

# 基于可解释机器学习的锈蚀 RC 构件抗剪承载力预测模型

戴理朝<sup>1,2</sup>, 王冲<sup>1</sup>, 袁平<sup>1</sup>, 王磊<sup>1</sup>

(1. 长沙理工大学 土木工程学院, 长沙 410114; 2. 长沙理工大学 南方地区桥梁长期性能提升技术国家地方联合工程实验室, 长沙 410114)

**摘要:** 基于机理方法推导的锈蚀钢筋混凝土 (RC) 构件抗剪承载力模型通常引入一系列假定与修正系数, 导致计算结果精度不高和适用性有限。本文基于数据驱动, 考虑黑箱模型的可信度与输入特征的合理性, 选择锈蚀 RC 构件的几何尺寸、纵筋配筋率、箍筋屈服强度、箍筋锈蚀率、混凝土强度等关键基本特征, 建立了基于可解释机器学习算法的实用模型。结果表明, 所有基本特征中锈蚀率、有效高度、剪跨比与梁宽对抗剪承载力较为敏感; 本预测模型阐明了锈蚀 RC 构件关键基本参数与抗剪承载力间显性映射关系, 相较于经验模型与黑箱模型, 它具有较高的透明度与预测精度。

**关键词:** 土木工程; RC 构件; 锈蚀; 抗剪承载力; 可解释机器学习; 特征选择

**中图分类号:** TU375.1 **文献标志码:** A **文章编号:** 1671-5497(2024)11-3231-13

**DOI:** 10.13229/j.cnki.jdxbgxb.20230024

## Prediction model for shear capacity of corroded RC beams based on interpretable machine learning

DAI Li-zhao<sup>1,2</sup>, WANG Chong<sup>1</sup>, YUAN Ping<sup>1</sup>, WANG Lei<sup>1</sup>

(1. School of Civil Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. National-Local Joint Laboratory of Engineering Technology for Long-term Performance Enhancement of Bridges in Southern District, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract:** The prediction model for shear capacity of corroded reinforced concrete (RC) beams based on the mechanism method usually introduces a series of assumptions and correction coefficients, resulting in low accuracy of calculation results and limited applicability. In the present study, based on the data drive, considering the reliability of the black box model and the rationality of the input features, the key basic characteristics of the corroded RC beams, such as geometric dimensions, longitudinal reinforcement ratio, stirrup yield strength, stirrup corrosion loss, and concrete strength, were selected. A practical model of

**收稿日期:** 2023-01-03.

**基金项目:** 国家重点研发计划项目 (2021YFB2600900); 国家自然科学基金项目 (52278140, 52008035); 湖南省自然科学基金项目 (2020JJ1006, 2021JJ40574); 南方地区桥梁长期性能提升技术国家地方联合工程实验室 (长沙理工大学) 项目 (22KE02); 长沙理工大学专业学位研究生实践创新与创业能力提升项目 (SJCX202123).

**作者简介:** 戴理朝 (1989-), 男, 副教授, 博士. 研究方向: 桥梁耐久性. E-mail: lizhaod@csust.edu.cn

**通信作者:** 王磊 (1979-), 男, 教授, 博士. 研究方向: 桥梁耐久性与可靠度. E-mail: leiwang@csust.edu.cn

shear capacity based on an interpretable machine learning algorithm was established. The results show that the corrosion loss, effective height, shear-to-span ratio and beam width are sensitive to the structural shear capacity. The practical model of shear capacity of corroded RC beams based on the data-driven can reveal the underlying mapping relationship between the basic features and the shear capacity. The proposed model have good applicability and prediction accuracy compared with the empirical model and black box model.

**Key words:** civil engineering; RC beams; corrosion; shear capacity; interpretability machine learning; feature selection

## 0 引言

钢筋混凝土(RC)构件在剪力和弯矩共同作用下,可能会沿斜截面发生剪切破坏。此外,在自然环境侵蚀作用下,RC构件内部钢筋会发生锈蚀<sup>[1]</sup>。锈蚀会降低RC构件的力学性能,导致其破坏模式从弯曲破坏演变为剪切破坏<sup>[2,3]</sup>。准确预测锈蚀RC构件抗剪承载力对保障其服役安全具有重要意义。

锈蚀RC构件抗剪承载力与剪跨比、混凝土抗压强度、纵向受拉钢筋配筋率、箍筋强度等设计参数<sup>[4,5]</sup>有关,同时也受锈蚀引起的材料力学性能劣化、保护层开裂、粘结性能退化等因素的影响<sup>[6,7]</sup>,合理准确地预测锈蚀RC构件抗剪承载力是当下研究的热点和难点。目前,国内外学者基于机理驱动对RC构件抗剪承载力进行了分析。理论模型方面,一些学者基于极限平衡理论<sup>[8]</sup>、“桁架—拱”理论<sup>[4]</sup>、等效桁架理论<sup>[9]</sup>等建立了锈蚀RC梁抗剪承载力计算模型。经验公式方面,一些学者基于试验数据拟合得到RC梁抗剪承载力表达式<sup>[1,10]</sup>。数值模拟方面,金浏等<sup>[11]</sup>考虑不同的混凝土塑性-损伤本构模型、混凝土细观组成的非均质性等因素的影响,进一步阐明了RC梁的抗剪机理。基于机理驱动的计算模型常会引入一系列假定和简化,导致预测精度不高与适用范围受限等问题。

基于机器学习的数据驱动方法可以从已有试验数据中精确挖掘出物理量间潜在的演变规律,已应用于混凝土结构失效模式及承载力预测。Huang等<sup>[12]</sup>通过多种机器学习方法对填充墙框架的破坏模式进行预测;Mangalathu等<sup>[13-15]</sup>通过机器学习技术,对RC梁柱节点破坏模式<sup>[13]</sup>、RC桥墩失效模式<sup>[14]</sup>、桥梁抗震性能的临界不确定性参数<sup>[15]</sup>等进行预测;Feng等<sup>[16]</sup>采用机器学习方法对

RC柱的破坏模式与承载力及锈蚀RC梁时变抗剪承载力<sup>[17]</sup>进行预测;Nguyen等<sup>[18]</sup>采用多种机器学习算法建立了锈蚀RC梁的抗剪承载力模型;Hoang等<sup>[19]</sup>利用元启发式最小二乘支持向量回归模型预测锈蚀钢筋和混凝土间的极限粘结强度。尽管上述研究展现了机器学习方法在结构性能预测方面的优势,可根据输入参数给出准确的预测结果,却难以阐明两者间复杂的非线性关系,无法对锈蚀机理作出合理解释。

可解释机器学习模型不仅能够提高其可信度与扩大应用范围,还可以阐明输入关键参数与结构响应间的底层映射关系。近年来,一些可解释性模型被提出用于解决机器学习模型黑箱问题,其中,SHapley Additive ExPlanations(SHAP)<sup>[20]</sup>方法和Genetic programming(GP)<sup>[21]</sup>方法已初步应用于土木领域。Mangalathu等<sup>[22]</sup>利用SHAP方法对RC构件的失效模式进行了分析。冯德成等<sup>[23]</sup>基于SHAP方法对钢筋混凝土矮墙承载力进行了分析。Chaabene等<sup>[24]</sup>利用置换特征重要性(PFI)筛选出4个重要参数,基于GP与这些参数建立了纤维混凝土梁抗剪承载力预测方程。Gandomi等<sup>[25]</sup>利用模拟退火算法优化了GP符号演变过程,开发了RC结构深梁抗剪承载力经验模型。Jeong等<sup>[26]</sup>利用PFI筛选出了重要参数,建立了预应力混凝土构件有效传递长度的预测方程。

SHAP方法可对黑箱预测模型内部机制进行解释,并量化输入参数对模型的重要程度,却无法定量阐明参数与预测结果间映射关系。而GP方法可以在输入参数与抗剪承载力间建立高透明度的显式回归方程,这更容易应用到土木工程中,但输入参数的选择及维度将极大地影响其回归过程。在锈蚀因素影响下,RC构件的有效高度、箍筋屈服强度等因素与抗剪承载力间的演变规律更加复杂。因此,有必要选择最优的特征参数以推

