

DOI:10.3969/j.issn.1003-5060.2026.05.019

基于卷积神经网络的钢纤维混凝土性能预测模型

朱玲玲¹, 洪 丽^{1,2,3}, 谭雨晴¹, 赵 丹¹, 李虹岑¹

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 土木工程结构与材料安徽省重点实验室, 安徽 合肥 230009; 3. 水泥基材料低碳技术与装备教育部工程研究中心, 安徽 合肥 230009)

摘 要:文章基于卷积神经网络(convolutional neural network, CNN)建立钢纤维混凝土坍落度、抗压强度和劈裂抗拉强度的预测模型。基于文献调研建立了 294 组钢纤维混凝土材料组成及性能数据的数据库,以水灰比、砂率、钢纤维体积掺量、钢纤维长径比和减水剂用量作为模型的输入变量,以钢纤维混凝土的坍落度、抗压强度和劈裂抗拉强度为输出结果,以均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均偏差误差(mean bias error, MBE)和决定系数 R^2 为评价指标,衡量预测模型的准确性和可靠性。结果表明,与反向传播神经网络(back propagation neural network, BPNN)、支持向量回归(support vector regression, SVR)、随机森林(random forest, RF)和径向基神经网络(radial basis function neural network, RBFNN)相比,基于 CNN 建立的钢纤维混凝土预测模型精度最高、泛化能力最强。采用 SHAP (SHapley Additive exPlanations)方法分析了钢纤维混凝土坍落度、抗压强度和劈裂抗拉强度的敏感因素,确定每个特征对目标性能的具体影响。该研究结果为后续实现基于多性能需求的钢纤维混凝土配合比优化设计提供依据,有助于指导工程实践和施工设计。

关键词:卷积神经网络(CNN);钢纤维混凝土;坍落度;强度;性能预测

中图分类号: TU528.572

文献标志码: A

文章编号: 1003-5060(2026)05-0711-10

Convolutional neural network-based model for predicting the performance of steel fiber reinforced concrete

ZHU Lingling¹, HONG Li^{1,2,3}, TAN Yuqing¹, ZHAO Dan¹, LI Hongcen¹

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Key Laboratory of Civil Engineering Structures and Materials, Hefei 230009, China; 3. Engineering Research Center of Low-carbon Technology and Equipment for Cement-based Materials, Ministry of Education, Hefei 230009, China)

Abstract: In this paper, a prediction model for slump, compressive strength, and splitting tensile strength of steel fiber reinforced concrete is established by employing the convolutional neural network(CNN). Initially, a comprehensive database was constructed, comprising 294 distinct datasets of steel fiber reinforced concrete material compositions and their corresponding performance metrics, collated through extensive literature review. The input parameters of the model encompassed the water-to-cement ratio, sand rate, steel fiber volume fraction, steel fiber length-to-diameter ratio, and the dosage of water reducing agents. In contrast, the output variables were the slump, compressive strength, and splitting tensile strength of the steel fiber reinforced concrete. Subsequently, the precision and robustness of the model were evaluated using various statistical metrics, including root mean squared error(RMSE), mean absolute error(MAE), mean bias error(MBE), and the coefficient of determination(R^2). The findings revealed that the CNN-based prediction model for steel fiber reinforced concrete significantly outperformed alternative models such as back propagation neural

收稿日期:2024-01-23;修回日期:2024-05-06

基金项目:国家重点研发计划资助项目(2020YFC1909902)

作者简介:朱玲玲(2000—),女,安徽铜陵人,合肥工业大学博士生;

洪 丽(1985—),女,安徽宣城人,博士,合肥工业大学副教授,硕士生导师,通信作者, E-mail: hongli2014@hfut.edu.cn.

network(BPNN), support vector regression(SVR), random forest(RF), and radial basis function neural network(RBFNN) in terms of accuracy and generalization capability. Finally, the SHapley Additive exPlanations (SHAP) method was employed to scrutinize the influence of each variable on the target performance attributes, namely the slump, compressive strength, and splitting tensile strength. The insights garnered from this study provide a foundational basis for the optimization of steel fiber reinforced concrete mix designs to meet multifaceted performance demands, thereby contributing valuable insights to the domains of engineering practice and structural design.

