

오차파형전달방식 간접적응형 분산학습제어 알고리즘을 적용한 수직다물체시스템의 반복정밀도 보증[†]

(Quality Assurance of Repeatability for the Vertical Multiple Dynamic Systems in Indirect Adaptive Decentralized Learning Control based Error Wave Propagation)

이 수 철*
(Soo Cheol Lee)

요 약 반복학습제어는 특정목적 케도의 반복작업을 수행하는 정밀도를 개선하는 제어기를 개발하는 기술이다. 기존 연구에서는 수직다물체의 반복정밀도를 개선하기 위하여 누적학습제어와 적응제어 기법을 한 반복영역에서 동시에 실시하는 기법을 개발하였다. 당초 이 기술은 생산조립라인의 산업용 로봇에서 발생하는 반복정밀도를 개선하기 위해 개발하였으며, 특히, 분산학습기법은 산업용 로봇에서 발생하는 실질적 제어 방식에 유효한 기법이다. 본 논문에서 개발한 제어기술은 한 반복영역의 모든 시간대의 입출력 정보를 동시에 학습하기 보다는 매 시간대의 입출력 정보를 각 시간대마다 충분히 학습하고 다음 시간대의 정보를 학습하는 것이다. 본 논문에서 개발한 기술을 산업용 로봇과 의료기기에 적용하면 수직다물체의 정밀도 품질보증 확보에 큰 기여를 하게 된다.

핵심주제어 : 반복정밀도, 간접적응형 분산학습제어, 오차파형전달방식

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. Error wave propagation method will show up in the numerical simulation for five-bar linkage as a vertical dynamic robot. The methods of learning system are shown up for the iterative precision of each link at each time step in repetition domain. Those can be helped to apply to the vertical multiple dynamic systems for precision quality assurance in the industrial robots and medical equipments.

Key Words : Iterative precision, Indirect Adaptive decentralized learning control, Error wave propagation method

* 이 논문은 2005학년도 대구대학교 학술연구비지원에 의한 논문임

† 대구대학교 공과대학 자동차산업기계공학부 교수

1. 서 론

일반적인 산업현장에서 사용되는 대부분의 자동화 장치는 미리 설계한 생산 공정에 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 기간이 지난 후에 교정하여 사용하는 방법 등이 있다. 하지만 이러한 방법은 생산과 관련이 없는 곳에 시간을 투자함으로써 생산성을 떨어뜨리는 요인으로 작용하고, 특히 특정 범위를 지정하여 관리되는 오차를 제때에 발견하지 못한다면 제품의 하자에 따른 손실을 유발할 수도 있다. 이러한 문제점을 유발할 수 있는 하드웨어적인 방법 외에 소프트웨어적인 제어 알고리즘으로 접근할 수 있는 방법 중의 하나가 반복학습제어이다[1-3]. 일반적으로 대부분 산업현장에서 사용되는 제어알고리즘은 설계 시 시스템의 정확한 모델링이 필요로 한다. 그러나, 정확하게 시스템을 수학적인 방정식으로 표현하기는 어렵기 때문에 시스템규명법(system identification) 등을 사용하여 실험적인 방법으로 시스템을 모델링하여 사용하기도 한다[4-9].

한편, 전자조립라인에서 가장 많이 사용되는 수평다물체시스템에는 선형분산학습제어 연구가 진행되었다[7-8]. 그러나, 자동차조립라인과 재활보조기기 개발에서 많이 활용되는 수직다물체시스템인 5절링크기구에 대한 연구를 진행하기 시작하면서 시스템의 정보를 확실히 아는 상태에서 반복정밀도를 보장하는 것을 보여 주었다[9].

본 연구에서는 반복 운동하는 5절링크기구의 반복정밀도를 향상시키기 위해 분산학습 제어기 중에서도 시스템의 모델링이 필요하지 않는 간접적 응방식의 분산학습제어기를 도입하여 동일작업의 반복 시 발생되는 시스템의 반복오차를 최소화 할 수 있는 학습방법과 안정성 등을 연구하여 왔다.

