

진동 제어 장치를 포함한 구조물의 지진 응답 예측을 위한 순환신경망의 하이퍼파라미터 연구

Research on Hyperparameter of RNN for Seismic Response Prediction of a Structure With Vibration Control System

김 현 수*
Kim, Hyun-Su

박 광 섭**
Park, Kwang-Seob

Abstract

Recently, deep learning that is the most popular and effective class of machine learning algorithms is widely applied to various industrial areas. A number of research on various topics about structural engineering was performed by using artificial neural networks, such as structural design optimization, vibration control and system identification etc. When nonlinear semi-active structural control devices are applied to building structure, a lot of computational effort is required to predict dynamic structural responses of finite element method (FEM) model for development of control algorithm. To solve this problem, an artificial neural network model was developed in this study. Among various deep learning algorithms, a recurrent neural network (RNN) was used to make the time history response prediction model. An RNN can retain state from one iteration to the next by using its own output as input for the next step. An eleven-story building structure with semi-active tuned mass damper (TMD) was used as an example structure. The semi-active TMD was composed of magnetorheological damper. Five historical earthquakes and five artificial ground motions were used as ground excitations for training of an RNN model. Another artificial ground motion that was not used for training was used for verification of the developed RNN model. Parametric studies on various hyper-parameters including number of hidden layers, sequence length, number of LSTM cells, etc. After appropriate training iteration of the RNN model with proper hyper-parameters, the RNN model for prediction of seismic responses of the building structure with semi-active TMD was developed. The developed RNN model can effectively provide very accurate seismic responses compared to the FEM model.

Keywords : Seismic response prediction, Deep learning, Semi-active TMD, Artificial intelligence, MR damper

1. 서론

2016년 알파고와 이세돌의 바둑 대결에서 세상을 놀라게 한 인공지능은 4차 산업혁명이라는 커다란 물결과 더불어 다양한 산업 분야에 적용되어 커다란 변화를 일으키고 있다. 특히 인공지능의 한 분야인 딥러닝(Deep learning)은 바둑, 게임과 같은 분야뿐만 아니라 인간의 판단 과정을 효과적으로 모사할 수 있는 기술로 인정받고 있다. 딥러닝은 머신러닝(Machine learning)의 일종으로 신경세포인 뉴런(Neuron)을 추상화한 인공신경망(Artificial Neural Network, ANN)이 학습을 통해 시범

스의 결합 세기를 가중치, 편향, 활성화함수 등으로 변화시켜서 문제 해결 능력을 가지는 모델을 전반적으로 가리킨다. 딥러닝은 지도 학습, 비지도 학습 및 강화 학습으로 나눌 수 있으며 다양한 건설 분야에 적용되고 있다. 건축 BIM(Building Information Modeling)의 IFC(Industry Foundation Classes) 정합성 검토나 모델의 상세 수준 자동화 등에 적용되고 있으며, 구조 공학 분야에서도 구조 설계 자동화와 최적화, 구조 제어 및 시스템 식별, 구조 상태 평가 및 모니터링 등 매우 다양한 형태로 적용되고 있다.

딥러닝과 비슷한 개념의 소프트 컴퓨팅 기법에 속하는 퍼지논리제어기(Fuzzy Logic Controller), 유전자알고리즘(Genetic algorithm), 인공신경망(ANN) 등은 구조 제어 분야에 있어서 제어알고리즘 개발에 다수 적용되어 왔다¹⁾. 수치 해석을 통한 건축 구조물에 대한 구조

* 주·교신저자, 정회원, 선문대학교 건축학부 교수, 공학박사
Division of Architecture, Sunmoon University
Tel: 041-530-2315 Fax: 041-530-2839
E-mail: hskim72@sunmoon.ac.kr

