

실시간 2차원 학습 신경망을 이용한 전기·유압 서보시스템의 추적 제어

Tracking Control of a Electro-hydraulic Servo System Using 2-Dimensional Real-Time Iterative Learning Algorithm

곽동훈, 조규승, 정봉호, 이진걸
(Dong-Hoon Kwak, Gyu-Seung Cho, Bong-Ho Jung, and Jin-Kul Lee)

Abstract : This paper addresses that an approximation and tracking control of real-time recurrent neural networks(RTRN) using two-dimensional iterative learning algorithm for an electro-hydraulic servo system. Two dimensional learning rule is driven in the discrete system which consists of nonlinear output function and linear input. In order to control the trajectory of position, two RTRN with the same network architecture were used. Simulation results show that two RTRN using 2-D learning algorithm are able to approximate the plant output and desired trajectory to a very high degree of accuracy respectively and the control algorithm using two identical RTRN was very effective to trajectory tracking of the electro-hydraulic servo system.

Keywords : approximation, real-time recurrent neural network, hydraulic servo system, tracking control

I. 서론

전자계측장치와 마이크로 프로세서의 발달로 전기유압 서보시스템은 빠른 응답성을 요구하는 가진 시스템, 로봇, 비행시뮬레이터에서부터 고출력이 요구되는 크레인과 같은 건설장비에 이르기까지 다양한 분야에서 활용되어지고 있다. 유압의 장점인 고출력과 전기적 신호처리를 결합한 전기·유압 서보시스템은 그 응용범위가 점점 더 확대되어가고 있으나, 유체의 압축성, 제어입력의 포화, 밸브 방향의 절환, 마찰, 누유와 히스테리시스에 의한 불감대 등으로 인한 강한 비선형성을 가지고 있고, 부하변동, 외부온도의 변화와 구성품 마모로 인한 체적탄성계수 변화와 같은 외부환경 요인으로 인해 파라미터 변동이 심한 특징을 가지고 있다. 따라서, 시스템을 모델링하고 정확한 파라미터를 찾는다는 것은 매우 힘든 일이다. 그러므로, 이러한 시스템의 고정도 제어를 위해서는 수학적 모델링 없이 시스템을 식별할 수 있는 알고리즘이 유용하게 활용될 수 있다[1][2]. 또한, 이러한 문제를 극복하기 위해 반복 학습 제어 알고리즘이 S. Arimoto 등에 의해 선형 시변 연속계에 대해 미분제어기 형태의 학습 규칙이 처음 제시된 이후[3] 비례, 비례-미분형태 등의 여러 형태가 제시되었고[4][5], P. Bondi와 J.J. Craig 등은 비선형 시스템의 학습 제어에 대한 해석이 이루어졌다[6][7]. 그러나, 이를 제어 알고리즘들은 대부분 수렴율이 늦고, 계산량이 많아 연산시간이 오래 걸려 실시간을 구현하는데는 많은 어려움이 있어, Kurek 등은 선형 이산 다변수 시스템에 대한 2차원 학습 제어 알고리즘을 제시하고, 수렴성에 대해서 증명하였다[8]. Chow 등은 선형 연속 다변수 시스템에 대한 2차원 학습 제어 알고리즘을

제시하였다[9]. 그러나, 이들 알고리즘 또한 시스템 행렬 CB 의 랭크가 C 의 랭크와 같을 경우에만 성립하므로 실제 시스템에 적용하는데는 어려움이 있다. 또한, Chow 등은 시변 가중치를 가지는 회귀적 신경망을 이용하여 비선형 이산 시간계에 대해 비선형 함수의 인자가 출력과 입력의 함수로 주어진 경우에 대한 2차원 회귀적 신경망 학습 알고리즘과 제어 알고리즘을 제시하고, 간단한 수치 예제의 시뮬레이션을 통해 성능을 증명하였으며[10], 이알고리즘을 연속시간계로 확장하였다[11].

본 논문에서는 비선형함수가 비선형 출력 함수와 선형 입력항으로 분리되어 있는 형태의 이산 시간계에서 2차원 학습 신경망 알고리즘의 학습 규칙을 유도하고, 동일한 구조를 가지는 두개의 신경망을 이용한 제어 알고리즘을 이용하여, 전기·유압서보 시스템의 궤적 추적 제어를 수행하고, 성능을 분석하였다.

