

# 수직다물체시스템의 간접적응형 분산학습제어에 관한 연구

이수철\*, 박석순#, 이재원\*\*

## A Study on Indirect Adaptive Decentralized Learning Control of the Vertical Multiple Dynamic System

Soo Cheol Lee\*, Seok Sun Park# and Jae Won Lee\*\*

### ABSTRACT

The learning control develops controllers that learn to improve their performance at executing a given task, based on experience performing this specific task. In a previous work, the authors presented an iterative precision of linear decentralized learning control based on p-integrated learning method for the vertical dynamic multiple systems. This paper develops an indirect decentralized learning control based on adaptive control method. The original motivation of the learning control field was learning in robots doing repetitive tasks such as on an assembly line. This paper starts with decentralized discrete time systems, and progresses to the robot application, modeling the robot as a time varying linear system in the neighborhood of the nominal trajectory, and using the usual robot controllers that are decentralized, treating each link as if it is independent of any coupling with other links. Some techniques will show up in the numerical simulation for vertical dynamic robot. The methods of learning system are shown up for the iterative precision of each link.

**Key Words** : Iterative precision(반복정밀도), Indirect adaptive decentralized learning control(간접적응형 분산학습 제어), Learning control gain(학습조절자), Vertical multiple dynamic system(수직다물체시스템)

### 1. 서론

일반적인 산업현장에서 사용되는 대부분의 자동화 장치는 미리 설계한 생산공정에 따라 일정한 운동을 반복하도록 제작되어 있다. 그러나, 연속적인 반복운동과정에서 누적오차의 발생으로 원하는 궤적에서 어느 정도 벗어나는 운동을 행하게

되고, 이는 정확성에 의해서 품질이 좌우되는 생산 현장의 문제점 중의 하나로 남아 있다. 이러한 문제점을 극복하기 위하여 하드웨어적인 방법으로 운동의 시작점과 끝점 등에 센서를 설치하여 시작점과 끝점을 매번 조정하거나 일정한 시간이 지난 후에 교정하여 사용하는 방법 등이 있다. 하지만 이러한 방법은 생산과 관련이 없는 곳에 시간을

· 접수일: 2004년 6월 10일; 게재승인일: 2005년 1월 21일

\* 대구대학교 자동차산업기계공학과

# 교신저자: 영남대학교 기계공학과 대학원

E-mail: sspark@yumail.ac.kr, Tel. 053-815-5399

\*\* 영남대학교 기계공학과

투자함으로써 생산성을 떨어뜨리는 요인으로 작용하고, 특히 특정 범위를 지정하여 관리하는 오차를 제때에 발견하지 못한다면 제품의 하자에 따른 손실을 유발할 수도 있다. 이러한 문제점을 해결하는 방법으로 메커니즘을 수정 또는 교환하는 하드웨어적인 방법 외에 소프트웨어적인 제어 알고리즘으로 접근할 수 있는 방법중의 하나가 반복학습제어이다<sup>1-3</sup>.

또한, 일반적으로 산업현장에서 대부분 사용되는 제어알고리즘은 설계 시 시스템의 정확한 모델링을 필요로 한다. 그러나, 시스템을 정확하게 수학적 방정식으로 표현하기는 어렵기 때문에 시스템규명법 등을 사용하여 실험적인 방법으로 시스템을 모델링하여 사용하기도 한다<sup>4-7</sup>.

그러므로 본 연구에서는 반복운동하는 수직다물체시스템의 반복정밀도를 향상시키기 위해 분산학습 제어기 중에서도 시스템의 모델링이 필요하지 않는 간접적응방식의 분산학습제어기를 도입하여 동일작업의 반복 시 발생하는 시스템의 반복오차를 최소화 할 수 있는 학습방법과 수렴성 등을 연구하고자 한다.

