

DOI:10.19651/j.cnki.emt.2417770

改进 YOLOv8 的煤矿井下低照度图像钻杆计数方法^{*}

冉庆庆 董立红 温乃宁

(西安科技大学计算机科学与技术学院 西安 710054)

摘要: 针对现有的煤矿井下钻杆计数方法在低照度环境下统计精度低且性能下降等问题,提出一种基于改进 YOLOv8 的煤矿井下低照度图像钻杆计数方法。该方法通过检测钻机卡盘与夹持器两个预测框的中心点坐标,绘制间距曲线并统计波峰的数值实现钻杆数量的计算。首先,采用 SCI 模块对低照度图像进行前置处理,解决低照度图像光照不均、对比度低等问题,确保后续模型能够提取到更多有效特征信息;其次,在主干网络中将 EMA 注意力机制融合到 C2f 模块,保留各通道的信息并建立长短期长下文依赖关系,增强对低照度、复杂背景中目标关注程度;此外,在颈部网络使用 BiFPN 结构作为特征融合方式以降低特征信息丢失,增强网络特征融合能力,提高模型在低照度场景下的检测精度;最后,设计了 Inner-CIoU 损失函数,基于不同大小的辅助边界框回归,提升模型对低照度和噪声的适应能力。实验结果表明,改进后的 YOLOv8-GC 算法 mAP@0.5 提升了 5.7%,检测速度达到 151 fps;低照度环境下钻杆计数精度达 97.2%,充分证明了本文改进算法的有效性和应用潜力。

关键词: 瓦斯抽采;低照度;SCI;目标检测;EMA;BiFPN;钻杆计数

中图分类号: TP391.41; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

Improved YOLOv8 method for counting drill rods in low-light images in coal mines

Ran Qingqing Dong Lihong Wen Naining

(College of Computer Science and Technology, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: Aiming at the issues of low statistical accuracy and performance degradation of existing coal mine underground drill pipe counting methods in low-light environments, this paper proposes a low-light image drill pipe counting method for coal mine underground based on improved YOLOv8. This method calculates the number of drill pipes by detecting the center point coordinates of the two prediction boxes of the drill chuck and the holder, drawing the spacing curve, and counting the peaks. Firstly, the SCI module is used for pre-processing low-light images to address issues such as uneven illumination and low contrast, ensuring that the subsequent model can extract more effective feature information. Secondly, the EMA attention mechanism is integrated into the C2f module in the backbone network to retain information from each channel and establish long- and short-term context dependencies, enhancing the focus on targets in low-light and complex backgrounds. Additionally, the BiFPN structure is used as the feature fusion method in the neck network to reduce feature information loss and enhance the network's feature fusion capability, improving the detection accuracy of the model in low-light scenarios. Finally, the Inner-CIoU loss function is designed, based on auxiliary bounding box regression of different sizes, to enhance the model's adaptability to low-light and noise. Experimental results show that the improved YOLOv8-GC algorithm achieves a 5.7% increase in mAP@0.5, with a detection speed of 151 fps; the drill pipe counting accuracy in low-light environments reaches 97.2%, fully demonstrating the effectiveness and application potential of the proposed improved algorithm.

Keywords: gas extraction; low illumination; SCI; target detection; EMA; BiFPN; drill pipe counting

0 引言

中国是世界上最大的煤炭生产国,煤炭作为我国能源

结构的主体,其安全稳定供给对于国家能源安全具有重要意义^[1]。而与煤相伴的瓦斯,随着煤炭开采强度和深度的增加,含量和压力也不断升高,不仅危及矿工的生命安全,

而且还严重威胁煤矿安全生产和煤炭的稳定供给。为有效防范煤与瓦斯事故,确保煤矿安全稳定开采,在煤矿掘进前进行瓦斯抽取已成为预防此类事故的关键举措^[2-3]。目前,煤矿通常采用钻机打孔进行瓦斯抽取,而钻孔深度是评估抽采效果的关键指标。常通过统计钻杆数量间接计算钻孔深度,进而分析瓦斯抽采是否达到预期标准。因此,准确统计钻杆数量,对于煤矿瓦斯治理、能源结构优化、保障矿井安全生产至关重要^[4]。

目前,传统的钻杆计数方法主要依赖井下工作人员实时记录与井上人员观察打钻录像进行验收,劳动强度大且作业效率低。随着钻探设备的发展,煤矿企业开始使用随钻测量技术获取钻孔数据^[5],但其依赖专用设备与仪器,安装困难且成本高昂。

近年来,随着人工智能的快速发展,其各种方法已经广泛应用于安全、国防、通信、教育等领域^[6-7]。国内越来越多学者开始采用基于图像处理的方法进行钻杆计数研究。董立红等^[8]基于改进的 Camshift 算法,实时捕捉钻杆目标,并设置锚点和判断时间间隔来进行钻杆计数。彭业勋等^[9]结合角点检测和金字塔光流法,利用跳帧思想进行钻杆计数。Zhou 等^[10]基于 LDOF 算法捕捉钻杆运动信息,并通过光流进一步建立模型实现钻杆计数。方杰等^[11]利用 ECO-HC 算法实时跟踪钻杆目标,通过分析钻杆的运动轨迹波形图建立计数模型进行钻杆计数。Tan 等^[12]使用改进的 KCF 算法跟踪钻机,根据钻机运动轨迹计算钻杆数量。以上传统的图像处理方法,在煤矿井下这样复杂多变、光照条件差的环境中,稳定性不足。

宗占强^[13]使用 AlexNet 网络对钻机打钻与装钻动作进行识别,实现钻杆计数。张栋等^[14]通过改进 MobileNetV2 模型识别钻机工作状态统计钻杆数量。高瑞等^[15]根据视频中卸杆和非卸杆动作的差异实现钻杆计数。杜京义等^[16]通过提取人体关键点信息得到骨架序列数据,从而识别不同的动作类别进行钻杆计数。但以上几种方法过于依赖工人动作识别,特征主观性强,在煤矿井下低照度场景下易与相似动作混淆,导致计数错误。王向前等^[17]结合改进 YOLOv5 和 DeepSORT 目标跟踪算法实现钻杆计数。张栋等^[18]通过目标检测记录钻机运动轨迹,获取打入钻杆数量。以上方法依赖分类器性能,对图像信息整合不足,在煤矿井下低照度场景下泛化能力弱,易漏检误检导致计数有误。

综合上述现有研究,尽管现有的煤矿井下钻杆计数方法在计数精度上取得了不错的成绩,但由于煤矿井下钻场环境特殊,其空间条件受限,且全天候人造光源分布不均,导致设备采集的图像光线不足、对比度低、细节模糊、背景复杂等,进而导致钻机识别效果欠佳,钻杆计数的统计精度也随之降低。

