露天矿爆破块度动态识别模型研究与应用①

黄磊[1]，陶明[2]，刘玉龙[1]，罗朝[2]，徐源泉[2]
（1.中广核铀业发展有限公司，北京 100048；2.中南大学 资源与安全工程学院，湖南 长沙 410083）

摘　要：为解决非洲纳米比亚湖山矿爆破块度快速自动识别的问题，提出了一种露天矿爆破块度动态识别模型，通过双目相机获取立体图像并构建深度图，结合改进的 YOLOv8 实例分割模型实现碎石分类与块度分析；并采用迁移学习、ROI 提取和阴影数据增强技术优化模型，提升模型在复杂环境下的识别精度。模型训练结果表明，优化后的模型精确率达 0.375，召回率 0.600，准确度 0.300，该模型在露天矿极端复杂场景下具有强大鲁棒性，能从高噪、高干扰的背景中成功检出大部分有效岩块。现场实测数据表明，该模型能在高粉尘与动态光照环境下稳定运行，对现场有效岩石的识别准确率达 85%，块度分布曲线误差控制在 8%以内。该模型为湖山矿爆破效果的高效评估与智能检测提供了可靠的技术支撑。

关键词：爆破块度；图像识别；图像分割；YOLOv8；双目视觉；数据增强；ROI 提取；迁移学习
中图分类号：TD235　　**文献标志码**：A　　doi：10.3969/j.issn.0253-6099.2026.02.005
文章编号：0253-6099(2026)02-0028-08

Research and Application of Dynamic Recognition Model for Blast Fragmentation in Open-Pit Mines

HUANG Lei[1], TAO Ming[2], LIU Yulong[1], LUO Zhao[2], XU Yuanquan[2]
(1.*CGNPC Uranium Resources Co., Ltd., Beijing* 100048, *China*; 2.*School of Resources and Safety Engineering, Central South University, Changsha* 410083, *Hunan*, *China*)

Abstract: For rapid and automatic recognition of blast fragmentation in the Husab Mine in Namibia of Africa, a dynamic recognition model was proposed for blast fragmentation in open-pit mines. By acquiring stereo images through a binocular camera and constructing a depth map, in combination with an improved YOLOv8 instance segmentation model, the classification of gravel and fragmentation analysis were realized. Moreover, transfer learning, ROI extraction, and shadow data augmentation technologies were all adopted to optimize the model, enhancing its recognition accuracy in complex environments. The model training results show that the optimized model can achieve a precision of 0.375, a recall of 0.600, and an accuracy of 0.300. This model exhibits strong robustness in extremely complex scenes of open-pit mines, and is capable of successfully detecting most effective rock blocks from high-noise and high-interference backgrounds. Field measurement data indicate that the model can operate stably in environments with high dust and dynamic lighting, achieving a recognition accuracy of 85% for effective rocks on site, and the error of the fragmentation distribution curve is controlled within 8%. This model provides reliable technical support for the efficient evaluation and intelligent detection of blasting effects in the Husab Mine.

Key words: blast fragmentation; image recognition; image segmentation; YOLOv8; binocular vision; data augmentation; ROI extraction; transfer learning

爆破破岩是露天矿山开采的有效方式。爆破块度是衡量爆破效果的重要指标之一[1]，是爆破设计优化的基础[2]。随着计算机视觉技术和深度学习算法的快速发展，许多研究者采用图像识别技术测量岩石爆破块度[3]，但存在两方面的限制，一是如何精准高效地分割图像中的岩石碎片；二是如何根据图像得到岩

① **收稿日期**：2025 -10-13
基金项目：国家自然科学基金面上项目(52274105)
作者简介：黄磊(1987—)，男，四川内江人，硕士，高级工程师，主要从事露天采矿、工程爆破技术经济等工作。E-mail：hl0811432923@163.com
通信作者：罗朝(2003—)，男，湖南邵阳人，硕士研究生，主要从事矿山爆破、智慧矿山等研究工作。E-mail：245511044@csu.edu.cm

石的实际尺寸。

现有研究主要聚焦于岩石图像的精确识别、多标签分类以及掩膜分割三个层面。在岩石图像的精确识别与预处理方面,现有研究主要通过改进传统卷积神经网络架构、引入高阶神经网络以及设计特定的图像去噪算法,以提升模型在复杂噪点环境下的训练效率、识别精度及容错率[4-6]。然而,这类基础性研究多侧重于单一目标的识别,忽略了复杂岩石的多类别属性。为此,部分研究引入并优化了残差网络,通过深化网络层数,实现对含有多种矿物成分的岩石(如砂岩、灰岩)的高效多标签分类[7-8]。但上述工作仍局限于图像级别的分类与特征提取,尚未实现对图像中目标岩石的精确像素级分割与定位。为突破图像级分类的局限,研究重点逐渐转向岩石的精确掩膜与实例分割。相关工作依托卷积自编码器、深度神经网络等主流深度学习模型,覆盖了从微观 CT 图像到宏观露天矿堆料等不同尺度的应用场景[9-11]。当前的岩石图像分割研究主要集中在二维平面层面,仅能获取岩石在二维图像中的像素尺寸与平面分布特征。对于实际矿井或爆破工程而言,这种二维分割难以真实反映岩石在三维物理空间中的实际粒径、体积与块度分布,这也成为了当前岩石块度精确筛分与测量亟待突破的瓶颈。在岩石实际块度的统计分析中,视觉测量技术基于机器视觉原理,对目标图像处理和分析,提取物体的几何特征与空间信息[12]。该技术分为主动测量和被动测量[13]。主动测量使用结构光投影法和脉冲时差测距法,与被动测量相比,主动测量的成本较高。被动测量主要使用单目视觉法和双目视觉法[14]。单目视觉法通过解析单帧图像的几何特征实现尺寸测量,该方法具有系统架构简单、实时性强的优势,但其测量精度易受相机-物体相对位姿影响,需频繁标定且仅能获取二维参数[15]。双目视觉法基于双目成像原理,通过计算异源影像的视差场重建三维信息,该方法不仅能够直接获取待测物体的几何大小,还能够直接获取待测物体的空间姿态[16]。

