

2차원 학습 회귀적 신경망을 이용한 전기·유압 서보시스템의 실시간 추종

정봉호*, 곽동훈#, 이춘태*, 이진결**

Real-time Approximation of a Hydraulic Servo System Using a Recurrent Neural Network with 2-D Learning Algorithm

Bong-Ho Jung*, Dong-Hoon Kwak#, Choon-Tae Lee* and Jin-Kul Lee**

ABSTRACT

This paper presents the experiments on the approximation of a hydraulic servo system using a real time recurrent neural networks (RTRN) with time varying weights. In order to verify the effectiveness of the RTRN algorithm in hydraulic servo system, we design the experimental hydraulic system and implemented the real time approximation of system output. Experimental results show that approximated output of the RTRN well follows the position trajectory of the electro-hydraulic servo system. And also it is verified that the 2-D RNN can be implemented in sampling time even though high sampling frequency experimentally.

Key Words : electro-hydraulic servo system(전기·유압 서보시스템), recurrent neural network(회귀적 신경망), 2-dimensional learning rule(2차원 학습 규칙)

1. 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 전환, 마찰, 누유와 히스테리시스에 의한 불감

대 등으로 인한 강한 비선형성을 가지고 있고, 부하변동, 외부온도의 변화와 구성품 마모로 인한 체적탄성계수 변화와 같은 외부 환경 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 있다¹. 이를 위해 Kurek² 등은 선형 이산 다변수 시스템에 대한 2차원 학습제어 알고리즘을 제시하고 수렴성에 대해서 증명하였다. 또한, Chow^{3,4,5} 등

* 접수일: 2002년 11월 25일; 게재승인일: 2003년 7월 11일

교신저자: 부산대학교 지능기계공학과
Email: dhkwak@pusan.ac.kr, Tel: (051) 510-1449

* 부산대학교 대학원 지능기계공학과

** 부산대학교 기계공학부

은 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, 이 알고리즘을 연속시간계로 확장하였다. 본 연구에서는 고정도 제어를 위한 사전 단계로 최근 디지털 신호처리, 디지털 이미지 프로세싱 등 광범위한 분야에서 활용되고 있는 이산 시간계에서의 2차원 학습(2-dimensional learning) 회귀적 신경망(recurrent neural network)⁴을 이용하여 실험을 통해 알고리즘의 타당성을 검증하고, 전기·유압 서보시스템의 실시간 위치 추종 및 제어에 대한 가능성을 확인하였다.

2. 실시간 회귀적 신경망과 2차원 학습 알고리즘

실시간 회귀적 신경망(real time recurrent neural network)은 미지의 동특성을 가진 비선형 시스템에 대한 실시간 학습제어 신경망으로 많이 사용되고 있다. Fig. 1은 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 특정시간에 원하는 값에 어떤 특정 뉴런의 출력을 일치시키는 것이다.




Fig. 1 The architecture graph of a real time recurrent neural network

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.

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

실시간 회귀적 신경망의 상태공간 비선형 동특성은 식(2)와 같이 표현할 수 있다.

$$y(t+1) = f^*[W_1(t)y(t) + W_2(t)u(t)] \quad (2)$$

여기서, $y(t) \in R^N$, $u(t) \in R^M$, 가중치 $W_1 \in R^{N \times N}$, $W_2 \in R^{N \times M}$ 이다. 함수 $f^*(\cdot)$ 는 비선형 활성화 함수이다.

2차원 학습 알고리즘은^{2,3} 시변 가중치를 가지는 실시간 회귀적 신경망에 대한 새로운 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, 학습과정동안 실시간 신경망의 각 변수는 두 개의 독립변수인 이산화된 시간 t 와 반복학습 회수인 k 에 종속되어진다. 실시간 신경망을 2차원으로 표현하면 식(3)과 같이 쓸 수 있다.

$$\hat{y}(t+1, k) = f^*[W_1(t, k)\hat{y}(t, k) + W_2(t, k)u(t, k)] \quad (3)$$

이때 원하는 출력 $y_d(t)$ 와 신경망 뉴런의 출력 $\hat{y}(t, k)$ 사이의 학습오차는 식(4)와 같이 나타낼 수 있다.

