

李占科, 许正魁, 王艳宁, 等. 基于可解释 GWO-XGBoost 的隧道挤压预测研究[J]. 水利水电技术(中英文), 2025, 56(4): 82-93. DOI: 10.13928/j.cnki.wrahe.2025.04.007

LI Zhanke, XU Zhengkui, WANG Yanning, et al. Tunnel squeezing prediction using explainable GWO-XGBoost model[J]. Water Resources and Hydropower Engineering, 2025, 56(4): 82-93. DOI: 10.13928/j.cnki.wrahe.2025.04.007

# 基于可解释 GWO-XGBoost 的隧道挤压预测研究

李占科<sup>1</sup>, 许正魁<sup>1</sup>, 王艳宁<sup>2</sup>, 王 昆<sup>3</sup>, 贾运甫<sup>4</sup>, 车 璇<sup>5</sup>, 关 鹏<sup>5</sup>

(1. 中国水利水电第四工程局有限公司, 青海 西宁 810000; 2. 天津市政工程设计研究总院有限公司, 天津 300000; 3. 中国水电建设集团十五工程局有限公司, 陕西 西安 712000; 4. 新疆水利水电勘测设计研究院有限责任公司, 新疆 乌鲁木齐 830000; 5. 中国地质大学(武汉)工程学院, 湖北 武汉 430074)

**摘要:**【目的】为了实现对隧道挤压的准确预测,【方法】构建了 XGBoost 分类预测模型,利用灰狼优化算法(GWO)对 XGBoost 模型进行超参数优化,基于经过插补和过采样处理的不平衡缺失数据集进行模型的训练和测试。模型的输入特征为隧道埋深( $H$ )、岩石掘进质量指数( $Q$ )、隧道直径( $D$ )、强度应力比( $SSR$ )和支护刚度( $K$ ),评价指标为准确率( $ACC$ )、 $F1$ 分数、 $Kappa$ 系数和 Matthews 相关系数( $MCC$ )。【结果】所构建的 GWO-XGBoost 模型在训练集和测试集上预测准确率均达到了 98.94%,在测试集上的评价指标累计值达到了 5.913 1,展现出了优越的预测性能。 $SSR$ 、 $D$ 、 $K$ 、 $Q$ 和 $H$ 的平均 Shapley 可加性解释(Shapley Additive exPlanation, SHAP)值分别为 3.06、1.07、0.82、0.73和0.51,表明  $SSR$  是对模型输出结果影响最大的特征。【结论】GWO-XGBoost 模型在互助北山隧道和木寨岭隧道的挤压预测结果与实际情况相符,证明了该模型在隧道工程中具有较高的适用性和预测准确性。

**关键词:** 隧道挤压预测; XGBoost; 灰狼优化算法; 模型解释; 缺失数据集; 变形; 影响因素

DOI: 10.13928/j.cnki.wrahe.2025.04.007

开放科学(资源服务)标志码(OSID):

中图分类号: U455.1

文献标志码: A

文章编号: 1000-0860(2025)04-0082-12



## Tunnel squeezing prediction using explainable GWO-XGBoost model

LI Zhanke<sup>1</sup>, XU Zhengkui<sup>1</sup>, WANG Yanning<sup>2</sup>, WANG Kun<sup>3</sup>, JIA Yunfu<sup>4</sup>, CHE Xuan<sup>5</sup>, GUAN Peng<sup>5</sup>

(1. Sinohydro Engineering BUREAU 4 Co., Ltd., Xining 810000, Qinghai, China; 2. Tianjin Municipal Engineering Design & Research Institute, Tianjin 300000, China; 3. Sinohydro Engineering BUREAU 15 Co., Ltd., Xi'an 810000, Shaanxi, China; 4. Xinjiang Survey and Design Institute for Water Resources and Hydropower, Urumqi 830000, Xinjiang, China; 5. China University of Geosciences, Wuhan 430074, Hubei, China)

**Abstract:** [Objective] To achieve accurate prediction of tunnel squeezing, [Methods] an eXtreme Gradient Boosting (XGBoost) model tuned by Grey Wolf Optimization (GWO) was constructed for tunnel squeezing prediction. Training and testing of the

收稿日期: 2024-07-22; 修回日期: 2024-08-20; 录用日期: 2024-08-22; 网络出版日期: 2024-10-14

基金项目: 国家自然科学基金青年科学基金项目(52008383); 湖北省自然科学基金项目(2023AFB369)

作者简介: 李占科(1982—), 男, 高级工程师, 学士, 主要从事隧道工程研究。E-mail: 472482403@qq.com

通信作者: 关 鹏(1988—), 男, 讲师, 博士, 主要从事隧道工程科研工作。E-mail: 275726392@qq.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

GWO-XGBoost model were conducted on an imbalanced dataset with missing data that had undergone imputation and oversampling techniques. The input features of the GWO-XGBoost model included tunnel burial depth ( $H$ ), rock tunnelling quality index ( $Q$ ), diameter ( $D$ ), strength stress ratio ( $SSR$ ), and support stiffness ( $K$ ). The performance of the GWO-XGBoost model was rigorously evaluated using a suite of metrics, including accuracy ( $ACC$ ), the  $F1$  score, the  $Kappa$  coefficient, and the Matthews correlation coefficient ( $MCC$ ). [Results] The result indicated that the presented GWO-XGBoost model achieved an impressive prediction accuracy of 98.94% on both the training set and the test set. Moreover, on the test set, the cumulative value of the evaluation metrics soared to 5.913 1, underscoring the model's exceptional predictive capabilities. The average Shapley Additive exPlanation (SHAP) values for  $SSR$ ,  $D$ ,  $K$ ,  $Q$ , and  $H$  were 3.06, 1.07, 0.82, 0.73, and 0.51, respectively, indicating that  $SSR$  was the most influential feature affecting the model's output result. [Conclusion] The application of the GWO-XGBoost model to the Huzhubeishan Tunnel and Muzhailing Tunnel has yielded squeezing predictions that closely align with the actual conditions observed, proving the high applicability and predictive accuracy of the presented model in tunnel engineering.