本文提出了一种露天矿爆破块度动态识别模型,通过获取爆破现场的图像,结合 ROI(region of interest,区域识别)算法和阴影条件数据增强,实现爆破碎石的自动分类与块度检测。该方法成功应用于非洲纳米比亚湖山矿现场工业环境,实现了较高的识别精度,为湖山矿爆破效果评估和优化提供了重要支持。

1　算法实现

1.1　YOLOv8 实例分割模型

本文采用 YOLOv8 实例岩石碎片分割模型。YOLO(you only look once)是一种实时目标检测算法[17],具有高效的检测速度和准确性,适用于各种计算机视觉应用领域。YOLOv8 模型结构如图 1 所示。

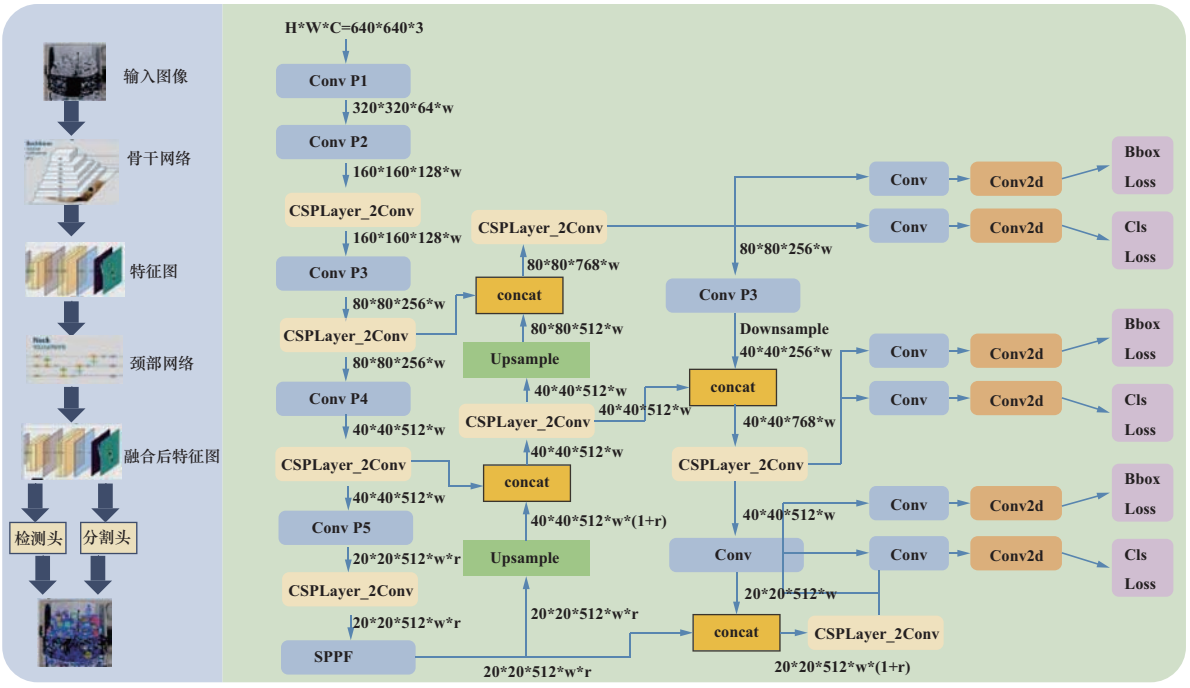


图 1　YOLOv8 模型结构

Fig. 1　Structure of YOLOv8 model

YOLOv8 架构采用模块化设计理念,根据模型复杂度与精度需求划分为 n/s/m/x 等多个版本,其核心

结构包含数据预处理层(Input)、特征提取骨干网络(Backbone)、跨尺度特征聚合模块(Neck)和多任务预测头(Head)四部分。在输入端,通过图像重组、Mosaic数据增强、灰度填充和锚点计算等技术增强模型对岩石图像的适应能力。特征提取骨干网络采用改进的C2f模块取代传统C3模块,该模块通过多分支跨层连接机制显著提升了特征学习能力,但同时也增加了网络复杂度。跨尺度特征聚合模块整合了SPPCSPC、CBS、Ups和E-ELAN等组件,通过多层次特征融合有效扩展了感受野,在保持检测性能的同时优化了收敛速度。预测部分采用解耦头设计,将分类与检测任务分离,显著提升了岩石碎片边界框的定位精度和分类准确性。

1.2 图像采集与数据集构建

1.2.1 图像采集

本文图像主要来源于湖山矿爆破矿岩的碎片图像、国内不同矿山爆破矿岩堆积图像和网络开源岩石数据集。在湖山矿实际工况下拍摄了不同天气和不同光照环境下的图像,共1 536张。部分采集图像见图2。



图2 部分采集图像

Fig.2 Collected images (some)

1.2.2 图像标注

针对传统手动标注效率低下的问题,采用半自动化的图像标注方法实现岩石碎片的精确标注。结合锚点标注技术和语义分割模型辅助标注:通过关键点标记确定碎石大致区域,然后利用预训练语义分割模型生成初步掩膜,最后人工对少量区域进行微调修正。图像标注如图3所示。基于LabelMe软件的混合标注方案,在保证多边形标注精度的同时,提升了标注效率,解决了海量碎石图像标注的难题,为后续模型训练提供了高质量的数据基础。

1.2.3 数据增强

采用随机中心裁剪、水平翻转、竖直翻转、饱和度变化、亮度变化操作对1 536张训练集图像进行扩增。图像由1 536张扩增为7 680张。按照7:2:1的比例将数据集随机划分为训练集(5 376张)、验证集(1 536张)、测试集(768张),用于YOLOv8实例分割模型的训练和验证。

