

中文引用格式:刘光伟,张浩博,雷健,等. 面向露天矿无人矿卡行驶障碍物检测模型[J]. 中国安全科学学报,2025,35(11):49-55.
英文引用格式:LIU Guangwei, ZHANG Haobo, LEI Jian, et al. Obstacle detection model for unmanned mining trucks during driving in open-pit mines[J]. China Safety Science Journal,2025,35(11):49-55.

面向露天矿无人矿卡行驶障碍物检测模型^{*}

刘光伟 教授, 张浩博^{**}, 雷 健, 黄云龙 讲师, 任崇辉
(辽宁工程技术大学 矿业学院, 辽宁 阜新 123000)

中图分类号:X924.3 文献标志码:A DOI: 10.16265/j.cnki.issn1003-3033.2025.11.0260
基金项目:国家自然科学基金资助(52374123); 辽宁省教育厅基本科研项目的(LJ212510147033)。

【摘 要】 为准确检测到露天矿无人矿卡行驶途中的障碍物,提出一种改进 YOLOv8 的障碍物检测模型。首先,通过引入超级令牌注意力机制(STA),解决传统注意力机制存在的冗余计算与全局建模不足的问题,增强对小目标和遮挡目标的特征表达能力;其次,设计颈部网络结构,融合高低层级特征,进一步提升小目标的定位精度;然后,构建复合损失函数,平衡边界框回归精度与鲁棒性,以适应露天矿障碍物的多样形态;最后,利用自建数据集对比验证改进模型的有效性。结果表明:改进后的模型精度、召回率、交并比(IoU)阈值为0.5时的平均精度均值(mAP@50)分别为86.2%、78.9%、83.1%,较YOLOv8分别提升10.3%、19.4%、18.0%;改进模型在检测精度、召回率和计算复杂度方面均展现出优势。

【关键词】 露天矿; 无人矿卡; 障碍物检测; 超级令牌注意力机制(STA); YOLOv8

Obstacle detection model for unmanned mining trucks during driving in open-pit mines

LIU Guangwei, ZHANG Haobo, LEI Jian, HUANG Yunlong, REN Chonghui
(School of Mining, Liaoning Technical University, Fuxin Liaoning 123000, China)

Abstract: To accurately detect obstacles during the operation of unmanned mining trucks in open-pit mines, an improved obstacle detection model based on YOLOv8 was proposed. Firstly, STA mechanism was introduced to address the issues of redundant computation and insufficient global modeling in traditional attention mechanisms, thereby enhancing the feature representation capability for small and occluded targets. Secondly, a neck network structure was designed to further improve the localization accuracy of small targets by fusing high-level and low-level features. Then, a compound loss function was constructed to balance the regression accuracy and robustness of bounding boxes, so as to adapt to the diverse shapes of obstacles in open-pit mines. Finally, a self-built dataset was utilized to conduct comparative experiments for verifying the effectiveness of the improved model. The results show that the accuracy, recall rate, and mean Average Precision (mAP) at an Intersection over Union (IoU) threshold of 0.5 of the improved model are 86.2%, 78.9%, and 83.1% respectively, which are 10.3%, 19.4%,

* 文章编号:1003-3033(2025)11-0049-07; 收稿日期:2025-05-10; 修稿日期:2025-08-11

** 通信作者:张浩博(2000—),男,内蒙古呼伦贝尔人,硕士研究生,研究方向为机器视觉及露天开采理论与技术。E-mail:871407626@qq.com。

and 18.0% higher than those of YOLOv8. Compared with traditional detection algorithms, the improved model exhibits advantages in detection accuracy, recall rate and computational complexity.

