

# 신경망의 입력으로 모달응답을 이용한 지진하중을 받는 구조물의 능동신경망제어

## Active Neuro-control for Seismically Excited Structure using Modal States as the Input of the Neural Network

이 헌 재<sup>1)</sup> · 조 상 원<sup>2)</sup> · 정 형 조<sup>3)</sup> · 이 인 원<sup>4)</sup>  
*Lee, Heon Jae Cho, Sang Won Jung, Hyung Jo Lee, In Won*

요 약 : 본 논문에서는 지진하중을 받는 구조물의 응답을 줄이기 위해 모달 응답을 신경망 제어기의 입력으로 이용하는 새로운 능동제어기법을 제안하였다. 이헌재 등(2003)이 제안한 기존의 신경망을 이용한 지진하중을 받는 구조물의 진동제어는 구조물의 어떤 응답을 신경망의 입력으로 사용할지를 결정해줘야 하는 불편이 있었다. 구조시스템의 자유도가 크지 않으면 상관없지만, 일반적인 토목구조물의 경우 자유도가 무척 크므로 입력으로 어떤 응답을 사용할 것인지를 정하는 문제는 매우 번거롭고 복잡한 작업이라 할 수 있다. 그에 비해 제안방법은 구조물의 첫 번째의 몇 모드응답을 신경망의 입력으로 곧바로 사용하기 때문에 번거로운 작업이 필요하지 않다. 제안방법의 효용성을 증명하기 위해 수치해석을 수행하였다. 김동현(2000, 2001) 등이 제안한 가격함수를 이용한 새로운 신경망 학습기법과 민감도계산기법을 사용하여 학습을 용이하게 하였고, 동일한 초기 가중치를 기존방법과 제안방법에 같이 사용함으로써 공정한 비교를 꾀하였다. 수치예제 결과 제안된 모드응답을 신경망의 입력으로 사용하는 능동 신경망제어기법은 뛰어난 제진효과를 나타내는 기존방법과 거의 비슷한 성능을 발휘하였다. 그러나, 기존방법의 경우 어떤 응답을 입력으로 사용할지를 결정하기 위하여 제안방법보다 15배나 많은 수치해석을 해야하는 번거로움이 있었다. 그러므로 신경망 제어기를 학습시키기 용이한 제안된 능동 신경망제어 방법은 지진하중을 받는 구조물을 제어하는데 있어 매우 효율적인 방법이라할 수 있다.

ABSTRACT: A new active neuro-control strategy for seismic response reduction using modal states is proposed. In order to apply the neuro-control strategy to the given structural system it is needed to select state variables used as inputs into the neural network. If the degrees of freedom of the analytical model is large, there are so many possible combinations of the states variables. And selecting state variables is very complicated and troublesome task for the designer. In order to avoid this problem, the proposed control system adopts modal states as inputs. Since the modal states contain the information of the whole structural system's behavior, it is proper to use modal states as inputs of the neuro-controller. The simulation results show that the proposed active neuro-control strategy is quite effective to reduce seismic responses. In addition, the consuming time for training proposed neuro-controller is quite shorter than that for the conventional neuro-controller. The results of this investigation, therefore, indicate that the proposed active neuro-control strategy using modal states as the inputs could be effectively used for control seismically excited structures.

핵심용어 : 능동제어, 신경망, 모드 응답, 민감도계산기법

KEYWORDS : Active Control, Neural Network, Modal control, Sensitivity evaluation algorithm

### 1. 서론

인공신경망은 인공신경망의 학습기능이 해석적인 답을 얻기 어려운 복잡한 공학문제를 풀 수 있는 새로운 가능성을 제시하였기 때문에 공학의 여러 분야에 널리 이용되어 왔다. 특히, 신경망을 이용한 지진하중을 받는 구조물의 진동제어에 관한 연구는 Ghaboussi 등(1995)과 Chen 등(1995)에 의해 동시에 제안되었다. 그들은 신경망이 구조물의 진동제어의 한 방법이 될 수 있음을 보여주었으나 학습시 목표응답을 구하

- 1) 학생회원, 한국과학기술원, 건설및환경공학과, 박사과정  
(E-mail : wildhawk7@hanmail.net)
- 2) 학생회원, 한국과학기술원, 건설및환경공학과, 박사후연구교수, 공학박사  
(E-mail : wood@kaist.ac.kr)
- 3) 정회원, 세종대학교, 토목환경공학과, 부교수, 공학박사  
(E-mail : hjung@sejong.ac.kr)
- 4) 정회원, 한국과학기술원, 건설 및 환경공학과, 정교수, 공학박사  
(E-mail : iwlee@kaist.ac.kr)

는 문제와 에뮬레이터 신경망을 사용해야하는 등의 문제점이 드러났다. Kim 등(2000)은 가격함수와 민감도 계산기법을 제안함으로써 위와 같은 문제점을 해결하였다. 이현재 등(2003)은 Kim 등이 제안한 새로운 신경망 학습방법을 반응동신경망제어에 적용하여 신경망이 자기유변유체감쇠기를 이용한 반응동제어에 효과적으로 사용될 수 있음을 보여주었다.

