

DOI: 10.11779/CJGE20221141

基于数字钻探与多尺度模型融合的隧道岩体完整性自动解译技术研究及应用

梁铭¹, 彭浩^{*1}, 解威威^{1,2}, 韩玉¹, 宋冠先¹, 朱孟龙¹, 黄能豪¹, 周邦鸿¹, 卢振龙¹

(1. 广西路桥工程集团有限公司, 广西 南宁 530000; 2. 广西大学土木与建筑工程学院, 广西 南宁 530004)

摘要: 在多岩性与多指标钻探数据收集的基础上, 综合考虑解译精度与预报效果, 借助机器学习工具, 提出一种基于数字钻探与多尺度模型融合的隧道岩体完整性自动解译技术。首先, 对原始钻探数据有针对性的进行降噪与等距分割(0.5, 1, 2 m)等预处理, 形成多尺度、高质量机器学习数据集; 然后, 进行模型参数自动寻优、训练、评估与可解释性等操作, 验证模型的准确性与可靠性; 最后, 采用加权平均的方法进行多尺度模型解译结果的融合, 以增强该技术的工程实用效果。为方便实际工程应用, 以上述技术为核心开发轻量化数字钻探智能解译平台, 经多条灰岩与砂岩隧道应用结果表明: 对比地质雷达与常规钻探解译, 多尺度模型融合解译在解译效率、预测效果等方面总体表现优异, 可为隧道施工的开挖与支护提供可靠的岩体完整性信息。

关键词: 隧道工程; 超前钻探预报; 岩体质量评价; 机器学习; 模型可解释性

中图分类号: TU43; U451 文献标识码: A 文章编号: 1000-4548(2024)02-0396-10

作者简介: 梁铭(1992—), 男, 硕士, 工程师, 主要从事隧道超前地质预报智能化解译等方面的科研工作。E-mail: csuliangming@csu.edu.cn。

Application of automatic interpretation technology of tunnel rock mass integrity based on digital drilling and multi-scale model fusion

LIANG Ming¹, PENG Hao¹, XIE Weiwei^{1,2}, HAN Yu¹, SONG Guanxian¹, ZHU Menglong¹, HUANG Nenghao¹, ZHOU Banghong¹, LU Zhenlong¹

(1. Guangxi Road and Bridge Engineering Group Co., Ltd., Nanning 530000, China; 2. College of Civil Engineering and Architecture, Guangxi University, Nanning 530000, China)

Abstract: By collecting the multi-lithology and multi-index drilling data, an automatic interpretation technology of tunnel rock mass integrity based on integrated algorithm and multi-scale model fusion is proposed considering comprehensive interpretation accuracy and practical effect. First, the pre-processing such as noise reduction and equidistant segmentations (0.5, 1 and 2 m) is carried out of the raw data to form a multi-scale, high-quality machine learning dataset. Then the operations such as automatic parameter optimization, training, evaluation and interpretability of model are performed to verify the accuracy and reliability. Finally, the weighted average method is used to fuse the multi-scale interpretation results to enhance the engineering practical effect. In addition, in order to facilitate practical engineering applications, a lightweight automatic interpretation platform is developed. The application results of several limestone and sandstone tunnels show that compared with the conventional interpretation, the multi-scale model fusion interpretation has the overall excellent performance in interpretation efficiency and prediction effect. It can provide reliable rock mass integrity information for the excavation and support of tunnel construction.

Key words: tunnel engineering; advanced drilling forecast; rock mass quality evaluation; machine learning; model interpretability

0 引言

超前地质预报是保障隧道施工安全的重要手段之一, 它可以探明掌子面前方未开挖岩体的地质构造、不良地质体类型、特殊岩土体性质等, 为隧道开挖工法与支护措施提供重要参考^[1]。根据工作原理, 隧道

超前地质预报大体可分为地球物理法与地质分析法两类。前者如地质雷达、地震波等通过探测岩体的物理性质变化来进行地质预报, 缺点是具有显著多解性^[2];

基金项目: 广西壮族自治区科技厅项目(桂科 AB22080033)

收稿日期: 2022-09-19

*通信作者(E-mail: gxlq3409ph@163.com)

超前钻探属于地质分析法,可直接揭露未开挖岩体的强度、完整性等信息,是较为直接、有效且可靠的超前地质预报方法之一,在工程实践中应用广泛^[3]。

随着数字钻探技术的发展,20世纪70年代后,开始出现携带多种传感器的多功能钻机,可以对钻进过程中的钻进速率、推力等参数进行实时记录^[4],这为钻探解译技术的发展提供了有利条件。这段时间的研究成果以国外为主^[5-6],覆盖岩体质量评价、软弱面识别、溶洞发育探测等。但上述研究大多只考虑少量(1~2个)钻进参数的作用,使得解译的可靠度不足,且在原始钻探数据的降噪方面缺乏相应研究。

进入21世纪后,超前钻探预报在国内外隧道岩溶探测等领域越来越得到重视,钻探数据解译成为学者关注的焦点。针对常规钻探解译存在的依赖主观经验判断、评判标准不统一以及解译效率低等问题,目前研究成果大体可分为以下三类。一是基于破岩机理分析,此类解译多以钻进过程的能量分析与力学平衡为切入点:如Wang等^[7]推导了随钻参数与岩石单轴抗压强度的定量关系模型;梁栋才等^[8]出了相应的地层识别综合指标。但上述研究为建立相关能量等式进行了大量理想假设,且未考虑钻探过程中的能量损耗问题,能否适应钻探现场的复杂环境仍需要进一步讨论。因此,也有学者从淡化原理分析角度出发,利用传统数理统计为工具进行钻探解译分析:Ghosh等^[9]Elbert等^[10]通过对钻探数据进行统计分析,构造定量评价指标FI(Fracture Index);Wu^[11]利用聚类分析实现了TBM施工过程四类岩性的有效识别。但此类研究为保证统计分析效果,通常考虑一个或两个钻进参数的作用,且所得结论仅在单条隧道或单一岩性隧道成立,未进行更复杂隧道条件下的可靠度验证。

随着大数据、人工智能等信息化技术的发展,机器学习的理念已逐步渗入各个领域,为数据分析提供了新的思路,因此近些年开始有研究者将机器学习的方法引入隧道钻探数据解译中,并取得了一定成果:房昱纬等^[12]提出了一种基于神经网络的钻探测试数据智能分析和地层识别方法;Wang等^[13]利用支持向量机(SVM)实现了对III~V级围岩的超前分类。此外,基于超前钻探参数的围岩智能质量评价方法在郑万铁路的多条隧道得到了成功应用^[14],从工程应用角度验证了此类机器学习方法的实用性。