Keywords: open-pit mine; unmanned mining truck; obstacle detection; super token attention mechanism (STA); YOLOv8

0 引言

露天矿开采的高效化、智能化是矿产资源开发行业转型升级的关键,无人驾驶矿用卡车(简称无人矿卡)是矿山智能化的核心设备^[1]。然而,露天矿作业环境复杂,致使传统目标检测模型难以识别障碍物,威胁无人矿卡安全与作业可靠性^[2]。因此,开展适配露天矿复杂场景的障碍物检测技术,对保障无人矿卡安全运行、推动矿山智能化落地具有重要的工程价值。

近年来,国内外学者围绕无人驾驶障碍物检测展开大量研究并取得阶段性成果。国外研究起步较早,聚焦于多传感器融合与算法鲁棒性优化。例如:VERMA 等^[3]提出了基于实时运动学的自动驾驶传感器故障检测法,用单/双传输等技术提升了系统抗干扰能力;BOTEZATU 等^[4]提出了基于深度学习的自动驾驶道路分析方法,用单/两阶段检测策略与卷积神经网络技术提升自动驾驶系统安全性与效率;PONN 等^[5]提出了基于元信息的自动驾驶摄像头目标检测性能分析模型,运用随机森林建模等技术评估模型性能。国内研究则更贴合露天矿场景特点,逐步从通用检测算法向场景适配性优化演进,部分团队通过改进特征融合方式、调整网络结构等方法提升模型对矿山障碍物的识别能力。例如:朱永军等^[6]通过引入鲁棒特征下采样模块、设计特征增强颈部网络、替换损失函数,将改进模型用于露天矿复杂背景下小目标检测;顾清华等^[7]通过重构 Neck 网络和优化损失函数降低了模型计算量;续瑞等^[8]提出了基于单目视觉的露天矿卡道路障碍物检测及测距算法,解决了露天矿区复杂环境下矿卡碰撞预警系统中道路障碍物识别与测距不准确的问题;程铄棋等^[9]提出了轻量级障碍检测算法,通过设计模块和新损失函数实现轻量化实时检测。尽管现有研究已覆盖小目标检测、轻量化部署等需求,但在露天矿复杂场景下(如粉尘天气下的小尺寸目标、多辆矿卡会车时的相互遮挡),模型检测精度还有待提升。


鉴于此,笔者拟针对露天矿复杂场景下无人矿卡行驶途中的障碍物检测精度与鲁棒性需求,以

YOLOv8 为基线模型,通过引入注意力机制、设计小目标检测的跨分支颈部网络(Cross-Branch Network for Small Object Detection, CBN-SOD)结构和重构损失函数,提出一种面向露天矿行车安全的障碍物检测算法,以期提升复杂环境下障碍物的检测性能。

1 无人矿卡行驶障碍物目标检测模型

1.1 模型改进策略

基于 YOLOv8 模型改进 3 个维度,具体结构如图 1 所示。



注:超级令牌注意力机制模块(Super Token Attention, STA);快速空间金字塔池化模块(Spatial Pyramid Pooling Fast, SPPF);跨阶段局部特征融合模块(Cross Stage PartialDarknet53 to 2-stage Feature Pyramid Network, C2f)。

图 1 改进的 YOLOv8 结构
Fig. 1 Improved YOLOv8 structure

首先,采用 STA,通过时空注意力模块同步捕捉目标空间特征与时间序列信息,增强小目标和遮挡目标的识别准确率;然后,引入动态特征路由机制,并用内容感知重组特征上采样(Content-Aware Reassembly Feature, CARAFE)替代传统最近邻插值,扩大感受野且提升多尺度特征融合效率;最后,采用形状归一化加权距离损失函数(Shape Normalized Weighted Distance, Shape-NWD)优化不规则目标的

回归精度。改进后算法模型命名为 MD(根据矿山和检测的英文首字母 Mine 和 Detection 命名)。

1.2 STA

无人驾驶对露天矿开采至关重要,精准检测障碍物需有效建模目标的空间分布与时间运动轨迹。但传统视觉模型因缺乏时空联合建模能力,在遮挡

场景中表现不足^[10]。为此,使用 STA 高效表征复杂场景的小目标和遮挡目标,并依托超级视觉令牌架构(Super Token Vision Transformer, STViT)完成落地,其架构如图 2 所示。其中, X_1 为输入的令牌数量; X 为经卷积处理后的中间令牌特征; Y 为经 STA 处理后的全局特征增强令牌; P 为最终输出的令牌。