导出结构简单、预测精度高的锈蚀 RC 构件抗剪承载力实用方程。

本文旨在建立一种基于可解释机器学习算法的锈蚀 RC 构件抗剪承载力实用模型。首先,从文献中搜集了 192 组 RC 梁的抗剪承载力数据,利用随机森林(RF)、极端梯度提升树(XGBoost)、多层感知神经网络(MLP)、支持向量回归(SVR),构建锈蚀 RC 构件抗剪承载力黑箱模型;其次,通过 SHAP 对上述黑箱模型进行特征重要性分析以明确重要特征参数;最后,利用 GP 推导出锈蚀 RC 构件抗剪承载力实用方程。

## 1 锈蚀 RC 构件抗剪承载力数据库

本文共搜集了 192 组锈蚀 RC 梁抗剪试验数据,构件的具体参数与加载方式如表 1 所示。根据已有的先验知识,选择对锈蚀 RC 梁影响较大的结构基本特征,如几何参数、材料参数、配筋信息、锈蚀率等共计 11 个:混凝土轴心抗压强度( $f_c$ )、梁宽( $b$ )、有效高度( $h_0$ )、纵向受拉钢筋配筋率( $\rho_l$ )、箍筋配筋率( $\rho_v$ )、箍筋屈服强度( $f_{yv}$ )、同一截面箍筋各肢的全部截面面积( $A_{sv}$ )、箍筋间距( $s$ )、剪跨比( $\lambda$ )、纵筋锈蚀率( $\eta_l$ )、箍筋锈蚀率( $\eta_w$ )。

表 1 锈蚀钢筋混凝土梁抗剪试验数据

Table 1 Shear test data of corroded reinforced concrete beams

学者	$f_c$ /MPa	$b$ /mm	$h_0$ /mm	$\rho_l$ /mm	$\rho_v$ /%	$f_{yv}$ /kN	$A_{sv}$ /mm <sup>2</sup>	$s$ /mm	$\lambda$	$\eta_l$ /%	$\eta_w$ /%	$V_u$ /kN	加载方式
薛昕等 <sup>[3]</sup>	15.8~18.8	120	220	2.17	0.39	300	57	120	1.5~3.2	0~17.3	0~16.7	70.5~124.3	单点
柳世涛 <sup>[27]</sup>	19.5~23.9	200	265	2.15	0.14~0.25	339~524	57~101	150~250	2~3.5	0~12.1	0~60.1	93.8~181.5	双点
Xia 等 <sup>[28]</sup>	12.97	120	200	2.62	0.48~0.56	321~463	57~101	100~150	1.5	0	0~54.2	85.2~138.2	双点
霍飞格 <sup>[29]</sup>	16.8~17.6	250	475	1.63	0.08~0.13	331~337	43~66	200	1.74	0	0~36.3	205.8~275.6	双点
赵冰等 <sup>[30]</sup>	9.5	100	175	1.94	0.44	324	66	150	1.5~2.5	0	4~23.3	41.9~53.0	双点
杨晓明等 <sup>[31]</sup>	15.8~18.7	120	220	2.17	0.39	300	57	120	1.5~3.2	0~17.3	0~16.8	70.5~123.3	双点
李冰等 <sup>[32]</sup>	18.3~26.7	150	150	2.68	0.19~0.25	444.15	57	150~200	2.0~3.0	0~26.2	0~32.7	52.1~78.2	双点
赵羽习等 <sup>[9]</sup>	11.9	150	155	2.26~2.79	0.19~0.45	331.52	66~101	100~200	2.2~3.1	0~26.0	0~9.2	40.0~72.0	单点
李学田等 <sup>[33]</sup>	18.1	150	175	2.3	0.25	275	57	150	1.5~2.2	0~3.4	0~2.8	75.9~131.0	单点
霍艳华 <sup>[4]</sup>	9.2~12.8	100	175	1.94	0.44	324	66	150	1.5~2.5	0~20.0	3.0~30.8	41.9~53.0	双点
祝建军 <sup>[34]</sup>	17.9	100	175	2.06	0	0	0	0	1.5~2.5	0~12.5	0	19.3~44.2	双点
Higgins 等 <sup>[35]</sup>	17.6~20.0	254	521	1.90	0.16~0.20	585	101	203~305	2.04	0	0~42.5	324.0~475.2	双点
王小惠等 <sup>[36]</sup>	17.0	150	170	1.58	0	0	0	0	3.97	1.0~4.7	0	24.4~36.3	双点
徐善华等 <sup>[8]</sup>	15.1~16.3	120	200	1.92	0.32	275	57	150	1~2	0	0~38.7	57.7~146.8	双点
Rodriguez 等 <sup>[2]</sup>	14.3	150	170	1.77	0.22	626	57	85~170	4.7	19.0~31.9	0~93.8	27.7~38.6	双点

由于试验数据的差异性,需换算混凝土强度与钢筋锈蚀程度的表征。本文采用轴心抗压强度设计值( $f_c$ )表示混凝土强度。根据文献[37],当搜集的样本强度表征为圆柱体抗压强度标准值时,按照下式进行换算:

$$f_c' = 0.79f_{cu,k} \quad (1)$$

$$f_{ck} = 0.88\alpha_{c1}\alpha_{c2}f_{cu,k} \quad (2)$$

$$f_c = f_{ck}/1.4 \quad (3)$$

当强度表征为轴心抗压强度标准值时,按照式(2)~式(3)进行换算。式中: $f_c'$ 为圆柱体抗压强度标准值; $f_{ck}$ 为轴心抗压强度标准值; $f_{cu,k}$ 为立方体抗压强度标准值; $\alpha_{c1}$ 为强度换算系数,该参数在混凝土强度小于 C50 时取 0.76,在 C50~C80 取 0.76~0.82,中间值可采用线性插值方法获得; $\alpha_{c2}$ 为脆性折减系数,对于 C40 以下取 1.0, C40~C80 取 1.0~0.87; $\delta$ 为混凝土立方体强度

变异系数,按文献[33]规定取值。

本文采用锈蚀钢筋截面损失率表示钢筋锈蚀率,锈蚀钢筋截面损失率与质量损失率之间的统计关系<sup>[10]</sup>如下:

$$\eta_s = \begin{cases} 0.013 + 0.987\eta, & \eta < 10\% \\ 0.061 + 0.939\eta, & 10\% < \eta < 20\% \\ 0.129 + 0.871\eta, & 20\% < \eta < 30\% \\ 0.199 + 0.801\eta, & 30\% < \eta < 40\% \end{cases} \quad (4)$$

式中: $\eta_s$ 和 $\eta$ 分别为钢筋截面损失率与质量损失率。

锈蚀 RC 构件抗剪试验数据的类型与分布决定了数据驱动方法的评估精度。在不同机器学习模型中,分析输入参数对预测结果的影响程度时,需了解这些数据的大小及分布,以判断该参数对模型预测结果的敏感性。

