
퍼지규칙에 의한 직.간접 혼합 신경망 적응제어시스템의 설계

이 순 영*, 장 순 용**

Design of the Combined Direct and Indirect Adaptive Neural Controller Using Fuzzy Rule

Soon-Young Lee, Soon-Yong Jang

Abstract

In this paper, the direct and indirect adaptive controller are combined based on the Lyapunov synthesis approach. The proposed controller is constructed from RBF Neural Network and weighting parameters are adjusted on-line according to some adaptation law. In this scheme, fuzzy IF-THEN rules are used to decide the combined weighting factor. In the results, proposed controller has the main advantages of both the direct adaptive controller and the indirect adaptive controller. The effectiveness of the proposed control scheme is demonstrated through simulation results of control for one-link rigid robotics manipulator.

요 약

본 논문에서는 직접 적응제어기와 간접 적응제어기를 Lyapunov 안정도 이론에 근거하여 결합하였다. 제어기는 RBF 신경망을 이용하여 구성하였으며 하중파라미터들은 적응칙에 의하여 조정되도록 하였다. 또한 시스템의 성능에 영향을 미치는 결합 가중치는 퍼지 IF-THEN 규칙을 이용하여 결정되도록 하였다. 이렇게 함으로써 직접 적응제어기와 간접 적응제어기의 장점을 지니는 직 간접 혼합 신경망 적응제어기를 구성할 수 있었다. 제안한 알고리즘의 효용성을 보이기 위하여 일축 강체 로봇 매니퓰레이터를 대상으로 시뮬레이션한 결과 만족할 만한 성능을 보였다.

* 경상대학교 전기전자공학부 교수

** 한국항공우주산업(주) 비행제어팀

접수일자 : 2000년 10월 20일

I. 서 론

대부분의 물리계는 비선형 시스템이므로 비선형 시스템에 대한 정확한 제어는 매우 중요하다. 과거에는 비선형 시스템의 제어는 시스템의 정확한 동태방정식에 기초한 선형화 모델을 이용하여 선형 제어를 사용하였다. 이러한 제어는 제어계의 정밀성이 크게 요구되지 않는 경우 외에는 그 제어효과를 보장하기가 어렵다. 따라서 Sastry 와 Isidori 는 계통의 상대차수를 알 경우 적용할 수 있는 입출력 선형화 기법을 제시하였으며[1], Wang은 퍼지이론과 적응제어 이론을 결합한 비선형 적응제어를 제안하였다[2][3]. Narendra는 신경망으로 제어를 구성한 후 하중함수들을 적응제어 이론을 이용하여 변환시키는 신경망 적응제어를 개발하였다[4].

신경망을 이용한 비선형 적응제어도 일반적인 적응제어기와 마찬가지로 제어기 파라미터를 직접 조정하는 신경망 직접적응제어기와 신경망 식별기를 이용하여 제어를 구성하는 신경망 간접적응제어기로 구분된다[2][3]. 신경망 직접적응제어기는 시스템의 제어입력을 신경망 간접적응제어기는 시스템의 비선형 파라미터들을 신경망으로 구성하는데 sigmoid 함수를 이용한 다층신경망(multilayer perceptron)[5][6]이나 Gauss 함수에 의한 RBF(radial basis funtion) 신경망[7]이 주로 사용된다. 또한 신경망에 사용된 가중치들을 조정하기 위한 적응직도 MRAC 와 비슷하게 Lyapunov안정도 이론에 의하여 구하여 진다[8][9]. 그러나 신경망을 이용하여 입력이나 파라미터를 구성할 경우 필연적으로 근사화 오차(approximation error)가 발생하게 되어 응답성능이 저하되는데 이의 개선을 위하여 sliding mode 제어기나 입력에 사구간을 도입한 새로운 방법들이 제안되기도 하였다[10]-[12].

