

論文 2002-39SC-4-2

신경회로망 외란 관측기를 이용한 불확실한 로봇 시스템의 운동 제어

(Motion Control of an Uncertain Robotic Manipulator System via Neural Network Disturbance Observer)

金殷泰 * , 金漢正 **

(Euntai Kim and Hanjung Kim)

요약

본 논문에서는 로봇 매니퓰레이터의 제어에 사용할 수 있는 신경망 외란 관측기를 제안하도록 한다. 제안한 신경망 외란 관측기는 다층신경망의 구조로 신경망 외란관측기의 오차와 제어 오차가 충분히 작은 콤팩트 집합에 절대 상시 유게된다. 본 논문에서 제안하는 신경망 외란 관측기는 기존의 적응 제어기의 단점을 해결한 방식으로 복잡한 회귀 모델을 필요로 하지 않는다. 끝으로 제안한 방식을 3관절 로봇에 적용하여 그 타당성을 확인한다.

Abstract

A neural network disturbance observer for a robotic manipulator is derived in this paper. The neural network used as the disturbance observer is a feedforward MLP(multiple-layered perceptron) network. The uniform ultimate boundness(UUB) of the proposed neural disturbance observer and the control error within a sufficiently small compact set is guaranteed. This neural disturbance observer method overcomes the disadvantages of the existing adaptive control methods which require the tedious analysis of the regressor matrix of the given manipulator. The effectiveness of the proposed neural disturbance observer is demonstrated by the application to the three-link robotic manipulator.

Keyword : Neural Network, Disturbance Observer, Uncertain Robot

I. 서론

산업 로봇의 운동제어는 로보틱스에서 가장 중요한

문제 중 하나로 지난 십 년간 많은 관심을 끌었고 이에 대한 많은 연구결과가 보고되었다. 일반적으로 로봇 동력학에 대한 완벽한 정보가 있을 때, 로봇의 운동 제어는 쉽게 해결할 수 있는 문제로 가장 대표적인 방식으로는 중력항(gravity term)을 상쇄한 PD제어 기법^[1-2]과 피드백 선형화(feedback linearization)를 이용하여 로봇 동력학을 선형화한 계산토우크(computed torque)방식^[2-4]를 들 수 있다.

그러나 실제의 경우, 작업에 따라 변하는 부하, 경우에 따라 변하는 마찰계수, 백래쉬(backlash)등 모델링되지 않은 비선형성 등으로 인해 로봇의 동력학에 대한

* 正會員, 延世大學校 電氣電子工學部

(Yonsei University, School of Electrical and Electronic Engr.)

** 正會員, 國立 韓京大學校 制御計測工學科

(Hankyong National University, Dept. of Control and Instrumentation Engr.)

接受日字: 2000年12月12日, 수정완료일: 2002年6月24日

정확한 정보를 얻는 일은 거의 불가능한 일이다. 기본적으로 이 같은 문제의 해결책으로 적응제어와 강인제어 기법이 널리 연구되었다. 적응 제어의 경우^[5-7], 실제 시스템에서 계산하기 어려운 로봇 회귀 함수(robot regressor function)를 필요로 하며, 불확실성이 모두 구조화된(structured) 경우여야 하며, 구조화되지 않은 불확실성에 대해서는 그 성능 및 안정성까지도 보장할 수 없다는 단점이 있다. 반면 강인 제어의 경우^[8-10], 구조화되지 않은 불확실성도 다룰 수 있지만, 불확실성의 크기의 한계를 미리 알아야 하며 결과적으로 얻게 되는 제어기는 모든 불확실성을 상쇄할 수 있는 대단히 큰 이득의 스위치형 혹은 포화형(saturation-type)제어기이다.

이 같은 문제의 대안으로, 최근 신경망이 로봇 시스템의 제어에 널리 이용되고 있다. Kawato 등은^[11-12]에서 주어진 로봇에 대한 회귀함수 집합을 이용하여 로봇을 신경망 학습 제어하였고 Lewis는 다층 신경망을 이용하여 불확실한 로봇의 비선형 적응 제어가 가능함을 보였다^[13]. 그 밖에 많은 로봇의 위치 제어에 대한 연구 결과가 발표되었다^[14-16].

본 논문에서는 신경회로망을 이용하여 외란관측기를 구성하고 이를 이용하여 불확실한 로봇 시스템을 운동 제어하는 새로운 방식을 제시한다. 본 논문에서 제안되는 신경망 외란 관측기는 외부에서 들어오는 외란(external disturbance) 뿐 아니라 내부의 파라미터 변화(internal parameter perturbation)를 모두 관측하는 것으로 기존의 외란관측기의 개념^[17]을 신경망을 이용하여 구현한 것이다. 기본 방식은 그림 1과 같이 로봇 시스템의 제어 시 발생하게 되는 외란부분을 신경망을 이용하여 관측하고 제거함으로써 주어진 제어목적을 달성하는 방식이다.

본 논문의 방식은 기존의 신경망을 이용한 로봇 운

동 제어 방식과 비교할 때 학습과 제어가 동시에 이루어지고, 이론적으로 제어 방식의 안정도가 보장되며, 강인 제어기에 가까운 높은 이득의 스위치형 지도 강인 제어기(supervisory robustifying controller)를 필요로 하지 않는다는 장점을 가지고 있다.

본 논문의 구성은 다음과 같다. 2장에서는 로봇의 동력학 방정식을 간단히 설명하고 3장에서는 외란관측기를 구성하는 다층 신경망의 구조를 알아본다. 4장에서는 본 논문의 주요 내용인 외란 관측기를 제안하고 설계 방식을 설명하며 5장에서는 컴퓨터 모의 실험을 통해 제안한 방식의 타당성을 확인한다. 6장은 본 논문의 마지막으로 본 연구의 결론을 이끌어 낸다.

II. 로봇 모델

A. 공칭 로봇 시스템의 동력학 모델

본 절에서는 자유도 n 인 다관절 로봇의 동력학 방정식을 살펴본다. 이 방정식은 로봇 제어의 입력으로 사용하게 되는 각 관절 토크와 이에 의해 발생하게 되는 관절의 위치 속도, 가속도와의 관계를 설명하는 식으로, 라그랑제(Lagrange) 운동 역학을 이용하여 유도할 수 있다. 우선 다음과 같은 라그랑지안(Lagrangian)을 정의한다^[3].

$$\mathcal{L}(\mathbf{q}, \dot{\mathbf{q}}) = K(\mathbf{q}, \dot{\mathbf{q}}) - P(\mathbf{q}) \quad (1)$$

여기서 $K(\mathbf{q}, \dot{\mathbf{q}})$ 는 로봇 시스템의 운동 에너지를 나타내는 항으로, 식 (2)와 같이 관절 속도의 제곱의 형태로 표현되며 $P(\mathbf{q})$ 는 로봇의 중력에 의한 위치에너지 를 나타내는 항이다.

$$K(\mathbf{q}, \dot{\mathbf{q}}) = \frac{1}{2} \dot{\mathbf{q}}^T \mathbf{M}(\mathbf{q}) \dot{\mathbf{q}} \quad (2)$$