统一量纲后,这些数据的基本特点及分布情况如图 1 所示,可以发现,输入样本的变量分布很

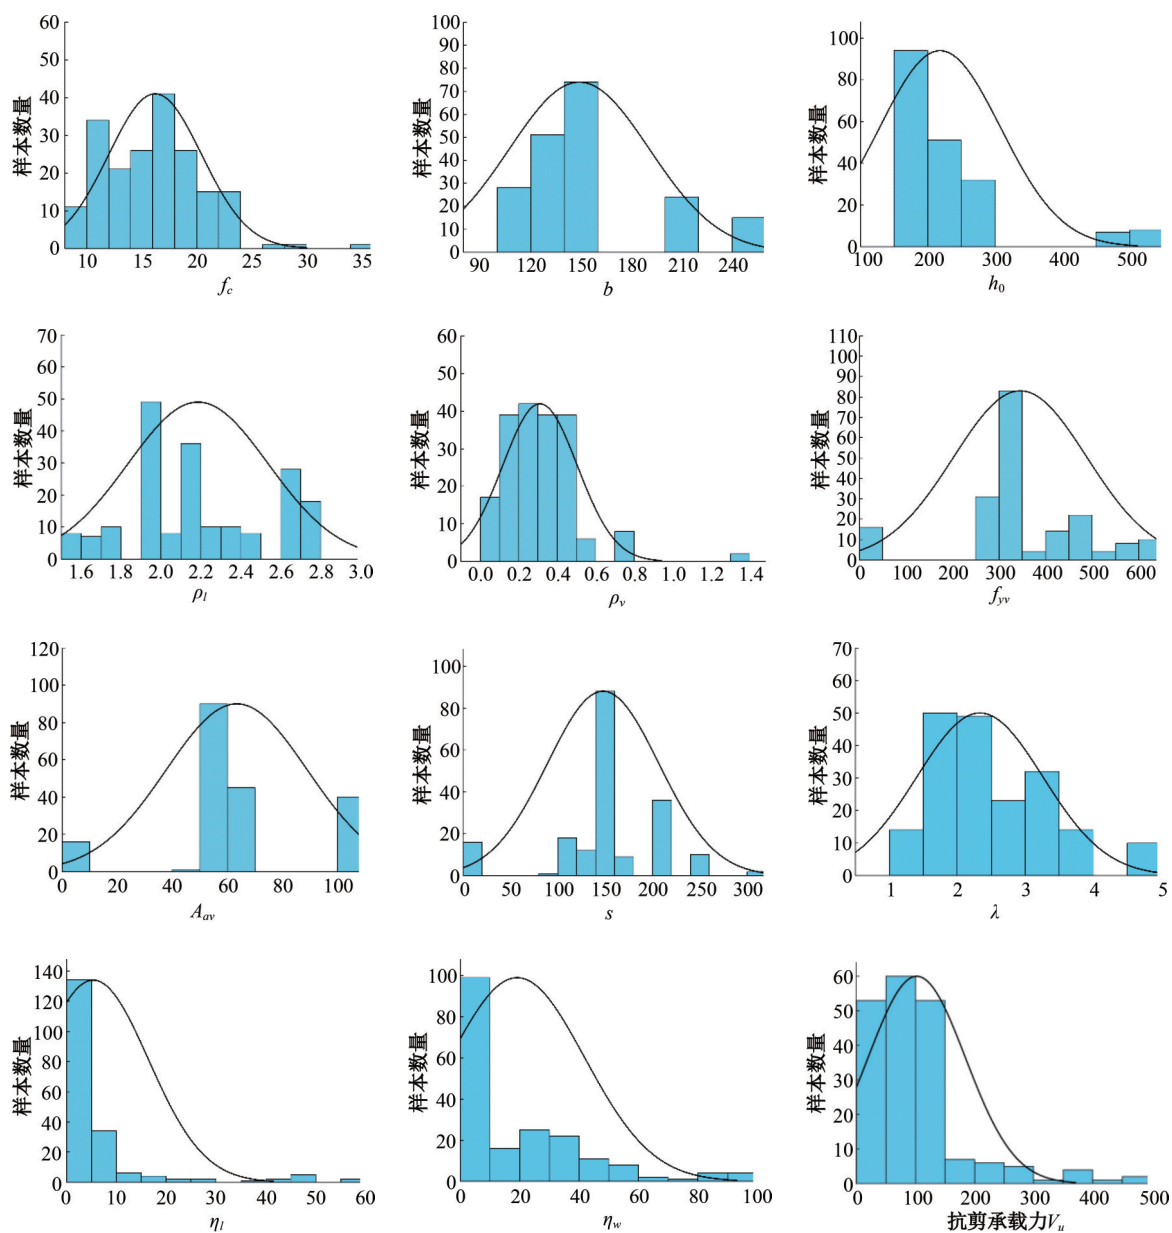


图 1 输入与输出变量样本分布

Fig. 1 Sample distribution of input and output variables

不均匀且分布规律相差较大,因此,在训练机器学习模型前,需要对这些数据进行特征标准化处理,标准化计算可表示为:

$$Z = \frac{x - u}{s} \quad (5)$$

式中: $Z$ 是标准化后的特征数据; $x$ 是原始特征数据; $u$ 是该特征的均值; $s$ 是该特征的标准差。

特征标准化可以将不同特征的取值范围统一到同一尺度,使其均值为0,方差为1,经标准化的数据其分布会更符合高斯分布,这样可以缩小不同特征之间的权重差异,增强每个特征的区分度,

使模型更好地捕捉数据之间的相关性和差异性。将标准化后的数据随机抽取80%的数据(153个)用于机器学习模型训练,20%的数据(39个)用于模型验证。

## 2 锈蚀 RC 构件抗剪承载力机器学习黑箱模型

本节旨在选取适用于锈蚀 RC 构件抗剪承载力预测的黑箱模型。先利用 RF、XGBoost、MLP 及 SVR 建立锈蚀 RC 梁抗剪承载力预测黑箱模型。再通过多种评价指标,明确上述机器学习黑

箱模型在预测锈蚀 RC 梁抗剪承载力的适用性。

## 2.1 机器学习模型

### 2.1.1 随机森林(RF)

随机森林<sup>[38]</sup>是以决策树<sup>[39]</sup>为基础学习器构建的集成算法。决策树是由节点和分支组成的数学模型,将特征值和边界值分别分配给节点和分支,节点根据输入的特征与输入分支的边界值对数据进行分类。与简单决策树模型相比,随机森林经历了随机化与聚合过程,其泛化能力更强。在本模型中,创建了 40 棵决策树,决策树的最大深度为 7,可使用的最大特征数量为 10,最小叶子节点含有的最少样本为 1,节点可分的最小样本数为 3。

### 2.1.2 极端梯度提升树(XGBoost)

与 RF 相比,梯度提升树(GBDT)<sup>[40]</sup>每一步只生成单棵决策树,首先利用初始数据库训练单棵决策树模型,然后跟踪分类器出错的实例,并增加其相对权重并计算其残差,在上一棵决策树的残差基础上训练一棵新的决策树。相较于 GBDT,XGBoost<sup>[41]</sup>在损失函数上增加了正则化项,并对损失函数进行了二阶泰勒展开。在本模型中,将决策树迭代训练 100 次,最大树深为 8,每个迭代产生模型的权重为 0.1,L1 正则项为 0,L2 正则项为 2.8,树的叶子节点上每一步分区所需的最小损失为 0.3。

### 2.1.3 多层感知神经网络(MLP)

MLP<sup>[42]</sup>是一种向前结构的人工神经网络,基本结构由三层组成:输入层、隐藏层和输出层。MLP 的单元(感知器)是由输入节点、权重、偏差、加权和、激活函数和输出节点组成的数字模型,输出节点根据连接权重、输入特征和权重的乘积反馈给具有神经元偏差( $b$ )的求和节点计算加权和,加权和( $\Sigma$ )用于激活函数( $f$ )推导出输出。在本模型中,设置了两层隐藏层,第一层神经元的数量为 10 个,第二层神经元的数量为 6 个,隐藏层的激活函数采用了 ReLU 函数,权重优化求解器采用了适用于小型数据集的 lbfgs 算法,最大迭代次数为 3 000。

### 2.1.4 支持向量回归(SVR)

SVR 作为支持向量机(SVM)<sup>[43]</sup>的分支而被提出用来解决回归问题。SVR 的本质则是追求超平面左右的数据间隔最小,从而所有样本点距

离超平面的总偏差最小。与 SVM 相同,SVR 也通过核函数方法将样本映射到高维空间,并通过调整误差幅度( $\epsilon$ )调整所需的精度。在本模型中,选择 rbf 函数作为核函数,正则化参数为 815,最大迭代次数为 1 000 次。

## 2.2 各机器学习预测模型结果对比

基于上述机器学习方法对锈蚀 RC 构件抗剪承载力进行预测,为比较各模型的优劣,本文采用可决系数(R2)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)及均方根误差(RMSE)作为评估预测模型的性能指标。其中,R2 用于判断回归模型的预测效果,越接近 1 说明模型效果越好;MAE 表示预测值与实际值间的绝对误差的平均值;MAPE 表示预测值与实际值间的绝对百分比误差的平均值;RMSE 表示预测值与实际值的误差平方根的均值,对异常值较敏感。

