

DOI: 10.11835/j.issn.2096-6717.2026.056



开放科学(资源服务)标识码 OSID:



基于机器学习的圆形截面锈蚀箍筋约束混凝土 峰值特征参数预测模型

张欣¹, 郑山锁¹, 李成龙¹, 阮升¹, 黄克起², 高璞²

(1. 西安建筑科技大学 土木工程学院; 结构工程与抗震教育部重点实验室, 西安 710055;

2. 中国建筑第六工程局有限公司, 天津 300171)

摘要: 现有锈蚀箍筋约束混凝土单轴受压应力-应变曲线峰值特征参数的计算模型普遍存在跨数据集泛化能力不足的问题, 严重制约了其在实际工程中的应用。基于112个圆形截面锈蚀箍筋约束混凝土柱的轴压试验数据, 以应力-应变曲线的峰值应力与峰值应变为预测目标, 采用支持向量回归(SVR)、人工神经网络(ANN)、极端梯度提升(XGBoost)、K-近邻(KNN)、类别提升(CATboost)和随机森林(RF)6种算法分别建立预测模型, 并利用SHAP方法进行可解释性分析。结果表明: SVR在峰值应力与峰值应变的预测中均表现最佳, 测试集上的决定系数(R^2)分别达到0.940和0.938。SHAP分析显示, 在考虑锈蚀对钢筋净截面积和屈服强度折减的前提下, 纵筋与箍筋锈蚀仍然对锈蚀箍筋约束混凝土的轴压力学性能产生不可忽略的附加影响。与现有经验模型对比, 建立的模型在峰值特征参数的预测精度上均优于传统模型, 展现出良好的泛化能力。

关键词: 锈蚀箍筋; 钢筋混凝土; 机器学习; 单轴受压性能; 峰值特征参数; 本构模型

中图分类号: TU375 **文献标志码:** A **文章编号:** 2096-6717(XXXX)XX-0001-12

Machine learning-based prediction models for peak characteristic parameters of circular-section corroded stirrup- confined concrete

ZHANG Xin¹, ZHENG Shansuo¹, LI Chenglong¹, RUAN Sheng¹, HUANG Keqi²,
GAO Pu²

(1. School of Civil Engineering; Key Laboratory of Structural Engineering and Earthquake Resistance, Ministry of Education, Xian University of Architecture and Technology, Xi'an 710055, P. R. China; 2. China Construction Sixth Engineering Bureau Co., Ltd., Tianjin 300171, P. R. China)

Abstract: Existing calculation models for the peak characteristic parameters of the uniaxial compressive stress-strain curve of corroded stirrup-confined concrete generally suffer from insufficient cross-dataset generalization

收稿日期: 2026-04-20

基金项目: 国家自然科学基金(52278530); 陕西省重点研发计划项目(2021ZDLSF06-10)

作者简介: 张欣(1997-), 男, 博士生, 主要从事工程结构抗震和耐久性研究, E-mail: zhangxin35710@163.com。

郑山锁(通信作者), 男, 教授, 博士生导师, E-mail: zhengshansuo@263.net。

Received: 2026-04-20

Foundation items: National Natural Science Foundation of China (No. 52278530); Key R&D Project of Shaanxi Province (No. 2021ZDLSF06-10).

Author brief: ZHANG Xin (1997-), PhD candidate, main research interest: seismic resistance and durability of engineering structures, E-mail: zhangxin35710@163.com.

ZHENG Shansuo (corresponding author), professor, doctoral supervisor, E-mail: zhengshansuo@263.net.

ability, which severely limits their application in practical engineering. To address this issue, based on 112 axial compression test data of circular-section corroded stirrup-confined concrete columns, this study takes the peak stress and peak strain of the stress-strain curve as prediction targets. Six algorithms, namely Support Vector Regression (SVR), Artificial Neural Network (ANN), eXtreme Gradient Boosting (XGBoost), K-Nearest Neighbors (KNN), Categorical Boosting (CatBoost), and Random Forest (RF), are employed to establish prediction models, and the SHAP method is utilized for interpretability analysis. The results indicate that SVR exhibits the best performance in predicting both peak stress and peak strain, achieving coefficient of determination values of 0.940 and 0.938 on the test set, respectively. SHAP analysis reveals that, under the premise of considering the reduction in net cross-sectional area and yield strength of rebars due to corrosion, corrosion of both longitudinal and stirrup rebars still exerts a non-negligible additional influence on the axial compressive mechanical properties of corroded stirrup-confined concrete. Compared with existing empirical models, the proposed model demonstrates superior prediction accuracy for peak characteristic parameters and exhibits favorable generalization ability, providing a more accurate tool for the calibration of stress-strain constitutive models of corroded stirrup-confined concrete.

Keywords: corroded stirrup; enforced concrete beams; machine learning; uniaxial compressive behavior; peak characteristic parameters; constitutive model

随着服役龄期增长,处于氯离子侵蚀环境中的钢筋混凝土(RC)结构,在高盐、高湿度或干湿交替作用下,氯离子逐渐渗透至混凝土内部,破坏碱性环境和钢筋表面钝化膜,引发钢筋锈蚀^[1-2]。锈蚀不仅导致钢筋有效截面积减少和力学性能降低,锈蚀产物的堆积和体积膨胀还会引起混凝土锈胀开裂,进而导致混凝土力学性能及钢筋-混凝土黏结性能退化,显著增加 RC 结构在地震荷载下的倒塌风险^[3-4]。