总体来说,利用机器学习模型来进行超前钻探数据解译可综合考虑各类钻探指标,且具备较高的解译效率^[15],但目前尚存在3点不足:①在原始钻探数据收集方面,存在隧道单一与岩性单一的问题,模型适

用性面临考验;②原始钻探数据受机械及现场复杂因素影响,存在不同类型的噪点数据,但具有针对性的预处理及降噪措施未完善;③目前大多研究未有效回应机器学习模型一直存在的“黑箱”问题,即模型可解释性欠缺,这使得模型的合理与可靠性存疑。

基于上述问题,提出一种基于数字钻探与机器学习方法的隧道岩体完整性自动解译技术,通过钻探过程中采集的推进速度、推进力等多项定量参数对所钻岩体完整性进行自动解译与评价。在原始钻探数据收集与预处理方面,囊括广西区内多条灰岩与砂岩隧道钻探数据,并制定契合钻探数据特征的标准化降噪预处理流程;在模型构建与评估方面,利用遗传算法解决机器学习模型的复杂参数寻优问题,并借助SHAP值理论增强模型可解释性,最终结合各尺度模型特点进行模型融合以优化解译效果;在工程应用方面构建数字钻探自动解译平台,并进行大量实际隧道应用检验了本文技术的可靠性与实用性。

1 主要算法介绍与具体实施方法

1.1 极限梯度提升算法(XGBoost)

决策树(decision tree)模型由于具备较好可解释性等优点,是机器学习领域最常用的模型之一,同时使得基于决策树的一些集成算法模型受到研究与重视,XGBoost便是其中之一。如图1所示,XGBoost通过串行训练大量单一决策树模型对预测结果进行校正,最终得到一个更加可靠、准确的预测结果^[16]。

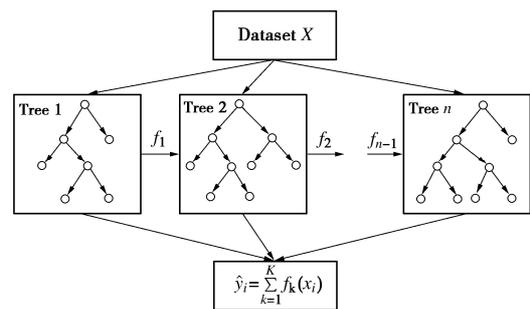


图1 XGBoost集成算法示意

Fig. 1 Schematic diagram of XGBoost

图1中: \hat{y}_i 为整个模型在这个样本上的预测结果, K 为决策树的总数量, f_k 为第 k 棵决策树, x_i 为样本 i 对应的特征向量。XGBoost引入了目标函数 O_{bj} 来衡量算法的运算效率,表达式为

$$O_{bj} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

式中: n 为决策树的总数目; $\sum_{i=1}^n l(y_i, \hat{y}_i)$ 为损失函数部分,用来衡量预测标签与真实标签的差距; $\sum_{k=1}^K \Omega(f_k)$ 为

正则化项用来表示模型复杂度。

在具体的分类模型性能评估方面，则借助准确率 A_{CC} 、精确率 P_{RE} 、召回率 R_{EC} 与调和平均数 F_1 进行综合评估，以考虑样本不平衡等因素导致的模型性能偏差，全面评价模型性能。具体计算公式如下：

$$A_{CC} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (2)$$

$$P_{RE} = \frac{T_p}{T_p + F_p} \quad (3)$$

$$R_{EC} = \frac{T_p}{T_p + F_N} \quad (4)$$

$$F_1 = \frac{2P_{RE} \times R_{EC}}{P_{RE} + R_{EC}} \quad (5)$$

式中： T_p ， T_N ， F_p ， F_N 分别为预测混淆矩阵中的真阳性、真阴性、假阳性和假阴性样本数量。

1.2 遗传算法 (GA)

遗传算法 (genetic algorithm) 最早由美国的 Holland 教授于 1975 年提出。如图 2 所示，作为一种借鉴生物界自然选择和自然遗传机制的随机搜索算法，它模拟自然选择和自然遗传过程中发生的繁殖、交叉和基因突变现象，利用遗传算子 (包括选择、交叉和变异操作) 对这些个体进行组合，产生新一代的候选种群，并重复此过程直到满足收敛条件为止。

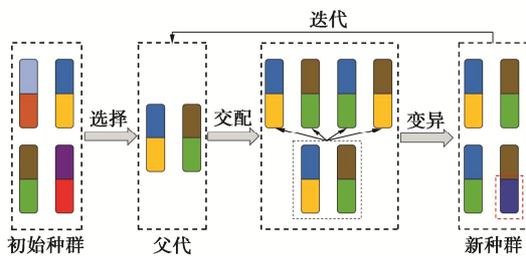


图 2 遗传算法流程示意

Fig. 2 Schematic diagram of genetic algorithm

目前，GA 算法机器学习模型参数寻优领域广泛应用^[17]。与机器学习领域常用的网格搜索相比，其主要本质特征在于群体搜索策略和简单的遗传算子：群体搜索可突破领域搜索的限制，实现整个解空间上的分布式信息采集和探索；遗传算子则利用适应度度量作为运算指标进行随机操作，降低了在搜索过程中对人机交互的依赖。

1.3 SHAP 值算法

SHAP 算法基于 SHAP 值 (shapley value) 进行模型可解释性，这一概念来自博弈论^[18]。其基本思想是用一个加性模型 $G(x)$ 来拟合训练好的分类器 $F(x)$ ：

$$F(x) = G(x) = \phi_0 + \sum_{j=1}^n \phi_j \quad (6)$$

式中： ϕ_0 为模型对样本的预测基准值，代表模型对任一样本预测结果的期望，即所有样本标签的均值； ϕ_j 为 n 维样本 x 第 j 个特征的 SHAP 值。

每个样本 x 的任一特征 x_j 在不同特征子集中的边际贡献的均值，即定义为该特征的 SHAP 值 ϕ_j ，具体计算方式：

$$\phi_j = \sum_S \frac{|S|!(n-|S|-1)!}{n} [F_x(S \cup \{x^j\}) - F_x(S)]$$

$$S \subseteq (\{x^1, x^2, \dots, x^n\} - \{x^j\}) \quad (7)$$

式中： $\{x^1, x^2, \dots, x^n\}$ 为全体输入特征的集合； S 为不包含特征 x^j 的特征子集。

1.4 具体实施方法

本文研究具体实施方法如图 3 所示。

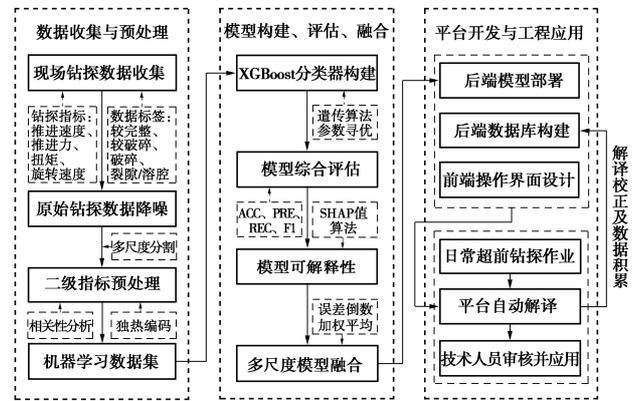


图 3 研究技术路线图

Fig. 3 Research technology roadmap

(1) 数字钻探数据获取及预处理：基于多条隧道进行原始钻探数据收集并制定标准化降噪及预处理措施。其中，在进行多尺度分割后构成供机器学习模型学习训练的数据集，并采取措施提高数据集质量。