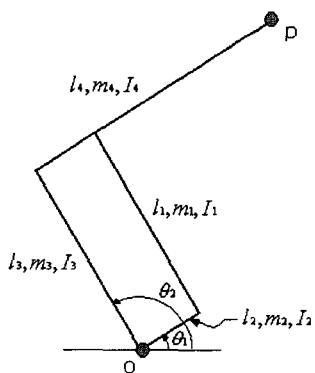
이 제어방식에서의 문제점은 반복영역의 과도 상태에서 학습조절자의 상태에 따라 오버슈트(Overshoot)현상이 나타나고 있다. 이를 극복하고

자 시간영역을 동시에 학습하지 않고 매 시간간격마다 동시학습을 시켜 안정성이 확보되면, 다음 시간간격으로 넘어 가는 방식의 파도전달방식을 적용하여 과도상태의 오버슈트를 줄여 나가고자 한다. 실제 실험이나 임상에서 이 오버슈트 현상은 실질적으로 문제를 일으키는 만큼 산업현장에서 발생되는 물리적 한계를 극복하고 개선하는 알고리즘으로서 채택이 가능하리라 본다[6]. 매시간대 마다 오차를 줄여 나가는 방법을 오차파형전달식(Error Wave Propagation Method)이라고 한다.

2. 대상시스템

2.1 시스템 구성

본 논문에서 사용된 시스템은 재활공학에서 다루게 되는 의지와 의족을 설계대상으로 한 것이다[10]. 이 시스템은 그림 1과 같이 수직면을 운동하는 5개의 링크로 구성되어 있고 하부에 2개의 동력원을 구비하고 있어 끝점(p)을 원하는 형태의 궤적을 따라 움직이게 할 수 있다. 이와 같은 형태의 메카니즘은 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 디커플 가속도 운동방정식을 생성할 수도 있도록 설계·제작 할 수 있어 커플되어 있는 다중의 서브시스템을 제어함에 따른 여러가지 어려움을 극복할 수 있어 유용하다[11].



<그림 1> Schematic diagram of the mechanics

2.2 운동방정식

본 논문에서는 Euler-Lagrange 방법으로 운동방정식을 유도했고 결과는 다음과 같다[11].

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

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

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

$$\begin{aligned} g_1 &= g(2m_2l_2 + m_4l_4)\cos\theta_1 \\ g_2 &= g(m_1l_1 + 2m_3l_3)\cos\theta_2 \end{aligned} \quad (3)$$

식(2)와 식(3)에서 사용된 재료의 물성치는 표 1에 정리하였고, $g = 980[\text{cm/s}^2]$ 이다.

<표 1> 대상시스템 재료의 물성치

물성	단위	기호	수치
길이	cm	l_1, l_3	25.2
		l_2	7.6
		l_4	30.7
질량	Kg	m_1, m_3	5e-5
		m_2	5e-4
		m_4	1e-4
관성모멘트	$\text{Kg}\cdot\text{cm}^2$	I_1, I_3	1.0600e-3
		I_2	2.6467e-3
		I_4	3.1500e-3

3. 간접적응형 방식의 분산학습제어

3.1 다물체시스템의 수학적 모델링

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

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

여기서, i 와 j 는 해당 시스템과 다른 시스템 번호를 나타내고 있다. $w_i(k)$ 는 외란이나 매 반복 시 똑같이 발생되는 forcing function이다. 그리고, 학습제어문제에서는 매 반복 시 같은 초기조건이 발생되고, forcing function은 목표궤적과 관련하여 매 반복 시 같은 값으로 발생된다. 따라서, 초기항과 forcing function term은 상쇄되고 다음과 같은 형태로 표현 할 수 있다.

$$\delta_j y_i = P_i \delta_j u_i \quad (5)$$

여기서, δ_j 는 반복 j 와 반복 $j-1$ 에서 특성치의 차이를 나타낸다.

$$\begin{aligned} y &= [y^T(1) \ y^T(2) \ \dots \ y^T(p)]^T \\ \underline{u} &= [\underline{u}^T(0) \ \underline{u}^T(1) \ \dots \ \underline{u}^T(p-1)]^T \end{aligned} \quad (6)$$

여기서, P 는

$$\left[\begin{array}{cccc} C(1)B(0) & 0 & \dots & 0 \\ C(2)A(1)B(0) & C(2)B(1) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ C(p)(\prod_{k=1}^{p-1} A(k))B(0) & C(p)(\prod_{k=1}^{p-1} A(k))B(1) & \dots & C(p)B(p-1) \end{array} \right]$$

이고, product notation은 원쪽의 큰 값에서 오른쪽의 작은 값으로 적산되는 것을 나타낸다. 그리고,

$$\delta_j y = -\delta_j e \quad (7)$$

이다.

