

# 기계학습 기반 지진 취약 철근콘크리트 골조에 대한 신속 내진성능 등급 예측모델 개발 연구

## Machine Learning-based Rapid Seismic Performance Evaluation for Seismically-deficient Reinforced Concrete Frame

강태욱<sup>1)</sup> · 강제도<sup>2)</sup> · 오근영<sup>3)</sup> · 신지욱<sup>4)\*</sup>

Kang, TaeWook<sup>1)</sup> · Kang, Jaedo<sup>2)</sup> · Oh, Keunyeong<sup>3)</sup> · Shin, Jiuk<sup>4)\*</sup>

<sup>1)</sup>경상국립대학교 건축공학과 석사과정, <sup>2)</sup>서울연구원 안전인프라연구실 부연구위원, <sup>3)</sup>한국건설기술연구원 건축연구본부 수석연구원,

<sup>4)</sup>경상국립대학교 건축공학과 조교수(공학박사)

<sup>1)</sup>Student, Department of Architecture Engineering, Gyeongsang National University, <sup>2)</sup>Associate Research Fellow, Division of Safety and Infrastructure Research, The Seoul Institute, <sup>3)</sup>Senior Research, Department of Building Research, Korea Institute of Civil Engineering and Building Technology,

<sup>4)</sup>Assistant Professor (PhD), Department of Architecture, Gyeongsang National University

### / A B S T R A C T /

Existing reinforced concrete (RC) building frames constructed before the seismic design was applied have seismically deficient structural details, and buildings with such structural details show brittle behavior that is destroyed early due to low shear performance. Various reinforcement systems, such as fiber-reinforced polymer (FRP) jacketing systems, are being studied to reinforce the seismically deficient RC frames. Due to the step-by-step modeling and interpretation process, existing seismic performance assessment and reinforcement design of buildings consume an enormous amount of workforce and time. Various machine learning (ML) models were developed using input and output datasets for seismic loads and reinforcement details built through the finite element (FE) model developed in previous studies to overcome these shortcomings. To assess the performance of the seismic performance prediction models developed in this study, the mean squared error (MSE), R-square ( $R^2$ ), and residual of each model were compared. Overall, the applied ML was found to rapidly and effectively predict the seismic performance of buildings according to changes in load and reinforcement details without overfitting. In addition, the best-fit model for each seismic performance class was selected by analyzing the performance by class of the ML models.

**Key words:** Seismically-deficient RC frame, FRP jacketing system, Machine learning, Rapid seismic performance assessment

## 1. 서론

내진설계가 적용되기 이전에 건설된 기존 철근콘크리트(Reinforced Concrete, RC) 건축물은 주요 구조부재 중 기둥에서 지진에 취약한 구조 상세를 갖는다. 이러한 유형의 건축물은 일반적으로 작은 직경의 띠철근이 넓은 간격으로 배근되어 있으며, 겹침이음의 위치가 휨모멘트가 최대인 지점에 배치되어 있다. 특히, 기둥의 부적합한 전단철근 상세에 의하여 낮은 전단 성능을 발휘하기 때문에 구조 엔지니어의 예상보다 조기에 파괴되는 취성적 거동을 보인다[1-4]. 이러한 현상은 2017년 11월에 발생한 포항지진[5]과 1999년 8월 터키에서 발생한 Kocaeli 지진[6], 2023년 2월 튀르키

예 지진[7] 등에서 관찰된 건축물 붕괴사고를 예로 들 수 있다. 포항지진의 경우 건축물의 피해가 주로 학교 및 필로티형 건축물 등에서 발생하였는데, 그 중에서도 필로티 건축물의 피해가 다수 발생하였다. Kocaeli 지진의 경우, 약 18,000동의 건축물 손상 또는 붕괴가 발생하였다. 이 중 RC 골조 건축물은 일반적으로 저층 기둥 및 특정 층에 손상이 집중되는 연층 현상이 발생하는 지점에서 조기파괴(전단 및 겹침이음 파괴)가 발생하였다. 튀르키예 지진에서는 약 19,000동의 건축물 붕괴가 발생하였다. 이 중 RC 건축물은 내진설계가 적용되지 않았거나 과거의 기준을 사용하여 설계되어 내진 성능이 미흡하였으며, 일부는 보-벽 또는 보-기둥의 접합상태의 불량으로 인한 구조재의 분리가 발생하였다.

앞서 언급한 사례에서 나타난 비연성 RC 기둥이 갖는 지진에 취약한 특성을 보완하기 위한 보강 시스템에 대한 연구가 이전부터 오늘날까지 진행되고 있으며, 기둥 자켓팅 보강 시스템은 기존의 기둥에 추가적인 구속력을

\*Corresponding author: Shin, Jiuk

E-mail: jiukshin@gnu.ac.kr

(Received February 23, 2024; Revised March 30, 2024; Accepted April 1, 2024)

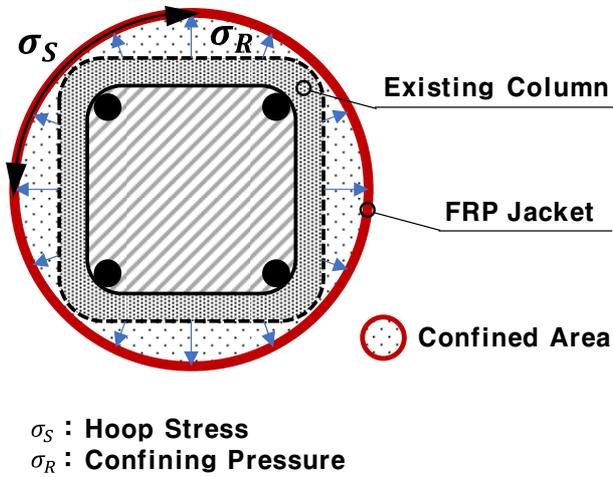


Fig. 1. Typical FRP column jacketing system

제공하여 연성 능력을 확보하기 위해 설치되고 있다. 본 연구에서는 보강시스템의 중 하나인 콘크리트와 강재 그리고 섬유보강폴리머(Fiber Reinforced Polymer, FRP) 기둥 자켓팅 시스템을 활용하였다.

FRP 기둥 자켓팅 시스템은 Fig. 1에 제시된 바와 같이 FRP 재료와 그라우팅 재료로 구성된다. FRP 재료는 기둥 외부에 설치하여 기존 콘크리트 기둥의 부피 팽창을 억제시킴에 따라 추가적인 구속력(Confining Pressure,  $\sigma_R$ )을 기둥에 부여하는 역할을 한다. FRP에 의한 추가 구속력은 콘크리트 구속 압축강도( $f_{cc}$ )와 극한 변형률( $\epsilon_{cu}$ )을 증가시켜 부재의 연성 능력을 확보할 수 있다. FRP 기둥 자켓팅 시스템에서 그라우팅 재료는 단면 형상을 기존 정사각형 또는 직사각형에서 원형 또는 타원형으로 전환하는 기능을 하는데 이는 FRP에 의해 발생하는 구속효과를 극대화하기 위한 것이다. 이러한 보강 시스템의 효과를 검증하기 위하여, FRP 자켓팅 시스템이 보강된 비내진 상세를 갖는 철근콘크리트 기둥을 대상으로 부재 단위의 정적 실험 연구가 진행되었다[8-11]. 이 중 Seible et al.[12-15]은 FRP 자켓팅 시스템이 보강된 비연성 기둥 부재에 대한 정적 실험을 기반으로 보강 효과를 검증하고, 이와 관련된 변위 연성도 기반의 설계 절차를 제안하였다. 해당 부재 단위의 실험 결과에 따르면 FRP 기둥 자켓팅 시스템이 보강된 철근콘크리트 기둥은 심각한 강성 및 강도저감 없이 연성 거동을 하는 것으로 나타났으며, 기둥 단부에 접침이음의 파기가 지연되는 것으로 조사되었다.

현재 국내 기존 건축물의 내진성능평가는 국토안전관리원의 “기존 시설물(건축물) 내진성능평가 요령”[16]을 따르고 있다. 해당 평가 기법은 총 4단계에 걸쳐서 기존 건축물의 내진성능을 평가하고 있다. 1단계는 현장조사, 2단계는 예비평가, 3단계는 1차 상세평가(선형해석) 그리고 4단계는 2차 상세평가(비선형해석)로 구성되어 있다. 여기서 3단계와 4단계는 컴퓨터 해석모델을 구축하고, 이를 통해 산정된 해석 결과를 바탕으로 기존 건축물의 내진성능을 결정한다. 기존 건축물이 목표 성능에 도달하지 못하는 경우, 내진 보강 시스템 등을 도입하여 4단계의 복잡한 내진성능평가 과정을 반복적으로 수행해야 하며, 이는 보강계획 수립 시 단계별로 모델링 및 해석 과정을 진행해야 하기에 막대한 인력과 시간이 소모된다는 단점이 있다.