## 2. 대상시스템

### 2.1 시스템 구성

본 논문에서 사용된 시스템은 재활공학에서 다루게 되는 의지와 의족을 설계대상으로 한 것이다<sup>9-12</sup>. 이 시스템은 Fig.1 과 같이 수직면을 운동하는 4 개의 링크로 구성되어 있고 하부에 2 개의 동력원을 구비하고 있어 끝점(p)을 원하는 형태의 궤적을 따라 움직이게 할 수 있다. 이와 같은 형태의 메커니즘은 동력원인 모터의 설치를 하부(o)에 할 수 있어 모터 질량에 따른 가반하중의 손실을 줄일 수 있다는 장점으로 수직형 산업용 로봇 등에 많이 활용되고 있다. 또한 이러한 구조는 서로 상관관계가 있는 링크 구조를 잘 조합함으로써 비연성(decoupling) 가속도 운동방정식을 생성할 수도 있도록 설계.제작할 수 있어 연성(coupling)되어 있는 다중의 서브시스템을 제어함에 따른 여러가지 어려움을 극복할 수 있어 유용하다<sup>13</sup>.




Fig. 1 Schematic diagram of the mechanism

### 2.2 운동방정식

본 논문에서는 Euler-Lagrange 방법<sup>13</sup> 으로 운동 방정식을 유도했고 결과는 다음과 같다.

$$\begin{aligned} d_{11}\ddot{\theta}_1 + d_{12}\ddot{\theta}_2 + h_{122}\dot{\theta}_2^2 + g_1 &= \tau_1 \\ d_{21}\ddot{\theta}_1 + d_{22}\ddot{\theta}_2 + h_{211}\dot{\theta}_1^2 + g_2 &= \tau_2 \end{aligned} \quad (1)$$

여기서,  $d_{11} \sim d_{22}$  는 관성항으로 식(2)와 같고  $h_{122}, h_{211}$  원심력항  $g_1, g_2$  는 중력항으로 식(3)과 같다.

$$\begin{aligned} d_{11} &= I_2 + I_4 + (m_1 + m_2)l_2^2 + m_4l_4^2 \\ d_{12} = d_{21} &= (m_1l_1l_2 + m_4l_3l_4)\cos(\theta_1 - \theta_2) \\ d_{22} &= I_1 + I_3 + m_1l_1^2 + (m_3 + m_4)l_3^2 \end{aligned} \quad (2)$$

$$\begin{aligned} h_{122} &= (m_1l_1l_2 + m_4l_3l_4)\sin(\theta_1 - \theta_2) \\ h_{211} &= -(m_1l_1l_2 + m_4l_3l_4)\sin(\theta_1 - \theta_2) \\ g_1 &= g\{(m_1 + m_2)l_2 + m_4l_4\}\cos\theta_1 \\ g_2 &= g\{m_1l_1 + (m_3 + m_4)l_3\}\cos\theta_2 \end{aligned} \quad (3)$$

식(2)와 식(3)에서 사용된 재료의 물성치는 Table 1 에 정리하였고, 중력가속도  $g = 980[cm/s^2]$  이다.

Table 1 Material properties used for calculation

Property	Unit	Symbol	Value
length	cm	$l_1, l_3$	25.2
		$l_2$	7.6
		$l_4$	30.7
mass	g	$m_1, m_3$	0.05

		$m_2$	0.5
		$m_4$	0.1
inertia moment	kg-cm <sup>2</sup>	$I_1, I_3$	1.0600e-2
		$I_2$	2.6467e-3
		$I_4$	3.1500e-2

### 3. 간접적응형 방식의 분산학습제어

다수의 서브시스템으로 구성된 시스템이 서로 연결된 형태를 수학적으로 표기하면 다음과 같다.

$$\begin{aligned}
 x_i(k+1) &= \sum_{j=1}^s A_{ij}(k)x_j(k) + B_i(k)u_i(k) + w_i(k) \\
 y_i(k+1) &= C_i(k+1)x_i(k+1) \quad (4) \\
 k &= 0, 1, 2, \dots, p-1
 \end{aligned}$$

여기서,  $i$ 는 해당 서브시스템 번호이고  $j$ 는  $i$ 와 다른 서브시스템 번호이다.  $s$ 는 서브시스템 개수,  $p$ 는 샘플링(sampling) 개수이고,  $A_i(k)$ 는 서브시스템행렬,  $B_i(k)$ 는 입력행렬,  $C_i(k)$ 는 출력행렬,  $w_i(k)$ 는 외란이나 매 반복 시 똑같이 발생하는 외력항(forcing function)이다.