기존의 신경망을 이용한 구조물의 진동제어 방법은 대부분 구조물의 응답을 신경망의 입력으로 사용하였다. 그러나 구조물의 자유도가 큰 경우에는 어떤 응답을 신경망의 입력으로 사용할지를 직접 정해줘야한다. 이는 매우 번거로운 작업이다. 그에 비해 모드응답은 모든 층의 정보를 모두 가지고 있기 때문에 모드응답을 신경망의 입력으로 사용한다면 기존의 신경망을 이용한 제어방법보다 더 간편하고 효율적으로 구조물을 제어할 수 있다.

본 연구에서는 센서로부터 측정된 응답을 이용하여 모드응답을 예측하기 위해 칼만필터를 구현하였으며, Spillover problem을 해결하기 위해 low-pass filter를 도입하였다. 수치예제를 통해 제안된 모드응답을 이용한 신경망 제어가 매우 효율적인 제어방법중 하나라는 것을 확인할 수 있었다.

## 2. 기존의 신경망을 이용한 능동제어시스템

기존의 신경망을 이용한 능동제어시스템은 외부하중을 받는 구조물의 응답을 예측하여 신경망의 입력으로 사용하고 신경망의 출력을 제어력으로 사용하여 구조물의 진동을 저감시킨다. 이때, 신경망을 적절한 제어력을 계산하도록 학습시켜야 하는데, 제어기 신경망의 학습규칙은 Kim 등(2002)이 제안한 식 (1)과 같은 가격함수를 이용하여 쉽게 구할 수 있다.

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

여기서  $y(n \times 1)$ 와  $u(m \times 1)$ 은 각각 측정된 구조물 응답의 상태벡터와 제어력 벡터이고,  $Q(n \times n)$ 와  $R(m \times m)$ 은 상대 가중치 행렬이다. 그리고  $k, N_f$ 는 각각 샘플단계, 총 샘플갯수를 의미한다. 일반적으로 토목구조물의 경우 구조물 모델의 자유도는 매우 크다. 이 때, 어떤 응답을 이용하여 신경망을 학습시키고 구조물의 제어를 실현시킬 것인지가 매우 중요한 요소가 된다. 이럴 경우 대부분 제어장치가 설치되어 있는 층과 꼭대기층의 응답이 신경망의 입력으로 많이 선택되지만, 그렇게 학습된 신경망이 가장 좋은 성능을 발휘할 수 있을지는 정확히 알 수 없다. 그러므로 여러 조합을 만들어서 각 경우에 대하여 신경망을 학습시켜보고, 가장 좋은 결과를 나타내는 조합의 신경망을 선택해야하는 번

거로움이 있다.

## 3. 모드응답을 입력으로 사용한 능동제어시스템

기존의 신경망이 식 (1)과 같은 가격함수를 이용하는데 비해, 본 연구에서 제안한 모드응답을 신경망의 입력으로 사용한 능동제어시스템은 식 (2)와 같은 가격함수를 이용한다.

$$\hat{J} = \frac{1}{2} \sum_{k=0}^{N_f-1} \{ \eta_{k+1}^T Q' \eta_{k+1} + u_k^T R u_k \} = \frac{1}{2} \sum_{k=0}^{N_f-1} \hat{J}_k \quad (2)$$

여기서  $\eta(l \times 1)$ 은 저차의 모드응답을  $Q(l \times l)$ 는 새로운 상대 가중치 행렬을 나타낸다. 제안된 방법은 직접적으로 가중치행렬의 차원이 줄어들었으며 ( $l < n$ ), 저차의 모드응답만 가지고 신경망을 학습시킬 수 있기 때문에 기존의 방법보다 매우 간편하다.