3.2 간접적응형 분산학습제어

식(5)를 각 시스템별로 재배열하면 다음과 같다.

$$\delta_r \underline{y}_i = P_{ii} \delta_r \underline{u}_i + \sum_{\substack{j=1 \\ j \neq i}}^s P_{ij} \delta_r \underline{u}_j \quad (8)$$

여기서, P_{ii} and P_{ij} 는 i th subsystem의 lower triangular matrices를 나타낸다. 첫 번째 항은 당해 입력에 대한 반응을 나타내고, 두 번째 항은 다른 시스템의 입력에 대한 반응을 나타낸다. 이는 분산학습제어방식을 기본적인 형태를 제공하고 있다.

이해를 돋기 위해 두 개의 시스템($s=2$)에 3개의 time step에서 식(8)은 다음과 같은 형태를 갖는다.

$$\begin{aligned} & \begin{bmatrix} \delta_r y_1(1) \\ \delta_r y_1(2) \\ \delta_r y_1(3) \end{bmatrix} = \\ & \begin{bmatrix} C_1 B_1 & 0 & 0 \\ C_1 A_{11} B_1 & C_1 B_1 & 0 \\ C_1 (A_{11}^2 + A_{12} A_{21}) B_1 & C_1 A_{11} B_1 & C_1 B_1 \end{bmatrix} \begin{bmatrix} \delta_r u_1(0) \\ \delta_r u_1(1) \\ \delta_r u_1(2) \end{bmatrix} \\ & + \\ & \begin{bmatrix} 0 & 0 & 0 \\ C_1 A_{12} B_2 & C_1 B_1 & 0 \\ C_1 (A_{11} A_{12} + A_{12} A_{22}) B_2 & C_1 A_{12} B_2 & 0 \end{bmatrix} \begin{bmatrix} \delta_r u_2(0) \\ \delta_r u_2(1) \\ \delta_r u_2(2) \end{bmatrix} \end{aligned} \quad (9)$$

인과성 때문에 P_{ii} 과 P_{ij} matrices는 lower block triangular 형태를 갖고 있고, 연결된 시스템에서 P_{ij} 는 zero diagonal block elements를 갖고 있다.

간접적용형기법은 참고문헌[6]에서 잘 설계되어 있다. 여기서, 분산제어를 위한 다양한 기법을 생각할 수 있다.

첫 번째 반복 시 당해시스템을 학습시키고, 다른 시스템의 학습은 중지시켜 버리는 것을 생각할 수 있다. 이때 반복 r 에서 subsystem i 's를 학습시킨다면 식(5)는 다음과 같다.

$$\delta_r \underline{y}_i = P_{ii} \delta_r \underline{u}_i \quad (10)$$

대상시스템에 대한 학습은 한 반복에서 얻어진 입력과 출력신호로부터 matrix P_{ii} 를 예측할 수 있다. 추측된 matrix를 $\hat{P}_{ii,r}$ 라 표현하면, 분산학습제어규칙은 다음과 같은 형태를 갖추게 된다.

$$\delta_r \underline{u}_i = \hat{P}_{ii,r}^{-1} (\underline{y}_i^* - \underline{y}_{i,r}) \quad (11)$$

추측방법에는 다양한 기법을 생각할 수 있다. 대표적인 기법으로는 projection algorithm, 또는, orthogonal projection algorithm, 그리고, recursive least squares algorithm 등을 예를 들 수 있다.

간접적용형 기법에 필요한 추가적인 단계를 나타내면, $\hat{P}_{l,r}$ 는 $\hat{P}_{ii,r}$ 의 l 번째 열을 transpose한 column vector이다. 그리고, $\delta_r^t \underline{u}$ 는 $P_{ii} \delta_r \underline{u}_i$ 의 곱에서 영의 요소로 구성되어지도록 만들어지는 $\delta_r \underline{u}$ 의 변형된 값이고, $\delta_r^l \underline{y}$ 는 $\delta_r \underline{y}$ 의 l 번째 열이다. 이때, recursive least squares 알고리즘의 지수가중치 방법은 다음과 같다.

$$\hat{P}_{l,r} = \hat{P}_{l,r-1} + M_{l,r-2} \delta_r^t \underline{u} \left[\frac{\delta_r^l \underline{y} - (\delta_r^t \underline{u})^T \hat{P}_{l,r-1}}{1 + (\delta_r^t \underline{u})^T M_{l,r-2} \delta_r^t \underline{u}} \right] \quad (12)$$