반복학습을 위해 매 반복 시의 입력의 차와 출력의 차를 식(5)로 정의한다.

$$\begin{aligned}
 \delta_r \underline{u}_i &= \underline{u}_i^r - \underline{u}_i^{r-1} \\
 \delta_r \underline{y}_i &= \underline{y}_i^r - \underline{y}_i^{r-1} \quad (5)
 \end{aligned}$$

일반적인 학습제어문제에서는 매 반복 시 같은 초기조건이 발생되고, 외력항은 목표계적과 관련하여 매 반복 시 같은 값으로 발생되므로 식(4)와 (5)에서 초기항과 외력항은 상쇄되고 다음과 같은 형태로 표현 할 수 있다.

$$\delta_r \underline{y}_i = P_i \delta_r \underline{u}_i \quad (6)$$

여기서,  $\delta_r$ 는 반복  $r$ 과 반복  $r-1$ 에서 특성치의 차이를 나타낸다. 또한,  $P_i$ 는

$$\begin{bmatrix}
 C(1)B(0) & 0 & \dots & 0 \\
 C(2)A(1)B(0) & C(2)B(1) & \dots & 0 \\
 \vdots & \vdots & \ddots & \vdots \\
 C(p)(\prod_{k=1}^{p-1} A(k))B(0) & C(p)(\prod_{k=1}^{p-1} A(k))B(1) & \dots & C(p)B(p-1)
 \end{bmatrix}$$

이다.

식(6)를 각 서브시스템별로 재배열하면 다음과 같다.

$$\delta_r \underline{y}_i = P_{ii} \delta_r \underline{u}_i + \sum_{j=1, j \neq i}^s P_{ij} \delta_r \underline{u}_j \quad (7)$$

여기서,  $P_{ii}$  and  $P_{ij}$ 는  $i$ 서브시스템의 하(lower) 삼각행렬(triangular matrix)을 나타낸다. 첫 번째 항은  $i$ 서브시스템의 입력에 대한 반응을 나타내고, 두 번째 항은 다른 서브시스템의 입력에 대한 반응을 나타낸다. 이는 분산학습제어방식의 기본적인 형태이다.

이해를 돕기 위해 두 개의 서브시스템( $s=2$ )에 3 개의 시간영역에서 식(7)은 다음과 같은 형태를 갖게 된다.

$$\begin{bmatrix}
 \delta_r y_i(1) \\
 \delta_r y_i(2) \\
 \delta_r y_i(3)
 \end{bmatrix} =
 \begin{bmatrix}
 C_1 B_1 & 0 & 0 \\
 C_1 A_1 B_1 & C_1 B_1 & 0 \\
 C_1 (A_1^2 + A_1 A_2) B_1 & C_1 A_1 B_1 & C_1 B_1
 \end{bmatrix}
 \begin{bmatrix}
 \delta_r u_i(0) \\
 \delta_r u_i(1) \\
 \delta_r u_i(2)
 \end{bmatrix}
 +
 \begin{bmatrix}
 0 & 0 & 0 \\
 C_1 A_1 B_2 & 0 & 0 \\
 C_1 (A_1 A_2 + A_2 A_{22}) B_2 & C_1 A_2 B_2 & 0
 \end{bmatrix}
 \begin{bmatrix}
 \delta_r u_2(0) \\
 \delta_r u_2(1) \\
 \delta_r u_2(2)
 \end{bmatrix} \quad (8)$$

인과성 때문에  $P_{ii}$ 과  $P_{ij}$  행렬은 하 삼각행렬 형태를 갖고 있고, 연결된 시스템에서  $P_{ij}$ 는 0의 대각행렬을 갖고 있다. 여기서, 분산제어를 위한 다양한 기법을 생각할 수 있고, 한 기법으로서 한 반복에 해당 서브시스템을 학습시키고, 다른 서브시스템의 학습은 중지시켜 버리는 것을 생각할 수 있다. 본 논문에서는 이러한 학습방법을 개별학습이라 하였다. 이러한 학습방법을 사용하여 반복  $r$ 에서  $i$ 서브시스템을 학습시킨다면 식(7)는 다음과 같아 진다.

