

불확실성이 있는 로봇 시스템의 역모델 학습에 의한 신경회로망 제어

Neural Network Control by Learning the Inverse Dynamics of Uncertain Robotic Systems

김성우, 이주장
(Sung-Woo Kim and Ju-Jang Lee)

Abstract : This paper presents a study using neural networks in the design of the tracking controller of robotic systems. Our strategy is to put to use the available knowledge about the robot manipulator, such as estimation models, in the controller design via the computed torque method, and then to add the neural network to control the remaining uncertainty. The neural network used here learns to provide the inverse dynamics of the plant uncertainty, and acts as an inverse controller. In the simulation study, we verify that the proposed neural network controller is robust not only to structured uncertainties, but also to unstructured uncertainties such as friction models.

Keywords: neural network control, inverse learning, robot system, uncertainty

I. 서론

로봇 매니플레이터의 추적제어 (tracking control)는 로봇 공학에 있어서의 매우 중요한 문제로 최근에 집중적으로 연구되고 있는 분야이다. 추적제어라는 것은 로봇의 각각의 조인트에 제어입력을 가하여 미리 정해 놓은 기준경로 (desired trajectory)를 따라갈 수 있도록 하는 것으로서 유연 생산 시스템 (flexible manufacturing)의 구현을 위하여는 고속·고정밀의 추적제어가 반드시 요구된다고 하겠다.

일반적으로 로봇 매니플레이터의 모델 및 불확실성 등에 대한 정보를 완전히 알고 있다면, 위와 같은 추적제어는 CTM (computed torque method)를 사용함으로써 얻어질 수 있다 [1]. 그러나 실제 로봇에는 구조화 된 또는 구조화 되지 않은 불확실성 (structured and/or unstructured uncertainty)이 존재한다. 구조화된 불확실성이란 로봇의 부하 중량의 변화와 같이 모델의 구조는 알고 있으나 그 모델의 파라미터들을 모르는 경우이고, 구조화되지 않은 불확실성이란 외란, 마찰력등과 같은 경우를 말한다. 따라서 이러한 불확실성으로 인하여 로봇을 CTM만으로 제어하여서는 우리가 원하는 제어성능을 얻을 수 없게 된다.

이러한 로봇의 불확실성이 있는 경우의 제어를 위하여 그 동안은 적응제어기를 이용한 제어방식들이 많이 제안되어 왔었다 [2-4]. 이들 적응제어기는 로봇에 대한 사전 지식이 없더라도 사용될 수 있는 장점이 있으나, 이를 위한 실시간 로봇 파라미터들의 동정화에 많은 시간과 계산이 필요하게 된다. 더욱이 이러한 적응제어 방식들은 측정잡음 (measurement noise)에 매우 민감하고, 구조화되지 않은 불확실성이 있을 경우에는 효과적이지 않은 단점이 있다.

최근들어 이러한 단점들을 극복하기 위하여 신경회로망의 학습과 일반화 (learning and generalization) 능력 [5-8]을 이용한 로봇 매니플레이터의 제어가 활발히 연구되어 왔다 [8-13]. Ishiguro [9]는 신경회로망과 CTM을 결합한 방식을 제안하여 사용하였다. 이 방법에서는 신경회로망이 로봇의 불확실성을 보상 (compensation)하는데 사용되었다. 그러나 이러한 불확실성의 보상을 위하여 추가로 어떤 '모델 다이내믹스 (model dynamics)'를 따로 계산하여야 했으며, 또한 관절 가속도 (joint acceleration)도 필요하게 되는

단점이 있다. Saad [10]에 의하여는 신경회로망을 이용하여 로봇 시스템의 입·출력 관계를 모사함으로써 제어하는 방식이 제안되었다. 여기서는 관절 가속도를 측정할 필요는 없었으나, 대신에 이를 생성하는 또하나의 신경회로망이 필요하였다. Kawato [11-13]는 로봇의 경로추적제어에 그들이 제안한 '되먹임 오차 학습 (feedback error learning)'을 사용하였다. 그들의 연구에서는 로봇이 sin과 cos으로 구성된 여러 개의 서브 시스템 (sub-system)으로 나뉘질 수 있으며, 신경회로망은 단지 이 서브 시스템들을 조합하는 데가 중치만 조절하는 것에 사용되었을 뿐이다. 하지만 로봇 시스템을 여러 개의 서브 시스템으로 분리하는 것은 시스템에 대한 많은 정보를 요구하게 되므로 실제 적용에는 적합하지 않다.

