

신경회로망을 이용한 유압 스텐슬링 로봇의 정확한 위치 제어

Precise Position Control of Hydraulic Driven Stenciling Robot Using Neural Network

정 슬

충남대학교 메카트로닉스 공학과

Tel: +82-42-821-6876; Fax: +82-42-825-9225; e-mail: jungsl@hanbat.chungnam.ac.kr

Abstract

In this paper, accurate position control of a stenciling robot manipulator is designed. The stenciling robot is required to draw lines and characters on the pavement. Since the robot is huge and heavy, the inertia is expected to play a major role in the tracking performance as desired. Here we are proposing neural network control scheme for a computed-torque like controller for the stenciling robot. On-line compensation is achieved by neural network. Simulation studies with stenciling robot are carried out to test the performance of the proposed control scheme.

Keywords : Position Control, Stenciling robot, Neural network

1 서론

스텐슬링 로봇은 최근에 미국 캘리포니아 대학에서 도로 위에 글자나 사인을 페인트칠하는 목적으로 제작되었다. 스텐슬링 로봇은 2자유도를 갖고 있으며 구조적으로 크기가 매우 크고 무겁기 때문에 하이드릴릭 모터로 제어한다. 스텐슬링 로봇 설계의 목적은 제어를 간단하게 만드는 것이므로 간단한 PID제어를 사용하였다. 하지만 선형제어기로는 비선형 불확실성을 보상하지 못하므로 일반적으로 계산 토크방식을 사용해서 선형화 한 뒤에 제어하는데 이 방식도 로봇의 모델을 정확하게 알아야 하는 단점이 있다. 따라서 로봇의 동적 모델의 오차와 로봇 팔끝에 달려있는 페인트 분사 용 모터 시스템의 무게를 무시하므로 정확한 위치제어를 할 수 없게 되기때문에 글자나 사인을 바르게 그릴 수 없게 된다.

로봇팔 자체의 무게는 역 균형 스프링(counter balance spring)이 받치고 있으므로 기계적으로 보상이 된다. 로봇이 천천히 움직일 경우에 관성을 제외한 다른 동적요소가 로봇의 움직임에 미치는 영향은 작게 된다.

따라서 로봇의 모든 동적 모델을 고려하지 않고, 단지 관성의 대략적인 값 만을 갖는 간단화 된 계산 토크방식을 사용하여 로봇을 제어하고자 한다. 팔끝에 설치된 하이드릴릭 모터로 제어되는 분사식 페인팅 시스템의 무게는 보통 35Kg 이상되지만 그 무게를 정확하게 모르므로 그에 의한 영향을 무시할수 없다. 또한 각 조인트의 마찰력이나 백래쉬 등의 불확실성에 의한 영향도 무시할 수 없다. 따라서 관성 및 다른 동적 영향의 보상은 로봇 경로 수행에 직접적인 영향을 미치게 된다.

최근에는 이러한 비선형 불확실성을 신경회로망으로 보상하는 방식에 대해서 지속적인 연구가 진행되고 있는 실정이다[1-4]. 이 논문에서는 간단화 된 계산 토크방식을 기본으로 제어를 설계한 뒤에 불확실성을 보상하기위해 신경회로망을 사용하는 제어 방식을 제안한다. 기존의 신경회로망 보상방식과는 달리 기준경로에 보상하는 기준 경로 보상 방식을 사용한다. 로봇이 글자를 쓰는 작업을 수행하는 시뮬레이션을 통해 제안하는 제어 방식의 성능을 알아본다.

2 간단한 계산 토크제어 방식

로봇의 동적 방정식은 다음과 같다.

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

여기서 q, \dot{q}, \ddot{q} 은 $n \times 1$ 벡터의 각각 각위치, 각속도 그리고 각가속도 이다. $D(q)$ 는 the $n \times n$ 관성행렬; $C(q, \dot{q})\dot{q}$ 는 $n \times 1$ 코리올리스와 원심력의 벡터, $G(q)$

는 $n \times 1$ 의 중력, τ_f 는 $n \times 1$ 각조인트에서의 마찰력 벡터이고, τ 는 $n \times 1$ 벡터의 조인트 토크이다.

로봇이 천천히 움직일 경우에는 코리올리스와 원심력의 영향이 관성에 비해서 매우 작다. 스텐슬링 로봇의 경우에는 로봇 팔이 역균형 스프링에 의해서 기계적으로 받혀지므로 중력은 보상된다.

