

基于PCA-PSO-RF的地层结构 随钻智能识别方法

林成远^{1,2}, 张占荣^{1,2*}, 孙红林^{1,2}, 胡萍³

(1. 中铁第四勘察设计院集团有限公司, 湖北 武汉 430063; 2. 湖北省住房和城乡建设厅智能勘察工程技术创新中心, 湖北 武汉 430063; 3. 中国地质大学(武汉)工程学院, 湖北 武汉 430074)

摘要:针对传统钻探取心效率低、信息滞后,且现有随钻识别模型常忽略参数多重共线性与超参数优化而导致分类精度受限的问题,提出一种融合主成分分析(PCA)、粒子群优化(PSO)与随机森林(RF)的地层结构随钻智能识别方法。首先,通过皮尔逊相关性分析从多个随钻参数中筛选出与岩层结构强相关的给进压力、转速、扭矩和泵压4个特征;其次,采用PCA将原始四维特征降维至累计贡献率超95%的3个主成分,消除特征间多重共线性;最后,利用PSO算法对RF分类器超参数进行全局寻优。基于实测数据构建模型并与多种模型对比,结果表明:PCA-PSO-RF融合模型的F1分数高达0.964,精确率与召回率均超过96%,显著优于未经优化的RF模型及主流梯度提升算法;在独立钻孔数据集上验证准确率为84.8%,对无标签数据的预测准确率为83%,其中完整段误判率仅2%,证明了该模型具有良好的鲁棒性与泛化能力。本研究实现了岩层破碎段与完整段的实时高精度识别,为智能钻探与岩土工程勘察提供了可靠的技术支撑。

关键词:随钻监测;地层结构;岩体完整性;主成分分析;粒子群优化;随机森林;机器学习;智能识别

中图分类号:P634 **文献标识码:**A **文章编号:**2096-9686(2026)04-0126-08

Intelligent identification method of formation structure while drilling based on PCA-PSO-RF

LIN Chengyuan^{1,2}, ZHANG Zhanrong^{1,2*}, SUN Honglin^{1,2}, HU Ping³

(1. China Railway SiYuan Survey and Design Group Co., Ltd., Wuhan Hubei 430063, China; 2. Technology Innovation Center of Intelligent Geotechnical Investigation in Department of Housing and Urban-Rural Development of Hubei Province, Wuhan Hubei 430063, China; 3. Faculty of Engineering, China University of Geosciences, Wuhan Hubei 430074, China)

Abstract: To address the problems of low efficiency and information lag in conventional core drilling, as well as the limited classification accuracy of existing while-drilling identification models caused by the neglect of parameter multicollinearity and hyperparameter optimization, an intelligent while-drilling identification method for formation structure is proposed based on the fusion of principal component analysis (PCA), particle swarm optimization (PSO), and random forest (RF). First, four features-feed pressure, rotational speed, torque, and pump pressure-that are highly correlated with formation structure are selected from multiple while-drilling parameters using Pearson correlation analysis. Second, PCA is applied to reduce the original four-dimensional features to three principal components with a cumulative contribution rate exceeding 95%, thereby eliminating multicollinearity among the features. Finally, the

收稿日期:2025-10-29; 修回日期:2026-03-15 DOI:10.12143/j.ztgc.2026.04.013

基金项目:中国铁建股份有限公司重大专项(编号:2024-W01)

第一作者:林成远,男,汉族,1990年生,高级工程师,地质工程专业,博士,研究方向为智能勘探与工程地质仿真,湖北省武汉市武昌区和平大道745号,chengyuan1267@foxmail.com。

通信作者:张占荣,男,汉族,1982年生,地路院副总工程师,正高级工程师,岩土工程专业,博士,研究方向为精细化勘察与原位测试,湖北省武汉市武昌区和平大道745号,65158440@qq.com。

引用格式:林成远,张占荣,孙红林,等.基于PCA-PSO-RF的地层结构随钻智能识别方法[J].钻探工程,2026,53(4):126-133.