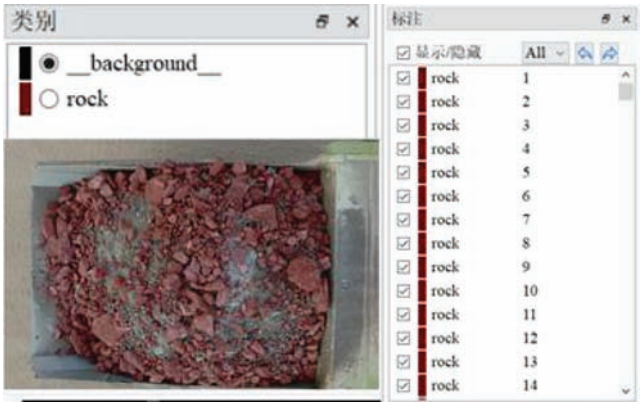


图3 图像标注

Fig.3 Image annotation

1.3 双目视觉测量

标定双目相机减少了相机在使用过程中2个摄像头之间的校对误差,得到深度信息后,计算该像素点的实际三维坐标。双目相机成像模型如图4所示。

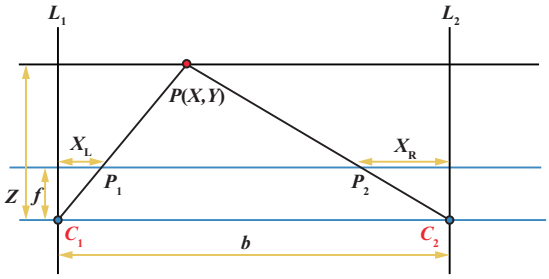


图4 双目相机成像模型

Fig.4 Binocular camera imaging model

设C_1和C_2分别代表双目相机的左右镜头中心点,f为镜头焦距,b为相机左右镜头中心的基线距离。以C_1和C_2为起点,分别作垂直于水平面且指向成像方向的矢量线,作为OAK-D-Pro-W-Poe相机光轴的参考基准线(两线保持平行)。Z是目标点P到相机连线的垂直距离,目标点P在空间中的实际位置通过左右成像平面上的投影点P_1和P_2表示,P_1、P_2在各自成像平面上的x坐标分别为X_L和X_R,其视差可表示为X_L-X_R,根据ΔPP_1P_2与ΔPC_1C_2的空间几何关系,利用相似三角形原理可推导出目标点P的深度值Z为:

$$\begin{cases} \dfrac{Z}{f}=\dfrac{X}{X_L}=\dfrac{Y}{Y_L}=\dfrac{X-b}{X_R} \\ X_L-X_R=d \end{cases} \tag{1}$$

由式(1)可得三维坐标的计算公式如下:

$$\begin{cases} Z = \dfrac{f \times b}{d} \\ X = \dfrac{X_{\mathrm{L}} \times Z}{f} \\ Y = \dfrac{Y_{\mathrm{L}} \times Z}{f} \end{cases} \tag{2}$$

采用威尔兹算法计算掩膜的最小外接圆直径,基本思想是通过递归逐步选取点来构建外接圆,并在保证所有点被圆包含的前提下,尽量减少圆的半径。威尔兹算法流程如图 5 所示,初始化轮廓点集 $\boldsymbol{P}$,并确定点集 $\boldsymbol{R}=\varnothing$;递归过程中,若点 $p \in \boldsymbol{P}$ 不在当前外接圆内,则将点 p 加入 $\boldsymbol{R}$ 并缩小问题规模;当 $\boldsymbol{P}$ 为空集且 $|\boldsymbol{R}| \leqslant 3$时终止,此时可唯一确定最小外接圆。碎石的实际粒径尺寸采用能够将岩石碎片完全包裹的最小外接圆直径表示。

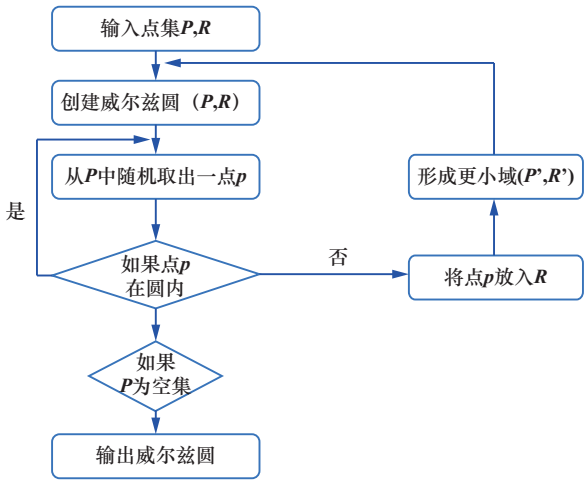


图 5　威尔兹算法流程

Fig. 5　Flowchart of Wilkes algorithm

1.4　岩石碎片块度识别模型

本文提出了一种基于 YOLOv8 实例分割、双目视觉测量和威尔兹算法的露天矿复杂环境岩石爆破块度检测模型。块度识别模型流程如图 6 所示。

首先通过双目相机采集岩石图像,经高斯滤波预处理后,利用 YOLOv8 模型对左视图进行实例分割获取岩石掩膜;然后通过深度图与 RGB 图像的像素级对齐,计算每个像素点的三维坐标。对于每个岩石掩膜,系统先剔除深度异常点,然后通过两两组合计算像素点间的实际距离,建立像素-实际长度比例尺数组,从而计算图片平均比例尺,最终采用威尔兹算法计算最小外接圆像素尺寸,并结合对应的比例尺转换得到实际块度尺寸。