各机器学习模型在所有 192 组数据(训练集+测试集)的预测结果如图 2 所示,RF、XGBoost、MLP 及 SVR 的预测精度对比结果如表 2 所示,结果表明,SVR 在测试集上的预测性能最好,所有评估指标均优于其他 3 种模型,XGBoost 与 MLP 的预测精度相似,RF 的效果最差,且 RMSE 达到了 20.133,表明 RF 在测试集上的预测存在异常值。4 种机器学习算法在测试集上的 R2 均达到了 0.966 以上,MAPE 在 15% 以内,说明上述机器学习算法均适用于锈蚀 RC 构件抗剪承载力预测,可利用 SHAP 对上述模型进行内部机制解释。

表 2 各机器学习模型抗剪承载力预测精度对比  
Table 2 Comparison of prediction accuracy for shear capacity of each machine learning model

数据集	模型	指标			
		R2	MAE	MAPE/%	RMSE
训练结果	RF	0.990	4.102	4.626	7.17
	XGBoost	0.998	1.367	1.572	2.90
	MLP	0.995	3.285	3.940	5.204
	SVR	0.993	3.003	3.438	6.252
测试结果	RF	0.966	12.995	14.774	20.133
	XGBoost	0.982	10.063	10.836	14.887
	MLP	0.982	9.850	12.557	14.634
	SVR	0.985	8.834	10.568	13.344

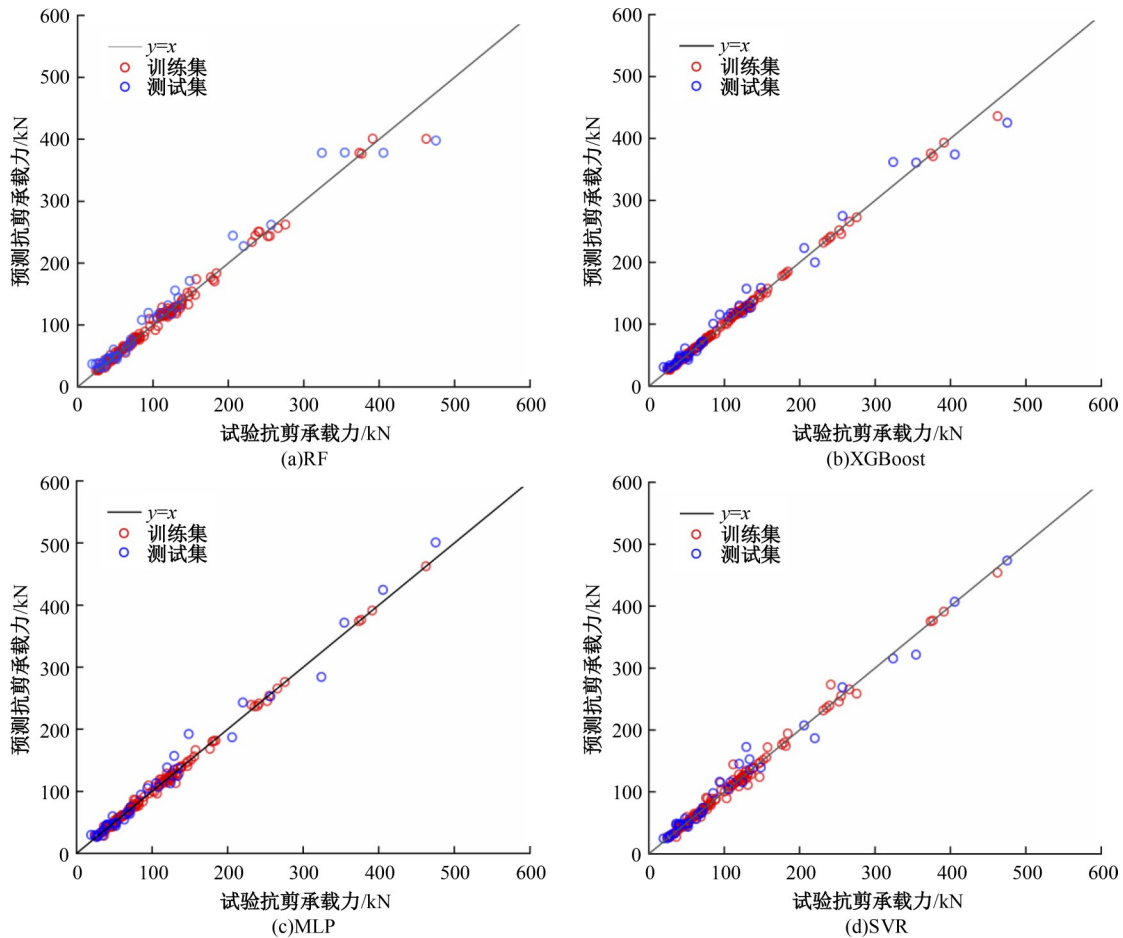


图2 不同机器学习RC梁抗剪承载力预测

Fig. 2 Shear capacity prediction of RC beams with different machine learning

### 3 基于可解释机器学习的锈蚀RC构件抗剪承载力实用模型

虽然上述RF、XGBoost、MLP与SVR模型可以保证预测精度的精确性,但人们难以理解其内部工作机制,无法表征输入变量与承载力间的复杂非线性关系。GP是一种基于达尔文理论的机器学习方法,可在数学表达式空间内搜索能够拟合给定数据集的表达式,对非线性复杂问题具有很强的求解能力。该方法建立高精度预测模型的同时,还具有开发显式预测函数的能力。因此,本研究采用GP进一步推导包含输入参数与输出结果的显式锈蚀RC梁抗剪承载力方程。GP虽然可以捕捉构件的几何信息、材料特性及劣化信息等参数与抗剪承载力间的映射关系并开发出显式函数,但输入参数的选择与维度将极大影响所开发函数的复杂度及透明度。在机器学习模型中,输入变量维度的增加会造成数据密度降低,若要拟合出精确的回归模型,就需增加数据样本的数

量,这种现象被称为维度诅咒<sup>[44]</sup>。通过选择出对预测结果影响较大的输入变量,不仅可以保留最大的信息量,还可以避免维度诅咒,从而得到具有广义性质的模型<sup>[45]</sup>。

目前,最常用的特征选择方法为置换特征重要性(PFI)<sup>[46]</sup>,如图3所示,PFI通过随机打乱某一输入特征的序列,并比较模型前后预测精度差,从而计算出该特征对模型的重要性。但该方法无法忽略特征间的相关性影响且无法判断黑箱模型本身的可信度,若黑箱模型本身不可信,该方法计算出来的特征重要性将无意义。SHAP方法不仅判断黑箱模型的可信度,还可以量化输入变量对输出结果作出的贡献,明确单个特征变量或多个特征变量交互下对预测结果的影响。因此,可以利用SHAP方法明确最佳的输入特征及维度,从而建立锈蚀RC构件抗剪承载力预测实用模型。

#### 3.1 基于SHAP方法的特征重要性排序

SHAP<sup>[20]</sup>是一种基于博弈论描述机器学习模型性能的加性解释模型,SHAP使用了一种可添加




图 3 置换特征重要性

Fig. 3 Schematic representation of permutation feature importance

的特征属性方法,所有的特征都被视为贡献者,输出目标被定义为输入特征的线性添加,可以表示为:

$$f(x) = g(x') = \varphi_0 + \sum_{i=1}^M \varphi_i x'_i \quad (6)$$

式中: $g(x')$ 为解释模型; $f(x)$ 为机器学习模型, $x = (x_1, x_2, \dots, x_i)$ 为输入的特征, $x'$ 为简化输入特征,与 $x$ 存在映射关系; $M$ 为输入特征的个数; $\varphi_0$ 为所有样本的预测目标均值(通常也被称为基线值,base value); $\varphi_i$ 为第*i*个特征的贡献值。

SHAP方法可视为机器学习黑箱模型的一个接口,每个训练好的黑箱模型可以通过SHAP分析其内部机制。SHAP对黑箱模型作出解释时,会计算所有试验样本(训练集)特征的权重并加权拟合,得到最终的 $\varphi_i$ 与基线值。图4为赵羽习等<sup>[9]</sup>的试验样本1-5和徐善华等<sup>[8]</sup>的试验样本C1的SHAP(以SVR模型为例)解释示意图,SHAP将黑箱模型的预测结果解释为基线值与各输入变量对其贡献的总和,经SHAP处理后,基线值可视作不受任何特征影响的预测均值,色条的长度表示该数值下的特征对模型的贡献程度,当特征显示为红色时,表示该特征会提高SHAP基线值;当特征显示为蓝色时,表示该特征会降低SHAP基线值。

