

# 경년열화를 고려한 전단벽 구조물의 기계학습 기반 지진응답 예측모델 개발

## Development of Machine Learning Based Seismic Response Prediction Model for Shear Wall Structure considering Aging Deteriorations

김 현 수\*  
Kim, Hyun-Su

김 유 경\*\*  
Kim, Yukyung

이 소 연\*\*\*  
Lee, So Yeon

장 준 수\*\*\*  
Jang, Jun Su

### Abstract

Machine learning is widely applied to various engineering fields. In structural engineering area, machine learning is generally used to predict structural responses of building structures. The aging deterioration of reinforced concrete structure affects its structural behavior. Therefore, the aging deterioration of R.C. structure should be considered to exactly predict seismic responses of the structure. In this study, the machine learning based seismic response prediction model was developed. To this end, four machine learning algorithms were employed and prediction performance of each algorithm was compared. A 3-story coupled shear wall structure was selected as an example structure for numerical simulation. Artificial ground motions were generated based on domestic site characteristics. Elastic modulus, damping ratio and density were changed to considering concrete degradation due to chloride penetration and carbonation, etc. Various intensity measures were used as input parameters of the training database. Performance evaluation was performed using metrics like root mean square error, mean square error, mean absolute error, and coefficient of determination. The optimization of hyperparameters was achieved through k-fold cross-validation and grid search techniques. The analysis results show that neural networks and extreme gradient boosting algorithms present good prediction performance.

*Keywords : Concrete Aging degradation, Machine learning, Seismic response prediction, Shear wall structure*

### 1. 서론

철근콘크리트 구조물에서 염화물 침투, 탄산화 등의 요인으로 인하여 열화가 발생하면 구조재료의 특성이 변화되고 때로는 철근이 부식되어 콘크리트의 탈락 등으로 구조물의 성능이 저하된다<sup>1)</sup>. 특히 지진하중에 대한 응답해석을 수행할 때 구조물의 경년열화는 동적 특성의 변화, 저항성능의 감소, 지진응답의 변화를 유발할 수 있다<sup>2)</sup>. 따라서 지진하중을 받는 철근콘크리트 구조물의 내진성능평가를 위해서는 열화를 고려한 구조해석은 필수적이다.

철근콘크리트 구조물에 재료의 특성 및 구조적 성능변화를 일으킬 수 있는 열화인자로는 염화물 침투, 콘크리트의 중성화(탄산화), 열효과 등이 있다. 이러한 열화인자들은 철근의 부식, 피복 콘크리트의 탈락, 콘크리트의 강도 및 강성 저하, 질량과 감쇠의 변화 등 구조물의 구조적 안전성과 지진응답에 영향을 미칠 수 있는 특성변화를 일으킬 수 있다. 따라서 이러한 열화인자들에 의한 철근콘크리트 재료의 불확실성을 고려하는 해석이 필요하다.

근래에 들어서 기계학습 기법은 구조공학의 다양한 분야에 활용되어 우수한 성과를 나타내고 있다<sup>3)</sup>. 특히 구조물의 거동예측에 우수한 성능을 나타내는 기계학습 기반 모델이 다수 개발되었고<sup>4,5)</sup> 이러한 기법들은 효과적인 구조물의 지진취약도 분석에 활용되고 있다<sup>6,7)</sup>. 기계학습은 학습용 데이터베이스를 기반으로 입력 출력 데이터간의 매우 복잡한 비선형관계를 분석하고 예측할 수 있는 모델을 생성하며 기존의 회귀분석 방

\* 교신저자, 종신회원, 선문대학교 건축학부 교수, 공학박사

Division of Architecture, Sunmoon University  
Tel: 041-530-2315 Fax: 041-530-2839  
E-mail : hskim72@sunmoon.ac.kr

\*\* 정회원, 선문대학교 건축학부 연구원

Division of Architecture, Sunmoon University

\*\*\* 학생회원, 선문대학교 건축학부 학사과정

Division of Architecture, Sunmoon University

법에 비해서 매우 정확도가 높은 결과를 나타낼 수 있는 기술이다. 본 연구에서는 기계학습 기법을 활용하여 경년열화를 고려한 철근콘크리트 구조물의 지진 응답 예측모델을 개발하고 그 정확성을 검증하였다.