箍筋约束效应使核心区混凝土处于三轴受压应力状态,显著增强其抗压强度与变形能力^[5-6]。因而在 RC 桥梁、建筑的关键构件中得到了广泛应用。然而,箍筋约束混凝土同样面临因内部钢筋锈蚀引起的力学性能劣化问题。为准确预测锈蚀箍筋约束混凝土的单轴受压力学性能,学者提出了若干应力-应变曲线峰值特征参数预测模型。然而,文献[7]指出,现有模型普遍仅对自身试验数据精度良好,跨数据集时预测偏差显著增大,泛化能力严重不足。其根本原因在于,锈蚀箍筋约束混凝土的轴压力学性能受多个高度非线性且相互耦合的因素控制,传统解析模型难以表征上述复杂耦合效应,经验回归模型同样难以应对高维输入空间的复杂映射关系。

近年来,机器学习方法凭借其卓越的非线性映射能力,在材料力学性能预测领域展现出广阔的应用前景。Zheng 等^[8]对比了反向传播神经网络(BPNN)和支持向量回归(SVR)算法在矩形截面锈蚀箍筋约束混凝土强度退化系数预测上的性能差异,指出机器学习模型的预测精度显著高于传统经

验公式。Ju 等^[9]对比了 6 种机器学习算法在预测地聚物混凝土冻融损伤后抗压强度损失率方面的性能差异,并通过 SHAP 方法对模型进行可解释性分析。Ebrahimzadeh 等^[10]和 Mahmoudian 等^[11]同样采用可解释机器学习模型预测了 FRP/钢筋与混凝土的弯曲粘结强度。Huang 等^[12]基于机器学习方法建立了锈蚀钢筋-混凝土黏结强度预测模型。上述研究充分验证了机器学习方法在材料力学性能预测领域的有效性。然而,将机器学习方法应用于圆形截面锈蚀箍筋约束混凝土抗压性能预测的研究仍极为有限。

笔者以峰值应力和峰值应变为预测目标,基于 112 组轴压试验数据,采用 SVR、人工神经网络(ANN)、极端梯度提升(XGBoost)、K-近邻(KNN)、类别提升(CatBoost)和随机森林(RF)6 种机器学习算法建立预测模型,通过贝叶斯优化与五折交叉验证进行超参数调优,并利用 SHAP 进行可解释性分析。通过与既有经验模型对比,验证了模型具有较好的跨数据集泛化能力。

1 数据库的建立与数据分析

1.1 数据库的建立

数据收集自 Web of Science 收录的学术论文,锈蚀方法均为通电加速锈蚀^[13-17]。经过系统检索和筛选,建立了含有 112 根圆形截面锈蚀箍筋约束混凝土柱的轴心压缩试验数据库,如表 1 所示。选取 10 个输入特征,包括:箍筋锈蚀率 η'_s 、纵筋锈蚀率 η'_l 、箍筋屈服强度 f'_{yh} 、纵筋屈服强度 f'_{yl} 、体积配箍率 ρ'_v 、箍筋特征值 λ'_v 、纵筋配筋率 ρ'_{lc} 、纵筋特征值 λ'_l 、非约

束混凝土的轴心抗压强度 f_{c0} 和峰值应变 ϵ_{c0} 。输出变量为锈蚀箍筋约束混凝土的峰值强度 f_{cc}' 和峰值应变 ϵ_{cc}' 。

表 1 轴心压缩试验数据库

Table 1 Database of axial compression tests

文献	混凝土强度 f_{c0}/MPa	数量	箍筋锈蚀 率/%	纵筋锈蚀 率/%	锈蚀 模式
Liu 等 ^[13]	25.63	15	0~22.86	0~10.96	T+L
Liang 等 ^[14]	29.56~47.03	36	0~21.58	0~11.77	T+L
Vu 等 ^[15]	19.00~25.76	12	0~31.50	0	T
Zhou 等 ^[16]	15.73~27.36	39	0.4~21.74	0	T
Andisheh 等 ^[17]	30.61~32.72	10	0~40.00	0~18.00	T+L

注:锈蚀模式中“T+L”表示纵筋与箍筋共同锈蚀,“T”表示仅箍筋锈蚀。

λ_v' 和 λ_v^l 计算式分别如式(1)、式(2)所示。

$$\lambda_v' = \rho_v' f_{yh}' / f_{c0} \quad (1)$$

$$\lambda_v^l = \rho_v^l f_{yh}^l / f_{c0} \quad (2)$$

调研中发现,文献[13]中纵筋锈蚀率缺失。考虑到现有研究均采用通电加速锈蚀法对试件进行加速锈蚀,且纵筋与箍筋直径的比值接近,因此通过拟合文献[14,17]中纵筋锈蚀率与箍筋锈蚀率的对应关系对其纵筋锈蚀率进行推算。由于通电加速锈蚀时箍筋与纵筋的起锈时间接近,采用截距为零^[18]的线性函数对散点数据进行拟合,结果如式(3)所示。

$$\eta_s' = 0.479\eta_s^l \quad (R^2 = 0.98) \quad (3)$$

分别采用式(4)、式(5)对锈蚀钢筋剩余净截面积和屈服强度进行修正^[19]。

$$A_{s,corr} = (1 - \eta_{s,corr}) A_s \quad (4)$$

$$f_{yh,corr} = (1 - 1.696\eta_{s,corr}) f_{yh} \quad (5)$$

式中: $A_{s,corr}$ 和 A_s 分别为锈蚀钢筋和未锈蚀钢筋的净截面积。 $f_{yh,corr}$ 和 f_{yh} 分别为锈蚀钢筋和未锈蚀钢筋的屈服强度。 $\eta_{s,corr}$ 为锈蚀钢筋平均质量损失率。

锈蚀试件所有相关输入特征(f_{yh}^l 、 f_{yh}^l 、 ρ_v^l 、 ρ_{cc}^l 、 λ_v' 和 λ_v^l)均基于式(4)、式(5)进行了锈蚀修正。

