

陈伟,穆华星,管彦允,等.改进YOLOv8s的煤矿井下矿工行为检测方法[J].辽宁工程技术大学学报(自然科学版),2025,44(3):257-264.DOI:10.11956/j.issn.1008-0562.20240239

CHEN Wei, MU Huaxing, GUAN Yanyun, et al. Improving YOLOv8s for behavior detection of underground miners in coal mine[J]. Journal of Liaoning Technical University(Natural Science), 2025, 44(3): 257-264. DOI: 10.11956/j.issn.1008-0562.20240239

改进YOLOv8s的煤矿井下矿工行为检测方法

陈伟^{1,2}, 穆华星^{1,2}, 管彦允^{1,2}, 刘珏廷^{1,2*}, 徐婷婷^{1,2}, 王泽华^{1,2}

(1. 中国矿业大学 计算机科学与技术学院, 江苏 徐州 221116;

2. 中国矿业大学 矿山数字化教育部工程研究中心, 江苏 徐州, 221116)

摘要: 为解决煤矿井下视觉设备对矿工行为检测效果不佳的问题, 采用模型优化和实验的方法, 基于YOLOv8s构建基准模型, 引入高效多尺度注意力机制改进主干网络, 增强对矿工多姿势及多尺度特征的提取和表示能力。优化损失函数, 提高对于井下复杂场景中低质量图像检测的准确性和稳定性。设计一种轻量化模块, 替换原颈部深层网络的特征处理模块, 保障检测高效性。研究表明: 改进后的模型对井下矿工行为检测的平均精确度均值提高了1.2%, 模型参数量减少了17%。研究结论为类似场景下特定任务的目标检测优化提供借鉴。

关键词: 煤矿复杂环境; 行为检测; YOLOv8s; 注意力机制; 轻量化; 低质量图像

中图分类号: TD76

文献标志码: A

文章编号: 1008-0562(2025)03-0257-08

Improving YOLOv8s for behavior detection of underground miners in coal mine

CHEN Wei^{1,2}, MU Huaxing^{1,2}, GUAN Yanyun^{1,2}, LIU Jueting^{1,2*}, XU Tingting^{1,2}, WANG Zehua^{1,2}

(1. School of Computer Science and Technology, China University of Mining and Technology,

Xuzhou 221116, China; 2. Mining Digital Education Ministry Engineering Research Center,

China University of Mining and Technology, Xuzhou 221116, China)

Abstract: To address the problem of poor performance in detecting miner behavior in underground coal mine through visual equipment, model optimization and experimental methods are adopted. A benchmark model is constructed based on YOLOv8s. An efficient multi-scale attention mechanism is introduced to improve the backbone network, enhancing the ability to extract and represent multi-pose and multi-scale features of miners. The loss function is optimized to improve the accuracy and stability of low-quality image detection in complex underground scenes; a lightweight module is designed to replace the feature processing module of the original neck deep network, ensuring efficient detection. The results show that the average accuracy of the improved model for underground miner behavior detection is increased by 1.2%, and the amount of model parameters is reduced by 17%. The research conclusions provide reference for the target detection optimization of specific tasks in similar scenarios.

Keywords: complex environment of coal mines; behavior detection; YOLOv8s; attention mechanism; lightweight; low quality image

0 引言

煤矿井下目标检测是建设煤矿人工智能辅助监管监察系统的关键任务, 对煤矿行业的高质量

发展具有重要意义^[1-2]。煤矿井下作业环境复杂, 对井下作业人员的行为规范性提出了严格要求^[3-4], 矿工的不规范行为会导致煤矿安全隐患^[5-6], 为保障综采工作面人员安全, 有必要对矿井作业人员

收稿日期: 2024-08-03 修回日期: 2024-11-26 接受日期: 2024-12-30 责任编辑: 张雯

基金项目: 国家自然科学基金面上项目(52274160; 51874300); 国家自然科学基金委员会-山西省人民政府煤基低碳联合基金项目(U1510115)

作者简介: 陈伟(1978-), 男, 江苏徐州人, 博士, 教授, 主要从事智能矿山、计算机视觉方面的研究。E-mail: chenwdavior@163.com

通信作者: 刘珏廷(1990-), 男, 河南洛阳人, 博士, 讲师, 主要从事智能矿山、自然语言处理方面的研究。E-mail: 6476@cumt.edu.cn

的行为进行检测^[7-8]。然而,受井下复杂环境图像质量差^[9-10]、待检测对象的特征多样^[11]以及计算资源受限^[12-13]等问题影响,现有检测方法应用于该场景该任务时检测效果不佳。