기계학습모델의 개발을 위하여 지진하중을 받는 예제 철근콘크리트 구조물로 비교적 단순한 3층 병렬 전단벽 구조물을 선택 하였다. 구조물에 가해지는 하중으로는 인공지진하중을 생성하여 사용하였다. 본 연구에서는 인공지진하중을 생성하기 위해서 Rezaeian(2010)이 제안한 기법을 사용하였다. 이 방법에서는 추계학적인 방법과 필터링 방법을 조합하여 인공지진동을 생성하였다. 특히 시간 종속적인 필터와 주파수 영역대의 시간 종속적인 필터를 조합하여 필터를 구축하였고, 지진동의 시간 영역대와 주파수 영역대의 비안정적인(nonstationary) 특성을 잘 반영한다.

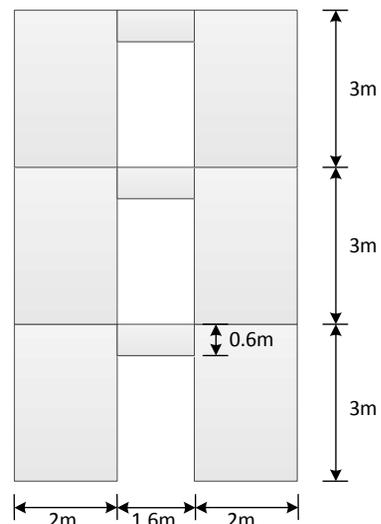
생성한 인공지반운동 시간이력 전체를 기계학습모델의 입력으로 사용할 수 없기 때문의 지반운동을 동적특성을 대표할 수 있는 특성값을 추출하였다. 이를 위해서 지진하중에 대한 취약도분석 등에서 널리 사용되고 있는 지진 강도지표(earthquake intensity measure)를 사용하였다. 지금까지 매우 다양한 지진 강도지표가 발표되었는데 본 연구에서는 PGA, PGV 등을 포함하여 널리 사용되고 있는 13개의 지진 강도지표를 사용하였다. 전술한 바와 같이 경년열화가 발생한 철근콘크리트 구조물에서는 재료의 강도 및 강성 저하, 질량과 감쇠의 변화 등이 발생하게 된다. 본 연구에서는 선형동적시간이력해석을 수행하므로 경년열화에 의한 재료의 특성변화는 탄성계수, 밀도, 감쇠의 변화로 고려하였다. 기계학습 기반 지진응답 예측모델의 출력(예측 목표)으로는 예제 구조물의 응답이 가장 크게 발생하는 최상층의 최대 횡변위를 선택하여 효과적으로 구조물의 안전성을 평가할 수 있도록 하였다.

지금까지 매우 다양한 기계학습 알고리즘이 발표되었다. 그 중 본 연구에서는 구조공학분야에 많이 적용되는 Decision Tree, Random Forest, XGBoost, Neural Network의 기계학습 알고리즘 4개를 선정하였고 이를 통해서 개발된 지진응답 예측모델의 정확성을 비교·검증하였다. 기계학습 모델의 예측성능을

검토하기 위해서는 유한요소해석 결과를 정확해로 보고 모델 예측치의 차이를 계산해서 평가하는 방법이 일반적이다. 본 연구에서는 다양한 기계학습모델 성능 평가지수 중에서 평균 제곱근 오차(Root Mean Square Error; RMSE), 평균제곱오차(Mean Squared Error; MSE), 평균 절대 오차(Mean Absolute Error; MAE) 및 결정계수 (Coefficient of determination; R2)를 이용하였다.

## 2. 예제구조물 및 지진하중

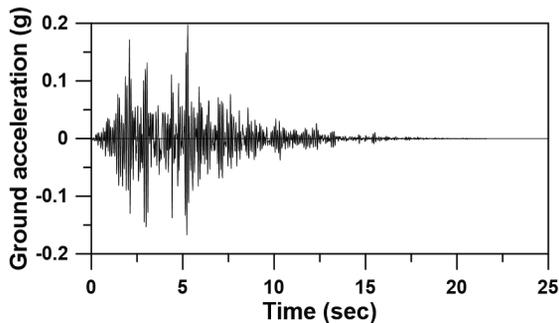
본 연구에서는 지진하중을 받는 건축 구조물의 동적응답을 예측하기 위해서 철근 콘크리트 예제구조물을 구성하였다. 예제구조물은 골조구조물보다 경년열화가 비교적 큰 3층 병렬 전단벽 구조물로 선택하였고 이를 <Fig. 1>에 나타내었다.



