

DOI:10.11784/tdxbz202504008

深埋 TBM 隧道岩爆智能动态预警系统研发及工程实践

丰光亮¹, 陈靖文², 李邵军¹, 吝曼卿², 杨静熙³, 梁志强⁴

(1. 中国科学院武汉岩土力学研究所岩土力学与工程安全全国重点实验室, 武汉 430071;

2. 武汉工程大学资源与安全工程学院, 武汉 430074;

3. 中国电建集团成都勘测设计研究院有限公司, 成都 610072;

4. 中国水利水电第十四工程局有限公司, 昆明 650041)

摘要: 隧道掘进机(TBM)开挖的深埋隧道岩爆灾害频发, 对施工安全造成极大威胁. 针对深埋 TBM 隧道岩爆案例分散、预警模型固化和预警时效性不足等问题, 本研究集成多个 TBM 隧道工程岩爆案例、机器学习和智能算法, 自主研发了深埋 TBM 隧道岩爆智能动态预警系统. 系统构建了包含 TBM 隧道岩爆基本信息、地质特征及微震监测指标的专用岩爆数据库, 设计了项目及工区管理、岩爆案例和模型管理、预警结果管理等多个功能, 实现了不同 TBM 工程岩爆案例分区块存储、统一管理、多源数据动态整合和更新. 基于极致梯度提升(XGBoost)、贝叶斯优化(BO)和超参数带宽(Hb)优化构建了 TBM 隧道岩爆智能预警模型, 将准确率从基础 XGBoost 模型的 78.2%提升至 83.4%(BO-XGBoost 优化模型)和 84.0%(Hb-XGBoost 优化模型), 实现预警准确率的有效提升. 此外, 通过数据库岩爆案例调用和模型增量更新实现了预警模型动态更新机制, 系统响应时间控制在 30~60 min, 且更新过程不影响系统的使用, 这使得模型具备了持续学习的能力, 其预警效果将随案例的积累不断提升. 在中国西部某深埋 TBM 隧道的工程应用表明, 该系统相比传统预警方式, 有效提升了预警准确率和时效性, 具有显著的实用价值与预警效能. 研究成果可为深埋 TBM 隧道岩爆防控提供依据, 以期推动岩爆预警向自动化、智能化发展.

关键词: 深埋隧道; 隧道掘进机; 岩爆数据库; 岩爆预警; 系统研发

中图分类号: U452.28

文献标志码: A

文章编号: 0493-2137(2026)03-0273-13

Development and Engineering Practice of Intelligent Dynamic Early-Warning System for Rockbursts in Deep-Buried TBM Tunnels

Feng Guangliang¹, Chen Jingwen², Li Shaojun¹, Lin Manqing², Yang Jingxi³, Liang Zhiqiang⁴

(1. State Key Laboratory of Geomechanics and Geotechnical Engineering Safety, Institute of Rock and Soil Mechanics, Chinese Academy of Sciences, Wuhan 430071, China;

2. School of Resources and Safety Engineering, Wuhan Institute of Technology, Wuhan 430074, China;

3. PowerChina Chengdu Engineering Co., Ltd., Chengdu 610072, China;

4. Sinohydro Bureau 14 Co., Ltd., Kunming 650041, China)

Abstract: Rockbursts occur frequently in deep-buried tunnels excavated by tunnel boring machines (TBMs), posing a significant threat to construction safety. To address the issues such as scattered rockburst cases in deep-buried TBM tunnels, fixed early-warning models and insufficient early-warning timeliness, multiple rockburst cases from TBM tunnel projects, machine learning and intelligent algorithms are integrated to develop a deep-buried TBM tunnel rockburst intelligent dynamic early-warning system. This system establishes a specialized rockburst database, which includes the basic information, geological characteristics and microseismic monitoring indexes for TBM tunnel rockbursts. It features multiple functions such as project and work area management, rockburst cases and model manage-

收稿日期: 2025-04-08; 修回日期: 2025-09-26.

作者简介: 丰光亮 (1987—), 男, 博士, 研究员.

通信作者: 丰光亮, glfeng@whrsm.ac.cn.

基金项目: 国家自然科学基金资助项目(52422906); 湖北省杰出青年基金资助项目(2024AFA068).

Supported by the National Natural Science Foundation of China (No. 52422906), the Science Foundation for Distinguished Young Scholars of Hubei (No. 2024AFA068).

ment, and early-warning result management, enabling block storage, unified management, and dynamic integration and updates of multi-source data for different TBM engineering rockburst cases. An intelligent early-warning model for TBM tunnel rockbursts is constructed using extreme gradient boosting (XGBoost), Bayesian optimization (BO), and Hyperband (Hb) optimization. The accuracy rate is improved from 78.2% for the basic XGBoost model to 83.4% for the BO-XGBoost optimized model and 84.0% for the Hb-XGBoost optimized model, achieving a significant improvement in early-warning accuracy. Additionally, the system implements a dynamic update mechanism for the early-warning model through the invocation of rockburst cases from the database and incremental model updates. The system's response time is controlled within 30—60 min, and the update process does not affect the system usage. This endows the model with the capability of continual learning, enabling its early-warning performance to improve progressively with the accumulation of cases. The application of this system in a deep-buried TBM tunnel in western China demonstrates that, compared with the traditional early-warning methods, the system significantly improves both the accuracy rate and timeliness, showing remarkable practical value and early-warning effectiveness. The research findings in this paper can provide a basis for rockburst prevention and control in deep-buried TBM tunnels, aiming to promote the automation and intelligence of rockburst early-warning systems.

Keywords: deep-buried tunnel; tunnel boring machine (TBM); rockburst database; rockburst early-warning; system development

随着中国城市化进程的加速和对交通运输需求的持续增长,铁路、公路和水利等基础设施建设逐渐向深部发展。相比于浅部,深部工程通常需要应对更复杂的地质条件,如软弱地层、高地温、高地应力等,这加剧了深埋隧道工程灾害的发生频率和破坏性,严重影响施工人员的生命安全和工程进度。岩爆作为岩体中聚集的高弹性应变能突然释放的动力现象,具有很强的突发性、随机性和危害性^[1-2]。实施岩爆预警对确保施工洞段高效开挖和人员安全具有重大意义。深埋隧道主要开挖方法为隧道掘进机(tunnel boring machine, TBM)和钻爆法。近年来,随着中国 TBM 施工技术和自主研发水平的不断发展, TBM 隧道工程数量逐渐增多,如小直径 TBM 施工的云南那邦水电站引水隧洞、西藏旁多水利枢纽工程和陕西引红济石工程,以及大直径 TBM 施工的锦屏 II 级水电站隧洞和兰渝线西秦岭铁路隧道工程^[3]。在众多 TBM 隧道工程中,岩爆问题一直是重点和难点,例如:以锦屏 II 级水电站引水隧洞为典型代表的深埋 TBM 工程,在其施工过程中发生大量轻微、中等岩爆,局部开挖段伴随强烈、极强岩爆,严重阻碍工程进度;在巴基斯坦 Neelum-Jhelum (N-J) 水电工程施工期间曾发生极强岩爆,导致 TBM 系统的操作室、液压泵站、轨道等组件遭到不同程度的破坏^[4]。因此,实现 TBM 隧道岩爆及时准确预警已成为深部工程建设中的重要内容。

