

钢纤维混凝土力学强度的可解释机器学习建模与预测

林 朗^{1,4}, 盛小龙², 徐金俊³, 肖钊名¹, 余 勇⁴

(1. 佛山大学土木与交通学院, 广东 佛山 528225; 2. 江西省勘察设计院有限公司, 南昌 330095; 3. 南京工业大学土木工程学院, 南京 211816; 4. 华南理工大学, 亚热带建筑与城市科学国家重点实验室, 广州 510641)

摘 要: 掺入钢纤维虽能显著提升素混凝土的强度与韧性, 但也导致其力学响应更为复杂, 随机性和不可预测性增强。为深入探究钢纤维混凝土的抗压与劈拉强度, 本工作构建了一个包含 636 组试验样本的数据库, 特别涵盖了粗骨料尺寸、纤维形状、几何特征及含量等关键变量。基于此数据库, 随即开发并对比了 5 种人工智能预测模型: 随机森林(RF)、梯度提升回归树(GBRT)、极端梯度提升(XGB)、轻量级梯度提升机(LGBM)和贝叶斯神经网络(BNN)。在有效预防过拟合与欠拟合的基础上, 详细评估了各模型的预测精度与鲁棒性, 并结合沙普利加性解释(SHAP)值分析、部分依赖图(PDP)和个体条件期望(ICE)等解释技术揭示模型的内部机制。结果显示: 模型在测试集上的决定系数(R^2)介于 0.84~0.90 之间, 训练集 R^2 介于 0.80~0.90, 差距较小, 均高于 0.75, 展现出良好的预测能力与泛化性能, 其中以 LGBM 模型表现最佳。变量贡献分析表明, 影响抗压强度的关键因素依次为水灰比、砂率、纤维增强系数、骨灰比与粗骨料最大粒径; 而劈拉强度主要受纤维增强系数、砂率和水灰比控制。

关键词: 钢纤维混凝土; 抗压强度; 劈拉强度; 机器学习; 性能评估

中图分类号: TU528 文献标志码: A 文章编号: 0454-5648(2026)05-1791-12

网络出版时间: 2025-12-16



传统混凝土因抗拉性能先天不足, 长期面临“易裂难愈”的技术瓶颈: 其抗拉强度通常仅为抗压强度的 1/16~1/8, 极易开裂, 进而显著削弱结构的韧性与耐久性。为改善这一固有缺陷, 研究人员提出了钢纤维增强混凝土^[1-3]。该类材料通过短切钢纤维在裂缝扩展过程中的桥接作用, 显著提升了抗裂性能、延展能力与服役耐久性, 展现出在桥梁结构、海洋工程和防爆设施等领域的广泛应用前景。

然而, 钢纤维的引入虽显著提升了混凝土的力学性能, 却也使其力学响应更趋复杂与非线性。如何精准评估其力学强度, 已成为保障结构安全与工程可行性的关键问题。目前, 力学指标评估仍以试验研究为主, 辅以经验模型构建。在已有研究中, Abbass 等^[2]、白敏等^[3]和常虹等^[4]采用线性回归方法, 基于水灰比、纤维体积分数等关键变量进行强度预测; 王艳^[5]结合复合材料理论, 探讨钢纤维混凝土各类强度与抗压强度的内在关系, 并提出经验

公式; 李德春等^[6]与刘杰^[7]则分别聚焦抗压强度与内部配比参数之间的耦合效应, 构建了相应的预测框架。尽管上述模型在理论上有所拓展, 但受限于样本规模和变量维度, 普遍适用性较弱, 难以满足复杂工程条件下的性能评估需求, 进而制约了钢纤维混凝土的推广应用。

近年来, 随着计算机科学及相关技术的迅速发展, 机器学习为钢纤维混凝土力学性能的研究与评估开辟了新的路径。相比传统分析方法, 机器学习在建模非线性关系、处理大规模数据以及进行性能预测等方面展现出更强的适应性与准确性^[8, 9]。目前, 该方法在钢纤维混凝土领域已有一定应用进展。例如, Acikgenc 等^[10]基于反向传播神经网络(BPANN)构建了考虑水灰比与纤维体积率的抗压强度预测模型; Karahan 等^[11]则将 BPANN 与非线性回归相结合, 系统分析了粉煤灰掺量变化对混凝土强度的影响。

收稿日期: 2025-07-09。 修订日期: 2025-08-07。

基金项目: 国家自然科学基金(52008108, 51708289); 广东省基础与应用基础研究基金面上项目(2026A1515012214)。

第一作者: 林 朗(1992—), 男, 博士, 讲师。

通信作者: 余 勇(1990—), 男, 博士, 副教授。

Received date: 2025-07-09. Revised date: 2025-08-07.

First author: LIN Lang (1992—), male, Ph.D., Lecturer.

E-mail: bbtbfbi@163.com

Correspondent author: YU Yong (1990—), male, Ph.D., Associate Professor.

E-mail: yuyong1990@foxmail.com

尽管既有研究初步展现了机器学习在钢纤维混凝土性能预测中的应用潜力,但该领域仍面临若干关键挑战。一方面,钢纤维混凝土受多种因素共同影响,除传统的水泥、砂、石等参数外,还涉及纤维含量、形状、几何特征以及骨料与纤维之间的相互作用,当前研究对此多未充分考虑;另一方面,现有研究的样本规模普遍较小,限制了模型的泛化能力。此外,现有多数机器学习模型依赖高度复杂的“黑箱”算法,缺乏足够的透明度与可解释性,从而在一定程度上影响了其在工程实践中的信任基础与推广前景。因此,有必要构建大规模、高质量的试验数据库,并开发兼具高预测精度与良好可解释性的模型,以推动该技术在工程实践中的可靠应用和更广泛的接受度。