**Keywords:** tunnel squeezing prediction; XGBoost; grey wolf optimizer; model explanation; missing dataset; deformation; influencing factors

## 0 引言

隧道挤压是指隧道围岩应力超过剪切强度导致围岩发生较大变形,超过了隧道设计允许的变形值<sup>[1-3]</sup>。隧道挤压通常是由围岩蠕变产生,需要经过很长时间才能形成<sup>[4-5]</sup>。隧道挤压通常发生在深埋、软弱围岩、高地应力或构造应力区域的隧道中<sup>[6-8]</sup>。研究表明,造成隧道挤压的因素主要与围岩种类和性质、构造应力、隧道截面尺寸、高地应力以及支护结构有关<sup>[9-10]</sup>。严重的隧道挤压会导致隧道坍塌、预算超支和工期延误等问题,因而给隧道施工和运行造成很大困难<sup>[11-12]</sup>。因此,对隧道挤压进行准确预测对于保证隧道工程安全高效按时完成具有重要意义。传统的隧道挤压预测方法主要包括经验法<sup>[13]</sup>和理论分析法<sup>[14-15]</sup>等。如陈卫忠等<sup>[16]</sup>基于对 100 多条隧道变形监测数据的分析,提出了一种适用于国内岩体基本质量指标 [ $BQ$ ] 值的隧道挤压变形预测方法;石州等<sup>[17]</sup>结合木寨岭公路隧道的隧道挤压变形统计结果,提出了基于模糊综合评价的隧道挤压变形分级预测方法。随着计算机技术的不断进步,近年来,多种机器学习方法已经被广泛应用于地下工程的分类和回归预测中,并且取得了令人满意的预测效果<sup>[18-23]</sup>。也有学者将机器学习方法应用于隧道挤压预测中,并且表现出了极高的预测准确性。张志强等<sup>[24]</sup>建立了我国西南地区隧道工程大变形案例数据库,并构建了贝叶斯网络模型用来进行隧道挤压大变形灾害的分级预测。BO 等<sup>[25]</sup>提出了一种机器学习分类模型,集成了四种不同的机器学习分类模型,经过贝叶斯算法和麻雀搜索算法优化后,在测试集上取得了 98% 的预测准确度。ZHOU 等<sup>[26]</sup>构建了支持向量机隧道挤压分类预测模型,采用鲸鱼算法进行超参数优化,基于

114 个样本数据的数据集进行训练和测试,实现了 95.56% 的分类准确性。ZHANG 等<sup>[27]</sup>使用加权投票方法集成了七个机器学习分类器,使用萤火虫算法进行超参数优化,达到了 96.00% 的隧道挤压预测准确率。GENG 等<sup>[28]</sup>采用贝叶斯优化算法和熵权法的组合来增强极限梯度提升模型,利用源自 139 个隧道历史案例的数据集实现了隧道挤压强度的准确预测。然而,现有研究还存在一些局限性有待完善:(1)较少研究涉及对存在缺失信息的不平衡数据集进行处理以提升模型预测准确性;(2)使用灰狼优化算法对模型超参数进行优化的研究有限;(3)对模型解释的研究有限。

为了解决以上局限性,本研究利用多重插补 (MI) 方法和合成少数过采样技术 (SMOTE) 对不平衡缺失样本数据集进行了插值和过采样处理。然后,构建极限梯度提升 (XGBoost) 模型进行隧道挤压预测,并采用灰狼优化算法 (GWO) 进行超参数优化以提升模型的预测准确性。此外,还采用 Shapley 可加性解释 (Shapley Additive exPlanation, SHAP) 方法对机器学习模型进行解释,以提升机器学习预测结果的可解释性和可信度。最后,采用互助北山隧道和木寨岭隧道案例对所提出的挤压预测方法进行了验证,促进机器学习模型在隧道工程中的应用。

## 1 方法

为了实现隧道挤压的准确预测,本文构建了 XGBoost 模型,并采用 GWO 对 XGBoost 模型进行超参数优化。为了充分利用缺失数据集中的有效信息,采用多重插补 (MI) 和过采样技术对不平衡缺失数据集进行了处理,并用于 GWO-XGBoost 模型的训练和测试。本研究的技术流程如图 1 所示。

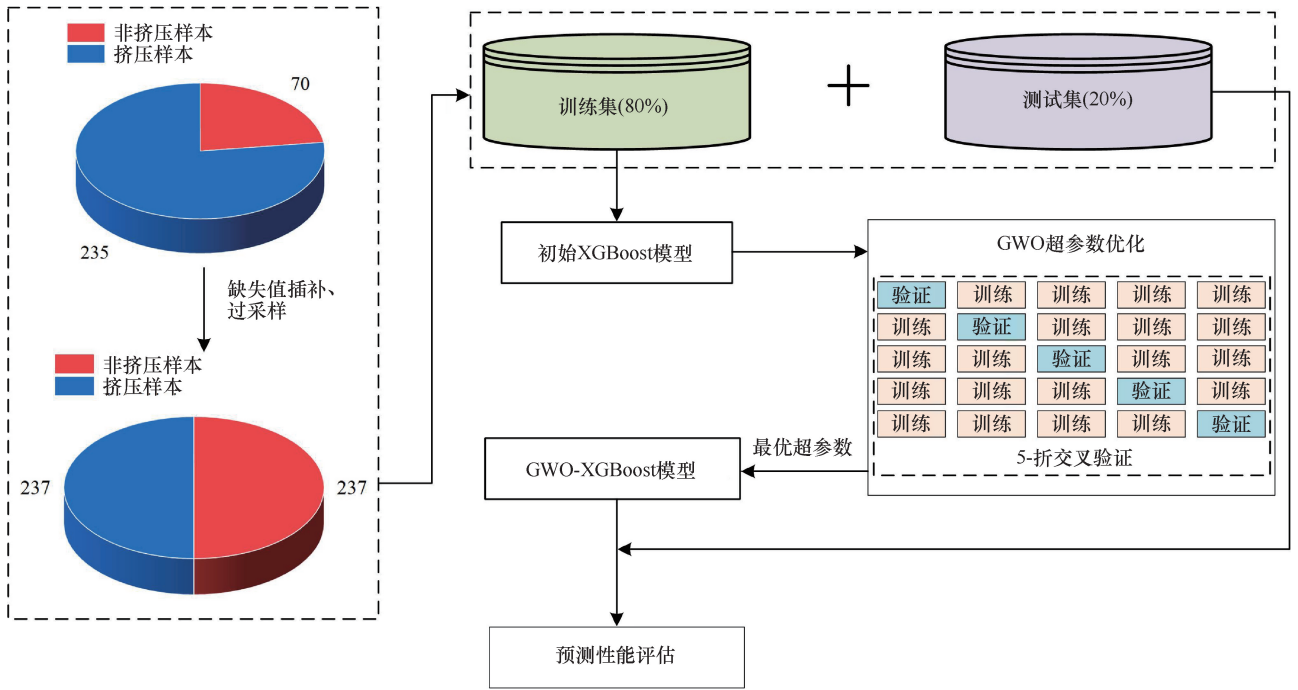


图 1 技术流程

Fig. 1 The flowchart of the proposed approach

### 1.1 极端梯度提升分类算法

极端梯度提升算法是一种优化的分布式梯度提升 (GDBT) 算法<sup>[29]</sup>。该算法提高了基于树 (顺序决策树) 的机器学习算法的性能和速度, 具有高效、灵活和可移植性等特点。在梯度提升算法中, 构建新模型来预测之前模型的残差, 然后将这些模型组合在一起进行最终预测<sup>[30]</sup>。在构建新模型时, 使用梯度下降算法使损失函数最小化。XGBoost 是一种按顺序生成决策树的集成学习模型。所有自变量都被分配了权重, 然后被输入决策树来预测结果。树预测错误的变量的权重会增加, 然后赋予下一棵决策树。这些单独的树的组合产生了更准确和更稳健的集成模型。XGBoost 模型最终的目标函数可以表示为<sup>[31]</sup>

$$L^{(t)} \approx \sum_{i=1}^m \left[ g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i) \quad (1)$$

