

机器学习在混凝土抗压强度预测的应用研究



姜万顺¹, 肖丙刚^{1,*}, 王奕鹏¹, 张亮亮², 赵华², 冯兰洲², 徐昌杰², 赖德发²

¹中国计量大学信息工程学院, 浙江杭州 310018

²中才邦业(杭州)智能技术有限公司, 浙江杭州 310000

摘要: 混凝土抗压强度是影响建筑质量的主要因素之一, 也是混凝土设计的关键参数, 对其进行预测具有必要性。然而, 早期采用经验公式预测混凝土抗压强度大多数是针对特定的混凝土, 无法普遍推广, 而其他预测方法例如: 物理检测法、有限元分析法等步骤繁琐, 适用条件苛刻也无法形成普适性的预测模型。近年来, 基于机器学习的混凝土抗压强度预测模型成为国内外研究热点。本文首先通过比较各种机器学习方法, 包括回归模型、支持向量回归机模型、树模型、神经网络和集成学习等在混凝土抗压强度方面的应用, 得出支持向量回归机模型与集成学习在抗压强度的预测上具有更高的有效性。最后, 文章讨论了目前所广泛采用的混凝土抗压强度预测方法的不足之处, 并给出了基于机器学习的混凝土抗压强度预测模型未来的研究方向。

关键词: 混凝土抗压强度; 机器学习; 集成学习; 过拟合

DOI: [10.57237/j.se.2023.05.003](https://doi.org/10.57237/j.se.2023.05.003)

A Study on the Application of Machine Learning for Predicting Concrete Compressive Strength

Jiang Wan-shun¹, Xiao Bing-gang¹, Wang Yi-peng¹, Zhang Liang-liang², Zhao Hua²,
Feng Lan-zhou², Xu Chang-jie², Lai De-fa²

¹School of Information Engineering, China Jiliang University, Hangzhou 310018, China

²SINOMA Bonyear (Hangzhou) Intelligent Technology Co. Ltd., Hangzhou 310000, China

Abstract: The compressive strength of concrete is one of the main factors affecting the quality of construction, and it is also a key parameter for concrete design, so it is necessary to predict it. However, most of the early empirical formulas for predicting the compressive strength of concrete are for specific concretes, which can not be universally promoted, while other prediction methods such as physical testing method, finite element analysis method, etc. are cumbersome in terms of steps, and can not be formed into a generalized prediction model under the harsh conditions of applicability. In recent years, the concrete compressive strength prediction model based on machine learning has become a hot research topic at home and abroad. In this paper, firstly, by comparing the application of various machine learning methods, including regression model, support vector regression machine model, tree model, neural network and integrated learning in concrete compressive strength, it is concluded that the support vector regression machine model and

基金项目: 2022 年度杭州市重大科技创新项目 (2022AIZD0085); 2022 年度杭州市重大科技创新项目 (2022AIZD0016).

*通信作者: 肖丙刚, bgxiao@cjlu.edu.cn

收稿日期: 2023-09-08; 接受日期: 2023-10-26; 在线出版日期: 2023-10-28

<http://www.sciandeng.com>

integrated learning have higher effectiveness in the prediction of compressive strength. Finally, the article discusses the shortcomings of the widely used concrete compressive strength prediction methods and gives the future research direction of machine learning based concrete compressive strength prediction model.

Keywords: Concrete Compressive Strength; Machine Learning; Ensemble Learning; Overfitting

1 前言

混凝土是建筑行业最重要的结构材料之一，其抗压强度（Concrete Compressive Strength, CCS）对建筑的荷载和安全性能起着决定性作用[1]。早期人们主要考经验公式预测抗压强度,如 Duff Abrams [2]就提出著名的“水灰比法则”（water-to-cement ratio rule），同时利用混凝土回弹仪[3]、超声波传感器[4]等方法检测样本的抗压强度也有所发展。但经验公式存在局限性没有大规模使用[5]，而物理检测法过程繁琐。