为了提高煤矿井下低照度场景下的钻杆计数精度,本文提出一种基于改进 YOLOv8 的钻杆计数方法。首先,在

YOLOv8 算法的基础上,构建钻机目标检测模型 YOLOv8-GC;针对低照度环境下图像退化等问题,采用 SCI 模块对低照度图像进行图像增强,提升钻机目标特征的对比度,凸显细节信息,降低低照度环境对检测的影响;设计了 C2f_EMA 模块增强模型对低照度、复杂背景中重点区域的关注程度。该模块通过结合 EMA 注意力机制,有效提高了通道利用率,并增强了模型的特征提取能力,从而能够更好突出特征图中钻机目标信息;使用 BiFPN 改造颈部网络,实现了目标语义信息和位置信息的充分融合和应用,使模型能够增强对局部和全局信息的感知,减少低照度的影响;设计了 Inner-CIoU 损失函数,基于不同尺度的辅助边界框加速回归,提升模型在低照度场景下的泛化能力、定位精度和收敛速度。接着,计算钻机卡盘与夹持器预测框的中心点坐标间距,绘制间距曲线并通过统计间距曲线的波峰数值确定钻进钻杆的数量,进而计算钻孔的深度。

1 YOLOv8 算法

YOLOv8 是 YOLO 目标检测算法的最新迭代版本,具备更快的速度和更高的准确性,其网络结构主要由输入端 (Input)、主干网络 (Backbone)、颈部网络 (Neck)、检测头 (Head) 四部分组成。在输入端,YOLOv8 使用 Mosaic 数据增强和自适应图片缩放技术,提升了模型对多样性和复杂场景的适应能力。主干网络使用 DarkNet53 结构自下而上负责从输入图像中提取特征。融合层采用了特征金字塔网络 (feature pyramid network, FPN) 和路径聚合网络 (path aggregation network, PAN) 的组合,增强了多尺度特征的融合与传递能力。在检测头部分使用解耦头结构,将检测与分类分离,从而确保模型在处理各类任务时的准确性和鲁棒性。

2 改进 YOLOv8 算法

本文提出一种基于改进 YOLOv8 算法的 YOLOv8-GC 算法,以实现高精度钻机目标检测。YOLOv8-GC 算法的网络结构如图 1 所示。

2.1 SCI 模块

煤矿井下钻场工作场景环境恶劣,缺乏自然光,主要依赖工人头灯照明,获取的图像质量差、对比度低等。导致图像中的目标往往与巷道背景的黑暗区域呈现低对比度融合状态,模型难以捕捉图像中目标的特征信息^[19],严重影响后续图像处理中检测以及计数结果。为此,本文采用自校准照明网络 (self-calibrating illumination network, SCI)^[20] 对图像进行预处理。

SCI 可以有效提高煤矿井下低照度图像的质量,不仅增强图像的亮度,还能有效恢复图像中的纹理细节,为模型在特征提取阶段提供更多有价值信息。此外,通过减少低光环境中的噪声干扰,SCI 网络显著提高了检测算法的鲁棒性,本文将在 3.4 节进行具体实验。SCI 结构如图 2 所示。

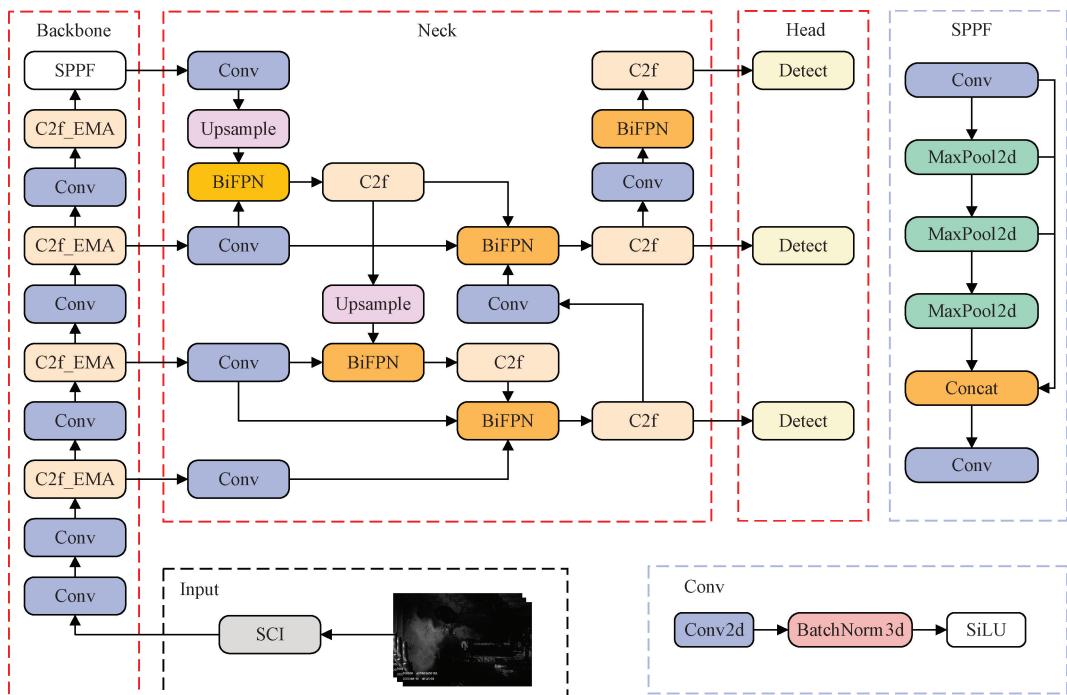


图 1 YOLOv8-GC 网络结构

Fig. 1 YOLOv8-GC network structure

在 Retinex 理论的基础上,SCI 采用分阶段的照明学习,并通过残差的方式学习低光观测值和照明之间的关系。其基本单元表示为:

$$F(X^t): \begin{cases} u^t = H_\theta(X^t), X^0 = y \\ X^{t+1} = X^t + u^t \end{cases} \quad (1)$$

式中: u^t 和 X^t 表示第 t 阶段的残差项和光照; H_θ 是光照估计网络,采用权重共享机制,使各阶段共享相同的网络结构和参数。

为确保各阶段结果的一致性,SCI 引入了自校准模块,将其添加到低光观察值中以校正每个阶段的输入。自校准模块公式为:

$$G(X^t): \begin{cases} Z^t = y \otimes X^t \\ S^t = K_\theta(Z^t) \\ V^t = y + S^t \end{cases} \quad (2)$$

式中: Z^t 是当前阶段输出 X^t 和低照度观察图像 y 计算的融合结果, S^t 是自校准映射,由参数化算子 k 生成, V^t 是经过校准后的输入,用于下一阶段。

