

지진시 구조물의 지능제어 기법 Intelligent Control of Structures under Earthquakes

김동현* 이규원** 이종현*** 이인원****
Kim, Dong-Hyawn Lee, Gyu-Won Lee, Jong-Heon Lee, In-Won

ABSTRACT

Optimal neuro-control algorithm is extended to the control of a multi-degree-of-freedom structure. An active mass driver(AMD) system on the top roof is used as a controller. The control signals are made by a multi-layer perceptron(MLP) which is trained by minimizing a sub-optimal performance index. The performance index is a function of both the output responses and the control signals. Structure having nonlinear hysteretic behavior is also trained and controlled by using proposed control algorithm. Bothe the time delay effect and the dynamics of hydraulic actuator are included in the simulation. Example shows that optimal neuro-control algorithm can be applicable to the multi-degree of freedom structures.

1. 서론

구조물의 진동제어를 함에 있어 신경망을 이용하는 목적은 크게 두 가지로 볼 수 있다. 첫째, 구조물의 정확한 모델링을 할 수 없을 때 제어기의 설계를 가능하게 한다. 기존의 모델에 근거한 제어기 설계 방법에서는 수학적 모델에 바탕을 두고 제어기를 설계하기 때문에 모델링의 오차에 따라 제어기의 성능이 좌우되고 심할 경우에는 안정성을 보장하기 어렵다. 물론 모델링 오차를 감안한 강인제어 설계방법이 있기는 하지만 여기에서도 모델링의 오차한계를 어느 정도 제한하고 있다. 둘째, 비선형 거동을 하는 구조물의 제어에도 쉽게 적용할 수 있다. 비선형 거동을 하는 구조물의 제어를 위해서 기존의 비선형 제어에서는 선형화 등을 통하여 제어기를 설계하지만 신경망을 이용한 진동제어는 그러한 구조물의 비선형 특성을 학습하기 때문에 선형화 등의 부정확한 방법을 사용하지 않으며 또한 제어력의 산정 시간 또한 매우 빠르다는 장점이 있다.

본 연구는 김주태(2000)등이 제안한 신경망을 이용한 최적제어 기법을 다자유도 구조물에 적용하였다.[1] 전단 건물의 제어를 위하여 최상층에 설치된 능동질량감쇠기(AMD)를 이용하였으며 AMD에 필요한 제어기 신호를 만들기 위하여 신경망을 학습시켰다. 수치해석에서는 3층 전단 건물 모형과 유압식 가진기를 이용한 제어를 구현하였으며 시간 지연 효과를 고려하였다.

-
- * 한국과학기술원 토목공학과 박사과정
 - ** 전북대학교 토목공학과 교수
 - *** 경일대학교 토목공학과 교수
 - **** 한국과학기술원 토목공학과 교수

2. 신경망을 이용한 진동제어

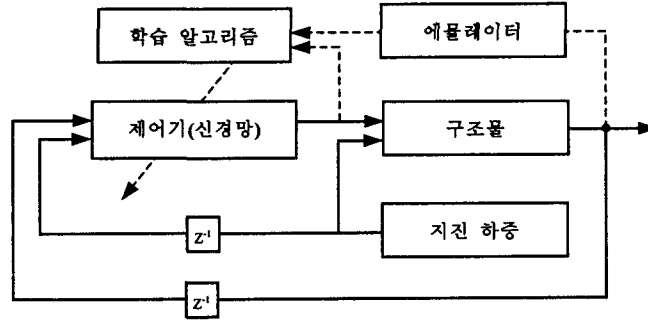


그림 1 신경망을 이용한 제어알고리즘의 개념도

그림 1 은 본 연구에서 사용하는 신경망을 이용한 진동제어의 개념을 보여주고 있다. 지진하중이 가해지면 구조물은 진동을 하게 된다. 이 진동신호를 계측기를 통하여 측정하면 이것은 제어기 신경망의 입력으로 사용된다. 물론 제어기 신경망의 입력에는 이것 외에 지진하중 신호도 포함된다. 입력신호를 받은 제어기 신경망은 미리 학습된 가중치들을 이용하여 진동하고 있는 구조물에 필요한 제어력을 계산한다. 이 제어신호는 AMD 를 구동하고 결과적으로 구조물의 진동을 제어하게 된다. 제어기를 성공적으로 작동시키기 위해서는 제어기 신경망을 사전에 학습시켜야 하는데 이 때 이용되는 것이 에뮬레이터(emulator) 신경망이다. 에뮬레이터는 미리 구조물의 동적 거동을 모사하도록 학습시키는데, 그 학습이 성공적으로 끝난 것은 제어기의 신호와 구조물의 진동응답 사이의 민감도를 얻는데 사용된다. 이러한 민감도와 진동신호를 이용하여 제어신호의 오차를 계산하고 계산된 제어신호의 오차는 제어기 신경망을 학습하는데 이용된다. 에뮬레이터 신경망이 미리 학습되었다는 가정 하에 제어기 신경망을 학습하기 위한 가격함수를 식(1)과 같이 정의하자.

