

doi:10.3963/j.issn.1001-487X.2026.02.012

## 基于机载激光雷达和机器学习的爆堆体积预测<sup>\*</sup>

苗作华<sup>1,2</sup>, 杨凡<sup>1</sup>, 王永琦<sup>3</sup>, 严蔚涵<sup>1</sup>, 谭志兵<sup>1</sup>, 朱叶风<sup>2,4</sup>

- (1. 武汉科技大学 资源与环境工程学院, 武汉 430081;  
2. 冶金工业安全风险数智防控与应急联动重点实验室, 宁波 315800;  
3. 易普力(新疆)矿山工程有限公司, 昌吉回族自治州 831100;  
4. 宁波钢铁有限公司 安全保卫部, 宁波 315800)

**摘要:** 露天矿山台阶爆破后爆堆的松散系数是衡量爆破质量的重要指标,在明确了设计方量后,准确预测爆堆体积对于优化爆破参数、控制爆破效果及估算后续装运工程量具有重要意义。针对露天矿山爆破后爆堆体积测量效率低、小样本预测精度不足等问题,提出了一种基于机载激光雷达(LiDAR)与机器学习的智能化预测模型。首先采用轻量化无人机LiDAR系统,实现了爆堆点云数据的免像控快速采集;其次特征选择部分使用DeepSeek接口构建了融合Pearson相关性分析、ANOVA方差检验、随机森林特征重要性评估及递归特征消除的特征选择模型,从8项初始参数中筛选出6个关键影响因素。最后GS-KCV优化贝叶斯岭回归预测模型在测试集上 $R^2$ 达到0.76,较传统方法提升显著,MAE(19 949.67 m<sup>3</sup>)和RMSE(23 020.80 m<sup>3</sup>)分别降低26%和28%,解决了现有模型在小样本场景下易陷局部最优的难题。通过大疆M350无人机与禅思L<sub>2</sub>激光雷达的工程化应用验证,基于机载激光雷达与机器学习的智能化预测模型实现了爆破参数获取-体积预测-效果评估的全流程优化。

**关键词:** 矿山爆破; 贝叶斯岭回归; 爆堆体积预测; 机载激光雷达; 特征选择; 网格搜索

**中图分类号:** TD235.3 **文献标识码:** A **文章编号:** 1001-487X(2026)02-0120-10

## Muckpile Volume Prediction based on Airborne LiDAR and Machine Learning

MIAO Zuo-hua<sup>1,2</sup>, YANG Fan<sup>1</sup>, WANG Yong-qi<sup>3</sup>, YAN Yu-han<sup>1</sup>, TAN Zhi-bing<sup>1</sup>, ZHU Ye-feng<sup>2,4</sup>

- (1. School of Resources and Environmental Engineering, Wuhan University of Science and Technology, Wuhan 430081, China; 2. Key Laboratory of Digital Intelligence for Safety Risk Prevention and Emergency Response in Metallurgical Industry, Ningbo 315800, China; 3. EPR(Xinjiang) Mining Engineering Co., Ltd., Changji Hui Autonomous Prefecture 831100, China; 4. Security Department, Ningbo Iron & Steel Co., Ltd., Ningbo 315800, China)

**Abstract:** The bulking factor of blasted muck piles in open-pit mines serves as a crucial metric for assessing

收稿日期(Date of reception): 2025-09-03

网络首发日期(Published online): 2025-10-31

作者简介: 苗作华(1974-),男,湖北武汉人,博士、教授、硕士研究生导师,从事人工智能与智慧矿山研究,(E-mail) miaozuohua@wust.edu.com。

通信作者: 杨凡(2000-),男,湖北武汉人,硕士研究生,研究方向为智慧矿山,(E-mail) sunshineyfyf@qq.com。

基金项目: 国家自然科学基金资助项目(41071242, 41971237); 教育部产学研合作协同育人项目

**About the author:** MIAO Zuo-hua(1974-), male, born in Wuhan city, Hubei province, Ph. D, professor, master's supervisor, mainly engaged in artificial intelligence and smart mining, (E-mail) miaozuohua@wust.edu.com.

**Corresponding author:** YANG Fan(2000-), male, born in Wuhan city, Hubei province, master's candidate, mainly engaged in smart mining, (E-mail) sunshineyfyf@qq.com.

**Fund Programs:** National Natural Science Foundation of China(41071242, 41971237), Ministry of Education Industry-Academia Collaboration Project(202102136008)

blast performance. Precise estimation of muck pile volume is vital for optimizing blast parameters, controlling fragmentation effects, and planning subsequent excavation and haulage operations once the target excavation volume is established. To overcome limitations such as inefficiency, reliance on traditional volume-measurement approaches, and inadequate precision in small-sample predictions for blasted muck piles, this research develops an intelligent prediction model that leverages airborne LiDAR and machine learning algorithms. A lightweight UAV-LiDAR system for efficient, ground-control-independent acquisition of muck pile point cloud data was developed. Feature selection used the DeepSeek API to develop a hybrid model that integrates Pearson correlation analysis, ANOVA F-test, random forest feature importance assessment, and recursive feature elimination, ultimately extracting six critical factors from eight initial parameters. The GS-KCV-optimized Bayesian Ridge Regression model demonstrates predictive capability, achieving a test set  $R^2$  of 0.76, a marked improvement over traditional approaches. The model reduces MAE to 19 949.67  $\text{m}^3$  (26% decrease) and RMSE to 23 020.80  $\text{m}^3$  (28% decrease), while effectively addressing the common limitation of local-optima convergence in small-sample scenarios. Field tests conducted with DJI M350 drones integrated with Zenmuse  $L_2$  LiDAR systems verify the method's ability to holistically optimize the operational process, spanning blast parameter collection, volume prediction, and performance assessment, providing a practical technological solution for intelligent mining transformation.