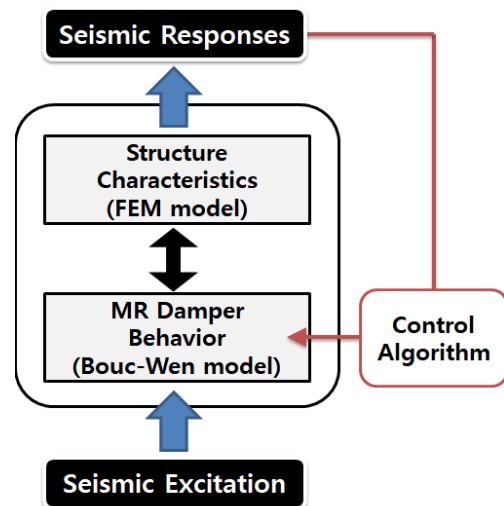
** 정회원, (주)보루 이사
Boru E&C

제어시스템 개발을 위해서는 구조물의 동적 거동을 표현할 수 있는 모델과 제어알고리즘을 표현할 수 있는 모델이 필요하다. Bathaei, Zahrai, Ramezani(2018)의 연구에서는 11층 건물의 지진 응답 제어를 위하여 동조질량감쇠기(Tuned Mass Damper, TMD) 및 MR(Magnetorheological) 감쇠기를 이용한 구조제어시스템을 개발하였다²⁾. 이 연구에서 구조물의 동적 거동을 모사하기 위하여 개방형 구조 해석 플랫폼인 OpenSees를 사용하였고, MR 감쇠기와 퍼지제어 알고리즘을 모형화하기 위하여 Matlab을 사용하였다. 또한 두 프로그램을 연결하기 위하여 TCL/TK 프로그래밍 언어를 사용하는 등 복잡한 과정을 거쳐야 했다. 지진 하중과 풍하중을 받는 중저층 및 고층 빌딩구조물에 대한 동적 응답 제어 벤치마크 문제와 스마트 면진장치가 설치된 구조물의 지진 응답 제어에 대한 벤치마크 문제가 2000년대 초반 발표된 이후 많은 연구자들에 의해 연구에 활용되어 왔다³⁾. 이러한 구조 제어 문제들을 살펴보면 대부분의 연구에서 유한요소해석기법(Finite Element Method, FEM)을 이용하여 구조물의 동적 거동을 모사하는 모델을 사용하고 소프트웨어 컴퓨팅 기법 또는 전통적인 최적제어알고리즘 등을 이용하여 제어 시스템 개발을 수행하고 있다⁴⁾.

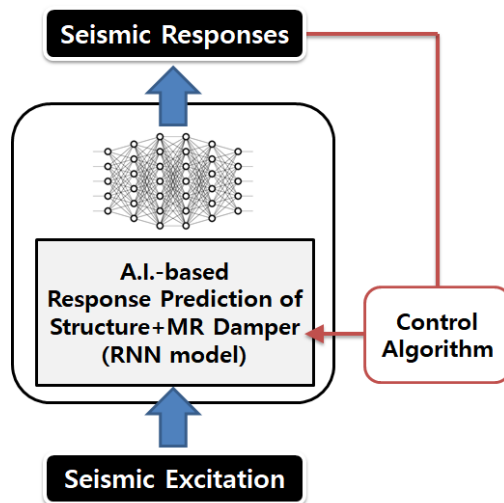
근래에 준능동 구조 제어 장치로 가장 널리 사용되고 있는 MR 감쇠기의 거동을 모사하기 위해서 Bouc-Wen 모델과 같은 비선형 모델이 주로 사용되고 있다. 제어 명령을 통해서 MR 감쇠기의 비선형 거동을 표현하는 모델을 일반 FEM 해석 프로그램에서 제공하지 않기 때문에 Bathaei, Zahrai, Ramezani(2018)의 연구²⁾에서와 같이 구조물의 거동을 나타내는 FEM 모델과 비선형 준능동 감쇠기를 나타내는 모델을 따로 만들어서 상호작용을 고려한 수치 해석을 수행하게 되며 이를 <Fig. 1>에 나타내었다. 만약 대상 구조물의 규모나 비정형성이 커서 많은 자유도로 구성된 FEM 모델을 사용하여 시간 이력 해석을 수행할 경우 해석에 많은 시간이 소요되어 최적 제어 시스템의 개발을 위해서 수천 번의 시뮬레이션이 필요하게 되고 설계 과정에 큰 부담이 발생할 수 있을 뿐만 아니라 미처 탐색하지 못한 영역이 발생할 수 있다.

