

2차원 반복 학습 신경망을 이용한 전기·유압 서보시스템의 제어 Control of an Electro-hydraulic Servosystem Using Neural Network with 2-Dimensional Iterative Learning Rule

곽동훈 · 이진걸

D. H. Kwak and J. K. Lee

Key Words : Approximation(근사), Recurrent Neural Network(회귀적 신경망), Electro-hydraulic Servo System(전기·유압 서보시스템), Tracking Control(추적제어)

Abstract: This paper addresses an approximation and tracking control of recurrent neural networks(RNN) using two-dimensional iterative learning algorithm for an electro-hydraulic servo system. And 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 RNN's with the same network architecture were used. Simulation results show that two RNN's 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 same RNN was very effective to control trajectory tracking of electro-hydraulic servo system.

1. 서 론

전기·유압 서보시스템은 높은 중량대 출력비와 빠른 응답성, 다양한 동작이 가능하다는 장점으로 인해 고속의 응답성을 요구하는 가진 시스템(exciter)에서부터 고출력이 요구되는 굴삭기, 크레인과 같은 대형 건설중장비에 이르기까지 다양한 산업분야에서 활용되고 있으며, 매우 중요한 역할을 담당하고 있다.

현대 기술이 발전하면서 점점 더 높은 정확도와 빠른 응답성과 같은 시스템 요구 사양들이 높아지고 있으며, 다양하고 복합적인 임무가 요구되어지고 있고, 이것은 시스템을 고정도, 대형화, 복합화 되게 만들고 있다. 그럴지라도 물리적 법칙에 의하여 시스템을 수학적으로 정확하게 모델링할 수 있고, 이를 시스템의 파라미터 값들을 정확하게 구해낼 수 있다면 모델에 기초한 여러 제어 이론들에 의해 시스템의 성능을 향상시킬 수 있는 시스템의 해석과 고정도의 제어가 가능하다. 그러나 이를 대부분의 이론들이 선형이론에 바탕을 두고 있어 모든 작동 범위에서 사용하기 어렵다는 단점을 가지고 있다¹⁾.

전기·유압 서보시스템은 비선형성과 파라미터 불확실성, 즉, 유체의 압축성, 제어입력의 포화, 밸브 방향의 전환, 마찰, 누유와 히스테리시스에 의한 불감대 등으로 인한 강한 비선형성과 부하 변동, 외부온도의 변화, 구성품 마모와 공기의 흡입으로 인한 체적탄성계수 변화와 같은 외부 환경 요인으로 인해 파라미터 변동이 심하기 때문에 시스템의 정확한 모델링과 파라미터를 구하는 것이 힘들고, 이러한 요인은 시스템의 해석과 제어를 어렵게 만들어 고정도의 제어를 실현하는데 있어 제한 요소로 작용하고 있다²⁾. 즉, 비선형 시스템으로 해석하고 제어하기 위해서는 그 시스템의 특성에 맞게 시스템의 해석과 제어가 적용되어야 하지만, 비선형성이 강하고, 파라미터 불확실성이 많은 유압 시스템의 경우에는 시스템을 모델링하고 정확한 파라미터를 찾는다는 것은 매우 어려운 일이다. 그러므로 이러한 시스템의 고정도 제어를 위해서는 수학적 모델링 없이 시스템을 식별하고 제어할 수 있는 제어 알고리즘이 요구되고, 이러한 목적에 부합되는 것들 중의 하나가 신경망 제어이론이라 할 수 있다.

강한 비선형성과 파라미터 불확실성을 가지고 있는 전기·유압 서보시스템을 근사하고 제어하기 위해서는 물리적 법칙에 의한 모델링이 필요 없는 수학적 모델식을 입·출력 데이터에 의해 시스템을 근사

접수일 : 2003년 1월 16일

곽동훈(책임저자): 부산대학교 대학원 지능기계공학과
E-mail : dhkwak@pusan.ac.kr, Tel : 051-510-1449
이진걸 : 부산대학교 기계공학학부

하도록 학습을 시킨 후 가중치, 즉, 파라미터를 구하여 고정도 제어를 실현할 수 있는 신경망 제어 이론의 적용이 요구되어진다. 그러나 신경망을 이용한 추정 및 제어에 대한 이전의 대부분의 연구에서는 주로 학습 규칙으로 경사 구배 하강법(Gradient descent method)을 적용하였는데 이들 대부분은 수렴속도가 늦고 연산 시간이 많이 걸려 실시간으로 시스템을 제어하는 것이 어렵다는 단점을 가지고 있다. 그러므로 강한 비선형성과 파라미터 불확실성을 가지고 있는 비선형 시스템에 대해서 물리적 법칙에 의하지 않고 수학적 모델링에 의해 실시간 제어가 가능한 신경망에 대한 연구의 필요성이 제기되고 있다.