因此,第 t 阶段光照优化过程基本单元可重新表示为:

$$F(X^t) \rightarrow F(G(X^t)) \quad (3)$$

这样算法在学习过程通过级联照明学习与自校正模块以改善煤矿井下钻场低照度图像质量提升图像清晰度。

2.2 C2f_EMA 模块

由于钻场工作面低照度、复杂背景环境的影响,加之钻机长时间运行,钻机表面覆盖大量煤尘,因此在对煤矿井下钻机卡盘、夹持器目标进行检测时,存在前景目标与

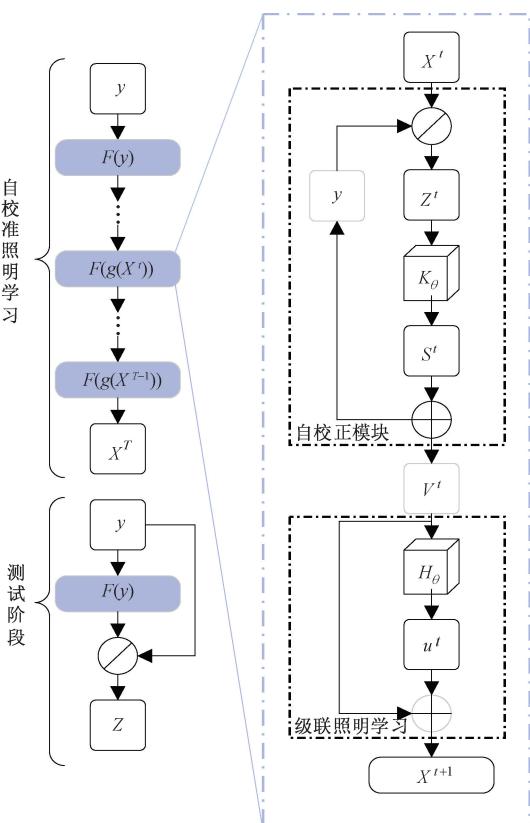


图 2 SCI 结构

Fig. 2 SCI structure

巷道背景相似、对比度低、质量差等问题,导致现有的目标检测模型在进行检测时,存在有效特征信息利用困难、检测精度低等问题。为了解决该问题,本文在骨干网络中引入了高效多尺度注意力(efficient multi-scale attention, EMA)机制^[21],其结构如图 3 所示。EMA 将输入特征图沿通道维度划分为 g 个子特征,然后使用 3 条多尺度并行子网络分组学习不同的特征信息,确保空间语义特征在特征组内均匀分布,同时减少操作复杂度。此外,该模块通过跨空间学习的方法,从不同空间维度聚合信息,提高对重要信息的关注程度。

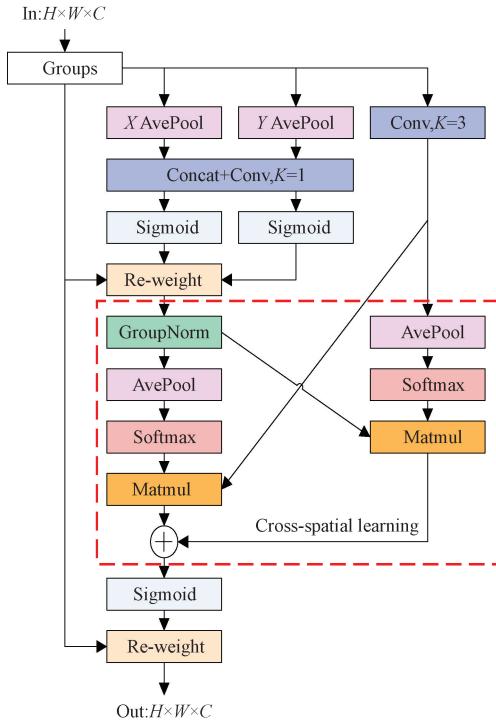


图 3 EMA 注意力机制结构

Fig. 3 EMA attention mechanism structure

本文将 EMA 注意力机制嵌入到 C2f 模块中的 Bottleneck 结构之前,形成 C2f_EMA 模块,其结构如图 4 所示。C2f_EMA 模块通过通道和跨空间的信息交互,动态调整权重以优化模型对钻机目标的关注度,从而突出特征图中的钻机目标信息,有利于恢复低照度图像中分散和模糊的特征,提高模型在低照度场景下的特征提取能力。

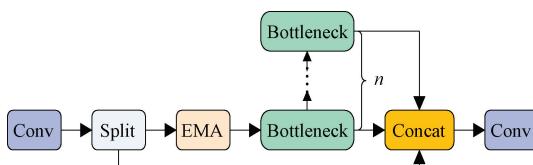


图 4 C2f_EMA 结构

Fig. 4 C2f_EMA structure

2.3 BiFPN 特征融合网络

YOLOv8 采用 PAN+FPN 的结构进行多尺度特征融

合,其网络结构如图 5 所示。但是该特征融合网络没有考虑浅层特征与深层特征的直接融合,对来自骨干特征提取网络的原始信息利用率低,并且该网络在特征融合阶段未对不同尺度的输入特征进行差异化处理。这将导致特征图经历多次卷积和上下采样操作之后丢失部分局部细节特征和语义信息,造成目标特征信息与黑暗区域的背景噪声融合^[22],最终造成目标丢失,出现漏检情况。为改善这一状况,采用 BiFPN^[23]作为颈部网络整合来自不同层级的特征信息,包括低层级的细节特征和高层级的语义特征,进一步提升模型在低照度场景下对钻机卡盘、夹持器的检测精度。BiFPN 的网络结构如图 6 所示。

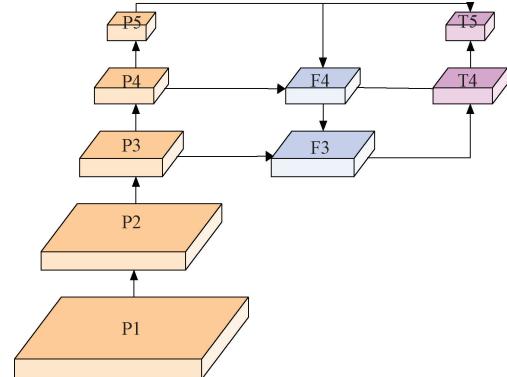


图 5 PAN-FPN 网络结构

Fig. 5 PAN-FPN network structure

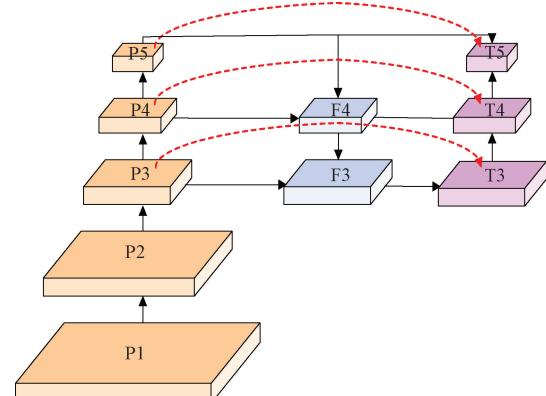


图 6 BiFPN 网络结构

Fig. 6 BiFPN network structure

相较于 PANet, BiFPN 首先去除了对网络贡献较低仅有只有一条输入边的节点,其次引入跳跃连接机制,通过增加特征融合路径来提升网络性能。此外,由于不同输入特征分辨率不同,其对输出特征的贡献也不相等,为解决这个问题,BiFPN 使用快速归一化来调整特征融合过程,引导网络模型更加关注深层信息的学习,减少因低照度环境造成的影响,其计算如式(4)所示。

$$O = \sum_i \frac{w_i}{\epsilon + \sum_j w_j} \times l_i \quad (4)$$

式中: w_i 为权重, 在每个 w_i 之后都应用 SiLU 激活函数确保其非负。此外, 为了避免数值不稳定, 设置 $\epsilon = 0.0001$, 并且归一化权重的每个值为 $0 \sim 1$ 之间。作为一个具体的例子, BiFPN 第 i 层的两个特征融合可以表示如下:

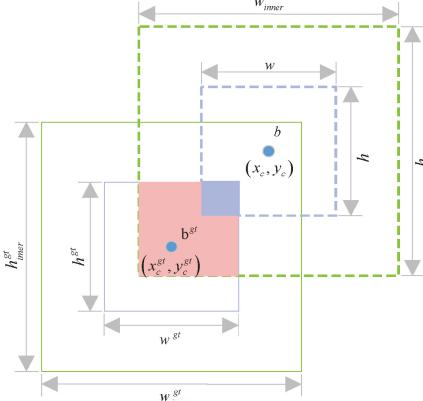
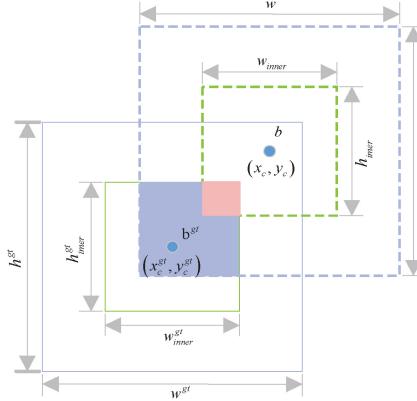
$$P_i^m = \text{Conv} \left(\frac{\omega_1 \times P_i^{in} + \omega_2 \times \text{Res}(P_{i+1}^{in})}{\omega_1 + \omega_2 + \epsilon} \right) \quad (5)$$

$$P_i^{out} = \text{Conv} \left(\frac{\omega'_1 \times P_i^{in} + \omega'_2 \times P_i^m + \omega_3 \times \text{Res}(P_{i-1}^{out})}{\omega'_1 + \omega'_2 + \omega'_3 + \epsilon} \right) \quad (6)$$

式中: P_i^{in} 是第 i 层的输入特征, P_i^m 表示自顶向下路径第 i 层的中间特征, P_i^{out} 表示自底向上路径第 i 层的输出特征, “Res” 是分辨率匹配的上采样或者下采样操作, “Conv” 通常指的是用于特征处理的卷积操作。

2.4 Inner-CIoU 损失函数

基于 IoU 相关的边界框回归损失函数不断迭代发展, 如 GIoU、DIoU、CIoU 等。YOLOv8 采用 CIoU 作为边



- █ Target Box
- █ InnerTarget Box
- █ Anchor Box
- █ InnerAnchor Box

图 7 Inner-IoU 损失函数

Fig. 7 Inner-IoU loss function

Inner-IoU 通过使用不同大小的辅助边界框来计算 IoU 损失, 其定义如式(10)所示。

$$IOU_{inner} = \frac{inter}{union} \quad (10)$$

式中: IOU_{inner} 是 Inner-IoU 的交并比, $inner$ 和 $union$ 的计算公式如式(11)、(12)所示。

$$inner = (\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \times (\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)) \quad (11)$$

$$union = (w^{gt} \times h^{gt}) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inter \quad (12)$$

式中: $inner$ 和 $union$ 分别是真实框与预测框的相交、合并区域, 其中, b_l^{gt} 、 b_r^{gt} 、 b_t^{gt} 、 b_b^{gt} 、 b_l 、 b_r 、 b_t 、 b_b 的计算公式如下:

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (13)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (14)$$

$$b_l = x_c - \frac{w \times ratio}{2}, b_r = x_c + \frac{w \times ratio}{2} \quad (15)$$

界框回归损失函数, CIoU 的计算公式如式(7)~(9)所示。

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (7)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (8)$$

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(r, r^{gt})}{n^2} + \alpha v \quad (9)$$

式中: v 用来权衡长宽比, α 为宽高比一致性参数, ρ^2 表示预测框与真实框中心点之间的欧氏距离。

针对现有 CIoU 损失函数在低照度钻机卡盘、夹持器检测任务中的泛化能力较弱且收敛速度较慢的问题, 引入了 Inner-IoU^[24] 损失函数对其进行改进, Inner-IoU 只关注边界框的中心部分而非整体重叠区域, 从而提高了重叠区域评估的准确性, 并加速了模型的学习过程和定位精度。Inner-IoU 的结构如图 7 所示。

图 7 Inner-IoU 损失函数

Fig. 7 Inner-IoU loss function

$$b_t = y_c - \frac{h \times ratio}{2}, b_b = y_c + \frac{h \times ratio}{2} \quad (16)$$

式中: $ratio$ 是控制辅助边界框尺度大小的比例因子, x_c^{gt} 和 y_c^{gt} 为真实框的中心点坐标, x_c 和 y_c 为预测框的中心点坐标。

在进行上述计算后, 将 Inner-IoU 和 CIoU 结合, 得到 Inner-CIoU 损失函数, 如式(17)所示。

$$L_{Inner-CIoU} = L_{CIoU} + IoU - IoU_{inner} \quad (17)$$

3 实验

3.1 数据集构建

本文实验使用的煤矿井下钻场低照度数据集, 一部分数据来源于开源的煤矿井下钻场目标检测数据集^[25], 另一部分来自 2021~2024 年期间, 某煤矿 40307 等多个工作面, 在不同低照明情况下, 使用矿用本安型执法记录仪从不同角度和不同距离拍摄的瓦斯抽采过程中的多段实际视频, 该设备能够实现最大分辨率为 400 万像素的图像采

集,帧率为 30 fps。该数据集涵盖了 31 个钻场,共计 137 段视频,每段视频时长均为 10 min。将采集的钻机实时打钻视频通过精心挑选和去重处理,随后经过抽帧和清洗的步骤获得分辨率为 1280×720 的 18 371 张低照度图像。使用 LabelImg 图像标注工具对筛选后的图像进行标注,生成包含钻机卡盘和夹持器位置信息的 txt 文件。随后将标注完成的图片按 7:2:1 的比例划分为训练集、验证集和测试集。

