

격자 확률신경망 기법을 이용한 구조물의 능동 제어

Active Control of Structures Using Lattice Probabilistic Neural Network

장성규† · 김두기* · 김동현** · 정희영***

Seong Kyu Chang, Doo Kie Kim, Dong Hyawn Kim and Hie-Young Jung

Key Words : 능동 제어, 격자 확률신경망, 구조물, 지진

ABSTRACT

A new neuro-control scheme for active control of structures is proposed. It utilizes lattice pattern of state vector as training data of probabilistic neural network (PNN). Therefore, it is the so-called lattice probabilistic neural network (LPNN). PNN makes control forces by using all the training patterns. Therefore, it takes much time to obtain a control force in application. This inevitably may delay the control action. However, control force of LPNN is calculated by using only the adjacent information of LPNN input. So, the response of LPNN is greatly faster than PNN. The proposed control algorithm is applied for one story building under California and El Centro earthquakes. Also, control results of the LPNN are compared with those of the conventional PNN. The structural responses have been suppressed effectively by the proposed algorithm.

1. 서 론

지난 30 년 동안, 구조물의 진동을 줄이기 위한 다양한 진동 제어 방법들에 관한 연구가 수행·개발되었다. 그 중에 지난 10 년 동안 신경망을 이용한 구조물의 능동제어는 Chen⁽¹⁾, Ghaboussi⁽²⁾, Bani-Hani⁽³⁾ 및 Kim⁽⁴⁾ 등에 의해 연구되었다. 위의 논문들에서는 지진 시 구조물의 진동을 줄이기 위한 인공신경망의 학습능력을 제시하였으며, 구조물의 진동을 효과적으로 줄일 수 있었다. 그러나, 일반적인 신경망 방법은 네트워크를 학습하는데 많은 시간이 소요되는 단점이 있으며⁽⁶⁾, 이에 대한 대책으로 최근에는 Kim⁽⁵⁾이 구조물의 진동을 줄이기 위하여 Cerebellar Model Articulation Controller (CMAC)를 적용하였으며, 기존의 신경망의 제어 결과와 비교하여 좋은 결과를 도출하였다. Kim⁽⁷⁾ 등은 구조물의 제어에서 인공신경망의 학습시간을 피하기 위하여 확률신경망을 이용한 제어 방법을 제안하였으며, 지진 시 단순 구조물에 대하여 좋은 성능을 보여주었다. 그러나, 확률신경망을 이용한 제어 방법은 제어력을 계산하기 위하여 많은 양의 계산을 해야 하는 단점이 있다. 즉, 확률신경망은 입력값과 모든 훈련 패턴과의 유클리드 거리를 계산하여 메모리에 저

장하며, 가장 가까운 훈련패턴을 제어력으로서 출력한다. 또한 제어 결과의 보다 나은 정밀도를 위해서 확률신경망의 훈련패턴을 하나 증가시키면, 계산시간 또한 그 수만큼 증가하게 된다.

이러한 확률신경망의 단점을 보완하기 위하여, 훈련패턴을 준비하고, 확률신경망의 출력을 계산하는 새로운 방법을 제시하였다. 기존의 확률신경망의 훈련패턴은 상태공간에서 임의로 분포되어 있는 반면, 본 논문에서 제안된 확률신경망의 훈련패턴을 상태공간에서 격자 점에 일정하게 분포시켰다. 제안된 방법의 훈련패턴이 격자형태로 되어 있어, 본 논문에서는 이를 격자 확률신경망이라 하였으며, 격자 확률신경망에서 훈련패턴이 규칙적으로 분포되어 있기 때문에 입력 값의 위치를 쉽게 알 수 있게 되었다. 게다가, 격자 확률신경망의 출력은 단지 입력패턴 주위의 훈련패턴만을 이용하여 간단하게 계산할 수 있어 실제 예제에서 격자 확률신경망의 계산 시간을 상당히 줄일 수 있었다.

본 논문에서는 제안된 격자 확률신경망을 이용하여 1 층 전단 건물 모형을 제어하였으며, 제안된 격자 확률신경망 제어기의 성능을 검증하기 위하여 California 지진 및 El Centro 지진을 사용하였다. 또한 본 논문에서는 Northridge 지진에 대하여 격자 확률신경망의 제어 결과와 기존의 확률신경망의 결과⁽⁷⁾와 비교를 수행하였으며, 제안된 격자 확률신경망 알고리즘이 구조물을 더 효과적으로 제어 할 수 있었다.