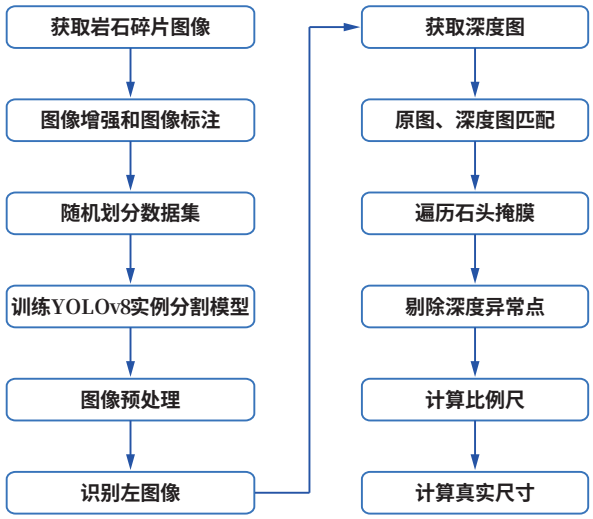


图 6　块度识别模型流程

Fig. 6　Flowchart of fragmentation recognition model

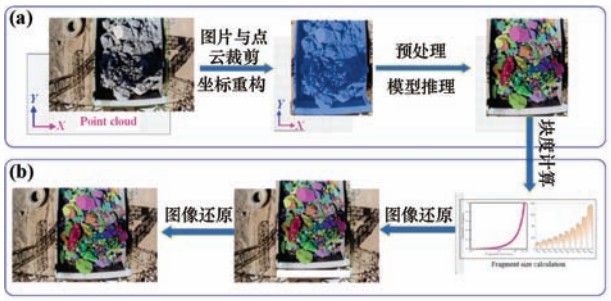
2　模型优化与训练验证

2.1　工程场景下的模型优化策略

在湖山矿采集的原始数据存在如下问题:① 现场设备的横向视野范围较大,容易误识别如轮胎和路边岩石等物体;② 强光照环境会导致扫描站框架产生阴影,遮挡卡车爆堆区域,干扰数据采集和识别效果,可能导致模型在阴影部分识别效果差,将部分多块岩石误判为一块岩石。

2.1.1　ROI 区域识别算法

为了解决因设备横向视野大而产生误识别的问题,采用针对性的 ROI 区域识别算法,通过智能区域筛选机制,在图像预处理阶段精确提取运载卡车区域,ROI 区域识别如图 7 所示,仅将该关键区域输入 YOLOv8 实例分割模型进行处理,有效排除了背景干扰。算法实现包含 3 个关键步骤:① 基于深度信息的卡车区域动态检测与裁剪;② 目标区域增强预处理;③ 识别结果与原图的智能拼接。



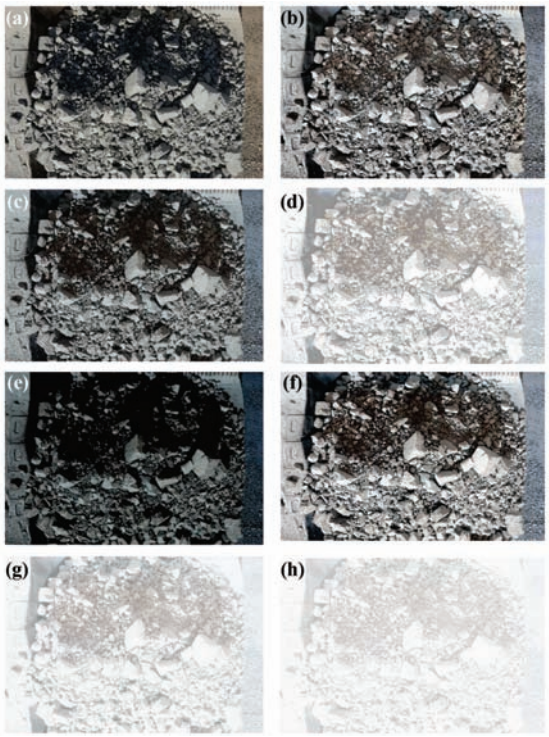
(a) ROI 提取与识别;(b) 块度计算与图像还原

图 7　ROI 区域识别

Fig. 7　ROI region recognition

2.1.2 阴影条件数据增强

为了解决扫描站框架阴影遮挡问题,本文在训练集中对图像进行阴影环境下的数据增强,对图像采用直方图均衡化、拉普拉斯算子增强、LoG(Laplacian of Gaussian)对象增强、伽马变换、CLAHE 增强、单尺度 Retinex 增强(ssr)和多尺度 Retinex 增强(msr)等方式处理后,训练数据集获得了丰富的光照变化信息。阴影数据增强如图 8 所示。



(a) 原图; (b) CLAHE 增强; (c) 拉普拉斯算子增强; (d) LoG 对象增强; (e) 伽马变换; (f) 直方图均衡化; (g) msr; (h) ssr

图 8 阴影数据增强

Fig. 8 Shadow data augmentation

2.2 模型训练与验证

2.2.1 训练环境与参数

采用控制变量法确保试验的可比性,所有对比试验均在统一的训练环境和超参数配置下进行。试验设计包含 2 个主要部分:首先对比 YOLO 系列模型的性能,筛选适用于湖山矿岩石块度分割的实例分割模型;并基于选定的基础模型,验证改进后优化模型的有效性。在模型训练过程中,采用迁移学习策略,以预训练模型作为基准架构进行微调优化。通过网格搜索结合交叉验证的方法,经过多轮试验确定了最优超参数组合。试验训练环境配置和超参数设置分别详见表 1 和表 2。具体试验流程为:第一阶段针对 YOLOv5、YOLOv7、YOLOv8 和 YOLOv11 进行性能对比测试,评估各模型在岩石块度分割任务中的表现;第二阶段则以性能最优的基础模型为基准,通过引入改进策略构建优化模型,并验证其性能提升效果。