$$e(t, k) = y_d(t) - \hat{y}(t, k) \quad (4)$$

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

$$W(t, k+1) = W(t, k) + \Delta W(t, k) \quad (5)$$

이때 경계조건으로서 출력 $y(0)$ 는 식(6)과 같이 0이 아닌 동일한 초기상태를 가지고 시작한다.

$$y(0, k) = y(0) \neq 0, \text{ for } k=0,1,2, \dots \quad (6)$$

또한, 초기 가중치는 매시간 마다 균일 분포 난수(uniform distribution random)를 이용하여 초기화하는 방법과 시간 $t=0$ 에서 초기 가중치는 균일 분포 난수(uniform distribution random)를 이용하여 초기화하고, 다음 시간에서의 가중치는 식(7)과 같이 앞선 시간스텝에서 수렴된 가중치를 이용하는 방법이 있다.

$$W(t) = W(t, k_t) = W(t, 0) + \sum_{k=1}^{k_t} \Delta W(t, k) \quad (7)$$

$$W(t+1, 0) = W(t, k_t)$$

가중치 W 를 학습시키는 규칙을 식(8)과 같이 나타낼 수 있다⁴.

$$W(t, k+1) = W(t, k) + [C^{-1}(t, k)e(t+1, k) - W_1(t, k)\eta(t+1, k)] \cdot [x(t, k+1)^T x(t, k+1)]^{-1} x(t, k+1)^T \quad (8)$$

여기서, 각각의 항들에 대한 정의는 식(9)-(12)와 같다.

$$\eta(t+1, k) = y(t, k+1) - y(t, k) \quad (9)$$

$$C^{-1}(t) = [\text{diag}(f'(\xi_1), f'(\xi_2), \dots, f'(\xi_n))]^{-1} \quad (10)$$

$$\xi = (\xi_1, \xi_2, \dots, \xi_n) = W(t, k)x(t, k) \quad (11)$$

$$x(t, k) = \begin{pmatrix} y(t, k) \\ u(t) \end{pmatrix} \quad (12)$$

가중치를 학습시키는 학습규칙의 수렴성에 대한 증명은 참고문헌4)에 기술되어있다. 2차원 학습실시간 회귀적 신경망의 흐름도는 Fig. 2와 같다.

3. 실험장치 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 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 측정하기 위하여 500kg까지 측정할 수 있는 스트레인 게이지형 로드셀을 장착하였다. 공간상의 활용을 위해 스프링, 댐퍼 시스템과 유압 실린더를 병렬로 설치하고, 양단에 수직하중이 작용하도록 하기 위해 크래비스 베어링을 설치하고 지그(Zig)를 이용하여 고정하였다. 또한 수직으로 움직일 수 있도록 4개의 가이드 레일을 설치하였으