기존의 내진성능평가 기법의 한계를 극복하기 위하여, 최근 인공지능망(Artificial Neural Network, ANN)과 같은 기계학습(Machine Learning,

ML)을 활용한 건축물 내진성능평가 기법이 개발 및 검증 과정이 이루어지고 있으며, 건설분야 외의 분야에도 다양하게 융합되어 개발 및 검증 과정이 이루어지고 있다. Lee[17]는 양생 기간에 따른 콘크리트 강도를 예측할 수 있는 ANN 기반 모델을 제안하였다. 이 ANN 모델은 실험적 결과와 간편성 때문에 실무에서 널리 사용되는 기존 방식과의 비교와 함께 더 나은 상관관계를 보여주었다. Inel[18]은 휨제어 RC 기둥의 극한 변형 능력을 평가 가능한 ANN 모델을 개발하기 위하여, 237개의 직사각형 기둥의 실험데이터를 학습한 이후 그 성능을 검증하였다. 이전 연구에서의 부재 수준에 비탄성-비선형 문제를 예측하는 ANN 접근방식의 잠재적 사용을 입증하였다. Stewart and Morrill[19]은 유한요소(Finite Element, FE) 해석 기반 시뮬레이션 모델을 이용하여 간단한 폭발하중 시나리오 아래 강재 기둥에 대한 ANN 기반 모델을 개발하였다. FE 시뮬레이션과 비교하였을 때, ANN 모델은 폭발하중 아래 강재 기둥의 신속하게 합리적인 응답을 생성할 수 있었다. Shin et al. (2020)[20]은 ANN 모델을 이용하여 지진에 취약한 RC 건축물 골조를 대상으로 신속하게 복합재난(지진 그리고 폭발)에 대한 성능 평가 및 완화 전략을 제시하였으며, 이 연구에서는 각각 기준이 다른 지진 및 폭발 하중에 대해 새로운 하이브리드 성능평가 기준을 제시하고, ANN 모델을 활용하여 훈련, 검증 그리고 평가된 초고속 데이터 생성 엔진(Fast Running Model, FRM)을 활용하여 검증하였다. 이 연구에서 활용한 FRM은 다량의 신뢰도 높은 응답 데이터베이스를 신속히 생성할 수 있었고, 이를 기반으로 비연성 RC 골조의 지진 및 폭발성능 보강에 대한 신속한 의사결정 접근방식을 개발하였다. Pham et al. (2021)[21]은 경사면의 안정성 상태를 정확히 추정하기 위하여, 앙상블 학습기 중 병렬학습과 순차학습을 적용하여 경사면 안정성 추정 분류 모델을 개발하였다. 해당 예측모델에 대한 성능을 평가하기 위하여, 8개의 다중 기계학습 알고리즘과 단일 학습 분류 모델을 이용하여 경사면 안정성 상태를 예측하였으며, 하이퍼파라미터 조정과 K-fold 교차검증을 통해 다른 학습 분류 모델보다 앙상블 학습을 활용한 모델의 성능이 우수함을 입증하였다.

본 연구의 목적은 FRP 자켓팅 시스템으로 보강한 지진에 취약한 RC 건축물의 내진성능을 반복적인 계산과정 없이 신속하게 평가할 수 있는 최적의 모델을 제시하는 것이다. 주요 목표를 달성하기 위하여, 본 연구에서는 ML 모델 중 ANN, 의사결정 나무(Decision Tree, DT) 그리고 랜덤포레스트(Random Forest, RF)를 이용한 건축물의 내진성능 등급 예측 모델을 구축하였다. 이후, 이전 실물 규모의 동적 시험을 기반으로 검증된 FE 모델을 활용하여 얻었던 데이터셋을 3개의 모델(ANN, DT 그리고 RF)에 적용한 후 도출되는 결과(예, R-square( $R^2$ ), 평균제곱오차(Mean Squared Error, MSE) 그리고 잔차(Residual))의 비교를 통해 건축물의 내진성능 및 구조적 취약성 평가를 위한 최적의 모델을 제시하였다. 본 연구에서 사용된 학습 데이터셋은 과거 실물 규모의 동적 실험[4, 22]을 기반으로 개발 및 검증된 유한요소해석 모델을 활용[23]하여 하중 조건 및 FRP 자켓팅 시스템의 구조 상세를 변수에 따라 구축되었다. 본 연구에서 이전 실물 규모의 동적 시험에 활용되었던 비연성 2층 RC 시험 골조는 기존 건축물 골조로 채택되었다. 이 건축물 골조는 비선형 유한요소해석 프로그램은 LS-DYNA를 이용하여 개발되었으며, FE 모델에 대한 시뮬레이션된 응답은 과거 실험 연구와 비교하여 검증하였다.

## 2. 유한요소해석 기반 데이터셋 구축

### 2.1 유한요소해석 모델 개발 및 검증

과거 연구[4, 22]에서 1970년대 이전에 건설된 기둥의 지진 취약성을 보완한 저층 RC 건축물 골조에 대한 실험 규모의 진동 실험을 수행하였다. Fig. 2에 제시된 것과 같이 비보강(as-built) 시험 골조는 1971년 이전 ACI(American Concrete Institute) 기준에 따라 설계되었으며, 보강 시험 골조는 FRP 자켓팅 시스템을 활용하여 기둥을 보강하였다. 이 시험 골조의 경우, 실제 동적 거동(예, 시간-변위 이력 응답과 층간변위비(Inter-story Drift Ratio, IDR), 부착파괴 효과), 비보강 및 보강 시험 골조 사이의 동적 거동 비교에 의한 FRP 기둥 자켓팅 시스템의 정량적 보강 효과 측정을 위해 일련의 실험 규모의 동적 시험이 수행되었으며, 해당 동적 실험 결과를 기반으로 2층, 2경간 비연성 RC 골조에 대한 모델을 개발하였다.

과거 연구에서는 LS-DYNA를 이용하여 시험 골조에 대한 FE 수치 해석 모델을 개발하였다. FE 모델은 계산시간을 줄이기 위해 대칭 조건에서 개발되었다. 실험체의 주요 구조부재인 기둥과 보의 콘크리트 재료 모델은 콘크리트의 경화(Hardening), 연화(Softening), 전단 팽창(Shear Dilation), 구속효과 등을 잘 묘사할 수 있는 KCC(Karagozian and Case Concrete) 모델[24]을 사용하였으며, 철근 재료는 비선형 거동을 묘사할 수 있는 Plastic Kinematic 모델을 활용하였다. 콘크리트는 255 mm의 메쉬 크기를 갖는 8개의 노드를 갖는 Solid 요소를 이용하여 생성되었고, 철근은 Beam 요소를 이용하여 개발되었다. 부착파괴 모델의 파라미터는 실험 규모의 동적 실험에서 측정된 데이터를 기반으로 결정되었으며, 철근과 콘크리트 사이의 부착파괴 효과는 LS-DYNA에서 1D 슬라이드 라인 모델을 이용하여 시뮬레이션되었다. 해당 모델은 동적 하중에 대한 실험결과와 비교를 통하여 검증하였으며, 실험에서 측정된 시간-변위 응답 대비 약

12%의 오차를 보였다. 더 상세한 정보는 Shin 등[25]의 논문을 참고할 수 있다.

### 2.2 입력력 데이터셋 구성

본 장은 ML 모델에 활용된 입력력 데이터셋의 구성을 설명하기 위한 것이다. 입력 매개변수의 선정이유 및 출력변수를 산정하는 과정의 상세한 설명은 다음 논문을 참고할 수 있다[26].