LIN Chengyuan, ZHANG Zhanrong, SUN Honglin, et al. Intelligent identification method of formation structure while drilling based on PCA-PSO-RF[J]. Drilling Engineering, 2026, 53(4): 126-133.

PSO algorithm is used to globally optimize the hyperparameters of the RF classifier. The model is constructed based on measured data and compared with various other algorithms. The results indicate that the PCA-PSO-RF fusion model achieves an $F1$ -score of 0.964, with both precision and recall exceeding 96%, significantly outperforming the unoptimized RF model and mainstream gradient boosting algorithms. The validation accuracy on an independent borehole dataset is 84.8%, and the prediction accuracy for unlabeled data is 83%, with a misclassification rate of only 2% for intact rock sections, demonstrating the model's robustness and generalization capability. This study achieves real-time, high-precision identification of fractured and intact rock sections, providing reliable technical support for intelligent drilling and geotechnical engineering investigation.

Key words: monitoring while drilling; formation structure; rock mass integrity; principal component analysis; particle swarm optimization; random forest; machine learning; intelligent identification

0 引言

工程勘察是工程项目建设的前置环节,通过对地层的详细调查和评估,为项目设计和施工提供科学依据。钻探作为勘察的主要手段,可以通过取心获取地下岩土样本,直观地反映地层信息。然而,传统的钻探取心方法存在诸多局限性,如取心效率低、样品易受破坏、信息滞后且依赖人工分析,以及难以实时、精确地识别地层界面等。已有研究表明,钻进过程中,钻机与岩层之间存在明显的机-岩相互作用,钻进参数能在一定程度上反映岩层的力学性质和结构特征^[1-3]。基于这一理论基础,在钻机上安装传感器,实时采集钻进过程中的数据。通过分析这些随钻数据能够推断地层信息,可以有效提升钻探效率,提高勘察过程的自动化水平和识别精度。

随钻参数监测技术作为实现地层信息实时获取的关键手段,在岩土工程数字化与智能化进程中发挥着重要作用。随钻监测的核心价值在于利用实时获取的钻进响应数据,实现对地层岩体结构及完整性的动态识别与评价^[4]。目前,随钻测量技术(MWD)与随钻测井技术(LWD)在钻探工程中已得到广泛应用^[5-8],二者结合显著提升了地层探测的自动化水平。然而,在复杂地质条件下,如何从高频监测数据中准确识别不同进尺段的岩体完整程度,仍是当前随钻识别领域亟待解决的技术难题。

在随钻参数与岩土体特性关联研究领域,学界已取得了丰富的研究成果^[9]。在监测设备方面,岳中琦等^[10-11]开发的钻孔过程监测仪(DPM),通过连续记录钻进全部参数,有效弥补了传统随钻测量系统的局限性。在理论与模型构建上,Ataei等^[12]通过室内实验,构建了岩石可钻性指数(RDi)与钻速的经验公式,为岩体参数的随钻预测提供了新的技术途径。针对特殊环境,李中等^[13]将随钻监测技术成功应用

于深水高温高压环境,实现了地层孔隙压力的计算,验证了该技术在极端环境下的适用性。在力学参数预测方面,王玉杰等^[14]通过室内实验,明确了数字钻进参数与岩石单轴抗压强度之间的定量关系。曹瑞琅等^[15]开发了新型数字钻进监测系统,并提出岩体完整性指标(DPI),建立了钻压、扭矩、转速与钻速的函数模型。此外,谭卓英等^[16-17]针对花岗岩地层的研究表明,钻进比功与岩石风化程度呈显著正相关。尽管上述研究在机理探索、设备研发和模型构建上成果显著,但其模型在多样化地质条件下的普适性,以及多参数协同分析的深度仍有待提升。这些不足在一定程度上制约了随钻监测技术在岩层破碎段精准识别与复杂地层分类中的进一步应用。

