

로봇 머니플레이터의 반복 학습 제어

Iterative Learning Control of Robot Manipulators

°문 정호, 도 태용, 정 명진

한국과학기술원 전기및전자공학과

E-mail: moon@donghae.kaist.ac.kr, mjchung@ee.kaist.ac.kr

Abstract— This paper presents an iterative learning control scheme for industrial manipulators. Based upon the frequency-domain analysis, the input update law of the learning controller is given together with a sufficient condition for the convergence of the iterative process in the frequency domain. The proposed learning control scheme is structurally simple and computationally efficient since it is independent joint control depending only on locally measured variables and it does not involve the computation of complicated nonlinear manipulator dynamics. Moreover, it is capable of canceling the unmodeled dynamics of the manipulator without even the parametric model. Several important aspects of the learning scheme inherent in the frequency-domain design are discussed and the control performance is demonstrated through computer simulations.

1. 서론

현재 생산 현장에서 사용되는 많은 산업용 머니플레이터들은 대부분 같은 채적을 반복하는 작업에 사용되고 있다. 만일 제어 알고리즘이 그 반복적인 특성을 고려 않고 설계된다면, 매 시도마다 항상 같은 형태의 추종 오차가 발생하며, 아무리 많은 시도를 하더라도 제어 성능이 향상되지 않는다. 또한 많은 비선형성을 가지고 있는 머니플레이터 동력학의 정확한 모델을 얻는 것은 거의 불가능하기 때문에 어느 정도의 모델링 오차는 피할 수 없다. 기존의 제어기는 제어 대상 시스템의 수학적인 모델을 기반으로 설계되므로 이러한 모델링 오차를 다루기가 힘들다. 이러한 요인들 때문에 반복 학습 제어 이론은 머니플레이터 제어에 많이 적용되어 왔다.

Arimoto[10]가 반복 학습 제어 이론의 개념을 제안한 이후 반복 학습 이론은 머니플레이터에 적용한 초기의 결과가 몇 명의 연구자들에 의해서 발표되었다 [7]-[9]. 이러한 결과들은 대부분 가속도 신호의 측정, 머니플레이터 동력학의 선형화, 큰 이득을 가지는 계획 제어기의 사용 등을 특징으로 하고 있다. 이후 Kuc은 고정된 이득을 가지는 PD 제어기와 가속도 측정이 필요 없는 학습 알고리즘으로 구성된 학습 제어기를 제시하였다 [4]. Horowitz는 함수 추정과 적응 제어 알고리즘을 사용한 학습 제어 알고리즘을 제안하였다 [5]. 한편, 머니플레이터 제어를 위한 반복 학습 제어 이론은 주파수 영역에서도 독립적으로 연구되어 왔다. Craig는 머니플레이터의 조인트 움직임에 영향을 미치는 마찰력의 영향을 보상하기 위한 학습 제어 방법을 제안하고 그 수렴 특성을 주파수 영역에서 분석하였다 [2]. De Luca는 부가적인 학습 필터를 도입하여 [2]의 학습 알고리즘을 일반화하고 그 결과를 높은 기어비를 가지는 산업용 머니플레이터에 적용하였다 [1]. Kavli는 시스템 전달 함수가 어떤 영역 속에 존재하는 경우의 학습 알고리즘의 수렴 특성과 그 성능을 분석하고 머니플레이터의 제어에 그 결과를 응용하였다 [3].

반복 학습 제어의 주파수 영역 해석은, 추종 주파수 대역과 주파수의 함수로서의 수렴 속도 등 시간 영역 해석 방법에서는 분석될 수 없는 유용한 개념을 제공한다. 주파수 영역 해석은 제어 대상 시스템의 전달 함수를 바탕으로 하기 때문에 주로 높

은 기어비를 가지는 산업용 머니플레이터에 적용되어 왔다. 높은 기어비를 가지는 머니플레이터에서는 선형인 액츄에이터의 동력학이 비선형 효과보다 훨씬 큰 영향을 가지기 때문에, 머니플레이터 동력학은 각 축마다 독립된 선형 시스템들로 쉽게 근사화될 수 있다. 하지만 대부분의 경우에 학습 제어기는 근사화된 선형 시스템의 외란으로 작용하는 비선형 항의 영향을 고려하지 않고 설계된다. 따라서 계획 제어기뿐만 아니라 학습 제어기가 가해지더라도 항상 머니플레이터 동력학의 비선형성 정도에 따른 추종 오차가 존재하게 된다.