여기서 $\mathbf{M}(\mathbf{q})$ 는 다관절 로봇의 관절 영역에서의 질량과 관성을 나타내는 $n \times n$ 크기의 대칭 행렬이다. 라그랑제 운동 역학에 의해 자유도 n 인 로봇의 동력학 방정식은 다음의 식 (3)과 같이 표현된다.

$$\frac{d}{dt} \left(\frac{\partial \mathcal{L}}{\partial \dot{\mathbf{q}}} \right) - \frac{\partial \mathcal{L}}{\partial \mathbf{q}} = \tau \quad (3)$$

여기서 τ 는 로봇 시스템의 입력으로 작용하는 일반화된 토크이다. 식 (1)과 (2)를 (3)에 넣고 정리하면 로

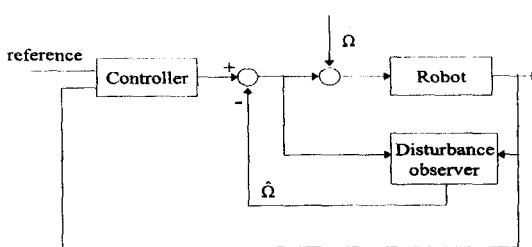


그림 1. 외란관측기를 포함한 시스템의 구성

Fig. 1. The Configuration of the system including disturbance observer.

봇의 동력학 방정식은 다음의 식으로 표현된다.

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + \dot{\mathbf{M}}(\mathbf{q})\dot{\mathbf{q}} - \frac{\partial K(\mathbf{q}, \dot{\mathbf{q}})}{\partial \mathbf{q}} + \frac{\partial P(\mathbf{q})}{\partial \mathbf{q}} = \tau \quad (4)$$

이제 (5)(6)과 같이 변수를 정의하면 식 (4)의 로봇 방정식은 식 (7)과 같이 된다.

$$C(\mathbf{q}, \dot{\mathbf{q}}) = \dot{\mathbf{M}}(\mathbf{q})\dot{\mathbf{q}} - \frac{\partial K}{\partial \mathbf{q}} \quad (5)$$

$$G(\mathbf{q}) = \frac{\partial P(\mathbf{q})}{\partial \mathbf{q}} \quad (6)$$

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + C(\mathbf{q}, \dot{\mathbf{q}}) + G(\mathbf{q}) = \tau \quad (7)$$

여기서 $\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}}$ 는 로봇의 관성 성분을 나타내고, $C(\mathbf{q}, \dot{\mathbf{q}})$ 는 원심력과 코리올리 효과의 항들을 포함하며 $G(\mathbf{q})$ 는 중력의 항을 나타내며 τ 는 로봇의 입력 토크이다. 여기에 로봇의 마찰효과 $F(\dot{\mathbf{q}})$ 를 더하면 관절영역에서 표현된 최종 로봇 동력학은 다음의 식으로 표현된다.

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + C(\mathbf{q}, \dot{\mathbf{q}}) + G(\mathbf{q}) + F(\dot{\mathbf{q}}) = \tau \quad (8)$$

B. 외란을 포함한 로봇 시스템의 동력학 모델

로봇 시스템의 실제 파라미터가 공칭(nominal) 파라미터와 다르거나 혹은 외부 외란의 영향을 받는 경우, 공칭식 (8)로 표현되는 로봇 시스템은 실제로 (9)의 식으로 표현된다.

$$\widehat{\mathbf{M}}(\mathbf{q})\ddot{\mathbf{q}} + \widehat{\mathbf{C}}(\mathbf{q}, \dot{\mathbf{q}}) + \widehat{\mathbf{G}}(\mathbf{q}) + \widehat{\mathbf{F}}(\dot{\mathbf{q}}) + \tau_d = \tau \quad (9)$$

여기서 $\widehat{\mathbf{M}}, \widehat{\mathbf{C}}, \widehat{\mathbf{G}}, \widehat{\mathbf{F}}$ 는 각 공칭값 $\mathbf{M}, \mathbf{C}, \mathbf{G}, \mathbf{F}$ 의 실제값이며 τ_d 는 외부에서 들어오는 외란이다. 식 (9)로 표현되는 실제 로봇 시스템은 공칭모델을 이용하여 다음의 식 (10)로 표현할 수 있다.

$$\begin{aligned} & \mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + C(\mathbf{q}, \dot{\mathbf{q}}) + G(\mathbf{q}) + F(\dot{\mathbf{q}}) \\ & - \mathbf{M}(\mathbf{q})\mathcal{Q}(\mathbf{q}, \dot{\mathbf{q}}, \tau) = \tau \end{aligned} \quad (10)$$

여기서

$$\begin{aligned} \mathcal{Q}(\mathbf{q}, \dot{\mathbf{q}}, \tau) & \equiv \widehat{\mathbf{M}}^{-1}(\mathbf{q})\{\tau - \tau_d - \widehat{\mathbf{C}}(\mathbf{q}, \dot{\mathbf{q}}) - \widehat{\mathbf{G}}(\mathbf{q}) \\ & - \widehat{\mathbf{F}}(\dot{\mathbf{q}})\} - \mathbf{M}^{-1}(\mathbf{q})\{\tau - C(\mathbf{q}, \dot{\mathbf{q}}) - G(\mathbf{q}) - F(\dot{\mathbf{q}})\} \end{aligned}$$

이다. 식 (10)은 실제 로봇 시스템 (9)를 공칭 모델을

이용하여 표현한 식으로 $\mathcal{Q}(\cdot)$ 항은 외부의 외란 (τ_d)과 내부의 파라미터 불확실성($\widehat{\mathbf{M}} - \mathbf{M}, \widehat{\mathbf{C}} - \mathbf{C}$)등을 모두 포함한 전제 외란이다. 위 식(10)는 다음장의 신경망 외란관측기를 설계하는데 유용하게 사용된다.

III. 다층 신경망

본 논문에서 사용되는 다층 신경망은 그림 2와 같이 입력층 1층, 비선형 은닉층 1층, 선형 출력층 1층의 3층으로 구성된 신경망이다.^[18-19] 의해 은닉층의 노드가 충분히 많은 경우 이 같은 신경망의 구성을 크게 일반성을 잃지 않는다. 은닉층의 비선형 노드는 비선형 활성화 함수 $\sigma(\cdot)$ 와 선형 조합기로 구성되어 있다. 본 논문에서는 식 (11)로 표현되는 2극 활성화함수를 이용한다.

$$\sigma(z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (11)$$

이 경우 활성화함수와 그 도함수 사이에는 다음과 같은 관계가 있다.

$$\frac{d\sigma(z)}{dz} = 1 - \sigma^2(z) \quad (12)$$

그림 2의 신경망의 입출력 관계를 식으로 표현하면 입력 $(\theta_1, \theta_2, \dots, \theta_{N_i})$ 이 N_i 차원일 때 3층 신경망은 다음의 식으로 표현된다.

$$y_i = \sum_{j=1}^{N_i} \left[w_{ij} \sigma \left(\sum_{k=1}^{N_h} v_{jk} \theta_k + \mu_{ij} \right) \right], \quad i = 1, \dots, N_o \quad (13)$$

여기서 w_{ij} 는 j 번째 은닉층 노드에서 i 번째 출력층

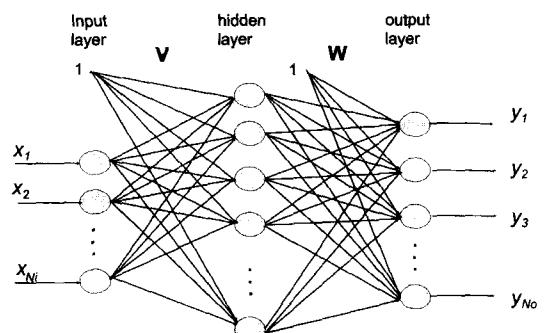


그림 2. 다층 신경망 제어기

Fig. 2. MLP network.

