

# 불확실한 로보트 시스템의 제어와 파라미터 추정을 위한 반복학습제어기법

국 택 용 ○ 이 진 수 \*  
포항공과대학 전자전기 공학과 ○ 포항공과대학 전자전기공학과 \*

## Control and Parameter Estimation of Uncertain Robotic Systems by An Iterative Learning Method

Tae-yong Kuc and Jinsoo Lee  
Department of Electrical Engineering, POSTECH, Korea

### Abstract

An iterative learning control scheme for exact-tracking control and parameter estimation of uncertain robotic systems is presented. In the learning control structure, tracking and feedforward input converge globally and asymptotically as iteration increases. Since convergence of parameter errors depends only on the persistent exciting condition of system trajectories along the iteration independently of length of trajectories, it may be achieved with only system trajectories of small duration. In addition, these learning control schemes are expected to be effectively applicable to time-varying parametric systems as well as time-invariant systems, for the parameter estimation is performed at each fixed time along the iteration. Finally, no usage of acceleration signal and no inversion of estimated inertia matrix in the parameter estimator makes these learning control schemes more feasible.

### 1. 연구 배경

로보트 매니퓰레이터(robot manipulator)를 위한 제어시스템으로서 모델참조제어(MRAC)등 적용시스템에 관한 연구가 최근 활발하게 진행되고 있다. 적용제어는 로보트 매니퓰레이터의 가변적 동작특성 등에 적절히 대처할 수 있다는 점에 그 유용성이 있다고 할 수 있는데, 특히 부하의 변동 또는 다양한 작업도구 등에 적용성을 줄 수 있어 고전적 제어방식에 비해서 작업성능의 향상이 예상된다. 또한 불완전한 모델링으로 인한 시스템 parameter의 불확실성—로보트 팔의 길이, 무게, 관성, 마찰계수 등—에 대한 적용능력을 부여하는 데 도움이 될 것이다.

그럼에도 불구하고 여러가지 접근방식에 의하여 유도된 로보트를 위한 적용제어 시스템의 대부분은 그 유도과정에서 많은 가정과 근사법을 사용함으로써 제한된 성능범위를 가질 수 밖에 없다. 이러한 가정들—관절운동의 독립성에 대한 가정 [4], 로보트 운동식의 선형화 [12], 로보트의 저속운동에 대한 가정 [12,10] 등—은 로보트의 운동속도가 빨라지거나 직접구동기(direct drive actuator)를 사용하게 될 때 성립되지 않는다. 따라서 고속 운동으로 인하여 생기는 비선형성을 제어시스템이 보상해 줄 필요가 있다. 그러한 비선형성을 고려한 모델참조 제어기로서 hyperstability technique을 사용한 방식이 있는데 ([5,2]), 이 역시 중력의 영향을 무시하고 로보트의 parameter의 범위에 대한 가정을 하는 등 단점을 지니고 있다.

더욱 최근 개발된 로보트 적용제어기법으로 computed torque 방식에 기초한 Craig, Hsu 와 Sastry([3]), Middleton 과 Goodwin([8]), 그리고 Slotine 과 Li 의 방법([11]) 등이 있다. 이들 제어기법에서는 로보트의 운동식을 불확실한 parameter에 대하여 선형성을 부여하기 위하여 reparametrization 기법을 사용하며, 주어진 상태궤적이 유한할 때 추적오차는 광역적인 수렴성을 갖는다.

그러나 이러한 광역적 수렴성에도 불구하고 이를 제어기 역시

몇 가지 단점을 지니고 있는데, 이는 가속도 측정의 필요성과 측정된 관성행렬의 가역성(invertibility)에 대한 가정 등이다 ([3]). 그리고 Slotine 과 Li의 방식은 마찰등 disturbance가 있는 이상적인 모델을 사용하고 있으므로 현실적인 모델로서 disturbance 등이 있는 경우에는 광역적 안정성이 성립되지 않음을 알 수 있다. 또한 parameter의 수령은 시스템의 궤적이 PE(persistent exciting) 조건을 만족할 때 가능하다는 것이 잘 알려져 있지만 ([3]), 대부분의 실제 시스템의 궤적은 유한한 길이와 크기 때문에 PE 조건을 만족시키기가 용이하지 않다. 더욱 중요한 것은 이들 적용제어기의 parameter 측정이 시스템 parameter의 시불변성(time invariance) 가정아래 이루어지고 있기 때문에 시스템 parameter가 시변적 성질(slow variation) 또는 step change 등)을 지닐 경우에는 이를 적용 제어기법들이 parameter는 물론 상태궤적 오차의 광역적 수렴성도 보장할 수 없게 된다는 것이다.

