

中文引用格式:王淑贤,杨溢,石玉莲,等. 基于 GA-QLightGBM 分位数回归的爆破块度预测模型[J]. 中国安全科学学报, 2026, 36(2): 163–171.

英文引用格式:WANG Shuxian, YANG Yi, SHI Yulian, et al. Prediction model of blasting fragmentation based on GA-QLightGBM quantile regression[J]. China Safety Science Journal, 2026, 36(2): 163–171.

基于 GA-QLightGBM 分位数回归的爆破块度预测模型*

王淑贤¹, 杨溢^{**1}教授, 石玉莲², 沈亚奎³

(1 昆明理工大学 公共安全与应急管理学院, 云南 昆明 650032; 2 昆明理工大学 国土资源工程学院, 云南 昆明 650032; 3 天津大学 建筑工程学院, 天津 300072)

中图分类号: X932; TD235

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2026.02.0434

基金项目: 国家自然科学基金资助(41861134008)。

【摘要】 针对矿山爆破块度预测中存在的 uncertainty 高、影响因素复杂等问题, 提出一种融合遗传算法(GA)优化与分位数回归的轻量级梯度提升机(LightGBM)预测模型(GA-QLightGBM)。首先, 利用 GA 优化 LightGBM 超参数, 通过模拟自然选择过程(选择、交叉、变异)进行寻优, 提升模型预测精度与稳定性; 然后, 通过设置不同分位数构建爆破块度的预测区间, 量化预测结果的 uncertainty; 最后, 将该模型应用于矿山实测数据集, 对比验证其预测性能与泛化能力, 为爆破块度预测及 uncertainty 分析提供新思路。结果表明: 该模型在点预测方面的决定系数为 0.880, 均方误差(MSE)为 0.004, 优于传统点预测模型; 在区间预测方面, 覆盖概率(PICP)、归一化平均带宽(PINAW)和修正区间预测精度(CPIA)分别为 0.947、0.228 和 0.762, 验证了 GA-QLightGBM 的准确性与可靠性。

【关键词】 遗传算法(GA); 轻量级梯度提升机(LightGBM); 爆破块度; uncertainty; 分位数回归; 预测模型

Prediction model of blasting fragmentation based on GA-QLightGBM quantile regression

WANG Shuxian¹, YANG Yi¹, SHI Yulian², SHEN Yaxi³

(1 Faculty of Public Safety and Emergency Management, Kunming University of Science and Technology, Kunming Yunnan 650032, China; 2 School of Land and Resource Engineering, Kunming University of Science and Technology, Kunming Yunnan 650032, China; 3 School of Architecture and Engineering, Tianjin University, Tianjin 300072, China)

Abstract: To address the challenges of high uncertainty and complex influencing factors in predicting blast fragmentation in mining operations, this study proposed a LightGBM prediction model GA-QLightGBM that integrated GA optimisation with quantile regression. First, GA was employed to optimise the hyperparameters of LightGBM by simulating the natural selection process (selection, crossover, and mutation), thereby improving the model's predictive accuracy and stability. Then, different quantiles were set to construct prediction intervals for blast fragmentation, enabling the quantification of prediction

* 文章编号: 1003-3033(2026)02-0163-09; 收稿日期: 2025-09-10; 修稿日期: 2025-12-10

** 通信作者: 杨溢(1965—), 男, 云南大理人, 博士, 教授, 主要从事安全生产、爆破工程研究。E-mail: 2919847230@qq.com。

uncertainty. Finally, the proposed model was applied to mine field datasets to verify its predictive performance and generalisation ability, providing an effective approach for blast fragmentation prediction and uncertainty analysis. The results show that the model achieves a coefficient of determination (R^2) of 0.880 and a mean squared error (MSE) of 0.004 in point prediction, outperforming traditional point prediction models. In interval prediction, the prediction interval coverage probability (PICP), prediction interval normalized average width (PINAW), and corrected prediction interval accuracy (CPIA) are 0.947, 0.228, and 0.762, respectively, confirming the accuracy and reliability of GA-QLightGBM model. These findings offer a practical framework for quantifying the uncertainty of blast fragmentation, supporting refined blast design and risk control in mining engineering.