TBM 和钻爆法开挖隧道岩爆特征存在一定差异,主要体现在岩爆孕育过程、能量转化与释放等方面^[5-8]。岩爆预警应根据工程实际施工方法进行区分。目前针对 TBM 隧道岩爆预警已有一定的研究,

例如:冯夏庭等^[9]提出并总结了多种岩爆经验指标法和数值指标分析法,针对钻爆法和 TBM 法的岩爆类型分析了其适用性;李禹霏^[10]运用强度判据、能量判据和 BP 神经网络对雅鲁藏布江下游水电站某 TBM 施工洞段进行岩爆预警;Feng 等^[11]基于巴基斯坦 N-J 水电工程 58 个岩爆实例,提出 TBM 隧洞预警岩爆的 6 个微震(microseismic, MS)参数阈值,用于不同岩性条件下岩爆强度的分级预警,并验证了其有效性;Basnet 等^[12]通过特征选择提取 3 个关键微震参数并构建智能分类模型,提高了对西部某 TBM 铁路隧道岩爆风险的预测精度;马天辉等^[13]将锦屏二级水电站岩爆高发洞段作为研究对象,提出了微震事件密度云图、微震事件震级与频度关系、微震事件震级、能量及集中度等多个岩爆判据。

近年来,随着计算机技术的飞速发展,研究人员探索了不同人工智能技术与岩爆预警的融合。Li 等^[14]探讨了集成树对岩爆预警的影响,包括随机森林、极端随机树、自适应提升机、梯度提升机、极致梯度提升机、轻量梯度提升机和类别型特征提升机。Zhou 等^[15]集成了萤火虫算法和人工神经网络,拟合了隧道岩爆风险与其影响因素之间复杂的关系。杨玲等^[16]构建了一种结合麻雀搜索算法、支持向量机的预测准确率和自适应增强学习算法的岩爆等级预测模型,发现该模型的预测准确率比单一的支持向量机的预测准确率高出 31.25%。然而,受复杂的岩爆孕育环境及致灾机理等因素影响,预警效果仍未达到期望高度,其主要原因包括:现有深埋 TBM 隧道岩爆案例较分散,研究多集中在个例分析,缺乏丰富且具有针对性的 TBM 隧道岩爆数据集成;机器学习由于

其强大的数据挖掘和泛化能力而被广泛用于岩爆预警,然而随着工程推进,固定化模型不能及时反映数据的最新趋势;TBM 每日开挖效率高且岩爆风险变化剧烈,随着岩爆监测数据的增多,依赖专业人员实施岩爆预警将影响其时效性。

为了推动深埋 TBM 隧道岩爆预警学科的发展,进一步提升岩爆预警效果,本文基于国内外多个 TBM 工程实例和理论算法,研发了深埋 TBM 隧道岩爆智能动态预警系统,实现了项目、工区、标段和隧道区块化存储、统一管理和数据动态更新。在此基础上,建立了基于机器学习的岩爆智能预警模型,将两种调优方法应用于模型性能提升,通过数据调用和增量更新实现预警模型的动态更新,提高了岩爆预警的准确率和时效性。将该系统应用于中国西部某深埋 TBM 隧道工程,验证了预警模型和动态更新机制的可靠性与必要性。

1 深埋 TBM 隧道岩爆智能动态预警系统

受地质、开挖扰动等多种因素影响,岩爆的机制复杂且种类繁多,往往需要丰富的岩爆案例和指标以

建立可靠的预警方法。由于单一工程岩爆数据的稀缺性,岩爆复杂的模式和特征难以识别,进而影响岩爆预警的准确率,这种现象在区分了施工方法后更为明显。随着深埋 TBM 工程的不断实施,同一工程中工区、标段和隧道数量的逐渐增多也将使岩爆案例统计更加繁琐。为此,有必要建立一个涵盖丰富岩爆案例和指标的数据库,将数据库嵌入系统以实现不同工程岩爆数据的分区块存储和动态更新,从而提高岩爆案例查询、统计和分析的效率。

1.1 数据库基本内容

为满足数据库基本功能和岩爆预警需求,将数据库设计为 3 个主要组成部分,即岩爆基本信息数据、岩爆地质及微震指标数据、岩爆预警模型信息数据,如图 1 所示。图 1 中岩爆基本信息数据主要用于组织化管理岩爆案例、TBM 各项参数及预警结果,以供资源分配和数据调用;岩爆地质及微震指标数据是预警研究的基础,所列指标尽可能包含全面的岩爆孕育信息,并且考虑了工程现场数据获取的难易程度;岩爆预警模型信息数据是实施预警的关键,包含模型名称、创建时间、模型建立及更新所使用的数据和模型预警准确率等信息,便于对模型更改、管理和使用。

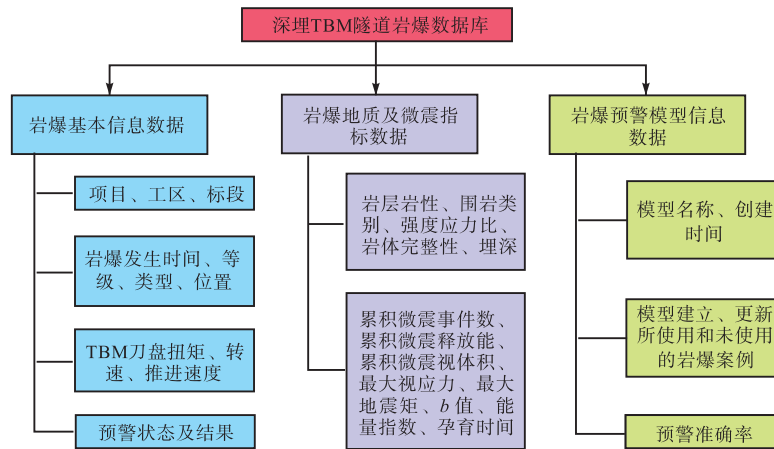


图 1 深埋 TBM 隧道岩爆数据库主要构成部分

Fig.1 Main parts of rockburst database of deep-buried TBM tunnel

基于图 1 中数据库的组成部分,设计了数据库主要功能模块,包含项目及工区管理、岩爆数据管理、预警模型管理、预警结果管理和数据云同步等。

(1) 项目及工区管理:提供可选择的省份、城市及区县菜单列表新建工程;根据具体工程添加、编辑和备注工区;导出项目及工区的基本信息。

(2) 岩爆数据管理:基于对应的项目、工区、标段或隧道,可以手动录入或批量导入岩爆数据;数据库中所有岩爆数据可供查询、分类、更改和导出。

(3) 预警模型管理:可以使用数据库中的岩爆案

例新建或更新模型,并提供可查询的模型名称、创建时间、数据使用情况和预警效果信息。

(4) 预警结果管理:基于具体预警模型和工区中新添加的岩爆监测数据,可实施岩爆预警;在预警结果与工程现场实际岩爆发生情况对比后,通过人工选择是否将新岩爆信息导入数据库。