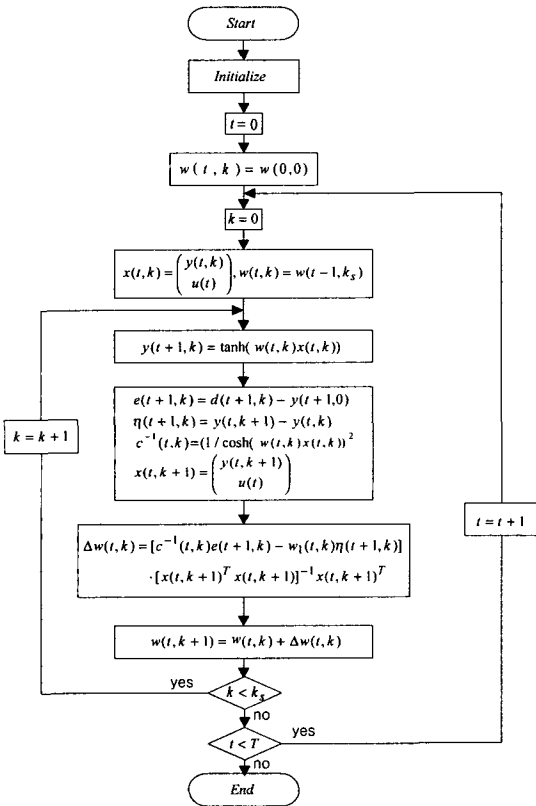


Fig. 2 A flowchart of 2-D recurrent neural network




Fig. 3 Schematic of electro-hydraulic servo system

나, 가이드 레일의 위치가 정확하게 수직이 되게 하는 것이 어렵고 수직이 되지 않을 경우에는 오히려 실린더의 움직임을 방해하기 때문에 3개만 사용하였다. 플랜트의 스프링, 댐퍼의 역할을 구현하기 위해 스프링과 댐퍼가 동시에 구현되는 차량용 현가장치를 이용하였으며, 유압실린더는 실제 대부분의 유압 시스템에서 사용되고 있는 편로드 실린더로 행정 14cm를 사용하였다. 센서로는 변위를 측정하기 위하여 30cm 까지 측정 가능한 포텐쇼미터를 장착하였으며, 보조 센서로서 실린더 내의 압력을 측정하기 위하여 차동 압력 변환기를 실린더의 입·출구에 장착하였다. 시스템의 제어를 위한 제어기로는 66MHz급의 퍼스널 컴퓨터를 사용하였으며, 인터페이스 장치로는 12비트 분해능을 가지는 AD LINK 사의 A/D, D/A 보드를 사용하였다. 시스템의 동력공급 장치는 정용량형 펌프, 전동기, 릴리프 밸브 등으로 구성된 유압 파워 유닛을 사용하였다. Fig. 4는 전기·유압 서보시스템의 위치제어를 위한 계통도이다. 시스템의 구동 원리는 유압실린더의 피스톤 변위는 변위 측정 센서인 포텐쇼미터에 의해 전기적 신호로서 검출되고, 기준입력과 오차를 보정하기 위한 제어입력이 서보 증폭기에 가해




Fig. 4 Schematic diagram of electro-hydraulic position control system

진다. 서보 증폭기에서 나온 전류 출력은 서보 밸브 스톱의 위치를 변경시켜 실린더에 유입되는 유량을 조절함으로써 시스템의 변위를 제어하도록 구성되어 있다.

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 (13)과 같다.

$$u(t) = u(t-1) \times \text{sign}(r(t) - 0.5) \quad (13)$$

여기서, 초기 입력 : $u(0)=1$ or $u(0)=-1$, $r(t)$ 는 0에서 1사이의 랜덤변수이다.

PRBS신호가 가해질 때, 매 샘플링 순간마다 포텐쇼미터를 이용하여 변위를 측정하고, 제어기 내에서 가해진 입력과 출력을 이용해서 2차원 학습 신경망에서 반복 학습 회수를 조정하면서 샘플링 시간내에 실시간으로 변위를 추종하였다. 이때 2차원 학습알고리즘에서 가중치는 매 샘플링 시간마다 난수를 이용해 초기한 경우와 앞선 스텝에서 구한 가중치를 이용하는 두가지 경우에 대해서 실험을 수행하였다. 또한 2차원 학습 신경망에서의 추정과 제어가 실시간으로 가능한지를 확인하기 위하여 반복 학습 회수를 고정된 후 샘플링 주기를 100Hz에서부터 점차 증가 시켜가면서 샘플링 시간내에 학습에 의한 연산이 이루어져 추종이 이루어지는지를 실험하였다.


4. 실험 결과 및 고찰

비선형성이 강하고 불확실성이 많은 전기·유압 서보 시스템에 2차원 실시간 신경망 알고리즘을 사용하여 실시간 근사 가능성에 대한 실험을 수행하였다.


회귀적 신경망의 구조는 뉴런의 수를 늘이거나, 가중치를 학습하는 반복회수를 늘임으로서 추종의 정확도를 높일 수 있다. 그러나, 계산 시간상으로는 뉴런의 수를 늘이면 반복 학습 회수가 줄어들고, 뉴런의 수를 줄이면 반복 학습 회수가 많아지는 서로 상충되는 특성을 가지고 있고, 정확도에 있어서는 서로 큰 차이가 없는 것으로 알려져 있다⁵⁾. 따라서, 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. 이때 비선형 활성화 함수 $f(x)$ 로는 $\tanh(x)$ 를 사용하였고, 시스템에 사용한 샘플링 주기는 100Hz이다.