† 책임저자; 군산대학교 토목환경공학부 박사과정
E-mail : s9752033@kunsan.ac.kr
Tel : (063) 469-4770, Fax : (063) 469-4791

* 군산대학교 토목환경공학부 교수

** 군산대학교 해양시스템공학과 교수

*** 서울시립대학교 토목공학과 교수

2. 격자확률신경망을 이용한 능동제어

2.1 상태공간방정식

본 논문에서 사용된 지진하중과 제어력을 받는 1 자유도 구조물의 운동방정식은 다음과 같다.

$$m\ddot{u} + c\dot{u} + ku = \bar{L}_c f_c + \bar{L}_e f_e \quad (1)$$

여기서 m , c 및 k 는 각각 구조물의 질량, 감쇠 및 강성행렬; $u(t)$ 는 변위; $f_c(t)$ 는 제어력; $f_e(t)$ 는 지진 가속도 (\ddot{u}_g)에 비례하는 외력으로 식 (2)와 같으며; \bar{L}_c 와 \bar{L}_e 는 각각 제어력과 외력의 작용 위치를 나타내는 위치 행렬로 다음과 같다.

$$f_e = -m\ddot{u}_g \quad (2)$$

$$\bar{L}_c = \langle 1 \rangle \quad (3)$$

$$\bar{L}_e = \langle 1 \rangle \quad (4)$$

운동방정식의 양변에 $\frac{1}{m}$ 을 곱하면 식 (1)은 다음과 같으며

$$\ddot{u} = -\frac{c}{m}\dot{u} - \frac{k}{m}u + \frac{\bar{L}_c}{m}f_c + \frac{\bar{L}_e}{m}f_e \quad (5)$$

변위와 속도를 식 (7)이라 하고, 식 (5)를 정리하면, 식 (6)의 상태공간 방정식으로 나타낼 수 있다.

$$\dot{z} = \mathbf{A}z + \mathbf{L}_c f_c + \mathbf{L}_e f_e \quad (6)$$

$$z(t) = \langle u(t) \quad \dot{u}(t) \rangle^T \quad (7)$$

$$\mathbf{A} = \begin{bmatrix} 0 & I \\ -\frac{k}{m} & -\frac{c}{m} \end{bmatrix} \quad (8)$$

$$\mathbf{L}_c = \begin{bmatrix} 0 \\ \frac{\bar{L}_c}{m} \end{bmatrix} \quad (9)$$

$$\mathbf{L}_e = \begin{bmatrix} 0 \\ \frac{\bar{L}_e}{m} \end{bmatrix} \quad (10)$$

여기서 $z(t)$ 는 상태 벡터; \mathbf{A} 는 시스템 행렬; \mathbf{L}_c 및 \mathbf{L}_e 는 상태공간에서 제어력과 외력의 위치를 나타내는 행렬이다⁽⁸⁾.

2.2 훈련패턴과 제어력

격자 확률신경망 제어기의 훈련패턴은 Fig. 1과 같이 상태벡터 (u_k, \dot{u}_k)와 제어력 ($f_{j,k}$)의 격자 형태로 구성된다. 상태벡터는 임의의 구조물의 응답을 최대 및 최소 값 사이의 일정한 간격으로

나누었으며, 제어력은 위의 상태벡터 ($z: u_k, \dot{u}_k$)와 제어이득 (\mathbf{G})의 곱으로 다음과 같다.

$$f_{j,k} = -\mathbf{G} \cdot z = -(\mathbf{R}^{-1} \cdot \mathbf{L}_e^T \cdot \mathbf{S}) \cdot z \quad j, k = -3, \dots, 3 \quad (11)$$

여기서 \mathbf{S} 는 다음의 Riccati 방정식의 해이다.

$$\mathbf{A}^T \mathbf{S} + \mathbf{S} \mathbf{A} - \mathbf{S} \mathbf{L}_e \mathbf{R}^{-1} \mathbf{L}_e^T \mathbf{S} + \mathbf{Q} = 0 \quad (12)$$

여기서 \mathbf{Q} 와 \mathbf{R} 은 가중치 행렬을 나타낸다. 격자 확률신경망 제어기의 계산 과정은 2.3 절에서 설명하기로 한다.