Keywords: genetic algorithm (GA); light gradient boosting machine (LightGBM); blasting fragmentation; uncertainty; quantile regression; prediction model

0 引言

爆破技术广泛应用于矿山开采^[1]和隧道建设^[2]等领域。而研究表明:炸药总能量中仅20%~30%转化为有效破碎岩石的机械能^[3-4],其他能量主要耗散为地震波^[5]、地面振动^[6]及飞石^[7]等形式,并对周边环境与建(构)筑物产生不利影响。爆破后碎块尺寸(即爆破块度)对后续工程效率具有显著影响,因此,准确预测与控制对优化矿石开采、挖掘及处理工艺至关重要^[8]。

目前,爆破块度预测方法主要分为经验模型^[9]、数值模拟^[10]、统计模型^[11]与实验室测试^[9]等,这些传统方法虽各有优势,但普遍存在局限性,经验模型与统计模型的泛化能力与非线性拟合能力不足;数值模拟方法计算复杂且对输入参数极为敏感;实验室测试则成本高昂且存在尺度效应。因此,基于机器学习的预测方法已成为该领域的新兴研究方向^[12]。然而,现有机器学习方法仍面临2大挑战:①模型性能严重依赖超参数,而传统的网格或随机搜索方法优化效率低、成本高;②研究多聚焦于点预测,难以量化如岩体非均质性、装药随机性等多重因素引入的不确定性^[13],无法为精细化的爆破设计与风险管控提供可信度评估。

鉴于此,笔者拟以爆破块度不确定性预测为对象,系统考虑爆破块度受多源随机因素影响的复杂性,提出基于遗传算法^[14](Genetic Algorithm, GA)优化的轻量级梯度提升机^[15](Light Gradient Boosting Machine, LightGBM)模型超参数配置框架,并引入分位数损失函数实现区间预测,量化预测结果的不确定性,最终建立同时兼顾精度与可信度的爆破块度预测方法体系,以期实现精细化爆破设计与风险管控提供技术支撑。

1 GA-QLightGBM 模型构建理论

1.1 LightGBM

LightGBM 算法在梯度提升决策树(Gradient Boosting Decision Tree, GBDT)基础上,通过引入单边梯度采样(Gradient-based One-Side Sampling, GOSS)、互斥特征捆绑(Exclusive Feature Bundling, EFB)以及基于直方图等技术,显著提升了大规模数据及高维特征下的训练效率与精度。其工作原理为:GOSS 是 LightGBM 实现轻量级的关键因素,GOSS 在每次迭代时保留所有梯度较大的样本,并仅随机采样一小部分梯度较小的样本,从而使得 LightGBM 模型在不显著损失精度的情况下,大幅减少计算开销。其采样过程表述为:

$$V_j(d) = \frac{1}{n} \left(\sum_{x_i \in M} g_i + \frac{1-a}{b} \sum_{x_i \in N} g_i \right) \quad (1)$$

式中: $V_j(d)$ 为第 j 个特征上、分裂点 d 时的梯度统计量; n 为原始训练数据中的样本总数; x_i 为第 i 个训练样本; M 为梯度较大的样本集; g_i 为第 i 个样本的梯度(一阶导数), a 和 b 为采样比例; N 为随机采样的梯度较小样本集。此外,在高维稀疏数据中,许多特征是互斥的,EFB 技术通过将多个互斥的特征捆绑成一个单一特征,从而减少特征数量,进一步缓解计算压力。

LightGBM 将连续特征值离散化为直方图,通过遍历直方图来寻找最优分裂点。其分裂增益 I 采用下式计算,并综合考虑一阶梯度 G 和二阶梯度 H 以提升精度:

$$I = \frac{1}{2} \left(\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right) - C \quad (2)$$

式中: G_L 为左子节点中所有样本的一阶梯度之和;

