

로봇의 궤적추종제어를 위한 직접학습 제어법칙의 구현

김진혁*, 안현식*, 김도현*

*국민대학교 전자공학과

Implementation of a Direct Learning Control Law for the Trajectory Tracking Control of a Robot

Jin-Hyoung Kim*, Hyun-Sik Ahn* and Do-Hyun Kim*

*Department of Electronics Engineering, Kookmin University

Abstract - In this paper, the Direct Learning Control is applied to robot's trajectory tracking control to solve the problem that lies in the existing Iterative Learning Control(ILC) and the tracking performance is analyzed and the better approach is searched using computer simulation and experiments. It is assumed that the Direct Learning Control(DLC) is saved onto memory basically after obtaining control input profiles for several periodic output trajectories using the ILC.

In case the new output trajectory has special relations with the previous output trajectories, there is an advantage that the desired control input profile can be obtained without iterative executions only using the DLC. The robot's tracking control system is comprised of DSP chip, A/D converter, D/A converter and high-speed pulse counter included in the control board and the performance is examined by carrying out the tracking control for the given output trajectory.

1. 서 론

2축 스카라 로봇과 같이 주어진 작업공간에서 특정한 임무를 반복적으로 수행하는 시스템의 경우에는 점근적 안정성만을 보장하는 현대 제어이론보다 유한시간 구간 내에서 완전 추종을 가능케 하는 반복학습 제어가 매우 효과적이다[1].

그러나 반복학습의 가장 큰 단점으로 반복적인 학습을 들 수 있다. 시스템을 대상으로 반복학습이 오차 없는 응답을 찾는 데에는 많은 시간을 소모한다. 그러므로 빠른 응답특성을 원할 경우 반복학습은 한계를 가지고 있다. 이와 같은 단점을 개선하기 위해 직접학습 제어이론이 제기되었다[2].

직접학습 제어는 새로운 궤적에 주어졌을 때 반복학습 없이 바로 직접학습에 의해 원하는 입력을 찾는 것이다. 새로운 궤적이 이미 저장된 기준궤적과 특별한 관계를 ("Proportional") 갖는 경우에 직접학습을 적용할 수 있다.

직접학습은 계산된 계수의 값을 저장된 기준입력 값에 곱해주므로 빠른 시간 내에 원하는 입력을 찾을 수 있게 한다. 반복학습의 시간 한계를 직접학습을 통해 개선할 수 있다.

본 논문에서는 2축 스카라 로봇을 대상으로 하여 로봇의 추종궤적 제어를 위해 직접학습 제어법칙을 구현한다. 직접학습을 적용한 모의 실험을 통해 원하는 입력을 찾고, 실시간 시스템에 적용하여 결과를 보이고자 한다.

2. 직접학습

2.1 문제의 정의 및 가정

다음의 비선형 동역학 방정식을 고려하자.

$$\begin{aligned} \frac{d\mathbf{x}(t)}{dt} &= \mathbf{f}(\mathbf{x}(t)) + \mathbf{B}(\mathbf{x}(t))\mathbf{u}(t) \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t) \end{aligned} \quad (1)$$

여기서 $\mathbf{u}(t) \in R^n$ 은 입력벡터, $\mathbf{y}(t) \in R^m$ 은 출력벡터, $\mathbf{x}(t) \in R^m$ 은 시스템 상태변수벡터, $\mathbf{f}(\mathbf{x}(t)) \in R^m$ 은 불확실한 벡터함수, $\mathbf{B}(\mathbf{x}(t)) \in R^{m \times n}$ 은 불확실한 행렬 및 $\mathbf{C} \in R^{m \times m}$ 은 불확실한 상수행렬을 나타낸다.

식 (1)의 비선형 시스템을 대상으로 직접학습을 적용하기 위한 조건으로 직접학습이론 적용시 궤적들은 서로 비례적인 관계("Proportional")가 있어야 하고 이 비례적인 관계를 만족하기 위한 가정과 정의가 있다.

[가정 1] $\forall t \in R_+$, $\forall \mathbf{x} \in D \subset R^m$ 일 경우, D 는 단일 제어해가 존재하는 컴팩트(Compact) 집합이며 행렬 \mathbf{C} 와 $\mathbf{B}(\mathbf{x}(t))$ 는 플랭크를 가진다.

가정 1과 연관지어 정의 1과 정의 2에서는 궤적들이 서로 어떤 비례 관계가 있는지 보인다.