式中,  $m$  为样本个数;  $x_i$  为第  $i$  个样本点;  $g_i$  为损失函数的一阶导数;  $h_i$  为损失函数的二阶导数;  $f_i(x_i)$  为第  $t$  步预测中第  $i$  个样本的得分;  $\Omega(f_i)$  为第  $i$  个弱学习器的正则化项, 用于避免模型发生过拟合。

### 1.2 灰狼优化算法

灰狼优化算法模拟狼的领导等级和捕食行为, 然后利用灰狼在捕食过程中的搜索、包围、狩猎等活动能力, 达到优化的目的<sup>[32-34]</sup>。GWO 根据狼的特征定义了四种类型:  $\alpha$  狼、 $\beta$  狼、 $\delta$  狼和  $\omega$  狼。 $\alpha$  狼被认为

是最具统治力的, 负责整个灰狼种群;  $\beta$  狼排名第二;  $\delta$  狼排名第三; 其余的狼都是  $\omega$  狼, 在狼群中排名最低。假设狼的数量为  $N$ , 搜索区域为  $d$ , 则第  $i$  只狼的位置可以表示为:  $X_i = (X_{i1}, X_{i2}, X_{i3}, \dots, X_{id})$ 。为了对狼的社会等级进行数学建模, 最适应的解决方案被认为是  $\alpha$  狼。因此, 第二和第三最佳解决方案分别被命名为  $\beta$  狼和  $\delta$  狼。其余候选解被假定为  $\omega$  狼。在 GWO 中, 猎物的位置对应于头狼的位置。GWO 算法搜索最优超参数的技术流程如图 2 所示<sup>[33]</sup>。

### 1.3 模型评价指标

混淆矩阵被广泛应用于二分类问题的预测性能评价<sup>[35]</sup>, 其参数意义如表 1 所列。

表 1 混淆矩阵参数意义

Table 1 Meaning of the parameters in confusion matrix

混淆矩阵		预测值	
		正	负
真实值	正	TP	FN
	负	FP	TN

为了更全面地表征模型性能, 本研究还选取准确率 (ACC)、F1 分数、Kappa 系数和 Matthews 相关系数 (MCC) 四个指标来对模型预测性能进行评价<sup>[25]</sup>。这些评价指标的最优值为 1, 指标值越接近 1, 表明模型的预测性能越好。评价指标采用式 (2) — 式 (7) 进行计算。

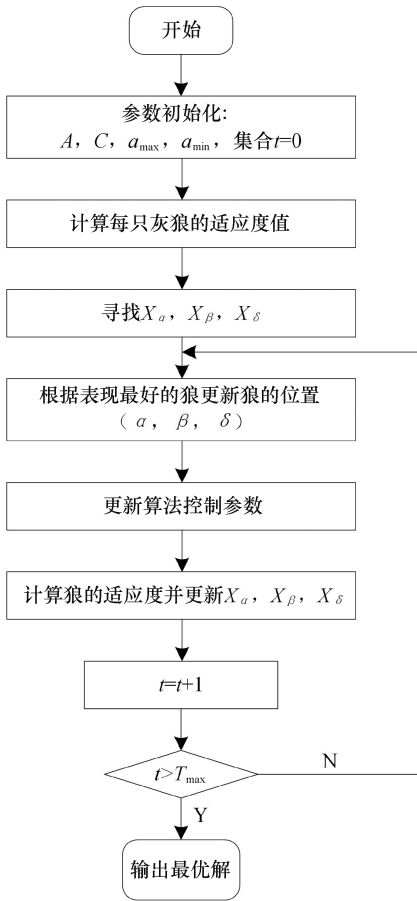


图2 GWO 流程

Fig. 2 The flowchart of the GWO

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$P = \frac{TP}{TP + FP} \quad (3)$$

$$R = \frac{TP}{TP + FN} \quad (4)$$

$$F_1 = 2 \frac{P \cdot R}{P + R} \quad (5)$$

$$Kappa =$$

$$\frac{2(TP \times TN - FP \times FN)}{(TP + FP) \times (FP + TN) + (TP + FN) \times (FN + TN)} \quad (6)$$

$$MCC = \frac{TP \times TN - FP \times FN}{(TP + FP)(FP + TN)(TP + FN)(FN + TN)} \quad (7)$$

式中,  $P$  为精确率;  $R$  为召回率。

## 2 数据集

### 2.1 数据集描述

本研究根据已发表的研究构建了来自 9 个国家

(中国、印度、尼泊尔、委瑞内拉、奥地利、希腊、不丹、日本和土耳其) 包含 305 个样本数据的数据集<sup>[25,36]</sup>。其中, 挤压案例 235 例, 非挤压案例 70 例。数据集的统计特征如表 2 所列。

表2 数据集统计

Table 2 Statistical description of the dataset

指标名称	$H/m$	$Q$	$D/m$	$SSR$	$K/MPa$
缺失数量	0	141	1	71	58
平均值	350.34	1.66	11.27	0.39	778.10
标准差	208.59	7.74	51.59	0.67	641.40
最小值	34.00	0.00	0.60	0.00	2.53
25%分位数	200.00	0.02	5.40	0.12	26.20
中间值	300.00	0.08	8.70	0.25	919.82
75%分位数	500.00	0.80	11.00	0.39	1 239.62
最大值	1 110.00	93.50	906.00	8.61	1 979.56

特征的选择对于机器学习预测准确性具有不可忽视的影响, 基于合适的特征变量体系可以训练出预测准确性更高的模型。如表 2 所列, 本研究选择了 5 个影响隧道挤压的参数, 分别是隧道埋深( $H$ )、岩石掘进质量指数( $Q$ )、隧道直径( $D$ )、强度应力比( $SSR$ )和支持刚度( $K$ )。

隧道埋深决定了隧道围岩应力, 即引起隧道挤压变形的主应力。因此,  $H$  对隧道挤压预测具有重要意义。

岩石开挖质量指标由 BARTON 等<sup>[37]</sup>提出,  $Q$  值在隧道开挖期间记录, 可以全面描述岩石的分级, 被广泛用于隧道挤压预测<sup>[4,38]</sup>。本数据集中的  $Q$  值数量为 164 个, 缺失数量为 141 个。  $Q$  值采用下式计算

$$Q = \frac{RQD}{J_n} \times \frac{J_r}{J_a} \times \frac{J_w}{SRF} \quad (8)$$

式中,  $RQD$  为岩石质量指标;  $J_n$  为节理组数;  $J_r$  为节理粗糙度;  $J_a$  为节理蚀变度;  $J_w$  为节理水折减系数;  $SRF$  为应力折减系数。

隧道挤压受到隧道尺寸的影响<sup>[8,26]</sup>, 通常表示为隧道直径  $D$  (或等效直径  $D = \sqrt{4A/\pi}$ , 其中  $A$  是非圆形隧道的截面积)。本研究构建的数据集中  $D$  的数量为 304 个, 缺失数量为 1 个。