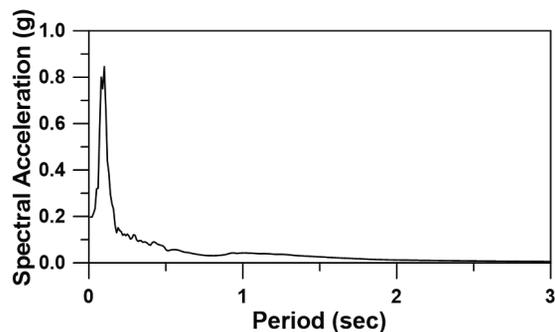
<Fig. 1> Shear wall example structure

예제구조물은 그림에 나타난 바와 같이 층고 4m의 3층 건물이며 병렬 전단벽의 형태를 나타낸다. 전단벽의 폭-높이 비는 1.5이고 두께는 200mm로 하였다. 본 연구에서는 최상층의 최대 횡변위를 기계학습 모델이 예측하는 목표값으로 선택하였다. 사용한 철근 콘크리트 재료의 탄성계수는  $2.58 \times 10^4 \text{ N/mm}^2$ , 프아송 비는 0.167, 밀도는  $2.35 \times 10^{-5} \text{ N/mm}^2$ 이고 감쇠는 Rayleigh Damping을 사용하였고 2%의 감쇠비를 갖도록 모형화하였다.

예제구조물에 가해지는 지진하중으로는 인공지진하중을 작성하여 사용하였다. 지금까지 여러 연구자들에 의해서 다양한 인공지진 생성기법이 제안되었다. 그 중에서 본 연구에서는 Rezaeian(2010)이 제안한 기법을 사용하였다. Rezaeian은 필터(Filter)의 매개변수를 조절하여 다양한 인공지진동을 생성하였다. 또한, 필터의 매개변수를 대상 부지의 비교적 관측하기 쉬운 물리적 특성값에 회귀 적합하여, 적은 수의 물리적 특성값으로부터 직접적으로 매개변수를 조절할 수 있도록 하였다. 따라서 적은 실측데이터가 가용하더라도, 회귀 적합식을 통해 매개변수를 추정할 수 있고, 이를 통해 부지 특성을 충분히 반영할 수 있을 것으로 기대하였다. 또한 불규칙 진동 이론에 기반한 확률적 모델로서, 부지 특성을 반영함과 동시에 특성이 서로 다른 다양한 인공 지진을 생성하여 딥러닝 모델의 과적합을 피하는 등 딥러닝 모델 학습용으로 적합할 것으로 예상된다.



〈Fig. 2〉 Time histories of artificial earthquakes



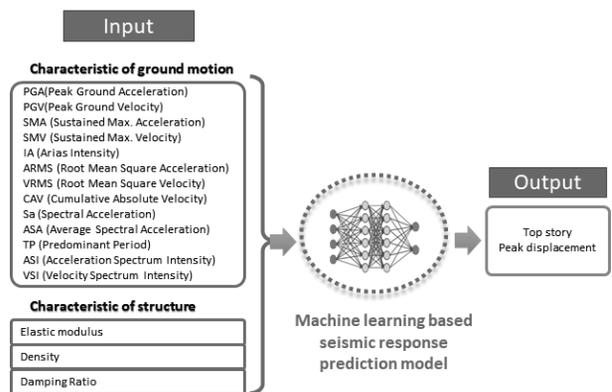
〈Fig. 3〉 Comparison of response spectrum

본 연구에서는 기계학습 모델의 개발과 검증을 위하여 Rezaeian(2010)이 제안한 기법을 적용하여 500 개의 인공지진을 생성하였고 그 중 하나의 지진에 대해서 〈Fig. 2〉와 〈Fig. 3〉에 지반가속도 시간이력과

응답스펙트럼을 나타내었다.

### 3. 지진응답 예측모델 학습을 위한 데이터베이스 구축

지진응답 예측 정확성이 높은 기계학습 모델을 개발하기 위해서는 적절한 학습 및 검증용 데이터베이스를 구축하는 것이 필요하다. 데이터베이스의 입력 및 출력은 〈Fig. 4〉에 나타난 바와 같다. 입력은 크게 지반운동의 특성과 구조물의 특성에 대한 변수로 이루어진다. 지반운동의 특성은 인공지진 가속도시간이력 데이터에서 특정한 값으로 추출한다. 이때 구조물의 지진 취약도 분석에 널리 사용되는 지진 강도지표를 사용하여 특성치를 추출하였다. 지진강도지표로는 일반적으로 PGA(peak ground acceleration)가 가장 널리 사용되고 있다. 본 연구에서는 〈Fig. 4〉에 나타난 바와 같이 PGA를 포함한 13개의 지진 강도지표를 지반운동 특성치로 사용하였다.



