

기계학습 기반 강 구조물 지진응답 예측기법

Machine Learning based Seismic Response Prediction Methods for Steel Frame Structures

이 승 혜*
Lee, Seunghye

이 재 홍**
Lee, Jaehong

Abstract

In this paper, machine learning models were applied to predict the seismic response of steel frame structures. Both geometric and material nonlinearities were considered in the structural analysis, and nonlinear inelastic dynamic analysis was performed. The ground acceleration response of the El Centro earthquake was applied to obtain the displacement of the top floor, which was used as the dataset for the machine learning methods. Learning was performed using two methods: Decision Tree and Random Forest, and their efficiency was demonstrated through application to 2-story and 6-story 3-D steel frame structure examples.

Keywords : Machine learning, Steel frame structures, Seismic response, Prediction methods, Deep learning

1. 서론

2010년 이후 전 세계적으로 큰 주목을 받아왔던 규모(Magnitude) 7.0이 넘는 지진을 살펴보면 매년 1건 이상의 지진이 발생하는 것을 알 수 있다 <Table 1>. 이러한 지진은 내진설계가 제대로 이루어지지 않은 지역에서는 대규모의 인명 사상자가 발생하며, 2011년 동일본 대지진(도호쿠 지방 태평양 해역 지진)의 경우와 같이 선진기술력으로 준비를 해왔다 하더라도 지진해일이 수반되어 수 만명의 인명피해가 발생할 수 있다. 우리나라 또한 2016년 경주지진(M_w 5.4)과 2017년 포항지진(M_w 5.4)이 발생한 이후 한반도

가 더 이상 안전지대가 아니라는 인식이 자리 잡았다¹⁾.

<Table 1> Largest earthquakes by year (Since 2010)²⁾.

Year	Magnitude	Event
2010	8.8	2010 Chile earthquake
2011	9.0 - 9.1	2011 Tohoku earthquake
2012	8.6	2012 Indian Ocean earthquake
2013	8.3	2013 Okhotsk Sea earthquake
2014	8.2	2014 Iquique earthquake
2015	8.3	2015 Illapel earthquake
2016	7.9	2016 Solomon Islands earthquakes
2017	8.2	2017 Chiapas earthquake
2018	8.2	2018 Fiji earthquakes
2019	8.0	2019 Peru earthquake
2020	7.8	July 2020 Alaska Peninsula earthquake
2021	8.2	2021 Chignik earthquake
2022	7.6	2022 Michoacán earthquake
2022	7.6	2022 Papua New Guinea earthquake
2023	7.8	2023 Turkey-Syria earthquakes
2024	7.5	2024 Noto earthquake

* 정회원, 딥러닝 건축연구소,
세종대학교 건축공학과 조교수, 공학박사
Deep Learning Architecture Research Center
Dept. of Architectural Engineering,
Sejong University

** 교신저자, 정회원, 딥러닝 건축연구소,
세종대학교 건축공학과 교수, 공학박사
Deep Learning Architecture Research Center
Dept. of Architectural Engineering,
Sejong University
Tel: 02-3408-3287
E-mail: jhlee@sejong.ac.kr

구조물의 내진성능평가(Seismic performance assessment) 및 지진응답예측(Seismic response prediction)을 위해서는 수치해석 모델링을 통해 비선형 지진응답을 수행해야 하지만 이는 많은 계산시간과 인력, 비용이 요구된다. 이는 실제 지진에 대한 구조물의 동적응답 산정이 지반과 구조물 사이의 상호작용(Soil-Structure Interaction, SSI)을 고려하여 다양한 지반조건 하에서 FDM(Finite Difference Method) 혹은 FEM(Finite Element Method) 기반 상용소프트웨어를 사용하여 모델링 및 데이터베이스 구축을 하기 때문이다³⁾.

최근 기계학습(Machine learning) 혹은 인공지능(Artificial intelligence) 기법을 사용하여 구조물의 지진응답을 예측하려는 연구가 많이 진행되고 있다. 축적된 데이터를 사용하는 지도학습(Supervised learning) 기반의 모델은 대부분 Artificial Neural Network (ANN)의 적용을 시작으로 진행한다. 특히 구조물의 비선형 거동을 예측하는 기술에는 다양한 기계학습 기법이 사용되어 온 것을 알 수 있다. Neural Network⁴⁾ 뿐 만 아니라 Long Short-Term Memory (LSTM)⁵⁾, WaveNet⁶⁾, Convolutional Neural Network (CNN)⁷⁾ 등 다양한 기법을 통해 예측률을 높이려는 노력이 계속되고 있다.