随着机器学习（Machine Learning, ML）技术的发展，研究人员对于利用机器学习来预测混凝土抗压强度的兴趣不断增加[6, 7]。机器学习因其自动学习隐含特征和有用信息的能力，以及对混凝土特性的兼容性，成为混凝土抗压强度研究的热点[8]。

本文将总结机器学习在混凝土抗压强度预测方面

的应用，为今后研究提供参考意义。

2 基于机器学习的混凝土抗压强度预测模型

2.1 机器学习用于抗压强度预测流程

机器学习模型用于预测混凝土抗压强度的典型步骤如图 1 所示，主要包括：问题提出、数据集构建、数据预处理、模型构建、模型评估和模型部署。关键步骤是问题的提出和模型的构建与评估，并通过试验或经验验证，最终根据结果进行迭代调优。

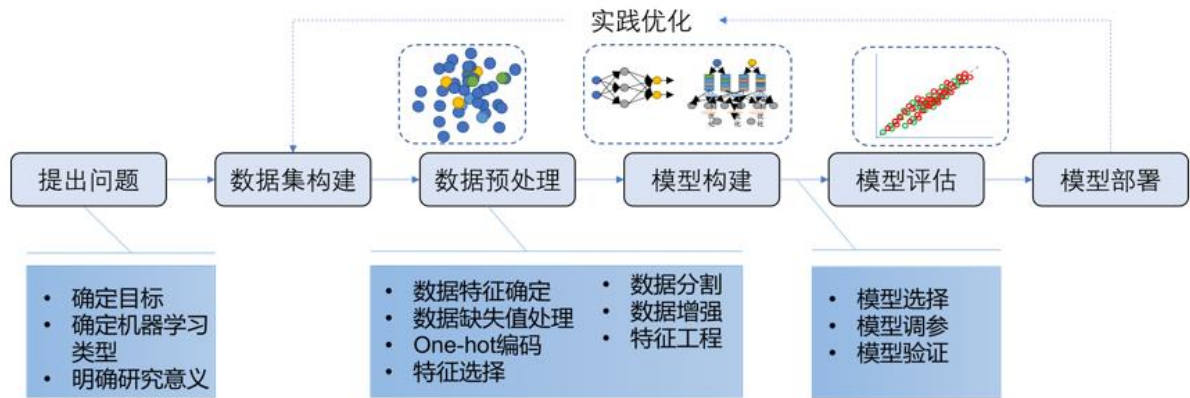


图 1 机器学习的混凝土抗压强度预测模型流程

2.2 常见机器学习模型在抗压强度预测方面的应用

2.2.1 线性模型

在应用和分析中，最简单的模型就是线性回归

(Linear Regression, LR)。除了对数据集进行有效拟合预测外，线性回归还可以作为评估其他技术的基准[9]。其公式可以表示为：

$$\hat{y} = x^T \beta + \epsilon$$

其中 β 为线性模型系数（参数）的 N 维向量， ϵ 是误差项。

多项式回归 (Multivariate Polynomial Regression, MPR) 是线性回归模型的推广, 一个具有两个预测变量的扩展二阶多项式可简单表述为:

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \beta_{12} x_1 x_2$$

2.2.2 支持向量回归机

而支持向量机是一种从统计学理论衍生而来的统计模型, 支持向量回归机 (Support Vector Machine Regression, SVR) 是将支持向量机用于回归问题的特殊形式, 利用支持向量回归机进行混凝土抗压强度预测模型构建, 最重要的是对于支持向量回归机中三个重要性能指标: 惩罚参数 C 、核函数数 σ 以及不敏感损失参数 ϵ , 进行确定, 为了提高参数优化能力, 一般会利用智能优化算法对此三种参数进行优化。智能优化算法的使用对支持向量回归机参数选择有较大帮助[10-12]。

2.2.3 树模型

决策树 (Decision Tree, DT) 是一种基于树状结构的机器学习模型, Shah S A R 等人利用决策树预测混凝土抗压强度, 显示出了相关变量与混凝土抗压强度之间具有强相关性与高精度[13]。而随机森林(Random Forest, RF) 算法是一种将多棵决策树进行集成的方法。随机森林预测技术还具有对异常值具有鲁棒性的特点, 因此在预测混凝土抗压强度时可以得到较好的预测效果[14]。