基于上述背景,本工作开展了以下三方面的研究:1)在详细梳理现有文献的基础上,构建并整理了涵盖 636 组试验样本的钢纤维混凝土抗压强度与劈拉强度数据库,纳入了诸多此前模型未充分考虑的因素,如粗骨料最大粒径、纤维形状与长径比等,这为后续建模提供了坚实的数据基础;2)构建并评估了 5 类主流机器学习模型,包括随机森林(RF)、梯度提升回归树(GBRT)、极端梯度提升(XGB)、轻量级梯度提升机(LGBM)以及新兴的深度学习模型——贝叶斯神经网络(BNN),并系统对比其预测性能,以筛选最具潜力的力学强度预测工具;3)引入沙普利加性解释(SHAP)值、部分依赖图(PDP)和个体条件期望(ICE)等技术,对模型决策逻辑和关键影响因素进行了深入解析,揭示其内在机制及变量间的相互作用。

1 试验数据库建立

本工作基于 24 项独立试验研究^[2-7, 12-29],建立

了 1 个涵盖 636 组钢纤维混凝土性能数据的综合数据库,其中包括 419 组抗压强度记录和 217 组劈拉强度记录。由于不同学者在试验方案与操作细节上存在一定差异,为保证数据的一致性与可比性,本工作在数据库构建过程中统一采用了以下筛选原则:1)胶凝材料仅限于普通硅酸盐水泥,粗细骨料必须来源于天然材料,钢纤维须为单一品种,禁止混掺;2)所有试件均需在 20 °C、95%湿度条件下养护不少于 14 d;3)抗压强度与劈拉强度测试均须采用静力加载,加载速率分别控制在 0.3~0.8 MPa/s 和 0.02~0.10 MPa/s 区间;4)所有获得的抗压强度与劈拉强度结果最终均需统一换算为 150 mm 特征尺寸的圆柱体强度与立方体强度。

在本数据库中,636 组样本均包含若干与混凝土配合比密切相关的关键变量,包括水灰比(w/c)、砂率(s/a)、骨灰比(a/c)、粗骨料最大粒径($g_{\max}$)、纤维形状系数(ρ_f)、纤维长径比(L_f/d_f)、纤维体积分数(V_f),以及对应的力学性能指标——圆柱体抗压强度(f_c)或劈拉强度(f_t)。 ρ_f 依据文献[29]定义:端钩型(hooked)纤维取值 1.00,波浪型(wave)为 0.75,端尾型(tail-ended)、铣削型(milled)和平直型(straight)统一赋值 0.50,以体现不同纤维形状对混凝土界面粘结性能的差异。值得一提的是,与现有研究相比,本数据库在数据完整性和变量覆盖范围方面更为全面,较为完整地纳入了纤维和基体的特征变量。该数据库已在 GitHub 平台开源,详见 <https://github.com/Lang-Lin/SFRC-database/blob/main/Database-SFRC.xls>。表 1 汇总了数据库中各输入、输出变量的统计特征。由表 1 可见:

1) 钢纤维混凝土的 w/c、s/a、a/c 及 $g_{\max}$ 分别分布于 0.29~0.69、0.29~0.77、2.38~7.68 和 10~40 mm 区间,基本覆盖了常规混凝土配比设计

表 1 钢纤维混凝土数据库参数的统计特征

Table 1 Statistical characteristics of steel fiber concrete database parameters

Parameters	w/c	s/a	a/c	$g_{\max}/\text{mm}$	ρ_f	L_f/d_f	$V_f/\%$	f_c/MPa	f_t/MPa
Maximum value	0.69	0.77	7.68	40.00	1.00	84.51	3.00	74.86	10.48
Minimum value	0.29	0.29	2.38	10.00	0.00	26.56	0	16.00	1.95
Mean	0.47	0.43	4.87	19.35	0.76	57.87	0.74	40.85	4.68
Standard deviation	0.09	0.08	1.18	5.54	0.38	16.20	0.55	11.99	1.50
Standard error	0.00	0.00	0.06	0.27	0.02	0.87	0.03	0.59	0.10
Median	0.47	0.41	4.65	20.00	1.00	58.33	0.60	37.98	4.37
Mode	0.50	0.38	4.50	20.00	1.00	80.00	1.00	33.28	4.28
Kurtosis	-0.95	3.94	-0.74	2.41	-0.03	-1.14	0.09	-0.11	1.96
Skewness	0.12	1.63	0.38	0.88	-1.28	0	0.60	0.78	1.17

Note: w/c is water-to-cement ratio; s/a is sand-to-aggregate ratio; a/c is aggregate-to-cement ratio; $g_{\max}$ is maximum coarse aggregate size; ρ_f is fiber shape factor; L_f/d_f is fiber aspect ratio; V_f is fiber volume fraction; f_c is compressive strength; f_t is splitting tensile strength.

的典型范围。

2) 纤维体积分数 V_f 取值介于 0~3%，不仅包含工程中常用的 0~2% 区间，也涵盖部分研究为探究增强极限而采用的较高掺量^[30]。

3) 混凝土圆柱体抗压强度 f_c 分布于 16~75 MPa，涵盖从普通强度至高强度混凝土的宽广区间，具备良好的工程代表性和适用性。

综上，本工作构建的钢纤维混凝土性能数据库范围广泛且具代表性，能够较充分反映实际工程中配比参数及强度水平的多样性特征。

基于表 1 所示的统计特征，本文选取 w/c 、 s/a 、 a/c 、 $g_{\max}$ 和纤维增强系数 $[\theta]$ ，定义为 $(V_f \times \rho_f \times L_f)/d_f$

作为预测模型的输入变量，以钢纤维混凝土的 f_c 或 f_t 作为输出变量。上述输入参数不仅与混凝土配比设计密切相关，同时被广泛认可为影响混凝土宏观力学性能的关键因素^[29]。图 1 展示了数据库中各输入和输出变量的频率分布特征。