본 연구에서는 지진에 대한 강 구조물의 비선형 응답을 예측하는 기계학습 모델을 제안하였다. Beam-column으로 구성된 프레임 구조물을 대상으로 기하 비선형성(Geometrical nonlinearity)과 재료 비선형성(material nonlinearity)을 고려하였으며 2차 비탄성해석(second-order inelastic analysis)을 적용하였다. El Centro 지진⁸⁾을 적용하여 응답해석을 수행하였으며 분류(Classification)와 회귀(Regression)에 모두 사용할 수 있는 지도학습형 기계학습 알고리즘인 Decision Tree⁹⁾와 앙상블학습(Ensemble learning) 기법 중 하나인 Random Forest¹⁰⁾ 기법을 사용한 예측모델을 제안하였다. 2-Story 와 6-Story의 강구조 모델을 사용하여 효율성을 입증하였다.

2. 프레임 구조의 비선형 동적해석

2.1 프레임 구조

프레임 강 구조물의 해석을 수행하기 위해 선행 연구의 비선형 해석 모델을 채택하였다¹¹⁾. 본 해석 모델은 기하 및 재료 비선형성을 적용하며 소성힌지모델(Plastic hinge model)¹²⁾의 수정된 버전을 사용한다. 부재에 증분되어 가해지는 기본 하중과 변형 간의 관계식은 다음과 같이 나타낼 수 있다.

$$\begin{Bmatrix} P \\ M_{yA} \\ M_{yB} \\ M_{zA} \\ M_{zB} \\ T \end{Bmatrix} = \begin{bmatrix} E_t A/L & 0 & 0 & 0 & 0 \\ 0 & k_{iyy} & k_{ijy} & 0 & 0 \\ 0 & k_{iyy} & k_{jyy} & 0 & 0 \\ 0 & 0 & 0 & k_{iiz} & k_{ijz} \\ 0 & 0 & 0 & k_{iiz} & k_{jiz} \\ 0 & 0 & 0 & 0 & GJ/L \end{bmatrix} \begin{Bmatrix} \delta \\ \theta_{yA} \\ \theta_{yB} \\ \theta_{zA} \\ \theta_{zB} \\ \phi \end{Bmatrix} \quad (1)$$

여기서 좌항의 P, M_{yA}, M_{yB}, M_{zA}, M_{zB}, T는 각각 증분하여 가해지는 축력(Axial force), y축과 z축에 대한 단부모멘트(End moment), 비틀림하중(torsion)을 나타낸다. 좌항의 δ, θ_{yA}, θ_{yB}, θ_{zA}, θ_{zB}, φ는 각각 증분하여 가해지는 하중에 대한 변위(displacement), 절점 회전각(joint rotation)과 비틀림각(Angle of twist)을 의미한다. 6x5 행렬식 안의 A, I_y, I_z, L은 각각 부재 단면적, y축과 z축에 대한 관성모멘트(moment of inertia)와 부재의 길이를 뜻하며 E_t는 잔류응력(Residual stress)으로 인한 점진적인 항복을 설명하는 CRC(Column Research Council) 접선계수(Tangent modulus)이며 G는 재료의 전단계수를 뜻한다. 행렬식 안의 k항목은 다음과 같다.

$$k_{iyy} = \eta_A \left(S_1 - \frac{S_2^2}{S_1} (1 - \eta_B) \right) \frac{E_t I_y}{L} \quad (2a)$$

$$k_{ijy} = \eta_A \eta_B S_2 \frac{E_t I_y}{L} \quad (2b)$$

$$k_{jyy} = \eta_B \left(S_1 - \frac{S_2^2}{S_1} (1 - \eta_A) \right) \frac{E_t I_y}{L} \quad (2c)$$

$$k_{iiz} = \eta_A \left(S_3 - \frac{S_4^2}{S_3} (1 - \eta_B) \right) \frac{E_t I_z}{L} \quad (2d)$$

$$k_{ijz} = \eta_A \eta_B S_4 \frac{E_t I_z}{L} \quad (2e)$$

$$k_{jjz} = \eta_B \left(S_3 - \frac{S_4^2}{S_3} (1 - \eta_A) \right) \frac{E_t I_z}{L} \quad (2f)$$