그런 문제점을 해결하기 위하여, 본 논문에서 산업용 머니플레이터를 위한 새로운 반복 학습 제어 기법을 제시한다. 제안된 제어 기법은 근사화된 선형 시스템 모델을 기반으로 설계되는 feedforward 보상항을 가진 PD 제어기와 비선형 항의 영향을 보상하기 위한 학습 제어기로 구성된다. 주파수 영역에서 주어지는 학습 제어기의 입력 설정 규칙과 그의 수렴 조건은 [1]과 [3]에서 제시된 것들과 매우 유사하지만, 전체적인 제어 알고리즘은 전혀 다른 구조를 가지고 있고 수렴 조건도 다소 다른 맥락에서 유도된다. 제안된 제어 방법은 많은 실시간 계산을 필요로 하지 않고 각 축을 독립적으로 제어하기 때문에 비교적 느린 프로세서로도 쉽게 구현될 수 있다.

2. 머니플레이터의 동력학 모델

n -링크 로봇 머니플레이터의 동력학 모델은 다음과 같이 표현된다.

$$M(\mathbf{q})\ddot{\mathbf{q}} + N(\mathbf{q}, \dot{\mathbf{q}}) = \mathbf{T} \quad (1)$$

여기서 \mathbf{q} 는 $n \times 1$ 조인트 위치 벡터, \mathbf{T} 는 $n \times 1$ 조인트 토크 벡터, $M(\mathbf{q})$ 는 $n \times n$ 대칭인 양한정 관성 행렬, $N(\mathbf{q}, \dot{\mathbf{q}})$ 는 원심력, Coriolis 힘, 중력, 마찰력 등에서 기인하는 $n \times 1$ 벡터이다. $M(\mathbf{q})$ 와 $N(\mathbf{q}, \dot{\mathbf{q}})$ 의 요소들은 일반적으로 조인트 위치와 속도의 복잡한 비선형 함수이다. 이들은 또한 정확하게 알 수 없으며 머니플레이터 동작 동안 변하기도 하는 링크와 부하의 질량, 관성 moment들의 함수이기도 하다. 특히 마찰력은 수학적 모델로 잘 표현할 수 없는 비선형 항들을 포함하고 있으며, 머니플레이터 동작에 많은 영향을 끼친다.

로봇 머니플레이터를 움직이기 위해서는 액츄에이터가 필요하다. 머니플레이터의 조인트에 가해지는 토크를 크게 하기 위하여 액츄에이터는 보통 기어를 통하여 머니플레이터에 연결된다. 액츄에이터를 포함한 머니플레이터의 완전한 동력학을 얻기 위해서는 머니플레이터의 동력학과 액츄에이터의 동력학을 조합하여야 한다. 액츄에이터의 동력학은 보통 각 축마다 독립적인 n 개의 수식으로 표현되므로, 액츄에이터를 포함한 머니플레이터의 동력학 모델은 다음과 같이 표현된다.

$$(J_M + \frac{m_{ii}}{\eta_i^2})\ddot{q}_i + B_M \dot{q}_i = \frac{1}{\eta_i} \tau_i(t) - \frac{1}{\eta_i^2} w_i(t), \quad i = 1, \dots, n \quad (2)$$

여기서 J_M 은 액츄에이터 모터 관성, B_M 은 모터 운동 마찰 계수, τ_i 는 i 번째 조인트의 액츄에이터 토크, q_i 는 q 의 i 번째 값이다. η_i 는 i 번째 모터와 i 번째 조인트 사이의 기어비이다. m_{ii} 는 $M(q)$ 의 대각 요소 중 상수 부분을 나타낸다. $M(q)$ 의 대각 요소 중의 시변항과 비대각 요소, 비선형 항인 $N(q, \dot{q})$ 그리고 모델되지 않은 동력학은 모두 $w_i(t)$ 에 포함된다. 따라서 $w_i(t)$ 는 i 번째 조인트에 대한 나머지 조인트들의 영향을 포함한다. 기어비가 높은 조인트인 경우, 즉 $\eta_i \gg 1$ 이면, 모터의 동력학 모델이 비선형 항의 영향과 모델되지 않은 동력학보다 훨씬 더 큰 영향을 미치게 되어서 머니플레이터의 동력학은 선형 모델로 근사화 될 수 있다. 다음을 정의하면

