

基于不同机器学习方法的UHPC抗压强度预测

杨毅超¹ 张金帆² 潘钻峰^{2,*} 顾征宇¹ 程欣玥²

(1.上海烟草集团有限责任公司,上海 200082; 2.同济大学土木工程学院,上海 200092)

摘要 超高性能混凝土(ultra-high performance concrete,简称UHPC)是一种新型水泥基复合材料,在抗压强度、韧性、延性和耐久性等方面均表现出远超常规混凝土的卓越性能。然而,目前尚缺乏系统化的UHPC配比设计规范,工程实践和科研领域主要依赖经验性结论进行配比设计。本文通过对UHPC相关文献的调研,收集了300组UHPC配合比及材性试验数据,建立包含水泥、粉煤灰、硅灰、石英砂、减水剂、钢纤维和水的用量共7个影响因素及此配比下UHPC抗压强度实测值的数据库。基于此,本文采用支持向量回归(SVR)、反向传播神经网络(BPNN)、随机森林(RF)及极限学习机(ELM)等机器学习方法,开展了UHPC抗压强度的预测模型训练,并基于机器学习方法提出了一种针对指定抗压强度的UHPC配比设计方法。研究表明,以上机器学习方法均能根据UHPC各组分的用量及配比关系对抗压强度进行较为准确的初步预测,训练集的决定系数 R^2 均超过0.8,预测精度较高。通过该配比设计方法,研究者能够有效获得满足特定抗压强度要求的UHPC配比方案。

关键词 超高性能混凝土,机器学习,配比,抗压强度预测

中图分类号: TU528 文献标志码: A DOI: 10.15935/j.cnki.jggcs.202506.0003

Prediction of UHPC Compressive Strength Based on Different Machine Learning Methods

YANG Yichao¹ ZHANG Jinfan² PAN Zuanfeng^{2,*} GU Zhengyu¹ CHENG Xinyue²

(1.Shanghai Tobacco Group Co., Ltd., Shanghai 200082, China;

2.College of Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract Ultra-High Performance Concrete (UHPC) is a high-performance cementitious composite material characterized by ultra-high compressive strength, superior toughness, enhanced ductility, and excellent durability. However, a systematic and standardized framework for UHPC mix design remains lacking. In both engineering applications and scientific research, mix proportioning still heavily relies on empirical approaches. To address this gap, this study compiled a comprehensive database consisting of 300 mix designs and corresponding experimental material properties from a thorough review of the existing UHPC literature. The database incorporates seven key influencing factors: cement content, fly ash content, silica fume content, quartz sand content, superplasticizer dosage, steel fiber content, and water content, along with their experimentally measured compressive strengths. Based on this dataset, several machine learning algorithms—including Random Forest (RF), Extreme Learning Machine (ELM), Support Vector Regression (SVR), and Backpropagation Neural Networks (BPNN)—were employed to develop predictive models for the compressive strength of UHPC. Furthermore, a machine learning-driven mix design methodology was proposed to achieve

收稿日期: 2025-06-04

基金项目: 国家自然科学基金(52378186)

作者简介: 杨毅超(1987-),男,工程师,主要研究方向为混凝土结构。E-mail:ycyang_sh@163.com

* 联系作者: 潘钻峰(1981-),男,教授,主要研究方向为建筑工业化与智能建造。E-mail:zfpan@tongji.edu.cn

targeted compressive strength. The results demonstrate that all adopted machine learning models can provide reasonably accurate preliminary predictions of compressive strength based on the constituent proportions, with the coefficient of determination (R^2) of the training set exceeding 0.8, indicating satisfactory predictive performance. The proposed method effectively generates UHPC mix proportions that meet specified strength requirements, offering a data-driven alternative to conventional empirical design.

Keywords ultra-high performance concrete, machine learning, mix design, compressive strength prediction

0 引言

超高性能混凝土一般是指有着超高抗压强度、极强抗渗能力的纤维增强水泥基复合材料^[1],近年来在建筑行业的应用渐趋广泛。与普通混凝土相比,UHPC剔除了大粒径的粗骨料,提高了水泥的质量占比,同时增加了石英砂和硅灰等相较于水泥颗粒更细的胶凝材料以及钢纤维材料,使UHPC组材内部达到了较高的密实度,因此具有超高强度、类金属拉伸强化特性和超高耐久性能等特点。

机器学习具有从数据集输入和输出变量之间追踪非线性和模糊联系的能力,可以从数据中学习并作出预测或决策^[2]。目前机器学习模型可分为单一学习模型和集成学习模型。单一学习模型主要有决策树、反向传播神经网络、支持向量机、高斯过程回归等^[3]。集成学习模型主要包括随机森林(RF)、自适应增强(AdaBoost)、梯度增强回归树方法(GBRT)和极端梯度增强(XGBoost)等。

