다층퍼셉트론과 합성곱 신경망에 기반한 지진 지반응답해석

Seismic Ground Response Analysis Based on Multilayer Perceptron and Convolution Neural Networks

홍석경* · 안재훈**

Hong, Seokgyeong*, and Ahn, Jaehun**

Abstract

The importance of establishing a disaster prevention plan considering seismic performance is being highlighted to reduce damage to structures caused by earthquakes. Earthquake waves propagate from the bedrock to the ground surface through the soil. During the transmission process, they are amplified in a specific frequency range, and the degree of amplification depends mainly on the characteristics of the ground. Therefore, a seismic response analysis process is essential for enhancing the reliability of the seismic design. We propose a model for predicting seismic waves on the surface from seismic waves measured on the bedrock based on Multilayer Perceptron (MLP) and Convolutional Neural Networks (CNN) and validate the applicability of the proposed model with Spectral Acceleration (SA). Both the proposed models based on MLP and CNN successfully predicted the seismic response of the surface. The CNN-based model performed better than the MLP-based model, with a 10% smaller average error. We plan to implement the physical properties of the ground, such as shear wave velocity, to create a more versatile model in the future.

Key words : Seismic Ground Response, Multilayer Perceptron (MLP), Convolution Neural Networks (CNN)

요 지

지진으로 인한 구조물의 피해를 줄이기 위한, 내진성능을 고려한 방재계획 수립의 중요성이 부각되고 있다. 지진파는 기반암으로부터 기반암 상부의 토사지반을 통해 전달된다. 전달되는 과정에서 특정 진동수(frequency)범위에서 증폭되기도 하며, 그 증폭 정도는 주로 지반 특성에 따라 좌우된다. 따라서 내진 설계의 신뢰성을 높이기 위해서는 지진 지반응답해석 과정이 필수적이다. 본 연구에서는 지반 하부 혹은 기반암의 지진파로부터 지표의 지진파를 예측하기 위한 모델을 다층퍼셉트론(MLP)과 합성곱 신경망(CNN) 인공신경망 모델을 바탕으로 제안하고, 제안한 모델의 적용성을 가속도 스펙트럼을 바탕으로 검증하였다. MLP와 CNN에 기반 하여 제안된 모델 모두 지표면의 지진파 가속도를 성공적으로 예측하였다. 또한, CNN에 기반한 모델은 MLP 모델과 비교하여 예측 지진파의 가속도 스펙트럼 평균오차가 약 10% 작게 산출되는 것을 확인하였다. 향후에는 해당 지역의 전단파 속도 등의 물성을 모델에 적용하여, 보다 보편적으로 활용할 수 있는 모델을 생성하고자 한다.

핵심용어 : 지진 지반응답해석, 다층퍼셉트론(MLP), 합성곱 신경망(CNN)

1. 서 론

지진 발생에 따른 지진·지반재해는 사회 및 경제적으로 막대한 피해를 야기한다(Green et al., 2011; Lee et al., 2012). 따라서 지진 재해를 예방하는 것이 매우 중요하다. 지진으로 인한 피해를 줄이기 위해서는 지진의 예상 규모

에 따른 구조물의 내진성능을 고려한 방재계획을 수립해야 한다.

지진파는 기반암으로부터 기반암 상부의 토사지반을 통해 전달된다. 전달되는 과정에서 특정 진동수(frequency) 범위에서 증폭되기도 하며, 그 증폭 정도는 지반 특성에 따라 좌우된다. 따라서 내진 설계의 신뢰성을 높이기 위해

*정회원, 부산대학교 사회환경시스템공학과 석사과정(E-mail: topkid4140@pusan.ac.kr)

Member, Master's Course, Department of Civil and Environmental Engineering, Pusan National University

**교신저자, 정회원, 부산대학교 사회환경시스템공학과 교수(Tel: +82-51-510-7627, Fax: +82-51-510-9596, E-mail: jahn@pusan.ac.kr)

Corresponding Author, Member, Professor, Department of Civil and Environmental Engineering, Pusan National University

서는 지진 지반응답해석 과정이 필수적이다(Kramer, 2005; Phanikanth et al., 2011). 지진 지반응답해석은 지진에 의해서 발생한 지반 운동이 지반 조건에 따라 증폭되는 정도를 예측하기 위해서 수행하는 과정이다. 지진 지반응답해석은 지반의 물성, 지진의 규모 등의 입력변수가 요구된다.