이러한 상황에서 그림1에는 간단화 된 제어 방식을 보여준다.

그림1에서 보면 제어 입력 시그널 u 는 다음과 같다.

$$u = \ddot{q}_d + K_D(\dot{q}_d - \dot{q}) + K_P(q_d - q) \quad (2)$$

여기서 K_D, K_P 는 $n \times n$ 제어기의 이득 행렬이다. 로봇의 동적 요소 $C(q, \dot{q})\dot{q}$ 의 값을 우리는 모르고, 관성도 대략적인 값 $\hat{D} = \text{diag}[\alpha, \beta]$ 을 사용한다고 하자.

이 경우에 제어 법칙은 다음과 같다.

$$\tau = \hat{D}u + \hat{G} \quad (3)$$

식(1)(2)(3)을 합성하면 다음과 같은 위치오차의 이차 방정식이 된다.

$$\ddot{e} + K_{D\hat{e}} + K_{P\hat{e}} = \hat{D}^{-1}(\Delta D\ddot{q} + \Delta G + \tau_f) \quad (4)$$

여기서 $\Delta D = D - \hat{D}$, $\Delta G = G - \hat{G}$ and $e = q_d - q$ 이다. 식(4)에서 보면 로봇의 동적 모델에 오차가 생길 경우에 위치 오차가 영으로 수렴하지 않고 항상 존재한다. 이러한 경로수행 오차는 불확실한 값의 관성과 알지 못하는 동적 요소에 의한 것인데 다음장에서는 신경회로망을 사용해서 보상하는 알고리즘을 제안한다.

3 신경회로망 보상 방식

비선형 맵핑 도구로 알려진 신경회로망은 여러 분야에서 성능이 입증되었다[1,2]. 제어시스템에서 신경회로망의 목적은 공정의 불확실성을 보상하는 것이다. 신경회로망의 가중치 값들은 트래킹 오차에 따라 적응제어식으로 매번 바뀐다.

전통적으로 다른 방식에서는 신경회로망의 보상 신호는 토크에 더해졌지만 이 논문에서 기준경로에 더해진다.

제안하는 제어방식의 그림2에서 보상신호가 경로에 더해진 제어 입력 u 는 다음과 같다.

$$u = K_D(\dot{q}_d - \dot{q}) + K_P(q_d - q + \Phi) \quad (5)$$

여기서 Φ 는 신경회로망의 출력이다.

보상 신호 Φ 는 K_P 에 곱하여 저서 필요한 토크를 생성한다. 식 (3)(5)과 (1)을 합성하면 다음과 같은 오차 방정식이 된다.

$$v = \ddot{e} + K_{D\hat{e}} + K_{P\hat{e}} = \hat{D}^{-1}(\Delta D\ddot{q} + h + \Delta G + \tau_f) - K_P\Phi \quad (6)$$

$v = 0$ 으로 수렴후에 이상적인 신경회로망의 출력 Φ 는 다음과 같다.

$$\Phi = K_P^{-1}\hat{D}^{-1}(\Delta D\ddot{q} + h + \Delta G + \tau_f) \quad (7)$$

여기서 주의할 것은 신경회로망의 보상 신호값의 크기가 제어기 이득 K_P 에 의해서 나누어 진다는 것이다. 따라서, 보상될 불확실성의 값이 작아져서 신경회로망의 비선형 영역에 놓이게 되므로 비선형의 특성을 잘 인식할 수 있게 된다.

4 신경회로망 학습구조

여기서 보상기로 사용된 신경회로망은 입력 버퍼, 비선형 히든층 그리고 선형인 출력층으로 구성되는 기본적인 feedforward 형태이다.

입력 $X = [q^T \dot{q}^T \ddot{q}^T]^T$ 는 입력버퍼와 히든층 사이의 가중치 (w_{ij}^1)과 곱해져서 히든층에서 합해진다. 합해진 값은 다음과 같은 비선형 활성화 함수를 통하게 된다.

$$f(\cdot) = \frac{1}{1 + \exp(-(\cdot))} \quad (8)$$

활성화된 값은 히든층과 출력층 사이의 가중치값 (w_{jk}^2)와 곱하여지고 출력에서 각각 더하여 진다. 그러므로 신경회로망의 n 번째 출력값 ϕ_n 은 다음과 같이 입력으로부터 계산되어진다.

$$\phi_n = \left[\sum_{j=1}^{n_H} w_{jk}^2 \left(\frac{1}{1 + \exp(-(\sum_{i=1}^{n_I} x_i w_{ij}^1 + b_j^1))} \right) \right] + b_k^2 \quad (9)$$

여기서 n_I 는 입력의 수, n_H 는 히든 유닛의 수이다.