여기서,

$$M_{l,r-1} = M_{l,r-2} - \frac{M_{l,r-2} \delta_r^t \underline{u} (\delta_r^t \underline{u})^T M_{l,r-1}}{\alpha_r + (\delta_r^t \underline{u})^T M_{l,r-2} \delta_r^t \underline{u}} ; r \geq 2$$

$$\alpha_r(t) = \alpha_0 \alpha_r(t-1) + (1 - \alpha_0) \quad (13)$$

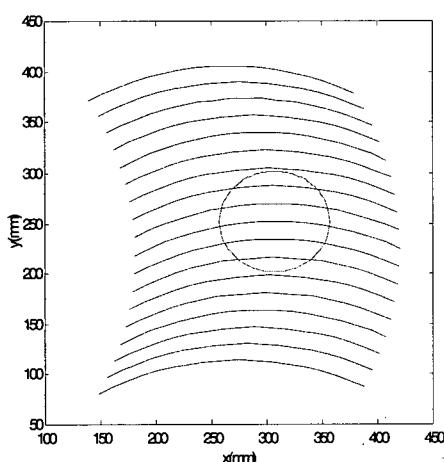
여기서, $\alpha_r(0) = 0.95, \alpha_0 = 0.99$ 를 일반적으로 사용한다. 또한, $M_{l,0}$ 의 초기값은 $\hat{P}_{l,r}$ 과 같은 차원의 identity matrix를 취한다. 이 matrix는 l 이 증가함에 따라 $\hat{P}_{l,r}$ 의 차원도 증가할 때 새롭게 조정되어야 하며, 다중 출력의 경우 같은 시간대에 상관하는 모든 열에서 같은 $M_{l,r}$ 이 사용될 수도 있다.

식(11)과 식(12)에서 설계조건을 살펴보면, 시스템에 대한 정보를 갖고 있지 않아도 입력신호와 출력신호 자료에서 설계조건들을 예측할 수 있다. 식(12)의 알고리즘을 통하여 zero tracking error로의 수렴을 보장 받을 수 있다.

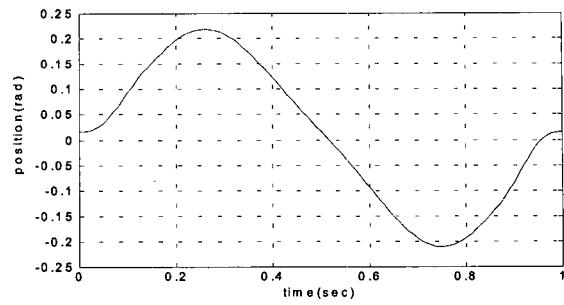
4. 모의실험

4.1 목표궤적

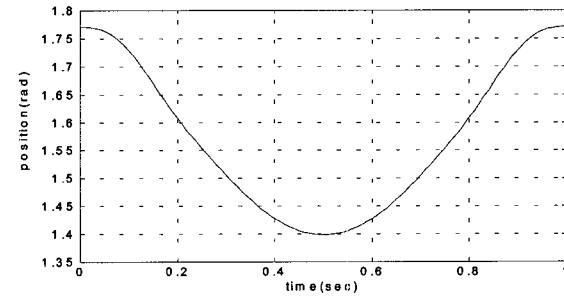
실험에서 사용하게 될 특정 궤적을 생성하기 위해서 또는 현실적인 메카니즘의 구성을 위해서 그림 1에서 나타난 θ_1 과 θ_2 의 영역설정이 필요하다. 여기서, $\theta_1 = 0^\circ$, $\theta_2 = 90^\circ$ 일 때를 기구의 원점(home-position)으로 설정하였고 $\theta_1 = -30^\circ \sim 30^\circ$, $\theta_2 = 60^\circ \sim 120^\circ$ 로 영역의 한계를 주었다. 이때 p점의 최대 작업영역(work-space)은 그림 2의 빛금선과 같고 빛금선 속의 원은 본 실험에서 반복시키고자 하는 반지름이 50mm인 원호 궤적이고 x축, y축의 수치는 그림 1에서 o점을 기준으로 p점의 상대거리를 나타낸다. 그림 3의 (a)와 (b)는 그림 2에서 나타난 원의 궤적을 나타내기 위한 θ_1 과 θ_2 의 각도의 변화를 시간의 경과에 따라 나타낸 결과로서 목표궤적이 된다.



