)$$

$$\text{tr}(\hat{u}^T (u^* - \hat{u})) \leq \|\hat{u}\|_F \|u^*\|_F - \|\hat{u}\|_F^2 \quad (17)$$

$$\text{tr}(\hat{\sigma}^T (\sigma^* - \hat{\sigma})) \leq \|\hat{\sigma}\|_F \|\sigma^*\|_F - \|\hat{\sigma}\|_F^2 \quad (18)$$

식(16)를 다시 정리하면 다음과 같다.

$$\begin{aligned} \dot{V} &\leq -K_{dmin} \|s\|^2 + \|\tau_d + \epsilon\| \|s\| + \alpha \|s\| \|\hat{u}\|_F \\ &\quad (\|u^*\|_F - \|\hat{u}\|_F) + \beta \|s\| \|\hat{\sigma}\|_F (\|\sigma^*\|_F - \|\hat{\sigma}\|_F) \end{aligned} \quad (19)$$

식(19)에서 s 의 norm이 식(20)을 만족하면 식(21)이 성립 한다.

$$\|s\| \geq \frac{\|\tau_d + \epsilon\| + \frac{1}{4} \|u^*\|_F + \frac{1}{4} \|\sigma^*\|_F}{K_{dmin}} \quad (20)$$

$$\dot{V} \leq 0 \quad (21)$$

이 성립한다.

Lyapunov 후보 함수 식(12)은 양의 한정이고 그것의 일차 미분인 식(16)은 식(20)의 조건이 성립할 경우 음의 반한정이 된다. 그러므로 식 (12)에서 $s, \tilde{c}, \tilde{u}, \tilde{\sigma} \rightarrow \infty$ 인 경우 $V \rightarrow \infty$ 이므로 Lyapunov 직접 방법에 따라 전체 제어 시스템은 전역적으로 안정하다. 그리고 식(12), (20), (21)은 궤적 추적 오차 $s(t)$ 가 UUB함을 보여준다. 또한, 식(20)에서 K_{dmin} 을 크게 할수록 궤적 추적 오차는 더 작은 영역으로 bounded됨을 보여주고 있다.

4. 실험 및 실험 결과

제안된 제어 알고리즘을 SCARA 로봇의 2축 제어 실험에 적용하여 그 타당성을 검증하였다. 실험에 사용된 SCARA

로봇의 사양은 표 1과 같다. 본 실험에서는 TMS320C40칩이 내장된 DSP(Digital Signal Processing)보드를 이용하여 제어 알고리즘을 빠르게 수행할 수 있도록 하였다. 실험장치의 전체 구조도는 그림 3과 같다.

표 1 로봇 매니퓰레이터의 사양

Table 1 Specification of manipulator

	link 1	link 2
질량 (Kg)	10.71	9.65
link 길이 (m)	0.35	0.26
질량 중심점 (m)	0.116	0.178

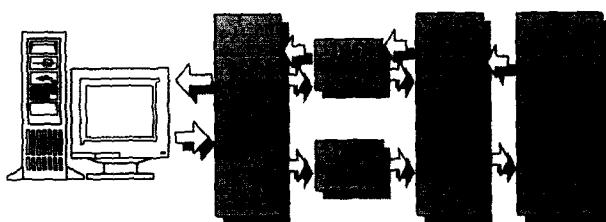


그림 3 실험 장치 구성

Fig. 3 Hardware schematic diagram

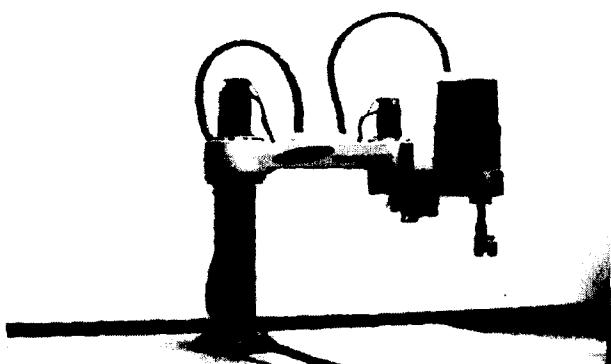


그림 4 SCARA 로봇 매니퓰레이터

Fig. 4 SCARA type robot manipulator

그림 4는 실험에 사용한 SCARA 로봇 매니퓰레이터를 보여주고 있다.