지금까지의 로봇의 추적제어에 대한 기존의 연구를 토대로 본 연구에서는 신경회로망을 이용한 새로운 제어 및 학습방법을 제안한다. 본 연구에서 접근하는 제어방식은 신경회로망만을 이용하여 모든 것을 제어하는 것이 아니라, 우리가 알고 있거나 쓸 수 있는 정보들은 CTM으로써 제어하고, CTM으로 할 수 없는 불확실한 양들은 신경회로망을 이용하여 제어하는 것이다. 이러한 접근방식은 신경회로망의 크기 (예를 들어 노드의 수)를 줄일 수 있게되며, 또한 학습에 필요한 학습시간도 단축할 수 있는 장점을 갖게 된다. 아울러 이러한 제어구조에 적합한 신경회로망의 학습법칙을 제안하고 제안된 학습법칙이 결국 로봇시스템의 불확실성에 대한 역 다이내믹 모델 (inverse dynamic model)을 학습하게 되는 것임을 보일 것이다. 이렇게 학습·제어되는 제안된 신경회로망은, 관절 가속도를 측정하거나 이를 만들어내기 위한 또다른 신경회로망을 필요로 하지 않고, 로봇 시스템을 여러 개의 작은 시스템 나눌 필요도 없으며, 신경회로망의 기준 출력 값 (desired output value)가 없어도 학습이 되며, 학습과 제어가 동시에 이루어 질 수 있는 장점이 있음을 보이게 될 것이다.

본 논문은 다음과 같이 구성된다. 우선 2장에서 로봇의 다이내믹 모델과 CTM제어기의 문제점과 신경회로망을 이용하여 극복하여야 할 불확실성으로 어떠한 것들이 있는가에 대하여 살펴본다. 다음 3장에서는 이러한 불확실성을 극복하기 위한 신경회로망 제어기와 그 학습법칙을 도출하여 낸다. 그리고 4장에서는 시뮬레이션으로써 2축 로봇에 대하여 제안된 신경회로망 학습·제어 방식을 검증한다. 5장에서는 기존의 되먹임 오차 학습법의 문제점 및 본 논문에서 제

안된 방식과의 차이점을 고찰·비교한 후 마지막으로 6장에서 결론을 내린다.

II. 로봇의 다이내믹 모델과 CTM 제어기

로봇의 다이내믹 모델은 일반적으로 아래와 같이 쓰여질 수 있다 [1-4,14,15].

$$\tau = M(q) \ddot{q} + N(q, \dot{q}) \tag{1}$$

여기서

$$N(q, \dot{q}) = C(q, \dot{q}) \dot{q} + g(q) + f(\dot{q}),$$

$M(q)$ 은 $n \times n$ 관성 행렬, $C(q, \dot{q})$ 은 구심력과 Coriolis 효과를 포함하는 $n \times n$ 행렬, $g(q)$ 는 중력을 나타내는 $n \times 1$ 벡터, $f(\dot{q})$ 는 점성과 쿨롱(Coulomb) 마찰력을 나타내는 $n \times 1$ 벡터, q 는 관절 벡터, 그리고 τ 는 관절에 가하여지는 토크(torque) 벡터이다.

만약에 로봇 모델에 대한 $M(q)$ 과 $N(q, \dot{q})$, 그리고 마찰력을 모두 알고 있다면, CTM 제어기는 다음과 같이 설계될 수 있다.

$$\tau = M(q) (\ddot{q}_d + K_v \dot{e} + K_p e) + N(q, \dot{q}). \tag{2}$$

여기서 q_d 는 기준 경로, $e = q_d - q$ 는 추적 에러를 나타내며, K_p, K_v 는 각각 상수인 대각선 행렬을 나타낸다. 이와 같은 제어기를 사용하게 되면 로봇 모델에서의 비선형성과 마찰력등이 모두 보상되고 최종적으로 다음과 같은 폐루프 시스템의 오차방정식을 얻게된다.

$$M(q) (\ddot{e} + K_v \dot{e} + K_p e) = 0, \tag{3}$$

따라서 K_p, K_v 의 값을 적당히 정해주면 추적에러의 지수함수적 수렴성을 보일 수 있다.

그러나 실제로는 로봇 모델에 대한 정확한 양을 알 수 없으므로, (3)과 같은 지수함수적 추적오차의 수렴은 만족되지 않는다. 즉 $M(q)$ 과 $N(q, \dot{q})$ 에 대하여 단지 그들의 추정값만 알고 있으며, 마찰력은 구조화되지 않은 불확실성이라고 가정한다면, 제어입력인 CTM은 다음과 같이 되고,

$$\tau = \hat{M}(q) (\ddot{q}_d + K_v \dot{e} + K_p e) + \hat{N}(q, \dot{q}), \tag{4}$$

따라서 폐루프 시스템의 오차 방정식도 정확히 0으로 되지 않고 아래와 같이 되어,

$$\hat{M}(q) (\ddot{e} + K_v \dot{e} + K_p e) = \Delta M(q) \ddot{q} + \Delta N(q, \dot{q}), \tag{5}$$

추적에러의 수렴성이 만족되지 않게 됨을 볼 수 있다. 단, 여기서 $\Delta M = M - \hat{M}$, $\Delta N = N - \hat{N}$ 은 각각 M 과 N 의 추정 오차를 나타낸다.

위에서 우리는 추정값만을 이용한 CTM 제어를 사용한다면 (5)의 우변에 나타나는 것과 같은 불확실성으로 인하여 정확한 추적제어를 할 수 없음을 보였다. 따라서 우리는 다음의 장에서 이러한 불확실성을 극복할 수 있는 신경회로망 제어기를 설계할 것이다.