(5) 数据云同步:所有数据信息存储在云服务器中,可以不限区域和时间登录服务器,实现数据共享和快捷导出,同时保证数据安全。


数据库的实现引入了 3 项关键技术:首先是高性

能数据写入,通过 SQL Server 内存优化表消除锁竞争,采用批量提交策略和异步持久化机制,将写入延迟控制在 5 ms 以内;其次为智能查询优化,建立时空联合索引(B-Tree 时间索引与 R-Tree 空间索引),开发动态物化视图自动预计算常用统计指标,并实现复杂查询的自动并行化处理;最后是全链路可靠性保障,部署 Always On 可用性组实现自动故障转移(恢复时间目标小于 30 s),建立包含完整备份、差异备份和日志备份的 3 级备份体系,支持从数据库级到事务级的精细恢复。


1.2 系统整体架构

基于 Java 语言开发了深埋 TBM 隧道岩爆智能动态预警系统,系统架构主要包含数据层、应用层、安全层、网络层和用户层等:数据层定义了数据的结构,包括表、索引及视图等,提供了数据创建、读取和更新等基本的数据管理操作;应用层主要实现岩爆预警模型与数据库交互的接口,以执行复杂的分析操作;安全层和网络层控制对数据的访问权限和数据传输加密,有利于保护工程数据安全;用户层主要通过图形化的方式展示数据,以更加直观地体现岩爆统计信息和预警情况,其部分展示效果如图 2 所示。基于上述结构将数据信息部署在云服务器中,以提高数据共享效率并降低信息存储成本。

深埋 TBM 隧道岩爆智能动态预警系统主要包含项目管理、预警模型管理、预警结果管理这 3 个动态更新结构,如图 3 所示。图 3 中项目管理可基于项目成立、结束时间、城市、区域及负责人等新增或修改项目,界面见图 4(a);进一步可将某具体项目划分为工区、标段和隧道,实现岩爆数据的分区块存储、统一管理和动态更新,见图 4(b)和(c)。预警模型



(a) 某隧道岩爆统计



(b) 某次岩爆预警情况

图 2 系统图形界面示例

Fig.2 Example of system graphical interface

管理主要利用所有项目已统计的岩爆案例建立或更新预警模型,并保存模型基本信息和预警效果,这一过程实现了数据流动,确保所有项目、工区、标段和隧道中新增或修改的岩爆案例可实时传递于模型。预警结果管理基于现场监测的岩爆孕育信息,使用已建立或更新后的模型实施岩爆预警,预警结果单独存放,通过人工选择将其导入对应工区、标段和隧道的数据库中,从而完成整个系统岩爆案例的动态更新。

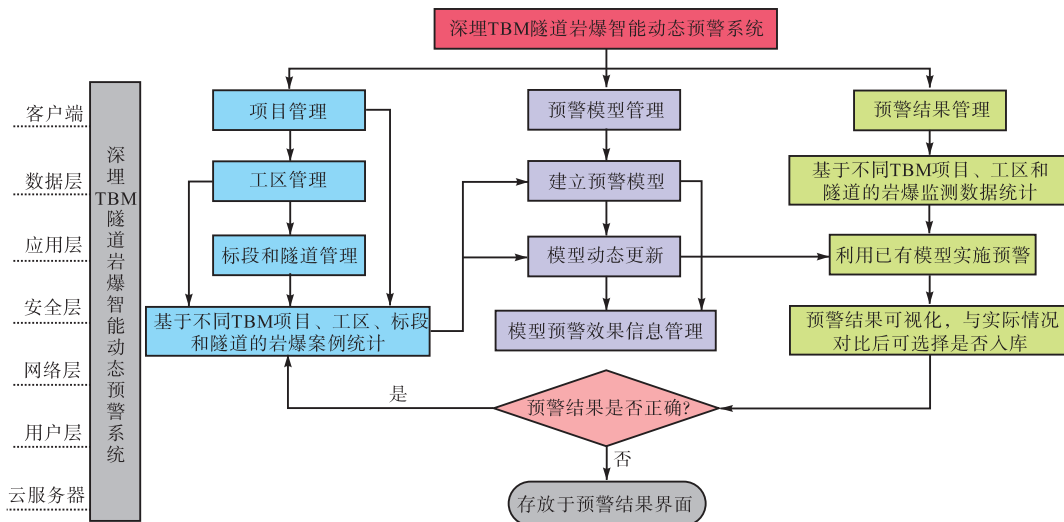


图 3 深埋 TBM 隧道岩爆智能动态预警系统基本结构

Fig.3 Basic structure of intelligent dynamic early-warning system for rockbursts in deep-buried TBM tunnels

<input type="checkbox"/>	序号	项目名称	成立时间	结束时间	是否有效	项目状态	省份	城市	区域	负责人	项目介绍标题
<input type="checkbox"/>	11	1号项目			是	—	西藏自治区	—	—	—	
<input type="checkbox"/>	12	2号项目			是	—	西藏自治区	—	—	—	

(a) 项目管理界面

工区名称

工区名称	创建时间	最新修改时间	说明	操作
▼ 项 X工区	2024-04-16 10:58:44	2024-09-22 13:55:34		<input type="button" value="添加标段"/> <input type="button" value="编辑"/> <input type="button" value="删除"/>
▼ 标 X标段	2024-04-16 10:58:54	2024-09-22 13:55:38		<input type="button" value="添加子级"/> <input type="button" value="编辑"/> <input type="button" value="删除"/>
隧 X隧道	2024-04-16 10:59:05	2024-09-19 15:24:36		<input type="button" value="编辑"/> <input type="button" value="删除"/>

(b) 工区、标段和隧道编辑界面

工区分布 案例库

搜索... 岩爆等级 请选择 事件名称

案例
当前选中: X工区 > X标段 > X隧道, 施工方法: TBM, 风险范围为掌子面里程坐标前后20 m范围。

序号	开挖方式	累积微震事件数	累积微震释放能	累积微震视体积	操作
1	TBM	5	66 273.51	24 543.312 5	<input type="button" value="编辑"/> <input type="button" value="删除"/>
2	TBM	21	225 582.62	1 580 918.181 0	<input type="button" value="编辑"/> <input type="button" value="删除"/>
3	TBM	24	688 833.77	342 549.985 0	<input type="button" value="编辑"/> <input type="button" value="删除"/>
4	TBM	41	1 078 808.90	1 073 057.010 0	<input type="button" value="编辑"/> <input type="button" value="删除"/>

(c) 工区、标段和隧道岩爆数据分块存储界面

图 4 项目及工区等信息编辑界面

Fig.4 Editing interfaces of information about project, work area, etc

2 基于机器学习的岩爆智能动态预警模型

2.1 预警指标体系

高强度脆性岩石和高应力环境是岩爆的 2 个必要条件^[17]. 为确保预警指标能够直接或间接反映岩体条件和应力环境, 从数据库中选取了 2 个地质指标、5 个微震指标和 2 个施工指标, 构建了融合地质、微震和施工信息的多因素岩爆预警指标体系, 如表 1 所示. 围岩的性质和所处应力环境很大程度上决定了是否会发生岩爆, 硬脆性围岩在高应力环境下极易发生岩爆. 为表征围岩的完整程度和围岩应力环境, 选取岩体完整性系数和强度应力比作为地质指标^[18]. 微震监测是对岩石微裂纹引发的微震事件进行三维监测, 可以有效捕捉岩石断裂过程中释放的微震波, 分析微震波数据得到的震源参数反映了岩体在应力场作用下的力学响应特性^[19]. 目前常用的震源参数包括微震事件数、微震释放能、视体积、视应力和地震矩等, 可表征岩体微破裂事件的各种相关信息^[20-22]. 为了在预测某区域一段时间内所有微震活动的同时使微震指标与 TBM 开挖工序的时间尺度相匹配, 震源参数取每日 TBM 监测数据的累积值或最大值. TBM 施工属于动态扰动, 涉及刀盘切削和振动等多个因素, 这种动态效应与岩爆的耦合作用尚未被完全

解释, 为了准确体现 TBM 施工扰动的频率和幅度, 进而反映其对岩爆的影响, 选取 TBM 日平均推进速度和日平均刀盘转速作为施工指标.