2 既有经验模型及其预测效果

表 2 汇总了文献[4, 29, 31, 32]中提出的若干钢纤维混凝土 f_c 与 f_t 经验模型。图 2 基于这些模型对本工作数据库中的每一样本进行预测，并与试验值进行了对比。现有模型在精度和稳定性方面均存在不同程度的偏差与不确定性，具体表现如下：




图 1 输入与输出参数分布情况
Fig. 1 Distribution of input and output parameters

表 2 既有经验模型
Table 2 Existing semi-empirical models


Notation	Predictive model	Avg ($f_{*,pre}^*/f_{*,test}^*$)	Cov ($f_{*,pre}^*/f_{*,test}^*$)	Reference
A	$f_c=85+15.12V_f-4.71V_f^2$	2.44	27.9%	[31]
B	$f_c=30.68+45.12V_f-69.67V_f^2+29.16V_f^3$	1.06	34.0%	[4]
C	$f_c = [22.4(w/c+0.09) \times (w/c)^{-1.50} \times (a/c)^{-0.147} + 0.623(w/c)^{-0.345} \times (a/c)^{-0.222} \times \theta] \times (1+\theta)^{-0.136} \times (1+\rho_f)^{-0.044} \times (1+L_f/g_{\max})^{0.131}$	0.96	21.9%	[29]
D	$f_t=5.8+3.01V_f-0.02V_f^2$	1.86	26.9%	[31]
E	$f_t=0.58f_c^{0.5}+3.02V_f^2$	1.48	41.9%	[32]
F	$f_t = 2.98(w/c)^{-0.263} \times (1+\alpha_t\theta) \times (1+L_f/g_{\max})^{-0.084}$	0.99	28.3%	[29]

Note: For hooked-end fibers, crimped fibers, and straight fibers, α_t is taken as 0.76, 0.55, and 0.52, respectively; $f_{*,pre}^*$ is predicted strength; $f_{*,test}^*$ is tested strength; α_t is fiber end-factor coefficient.

1) 模型 A 显著高估了 f_c ，整体误差较大。模型 B 和模型 C 虽平均预测合理，但预测值与实测值之比的变异系数高达 34.0%和 21.9%，波动性强，难

以提供稳定可靠的工程依据。

2) 模型 D 和模型 E 普遍高估 f_t ，预测波动剧烈，存在系统性偏差。模型 F 精度略优，但结果离散性



Note: x is tested value ; y is predicted value.

图2 既有经验模型的预测值与试验值对比

Fig. 2 Comparing experimental strengths with predicted ones using existing semi-empirical models

仍大，稳定性和泛化能力不足。

预测不准确源于以下几个因素：1) 现有模型通常简化地使用纤维体积分数来修正素混凝土强度，未考虑不同类型纤维对强度提升的差异性，也未充分反映纤维与基体之间的相互作用；2) 钢纤维混凝土强度与相关影响变量之间通常呈现非线性关系，且各变量之间存在高度复杂的耦合效应，然而大多数现有线性模型未能充分考虑这一点；3) 大多数现有模型基于自测数据构建，模型参数缺乏经过大样本验证的可靠性支持。此外，尽管本工作在数据库构建中尽力统一原则以保证数据一致性，但各国学者在测试条件和操作上的差异仍不可避免，进而影响预测模型的精度与稳定性。

综上，现存的钢纤维混凝土力学强度预测方法普遍存在准确性不足、结果波动显著、适应性有限等问题，难以支撑工程实践对高稳定性与强可靠性的建模需求。因此，有必要开发一种具备精准预测能力、良好鲁棒性和清晰可解释性的模型，为钢纤维混凝土性能的科学评估与工程推广提供有力支撑。

3 基于机器学习的钢纤维混凝土力学性能预测

图3展示了基于可解释机器学习技术构建钢纤维混凝土强度预测模型的整体流程，涵盖数据库构建、模型训练、性能评估、模型筛选以及结果解释等关键环节。在模型训练阶段，首先对输入特征进行归一化处理，随后将数据集按75%与25%划分为训练集与测试集，并在此基础上实施超参数优化，

以提升模型性能与泛化能力。




图3 可解释机器学习模型实施流程

Fig. 3 Procedure of explainable machine learning prediction models

3.1 模型简介

本工作基于4种集成学习方法(RF、GBRT、XGB、LGBM)与1种深度学习方法(BNN)，构建了钢纤维混凝土 f_c 与 f_t 的人工智能模型，均在Python 3.8平台上实现。

3.1.1 RF模型 RF模型通过随机抽取特征和样本子集构建多棵决策树，并以均值汇总树的预测结果，具有处理大规模数据、泛化能力强及评估特征

重要性的优势。

3.1.2 GBRT、XGB 和 LGBM 模型 与 RF 类似, GBRT 同样基于回归树的集成学习方法。其通过迭代拟合前一棵树的残差, 利用梯度下降优化损失函数, 将各棵树的预测结果累加形成最终输出。

XGB 和 LGBM 均为 GBRT 的高效变体。XGB 引入二阶泰勒展开近似目标函数, 提升预测精度, 并通过正则化项抑制模型复杂度, 防止过拟合。LGBM 采用连续特征离散化构建直方图, 利用直方图差分 and 累加运算快速确定最优分割点, 显著降低计算和内存开销, 同时保持对数据模式的高效捕捉。

3.1.3 BNN 模型

BNN 通过在神经网络中引入概率机制, 实现对模型参数的不确定性建模与推断。本研究采用基于 MC Dropout 的变分贝叶斯方法, 通过在训练和预测阶段均启用 Dropout, 利用多次随机采样获得预测均值和不确定度, 从而增强模型的鲁棒性与解释能力。