II. 전기·유압 서보시스템의 모델링

편로드 유압 실린더는 피스톤의 수압 면적이 다른 비대칭성 때문에 \dot{x}_p 가 양인 경우와 음인 경우로 나누어서 모델링을 수행한다. 그럼 1과 같이 화살표 방향을 양의 방향으로 두고, 실린더의 변위를 x_p , 서보 밸브 스플변위는 x_v 라한다. $\dot{x}_p > 0$ 인 경우에 밸브 스플 변위 x_v 로 인한 작동유의 공급측 유량 $q_1(t)$ 및 귀환측 유량 $q_2(t)$ 는 스플의 오리피스 유량 방정식으로부터 각각 (1)과 같이 나타낼 수 있다.

$$\begin{aligned} q_1(t) &= C_d \omega x_v(t) \sqrt{\frac{2}{\rho} (p_s - p_1(t))} \\ q_2(t) &= C_d \omega x_v(t) \sqrt{\frac{2}{\rho} p_2(t)} \end{aligned} \quad (1)$$

여기서, C_d 는 밸브 스플의 오리피스 유량 계수, w 는 밸브 포트의 단면적 구배, ρ 는 작동유의 밀도, p_s 는 공급

논문접수 : 2002. 9. 14., 채택확정 : 2003. 4. 3.

곽동훈 : 부산대학교 대학원 지능기계공학과(dhkwak@pnu.edu)
조규승 : 부산대학교 대학원 기계설계공학과(meditation@daum.net)
정봉호 : 부산대학교 대학원 지능기계공학과(bigbong@pnu.edu)
이진걸 : 부산대학교 기계공학부(leepjik@pnu.edu)




그림 1. 편로드 전기·유압 서보시스템.

Fig. 1. Single-rod electro-hydraulic servo system.

압력 그리고 $p_1(t)$ 및 $p_2(t)$ 는 각각 유압 실린더 내의 공급측과 귀환측의 압력을 나타낸다. 유압 실린더 좌우 양 실에 연속 방정식을 각각 적용하면 실린더의 공급측 유량 $q_1(t)$ 와 귀환측 유량 $q_2(t)$ 는 (2)와 같이 쓸 수 있다.

$$\begin{aligned} q_1(t) &= C_{ip}(p_1(t) - p_2(t)) + C_{ep}p_1(t) \\ &\quad + \frac{dV_1(t)}{dt} + \frac{V_1(t)}{K_m} \frac{dp_1(t)}{dt} \\ q_2(t) &= C_{ip}(p_1(t) - p_2(t)) - C_{ep}p_2(t) \\ &\quad - \frac{dV_2(t)}{dt} - \frac{V_2(t)}{K_m} \frac{dp_2(t)}{dt} \end{aligned} \quad (2)$$

여기서, C_{ip} 및 C_{ep} 는 각각 내부, 외부 누설 계수이고, K_m 은 작동유의 체적 탄성 계수이며, $V_1(t)$, $V_2(t)$ 는 공급측과 귀환측의 체적을 나타내고 (3)과 같다.

$$V_1(t) = V_{10} + A_1 x_p(t)$$

$$V_2(t) = V_{20} - A_2 x_p(t)$$

실린더 좌우 양실의 유량비 η 를 (4)와 같이 정의하고(4) 누설과 용적효율에 의한 유량은 피스톤 운동에 의한 유량 보다 매우 적다고 가정하고, (3)을 이용하면 (4)와 같이 실린더 단면적의 비로 나타내어진다.

$$\eta = \frac{q_2(t)}{q_1(t)} = \frac{\sqrt{p_2(t)}}{\sqrt{p_s - p_1(t)}} = -\frac{V_2}{V_1} = \frac{A_2}{A_1} \quad (4)$$

부하 압력 $p_L(t)$ 과 부하유량 $q_L(t)$ 를 각각 (5)와 (6)과 같이 정의한다.

$$p_L(t) = p_1(t) - p_2(t) \quad (5)$$

$$q_L(t) = \frac{q_1(t) + q_2(t)}{2} \quad (6)$$

(1)과 (5)를 (6)에 대입하고 정리하면 (7)과 같다.

$$q_L(t) = \alpha C_d w x_v(t) \sqrt{\frac{1}{\rho} (p_s - p_L(t))} \quad (7)$$

여기서,

$$\alpha = \frac{1 + \eta}{\sqrt{2(1 + \eta^2)}}$$

$x_p < 0$ 인 경우에도 유사하게 부하유량 q_L 이 얻어지고, 두 개의 관계를 하나의 식으로 표현하면 편로드 유압 실린

$$q_L(t) = \alpha C_d w x_v(t) \sqrt{\frac{1}{\rho} (p_s - \frac{\dot{x}_p}{|\dot{x}_p|} p_L(t))} \quad (8)$$