일반적으로 직접 적응제어방식은 간접 적응제어 방식에 비하여 수렴성은 좋으나 과도응답특성이 나쁜 경향이 있으며, 간접 적응제어방식의 특성은 직접 적응제어방식과 상반되는 특성을 지닌다[2][9]. 따라서 본 논문에서는 간접방식과 직접방식을 결합한 혼합 신경망 적응제어를 제안한다. 두 방식의 결합에 있어 중요한 요소인 결합가중치 선정은 시

스템의 출력오차를 이용한 퍼지규칙에 의하여 on-line으로 결정함으로써 예측되지 않은 외란 및 모델링 오차에 대한 강인성 부여와 빠른 응답특성을 가진 제어를 구성할 수 있었다. 제안한 혼합 신경망 적응제어 알고리즘의 타당성을 검증하기 위하여 비선형 시스템인 일축 강체 로봇 매니퓰레이터 (one-link rigid robotics manipulator)를 대상으로 한 컴퓨터 시뮬레이션을 행하였다.

II. 신경망 적응제어 시스템의 설계

2.1 문제 설정

다음과 같은 n 차의 상태방정식으로 표현되는 비선형 플랜트를 생각한다.

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= x_3 \\ &\dots \\ \dot{x}_n &= f(x_1, x_2, \dots, x_n) + g(x_1, x_2, \dots, x_n)u \\ y &= x_1 \end{aligned} \dots \dots \dots (1)$$

위의 플랜트는 다음과 같은 벡터형식으로 나타낼 수 있다.

$$\dot{x}^{(n)} = f(x) + g(x)u \dots \dots \dots (2)$$

여기서 u와 y는 각각 입력과 출력을 나타내고, f(·), g(·)는 미지의 연속함수이며, 0 < g(x) ≤ g_k 라고 가정한다.

제어목적은 n 차 시스템의 x가 원하는 출력특성을 갖는 x_m을 추종하게 하는 최적의 제어입력 u*를 구하는 것이다 만일 시스템의 비선형항 f(·), g(·)를 정확히 알 수 있다면 제어입력 u*는 폐환 선형화 기법에 의해 다음과 같이 구성될 수 있다[2].

$$u^* = \frac{1}{g(x)} (-f(x) + K^T e + \dot{x}_m^{(n)}) \dots \dots \dots (3)$$

여기서 K^T=(k₁, ···, k_n)는 h(s)=sⁿ+k_nsⁿ⁻¹+···+k₁가 Hurwitz 다항식이 되도록 임의

로 선택한 벡터이다. 식 (3)의 제어입력을 시스템에 적용하면 오차식은 $e^{(n)} + k_n e^{(n-1)} + \dots + k_1 e = 0$ 이 되어 $t \rightarrow \infty$ 에서 오차가 0이 된다.

비선형 시스템에서 미지의 파라미터를 정확히 알 수 있다면 식 (3)에서 제시한 제어입력을 시스템에 적용할 수 있다. 그러나 실제의 경우에 있어서 비선형함 $f(\cdot)$, $g(\cdot)$ 는 미지이므로 제어입력을 위의 식(3)과 같이 선정할 수 없으므로 RBF 신경망을 이용하여 제어입력을 구성한다.

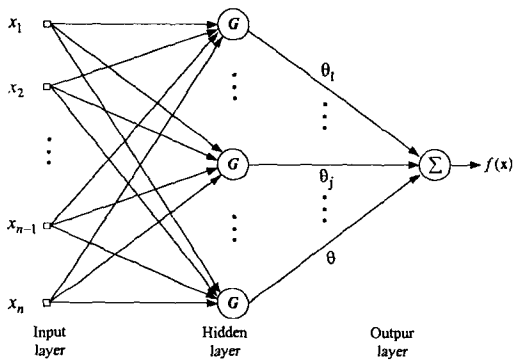


Fig. 1. Radial basis function network

위의 그림1은 RBF 회로망의 구조를 나타낸다. 여기서 x 와 $f(x)$ 는 RBF 회로망의 입력과 출력을 나타내고 m 은 은닉층의 개수를 나타낸다. θ_i 는 은닉층의 i 번째 뉴런으로부터 출력으로의 하중값을 나타낸다. 각 은닉층의 활성화 함수로는 주로 Green 함수나 Gauss 함수가 사용되는데 본 논문에서는 다음과 같이 정의 되는 Gauss 함수를 사용하였다[3].

$$\xi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \dots\dots\dots (4)$$

여기서 c_i 과 σ_i 은 상수 파라미터로 각각 표준편차와 평균값을 나타낸다.

