

# 기계학습 기반 철근콘크리트 기둥에 대한 신속 파괴유형 예측 모델 개발 연구

## Machine Learning-Based Rapid Prediction Method of Failure Mode for Reinforced Concrete Column

김수빈<sup>1)</sup> · 오근영<sup>2)</sup> · 신지욱<sup>3)\*</sup>

Kim, Subin<sup>1)</sup> · Oh, Keunyeong<sup>2)</sup> · Shin, Jiuk<sup>3)\*</sup>

<sup>1)</sup>경상국립대학교 건축공학과 석사과정, <sup>2)</sup>한국건설기술연구원 건축연구본부 수석연구원, <sup>3)</sup>경상국립대학교 건축공학과 조교수(공학박사)

<sup>1)</sup>Student, Department of Architecture Engineering, Gyeongsang National University, <sup>2)</sup>Senior Researcher, Department of Building Research, Korea Institute of Civil Engineering and Building Technology, <sup>3)</sup>Assistant Professor(PhD), Department of Architecture Engineering, Gyeongsang National University

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

Existing reinforced concrete buildings with seismically deficient column details affect the overall behavior depending on the failure type of column. This study aims to develop and validate a machine learning-based prediction model for the column failure modes (shear, flexure-shear, and flexure failure modes). For this purpose, artificial neural network (ANN), K-nearest neighbor (KNN), decision tree (DT), and random forest (RF) models were used, considering previously collected experimental data. Using four machine learning methodologies, we developed a classification learning model that can predict the column failure modes in terms of the input variables using concrete compressive strength, steel yield strength, axial load ratio, height-to-dept aspect ratio, longitudinal reinforcement ratio, and transverse reinforcement ratio. The performance of each machine learning model was compared and verified by calculating accuracy, precision, recall, F1-Score, and ROC. Based on the performance measurements of the classification model, the RF model represents the highest average value of the classification model performance measurements among the considered learning methods, and it can conservatively predict the shear failure mode. Thus, the RF model can rapidly predict the column failure modes with simple column details.

**Key words:** Reinforced concrete columns, Machine-learning, Flexural failure, Shear failure, Flexure-shear failure

## 1. 서론

철근콘크리트 기둥의 파괴유형 결정은 건축물과 교량의 성능평가과정에서 중요한 구성요소이며 전반적으로 급격한 강도 감소 등의 구조적 안전성과 밀접한 관련이 있다. 내진설계 적용 이전에 건설된 철근콘크리트 골조 구조물은 기둥의 파괴유형에 따라 전체 거동에 영향을 미칠 수 있다. 기존의 지진에 취약한 구조상세를 보유한 기둥에 대하여 구조엔지니어는 이를 고려하여 보강 공법을 결정해야 한다. 기둥의 파괴유형은 기둥의 구조상세(주철근비, 전단철근비 등), 기하학적 특성(기둥의 길이, 경계조건 등) 등에 영향을 받는다. 이는 과거 수행된 다양한 실험 연구를 통하여 검증된다[1-3].

Zhu et al.[4]은 띠철근의 전단강도를 이용하여 철근콘크리트 기둥의 파괴 유형을 분류하고자 하였다. Qi et al.[5]는 전단 경간 대 깊이 비율, 후프 간격 대 깊이 비율과 같은 일부 매개변수를 고려하였다. 앞에 언급한 과거에 수행된 실험을 통하여 기둥의 파괴유형을 반영할 수 있는 다양한 변수가 조사되었다. 이를 기반으로 현재 기준에서는 기둥의 전단성능을 산정할 수 있는 실험 기반의 식을 제안하고 있다. 해당 식을 활용하여 기둥의 파괴유형을 결정하기 위하여, 파이버 요소 기반의 해석모델에 대한 비선형 정적해석과 코드에서 제시하는 전단성능 식을 비교하여 판단한다. 다양한 변수를 기반으로 기둥의 파괴유형을 신속하게 판단하기 위하여 본 연구에서는 기계학습 방법론을 적용하였다.

기계학습 모델은 철근콘크리트 건축물의 파괴 유형을 예측하는 데 활용될 수 있다. 예를 들어 인공 신경망(ANN) 성능은 이전에 철근콘크리트 기둥의 강도 예측[6] 또는 철근콘크리트 골조의 지진 연구[7]와 같은 여러 대 상에 대해 평가되었다. Alibrandi et al.[8]은 분류기법 중 SVM(Support

\*Corresponding author: Shin, Jiuk

E-mail: jiukshin@gnu.ac.kr

(Received October 30, 2023; Revised December 14, 2023; Accepted December 15, 2023)

Vector Machine) 접근 방식을 사용하여 구조물의 파괴 확률을 평가하였다. 이 기술은 철근콘크리트 보-기둥 접합부의 파괴 유형을 분류하기 위해 Mangalathu and Jeon[9]에 의해 사용되었다. 복잡한 계산 없이 실무에 활용할 수 있는 또 다른 기계학습 모델은 의사결정나무(DT)이다. 과거 연구에서 철근콘크리트 접합부의 파괴 유형을 분류하기 위해 DT를 사용하였다 [10]. 기둥의 파괴 유형은 전체 강도에 따라 달라지고 [11] RC 기둥의 에너지 소산 용량과 연성에 영향을 미치기 때문에 [12], 파괴 등급에 대한 지식은 엔지니어가 위험한 파괴를 방지하기 위해 해당 부재에 대한 최적화된 특성을 선택하는 데 도움이 될 수 있다. Mangalathu et al.[13]는 철근콘크리트 원형 기둥의 파괴유형을 예측하기 위한 기계학습 기법을 제안하였다. 또한, Feng et al.[14]은 직사각형 RC 기둥의 파괴유형 예측을 목표로 앙상블 기계학습을 연구하였다.