Key words: convolutional neural network(CNN); steel fiber reinforced concrete; slump; strength; performance prediction

纤维混凝土作为一种高性能建筑材料,以其优异的抗裂、抗拉、抗折及抗冲磨性能,在公路、桥梁和机场等关键基础设施中发挥着重要作用^[1]。常用于混凝土的纤维主要有钢纤维、碳纤维、玄武岩纤维、聚丙烯纤维及聚乙烯醇纤维等^[1]。纤维可以阻止和减少裂缝的形成与扩展,还可提高混凝土的韧性^[2]。

纤维混凝土的性能受众多因素的影响,学者们开展了大量研究。文献[3]研究了水灰比、钢纤维体积率、再生骨料取代率对钢纤维再生混凝土工作性能和强度的影响,分别建立了基于工作性能和抗压强度的钢纤维再生混凝土配合比设计方法;文献[4]基于粗骨料用量、细骨料用量、水用量、水泥用量、粉煤灰用量、硅灰用量和钢纤维体积掺量,建立了钢纤维自密实轻骨料混凝土的配合比设计方法;文献[5]基于水泥用量、水灰比、骨料用量、减水剂用量、钢纤维体积掺量和钢纤维长径比,根据诺姆图^[6]开发了包含钢纤维混凝土的抗弯强度和韧性模量的配合比设计图。这些研究主要侧重于通过实验方法来探索各种材料比例对混凝土性能的影响,对混凝土组分与性能之间关系的拟合能力有限。

随着计算机技术的发展,国内外学者利用反向传播神经网络(back propagation neural network, BPNN)、支持向量回归(support vector regression, SVR)、随机森林(random forest, RF)等机器学习方法预测混凝土的强度,为混凝土的性能设计提供了新的思路。

文献[7]基于 BPNN 提出了透水混凝土的配合比设计优化方法,分析透水混凝土性能指标与影响因素间复杂的非线性映射关系;文献[8]基于 SVR 和萤火虫算法的多目标优化模型,进行钢纤维混凝土的配合比设计;文献[9]以 1 030 个样本构建高性能混凝土的数据集,提出基于 RF 的高性能混凝土抗压强度预测模型;文献[10]采用水

胶比、再生粗骨料取代率、再生细骨料取代率和粉煤灰掺量为输入变量,建立基于卷积神经网络(convolutional neural network, CNN)的再生混凝土抗压强度预测模型;文献[11]使用多种机器学习算法来建模预测钢纤维混凝土的抗压强度,对比发现 CNN 和 SVR 是最佳的预测模型。

上述研究展示了深度学习在混凝土性能预测领域的潜力,但缺乏对深度学习模型的解释,这在工程应用中会导致一定程度的不确定性和信任问题。而 SHAP(SHapley Additive exPlanations)^[12]方法可用于解释机器学习模型的输出,具有局部保真性、缺失无影响和一致性。SHAP 方法基于合作博弈论中的 Shapley 值原理,为每个特征组合计算其对最终预测结果的贡献。这种方法为理解每个特征如何影响输出提供了一个严格的框架,并已被证明在解释复杂机器学习模型的行为方面是有效的^[13-14]。因此,本文利用深度学习方法,建立了钢纤维混凝土的工作性能和力学性能预测模型,结合 SHAP 方法进行模型的解释,为后续实现基于多性能需求的钢纤维混凝土配合比优化设计提供一定的依据。

1 模型的输入

1.1 参数的选择

影响钢纤维混凝土性能的因素主要包括水的用量、水泥用量、水灰比、细骨料用量、粗骨料用量、砂率、钢纤维体积掺量、钢纤维长径比、钢纤维种类、减水剂用量等。在建立性能预测模型前需要确保输入参数之间不是高度相关的,避免出现多重共线性,导致模型失真或不准确。因此,需确定纤维混凝土性能预测模型输入参数有:水灰比、砂率、钢纤维体积掺量、钢纤维长径比、减水剂用量、粗骨料用量和细骨料用量。

1.2 数据集的建立

基于文献[15-19]的调研,获得了 294 组钢纤

维混凝土的配合比设计参数及坍落度、抗压强度、劈裂抗拉强度数据,统计分析得到全部参数的取值范围见表1所列。

用于各个模型的数据集共有5个输入参数和3个输出参数,按照8:2的比例划分为训练集和测试集,其中训练集主要用于模型训练和误差计算,测试集则主要用于评价模型的精度和效率。数据集中存在部分缺失数据,本文对不同性能的缺失数据进行删除,分别建立预测模型,得到因素与各个性能的隐函数,作为后续进行多目标优化配合比优化设计的目标函数^[20]。此外,为减少不同参数之间的尺度差异对模型的影响,基于MATLAB^[21]的Mapminmax函数^[22]对数据进行了归一化处理。