여기서 S_1, S_2, S_3, S_4 는 각각 y 축과 z 축에 대한 안정함수(Stability function)를 뜻한다¹³⁾. 식(2a)부터 식(2f)의 η_A 와 η_B 는 A와 B 양 끝단에서 소성화로 인한 비탄성 강성 감소를 허용하는 스칼라 매개변수이다. 이 항은 탄성 상태일 때 1.0 소성한지로 되었을 때 0의 값을 갖는다. 매개변수 η 는 아래 식과 같이 포물선 함수로 변화하는 것으로 가정된다.

$$\eta = 1.0 \text{ for } \alpha \leq 0.5 \quad (3a)$$

$$\eta = 4\alpha(1 - \alpha) \text{ for } \alpha > 0.5 \quad (3b)$$

여기서 α 는 Orbison yield surface로 다음과 같이 나타낼 수 있다.

$$\alpha = 1.15p^2 + m_z^2 + m_y^4 + 3.67p^2m_z^2 + 3.0p^6m_y^2 + 4.65m_z^4m_y^2 \quad (4)$$

여기서 식(4) 항목의 함수는 다음과 같이 나타낼 수 있다.

$$p = P/P_y \quad (5a)$$

$$m_z = M_z/M_{pz} \text{ (strong-axis)} \quad (5b)$$

$$m_y = M_y/M_{py} \text{ (weak-axis)} \quad (5c)$$

2.2 동적 해석

수치 증분에 대한 운동방정식(equation of motion)을 풀기 위해 Newmark-beta Method¹⁴⁾중 Constant-Average-Acceleration 적분법이 사용되었다. 각 시간 단계의 잔류 힘은 Newton-Raphson 반복과정을 통해 제거되며 구조물의 증분 운동방정식은 다음과 같다.

$$[M]\{\Delta \ddot{D}\} + [C]\{\Delta \dot{D}\} + [K]\{\Delta D\} = \{\Delta F\} \quad (6)$$

여기서 $[\Delta \ddot{D}]$, $[\Delta \dot{D}]$, $[\Delta D]$ 는 각각 증분 가속도,

증분 속도, 증분 변위의 벡터를 의미한다. $[M]$, $[C]$, $[K]$ 는 각각 질량, 감쇠, 탄젠트강성 행렬을 의미한다. 시간 스텝은 $k+1$ 스텝에서 k 단계를 뺀 차로 나타내며 ($\Delta t = t_{k+1} - t_k$) $\{\Delta F\}$ 하중 증분이 구조물에 가해질 때 본 해석법은 반복과정을 통해 수렴 해를 찾아낸다. $k+1$ 단계의 변위 $\{\Delta D^{k+1}\}$ 는 이전 단계 변위 $\{\Delta D^k\}$ 에 계산된 변위 증분 $\{\Delta D\}$ 을 더하여 계산된다.


$$\{\Delta D^{k+1}\} = \{\Delta D^k\} + \{\Delta D\} \quad (7)$$

각 스텝이 수렴하여 해를 찾으면 구조물의 응답은 아래와 같은 식을 사용하여 갱신된다.

$$\{D_{n+1}\} = \{D_n\} + \{\Delta D^{k+1}\} \quad (8a)$$

$$\{\dot{D}_{n+1}\} = -\{\dot{D}_n\} + \frac{2}{\Delta t} \{\Delta D^{k+1}\} \quad (8b)$$

$$\{\ddot{D}_{n+1}\} = -\{\ddot{D}_n\} - \frac{4}{\Delta t} \{\Delta \dot{D}_n\} + \frac{4}{\Delta t^2} \{\Delta D^{k+1}\} \quad (8c)$$



〈Fig. 1〉 Ground acceleration spectrum of El Centro earthquake

3. 구조물 응답 데이터 확보

본 연구에서는 El Centro 지진을 사용하여 구조물 응답 데이터를 수집하였다. 1940년 5월 18일 미국 캘리포니아 남부 Imperial Valley에서 발생한 El Centro 지진은 규모 6.9로 본 지역에 막대한 피해를 주었다. El Centro 기록으로 알려진 지반 운동 데이터는 지진 공학 연구에 광범위하게 사용되고 있으며 내진 설계

및 구조해석 방법론의 발전에 크게 기여하였다. (Fig. 1)은 El Centro 지진의 지반 가속도 응답데이터를 나타낸 그래프이다.