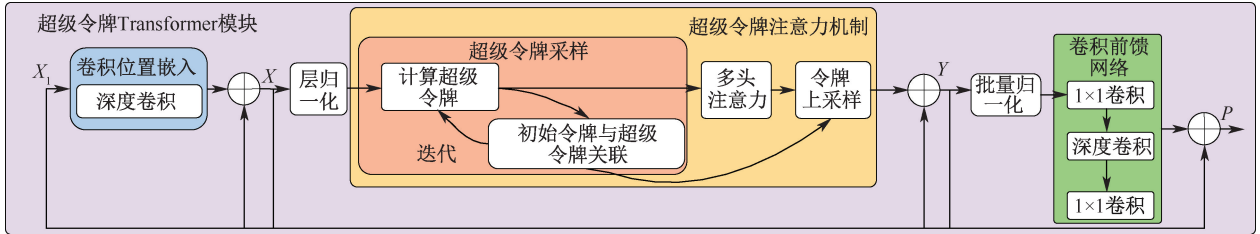


图 2 STViT 架构

Fig. 2 STViT architecture

首先,架构输入端接收连续 3 帧图像,分别送入卷积主干网络;然后,拼接 3 帧单帧空间特征为三维特征序列,经全局平均池化生成时空超级令牌,减少后续注意力计算冗余。进入第 2 阶段,时空超级令牌输入多头自注意力模块,通过可学习权重矩阵映射至查询、键、值空间,计算注意力权重时同步捕捉空间邻域与时间序列关联,借稀疏关联机制降计算复杂度,保障小目标与遮挡目标特征捕捉能力;最后,通过关联矩阵将优化后的全局时空特征映射回原始单帧特征空间,引入残差连接逐元素相加原始单帧与全局特征,完成跨帧融合,输出兼具局部细节与全局时空关联的特征图。

1.3 改进颈部网络结构

露天矿无人矿卡作业环境中障碍物种类多样,而传统颈部网络采用固定的层级融合路径,不能灵活适配不同尺度的目标,使得小目标检测精度不高,多尺度特征融合效率也受到限制^[11]。而 CBN-SOD 颈部网络结构引入动态路由门控机制,借助可学习的权重矩阵,实现对高低层特征的自适应选择,其核心公式如下:

$$g = \sigma(\text{MLP}(G(H) \oplus G(L))) \quad (1)$$

$$Z = g \otimes H + (1 - g) \otimes L \quad (2)$$

式中: g 为通道级门控向量; σ 为 Sigmoid 激活函数; H 为高层语义特征; L 为低层语义特征; $\oplus$ 为特征拼接; G 为全局平均池化操作; Z 为融合后的特征; $\otimes$ 为元素级乘法。

具体实现过程中,首先,卷积操作低层语义特征,调整其通道与维度以匹配高层语义特征,卷积操作见下式:

$$L_1 = \text{Conv}(L, W_1) \quad (3)$$

式中: L_1 为对 L 进行卷积操作后的特征图,用于匹配高层语义特征图的通道数和维度; W_1 为卷积核权重矩阵; $\text{Conv}(\cdot)$ 为卷积操作。

然后,将调整后的 L_1 与 H 按通道拼接融合,融合后的特征图 Z_1 见下式:

$$Z_1 = L_1 + H \quad (4)$$

最后,再对 Z_1 进行卷积操作以进一步提取融合后的特征,得到最终用于小目标检测的特征图,见下式:

$$Z_2 = \text{Conv}(Z, W_2) \quad (5)$$

式中: Z_2 为最终用于小目标检测的特征图; W_2 为另一组卷积核权重矩阵。

另外,在 YOLO 模型中,上采样是关键操作。YOLOv8 采用的最近邻插值上采样依赖像素空间位置,无法充分利用语义信息,导致感知范围有限、图像质量欠佳,相比之下, CARAFE 具备更大的感受野,能更高效利用语义信息识别小目标,结构如图 3 所示。采用自适应上采样策略,先通过 1×1 卷积操作将通道维度从 C 缩减至 C_m ,再利用压缩后的特征图生成空间自适应的上采样核,得到形状为 $H \times W \times \theta^2 k^2$ 的上采样核,并将其展开为 $H \times W \times k \times k$ 的核矩阵。最后通过 softmax 函数归一化确保权重满足概率分布。特征重组时,为输出特征图的每个空间位置定位对应的输入感受野,提取 $k \times k$ 的局部区域,通过预测的卷积核参数进行加权融合,实现多尺度特征高效聚合。最终生成 $\theta H \times \theta W \times C$ 的上采样特征图。其中, θ 为上采样后特征图尺寸与原始特征图尺寸的比例系数。