H_L 为左子节点中所有样本的二阶梯度之和; λ 为正则化参数; G_R 为右子节点中所有样本的一阶梯度之和; H_R 为右子节点中所有样本的二阶梯度之和; C 为结构复杂度参数。综上所述,LightGBM 通过 GOSS 和 EFB 技术优化了数据样本和特征空间的利用效率,再结合直方图算法加速了训练过程。尽管该算法对超参数配置较为敏感,但其性能在处理如爆破块度此类具有复杂非线性关系的工程预测问题中具有显著优势,因此,使用 LightGBM 模型作为不确定性预测的基模型。

1.2 GA

为解决 LightGBM 模型超参数配置复杂、人工调参效率低的问题,引入 GA 自动优化其超参数。采用实数编码方式优化 LightGBM 的超参数(包括 n_estimators、max_depth 和 learning_rate)。优化流程包括种群初始化、选择、交叉和变异 4 个主要步骤。首先,生成一定数量的候选参数组合(即初始种群),计算每个个体的模型性能指标(如预测误差)以作为适应度值;随后,在选择阶段,依据适应度比例确定个体被保留的概率,以优先保留性能较优的参数组合;交叉阶段通过模拟二进制交叉在参数间进行信息交换,生成新的候选解;变异阶段采用多项式变异随机扰动部分参数,以保持搜索多样性并避免陷入局部最优。经过多轮迭代后,当达到最大迭代步数或收敛条件时,输出性能最优的超参数组合。该方法通过全局搜索与自适应调整机制,有效提升了 LightGBM 超参数寻优的效率与模型的预测精度。

1.3 分位数损失

分位数损失是一种回归损失函数,通过赋予不同分位数预测误差非对称权重,适用于不同置信水平的预测需求^[16]。爆破过程受岩石特性、炸药性能及地质条件等多变因素影响,导致块度分布具有高度不确定性及随机性。即使参数相同,微小扰动亦可能导致结果差异,使点预测难以准确表征实际分布。因此,在数据有限或高不确定性条件下,块度的区间预测可提供更可靠的结果。其表达式为:

$$F_{\alpha}(y_i, \hat{y}_i) = \sum_{i: y_i < \hat{y}_i} (1 - \alpha) |y_i - \hat{y}_i| + \sum_{i: y_i \geq \hat{y}_i} \alpha |y_i - \hat{y}_i|$$

(3)

式中: $F_{\alpha}(y_i, \hat{y}_i)$ 为在给定分位数 α 条件下真实值和预测值的分位数损失; y_i 为样本真实值; $\hat{y}_i$ 为预测模型生成的预测值;通过设定不同的分位数 α ,预测模型会生成不同预测值 $\hat{y}_i$,不同预测值 $\hat{y}_i$ 构成的

区间范围即为模型的预测区间。此外,称 $\alpha = 0.5$ 时的点预测模型为中位数回归模型。区间预测上限设置 $\alpha = 0.95$,区间预测下限设置 $\alpha = 0.05$ 。

2 GA-QLightGBM 预测模型构建

基于 LightGBM、GA 优化及分位数损失理论,构建 GA-QLightGBM 模型。该模型通过设定不同分位数直接构建爆破块度预测区间,旨在克服常规点预测模型因不确定性导致的误差问题,实现预测不确定性的量化。模型性能通过实际工程案例评估。模型构建步骤如下:

步骤 1:预测模型输入参数确定。基于收集的爆破案例数据构建数据库,经过数据清洗及预处理后,分析爆破设计参数与爆破块度的相关性以确定模型输入变量。包括:①计算各爆破设计参数间的皮尔逊相关系数;②统计数据集中爆破设计数据属性(特征和标签)的分布情况及独立性。

步骤 2:模型训练与优化。以 LightGBM 为基础预测模型,采用 GA 优化超参数,结合嵌套 5 折交叉验证评估性能。通过引入分位数损失函数构建预测区间:设置最小化分位数损失为区间预测优化目标,生成不同分位数 α 对应预测值形成预测区间(上限设置 $\alpha = 0.95$,区间预测下限设置 $\alpha = 0.05$);当 $\alpha = 0.5$ 时构成中位数回归模型,其超参数优化目标为最大化决定系数 R^2 。超参数优化流程为:随机初始