Adeli and Yeh (1989)이 인공신경망의 토목·구조 공학 응용에 관한 연구를 발표한 후로, 해당 분야에서 인공신경망을 활용한 연구가 활발히 진행되고 있다. Wu and Jahanshahi (2019)는 지반과 구조물간의 상호작용을 고려하고자 기존의 MLP 모델을 참고하여 3층 규모의 철재 골조의 linear single degree of freedom (SDOF), nonlinear SDOF system, multi-degree of freedom의 동적 응답을 추정하기 위한 Convolution Neural Networks를 제안하였다. Yu et al. (2020)은 탄화수소 탐사 및 개발 과정에서 Multilayer Perceptron을 포함하는 머신러닝 알고리즘을 적용하여 간극수압의 예측에 있어서 Parametric model에 비해 높은 예측 정확도를 보였다.

본 논문은 특정지역에 대해 기반암에서 계측된 지진파 데이터와 그에 대응하는 지표면에서 계측된 지진파 데이터를 학습한 인공신경망 모델을 통해 지표면에서의 지진파를 예측하고자했다.

2. 인공신경망 모형

계측 데이터에 기반한 지진 지반응답해석을 위해 인공신경망 모형 Multilayer Perceptron (MLP)과 Convolution Neural Networks (CNN)를 적용하였다.

2.1 Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP)은 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 인공신경망으로 Fig. 1의 형태를 가진다. MLP의 입력층은 다수의 입력 데이터를 받고, 출력층은 데이터의 출력을 담당한다. 은닉층은 입력층과 출력층 사이에서 두 층을 연결시킨다. 은닉층의 층수와 각 층의 노드 개수를 설정하여 모델을 구성한다.

Fig. 1. Typical form of the MLP with Hidden Layer (Roshan, 2020)

2.2 Convolution Neural Networks (CNN)

Convolution Neural Networks (CNN)는 인공신경망에 필터를 적용함으로써 이미지 특징 추출을 더욱 효과적으로 처리하기 위한 모형이다. CNN은 Convolution 과정과 Pooling 과정을 통해 진행된다. Convolution 과정은 데이터의 특징을 추출하고 도출시키는 과정이며, Pooling 과정은 Convolution 과정을 거친 레이어의 사이즈를 줄여주는 과정이다. Fig. 2는 CNN의 일반적인 과정을 나타낸다.

3. 지진 지반응답해석 절차

3.1 지진파 계측 데이터

일본은 지정학적, 지질학적 특징으로 인해 매년 크고 작은 규모의 지진이 발생한다. 이에 따라 일본은 1995년 고베 지진 발생 이후, 일본의 NIED (The National Research Institute for Earth Science and Disaster Prevention)에서는 일본 전역에 지진계를 배치하여 지진의 계측 및 기록을 하고 있으며, KiK-NET을 통해 지진 발생 위치, 규모, 속도, 측정된 위치의 지층종류 등의 정보를 제공하고 있다. 본 연구를 위해 선정한 지역은 진원 기준 지진규모 6.0 이상 9.0 이하 지진의 영향을 받은 후쿠시마현 카와마타 지역이다.

Fig. 2. Typical process of the CNN (DummyKoders, 2020)

3.2 지진 지반응답해석 모형

본 연구는 후쿠시마현 카와마타 지역 지반 하부 기반암에서 계측된 50개의 지진파 데이터(입력데이터)와 그에 대응하는 지표면으로 전파된 50개의 지진파데이터(출력데이터)를 인공신경망 모형 MLP, CNN에 각각 적용하여 지반응답가속도를 예측 및 비교하였다. 입력데이터는 시간이력의 가속도, 속도, 변위로 구성하였다. 지진파의 시간에 따른 가속도 데이터를 Seismosoft (2016)에서 제공한 Seismo Signal 프로그램을 통해 적분한 후 속도를 생성, 속도를 적분하여 변위를 생성하였다. 출력데이터는 지진파의 시간에 따른 가속도 데이터만으로 구성되었다. 입력데이터와 그에 대응하는 출력데이터로 세트를 구성하여 총 50세트의 데이터 중에 40세트(학습데이터 세트)는 인공신경망 모형에 적용하여 모델을 학습시키고, 나머지 10세트(검증데이터 세트)는 학습된 모델에 입력하여 적용성을 검증하였다.

MLP 모델은 100개의 노드를 가진 하나의 은닉층을 적용하였고, CNN 모델은 (10,1)의 크기를 갖는 필터를 60개 적용하였다. Convolution과정을 수행한 후, Pooling과정은 적용하지 않았다. 두 모형의 학습 과정에서 손실함수는 Eq. (1)에 나타난 Mean squared error (MSE)를 적용하였다. Optimizer는 Kingma and Ba (2014)가 제안한 Adam을, Activation 함수는 Nair and Hinton (2010)에 의해 제안된 Rectified Linear Units (ReLU)을 적용하였다.

$$MSE = \frac{1}{n} \sum (y - \hat{y})^2 \quad (1)$$

3.3 가속도 스펙트럼(Spectral Acceleration)

특정한 지진에 대하여 특정 감쇠율을 가진 단자유도 구조물의 진동주기에 따른 동적해석을 수행한 후에 발생하는 구조물의 주기별 최대 가속도를 가속도 스펙트럼(Spectral Acceleration, SA)이라고 한다. 본 연구는 인공신경망 모형을 바탕으로 학습시킨 모델로 예측한 10개의 지표면 지진파 가속도 스펙트럼과 실제 계측된 10개의 지표면 지진파 가속도 스펙트럼을 비교·분석하였다.