目前,井下目标检测研究集中于单一类别的矿工、安全帽、煤矸石的检测^[14-15],而针对多种类别的矿工行为检测研究相对较少。温廷新等^[16]基于迁移学习的残差网络识别出矿工的跌倒与投掷两个动作,获得了良好效果。刘浩等^[17]使用 OpenPose 神经网络识别人体关键点,结合特征提取网络实现了井下多种不安全行为的识别。王宇等^[18]基于多模态特征融合对井下人员的不安全行为进行识别。YAO 等^[19]改进了 YOLOv5s 模型,对矿工在提升罐笼过程中不戴安全帽进行了行为识别。

上述相关研究存在如下问题:没有在复杂环境中进一步检测出对象的位置;未充分考虑煤矿井下复杂特定环境和待检测对象的特征;对矿工

行为姿势的多样性特征关注不足,对于井下存在多尺度多姿态变化的检测对象缺乏针对性;模型较大且验证数据集类别少、规模小,模型的鲁棒性有待验证。因此,本文提出基于 YOLOv8s 模型改进的矿工行为检测方法,并通过大型数据集验证所提方法的有效性和鲁棒性。

1 改进的井下矿工行为检测方法

1.1 方法概述

YOLOv8s 模型在通用数据集的目标检测任务中表现良好,但在煤矿井下这一特定场景,检测矿工行为时效果不佳。井下活动对象和检测角度多,待检测对象多姿势多尺度变化,且缺少计算和存储资源,图像质量差,呈“四多两缺一差”特征,对目标检测方法需要定制需求,YOLOv8s 模型存在较大改进空间。煤矿井下检测示意图 1。




图 1 井下综采工作面复杂环境与视觉设备示意

Fig. 1 complex environment and visual equipment of underground fully mechanized mining face

针对煤矿井下矿工行为检测需求,从以下三方面提出改进方案。

(1) 改进 YOLOv8s 的主干网络,引入高效多尺度注意力(efficient multi-scale attention, EMA)模块,设计融合 EMA 的主干网络,以更好适应井下矿工行为的多姿势多尺度变化特点,增强模型对不同姿势下多尺度变化特征的提取和表示能力。

(2) 优化损失函数,设计基于具有动态非单调聚焦机制的 IoU (wise-IoU, WIoU) 边界框回归

损失函数,替换 CIoU 损失函数,以适应井下复杂环境中光照不均、粉尘水雾导致的图像低质量情况,优化锚框的回归精度,降低网络训练难度,提高检测精度。

(3) 改进 YOLOv8s 模型颈部网络的 C2f 模块。设计 C2f_ScConv 模块,应对计算、存储资源不足的情况,降低计算成本和模型存储,提高特征融合效率,保障检测的高效性。

改进后的 YOLO-EWS 模型结构见图 2,图中红色虚线框内为本文改进部分。




图2 YOLO-EWS模型结构

Fig. 2 YOLO-EWS model structure

1.2 融合EMA注意力机制的主干网络

煤矿井下工人的作业行为姿态通常有行走、坐着、站立、操作设备、弯腰、倚靠、摔倒、爬等。待检测对象在不同姿势或视角下呈现不同的视觉表征,尺度和姿势的变化增加了检测的复杂性。因此,在主干网络中引入具有跨空间学习的EMA模块^[20],EMA模块的结构见图3。




图3 EMA结构

Fig.3 EMA structure

EMA将部分通道重塑为批维度,能够捕获不同尺度的特征,以此应对多尺度问题。并将通道维度分为多个子特征组,使空间语义特征在每个特征组中分布良好,关注局部细节特征,从而处理多姿态问题。此外,EMA采用并行子结构,具有灵活和轻量级的特点。将EMA集成至YOLOv8s模型骨干网络的深层网络中,增强对矿工多尺度多样行为的多尺度特征表征与细粒度特征提取能力。

1.3 基于WIoU的边界框回归损失函数

煤矿井下工作区域依赖于人工照明,存在光照不足、不均匀问题。同时,粉尘悬浮致使能见度低,影像模糊,且井下地形复杂,设备分布广泛,各种岩石、机械设备和管道等障碍物遍布。上述因素导致煤矿井下视觉设备获取的数据图像质量低,影响井下目标检测效果。