<그림 2> Work-space and desired trajectory



(a) Θ_1



(b) Θ_2

<그림 3> Desired trajectory in Joint space

4.2 PD제어기 설계 및 이산화 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.

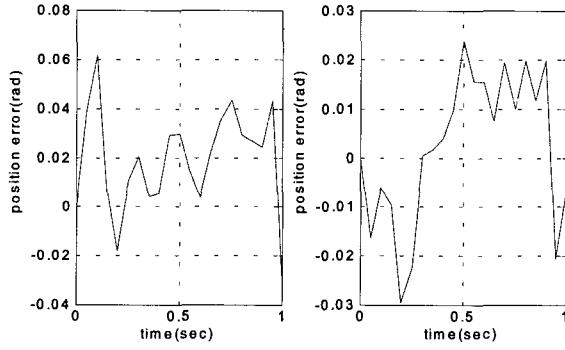
$$\begin{aligned}\tau_1 &= K_{p1}(\theta_1^* - \theta_1) + K_{v1}(\dot{\theta}_1^* - \dot{\theta}_1) + u_1 \\ \tau_2 &= K_{p2}(\theta_2^* - \theta_2) + K_{v2}(\dot{\theta}_2^* - \dot{\theta}_2) + u_2\end{aligned}\quad (14)$$

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

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

이고, 좌반 평면에 위치하여 수렴할 수 있는 안정성을 확보하였다. 이러한 PD제어 결과를 그림 4에 나타내었다. 그림 4에 나타난 결과는 그림 3에서 제시한 매 반복시 주기(1 sec.)의 매시간대

원하는 각 축의 위치궤적(rad.)과 모의실험을 통해 발생한 궤적과의 차이를 나타낸 것이다.



<그림 4> Position error with PD control

식(14)를 선형화하기 위해 $\epsilon\theta_1 = \dot{\theta}_1^* - \dot{\theta}_1$, $\epsilon\theta_2 = \dot{\theta}_2^* - \dot{\theta}_2$ 이라 하고, $\epsilon\theta \equiv 0$ 로 가정하여 $\cos\theta \equiv 1$ 로 근사화하여 선형화 하였다. 식(14)를 식(1)과 조합하면 다음과 같다.

$$\begin{aligned} d_{11}\ddot{\epsilon\theta}_1 + d_{12}\ddot{\epsilon\theta}_2 &= -K_v\epsilon\dot{\theta}_1 - K_p\epsilon\theta_1 + u_1 + w_1 \\ d_{22}\ddot{\epsilon\theta}_2 + d_{21}\ddot{\epsilon\theta}_1 &= -K_v\epsilon\dot{\theta}_2 - K_p\epsilon\theta_2 + u_2 + w_2 \end{aligned} \quad (15)$$

여기서,

$$\begin{aligned} w_1 &= d_{11}\ddot{\theta}_1^* + d_{12}\ddot{\theta}_2^* + g_1(\theta_1^*) \\ w_2 &= d_{21}\ddot{\theta}_1^* + d_{22}\ddot{\theta}_2^* + g_2(\theta_2^*) \end{aligned} \quad (16)$$

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

$$\begin{aligned} \dot{x}(t) &= A_c x(t) + B_c u(t) + w_c(t) \\ y(t) &= Cx(t) \end{aligned} \quad (17)$$

여기서, 각 상태행렬은 참고문헌9의 식(18)과 같다. 그리고, 상태행렬을 이산화하고, 2.2절에서 나타낸 물성치를 대입하여 이산화 상태행렬을 수치적으로 나타내면 다음과 같다.

$$\begin{aligned} A &= \begin{bmatrix} 3.7780e-001 & 2.0620e-002 & 2.7971e-002 & 2.5895e-003 \\ -1.6986e+001 & -9.4034e-002 & 4.3571e-001 & 5.8535e-002 \\ 5.5941e-002 & 2.8093e-003 & 7.4787e-001 & 2.7659e-002 \\ 8.7155e-001 & 8.0151e-002 & -8.0293e+000 & 1.8470e-001 \end{bmatrix} \\ B &= \begin{bmatrix} 1.7283e-004 & -1.5539e-005 \\ 4.7118e-003 & -2.4210e-004 \\ -1.5539e-005 & 1.4000e-004 \\ -2.4210e-004 & 4.4607e-003 \end{bmatrix} \end{aligned} \quad (18)$$

