

doi:10.3963/j.issn.1001-487X.2022.01.003

## LOO-XGboost 模型预测岩石爆破块度\*

叶海旺<sup>1a,2</sup>, 胡俊杰<sup>1b</sup>, 雷涛<sup>1a,2</sup>, 李宁<sup>1a,2</sup>, 王其洲<sup>1a,2</sup>, DAHÉ MONYEGNI GHISLAIN<sup>1a</sup>

(1. 武汉理工大学 a. 资源与环境工程学院; b. 安全科学与应急管理学院, 武汉 430070;

2. 矿物资源加工与环境湖北省重点实验室, 武汉 430070)

**摘要:** 针对小样本条件下使用机器学习方法预测岩石爆破块度存在的数据利用率不足, 预测精度存在浮动较大的问题。将留一法(LOO)与极限梯度提升(XGboost)算法结合, 利用 Python 3.7 构建 LOO-XGboost 岩石爆破块度预测模型, 选取 31 组爆破数据进行 LOO-XGboost 模型训练与预测, 通过调用不同参数, 得到模型的最优内置参数如下: 求解方式为树模型, 学习率为 0.30, 决策树数量为 50, 决策树最大迭代深度为 3, 叶子节点最小样本数为 3, 随机采样比例为 0.8。将预测结果与同条件下的支持向量机回归(SVR)、BP 神经网络(BPNN)、随机森林(RF)模型以及 10 折交叉验证下的 XGboost 模型进行对比, 对比结果为 LOO-XGboost 模型预测精度明显高于其他 4 种模型, 其相关系数、均方根误差、平均绝对误差分别为 0.9128、0.0587、0.0342。结果表明: LOO-XGboost 模型既保证了小样本情况下的数据利用率, 又提高了预测精度, 适合应用于岩石爆破块度预测。

**关键词:** 岩石块度; LOO-XGboost 模型; 小样本预测; 模型对比; Python 3.7

**中图分类号:** TD235.3      **文献标识码:** A      **文章编号:** 1001-487X(2022)01-0016-06

## Fragmentation Prediction of Rock Blasting by LOO-XGboost Model

YE Hai-wang<sup>1a,2</sup>, HU Jun-jie<sup>1b</sup>, LEI Tao<sup>1a,2</sup>, LI Ning<sup>1a,2</sup>,

WANG Qi-zhou<sup>1a,2</sup>, DAHÉ MONYEGNI GHISLAIN<sup>1a</sup>

(1. a. School of Resources and Environmental Engineering; b. School of Safety Science and Emergency Management, Wuhan University of Technology, Wuhan 430070, China;

2. Key Laboratory of Mineral Resources Processing and Environment Hubei Province, Wuhan 430070, China)

**Abstract:** In order to solve the problems of insufficient data utilization and large fluctuation of prediction accuracy in predicting rock blasting fragmentation using machine learning method under the condition of small samples, a LOO-XGboost model is built by Python 3.7, which combines the leave-one-out method(LOO) with the eXtreme Gradient Boosting(XGboost) algorithm. Firstly, 31 sets of blasting data are selected for training and prediction. By calling different parameters, the optimal built-in parameters of the model are obtained as follows: tree model as solution method, the learning rate of 0.30, the number of decision trees of 50, the maximum iteration depth of the decision tree of 3, the minimum sample number of leaf nodes of 3, and the random sampling ratio of 0.8. Through comparing the prediction results with the support vector machine regression(SVR), BP neural network(BPNN), random forest(RF) model and XGboost model under 10 fold cross validation under the same conditions, the LOO-XGboost model has significantly higher prediction accuracy than the other four models. The correlation coefficient, root mean square error, and average absolute error are 0.9128, 0.0587 and 0.0342, respectively. The results show that the LOO-XGboost model can not only guarantee the data utilization in the case of small samples, but also improve the prediction accuracy, and it is suitable for the prediction of rock blasting fragmentation.