(2) 自动解译模型构建及评估：以 XGBoost 集成算法为分类器构建岩体完整性自动解译模型，配合 GA 算法实现其超参数自动寻优，并对所构建模型进行性能指标综合评估与 SHAP 值可解释性分析以验证模型的准确度与可靠度。最终根据评估分析结果进行多尺度模型融合。

(3) 自动解译平台开发及工程应用：部署上述模型构建数字钻探智能解译平台以开展实际工程应用，并对自动解译结果进行校正，在检验技术工程实用性的同时不断丰富钻探数据以实现模型迭代优化。

2 数字钻探数据获取及预处理

2.1 原始钻探数据来源及工程概况

广西地貌总体为山地丘陵性盆地，隧址区多岩溶、软弱夹层等不良地质体发育。为保障施工安全，隧道现场使用 Casagrande C6-2 型多功能钻机进行超

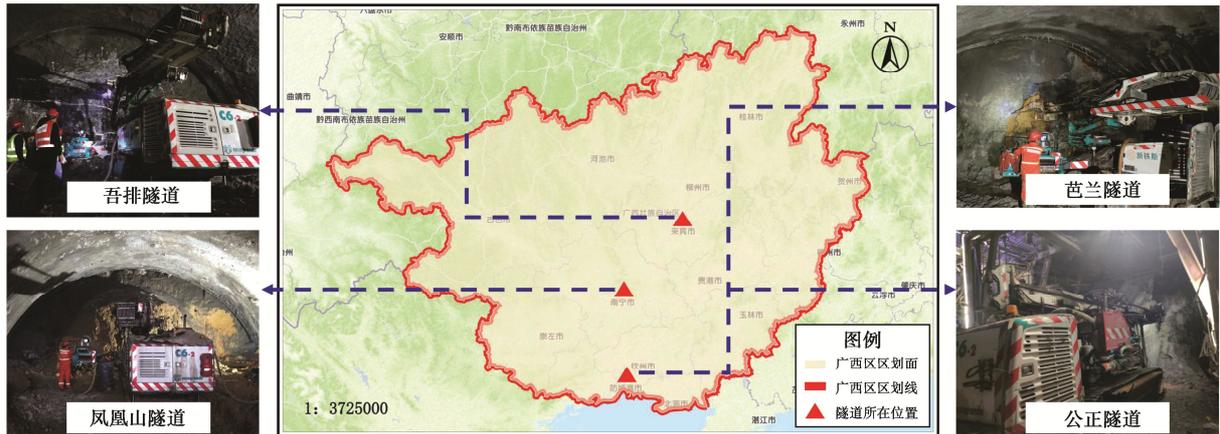


图 4 隧道位置及现场超前钻探作业

Fig. 4 Tunnel location and on-site advance drilling operations

前钻探地质预报。原始钻探数据来源如图 4 所示。

如图 4 所示, 钻探数据收集自 4 条隧道(灰岩、砂岩各两条), 各条隧道的简要工程概况介绍如下。

(1) 吾排隧道: 位于来宾市新柳南高速。设计长度约为 1620 m, 最大埋深约 280 m, 主要穿越较破碎—破碎的中风化灰岩地层, 且岩溶较为发育。

(2) 凤凰山隧道: 位于南宁市新柳南高速。设计长度约为 1500 m, 最大埋深约 240 m, 主要穿越较完整—较破碎的中风化灰岩地层, 且岩溶较为发育。

(3) 芭兰隧道: 位于防城港市上防高速。特长隧道, 最大埋深约 236 m。围岩主要为中风化砂岩, 岩体裂隙及软弱夹层发育, 整体呈较破碎—破碎。

(4) 公正隧道: 位于防城港市上防高速。设计长度约为 4187 m, 属特长隧道, 最大埋深约 407 m。隧道围岩主要为微风化—中风化砂岩, 岩体裂隙及软弱夹层发育, 整体呈较完整—破碎, 地下水较发育。

基于上述 4 条隧道, 共收集原始钻探数据两万余条, 覆盖隧道长度累计约 400 m (数字钻探系统采样频率约为 50 条/m)。在数据收集过程中, 技术人员根据相关隧道规范^[9]与钻探作业现场实际情况对岩体的“较完整”、“较破碎”、“破碎”及“裂隙/溶腔”4 类岩体完整性及不良地质情况进行解译及标注。

2.2 原始钻探数据降噪

(1) 原始钻探数据特征分析

在数字钻探系统下, 每条原始钻探数据除深度外, 主要包括推进速度、推进力、扭矩与旋转速度共 4 项钻探指标。选取具备代表性的芭兰隧道 YK2+621—YK2+611 共 10 m 原始钻探数据, 进行特征分析, 如图 5 所示, 主要具备以下 3 个特点: ①采样阶段性, 包括初期的上升段及过后的正常采样阶段, 其中上升

段通常集中在 0~1 m 的进尺范围内, 该范围主要涉及钻机空钻、初喷混凝土及受钻爆扰动影响较大的岩体段落, 数据不具备解译价值。②个别指标离散程度大, 推进速度、扭矩的数值都表现出了较大的离散性, 同时这也是常规解译过程中技术人员的主要判据。③存在不同类型异常值, 在正常采样阶段, 主要存在两种类型的异常值, 受机手操作及机械因素影响, 钻探指标出现空值; 受换杆操作等影响, 推进速度采样值会出现极短暂的激增。