4. 지진 지반응답해석 결과

4.1 지진 지반응답해석 결과

인공신경망을 적용한 지진 지반응답해석 결과를 Figs. 3-6에 나타내었다. MLP모델이 예측한 지표면 지진파 SA와 대응되는 실제 지표면에서 계측된 지진파 SA를 Fig. 3에 나타내었다. 그리고 Fig. 3의 각 지진파의 오차($Error_{each}$)를 Eq. (2)를 이용하여 산정한 후, Fig. 4에 나타내었다. CNN모델에 의해 예측된 지진파 SA와 실제 지표면의 지진파 SA를 Fig. 5에 나타냈다. 그리고 Fig. 5의 각 지진파의 오차($Error_{each}$)를 Eq. (2)를 이용하여 산정한 후, Fig. 6에 나타내었다.

$$Error_{each} = S_{a.measure} - S_{a.predict} \quad (2)$$

각 인공신경망 모형의 훈련 손실값과 검증 손실값을 MSE를 바탕으로 산정하여 Table 1을 통해 나타내었다.

Table 1. Train and Test Losses (MSE)

Loss	MLP	CNN
Train	1.80×10^6	1.53×10^6
Test	0.00103	0.00067

각 지진파별 평균 오차($Error_{avg}$)를 Eq. (3)을 바탕으로 산정하였다. 이때, i 는 단자유도 구조물의 주기번호, n 은 주기의 개수를 나타낸다. 산정한 각 지진파별 평균 오차($Error_{avg}$)를 Table 2를 통해 나타내었다.

$$Error_{avg} = \frac{1}{n} \sqrt{\sum_{i=1}^n (S_{a.measure(i)} - S_{a.predict(i)})^2} \quad (3)$$

Table 2. Mean Error of the Seismic Waves by the Type of Neural Networks

Seismic Wave	MLP	CNN
1	0.00228	0.00167
2	0.00573	0.00239
3	0.00105	0.00082
4	0.00072	0.00091
5	0.00044	0.00027
6	0.00056	0.00036
7	0.00051	0.00046
8	0.00032	0.00031
9	0.00029	0.00054
10	0.00015	0.00011
Average	0.00111	0.00073

4.2 결과 비교·분석

MLP모델로 예측한 지진파와 실제 지진파는 유사한 경향을 보였고, 높은 예측 정확도를 나타냈다. MLP, CNN모델 모두 1번 지진파와 2번 지진파의 오차 평균이 나머지 지진파 오차의 평균보다 큰 것을 확인할 수 있는데, 이는 1, 2번 지진파의 예측이 다른 지진파에 비해 정확도가 다소 낮기도 하지만 지진파의 규모 자체가 커서 SA가 크기 때문이다. CNN모델로 예측한 오차는 MLP 모델에 비해 평균적으로 10% 작은 것으로 나타났다. 다만 10개 지진파 중 2개의 지진파의 경우 CNN 모델에 의한 평균 오차가 더 큰 것을 확인하였다.

(a) Seismic wave 1

(b) Seismic wave 2

(c) Seismic wave 3

(d) Seismic wave 4

(e) Seismic wave 5

(f) Seismic wave 6

(g) Seismic wave 7

(h) Seismic wave 8

(i) Seismic wave 9

(j) Seismic wave 10

Fig. 3. SA Predicted by MLP Model and SA Measured on the Ground Surface

(a) Seismic wave 1

(b) Seismic wave 2

(c) Seismic wave 3

(d) Seismic wave 4

(e) Seismic wave 5

(f) Seismic wave 6

(g) Seismic wave 7

(h) Seismic wave 8

(i) Seismic wave 9

(j) Seismic wave 10

Fig. 4. Error Between SA Predicted by MLP Model and SA Measured on the Ground Surface

(a) Seismic wave 1

(b) Seismic wave 2

(c) Seismic wave 3

(d) Seismic wave 4

(e) Seismic wave 5

(f) Seismic wave 6

(g) Seismic wave 7

(h) Seismic wave 8

(i) Seismic wave 9

(j) Seismic wave 10

Fig. 5. SA Predicted by CNN Model and SA Measured on the Ground Surface

(a) Seismic wave 1

(b) Seismic wave 2

(c) Seismic wave 3

(d) Seismic wave 4

(e) Seismic wave 5

(f) Seismic wave 6

(g) Seismic wave 7

(h) Seismic wave 8

(i) Seismic wave 9

(j) Seismic wave 10

Fig. 6. Error Between SA Predicted by CNN Model and SA Measured on the Ground Surface

인공신경망 모형은 Parameter를 어떤 식으로 설정하는지에 따라 예측 정확도의 변화를 보였다. 특히, 논문에서 제안된 모형의 경우에는 CNN 모형의 필터 크기를 키우고 Pooling 과정을 생략했을 때 예측 성능이 눈에 띄게 향상되었다.