**Key words:** rock fragmentation; LOO-XGboost model; small sample prediction; model comparison; Python 3.7

岩石爆破块度是衡量生产爆破效果最重要的指标之一, 岩石爆破后的块度制约着后续生产过程中的装载、拖运和破碎作业等。因此国内外专家对爆破块度预测做了许多研究, Gheibie 等提出了一种效果较好的 Kuz-Ram 爆破块度预测模型<sup>[1]</sup>。聂军等证明了 GEM 方法在爆破块度预测方面的可靠性<sup>[2]</sup>。史秀志等得出 SVM、LS-SVR 方法预测岩石爆破块度优于 Kuz-Ram 公式法<sup>[3,4]</sup>。刘阳等提出随机森林和 GA-BP 神经网络方法优于多元回归以及 BP 神经网络<sup>[5]</sup>。唐跃等基于 10 折交叉验证证明了 RBF 核优于线性核, 且单次随机试验的随机误差大<sup>[6]</sup>。柳小波等证明了 RBF 核函数的神经网络优于 BP 神经网络<sup>[7]</sup>。潘玉忠等证明了 SVM 模型优于 BP 神经网络模型<sup>[8]</sup>。王仁超等基于 10 折交叉验证证明了随机森林模型优于 BPNN、SVR 模型<sup>[9]</sup>。岩石爆破实验成本较高, 因此爆破块度预测的数据样本量较少, 为了让爆破数据得到客观充分的利用, 提高预测精度, 运用留一法 (Leave-One-Out, LOO) 对爆破数据进行预处理, 然后导入 XGboost 算法 (eXtreme Gradient Boosting, XGboost)<sup>[10]</sup>, 使用 Python 3.7 构建 LOO-XGboost 模型来对岩石块度进行预测。

## 1 留一法与极限梯度提升算法原理

### 1.1 留一法 (LOO)

留一法 (LOO) 属于交叉验证法的特殊情况, 它将每条数据都作为一次测试集, 除测试集外的数据皆作为训练集, 充分利用所有数据, 训练与数据量相同的次数, 以此类推得到所有数据的预测值。

### 1.2 极限梯度提升 (XGboost)

极限梯度提升 (XGBoost) 属于集成学习算法, 是近年来机器学习中表现较好的算法<sup>[11]</sup>, XGboost 在目标函数中加上了正则化项, 此外 XGboost 算法使用到了二阶导数, 损失更精确。XGBoost 算法基本原理如下<sup>[12-15]</sup>, 对于给定数据集  $D = \{(X_i, y_i)\}$ ,  $K$  个集成树模型的输出为

$$\hat{y}_i = \phi(X_i) = \sum_{k=1}^K f_k(X_i)$$

$$f_k \in F, F = \{f(x) = w_q(x)\}, (q: R \rightarrow T, w \in R^T)$$
(1)

式中:  $F$  为所有 CART 树的函数空间, 每个  $f_k$  数值为样本点所在叶节点的得分。  $q$  为多个样本点映射到各叶子结点的函数,  $T$  为叶子结点的个数,  $w_i$  代表第  $i$  个叶子节点的得分。

定义带正则项的目标函数为

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (2)$$

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (3)$$

式中:  $\gamma, \lambda$  均为惩罚系数, 经过  $t$  轮迭代后的目标函数为

$$L^{(t)} = \sum_{i=1}^n l[y_i, \hat{y}_i^{(t-1)} + f_i(x)] + \Omega(f_i) \quad (4)$$

为求解最优化问题, 让损失函数  $l(y_i, \Phi)$  在  $\Phi = \hat{y}_i^{(t-1)}$  处进行二阶泰勒展开, 得到最优解目标函数为

$$\tilde{L}^{(t)} = \sum_{i=1}^n \left[ g_i w_q(x_i) + \frac{1}{2} h_i w_q^2(x_i) \right] + \gamma T + \frac{1}{2} \gamma \sum_j w_j^2 \quad (5)$$

再设  $I_j$  表示第  $j$  个叶子节点中所有的样本, 即  $I_j = \{i | q(x_i) = j\}$ , 对  $x_i \in I_j$  有  $w_q(x_i) = w_j$ , 则目标函数可写成

$$\hat{L}^{(t)} = \sum_{j=1}^T \left[ G_j w_j + \frac{1}{2} (H_j + \gamma) w_j^2 \right] + \gamma T \quad (6)$$