图 1 超参数寻优嵌套 5 折交叉验证

Fig. 1 Flowchart of hyperparameter optimization with nested 5-fold cross-validation

化种群后,利用 GA 进行迭代执行选择、交叉和变异操作。对每个超参数组合实施嵌套 5 折交叉验证(图 1),其中内层循环将训练集 5 等分,轮转使用 4 份训练模型、1 份验证,重复 5 次计算适应度均值;外层循环据此评估超参数性能。通过选择高适应度个体更新种群,直至满足终止条件输出最优超参数:内层 5 次验证均值确定参数取值,外层 5 次测试均值作为最终性能指标。

步骤 3:预测模型结果对比与性能评价。选取 6 种点预测模型(①GA-LightGBM 均值回归;②GA-QRF 中位数回归;③GA-RF 均值回归;④GA-QKNN 中位数回归;⑤GA-KNN 均值回归;⑥经验公式)与

2 种区间预测模型(⑦GA-QRF 分位数回归;⑧GA-QKNN 分位数回归)进行性能对比。通过预处理数据集验证:GA-QLightGBM 分位数回归模型直接构建的爆破块度预测区间可有效量化预测不确定性,为爆破参数优化决策提供信息支持。采用决定系数 R^2 、均方误差 (Mean Squared Error, MSE)、区间覆盖概率 (Prediction Interval Coverage Probability, PICP)、区间归一化平均带宽 (Prediction Interval Normalized Average Width, PINAW) 以及修正区间预测精度 (Corrected Prediction Interval Accuracy, CPIA) 指标进行综合评价模型预测精度与计算效率。GA-QLightGBM 爆破块度预测模型流程如图 2 所示。




图 2 GA-QLightGBM 模型建立流程
Fig. 2 Flowchart of GA-QLightGBM model development

3 GA-QLightGBM 预测模型的应用

3.1 数据预处理

3.1.1 数据选择

由文献[17]可知:将爆破设计参数考虑为比值能够有效简化模型,提高预测精度,并便于参数优化,因此,采用爆破设计参数比值替代原始参数。模型训练数据来自 7 座矿山爆破案例。验证数据集划分鲁棒性表明:当训练集占比为 70%、80%与 90%时,测试集的决定系数 R^2 分别为 0.875、0.880 及 0.889。鉴于 80%与 90%区间的决定系数 R^2 差异仅为 0.009,9 : 1 的数据划分会导致测试样本过少,

预测精度缺乏代表性,因此,采用 75 组训练集(80%)与 19 组测试集(20%)的划分方案。表 1 为部分爆破块度样本。

表 1 爆破块度样本

Table 1 Sample of blast fragmentation								
编号	S/B	H/B	B/D	T/B	P_f	X_B	E	X_{50}
1	1.25	3.75	17.98	1.56	1.24	1.53	16.9	0.19
2	1.2	2.8	28.09	1	0.5	1.49	16.9	0.17
3	1.17	1.75	26.2	1.16	0.36	1.56	45	0.76
4	1	2.67	52.17	0.58	0.47	0.95	50	0.11
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
91	1.2	2.4	25	1.4	0.28	0.5	9.57	0.35
92	1.17	1.96	26.2	1.3	0.34	1.56	45	0.75
93	1.14	3.18	24.72	1.14	0.69	2.01	16.9	0.2
94	1	2.67	27.67	0.89	0.75	0.79	50	0.25

3.1.2 特征分析

基于历史爆破块度数据库,剔除重复、缺失及异常样本后,使用皮尔逊相关系数 r (下式) 分析爆破设计参数与块度之间的相关性,建立核密度估计图。考虑特征重要性排序,保留强相关特征 ($|r| \geq 0.75$),弱相关特征进行细化处理,低重要性特征予以剔除。

$$r = \frac{\sum_{i=1}^n (J_i - \bar{J}) (O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (J_i - \bar{J})^2} \sqrt{\sum_{i=1}^n (O_i - \bar{O})^2}} \quad (4)$$