表1 钢纤维混凝土参数

参数	最小值	最大值	平均值	标准差
水用量/(kg/m ³)	120	235	175	23
水泥用量/(kg/m ³)	320	627	436	53
水灰比	0.30	0.60	0.43	0.07
细骨料用量/(kg/m ³)	500	1 125	745	113
粗骨料用量/(kg/m ³)	553	1 312	135	143
砂率	0.29	0.65	0.44	0.07
钢纤维体积率/%	0	2.50	0.83	0.56
钢纤维长径比	34	90	54	13
减水剂用量/%	0	2.50	0.36	0.57
坍落度/mm	18	210	108	61
抗压强度/MPa	23.06	97.40	48.64	12.06
劈裂抗拉强度/MPa	0.41	8.37	4.64	1.50

2 模型的建立

2.1 模型架构设计

本文构建的卷积神经网络架构,基于2012年ILSVRC(ImageNet large scale visual recognition competition)的AlexNet^[23]进行简化处理,用于数据的回归分析。主要包括1个输入层,1个卷积层,1个用于加速模型训练的批归一化层,1个对卷积层的输出进行非线性激活的ReLU激活层,1个以0.2的概率(根据模型大小和复杂性确定)随机抑制神经元来减少过拟合的Dropout层,1个用于生成预测值的全连接层,以及1个作为输出层的回归层。

本文构建的卷积神经网络架构图如图1所示,针对不同性能的预测模型,模型的输入参数不同,图1中以坍落度预测模型的输入参数为例。




图1 卷积神经网络架构图

2.2 损失函数和参数设置

预测模型的损失函数采用均方误差^[24](mean squared error, MSE)来衡量模型预测结果与真实结果之间的差距。损失函数越小,表明模型预测结果与实际结果越接近。计算公式为:

$$E_{\text{MSE}} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (1)$$

其中: y_i 为真实值; $\hat{y}_i$ 为预测值; m 为样本个数。

为得到最小的损失函数,模型采用自适应时刻估计方法^[25](adaptive moment estimation, Adam)为优化算法,其收敛速度更快,学习效果好,且可以纠正其他优化技术中存在的问题,如学习率消失、收敛过慢或高方差的参数更新导致损失函数波动较大等。

在模型训练的过程中,合理调整参数对于提高模型性能和加速收敛至关重要。参数设置主要包括学习率、批大小和最大训练次数。学习率决定了参数更新的步长,过大可能会导致模型无法收敛,而过小则会使得训练效率低。初始学习率设定为0.01,在训练过程中进行动态调整,以适应模型的学习进度。批大小指每次迭代中用于更新参数的样本数量,通过试算设置为30。最大训练次数指模型需要迭代的总次数,为避免过拟合和欠拟合,设定最大训练次数为800次。

2.3 评价指标

本文预测模型的评价指标包括决定系数 R^2 、均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和平均偏差误差(mean bias error, MBE)。

R^2 是衡量模型拟合优度的统计量,代表了模型中因变量可由自变量解释的百分比^[26],数值范围为[0,1],越接近1表示对模型的输出的解释能力越强,数据拟合越好。计算公式为:

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

其中: y_i 为真实值; $\hat{y}_i$ 为预测值; m 为样本个数。

RMSE 表示预测值与真实值之间的样本标准差,该值越接近 0 代表模型的准确率越高^[27]。RMSE 对预测误差的敏感度很高,对异常值非常敏感。计算公式为:

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

其中: y_i 为真实值; $\hat{y}_i$ 为预测值; m 为样本个数。

MAE 是绝对误差的算术平均值,该值越低表示模型的准确率越高^[28]。MAE 对离群值不敏感,避免异常值对模型的评估产生较大的偏差,搭配 RMSE 用于评价模型。计算公式为:

$$E_{\text{MAE}} = \frac{1}{m} \sum_{i=1}^m |(y_i - \hat{y}_i)| \quad (4)$$

其中: y_i 为真实值; $\hat{y}_i$ 为预测值; m 为样本个数。

MBE^[28]表示预测值与实际值之间的误差平均值。MBE 的值接近于 0 表示模型的预测偏差越小,负值表示模型倾向于低估实际值,而正值则表明模型倾向于高估实际值。计算公式为:

$$E_{\text{MBE}} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i) \quad (5)$$

其中: y_i 为真实值; $\hat{y}_i$ 为预测值; m 为样本个数。

3 结果与讨论

3.1 环境配置

为保证模型正常运行和足够的数据存储空间,本文采用的软硬件配置如下:Windows 11 操作系统并配备 Python 3.7.2^[29] 和 MATLAB R2021a^[21],可提供强大的编程和科学计算支持;内部搭载 AMD Ryzen 7 5800H with Radeon Graphics 处理器,搭配 NVIDIA GeForce RTX 3050-6G 图形处理器,保证计算能力和图形处理能力;此外,配备 16 GiB 的内存及 520 GiB 的固态硬盘,确保多任务处理能力和高效数据存取。