$$\begin{aligned} J_i &= \eta_i J_M + \frac{m_{ii}}{\eta_i} \\ B_i &= \eta_i B_M \\ d_i(t) &= \frac{1}{\eta_i} w_i(t), \end{aligned}$$

동력학 (2)는

$$J_i \ddot{q}_i + B_i \dot{q}_i = \tau_i - d_i(t) \quad (3)$$

와 같이 간결하게 표현된다. 지금부터는 첨자의 반복을 피하기 위해서 i 번째 축을 나타내는 아래 첨자 i 를 생략한다.

3. 반복 학습 제어기의 설계

제어기 설계의 주된 목적은 각 축을 독립적으로 제어하며 반복적인 시도를 통해서 추종 성능을 향상시키는 것이다. 제어기는 feedforward 보상항을 가진 PD 제어기와 비선형 외란을 보상하기 위한 학습 제어기로 구성된다. 원하는 조인트 각을 q_d 라고 하자. 추종 오차를 다음과 같이 정의하면

$$e = q_d - q,$$

feedforward 보상항을 가진 PD 제어기는 다음과 같이 주어진다.

$$T_{PD}(t) = J \ddot{q}_d + B \dot{q}_d + k_v \dot{e} + k_p e \quad (4)$$

여기서 k_v 와 k_p 는 폐루프의 안정성을 보장하기 위한 양의 상수인 채한 제어기 이득이다. 원하는 조인트 변수 \ddot{q}_d 와 \dot{q}_d 는 미리 알고있기 때문에 feedforward 보상 입력의 계산은 off-line으로 수행될 수 있다. PD 제어 입력 (4)를 (3)으로 표현되는 머니플레이터의 조인트에 가하면, 오차의 동력학식은

$$J \ddot{e} + (k_v + B) \dot{e} + k_p e = d(t) \quad (5)$$

와 같이 된다. PD 이득은 폐루프 시스템이 적당한 감쇄 상수와 공진 주파수를 갖도록 선택한다. 사실, 이 PD 제어기만으로도 많은 경우 좋은 추종 성능을 얻을 수 있다. 만일 PD 제어 입력 (4)가 머니플레이터의 각 축에 가해지고 $e(0) = 0$, $\dot{e}(0) = 0$ 이라면, 위치와 속도의 추종 오차는 어떤 한계 값 이하로 제한되어 그 값은 채한 제어기의 이득에 비례하여 감소한다 [11]. 따라서 외란 $d(t)$ 의 영향을 신속하게 감소시키기 위해서는 제어기

이득을 가능한 크게 유지하는 것이 중요하다. 하지만 실제로 액츄에이터 토크의 제한으로 인해서 제어기 이득을 무한정 크게 할 수 없기 때문에 입력 (4)만으로는 추종 오차의 한계를 임의로 만들 수 없다.

머니플레이터가 같은 제작을 계속 반복한다는 가정 하에서는 비선형 외란 입력 $d(t)$ 의 동력학 또한 매주마다 반복되는 특성을 지닌다 [2]. 부가적인 학습 제어기는 반복적인 시도를 통하여 $d(t)$ 를 상쇄하기 위한 feedforward 토크를 생성하는 것을 목적으로 한다. 지금부터 아래 첨자 k 는 학습 횟수를 나타내는데 사용된다. 학습 제어 입력이 PD 제어 입력 (4)에 더해지면 오차의 동력학식은 다음과 같이 된다.

$$J \ddot{e}_k + (k_v + B) \dot{e}_k + k_p e_k = d(t) - v_k(t) \quad (6)$$

여기서 v_k 은 k 번째의 학습 제어 입력이다. 이상적인 경우, 즉 학습 제어 입력이 미지의 $d(t)$ 를 완벽하게 상쇄시키면 (6)은 더 이상 외란 입력을 가지지 않기 때문에 추종 오차는 없어진다. 좀 더 정확하게 이야기하면, $d(t)$ 의 동력학 중에서 반복적이지 않아서 학습 제어기로 상쇄할 수 없는 성분이 있을 수도 있다. 그렇다고 하더라도 반복적인 성분이 비반복적인 성분에 비해서 훨씬 크기 때문에 학습 제어는 여전히 효과적일 수 있다.