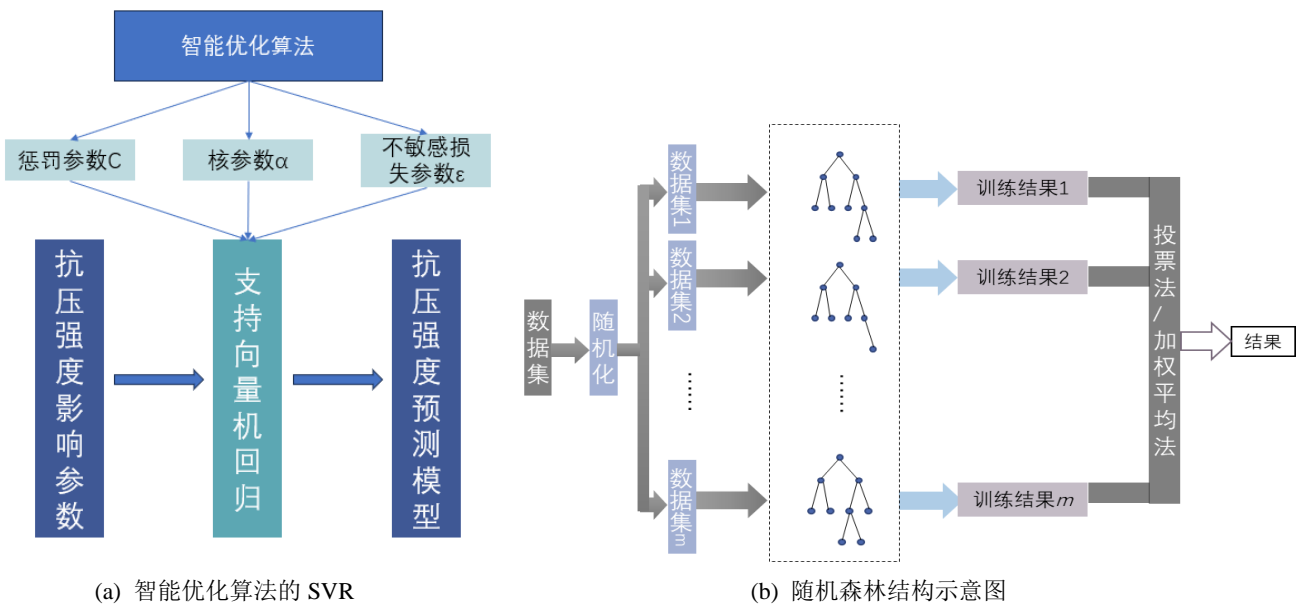
2.2.4 神经网络

神经网络 (Neural Network, NN) 种类繁多, 是一种模拟人类大脑的信息处理系统的算法模型[15]。预测前需对混凝土数据进行预处理, 提取输入特征。在训练过程中, 神经网络通过调整权重和偏置的参数, 使得预测结果接近真实值。反向传播算法、梯度下降算法等可用于最小化损失函数, 提高预测准确率。

2.2.5 集成学习

利用集成学习 (Ensemble Learning, EL) 策略进行训练也是常见的方案, 上述方案中随机森林即是一种集成学习策略。集成学习基本思想是通过结合多个学习算法的预测结果, 来提高准确率, 并降低过拟合[16]。集成学习的策略有很多种, 如: bagging、boosting、stacking 等[17]。

Bagging 是一种通过从数据中随机选取训练样本来生成多个学习算法的方法, 代表的算法为随机森林。Boosting 是一种将多个弱分类器组合成一个强分类器的方法, 通过加强每一轮学习过程中的错误, 促使学习算法强化那些难以被正确分类的样本, 从而提高学习算法的预测准确性, 代表的算法有 AdaBoost、GBDT、XGBoost 等。Stacking 是一种将多个学习算法的预测结果结合在一起, 并通过第二层学习算法综合这些结果, 来得到最终预测结果的方法。



