

DOI:10.11918/202310012

锈蚀 RC 柱水平抗力的机器学习预测及参数敏感性分析

丁自豪^{1,2}, 雷川鹤^{1,2}, 郑史雄^{1,2}, 贾宏宇^{1,2}, 陈志强³, 许智^{1,2}

(1. 西南交通大学 土木工程学院, 成都 610031; 2. 桥梁智能与绿色建造全国重点实验室(西南交通大学), 成都 611756; 3. 成都大学 建筑与土木工程学院, 成都 610106)

摘要:为实现地震作用下破坏模式未知锈蚀 RC 柱的水平抗力快速预测,基于机器学习(ML)方法对锈蚀矩形 RC 柱的剩余水平抗力开展研究。首先,确定 ML 模型的输入参数,建立锈蚀矩形 RC 柱数据集,并对输入参数之间的相关性进行分析;然后,选择 6 种代表性 ML 算法(SVM、KNN、ANN、CNN、RF 和 CatBoost),搭建锈蚀 RC 柱的水平抗力 ML 模型,并采用网格搜索或试错法对模型的超参数进行优化,基于 5 折-交叉验证确定了 ML 模型的最优超参数;最后,根据 4 个常用的回归评估指标(E_{MA} 、 E_{RMS} 、 E_{MAP} 和 R^2)与测试集,对 6 种 ML 模型的预测精度进行评估,并基于性能优异的 ML 模型开展了输入参数重要性排序以及参数敏感性分析。结果表明:神经网络模型的预测性能普遍优于集成类或其他单一类模型,其中 ANN 模型的预测效果最佳,其预测值与试验值之比的均值和标准差分别为 1.01 和 0.14;剪跨比对锈蚀矩形 RC 柱的水平抗力影响最大且较为显著,重要性占比可高达 35%;矩形 RC 柱的水平抗力随着剪跨比、箍筋间距与截面有效高度比以及钢筋锈蚀率的增加呈减小趋势,而随着轴压比的增加呈先增大后趋于稳定或减小趋势。

关键词: 钢筋混凝土柱; 锈蚀; 地震作用; 水平抗力; 机器学习

中图分类号: TU375.3; TU311.41

文献标志码: A

文章编号: 0367-6234(2024)11-0080-08

Machine learning prediction and parameter sensitivity analysis for lateral capacity of corroded RC columns

DING Zihao^{1,2}, LEI Chuanhe^{1,2}, ZHENG Shixiong^{1,2}, JIA Hongyu^{1,2}, CHEN Zhiqiang³, XU Zhi^{1,2}

(1. School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031, China; 2. State Key Laboratory of Bridge Intelligent and Green Construction (Southwest Jiaotong University), Chengdu 611756, China; 3. School of Architecture and Civil Engineering, Chengdu University, Chengdu 610106, China)

Abstract: To achieve rapid lateral capacity prediction of corroded RC columns without specific failure modes under seismic action, residual lateral capacity of corroded rectangular RC columns has been investigated based on machine learning (ML) methods. First, the input parameters for the ML model were determined, the dataset of corroded rectangular RC column was reorganized and correlations among the input parameters were analyzed. Then, six typical ML algorithms, including SVM, KNN, ANN, CNN, RF and CatBoost, were selected to establish the ML models for lateral capacity of corroded RC columns, and the hyper-parameters of ML models were optimized and determined using grid search or trial-and-error methods as well as 5-fold cross-validation. Finally, the predictive accuracy of the six ML models was evaluated based on four widely-used regression evaluation metrics (E_{MA} , E_{RMS} , E_{MAP} and R^2) and testing set, and the importance ranking of input parameters and parameter sensitivity analysis were carried out based on the excellent ML models. Results show that the predictive performance of neural network models is generally better than that of ensemble models or other single models, in which ANN model is more satisfactory, and the mean and standard deviation of the ratio of its predicted result to experimental value are 1.01 and 0.14, respectively. Shear-span ratio has the highest and significant effect on the lateral capacity of corroded rectangular RC columns, with an importance of up to 35%. The lateral capacity of rectangular RC columns decreases with the increase of shear-span ratio, the ratio of stirrup spacing to section effective height and corrosion level, but increases at first and then tends to stabilize or decrease with the increase of axial load ratio.

Keywords: reinforced concrete column; corrosion; seismic action; lateral capacity; machine learning

收稿日期: 2023-10-09; 录用日期: 2023-11-20; 网络首发日期: 2024-04-23

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20240422.1612.002>

基金项目: 国家自然科学基金(52178169); 国家重点研发计划(2021YFB1600300)

作者简介: 丁自豪(1993—), 男, 博士研究生; 郑史雄(1965—), 男, 教授, 博士生导师

通信作者: 郑史雄, zhengsx@swjtu.edu.cn

钢筋混凝土 (RC) 柱或墩是建筑、桥梁工程领域中较为重要的承重和抗侧力构件。地震作用下, RC 柱的承载能力能否满足要求对于结构的整体性安全尤为重要。然而,在腐蚀环境(如氯离子侵蚀)的长期作用下,在役 RC 柱中钢筋易发生锈蚀,导致其水平抗力显著降低,极大地缩短了构件的使用年限并严重危及结构安全^[1-2]。因此,准确分析锈蚀 RC 柱的水平抗力对于既有 RC 结构的安全性评估、维修加固决策以及全寿命周期管理具有重要意义。