본 연구에서는 해당 구조물에 El Centro 지진의 지반 가속도 응답 데이터를 대입하여 최상층 변위 응답을 도출하였다. 2장에서 서술한 비선형 동적해석 기법을 사용하여 Python 코드를 작성하였으며 이를 통해 시간에 따른 변위 응답을 2차원 그래프로 얻을 수 있었다. 시간 스텝의 증분은 1/50으로 하였으며 Newmark-beta method를 위한 수렴기준은 10^{-9} 으로, 감쇠계수는 0.05로 설정하였다.

4. 기계학습 예측모델

최적의 회귀 기법을 선택하기 위해 주요한 속성은 종속변수(Dependent variable)과 독립변수(Independent variable)의 특성과 변수간의 관계라 할 수 있지만 일반적인 회귀 문제는 독립변수를 입력으로 받아 그에 대한 종속변수를 결과로 예측하는 문제 형태를 취한다. 선형 회귀(Linear regression) 기법은 가장 기본적인 형태라 할 수 있지만 현실의 대부분 문제는 비선형 형태를 띠게 마련이다. 최근에는 Decision Tree 학습법이나 앙상블 기법(Ensemble method)¹⁵⁾로 비선형 데이터의 해석을 수행하는 추세이다. 본 연구에서는 Decision Tree와 앙상블 기법 중 하나인 Random Forest 모델을 사용하여 지진하중에 대한 구조물 응답 예측을 수행하였다.

2.1 Decision Tree

Decision Tree 알고리즘은 앞서 소개한 바와 같이 분류 및 회귀 작업 모두에 널리 쓰이는 강력한 기계학습 방법 중 하나이다. Decision Tree 기법은 특성값을 기반으로 데이터를 반복적으로 분할하여 최종 예측을 제공하는 일련의 결정 노드(Decision node)와 리프 노드(Leaf node)를 생성함으로써 마치 나무(Tree)와 같이 결정모델을 구성한다. 분류 작업 중 다양한 분할 기준을 설정하는데 주로 지니 불순도(Gini Impurity)나 엔트로피(Entropy)를 사용한다. 이러한 분할 기준은 나무를 분할 함에 있어 분할 품질을 평

가하는데 사용되며 효과적인 예측 모델의 생성을 보장한다. 과적합(Overfit)하는 경향에도 불구하고 단순성과 해석이 가능한 특징으로 인해 여전히 널리 사용되고 있다.

2.1 Random Forest

Decision Tree와 같이 트리 기반의 알고리즘(Tree-based algorithm)들이 관측값과 목표값을 연결시켜주는 예측모델에 결정트리를 사용한다면 앙상블 기법은 이러한 결정트리를 사용하지만 다양한 학습 알고리즘들을 결합하여 개별 알고리즘만으로 얻을 수 있는 것 보다 더 나은 예측 성능을 도출한다.

Random Forest 기법은 다중의 의사결정 트리를 구성하고 그 예측을 집계하여 모델의 정확도와 견고성을 향상시키는 앙상블 학습 방법이다. 이 방법은 무작위 기능선택(Random feature selection)을 활용하여 과적합과 분산을 전체적으로 줄이는 다양한 트리를 구성한다. 분류 작업의 경우 Decsion Tree가 특정 분할기준을 사용하여 확장하는 것이 비해 회귀 문제에서의 Random Forest는 개별 트리의 예측 평균을 사용한다.


하지만 모델이 복잡하고 비선형에 최적화 되었다고 해서 무작정 예측율이 높은 것이 아니므로 해당 데이터에 적합한 예측모델을 찾는 과정은 필수로 수반되어야 한다. 최근 다양한 구조해석 및 설계 문제에 기계학습 예측기법을 적용하는 연구들을 많이 찾아볼 수 있으나 각각의 데이터를 분석하고 전처리(preprocssion)과정을 통해 정제된 뒤 다양한 모델을 적용하는 과정은 시행착오(Trial and error)법처럼 수행되어야 하므로 데이터 경향에 맞는 최적의 모델을 찾는 궁극적인 목표를 위해 모두 필요한 과정이라 하겠다.