利用SHAP方法对4个黑箱模型作出解释,计算并记录每一个样本的SHAP值与特征的贡献值,就可以得到SHAP摘要图。SHAP摘要图

可以从全局的角度分析特征对预测结果的影响,图5展示了各模型的SHAP摘要图。其中,横坐标代表各个特征的SHAP值,右侧纵坐标为各特征的特征值大小,红色代表该特征的值相对较大;蓝色代表该特征的值相对较小。以箍筋锈蚀率( $\eta_w$ )为例,当 $\eta_w$ 值相对较大时,数据点显示为红色,降低黑箱模型的SHAP值,当 $\eta_w$ 值相对小时,数据点显示为蓝色,提高黑箱模型的SHAP值。这说明当 $\eta_w$ 相对较小时,可以提高黑箱模型构件抗剪承载力,当 $\eta_w$ 超过某一阈值时,会降低黑箱模型构件抗剪承载力。

从图5(a)得到以下结论:箍筋与纵筋的轻微锈蚀在一定程度上能提高SVR模型构件抗剪承载力,该现象与现有研究结果吻合,轻微锈蚀会增强钢筋与混凝土间的粘结力,提高斜裂缝两侧骨料的咬合作用,从而提高构件的抗剪承载力<sup>[9]</sup>,严重锈蚀时会降低模型构件抗剪承载力;增大箍筋的强度与截面积可以提高模型构件抗剪承载力;混凝土梁的有效截面是确保其抗剪承载力的重要因素;增大纵筋和箍筋的配筋率及混凝土强度可以提高构件抗剪承载力;过大的箍筋间距会对抗剪承载力产生不利影响。上述结论表明,SVR的内部机制与先验知识一致,是可信用度高的黑箱模型。依次对其余模型进行分析后发现,XGBoost与RF均有较好的可信用度,MLP中 $A_{sv}$ 的运行机制与先验知识不一致,可信用度较低。




图 4 SHAP 计算示意图

Fig. 4 SHAP value calculation diagram

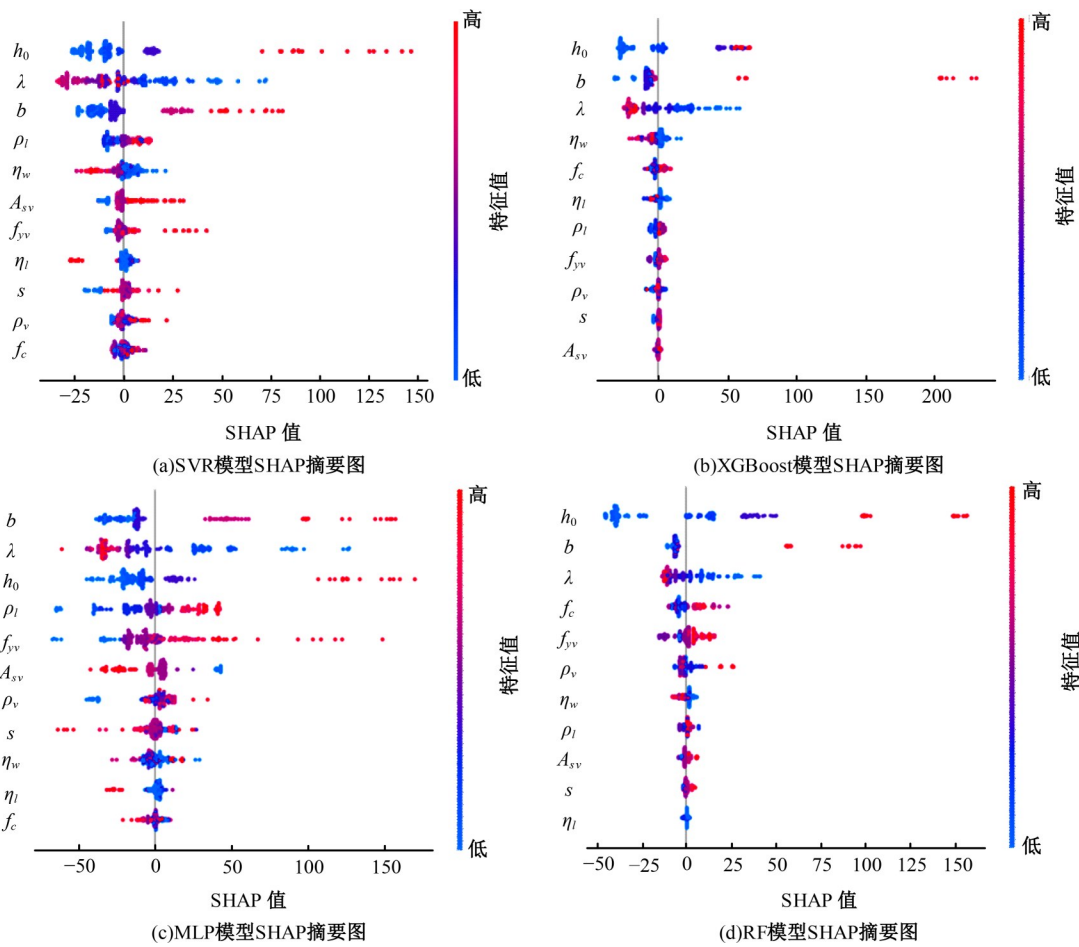


图 5 SHAP 全局分析图

Fig. 5 SHAP global analysis chart

### 3.2 重要特征选择

不同的机器学习模型在进行抗剪承载力预测训练时,虽然其预测性能相差不大,但其权重分配可能有所不同,需要分别计算各模型的重要特征排序结果。SHAP 不仅解释输入特征对输出结果的影响,还可以计算出其贡献值,因此,可以利用 SHAP 对可信度高的黑箱模型(RF、XGBoost、SVR)

进行重要特征排序。此外,在进行重要特征选择时,更多依赖于工程经验与权衡,暂未有统一的明确指标与方法。因此,不仅要比较不同机器学习模型重要特征排序的差异,还要结合先验知识判断其合理性,最终选出重要特征参数。

如表 3 所示列出了各训练模型的重要特征排序结果,为便于比较,将上述参数划分为几何尺寸

表 3 各训练模型的特征重要性排序  
Table 3 Feature importance ranking of each training model

训练模型	特征重要性排序										
	1	2	3	4	5	6	7	8	9	10	11
RF	$h_0$ 46.3%	$b$ 14.7%	$\lambda$ 12.7%	$f_c$ 6.9%	$f_{yv}$ 6.6%	$\rho_v$ 4.4%	$\eta_w$ 2.9%	$A_{sv}$ 2.0%	$\rho_l$ 1.9%	$s$ 0.9%	$\eta_l$ 0.7%
XGBoost	$h_0$ 32.6%	$b$ 24.7%	$\lambda$ 21.4%	$\eta_w$ 4.6%	$f_c$ 3.8%	$\eta_l$ 3.2%	$\rho_l$ 3.2%	$f_{yv}$ 3.1%	$\rho_v$ 1.7%	$s$ 1.1%	$A_{sv}$ 0.6%
SVR	$h_0$ 24.8%	$\lambda$ 20.3%	$b$ 19.1%	$\rho_l$ 7.0%	$\eta_w$ 5.8%	$A_{sv}$ 5.1%	$f_{yv}$ 4.5%	$\eta_l$ 3.7%	$s$ 3.6%	$\rho_v$ 3.2%	$f_c$ 2.9%

参数: $h_0$ 、 $b$ 、 $\lambda$ ;材料参数: $A_{sv}$ 、 $f_{yv}$ 、 $\rho_l$ 、 $\rho_v$ 、 $s$ 、 $f_c$ ;锈蚀参数: $\eta_w$ 、 $\eta_l$ 。可以发现,不论是哪种机器学习模型,相较于材料参数与锈蚀参数,几何尺寸参数的重要性最高,且有效高度、剪跨比与梁宽的重要程度之和占比在 64.2%~78.7%。