검출된 위치 신호와 입력신호는 2차원 학습 실시간 신경망 알고리즘을 이용하여 샘플링 시간 내에 반복학습을 통해 학습을 수행하여 원하는 출력값, 즉 변위를 추종하게된다.


실험은 먼저 매시간 스텝마다 가중치를 균일 분포 난수함수로 초기화시키는 경우와 시간 $t=0$ 에서만 균일 분포 난수함수로 초기화하고, 다음 시간 스텝에서는 앞선 시간 스텝에서 출력을 원하는 출력에 추종했을 때의 가중치를 초기 가중치로 사용하는 경우에 대하여 수행하였다. Fig. 5는 매 시간 스텝마다 가중치를 0에서 1사이의 난수를 이용해서 초기화하고, 학습 반복회수를 3회로 하였을 때의 실험 결과를 나타내고 있다. (a)에서 정규화된 출력값은 포텐쇼미터로부터 측정할 수 있는 값이 30cm 이므로 계측기로부터 얻어진 신호를 측정할 수 있는 최대값 30cm로 나눈 값을 의미한다. 그림에서 1800스텝 동안은 오차가 2.5% 정도로 실제 변위 0.75cm 이내의 양호한 추종이 이루어졌으나, 그 이후 오차가 최대 12%로 3.6cm의 오차가 발생함을 볼 수 있다. Fig. 6은 반복회수를 7회로 늘렸을 때




(a) Approximation of position output



(b) Error of position




(a) Approximation of position output




(b) Error of position

Fig. 5 Real-time approximation results with random initial weight at every time step(iteration number : 3)

Fig. 6 Real-time approximation results with random initial weight at every time step (iteration number : 7)




(a) Approximation of position output




(b) Error of position

Fig. 7 Real time approximation results with converged initial weight at every time step (iteration number : 3)



(a) Approximation of output



(b) Error of position

Fig. 8 Real time approximation results with converged initial weight at every time step (iteration number : 7)

의 결과이다. 약 2800스텝에서 오차가 커지기 시작하고, 오차도 최대 0.06이하로 정확도가 상당히 개선되었으나, Fig. 5와 유사한 경향을 보임을 알 수 있다. 또한 그림에서 정규화된 출력의 최대 범위인 1에 가까이 갈수록 오차가 커지고 출력값이 0.7이하에서는 다시 오차가 줄어들고 있음을 볼 수 있다. 이것은 매 스텝마다 초기 가중치를 난수로 초기화하고, 학습규칙 (8)에 의한 가중치 변화량이 출력값이 1에 가까이 갈수록 비선형 활성화 함수의 변화율 값의 역행렬 $C^{-1}(t)$ 가 작아져 빠른 속도로 추종하지 못하기 때문이다. 그러므로 정규화 시키는 값을 실제 측정할 수 있는 변위 보다 크게 사용하여 사용범위를 제한함으로써 정도를 향상시키는 것이 가능하다. Fig. 7은 초기에 0에서 0.1사이의 난수화된 초기값을 주고, 그 다음 시간스텝에서는 앞선 시간스텝에서 수렴된 가중치를 초기 가중치로 이용하여 매 시간스텝에서 3번의 반복학습을 수행하였을 때의 결과를 나타내고 있다. 약 2300스텝 이하에서는 중간에 수렴하지 못하고, 오차가 크게 발생하는 부분이 있으나, Fig. 8에서는 반복학습 회수를 7회로 늘였을 때의 최대 오차가 0.02 이하이다. 출력값이 난수화된 초기 가중치를 사용한 것과는 달리 잘 추종하고 있음을 알 수 있다. 이것은 가중치의 초기값을 수렴된 가중치를 이용함으로써 변화율 $C^{-1}(t)$ 가 작더라도 가중치를 학습시키는데 더욱 유리함을 나타내고 있다. 또한, 7회 이상의 반복학습을 수행하였을 경우에는 오차는 점점 줄어들지만, 연산시간에 비해 오차가 줄어드는 폭이 작으므로 반복학습 7회가 가장 적절한 것으로 생각되어진다.