따라서 본 연구에서는 많은 자유도를 가진 FEM 모델과 비선형 MR 감쇠기 모델의 상호작용을 고려한 기존 수치 해석 기법의 비효율성과 복잡함을 줄이면서도 정

확성을 유지할 수 있는 기법을 딥러닝을 이용하여 제안하였다. 딥러닝의 다양한 기법 중시간이력 응답 예측에 우수한 성능을 보이는 순환신경망(Recurrent Neural Network, RNN)을 이용하여 구조물의 지진 응답 예측 모델을 개발하였다. 이때 <Fig. 2>와 같이 하나의 RNN 모델을 이용하여 구조물과 MR 감쇠기의 상호작용을 고려한 비선형 응답을 예측하도록 구성하였다.



<Fig. 1> Conventional model for structural control system development



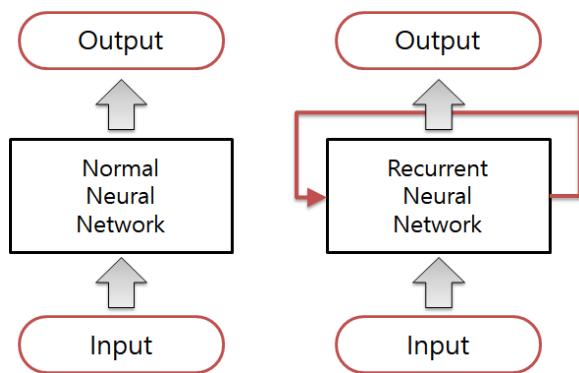
<Fig. 2> AI-based model for structural control system development

딥러닝의 일종인 RNN을 이용하면 복잡한 동적평형 방정식을 수치해석적으로 풀어야 하는 기존의 방법에 비해 매우 간단한 연산으로 구조물의 지진 응답을 예측할 수 있다. 기존의 FEM 모델과 비교하여 정확한 응답을 예측하는 모델을 생성하기 위해서는 RNN 모델 생성을 위해 적용되는 다양한 하이퍼파라미터(Hyperparameter)

의 최적값을 찾는 것이 필요하다. 본 연구에서는 MR 감쇠기를 이용하여 구성된 준능동 TMD가 설치된 구조물의 지진 응답을 정확하게 예측하기 위한 RNN 모델을 개발하고, 해당 모델의 정확성을 높이기 위한 하이퍼파라미터 분석 연구를 수행하였다.

2. 순환신경망 모델


딥러닝의 다양한 모델은 입력 데이터를 기반으로 출력을 예측하는데 우수한 성과를 나타내고 있다. 일반적인 신경망은 입력층의 데이터를 출력층의 한 방향으로만 흐르는 피드포워드(Feedforward) 신경망의 형태로 사용한다. 그러나 순환신경망은 피드포워드 신경망과 비슷하지만 <Fig. 3>에 나타난 바와 같이 출력이 다시 입력으로 받는 부분이 포함되어 있다.



<Fig. 3> Difference between normal and recurrent neural network

본 연구에서는 지반가속도, 속도, 변위 등의 동적 응답과 함께 준능동 제어 장치로 전달되는 명령 전압을 입력으로 하고 구조물의 지진 응답을 출력으로 하는 신경망모델을 생성하고자 한다. 이때 일반적인 피드포워드 신경망을 사용한다면 동일한 입력 데이터에 대하여 동일한 출력 데이터가 생성될 것이다. 즉, 입력 지반가속도 및 명령 전압이 같다면 동일한 동적 응답이 예측되는 것이다. 이는 지반가속도가 증가하고 있는 중인지 감소하고 있는 중인지, 명령 전압이 어떻게 변하고 있는 중인지 등에 대한 정보를 신경망에 전달할 방법이 없게 되므로 예측 응답의 정확도가 떨어지게 된다. 따라서 이러한 시간이력 데이터의 예측을 위해서는 과거에 입력된 데이터와 나중에 입력된 데이터 사이의 관계를 고려해야 하는 문제가 발생하는데 이를 해결하기 위해서 순환신경망 방법이 제안되었다. 순환신경망은 여러 개의 데이