随着计算机技术的不断发展,近年来,机器学习在岩体性质预测中的应用逐渐增多。金长宇等^[18]基于神经网络,成功对柱状节理玄武岩的力学参数实现了高精度反演;周冠南等^[19]通过BP神经网络结合隧道变形数据预测了围岩力学参数;孙明志等^[20]采用支持向量机(SVM)算法,反分析位移反演获取了岩土力学参数;魏家俊^[21]通过 K 近邻算法预测了地层岩体的类型和完整性,准确率达86%;郝慧珍等^[22]利用机器学习算法对矿物识别开展了研究,表明机器学习在岩土参数预测中具有广阔的应用前景。

上述研究多侧重于利用随钻测试技术识别地层种类和地层物理力学性质,而对于岩层结构的实时识别研究较少,且在模型构建过程中,往往忽略了钻进参数间的多重共线性问题及模型超参数优化对性能的关键影响。基于此,本文提出一种基于PCA-PSO-RF的地层结构随钻智能识别方法。该方法首先通过主成分分析(PCA)对钻进参数进行降维去噪,以消除特征冗余;继而利用粒子群优化(PSO)算法对随机森林(RF)分类器的超参数进行

全局优化,以充分挖掘模型潜力。通过对比多种算法组合,系统验证了该融合模型在岩层破碎段识别中的优越性、鲁棒性与工程应用潜力。

1 基本原理

在随钻识别研究中,由于随钻参数之间存在多重共线性、冗余特征,以及模型超参数选择对分类性能有一定影响,单一模型往往难以同时兼顾特征提取与参数优化。PCA可用于消除特征间相关性,提取关键主成分,降低维度冗余;RF作为基分类器,具有良好的鲁棒性与抗过拟合能力,适用于小样本高维数据;PSO可对RF的关键超参数进行全局寻优,提升模型分类性能。三种方法融合可形成“特征降维-参数优化-集成分类”的递进式建模流程,有效解决现有研究中特征冗余与参数调优不足的问题。

1.1 主成分分析法

PCA通过提取数据中方差贡献最大的方向,可以有效消除特征间的冗余信息,突出影响地层结构的关键性综合指标,为后续分类模型提供更精炼、更有效的输入特征。具体运算步骤如下:

(1) 标准化原始数据矩阵 $X(m \times n, m$ 为样本数, n 为特征数)。

(2) 计算协方差矩阵:

$$R = \frac{1}{m-1} X^T X \quad (1)$$

(3) 求解特征值与特征向量,按特征值降序排列。

(4) 选取累计贡献率超过 90% 的前 k 个主成分。

(5) 构造降维后数据集 $M = X \times U_k$, 其中 U_k 为前 k 个特征向量构成的矩阵。

本研究采用PCA对随钻参数进行降维,旨在消除多重共线性,增强模型的鲁棒性与泛化能力。

1.2 PSO-RF算法模型

随机森林作为一种集成学习算法,通过构建多棵决策树并投票决定最终分类结果。其分类决策规则为:

$$\hat{y} = \arg \max \sum_{t=1}^T \mathbb{I}(h_t(x)=c) \quad (2)$$

式中: $\hat{y}$ ——随机森林的最终预测类别; c ——可能的类别标签; T ——决策树的总数; $\mathbb{I}$ ——指示函数,当 $(h_t(x)=c)$ 时, $\mathbb{I}(h_t(x)=c)$ 的值为 1, 否则为 0。

为优化RF的模型参数,引入PSO算法,旨在通过超参数自动寻优,增强模型的分类效能。PSO的

寻优过程模拟了鸟群的社会行为,每一个候选解都被抽象为一个具有飞行能力的“粒子”,粒子群在 D 维搜索空间中飞行,通过跟踪个体历史最优位置(pbest)和群体历史最优位置(gbest)来动态调整自身的飞行速度与位置,逐步逼近全局最优解。