더를 갖는 서보 밸브의 부하 유량식은 (8)과 같다. 부하 유량 방정식(8)을 Taylor 급수 전개하고 1차항만 고려하면 (9)와 같이 나타낼 수 있다.

$$q_L(t) = k_q x_v(t) - k_p p_L(t) \quad (9)$$

여기서 k_q 는 유량 계수 [$\text{cm}^3/\text{s}/\text{cm}$], k_p 는 유량압력 계수 [$\text{cm}^5/\text{kg}/\text{s}$]로 각각 (10), (11)과 같다.

$$k_q = \frac{\partial q_L}{\partial x_v} = \alpha C_d w \sqrt{\frac{1}{\rho} (p_s - \frac{\dot{x}_p}{|\dot{x}_p|} p_L)} \quad (10)$$

$$k_p = - \frac{\partial q_L}{\partial p_L} = - \frac{\alpha C_d w x_v \sqrt{\frac{1}{\rho}}}{2 \sqrt{p_s - p_L}} \quad (11)$$

유압 실린더의 최대 행정을 L_{\max} , 유압 실린더의 최대 용적을 V_{\max} 라고 하면 (12)와 같이 표현할 수 있다.

$$\begin{aligned} V_{\max} &= L_{\max} A_1 \\ V_2(t) &= (V_{\max} - V_1(t)) \eta \end{aligned} \quad (12)$$

편로드 유압 실린더의 부하 유량식을 얻기 위해서 (1)을 (6)에 대입하고, (12)를 이용하면 (13)과 같이 나타낼 수 있다.

$$q_L(t) = A_{me} \frac{dx_p(t)}{dt} + C_t p_L(t) + \frac{V_e}{4K_m} \frac{dp_L(t)}{dt} \quad (13)$$

여기서, C_t 는 피스톤 전체 누유 계수, A_{me} 는 평균 피스톤 단면적, V_e 는 유압 실린더의 등가용적으로 다음과 같이 정의된다.

$$C_t = (C_{ip} + \frac{C_{ep}}{2})$$

$$A_{me} = \frac{A_1 + A_2}{2} = \frac{(1 + \eta) A_1}{2}$$

$$V_e(t) = \frac{2 V_{\max} \left\{ \eta^3 + \frac{V_1(t)}{V_{\max}} (1 - \eta^3) \right\}}{1 + \eta^2}$$

비대칭 유압 실린더의 부하유량은 x_p 의 방향과는 관계가 없음을 알 수 있다.

편로드 유압 실린더의 운동 방정식은 (14)와 같다.

$$\begin{aligned} p_L A_{me} &= \\ M \ddot{x}_p(t) + B \dot{x}_p(t) + K(x_p(t) + K_n x_p(t)^3) + F_d & \end{aligned} \quad (14)$$

여기서, M 는 관성 질량 부하, B 는 점성 부하, K 는 탄성 부하, K_n 은 비선형 탄성 계수, 그리고 F_d 는 부하 또는 쿠롱 마찰 등에 의한 외부 외란이다.

$K_d = C_t + k_p$, 스플의 변위 $x_v = K_v u(t)$ 라 둔다. 이 때 K_v 는 서보증폭기의 계인이고, $u(t)$ 는 제어기로부터

나온 제어입력 이다. (9), (13), (14)와 상태변수 $[x_1(t) x_2(t) x_3(t)]$ 를 $[x(t) \dot{x}(t) \ddot{x}(t)]$ 와 같이 정의하고, 상태 방정식의 형태로 정리하면 (15)와 같다.

$$\begin{aligned}\dot{x}_1(t) &= x_2(t) \\ \dot{x}_2(t) &= x_3(t) \\ \dot{x}_3(t) &= -\sum_i^3 a_i x_i(t) + b(x) u(t) - N(x, t) - d(t)\end{aligned}\quad (15)$$

여기서,

$$\begin{aligned}a_1 &= \frac{4K_m K_h K}{MV_e} \\ a_2 &= \frac{4K_m K_h B}{MV_e} + \frac{4K_m A_{me}^2}{MV_e} + \frac{K}{M} \\ a_3 &= \frac{4K_m K_h}{V_e} + \frac{B}{M} \\ b(x) &= \frac{4K_m A_{me}}{MV_e} k_q K_v \\ N(x, t) &= \frac{3KK_n}{M} x_1^2 x_2 + \frac{4K_m K_h}{MV_e} KK_n x_1^3 \\ d(t) &= \frac{4K_m K_h}{MV_e} F_d + \frac{1}{M} F_d\end{aligned}$$

$N(x, t)$ 는 비선형항을 나타내고 있다.