3.2 模型的训练和验证

基于 CNN 的坍落度预测结果如图 2 所示。




图 2 坍落度的预测结果对比

从图 2 可以看出:训练集和测试集的 RMSE 分别为 7.69、9.87 mm,误差均小于 10%,模型预测精度较高;训练集和测试集 R^2 分别为 0.98、0.97,拟合程度高;训练集和测试集 MAE 分别为 5.02、7.23 mm,MBE 分别为 -1.67、0.15 mm。说明本文所建立的坍落度预测模型能够较准确地映射出各因素与坍落度之间的关系,训练集和测试集的结果相差不大,说明泛化能力强。

基于 CNN 的抗压强度预测结果如图 3 所示。从图 3 可以看出:训练集和测试集的 RMSE 分别为 2.14、2.48 MPa,误差小于 5%,在抗压强度的误差允许范围内(小于 15%);训练集和测试集的 R^2 分别为 0.98、0.96,拟合程度较高;训练

集和测试集的 MAE 分别为 1.21、1.69 MPa,MBE 分别为 0.13、0.80 MPa。研究发现,所建立的抗压强度预测模型成功地揭示了各因素与抗压强度之间的关联,并表现出良好的泛化性能。

基于 CNN 的劈裂抗拉强度预测结果如图 4 所示。由图 4 可知:训练集和测试集的 RMSE 分别为 0.18、0.22 MPa,误差小于 5%,在劈裂抗拉强度的误差允许范围内(小于 15%);训练集和测试集的 R^2 分别为 0.97、0.94,拟合程度较高;训练集和测试集的 MAE 分别为 0.11、0.19 MPa,MBE 分别为 0.02、0.11 MPa。结果表明,建立的劈裂抗拉强度预测模型能有效地反映出各因素与劈裂抗拉强度的联系,并具有较高的泛化性。




图 3 抗压强度的预测结果对比




图 4 劈裂抗拉强度的预测结果对比

3.3 与传统机器学习模型的比较

本文基于同一数据集,分别采用 BPNN、SVR、RF 和径向基神经网络(radial basis function neural network,RBFNN)对钢纤维混凝土坍

落度、抗压强度和劈裂抗拉强度进行预测,并与本文所建立的卷积神经网络模型结果进行比较。

钢纤维混凝土坍落度预测模型的评价指标对比结果如图 5 所示。




图 5 钢纤维混凝土坍落度预测模型评价指标对比

从图 5 可以看出,模型表现从优到劣依次为 CNN、SVR、RBFNN、BPNN、RF。CNN 模型的 RMSE 和 MAE 远小于其他模型,且 R^2 最大,模型精度最高。这是由于权重共享机制,CNN 模型的参数数量相对于全连接网络大大减少,降低了模型复杂度和过拟合风险^[30]。从 MBE 来看,各

模型的表现有正有负,但 CNN、RF 和 BPNN 的 MBE 值相对较小,表明预测偏差较小。对比训练集和测试集可知,图 5 中 CNN 模型的形状相似且形成的面积最小,CNN 模型的 RMSE、MAE 和 R^2 值均相差不大,模型泛化能力最好。SVR 模型的泛化能力强,可避免过拟合,但是对于参数

的选择和调整较为敏感^[31],表现差于 CNN 模型; RBFNN 模型的非线性拟合能力强^[32],但需要足够多的样本来训练模型,中心点的选择不当可能影响网络性能,表现较差;BPNN 模型由于存在局部极小化、易出现过拟合的缺陷,表现较差^[33]; RF 模型的 RMSE、MAE 最大且 R^2 最小,表现最差,虽然不太容易过拟合,但是在坍落度数据量少的情况下的预测效果不是很好,解释性不强^[34]。

钢纤维混凝土坍落度预测模型残差对比结果如图 6 所示。从图 6 可以看出,SVR 模型和 CNN 模型的残差(真实值与预测值的差)波动较小,且接近于 0,说明模型性能优于其他模型。但 SVR 模型存在的异常点(图 6 中方块点)较多,模型预测可靠性较差。因此 CNN 模型是这 5 个模型中的最佳选择。




图 6 钢纤维混凝土坍落度预测模型残差对比

钢纤维混凝土抗压强度预测模型的评价指标对比结果如图 7 所示。从图 7 可以看出,模型表现从优到劣依次为 CNN、SVR、RBFNN、RF、BPNN。由于抗压强度数据较为充足,此时 RF 模型不再是表现最差的模型,而 BPNN 模型由于自身缺陷表现最差。CNN 模型的 RMSE 和 MAE 均小于其他模型,且 R^2 最大,模型精度最高。从 MBE 来看,CNN 模型的误差被高估,在抗压强度允许误差范围内。对比训练集和测试集可以发现,图 7 中 CNN 模型的形状更为相似,CNN 模型的 RMSE、MAE 和 R^2 值均相差不大,模型过拟合风险最小、泛化能力最好。