$P(s)$ 와 $Q(s)$ 는 안정하고 프라퍼한 전달 함수라고 하자. 학습 제어기의 입력 수정 규칙은 주파수 영역에서 다음과 같이 주어진다.

$$V_{k+1}(s) = P(s)V_k(s) + Q(s)E_k(s) \quad (7)$$

여기서 $V_k(s)$ 와 $E_k(s)$ 는 각각 학습 제어 입력 $v_k(t)$ 와 추종 오차 $e_k(t)$ 의 Laplace 변환이다 [1], [3]. 이 수정 규칙은 여러 논문에서 제안된 규칙의 일반화된 형태이다. 예를 들어서 $P(s) = 1$ $Q(s) = \beta$ 로 두면 (7)는 소위 P -형 학습 알고리즘인

$$v_{k+1}(t) = v_k(t) + \beta e_k(t) \quad (8)$$

로 된다. 시간 t' 에서 $v_{k+1}(t')$ 값이 $e_k(t')$ 값만의 영향을 받는 (8)과 달리, 입력 수정 규칙 (7)의 경우 $v_{k+1}(t')$ 는 $e_k(t')$ 뿐만 아니라 $[0, t']$ 동안의 모든 $e_k(t)$ 값의 영향을 받는다. 따라서 (7)은 (8)보다 훨씬 많은 정보를 사용하므로 더 많은 설계의 자유도를 제공한다.

(6)의 양변을 Laplace 변환한 다음 (7)에 대입하면, 다음 식이 얻어진다.

$$V_{k+1}(s) = P(s)V_k(s) + Q(s)H(s)(D(s) - V_k(s)) \quad (9)$$

여기서 $D(s)$ 는 $d(t)$ 의 Laplace 변환이며

$$H(s) = \frac{1}{J s^2 + (B + k_v)s + k_p}. \quad (10)$$

$d(t)$ 는 매 주기 반복적이기 때문에 $d(t)$ 의 Laplace 변환은 항상 존재한다. (9)의 각 항을 정리하면

$$V_{k+1}(s) = (P(s) - Q(s)H(s))V_k(s) + Q(s)H(s)D(s) \quad (11)$$

로 된다. 매 반복마다 초기 추종 오차가 0, 즉 $q(0) = q_d(0)$ 라고 하자. 만일 $P(s)$ 와 $Q(s)$ 가 다음 조건을 만족하도록 선택된다면

$$\|P(s) - Q(s)H(s)\|_\infty = \rho < 1 \quad (12)$$

수열 (11)은 다음 값으로 수렴한다.

$$V_\infty(s) = \lim_{k \rightarrow \infty} V_k(s) = \frac{Q(s)H(s)D(s)}{1 - P(s) + Q(s)H(s)} \quad (13)$$

여기서 $\|\cdot\|_\infty$ 는 전달 함수의 ∞ 노음을 나타낸다 [1], [3].

만일 $P(s)$ 를 1로 두고 조건 (12)를 만족시키는 $Q(s)$ 를 찾을 수 있다면 $V_k(s)$ 는 $D(s)$ 로, 즉 $v_k(t)$ 는 $d(t)$ 로 수렴한다는 것을

표 1: 머니플레이터와 관련된 매개 변수.

