

## 학습을 이용한 로봇 머니플레이터용 지능제어

### Intelligent Control of Robot Manipulators by Learning

이 동 훈, 정 재 욱\*, 국 태 욱  
(DongHun Lee, ChaeWook Chung, and TaeYong Kuc)

**Abstract :** An intelligent control method is proposed for control of rigid robot manipulators which achieves exponential tracking of repetitive robot trajectory under uncertain operating conditions such as parameter uncertainty and unknown deterministic disturbance. In the learning controller, exponentially stable learning algorithms are combined with stabilizing computed error feedforward and feedback inputs. It is shown that all the error signals in the learning system are bounded and the repetitive robot motion converges to the desired one exponentially fast with guaranteed convergence rate. An engineering workstation based control system is built to verify the effectiveness of the proposed control scheme.

**Keywords :** learning controller, robot manipulator, exponential tracking, uncertainty

#### I. 서론

최근 로봇 머니플레이터의 완전한 비선형 동력학에 적용하기 위한 적응제어 방법들이 개발되어 오고 있다[4,8,10][13,14,15,17,18,19]. 로봇 머니플레이터의 적응제어기에 대한 최근의 연구결과 중에, 소위 계산 토크(computed torque)에 기초한 제어기법은 로봇 시스템의 불완전한 모델링으로 인한 파라미터 불확실성(uncertainty)뿐만 아니라 로봇 동력학의 비선형성까지도 고려하고 있다[4,10,13,14,15,17,19]. 머니플레이터 동역학의 구조에 관하여 이들 제어기의 전역 안정도(global stability) 증명을 가능하게 하는 세 가지 핵심적인 특징은 관성행렬의 양의 한정성 (positive definiteness), 선형 파라미터화(parameterization) 성질, 로봇 시스템의 수동성(passivity)이다.

이와는 달리 로봇 운동 궤적의 반복적인 성질을 바탕으로 한 학습 기법들이 최근 로봇공학의 여러 문헌에 제시되고 있다[1,2,3,4,5,6,9,11,15]. 다양한 학습제어 기법들 중에서 계산 토크에 기초한 학습제어 기법들은 학습 초기 단계에 로봇 동력학의 안정화를 위해 몇몇 추가적인 계산 토크 입력들을 사용한다. 그러나 이러한 학습제어 기법들은 계산 토크에 기초한 적응제어 기법[4,10,13,14,15,17,19]들과는 달리 정상 상태 뿐만 아니라 과도 상태에서도 로봇 운동의 성능을 향상시킨다. 학습제어는 로봇 운동을 시행하는 횟수에 따라 원하는 궤적(desired trajectory)에 대한 최적제어입력을 학습한다는 측면에서 볼 때 점근적인(asymptotic) 최적제어 방법으로 생각할 수도 있다.

적응제어와 학습제어 방법, 이 두 가지 제어 방법은 각각 적응성, 최적성, 강인성 등 나름대로 유용하고 장점들을 가지고 있기 때문에 두 제어 방법을 하나의 통일된 제어기로

합칠 때 친다면 로봇 지능이라는 측면에서 더욱 실용적이고도 효과적인 제어를 기대할 수 있다.

이 논문은 계산 토크 오차에 기초한 학습제어 기법[6]을 로봇 머니플레이터용 최적 학습제어기의 합성과 해석에 적용한 방법을 확장한 것으로, 학습제어기의 수렴 속도를 조절하는 알고리즘[7]을 기초로 수렴 속도를 임의대로 빠르게 설정할 수 있는 최적 학습제어기를 개발한다.

제안된 최적학습제어기는 시스템파라미터를 예측할 수 있을 뿐만 아니라, 로봇시스템의 원하는 궤적에 따르는 역동력학의 해인 최적 제어 입력을 학습할 수 있다.

아울러 적응 제어 기법에서 사용하는 표준 Lyapunov 안정도 이론을 이용하여 개발한 학습제어 시스템의 모든 신호들이 유계됨을 보이고, 로봇 운동이 원하는 운동으로 전역적이며 지수적으로 수렴함을 입증한다. 제안한 최적 학습제어기의 괄목할 만한 특징 중의 하나는 미리 정해진 수렴 속도로써 학습제어 시스템이 지수적으로 수렴한다는 것이다. 이때 수렴 속도는 파라미터 불확실성과 미지의 확정(deterministic) 외란과는 무관하게 정할 수 있다.

#### II. 문제설정

다음과 같은  $n$  자유도를 가진 강체 머니플레이터 시스템을 고찰한다.

$$D(q)\ddot{q} + B(q, \dot{q})\dot{q} + g(q, \dot{q}) + d = \tau \quad (1)$$

여기서  $q \in R^n$ 는 일반화 관절 좌표 벡터,  $D(q) \in R^{n \times n}$ 는 양의 값을 가지는 관성행렬,  $B(q, \dot{q})\dot{q}$ 는 구심력과 전향력 벡터,  $g(q, \dot{q})$ ,  $d$ ,  $\tau$ 는 각각 중력과 마찰력, 확정 외란, 입력 벡터를 나타낸다. 미지의 확정 외란 벡터는  $d(t) = d_1(t) + d_2(t)$ 이며, 여기서  $d_1$ 은 주기  $\delta$ 를 가지는 주기성 외란이고,  $d_2$ 는 양수  $d_0$ 에 대해  $\|d_2\| \leq d_0$ 으로 유계된다. 그러면 제어기 설계 목적은 로봇 시스템의 궤적  $q$ 를 원하는 궤적  $q_d \in C^2$ 로 주어진 수렴 속도로 이

\* 책임저자(Corresponding Author)

논문접수 : 2004. 6. 6., 채택확정 : 2004. 10. 19.