钢纤维混凝土抗压强度预测模型残差对比结果如图 8 所示。从图 8 可以看出,SVR 模型和 CNN 模型的箱体高度较小,代表残差波动较小,且残差在 0 附近波动,模型性能相比于其他模型要好。但是 SVR 模型存在的异常点较多,模型预测可靠性较差。因此,CNN 模型是这 5 个模型中的最佳选择。




图 7 钢纤维混凝土抗压强度预测模型评价指标对比




图 8 钢纤维混凝土抗压强度预测模型残差对比

钢纤维混凝土劈裂抗拉强度预测模型的评价指标结果如图 9 所示。由图 9 可知,与坍落度模型类似,模型表现从优到劣依次为 CNN、SVR、RBFNN、BPNN、RF,其中 RF 模型表现最差,原因在于劈裂抗拉强度数据较少。CNN 模型的 RMSE 和 MAE 均小于其他模型,且 R^2 最大,模型精度最高;从 MBE 来看,CNN 模型的误差被高估,在劈裂抗拉强度允许误差范围内。对比训练集和测试集可发现,图 9 中 CNN 模型的形状更相似,CNN 模型的 RMSE、MAE 和 R^2 值均相差不大,模型过拟合风险最小、泛化能力最好。

钢纤维混凝土劈裂抗拉强度预测模型残差对

比结果如图10所示。从图10可以看出,SVR模型和CNN模型的箱体高度较小,表示残差波动较小,且残差在0附近波动,模型性能相比于其他模型要好。但是SVR模型存在的异常点较多,模型预测可靠性较差。因此CNN模型是这5个模型中的最佳选择。




图9 钢纤维混凝土劈裂抗拉强度预测模型评价指标对比




图10 钢纤维混凝土劈裂抗拉强度预测模型残差对比

3.4 钢纤维混凝土性能敏感因素分析

为进一步评估影响纤维混凝土的各项性能的敏感影响因素,本文基于SHAP分析研究了钢纤维混凝土坍落度、抗压强度和劈裂抗拉强度的敏感因素。坍落度SHAP值散点图如图11所示。图11中:每个点表示1个样本对模型预测的贡

献;SHAP值为负值表示负面影响,正值表示正面影响;点的颜色从蓝色到红色表示特征值的范围,蓝色表示低值,红色代表高值。




图11 坍落度SHAP值散点图

由图11可知,减水剂用量 S_P 是钢纤维混凝土坍落度的敏感因素之一,由于数据集中 S_P 为0的数据比例过高,当减水剂用量在小于1%时,坍落度可能会降低,如果超出1%时,坍落度则会随着减水剂用量的增加而增加。此外,随着钢纤维体积掺量 V_{oF} 的增加,混凝土的坍落度不断减小,由于纤维在混凝土中形成网络结构,抑制了混凝土的分离和流动^[35-36]。同时,随着钢纤维长径比 R_F 的增加,阻碍混凝土中颗粒的运动,从而降低了纤维混凝土的坍落度^[37-38]。另外,较低的砂率 β_s 可能降低混凝土坍落度,由于砂粒粗难填充空隙,而较高砂率则能提高坍落度,但须合适水灰比以确保工作性;低水灰比 W/C 使混凝土流动性差,坍落度减少,极低比例还可能影响施工性。

综上,坍落度与 R_F 、 V_{oF} 呈负相关,与 β_s 、 W/C 呈正相关。特征重要性以SHAP值绝对值的平均值衡量^[27]。特征重要性从高到低依次为 S_P 、 R_F 、 V_{oF} 、 β_s 、 W/C 。

抗压强度SHAP值散点图如图12所示。从图12可以看出,较低的 W/C 通常会导致混凝土具有更高的抗压强度,这是由于水泥在少量水的情况下可以形成更密实、硬化更彻底的水泥石,从而增强混凝土的结构完整性,而随着水灰比增加,抗压强度降低,是由于多余的水分蒸发后会留下孔隙;适量的 V_{oF} 可桥接混凝土中的微裂缝,减缓裂缝的扩展^[39],可以提高抗压强度,但过量的钢纤维可能导致混凝土内部钢纤维分布不均匀,工作性能下降影响混凝土结构的完整性和密实度,反而会导致抗压强度降低;对于粗骨料用量 C_A ,增加粗骨料用量通常会增加混凝土的抗压强度,由于粗骨料的添加可以提高混凝土的骨料填充率;对于细骨料用量 F_A ,细骨料的适量使用可以改善混凝土的流动性和工作性能,但过多的细骨