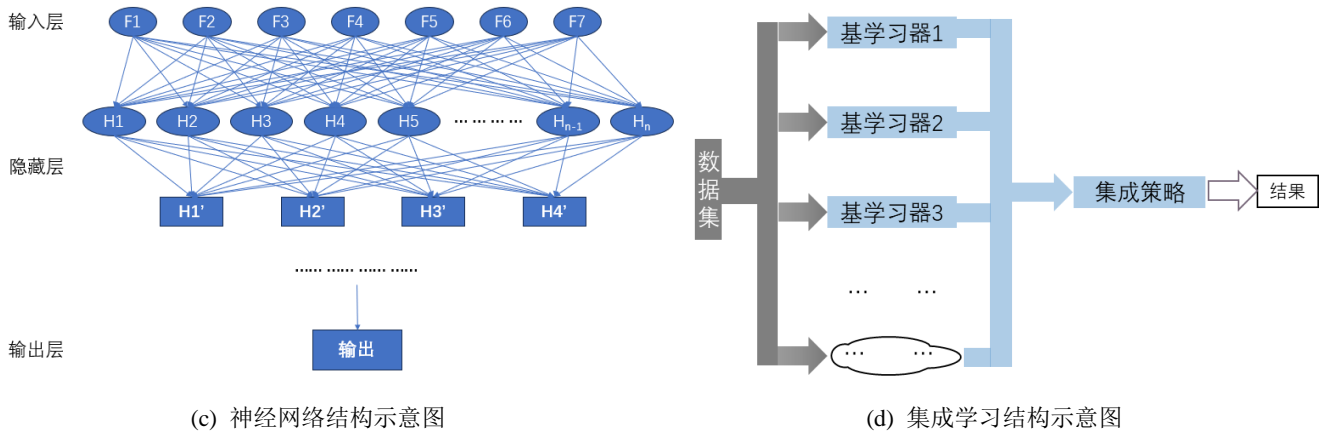


图 2 不同机器学习模型结构示意图

表 1 总结了不同机器学习模型在混凝土抗压强度预测方面应用情况。

表 2 利用公开的混凝土抗压强度数据集，按照 8:2 划分训练集与测试集，并调整各模型超参数，得到的平均绝对误差 (MAE)、均方根误差 (RMSE)、平均绝对百分比误差 (MAPE)、与决定系数 (R2)，其中前 3 项越小、决定系数越接近于 1，模型预测效果越好。表中 Stacking 模型基学习器分别为 SVR-GBDT-DT，元学习器为 GBDT

由表 2 可知，简单回归模型（线性回归、多项式回归）预测能力较差，树模型与神经网络模型整体效果相当，能基本预测出数据趋势。

而预测能力最突出的模型为集成学习中的 Stacking 策略模型，其决定系数高达 0.9415。而其他几种类型的集成学习模型（随机森林、AdaBoost、GBDT、XGBoost）除随机森林外，决定系数均超过了 0.9。除集成学习模型外，其他模型中 SVR 表现最优。因此集成学习与 SVR 在混凝土抗压强度预测领域，有较好应用前景。