PSO与RF的结合,本质上是利用PSO的全局搜索能力来优化RF的关键超参数,以待优化超参数作为粒子的位置坐标,以RF模型在验证集上的分类准确率作为粒子适应度,通过PSO的迭代寻优,最终为RF确定一组高性能的参数配置。本研究以经过PCA降维后的综合指标作为模型的输入参数,以地层结构完整性状态为输出参数,该融合模型的完整流程如图1所示。




图1 PSO-RF算法模型流程

Fig.1 Flowchart of the PSO-RF algorithm model

2 随钻数据获取与处理

2.1 数据来源

现场试验于河南省信阳市的钻探试验基地进行,地层主要为泥质砂岩和粉砂岩。试验选定5个孔位,深度均控制在50 m左右,选用XY-2型钻机,配合 $\varnothing 91$ mm复合片钻头。

安装钻探数据监测系统采集随钻参数数据,记录钻进过程中立轴位移、给进压力、提升压力、转

速、扭矩、泵压、流量等关键参数。传感器布置如图2所示,拉线位移传感器、转速传感器安装在回转器立轴卡盘位置,记录钻进过程中的位移和转速;扭矩传感器安装在齿轮箱皮带轮位置,监测钻进中的扭矩;泵压传感器、泵量传感器分别安装在泥浆压

力室和泥浆泵出口,用于监测泥浆压力和流量;油压传感器安装在液压给进系统输油管道上,用于监测油缸有杆腔给进压力 P_1 和无杆腔提升压力 P_0 。监测数据频率为1 Hz,按照时间序列依次、连续采集,得到钻进全过程数据约60万组。



图2 钻机及传感器安装位置

Fig.2 Drilling rig and sensor layout

2.2 数据预处理与可行性分析

由于钻探作业的连续性,传感器采集的原始数据流中混杂了大量非钻进状态的无效信息,这会显著干扰后续分析的准确性。为此,必须进行数据预处理,其核心任务是提取钻头真正切削地层产生进尺阶段的数据。数据预处理步骤:(1)剔除转速、扭矩及立轴位移 ≤ 0 的数据;(2)提取立轴位移数值减小区段数据;(3)提取 $P_1 > P_0$ 且 P_0 接近于0的区段数据。经处理保留的即是有效钻进阶段数据。

在建立模型之前,需要先验证随钻数据与地层结构之间的相关性,确保所建模型的合理性且能够在实际生产中应用。

钻进速度是指钻头在单位时间内向下钻进的距离,综合反映了钻进作业的地层信息、设备状态和作业效率,是钻进过程中的一个重要参数。基于此,绘制某段钻进过程的钻进时间与钻进深度的曲线,并结合该段的岩心照片进行分析(图3)。图中

曲线展示了钻头钻进深度随钻进时间的变化。在25 min内,钻孔深度从26 m增加至33 m,曲线斜率反映了不同时刻的钻速。当钻至28 m时,曲线出现了一个明显的转折点,斜率由缓变陡,表明钻速显著增加。




图3 钻进曲线与岩心对比

Fig.3 Comparison of drilling curve and cores

为探究这一变化的原因,结合岩心照片进行分析,可以观察到28 m深度处对应岩层的破碎段与完整段的分界线。具体而言,在破碎段(26~28 m),岩体节理、裂隙发育,结构面多,岩体破碎,承载能力差,钻头易发生“打滑”或“吃入不足”现象,实际钻速较低。而在完整段(28~33 m),钻头切削效率稳定,实际钻速较高。

2.3 参数筛选与主成分分析

依次绘制各随钻参数与钻进深度曲线,如图4所示。给进压力、转速、扭矩和泵压4个参数的曲线在钻进深度为28 m的破碎段与完整段分界处均出现明显波动,表明这些参数与地层结构之间存在相关性,能够在一定程度上反映地层结构的变化。由于位移为卡盘相对于钻杆的移动距离,提升压力在纯钻进状态下始终趋近于零值,故这2个参数与地层结构不具有相关性,因此在界面处不存在明显变化。