3.2 实验环境及参数设置

本文实验的操作系统为 Ubuntu 18.04, 使用 Python 3.8、CUDA 11.1 和 PyTorch 1.8.1 深度学习开发环境, GPU 为 NVIDIA GeForce RTX 3090, CPU 为 Intel(R) Xeon(R) Gold 6330 CPU @ 2.00 GHz。实验中, 使用 YOLOv8n 作为基线模型, 输入图像为 1280×720 , 初始学习率为 0.01, batch size 为 32, 模型动量系数和权重衰减因子分别设置为 0.937 和 0.0005, epochs 为 100。

3.3 性能评价指标

为了全面评估模型的性能,本文选择准确率(precision, P)、召回率(recall, R)、平均精度均值(mean average precision, mAP)以及每秒检测帧数(frames per second, FPS)作为模型性能评价指标。其计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i \quad (20)$$

$$FPS = \frac{FrameNum}{ElapsedTime} \quad (21)$$

式中: TP 表示预测为正样本的正样本数量,即正确检测到钻机卡盘和夹持器的数量; FP 表示将负样本误判为正样本的数量,即分类错误的检测目标数量; FN 表示正样本被错误预测为负样本的数量,即漏检的目标数,图 8 展示了这几种分类情况; AP_i 表示第 i 类检测目标的平均精度,即 P-R 曲线下的面积; FrameNum 为检测图片的数量, ElapsedTime 为完成检测所用的时间。

Representation of common evaluation metrics		Prediction	
		Positive A	Negative B
prediction	True A	TP	FP
	False B	FN	TN

图 8 评价指标

Fig. 8 Evaluation metrics

3.4 SCI 低光图像增强实验

为直观展现 SCI 模块的图像增强效果,从前述数据集中选取了几张低光照图像样本进行处理,并将图像增强前后的效果进行可视化对比,如图 9 所示,其中图 9(a)为数据集中的两张原始图像,图 9(b)为使用 SCI 图像增强算法处理后的图像。

从图 9(a)中可以观察到,由于整体亮度较低,钻机卡盘和夹持器与巷道背景相似,轮廓模糊,特征不明显,这对后续检测算法的性能构成了挑战。而对比图 9(b)可以明显看出,增强后的图像在亮度和对比度方面均明显优于原图,且更加细化了前景与背景差异,具有更高的视觉质量。特别是在钻机卡盘、夹持器边缘和细节部分,增强后的图像更加清晰可辨,为后续目标的准确检测提供了良好基础。

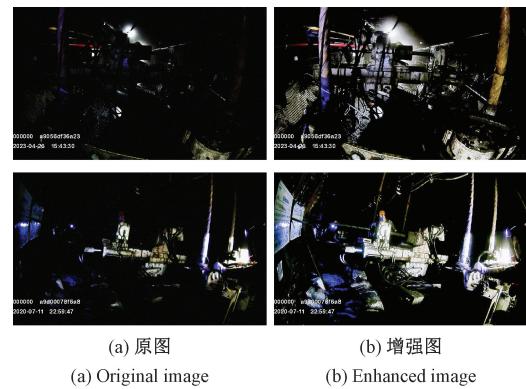


图 9 SCI 增强前后图像对比
Fig. 9 Comparison of images before and after SCI enhancement

为进一步探究不同图像增强方法对目标检测准确率的提升,本文采用自适应伽马变换 AGT^[26]、低照度图像增强算法(low-light image enhancement, LIME)^[27]、照亮式生成对抗网络(enlighten generative adversarial network, EnlightenGAN)^[28]、零参考深度曲线估计(zero-reference deep curve estimation, Zero-DCE)^[29]、以及 SCI 在内的多种方法分别对数据集图像进行增强处理,并在检测阶段均使用 YOLOv8n 模型进行评估。实验结果如表 1 所示,其中初始参照组为未使用图像增强方法进行处理。

表 1 各图像增强方法对比实验

Table 1 Comparison experiment of various image enhancement methods

增强方法	mAP@0.5/%
初始参照组	86.6
AGT	85.7
LIME	83.2
EnlightenGAN	87.0
Zero-DCE	87.1
SCI	88.2

从实验结果可以看出,传统图像增强方法 AGT 与 LIME 在增强图像的同时加剧了噪声问题,其 mAP 分别仅为 85.7% 和 83.2%。而深度图像增强算法 EnlightenGAN 和 Zero-DCE 相比原始检测效果有一定提升,但由于增强后的图像伪影、噪声干扰等问题没有得到抑制,仅能检测到较为明显的特征。使用 SCI 处理后的图像不仅增强了图像的明暗对比度,还有效降低了在低照度和光线复杂场景中因过曝光导致的误判率,其平均精度较

初始对照组从 86.6% 提升至 88.2%。因此,本文选用 SCI 图像增强方法对低照度图像进行处理。

3.5 消融实验

为验证所提出的各改进模块对模型性能的影响,使用相同的数据集和软硬件环境,以 YOLOv8n 为基线模型,依次对不同改进模块的检测效果进行消融实验。具体的消融实验结果如表 2 所示,其中“√”表示采用了该方法,“—”表示没有使用该方法。

表 2 消融实验结果

Table 2 Ablation experiment results

模型	SCI	C2f_EMA	BiFPN	Inner-CIoU	P/%	R/%	mAP@0.5/%	FPS
1	—	—	—	—	90.5	79.4	86.6	192
2	√	—	—	—	91.6	81.6	88.2	163
3	—	√	—	—	92.1	82.3	89.3	175
4	—	—	√	—	92.4	82.5	89.1	179
5	—	—	—	√	91.3	81.7	87.9	208
6	√	√	—	—	93.7	83.9	90.1	152
7	√	√	√	—	94.7	85.4	91.4	140
8	√	√	√	√	95.6	86.3	92.3	151

从表 2 可以明显看出,单独加入各改进模块,mAP@0.5 均得到了不同程度的提升,说明各改进模块的有效性。其中模型 2 在单独加入 SCI 后效果明显,改进后模型的 mAP@0.5 相较于基线提升了 1.6%,说明了模型通过采用级联的照明学习过程提升了低照度环境下图像的质量。模型 3 在加入 C2f_EMA 后相较于基线模型 mAP@0.5 提高了 2.7%,验证了该模块可以提高通道利用率,增强对重点区域的关注程度,更好的突出了特征图中的目标信息。模型 4 的 mAP@0.5 相较于基线模型提高了 2.5%,说明使用 BiFPN 改造模型颈部网络结构,增强了网络的特征融合能力,减少了复杂背景的影响。模型 5 在采用 Inner-IoU 基于不同尺度的辅助边界框改进基线模型损失函数后, mAP@0.5 也有效提升 1.3%。

