

구조물의 진동제어를 위한 신경망제어기의 학습법

Learning Rule of Neuro-Controller for Structural Control

김동현* · 한상훈* · 박우선** · 서승남** · 이인원***

Kim, Dong Hyawn · Han, Sang Hun · Park, Woo Sun · Seo, Seung Nam · Lee, In Won

Abstract

Neuro-controller training algorithm based on cost function is applied to multi-degree of freedom system. And sensitivity evaluation algorithm replacing emulator neural network is proposed. In conventional methods, emulator neural network is used to evaluate sensitivity of structural response to control signal. In this case, much of time is usually spent on training of emulator. In the proposed algorithm, however, it takes only one sampling time to obtain the sensitivity. Therefore, training time for emulator is eliminated. In result, only one neural network is used for the neuro-control system. In numerical examples, three-story building structure with linear and nonlinear stiffness is controlled by trained neural network. The actuator dynamics and control time delay are considered in the simulation. Numerical examples show that the proposed control algorithm is valid in structural control.

Keywords : control, sensitivity, neural network, training

요 지

가격함수를 이용한 신경망제어기의 학습기법을 다자유도 구조물에 적용하였으며 에뮬레이터 신경망을 대체 하는 민감도 계산기법을 제안하였다. 기존방법에서 제어신호에 대한 응답의 민감도를 구하기 위해서 에뮬레이터를 사용하였으나 학습시간이 매우 많이 소요되었다. 그러나 제안방법은 단 한단계의 샘플시간만이 소요된다. 그래서 에뮬레이터 신경망의 학습시간을 줄일 수 있다. 결과적으로 한 개의 신경망을 이용하여 제어시스템을 구성할 수 있다. 수치해석에서는 3층 전단건물의 진동제어를 수행하였으며 가진기의 동적효과와 시간지연을 고려하였다. 제안방법은 수치해석에 의하여 그 성능이 검증되었다.

핵심용어 : 제어, 민감도, 신경망, 학습

1. 서 론

인공신경망은 1990년대 이후 공학의 여러 분야에 널리 이용되어 왔으며 특히, 시스템 식별, 최적설계 및

진동제어 등의 연구분야가 그 대표적인 예이다. 그 이유는 인공신경망의 학습기능이 해석적인 답을 얻기 어려운 복잡한 공학문제를 풀 수 있는 새로운 가능성을 제시하였기 때문이다. 구조물의 진동제어 연구도

*한국해양연구원 연안항만공학연구본부 선임연구원

**정회원 · 한국해양연구원 연안항만공학연구본부 책임연구원

***정회원 · 한국과학기술원 토목공학과 교수

신경망이 효과적으로 적용될 수 있는 분야 중 하나이다. 대부분의 진동제어 연구에서는 구조물의 물성을 선형으로 가정하지만 실제로 비선형성이 존재하며 무엇보다도 명확한 수학적 모델을 구성하는 일은 아직까지 쉽지 않은 문제로 남아 있다. 따라서 수학적 모델에 근거하지 않고 단지 구조물의 동적응답만을 이용하여 제어기를 설계할 수 있는 인공신경망기법이 요구되고 있다.

인공신경망(이하 신경망이라 함)을 이용한 구조물의 진동제어에 관한 연구는 Ghaboussi(1995) 등과 Chen(1995) 등에 의해 같은 시기에 제안되었다. 그들은 논문에서 지진 시 구조물의 진동을 억제하기 위한 제어기의 설계에 있어 신경망의 학습기능을 이용할 수 있음을 보였다. 그 후 Nikzad(1996) 등은 가진기의 동적특성과 시간지연효과를 고려한 제어방법을 제안하였다. 또한 Bani-Hani(1998b) 등은 비선형 구조물의 진동제어 방법을 제안하였다.