본 연구에서는 고정도, 대형화, 복합화 되어가고 있는 비선형 시스템들에 대해서 물리적 법칙에 의한 모델링을 수행하지 않고, 온라인으로 고정도의 근사 및 제어를 할 수 있는 2차원 학습 회귀적 신경망³⁻⁴⁾과 학습 규칙을 제시하고자 하였다. 또한 강한 비선형성과 파라미터 불확실성을 가지고 있는 것으로 알려져 있는 전기·유압 서보시스템에 대해서 2차원 학습 신경망을 적용하고 온라인 근사 및 제어 가능성을 제시하고자 하였다.

2. 2차원 학습 회귀적 신경망

2.1 회귀적 신경망

회귀적 신경망(recurrent neural network)은 미지의 동특성을 가진 비선형 시스템에 대한 온라인 학습제어 신경망으로 사용되고 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. 온라인 학습과정은 특정시간에 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 식 (1)과 같이 정의할 수 있다.

$$e_j(t) = d_j(t) - y_j(t) \quad (1)$$

일반적인 미지의 비선형 이산시간 시스템의 동특성은 식 (2)와 같이 나타내어지고, 온라인 회귀적 신경망의 상태공간 비선형 동특성은 식 (3)과 같이 표현할 수 있다.

$$y_p(t+1) = g_p(y_p(t), u(t)) \quad (2)$$

$$y(t+1) = f[W_1(t)y(t) + W_2(t)u(t)] \quad (3)$$

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.

식 (3)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.

식 (3)과 같이 기술되는 온라인 회귀적 신경망 알고리즘은 신경망 출력이 원하는 응답을 허용오차 범위 내에서 근사하도록 가중치 $W_1(t)$ 와 $W_2(t)$ 를 계속적으로 갱신하는 것이다.

2차원 학습 알고리즘은 시변 가중치를 가지는 회귀적 신경망에 대한 새로운 온라인 반복 학습 알고리즘이다. 즉, 회귀적 신경망은 시간 변수 t 에 의해 서만 기술되는 반면, 2차원 온라인 회귀적 신경망 알고리즘은 시간 t 에 의한 동적인 과정과 반복 학습을 반영할 변수 k 에 의해 표현되므로, 학습과정 동안 온라인 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 온라인 신경망을 위의 1)번 형태의 비선형식을 이용하여 2차원으로 표현하면 식 (4)와 같이 쓸 수 있다.

$$y(t+1, k) = W_1(t, k)\sigma[y(t, k)] + W_2(t, k)u(t) \quad (4)$$

이때 원하는 출력 $y_d(t)$ 와 신경망 뉴런의 출력 $y(t, k)$ 사이의 학습오차는 식 (5)와 같이 나타낼 수 있다.

$$e(t, k) = y_d(t) - y(t, k) \quad (5)$$

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. 식 (5)의 오차를 줄이기 위한 가중치의 학습과정은 식 (6)과 같이 주어진다.

$$W(t, k+1) = W(t, k) + \Delta W(t, k) \quad (6)$$

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

이때 경계조건으로서 출력 $y(0)$ 는 식 (7)과 같이 0이 아닌 동일한 초기상태를 가지고 시작한다.

$$y(0, k) = y(0) \neq 0, \quad \text{for } k=0, 1, 2, \dots \quad (7)$$

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

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

미분의 평균값 정리에 의해서 식 (8)의 관계가 성립한다.

$$\begin{aligned} & \sigma[y(t-1, k+1)] - \sigma[y(t-1, k)] \\ &= \sigma'(\xi)[y(t-1, k+1) - y(t-1, k)] \end{aligned} \quad (8)$$

단, $y(t-1, k) < \xi < y(t-1, k+1)$ 이다. 반복법을 사용할 경우 $\xi = y(t-1, k)$ 로 둘 수 있고, 오차에 대해서 정리하면 식 (9)와 같다.

$$\begin{aligned} & e(t, k+1) - e(t, k) = -\eta(t+1, k) \\ &= \Delta W_1(t-1, k) e[y(t-1, k+1)] \\ &+ \Delta W_2(t-1, k) u(t-1) \\ &+ W_1(t-1, k) \sigma'(y(t-1, k)) \\ &\quad \cdot [y(t-1, k+1) - y(t-1, k)] \end{aligned} \quad (9)$$

학습규칙을 (10)과 같이 둔다.

$$\begin{aligned} \Delta W(t, k) &= [K_1(t, k) e(t+1, k) - K_2(t, k) \eta(t+1, k)] \\ &\quad \cdot [x(t, k+1)^T x(t, k+1)]^{-1} x(t, k+1)^T \end{aligned} \quad (10)$$

이때 $K_1(t, k), K_2(t, k) \in R^{N \times N}$ 이다.

