GRU를 활용한 인공지능기반 구조물 시계열 응답 예측 Structural Response Estimation Using Gated Recurrent Unit

전건열* · 박재형** · 정종원*** · 윤형철****

Jeon, Geonyeol*, Park, Jaehyung**, Jung, Jongwon***, and Yoon, Hyungchul****

Abstract

Recent tragedies have demonstrated that natural disasters, such as earthquakes and typhoons, can wreak havoc on society. Numerical models and simulations are used for predicting the structural response and damage caused by disasters. However, some structures do not have any design drawings or numerical models, and thus, problems are encountered when conducting numerical simulations. Furthermore, even if the model exists, the response predicted through numerical simulation may be different from the response of the actual structure. Although effort has been made to resolve this issue using model-updating techniques, these methods are laborious for developing a new model that reflects the current state of the structure. Therefore, the aim of this study is to develop a new method that automatically predicts the time-series response of structures using a deep learning technique. The gated recurrent unit, based on the recurrent neural network, was used to predict the structural response. Simulation-based validation tests were conducted to verify the performance of the proposed method. The proposed method could estimate the response of the structure with a root-mean-square error of 13.59%.

Key words : Deep Learning, Time-series Response Prediction, System Identification, Gated Recurrent Unit, Neural Network

요 지

최근 지진이나 태풍 등의 자연재해로 인해 많은 시설물들이 피해를 입고 있다. 이러한 피해를 예측하고 대비하기 위해 수치해석 모델이 이용되고 있다. 하지만 구조물에 따라 설계도면이나 수치해석 모델이 존재하지 않는 경우도 많으며, 모델이 존재하는 경우에도 다양한 원인으로 응답의 예측이 실제 구조물의 응답과 차이를 보인다. 모델 업데이트 기법을 통해 현재 상태의 구조물에 대한 모델링을 구축하고자 하는 노력도 있었으나, 현재 상태를 반영한 모델을 새로 작성하기 위해 많은 인력과 시간을 필요로 한다. 따라서 본 연구에서는 딥러닝 기술을 활용하여, 새로운 하중에 대하여 구조물의 시계열 응답을 자동으로 예측하는 기술을 개발하였다. 네트워크 구축에는 RNN (Recurrent Neural Network) 기반 GRU (Gated Recurrent Unit)를 사용하였고, 개발된 네트워크 성능을 검증하기 위해 시뮬레이션을 진행하여 결과를 비교하였으며, 13.59%의 오차로 구조물의 응답을 예측할 수 있었다.

핵심용어 : 딥러닝, 시계열 응답 예측, 시스템 식별, GRU, 인공지능경망

1. 서 론

최근 지진이나 태풍 등의 자연재해로 인해 많은 시설물들

이 피해를 입고 있다. 2016년 9월 경주시에서 발생한 규모 5.8의 지진으로 인해 건물 벽면이나 도로에 균열 및 부분 파손 등의 피해가 발생하였다(Oh and Shin, 2016). 뿐만

*정회원, 충북대학교 토목공학부 석사과정(E-mail: rjsdulf1111@naver.com)

Member, MS Students, Department of Civil Engineering, Chungbuk National University

**정회원, 충북대학교 토목공학부 석사과정(E-mail: pjcomputer@naver.com)

Member, MS Students, Department of Civil Engineering, Chungbuk National University

***정회원, 충북대학교 토목공학부 부교수(Tel: +82-43-261-2405, E-mail: jjung@cbungbuk.ac.kr)

Member, Associate Professor, Department of Civil Engineering, Chungbuk National University

****교신저자, 정회원, 충북대학교 토목공학부 부교수(Tel: +82-43-261-2404, Fax: +82-43-275-2377, E-mail: hyoon@chungbuk.ac.kr)

Corresponding Author, Member, Associate Professor, Department of Civil Engineering, Chungbuk National University

아니라 2020년 제9호 태풍 ‘마이삭’으로 인해 평창군에 위치한 송정1교와 동산교가 붕괴되는 사고가 발생하였다(Jung et al., 2020). 해외의 경우, 2019년 7월 미국 캘리포니아주 모하비 사막에서 지진이 발생하여 인근 건물과 도로에 화재 및 손상이 발생하였으며, 일부 교각은 붕괴되었다(Liu et al., 2019). 또한 2016년 중국 장쑤성에서는 토네이도로 인해 3,200채의 주택, 2개의 초등학교 등이 붕괴되는 피해를 입었다(Meng et al., 2018).

