

文章编号:1673-9469(2024)03-0008-08

DOI:10.3969/j.issn.1673-9469.2024.03.002

多元算法融合模型的CFRP约束型钢 混凝土柱承载力预测

王奕斌¹,王向英^{1*},张纪刚¹,杨光超¹,王胜²,陈德刚²

(1. 青岛理工大学 土木工程学院, 山东 青岛 266033;

2. 青岛青建理工建筑工业化研究院有限公司, 山东 青岛 266033)

摘要: 为准确预测多影响因素下碳纤维增强复合材料(CFRP)约束型钢混凝土柱(SRCC)的轴压承载力,提出了一种基于随机森林(RF)、分类提升(Catboost)、极端梯度提升(XGBoost)、梯度提升回归树(GBRT)的多元算法融合预测模型。首先采用合成少数类过采样技术(SMOTE)算法对原始数据集进行扩充,开展了10种传统机器学习和集成学习模型试验,筛选出决定系数 R^2 均大于0.92的RF、Catboost、XGBoost、GBRT的4种集成学习模型,用随机搜索优化其超参数,然后融合形成了RF-Catboost-XGBoost-GBRT预测模型,对CFRP约束SRCC的承载力进行预测。结果表明,两种数据集下RF-Catboost-XGBoost-GBRT模型的预测性能最好,原始数据集经SMOTE算法处理后,5种预测模型 R^2 平均提高20.43%,其中RF-Catboost-XGBoost-GBRT模型的 R^2 达到了0.942,预测值误差均在 $\pm 10\%$ 以内。

关键词: 组合结构;型钢混凝土柱;集成学习;融合模型;纤维复合增强材料

中图分类号:TU398

文献标识码:A

Prediction of Bearing Capacity of CFRP-constrained Steel and Concrete Columns Based on Multivariate Algorithm Fusion Model

WANG Yibin¹, WANG Xiangying^{1*}, ZHANG Jigang¹, YANG Guangchao¹,
WANG Sheng², CHEN Degang²

(1. School of Civil Engineering, Qingdao University of Technology, Qingdao, Shandong 266033, China;

2. Qingdao Qingjian Research Institute of Construction Industrialization Co., Ltd., Qingdao, Shandong 266033, China)

Abstract: In order to accurately predict the axial compression bearing capacity of steel reinforced concrete columns (SRCC) confined by carbon fiber reinforced polymer (CFRP) under multiple influencing factors. A multivariate algorithm fusion prediction model based on Random Forest (RF), categorical boosting (Catboost), eXtreme Gradient Boosting (XGBoost) and gradient boosting regression tree (GBRT) is proposed. Firstly, the synthetic minority oversampling technique (SMOTE) algorithm is used to expand the original data set, and 10 kinds of traditional machine learning and ensemble learning model tests are carried out. Four ensemble learning models of RF, Catboost, XGBoost and GBRT with determination coefficients (R^2) greater than 0.92 are selected. The hyperparameters are optimized by random search, and then the RF-Catboost-XGBoost-GBRT prediction model is formed by fusion. The bearing capacity of CFRP confined steel reinforced concrete rectangular columns is predicted. The results show that the RF-Catboost-XGBoost-GBRT model shows the best prediction performance under the two datasets, and after the original dataset is processed by SMOTE, the R^2 of the five prediction models

收稿日期:2023-08-09

基金项目:国家重点研发计划资助项目(2017YFC0703600);国家自然科学基金(NSFC)-山东联合基金重点支持项目(U2106222);国家自然科学基金青年基金资助项目(52108282);山东省自然科学基金资助项目(ZR2021QE053)

作者简介:王奕斌(1999-),男,山东乳山人,硕士研究生,主要从事装配式结构抗震方面的研究。

*通信作者:王向英(1972-),男,黑龙江呼兰人,博士,副教授,主要从事结构抗震试验方法及混凝土装配式技术的研究。

is increased by an average of 20.43%, among which the R^2 of the RF-Catboost-XGBoost-GBRT model reaches 0.942, and the prediction error is within $\pm 10\%$.

Key words: combined structures; steel and concrete columns; integrated learning; fusion models; fiber composite reinforced material

20世纪80年代开始,型钢混凝土(Steel Reinforced Concrete, SRC)结构凭借承载力高、刚度大、耗能能力和变形能力好等特点^[1],在建筑行业得到广泛应用。碳纤维增强复合材料(Carbon Fiber Reinforced Polymer, CFRP)作为一种复合新型高性能材料,具有轻质、高比强度、高比刚度等优点^[2],能较好提高构件承载能力和变形能力^[3],在 SRC 结构加固应用中具有重要意义。