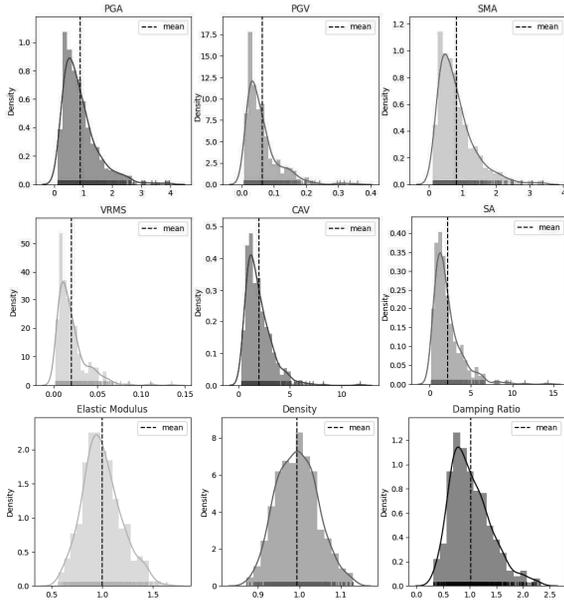
〈Fig. 4〉 Input and output of database

경년 열화에 의한 구조물 재료적 특성의 변화 및 불확실성을 고려하기 위해서 철근 콘크리트 재료의 탄성계수, 밀도 및 감쇠비를 변수로 선택하였다. 경년 열화에 의한 재료적 특성치들의 변화를 고려하여 해석시 사용한 특성치의 평균값과 변동계수를 〈Table 1〉에 나타내었다. 이 특성치들의 변동계수는 관련 선행연구<sup>9)</sup>에서 제안한 값을 사용하였다.

〈Table 1〉 Material parameter variation

Parameters	Distribution	Median	C.V.
Elastic modulus	Normal	25,8000 (MPa)	0.2
Density	Normal	$2.35 \times 10^{-5}$ (N/mm <sup>2</sup> )	0.05
Damping ratio	Log-normal	0.02	0.4

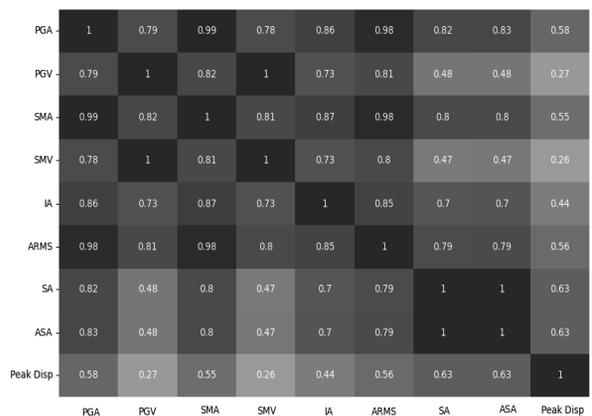
앞서 생성한 500개의 인공 지반가속도의 대표적인 특성치와 500개의 재료특성치 불확실성을 고려하기 위한 계수 데이터의 분포를 검토하기 위해서 히스토그램을 〈Fig. 5〉에 나타내었다. 그림에서 확인할 수 있듯이 지진 강도지표를 바탕으로 한 지반운동의 특성치는 모두 대수정규분포를 따르고 있고 이것은 지진 하중의 일반적인 특성을 잘 나타낸다고 볼 수 있다. 경년열화에 의한 재료 특성의 변화를 고려하기 위한 데이터도 〈Table 1〉에 나타낸 불확실성의 특성을 잘 표현하는 것을 알 수 있다.



〈Fig. 5〉 Distribution of input parameters

구성한 데이터베이스 입출력 특성(feature)간의 상관관계를 분석하기 위해서 〈Fig. 6〉에 특성 상관관계 히트맵을 나타내었다. 지반운동과 재료적 특성을 고려한 총 16개의 입력 변수 중에서 출력과 상관관계가

높은 변수를 선택하여 히트맵을 작성하였다. 그림을 보면 Spectral acceleration (SA, 0.63), Average spectral acceleration (ASA, 0.63), PGA(0.58)의 순으로 상관관계가 큰 것을 알 수 있다. 전반적으로 가속도와 관계된 지표의 상관관계가 높았고 속도와 관계된 지표의 상관관계가 낮은 것을 알 수 있다. 지면관계상 재료의 특성치 변화와 구조물의 응답과의 상관관계를 나타내지 못했지만 지반운동 특성치에 비해서 상관관계가 상대적으로 매우 작게 나타났다.