4.3 오차파형전달식 분산학습제어

지금까지의 분산학습제어에서는 각 시스템의 모든 정보행렬인 P_{ii} 의 모든 요소를 학습하여야 한다. 그러나, 모든 시스템을 동시에 학습하고자 할 때 매 시간대를 학습하기 위함으로써 기존 학습제어방식인 식(11) 대신 다음과 같이 매 시간대 별로 제어기를 설계할 수 있다.

$$u_{i,r}(k) = u_{i,r-1}(k) + \delta_r u_i(k)$$

여기서,

$$\delta_r u_i(k) = [E_r(C_i(k+1)B_i(k))]^{-1} \cdot (y_i^*(k+1) - y_{i,r-1}(k+1)) \quad (19)$$

시스템 i 의 요소 $C_i(k+1)B_i(k)$ 의 예측 $E_{r+1}(C_i(k+1)B_i(k))$ 은 다음의 식과 같이 최근의 값을 선택하게 된다.

$$E_{r+1}(C_i(k+1)B_i(k)) = \frac{\delta_r y_i(k+1)}{\delta_r u_i(k)} \quad (20)$$

이때, 학습제어신호를 수렴치로 다가갈 때 비정칙문제(nonsingularity problem)을 피하도록 신경을 써야 한다. 그리고, 매시간대마다 학습을 위하여 반복횟수를 달리 할 수 있다.

선형화된 미분방정식을 이산화하는 과정에서 시스템간의 커플링이 소개되었다. 그러나, 이 효과는 작은 표본시간대에서는 아주 작거나 거의 무시하여도 된다. 그리고, 실제 시스템은 비선형이나, 여기서 모형으로 고려된 미분방정식은 목적궤적 주변에서 선형화되었다. 따라서, 매시간마다 $C_i(k+1)B_i(k)$ 의 예측치가 실제값으로 다가 가도록

하면, 시스템이 목표궤적을 따라가게 된다.

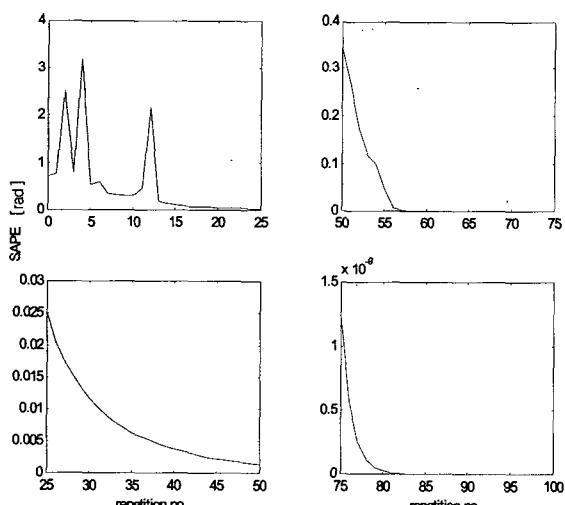
4.4 실험결과

본 절에서는 분산학습제어의 학습방법을 개별 학습으로 실험하였고, 그 결과를 각 경우에 대하여 시간영역의 반응인 error histories와 반복영역에서의 반응으로 나타내었다. 실험 시 샘플링시간은 0.05초로 하였고, 각 시스템 별로 반복횟수 $p=50$ 으로 하였다. 설명 중 시스템 1은 θ_1 을 나타내고 시스템 2는 θ_2 를 나타낸다. 그리고, 반복영역에서 위치오차의 추이를 살펴보기 위해서 매 반복 시 각 시간대 위치오차 절대값의 합(Summation of Absolute Position Error : SAPE)을 다음과 같이 정의하여 매 반복 시 관찰하였다.

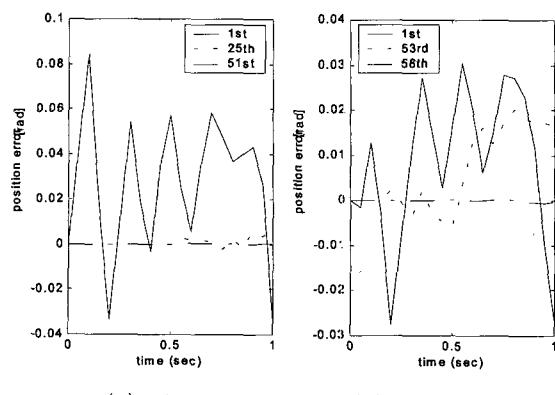
$$SAPE = \sum_{k=1}^p |e_i^j(k)|$$

여기서, $i = \text{number of subsystem}$,
 $j = \text{number of repetition}$ 이다.