国内外研究学者对于锈蚀 RC 柱的水平承载力预测,主要根据具体的破坏模式(如剪切破坏、弯曲破坏)分别提出了抗剪^[3]和抗弯承载力模型^[4]。例如,文献[5-8]通过考虑锈蚀对钢筋和有效保护层厚度的影响,对现有规范或经验公式进行修正,提出了相应的抗剪承载力模型;文献[9-10]基于桁架和拱等理论,考虑钢筋锈蚀对材料参数的影响,推导了抗剪承载力解析表达式。对于锈蚀 RC 柱的抗弯承载力模型,需进一步考虑大偏心受压和小偏心受压破坏,通常根据弯矩和力平衡条件进行计算^[4]。但由于锈蚀往往引起钢筋与混凝土之间的黏结滑移,导致小偏心受压构件的受压区高度难以确定。文献[11-12]基于压-剪-弯交互作用方法,提出了锈蚀 RC 柱的水平抗力模型,但该模型也需提前对其破坏模式进行假定。值得注意的是,对 RC 柱的破坏模式研究尚处于钢筋未发生锈蚀阶段^[13-14],大量试验研究结果表明钢筋锈蚀可能会导致 RC 柱的破坏模式发生改变^[11],若使用 RC 柱锈蚀前的破坏模式预测其锈蚀后的承载能力是不合理的。因此,现有基于破坏模式已知的方法难以对正在服役的 RC 柱承载能力进行有效预测。近年来,机器学习 (ML) 方法在土木工程领域得到了迅速的推广和应用^[15],尤其是对 RC 构件(包括梁、柱/墩、梁柱节点以及剪力墙等)的抗震性能评估。该方法不需要复杂的力学机理和大量的计算,即可根据已训练好的模型由输入参数快速得到预测结果。迄今,研究学者对往复荷载作用下锈蚀矩形 RC 柱的承载能力开展了大量的试验研究,这为探究 ML 模型的搭建提供了数据基础。因此,有必要尝试基于 ML 方法对腐蚀环境下矩形 RC 柱的水平抗力进行预测。

鉴于此,本文选取了 6 种常用的 ML 算法,探究其在锈蚀矩形 RC 柱水平抗力预测中的适用性。首先,确定 ML 模型的输入参数,建立锈蚀矩形 RC 柱数据集,并对输入参数之间的相关性进行分析;然后,基于支持向量机 (SVM)、 k 最近邻 (KNN)、人工

神经网络 (ANN)、卷积神经网络 (CNN)、随机森林 (RF) 和 CatBoost 算法与训练集,搭建锈蚀 RC 柱的水平抗力 ML 模型,并采用网格搜索或试错法对模型超参数进行优化,根据 5 折-交叉验证确定了 ML 模型的最优超参数;最后,基于 4 个常用的回归评估指标 (E_{MA} 、 E_{RMS} 、 E_{MAPE} 和 R^2) 与测试集,对 6 种 ML 模型的预测精度进行评估,并基于性能优异的 ML 模型开展了输入参数重要性排序以及参数敏感性分析。

1 输入参数与数据集

表 1 列出了近年来 ML 方法在 RC 柱中的代表性应用^[16-24]。表中, λ 为剪跨比, $\lambda = a/h_0$,其中 a 为剪跨,由柱高 L 和边界条件决定; n 为轴压比 $n = P/(f_c'bd)$; s/h_0 为箍筋间距与截面有效高度之比; b 与 d 分别为柱截面宽度和高度; c 为保护层厚度; P 为轴压力; f_c' (f_t) 为混凝土的抗压(拉)强度; n_l (n_t)、 d_l (d_t)、 ρ_l (ρ_t)、 A_l (A_t) 和 f_{yl} (f_{yt}) 分别为纵筋(箍筋)的数量、直径、配筋(箍)率、截面面积和屈服强度;需要说明的是,上述参数均未考虑锈蚀。 η_l 与 η_t 分别为纵筋与箍筋的最大截面锈蚀率;FM 为破坏模式; V_{max} 为 RC 柱的水平抗力。多数学者将无量纲 λ 、 n 、 s/h_0 、 $\rho_l f_{yl}/f_c'$ 、 $\rho_t f_{yt}/f_t$ 作为预测 RC 柱破坏模式的重要输入特征参数。文献[21]研究表明 $\rho_l f_{yl}/f_c'$ 和 $\rho_t f_{yt}/f_t$ 对于 RC 柱的承载能力预测权重较小,该物理参数可能会削弱基本参数对 ML 模型输出结果的贡献。 f_c' 与 f_t 通常可以相互转换^[18],具有强相关性(高达 0.99)^[22],且 RC 柱的受力机制通常无须考虑混凝土的抗拉作用。影响锈蚀 RC 柱的承载能力主要包括柱几何尺寸(b 、 d 和 L),钢筋与混凝土材料参数(c 、 s 、 f_c' 、 f_{yl} 、 f_{yt} 、 A_l 、 A_t 、 d_l 和 d_t),锈蚀率(η_l 和 η_t),竖向荷载 P 以及边界条件等 16 个基本参数^[4, 10, 24]。为了充分考虑锈蚀 RC 柱的基本参数与特征参数,同时有效兼顾 ML 模型的预测精度,尽可能地缩减输入参数的维度,本文将 ML 模型的输入确定为 10 个参数,即: λ 、 n 、 ρ_l 、 ρ_t 、 s/h_0 、 f_{yl} 、 f_{yt} 、 f_c' 、 η_l 和 η_t 。基于文献[24]所提供的 224 组锈蚀 RC 柱数据(弯曲破坏 163 组,弯剪破坏 26 组,剪切破坏 35 组),10 个输入参数的数据集统计信息见表 2。图 1 给出了各参数之间的相关性,由图 1 可知,仅 s/h_0 与 ρ_t 、 η_l 与 η_t 之间表现出一定的相关性(相关系数绝对值为 0.67 与 0.62),其余参数之间的相关系数绝对值均小于 0.5,再次说明了本文参数选择的合理性。

