

신경회로망을 이용한 매니플레이터의 슬라이딩모드 제어

양호석*, 이건복⁺

(논문접수일 2006. 7. 27, 심사완료일 2006. 9. 25)

Sliding Mode control of Manipulator Using Neural Network

Ho Seog Yang*, Gun Bok Lee⁺

Abstract

This Paper presents a new control scheme that combines a sliding mode control and a neural network. In the proposed sliding mode control, a continuous control is employed removing the switching phenomena and the equivalent control within the boundary layer is estimated through on-line learning of the neural network. The performances of the proposed control are compared with off-line neural network and on-line neural sliding mode control by computer simulation. The simulation results show that the proposed control reduces high frequency chattering and tracking error in example of the two link manipulator.

Key Words : Sliding Mode Control(슬라이딩 모드 제어), Neural Network(신경회로망), Robot Manipulator(로봇 매니플레이터), Multi Layer Perceptron(다층 퍼셉트론), Variable Structure Control(가변구조제어)

1. 서론

많은 비선형 동적시스템들은 매개변수나 구조의 불확실성으로 인해 정확한 수학적 모델을 확립하기 어렵다. 이러한 모델링의 부정확성은 비선형제어 시스템에서 성능저하의 큰 요인이 된다. 그러므로 이러한 모델의 불확실성에도 불구하고 제어성능을 유지하기위한 강인한 제어기의 설계가 필요하다⁽¹⁾. 이러한 제어기 설계의 방법으로 1950년대부터 가변구조제어(VSC ; Variable Structure Control) 방법이 연구

되었으며 이러한 가변구조 제어의 한 형태인 슬라이딩모드 제어(SMC; Sliding Mode Control)는 슬라이딩 평면상에서 불연속적인 제어 입력을 가함으로서 이러한 비선형 시스템의 모델링 오차나 외란에 의한 불확실성을 다루는 강인한 제어기법으로 잘 알려져 있다⁽²⁾. 슬라이딩모드 제어의 목적은 시스템의 궤적이 슬라이딩 곡면을 따라가도록 하는 것이다. 그러나 시스템의 불확실성을 보상하며 슬라이딩 곡면 상에 머물도록 하기 위해서는 제어 입력 값의 급격한 변화가 필요하고 이러한 급격한 입력 값의 변화가 슬라이딩 모드 제어

* 송실대학교 대학원 (songwoon@snut.ac.kr)
주소: 158-743 서울시 상도5동 송실대학교
⁺ 송실대학교 기계공학과

의 가장 큰 단점인 체터링을 발생하게 되어 시스템의 모델링 과정에서 무시되었던 고주파 성분의 특성을 유발할 수 있다. 이러한 체터링을 줄이기 위하여 Slotine은경계층을 도입하였고⁽³⁾ Zhou와 Fisher는 시변시스템에 대하여 연속 슬라이딩 모드 제어를 제안하였다⁽⁴⁾. 또한 최근에는 동적 시스템 인식능력이 탁월한 신경회로망을 이용하여 불확실성을 보상하고자 하는 연구가 수행되고 있다. Niu, Lam 등은 비선형 상태지연 시스템에 신경회로망을 이용한 슬라이딩모드 제어를 제안하였고⁽⁵⁾, Lin과 Shien등은 강인한 회귀신경망 슬라이딩모드 제어를 제안하였으며⁽⁶⁾, Lee와 Hong는 회귀신경망을 이용한 슬라이딩모드제어를 제안하였다⁽⁷⁾.

본 논문에서는 시스템의 불확실성의 영향을 최소화하고 슬라이딩모드제어가 갖는 단점을 보완하기 위하여 다층구조 신경회로망을 이용한 슬라이딩모드제어를 제안한다.

본 논문의 구성은 2장에서 매니플레이터의 모델링을 수행하고 3장에서는 슬라이딩 모드 제어기와 다층퍼셉트론 신경회로망 제어기가 결합된 새로운 제어기를 소개하고, 모의실험을 통한 제어기의 성능 평가를 4장에서 수행하였다. 5장에서 결론 및 향후 연구 과제를 설명한다.