본 논문은 파괴유형에 영향을 미칠 수 있는 다양한 변수를 기반으로 신속하게 철근콘크리트 기둥의 파괴유형을 예측하기 위하여 기계학습 기반 모델을 제안하였다. 본 연구는 철근콘크리트 기둥의 330개의 실험 테스트로 구성된 데이터베이스를 사용하고 있으며, 철근콘크리트 기둥 파괴 거동에 영향을 미칠 수 있는 6개의 주요 입력변수(콘크리트 압축강도, 철근 항복강도, 축력비, 세장비, 주철근비 그리고 전단철근비)를 사용한다. 본 연구의 목적은 철근콘크리트 기둥의 파괴유형(휨파괴, 휨-전단파괴, 그리고 전단파괴)을 예측하는 데 있어 다양한 기계학습 기법의 성능을 분석하여 예측 모델을 결정하는 것이다.

## 2. 실험 데이터베이스

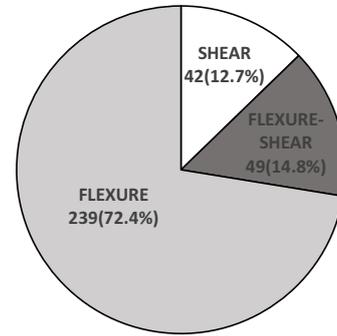
2장은 기계학습에 사용되는 데이터베이스와 철근콘크리트 기둥의 파괴 거동의 주요 변수를 설명한다.

### 2.1 철근콘크리트 기둥 데이터베이스

본 연구에서는 직사각형 철근콘크리트 기둥을 대상으로 예측 모델을 개발하였으며 총 330개의 데이터가 사용되었다. ACI와 PEER 보고서 [15]가 발표한 330개의 직사각형 RC 기둥의 실험 결과가 수집되었다. 데이터베이스는 휨파괴, 휨-전단파괴 그리고 전단파괴로 구성된다. 이전 연구에서는 균열 유형에 따라 횡하중 성능 저하로 인한 철근콘크리트 기둥의 세 가지 유형의 파괴 유형을 나타내었다 [16]. 휨파괴, 휨-전단파괴 그리고 전단파괴에 대한 정의는 Table 1에 나타내었다 [17]. 실험 방법의 비용과 시간 소모적 특성으로 인해 철근콘크리트의 파괴 유형을 결정하는 실용적인 기술을

**Table 1.** The considered failure mode

Failure Mode	Description
Flexure	Degradation occurred due to flexural deformation after yielding of the longitudinal reinforcement
Shear	Degradation (diagonal cracks) occurred due to shear distress before yielding of the longitudinal reinforcement
Flexure-shear	Degradation occurred after yielding of the longitudinal reinforcement but results from shear distress



**Fig. 1.** Reinforced Concrete Column Database for Failure Mode Classification

제공하는 것이 유용할 수 있다. Fig. 1은 본 연구에서 사용한 철근콘크리트 기둥 데이터베이스의 구성요소를 보여준다

### 2.2 파괴거동에 영향을 미치는 입력변수

본 연구에서 사용한 입력변수는 콘크리트 압축강도( $f_c$ ), 철근 항복강도( $f_y$ ), 축력비( $P/A_g f_c$ ), 형상비( $L/D$ ), 주철근비( $\rho$ ) 그리고 전단철근비( $\rho_v$ )이다. Fig. 2는 철근콘크리트 기둥 데이터베이스에 사용된 6개의 입력변수의 분포를 보여준다. 다양한 강도에 대한 파괴유형을 예측하기 위해 콘크리트와 철근의 강도를 입력변수로 선정하였다. Choi et al.[18]은 콘크리트 강도 및 축응력이 증가함에 따라 기둥의 전단강도가 증가하는 경향을 보이고 있음을 보여준다. 전단성능을 산정하는 식 (1)에 따르면 축하중이 증가함에 따라 전단강도가 증가함을 보여준다.

$$V_{ACI} = \frac{1}{6} \left( 1 + \frac{N_u}{14A_g} \right) \sqrt{f_{ck}} b_w d + \frac{A_v f_y d}{s} \tag{1}$$

여기서,  $N_u$ :  $V_{ACI}$ 와 동시에 발생하는 단면에 수직한 계수 축하중(N),  $A_g$ : 기둥의 전체 단면적( $\text{mm}^2$ ),  $f_{ck}$ : 콘크리트 설계기준강도(MPa),  $b_w$ : 부재의 복부 폭(mm),  $d$ : 기둥의 유효깊이(mm),  $A_v$ : s 거리 내의 전단철근의 총 단면적( $\text{mm}^2$ ),  $f_y$ : 철근의 설계기준항복강도(MPa), s: 전단철근의 간격(mm)이다. Bazant and Kwon[19]은 기둥의 세장비가 증가함에 따라 크기 효과(size effect)가 더욱 강해지고 취성도가 증가함을 보여준다. Shi et al.[20]은 주철근비가 증가함에 따라 휨강도가 증가하지만 변위에는 거의 차이가 없음을 보여주었고, 전단철근비가 증가함에 따라 강도가 증가하고 에너지 소산능력이 향상됨을 보여준다. Fig. 2에서 통계 데이터의 분포를 보여주고, Table 2는 입력변수의 최소값, 최대값, 그리고 대표값을 보여준다. 대표값은 통계 데이터 기반으로 선정하였고 데이터의 개수가 가장 집중되어있는 구간의 평균값을 대표값으로 결정하였다. 축력비는 축력비가 0인 경우는 존재하지 않으므로 최소값을 0 다음으로 작은 값으로 선정하였다.