3.2 过拟合与欠拟合的防止策略

过拟合与欠拟合是机器学习训练过程中的两大挑战。针对过拟合, 常用解决方法包括: 1) 限制模型复杂度, 如控制最大深度, 防止模型过度拟合训练数据中的噪声; 2) 引入 L2 正则化, 通过惩罚过大参数减少对单一特征的依赖; 3) 采用数据和特征的子采样策略, 随机选取部分样本与特征以增强模型的泛化能力; 4) 通过 5 折交叉验证, 检验模型在不同数据划分下的稳定性, 从而有效抑制过拟合现象。

针对欠拟合, 主要解决措施包括: 1) 增加训练轮数, 促进模型充分挖掘数据特征; 2) 调整学习率, 避免因步长过小导致学习缓慢, 无法捕捉数据规律; 3) 利用交叉验证监控模型性能, 若多折结果均表现不佳, 则需提升模型复杂度或优化超参数设置。

综合运用上述方法, 本文实现了模型复杂度与学习能力的协调统一, 显著提升了训练与测试阶段的整体表现。表 3 列出了本文 5 种机器学习算法的最佳超参数配置。

表 3 机器学习模型的超参数
Table 3 Hyperparameters for machine learning models

Models	Hyperparameter values
RF	f_c : n_estimators=300, min_samples_split=5, min_samples_leaf=2, max_features=None, max_depth=5 f_i : n_estimators=300, min_samples_split=5, min_samples_leaf=2, max_features=None, max_depth=5
GBRT	f_c : subsample=0.8, n_estimators=300, min_samples_split=50, min_samples_leaf=10, max_features=None, max_depth=4, learning_rate=0.02 f_i : subsample=0.8, n_estimators=500, min_samples_split=50, min_samples_leaf=10, max_features=log2, max_depth=3, learning_rate=0.02
XGB	f_c : subsample=0.8, n_estimators=500, min_child_weight=10, max_depth=3, learning_rate=0.02, gamma=0, colsample_bytree=0.7 f_i : subsample=0.8, n_estimators=500, min_child_weight=10, max_depth=3, learning_rate=0.02, gamma=0, colsample_bytree=0.8
LGBM	f_c : subsample=0.8, reg_lambda=0.1, reg_alpha=0.1, num_leaves=15, n_estimators=300, min_child_samples=15, max_depth=5, learning_rate=0.02, colsample_bytree=0.8 f_i : subsample=0.7, reg_lambda=1.0, reg_alpha=0.1, num_leaves=31, n_estimators=500, min_child_samples=15, max_depth=5, learning_rate=0.02, colsample_bytree=0.8
BNN	f_c : hidden1=64, hidden2=128, dropout_p=0.1, lr=0.01, epochs=250 f_i : hidden1=32, hidden2=64, dropout_p=0.05, lr=0.01, epochs=250

3.3 预测结果

本工作采用 3 项指标评估所构建机器学习模型的预测性能, 分别为决定系数(R^2)、平均绝对误差(MAPE)和均方根误差(RMSE), 计算公式见式(1)~式(3), 其中: R^2 衡量预测值与实际观测值的相关程度, 数值越接近 1 表示相关性越强; MAPE 反映预测误差的相对幅度, RMSE 则度量误差的绝对大小, 二者共同描述模型的准确性与稳定性。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3)$$

式中: n 表示样本数; y_i 和 $\hat{y}_i$ 分别表示每个样本的实测值和预测值; $\bar{y}$ 表示实测值的平均值。表 4 汇总了本工作所构建的 5 种机器学习模型在预测任务中的性能指标统计结果。从表 4 中数据可以归纳出以下几点: 1) 所有模型均展现出较强的预测能力, 训练集 R^2 介于 0.84~0.90, 说明拟合效果良好, 测试集 R^2 位于 0.80~0.90, 体现出良好的泛化性能^[8-9];

2) f_c 预测中, GBRT、XGB、LGBM 和 BNN 在训练集表现相近, 均优于 RF, 测试集上 LGBM 表现最佳, 其次为 XGB、BNN 与 GBRT, RF 略逊一筹;

3) f_t 预测方面, RF 表现最弱, LGBM 和 XGB 在训练集及测试集均排名前二。综合全库数据, LGBM 略优于 XGB。

表 4 机器学习模型的预测表现

Table 4 Predictive performance of machine learning models


Type	Model	Training set			Testing set			Whole dataset		
		R^2	RMSE/MPa	MAPE/%	R^2	RMSE/MPa	MAPE/%	R^2	RMSE/MPa	MAPE/%
f_c	BNN	0.861	4.37	7.98	0.869	4.56	8.20	0.864	4.42	8.04
	GBRT	0.864	4.33	8.43	0.854	4.83	9.40	0.862	4.46	8.68
	LGBM	0.892	3.86	7.68	0.881	4.32	8.47	0.890	3.98	7.87
	RF	0.841	4.69	9.63	0.830	5.18	10.77	0.838	4.82	9.92
	XGB	0.881	4.06	8.00	0.872	4.48	8.61	0.879	4.17	8.15
f_t	BNN	0.874	0.52	7.72	0.848	0.62	9.06	0.867	0.55	8.06
	GBRT	0.856	0.58	8.46	0.840	0.55	8.88	0.853	0.57	8.57
	LGBM	0.899	0.48	7.43	0.873	0.50	9.09	0.894	0.49	7.85
	RF	0.841	0.59	9.08	0.800	0.68	11.26	0.831	0.62	9.63
	XGB	0.887	0.49	7.43	0.899	0.50	8.65	0.891	0.50	7.74

Note: R^2 is coefficient of determination; RMSE is root mean square error; MAPE is mean absolute percentage error.