매개 변수	링크 1	링크 2	링크 3	단위
J	0.8	0.50	0.22	$\text{kg} \cdot \text{m}^2$
B	1.6	0.8	0.4	$\text{N} \cdot \text{m}/(\text{rad}/\text{s})$
k_p	60	60	50	$\text{N} \cdot \text{m}/\text{rad}$
k_v	12.2	9.3	5.6	$\text{N} \cdot \text{m}/(\text{rad}/\text{s})$
η	40	20	10	-

(13)으로부터 알 수 있다. 그러나 $H(s)$ 가 분모와 분자의 차수가 같은 최소 위상 시스템이 아니라면 이 수렴 조건을 만족시킬 수 없다는 사실이 알려져 있다 [6]. 다시 말해서, $H(s)$ 가 (10)과 같은 분모의 차수가 더 높인 시스템인 경우 $\|1 - Q(s)H(s)\|_\infty < 1$ 를 만족시키는 안정하고 프라퍼한 필터 $Q(s)$ 를 구하는 것은 불가능하다. 물론, $Q(s)$ 가 프라퍼해야 한다는 제한을 없애면 (12)를 만족시키는 $Q(s)$ 를 구할 수 있다. 하지만 이 경우 전체 폐루프가 고주파 잡음에 매우 민감하게 되어 시스템이 불안정해질 수 있기 때문에 바람직하지 않다.

부가적인 필터 $P(s)$ 의 도입은 수렴 조건을 완화시키고 더 많은 설계 자유도를 제공한다. $P(s)$ 를 적절히 선택한다면 분모와 분자의 차수가 같지 않은 $H(s)$ 에 대해서도 (12)를 만족시키는 $Q(s)$ 를 찾을 수 있다. 그렇지만 (13)에서 볼 수 있듯이 이 경우에는 수렴된 학습 제어 입력이 외란을 완전히 제거하지 못하므로 추종 오차가 0이 되지 않는다. 하지만 실제 문제에 있어서 $P(s)$ 의 도입에 의한 성능 저하는 크게 문제가 되지 않는다. 모든 머니플레이터의 원하는 궤적은 저주파 영역에 존재하기 때문에 정확한 추종 성능은 우리가 관심을 가지는 주파수 대역까지만 요구되기 때문이다. 따라서 정확한 추종이 요구되는 주파수 대역 내에서는 $P(s)$ 를 거의 1과 같도록 하고 고주파 영역에서는 수렴 조건을 만족시키도록 $P(s)$ 를 1보다 작게 만들면, 이론적으로 피할 수 없는 추종 오차에도 불구하고 제어 대역 내에서의 정확한 추종 성능을 얻을 수 있다.

다음으로 수렴 속도를 생각해보자. (11)에서 알 수 있듯이 어떤 주파수 ω 에서 학습 입력의 수렴 속도는 $|P(j\omega) - Q(j\omega)H(j\omega)|$ 의 값에 의해서 결정된다. 이 값이 작으면 작을수록 그 주파수에서의 수렴 속도는 빨라진다. 그러나 작은 ρ 값을 가지는 학습 제어기가 이보다 큰 ρ 값을 가지는 학습 제어기보다 항상 빠른 수렴 성능을 보이는 것은 아니다. 마찬가지로 같은 ρ 값을 가지는 학습 제어기들이 항상 같은 출력을 생성하는 것도 아니다. ρ 값은 단지 전 주파수에 대한 $|P(j\omega) - Q(j\omega)H(j\omega)|$ 값 중에서 가장 큰 값일 뿐이므로, 최악의 경우의 수렴률을 나타내며 학습 제어기의 수렴률을 평가하는 성능 지수로 사용될 수는 없다. 학습 제어 입력 혹은 추종 오차의 실제 수렴 속도에 결정적인 영향을 끼치는 값은 추종 주파수 대역 내의 $|P(j\omega) - Q(j\omega)H(j\omega)|$ 의 평균값이다.

학습 제어기 설계를 위한 지침은 다음과 같이 요약된다. 궤적 추종의 정확도를 결정짓는 $P(s)$ 는 추종해야 할 궤적을 고려하여 결정한다. 좋은 추종 성능을 얻기 위해서는 $P(s)$ 의 차단 주파수는 기준 궤적의 그것보다 충분히 높아야 한다. 일단 $P(s)$ 가 선택되면 학습 제어기의 수렴 조건을 만족시키는 $Q(s)$ 를 선택한다. 수렴 조건을 만족시키는 $Q(s)$ 는 무수히 많을 수 있지만 만 좋은 수렴 특성을 위해서 이들 중에서 $|P(s) - Q(s)H(s)|$ 의 값을 추종 대역 내에서 최소화시키는 것을 선택하는 것이 바람직하다.