2.3 시계열 교차 검증 기법

예측 기법이 주어진 데이터 세트에만 과적합한 모델을 만드는 것을 방지하기 위해 전체 데이터 세트를 시계열 교차 검증(Time series cross validation)기법을 통해 분할하여 평가하였다. 보통의 기계학습 과정은 훈련 세트(training set)와 테스트 세트(test set)를

일정한 비율로 분할하는 방법을 사용한다. 하지만 데이터 세트의 일부 구간을 따로 분할하여 훈련을 진행할 시 훈련 데이터에만 과적합하는 오류를 범하기 쉽다. 이를 방지하기 위해 많이 쓰이는 방법이 교차검증(Cross validation) 기법이다. 교차검증은 모집단 D를 k개의 집합으로 나누어 (k-1)개의 부분 집합을 훈련 세트로 사용하고 나머지 하나의 부분 집합을 테스트 세트로 사용하는 방식을 취한다. 총 k번의 훈련과 테스트를 거쳐 k개의 테스트 결과값에 대한 평균을 얻는 방식을 k겹 교차 검증(k-fold cross validation) 기법이라고 부른다.

본 연구의 데이터는 시간에 따른 순서가 존재하는 시계열성을 나타내기 때문에 k겹 교차 검증에서 더 나아가 관찰의 시간적 순서를 유지하며 훈련 데이터의 부분 집합을 취하는 시계열 교차 검증 기법을 사용하였다. 이 접근 방법은 과거의 데이터를 사용하여 미래 결과를 예측하는 실제 시나리오를 보다 정확하게 반영한다. (Fig. 2)는 시계열 교차 검증 기법의 예시를 그림으로 나타낸 것이다.



(Fig. 2) Illustration of the time series cross validation technique

2.4 평가기법


본 연구에서는 각 예측 모델의 성능을 평가하기 위해 평균 제곱 오차(Mean Squared Error: MSE)와 결정계수(Coefficient of determination: R^2) 두 가지 평가기법을 도입하였다. 특히 결정계수 R^2 지표는 예측 값(t)이 입력 값에 대해 얼마나 설명력을 갖게 되는지를 의미하는 수치로 1에 가까운 수일수록 양의 상관관계를 의미한다. n개의 데이터 샘플을 사용하였을 때 두 가지 성능 평가 지표의 식은 아래와 같다.

- Coefficient of determination (R^2)

$$R^2 = \left(\frac{n \sum ty - (\sum t)(\sum y)}{\sqrt{n(\sum t^2) - (\sum t)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \right)^2 \quad (9)$$

- Mean Square Error (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (10)$$




(Fig. 3) Two-story steel frame structure


5. 수치해석

본 연구에서는 2-Story 와 6-Story의 강구조 모델에 기계학습 예측모델을 적용하여 성능을 비교하였다. 해당 구조물에 El Centro 지반 가속도 응답을 가력한 후 최상층의 변위 응답을 도출하여 데이터를 구성하였다. 기계학습 예측을 위한 입력(Input)과 출력(Output)은 각각 El Centro 지진에 의한 지반 가속도와 비선형 동적 해석을 수행한 최상층의 변위 응답이 된다. 입력과 출력이 모두 단변량(univariate)이므로 비교적 쉬운 예측 문제라고 치부하기 쉬우나 입력 및 출력 모두 정(Positive)과 부(Negative) 방향으로 변가아 진동하는 형식으로 예측 모델 또한 비선형성을

된다. 수치해석을 위한 모델은 파이썬(Python) 프로그래밍 언어로 작성되었으며, 사이킷런(scikit-learn)¹⁶⁾ 라이브러리의 DecisionTreeRegressor, RandomForestRegressor를 사용하였다. 재현과 비교를 위해 모델을 위한 하이퍼 파라미터는 기본 설정을 사용하였다.



(a) Decision Tree



(b) Random Forest

〈Fig. 4〉 Comparison of ground truth and predicted response for 2-story steel frame structure

4.1 2-story steel space frame

첫 번째 예제는 2-story 강 프레임 구조물로 〈Fig. 2〉에 나타나 있다. 모든 부재는 W8 × 31 로 구성하였으며 재료의 탄성계수(Elastic modulus) 및 포아송비(Poisson's ratio)는 각각 200GPa과 0.3으로 설정하였다. 재료의 항복응력은 700MPa로 가정하였으며 프레임 절점에 질량은 50 N·sec²/mm로 입력하였다. x 방향의 기둥 간격은 3m, y 방향의 기둥 간격은 2.5m로 설정하였으며 1층과 2층의 층고는 각각 1.76m와 2.2m로 입력하였다. El Centro 지진은 x방향으로 가력되었으며 그에 대한 최상층 응답을 시간에 대한 변위 데이터로 수집하였다. 재료의 물성치는 〈Table 2〉에 정리되어 있다.