노드로 가는 은닉층에서의 웨이트이고 v_{jk} 는 k 번째 입력 노드에서 j 번째 은닉층 노드로 입력층에서의 웨이트이다. μ_{ij} 는 은닉층 노드에서의 임계치(threshold)이다. 이제 식 (13)의 다층 신경망 출력력 방정식을 벡터 방정식으로 표현하도록 한다. 출력 벡터를 각 $\Theta = (1, \theta_1, \dots, \theta_{N_s})^T$, $y = (y_1, y_2, \dots, y_{N_s})^T$ 으로 정의하고 웨이트 행렬을 $W = (w_{ij})$, $V = (v_{jk})$ 로 하면 식 (14)의 신경망 출력력은 다음의 벡터 식으로 표현된다.

$$y \equiv \hat{\Omega}(\Theta | V, W) = W\Sigma(V\Theta) \quad (14)$$

여기서 $\hat{\Omega}(\cdot)$ 는 신경망을 나타내고 벡터함수 $\Sigma(\cdot)$ 는 입력 $h = (h_1, h_2, \dots, h_n)^T$ 에 대하여 다음과 같이 정의된다.

$$\Sigma(h) \equiv (\sigma(h_1), \sigma(h_2), \dots, \sigma(h_n)) \quad (15)$$

이 같은 신경망은 [18, 19]에서 보고된 일반근사성에 의해서 비선형 함수를 원하는 수준까지 정확히 표현할 수 있고, 비선형 함수 $\Omega(\Theta)$ 를 신경망을 이용하여 근사하는 경우 최적의 신경망 웨이트는 식 (16)과 같이 주어진 비선형 함수와 신경망과의 차이를 최소화하는 값으로 정의할 수 있다.

$$\begin{aligned} [V^*, W^*] &= \arg \min_{\nu \in \Omega_v, w \in \Omega_w} \\ &[\sup_{\Theta \in D_\theta} |\Omega(\Theta) - \hat{\Omega}(\Theta | \hat{V}, \hat{W})|] \end{aligned} \quad (16)$$

여기서 D_θ 는 Θ 의 영역이고, Ω_v 와 Ω_w 는 신경망의 웨이트 추정치가 존재하는 영역으로 비선형 함수 $\Omega(\Theta)$ 는 최적의 웨이트를 갖는 신경망을 이용하여 다음과의 식과 같이 표현할 수 있다.

$$\Omega(\Theta) = \hat{\Omega}(\Theta | V^*, W^*) + \epsilon(\Theta) \quad (17)$$

여기서 $\epsilon(\Theta)$ 는 신경망의 복원 오차이며 다음의 식 (18)로 정의되는 유계 한계 ϵ_N 은 신경망 은닉층의 중간 노드 수를 늘임으로서 충분히 작게 할 수 있다.

$$\|\epsilon(\Theta)\| \leq \epsilon_N \quad (18)$$

IV. 신경망 외란관측기

A. 신경망 외란관측기의 구조

실제의 로봇시스템에서 외란을 나타내는 항 $\Omega(\cdot)$ 은 일반적으로 미리 알기 어렵고 수학적으로 표현하기도 힘들다. 그러나 이를 무시하고 계산토오크 방식을 사용하면 제어 성능은 크게 악화되며 심지어 전체 시스템이 불안정하게 될 수도 있다. 신경망은 이 같은 문제의 답이 될 수 있다. 앞 장에서 언급한 바와 같이 신경망은 주어진 비선형 함수를 원하는 만큼 정확히 표현할 수 있고, 신경망 $\hat{\Omega}(\Theta | \hat{V}, \hat{W})$ 이 내부 파라미터 변화와 외부 외란을 모두 포함하고 있는 $\Omega(\Theta)$ 를 충분히 잘 관측하면 그림 1과 같은 방식으로 로봇 시스템을 공칭 시스템과 같이 제어할 수 있다.

이 같은 신경망 외란관측기의 설계를 위하여 다음의 일차 필터를 생각한다.

$$\dot{\mu} = -x\mu + G(q, \dot{q}, \tau, \hat{V}, \hat{W}) \quad (19)$$

여기서

$$\begin{aligned} G(q, \dot{q}, \tau, \hat{V}, \hat{W}) &= x\dot{q} + M^{-1}(q)[\tau - C(q, \dot{q}) \\ &- G(q) - F(\dot{q})] + \hat{\Omega}(q, \dot{q}, \tau | \hat{V}, \hat{W}) \end{aligned}$$

이다. 식 (19)의 일차 필터를 다시 정리하면 다음과 같이 표현된다.

$$\begin{aligned} \dot{\tau} &= M(q)\dot{\mu} + C(q, \dot{q}) + G(q) \\ &+ F(\dot{q}) - xM(q)(\dot{q} - \mu) \\ &- M(q)\hat{\Omega}(q, \dot{q}, \tau | \hat{V}, \hat{W}) \end{aligned} \quad (19)$$

이식을 (*)에 대입하면,

$$\begin{aligned} M(q)(\dot{q} - \mu) &= -xM(q)(\dot{q} - \mu) + M(q) \\ &\{\Omega(q, \dot{q}, \tau) - \hat{\Omega}(q, \dot{q}, \tau | \hat{V}, \hat{W})\} \end{aligned} \quad (20)$$

외란 관측 오차를 다음과 같이 정의하도록 한다.

$$\zeta = q - \mu \quad (21)$$

여기서 ζ 를 외란 관측 오차라 하는 것은 $\zeta \rightarrow 0$ 으로 $\mu \rightarrow q$ 인 경우, 식(20)에서 신경망의 출력 $\hat{\Omega}(q, \dot{q}, \tau | \hat{V}, \hat{W})$ 이 외란 $\Omega(q, \dot{q}, \tau)$ 에 접근하는 것을 의미하

며 다시 말해서 신경회로망이 주어진 시스템에 발생한 외란을 잘 관측하는 것을 의미하기 때문이다. 이때 외란 관측 오차의 다이나믹스는 식 (20)으로부터 다음의 식으로 표현된다.

$$\dot{\zeta} = -x \zeta + \Omega(\mathbf{q}, \dot{\mathbf{q}}, \tau) - \hat{\Omega}(\mathbf{q}, \dot{\mathbf{q}}, \tau | \hat{V}, \hat{W}) \quad (21)$$

B. 신경망 외란관측기의 학습과 제어

신경망 외란관측기가 발생하는 외란을 잘 관측하는 경우 그림 1의 방식대로 제어기를 설계하면 계산도와 크 방식의 제어기를 변형한 다음의 식 (22)로 표현되는 제어기를 얻게된다.