表 1 训练环境

Table 1 Training environment

训练环境参数	配置
操作系统	Windows10
虚拟环境	Anaconda
中央处理器型号	12th Gen Intel(R) Core(TM) i5-12400
显卡型号	NVIDIA GeForce RTX 4070 Ti SUPER
内存	64GB
运算平台	CUDA10.2
开发语言	Python
开发 IDE	Pycharm
深度学习框架	Pytorch

表 2 模型超参数设置

Table 2 Model hyperparameter settings

参数	数值
输入图片分辨率	640×640×3
迭代次数	1 000
优化器	SGD
工作队列数量	16
学习率	0.01
耐性	50

2.2.2 模型训练结果分析

在算法模型的评价中,一般利用混淆矩阵来衡量分类模型分类性能,混淆矩阵通常包括 4 个元素:真正(true positive,TP)、假正(false positive,FP)、真负(true negative,TN)和假负(false negative,FN),如表 3 所示。

表 3 混淆矩阵

Table 3 Confusion matrix

真实值	预测值	
	预测为正类	预测为负类
实际为正类	TP	FN
实际为负类	FP	TN

本文采用精确率(P)、召回率(R)、平均精确率均值(m_{AP})、准确度(A)作为模型的评价指标。

精确率(P):模型预测的真类中 TP 的占比。

$$P = \frac{T_P}{T_P + F_P} \tag{3}$$

召回率(R):模型成功预测的目标类别样本占所有目标类别样本的比例。

$$R = \frac{T_P}{T_P + F_N} \tag{4}$$

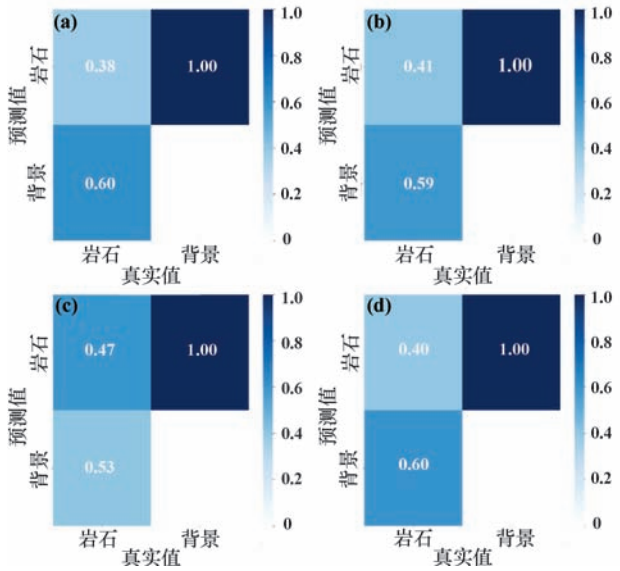
准确度(A):模型正确预测的目标类别样本在所

有数据中的比例。但在目标检测中,正负类别样本的数量可能不平衡,因此准确度在某些情况下不适合用于作为决定性的评价指标。

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \tag{5}$$

式(3)~(5)中:T_P 表示正样本被正确识别的数量;F_P 表示误报的负样本数量;T_N 表示负样本被正确识别的数量;F_N 表示漏报的正样本数量。

训练后得到的 YOLO 系列模型混淆矩阵如图 9 所示。根据图 9 可以得出 YOLO 系列各模型的精确率、召回率、准确度,如表 4 所示。



(a) YOLOv5; (b) YOLOv7; (c) YOLOv8; (d) YOLOv11

图 9　YOLO 系列模型混淆矩阵

Fig. 9　Confusion matrices of YOLO series models

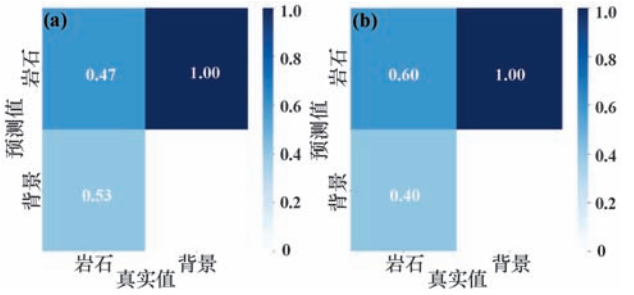
表 4　YOLO 系列模型评价指标

Table 4　Evaluation indicators of YOLO series models

模型	精确率	召回率	准确度
YOLOv5	0.275	0.380	0.190
YOLOv7	0.279	0.410	0.205
YOLOv8	0.319	0.470	0.235
YOLOv11	0.286	0.400	0.200

从表 4 可知,YOLOv8 的精确率、召回率和准确度均显著领先于其他模型,主要是因为 YOLOv8 在算法层面进行了多项优化:改进的特征金字塔网络(FPN)结构增强了多尺度特征融合能力,动态标签分配策略提升了小目标分割精度,更高效的训练框架则缩短了模型收敛时间。相比之下,YOLOv5 虽在轻量化方面表现突出但精度不足,YOLOv7 和 YOLOv11 则在特征提取的细腻程度上稍逊一筹。特别是在岩石碎片多且尺寸跨度大的复杂场景下的实例分割任务中,YOLOv8 对遮挡目标和边缘细节的处理更为精准,误检率和漏检率显著降低。基于量化指标对比和算法创新点的双重考量,选择 YOLOv8 作为岩石块度实例分割任务的基础模型,以 YOLOv8 结合 ROI 区域识别算法和阴影条件数据增强作为优化模型。