이제 위의 RBF 신경망을 이용하여 간접 제어입력과 직접 제어입력을 각각 다음과 같이 구성한다.

$$u_c = \frac{1}{\hat{g}(x|\theta_g)} (-\hat{f}(x|\theta_f) + K^T e + x_m^{(n)})$$

$$u_d = \hat{u}(x|\theta_u)$$

..... (5)

신경망 적응제어기의 구성에 사용된 RBF 신경망 함수는 다음과 같다.

$$\hat{f}(x|\theta_f) = \theta_f^T \xi_f(x)$$

$$\hat{g}(x|\theta_g) = \theta_g^T \xi_g(x) \dots\dots\dots (6)$$

$$\hat{u}(x|\theta_u) = \theta_u^T \xi_u(x)$$

여기서 $\theta_f \in R^m$, $\theta_g \in R^m$, $\theta_u \in R^m$ 는 RBF 신경망의 하중벡터를 나타낸다.

2.2 혼합 신경망 적응제어 시스템

이상에서 기술한 이론적 배경을 통해서 본 논문에서는 간접방식의 안정성과 직접방식의 수렴성을 이용하여 식 (5)에서 제시한 간접방식과 직접방식의 두 방식을 결합한 직·간접 혼합 신경망 적응제어기의 제어입력을 다음과 같이 설정하였다.

$$u = au_c + (1-a)u_d \dots\dots\dots (7)$$

여기에서 $a \in [0, 1]$ 는 결합 가중치(combined weighting factor)를 나타낸다. 본 논문에서는 퍼지 제어를 이용하여 식 (7)과 같이 주어진 혼합 신경망 적응제어의 제어입력에서의 결합 가중치를 on-line으로 최적의 값을 결정하도록 설계하였다. 퍼지 제어를 시스템의 전체 제어입력에 첨가함으로써 초기치에 의존하였던 가중치 선정 문제를 시스템의 작동시에 on-line으로 추정함으로써 외란 및 기타 변화되는 상황에 실시간으로 반응할 수 있어 강인성 및 응답특성을 향상할 수 있는 장점을 지닌다. 퍼지규칙을 도입함에 있어서 사용되는 퍼지 규칙은 다음과 같다.

- IF e is AN and de is ADN, THEN Rule is near IND.
- IF e is MN and de is MDP, THEN Rule is near MED.
- IF e is MP and de is ADN, THEN Rule is near DRC.

...

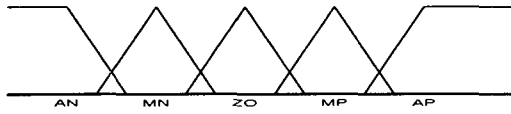


Fig. 2. e membership function.

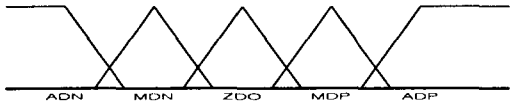


Fig. 3. \hat{e} membership function.

Table 1. Fuzzy rule definition by look-up table

		e				
		AN	MN	ZO	MP	AP
dc	ADN	IND	MED	IND	DRC	IND
	MDN	IND	MED	IMD	DRC	IND
	ZDO	MED	DRI	IND	DIE	DIE
	MDP	IND	MED	IMD	DIE	IND
	ADP	IND	DDE	IND	MED	MED

이상과 같이 식 (7)에서 제안된 혼합 신경망 적응 제어기의 제어입력을 앞서 제시한 비선형 시스템에 인가하여 오차방정식을 유도하면 식 (8)과 같다.

$$e^{(n)} = -K^T e + \alpha(\hat{f}(x|\theta_f) - f(x)) + \alpha(\hat{g}(x|\theta_g) - g(x))u_c + (1-\alpha)g(x)(u^* - \hat{u}(x|\theta_u)) \dots (8)$$

위의 식을 정리하면,

$$\dot{e} = \Lambda e + b[\alpha(\hat{f}(x|\theta_f) - f(x)) + \alpha(\hat{g}(x|\theta_g) - g(x))u_c + (1-\alpha)g(x)(u^* - \hat{u}(x|\theta_u))] \dots (9)$$

$$\Lambda = \begin{bmatrix} 0 & 1 & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & 1 \\ -k_n & -k_{n-1} & \dots & \dots & \dots & -k_1 \end{bmatrix}, b = \begin{bmatrix} 0 \\ 0 \\ \dots \\ 0 \\ 1 \end{bmatrix}$$