## 3. 기계학습방법론

기계학습(Machine-Learning, ML)은 과거 경험이 담긴 데이터를 수학적 모델에 입력함으로 컴퓨터가 데이터를 분석하고 스스로 학습하는 과정

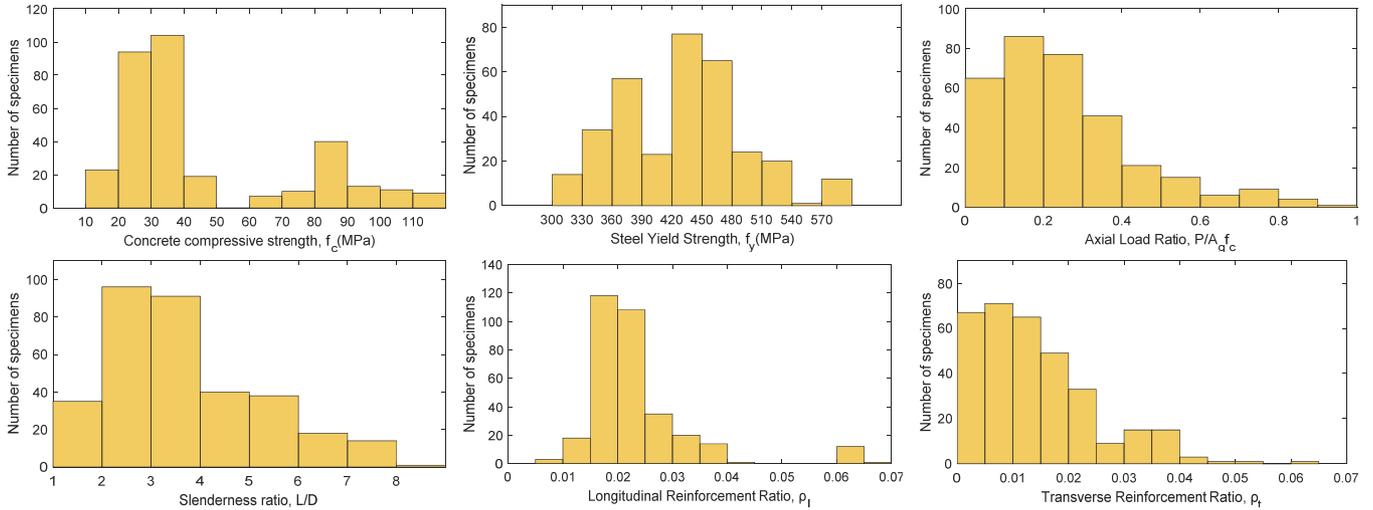


Fig. 2. Frequency of input parameters

Table 2. Statistics summary of experimental database used in this research

Parameter	Model range	Nominal	Extreme values	
			Minimum	Maximum
Concrete compressive strength	13.10 to 118.00	34.11	13.10	118.00
Steel Yield Strength	0 to 587.10	436.23	0	587.10
Axial Load Ratio	0.03 to 0.9	0.14	0.03	0.90
Slenderness ratio	1.12 to 8.67	2.43	1.12	8.67
Longitudinal Reinforcement Ratio	0.0009 to 0.0615	0.0073	0.0009	0.0615
Transverse Reinforcement Volumetric Ratio	0.0068 to 0.0694	0.0174	0.0068	0.0694

을 거쳐 패턴을 인식하여 목표하는 값을 예측할 수 있는 프로세스를 뜻한다. 지도학습은 확보한 데이터셋을 사용하여 모델을 훈련시킨 후 그 훈련된 모델을 통해 새로운 데이터를 예측하는 기법이며 데이터가 연속형 변수이면 회귀기법으로, 이산형 변수이면 분류기법으로 분류할 수 있다. 본 연구에서는 분류기법을 사용하여 파괴거동을 예측한다. 데이터는 훈련세트(training dataset)와 테스트세트(test dataset) 두 가지로 나뉜다. 훈련세트는 잠재적인 예측 관계를 발견하는 데 사용되고 테스트세트는 예측 모델의 효율성과 정확성을 테스트하는 데 사용된다. 이 기법의 이점은 기계학습 모델이 훈련모델의 일부가 아닌 데이터에 대해 테스트할 수 있고 기계학습 모델이 데이터에 과적합되었는지 여부를 평가할 수 있는 것이다. 본 연구에서는 기계학습 중 인공신경망(ANN), K-최근접 이웃(KNN), 의사결정나무(DT) 그리고 랜덤포레스트(RF)를 사용하였다.

인공 신경망(Artificial Neural Network, ANN)은 이 분야에서 가장 널리 사용되는 모델 중 하나이다. 인공신경망은 일련의 독립 매개변수(입력 변수)를 사용하여 종속 매개변수(목표 변수)의 값을 추정하는 방법이다. 인공신경망의 기본은 인간의 두뇌와 뉴런이 서로 상호 작용하는 동작을 간단하게 시뮬레이션하는 것이다. 신경망의 구조는 일반적으로 입력층, 은닉층, 출력층의 세 가지 계층으로 구성된다. 각 계층에는 전달 함수를 고려하여 가중 입력과 편향을 기반으로 출력을 결정하는 일부 노드(뉴런)가 있다. 이러한 뉴런은 인공신경망의 출력 매개변수를 결정한다. 신경망의 행렬 계산의 복잡성으로 인해 인공신경망의 최종 구조를 기반으로 간단한 솔루션(예: 선형 공식)을 제공하는 것은 불가능하다. 최적의 훈련 모델을 구현하기 위해

하이퍼파라미터를 설정한다. 인공신경망의 하이퍼파라미터에는 은닉층 크기, 은닉층의 활성화 함수, Batch 크기 그리고 최대 반복 횟수 등이 있다.