强度应力比也被广泛用于隧道挤压的分析和预测<sup>[4,25,39]</sup>。本研究构建的数据集中  $SSR$  的数量为 234 个, 缺失数量为 71 个  $SSR$  计算方式如下

$$SSR = \frac{\sigma_{cm}}{\gamma H} \quad (9)$$

式中,  $\sigma_{cm}$  为岩体强度;  $\gamma$  为岩体比重。

支护刚度是指隧道整个支护系统的刚度总和, 包括混凝土衬砌刚度  $K_c$ 、钢拱架刚度  $K_{sb}$  和锚杆刚度  $K_b$ 。及时且合理地安装支护体系可以减少隧道挤压变形, 因此支护刚度也是影响隧道挤压的一个重要因素<sup>[4]</sup>。本研究构建的数据集中  $K$  的数量为 247 个, 缺失数量为 58 个。支护刚度  $K$  公式为

$$K_c = \frac{E_c [R^2 - (R - t_c)^2]}{(1 + v_c) [(1 + 2v_c)R^2 + (R - t_c)^2]} \quad (10)$$

$$K_{sb} = p \frac{R}{u} \quad (11)$$

$$\frac{1}{K_b} = \frac{s_c s_l}{R} \left[ \frac{4l}{\pi d_b^2 E_b} + Q_{ld} \right] \quad (12)$$

$$K = K_c + K_{sb} + K_b \quad (13)$$

式中,  $E_c$  为混凝土的弹性模量;  $v_c$  为混凝土的泊松比;  $R$  为隧道半径;  $t_c$  为喷射混凝土厚度;  $p$  为径向支撑压力;  $u$  为径向变形;  $s_c$  为锚杆沿圆周向的间距;  $s_l$  为锚杆径向间距;  $d_b$  为锚杆直径;  $Q_{ld}$  为荷载-位移常数。

## 2.2 缺失数据填充

对数据集中的缺失数据进行简单的删除操作会导致缺失的样本数据中的有用信息的流失。本研究采用插值算法对缺失数据进行插补, 以保留缺失样本中的有效信息。选择广泛使用的  $k$  近邻 (KNN)<sup>[40]</sup> 插值和多重插补 (MI)<sup>[41]</sup> 来对缺失数据进行插补。

## 2.3 数据过采样

本研究所构建的数据集中包含 70 个非挤压样本, 235 个挤压样本, 样本分布不均衡。为了消除不均衡的样本分布对模型预测准确性的负面影响, 采用合成少数过采样技术 (SMOTE)<sup>[42-43]</sup> 对插补后的数据集进行过采样处理, 最终生成的数据集中挤压样本和非挤压样本各 237 个。本研究选择 MI 插补后经过 SMOTE 过采样生成的数据集来对机器学习模型进行训练和测试。其中, MI 插补过程中参数  $K$  取值为 15, SMOTE 过采样过程中参数  $K$  取值为 15。

指标相关性分析可以筛选出相关性较高的指标, 提高输入特征的合理性。经过缺失数据插补和过采样处理后的数据集的数据分布和特征相关性如图 3 所示。0 表示非挤压样本, 对应的颜色为红色, 1 表示挤压样本。对应的颜色为青色。各输入指标中,  $SSR$  和  $Q$  的相关性系数最大, 为 0.858。其中, 非挤压样本的  $SSR$  和  $Q$  的相关性系数为 0.904, 代

表高相关性; 而挤压样本  $SSR$  和  $Q$  的相关性系数仅为 0.335, 表明挤压样本的  $SSR$  和  $Q$  的相关性较低, 因此这两个指标均被保留。其余输入指标之间的相关性均较低, 表明本研究中构建的输入指标体系是合理的。

## 3 隧道挤压预测模型

### 3.1 GWO-XGBoost 模型超参数优化

对插补和过采样处理后的数据集进行标准化处理, 按照 8 : 2 的比例将其随机划分为训练集和测试集。构建 XGBoost 分类预测模型, 采用 GWO 对 XGBoost 模型的超参数进行优化, 灰狼种群数量为 10, 迭代次数为 100 次。优化过程中在训练集上采用 5 折交叉验证来避免过拟合。GWO-XGBoost 模型的不同种群数量的优化过程如图 4 所示。图 4 表明, 在所设置的种群数量中, 种群数量为 10 时, 在训练集上五折交叉验证的平均准确率最高, 为 94.46%。因此将种群数量设置为 10, 超参数优化结果如表 3 所列。

表 3 GWO-XGBoost 超参数搜索结果

Table 3 Results of hyper-parameter optimization of the GWO-XGBoost model

超参数	搜索域	最优解
$N_{estimators}$	[50, 1 000]	174
Max_depth	[3, 100]	50
Learning_rate	[0.001, 0.1]	0.095 9
Min_child_weight	[1, 10]	2
subsample	[0.5, 1]	0.81

### 3.2 模型预测结果

采用 GWO 优化得到的超参数组合构建 XGBoost 模型并在训练集上进行训练。所构建的最优 GWO-XGBoost 模型在训练集和测试集上的预测结果如表 4 和表 5 所列。所构建的 GWO-XGBoost 模型在训练集上的预测准确率为 98.94%, 在 379 个样本中仅有 4 个样本预测错误, 有 1 个非挤压样本被预测为挤压, 3 个挤压样本被预测为非挤压。该模型在测试集上的预测准确率为 98.94%, 51 个非挤压样本全部预测正确, 44 个挤压样本有 43 个预测正确, 仅有 1 个被错误预测为非挤压。训练集和测试集上的预测准确率相当, 表明该模型在训练过程中未发生过拟合。该模型在测试集上表现出的极高准确率可作为隧道挤压预测的新解决方案, 为实际隧道工程中挤压灾害的预测和控制提供参考。