가격함수를 최소화하기 위해 gradient descent 규칙을  $k$ 번째 가격함수에 적용하면 본 연구에서 사용한 신경망의 은닉층과 출력층 사이의 가중치 수정량은 다음과 같이 표현될 수 있다.

$$\Delta W_{ji}^2 = -\eta_l \frac{\partial \hat{J}_k}{\partial W_{ji}^2} \quad (3)$$

이 때,  $\eta_l$ 은 학습률이다. 식 (3)의 편미분에 chain rule을 적용하면, 식 (4)을 얻을 수 있다.

$$\frac{\partial \hat{J}_k}{\partial W_{ji}^2} = \frac{\partial \hat{J}_k}{\partial net_j^2} \frac{\partial net_j^2}{\partial W_{ji}^2} \quad (4)$$

일반화된 오차를 식 (5)와 같이 정의하면 가중치 수정량은 최종적으로 식 (6)와 같이 표현된다.

$$\begin{aligned} \delta_j^2 &= -\frac{\partial \hat{J}_k}{\partial net_j^2} = -\frac{\partial \hat{J}_k}{\partial o_j^2} \frac{\partial o_j^2}{\partial net_j^2} \\ &= -\left( \eta_{k+1}^T Q' \left\{ \frac{\partial \eta_{k+1}}{\partial u_{k,j}} \right\} + u_k^T r_j \right) G_j (f^2)' \Big|_{net_j^2} \end{aligned} \quad (5)$$

$$\Delta W_{ji}^2 = \eta_l \delta_j^2 o_i^1 \quad (6)$$

여기서  $r_j$ 는  $R$ 행렬의  $j$ 번째 열벡터이고,  $G_j$ 는 제어력의 이득상수이며 다음 식을 만족한다.

$$u_j = G_j o_j^2 \quad (7)$$

같은 방법으로, 편차값의 학습량도 식 (8)처럼 구할 수 있다.

$$\Delta b_j^2 = \eta_l \delta_j^2 \quad (8)$$

본 연구에서 사용한 신경망의 입력층과 은닉층 사이의 가중치와 편차값의 학습규칙도 같은 방법으로 식 (9)부터 식 (11)처럼 유도된다.

$$\begin{aligned} \Delta W_{ih}^1 &= \eta_l \delta_i^1 I_h \\ \delta_i^1 &= -\frac{\partial \hat{J}_k}{\partial net_i^1} = -\sum_{j=1}^{n_3} \frac{\partial \hat{J}_k}{\partial net_j^2} \frac{\partial net_j^2}{\partial o_i^1} \frac{\partial o_i^1}{\partial net_i^1} \\ &= \sum_{j=1}^{n_3} \delta_j^2 W_{ji}^2 (f') \Big|_{net_i^1} \end{aligned} \quad (9)$$

$$\Delta b_i^1 = \eta_l \delta_i^1 \quad (10)$$

여기서 민감도  $\{\partial \eta_{k+1} / \partial u_{kj}\}$ 는 Kim 등(2001)이 제안한 민감도 계산기법을 모드응답에 적용하여 구할 수 있었다.

## 4. 수치해석

### 4.1 해석모델

수치해석에서 사용한 모델은 Jansen과 Dyke 등(2000)이 사용한 그림 1의 6층 전단건물이다. 1층과 2층에 제어장치가 설치되어 있다.




그림 1. 수치해석모델 (Dyke et al, 1996)

### 4.2 해석방법

공정한 비교를 위하여 수치해석에서는 기존방법과 제안방법 모두 입력, 은닉, 출력층으로 구성된 동일한 신경망을 사용하였다.

또한, 임의로 100개의 초기 가중치를 선정하여 동일한 조건 하에서 학습될 수 있도록 하였다. 기존의 신경망제어는 표 1과 같은 조합으로 각 층의 변위와 속도 및 지반의 가속도를 입력으로 사용하였고, 제안된 신경망제어에서는 첫 번째 모드 응답(변위, 속도)과 지반의 가속도를 입력으로 사용하였다. 각각 대표적인 지진인 El Centro 지진(1940, 0.348 g)으로 학습하였고, 제안방법의 효용성을 증명하기 위하여 Kobe 지진(1995, 0.8337 g)과 California 지진(1994, 0.156 g)으로 검증하였다.