$$\begin{aligned} \tau &= \mathbf{M}(\mathbf{q})(\ddot{\mathbf{q}}_d + \mathbf{K}_v \dot{\mathbf{q}} + \mathbf{K}_p \tilde{\mathbf{q}}) + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) + \\ &\quad \mathbf{G}(\mathbf{q}) - \mathbf{M}(\mathbf{q}) \hat{\Omega}(\mathbf{q}, \dot{\mathbf{q}}, \tau | \hat{V}, \hat{W}) \end{aligned} \quad (22)$$

이고 $\tilde{\mathbf{q}} = \mathbf{q}_d - \mathbf{q}$ 이다. 여기서 위 식을 실제로 구현할 때는 τ 가 식의 좌우변에 모두 나타나므로 이를 직접 구현할 수는 없다. 그러나 결국 제어 신호 τ 는 \mathbf{q} 와 $\dot{\mathbf{q}}$ 의 함수여야 하므로 이를 이용하여 신경망 쪽을 표현하면 결국 신경망 부분은 식 (23)과 같이 \mathbf{q} 와 $\dot{\mathbf{q}}$ 의 함수로 표현될 수 있다.

$$\hat{\Omega}(\mathbf{q}, \dot{\mathbf{q}}, \tau(\mathbf{q}, \dot{\mathbf{q}}) | \hat{V}, \hat{W}) = \hat{\phi}(\mathbf{q}, \dot{\mathbf{q}} | \hat{V}_\phi, \hat{W}_\phi) \quad (23)$$

본 논문에서는 편의상 $\hat{\phi}(\cdot)$ 대신 $\hat{\Omega}(\cdot)$ 를 그대로 사용하면 로봇 제어 식은 다음의 식 (24)로 표현된다.

$$\begin{aligned} \tau &= \mathbf{M}(\mathbf{q})(\ddot{\mathbf{q}}_d + \mathbf{K}_v \dot{\mathbf{q}} + \mathbf{K}_p \tilde{\mathbf{q}}) + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) + \\ &\quad \mathbf{G}(\mathbf{q}) - \mathbf{M}(\mathbf{q}) \hat{\Omega}(\mathbf{q}, \dot{\mathbf{q}}, \tau | \hat{V}, \hat{W}) \end{aligned} \quad (24)$$

즉 신경망 외란관측기의 입력으로 \mathbf{q} 와 $\dot{\mathbf{q}}$ 만 사용해도 된다는 것을 의미한다.

이제 $\zeta \rightarrow 0$ 이 되도록, 즉 신경망 외란관측기 $\hat{\Omega}$ 가 실제 외란 Ω 를 잘 관측하도록 ($\hat{\Omega} \rightarrow \Omega$) 신경망 웨이트를 학습하면 식 (23)의 수정 계산 토오크 방식 제어기는 훌륭한 성능을 보일 것으로 예측된다. 그러나 ζ 을 줄이는 방향으로만 신경마을 학습하면 이론적으로 ζ 의 안정도만 보장되지만 로봇 제어오차에 대해서는 어떠한 보장도 할 수 없다. 따라서 이 같은 문제를 해결하기 위해서는 신경망 웨이트는 ζ 뿐 아니라 로봇 제어오차 $\tilde{\mathbf{q}}$ 과 $\dot{\tilde{\mathbf{q}}}$ 도 줄이도록 학습하여야 한다. 이를

위해 외란 관측기의 오차 다이나믹스 (21)과 제어기 (22)를 이용한 로봇 제어 시스템 (10)의 오차 다이나믹스를 결합하면 다음의 확장오차 다이나믹스를 얻는다.

$$\dot{\mathbf{x}} = \Pi \mathbf{E} + \mathbf{B}[\Omega(\boldsymbol{\theta}) - \hat{\Omega}(\boldsymbol{\theta} | \hat{V}, \hat{W})] \quad (25)$$

$$\text{여기서 } \mathbf{E} = \begin{pmatrix} \tilde{\mathbf{q}} \\ \dot{\tilde{\mathbf{q}}} \\ \zeta \end{pmatrix}, \quad \Pi = \begin{pmatrix} 0 & I & 0 \\ -\mathbf{K}_p & -\mathbf{K}_v & 0 \\ 0 & 0 & -xI \end{pmatrix}, \quad \mathbf{B} = \begin{pmatrix} 0 \\ -I \\ I \end{pmatrix}$$

이고 신경망 입력 $\boldsymbol{\theta} = (\mathbf{q}, \dot{\mathbf{q}})$ 이다. 또 \mathbf{E} 는 확장오차로 로봇 제어오차와 외란 관측 오차를 동시에 나타내는 양이며 Π 는 $\mathbf{K}_p, \mathbf{K}_v, x$ 의 정의에 따라 안정한 (Hurwitz) 행렬이다. 이제 다음의 정리는 신경망 관측기의 웨이트를 조정하는 역전파 알고리즘을 제안한다.

정리 1.

식 (10)으로 표현되는 로봇 시스템에 대하여 식 (19)의 일차 필터를 이용하여 외란을 관측한다. 이때 로봇 시스템은 식 (22)의 수정 계산 토오크 방식에 의하여 제어하고 외란 관측기로 사용되는 신경망을 식 (26)(27)으로 학습할 때, 외란 관측 오차 ζ 와 로봇 제어오차 $\tilde{\mathbf{q}}$ 과 $\dot{\tilde{\mathbf{q}}}$ 를 포함하고 있는 확장 오차 \mathbf{E} 는 절대상시유계(uniform ultimate bounded, UUB) 된다. ($\zeta, \tilde{\mathbf{q}}, \dot{\tilde{\mathbf{q}}} \in L_\infty$)

$$\hat{W} = \Gamma_w \mathbf{B}^T P \mathbf{E} \Sigma^T(\hat{V} \boldsymbol{\theta}) \quad (26)$$

$$\hat{V} = \Gamma_v \Sigma_v(\hat{V} \boldsymbol{\theta}) \hat{W}^T \mathbf{B}^T P \mathbf{E} \boldsymbol{\theta}^T \quad (27)$$

여기서 Γ_w 와 Γ_v 는 양한정 대각행렬로 신경망 웨이트의 학습율을 나타내며 $\Sigma_v(\cdot)$ 는 $\mathbf{h} = (h_1, h_2, \dots, h_n)^T$ 에 대하여 다음과 같이 정의된다.

$$\Sigma_v(\mathbf{h}) = \begin{pmatrix} 1 - \sigma^2(h_1) & 0 & \cdots & 0 \\ 0 & 1 - \sigma^2(h_2) & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 0 & 0 & \cdots & 1 - \sigma^2(h_n) \end{pmatrix} \quad (28)$$

또 P 는 $\Pi^T P + P \Pi = -Q$ 을 만족하는 양한정 행렬이다.