表 1 ML 方法在 RC 柱中的代表性应用

Tab. 1 Representative applications of ML methods in RC columns

作者	输入参数	算法	预测目标
谢龙隆等 ^[16]	$\lambda, n, s/h_0, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t$	ANN, CBT, GBDT, LGB, SVM, RF	FM (未锈蚀)
成浩等 ^[17]	$\lambda, n, s/h_0, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t$	ANN, DT, KNN, LR, PMLR, SVM	FM (未锈蚀)
Mangalathu 等 ^[18]	$\lambda, n, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t$	ANN, DT, KNN, QDA, RF, NB	FM (未锈蚀)
Feng 等 ^[19]	$\lambda, n, b, d, L, c, s, P, f'_c, f_{yl}, f_{yt}, \rho_l, \rho_t, n_l, n_t, d_l, d_t, FM$	AdaBoost, ANN, CART, GBDT, RF, SVM	FM, V_{max} (未锈蚀)
Naderpour 等 ^[20]	$\lambda, n, \rho_l, \rho_t, f_{yl}, f_{yt}$	ANN, DT	FM (未锈蚀)
Xu 等 ^[21]	$\lambda, n, s/h_0, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t, \eta_l, \eta_t, FM$	AdaBoost, ANN, CatBoost, DT, KNN, RF	FM, V_{max} (锈蚀)
Ali 等 ^[22]	$\lambda, n, s/h_0, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t, \rho_l, \rho_t, f'_c, f_t, f_{yl}, f_{yt}$	ANN, DT, NB	FM (未锈蚀)
Yu 等 ^[23]	$\lambda, n, s/h_0, \rho_l f_{yl}/f'_c, \rho_l f_{yt}/f_t, \rho_l, \rho_t, f'_c, f_{yl}, f_{yt}$	GBDT	FM (未锈蚀)
Ding 等 ^[24]	$b, d, L, c, s, P, f'_c, f_{yl}, f_{yt}, A_l, A_t, d_l, d_t, \eta_l, \eta_t, \text{边界条件}$	ANN, CatBoost, CNN, KNN, RF, SVM	FM, V_{max} (锈蚀)

表 2 锈蚀矩形 RC 柱数据集的统计信息

Tab. 2 Statistical information for the corroded rectangular RC column dataset

统计量	输入参数										输出参数
	λ	n	$\rho_l/\%$	$\rho_t/\%$	s/h_0	f_{yl}/MPa	f_{yt}/MPa	f'_c/MPa	$\eta_l/\%$	$\eta_t/\%$	V_{max}/kN
最大值	11.00	0.75	6.28	1.19	1.19	610.00	607.40	47.00	54.00	71.54	513.20
最小值	1.55	0.00	0.89	0.11	0.16	359.00	235.00	9.47	0.00	0.00	19.33
中位值	4.27	0.20	1.79	0.42	0.41	485.00	390.00	31.70	5.90	8.02	72.19
均值	4.37	0.23	0.86	0.41	0.48	462.88	412.51	30.79	9.18	14.25	130.68
标准差	1.66	0.13	0.77	0.20	0.22	64.83	98.58	8.52	10.42	16.55	119.21

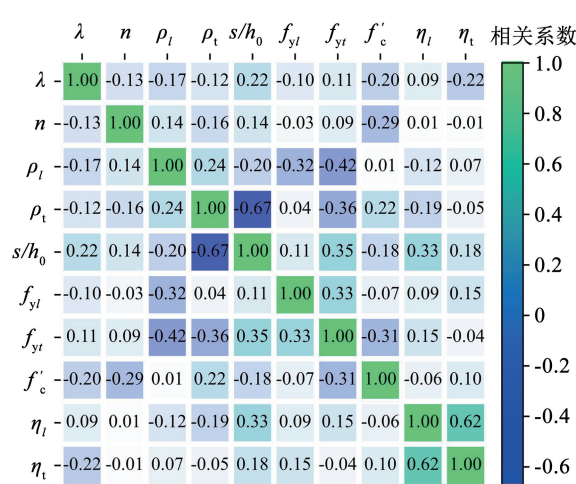


图 1 输入参数的相关系数矩阵

Fig. 1 Correlation coefficient matrix of input parameters

2 机器学习模型

本文选取了 6 种常用于土木工程领域的 ML 算法用于处理回归任务 (锈蚀矩形 RC 柱剩余水平抗力预测), 包括支持向量机 (SVM)、最近邻 (KNN)、神经网络 (ANN 和 CNN) 和集成算法 (RF 和

CatBoost)^[24]。其中, SVM 是一种经典且流行的算法, 在解决小样本、非线性和高维的模式识别问题中表现出许多优势; KNN 是一种相对简单的算法, 计算速率快, 需要调整的超参数较少; 神经网络模型选择了最为经典的 ANN 算法, 以及具有较好数据特征提取能力的 CNN 算法, 该类算法能够很好地捕捉输入变量与输出变量之间的复杂关系, 具有较强的鲁棒性和容错能力, 上述 4 种算法属于单一类学习; 集成类算法选择了 RF 和 CatBoost, 它们分别代表 Bagging 和 Boosting 类族, 能够较好地降低模型的偏差与方差, 对异常值和噪声具有较好的容忍度, 且不易过拟合。多种 ML 模型的使用可以探究不同算法对锈蚀矩形 RC 柱水平抗力预测的适用性。

2.1 模型搭建

为实现锈蚀 RC 柱的水平抗力预测, 将所确定的 10 个物理参数作为输入, 基于 224 组试验数据与 6 种 ML 算法, 通过对 ML 模型的训练、优化和验证, 最终得到可靠的 ML 预测模型, 具体实施流程如图 2 所示。

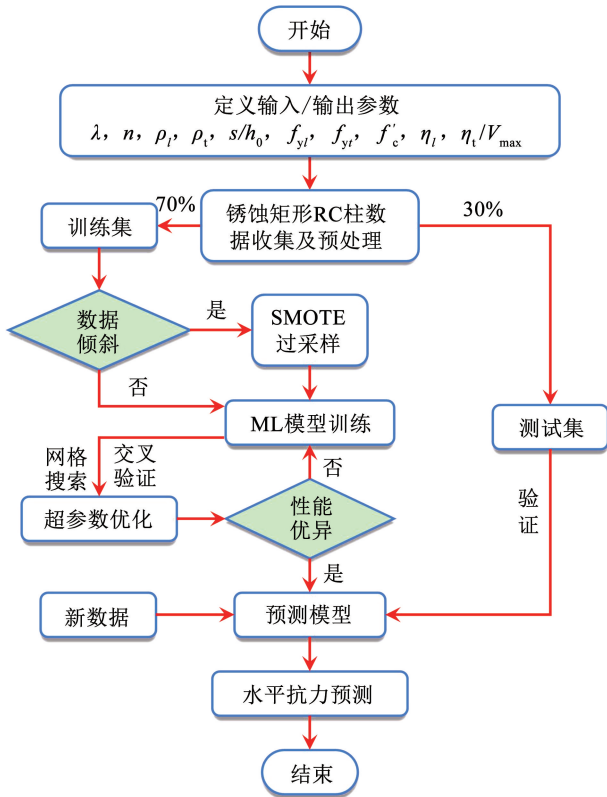


图 2 基于 ML 的锈蚀矩形 RC 柱水平抗力预测框架

Fig. 2 Framework of ML-based lateral capacity prediction of corroded rectangular RC columns