CFRP 约束型钢混凝土柱(Steel Reinforced Concrete Column, SRCC)承载力受到柱截面尺寸、偏心率、材料力学性能、加固方式和加固量、倒角半径等诸多因素影响^[4-6],表现出明显非线性特征。为了研究矩形混凝土柱的复杂受力机理,许多学者就 CFRP 加固 SRCC 在倒角半径、混凝土强度、截面高宽比、长细比、CFRP 加固率和加固方式等单一因素作用下轴压承载力进行了一系列试验和有限元研究^[7-13]。为了减小误差,机器学习成为了一种新的选择,机器学习以数据为基础,采用数据驱动建模的方法在土木工程领域已经应用非常广泛。如 Luo 等^[14]、Mangalathu 等^[15]、Huang 等^[16]根据实际数据建立了具有较强泛化能力的预测模型应用在土木工程领域,进而对工程中的未知工况进行精准预测。但由于机器学习的“黑箱”特性,限制了该方法的推广。为解决此问题,Štrumbelj 等^[17]基于博弈论理论提出了沙普利附加解释法,该方法用 Shapley 值来量化每个输入参数对输出参数的贡献,从而达到解释预测模型的目的。研究表明,小样本不平衡数据对建立模型的预测效果影响较大,模型对大样本量数据的规律学习更佳,而忽视小样本数据的内在规律^[18]。基于此,有学者将聚类算法和云模型结合、利用 Bootstrap 法等来扩充小样本数据集^[19]。这类方法可以对小样本数据进行扩充,但是不能解决数据不平衡的问题。2002年,有学者创造性地提出 SMOTE 算法,通过人工合成少数类样本来减小数据集失衡程度^[20],并且这种方法在许多领域得到了广泛应用。

基于上述研究背景,本文提出了一种基于 RF、Catboost、XGBoost、GBRT 多元算法融合模型预测 CFRP 约束 SRCC 轴压承载力的方法。首先收集了 CFRP 约束 SRCC 相关试验研究的小样本数据,

通过 SMOTE 算法对收集的试验数据进行处理,并扩充样本集,解决了样本不平衡问题。对该数据特征筛选后,对比了 7 种集成学习算法和 3 种传统机器学习算法的预测性能,并采用随机搜索算法对 R^2 均大于 0.92 的 Catboost、RF、XGBoost、GBRT 集成学习模型进行超参数优化。将 4 种超参数优化后的模型建立联系并结合,形成集成学习融合模型(RF-Catboost-XGBoost-GBRT 融合模型)来预测 CFRP 约束 SRCC 轴压承载力。

1 数据准备及预处理

1.1 试验样本收集及 SMOTE 算法处理

与研究 CFRP 加固矩形混凝土柱的文献^[21]不同,CFRP 加固混凝土型钢柱的研究成果相对较少,基于文献^[7-13]中描述预载水平(11个)、倒角半径(9个)、截面高宽比(8个)、长细比(5个)、纵筋配筋率(5个)、混凝土强度等级(6个)、CFRP 加固率和加固形式(10个)影响因素对 CFRP 约束 SRCC 柱轴压承载力影响的试验原始数据合计 54 个,各参数的试验样本数量相对较少。由于机器学习算法不善于对少数类样本的基本规律进行学习,因此,为全面研究在多因素影响下 CFRP 约束 SRCC 柱轴压承载力变化,并建立精度更高的预测模型,首先须对单一影响因素的试验数据进行扩充和均衡。

收集的原始数据各类样本数最大为 11,最小为 5,为小样本数据集。原始收集数据各类别之间占比不均衡,描述预载水平影响的数据集占比为 20.4%,而描述长细比、纵筋配筋率影响的数据集占比仅为 9.3%,若直接使用该数据集建立预测模型,则机器学习模型无法充分学习长细比和纵筋配筋率对 SRCC 承载力影响。

随机过采样的核心思想是随机地复制、重复少数类样本,最终使得少数类与多数类的个数相同从而得到一个新的均衡的数据集。SMOTE 算法是随机过采样技术的改进方法,克服了随机过采样技术过拟合的缺点,其基本思想是对少数类样本进行分析,并由少数类样本采用人工合成新样本,并添加到数据集中^[22]。具体 SMOTE 算法流

程如下:

(1)对于少数类中每一个样本 X_i ,以欧氏距离为标准计算其到少数类样本集中所有样本的距离,得到其 k 近邻;

(2)根据样本不平衡比例设置一个采样比例以确定采样倍率 N ,对于每一个少数类样本 X_i ,从其 k 近邻中随机选择若干个样本,假设选择的近邻为 X_n ;

(3)对于每一个随机选出的近邻 X_n ,分别与原样本按照如下公式构建新的样本。

$$X_{\text{new}} = X_i + r(X_i - X_n) \quad (1)$$

式中: X_{new} 、 X_i 、 X_n 分别表示新样本、少数类样本及其近邻样本的特征(坐标)值, r 表示 $0 \sim 1$ 的随机数。

SMOTE 算法处理前后数据集对比情况见表 1,处理后样本集的样本数量和均衡程度均得到较好改善,为建立预测模型提供了数据基础。

表 1 SMOTE 算法处理前后数据对比
Tab. 1 Comparison of data before and after SMOTE algorithm processing

	原始数据集	SMOTE 算法处理后数据集
样本集总数	54	325
均衡程度	11 : 9 : 8 : 5 : 5 : 6 : 10	43 : 45 : 46 : 48 : 51 : 48 : 44