수치해석 모델을 이용하면 구조물이 자연재해로부터 받는 피해를 예측하고 사전에 대처할 수 있다. Powell and Allahabadi (1988)는 결정론적 방법에 통해 지진에 대한 구조물의 피해를 예측하는 기법을 제시하였고, Pinelli et al. (2004)은 허리케인으로 인한 주거용 구조물의 피해를 예측하고자 하는 연구를 진행하였고, Shi et al. (2008)은 폭발 하중의 크기에 따른 교량의 응답을 예측하는 시뮬레이션을 진행하였고, Wang and Zhang (2014)은 Riedel-Hiermaier-Thoma (RHT) 모델을 이용하여 수중 폭발에 대한 중력식 댐의 손상을 예측하는 연구를 진행하였다. 또한 Ma et al. (2006)은 hysteretic model을 이용하여 손상된 구조물의 응답을 예측하는 연구를 수행하였다. 이러한 기법을 적용하기 위해서는 수치해석 모델을 필요로 한다.

수치해석 모델의 예측이 항상 정확한 것은 아니다. 구조물에 따라 설계도면이나 모델이 존재하지 않는 경우도 많으며, 모델이 존재하는 경우에도 노후화, 시공 오차, 비선형성 등의 원인으로 응답의 예측이 실제 구조물과 많은 차이를 보인다. 이러한 문제점을 해결하기 위해, 구조물의 동적 응답 정보로부터 수치해석 모델을 업데이트하는 연구들이 진행되었다. 이외에도 Auto-Regressive (AR) model과 Moving Average (MA) model을 결합하여, 통계적 회귀 분석법을 이용한 Auto-Regressive Moving Average (ARMA) model (Naganuma et al., 1987)이 개발되었으며, 미래의 응답을 이전의 응답에 투영하는 Stochastic Subspace Identification (SSI; Peeters and De Roeck, 1999) 등의 기법들이 개발되었다. Brownjohn et al. (2001)은 민감도 분석 기반 모델 업데이트를 통해 구조물의 손상을 예측하였고, Jaishi and Ren (2006)은 modal flexibility를 이용하여 모델 업데이트를 진행하는 연구가 수행되었다. 하지만 기존의 기법을 이용하여 현재 상태를 반영한 모델을 새로 작성하기 위해서는 많은 인력과 시간을 필요로 한다.

딥러닝 기술을 활용한다면 이러한 문제점을 해결할 수 있는 가능성을 보인다. 현재 건설 분야에 많은 딥러닝 관련 기술들이 혁신을 이루고 있다. Li (2000)는 Element Stiffness Simulating (ESS)기법에 인공신경망을 적용하여 시뮬레이션을 진행하는 연구를 수행하였고, Zhang et al. (2019)은 Long Short-term Memory (LSTM)를 이용하여 댐의 수위와 기온을 통해 댐의 방사형 변위를 예측하였고, Ozdagli and Koutsoukos (2019)는 Principal Component Analysis (PCA), Autoencoder (AE) 등의

기술을 이용하여 고유진동수와 모드 형상을 예측하는 연구를 수행하였다. 이러한 연구들은 딥러닝 기술을 이용하여 구조물의 시계열 응답을 예측할 수 있는 가능성을 보여 준다.

본 연구에서는 딥러닝 기술을 활용하여, 구조물의 시계열 응답을 자동으로 예측하는 기술을 개발하고자 한다. Recurrent Neural Network (RNN) 기반의 Gated Recurrent Unit (GRU; Cho et al., 2014)를 이용하여 네트워크를 구축하였고, 시뮬레이션을 통해 하중 데이터 및 3층 구조물의 시계열 응답 데이터 세트를 수집하였다. 구축된 네트워크에 수집한 데이터 세트를 학습시켜 하중 데이터를 통해 그에 따른 구조물의 응답을 예측하도록 설계하였다. 개발한 네트워크의 검증을 위해 시뮬레이션을 이용하여 예측한 응답 데이터를 평가하고자 한다.