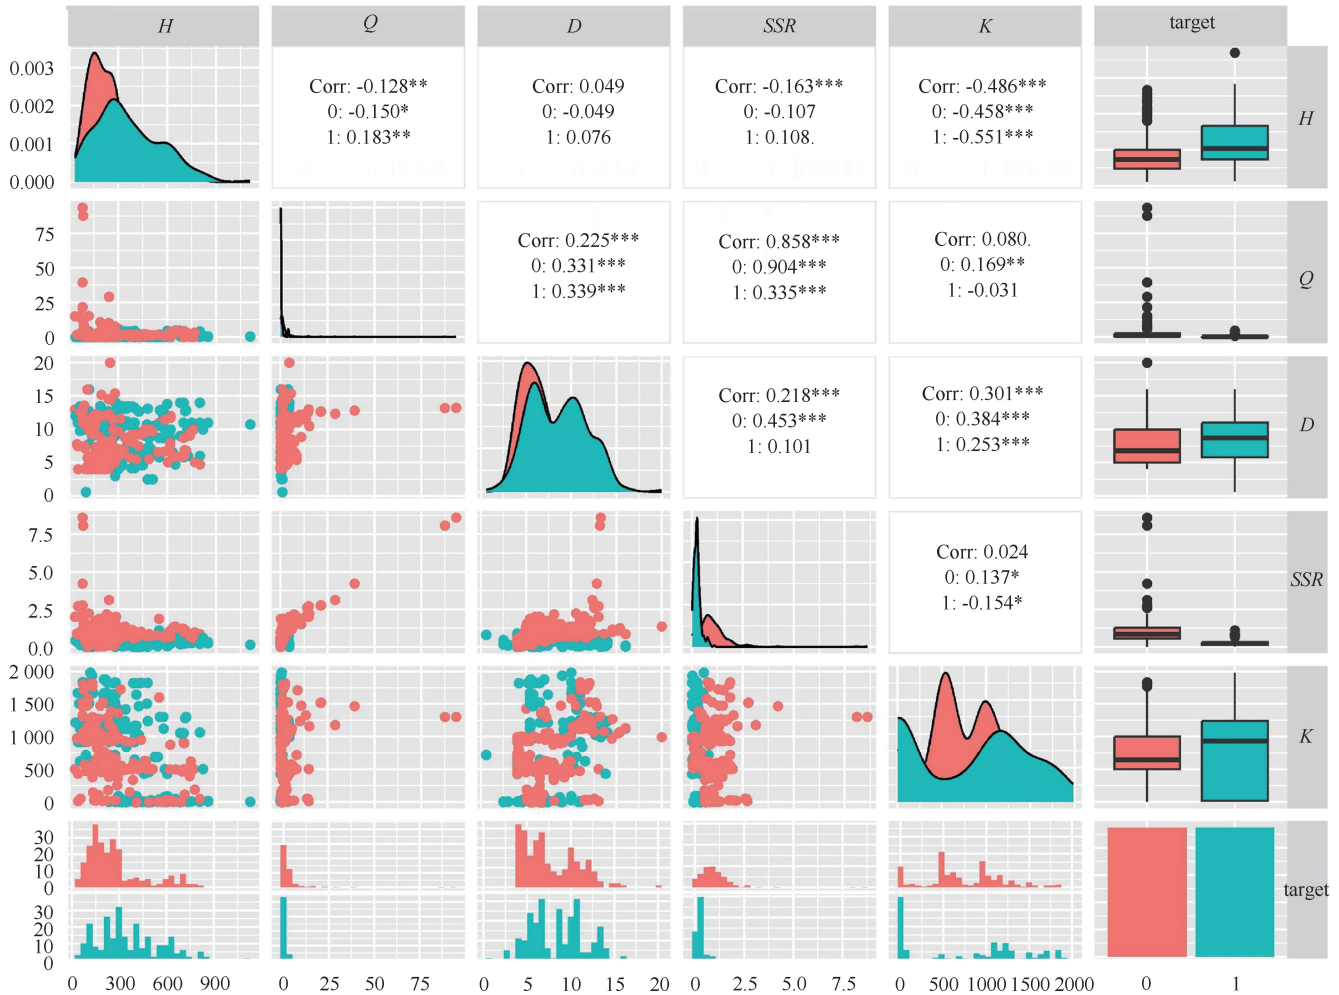


图3 数据集分布及特征相关性图

Fig. 3 Data distributions and feature correlations of the dataset




图4 GWO-XGBoost 优化曲线

Fig. 4 Optimization curves of the GWO-XGBoost model

### 3.3 模型预测性能对比分析

将 GWO-XGBoost 模型和经过 GWO 优化后的支

表4 GWO-XGBoost 在训练集上的预测结果

Table 4 Predicting results of the GWO-XGBoost model on the training set

训练集		预测值	
		非挤压	挤压
真实值	非挤压	185	1
	挤压	3	190

表5 GWO-XGBoost 在测试集上的预测结果

Table 5 Predicting results of the GWO-XGBoost model on the test set

测试集		预测值	
		非挤压	挤压
真实值	非挤压	51	0
	挤压	1	43

持向量机(SVM)模型<sup>[44]</sup>、决策树(DT)<sup>[27]</sup>模型和随机森林(RF)模型<sup>[45]</sup>在测试集上的预测效果进行对比分析,以验证本研究所构建的 GWO-XGBoost 模

型的预测性能的优越性。GWO-SVM、GWO-DT 和 GWO-RF 的超参数优化迭代次数均为 100 次, 且均采用 5 折交叉验证, 优化过程曲线如图 5 所示。




图 5 GWO-SVM、GWO-RF 和 GWO-DT 模型优化曲线

Fig. 5 Optimization curves of the GWO-SVM, GWO-RF and GWO-DT models

4 个机器学习模型在测试集上的预测结果如图 6 所示。4 个模型在测试集上对 51 个非挤压样本均预测正确; 对于 44 个挤压样本, GWO-XGBoost 模型仅有一个预测错误, GWO-SVM 模型有 5 个预测错误,

GWO-DT 模型有 4 个预测错误, GWO-RF 模型有 2 个预测错误。因此, GWO-XGBoost 模型在测试集上的预测准确率最高。

以假阳性率 ( $FPR$ ) 为横轴, 真阳性率 ( $FTR$ ) 为纵轴, 可绘制 ROC 曲线<sup>[46]</sup>。曲线下面积 ( $AUC$ ) 越大, 表明模型分类精度越高。4 个机器学习模型的 ROC 曲线如图 7 所示。4 个模型的 ROC 曲线中, GWO-XGBoost 模型的预测曲线最接近左上角,  $AUC$  为 1.0, 比其他 3 个模型的  $AUC$  更大, 表明该模型的在测试集上的预测表现比其他三个模型更好。

4 个模型在测试集上的预测性能如表 6 所列。GWO-XGBoost 模型、GWO-SVM 模型、GWO-DT 模型和 GWO-RF 模型在测试集上的预测准确率分别为 98.94%、94.74%、95.79% 和 97.89%, 6 个性能指标的累计值分别为 5.913 1、5.565 3、5.652 3 和 5.826 2, GWO-XGBoost 模型展现出了最高的预测准确性。4 个机器学习的预测性能排序为 GWO-XGBoost > GWO-RF > GWO-DT > GWO-SVM。

### 3.4 模型解释

机器学习模型是黑盒模型, 其预测依据无法进行




图 6 4 个模型在测试集上的预测结果 (单位: %)

Fig. 6 Prediction results of the 4 models on the test set (Unit: %)




图7 4个模型在测试集上的 ROC 曲线

Fig. 7 ROC curves of the 4 models on the test set

表6 四个模型在训练集上的预测性能指标

Table 6 Predicting performance of the 4 models on the test set

指标	GWO-XGBoost	GWO-SVM	GWO-DT	GWO-RF
ACC/%	98.94	94.74	95.79	97.89
P/%	100.00	100.00	100.00	100.00
R/%	97.73	88.64	90.91	95.45
F1	0.988 5	0.939 8	0.952 4	0.976 7
Kappa	0.978 8	0.893 3	0.914 8	0.957 5
MCC	0.979 0	0.898 5	0.918 1	0.958 4
累计值	5.913 1	5.565 3	5.652 3	5.826 2