이동훈, 국태욱 : 성균관대학교 정보통신공학부

(neowintop@ece.skku.ac.kr/tykuc@yurim.skku.ac.kr)

정재욱 : 안산공과대학 컴퓨터정보계열(skechy@act.ac.kr)

※ 본 연구는 대학 IT연구센터 육성·지원사업의 연구결과로 수행되었음.

끄는 최적 학습제어기를 구하는 것이며, 이때  $C^2$ 는 연속적으로 두 번 미분 가능한 함수의 집합이고,  $M$ 은 양수이다. 원하는 궤적과 최적 제어 입력 함수의 집합은 주기  $\delta$ 를 가지는 것으로 가정한다.

즉,

$$\begin{aligned} q_d(t) &= q_d(t+\delta), & \bar{q}_d(t) &= \bar{q}_d(t+\delta) \\ \dot{q}_d(t) &= \dot{q}_d(t+\delta), & \tau_d(t) &= \tau_d(t+\delta) \end{aligned}$$

이고 여기서 원하는 제어 입력  $\tau_d$  다음과 같이 정의한다.

$$\tau_d = D(q_d) \ddot{q}_d + B(q_d, \dot{q}_d) \dot{q}_d + g(q_d, \dot{q}_d) + d_1$$

이러한 설정으로 제안하는 최적 학습제어기는 다음과 같다.

$$\tau(t) = \tau_{fb}(t) + \tau_{ce}(t) + \tau_o^+(t) \quad (2)$$

여기서  $\tau_{fb}$ ,  $\tau_{ce}$  그리고  $\tau_o$ 는 각각 피드백 오차 입력, 계산 토크 오차 입력, 학습제어 입력을 나타낸다. 아울러 투영 (projection) 함수  $(\cdot)^+$ 는 다음과 같다.

$$x_i^+ = \Pr(x_i) = \begin{cases} \bar{x}_i, & x_i > \bar{x}_i \\ x_i, & \underline{x}_i \leq x_i \leq \bar{x}_i \\ \underline{x}_i, & \text{otherwise,} \end{cases}$$

여기서  $x_i$ 는  $x$ 의  $i$ 번째 요소를 나타내며,  $x_i^*$ 는  $x_i$ 의 원하는 값 또는 실제 값을 나타낸다. 안정화 오차 입력은 다음과 같다.

$$\begin{aligned} \tau_{fb} &= Iz + \hat{d}_0 \cdot \text{sgn}(z) \gamma(e, \dot{e}) \\ \tau_{ce} &= Y_e \hat{\theta}^+ \end{aligned} \quad (3)$$

여기서  $e = q_d - q$ ,  $z = \dot{e} + ae$  ( $a > 0$ )이고 피드백 이득  $I$ 와 비선형 함수  $\gamma$ 는 다음 절에서 정의한다.  $\hat{d}_0$ 는  $d_0$ 의 추정량이고  $\text{sgn}(z)$ 는  $|z| \neq 0$ 일 때는  $\text{sgn}(z) = z/|z|$ 로,  $z = 0$ 일 때는  $\text{sgn}(z) = 0$ 으로 정의한다.  $(\hat{\cdot})$ 은 추정 파라미터를 갖는 추정 시스템을 나타내므로 다음과 같은 추정 오차 시스템을 정의할 수 있다.

$$\begin{aligned} Y_e \dot{\theta} &= \hat{D}_e(q) \ddot{q}_d + \hat{B}_e(q, \dot{q}) \dot{q}_d + \hat{g}_e(q, \dot{q}) \\ &+ a(\hat{D}(q)\dot{e} + \hat{B}(q, \dot{q})e) \end{aligned}$$

여기서

$$\begin{aligned} \hat{D}_e(q) &= \hat{D}(q) - \hat{D}(q_d) \\ \hat{B}_e(q, \dot{q}) &= \hat{B}(q, \dot{q}) - \hat{B}(q_d, \dot{q}_d) \\ \hat{g}_e(q, \dot{q}) &= \hat{g}(q, \dot{q}) - \hat{g}(q_d, \dot{q}_d) \end{aligned}$$

로 정의한다.

제어 입력 (2)를 불확실한 시스템 (1)에 인가하여 다음과 같은 오차 시스템을 얻는다.

$$\begin{aligned} D(q) \dot{z} + B(q, \dot{q})z + Iz &= d_2 - \hat{d}_0^+ \text{sgn}(z) \\ &+ Y_e \hat{\theta}^+ + \tau_o^+ \\ &- \gamma(e, \dot{e}) \end{aligned} \quad (4)$$

여기서 파라미터의 오차 벡터와 학습 입력은  $\hat{\theta}^+ = \theta - \bar{\theta}^+ \in R^l$ 과  $\bar{\tau}_o = \tau_d - \tau_o^+$ 로 정의한다.