2. 매니플레이터의 운동방정식

이 절에서는 매니플레이터가 다음 두 조건이 만족되는 경우에 대해 오일러 라그랑지(Euler-Lagrange) 방정식을 구한다. 첫째, 운동에너지는 벡터 \dot{q} 의 2차 함수 형태이고,

$$k = \frac{1}{2} \sum_{k,m} M_{kj}(\dot{q}) \dot{q}_k \dot{q}_j := \frac{1}{2} \dot{q}^T M(\dot{q}) \dot{q} \quad (2.1)$$

둘째, 위치에너지 $P=P(q)$ 는 \dot{q} 과 무관하다⁽⁸⁾.

이 경우 매니플레이터의 k번째 링크를 구동하는 k번째 액츄에이터의 토크 τ_k 에 대한 오일러 라그랑지 방정식은 다음과 같다.

$$\tau_k = \sum_{j=1}^n M_{kj} \ddot{q}_j + \sum_{i=1}^n \sum_{j=1}^n h_{ijk} \dot{q}_i \dot{q}_j + c_k \quad (2.2)$$

$k = 1, 2, \dots, n$

또 이를 행렬 형식으로 표현하면 다음과 같다⁽⁸⁾.

$$\tau(t) = M(q(t)) \ddot{q}(t) + h(q(t), \dot{q}(t)) + c(q(t)) \quad (2.3)$$

여기서

$$\begin{aligned} \tau(t) &= n \times 1 && \text{토크벡터} \\ q(t) &= n \times 1 && \text{로봇팔의 관절벡터} \\ M(q) &= n \times n && \text{관성행렬} \\ h(q, \dot{q}) &= n \times 1 && \text{비선형 코리올리력과 원심력 벡터} \\ c(q) &= n \times 1 && \text{중력벡터} \end{aligned}$$

또한 액츄에이터가 결합된 매니플레이터의 운동방정식은 다음식과 같이 나타낼 수 있으며

$$(J_M + R^2 M) \ddot{q} + (B_M + R^2 h) \dot{q} + R^2 C = R K_M v \quad (2.4)$$

여기서,

$$\begin{aligned} J_M &: \text{모터관성}, & B_M &: \text{모터의 가쇠 및 역기전력} \\ R &: \text{기어비} & K_M &: \text{모터토크상수} \\ v &: \text{모터의 입력전압} \end{aligned}$$

행렬 형식으로 다시 쓰면

$$\tilde{M}(q) \ddot{q} + H(q, \dot{q}) \dot{q} + C(q) + d = T \quad (2.5)$$

의 형태가 된다.

위의 운동방정식에서 상태변수를 각 관절의 위치와 속도로 설정하면

$$x_1 = q, \quad x_2 = \dot{q}, \quad (x = (x_1^T, x_2^T)^T), \quad y = q = x_1$$

와 같으며 일반적으로 상태변수를 사용한 운동방정식은 다음과 같이 나타낸다.

$$\begin{aligned} \dot{x}_1 &= f_1(x_1, x_2) \\ \dot{x}_2 &= f_2(x_1, x_2) + B_2(x_1, x_2) u \\ &\quad - B_2(x_1, x_2) d(t) \end{aligned} \quad (2.6)$$

$$y = x_1$$

여기서,

$$\begin{aligned} f_1 &= x_2 \\ f_2 &= -\tilde{M}^{-1}(x_1)[H(x_1, x_2)x_2 + C(x_1)] \\ B_2 &= \tilde{M}^{-1}(x_1), \quad u = T \end{aligned}$$

이다.

3. 신경망을 이용한 슬라이딩 모드 제어기 설계

3.1 슬라이딩 모드 제어기 설계

일반적으로 동적 시스템은 다음과 같이 상태변수를 이용

하여 나타낸다.

$$x^{(n)}(t) = f(X) + b(X)u(t) + d(t) \quad (3.1)$$

여기서, $u(t)$ 는 제어입력이며, x 는 출력이다. 또한 $X = [x, \dot{x}, \dots, x^{(n-1)}]^T$ 는 상태벡터이며 $f(X)$ 는 불확실성을 포함하여 다음과 같이 표현할 수 있다.

$$f(X) = \hat{f}(X) + \Delta f(X) \quad (3.2)$$

$\hat{f}(X)$ 는 $f(X)$ 의 추정 값이고, $\Delta f(X)$ 는 모델의 불확실 정도를 나타내며 최대값을 $F(X)$ 로 할 수 있다.

$$|\Delta f(X)| \leq F(X) \quad (3.3)$$

제어의 목적은 주어진 불확실한 모델링 함수 $f(X)$ 와 $b(X)$, 외란 $d(t)$ 가 존재하는 상황에서 페루프 시스템의 상태가 원하는 상태벡터 $X_d = [x_d, \dot{x}_d, \dots, x_d^{(n-1)}]^T$ 를 추종하도록 즉 추적오차가 0이 되도록 제어입력 $u(t)$ 를 결정하는 것이다.