显性描述,对机器学习模型预测结果的解释逐渐受到广泛关注<sup>[47-49]</sup>。本研究采用 SHAP 方法<sup>[50]</sup>对 GWO-XGBoost 模型进行了解释,以增强模型预测结果的可信度。GWO-XGBoost 模型的特征重要性解释结果如图 8 所示。

图 8(a)展示了每个样本的 SHAP 值分布情况,SHAP 值为正表明该样本对模型预测结果产生了积极影响,SHAP 值为负表明该样本对模型的预测结果产生了消极影响。SHAP 值的绝对值越大,表明所产生的影响越大。以 SSR 为例,红色点(SSR 值高的点)的 SHAP 值主要为负,表明 SSR 值高的样本对模型的输出产生了消极影响;反之,蓝色点(SSR 值低的点)的 SHAP 值主要为正,表明 SSR 值低的点对模型的输出产生了积极影响。图 8(b)展示了每一个输入特征的平均 SHAP 值,SSR、D、K、Q 和 H 的平均 SHAP 值分别为 3.06、1.07、0.82、0.73 和 0.51。平均 SHAP 值越大,表示该特征对模型的输出结果重要性越高。因此,5 个输入特征的重要性排序为:SSR>D>K>Q>H。

采用 SHAP 方法对模型进行解释可以为隧道挤压灾害的预测和规避提供参考。例如,为了避免隧道挤




图8 GWO-XGBoost 模型解释结果

Fig. 8 Explanation of the GWO-XGBoost model

压灾害的发生,需要重点关注 SSR 这一因素,在 SSR 较高的地区,需要适当提升支护强度以避免隧道挤压灾害的发生。

## 4 工程应用

为了验证本研究所构建的 GWO-XGBoost 模型在隧道工程中的适用性,利用该模型对互助北山隧道和木寨岭隧道的部分断面进行了挤压预测。

### 4.1 互助北山隧道

互助北山隧道全长 11.16 km,最大埋深约 769.00 m,隧道区海拔高程介于 2 815~3 699 m 之间,相对高差达到 884 m,属于构造剥蚀中高山地貌。隧道穿越 7 个断层挤压破碎带,部分区段地应力较高,容易发生挤压灾害。该隧道的岩性主要为中风化和强风化片岩、辉长岩、安山玄武岩以及灰岩,隧道剖面图可参考文献<sup>[45]</sup>。本文选取互助北山隧道的 6 个断面采用所提出的方法进行了挤压预测,其中 H 和 D 是从工程资料中获取,Q、SSR 和 K 三个指标是通过 MI 插值得到。互助北山隧道挤压预测结果如表 7 所列。

所选取的 6 个隧道断面中,有 3 个隧道断面发生了挤压变形,分别是 K34+160、K40+470 和 K40+505,其预测的挤压概率分别为 98.98%、99.63% 和 99.72%。根据工程报告,在 K340+158—K340+178 段和 K400+460—K400+500 段发生了初支挤压开裂甚至坍塌,如图 9 所示。另外 3 个断面未发生挤压变

表 7 互助北山隧道挤压预测结果

Table 7 Squeezing prediction results of Huzhubeishan tunnel

隧道里程	$H/m$	$Q$	$D/m$	$SSR$	$K/MPa$	实际挤压情况	预测挤压结果	挤压概率/%
K34+160	126.7	0.125 0	11	0.300 0	1 132.24	挤压	挤压	98.98
K37+520	484.3	3.442 2	11	0.947 2	757.07	非挤压	非挤压	0.38
K38+310	624.5	2.287 0	11	0.861 0	9.79	非挤压	非挤压	14.18
K38+720	753.9	9.141 5	11	1.121 3	595.18	非挤压	非挤压	0.80
K40+470	497.9	0.015 0	11	0.223 0	1 000.00	挤压	挤压	99.63
K40+505	519.5	0.007 3	11	0.234 9	1 052.67	挤压	挤压	99.72



(a) K340+158—K340+178段初支挤压



(b) K400+460—K400+500挤压段坍塌

图 9 互助北山隧道挤压现场照片

Fig. 9 Squeezing in Huzhubeishan Tunnel

形, 分别是 K37+520、K38+310 和 K38+720, 其预测的挤压概率分别为 0.38%、14.18% 和 0.80%。6 个隧道断面的挤压变形预测结果全部与实际情况一致, 表明本研究所构建的 GWO-XGBoost 模型在互助北山隧道挤压变形的预测中具有较高的适用性和准确性。此外, 本案例中的三个缺失指标  $Q$ 、 $SSR$  和  $K$  是通过第 2.2 节中介绍的 MI 插值得到, 表明 MI 插值方法对于解决实际工程中的数据缺失问题具有较好的效果, 使得基于缺失数据的隧道挤压预测成为可能。

#### 4.2 木寨岭隧道

本文还采用文献[36]中的木寨岭高速公路隧道工程案例对所提出的隧道挤压预测方法进行了验证。此处不再对该隧道的工程背景进行详细介绍, 读者可参考文献[17, 36]。其中  $H$ 、 $D$ 、 $SSR$  和  $K$  是从工程资料中获取, 通过 MI 插值得到  $Q$ 。木寨岭隧道挤压预测结果如表 8 所列。

所选取的木寨岭隧道的 4 个断面均为挤压断面, 预测结果与实际情况一致, 挤压概率分别为

表 8 木寨岭隧道挤压预测结果

Table 8 Squeezing prediction results of Muzhailing tunnel

隧道里程	$H/m$	$Q$	$D/m$	$SSR$	$K/MPa$	实际挤压情况	预测挤压结果	挤压概率/%
K0+840	75.0	0.039 6	11	0.299	720.49	挤压	挤压	99.65
K0+868	85.0	0.047 7	11	0.364	720.49	挤压	挤压	98.97
K0+904	105.0	0.039 9	11	0.120	720.49	挤压	挤压	99.58
K0+924	115.0	0.039 9	11	0.110	720.49	挤压	挤压	99.42

99.65%、98.97%、99.58%和99.42%，表明本文所构建的 GWO-XGBoost 模型对于木寨岭隧道挤压预测具有较高的适用性和准确性。

## 5 结论

本研究构建了 GWO-XGBoost 模型，基于经过插补和过采样处理的缺失数据集进行训练和测试，然后采用 SHAP 方法对该模型进行了解释。所提出的 GWO-XGBoost 的输入特征包括  $H$ 、 $Q$ 、 $D$ 、 $SSR$  和  $K$ 。为了评估机器学习模型的预测准确性，选取  $ACC$ 、 $F1$ 、 $Kappa$  和  $MCC$  六个指标来对模型预测性能进行评价。此外，还将所构建的 GWO-XGBoost 模型用于互助北山隧道和木寨岭隧道的挤压预测中以证明该模型在实际工程中的适用性和预测准确性。本研究主要得出以下结论。

(1) GWO-XGBoost 模型在训练集上的预测准确率为 98.94%，在测试集上的预测准确率为 98.94%。测试集上的 51 个非挤压样本全部预测正确，44 个挤压样本有 43 个预测正确，仅有 1 个被错误预测为非挤压。