이와 같은 활발한 연구에도 불구하고 미해결된 두 가지 문제점이 있는데 그 하나는 학습시 목표응답을 구하는 문제이고 다른 하나는 에뮬레이터 신경망(emulator neural network)을 이용해야 하는 문제이다. 첫 번째 문제에 관하여는 Kim(2000b) 등이 가격함수를 이용한 학습방법을 제안하여 1자유도 구조물의 진동제어를 수행한 바 있다. 본 연구에서는 이 학습법을 다자유도 구조물에 적용하여 그 효용성을 검증하였다. 두 번째 문제에 관하여는 에뮬레이터 신경망을 이용하지 않는 새로운 학습방법을 제안함으로써 해결하고자 하였다. 따라서 기존의 방법에서는 제어기와 에뮬레이터에 각각 신경망을 사용하므로써 총 2개의 신경망이 필요하였으나 제안방법에서는 제어기신경망 하나만을 사용하므로써 학습의 효율성을 높였다.

수치해석에서는 지진시 3층 전단건물에 대한 진동제어 예제를 보였으며 이 때 구조물은 선형일 경우와 비선형일 경우 모두를 고려하였다. 가진기로는 건물 최상층의 능동질량감쇠기(active mass damper, AMD)를 이용하였고 유압램프의 동적효과와 시간지연효과를 고려하였다.

2. 신경망을 이용한 진동제어 기법

2.1 신경망의 기초이론

그림 1은 본 논문에서 사용한 다층신경망(multilayer




그림 1 신경망의 구조

perceptron)을 나타내고 있다. 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer) 등 총 3개의 층으로 구성되었으며 각각의 층은 여러 개의 노드(node)로 구성되어 있다. 은닉층은 1개 이상을 사용할 수 있으나 본 연구에서는 1개인 경우로만 제한하였다. 각 층의 노드갯수가 $n1, n2, n3$ 이고 입력층에서의 값이 $I_h(h=1, 2, \dots, n1)$ 로 표현될 때 은닉층에서의 출력값은 다음식으로 표현된다.

$$o_i^1 = f^1(\text{net}_i^1), (i=1, 2, \dots, n2) \quad (1)$$

여기서 f^1 은 활성화함수(activation function)를 나타내고 net_i^1 은 은닉층의 i 번째 노드에서의 입력값으로 식 (2)와 같이 표현된다.

$$\text{net}_i^1 = \sum_{h=1}^{n1} W_{ih}^1 I_h + b_i^1 \quad (2)$$

식 (2)에서 W_{ih}^1 은 입력층과 은닉층 사이의 가중치를 b_i^1 은 은닉층의 편차(bias)값을 의미한다. 이와 같은 방법으로 출력층의 값은 식 (3)으로 표현할 수 있다.

$$o_j^2 = f^2(\text{net}_j^2), (j=1, 2, \dots, n3) \quad (3)$$

식 (3)에서 출력층의 j 번째 입력값은 식 (4)와 같다.

$$\text{net}_j^2 = \sum_{i=1}^{n2} W_{ji}^2 o_i^1 + b_j^2 \quad (4)$$

여기서 W_{ji}^2 은 은닉층과 출력층 사이의 가중치, b_j^2 은 출력층의 편차이다.

신경망을 특정한 목적으로 사용하기 위해서는 가중치와 편차값들을 구해야 하는데 이러한 일련의 과정을 학습이라 한다. 학습은 일반적으로 신경망의 실제 출력값(o_d)과 목표값(o_a)과의 차이를 이용하여 식 (5)와 같이 오차함수를 정의한 후 이 값이 최소화되도록 정한다.