基础模型与优化模型的混淆矩阵如图 10 所示。根据图 10 可以得出基础模型和优化模型的精确率、召回率、准确度,如表 5 所示。



(a) 基础模型; (b) 优化模型

图 10　基础模型与优化模型混淆矩阵

Fig. 10　Confusion matrices of base model and optimization model

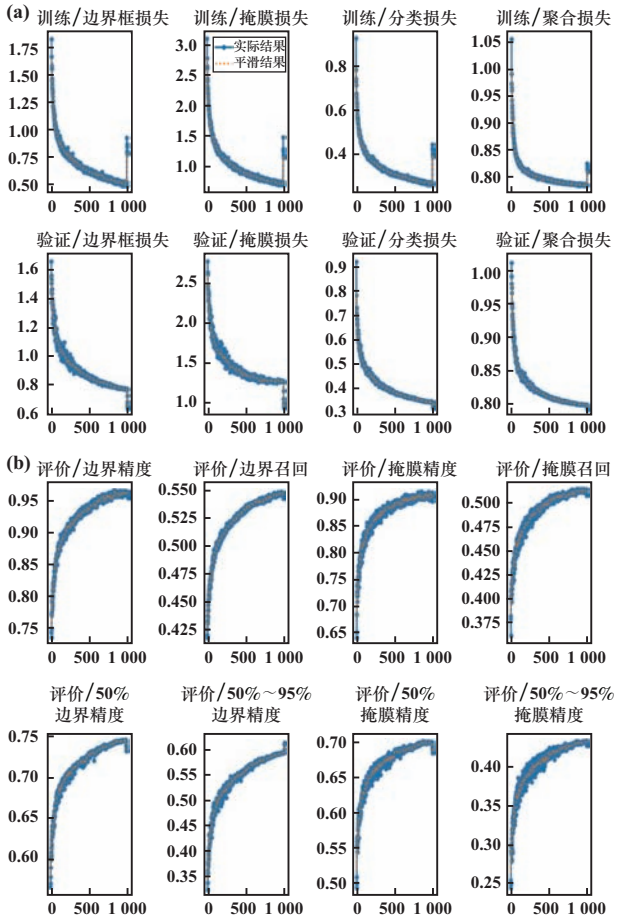
表 5　基础模型与优化模型评价指标

Table 5　Evaluation indicators of base model and optimization model

模型	精确率	召回率	准确度
基础模型	0.319	0.470	0.235
优化模型	0.375	0.600	0.300

由表 5 可知,相较于基础模型,优化模型精确率提升了 17.6%,召回率提升了 27.7%,准确度提升了 27.7%。但优化模型的精确率(0.375)和准确度(0.30)仍有待提升,主要受限于湖山矿采矿运输场景的特殊性。现场环境存在多重干扰:细小碎屑因车辆振动不断附着岩块表面,导致目标边缘模糊;卡车运动、金属反光和矿场扬尘共同造成图像失真;岩块表面矿粉污染进一步影响颜色识别。这些复杂工况不仅增加了视觉识别的难度,也降低了训练数据标注的一致性,最终制约了模型性能的表现。

图 11 为优化模型的训练过程性能变化趋势。训练集和验证集的边界框损失、掩膜损失、分类损失和分布聚合损失均呈现稳定下降趋势,表明模型在训练过程中学习效果显著且未出现过拟合现象,边界框和掩膜的精确率、召回率以及 m_{AP50} 指标均持续提升并最终收敛于较高水平,直观反映了模型预测性能的系统性提升。这些训练曲线充分验证了优化策略的有效性,表明优化模型在保持良好泛化能力的同时,各项关键指标均达到了理想状态。



(a) 损失函数曲线变化; (b) 评价指标曲线变化

图 11 优化模型的训练过程性能变化趋势

Fig. 11 Performance variation trends of optimization model during training process

3 现场试验

将本文提出的模型应用于湖山矿,模型采用 OAK-D-W-PoE 工业级双目相机作为图像采集设备,相机参数见表 6,配置了高性能工业计算机(详细配置参数见表 7),能够全天候稳定运行,确保岩石爆破块度识别系统实现实时、连续的智能分析与数据处理。在图像采集环节,双目相机被固定在专用门式扫描站的安装基座上,当运输矿石的卡车经过门式扫描站时,相机中心点深度变化激活相机连续动态拍照,现场试验如图 12所示。

为验证 ROI 区域识别算法和阴影条件数据增强技术的实际应用效果,分别采用基础模型(模型 1)、仅集成 ROI 区域识别算法的模型(模型 2)、结合 ROI 区域识别算法和阴影条件数据增强的模型(模型 3)对同一图像进行分析,结果分别如图 14、15、16 所示。结果表明:模型 1 存在将路边轮胎和碎石误识别为矿石的问题,且在龙门架阴影遮挡区域出现多块岩石的合并识别;模型 2 有效消除了非目标物体的误识别;模型 3 显著改善了阴影遮挡区域的识别精度。现场试验结果显示,所提出的模型能在高粉尘与动态光照环境下稳定运行,对现场有效岩石的识别准确率达 85%,块度分布曲线误差控制在 8%以内,显著提升了湖山矿岩石爆破块度识别的准确性和可靠性。

表 6 OAK-D-W-PoE 双目相机参数

Table 6 Parameters of OAK-D-W-PoE binocular camera

参数	RGB 相机	双目相机
图像传感器	IMX378	OV9282
对角线视场角/水平视场角/垂直视场角	120°D/95°H/70°V	150°D/128°H/80°V (RGBD 对齐后 106° D/97°H/70°V)
分辨率	12 MP(4 032×3 040)	1 MP(1 280×800)
最大帧率	60 FPS	120 FPS
焦距	4.81	2.35
光圈	2.0	2.2
对焦范围	FF:60 cm→∞	AF:19.6 cm→∞
镜头尺寸	1/2.3	1/4
畸变	<1.0%	<1.5%
像素大小	1.55 μm×1.55 μm	3 μm×3 μm
快门	卷帘快门	全局快门