2.3 격자확률신경망

Fig. 1은 두 개의 입력 (구조물의 변위와 속도)과 한 개의 출력(제어력)을 갖는 격자 확률신경망의 구조를 나타낸다. 본 논문에서는 제어력의 계산 시간을 줄이기 위하여, 격자 확률신경망의 훈련패턴을 상태공간에서 일정하게 격자 형태로 분포시켰다. 따라서, 상태공간에서 주어진 어떠한 입력도 그 위치를 다음 식으로 쉽게 알 수 있다.

$$position = \left(\frac{u_k + \frac{s}{2}}{j}, \frac{\dot{u}_k + \frac{v}{2}}{k} \right) \quad (13)$$

여기서 u_k 와 \dot{u}_k 는 각각 k 시간에서의 변위와 속도를 나타내며; j 와 k 는 상태공간에서 훈련패턴의 일정한 간격; s 와 v 는 각각 훈련패턴의 변위축과 속도축의 크기를 나타내며; $position$ 는 상태공간에서 주어진 입력의 위치를 나타낸다. 주어진 입력 주위의 훈련패턴은 식 (14)–(17)을 이용하여 바로 구할 수 있다.

$$j_1 = \text{ceil} \left[\frac{u_k + \frac{s}{2}}{j} \right] \quad (14)$$

$$j_2 = \text{ceil} \left[\frac{u_k + \frac{s}{2}}{j} \right] - 1 \quad (15)$$

$$k_1 = \text{ceil} \left[\frac{\dot{u}_k + \frac{v}{2}}{k} \right] \quad (16)$$

$$k_2 = \text{ceil} \left[\frac{\dot{u}_k + \frac{v}{2}}{k} \right] - 1 \quad (17)$$

여기서 $\text{ceil}(\cdot)$ 은 입력값보다 큰 가장 작은 정수를 계산하는 함수이며, 식 (14)–(17)은 주어진 입력 주위의 네 지점을 나타낸다. 격자 확률신경망은 주위의 훈련패턴을 쉽게 알 수 있기 때문에 모든 훈련패턴의 유클리드 거리를 구할 필요가 없다. 그러나, 기존의 확률신경망은 주어진 입력 주위의 훈련패턴을 알 수 없기 때문에 입력패턴(구조물의 변위와 속도)과 모든 훈련패턴과의 거리를 구해야만 한다. 기존 확률신경망의 유클리드 거리의 총수는 $n \times m$ 으로 나타낼 수 있으며, 여기서 n 은

훈련패턴의 수를 m 은 상태공간에서 자유도를 나타낸다. 그러나, 격자 확률신경망은 단지 $4 \times m$ 개의 계산만 필요하다. 따라서, 격자 확률신경망은 제어력을 매우 간단하고 빠르게 계산 할 수 있었다.

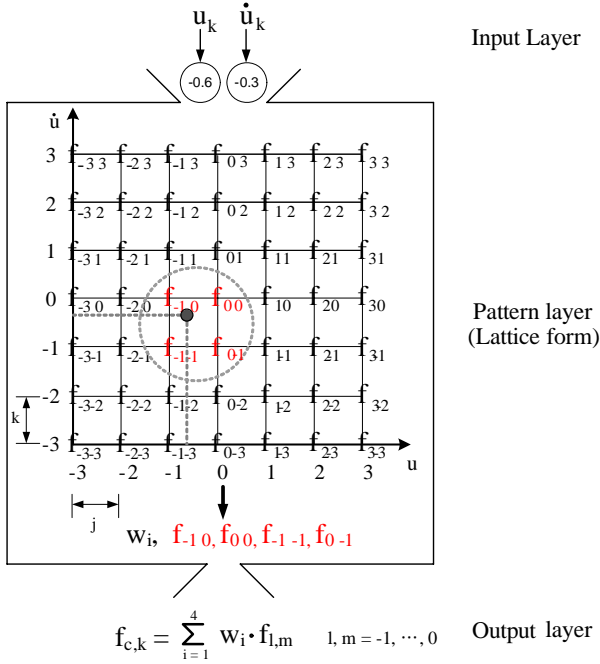


Fig. 1 Structure of LPNN

격자 확률신경망의 입력패턴(구조물의 응답)과 훈련패턴(격자형태)과의 거리는 다음 식으로 구할 수 있다.

$$dist_i = \sqrt{\sum (\mathbf{X} - \mathbf{Y})^2} \quad i=1, \dots, 4 \quad (18)$$