近几年来,机器学习的快速发展为很多学科提供了新形式的帮助。许多学者将机器学习算法应用于土木工程领域,并在混凝土强度预测方向进行了一些成功的尝试。2018年,Naderpour^[4]等考虑了水灰比、水胶比、吸水率、细骨料、自然粗骨料和再生粗骨料六个因素作为输入,采用了人工神经网络模型预测了再生混凝土(RAC)的抗压强度,取得了较好的拟合结果。2021年,北京交通大学的刘兵^[5]采用了反向传播神经网络、支持向量机法和极限学习机法建立了再生混凝土的强度预测模型,结果表明支持向量机法预测效果优于反向传播神经网络和支持向量机法。2022年重庆交通大学的胡定宇^[6]采用了随机森林(RF)、自适应增强(AdaBoost)、梯度增强回归树(GBRT)和极端梯度增强(XGBoost)等多种集成学习方法,依据混凝土配比组分对混凝土抗压强度进行了预

测,并分析了超参数对模型精度的影响。同时将上述几种集成学习方法同支持向量机法(SVM)、多层感知机法(MLP)进行比较,发现集成学习方法有着更强的准确性及偏差纠正能力。2024年鄢亦斌等^[7]基于改进的Andreasen-Andersen(MAA)颗粒堆积模型设计了93组UHPC配合比,采用线性回归模型、二次项回归模型、人工神经网络(ANN)模型预测了UHPC的流动度和28d抗压强度,并使用遗传算法(GA)对ANN模型进行优化,得到了GA-ANN模型,并对比了四种模型的预测精度和稳定性。

由于UHPC原材料较多,不同原材料之间存在复杂的耦合关系,目前尚未形成完善的针对UHPC材料的配比设计规范,在工程和科研领域中多依赖经验性的结论来指导配比设计。本文拟在考虑UHPC胶凝材料组分及比例、钢纤维参量和水胶比的基础上,利用支持向量回归(SVR)、反向传播神经网络(BPNN)、随机森林(RF)及极限学习机(ELM)等机器学习方法进行UHPC抗压强度的训练预测,建立起一种对于指定抗压强度的UHPC配比设计方法,从而减小在实际工程施工中,由于材料强度不达标而造成的人力物力及时间成本的浪费。

1 数据库的建立

机器学习模型建立的第一步是创建一个较为全面的数据库。一般来说问题涉及自变量的10~20倍数量的数据样本足以建立回归模型,本研究共收集了300组UHPC的配合比及材性试验结果^[8-14],作为此次机器学习的数据库。

此数据库中每一组数据包含此种UHPC配比中单位体积水泥、粉煤灰、硅灰、石英砂、减水剂、钢纤维和水的用量共7个影响因素及此配比下UHPC在28d时立方体抗压强度实测值。UHPC组材配合比初步分析结果见表1,其中减

水剂单位为占胶凝材料的体积分数,其余材料单位为 kg/m³。

表1 配比初步统计特征
Table 1 Preliminary statistical characteristics of the mix ratio

| No. | 变量 | Max | Min | 均值 | 方差 | 相关系数 |
|-----|-----|-------|------|---------|--------|--------|
| B-1 | 水泥 | 1 226 | 270 | 796.7 | 153.23 | 0.189 |
| B-2 | 粉煤灰 | 352 | 0 | 68.8 | 91.13 | -0.142 |
| B-3 | 硅灰 | 469 | 0 | 150.8 | 82.37 | 0.227 |
| B-4 | 石英砂 | 1 788 | 628 | 1 095.8 | 218.79 | -0.197 |
| B-5 | 水 | 234 | 57.6 | 179.8 | 33.25 | -0.027 |
| B-6 | 减水剂 | 4% | 0.5% | 0.0 | 1% | -0.147 |
| B-7 | 钢纤维 | 390 | 0 | 89.3 | 83.83 | 0.612 |

针对建立的包含 300 组 UHPC 配比及抗压强度的数据库,随机选择 85% 的数据进行训练,建立 UHPC 配比同抗压强度的回归数学模型,剩余 15% 的配比用作预测集。

评价指标选择决定系数 R^2 和均方误差 R_{MSE} ,可由式 1 和式 2 得出:

$$R^2 = \left[\frac{\sum_{i=1}^N (f_t - \bar{f}_t)(f_p - \bar{f}_p)}{\sqrt{\sum_{i=1}^N (f_t - \bar{f}_t)^2 \sum_{i=1}^N (f_p - \bar{f}_p)^2}} \right]^2 \quad (1)$$

$$R_{MSE} = \sqrt{\sum_{i=1}^N \frac{(f_t - f_p)^2}{N}} \quad (2)$$

式中: f_t 和 f_p 分别代表试验结果和预测结果; \bar{f}_t 和 \bar{f}_p 分别代表试验结果平均值和预测结果平均值; N 代表数据点的个数。

2 机器学习方法

2.1 支持向量回归(SVR)方法

支持向量回归(SVR)方法,是一种基于 Vapnik 的统计理论所提出的机器学习方法^[15]。假设含有 1 个训练样本的训练集样本为 $\{(X_i, y_i), i=1, 2, \dots, l\}$, 其中 $X_i (X_i \in R^d)$ 是第 i 个训练样本的输入列向量 $X_i = [X_i^1, X_i^2, \dots, X_i^d]^T, y_i \in R$ 为对应的输出值。

设在高维特征空间中建立的线性回归函数为

$$f(x) = \omega \Phi(x) + b \quad (3)$$

式中: $\Phi(x)$ 为非线性映射函数; 定义 ω 为线性不敏感损失函数。

$$L(f(x), y, \varepsilon) = \begin{cases} 0 & |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & |y - f(x)| > \varepsilon \end{cases} \quad (4)$$

