

岩石抗压强度随钻预测及其机制解释研究

张杰^{1,2}, 王胜^{1,2*}, 赖昆^{1,2}, 柏君^{1,2}, 徐世毅^{1,2}, 张洁^{1,2}

(1. 成都理工大学环境与土木工程学院, 四川 成都 610059; 2. 地质灾害防治与地质环境保护全国重点实验室, 四川 成都 610059)

摘要: 准确评估岩石抗压强度, 尤其是隧道施工过程中的实时强度预测, 是确保工程安全和优化设计的关键基础。基于随钻参数的机器学习预测方法在该领域展现出巨大潜力。然而, 传统机器学习模型的黑箱特性限制了其在工程实践中的应用。为此, 本研究提出一种基于可解释人工智能的岩石抗压强度随钻预测方法, 通过SHAP分析技术解析极端梯度提升(XGBoost)模型的决策机制, 实现预测过程透明化和可解释性。研究表明, 构建的XGBoost模型在岩石抗压强度预测方面取得了良好效果, 测试集预测精度达75.71%。更重要的是, SHAP值分析定量揭示了各输入参数对预测结果的贡献机制, 发现钻速均值以25.67%的贡献度占据主导地位, 而参数变异性指标(标准差类)的总贡献度高达49.70%, 突破了传统认知中仅关注参数均值的局限性。本研究揭示了随钻参数随钻进深度变化的一般规律, 实现了岩石抗压强度随钻预测, 对推动地下工程参数预测的可解释性和工程应用具有重要意义。

关键词: 岩石抗压强度; 随钻参数; 极端梯度提升算法; SHAP值分析; 模型可解释性

中图分类号: P634 **文献标识码:** A **文章编号:** 2096-9686(2025)S1-0085-06

Study on prediction of rock strength while drilling and its mechanism interpretation

ZHANG Jie^{1,2}, WANG Sheng^{1,2*}, LAI Kun^{1,2}, BAI Jun^{1,2}, XU Shiyi^{1,2}, ZHANG Jie^{1,2}

(1. College of Environment and Civil Engineering, Chengdu University of Technology, Chengdu Sichuan 610059, China;

2. State Key Laboratory of Geohazard Prevention and Geoenvironment Protection, Chengdu Sichuan, 610059, China)

Abstract: Accurate evaluation of rock strength, especially real-time strength prediction during tunnel construction, is a key basis for ensuring engineering safety and optimal design. Machine learning prediction methods based on drilling parameters have shown great potential in the field of rock strength assessment. However, the black-box nature of traditional machine learning models limits their application in engineering practice. To this end, this study proposes a rock strength prediction method based on interpretable artificial intelligence. The decision-making mechanism of the XGBoost model is analyzed via SHAP analysis technology to achieve transparency and interpretability of the prediction process. The results show that the XGBoost model has achieved good performance in rock strength prediction, with the test set prediction accuracy reaching 75.71%. More importantly, SHAP value analysis quantitatively reveals the contribution mechanism of each input parameter to the prediction results. It is found that the average drilling speed dominates with a contribution rate of 25.67%, while the total contribution rate of parameter variability indicators (standard deviation category) is as high as 49.70%. This finding breaks the limitation of only focusing on parameter means in traditional cognition. This study reveals the general law of drilling parameters changing with drilling depth, realizes rock strength prediction while drilling, and is of great significance for promoting the interpretability and engineering application of underground engineering parameter prediction.

Key words: rock strength; drilling parameters; extreme gradient lifting algorithm; SHAP value analysis; model interpretability

收稿日期: 2025-05-30; 修回日期: 2025-07-17 DOI: 10.12143/j.ztgc.2025.S1.013

基金项目: 珠峰科学研究计划(编号: 80000-2020ZF11411)

第一作者: 张杰, 男, 汉族, 2001年生, 硕士研究生, 地质工程专业, 研究方向为隧道工程围岩强度随钻测试, 四川省成都市成华区二仙桥东三路1号, 1454319619@qq.com。

通信作者: 王胜, 男, 土家族, 1982年生, 钻掘工程教研室主任, 教授, 博士生导师, 地质工程专业, 博士, 研究方向为钻探新材料与新技术, 四川省成都市成华区二仙桥东三路1号, yongyuandewangsheng@sina.com。

引用格式: 张杰, 王胜, 赖昆, 等. 岩石抗压强度随钻预测及其机制解释研究[J]. 钻探工程, 2025, 52(S1): 85-90.