组合加入各模块进行消融实验,模型整体性能仍呈现上升趋势。模型 6 在基线模型的基础上加入 SCI 模块,提升钻机目标特征的对比度,凸显更多细节信息,结合 C2f_EMA 模块保留各通道信息并建立长短期上下文依赖关系,增强模型在低照度场景下的特征提取能力,较基线模型其精度、召回率和 mAP@0.5 分别提高了 3.2%,4.5%,3.5%。模型 7 在模型 6 的基础上,使用 BiFPN 替代 PAN 和 FPN 作为颈部网络后,使模型增强对局部和全局信息的感知,减少低照度的影响,较基线模型精度提高了 4.2%,召回率提高了 6%,mAP@0.5 提高了 4.8%。模型 8 在模型 7 的基础上将原有的损失函数替换为 Inner-CIoU,进一步提高了模型的 P、R、mAP@0.5,说明 Inner-CIoU 能够很好的提升模型的泛化能力。综合实验结果表

明,各项改进策略均取得了显著效果,YOLOv8-GC 结合了各个模块的优势,在提升特征图利用率的同时,虽然 FPS 下降了 19 fps,但依然保持在 150 fps 以上,满足检测的要求,达到最佳效果。

为更加直观地评价 YOLOv8-GC 模型对煤矿井下钻机卡盘、夹持器目标检测的优越性,将其与基线模型分别使用前述数据集进行可视化分析,两种模型的结果如图 10 所示。

从图 10 中可以看出,基线模型在检测时发生了漏检、误检现象,而本文算法模型在漏检、误检方面都得到了很好的改善,可识别到因低照度漏检、误检的钻机卡盘、夹持器目标,同时目标的置信度也有所提升。可视化分析结果进一步证明了本文提出的低照度钻机目标检测方法使得目标具有更显著的特征表达和更高的模型定位精度,均有有效识别出待检测目标且置信度更高。

3.6 对比实验

为了进一步研究本文提出的方法在低照度钻机目标检测中的优势,选取了行业中应用广泛的其他主流目标检测模型,如 SSD^[30]、Faster-RCNN^[31]、YOLOv5、YOLOv7、YOLOv8、DK_YOLOv5^[32]、MLFE-YOLOX^[33]、YOLOv7-GFCA^[34] 与本文方法进行对比,所有模型均在相同的数据集和实验环境下进行对比实验,实验结果如表 3 所示。

从表 3 可以看出,SSD 作为常用的单阶段目标检测网络,mAP@0.5 最低,仅为 76.1%。本文提出的模型召回率和平均精度均优于其他模型,其中 mAP@0.5 达到了 92.3%,分别比 SSD、Faster-RCNN、YOLOv5、YOLOv7、

YOLOv8、DK_YOLOv5、MLFE-YOLOX、YOLOv7-GFCA 高出 16.2%、10.2%、7.6%、8.7%、5.7%、2.9%、2.1%、6.5%。召回率为 86.3%，分别比 SSD、Faster-RCNN、YOLOv5、YOLOv7、YOLOv8、DK_YOLOv5、MLFE-YOLOX、YOLOv7-GFCA 高出 17%、14.7%、9.6%、11%、6.9%、3.2%、2.5%、8.1%。因此对于低照度钻机目标检测任务来说，增强低照度环境下图像的亮度和

对比度以及模型的特征提取能力和特征融合能力，可以显著提升检测效果。尽管本文改进算法的 FPS 略低于 YOLOv8，这主要是由于模型复杂度的增加，但其满足低照度钻机目标检测的要求，同时在准确性上取得了最好的效果。综合各项指标考虑，本文方法在低照度钻机目标检测中具有更优异的性能，在低照度、复杂背景的钻场环境中，对钻机卡盘、夹持器的检测任务更有优势。

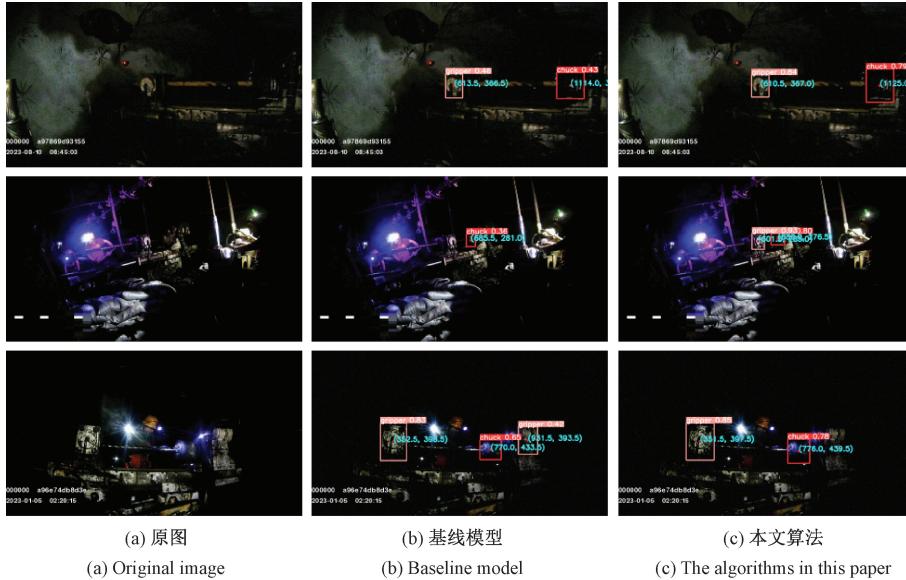


图 10 改进前后检测效果对比

Fig. 10 Comparison of detection results before and after improvement

表 3 不同检测算法的对比实验结果

Table 3 Comparison experiment results of different detection algorithms

模型	P/%	R/%	mAP@0.5/%	FPS
SSD	81.5	69.3	76.1	147
Faster-RCNN	87.1	71.6	82.1	93
YOLOv5	87.8	76.7	84.7	162
YOLOv7	88.0	75.3	83.6	169
YOLOv8	90.5	79.4	86.6	192
DK_YOLOv5	92.7	83.1	89.4	149
MLFE-YOLOX	93.4	83.8	90.2	174
YOLOv7-GFCA	89.7	78.2	85.8	186
本文方法	95.6	86.3	92.3	151

3.7 钻孔深度测量

改进的模型通过训练对煤矿井下钻机打钻视频进行检测，实现了钻机卡盘和夹持器的精确定位，从而在时间 t 获取两者预测框中心点的坐标信息，进而计算两者之间的距离 d_t ，如式(22)所示。

$$d_t = \sqrt{(x_t^c - x_t^g)^2 + (y_t^c - y_t^g)^2} \quad (22)$$

式中： d_t 是在时间 t 时卡盘和夹持器之间的距离， (x_t^c, y_t^c)

为卡盘的检测框中心点的坐标， (x_t^g, y_t^g) 为夹持器检测框中心点的坐标。

通过计算两者之间的距离并按时间顺序存储到文件中，滤波处理间距信息，统计波形的上升沿，从而计算钻杆数量和钻孔深度。图 11(a)和(b)展示了两段不同视频片段的钻机卡盘与夹持器的相对运动轨迹，纵坐标为两者预测框中心点的间距信息，横坐标为钻机打钻视频帧数变化情况。