上述基于钻进曲线的对照分析,定性揭示了随钻参数与地层结构间的潜在关联。然而,为实现地层结构的智能化、定量化识别,需进一步从大量数据中提取稳定、普适的规律,并克服参数间的信息冗余问题。

采用皮尔逊相关性分析,对所有随钻参数与岩体完整性标签进行定量评估,其结果以热力图形式展示(图5)。提升压力和立轴位移与完整性标签的相关系数绝对值均低于0.2,验证了这2个随钻参数对识别岩层结构的判别能力微弱,不宜作为有效特征,应当进行剔除。给进压力与泵压之间的相关系数高达0.79,表明二者携带的信息高度重叠。若将其同时输入模型,会引发多重共线性问题,导致模型

泛化能力下降。因此采用PCA对原始特征进行降维处理,避免所选钻进参数间存在的多重共线性对模型性能产生干扰,并提升模型训练效率。对整体数据集执行PCA,最终提取得到4个主成分,见表1。

由表1可知,前3个主成分的累计贡献率已超过95%,将原始数据投影至这3个主成分方向,得到一组新的三维特征数据集,以此作为随机森林模型的输入。最终以3个互不相关的主成分,替代了初始的4个随钻参数,有效剔除特征间的冗余信息,提升模型的预测效率。

3 预测模型建立与效果评估

在完成数据预处理与特征降维后,构建基于PSO的RF分类模型。如表2所示,将经过PCA降维处理的1818组钻孔特征数据集及其对应的岩体完整性标签(分为破碎段与完整段)随机打乱,按照70%与30%的比例划分为训练集与测试集。训练集用于模型的训练与参数优化,测试集则用于评估模型的泛化性能。

3.1 基于PSO-RF的预测模型

为克服随机森林模型超参数人工调优的局限性,并充分挖掘其分类潜力,采用PSO算法对RF模型的关键超参数进行自动全局寻优。RF决策树数量取值[50,300],最大深度取值[5,25],叶子节点最小样本数取值[1,5];PSO算法的参数设置应综合考虑计算成本与算法收敛性能,采用经验法则结合预实验的方式确定,PSO算法粒子种群规模设置为30,最大迭代次数100,个体学习因子与社会学习因子均设置为2.0,惯性权重采用从0.9线性递减至




图4 随钻参数曲线

Fig.4 Drilling parameter curves




图 5 随钻参数皮尔逊相关性热力图

Fig.5 Pearson correlation heatmap of real-time drilling parameters

表 1 主成分特征值及贡献率

Table 1 Principal component eigenvalues and contribution rates

主成分	特征值	贡献率/%	累计贡献率/%
1	2.15	53.75	53.75
2	1.08	27.00	80.75
3	0.62	15.50	96.25
4	0.15	3.75	100.00

表 2 样本数据集

Table 2 Sample dataset

样本号	P ₁ /MPa	转速/(r·min ⁻¹)	扭矩/(N·m)	泵压/MPa	岩体完整性标签
1	0.37	170	51	0.54	1
2	0.375	170	62	0.53	2
3	0.362	160	67	0.55	1
4	0.38	170	60	0.66	1
...	...	...	...	...	...
1816	0.38	170	51	0.31	1
1817	0.375	160	26	0.34	2
1818	0.38	170	40	0.33	1

0.4 的策略,以平衡算法前期的全局探索能力与后期的局部开发能力。优化的目标即适应度函数,定义为利用当前超参数组合构建的 RF 模型在训练集上通过 5 折交叉验证所得的平均分类准确率,以此确保所寻优参数组合具有优异的稳健性与泛化能力。经过 PSO 优化后的 RF 超参数分别取得最优值,其中决策树数量取值 186,最大树深度取值 18,叶子节