[정의 1] 일반화된 좌표 $\mathbf{q} = [q_1 \cdots q_n]^T$ 의 집합으로 나타나는 n 차 공간에서, 공간경로(패턴)는 궤적 $\mathbf{y}_i(t_i) = [y_{1i}(t_i), \dots, y_{ni}(t_i)]^T$ 에 의해 묘사된다.

t 를 매개변수로 하는 임의의 궤적 $\mathbf{y}_i(t)$ 은 벡터 영역에 있다. 때문에 0에서 T_i 까지 속하는 공간 경로는 t_i 에 의해 계산 될 수 있고, 또한 식 (1)과 같이 종합적인 좌표를 가지는 궤적 $\mathbf{y}_i(t)$ 의 각 구성요소의 결합에서 계산할 수 있다.

$$q_1 = y_{1i}(t_i), \quad q_2 = y_{2i}(t_i), \quad \dots, \quad q_n = y_{ni}(t_i) \quad (2)$$

[정의 2] 두 궤적 $\mathbf{y}_i(t_i)$ 과 $\mathbf{y}_j(t_j)$ ($i \neq j$)가 다음의 두 조건을 만족한다면, 다른 시간 스케일을 갖는 두 궤적은 동일한 공간좌표에 표현된다.

(i) $\forall t_i \in [0, T_i]$ 이고, $\mathbf{y}_i(t_i) = \mathbf{y}_j(t_i)$ 인 유일한 $t_j \in [0, T_j]$ 가 존재한다.

(ii) $\mathbf{y}_i(t_i) = \mathbf{y}_j(t_i)$ ($i \neq j$)을 만족하는 $t_i \in [0, T_i]$ 와 $t_j \in [0, T_j]$ 가 존재한다.

정의 2는 본 논문에서 사용하는 궤적들의 상호 연관 관계를 보여준다.

궤적 $\mathbf{y}_i(t_i)$ 와 또 다른 궤적 $\mathbf{y}_j(t_j)$ 사이에서 시간 비례계수 $\rho(t)$ 가 $\mathbf{y}_j(t_j) = \mathbf{y}_i(\rho(t_i))$ 인 관계가 있다고 하자. 여기서 $\rho(t_i)$ 는 $\rho(0) = 0$ 과 $T_i = \rho(T_j)$ 를 만족하는 연속 미분 사상함수이다.

$\forall t_i \in [0, T], \exists t_j \in [0, T]$ 일 때 $t_i = \rho(T_j)$ 인 경우 \mathbf{q} 는 식 (3)을 만족한다.

$$\mathbf{q} = \mathbf{y}_j(t_j) = \mathbf{y}_i(\rho(t_i)) = \mathbf{y}_i(t_i) \quad (3)$$

식 (3)이 성립한다면 두 궤적 $\mathbf{y}_i(t_i)$ 와 $\mathbf{y}_j(t_j)$ 는 같은 공간좌표에 있을 수 있다.

두 궤적이 다음과 같은 시간 스케일 요소 $\rho(t_i) = \frac{t_i}{k}$ 를 갖는다면, 결과적으로 두 궤적의 연산주기는 $T_i = \frac{T_j}{k}$ 처럼 $\frac{1}{k}$ 만큼 다르다. 정의 2가 만족하기 위한 가정 2를 살펴보자.

[가정 2] $l(l \geq 2)$ 개의 저장된 궤적 $\mathbf{y}_i(t_i), t_i \in [0, T_i]$ 이 있다. 각각에 대응되는 기준 제어입력 $\mathbf{u}_i(t_i)$ 는 반복학습을 통해 미리 얻어져 있을 경우 저장된 모든 궤적들은 식 (4)와 같이 일련의 연속적인 미분사상 $\rho_i(t)$ 를 통하여 서로 연관되어 있다.

$$\begin{aligned} t_i &= (\rho_i(t)) \\ \mathbf{y}_1(t_1) &= \mathbf{y}_2(t_2) = \dots, \mathbf{y}_l(t_l) \end{aligned} \quad (4)$$

여기서 $t \in [0, T], t_i \in [0, T_i]$ 이고 저장된 궤적 \mathbf{y}_i 와 $\mathbf{y}_j (i \neq j)$ 에 대한 사상함수는 다음을 만족한다.

$$\begin{aligned} \forall t \in [0, T], \quad i, j = 1, \dots, l \\ \frac{d\rho_i(t)}{dt} \neq 0, \quad \frac{d\rho_j(t)}{dt} \neq 0 \end{aligned} \quad (5)$$

또한 시간 $t \in [0, T]$ 에 대해 임의의 상수 $\delta > 0$ 이고 $\left| \frac{d\rho_i(t)}{dt} - \frac{d\rho_j(t)}{dt} \right| > \delta$ 인 관계를 가지는 적어도 2개의 궤적이 존재한다.