K-최근접 이웃(K-Nearest Neighbor, KNN)은 데이터를 그룹으로 분류하는 비모수적(non-parametric)인 방법이다. K-최근접 이웃 분류모델은 K-최근접 이웃에 가중치 1/k를 할당하고 다른 모든 이웃에는 가중치를 0으로 할당하는 것이다. 양의 정수 k와 테스트 관측치 x의 경우 분류기는 데이터 세트에서 x에 가까운 k포인트를 식별한다. k값은 학습 성능에 가장 큰 영향을 미치며, k값이 높을수록 데이터의 특징을 명확하게 표현하기 어려워므로 과소적합의 오류가 발생하며, k값이 낮은 경우 특정 데이터에 영향을 받아 과적합의 오류가 발생할 수 있다. K-최근접 이웃의 하이퍼파라미터에는 이웃 수, 이웃거리를 측정하는 방법, 거리 가중치 함수 그리고 최근접이웃 탐색방법 등이 있다.

의사결정나무(Decision Tree, DT)는 데이터를 분류하기 위한 비모수적인 방법이며 효율적이고 정확하며 복잡하지 않은 계산 접근 방식이다. 알고리즘은 훈련데이터를 기반으로 트리 모양의 그래프를 생성한다. 시작노드에서 끝 노드까지 트리의 결정에 따라 응답을 예측할 수 있다. 각 노드는 테스트 조건과 연결되며 각 분기는 테스트 결과를 나타낸다. 의사결정나무에서는 분류 목표에 가장 적합한 트리를 찾기 위해 먼저 일련의 데이터가 기계학습 알고리즘에 제공된다. 이 구조는 관찰 결과를 기반으로 각 독립 변수(분류자)에 대한 경계를 그리는 비교 접근 방식입니다. 각 단계를 비교하고 분기를 따라가면 입력 벡터의 레이블(이 문서에서는 오류 클래스)을 결정할 수 있다. 의사결정나무의 하이퍼파라미터에는 최대 트리 깊이, 결정 분

**Table 3.** Hyperparameters for each ML algorithm

Model	Parameter	Value
ANN	NumLayers	2
	Activations	tanh
KNN	NumNeighbors	1
	Distance	cityblock
DT	MinLeafSize	1
	Maximum depth of the tree	177
RF	Method	AdaBoostM2
	Maximum depth of the tree	5
	NumLearningCycles	488
	LearnRate	0.9274

할의 최대 개수 그리고 리프/가지 노드 관측값의 최소 개수 등이 있다.

양상블 학습 방법은 단일 기계학습 모델로 학습하는 방식이 아닌 여러개의 학습모델을 활용하여, 데이터를 학습하는 방법을 의미하며, Voting, Bagging, Boosting 그리고 Staking 방식이 대표적이다. 랜덤포레스트(Random Forest, RF)는 DT에 대한 양상블 모델로 서로 다른 특성을 갖는 여러개의 결정트리를 조합하여 결과를 산출하는 집단형 모델이다. 랜덤포레스트의 하이퍼파라미터에는 결정트리의 개수, 노드를 분할하기 위한 최소한의 샘플 데이터 수 그리고 트리의 최대 깊이 등이 있다.

본 연구에서 앞서 설명한 4개의 기계학습을 활용하였으며, 입력변수로 콘크리트 압축강도는 13.10 MPa과 118.00 MPa의 사이 랜덤하게 분포되어있는 데이터를 사용하였고, 철근 항복강도는 0 Mpa과 587.10 MPa의 사이, 축력비는 0.03과 0.9의 사이, 세장비는 1.12와 8.67의 사이, 주철근비는 0.0009와 0.0615의 사이, 그리고 전단철근비는 0.0068과 0.0694의 사이 랜덤하게 분포되어있는 데이터를 사용하였다. 입력변수를 사용하여 기계학습을 진행하고, 각 기계학습의 최적화 과정을 수행한다. ANN의 하이퍼파라미터는 은닉층 크기와 은닉층의 활성화 함수를 조정하고, KNN의 하이퍼파라미터는 이웃 수와 이웃거리를 측정하는 방법을 조정하며, DT의 하이퍼파라미터는 리프노드 관측값의 최소 개수와 최대 트리 깊이를 조정하였다. RF의 하이퍼파라미터는 트리의 최대 깊이, 학습횟수 그리고 학습률을 조정한다. Table 3은 본 연구에서 사용한 ANN, KNN, DT, 그리고 RF의 기계학습에 대한 하이퍼파라미터의 구성을 보여준다.

#### 4. 분류모델성능평가지표

본 연구에서는 철근콘크리트 기둥 파괴 유형 예측 모델 성능을 평가하기 위해서 분류모델성능평가지표를 이용하여 가장 적합한 모델을 선정하였다. 분류모델의 성능평가지표에는 오차행렬(Confusion Matrix)을 통하여 확인할 수 있으며, 오차행렬의 결과를 기반으로 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-Score, 그리고 AUC(Area Under the Curve)를 산정할 수 있다. Table 4는 오차행렬의 기본 개념을 나타낸 것이다. 험파괴를 기준으로 험파괴(positive)와 전단파괴(negative)를 분류하는 경우 만약 실제 전단파괴를 전단파괴로 예측하면 True Negative(TN), 실제 험파괴를 험파괴로 예측하면 True Positive(TP)로 나타낸다. False Negative(FN)의 경우 실제 험파괴를 전단파괴로 예측하는 경우이며 False Positive(FP)

**Table 4.** Confusion Matrix Concept

Classification		Predict Class	
		Positive	Negative
Actual Class	Positive	TP (True Positive)	FN (False Negative)
	Negative	FP (False Positive)	TN (True Negative)