로봇 매니퓰레이터의 기준 궤적을 각각 $q_{d1} = 0.5\sin(0.5t)[rad]$, $q_{d2} = 0.5\cos(0.5t)[rad]$ 으로 정하고 PD 제어기와 제안된 제어기의 파라메터들을 표 2와 같이 설정하여 실험하였다. 그리고 RBFN의 노드 수는 10개로 설정하였고 샘플링 주기는 5 [msec]로 하였다.

표 2 제안된 제어기의 파라메터

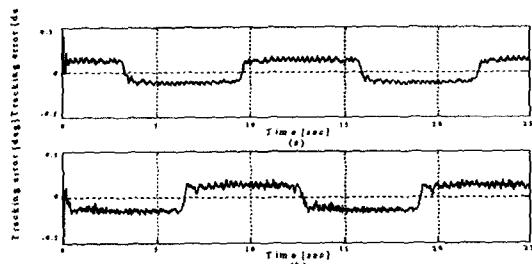
Table 2 Parameters of the proposed controller

λ	$[56 \ 60]^T$
K_d	$[4 \ 3]^T$
Γ	$diag(0.018 \ 0.018)$
α, β	0.15, 0.005

그림 5과 6은 각각 고정 이득 PD 제어기를 사용하였을 때와 제안된 제어기를 사용하였을 때의 기준궤적에 대한 추종 오차를 나타낸다. PD제어기는 계단 형태의 오차를 보이는 반면 제안된 제어기는 초기에 예상의 값이 크지만, RBFN이 학습됨으로써 추종 오차가 줄어들고 있음을 보여준다. 그림 7, 8, 9은 제안된 제어기에서 RBFN의 파라메터(가중치, 중심값, 표준편차)가 학습되어 가는 모습을 보여준다. 그리고 그림 10은 제안된 제어기의 토크 출력을 나타낸다. RBFN이 학습되지 않은 초기에는 PD제어기의 제어입력이 큰 값을 가지고 있지만 시간이 지남에 따라 PD제어기의 제어입력이 RBFN에 비해 상대적으로 줄어들고 있다.

본 논문에서 제안한 제어기의 장점을 보이기 위해서 기준 입력의 주파수를 빠르게 주고 실험을 하였다. 새로운 기준입력은 $q_{d1} = 0.5\sin(2t)[rad]$, $q_{d2} = 0.5\cos(2t)[rad]$ 이다. 그림 11와 12은 각각 고정 이득 PD 제어기를 사용하였을 때와 제안된 제어기를 사용하였을 때의 기준궤적에 대한 추종 오차를 나타낸다. 고정 이득 PD제어기는 오차가 증가하였지만, 제안된 제어기는 초기에 RBFN의 학습으로 인해서 진동이 있지만 학습을 함으로써 오차가 점차 줄어들고 있음을 보여주고 있다.

그리고 그림 13 과 14는 10~11초 사이에 외란 (0.75 [Nm])를 인가하였을 때의 궤적추종오차를 나타내고 있다. PD 제어기의 경우 그림 13과 같이 외란에 대해 민감한 반응을 보이지만, 본 논문에서 제안된 제어기의 경우는 그림 14와 같이 외란에 대해 강인한 특성을 보인다.