**Key words:** mining blasting; Bayesian Ridge Regression; muckpile volume prediction; airborne LiDAR; feature selection; grid search

在矿山爆破研究中,爆堆的松散系数是衡量爆破后岩土体积膨胀的关键参数<sup>[1,2]</sup>,是评估爆破破碎程度,反映爆破设计的好坏和优化施工方案的重要指标,直接影响了爆破技术效果与经济性,而准确获取松散系数需依赖爆后爆堆体积的精确测量。因此,提出一种完整的爆后爆堆体积预测模型,包括数据采集与处理、关键特征筛选、机器学习模型优化及性能验证等部分,实现从原始数据到预测结果的闭环流程。

传统爆堆体积测量方法由测量人员需近距离接触不稳定爆堆进行数据采集,存在效率低、受地形与天气限制、安全风险高等问题。近年来,机载激光雷达技术发展迅猛,凭借其免像控、精度高和全天候作业等优势,已成为一种全新的高效测量手段<sup>[3]</sup>。潘大伟等通过机载 LiDAR 技术和 LANDIS PRO 模型评估了矿山复垦区植被的碳储量及固碳能力<sup>[4]</sup>,为矿区生态修复的碳中和目标提供了数据支持和优化路径。杨英杰利用机载激光雷达技术结合 GNSS 基站和数据处理软件<sup>[5]</sup>,通过点云数据建模和 DEM 分析,实现了矿山治理中土石方量高效精确计算。在此基础上使用了大疆 M350 无人机搭载禅思  $L_2$  机载激光雷达快速获取爆破后爆堆的激光雷达点云数据,并结合使用大疆智图和 CloudCompare 数据处理软件实现了爆后爆堆体积的数据获取。

传统爆破预测研究方法主要依赖现场试验、经验公式及岩体力学模型构建,其精度受限于岩体复杂性和工况多变性。随着机器学习技术的发展,矿山爆破预测正经历从经验驱动向数据驱动的范式转

变,当前基于机器学习的智能爆破系统已在参数优化、效果预测等环节实现工程化应用,显著提升了爆破设计的科学性与适应性<sup>[6]</sup>。刘欢等系统梳理了岩石爆破块度预测方法的研究进展<sup>[7]</sup>,从传统经验公式到弹性力学/断裂力学理论模型,再到数值模拟技术和智能算法的应用,分析了各类方法的优缺点,并展望了未来智能化和高精度预测的发展方向。张文涛等提出了一种 PCA-WOA-XGBoost 混合模型<sup>[8]</sup>,通过主成分分析降维消除爆破参数冗余,并结合鲸鱼算法优化 XGBoost 超参数,实现了露天矿山爆破振动峰值振速的高精度预测。刘骏等提出了基于鲸鱼优化算法优化支持向量机的爆破块度预测模型<sup>[9]</sup>,通过归纳全球 7 座矿山的 97 组爆破数据,优化 SVM 的核参数与惩罚因子,使模型预测的平均绝对误差低至 0.045,均方误差为 0.0038,为矿山爆破块度的高精度预测提供了新方法。黄晶柱等基于马来西亚某矿山的 52 组爆破数据<sup>[10]</sup>,采用高斯过程回归构建了爆破飞石距离预测模型并实现了矿山安全警戒范围的高精度预测。以上研究均实现了较为理想的预测准确性,但目前已有的预测模型仍存在易陷于局部最优解,预测结果不稳定等问题,特别是针对单一矿山,由于数据样本少且来源单一,其预测适应性表现更为不佳。基于此,在特征选择部分引入了 DeepSeek 接口,对矿区小样本数据进行自动化分析与可视化,避免经验依赖并筛选关键特征变量,使用网格搜索和  $K$  折交叉验证优化贝叶斯岭回归、随机森林、XGBoost、KNN 的超参数,最终选择预测效果最优模型用于爆破后爆堆体积预测。

## 1 机器学习算法原理

### 1.1 贝叶斯岭回归算法

贝叶斯岭回归是一种结合贝叶斯概率框架和岭回归的线性回归方法<sup>[11]</sup>,相比普通岭回归,贝叶斯方法不仅能给出预测值,还能提供预测的不确定性估计。该算法能够自适应调节模型复杂度,提高泛化能力,在小样本和高维数据场景下表现尤为突出。这些特性使得贝叶斯岭回归特别适合矿山爆堆体积预测这类小样本、高精度的工程问题。