〈Fig. 4〉는 Decision Tree 모델과 Random Forest

모델을 사용하여 예측한 응답을 참값(Ground truth)과 비교한 것이다. 두 기법 모두 응답 경향을 잘 따르는 편이나 Decision Tree 모델의 예측률이 더 높은 것으로 파악되었다. 이는 〈Table 3〉의 결정계수 R²을 값을 비교하면 더 명확히 파악할 수 있다. 하지만 MSE 값이 Decision Tree의 경우가 더 큰 값을 보이는 것을 보아 일부 구간에서 실제 값과 크게 벗어나는 결과를 보임에 기인한 것으로 판단된다.

〈Table 2〉 Material properties of 2-story steel frame structure.

Property	
Elastic modulus	200 GPa
Poisson's ratio	0.3
Yield stress	700 MPa

〈Table 3〉 MSE and R-squared scores on the full dataset for 2-story steel frame structure.


	MSE	R ²
Decision Tree	2.22436	0.972
Random Forest	0.00016	0.785

4.2 6-story steel space frame


두 번째 예제는 6-story 강 프레임 구조물로 〈Fig. 5〉에 3차원 형상이 나타나 있으며 부재의 재료는 206,850 MPa의 탄성계수와 79,293 MPa의 전단계수 값을 갖는다. 프레임의 비선형 비탄성 동적해석을 위한 항복응력은 250 MPa로 설정하였다. 해당 구조물의 각 층 바닥 다이어프레임의 효과는 무시하였으며 9.6 kN/m²의 바닥하중에 가해진다. 6층 구간과 3층 구간이 접합되는 절점(8, 11, 14, 17, 20, 23)은 256.84 kN·sec²/m의 집중질량(Lumped mass)을, 이를 제외한 모든 절점은 128.42 kN·sec²/m의 집중질량을 가하였다. 모든 층은 3.658m의 층고를 가져 구조물은 총 21.948m의 높이이며 El Centro 지진은 y방향으로 가력되었다. 1층부터 3층의 기둥은 W12 × 87 부재를 선택하였으며 3층 구간과 6층 구간이 만나는 부재(13번~18번)는 W12 × 120 부재를 입력하였다. 4층부터 6층의 기둥은 W10 × 60 부재로 구성되어 있으며 모든 보 부재는 〈Fig. 6〉에 나타나 있다.

〈Table 4〉 Material properties of 2-story steel frame structure.

Property	
Elastic modulus	206,850 MPa
Shear modulus	79,293 MPa
Yield stress	250 MPa



〈Fig. 5〉 Six-story steel frame structure




〈Fig. 6〉 Plan view of a six-story steel frame

〈Fig. 7〉은 Decision Tree와 Random Forest 기법으로 6-story 프레임 구조물을 예측한 결과이다. 2-story의 결과와 마찬가지로 Decision Tree 기법이 더 좋은 결과값을 보이며 이는 〈Table 5〉의 R^2 값에서 확인할 수 있다($R^2 = 0.940$). Decision Tree를 사용한 결과라도 6-story의 경우 2-story의 경우보다 더 실제 응답 선을 벗어나는 노이즈(noise)가 보인다.


본 연구에서는 지진응답에 대한 구조물의 비선형 거동을 예측하는 가능한 모델을 제안하는 것으로 두 모델 모두 기본 값을 적용하였다. Random Forest의 평균화 특성 때문에 Decision Tree의 경우보다 노이즈가 많이 보이는 것처럼 보이나 두 기법 모두 추세선을 잘 따라가는 경향을 보여 추후 다양한 지진 응답을 통해 검증하고 모델을 수정해갈 필요가 있다.

〈Table 5〉 MSE and R-squared scores on the full dataset for 6-story steel frame structure.