式中: J_i 和 O_i 分别为变量 J 和 O 的样本值; $\bar{J}$ 和 $\bar{O}$ 为相应变量的平均值。




图 3 特征之间的相关系数

Fig. 3 Correlation coefficients between features

图 3 中,每个小图表示 2 个变量之间的关系,对角线区域为各属性核密度估计。分析相关系数上三角矩阵,结果表明:在 8 个属性(7 个特征与 1 个标签)中,炸药单耗 P_f 和排间间距与炮孔直径之比 B/D 之间呈弱相关。其余属性间不存在相关性。综合核密度估计图,各特征相互独立,故无需缩减数据样本规模。

3.2 评价标准

点预测效果评价指标选取 R^2 和 MSE, R^2 取值范围为 0~1,该值越接近 1,预测性能越好。

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (5)$$

式中: n 为样本总数量; $\hat{y}_i$ 为模型对第 i 个样本的预测值; y_i 为第 i 个样本的真实值; $\bar{y}$ 为所有真实值 y_i 的平均值。

MSE 是真实值与预测值之间差异的平方平均值,该指标通常用于评估模型预测值和真实值之间的偏差程度,数值越低表面模型的预测精度越高。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

用于区间预测的评估指标包括 PICP、PINAW 以及 CPIA。其中:

$$PICP = \frac{1}{n} \sum_{i=1}^n W_i, \quad W_i = \begin{cases} 1 & (L_i \leq y_i \leq U_i) \\ 0 & (\text{otherwise}) \end{cases} \quad (7)$$

式中:PICP 为真实值落入预测区间的概率大小; W_i 为

指示函数; L_i 为预测区间的下限; y_i 为实际观测值; U_i 为预测区间的上限,PICP 越大,代表预测效果越好。

$$\text{PINAW} = \frac{1}{nZ} \sum_{i=1}^n (U_i - L_i),$$
$$Z = \max(y_i) - \min(y_i) \quad (8)$$

式中:PINAW 为预测区间的平均宽度; Z 为目标值的极差,用于将预测区间宽度归一化处理; U_i 和 L_i 分别为第 i 个样本的预测区间上限和下限,PINAW 越大,代表预测区间的平均宽度越大。

CPIA 综合式 (8) 和式 (9) 2 种可靠性准则指标,提供一个更全面的预测性能度量:

$$\text{CPIA} = \frac{1}{n}(1 - \text{PINAW}) \sum_{i=1}^n \gamma_i, \gamma_i =$$
$$\begin{cases} 1 - \frac{L_i - y_i}{d_i}, & y_i \in \left[L_i - \frac{d_i}{2}, L_i \right) \\ 1, & y_i \in [L_i, U_i] \\ 1 - \frac{y_i - U_i}{d_i}, & y_i \in \left(U_i, U_i + \frac{d_i}{2} \right] \\ 0, & d_i = U_i - L_i \end{cases} \quad (9)$$

式中: γ_i 为一个依赖预测区间和实际观测值位置的函数; $d_i = U_i - L_i$ 为第 i 个样本的预测区间宽度, CPIA 越大,代表区间预测效果越好。

3.3 预测模型参数选择

采用 GA 寻优 LightGBM 模型的超参数。为平衡搜索效率与全局收敛性,GA 参数设定如下:种群规模为 50,最大迭代步数为 50,交叉概率设定 0.8,变异概率设定 0.1。

寻优后的模型最佳超参数见表 2—表 3,其中,表 2 为中位数回归模型的点预测最优超参数;表 3 为用于区间预测的区间上限和区间下限所采用的最优超参数。

表 2 文中模型($\alpha=0.5$)的最优超参数

Table 2 Optimal hyperparameters for proposed GA-QLightGBM model ($\alpha=0.5$)	
算法	中位数回归模型-最优超参数
GA-QLightGBM 中位数回归	n_estimators = 491 max_depth = 19 learning_rate = 0.077 019 412 1