YOLOv8s模型的边界框损失函数采用CIoU, CIoU假设训练数据样本质量高,未考虑难易样本的权衡问题,对于高质量和低质量图像采用同样的回归方式,不适用于井下图像的检测任务。而WIoU^[21]使用离群度替代传统的IoU来评估锚框的质量,通过构建梯度增益分配策略,平衡高、低质量锚框间的梯度增益,能够专注于普通质量的锚框,提升低质量图像的检测效果,增强检测器的整体性能。WIoU有3个版本,分别是WIoU v1、WIoU v2和WIoU v3。WIoU v1具有两层注意力机

制, 采用了基于注意力的预测盒损设计, 增加普通锚框的权重, 基于 WIoU v1 的损失函数为

$$L_{\text{WIoUv1}} = R_{\text{WIoU}} \times L_{\text{IoU}}, \quad (1)$$

$$R_{\text{WIoU}} = \exp \left[\frac{(a - a_{\text{gt}})^2 + (b - b_{\text{gt}})^2}{(S_{\text{wg}}^2 + S_{\text{hg}}^2)^*} \right], \quad (2)$$

$$L_{\text{IoU}} = 1 - O_{\text{IoU}}, \quad (3)$$

式(1)~式(3)中: R_{WIoU} 表示距离度量, 用来构建距离注意力; L_{IoU} 为经典的损失函数, 表示锚框重合度; $a - a_{\text{gt}}$ 为最小盒子和中心点的横坐标差; $b - b_{\text{gt}}$ 为最小盒子和中心点的纵坐标差; $S_{\text{wg}}, S_{\text{hg}}$ 是最小封闭盒的尺寸; *表示 S_{wg} 和 S_{hg} 与计算图分离, 以防止 R_{WIoU} 产生阻碍收敛的梯度; O_{IoU} 为原始 IoU。

WIoU v2 在 WIoU v1 的基础上构造了单调聚焦系数, 有效地降低了损失值中简单样例的权重, 引入 L_{IoU} 均值作为归一化因子, 加快模型的收敛速度, 基于 WIoU v2 的损失函数为

$$L_{\text{WIoUv2}} = \left(\frac{L_{\text{IoU}}^*}{\bar{L}_{\text{IoU}}} \right)^{\gamma} L_{\text{WIoUv1}}, \quad (4)$$

式中: L_{IoU}^* 为边界框长、宽与计算图分离的经典损失函数; $\bar{L}_{\text{IoU}}$ 为动量为 m 的指数运行平均值; γ 为超参数。

WIoU v3 使用额外超参数构造非单调聚焦系数, 用于动态划分锚框质量, 并将该系数应用于 WIoU v1, 增强对多个场景的泛化性, 基于 WIoU v3 的损失函数为

$$L_{\text{WIoUv3}} = r L_{\text{WIoUv1}}, \quad (5)$$

$$r = \frac{\beta}{\delta \alpha^{\beta - \delta}}, \quad (6)$$

$$\beta = \frac{L_{\text{IoU}}^*}{\bar{L}_{\text{IoU}}} \quad \beta \in [0, +\infty), \quad (7)$$

式(5)~式(7)中: r 为非单调聚焦系数; α 和 δ 是额外超参数。

额外超参数增加了模型的复杂性和不确定性, 理论上 WIoU v3 针对性不如 WIoU v2。综合考虑井下特定场景低质量图像以及模型收敛慢的情况, 选用 WIoU v2, 后文将通过实验进一步验证。WIoU v2 继承 WIoU 的优点, 并进一步抑制低质量样例的影响, 同时加快模型收敛, 提高检测的准确性和稳定性。

1.4 C2f_ScConv 轻量化模块

煤矿井下通道和工作空间通常较为狭窄, 难以容纳大型能源设备或高性能服务器, 且井下视

觉设备数量多、分布广, 这限制了单个视觉设备的资源供应。为保障井下作业安全高效进行, 对检测的实时性也有较高的要求。因此需要进行检测模型的轻量化设计。

在 YOLOv8s 模型的 C2f 模块中, 瓶颈(Bottleneck)部分使用了大量重复的标准卷积, 在处理大尺寸的输入数据时标准卷积需要耗费大量的计算资源, 卷积核的参数数量较大, 导致模型的存储需求增加, 不适用于井下资源受限的情况, 且深层颈部网络特征有重复。因此, 设计轻量级 C2f 模块, 替换 YOLOv8s 模型颈部网络最深层的 3 个 C2f 模块, 减少冗余计算与特征冗余。促进特征融合, 降低模型复杂度和计算成本, 保障模型检测精度。