추적오차 벡터는 다음과 같이 정의 한다.

$$\bar{X} = X - X_d = [\bar{x}, \dot{\bar{x}}, \dots, \bar{x}^{(n-1)}]^T \quad (3.4)$$

슬라이딩 모드 제어 기법은 페루프시스템의 구조가 상태변수의 값에 따라 불연속적으로 달라지는 가변구조 제어 시스템으로 이러한 변환은 미리 설정된 기준에 의해 이루어진다. 이러한 기준이 되는 함수 즉, 슬라이딩 곡면(sliding surface)을 다음과 같이 정의한다^(9,10).

$$\sigma(X, t) = \left(\frac{d}{dt} + \lambda\right)^{(n-1)} \bar{x} \quad (3.5)$$

$X \equiv X_d$ 의 추적제어 문제는 $t > 0$ 에서 $\sigma(X, t) = 0$ 을 만족하는 것으로 오차벡터 \bar{X} 를 슬라이딩 평면 $\sigma(t) = 0$ 위에 놓이게 하는 것이다. 이러한 제어 목적을 달성하는 제어입력 u 는 다음과 같은 슬라이딩조건으로부터 구할 수 있다^(9,10).

$$\frac{1}{2} \frac{d}{dt} \sigma^2(X, t) \leq -\eta \sigma, \quad \eta > 0 \quad (3.6)$$

위의 슬라이딩 조건은 시스템의 오차벡터가 어떠한 초기 값을 가지더라도 슬라이딩 곡면상에 도달하고 그 후 슬라이딩 평면 $\sigma(t) = 0$ 에 머물게 하는 구속조건이다.

페루프 시스템이 식 (3.6)의 슬라이딩 조건을 만족하는 제

어법칙 $u(t)$ 를 구하기 위해 2장의 매니플레이터 모델에 슬라이딩 평면 S 를 다음과 같이 정의한다.

$$S = \{X, \phi(t) - \sigma_a(X) = \sigma(X, t) = 0\} \quad (3.7)$$

여기서 상태벡터 X 는 X_1 과 X_2 의해 얻어지며, $\phi(t)$ 는 슬라이딩함수 $\sigma(X, t)$ 의 시간종속 부분이고, 제어 플랜트에 가하는 기준입력을 포함한다. $\sigma_a(X)$ 는 $\sigma(X, t)$ 에서 상태변수에만 의존하는 부분으로

$$\sigma_a = G_1 x_1 + G_2 x_2 \quad (3.8)$$

로 쓸 수 있다.

시스템에 대하여 다음과 같이 리아프노브 함수를 선택한다.

$$V = 1/2 \sigma^T \sigma \quad (3.9)$$

이 함수는 양의 한정함수이고, 리아프노브 함수의 도함수는 다음과 같이 정의하며 음의 한정 함수이다.

$$\dot{V} = -\sigma^T D \operatorname{sgn}(\sigma) < -\eta |\sigma| \quad (3.10)$$

여기서, D 는 양의 한정 행렬이고, $\operatorname{sgn}(\sigma)$ 는 σ 의 각 요소에 적용되는 시그모이드 함수를 의미한다.

식 (3.9)와 식 (3.10)으로부터

$$\sigma^T \dot{\sigma} = -\sigma^T D \operatorname{sgn}(\sigma) \quad (3.11)$$

와 같이 되며

슬라이딩 함수의 미분은 다음과 같다.

$$\dot{\sigma} = \dot{\phi} - G_1 f_1 + G_2 (f_2 - B_2 u + B_2 d) \quad (3.12)$$

식 (3.12)을 식 (3.11)에 대입하면 다음과 같이 제어입력 신호를 얻을 수 있다.

$$U(t) = U_{eq}(t) + \Delta U(t) \quad (3.13)$$

여기서, $U_{eq}(t)$ 는 등가제어 입력으로 다음과 같이 쓸 수 있으며

$$U_{eq}(t) = (G_2 B_2)^{-1} [\dot{\phi} + G_2 f_2 - G_1 f_1] + d \quad (3.14)$$

추가적인 제어 항은 다음과 같이 쓸 수 있다.