综上所述, 本工作构建的 5 种机器学习模型均展现出较强的预测能力, 有效避免了过拟合与欠拟合。LGBM 表现最为优异, 主要原因有以下 2 点: 首先, 作为集成学习方法, LGBM 通过多模型结合有效降低偏差和方差, 展现出较强的鲁棒性, 尤其在样本较少时能够更好地挖掘数据; 其次, LGBM 能够在混凝土力学行为中捕捉非线性且可分段建模

的特征, 这使其在小样本下相比于深度学习方法(如 BNN)具有更好的预测精度并能有效避免过拟合。鉴于 LGBM 模型相对最优的预测表现, 本工作最终推荐 LGBM 模型来预测钢纤维混凝土的 f_c 和 f_t 。


图 4 和图 5 紧接着直观展示了机器学习模型的预测效果。与图 2 相比, 可发现本工作所提模型在预测精度和稳定性方面均表现出显著提升。



Note: AVG is average value; COV is coefficient of variation.

图 4 f_c 机器学习预测

Fig. 4 Machine learning prediction of f_c

图 5 f_t 机器学习预测Fig. 5 Machine learning prediction of f_t

为了进一步验证所建立模型的准确性和泛用性, 本工作进一步对比了文献[33–35]的 f_c 和 f_t 实测值和 LGBM 模型预测值, 结果见图 6。由图 6 可见,

f_c 的预测与实测值之比的平均值和变异系数分别为 0.970 和 0.140, f_t 为 0.962 和 0.188, 表明本工作所建模型有着良好的预测性能和泛用性能。




图 6 本工作 LGBM 模型对文献[33–35]数据预测表现

Fig. 6 Predictive performance of the LGBM model developed in this work on the data reported in Refs. [33–35]

4 机器学习模型可解释性分析

现有的机器学习模型多为“黑盒”结构, 缺乏可解释性, 影响其可信度。本工作针对表现优异的 LGBM 模型, 引入 SHAP、PDP 与 ICE 方法进行解释分析, 以揭示其关键影响因素。

4.1 SHAP 分析

SHAP 方法由 Shapley^[36–37]基于博弈论提出, 用

于解释机器学习模型的预测结果。它通过计算每个特征在不同组合中的独立贡献, 并对其加权求和, 得到该特征的 SHAP 值。借助 SHAP 值, 可揭示单个样本或整个数据集中各特征对预测结果的具体影响, 帮助深化对模型行为的理解。

图 7 展示了 LGBM 抗压强度预测模型中各特征对应的 SHAP 值。图 7a 中, 每个点表示 1 个样本在该特征上的 SHAP 值, 颜色代表特征值大小, 红色

表示较高, 蓝色表示较低, 横轴为 SHAP 值大小。图 7b 则给出了各特征的平均绝对 SHAP 值, 反映其整体重要性。由图 7 可见:

1) w/c 、 a/c 和 $g_{\max}$ 降低时, SHAP 值普遍升高, 说明这些因素的减小有助于提升 f_c 。具体而言, w/c




图 7 抗压强度 LGBM 预测模型的 SHAP 分析结果

Fig. 7 SHAP analysis result of LGBM for compressive strength prediction

2) s/a 和 θ 升高时, SHAP 值亦增加, 表明这两者对 f_c 具有积极的影响。 s/a 的增加意味着细骨料的比例增加, 这可以有效填充骨料间的空隙, 提升混凝土的密实度, 进而提高强度。而 θ 的增大则增强了纤维对混凝土的约束作用, 延缓了混凝土的裂缝扩展过程, 提高了混凝土的韧性和抗压性能。

3) 按平均绝对 SHAP 值排序, 特征重要性依次为 w/c 、 s/a 、 θ 、 a/c 和 $g_{\max}$ 。由此可见, 降低 w/c 最能显著提升抗压强度, 因为 w/c 直接影响水泥的

的降低意味着水泥用量相对增加, 从而使得混凝土结构更加致密, 减少了孔隙率, 有利于提升 f_c 。而 a/c 的减小有助于减少混凝土中的气泡和孔隙, 从而降低局部缺陷的形成。 $g_{\max}$ 减小则有助于改善骨料间的界面结合, 提高混凝土的整体结构稳定性。

水化程度和结构密实性。而 $g_{\max}$ 的影响相对较小, 这表明尽管骨料粒径对混凝土的力学性能有所影响, 但相较于其他变量, $g_{\max}$ 的影响不如 w/c 、 s/a 或 θ 来得显著。

图 8 展示了 LGBM 劈拉强度预测模型的 SHAP 值分析结果。由图 8 可见:

1) w/c 和 a/c 降低, 以及 s/a 与 θ 的升高, 均对应较高的 SHAP 值, 说明这些变化有助于提升钢纤维混凝土的 f_t , 其影响趋势与 f_c 一致。




图 8 劈拉强度 LGBM 预测模型的 SHAP 分析结果

Fig. 8 SHAP analysis result of LGBM for splitting-tensile strength prediction

2) $g_{\max}$ 增大时, SHAP 值升高, 表明 $g_{\max}$ 对 f_t 具有正向作用, 这一趋势与 f_c 的影响相反。原因在于, 较大的 $g_{\max}$ 促使裂缝路径更加曲折和复杂, 使裂缝的扩展受到一定的阻碍, 延缓了破坏的发生。因此, 较大粒径的骨料通过改变裂缝扩展路径, 有助于提高混凝土的 f_t 。

3) 按平均绝对 SHAP 值排序, 影响 f_t 的特征依次为: θ 、 s/a 、 w/c 、 a/c 和 $g_{\max}$ 。从这一排序可以看出, 提升 θ (如增加掺量或提高纤维的长径比) 是增强

f_t 的最有效途径。纤维对混凝土的增强作用主要体现在改善其抗裂性和延缓破坏过程。而 $g_{\max}$ 的影响相对较弱, 尽管它在影响 f_t 时起到一定作用, 但相较于 θ 和水泥基体的优化, 其效果相对较小。

4.2 PDP 与 ICE 分析

PDP 和 ICE 方法通过直观展示目标变量随各影响因素变化的趋势, 成为解释机器学习模型的重要手段。图 9 和图 10 分别呈现了 LGBM 模型在 f_c 和 f_t 预测中的 PDP 与 ICE 曲线。由图 9 可见:




图 9 抗压强度 LGBM 预测模型的 PDP 与 ICE 分析

Fig. 9 PDP and ICE analysis of LGBM for compressive strength prediction

1) 随着 w/c 从 0.3 增加至 0.7、 a/c 从 2.38 提升至 7.68, 以及 $g_{\max}$ 径由 10 mm 增至 40 mm, 钢纤维混凝土的预测 f_c 均呈现明显下降趋势, 降幅分别约为 38.5%、10.9%和 8.9%。

2) 当 s/a 由 0.29 提高至 0.77, θ 由 0 增至 1.27

时, 预测 f_c 均呈现上升态势, 提升幅度分别约为 13.7%和 12.0%。

3) 上述 5 个特征对 f_c 影响的变化幅度排序与前述 SHAP 值的排序(图 7b)高度一致, 进一步增强了模型解释的可信性, 并验证了模型的稳健性。




图 10 劈拉强度 LGBM 预测模型的 PDP 与 ICE 分析

Fig. 10 PDP and ICE analysis of LGBM for splitting-tensile strength prediction

由图 10 可见:

1) 随着 w/c 由 0.3 增至 0.7、 a/c 由 2.38 提升至 7.68, 钢纤维混凝土的预测 f_t 呈现下降趋势, 降幅分别约为 13.3% 和 8.8%。

2) s/a 由 0.29 提高至 0.77、 $g_{\max}$ 由 10 mm 增至 40 mm、 θ 由 0 增至 1.27 时, 预测 f_t 总体上升, 涨幅约为 31.5%、7.1% 和 43.6%。

3) 上述特征对 f_t 影响的幅度排序与前文 SHAP 值(图 8b)一致, 进一步验证了模型的可解释性与合理性。

5 结论与展望

1) 本工作针对钢纤维混凝土, 选取 w/c 、 s/a 、 a/c 、 $g_{\max}$ 和 θ 作为输入, f_c 与 f_t 为输出, 构建了包含 636 组试验样本的数据库, 为高精度机器学习模型的建立提供了坚实基础。传统预测方法难以准确评估其力学性能。

2) 基于该数据库, 开发了 RF、GBRT、XGB、LGBM 和 BNN 5 种机器学习模型。所有模型均展现出优异的预测精度和良好的泛化能力, 显著优于传统经验方法, 其中 LGBM 模型的综合性能最为突出, 本工作推荐采用该模型来预测钢纤维混凝土的抗压强度和劈拉强度。

3) 利用 SHAP 方法, 系统分析了各输入参数对 f_c 和 f_t 的影响及趋势。 f_c 的关键影响因素依次为 w/c 、 s/a 、 θ 、 a/c 和 $g_{\max}$; f_t 的影响排序为 θ 、 s/a 、 w/c 、 a/c 和 $g_{\max}$ 。

4) 通过 PDP 与 ICE 技术, 定量分析了模型预测值随各输入参数变化的响应曲线。性能变化趋势和影响排序与 SHAP 结果高度一致, 进一步验证了模型的可解释性和可靠性。

5) 尽管本工作数据库较以往更为丰富, 但由于数据来源涵盖不同国家和地区、由不同学者进行测试, 不可避免存在一定差异, 这可能会对模型的预测性能产生一定影响。因此, 未来仍需构建更为完善和严谨的数据库, 以进一步提升模型。

参考文献:

- [1] ZHANG P, WANG C, GAO Z, et al. A review on fracture properties of steel fiber reinforced concrete[J]. J Build Eng, 2023, 67: 105975.
- [2] ABBASS W, KHAN M I, MOURAD S. Evaluation of mechanical properties of steel fiber reinforced concrete with different strengths of concrete[J]. Constr Build Mater, 2018, 168: 556–569.
- [3] 白敏, 牛荻涛, 姜磊, 等. 钢纤维改善混凝土力学性能和微观结构的研究[J]. 硅酸盐通报, 2013, 32(10): 2084–2089.
- BAI Min, NIU Ditao, JIANG Lei, et al. Bull Chin Ceram Soc, 2013,

32(10): 2084–2089.