식 (10)을 식 (9)에 대입하여 정리하면 식 (11)과 같다.

$$\begin{aligned} & e(t, k+1) - e(t, k) \\ &= -K_1(t-1, k)e(t, k) + K_2(t-1, k)\eta(t, k) \\ &- W_1(t-1, k)\sigma'[y(t-1, k)]\eta(t, k) \\ &= -K_1(t-1, k)e(t, k) + [K_2(t-1, k) \\ &- W_1(t-1, k)\sigma[y(t-1, k)]]\eta(t, k) \end{aligned} \quad (11)$$

식 (11)를 정리하면 식 (12)와 같이 나타낼 수 있다.

$$\begin{aligned} e(t, k+1) &= [I - K_1(t-1, k)]e(t, k) \\ &+ [K_2(t-1, k) - \\ &\quad W_1(t-1, k)\sigma[y(t-1, k)]]\eta(t, k) \end{aligned} \quad (12)$$

여기서, I 는 단위 행렬이다. 그리고 $\eta(t+1, k) = -[e(t, k+1) - e(t, k)]$ 이므로 (11)로부터 $\eta(t+1, k)$ 는 식 (13)과 같이 쓸 수 있다.

$$\eta(t+1, k) = [W_1(t-1, k)\sigma[y(t-1, k)] \\ - K_2(t-1, k)]\eta(t, k) + K_1(t-1, k)e(t, k) \quad (13)$$

식 (12)와 식 (13)를 행렬 형태로 나타내면 식 (14)와 같이 나타낼 수 있다.

$$\begin{bmatrix} \eta(t+1, k) \\ e(t, k+1) \end{bmatrix} = \begin{bmatrix} W_1(t-1, k)\sigma[y(t-1, k)] - K_2(t-1, k) & K_1(t-1, k) \\ K_2(t-1, k) - W_1(t-1, k)\sigma[y(t-1, k)] & I - K_1(t-1, k) \end{bmatrix} \begin{bmatrix} \eta(t, k) \\ e(t, k) \end{bmatrix} \quad (14)$$

참고문헌 3)의 정의에 의해서 $A_{t,k}^{0,1}$ 은 식 (15)와 같다.

$$A_{t,k}^{0,1} = \begin{bmatrix} 0 & 0 \\ K_2(t-1, k) - W_1(t-1, k)\sigma[y(t-1, k)] & I - K_1(t-1, k) \end{bmatrix} \quad (15)$$

참고문헌 3)의 Lemma 2는 수렴성에 관한 것으로 식 (16)과 같다.

$$\|A^{0,1}\| < \frac{1}{2} \Rightarrow \lim_{k \rightarrow \infty} \left| \frac{\eta(t, k)}{e(t, k)} \right| \rightarrow 0, \quad t: \text{fixed} \quad (16)$$

$$\text{단, } \|A^{0,1}\| = \sup_{t,k} \|A_{t,k}^{0,1}\|$$

$K_1(t-1, k) = I, K_2(t-1, k) = W_1(t-1, k)\sigma[y(t-1, k)]$ 라고 두면 식 (17)과 같다.

$$A_{t,k}^{0,1} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} \Leftrightarrow$$

$$\|A^{0,1}\| = \sup_{t,k} \|A_{t,k}^{0,1}\| = 0 < \frac{1}{2} \quad (17)$$

따라서, 수렴에 관한 Lemma인 식 (18)을 만족하므로 수렴함을 알 수 있다. 그러므로 학습규칙 식 (10)은 식 (18)과 같이 구해진다.

$$\begin{aligned} \Delta W(t, k) &= [e(t+1, k) - W_1(t, k)\sigma[y(t, k)]\eta(t+1, k)] \\ &\quad \cdot [x(t, k+1)^T x(t, k+1)]^{-1} x(t, k+1)^T \end{aligned} \quad (18)$$

초기 가중치는 매시간마다 균일 분포 난수(uniform distribution random)를 이용하여 초기화하는 방법과 시간 $t=0$ 에서 초기 가중치는 균일 분포 난수(uniform distribution random)를 이용하여 초기화한다.

2.2 2차원 학습 회귀적 신경망에 의한 적용 제어 최근 신경망이 비선형 시스템에 대한 학습과 모델링 능력 때문에 간접 적응 제어 기법은 비선형 시스템의 제어 기법으로 이용되고 있다. 식 (19)와 같이 기술되는 이산 시간 비선형 동특성 시스템을 고려하자.

$$\begin{aligned} y(k+1) \\ = f[y(k), y(k-1), \dots, y(k-n), \\ u(k), \dots, u(k-m)] \end{aligned} \quad (19)$$

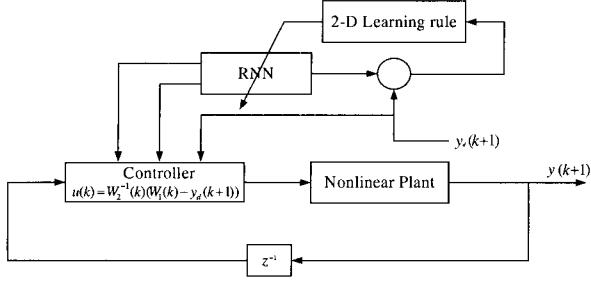


Fig. 1 Indirect adaptive control structure using the 2-D learning rule

여기서, $y(k)$ 와 $u(k)$ 는 시간 스텝 k 에서의 시스템 출력과 입력을 의미한다. 비선형 시스템에 대해 원하는 궤적이 되게 하기 위해서는 $y(k+1) = y_d(k+1)$ 이 되도록 제어입력이 만들어져야 한다. 그러나 식 (19)와 같은 비선형 시스템의 형태에서는 제어입력을 만들기 어렵기 때문에 시스템이 식 (20)과 같이 모델링될 수 있다고 가정한다.