Table 1는 본 연구에서 설정한 입력변수의 유형, 학습범위, 그리고 각 변수별 최소, 최대 그리고 대푯값을 보여준다. 입력변수는 크게 하중과 보강 매개변수로 구성하였으며, 보강변수를 FRP 자켓 시스템의 구성과 보강효과를 고려하여 FRP 재료 강도( $f_{ju}$ ), FRP 자켓 두께( $t_j$ ), 그라우팅에 의한 단면 확장 크기(ID), 그라우팅 재료 강도( $f_g$ ), 그리고 보강위치(S)로 설정하였다. 여기서 과거 연구에 따르면[26],  $f_{ju}$ 와  $t_j$  변수는 FRP 기둥 단면 확장에 따른 기둥의 보강위치는 과거 실험과 동일하게 강성 증가에 상당히 효과적인 것으로 나타났다. 1층에만 보강한 경우와 전체 층에 보강한 경우를 고려하여 보강 위치에 따른 성능 변화를 반영할 수 있다. 지진하중은 최대 스펙트럼 가속도( $S_{a,peak}$ )를 특징으로 하며, FEMA-356[27]은 설계 단주기 응답 가속도( $S_{DS}$ )가 0.5 g보다 높은 지역을 지진 활동도가 높은 지역으로 정의한다. 이를 바탕으로, 본 연구에서는 0.5 g의 최대 스펙트럼 가속도를 지진하중에 대한 최소 훈련 지점( $S_{a,min} = 0.5 \text{ g}$ )으로 사용하였다. 또한, FEMA-P695[28]에 명시된 내진설계범주(Seismic Design Category, SDC) D의 최대고려지진(Maximum Considered Earthquake, MCE) 단주기 응답 가속도( $S_{MS}$ )를 최대 스펙트럼 가속도( $S_{a,peak} = 1.5 \text{ g}$ )의 대푯값으로 설정하였다. 본 연구에서는 붕괴강도에 대한 대표 스펙트럼 가속도를 2배로 하였다( $S_{a,peak} = 2 \times 1.5 \text{ g} = 3.0 \text{ g}$ ).

Table 1에 제시된 최소, 최대 그리고 대푯값은 기존 연구문헌[19]을 통



Fig. 2. Full-scale, two-story two-bay non-ductile RC test frames: (a) Four identical full-scale test frames; (b) FRP jacketed column in retrofitted test frame; (c) Hydraulic linear shaker used in the dynamic testing program

**Table 1.** Summary of input parameters, ranges and training points used in FRM

Parameter Type	Parameter	Model Range	Nominal	Extreme Value	
				Minimum	Maximum
Loading	Peak Spectral Acceleration	0.5 ~ 3.0 g	1.5 g	0.5 g	3.0 g
Geometric and Material	Retrofit Location	No-Retrofit* to all-story Retrofit	First-story Retrofit	No-Retrofit*	All-story Retrofit
	Ultimate FRP Jacket Strength	166 ~ 1380 MPa	419 MPa	166 MPa	1380 MPa
	FRP Jacket Thickness	0 ~ 6.5 mm	3.6 mm	0.0 mm	6.5 mm
	Column Inner Diameter	444 ~ 559 mm	444 mm	No-Retrofit*	559 mm
	Grout Compressive Strength**	13.6 ~ 86.2 MPa	42.9 MPa	13.8 MPa	86.2 MPa

No-retrofit\* = as-built condition

Grout Compressive Strength\*\* = 1-Day to 28-Day Curing Compressive Strength

**Table 2.** Number of sample cases in seismic dataset

Loading Type	Initial Dataset			Number of Sample Cases
	As-built Frame	Retrofitted Frame		
		First-story Retrofit	All-story Retrofit	
Seismic Loading	3	34	34	71
Total number of sample cases				71

하여 선정되었다. Table 2에 제시한 것과 같이, 각 변수별로 3개의 훈련 포인트를 임의로 조합하여 총 71개의 입력정보를 생성하였으며, 이를 2장에서 언급한 FE 모델에 입력하였다. 각 입력정보에 대한 정보는 다음 논문 [26]에 자세히 제시되어 있다. 해당 모델은 Pushover 해석 기반의 CSM (Capacity Spectrum Method)을 활용하여 각 해석모델에 대한 내진성능을 평가하였다. CSM 방법론은 설계 지진 스펙트럼을  $S_d$  (스펙트럼 가속도) -  $S_u$  (스펙트럼 변위) 관계로 변환한 지진 요구(Seismic Demand) 곡선과 Pushover 해석 기반으로 변환된 성능곡선(Capacity Curve)과의 교차점을 목표 변위로 산정하는 방식[26]이다. 71개의 입력 데이터셋이 적용된 FE 모델에 대하여 CSM 방법론을 활용하여 발생된 변위비를 계산하였으며, 해당 변위비를 기반으로 71개의 FE 모델에 대한 내진성능등급을 예측하였다. 여기서, 내진성능등급은 FEMA 356[29]에서 정의한 내진성능

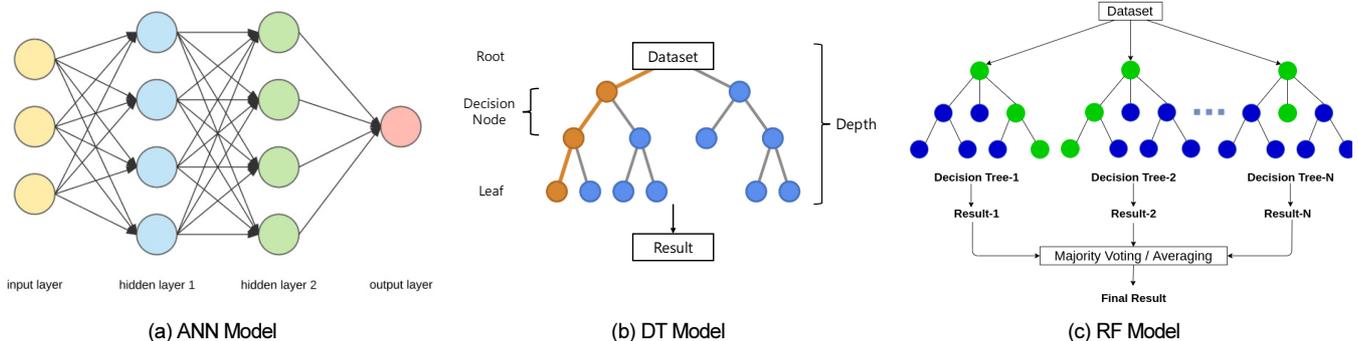
급을 활용하였다. 이와 같은 과정으로 구축된 입출력 데이터셋을 통해 학습된 ML 모델은 지진하중 시나리오 및 보강변수에 따른 건축물의 내진성능 등급을 예측할 수 있다.

### 3. 머신러닝 기반 데이터 생성 기술 개발

#### 3.1 학습모델 개요

본 연구에서는 FRP 자켓팅 시스템으로 보강한 지진 취약 RC 건축물의 내진성능을 반복적인 계산과정 없이 신속하게 평가할 수 있는 최적의 모델을 제시하기 위하여, 여러 ML 모델 중 ANN, RF 그리고 DT를 이용한 내진성능 등급 예측 모델을 구축하였으며, 아래 제시된 Fig. 3은 모델별 기본 구조를 나타내고 있다.

ANN 모델은 사람의 뇌가 학습하는 과정을 수학적 및 확률적 방법론으로 묘사하는 ML 방법론으로, 해당 모델은 입력층(Input Layer), 은닉층(Hidden Layer) 그리고 출력층(Output Layer)로 구성되어 있으며, 각 레이어는 여러 개의 노드(Node)로 구성되어 있고, 각 노드는 다른 1개 이상의 노드와 결합되어 있다. 노드와 노드 사이는 복잡하게 연결되어 있으며, 가중치(Weight Value)와 편향값(Bias Value)의 정보를 전달한다. 활성화 함수(Activation Function)는 가중치의 합을 출력신호로 변환하여 관련 정보를 다음 레이어로 전달하는 역할을 수행한다. ANN 모델은 최적의 훈련



**Fig. 3.** Basic configuration by models

**Table 3.** Summary of MSE,  $R^2$ , and average residual by models

Model		MSE	$R_2$	Average Residual
ANN	Training	0.01	0.99	0.01
	Testing	0.01	0.98	0.01
DT	Training	0.01	0.97	-0.01
	Testing	0.01	0.97	-0.01
RF	Training	0.01	1.00	0
	Testing	0.01	0.98	0.01

모델을 구현하기 위하여 하이퍼파라미터를 설정한다. ANN의 하이퍼파라미터에는 은닉층 크기, Layer 크기, 반복횟수 등이 있다.