ZHANG Jie, WANG Sheng, LAI Kun, et al. Study on prediction of rock strength while drilling and its mechanism interpretation[J]. Drilling Engineering, 2025, 52(S1): 85-90.

0 引言

岩石单轴抗压强度的准确测定是岩土工程建设顺利实施的保障^[1],尤其在隧道施工过程中的实时强度预测,是确保工程安全和优化设计的关键基础。目前主要采用室内试验方法,包括单轴压缩、三轴压缩和巴西劈裂试验等^[2-3],需要将现场钻孔岩心运至实验室进行测试。这种传统方法存在两个核心问题:第一,测试仅针对有限的完整岩心样本,无法反映岩石抗压强度沿钻孔深度的连续变化特征,导致结果代表性不足^[4-5];第二,单轴压缩试验^[6]对岩心长度有要求,但破碎地层难以获取合格样本,且运输过程中岩心易产生次生裂隙,严重影响测试精度和可靠性^[7]。

当前,随钻测试技术已成为岩土工程勘探和分析的重要手段之一。随钻参数是钻进过程中可控制收集的进尺、推力、转速、钻速等参数^[8]。研究表明,随钻参数与岩石抗压强度密切相关^[9-11],因此,通过对完整记录的随钻参数进行分析处理,能在一定程度上反映钻孔的地质信息。国内较早的随钻测试设备为Yue等^[12]、Gui等^[13]提出的一种钻孔过程监测(DPM)系统,该系统能以时序数列方式实时采集钻孔数据;He等^[14-15]开发了一种履带式的钻孔过程监控装置(DPMA),该装置在钻孔过程中,可以自主连续测量不同深度的钻压和扭矩。

机器学习凭借其强大的自适应性、非线性建模能力和高精度预测性能,在工程领域展现出巨大潜力。该技术能够自动提取数据特征,高效处理大规模数据集,并建立复杂的非线性映射关系。因此,大量算法模型被应用到岩石信息识别的研究中,如通过随钻振动信息并结合深度学习预测岩性^[16-17]、基于多源随钻信息实现岩体质量等级智能分级^[18-20]、结合室内试验和现场随钻测试数据预测岩石强度^[21-27]。近年来,随着智能钻探技术的快速发展,基于钻进参数的岩石特性预测研究取得显著进展。王亚飞等^[28]提出了基于模型融合的岩石类型识别方法,通过集成多种机器学习算法提高了分类精度;蒲先渤等^[29]采用主成分分析与Levenberg-Marquardt优化的BP神经网络相结合的方法,建立了岩石可钻性预测模型,有效解决了高维数据的降维问题。在钻速预测方面,周长春等^[30]开发了融合特征选择算法,通过优化输入参数组合显著提升了预测性能;胥知画等^[31]进一步引入粒子群优化算

法,实现了特征选择的智能化和自动化。

然而,仍存在若干关键问题亟待解决。首先,大多研究在处理随钻参数时仅关注其平均值,忽略了钻进中参数波动所蕴含的重要信息,而这种变异性恰恰反映了岩体的非均质性和结构特征。其次,尽管机器学习算法在预测精度上表现优异,但其固有的黑箱特性降低了模型在工程实践中的可信度,缺乏对各参数贡献机制的定量解析。最后,现有数据处理方法缺乏系统性,对于高频采集的海量随钻数据,如何有效提取特征信息并构建合理的预测模型仍需深入探索。据此,本研究开展水平钻进随钻参数的采集试验,构建了融合参数统计特征数据集,通过XGBoost算法实现了岩石抗压强度预测,并引入SHAP值解释各特征值的重要性。

1 试验概况

试验地点位于西南地区某一在建隧道,随钻参数的收集工作通过一个专门的钻杆前端测量系统实现。该系统主要由复合传感器、测试主机和高精度激光位移传感器3部分组成,具有体积小、拆装易及适用范围广等特点。复合传感器内部集成了推力、扭矩、转速传感器和蓝牙模块,数据可实时无线传输至测试主机进行分析,该传感器安装在主动钻杆尾部,确保在钻探作业期间捕获精确的数据。此外,连接到控制台的激光位移传感器专注于测量推进系统中的位移。这些指标对于确定钻探深度和钻进速度至关重要。为了保证数据的可靠性和稳定性,位移数据通过安全电缆传输到测试主机。随着钻进进行,该系统可实时、连续地记录钻机的动力和运动参数,采样频率10 Hz。钻机和传感框架的集成模式见图1。