여기서 \mathbf{X} 는 k 시간에서의 입력패턴 (u_k, \dot{u}_k) 이고; \mathbf{Y} 는 입력패턴 주위의 네 개의 훈련패턴 ($[u_l, \dot{u}_m]$) 이다(Fig. 1). 학습층에서 계산된 거리는 다음 식에 의해 가중치 (weight) 로 전환된다.

$$w_i = \frac{pd_i}{sp}, \quad pd_i = \frac{(sd - dist_i)}{2} \quad i=1, \dots, 4 \quad (19)$$

여기서 sd 는 거리의 총 합; pd_i 는 훈련패턴의 가중치 참여율; sp 는 pd_i 의 총 합; w_i 는 거리에 따른 훈련패턴의 가중치를 나타낸다. 출력층에서는 실질적으로 구조물에 가해지는 제어력을 출력하게 되며, 제어력 ($f_{c,k}$) 은 식 (20) 과 같이 입력패턴 주위의 훈련패턴에 해당하는 제어력 ($f_{l,m}$) 과 입력패턴과의 거리에 따라 계산된 가중치 (w_i) 의 곱으로 계산된다.

$$f_{c,k} = \sum_{i=1}^4 w_i \cdot f_{l,m} \quad i=1, \dots, 4 \quad (20)$$

1. 예제 해석

본 논문에서는 제안된 방법을 적용하기 위하여 Fig. 2 과 같이 active tendon system 이 설치된 1 층 전단 건물 모델을 사용하였다. 미지의 동적 하중에 대한 제안된 제어 알고리즘의 성능을 검증하기 위하여 California 지진 (1952, 0.152g) 및 El Centro 지진 (1940, 0.341g) 을 사용하였다. 위의 두 지진에 대하여 예제 모델을 제어하기 위한 격자 확률신경망 제어기의 블록다이어그램을 Fig. 3 에 나타냈다.




Fig. 2 Example building






Fig. 3 Block diagram of LPNN controller

2. 제어 결과

California 지진 및 El Centro 지진을 받는 구조물의 제어 전과 후의 응답을 Fig. 4 에 나타냈으며, 두 지진에 대하여 제안된 제어 알고리즘을 사용했을 때 구조물의 최대 변위 감소율은 각각 56.65% 및 59.56%로 효과적으로 감소하였다. Fig. 4로부터, 제안된 격자 확률신경망의 제어 알고리즘이 미지의 지진 하중에 대하여 구조물의 응답을 효과적으로 제어할 수 있음을 알았다. Fig. 5 는 각 지진에 대하여 제안된 알고리즘에 의해 계산된 제어력을 나타낸다.




(a) California earthquake




(b) El Centro earthquake

Fig. 4 Comparison of the uncontrolled and controlled response of structure



(a) California earthquake



(b) El Centro earthquake

Fig. 5 Control force corresponding to each earthquake

또한, 본 논문에서는 Northridge 지진에 대하여 제안된 격자 확률신경망의 제어 성능을 검증하기 위해 기존의 확률신경망⁽⁸⁾의 제어 결과와 비교해 보았다. 비교 결과, 제안된 격자 확률신경망 제어기가 기존 확률신경망에 비해 구조물의 변위와 속도를 각각 10.91%와 8.56%로 더 줄일 수 있었으며, Fig. 6 과 같이 4 초 이후의 격자 확률신경망의 제어 결과는 기존 확률신경망의 결과와 확연한 차이를 보여주었다. 또한, 격자 확률신경망은 하나의 시간간격에 대하여 제어력을 계산하는데 걸리는 시간이 $2.50e-04$ 초가 소요되는 것에 반하여, 기존의 확률신경망은 $1.82e-02$ 초가 소요됐다. 이는 매 0.01 초에 구조물을 제어해야 될 때, 기존의 확률신경망은 허용시간보다 너무 많은 계산시간이 소요되기 때문에 구조물은 불안정한 거동을 보이게 될 것이다.