2. 이론적 배경

2.1 RNN

머신러닝의 한 분야인 딥러닝은 Artificial Neural Network (ANN)을 기초로 하여 만들어진 기계학습 알고리즘이다. Rosenblatt (1958)은 신경세포의 메커니즘을 모방하여 퍼셉트론(perceptron)을 개발하였다. 퍼셉트론은 ANN의 기초가 되었으며, 3개 이상의 층(Layer)을 갖는 Multi Layer Perceptron (MLP)으로 발전되었다(Rosenblatt, 1961). 이러한 초기 ANN 알고리즘은 복잡한 문제 해결을 위해 신경망의 Hidden Layer를 늘리는 것이 필요하였다. Hidden Layer가 늘어남으로 인해 역전파(Backpropagation) 학습과정에서 데이터가 소실되어 학습이 진행되지 않는 기울기 소실(Vanishing Gradient) 문제가 발생하였다. 사전학습(Pre-training)을 이용한 방법과 데이터를 고의로 누락시키는 방법(Dropout)의 개발로 인해, 기울기 소실 문제가 개선되었다(Hinton et al., 2006; Srivastava et al., 2014). 이로 인해 신경망의 Hidden Layer를 깊게 구성할 수 있으며, Hidden Layer가 2개 이상으로 이루어진 신경망을 심층신경망(Deep Neural Network, DNN)이라 정의하게 되었다. 최근에는 DNN 중에서도 공간적 정보를 활용하는 Convolutional Neural Network (CNN)과 Sequential 데이터의 특성을 활용하는 Recurrent Neural Network (RNN) 등이 많이 사용되어 지고 있다(Rumelhart et al., 1986; Ciregan et al., 2012).

RNN은 DNN의 네트워크의 한 종류로서, 음성 인식, 언어 모델링 등의 순차적(Sequential) 데이터를 분석하거나 예측하는데 주로 사용되고 있다. RNN 알고리즘은 순전파(Forward propagation) 과정을 통해 출력을 계산하고, 역전파(back propagation) 과정을 통해 계산된 출력과 실제 출력의 오차가 작아지도록 가중치를 수정하여 학습이 진행된다. Vanilla RNN은 초기 ANN과 마찬가지로 기울기 소실 문제가 발생하였다. 이러한 단점을 해결하기 위해 Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU) 등의 알고리즘이 개발

되었다(Hochreiter and Schmidhuber, 1997).

2.2 GRU

Cho et al. (2014)이 개발한 GRU 알고리즘은 LSTM과 마찬가지로 초기 RNN의 문제점을 개선하고자 개발되었다. hidden-state와 cell-state 두 개의 벡터로 구성된 LSTM과 달리 hidden-state로만 이루어져 있으며, hidden-state가 cell-state의 역할까지 수행한다. GRU는 Fig. 1과 같이 구성되어 있으며, 다음 과정을 통해 입력 데이터에 대한 연산을 수행한다.

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (1)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \otimes h_{t-1}, x_t] + b_h) \quad (3)$$

$$h_t = z_t \otimes h_{t-1} + (1 - z_t) \otimes \tilde{h}_t \quad (4)$$

r_t (Eq. (1)), z_t (Eq. (2))는 각각 Reset Gate와 Update

Fig. 1. GRU Node

Gate의 계수이며, $\tilde{h}_t$ (Eq. (3))는 현재 정보의 Candidate이다. Reset Gate를 통과한 이전 time step의 hidden-state h_t (Eq. (4))와 입력 데이터 x_t 를 통해 $\tilde{h}_t$ 가 형성된다. Update Gate의 z_t 는 이전 hidden-state에서 전달된 데이터와 Candidate의 정보를 조절하여 hidden-state를 결정한다.

3. 본 론

3.1 시스템 구성

본 연구에서는 앞서 설명한 Gated Recurrent Unit (GRU)을 사용하여 구성된 네트워크를 사용하여, 특정한 구조물의 하중에 대한 응답을 자동으로 예측하는 시스템을 개발하였다. 본 시스템의 구성은 Fig. 2와 같다. 먼저 구조물에 가해지는 하중에 대한 시계열 데이터가 Input Layer를 통해 입력이 되면, GRU Layer와 Fully-Connected Layer를 통해 해당 구조물의 응답을 예측하고, 예측한 시계열 데이터를 Output Layer를 통해 출력하게 된다. 네트워크의 구성에 대한 자세한 설명은 다음 장에 기술하였다.