1.2 数据特征筛选

数据和特征基本决定了机器学习的上限,模型和算法会逼近这个上限^[23]。本文收集的样本数据特征主要包括试验试件的几何尺寸、材料性能参数、CFRP 布置形式、倒角半径、预载水平、截面高宽比、长细比、轴压承载力等。

本文模型建立输入参数选择主要分为两类:第一类主要与柱初始设计参数有关,包括柱截面高宽比(ω)、长细比(α)、纵筋直径(d/mm)、纵筋配筋率($\rho/\%$)、混凝土立方体抗压强度(f_c/MPa)、混凝土弹性模量(E_c/MPa);第二类主要包括后期设计参数,包括 CFRP 层数(n)、CFRP 布置方式(m)、CFRP 条带宽度(θ/mm)、CFRP 条带间距(β/mm)、倒角半径(R/mm)、预载水平(τ)。输出参数为 CFRP 约束 SRCC 的屈服荷载 F/kN 。

1.3 集成学习

机器学习算法可以通过给定数据建立输入和输出数据的映射关系,相对于传统经验公式拟合具有更高精度,其求解过程可以看作是在假想空

间中搜索具有强泛化能力的学习模型,但往往最佳学习模型的搜索比较困难。集成学习作为机器学习的延伸,通过组合多个机器学习来完成回归或分类任务,相较于单个机器学习模型具有高精度和泛化能力,能够更高效地解决工程中的实际问题。根据个体学习器的不同生成方式、个体学习器间是否存在强依赖关系以及串并行生成方式,目前集成学习大致分成 Boosting 和 Bagging 两类。

2 多元算法融合模型建立

按照图 1 所示流程,建立基于小样本 RF-Catboost-XGBoost-GBRT 融合模型预测 CFRP 约束 SRCC 轴压承载力。具体流程见图 1。

2.1 数据集划分

本文对由 SMOTE 算法扩充的 325 个 CFRP 约束 SRCC 数据集采用随机抽样方式,按照 2 : 8 划分测试集和训练集,训练集用于模型训练,测试集用于训练模型验证。

2.2 多种模型试验

为得到 CFRP 约束 SRCC 轴压承载力预测精度较高的模型,本文选择 Bagging 算法中的随机森林、ExtraTrees 算法和 Boosting 算法中的 GBRT、Adaboost、CatBoost、XGBoost、LightGBM 算法来建立集成预测模型,并采用传统机器学习中的 BP 神经网络、支持向量机(SVR)、岭回归(KNN)算法作对比,以上模型均采用默认参数设置。模型训练完成后采用决定系数(R^2)、均方根误差(RMSE)、平均绝对误差(MAE)三个评价指标对回归预测模型的精度进行评估。其中 R^2 是将预测值跟只使用均值的情况下相比,结果越靠近 1 模型准确度越高,MAE 能反映预测值误差的实际情况,取值越小,模型准确度越高, RMSE 为均方误差的平方根,取值越小,模型准确度越高。

图 2 中数字 1—10 为预测模型决定系数 R^2 排序,排名越靠前说明 R^2 越接近 1,表明模型预测精度越好。从图 2(a)可以看出,左侧 7 种集成学习算法的 R^2 明显高于 3 种传统机器学习。集成学习算法中 Catboost、RF、XGBoost、GBRT 四种算法预测精度较好, R^2 均达到 0.90 以上,其中 Catboost 的 R^2 最高为 0.938 0;传统机器学习中, BP 神经网络和 KNN 与集成学习算法的 R^2 相差不大,均达到 0.7 以上,但 SVR 相对其他算法的 R^2 明显较低,