为避免不同特征数据的维度差异导致特征权重不一,需对数据集进行归一化预处理,将 10 个输入特征参数分别无量纲化,缩放至 $[0, 1]$ 内,以消除变量量纲的影响,使得特征值有均衡的权重,归一化公式为

$$\bar{X} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中: X 为输入变量, X_{\max} 、 X_{\min} 分别为输入变量的最大值与最小值, \bar{X} 为标准化后的输入变量。

对于整理好的数据集(224 组),按照 7:3 比例随机划分为训练集(156 组)与测试集(68 组)。训练集中,发生弯曲破坏、弯剪破坏与剪切破坏柱分别为 114 组、18 组和 24 组,其中弯剪或剪切破坏的数量远少于弯曲破坏。由于不同破坏模式所对应的抗剪需求特征存在较大差异^[18, 22],为避免由数据集不平衡所引起的预测结果倾斜问题,基于 SMOTE^[23] 分别将弯剪与剪切破坏数据过采样至 114 组,从而将数据集调整为均衡状态,具体公式为

$$\bar{x}_{ik} = x_i + \xi(x_{ik} - x_i) \quad (2)$$

式中: x_i 为少数类样本点, x_{ik} ($k = 1, 2, \dots, K$) 为距离 x_i 最近的 K 个同类样本点, \bar{x}_{ik} 为合成样本, ξ 为 $(0, 1)$ 内的随机数。

为可视化 SMOTE 的过采样效果,本文基于线性判别分析(LDA)法^[25],将训练集样本与合成样本

投影至线性子空间内(即最大化分离破坏模式类别与最小化其类内方差),然后找到最具判别性的投影向量,将样本原有的 10 个维度降至 2 维平面,其过采样效果如图 3 所示。

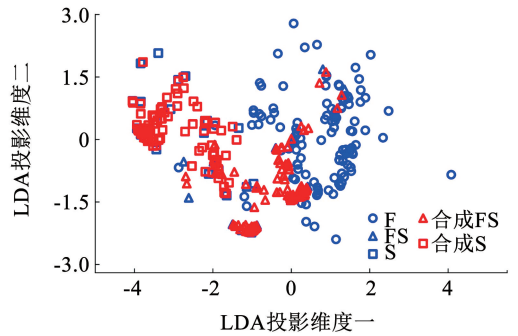


图 3 基于 SMOTE 的过采样效果

Fig. 3 Results of oversampling based on SMOTE

2.2 超参数优化

对于给定的学习任务,绝大多数 ML 算法的性能取决于超参数设置。为了确定最佳超参数,获取最优性能的 ML 模型,本文分别对 6 种 ML 模型进行超参数优化。针对 SVM、RF、KNN 和 CatBoost,采用网格搜索(GS)和 5 折-交叉验证(CV)的方法进行超参数优化,优化指标选用平均绝对误差 E_{MA} ,即

$$E_{MA} = \frac{\sum_{i=1}^N |P_i - Y_i|}{N} \quad (3)$$

式中: P_i 和 Y_i 分别为锈蚀 RC 柱的水平抗力预测值和实际值; N 为数据集样本个数。其优化过程如图 4(a)~4(d)所示。由图 4(a)可知,对于 SVM 模型, E_{MA} 值随着 C (惩罚参数)的增长逐渐减小并趋于稳定,但随着 γ (核函数参数)的增加先减小后增大。类似地,RF 模型的 E_{MA} 值随着最大树深与树的数量的增加逐渐减小最后趋于稳定(图 4(b)),较小的最大树深对模型的性能影响显著。KNN 模型仅需对超参数最近邻 k 值进行调整,如图 4(c)所示。随着 k 值的增加,模型误差逐渐增大,因此将 k 值确定为 1。对于 CatBoost 的超参数优化过程如图 4(d)所示,与 RF 类似,模型 E_{MA} 随着树的数量的增加先急剧下降随后趋于稳定,但受最大树深的影响并不显著,当最大树深为 5 时其 E_{MA} 值最小。对于神经网络这类深度学习算法,随着参数空间的增长,超参数优化所需计算会急剧增加,若采用 GS 与 CV 的方法费时费力,因此,本文对 ANN 与 CNN 采用试错法(TE)^[26],并将 20% 训练集数据作为验证集,用于检验模型训练过程的损失。对神经网络模型而言,增加隐藏层数或神经元个数,会提升模型的非线性学习能力,但同时也会增加模型的复杂度。

图 4(e) ~ 4(f) 给出了优化后的 ANN 与 CNN 模型在训练过程中的损失曲线。可以发现,两种模型的损失曲线在一开始下降迅速,但随着迭代次数的增加逐渐趋于平稳,最终 E_{MA} 值均保持在 20 以下,两种模型的验证损失与训练损失较为接近,说明其训练效果表现良好。6 种 ML 模型经过超参数优化,其最终超参数配置信息见表 3。

2.3 评价指标

为了量化 6 种 ML 算法在锈蚀矩形 RC 柱水平抗力预测中的性能表现,采用了 4 个常用的回归评价指标^[21,24],除了式中所描述的 E_{MA} ,其余指标分别为均方根误差 E_{RMS} ,平均绝对百分比误差 E_{MAP} 以及决定系数 R^2 ,即

$$E_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - Y_i)^2} \quad (4)$$

$$E_{MAP} = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_i - Y_i}{Y_i} \right| \times 100\% \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_i - Y_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (6)$$

