

# 基于 ACO-BP 模型的岩石爆破破碎块度预测<sup>①</sup>

陈莎莎<sup>1,2</sup>, 何理<sup>1,2,3</sup>, 李腾飞<sup>1,2</sup>, 张鑫玥<sup>1,2</sup>, 彭胜<sup>4</sup>, 姚颖康<sup>3</sup>, 刘昌邦<sup>5</sup>, 陈江伟<sup>6</sup>

(1. 武汉科技大学 冶金工业过程系统科学湖北省重点实验室, 湖北 武汉 430065; 2. 湖北省智能爆破工程技术研究中心, 湖北 武汉 430065; 3. 江汉大学 爆破工程湖北重点实验室, 湖北 武汉 430056; 4. 武汉科技大学 城市与建设学院, 湖北 武汉 430065; 5. 武汉爆破有限公司, 湖北 武汉 430056; 6. 中国建筑第七工程局有限公司, 河南 郑州 450004)

**摘要:** 为了对岩石爆破破碎块度进行有效预测, 设计开展了混凝土试件钻孔爆破试验, 得到不同试验条件下的破碎块度归一化值分布, 最终选取试块尺寸 40 mm 以上进行研究。采用 Spearman 相关系数分析各试验条件参数之间的相关性, 再采用蚁群算法 (ACO) 优化 BP 神经网络的初始权值和阈值, 构建 ACO-BP 模型。结合现场试块爆破破碎块度数据对模型进行了训练和测试, 并将预测模型与 BP 神经网络模型、随机森林 (RF) 模型、极限梯度提升 (XGboost) 模型进行了对比。结果表明, ACO-BP 模型预测爆破块度均方根误差为 0.13, 平均绝对误差为 0.11, 决定系数为 0.92, 预测精度和适用性更高, 能够更准确地预测岩石爆破破碎块度。

**关键词:** 岩石爆破; 破碎块度; 模型试验; 块度预测; ACO-BP 模型

中图分类号: TD235

文献标识码: A

doi: 10.3969/j.issn.0253-6099.2024.05.003

文章编号: 0253-6099(2024)05-0012-05

## Prediction of Blast-Induced Rock Fragmentation Based on ACO-BP Model

CHEN Shasha<sup>1,2</sup>, HE Li<sup>1,2,3</sup>, LI Tengfei<sup>1,2</sup>, ZHANG Xinyue<sup>1,2</sup>, PENG Sheng<sup>4</sup>,  
YAO Yinkang<sup>3</sup>, LIU Changbang<sup>5</sup>, CHEN Jiangwei<sup>6</sup>

(1. Hubei Province Key Laboratory of Systems Science in Metallurgical Process, Wuhan University of Science and Technology, Wuhan 430065, Hubei, China; 2. Hubei Provincial Intelligent Blasting Engineering Technology Center, Wuhan 430065, Hubei, China; 3. Hubei Provincial Key Laboratory of Blasting Engineering, Jiangnan University, Wuhan 430056, Hubei, China; 4. School of Urban Construction, Wuhan University of Science and Technology, Wuhan 430065, Hubei, China; 5. Wuhan Explosion & Blasting Co., Ltd., Wuhan 430056, Hubei, China; 6. China Construction Seventh Engineering Division Co., Ltd., Zhengzhou 450004, Henan, China)

**Abstract:** In order to effectively predict blast-induced rock fragmentation, a distribution of normalized rock fragmentation under different conditions was obtained by performing a designed experiment on drilling and blasting of a concrete specimen, and then the rock fragmentation exceeding 40 mm was selected for study. The correlation among variables under different testing conditions was analyzed by using Spearman correlation statistics, and the initial weights and thresholds of the BP neural network were optimized by using the ant colony optimization (ACO) to construct an ACO-BP model. The model was then trained with rock fragmentation by on-site blasting, and tested. Based on the comparison of such prediction mode with BP neural network model, random forest (RF) model and extreme gradient boosting (XGboost) model, it is found that the ACO-BP model is highly reliable in predicting blast-induced rock fragmentation, presenting a root mean square error of 0.13, an average absolute error of 0.11, and a coefficient of determination of 0.92. It is concluded that this model, with higher accuracy in prediction and applicability, can accurately predict blast-induced rock fragmentation.