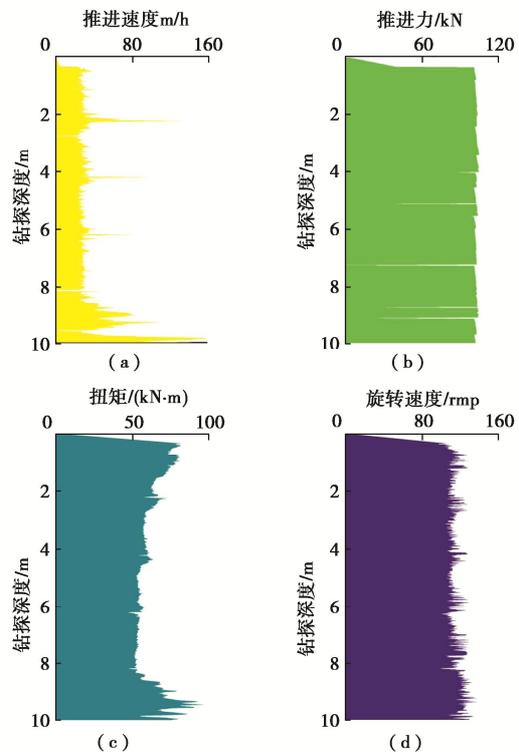


图 5 原始钻探数据可视化

Fig. 5 Visualization of raw drilling data

(2) 原始钻探数据降噪措施

针对原始钻探数据数字特征的分析及其降噪措施,此前已进行相关研究^[20],有关删除上升段、均值填充缺失值等重复措施在此不再赘述。

在已有研究基础上,为削弱激增异常值的不良影响,同时充分反映离散程度与钻探岩体完整性之间的潜在关系,进行多尺度等距分割与二级指标计算,即考虑实际工程经验与预报精度需求,将等距分割制尺度 d 定为 0.5, 1, 2 m, 并对指标各自分割段落内的数据进行二次计算,形成二级指标作为机器学习数据集的特征。具体地,计算均值与方差作为二级指标:

①均值 \bar{x} 。不同岩体完整性的原始钻探数据都存在一定的取值范围,均值是该取值范围的重要体现,且通过取均值可以降低分割间距内异常数据对整体真实数据的影响,从而实现进一步降噪。②方差 S_n^2 。通过对分割间距内原始钻探数据的方差进行计算,可以较为合理的反映不同完整性岩原始钻探数据的离散程度,实现离散程度与岩体完整性之间关系的规律挖掘与定量表达。

均值与方差的计算如下:

$$\bar{x} = (x_1 + x_2 + x_3 + \dots + x_n) / n \quad (8)$$

$$S_n^2 = [\sum_{i=1}^n (x_i - \bar{x})^2] / n \quad (9)$$

式中: n 为分割段落内的样本数量; x_i 与 \bar{x} 为各样本数值及总体样本均值。

以图 5 (a) 推进速度为例,上述降噪操作的效果如图 6 所示。

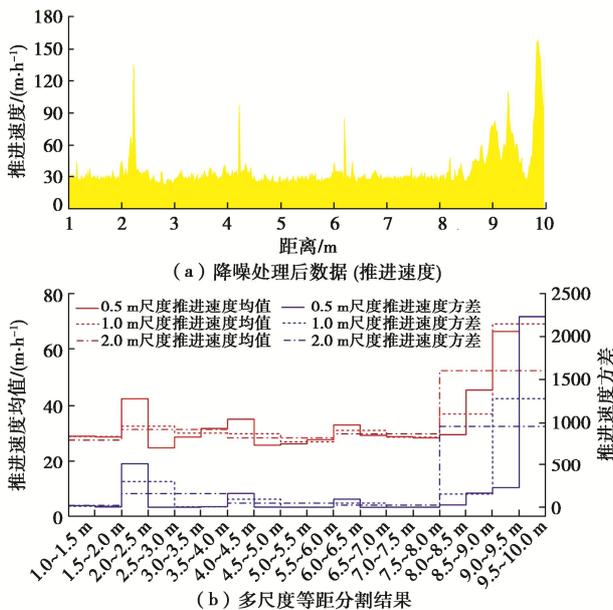


图 6 数据降噪及多尺度等距分割

Fig. 6 Data noise reduction and multi-scale segmentation

2.3 机器学习数据集预处理

(1) 数据集描述

原始钻探数据经上述处理后,形成的机器学习数据集对应 0.5, 1, 2 m 3 种分割尺度分别有样本 968 例、472 例以及 235 例,所有数据集包含 9 项特征(RMT 岩性类别、DRM 推进速度均值、TPM 推进速度均值、TM 扭矩均值、RM 旋转速度均值、DRV 推进速度方差、TPV 推进速度方差、TV 扭矩方差、RV 旋转速度方差)与 4 项标签(“较完整”、“较破碎”、“破碎”及“裂隙/溶腔”)。

以 0.5 m 尺度分割的数据集为例,其特征描述如表 1 所示。

表 1 数据集特征及其数字描述

Table 1 Dataset features and their numerical descriptions				
特征	最小值	最大值	中值	均值
RMT	—	—	—	—
DRM	12.39	207.80	31.44	49.16
TPM	96.35	109.09	102.39	103.03
TM	35.14	86.77	49.51	52.25
RM	64.60	182.01	144.99	139.61
DRV	1.24	2555.04	37.43	178.46
TPV	0.52	398.52	1.35	3.79
TV	0.17	153.11	3.38	10.02
RV	0.84	260.41	13.65	26.57

(2) 数据集特征相关性分析

为降低数据集特征维度、加快后续解译模型拟合速度,对机器学习数据集的 8 项二级指标进行相关性分析以剔除较高相关性的指标。特征之间相关性系数 ρ 为

$$\rho = \frac{\sum_{i=1}^n (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^n (a_i - \bar{a})^2} \sqrt{\sum_{i=1}^n (b_i - \bar{b})^2}} \quad (10)$$

式中: a_i 与 b_i 为两项特征的各自样本数值; \bar{a} 与 \bar{b} 为两项特征的样本均值。 ρ 介于 $-1 \sim +1$, 表示负相关与正相关程度,越接近 0 表示相关性越弱。

计算相关性绘制热力图如图 7 所示。可以发现 RMT 与 RM, TV 与 RV 由较强正相关性,分别为 0.68 和 0.78, RMT 与 TV、RV, DRV 与 TPM 以及 TPM 与 TPV 有较强负相关性,分别是 -0.71 , -0.76 , -0.65 , 0.62。综上考虑,将特征 RM、TPV、TV 以及 RV 去除,最终机器学习数据集保留 RMT、DRM、TPM、TM、以及 DRV 5 项特征。

(3) 数据集特征独热编码

为使机器学习模型识别非数值型特征,对特征 RMT 进行独热编码。相比较传统的数字编码(如将灰岩与砂岩分别编码为“0”和“1”),独热编码可以以矩阵的形式表达,从而避免数字编码自带的数学数字属性对后续机器学习模型训练造成的影响。灰岩与砂岩的独热编码分别为 $[0, 1]$ 与 $[1, 0]$ 。