는 실제 전단파괴를 험파괴로 잘못 예측한 경우를 나타낸다. 이러한 예측 결과를 이용하여 전체 예측 건수 대비 정확하게 예측한 건수의 비율을 나타내는 정확도(accuracy), 험파괴라고 예측한것 중 실제 험파괴인 비율을 나타내는 정밀도(precision), 실제 험파괴 중 험파괴라고 예측한 비율을 나타내는 재현율(recall), 재현율과 정밀도의 조화평균을 나타내는 F1-score를 이용하여 분석하였으며 아래의 식 (2)에서 식 (5)에 의해서 각각 계산되었다. 정밀도를 올리면 재현율은 낮아지고, 재현율을 높이면 정밀도가 낮아지는 trade-off 관계를 갖고 있다. ROC Curve는 민감도(Sensitivity)와 1-특이도(Specificity)로 그려지는 곡선을 의미한다. 여기서, 민감도는 재현율과 같고, 특이도는 식 (6)에 의해서 계산되었다. AUC는 ROC Curve의 아래 면적을 말한다. 우수한 분류 모델은 AUC 값이 1에 가까우며, 그래프가 좌상단에 근접하게 된다.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \tag{2}$$

$$Precision = \frac{TP}{(TP + FP)} \tag{3}$$

$$Recall = \frac{TP}{(TP + FN)} \tag{4}$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{(Precision + Recall)} \tag{5}$$

$$Specificity = \frac{TN}{(TN + FP)} \tag{6}$$

Fig. 3은 본 연구에서 사용한 기계학습 모델별 오차행렬이다. 오차행렬은 주어진 입력변수에 대한 실제값(파괴유형)과 기계학습 모델이 동일한 입력변수에 대하여 예측한 예측값(파괴유형)을 비교할 수 있다. 본 연구의 오차행렬에 표기된 1은 험파괴유형, 2는 전단파괴유형, 그리고 3은 험전단파괴유형을 뜻한다. 해당 행렬의 행은 실제값을 의미하며, 열은 예측값을 보여준다. 대각선 상에 있는 셀은 올바르게 분류된 관측값에 해당한다. 예를 들어 ANN모델의 경우, 험파괴유형으로 알려진 59개의 데이터가 올바르게 험파괴유형으로 분류됨을 알 수 있고, 전단파괴유형으로 알려진 4개의 데이터 중 올바르게 전단파괴유형으로 분류된 데이터가 2개, 하나의 데이터는 험파괴유형으로, 또 하나의 데이터는 험-전단파괴유형으로 오분류됨을 알 수 있다. 험-전단파괴유형으로 알려진 12개의 데이터 중 올바르게 험-전단파괴유형으로 분류된 데이터가 5개이고, 험파괴유형으로 오분류된