式中 \bar{Y} 为实际值的均值。 R^2 越高, E_{MA} 、 E_{RMS} 和 E_{MAP} 越小,表明 ML 预测模型的性能更好。

表 3 ML 模型的超参数配置

模型	方法	指标	最优超参数
SVM	GS & CV	E_{MA}	kernel = RBF, $C = 1\ 000$, gamma = 3
KNN	GS & CV	E_{MA}	$k = 1$
ANN	TE	E_{MA}	Dense(16, 32, 64 × 2, 128 × 2, 64, 32, 16, fx = ReLu), Dense(1), Adam (learning rate = 0.0005)
CNN	TE	E_{MA}	Conv(64, 128, 256, 128, 64, kernel size = 2, fx = ReLu), maxpooling, Dense(1), Adam (learning rate = 0.002)
RF	GS & CV	E_{MA}	最大树深 = 11, 树的数量 = 6
CatBoost	GS & CV	E_{MA}	最大树深 = 5, 树的数量 = 1 000

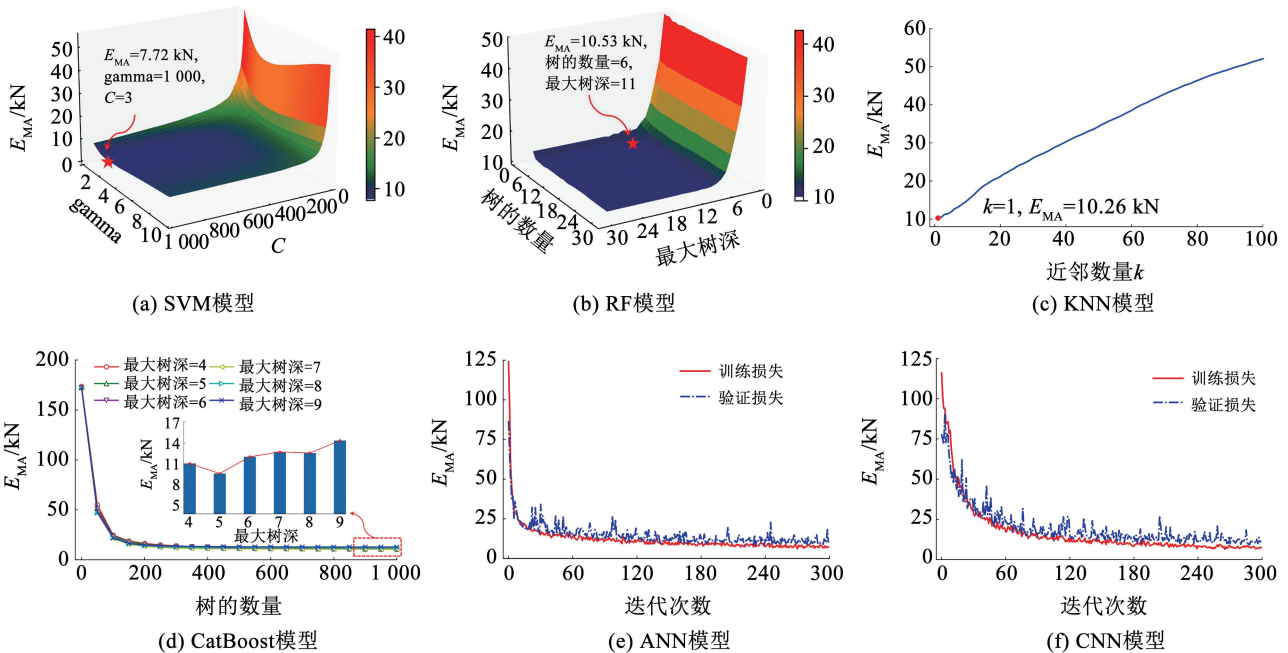


图 4 ML 模型的超参数优化

Fig. 4 Hyper-parameter optimization of ML models

3 ML 模型的预测性能评估

基于测试集中 68 根锈蚀矩形 RC 柱,可对 ML 模型的水平抗力预测精度进行评估,如图 5 所示。由图 5 可知,ANN、CNN 和 CatBoost 模型的预测散点绝大多数在 $\pm 30\%$ 误差之内,其预测值与试验值之比的均值分别为 1.01、1.01 和 1.02,且标准差均 ≤ 0.15 ,

上述模型的预测结果与试验值较为接近(在等值线 1.0 附近),表明其预测精度较高;而 SVM、KNN 和 RF 模型的预测值与试验值之比的均值分别为 1.06、1.03 和 1.04,标准差分别为 0.26、0.20 和 0.18,且有少数散点分布在 $\pm 30\%$ 误差线之外,离散性较大,说明其预测效果相对较差。