III. 신경회로망 제어 및 학습

1. 신경회로망 제어기의 설계

본 논문에서 다루고 있는 제어의 목적은 로봇 매니퓰레이터가 그 모델에 불확실성이 있는 경우에도 효과적으로 정확한 추적제어를 할 수 있도록 하는 것이다. 이러한 제어 목적을 달성하기 위하여 본 논문에서는 CTM과 함께 신경회로망을 이용한 제어 방식을 제안한다. 여기서 사용되는 신경회로망 제어기는 추정모델을 이용하여 설계된 CTM만을 사용하였을 때 발생하는 시스템의 불확실성을 극복하기 위하여 도입된 것이다.

기존의 Ishiguro [9]의 연구에서는 신경회로망을 이용하여, (5)에서의 불확실성, $\Delta M(q) \ddot{q} + \Delta N(q, \dot{q})$,를 보상하는 신경회로망 보상기(neural network compensator)를 도입하는 방식이 제안되었다. 이러한 보상기를 설계하기 위하여는 신

경회로망의 입력으로 관절 가속도(\ddot{q})가 반드시 필요로 하였다. 하지만 실제 로봇 시스템에서는 잡음등의 영향으로 관절 가속도를 측정하기란 매우 어려운 일이다.

이처럼 관절가속도가 요구되는 것을 피하기 위한 대안으로 기존의 신경회로망 제어기에서 주로 사용되는 역모델(inverse model)을 학습하는 방식이 있을 수 있다 [5-7,11,12]. 만약에 적당한 학습법칙에 의하여 신경회로망이 시스템의 역모델을 학습할 수만 있다면, 이러한 역모델은 바로 시스템과 직렬 연결되어 전체 시스템이 최종적으로 아이덴티티 맵핑(identity mapping)이 되도록 하여 제어가 되도록 하는 것이다(그림 1). 그러나 이러한 역모델을 이용한 제어방식은 신경회로망이 얼마나 정확히 그 시스템의 역모델을 학습할 수 있는가에 의존하며, 더욱이, 모델 되지 않은 외란과 잡음등이 발생할 경우에는 제어기의 안정성에 심각한 문제점이 야기될 수도 있다. 이런 경우에는 되먹임 루프(feedback loop)를 시스템에 도입함으로써 안정성을 어느 정도 증대시킬 수 있다.

따라서 본 연구에서는 상기의 단점들을 고려하여, 신경회로망이 역모델을 학습함으로써 관절 가속도를 측정하는 대신에 기준 관절 가속도(desired joint acceleration)만을 이용하도록 하고, 이와 아울러 CTM 제어를 이용하여 추가적으로 에러에 대한 되먹임 루프를 도입함으로써 외란과 잡음등에도 안정할 수 있도록 제어기를 설계한다. 또한 로봇 시스템에 대하여 알고 있는 부분은 CTM을 이용하여 제어하고, 나머지 모르는 불확실한 부분은 신경회로망이 학습함으로써 제어하도록 설계한다.




그림 1. 시스템의 역모델을 이용한 제어방식.

Fig. 1. Inverse control using the inverse model of the system.

제안된 제어기의 구조를 그림 2에 나타내었다. 우리가 얻을 수 있는 정보인 \hat{M} 과 \hat{N} 을 이용하여서 CTM 제어기를 설계하고, 이에 신경회로망 제어기를 추가한 형태로써 결국 로봇의 제어입력으로는 $\tau = \tau_{CTM} + \tau_{nn}$ 이 가하여 진다.

$$\tau = \tau_{CTM} + \tau_{nn} = \hat{M}(q) (\ddot{q}_d + K_v \dot{e} + K_p e) + \hat{N}(q, \dot{q}) + \tau_{nn} \tag{6}$$




그림 2. 신경회로망과 CTM을 이용하는 제안된 제어 구조.

Fig. 2. Proposed neural network controller combined with CTM.

여기서 τ_{CTM} 은 CTM을 이용한 제어입력으로서 (4)와 같고, τ_{nn} 은 신경회로망을 이용한 제어 입력이다.

본 논문에서 사용되는 신경회로망은 다층 퍼셉트론 (multilayer perceptron, MLP)으로서 첫번째 층으로 입력층, 두번째, 세번째 층으로 은닉층, 마지막 층으로 출력층의 구조를 갖는다. 각각의 층에서 사용되는 활성화함수 (activation function)으로는 은닉층에서는 비선형 시그모이드 함수 (sigmoid function)인 $f(x) = \tanh(x)$ 를, 출력층에서는 선형함수인 $f(x) = x$ 를 사용한다.

2. 신경회로망 제어기의 학습 법칙

앞에서는 신경회로망과 CTM를 결합한 제어기의 구조를 제안하였다. 하지만 이러한 제어 구조의 핵심은 결국 어떻게 신경회로망 제어기를 학습시킬 것인가가 관건이 된다. 본 논문에서는 신경회로망으로서 MLP를 사용하므로 가장 일반적인 신경회로망의 학습법칙인 오차 역전달 (error back propagation, EBP) 방식이 사용될 수 있지만, 이러한 EBP 방식은 반드시 신경회로망의 기준 출력값이 있어야만 오차의 역전달이 가능하다.