여기서 추종오차는 $e \triangleq y_m - y$ 이다. 추정하는 파라미터의 이상적인 값이 존재한다고 가정하고 각각 $\theta_f^*, \theta_g^*, \theta_u^*$ 라 두면 아래와 같이 정의할 수 있다[3].

$$\theta_f^* = \min_{\theta_f \in R^M} [\sup_{x \in R^n} |\hat{f}(x|\theta_f) - f(x)|]$$

$$\theta_g^* = \min_{\theta_g \in R^M} [\sup_{x \in R^n} |\hat{g}(x|\theta_g) - g(x)|] \dots (10)$$

$$\theta_u^* = \min_{\theta_u \in R^N} [\sup_{x \in R^n} |\hat{u}(x|\theta_u) - u^*|]$$

이제 최소근사오차(minimum approximation error)를 아래와 같이 가정한다..

$$\omega_1 = \hat{f}(x|\theta_f^*) - f(x)$$

$$\omega_2 = \hat{g}(x|\theta_g^*) - g(x) \dots (11)$$

$$\omega_3 = \hat{u}(x|\theta_u^*) - u^*$$

위의 가정으로부터 오차방정식을 구하면,

$$\dot{e} = \Lambda e + b[\alpha\phi_f \xi_f(x) + \alpha\phi_g \xi_g(x)u_c - (1-\alpha)g(x)\phi_u \xi_u(x) + \alpha\omega_1 + \alpha\omega_2 u_c - (1-\alpha)g(x)\omega_3] \dots (12)$$

여기서 ϕ_f, ϕ_g, ϕ_u 는 각각 다음과 같이 정의되는 파라미터 오차 벡터이다.

$$\phi_f = \theta_f - \theta_f^* \quad \phi_g = \theta_g - \theta_g^* \quad \phi_u = \theta_u - \theta_u^* \dots (13)$$

이제 $\omega \triangleq \alpha\omega_1 + \alpha\omega_2 + (1-\alpha)g(x)\omega_3$ 라 두면 혼합 신경망 적응제어기에서의 오차방정식은 아래와 같이된다.

$$\dot{e} = \Lambda e + b[\alpha\phi_f \xi_f(x) + \alpha\phi_g \xi_g(x)u_c - (1-\alpha)g(x)\phi_u \xi_u(x) + \omega] \dots (14)$$

전체 시스템에서의 안정도를 증명하기 위해서 다음과 같은 Lyapunov 함수를 가정한다.

$$V(e, \phi_f, \phi_g, \phi_u) = e^T P e + \frac{1}{2}(\phi_f^T \phi_f) + \frac{1}{2}(\phi_g^T \phi_g) + \frac{1}{2}(\phi_u^T \phi_u) \dots (15)$$

여기서 P 는 아래의 식 (16)을 만족하는 양의 한정행렬(positive definite matrix)이고, Q 는 임의의 $n \times n$ 양의 한정행렬을 나타낸다.

$$\Lambda^T P + P \Lambda = -Q \dots (16)$$

양의 한정행렬 P 를 단위행렬로 가정하고, 파라미터를 조정하는 적응칙을 다음과 같이 설정하였다.

$$\begin{aligned} \dot{\phi}_f &= -\alpha e^{(n)} \xi_f \\ \dot{\phi}_g &= -\alpha e^{(n)} \xi_g u_c \\ \dot{\phi}_u &= (1-\alpha) \text{sgn}(\phi) |e^{(n)} \xi_u| \end{aligned} \quad \dots\dots\dots (17)$$

식(14)과 식 (17)을 이용하여 Lyapunov 함수의 도함수를 구하면,

$$\begin{aligned} \dot{V} &= -e^T Q e + e^T P b \alpha \phi_f \xi_f + e^T P b \alpha \phi_g \xi_g u_c - e^T P b g (1-\alpha) \phi_u \xi_u \\ &\quad + (\phi_f^T \phi_f) + (\phi_g^T \phi_g) + (\phi_u^T \phi_u) + e^T P b w \\ &\leq -e^T Q e + \alpha e^{(n)} \phi_f \xi_f + \alpha e^{(n)} \phi_g \xi_g u_c + g \alpha (1-\alpha) |\phi_u| e^{(n)} \xi_u \\ &\quad + (\phi_f^T \phi_f) + (\phi_g^T \phi_g) + (\phi_u^T \phi_u) + e^{(n)} \omega \\ &= -e^T Q e + e^{(n)} \omega \leq 0 \end{aligned} \quad \dots\dots\dots (18)$$