DT 모델은 나무 형상의 모델로 구현한 인공지능 알고리즘으로, 데이터를 분석하여 데이터 사이에 존재하는 패턴을 학습하고, 이를 조합하여 결과를 추정하는 방법이다. 상위 노드부터 하위 노드로 트리구조를 형성하여 각 단계별 분류 변수와 분류 기준값을 선택하는 방식으로 학습을 수행한다. 대표적인 하이퍼파라미터로 가지의 깊이(Depth)를 고려할 수 있으나, 가지의 깊이가 깊어질수록 훈련 데이터셋에 과적합(Overfitting) 가능성이 높다는 특징을 갖는다. 해당 모델의 하이퍼파라미터에는 노드 개수, 최대 트리 깊이, 리프 노드 관측값의 최소 개수 등이 있다.

RF 모델은 Ensemble 학습 방법 중 하나로, Ensemble 학습 방법은 단일 ML 모델로 학습하는 방식이 아닌 여러 개의 학습모델을 활용하여 데이터를 학습하는 방법을 의미하며, Voting, Bagging, Boosting 그리고 Staking 방식이 대표적이다. 이 중 RF 방법론은 Bagging 방식에 포함되며, DT에 대한 Ensemble 모델로 서로 다른 특성을 갖는 여러 개의 결정트리를 조합하여 결과를 산출하는 집단형 모델이기 때문에 높은 정확도를 갖으며, DT 방식에서 발견될 수 있는 과적합 이슈에 대한 솔루션으로 활용할 수 있다. RF 모델의 하이퍼파라미터에는 트리수, 노드 개수, 최대 트리 깊이, 훈련수, 학습률 등이 있다.

### 3.2 학습모델 최적화 및 검증

본 연구에서는 ML 모델을 활용하여 FRP 자켓팅 시스템으로 보강한 지진에 취약한 RC 건축물의 내진성능을 신속하게 평가할 수 있는 최적의 모델의 최적화 및 검증을 위하여, FE 모델을 기반으로 구축된 데이터셋을 ANN, DT 그리고 RF 기법을 활용한 내진성능 등급 예측모델을 구축하였으며, 각 모델별 MSE,  $R^2$  그리고 Residual 결과를 비교하여 Best-fit 모델을 선택하였다.

ANN 기반 건축물의 내진성능 등급 예측 모델의 경우, 지진 FRM에 대한 6개의 입력 매개변수와 1개의 출력 매개변수로 신경망이 구축되었으며, 신경망은 5개의 히든 레이어로 구성되었다. 이는 다수의 히든 레이어가 다수의 입력 및 출력 매개변수 사이에서 권고되었기 때문에 선정되었다[26]. 추가적으로 로그 형태의 전달 함수는 정규화된 수요일 0~1까지로 제한하기 위하여 히든 레이어와 출력 레이어로 구현되었으며, 이 전달 함수는 신경망 모델로부터 음수값 계산을 예방할 수 있다. 해당 모델에 적용된 비보강 데이터 3개를 제외한 68개의 보강 데이터는 모델 훈련, 검증, 시험을 위하여 무작위로 선택되었으며, Feed forward 신경망 중 하나로 반복 과정에서

**Table 4.** Hyperparameters for each ML model

Model	Parameter	Value
ANN	LayerSizes	10
	Activations	relu
	Iteration	33
DT	NumNodes	13
	Maximum depth of the tree	4
	MinLeafSize	5
RF	NumSeedPoints	4
	NumNodes	17
	Maximum depth of the tree	5
	NumTrained	421
	LearnRate	0.426

계산된 수요(FRM 기반)와 목표 수요(FE 기반) 사이의 MSE를 최소화하기 위한 최적의 가중치( $w$ )와 편향( $\bar{b}$ ) 매개변수를 제공하는 Levenber-Marquardt Algorithm(LMA)은 본 연구에서 훈련 알고리즘으로만 이용되었다. 학습모델 최적화 과정에서 지진 FRM에 대한 MSE값은 27번째 반복 과정에서 최소화되었다.

DT 기반 건축물의 내진성능 등급 예측 모델의 경우, 지진 FRM에 대한 6개의 입력 매개변수와 1개의 출력 매개변수를 기반으로 하는 트리가 구축되었다. 이 트리는 13개의 노드를 가지의 깊이(Depth)가 4이며, 12개의 가지를 갖는 구조로 구성되었다. 모델의 최적화를 위하여, 해당 모델에 적용된 데이터셋 중 비보강데이터 3개를 제외한 68개의 보강데이터를 무작위로 선택하였으며, 하이퍼파라미터 최적화는 5번 노드에서 최적화되었다.

RF 기반 건축물의 내진성능 이용한 등급 예측 모델의 경우, 6개의 입력 매개변수와 1개의 출력 매개변수로 4개의 트리가 구축되었다. 이 트리는 각각 17개의 노드를 가지의 깊이(Depth)가 5이며, 16개의 가지를 갖는 구조로 구성되었다. 학습 모델의 최적화를 위하여, 해당 모델에 적용된 데이터셋 중 비보강데이터 3개를 제외한 68개의 보강데이터를 무작위로 선택하였으며, 하이퍼파라미터 최적화는 Ensemble 학습방법 중 Boosting 방식을 통해 진행되었다. Table 4는 본 연구에서 활용한 ANN, DT 그리고 RF 모델에 대한 하이퍼파라미터의 구성을 보여주고 있다.

MSE는 예측값에 대한 정확성을 측정하는 방법으로, 실제값과 예측값의 차이를 제공하여 평균화한 값을 사용한다. MSE는 0~1까지의 범위 내에서 그 값이 결정되며, 0에 수렴할수록 예측값이 실제값과 가깝기 때문에 정확도가 높다고 할 수 있다. MSE는 식 (1)을 통해 산정된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \tag{1}$$

여기서,  $Y_i$ 는 실제값 그리고  $\hat{Y}_i$ 은 예측값을 의미한다.

$R^2$ 은 실제 결과 대비 예측모델의 예측도를 의미하는 값으로, 0~1까지의 범위 내에서 그 값이 결정되며, 1에 수렴할수록 실제값과 가깝기 때문에 정확도가 높다고 할 수 있다.  $R^2$ 은 제시된 식 (2)을 통해 산정된다.

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \tag{2}$$

여기서, SST(Sum of Squares Total)는 전체변동, SSR(Sum of Squares due to Regression)은 회귀변동, 그리고 SSE(Sum of Squares Error)는 오차변동을 의미하며, 식 (2)에 활용되는 SSR, SSE 그리고 SST는 각각 식 (3)~(5)을 통해 산정된다.

$$SSR = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \tag{3}$$

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{4}$$

$$SST = SSR + SSE \tag{5}$$

여기서,  $y_i$ 는  $i$ 번째 종속변수(실제값),  $\bar{y}_i$ 는  $y_i$ 의 평균 그리고  $\hat{y}_i$ 는  $y_i$ 의 선형회귀값(예측값)을 의미한다.

Residual은 실제 출력변수와 예측한 출력변수의 오차를 의미하는 값으로, 0에 수렴할수록 실제값과 가깝기 때문에 오차가 작다고 할 수 있다. Residual( $e_i$ )은 제시된 식 (6)을 통해 산정된다.

$$e_i = y_i - \hat{y}_i \tag{6}$$

ANN, DT, 그리고 RF 기반 건축물의 내진성능 등급 예측모델과 FE 모델을 기반으로 구축된 68개의 데이터셋트를 활용하여 간단한 회귀분석을 수행하였다. 여기서, 학습모델 검증에 사용된 훈련 데이터셋트와 테스트 데이터셋트는 무작위로 선정되었으며, 각각 7:3의 비율(훈련 데이터셋트 48개 그리고 테스트 데이터셋트 20개)로 나누어 활용되었다. 세 개의 모델에 대한 MSE,  $R^2$  그리고 평균 Residual 결과를 Table 3에 요약하였다. 훈련 데이터셋트를 기반으로 구축된 회귀모델의 기울기는 각각 0.956, 0.974 그리고 1.000로, 절편은 각각 0.014, 0.009 그리고 0로 산정되었으며, 테스트 데이터셋트를 기반으로 구축된 회귀모델의 기울기는 각각 0.961, 0.966 그리고 0.997로, 절편은 각각 0.010, 0.009 그리고 -0.002로 산정되었다. 세 개의 모델에 대한 MSE,  $R^2$  그리고 평균 Residual 결과는 다음과 같다.