$$\delta_r \underline{y}_i = P_{ii} \delta_r \underline{u}_i \quad (9)$$

해당 서브시스템에 대한 학습은 한 반복에서

언어진 입력과 출력신호로부터 행렬  $P_{ii}$  를 예측할 수 있다. 추측된 행렬을  $\hat{P}_{i,r}$  라 표현하면, 분산확습제어구식은 다음과 같은 형태를 갖추게 된다.

$$\delta_r \underline{u}_i = \hat{P}_{i,r}^{-1} (\underline{y}_i^* - \underline{y}_{i,r}) \quad (10)$$

추측방법으로는 회귀적 최소자승법(recursive least squares algorithm)을 사용하였다<sup>4</sup>.

회귀적 최소자승법의 지수가중치 방법은 다음과 같다.

$$\hat{P}_{i,r} = \hat{P}_{i,r-1} + M_{i,r-2} \delta_r' \underline{u} \left[ \frac{\delta_r' \underline{y} - (\delta_r' \underline{u})^T \hat{P}_{i,r-1}}{1 + (\delta_r' \underline{u})^T M_{i,r-2} \delta_r' \underline{u}} \right] \quad (11)$$

여기서,

$$M_{i,r-1} = M_{i,r-2} - \frac{M_{i,r-2} \delta_r' \underline{u} (\delta_r' \underline{u})^T M_{i,r-2}}{\alpha_r(k) + (\delta_r' \underline{u})^T M_{i,r-2} \delta_r' \underline{u}}; r \geq 2$$

$$\alpha_r(k+1) = \alpha_0 \alpha_r(k) + (1 - \alpha_0) \quad (12)$$

$$k = 0, 1, 2, \dots, p-1$$

이다.  $\hat{P}_{i,r}$  는  $\hat{P}_{i,r}$  의  $l$  번째 행의 전치행렬(transpose matrix)이다. 그리고  $\delta_r' \underline{u}$  는  $P_{ii} \delta_r \underline{u}$  의 곱에서 영의 요소로 구성되어지도록 만들어지는  $\delta_r \underline{u}$  의 변형된 값이고,  $\delta_r' \underline{y}$  는  $\delta_r \underline{y}$  의  $l$  번째 행이다. 또한,  $M_{i,0}$  의 초기값은  $\hat{P}_{i,r}$  과 같은 차원의 단위행렬(identity matrix)를 취한다. 이 행렬은  $l$  이 증가함에 따라  $\hat{P}_{i,r}$  의 차원도 증가할 때 새롭게 조정되어야 하며, 다중 출력의 경우 같은 시간대에 상관하는 모든 열에서 같은  $M_{i,r}$  이 사용될 수도 있다. 그리고 식(12)의  $\alpha_r, \alpha_0$  는 일반적으로  $\alpha_r(0) = 0.95, \alpha_0 = 0.99$  를 사용한다<sup>4</sup>.

식(10)과 식(11)에서 설계조건을 살펴보면, 시스템에 대한 정보를 갖고 있지 않아도 입력신호와 출력신호 자료에서 설계조건들을 예측할 수 있다. 또한, 식(11)의 알고리즘을 통하여 추종오차(tracking error)의 수렴을 보장 받을 수 있다.

#### 4. 모의실험

##### 4.1 목표궤적

실험에서 사용하게 될 특정궤적을 생성하기 위

해서 또는 현실적인 메카니즘의 구성을 위해서 Fig. 1 에서 나타난  $\theta_1$  과  $\theta_2$  의 영역설정이 필요하다. 여기서,  $\theta_1 = 0^\circ, \theta_2 = 90^\circ$  일 때를 기구의 원점으로 설정하였고  $\theta_1 = -30^\circ \sim 30^\circ, \theta_2 = 60^\circ \sim 120^\circ$  로 영역의 한계를 주었다. 이때 p 점의 최대작업영역은 Fig. 2 의 빗금선과 같고 빗금선 속의 원은 본 실험에서 반복시키고자 하는 반지름이 50mm 인 원호 궤적이고 x 축, y 축의 수치는 Fig. 1 에서 o 점을 기준으로 p 점의 상대거리를 나타낸다.