### 1.2 GS-KCV 优化方法

网格搜索法(GS)是一种系统的超参数调优策略<sup>[12]</sup>,其优势在于将待优化的超参数取值范围划分为离散的网格点进行全局遍历,可确保参数空间的完全覆盖,从而有效避免小样本场景下最优解的遗漏。在参数寻优中使用GS方法去优化模型的参数,常选择K折交叉验证(KCV)来缓解过拟合,评估模型的效果<sup>[13]</sup>,考虑到小样本数据集有着数据分布代表性不足、易过拟合和易陷入局部最优等特点,选择使用五折交叉验证法,相应的原理如图1所示。




图1 五折交叉验证流程图

Fig. 1 Flowchart of 50% discount cross-validation

原始数据集被随机划分为5个大小相近的子集 $D_1$ 、 $D_2$ 、 $D_3$ 、 $D_4$ 、 $D_5$ ,每次选取其中一个子集作为验证集,其余4个子集作为训练集,重复5次后取平均后的均方误差MSE作为评价指标。KCV通过多次数据划分减少评估结果的方差,避免因单次数据分割的随机性导致偏差。

## 2 体积预测模型建立

### 2.1 工程背景

新疆准东西黑山片区某煤矿地处准噶尔盆地东

部,矿区地质构造整体呈近水平单斜形态,地层倾角普遍小于 $10^\circ$ 。矿区主要出露地层包括第四系松散沉积层和侏罗系含煤建造,其中煤系地层主要由砂岩、泥岩和煤层互层组成,具有明显的软硬岩互层特征。地质构造主要表现为水平层状分布,岩体强度差异显著,其中硬岩类占比达75%,中硬岩类占22.95%,软岩类仅2.05%。该工程采用台阶爆破法施工,标准台阶高度为15 m,配备10台一体式潜孔钻机和7台混装炸药车。钻孔采用梅花形布孔方式,根据不同岩性采用差异化参数:硬岩孔径138 mm、孔距8 m、排距6 m;软岩孔径152 mm、孔距9 m、排距7 m。爆破网路采用电子雷管逐孔起爆技术,通过精确控制毫秒延期时间来实现岩石的充分破碎。

爆堆体积作为爆破效果的核心评价指标,其与设计方量的比值(松散系数)能够综合反映爆破能量分布合理性、岩体破碎程度及抛掷控制精度。工程实践表明,松散系数过高会导致岩体过度破碎和抛掷浪费,而过低则表明爆破能量不足,岩石破碎不充分。借助基于机载激光雷达与机器学习的智能化预测模型得到的预测体积,通过装药参数和起爆方式等关键因素的动态分析和优化调整,实现了对爆破效果的预测和控制。

### 2.2 流程汇总

1)使用无人机搭载激光雷达快速获取爆后爆堆的激光点云数据并使用大疆智图重建爆堆的三维建模;2)使用CloudCompare获取爆堆的三维建模的体积并结合爆前参数构建原始数据集;3)特征选择部分通过SiliconFlow硅基流动调用DeepSeek接口来实现数据自动分析与可视化,DeepSeek通过读取分析原始数据集后选择合适的特征选择方法,最后决定采用皮尔逊相关性分析、ANOVA F-test、随机森林特征重要性和RFE进行特征筛选,剔除对输出参数影响较小的特征;4)通过网格搜索法尝试不同的参数组合,并使用五折交叉验证法来评估每个参数组合的性能,选定最优参数组合,在整个数据集上训练多个机器学习模型,根据模型评价指标来选取最优的模型作为最终的模型。见图2。

### 2.3 数据集收集

#### 2.3.1 设备及原理

大疆Matrice 350 RTK是一款专为高精度测绘与巡检任务设计的旗舰级行业无人机,其六向双目视觉和双频RTK定位系统确保在各类复杂环境下稳定飞行,最大抗风能力达到15 m/s,可适应露天矿山这种严苛的作业环境。搭载的禅思I2激光雷

达系统能够穿透植被间隙直达地表, 确保获取爆堆表面的真实形态数据, 最终生成高密度三维点云, 精准还原爆堆的空间形貌<sup>[14,15]</sup>。闫魏力等验证了无人机搭载三维激光扫描技术在露天矿山测量中的精

度(优于 5 cm)<sup>[16]</sup>, 并通过区域性偏差分析和典型剖面比对, 结合 RTK 实测数据验证了该技术的高可靠性。




图 2 爆堆体积预测的流程图

Fig. 2 Flowchart of burst pile volume prediction

实验中爆堆数据采集在爆区附近架设 GNSS 基准站, 通过静态测量标定站坐标后与无人机建立实时差分数据链, 使点云平面精度优于 2 cm; 作业前规划交叉航线并验证基站-移动站模糊度固定状态, 飞行中同步采集激光点云与差分定位数据; 后期处理时在大疆智图中融合基站观测值改正 POS 数据, 生成高程误差  $\leq 5$  cm 的 DEM, 结合 CloudCompare 提取爆堆体积并构建数据集。

### 2.3.2 采集流程

在新疆准东西黑山片区某煤矿高台阶缓边坡中使用大疆 M350 无人机搭载禅思 L2 机载激光雷达快速获取爆破后爆堆的激光雷达点云数据; 再将外业数据导入到大疆智图软件中对该数据进行数据重