- 증명 -

앞에서 언급한 바와 같이 확장 오차는 다음의 식 (29)로 주어진다.

$$\dot{\mathbf{x}} = \Pi \mathbf{E} + \mathbf{B}[\Omega(\boldsymbol{\theta}) - \hat{\Omega}(\boldsymbol{\theta} | \hat{V}, \hat{W})] \quad (29)$$

이제 신경망을 식 (14)로 표현하고 미지의 외란을 식 (17)로 표현하면 전체 확장오차의 다이나믹스는 다음의 식으로 정리된다.

$$\dot{\Sigma} = \Pi\Sigma + B[\mathbf{W}\Sigma(\mathbf{V}^*\Theta) - \widehat{\mathbf{W}}\Sigma(\widehat{\mathbf{V}}\Theta)] + B\varepsilon(\Theta) \quad (30)$$

신경망의 웨이트 오차를 $\widetilde{\mathbf{V}} = \mathbf{V}^* - \widehat{\mathbf{V}}$, $\widetilde{\mathbf{W}} = \mathbf{W} - \widehat{\mathbf{W}}$ 로 정의하고 다시 쓰면

$$\begin{aligned} \dot{\Sigma} &= \Pi\Sigma + B[\mathbf{W}\Sigma(\mathbf{V}^*\Theta) - \mathbf{W}\Sigma(\widehat{\mathbf{V}}\Theta) \\ &\quad + \mathbf{W}\Sigma(\widehat{\mathbf{V}}\Theta) - \widehat{\mathbf{W}}\Sigma(\widehat{\mathbf{V}}\Theta)] + B\varepsilon(\Theta) \\ &= \Pi\Sigma + B[\widetilde{\mathbf{W}}[\Sigma(\mathbf{V}^*\Theta) - \Sigma(\widehat{\mathbf{V}}\Theta)] \\ &\quad + \widetilde{\mathbf{W}}[\Sigma(\mathbf{V}^*\Theta) - \Sigma(\widehat{\mathbf{V}}\Theta)] \\ &\quad + \widetilde{\mathbf{W}}\Sigma(\widehat{\mathbf{V}}\Theta)] + B\varepsilon(\Theta). \end{aligned} \quad (31)$$

위 식에 대한 신경회로망 학습 규칙을 유도하기 위하여 다음의 식(32)과 같이 활성 힘수 벡터 $\Sigma(\widehat{\mathbf{V}}\Theta)$ 를 \mathbf{V}^* 의 주위에서 Taylor전개한다.

$$\begin{aligned} \Sigma(\widehat{\mathbf{V}}\Theta) &= \Sigma(\mathbf{V}^*\Theta) + \Sigma_v(\widehat{\mathbf{V}}\Theta) \cdot (\widehat{\mathbf{V}} - \mathbf{V}^*)\Theta \\ &\quad + O(\widehat{\mathbf{V}}\Theta) \end{aligned} \quad (32)$$

여기서 $O(\widehat{\mathbf{V}}\Theta)$ 는 $\Sigma(\widehat{\mathbf{V}}\Theta)$ 의 Taylor전개에서 발생하는 이차 이상의 고차항이다. 이 식을 식 (31)에 대입하면 다음의 식(33)과 같은 확장 오차의 다이나믹스를 얻는다.

$$\begin{aligned} \dot{\Sigma} &= \Pi\Sigma + B[\widetilde{\mathbf{W}}\Sigma(\widehat{\mathbf{V}}\Theta) + \widehat{\mathbf{W}}\Sigma_v(\widehat{\mathbf{V}}\Theta) \\ &\quad + \widetilde{\mathbf{V}}\Theta] + \nu(\Theta) \end{aligned} \quad (33)$$

여기서 $\nu(\Theta) = B[\widetilde{\mathbf{W}}[\Sigma(\mathbf{V}^*\Theta) - \Sigma(\widehat{\mathbf{V}}\Theta)] - \widehat{\mathbf{W}}O(\widehat{\mathbf{V}}\Theta) + \varepsilon(\Theta)]$ 이다. 또 앞에서도 언급한 바와 같이 Π 는 안정한 행렬이므로 임의의 양한정 행렬 \mathbf{Q} 에 대하여 다음을 만족하는 양한정 행렬 \mathbf{P} 가 존재한다.

$$\Pi^T P + P\Pi = -\mathbf{Q} \quad (34)$$

외란 관측 오차와 함께 제어 오차를 함께 줄이는 방향으로 신경 회로망을 학습하기 위하여 Lyapunov 후보 함수를 다음과 같이 확장 오차 Σ 를 이용하여 정의한다.

$$V = \frac{1}{2}\Sigma^T P\Sigma + \frac{1}{2}\text{tr}(\widetilde{\mathbf{W}}^T \Gamma_w^{-1} \widetilde{\mathbf{W}})$$

$$+ \frac{1}{2}\text{tr}(-\widetilde{\mathbf{V}}^T \Gamma_v^{-1} \widetilde{\mathbf{V}}) \quad (35)$$

이제 이 함수를 시간에 대하여 미분하고 식 (33)을 이용하면,

$$\begin{aligned} \dot{V} &= \Sigma^T P \dot{\Sigma} + \text{tr}(-\widetilde{\mathbf{W}}^T \Gamma_w^{-1} \widetilde{\mathbf{W}}) + \text{tr}(-\widetilde{\mathbf{V}}^T \Gamma_v^{-1} \widetilde{\mathbf{V}}) \\ &= \Sigma^T P \Pi \Sigma + \Sigma^T P B [\widetilde{\mathbf{W}}\Sigma(\widehat{\mathbf{V}}\Theta) + \widehat{\mathbf{W}}\Sigma_v(\widehat{\mathbf{V}}\Theta) \widetilde{\mathbf{V}}\Theta] \\ &\quad + \text{tr}(-\widetilde{\mathbf{W}}^T \Gamma_w^{-1} \widetilde{\mathbf{W}}) + \text{tr}(-\widetilde{\mathbf{V}}^T \Gamma_v^{-1} \widetilde{\mathbf{V}}) + \Sigma^T P \nu(\Theta) \\ &= \frac{1}{2}\Sigma^T (P\Pi + \Pi^T P)\Sigma + \text{tr}\{\Sigma^T(\widehat{\mathbf{V}}\Theta) \widetilde{\mathbf{W}}^T B^T P\Sigma\} \\ &\quad + \text{tr}\{\Theta^T \widetilde{\mathbf{V}}^T \Sigma_v(\widehat{\mathbf{V}}\Theta) \widetilde{\mathbf{W}}^T B^T P\Sigma\} \\ &\quad + \text{tr}(-\widetilde{\mathbf{W}}^T \Gamma_w^{-1} \widetilde{\mathbf{W}}) + \text{tr}(-\widetilde{\mathbf{V}}^T \Gamma_v^{-1} \widetilde{\mathbf{V}}) + \Sigma^T P \nu(\Theta) \\ &= -\frac{1}{2}\Sigma^T Q\Sigma + \text{tr}\{\widetilde{\mathbf{W}}^T B^T P\Sigma \Sigma^T(\widehat{\mathbf{V}}\Theta)\} \\ &\quad + \text{tr}\{\widetilde{\mathbf{V}}^T \Sigma_v(\widehat{\mathbf{V}}\Theta) \widetilde{\mathbf{W}}^T B^T P\Sigma \Theta^T\} \\ &\quad + \text{tr}(-\widetilde{\mathbf{W}}^T \Gamma_w^{-1} \widetilde{\mathbf{W}}) + \text{tr}(-\widetilde{\mathbf{V}}^T \Gamma_v^{-1} \widetilde{\mathbf{V}}) + \Sigma^T P \nu(\Theta) \\ &= -\frac{1}{2}\Sigma^T Q\Sigma + \text{tr}\{\widetilde{\mathbf{W}}^T [\Gamma_w^{-1} \widetilde{\mathbf{W}} + B^T P\Sigma \Sigma^T(\widehat{\mathbf{V}}\Theta)]\} \\ &\quad + \text{tr}\{\widetilde{\mathbf{V}}^T [\Gamma_v^{-1} \widetilde{\mathbf{V}} + \Sigma_v(\widehat{\mathbf{V}}\Theta) \widetilde{\mathbf{W}}^T B^T P\Sigma \Theta^T]\} \\ &\quad + \Sigma^T P \nu(\Theta) \end{aligned}$$