4. 모의 실험

3개의 자유도를 가지는 머니플레이터에 대하여 여러 가지 모의 실험을 수행하였다. 머니플레이터와 액츄에이터의 매개 변수

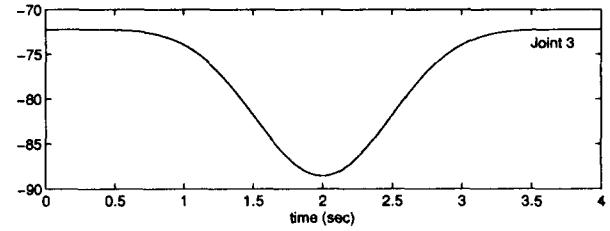


그림 1: 조인트 공간에서의 제 3축의 요구 경로.

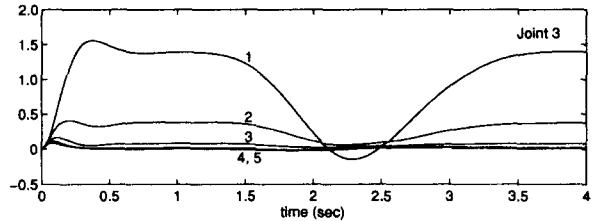


그림 2: 처음 5번 반복할 동안의 추종 오차.

그리고 각 축에 대한 PD 제어기의 이득은 표 1과 같다. PD 제어기의 이득은 모든 축의 폐루프 시스템이 임계 감쇄 시스템이 되도록 설정되었다. 모의 실험은 모든 축에 대해서 실시하였지만, 지면이 모자라는 관계로 세 번째 축의 경우만 설명한다. 그림 1은 3축이 추종하여야 할 요구 궤적이다.

우선 기준 궤적을 고려하여 필터 $P(s)$ 를 선택한다. 학습 제어의 궤적 목표는 비선형 외란 신호 $d(t)$ 를 생성하는 것으로 $P(s)$ 의 대역폭은 $d(t)$ 와 관계되어 있다. $d(t)$ 는 기준 신호의 고조파 신호를 포함하고 있으므로 $P(s)$ 의 대역폭은 기준 신호의 그것보다 충분히 넓어야 한다. 선택된 학습 필터 $P(s)$ 는

$$P(s) = \frac{1}{0.008s + 1} \quad (14)$$

로서 20 Hz의 차단 주파수를 가진다. 다음은 위의 $P(s)$ 와 함께 수렴 조건을 만족시키는 $Q(s)$ 를 구하여야 한다. $Q(s)$ 를

$$Q(s) = \frac{0.22s^2 + 6s + 50}{(0.008s + 1)^3} \quad (15)$$

로 선택하면 다음과 같이 수렴 조건이 만족됨을 쉽게 확인할 수 있다.

$$\|P(s) - Q(s)H(s)\|_\infty = 0.82$$

여기서

$$H(s) = \frac{1}{0.22s^2 + 6s + 50}.$$

$Q(s)$ 는 [0, 20 Hz] 영역에서는 $H(s)$ 의 역수와 거의 같으며 고주파 신호의 영향을 줄이기 위해서 주파수가 높아질수록 크기가 줄어들도록 선택되었다.

그림 2는 처음 5번 반복동안 3축에서 측정된 추종 오차이다. 학습 메모리가 처음에 $v_1(t) = 0$ 으로 초기화되었으므로 학습 제어 입력의 영향은 첫 번째 시도에서는 나타나지 않는다. 그럼에서 보듯이 시도 횟수가 늘어날수록 추종 오차가 급격히 줄어든다. 각 축의 추종 오차의 RMS(Root Mean Square) 값을 표시하는 그림 3은 추종 성능 향상에 대한 좀 더 정량적인 정보를 제공한다. 오차의 RMS 값은 점진적으로 감소하여 몇 번의 시도 이후에는 거의 0 근처로 수렴하며 이 때의 수렴 속도는 ρ 값보다 훨씬 빠르다는 것을 알 수 있다.