此次试验钻进方式为回转取心钻进,钻孔直径90 mm,钻进24.08 m,获取岩心67块,均为较完整的花岗岩(见图2)。同时收集了6类参数的原始数据(见图3)。其中推力是钻机推进系统施加于钻头的轴向力,使钻头与岩石保持紧密接触并破岩,直接反映了作用在钻头上的轴向载荷,受推进液压系统总压力的影响;扭矩是钻机动力头提供的旋转力矩,使钻头能够有效切削和破碎岩体;钻速反映了钻头穿透岩层的快慢程度,直接体现了岩石的可钻性;转速是钻头每分钟的旋转次数,需要根据岩性特征和钻头类型进行优化调整。转速与扭矩、推力



图1 传感器与钻机集成示意

共同作用,决定了钻头的切削效率和破岩效果。因此,通过实时获取这些随钻参数的动态响应特征,可为探究随钻参数与岩石力学性质之间的内在联系提供数据支撑。



图2 岩心照片




图3 原始随钻数据

2 数据处理

按照时间序列的方式采集数据,虽然具有数据记录完整的优势,但也伴随着信息密集、繁杂的特点,难以直观反映数据变化趋势。从图3中可以看出钻进深度曲线部分点的斜率为负值,即瞬时钻进速度小于零,这是不符合常理的。因此,本文以0.1 m的长度单元对原始数据进行分段,获取每一段随钻参数的均值和标准差,共计241组数据(见图4)。从图4(a)中可以看出均值分段后的各参数随深度

的变化趋势:转速曲线波动小,趋于一条直线;推力曲线随深度的增加,总体来说缓慢增大,同时与扭矩曲线的变化趋势相近、波动幅度同步;钻速与扭矩曲线随深度的增加则表现为明显的减小。图4(b)中标准差能够反映随钻数据的离散程度和变异性,这是均值无法体现的关键信息。当数据存在较大波动时,均值可能掩盖了数据的真实分布特征,而标准差则能准确捕捉这种变化幅度。例如,在钻进参数分析中,两段岩层可能具有相同的平均钻速,但一段参数稳定,另一段参数剧烈波动,这种差异通过标准差可以清晰识别。




图4 分段后随钻数据

本研究构建了241组数据集,包含了钻速、转速、推力、扭矩的均值及标准差8项参数作为输入值,对应的由室内单轴试验得到的岩石抗压强度作为目标输出。为了了解这些指标所在范围及其相关性,表1统计了数据集各参数的最小值、最大值及均值,图5显示了样本属性的统计信息及相关系数 R 。从图5(a)可以看出,大多数样本属性之间的相关性较差($R < 0.5$),只有钻速均值与岩石抗压强度中等相关。此外,图5(b)中则只有钻速、推力的标准差与岩石抗压强度中等相关($R > 0.6$)。因此,样本属性之间不存在因果关系,不需要数据降维。

表1 数据集样本参数统计

取值类型	钻速/(mm·s ⁻¹)		转速/(r·min ⁻¹)		推力/kN		扭矩/(N·m)		岩石抗压强度/MPa
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	
最小值	0.07	1.08	110.50	0.62	0.22	0.13	18.13	1.52	63.04
最大值	50.00	45.83	170.20	21.11	11.16	4.14	394.25	112.34	125.81
平均值	0.57	5.13	166.24	2.66	7.40	2.40	156.93	44.90	99.29




图5 数据集相关性热图

3 岩石抗压强度预测

3.1 极端梯度提升算法

极端梯度提升 (Extreme Gradient Boosting, XGBoost) 算法是一种基于决策树的高效分布式梯度提升算法,能够并行处理^[32-33]。XGBoost 由于其快速的运算、出色的精度和强大的广谱适用性,在可比拟的提升树算法中脱颖而出。如图6所示,随着 XGBoost 的每一个迭代步骤的执行都产生一个额外的树。新树从前一次迭代中接收与预测残差和实际值密切相关的输入。这个迭代过程一直持续下去,直到达到规定的迭代次数或者达到既定的阈值限制。模型的预测输出可以通过对预测结果求和得到^[34]。

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i), \quad f_k \in U \quad (1)$$