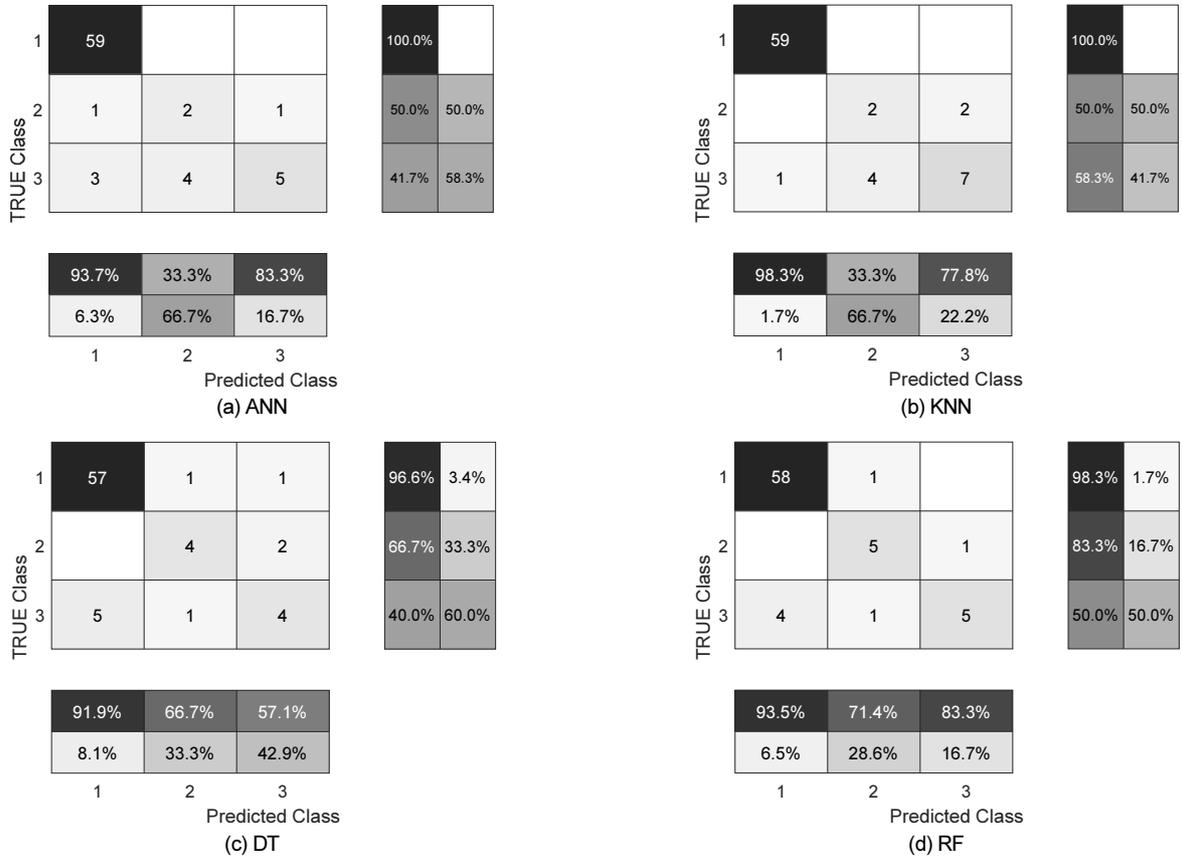


Fig. 3. Confusion Matrix by machine learning

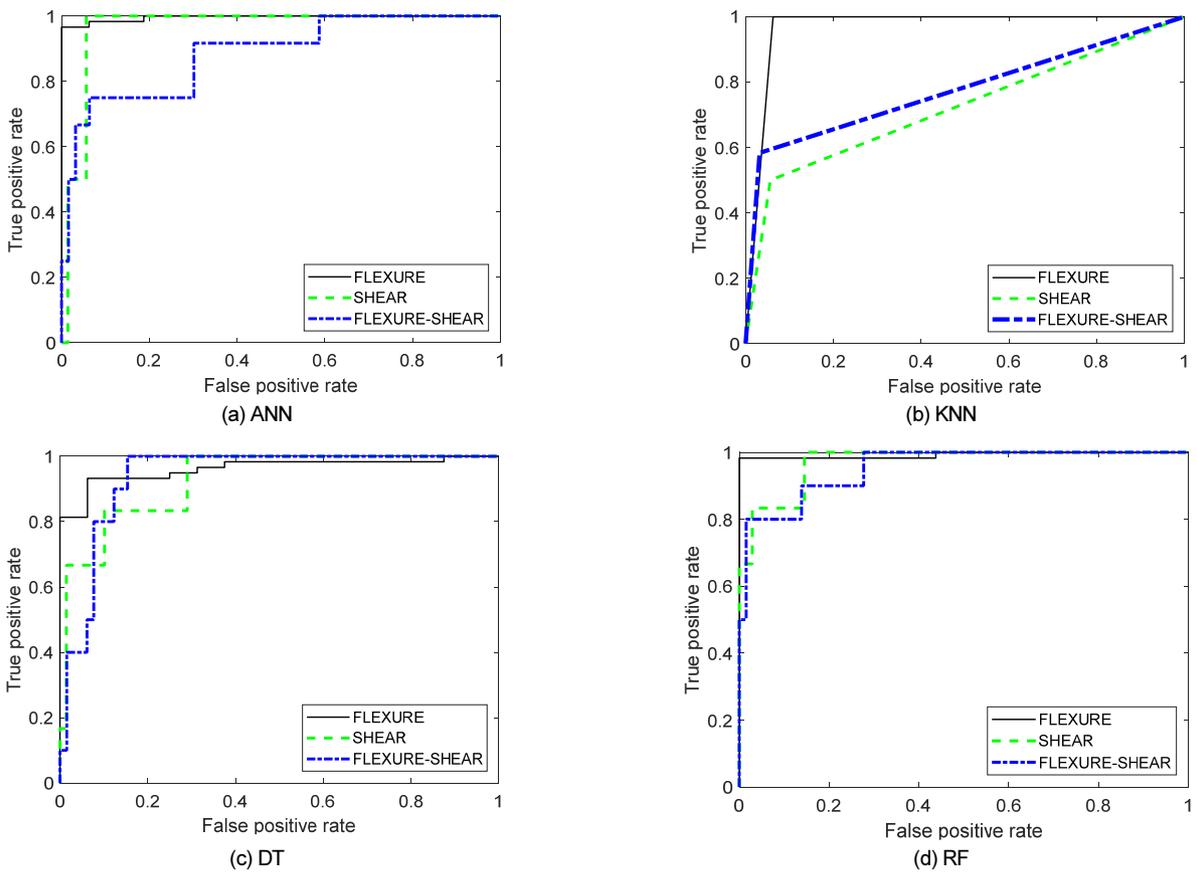


Fig. 4. ROC curve by machine learning

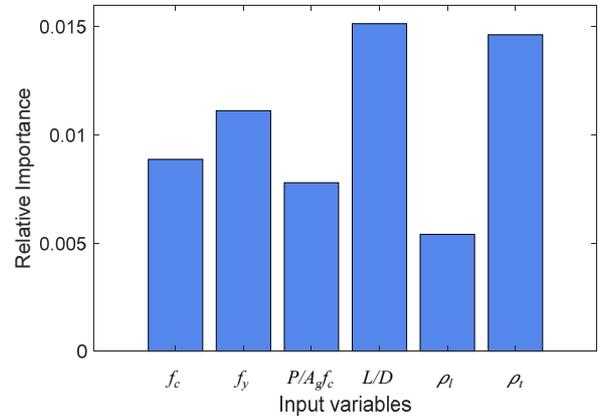
**Table 5.** Result of performance measurements of classification models

Measure		ANN	KNN	DT	RF
Accuracy		0.8820	0.9045	0.8632	0.8732
Precision	Flexure	0.9365	0.9833	0.9194	0.9355
	Shear	0.3333	0.3333	0.6667	0.7143
	Flexure-shear	0.8333	0.7778	0.5714	0.8333
	Overall	0.7010	0.6981	0.7192	0.8277
Recall	Flexure	1.0000	1.0000	0.9661	0.9831
	Shear	0.5000	0.5000	0.6667	0.8333
	Flexure-shear	0.4167	0.5833	0.4000	0.5000
	Overall	0.6389	0.6944	0.6776	0.7721
F1-Score	Flexure	0.9672	0.9916	0.9421	0.9587
	Shear	0.1721	0.1681	0.4714	0.6205
	Flexure-shear	0.3586	0.4575	0.2425	0.4344
	Overall	0.4993	0.5391	0.5520	0.6712
AUC	Flexure	0.9958	0.9688	0.9619	0.9905
	Shear	0.9648	0.7218	0.9275	0.9517
	Flexure-shear	0.8862	0.7758	0.9385	0.9185
	Overall	0.9489	0.8221	0.9426	0.9536