회귀행렬  $Y_e \in R^{n \times l}$ 은 시스템 파라미터 벡터  $\theta$ 와 예측 파라미터  $\hat{\theta}^+$ 의 재배치를 가지고 있는  $Y_e \hat{\theta}^+ = \tau_{ce}^* - \tau_{ce}$ 으로 얻어진다. 여기서  $\tau_{ce}^*$ 은 계산오차입력이다.

현재, 최적 학습제어기를 설계하는데 제기된 문제는 오차 시스템 (4)가 미리 지정된 속도로 수렴하도록 만드는 일련의 학습규칙을 찾는 문제가 된다.

다음절에서 이 문제는 원하는 수렴 속도를 반영한 성능 지수를 사용함으로써 쉽게 해결할 수 있음을 보일 것이다.

### III. 비적응 및 적응최적학습

우선 로봇 시스템의 파라미터를 알고 있는 경우,  $\hat{\theta} = \theta$ 를 고려한다.

지수적으로 가중된 함수들의 범함수를 다음과 같은 성능 지수  $V(t)$ 로 정의한다.

$$V(t) = \frac{1}{2} \beta \int_{t-\delta}^t W d\eta + \frac{1}{2} w^T(t-\delta) D w(t-\delta) \quad (5)$$

여기서  $w(t) = e^{\lambda t} z(t)$  ( $\lambda \geq 0$ ),  $\beta > 0$ , 이고, 양의 이득  $L = L^T > 0$ 을 가진  $W(t) = \bar{\tau}_{ow}^T L^{-1} \bar{\tau}_{ow} + \bar{d}_{0w}^2$ 이다. 아울러 지수적으로 가중된 오차를 각각  $\bar{\tau}_{ow} = \tau_d - e^{\lambda t} \tau_o$ 와  $\bar{d}_{0w} = d_0 - e^{\lambda t} \hat{d}_0$ 으로 정의한다.

(4)의 양변에  $e^{\lambda t}$ 을 곱하여 지수적으로 가중된 오차 시스템을 만든다.

$$\begin{aligned} D(q) \dot{w} + B(q, \dot{q})w + \Gamma_0 w \\ = e^{\lambda t} (d_2 - \hat{d}_0 \cdot \text{sgn}(z) + \bar{\tau}_{ow} + \gamma(e, \dot{e})), \end{aligned} \quad (6)$$

여기서  $\Gamma_0 = \Gamma - \lambda D$ 이다. 그러면 최적 학습제어기를 설계하기 위한 문제는 간단히 다음과 같이 쓸 수 있다. 즉, 주어진 제어 시스템 (2)와 (3)에 대해 구속 방정식 (6)에 지배를 받는 성능지수  $V(t)$ 를 최소화시키는 학습 입력  $\tau_o$ 와 외란 경계 추정량  $\hat{d}_0$ 에 대한 일련의 학습 규칙을 찾는 것이 된다.

이제 이차 성능 지수  $V(t)$ 를 Lyapunov식 안정도에 따라 최소화시킴으로써 앞의 문제가 하나의 해를 가짐을 보이고자 한다. 실제로 오차 시스템 (6)에 따라 성능 지수  $V(t)$ 를 미분하여 다음을 얻는다.

$$\begin{aligned} \dot{V}(t) &= w^T \left( D \dot{w} + \frac{1}{2} D w \right) + \Delta W(t) \\ &= -w^T(t-\delta) \Gamma_0 w(t-\delta) \\ &+ w^T(t-\delta) e^{\lambda(t-\delta)} (\bar{\tau}_{ow} + \gamma) \\ &+ w^T(t-\delta) e^{\lambda(t-\delta)} (d_2 - \hat{d}_0 \cdot \text{sgn}(z(t-\delta))) \\ &+ \Delta W(t) \end{aligned}$$

여기서  $\Delta W(t) = \frac{1}{2} \beta (W(t) - W(t-\delta))$ 이다.

$\tilde{\tau}_{ow^*} = \tau_d - e^{\lambda t} \tau_o^+$ 와  $\tilde{d}_{0w^*} = d_0 - e^{\lambda t} \tilde{d}_0$  일 때,  $W^+(t) = \tilde{\tau}_{ow^*} \cdot L^{-1} \tilde{\tau}_{ow^*} + \tilde{d}_{0w^*}$ 라 두면,  $W^+(t) \leq W(t)$ 이므로  $\Delta W(t)$ 는 다음과 같다.