3.2 GRU 기반 네트워크 구성

GRU 기반의 네트워크는 크게 Input Layer, Hidden Layer (GRU Layer, Fully Connected Layer) 그리고 Output Layer로 구성된다. 예측을 위한 데이터 연산은 Hidden Layer에서 수행된다. 하지만 Hidden Layer에서 직접 데이터를 받아 자동으로 학습할 수 없기 때문에 Input Layer를 통해 순차 데이터(sequential data)를 입력받아 필요에 따라 정규화를 진행하여 Hidden Layer에 데이터를 전달하게 된다. Hidden Layer에서는 정규분포를 따라 무작위로 설정된 가중치와 전달된 데이터를 연산하여 예측 데이터를 생성한다. 초기 가중치로 인한 예측 데이터는 실제 응답 데이터와 큰 오차가 발생한다. 이러한 오차를 이용하여 역전파(Backpropagation) 과정을 진행하고 가중치를 수정해가며 점차 실제 응답 데이터와 유사한 예측 데이터를 얻을 수 있다. Hidden Layer에서

Fig. 2. Overview of Structural Response Estimation Using GRU

는 전달받은 데이터를 통해 구조물의 응답에 대한 데이터를 연산한다. 최종적으로 구조물의 예측된 응답을 Output Layer를 통해 구조물의 자유도(Degree of Freedom) 개수 만큼의 순차 데이터 세트를 출력하게 된다.

본 연구에서 개발한 GRU 기반 네트워크의 성능은 GRU Node의 Hidden Unit 수, GRU Node 수, Hidden Layer 구성 등의 파라미터에 따라 영향을 많이 받는다. 이러한 파라미터는 입력과 출력 데이터에 따라 다른 최적의 값을 가지기 때문에 각 파라미터별 최적화 과정을 필요로 한다. 일반적으로 Hidden Unit과 GRU Node의 경우, 개수가 증가할수록 학습에 따른 결과가 향상되는 경향이 있다. 하지만 Hidden Unit과 GRU Node가 일정한 개수를 초과하였을 경우에는, 더 이상 개수가 증가함에 따라 성능의 향상은 이루어지지 않고, 학습에 소요되는 시간만 증가하는 결과가 발생한다. 따라서 본 연구에서는 Hidden Unit과 GRU Node의 개수를 변화시켜가며 최적의 개수를 설정하였으며, 세부사항은 4장에 서술하였다. DNN이 초기 ANN에서 Hidden Layer 층을 늘려 발전되었듯이 Hidden Layer의 개수가 증가할수록 네트워크의 성능은 향상된다. 하지만 이러한 성능의 향상이 Hidden Layer를 구성하는 GRU Node 수의 증가로 인한 것인지 Hidden Layer 층의 증가로 인한 것인지 알 수 없다. 따라서 본 연구에서는 GRU Node 수를 전체 개수를 고정하여 Hidden Layer의 구성을 변화시켜가며 최적의 구성을 설정하였으며, 세부사항은 4장에 서술하였다.

3.3 네트워크 학습

본 연구에서 제안한 GRU 기반 네트워크를 학습시키기 위하여, 임의의 하중에 따른 구조물의 응답 데이터를 수집하였다. 다양한 주파수 영역대에 대한 응답을 예측할 수 있도록, 구조물의 하중을 Band Limited White Noise (BLWN)로 설정하였다. 구조물의 하중으로 사용될 BLWN데이터의 길이는 60 Hz의 Sampling rate로 총 60초이며, 주파수 범위는 0 Hz~30 Hz이다. BLWN 데이터마다 임의의 seed를 사용하여 1,000개의 각기 다른 데이터셋을 구축하였다. BLWN에 따른 구조물의 응답 데이터를 수집하기 위해서 구조물의 수치해석 모델을 제작하여 시뮬레이션을 수행하였다. 각 BLWN 데이터셋에 따른 1,000개의 구조물 응답데이터를 수집하였으며, 시뮬레이션은 다자유도계 운동방정식을 상태공간 방정식으로 변환 후 Simulink를 활용하여 수행하였다.