	1층	2층	3층	4층	5층	6층
1층		-	-	-	-	-
2층	(1)		-	-	-	-
3층	(2)	(6)		-	-	-
4층	(3)	(7)	(10)		-	-
5층	(4)	(8)	(11)	(13)		-
6층	(5)	(9)	(12)	(14)	(15)	

표 1. 기존 신경망의 입력 조합

### 4.3 성능기준지표

Jansen과 Dyke 등(2000)은 다음과 같은 네가지 성능기준지표를 제시하여 각 제어방법의 성능을 비교하였다.

$$\begin{aligned} J_1 &= \max \left( \frac{|x_i(t)|}{x^{\max}} \right), \quad J_2 = \max \left( \frac{|d_i(t)/h_i|}{d_n^{\max}} \right), \\ J_3 &= \max \left( \frac{|\ddot{x}_{ai}(t)|}{\ddot{x}_a^{\max}} \right), \quad J_4 = \max \left( \frac{|f_i(t)|}{W} \right) \end{aligned} \quad (10)$$

이는 각각 최대변위, 최대층간변위, 최대절대가속도, 최대제어력에 대한 성능지표이다.

### 4.4 해석결과

표 2에는 기존 신경망의 학습에서 각 조합의 학습의 성공여부를 나타내었다. 여기서 성공적인 학습이란 네 가지 성능기준지표중 J1, J2, J3(제어성능과 관련된 성능기준지표)가 모두 1보다 작은 경우(제어하지 않았을 때보다 작은 경우)가 전체 100

개 중 하나라도 있는 경우를 말한다. 각 조합의 학습에 소모되는 시간은 평균적으로 12시간 정도였다.

표 2 각 조합의 학습 성공 여부 (S : 학습성공, F : 학습실패)

	1층	2층	3층	4층	5층	6층
1층		-	-	-	-	-
2층	S		-	-	-	-
3층	S	S		-	-	-
4층	S	F	F		-	-
5층	S	F	F	F		-
6층	S	S	F	F	F	

표 3. 각 조합의 성능기준지표 J1 (최대변위)

	1층	2층	3층	4층	5층	6층
1층		-	-	-	-	-
2층	0.309		-	-	-	-
3층	0.443	0.332		-	-	-
4층	0.407	F	F		-	-
5층	0.386	F	F	F		-
6층	0.410	0.393	F	F	F	

표 4. 각 조합의 성능기준지표 J2 (최대층간변위)

	1층	2층	3층	4층	5층	6층
1층		-	-	-	-	-
2층	0.453		-	-	-	-
3층	0.499	0.746		-	-	-
4층	0.508	F	F		-	-
5층	0.555	F	F	F		-
6층	0.465	0.888	F	F	F	

표 5. 각 조합의 성능기준지표 J3 (최대절대가속도)

	1층	2층	3층	4층	5층	6층
1층		-	-	-	-	-
2층	0.852		-	-	-	-
3층	0.730	0.709		-	-	-
4층	0.373	F	F		-	-
5층	1.328	F	F	F		-
6층	0.569	1.017	F	F	F	

표 3부터 표 5까지는 각각의 조합으로 학습된 신경망 중 가장 좋은 성능을 내는 신경망의 성능기준지표가 나타나있다. 또한 그림 2는 각 조합의 성능을 보기 좋게 그래프로 나타낸 것이다. 전체적으로 보았을 때, 1층과 4층의 응답을 신경망의 입력으로 사용한 경우가 가장 좋은 결과를 나타낸다고 볼 수 있다. 또한 1층의 최대가속도를 나타낸 (b)에서는 오히려 제안방법이 능동 신경망 제어보다도 더 성능이 좋은 것으로 나타났다. 최대제어력에 대한 (c)에서도 제안 방법은 능동 신경망제어나 clipped 최적제어보다 대체적으로 더 작은 최대

제어력을 갖는 것으로 나타났다. 결론적으로, 제안방법이 기존 방법보다 더 작은 제어력으로 더 좋은 성능을 내고 있다




그림 2. 각 조합의 성능기준지표 비교

표 6 기존방법과 제안방법의 성능비교

	J1	J2	J3	J4
기존방법	0.407	0.508	0.373	0.0178
제안방법	0.376	0.528	0.553	0.0148






그림 3. 제안방법의 각 지진에 대한 성능 (6층 변위)

는 것을 알 수 있다.