비선형성이 강한 것으로 널리 알려져 있는 전기·유압 서보 시스템에서의 2차원 실시간 신경망 알고리즘의 실시간 가능성을 확인하기 위하여 샘플링 주기를 높이면서 반복회수를 15회로 했을 때의 응답을 구한 결과 약 1.2kHz까지 샘플링 시간 내에 연산이 가능한 것으로 나타났다. 따라서, 대부분의 기계적인 시스템에서도 충분한 계산시간이 확보될 수 있어 제어 알고리즘과 결합하여 사용할지라도 실시간 연산이 가능함을 확인할 수 있었다.

5. 결론

본 연구에서는 전기·유압 서보시스템에 대한

실험을 통해서 2차원 학습 규칙을 가지는 회귀적 신경망 구조의 실시간 추종의 가능성을 다루었다. 회귀적 신경망 구조를 가장 단순한 2입력 1출력의 형태로 구성하고 매 시간 스텝에서 반복학습을 수행하는 2차원 학습 알고리즘을 이용했을 때 다음과 같은 결론을 얻었다.

[1] 비선형성이 강하고 불확실성이 높은 것으로 널리 알려진 전기·유압 서보시스템에 2차원 학습 실시간 신경망을 적용하여 원하는 오차 범위내로 실시간 추종이 가능함을 확인하였다.

[2] 실험에 사용된 2차원 실시간 신경망은 구조가 간단하고 계산시간이 적게 걸려 66MHz 급의 CPU를 사용하였을 때 샘플링 주기 1.2kHz에서 15회의 반복학습이 가능하였다. 따라서, 계산시간에 충분한 여유가 있으므로 2차원 학습 실시간 신경망을 이용하여 추종한 후 제어 알고리즘과 결합하여 실행할 경우에도 시간적 여유가 있음을 알 수 있다.

[3] 초기 가중치를 매 시간 스텝에서 초기화하는 경우에 비선형 활성화 함수의 미분값의 영향에 의해 정규화된 출력값이 양단 끝부분 근처에 가까이 갈수록 오차를 많이 발생하므로 사용범위를 제한하여 사용함으로써 정도를 향상시키는 것이 가능하다.

[4] 초기 가중치를 앞선 시간에서 수렴된 가중치를 이용할 경우 7번의 반복학습 만으로도 최대 2% 정도의 오차범위 내에 들어가고, 정규화된 출력값의 범위에도 영향을 받지 않으므로, 수렴된 가중치를 이용하는 것이 더욱 유리하다. 그러므로 매 시간 난수 가중치를 이용하는 것보다는 수렴된 가중치를 이용함으로써 추종 성능을 개선할 수 있다. 향후 연구 과제로는 2차원 실시간 학습 알고리즘과 제어 알고리즘의 결합을 통해 비선형 시스템의 제어에 관한 연구가 필요할 것으로 생각되어진다.

pp. 121-125, 1993.

3. Chow, T. W. S. and Fang, Y., "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.
4. Chow, T. W. S. and Fang, Y., "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.
5. Chow, T. W. S., Li, X. D. and Fang, Y., "A Real-Time Learning Control Approach for Nonlinear Continuous-Time System using Recurrent Neural Networks," IEEE Trans. Ind. Electronics, Vol. 47, No. 2, pp. 478-486, 2000.

참고문헌

1. Narendra, K. S. and Parthasarathy, K., "Identification and Control of Dynamic Systems using Neural Networks," IEEE Trans. Neural Networks, Vol. 1, No. 1, pp. 4-27, 1990.
2. Kurek, J. E. and Zaremba, M. B., "Iterative Learning Control Synthesis based on 2-D System Theory," IEEE Trans. Automat. Contr., Vol. 38,