表 3 文中模型($\alpha=0.05\&0.95$)的最优超参数

Table 3 Optimal hyperparameters for proposed GA-QLightGBM model ($\alpha=0.05 \& 0.95$)		
算法	区间预测模型-区间上限最优超参数	区间预测模型-区间下限最优超参数
GA-QLightGBM 分位数回归	n_estimators = 492 max_depth = 11 learning_rate = 0.094 235 605 5	n_estimators = 485 max_depth = 17 learning_rate = 0.082 550 947 7

图 4a 展示了使用 GA 优化 QLightGBM 进行中位数预测的过程,当 GA 到第 12 次迭代时,生成最优 R^2 值 (0.880);图 4b 展示了使用 GA 优化 QLightGBM 进行区间下限预测的过程,当 GA 到第

16 次迭代时,生成最优分位数损失 (0.007 0);图 4c 展示了使用 GA 优化 QLightGBM 进行区间上限预测的过程,当 GA 到第 24 步迭代时,生成最优分位数损失 (0.019)。




图 4 预测结果
Fig. 4 Prediction results

3.4 预测模型对比分析

为系统评估基于 GA-QLightGBM 分位数回归的爆破块度预测模型在点估计和区间预测方面的综合性能,设计多维度对比试验。在确定性预测评估中,

常用的经验模型为 Kua-Ram 模型^[18],通过爆炸能量、岩石体积和炸药特性预估爆破块度,表达式为:

$$X_{50} = A \cdot K^{-0.8} \cdot Q^{\frac{1}{6}} \cdot \left(\frac{115}{\text{RWS}} \right)^{\frac{19}{30}},$$

其中, A 为岩石系数

(经验值); K 为炸药单耗; Q 为单孔装药量;RWS 为炸药相对威力。在相同测试集上选取以下 6 类优化模型进行对比:① GA-LightGBM 均值回归模型;② GA-QRF 中位数回归模型;③ GA-RF 均值回归模型;④ GA-QKNN 中位数回归模型;⑤ GA-KNN 均值回归模型;⑥ 经验公式。在不确定性预测评估方面,

引入⑦ GA-QRF 分位数回归模型和⑧ GA-QKNN 分位数回归模型作为对比。

所有对比模型均基于经预处理的训练集构建,模型训练完成后,采用测试集进行性能评估,所得量化指标见表 4 和表 5。为确保对比试验设置合理,各对比模型的超参数优化过程与基准模型保持完全一致。

表 4 不同点预测模型 R^2 和 MSE 值
Table 4 R^2 and MSE values of different point prediction models

评价指标	* GA-QLightGBM 中位数回归	①GA-LightGBM 均值回归模型	②GA-QRF 中位数回归 模型	③GA-RF 均值回归 模型	④GA-QKNN 中位数回 归模型	⑤GA-KNN 均值回归 模型	⑥经验 公式
R^2	0.880	0.861	0.841	0.831	0.839	0.789	0.793
MSE	0.004	0.005	0.006	0.006	0.006	0.008	0.007

注: * 为本文提出的模型。

表 5 不同分位数预测模型 PICP、PINAW 以及 CPIA 值
Table 5 PICP, PINAW and CPIA of different
quantile prediction models

评价指标	** GA-QLightGBM 分位数回归	⑦GA-QRF 分位数回 归模型	⑧GA-QKNN 分位数回 归模型
PICP	0.947	0.684	0.526
PINAW	0.228	0.338	0.254
CPIA	0.762	0.640	0.574

注: * 为本文提出的模型。

结果表明:GA-QLightGBM 模型在爆破块度预测中展现出显著优势。在点估计方面,其中位数回归模型获得最优性能指标 ($R^2 = 0.880$, $MSE = 0.004$),较基准模型提升显著;在不确定性量化方面,分位数回归模型以 $PICP = 0.947$ 、 $PINAW = 0.228$ 和 $CPIA = 0.762$ 的评估结果,验证了其高精度区间预测能力。值得注意的是,通过分位数参数 α 的灵活配置实现了预测功能的可扩展性:当 $\alpha = 0.5$ 时执行中位数回归(点估计),而 $\alpha = 0.05 \& 0.95$ 组合则可构建置信度为 90%的预测区间,这种参数化机制为不同应用场景提供了自适应解决方案。