〈Fig. 6〉 Correlation heatmap of selected DB

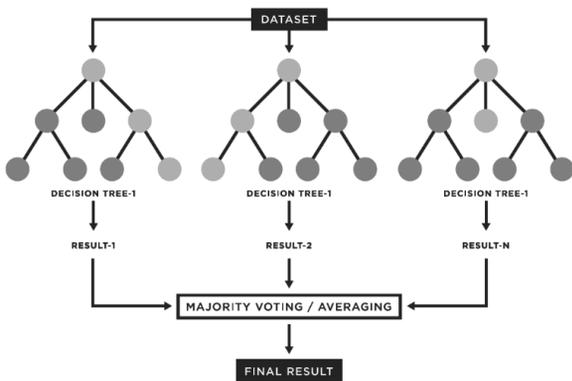
#### 4. 지진응답 예측모델개발을 위한 기계 학습 알고리즘

Thai(2002)는 1989년부터 2022년까지 발표된 485개의 논문을 분석하여 구조공학분야에 적용된 기계 학습 방법을 정리하였다. 이 연구결과를 보면 Neural networks 56%, Boosting algorithms 11%, Support vector machine 10%, Random forest 6%, Decision tree 5%의 비율로 사용되었다. 이러한 내용을 바탕으로 본 연구에서는 Neural networks, Boosting algorithms, Random forest, Decision tree의 4개의 알고리즘을 선정하여 구조물의 경년열화를 고려한 지진응답 예측모델을 개발하였다.

결정트리(Decision Tree, DT)는 데이터를 기반으로 하여 의사 결정 규칙을 학습하는 모델이다. 이 모델은 특성에 따라 데이터를 분할하여 트리 구조로 나타내며, 각 노드는 특정 특성에 대한 조건을 나타낸다. 이를 통해 데이터를 분류하거나 예측할 수 있다. 결정트

리의 장점은 해석이 쉽고 다양한 종류의 데이터를 처리할 수 있다는 것이다. 하지만 과적합되기 쉬운 단점이 있으며, 이를 극복하기 위해 가지치기와 같은 방법을 사용할 수 있다. 분류와 회귀 문제에 모두 활용이 가능한 지도 학습 모델 중 하나이다.

랜덤 포레스트(Random Forest, RT)는 <Fig. 7>에 나타낸 바와 같이 여러 결정트리를 조합하여 예측하는 알고리즘이다. 각 트리는 랜덤하게 선택된 데이터와 특성을 기반으로 학습하며, 이를 결합하여 더 정확하고 안정적인 예측을 수행한다. 각 트리는 독립적으로 학습하고 예측하기 때문에 과적합을 줄이고 다양한 종류의 데이터에 효과적으로 적용된다. 랜덤 포레스트는 대규모 데이터셋에서도 효과적이며, 분류와 회귀 문제에 모두 사용될 수 있다.



<Fig. 7> Concept of random forest<sup>10)</sup>

인공신경망(ANN)은 인간의 뇌의 구조에서 영감을 받아 만들어진 기계학습 모델이다. 이 모델은 여러 개의 뉴런으로 구성된 층(layer)을 가지고 있으며, 각 뉴런은 입력을 받아 가중치를 곱하고 활성화 함수를 통과시켜 출력을 생성한다. 이러한 층은 입력층, 은닉층, 출력층으로 구성된다. 인공신경망은 데이터를 학습하고 패턴을 발견하여 분류, 회귀, 패턴 인식 등 다양한 작업에 사용되며 딥러닝(Deep Learning)의 핵심 기술로 인정된다.

최근 기계학습 분야에서 부스팅 알고리즘이 우수한 성과를 나타내고 있다. 그 중 본 연구에서는 XGBoost 알고리즘을 사용한다. 이는 eXtreme Gradient Boosting의 준말로, 트리 기반의 앙상블 학습 알고리즘이다. Gradient Boosting의 확장된 버전으로, 각 트

리를 순차적으로 학습하면서 이전 트리의 오차를 보완하는 방식으로 동작한다. XGBoost는 트리 모델의 복잡성을 제어하기 위해 가지치기(pruning) 및 규제(regularization) 기법을 사용하며, 분류 및 회귀 문제 모두에 효과적으로 적용된다. 속도와 성능 면에서 우수하며, 대규모 데이터셋에서도 잘 작동한다고 알려져 있다.