그러나 본 논문에서와 같이 신경회로망 제어기가 로봇 시스템 앞에 놓여 있는 경우에는 시스템의 출력을 신경회로망의 기준 출력으로 설정할 수가 없어 바로 오차를 역전달할 수가 없게된다. 이러한 경우에 지금까지는 신경회로망의 기준 출력값을 얻기 위하여 시스템의 자코비안 (Jacobian) 행렬을 이용하는 '플랜트를 통한 오차 역전달 (EBP through the plant)' 방식 [5] 또는 시스템을 충분히 학습시켜 모사된것을 이용하는 '모사기 (identifier)'를 통하는 방식 [6] 등을 사용하여야만 하였다.

이와 같이 플랜트를 통한 오차 역전달 방식이나 모사기를 이용한 오차 역전달 방식들은 각각 자코비안 행렬을 계산하여야 하는 단점과 시스템의 모사기를 오프 라인 (off-line)으로 제어하기 전에 충분히 학습시킨 후야만 제어가 가능한 단점들이 있다. 따라서 본 연구에서는 이러한 단점들을 극복하고 제어와 동시에 학습이 이루어지며, 자코비안 행렬의 계산 또는 모사기를 필요로 하지 않고, 신경회로망의 기준 출력값도 요구하지 않는 새로운 학습법칙을 유도하여 낸다. 이러한 학습법칙은 앞에서 제안한 제어구조, 즉 신경회로망과 CTM을 동시에 사용하기 때문에 가능하게 되는 것이다. 다음에서 학습법칙을 유도할 것이다.

학습법칙의 유도를 위하여 로봇시스템에 (6)과 같은 제어 입력 가해진 경우의 시스템의 오차 방정식을 정리하여 아래와 같이 나타내어 보자.

$$\begin{aligned} & \hat{M}(q)(K_v \dot{e} + K_p e) \\ &= (M(q) \ddot{q} - \hat{M}(q) \ddot{q}_d) + \Delta N(q, \dot{q}) - \tau_{nn} \quad (7) \\ &= \Psi(q, \dot{q}, \ddot{q}, \ddot{q}_d) - \tau_{nn}, \end{aligned}$$

단, $\Psi(q, \dot{q}, \ddot{q}, \ddot{q}_d) = (M(q) \ddot{q} - \hat{M}(q) \ddot{q}_d) + \Delta N(q, \dot{q})$ 이며, 불확실성을 나타낸다.

우리는 (7)과 같은 오차 방정식으로부터 신경회로망을 이용하여 τ_{nn} 이 정확하게 $\Psi(\cdot)$ 를 학습할 수 있다면, (7)의 우변이 0이 되어 아래와 같이 쓸 수 있으므로,

$$\hat{M}(q)(K_v \dot{e} + K_p e) = 0, \quad (8)$$

결국 추측 오차도 점근적으로 0으로 수렴하게 됨을 보일 수 있게 된다. (\hat{M} 은 non-singular 행렬, K_v 와 K_p 모두 0보다 큰 값으로 이루어진 대각선 행렬이 되도록 선택하였으므로, (8)의 특성방정식의 극점들은 모두 0보다 작게 된다.) 따라서 이와 같이 τ_{nn} 이 $\Psi(\cdot)$ 를 학습하기 위하여는

신경회로망은 다음의 비용 함수 (cost function), E 을 최소화하면 된다.

$$E = \frac{1}{2} \|\Psi - \tau_{nn}\|^2. \quad (9)$$

위의 비용함수로부터 신경회로망의 학습법칙을 유도하기 위하여 신경회로망 내의 임의의 한 연결강도 (weight), w_j 에 대한 그레디언트 (gradient)를 구하면 아래와 같으므로

$$\begin{aligned} \frac{\partial E}{\partial w_j} &= -(\Psi - \tau_{nn})^T \frac{\partial \tau_{nn}}{\partial w_j} \quad (10) \\ &= -(\hat{M}(q)(K_v \dot{e} + K_p e))^T \frac{\partial \tau_{nn}}{\partial w_j}, \end{aligned}$$

따라서 신경회로망의 학습법칙은 최종적으로 아래와 같이 얻어진다.

$$\frac{dw_j}{dt} = -\eta \frac{\partial E}{\partial w_j} = \eta (\hat{M}(q) u_{pd})^T \frac{\partial \tau_{nn}}{\partial w_j}. \quad (11)$$

단, (10)에서는 (7)의 결과를 이용하였고, $u_{pd} = K_p e + K_v \dot{e}$ 이고, η 는 0보다 큰 상수로서 학습률을 나타낸다.