点最小样本数取值 2。

为全面评估 PCA-PSO-RF 模型的性能,引入 XGBoost (Extreme Gradient Boosting) 和 LightGBM (Light Gradient Boosting Machine) 作为基准模型。两种对比模型均使用相同的训练集和测试集,并通过网格搜索进行超参数优化。基于 PSO 与 RF 算法模型,以处理后的随钻数据作为样本,分别建立 RF、PCA-RF、PSO-RF、XGBoost、LightGBM 和 PCA-PSO-RF 预测模型,所有模型均在相同的测试集上进行预测,并采用精确率、召回率和 F1 分数作为性能评价指标,结果见表 3。

表 3 不同算法的 F1 分数、精确率和召回率

Table 3 F1-scores, precision rates and recall rates of different algorithms

模 型	精确率/%	召回率/%	F1 分数
RF	89.50	88.72	0.891
PCA-RF	92.15	91.88	0.920
PSO-RF	94.33	93.95	0.941
XGBoost	93.28	92.87	0.921
LightGBM	94.05	93.82	0.939
PCA-PSO-RF	96.44	96.42	0.964

整理并对比各模型的岩层结构识别准确率结果可知,不同优化策略对模型分类性能的提升效果存在显著差异:未经优化的 RF 模型的 F1 分数为 0.891,其性能低于 XGBoost (0.921) 与 LightGBM (0.939),表明在原始特征与参数设置下,RF 的分类能力不及主流梯度提升算法。引入 PCA 降维后,PCA-RF 模型的 F1 分数提升至 0.920,验证了 PCA 在消除特征共线性、提炼关键地层信息方面的有效性;采用 PSO 算法优化超参数后,PSO-RF 模型 F1 分数达 0.941,已超越 XGBoost 与 LightGBM,体现出算法优化对模型潜力的释放作用。而 PCA-PSO-RF 融合模型的 F1 分数为 0.964,较 PSO-RF 提升 2.4%,较 LightGBM 提升 2.7%。该结果表明:尽管基础 RF 模型性能不及主流集成方法,但通过 PCA 特征降维与 PSO 参数优化的协同作用,可系统提升其分类精度。PCA 提取的低冗余主成分构成了更具判别性的特征空间,PSO 在该空间上对超参数进行全局寻优,二者共同形成“特征-参数”双重优化机制,显著增强了模型的识别能力与泛化性能,从而为随钻地层结构的实时精准识别

提供了可靠的技术途径。

3.2 模型验证

为了进一步验证 PCA-PSO-RF 模型在岩体完整性分类中的泛化能力,选用同一测试区域另外一组钻孔数据对已建立的模型进行验证。验证数据集包含 809 组有效钻进数据,具有与上述训练数据集相似的地层类型,但包含了不同的地层结构和钻进条件。

钻孔数据经处理后输入模型进行验证,最终模型在独立验证集上的准确率为 84.8%,综合精确率为 84.9%,综合召回率为 84.8%, $F1$ 分数为 0.85。结合分类混淆矩阵(图 6),该 PCA-PSO-RF 模型能够较好地识别随钻数据与地层结构的关系,分类性能较为稳定。




图 6 测试集混淆矩阵

Fig.6 Test set confusion matrix

采用上述模型对包含 200 个样本的无标签数据集进行预测并输出分类预测值。如图 7 所示,模型的总体预测准确率达到 83%,在无标签数据集预测中,仅有 15% 的破碎段岩层被误判,完整段岩层的误判率仅 2%,预测结果基本满足工程应用需求。

4 结论

本文围绕地层结构的随钻智能识别问题,开展了从数据预处理、特征降维到模型构建与优化的一系列研究,得到以下主要结论。

(1) 基于钻进参数曲线与皮尔逊相关性分析,有效筛选出给进压力、转速、扭矩、泵压 4 个与岩层结构高度相关的参数,并排除了提升压力和立轴位移 2 个不敏感参数,为模型构建奠定了合理的特征基础。