그림 5 PD 제어기의 궤적 추종오차($\omega=0.5[\text{rad/s}]$) (a) 관절 1
(b) 관절 2Fig. 5 Tracking errors of PD controller($\omega=0.5[\text{rad/s}]$) (a)
Joint 1 (b) Joint 2

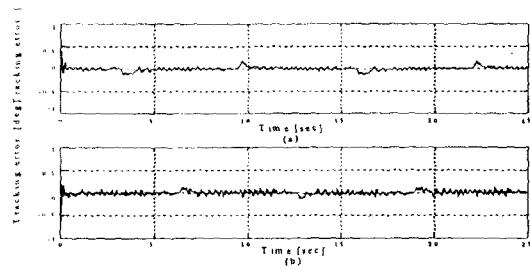


그림 6 제안된 제어기의 궤적 추종 오차($\omega=0.5[\text{rad/s}]$) (a) 관절 1 (b) 관절 2

Fig. 6 Tracking errors of the proposed controller($\omega=0.5$ [rad/s]) (a) Joint 1 (b) Joint 2

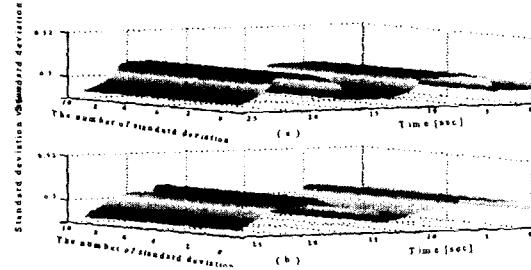


그림 9 제안된 제어기의 표준편차 (a) 관절 1 (b) 관절 2

Fig. 9 Standard deviations of the proposed controller (a) Joint 1 (b) Joint 2

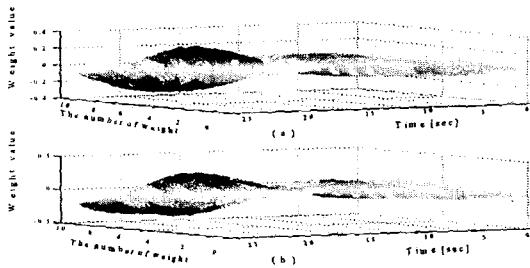


그림 7 제안된 제어기의 가중치 (a) 관절 1 (b) 관절 2

Fig. 7 Weights of the proposed controller (a) Joint 1 (b) Joint 2

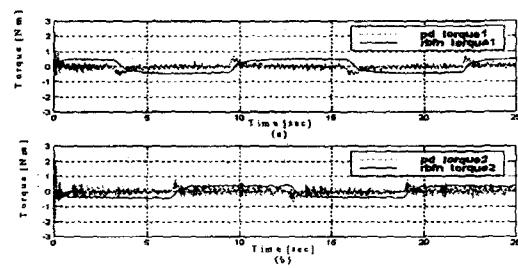


그림 10 제안된 제어기의 토크 (a) 관절 1 (b) 관절 2

Fig. 10 Torques of the proposed controller (a) Joint 1 (b) Joint 2

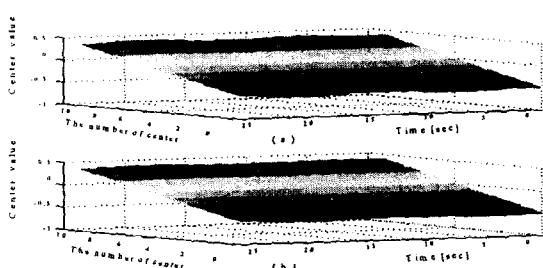


그림 8 제안된 제어기의 중심값 (a) 관절 1 (b) 관절 2

Fig. 8 Centers of the proposed controller (a) Joint 1 (b) Joint 2

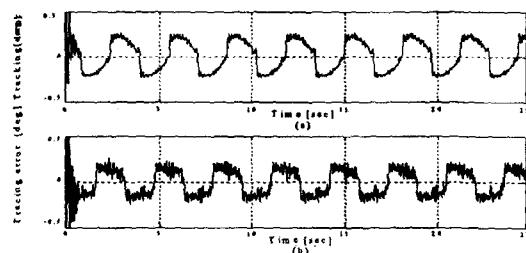


그림 11 주기가 다를 때의 PD 제어기의 궤적 추종 오차 ($\omega=2[\text{rad/s}]$) (a) 관절 1 (b) 관절 2

Fig. 11 Tracking errors of PD controller under different period($\omega=2[\text{rad/s}]$) (a) Joint 1 (b) Joint 2