式中:  $G_j = \sum_{i \in I_j} g_i, H_j = \sum_{i \in I_j} h_i$ , 偏导数等于零时的最优参数为

$$w_j^* = - \frac{G_j}{H_j + \lambda} \quad (7)$$

则最小损失的目标函数如下

$$\tilde{L}_{\min} = - \frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (8)$$

信息增益 (Information Gain) 为

$$G_{\text{ain}} = \frac{1}{2} \left[ \frac{G_j^2}{H_j + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G_L + G_R}{H_L + H_R + \lambda} \right] - \gamma \quad (9)$$

XGboost 算法在每轮测试时都会求出一个最优的信息增益, 然后根据这个最优的信息增益来指导生成决策树, 通过不断迭代找到最优树模型。

## 2 模型建立

T Hudaverdi 等收集了世界上 6 座不同矿山的爆破数据建立了包含 97 组样本的小型爆破数据库<sup>[16]</sup>, 研究人员考虑了主要的爆破设计参数并将其综合为 7 个影响因子: 孔距与抵抗线比 ( $S/B$ ), 台阶高度与抵抗线比 ( $H/B$ ), 抵抗线与孔径比 ( $B/D$ ), 堵塞长度与抵抗线比 ( $T/B$ ), 炸药单耗 ( $PF$ ), 平均原

收稿日期: 2021-09-01

作者简介: 叶海旺 (1971-), 男, 教授、博士, 主要从事采矿、爆破、安全等方面的教学和科研工作, (E-mail) yehaiwang@sina.com。

通讯作者: 雷涛 (1983-), 男, 讲师、博士, 主要从事采矿、数字化矿山方面的教学和科研工作, (E-mail) 354810915g@qq.com。

基金项目: 国家重点研发计划 (2020YFC1909602, 2021YFC2902901); 湖北省重点研发计划 (2021BCA152)

岩块度( $XB$ ),弹性模量( $E$ ),取其中 31 组爆破数据 来进行模型检验,详细数据见表 1。

表 1 爆破数据样本  
Table 1 Blasting data samples

No	S/B	H/B	B/D	T/B	PF/(kg · m <sup>-3</sup> )	XB/m	E/GPa	X <sub>50</sub> /m
1	1.24	1.33	27.27	0.78	0.48	0.58	60.00	0.37
2	1.24	1.33	27.27	0.78	0.48	0.58	60.00	0.37
3	1.24	1.33	27.27	0.78	0.48	1.08	60.00	0.33
4	1.24	1.33	27.27	0.78	0.48	1.11	60.00	0.42
5	1.17	1.50	26.20	1.12	0.30	0.68	45.00	0.48
6	1.17	1.58	26.20	1.22	0.28	0.68	45.00	0.48
7	1.17	1.96	26.20	1.30	0.34	1.56	45.00	0.75
8	1.17	1.75	26.20	1.31	0.29	1.56	45.00	0.96
9	1.00	2.67	27.27	0.89	0.75	0.83	50.00	0.23
10	1.00	2.67	27.27	0.89	0.75	0.78	50.00	0.25
11	1.00	2.40	30.30	0.80	0.61	1.02	50.00	0.27
12	1.00	2.40	30.30	0.80	0.61	0.75	50.00	0.30
13	1.13	5.00	39.47	1.93	0.31	2.00	45.00	0.64
14	1.20	6.00	32.89	3.67	0.30	2.00	45.00	0.54
15	1.20	6.00	32.89	3.70	0.30	2.00	45.00	0.51
16	1.24	1.33	27.27	0.78	0.48	1.11	60.00	0.47
17	1.13	5.00	39.47	3.11	0.31	2.00	45.00	0.64
18	1.00	2.67	27.27	0.89	0.75	0.77	50.00	0.25
19	1.25	2.50	28.57	0.83	0.42	0.50	13.25	0.18
20	1.28	3.61	18.95	1.67	0.89	0.61	16.90	0.20
21	1.20	4.80	28.09	1.20	0.72	0.29	16.90	0.14
22	1.20	4.00	28.09	1.60	0.49	0.81	16.90	0.16
23	1.00	2.83	33.71	1.00	0.48	0.45	15.00	0.27
24	1.20	2.40	28.09	1.00	0.53	0.86	15.00	0.14
25	1.20	2.40	28.57	1.00	0.53	0.44	15.00	0.14
26	1.20	2.40	28.09	1.00	0.53	0.44	15.00	0.20
27	1.25	1.33	27.27	0.83	0.42	1.11	60.00	0.47
28	1.13	5.00	39.49	3.11	0.31	2.00	45.00	0.64
29	1.10	2.40	30.30	0.80	0.56	1.23	50.00	0.44
30	1.00	2.67	27.67	0.89	0.75	0.79	50.00	0.25
31	1.25	6.25	31.58	0.63	0.48	1.03	32.00	0.20