위에서 최소근사오차 $\omega=0$ 이라면 $e \in \mathcal{L}^2 \cap \mathcal{L}^\infty$, $\dot{e} \in \mathcal{L}^\infty$ 를 만족하게 되어 Barbalat lemma에 의해 플랜트와 모델사이의 추정오차 e 는 점근적으로 0에 수렴한다[9]. 그러나 ω 가 아주 작은 값이나 0이 아닐 경우 전체계의 안정도를 보장할 수 없게 된다. 이 경우 오차모델의 안정도를 보장하기 위해 감독제어입력(supervisory control input)이나 가변구조제어입력 등의 보조제어 입력이 필요하게 된다 [2][3].

III. 시뮬레이션 및 검토

본 연구에서 제안한 혼합 신경망 적응제어기의 타당성을 컴퓨터 시뮬레이션을 통하여 검증하였다. 시뮬레이션에 사용된 비선형 플랜트는 일축 강체 로봇 매니플레이터로서 아래와 같은 동태방정식으로 나타낼 수 있다.

$$\begin{aligned} \begin{bmatrix} \dot{q}_p \\ \ddot{q}_p \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} q_p \\ \dot{q}_p \end{bmatrix} + \begin{bmatrix} 0 \\ -(mL^2)^{-1} d \dot{q}_p - dg^{-1} \cos(q_p) \end{bmatrix} + \begin{bmatrix} 0 \\ (mL^2)^{-1} u \end{bmatrix} \\ y_p &= [0 \ 1] \begin{bmatrix} q_p \\ \dot{q}_p \end{bmatrix} \end{aligned}$$

여기서 L은 링크 길이, m은 링크질량, g는 중력가속도, q_p 는 관절각을 나타낸다. 위의 비선형 플랜트가 추종해야 할 기준모델 시스템은 아래와 같이 설정하였다.

$$\begin{aligned} \begin{bmatrix} \dot{q}_m \\ \ddot{q}_m \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ -1 & -2 \end{bmatrix} \begin{bmatrix} q_m \\ \dot{q}_m \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} r \\ y_m &= [0 \ 1] \begin{bmatrix} q_m \\ \dot{q}_m \end{bmatrix} \end{aligned}$$

플랜트 및 기준모델의 초기값은 동일하게 0으로 두었다. 두 시스템의 기준입력은 $r(t) = \pi \sin(0.2t)$ 이며 20초부터 전체 출력의 30%에 해당하는 외란을 지속적으로 인가하여 외란에 대한 강인성을 검증하였다.

시뮬레이션 시간은 0 ~ 60초이며 샘플링 시간은 5[msec]로 설정하였다. 그림 4, 5는 직접법을 적용한 경우의 출력과 추종오차를 나타내는 그래프이다. 그림 6, 7은 간접법을 적용한 경우이고, 그림 8, 9는 제안한 제어 알고리즘을 적용한 경우의 결과를 나타낸다. 또한 그림 10, 11에서는 퍼지규칙에 의한 on-line으로 결정된 결합가중치상수와 제어입력을 나타내었다.

시뮬레이션 결과에서도 직접법은 과도한 응답을 지니지만 수렴성이 간접법에 비해 우수하며 간접법은 수렴성은 직접법에 비해 나쁘지만 과도응답이 작음을 볼 수 있다. 앞서 제시한 두 방법의 장점을 지니도록 결정한 퍼지규칙에 의해 제안한 알고리즘을 적용할 경우 직접법과 간접법에 비해 수