(11)이 나타내는 학습법칙의 의미는 다음과 같이 해석될 수 있다. 신경회로망은 오차를 역전달하는 대신에 $\hat{M} u_{pd}$ 를 이용하여 학습을 한다. 이와 같이 학습은 결국 신경회로망이 (9)를 최소화하는 것이므로 학습과 제어가 진행될수록 점점 더 (8)과 같이 오차의 방정식이 0으로 접근하게 되어 결국은 오차가 점점 더 작아지게 되는 것이다.

이러한 학습과 제어 방식은 결국은 오차가 아주 작게 되면, 신경회로망은 기준 입력값을 받아 출력을 내고, 이 기준 입력값과 출력값은 서로 거의 같아 아이덴티티 맵핑을 이루게 되므로 시스템의 역모델²⁾을 학습하여 제어하는 것으로 생각될 수 있다.

IV. 시뮬레이션

시뮬레이션의 대상 로봇으로 Hashimoto [15]에 의하여 설계된 2축 로봇 매니퓰레이터를 다룬다. 이 로봇의 운동방정식에 사용된 각각의 M_{ij}, C_{ij} ($i, j = 1, 2$)값들은 [15]에서와 동일하다.

마찰력은 구조화되지 않은 불확실성이라고 가정하였고, 실제값은

$$f(q) = \begin{bmatrix} f_1(\dot{q}) \\ f_2(\dot{q}) \end{bmatrix} = \begin{bmatrix} 7.8 \dot{q}_1 + 0.2 \operatorname{sgn}(\dot{q}_1) \\ 3.2 \dot{q}_2 + 0.2 \operatorname{sgn}(\dot{q}_2) \end{bmatrix} \quad (12)$$

위와 같다고 설정하였다.




그림 3. 시뮬레이션에 사용된 로봇의 초기 위치 및 기준 궤적.

Fig. 3. Initial configuration and desired trajectory of the robot.

이와 같은 로봇 시스템에 대하여 우리의 목적은 로봇의 엔

1) 일반적으로 신경회로망이 하나 이상의 은닉층을 가지고 있으면, universal approximation theorem [16,17]에 의하여 어떠한 비선형 함수라도 주어진 임의의 오차 범위 이내로 학습할 수 있음이 증명되어 있다.

2) 좀더 정확하게 말하면, 로봇 자체의 역모델이 아니라, 로봇에서 CTM으로 보상되고 난 나머지 부분, 즉 불확실성, Ψ 에 대한 역모델을 학습하는 것이다.

드 이펙터 (end-effector)의 움직임이 기준 경로를 따라가도록 제어하는 것이다 (그림 3). 기준 경로는 반지름 0.15m, 중심이 (0.2m, 0.2m)에 위치한 원으로서 아래와 같이 주어진다.

$$\begin{bmatrix} x_d(t) \\ y_d(t) \end{bmatrix} = \begin{bmatrix} 0.2 + 0.15 \sin(2\pi t/5) \\ 0.2 + 0.15 \cos(2\pi t/5) \end{bmatrix} \quad (13)$$

상기의 제어 목적을 달성하기 위하여 본 논문에서 제안된 신경회로망과 CTM을 이용한 제어 방식을 사용한다. CTM은 \hat{M} 과 \hat{g} 를 사용하여,

$$\tau_{CTM} = \hat{M}(q) (\ddot{q}_d + u_{pid}) + \hat{g}(q), \quad (14)$$

위와 같이 설계되며, 여기서 \hat{M} 과 \hat{g} 은 2kg 부하질량일 때의 값을 임의로 20% 씩 변화시킨 값, 즉 $\hat{M}_{ij} = (1 + 0.2) M_{ij}|_{2kg}$, $\hat{g}_i = (1 + 0.2) g_i|_{2kg}$ 을 사용하였으며, K_p, K_v 는 각각 $K_p = 30^2$, $K_v = 2 \cdot 30$ 이 되도록 설계하였다. 신경회로망 제어기로는 MLP로서 각층의 노드의 개수가 각각 6-15-9-2이며, 은닉층과 출력층에서는 바이어스 항이 문턱값 (threshold)으로 더해진다. 학습을 시작하기 전에 각 층의 연결강도와 문턱값들은 (-0.05, +0.05) 사이의 값들 중에서 임의로 값으로 초기화하였다. 학습율은 $\eta = 0.01$ 로 놓고 사용하였다.




그림 4. CTM 제어만을 사용하였을 때의 추적 오차 추이.


Fig. 4. Transition of the tracking error when the CTM only is used.

시뮬레이션 결과는 그림 4, 5, 6에 나타내었다. 그림 4는 신경회로망을 사용하지 않고 추정값으로 설계된 CTM 제어기만을 이용하였을 때의 결과이다. 그림에서 보듯이 CTM으로 보상되지 않는 불확실성에 의하여 추적오차가 0으로 수렴하지 않음을 볼 수 있다. 이에 반하여 제안된 신경회로망과 CTM 제어기를 함께 이용한 경우(그림 5)에는 신경회로망이 작업을 수행함에 따라 불확실성에 대하여 점점 더 학습을 하여 제어하게 되므로 추적 오차도 따라서 점점 줄어들고 있음을 볼 수 있다. 실제로 5번째 사이클 이후(그림 5. (b))에는 추적오차가 거의 0으로 유지되고 있음을 볼 수 있다. 다음의 그림 6은 신경회로망과 불확실성 항, ψ 과의 관계를 첫번째 조인트에 대하여 나타낸 것이다. 학습 초기에는 신경회로망의 출력이 ψ 와 차이를 나타내지만 학습이 진행됨에 따라 이 둘의 차이가 점점 줄어들고 있음을 보이고 있다.