图3 CARAFE 结构

Fig.3 CARAFE structure

1.4 改进损失函数

在露天矿无人矿卡的障碍物检测任务中,传统损失函数难以衡量不重叠边界框的相似性。因此,将形状感知交并比损失函数(Shape-Intersection over Union Loss Function, Shape-IoU)的思想融入到归一化瓦瑟斯坦距离损失函数(Normalized Weighted Distance, NWD)中。Shape-IoU 损失函数锚框与真实框的关系如图 4 所示。其中, (x_1, y_1) 为真实标注框的中心坐标, (x, y) 为锚框的中心坐标, w_1 、 h_1 分别为真实标注框的宽度和高度, w 、 h 分别为锚框的宽度和高度, f_1 、 f 分别为真实框和锚框的标识点。




图4 Shape-IoU

Fig.4 Shape-IoU

Shape-NWD 损失函数通过引入边界框宽度与高度的权重系数,进一步平衡边界框形状和尺寸的影响。计算过程如下:

$$v = \frac{2 \times (w_1)^s}{(w_1)^s + (h_1)^s} \quad (6)$$

$$b = \frac{2 \times (h_1)^s}{(w_1)^s + (h_1)^s} \quad (7)$$

式中: s 为缩放因子; v 和 b 分别为水平和垂直方向的权重系数。

$$D = \sqrt{b \times (x - x_1)^2 + v \times (y - y_1)^2 + F} \quad (8)$$

$$F = \frac{(w^2 - w_1)^2 + (h^2 - h_1)^2}{q^2}, q = 2 \quad (9)$$

式中: D 为瓦瑟斯坦距离; F 为计算的形状差异值,作为距离损失的一部分,融合形状约束; q 为权重参数。

最后,归一化处理 D , 稳定模型训练过程,避免因距离度量值过大或过小导致的梯度问题。

$$N = \exp\left(-\frac{D}{E}\right) \quad (10)$$

$$M = 1 - N \quad (11)$$

式中: N 为基于指数函数的归一化距离度量; E 为与图像尺寸密切相关的常数; M 为最终的损失函数值,取值范围为 $[0, 1]$ 。

2 无人矿卡障碍物检测模型结果分析

2.1 障碍物检测数据集建立

露天矿无人矿卡卡车障碍物检测数据集采集自新疆某露天矿,通过行车途中不同角度的摄像头拍摄现场视频,从中筛选出 4 300 张相似度较低的图像构建而成,再按 4 : 1 比例划分为训练集和测试集。为标注图像中的障碍物,使用 Python 编写的 Labellmg 工具标注,效果如图 5 所示。

2.2 模型设置与评价指标

在图像预处理阶段,可裁剪、缩放训练集图片,




图 5 数据集标注工作

Fig.5 Dataset annotation work

其中,裁剪的目的是去除图像中不必要的空白区域,缩放是将图像分辨率调整到适合模型训练大小,基于显卡显存和训练效率,设批次大小为 16,平衡显存占用与梯度稳定性;训练轮数 300,兼顾性能与泛化能力,避免过拟合。初始与最终学习率均为 0.001,前 3 轮热身训练,初始动量 0.52,第 4 轮起调为 0.57;设权重衰减系数 0.000 5 防过拟合。对比试验均控制单一变量,其他配置一致。采用平均精度均值(mean Average Precision, mAP)作为评估模型性能的核心指标。mAP@ 50 表示在置信度阈值为 50%时的均值^[12]。检测模型的性能通过以下指标来量化评估: P 表示预测结果中正样本的准确程度, R 表示实际正样本被成功检测的比例,具体计算过程见下式:

$$P = \frac{TP}{TP + FP} \times 100\% \tag{12}$$

$$R = \frac{TP}{TP + FN} \times 100\% \tag{13}$$

式中:TP(True Positive)为模型预测为正样本且实际也为正样本的数量;FP(False Positive)为模型预测为正样本但实际为负样本的数量;FN(False Negative)为未实际预测为正样本但模型预测为负样本的数量。