기존의 적용제어 기법들이 갖는 이러한 단점들을 보완하기 위한 하나의 시도로서 우리는 반복 학습제어기를 도입하려고 하는데 이 학습제어기는 주어진 시스템 궤적을 모든 동작구간에서 정확히 추적하는 것과 미정의 시스템 parameter의 추정을 목표로 하며 그 수령 특성은 광역적(global)인 것이 될 것이다. parameter의 추정은 각 sampling 간격마다 이루어지며 시스템의 가속도뿐만 아니라 측정된 관성행렬의 가역성(invertibility)에 대한 가정도 불필요하게 된다. 더욱 중요한 것은 parameter의 측정이나 시스템의 안정성 증명에 있어서 시스템 parameter의 시불변성을 이용하지 않으므로 이러한 학습제어 기법이 시변 parameter를 갖는 로보트 시스템—on-line pick and place task 등—에도 사용 가능하다는 점이다.

더우기 반복시행에 따른 PE condition을 만족하게 되면 추정 parameter도 수렴함을 증명할 수 있는데 이러한 PE 조건은 일반적인 적용제어에서의 PE 조건 ([3]) 보다도 그 실현 가능성성이 월등한 큰 것으로 보인다.

## 2. 용어해설 및 정의

위에서 정확한 추적(exact-tracking)이란 시스템의 상태궤적 이 모든 동작구간  $[0, t_f]$ 에서 주어진 상태궤적을 따르는 것을 뜻한다. 용어의 정의를 위하여 " $\equiv$ "를 사용하며  $R_+$ 은 음이 아닌 실수의 집합을 나타낸다. 또한  $R^n$ 은 실수집합 위에서의 n차원 벡터공간으로서 Euclidean 또는  $l_2$  norm을 가진다.

$$|x| = \sqrt{\sum_{i=1}^n x_i^2}.$$

실수의 집합에서 정의된  $n \times l$  행렬  $B$ 에 대하여 induced norm  $\|B\|$ 는 다음과 같이 정의된다.

$$\|B\| = \sqrt{\lambda_{\max}(B^T B)},$$

여기서  $\lambda_{\max}(\cdot)$ 는 고유치(eigenvalue) 중 가장 큰 값을 나타낸다.

$C^2[0, t_f]$ 는 구간  $[0, t_f]$ 에서 최소 2회 이상 미분가능한 함수의 집합을 뜻한다.

Lyapunov stability 이론을 전개하면서 안정영역의 오차집합  $\Omega$ 는 다음과 같이 정의 한다.

$$\Omega = \{z, \dot{\theta} | \dot{W}(z, \dot{\theta}) \leq 0\},$$

여기서  $\dot{W}$ 은 Lyapunov 함수의 시간미분을 나타내고  $z, \dot{\theta}$ 는 궤적오차, parameter 추정오차를 나타낸다.

행렬함수  $Y^j : R_+ \rightarrow R^{n \times l}$ 의 반복에 따른 PE 조건을 다음과 같이 정의한다.

정의: 행렬함수  $Y^j : R_+ \rightarrow R^{n \times l}$ 이 다음조건을 만족할 때  $Y^j$ 는 반복회수를 따라 persistently exciting하다고 말한다. 즉, 각각의  $t$  ( $[0, t_f]$ )에 대하여 양의 상수  $\alpha_1, \alpha_2$ 와 양의 정수  $N$ 이 존재하여 다음을 만족한다.

$$\alpha_1 I \leq \sum_{i=j}^{j+N} Y^{jT}(t) Y^i(t) \leq \alpha_2 I$$

## 3. 주요 결과

다음과 같은 로보트 시스템이  $J$ 번째 반복(iteration)에서 주어졌다고 가정하자.

$$S : D(q^j(t)) \ddot{q}^j(t) + F(q^j(t), \dot{q}^j(t)) + T_a = T^j,$$

여기서 일반화된 관절 좌표계  $q^j \in R^n$ 에 대하여  $D^j \in R^{n \times n}$ 은 양의 대칭행렬이고  $F^j \in R^n$ 은 구심력과 Coriolis 힘 그리고 중력, 마찰력 등을 포함하는 벡터이다. 또한  $T^j$ 는 입력 torque (또는 force) 벡터이고  $T_a$ 는 불완전한 모델링으로 인한 유한한 크기를 갖는 미지의 disturbance이다.