수렴 속도의 변화를 조사하기 위해서 다른 학습 필터를 사용하여 또 하나의 모의 실험을 수행하였다. $P(s)$ 는 고정시키고

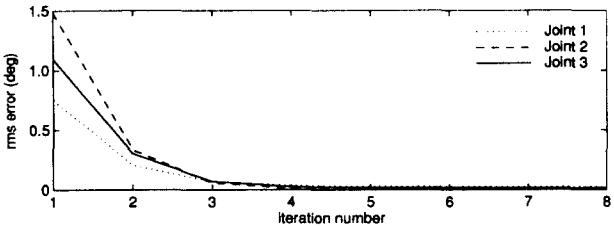


그림 3: 추종 오차의 RMS 값.

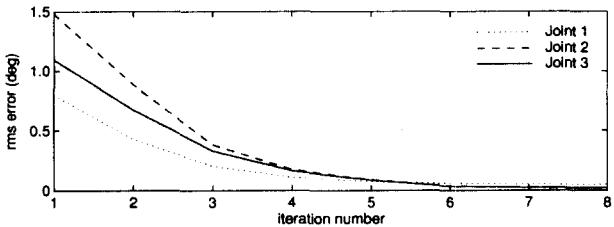


그림 4: 필터 (16)을 사용한 경우 추종 오차의 RMS 값.

$Q(s)$ 의 이득을 원래의 절반으로 줄이면 $Q(s)$ 는

$$Q'(s) = 0.5 \frac{0.22s^2 + 6s + 50}{(0.008s + 1)^3} \quad (16)$$

이 된다. 이 새로운 학습 제어기는 다음과 같이

$$\|P(s) - Q'(s)H(s)\|_\infty = 0.77$$

수렴 조건을 만족시킨다. 앞에서 언급되었듯이 이 ∞ 노음 값만으로는 실제 오차의 수렴 속도를 예측할 수 없다. 이 새로운 학습 제어기에 의해 얻어진 추종 오차의 RMS 값은 그림 4에 나타나 있다. 그림에서 알 수 있듯이 필터 (16)은 필터 (15)보다 더 작은 $\|P(s) - Q(s)H(s)\|_\infty$ 값을 가지고 있지만 실제 오차의 수렴 속도는 더 느려진다. 왜 이러한 결과가 얻어졌는가에 대한 설명은 $P(s) - Q(s)H(s)$ 의 Bode 선도를 표시한 그림 5에서 쉽게 얻어진다. 필터 (15)가 필터 (16)보다 더 큰 $\|P(j\omega) - Q(j\omega)H(j\omega)\|_\infty$ 값을 가지고 있지만 10 Hz 이하의 주파수 영역에서는 훨씬 더 작은 $|P(j\omega) - Q(j\omega)H(j\omega)|$ 값을 가진다. 그림 2에서 볼 수 있듯이 추종 오차는 대부분 10 Hz 보다 훨씬 낮은 저주파 영역에 존재하므로 실제로 계적 추종에 중요한 영향을 가지는 영역은 10 Hz 이하의 영역이다. 따라서 필터 (15)를 사용한 경우 오차의 수렴 속도가 빠른 것은 당연한 결과라 할 수 있다.

마지막 모의 실험은 $P(s)$ 의 주파수 대역과 추종의 정밀도와의 관계를 분석하기 위한 것이다. 필터 (14)는 20 Hz의 차단 주파수를 가지고 있었는데 이 필터의 차단 주파수를 10 Hz, 5 Hz로 차례로 바꾸면서 모의 실험을 실시하였다. 각 필터를 사용한 경우 20 번의 시도 후 남아 있는 추종 오차를 그림 6에 도시하였다. 분명히 차단 주파수가 높으면 높을수록 남아있는 오차가 작아진다는 사실을 알 수 있다. 좀 더 정량적으로 이야기하면 각각의 경우 잔존 오차는 초기 오차의 2.2%, 5.7%, 12.7% 이내에 존재한다. 이 결과는 앞에서 언급된 이론적인 분석과 일치한다.