다자유도의 운동방정식은 Eq. (5)와 같이 나타낼 수 있다.

$$M\ddot{x} + C\dot{x} + Kx = P \quad (5)$$

이때, M, C, K 는 각각($n \times n$) 크기의 질량행렬, 감쇠행렬 및 강성행렬이며, x 는 구조물의 변위 벡터, P 는 하중 행렬이며, n 은 자유도수를 나타낸다. 운동 방정식을 풀기 위해, 상태방정식(Eq. (6))과 출력방정식(Eq. (7))으로 이루어진

상태공간모델(State-Space Model; Eq. (8))을 작성하였다.

$$\dot{z}(t) = A_s \cdot z(t) + B_s \cdot P(t) \quad (6)$$

$$y(t) = C_s \cdot z(t) + D_s \cdot P(t) \quad (7)$$

$$A_s = \begin{bmatrix} O & I \\ -M^{-1}K & -M^{-1}C \end{bmatrix}, \quad (8)$$

$$B_s = \begin{bmatrix} O \\ q \end{bmatrix},$$

$$C_s = [I \ O],$$

$$D_s = [0 \ 0 \ 0]^T \quad (q = [-2k/m \ 0 \ 0]^T)$$

$z(t)$ 는 상태벡터(state vector)로써, 구조물의 변위벡터 x 와 속도벡터 $\dot{x}$ 으로 이루어진 벡터이며, $y(t)$ 는 사용자가 얻고자 하는 변수로 구성된 출력변수(observation vector)로써, 본 연구에서는 구조물의 변위벡터 x 로 설정하였다. 이렇게 구성된 State-Space Model을 이용하여 Simulink를 통해 시뮬레이션을 진행하였다.

시뮬레이션을 통해 수집한 1,000세트의 학습데이터(하중데이터와 그에 따른 응답데이터)를 활용하여 네트워크를 학습시켰다. 네트워크 학습은 Solver에 사용할 최적화 함수, 반복횟수(Epoch), 배치(batch) 크기 등이 학습의 결과에 영향을 미치게 된다. 먼저 Solver에 사용되는 최적화 함수로는 Momentum, Adagrad, Adadelta, RMSprop, Adam 등의 함수들이 대표적으로 사용된다(Sutton, 1986; Duchi et al., 2011; Zeiler, 2012; Kingma and Ba, 2014; Ruder, 2016). 본 연구에서는 Momentum과 RMSprop의 장점을 조합하여 빠르고 정확하게 적절한 목적 함수(objective function)를 찾는 Adam method를 이용하였다. 네트워크의 학습 반복 횟수(Epoch)는 데이터를 반복하여 학습시키는 횟수를 의미한다. 일반적으로 반복 횟수가 많을수록 정확한 결과가 나타나지만, 지나치게 높으면 해당 데이터에 대해 과적합 문제가 발생할 수 있다. 본 연구에서는 학습 결과가 충분히 수렴하면서 과적합이 발생하지 않도록 반복횟수(Epoch)를 10,000회로 설정하여 학습을 진행하였다. 마지막으로, 배치(batch) 크기란 한 번의 학습에 사용되는 데이터의 크기를 의미한다. 배치를 크게 하면 한 번의 학습에 사용되는 데이터의 수가 많아지므로 학습 속도가 빨라지지만 오차가 발생하게 된다. 이러한 문제를 방지하기 위해 본 연구에서는 배치 크기를 128로 설정하여 학습을 진행하였다.

4. 검증 실험

4.1 검증 실험 구성

본 연구에서 개발한 GRU 기반 네트워크가 지진 하중에 따른 구조물의 응답을 얼마나 정확하게 예측 할 수 있는지를

검증하기 위하여 3층 건물에 대한 시뮬레이션 기반 검증 실험을 수행하였다. Fig. 3은 검증 실험의 과정을 나타낸 것이다. 검증 실험의 Input 데이터로 총 200세트의 Band Limited White Noise (BLWN) 시계열 데이터를 사용하였으며, 본 연구에서 개발한 GRU 기반 네트워크를 통해 예측한 구조물의 응답을 시뮬레이션 결과와 비교하였다.

먼저 Hidden Unit 수에 따른 네트워크의 성능을 비교하기 위하여 Hidden Unit 수를 2부터 9까지 변화시켜가며 구조물의 응답 예측을 비교하였으며, GRU Node 수에 따른 네트워크 성능을 비교하기 위하여 GRU Node 수를 1부터 15까지 변화시키며 구조물의 응답 예측을 비교하였으며, Hidden Layer의 구성에 따른 네트워크 성능을 비교하기 위하여 Hidden Layer의 구성을 변화시키며 구조물의 응답 예측을 비교하였다. 마지막으로 위에서 서술한 각 실험별로 얻은 최적의 Hidden Unit 수와 GRU Node 수, Hidden Layer의 구성을 사용하여, 본 연구에서 개발한 GRU기반 네트워크의 정확도를 검증하였다.