由于不同文献混凝土强度定义不同,分别采用式(6)、式(7)将混凝土立方体抗压强度 $f_{cu,k}$ 和混凝土圆柱体轴心抗压强度 $f_{c0,c}$ 统一转换为混凝土棱柱体轴心抗压强度 f_{c0} ^[20]。

$$\text{棱柱体: } f_{c0} = 0.76f_{cu,k} \quad (6)$$

$$\text{圆柱体: } f_{c0,c} = 0.79f_{cu,k} \quad (7)$$

1.2 数据分布

图1展示了各输入特征的数据分布。其中,箍筋锈蚀率 η_s' 的中位值为11.32%,在5%~25%区间

分布较为均匀。多数研究对纵筋采取了防腐处理,因此纵筋锈蚀率 η_s' 的中位值为0.00%,而对于纵筋未作防腐处理的试件,其纵筋锈蚀率普遍不超过13%,明显低于箍筋锈蚀率,与钢筋混凝土结构实际锈蚀特征相吻合。箍筋屈服强度 f_{yh}' 和纵筋屈服强度 f_{yh}^l 的中位值分别为241.61 MPa和450.00 MPa,其中纵筋屈服强度基本符合规范一般规定,而箍筋屈服强度略低于中国规范^[20]建议取值。箍筋间距 s 的中位值为60 mm,最大箍筋间距为100 mm。箍筋体积配箍率 ρ_v' 中位值为1.50%。纵筋配筋率 ρ_{cc}^l 中位值为1.96%。箍筋特征值 λ_v' 和纵筋特征值 λ_v^l 的中位值分别为0.12和0.32。未约束混凝土轴心抗压强度 f_{c0} 的中位值为27.36 MPa,并主要分布于25.30~31.67 MPa。由于多数研究假设混凝土峰值应变 ϵ_{c0} 为0.002,因此该变量数据分布高度集中,中位值及各分位值均为0.002。整体而言,数据集中各特征变量的中位值分布基本合理、覆盖范围较为广泛,材料与配筋参数均处于工程常见取值范围内,能为锈蚀箍筋约束混凝土单轴受压力学性能研究提供具有代表性的基础数据。

1.3 相关性分析

变量间较强的相关性会增加机器学习模型过拟合风险,因此采用Pearson系数量化各变量间线性关系强弱^[21],如图2所示。Pearson系数绝对值越大表示线性关系越强,系数正、负表示正相关和负相关。对系数绝对值大于0.7,且物理意义重复的变量考虑剔除^[22]。

观察可知,多数输入特征中的Pearson系数绝对值小于0.7,表明变量间多重共线性程度较低,蕴含的信息具有较好的独立性。其中, f_{yh}' 与 η_s' 呈较强的负相关,但二者物理意义不同,不构成信息冗余,故予以保留;而 λ_v' 与 ρ_v' 均一定程度上反映箍筋的配置水平,因此对二者之一进行剔除(经后续筛选,最终剔除 λ_v')。输入特征 f_{c0} 与输出变量 f_{cc}' 之间呈较强的正相关性,表明基体材料性能对锈蚀箍筋约束混凝土抗压强度具有基础支配作用。其余输入与输出变量的Pearson系数绝对值均小于0.7,表明输入与输出变量间普遍存在非线性关系。因此采用机器学习方法对该数据集输出变量进行预测具有较好的适用性。

采用两阶段输入特征筛选策略:首先根据先验知识剔除与输出变量无物理关联的输入特征,以减少冗余信息。随后,在交叉验证框架内以模型平均精度为评价准则,进一步剔除相关性较强、信息重复且对模型精度提升无益甚至产生负向影响的输入特征。经筛选后,各输出变量对应的最终输入特




图1 输入特征变量分布

Fig. 1 Distribution of input feature variables




图2 变量间相关性系数

Fig. 2 Correlation coefficients between variables

征子集如表2所示。

表2 输出变量与输入特征子集

Table 2 Output variables and subsets of input features

输出变量	输入特征子集
f_{cc}^t	$\eta_s^t, \eta_s^v, f_{cc}^t, \rho_v^t, \rho_{cc}^t, f_{yh}^t, f_{yh}^v$
ϵ_{cc}^t	$\eta_s^t, \eta_s^v, f_{cc}^t, \rho_v^t, \rho_{cc}^t, f_{yh}^t, f_{yh}^v, \epsilon_{cc}^t$

2 机器学习模型和性能评估

2.1 机器学习模型

为了保证模型选择的客观性,首先采用6种主流机器学习算法(SVR、ANN、XGBoost、KNN、CatBoost和RF)进行建模与对比^[23-25]。鉴于篇幅,最终仅保留展示3种预测性能最优模型(SVR、ANN和XGBoost)的对比结果。SVR通过核函数将数据映射至高维空间,并引入 ϵ -不敏感损失函数,

适用于小样本非线性回归且对异常值鲁棒。ANN由输入层、隐藏层和输出层构成,通过反向传播与梯度下降训练,具备逼近任意复杂非线性函数的能力。XGBoost以决策树为基学习器,逐步拟合残差,引入L1/L2正则化控制过拟合,支持并行计算,精度高且鲁棒性强。KNN是一种非参数惰性学习算法,通过计算样本间距离,取K个最近邻的均值作为预测,原理简单但易受噪声影响。CatBoost基于梯度提升框架,能自动高效处理类别型特征,采用对称树结构防止过拟合。RF基于Bagging集成策略,对训练集自助采样后并行训练多棵决策树,取平均值作为输出,可有效降低过拟合风险,提升预测稳定性。

为评估不同机器学习模型的泛化能力,将完整数据集按8:2的比例划分为训练集与测试集,其中80%的数据用于模型训练,20%的数据用于性能测试。为保证训练结果的可重复性和模型对比的公平性,在数据划分过程中固定随机种子。基于相同的训练集对各机器学习模型进行训练,并在统一的测试集上对其预测性能进行系统评估。