式中: $f(x)$ 为回归函数返回的预测值, y 为对应的真实值; 若 $f(x)$ 与 y 之间的差别 $\leq \varepsilon$, 则损失为 0。

引入松弛变量 ζ, ζ_i^* , 得:

$$\begin{cases} \min = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\zeta_i + \zeta_i^*) \\ s.t. \begin{cases} y_i - \omega \Phi(x_i) - b \leq \varepsilon + \zeta_{i,i=1,2,\dots,l} \\ -y_i + \omega \Phi(x_i) + b \leq \varepsilon + \zeta_i^* \\ \zeta_i \geq 0, \zeta_i^* \geq 0 \end{cases} \end{cases} \quad (5)$$

式中: C 含义为惩罚因子; C 越大表示对训练误差大于 ε 的样本的惩罚越大, ε 规定了回归函数的误差要求, 越小表示回归函数的误差越小, 引入拉格朗日函数, 并转换为以下形式:

$$\max = \left[\begin{aligned} & -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (a_i + a_i^*) (a_j + a_j^*) K(x_i + x_j) \\ & - \sum_{i=1}^l (a_i + a_i^*) y_i \end{aligned} \right] \quad (6)$$

$$s.t. \begin{cases} \sum_{i=1}^l (a_i + a_i^*) = 0 \\ 0 \leq a_i \leq C \\ 0 \leq a_i^* \leq C \end{cases} \quad (7)$$

式中: $K(x_i + y_j) = \Phi(x_i) \Phi(x_j)$, 为核函数。假定上式得到的最优解为 $a = [a_1, a_2, \dots, a_l], a^* = [a_1^*, a_2^*, \dots, a_l^*]$, 则有:

$$\omega^* = \sum_{i=1}^l (a_i - a_i^*) \Phi(x_i) \quad (8)$$

回归函数为:

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) \Phi(x_i) \Phi(x) + b^* = \sum_{i=1}^l (a_i - a_i^*) K(x_i, x) + b^* \quad (9)$$

式中: 不为零的参数 $(a_i - a_i^*)$ 为样本 x_i 的支持向量。

结果如图 1 所示, 图 1(a) 中横坐标为配比编号, 纵坐标为试块的抗压强度, 其中“—○—”表示实测 UHPC28 d 抗压强度, “—□—”表示采用 SVR 算法得到的 UHPC 抗压强度预测值。图 1(b) 中横坐标为实测 UHPC 强度, 纵坐标为采用 SVR 方法预测得到的 UHPC 抗压强度, 图中虚线为直线 $y=x$, 当数据点越靠近直线 $y=x$ 说明预测值越接近实测值, 下述几种方法结果图像坐标轴含义与

此方法相同。

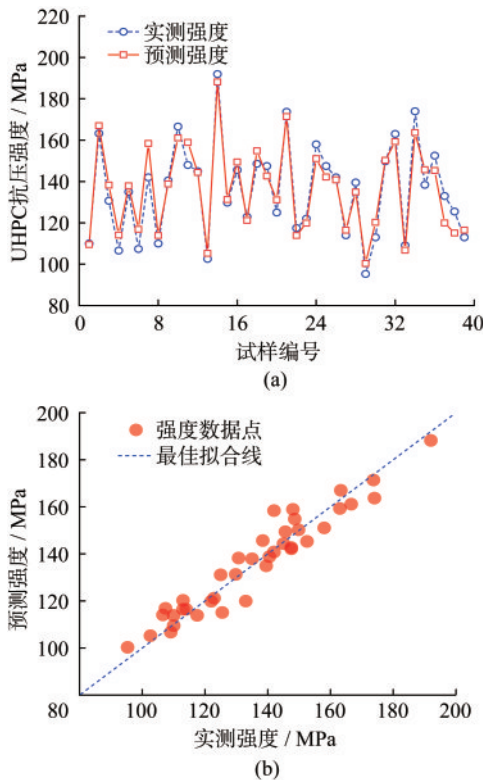


图1 SVR方法预测效果图

Fig.1 Performance evaluation of SVR prediction model

如图1所示,通过SVR算法训练得到的预测结果与真实值相比,均方误差 R_{MSE} 为 3.975, R^2 为 0.85。由式(1)可知均方差为0时表示预测值与真实值完全重合,均方差越小表示预测值与真实值越接近;同时 R^2 范围为 0~1,越接近 1 表示拟合效果越好。因此可以看出使用此方法进行训练所得到的预测值接近真实值,算法预测可靠度较高。

2.2 反向传播神经网络(BP)方法

反向传播神经网络(BP神经网络模型)中包含输入层、隐含层和输出层,主要影响参数有隐含层的节点个数、学习率的选择和激活函数。隐含层神经元越多,模型拟合的效果越好,但神经元过多反而会使得训练速度变慢,另外在数据量少的情况下会使得结果出现过拟合现象,因此隐含层神经元数量的确定是算法能否高效准确运行的关键。

本文通过反向传播神经网络算法建立 UHPC 的强度预测模型来实现 UHPC 强度预测,反向传播神经网络的拓扑结构如图 2 所示,通过激活函数实现从输入层到输出层的任意非线性映射。其中输入向量为 $X=(x_1, x_2, \dots, x_i \dots x_n)$,期望的输出向