본 연구에서 개발된 기계학습 모델의 지진응답 예측성능을 검토하기 위해서 회귀분석 연구에서 일반적으로 사용하는 4개의 평가지표를 사용하였고 이를 식 (1)-(4)에 나타내었다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

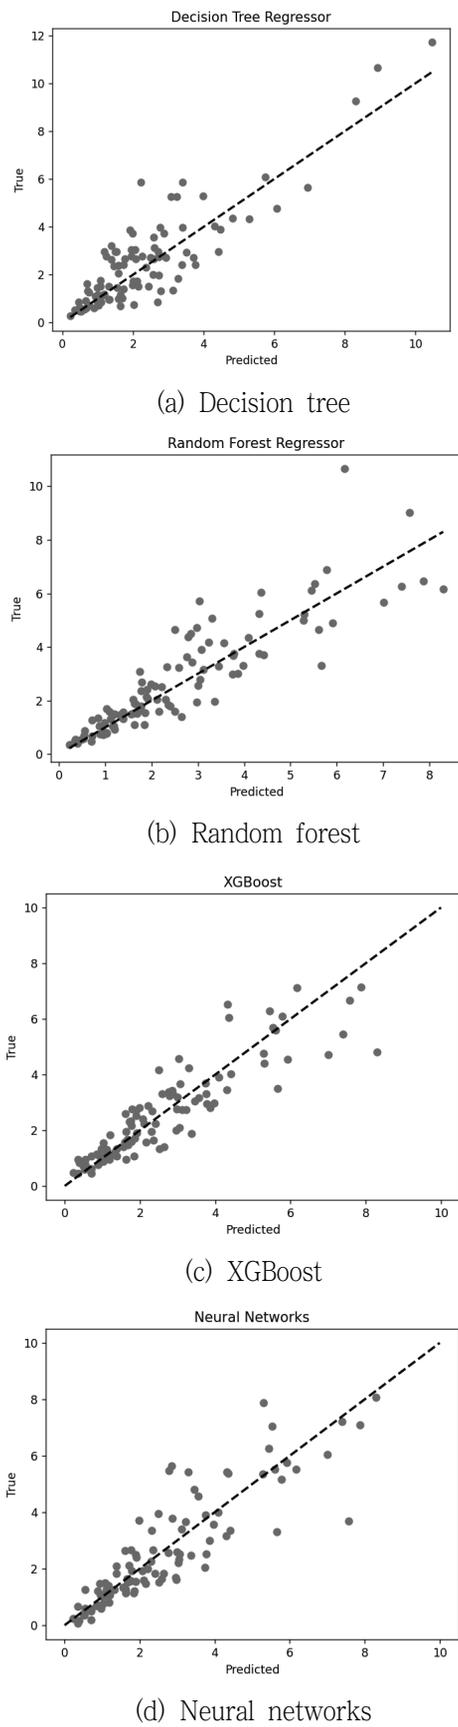
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{MSE}{Var(y)} \quad (4)$$

여기서, n은 관측치의 개수,  $\hat{y}_i$ 는 예측치,  $y_i$ 는 관측치,  $\bar{y}$ 는 관측치의 평균값, 그리고 Var는 목표값에 대한 분산을 의미한다.

## 5. 기계학습기반 지진응답 예측모델의 정확성 평가

앞 절에서 소개한 4개의 기계학습 알고리즘을 활용해서 예제 구조물에 대한 지진응답 예측모델을 개발하였다. 이때 500개의 데이터베이스 중에서 80%를 임의로 선택해서 학습에 사용하였고 학습에 사용되지 않은 20%의 데이터는 개발된 모델의 검증에 사용하였다. 즉, 검증에 사용되는 데이터는 개발된 지진응답 예측모델이 처음 접하는 데이터이다. 개발된 4개의 기계학습기반 지진응답 예측모델의 예측결과를 목표값과 비교하여 <Fig. 8>에 나타내었다.