예측값에 대한 정확도를 의미하는 MSE 결과는 세 개의 모델이 모두 0.01로 산정되었으며, 이는 세 개의 모델 모두 정확도가 높고, 정확도 측면에서 각 모델 사이의 차이가 없음을 의미한다. 실제 결과 대비 예측모델의 예측도를 의미하는  $R^2$  결과는 다음과 같다. 훈련 데이터셋트를 기반으로 산정된  $R^2$  결과는 세 개의 모델이 각각 0.98, 1.00 그리고 0.97로 산정되었으며, 테스트 데이터셋트를 기반으로 산정된  $R^2$  결과는 세 개의 모델이 각각 0.98, 0.97 그리고 0.98로 산정되었다. 이는 세 개의 모델 모두 실제 결과 대비 예측모델의 예측도가 높은 것으로 나타났으며, 이중 테스트 데이터셋트를 기반으로 산정된  $R^2$  결과가 0.98로 가장 높았던 ANN 그리고 RF 기반 예측모델의 예측도가 가장 높다고 판단되었다.

예측한 결과와 실제 결과와의 오차를 의미하는 평균 Residual 결과는 다음과 같다. 훈련 데이터셋트를 기반으로 산정된 평균 Residual 결과는 세 개의 모델이 각각 0.01, -0.01 그리고 0으로 산정되었으며, 테스트 데이터셋트를 기반으로 산정된 평균 Residual 결과는 세 개의 모델이 각각 0.01, -0.01 그리고 0.01로 산정되었다. 이는 실제 결과와 예측모델의 결과 사이의 차이가 크지 않음을 의미한다. 각 모델별 MSE,  $R^2$  그리고 평균 Residual 결과의 비교를 바탕으로, 세 개의 예측모델 모두 전반적으로 예측 성능이 우수한 것으로 평가되었다. Fig. 4는 FE 모델을 기반으로 구축된 68개의 데이