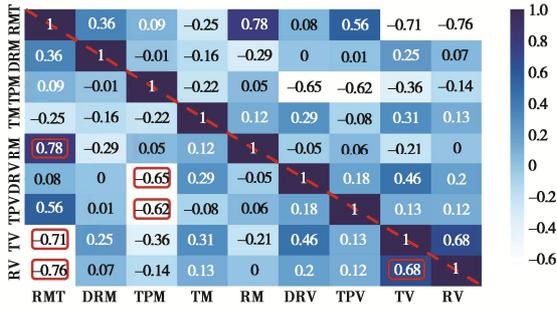


图 7 特征相关性热力图

Fig. 7 Feature correlation heatmap

3 解译模型构建、评估及多尺度融合

3.1 GA-XGBoost 自动解译模型构建

以 XGBoost 为分类器, 结合 GA 算法形成 GA-XGBoost 模型。GA 算法具体设置如下: 在种群规模方面, 种群迭代 20 次, 初始种群个体数量为 10; 在种群适应度的衡量指标方面, 定义为 5 折交叉验证的 ACC, 计算如式 (2) 所示; 在个体交配形式方面, 采用均匀交叉方式进行, 且设置个体突变概率为 0.1 以增加物种多样性。

在超参数取值范围方面, 根据 XGBoost 模型相关的研究, 选取其中重要的 6 项超参数为寻优对象, 具体超参数及其寻优空间为: $n_estimators$ 、 max_depth 依次为 (10, 200, 1)、(3, 10, 1)、 $learning_rate$ 、 min_child_weight 、 $subsample$ 与 $colsample_bytree$ 全部为 (0, 1, 0.01), 括号内取值分别代表最小取值、最大取值与寻优密度。迭代收敛条件为

$$f_{it}(n)_{max} - f_{it}(n-1)_{max} = 0 \quad (11)$$

式中: $f_{it}(n)_{max}$ 为当代最优个体适应度值; $f_{it}(n-1)_{max}$ 为前一代最优个体适应度值。即在迭代过程中当种群内最优个体的适应度值不发生变化时, 认为迭代收敛。

选取迭代收敛后各尺度最优个体所携带信息 (即 XGBoost 模型超参数组合), 如表 2 所示。

表 2 数据集特征及其数字描述

Table 2 Dataset features and their numerical descriptions			
超参数	0.5 m	1.0 m	2.0 m
$n_estimators$	106	83	72
max_dept	7	8	8
$learning_rate$	0.21	0.30	0.50
min_child_weight	0.45	0.13	0.53
$subsample$	0.68	0.45	0.37
$colsample_bytree$	0.95	0.91	0.72

3.2 各尺度解译模型性能综合评估

为进行解译模型的合理评估, 设置训练集与预测集的比例为 7:3, 并按照式 (2) ~ (5) 对模型进行综合指标评估。同时, 将未进行超参数寻优的 XGBoost

模型评估结果作为对比 (取模型默认超参数), 结果如表 3 所示。

表 3 数据集特征及其数字描述

Table 3 Dataset features and their numerical descriptions

类别	尺度/m	$Acc\%$	$P_{ER}\%$	$R_{EC}\%$	$F1\%$
GA 寻优	0.5	96.91	98.07	96.38	97.11
	1.0	94.32	96.13	92.23	93.58
	2.0	91.43	96.25	86.31	89.03
未寻优	0.5	92.86	95.00	92.19	92.59
	1.0	91.84	92.17	89.52	90.70
	2.0	87.55	90.05	84.64	87.26

由表 3 可知, 参数寻优后模型性能普遍高于使用默认参数的 XGBoost 模型, 且具体呈现出两点规律: ①随着分割尺度的增大, 模型性能由逐渐下降, 以 Acc 为例, 由 0.5 m 尺度下的 96.91% 下降到 2 m 尺度下的 91.43%, 推测与分割尺度增大导致的训练数据集样本数量大幅减少有关; ② P_{ER} 指标普遍高于 R_{EC} 指标, 这说明模型具有偏向正样本的预测趋势。为进一步探究具体模型的分类型预测情况, 输出各尺度模型预测混淆矩阵的热力图, 结果如图 8 所示。

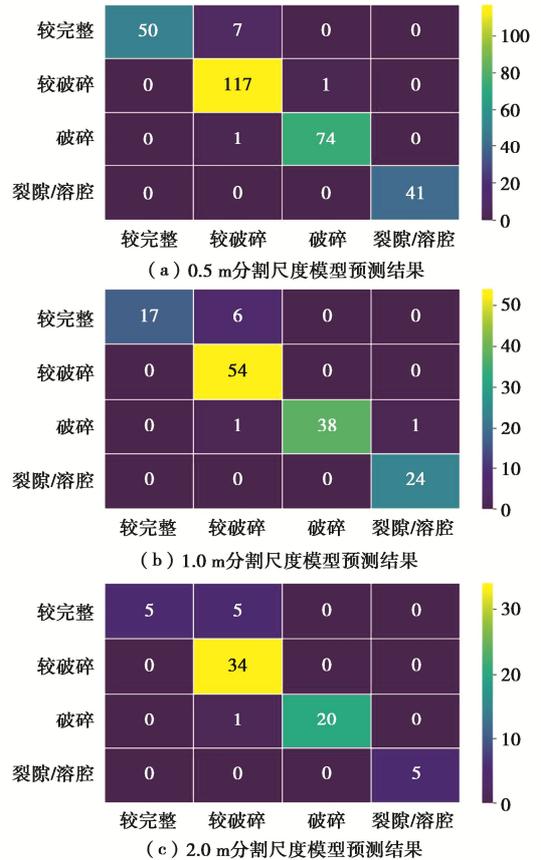


图 8 预测结果混淆矩阵热力图

Fig. 8 Confusion matrix heatmap of multi-scale model prediction

图 8 中横坐标为实际样本标签, 左侧纵坐标为预测样本标签, 右侧纵轴表示预测集样本数量及其颜色梯度映射。与上述第二点规律相匹配, 各尺度分类模

型的错误预测主要集中在将“较完整”预测为“较破碎”，且随着分割尺度的增大，这种预测趋势愈加明显。推测原因主要有两点：①根据工程实践经验，这两类岩体实际存在偏于保守的主观判别倾向，导致这两类原始钻探数据标签存在一定程度的失真；②随着分割尺度的加大，“较完整”分割段落内计算的均值与方差更加容易与“较破碎”混淆。

3.3 各尺度解译模型可解释性论述

SHAP 值作为一种定量模型可解释性工具，有以下两点显著规律：①某一特征的总 SHAP 值越大，该特征对于模型而言重要度越高；②就某一特征对应各分类标签而言，SHAP 值占比越大，说明该特征对该标签的预测越重要。各尺度模型输出的 SHAP 值统计如图 9 所示。