表 1 不同机器学习模型在混凝土抗压强度预测方面应用情况

名称	概述	总结
回归模型		
线性回归	将输出（目标）变量描述为预测变量的线性组合的模型。	模型简单，易于实现，但对异常值与非线性数据表现不佳，一般用于对其他模型评价[18]与其他模型集成[19]
多项式回归	使用输入变量的 n 次多项式来预测输出变量。	相较于线性回归更复杂，利用多项式回归方程预测混凝土抗压强度[20]可取得较好效果，但由于混凝土抗压强度影响因子多，一般与其他模型结合分析[21]。
支持向量回归机	建立一个超平面用来最大程度拟合最多实例，其中利用核函数进行非线性映射。	具有较强的泛化能力，准确度与稳定性相较于线性模型得到大幅提升，一般利用支持向量回归机预测混凝土抗压强度[22-25]或与其他模型集成新模型预测混凝土抗压强度[11, 19, 26]均有较多应用。
树模型		
决策树	利用节点特征迭代来分割数据构建树模型，并保证最大化信息增益，直到得到叶子节点。	树模型可解释性更强，同时决策树计算复杂性低，利用决策树预测混凝土抗压强度[12, 13, 27-29]误差在可接受范围内，但模型训练容易导致过拟合，效果不理想。
随机森林	利用多个决策树组成的一种集成学习方法	解决了决策树的过拟合问题，但降低了可解释性，利用随机森林预测混凝土抗压强度[28, 30-31]、或者与其他算法集成[32]、用于其他模型评估[33]均有较多应用。
神经网络	利用相互连接的神经元构建，每个神经元与其他神经元连接，并具有权重与阈值，来最小化损失函数。	神经网络种类多，对于复杂的非线性关系预测准确率高，但容易造成过拟合，利用神经网络预测混凝土抗压强度[34-39]或结合其他模型预测抗压强度[21]、抗弯强度[40]均有应用。
集成学习	组合多个学习算法，以提高预测性能的技术。	可有效解决过拟合问题，同时准确率有所提高，三大集成策略 bagging、boosting 及 stacking 在混凝土抗压强度样本量不大时表现较为优异 [41-44]。

表 2 不同机器学习模型在混凝土抗压强度数据集上的评价指标

模型名称	MAE	RMSE	MAPE (%)	R ²
回归模型				
线性回归	7.8646	9.7784	33.16	0.6369
多项式回归	7.5137	9.6804	27.07	0.5923
SVR	3.8289	6.0450	13.38	0.8613
树模型				
决策树	4.0600	6.3500	13.23	0.8500
随机森林	3.9777	5.5366	13.00	0.8810
神经网络	4.7863	6.1800	17.91	0.8550
集成学习				
AdaBoost	3.1942	4.8052	10.26	0.9106
GBDT	2.6792	4.1911	8.66	0.9318
XGBoost	2.7298	4.1297	8.81	0.9338
Stacking	2.5923	4.0364	9.07	0.9415

3 总结

本文讨论了各种机器学习方法在混凝土抗压强度预测方面的应用，具有自动学习隐含特征和信息的能力，在预测复杂混凝土抗压强度方面表现出良好的应用前景，尤其是集成学习通过组合不同模型，能提高模型预测泛化性能，从而避免模型过拟合，可以加强集成学习在混凝土抗压强度预测方面的研究。

目前，机器学习方法在混凝土抗压强度预测方面已经取得了一定的成果，但仍面临着一些挑战，未来的研究可以从以下几个方面展开：

- (1) 数据集的建立和完善。混凝土抗压强度受到多种因素的影响，需要包含大量的样本数据来训练模型。未来的研究可以进一步扩大数据集的规模，并且考虑到不同地区和不同年代的混凝土材料的不同特性，建立更加全面和有代表性的数据集。
- (2) 特征选择和提取。在混凝土抗压强度预测中，特征选择对机器学习模型的性能影响很大。现有方法中，已经有研究人员利用智能优化算法来选择模型特征与算法参数，未来的研究可以探索更加高效的特征选择和提取方法，从而进一步提高模型的预测能力和泛化性能。
- (3) 模型结构的优化。目前，混凝土抗压强度预测中常用的机器学习模型主要包括神经网络、支持向量回归机和决策树等。未来的研究可以尝试更加复杂和灵活的模型结构，如深度学习模型和集成学习模型，进一步提高预测精度和鲁棒性。

- (4) 模型可解释性。对于混凝土抗压强度预测模型，其可解释性也很重要，尤其是对于工程运用而言，良好的解释性可以保障施工的安全性。树模型拥有较强的解释性，但准确性不如神经网络，未来的研究可以探索更加有效的方法，从而提高模型的可解释性，从而提高模型的可信度和可靠性。