5. 결 론

본 연구는 지반하부 혹은 기반암에서 계측된 지진파와 그에 대응하는 지표면 계측된 지진파를 인공신경망 모형 MLP와 CNN을 바탕으로 학습시킨 모형을 생성하고, 생성된 모형에 기반암에서의 지진파를 입력하여 지표면에서의 지진파를 예측하였다.

후쿠시마현 카와마타 지역 기반암에서 계측된 지진파의 가속도, 속도, 변위로 구성된 입력데이터와 그에 대응하는 지표면에서 계측된 지진파의 가속도로 구성된 출력데이터를 세트로 구성하고, 본 연구에 50세트를 사용하였다. 40세트를 통해 각 인공신경망 모형 모형을 훈련시켰고, 나머지 10세트를 통해 모형의 적용성을 가속도 스펙트럼을 바탕으로 검증하였다.

MLP모형과 CNN모형 모두 기반암 지진파를 입력받아 지표면 지진파를 성공적으로 예측하였다. CNN모형에 의해 예측된 지진파와 실제 계측 지진파의 평균오차는 MLP모형에 의한 결과에 비해 약 10% 작은 평균오차를 보이는 것을 확인할 수 있었다.

향후 지반의 물성에 해당하는 지층구조, 전단파 속도 등을 입력변수에 포함시켜 일반적인 지역에 적용할 수 있는 모형을 생성하고자 한다.

감사의 글

이 과제는 부산대학교 기본연구지원사업(2년)에 의하여 연구되었습니다.

References

- Adeli, H., and Yeh, C. (1989). Preceptron learning in engineering design. *Computer-Aided Civil and Infrastructure Engineering*, Vol. 4, No. 4, pp. 247-256.
- DummyKoders. (2020). *Face detection using MTCNN (Part 1)*. Medium. Retrieved from <https://medium.com/dummykoders/face-detection-using-mtcnn-part-1-c35c4ad9c542>
- Green, R.A., Olson, S.M., Cox, B.R., Rix, G.J., Rathje, E., Bachhuber, J., et al. (2011). Geotechnical aspects of failures at port-au-prince seaport during the 12 January 2010 haiti earthquake. *Earthq. Spectra*, Vol. 27, No. 1 (suppl 1), pp. 43-65. doi:10.1193/1.3636440.
- Kingma, D.P., and Ba, J. (2014). *Adam: a method for stochastic optimization*. arXiv:1412.6980
- Kramer, S.L. (2005). *Geotechnical earthquake engineering*. Upper Saddle River, NJ, USA: Prentice Hall.
- Lee, S.H., Sun, C.G., Yoon, J.K., and Kim, D.S. (2012). Development and verification of a new site classification system and site coefficients for regions of shallow bedrock in Korea. *J. Earthq. Eng.*, Vol. 16, No. 6, pp. 795-819. doi:10.1080/13632469.2012.658491
- Nair, V., and Hinton, G.E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th International Conference on International Conference on Machine Learning*, Haifa, Israel.
- Phanikant, V.S., Choudhury, D., and Reddy, G.R. (2011). Equivalent-linear seismic ground response analysis of some typical sites in Mumbai. *Geotech. Geol. Eng.*, Vol. 29, 1109. doi:10.1007/s10706-011-9443-8
- Roshan, B. (2020). *Applying ANN/Digit and fashion MNIST*. Medium. Retrieved from <https://medium.com/analytcs-vidhya/applying-ann-digit-and-fashion-mnist-13accfc44660>
- Seismosoft. (2016). Seismo signal [Computer software]. Retrieved from <https://seismosoft.com/products/seis-mosignal>
- Wu, R.T., and Jahanshahi, M.R. (2019). Deep convolutional neural network for structural dynamic response estimation and system identification. *Journal of Engineering Mechanics*, Vol. 145, No. 1, 04018125. doi:10.1061/(ASCE)EM.1943-7889.0001556
- Yu, H., Chen, G., and Gu, H. (2020). A machine learning methodology for multivariate pore-pressure prediction. *Computers & Geosciences*, Vol. 143, 104548. doi:10.1016/j.cageo.2020.104548

Received	January 4, 2021
Revised	January 4, 2021
Accepted	January 11, 2021