III. 실시간 2차원 학습 신경망과 제어 알고리즘

1. 실시간 2차원 학습 신경망

실시간 회귀적 신경망(real time recurrent neural network)은 미지의 동특성을 가진 비선형 시스템에 대한 실시간 학습제어 신경망으로 사용되고 있다. 그림 2는




그림 2. 실시간 회귀적 신경망 구조.

Fig. 2. The architecture graph of a real time recurrent neural network.

실시간 회귀적 신경망의 구조를 나타내고 있다. 회귀적 신경망은 N 개의 출력 뉴런과 입력으로서 N 개의 앞선 시간 피드백 출력 신호와 M 개의 외부 입력 신호가 서로 연결되어 있는 구조를 가지고 있다. 실시간 학습과정은 특정 시간에 원하는 값에 어떤 특정 뉴런의 출력을 일치시키는 것이다. 그러므로, 시간 t 에서 뉴런 j 의 원하는 응답을

$d_j(t)$ 라 두고, 뉴런 j 의 출력을 $y_j(t)$ 라 하면 오차 $e_j(t)$ 는 (16)과 같이 정의할 수 있다.

$$e_j(t) = d_j(t) - y_j(t) \quad (16)$$

일반적인 미지의 비선형 이산시간 시스템의 동특성은 (17)과 같이 나타내어지고, 실시간 회귀적 신경망의 상태공간 비선형 동특성은 (18)과 같이 표현할 수 있다.

$$y_p(t+1) = g_p(y_p(t), u(t)) \quad (17)$$

$$y(t+1) = f[W_1(t)y(t) + W_2(t)u(t)] \quad (18)$$

여기서, 함수 g_p 는 미지이나 해석적이고, 치역은 $(-1, 1)^n$ 으로 가정하고, $y(t) \in \mathbf{R}^N$, $u(t) \in \mathbf{R}^M$, 가중치 $W_1 \in \mathbf{R}^{N \times N}$, $W_2 \in \mathbf{R}^{N \times M}$ 이다. 함수 $f(\cdot)$ 는 비선형 함수이다.

(18)에서의 비선형 함수의 형태로 주로 많이 사용되는 것으로 다음의 3가지 형태가 있다.

- 1) $f[W_1(t)y(t) + W_2(t)u(t)] = W_1\sigma(y(t)) + W_2u(t)$
- 2) $f[W_1(t)y(t) + W_2(t)u(t)] = \sigma(W_1y(t) + W_2u(t))$
- 3) $f[W_1(t)y(t) + W_2(t)u(t)] = \sigma(W_1y(t)) + W_2u(t)$

여기서, $\sigma(\cdot)$ 는 비선형 활성화 함수이다.

(18)과 같이 기술되는 실시간 회귀적 신경망 알고리즘은 (19)와 같이 신경망 출력이 원하는 응답을 원하는 허용오차 내에서 추종하도록 가중치 $W_1(t)$ 와 $W_2(t)$ 를 계속적으로 갱신하는 것이다.

$$|e_j(t)| < \epsilon \quad \text{for } i=1, 2, \dots, n; t=1, 2, \dots \quad (19)$$

2차원 학습 알고리즘은[10][11] 시변 가중치를 가지는 회귀적 신경망에 대한 새로운 실시간 반복 학습 알고리즘이다. 즉, 실시간 회귀적 신경망은 시간 변수 t 에 의해서만 기술되는 반면, 2차원 실시간 회귀적 신경망 알고리즘은 시간 t 에 의한 동적인 과정과 반복 학습을 반영할 변수 k 에 의해 표현되므로, 학습과정 동안 실시간 신경망의 각 변수는 두 개의 독립변수인 이산화된 시간 t 와 반복학습 회수인 k 에 종속되어진다. 알고리즘의 수행과정은 매 시간 t 에서 k 번의 반복학습을 통해 적절한 가중치를 얻음으로써 신경망 출력이 원하는 출력을 근사 시킬 수 있도록 하는 것이다. 그러므로 실시간 신경망을 앞서 기술한 1번 형태의 비선형식을 이용하여 2차원으로 표현하면 (20)과 같이 쓸 수 있다.

$$y(t+1, k) = W_1(t, k)f[y(t, k)] + W_2(t, k)u(t) \quad (20)$$

이때 원하는 출력 $y_d(t)$ 와 신경망 뉴런의 출력 $y(t, k)$ 사이의 학습오차는 (21)과 같이 나타낼 수 있다.

$$e(t, k) = y_d(t) - y(t, k) \quad (21)$$

여기서, $y_d(t)$ 는 원하는 응답으로써 반복회수 k 와는 독립적이며, 시간 t 에서 신경망 입력 $u(t, k)$ 도 k 에 대해 독립적이므로 $u(t)$ 로 나타낼 수 있다.