料可能会影响混凝土的致密性,降低抗压强度。

综上,抗压强度与 W/C 、 F_A 呈负相关,与 V_{oF} 、 R_F 、 C_A 呈正相关。特征重要性从高到低依次为 W/C 、 V_{oF} 、 R_F 、 C_A 、 F_A 。




图 12 抗压强度 SHAP 值散点图

劈裂抗拉强度 SHAP 值散点图如图 13 所示。由图 13 可知,随着 V_{oF} 的增加,混凝土的劈裂抗拉强度通常会提高,主要是由于钢纤维可有效抵抗拉应力,增强混凝土的抗裂性和韧性^[40],但是超过最佳的钢纤维体积掺量,纤维聚集造成的劈裂抗拉强度增幅可能会逐渐减缓甚至下降;较低的 W/C 通常意味着混凝土具有更高的密度和较低的孔隙率,能够提高劈裂抗拉强度,但高水灰比会导致混凝土中存在更多未参与水化反应的水分,在水分蒸发后形成较多的孔隙^[41],降低其劈裂抗拉强度;在适当用量范围内,随着 S_P 用量增加,纤维分散性更好,有利于抗拉强度的增加;较高的 β_s 可改善混凝土的流动性,促进钢纤维在混凝土中的均匀分布,增强劈裂抗拉强度;当 R_F 较小时对强度增强效果不明显,而较高的 R_F 意味着纤维较长,长纤维更可能跨越裂缝,有效地传递应力,从而减缓裂缝的扩展,提高混凝土的劈裂抗拉强度。综上,劈裂抗拉强度与 W/C 、 S_P 呈负相关,与 β_s 、 V_{oF} 呈正相关。特征重要性从高到低依次为 V_{oF} 、 W/C 、 S_P 、 β_s 、 R_F 。




图 13 劈裂抗拉强度 SHAP 值散点图

3.5 试验结果与预测结果的对比

为进一步验证模型的准确性和可靠性,设计 7 组钢纤维混凝土进行性能试验,具体配合比为:水 225 kg/m^3 ,水泥 450 kg/m^3 ,水灰比 0.50,砂

789 kg/m^3 ,石 964 kg/m^3 ,砂率 0.45,钢纤维体积掺量 0.5%,钢纤维长径比 47,减水剂掺量分别为 0、0.05%、0.10%、0.15%、0.20%、0.25%、0.30%。将钢纤维混凝土的坍落度 S_F 、抗压强度 f_{cu} 和劈裂抗拉强度 f_{st} 的试验结果与预测结果 S_F' 、 f_{cu}' 、 f_{st}' 进行对比,如图 14 所示。




图 14 钢纤维混凝土性能试验结果与预测结果对比

从图 14 可以看出,钢纤维混凝土的坍落度误差小于 0.13,抗压强度误差小于 0.11,劈裂抗拉强度误差小于 0.08,说明模型预测结果在误差允许范围内,预测准确性和可靠性得到验证。

4 结 论

本文基于卷积神经网络建立了钢纤维混凝土的坍落度、抗压强度和劈裂抗拉强度的预测模型,

通过与BPNN、SVR、RF和RBFNN的对比发现,基于CNN的模型精度更高,泛化能力更好。其中,钢纤维混凝土坍落度预测模型测试集的 R^2 为0.97, RMSE、MAE和MBE分别为9.87、7.23、0.15 mm;钢纤维混凝土抗压强度预测模型测试集的 R^2 为0.96, RMSE、MAE和MBE分别为2.48、1.69、0.80 MPa;钢纤维混凝土劈裂抗拉强度预测模型测试集的 R^2 为0.94, RMSE、MAE和MBE分别为0.22、0.19、0.11 MPa。

采用SHAP分析钢纤维混凝土坍落度、抗压强度和劈裂抗拉强度的敏感性因素,这5个因素对坍落度影响均很大,具体的特征重要性从高到低依次为 S_p 、 R_F 、 V_{of} 、 β_s 、 W/C ;水灰比对抗压强度的影响最大,具体的特征重要性从高到低依次为 W/C 、 V_{of} 、 R_F 、 C_A 、 F_A ;钢纤维体积掺量对劈裂抗拉强度的影响最大,具体的特征重要性从高到低依次为 V_{of} 、 W/C 、 S_p 、 β_s 、 R_F 。进一步揭示了5个因素对钢纤维混凝土坍落度、抗压强度和劈裂抗拉强度的影响,为优化钢纤维混凝土的设计、提高钢纤维混凝土的性能奠定了理论基础。

[参 考 文 献]