여기에 신경 회로망 웨이트 학습 규칙의 식 (26)과 (27)를 넣고 정리하면 Lyapunov 후보 함수 V 의 시간 도함수는 다음과 같이 정리된다.

$$\dot{V} \leq -\frac{1}{2}\Sigma^T Q\Sigma + \Sigma^T P \nu(\Theta) \quad (36)$$

$$\leq -\frac{1}{2}\lambda_{\min}(\mathbf{Q})\|\Sigma\|^2 + \Sigma^T P \nu(\Theta)$$

$$\pm \left\{ \frac{\lambda_{\min}(\mathbf{Q})}{4\lambda_{\max}(\mathbf{P})} \Sigma^T P\Sigma + \frac{\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})} \nu^T(\Theta) P \nu(\Theta) \right\}$$

$$\leq -\frac{1}{2}\lambda_{\min}(\mathbf{Q})\|\Sigma\|^2 + \left\{ \frac{\lambda_{\min}(\mathbf{Q})}{4\lambda_{\max}(\mathbf{P})} \Sigma^T P\Sigma \right.$$

$$\left. + \frac{\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})} \nu^T(\Theta) P \nu(\Theta) \right\} - \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(\mathbf{Q})}{\lambda_{\max}(\mathbf{P})}} \Sigma \right.$$

$$\left. - \sqrt{\frac{\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})}} \nu \right)^T P \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(\mathbf{Q})}{\lambda_{\max}(\mathbf{P})}} \Sigma \right.$$

$$\left. - \sqrt{\frac{\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})}} \nu \right)$$

$$\leq -\frac{1}{4}\lambda_{\min}(\mathbf{Q})\|\Sigma\|^2 + \frac{\lambda_{\max}^2(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})}\|\nu(\Theta)\|^2$$

따라서 $\|\mathbf{E}\| \geq 2 \frac{\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})} \|\nu(\boldsymbol{\Theta})\|$ 인 경우 $V < 0$ 이

다. 여기서 $\nu(\boldsymbol{\Theta})$ 는 정의에 의해서 $\|\nu(\boldsymbol{\Theta})\| < \bar{\nu}$ 를 보일 수 있고 외란 관측 오차와 로봇 제어오차를 포함한 확장 오차 \mathbf{E} 는 절대 상시 유계 (UUB) 된다. ■

주의 1.

(1) 정리 1의 신경망 웨이트 학습 규칙 (26)과 (27)를 다음의 식 (37)과 (38)과 같이 투사규칙(projection rule)^[20]을 이용하여 수정하면 학습오차 역시 절대상시 유계되고 관련된 모든 신호는 유계된다.

$$\begin{aligned} \hat{\mathbf{W}} &= \Gamma_w \mathbf{B}^T \mathbf{P} \mathbf{E} \Sigma^T (\hat{V} \boldsymbol{\Theta}) \\ &- I_w \frac{\text{tr}\{\Gamma_w \mathbf{B}^T \mathbf{P} \mathbf{E} \Sigma^T (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T\}}{\text{tr}(\hat{\mathbf{W}}^T \Gamma_w \hat{\mathbf{W}})} \Gamma_w \hat{\mathbf{W}} \end{aligned} \quad (37-1)$$

$$I_w = \begin{cases} 0, & \text{if } \|\hat{\mathbf{W}}\| < M_w \text{ or} \\ & \|\hat{\mathbf{W}}\| = M_w \text{ and } \text{tr}\{\Gamma_w \mathbf{B}^T \mathbf{P} \mathbf{E} \Sigma^T (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T\} \leq 0 \\ 1, & \text{if } \|\hat{\mathbf{W}}\| = M_w \text{ and } \text{tr}\{\Gamma_w \mathbf{B}^T \mathbf{P} \mathbf{E} \Sigma^T (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T\} > 0 \end{cases} \quad (37-2)$$

$$\begin{aligned} \hat{V} &= \Gamma_v \Sigma_v (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T \mathbf{B}^T \mathbf{P} \mathbf{E} \boldsymbol{\Theta}^T \\ &- I_v \frac{\text{tr}\{\Gamma_v \Sigma_v (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T \mathbf{B}^T \mathbf{P} \mathbf{E} \boldsymbol{\Theta}^T \hat{V}^T\}}{\text{tr}(\hat{V}^T \Gamma_v \hat{V})} \Gamma_v \hat{V} \end{aligned} \quad (38-1)$$

$$I_v = \begin{cases} 0, & \text{if } \|\hat{V}\| < M_v \text{ or} \\ & \|\hat{V}\| = M_v \text{ and } \text{tr}\{\Gamma_v \Sigma_v (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T \mathbf{B}^T \mathbf{P} \mathbf{E} \boldsymbol{\Theta}^T \hat{V}^T\} \leq 0 \\ 1, & \text{if } \|\hat{V}\| = M_v \text{ and } \text{tr}\{\Gamma_v \Sigma_v (\hat{V} \boldsymbol{\Theta}) \hat{\mathbf{W}}^T \mathbf{B}^T \mathbf{P} \mathbf{E} \boldsymbol{\Theta}^T \hat{V}^T\} > 0 \end{cases} \quad (38-2)$$

(2) 위의 식 (36)에서 양변을 시간 $t=0$ 에서 $t=T$ 사이로 적분하면

$$\begin{aligned} \int_{t=0}^T \|\mathbf{E}(t)\|^2 dt &\leq \frac{4}{\lambda_{\min}(\mathbf{Q})} [V(0) - V(T)] \\ &+ \left\{ \frac{2\lambda_{\max}(\mathbf{P})}{\lambda_{\min}(\mathbf{Q})} \right\}^2 \int_0^T \|\nu(t)\|^2 dt \end{aligned}$$

이고 즉 확장 오차의 확장 L_2 놈은 ν 의 확장 L_2 놈의 차원에 유계된다.

(3) 정리에서 확장 오차의 유계 경계는 다음의 식 (39)으로 주어진다.

$$\|\mathbf{E}\| \leq \frac{2}{\gamma} \|\nu(\boldsymbol{\Theta})\|, \gamma = \frac{\lambda_{\min}(\mathbf{Q})}{\lambda_{\max}(\mathbf{P})} \quad (39)$$

여기서 γ 는 Π 시스템의 최대 감쇄율(maximal decay rate)로 K_p, K_v, χ 을 조절하여 원하는 만큼 크게 할 수는 있다. 따라서 확장오차는 γ 를 크게 하여 원하는 수준으로 줄일 수 있고 다른 신경망 제어 방식과 달리 스위치형 지도 장인 제어기를 추가로 필요로 하지 않는다.