式中: $\hat{y}_i^{(t)}$ ——模型第 t 轮迭代的预测值; x_i ——样




图6 XGBoost 的架构

本; $f_t(x_i)$ ——第 t 轮中的分类和回归树; U ——树集。

迭代前需要定义模型优化的目标函数,使树模型的预测值尽可能接近真实值,该目标函数由损失函数和正则化项两个部分组成。损失函数通过计算模型的预测输出与实际值之间的差异来评估模型的准确性。为了抑制模型的复杂性,并避免过度逼近,使用了正则化特征。该术语在整个计算过程中集成到目标函数中,确保每次迭代都经过数学正则化,显着提高效率和可用性^[35]。损失函数 $Obj^{(t)}$ 和正则化项 Ω 为:

$$Obj^{(t)} = \sum_{k=1}^n l(y_i, \hat{y}_i^{(t)}) + \Omega(f_t) \quad (2)$$

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (3)$$

式中: l ——样本 x_i 的训练误差; y_i ——样本实际值; T, w ——CART 叶节点的数量、比例; γ ——进一步划分叶节点所需的最小损失; λ ——正则化参数。

3.2 训练 XGBoost 模型

为了减少数据差异并准确地代表算法的精度,本文将构建的 241 组随钻参数与岩石强度数据集,其中随钻特征值包括钻速、转速、推力、扭矩的均值及标准差,在合并后进行随机打乱,然后再进行拆分。随后,数据集以 8:2 的比例分为训练集和测试集,即使用 193 个数据样本进行训练,其余 48 个样本用于测试。选择此分割比是为了确保稳健的模型训练过程,同时保留足够的数据来评估模型的概括性能。8:2 的分配比是机器学习中的常见做法,可以有效平衡训练和测试阶段的需求。为了进一步评估模型的稳定性和稳健性,本研究对数据集实施了 5 次交叉验证。此方法有助于确保模型的性能在不同的数据分割中保持一致。同时,设置 XGBoost 模型的超参数,树的数量为 500、树的最大深度为 6、学习率为 0.085,模型训练后最终得到测试集的预测精度为 75.71% (见图 7)。




图7 XGBoost模型预测效果




图8 SHAP值特征重要性排行

3.3 模型可解释性分析

基于SHAP值分析的特征重要性结果揭示了随钻参数对岩石抗压强度预测的差异化贡献机制(图8)。研究结果表明,钻速均值以0.2567位居重要性首位,显著高于其他参数,这一发现与岩石破碎理论高度吻合。钻速作为钻头穿透效率的直接体现,综合反映了岩石的可钻性和整体强度特征。值得注意的是,钻速相关的两个参数(均值和标准差)合计贡献度占总重要性的45.86%,充分证明了钻速参数在岩石抗压强度评估中的核心地位。参数变异性指标展现出了超预期的预测能力,推力标准差(0.2102)和钻速标准差(0.2019)分别位列第二和第三位,其重要性显著超过了相应的均值参数。这一现象表明,钻进过程中参数的波动特征比其绝对水平更能反映岩体的非均质性和结构特征。扭矩和转速参数表现出相对较低但仍不可忽视的贡献。扭矩均值(0.0945)和推力均值(0.0909)的重要性相近,表明这两个力学参数在反映岩石抗压强度方面具有相似的信息含量。从参数类型的整体贡献来看,均值类参数的总贡献度为0.5130,标准差类参数为0.4970,两者基本持平。这种平衡分布验证了本研究采用统计特征双重表征策略的合理性,即同时考虑参数的中心趋势和离散程度能够更全面地刻画钻进过程的复杂性。

4 结论

本研究以西南地区某在建隧道为依托,通过开展水平钻进试验并实时采集随钻参数,成功建立了基于XGBoost算法的岩石抗压强度智能预测模型,并引入SHAP分析技术实现了预测过程的可解释性。研究取得的主要成果和结论如下:

(1)解决了传统岩石强度测试的实时性难题。传统室内单轴压缩试验需要将岩心运输至实验室,存在明显的时间滞后性,无法满足隧道快速施工的决策需求。本研究建立的随钻预测方法能够在钻进过程中实时评估岩石强度,测试集预测精度达到75.71%,为施工人员提供即时的围岩强度信息,有效支撑了隧道开挖方案的动态调整 and 支护参数的及时优化。