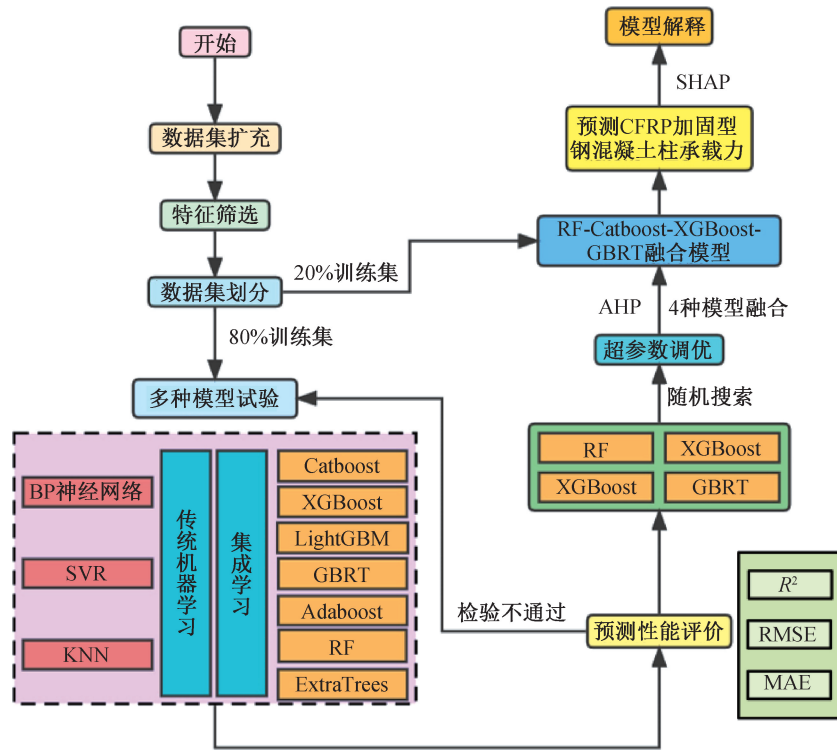

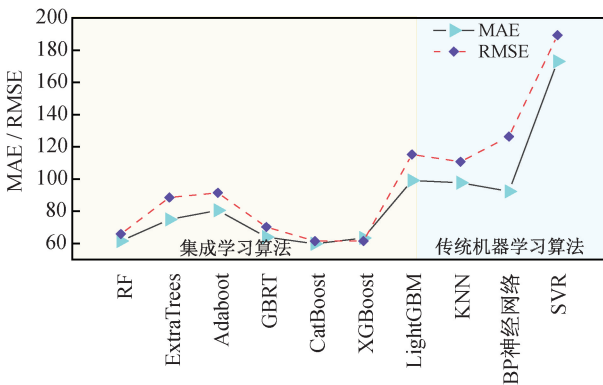


图 1 多元算法融合模型建立流程图

Fig. 1 Flowchart for establishing the multivariate algorithm fusion model



(a) 10种模型预测R²



(b) 10种模型预测MAE和EMSE

图 2 10 种模型预测结果

Fig. 2 Prediction results of 10 models

仅为 0.28, 预测性能较差。由图 2(b) 可看出, 集成学习算法的 MAE 和 RMSE 均比传统机器学习算法较小, 相对其他算法 Catboost、RF、XGBoost、GBRT 四种算法的 MAE 和 RMSE 相对较小, 说明在这 10 种算法中预测性能最佳, 而 SVR 的 MAE 和 RMSE 较大, 不能很好地预测 CFRP 约束 SRCC 轴压承载力。综合以上分析, 本文选择预测性能优越的 Catboost、RF、XGBoost、GBRT 四种集成学习算法作为后续加权融合 CFRP 约束 SRCC 轴压承载力预测模型的基础。

2.3 超参数调优

机器学习中, 模型的参数很难通过人为方式直接设置为最优参数。通常需要采用网格搜索、随机搜索、贝叶斯优化或一些启发式算法对超参数进行优化, 给预测模型选择一组最优超参数, 提高模型的预测性能和效果。网格搜索就是对网格中的每个交点进行遍历, 从而找到最优组合, 这种方法效果较好, 但需要对整个参数空间进行搜索, 计算代价较大。随机搜索的优势在于搜索效率高, 对于复杂问题应用较为容易。故本文设置了 10 折交叉验证以预测模型性能的平均得分, 为了实现目标采用随机搜索对 Catboost、RF、XGBoost、GBRT 四种模型的超参数进行搜索, 以寻求更优预测性能。四种模型的超参数调优过程如图 3 所示,




图3 超参数调整过程

Fig. 3 Hyperparameter adjustment process

平面坐标表示两个超参数,纵坐标表示预测模型性能平均得分。

通过图 3(a)可以看出,RF 模型的预测平均得分随着树的数量值的增大先快速增大后慢慢趋于平稳,其随着特征的最大选择数量值的增加小幅度波动,在最大选择数量值为 2 附近时预测性能较好;通过图 3(b)可以看出,GBRT 模型的预测性能随着树的最大深度值的增大有所降低,在最大深度值为 5 附近预测性能最佳,而树的数量值在 100 以内时的预测性能更好;通过图 3(c)可以看出,在子样本取值为 0.1 左右时 XGBoost 模型预测性能出现明显的峰值,其预测性能随着特征比例取值增加而上下波动,在特征比例值为 0.7 左右预测效果相对较好;通过图 3(d)可以看出,Catboost 模型的预测性能随着次迭代和学习比率值的增加而先增加后小幅度波动,在次迭代值为 150、学习比率值为 0.15 时预测性能达到最佳。超参数调整范围和结果如表 2 所示,调参前后四种模型的评价指标 R^2 、MAE、RMSE 变化情况如图 4 所示。

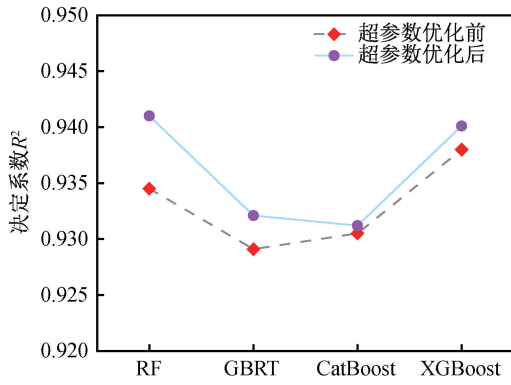
通过图 4(a)可以看出,经过超参数优化后四

个预测模型的 R^2 均有所提高,RF 和 GBRT 模型提高较为明显,而 Catboost 和 XGBoost 模型 R^2 提高幅度较小;通过图 4(b)(c)可以看出,4 种模型的 MAE 和 RMSE 均有所减小,仍然是 RF 和 GBRT 模型减小幅度较大,而 Catboost 和 XGBoost 模型减小幅度较小。综合来看,尽管调整前后评价指标变化不是特别明显,但是当精度达到 0.9 以上时,想