为了提高预测精度,提高求解速度,预测之前,对数据进行归一化(Normalization)预处理,公式如下

$$X_{\text{new}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

式中: $X_{\text{new}}$ 为处理后的数据值, $X_{\min}$ 、 $X_{\max}$ 为数据中的最小、最大值。

使用 Python 3.7 软件建立 LOO-XGboost 预测模型,详细步骤如下:

(1)将归一化后的数据导入到 Python 3.7 中,编写 LOO-XGboost 模型程序。

(2)数据导入 LOO-XGboost 程序进行训练,然后进行参数寻优,得到模型优化参数如下:学习率为

0.30 (learning rate = 0.30), CART 树数量为 50 ( $n_{\text{estimators}} = 50$ ), 最大深度为 3 ( $\text{max\_depth} = 3$ ), 最小叶子结点权重为 3 ( $\text{min\_child\_weight} = 3$ ), 通过 LOO-XGboos 模型,运行 31 次,得到每条测试集的预测值,即 31 组平均粒径( $X_{50}$ )预测值。

(3)计算相关系数( $R^2$ )、均方根误差(RMSE)、平均绝对误差(MAE),流程如图 1,相关公式如下<sup>[17]</sup>

$$R_2 = 1 - \frac{\sum_i (p_i - y_i)^2}{\sum_i (\bar{y}_i - y_i)^2} \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_i (p_i - y_i)^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_i |p_i - y_i| \quad (13)$$

式中:  $y_i$  为  $X_{50}$  真实值,  $p_i$  为  $X_{50}$  预测值,  $\bar{y}_i$  为  $X_{50}$  平均值。

### 3 预测结果分析

将 LOO-XGboost 模型预测的 31 组平均粒度 ( $X_{50}$ ) 与留一法下的支持向量机回归 (LOO-SVR)、BP 神经网络 (LOO-BPNN)、随机森林 (LOO-RF) 模型以及 10 折交叉验证 XGboost 模型 (10FLOD-XGboost) 的预测结果对比, 预测结果保留 2 位小数, 结果如表 2, 图 2。