**Key words:** rock blasting; rock fragmentation; model test; fragmentation prediction; ACO-BP model

在矿山开采过程中, 爆破开挖是一个非常关键的过程。优化爆破参数是降低生产总费用、提高生产效

益的关键。对爆破效果进行量化、精确的检测一直是国内外科研人员关注的焦点<sup>[1-2]</sup>。

① 收稿日期: 2024-05-10

基金项目: 国家自然科学基金(52274136, 51904210); 爆破工程湖北省重点实验室基金项目(BL2021-11); 湖北省重点研发计划(2020BCA084)

作者简介: 陈莎莎(2000—), 女, 湖北荆州人, 硕士研究生, 从事爆破块度控制方面的研究。E-mail: chenshashacc@icloud.com

通信作者: 何理(1986—), 男, 湖北十堰人, 副教授, 从事工程爆破理论及技术方面的研究。E-mail: emp-heli@hotmail.com

关于爆破破碎块度预测国内外学者进行了大量研究,并提出了许多理论模型<sup>[3]</sup>。经典模型包括 Kuz-Ram 模型<sup>[4]</sup>和 Rosin-Rammer 模型<sup>[5]</sup>。随着人工智能技术的快速发展,计算机分析在爆破工程中得到了广泛应用<sup>[6]</sup>,近年来国内外学者开始运用机器学习的方法,如 BP 神经网络<sup>[7]</sup>、支持向量机<sup>[8]</sup>等对爆破块度进行预测。刘英等<sup>[9]</sup>基于 BP 神经网络基本原理,利用 PSO 算法优化网络权重和偏置,构建 PSO-BPNN 预测模型,缩短了爆破块度计算时间,可靠性高;模型预测输出值与工程实际平均爆破块度值最大相对误差为 6.56%。JIA 等<sup>[10]</sup>利用灰狼优化器(GWO)对 ELM 的输入权值和隐层阈值进行优化,建立 GWO-ELM 爆破破碎块度的预测模型,该模型精度更高,数据拟合能力强。然而,BP 神经网络用于预测爆破破碎块度存在训练过程可能陷于局部最小等缺陷。通过改变爆破参数,从而控制爆破块度,可有效解决二次破碎成本高、搬运难度大、粉尘污染等问题。因此对岩石爆破破碎块度进行准确预测极为关键。

本文利用采用蚁群算法(ant colony optimization, ACO)对 BP 神经网络进行优化,确定最优的初始权值和阈值参数,将其代入 BP 神经网络,构建 ACO-BP 预测模型。设计 2 次爆破试验,并对试验数据进行 Spearman 分析,确定各种爆破破碎块度影响因素之间的主次关系;在此基础上,选取 80%的试验数据作为训练集,剩余 20%数据作为预测集进行预测。并与 BP 神经网络模型、随机森林模型(RF)、极限梯度提升模型(XGboost)的预测结果进行对比分析,以此验证 ACO-BP 模型的可行性。

### 1 试验概述

在 2 次不同条件下的混凝土试件爆破试验中共得到 315 个数据集。试验 1 以边长 150 mm 的混凝土试件为研究对象,设计并制作了 21 个标准试件,按设计强度等级 C30、C40 和 C60 分为 3 组,分别用字母 S、H 和 T 表示,每组各 7 个,在试件的中心钻炮眼,孔深 125 mm,孔径 8 mm。将数码电子雷管放置于炮孔底部,如图 1 所示。试验 2 同样选取边长 150 mm 的混凝土试件为研究对象,设计并制作了 42 个标准试件,试件编号用 N 表示。各组试件的混凝土强度、约束面和水环境条件见表 1,其中,约束面和自由面之和等于 6。在地面先挖一个深度相当于 2 倍试件边长(总深约 300 mm)的立方体坑洞。设置约束面前,需将坑洞四周磨平,尽可能增大试件与坑洞接触面的摩擦,让咬合力接近于现场实际。将试件约束面与坑洞紧密接触实

现约束。试件顶部通过回填压实现场岩土实现与坑洞壁接触。无水环境是指坑洞纯自然环境。有水环境是指往坑洞浇灌水直至溢出,并保持整个爆破过程,旨在模拟水饱和和环境下的爆破破碎块度试验。