- [1] ZENG J J, WANG J S, OUYANG Y, et al. Tri-axial compressive behavior of expansive concrete and steel fiber-reinforced expansive concrete[J]. Journal of Building Engineering, 2023, 68: 106026.
- [2] 郑逢时. UHMWPE纤维表面处理及其水泥砂浆性能研究[D]. 西安:长安大学, 2015.
- [3] 张丽娟. 钢纤维再生混凝土配合比设计及其性能计算方法[D]. 郑州:郑州大学, 2017.
- [4] LI J, ZHAO E, NIU J, et al. Study on mixture design method and mechanical properties of steel fiber reinforced self-compacting lightweight aggregate concrete[J]. Construction and Building Materials, 2020, 267(4): 121019.
- [5] ULAS M A, ALYAMAC K E, ULUCAN Z C. Development of nomogram for the practical mix design of steel fiber reinforced concrete[J]. Construction and Building Materials, 2018, 181: 437-446.
- [6] MONTERIO P J M, HELENE P R L, KANG S H. Designing concrete mixtures for strength, elastic modulus and fracture energy[J]. Materials and Structures, 1993, 26: 443-452.
- [7] 陈秀玲. 基于BP神经网络和M2VA法的透水混凝土配合比设计优化[D]. 马鞍山:安徽工业大学, 2020.
- [8] HUANG Y, ZHANG J, ANN F T, et al. Intelligent mixture design of steel fibre reinforced concrete using a support vector regression and firefly algorithm based multi-objective optimization model[J]. Construction and Building Materials, 2020, 260: 120457.
- [9] 崔晓宁, 王起才, 张戎令, 等. 基于随机森林的高性能混凝土抗压强度预测[J]. 兰州交通大学学报, 2021, 40(6): 1-6, 14.
- [10] DENG F M, HE Y G, ZHOU S X, et al. Compressive strength prediction of recycled concrete based on deep learning[J]. Construction and Building Materials, 2018, 175: 562-569.
- [11] PAKZAD S S, ROSHAN N, GHAEHNOVI M. Comparison of various machine learning algorithms used for compressive strength prediction of steel fiber-reinforced concrete[J]. Scientific Reports, 2023, 13: 3646.
- [12] LUNDBERG S, LEE S I. A unified approach to interpreting model predictions[C]//31st Conference on Neural Information Processing Systems. [S.l.: s. n.], 2017: 105-115.
- [13] ZHAO W, FENG S, LIU J, et al. An explainable intelligent algorithm for the multiple performance prediction of cement-based grouting materials[J]. Construction and Building Materials, 2023, 366: 130146.
- [14] LIANG M, CHANG Z, WAN Z, et al. Interpretable ensemble-machine-learning models for predicting creep behavior of concrete[J]. Cement & Concrete Composites, 2022, 125: 104295.
- [15] 查秦雄, 杨晓林, 赵傲铭, 等. 关于优化C40钢纤维混凝土配合比设计的研究[J]. 江西建材, 2018(4): 22-23, 25.
- [16] 梁英花. 钢纤维混凝土在隧道路面中的应用研究[J]. 交通世界, 2017(10): 106-107, 113.
- [17] 马永林. 钢纤维喷射混凝土配合比设计研究[J]. 矿业工程, 2016, 14(2): 60-64.
- [18] DING X, ZHAO M, ZHOU S, et al. Statistical analysis and preliminary study on the mix proportion design of self-compacting steel fiber reinforced concrete[J]. Materials, 2019, 12(4): 637-654.
- [19] SALARI Z, VAKHSHOURI B, NEJADI S. Analytical review of the mix design of fiber reinforced high strength self-compacting concrete[J]. Journal of Building Engineering, 2018, 20: 264-276.
- [20] EMMANUEL T, MAUPONG T MPOELEN D, et al. A survey on missing data in machine learning[J]. Journal of Big Data, 2021(8): 140-177.
- [21] The MathWorks, Inc. MATLAB and statistics toolbox release 2021a [EB/OL]. (2021-03-16) [2023-11-01]. https://ww2.mathworks.cn/en/products/new_products/release2021a.html.
- [22] The MathWorks, Inc. Mapminmax [EB/OL]. (2018-03-15) [2023-11-01]. <https://ww2.mathworks.cn/help/deeplearning/ref/mapminmax.html>.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2): 84-90.
- [24] KOSHEGIO. The mean squared error (MSE) in regression; a beginner's guide [EB/OL]. (2023-01-05) [2024-01-01]. <https://blog.koshegio.com/2023/01/the-mean->