- [4] 常虹, 沈鹏, 谷复光. 钢纤维混凝土力学性能试验研究[J]. 混凝土, 2020(4): 67–69.
- CHANG Hong, SHEN Peng, GU Fuguang. Concrete, 2020(4): 67–69.
- [5] 王艳. 一般大气环境多因素作用下钢纤维混凝土耐久性研究[D]. 西安: 西安建筑科技大学, 2011.
- WANG Yan. Steel fiber reinforce concrete durability in the atmospheric environment based on multi-factor effects[D]. Xi'an: Xi'an University of Architecture and Technology, 2011.
- [6] 李德春, 许冲, 崔振东, 等. 基于正交试验的纤维混凝土力学性能影响研究[J]. 混凝土, 2022(6): 29–32.
- LI Dechun, XU Chong, CUI Zhendong, et al. Concrete, 2022(6): 29–32.
- [7] 刘杰. 钢纤维再生混凝土拉压性能及其相互关系[D]. 郑州: 郑州大学, 2016.
- LIU Jie. Study on the relationship between pressure and tensile properties of steel fiber recycled concrete[D]. Zhengzhou: Zhengzhou University, 2016.
- [8] YAN J, SU J, XU J J, et al. Ensemble machine learning models for compressive strength and elastic modulus of recycled brick aggregate concrete[J]. Mater Today Commun, 2024, 41: 110635.
- [9] LIN L, XU J J, YUAN J L, et al. Compressive strength and elastic modulus of RBAC: An analysis of existing data and an artificial intelligence based prediction[J]. Case Stud Constr Mater, 2023, 18: e02184.
- [10] AÇIKGENÇ M, ULAŞ M, ALYAMAÇ K E. Using an artificial neural network to predict mix compositions of steel fiber-reinforced concrete[J]. Arab J Sci Eng, 2015, 40(2): 407–419.
- [11] KARAHAN O, TANYILDIZI H, ATIS C D. An artificial neural network approach for prediction of long-term strength properties of steel fiber reinforced concrete containing fly ash[J]. J Zhejiang Univ Sci A, 2008, 9(11): 1514–1523.
- [12] MINELLI F, CONFORTI A, CUENCA E, et al. Are steel fibres able to mitigate or eliminate size effect in shear?[J]. Materials and Structures, 2014, 47(3): 459–473.
- [13] NILI M, AFROUGHSABET V. Combined effect of silica fume and steel fibers on the impact resistance and mechanical properties of concrete[J]. Int J Impact Eng, 2010, 37(8): 879–886.
- [14] NGUYEN-MINH L, ROVNÁK M, TRAN-QUOC T, et al. Punching shear resistance of steel fiber reinforced concrete flat slabs[J]. Procedia Eng, 2011, 14: 1830–1837.
- [15] IBRAHIM I S, CHE BAKAR M B. Effects on mechanical properties of industrialised steel fibres addition to normal weight concrete[J]. Procedia Eng, 2011, 14: 2616–2626.
- [16] EREN Ö, MARAR K. Effects of limestone crusher dust and steel fibers on concrete[J]. Constr Build Mater, 2009, 23(2): 981–988.
- [17] ŞAHİN Y, KÖKSAL F. The influences of matrix and steel fibre tensile strengths on the fracture energy of high-strength concrete[J]. Constr Build Mater, 2011, 25(4): 1801–1806.
- [18] BURATTI N, MAZZOTTI C, SAVOIA M. Post-cracking behaviour of steel and macro-synthetic fibre-reinforced concretes[J]. Constr Build Mater, 2011, 25(5): 2713–2722.
- [19] LAU A, ANSON M. Effect of high temperatures on high performance steel fibre reinforced concrete[J]. Cem Concr Res, 2006, 36(9): 1698–1707.
- [20] SHAKYA K, WATANABE K, MATSUMOTO K, et al. Application of steel fibers in beam-column joints of rigid-framed railway bridges to reduce longitudinal and shear rebars[J]. Constr Build Mater, 2012,

- 27(1): 482–489.
- [21] SOULIOTI D V, BARKOULA N M, PAIPETIS A, et al. Effects of fibre geometry and volume fraction on the flexural behaviour of steel-fibre reinforced concrete[J]. *Strain*, 2011, 47(s1): 535–541.
- [22] ÜNAL O, DEMIR F, UYGUNOĞLU T. Fuzzy logic approach to predict stress-strain curves of steel fiber-reinforced concretes in compression[J]. *Build Environ*, 2007, 42(10): 3589–3595.
- [23] CARMONA S, AGUADO A, MOLINS C. Characterization of the properties of steel fiber reinforced concrete by means of the generalized Barcelona test[J]. *Constr Build Mater*, 2013, 48: 592–600.
- [24] CANTIN R, PIGEON M. Deicer salt scaling resistance of steel-fiber-reinforced concrete[J]. *Cem Concr Res*, 1996, 26(11): 1639–1648.
- [25] PIGEON M, CANTIN R. Flexural properties of steel fiber-reinforced concretes at low temperatures[J]. *Cem Concr Compos*, 1998, 20(5): 365–375.
- [26] 张梓超. 钢纤维混凝土单轴受压本构关系试验研究[D]. 郑州: 郑州大学, 2017.
- ZHANG Zichao. Experimental study on constitutive relation of steel fiber reinforced concrete under uniaxial compression[D]. Zhengzhou: Zhengzhou University, 2017.
- [27] 陈京钰. 骨料粒径与纤维长度对钢纤维混凝土断裂性能影响的研究[D]. 郑州: 郑州大学, 2016.
- CHEN Jingyu. The study of the effect of the aggregate size and the steel fiber's length on the fracture property of SFRC[D]. Zhengzhou: Zhengzhou University, 2016.
- [28] 李川川. 钢纤维混凝土立方体与圆柱体试件力学性能及其关系研究[D]. 郑州: 郑州大学, 2016.
- LI Chuanchuan. Study on mechanical properties and relationship of steel fiber reinforced concrete cubic and cylindrical specimen[D]. Zhengzhou: Zhengzhou University, 2016.
- [29] WANG Y M, JIN H M, DEMARTINO C, et al. Mechanical properties of SFRC: Database construction and model prediction[J]. *Case Stud Constr Mater*, 2022, 17: e01484.
- [30] 中国建筑科学研究院, 大连悦泰建设工程有限公司等. JGJ/T 221—2010 纤维混凝土应用技术规程[S]. 北京: 中国建筑工业出版社, 2011.
- [31] SONG P S, HWANG S. Mechanical properties of high-strength steel fiber-reinforced concrete[J]. *Constr Build Mater*, 2004, 18(9): 669–673.
- [32] ASHOUR S A, HASANAIN G S, et al. Shear behavior of high-strength fiber reinforced concrete beams[J]. *Struct J*, 1992, 89(2): 176–184.
- [33] 赵琅. 用于海上风电混塔的钢纤维混凝土强度试验[J]. *船舶工程*, 2025, 47(增刊 1): 68–73.
- ZHAO Lang. *Ship Eng*, 2025, 47(Suppl 1): 68–73.
- [34] 关羿, 蒋亚龙, 疏杨, 等. 钢纤维混凝土抗压试验及数值模拟[J]. *兰州工业学院学报*, 2023, 30(6): 98–102.
- GUAN Yi, JIANG Yalong, SHU Yang, et al. *J Lanzhou Inst Technol*, 2023, 30(6): 98–102.
- [35] 张华. 钢纤维混凝土强度与弯曲韧性研究[D]. 郑州: 郑州大学, 2011.
- ZHANG Hua. Experimental study on flexural toughness of steel fiber reinforced concrete[D]. Zhengzhou: Zhengzhou University, 2011.
- [36] SHAPLEY L S. Stochastic games[J]. *Proc Natl Acad Sci U S A*, 1953, 39(10): 1095–1100.
- [37] SHAPLEY L S. On balanced sets and cores[J]. *Naval Res Logist Q*, 1967, 14(4): 453–460.