터가 순서대로 입력되었을 때 앞서 입력받은 데이터를 잠시 기억해 놓는 특징을 가지고 있다. 이렇게 기억된 데이터가 얼마나 중요한지를 판단하고 별도의 가중치를 주어 다음 단계의 입력 데이터와 함께 사용된다. 모든 입력값에 대하여 이러한 작업을 순서대로 실행하기 때문에 다음 층으로 넘어가기 전 같은 층을 맴도는 것처럼 보여 순환신경망이라고 불린다. 순환신경망의 학습 유형은 <Fig. 4>에 나타난 바와 같이 다양한 형태로 이루어질 수 있다⁵⁾. 이미지를 말로 설명하는 Image captioning 기능은 One-to-many 유형으로 학습할 수 있고 자동번역기(Machine translation)는 Many-to-many 유형으로 학습할 수 있다. 본 연구에서 대상으로 하고 있는 시간이력 데이터 예측은 Many-to-one 유형을 사용하는 것이 적절하다고 알려져 있다.




<Fig. 4> Various types of RNN models⁵⁾

3. 예제 구조물

순환신경망을 이용하여 건축 구조물의 지진 응답을 예측할 수 있는 모델을 개발하기 위한 예제 구조물로 Bathaei, Zahrai, Ramezani(2018)의 연구에서 사용한 11층 빌딩 구조물을 사용하였다. 총질량 및 층강성은 <Table 1>에 나타내었다. 예제 구조물은 <Fig. 5>에 나타난 바와 같이 11층의 전단 모델로 표현되고, 1차모드 고유진동주기는 0.89초이다. 구조물의 감쇠는 Rayleigh 감쇠 2%를 적용하였다. 최상층에는 준능동 TMD가 설치되어 있고, 준능동 TMD의 핵심 구성 요소인 MR 감쇠기는 그림에 나타난 바와 같이 널리 사용되는 Bouc-Wen 모델⁶⁾을 사용하여 모형화하였다. 준능동 TMD의 질량은 구조물 전체 질량의 2%를 사용하였고, 구조물의 1차모드 고유진동주기에 조율하였다. 사용된 MR 감쇠기의 용량은 500kN이다.

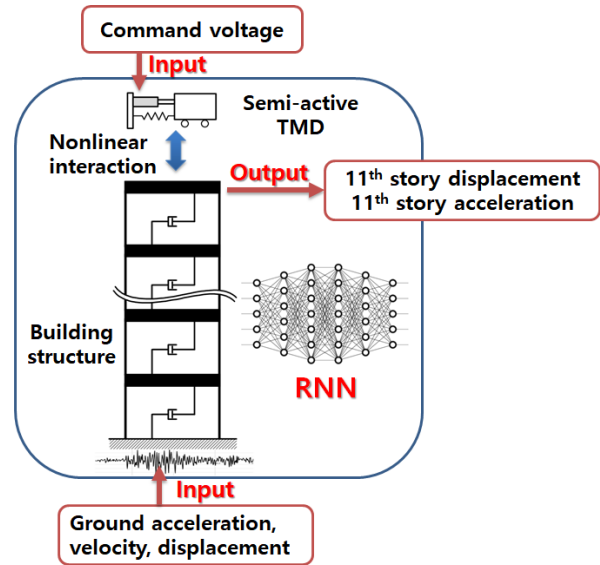
〈Table 1〉 Example structure properties

Story	Mass (kg)	Stiffness (kN/m)
1	215,370	4.68×10^5
2	201,750	4.76×10^5
3	201,750	4.68×10^5
4	200,930	4.50×10^5
5	200,930	4.50×10^5
6	200,930	4.50×10^5
7	203,180	4.50×10^5
8	202,910	4.37×10^5
9	202,910	4.37×10^5
10	176,100	4.37×10^5
11	66,230	3.12×10^5