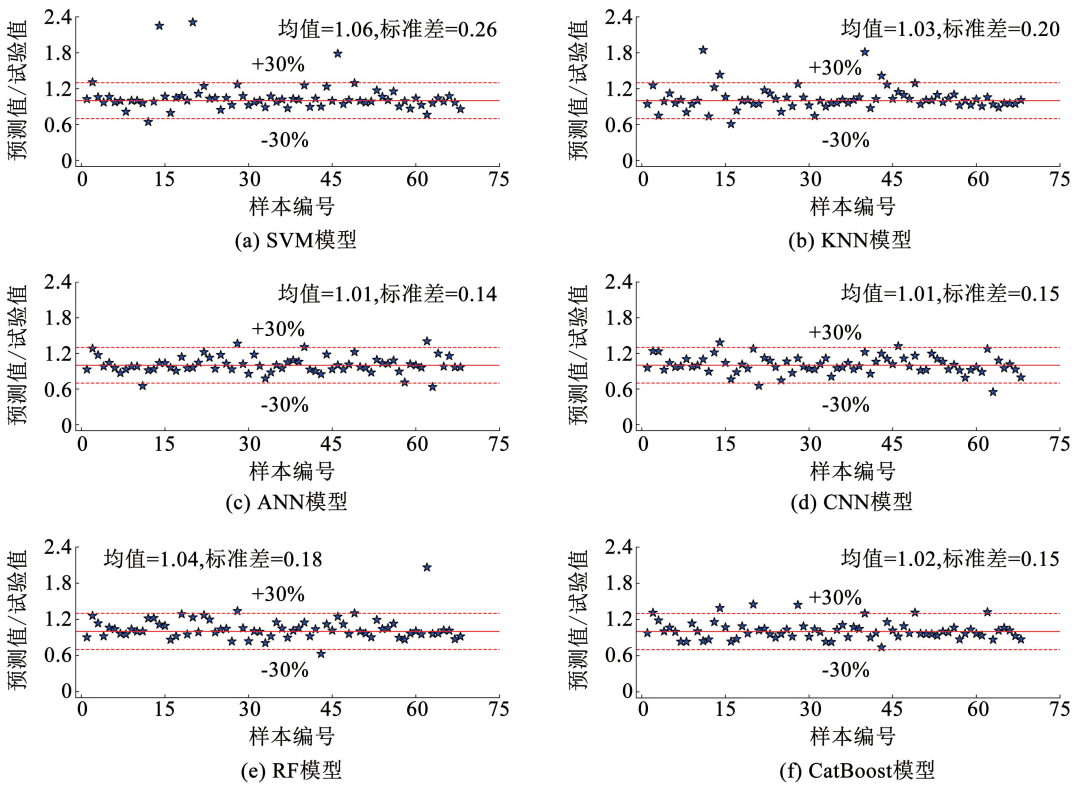


图 5 ML 模型预测结果与测试集对比

Fig. 5 Comparison between prediction results of ML models and testing set

表 4 基于前文的评价指标定量给出了各 ML 模型的预测精度, 6 种 ML 模型的预测和训练精度差值较小, 表明各模型在训练过程中得到适度拟合。其中, ANN 模型在测试集中的 E_{MA} 、 E_{MAP} 和 E_{RMS} 值分别为 12.19 kN、10.44% 和 18.16 kN, R^2 为 0.97, 性能表现最优; CatBoost 和 CNN 模型的预测精度与

ANN 模型较为接近; SVM 模型具有最大的 E_{MAP} 值 13.07%, 而 KNN 模型在 E_{MA} 和 E_{RMS} 两项指标中误差值最大, 且 R^2 值最小, 表明该两个模型的精度相对较差。总体而言, 神经网络模型的预测精度普遍优于集成类模型和其他单一类模型 (如 SVM 与 KNN 模型), 其中 ANN 模型的精度最优。

表 4 ML 模型水平抗力预测精度评估

Tab. 4 Accuracy evaluation of ML models for lateral capacity prediction

模型	R^2		E_{MA}/kN		$E_{MAP}/\%$		E_{RMS}/kN	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
SVM	0.98	0.97	7.72	11.94	9.21	13.07	15.43	21.08
KNN	0.96	0.91	10.26	16.12	9.24	12.27	23.08	34.39
ANN	0.99	0.97	8.34	12.19	7.66	10.44	13.08	18.16
CNN	0.99	0.97	9.06	13.79	7.85	11.49	14.62	19.87
RF	0.98	0.96	10.53	14.16	8.00	11.61	18.58	23.81
CatBoost	0.99	0.97	9.71	12.67	6.75	10.66	16.83	18.97

4 输入参数的重要性与敏感性分析

通过上述分析, CatBoost、ANN 和 CNN 模型在预测锈蚀矩形 RC 柱的水平抗力任务中表现优异。限于篇幅, 将神经网络 ANN 模型与集成类 CatBoost

模型作为代表, 基于 SHAP 方法^[27], 对 10 个输入参数的重要性进行排序, 如图 6 所示。

由图 6 可知, 剪跨比 λ 对 RC 柱水平抗力的影响最为显著, 重要性占比高达 35%, 明显大于其余 9 个输入参数。为探究常受关注的重要特征参数

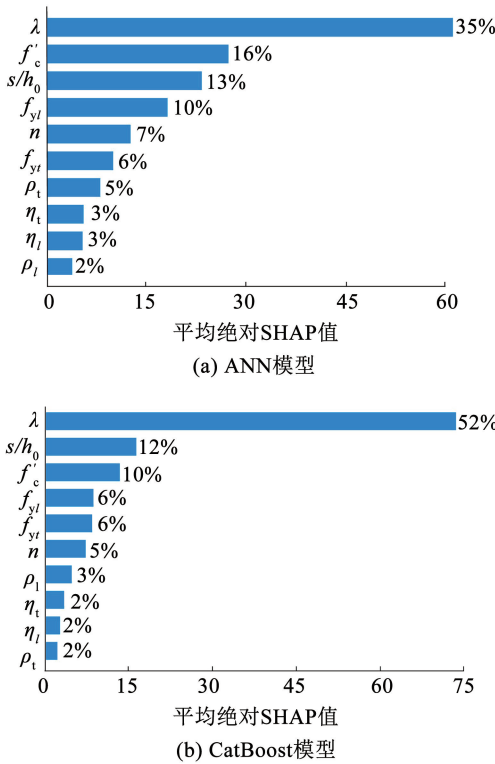


图 6 输入参数的重要性排序

Fig. 6 Importance ranking of input parameters

表 5 样本柱的参数信息

Tab. 5 Configuration of sample columns

编号	λ	n	$\rho_t/\%$	$\rho_l/\%$	s/h_0	f_{yt}/MPa	f_{yt}/MPa	f'_c/MPa	$\eta_t/\%$	$\eta_l/\%$
C1	1 ~ 5 (1.76)	0.1 ~ 0.5 (0.10)	2.05	0.93	0.2 ~ 1.0 (0.16)	550.0	300.0	32.2	0 ~ 20 (0)	0 ~ 50 (0)
C2	1 ~ 5 (3.95)	0.1 ~ 0.5 (0.33)	1.37	0.52	0.2 ~ 1.0 (0.40)	525.0	390.0	33.8	0 ~ 20 (0)	0 ~ 50 (0)
C3	1 ~ 5 (2.28)	0.1 ~ 0.5 (0.20)	1.42	0.44	0.2 ~ 1.0 (0.26)	382.0	449.0	36.9	0 ~ 20 (0)	0 ~ 50 (0)