表 1 岩爆预警指标相关公式及含义

Tab.1 Relevant formulas and meaning of rockburst early-warning indexes

指标名称	表达式	注释
强度应力比 δ	$\delta = \frac{\sigma_c}{\sigma_1}$	σ_c 为岩石的抗压强度; σ_1 为岩体最大主应力值
岩体完整性系数 K_v	$K_v = \left(\frac{V_m}{V_r}\right)^2$	V_m 为岩体纵波速度值; V_r 为室内岩石(块)纵波速度值
累积微震事件数 N	$N = \sum_{i=1}^n N_i$	N_i 为岩体微破裂产生弹性波的次数
累积微震释放能 E	$E_i = \frac{8}{5} \pi \rho v R^2 \int_0^{t_i} \mu^2(t) dt$ $E = E_1 + E_2 + \dots + E_i$	E_i 为单次微震释放能; ρ 为岩石密度; v 为纵波或横波速度值; R 为震源距离; t_i 为震动时间; $\mu(t)$ 为远场速度脉冲函数
累积微震视体积 V_A	$V_i = \frac{\mu P^2}{E_i}$ $V_A = V_1 + V_2 + \dots + V_n$	V_i 为单次微震视体积; μ 为岩石的剪切模量; P 为微震体变势
最大视应力 A	$A = \max\left(\frac{\mu E_i}{M_0}\right)$	M_0 为地震矩的大小
最大地震矩 M	$M = \max(\mu DS)$	D 为断层面的平均位错量; S 为断层面面积
平均推进速度值 T	—	TBM 在单位时间内向前推进的平均线性距离
平均刀盘转速值 D_r	—	刀盘围绕其轴心旋转时产生的扭矩

2.2 智能预警模型

岩爆多源预警指标数据属于标准的表格型数据, 梯度提升决策树 (gradient boosting decision tree, GBDT) 通过结合多个决策树能够灵活、高效地处理表格型数据中高维特征和复杂的非线性关系. GBDT 是一种基于加法模型和前向分步算法的梯度提升方法, 其核心思想是通过逐步优化损失函数的负梯度来构建模型^[23]. GBDT 的基本结构如图 5 所示, 其中节点的分布呈现阶梯状, 表示多个不同层次的决策树在每一层的输出结果, 节点颜色表示不同的类别或预测值; 每棵决策树都对模型的最终输出做出贡献, 一般通过投票或加权平均的方式综合各棵树的预测结果.




图 5 GBDT 的基本结构
Fig.5 Basic structure of GBDT

GBDT 的计算过程如下.

(1) 确定加法模型.

GBDT 的预测结果是多个弱学习器 (决策树) 的加权和, 即

$$F(x; \{\beta_m, \alpha_m\}_1^{\bar{M}}) = \sum_{m=1}^{\bar{M}} \beta_m h(x; \alpha_m) \quad (1)$$

式中: $F(x)$ 为多个基学习器的加权组合; \bar{M} 为基学习器的总数; $h(x; \alpha_m)$ 为决策树; α_m 为模型参数; β_m 为第 m 个基学习器的权重系数.

(2) 损失函数优化.

$\{\beta_m, \alpha_m\}$ 通过最小化损失函数 L 学习, 即

$$\min_{\{\beta_m, \alpha_m\}} \sum_{i=1}^N L \left(y_i, \sum_{m=1}^{\bar{M}} \beta_m h(x_i; \alpha_m) \right) \quad (2)$$

为得到式 (1) 的最优解, 基于式 (2) 采用前向分布算法逐步添加基学习器, 每步仅优化当前决策树 $h(x; \alpha_m)$ 和权重 β_m , 即

$$\arg \min_{\beta, \alpha} \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + \beta h(x_i; \alpha)) \quad (3)$$

(3) 计算损失函数的负梯度.

用 $g_m(x)$ 表示当前模型 $F_{m-1}(x)$ 的预测值与真实值间的残差方向, 即

$$g_m(x) = \left[-\frac{\partial \varphi(F(x))}{\partial F(x)} \right]_{F(x)=F_{m-1}(x)} \quad (4)$$

式中 $\varphi(F(x))$ 为损失函数.

(4) 拟合残差.

由于每一个 $h(x; \alpha_m)$ 都建立在残差方向, 基于式

(5) 拟合残差, 即

$$\alpha_m = \arg \min_{\alpha} \sum_{i=1}^N [g_m(x_i) - h(x_i; \alpha)]^2 \quad (5)$$

(5) 得到基学习器的权重.

基于线搜索确定权重 β_m , 即

$$\beta_m = \arg \min_{\beta} \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + \beta h(x_i; \alpha_m)) \quad (6)$$

(6) 更新模型.

最后, 通过式 (7) 更新模型, 即

$$F_m(x) = F_{m-1}(x) + \beta_m h_m(x; \alpha_m) \quad (7)$$

极致梯度提升 (extreme gradient boosting, XGBoost) 是对 GBDT 算法的改进^[24]. XGBoost 引入正则化和二阶梯度近似, 平衡了模型精度与效率, 更适合处理岩爆预警等中小型数据量任务, 其基本架构如图 6 所示. 图 6 中多个基分类器 $\{f_1(x_i), f_2(x_i), \dots, f_N(x_i)\}$ 表示多个单独的模型, 根据先前模型的残差按顺序进行训练; 当基分类器训练完成后, 将通过识别偏差修正模型预测, 基于参数调整改善预测结果; 最终, 合并所有基分类器的预测结果, 完成 XGBoost 训练. 对于多分类任务, XGBoost 为每个岩爆等级生成一个对数几率, 通过 softmax 函数将决策树的输出转换为不同岩爆等级的概率.

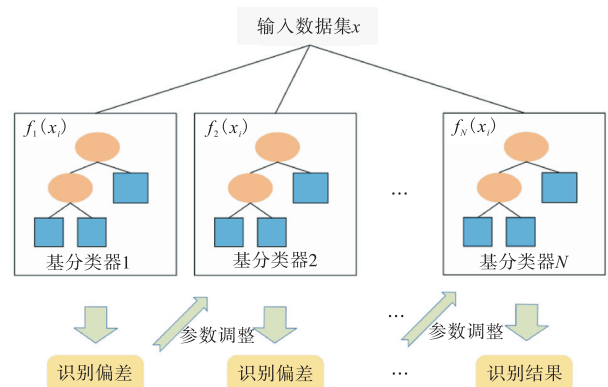


图 6 XGBoost 模型架构
Fig.6 Architecture of XGBoost model

为充分发挥 XGBoost 性能, 通过调优搜寻模型的最佳超参数组合, 包括定义调节空间、选择优化算法、评估优化过程和选择最佳超参数组合共 4 个阶段.