$$E = \sum |o_d - o_a|^2 \quad (5)$$

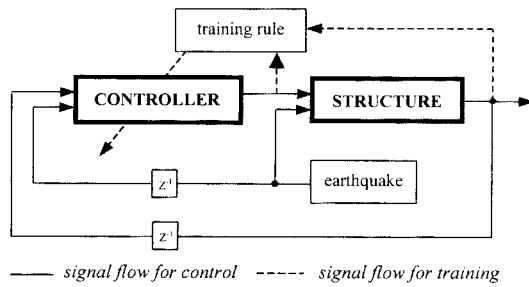


그림 2 제어블럭선도

2.2 제어알고리즘과 학습규칙

그림 2는 신경망을 이용한 진동제어의 블록선도 (block diagram)이다. 외부하중에 의해 가진된 구조물의 진동을 계측하여 신경망 입력으로 사용하고 신경망의 출력을 제어력으로 사용하여 구조물의 진동을 억제한다. 신경망이 적절한 제어력을 만들도록 하기 위해서는 학습을 시켜야 하는데, 기존의 방법에서는 학습시 필요한 민감도 값을 구하기 위해 에플레이터 신경망을 사용하였다. 그러나, 본 연구에서는 직접 민감도 자료를 구하여 사용하므로써 에플레이터를 사용하지 않도록 하여 결과적으로 하나의 신경망만을 이용하도록 하였다. 따라서, 에플레이터 신경망을 학습시키기 위해 소요되던 많은 시간을 단축할 수 있고 제어기신경망 학습시 에플레이터 신경망을 매 단계마다 이용할 필요가 없게 되었다.

제어기 신경망의 학습규칙은 Kim 등(1999, 2000b)이 제안한 가격함수를 이용하여 쉽게 구할 수 있다. 이를 위해 가격함수를 식 (6)과 같이 정의한다.

$$J = \frac{1}{2} \int_0^{T_f} (z^T Q z + u^T R u) dt \quad (6)$$

여기서, $z(n \times 1)$ 와 $u(m \times 1)$ 은 각각 구조물 응답의 상태벡터와 제어력벡터이고 $Q(n \times n)$ 와 $R(m \times m)$ 은 상대 가중치 행렬이다. 그리고 T_f 는 최종제어 시간을 나타낸다. 만일, 구조물의 거동이 선형이고 모두 식별 가능하다면 소위 Riccati 방정식을 이용하면 가격함수를 최소화하는 최적의 제어력을 쉽게 구할 수 있다. 그러나 비선형거동을 하거나 구조계수가 불명확하다면 신경망기법과 같은 지능제어기법의 도입이 필요하게 된다.

제어기의 구현은 현실적으로 디지털 컴퓨터상에서 이루어지므로 식 (6)의 가격함수를 이산영역에서 표현

해야 한다. 따라서 식 (7)의 이산화된 가격함수를 고려하자.

$$\hat{J} = \frac{1}{2} \sum_{k=0}^{N_f-1} (z_{k+1}^T Q z_{k+1} + u_k^T R u_k) = \frac{1}{2} \sum_{k=0}^{N_f-1} \hat{J}_k \quad (7)$$

여기서 k , N_f 및 T_s 는 각각 샘플단계, 총 샘플갯수 및 샘플 간격을 의미한다. 이산화된 가격함수를 최소화하기 위해 gradient descent 규칙을 k 번째 가격함수에 적용하면 은닉층과 출력층 사이의 가중치 수정량은 식 (8)과 같이 표현할 수 있다.

$$\Delta W_{ji}^2 = -\eta \frac{\partial \hat{J}_k}{\partial W_{ji}^2} \quad (8)$$

이 때 η 는 학습량을 조절하는 변수이다. 식 (8)의 편미분을 사슬법칙(chain rule)을 적용하면 식 (9)를 얻을 수 있다.

$$\frac{\partial \hat{J}_k}{\partial W_{ji}^2} = \frac{\partial \hat{J}_k}{\partial net_j^2} \frac{\partial net_j^2}{\partial W_{ji}^2} \quad (9)$$

위 식에서 편미분의 첫 항을 일반화된 오차라하여 식 (10)과 같이 정의하면 가중치의 학습량은 식 (11)로써 최종적으로 표현된다.

$$\delta_j^2 = -\frac{\partial \hat{J}_k}{\partial net_j^2} = -\frac{\partial \hat{J}_k}{\partial o_j^2} \frac{\partial o_j^2}{\partial net_j^2} \quad (10)$$

$$\Delta W_{ji}^2 = \eta \delta_j^2 o_i^1 \quad (11)$$

여기서,

$$\delta_j^2 = -\left(z_{k+1}^T Q \left\{ \frac{\partial z_{k+1}}{\partial u_{k,j}} \right\} + u_k^T r_j \right) G_j(f^2) \Big|_{net_j^2} \quad (12)$$