데이터가 3개, 전단파괴유형으로 오분류된 데이터가 4개임을 알 수 있다. ANN 모델과 KNN 모델의 경우, 전반적으로 전단파괴유형에 대한 정밀도, 재현율, F1-score의 값은 평균값에 미치지 못하며, 휨파괴유형에 대한 정밀도, 재현율, F1-score의 값은 평균값보다 높은 것으로 나타난다. 따라서 휨파괴유형은 정확하게 예측 가능하나, 전단파괴유형에 대한 예측은 정확하지 않다. DT 모델은 전반적으로 전단파괴유형과 휨-전단파괴유형에 대한 정밀도, 재현율, F1-score의 값은 평균값에 미치지 못하며, 휨파괴유형에 대한 정밀도, 재현율, F1-score의 값은 평균값보다 높은 것으로 나타난다. DT 모델은 휨파괴유형은 정확하게 예측 가능하나, 전단파괴유형과 휨-전단파괴유형에 대한 예측은 정확하지 않다. RF 모델은 전반적으로 휨파괴유형에 대한 정밀도, 재현율, F1-score의 값은 평균값보다 높은 것으로 나타나며, 전단파괴유형에 대한 재현율을 제외한 정밀도와 F1-score의 값은 평균값에 미치지 못한 것으로 나타났다. 또한 휨-전단파괴유형은 정밀도를 제외한 재현율과 F1-score의 값이 평균값에 미치지 못한 것으로 나타났다. 따라서 휨파괴유형은 예측이 정확하나, 전단파괴에 대한 예측은 보수적으로 판단될 수 있다.

Fig. 4는 본 연구에서 사용한 기계학습 모델별 ROC곡선이다. KNN 모델을 제외한 나머지 3가지 모델은 전반적으로 높은 AUC의 값을 가진다. 휨파괴유형에 대한 AUC 값은 4개의 모델 모두 0.95 이상으로 성능이 우수하다고 판단되고, 전단파괴유형과 휨-전단파괴유형에 대한 AUC 값도 KNN을 제외하고 0.85 이상으로 성능이 우수하다고 판단된다.

Table 5는 기계학습별로 오차행렬에 대한 각 파괴유형별 정확도, 정밀도, 재현율, F1-Score, 그리고 AUC의 값을 나타낸다. KNN 모델의 정확도가 가장 높게 나타났다. 정확도는 가장 직관적으로 모델의 성능을 나타낼 수 있는 평가지표이지만, 데이터가 불균형할 때 다른 평가지표(정밀도, 재현율, 그리고 AUC)를 활용한다. 전반적으로 모든 모델에 대하여 휨파괴유형은 90% 이상 성공적으로 예측하는 것으로 나타났다. 정밀도, 재현율, F1-score,



**Fig. 5.** Relative importance of input variables for predicting the failure modes of reinforced concrete columns

그리고 AUC의 평균값을 기준으로, 가장 우수한 성능을 보인 학습모델은 RF 모델로 판단된다. RF 모델은 휨파괴유형의 정밀도, 재현율, F1-score 그리고 AUC의 값이 0.9 이상으로 휨파괴유형을 예측하는 성능은 우수하다. 전단파괴유형의 정밀도는 0.71이고 재현율이 0.83으로 휨파괴유형에 비해 예측하는 성능이 낮지만 수치로 보았을 때 성능이 우수하다고 판단한다. 휨-전단파괴유형은 정밀도는 0.83이지만 재현율이 0.5로 휨-전단파괴유형을 예측하는 데 다소 미흡하다고 판단된다. 정밀도와 재현율의 조화평균을 의미하는 F1-score를 기준으로 각 기계학습 모델의 성능 순서는 RF, DT, KNN 그리고 ANN 모델로 평가된다. ANN 분류기는 휨-전단파괴유형의 재현율이 RF와 함께 가장 우수한 것으로 나타났으나, 전단파괴유형의 재현율은 RF와 DT 모델 대비 현저히 낮게 나타났다. 본 연구에서 개발된 기계학습 기반 모델은 간단한 정보를 활용하여 사전에 기동 파괴유형을 예측한다는 점을 고려했을 때 보수적으로 예측하는 모델이 타당할 것으로 판단되므로, 각 파괴유형별 재현율 중 전단파괴유형이 높은 모델을 선정하는 것이 합리적이다. 따라서 기동의 파괴유형을 예측하는 기계학습 모델 중 각 파괴유형별 정밀도, 재현율, F1-score, AUC 및 각 지표의 평균값을 고려했을 때 가장 높은 성능을 보여준 RF 모델이 결과를 잘 예측한다고 판단된다.

Fig. 5는 입력변수의 상대적인 중요도를 나타낸다. 여기서, 각 기호는 콘크리트 압축강도( $f_c$ ), 철근 항복강도( $f_y$ ), 축력비( $P/A_g f_c$ ), 형상비( $L/D$ ), 주철근비( $\rho$ ) 그리고 전단철근비( $\rho_t$ )이다. 학습데이터 기준 파괴유형에 영향을 미치는 요소를 중요도 평가를 통하여 산정하였다. 중요도를 통하여 각 변수가 모델의 성능에 얼마나 기여하는지를 알 수 있으며, 해당 변수가 예측에 중요한 역할을 하는 정도를 파악할 수 있다. 재료에 대한 영향보다는 세장비와 전단철근비에 대한 영향이 가장 높고, 주철근비는 다른 입력 변수에 비해 상대적으로 영향을 적게 미치는 것으로 나타났다.

## 5. 결론

본 논문에서는 철근콘크리트 기동의 파괴유형을 신속하게 예측하기 위한 기계학습 모델을 제안하였다. 기동의 파괴유형 예측 모델을 개발 및 검증하기 위하여 과거에 실험을 통하여 수집된 기동 데이터를 활용하여 4개의 기계학습을 수행하였으며, 분류모델의 성능평가지표를 통해 평가하였다.