$$\begin{aligned} y(k+1) &= f[y(k), y(k-1), \dots, y(k-n), \\ &\quad u(k), \dots, u(k-m)] \\ &\quad + g[y(k), y(k-1), \dots, y(k-n), \\ &\quad u(k-1), \dots, u(k-m)] u(k), \end{aligned} \quad (20)$$

만약 비선형 함수 $f(\cdot)$ 와 $g(\cdot)$ 를 알 수 있다면 제어입력은 식 (21)과 같이 구할 수 있고, 원하는 출력 $y_d(k+1)$ 을 정확하게 추적할 수 있다.

$$u(k) = -\frac{f(\cdot)}{g(\cdot)} + \frac{y_d(k+1)}{g(\cdot)} \quad (21)$$

그러나 $f(\cdot)$ 와 $g(\cdot)$ 는 미지의 함수이다. 신경망은 이를 함수를 근사하기 위해 학습시키고, 적절한 제어입력을 만들어 내는데 이용할 수 있다. 2차원 학습 회귀적 신경망은 매 시간 스텝마다 미지의 함수 $f(\cdot)$ 와 $g(\cdot)$ 를 근사하게 되고 제어입력은 식 (22)와 같이되고, 2차원 학습 회귀적 신경망을 이용한 간접 적응 제어 시스템의 블록선도는 Fig. 1과 같다.

$$u(k) = -\frac{W_1(\cdot)}{W_2(\cdot)} + \frac{y_d(k+1)}{W_2(\cdot)} \quad (22)$$

3. 전기·유압 서보시스템

3.1 전기·유압 서보시스템의 모델링

편로드 유압 실린더는 피스톤의 수압 면적이 다른

비대칭성 때문에 \dot{x}_p 가 양인 경우와 음인 경우로 나누어서 모델링을 수행한다. Fig. 2와 같이 화살표 방향을 양의 방향으로 두고, 실린더의 변위를 x_p , 서보 밸브 스페셜변위는 x_v 라한다. $\dot{x}_p > 0$ 인 경우에 밸브 스페셜 변위 x_v 로 인한 작동유의 공급측 유량 $q_1(t)$ 및 귀환측 유량 $q_2(t)$ 는 스페셜의 오리피스 유량 방정식으로부터 각각 식 (23)과 같이 나타낼 수 있다.

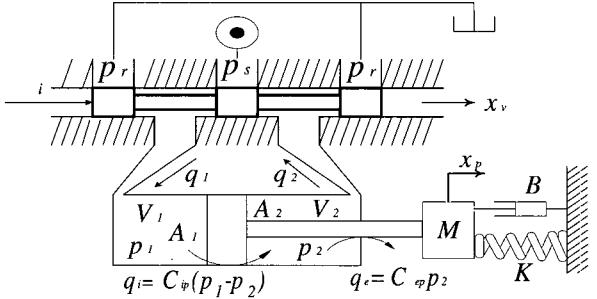


Fig. 2 An electro-hydraulic servo system with single-rod cylinder

$$\begin{aligned} q_1(t) &= C_d \omega x_v(t) \sqrt{\frac{2}{\rho} (p_s - p_1(t))} \\ q_2(t) &= C_d \omega x_v(t) \sqrt{\frac{2}{\rho} p_2(t)} \end{aligned} \quad (23)$$

여기서, C_d 는 밸브 스페셜의 오리피스 유량 계수, ω 는 밸브 포트의 단면적 구배, ρ 는 작동유의 밀도, p_s 는 공급 압력 그리고 $p_1(t)$ 및 $p_2(t)$ 는 각각 유압 실린더 좌우 양실에 연속 방정식을 각각 적용하면 실린더의 공급측 유량 $q_1(t)$ 와 귀환측 유량 $q_2(t)$ 는 식 (24)와 같이 쓸 수 있다.

$$\begin{aligned} q_1(t) &= C_{ip}(p_1(t) - p_2(t)) + C_{ep}p_1(t) \\ &\quad + \frac{dV_1(t)}{dt} + \frac{V_1(t)}{K_m} \frac{dp_1(t)}{dt} \\ q_2(t) &= C_{ip}(p_1(t) - p_2(t)) - C_{ep}p_2(t) \\ &\quad - \frac{dV_2(t)}{dt} - \frac{V_2(t)}{K_m} \frac{dp_2(t)}{dt} \end{aligned} \quad (24)$$

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

실린더 좌우 양실의 유량비 $\eta = q_2(t)/q_1(t)$ 라고 두고, 누설과 용적효율에 의한 유량은 피스톤 운동에 의한 유량보다 매우 적다고 가정하면 실린더 단

면적의 비로 나타내어진다.