注:括号里面的取值为默认值,如 C1 中,当对参数 λ 进行敏感性分析时, n 、 s/h_0 、 η_l 和 η_t 分别取为 0.10、0.16、0 和 0。

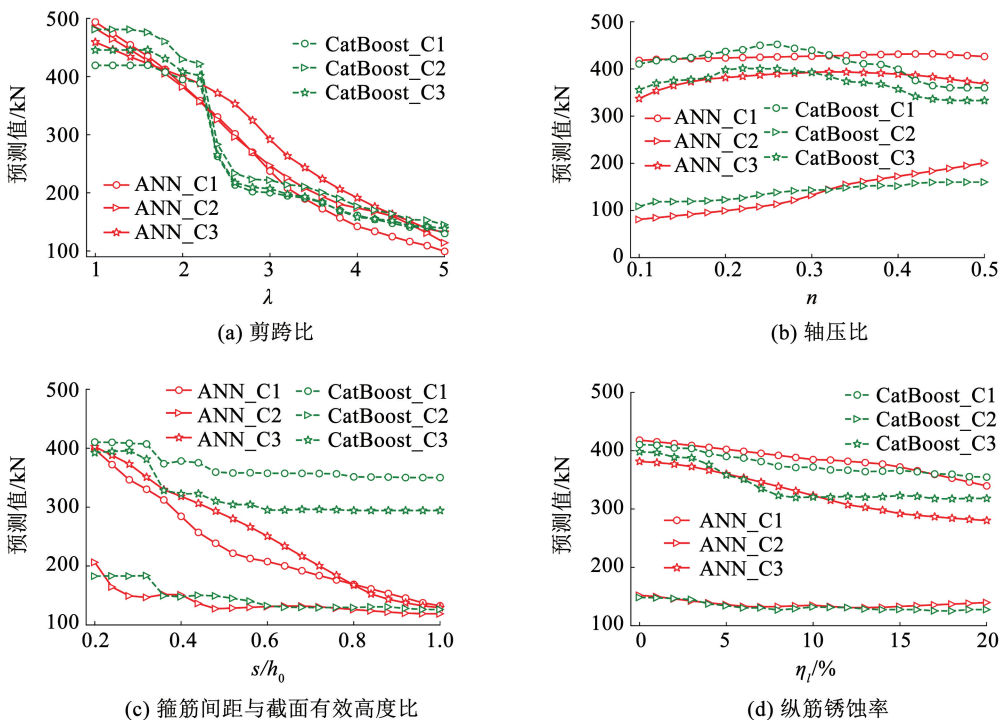


图 7 基于 ML 模型的参数敏感性分析

Fig. 7 Parameter sensitivity analysis based on ML models

(如: λ 、 n 和 s/h_0) 以及钢筋锈蚀程度对矩形 RC 柱水平抗力的影响,从数据集中随机挑选 3 根试验柱作为样本,其输入参数信息见表 5,当研究某一参数对输出结果的影响时,其余参数固定并按表中进行取值。在同一实际结构中,由于腐蚀环境(如氯离子)从外到内逐渐侵入,箍筋锈蚀程度往往大于纵筋,因此在考虑钢筋锈蚀影响时,将纵筋与箍筋锈蚀程度按照式(7)关系进行同步变化^[28]。

$$\eta_t = 1.56\eta_l^{1.16} \quad (7)$$

图 7 给出了不同输入参数对矩形 RC 柱水平抗力的影响。对于不同 RC 柱,其水平抗力预测值的变化范围及幅度有所区别,取决于 RC 柱的具体构造,但明显受 λ 影响较大,当 λ 从 1 增加到 5,RC 柱的水平抗力可降低约 65% ~ 80%;对于不同的 ML 算法,ANN 模型的预测曲线较为光滑,基本表现为持续降低或增加;而 CatBoost 模型的变化幅度相对不稳定,例如,随着 λ 和 s/h_0 的增加,其水平抗力预测值先保持不变然后突然骤降,再趋于平缓,由此说明 ANN 模型的泛化能力优于 CatBoost 模型。总体而言,RC 柱的水平抗力随着 λ 、 s/h_0 以及钢筋锈蚀率的增加呈减小趋势,而随着 n 的增加呈先增大后趋于稳定或减小趋势。

5 结 论

1) 本文所建立的 ML 模型具有较好的预测精度, 能够实现破坏模式未知条件下锈蚀矩形 RC 柱水平抗力的快速预测。

2) 神经网络模型的预测精度普遍优于集成类或其他单一类模型。其中 ANN 模型的预测效果最佳, 其预测值与试验值之比的均值和标准差分别为 1.01 和 0.14, CatBoost 和 CNN 模型的预测精度仅次于 ANN 模型, 而 RF、SVM 和 KNN 模型的精度较差。此外, 神经网络模型的泛化能力优于集成类算法。

3) 剪跨比 λ 对锈蚀矩形 RC 柱的水平抗力影响最大且较为显著, 重要性占比高达 35%; 当 λ 从 1 增加到 5, RC 柱的水平抗力可降低 65% ~ 80%。

4) 矩形 RC 柱的水平抗力随着 λ 、箍筋间距与截面有效高度比 (s/h_0) 以及钢筋锈蚀率的增加呈减小趋势, 而随着轴压比 n 的增加呈先增大后趋于稳定或减小趋势。