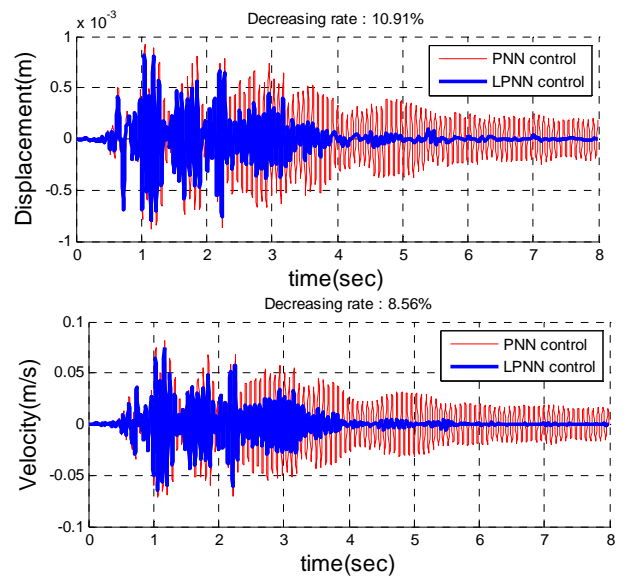


Fig. 6 Controlled responses by the LPNN and the PNN

그렇지만, 격자 확률신경망은 제어하기 위한 시

간 간격보다 더 짧은 시간 안에 제어력을 계산하므로 시간에 제약을 받지 않는다. 왜냐하면, 기존의 확률신경망은 구조물의 상태벡터와 모든 훈련패턴과의 거리를 계산하지만, 제안된 격자 확률신경망은 단지 구조물의 상태벡터와 그와 관련된 네개의 훈련패턴과의 거리만 계산하기 때문이다.

5. 결론

본 논문에서는 격자 확률신경망이라는 제어 알고리즘을 제안하였다. 격자 확률신경망은 제어력 계산을 효과적으로 줄이기 위하여 격자 형태로 훈련패턴을 채택하였으며, 이 격자 형태의 훈련패턴으로 인하여 격자 확률신경망은 어느 입력패턴이 주어지더라도 입력패턴 주위의 훈련패턴을 바로 지정할 수 있게 되었고, 그 주위 훈련패턴의 가중치의 합으로부터 제어력을 구할 수 있었다. 1층 전단건물 제어 예제에서 격자 확률신경망은 제어력 계산 시간이 거의 소요되지 않는 반면, 기존 확률신경망은 제어력 계산에서 상대적으로 긴 시간이 소요되어 실제 문제에 적용하는데 어려움이 따를 것이다.

California 지진 및 El Centro 지진을 사용하여 미지의 지진하중에 대하여 제안된 격자 확률신경망 알고리즘을 검증하였으며, 구조물의 응답을 줄이는데 매우 효과적이었다. 또한 본 논문에서는 Northridge 지진에 대하여 기존 확률신경망의 제어 결과도 비교하였으며, 격자 확률신경망 제어기가 구조물의 응답 감소와 제어력 계산 시간에 있어서 더 효과적이었음을 알 수 있었다.

후 기

이 논문은 2006 년도 정부(과학기술부)의 재원으로 한국과학재단의 지원을 받아 수행된 연구임 (No. R01-2006-000-10610-0)

참고문헌

- (1) Chen, H.M., Tsai, K.H., Qi, G.Z., Yang, J.C.S., and Amini, F., 1995, "Neural network for structural control", ASCE Journal of Computation in Civil Engineering, Vol. 9, No.2, pp. 168~176
- (2) Bani-Hani, K., and Ghaboussi, J., 1998, "Nonlinear structural control using neural networks", ASCE Journal of Engineering Mechanics, Vol. 124, No. 3, pp. 319-328
- (3) Ghaboussi, J. and Joghataie, A., 1995, "Active control of structure using neural networks" ASCE Journal of Engineering Mechanics, Vol. 121, No. 4, pp. 555-567
- (4) Kim, D.H., Oh, J.W., and Lee, I.W., 2002, "Cerebellar Model Articulation Controller (CMAC) for Suppression of

Structural Vibration", ASCE Journal of Computing in Civil Engineering, Vol. 16, No.4, pp. 291-298

(5) Kim, D.H., and Lee, I.W., 2001, "Neuro-control of seismically excited steel structure through sensitivity evaluation scheme", Earthquake Engineering and Structural Dynamics. Vol. 30, pp. 1361-1377

(6) Madan, A., 2005, "Vibration control of building structures using self-organizing and self-learning neural networks", Journal of sound and vibration, Vol. 287, No.4/5, pp. 759-784

(7) Kim, D.K., Lee, J.J., Chang, S.K., and Chang, S.K., 2007, "Active Vibration Control of a Structure Using Probabilistic Neural Network", In proceeding of the TRB 86th Annual Meeting, Washington, D.C., February.

(8) Soong, T.T., 1990, Active Structural Control: Theory and Practice, Longman Scientific and Technical

(9) Specht, D.F., 1990, "Probabilistic Neural Networks. Neural Networks", Vol. 3, No. 1, 109-118