量为 $Y=(y_1, y_2, \dots, y_i \dots y_n)$, w_{ij} 为输入层节点同隐含层节点间的网络权值向量, w_{jk} 为隐含层节点与输出层节点间的网络权值向量。




图2 BP神经网络拓扑结构示意图

Fig.2 BP neural network topology diagram

按上述方法建立反向传播神经网络后,对于 UHPC 抗压强度的预测结果如图 3 所示。

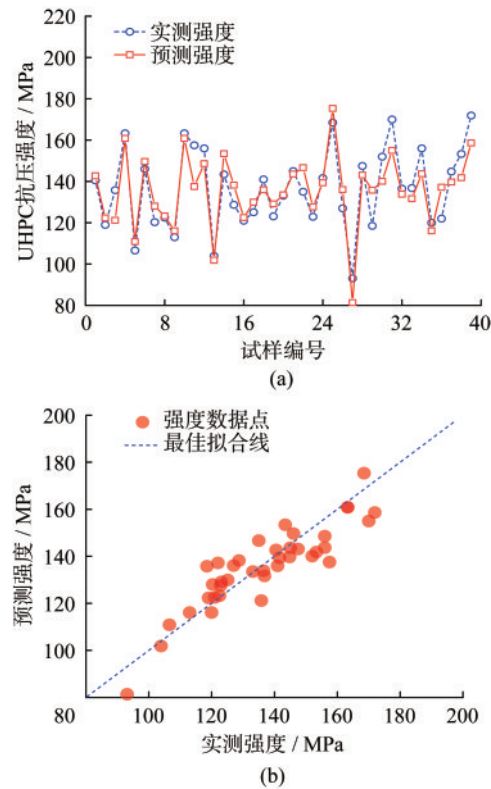


图3 BP神经网络预测效果图

Fig.3 BP neural network prediction result diagram

运用BP神经网络方法进行 UHPC 强度预测,最终预测结果 R^2 为 0.81, R_{MSE} 为 16.85。虽然 R^2 值较小,但通过图 3 可以发现除个别数据预测值与真实值相差较远外,其他数据总体吻合度较好。

2.3 极限学习机(ELM)方法

极限学习机(ELM)方法是 2006 年由 Huang

等^[16]提出的前馈神经网络,主要包含三部分,为输入层、隐含层和输出层。对于 N 组样本来说,其主要工作原理^[17]如下式所示:

$$t_i = \sum_{j=1}^l \beta_j g(\omega_j x_i + b_j) \quad (10)$$

式中: x_i 和 $t_i(i=1, 2, \dots, N)$ 分别为神经网络的输入和输出样本, $g(x)$ 为假设的隐含层激活函数, l 为隐含层神经元的个数, b_i 为 i 个隐含神经元的阈值。 ω_i 和 β_i 分别为神经网络的输入、输出权重。

式(10)可以表示为

$$H\beta = T' \quad (11)$$

式中: H 为隐含层输出矩阵;隐含层同输出矩阵的连接权重 β 可以通过求 $\min_{\beta} \|H\beta - T'\|$ 的最小二乘解求得。

根据EIM定理,当训练集的样本数量较大时, l 的取值通常 $<N$,因此ELM的训练误差可以无限趋向于0,即

$$\sum_{i=1}^l \|t_i - y_i\| < \varepsilon \quad (12)$$

式中: y_i 为此级极限学习机神经网络的期望输出; ε 为一任意大于0的实数。

采用极限学习机方法得到的预测结果如图4所示。

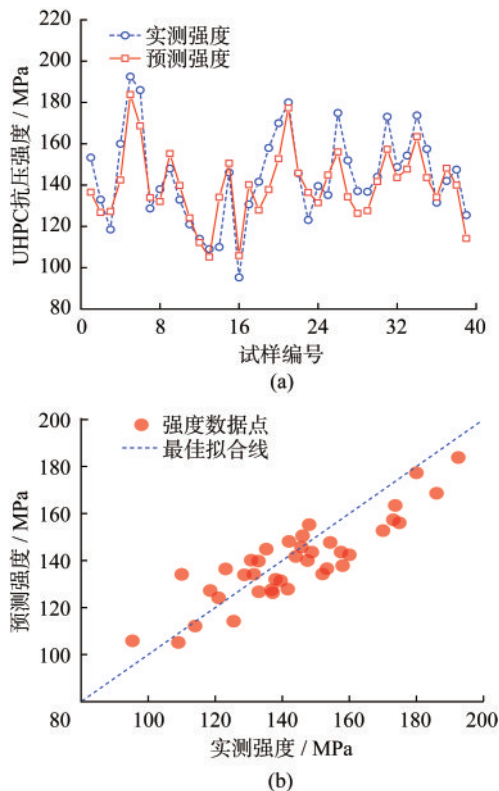


图4 极限学习机法预测效果图

Fig.4 Extreme learning machine prediction result diagram

运用极限学习机方法预测 UHPC 抗压强度,最终 R^2 为0.83, R_{MSE} 为12.3。相较于前两种方法,极限学习机方法预测结果呈现出两级分化状态,即多数试样预测强度同实测强度较为接近,也有一部分试样预测强度同实测强度偏差较大。