Fig. 2 Work-space and desired trajectory

Fig. 3 의 (a)와 (b)는 Fig. 2 에서 나타난 원의 궤적을 나타내기 위한  $\theta_1$  과  $\theta_2$  의 각도의 변화를 시간의 경과에 따라 나타낸 결과로서 목표궤적이 된다.




Fig. 3 Desired trajectory in Joint space

### 4.2 PD 제어기 설계 및 상태방정식

실험에 사용한 운동방정식은 식(1)과 같고 각 서브시스템의 모터에 부가되는 토크(torque)에 분산제어를 위해 분산제어량  $u_1, u_2$ 를 추가하여 정리하면 식(13)와 같다.

$$\begin{aligned} \tau_1 &= K_{p1}(\theta_1^* - \theta_1) + K_{v1}(\dot{\theta}_1^* - \dot{\theta}_1) + u_1 \\ \tau_2 &= K_{p2}(\theta_2^* - \theta_2) + K_{v2}(\dot{\theta}_2^* - \dot{\theta}_2) + u_2 \end{aligned} \quad (13)$$

여기서,  $K_{p1}, K_{v1}, K_{p2}, K_{v2}$ 는 PD 조절이득으로 각각 3600, 100, 1800, 126.25 이다. 이때 극점은

$$P_i = \begin{bmatrix} -1.2037e+001 \pm 2.6260e+001i \\ -9.9960e+000 \pm 1.3767e+001i \end{bmatrix}$$

로서 극점이 좌반평면(LHP : left half plane)에 위치하여 시스템의 안정성을 예측할 수 있다. 이러한 PD 제어 결과를 Fig. 4에 나타내었다. Fig. 4에 나타난 결과는 Fig. 3에서 제시한 각 축의 목표궤적과 모의실험을 통해 발생한 궤적과의 차이를 나타낸 것이다.




Fig. 4 Position error with PD control

$\varepsilon\theta_1 = \theta_1 - \theta_1^*$ ,  $\varepsilon\theta_2 = \theta_2 - \theta_2^*$  이라 하고,  $\varepsilon\theta \approx 0$ 로 가정하여 식(13)를 식(1)과 조합하면

$$\begin{aligned} d_{11}\varepsilon\ddot{\theta}_1 + d_{12}\varepsilon\ddot{\theta}_2 &= -K_{v1}\varepsilon\dot{\theta}_1 - K_{p1}\varepsilon\theta_1 + u_1 + w_1 \\ d_{22}\varepsilon\ddot{\theta}_2 + d_{21}\varepsilon\ddot{\theta}_1 &= -K_{v2}\varepsilon\dot{\theta}_2 - K_{p2}\varepsilon\theta_2 + u_2 + w_2 \end{aligned} \quad (14)$$

이다. 여기서,

$$\begin{aligned} w_1 &= -\{d_{11}\dot{\theta}_1^* + d_{12}(\theta^*)\dot{\theta}_2^* + h_{122}(\theta^*)\dot{\theta}_2^*\dot{\theta}_2^* + g_1(\theta_1^*)\} \\ w_2 &= -\{d_{21}(\theta^*)\dot{\theta}_1^* + d_{22}\dot{\theta}_2^* + h_{211}(\theta^*)\dot{\theta}_1^*\dot{\theta}_1^* + g_2(\theta_2^*)\} \end{aligned} \quad (15)$$

위 식을 종합하여 상태행렬로 표현하기 위해 상태벡터를  $x = [\varepsilon\theta_1 \ \varepsilon\dot{\theta}_1 \ \varepsilon\theta_2 \ \varepsilon\dot{\theta}_2]^T$ 라 놓으면 상태변수 형태의 운동방정식은 다음과 같다<sup>8</sup>.