计算复杂度(Giga Floating-point Operations Per Second, GFLOPS)是衡量深度学习模型计算量的核心指标,用于量化模型在处理输入数据时所需的浮点运算量。计算公式见下:

$$GFLOPs = K \times K_1 \times K_2 \times X_1 \times X_2 \tag{14}$$

式中: K 为卷积核总数; K_1 、 K_2 分别为卷积核的垂直高度和水平宽度; X_1 为输入特征图的通道数; X_2 为对应输出特征图的通道维度。

2.3 改进模型消融试验

为验证每个模块的独立有效性与协同作用,在

相同试验条件下均基于 YOLOv8 模型开展消融试验,逐步引入各改进模块并对比性能变化。其中,A 表示引入 STA 模块,B 表示引入 CBN-SOD 模块,C 表示引入 Shape-NWD 模块,符号√表示使用该模块,×表示不使用该模块。结果见表 1。

表 1 消融试验

Table 1 Ablation experiment

A	B	C	$P/\%$	$R/\%$	mAP@ 50/%	GFLOPs
×	×	×	75.9	59.5	65.1	8.9
√	×	×	84.6	77.4	82.7	13.3
×	√	×	85.4	77.8	82.6	12.7
×	×	√	85.2	77.9	81.9	16.9
×	√	√	85.9	77.6	82.4	16.9
√	×	√	85.4	78.4	82.9	13.2
√	√	×	85.1	78.1	83.0	16.9
√	√	√	86.2	78.9	83.1	16.9

从表 1 结果看出,单独引入 STA 模块时,模型精度从 75.9% 升至 84.6%,召回率从 59.5% 升至 77.4%,mAP@ 50 提升 17.8%,计算复杂度为 13.3GFLOPS,表明其通过时空融合增强动态场景中 小目标与遮挡目标检测能力,但计算量略增。单独引入 CBN-SOD 模块时,精度为 85.4%、召回率为 77.8%,mAP@ 50 为 82.6%,计算复杂度降至 12.7GFLOPS,说明 CARAFE 提升多尺度融合效率,实现降本增效。单独引入 Shape-NWD 模块时,精度为 85.2%、召回率为 77.9%,mAP@ 50 为 81.9%,说明形状约束与分布相似性对边界框的回归具有优化作用。同时引入 STA 与 CBN-SOD 模块时,精度为 85.1%、召回率为 78.1%,mAP@ 50 为 83.0%,较单独引入 STA 模块和 CBN-SOD 模块均具有提升,说明通过特征解耦等机制实现精度与效率的增益。同时引入 STA 和 Shape-NWD 模块时,mAP@ 50 为 82.9%,较单独引入 STA 模块时提升 0.2%,说明模型的鲁棒性得到提升。同时引入 CBN-SOD 与 Shape-NWD 模块时,mAP@ 50 为 82.4%,略低于单独引入 CBN-SOD 模块,但计算复杂度保持 16.9GFLOPS,证明二者具备互补性。同时引入三模块时性能最优,精度为 86.2%、召回率为 78.9%,mAP@ 50 为 83.1%,较基线模型提升 18%,计算复杂度为 16.9GFLOPS。由此可见,改进后的模型在检测性能上具有显著的提升。

2.4 与主流模型对比

为验证改进模型在露天矿复杂场景中的综合性能,选取快速区域卷积神经网络(Faster Region-

based Convolutional Neural Network, Faster R-CNN)、单阶段多框检测器(Single Shot MultiBox Detector, SSD)、YOLOXs、YOLOv8 共 4 种主流目标检测模型作对比,结果见表 2。