4.2 검증실험 결과

먼저, 본 연구에서 개발한 GRU 기반 네트워크에서 Hidden Unit 수의 영향을 알아보기 위하여 Hidden Unit 수를 2부터 9까지 변화시키며 실험을 진행하였다. Hidden Layer 층과 GRU Node는 각각 1개로 구성하였으며, Hidden Unit 수에 따른 구조물의 응답 예측결과와 시뮬레이션 결과를 비교하여, 오차와 학습 소요 시간을 Fig. 4(a)에 나타내었다. 이를 통해 Hidden Unit이 2~8개까지는 오차율이 감소하며, 8개를 초과하여도 크게 감소하지 않음을 확인할 수 있다. 따라서 Hidden Unit을 8개로 하였을 때, 최적의 결과를 도출하였다.

GRU Node의 수에 따른 네트워크의 성능을 비교하기 위하여 GRU Node 수를 1부터 15까지 변화시켜가며 실험을 진행하였다. Hidden Layer의 수는 1개로, Hidden Unit의 수는 8개로 구성하였다. Fig. 4(b)는 GRU Node 수에 따른 RMSE를 비교한 결과와 학습 소요 시간을 나타내었다. Fig. 4(b)에서 나타나듯이, Hidden Unit 수와 마찬가지로 GRU Node 수가 증가할수록 네트워크의 성능이 향상되는 것을 알 수 있었다. 하지만 GRU Node 수가 증가할수록 학습

Fig. 3. Simulated Validation Test Configuration

Fig. 4. Error Rate and Learning Time for the Proposed System by (a) Number of Hidden Units, and (b) Number of GRU Nodes

Fig. 5. 9 Different Configurations for the GRU Layer

Fig. 6. Error Rate and Learning Time for Different Network Configurations

Fig 7. Predicted Response using (a) Using the Proposed System Node and (b) A Single GRU Node

시간은 기하급수적으로 증가한다. GRU Node 수를 12개 이상으로 설정할 경우, 학습시간에 비하여 네트워크의 성능 향상도가 저조하기 때문에, 본 연구에서는 GRU Node 수를 12개로 구성하였다.

Hidden Layer의 구성에 따른 네트워크의 성능을 비교하기 위하여 Hidden Layer를 Fig. 5와 같이 9개의 case로 구분하여 각 case별로 실험을 진행하였다. 모든 case에 대해서 총 GRU Node 수는 12개로 동일하게 설정하였으며, Case 1은 GRU Layer는 단일 레이어로 구성하고 모든 Node를 병렬로 연결하였으며, Case 2부터 Case 5까지는 GRU Layer와 각 레이어의 GRU Node와 레이어 수의 곱이 12가 되도록 하여 구성하였고, Case 6부터 Case 9까지는 각 레이어의 GRU Node 수가 다르도록 하여 구성하였다. 각 case별로 네트워크의 성능을 비교한 결과는 Fig. 6과 같다. 표에서 알 수 있듯이, Case 6의 RMSE가 13.59%로 가장 높은 정확도를 나타냈으며, Case 7은 13.85%로 두 번째로 높은 정확도를 나타냈고, Case 9가 가장 낮은 정확도를 나타냈다. 반면에 학습에 소요되는 시간은 GRU Node의 수가 동일하기 때문에 비슷한 시간이 소요되는 것으로 나타났다. 따라서 본 연구에서는 높은 정확도를 유지하면서도 학습시간이 너무 오래 걸리지도 않도록 Hidden Unit을 8개, GRU Node 수는 12개로 설정하고, Hidden Layer의 GRU Node를 층별로 각각 1, 5, 1, 5개로 구성하였다.

본 시스템에서 제안한 네트워크로 예측한 구조물의 응답과, 단일 노드를 이용하여 예측한 구조물의 응답을 각각 Figs. 7(a) and 7(b)에 나타내었다. Fig. 7에서 알 수 있듯이, 단일 GRU 노드를 사용하였을 경우에는 구조물의 예측응답이 시뮬레이션 결과와 큰 차이를 나타내었지만, 본 시스템에서 제안한 네트워크는 시뮬레이션 결과가 거의 일치하는 결과를 나타내었다.