우리는 아래의 모든과정에서 parameter들이 부분적으로 알려져 있거나 정확한 값을 알 수 없다고 가정하겠다.

이제 각각의 관절각이 일정한 궤적  $q_d(t) \in C^2[0, t_f]$ 을 모든 구간에서 추적하도록 하는 문제를 생각해보자.

이러한 문제는 제어관점에서 볼 때 정확한 추적(exact-tracking)의 문제가 됨을 알 수 있다.

이 목표를 달성하기 위하여 우리는 다음과 같은 제어입력을 구성한다.

$$T^j = E^j + H^j. \quad (1)$$

여기서 오차입력  $E^j$ 는 다음과 같다.

$$\text{at } j = 1 \quad E^1 = \hat{D}^1 \ddot{q}_d + \hat{F}^1 + a \hat{D}^1 \dot{e}^1 + E_o^1, \quad (2)$$

$$\text{at } j \geq 2 \quad E^j = \hat{D}_e^j \ddot{q}_d + \hat{F}_e^j + a \hat{D}^j \dot{e}^j + E_o^j \quad (3)$$

또한  $a$ 는 양의 상수이고

$$D_e^j \equiv D(q^j) - D(q_d)$$

$$F_e^j \equiv F(q^j, \dot{q}^j) - F(q_d, \dot{q}_d)$$

$$E_o^j \equiv L z^j$$

$$z^j \equiv \dot{e}^j + ae^j$$

$$e^j \equiv q_d - q^j$$

아래에서 정해질  $L$ 은 부제한 이득 행렬을,  $(^*)$ 은 추정된 시스템을 나타낸다.  $H^j$ 는 경제한 입력으로 다음과 같은 학습율에 따라 학습된다.

$$H^{j+1} = H^j + \beta E_o^j, \quad (4)$$

여기서  $\beta$ 는 학습이득으로 ( $0 < \beta < 2$ )의 값이다.

위 제어 입력 1)를 시스템에 가한 후 reparametrization 과 정을 거치면 다음과 같은 오차에 관한 식을 얻는다.

$$D^1 \dot{z}^1 + L z^1 = Y^1(q^1, \dot{q}^1, \dot{q}_d, \ddot{q}_d) \hat{\theta}^1 + T_a \quad (5)$$

$$D^j \dot{z}^j + L z^j = Y^j(q^j, \dot{q}^j, q_d, \dot{q}_d, \ddot{q}_d) \hat{\theta}^j + \bar{U}^j,$$

여기서  $Y^j \in R^{n \times l}$ 은 regression 행렬,  $\hat{\theta}^j$ 는 parameter 오차 벡터이고  $\bar{U}^j$ 는 입력오차로서 다음과 같이 주어진다.

$$\hat{\theta}^j \equiv \theta - \hat{\theta}^j$$

$$\bar{U}^j \equiv T_d - H^j$$

$T_d$ 는  $\{q_d, \dot{q}_d, \ddot{q}_d\}$ 에 대응되는 입력으로 다음과 같이 주어진다.

$$T_d \equiv D(q_d) \ddot{q}_d + F(q_d, \dot{q}_d) + T_a$$

시스템 parameter는 다음과 같은 학습율에 따라 추정된다.

$$\begin{aligned} \dot{\theta}^1 &= \beta^1 Y^{1T} z^1 \\ \theta^{j+1} &= \hat{\theta}^j + \beta S^{-1} Y^{jT} z^j \end{aligned} \quad (6)$$

여기서  $S$ 는 정규화(normalization)행렬이다.