图 5 展示了模型点预测值与实测值的对比关系,可见 19 组测试样本中最大绝对误差仅为 0.15,显示出良好的预测稳定性。在区间预测性能方面(图 6),模型的预测区间成功覆盖了 18 组测试样本(覆盖率 94.7%),且区间宽度始终维持在较低水平($PINAW = 0.228$),表明其能在保证预测精度的同时提供充分的信息量。与传统点估计模型相比,混合建模框架通过融合分位数回归与 GA 优化,有效实现了爆破块度不确定性的量化表征。图 5 和图 6 数据表明:该框架的预测精度 ($R^2 = 0.880$) 与区间覆

盖率 ($PICP = 94.7\%$) 较传统方法提升显著,为爆破参数的智能优化提供了理论依据和技术支撑。




图 5 真实值与模型预测值之间的差异
Fig. 5 Difference between actual values and
model prediction values




图 6 真实值与模型区间预测值关系
Fig. 6 Relationship between actual values and
model interval prediction values

4 结 论

1) GA 优化 LightGBM 超参数并引入分位数损失函数构建的区间预测模型,能够有效处理爆破块度预测中的不确定性和复杂性。所选 8 项指标可表征爆破块度非线性特性且工程易量化,参数独立性验证表明联合优化后整体预测效果显著提升。

2) GA-QLightGBM 模型基于 GA 与分位数回归理论构建,采用现场可快速获取的爆破设计比值作为输入参数,避免了传统方法对原位试验的依赖。

经实际工程数据验证,该模型在点预测 ($R^2=0.880$, $MSE=0.004$) 和区间预测 ($PICP=0.947$, $PINAW=0.228$, $CPIA=0.762$) 性能上均优于 7 类对比模型,显示出对现场参数区间估计的可靠性。

3) 受限于现有数据采集技术对动态施工扰动的量化精度不足问题,以及多源误差耦合机制的理论建模难度较高,尚未构建施工扰动(钻孔偏差、装药波动、节理渗水)的误差传递机制。现场管控不足时设计参数失准会降低预测可靠性。未来研究可围绕多源扰动的动态耦合模型开发,以实现爆破全周期的智能精准控制。

参 考 文 献

[1] LIU Jianpo, ZHANG Changyin, SI Yingtao, et al. Temporal-spatial evolution of acoustic emission during progressive fracture processes around tunnel triggered by blast-induced disturbances under uniaxial and biaxial compression[J]. Tunnelling and Underground Space Technology, 2020, 96:DOI:10.1016/j.tust.2019.103229.

[2] KIM Y, LEE S. A study of the effects of geological conditions on Korean tunnel construction time using the updated NTNU drill and blast prediction model[J]. Applied Sciences-Basel, 2021, 11(21):DOI:10.3390/app112110096.

[3] LU Wenbo, LENG Zhendong, CHEN Ming, et al. A modified model to calculate the size of the crushed zone around a blast-hole[J]. Journal of the Southern African Institute of Mining and Metallurgy, 2016, 116(5): 412-422.

[4] SINGH T, SINGH V. An intelligent approach to prediction and control ground vibration in mines[J]. Geotechnical and Geological Engineering, 2005, 23(3): 249-262.

[5] TRIVINO L, MOHANTY B. Assessment of crack initiation and propagation in rock from explosion-induced stress waves and gas expansion by cross-hole seismometry and FEM-DEM method[J]. International Journal of Rock Mechanics and Mining Sciences, 2015, 77: 287-299.

[6] CHEN Yong, LONG Feiyu, KUANG Wei, et al. A method for predicting blast-induced ground vibration based on Mamdani fuzzy inference system[J]. Journal of Intelligent & Fuzzy Systems, 2023, 44(5): 7 513-7 522.

[7] TRIVEDI R, SINGH T N, GUPTA N. Prediction of blast-induced flyrock in opencast mines using ANN and ANFIS[J]. Geotechnical and Geological Engineering, 2015, 33(4): 875-891.