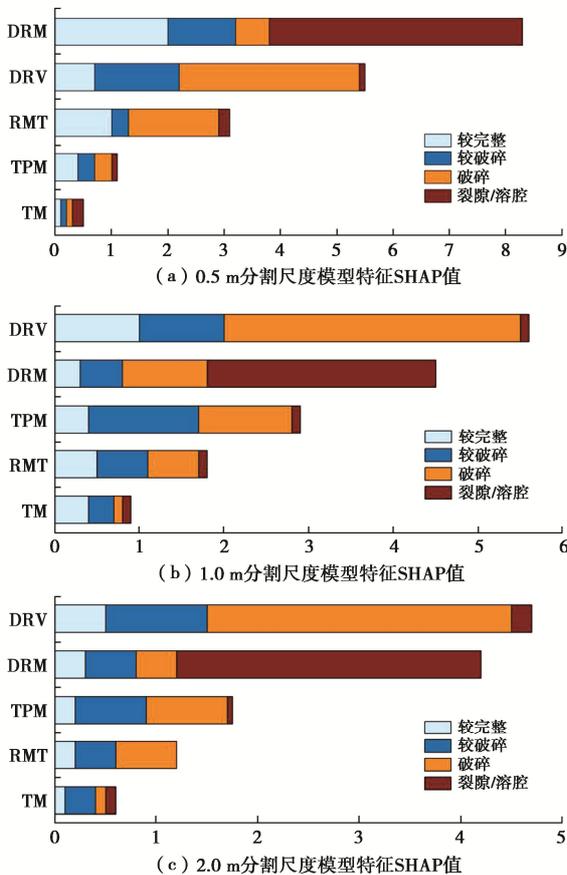


图9 各尺度模型下各项特征 SHAP 值

Fig. 9 SHAP values of each feature under each scale model

结合上述规律，针对各尺度模型可解释性有以下 3 点特征：①随着分割尺度的增大，5 项特征对模型的重要程度会发生变化。但总体而言，DRM 与 DRV 是最重要的两项指标，说明了推进速度对钻探数据解译的重要性，这也与工程实践及已有研究成果相吻合。②DRM 与 DRV 两项重要特征分别对“裂隙/溶腔”、“破碎”两项标签始终保持较高的 SHAP 值，即对标签预测做出贡献。从工程实践经验角度出发，当钻进

到“裂隙/溶腔”地层时，钻进速度急剧升高且保持相对平稳；当钻进到破碎岩体时，一方面破碎岩体相较于完整岩体更易钻进，推进速度更快，另一方面受破碎岩体影响，推进速度数据离散度大大提高。③针对前文所述的标签“较完整”容易产生的错误预测，发现所有特征对该标签的 SHAP 值都较少，且该现象随着分割尺度的增大愈发明显。

综上所述，针对 4 类标签，从模型性能角度出发，本文所构建各尺度自动解译模型都具备较好的分类性能，且通过模型可解释性发现模型内在的预测逻辑与表现出的预测效果相一致，且都与工程实践的经验较吻合，模型具有较高的合理性与可靠度。

3.4 基于加权平均的多尺度模型融合

在进行数据收集时，为提高数据质量，多选取噪音数据少以及标签特征显著的钻探数据，进而影响模型在实际、连续原始钻探数据中的解译效果。因此为提高模型的工程实用性，选取凤凰山隧道 ZK109+403 掌子面钻探 1 号孔中的 1~20 m 数据进行模型实际预测效果的说明。原始钻探数据如图 10 (a)~(c) 所示，各尺度模型自动解译效果如图 10 (d)~(f) 所示。可以发现多尺度模型在实际的连续原始钻探数据中应用时，主要呈现出以下 2 个特点。

(1) 0.5 m 尺度下由于分割间距过小，导致模型对 DRM 与 DRV 两项重要特征的数值变化过于敏感，从而产生两种现象：①少量原始数据点的激增或骤降极易导致其预测结果在“较完整”、“较破碎”与“破碎”3 类标签之间变化，一方面容易产生因异常数据导致的错判，另一方面总体预测效果的完整性较差，如 1~5, 9.5~10 m 的预测效果所示。②同样由于上述原因致使对于“裂隙/溶腔”标签的预测十分精确，一些薄层状的软弱夹层或者裂隙/溶腔也可以预测，如 12~13.5 m。前者不利于工程实际应用，后者对于隧道施工安全而言又较为有利。

(2) 在 1, 2 m 的尺度下，由于分割间距的增大，较 0.5 m 尺度的预报效果完整性更好，同时与之对应的缺点是预测精准度不足，如 1 m 尺度下 13~13.5 m “裂隙/溶腔”标签的预测、2 m 尺度下的 14~15 m “裂隙/溶腔”标签的预测等。

结合以上两点，提出一种基于误差倒数加权平均^[21]多尺度模型融合的钻探岩体完整性自动解译模型，可以极大融合 3 种尺度的解译效果，使得最终解译在保证精准度的同时，提高预报完整性以优化解译效果。所设置的融合规则遵循以下两点：