2.2 원하는 제어입력의 직접학습 방법

새로운 궤적 $\mathbf{y}_d(t_d), t_d \in [0, T_d]$ 와 연관지어 식 (1)의 비선형 불확실 시스템에 대해서 저장된 $\mathbf{u}_i(t_i) (i=1, \dots, l)$ 을 가지고 제어입력 $\mathbf{u}_d(t_d)$ 를 직접적으로 계산할 수 있다[2].

$$\mathbf{u}_d(t_d) = [\mathbf{I} \quad \mathbf{I}] (\mathbf{A}_l^T \mathbf{A}_l)^{-1} \mathbf{A}_l^T \bar{\mathbf{u}}_l \quad (6)$$

$$\text{여기서 궤적행렬 } \mathbf{A}_l = \begin{bmatrix} \left(\frac{d\rho_1(t_d)}{dt_d} \right)^{-1} \mathbf{I} & \mathbf{I} \\ \vdots & \vdots \\ \left(\frac{d\rho_l(t_d)}{dt_d} \right)^{-1} \mathbf{I} & \mathbf{I} \end{bmatrix}, \text{ 원하는 }$$

제어입력 $\bar{\mathbf{u}}_l = [\mathbf{u}_1^T(\rho_1(t_d)), \dots, \mathbf{u}_l^T(\rho_l(t_d))]^T$ 이다.

3. 모의 실험 결과

기준 궤적 $\mathbf{x}_1, \mathbf{x}_2$ 가 주어졌을 때 반복학습을 통해 각각에 대응되는 $\mathbf{u}_1, \mathbf{u}_2$ 를 찾는다[3]. 다음으로 새로운 궤적이 주어졌을 때 직접학습을 통해 원하는 제어입력을 찾는다.

실험에서 이용한 로봇의 동역학 방정식은 다음과 같다.

$$\mathbf{M}(\theta) \dot{\theta} + \mathbf{v}(\theta, \dot{\theta}) + \mathbf{F}_r(\theta) = \tau \quad (7)$$

여기서 $\theta : 2 \times 1$ 관절벡터, $\mathbf{M}(\theta) : 2 \times 2$ 관성행렬, $\mathbf{v}(\theta, \dot{\theta}) : 2 \times 1$ 코리올리력 및 원심력 벡터, $\mathbf{F}_r(\theta) : 2 \times 1$ 마찰력벡터 및 $\tau : 2 \times 1$ 토오크벡터이다.

이제 직접학습 제어시스템을 구성하면 그림 1과 같다.

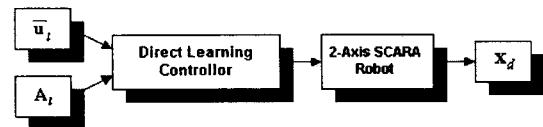


그림 1. 직접학습 제어시스템.

본 논문에서는 다음의 새로운 궤적이 주어졌을 때, 직접학습을 통해 원하는 제어입력을 찾는다.

$$\mathbf{x}_d = \begin{bmatrix} t_d^3(4-3t_d) \\ t_d^3(4-3t_d) \end{bmatrix}, t_d \in [0, 2]$$

아래에 저장된 두 기준궤적이 있고, 여기에 새로운 궤적에 대해 직접학습을 적용하기 위해 반복학습을 실행한다.

$$(i) \quad \mathbf{x}_1 = \begin{bmatrix} 8t_1^3(4-6t_1) \\ 8t_1^3(4-6t_1) \end{bmatrix}, t_1 = \rho_1(t_d) = \frac{1}{2}t_d, \\ t_1 \in [0, 0.5], \text{ 샘플링 시간} : 0.0025.$$

$$(ii) \quad \mathbf{x}_2 = \begin{bmatrix} \frac{1}{8}t_2^3(4-1.5t_2) \\ \frac{1}{8}t_2^3(4-1.5t_2) \end{bmatrix}, t_2 = \rho_2(t_d) = 2t_d, \\ t_2 \in [0, 2], \text{ 샘플링 시간} : 0.01.$$

위의 저장된 두 개의 기준궤적으로부터 DLC를 적용하여 다음과 같이 원하는 제어입력을 찾는다.

$$\mathbf{u}_d(t_d) = \left[\frac{1}{3} \mathbf{I} \quad \frac{2}{3} \mathbf{I} \right] \bar{\mathbf{u}}_l \quad (8)$$

이와같이 직접 계산된 \mathbf{u}_d 를 로봇에 입력으로 인가하

는 경우 그림 2와 같이 궤적을 추종한다.