식 (12)에서 G_j 는 제어력의 이득상수이며 다음식을 만족한다.

$$u_j = G_j o_j^2 \quad (13)$$

그리고 r_j 는 R 행렬의 j 번째 열벡터이다. 같은 방법으로 편차값의 학습량도 식 (14)처럼 구할 수 있다.

$$\Delta b_j^2 = \eta \delta_j^2 \quad (14)$$

입력층과 은닉층 사이의 가중치와 편차값의 학습규칙도 이와 같이 유도할 수 있으며 그 결과는 식 (15)~(17)로 정리된다. 이상의 학습규칙에서 제어력에

대한 상태벡터의 변화량 즉 민감도 값을 제외하고는 모든 값을 쉽게 얻을 수 있다. 그리고 민감도 값은 기존의 신경망 제어에서는 에플레이터를 이용하여 구했다. 즉, 제어력의 입력에 대한 구조물의 거동을 예측하도록 에플레이터를 학습시키고 학습된 에플레이터를 이용하여 민감도를 구해야 했다. 그러나 본 연구에서는 민감도 값을 구하기 위해 다음 장에서 제안하는 민감도 계산법을 이용하므로써 제어기 신경망의 학습을 용이하게 하였다.

$$\Delta W_{ih}^1 = \eta \delta_i^1 I_h \quad (15)$$

$$\delta_i^1 = - \frac{\partial \hat{J}_k}{\partial net_i^1} = - \sum_{j=1}^{n_3} \frac{\partial \hat{J}_k}{\partial net_j^2} \frac{\partial net_j^2}{\partial o_i^1} \frac{\partial o_i^1}{\partial net_i^1} = \sum_{j=1}^{n_3} \delta_j^2 W_{ji}^2 (f^1)' \quad (16)$$

$$\Delta b_i^1 = \eta \delta_i^1 \quad (17)$$

3. 민감도 계산법

응답의 민감도는 구조물의 운동방정식이 명확히 규명된 상태에서는 쉽게 구할 수 있다. 그렇지 않을 경우 신경망 제어기법에서는 에플레이터를 이용해 왔다. 이 방법은 에플레이터 학습에 많은 시간을 소비해야 하는 문제점이 있었다. 이를 개선하기 위해 본 연구에서 제안하는 민감도 계산법을 알아보면 다음과 같다.

상태공간에서의 구조물의 선형 운동방정식은 식 (18)과 같다.

$$\dot{z} = \mathbf{A}z + \mathbf{B}u \quad (18)$$

여기서 $\mathbf{A}(n \times n)$ 와 $\mathbf{B}(n \times m)$ 는 각각 시스템 행렬과 제어력의 위치행렬이다. 이 식을 이산화시키면 식 (19)가 된다.

$$z_{k+1} = \mathbf{G}z_k + \mathbf{H}u_k \quad (19)$$

$\mathbf{G}(n \times n)$ 와 $\mathbf{H}(n \times m)$ 는 0차 근사화방법(zeroth order hold approximation)을 사용하면 다음과 같다(Franklin 등, 1997).

$$\mathbf{G} = e^{\mathbf{A}T_s} \quad (20)$$

$$\mathbf{H} = (e^{\mathbf{A}T_s} - \mathbf{I})\mathbf{A}^{-1}\mathbf{B} \quad (21)$$

식 (21)에서 알 수 있듯이 행렬 \mathbf{H} 는 단지 샘플시간만의 함수이다. 그리고 대부분 샘플시간을 고정하기

때문에 이 행렬은 상수행렬이 된다. 따라서 식 (19)를 k 번째 시간단계의 제어력벡터에 관하여 미분하면 식 (22)를 얻을 수 있다.

$$\frac{\partial z_{k+1}}{\partial u_k} = \mathbf{H} \quad (22)$$

식 (22)가 의미하는 것은 제어력에 대한 응답의 민감도가 행렬 \mathbf{H} 와 일치한다는 것이다. 즉, 민감도를 구하는 것은 행렬 \mathbf{H} 를 구하는 것과 같게 된다. 행렬 \mathbf{H} 를 구하기 위해 구조물이 정지 상태에 있을 때 k 번째 제어기에만 단위 제어력을 가하자. 이 조건은 식 (23)과 (24)로 표현된다.