〈Fig. 8〉 Predictions of ML models

가로축은 예측치이고 세로축은 참값으로 간주하는 목표값이므로 예측치가 대각선위에 나타나면 정확도가 높은 것을 의미한다. 그림을 보면 Decision tree 모델의 예측결과보다 Random forest 모델의 예측결과가 대각선에 더 가깝게 분포해있는 것을 알 수 있다. 또 Random forest 모델의 예측결과보다 XGBoost 모델의 예측결과가 더 대각선 주위에 모여서 존재하는 것을 알 수 있다. Neural networks 모델의 결과는 XGBoost 모델의 예측결과보다 대각선으로의 밀집도가 낮은 것을 알 수 있다. 네 개의 예측모델 모두에서 지진응답의 크기가 작은 부분에서는 대각선에 밀집되어 분포되어서 정확도가 높은 예측을 할 수 있지만 응답이 커질수록 정확도가 낮아지는 것을 알 수 있다. 이러한 현상의 이유는 〈Fig. 5〉에 나타난 데이터베이스의 분포를 보면 유추할 수 있다. 즉, 500개의 데이터베이스 중에서 지반운동의 강도가 작은 데이터가 압도적으로 많아서 작은 지반운동에 의한 크지 않은 지진응답은 기계학습 기반 모델이 충분히 학습하여 이러한 응답은 효과적으로 예측할 수 있지만 상대적으로 부족한 큰 지진응답에 대해서는 충분한 학습이 이루어지지 않아서 예측 정확도가 떨어지는 것으로 판단된다.

기계학습 모델의 예측정확성을 높이기 위해서는 최적의 하이퍼파라미터를 선택하는 것이 필요하다. 본 연구에서는 Random forest 모델을 개발할 때 13개의 트리모델을 사용하였다. XGBoost 모델을 개발할 때에는 17개의 트리모델을 사용하였으며 트리의 최대 깊이는 3으로 하였고 학습률은 0.3으로 하였다. Neural networks 모델을 구성하기 위해서 3개의 히든 레이어를 사용하였으며 각각의 노드 수는 50, 50, 10개로 하였다.

개발한 4개의 기계학습 기반 지진응답 예측모델의 정확성을 정량적으로 검토해보기 위해서 각 모델별로 앞서 소개한 4개의 성능평가지표를 계산하여 〈Table 2〉에 나타내었다. 4개의 기계학습 모델 중에서 Decision tree의 결정계수( $R^2$ )가 0.7로서 가장 작은 것을 알 수 있다. 이에 비하여 Random forest와 Neural networks 모델의 결정계수는 모두 0.74로 Decision tree 모델보다는 더 우수한 예측성능을 나타냈다. 두 모델의 결정계수는 같지만 RMSE와 MSE는

Neural networks 모델이 조금 더 작게 나타났다. 마지막으로 XGBoost 모델의 결정계수는 0.8로서 4개의 기계학습모델 중 가장 우수한 예측성능을 나타내었다. 이것은 <Fig. 8>에 그래프로 나타낸 예측성능과 유사한 결과를 보여준다.

<Table 2> Comparison of performance indices

M.L.	RMSE	MSE	MAE	R <sup>2</sup>
Decision tree	0.99	0.99	0.74	0.70
Random forest	0.95	0.90	0.65	0.74
XGBoost	0.83	0.69	0.59	0.80
Neural networks	0.94	0.89	0.65	0.74

## 5. 결론

본 연구에서는 철근 콘크리트 구조물의 구조적 성능과 동적 거동에 영향을 미치는 경년열화를 고려하여 전단벽식 구조물의 지진응답을 예측할 수 있는 기계학습 모델을 개발하였다. 이를 위해서 골조 구조물보다 콘크리트의 사용량이 커서 경년열화현상이 상대적으로 크게 발생할 것으로 예상되는 전단벽 구조물로 예제구조물을 작성하였다. 예제구조물에 가해지는 지진하중으로는 500개의 인공지진하중을 생성하였고 이를 활용하여 시간이력해석을 수행하였다. 해석시 경년열화 현상을 나타내기 위해서 철근 콘크리트 재료의 탄성계수, 밀도 및 감쇠비를 변수로 선택하여 변동계수로 불확실성을 고려하였다. 지진하중의 전체 시간 이력 데이터를 기계학습모델의 입력으로 사용할 수 없기 때문에 지반운동의 특성을 대표할 수 있는 지진 강도지표를 사용하여 데이터베이스를 구성하였다. 다양한 기계학습 알고리즘 중에서 본 연구에서는 Neural networks, XGBoost, Random forest, Decision tree의 4개의 기계학습 알고리즘을 선정하여 구조물의 경년열화를 고려한 지진응답 예측모델을 개발하였다. 개발된 경년열화모델의 예측성능을 평가하기 위해서 회귀분석모델 평가에 주로 사용되는 4개의 지표(RMSE, MSE, MAE, R<sup>2</sup>)를 사용하였다. 개발