부하 압력을 $p_L(t)$, 부하유량을 $q_L(t)$ 로 정의하고 유량방정식 (24)를 정리한다. 또한, $\dot{x}_p < 0$ 인 경우에도 유사하게 부하유량 q_L 이 얻어지므로 두 개의 관계를 하나의 식으로 정리하면 편로드 유압 실린더를 갖는 서보 밸브의 부하 유량식은 식 (25)와 같이 표현되어진다.

$$q_L(t) = \alpha C_d u x_v(t) \sqrt{\frac{1}{\rho} \left(p_s - \frac{\dot{x}_p}{|\dot{x}_p|} p_L(t) \right)} \quad (25)$$

여기서, $\alpha = \frac{1 + \eta}{2(1 + \eta^2)}$ 이다.

부하 유량 방정식 (25)를 Taylor 급수 전개하고 1차항만 고려하면 식 (26)과 같이 나타낼 수 있다.

$$q_L(t) = k_q x_v(t) - k_p p_L(t) \quad (26)$$

여기서 k_q 는 유량 계수[m³/s/m], k_p 는 유량-압력 계수[m⁵/N/s]이다.

편로드 유압 실린더의 부하 유량식은 식 (27)과 같이 나타낼 수 있다.

$$q_L(t) = A_{me} \frac{dx_p(t)}{dt} + C_t p_L(t) + \frac{V_e}{4K_m} \frac{dp_L(t)}{dt} \quad (27)$$

여기서, C_t 는 피스톤 전체 누유 계수, A_{me} 는 평균 피스톤 단면적, V_e 는 유압 실린더의 등가용적이다.

편로드 유압 실린더의 운동 방정식은 식 (28)과 같다.

$$\begin{aligned} p_L A_{me} = \\ M \ddot{x}_p(t) + B \dot{x}_p(t) + K(x_p(t) + K_n x_p(t)^3) + F_d \end{aligned} \quad (28)$$

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.

$K_u = C_t + k_p$, 스플의 변위 $x_v = K_v u(t)$ 라 둔다. 이 때 K_v 는 서보증폭기의 계인이고, $u(t)$ 는 제어기로부터 나온 제어입력이다. (26), (27), (28)과 상태변수 [$x_1(t)$ $x_2(t)$ $x_3(t)$]를 위치, 속도, 가속도라 정의하고, 상태 방정식의 형태로 정리하면 식 (29)와 같다.

$$\begin{aligned} \dot{x}_1(t) &= x_2(t) \\ \dot{x}_2(t) &= x_3(t) \\ \dot{x}_3(t) &= -\sum_i a_i x_i(t) + b(x) u(t) - N(x, t) - d(t) \end{aligned} \quad (29)$$

여기서,

$$a_1 = \frac{4K_m K_u K}{MV_e}$$

$$a_2 = \frac{4K_m K_u B}{MV_e} + \frac{4K_m A_{me}^2}{MV_e} + \frac{K}{M}$$

$$a_3 = \frac{4K_m K_u}{V_e} + \frac{B}{M}$$

$$b(x) = \frac{4K_m A_{me}}{MV_e} k_q K_v$$

$$N(x, t) = \frac{3KK_n}{M} x_1^2 x_2 + \frac{4K_m K_u}{MV_e} KK_n x_1^3$$

$$d(t) = \frac{4K_m K_u}{MV_e} F_d + \frac{1}{M} F_d$$

$N(x, t)$ 는 비선형항을 나타내고 있다.

3.2 실험장치의 구성

전기·유압 서보시스템은 건설 중장비, 시뮬레이터, 자동차 등에 서보밸브 또는 비례전자밸브와 실린더 등과 함께 주로 사용되어진다. 그러므로 본 연구에서는 대부분의 전기·유압 시스템에서 공통적으로 이용되는 1자유도 전기·유압 서보시스템을 설계 제작하였다. 설계 제작한 전기·유압 서보시스템의 구성은 Fig. 3과 같다. 시험기의 상부는 하중을 가변할 수 있게 하여 다양한 관성부하 조건에서 실험할 수 있도록 제작하였고, 부하의 하부에는 부하에 작용하는 힘을 계측하기 위하여 4900N까지 측정할 수 있는 스트레인 게이지형 로드셀을 장착하였다. 공간상의 활용을 위해 스프링, 댐퍼 시스템과 유압실린더를 병렬로 설치하고, 양단에 수직하중이 작용하도록 하기 위해 크래비스 베어링을 설치하고 지그(zig)를 이용하여 고정하였다. 또한 수직으로 움직일 수 있도록 4개의 가이드 레일을 설치하였으나, 가이드 레일의 위치가 정확하게 수직이 되게 하는 것이 어렵고 수직이 되지 않을 경우에는 오히려 실린더의 움직임을 방해하기 때문에 3개만을 사용하였다. 플랜트의 스프링, 댐퍼의 역할을 구현하기 위해 스프링과 댐퍼가 동시에 구현되는 차량용 현가장치를 이용하였으며, 유압실린더는 실제 대부분의 유압 시스템에서 사용되고 있는 편로드 실린더로 최고 사용압력 140bar, 행정 0.14m를 사용하였다. 센서로는 변위를 측정하기 위하여 0.3m 까지 측정 가능한 포텐시미터를 장착하였으며, 보조 센서로서 실린더 내의 압력을 계측하기 위하여 차동 압력 변환기를 실린더의 입·출구에 장착하였다. 시스템의 제어를 위한 제어기로는 66MHz급의 퍼스널 컴퓨터를 사용하였으며,

인터페이스 장치로는 12비트 분해능을 가지는 인터페이스 보드를 사용하였다.