〈Fig. 5〉 Example building with semi-active tuned mass damper

제어 명령에 따라 감쇠력이 변하는 MR 감쇠기는 비선형성이 매우 강하다. 이를 지진 하중을 받는 빌딩 구조물에 설치하여 응답 제어에 사용하면 구조물과의 비선형 상호작용에 의하여 구조물의 응답도 비선형성이 포함된다. 본 연구에서 개발하는 순환신경망 모델은 이러한 비선형성을 포함하여 표현하는 것이 필요하다. 따라서 본 연구에서 개발하는 순환신경망 모델은 〈Fig. 6〉과 같이 준능동 TMD와 빌딩 구조물의 상호작용을 고려한 동적 응답을 표현한다. 지반가속도, 속도 및 변위와 MR 감쇠기로 전달되는 명령 전압을 그림에 나타난 바와 같이 순환신경망 모델의 입력 데이터로 선택하였다. 순환신경망 지진 응답 예측 모델의 출력으로는 구조물의 안전성과 사용성을 나타내는 대표적인 동적 응답인 구조물 최상층의 변위 응답과 가속도 응답을 선택하였다.



〈Fig. 6〉 Input and output relationship of RNN

4. 학습 및 검증 데이터셋의 구성

예제 구조물에 대한 지진 응답 예측을 위한 순환신경망 모델을 학습하기 위해서 지반 운동 데이터 및 명령 전압 시간이력 데이터를 생성하였다. 순환신경망 모델의 학습을 위한 데이터셋과 검증을 위한 테스트 데이터셋은 구분되어 생성되어야 한다. 학습과 검증을 위하여 각각 10개 및 3개의 지진 하중을 사용하였고 이를 〈Table 2〉에 나타내었다.

〈Table 2〉 Training and test earthquakes


No.	EQ name	P.G.A. (g)	Purpose
1	El Centro (1940)	0.313	Training
2	Taft (1952)	0.156	Training
3	Northridge (1994)	0.603	Training
4	Loma Prieta (1989)	0.220	Training
5	Kobe (1995)	0.686	Training
6	Artificial EQ1	0.517	Training
7	Artificial EQ2	0.537	Training
8	Artificial EQ3	0.576	Training
9	Artificial EQ4	0.566	Training
10	Artificial EQ5	0.385	Training
11	Artificial EQ6	0.562	Test
12	Artificial EQ7	0.615	Test
13	Jiji (1999)	0.512	Test

표에 나타난 바와 같이 10개의 학습용 지진 하중 중 5개는 역사지진 하중을 선택하였고 5개는 인공지진 하중을 사용하였다. 검증용 3개의 지진 하중 중 2개는 인공지진 하중을 사용하였고 1개는 역사지진을 사용하였다. 인공지진 하중을 생성하기 위하여 강진 지역 지반 운동(s)의 특성을 적절하게 표현하는 식 (1)의 필터를 사용하였다.


$$F(s) = \frac{4\zeta_g\omega_g s}{s^2 + \zeta_g\omega_g s + \omega_g^2} \quad (1)$$

여기서, $\omega_g = 2\pi \text{ rad/s}$ 이며 $\zeta_g = 0.3$ 의 값을 사용하였다. Nagarajaiah & Narasimhan(2006)의 선행 연구³⁾를 보면 이 필터는 강진 지역 지진 하중의 주파수 특성을 매우 잘 표현하고 있다. 최대지반가속도(Peak Ground Acceleration, PGA)를 0.7g로 생성한 0.005초 시간 간격의 백색잡음을 위 필터에 통과시킨 지진 하중 시간이력에 포락선(Envelope)을 적용시켜 일반적인 지진 하중의 형태를 갖도록 하였다. 생성한 6번 인공지진 하중을 <Fig. 7>에 나타내었다. 전술한 바와 같이 <Table 2>에 기술된 13개의 지반 운동 가속도를 수치적분하여 지반 속도 및 지반 변위를 생성하였고 이를 학습 및 검증 데이터셋의 입력으로 사용하였다. 학습 및 검증 데이터의 입력에는 <Fig. 6>에 나타난 바와 같이 지반 운동 이외에 명령 전압이 사용된다. 본 연구에서 사용된 MR 감쇠기는 0~10volt의 전압이 사용되므로 이 사이의 값이 랜덤하게 생성될 수 있도록 백색파를 사용하였다. 명령 전압의 최대값은 16volt로 하여 최대 제어력을 발휘하는 구간을 조금 더 길게 하였고, 중심축을 6volt 양의 방향으로 이동하여 평균을 MR 감쇠기 용량의 중간 값 이상이 되도록 하였다. 이렇게 생성한 명령 전압 시간이력을 <Fig. 8>에 나타내었다. 10개의 학습 데이터와 3개의 검증 데이터에 사용된 모든 명령 전압은 각각 다르게 하여 과적합(Overfitting)을 피할 수 있도록 하였다.