表 7 工业计算机参数

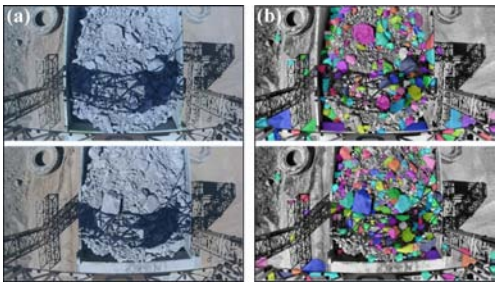
Table 7 Parameters of industrial computer

名称	参数
系统	WIN10
中央处理器	I7-6700
内存	32 G
存储	256 G SSD+1 TB 机械硬盘
显卡	NVIDIA RTX 4060
尺寸	标准 4U 机柜,482 mm×478 mm×177 mm
重量	19.75 kg



图 12 现场试验

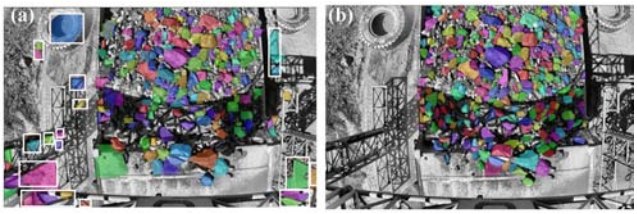
Fig. 12 Field test



(a) 原图;(b) 识别后

图 13　模型 1 识别效果

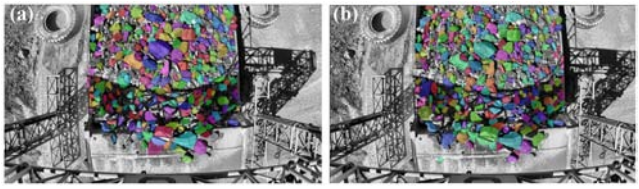
Fig. 13　Recognition effect of model 1



(a) 优化前;(b) 优化后

图 14　模型 2 优化前后对比

Fig. 14　Comparison of model 2 before and after optimization



(a) 优化前;(b) 优化后

图 15　模型 3 优化前后对比

Fig. 15　Comparison of model 3 before and after optimization

4　结论

1) 结合 YOLOv8 实例分割模型、双目视觉技术、ROI 提取和阴影数据增强方法,提出了一种露天矿爆破块度动态识别模型。ROI 提取技术减少了背景干扰,使得模型能够专注于爆破碎石区域,从而提高识别精度。阴影数据增强技术有效模拟了矿山环境中不同的光照和阴影条件,进一步提升了模型在复杂光照下的鲁棒性。

2) 采用威尔兹算法计算岩石的外接圆直径,结合通过双目视觉技术获取的深度图和原始图像,计算图像中像素尺寸与实际尺寸之间的比例尺,从深度图中提取了岩石碎片的深度信息,进而获得岩石碎片的真实尺寸。

3) 现场试验表明,结合 ROI 区域识别算法和阴影条件数据增强的模型能在高粉尘与动态光照环境下稳定运行,对现场有效岩石的识别准确率达 85%,块度分布曲线误差控制在 8%以内,显著提升了湖山矿岩石爆破块度识别的准确性和可靠性。

4) 未来可从三个维度提升模型性能:数据层面需构建更贴近真实工况的训练集,通过振动模拟和精细化标注提升数据质量;算法层面应引入注意力机制和多模态融合,增强模型抗干扰能力;结合动态补偿拍摄和工况自适应算法实现持续优化。

参考文献(References):

[1] 李萍丰,徐振洋,王雪帆,等. 露天矿山爆破共享控制理论的基本方法[J]. 爆破, 2024,41(3):16-25.
LI Pingfeng, XU Zhenyang, WANG Xuefan, et al. Basic method of open-pit mine blasting sharing control theory[J]. Blasting, 2024, 41(3):16-25.

[2] 傅鹏. 岩体结构面对台阶爆破效果影响研究[J]. 爆破, 2023, 40(1):77-84.
FU Peng. Influence of rock mass structure on bench blasting effect[J]. Blasting, 2023,40(1):77-84.

[3] 王大坤,叶图强,闫大洋,等. 基于三维激光扫描技术的爆破块度识别[J]. 有色金属工程, 2022(11):120-127.
WANG Dakun, YE Tuqiang, YAN Dayang, et al. Blasting fragmentation identification based on 3D laser scanning technology[J]. Nonferrous Metals Engineering, 2022(11):120-127.

[4] 李炳臻,刘克,顾佼佼,等. 卷积神经网络研究综述[J]. 计算机时代, 2021(4):8-12.
LI Bingzhen, LIU Ke, GU Jiaojiao, et al. Review of the researches on convolutional neural networks[J]. Computer Era, 2021(4):8-12.

[5] 程纬华,乔登攀,张磊,等. BP 神经网络在露天矿边坡稳定性分析中的应用[J]. 矿冶, 2012,21(2):10-14.
CHENG Weihua, QIAO Dengpan, ZHANG Lei, et al. Application of BP networks in the stability analysis of slopes in the open-pit mine[J]. Mining and Metallurgy, 2012,21(2):10-14.

[6] 孟雪. 基于 BP 神经网络的图像识别[J]. 软件, 2022,43(7):137-141.
MENG Xue. Image recognition based on BP neural network[J]. Software, 2022,43(7):137-141.

[7] 余晓露,李龙龙,蒋宏,等. 融合图像处理与深度学习的亮晶颗粒灰岩岩相学分析应用[J]. 石油实验地质, 2023,45(5):1026-1038.
YU Xiaolu, LI Longlong, JIANG Hong, et al. Application of sparry grain limestone petrographic analysis combining image processing and deep learning[J]. Petroleum Geology & Experiment, 2023,45(5): 1026-1038.

[8] 吴博,李永胜,王睿,等. 基于自训练的多标签岩矿石薄片分类方法[J]. 黄金, 2024,45(2):61-67.
WU Bo, LI Yongsheng, WANG Rui, et al. Multi-label rock ore slice classification approach based on self-training[J]. Gold, 2024, 45(2):61-67.