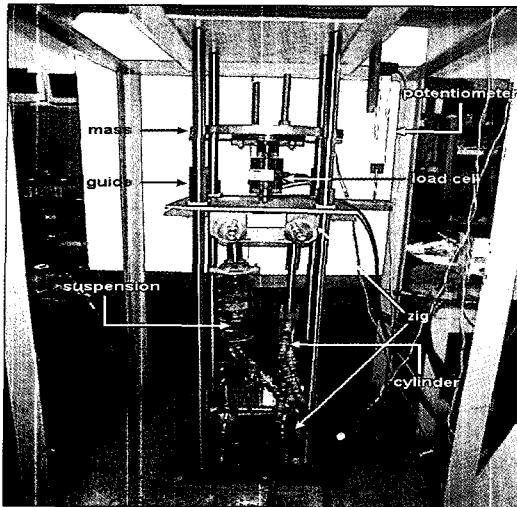


Fig. 3 Schematic of the electro-hydraulic servo system

4. 전기·유압 서보시스템의 위치 균사

실험과정은 먼저, 2차원 학습 회귀적 신경망에 의한 플랜트의 추종 성능을 알아보기 위해 제어기에서 입력신호로서 지속적 가진을 만족하는 유사 랜덤 이진 신호(Pseudo Random Binary Sequence)를 생성하여 서보밸브에 가하였다.

PRBS 신호는 두 레벨을 스위칭 하는 신호로서 백색잡음의 특성을 가지게 되고, 따라서, 전 주파수 대역에 걸쳐 일정한 에너지를 가진 입력 신호로서 사용되어 질 수 있다. 실험에 사용된 PRBS 신호는 식 (30)과 같다.

$$u(t) = u(t-1) \times sign(r(t) - 0.5) \quad (30)$$

여기서, 초기 입력 : $u(0)=1$ or $u(0)=-1$, $r(t)$ 는 0에서 1사이의 랜덤변수이다. Fig. 4는 실험에 사용된 PRBS 신호를 나타내고 있다.

PRBS신호가 가해질 때, 매 샘플링 순간마다 포텐 쇼미터를 이용하여 변위를 계측하고, 제어기 내에서 가해진 입력과 출력을 이용해서 2차원 학습 신경망에서 반복 학습 회수를 조정하면서 샘플링 시간 내에 온라인으로 변위를 추종하였다.

본 실험에서는 계산 속도를 높이기 위하여 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. 이 때 비선형 활성화 함수 $f(x)$ 로는 $tanh(x)$ 를 사용하였다.

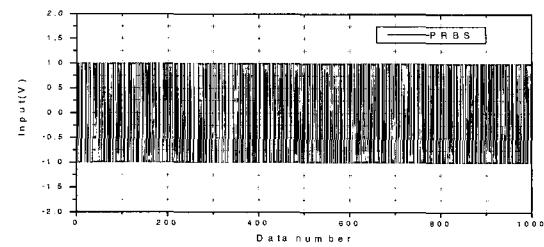
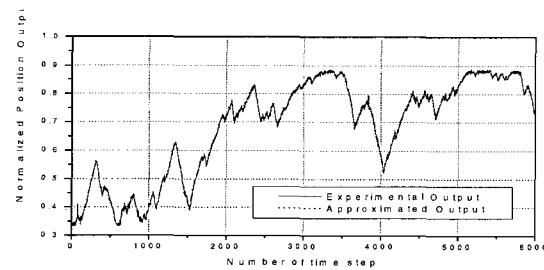
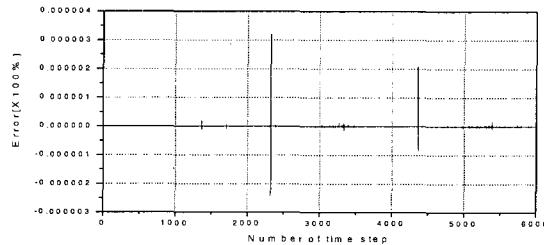


Fig. 4 Pseudo random binary input sequence



(a) Approximation of position output



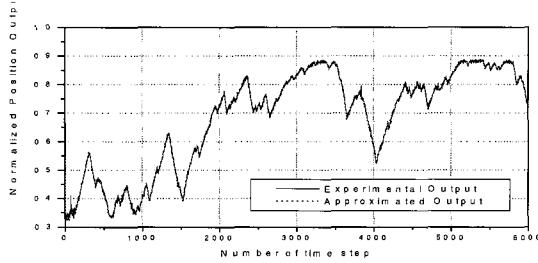
(b) Error of position

Fig. 5 On-line approximation results with random initial weight at every time step by learning rule for model 1) (iteration:7)