(1) 4 项解译标签编码为定量值（编码为 1, 2, 3, 4），根据式 (12) 进行预测标签的加取平均计算：

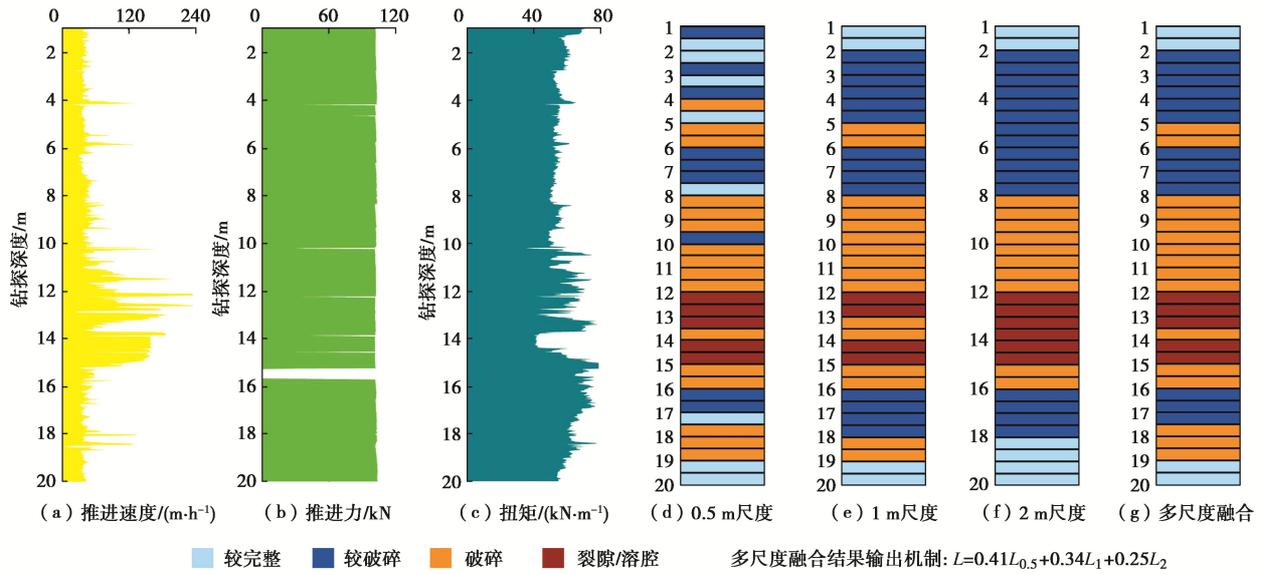


图 10 各尺度模型解译效果及多尺度模型融合解译效果

Fig. 10 Interpretation effects of each scale model and multi-scale model fusion

$$L = \omega_1 L_{0.5} + \omega_2 L_1 + \omega_3 L_2 \quad (12)$$

式中: $L_{0.5}, L_1$ 与 L_2 为各尺度模型的预测标签取值; $\omega_1, \omega_2, \omega_3$ 代表各尺度模型的权重。权重可以根据误差倒数法确定:

$$\omega_1 = (\varepsilon_2 + \varepsilon_3) / 2(\varepsilon_1 + \varepsilon_2 + \varepsilon_3) \quad (13)$$

$$\omega_2 = (\varepsilon_1 + \varepsilon_3) / 2(\varepsilon_1 + \varepsilon_2 + \varepsilon_3) \quad (14)$$

$$\omega_3 = (\varepsilon_1 + \varepsilon_2) / 2(\varepsilon_1 + \varepsilon_2 + \varepsilon_3) \quad (15)$$

式中, $\varepsilon_1, \varepsilon_2$ 与 ε_3 为各尺度模型误差。

其中, 根据表 3 的 ACC 指标, 可求得各尺度模型的误差分别为 3.09%, 5.68%, 8.57%。最终多尺度模型融合计算公式为

$$L = 0.41L_{0.5} + 0.34L_1 + 0.25L_2 \quad (16)$$

(2) 从隧道施工安全角度出发, 制定特殊规则, 即当 0.5 m 尺度下模型预测标签为“4”(即“裂隙/溶腔”)时, 融合预测标签取“4”为最终标签。

最终解译效果如图 10 (g) 所示。显然, 对比各尺度模型预测结果, 多尺度模型融合可有效避免各尺度模型不足, 在保证预测精度的前提下整体预测效果大大提高。

4 平台开发与工程应用

4.1 平台构建及应用概况

为方便工程应用, 基于 Streamlit 轻量化开源工具开发数字钻探智能解译平台, 前端界面见图 11。

如图 11 所示, 该平台界面主要有 3 个功能区组成: 在“超前钻探信息录入”部分, 对当前钻探作业的基本信息及数据进行录入与上传; 在“原始钻探数据可视化”部分, 对原始钻探数据进行可视化展示; 在“数

据预处理及智能解译”部分, 对上传的原始钻探数据进行预处理、自动解译以及解译结果可视化等操作。



图 11 数字钻探智能解译平台界面

Fig. 11 Platform of intelligent interpretation

如图 3 所示, 该技术及其平台在应用过程中, 遵循以下步骤: ①现场超前钻探作业, 获取原始钻探数据; ②导入平台自动进行数据预处理以及解译; ③技术人员参照解译评价结果, 撰写钻探成果报告; ④技术人员对解译有误数据进行校正与提取, 并添加到平台后端数据集; ⑤根据新的数据集进行模型学习与迭代优化, 不断提高模型的适用性与鲁棒性。

4.2 具体工程应用

目前, 上述技术及平台已在多条隧道的超前钻探地质预报服务中进行了应用。选取百宝隧道以及龙湾 2 号隧道的部分应用成果进行工程应用说明, 具体如表 4 所示。

由表 4 可知: 在实际工程应用中, 结合实际开挖揭露的真实岩体完整性情况, 对比超前地质雷达解译结果、钻探常规解译与本文自动解译可知, 多尺度模型融合的智能解译结果在 4 类岩体完整性预报满足较高准确度的条件下, 可提供较为详尽的预报解译信息,

表4 隧道工程技术应用统计表(部分)

Table 4 Statistics of technological applications in tunnels (part)

隧道及岩性	掌子面及超前钻探预报里程	地质雷达结论	超前钻探解译			实际揭露岩体完整性情况
			孔号	常规人工解译	多尺度模型融合自动解译	
百宝隧道(砂岩)	 ZK28+765—ZK28+735	该里程段岩体较破碎, 节理裂隙较发育, 层理较发育, 结合差	1	(1) 整体为较破碎	(1) 较完整—较破碎, 分别占比 55.56%与 44.44%	总体较完整—较破碎, 其中 26~27 m 发育有薄层状软弱夹层
			2	(1) 整体为较破碎 (2) 26~28 m 疑似发育有波层状软弱夹层	(1) 较完整—较破碎, 分别占比 77.59%与 20.69% (2) 26.5~27 m 疑似发育有薄层状软弱夹层	
龙湾2号隧道(灰岩)	 ZK343+825—ZK343+801	该里程段围岩岩体破碎, 结构面夹泥, 溶蚀裂隙发育, 发育有泥质填充型溶洞	1	(1) 1~11 m 疑似发育泥质填充型溶洞 (2) 12~24 m 较破碎	(1) 1.5~4 m、5~11 m 疑似发育泥质填充型溶洞, 4~5 m 为破碎岩体 (2) 12~24 m 总体较完整—较破碎, 分别占比 20.83%与 41.67%	1~11 m 为较破碎—破碎, 11~22 m 为较完整—较破碎, 其中 1.5 m 附近发育有薄层溶蚀裂隙, 2~10 m 密集发育泥质填充溶洞, 且溶洞规模较大
			2	(1) 1~12 m 整体破碎, 其中 5~8 m 疑似发育有泥质填充溶洞 (2) 13~22 m 较完整—较破碎	(1) 1~12 m 整体破碎, 其中 2~2.5 m 疑似发育有薄层状裂隙/空腔, 5~7.5 m 疑似发育有泥质填充溶洞 (2) 13~22 m 总体较完整—较破碎, 分别占比 43.04%与 28.70%	

包括各类岩体的位置信息与各孔钻探情况的统计信息, 这对提高超前钻探地质预报效率、更加全面掌握隧道掌子面前方岩体质量状况提供了有利工具。

5 结 论

针对目前超前钻探地质预报数据解译领域存在的诸多问题, 综合考虑预测精度与预报效果两个方面, 提出并实现了一种基于数字钻探与多尺度模型融合的隧道岩体完整性自动解译技术, 得到以下 3 点结论。