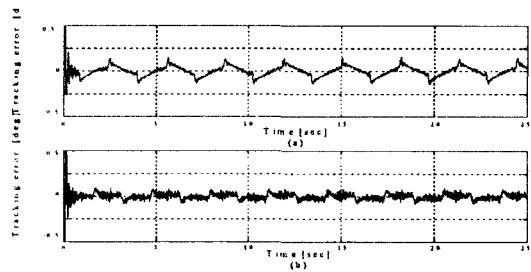


그림 12 주기가 다른 때의 제안된 제어기의 궤적 추종 오차($\omega=2[\text{rad/s}]$) (a) 관절 1 (b) 관절 2

Fig. 12 Tracking errors of the proposed controller under different period (a) Joint 1 (b) Joint 2

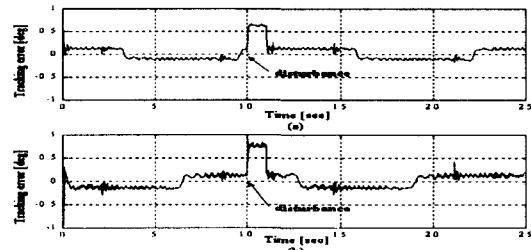


그림 13 외란이 있을 때의 PD제어기의 궤적 추종오차
(a) 관절 1 (b) 관절 2

Fig. 13 Tracking errors of PD controller under disturbance
(a) Joint 1 (b) Joint 2

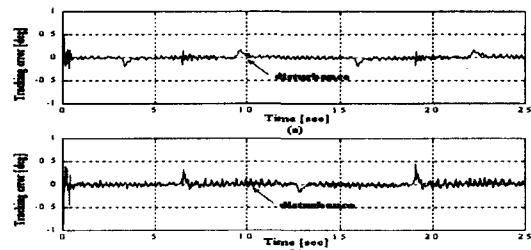


그림 14 외란이 존재할 때의 제안된 제어기의 궤적 추종
오차 (a) 관절 1 (b) 관절 2

Fig. 14 Tracking errors of the proposed controller under disturbances (a) Joint 1 (b) Joint 2

5. 결 론

본 논문에서는 로봇 매니퓰레이터의 궤적 제어를 위해 시스템 인식(identification)과 근사에 많이 사용되고 있는 RBFN을 사용하였다. 그리고 적용 제어 기법을 이용하여 RBFN의 파라메터들을 실시간으로 학습하였다.

신경망 적용 제어기는 실시간으로 학습되는 RBFN과 고정

이득 PD 제어기가 병렬로 연결된 구조를 가지고 있다. RBFN은 파라메터 불확실성 등에 대해 적응하도록 실시간으로 학습되며, 전체 제어 시스템의 안정도를 보장하기 위해서 Lyapunov 안정도 이론에 근거하여 가중치 및 basis function의 중심값과 표준 편차의 학습 규칙을 구하였다. 그리고 외란과 RBFN의 모델링 오차가 존재하는 상황하에서 전체 제어 시스템의 안정성을 보장하고, RBFN의 모든 파라메터를 학습하는 제어기를 설계하였으며 궤적 추종 오차의 UUB(uniformly ultimately boundedness)를 보장하였다.

마지막으로 실험을 통하여 PD 제어기만을 사용했을 경우보다 제안한 제어기가 우수한 성능을 가짐을 확인하였다.

감사의 글

본 연구는 부산대학교 학술 연구조성비 지원을 받아 이루어졌습니다.