对于 RC 构件而言,有效高度及梁宽直接决定了构件的截面尺寸,影响截面刚度等物理信息,进而影响构件力学特性。此外,大量试验研究表明,剪跨比是影响受弯构件斜截面抗剪承载力最主要的因素,因而在每一个机器学习模型中,几何尺寸参数都占有较大的比重,所以选择几何尺寸的  $h_0$ 、 $b$  及  $\lambda$  3 个参数作为重要特征参数。

材料参数方面,大量试验表明,梁的抗剪承载力随  $\rho_l$  的提高而增大;梁的斜截面破坏是由混凝土达到相应受力状态下的极限强度而发生的;配置箍筋数量适当时,斜裂缝出现后,原来由混凝土承受的拉力由箍筋承受。综上所述,各材料参数均对锈蚀 RC 梁有重要影响。为选出适合参数进行公式推导,选择 SHAP 特征重要排序均值前 50% 作为重要特征参数,即  $f_{yv}$ 、 $f_c$  与  $\rho_l$ 。

箍筋锈蚀和纵筋锈蚀都会影响构件的力学性能。在 GP 中,若同时选择两个参数进行公式推导,会导致遗传树过于膨胀,即推导出的公式十分

复杂,不实用。因此,本文选择两者中的一个作为锈蚀的评价指标。由于箍筋位于纵筋外侧,在侵蚀介质作用下,箍筋一般首先锈蚀,且其锈蚀程度会大于纵筋,而混凝土梁的抗剪承载力主要依赖于箍筋。在 SHAP 重要特征排序均值中, $\eta_w$  相对  $\eta_l$  更重要,故选择  $\eta_w$  作为重要特征参数。

通过上述分析,最终选择有效高度、剪跨比、梁宽、箍筋屈服强度、纵筋配筋率、混凝土强度及箍筋锈蚀率作为重要特征参数,用于 GP 符号回归。

### 3.3 遗传编程

GP 是由 Koza<sup>[21]</sup>提出的一种基于遗传算法的进化规划技术,目前正积极应用于符号回归。GP 中使用的树由终端节点和功能节点组成,终端节点位于树的末端,代表特征节点或常数节点,函数节点位于树的内部,是以终端节点或子树为参数的数学运算符。图 6 为 GP 中染色体的树状表示及符号回归过程。首先随机生成初始种群即若干棵基因树,每一棵基因树都代表一个符号回归模型,然后通过选择某种策略对基因树进行筛选和进化,即从父辈中择优繁育子代,这些子代间继续通过交叉、遗传、变异等操作进化,直到迭代的次数达到规定次数或基因树收敛到全局最优。

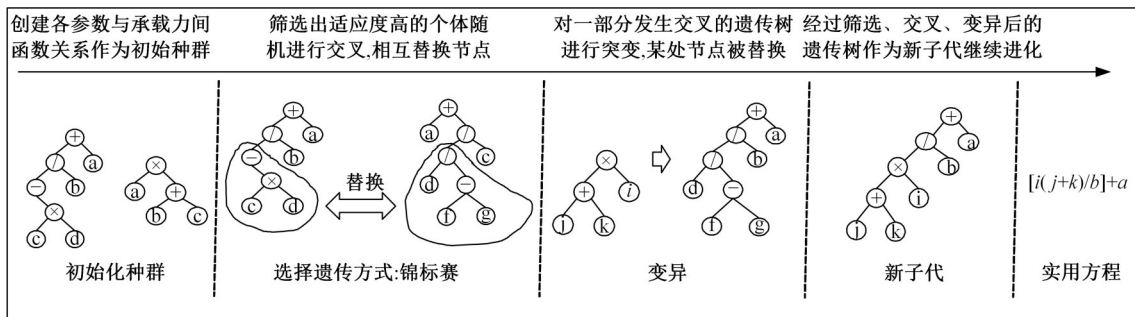


图 6 GP 符号回归过程

Fig. 6 Regression process of GP symbolics

本文采用锦标赛选择作为优势基因树的选择策略,锦标赛选择将每一代种群中的个体随机分组,每组中的个体进行竞争,然后从中选取  $k$  棵最优树作为锦标赛获胜者,对这些锦标赛获胜者进行交叉(即随机选择和交换两棵树的子树)、变异(即随机选择某棵子树,然后将它替换到锦标赛获胜者的随机树中)等操作。

为尽可能拟合出一个简单实用的方程,在符号选择上除了加、减、乘、除这 4 个基础运算符,考虑到尽量与经验模型形式上类似,增加了开方运算符进行 RC 构件的抗剪承载力符号回归。同时,为避免复杂运算,确保足够的透明度,基因树的最大深度为 7,初始种群数量为 5 000,公式计算长度限定为 30 次以内,交叉率为 80%,突变率为 10%,与先前的黑箱模型相同,采用训练集的 153 组样本对模型进行训练,测试集的 39 组样本用于验证,最终的拟合表达式为:

$$V_{cs} = \left\{ f_c + h_0 \left[ b + \frac{f_{yv}}{\lambda} - \frac{0.548 f_{yv} (f_c + \eta_w)}{f_c^2 \sqrt{\rho_l}} \right] \right\} \sqrt{\rho_l} \quad (7)$$

各输入参数的单位如下: $h_0$ (mm)、 $\lambda$ 、 $b$ (mm)、 $f_{yv}$ (MPa)、 $\rho_l$ (%)、 $f_c$ (MPa)以及 $\eta_w$ (%),公式拟合的结果单位为  $N$ 。

#### 4 现有锈蚀 RC 梁抗剪承载力计算模型对比分析

表 4 列出了赵羽习等<sup>[9]</sup>、霍艳华<sup>[4]</sup>、李士斌等<sup>[1]</sup>及 Ahmed K<sup>[47]</sup>给出的锈蚀 RC 构件抗剪承载力的经验模型,通过测试集的 39 组试验值与模型计算值比值的均值( $\mu$ )、均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)以及 R2 比较各计算模型的精度,计算结果如表 5 所示。

表 5 中李士斌等<sup>[1]</sup>与 Ahmed K<sup>[47]</sup>的均值( $\mu$ )分别为 1.58 与 0.94,相较于其他模型较为合理,而赵羽习等<sup>[9]</sup>与霍艳华<sup>[4]</sup>的均值( $\mu$ )分别为 2.13 与 1.99,其预测结果误差较大。这是由于赵羽习等<sup>[9]</sup>与霍艳华<sup>[4]</sup>提出的模型适用性有限,如赵羽习等<sup>[9]</sup>是基于 Zararis 理论提出的简化模型,Zararis 理论更适用于小剪跨比梁,且简化模型仅考虑了箍筋锈蚀。而霍艳华<sup>[4]</sup>提出的计算模型更适用于剪跨比为 1.5~3 的梁,当锈蚀率较大时,计算过于保守。本文提出的实用方程与机器学习预测模型的均值( $\mu$ )为 0.89~0.96,其计算值偏向真实值。理论预测值与试验测试值如图 7 所示。结果表明,本文提出的实用模型的预测精度与可解释性介于已有的经验模型与黑箱模型间,可为锈蚀 RC 构件抗剪承载力计算提供科学依据。

表 4 RC 构件抗剪承载力计算模型

Table 4 Calculation model for shear capacity of RC beams

作者	计算模型
李士斌等 <sup>[1]</sup>	集中荷载下的梁: $V_{cs} = \frac{1.75 f_c b_c h_{0c}}{1 + \lambda} + \frac{f_{yv} A_{sv} h_{0c}}{s}$ , 矩形截面梁: $V_{cs} = 0.7 f_t b_c h_{0c} + 1.25 \frac{f_{yv} A_{sv} h_{0c}}{s}$
Ahmed K <sup>[47]</sup>	$V_{cs} = 0.17 \lambda \sqrt{f_c} b_{eff} h_0 + \frac{A_{v,eff} f_{yv} h_0}{s}$
赵羽习等 <sup>[9]</sup>	$V_{cs} = P_v V_{cs0}, P_v = \begin{cases} 1.0, & \eta_w \leq 10\% \\ 1.17 - 1.7 \eta_w, & \eta_w > 10\% \end{cases}, V_{cs0} = \frac{b h_0}{\lambda} \left[ \frac{C_s}{h_0} \left( 1 - 0.5 \frac{C_s}{h_0} \right) f_c^t + 0.5 \rho_v f_{yv} \left( 1 - \frac{C_s}{h_0} \right)^2 \lambda^2 \right]$
霍艳华 <sup>[4]</sup>	$V_{cs} = \varphi \frac{1.75}{1 + \lambda} f_t b h_0 + \gamma \frac{A_{sv} f_{yv} h_0}{s}, \varphi = \begin{cases} 1.0, & \eta_t \leq 5\% \\ 1.098 - 1.96 \eta_t, & \eta_t > 5\% \end{cases}, \gamma = 1 - 1.059 \eta_w$