阶段 1 定义调节空间.

据统计, XGBoost 共有 63 种超参数, 由于调节

所有超参数将极大降低模型优化效率且部分超参数对模型实际影响较小,因此仅选取重要超参数建立调节空间并设置相应调节范围,如表 2 所示。

表 2 对 XGBoost 影响较大的 9 种超参数

Tab.2 Nine hyperparameters that have a significant impact on XGBoost

超参数名称	调节范围	说明
eta	$[1 \times 10^{-4}, 1]$	缩小或放大最终的预测
nrounds	$[1, 300]$	控制模型迭代次数
subsample	$[0.1, 1]$	将更多随机性引入到训练中
colsample_bytree	$[0.1, 1]$	控制每个决策树使用特征的比例
max_depth	$[1, 20]$	控制决策树在训练过程中可能达到的最大层数
alpha	$[1 \times 10^{-3}, 1 \times 10^3]$	调节各特征的权重
lambda	$[1 \times 10^{-3}, 1 \times 10^3]$	控制模型复杂度
gamma	$[1 \times 10^{-3}, 1 \times 10^3]$	决定一个叶节点是否进一步分割
min_child_weight	$[1 \times 10^{-3}, 1 \times 10^3]$	为每个节点中继续分割的最小实例数设置阈值

阶段 2 选择优化算法。

大多数优化算法如贝叶斯优化 (Bayesian optimization, BO)^[25]、协方差矩阵自适应调整的进化策略 (covariance matrix adaptation evolution strategy, CMA-ES)^[26] 和多保真优化 (multi-fidelity optimization, MFO)^[27] 等采用迭代技术, 以在调节空间中寻找可能最优的超参数配置。BO 算法^[25] 基于代理模型近似待优化的未知函数, 是从调节空间到泛化性能估计的映射。CMA-ES 算法^[26] 是一种进化策略, 通过均值向量和协方差矩阵表示候选点的概率分布, 并从该分布中采样生成一组新的候选点, 每个候选点的概率与其性能成比例。MFO 算法^[27] 利用计算成本较低的低保真度评估 (即质量较差的预测) 提高整体优化效率, 动态地为性能较高的配置分配越来越多的资源, 并终止表现不佳的配置。由于 CMA-ES 在局部精细化搜索上的表现较差且只能依赖高保真度评估, 考虑到所使用的调节空间较大且结构复杂, 为了在合理的时间内全面评估整个调节空间, 选取 BO 和 MFO 优化 XGBoost 模型。

阶段 3 评估优化过程。

将高斯过程和随机森林这两种典型学习器作为 BO 的代理模型, 引入期望改进作为代理模型的采集函数, 即

$$\alpha_{ei}(x) = E[\max(f_{\min} - Y(x), 0)] \quad (8)$$

式中: $\alpha_{ei}(x)$ 为采集函数; f_{\min} 为观测的最佳函数值; $Y(x)$ 为给定点 x 代理模型的预测值。

基于无导数优化的 DIRECT 法^[28] 和基于梯度优

化的 StoGO 法^[29] 这两种全局优化技术对采集函数进行调整, 得到不同优化器-代理模型的迭代结果, 如图 7 所示。BO 成功学习了每一次迭代中配置超参数的经验, 当使用 StoGO 法作为函数优化器和随机森林作为代理模型时, 模型错误率能在规定的迭代次数内达到最低。

MFO 算法将优化过程视为一种在给定资源 (迭代次数、树的数量等) 下的调节过程, 一种常见的 MFO 算法为超参数带宽 (hyperband, Hb) 优化算法^[30], 通过将不同预算进行分组以优化调节空间。由表 2 中 nrounds 的调节范围设置最大和最小预算分别为 256 和 16, 总分组数经计算得出, 即

$$s_{\max} = \log_{\eta} \frac{r_{\max}}{r_{\min}} + 1 \quad (9)$$

式中: s_{\max} 为总分组数; η 为每个阶段丢弃的配置比例; r_{\min} 和 r_{\max} 分别为单个超参数组合实际所能分配的最小预算和最大预算。




图 7 基于不同优化器-代理模型的迭代结果

Fig.7 Iteration results based on different optimizer-agent models

Hb 优化算法的最终结果见图 8。调整结束时, 最佳超参数配置是在所有分组中模型错误率最低的配置, 当预算为 256 时, Hb 优化算法发现了使模型错误率最低的超参数组合。




图 8 不同预算下的迭代结果

Fig.8 Iteration results under different budgets

阶段 4 选择最佳超参数组合。

在给定的调节空间内, 两种算法经过一定次数的

迭代后均使模型错误率降低至 15% 以下, 基于 BO 算法和 Hb 优化算法的模型调优结果见表 3.

表 3 基于 BO 算法和 Hb 优化算法的模型调优结果

Tab.3 Model tuning results based on BO algorithm and Hb optimization algorithm

超参数名称	BO 算法调节最优值	Hb 优化算法调节最优值
eta	0.000 518	0.046 700
nrounds	218	256
subsample	0.675	0.697
colsample_bytree	0.503	0.423
max_depth	13	15
alpha	0.015 00	0.002 78
lambda	0.024 8	0.075 2
gamma	0.438 0	0.041 2
min_child_weight	0.145 00	0.002 39

2.3 模型评估及动态更新

使用 5 次重复的 4 折交叉验证评估模型的泛化性能, 如图 9 所示. 基于表 1 的预警指标信息, 在数据库中任取 76 个岩爆案例, 构建 XGBoost 模型、BO 优化模型和 Hb 优化模型, 混淆矩阵如图 10 所示, 其中准确率(A_{CC})量化了模型性能, 其表达式为

$$A_{CC}(f, D') = \frac{1}{n'} \sum_{i=1}^{n'} \mathbb{I}(f(x_i) = y_i) \quad (10)$$

式中: f 为使用的机器学习算法; D' 为输入数据; n' 为输入数据的总量; $\mathbb{I}(f(x_i) = y_i)$ 为指示函数, 当 $f(x_i) = y_i$ 为真时取 1, 否则取 0.

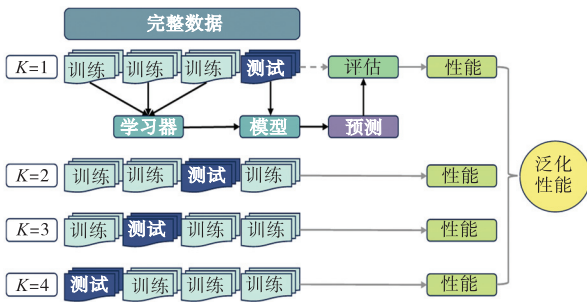


图 9 重复 4 折交叉验证

Fig.9 Repeated four-fold cross validation

XGBoost 基模型仅有 78.2% 的预警准确率, 经 BO 算法和 Hb 优化算法优化后准确率提高 5.0% 左右; BO 算法和 Hb 优化算法对模型的优化精度相似, 然而在迭代过程中, BO 算法的收敛速度慢于 Hb 优化算法的对应值, 随着模型复杂度的增加, BO 算法将消耗更多的计算资源.