참 고 문 헌

- [1] J.-J. E. Slotine and W. Li, *Applied Nonlinear Control*, Prentice-Hall, 1991.
- [2] 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.
- [3] 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.
- [4] D. Y. Meddah and A. Benallegue, "A stable neuro-adaptive controller for rigid robot manipulators," *Journal of Intelligent and Robotic Systems*, vol. 20, pp. 181-193, 1997.
- [5] R. Carelli and E. F. Camacho, "A neural network based feedforward adaptive controller for robots," *IEEE Trans. on Systems, Man and Cybernetics*, vol. 25, no. 9, pp. 1281-1288, Sep. 1995.
- [6] M. Zhihong, H. R. Wu, and M. Palaniswame, "An adaptive tracking controller using neural networks for a class of nonlinear systems," *IEEE Trans. on Neural Networks*, vol. 9, no. 5, Sep. 1998.
- [7] V. Etxebarria and M. D. L. Sen, "An approach to adaptive neural control of robot manipulator," *Journal of Systems Science*, vol. 27, no. 11, 1996.
- [8] S. Yildirim, "New neural networks for adaptive control of robot manipulators," *IEEE Trans. on Neural Networks*, 1997.
- [9] M. A. Abido and Y. Abdel-Magid, "On-line identification of synchronous machines using radial basis function neural networks," *IEEE Trans. on Power Systems*, vol. 12, no. 4, Nov. 1997.
- [10] Y. Li and J. M. Deng, "WAV - a weight adaptation algorithm for normalized radial basis function networks," *IEEE Trans. on Neural Networks*, 1998.

- [11] L. Yingwei, N. Sundararajan and P. Saratchandran, "Identification of time-varying nonlinear systems using minimal radial basis function neural networks," *IEE Proc.-Control Theory Appl.*, vol. 144, no. 2, March 1997.
- [12] L. Behera, S. Chandhury and M. Gopal, "Neuro-adaptive hybrid controller for robot-manipulator tracking control," *IEE Proc.-Control Theory Appl.*, vol. 143, no. 3, May 1996.
- [13] G. P. Liu, V. Kadirkamanathan and S. A. Billings, "Variable neural networks for adaptive control of nonlinear systems," *IEEE Trans. on Systems, Man and Cybernetics*, vol. 29, no. 1, Feb. 1999.
- [14] K. S. Fu, R. C. Gonzalez, and C. S. G. Lee, *Robotics*, McGraw-Hill International Editions, 1987.
- [15] M. W. Spong and M. Vidyasagar, *Robot Dynamics and Control*, John Wiley & Sons, 1989.
- [16] J. S. R. Jang, C. T. Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice-Hall, 1997.
- [17] Li-Xin Wang, *Adaptive Fuzzy Systems and Control : Design and Stability Analysis*, Prentice Hall, 1994.
- [18] 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.

저 자 소 개



김 정 대 (金 正 大)

1972년 3월 21일 생. 1998년 동아대 전기공학과 졸업. 2000년 부산대 일반대학원 전기공학과 졸업(석사). 2000~현재 (주)코웰 시스넷 개발부 근무

Tel : 02-3400-7958, Fax : 0x-404-2279

E-mail : tosher@hanmail.net



최 영 규 (崔 榮 奎)

1957년 6월 18일 생. 1980년 서울대 공대 전기공학과 졸업. 1982년 한국과학기술원 전기 및 전자공학과 졸업(석사). 1987년 동 대학원 전기 및 전자공학과 졸업(공박). 1990~1991년 CALTECH Visiting Scholar.

1998~1999년 Univ. of Southwestern Louisiana Visiting Professor. 현재 부산대 공대 전자전기정보컴퓨터공학부 교수

Tel : 051-510-2371, Fax : 051-510-0212

E-mail : ykicho@pusan.ac.kr



이 민 중 (李 敏 中)

1970년 10월 14일 생. 1996년 부경대 전기공학과 졸업. 1998년 부산대 일반대학원 전기공학과 졸업(석사). 1998~현재 동대학원 전기공학과 박사과정

Tel : 051-510-1445, Fax : 051-513-0212

E-mail : mnjlee@hanmail.net



김 성 신 (金 成 信)

1960년 8월 28일 생. 1984년 연세대 공대 전기공학과 졸업. 1996년 동 대학교 일반대학원 전기공학과 졸업(석사), 1996년 미국 Georgia Institute of Technology 졸업(공박). 1996~1998년 Georgia Institute of Technology 선임연구원. 1997~1998년 Appalachian Electronic Instruments Inc. 연구원. 현재 부산대 공대 전자전기정보컴퓨터공학부 조교수

Tel : 051-510-2374, Fax : 051-513-0212

E-mail : sskim007@pusan.ac.kr