- (1) 전반적으로 고려된 모든 기계학습 방법론은 휨파괴유형을 정확하게 예측하는 것으로 나타났다. 과거 실험 데이터 중 휨파괴유형에 대한 비중이 높기 때문에 휨파괴유형에 대한 예측을 보다 정확하게 할 수 있다고 판단된다.
- (2) 각 파괴유형별 분류모델 성능평가지표의 평균값을 고려했을 때 정확도를 제외한 정밀도, 재현율, F1-Score, 그리고 AUC에서 RF모델의 성능 수준이 가장 높은 것으로 나타났으므로, RF 모델은 기둥의 파괴유형을 정확하게 예측할 것으로 판단된다.
- (3) RF 모델은 정확도 검증에 활용된 각 성능지표에 대한 평균값 및 진단과 파괴유형에 대한 재현율이 가장 높은 것으로 나타났다. 따라서 실험 또는 해석 이전에 간단한 구조 상세 정보(재료강도, 축력비, 형상비, 철근 상세 정보 등)를 기반으로 파괴유형을 예측하기 위하여 보수적으로 예측할 수 있는 RF 모델이 가장 합리적인 것으로 판단된다.

## / 감사의 글 /

본 논문은 2023년도 교육부의 재원으로 한국연구재단의 지원(2021 RIS-003)을 받아 수행된 지자체-대학 협력기반 지역혁신 사업 및 과학기술정보통신부의 재원으로 수행된 한국건설기술연구원 주요사업(No.2023 0146-001)의 일환으로 수행되었음.

## / REFERENCES /

1. Mo YL, Wang SJ. Seismic behavior of RC columns with various tie configurations. *Journal of Structural Engineering*. 2000;126(10):1122-1130.
2. Lynn AC, Moehle JP, Mahin SA, Holmes WT. Seismic evaluation of existing reinforced concrete building columns. *Earthquake Spectra*. 1996;12(4):715-739.
3. Sezen H, Moehle JP. Seismic behavior of shear-critical reinforced concrete building columns. *Seventh US National Conference on Earthquake Engineering*. Boston, MA. Earthquake Engineering Research Institute; c2002.
4. Zhu L, Elwood K, Haukaas T. Classification and seismic safety evaluation of existing reinforced concrete columns. *J Struct Eng*. 2007;133(9):1316-1330. Available from: [https://doi.org/10.1061/\(ASCE\)0733-9445\(2007\)133:9\(1316\)](https://doi.org/10.1061/(ASCE)0733-9445(2007)133:9(1316))
5. Qi YI, Han XL, Ji J. Failure mode classification of reinforced concrete column using Fisher method. *Journal of Central South University*. 2013;20(10):2863-2869. Available from: <https://doi.org/10.1007/s11771-013-1807-1>
6. Naderpour H, Mirrashid M. Proposed soft computing models for moment capacity prediction of reinforced concrete columns. *Soft Comput*. 2020;24(15):11715-11729. Available from: <https://doi.org/10.1007/s00500-019-04634-8>
7. Mirrashid M, Naderpour H. Innovative Computational Intelligence-Based Model for Vulnerability Assessment of RC Frames Subject to Seismic Sequence. *J Struct Eng*. 2021;147(3):04020350. Available from: [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0002921](https://doi.org/10.1061/(ASCE)ST.1943-541X.0002921)
8. Alibrandi U, Alani AM, Ricciardi G. A new sampling strategy for SVM-based response surface for structural reliability analysis. *Probab Eng Mech*. 2015;41:1-12. Available from: <https://doi.org/10.1016/j.probengmech.2015.04.001>
9. Mangalathu S, Jeon JS. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques. *Eng Struct*. 2018;160:85-94. Available from: <https://doi.org/10.1016/j.engstruct.2018.01.008>
10. Naderpour H, Mirrashid M. Classification of failure modes in ductile and non-ductile concrete joints. *Eng Fail Anal*. 2019;103:361-375. Available from: <https://doi.org/10.1016/j.engfailanal.2019.04.047>
11. Alcantara PA, Imai H. Failure mode classification of reinforced concrete columns by the analysis of the strain distribution in the main reinforcement. *Proceedings of the 12th World Conference on Earthquake Engineering; 2000 Jan 30-Feb 4; Auckland, NZ; New Zealand Society for Earthquake Engineering; c2000*.
12. Ying M, Jin-Xin G. Seismic failure modes and deformation capacity of reinforced concrete columns under cyclic loads. *Periodica Polytechnica Civil Engineering*. 2018;62(1):80-91.
13. Mangalathu S, Hwang SH, Jeon JS. Failure mode and effects analysis of RC members based on machine-learning-based SHapley Additive exPlanations (SHAP) approach. *Eng Struct*. 2020;219:110927.
14. Feng DC, Liu ZT, Wang XD, Jiang ZM, Liang SX. Failure mode classification and bearing capacity prediction for reinforced concrete columns based on ensemble machine learning algorithm. *Adv Eng Inf*. 2020;45:101126.
15. Berry M, Parrish M, Eberhard M. PEER structural performance database user's manual (version 1.0). Berkeley: University of California; c2004.
16. Yoshikawa H, Miyagi T. Ductility and failure modes of single reinforced concrete columns. *Nippon Konkurito Kogaku Kyokai Ronbunshu*. 1999;51(1):229-224.
17. Naderpour H, Mirrashid M, Parsa P. Failure mode prediction of reinforced concrete columns using machine learning methods. *Engineering Structures*. 2021;248:113263.
18. Choi JS, Yang WJ, Yi WH. Shear Strength Evaluation of Reinforced Concrete Columns 1 : Variable Analysis for Code Method. *Journal of the Architectural Institute of Korea (JAIK)*. 2017;37(1):687-688.
19. Bažant ZP, Kwon YW. Failure of slender and stocky reinforced concrete columns: Tests of size effect. *Materials and Structures*. 1994;27:79-90.
20. Shi Q, Ma L, Wang Q, Wang B, Yang K. Seismic performance of square concrete columns reinforced with grade 600 MPa longitudinal and transverse reinforcement steel under high axial load. In: *Structures*. Elsevier; c2021. p. 1955-1970.