이제 부제한 이득행렬  $L$ 이 다음 조건을 만족하도록 주어졌다 고 가정하면

$$D_0^1 \equiv (2L - \hat{D}^1) > 0,$$

$$D_0^j \equiv ((2 - \beta)L - \hat{D}^j - \beta Y^{j-1} S^{-1} Y^{jT}) > 0$$

우리는 아래와 같이 우리의 제어목적이 달성됨을 알 수 있다.

정리 1: 반복학습 제어기가 제어입력 (1)과 경제한학습 입력을 위한 학습율 (4), parameter 추정을 위한 추정율 (6) 등으로 구성되었다면 주어진 시스템  $\Sigma$ 는 다음과 같은 광역적 수렴특성을 갖는다.

$$i) \quad V^{j+1}(t) \leq V^j(t)$$

$$ii) \quad \lim_{j \rightarrow \infty} e^j(t) = 0$$

$$iii) \quad \lim_{j \rightarrow \infty} \bar{U}^j(t) = 0,$$

여기서

$$V^j(t) \equiv \int_0^t (\hat{U}^{jT}(\tau) R \hat{U}^j(\tau) + \hat{\theta}^{jT} S \hat{\theta}^j) d\tau.$$

$$R \equiv L^{-1}$$

증명)  $j=1$  일 때

$\hat{q}_d$  와  $\hat{\theta}^1$  가 유한하므로  $V^1$  은 유한함을 알 수 있다. 실제로 Lyapunov 함수를 다음과 같이 정의하자.

$$W(t) \equiv \frac{1}{2}(z^{1T} D_0^1 z^1 + \frac{1}{\beta^1} \hat{\theta}^{1T} \hat{\theta}^1)$$

$W(t)$  를 오차식 (5) 와 parameter 추정식 (6) 을 따라 미분하면 다음을 얻는다

$$\dot{W}(t) \leq -\frac{1}{2} z^{1T} (D_0^1 z^1 - 2T_a).$$

이식은 시스템이 안정영역의 오차집합  $\Omega$  내에서 안정함을 알 수 있다.

$j>2$  일 때,  
다음을 정의하자.

$$\hat{U} \equiv \hat{U}^{j+1} - \hat{U}^j.$$

$$\hat{\theta} \equiv \hat{\theta}^{j+1} - \hat{\theta}^j.$$

그러면 (4))으로부터

$$\hat{U} = -\beta E_o^j.$$

$$\hat{\theta} = -\beta S^{-1} Y^{jT} z^j.$$

또한 다음과 같이 에너지의 차를 정의하면

$$\Delta V \equiv V^{j+1} - V^j,$$

오차식 (5)와 parameter 추정식 (6), ( )로부터 다음을 얻을 수 있다.

$$\begin{aligned} \Delta V &= \int_0^t (\hat{U}^T R \hat{U} + 2\hat{U}^T R \hat{U}^j + \hat{\theta}^T S \hat{\theta} + 2\hat{\theta}^T S \hat{\theta}^j) d\tau \\ &= \int_0^t (\beta^2 z^{jT} L z^j - 2\beta z^{jT} (D^j z^j + L z^j - Y^j \hat{\theta}^j)) d\tau \\ &+ \int_0^t (\beta^2 z^{jT} (Y^j S^{-1} Y^{jT}) z^j - 2\beta z^{jT} Y^j \hat{\theta}^j) d\tau \\ &= \int_0^t (\beta^2 z^{jT} L z^j - 2\beta z^{jT} (D^j z^j + L z^j)) d\tau \\ &+ \int_0^t \beta^2 z^{jT} (Y^j S^{-1} Y^{jT}) z^j d\tau. \end{aligned}$$

여기서 부분적분을 행하면

$$\Delta V = -\beta z^{jT} D^j z^j - \int_0^t (\beta z^{jT} D_0^j z^j) d\tau \leq 0.$$

따라서 1) 을 얻을 수 있고 위식에서 등호는 오직  $z^j = 0$  일 때만 성립한다. 유한하고 단조감소 수열  $\{V^j\}$  는 일정한 상수로 수렴하므로  $j \rightarrow \infty$  에따라  $\Delta V$  은 0에 수렴하는데 이는  $z^j$  가 모든 구간  $[0, t_f]$  에서 0에 수렴함을 의미한다.  $j$ 의 정의로 부터  $z^j$  는 안정된 필터의 입력으로 간주될 수 있으므로 우리는 11) 을 얻게 된다. 마지막으로, 모든 구간에서  $z^j$  가 0에 수렴한다는 것은  $\hat{\theta}^j$  역시 0에 수렴함을 의미하므로 식 (5)로부터 111) 을 얻는다. 증명 끝!