(20)의 오차를 줄이기 위한 가중치의 학습과정은 (22)와 같이 주어진다.

$$W(t, k+1) = W(t, k) + \Delta W(t, k) \quad (22)$$

여기서, $W(t, k) = [W_1(t, k) \mid W_2(t, k)]$ 이다.

이때 경계조건으로서 출력 $y(0)$ 은 (23)과 같이 0이 아닌 동일한 초기상태를 가지고 시작한다.

$$y(0, k) = y(0) \neq 0, \text{ for } k=0, 1, 2, \dots \quad (23)$$

또한, 초기 가중치는 매시간마다 균일 분포 난수(uniform distribution random)를 이용하여 초기화한다.

가중치를 학습시키기 위한 2차원 학습 규칙은 다음과 같이 구할 수 있다.

(20)과 (22)로부터 오차에 대해 정리하면 (24)와 같다.

$$\begin{aligned} e(t, k+1) - e(t, k) &= -\eta(t+1, k) \\ &= -[y(t, k+1) - y(t, k)] \\ &\quad - [W_1(t-1, k+1)\sigma[y(t-1, k+1)] \\ &\quad - W_1(t-1, k)\sigma[y(t-1, k)] \\ &\quad + W_2(t-1, k+1)u(t-1)] \\ &\quad - W_2(t-1, k)u(t-1)] \\ &= [W_1(t-1, k+1) - W_1(t-1, k)]\sigma[y(t-1, k+1)] \\ &\quad + W_1(t-1, k)[\sigma[y(t-1, k+1)] - \sigma[y(t-1, k)]] \quad (24) \\ &\quad + [W_2(t-1, k+1) - W_2(t-1, k)]u(t-1) \\ &= \Delta W_1(t-1, k)\sigma[y(t-1, k+1)] \\ &\quad + \Delta W_2(t-1, k)u(t-1) \\ &\quad + W_1(t-1, k)[\sigma[y(t-1, k+1)] - \sigma[y(t-1, k)]] \end{aligned}$$

미분의 평균값 정리에 의해서 (25)의 관계가 성립한다.

$$\begin{aligned} \sigma[y(t-1, k+1)] - \sigma[y(t-1, k)] \\ = \sigma'(\xi)[y(t-1, k+1) - y(t-1, k)] \quad (25) \end{aligned}$$

단, $y(t-1, k) < \xi < y(t-1, k+1)$ 이다. 반복법을 사용할 경우 $\xi = y(t-1, k)$ 로 둘 수 있고, 따라서 (24)를 정리하면 (26)과 같다.

$$\begin{aligned} e(t, k+1) - e(t, k) \\ = \Delta W_1(t-1, k)\sigma[y(t-1, k+1)] \\ + \Delta W_2(t-1, k)u(t-1) \\ + W_1(t-1, k)\sigma'(y(t-1, k)) \\ \cdot [y(t-1, k+1) - y(t-1, k)] \quad (26) \end{aligned}$$

편의상 (26)식을 행렬 A 와 벡터 x, b 로 (27)과 같이 나타낼 수 있다.

$$\begin{aligned} A &= [\Delta W_1(t-1, k) \mid \Delta W_2(t-1, k)] \\ x &= \left[\begin{array}{c} \sigma[y(t-1, k+1)] \\ u(t-1) \end{array} \right] \quad (27) \\ b &= e(t, k+1) - e(t, k) + W_1(t-1, k) \\ &\quad \cdot [\sigma(y(t-1, k)) \cdot [y(t-1, k+1) - y(t-1, k)]] \end{aligned}$$

여기서, $A \in \mathbf{R}^{n \times (n+m)}$, $x \in \mathbf{R}^{n+m}$, $b \in \mathbf{R}^n$ 이다. 따라서 (26)식의 방정식은 (28)과 같이 나타낼 수 있다.

$$Ax = b \quad (28)$$

(28)을 만족하는 행렬 A 는 무한히 많으므로 간단한 형태로 표현되는 한개의 경우를 (29)와 같이 나타낼 수 있다.

$$A = b(x^T x)^{-1} x^T \quad (29)$$

(29)식을 (28)에 대입하면 (30)식과 같아 된다.

$$Ax = b(x^T x)^{-1} x^T x = b \quad (30)$$

이상의 관계를 이용하면 학습 규칙은 (31)과 같이 나타낼 수 있다.

$$\Delta W(t, k) = [e(t+1, k) - W_1(t, k)\sigma'(y(t, k))\eta(t+1, k)] \\ \cdot [x(t, k+1)^T x(t, k+1)]^{-1} x(t, k+1)^T \quad (31)$$

여기서, $x(t, k+1) = \begin{pmatrix} y(t, k+1) \\ u(t) \end{pmatrix}$ 이다.