2.4 随机森林(RF)方法

随机森林(RF)方法是一类集成学习方法。集成学习是将多个分类器集成以便提高预测性能的算法,主要包括 Boosting(串行)和 Bagging(并行)两种常见的集成学习方法。本文采用的随机森林方法是将随机子空间法与 Bagging 方法相结合的集成方法。

在使用 bootstrap 抽样时,单棵树的训练集从 N 个原始样本中有放回地随机抽取 N 个样本,当 N 足够大时,单个样本在 N 次抽样中会被抽中的概率为

$$P = 1 - \left(1 - \frac{1}{N}\right)^N \quad (13)$$

当 $N \rightarrow \infty$ 时,

$$1 - \left(1 - \frac{1}{N}\right)^N \approx 1 - \frac{1}{e} \approx 0.632 \quad (14)$$

即表明每有约63.2%的样本数据被抽取作为训练集参与建模,因此会有约36.8%的训练数据被浪费掉,没有参与模型训练,这些数据被叫作袋外数据(Out of Bag, OOB),可用作模型的测试集,评估模型的泛化能力。

假设数据量为 n 个,特征变量有 k 个,每个袋外数据的均方误差依次为 $R_{MSE1}, R_{MSE2}, \dots, R_{MSEn}$,标准误差为 R_{SE} ,在袋外数据中对所有特征变量都进行置换,并得到如下误差矩阵 A :

$$A = \begin{bmatrix} R_{MSE11} & \dots & R_{MSE1n} \\ \vdots & \ddots & \vdots \\ R_{MSEe1} & \dots & R_{MSEen} \end{bmatrix} \quad (15)$$

将 $R_{MSE1}, R_{MSE2}, \dots, R_{MSEn}$ 与矩阵 A 中对应行向量相减,再取其平均值与标准误差 R_{SE} 相除,从而计算出变量的重要性评分 U_i :

$$U_i = \frac{\left(\sum_{j=1}^n R_{MSE} - R_{MSEij}\right)}{R_{SE}}, (1 \leq i \leq k) \quad (16)$$

式中: j 为矩阵 A 中向量的列数。

采用随机森林方法得到的预测结果如图5所示。

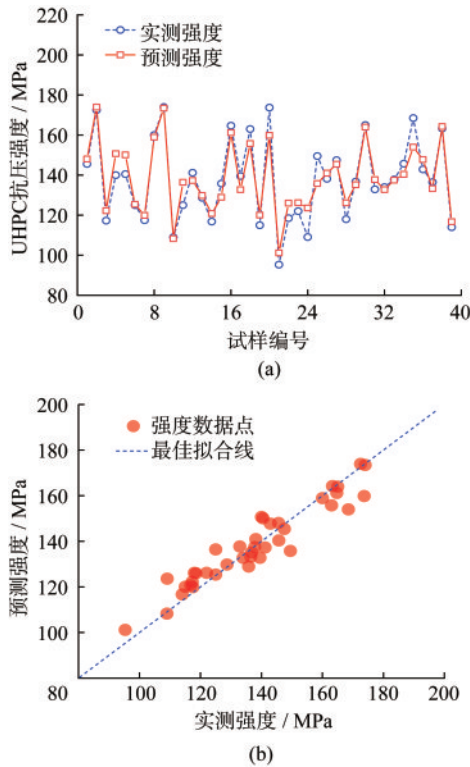


图5 随机森林法预测效果图

Fig.5 Random forest prediction result diagram

从图5中可以看出,随机森林方法预测 R^2 为0.92, R_{MSE} 为2.937,为几种方法中拟合效果最佳的方法。这说明随机森林方法作为一种集成学习方法,相较于其他单一型学习方法,具有拟合效果好、防止过拟合的优势。

3 给定强度的UHPC配比设计方法

为进行特定抗压强度的UHPC配合比设计,本节将基于机器学习设计一种方法来实现。现以抗压强度120 MPa为例进行UHPC配合比设计。

首先从建立的总数据库中挑选出最终UHPC抗压强度处于120~130 MPa区间附近的配合比数据,建立子数据库,求取各项成分均值,并作出合理化调整,得到基准组配比,如表2所示。

其中对于各组分的调整原则作以下说明:对于钢纤维、水两组相对独立变量,采取单一变量参数化分析,即以基准组为标准,参数变量上下浮动。对于水泥、粉煤灰、硅灰和石英砂几组相关联变量,采用固定砂胶比的方法,即石英砂用量同胶凝材料用量之比为定值。对于水泥、粉煤灰和硅灰三组组分,本节因控制砂胶比及石英砂用量不变,因此胶凝材料总量也应为一定值。另外一般认为粉煤灰作为一类较为廉价的材料,常用作水泥和硅灰按比