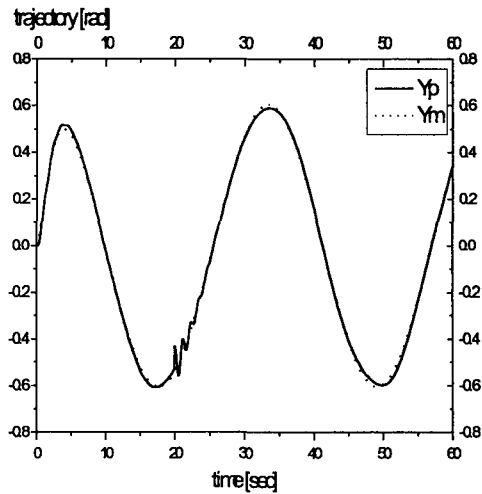


Fig. 4. Outputs of the direct controller

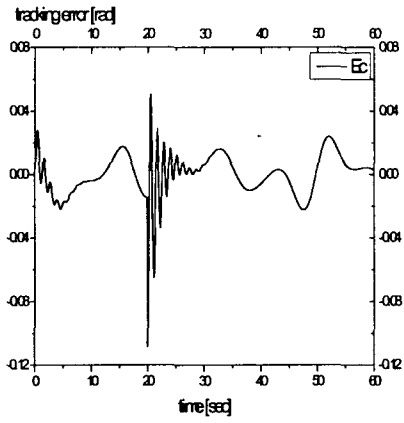


Fig. 5. Tracking error of the direct controller.