参 考 文 献

- [1] 李磊, 王文韬, 王卓涵, 等. 锈蚀 RC 框架柱性能劣化的模拟与评估[J]. 哈尔滨工业大学学报, 2021, 53(4): 41
LI Lei, WANG Wentao, WANG Zhuohan, et al. Modeling and evaluation of deterioration of corroded RC columns[J]. Journal of Harbin Institute of Technology, 2021, 53(4): 41. DOI: 10.11918/202008054
- [2] 杨慧, 何浩祥, 闫维明. 考虑碳化和氯离子累积效应的梁桥时变可靠度[J]. 哈尔滨工业大学学报, 2019, 51(6): 71
YANG Hui, HE Haoxiang, YAN Weiming. Time-dependent reliability analysis on reinforced concrete beam bridge considering carbonization and chloride accumulation effect[J]. Journal of Harbin Institute of Technology, 2019, 51(6): 71. DOI: 10.11918/j.issn.0367-6234.201805012
- [3] DING Zihao, ZHENG Shixiong, YU Bo. Probabilistic prediction and calibration for residual shear strength of corroded reinforced concrete columns[J]. Journal of Building Engineering, 2022, 48: 103901. DOI: 10.1016/j.job.2021.103901
- [4] 丁自豪, 桑卜久, 卢朝辉, 等. 锈蚀 RC 柱的概率抗弯承载力模型与概率校准分析[J]. 应用基础与工程科学学报, 2022, 30(6): 1468
DING Zihao, SANG Bujia, LU Zhaohui, et al. Probabilistic flexural capacity models and probabilistic calibration analysis for corroded RC columns[J]. Journal of Basic Science and Engineering, 2022, 30(6): 1468. DOI: 10.16058/j.issn.1005-0930.2022.06.012
- [5] VU N S, YU Bo, LI Bing. Prediction of strength and drift capacity of corroded reinforced concrete columns[J]. Construction and Building Materials, 2016, 115: 304. DOI: 10.1016/j.conbuildmat.2016.04.048
- [6] ZHANG Dawei, ZHAO Yuxi, JIN Weiliang, et al. Shear strengthening of corroded reinforced concrete columns using pet fiber based composites[J]. Engineering Structures, 2017, 153: 757. DOI: 10.1016/j.engstruct.2017.09.030
- [7] VU N S, LI Bing. Seismic performance assessment of corroded

- reinforced concrete short columns[J]. Journal of Structural Engineering, 2018, 144(4): 04018018. DOI: 10.1061/(ASCE)ST.1943-541X.0001994
- [8] ZHANG Yijian, DESROCHES R, TIEN I. Impact of corrosion on risk assessment of shear-critical and short lap-spliced bridges[J]. Engineering Structures, 2019, 189: 260. DOI: 10.1016/j.engstruct.2019.03.050
- [9] TRAN C T N, NGUYEN X H, NGUYEN H C, et al. Strut-and-tie model for shear capacity of corroded reinforced concrete columns[J]. Advances in Concrete Construction, 2020, 10(3): 185. DOI: 10.12989/acc.2020.10.3.185
- [10] YU Bo, DING Zihao, LIU Shengbin, et al. Theoretical and practical models for shear strength of corroded reinforced concrete columns[J]. Structural Engineering and Mechanics, 2021, 79(5): 565. DOI: 10.12989/sem.2021.79.5.565
- [11] LI Qiang, NIU Ditaio, XIAO Qianhui, et al. Experimental study on seismic behaviors of concrete columns confined by corroded stirrups and lateral strength prediction[J]. Construction and Building Materials, 2018, 162: 704. DOI: 10.1016/j.conbuildmat.2017.09.030
- [12] 邢国华, 杨成雨, 常召群, 等. 锈蚀钢筋混凝土柱的修正压-剪-弯分析模型研究[J]. 工程力学, 2019, 36(8): 87
XING Guohua, YANG Chengyu, CHANG Zhaoqun, et al. Study on modified axial-shear-flexure interaction model for corroded reinforced concrete columns[J]. Engineering Mechanics, 2019, 36(8): 87. DOI: 10.6052/j.issn.1000-4750.2018.07.0376
- [13] YU Bo, YU Zecheng, LI Bing, et al. Probabilistic classification criterion for failure modes of reinforced concrete columns[J]. Journal of Earthquake Engineering, 2022, 27(5): 1175. DOI: 10.1080/13632469.2022.2041506
- [14] NING Chaolie, FENG Decheng. Probabilistic indicator to classify the failure mode of reinforced-concrete columns[J]. Magazine of Concrete Research, 2019, 71(14): 734. DOI: 10.1680/jmacr.17.00097
- [15] THAI H T. Machine learning for structural engineering: a state-of-the-art review[J]. Structures, 2022, 38: 448. DOI: 10.1016/j.istruc.2022.02.003
- [16] 谢龙隆, 喻泽成, 余波. 基于类不平衡数据集的钢筋混凝土柱破坏模式判别方法[J]. 建筑结构学报, 2023, 44(5): 273
XIE Longlong, YU Zecheng, YU Bo. Classification method for failure modes of reinforced concrete columns based on imbalanced datasets[J]. Journal of Building Structures, 2023, 44(5): 273. DOI: 10.14006/j.jzjgxb.2021.0672
- [17] 成浩, 喻泽成, 余波. 物理规律监督的 RC 柱地震破坏模式可解释机器学习方法[J]. 建筑结构学报, 2023, 44(11): 69
CHENG Hao, YU Zecheng, YU Bo. A physics-supervised interpretable machine learning approach for seismic failure modes prediction of RC columns[J]. Journal of Building Structures, 2023, 44(11): 69. DOI: 10.14006/j.jzjgxb.2022.0370
- [18] MANGALATHU S, JEON J S. Machine learning-based failure mode recognition of circular reinforced concrete bridge columns: comparative study[J]. Journal of Structural Engineering, 2019, 145(10): 04019104. DOI: 10.1061/(ASCE)ST.1943-541X.0002402
- [19] FENG Decheng, LIU Zhentao, WANG Xiaodan, et al. Failure mode classification and bearing capacity prediction for reinforced concrete columns based on ensemble machine learning algorithm[J]. Advanced Engineering Informatics, 2020, 45: 101126. DOI: 10.1016/j.aei.2020.101126