为验证本文所提出的钻杆计数方法在煤矿井下钻场低照度工作环境中的实际应用效果，选取某省煤矿井下钻场工作面录制的 6 段钻机打钻完整过程视频进行测试，并采用人工计数的方法进行对比实验，统计结果如表 4 所示。

表 4 中，视频质量分为完整清晰和低照度。其中“进尺”是工人的钻孔进尺记录卡中填报数据，“人工验收”是验收人员人工数杆验收的数据，“模型验收”则是本文提出的钻杆计数方法自动计算的结果。

实验表明，本文方法在完整清晰视频中达到了 99.1% 的计数精度，即使在低照度场景下，也能达到 97.2% 的计数精度。因此，无论是在完整清晰还是低照度的场景下，本文提出的钻杆计数方法均表现出较高的准确率，且本文提出的方法计数精度与人工计数基本保持一致。综上所

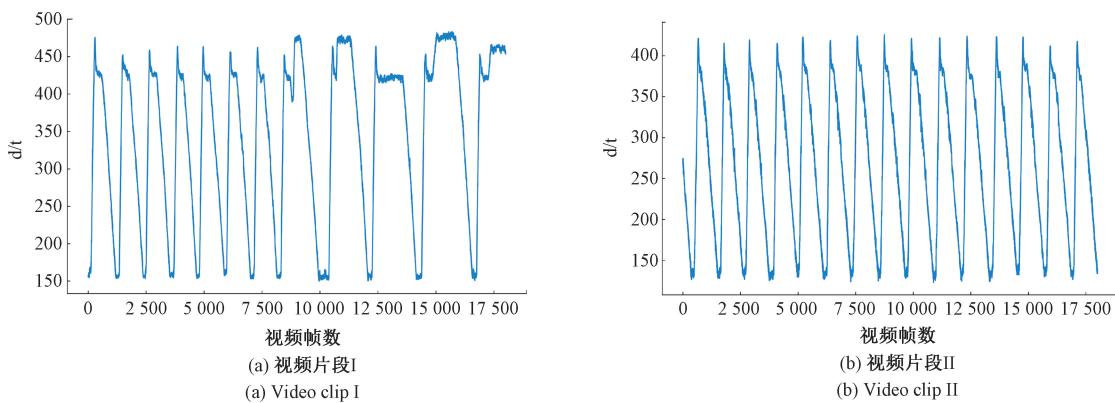


图 11 钻机卡盘与夹持器相对运动轨迹

Fig. 11 Relative motion trajectory of the drill rig chuck and the gripper

表 4 智能化钻杆计数验收台账

Table 4 Intelligent drill rod counting acceptance log

钻孔编号	方位角	倾角	孔径	进尺	人工验收	模型验收	视频质量验收情况
001	180	3	113	90	89	90	完整清晰
002	180	3	113	100	98	99	完整清晰
003	180	5	113	180	176	182	完整清晰
004	180	5	113	190	183	186	完整、低照度
005	180	5	113	120	115	116	完整、低照度
006	180	3	113	160	152	155	完整、低照度

述,本文方法具有较高的应用价值。

4 结 论

针对煤矿井下低照度环境下钻机卡盘与夹持器图像对比度低、图片质量差等问题,本文引入了 SCI 图像增强方法,有效提升了目标位置及细节信息的可见性,将平均精度从 86.6% 提升至 88.2%。

在 YOLOv8 的主干网络中,本文将 EMA 注意力机制融合到 C2f 模块中,并引入加权特征金字塔网络 BiFPN 作为颈部网络,以及设计了 Inner-CIoU 损失函数,显著增强了模型的特征提取能力、特征融合能力和定位精度。

大量实验结果表明,YOLOv8-GC 模型的平均精度均值达到了 92.3%,检测速度为 151 fps,优于 SSD 和 YOLOv3 等目前主流的目标检测算法。将 YOLOv8-GC 模型应用于煤矿井下钻机打钻视频,通过绘制间距曲线并统计钻杆数量,计数精度在完整清晰视频中达到 99.1%,在低照度视频中达到 97.2%,均能较为准确进行钻杆计数。

参考文献

- [1] 中矿(北京)煤炭产业景气指数研究课题组,郭建利. 2023~2024 年中国煤炭产业经济形势研究报告[J]. 中国煤炭, 2024, 50(3): 12-20.
Research Group of Zhongkuang(Beijing) Coal Industry

Prosperity Index, GUO J L. Research report on the economic situation of China's coal industry from 2023 to 2024[J]. China Coal, 2024, 50(3): 12-20.

- [2] 梁运培,郑梦浩,李全贵,等. 我国煤与瓦斯突出预测与预警研究现状[J]. 煤炭学报, 2023, 48(8): 2976-2994. LIANG Y P, ZHENG M H, LI Q G, et al. A review on prediction and early warning methods of coal and gas outburst[J]. Journal of China Coal Society, 2023, 48 (8): 2976-2994.
- [3] 王恩元,张国锐,张超林,等. 我国煤与瓦斯突出防治理论技术研究进展与展望[J]. 煤炭学报, 2022, 47(1): 297-322. WANG EN Y, ZHANG G R, ZHANG CH L, et al. Research progress and prospect on theory and technology for coal and gas outburst control and protection in China[J]. Journal of China Coal Society, 2022, 47(1): 297-322.
- [4] 胡金成,张立斌,蒋泽,等. 基于 AI 视频分析的煤矿瓦斯抽采钻场远程监督管理方法[J]. 工矿自动化, 2023, 49(11): 167-172. HU J CH, ZHANG L B, JIANG Z, et al. Remote supervision and management method for coal mine gas extraction drilling site based on AI video analysis[J]. Journal of Mine Automation, 2023, 49(11): 167-172.