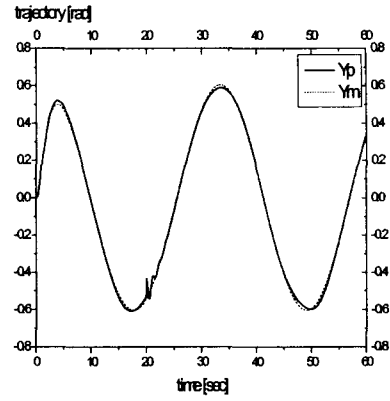


Fig. 8. Outputs of the proposed controller

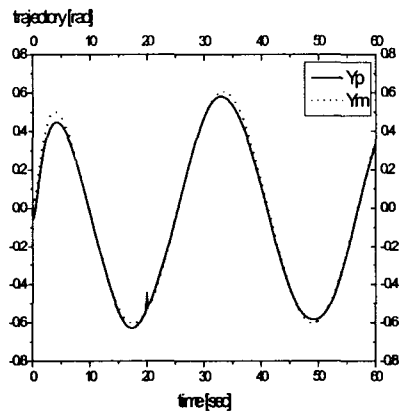


Fig. 6. Outputs of the indirect controller

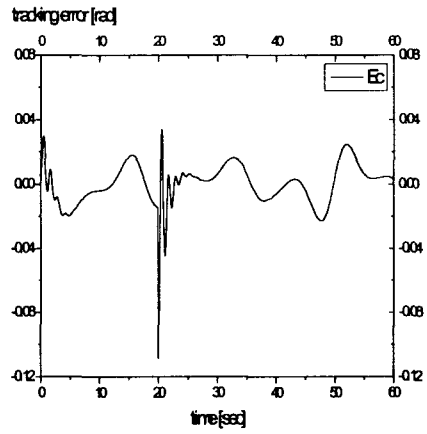


Fig. 9. Tracking error of the proposed controller

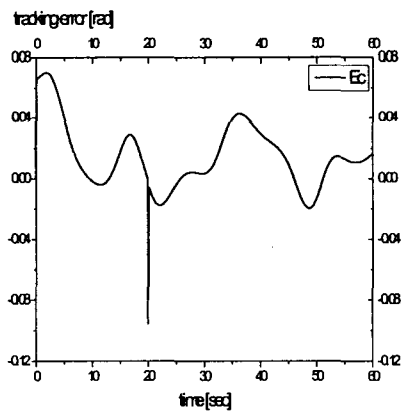


Fig. 7. Tracking error of the direct controller

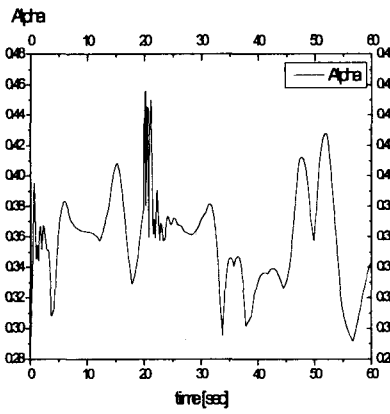


Fig. 10. Combined weighting factor

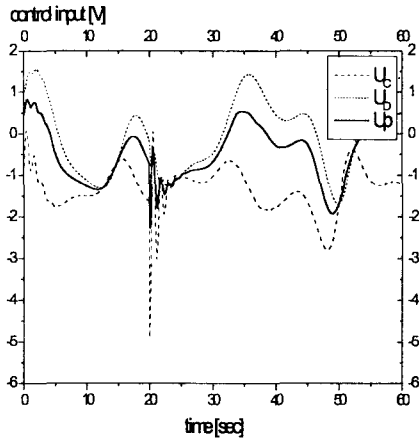


Fig. 11. Control inputs

렴성 및 과도응답특성이 향상되었음을 확인할 수 있었다.

IV. 결 론

본 논문에서는 간접법의 안정성과 직접법의 응답특성의 장점을 이용하여 제어기의 성능향상을 꾀하기 위해 퍼지규칙에 의해 두 방법을 결합한 혼합 신경망 적응제어기를 제안하였다. 두 방식의 결합에 사용된 결합 가중치 변수는 on-line으로 퍼지 규칙에 의하여 결정함으로써 예측되지 않는 외란 및 내부동적특성에 대해 강인성을 향상시킬 수 있었다.

제안한 혼합 신경망 적응제어기를 비선형 시스템인 일축 강체 로봇 매니플레이터에 적용하여 시뮬레이션한 결과 기존의 직접법과 간접법의 장점을 지닌 제어기를 구성할 수 있음을 확인할 수 있었으며, 또한 지속적인 외란을 인가하여 본 결과 강인성이 향상되었음을 확인할 수 있었다.

참고문헌

[1] S. S. Sastry, A. Isidori, "Adaptive Control of Linearizable Systems", IEEE Trans. Automatic Control, vol. 34, no. 11, pp. 1123-1131, 1989.

[2] L. X. Wang, Adaptive Fuzzy Systems and Control, Prentice Hall, 1994

[3] L. X. Wang, A Course in Fuzzy Systems and Control, Prentice Hall, 1997

[4] K. S. Narendra. "Neural Networks for Control: Theory and Practice", Proceedings of the IEEE, vol. 84, no. 10, pp. 1385-1406, 1996

[5] S. Haykin, Neural Networks, Prentice Hall, 1994

[6] N. Sadegh, "A Perceptron Network for Functional Identification and Control of Nonlinear Systems", IEEE Trans. on Neural Networks, vol. 4, no. 6, pp. 982-988, 1993

[7] R. B. McLain, M. A. Henson, M. Pottmann, "Direct Adaptive Control of Partially Known Nonlinear Systems", IEEE Trans. on Neural Networks, vol. 10, no. 3, pp. 714-721, 1999

[8] K. S. Narendra, A. M. Annaswamy, Stable Adaptive Systems, Prentice Hall, 1989

[9] S. S. Ge, C. C. Hang, T. Zhang, "A Direct Adaptive Controller for Dynamic Systems with a Class of Nonlinear Parameterization", Automatica, vol. 35, pp. 741-747, 1999

[10] S. Fabri, V. Kadiramanathan, "Dynamic Structure Neural Networks for Stable Adaptive Control of Nonlinear Systems", IEEE Trans. on Neural Networks, vol. 7, no. 5, pp. 1151-1167, 1996

[11] R. M. Sanner, J. J. E. Slotine, "Gaussian Networks for Direct Adaptive Control", IEEE Trans. on Neural Networks, vol. 3, no. 6, pp. 837-863, 1992

[12] F. Sun, Z. Sun, P. Y. Woo, "Stable Neural Network Based Adaptive Control for Sampled Data Nonlinear Systems", IEEE Trans. on Neural Networks, vol. 9, no. 5, pp. 956-968, 1998



이 순 영(李順榮)

1980년 한양대학교 전기공학과
졸업

1982년 한양대학교 대학원 전기
공학과 졸업(석사)

1985년 한양대학교 대학원 전기
공학과 졸업(박사)

1986년 ~ 현재 경상대학교 전기전자공학부 교수



장 순 용(張順龍)

1998년 경상대학교 전기공학
과 졸업

2000년 경상대학교 전기공학
과 대학원 졸업(공학
석사)

2000년 - 현재 한국항공우주산업(주) 비행제어팀