$$\begin{aligned} \Delta W(t) &\leq \frac{1}{2\beta} (W(t) - W^+(t-\delta)) \\ &= \frac{1}{2\beta} (e^{2\lambda t} |\tau_o(t)|_{L^{-1}}^2 - e^{2\lambda(t-\delta)} |\tau_o^+(t-\delta)|_{L^{-1}}^2) \\ &\quad - \frac{1}{\beta} \tau_d^T L^{-1} (e^{\lambda t} \tau_o(t) - e^{\lambda(t-\delta)} \tau_o^+(t-\delta)) \\ &\quad + \frac{1}{2\beta} (e^{2\lambda t} |\tilde{d}_0(t)|^2 - e^{2\lambda(t-\delta)} |\tilde{d}_0(t-\delta)|^2) \\ &\quad - \frac{1}{\beta} d_0^T (e^{\lambda t} \tilde{d}_0(t) - e^{\lambda(t-\delta)} \tilde{d}_0(t-\delta)) \end{aligned}$$

여기서  $|\cdot|_M^2 = (\cdot)^T M (\cdot)$ . 그러면

$$\begin{aligned} V(t) &\leq -|w(t-\delta)|_{\Gamma_0}^2 + \frac{\beta}{2} |w(t-\delta)|_{L_0}^2 \\ &\quad + (1 - e^{-\lambda(t-\delta)}) e^{\lambda(t-\delta)} \\ &\quad \quad (w^T(t-\delta) \tau_d + \|w(t-\delta)\| d_0) \\ &\quad - e^{\lambda(t-\delta)} w^T(t-\delta) \gamma + E(t) \end{aligned}$$

로 정리할 수 있고, 여기서

$$\begin{aligned} L_0 &= I + L \\ E(t) &= \frac{1}{2\beta} (|e^{\lambda t} \tau_o(t)|_{L^{-1}}^2 - |e^{\lambda(t-\delta)} \tau_o^+(t-\delta) + \beta L w(t-\delta)|_{L^{-1}}^2) \\ &\quad + \frac{1}{2\beta} (|e^{\lambda t} \tilde{d}_0(t)|^2 - |e^{\lambda(t-\delta)} \tilde{d}_0(t-\delta) + \beta \|w(t-\delta)\| |^2) \\ &\quad - \frac{1}{\beta} \tau_d^T L^{-1} (e^{\lambda t} \tau_o(t) - e^{\lambda(t-\delta)} \tau_o^+(t-\delta) - \beta L w(t-\delta)) \\ &\quad - \frac{1}{\beta} d_0^T (e^{\lambda t} \tilde{d}_0(t) - e^{\lambda(t-\delta)} \tilde{d}_0(t-\delta) - \beta \|w(t-\delta)\|) \end{aligned}$$

이다. 학습 규칙을 다음과 같이 가정하면

$$\begin{aligned} e^{\lambda t} \tau_o(t) &= e^{\lambda(t-\delta)} \tau_o^+(t-\delta) + \beta L w(t-\delta) \\ e^{\lambda t} \tilde{d}_0(t) &= e^{\lambda(t-\delta)} \tilde{d}_0(t-\delta) + \beta \|w(t-\delta)\| \end{aligned}$$

$E(t) = 0$ 이 된다. 더욱이  $\Gamma = \beta L_0$ ,  $\gamma$ 를 포화형(saturation-type) 제어입력으로 두면

$$\gamma = (1 - e^{-\lambda(t-\delta)}) \sigma_0 \text{sgn}(z)$$

가 된다. 여기서  $\sigma_0$ 는  $\|\tau_d\| + d_0 \leq \sigma_0$ 를 만족한다. 따라서,

$$\begin{aligned} V(t) &\leq -\frac{\beta}{2} w^T(t-\delta) \overline{L} w(t-\delta) \\ &\leq 0 \end{aligned} \tag{7}$$

여기서 행렬  $L = L^T > 0$ 을  $\overline{L} = I + L - \frac{2\lambda}{\beta} D > 0$ 이 되도록 선정한다.

위의 구조에서 선정한 학습 규칙과 피드백 입력은 성능지수  $V(t)$ 를 Lyapunov식 안정도에 따라 시간이 진행됨에 따라 점근적으로 최소화 시킨다.

이제  $\alpha = e^{-\lambda \delta}$ 와  $\overline{\beta} = \alpha \beta$ 로 두면, 학습 규칙은 다음과 같이 된다.

$$\tau_o(t) = \alpha \tau_o^+(t-\delta) + \overline{\beta} L z(t-\delta) \tag{8}$$

$$\tilde{d}_0(t) = \alpha \tilde{d}_0(t-\delta) + \overline{\beta} z(t-\delta) \tag{9}$$

여기서  $\alpha$  ( $0 < \alpha \leq 1$ )는 망각 인자(forgetting factor)이다.  $t \in [0, \delta]$ 에서 초기 조건을  $\tau_o(t) = \tau_d(t) - d_1$ 과  $\tilde{d}_0(t) = \overline{d}$ 로 설정한다. 여기서  $\overline{d}$ 는 공칭 외란 유계이다. 그러면 학습 규칙 (8)과 (9)로써 학습 제어기의 수렴성을 다음과 같이 정리한다.