$$J = \frac{1}{2} \int_0^{\infty} (\mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{u}^T \mathbf{R} \mathbf{u}) dt \quad (1)$$

여기서 \mathbf{x} 와 \mathbf{u} 는 각각 변위와 제어력 벡터이고 \mathbf{Q}, \mathbf{R} 은 각각 상대 가중치 행렬이다. 식(1)은 최적제어에서 흔히 사용하는 가격함수로서 구조물의 해석적 모델을 알 수 있을 때 Riccati 방정식을 풀면 이 가격함수를 최소로 하는 제어 이득을 계산할 수 있다. 그러나 구조물의 모델을 알 수 없거나 매우 오차가 많이 포함되어 있다고 하면 그 결과를 신뢰하기가 어렵다. 본 연구에서는 이 가격함수를 최소화 하기 위하여 신경망을 학습시키는데 이를 위하여 우선 이산 시간 영역으로 앞 식을 다시 정리하면 식(2)와 같다.

$$\hat{J} = \sum_{i=0}^N \hat{J}_n = \sum_{n=0}^N \frac{1}{2} \{ \mathbf{x}(i)^T \mathbf{Q} \mathbf{x}(i) + \mathbf{u}(i)^T \mathbf{R} \mathbf{u}(i) \} \Delta t \quad (2)$$

제어기 신경망의 학습을 기술하기 위하여 그림 2 와 같은 다층신경망의 l 번째 층과 $(l+1)$ 번째 층이 있다고 하자.




그림 2 신경망의 l번째 층과 (l+1)번째 층 사이의 구조

l번째 층의 입력을 net_γ^l ($\gamma = 1, 2, \dots, \Gamma$) 이라고 하면 출력은 $o_\gamma^l = f^l(net_\gamma^l)$, ($\gamma = 1, 2, \dots, \Gamma$) 이 된다. 여기서 f^l 은 l번째 층에서의 활성화 함수이다. 이와 같이 하면 (l+1)번째 층에서의 출력은 $o_\lambda^{l+1} = f^{l+1}(net_\lambda^{l+1})$, ($\lambda = 1, 2, \dots, \Lambda$) 이 된다. 이 두 층 사이에서 γ 번째 뉴런과 λ 번째 뉴런 사이의 가중치는 $W_{\lambda\gamma}^l$ 로 나타내기로 한다. 식 (2)의 가격함수에서 순간 가격함수(\hat{J}_n)를 최소화 하는 가중치를 찾기 위해서 steepest descent rule 을 적용하면 가중치의 학습량을 식 (3) 과 같이 구할 수 있다.

$$\Delta W_{\lambda\gamma}^l = -\eta \frac{\partial \hat{J}_n}{\partial W_{\lambda\gamma}^l} = -\eta \frac{\partial \hat{J}_n}{\partial net_\lambda^{l+1}} \frac{\partial net_\lambda^{l+1}}{\partial W_{\lambda\gamma}^l} \quad (3)$$

여기서 η 는 학습률을 나타낸다. 식의 간결성을 위해 식(4)를 도입하면 식(3)은 다시 식(5)로 간단히 표현할 수 있다.

$$\delta_\lambda^{l+1} = -\frac{\partial \hat{J}_n}{\partial net_\lambda^{l+1}} \quad (4)$$

$$\Delta W_{\lambda\gamma}^l = \eta \delta_\lambda^{l+1} o_\gamma^l \quad (5)$$

바이어스의 학습량도 마찬가지로 식(6)으로 표현할 수 있다.

$$\Delta b_\lambda^{l+1} = -\eta \frac{\partial \hat{J}_n}{\partial b_\lambda^{l+1}} = -\eta \frac{\partial \hat{J}_n}{\partial net_\lambda^{l+1}} \frac{\partial net_\lambda^{l+1}}{\partial b_\lambda^{l+1}} = \eta \delta_\lambda^{l+1} \quad (6)$$

식(5)와 (6)을 이용하여 출력층에서 입력층의 방향으로 가중치를 학습하는 과정을 반복하면 가중치와 바이어스가 특정 값으로 수렴하게 되는데 이렇게 학습된 제어기 신경망을 사용하면 주어진 시간 동안의 제어결과에 대한 가격함수가 최소화 된다. 물론 학습 시에는 순간 가격함수를 이용하였지만 총 가격함수가 최소화되는데 이것은 신경망을 일괄학습(batch learning)이나 형태학습(pattern learning)을 통하여도 결과가 다르지 않다는 것과 일맥상통(一脈相通)한다.