随着工程的不断推进, 基于固定数据建立的岩爆预警模型难以及时反映数据的最新趋势. 为避免模型过拟合于旧数据, 有必要设计模型动态更新机制, 根据预设条件自动触发模型的再训练和部署. 将

预测类 \ 真实类	强烈岩爆	中等岩爆	轻微岩爆	无岩爆
强烈岩爆	20	0	0	0
中等岩爆	0	60	20	1
轻微岩爆	0	20	143	25
无岩爆	0	0	17	74

(a) 初始模型(准确率为 78.2%)

预测类 \ 真实类	强烈岩爆	中等岩爆	轻微岩爆	无岩爆
强烈岩爆	20	0	0	0
中等岩爆	0	67	9	0
轻微岩爆	0	13	154	24
无岩爆	0	0	17	76

(b) BO 优化模型(准确率为 83.4%)

预测类 \ 真实类	强烈岩爆	中等岩爆	轻微岩爆	无岩爆
强烈岩爆	20	0	0	0
中等岩爆	0	67	10	0
轻微岩爆	0	13	154	22
无岩爆	0	0	16	78

(c) Hb 优化模型(准确率为 84.0%)

图 10 初始模型及优化模型混淆矩阵预测效果

Fig.10 Prediction results of confusion matrix of original and optimization models

XGBoost 模型及优化算法嵌入在深埋 TBM 隧道岩爆智能动态预警系统, 建立了可操作式模型动态更新模块, 实现数据库中岩爆案例的调用和模型自适应训练, 如图 11 所示. 首先, 动态更新模块将岩爆数据库中的案例分割为两部分, 左侧为数据库新增的岩爆案例和模型未使用的岩爆案例, 右侧为模型构建过程中已使用的岩爆案例; 两部分岩爆案例可供实时选择和调用, 以剔除模型中质量较差的数据或添加新数据; 完成数据调用后, 可执行模型更新, 其响应时间范围

为 30~60 min,更新过程不影响系统其他功能使用,这使得模型具备了持续学习的能力,其预警效果将随

案例的积累不断提升;更新后,新模型将存储在模型信息界面,如图12所示.



图 11 模型动态更新界面

Fig.11 Dynamic update interface of model

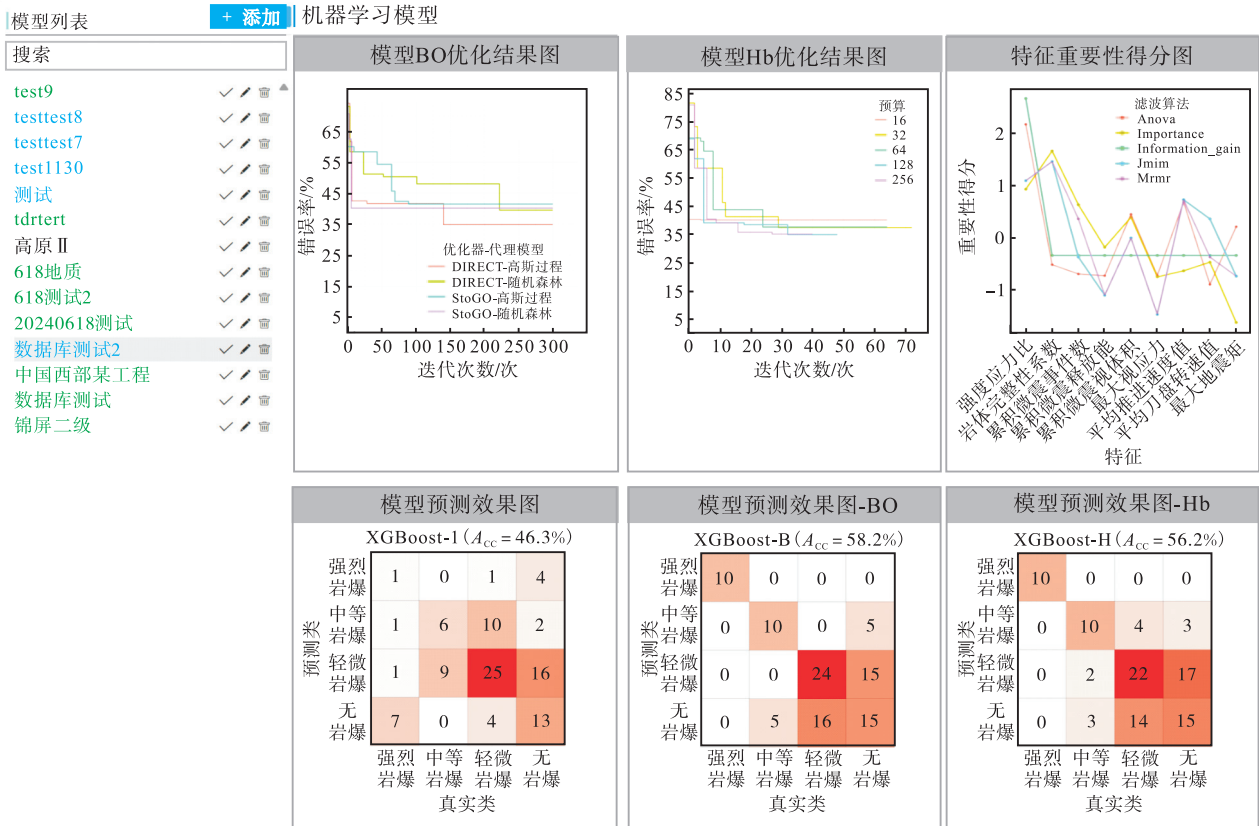


图 12 模型信息界面

Fig.12 Information interface of model

3 工程应用

3.1 工程概况

中国西部某深埋 TBM 隧道工程属于 I 级风险(极高风险)隧道,以高寒、高海拔、大高差和强烈的构造作用为典型地质背景,采用双线双洞 TBM 掘进施工,隧道内外动力地质作用十分强烈,高地应力岩爆灾害发育,给隧道的安全建设带来巨大的挑战. 图 13 为隧道开挖过程中发生的一例中等岩爆,导致隧底隆起、钢架变形.




图 13 中国西部某深埋 TBM 隧道工程现场某次中等岩爆
Fig.13 One moderate rockburst occurred at the site of a deep-buried TBM tunnel project in western China

3.2 岩爆智能预警实施

选用 2024 年的 3 个岩爆案例进行分析,包含无岩爆、轻微岩爆和中等岩爆各一例,现场监测情况见表 4.