所有试件均采用单发雷管引爆,炮孔、炮泥、起爆器、室外温度、起爆条件等均保持一致。通过专用粒径筛对爆破后的试件破碎块度进行分类筛选。

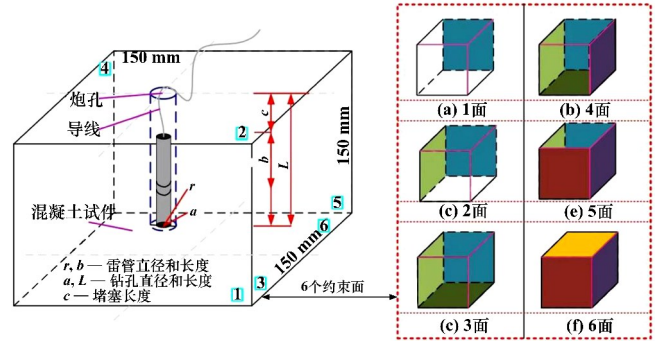


图 1 试件构造及几何尺寸

图 2 为 2 次试验数据不同爆破破碎块度的归一化值,通过图 2 可以直观地分析异常值。样本的中位数由白色圆点表示,粗黑线的顶部和底部分别表示样本的第 3 和第 1 个四分位数。上邻值和下邻值分别由黑色细线的顶部和底部表示,线外为离群值。由图 2 可以看出,除试块尺寸 0~5 mm 外,其他数据分布较为均衡,考虑到较大的爆破块度在爆破中造成的影响,选取试块尺寸 40 mm 以上进行预测。

### 2 研究方法

#### 2.1 蚁群算法(ACO)

ACO 是一种仿生智能优化算法<sup>[11]</sup>,最早由意大利学者 Dorigo、Maniezzo 等于 1991 年提出,通常用于路径规划等问题。

ACO 基本流程如下:

1) 初始化参数设置。蚁群算法的参数包括信息素启发式因子  $\alpha$ 、期望启发式因子  $\beta$ 、信息素汽化因子  $\rho$ 、信息素强度  $Q$ 、最大迭代次数  $K$ 、蚁群数  $M$ 。


2) 转移概率。传统蚁群算法采用轮盘赌的方法选择下一个转移点,适应度大的点转移概率高。第  $m$  个蚂蚁从第  $i$  位转移到第  $j$  位的转移概率按下式计算:

$$P_{ij}^m = \begin{cases} \frac{[\tau(i,j)]^\alpha \cdot [\eta(i,j)]^\beta}{\sum_{s \in J_n(i)} [\tau(i,s)]^\alpha \cdot [\eta(i,s)]^\beta} & (i,j) \in J_m \\ 0 & (i,j) \notin J_m \end{cases} \quad (1)$$

式中: $\tau(i,j)$  为信息素浓度; $\eta(i,j)$  为启发式信息; $J_m$  为当前点的可移动点集合。

表1 试验的参数特性

试件编号	混凝土强度			约束面数量/个	环境条件	试件编号	混凝土强度			约束面数量/个	环境条件
	抗压强度/MPa	EEC种类	EEC加厚层厚度/mm				抗压强度/MPa	EEC种类	EEC加厚层厚度/mm		
S-1	30	—	—	1	无水	N-12	30	PVA	20	6	无水
S-2	30	—	—	2	无水	N-13	40	PVA	10	6	无水
S-3	30	—	—	3	无水	N-14	40	PVA	20	6	无水
S-4	30	—	—	4	无水	N-15	50	PVA	10	6	无水
S-5	30	—	—	5	无水	N-16	50	PVA	20	6	无水
S-6	30	—	—	6	无水	N-17	30	PE	20	6	无水
S-7	30	—	—	6	有水	N-18	40	PE	10	6	无水
H-1	40	—	—	1	无水	N-19	40	PE	20	6	无水
H-2	40	—	—	2	无水	N-20	50	PE	10	6	无水
H-3	40	—	—	3	无水	N-21	50	PE	20	6	无水
H-4	40	—	—	4	无水	N-22	40	PVA	10	6	有水
H-5	40	—	—	5	无水	N-23	30	—	—	6	有水
H-6	40	—	—	6	无水	N-24	40	—	—	6	有水
H-7	40	—	—	6	无水	N-25	50	—	—	6	有水
T-1	60	—	—	1	无水	N-26	30	FE	10	6	有水
T-2	60	—	—	2	无水	N-27	30	FE	20	6	有水
T-3	60	—	—	3	无水	N-28	40	FE	10	6	有水
T-4	60	—	—	4	无水	N-29	40	FE	20	6	有水
T-5	60	—	—	5	无水	N-30	50	FE	10	6	有水
T-6	60	—	—	6	无水	N-31	50	FE	20	6	有水
T-7	60	—	—	6	有水	N-32	30	PVA	10	6	有水
N-1	30	—	—	6	无水	N-33	30	PVA	20	6	有水
N-2	40	—	—	6	无水	N-34	50	PVA	10	6	有水
N-3	50	—	—	6	无水	N-35	50	PVA	20	6	有水
N-4	30	PE	10	6	无水	N-36	30	PE	10	6	有水
N-5	30	FE	10	6	无水	N-37	30	PE	20	6	有水
N-6	30	FE	20	6	无水	N-38	40	PE	10	6	有水
N-7	40	FE	10	6	无水	N-39	40	PE	20	6	有水
N-8	40	FE	20	6	无水	N-40	50	PE	10	6	有水
N-9	40	FE	10	6	无水	N-41	50	PE	20	6	有水
N-10	50	FE	20	6	无水	N-42	40	PVA	20	6	有水
N-11	30	PVA	10	6	无水						