建操作生成精细的三维建模, 如图 3 所示。




图 3 爆堆的点云图

Fig. 3 Point cloud of the bursting pile

### 2.3.3 体积计算

将建模导入到 CloudCompare 中进行划分爆堆区域后, 使用 Python 代码使该部分区域 Z 轴坐标为

0 形成一个底面,并组合成一个有斜面有底面的整体。CloudCompare 的计算 2.5D 体积会将底面作为基准面,提取物体上表面的点云数据,得到其高度分

布,计算两者的高度差并在网格单元上积分,最终得出物体的相对于地面的体积。CloudCompare 计算体积界面如图 4 所示。




图 4 CloudCompare 计算体积界面

Fig. 4 CloudCompare volume calculation interface

#### 2.3.4 数据集整理

以爆前参数作为输入特征,以处理计算得到的爆堆特征信息作为输出特征构成数据集如表 1 所示。

表 1 数据集组成  
Table 1 Data set components

|                             |            |                         |
|-----------------------------|------------|-------------------------|
| 输入参数<br>Input<br>parameters | <i>OH</i>  | 超深 Over hole            |
|                             | <i>NR</i>  | 排数 Number of rows       |
|                             | <i>S/B</i> | 炮孔密集系数 Spacing/burden   |
|                             | <i>BW</i>  | 爆区宽度 Blast width        |
|                             | <i>BL</i>  | 爆区长度 Blast length       |
|                             | <i>WDR</i> | 水孔孔数比 Water drill ratio |
|                             | <i>PF</i>  | 单耗 Powder factor        |
|                             | <i>DV</i>  | 设计方量 Design volume      |
| 输出 Output                   | <i>AV</i>  | 实际体积 Actual volume      |

选择 *AV* 作为输出参数,*OH*、*NR*、*S/B*、*BW*、*BL*、*WDR*、*PF*、*DV* 八个特征作为模型的输入参数。

#### 2.4 特征选择

特征选择部分引入了 DeepSeek-V3 大模型,通过 SiliconFlow 硅基流动 API 调用,自动解析分析需求,实现了数据自动分析和可视化,完成了特征筛选。其选择的模型为 DeepSeek-V3,api\_base 为 <https://api.siliconflow.cn/v1>,自定义指令包含数据预

处理、核心分析、可视化规范和输出要求四个部分。

依据新疆准东西黑山片区某煤矿 2024 年 11 月至 2025 年 5 月的 50 次爆破监测数据建立数据集,包含 8 个特征变量,将样本数据导入到 Python 3.7 中训练,得到属性相关热力图和综合特征选择图,如图 5、图 6 和表 2 所示。




图 5 属性相关图

Fig. 5 Attribute correlation diagram

从图 5、6 和表 2 得出,*NR* 与 *BW* 的相关系数为 0.977,接近完全线性关系,而 *BW* 的 ANOVA F-test 得分高于 *NR*,且 *BW* 被 REF 筛选出来,所以将特征 *NR* 剔除;*S/B* 的 ANOVA F-test 和随机森林重要性

得分均较低,且未被 RFE 选中,故剔除。




图 6 随机森林特征重要性和 ANOVA F-test 分数  
Fig. 6 Random forest feature importance and ANOVA F-test scores

表 2 RFE 最佳特征选择  
Table 2 Optimal feature selection for RFE

| RFE 保留的特征<br>Features retained by RFE |                                         | RFE 剔除的特征<br>Features excluded by RFE |  |
|---------------------------------------|-----------------------------------------|---------------------------------------|--|
| 输入特征<br>Input features                | 超深/OH、爆区宽度/BW、爆区长度/BL、<br>设计方量/DV、单耗/PF | 炮孔密集系数/S/B、排数/NR、<br>水孔孔数比/WDR        |  |

DV 和 BL 是对目标变量 AV 最重要的特征,无论是在线性还是非线性方法中,都表现出极高的预测能力;OH 在相关性分析、随机森林和 RFE 方法中均表现出对目标变量的贡献,尤其是在非线性模型中作用显著;而 PF 不仅在 RFE 中被筛选为关键特征,还在随机森林模型中表现出较高的特征重要性;WDR 在相关性分析中排名靠前,体现出较强的预测能力;BW 虽然在线性模型中贡献有限,但在随机森林和 RFE 中仍显示出一定的解释作用。

因此,经特征选择后的保留下来的特征变量共有六个,分别是 PF、DV、BL、BW、OH 和 WDR。筛选后的部分数据集如表 3 所示。

2.5 GS-KCV 优化贝叶斯岭

(1)噪声精度  $\alpha$  的形状参数( $\alpha_1$ )。用于控制噪声方差  $\sigma^2$  先验分布的形状。较小的  $\alpha_1$  使先验更弱,允许模型更多依赖数据来估计噪声方差。其取值范围为[ $1e-6,1e-5,1e-4$ ]。

(2)噪声精度  $\alpha$  的尺度参数( $\alpha_2$ )。用于控制噪声方差  $\sigma^2$  先验分布的尺度。较小的  $\alpha_1$  使先验分布

更宽,允许  $\sigma^2$  取值范围更大。取值范围为[ $1e-6,1e-5,1e-4$ ]。

(3)权重精度  $\lambda$  的形状参数( $\lambda_1$ )。调节  $\lambda$  先验分布的形状。较小的  $\lambda_1$  使先验更弱,允许  $\lambda$  的估计更灵活,模型更依赖数据来确定正则化强度。取值范围为[ $1e-6,1e-5,1e-4$ ]。