정리 1(Non-Adaptive Optimal Learning) : 시스템 (1), 제어 입력 (2)와 (3), 학습규칙 (8)과 (9)로 구성된 학습 시스템에서  $\beta$ 와  $L$ 이 주어진  $\lambda \geq 0$ 에 대해  $\overline{L} = (I + L - 2\lambda D / \beta) > 0$ 을 만족한다고 가정하면, 학습 시스템은 다음과 같이 수렴한다. 모든  $t \in [0, \delta]$ 에 대하여

- i)  $\lambda = 0$ 이면,  $\lim_{k \rightarrow \infty} z(t+k\delta) \rightarrow 0$ 으로 전역적 점근 수렴을 하고, ii)  $\lambda > 0$ 이면,  $\lim_{k \rightarrow \infty} z(t+k\delta) \rightarrow 0$ 으로 포락선  $e^{-\lambda t}$ 로서 전역적 지수 수렴을 한다.

정리1로부터 다음 사항을 유추할 수 있다.

- 1) 정리 1은  $\lambda$ 의 정의를 통하여 수렴정도가 조절될 수 있음을 의미한다.
- 2) 만약  $\lambda = 0$ 일 경우 비영점  $\lambda$ 의 영향으로 추가입력  $\gamma$ 의 크기는 0으로 감소한다.
- 3)  $(1 - e^{-\lambda t}) \leq 1$ 에 따라 비선형 입력  $\gamma$ 의 값은  $\lambda$ 의 크기와 상관없이 독립적으로 정의 될 수 있다. 지수적 수렴도  $\lambda$ 는 피드백 이득  $L$ 과 학습 이득  $\beta$ 가 부등식  $\overline{L} > 0$ 을 만족하는 동안 임의로 크게 설정될 수 있다, 이때  $\beta L$ 는  $\lambda D$ 이다.

- 4) 실제 망각인자  $a$ 는  $0.95 \leq a \leq 0$ 내에서 일관성 있게 작은 값으로 선택하고 또한  $\lambda = -\frac{1}{\delta} \ln a$ 에 따라서 지수수렴함수  $\lambda$ 가 유계되는 결과를 가져온다. 이때  $\delta$ 는 로봇 운동 궤적의 주기이다.

- 5) 합성 오차  $z = e + ae$ 에서  $a$ 의 해석은 두 개다: 하나는 PD오차의 비례 이득이고 다른 하나는 1차 필터의 역시간상수이다.

$$e(t) = e^{-at} e(0) + \int_0^t e^{-a(t-\eta)} z(\eta) d\eta$$

두 번째 해석은  $z$ 가 0으로 수렴하기 때문에 위치오차  $e$  또한 0으로 수렴한다. 큰 값의  $a$ 는 빠른 수렴을 의미하지만 큰 제어 출력과 센서 노이즈에 민감하다는 것을 의미한다.

파라미터를 모를 경우, 다음의 학습 규칙을 파라미터 추정정에 사용한다.

$$\hat{\mathcal{V}}(t) = \alpha \hat{\mathcal{V}}(t-\delta) + \overline{\beta} S^{-1} Y_o^T(t-\delta) z(t-\delta) \tag{10}$$

여기서  $S$ 는 대칭(symmetric)이며 정치(positive definite) 행렬이고,  $\alpha$ 와  $\overline{\beta}$ 는 (8)과 (9)에서 정의하였다. 이제 강인제어 입력  $\gamma(t)$ 를

$$\gamma(t) = (1 - e^{-\lambda(t-\delta)})(\sigma_0 + \sigma(e, \dot{e}))\text{sgn}(z)$$

로 대체하자. 여기서  $\sigma_0$ 는 정리 1에 정의하였고,  $\sigma(e, \dot{e})$ 는  $\|Y_e\theta\| \leq \sigma(e, \dot{e})$  ([14] 참조)처럼  $Y_e\theta$ 의 경계 함수이다. 따라서 학습 규칙 (8), (9), (10)과 제어 입력 (2)로서 다음의 결과를 얻는다.

정리 2 (Adaptive Optimal Learning) : 피드백 이득  $L$ 을 다음처럼 선택한다고 가정하면,

$$\bar{L} = I + L - Y_e S^{-1} Y_e^T - \frac{2\lambda}{\beta} D > 0$$

학습 규칙 (8),(9),(10)과 제어 입력 (2)로 구성된 학습 시스템은 다음과 같이 수렴한다. 모든  $t \in [0, \delta]$ 에 대해

i)  $\lambda = 0$ 이면,  $\lim_{k \rightarrow \infty} z(t+k\delta) \rightarrow 0$ 으로 전역적 점근 수렴을 하고, ii)  $\lambda > 0$ 이면,  $\lim_{k \rightarrow \infty} z(t+k\delta) \rightarrow 0$ 으로 속도  $e^{-\lambda t}$ 로서 전역적 지수수렴을 한다.