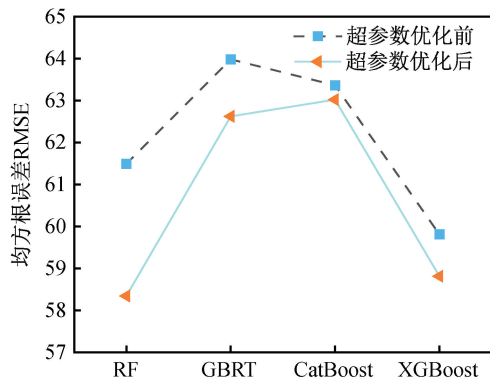
表 2 RF、GBRT、XGBoost、Catboost 超参数调整

Tab. 2 RF, GBRT, XGBoost, Catboost

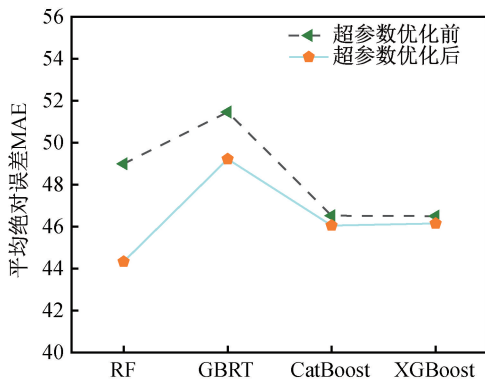
hyperparameter adjustment			
算法类型	参数名称	调参范围	调参后参数取值
RF	数的数量	[1,100]	2.0
	最大选择数量	[1,8]	25
GBRT	数的最大深度	[2,20]	5.0
	数的数量	[20,200]	69
XGBoost	子样本	[0.1,0.9]	0.1
	特征比例	[0.1,0.9]	0.7
Catboost	学习比率	[0.01,0.15]	0.04
	次迭代	[50,300]	300



(a) 决定系数 R^2 变化情况



(b) 均方根误差 RMSE 变化情况



(c) 平均绝对误差 MAE 变化情况

图 4 超参数优化前后评价指标变化情况

Fig. 4 Changes in evaluation indicators before and after hyperparameter optimization

要进一步提升模型的精度难度较大,能够小幅度提升模型预测精度本身就已经很不容易,因此采用随机搜索对 4 种模型的超参数调优有一定效果,进一步提高了模型的预测精度,经过超参数调优后 Catboost、RF、XGBoost、GBRT 四种模型的 R^2 均达到 0.93 以上,分别为 0.940 1、0.941 0、0.931 2、0.932 1。

2.4 RF-Catboost-XGBoost-GBRT 融合预测模型建立

鉴于每种预测模型的优势各不相同,为实

现 4 种超参数调优后的预测模型的优势互补。本文建立了 RF-Catboost-XGBoost-GBRT 集成算法加权融合预测模型对 CFRP 加固型钢混凝土柱的轴压承载力进行预测。其中融合权重根据四种预测模型精度采用层次分析法 (Analytical Hierarchy Process, AHP) 获得,再由 4 种预测模型的权重进行加权融合输出新的预测值。具体步骤如下:

(1) 根据调优后的决定系数 R^2 大小顺序构建 Catboost、RF、XGBoost、GBRT 四种模型的评价矩阵,如表 3 所示。

表 3 模型评价矩阵

Tab. 3 Model evaluation matrix

模型名称	XGBoost	GBRT	Catboost	RF
XGBoost	1.00	0.50	0.33	0.25
GBRT	2.00	1.00	0.50	0.33
Catboost	3.00	2.00	1.00	0.50
RF	4.00	3.00	2.00	1.00

(2) 根据模型评价矩阵求得模型权重,但评价矩阵构建的偏离应有一个度,为此通过一致性检验判断评价矩阵是否可以接受。通过表 4 可以看出 RF 模型的权重最大为 46.685%,XGBoost 的权重最小为 9.53%。根据 RI 表查到对应的 RI 值为 0.882,因此, $CR = CI/RI = 0.012 < 0.1$,满足一致性检验要求。

(3) 根据 4 种预测模型的权重进行融合构成集成算法加权融合预测模型,其预测输出值 Y 如下:

$$Y = \sum_{i=1}^4 w_i e_i \quad (2)$$

式中: w_i 为模型对应权重, e_i 为 4 种对应预测模型。

表 4 AHP 层次分析结果

Tab. 4 Analysis results of AHP

模型名称	权重值/%	CI 值	RI 值	CR 值	检验结果
XGBoost	9.530	0.010	0.882	0.012 < 0.100	通过
GBRT	16.027				
Catboost	27.759				
RF	46.685				