依托数据库收集的锦屏 II 级水电站、川藏铁路和

巴基斯坦 N-J 水电站等国内外典型深埋 TBM 隧道工程岩爆案例,建立了两个岩爆预警模型. 第 1 个模型选择与 1 号案例对应日期前该隧道收集到的所有岩爆案例和其他深埋 TBM 工程岩爆案例,称其为模型 A;由于 3 号相比于 1 号和 2 号案例具有较大的时间跨度,为验证模型动态更新机制的有效性,第 2 个模型在模型 A 的基础上补充训练了与 3 号案例对应日期前的岩爆案例,专门用于 3 号预警案例,称其为模型 B. 基于选中的具体工区、标段和隧道,在岩爆预警界面添加了表 4 中 3 个岩爆监测信息,使用模型 A 实施岩爆预警. 系统在后台利用模型 A 计算各岩爆等级发生概率. 同理将模型 B 应用于 3 号案例,得到两模型的预警结果,汇总于表 5.

表 4 3 例岩爆现场监测情况

Tab.4 Three cases of rockburst monitored on site

案例编号	日期	信息描述	岩爆等级
1 号	2024-03-16	III 级围岩,出露岩性为花岗岩,节理裂隙较发育;累积微震事件数和释放能保持较低水平,无大能量微震事件发生	无岩爆
2 号	2024-03-18	III 级围岩,出露岩性为花岗岩,右边墙有剥落掉块现象;累积微震事件数和释放能保持较高水平,无大能量微震事件发生	轻微岩爆
3 号	2024-07-07	III 级围岩,出露岩性为花岗岩,护盾后方围岩较完整;大部分微震事件释放能保持中上水平,累积微震释放能保持较高水平	中等岩爆

表 5 模型 A 与 B 岩爆预警结果

Tab.5 Rockburst early-warning results based on Model A and Model B

模型类型	案例编号	日期	预警概率/%				预警等级	实际发生等级
			无岩爆	轻微岩爆	中等岩爆	强烈岩爆		
A	1 号	2024-03-16	35.3	28.0	18.4	18.3	无岩爆	无岩爆
	2 号	2024-03-18	24.3	39.5	19.1	17.1	轻微岩爆	轻微岩爆
	3 号	2024-07-07	17.5	21.0	28.3	33.2	强烈岩爆	中等岩爆
B	3 号	2024-07-07	17.2	18.5	34.7	29.6	中等岩爆	中等岩爆

对比表 5 中预警结果与现场实际情况可以发现,建立的两种岩爆预警模型均具有一定可靠性. 模型 A 成功预警了 1 号和 2 号案例,然而随着 TBM 推进,模型 A 并未对新岩爆案例进行增量学习,导致其在 3 号案例的预警中产生一定程度的误判. 相比于模型 A,模型 B 对近 4 个月岩爆案例进行再训练,成功完成 3 号案例的预警. 针对 3 号案例,模型 A 和 B 给出了不同的预警结果,模型 A 对中等岩爆和强烈岩爆的预警概率分别为 28.3% 和 33.2%,模型 B 的对应值分别为 34.7% 和 29.6%,可见执行动态更新后的模型 B 拟合了更多岩爆信息,优化了各预警指标的

权重,从而保证预警的可靠性. 此外,模型 A 的一次错判说明,随着工程推进,模型固化将不能及时反映数据的最新趋势,及时更新预警模型可以有效提高预警准确率.

将模型 B 应用于现场 2024-07-07—2024-08-07 岩爆预警,不同等级岩爆实际发生个数与预警正确个数如图 14 所示. 基于模型 B 得到岩爆预警准确率约为 84.4%,其中实际发生无岩爆 20 例,预警正确 17 例;实际发生轻微岩爆 9 例,预警正确 7 例;中等岩爆 3 例全部预警正确. 因此,基于 BO 算法、Hb 优化算法和动态更新构建的模型表现出较高的预警准确性.




图 14 2024-07-07—2024-08-07 岩爆预警效果

Fig.14 Rockburst early-warning results from 2024-07-07 to 2024-08-07

4 结 论

中国西部某深埋 TBM 隧道属于极高应力岩石地下工程, 以此为工程背景, 基于多源岩爆预警指标体系和岩爆实例, 开展岩爆智能动态预警系统设计和智能动态预警模型研究, 获得的主要结论如下。

(1) 研发了深埋 TBM 隧道岩爆智能动态预警系统, 包含岩爆基本信息数据、岩爆地质及微震指标数据、岩爆预警模型信息数据, 实现了不同 TBM 隧道岩爆数据集成、分区块存储和统一管理。

(2) 基于多源预警指标体系构建了 XGBoost 岩爆智能预警模型并对其实施优化, 发现 BO 算法和 Hb 优化算法两种自适应调优均提高了模型预警准确率, 且优化精度相似。然而, 在迭代过程中 BO 算法收敛速度较慢, 随着模型复杂度的增加, BO 算法将消耗更多计算资源。

(3) 实现了岩爆案例、预警模型和预警结果的动态更新, 使得预警系统时效性得到了增强, 预警效果得到了提升。将系统应用于中国西部某深埋 TBM 隧道工程, 发现随着工程的推进, 固定化模型不能及时反映数据的最新趋势, 而模型更新后成功识别了现场更多高等级岩爆实例, 验证了经过调优及动态更新的 XGBoost 模型具有较好的泛化性能。

参考文献:

- [1] 李天斌, 许韦豪, 马春驰, 等. 基于深度学习的隧道微震监测及岩爆预警技术与系统研究[J]. 岩石力学与工程学报, 2024, 43(5): 1041-1063.
Li Tianbin, Xu Weihao, Ma Chunchi, et al. Research of technology and system of tunnel microseismic monitoring and rockburst early warning based on deep learning[J]. Chinese Journal of Rock Mechanics and Engineering, 2024, 43(5): 1041-1063 (in Chinese).
- [2] 薛亚东, 董宏鑫, 李彦杰. 山岭公路隧道施工安全风险评估理论体系[J]. 天津大学学报(自然科学与工程技术版), 2019, 52(增1): 84-91.
Xue Yadong, Dong Hongxin, Li Yanjie. Theoretical system for the safety risk assessment of mountain tunnel construction[J]. Journal of Tianjin University (Science and Technology), 2019, 52(Suppl 1): 84-91 (in Chinese).
- [3] 杜立杰. 中国 TBM 施工技术进展、挑战及对策[J]. 隧道建设, 2017, 37(9): 1063-1075.
Du Lijie. Progress, challenges, and countermeasures for TBM construction technology in China[J]. Tunnel Construction, 2017, 37(9): 1063-1075 (in Chinese).
- [4] Feng G L, Ma J G, Chen B R, et al. Microseismic energy and intensity criterion of rockburst in deep TBM tunnels: A case study of the Neelum-Jhelum hydropower project[J]. Journal of Central South University, 2023, 30(5): 1695-1709.
- [5] Chen Y Y, Xiao P W, Li P, et al. Formation mechanism of rockburst in deep tunnel adjacent to faults: Implication from numerical simulation and microseismic monitoring[J]. Journal of Central South University, 2022, 29(12): 4035-4050.
- [6] 冯夏庭, 陈炳瑞, 明华军, 等. 深埋隧洞岩爆孕育规律与机制: 即时型岩爆[J]. 岩石力学与工程学报, 2012, 31(3): 433-444.
Feng Xiating, Chen Bingrui, Ming Huajun, et al. Evolution law and mechanism of rockbursts in deep tunnels: Immediate rockburst[J]. Chinese Journal of Rock Mechanics and Engineering, 2012, 31(3): 433-444 (in Chinese).
- [7] 于洋, 冯夏庭, 陈炳瑞, 等. 深埋隧洞不同开挖方式下即时型岩爆微震信息特征及能量分形研究[J]. 岩土力学, 2013, 34(9): 2622-2628.
Yu Yang, Feng Xiating, Chen Bingrui, et al. Analysis of energy fractal and microseismic information characteristics about immediate rockbursts in deep tunnels with different excavation methods[J]. Rock and Soil Mechanics, 2013, 34(9): 2622-2628 (in Chinese).
- [8] 钱波, 徐奴文, 肖培伟, 等. 双江口水电站地下厂房顶拱开挖围岩损伤分析及变形预警研究[J]. 岩石力