2.2 评估指标

选取6个评价指标对模型准确性进行全面评估和比较:决定系数(R^2),均方根误差(RMSE),平均绝对误差(MAE),相对绝对误差(RAE),回归相对标准误差(RSR)以及方差解释(VAF)。其中, R^2 、RMSE和MAE是广泛应用的基础评价指标,在评估模型时具有优先参考性。RAE和RSR是无量纲的标准化误差指标,主要用于表征预测误差相对于观测数据变异性的相对大小,其值越小表明模型预测性能越优。VAF则以百分比形式反映模型对观

测数据方差的解释程度,取值越高说明模型预测效果越好。上述指标从不同维度互为补充,为评估模型的准确性与稳定性提供了多重视角。各指标的具体计算式如式(8)~式(13)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{test}^i - y_{pred}^i)^2}{\sum_{i=1}^n (y_{test}^i - \bar{y}_{test})^2} \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{test}^i - y_{pred}^i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{test}^i - y_{pred}^i| \quad (10)$$

$$RAE = \frac{\sum_{i=1}^n |y_{test}^i - y_{pred}^i|}{\sum_{i=1}^n |y_{test}^i - \bar{y}_{test}|} \quad (11)$$

$$RSR = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_{test}^i - y_{pred}^i)^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_{test}^i - \bar{y}_{test})^2}} \quad (12)$$

$$VAF = \left(1 - \frac{Var(y - \hat{y})}{Var(y)} \right) \times 100 \quad (13)$$

式中: y_{test}^i 和 y_{pred}^i 分别为因变量的试验值和模型预测值, $\bar{y}_{test}$ 为因变量的试验平均值。

超参数调整是模型优化的关键环节,通过合理的超参数优化,可显著提升模型的预测能力。为此,采用贝叶斯优化器在预定义的参数空间内自动搜索最佳超参数组合,并在优化过程中结合5折交叉验证以防止过拟合。经贝叶斯优化得到的各机器学习模型对不同输出变量的最优超参数如表3所示。

表3 各机器学习模型的最优超参数

Table 3 Optimal hyperparameters for each machine learning model

输出变量	机器学习模型	关键超参数和最优值
f_{cc}'	SVR	正则化参数 C : 94.047 20; 损伤函数带宽 ϵ : $1.690\ 18 \times 10^{-3}$; 径向基核函数参数 γ : 0.090 129; 核函数类型: rbf; 随机种子: 42
	ANN	隐藏层神经元数量 h : 17; 激活函数类型: relu; 优化算法: lbfgs; L2 正则化系数 α : 12.921 41; 最大迭代次数: 2000; 随机种子: 42
	XGBoost	基学习器数量 T : 148; 最大树深度 d_{max} : 2; 学习率 η : 0.098 858; 样本子采样比例: 0.708 86; 特征子采样比例(每棵树): 0.737 77; L1 正则化系数 α : 7.779 19; L1 正则化系数 λ : 11.814 61; 随机种子: 42
ϵ_{cc}'	SVR	正则化参数 C : 97.482 00; 损伤函数带宽 ϵ : $3.226\ 36 \times 10^{-3}$; 径向基核函数参数 γ : 0.195 56; 核函数类型: rbf; 随机种子: 42
	ANN	隐藏层神经元数量 h : 15; 激活函数: tanh; 优化算法: lbfgs; L2 正则化系数 α : 14.465 66; 最大迭代次数: 2000; 随机种子: 42
	XGBoost	基学习器数量 T : 98; 最大树深度 d_{max} : 2; 学习率 η : 0.095 773; 样本子采样比例: 0.680 03; 特征子采样比例(每棵树): 0.754 70; L1 正则化系数 α : 9.999 71; L1 正则化系数 λ : 10.529 30; 随机种子数: 42


2.3 模型性能对比

不同输出变量在3种最优机器学习模型下的训练集和测试集的散点分布如图3、图4所示。观察可知,不同机器学习模型对峰值应力和峰值应变的预测精度存在显著差异。各机器学习模型对峰值应力均表现出较高的预测精度,散点数据基本分布于 $\pm 20\%$ 误差线以内,其中SVR和ANN在训练集和测试集上的 R^2 均大于0.91,展现出优异的预测性能。而XGBoost虽然在训练集上的 R^2 达到了0.95,但测试集上的 R^2 仅有0.88,表明其存在一定程度的过拟合现象;对于峰值应变而言,SVR和ANN同样表现优异,训练集和测试集上的 R^2 均大于0.92。相比之下,XGBoost在训练集上的 R^2 为0.92,而在测试集上的 R^2 仍然相对较低,仅为0.87,同样表现出过拟合倾向,预测性能相对较差。


为进一步对比不同机器学习模型预测性能的差异,图5展示了各机器学习模型在峰值应力和峰值应变两个数据集上的绝对误差分布情况。对于

峰值应力而言,SVR、ANN和XGBoost模型在四分位距(25%~75%)范围内的绝对误差分别集中于 $[-0.86, 0.96]$ 、 $[-1.52, 1.46]$ 和 $[-1.79, 1.29]$,误差均值分别为-0.12、-0.18和-0.30。可见SVR模型的误差波动范围与绝对误差均值均显著小于其他机器学习模型;对于峰值应变而言,四分位距范围内的绝对误差分别集中于 $[-1.66 \times 10^{-4}, 1.05 \times 10^{-4}]$ 、 $[-2.17 \times 10^{-4}, 1.97 \times 10^{-4}]$ 和 $[-3.02 \times 10^{-4}, 2.79 \times 10^{-4}]$,误差均值分别为 -9.30×10^{-6} 、 -9.51×10^{-7} 和 1.00×10^{-5} 。可见SVR模型的误差波动范围仍然显著低于其他机器学习模型,而ANN模型具有最小的绝对误差均值。