$$\begin{aligned} \dot{x}(t) &= A_c x(t) + B_c u(t) + w_c(t) \\ y(t) &= Cx(t) \end{aligned} \quad (16)$$

여기서, 연속시간 상태행렬  $A_c, B_c$ 에 2.2절에서 나타낸 물성치를 대입하여 이산화 상태행렬  $A, B$ 로 나타내면 다음과 같다.

$$\begin{aligned} A &= \begin{bmatrix} 3.7780e-001 & 2.0620e-002 & 2.7971e-002 & 2.5895e-003 \\ -1.6986e+001 & -9.4034e-002 & 4.3577e-001 & 5.8535e-002 \\ 5.5941e-002 & 2.8093e-003 & 7.4787e-001 & 2.7659e-002 \\ 8.7155e-001 & 8.0151e-002 & -8.0293e+000 & 1.8470e-001 \end{bmatrix} \\ B &= \begin{bmatrix} 1.7283e-004 & -1.5539e-005 \\ 4.7183e-003 & -2.4210e-004 \\ -1.5539e-005 & 1.4007e-004 \\ -2.4210e-004 & 4.4607e-003 \end{bmatrix} \end{aligned} \quad (17)$$

### 4.3 실험결과

본 절에서는 분산학습제어의 학습방법을 개별 학습으로 하였고, 식(12)의  $\alpha_r(k)$ 를 지수가중치와 지수고정치로 나누어 실험하였다. 그 결과를 각 경우에 대하여 시간영역의 반응인 위치오차와 반복영역에서의 반응으로 나타내었다. 실험 시 샘플링시간은 0.05 초로 하였고, 각 서브시스템 별로 반복횟수  $r = 50$ 으로 하였다. 설명 중 서브시스템 1은  $\theta_1$ 을 나타내고 서브시스템 2는  $\theta_2$ 를 나타낸다. 그리고, 반복영역에서 위치오차의 추이를 살펴보기 위해서 매 반복 시 각 시간대 위치오차 절댓값의 합(Summation of Absolute Position Error : SAPE)을 다음과 같이 정의하여 매 반복 시 관찰하였다.

$$SAPE = \sum_{k=1}^r |e'_r(k)|$$

여기서,

- $i$  = 서브시스템 번호
- $r$  = 반복학습수

이다.

두가지 실험조건에 따른 결과는 다음과 같다.

실험조건 1 : 지수가중치  $\alpha_r(k)$ 의 초기치  $\alpha(0) = 0.95$ ,  $\alpha_0 = 0.8$ 를 사용




Fig. 5 Position error histories




Fig. 8 Summation of absolute position error

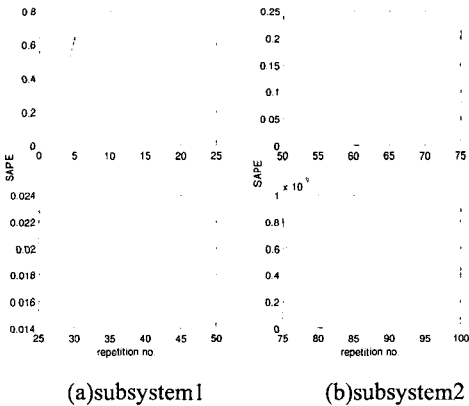


Fig. 6 Summation of absolute position error

실험조건 2 : 지수가중치  $\alpha_r(k) = 1.0$  로 고정




Fig. 7 Position error histories

Fig. 5 와 Fig. 7 은 실험조건 1 과 실험조건 2 의 시간영역의 반응인 위치오차를 나타내고, Fig. 6 과 Fig. 8 은 반복영역에서의 반응인 SAPE 의 크기를 나타낸다. 두가지 영역의 반응결과를 보면 두 조건 모두 반복횟수가 증대될수록 위치오차와 SAPE 의 크기가 감소하여 0 으로 수렴한다. 본 연구 결과의 특징으로는 서브시스템 1 보다 서브시스템 2 의 수렴 정도가 우수하다는 것이다. 이는 Fig. 3 의 관절계적의 형태에 의한 영향으로 판단된다. 그리고, 본 시스템에서는 식(12)의 지수가중치  $\alpha_r(k)$  를 반복구간별로 변화시키는 것과 실험조건 2 처럼 지수가중치를  $\alpha_r(k) = 1.0$  로 고정하는 것의 결과가 거의 일치한다. 이는 위치오차의 수렴정도로는 비슷하지만 식(12)를 단순화시켜 연산할 수 있다는 면에서 지수가중치가 유리하다는 것을 의미한다.