(2)构建了一套完整的随钻参数采集与处理体系。通过集成复合传感器、测试主机和高精度激光位移传感器的测量系统,实现了推力、扭矩、转速、钻速等关键参数的实时高频采集。针对原始数据信息密集且包含异常值的特点,采用0.1m长度单元分段处理方法,有效提取了各参数的均值和标准差特征,为后续建模分析奠定了坚实的数据基础。

(3)揭示了随钻参数随钻进深度变化的一般规律。研究发现转速参数表现出良好的稳定性并呈线性分布特征,推力参数随钻进深度增加呈缓慢上升趋势,且与扭矩参数变化规律高度一致,而钻速和扭矩参数则随深度增加呈显著递减趋势。基于SHAP特征重要性分析,扭矩均值(0.0945)与推力均值(0.0909)的贡献度相近,验证了这两个力学参数在岩石强度表征方面具有等效的信息价值。

(4)实现了预测模型的工程可解释性。传统机器学习模型的黑箱特性严重制约了其在工程实践中的推广应用。本研究通过SHAP值分析定量揭示了各输入参数的贡献机制:钻速均值贡献度25.67%占据主导地位,参数变异性指标总贡献度达49.70%。这种可解释性使工程技术人员能够理解模型的决策依据,增强了预测结果的可信度,并为优化钻进参数提供了科学指导。

参考文献:

- [1] 岳中琦. 钻孔过程监测(DPM)对工程岩体质量评价方法的完善与提升[J]. 岩石力学与工程学报, 2014, 33(10): 1977-1996.
- [2] Linchum B A, Steven H W, Rempe D, et al. Critical zone structure under a granite ridge inferred from drilling and three dimensional seismic refraction data[J]. Journal of Geophysical Research: Earth Surface, 2018, 123(6): 1317-1343.
- [3] 王琦, 高红科, 蒋振华, 等. 地下工程围岩数字钻测试系统研发与应用[J]. 岩石力学与工程学报, 2020, 39(2): 301-310.
- [4] 刘家顺, 郑智勇, 左建平, 等. 定向剪切应力路径下类弱胶结软岩椭圆各向异性强度准则[J]. 岩石力学与工程学报, 2024, 43(5): 1219-1229.
- [5] 陈天宇, 冯夏庭, 张希巍, 等. 黑色页岩力学特性及各向异性特性试验研究[J]. 岩石力学与工程学报, 2014, 33(9): 1772-1779.
- [6] 住房和城乡建设部. 工程岩体试验方法标准: GB/T 50266-2013[S]. 北京: 中国计划出版社, 2013.
- [7] Wang X, Peng P, Shan Z, et al. In situ strength profiles along two adjacent vertical drillholes from digitalization of hydraulic rotary drilling[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2023, 15(1): 146-168.
- [8] 岳中琦, 李焯芬, 罗锦添, 等. 香港大学钻孔过程数字监测仪在土钉加固斜坡工程中的应用[J]. 岩石力学与工程学报, 2002, (11): 1685-1690.
- [9] 王玉杰, 余磊, 赵宇飞, 等. 基于数字钻进技术的岩石强度参数测定试验研究[J]. 岩土工程学报, 2020, 42(09): 1669-1678.
- [10] Zhang K, Hou R, Zhang G, et al. Rock drillability assessment and lithology classification based on the operating parameters of a drifter: case study in a coal mine in China[J]. Rock Mechanics and Rock Engineering, 2016, 49: 329-334.
- [11] Karasawa H, Ohno T, Kosugi M, et al. Methods to estimate the rock strength and tooth wear while drilling with roller-bits—part 1: milled-tooth bits[J]. Energy Resour Technol, 2002, 124(3): 125-132.
- [12] Yue Z Q, Lee C F, Law K T, et al. Automatic monitoring of rotary-percussive drilling for ground characterization—illustrated by a case example in Hong Kong[J]. International journal of rock mechanics and mining sciences, 2004, 41(4): 573-612.
- [13] Gui M W, Soga K, Bolton M D, et al. Instrumented borehole drilling for subsurface investigation[J]. Journal of geotechnical and geoenvironmental engineering, 2002, 128(4): 283-291.
- [14] He M, Li N, Zhang Z, et al. An empirical method for determining the mechanical properties of jointed rock mass using drilling energy[J]. International journal of rock mechanics and mining sciences, 2019, 116: 64-74.
- [15] He M, Zhang Z, Ren J, et al. Deep convolutional neural network for fast determination of the rock strength parameters using drilling data[J]. International Journal of Rock Mechanics and Mining Sciences, 2019, 123: 104084.
- [16] 岳中文, 闫逸飞, 王煦, 等. 基于随钻数据的岩性识别机器学习算法研究进展[J]. 科学技术与工程, 2023, 23(10): 4044-4057.
- [17] 王胜, 赖昆, 张拯, 等. 基于随钻振动信号与深度学习的岩性智能预测方法[J]. 煤田地质与勘探, 2023, 51(9): 51-63.
- [18] Bai J, Wang S, Xu Q, et al. Intelligent real-time predicting method for rock characterization based on multi-source information integration while drilling[J]. Bulletin of Engineering Geology and the Environment, 2023, 82(4): 150.
- [19] Bai J, Wang S, Liu L, et al. Knowledge-based machine learning for real-time rock strength testing while drilling: bridging simulation and reality[J]. Measurement, 2025, 246: 116664.
- [20] Bai J, Wang S, Xu Q, et al. Adaptive threshold multimodal fusion for rock prediction in complex geological environments while drilling[J]. Bulletin of Engineering Geology and the Environment, 2025, 84(4): 178.
- [21] 岳中文, 龙思晨, 闫逸飞, 等. 基于Stacking算法与钻进参数的岩石单轴抗压强度预测[J/OL]. 采矿与安全工程学报, 1-13 [2025-05-30]. <http://kns.cnki.net/kcms/detail/32.1760.td.20241029.1928.002.html>.
- [22] 王琦, 孙会彬, 江贝, 等. 基于数字钻探和支持向量机预测岩体单轴抗压强度的方法[J]. 岩土力学, 2019, 40(3): 1221-1228.
- [23] 房昱纬, 吴振君, 盛谦, 等. 基于超前钻探测试的隧道地层智能识别方法[J]. 岩土力学, 2020, 41(7): 2494-2503.
- [24] 刘勇斌, 张晓平, 李馨芳, 等. 基于冲击回转钻进的岩石强度随钻识别研究[J]. 岩土力学, 2024, 45(3): 857-866.
- [25] Cheng X, Tang H, Wu Z, et al. BiLSTM-based deep neural network for rock-mass classification prediction using depth-sequence MWD data: A case study of a tunnel in Yunnan, China[J]. Applied Sciences, 2023, 13(10): 2 076-3 417.
- [26] Kalantari S, Baghbanan A, Hashemalhosseini H. An analytical model for estimating rock strength parameters from smallscale drilling data[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2019, 11(1): 135-145.
- [27] 王腾, 吴振君, 汤华, 等. 基于随钻测试和回弹试验的岩石强度预测研究[J/OL]. 岩石力学与工程学报, 1-15 [2025-05-30]. <http://kns.cnki.net/kcms/detail/42.1397.o3.20250421.1700.002.html>.
- [28] 王亚飞, 张占荣, 刘华吉, 等. 基于模型融合的钻进参数识别岩石类型研究[J]. 钻探工程, 2023, 50(2): 17-25.
- [29] 蒲先渤, 李泽群, 尹飞, 等. 基于PCA-LM-BP神经网络的岩石可钻性预测研究[J]. 钻探工程, 2023, 50(6): 63-68.
- [30] 周长春, 姜杰, 李谦, 等. 基于融合特征选择算法的钻速预测模型研究[J]. 钻探工程, 2022, 49(4): 31-40.
- [31] 胥知画, 姜杰, 周长春, 等. 基于粒子群优化的融合特征选择钻速预测模型研究[J]. 钻探工程, 2025, 52(2): 134-143.
- [32] Chen T, Guestrin C. Xgboost: A scalable tree boosting system [C]//Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining. 2016: 785-794.
- [33] Wang L, Geng P, Chen J, et al. Machine learning-based fragility analysis of tunnel structure under different impulsive seismic actions [J]. Tunnelling and Underground Space Technology, 2023, 133: 104953.
- [34] Sun J, Zhang R, Zhang A, et al. Rock strength prediction based on machine learning: A study from prediction model to mechanism explanation[J]. Measurement, 2024, 238: 115373.
- [35] Bharti J P, Mishra P, Moorthy U, et al. Slope stability analysis using RF, GBM, CART, BT and XGBoost[J]. Geotechnical and Geological Engineering, 2021, 39: 3741-3752.

(编辑 王跃伟)