$$\Delta U(t) = -(G_2 B_2)^{-1} D \operatorname{sgn}(\sigma) = -K \operatorname{sgn}(\sigma) \quad (3.15)$$

시스템이 슬라이딩조건을 만족하는 u 는 다음과 같이 선택한다^(9,10).

$$u = u_{eq} - K \operatorname{sgn}(\sigma) \quad (3.16)$$

여기서, sgn 함수는 다음과 같다.

$$\operatorname{sgn}(\sigma) = \begin{cases} +1 & \text{if } \sigma > 0 \\ -1 & \text{if } \sigma < 0 \end{cases}$$

슬라이딩 모드 제어의 강인함은 불연속 함수 $\operatorname{sgn}(\sigma)$ 에 근거한 빠른 스위칭에 있으나 제어입력의 급격한 변화는 시스템의 체터링을 유발한다. 이와 같은 체터링을 피하는 방법으로 스위칭 평면 주위에 Fig. 1과 같은 얇은 경계층을 도입한다^(3,10). 여기서 Φ 는 경계층의 두께이고 $\epsilon = \Phi/\lambda^{(n-1)}$ 는 경계층의 폭이다.

$$B_1(t) = \{X, |\sigma(X, t)| \leq \Phi\}, \quad \Phi > 0 \quad (3.17)$$

경계층으로 끌어들임을 지속하기 위하여 Φ 는 시간에 따라서 변하며 실제 적용하기 위해서 식 (3.6)의 조건을 다음과 같이 수정한다.

$$|\sigma| \geq 0 \rightarrow \frac{1}{2} \frac{d}{dt} \sigma^2 \leq (\dot{\Phi} - \eta) |\sigma| \quad (3.18)$$

위 식을 만족하기 위하여 식 (3.16)의 제어법칙 $u(t)$ 는 다음과 같이 수정된다.

$$u = u_{eq} - K \operatorname{sat}(\sigma/\Phi) \quad (3.19)$$




Fig. 1 Construction of the boundary layer in the case $n=2$

여기서, sat 함수는 다음과 같다.

$$\operatorname{sat}(\sigma/\Phi) = \begin{cases} \sigma/\Phi & |\sigma/\Phi| < 1 \\ \operatorname{sgn}(\sigma/\Phi) & \text{otherwise} \end{cases}$$

3.2 신경회로망 제어

전형적인 신경 회로망의 구조는 Fig. 2와 같이 신경세포(neuron), 연결가중치(weight), 활성화함수(activation function)으로 이루어지며 바이어스 b_k 는 활성화함수의 입력 값을 증가시키거나 감소시킨다.

Fig. 2에서 k 번째 뉴우런은 다음과 같이 표현할 수 있다.

$$y_k = \phi(u_k + b_k) \quad (3.20)$$

여기서,

w_{kj} : 가중치, b_j : 바이어스

x_i : 입력, y_k : 비선형 함수의 출력이다.

입력층과 출력층 사이에 하나이상의 중간층(은닉층)이 존재하는 신경회로망을 다층 퍼셉트론(MLP : Multi Layer Perceptron)이라고 하며 신호의 흐름은 입력층 은닉층 출력층 방향으로 연결되어 있으며, 출력층에서 입력층으로 직접적인 연결은 존재하지 않는 신경회로망을 전방향(Feedforward) 신경회로망 이라고하고 출력층 으로부터 입력층으로의 영향이 있는 네트워크를 회귀(Recurrent)신경회로망 이라한다. 대부분의 다층 퍼셉트론은 역전파 알고리즘(Back-propagation Algorithm)을 사용하여 학습시킬 수 있으며 Fig. 3에 다층 퍼셉트론의 구조를 나타낸다.