表2 实测强度为120 MPa的配合比集合

Table 2 The mix ratio set with a measured strength of 120 MPa

| No. | C | FA | SF | S | W | 钢纤维/ ($\text{kg}\cdot\text{m}^{-3}$) | 抗压强度/MPa |
|-------|-------|------|-------|-------|--------|---|----------|
| A-3 | 750 | 200 | 144 | 990 | 190 | 0 | 120.3 |
| A-17 | 700 | 105 | 210 | 840 | 203 | 78.5 | 117.4 |
| A-18 | 700 | 105 | 210 | 840 | 203 | 157 | 125.7 |
| A-26 | 1 087 | 121 | 0 | 967 | 195.7 | 156 | 133.4 |
| A-47 | 791 | 186 | 186 | 930 | 226 | 78 | 123.1 |
| A-52 | 800 | 0 | 200 | 1 056 | 180 | 156 | 128.8 |
| A-92 | 907 | 0 | 0 | 1 179 | 163.26 | 156 | 127.0 |
| A-104 | 661 | 0 | 136 | 1 232 | 159.4 | 78 | 125.5 |
| A-116 | 879 | 0 | 293 | 1 406 | 211 | 0 | 123.0 |
| A-117 | 879 | 0 | 293 | 1 406 | 223 | 0 | 122.0 |
| A-136 | 800 | 0 | 200 | 1 100 | 180 | 39 | 125.0 |
| 均值 | 814 | 65.2 | 170.2 | 1 086 | 194.0 | 81.7 | 124.7 |
| 基准组 | 815 | 65 | 170 | 1 080 | 195 | 78 | — |

注:表中C为水泥用量,FA为粉煤灰用量,SF为硅灰用量,S为砂用量,W为水用量。

例的替代品,此比例即为水泥或硅灰的取代率。因此本节中考虑水泥及硅灰的参数分析时,通过控制粉煤灰用量来实现胶凝材料总量保持不变。

基于水泥、硅灰、水和钢纤维四组变量进行参数分析,具体配比如表3—表6所示。

表3 考虑水泥用量的UHPC配合比

Table 3 UHPC mix ratio based on cement content

| 编号 | C | FA | SF | S | W | 钢纤维 | 抗压强度 |
|----|-----|-----|-----|-------|-----|-----|--------|
| S1 | 755 | 105 | 170 | 1 080 | 195 | 78 | 121.21 |
| S2 | 785 | 85 | 170 | 1 080 | 195 | 78 | 123.96 |
| JZ | 815 | 65 | 170 | 1 080 | 195 | 78 | 126.11 |
| S3 | 845 | 45 | 170 | 1 080 | 195 | 78 | 129.39 |
| S4 | 875 | 25 | 170 | 1 080 | 195 | 78 | 130.14 |

表4 考虑硅灰掺量的UHPC配合比

Table 4 UHPC mix ratio based on the addition of silica fume

| 编号 | C | FA | SF | S | W | 钢纤维 | 抗压强度 |
|-----|-----|-----|-----|-------|-----|-----|--------|
| SF1 | 815 | 105 | 110 | 1 080 | 195 | 78 | 117.09 |
| SF2 | 815 | 85 | 140 | 1 080 | 195 | 78 | 121.78 |
| JZ | 815 | 65 | 170 | 1 080 | 195 | 78 | 126.11 |
| SF3 | 815 | 45 | 200 | 1 080 | 195 | 78 | 129.73 |
| SF4 | 815 | 25 | 230 | 1 080 | 195 | 78 | 134.59 |

采用SVR方法、BP神经网络方法、极限学习机方法和随机森林方法预测各组配比抗压强度并取均值,预测结果如图6所示。

表5 考虑水用量的UHPC配合比


Table 5 UHPC mix ratio based on water content

| 编号 | C | FA | SF | S | W | 钢纤维 | 抗压强度 |
|----|-----|----|-----|-------|-----|-----|--------|
| W1 | 815 | 65 | 170 | 1 080 | 155 | 78 | 142.75 |
| W2 | 815 | 65 | 170 | 1 080 | 175 | 78 | 132.89 |
| JZ | 815 | 65 | 170 | 1 080 | 195 | 78 | 126.11 |
| W3 | 815 | 65 | 170 | 1 080 | 215 | 78 | 124.24 |
| W4 | 815 | 65 | 170 | 1 080 | 235 | 78 | 123.33 |

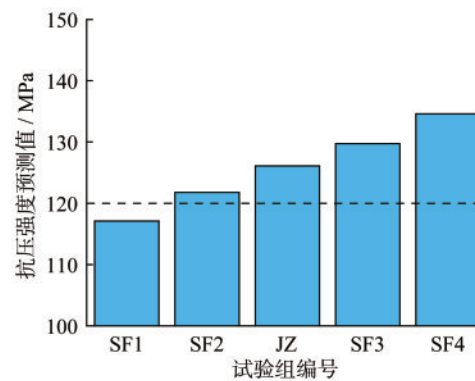
表6 考虑钢纤维掺量的UHPC配合比

Table 6 UHPC mix ratio based on steel fiber content

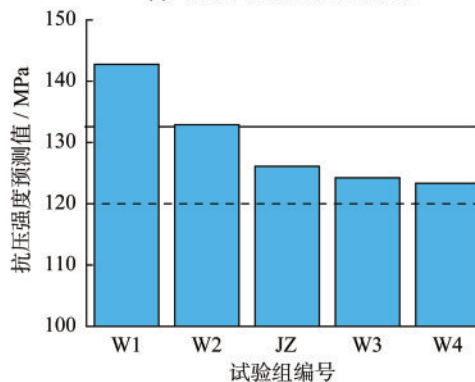
| 编号 | C | FA | SF | S | W | 钢纤维 | 抗压强度 |
|----|-----|----|-----|-------|-----|-----|--------|
| F1 | 815 | 65 | 170 | 1 080 | 195 | 0 | 110.43 |
| F2 | 815 | 65 | 170 | 1 080 | 195 | 39 | 118.39 |
| JZ | 815 | 65 | 170 | 1 080 | 195 | 78 | 126.11 |
| F3 | 815 | 65 | 170 | 1 080 | 195 | 117 | 132.96 |
| F4 | 815 | 65 | 170 | 1 080 | 195 | 158 | 139.34 |