작성한 지진 하중 및 명령 전압 데이터를 입력하였을 때 준능동 TMD와 구조물의 상호작용을 고려한 11층 가속도 및 변위 출력 데이터를 계산하기 위하여 FEM 모델을 이용한 수치 해석을 수행하였다. 이렇게 얻은 학습 및 검증 데이터셋을 이용하여 순환신경망 모델을 개발하였다.



<Fig. 7> Ground acceleration time history of artificial earthquake 1



<Fig. 8> Command voltage time history

5. 순환신경망 모델의 성능 평가

전술한 예제 구조물의 지진 응답 예측을 위한 순환신경망 모델을 개발하기 위해서 10개의 학습 데이터셋을 이용하여 1,000회 반복 학습(1000 epoch)을 수행하였다. 순환신경망 모델 작성 및 학습은 Python 3.5.0과 Tensorflow 1.6.0을 사용하였다. FEM 해석을 통하여 얻은 구조물의 응답을 참값이라고 했을 때 순환신경망에 의한 예측값과의 차이를 오차로 두고 오차를 최소화시키는 방향으로 학습이 이루어지게 된다. 그런데 이 오차에는 양수와 음수가 섞여 있기 때문에 오차를 단순히 더해 버리면 제대로 된 오차를 파악할 수 없다. 따라서 식 (2)와 같이 부호를 없애기 위해 제곱의 함으로 표현한 식을 최적화 과정의 손실(Loss) 함수로 사용하였다.

$$loss = \sum_{i=1}^n (p_i - y_i)^2 \quad (2)$$

여기서, n은 데이터의 개수(시간 간격의 수), p_i 는 순환신경망에 의한 예측값, y_i 는 FEM 해석 결과로 정확해를 나타낸다. 학습을 마친 순환신경망 모델의 정확도를 검

증하기 위하여 테스트 데이터셋으로 평가할 때는 다음의 평균제곱근오차(Root Mean Squared Error, RMSE)를 사용하여 평가하였다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2} \quad (3)$$

순환신경망 모델의 지진 응답 예측 정확성을 평가하기 위하여 설정한 하이퍼파라미터 및 함수의 기본 값을 <Table 3>에 나타내었다. 기본값을 그대로 유지하고 시계열 입력 데이터의 길이를 나타내는 시퀀스 길이(Sequence length)만 변화시켜서 학습 시 손실 함수와 검증 시 RMSE를 비교하여 <Table 4>에 나타내었다. 이 값들은 각 Epoch마다 편차가 존재하므로 최종 10회의 학습 및 테스트 결과의 평균을 비교하였다. 결과를 보면 시퀀스 길이가 증가함에 따라 6까지는 오차가 줄어들지만 그 이후 오히려 늘어나는데 이는 과적합때문인 것으로 판단된다.