(a) 试验1; (b) 试验2

图2 爆破破碎块度归一化值分布

3) 信息素更新。信息素的更新规律包括信息素增强和信息素挥发,分别按下式计算:

$$\tau_{i+1}^m(i,j) = (1 - \rho) \times \tau_i^m(i,j) + \sum_{m=1}^M \Delta\tau_i^m(i,j) \quad (2)$$

$$\Delta\tau_i^m(i,j) = \begin{cases} Q/L_m & \text{如果蚂蚁 } m \text{ 沿点 } i \text{ 移动到点 } j \\ 0 & \text{其他} \end{cases} \quad (3)$$

式中: $\rho$ 为取值为 $[0, 1]$ 的全局信息素挥发因子; $(1-\rho)$ 为信息素残差系数; $\tau_i^m(i,j)$ 为当前迭代中从第*i*

个点到第  $j$  个点的信息素浓度;  $\tau_i^m(i, j)$  为当前迭代中第  $m$  个蚂蚁从第  $i$  个点到第  $j$  个点的路径上的信息素浓度变化;  $L_m$  为当前迭代中第  $m$  个蚂蚁的路径长度。

### 2.2 ACO-BP 算法

BP 神经网络<sup>[12]</sup>是 1986 年由 Rumelhart 和 McClelland 为首的科学家提出的概念,是应用较为广泛的神经网络模型之一。BP 神经网络是一种按误差反向传播的多层前馈网络<sup>[13]</sup>,利用梯度下降法和非线性变换,使输出误差最小。尽管 BP 神经网络能解决较复杂的非线性问题,但易收敛于局部极小值点。ACO 则可以较好地克服上述问题。

采用 ACO 优化 BP 神经网络的基本思路是:获得权值矩阵和阈值向量的因素,构成蚂蚁种群的路径坐标。蚂蚁到达食物源的路径越短,路径上的信息素含量越高,所以将均方误差作为蚂蚁的适应度值。最终蚂蚁种群确定的最短路径作为最优初始权值和阈值参数,再赋给 BP 神经网络,进行训练和测试。

ACO-BP 算法流程如图 3 所示。

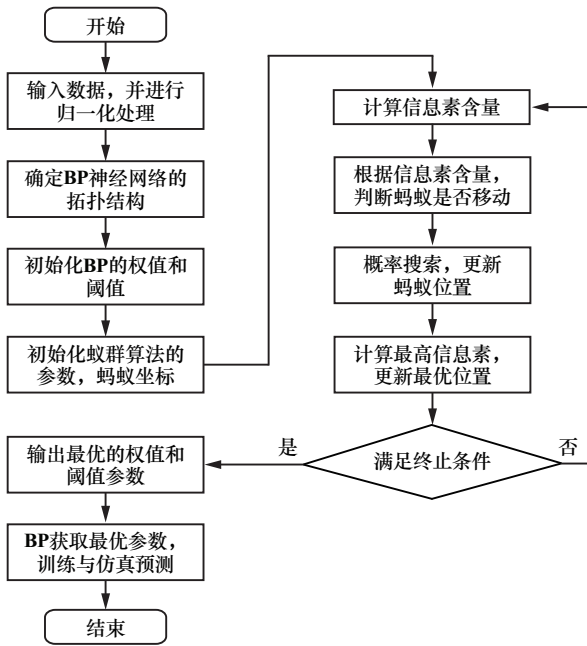


图3 ACO-BP 算法流程

## 3 混凝土爆破破碎块度的智能预测

### 3.1 评价指标

为了得到模型的预测性能,采用均方根误差  $E_{RMSE}$ 、平均绝对误差  $E_{MAE}$ 、决定系数  $R^2$  等 3 个指标进行评价,计算公式<sup>[14]</sup>如下:

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$R^2 = 1 - \frac{\sum_i (y_i - \bar{y}_i)^2}{\sum_i (y_i - \hat{y}_i)^2} \quad (6)$$

式中:  $y_i$  为观测值;  $\hat{y}_i$  为预测值;  $\bar{y}_i$  为观测值的平均值;  $n$  为训练或测试阶段的样本个数。

$E_{RMSE}$  和  $E_{MAE}$  的值越接近 0,所使用的机器学习(machine learning, ML)方法的预测性能越好。 $R^2$  介于 0~1 之间,  $R^2$  越大,表明预测模型越有效。

### 3.2 Spearman 分析

采用 Spearman 相关系数分析各试验条件参数之间的相关性,相关热力图如图 4 所示。由图 4 可知,约束面个数、水环境条件是影响爆破破碎块度的重要指标,其 Spearman 相关系数分别为 0.632、0.484。混凝土强度对爆破破碎块度的影响较小, Spearman 相关系数为 0.187。

	混凝土强度	约束面个数	水环境条件	EEC种类	EEC厚度	40 mm以上
混凝土强度		-0.119	-0.043	-0.136	-0.119	0.187
约束面个数			0.386	0.482	0.506	0.632
水环境条件				0.240	0.252	0.484
EEC种类					0.756	0.402
EEC厚度						0.456
40 mm以上						

图4 关键变量热力图

### 3.3 ACO-BP 模型构建

采用 MATLAB 建立 ACO-BP 模型,考虑到数据集大小,对模型初始化参数进行设定,初始化参数取值见表 2 和表 3。

表2 BP 初始化参数取值

参数	取值	参数	取值
输入层个数	6	输出层个数	1
最大学习次数	1 000	初始学习速率	0.01
最终训练要求精度	0.000 01	动量因子	0.01
学习因子 c1	1	学习因子 c2	2
隐含层节点数	6		

表3 ACO 初始化参数取值

种群规模	最大迭代次数	信息素挥发系数	转移概率常数	信息释放总量
10	50	0.9	0.2	1

将归一化处理后的 63 组数据集分为 2 组,前 50 组(约占总数据集的 4/5)为模型的训练样本,对模型

进行训练和学习,结果见图5;后13组(约占总数据集的1/5)作为测试样本进行预测。由图5可知,当进化代数达到45时,曲线已趋于平稳状态。将得到的最佳阈值和权重代入BP模型,对测试样本进行预测,得到测试样本的真实值与预测值对比见图6。




图5 ACO的进化收敛曲线




图6 测试样本预测值和实测值对比

由图6可知,ACO-BP模型的预测效果良好,统计得到测试样本真实值与预测值的均方根误差  $E_{RMSE} = 0.13$ , 相关系数  $R^2 = 0.92$ , 说明该模型回归拟合效果良好。

### 3.4 预测结果分析

为了得到较为精准的预测块度的ML方法,利用20%的数据集对ML方法预测数据的可靠性进行测试,并对预测值和实测值进行比较。通过输入13组测试样本数据进行预测,分别与未优化的BP神经网络模型、RF算法、XGboost算法进行对比分析,4种模型对爆破破碎块度的预测值与实测值的对比结果见图7。

由图7可知,ACO-BP模型的预测值与实测值最接近,效果明显优于未经优化的BP模型、RF模型和XGboost模型。

根据式(4)~(6)计算4种ML模型的预测结果见表4。由表4可知,XGboost模型和RF模型的预测精度较差。BP神经网络模型运算时间短,相对于RF模型和XGboost模型,其预测精确度有较大提高,说明

BP模型更适用于数据集样本较少的爆破破碎块度预测。ACO-BP神经网络模型在本研究中的预测精度更高且波动性更小, $R^2$ 更接近1,模型的拟合效果更好,能够更精确地预测爆破破碎块度。