신경회로망은 y 개의 입력벡터에 연결된 n 개의 뉴우런 층으로 구성되며 다음식과같이 표현된다.

$$y = \phi_i(W_i \phi_{i-1}(W_{i-1} \dots \phi_1(w_1 x - b_1) + \dots + b_{i-1}) + b_i) \quad (3.21)$$

여기서, W_i 는 i 번째 층과 관련된 가중치행렬이고, ϕ_i 는 i




Fig. 2 Nonlinear model of a neuron




Fig. 3 The structure of MLP

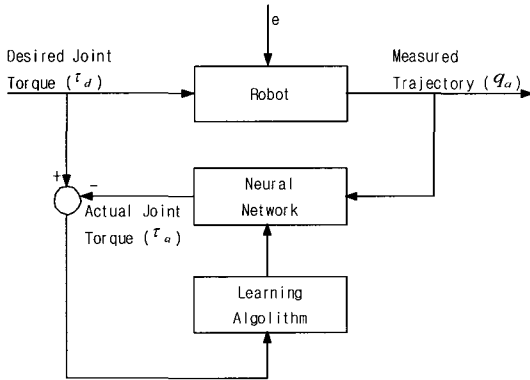


Fig. 4 off-line learning of the inverse dynamics of the manipulator by neural network

번째 층과 관련된 비선형 연산자, b_i 는 i 번째 층의 각 절점에 관련된 임계 값 또는 바이어스 값이다.

매니플레이터의 역 동역학의 오프라인학습을 위한 다층 퍼셉트론 회로망은 Fig. 4에서 보이는 바와 같다. 구동 토크 τ_a 는 로봇의 실제궤적 q_d 를 나타내도록 로봇을 구동하는데 사용하며 신경회로망에서는 실제궤적 q_d 를 입력으로 받고 모터를 구동하기위한 토크 τ_a 를 생성한다.

학습 알고리즘으로는 목적함수를 최소화시키는 경사하강 추적법(Gradient Descent Method)에 기초한 역전파 알고리즘을 사용하며, 신경회로망의 목적함수 E 는 다음과 같이 모든 학습패턴의 오차 제곱을 최소화하도록 설정한다.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.22)$$

$$e_j(n) = y_{dj}(n) - y_j(n)$$

여기서, $E(n)$ 은 목적함수이고 $y_{dj}(n)$ 는 목적값, $y_j(n)$ 는 실제 출력값이다.

델타법칙에 근거하는 역전파 알고리즘은 기울기에 의존하므로 목적함수를 가중치로 미분하면 다음과 같다.

$$\frac{\partial E}{\partial w_{ij}} = \begin{bmatrix} \frac{\partial E}{\partial w_{1j}} \\ \frac{\partial E}{\partial w_{2j}} \\ \vdots \\ \frac{\partial E}{\partial w_{nj}} \end{bmatrix} \quad (3.23)$$

w_{ij} 를 i 번째 입력과 j 번째 출력사이의 가중치라 정의하면 가중치값에 대한 음의 그라디언트를 연쇄법칙을 사용하여 구하면 다음과 같다.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial w_{ij}} \quad (3.24)$$

$$= (y_{dj} - y_j) \frac{\partial (y_{dj} - y_j)}{\partial y_j} \frac{\partial y_j}{\partial w_{ij}}$$

$$= -(y_{dj} - y_j) \frac{\partial y_j}{\partial w_{ij}}$$

$$\frac{\partial y_j}{\partial w_{ij}} = \frac{\partial y_j}{\partial v_j} \frac{\partial v_j}{\partial w_{ij}} = \phi'(v_j) x_i \quad (3.25)$$

여기서,

$$v_j = \sum_{i=0}^n w_{ij} x_i \quad : \text{선형결합 출력}$$

$$y_j = \phi_j(v_j) \quad : \text{비선형함수 출력이며}$$

$\frac{\partial y_j}{\partial v_j}$ 를 계산하기 위해서는 $y_j = \phi_j(v_j)$ 는 미분가능 함수

이어야 한다.

식 (3.25)를 식 (3.24)에 대입해서 정리하면 목적함수를 가중치로 미분한 값은 다음과 같이 나타낸다.

$$\frac{\partial E}{\partial w_{ij}} = -(y_{dj} - y_j) \phi'(v_j) x_i \quad (3.26)$$

$$= e_j \phi'(v_j) x_i$$

가중치의 변화율은 음의 그라디언트로 다음과 같고

$$\Delta w_{ij} = -\eta e_j \phi'(v_j) x_i \quad (3.27)$$

$$= \eta \delta_j x_i$$

여기서, η 는 학습을 이다.