2. 실시간 2차원 학습 신경망 제어 알고리즘

2차원 학습 신경망 제어 알고리즘의 기본 개념은 2개의 똑같은 구조를 가지는 실시간 회귀적 신경망을 이용하여, 하나는 플랜트의 응답을 추종하고, 다른 하나는 원하는 응답을 추종하도록 하여, 두 개의 신경망의 출력이 같게되도록 제어입력을 반복 학습 시켜 매 순간마다 결정되어지도록 하는 것이다.

제어 알고리즘은 다음과 같다.

1) 플랜트의 응답을 추종할 실시간 2차원 학습 회귀적 신경망을 구성한다. 이때 RTRN 모델은 다음과 같다.

$$y(t+1, k) = W_1(t, k)f[y(t, k)] + W_2(t, k)u(t)$$

2) 똑 같은 구조의 신경망을 이용하여 원하는 궤적을 추종하는 신경망을 구성한다.

$$y_d(t+1, k) = W_1^*(t, k)f[y_d(t, k)] + W_2^*(t, k)u(t)$$

3) 두 개의 신경망이 각각의 플랜트의 출력값과 원하는 궤적의 출력값을 허용오차 ϵ_1 이하가 되도록 반복 학습시킨 후 이 두 신경망의 출력값이 서로 같게 만들도록 제어입력 $u(t)$ 를 다음과 같이 결정한다.

$$u(t) = W_2(t, k)^{-1}[y_d(t+1, k) - W_1(t, k)\sigma(y(t, k))]$$

여기서, $W_2(t, k)^{-1}$ 은 의사역행렬(pseudo inverse)이다.

제어입력 $u(t)$ 는 플랜트의 출력과 원하는 궤적의 출력값이 어떤 허용오차 범위 ϵ 내에 들어갈 때까지 반복 학습을 수행하여 결정되어 진다. 그럼 3은 반복 학습 제어 알고리즘의 흐름도를 나타내고 있다.

IV. 시뮬레이션 및 고찰

본 논문에서는 원하는 궤적과 전기·유압 서보시스템의 출력을 추종하도록 2개의 실시간 2차원 학습 회귀적 신경망을 구현하고, 두 개의 신경망에 같은 입력을 주고 두 개의 출력이 같게되는 제어입력을 학습시키도록 하였다. 회귀

적 신경망의 구조는 실시간 적용시 유리하도록 입력 뉴런의 수는 2개로 각각 피드백되는 한 스텝 앞선 변위 출력과 제어입력이며, 출력 뉴런으로 현재의 변위 출력을 가지며 히든 뉴런이 없는 가장 단순한 구조로 선정하였다. 이때 사용된 비선형 활성화 함수 $f(x)$ 는 $\tanh(x)$ 이다. 원하는 출력 궤적은 다음과 같이 정현파 함수를 사용하였고, 이때 주기 f 는 0.1Hz로 하였다.




그림 3. 2개의 RTRN을 이용한 제어 알고리즘 흐름도.

Fig. 3. A Flowchart of control algorithm using two same RTRN's.

$$d(t) = 0.05 \times \sin((2.0\pi t f) + (\pi/4.0)) + 0.3$$

초기값은 $y(0) = d(0) = 0.34$ 로 가정하였다. 또한, 2차원 학습은 매시간 스텝마다 초기 가중치를 균일 분포 난수를 이용하여 0.5에서 1사이의 값으로 초기화하였다. 학습 알고리즘은 이산 시간에 대하여 유도되어 있기 때문에 플랜트의 거동은 연속시간계로 시뮬레이션 하기 위해 4계 Runge Kutta 방법을 사용하였고, 샘플링 주기는 0.001초로 하였으며, 신경망 학습 알고리즘의 추종과 제어는 0.01초마다 실행되도록 하였다. 시뮬레이션에 사용된 파라미터 값들은 표 1과 같다.

오리피스 유량식에 의한 비선형성과 비선형 스프링에 의한 비선형성이 포함된 전기·유압 서보시스템의 추적 제어 성능을 확인하기 위하여 유체의 오리피스식에 의한 영향을 시변 파라미터로 고려하고, 스프링의 비선형 항을 선형계수

표 1. 전기·유압 서보 시스템의 파라미터 값


Table 1. The values of the electro-hydraulic servo system parameters.