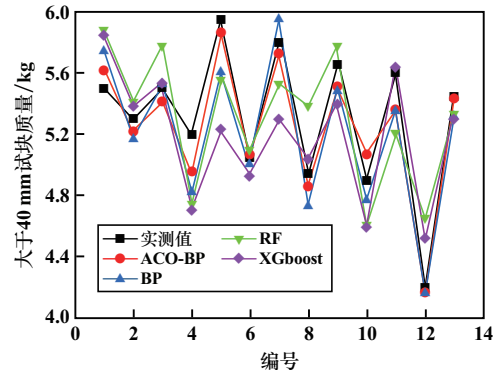


图7 4种ML模型预测值和实测值的对比

表4 4种ML模型评价指标比较

ML方法	$E_{RMSE}$	$E_{MAE}$	$R^2$
BP	0.20	0.19	0.80
RF	0.32	0.32	0.48
XGboost	0.33	0.27	0.48
ACO-BP	0.13	0.11	0.92

## 4 结论

1) 利用蚁群算法优化BP神经网络的初始权值和阈值,构建了用于岩石爆破破碎块度预测的ACO-BP模型。

2) 通过对影响爆破破碎块度的几个因素进行Spearman相关系数分析,得出试验条件下约束面个数、水环境条件是影响爆破破碎块度的两个重要因素。

3) 与BP神经网络模型、XGboost模型、RF模型相比,ACO-BP模型预测效果更好,预测误差更小( $E_{RMSE} = 0.13, E_{MAE} = 0.11, R^2 = 0.92$ )。该算法可进一步提高爆破破碎块度预测精度。

### 参考文献:

- [1] 崔年生,楼晓明. 露天矿山深孔台阶压渣爆破参数优化研究[J]. 矿冶工程, 2023,43(4):44-47.
- [2] 林杰,刘少光,李广斌,等. 基于灰色关联理论深孔切割槽爆破块度影响因素分析及参数优化[J]. 矿冶工程, 2023,43(5):6-10.
- [3] 翟小鹏,杨军,陈占扬,等. 基于应变率变化的爆破块度预测模型及应用[J]. 工程爆破, 2022,28(6):73-79.
- [4] 刘强,施富强,汪旭光,等. 基于三维激光点云的爆破块度统计预测方法[J]. 煤炭学报, 2020,45(增刊2):781-790.
- [5] KHANDELWAL M, MONJEZI M. Prediction of backbreak in open-pit blasting operations using the machine learning method[J]. Rock Mech Rock Eng, 2013,46:389-396.

(下转第21页)

700~740 m 中段之间的采空区充填后,2<sup>#</sup>采空区和3<sup>#</sup>采空区、4<sup>#</sup>采空区之间的贯通风险未消除;采空区顶板暴露面积未减小,顶板产生了较大范围的塑性破坏。700~780 m 中段之间的采空区充填后,采空区之间相互贯通的风险消失,但4<sup>#</sup>采空区和5<sup>#</sup>采空区顶板仍有塑性破坏,顶板有可能发生垮塌;700~820 m 中段的采空区充填后,1<sup>#</sup>采空区、2<sup>#</sup>采空区、3<sup>#</sup>采空区、4<sup>#</sup>采空区塑性破坏的风险消除,但5<sup>#</sup>采空区有大范围的塑性破坏。

## 4 结 论

1) 采空区主要分布在700 m 以上中段,其中2<sup>#</sup>、4<sup>#</sup>和5<sup>#</sup>采空区体积较大,初步估算,采空区总体积约 $40.45 \times 10^4 \text{ m}^3$ 。

2) 基于数值模拟计算结果,当前采空区顶板不稳定,存在较大垮落风险;1<sup>#</sup>~4<sup>#</sup>采空区之间未贯通的岩体受力集中,塑性区贯通,有可能产生大规模失稳破坏。

3) 对700~820 m 中段采空区逐步充填后,采空区失稳风险逐渐消除,不会影响700 m 以下中段生产活动,建议优先对1<sup>#</sup>~4<sup>#</sup>采空区进行充填处理,可有效降低采空区大规模垮塌的风险。

### 参考文献:

- [1] 谢伟,倪彬,李乾龙,等. 基于 Mathews 图解法的采空区稳定性分析[J]. 金属矿山, 2022(6):40-45.
- [2] 王维. Mathews 图解法和 Q 系统分类法在苍山铁矿采场参数优化的应用[J]. 现代矿业, 2021,37(4):61-64.