3 结果分析

3.1 原始数据集与 SMOTE 扩充数据集预测性能对比

为验证 SMOTE 算法对原始数据集扩充后的

有效性,采用性能相对优越的 Catboost、RF、XGBoost、GBRT 四种超参数优化后的模型和建立的集成算法加权融合预测模型,对原始数据和 SMOTE 扩充数据集的预测性能进行比较,比较结果如图 5 所示。

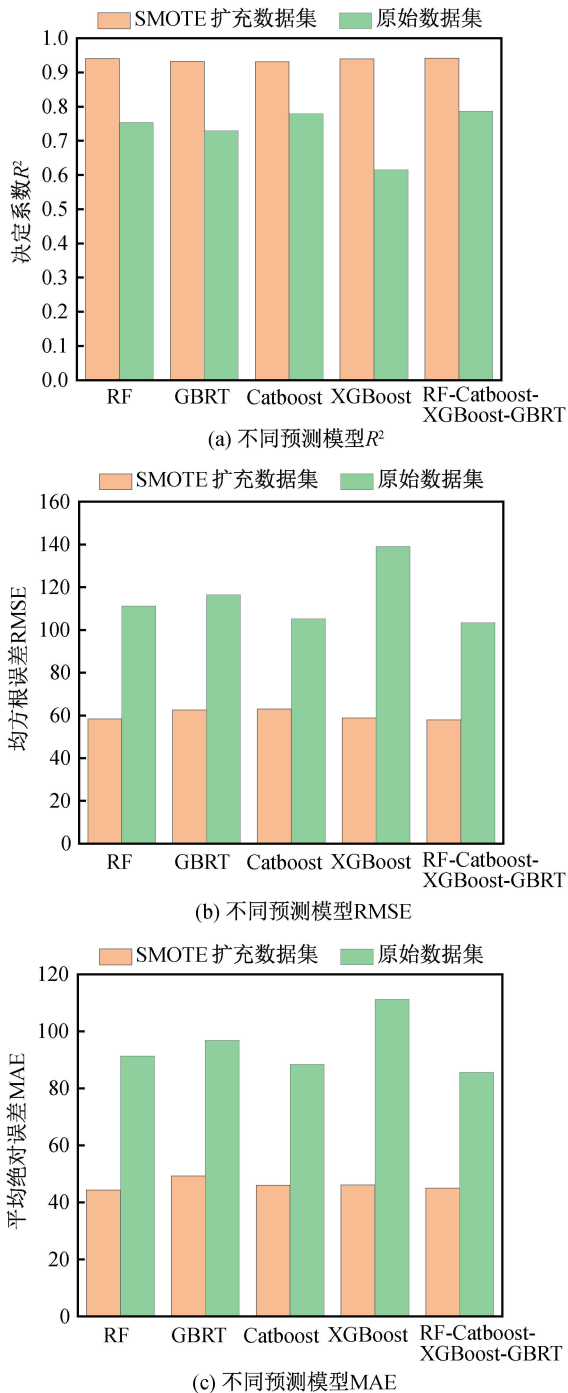


图 5 SMOTE 扩充数据前后预测性能对比

Fig. 5 Comparison of predictive performance before and after SMOTE data augmentation

通过图 5(a) 可看出,使用原始数据集的 5 种预测模型的 R^2 除了 XGBoost 模型为 0.614 9 外,

其他 4 种模型 R^2 均在 0.7~0.8 之间,经过 SMOTE 算法扩充数据后 5 种预测模型的 R^2 均有较大幅度提升,均达到 0.93 以上。Catboost、RF、XGBoost、GBRT 和 RF-Catboost-XGBoost-GBRT 融合模型分别提升 18.72%、20.24%、15.17%、32.52%、15.51%,平均提升 20.43%。XGBoost 模型的 R^2 提升最明显,两种数据集下 RF-Catboost-XGBoost-GBRT 融合模型的 R^2 均比另外 4 种预测模型大。通过图 5(b)(c) 可以看出,使用 SMOTE 扩充数据集后 5 种预测模型的 RSME、MAE 均有大幅降低。Catboost、RF、XGBoost、GBRT 和 RF-Catboost-XGBoost-GBRT 融合模型 RSME 分别降低了 47.51%、46.23%、40.10%、57.69%、44.02%,平均降低 47.11%;5 种模型 MAE 分别降低了 51.42%、49.19%、47.93%、58.51%、47.35%,平均降低 50.88%。XGBoost 模型 RMSE 和 MAE 降低最为明显,两种数据集下 RF-Catboost-XGBoost-GBRT 融合模型性能最好。因此,经过 SMOTE 处理后的数据集能够有效提高预测模型的预测性能,且两种数据集下 RF-Catboost-XGBoost-GBRT 融合模型的预测精度和性能均为最好。