식(6)으로부터 오차 방정식을 작게 하려면 다음과 같은 목적함수를 사용한다.

$$E = \frac{1}{2} v^T v \quad (10)$$

여기서 $v = \ddot{e} + K_{D\hat{e}} + K_{P\hat{e}}$ 이다. 목적함수 E 의 그라디언트는 다음과 같이 식(10)을 미분한 다음 식(6)으로부터 얻어진다.

$$\frac{\partial E}{\partial w} = \frac{\partial v^T}{\partial w} v = -K_P \frac{\partial \Phi}{\partial w} \quad (11)$$

신경회로망의 가중치는 매번 바뀌는데 다음과 같다.

$$\Delta w(t) = -\eta \frac{\partial E}{\partial w} + \alpha \Delta w(t-1) \quad (12)$$

여기서 η 는 학습률이고 α 는 모멘텀 상수이다.

식(12)에서 각 가중치 값을 바꾸어 주기 위한 자세한 백프로파게이션의 법칙을 얻을 수 있다.

$$\Delta w_{ij}^1(t) = \eta s_j (1 - s_j) x_i \left[\sum_{k=1}^{n_o} v_k w_{jk}^2 \right] + \alpha \Delta w_{ij}^1(t-1)$$

$$\Delta w_{jk}^2(t) = \eta v_k s_j + \alpha \Delta w_{jk}^2(t-1)$$

$$\Delta b_j^1(t) = \eta s_j (1 - s_j) \left[\sum_{k=1}^{n_o} v_k w_{jk}^2 \right] + \alpha \Delta b_j^1(t-1)$$

$$\Delta b_k^2(t) = \eta v_k + \alpha \Delta b_k^2(t-1) \quad (13)$$

$$s_j = \frac{1}{1 + \exp(-(\sum_{i=1}^{n_i} x_i w_{ij}^1 + b_j^1))} \quad (14)$$

$$s_k = \sum_{j=1}^{n_o} s_j w_{jk}^2 + b_k^2 \quad (15)$$

여기서 n_o 는 출력의 수이고, s_j 는 히든층의 j 번째 유닛, 그리고 s_k 는 출력의 k 번째 유닛이다. ε_k 는 벡터 ε 의 k 번째 요소이다.

5 시뮬레이션 연구

그림 3에 나타난 2축 스텐슬링 로봇을 가지고 경로 수행 능력을 조사한다. 로봇의 관성 $\hat{D}(q)$ 는 실제 관성 $D(q)$ 의 대략적인 값인 $\hat{D} = \text{diag}[1620, 180]$ 로 설정되었다. 로봇의 모델은 대략적인 값인 관성 값은 실제 값보다 50%로 정하여 지고 코리올리스나 원심력은 모른다고 가정한다. 또한 35Kg 되는 페인팅 시스템이 로봇의 팔 끝에 달려있다고 가정을 한다. 스텐슬링 로봇은 가상적으로 도로위에 'L'과 'O'자를 각각 페인트칠한다고 하자.

제어기 이득은 "L"자를 쓰는 경우에 $K_D = \text{diag}[40, 40]$, $K_P = \text{diag}[400, 400]$ 이고 "O"를 쓰는 경우에 있어서는 $K_D = \text{diag}[20, 20]$, $K_P = \text{diag}[100, 100]$ 를 사용하였다.

히든층에서는 6개의 신경유닛이 사용되었고, 초기 가중치 값은 무작위로 정해졌으며 학습률은 각 경로마다 최적화 되었다. 그림 4는 스텐슬링 로봇이 "L"자를 쓰고 있는 경우를 나타낸다. 신경회로망을 사용할 때와 사용하지 않을 경우의 성능이 확실하게 차이가 남을 볼 수 있다. 신경회로망으로 보상이 되었을 경우는 주어진 경로와 실제 경로의 분간이 어렵다. 학습률 η 는 0.00001로 최적화 되었다.