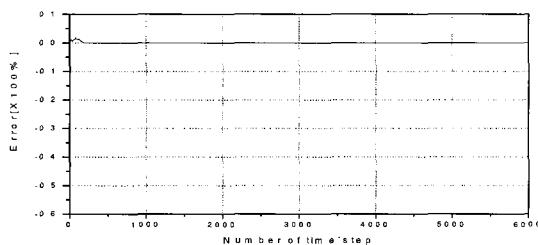
Fig. 5는 매시간 스텝에서 난수화된 초기값을 사용하고 반복회수를 7회로 하였을 때의 결과이다. 약 2300스텝에서 최대오차 3.5×10^{-6} 가 발생하고 나머지 구간에서는 거의 0을 보이고 있다.

Fig. 6은 초기에 0에서 1.0 사이의 난수화된 초기 값을 주고, 그 다음 시간 스텝에서는 앞선 시간스텝에서 수렴된 가중치를 초기 가중치로 이용하여 매 시간 스텝에서 1번의 반복학습을 수행하였을 때의 결과를 나타내고 있다. (a)와 (b)에서 초기 200스텝 내에서는 오차가 최대 0.02 정도 발생하였으나, 그 이후 가중치가 안정된 값 근처로 수렴이 이루어지고 난 후에는 거의 오차 0으로 잘 균사하고 있음을 보이고 있다. 이 결과는 기존의 비선형 모델 2)를 이용한 경

우⁵⁾보다 같은 반복회수에 비해 더 적은 반복으로 유사한 성능을 가질 수 있음을 보여주고 있다.



(a) Approximation of position output



(b) Error of position

Fig. 6 On-line approximation results with convergent initial weight at every time step by learning rule for model 1) (iteration : 1)

5. 전기·유압 서보시스템의 위치 추적 제어

위치 추적 제어를 위한 회귀적 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.

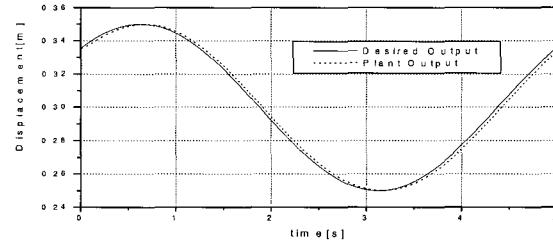
원하는 출력 궤적은 다음과 같이 정현파 함수를 사용하였고, 이때 주기 f 는 0.2Hz로 하였다.

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

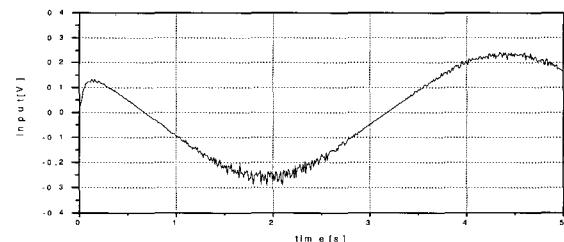
초기값은 $y(0) = d(0) = 0.34$ 로 가정하였다. 또한, 2차원 학습은 매시간 스텝마다 초기 가중치를 균일 분포난수를 이용하여 0.5에서 1사이의 값으로 초기화하였다. 오리피스 유량식에 의한 비선형성과 비선형 스프링에 의한 비선형성이 포함된 전기·유압 서보시스템의 추적 제어 성능을 확인하기 위하여 유체의 오리피스식에 의한 영향을 시변 파라미터로 고려하고, 스프링의 비선형 항을 선형계수 $K=3.0$ 보다 큰 $K_n=5.0$ 을 적용하여 비선형성이 포함되도록 하여 시뮬레이션을 수행하였다.

온라인 2차원 학습 알고리즘의 비선형함수가 비선형 출력 함수와 선형 입력항으로 분리되어 있는 형

태의 이산 시간계에서의 2차원 학습 신경망 알고리즘의 학습 규칙을 유도하고, 이 학습 규칙을 이용하여 비선형성이 강한 스프링을 포함하고 있는 전기·유압 서보시스템의 변위 추종을 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 궤적 추적 제어를 수행한 결과, 제어가 가능한 정확도를 가지는 출력의 추종은 3회의 반복 학습을 통해서 추종이 가능하였고, 제어 입력의 학습은 30회의 반복 학습에 의해 원하는 궤적의 추종이 이루어졌으며, 반복회수를 늘일수록 더 좋은 정도의 추적제어가 가능함을 보여줌으로써 오리피스에 의한 제곱근과 비선형 스프링에 의한 비선형성이 포함된 전기·유압 서보시스템의 궤적 추적제어에 탁월한 성능을 가지고 있음을 알 수 있다.