(4)权重精度  $\lambda$  的尺度参数( $\lambda_2$ )。控制  $\lambda$  先验分布的尺度,影响其均值和方差。较小的  $\lambda_2$  使分布更宽,允许  $\lambda$  有更大变化范围。取值范围为[ $1e-6,1e-5,1e-4$ ]。

对于上述参数空间中的每个参数组合,使用五折交叉验证模型将划分好的训练集分为五个子集,记录每一组 MSE,从所有参数中选择 MSE 平均最小的参数组合,得到最优参数,各参数的取值范围和最优参数取值如表 4 所示。

3 模型验证

3.1 模型评价指标

利用筛选出来的特征,分别选取 GS-KCV 优化

后的贝叶斯岭回归、随机森林回归、XGBoost 和 KNN 绝对误差 (MAE) 和均方根误差 (RMSE) 作为衡量指  
四种模型进行实验分析, 采用决定系数 ( $R^2$ )、平均 标,  $R^2$ 、MAE 和 RMSE 的计算公式如下。

表 3 部分数据集

Table 3 Selected data sets

| 水孔孔数比<br>WDR | 超深<br>OH/m | 爆区长度<br>BL/m | 爆区宽度<br>BW/m | 单耗<br>PF/(kg · m <sup>-3</sup> ) | 设计方量<br>DV/m <sup>3</sup> | 实际体积<br>AV/m <sup>3</sup> |
|--------------|------------|--------------|--------------|----------------------------------|---------------------------|---------------------------|
| 1            | 0.5        | 161.5        | 57.5         | 0.333                            | 120 233                   | 117 742                   |
| 1            | 1.5        | 195.0        | 37.5         | 0.417                            | 84 394                    | 70 150                    |
| 1            | 1.5        | 367.5        | 42.5         | 0.172                            | 179 044                   | 173 264                   |
| 1            | 1.0        | 270.0        | 52.5         | 0.433                            | 197 086                   | 141 241                   |
| 1            | 1.5        | 247.5        | 45.4         | 0.490                            | 136 282                   | 117 274                   |
| 0.9          | 1.5        | 300.0        | 46.1         | 0.471                            | 168 844                   | 166 029                   |
| 1            | 1.5        | 280.8        | 47.5         | 0.426                            | 166 764                   | 152 432                   |
| 1            | 1.5        | 314.5        | 36.0         | 0.385                            | 98 049                    | 97 641                    |
| 1            | 0          | 296.0        | 37.5         | 0.357                            | 56 872                    | 44 796                    |
| 1            | 1.5        | 348.5        | 36.0         | 0.355                            | 152 078                   | 132 495                   |
| 1            | 0.5        | 674.5        | 29.0         | 0.284                            | 225 015                   | 214 988                   |
| 1            | 1.0        | 486.0        | 60.5         | 0.294                            | 326 142                   | 273 850                   |
| 0            | 0.5        | 209.0        | 29.0         | 0.212                            | 64 241                    | 59 723                    |
| 1            | 0          | 217.5        | 68.9         | 0.411                            | 127 210                   | 75 725                    |
| 1            | 1.5        | 442.5        | 29.0         | 0.378                            | 158 836                   | 189 745                   |
| 1            | 1.0        | 655.2        | 35.0         | 0.309                            | 282 401                   | 270 447                   |
| 1            | 1.5        | 337.5        | 36.0         | 0.394                            | 159 898                   | 151 596                   |

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

式中:  $n$  为样本数量;  $y_i$  和  $\hat{y}_i$  分别为第  $i$  个样本的实际值和预测值;  $\bar{y}$  为实际值的均值。

表 4 贝叶斯岭的参数设定的取值范围和最优参数取值

Table 4 Range of values for parameter settings and optimal parameter values for bayes ridge

| 参数名称<br>Parameter name                                                                    | 取值范围<br>Value range | 最佳参数取值<br>Optimal parameter values |
|-------------------------------------------------------------------------------------------|---------------------|------------------------------------|
| 噪声精度 $\alpha$ 的形状参数( $\alpha_1$ )<br>Shape parameter of noise precision( $\alpha_1$ )     | [1e-6, 1e-5, 1e-4]  | 1e-6                               |
| 噪声精度 $\alpha$ 的尺度参数( $\alpha_2$ )<br>Scale parameter of noise precision( $\alpha_2$ )     | [1e-6, 1e-5, 1e-4]  | 1e-4                               |
| 权重精度 $\lambda$ 的形状参数( $\lambda_1$ )<br>Shape parameter of weight precision( $\lambda_1$ ) | [1e-6, 1e-5, 1e-4]  | 1e-6                               |
| 权重精度 $\lambda$ 的尺度参数( $\lambda_2$ )<br>Scale parameter of weight precision( $\lambda_2$ ) | [1e-6, 1e-5, 1e-4]  | 1e-4                               |