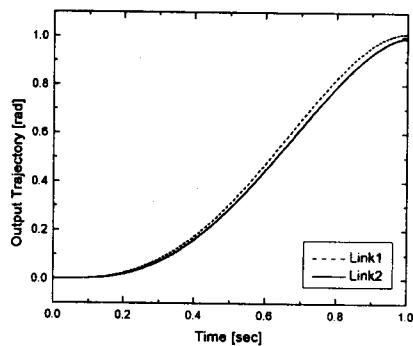


그림 2. 로봇의 추종궤적.

4. 실시간 실험

4.1 시스템 구성

제안된 제어시스템에 대한 실시간 실험에 있어서 IBM PC(Pentium III)와 dSPACE사의 DS1102 DSP 보드를 사용하여 시스템을 구축하였다.

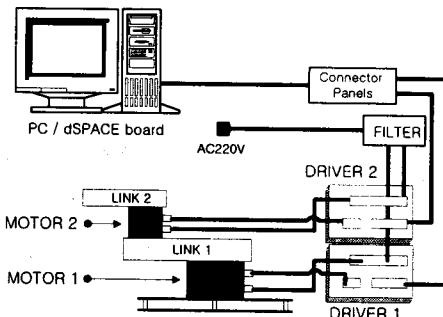


그림 3. 실시간 제어시스템.

기준 궤적은 Math Works사의 Matlab을 이용하여 생성했으며 이 궤적을 이용하여 실시간 실험에 사용하였다. Matlab의 RTW를 이용하여 컴파일한 후 dSPACE 사의 Control Desk와 DS 1102 DSP 보드를 통해 구현하였으며 전체 실험 과정을 그림 4에 보이고 있다.

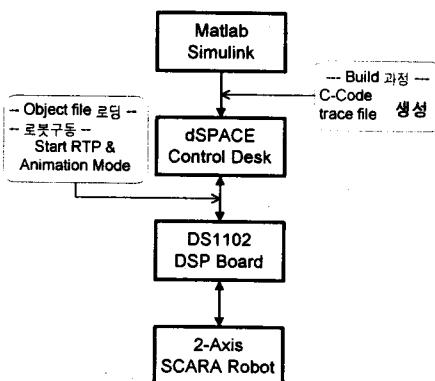


그림 4. 실시간 실험 구성도.

2축 스카라 로봇에 대한 계원을 표 1에서 보인다.

표 1. 2축 스카라 로봇의 계원

항목	값	단위
Link1의 길이	0.37	m
Link2의 길이	0.35	m
Link1의 질량	13.072	Kg
Link2의 질량	5.8744	Kg
Motor1의 질량	73	Kg
Motor2의 질량	14	Kg
Link1의 구동 마찰력	5.5	Nm
Link2의 구동 마찰력	0.9	Nm

실시간 실험을 통해 얻어진 출력 궤적을 그림 5에 보인다.

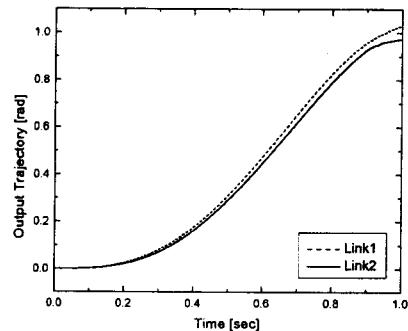


그림 5. 로봇의 실제 추종궤적.

3. 결 론

본 논문에서는 직접학습을 통한 모의 실험과 실시간 실험 결과를 보였다. 모의 실험에서는 반복학습 없이 직접학습만으로 원하는 입력을 찾을 수 있었으며 실시간 실험에서는 모의실험에서 얻은 입력을 로봇 시스템에 적용함으로써 로봇이 원하는 궤적을 추종하도록 하였다.

향후 실시간 실험에서 얻어진 출력 궤적에 대해 반복학습을 시키자. ILC의 경우 원하는 입력을 찾는데 많은 반복학습이 필요한 반면, DLC+ILC의 경우 적은 반복학습으로 원하는 입력을 빠른 시간 내에 찾을 수 있을 것이다.

(참 고 문 헌)

- [1] S. Arimoto, S. Kawamura, and F. Miyazaki, "Iterative learning control for robot systems," in *Proceedings of IECON*, 1984.
- [2] Jian-Xin Xu, "Direct learning of control efforts for trajectories with different time scales," *IEEE Transactions on Automatic Control*, Vol.43 No.7, July.
- [3] 여 성원, 이산시간 비선형 시스템의 수렴속도 개선을 위한 반복학습제어에 관한 연구, 국민대학교 석사학위 논문, 1997.
- [4] T.-J. Jang, C.-H. Choi and H.-S. Ahn, "Iterative learning control in feedback systems," *Automatica* a. Vol. 31, No. 2, pp.243-248, 1995.