综上，相较之下，机器学习在混凝土抗压强度预测领域还有巨大潜力，也必将在未来更好的预测混凝土抗压强度，来提升工程质量。

参考文献

- [1] Bloem D L, Delevante O L. Building code requirements for reinforced concrete [J]. ACI Journal, 1970, 1(1970): 77.
- [2] Neville A M. Properties of concrete [M]. London: Longman, 1995.
- [3] 肖建庄, 李佳彬, 孙振平. 回弹法检测再生混凝土抗压强度研究 [J]. 四川建筑科学研究, 2004, 30(4): 51-54.
- [4] Yoon H, Kim Y J, Kim H S, et al. Evaluation of early-age concrete compressive strength with ultrasonic sensors [J]. Sensors, 2017, 17(8): 1817.
- [5] Popovics S. New formulas for the prediction of the effect of porosity on concrete strength [C] // Journal Proceedings. 1985, 82(2): 136-146.
- [6] Young B A, Hall A, Pilon L, et al. Can the compressive strength of concrete be estimated from knowledge of the mixture proportions? New insights from statistical analysis and machine learning methods [J]. Cement and Concrete Research, 2019, 115: 379-388.

- [7] DeRousseau M A, Kasprzyk J R, Srubar Iii W V. Computational design optimization of concrete mixtures: A review [J]. *Cement and Concrete Research*, 2018, 109: 42-53.
- [8] Biernacki J J, Bullard J W, Sant G, et al. Cements in the 21st century: challenges, perspectives, and opportunities [J]. *Journal of the American Ceramic Society*, 2017, 100(7): 2746-2773.
- [9] Seber G A F, Lee A J. *Linear regression analysis* [M]. John Wiley & Sons, 2003.
- [10] 朱伟, 石超峰, 李楠. 基于遗传算法优化支持向量机的再生混凝土抗压强度预测模型 [J]. *中外公路*, 2014, 34(1): 311-314.
- [11] Zhang D, Sun F, Liu T. Prediction of compressive strength of geopolymer concrete based on support vector machine and modified cuckoo algorithm [J]. *Advances in Materials Science and Engineering*, 2021, 2021: 1-14.
- [12] Wu X, Zhu F, Zhou M, et al. Intelligent Design of Construction Materials: A Comparative Study of AI Approaches for Predicting the Strength of Concrete with Blast Furnace Slag [J]. *Materials*, 2022, 15(13): 4582.
- [13] Shah S A R, Azab M, Seif ElDin H M, et al. Predicting Compressive Strength of Blast Furnace Slag and Fly Ash Based Sustainable Concrete Using Machine Learning Techniques: An Application of Advanced Decision-Making Approaches [J]. *Buildings*, 2022, 12(7): 914.
- [14] 吴贤国, 刘鹏程, 陈虹宇, 等. 基于随机森林的高性能混凝土抗压强度预测 [J]. *混凝土*, 2022.
- [15] Haykin S. *Neural networks: a comprehensive foundation* [M]. Prentice Hall PTR, 1998.
- [16] Dietterich T G. Ensemble methods in machine learning [C] // *Multiple Classifier Systems: First International Workshop, MCS 2000 Cagliari, Italy, June 21-23, 2000 Proceedings 1*. Springer Berlin Heidelberg, 2000: 1-15.
- [17] Zhou Z H, Zhou Z H. *Ensemble learning* [M]. Springer Singapore, 2021.
- [18] Gazder U, Al-Amoudi O S B, Khan S M S, et al. Predicting compressive strength of bended cement concrete with ANNs [J]. *Computers and Concrete, An International Journal*, 2017, 20(6): 627-634.
- [19] Chou J S, Pham A D. Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength [J]. *Construction and Building Materials*, 2013, 49: 554-563.
- [20] Chore H S, Shelke N L. Prediction of compressive strength of concrete using multiple regression model [J]. *Structural engineering and mechanics: An international journal*, 2013, 45(6): 837-851.
- [21] Saha P, Prasad M L V, RathishKumar P. Predicting strength of SCC using artificial neural network and multivariable regression analysis [J]. *Comput. Concr*, 2017, 20(1): 31-38.
- [22] Nguyen H, Vu T, Vo T P, et al. Efficient machine learning models for prediction of concrete strengths [J]. *Construction and Building Materials*, 2021, 266: 120950.
- [23] 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.
- [24] Nguyen-Sy T, Wakim J, To Q D, et al. Predicting the compressive strength of concrete from its compositions and age using the extreme gradient boosting method [J]. *Construction and Building Materials*, 2020, 260: 119757.
- [25] Yan K, Xu H, Shen G, et al. Prediction of splitting tensile strength from cylinder compressive strength of concrete by support vector machine [J]. *Advances in Materials Science and Engineering*, 2013, 2013.
- [26] Garg A, Aggarwal P, Aggarwal Y, et al. Machine learning models for predicting the compressive strength of concrete containing nano silica [J]. *Comput. Concr*, 2022, 30(1): 33-42.
- [27] Zhang M, Li M, Shen Y, et al. Multiple mechanical properties prediction of hydraulic concrete in the form of combined damming by experimental data mining [J]. *Construction and Building Materials*, 2019, 207: 661-671.
- [28] Zhang J, Li D, Wang Y. Toward intelligent construction: Prediction of mechanical properties of manufactured-sand concrete using tree-based models [J]. *Journal of Cleaner Production*, 2020, 258: 120665.
- [29] Erdal H I. Two-level and hybrid ensembles of decision trees for high performance concrete compressive strength prediction [J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(7): 1689-1697.
- [30] Ouyang N, Song Y, Li Y, et al. Predicting concrete's strength by machine learning: Balance between accuracy and complexity of algorithms [J]. *ACI Materials Journal*, 2020, 117(6).
- [31] Marani A, Nehdi M L. Machine learning prediction of compressive strength for phase change materials integrated cementitious composites [J]. *Construction and Building Materials*, 2020, 265: 120286.
- [32] Huang J, Sabri M M S, Ulrikh D V, et al. Predicting the compressive strength of the cement-fly ash-slag ternary concrete using the firefly algorithm (fa) and random forest (rf) hybrid machine-learning method [J]. *Materials*, 2022, 15(12): 4193.