$$z_k = \mathbf{0} \quad (23)$$

$$u_{j,k} = \begin{cases} 1 & (\text{if } j=i) \\ 0 & (\text{if } j \neq i) \end{cases} \quad j=1,2,\dots,m \quad (24)$$

그러면 식 (19)는 식 (25)가 된다.

$$z_{k+1} = \mathbf{h}_i \quad (25)$$

여기서 \mathbf{h}_i 는 행렬 \mathbf{H} 의 i -번째 열벡터이다. 즉, \mathbf{h}_i 는 한 샘플단계 이후에 발생하는 구조물의 응답이 되는 것이다. 단위 제어력을 각각의 제어기마다 가하고 한 샘플단계 후의 응답을 측정하면 행렬 \mathbf{H} 를 구할 수 있다.

물론, 한 샘플단계 후의 변위와 속도응답을 측정하기 매우 어려운 작은 값이다. 따라서 이보다 훨씬 측정이 용이한 가속도 응답을 측정 후 이를 적분하여 변위와 속도응답을 구해야 한다. 그리고 비선형 구조물일 경우는 이와 같이 구한 민감도 값에 다소 오차가 포함될 수 있지만 신경망 학습시 중요한 것은 절대적인 민감도 값보다 각 민감도의 상대적인 크기이며 학습률을 1보다 작은 값으로 사용하기 때문에 제어기신경망의 학습에는 문제가 되지 않는다.

4. 수치해석

4.1 해석 모델

수치해석에 사용한 모델은 그림 3의 3층 전단건물이다. 본 모델은 여러 문헌에서 사용한 것으로 가진기의 동적 거동과 가진기의 시간 지연 및 건물 층간 강성의 비선형 거동을 묘사하도록 되어 있다. 식 (26)



그림 3 AMD가 설치된 3층 전단건물

은 비선형 거동을 묘사하기 위한 층간 강성에 관한 것이다.

$$k_s(x_s, x_s) = \alpha k_0 x_s + (1 - \alpha) k_0 dy \quad (26)$$

이 식에서 x_s , k_0 및 α 는 각각 층간 변위, 선형강성 및 선형성의 비율을 나타내며 d 와 y 는 이력거동의 특성을 결정짓는 변수로서 식 (27)의 관계를 만족한다.

$$y = \frac{1}{d} (\rho x_s - \mu |x_s| |y|^{p-1} - \alpha x_s |y|^p) \quad (27)$$

이력 거동시 감쇠량과 항복점은 상수 ρ , η 및 σ 에 따라 달라진다.

4.2 동적해석

구조물의 층별 질량은 200 kg, 층간 선형강성은 2.25×10^5 N/m을 사용하였으며 모우드별 감쇠비는 각각 0.6, 0.7 및 0.3%를 사용하였다. 능동질량구동기(AMD)의 질량은 구조물 총 질량의 3%에 해당하는 18 kg을 사용하였다. 가진기의 성능계수는 참고문헌의 값을 그대로 사용하였다. 선형구조물의 해석은 $\alpha = 1.0$ 을 비선형구조물의 해석은 $\alpha = 0.5$ 를 사용하였다. 그리고 샘플시간, 제어기의 시간지연 그리고 적분시간 간격은 각각 0.005초, 0.0005초, 그리고 0.00025초를 사용하였다.