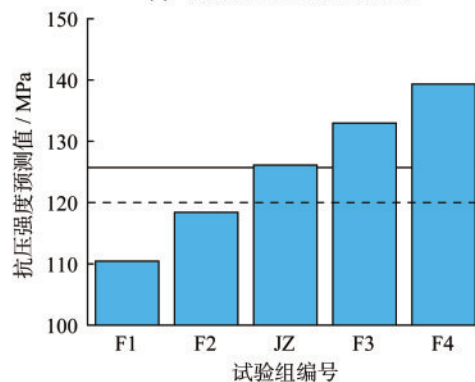
(a) 考虑水泥用量的预测结果



(b) 考虑硅灰掺量的预测结果



(c) 考虑水用量的预测结果



(d) 考虑钢纤维掺量的预测结果

图6 各个参数的抗压强度预测结果

Fig.6 Compressive strength prediction results for each parameter

在进行水泥用量、硅灰用量、用水量和钢纤维掺量的参数分析之后,可以发现硅灰和钢纤维的用量与UHPC抗压强度之间存在正相关关系,而水胶比(水的用量)同UHPC抗压强度之间存在负相关关系。有多组数据最终接近目标强度120 MPa,包括试验组编号JZ、S1、S2、SF1、SF2、W4、W5配比。因为配比同抗压强度是一种多对一的映射关系,即同一指定抗压强度会由多种不同配比来实现。因此本次机器学习预测结果也会出现多组符合强度要求的配比。

此外,此次机器学习采用的配合比优选方法尚存在一定局限性,该方法依赖人工经验在原数据范围内构建候选方案,无法确保获得全局最优

解。若在具体实际工程中要求采用指定抗压强度下的最优配比,还应综合考虑造价、材料流动性等多方面工程约束,利用全局优化算法自动搜索最优配合比。

4 结 论

本文通过文献调研建立了UHPC配比数据库,在考虑UHPC胶凝材料组分及比例、钢纤维掺量和水胶比的基础上,利用支持向量回归(SVR)、反向传播神经网络(BPNN)、随机森林(RF)及极限学习机(ELM)等机器学习方法对UHPC抗压强度进行训练预测,并设计给定强度的UHPC配比

设计方法,探究抗压强度的参数影响分析,得到如下结论:

(1) 上述几种方法皆能够依据 UHPC 各个组分的用量及配比关系,初步地预测 UHPC 的抗压强度,最终得到的训练集的决定系数 R^2 皆在 0.8 以上,预测拟合效果较好。

(2) 随机森林方法预测 R^2 为 0.92,均方误差 R_{MSE} 为 2.937,为几种方法中拟合效果最佳的方法。相较于其他单一型学习方法(支持向量回归、BP 神经网络、极限学习机),集成学习方法具有拟合效果优、防止过拟合的优势。因此集成学习方法预测结果优于单一学习方法。

(3) 本文通过基于机器学习方法,建立起一种对于指定抗压强度的 UHPC 配比设计方法,并对配合比中的水泥用量、硅灰用量、用水量和钢纤维掺量展开参数影响分析,硅灰和钢纤维的用量与 UHPC 抗压强度之间存在正相关关系,而水胶比(水的用量)同 UHPC 抗压强度之间存在负相关关系。同一指定抗压强度会由多种不同配比来实现,预测结果也会出现多组符合强度要求的配比。