참고 1)  $j=1$  일 때 만약  $T_a$  가 없다면 시스템  $\Sigma$  은 Lyapunov 의미에서 광역적으로 안정 할 것이다.

참고 2) 안정성의 증명에 있어서 우리는 목적으로 가며 반복 횟수마다 주기적임을 가정하고 있다.

참고 3) 기존의 적용제어기 ([3]) 와 달리 위의 학습제어기에서는 시스템의 가속도 측정이나 추정된 관성행렬의 가역성에 대한 가정등이 전혀 필요하지 않음을 알 수 있다.

참고 4) 위의 결과로 정확한 궤적추적(exact-tracking)과 외란제거(disturbance rejection), 경제한 입력의 학습등이 동시에 이루어짐을 알 수 있고 결과적으로 역 동적 제어(inverse dynamics control) 가 가능하게됨을 알 수 있다.

참조 5) parameter를 추정하는 과정을 살펴보면 시스템 parameter가 모든 동작구간에서 일정한 상수가 아니드라도 첫번 째 시행에서 parameter 추정값만 유한하면 시스템 parameter가 모든 동작 구간에서 일정상수일 때와 같은 결과를 얻을 수 있음 알 수 있다. 즉, 기존의 적용제어기와 달리 시번 parameter 시스템에 대해서도 우리의 제어목적을 이를 수 있게 되는 것이다.

위 결과의 제 1) 항은 학습제어기 내의 추정 parameter의 오차가 모든 반복시행을 통하여 유한함을 의미하는데 추정된 parameter가 수렴하기 위해서는 시스템의 궤적이 반복횟수를 따라 PE 조건을 만족해야 한다.

실제로, 위 학습제어기에서 parameter의 수렴에 관한 결과를 다음과의 정리로 나타내었다.

정리 2: 헬름  $y_j$  가 반복시행에 따른 PE 조건을 만족한다고 가정하자. 그러면 위 학습제어기에서의 추정 parameter는 시스템의 실제값에 광역적(global)으로 수렴하게 된다. 즉, 초기 parameter 추정에 관계없이 모든 동작구간  $[0, t_f]$  에서

$$\lim_{j \rightarrow \infty} \hat{\theta}^j = 0$$

이다.

증명) 먼저, parameter 추정기 (6) 을 다음과 같이 쓸 수 있다.

$$\hat{\theta}^{j+1} = \hat{\theta}^j - \beta S^{-1} Y^{jT} z^j. \quad (7)$$

이 식에 연속적인 반복관계를 적용하면  $n=1, 2, \dots, N$  까지 다음과 같다.

$$\hat{\theta}^{j+n} = \hat{\theta}^{j+N+1} + \beta \sum_{i=j+n}^{j+N} S^{-1} Y^{iT} z^i. \quad (8)$$

식 (7) 의 양변에  $(j+n-1)$  번째 반복 시행의 행렬  $Y^{(j+n-1)}$  을 곱하면  $n=1, 2, \dots, N+1$  까지 다음을 얻는다.

$$Y^{(j+n-1)} \hat{\theta}^{(j+n)} = Y^{(j+n-1)} \hat{\theta}^{(j+n-1)} - \beta Y^{(j+n-1)} S^{-1} Y^{(j+n-1)T} z^{(j+n-1)}$$

이제 다음을 정의하면

$$S_N^{n-1} \equiv Y^{(j+n-1)} \hat{\theta}^{(j+n-1)} - \beta \sum_{i=j+n-1}^{j+N} Y^{(j+n-1)} S^{-1} Y^{iT} z^i.$$

학습제어기의 수렴결과로부터 모든  $n$  ( $n \leq N+1$ ) 에 대하여 다음이 성립한다.

$$\lim_{j \rightarrow \infty} S_N^{n-1} = 0 \quad (9)$$

마찬가지로 (7) 과 (8)로부터 다음을 알 수 있다.