作者贡献声明:

林 朗、余 勇: 提出研究方向、设计论文框架、撰写论文
 盛小龙: 绘制图表、参与数据分析与论文撰写
 徐金俊: 完善论文框架、修订论文
 肖钊名: 实验测试、参与数据分析

Machine Learning Modeling and Prediction of Mechanical Strengths of Steel Fiber-Reinforced Concrete

LIN Lang^{1,4}, SHENG Xiaolong², XU Jinjun³, XIAO Yiming¹, YU Yong⁴

(1. School of Civil Engineering and Transportation, Foshan University, Foshan 528225, Guangdong, China; 2. Jiangxi Institute of Survey and Design Co., Ltd., Nanchang 330095, China; 3. College of Civil Engineering, Nanjing Tech University, Nanjing 211816, China; 4. State Key Laboratory of Subtropical Building and Urban Science, South China University of Technology, Guangzhou 510641, China)

Extended Abstract

Introduction Conventional concrete suffers from its inherently low tensile strength. To address this drawback, researchers propose steel fiber reinforced concrete (SFRC) as a novel material that significantly improves tensile properties and exhibits outstanding performance in cracking resistance, toughness, and durability. However, the incorporation of steel fibers makes the mechanical behavior of SFRC more complex. To ensure its safe application in structural engineering, an accurate prediction of its mechanical properties is essential.

Artificial intelligence technologies are widely applied to accurately evaluate the mechanical properties of concrete. However, the existing machine learning models for SFRC are typically trained on a limited number of samples (*i.e.*, fewer than 300), which restricts their generalization capability. Moreover, these models often lack interpretability, undermining their credibility and limiting their practical application in engineering projects.

This study was to establish a database for the compressive and splitting tensile strengths of SFRC, develop corresponding machine learning prediction models, and evaluate their predictive performance. Furthermore, the interpretability of the models was analyzed. The findings of this study could offer some insights into the development of high-precision machine learning models for SFRC and their interpretability analysis, thereby promoting their application in engineering practices.

Methods In this study, a total of 636 experimental data points on SFRC were collected from 24 independent studies to establish a comprehensive database, including 419 data points for compressive strength and 217 for splitting tensile strength. Each data entry contains a mix-related information such as the water-to-binder ratio, sand ratio, aggregate-to-binder ratio, maximum size of coarse aggregate, fiber shape factor, fiber aspect ratio, fiber volume fraction, and the corresponding compressive or splitting tensile strength.

Based on this database, five machine learning models (*i.e.*, Random Forest (RF), Gradient Boosting Regression Tree (GBRT), Extreme Gradient Boosting (XGB), Light Gradient Boosting Machine (LGBM) and Bayesian Neural Network (BNN)) were proposed. The predictive performance of these models was evaluated using the coefficient of determination (R^2), mean absolute percentage error (MAPE), and root mean square error (RMSE), in order to identify the most effective prediction model.

For the selected model, the SHAP (SHapley Additive exPlanations) method was employed to analyze the trends and contribution of each input parameter on the compressive and splitting tensile strengths of SFRC. In addition, the Partial Dependence Plot (PDP) and Individual Conditional Expectation (ICE) methods were also used to quantitatively investigate the variation patterns of predicted values with respect to individual input parameters.

Results and discussion All the models proposed demonstrate a great predictive performance. The R^2 for the test set ranges from 0.84 to 0.90, while for the training set it ranges from 0.80 to 0.90. A small difference between them (*i.e.*, both being > 0.75) indicates a good predictive accuracy and a generalization ability. For the overall performance across R^2 , MAPE and RMSE metrics, the LGBM model shows the optimum prediction performance.

The SHAP analysis reveals that the compressive and splitting tensile strengths of SFRC decrease with increasing water-to-binder ratio and aggregate-to-binder ratio, while the strengths both increase at a higher sand ratio and a greater fiber reinforcement factor. In addition, as the maximum size of coarse aggregate increases, the compressive strength decreases, whereas the splitting tensile strength increases. These results are consistent with the practical observations. Based on the mean absolute SHAP values, the input parameters influencing the compressive strength in a descending order are water-to-cement ratio, sand ratio, fiber reinforcement factor, aggregate-to-cement ratio, and maximum coarse aggregate size. For splitting tensile strength, the order is fiber reinforcement factor, sand ratio, water-to-binder ratio, aggregate-to-binder ratio, and maximum coarse aggregate size.

The influence and parameter importance rankings obtained through the PDP and ICE analysis are in a reasonable agreement with those derived from SHAP, further validating the interpretability and reliability of the model.

Conclusion A large-scale database containing 636 data entries was established for the compressive and splitting tensile strengths of SFRC. Based on this database, five machine learning prediction models (*i.e.*, RF, GBRT, XGB, LGBM and BNN) were proposed. All the models exhibited good predictive performance and generalization ability, significantly outperforming the existing prediction methods. Among them, the LGBM model showed the optimum overall performance. The SHAP, PDP and ICE techniques were employed to analyze the influence and importance of each input parameter on the compressive and splitting tensile strengths. Based on the variable contribution analysis, the main factors affecting the compressive strength were the water-to-cement ratio, sand ratio, fiber reinforcement factor, aggregate-to-cement ratio, and maximum coarse aggregate size. In contrast, the key determinants of splitting tensile strength were the fiber reinforcement coefficient, sand ratio and water-to-cement ratio.

Keywords steel fiber-reinforced concrete; compressive strength; splitting tensile strength; machine learning; performance evaluation