- [33] Pham A D, Ngo N T, Nguyen Q T, et al. Hybrid machine learning for predicting strength of sustainable concrete [J]. *Soft Computing*, 2020, 24(19): 14965-14980.
- [34] Yeh I C. Modeling of strength of high-performance concrete using artificial neural networks [J]. *Cement and Concrete research*, 1998, 28(12): 1797-1808.
- [35] Trtnik G, Kavčič F, Turk G. Prediction of concrete strength using ultrasonic pulse velocity and artificial neural networks [J]. *Ultrasonics*, 2009, 49(1): 53-60.
- [36] Uysal M, Tanyildizi H. Predicting the core compressive strength of self-compacting concrete (SCC) mixtures with mineral additives using artificial neural network [J]. *Construction and Building Materials*, 2011, 25(11): 4105-4111.
- [37] Prasad B K R, Eskandari H, Reddy B V V. Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN [J]. *Construction and Building Materials*, 2009, 23(1): 117-128.
- [38] Koo C, Jin R, Li B, et al. Case-based reasoning approach to estimating the strength of sustainable concrete [J]. *Computers and Concrete*, 2017, 20 (6): 645-654.
- [39] Özcan F, Atiş C D, Karahan O, et al. Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete [J]. *Advances in Engineering Software*, 2009, 40(9): 856-863.
- [40] Qu D, Cai X, Chang W. Evaluating the effects of steel fibers on mechanical properties of ultra-high performance concrete using artificial neural networks [J]. *Applied Sciences*, 2018, 8(7): 1120.
- [41] 吴顺川, 王艳超, 张化进. 基于 Stacking 集成算法的岩石单轴抗压强度预测方法研究 [J]. *矿业研究与开发*, 2022.
- [42] Schapire R. E. *The Strength of Weak Learnability* [M]. Kluwer Academic Publishers, 1990.
- [43] Liu G, Sun B. Concrete compressive strength prediction using an explainable boosting machine model [J]. *Case Studies in Construction Materials*, 2023, 18: e01845.
- [44] Li Q, Song Z. Prediction of compressive strength of rice husk ash concrete based on stacking ensemble learning model [J]. *Journal of Cleaner Production*, 2023, 382: 135279.