- squared-error-mse-in. html.
- [25] KINGMA D P, BA J. Adam: a method for stochastic optimization[C]//International Conference on Learning Representations. [S. l. : s. n.], 2015: 23-38.
- [26] OBER P B. Introduction to linear regression analysis[J]. Journal of the Royal Statistical Society, 2010, 40 (12): 2775-2776.
- [27] HYNDMAN R J, KOEHLER A B. Another look at measures of forecast accuracy[J]. International Journal of Forecasting, 2006, 22(4): 679-688.
- [28] WILLMOTT C, MATSUURA K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance[J]. Climate Research, 2005, 30(1): 79.
- [29] Python Software Foundation. Python language reference, Version 3. 7. 2 [EB/OL]. (2021-05-03) [2023-11-01]. <https://www.python.org>.
- [30] ALZUBAIDI L, ZHANG J, HUMAIDI A J, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions [J]. Journal of Big Data, 2021(8): 53-127.
- [31] 张然, 柴志勇, 张婷, 等. 基于机器学习模型的洪水预报研究进展[J]. 水利水电技术(中英文), 2023, 54(11): 89-101.
- [32] 许敏, 胡丽丹. 径向基函数神经网络快速算法及其应用[J]. 统计与决策, 2021, 37(16): 52-56.
- [33] 成睿, 孟广源, 殷瑶, 等. 神经网络 BPNN 模型机器学习方法应用于电化学去除氨氮过程的预测与优化[J]. 华东理工大学学报(自然科学版), 2023, 49(2): 202-210.
- [34] 崔晓宁, 王起才, 张戎令, 等. 基于随机森林的高性能混凝土抗压强度预测[J]. 兰州交通大学学报, 2021, 40(6): 1-6, 14.
- [35] KAMAL M M, SAAFAN M, ETMAN Z A, et al. Effect of polypropylene fibers on development of fresh and hardened properties of recycled self-compacting concrete[J]. International Journal of Engineering and Advanced Technology (IJEAT), 2013, 5(2): 86-93.
- [36] WANG W, SHEN A, LYU Z, et al. Fresh and rheological characteristics of fiber reinforced concrete: a review[J]. Construction and Building Materials, 2021, 296: 123734.
- [37] CENTONZE G, LEONE M, AIELLO M A. Steel fibers from waste tires as reinforcement in concrete: a mechanical characterization[J]. Construction and Building Materials, 2012, 36: 46-57.
- [38] WU Z, SHI C, HE W, et al. Effects of steel fiber content and shape on mechanical properties of ultra high performance concrete[J]. Construction and Building Materials, 2016, 103: 8-14.
- [39] 曹二伟. 混杂纤维混凝土碳化性能研究[D]. 沈阳: 东北大学, 2019.
- [40] 代超. 钢纤维-水泥石基体界面特征及对混凝土宏观性能影响的研究[D]. 重庆: 重庆交通大学, 2015.
- [41] 肖巍. 混凝土强度与耐久性的关系研究[D]. 南昌: 南昌大学, 2018.

(责任编辑 吴 亮)

(上接第 710 页)

- [9] ZHAO C, ZENG C, HUANG H, et al. Preliminary study on the periodic base isolation effectiveness and experimental validation [J]. Engineering Structures, 2021, 226(7): 111364.
- [10] 赵春风, 王胤植, 楚凡, 等. 十字形梯度地震超材料带隙特性与隔震性能研究[J]. 工程力学, 2025, 42(9): 63-75.
- [11] 关春颖, 苑立波. 六角蜂窝结构光子晶体异质结带隙特性研究[J]. 物理学报, 2006, 55(3): 1244-1247.
- [12] OUDICH M, ASSOUAR M B. Surface acoustic wave band gaps in a diamond-based two-dimensional locally resonant phononic crystal for high frequency applications[J]. Journal of Applied Physics, 2012, 111(1): 014504.
- [13] 秦凯强, 刘泽, 于桂兰. 具有低频超宽衰减域的部分埋入式表面波屏障[J]. 地震工程与工程振动, 2020, 40(2): 187-194.
- [14] 李丽霞, 李鹏国, 贾琪, 等. 新型半埋入式地震超材料超低频带隙机理及性能研究[J]. 西安建筑科技大学学报(自然科学版), 2023, 55(1): 103-110.
- [15] COLQUITT D J, COLOMBI A, CRASTER R V, et al. Seismic metasurfaces: sub-wavelength resonators and rayleigh wave interaction[J]. Journal of the Mechanics & Physics of Solids, 2016, 99: 379-393.
- [16] XU R, MUZAMIL M, FAN L, et al. Broadband seismic metamaterial with an improved cylinder by introducing plus-shaped structure[J]. Europhysics Letters, 2021, 133(3): 37001-37006.
- [17] LIU Y F, HUANG J K, LI Y G, et al. Trees as large-scale natural metamaterials for low-frequency vibration reduction [J]. Construction and Building Materials, 2019, 199(2): 737-745.

(责任编辑 吴 亮)