파라미터	값	단위
P_s	6.867×10^6	N/m ²
K_m	7.0×10^8	N/m ²
V_e	3.6×10^{-4}	m ³
K_{lt}	3.0×10^{13}	m ⁴ s/kg
A_{me}	1.3×10^{-3}	m ²
M	5.0	kg
B	60.0	kg/s
K	3.0	kg/s ²
K_n	5.0	
K_v	0.0017	m/V
k_q	$3.1 \times 10^{-5} \sqrt{p_s - p_L sgn(x_v)}$	m ² /s

$K=3.0$ 보다 큰 $K_n=5.0$ 을 적용하여 비선형성이 포함되도록 하여 시뮬레이션을 수행하였다.

그림 4는 실시간 회귀적 신경망의 출력이 원하는 궤적 $d(t)$ 를 추종한 결과이고, 그림 5는 전기·유압 서보시스템의 변위를 추종한 결과이다. 이때 반복 학습을 3회 수행하였다. 두 경우 모두 최대 오차가 1.8초 근방에서 약 0.005m 와 0.008m가 발생하였고, 대부분의 경우에는 거의 오차 없이 잘 추종하고 있음을 보여주고 있다.

그림 6은 실시간 2차원 학습 신경망 제어 알고리즘을 적용하였을 때의 결과이다. (a)는 원하는 궤적과 전기·유압 서보시스템의 출력을 나타내고 있고, (b)는 그때의 오차, (c)는 제어입력을 나타내고 있다. III.2절에서 기술한 제어 알고리즘은 허용오차 범위 내에 들어 간 경우에 다음 단계로 넘어가게 되어있으나, 실시간 연산을 하여 제어를 해야 할 경우에는 주어진 시간 안에 허용 오차 범위 내의 연산이 이루어지지 않을 수도 있기 때문에, 각각의 원하는 궤적과 플랜트의 출력을 추종하는데는 3번의 반복 학습을 수행하고, 제어 입력 $u(t)$ 는 30번의 정해진 회수만큼 반복

그림 4. 원하는 궤적 $d(t)$ 의 추종 결과(반복회수 3회).Fig. 4. Approximation of desired output $d(t)$ with 3 iteration.




그림 5. 전기·유압 서보시스템의 출력 $\bar{y}(t)$ 의 추종 결과(반복회수 3회).

Fig. 5. Approximation of output $\bar{y}(t)$ of electro-hydraulic system with 3 iteration.




그림 6. 2차원 학습 제어 알고리즘 케적 추종 결과(반복학습 30회).

Fig. 6. Simulation results using control algorithm with two same RTRN's with 30 iteration.

학습을 시켰다. 그림 6에서 보는 바와 같이 오차는 최대 약 0.008m 정도가 발생하였으나, 원하는 케적을 잘 추종하고 있음을 볼 수 있다.

그림 7은 전기·유압 서보시스템의 원하는 케적과 출력을 반복 학습회수를 4회로 하였을 때의 추종 오차를 나타내고 있다. 최대 오차는 약 0.00003으로 반복학습을 1회 증가로 약 10배 이상 감소함을 볼 수 있다. 이것은 4번의 반복 학습만으로 비선형성이 강한 시스템에 대해서도 탁월한 추종 성능을 보임을 알 수 있다.

그림 8은 제어입력을 40회 반복 학습을 시킨 경우의 추종 결과를 나타내고 있다. 오차는 최대 0.0043[m] 정도로 30회 반복하였을 경우보다 약 2배의 정도가 향상되었음을 볼 수 있다.




그림 7. 전기·유압 서보시스템의 원하는 케적과 출력 추종 오차(반복 회수 : 4회).

Fig. 7. Simulation results using control algorithm with two same RTRN's with 4 iteration.




그림 8. 2차원 학습 제어 알고리즘 케적 추종 결과(반복학습 40회).

Fig. 8. Simulation results using control algorithm with two same RTRN's with 40 iteration.

이것은 실시간 연산에 문제가 되지 않을 경우에 반복 회수를 많이 늘일수록 더 나은 정도의 케적 추적이 가능하다는 것을 의미한다.