(1) 通过对原始钻探数据特点进行分析, 制定了包括多尺度(0.5, 1, 2 m)等距分割在内的多种降噪措施, 削弱异常值对原始钻探数据质量的影响。同时计算各分割段落内均值与方差作为二级指标实现高维特征提取以提高数据集质量, 为后续模型学习训练提供良好的数据基础。

(2) 配合 GA 算法解决了 XGBoost 建模过程中存在的复杂超参数寻优问题, 利用多项指标对各尺度模型进行了综合评估, 同时利用 SHAP 算法对模型可解释性进行论证。结果表明模型内在的预测逻辑与表现出的预测效果相一致, 且与工程实践的经验较吻合, 模型总体具备较高的准确性与可靠性。

(3) 针对各尺度模型在实际工程原始钻探数据上的表现, 提出一种基于误差倒数加权平均的多尺度模型融合方法以削弱各尺度模型缺点、优化预报效果、增强技术工程实用性, 并开发相应数字钻探智能解译平台。经实际工程应用表明, 本文所研究的多尺度模型融合解译技术在满足较高预报准确度的基本条件下, 可高效、便捷地提供更为详尽的地质预报信息。

参考文献:

[1] 李术才, 刘 斌, 孙怀风, 等. 隧道施工超前地质预报研究

现状及发展趋势[J]. 岩石力学与工程学报, 2014, 33(6): 1090-1113. (LI Shucui, LIU Bin, SUN Huaifeng, et al. State of art and trends of advanced geological prediction in tunnel construction[J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(6): 1090-1113. (in Chinese))

- [2] 晏 军. 岩溶隧道超前地质预报几种主要物探方法的选择与实践[J]. 隧道建设(中英文), 2020, 40(增刊 1): 327-336. (YAN Jun. Selection and application of several main geophysical methods for advanced geological prediction of Karst tunnels[J]. Tunnel Construction, 2020, 40(S1): 327-336. (in Chinese))
- [3] 周 轮, 李术才, 许振浩, 等. 隧道综合超前地质预报技术及其工程应用[J]. 山东大学学报(工学版), 2017, 47(2): 55-62. (ZHOU Lun, LI Shucui, XU Zhenhao, et al. Integrated advanced geological prediction technology of tunnel and its engineering application[J]. Journal of Shandong University (Engineering Science), 2017, 47(2): 55-62. (in Chinese))
- [4] 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. (YUE Zhongqi. Drilling process monitoring for refining and upgrading rock mass quality classification methods[J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(10): 1977-1996. (in Chinese))
- [5] PFISTER P. Recording drilling parameters in ground engineering[J]. Ground Engineering, 1985, 18(3): 16-21.
- [6] GUI M, SOGA K, Bolton, et al. Instrumented borehole drilling using ENPASOL system Field Measurements of Geomechanics, 1999.
- [7] WANG Q, GAO H K, JIANG B, et al. In-situ test and bolt-grouting design evaluation method of underground

- engineering based on digital drilling[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2021, **138**: 104575.
- [8] 梁栋才, 汤 华, 吴振君, 等. 基于多钻进参数和概率分类方法的地层识别研究[J]. *岩土力学*, 2022, **43**(4): 1123-1134. (LIANG Dongcai, TANG Hua, WU Zhenjun, et al. Stratum identification based on multiple drilling parameters and probability classification[J]. *Rock and Soil Mechanics*, 2022, **43**(4): 1123-1134. (in Chinese))
- [9] SCHUNNESSON H, FALKSUND H, GUSTAFSON A, et al. Assessment of rock mass quality using drill monitoring technique for hydraulic ITH drills[J]. *International Journal of Mining and Mineral Engineering*, 2017, **8**(3): 169.
- [10] ELDERT J, SCHUNNESSON H, JOHANSSON D, et al. Application of measurement while drilling technology to predict rock mass quality and rock support for tunnelling[J]. *Rock Mechanics and Rock Engineering*, 2020, **53**(3): 1349-1358.
- [11] WU Z J, WEI R L, CHU Z F, et al. Real-time rock mass condition prediction with TBM tunneling big data using a novel rock-machine mutual feedback perception method[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2021, **13**(6): 1311-1325.
- [12] 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. (FANG Yuwei, WU Zhenjun, SHENG Qian, et al. Intelligent recognition of tunnel stratum based on advanced drilling tests[J]. *Rock and Soil Mechanics*, 2020, **41**(7): 2494-2503. (in Chinese))
- [13] WANG M N, ZHAO S G, TONG J J, et al. Intelligent classification model of surrounding rock of tunnel using drilling and blasting method[J]. *Underground Space*, 2021, **6**(5): 539-550.
- [14] 王志坚. 郑万高铁隧道智能化建造技术研究及展望[J]. *隧道建设(中英文)*, 2021, **41**(11): 1877-1890. (WANG Zhijian. Status and prospect of intelligent construction technology of tunnel of Zhengzhou-wanzhou high-speed railway[J]. *Tunnel Construction*, 2021, **41**(11): 1877-1890. (in Chinese))
- [15] LI S C, LIU B, XU X J, et al. An overview of ahead geological prospecting in tunneling[J]. *Tunnelling and Underground Space Technology*, 2017, **63**: 69-94.
- [16] CHEN T Q, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, 2016.
- [17] 吴贤国, 陈 彬, 刘 琼, 等. 基于 LSSVM 和 NSGA-II 混凝土耐久性多目标配合比优化[J]. *隧道建设(中英文)*, 2020, **40**(12): 1691-1699. (WU Xianguo, CHEN Bin, LIU Qiong, et al. Optimization of multi-objective mix ratio for concrete durability based on LSSVM and NSGA-II [J]. *Tunnel Construction*, 2020, **40**(12): 1691-1699. (in Chinese))
- [18] LUNDBERG S, LEE S I. A unified approach to interpreting model predictions[EB/OL]. 2017: arXiv: 1705.07874. <https://arxiv.org/abs/1705.07874>
- [19] 公路隧道设计规范: JTG 3370.1—2018[S]. 北京: 人民交通出版社, 2018. (Specifications for Design of Highway Tunnels: JTG 3370.1 — 2018[S]. Beijing: China Communications Press, 2018. (in Chinese))
- [20] 梁 铭, 彭 浩, 解威威, 等. 基于超前钻探及优化集成算法的隧道围岩双层质量评价[J]. *隧道建设(中英文)*, 2022, **42**(8): 1443-1452. (LIANG Ming, PENG Hao, XIE Weiwei, et al. Double-layer quality evaluation of surrounding rock of a tunnel based on advance drilling and optimized integration algorithm[J]. *Tunnel Construction*, 2022, **42**(8): 1443-1452. (in Chinese))
- [21] 陈振宇, 刘金波, 李 晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. *电网技术*, 2020, **44**(2): 614-620. (CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. *Power System Technology*, 2020, **44**(2): 614-620. (in Chinese))