## 5. 결론

본 논문에서는 시스템의 정보를 필요치 않는 간접적응형 분산학습제어법을 수직다물체시스템에 적용시켜 실험하였다. 시스템의 추측방법으로 회귀적 최소자승법의 지수가중치방법을 사용하였고 지수가중치를 변화시켜가면서 실험한 결과와 지수가중치를 고정시켜 사용하는 것의 결과가 거의 비슷하였다. 즉, 어떤 방법을 사용하더라도 시스템 정밀도 향상을 증대시키는 것을 알 수 있다.

## 후 기

본 논문은 BK21 지역대학 육성사업에 의한 연구비지원으로 이루어진 것으로서, 이에 관계자 여러분께 감사드립니다.

## 참고문헌

1. Arimoto, S., Kawamura, S. and Miyasaki, F., "Bettering Operation of Robots by Learning," *Journal of Robotic Systems*, Vol. 1, No. 2, pp. 123-140, 1984.
2. Middleton, R. H., Goodwin, G. C. and Longman, R. W., "A Method for Improving the Dynamic Accuracy of a Robot Performing a Repetitive Task," *International Journal of Robotics Research*, Vol. 8, No. 5, pp.67-74, 1989.
3. Phan, M. and Longman, R. W., "A Mathematical Theory of Learning Control for Linear Discrete Multivariable Systems," *Proceedings of the AIAA/AAS Astrodynamics Conference*, Minneapolis, Minnesota, pp. 740-746, 1988.
4. Goodwin, G. C. and Sin, K. S., "Adaptive Filtering Prediction and Control," Prentice Hall, Inc., 1984.
5. Phan, M. and Longman, R. W., "Indirect Learning Control with Guaranteed Stability," *Proceedings of the 1989 Conference on Information Sciences and Systems*, Johns Hopkins University, Baltimore, MD, 1989, pp.125-131.
6. Longman, R., Lee, S. and Phan, M., "Indirect Decentralized Learning Control," *Advances in the Astronautical Sciences*, American Astronautical Society, *Proceedings of the 1992 AAS/AIAA Spaceflight Mechanics Meeting*, Colorado Springs, February 1992.
7. Lee, S., "Precision of Iterative Learning Control for the Multiple Dynamic Subsystems," *J. of the KSPE*, Vol. 18, No. 3, pp.131-142, 2001.
8. Lee, S. and Park, S., "Research for Improvement of Iterative Precision of the Vertical Multiple Dynamic System," *J. of the KSPE*, Vol. 21, No. 5, pp.64-72, 2004.
9. Yum, Y., "Bio-Robots and Intelligent Prosthetics," *J. of the KSPE*, Vol. 17, No. 11, pp.36-42, 2000.
10. Kim, S., Jung, S., Ryu, D., Choi, K. and Kim, B., "Development of the Pneumatic Manipulator of Gait Rehabilitation Robot using Fuzzy Control," *J. of the KSPE*, Vol. 17, No. 12, pp.169-175, 2000.
11. Shin, H., Kang, C., Jung, S. and Kim, S., "Force Control of an Arm of Walking Training Robot Using Sliding Mode Controller," *J. of the KSPE*, Vol. 19, No. 12, pp.38-44, 2002.
12. Shin, H., Choi, S. and Kim, S., "Position and Vibration Control of Flexible 2-Link Robot Arm Using Piezoelectric Actuators and Sensors," *J. of the KSPE*, Vol. 17, No. 11, pp.206-212, 2000.
13. Spong, Mark W. and Vidyasagar, M., "Robot Dynamics and Control," John Wiley & Sons, Inc., 1989.