증명 : 정리 1과 정리 2

정리1에서  $V_0(t)$ 를

$(n-1)\delta \leq t \leq n\delta, (n=1, 2, 3, \dots)$ 에 대해

$$V_0(t) = \frac{1}{2\beta} \int_0^t W(\eta) d\eta + \frac{1}{2} \sum_{k=1}^n w^T(t-k\delta) D w(t-k\delta)$$

로 정의하면,  $V_0(t)$ 은 다음과 같이 유계된다.

$$V_0(t) \leq V_n(t) = \frac{1}{2\beta} \sum_{k=1}^n \left( \int_{t-k\delta}^{(t-k\delta)+\delta} W(\eta) d\eta + w^T(t-k\delta) D w(t-k\delta) \right)$$

시간 차이들의 모든  $n$ 에 한 적분을 하기위해 위의 (8)번 식의 구조에서 동일한 절차를 따르면

$$V_n(t) \leq -\frac{\beta}{2} \sum_{k=1}^n w^T(t-k\delta) \bar{L} w(t-k\delta) \leq 0$$

를 얻고, 여기서  $\bar{L}$ 은 (7)에서와 같이 정의한다. 부등식은  $V_0(t)$ 가 유계이고  $w(t) \in L_2 \cap L_\infty$ 이라는 것을 의미한다.

$\lambda = 0$ 일 때 학습 신호  $\tau_0^i$ 와  $\mathcal{D}_0$ 가 유계되었기 때문에 (4)에서  $\dot{z} \in L_\infty$ 이 되고, 이것은 의 균일 유계성과 Barbalat의 lemma [16]로부터 전역적으로 점근적인  $\lim_{t \rightarrow \infty} z(t) = 0$ 을 뜻한다. 더욱이,  $\lambda > 0$ 이면,  $w(t) \in L_\infty$ 이므로 ii)가 구해진다. 이로써 정리 1의 증명을 완결하고, 정리 2는  $W(t)$ 를 아래와 같이 대치하면 유사하게 증명할 수 있다.

$$W(t) = \tau_{ow}^T L^{-1} \tau_{ow} + \mathcal{D}_w^T S \mathcal{D}_w + \mathcal{D}_{0w}^T$$

여기서  $\mathcal{D}_w = \theta - e^{\lambda t} \theta$ . ■

행렬  $Y_e S^{-1} Y_e^T$ 로 표현되는 정리 2의 피드백 이득  $L$ 은 파라미터 불확실성으로 인하여 정리 1보다 더 크게 되리라 예상되나, 학습 규칙 (8), (9), (10)에서  $z(t-\delta)$ 대신에  $z(t)$ 를 사용하면, 정리 1과 같은 동일한 피드백 이득  $L$ 을 사용할 수 있다. ([12]의 예 참조)

#### IV. 실험결과

제한한 학습 제어 기법의 시연을 위해 SCARA형 로봇 머니플레이터를 사용하여 몇 가지 실험을 한다. 사용된 로봇 머니플레이터는 4자유도를 가지고 있으나 앞 쪽 두개의 링크(link)에 대해서만 실험에 이용한다. 이것은 세 번째와 네 번째 링크(link)는 각각 말단장치(end\_effector)의 이동과 방향만을 담당하므로 전체 동역학 식에서 분리할 수 있기 때문이다. 따라서 실험에서는 앞의 두 관절에 대한 동적 모델을 사용한다.

머니플레이터의 동적 운동은 다음과 같은 요소들로 구성된 미분 방정식으로 표현된다 [20]:

$$D = \begin{bmatrix} d_{11} & d_{12} \\ d_{21} & d_{22} \end{bmatrix}, B = \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix}, g = \begin{bmatrix} g_1 \\ g_2 \end{bmatrix}$$

$$d_{11} = m_1 l_{c_1}^2 + m_2 l_1^2 + m_2 l_{c_2}^2 + 2m_2 l_1 l_{c_2} C_2 + I_1 + I_2$$

$$d_{12} = d_{21} = m_2 l_1 l_{c_2} C_2 + I_2$$

$$d_{22} = m_2 l_{c_2}^2 + I_2$$

$$b_{11} = -m_2 l_1 l_{c_2} S_2 \dot{q}_2$$

$$b_{12} = -m_2 l_1 l_{c_2} S_2 (\dot{q}_1 + \dot{q}_2)$$

$$b_{21} = m_2 l_1 l_{c_2} S_2 \dot{q}_1$$

$$b_{22} = 0$$

$$g_1 = k_1 \dot{q}_1 + p_1 \text{sgn}(\dot{q}_1)$$

$$g_2 = k_2 \dot{q}_2 + p_2 \text{sgn}(\dot{q}_2)$$

여기서  $C_i = \cos(q_i), S_i = \sin(q_i)$ 이다.  $k_i$ 와  $p_i$ 는 각각 viscous와 Coulomb 마찰 계수를 나타낸다. 파라미터  $\theta_1, \dots, \theta_{10}$ 는 다음과 같이 정의한다.

$$\theta_1 = m_1 l_{c_1}^2, \theta_2 = m_2 l_1^2, \theta_3 = m_2 l_{c_2}^2,$$

$$\theta_4 = m_2 l_1 l_{c_2}, \theta_5 = I_1, \theta_6 = I_2,$$

$$\theta_7 = k_1, \theta_8 = k_2, \theta_9 = p_1,$$

$$\theta_{10} = p_2,$$

파라미터 재편성이 된 오차 방정식의 회귀 행렬  $Y_e$ 의 세부 요소는 [6]를 사용한다.