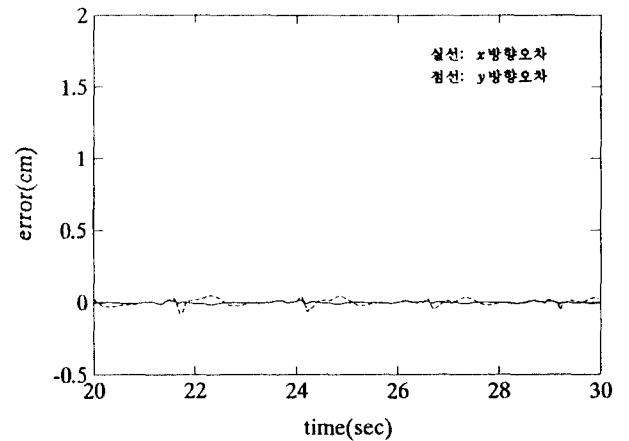
이상의 결과를 근거로 본 논문에서 제안된 제어 방식과 학습방식에 의하여 로봇의 추적 제어가 불확실성이 있는 경우에도 성공적으로 수행되고 있음을 보일 수 있다.

V. 고찰 및 비교

최종적으로 구해진 신경회로망의 학습법칙만을 고려한다면, 본 논문에서 제안한 학습법칙은 기존의 Kawato [11-13]의 '되먹임 오차 학습 (feedback error learning)' 방식과 유사하게 생각될 수도 있다. 그러나 본 논문의 결과는 크게 두가지 방식에 있어서 Kawato의 방식과 차이가 있다.



(a) 1st and 2nd cycle (1cycle = 5sec.).



(b) 5th and 6th cycle.

그림 5. 신경회로망과 CTM 제어기를 사용하였을 때의 추적 오차의 추이.

Fig. 5. Transition of the tracking error when the proposed neural network controller and the CTM are used.


1. 신경회로망의 구조상의 차이

서론에서도 잠깐 설명하였지만, Kawato의 연구에서 사용된 신경회로망은 여러 개의 서브 시스템으로 나눈 것들을 조합함에 있어서 그들의 가중치만을 조절하는데 사용한 것이다. 실제로 Kawato의 연구에서는 서브 시스템으로 $\sin(\theta_2)\cos(\theta_2)\dot{\theta}_1\dot{\theta}_2$, $\sin(\theta_2)\dot{\theta}_2\dot{\theta}_2^2$ 와 같은 항들을 준비하고, 신경회로망은 이들을 함할 때에 가중치만을 조절하도록 되어있다 [13]. 다시 말해서, 그들의 신경회로망은 다음의 수식으로 표현된다.


$$\tau_{nn} = w^T f \quad (15)$$

여기서, τ_{nn} 는 신경회로망의 출력, w 는 연결강도를 나타내는 벡터, f 는 신경회로망의 입력으로서 f_i 는 각각 i 번째 서브 시스템을 나타낸다 (그림 7). 이와 같은 식은 어떤 비선형 시스템이 시그널 항과 파라미터 항으로 나누어질 수 있어, '선형 파라미터화 (linear parameterization)' (2-4) 될 수 있다는 것을 의미한다. 그러나 이렇게 시스템이 선형

파라미터화될 수 있다는 가정은 수식상의 전개는 간단하게 되지만, 반면에 시스템에 대한 많은 정보를 알아야만 하는 단점이 있다. 예를 들어 Kawato의 연구에서와 같이 대상 시스템이 로봇인 경우 관성 행렬과 중력 항에 포함되는 \cos, \sin 같은 것과 원심력과 Coriolis 효과에 의한 관절 속도와 그들의 곱등에 대한 모든 정보를 알아야만 선형 파라미터화가 가능해진다. 더욱이 이러한 선형 파라미터화는 시스템이 불확실하며, 시스템의 구조에 대하여 잘 모를 때에는 사용하기가 매우 어렵다.



(a) 1st and 2nd cycle (1cycle = 5초).



(b) 5th and 6th cycle.

그림 6. 첫번째 조인트에 대한 신경회로망의 출력값 (τ_{nn})과 불확실성(Ψ)의 비교.

Fig. 6. Comparison of τ_{nn} and Ψ for the first joint.

이에 반하여 본 논문에서 제안된 구조는 다층 퍼셉트론을 이용함으로써 이와 같은 시스템에 대한 정보를 요구함이 없이 기준 궤적에 대한 입력만 있으면 되므로 시스템이 불확실하고 그 구조를 모르더라도 신경회로망의 비선형 맵핑 (nonlinear mapping) 능력과 일반화 (generalization) 능력을 사용하여 효율적으로 시스템에 대한 제어가 가능한 장점이 있다.