$$S_N^{n-1} = Y^{(j+n-1)} \hat{\theta}^{(j+N+1)}. \quad (10)$$

이제  $N+1$  개의 유한곱수를 다음과 같이 정의하자.

$$S_N \equiv \sum_{n=1}^{N+1} S_N^{(n-1)T} S_N^{(n-1)}.$$

그러면 (10)으로부터 다음을 얻는다.

$$S_N = \hat{\theta}^{(j+N+1)T} \sum_{i=j}^{j+N} (Y^{iT} Y^i) \hat{\theta}^{(j+N+1)}.$$

이식에 PE 조건을 적용하여 다음 부등식을 얻는다.

$$0 \leq \alpha_1 \hat{\theta}^{(j+N+1)T} \hat{\theta}^{(j+N+1)} \leq S_N \leq \alpha_2 \hat{\theta}^{(j+N+1)T} \hat{\theta}^{(j+N+1)}.$$

이제 (9) 항을 참조하면 우리가 원하는 결과를 얻게된다. 증명 끝!

참조 6) 위의 결과는 시스템 parameter의 시불변성과 무관하므로 시불변뿐만 아니라 시변 parameter의 수립성질에도 적용 가능함을 알 수 있다.

참조 7) 위에서 가정한 "반복 시행에 따른 PE 조건"은 기존의 적용제어기에서 볼 수 있는 PE 조건 ([3])과는 달리 궤적의 길이 ( $l_f$ )가 작아도 실현될 가능성이 있음을 그 특징으로 한다.

#### 4. 컴퓨터 시뮬레이션 및 결과고찰

간단한 2 축 토보브 미니플레이터에 대한 컴퓨터 모의실험 결과를 간략히 소개한다. 여기서 제안한 학습 제어기가 기준의 적응제어기와 다른 주요 특성들이 d와 탄제거(disturbance rejection)과 시변(time-varying) 시스템 parameter에 대한 적응성이 등장하기 때문에 이를 비교하고 위하여 먼저 일정한 크기의 disturbance 존재하에서 결과를 추적 실험을 하였다.

두 번째로 시번 parameter에 대한 적응성을 보기 위하여 시스템이 목표궤적을 추적하는 도중에 부하를 들어 올려 낸다는 상황을 설정하였다. 이러한 부하의 변동은 궤적을 따라 운동하는 도중에 시스템의 parameter에 step change mode를 품으로써 일정 구간에서 시번 parameter 시스템이 되도록 만든다.

위의 두 상황에서 기존의 적응체어방식 ([3], [8], [11] 등)으로는 광역적(global)인 수렴성을 보장할 수 없으리라는 것은 명백하다.

모의 실험결과로서 그림 2-3은 그 자체로 위에 제안한 반복학습제어기의 성능과 효용성을 입증하지만 진정한 가치는 반복 작업을 하는 산업용 보모보등 실제 시스템에 적용하여 on-line 학습과 실시간 제어(real-time control)을 함으로써 나타낼 것이다.

글으로, 일반적인 학습 제어에서 생기는 문제로서 sampling 주파수가 커지거나 동작시간이 길어짐에따라 생기는 memory의 충가를 들 수 있는데, 일반적인 도표창조(table-look-up) 방식이 갖는 이러한 문제에 대한 해결책의 하나로 AME (Associative Mapping Elements) 의 사용이 있다 ([6],[7]). 이 AME는 CMAC(Cerebellum Model Articulated Controller) ([1]) 과 비슷한 특성을 갖는 단순한 형태의 신경회로(neural network)라고 할 수 있는데 CMAC과 다른 가장 큰 장점은 유한한 memory로써 모든 입력상태를 나타낼 수 있다는 것이다. 따라서 궤적의 길이나 sampling 주파수가 늘어나는 경우에도 학습에 필요한 전체 memory 양은 늘지 않게 된다.

## 5. 결론

불완전한 모델링으로 인하여 제어하기 어려운 토보트 미니플레이터를 원하는 궤적의 모든 동작구간에서 정확히 추적, 제어할 수 있는 학습제어기를 제안하고 그 동작특성—외란제거 (disturbance rejection), 시변 parameter에 대한 적응성, 제어 입력의 학습에 따른 역 동적제어 (inverse dynamics control)의 가능성 등—을 소개하였다. Computer simulation을 통하여 그 성능을 보였고 앞으로의 연구구조체로 산업현장에 쓰이는 실제 토보트의 반복 작업동에 적용하는 문제를 고려하고 있다.