4.3 민감도 계산

3장에서 설명하였듯이 가진기에 단위 제어신호를 가한 후 한 샘플링시간(0.005초) 후의 응답을 측정하




그림 4 민감도 계산을 위한 응답

표 1 민감도 결과

| 항 목 | 정확해 | 제안방법 |
|------------------------------|----------------------------------|-----------------------------------|
| 변위민감도(m/volt) (ratio) | 4.433×10^{-5} (1.00) | 4.436×10^{-5} (1.001) |
| 속도민감도(m/sec/volt) (ratio) | 2.443×10^{-2} (1.00) | 2.441×10^{-2} (0.999) |

으로써 민감도를 계산하였다. 그림 4가 측정된 가속도 신호를 이용하여 변위 및 속도의 민감도를 구한 결과를 보여 준다. 측정시 0.1 g의 잡음신호가 포함되어 있는 가정을 하였으나, 표 1의 결과에서 알 수 있듯이 그 결과가 매우 정확하였다. 이것은 변위와 속도 민감도를 구하기 위하여 가속도민감도를 적분하는 과정에서 측정잡음이 상쇄되는 현상이 발생하기 때문이다. 기존방법으로 민감도를 구하기 위해서는 에뮬레이터를 학습시켜야 하는데 보통 수십분에서 수시간씩 걸리게 된다. 그러나 본 방법에서는 단 한 샘플링시간(0.005초)밖에 걸리지 않기 때문에 신경망제어기의 구성에 필요한 전체 시간을 획기적으로 단축할 수 있다.

4.4 제어기의 학습

제어기 신경망은 입력, 은닉 및 출력층으로 구성되었고 입력층은 3층의 변위, 속도 및 지반 가속도를 위한 3개의 노드를 사용하였다. 은닉층은 3개의 노드를 사용하였고 출력층은 제어신호를 위한 한 개의 노드를 사용하였다. 학습을 위한 가격함수는 모든 상태

값을 사용하지 않고 식 (28)에서와 같이 3층에서의 상태값만을 이용하였다.

$$\hat{J}_k = z_{3,k+1}^T Q z_{3,k+1} + r u_k^2 \quad (28)$$

그리고 상대가중치 행렬은 식 (29) 및 (30)을 사용하였다.

$$Q = \begin{bmatrix} \frac{1}{\tilde{x}_3^2} & 0 \\ \frac{1}{\tilde{x}_3} & \\ 0 & \frac{1}{\tilde{x}_3^2} \end{bmatrix}, \quad r = 0.1 \frac{1}{\tilde{u}^2} \quad (29), (30)$$

이 식에서 \tilde{x}_3 과 \tilde{x}_3 은 El Centro 지진(1940, 0.348 g) 시 발생하는 제어 전 변위와 속도의 최대값이며 \tilde{u} 는 제어신호의 최대값으로 3 volt를 사용하였다. 선형 구조물과 비선형 구조물에 대하여 각각 El Centro 지진 발생 시 제어기 신경망을 학습시켰고 이와 다른 지진

에 대하여 제어기의 성능을 검증하였다.

4.5 제어 성능

학습된 신경망을 이용하여 최대가속도 크기와 주파수 분포가 서로 다른 두개의 지진 즉, Northridge지진(0.334 g)과 Kern County지진(0.158 g)에 대한 제어기의 성능을 검증하였다. 그림 5와 그림 6에서 알 수 있듯이 학습하지 않은 지진이 발생하여도 진동제어 효과가 우수한 것으로 나타났다. 비선형구조물의 제어성능을 알아보기 위해서 각 층간 복원력과 변위관계를 그림 7에 나타내었다. 제어 전 층간의 거동이 이력특성을 보이지만 제어 후에는 그 크기도 작아졌고 모든 응답이 선형영역에 머무는 것으로 확인되었다.

5. 결 론

가격함수를 이용한 신경망 학습법을 다자유도 구조물의 진동제어에 적용하였으며, 특히 에몰레이터 신경망을 사용하지 않고 제어기를 학습시킬 수 있는 기법