[9] KARIMPOULI S, TAHMASEBI P. Segmentation of digital rock images using deep convolutional autoencoder networks[J]. Computers & Geosciences, 2019,126:142-150.

(下转第 43 页)

pression[J]. Chinese Journal of High Pressure Physics, 2024, 38(5):203-216.

[9] YANG S Q, JIANG Y Z, XU W Y, et al. Experimental investigation on strength and failure behavior of pre-cracked marble under conventional triaxial compression[J]. International Journal of Solids and Structures, 2008,45(17):4796-4819.

[10] HUANG Y H, YANG S Q, TIAN W L. Crack coalescence behavior of sandstone specimen containing two pre-existing flaws under different confining pressures[J]. Theoretical and Applied Fracture Mechanics,2019,99:118-130.

[11] 张梅丽,梁正召,高敏,等. 含交叉裂隙岩体力学性质数值模拟研究[J]. 地下空间与工程学报, 2020,16(3):758-769.
ZHANG Meili, LIANG Zhengzhao, GAO Min, et al. Numerical simulation of mechanical properties of rock specimens with cross-crack under different confining pressure[J]. Chinese Journal of Underground Space and Engineering, 2020,16(3):758-769.

[12] 刘剑. 闪长岩加卸荷失稳破裂前兆信息研究[D]. 昆明:昆明理工大学, 2022.
LIU Jian. Study on the precursor information of diorite plus unloading instability rupture[D]. Kunming: Kunming University of Science and Technology, 2022.

[13] 李宏强,姚忠劭,曾志杭,等. 冻融循环单轴压缩下不等长交叉裂隙砂岩变形破坏特征研究[J]. 三峡大学学报(自然科学版), 2024,46(6):65-72.
LI Hongqiang, YAO Zhongshao, ZENG Zhihang, et al. Study on deformation and failure characteristics of sandstone with unequal length cross cracks under uniaxial compression of freeze-thaw cycle[J]. Journal of China Three Gorges University (Natural Sciences), 2024, 46(6):65-72.

[14] POTYONDY D O, CUNDALL P A. A bonded-particle model for rock[J]. International Journal of Rock Mechanics and Mining Sciences, 2004,41(8):1329-1364.

[15] 郭佳奇,刘希亮,乔春生. 自然与饱水状态下岩溶灰岩力学性质及能量机制试验研究[J]. 岩石力学与工程学报, 2014,33(2):296-308.
GUO Jiaqi, LIU Xiliang, QIAO Chunsheng. Experimental study of mechanical properties and energy mechanism of karst limestone under natural and saturated states[J]. Chinese Journal of Rock Mechanics and Engineering, 2014,33(2):296-308.

引用本文:唐晞源,周宗红,徐阳,等. 含交叉裂隙岩体裂纹扩展与能量演化研究[J]. *矿冶工程*, 2026,46(2):36-43.
TANG Xiyuan, ZHOU Zonghong, XU Yang, et al. Crack propagation and energy evolution of rock mass with cross-fractures[J]. Mining and Metallurgical Engineering, 2026,46(2):36-43.

(上接第 35 页)

[10] VARFOLOMEEV I, YAKIMCHUK I, SAFONOV I. An application of deep neural networks for segmentation of microtomographic images of rock samples[J]. Computers, 2019,8(4):72.

[11] SHRIVASTAVA S, DEB D, BHATTACHARJEE S. Prediction of particle size distribution curves of dump materials using convolutional neural networks[J]. Rock Mechanics and Rock Engineering, 2022, 55(1):471-479.

[12] 张宗华,刘巍,刘国栋,等. 三维视觉测量技术及应用进展[J]. 中国图象图形学报, 2021,26(6):1483-1502.
ZHANG Zonghua, LIU Wei, LIU Guodong, et al. Overview of the development and application of 3D vision measurement technology[J]. Journal of Image and Graphics, 2021,26(6):1483-1502.

[13] 郑太雄,黄帅,李永福,等. 基于视觉的三维重建关键技术研究综述[J]. 自动化学报, 2020,46(4):631-652.
ZHENG Taixiong, HUANG Shuai, LI Yongfu, et al. Key techniques for vision based 3D reconstruction: A review[J]. Acta Automatica Sinica, 2020,46(4):631-652.

[14] 李小菁,黄振宇,凌珊. 基于光栅结构光双目视觉的动态三维测量方法研究[J]. 中国测试, 2018,44(9):35-38.
LI Xiaojing, HUANG Zhenyu, LING Shan. Dynamic 3D measurement method based on raster binocular stereo vision sensor[J]. China Measurement & Testing Technology, 2018,44(9):35-38.

[15] 吴琼,刘宝龙,王科,等. 双目立体视觉技术的实现及其进展[J]. 中国新通信, 2020,22(2):166.
WU Qiong, LIU Baolong, WANG Ke, et al. Realization and progress of binocular stereo vision technology[J]. China New Telecommunications, 2020,22(2):166.

[16] 魏振忠,冯广堃,周丹雅,等. 位姿视觉测量方法及应用综述[J]. 激光与光电子学进展, 2023,60(3):134-166.
WEI Zhenzhong, FENG Guangkun, ZHOU Danya, et al. A review of position and orientation visual measurement methods and applications[J]. Laser & Optoelectronics Progress, 2023,60(3):134-166.

[17] REDMON J, DIVVALA S, GIRSHICK R, et al. Youonly look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, 2016:779-788.

引用本文:黄磊,陶明,刘玉龙,等. 露天矿爆破块度动态识别模型研究与应用[J]. *矿冶工程*, 2026,46(2):28-35.
HUANG Lei, TAO Ming, LIU Yulong, et al. Research and application of dynamic recognition model for blast fragmentation in open-pit mines[J]. Mining and Metallurgical Engineering, 2026,46(2):28-35.