된 기계학습 모델의 정확도를 평가해보면 Decision tree 모델의 정확도가 낮았고 그 다음으로 Random forest와 Neural networks의 정확도가 높은 것으로 나타났다. 본 연구에서는 XGBoost의 지진응답 예측성능이 가장 우수한 것으로 나타났다. 각 모델별 지진응답 예측성능 평가결과 학습데이터가 많았던 작은 지진응답에 대해서는 정확한 예측을 하였지만 상대적으로 학습 데이터가 적었던 큰 지진응답에 대해서는 예측의 정확도가 낮은 것을 확인할 수 있었다. 따라서 추후 연구에서는 기계학습 모델이 큰 지진응답에 대해서도 충분히 학습할 수 있도록 데이터베이스를 구축하고 보다 다양한 기계학습 알고리즘을 사용해서 예측 정확도를 더 높이기 위해 노력할 계획이다. 또한 본 연구에서는 구조물의 최상층 최대변위를 예측목표로 선정하였는데 추후 층간변위 및 가속도 응답도 예측목표에 포함하여 연구의 활용성을 더 높이는 방향으로 연구를 수행할 계획이다.

## 감사의 글

본 논문은 2022년도 가동원전 안전성향상 핵심기술개발사업의 지원으로 수행되고 있는 과제(과제번호: 20224B10200080) 내용의 일부입니다. 산업통상자원부와 한국에너지기술평가원의 연구비 지원에 깊은 감사를 드립니다.

## References

1. Hariri-Ardebili, M.A., Sanchez, L. and Rezakhani, R., "Aging of Concrete Structures and Infrastructures: Causes, Consequences, and Cures (C<sup>3</sup>)", *Advances in Materials Science and Engineering*, 2020, DOI:<https://doi.org/10.1155/2020/9370591>
2. Arel, H.S., Aydin, E. and Kore, S.D., "Ageing management and life extension of concrete in nuclear power plants", *Powder Technology*, Vol. 321, pp. 390-408, 2017, DOI:<https://doi.org/10.1016/j.powtec.2017.08.053>
3. Thai, H.T., "Machine learning for structural engineering: A state-of-the-art review",

- Structures, Vol. 38, pp. 448-491, 2022,  
DOI:<https://doi.org/10.1016/j.istruc.2022.02.003>
4. Kazemi, F., Asgarkhani, N. and Jankowski, R.,  
“Machine learning-based seismic response and performance assessment of reinforced concrete buildings”, Archives of Civil and Mechanical Engineering, Vol. 23, 2023.  
DOI:<https://doi.org/10.1007/s43452-023-00631-9>
5. Asgarkhani, N., Kazemi, F., Jakubczyk-Gańczyńska, A., Mohebi, B. and Jankowski, R.,  
“Seismic response and performance prediction of steel buckling-restrained braced frames using machine-learning methods”, Engineering Applications of Artificial Intelligence, Vol. 128, 2024,  
DOI:<https://doi.org/10.1016/j.engappai.2023.107388>
6. Kazemi, F., Asgarkhani, N. and Jankowski, R.,  
“Machine learning-based seismic fragility and seismic vulnerability assessment of reinforced concrete structures”, Soil Dynamics and Earthquake Engineering, Vol. 166, 2023,  
DOI:<https://doi.org/10.1016/j.soildyn.2023.107761>
7. He, S., Liao, Y., Sun, P.P. and Zhang, R., “Deep learning enabled seismic fragility evaluation of structures subjected to mainshock-aftershock earthquakes”, Urban Lifeline, Vol. 2, 2024,  
DOI:<https://doi.org/10.1007/s44285-024-00013-4>
8. Rezaeian, R. and Kiureghian, A.D., “Simulation of synthetic ground motions for specified earthquake and site characteristics”, Vol. 39, pp. 1155-1180, 2010,  
DOI:<https://doi.org/10.1002/eqe.997>
9. Wang, Z., Pedroni, N., Zentner, I. and Zio. E.,  
“Seismic fragility analysis with artificial neural networks: Application to nuclear power plant equipment”, Engineering Structures, Vol. 162, pp.213-225, 2018,  
DOI:<https://doi.org/10.1016/j.engstruct.2018.02.024>
10. Gunay, D., “Random Forests”, Retrieved May 15, 2024 from  
<https://medium.com/@denizgunay/random-forest-af5bde5d7e1e>  
2023
- Received : May 18, 2024
  - Revised : May 25, 2024
  - Accepted : May 31, 2024