通过蛛网图可全面评估各模型在6项指标上的预测性能。图中指标连线越靠近中心,模型表现越优。如图6(a)、(b)所示,在峰值应力训练集和测试集中,SVR模型各指标连线均最接近中心,表现出最优的预测性能,而XGBoost模型在训练集的各指标连线仅次于SVR,但其测试集的各指标连线则显



(a) SVR



(b) ANN




(c) XGBoost


图3 各机器学习模型对峰值应力预测结果对比

Fig. 3 Comparison of peak stress prediction results across different machine learning models


著偏离中心,这说明其对峰值应力的预测性能较差;如图6(c)、(d)所示,在峰值应变训练集和测试集中,SVR各指标连线仍然最接近中心位置,表明其对峰值应变仍然具有最好的预测性能。ANN各指标连线仅次于SVR,而XGBoost模型的各指标连线则显著偏离中心,表明其对峰值应变的预测性能仍然较差。为进一步评估模型稳定性与泛化能力,采用十次五折交叉验证计算测试集各评估指标均值,结果如表4所示。综合来看,SVR对于峰值应力和峰值应变均表现出最佳的预测性能和稳定性。这是因为本文数据集属于小样本,而SVR遵循结构风险最小化原则,在最小化训练误差的同时主动控



(a) SVR



(b) ANN



(c) XGBoost

图4 各机器学习模型对峰值应变预测结果对比

Fig. 4 Comparison of peak strain prediction results across different machine learning models

制模型复杂度,从而有效抑制过拟合。同时其决策函数仅由少数支持向量决定,对数据中的噪声和异常值不敏感,结合核函数可灵活拟合非线性关系,且 ϵ 不敏感损失函数进一步增强了模型的鲁棒性,使SVR在有限样本下仍能获得良好的泛化性能。因此在后续研究与分析中,选取SVR作为最优预测模型,并进行后续对比与模型可解释性分析。

3 模型可解释性分析

为避免“黑箱”模型所带来的可解释性不足问题,采用SHAP方法对最优机器学习模型各输入特征的重要性进行量化分析^[26-27]。




图5 各机器学习模型输出变量绝对误差对比

Fig. 5 Comparison of absolute errors in the output variables of each machine learning model




图6 各机器学习模型训练集和测试集的评估指标蛛网图

Fig. 6 Spider chart of evaluation metrics for the training and testing sets of various ML models

峰值应力 f'_{cc} 和峰值应变 ϵ'_{cc} 所有输入特征的平均绝对 SHAP 值如图 7 所示。观察可知,对于 f'_{cc} ,各因素重要性排序为: f_{c0} 、 ρ'_v 、 ρ'_{cc} 、 f'_{yh} 、 f'_{yh} 、 η'_s 和 η'_s 。其中, f_{c0} 占主导地位,贡献了 43.8%,表明基体材料强度是决定锈蚀箍筋约束混凝土峰值应力的关键,而 ρ'_v 贡献仅次其后,表明箍筋约束效应对提升混凝土强度具有重要作用;对于 ϵ'_{cc} ,各因素的重要性排序为:

ρ'_{cc} 、 f'_{yh} 、 η'_s 、 f_{c0} 、 η'_s 、 ρ'_v 、 f'_{yh} 和 ϵ_{c0} 。其中, ρ'_{cc} 的影响最为显著,贡献约为 32.4%,而 ϵ_{c0} 贡献仅为 4.8%,主要原因在于既有研究中的试件所采用的 ϵ_{c0} 值高度集中在 0.002 附近,数据变异性较小,从而降低了该因素在 SHAP 分析中的相对重要性^[9]。此外,在考虑锈蚀对钢筋截面积与强度的折减后, η'_s 与 η'_s 仍然对 f'_{cc} 和 ϵ'_{cc} 产生不同程度影响。这表明,仅通过理论推导

表 4 不同机器学习模型对峰值强度的预测精度对比

Table 4 Comparison of prediction accuracy for peak stress among different machine learning models

输出变量	机器学习模型	R^2	RMSE	VAF	MAE	RAE	RSR
f_{cc}^l	SVR	0.871	3.200	88.425	2.425	0.344	0.353
	ANN	0.870	3.223	88.187	2.537	0.361	0.355
	XGBoost	0.827	3.692	83.937	3.026	0.431	0.410
ϵ_{cc}^l	SVR	0.822	8.593×10^{-4}	83.777	5.782×10^{-4}	0.344	0.403
	ANN	0.818	8.461×10^{-4}	83.100	5.920×10^{-4}	0.362	0.407
	XGBoost	0.767	9.917×10^{-4}	78.488	7.088×10^{-4}	0.425	0.466

难以精确预测锈蚀箍筋约束混凝土的力学性能变化,并且应同时考虑箍筋与纵筋锈蚀对锈蚀箍筋约束混凝土轴压力学性能的影响。





图 7 各输出变量重要性分析


Fig. 7 Analysis of the importance of output variables

为进一步明晰各输入特征对输出变量的影响方向,绘制了各输入特征的 SHAP 值蜂群图,如图 8 所示。在 SHAP 蜂群图中,每个点代表一个样本,横坐标为该变量的 SHAP 值,正值表示正向影响,负值则相反,绝对值越大表示影响程度越显著。点的颜色表示该样本中对应特征变量的实际取值,由蓝色至红色表示变量值从小到大的递增。

由图 8(a)可见, f_{c0} 和 ρ_v^l 的分布范围较宽,凸显了其对于输出结果的重要影响。 f_{c0} 、 ρ_v^l 和 f_{yh}^l 的高值均对应了较大的 SHAP 值,表明其对峰值应力 f_{cc}^l 均具有正向影响。因此,增强基体材料强度和核心区混凝土的约束效应将显著提升锈蚀箍筋约束混凝土的抗压强度。而 ρ_{cc}^l 、 f_{yh}^t 、 η_s^l 和 η_s^t 的高值则对应了较低