(2) PCA 能够有效消除所选钻进参数间的多重




图 7 无标签数据集预测结果

Fig.7 Prediction results for unlabeled dataset

共线性,将原始四维特征降维至贡献率超过 95% 的 3 个主成分,在保留关键地层信息的同时,提高了后续模型的训练效率与泛化能力。

(3) PSO 算法能够高效实现 RF 超参数的自动寻优。PSO-RF 模型的 $F1$ 分数达到 0.941,显著优于基准 RF 模型,证明了参数优化对提升模型性能的必要性。

(4) PCA-PSO-RF 融合模型综合性能最优, $F1$ 分数高达 0.964,其精确率与召回率均超过 96%。该结果验证了特征降维与参数优化的协同增强效应,为解决随钻地层结构的实时精准识别问题提供了可靠的技术途径。

参考文献 (References):

- [1] 汤凤林,赵荣欣,Нескоромных В В,等. PDC 钻头钻进岩石破碎过程及其与钻进规程参数关系的分析研究[J]. 钻探工程, 2024,51(1):5-14.
TANG Fenglin, ZHAO Rongxin, Нескоромных В В, et al. Analytical research on the rock fragmentation process and its relationship with drilling parameters in PDC bit drilling[J]. Drilling Engineering, 2024,51(1):5-14.
- [2] 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.
WANG Yafei, ZHANG Zhanrong, LIU Huaji, et al. Data-driven model for the identification of the rock type by drilling data[J]. Drilling Engineering, 2023,50(2):17-25.
- [3] 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.
- [4] 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.
- [5] 陈健, 岳中琦. 基于钻孔过程监测系统(DPM)全钻分析的钻孔过程塌孔监测[J]. 工程勘察, 2010, 38(11): 26-31.
CHEN Jian, YUE Zhongqi. Hole collapse detection based on full drill analysis of DPM system[J]. Journal of Geotechnical Investigation & Surveying, 2010, 38(11): 26-31.
- [6] Rai P, Schunesson H, Lindqvist P A, et al. An overview on measurement-while-drilling technique and its scope in excavation industry[J]. Journal of the Institution of Engineers (India): Series D, 2015, 96(1): 57-66.
- [7] 朱芝同, 吴川, 韦海瑞, 等. 绳索取心近钻头随钻测量系统设计与试验[J]. 钻探工程, 2025, 52(1): 24-30.
ZHU Zhitong, WU Chuan, WEI Hairui, et al. Design of a near-bit downhole measurement system while drilling for wireline coring[J]. Drilling Engineering, 2025, 52(1): 24-30.
- [8] 胡小林, 黄麟森, 王清峰. 煤矿井下随钻测量技术的应用研究[J]. 矿冶, 2012, 21(4): 89-92.
HU Xiaolin, HUANG Linsen, WANG Qingfeng. Study on measurement while drilling technology application in coal mine underground[J]. Mining and Metallurgy, 2012, 21(4): 89-92.
- [9] 柏君, 王胜, 赖昆, 等. 基于随钻关键参数的岩体智能探测方法研究进展[J]. 钻探工程, 2024, 51(5): 77-84.
BAI Jun, WANG Sheng, LAI Kun, et al. Research progress on intelligent rock mass detection method based on drilling parameters[J]. Drilling Engineering, 2024, 51(5): 77-84.
- [10] 岳中琦, 郭建英, 谭国焕, 等. 香港大学钻孔过程数字监测仪在自动化施工和设计中的作用[C]//全国岩土与工程学术大会论文集(上册). 北京: 人民交通出版社, 2003: 170-178.
YUE Zhongqi, GUO Jianying, TAN Guohuan, et al. The role of Hong Kong University drilling process digital monitoring instrument in automated construction and design[C]//Proceedings of the National Conference on Geotechnical and Engineering (Volume 1). Beijing: China Architecture Society Engineering Survey Branch People's Transportation Press, 2003: 170-178.
- [11] 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.
- [12] Ataie M, KaKaie R, Ghavidel M, et al. Drilling rate prediction of an open pit mine using the rock mass drillability index[J]. International Journal of Rock Mechanics and Mining Sciences, 2015, 73: 130-138.