(2) GWO-XGBoost、GWO-SVM、GWO-DT 和 GWO-RF 模型的对比中，GWO-XGBoost 模型展现出了最好的预测性能，4 个机器学习模型在测试集上的  $ACC$  分别为 98.94%、94.74%、95.79% 和 97.89%，预测性能评价指标累计值分别为 5.913 1、5.565 3、5.652 3 和 5.826 2，GWO-XGBoost 模型的预测性能优于其他 3 个模型。

(3) SHAP 解释结果表明， $SSR$ 、 $D$ 、 $K$ 、 $Q$  和  $H$  的平均 SHAP 值分别为 3.06、1.07、0.82、0.73 和 0.51， $SSR$  在 5 个输入特征中对模型输出结果具有最高的重要性，5 个输入特征的重要性排序为： $SSR > D > K > Q > H$ 。

(4) GWO-XGBoost 模型对互助北山隧道的三个挤压断面和三个非挤压断面以及木寨岭隧道的四个挤压断面的预测结果全部与实际情况相符，证明了其在实际隧道挤压预测中具有较高的适用性和准确性。

尽管 GWO-XGBoost 模型对隧道挤压预测取得了极高的准确性，但本研究具有一定的局限性。本研究的预测结果为挤压和非挤压，而不是预测出更具体的挤压变形率或挤压变形等级。因此，未来研究将聚焦于实现隧道挤压变形率或变形等级的准确预测，进一步提升机器学习模型对于隧道安全建设的帮助。此外，本研究所提出的隧道挤压预测方法仅

在两个隧道案例中进行了验证，未来研究中可搜集更多数据样本来扩充数据集，提高模型的泛化性能，并在更多的隧道案例中对该方法进行检验。

## 参考文献 (References) :

- [1] 廖烟开, 由志伟, 李瑞林, 等. 叙毕铁路软岩隧道挤压性变形防治技术研究[J]. 现代隧道技术, 2023, 60(S1): 112-116.  
LIAO Yankai, YOU Zhiwei, LI Ruilin, et al. Research on prevention and control technology of extrusion deformation in soft rock tunnel on Xuyong-Bijie railway[J]. Modern Tunnelling Technology, 2023, 60(S1): 112-116.
- [2] 刘吉光, 王栋, 马国海, 等. TBM 隧道下穿运营高铁隧道变形影响研究[J]. 铁道勘察, 2024, 50(6): 122-128.  
LIU Jiguang, WANG Dong, MA Guohai, et al. Study on the deformation influence of tbm tunnel undercrossing high-speed rail tunnel[J]. Railway Investigation and Surveying, 2024, 50(6): 122-128.
- [3] 崔明, 荆敏, 石红伟. 串珠形溶洞区盾构隧道稳定性研究[J]. 铁道勘察, 2023, 49(2): 44-50.  
CUI Ming, JING Min, SHI Hongwei. Research on the stability of shield tunnel in the environment of beaded karst cave[J]. Railway Investigation and Surveying, 2023, 49(2): 44-50.
- [4] FENG X, JIMENEZ R. Predicting tunnel squeezing with incomplete data using Bayesian networks[J]. Engineering Geology, 2015, 195: 214-224.
- [5] 丁秀丽, 张雨霆, 黄书岭, 等. 隧洞围岩大变形机制、挤压大变形预测及应用[J]. 岩石力学与工程学报, 2023, 42(3): 521-544.  
DING Xiuli, ZHANG Yuting, HUANG Shuling, et al. Large deformation mechanism of surrounding rock masses of tunnels, prediction method of squeezing large deformation and its application [J]. Chinese Journal of Rock Mechanics and Engineering, 2023, 42(3): 521-544.
- [6] SHRESTHA G L, BROCH E. Influences of the valley morphology and rock mass strength on tunnel convergence: with a case study of Khimti I headrace tunnel in Nepal[J]. Tunnelling and Underground Space Technology, 2008, 23(6): 638-650.
- [7] PANET M. Two case histories of tunnels through squeezing rocks[J]. Rock Mechanics and Rock Engineering, 1996, 29(3): 155-164.
- [8] DWIVEDI R D, SINGH M, VILADKAR M N, et al. Prediction of tunnel deformation in squeezing grounds[J]. Engineering Geology, 2013, 161: 55-64.
- [9] 李尚革, 冯雪亮. 基于熵权和灰色关联的 TBM 施工成本风险管理研究[J]. 水利发展研究, 2024, 24(5): 45-52.  
LI Shangge, FENG Xueliang. Research on cost risk management of TBM construction based on entropy right and grey relation[J]. Water