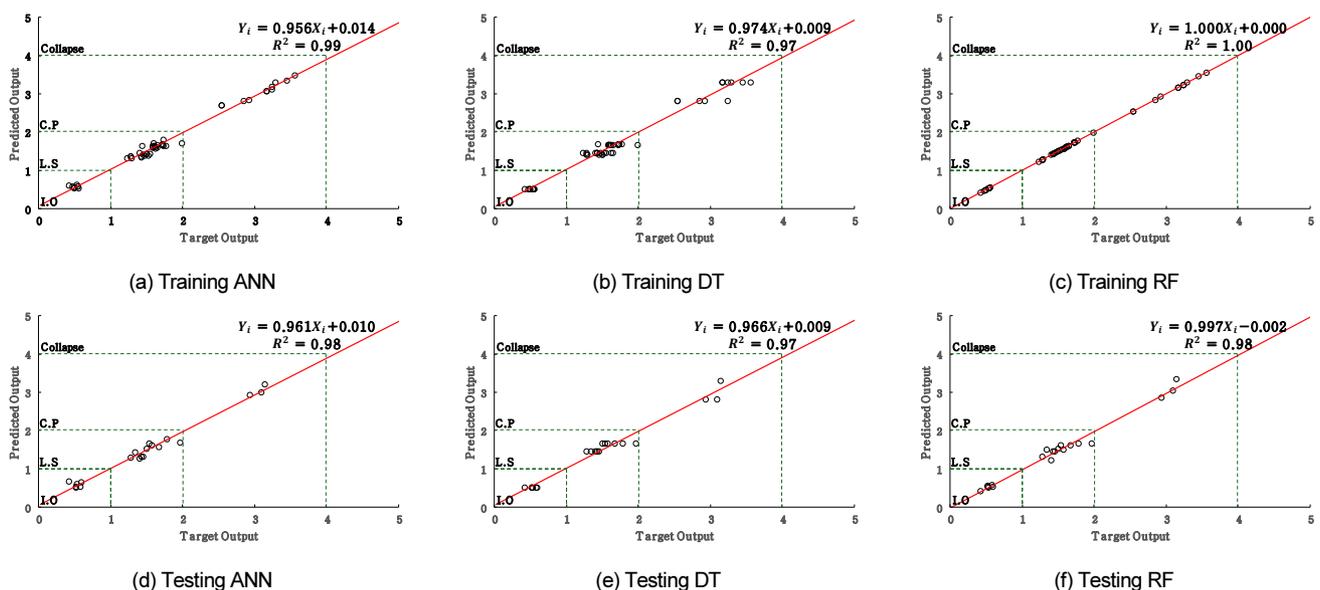


Fig. 4. Regression analyses between FE- and FRM-based demands by models

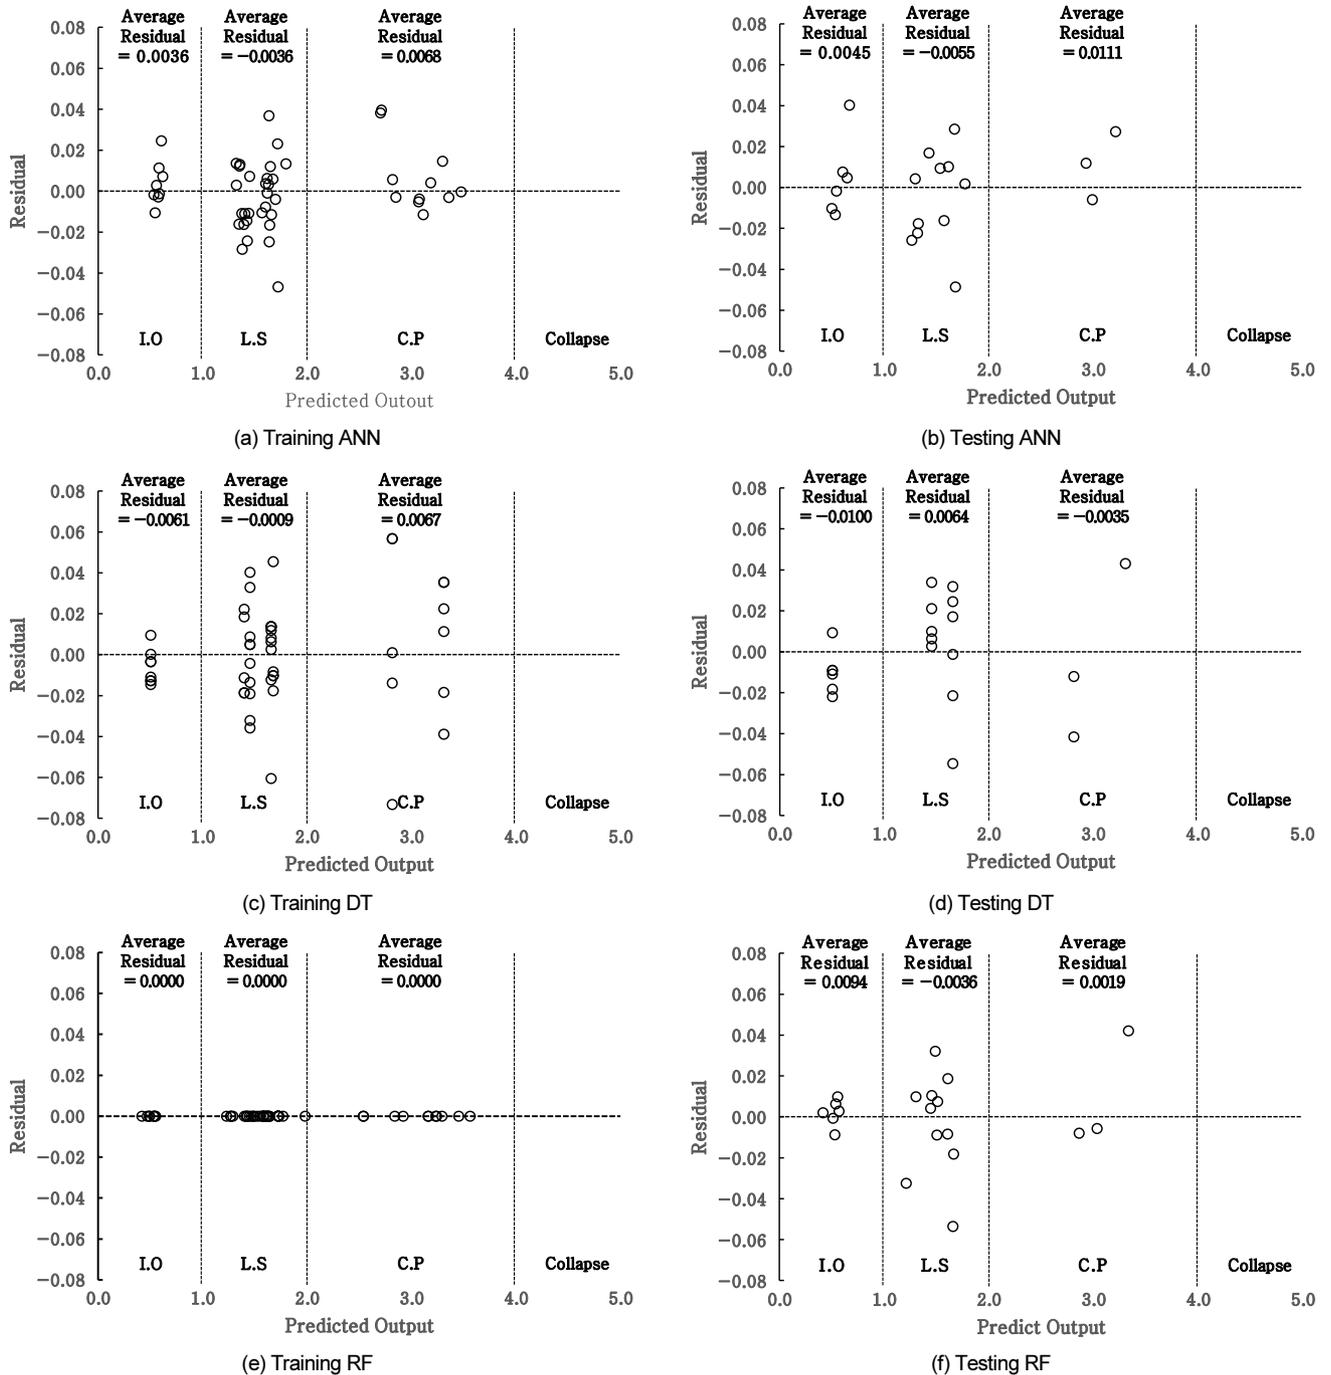


Fig. 5. Diagnostic residual plots for FRM models

터세트와 ANN, DT 그리고 RF 기반 건축물의 내진성능 등급 예측 모델을 활용하여 수행한 회귀분석 결과를 보여주고 있다.

ANN, DT 그리고 RF를 이용한 건축물의 내진성능 등급 예측모델의 등급별 예측 성능을 평가하기 위하여, 실제 변위비와 세 개의 예측모델 기반 예측 변위비를 등급별로 분류하고, 이를 기반으로 등급별 평균 Residual을 산정하였으며, 각 모델별 평균 Residual 결과를 비교하였다. 건축물의 내진성능 등급은 FEMA 356[29]에서 정의한 내진성능 등급을 활용하였으며, Table 5는 FEMA 356에서 정의한 내진등급에 대한 성능한계를 보여준다. 이를 기반으로, FE 모델 기반 데이터세트의 케이스별 실제 변위비와 ANN,

Table 5. Definition of seismic performance levels in FEMA 356[29]

	Seismic Performance level	Drift Limit
1	Immediate Occupancy (IO)	$\leq 1.0\%$
2	Life Safety (LS)	$\leq 2.0\%$
3	Collapse Prevention (CP)	$\leq 4.0\%$
4	Collapse	$> 4.0\%$

DT 그리고 RF 기반 예측모델을 활용하여 예측한 변위비의 내진성능 등급을 분류하였고, Table 6에 본 연구에서 활용된 케이스별 실제 변위비와 등

**Table 6.** Summary of FE model-based drift ratio and class of seismic performance and prediction model-based drift ratio, class of seismic performance and residual

Case #	Actual Drift Ratio		Predicted Drift Ratio								
			ANN			DT			RF		
	Output	Class	Output	Class	Residual	Output	Class	Residual	Output	Class	Residual
4	1.64	LS	1.67	LS	0.006	1.66	LS	0.003	1.64	LS	0.000
5	3.29	CP	3.29	CP	0.015	3.31	CP	0.011	3.29	CP	0.000
6	0.55	IO	0.54	IO	-0.011	0.50	IO	-0.015	0.55	IO	0.000
7	1.72	LS	1.70	LS	-0.004	1.68	LS	-0.008	1.72	LS	0.000
8	1.58	LS	1.65	LS	0.012	1.66	LS	0.014	1.58	LS	0.000
9	1.58	LS	1.62	LS	0.006	1.66	LS	0.014	1.58	LS	0.000
10	1.57	LS	1.61	LS	0.010	1.66	LS	0.017	1.51	LS	0.000
11	1.62	LS	1.62	LS	-0.001	1.66	LS	0.006	1.62	LS	0.000
12	1.78	LS	1.77	LS	0.002	1.66	LS	-0.021	1.67	LS	0.000
13	3.45	CP	3.35	CP	-0.003	3.31	CP	-0.018	3.45	CP	0.000
14	3.16	CP	3.06	CP	-0.005	3.31	CP	0.035	3.16	CP	0.000
15	0.57	IO	0.53	IO	-0.013	0.50	IO	-0.018	0.57	IO	0.003
16	0.53	IO	0.62	IO	0.007	0.50	IO	-0.011	0.53	IO	0.000
17	3.16	CP	3.07	CP	-0.004	3.31	CP	0.035	3.16	CP	0.000
18	0.53	IO	0.60	IO	0.008	0.50	IO	-0.011	0.51	IO	0.000
19	3.14	CP	3.21	CP	0.027	3.31	CP	0.043	3.34	CP	0.042
20	0.52	IO	0.54	IO	-0.002	0.50	IO	-0.009	0.54	IO	0.006
21	3.23	CP	3.18	CP	0.004	3.31	CP	0.022	3.23	CP	0.000
22	3.56	CP	3.47	CP	0.000	3.31	CP	-0.039	3.56	CP	0.000
23	0.54	IO	0.58	IO	-0.001	0.50	IO	-0.013	0.54	IO	0.000
24	0.59	IO	0.64	IO	0.005	0.50	IO	-0.022	0.53	IO	0.000
25	1.77	LS	1.63	LS	-0.025	1.68	LS	-0.018	1.77	LS	0.000
26	1.72	LS	1.66	LS	-0.012	1.66	LS	-0.012	1.72	LS	0.000
27	1.73	LS	1.64	LS	-0.017	1.68	LS	-0.010	1.73	LS	0.000
28	1.58	LS	1.60	LS	0.004	1.66	LS	0.014	1.58	LS	0.000
29	1.43	LS	1.63	LS	0.037	1.68	LS	0.045	1.43	LS	0.000
30	1.73	LS	1.80	LS	0.013	1.68	LS	-0.010	1.73	LS	0.000
31	1.98	LS	1.72	LS	-0.047	1.66	LS	-0.061	1.98	LS	0.000
32	1.96	LS	1.68	LS	-0.049	1.66	LS	-0.055	1.66	LS	0.000
33	1.49	LS	1.53	LS	0.009	1.66	LS	0.032	1.51	LS	0.007
34	1.61	LS	1.63	LS	0.003	1.66	LS	0.008	1.61	LS	0.000
35	1.53	LS	1.67	LS	0.028	1.66	LS	0.025	1.61	LS	0.019
36	1.67	LS	1.57	LS	-0.016	1.66	LS	-0.001	1.61	LS	0.000
37	1.59	LS	1.71	LS	0.023	1.66	LS	0.012	1.59	LS	0.000
38	1.47	LS	1.39	LS	-0.016	1.45	LS	-0.004	1.47	LS	0.000
39	2.93	CP	2.93	CP	0.012	2.82	CP	-0.012	2.87	CP	0.000
40	0.49	IO	0.53	IO	-0.002	0.50	IO	-0.004	0.49	IO	0.000
41	1.55	LS	1.43	LS	-0.024	1.45	LS	-0.019	1.55	LS	0.000
42	1.27	LS	1.35	LS	0.012	1.40	LS	0.022	1.27	LS	0.000
43	1.27	LS	1.29	LS	0.004	1.45	LS	0.034	1.31	LS	0.010
44	1.27	LS	1.36	LS	0.013	1.45	LS	0.033	1.27	LS	0.000
45	1.42	LS	1.32	LS	-0.018	1.45	LS	0.006	1.46	LS	0.010
46	1.62	LS	1.57	LS	-0.011	1.45	LS	-0.032	1.62	LS	0.000
47	3.09	CP	2.99	CP	-0.006	2.82	CP	-0.041	3.04	CP	0.000
48	2.54	CP	2.70	CP	0.038	2.82	CP	0.057	2.54	CP	0.000
49	0.52	IO	0.50	IO	-0.010	0.50	IO	-0.009	0.56	IO	0.010
50	0.42	IO	0.67	IO	0.040	0.50	IO	0.009	0.42	IO	0.002
51	2.54	CP	2.71	CP	0.040	2.82	CP	0.057	2.54	CP	0.000
52	0.42	IO	0.60	IO	0.025	0.50	IO	0.009	0.42	IO	0.000
53	2.92	CP	2.85	CP	-0.003	2.82	CP	-0.014	2.92	CP	0.000
54	0.49	IO	0.56	IO	0.003	0.50	IO	-0.004	0.49	IO	0.000
55	2.84	CP	2.82	CP	0.006	2.82	CP	0.001	2.84	CP	0.000
56	3.24	CP	3.11	CP	-0.012	2.82	CP	-0.073	3.24	CP	0.000
57	0.47	IO	0.58	IO	0.011	0.50	IO	0.000	0.47	IO	0.000
58	0.54	IO	0.57	IO	-0.003	0.50	IO	-0.013	0.54	IO	0.000
59	1.44	LS	1.32	LS	-0.022	1.45	LS	0.003	1.45	LS	0.004
60	1.29	LS	1.32	LS	0.003	1.40	LS	0.018	1.29	LS	0.000
61	1.52	LS	1.38	LS	-0.028	1.45	LS	-0.014	1.52	LS	0.000
62	1.45	LS	1.40	LS	-0.011	1.40	LS	-0.011	1.45	LS	0.000
63	1.23	LS	1.32	LS	0.014	1.45	LS	0.040	1.23	LS	0.000
64	1.64	LS	1.60	LS	-0.008	1.45	LS	-0.036	1.64	LS	0.000
65	1.49	LS	1.42	LS	-0.015	1.40	LS	-0.019	1.49	LS	0.000
66	1.49	LS	1.44	LS	-0.011	1.40	LS	-0.019	1.49	LS	0.000
67	1.40	LS	1.26	LS	-0.026	1.45	LS	0.010	1.21	LS	0.000
68	1.42	LS	1.35	LS	-0.016	1.45	LS	0.005	1.42	LS	0.000