그림 5 Northridge 지진시 변위 응답




그림 6 Kern County지진시 변위 응답

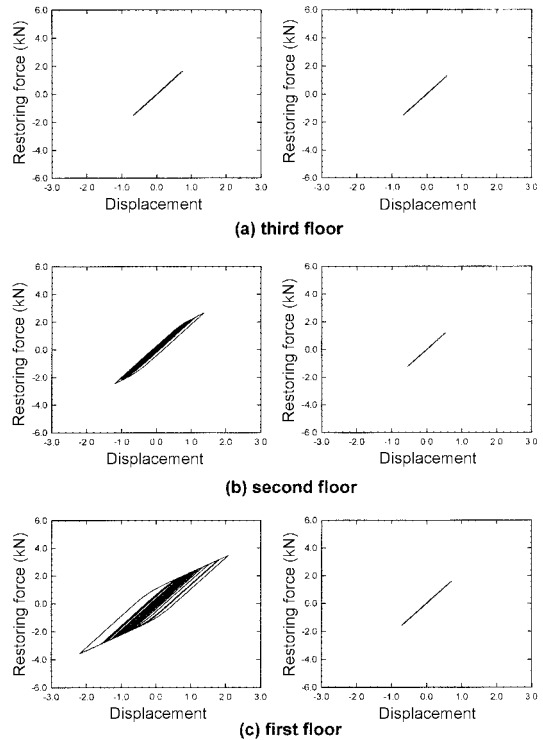


그림 7 Northridge지진시 비선형 구조물의 응답(좌: 제어 전, 우: 제어 후)

을 제안하였다. 따라서 단 한 개의 신경망(제어기 신경망)을 이용하여 진동제어 시스템을 구성할 수 있었다. 제안방법의 민감도 계산법은 비록 선형구조물에 대하여 유도하였지만 비선형 구조물의 진동제어에도 성공적으로 적용됨을 수치해석에서 보였다.

참고문헌

1. Baber, T.T. and Wen, Y.K. (1981) Random vibration of hysteretic degrading systems. *J. Engrg. Mech., ASCE*, Vol. 107, No. 6, pp. 1069-1087.
2. Bani-Hani, K. and Ghaboussi, J. (1998a) Neural networks for structural control of a benchmark problem, active tendon system. *Earthq. Engrg. & Struct. Dyn.*, Vol. 27, pp. 1225-1245.
3. Bani-Hani, K. and Ghaboussi, J. (1998b) Nonlinear structural control using neural networks. *J. Engrg. Mech., ASCE*, Vol. 124, No. 3, pp. 319-327.
4. Chen, H.M., Tsai, K.H., Qi, G.Z., Yang, J.C.S. and Amini, F. (1995) Neural network for structural control. *J. Comput. Civil Engrg., ASCE*, Vol. 9, No. 2, pp. 168-176.
5. Franklin, G.F., Powell, J. D. and Workman, M (1997) Digital control of dynamic systems. 3rd ed. *Addison Wesley*.
6. Ghaboussi, J. and Joghataie, A. (1995) Active control of structure using neural networks. *J. Engrg. Mech., ASCE*, Vol. 121, No. 4, pp. 555-567.
7. Kim, D.H. (2000a) Vibration control of structures using neural networks. Ph.D dissertation, *Dept. of Civil Engineering, Korea Advanced Institute of Science & Technology (KAIST)*, Taejon, Korea.
8. Kim, D.H. and Lee, I.W. (2001) Neuro-control of seismically excited steel structures through sensitivity evaluation scheme, *Earthquake Engineering & Structural Dynamics*, Vol. 30, No. 9, pp. 1361-1377.
9. Kim, J.T., Jung, H.J. and Lee, I.W. (2000b) Optimal structural control using neural networks. *J. Engrg Mech., ASCE*, Vol. 126, No. 2, pp. 201-205.
10. Kim, J.T., Oh, J.W. and Lee, I.W. (1999) Artificial Neural Networks for Structural Vibration Control. *Proc. 1st Int. Conf. on Advances in Structural Engineering and Mechanics*, Seoul, Korea, pp. 23-25.
11. Nikzad, K. and Ghaboussi, J. (1996) Actuator dynamics and delay compensation using neurocontrollers. *J. Engrg. Mech., ASCE*, Vol. 122, No. 10, pp. 966-975.
12. Tang, Y. (1996) Active control of SDF systems using artificial neural networks. *Comput. & Struct.*, Vol. 60, No. 5, pp. 695-703.

(접수일:2001.3.24/심사일:2001.5.22/심사완료일:2001.7.6)