5. 결론

본 논문에서는 산업용 머니퓰레이터를 위한 반복 학습 제어 기법과 그 학습 과정의 수렴을 보장하는 충분 조건이 제안되었다. 제안된 제어 기법은 feedforward 보상항을 포함하는 PD 제어

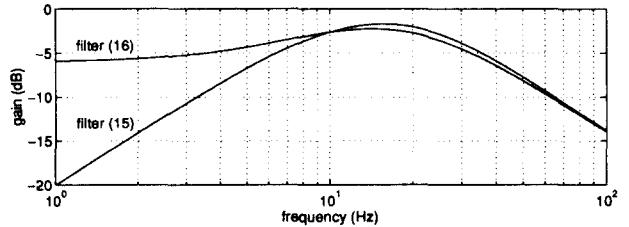


그림 5: $P(s) - Q(s)H(s)$ 의 Bode 선도.

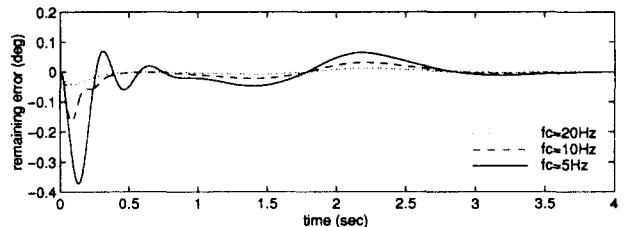


그림 6: 20번 시도후의 잔존 추종 오차.

기와 반복되는 시도를 통하여 추종 성능을 향상하기 위한 학습 제어기로 구성되어 있다. 학습 제어기는 계획 제어기가 완벽하게 제거할 수 없는 머니퓰레이터 동력학의 비선형 항의 영향을 효과적으로 보상한다. 각 축을 독립된 시스템으로 다루기 때문에 제안된 제어 알고리즘은 하나의 축에 대해 하나의 마이크로 프로세서로 구현될 수 있다. 주파수 영역에서 설계되는 학습 제어기의 중요한 성질에 대한 설명과 학습 필터를 선택하기 위한 기준을 제시하였다. 정확한 추종 성능을 유지하면서 빠른 수렴을 보장하는 제어기의 설계 방법을 좀 더 수학적으로 체계화하는 것은 추후 연구 과제의 하나이다.

참고 문헌

- [1] A. De Luca, G. Paesano, and G. Ulivi, "A frequency-domain approach to learning control: Implementation for a robot manipulator," *IEEE Trans. Ind. Electron.*, vol. 39, no. 1, pp. 1-10, 1992.
- [2] J. J. Craig, *Adaptive Control of Mechanical Manipulators*, Addison-Wesley, 1988.
- [3] T. Kavli, "Frequency domain synthesis of trajectory learning controller for robot manipulators," *J. Robot. Syst.*, vol. 9, no. 5, pp. 663-680, 1992.
- [4] T.-Y. Kuc, K. Nam, and J. S. Lee, "An iterative learning control of robot manipulators," *IEEE Trans. Robot. Automat.*, vol. 7, no. 6, pp. 835-841, 1991.
- [5] R. Horowitz, "Learning control of robot manipulators," *ASME J. Dynam. Syst., Meas., Contr.*, vol. 115, pp. 402-411, 1993.
- [6] K. L. Moore, M. Dahleh, S. P. Bhattacharyya, "Iterative learning control: A survey and new results," *J. Robot. Syst.*, vol. 9, no. 5, pp. 563-594, 1992.
- [7] P. Bondi, G. Casalino, and L. Gambardella, "On the iterative learning control theory for robot manipulators," *IEEE J. Robot. Automat.*, vol. 4, pp. 14-22, 1988.
- [8] S. Kawamura, F. Miyazaki, and S. Arimoto, "Realization of robot motion based on a learning method," *IEEE Trans. Syst. Man, Cybern.*, vol. 18, no. 1, pp. 126-134, 1988.
- [9] S.-R. Oh, Z. Bien, and I. H. Suh, "An iterative learning control method with application for the robot manipulator," *IEEE J. Robot. Automat.*, vol. 4, no. 5, pp. 508-514, 1988.
- [10] S. Arimoto, S. Kawamura, and F. Miyazaki, "Bettering operation of robots by learning," *J. Robot. Syst.*, vol. 1, no. 2, pp. 123-140, 1984.
- [11] F. L. Lewis, C. T. Abdallah, and D. M. Dawson, *Control of Robot Manipulators*, Macmillan Publishing Company, 1993.