表 2 改进模型与主流模型对比结果

Table 2 Results of improved model compared with mainstream models				
模型	P/%	R/%	mAP@ 50/%	GFLOPs
Faster R-CNN	80.3	45.0	51.6	369.7
SSD	80.5	50.1	56.1	269.3
YOLOXs	64.2	54.6	56.2	8.2
YOLOv8	75.9	59.5	65.1	8.9
MD-YOLOv8	86.2	78.9	83.1	16.9

从表 2 结果看到,改进模型在核心检测指标与计算复杂度的平衡上优势显著。检测精度方面,MD-YOLOv8 达到 86.2%,高于 Faster R-CNN、SSD,相比基线模型提升 10.3%,同时远超 YOLOXs,说明

对露天矿场景中警示牌、落石、矿用卡车等目标的误检率更低。召回率维度的提升更为明显,MD-YOLOv8 的 78.9% 相比 YOLOv8 提升 19.4%,有效减少了复杂工况下小目标、遮挡目标的漏检情况。对于综合性能指标 mAP@ 50, MD-YOLOv8 相比 YOLOv8 提升 18.0%,证明它对不同类型障碍物的整体检测能力更强,能更适配露天矿多样的障碍物形态。计算复杂度方面,虽然改进模型高于 YOLOv8 和 YOLOXs,但远低于 Faster R-CNN 与 SSD,在精度大幅提升的同时,仍能满足无人矿卡实时检测的算力需求,避免因计算量过大导致检测延迟。

2.5 模型可视化分析

为直观展现改进模型在露天矿复杂场景中的障碍物检测能力,选取含警示牌、矿用卡车、落石的场景图像进行检测效果可视化对比,结果如图 6 所示。



图 6 检测效果可视化
Fig. 6 Visualization of detection results

在雾霏道路场景中,STA 强化了时空特征建模,使热力图更聚焦目标核心区域,小尺寸警示牌的特征激活更集中。即便遮雾干扰导致特征模糊,动态路由机制仍能捕捉目标连续性特征,热力分布贴合实际形状;CARAFE 算子优化的检测框定位精准,与真实边界贴合紧密,配合 Shape-NWD 损失函数提升置信度,有效针对雾霏场景小目标识别困难的问题。面对会车道路场景,颈部网络动态特征路由机制增强多尺度融合效率,针对遮挡目标,边界框借助低层特征与高层语义的互补,准确反映实际轮廓,落石等遮挡目标识别更优。多尺度检测中,小目标依托 CARAFE 算子的边缘纹理增强,成功提取特征,更贴近真实目标。在积雪道路场景里,STA 的时空稳定性与颈部网络的特征强化能力协同,使小目标边界定位精准,检测框贴合真实边界。即便积雪覆盖掩

盖特征,动态路由与 CARAFE 算子仍能稳定提取警示牌等小目标特征,保障复杂环境下的检测鲁棒性,验证 Shape-NWD 损失函数对极端环境的适应性。

3 结 论

- 1) 从融入注意力机制、替换颈部网络结构和损失函数 3 方面改进基线模型,有效识别露天矿复杂场景中小目标及遮挡目标。
- 2) 通过自建数据集进行消融试验和各检测模型对比试验。结果表明:改进后模型的精度达 86.2%,较基线模型提升 10.3%;召回率为 78.9%,提升 19.4%;mAP@ 50 为 83.1%,提升 18.0%;计算复杂度为 16.9GFLOPs,远低于 FasterR-CNN 和 SSD,在保证精度的同时满足无人矿卡实时检测需求,为安全行驶提供技术保障。

3) 当前数据集仅取自单一露天矿,场景覆盖有限。未来将重点拓展多矿区条件下的数据集,以进一步验证模型鲁棒性。

参 考 文 献

[1] 付恩三,刘光伟,白润才,等. 大数据时代矿山协同监管监察新思路[J]. 中国安全科学学报, 2023, 33(8): 39-44.
FU Ensan, LIU Guangwei, BAI Runcai, et al. Exploration and research of mine multi-element cooperative supervision new thinking in era of big data[J]. China Safety Science Journal, 2023, 33(8): 39-44.