### 3.2 模型预测结果

数据集随机分为训练集和测试集: 训练集用于

模型训练和参数调优, 测试集用于评估模型表现, 最终选出性能最佳的模型。部分模型预测值与真实值

对比表和对比图如表 5 和图 7 所示。

表 5 部分模型预测值与真实值数值对比  
Table 5 Comparison of model predicted and true values

| 序号<br>Serial<br>number | 真实值<br>Actual<br>value | GS-KCV-<br>随机森林预测值<br>GS-KCV-random<br>forest prediction | GS-KCV-XGBoost<br>预测值<br>GS-KCV-XGBoost<br>prediction | GS-KCV-k<br>近邻预测值<br>GS-KCV-k-nearest<br>neighbors prediction | GS-KCV-<br>贝叶斯岭回归预测值<br>GS-KCV-bayesian ridge<br>regression prediction |
|------------------------|------------------------|----------------------------------------------------------|-------------------------------------------------------|---------------------------------------------------------------|------------------------------------------------------------------------|
| 1                      | 202 431.23             | 223 039.73                                               | 194 679.92                                            | 181 950.55                                                    | 199 876.52                                                             |
| 2                      | 145 800.38             | 162 559.40                                               | 131 287.71                                            | 149 895.36                                                    | 143 265.91                                                             |
| 3                      | 109 666.41             | 118 831.24                                               | 92 975.09                                             | 113 659.59                                                    | 107 892.34                                                             |
| 4                      | 251 629.89             | 248 540.86                                               | 216 918.60                                            | 228 804.58                                                    | 247 853.27                                                             |
| 5                      | 231 853.11             | 223 140.11                                               | 212 742.03                                            | 242 158.38                                                    | 228 796.45                                                             |
| 6                      | 73 620.05              | 92 105.64                                                | 108 774.07                                            | 85 534.87                                                     | 75 218.93                                                              |




图 7 模型预测值与真实值图像对比  
Fig. 7 Comparison of model predicted and true value images

由表 5 和图 7 可知,GS-KCV-贝叶斯岭回归模

型测试集的预测值与真实值较为接近,说明 GS-KCV-贝叶斯岭回归模型可以为爆后爆堆体积提供一定的准确性。

3.3 模型评价指标对比

对优化好的四个模型的预测结果进行对比,以  $R^2$ 、MAE 和 RMSE 作为评价指标。各优化模型预测结果如表 6 所示。

GS-KCV-贝叶斯岭回归模型在所有模型中表现最优,其  $R^2$  (0.76) 最高,说明对数据变异的解释能力最强;MAE (19 949.67) 和 RMSE (23 020.80) 均为最低,表明预测准确性和稳定性最好。相比之下,随机森林、XGBoost 和 KNN 模型的各项指标均不如它,尤其是在  $R^2$  上差距明显,说明贝叶斯岭回归在捕捉数据规律和减少误差方面优势突出,结合了贝叶斯优化和线性模型的稳定性,既能较好拟合数据,又不易过拟合。

表 6 模型评价指标对比  
Table 6 Comparison of model evaluation metrics

| 模型<br>Model                                               | 决定系数<br>$R^2$ | 平均绝对误差<br>MAE | 均方根误差<br>RMSE |
|-----------------------------------------------------------|---------------|---------------|---------------|
| GS-KCV-贝叶斯岭回归模型<br>GS-KCV-bayesian ridge regression model | 0.76          | 19 949.67     | 23 020.80     |
| GS-KCV-随机森林回归模型<br>GS-KCV-random forest regression model  | 0.67          | 26 972.25     | 32 158.71     |
| GS-KCV-XGBoost 模型<br>GS-KCV-XGBoost model                 | 0.64          | 25 447.53     | 28 041.06     |
| GS-KCV-KNN 模型<br>GS-KCV-k-nearest neighbors model         | 0.47          | 31 798.13     | 36 817.16     |

4 结论

1)提出了一个完整高效的爆后爆堆体积预测

模型,从爆后爆堆中使用无人机搭载激光雷达快速精准收集数据,处理激光雷达点云数据、重建三维建模;网格化高精度建模获取爆后爆堆体积并结合爆

前参数建立原始数据集,引入 deepseek 接口实现数据自动化分析与可视化,进行特征筛选;使用不同的优化模型进行对比找到并确定最终优化预测模型。

2)将 GS-KCV-贝叶斯岭回归爆后爆堆体积预测模型与 GS-KCV-随机森林回归、GS-KCV-XGBoost 和 GS-KCV-KNN 模型相比较,其中 GS-KCV-贝叶斯岭回归爆后爆堆体积预测模型的  $R^2$  最高、MAE 和 RMSE 最低。

3)从新疆准东西黑山片区某煤矿实际工程中获取数据,建立了 GS-KCV-贝叶斯岭爆后爆堆体积预测模型,再去应用于实际工程中进行后续的爆破,预测结果与实际值接近,预测效果优良