- [5] 陈泽平, 闫保永, 王国震, 等. 煤矿井下随钻测量技术研究现状及展望[J]. 矿业安全与环保, 2022, 49(6): 130-134.
- CHEN Z P, YAN B Y, WANG G ZH, et al. Research status and prospect of MWD technology in coal mine [J]. Mining Safety & Environmental Protection, 2022, 49(6): 130-134.
- [6] 常丽, 张雪, 蒋辉, 等. 融合 YOLOv5s 与 SRGAN 的实时隧道火灾检测[J]. 电子测量与仪器学报, 2022, 36(8): 223-230.
- CHANG L, ZHANG X, JIANG H, et al. Real-time tunnel fire detection by fusion of YOLOv5s and SRGAN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 223-230.
- [7] 董兆苒, 董明利, 何彦霖, 等. 血管介入手术导丝末端检测方法研究[J]. 仪器仪表学报, 2023, 44(2): 221-229.
- DONG ZH R, DONG M L, HE Y L, et al. Study on the detection method of putting guide wire endin vascular interventional surgery[J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 221-229.
- [8] 董立红, 王杰, 库向阳. 基于改进 Camshift 算法的钻杆计数方法[J]. 工矿自动化, 2015, 41(1): 71-76.
- DONG L H, WANG J, SHE X Y. Drill counting method based on improved Camshift algorithm [J]. Journal of Mine Automation, 2015, 41(1): 71-76.
- [9] 彭业勋. 煤矿井下钻杆计数方法研究[D]. 西安: 西安科技大学, 2019.
- PENG Y X. Research on the counting method of drill pipe in coal mine [D]. Xi'an: Xi'an University of Science and Technology, 2019.
- [10] ZHOU M, YUAN J, GAO Z, et al. Drill pipe counting method based on local dense optical flow estimation [C]. Image and Graphics: 11th International Conference, 2021: 443-454.
- [11] 方杰, 李振璧, 夏亮. 基于 ECO-HC 的钻杆计数方法[J]. 煤炭技术, 2021, 40(11): 186-189.
- FANG J, LI ZH B, XIA L. Drill pipe counting method based on ECO-HC [J]. Coal Technology, 2021, 40(11): 186-189.
- [12] TAN T, GUO C, ZHANG G, et al. Research and application of downhole drilling depth based on computer vision technique [J]. Process Safety and Environmental Protection, 2023, 174: 531-547.
- [13] 宗占强. AlexNet 网络的井下钻杆打钻动作识别[J]. 电子世界, 2021(17): 118-120.
- ZONG ZH Q. Drilling action recognition of downhole drill pipe in AlexNet network[J]. Electronic World, 2021(17): 118-120.
- [14] 张栋, 姜媛媛. 基于改进 MobileNetV2 的钻杆计数方法[J]. 工矿自动化, 2022, 48(10): 69-75.
- ZHANG D, JIANG Y Y. Drill pipe counting method based on improved MobileNetV2[J]. Journal of Mine Automation, 2022, 48(10): 69-75.
- [15] 高瑞, 郝乐, 刘宝, 等. 基于改进 ResNet 网络的井下钻杆计数方法[J]. 工矿自动化, 2020, 46(10): 32-37.
- GAO R, HAO L, LIU B, et al. Research on underground drill pipe counting method based on improved ResNet network [J]. Journal of Mine Automation, 2020, 46(10): 32-37.
- [16] 杜京义, 党梦珂, 乔磊, 等. 基于改进时空图卷积神经网络的钻杆计数方法[J]. 工矿自动化, 2023, 49(1): 90-98.
- DU J Y, DANG M K, QIAO L, et al. Drill pipe counting method based on improved spatial-temporal graph convolution neural network[J]. Journal of Mine Automation, 2023, 49(1): 90-98.
- [17] 王向前, 史策. 基于 DeepSORT 和改进 YOLOv5 的煤矿井下钻杆计数方法[J]. 煤炭技术, 2024, 43(2): 200-204.
- WANG X Q, SHI C. Drill pipe counting method based on DeepSORT and improved YOLOv5 in coal mine underground [J]. Coal Technology, 2024, 43(2): 200-204.
- [18] 张栋, 姜媛媛. 融合机制与逆残差结构的轻量级钻机目标检测方法[J]. 电子测量与仪器学报, 2022, 36(11): 201-210.
- ZHANG D, JIANG Y Y. Lightweight target detection method of drilling rig based on attention mechanism and inverse residual structure[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 201-210.
- [19] 刘震, 杨贤昭, 陈洋, 等. 基于改进 YOLOv8s 的雾天目标检测算法[J]. 电子测量技术, 2024, 47(20): 186-194.
- LIU ZH, YANG X ZH, CHEN Y, et al. Object detection algorithm for foggy conditions based on improved YOLOv8s [J]. Electronic Measurement Technology, 2024, 47(20): 186-194.
- [20] MA L, MA T, LIU R, et al. Toward fast, flexible, and robust low-light image enhancement[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 5637-5646.
- [21] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal

- Processing(ICASSP). IEEE, 2023: 1-5.
- [22] 黄玉龙,张晓玲.基于图像特征增强的低照度目标检测算法[J].电子测量技术,2024,47(13):167-175.
HUANG Y L, ZHANG X L. Low-light object detection algorithm based on image feature enhancement [J]. Electronic Measurement Technology, 2024, 47(13): 167-175.
- [23] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [24] ZHANG H, XU C, ZHANG S. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arXiv: 2311.02877, 2023.
- [25] 周蔚,董立红,叶鸥,等.煤矿井下钻场目标检测数据集[J].中国科学数据(中英文网络版),2024, 9 (2): 305-317.
ZHOU W, DONG L H, YE OU. et al. Coal mine drilling field target detection dataset [J]. Chinese Scientific Data(Chinese and English Online Version), 2024, 9(2): 305-317.
- [26] 牟琦,葛相甫,王新月,等.基于多尺度梯度域引导滤波的煤矿井下图像增强方法[J].工矿自动化,2024, 50(6): 79-88,111.
MU Q, GE X F, WANG X Y, et al. A coal mine underground image enhancement method based on multi-scale gradient domain guided image filtering[J]. Journal of Mine Automation, 2024, 50(6): 79-88, 111.
- [27] GUO X, LI Y, LING H. LIME: Low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing, 2016, 26 (2): 982-993.
- [28] JIANG Y, GONG X, LIU D, et al. Enlightengan: Deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing, 2021, 30: 2340-2349.
- [29] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1780-1789.
- [30] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector [C]. 14th European Conference on Computer Vision. Amsterdam: Springer, 2016: 21-37.
- [31] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [C]. 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2015: 91-99.
- [32] WANG J, YANG P, LIU Y, et al. Research on improved YOLOv5 for low-light environment object detection[J]. Electronics, 2023, 12(14): 3089.
- [33] 谭豪,张惊雷,贾鑫.基于多级特征提取的低光照目标检测算法[J].计算机工程与应用,2024, 60 (24): 235-242.
TAN H, ZHANG J L, JIA X. Low-light target detection algorithm based on multi-level feature extraction [J]. Computer Engineering and Applications, 2024, 60(24): 235-242.
- [34] CHEN T, DONG L, SHE X. Research on automatic counting of drill pipes for underground gas drainage in coal mines based on YOLOv7-GFCA model [J]. Applied Sciences, 2023, 13(18): 10240.

作者简介

冉庆庆(通信作者),硕士研究生,主要研究方向为计算机视觉。

E-mail:1258557014@qq.com

董立红,博士,教授,主要研究方向为智能信息处理技术。
E-mail:1430315357@qq.com

温乃宁,博士,高级工程师,主要研究方向为计算机系统集成与智能测控。

E-mail:695517184@qq.com