[2] 阮顺领,王京,顾清华,等. 面向边缘计算的矿区障碍检测模型研究[J]. 煤炭科学技术, 2024, 52(11): 141-152.
RUAN Shunling, WANG Jing, GU Qinghua, et al. Research on mining area obstacle detection model for edge computing[J]. Coal Science and Technology, 2024, 52(11): 141-152.

[3] VERMA S, BERNSTEIN S D. Real-time kinematics-based sensor-fault detection for autonomous vehicles using single and double transport with adaptive numerical differentiation[J]. Control Engineering Practice, 2025, 159: DOI:10.1016/J.CONENGPRAC.2025.106304.

[4] BOTEZATU A P, BURLACU A, ORHEI C. A review of deep learning advancements in road analysis for autonomous driving[J]. Applied Sciences, 2024, 14(11): DOI:10.3390/APP14114705.

[5] PONN T, KROGER T, DIERMEYER F. Identification and explanation of challenging conditions for camera-based object detection of automated vehicles[J]. Sensors, 2020, 20(13): DOI:10.3390/s20133699.

[6] 朱永军,蔡光琪,韩进,等. 基于改进 YOLOv11 的露天矿复杂背景下小目标检测[J]. 工矿自动化, 2025, 51(4): 93-99.
ZHU Yongjun, CAI Guangqi, HAN Jin, et al. Small object detection in complex open-pit mine backgrounds based on improved YOLOv11[J]. Journal of Mine Automation, 2025, 51(4): 93-99.

[7] 顾清华,周琼,王丹. 基于改进 YOLOv8 的露天矿区行车障碍物检测[J]. 黄金科学技术, 2024, 32(2): 345-355.
GU Qinghua, ZHOU Qiong, WANG Dan. Traveling obstacle detection in open-pit mine area based on improved YOLOv8[J]. Gold Science and Technology, 2024, 32(2): 345-355.

[8] 续瑞,王建国,朱勒地孜·马合买提,等. 基于单目视觉的露天矿卡道路障碍物检测及测距算法研究[J]. 现代矿业, 2025, 41(4): 5-10.
XU Rui, WANG Jianguo, JULEDZI Mahmut, et al. Research of obstacle detection and location algorithm based on monocular vision in open-pit mining truck roads[J]. Modern Mining, 2025, 41(4): 5-10.

[9] 程铄棋,伊力哈木·亚尔买买提,谢丽蓉,等. 露天矿山下无人矿卡的轻量级障碍检测算法研究[J]. 煤炭科学技术, 2025, 53(7): 262-274.
CHENG Shuoqi, ILHAMU·Yarmaimaiti, XIE Lirong, et al. Lightweight detection algorithms for small targets on unmanned mining trucks [J]. Coal Science and Technology, 2025, 53(7): 262-274.

[10] 顾清华,苏存玲,王倩,等. 基于双曲嵌入的露天矿区暗光环境下道路多目标检测模型[J]. 工矿自动化, 2024, 50(1): 49-56, 114.
GU Qinghua, SU Cunling, WANG Qian, et al. A multi-target road detection model in a low-light environment in an open-pit mining area based on hyperbolic embedding[J]. Journal of Mine Automation, 2024, 50(1): 49-56, 114.

[11] 王仁炎,陆占国,胡振涛,等. 基于改进 YOLOv3 的露天矿卡车目标检测方法[J]. 矿业研究与开发, 2024, 44(2): 164-169.
WANG Renyan, LU Zhanguo, HU Zhentao, et al. Target detection method of truck in open-pit mine based on improved YOLOv3 algorithm[J]. Mining Research and Development, 2024, 44(2): 164-169.

[12] 夏正洪,何琥,杨磊,等. 基于改进 YOLOv8n 的飞机铆钉及脱落异常检测算法[J]. 中国安全科学学报, 2025, 35(2): 66-72.
XIA Zhenghong, HE Hu, YANG Lei, et al. Aircraft rivet and detachment anomaly detection algorithm based on improved YOLOv8n[J]. China Safety Science Journal, 2025, 35(2): 66-72.



作者简介: 刘光伟 (1981—),男,辽宁沈阳人,博士,教授,主要从事露天矿开采设计基础理论与矿业系统工程研究。E-mail:liuguangwei@Intu.edu.cn。