**Table 7.** Summary of average residual by seismic performance levels of models

Model		Average Residual by Seismic Performance Levels		
		IO	LS	CP
ANN	Training	0.004	-0.004	0.007
	Testing	0.005	-0.006	0.011
DT	Training	-0.006	-0.001	0.007
	Testing	-0.010	0.006	-0.004
RF	Training	0	0	0
	Testing	0.009	-0.004	0.002

급, 각 모델을 이용하여 예측한 변위비와 등급 그리고 Residual을 요약하였다. FE 모델을 기반으로 구축된 데이터셋의 경우 각 등급(IO, LS, CP 그리고 Collapse)별로 각각 14개, 40개, 14개 그리고 0개가 분류되었으며, ANN, DT 그리고 RF 기반 예측모델을 활용하여 예측한 변위비의 내진성능 등급을 분류한 결과 또한 각 등급별로 각각 14개, 40개, 14개 그리고 0개가 분류되었다.

세 개의 예측모델에 대한 등급별 평균 Residual 결과는 다음과 같다. ANN 모델의 경우, 훈련 데이터셋을 기반으로 예측한 등급별(IO, LS 그리고 CP) 변위비와 실제 변위비 사이의 평균 Residual은 각각 0.004, -0.004 그리고 0.007로 산정되었으며, 테스트 데이터셋을 기반 예측한 등급별 변위비와 실제 변위비 사이의 평균 Residual은 각각 0.005, -0.006 그리고 0.011로 산정되었다. DT 모델의 경우, 훈련 데이터셋을 기반으로 예측한 등급별 변위비와 실제 변위비 사이의 평균 Residual은 각각 -0.006, -0.001 그리고 0.007로 산정되었으며, 테스트 데이터셋을 기반으로 예측한 등급별 변위비와 실제 변위비 사이의 평균 Residual은 각각 -0.010, 0.006 그리고 -0.004로 산정되었다. RF 모델의 경우, 훈련 데이터셋을 기반으로 예측한 등급별 변위비와 실제 변위비 사이의 평균 Residual은 모두 0으로 산정되었으며, 테스트 데이터셋을 기반으로 예측한 등급별 변위비와 실제 변위비 사이의 평균 Residual은 각각 0.009, -0.004 그리고 0.002로 산정되었다. Fig. 5는 ANN, DT 그리고 RF 모델을 활용하여 예측한 변위비와 실제 변위비 사이의 Residual을 보여주고 있다. Fig. 5(e)에서 Training RF의 경우 다른 모델에 비해 Residual 결과가 상당히 작았으나 (Training RF의 Residual 결과 = 0), Fig. 5(f)에서 Testing RF는 그다지 낮지 않은 것을 확인하였다. RF 모델의 경우 앙상블(Ensemble) 기법을 활용함으로써 다른 모델에 비해 실제값과의 오차가 작은 것으로 나타났다. 또한, 모델의 학습모델 검증 과정에서 활용된 테스트 데이터셋은 학습 과정에 관여하지 않기 때문에, 학습과정을 거쳐 최적화된 모델과 테스트 데이터셋 사이의 차이가 발생할 수 있다. 이러한 이유로 인해 Training RF와 Testing RF 사이의 차이가 발생하였다고 판단된다. Table 7은 실제 변위비, ANN, DT 그리고 RF 기반 예측모델을 활용하여 예측한 변위비 그리고 평균 Residual을 보여주고 있다.

ANN, DT 그리고 RF를 이용하여 구축한 건축물의 내진성능 등급 예측 모델의 등급별(IO, LS 그리고 CP) 예측 성능을 평가하기 위하여, 각 모델 별 테스트 데이터셋을 기반으로 산정된 등급별 평균 Residual 결과를 비교하였다. IO 등급의 경우, 세 개의 예측모델의 평균 Residual 결과는 각각 0.005, -0.010 그리고 0.009로 산정되었다. 세 개의 예측모델의 평균

Residual 결과를 비교하였을 때, ANN 기반 예측모델의 평균 Residual 결과가 가장 낮았으므로, ANN 기반 예측모델이 IO 등급을 예측하는데 가장 적합할 것으로 평가되었다. LS 등급의 경우, 세 개의 예측모델의 평균 Residual 결과는 각각 -0.006, 0.006 그리고 -0.004로 산정되었다. 세 개의 예측모델의 평균 Residual 결과를 비교하였을 때, RF 기반 예측모델의 평균 Residual 결과가 가장 낮았으므로, RF 기반 예측모델이 LS 등급을 예측하는데 가장 적합할 것으로 평가되었다. CP 등급의 경우, 세 개의 예측모델의 평균 Residual 결과는 각각 0.011, -0.004 그리고 0.002로 산정되었다. 세 개의 예측모델의 평균 Residual 결과를 비교하였을 때, RF 기반 예측 모델의 평균 Residual 결과가 가장 낮았으므로, RF 기반 예측모델이 CP 등급을 예측하는데 가장 적합할 것으로 평가되었다.

## 4. 결론

본 연구는 FRP 재킷 시스템을 보강한 지진에 취약한 RC 건축물을 대상으로 반복 계산과정 없이 내진성능을 신속하게 평가할 수 있는 기계학습 모델을 개발하였다. 해당 기계학습 모델은 과거 연구를 통하여 구축된 유한요소 해석 기반의 데이터셋을 활용하여 개발되었으며, 실제값과 예측값 사이의 회귀분석을 통하여 예측 모델의 성능을 평가하였다. 본 연구에서 도출된 결론은 아래와 같다.