실험 장치는 워크스테이션(workstation) 기반의 제어기로써 전체 시스템을 제어한다. 제어기는 SUN SPARC Classic, VME bus system, 전력 구동단으로 이루어져 있다. 제어 프로그램은 실시간 제어를 보장하는 RTOS(Real Time OS)가 탑재된 UNIX 운영체제하에서 실행된다. 실험장치와 제안된 학습제어기는 그림2와 그림3에 보이고 있다.

원하는 관절 궤적을 다음과 같은 정현제적으로 정하고, 시행시간은  $t \in [0, 1]$ 이다.

$$q_{d_1}(t) = \frac{\pi}{6} \sin(2\pi t) \quad q_{d_2}(t) = -\frac{\pi}{6} \sin(2\pi t)$$

피드백 이득은  $a = 3.0$ 과  $L = \text{diag}[40 \ 20]$ 으로 설정하고, 샘플링 기간은 2.5ms로 정하였다. 실제적인 물리적 한계를 고려하여 구동기 입력 토크를 관절 1은 400Nm, 관절 2는 200Nm를 최대값으로 제한하였다.

그림 4은 학습 입력 없이 PD 제어기만의 추적 성능을 도시하였고, 그림 5는  $\beta = 0.6$ , 파라미터  $\lambda = 0.0$ , 즉,  $\alpha = 1$

로 설정하여 초기 1회의 학습제어기의 반응을 보이고 있고 그림 6은 25회 학습후의 점근 수렴을 보이고 있는 학습 시스템의 결과를 도시하였다. 마지막으로 그림 7은 세 가지  $\lambda$ 에 대한 학습 시스템의 지수적 수렴성을 제시하고 있다. 여기서 여러 가지  $\lambda$ 를 설정함으로써 제어 시스템의 수렴 속도를 조절할 수 있음을 확인할 수 있다.

IV. 결론




그림 1. 실험에 사용된 스카라형 머니플레이터. Fig. 1. SCARA-type robot manipulator used in the experiment.

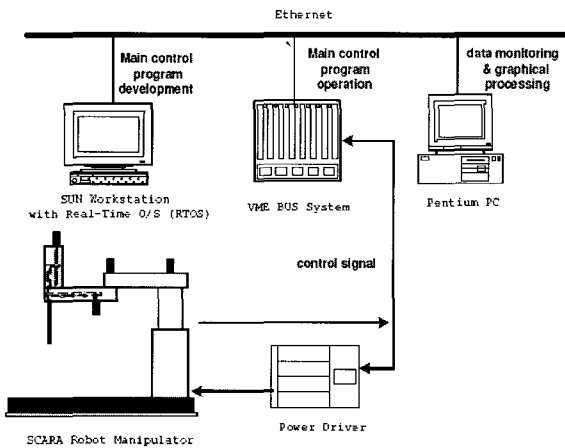


그림 2. 실험 장치구성. Fig. 2. The experimental setup.

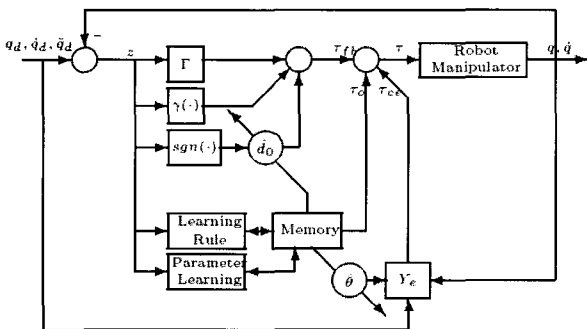


그림 3. 제안된 학습제어기의 구성. Fig. 3. Schematic diagram of the proposed learning controller.

이 논문에서는 계산 토크 기반의 제어 시스템 연구의 일환으로 반복적인 로봇 운동의 고속 추적을 위한 최적 학습 제어기를 제시하였다. 제안한 제어기에서 학습 알고리즘은 로봇 시스템의 불확실한 파라미터, 미지의 외란 경계를 추




그림 4. PD 제어기의 응답. Fig. 4. Response of PD controller.




그림 5. 제안된 학습 제어기의 첫 번째 시도에서 응답. Fig. 5. Response of the proposed learning controller at the 1st trial.




그림 6. 제안된 학습 제어기의 25번째 시도에서 응답. Fig. 6. Response of the proposed learning controller at the 25th trial.





그림 7. 세가지 다른 값을 가지는 제안된 학습 제어기의 지수적 수렴.

Fig. 7. Exponential convergence of the proposed learning controller with three different  $\lambda$ .

정하는 파라미터 학습 규칙과 원하는 제어 입력에 대한 입력 학습 규칙을 포함하고 있다. 이러한 규칙을 이용하여 설계 및 제작된 학습 제어 시스템은 내부의 모든 오차 신호들이 유계되고, 로봇 운동이 미리 정한 수렴 속도로써 원하는 운동으로 수렴함을 실험을 통하여 입증하였다. 또한 실험 결과는 제안된 제어기의 수렴정도와 효과를 보여주고 있다.