표 6은 기존 방법중에 가장 좋은 결과를 나타내고 있는 1층과 4층의 응답을 입력으로 사용한 신경망과 제안방법으로 학습시킨 신경망의 성능을 비교한 표이다. 기존방법이 제안방법

보다 약간 더 좋은 성능을 보이고 있지만, 그 차이는 크지 않다고 볼 수 있다. 그러나 제안방법으로 학습시킨 신경망은 학

표 7 California 지진에 대한 성능비교

	J1	J2	J3	J4
기존방법	0.146	0.196	0.458	0.0071
제안방법	0.148	0.217	0.432	0.0059

표 8 Kobe 지진에 대한 성능비교

	J1	J2	J3	J4
기존방법	0.356	0.342	0.584	0.0178
제안방법	0.322	0.335	0.501	0.0178

습에 소모되는 시간이 12시간 인데 비해, 기존방법은 그 15배 정도가 더 소비되었고, 구조물의 자유도가 커지면 커질수록 그 차이는 더욱더 커질것이다. 즉, 신경망의 입력을 정하는데 있어서 번거로운 작업을 거쳐야 하는 기존의 신경망보다 입력을 정할 필요없이 저차의 모드응답을 입력으로 사용하는 제안된 신경망이 더 효과적인 방법이라 할 수 있다.

제안방법의 효율성을 증명하기 위하여 그림 3에서처럼 학습시킨 지진과 주파수분포나 규모가 다른 California 지진과 Kobe 지진으로 학습된 신경망을 검증하였다. 또한 표 7과 표 8에서는 각각의 지진에 대한 기존방법과 제안방법의 성능을 비교하였다. El Centro 지진에서와 마찬가지로 제안방법의 성능이 기존방법에 비해 많이 떨어지지 않음을 확인할 수 있다. 그러므로 번거로운 입력선택과정이 필요없는 제안방법이 효율적인 방법이라 할 수 있다.

## 5. 결론

본 연구에서는 지진하중을 받는 구조물의 응답을 감소시키기 위해 모드응답을 입력으로 사용하는 능동 신경망 제어방법을 제안하였다. 제안방법의 효율성을 증명하기 위해서 6층 전단 건물 모형을 이용한 수치해석을 수행하였다. 수치해석 결과, 지진의 종류에 관계없이 제안방법의 성능이 기존방법의 성능보다 크게 떨어지지 않음을 알 수 있었다. 그러나 기존방법은 신경망의 입력을 결정하기위해 번거로운 작업을 수행해야 하기 때문에 저차의 모드응답을 곧바로 입력으로 사용하게 되는 제안방법이 더 간편하다고 볼 수 있다. 그러므로 제안된 모드응답을 신경망의 입력으로 사용하는 능동 신경망 제어방법은 지진하중을 받는 구조물의 진동을 저감시키는데 매우 효율적인 방법이다.

## 감사의 글

본 연구는 국가지정 연구실(과제번호: 2000-N-NL-01-C-251)과 스마트 사회기반시설 연구센터의 지원하에 수행되었습니다. 지원에 깊은 감사를 드립니다.

## 참고문헌

1. Chen HM, Tsai KH, Qi GZ, Yang JCS, Amini F, 1995, "Neural Network for Structural Control", ASCE Journal of Computing in Civil Engineering, Vol.9, No.2, pp.168-176.
2. Dong-Hyawn Kim, In-Won Lee, 2001, "Neuro-control of Seismically Excited Steel Structure through sensitivity evaluation scheme", Earthquake Engineering and Structural Dynamics, Vol.30, No.9, pp.1361-1378.
3. Dyke SJ, Spencer BF Jr., 1996, "Modeling and Control of Magnetorheological Damper for Seismic Response", Smart Material and Structures, Vol.5, No.5, pp.565-575.
4. Ghaboussi, J. and Joghataie, A., 1995, "Active Control of Structure using Neural Network", ASCE Journal of Engineering Mechanics, Vol.121, No.4, pp.555-567.
5. Ju-Tae Kim, Hyung-Jo Jung, In-Won Lee, 2000, "Optimal Structural Control using Neural Networks", ASCE Journal of Engineering Mechanics, Vol.126, No.2, pp.201-205.
6. B. F. Spencer Jr., S. J. Dyke, M. K. Sain and J. D. Carlson, 1996, "Phenomenological model of a magnetorheological damper," ASCE Journal of Engineering Mechanics, pp. 230-238.
7. Sang-Won Cho, Byoung-Wan Kim, Hyung-Jo Jung, In-Won Lee, Accepted for Publication, "Implementation of Modal Control for Seismically Excited Structures using MR Dampers," ASCE Journal of Engineering Mechanics.
8. 이헌재, 정형조, 오주원, 이인원, 2003, "자기유변유체감쇠기의 독특성을 고려한 지진하중을 받는 구조물의 반능동 신경망 제어," 한국지진공학회 춘계학술발표회 논문집, pp. 473-480.