### 参考文献 (References)

- [1] 于鑫鑫,张 翌,马赛赛. 基于无人机航测技术的露天矿爆堆特征感知方法应用[J]. 露天采矿技术,2025,40(3):45-48.
- [1] YU Xin-xin,ZHANG Zhao,MA Sai-sai. Application of explosive pile characteristics perception method in open-pit mines based on UAV survey technology[J]. Opencast Mining Technology,2025,40(3):45-48. (in Chinese)
- [2] 苗作华,谢 媛,任 磊,等. 基于三维可视化的爆堆形态灰色敏感度分析[J]. 金属矿山,2022(2):83-89.
- [2] MIAO Zuo-hua,XIE Yuan,REN lei,et al. Grey sensitivity analysis of detonation heap morphology based on 3D visualization[J]. Metal Mine,2022(2):83-89. (in Chinese)
- [3] 吴江昊,姜 涛. 基于机载激光雷达的高陡边坡孤立危岩体识别方法[J]. 经纬天地,2024(6):19-23,55.
- [3] WU Jiang-hao,JIANG Tao. Identification method on isolated dangerous rock mass in high -steep slope based on airborne LiDAR[J]. Survey World,2024(6):19-23,55. (in Chinese)
- [4] 潘大伟,周 雷,王世平,等. 基于机载 LiDAR 和 LANDIS PRO 模型的矿山生态复垦区地上植被固碳能力及其提升路径研究[J/OL]. 生态学杂志,2025:1-13. [2025-10-21]. <https://link.cnki.net/urlid/21.1148.Q.20241127.1442.004>.
- [4] PAN Da-wei,ZHOU Lei,WANG Shi-ping,et al. Carbon sequestration capacity of aboveground vegetation in mine ecological reclamation area based on airborne LiDAR and LANDIS PRO model and its promotion path[J/OL]. Chinese Journal of Ecology,2025:1-13. [2025-10-21]. <https://link.cnki.net/urlid/21.1148.Q.20241127.1442.004>. (in Chinese)
- [5] 杨英杰. 机载激光雷达在矿山治理中土石方量计算的应用[J]. 世界有色金属,2024(22):207-209.
- [5] YANG Ying-jie. Application of airborne LiDAR in calculating earthwork volume in mine management[J]. World Nonferrous Metals,2024(22):207-209. (in Chinese)
- [6] 夏淑媛,董永峰,王利琴. 基于特征工程的 XGBoost 爆破块度预测研究[J]. 爆破,2023,40(2):97-101,131.
- [6] XIA Shu-yuan,DONG Yong-feng,Wang Li-qin. Research on XGBoost burst block size prediction based on feature engineering[J]. Blasting,2023,40(2):97-101,131. (in Chinese)
- [7] 刘 欢,潘 城. 岩石爆破块度预测方法研究现状及展望[J]. 建井技术,2025,46(3):73-81.
- [7] LIU Huan,PAN Cheng. Research status and prospects of rock blasting fragmentation prediction methods[J]. Mine Construction Technolgy. 2025,46(3):73-81. (in Chinese)
- [8] 张文涛,汪海波,高朋飞,等. 基于 PCA-WOA-XGBoost 的露天矿山爆破振动峰值振速预测[J]. 工程爆破,2024,30(6):155-167,177.
- [8] ZHANG Wen-tao,WANG Hai-bo,GAO Peng-fei,et al. Prediction of PPV of blasting vibration in open-pit mine based on PCA-WOA-XGBoost model[J]. Engineering Blasting,2024,30(6):155-167,177. (in Chinese)
- [9] 刘 骏,王文通,张千俊,等. 基于 WOA-SVM 模型的爆破块度预测研究[J]. 采矿技术,2024,24(2):103-107.
- [9] LIU Jun,WANG Wen-tong,ZHANG Qian-jun,et al. Research on blast fragmentation prediction based on WOA-SVM model[J]. Mining Technology,2024,24(2):103-107. (in Chinese)
- [10] 黄晶柱,钟依禄,黄裘俊,等. 基于高斯过程回归矿山爆破飞石距离预测模型[J]. 工程爆破,2023,29(2):73-79,108.
- [10] HUANG Jin-zhu,ZHONG Yi-lu,HUANG Qiu-jun,et al. Prediction model of blasting flyrock distance in mine based on Gaussian process regression[J]. Engineering Blasting,2023,29(2):73-79,108. (in Chinese)
- [11] 王纯杰,戚顺欣,张洪阳. Logistic 回归模型参数的贝叶斯估计及应用[J]. 统计与决策,2020,36(22):14-18.
- [11] WANG Chun-jie,QI Shun-xin,ZHANG Hong yang. Bayesian estimation and application for parameters in Logistic regression model[J]. Statistics & Decision,2020,36(22):14-18. (in Chinese)
- [12] 费鸿禄,左壮壮,蒋安俊,等. 基于 KS-GS-SVR 的峰值爆破振速预测[J]. 工程爆破,2023,29(2):120-128.
- [12] FEI Hong-lu,ZUO Zhuang-zhuang,JIANG An-jun,et al. Peak blasting vibration velocity prediction based on KS-GS-SVR[J]. Engineering Blasting,2023,29(2):120-128. (in Chinese)
- [13] 赵 颖,岳中文,薛克军,等. 基于特征选择的 GS-KCV-XGBoost 露天金属矿爆破块度预测模型[J]. 工程爆破,2024,30(6):168-177.
- [13] ZHAO Yin,YUE Zhong-wen,XUE Ke-jun,et al. GS-