表 5 RC 构件抗剪承载力各计算模型评价指标

Table 5 Evaluation index of each calculation model for shear capacity of RC beams

评价指标	李士斌等 <sup>[1]</sup>	Ahmed K <sup>[47]</sup>	赵羽习等 <sup>[9]</sup>	霍艳华 <sup>[4]</sup>	本文模型	SVR	MLP	XGBoost	RF
$\mu$	1.58	0.94	2.13	1.99	0.89	0.96	0.96	0.96	0.92
RMSE	61.46	49.37	92.07	68.5	25.6	13.3	14.6	14.9	20.1
MAE	41.88	37.7	65.13	47.53	17.8	8.8	9.9	10.1	13.0
MAPE/%	36.50	64.61	57.91	40.52	20.68	10.57	12.56	10.84	14.77
R2	0.844	0.898	0.653	0.807	0.948	0.985	0.982	0.982	0.966

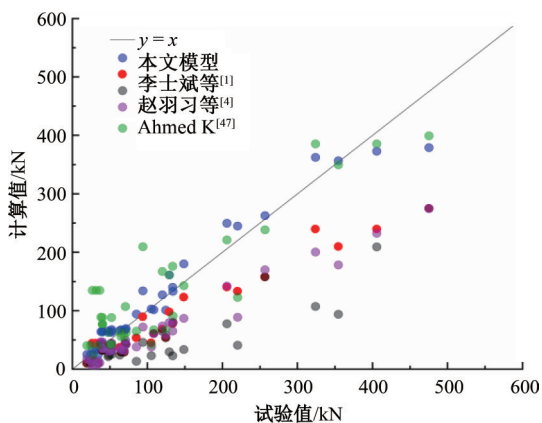


图7 RC构件抗剪承载力计算模型拟合效果图

Fig. 7 Fitting effect of shear bearing capacity calculation model of RC beams

## 5 结束语

本文建立了一种基于可解释机器学习算法的锈蚀 RC 构件抗剪承载力实用模型。首先,本文通过搜集的 192 组试验数据集,给出了基于不同机器学习算法的抗剪承载力黑箱模型;其次,采用 SHAP 方法量化了各特征参数的敏感性;最后,通过 GP 方法推导了一个简单实用的抗剪承载力计算公式,明确了关键特征参数与抗剪承载力间的映射关系。结果表明:

(1)建立的锈蚀 RC 构件抗剪承载力黑箱模型中,XGBoost 与 SVR 的综合性能最佳,MLP 次之,RF 最差;XGBoost、SVR 与 RF 均有较高的可信度,MLP 的内部机制与先验知识不一致,可信度不足。

(2)建立了基于可解释机器学习算法的锈蚀 RC 构件抗剪承载力实用模型,该模型可考虑锈蚀 RC 构件的几何尺寸、配筋率、箍筋屈服强度、锈蚀率等关键基本特征,并能揭示各基本特征与抗剪承载力间的底层映射关系。

(3)锈蚀 RC 构件抗剪承载力对几何尺寸参数中的有效高度、剪跨比与梁宽最为敏感;材料参数中,箍筋屈服强度与混凝土强度的重要性高于其他参数,箍筋间距的重要性最小;相较于纵筋锈蚀,箍筋锈蚀对 RC 构件抗剪承载力的影响更大。

(4)本文提出的锈蚀 RC 构件抗剪承载力实用模型,其预测精度与可解释性介于已有的经验模型与黑箱模型之间,可为锈蚀 RC 构件抗剪承载力计算提供依据。

(5)机理驱动方法一般基于力学原理,对一些难以定量表达的用量用各类系数进行表征,能很好

地解析抗剪承载力形成机理;数据驱动方法基于数据本身,能够综合所有因素的影响并建立高精度模型,但难以解析抗剪承载力形成机理;机理驱动方法和数据驱动方法相结合,不但能对抗剪承载力进行解析,还可以提高准确性,相关理论有待进一步研究。

## 参考文献:

- [1] 李士彬,张鑫,贾留东,等. 箍筋锈蚀钢筋混凝土梁的抗剪承载力分析[J]. 工程力学, 2011, 28(S1): 60-63.  
Li Shi-bin, Zhang Xin, Jia Liu-dong, et al. Analysis for shear capacity of reinforced concrete beams with corrosion stirrups[J]. Engineering Mechanics, 2011, 28(S1): 60-63.
- [2] Rodriguez J, Ortega L M, Casal J. Load carrying capacity of concrete structures with corroded reinforcement[J]. Construction and Building Materials, 1997, 11(4): 239-248.
- [3] 薛昕,杨成. 纵向受拉钢筋锈蚀钢筋混凝土梁的抗剪性能[J]. 上海交通大学学报, 2016, 50(11): 1767-1772.  
Xue Xin, Yang Cheng. Shear performance of reinforced concrete beams containing corroded longitudinal bars[J]. Journal of Shanghai Jiaotong University, 2016, 50(11): 1767-1772.
- [4] 霍艳华. 锈蚀钢筋混凝土简支梁受剪承载力研究[J]. 工业建筑, 2006, 36(z1): 910-912.  
Huo Yan-hua. Research on shear capacity of simply supported concrete beam with corroded reinforcement [J]. Industrial Construction, 2006, 36(z1): 910-912.
- [5] 梁兴文,汪萍,徐明雪,等. 配筋超高性能混凝土梁受弯性能及承载力研究[J]. 工程力学, 2019, 36(5): 110-119.  
Liang Xing-wen, Wang Ping, Xu Ming-xue, et al. Investigation on flexural capacity of reinforced ultra high performance concrete beams[J]. Engineering Mechanics, 2019, 36(5): 110-119.
- [6] 何世钦,贡金鑫. 钢筋混凝土梁中锈蚀钢筋粘结性能的试验研究[J]. 哈尔滨工业大学学报, 2006, 38(12): 2167-2170.  
He Shi-qin, Gong Jin-xin. Experimental studies on bond characteristics of corroded steel bar in reinforced concrete beams[J]. Journal of Harbin Institute of Technology, 2006, 38(12): 2167-2170.
- [7] 戴理朝,周亮,杨晓文,等. 基于 Connector 单元的锈蚀 RC 梁界面粘结性能微观数值模拟[J]. 吉林大学学报:工学版, 2023, 53(10): 2886-2896.