또 다른 형태의 작업으로 로봇이 원을 그리는 경우이다. 그림 5에서는 로봇의 원경로를 따라가는 것을 보여준다. 신경회로망으로 보상이 된 경우와 되지 않은 두 경우를 비교해 보여 주고 있다. 로봇이 글자 "O"를 쓰는데 걸리는 시간은 8초이다. 이 경우에

학습률은 0.00005로 최적화 되었다. 초기상태에서 약간의 오버슈트가 관찰되었으나 신경회로망이 곧 보상하므로 잘 따라가는 것을 볼수있다. 그림 5에서 보듯이 신경회로망의 성능이 뛰어남을 알 수 있다. 신경회로망으로 보상이 되지 않았을 경우에는 실제 주어진 경로를 따라가지 못하고 커다란 오차를 나타낸다. 그림 5에 나타난 경로 오차는 실제 로봇에도 나타났다. 그림 6은 각 조인트의 신경회로망의 보상출력 신호를 나타낸다.

6 결론

이 논문에서는 로봇의 동적 모델이 확실하지 않은 경우에 발생하는 경로 오차를 줄이기 위해 신경회로망을 보상기로 사용하는 제어 방식을 알아보았다. 대략적인 관성의 정보를 기본으로 간단화 된 계산 토크방식하에서 수행한 로봇의 경로는 신경회로망을 사용하므로 오차를 현저하게 줄일 수 있었다.

여기서 제안하는 방식의 중요한 점은 이미 PD나 PID 제어 방식으로 제어된 로봇을 제어기를 바꿈없이 경로를 조작하므로 불확실성을 보상할 수 있다는 것이다.

참고문헌

- [1] S. Liu and H. Asada, "Teaching and learning of deburring robots using neural networks", *International Conference on Robotics and Automations*, pp. 339-345, 1993
- [2] A. Ishiguro, T. Furuhashii, S. Okuma and Y. Uchikawa, "A Neural Network Compensator for Uncertainties of robot manipulator", *IEEE Trans. on Industrial Electronics*, vol. 39, pp. 61-66, 1992
- [3] M. Kawato, K. KuruKKawa and R. Suzuki, "A Hierarchical Neural Model for learning of Voluntary Movements", *Biological Cybernetics*, pp. 169-185, 1987
- [4] S. Jung and T. C. Hsia, "On an Effective Design Approach of Cartesian Space Neural Network Control of Robot Manipulators", *Robotica*, vol. 15, Part 3, pp. 305-312, 1997