- 1) 기존 내진성능평가 방법은 단계별 모델링 및 해석 과정으로 인해 막대한 인력과 시간이 소모된다. 이를 극복하기 위하여, ML 모델 중 ANN, DT 그리고 RF를 이용하여 RC 건축물의 내진성능 등급 예측모델을 구축하였다. 본 연구에서 구축한 예측모델은 지진하중, 보강위치, FRP 재킷 강도 및 두께, 기둥의 내경 그리고 그라우트 강도의 입력데이터를 통해 신속하게 높은 신뢰도(정확도)의 내진성능 평가가 가능한 것으로 나타났다.
- 2) 과거 연구로부터 구축된 FE 모델 기반 데이터셋과 ANN, DT 그리고 RF 기반 RC 건축물의 내진성능 등급 예측모델을 활용하여 회귀분석을 수행하였으며, 모델별 MSE,  $R^2$  그리고 평균 Residual 결과를 바탕으로 세 개의 예측모델에 대한 정확도와 예측 성능을 평가하였다. 세 개의 예측모델 모두 MSE 결과가 0.01로 산정되었으며,  $R^2$  결과는 0.97~1.00로 산정되었고, 평균 Residual 결과는 -0.01 ~0.01로 산정되어 전체적으로 실제 결과 대비 예측모델의 성능이 높은 것으로 확인되었다.
- 3) ANN, DT 그리고 RF 기반 RC 건축물의 내진성능 등급 예측모델의 등급별 예측 성능을 평가하기 위하여, 세 개의 예측모델의 등급별 평균 Residual 결과를 비교하였다. IO 등급의 경우, ANN 기반 예측모델의 평균 Residual 결과가 가장 낮았으며(0.005), 해당 모델이 IO 등급을 가장 정확하게 예측하는 모델로 평가하였다. LS 등급의 경우, RF 기반 예측모델의 평균 Residual 결과가 가장 낮았으며(-0.004), 해당 모델이 LS 등급을 가장 정확하게 예측하는 모델로 평가하였다. CP 등급의 경우, RF 기반 예측모델의 평균 Residual 결과가 가장 낮았으며(0.002), 해당 모델이 CP 등급을 가장 정확하게 예측하는 모델로 평가하였다.
- 4) 본 연구에서 구축된 등급별 Best-fit 모델을 기본 예측모델로 활용하여 모든 내진성능 등급을 정확하게 예측할 수 있는 통합 예측모델 개발을

위한 기반 연구가 수행되었으며, 이를 바탕으로 추후 모든 내진성능 등급을 정확하게 예측할 수 있는 Meta-Learner 모델의 개발 및 검증 과정을 진행할 계획이다.

/ 감사의 글 /

본 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(RS-2024-00348713) 및 과학기술정보통신부의 재원으로 수행된 한국건설기술연구원 주요사업의 결과물임(No.20230146-001).

/ REFERENCES /

1. Bracci JM, Reinhom AM, Mander JB, Seismic resistance of concrete frame structures designed for gravity loads: performance of structural system, *ACI Struct J*, 1995;92(5):597-609.
2. Sause R, Herries KA, Walkup SL, Pessiki Sm Ricles JM, Flexural behavior of concrete columns retrofitted with carbon fiber reinforced polymer jackets, *ACI Sturct J*, 2004;101(5):708-716.
3. Jeon J-S, DesRoches R, Lowes LN, Brilakis I, Framework of aftershock fragility assessment—case studies: older California Reinforced concrete building frames, *Earthquake Eng. Struct. Dyn*, 2015;44(15):2617-2636.
4. Wright TR, Full-scale seismic testing of a reinforced concrete moment frame using mobile shakers, Atlanta, GA (US): Georgia Institute of Technology, PhD Thesis.
5. Ministry of the Interior and Safety (MOIS), Pohang Earthquake White Paper, 2018: 144-163, 209-213, 227-241.
6. Aschheim M, Gülkan P, Sezen H, Bruneau M, Elnashai AS, Halling M, et al, Performance of buildings, *Earthquake Spectra*, 2000; 16(S1):237-279.
7. Gulen O, Robert KD, Tugce B, Jui-Liang L, Tunç Deniz Uludağ et al., Field reconnaissance and observations from the February 6, 2023, Turkey earthquake sequence, *Original Paper 2023*;119:663-700.
8. Sause R, Harries KA, Walkup SL, Pessiki S, Ricles JM, Flexural behavior of concrete columns retrofitted with carbon fiber reinforced polymer jackets, *ACI Structural J*, 2004;101(5):708-716.
9. Harries K, Ricles J, Pissiki S, Sause R, Seismic retrofit of lap splices in nonductile columns using CFRP jackets, *ACI Struct J*, 2006;103(6):226-236.
10. Haroun MA, Mossalam AS, Feng Q, Elsanadedy Hm, Experimental investigation of seismic repair and retrofit of bridge columns by composite jackets, *J Reinforced Plastics and Composites*, 2003; 22(4):1243-1268.
11. Lan YM, Sotelino ED, Chen WF, State of the art review of highway bridge columns retrofitted with FRP jackets, Department Report CE-STR-98-5; School of Civil Engineering Purdue University; West Lafayette (IN); c1998.
12. Seible F, Prisetley MJN, Innamorato D, Weeks J, Policelli F, Carbon fiber jacket retrofit test of circular shear bridge column, CRC-2, advanced Composites Technology Transfer Consortium Rep. No,

- ACTT-94/02, University of California, San Diego, La Jolla, California; c1994.
13. Seible F, Hegemier GA, Priestley MJN, Ho F, Innamorato D, Rectangular carbon jacket retrofit of flexural column with 5% continuous reinforcement, Advanced Composites Technology Transfer Consortium Report No. ACTT-95/03, University of California, San Diego, La Jolla, California; c1995.
14. Seible F, Hegemier GA, Priestley MJN, Innamorato D, Ho F, Carbon fiber jacket retrofit test of circular flexural columns with lap spliced reinforcement, Advanced Composites Technology Transfer Consortium Report No. ACTT-95/04, University of California, San Diego, La Jolla, California; c1995.
15. Seible F, Priestley MJN, Hegemier GA, Innamorato, Seismic retrofit of RC Columns with continuous carbon fiber jackets, *J Composites for Construction*, 1997;1(2):52-62.
16. Ministry of Land, Infrastructure and Transport (MOLIT), Korea Authority of Land & Infrastructure Safety (KALIS), Guidelines for Seismic Performance Evaluation of Existing Structures (Buildings), 2021:2-4.
17. Lee SC, Prediction of concrete strength using artificial neural networks, *Eng Struct*, 2003;25(7):849-57.
18. Inel M, Modeling ultimate deformation capacity of RC columns using artificial neural networks, *Eng Struct*, 2007;29(3):329-335.
19. Stewart LK, Morrill KB, Residual capacity prediction of blast-loaded steel columns using physics-based fast running models, *Int J Safety Security Eng*, 2015;5(4):289-303.
20. Shin J, Scott DW, Stewart LK, Jeon J, Multi-hazard assessment and mitigation for seismically-deficient RC building frames using artificial neural network models, *Engineering Structures*, 2020; 207: 110204. Available from: <https://doi.org/10.1016/j.engstruct.2020.110204>
21. Pham K, Kim D, Park S, Choi H, Ensemble learning-based classification models for slope stability analysis, *Catena*, 2021;196: 104886. Available from: <https://doi.org/10.1016/j.catena.2020.104886>
22. Shin J, Scott DW, Stewart LK, Yang CS, Wright RT, DesRoches R, Dynamic response of a full-scale reinforced concrete building frame retrofitted with FRP column jackets, *Eng Struct*, 2016; 125:244-53.
23. Livermore Software Technology Corporation, LS-DYNA Keyword User's Manual Version 971/R7.0, Livermore, CA (US); c2013.
24. FEMA-P695, Quantification of building seismic performance factors Rep. No. FEMA-P695, Federal Emergency Management Agency (FEMA): Washington, DC (US); c2009.
25. Shin J, Stewart LK, Yang CS, Scott DW, Implementation of bond-slip performance models in analyses of non-ductile reinforced concrete frames under dynamic loads, *J Earthquake Eng*, 2020; 24(1):129-154.
26. Shin, J, Multi-hazard performance criteria for non-ductile reinforced concrete frame buildings retrofitted with an FRP column jacketing system, PhD thesis, Georgia Institute of Technology, Atlanta, GA (US); c2017.

27. FEMA-356. Pre-standard and commentart for the seismic rehabilitation of buildings, prepared by ASCE. Rep. No. FEMA-356, Federal Emergency Management Agency (FEMA): Washington, DC (US); c2000.
28. FEMA-P695. Quantification of building seismic performance factors Rep. No. FEMA-P695, Federal Emergency Management Agency (FEMA): Washington, DC (US); c2009.
29. FEMA-356. Pre-standard and commentart for the seismic rehabilitation of buildings, prepared by ASCE. Rep. No. FEMA-356, Federal Emergency Management Agency (FEMA): Washington, DC (US); c2000.