<Table 3> Default hyperparameter and function

Item	Value
Sequence length	5
RNN cell number	1
Dropout ratio	0.8
Hidden layer dimension	5
Learning rate	0.01
RNN type	LSTM
Activation function	tanh
Optimizer	Adam

<Table 4> Effect of sequence length

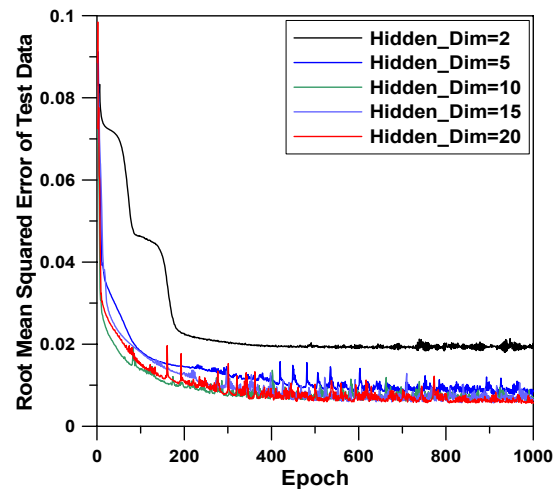
Seq_Len	Avg. loss	Avg. RMSE
1	2.648	11.490 × 10 ⁻³
2	2.317	9.408 × 10 ⁻³
5	2.273	8.623 × 10 ⁻³
6	2.248	8.141 × 10 ⁻³
7	2.496	8.925 × 10 ⁻³
10	2.535	9.279 × 10 ⁻³

순환신경망 모델의 폭을 의미하는 히든레이어의 크기를 변화시켜서 학습한 결과를 <Table 5>에 나타내었다. 히든 레이어의 크기를 크게 할수록 손실함수의 평균값

은 지속적으로 줄어들지만 테스트 데이터의 RMSE 값은 20을 기준으로 증가하였다. RNN 모델이 학습 데이터를 기억하는 과적합이 시작되었기 때문이다. 시퀀스 길이에 비해서 히든 레이어의 크기가 RNN 예측 모델의 정확도에 더 큰 영향을 미치는 것을 알 수 있다. 학습 횟수에 따른 테스트 데이터의 RMSE 변화를 <Fig. 9>에 나타내었다. 히든 레이어의 크기가 10 이상이면 비슷한 결과를 나타내었고, 약 400회의 학습 이후 거의 일정한 RMSE 값을 나타내었다.


<Table 5> Effect of hidden layer dimension

Hidden	Avg. loss	Avg. RMSE
2	6.207	19.516 × 10 ⁻³
5	2.263	8.509 × 10 ⁻³
10	1.278	6.733 × 10 ⁻³
15	1.004	6.561 × 10 ⁻³
20	0.769	6.053 × 10 ⁻³
30	0.618	6.341 × 10 ⁻³
40	0.539	6.757 × 10 ⁻³




<Fig. 9> RMSE variation of test data


순환신경망 모델의 타입으로 널리 사용되는 LSTM(Long Short-Term Memory)과 GRU(Gated Recurrent Units)는 거의 비슷한 결과를 나타내었다. 전통적인 Vanilla RNN에 비해서는 약 6% 우수한 정확도를 나타내었다. 순환신경망 모델의 하이퍼파라미터와 함수의 기본값을 <Table 3>에 나타낸 값으로 사용하고 히든 레이어의 크기만 20으로 하여 생성한 모델의 예측값과 FEM 모델의 결과를 비교하여 <Figs. 10~15>에 나타내었다.




〈Fig. 10〉 Displacement time history of test EQ1




〈Fig. 11〉 Acceleration time history of test EQ1




〈Fig. 12〉 Displacement time history of test EQ2



〈Fig. 13〉 Acceleration time history of test EQ2



〈Fig. 14〉 Displacement time history of test EQ3



〈Fig. 15〉 Acceleration time history of test EQ3

FEM 모델의 결과를 기준으로 RNN 모델이 변위 응답뿐만 아니라 가속도 응답에 대해서도 매우 정확한 예측이 가능한 것을 확인할 수 있다. 학습에 사용되지 않은 3개의 테스트 지진 및 명령 전압에 대해서 변위 및 가속도 응답의 총 6개 응답에 대한 평균 RMSE는 0.006053으로 매우 작게 나타났다. 정확해로 생각되는 FEM 해석 결과를 얻기 위하여 Matlab을 사용하여 수치 해석을 수행하였으며, 시간 간격을 충분히 작게 하지 않으면 수치적분이 불가능해지기 때문에 0.0005초의 시간 간격을 사용하였다. FEM 모델과 RNN 모델의 해석 시간을 비교하기 위해 10회 수행 후 평균값을 계산하였으며 각각 65.87초와 0.74초가 소요되었다. 이는 RNN 모델을 사용하면 기존 FEM 모델의 결과와 거의 일치하는