(a) 峰值应力



(b) 峰值应变

图 8 各输入特征的 SHAP 值蜂群图

Fig. 8 Swarm plot of SHAP values for each input feature

的 SHAP 值,表明这些因素对 f_{cc}^l 均具有负向影响。其中, ρ_{cc}^l 和 f_{yh}^t 对 f_{cc}^l 产生负向影响的原因主要有两方面:首先,既有研究^[13-17]在将荷载-位移曲线转换为应力-应变曲线的过程中,通常未对核心区内纵筋所占面积进行折减,导致配筋率越高,钢筋截面面积占比越大,由此计算得到的 f_{cc}^l 相对越小。其次,高配筋率或高强度纵筋在受压时会加剧与核心混凝土之间的横向变形不协调(泊松比差异),部分抵消箍筋的向内约束效应,从而进一步降低 f_{cc}^l 。 η_s^l 和 η_s^t 对 f_{cc}^l 具有负向影响说明除锈蚀导致的钢筋截面面积减小和屈服强度降低外,钢筋应力集中、混凝土截面损伤以及钢筋-混凝土界面黏结性能退化同样对 f_{cc}^l 产生削弱作用。

由图 8(b)可见, ρ_{cc}^l 、 f_{c0} 、 η_s^l 和 f_{yh}^l 的高值对应了较

低的 SHAP 值,表明其对峰值应变 ϵ'_{cc} 均具有负向影响。而 f'_{yh} 、 η'_s 、 ρ'_v 和 ϵ_{c0} 的高值则对应了较高的 SHAP 值,表明其对 ϵ'_{cc} 均具有正向影响。这说明基体材料变形能力和约束效应是提升 ϵ'_{cc} 的关键,而纵筋配置增强则会导致 ϵ'_{cc} 降低,其原因与纵筋配置提升导致的峰值应力降低一致。此外,箍筋锈蚀导致约束效应退化,进而造成峰值应变减小,目前学界对此已基本形成共识。然而,部分纵筋与箍筋共同锈蚀试件的试验结果^[13,28-29]显示,内部钢筋锈蚀反而会导致峰值应变延后。由于目前对此现象尚无统一论,SHAP 分析所显示的 η'_s 与 ϵ'_{cc} 之间的正相关关系尚无法基于先验知识进行有效判断,有待进一步研究。

4 机器学习模型与既有模型对比

现有圆形截面锈蚀箍筋约束混凝土峰值应力与峰值应变预测模型如表 5 所示。由表 5 可见,现有研究普遍以 Mander 完好箍筋约束混凝土峰值特征参数计算公式为基础,通过引入修正项来考虑钢筋锈蚀的影响。然而,不同计算模型修正项差异显著,考虑的影响因素普遍较少,并且忽略了纵筋锈

蚀的影响,可能导致计算结果出现显著不同。

为了对比各传统模型,以及传统模型与机器学习模型预测结果的精度差异,收集来自不同文献^[14-15]的 48 个(L1~L36, CL0~CS3)锈蚀箍筋约束混凝土试件数据作为算例。两组试件均涵盖了不同的锈蚀程度、箍筋配置和混凝土强度,且峰值特征参数差异显著,具备良好的代表性。分别采用最优机器学习模型与传统模型对其峰值应力与峰值应变进行预测与计算,结果如图 9、图 10 所示。由图 9、图 10 可以看出,传统模型对于峰值应力的预测精度相对较高,且不同模型之间的差异相对较小。而不同模型对于峰值应变的预测精度差异十分显著。其中,Liang 等的模型^[14]对 L1~L36 试件预测精度最高,而 Vu 等的模型^[15]、余波等的模型^[30]和陶伯雄的模型^[31]则对 CL0~CS3 试件展现出最好的预测精度。当对不同模型进行交叉验证时,其预测精度普遍下降显著。表明既有模型通常仅在自身依据的试验数据范围内具备良好的预测精度,普适性严重不足。相比之下,机器学习模型在峰值应力和峰值应变的预测精度上均优于传统模型,且在不同来源的试验数据上均保持较高的预测准确性,展现出良好的泛化能力。

表 5 圆形截面锈蚀箍筋约束混凝土峰值特征参数预测模型

Table 5 Prediction model for peak characteristic parameters of circular-section corroded stirrup-confined concrete

编号	文献	峰值应力	峰值应变
1	Liang 等 ^[14]	$f'_{cc} = (1 - 0.008\eta_s) f_{co} \left(-1.254 + 2.254 \sqrt{1 + \frac{7.94f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} \right)$	$\epsilon'_{cc} = (1 - 0.011\eta_s) \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
2	Vu 等 ^[15]	$f'_{cc} = (1 - 0.51\eta_s) f_{co} \left(-1.254 + 2.254 \sqrt{1 + \frac{7.94f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} \right)$	$\epsilon'_{cc} = (1 - 0.28\eta_s) \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
3	余波等 ^[30]	$f'_{cc} = f_{co} \left(-5.19 + 6.20 \sqrt{1 + \frac{2.25f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} \right)$	$\epsilon'_{cc} = (1 - 1.915\eta_s) \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
4	陶伯雄 ^[31]	$f'_{cc} = (1 - 0.658\eta_s) f_{co} \left(-1.254 + 2.254 \sqrt{1 + \frac{7.94f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} \right)$	$\epsilon'_{cc} = (1 - 1.915\eta_s) \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
5	Zhou 等 ^[16]	$f'_{cc} = \left[1 - \left(12.88 \frac{f'_l}{f_{co}} \right)^{2.7} \eta_s \right] f_{co} \left(-1.254 + 2.254 \sqrt{1 + \frac{7.94f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} \right)$	$\epsilon'_{cc} = \left[1 - \left(18.67 \frac{f'_l}{f_{co}} \right)^{3.14} \eta_s \right] \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
6	Andisheh 等 ^[17]	$f'_{cc} = f_{co} \left(2.254 \sqrt{1 + \frac{7.94f'_l}{f_{co}}} - 2\frac{f'_l}{f_{co}} - 1.254 \right)$	$\epsilon'_{cc} = 0.002 \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$
7	Liu 等 ^[13]	$f'_{cc} = f_{co} \left(\begin{aligned} &-1.254 + 2.254 \sqrt{1 + 3.97k_e(1 - \eta_s)(1 - 1.007\eta_s)\lambda_t} \\ &- k_e(1 - \eta_s)(1 - 1.007\eta_s)\lambda_t \end{aligned} \right)$	$\epsilon'_{cc} = (0.995 + 0.0044\eta_s) \epsilon_{co} \left[1 + 5 \left(\frac{f'_{cc}}{f_{co}} - 1 \right) \right]$