2. 학습법칙의 차이

Kawato의 학습법칙은 기본적으로 그들이 적핵뉴론 (red nucleus neuron)을 관찰함으로써 가정하여낸 것으로 다음과 같이 쓸 수 있다.

$$\frac{dw}{dt} = -\eta \tau_c^T \frac{\partial \tau_{nn}}{\partial w} = \eta \tau_c^T f \quad (16)$$

여기서 τ_c 는 되먹임 제어기의 출력을 나타낸다 (그림 7). (16)과 같은 Kawato의 되먹임 오차 학습법 (feedback error learning)은 그 유도된 배경이 생물학적인 뉴런을 관찰하여

가정한 것이므로, 실제로 최적화 (minimization) 관점에서 살펴볼 때, 무엇을 최적화하는 것인지를 명확하게 유도하지 못하였다. 다만, 되먹임 오차학습법의 의미가 되먹임 제어기의 출력을 최소화하도록 신경회로망을 학습시키는 것이므로 비용함수는 아래의 형태가 아닌가 추론해 볼 수가 있다.

$$E_1 = \frac{1}{2} \|\tau_c\|^2 \quad (17)$$

위와 같은 비용함수에 대하여 신경회로망의 연결강도에 대한 그레디언트를 구하면

$$\begin{aligned} \frac{\partial E_1}{\partial w} &= \tau_c^T \frac{\partial \tau_c}{\partial w} = \tau_c^T \frac{\partial (\tau - \tau_{nn})}{\partial w} \\ &= -\tau_c^T \frac{\partial \tau_{nn}}{\partial w} = -\tau_c^T f \end{aligned} \quad (18)$$

단, 여기서 $\tau_c = \tau - \tau_{nn}$ 을 이용하였다. (18)의 그레디언트로부터 되먹임 오차 학습법은 (16)과 같이 얻어질 수 있을 것으로 보인다.




그림 7. Kawato의 되먹임 오차 학습법.
Fig. 7. Kawato's feedback error learning.

그러나 이와 같은 결론은 제어 입력 τ 가 연결강도 w 에 무관하다고 잘못 가정한 결과이다. 제어 입력 τ 는 $\tau = \tau_c + \tau_{nn} = Ke + w^T f$ 로서 w 의 함수이므로 결코 w 와 무관하지 않다. 따라서 (18)의 세번째 등호는 성립하지 않는다. 그러므로 비용함수의 형태가 (17)로 주어져서는 (16)의 학습법칙을 얻을 수 없다. 실제로 비용함수의 형태가 (17)인 경우의 그레디언트는 다음과 같이 구해진다.

$$\begin{aligned} \frac{\partial E_1}{\partial w} &= \tau_c^T \frac{\partial \tau_c}{\partial w} = \tau_c^T K \frac{\partial e}{\partial w} = -\tau_c^T K \frac{\partial y}{\partial w} \\ &= -\tau_c^T K J \frac{\partial u}{\partial w} \end{aligned} \quad (20)$$

한편

$$\begin{aligned} \frac{\partial \tau}{\partial w} &= \frac{\partial \tau_c}{\partial w} + \frac{\partial \tau_{nn}}{\partial w} \\ &= -KJ \frac{\partial \tau}{\partial w} + \frac{\partial \tau_{nn}}{\partial w} \end{aligned} \quad (20)$$

여기서 $e = y_d - y$ 이고 $J = \partial y / \partial u$ 는 시스템의 자코비안 행렬이다. 결국 비용함수가 (17)인 경우의 신경회로망의 학습법칙은 시스템의 자코비안 행렬을 필요로 하는 '플랜트를 통한 오차 역전달 (back propagation through the plant)' 방식 [5]과 아울러 센서터비티 모델 (sensitivity model)을 사용하여 그레디언트를 계산하는 '동적 오차 역전달 (dynamic error back propagation)' 방식 [6]을 모두 사용해야만 학습이 가능하게 됨을 알 수 있다.

결론적으로 Kawato의 되먹임 오차 학습법은 그 학습법칙이 생물학적 뉴런으로부터 유도, 가정된 것이므로 무엇이 최적화되는 것인지 명확하게 알 수 없으며, 이러한 문제에 대하여 이제까지 연구, 발표된 결과는 아직까지 없었다. 이에 반하여 본 논문에서 제안된 학습법칙, (11)은 비용함수가 (9)로 주어지며, 이 비용함수를 최소화하기 위한 신경회로망의 학습법칙은 (10)과 (11)을 통하여 유도하였으므로, 신경

회로망이 결국 무엇을 학습하는 것인 가를 명확하게 보일 수 있었다.

VI. 결론

본 논문에서는 신경회로망을 이용한 새로운 제어 및 학습방식을 제안하였다. 제어방식의 구조는 CTM과 신경회로망을 이용하는 것으로서, 우리가 로봇 시스템에 대하여 알고 있는 추정값에 대하여는 CTM을 이용하여 제어기를 설계하고 모르는 불확실한 부분에 대하여는 신경회로망을 이용하여 학습함으로써 제어하도록 한 것이다. 이와 같은 구조는 신경회로망만을 이용하여 시스템을 제어할 때보다 신경회로망의 크기와 학습시간을 줄일 수 있게되며, CTM만으로는 극복할 수 없었던 불확실성도 아울러 제어할 수 있게 되는 장점을 갖고 있다.