5. 결 론

본 연구는 인공지능망의 한 종류인 GRU (Gated Recurrent Unit) 네트워크를 활용하여 특정 구조물의 하중에 따른 응답을 자동으로 예측하는 시스템을 개발하였다. 제안한 시스템은 하중의 시계열 데이터 입력을 위한 Input Layer와, GRU Layer, 그리고 응답 데이터를 내보내는 Output Layer로 구성되었으며, GRU Layer는 Hidden Unit의 수가 8개, GRU Unit의 수가 12개, 그리고 구성이 층별로 각각 1, 5, 1, 5개일 때 가장 높은 정확도를 나타내었다.

본 연구에서 개발한 GRU기반의 네트워크를 활용한다면, 기존의 구조물에 대한 거동 정보를 수집하여 아직 발생하지 않은 가상의 하중에 대한 구조물의 응답을 예측할 수 있을 것으로 기대된다. 본 연구에서 개발한 GRU 기반 네트워크는 이론적으로는 선형 시스템뿐만 아니라 비선형 시스템으로의 확장도 용이하여, 복잡한 구조물 시스템의 거동을 유한요소

모델보다 더욱 효과적으로 예측할 수 있을 것으로 기대된다.

본 연구에서 개발한 GRU기반 네트워크는 3층 구조물에 대한 시뮬레이션 데이터로 학습되었기 때문에, 이를 실구조물에 적용시키기 위해 생기는 문제점들을 향후 연구에서 해결하고자 한다.

- 1) 본 연구에서는 구조물에 가해지는 하중을 Band Limited White Noise (BLWN)로 한정시켜 진행하였다. 다양한 주파수대역에서의 구조물의 응답 데이터를 얻기 위하여 본 연구는 주파수 범위가 0 Hz~30 Hz의 BLWN를 하중 데이터로 사용하였다. BLWN가 아닌 특정 주파수 성분만 지닌 하중 데이터에 대해서는 본 연구에서 제안한 방법의 정확도가 검증되지 않았다. 향후, 입력 데이터의 종류와 위치를 다양화시켜 다양한 형태의 하중 데이터에 대한 구조물의 응답을 예측하는 연구를 진행할 계획이다.
- 2) 본 연구에서는 3자유도의 구조물을 대상으로 하였다. 실구조물의 경우, 많은 부재와 결합부로 구성되어 있기 때문에, 정확한 모델링을 위해서는 많은 자유도를 필요로 한다. 자유도가 높은 구조물의 거동은 본 연구에서 사용한 3자유도 구조물의 거동보다 더 복잡한 형상의 거동이 나타나기 때문에, GRU 네트워크의 최적 GRU노드 수, 레이어 구성 등을 변경해야 할 것으로 예상된다. 또한, 자유도가 높은 구조물의 경우, 3자유도 모델보다 더 많은 학습데이터를 필요로 할 것으로 예상된다.
- 3) 본 연구에서는 시뮬레이션을 이용하여 학습데이터를 수집하였다. 본 연구에서 개발한 GRU기반 시계열응답 예측 기법을 실구조물에 적용시키기 위해서는, 실 구조물에 가해지는 하중과 응답에 대한 많은 데이터의 수집이 요구된다. 현재 우리나라의 모든 구조물에 대해서 지진 하중과 응답의 학습데이터를 구축하는 것은 어렵지만, 특정 중요 구조물에 대해서 모니터링 시스템을 구축 후 지진이 일어날 때 마다 그 거동을 기록해 둔다면 향후 재난 대응 및 피해 예측에 큰 도움을 줄 수 있을 것으로 기대된다.

감사의 글

이 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(21CTAP-C152100-03).

References

- Brownjohn, J.M., Xia, P.Q., Hao, H., and Xia, Y. (2001). Civil structure condition assessment by FE model updating: Methodology and case studies. *Finite*