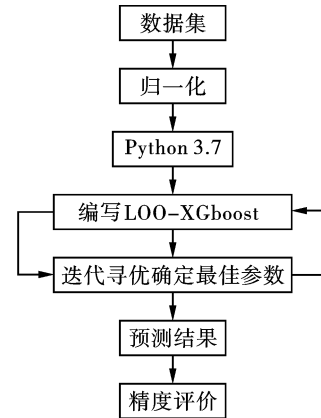


图 1 模型建立流程图

Fig. 1 Flow chart of model establishment

表 2 不同模型的预测结果

Table 2 Comparison of prediction results under different models

No	实际值 ( $X_{50}$ )/m	LOO-SVR	LOO-BPNN	LOO-RF	10FLOD-XGboost	LOO-XGboost
1	0.37	0.33	0.30	0.35	0.38	0.37
2	0.37	0.33	0.30	0.35	0.38	0.37
3	0.33	0.51	0.49	0.45	0.47	0.45
4	0.42	0.44	0.49	0.56	0.47	0.48
5	0.48	0.56	0.52	0.48	0.58	0.50
6	0.48	0.58	0.54	0.52	0.59	0.51
7	0.75	0.82	0.64	0.68	0.83	0.85
8	0.96	0.67	0.58	0.60	0.68	0.69
9	0.23	0.32	0.27	0.25	0.24	0.25
10	0.25	0.31	0.25	0.25	0.25	0.25
11	0.27	0.40	0.34	0.30	0.25	0.27
12	0.30	0.34	0.26	0.27	0.24	0.27
13	0.64	0.56	0.57	0.65	0.66	0.68
14	0.54	0.50	0.62	0.60	0.62	0.52
15	0.51	0.50	0.64	0.63	0.62	0.55
16	0.47	0.44	0.48	0.43	0.45	0.45
17	0.64	0.54	0.61	0.62	0.65	0.64
18	0.25	0.31	0.25	0.25	0.25	0.25
19	0.18	0.23	0.22	0.23	0.24	0.22
20	0.20	0.30	0.12	0.20	0.31	0.21
21	0.14	0.22	0.12	0.17	0.17	0.14
22	0.16	0.27	0.22	0.17	0.29	0.12
23	0.27	0.31	0.21	0.24	0.26	0.25
24	0.14	0.30	0.32	0.21	0.19	0.13
25	0.14	0.20	0.20	0.18	0.21	0.16
26	0.20	0.25	0.16	0.22	0.25	0.21
27	0.47	0.47	0.48	0.44	0.45	0.46
28	0.64	0.54	0.62	0.63	0.63	0.63
29	0.44	0.47	0.37	0.39	0.37	0.44
30	0.25	0.31	0.25	0.25	0.25	0.25
31	0.20	0.36	0.18	0.26	0.18	0.20

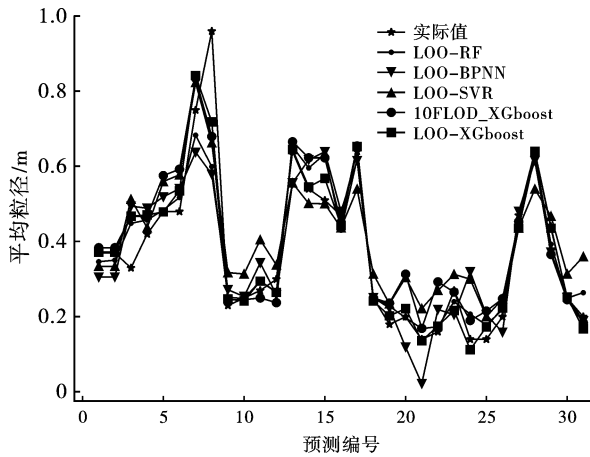


图2 不同模型的预测结果折线图

Fig. 2 Line diagrams of prediction results of different models

计算出各模型的  $R^2$ 、RMSE、MAE 作为评价指

标,结果如表3、图3。

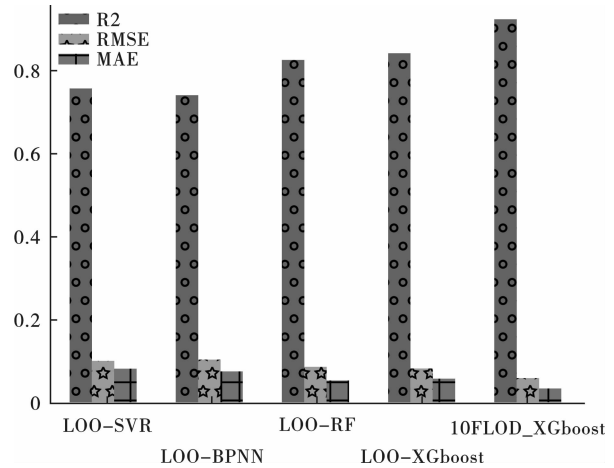


图3 评价指标对比图

Fig. 3 Comparison diagram of evaluation indices

表3 评价指标对比

Table 3 Comparison of evaluation indices

模型	LOO-SVR	LOO-BPNN	LOO-RF	10FLOD-XGboost	LOO-XGboost
$R^2$	0.7478	0.7321	0.8160	0.8320	0.9128
RMSE	0.0998	0.1029	0.0853	0.0814	0.0587
MAE	0.0813	0.0745	0.0531	0.0572	0.0342