V. 모의실험

본 논문에서는 제안한 알고리즘의 타당성을 확인하기 그림 3의 평면형 3축 로봇을 이용하여 모의실험을 수행한다. 평면형 3축 로봇에 대하여 $i=1, 2, 3$ 의 각 링크의 길이를 a_i 로 각 링크의 질량을 m_i 로, 또 각 링크의 무게 중심 주위의 관성모멘트를 I_{oi} 로 표시할 때 3축 로봇의 다이나믹스는 다음의 식 (40)으로 표현된다.

$$\begin{aligned} \mathbf{M}(\mathbf{q}) \begin{pmatrix} \ddot{q}_1 \\ \ddot{q}_2 \\ \ddot{q}_3 \end{pmatrix} + \begin{pmatrix} d_4 S_2 + d_5 S_{23} & -d_4 S_2 + d_6 S_3 & -d_5 S_{23} - d_6 S_3 \\ d_4 S_2 + d_5 S_{23} & d_6 S_3 & -d_6 S_3 \\ d_5 S_{23} & d_6 S_3 & 0 \end{pmatrix} \\ \begin{pmatrix} \dot{q}_1^2 \\ (\dot{q}_1 + \dot{q}_2)^2 \\ (\dot{q}_1 + \dot{q}_2 + \dot{q}_3)^2 \end{pmatrix} + \begin{pmatrix} v_1 \dot{q}_1 \\ v_2 \dot{q}_2 \\ v_3 \dot{q}_3 \end{pmatrix} \\ + \begin{pmatrix} \frac{1}{2} a_1 C_1 & a_1 C_1 + \frac{1}{2} a_2 C_{12} & a_1 C_1 + a_2 C_{12} + \frac{1}{2} a_3 C_{123} \\ 0 & \frac{1}{2} a_2 C_{12} & a_2 C_{12} + \frac{1}{2} 2 a_3 C_{123} \\ 0 & 0 & \frac{1}{2} a_3 C_{123} \end{pmatrix} \\ \begin{pmatrix} m_1 g \\ m_2 g \\ m_3 g \end{pmatrix} = \tau \end{aligned} \quad (40)$$

여기서

$$\mathbf{M}(\mathbf{q}) = \begin{pmatrix} 2d_1 + d_4 C_2 + d_5 C_{23} & 2d_2 + d_4 C_2 + d_6 C_3 & 2d_3 + d_5 C_{23} + d_6 C_3 \\ d_4 C_2 + d_5 C_{23} & 2d_2 + d_6 C_3 & 2d_3 + d_6 C_3 \\ d_5 C_{23} & d_6 C_3 & 2d_3 \end{pmatrix}$$

$$\begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \end{pmatrix}$$

이고 $g=9.8 \text{m/sec}^2$ 를 나타내며 S_i 나 C_{ij} 는 삼각함수값을 나타낸다. 즉 S_1 는 $\sin(q_1)$ 을 의미하며 C_{12} 는 $\cos(q_1 + q_2)$ 를 표현한 것이다. 끝으로 d_i 의 정의는 다음의 표 1과 같다.

표 2는 모의 실험에 사용되는 로봇의 공칭 파라미터와 실제 파라미터를 나타내고 있다. 본 모의 실험에서는 로봇의 각 관절 질량에 불확실성이 있어서 우리가

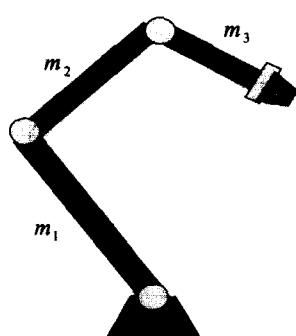


그림 3. 평면형 3축 로봇

Fig. 3. Planar three-link robot.

표 1. 로봇 파라미터 d의 정의

Table 1. Definition of the robot parameter d.

d_i	정의
d_1	$\frac{1}{2}[(\frac{1}{4}m_1 + m_2 + m_3)a_1^2 + I_{o1}]$
d_2	$\frac{1}{2}[(\frac{1}{4}m_2 + m_3)a_2^2 + I_{o2}]$
d_3	$\frac{1}{2}[(\frac{1}{4}m_3)a_3^2 + I_{o3}]$
d_4	$(\frac{1}{2}m_2 + m_3)a_1a_2$
d_5	$\frac{1}{2}m_3a_1a_3$
d_6	$\frac{1}{2}m_3a_2a_3$

표 2. 로봇의 공칭 파라미터와 실제 파라미터
Table 2. Actual and nominal parameters of robot system.

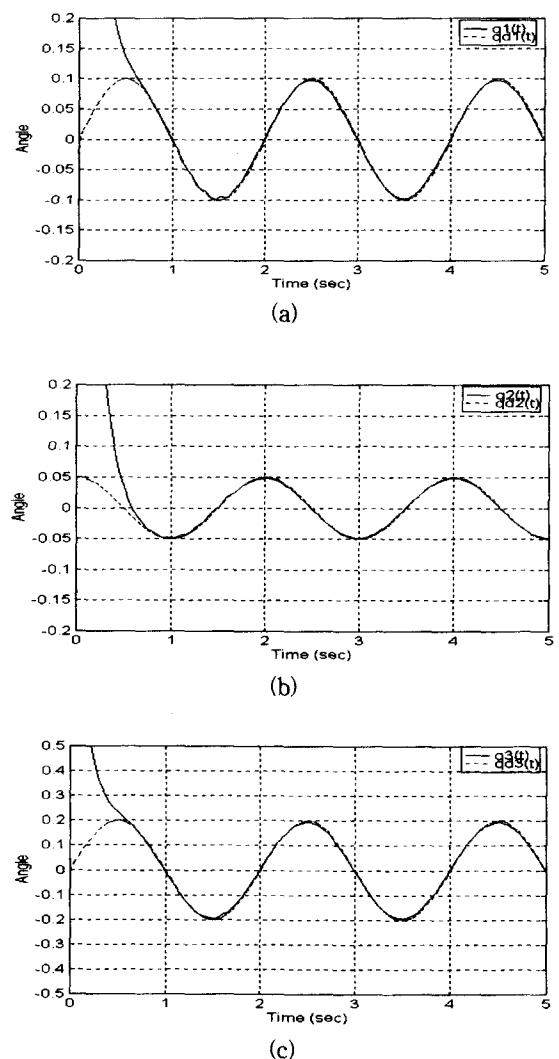
	질량 (m_i , Kg)		링크길이 (a_i , m)	관성모멘트 (I_{oi} , Kgm^2)
	공칭값	실제값		
관절 1	1.0	1.3	1.0	43.33×10^{-3}
관절 2	0.7	1.0	1.0	25.08×10^{-3}
관절 3	1.4	1.4	0.5	32.67×10^{-3}

알고 있는 공칭 질량과 실제 로봇의 질량간에 차이가 있는 것으로 간주한다. 이 파라미터의 차이를 제안한 신경망 외란 관측기를 이용하여 관측하고 상쇄하여야 한다.