3.2 基于 SMOTE 扩充数据集的 RF-Catboost-XGBoost-GBRT 融合模型预测性能比较

图 6 为 RF-Catboost-XGBoost-GBRT 融合模型的预测值与真实承载力的对比情况,从中能够直观地看出 RF-Catboost-XGBoost-GBRT 融合模型的预测承载力均在 $\pm 10\%$ 的误差范围内,可见其对于 CFRP 加固型钢混凝土柱的轴压承载力预测效果较好。图 7 为 RF-Catboost-XGBoost-GBRT 融合模

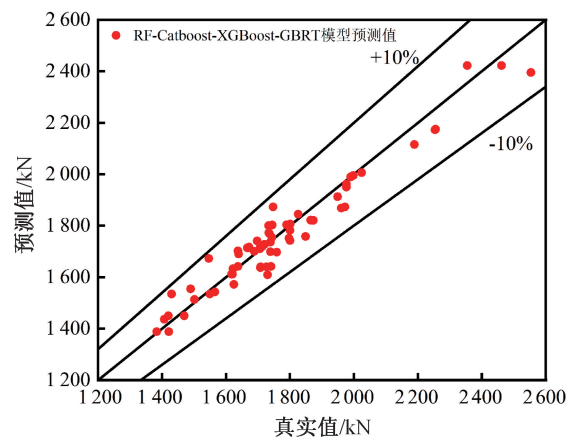


图 6 RF-Catboost-XGBoost-GBRT 预测值误差情况

Fig. 6 Errors of values predicted by RF-Catboost-XGBoost-GBRT




图 7 RF-Catboost-XGBoost-GBRT 预测和真实承载力比较
Fig. 7 Comparison of RF-Catboost-XGBoost-GBRT prediction and real bearing capacity

型在测试集上预测值和真实承载力的拟合情况,整体来看,该预测模型能够较好地与真实承载力进行拟合,仅局部样本拟合偏差较大,且误差均在 10% 以内。

表 5 为 RF-Catboost-XGBoost-GBRT 融合模型与 Catboost、RF、XGBoost、GBRT 四种超参数优化后的预测性能指标值。其中 RF-Catboost-XGBoost-GBRT 融合模型的 R^2 最大,相对于 RF、GBRT、XGBoost、Catboost 模型分别提高了 0.1%、0.99%、0.19%、1.08%; RF-Catboost-XGBoost-GBRT 融合模型的 RMSE 均比 RF、GBRT、XGBoost、Catboost 四种模型低; RF-Catboost-XGBoost-GBRT 融合模型的 MAE 仅次于 RF,且两者仅相差 0.71。总的来看,RF-Catboost-XGBoost-GBRT 融合模型比 4 种超参数优化后的集成学习模型预测性能更好。

表 5 不同模型预测性能指标对比

Tab. 5 Comparison of performance indicators predicted by different models

模型名称	R^2	RMSE	MAE
RF	0.941 0	58.34	44.33
GBRT	0.932 1	62.62	49.22
XGBoost	0.931 2	63.02	46.05
Catboost	0.940 1	58.81	46.15
RF-Catboost-XGBoost-GBRT	0.942 0	57.88	45.04

4 结论

1) Catboost、RF、XGBoost、GBRT 和 RF-Catboost-XGBoost-GBRT 融合模型使用 SMOTE 算法扩充数据集其预测性能评价指标得到大幅度提升,5

种模型的 R^2 平均提升 20.43%, RMSE 平均降低 47.11%, MAE 平均降低 50.88%, 其中 XGBoost 模型性能提升尤为明显。

2) 相较于 BP 神经网络、KNN、SVR 三种传统机器学习算法,集成学习算法的预测性能更加优越,其中 Catboost、RF、XGBoost、GBRT 四种集成学习模型的预测性能最好, R^2 均达到了 0.92 以上,经过超参数优化后四种模型的预测性能进一步得到提升, R^2 均达到了 0.93 以上。

3) 本文提出的 RF-Catboost-XGBoost-GBRT 多元算法融合模型结合了 Catboost、RF、XGBoost、GBRT 集成学习模型的优势,预测准确性得到进一步提高。对 CFRP 加固 SRCC 的轴压承载力预测值均在 $\pm 10\%$ 的误差范围内,可取得与真实值较好的拟合效果。

参考文献:

- [1] 郑山锁, 邓国专, 李磊, 等. 型钢高强高性能混凝土框架结构抗震性能的试验研究[J]. 工程力学, 2009 (5): 88-93.
- [2] ZHENG H, ZHANG W, LI B, et al. Recent advances of interphases in carbon fiber-reinforced polymer composites: A review [J]. Composites Part B: Engineering, 2022, 233: 109639.
- [3] 卢亦焱, 黄银燊, 张号军, 等. FRP 加固技术研究新进展[J]. 中国铁道科学, 2006, 27(3): 34-42.
- [4] 高鹏, 赵元鸿, 洪丽, 等. 圆角半径对碳纤维增强聚合物复合材料布约束型钢混凝土矩形短柱轴压性能的影响[J]. 复合材料学报, 2020, 37(4): 775-785.
- [5] 黄真锋, 孙志雄, 张素梅, 等. 闭口型压型钢板混凝土组合剪力墙轴压性能试验研究[J]. 建筑结构学报, 2019, 40(S1): 84-90.
- [6] 李文, 谷长霖, 梅宝瑞. 偏心率对 CFRP 钢管约束混凝土柱力学性能的影响[J]. 河北工程大学学报(自然科学版), 2020, 37(01): 7-11.
- [7] 宗文. 倒角半径对碳纤维布约束型钢混凝土矩形短柱轴压性能的影响[D]. 合肥:合肥工业大学, 2016.
- [8] 王健. 碳纤维布约束有预载型钢混凝土矩形短柱轴压性能研究[D]. 合肥:合肥工业大学, 2015.
- [9] 彭飞. 截面高宽比对 CFRP 约束型钢混凝土矩形柱轴压性能的影响[D]. 合肥:合肥工业大学, 2017.
- [10] 丁磊. 长细比对 CFRP 加固型钢混凝土柱轴压性能的影响[D]. 合肥:合肥工业大学, 2017.
- [11] 殷强. 加固率和加固方式对碳纤维布条带约束型钢混凝土柱轴压性能的影响[D]. 合肥:合肥工业大学, 2016.

(下转第 31 页)

- [3] 欧阳建新, 郭荣鑫, 万夫雄, 等. 玄武岩复合材料增强 ECC 受拉性能及裂缝控制机理[J]. 硅酸盐通报, 2022, 41(8): 2684-2695.
- [4] ALI A Y, HAMEED M. Analysis for behavior of reinforcement lap splices in deep beams[J]. Journal of University of Babylon for Engineering Sciences, 2018, 26(5): 347-361.
- [5] ZHANG N, GU Q, WU Y, et al. Refined peridynamic modeling of bond-slip behaviors between ribbed steel rebar and concrete in pull-out tests[J]. Journal of Structural Engineering, 2022, 148(12): 04022197.
- [6] NILSON A H. Internal measurement of bond slip[J]. Journal proceedings, 1972, 69(7): 439-441.
- [7] 狄生林. 钢筋混凝土粘结力与滑移关系的试验研究[D]. 南京: 东南大学, 1981.
- [8] 金芷生, 朱万福, 庞同和. 钢筋与混凝土粘结性能试验研究[J]. 南京工学院学报, 1985, 2: 73-85.
- [9] 滕智明, 王传志. 钢筋混凝土结构理论[M]. 北京: 中国建筑工业出版社, 1985.
- [10] 徐有邻. 变形钢筋-混凝土粘结锚固性能的试验研究[D]. 北京: 清华大学, 1990.
- [11] KANKAM C K. Relationship of bond stress, steel stress, and slip in reinforced concrete[J]. Journal of Structural Engineering, 1997, 123(1): 79-85.
- [12] 蒋德稳, 邱洪兴. 拔出型试验钢筋与混凝土间滑移量的简化解法[J]. 东南大学学报(自然科学版), 2009, 39(04): 830-834.
- (责任编辑 王利君)
-
- (上接第 15 页)
- [12] 童林. 不同混凝土强度等级下 CFRP 约束型钢混凝土矩形短柱轴压性能研究[D]. 合肥: 合肥工业大学, 2017.
- [13] 吴宜龙. CFRP 约束型钢混凝土矩形短柱轴压承载力设计方法研究[D]. 合肥: 合肥工业大学, 2018.
- [14] LUO H, PAAL S G. Machine learning-based backbone curve model of reinforced concrete columns subjected to cyclic loading reversals[J]. Journal of Computing in Civil Engineering, 2018, 32(5): 04018042.
- [15] 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.
- [16] 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: 100767.
- [17] ŠTRUMBELJ E, KONONENKO I. Explaining prediction models and individual predictions with feature contributions[J]. Knowledge and Information Systems, 2014, 41: 647-665.
- [18] CAKIROGLU C, ISLAM K, BEKDAŞ G, et al. Interpretable Machine Learning Algorithms to Predict the Axial Capacity of FRP-Reinforced Concrete Columns[J]. Materials, 2022, 15(8): 2742.
- [19] DING H, LU Y, SZE N N, et al. A deep generative approach for crash frequency model with heterogeneous imbalanced data[J]. Analytic Methods in Accident Research, 2022, 34: 100212.
- [20] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16: 321-357.
- [21] CHOO C C, HARIK I E, GESUND H. Strength of rectangular concrete columns reinforced with fiber-reinforced polymer bars[J]. ACI Materials Journal, 2006, 103(3): 452.
- [22] ZHOU Z, CHEN H, LI G, et al. Data-driven fault diagnosis for residential variable refrigerant flow system on imbalanced data environments[J]. International Journal of Refrigeration, 2021, 125: 34-43.
- [23] 陈锋, 李张铮, 庄毅莹. 基于 GBDT 算法的潜在 5G 用户预测研究与实现[J]. 邮电设计技术, 2021(04): 45-49.
- (责任编辑 王利君)