결과를 얻으면서도 해석 시간은 1.1%만 사용하므로 준 능동 구조제어시스템 최적 설계 시 더 넓은 영역을 더 빨리 탐색할 수 있는 매우 효과적인 대안이 될 수 있을 것으로 판단된다. 수치 해석은 Intel(R) Core(TM) i7-7500U CPU, RAM 8GB, Windows 10 64-bit 운영 체제에서 수행되었다.

6. 결론

본 연구에서는 준능동 TMD가 설치된 건축 구조물의 지진 응답 예측을 위한 순환신경망 모델을 개발하였다. 이를 위하여 분리된 학습 및 테스트 데이터셋을 구성하여 모델 생성 및 검증을 수행하였고, 사용된 하이퍼파라

미터와 함수의 최적값을 검토하였다. 해석 결과, 순환신경망 모델의 핵심 변수인 시퀀스 길이와 히든레이어의 크기가 예측 모델의 정확도에 영향을 미쳤으며, 특히 후자가 핵심적인 역할을 하는 것으로 나타났다. 일반적으로 순환신경망의 폭 및 깊이와 시퀀스 길이 등이 클 경우 정확도가 높아진다. 그러나 너무 크게 되면 과적합 현상 때문에 학습은 잘 이루어지더라도 학습되지 않은 데이터에 대한 정확도는 감소하는 결과가 나타났다. 본 연구에서 개발된 RNN 지진 응답 예측 모델은 일반적으로 사용되는 FEM 모델과 매우 비슷한 결과를 나타내면서도 해석 시간은 1.1%만 소요되므로 시간이력 해석을 통한 준능동 구조제어시스템의 설계의 효율성에 크게 이바지할 수 있을 것으로 기대된다.

감사의 글

본 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2019R1A2C1002385).

References

1. Kim, H. S., & Kang, J. W., "Seismic Response Control of Retractable-roof Spatial Structure using Smart TMD", Journal of Korean Association for Spacial Structures, Vol.16, No.4, pp.91~100, 2016, doi: 10.9712/KASS.2016.16.4.091
2. Bathaei, A., Zahrai, S. M., & Ramezani, M., "Semi-active seismic control of an 11-DOF building model with TMD+MR damper using type-1 and -2 fuzzy algorithms", Journal of Vibration and Control, Vol.24, No.13, pp.2938~2953, 2018
3. Nagarajaiah, S., & Narasimhan, S., "Smart base-isolated benchmark building. Part II: phase I sample controllers for linear isolation systems", Structural Control and Health Monitoring, Vol.13, No.2-3 pp.589~604, 2006, doi: 10.1002/stc.100

4. Kim, H. S., & Kang, J. W., "Vibration Control Performance Evaluation of Hybrid Mid-Story Isolation System for a Tall Building", Journal of Korean Association for Spatial Structures, Vol.18, No.3 pp.37~44, 2018 doi: 10.9712/KASS.2018.18.3.37
5. dProgrammer. Recurrent Neural Network (RNN), Long-Short Term Memory (LSTM) & Gated Recurrent Unit (GRU) (April 2019 ed.). Retrieved from <http://dprogrammer.org/rnn-lstm-gru>
6. Sues, R. H., Mau, S. T., & Wen, Y. K., "System Identification of Degrading Hysteretic Restoring Forces", Journal of Engineering Mechanics, Vol.114, No.5, pp.833~846, 1988, doi: 10.1061/(ASCE)0733-9399(1988)114:5(833)

- Received : March 05, 2020
- Revised : March 20, 2020
- Accepted : March 20, 2020