목적값과 실제값 사이의 에러를 줄여나가는 일반화된 델타법은 다음과 같이 나타낼 수 있다.

$$\begin{aligned} w_{ij}(n+1) &= w_{ij}(n) + \eta(y_{dj}(n) - y_j(n))x_i \\ &= w_{ij}(n) + \Delta w_{ij}(n) \\ &= w_{ij}(n) + \eta \delta_j x_i \end{aligned} \quad (3.28)$$

온라인신경회로망제어는 Fig. 5와 같이 슬라이딩모드 제어의 등가제어 입력항과 추가제어 항은 다층퍼셉트론 신경회로망에서 계산되어 그 결과를 더하여 매니플레이터의 제어입력으로 보낸다.

신경망으로부터 출력된값 U_{eqk} 는 원하는값 U_{eqk}^d 와 비교하여 오차 e_k 를 만들며

$$e_k = U_{eqk}^d - U_{eqk} \quad (3.29)$$

최소화할 목적함수는 모든 오차의 합으로 다음과 같다.

$$E = \frac{1}{2} \sum_{k=1}^2 (U_{eqk}^d - U_{eqk})^2 \approx \frac{1}{2} \sum_{k=1}^2 e_k^2 \quad (3.30)$$

오차를 최소화하기위해 가중치값을 갱신하기위한 출력층의 가중치 변화율은 다음과 같다.

$$\begin{aligned} \Delta w_{jk} &= -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial U_{eqk}} \frac{\partial U_{eqk}}{\partial v_k} \frac{\partial v_k}{\partial w_{jk}} \\ &= -\eta e_k \phi'(v_k) u_{eqk} \\ &= \eta \delta_k U_{eqk} \end{aligned} \quad (3.31)$$

$$\delta_k = -\frac{\partial E}{\partial v_k} = -\frac{\partial E}{\partial U_{eqk}} \frac{\partial U_{eqk}}{\partial v_k} = e_k \phi'(v_k) \quad (3.32)$$

출력이 다음과 같은 하이퍼블릭 탄젠트 함수이면




Fig. 5 Overall system with proposed controller

$$\phi(v_k) = \frac{1 - e^{-v_k}}{1 + e^{-v_k}} \quad (3.33)$$

시그모이드 함수의 미분은 다음과 같다.

$$\phi'(v_k) = \frac{1}{2} (1 - \phi^2(v_k)) \quad (3.34)$$

은닉층의 가중치 변화는 다음으로 계산한다.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \mu \delta_j U_{eqi} \quad (3.35)$$

여기서, $\delta_j = (\sum_{k=1}^2 \delta_k w_{jk}) \phi'(U_{eqk})$ 이다.

4. 모의시험 및 고찰

본 절에서는 Fig. 6과 같은 2링크 매니플레이터에 대해서 Fig. 7과 같은 오프라인 신경회로망 제어기와 온라인 신경회로망 슬라이딩모드 제어기에 대하여 시뮬레이션을 수행하여 두 경우의 제어성능을 비교하였다.

2링크 매니플레이터의 운동방정식은 2장의 오일러 라그랑지 방정식으로부터

$$\begin{bmatrix} M_{11}(\theta_2) & M_{12}(\theta_2) \\ M_{12}(\theta_2) & M_{22}(\theta_2) \end{bmatrix} \begin{bmatrix} \ddot{\theta}_1 \\ \ddot{\theta}_2 \end{bmatrix} + \begin{bmatrix} -A_{12}(\theta_2)\dot{\theta}_2 - A_{12}(\theta_2)(\dot{\theta}_1 + \dot{\theta}_2) \\ A_{12}(\theta_2)\dot{\theta}_1 & 0 \end{bmatrix} \begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix} + \begin{bmatrix} g_1(\theta_1, \theta_2)g \\ g_2(\theta_1, \theta_2)g \end{bmatrix} = \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \end{bmatrix}$$




Fig. 6 Two-link manipulator




Fig. 7 Neural Network controller based on off-line learning

와 같이 유도할 수 있으며

여기서,

$$M_{11} = (m_1 + m_2)r_1^2 + m_2r_2^2 + 2m_2r_1r_2\cos\theta_2$$

$$M_{12} = m_2r_2^2 + m_2r_1r_2\cos\theta_2$$

$$M_{22} = m_2r_2^2$$

$$A_{12} = m_2r_1r_2\sin\theta_2$$

$$g_1 = (m_1 + m_2)r_1\cos\theta_1 + m_2r_2\cos(\theta_1 + \theta_2)$$

$$g_2 = m_2r_2\cos(\theta_1 + \theta_2)$$

이다.