根据上述的评价结果可知, LOO-XGboost 模型预测岩石爆破块度的效果最好,  $R^2$  值为 0.9128, RMSE 为 0.0587, MAE 为 0.0342, 而其他模型的  $R^2$  值分别为 0.7478、0.7321、0.8160、0.8320, RMSE 分别为 0.0998、0.1029、0.0853、0.0814, MAE 分别为 0.0813、0.0745、0.0531、0.0572, 综上 LOO-XGboost 预测精度与其他模型相比有较大提高, 并且证明了在块度预测问题上 XGboost 算法比 SVR、BPNN、RF 更优, LOO 比 10 折交叉验证更优。

## 4 结论

(1) 利用 Python 3.7 软件建立 LOO-XGboost 模型用于岩石爆破块度的预测, 解决了数据集划分不合理, 模型训练次数不足的问题。

(2) 根据评价指标对比结果得出预测效果排序为: LOO-XGboost > 10 折交叉验证 XGboost > LOO-RF > LOO-SVR > LOO-BPNN。其中 LOO-XGboost 模型预测的均方误差仅为 0.0587 且相关系数达到了 0.9128, 证明了此模型的优越性。

(3) LOO-XGboost 模型充分利用了所有数据, 预测精度高, 其结果能作为以后岩石平均粒径 ( $X_{50}$ ) 参考值, 对控制岩石爆破块度有指导作用, 对精细化矿

山爆破有积极意义。

## 参考文献 (References)

- [1] GHEIBIE S, AGHABABAEI H, HOSEINIE S H, et al. Modified Kuz-Ram fragmentation model and its use at the Sungun Copper Mine [J]. Int J Rock Mech Min Sci, 2009, 46(6): 967-973.
- [2] 聂军, 史秀志, 陈新, 等. 基于 GEP 的露天矿台阶爆破块度预测模型 [J]. 爆破, 2015, 32(2): 82-88.
- [2] NIE Jun, SHI Xiu-zhi, CHEN Xin, et al. Prediction model of bench blasting fragmentation based on GEP in open-pit mine [J]. Blasting, 2015, 32(2): 82-88. (in Chinese)
- [3] 史秀志, 王洋, 黄丹, 等. 基于 LS-SVR 岩石爆破块度预测 [J]. 爆破, 2016, 33(3): 36-40.
- [3] SHI Xiu-zhi, WANG Yang, HUANG Dan, et al. Based on LS-SVR rock blasting fragmentation prediction [J]. Blasting, 2016, 33(3): 36-40. (in Chinese)
- [4] 史秀志, 周健, 吴帮标, 等. 台阶爆破岩石破碎平均粒径预测的支持向量机方法 (英文) [J]. Transactions of Nonferrous Metals Society of China, 2012, 22(2): 432-441.
- [4] SHI Xiu-zhi, ZHOU Jian, WU Bang-biao, et al. Support vector machine method for predicting average particle size of rock broken by bench blasting (English) [J]. Transac-