가격함수를 구성함에 있어서 모든 상태량을 사용하면 최적의 결과를 줄 수 있으나 현실적으로 모든 상태를 구하기란 쉽지 않다. 따라서 상태량의 일부분만을 이용하여 신경망을 학습시킬 수도 있는데 이렇게 하면 sub-optimal 제어기가 구현되는 것이다.

3. 능동질량감쇠기(AMD) 및 전단건물




그림 3 AMD 가 설치된 전단 건물

그림 3 은 능동질량감쇠기가 설치된 3층 전단건물을 보여주고 있다. 이러한 구조물의 운동방정식은 식(7)과 같다.

$$\mathbf{M}\ddot{\mathbf{x}} + \mathbf{C}\dot{\mathbf{x}} + \mathbf{K}(\mathbf{x}, \dot{\mathbf{x}}) = \mathbf{L}f - \mathbf{M}[1]\ddot{x}_g \quad (7)$$

여기서 $\mathbf{M}, \mathbf{C}, \mathbf{K}$ 는 각각 질량행렬, 감쇠행렬 및 강성벡터를 나타내며, \mathbf{L} 은 제어기의 위치를 나타내는 벡터이고 f 는 제어기에서 발생하는 힘을 나타낸다. 또한 \mathbf{x} 와 \ddot{x}_g 는 상대 변위(벡터)와 지진가속도를 의미한다. 한편 AMD 의 구동에 사용되는 유압식 가진기의 운동은 식(8)과 (9)로 묘사할 수 있다.

$$\frac{\tau}{\alpha_1\alpha_2}\dot{q} + \frac{1}{\alpha_1\alpha_2}q = u \quad (8)$$

$$a_r\dot{x}_r + \frac{c_l}{a_r}f + \frac{V}{2\beta a_r}f = q \quad (9)$$

식(8)에서 u 와 q 는 각각 제어신호와 유량속도를, 식(9)의 x_r 은 AMD 와 구조물의 상대변위를 나타낸다. 나머지 상수들은 유압 가진기의 성능과 관련된 것들이다.[참고문헌 2]

비선형 구조물의 제어성능을 검증하기 위하여 구조물의 강성에 의한 복원력을 Bouce-Wen 모델에 의해 식(10)으로 표현한다.

$$r(x) = \theta kx + (1-\theta)kdy \quad (10)$$

이 식에서 k 는 선형강성을 θ 는 선형강성이 차지하는 비율을 각각 의미한다. 그리고 x 는 구조물의 변위이고 y 는 비선형 이력특성을 나타내는 변수로서 식(11)의 미분방정식을 만족한다.

$$\dot{y} = \frac{1}{d}(\rho\dot{x} - \xi|\dot{x}|y|y|^{p-1} - \sigma\dot{x}|y|^p) \quad (11)$$

이 식에서 d, ρ, ξ, σ, p 는 각각 힘과 변위 평면상에서 이력곡선의 모양을 결정짓는 상수들이다.

4. 수치 해석

전단건물 각 층의 질량은 200(kg), 강성은 2.25×10^5 (N/m), 모드별 감쇠는 각각 0.6, 0.7 및 0.3%로 하였다. AMD의 질량은 전체 질량의 3%인 18kg을 사용하였고 AMD의 강성 및 감쇠값은 참고문헌에 의한 최적값을 사용하였다.[6] 해석을 위한 적분 시간 간격은 0.0005초이고 매 0.005초마다 sampling을 하였다. 그리고 제어력의 계산에 필요한 지연 시간은 0.0005초라 가정하였다. 가격함수의 구성은 3층에서의 상태량과 제어신호만을 이용하였다.

신경망의 구조는 입력층-은닉층-출력층으로 구성되었다. 입력층은 상대변위와 상대속도 그리고 지진가속도로 이루어지는 3개의 뉴우런을 가지며 은닉층과 출력층은 각각 3개와 1개씩의 뉴우런을 가진다. 신경망의 학습은 El Centro 지진(1940)시 5초 동안의 응답을 이용하였고 제어 효과의 검증은 El Centro 지진과 Northridge(1994)지진에 대하여 수행하였다. 제어 결과를 그림 4에서 제어를 수행할 때와 그렇지 않을 때의 3층에서의 지상에 대한 상대변위를 비교하였다. 제어결과 El Centro 지진과 Northridge 지진에서 각각 43.1%와 24.2%의 최대 변위 억제 효과를 얻었다.