注: η_s 为箍筋锈蚀率; f'_l 和 f_{lc} 分别为未锈蚀箍筋的有效侧向围压和锈蚀箍筋的有效侧向围压,参考文献[15]计算; k_e 为有效约束系数,参考文献[5-6]计算; λ_t 为配箍率特征值,采用式(1)计算; ρ_v 为体积配箍率。

5 结论


基于 112 组圆形截面锈蚀箍筋约束混凝土柱的轴压试验数据,采用 SVR、ANN、XGBoost、KNN、CatBoost 和 RF 六种机器学习算法建立了峰值应力

与峰值应变预测模型,通过贝叶斯优化与五折交叉验证进行超参数调优,并结合 SHAP 方法进行可解释性分析,得到以下主要结论:

1) 在 6 种机器学习算法中,SVR 对锈蚀箍筋约



(a) 峰值应力对比



(b) 峰值应变对比

图9 各公式/机器学习模型与文献[14]中算例对比


Fig. 9 Comparison of various formulas/ML models with the examples in Reference [14]

束混凝土峰值应力与峰值应变具有最优的预测性能,测试集上的决定系数(R^2)分别为 0.940 和 0.938。


2)在已考虑锈蚀导致钢筋净截面减小及屈服强度折减的前提下,纵筋与箍筋的锈蚀仍对峰值应力与峰值应变产生不可忽略的附加影响,表明仅凭理论推导难以精确预测锈蚀箍筋约束混凝土的力学性能退化规律,并应同时考虑纵筋与箍筋锈蚀的影响。

3)对比结果表明,传统公式仅在自身试验数据范围内保持较好的预测精度,跨数据集时误差显著增大;而机器学习模型在峰值应力与峰值应变的预测精度上均优于传统公式,并有效克服了传统经验公式泛化能力严重不足的缺陷,可为锈蚀箍筋约束混凝土的应力-应变本构模型修正提供一种泛化能力更强的预测工具。

4)鉴于试验数据有限,构建的机器学习预测模型优先推荐用于训练数据所覆盖的参数范围。后



(a) 峰值应力对比



(b) 峰值应变对比

图10 各公式/机器学习模型与文献[15]中算例对比

Fig. 10 Comparison of various formulas/ML models with the examples in Reference [15]

续研究中,可通过进一步扩展数据库,来提升模型的适用范围与预测可靠性。

参考文献

- [1] Feng W P, Tarakbay A, Ali Memon S, et al. Methods of accelerating chloride-induced corrosion in steel-reinforced concrete: a comparative review[J]. Construction and Building Materials, 2021, 289: 123165.
- [2] Zhu Y Y, Rui Y, Zhu H H, et al. The effect mechanism of chloride ion concentration on the damage deterioration of reinforced concrete under electric field accelerated corrosion[J]. Journal of Building Engineering, 2026, 123: 115848.
- [3] Yang L, Zheng S S, Zheng Y, et al. Seismic capability assessment of in-service reinforced concrete shear wall structures considering corrosion: methodology and case analysis[J]. Journal of Building Engineering, 2025, 111: 113267.
- [4] Li Y H, Zheng S S, Dong L G, et al. Seismic capacity evaluation of corroded reinforced concrete frame struc-