위의 모의실험에서 기준신호는 다음의 식 (41)과 같아 하였다.

$$\mathbf{q}_d = \begin{pmatrix} q_{d1} \\ q_{d2} \\ q_{d3} \end{pmatrix} = \begin{pmatrix} 0.1 \sin(\pi t) \\ 0.05 \cos(\pi t) \\ 0.2 \sin(\pi t) \end{pmatrix} (\text{rad}) \quad (41)$$

제어기는 식 (22)의 수정 계산토오크 제어기를 사용하였고 K_v 와 K_u 는 크리티컬 뎁핑을 위하여 각 $20I_v$ 와 $100I_u$ 로 선택하였다. 반면, 신경망 외란 관측기의 1차 필터의 극점은 $x = -10$ 으로 하였고 신경회로망은 3층의 구조로 입력노드는 6개가 되며 (a, q), 은닉층의 중간노드는 70개를 사용하였고, 출력층은 3 자유도 (DOF) 로봇이므로 3개의 노드로 구성하였다. 학습율은 출력층에서나 은닉층에서나 모두 $\Gamma_v = 15I_v$, $\Gamma_u = 15I_u$ 으로 하였다. 그림 4는 각 관절의 기준신호와 실제 관절값을 나타낸다. 마치 로봇 동력학에 불확실성이 없는 것 같이 1~2초안에 로봇 관절값이 기준 신호를 추적

그림 4. 제어결과
Fig. 4. Control result.

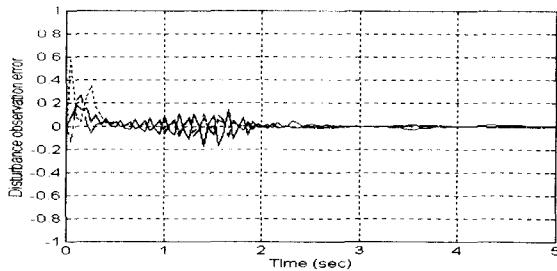


그림 5. 외란관측오차

Fig. 5. Disturbance observation error.

하는 것을 볼 수 있다. 그림 5는 세 관절의 외란관측 오차를 나타낸다. 약 2초 후에 각 관절의 외란관측오차가 사라지는 것을 알 수 있다.

VI. 결 론

본 논문에서는 신경망 외란관측기를 제안하였고 이를 이용하여 불확실한 로봇시스템의 운동을 제어하는 알고리즘을 제안하였다. 본 논문에서 제안한 알고리즘은 신경망이 오프라인으로 학습할 필요없이 제어와 학습이 동시에 수행되는 방법으로 로봇의 회귀함수를 요구하지 않는 특징을 가지고 있다.

추후 연구 과제로 불확실한 로봇의 힘제어에 적용하는 방식에 대한 연구가 요망된다.

참 고 문 헌

- [1] R. J. Schilling, *Fundamentals of Robotics*, Englewood Cliffs, NJ: Prentice Hall, 1990.
- [2] F. L. Lewis, C. T. Abdallah, and D. M. Dawson, *Control of Robot Manipulators*, New York, MacMillan Publishing Company, 1993.
- [3] Spong and M. Vidyasagar, *Robot Dynamics and Control*, John Wiley & Sons, Inc., 1989.
- [4] L. R. Hunt, R. Su and G. Meyer, "Global transformations of nonlinear systems," *IEEE Trans. Autom. Control*, vol. AC-28, no. 1, pp. 24-31, 1983.
- [5] R. Ortega and M. W. Spong, "Adaptive motion control of rigid robots: A tutorial," *Automatica*, vol. 25, pp. 977-888, 1989.
- [6] 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.
- [7] J. J. E. Slotine and W. Li, *Applied Nonlinear Control*, Prentice Hall 1991.
- [8] C. Abdallah, D. Dawson, P. Dorato and M. Jamshidi, "Survey of robust control of rigid robots," *IEEE Contr. Syst. Mag.*, vol. 11, pp. 24-30, 1991.
- [9] Y. Stepanenko and C. Y. Su, "Variable structure control of robust manipulators with nonlinear sliding manifolds," *Int. Jour. Contr.*, vol. 58, pp. 265-300, 1993.
- [10] C. Y. Su and Y. Stepanenko, "Adaptive variable structure tracking control for constrained robots," *IEEE Trans. Aerospace and Electronic Systems*, vol. 30, no. 2, pp. 493-503, 1994.
- [11] H. Miyamoto, M. Kawato, T. Setoyama and R. Suzuki, "Feedback error learning neural networks for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, pp. 251-265, 1988.
- [12] M. Kawato, Y. Uno, M. Isobe and R. Suzuki, "Hierarchical neural network model for voluntary movement with application to robotics," *IEEE Control Systems Mag.*, pp. 8-16, 1988.
- [13] F. L. Lewis, A. Yesildirek and K. L. Liu, "Multilayer neural-net robot controller with guaranteed tracking performance," *IEEE Trans. Neural Networks*, vol. 7, no. 2, pp. 388-399, 1996.
- [14] V. Yen and T. -Z. Liu, "A neural network assisted computed torque method for manipulator tracking control problems," *Int. Jour. of Systems Science*, vol. 27, no. 11, pp. 1133-1141, 1996.
- [15] R. Carelli, E. F. Camacho and D. Patino, "A neural network based feedforward adaptive controller for robots," *IEEE Trans. Sys., Man, and Cyb.*, vol. 25, no. 9, pp. 1281-1288, 1995.
- [16] V. Etxebarria and M. de La Sen, "An approach

- to adaptive neural control of robot manipulators," Int. Jour. of Systems Science, vol. 27, no. 11, pp. 1143-1152, 1996.
- [17] W. H. Chen, D. J. Ballance, P. J. Gawthrop and J. O'Reilly, "A nonlinear disturbance observer for robotic manipulator," IEEE Trans. Ind. Electron., vol. 47, no. 4, pp. 932-938, 2000.
- [18] K. Funahashi, "On the approximate realization of continuous mappings by neural networks," Neural Networks, vol. 2, pp. 183-192, 1989.
- [19] K. Hornik, M. Stinchcombe and H. White, "Multilayer feedforward networks are universal approximators," Neural Networks, vol. 2, pp. 359-366, 1989.
- [20] L. X. Wang, A Course in Fuzzy Systems and Control, NJ: Prentice-Hall, 1997.

저자 소개

金 殷 泰(正會員)

1992년 2월 : 연세대학교 전자공학과 졸업(공학사). 1994년 2월 : 연세대학교 전자공학과 석사과정 졸업(공학석사). 1999년 2월 : 연세대학교 전자공학과 박사과정 졸업(공학박사). 1999년 3월~2002년 2월 : 국립환경대학교 제어계측공학과 조교수. 2002년 3월~현재 : 연세대학교 전기전자공학부 조교수. 1998년~현재 : IEEE TFS, IEEE SMC, IEEE CAS, FSS 등에서 심의위원으로 활동중. <주관심분야 : 소프트컴퓨팅, 로보틱스와 메카트로닉스>

金 漢 正(正會員)

1994년 12월 : 미국 Auburn University 물리학과졸업 (ø학사). 1989년 9월 : 미국 Auburn University 물리학과석사과정 졸업. 1996년~현재 : 국립환경대학교 제어계측공학과 조교수. 현재 : American Physical Society member 및 한국 플라즈마 협회, 한국 물리학회, 대한전자공학회 회원으로 활동중. <주관심분야~박막물성연구, 타원분광기 이론 및 측정, 확산에의한 산화이론, 디지털응용, 퍼지이론, 로봇추적제어 등>