- Resources Development Research, 2024, 24(5): 45-52.
- [10] PANTHI K K, NILSEN B. Uncertainty analysis of tunnel squeezing for two tunnel cases from Nepal Himalaya[J]. International Journal of Rock Mechanics and Mining Sciences, 2007, 44(1): 67-76.
- [11] SINGH M, SINGH B, CHOUDHARI J. Critical strain and squeezing of rock mass in tunnels [J]. Tunnelling and Underground Space Technology, 2007, 22(3): 343-350.
- [12] BHASIN R, GRIMSTAD E. The use of stress-strength relationships in the assessment of tunnel stability [J]. Tunnelling and Underground Space Technology, 1996, 11(1): 93-98.
- [13] GHIASI V, GHIASI S, PRASAD A. Evaluation of tunnels under squeezing rock condition [J]. Journal of Engineering, Design and Technology, 2012, 10(2): 168-179.
- [14] PANTHI K K. Predicting tunnel squeezing: a discussion based on two tunnel projects [J]. Hydro Nepal: Journal of Water, Energy and Environment, 2013, 12: 20-25.
- [15] ARORA K, GUTIERREZ M. Viscous-elastic-plastic response of tunnels in squeezing ground conditions: Analytical modeling and experimental validation[J]. International Journal of Rock Mechanics and Mining Sciences, 2021, 146: 104888.
- [16] 陈卫忠, 田云, 王学海, 等. 基于修正[BQ]值的软岩隧道挤压变形预测[J]. 岩土力学, 2019, 40(8): 3125-3134.  
CHEN Weizhong, TIAN Yun, WANG Xuehai, et al. Squeezing prediction of tunnel in soft rocks based on modified [BQ][J]. Rock and Soil Mechanics, 2019, 40(8): 3125-3134.
- [17] 石州, 罗彦斌, 陈建勋, 等. 木寨岭公路隧道大变形综合评价预测[J]. 公路交通科技, 2020, 37(8): 90-98.  
SHI Zhou, LUO Yanbin, CHEN Jianxun, et al. Comprehensive evaluation and prediction of large deformation of muzhailing highway tunnel [J] Journal of Highway and Transportation Research and Development, 2020, 37(8): 90-98.
- [18] MAHMOODZADEH A, MOHAMMADI M, DARAEI A, et al. Forecasting tunnel geology, construction time and costs using machine learning methods[J]. Neural Computing & Applications, 2021, 33(1): 321-348.
- [19] XU Z, MA W, LIN P, et al. Deep learning of rock microscopic images for intelligent lithology identification: Neural network comparison and selection [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(4): 1140-1152.
- [20] ZHANG W, LI Y, WU C, et al. Prediction of lining response for twin tunnels constructed in anisotropic clay using machine learning techniques[J]. Underground Space, 2022, 7(1): 122-133.
- [21] KIM D, PHAM K, OH J Y, et al. Classification of surface settlement levels induced by TBM driving in urban areas using random forest with data-driven feature selection[J]. Automation in Construction, 2022, 135: 104109.
- [22] ZHANG W, ZHANG R, WU C, et al. State-of-the-art review of soft computing applications in underground excavations [J]. Geoscience Frontiers, 2020, 11(4): 1095-1106.
- [23] RAY R, KUMAR D, SAMUI P, et al. Application of soft computing techniques for shallow foundation reliability in geotechnical engineering[J]. Geoscience Frontiers, 2021, 12(1): 375-383.
- [24] 张志强, 范俊奇, 曾鹏, 等. 基于贝叶斯网络的隧道勘察设计期大变形灾害概率分级预测与应用研究[J]. 地球科学, 2023, 48(5): 1923-1934.  
ZHANG Zhiqiang, FAN Junqi, ZENG Peng, et al. Probabilistic classification prediction of tunnel squeezing based on Bayesian network and its application during investigation and design stage [J]. Earth Science, 2023, 48(5): 1923-1934.
- [25] BO Y, HUANG X, PAN Y, et al. Robust model for tunnel squeezing using Bayesian optimized classifiers with partially missing database [J]. Underground Space, 2023, 10: 91-117.
- [26] ZHOU J, ZHU S, QIU Y, et al. Predicting tunnel squeezing using support vector machine optimized by whale optimization algorithm[J]. Acta Geotechnica, 2022, 17(4): 1343-1366.
- [27] ZHANG J, LI D, WANG Y. Predicting tunnel squeezing using a hybrid classifier ensemble with incomplete data [J]. Bulletin of Engineering Geology and the Environment, 2020, 79(6): 3245-3256.
- [28] GENG X, WU S, ZHANG Y, et al. Developing hybrid XGBoost model integrated with entropy weight and Bayesian optimization for predicting tunnel squeezing intensity [J]. Natural Hazards, 2023, 119(1): 751-771.
- [29] CHEN T Q, GUESTRIN C. XGBoost. A scalable tree boosting system [C]//KRISHNAPURAM B, SHAH M. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2016: 785-794.
- [30] ZHOU X, ZHAO C, BIAN X. Prediction of maximum ground surface settlement induced by shield tunneling using XGBoost algorithm with golden-sine seagull optimization [J]. Computers and Geotechnics, 2023, 154: 105156.
- [31] MA M, ZHAO G, HE B, et al. XGBoost-based method for flash flood risk assessment[J]. Journal of Hydrology, 2021, 598: 126382.
- [32] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [33] YANG H, WANG Z, SONG K. A new hybrid grey wolf optimizer-feature weighted-multiple kernel-support vector regression technique to predict TBM performance [J]. Engineering with Computers, 2022, 38(3): 2469-2485.
- [34] YU X, XU W, LI C. Opposition-based learning grey wolf optimizer for global optimization [J]. Knowledge-Based Systems, 2021, 226: 107139.
- [35] SOKOLOVA M, LAPALME G. A systematic analysis of performance

- measures for classification tasks [J]. *Information Processing & Management*, 2009, 45(4): 427-437.
- [36] 焦玉勇, 欧光照, 王浩, 等. 基于证据理论的隧道挤压变形预测 [J]. *应用基础与工程科学学报*, 2021, 29(5): 1156-1170.  
JIAO Yuyong, OU Guangzhao, WANG Hao, et al. Prediction of tunnel squeezing based on evidence theory [J]. *Journal of Basic Science and Engineering*, 2021, 29(5): 1156-1170.
- [37] BARTON N, LIEN R, LUNDE J. Engineering classification of rock masses for the design of tunnel support[J]. *Rock mechanics*, 1974, 6(4): 189-236.
- [38] JIMENEZ R, RECIO D. A linear classifier for probabilistic prediction of squeezing conditions in Himalayan tunnels [J]. *Engineering Geology*, 2011, 121(3/4): 101-109.
- [39] HOEK E. Big Tunnels in bad rock[J]. *Journal of Geotechnical and Geoenvironmental Engineering*, 2001, 127(9): 726-740.
- [40] FIX E, HODGES J L. Discriminatory analysis. Nonparametric discrimination; Consistency properties [J]. *International Statistical Review / Revue Internationale de Statistique*, 1989, 57(3): 238-247.
- [41] MAHDEVARI S, TORABI S R, MONJEZI M. Application of artificial intelligence algorithms in predicting tunnel convergence to avoid TBM jamming phenomenon[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2012, 55: 33-44.
- [42] DABLAIN D, KRAWCZYK B, CHAWLA N V. DeepSMOTE: Fusing deep learning and SMOTE for imbalanced data [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(9): 6390-6404.
- [43] FERNANDEZ A, GARCIA S, HERRERA F, et al. SMOTE for learning from imbalanced data: Progress and challenges, marking the 15-year anniversary [J]. *Journal of Artificial Intelligence Research*, 2018, 61: 863-905.
- [44] HUANG Z, LIAO M, ZHANG H, et al. Predicting tunnel squeezing using the SVM-BP combination model [J]. *Geotechnical and Geological Engineering*, 2022, 40(3): 1387-1405.
- [45] AN X, ZHENG F, JIAO Y, et al. Optimized machine learning models for predicting crown convergence of plateau mountain tunnels [J]. *Transportation Geotechnics*, 2024, 46: 101254.
- [46] FAWCETT T. An introduction to ROC analysis [J]. *Pattern Recognition Letters*, 2006, 27(8): 861-874.
- [47] LOVE P E D, FANG W, MATTHEWS J, et al. Explainable artificial intelligence (XAI): Precepts, models, and opportunities for research in construction [J]. *Advanced Engineering Informatics*, 2023, 57: 102024.
- [48] 王雪飞, 高科超, 张兴华, 等. 试井数据监督式机器学习方法预测变质岩潜山储层产量 [J]. *石油钻采工艺*, 2024, 46(4): 443-454.  
WANG Xuefei, GAO Kechao, ZHANG Xinghua, et al. A supervised machine learning method based on well test data to predict reservoir production in buried-hill metamorphic rock [J]. *Oil Drilling & Production Technology*, 2024, 46(4): 443-454.
- [49] CORTEZ P, EMBRECHTS M J. Using sensitivity analysis and visualization techniques to open black box data mining models [J]. *Information Sciences*, 2013, 225: 1-17.
- [50] ARSLAN Y, LEBICHOT B, ALLIX K, et al. Towards refined classifications driven by SHAP explanations [J]. *Machine Learning and Knowledge Extraction*, 2022: 13480.

(责任编辑 王海锋)