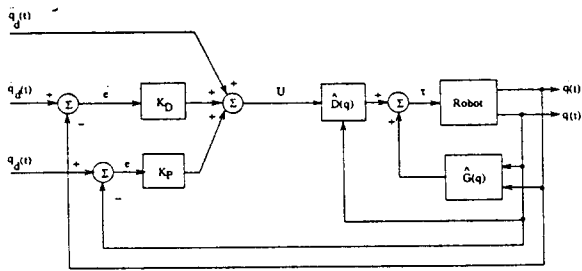


Figure 1: Computed Torque like Control Structure

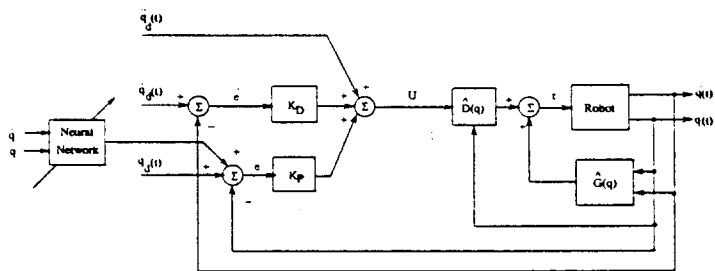


Figure 2: Proposed NN Computed Torque like Control Structure

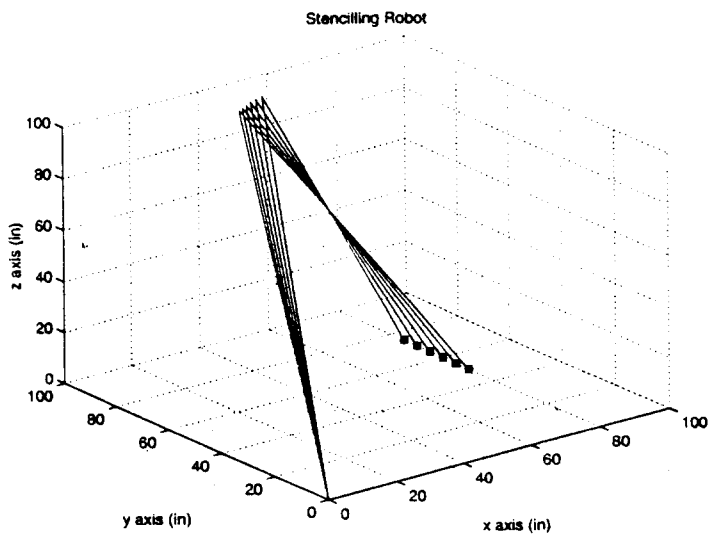


Figure 3: Stenciling Robot Structure

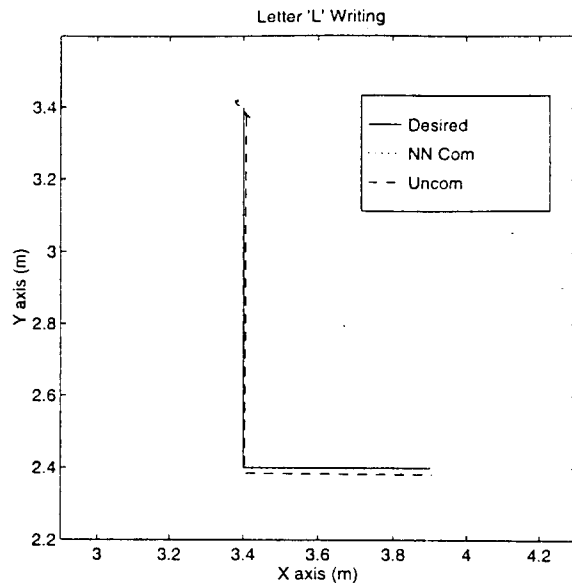


Figure 4: Writing a character "L" in Cartesian Space

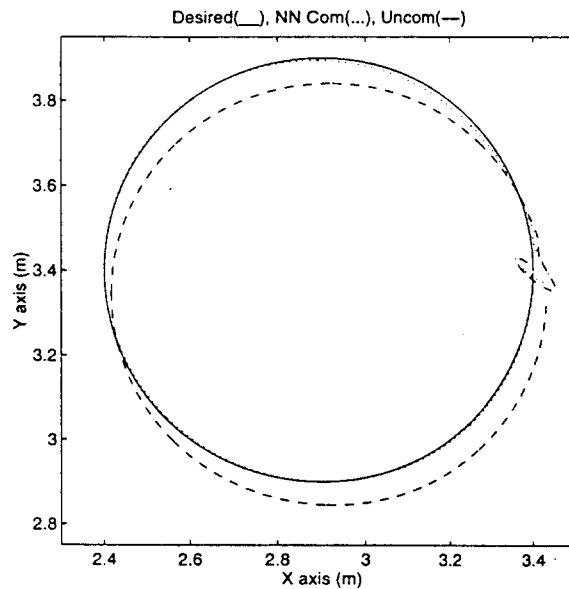


Figure 5: Writing a Character "O" in Cartesian Space

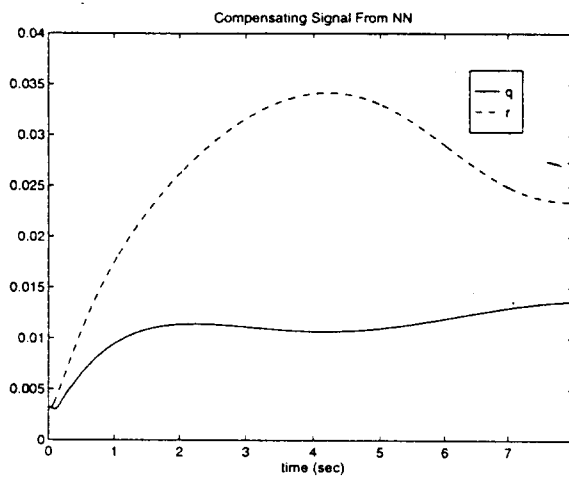


Figure 6: Neural network compensating signal