参 考 文 献

- [1] YOO D Y, YOON Y S. A review on structure behavior, design, and application of ultra-high-performance fiber-reinforced concrete [J]. *International Journal of Concrete Structure and Materials*, 2016, 10(2): 125-142.
- [2] 欧阳利军, 石永超, 丁斌, 等. 基于机器学习预测超高性能混凝土的抗压强度 [J]. *混凝土与水泥制品*, 2025, 347(3): 1-7.
OUYANG Lijun, SHI Yongchao, DING Bin, et al. Prediction of compressive strength of ultra-high performance concrete based on machine learning [J]. *Concrete and Cement Products*, 2025, 347(3): 1-7. (in Chinese)
- [3] 刘凯华, 郑佳凯, 谢维力, 等. 基于机器学习的再生混凝土配合比设计方法 [J]. *湖南大学学报(自然科学版)*, 2023, 50(9): 88-96.
LIU Kaihua, ZHENG Jiakai, XIE Weili, et al. Mix proportion design method of recycled concrete based on machine learning [J]. *Journal of Hunan University (Natural Science Edition)*, 2023, 50(9): 88-96. (in Chinese)
- [4] NADERPOUR H, RAFIEAN A H, FAKHARIAN P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks [J]. *Journal of Building Engineering*, 2018(16): 213-219.
- [5] 刘兵. 基于机器学习的再生混凝土强度预测和 LAA-LCC 生态效率评价 [D]. 北京: 北京交通大学, 2021.
LIU Bing. Recycled aggregate concrete strength prediction and eco-efficiency evaluation of LCA-LCC Based on Machine Learning [D]. Beijing: Beijing Jiaotong University, 2021. (in Chinese)
- [6] 胡定宇. 基于机器学习和优化算法的混凝土性能预测及配合比设计 [D]. 重庆: 重庆交通大学, 2022.
HU Dingyu. Concrete performance prediction and mix proportion design based on machine learning and optimization algorithm [D]. Chongqing: Chongqing Jiaotong University, 2022. (in Chinese)
- [7] 鄢亦斌, 刘开志, 高立强, 等. 基于机器学习的超高性能混凝土性能预测 [J]. *混凝土与水泥制品*, 2024, 343(11): 49-53, 59. DOI: 10.19761/j.1000-4637.2024.11.049.06.
YAN Yibin, LIU Kaizhi, GAO Liqiang, et al. Performance prediction of ultra-high performance concrete based on machine learning [J]. *Concrete and Cement Products*, 2024, 343(11): 49-53, 59. DOI: 10.19761/j.1000-4637.2024.11.049.06. (in Chinese)
- [8] 陈玉超, 潘杰, 刘明涛, 等. 超高减水型聚羧酸减水剂的合成及其在 UHPC 中的应用研究 [J]. *新型建筑材料*, 2023, 50(3): 127-130.
CHEN Yuchao, PAN Jie, LIU Mingtao, et al. Synthesis of ultra-high water-reducing polycarboxylate superplasticizer and its application in UHPC [J]. *New Building Materials*, 2023, 50(3): 127-130. (in Chinese)
- [9] 李永. 本土化材料对 UHPC 力学性能及微观结构的影响 [D]. 兰州: 兰州交通大学, 2022.
LI Yong. Influence of localized materials on mechanical properties and microstructure of UHPC [D]. Lanzhou: Lanzhou Jiaotong University, 2022. (in Chinese)
- [10] 许文英, 尹江涛, 张利俊, 等. UHPC 用超高性能减水剂的合成与性能研究 [J]. *新型建筑材料*, 2022, 49(1): 81-84.
XU Wenyong, YIN Jiangtao, ZHANG Lijun, et al. Study on synthesis and properties of ultra-high performance water reducer for UHPC [J]. *New Building Materials*, 2022, 49(1): 81-84. (in Chinese)
- [11] 余睿, 范定强, 孙美娟, 等. 钢纤维掺量及其 3D 空间结构对超高性能混凝土性能的影响 [J]. *硅酸盐学报*, 2021, 49(11): 2313-2321.
YU Rui, FAN Dingqiang, SUN Meijuan, et al. The influence of steel fiber content and its 3D spatial structure on the performance of ultra-high performance

- concrete [J]. Journal of Silicate, 2021, 49(11): 2313-2321. (in Chinese)
- [12] 刘奎启. 超高性能混凝土减水剂优选试验研究[J]. 市政技术, 2021, 39(12): 138-141, 146.
LIU Kuiqi. Experimental study on optimization of super high performance concrete water reducing agent [J]. Municipal Technology, 2021, 39(12): 138-141, 146. (in Chinese)
- [13] 樊俊江, 於林锋, 韩建军. 配比参数对UHPC流动性及抗压强度的影响试验研究[J]. 新型建筑材料, 2019, 46(4): 5-8.
FAN Junjiang, YU Linfeng, HAN Jianjun. Experimental study on the influence of mixing parameters on the fluidity and compressive strength of UHPC [J]. New Building Materials, 2019, 46(4): 5-8. (in Chinese)
- [14] 陈庆, 马瑞, 蒋正武, 等. 基于GA-BP神经网络的UHPC抗压强度预测与配合比设计[J]. 建筑材料学报, 2020, 23(1): 176-183, 191.
CHEN Qing, MA Rui, JIANG Zhengwu, et al. Compressive strength prediction and mix proportion design of UHPC based on GA-BP neural network [J]. Journal of Building Materials, 2020, 23(1): 176-183, 191. (in Chinese)
- [15] 高宝成, 陶博文. 基于SVR算法的混凝土强度预测[J]. 城市住宅, 2019, 26(4): 143-146.
GAO Baocheng, TAO Bowen. Prediction of concrete strength based on SVR algorithm [J]. Urban housing, 2019, 26(4): 143-146. (in Chinese)
- [16] HUANG G, ZHU Q, SIEW C. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70: 489-501.
- [17] 曹恩华, 包腾飞, 胡绍沛, 等. 基于变量筛选优化极限学习机的混凝土坝变形预测模型[J]. 长江科学院院报, 2022, 39(7): 59-65.
CAO Enhua, BAO Tengfei, HU Shaopei, et al. Deformation prediction model of concrete dam based on variable screening optimization extreme learning machine [J]. Journal of Yangtze River Academy of Sciences, 2022, 39(7): 59-65. (in Chinese)