- tions of Nonferrous Metals Society of China, 2012, 22(2):432-441. (in Chinese)
- [5] 刘阳,谭凯旋,郭钦鹏,等. 运用随机森林和 GA-BP 神经网络预测岩石爆破块度[J]. 矿业研究与开发, 2021, 41(1):135-140.
- [5] LIU Yang, TAN Kai-xuan, GUO Qin-peng, et al. Using random forest and GA-BP neural network to predict rock blasting fragmentation[J]. Mining Research and Development, 2021, 41(1):135-140. (in Chinese)
- [6] 唐跃,徐曲,柯波,等. 基于交叉验证的矿岩爆破块度 SVM 模型优选研究[J]. 爆破, 2018, 35(3):74-79.
- [6] TANG Yue, XU Qu, KE Bo, et al. Optimization of SVM model of rock fragmentation based on cross-validation [J]. Blasting, 2018, 35(3):74-79. (in Chinese)
- [7] 柳小波,袁鹏喆,张兴帆. 基于 RBF 神经网络的露天矿爆破效果预测研究[J]. 中国矿业, 2020, 29(1):81-84.
- [7] LIU Xiao-bo, YUAN Peng-zhe, ZHANG Xing-fan. Research on the prediction of blasting effect of open-pit mine based on RBF neural network [J]. China Mining, 2020, 29(1):81-84. (in Chinese)
- [8] 潘玉忠,张义平,王强,等. 台阶爆破块度的 SVM 预测模型研究[J]. 矿业研究与开发, 2010, 30(5):97-99.
- [8] PAN Yu-zhong, ZHANG Yi-ping, WANG Qiang, et al. SVM prediction model of bench blasting fragmentation [J]. Mining Research and Development, 2010, 30(5):97-99. (in Chinese)
- [9] 王仁超,朱品光. 基于随机森林回归方法的爆破块度预测模型研究[J]. 水力发电学报, 2020, 39(1):89-101.
- [9] WANG Ren-chao, ZHU Pin-guang. Study on prediction model of blasting fragmentation based on random forest regression method [J]. Journal of Hydroelectric Engineering, 2020, 39(1):89-101. (in Chinese)
- [10] CHEN Tian-qi, CARLOS Guestrin. XGBoost: a scalable tree boosting system. [J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2016, abs/1603.02754.
- [11] 李晨阳,陈雄飞,张勇,等. 基于 XGBoost 的铝合金 LIBS 光谱分类识别方法[J]. 光谱学与光谱分析, 2021, 41(2):624-628.
- [11] LI Chen-yang, CHEN Xiong-fei, ZHANG Yong, et al. Classification and identification method of aluminum alloy LIBS spectrum based on XGBoost [J]. Spectroscopy and Spectral Analysis, 2021, 41(2):624-628. (in Chinese)
- [12] 闫星宇,顾汉明,肖逸飞,等. XGBoost 算法在致密砂岩气储层测井解释中的应用[J]. 石油地球物理勘探, 2019, 54(2):447-455.
- [12] YAN Xing-yu, GU Han-ming, XIAO Yi-fei, et al. Application of XGBoost algorithm in logging interpretation of tight sandstone gas reservoirs [J]. Petroleum Geophysical Prospecting, 2019, 54(2):447-455. (in Chinese)
- [13] 谢学斌,李德玄,孔令燕,等. 基于 CRITIC-XGB 算法的岩爆倾向等级预测模型[J]. 岩石力学与工程学报, 2020, 39(10):1975-1982.
- [13] XIE Xue-bin, LI De-xuan, KONG Ling-yan, et al. Rockburst tendency grade prediction model based on CRITIC-XGB algorithm [J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(10):1975-1982. (in Chinese)
- [14] 张福浩,朱月月,赵习枝,等. 地理因子支持下的滑坡隐患点空间分布特征及识别研究[J]. 武汉大学学报(信息科学版), 2020, 45(8):1233-1244.
- [14] ZHANG Fu-hao, ZHU Yue-yue, ZHAO Xi-zhi, et al. Research on spatial distribution characteristics and identification of landslide hidden danger points supported by geographical factors [J]. Journal of Wuhan University (Information Science Edition), 2020, 45(8):1233-1244. (in Chinese)
- [15] 闫星宇,顾汉明,肖逸飞,等. XGBoost 算法在致密砂岩气储层测井解释中的应用[J]. 石油地球物理勘探, 2019(2):447-455.
- [15] YAN Xing-yu, GU Han-ming, XIAO Yi-fei, et al. Application of XGBoost algorithm in logging interpretation of tight sandstone gas reservoirs [J]. Petroleum Geophysical Prospecting, 2019(2):447-455. (in Chinese)
- [16] HUDAVERDI T, KULATILAKE P H S W, KUZU C. Prediction of blast fragmentation using multivariate analysis procedures [J]. Int J Numer Anal Methods Geomech, 2011, 35(12):1318-1333.
- [17] 王晓晖,张亮,李俊清,等. 基于遗传算法与随机森林的 XGBoost 改进方法研究[J]. 计算机科学, 2020, 47(S2):454-458, 463.
- [17] WANG Xiao-hui, ZHANG Liang, LI Jun-qing, et al. Research on improved method of XGBoost based on genetic algorithm and random forest [J]. Computer Science, 2020, 47(S2):454-458, 463. (in Chinese)