비선형 구조물의 제어검증을 위해서 식(10)의 θ 값이 0.5일 때를 해석하였다. 비선형 제어기의 학습에는 선형제어와 같이 El Centro 지진을 이용하였으며 Northridge 지진에 대한 검증도 수행하였다. 그림 5는 제어 전·후에 있어서 1층의 변위-복원력 관계를 비교하였다. 제어를 하지 않았을 때는 비선형 이력특성을 보이는 반면 제어를 수행하였을 때는 선형영역 내에서 거동을 하는 것으로 나타났다.

5. 결론

본 연구에서는 신경망을 이용한 구조물의 최적 진동제어 방법을 다자유도 구조물에 적용한 것으로서 AMD와 가진기의 동적특성 및 시간지연 효과를 포함한 성능검증을 수행하였다.[1] 가격함수를 구성함에 있어서는 3층의 상태량과 제어신호만을 이용하는 sub-optimal 제어 기법을 사용하였다. 비선형 구조물의 제어효과를 확인하기 위해서는 이력특성을 가지는 해석적 모델을 이용하여 수치해석 하였다. 수치해석 결과, 3층 전단건물의 진동을 매우 획기적으로 줄일 수 있었다.


감사의 글

본 연구는 BK21 사업의 핵심 연구과제 중 '첨단구조공학사업팀'에 대한 연구비 지원으로 수행된 것으로 연구비 지원에 감사드립니다.

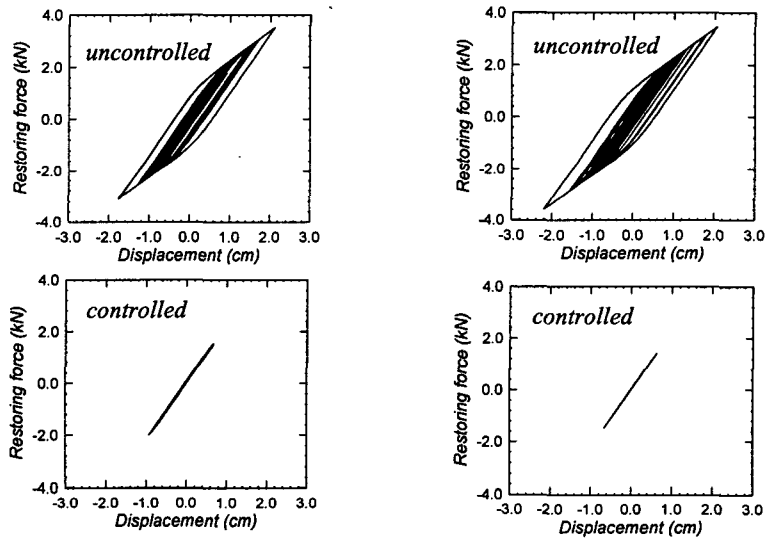
참고 문헌

1. J. T. Kim, H. J. Jung, I. W. Lee(2000), "Optimal Structural Control Using Neural Networks," *ASCE Journal of Engineering Mechanics*, Vol. 126(2), 201-205.
2. K. Bani-Hani, and J. Ghaboussi (1998), "Nonlinear Structural Control using Neural Networks," *ASCE Journal of Engineering Mechanics*, Vol. 124(3), 319-327.
3. H. Irschik, K. Schlacher, and A. Kugi (1998), "Control of Earthquake Excited Nonlinear Structure using Liapunov's Theory," *Computers and Structures*, Vol. 63, 83-90.
4. D. H. Nguyen, and B. Widrow (1990), "Neural Networks for Self-Learning Control Systems," *IEEE Control Systems Magazine*, April, 18-23.

5. H. M. Chen, K. H. Tsai, G. Z. Qi, J. C. S. Yang, and F. Amini (1995), "Neural Network for Structural Control," *ASCE Journal of Computing in Civil Engineering*, Vol. 9(2), 168-176.
6. T. T. Soong & G. F. Dargush (1997), *Passive Energy Dissipation Systems in Structural Engineering*, John Wiley & Sons, England.



(가) El Centro 지진의 경우 (나) Northridge 지진의 경우
 그림 4 3층의 변위 비교(선형 구조물)



(가) El Centro 지진의 경우 (나) Northridge 지진의 경우
 그림 5 1층의 변위-복원력 관계(비선형 구조물)