아울러 이러한 제어구조이외에 제안된 신경회로망 제어를 학습할 수 있는 학습법칙을 제안하였는데, 이러한 학습법칙은 신경회로망의 기준 출력값이 없더라도 학습이 가능하며, 시스템의 자코비안 행렬이나 모사기등도 요구하지 않고, 제어와 학습이 동시에 이루어지는 장점이 있다. 결국 이렇게 학습된 신경회로망은 로봇 시스템의 불확실성에 대한 역모델을 학습하게 되고, 따라서 관측 가속도 정보를 필요로 하지 않게 되는 장점도 있다.

시뮬레이션에서는 제안된 제어와 학습방식을 로봇시스템에 적용하였고, 제안된 방식이 시스템의 구조화된 불확실성(예를 들어 관성행렬의 불확실성)뿐만이 아니라 구조화되지 않은 불확실성(예를 들어 마찰력)에도 강인한 특성을 보임을 검증하였다.

참고 문헌

- [1] J. Y. S. Luh, M. W. Walker, and R. P. C. Paul, "Resolved acceleration control of mechanical manipulators," *IEEE Trans. Automatic Control*, vol. 25, no. 3, pp. 468-475, 1980.
- [2] J. J. Craig, P. Hsu and S. S. Sastry, "Adaptive control of mechanical manipulators," *Int. J. Robotics Research*, vol. 6, no. 2, pp. 16-28, 1987.
- [3] J.-J. E. Slotine and W. Li, "Adaptive manipulator control: A case study," *IEEE Trans. Automatic Control*, vol. 33, no. 11, pp. 995-1003, 1988.
- [4] J.-J. E. Slotine and W. Li, *Applied Nonlinear Control*, Englewood Cliffs, NJ, Prentice Hall, 1991.
- [5] D. Psaltis, A. Sideris, and A. A. Yamamura, "A multilayered neural network controller," *IEEE Control Systems Magazine*, pp. 17-21, Apr. 1988.
- [6] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp. 4-27, Mar. 1990.
- [7] K. J. Hunt, D. Sbarbaro, R. Zbikowski and P. J. Gawthrop, "Neural networks for control systems - A survey," *Automatica*, vol. 28, no. 6, 1083-1112, 1992.
- [8] T. Fukuda and T. Shibata, "Theory and application of neural networks for industrial control systems," *IEEE Trans. Industrial Electronics*, vol. 39, no. 6, pp. 472-489, Dec. 1992.
- [9] A. Ishiguro, T. Furuhashi, S. Okuma and Y. Uchikawa, "A neural network compensator for uncertainties of robotics manipulators," *IEEE Trans. Industrial Electronics*, vol. 39, no. 6, pp. 565-570, Dec. 1992.
- [10] M. Saad, P. Bigras, L.-A. Dessaint, and K. Al-Haddad, "Adaptive robot control using neural networks," *IEEE Trans. Industrial Electronics*, vol. 41, no. 2, pp. 173-181, Apr. 1994.
- [11] M. Kawato, K. Furukawa, R. Suzuki, "A hierarchical neural network model for control and learning of voluntary movements," *Biol. Cybern.*, vol. 57, pp. 165-185, 1987.
- [12] H. Goni and M. Kawato, "Learning control for a closed loop system using feedback-error-learning," *Proc. 29th IEEE CDC*, pp. 3289-3294, 1990.
- [13] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki, "Feedback error-learning neural network for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, pp. 251-265, 1988.
- [14] D. M. Dawson and Z. Qu, "On the global ultimate boundedness of a DCAL-like robot controller," *IEEE Trans. Robotics and Automation*, vol. 8, no. 3, pp. 409-413, 1992.
- [15] H. Hashimoto, K. Maruyama, and F. Harashima, "A Microprocessor-based robot manipulator control with sliding mode," *IEEE Trans. Industrial Electronics*, vol. 34, no. 1, pp. 11-18, 1987.
- [16] G. Cybenko, "Approximation by superpositions of a sigmoidal function," *Mathematics of Control, Signals, and Systems*, vol. 2, pp. 303-314, 1989.
- [17] K. Funahashi, "On the approximation realization of continuous mappings by neural networks," *Neural Networks*, vol. 2, pp. 183-192, 1989.



김성우

1967년 11월 26일 서울 출생. 한국과학기술원 전기 및 전자공학과 학사, 1990 및 석사, 1991. 현 동대학원 박사과정.



이주장

1948년 11월 14일 서울 출생. 서울대학교 전기공학과 학사, 1973 및 석사, 1978. 미국 위스콘신 대학 전기과 박사, 1984. 현재 한국과학기술원 전기 및 전자공학과 부교수, 당학회 총무이사.