또한 추측방법으로 least square algorithm를 사용하였다.



<그림 5> Summation of absolute position error



(a) subsystem1 (b) subsystem2

그림 5에서 SAPE 추이를 살펴보면, 서브시스템 1보다 서브시스템 2에서 수렴 정도가 우수하게 나타나고 있다. 그리고, 그림 6에서는 매 반복 영역에서의 시간영역 반응인 error histories와 반복영역에서의 반응결과를 보면 반복횟수가 증대될수록 error의 크기가 감소하여 0으로 수렴하는 것을 알 수 있다. 실제 산업현장에서는, 그림 5에서 나타나는 매 반복 시 전체 시간영역의 오차스펙트럼인 SAPE의 수렴 현상에 의미를 부여하는 것보다는, 그림 6과 같이 매 시간대마다 학습시킴으로써 실제 위치오차에 있어서 시간대마다 오차를 0으로 잡아 줌으로써 매 시간대의 기계적 오버슈트를 방지할 수 있다. 본 실험에서는 알고리즘의 지수가중치를 조정함으로써 학습속도를 조정할 수 있었다.

5. 결 론

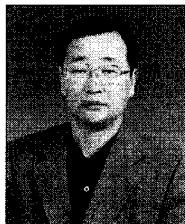
본 논문에서는 대상 시스템의 재료 물성치에 대한 정보를 필요치 않는 간접적응형 분산학습제어법을 매시간별로 수직다물체시스템인 5절링크기구에 적용시켜 보았다. 본 논문의 결과는 기존 수직다물체를 반복학습제어하는 방안으로서 모든 시간대의 입출력을 추정하여 동시에 학습하는 방법에서 나타나는 오버슈트 현상을 개선할 수 있는 방안으로 제시되었다.

매 시간대별로 두 시스템을 동시에 학습시킴으로써 학습에 필요한 연산 경비를 줄일 수 있고, 급격한 오버슈터에 의한 불리적 충돌이나 Jerk 현상을 줄일 수 있으므로 각종 산업용 로봇이나 재

활용 기기와 같은 5절링크기구의 반복정밀도의 향상을 보장할 수 있다. 그리고, 추정방법으로 recursive least squares algorithm의 지수가증치 방법을 사용하였다. 이러한 알고리즘은 쾌적한 동작을 구현하는 의료용 기기와 초정밀 반복 작업을 요하는 산업용 수직다물체시스템의 반복정밀도 향상에 기여 할 수 있음을 알 수 있다.

참 고 문 현

- [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] Chang C.-K., Longman R. W., and Phan M., "Techniques for Improving Transients in Learning Control Systems," Proceedings of the AAS/AIAA Astrodynamics Specialist Conference, Durango, Colorado, August 1991, Advances in the Astronautical Sciences.
- [7] 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.
- [8] Lee, S., "Precision of Iterative Learning Control for the Multiple Dynamic Subsystems," J. of the KSPE, Vol. 18, No. 3, pp.131-142, 2001.
- [9] Lee, S. and Park S., "Research for Improvement of Iterative Precision of the Vertical Multiple Dynamic Subsystem," J. of the KSPE, Vol. 21, No. 5, pp.64-72, 2004.
- [10] Youm Y., "Bio-Robots and Intelligent Prosthetics," J. of the KSPE, Vol. 17, No. 11, pp.36-42, 2000.
- [11] 강철구, 권인소, 윤중선, 정완균 공역, Spong and Vidyasagar 원저, "로봇 동역학과 제어", 희중당, 1994



이 수 철 (Soo Cheol Lee)

- 정회원
- 1984년 2월 : 서울대학원 농공 학과 졸업(농학석사)
- 1993년 10월 : 미국 Columbia 대학원 기계공학과 졸업 (M.Phil./ Ph.D.)
- 2006년 4월 ~ 현재 : 대구대학교 자동차산업기계 공학부 교수
- 관심분야 : 시스템분석기술, 분산학습제어, 공장 자동화