참 고 문 헌

- [1] J.S. Albus, "Brains, Behavior, and Robotics," N.H. Byte Books, 1981.
  - [2] A. Balestrino, G. De Maria, and L. Sciavicco, "An Adaptive Model Following Control of Manipulators," ASME J. Dynam. Syst., Meas. Contr., Vol. 105, pp143-151, Sept. 1983.
  - [3] J.J. Craig, P. Hsu and S.S. Sastry, "Adaptive Control of Mechanical Manipulators", The IEEE Int. Conf. on Robotics and Automation.CA. 1986.
  - [4] S. Dubowsky and D.T. DesForges, "The Application of Model Reference Adaptive Control to Robot

Manipulators," Trans. ASME JDSME Vol. 101, pp193-200, 1979.

[5] R.Horowitz and M.Tomizuka, "An Adaptive Control Scheme for Mechanical Manipulators - Compensation of Nonlinearity and Decoupling Control," ASME J.DSMC, Vol.108, pp127-135, 1986.

[6] Tae-yong Kuc, "A General Iterative Learning Control Scheme for A Class of Holonomic Systems", MEE's Thesis, Dept. of EE, Eng., POSTECH.

[7] Tae-yong Kuc and Kwanghee Nam, "CMAC Based Iterative Learning Control of Robot Manipulators," The IEEE Conf. on Decision and Control, Tampa FL., 1989.

[8] R.H. Middleton and G.C. Goodwin, "Adaptive Computed Torque Control for Rigid-link Manipulators," IEEE CDC, Athens, Greece 1986.

[9] J.S. Reed and P.A. Ioannou, "Instability Analysis and Robust Adaptive Control of Robot Manipulators," IEEE Trans. on Robotics and Automation, Vol.5, No.3, June 1989.

[10] H.Seraji,"A New Approach to Adaptive Control of Manipulators," J.DSMC, Vol.109, Sep. 1987.

[11] J-J. E. Slotine and W. Lee, "Composite Adaptive Control of Robot Manipulators," *Automatica*, Vol. 25, No. 4, pp 509-519, 1989.

[12] M.Tagekaki and S.Arimoto, "An Adaptive Trajectory Control of Manipulators," Int.J.of Control, Vol.34, pp201-217, 1981.

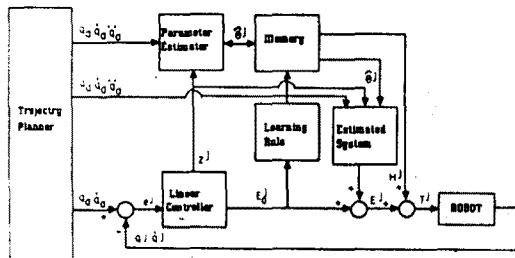


Figure 1: Schematic Diagram of the Parameter Adaptive Learning Controller

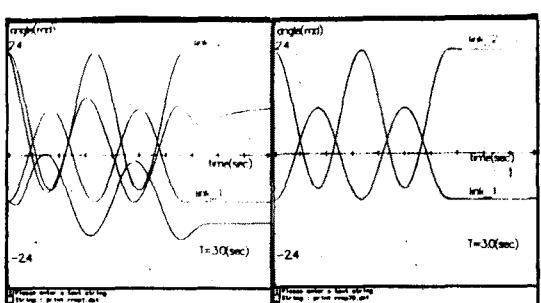
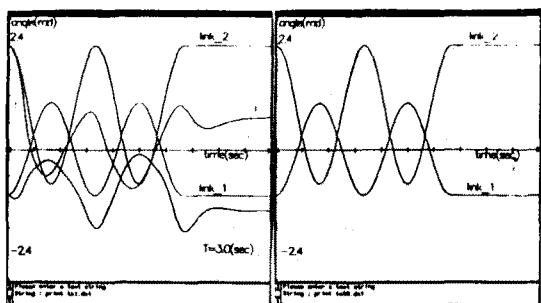


Figure 3: Trajectories of the system with bounded disturbances