#### 참고문헌

- [1] S. Arimoto, S. Kawamura, and F. Miyazaki, "Bettering operation of robots by learning," *Journal of Robotic Systems*, vol. 1, no. 2, pp. 123-140, 1984.
- [2] Z. Bien and J. X. Xu, *Iterative learning control-Analysis, Design, Intergration and Applications*, Boston: Kluwer Academic Pub., 1998.
- [3] P. Bondi, G. Casalino and L. Gambardella, "On the iterative learning control theory for robotic Manipulators," *IEEE J. Robot. Automat.*, vol. 4, no. 1, pp. 14-22, 1988.
- [4] J. J. Craig, P. Hsu and S. S. Sastry, "Adaptive control of mechanical manipulators," *IEEE Conf. on Robotics and Automation*, CA, USA, pp. 190-195, 1986.
- [5] R. Horowitz, W. Messener and J. Moore, "Exponential convergence of a learning controller for robot manipulators," *IEEE Trans. Automat. Contr.*, vol. 36, no. 7, pp. 890-894, 1991.
- [6] T.Kuc and J.Lee "An Adaptive Learning Control of Robot Manipulators," *IEEE Conf. Dec. Contr.*, U.K, pp. 1206-1211, 1991.
- [7] T. Kuc, J. Lee and B. Park "Tuning convergence rate of a robust learning controller for robot manipulators," *IEEE Conf. Dec. Contr.*, New Orleans, USA, pp. 1714-1719, 1995.
- [8] M. Liu, "Computed torque scheme based adaptive tracking for robot manipulators," *IEEE Int. Conf. on Robotics and Automation*, pp. 587-590, 1995.
- [9] W. Messner, R. Horowitz, W. Kao and M. Boals "A new adaptive learning rule," *IEEE Conf. on Robotics and Automation*, pp. 1522-1527, 1990.
- [10] R. H. Middleton and G. C. Goodwin "Adaptive computed torque control for rigid-link manipulations," *System and Control Letters*, vol. 10, pp. 9-16, 1988.
- [11] K. L. Moore, M. Dahleh and S. P. Bhattacharyya "Iterative learning control: a survey and new results," *Journal of Robotic Systems*, vol. 9, no. 5, pp. 563-594, 1992.
- [12] B. Park, T. Kuc and J. Lee "Adaptive learning control of uncertain robot manipulators," *Int. J. Contr.*, vol. 65, no. 5, pp. 725-744, 1996.
- [13] J. S. Reed and P. A. Ioannou "Instability analysis and robust adaptive control of robot manipulators," *IEEE Trans. on Robotics and Automation*, vol. 5, pp. 381-385, 1989.
- [14] N. Sadegh and R. Horowitz "Stability and robustness analysis of a class of adaptive controllers for robotic manipulators," *Int. J. Robot. Res.*, vol. 9, no. 3, pp. 74-92, 1990.
- [15] N. Sadegh, R. Horowitz, W. Kao and M. Tomizuka "A unified approach to the design of adaptive and repetitive controllers for robotic manipulators," *ASME J. of Dynamic Systems, Measurement and Control*, vol. 112, pp. 618-629, 1990.
- [16] S. Sastry and M. Bodson, *Adaptive Control: Stability, Convergence and Robustness*, Prentice-Hall, New Jersey: Prentice-Hall Inc., 1989.
- [17] J. J. E. Slotine and W. Lee "Composite adaptive control of robot manipulators," *Automatica*, vol. 25, no. 4, pp. 509-519, 1989.
- [18] Y. D. Song, R. H. Middleton and J. N. Anderson "Study on the exponential path tracking control of robot manipulators via direct adaptive methods," *IEEE Int. Conf. on Robotics and Automation*, Sacramento, USA, Apr. 1991.
- [19] M. W. Spong and R. Ortega "On adaptive inverse dynamics control of rigid robots," *IEEE Trans. on Automat. Contr.*, vol. 35, no. 1, pp. 92-95, 1990.
- [20] M. W. Spong and M. Vidyasagar, *Robot Dynamics and Control*, New York: Wiley, 1989.



### 이 동 훈

1996년 성균관대학교 전자공학과(공학사). 1998년 성균관대학교 전기·전자 및 컴퓨터공학과(공학석사). 1998년~현재 성균관대학교 정보통신공학부 전기·전자 공학과 박사과정. 관심분야는 지능제어, 로봇공학, 시스템아키텍처,

비전프로세싱, 멀티에이전트시스템.



### 국 태 용

1988년 서울대학교 제어계측공학과(공학사). 1990년 포항공과대학 전자전기공학과(공학석사). 1993년 포항공과대학 전자전기공학과(공학박사). 1993년 삼성항공 정밀기기연구소. 1993년 목포대학교 전기공학과 전임강사. 1995년~

현재 성균관대학교 정보통신공학부 교수. 관심분야는 지능 로봇 시스템, 다이나믹 시뮬레이터, 지능 캐릭터 애니메이션 시스템, 가상현실 시스템, 혼합 센서 모듈.



### 정 재 욱

1989년 성균관대학교 전자공학과(공학사). 1991년 성균관대학교 대학원 전자공학과(공학석사). 1998년 성균관대학교 대학원 전자공학과(공학박사). 1991~1993년 삼성종합기술원 연구원. 1998년~현재 안산공과대학 컴퓨터정보계열

조교수. 관심분야는 지능제어, 로봇공학, 임베디드 시스템 설계.