본 모의실험에서 사용된 파라미터는 다음과 같다.

$$r_1 = 1, \quad r_2 = 0.8, \quad m_1 = 0.5, \quad m_2 = 0.5$$

또한 로봇에 작용하는 미지의 외란은 다음과 같이 가정하였다.

$$\begin{bmatrix} d_1 \\ d_2 \end{bmatrix} = \begin{bmatrix} 0.5 \cdot \sin(5t) + 2\theta_1 \\ 0.5 \cdot \sin(3t) + 2\theta_2 \end{bmatrix}$$

오프라인 신경회로망은 3개의 층(은닉층 1개 포함)으로 구성되며 입력층에 6개의 뉴uron, 출력층에 2개의 뉴uron, 은닉층에 24개의 뉴uron으로 구성한다. 역동역학의 오프라인 학습동안 예러가 수렴함을 Fig. 8에서 보여주고 있다.

이것은 신경회로망이 로봇의 역동역학 학습을 아주 잘 수행하고 있음을 관측할 수 있다. 오프라인 제어기의 위치추종 응답은 Fig. 9에 나타내었다. 시뮬레이션에서와 같이 이러한 제어기는 모델의 불확실성이나 외란이 없을 경우 잘 수행된다.

그러나 실제로는 시스템의 동특성이나 외란을 정확히 아는 것은 불가능하고 오프라인 학습이 미래에 발생할 수 있는 모든 가능한 상황을 포함하여 보장하지는 못한다. 따라서 이러한 종류의 제어기는 시스템이나 환경의 변화에 적응하지 못하기 때문에 이상적이지 못하여 온라인 신경회로망 제

기를 제안한다.

온라인 신경회로망에서 등가제어입력을 계산하기 위한 구조는 입력층에 12개의 뉴uron, 중간 은닉층에 24개의 뉴uron, 출력층에 2개의 뉴uron을 가지는 구조로 되어있으며 은닉층의 비선형 활동함수는 하이퍼볼릭 탄젠트 함수 $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 를 사용하고, 출력층의 선형함수는 $f(x) = x$ 를 사용하였다.

모든 가중치는 ± 0.5 의 범위 내에서 랜덤하게 초기화시켰다.

Fig. 9에서 모델링 되지 않은 외란이 존재할 때의 온라인 신경회로망 제어기를 사용한 매니플레이터 관절의 위치추종 응답을 보여주고 있으며, Fig. 10과 Fig. 11에서는 추종응답을 Fig. 12와 Fig. 13에서는 추종에러를 나타내고 있다. 결




Fig. 9 Off-line position tracking response for joint 1,2 without disturbance




Fig. 10 On-line position tracking response for joint 1 with disturbance




Fig. 11 On-line position tracking response for joint 2 with disturbance




Fig. 8 Convergence error of the neural network in the off-line learning of the inverse dynamics

과에서 보듯이 신경회로망 슬라이딩 모드 제어기의 정상상태 응답이 외란이 존재함에도 불구하고 원하는 출력을 잘 추종하고 있음을 보여주고 있다. Fig. 14과 Fig. 15는 각 관절의 등가제어입력을 보여주고 있으며 첫 번째 관절이 두 번째 관절의 관성부하를 포함하고 있어 크게 나타남을 볼 수 있다.

Fig. 16과 Fig. 17은 시스템의 불확실성에 대한 강인성을

확인하기위해 식 3.2의 시스템 모델의 공칭 파라미터에 값에 $\pm 5\%$ 의 변화를 주어 모의 실험한 시스템의 응답이다. 그림에서 보는 바와 같이 추정 값의 변화에도 불구하고 시스템의 인식이 잘 이루어지고 있으며 이 경우 불확실성에 대한




Fig. 12 On-line position tracking error for joint 1(θ_1)




Fig. 16 On-line position tracking response for joint 1 with unmodelled parameter




Fig. 13 On-line position tracking error for joint 2(θ_2)




Fig. 17 On-line position tracking response for joint 2 with unmodelled parameter




Fig. 14 Equivalent control input of joint 1 using NN




Fig. 18 Equivalent control input of joint 1 using NN with unmodelled parameter




Fig. 15 Equivalent control input of joint 2 using NN




Fig. 19 Equivalent control input of joint 2 using NN with unmodelled parameter

오차의 영향이 첫 번째 관절의 위상이 바뀌는 지점에서 좀 더 크게 나타나고 있으며 이는 두 번째 관절의 관성부하의 영향을 많이 받고 있는 것으로 판단된다. 그럼에도 불구하고 단말장치가 연결되어있는 두 번째 관절은 원하는 궤적을 잘 추종하고 있음을 보여주고 있다.