- KCV-XGBoost open-pit metal mine blasting block size prediction model based on feature selection[J]. Engineering Blasting, 2024, 30(6):168-177. (in Chinese)
- [14] 王麟. 基于矿山地质测绘的无人机机载激光雷达技术的分析[J]. 世界有色金属, 2024(12):149-151.
- [14] WANG Lin. Analysis of unmanned aerial vehicle airborne LiDAR technology based on mining geological surveying and mapping[J]. World Nonferrous Metals, 2024(12):149-151. (in Chinese)
- [15] 刘新跃, 胡科, 杨文. 机载激光雷达在地形测绘中的运用[J]. 科技视界, 2025, 15(2):6-8.
- [15] LIU Xin-yue, HU Ke, YANG Wen. The application of airborne lidar in topographic mapping[J]. Technology Perspective, 2025, 15(2):6-8. (in Chinese)
- [16] 闫魏力, 张驰, 王洛锋. 无人机载三维激光扫描技术在露天矿山测量中的应用[J]. 黄金, 2022, 43(8):41-44.
- [16] YAN Wei-li, ZHANG Chi, WANG Luo-feng. Application of UAV-based 3D laser scanning technology in open-pit mine surveying[J]. Gold, 2022, 43(8):41-44. (in Chinese)
- 
- (上接第81页)
- [18] GUO Yan-chao, YANG Ren-shu, PENG Shu-ping, et al. Experimental study on decoupled charge blasting-induced crack propagation with parabolic shaped charge[J]. Engineering Fracture Mechanics, 2024:304110178.
- [19] LING Tian-long, LI Sheng-lin, LIU Dian-shu, et al. Blasting damage of tunnel rock mass based on cumulative effect[J]. Rock Mechanics and Rock Engineering, 2022, 56(3):1679-1695.
- [20] 朱礼臣. 隧道掏槽爆破岩块抛掷堆积形态的数值模拟[J]. 工程爆破, 2024, 30(3):54-61.
- [20] ZHU Li-chen. Numerical simulation of rock throwing accumulation morphology in tunnel cutting blasting[J]. Engineering Blasting, 2024, 30(3):54-61. (in Chinese)
- [21] HANG Xiang-yu, YAN Peng, HE Hua-xiong, et al. Experimental investigations of the effect of millisecond-delay time on the blast vibration reduction with electronic detonators[J]. Journal of Vibration and Control, 2023, 29(17-18):4204-4215.
- [22] DONG Hong-jie, GUO Yang, YANG Zhi-ming, et al. The local Well-Posedness of the relativistic Vlasov-Maxwell-Landau system with the specular reflection boundary condition[J]. SIAM Journal on Mathematical Analysis, 2024, 56(5):6613-6688.
- [23] 张鑫, 刘泽功, 常帅, 等. 爆破荷载作用下煤岩本构模型参数特性研究[J]. 振动与冲击, 2025, 44(5):263-277.
- [23] ZHANG Xin, LIU Ze-gong, CHANG Shuai, et al. Study on the parameter characteristics of the constitutive model of coal and rock under blasting load[J]. Vibration and Impact, 2025, 44(5):263-277. (in Chinese)
- [24] LIN Ming-hua, LIN Bai-quan, YANG Wei, et al. Study on influence of preset circular holes on propagation of blast-induced cracks based on experiments and discrete element simulations[J]. Rock Mechanics and Rock Engineering, 2024, 57(11):9597-9616.
- [25] 朱宝合, 郑邦友, 戴亦军. 复杂条件下隧道揭煤前段爆破施工工艺[J]. 煤矿安全, 2019, 50(11):144-148.
- [25] ZHU Bao-he, ZHENG Bang-you, DAI Yi-jun. Blasting construction technology in the front section of tunnel uncovering coal under complex conditions[J]. Coal Mine Safety, 2019, 50(11):144-148. (in Chinese)
- [26] 陈一曦, 钟明寿, 刘影, 等. 平行掏槽孔内延时爆破技术的 SPH-FEM 数值模拟[J]. 工程爆破, 2023, 29(3):55-62.
- [26] CHEN Yi-xi, ZHONG Ming-shou, LIU Ying, et al. SPH-FEM numerical simulation of delayed blasting technology in parallel cut holes[J]. Engineering Blasting, 2023, 29(3):55-62. (in Chinese)
- [27] MA Long-hao, LIN Fei, DU Yan-qiang, et al. Blasting profile evaluation of sand-mud interbedded surrounding rock during the large-span tunnel construction[J]. Scientific Reports, 2024, 14(1):12405-12405.
- [28] WANG An-tong, TAO Tie-jun, TIAN Xing-chao, et al. Analysis of the influence of shear-tensile resistance and rock-breaking effect of cutting holes[J]. Scientific Reports, 2024, 14(1):4917-4917.
- [29] 李玉华, 高亚伟, 钟秋锋, 等. 不同掏槽孔角度下隧道楔形掏槽爆破效果研究[J]. 现代隧道技术, 2025, 62(3):108-116.
- [29] LI Yu-hua, GAO Ya-wei, ZHONG Qiu-feng, et al. Study on wedge cutting blasting effect of tunnel under different cutting hole angles[J]. Modern Tunnel Technology, 2025, 62(3):108-116. (in Chinese)
- [30] YU Tao, SUN Jun-feng, WANG Jian-feng, et al. Study on the Propagation Law and Waveform Characteristics of a Blasting Shock Wave in a Highway Tunnel with the Bench Method[J]. Buildings, 2024, 14(9):2802-2802.
- [31] TB 10120—2019 铁路瓦斯隧道技术规范[S]. 2019.