- Dai Li-chao, Zhou Liang, Yang Xiao-wen, et al. Microscopic numerical simulation of interface bond performance of corroded RC beam based on connector element[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2023, 53(10): 2886-2896.
- [8] 徐善华, 牛荻涛. 锈蚀钢筋混凝土简支梁斜截面抗剪性能研究[J]. *建筑结构学报*, 2004, 25(5): 98-104.  
Xu Shan-hua, Niu Di-tao. The shear behavior of corroded simply supported reinforced concrete beam[J]. *Journal of Building Structures*, 2004, 25(5): 98-104.
- [9] 赵羽习, 金伟良. 锈蚀箍筋混凝土梁的抗剪承载力分析[J]. *浙江大学学报: 工学版*, 2008, 42(1): 19-24.  
Zhao Yu-xi, Jin Wei-liang. Analysis on shearing capacity of concrete beams with corroded stirrups[J]. *Journal of Zhejiang University (Engineering Science)*, 2008, 42(1): 19-24.
- [10] 卢朝辉, 李海, 赵衍刚, 等. 锈蚀钢筋混凝土梁抗剪承载力预测经验模型[J]. *工程力学*, 2015, 32(z1): 261-270.  
Lu Zhao-hui, Li Hai, Zhao Yan-gang, et al. An empirical model for shear strength prediction of corroded RC beams[J]. *Engineering Mechanics*, 2015, 32(z1): 261-270.
- [11] 金浏, 王涛, 杜修力. 无腹筋RC悬臂梁抗剪强度及尺寸效应理论研究[J]. *计算力学学报*, 2020, 37(4): 396-404.  
Jin Liu, Wang Tao, Du Xiu-li. Size effect theory on shear strength of RC cantilever beams without stirrups[J]. *Chinese Journal of Computational Mechanics*, 2020, 37(4): 396-404.
- [12] Huang H, Burton H V. Classification of in-plane failure modes for reinforced concrete frames with infills using machine learning[J]. *Journal of Building Engineering*, 2019, 25: No. 100767.
- [13] Mangalathu S, Jeon J S. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques[J]. *Engineering Structures*, 2018, 160: 85-94.
- [14] 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): No. 04019104.
- [15] Mangalathu S, Jeon J S, DesRoches R. Critical uncertainty parameters influencing seismic performance of bridges using Lasso regression[J]. *Earthquake Engineering & Structural Dynamics*, 2018, 47(3): 784-801.
- [16] Feng D C, Liu Z T, Wang X D, 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: No. 101126.
- [17] Fu B, Feng D C. A machine learning-based time-dependent shear strength model for corroded reinforced concrete beams[J]. *Journal of Building Engineering*, 2021, 36: No. 102118.
- [18] Nguyen T H, Nguyen D T, Nguyen D H, et al. Evaluation of residual strength of corroded reinforced concrete beams using machine learning models[J]. *Arabian Journal for Science and Engineering*, 2022, 47(8): 9985-10002.
- [19] Hoang N D, Tran X L, Nguyen H. Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized least squares support vector regression model[J]. *Neural Computing and Applications*, 2020, 32: 7289-7309.
- [20] Lundberg S M, Lee S I. A unified approach to interpreting model predictions[C]//*Advances in Neural Information Processing Systems*, Long Beach, USA, 2017: 4765-4774.
- [21] Koza J R. Genetic programming as a means for programming computers by natural selection[J]. *Statistics and Computing*, 1994, 4: 87-112.
- [22] Mangalathu S, Hwang S H, Jeon J S. Failure mode and effects analysis of RC members based on machine-learning-based shapley additive explanations (SHAP) approach[J]. *Engineering Structures*, 2020, 219: No. 110927.
- [23] 冯德成, 吴刚. 混凝土结构基本性能的可解释机器学习建模方法[J]. *建筑结构学报*, 2022, 43(4): 228-238.  
Feng De-cheng, Wu Gang. Interpretable machine learning-based modeling approach for fundamental properties of concrete structures[J]. *Journal of Building Structures*, 2022, 43(4): 228-238.
- [24] Chaabene W B, Nehdi M L. Genetic programming based symbolic regression for shear capacity prediction of SFRC beams[J]. *Construction and Building Materials*, 2021, 280: No. 122523.
- [25] Gandomi A H, Alavi A H, Mohammadzadeh S D, et al. An empirical model for shear capacity of RC deep beams using genetic-simulated annealing[J]. *Archives of Civil and Mechanical Engineering*, 2013, 13: 354-369.
- [26] Jeong H, Han S J, Choi S H, et al. Genetic programming approach and data generation for transfer lengths

- in pretensioned concrete members[J]. *Engineering Structures*, 2021, 231: No. 111747.
- [27] 柳世涛. 受腐蚀钢筋混凝土梁抗剪性能研究[D]. 长沙:中南大学土木工程学院, 2013.  
Liu Shi-tao. Research on shear behavior of corroded RC beams[D]. Changsha: School of Civil Engineering, Central South University, 2013.
- [28] Xia J, Jin W, Li L. Shear performance of reinforced concrete beams with corroded stirrups in chloride environment[J]. *Corrosion Science*, 2011, 53(5): 1794-1805.
- [29] 翟飞格. 箍筋锈蚀配斜筋 RC 梁抗剪承载力研究[D]. 长沙:长沙理工大学土木工程学院, 2010.  
Zhai Fei-ge. The research on shear capacity of corroded stirrups RC beams with diagonal reinforcement [D]. Changsha: School of Civil Engineering, Changsha University of Science and Technology, 2010.
- [30] 赵冰, 曾凡振. 锈蚀箍筋混凝土简支梁抗剪承载力模型及有限元分析[J]. *中国农村水利水电*, 2010, 2010(10): 88-91.  
Zhao Bing, Zeng Fan-zhen. The model and finite element analysis of shear capacity of simply supported concrete beam with corroded stirrup[J]. *China Rural Water and Hydropower*, 2010, 2010(10): 88-91.
- [31] 杨晓明, 吴桐, 王耀耀. 小剪跨比锈蚀钢筋混凝土梁受剪性能试验研究[J]. *建筑结构学报*, 2019, 40(12): 147-154.  
Yang Xiao-ming, Wu tong, Wang Yao-yao. Experimental study on shear behavior of corroded reinforced concrete beams with low shear span ratio[J]. *Journal of Building Structures*, 2019, 40(12): 147-154.
- [32] 李冰, 高向华, 王小惠, 等. 局部区段锈蚀的钢筋混凝土梁抗剪承载力试验研究[J]. *混凝土与水泥制品*, 2010, 2010(6): 60-65.  
Li Bing, Gao Xiang-hua, Wang Xiao-hui, et al. Experimental study on shear capacity of reinforced concrete beams with local section corrosion[J]. *Concrete and Cement Products*, 2010, 2010(6): 60-65.
- [33] 李学田, 殷惠光. 锈蚀钢筋混凝土梁抗剪能力退化机理和预计模型[J]. *徐州工程学院学报: 自然科学版*, 2010, 25(4): 58-63.  
Li Xue-tian, Yin Hui-guang. Degradation mechanism and predicting models of shearing capacity for corroded reinforced concrete beams[J]. *Journal of Xuzhou Institute of Technology (Natural Sciences Edition)*, 2010, 25(4): 58-63.
- [34] 祝建军. 纵筋锈蚀对无腹筋梁斜截面受剪承载力的影响[D]. 南昌:南昌大学建筑工程学院, 2007.  
Zhu Jian-jun. Effect of corroded longitudinal reinforcements on shear capacity of simple supported concrete beam without stirrups[D]. Nanchang: School of Civil Engineering and Architecture, Nanchang University, 2007.
- [35] Higgins C, Farrow W C. Tests of reinforced concrete beams with corrosion-damaged stirrups[J]. *ACI Materials Journal*, 2006, 103(1): 133-141.
- [36] 王小惠, 刘西拉. 基于粘结强度变化的锈蚀无腹筋梁承载能力的研究[J]. *四川建筑科学研究*, 2007, 33(3): 56-61.  
Wang Xiao-hui, Liu Xi-la. Research on load carrying capacity of corroded RC beam without web reinforcement on the basis of the change of bond strength [J]. *Sichuan Building Science*, 2007, 33(3): 56-61.
- [37] GB50010—2010. 混凝土结构设计规范[S].
- [38] Liaw A, Wiener M. Classification and regression by random forest[J]. *R News*, 2002, 2(3): 18-22.
- [39] Safavian S R, Landgrebe D. A survey of decision tree classifier methodology[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1991, 21(3): 660-674.
- [40] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. *Journal of Computer and System Sciences*, 1997, 55(1): 119-139.
- [41] Chen T, Guestrin C. Xgboost: a scalable tree boosting system[C]//*Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining*, San Francisco, USA, 2016: 785-794.
- [42] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [43] Hearst M A, Dumais S T, Osuna E, et al. Support vector machines[J]. *IEEE Intelligent Systems and Their Applications*, 1998, 13(4): 18-28.
- [44] Friedman J H. On bias, variance, 0/1—loss, and the curse-of-dimensionality[J]. *Data Mining and Knowledge Discovery*, 1997, 1: 55-77.
- [45] Kuhn M, Johnson K. *Feature Engineering and Selection: A Practical Approach for Predictive Models*[M]. Boca Raton: Chapman & Hall/CRC Press, 2019.
- [46] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45: 5-32.
- [47] Elsayed A K. Shear capacity assessment of reinforced concrete beams with corroded stirrups[J]. *Construction and Building Materials*, 2017, 134: 176-184.