- tures[J]. Archives of Civil and Mechanical Engineering, 2024, 25(1): 21.
- [5] Mander J B, Priestley M J N, Park R. Theoretical stress-strain model for confined concrete[J]. Journal of Structural Engineering, 1988, 114(8): 1804-1826.
- [6] Mander J B, Priestley M J N, Park R. Observed stress-strain behavior of confined concrete[J]. Journal of Structural Engineering, 1988, 114(8): 1827-1849.
- [7] Zhang X, Zheng S S, Ruan S, et al. State-of-the-art review on the uniaxial compressive properties of corroded stirrup-confined concrete[J]. Journal of Building Engineering, 2025, 112: 113854.
- [8] Zheng N H, Zhang W P, Zhou Y, et al. Confinement strength prediction of corroded rectangular concrete columns using BP neural networks and support vector regression[J]. Structures, 2024, 67: 107021.
- [9] Ju C B, Xu X, Wang Q, et al. Prediction of compressive strength loss rate in geopolymer composites under freeze-thaw cycles via machine learning[J]. Construction and Building Materials, 2026, 519: 145929.
- [10] Ebrahimzadeh M, Mahmoudian A, Tajik N, et al. Interpretable machine learning models for predicting flexural bond strength between FRP/steel bars and concrete[J]. Structures, 2025, 74: 108587.
- [11] Mahmoudian A, Bypour M, Kioumars M. Explainable boosting machine learning for predicting bond strength of FRP rebars in ultra high-performance concrete[J]. Computation, 2024, 12(10): 202.
- [12] Huang T, Wan C F, Liu T B, et al. Degradation law of bond strength of reinforced concrete with corrosion-induced cracks and machine learning prediction model[J]. Journal of Building Engineering, 2024, 98: 111022.
- [13] Liu J F, Sun Y, Gu Y, et al. Study on the constitutive relationship of core concrete in reinforced concrete circular columns considering stirrup corrosion[J]. Structures, 2025, 82: 110497.
- [14] Liang Z T, Zheng S S, Shang Z G, et al. Examination of the stress-strain model for confined concrete considering the impact of corroded spiral bars[J]. Journal of Building Engineering, 2024, 95: 109969.
- [15] Vu N S, Yu B, Li B. Stress-strain model for confined concrete with corroded transverse reinforcement[J]. Engineering Structures, 2017, 151: 472-487.
- [16] Zhou H J, Zhong Z H, Liu J, et al. Experimental and theoretical study on the mechanical behavior of concrete confined by corroded stirrups[J]. Materials and Structures, 2022, 55(3): 108.
- [17] Andisheh K, Scott A, Palermo A. Effects of corrosion on stress - strain behavior of confined concrete[J]. Journal of Structural Engineering, 2021, 147(7): 04021087.
- [18] 代旷宇. 锈蚀钢筋混凝土柱及框架结构抗震性能与地震易损性研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- Dai K Y. Seismic performance and fragility analysis of corroded reinforced concrete columns and frame structures[D]. Harbin: Harbin Institute of Technology, 2021. (in Chinese)
- [19] 李亚辉, 郑山锁, 董立国, 等. 非均匀锈蚀钢筋拉伸性能试验与模拟[J]. 建筑材料学报, 2022, 25(9): 991-998.
- Li Y H, Zheng S S, Dong L G, et al. Tensile properties test and simulation of non-uniform corroded reinforcement[J]. Journal of Building Materials, 2022, 25(9): 991-998. (in Chinese)
- [20] GB/T 50010—2010 混凝土结构设计标准[S].
- GB/T 50010—2010 Code for design of concrete structures[S]. (in Chinese)
- [21] Jomthanachai S, Wong W P, Khaw K W. An application of machine learning regression to feature selection: a study of logistics performance and economic attribute[J]. Neural Computing and Applications, 2022, 34(18): 15781-15805.
- [22] 陈柳灼, 邱羿志, 周炎. 基于深度神经网络的锈蚀 RC 梁位移角限值与破坏模式多目标预测方法[J/OL]. 工程力学. <https://link.cnki.net/urlid/11.2595.o3.20241014.0945.004>.
- Chen L Z, Qiu Y Z, Zhou Y. Deep neural network-aided multi-objective prediction method for drift ratio limits and failure mode of corroded RC beam[J/OL]. Engineering Mechanics. <https://link.cnki.net/urlid/11.2595.o3.20241014.0945.004>(in Chinese).
- [23] Wu J R, Wang Y G. A working likelihood approach to support vector regression with a data-driven insensitivity parameter[J]. International Journal of Machine Learning and Cybernetics, 2023, 14(3): 929-945.
- [24] Gao T, Zhao Z W, Gao H, et al. Axial capacity of GFRP - concrete - steel composite columns and prediction based on artificial neural network[J]. Mechanics of Advanced Materials and Structures, 2024, 31(26): 7714-7729.
- [25] Sagi O, Rokach L. Ensemble learning: a survey[J]. WIREs Data Mining and Knowledge Discovery, 2018, 8(4): e1249.
- [26] Xu R T, Chen Z P, Liu X M. Prediction and optimization of compressive strength of carbonated cement-based materials using machine learning[J]. Engineering Applications of Artificial Intelligence, 2026, 173: 114441.
- [27] Jiang C M, Chen G, Li S X, et al. Machine learning-aided prediction and genetic algorithm optimization of sulfate resistance in Portland cement-based materials[J]. Construction and Building Materials, 2025, 494: 143334.
- [28] 郑山锁, 郑跃, 董立国, 等. 近海环境下锈蚀箍筋约束混凝土本构模型[J]. 浙江大学学报(工学版), 2020, 54

- (1): 48-55, 72.
- Zheng S S, Zheng Y, Dong L G, et al. Constitutive model of confined concrete by corroded stirrups in coastal environment[J]. Journal of Zhejiang University (Engineering Science), 2020, 54(1): 48-55, 72. (in Chinese)
- [29] 郑跃, 郑山锁, 明铭, 等. 酸雨侵蚀箍筋约束混凝土本构模型研究[J]. 湖南大学学报(自然科学版), 2021, 48(1): 135-143.
- Zheng Y, Zheng S S, Ming M, et al. Research on constitutive model of confined concrete with stirrups by acid rain erosion[J]. Journal of Hunan University (Natural Sciences), 2021, 48(1): 135-143. (in Chinese)
- [30] 余波, 秦成辉, 陶伯雄. 锈蚀箍筋约束混凝土的单轴受压试验与本构关系模型[J]. 防灾减灾工程学报, 2021, 41(3): 511-519, 548.
- Yu B, Qin C H, Tao B X. Uniaxial compression experiment and constitutive model for concrete confined by corroded hoops[J]. Journal of Disaster Prevention and Mitigation Engineering, 2021, 41(3): 511-519, 548. (in Chinese)
- [31] 陶伯雄. 混凝土的单轴受压随机本构关系模型研究[D]. 南宁: 广西大学, 2017.
- Tao B X. Study on stochastic constitutive model of concrete under uniaxial compression[D]. Nanning: Guangxi University, 2017. (in Chinese)
- (编辑 XXX)