Fig. 18과 Fig. 19에서는 모델의 추정 값에 변화를 줄었을 경우 등가제어 입력을 나타내고 있다.

위의 결과를 검토하면 오프라인 신경회로망 제어에서는 모델의 불확실성이나 외란이 없을 경우 목표 값을 잘 추종하나 약간의 정상상태 오차가 존재하고 있으며 온라인 신경회로망 슬라이딩 모드 제어에서는 초기 학습시간동안 과도상태의 유효한 오차가 관측되고 있으나 과도시간이 지난 후 이러한 오차는 급격히 감소됨을 볼 수 있다. 또한 외란 및 시스템 모델의 추정 값의 변화에도 불구하고 시스템의 출력 응답 특성이 잘 추종함을 알 수 있다.

5. 결론

본 논문에서는 시스템의 불확실성의 영향을 최소화하고 슬라이딩모드 제어의 단점인 채터링을 줄이기 위해 신경회로망을 이용한 슬라이딩 모드제어를 제안하였다. 슬라이딩 모드 제어의 안정성은 리아프노브(Lyapunov) 함수를 사용함으로써 보장하였고 제안된 신경 회로망은 다층퍼셉트론 이론을 사용하였다. 제안된 제어를 2링크 매니플레이터에 적용하여 모의실험으로 그 성능을 확인하여 다음과 같은 결론을 얻었다.

- (1) 슬라이딩모드의 등가제어 입력 값을 신경회로망에 의해 결정함으로써 슬라이딩모드 제어의 빠른 스위칭 제어입력 대신 신경회로망의 연속적인 제어입력의 선택으로 채터링 문제를 극복할 수 있음을 보였다.
- (2) 미지의 외란으로 가정한 신호에 대하여 강인한 성질을 가지고 있음을 알 수 있다.
- (3) 또한 부하의 변동 및 시스템의 파라미터 변화 등 불확실성이 존재하는 비선형 시스템의 제어에 강인한 출력응답 특성을 확인 하였다.

후 기

본 연구는 2006년도 숭실대학교 학술논문 연구비 지원으로 수행 되었습니다.

참고 문헌

- (1) Yang, H. S, Jung, Y. C and Lee, G. B, 2001, "Continuous-Time Controller Design using Identification of Feedback System in Frequency Domain," *Proc. of the KSME*, Vol. 1, No. 2, pp. 664~669.
- (2) Utlin, V. I. and Darkunov, S. V., 1992, "Sliding Mode Control in Dynamic System," *Int. J. Control*, Vol. 55, No. 4, pp. 1029~1037.
- (3) Slotine J. J. E., 1984, "Sliding Control Design for Non-linear System," *Int. J. Control*, Vol. 40, No. 2, pp. 421~434.
- (4) Zhou, F., Fisher, D. G., 1992, "Continuous Sliding Mode Control," *Int. j. Control*, Vol. 55, pp. 313~327.
- (5) Niu, Y., Lam, J., Wang, X. and Ho, D. W. C., 2003, "Sliding-mode Control for nonlinear state-delayed system using neural-network approximation," *IEE Proc. Control Theory Appl.*, Vol. 150. No. 3, pp. 233~239.
- (6) Lin, F. J., Shieh, P. H. and Shen, P. H., 2006, "Robust Recurrent-neural-network Sliding - mode Control for the X-Y table of a CNC Machine," *IEE Proc. Control Theory Appl.*, Vol. 153, No. 1, pp. 111~123.
- (7) Hong, K. S. and Lee, G. B., 2000, "Sliding Mode Control based on Recurrent Neural Network," *Proc. of KSMTE*, Vol. 2, pp. 135~139.
- (8) Spong, M. W. and Vidyasagar, M., 1989, *Robotics Dynamics and Control*, Jone Wiley & Sons.
- (9) Slotine, J. J. E. and Li, W., 1991, *Applied Nonlinear Control*, Prentice-Hall, Inc. Englewood Cliffs, N. J.
- (10) Palm, R., 1992, "Sliding mode Fuzzy Control," *IEEE Int. Conf. on fuzzy systems*, pp. 519~526.