- 学与工程学报, 2019, 38(12): 2512-2524.
- Qian Bo, Xu Nuwen, Xiao Peiwei, et al. Damage analysis and deformation early-warning of surrounding rock mass during top arch excavation of underground powerhouse of Shuangjiangkou hydropower station[J]. Chinese Journal of Rock Mechanics and Engineering, 2019, 38(12): 2512-2524(in Chinese).
- [9] 冯夏庭, 肖亚勋, 丰光亮, 等. 岩爆孕育过程研究[J]. 岩石力学与工程学报, 2019, 38(4): 649-673.
- Feng Xiating, Xiao Yaxun, Feng Guangliang, et al. Study on the development process of rockbursts[J]. Chinese Journal of Rock Mechanics and Engineering, 2019, 38(4): 649-673(in Chinese).
- [10] 李禹霏. 高原深埋 TBM 施工隧洞岩爆风险评估及对策研究[D]. 成都: 成都理工大学环境与土木工程学院, 2015.
- Li Yufei. Research on Risk Evaluation and Countermeasure of Rockburst in Deep Buried TBM Tunnel Constructed in Plateau Region[D]. Chengdu: College of Environment and Civil Engineering, Chengdu University of Technology, 2015(in Chinese).
- [11] Feng G L, Chen B R, Xiao Y X, et al. Microseismic characteristics of rockburst development in deep TBM tunnels with alternating soft-hard strata and application to rockburst warning: A case study of the Neelum-Jhelum hydropower project[J]. Tunnelling and Underground Space Technology, 2022, 122: 104398.
- [12] Basnet P M S, Feng G L, Jin A B, et al. Evaluating the rockburst potential in the railway tunnel after identifying the most significant microseismic inputs for the classifier using feature selection techniques[J]. Rock Mechanics and Rock Engineering, 2025, 58: 13587-13612.
- [13] 马天辉, 唐春安, 唐烈先, 等. 基于微震监测技术的岩爆预测机制研究[J]. 岩石力学与工程学报, 2016, 35(3): 470-483.
- Ma Tianhui, Tang Chun'an, Tang Liexian, et al. Mechanism of rock burst forecasting based on microseismic monitoring technology[J]. Chinese Journal of Rock Mechanics and Engineering, 2016, 35(3): 470-483(in Chinese).
- [14] Li D Y, Liu Z D, Armaghani D J, et al. Novel ensemble intelligence methodologies for rockburst assessment in complex and variable environments[J]. Scientific Reports, 2022, 12: 1844.
- [15] Zhou J, Guo H Q, Koopialipour M, et al. Investigating the effective parameters on the risk levels of rockburst phenomena by developing a hybrid heuristic algorithm[J]. Engineering with Computers, 2021, 37: 1679-1694.
- [16] 杨玲, 魏静. 基于支持向量机和增强学习算法的岩爆烈度等级预测[J]. 地球科学, 2023, 48(5): 2011-2023.
- Yang Ling, Wei Jing. Prediction of rockburst intensity grade based on SVM and adaptive boosting algorithm[J]. Earth Science, 2023, 48(5): 2011-2023(in Chinese).
- [17] Miao S J, Cai M F, Guo Q F, et al. Rock burst prediction based on in-situ stress and energy accumulation theory[J]. International Journal of Rock Mechanics and Mining Sciences, 2016, 83: 86-94.
- [18] Liu X Q, Wang G, Song L B, et al. A new rockburst criterion of stress-strength ratio considering stress distribution of surrounding rock[J]. Bulletin of Engineering Geology and the Environment, 2023, 82(1): 29.
- [19] Feng G L, Feng X T, Chen B R, et al. A microseismic method for dynamic warning of rockburst development processes in tunnels[J]. Rock Mechanics and Rock Engineering, 2015, 48: 2061-2076.
- [20] Feng G L, Feng X T, Xiao Y X, et al. Characteristic microseismicity during the development process of intermittent rockburst in a deep railway tunnel[J]. International Journal of Rock Mechanics and Mining Sciences, 2019, 124: 104135.
- [21] 于群. 深埋隧洞岩爆孕育过程及预警方法研究[D]. 大连: 大连理工大学建设工程学院, 2016.
- Yu Qun. Study on Rockburst Nucleation Process and Early Warning Method of Deep-Buried Tunnels[D]. Dalian: School of Infrastructure Engineering, Dalian University of Technology, 2016(in Chinese).
- [22] 黄志平. 深埋隧洞开挖卸荷岩爆孕育过程及微震预警分析[D]. 沈阳: 东北大学资源与土木工程学院, 2015.

- Huang Zhiping. Analysis of Evolution Process and Seismic Early Warning of Rockburst Induced by Excavation Unloading in Deep-Buried Tunnel[D]. Shenyang: School of Resources and Civil Engineering, Northeastern University, 2015 (in Chinese).
- [23] Wang J C, Dong L J. Risk assessment of rockburst using SMOTE oversampling and integration algorithms under GBDT framework[J]. Journal of Central South University, 2024, 31(8): 2891-2915.
- [24] 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, USA, 2016.
- [25] Snoek J, Larochelle H, Adams R P. Practical Bayesian optimization of machine learning algorithms[C]//26th Annual Conference on Neural Information Processing Systems 2012. Lake Tahoe, USA, 2012.
- [26] Auger A, Hansen N. Theory of evolution strategies: A new perspective[G]//Theory of Randomized Search Heuristics: Foundations and Recent Developments. Singapore: World Scientific Publishing Co. Pte. Ltd., 2011.
- [27] Zhou J, Huang S, Qiu Y G. Optimization of random forest through the use of MVO, GWO and MFO in evaluating the stability of underground entry-type excavations[J]. Tunnelling and Underground Space Technology, 2022, 124: 104494.
- [28] Gablonsky J M, Kelley C T. A locally-biased form of the DIRECT algorithm[J]. Journal of Global Optimization, 2001, 21: 27-37.
- [29] Madsen K, Zertchaninov S. A C++ Programme for Global Optimization[M]. Denmark: IMM Publications, 1998.
- [30] Li L S, Jamieson K, DeSalvo G, et al. Hyperband: A novel bandit-based approach to hyperparameter optimization[J]. Journal of Machine Learning Research, 2018, 18: 1-52.

(责任编辑: 武立有)