V. 결론

본 논문에서는 실시간 2차원 학습 알고리즘의 비선형함수가 비선형 출력 함수와 선형 입력항으로 분리되어 있는 형태의 이산 시간계에서의 2차원 학습 신경망 알고리즘의 학습 규칙을 유도하고, 이 학습 규칙을 이용하여 비선형성이 강한 스프링을 포함하고 있는 전기·유압 서보시스템의 케적 추적을 수행한 결과 단 4번의 반복 학습을 통해서 10^{-5} 정도의 오차 범위 내에서 추종이 가능하였다. 또한, 동일한 구조를 가지는 두개의 2차원 학습 신경망을 이용한 제어 알고리즘을 이용하여 비선형 전기·유압 서보시스템의 케적 추적 제어를 수행한 결과, 제어가 가능한 정확도를 가지는 출력의 추종은 3회의 반복 학습을 통해서 추종이 가능하였고, 제어 입력의 학습은 30회의 반복 학습에 의해 원하는 케적의 추종이 이루어졌으며, 반복회수를 늘일수록 더

좋은 정도의 추적제어가 가능함을 보여줌으로써 오피스에 의한 제곱근과 비선형 스프링에 의한 비선형성이 포함된 전기·유압 서보시스템의 궤적 추적제어에 타월한 성능을 가지고 있음을 알 수 있다.

향후 연구과제로는 본 연구에서 구현한 제어 알고리즘을 실제 플랜트에 적용하여 실험을 통해 타당성을 확인하고, 다중입·출력 시스템으로 확장에 대한 연구가 필요할 것으로 생각된다.

참고문헌

- [1] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamic systems using neural networks," *IEEE Trans. Neural Networks*, vol. 1, no. 1, pp. 4-27, 1990.
- [2] 곽동훈, 이춘태, 정봉호, 이진걸, "신경망-유전자 알고리즘을 이용한 전기·유압 서보시스템의 파라미터 식별," *한국정밀공학회 논문지*, 제19권, 제11호, pp. 76-83, 11, 2002.
- [3] S. Arimoto, S. Kawamura, and F. Miyazaki, "Bettering operation of robots by learning," *J. Robot Syst.*, vol. 1, pp. 123-140, 1984.
- [4] S. Kawamura, F. Miyazaki, and S. Arimoto, "Application of learning method for dynamic control of robot manipulators," in *Proc. 24th Conf. Decision Contr.*, Fort Lauderdale, FL, pp. 1381-1386, 1985.
- [5] T. Mita and E. Kato, "Iterative control of robot manipulator," in *Proc. 15th ISIR*, Tokyo, Japan, pp. 665-672, 1984.
- [6] P. Bondi, G. Casalino, and L. Gambardella, "On the iterative learning control theory for robotic manipulators," *IEEE J. Robot. Automat.*, vol. 4, pp. 14-22, 1988.
- [7] J. J. Craig, "Adaptive control of manipulators through repeated trials," in *Proc. Amer. Cont. Conf.*, San Diego, CA, pp. 1566-1573, 1984.
- [8] J. E. Kurek and M. B. Zaremba, "Iterative learning control synthesis based on 2-D system theory," *IEEE Trans. Automat. Contr.*, vol. 38, pp. 121-125, 1993.
- [9] T.W.S. Chow and Y. Fang, "An iterative learning control method for continuous-time system based on 2-D system theory," *IEEE Trans. Circuits Syst. I*, vol. 45, pp. 683-689, 1998.
- [10] T.W.S. Chow and Y. Fang, "A recurrent neural network based real-time learning control strategy applying to nonlinear systems with unknown dynamics," *IEEE Trans. Ind. Electronics*, vol. 45, no. 1, pp. 151-161, 1998.
- [11] T.W.S. Chow, X.D. Li and Y. Fang, "A real-time learning control approach for nonlinear continuous-time system using recurrent neural networks," *IEEE Trans. Ind. Electronics*, vol. 47, no. 2, 2000.

곽동훈

1966년 9월 21일생. 1989년 부산대학교 기계설계공학과 졸업. 동대학원 석사(1992). 동대학원 박사수료(2001). 1992년~1999년 국방과학연구소 연구원. 2001~현재 부산대학교 기계기술 연구소 전임연구원. 관심분야는 신경망을 이용한 시스템 식별 및 제어,



조규승

1968년 3월 19일생. 1992년 부산대학교 정밀기계공학과 졸업. 동대학원 석사(1996). 동대학 박사 수료(2000). 1996년~1998 현대중공업. 관심분야는 소음/진동, 비선형제어.



정봉호

1973년 9월 4일생. 2000년 경희대학교 기계공학과 졸업. 부산대학교 대학원 석사(2002), 동대학 박사과정(현재). 관심분야는 신경망과 진화 알고리즘을 이용한 시스템 식별 및 제어, 고장 진단 및 허용.



이진걸

제어·자동화·시스템공학 논문지 제 9 권 제 2 호 참조.