(a) Response of the plant and the desired output

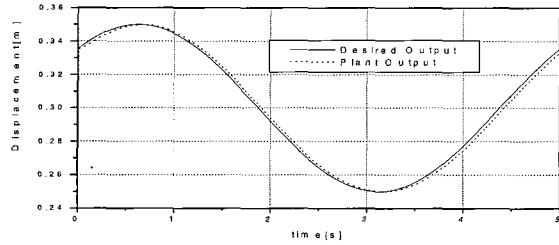


(b) Control input

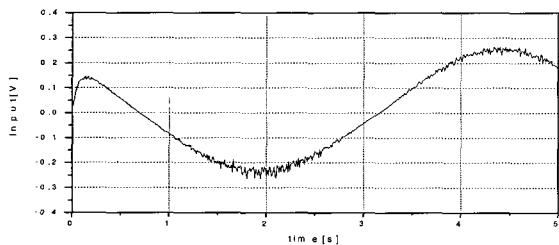
Fig. 7 Simulation results using indirect adaptive control with 4 learning iteration and 50 control iteration

플랜트를 근사하기 위해 2차원 학습 신경망은 4회의 반복 학습을 수행하고, 제어입력은 매 시간 스텝에서 50회를 반복 수행하여 제어입력을 구하고, 계산된 제어입력을 플랜트에 가하였을 때의 시뮬레이션 결과를 Fig. 7에 나타내었다. 그림에서 알 수 있는 바와 같이 추적 오차는 플랜트의 출력의 기울기

가 최대가 되는 점을 주위로 해서 제어입력이 채터링을 일으키면서 최대 0.003의 추적 오차를 보이면서 양호한 추적 성능을 보여주고 있다.



(a) Response of the plant and the desired output



(b) Control input

Fig. 8 Simulation results using indirect adaptive control with 4 learning iteration and 50 control iteration (disturbance)

Fig. 8은 신경망은 4회의 반복 학습, 제어입력은 50회 반복 수행하고, 외란 $F_d = 980 N$ 를 $t=0$ 인 초기 상태에서 가했을 때의 시뮬레이션 결과이다. 그럼에서 알 수 있는 바와 같이 결과는 외란이 가능하지 않은 결과인 Fig. 7과 거의 동일한 결과를 보여주고 있다. 즉, 제어기가 외란에 대해서 강인한 성능을 가지고 있음을 나타내고 있다.

간접 적응 제어의 형태에서 추적 오차가 반복 회수를 증가할수록 오차가 줄어 들어가는 것을 볼 수 있다. 이것은 제어입력이 플랜트의 출력이 원하는 출력 값으로 갈 수 있도록 그 순간의 시간 스텝에서 반복적으로 계산되어 지면서 원하는 출력이 되도록 하는 참값의 제어입력 값으로 수렴되어지는 것으로 생각되어 진다.

6. 결 론

본 연구에서는 기존에 제시된 입력과 출력이 인자로 포함된 비선형 시스템에 대한 2차원 학습 규칙에 비해서 제어에 유리하게 적용될 수 있는 것으로 알

려진 비선형 함수와 선형입력으로 구성된 비선형 모델에 대한 2차원 학습 규칙을 제시하였다. 또한 이 두 가지 학습 규칙을 회귀적 신경망 구조에 적용하여, 전기·유압 서보시스템에 대한 실험을 통해서 온라인 근사의 가능성을 다루었다. 그리고 이들 2차원 학습 규칙과 회귀적 신경망을 이용하여 구성한 제어 구조에 의한 전기·유압 서보시스템의 위치 추적 제어를 수행하여 제안된 2차원 학습 규칙에 의해 양호한 위치 추적 제어가 가능함을 보였고, 실시간 제어를 위해 2차원 학습 회귀적 신경망을 이용한 간접 적응제어기법을 적용하여 실시간 제어의 가능성을 보였다.

온라인 근사의 경우 제안된 비선형 모델 1)에 대한 학습 규칙을 이용한 경우에는 매 시간 스텝에서 가중치를 난수로 사용했을 때도 7회의 반복 학습으로 오차 3.5×10^{-6} 이하로 근사가 가능하였고, 수렴된 가중치를 이용할 경우에는 1회의 반복 학습으로 0.02이하의 오차 범위 내로 근사가 가능하여 기존의 비선형 모델 2)에 대한 학습규칙을 이용한 경우에 비해 탁월한 근사 성능을 보임을 알 수 있다.

비선형 모델 1)에 대한 2차원 학습 회귀적 신경망을 이용한 간접 적응 제어를 수행하여 기존의 연구에서 제시된 비선형 모델 2)에 대한 학습규칙과 2개의 신경망을 이용한 경우보다⁵⁾ 연산시간을 줄이면서 유사한 제어 성능을 얻었으며, 외란에도 강인한 제어가 가능함을 볼 수 있다. 또한, 제어 입력을 계산하기 위한 반복 회수를 높일수록 더 나은 정도의 제어가 이루어짐을 알 수 있다.

참고 문헌

- 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, 2002.
- 3) 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.

- 4) 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.
- 5) 정봉호, 곽동훈, 이춘태, 이진걸, "2차원 학습 회귀적 신경망을 이용한 전기·유압 서보시스템의 실시간 추종", 한국정밀공학회 논문지, 제20권 제8호, pp. 94~100, 2003.