- Elements in Analysis and Design*, Vol. 37, No. 10, pp. 761-775.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., et al. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Ciregan, D., Meier, U., and Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. In *2012 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 3642-3649). IEEE.
- Duchi, J., Hazan, E., and Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, Vol. 12, No. 7.
- Hinton, G.E., Osindero, S., and Teh, Y.W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, Vol. 18, No. 7, pp. 1527-1554.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780.
- Jaishi, B., and Ren, W.X. (2006). Damage detection by finite element model updating using modal flexibility residual. *Journal of Sound and Vibration*, Vol. 290, No. 1-2, pp. 369-387.
- Jung, H.S., Lee, M., Yoo, M., and Lee, I.W. (2020). Response dominant frequency analysis for scour safety evaluation of railroad piers. *Journal of the Korean Geotechnical Society*, Vol. 36, No. 11, pp. 83-95.
- Kingma, D.P., and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Li, S. (2000). Global flexibility simulation and element stiffness simulation in finite element analysis with neural network. *Computer Methods in Applied Mechanics and Engineering*, Vol. 186, No. 1, pp. 101-108.
- Liu, C., Lay, T., Brodsky, E.E., Dascher-Cousineau, K., and Xiong, X. (2019). Coseismic rupture process of the large 2019 Ridgecrest earthquakes from joint inversion of geodetic and seismological observations. *Geophysical Research Letters*, Vol. 46, No. 21, pp. 11820-11829.
- Ma, F., Ng, C.H., and Ajavakom, N. (2006). On system identification and response prediction of degrading structures. *Structural Control and Health Monitoring: The Official Journal of the International Association for Structural Control and Monitoring and of the European Association for the Control of Structures*, Vol. 13, No. 1, pp. 347-364.
- Meng, Z., Bai, L., Zhang, M., Wu, Z., Li, Z., Pu, M., et al. (2018). The deadliest tornado (EF4) in the past 40 years in China. *Weather and Forecasting*, Vol. 33, No. 3, pp. 693-713.
- Naganuma, T., Deodatis, G., and Shinozuka, M. (1987). ARMA model for two-dimensional processes. *Journal of Engineering Mechanics*, Vol. 113, No. 2, pp. 234-251.
- Oh, S., and Shin, S. (2016). Correlation analysis of gyeongju earthquake waveform and structural damage scale. *Journal of the Architectural Institute of Korea Structure & Construction*, Vol. 32, No. 12, pp. 33-44.
- Ozdogli, A.I., and Koutsoukos, X. (2019). Machine learning based novelty detection using modal analysis. *Computer-Aided Civil and Infrastructure Engineering*, Vol. 34, No. 12, pp. 1119-1140.
- Peeters, B., and De Roeck, G. (1999). Reference-based stochastic subspace identification for output-only modal analysis. *Mechanical Systems and Signal Processing*, Vol. 13, No. 6, pp. 855-878.
- Pinelli, J.P., Simiu, E., Gurley, K., Subramanian, C., Zhang, L., Cope, A., et al. (2004). Hurricane damage prediction model for residential structures. *Journal of Structural Engineering*, Vol. 130, No. 11, pp. 1685-1691.
- Powell, G.H., and Allahabadi, R. (1988). Seismic damage prediction by deterministic methods: Concepts and procedures. *Earthquake Engineering & Structural Dynamics*, Vol. 16, No. 5, pp. 719-734.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological review*, Vol. 65, No. 6, pp. 386.
- Rosenblatt, F. (1961). *Principles of neurodynamics. perceptrons and the theory of brain mechanisms*. Cornell Aeronautical Lab Inc Buffalo NY.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986). Learning representations by back-propagating errors. *Nature*, Vol. 323, No. 6088, pp. 533-536.
- Shi, Y., Hao, H., and Li, Z.X. (2008). Numerical derivation of pressure-impulse diagrams for prediction of RC column damage to blast loads. *International Journal of Impact Engineering*, Vol. 35, No. 11, pp. 1213-1227.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The*

- Journal of Machine Learning Research*, Vol. 15, No. 1, pp. 1929-1958.
- Sutton, R. (1986). Two problems with back propagation and other steepest descent learning procedures for networks. In *Proceedings of the Eighth Annual Conference of the Cognitive Science Society* (pp. 823-832).
- Wang, G., and Zhang, S. (2014). Damage prediction of concrete gravity dams subjected to underwater explosion shock loading. *Engineering Failure Analysis*, Vol. 39, pp. 72-91.
- Zeiler, M.D. (2012). Adadelta: An adaptive learning rate method. *arXiv preprint arXiv:1212.5701*.
- Zhang, J., Cao, X., Xie, J., and Kou, P. (2019). An improved long short-term memory model for dam displacement prediction. *Mathematical Problems in Engineering*, 2019.

Received	March 11, 2021
Revised	March 12, 2021
Accepted	March 22, 2021