- [13] 李中, 张祯祥, 杨进, 等. 地层压力随钻监测方法在深水高温高压井中的研究与应用[J]. 地球科学, 2019, 44(8): 2597-2602.
LI Zhong, ZHANG Zhenxiang, YANG Jin, et al. Research and application of formation pressure monitoring while drilling in deepwater with high temperature and high pressure[J]. Earth Science, 2019, 44(8): 2597-2602.
- [14] 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(9): 1659-1668.
WANG Yujie, SHE Lei, ZHAO Yufei, et al. Experimental study on measurement of rock strength parameters based on digital drilling technology[J]. Chinese Journal of Geotechnical Engineering, 2020, 42(9): 1659-1668.
- [15] 曹瑞琅, 王玉杰, 赵宇飞, 等. 基于钻进过程指数定量评价岩体完整性原位试验研究[J]. 岩土工程学报, 2021, 43(4): 679-687.
CAO Ruilang, WANG Yujie, ZHAO Yufei, et al. In-situ tests on quantitative evaluation of rock mass integrity based on drilling process index[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(4): 679-687.
- [16] 谭卓英, 王思敬, 蔡美峰. 岩土工程界面识别中的地层判别分类方法研究[J]. 岩石力学与工程学报, 2008, 27(2): 316-322.
TAN Zhuoying, WANG Sijing, CAI Meifeng. Study on discriminant classification method for ground formation in identification of geotechnical engineering interfaces[J]. Chinese Journal of Rock Mechanics and Engineering, 2008, 27(2): 316-322.
- [17] 谭卓英. 金刚石钻进能量在风化花岗岩地层中的变化特征[J]. 岩土工程学报, 2007, 29(9): 1303-1306.
TAN Zhuoying. Variation characteristics of penetrating energy for diamond drilling in weathered granite formation[J]. Chinese Journal of Geotechnical Engineering, 2007, 29(9): 1303-1306.
- [18] 金长宇, 冯夏庭, 张春生. 神经网络在柱状节理玄武岩体参数反演中的应用[J]. 水力发电学报, 2010, 29(2): 234-238.
JIN Changyu, FENG Xiating, ZHANG Chunsheng. Application of neural network to back analysis of mechanical parameters of columnar joint basalt[J]. Journal of Hydroelectric Engineering, 2010, 29(2): 234-238.
- [19] 周冠南, 孙玉永, 贾蓬. 基于遗传算法的BP神经网络在隧道围岩参数反演和变形预测中的应用[J]. 现代隧道技术, 2018, 55(1): 107-113.
ZHOU Guannan, SUN Yuyong, JIA Peng. Application of genetic algorithm based BP neural network to parameter inversion of surrounding rock and deformation prediction[J]. Modern Tunnelling Technology, 2018, 55(1): 107-113.
- [20] 孙明志, 戴文亭, 孙思博, 等. 基于GA-SVM岩土参数反演的改进PBA工法研究[J]. 地下空间与工程学报, 2020, 16(4): 1163-1171.
SUN Mingzhi, DAI Wenting, SUN Sibao, et al. Research on the improvement of PBA construction method based on GA-SVM[J]. Chinese Journal of Underground Space and Engineering, 2020, 16(4): 1163-1171.
- [21] 魏家俊. 基于机器学习的钻井监测数据处理方法研究[J]. 世界有色金属, 2020(19): 164-165.
WEI Jiajun. Research on drilling monitoring data processing method based on machine learning[J]. World Nonferrous Metals, 2020(19): 164-165.
- [22] 郝慧珍, 顾庆, 胡修棉. 基于机器学习的矿物智能识别方法研究进展与展望[J]. 地球科学, 2021, 46(9): 3091-3106.
HAO Huizhen, GU Qing, HU Xiumian. Research advances and prospective in mineral intelligent identification based on machine learning[J]. Earth Science, 2021, 46(9): 3091-3106.

(编辑 王跃伟)