[8] 田睿, 孟海东, 陈世江, 等. RF-AHP-云模型下岩爆烈度分级预测模型[J]. 中国安全科学学报, 2020, 30(7): 166-172.

TIAN Rui, MENG Haidong, CHEN Shijiang, et al. Prediction model of rockburst intensity classification based on RF-AHP-Cloud model[J]. China Safety Science Journal, 2020, 30(7): 166-172.

[9] 吴发名, 刘勇林, 李洪涛, 等. 基于原生节理统计和爆破裂纹模拟的堆石料块度分布预测[J]. 岩石力学与工程学报, 2017, 36(6): 1 341-1 352.

WU Faming, LIU Yonglin, LI Hongtao, et al. Fragmentation distribution prediction of rockfill materials based on statistical results of primary joints and simulation of blasting cracks[J]. Chinese Journal of Rock Mechanics and Engineering, 2017, 36(6): 1 341-1 352.

[10] 曹泽铭, 杨建华, 叶志伟, 等. 地应力对岩体爆破块度分布特征的影响研究[J]. 岩土工程学报, 2024, 46(10): 2 202-2 211.

CAO Zeming, YANG Jianhua, YE Zhiwei, et al. Influences of in-situ stress on distribution characteristics of rock blasting fragmentation[J]. Chinese Journal of Geotechnical Engineering, 2024, 46(10): 2 202-2 211.

[11] 武仁杰, 李海波, 于崇, 等. 基于统计分级判别的爆破块度预测模型[J]. 岩石力学与工程学报, 2018, 37(1): 141-147.

WU Renjie, LI Haibo, YU Chong, et al. Model for blasting fragmentation prediction based on statistical classification[J].

Chinese Journal of Rock Mechanics and Engineering, 2018, 37(1): 141-147.

[12] 崔铁军, 马云东, 白润才. 基于 ANN 耦合遗传算法的爆破方案选择方法[J]. 中国安全科学学报, 2013, 23(2): 64-68.

CUI Tiejun, MA Yundong, BAI Runcai. Selection of blast scheme based on coupling of genetic algorithm and artificial neural network[J]. China Safety Science Journal, 2013, 23(2): 64-68.

[13] 刘英, 毛羽, 徐士超, 等. 基于 PSO-BPNN 模型的爆破块度预测[J]. 爆破, 2024, 41(2): 136-142.

LIU Ying, MAO Yu, XU Shichao, et al. Blasting fragmentation prediction based on PSO-BPNN model[J]. Blasting, 2024, 41(2): 136-142.

[14] MIRJALILI S, DONG Jinsong, SADIQ A S, et al. Genetic algorithm: theory, literature review, and application in image reconstruction[J]. Nature-inspired optimizers: Theories, Literature Reviews and Applications, 2019, 811: 69-85.

[15] KE Guolin, MENG Qi, FINLEY T, et al. LightGBM: a highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems, 2017, 30: 3 146-3 154.

[16] KOENKER R, BASSETT J G W. March madness, quantile regression bracketology, and the Hayek hypothesis[J]. Journal of Business & Economic Statistics, 2010, 28(1): 26-35.

[17] 陈程, 李全明. 地下矿山巷道掘进凿岩爆破技术参数优化研究进展与展望[J]. 中国矿业, 2023, 32(10): 103-110.

CHEN Cheng, LI Quanming. Research progress and prospect of parameters optimization of rock drilling and blasting technical in underground mine roadway excavation[J]. China Mining Magazine, 2023, 32(10): 103-110.

[18] 陈起建. 隧道岩体爆破碎片预测方法对比研究[J]. 工程爆破, 2023, 29(4): 78-86.

CHEN Qijian. Comparative study on prediction methods of blasting debris in tunnelrock mass[J]. Engineering Blasting, 2023, 29(4): 78-86.

作者简介：王淑贤（2001—），女，云南曲靖人，硕士研究生，主要研究方向为爆破安全。
E-mail:1766018969@qq.com。