	MSE	R^2
Decision Tree	0.00127	0.940
Random Forest	0.00509	0.760



(a) Decision Tree



(b) Random Forest

〈Fig. 7〉 Comparison of ground truth and predicted response for 6-story steel frame structure

6. 결론

본 논문에서는 강 구조물의 지진응답을 예측하기 위해 기계학습 모델을 적용하였다. 해당 구조물은 기하 및 재료 비선형 모두를 고려하였으며 비선형 비탄성 동적해석을 수행하였다. El Centro 지진의 지반가속도 응답을 가려하여 이에 대한 최상층의 변위를 얻었으며 이를 기계학습의 데이터셋으로 구성하였다. 학습은 Decision Tree와 Random Forest 두 가지 방법으로 수행하였으며 2-story와 6-story 예제에 적용하여 효율성을 입증하였다. 두 기법 모두 응답의 추세를 잘 따라가는 경향을 보이나 구조물의 주기가 길어질수록 노이즈를 보이는 경향이 있다. 추후 연구에서는 다양한 지진과 기계학습 기법을 적용하여 최적의 예측기법과 이를 수정하는 방법에 대해 연구할 필요가 있다.

감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2023R1A2C2003310).

References

1. Yun, S., Hamm, S., Jeon, H., and Cheong, J., "Trend Analysis of Earthquake Researches in the World", Journal of the Korean earth science society Vol.42, No.1 pp.76-87, 2021
2. <https://www.isc.ac.uk/iscgem/index.php>
3. Won, J., and Shin, J., "Development of Artificial Neural Network Model for Prediction of Seismic Response of Building with Soil-structure Interactio", JOURNAL OF THE KOREAN GEOTECHNICAL SOCIETY, Vol.36, No.8, pp. 7-15, 2020
DOI:<https://doi.org/10.7843/kgs.2020.36.8.7>
4. Lagaros, N. D., & Papadrakakis, M. (2012). Neural network based prediction schemes of the non-linear seismic response of 3D buildings. *Advances in Engineering Software*, 44(1), 92-115.
DOI:<https://doi.org/10.1016/j.advengsoft.2011.05.033>
5. Zhang, R., Chen, Z., Chen, S., Zheng, J., Büyüköztürk, O., & Sun, H. (2019). Deep long short-term memory networks for nonlinear structural seismic response prediction. *Computers & Structures*, 220, 55-68.
DOI:<https://doi.org/10.1016/j.compstruc.2019.05.006>
6. Ning, C., Xie, Y., & Sun, L. (2023). LSTM, WaveNet, and 2D CNN for nonlinear time history prediction of seismic responses. *Engineering Structures*, 286, 116083.
DOI:<https://doi.org/10.1016/j.engstruct.2023.116083>
7. Zhang, R., Liu, Y., & Sun, H. (2020). Physics-guided convolutional neural network (PhyCNN) for data-driven seismic response modeling. *Engineering Structures*, 215, 110704.
DOI:<https://doi.org/10.1016/j.engstruct.2020.110704>
8. Pacific Earthquake Engineering Research Center (PEER). (1940). "Imperial Valley (El Centro) Earthquake Record." PEER Ground Motion Database. Retrieved from <https://ngawest2.berkeley.edu/>
9. Quinlan, J. R.. "Induction of decision trees", *Machine Learning*, 1(1), p.p. 81-106, 1986
10. Breiman, L., "Random Forests", *Machine Learning*, 45(1), p.p. 5-32, 2001
11. Thai, H. T., & Kim, S. E., "Practical advanced analysis software for nonlinear inelastic analysis of space steel structures", *Advances in Engineering Software*, 40(9), p.p. 786-797, 2009
12. Housner, G. W. (1960). Limit Design of Structures. *Journal of the Engineering Mechanics Division, ASCE*, 86(EM4), 107-132.
13. Chen, W. F., & Lui, E. M. (1987). *Structural stability: theory and implementation*. (No

Title).

14. Newmark, N. M. (1959). A method of computation for structural dynamics. *Journal of the engineering mechanics division*, 85(3), 67-94.
15. Dietterich, T. G. (2000, June). Ensemble methods in machine learning. In *International workshop on multiple classifier systems* (pp. 1-15). Springer, Berlin, Heidelberg.
16. <https://scikit-learn.org/stable/>

- Received : May 28, 2024
- Revised : June 04, 2024
- Accepted : June 04, 2024