- [3] 刘畅. 基于房柱法开采的缓倾斜大面积采空区群稳定性研究[D]. 长沙:长沙矿山研究院, 2013.
- [4] 赵延林,吴启红,王卫军,等. 基于突变理论的采空区重叠顶板稳定性强度折减法及应用[J]. 岩石力学与工程学报, 2010,29(7):1424-1434.
- [5] 夏开宗,陈从新,刘秀敏,等. 基于突变理论的石膏矿矿柱-护顶层支撑体系的破坏分析[J]. 岩石力学与工程学报, 2016,35(增刊2):3837-3845.
- [6] 周科平,曹立雄,李杰林,等. 复杂采空区群稳定性数值分析及安全分级评价[J]. 黄金科学技术, 2022,30(3):324-332.
- [7] 赵亮,文兴,覃敏,等. 某石膏矿床深部开采稳定性分析[J]. 矿业研究与开发, 2022,42(5):54-59.
- [8] 宋卫东,付建新,杜建华,等. 基于精密探测的金属矿山采空区群稳定性分析[J]. 岩土力学, 2012,33(12):3781-3787.
- [9] 张宗国,史秀志,邱贤阳. 利用 Mathews 合成图与动静荷载数值模拟评价倾斜矿体采场稳定性[J]. 中国有色金属学报, 2022,32(5):1504-1514.
- [10] 杨勇,张敏思,张飞,等. 红岭多金属矿复杂采空区稳定性[J]. 科学技术与工程, 2021,21(35):14982-14987.
- [11] 王炳文,熊庭永,雷强,等. 玲珑矿区多阶段遗留采空区群稳定性分析及治理[J]. 矿业科学学报, 2019,4(5):425-433.
- [12] 阳俊,曾维伟. 基于 GA-BP 神经网络的采空区地表沉降预测模型[J]. 矿冶工程, 2022,42(2):42-45.
- [13] 戴水平,李恒,李佳建. 基于数值模拟的大型采空区稳定性数值模拟研究[J]. 采矿技术, 2023,23(5):126-132.
- [14] 徐卫东,张永亮,陈晓利,等. 庙岭金矿采空区混合强度充填方法研究[J]. 矿冶工程, 2022,42(2):14-18.
- [15] 张晶,周宗红,任凤玉,等. 充填条件下复杂采空区围岩冒落规律与治理方案研究[J]. 有色金属工程, 2023,13(3):121-128.

引用本文:刘畅,郭泽洋,江飞飞,等. 充填条件下采空区稳定性分析[J]. 矿冶工程, 2024,44(5):17-21.

(上接第16页)

- [6] 何理,刘易和,李琳娜,等. 基于粒子群-最小二乘支持向量机模型的矿山爆破振动速度预测[J]. 金属矿山, 2022(7):145-150.
- [7] MONJEZI M. DEGHANI H. Evaluation of effect of blasting pattern parameters on back break using neural networks[J]. International Journal of Rock Mechanics and Mining Sciences, 2008,45:1446-1453.
- [8] 田睿,李燕卿,刘占宁,等. 基于改进樽海鞘算法优化支持向量机的岩爆预测模型[J]. 矿冶工程, 2023,43(2):5-9.
- [9] 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.
- [10] JIA Z, SONG Z, FAN J, et al. Prediction of blasting fragmentation based on GWO-ELM[J]. Shock and Vibration, 2022:7385456.
- [11] PATLE B K, BABU L G, PANDEY A, et al. A review: on path

planning strategies for navigation of mobile robot[J]. Defence Technology, 2019,15(4):582-606.

- [12] 赵红梦,姜志侠. PCA-BP 算法在地面爆破振动中的应用[J]. 工程爆破, 2020,26(5):30-35.
- [13] 徐国权,王鑫瑀. 基于神经网络算法的爆破振动预测模型开发[J]. 有色金属工程, 2023,13(5):94-102.
- [14] LIU Y, LI A, DAI F, et al. An AI-powered approach to improving tunnel blast performance considering geological conditions[J]. Tunneling and Underground Space Technology, 2024,144:105508.

引用本文:陈莎莎,何理,李腾飞,等. 基于 ACO-BP 模型的岩石爆破破碎块度预测[J]. 矿冶工程, 2024,44(5):12-16.