ScConv^[22] 是高效卷积模块, 由空间重构单元(spatial reconstruction unit, SRU)和通道重构单元(channel reconstruction unit, CRU)构成。SRU 根据权重分离冗余特征并重构, 分离操作将信息丰富的特征图与空间内容对应信息较少的特征图分离开来, 抑制空间维度上的冗余。重构操作将信息丰富的特征与信息较少的特征相加, 生成信息更丰富的特征以节省空间。两部分采用交叉重建操作, 组合加权 2 个不同的信息特征, 并加强它们之间的信息流, 增强特征的表征能力。CRU 利用分割变换和融合策略充分利用特征的通道冗余, 将上一层输入的通道分割为两部分, 变换阶段充当“丰富特征提取器”, 采用高效卷积运算代替标准 $k \times k$ 卷积, 以提取高级代表性信息并降低计算成本和存储。融合阶段自适应合并来自两个变换阶段的输出特征。ScConv 模块结构见图 4。




图 4 ScConv 模块

Fig.4 ScConv module

传统的 Bottleneck 由 1×1 、 3×3 、 1×1 卷积层依次排列组成。第一个 1×1 卷积层用来减小输入特征图的通道数, 以产生较少数量的特征图, 降低计算复杂度。 3×3 卷积层执行常规的卷积操作, 用来捕捉输入特征图的空间信息和模式。最后一个 1×1 卷积层将特征图的通道数恢复到较大的数量, 有助于保留和整合不同尺寸和深度的特征。ScBottleneck 模块见图 5, 由两个 3×3 的 ScConv 卷积核堆叠而成, 可以有效减少特征映射中的冗余。

由于ScConv的卷积特性,输出的通道数与输入的通道数保持一致,不做变换,避免先将通道数降维,再将通道数恢复的繁杂操作。最后通过shortcut功能实现输入特征与输出特征的残差融合。




图5 ScBottleneck 模块

Fig.5 ScBottleneck module

本文设计的C2f_ScConv模块见图6。使用ScBottleneck模块替换原有C2f模块中的Bottleneck模块,提升颈部深层次网络的特征融合效率,减少冗余特征信息,使之在Detect操作前,具备充足且冗余度低的特征信息,以减少模型参数量和计算量,保证井下检测的实时性和有效性。




图6 C2f_ScConv模块

Fig.6 C2f_ScConv module

2 实验概况及评价指标

2.1 数据集

本实验使用井下综采工作面图像数据集“DsLMF+”^[23],煤矿工人行为部分共有24 709张图片,来自67个不同场景。数据集按8:2的比例分为训练集和验证集,分别有19 767张和4 942张图片,包括行走(walking)、坐(sitting)、站立(standing)、操作(operation)、弯腰(stoop)、倚靠(lean against)、跌倒(tumble)、翻爬(climb over) 8个行为类别。

2.2 实验环境及评价指标

实验使用Ubuntu 18.04.3操作系统,内存24 GB,Python 3.8.13编译环境,CPU为Intel(R) Xeon(R) Gold 5120 CPU @ 2.20GHz, GPU为NVIDIA GeForce RTX 2080 Ti和丽台Tesla P100 12GB,基于Pytorch 1.13.1学习框架训练网络。YOLOv8s对应ultralytics版本8.0.161。训练轮数epoch设为300。

实验选取平均精确度均值(mean average precision, mAP)、参数量、计算量、推理速度,用以评估模型的性能。其中,mAP能够度量多个不同目标类别的平均精确度,用以评估目标检测

模型在多类别情况下的性能,可表示为

$$m_{AP} = \frac{\sum_{i=1}^k \int_0^1 P(R) dR}{k}, \quad (8)$$

$$P = \frac{T_p}{T_p + F_p}, \quad (9)$$

$$R = \frac{T_p}{T_p + F_N}, \quad (10)$$

式中: k 为类别数; P 为正确预测的正样本数量占实际预测的正样本数量的比例; R 为正确预测的正样本数量占正样本数量的比例; T_p 为检测器正确检测的次数; F_p 为检测器定位错误的次数; F_N 为检测器错误和漏检的次数。

mAP_{50} 表示目标检测模型在交并比阈值为50%时的平均精度, mAP_{50-95} 表示在50%~95%交并比阈值范围内的mAP值的平均数。

此外,通过参数量和计算量表示运算复杂度,两者数值越大,训练和推理时间越长。以单张图像的平均推理时间衡量推理效率。

3 实验结果及分析

3.1 定量实验分析

YOLO-EWS模型的井下矿工行为平均检测精度训练结果见图7。 mAP_{50} 在训练至第246轮时达到最大值93%, mAP_{50-95} 在第277轮达到最大值76.7%,模型训练曲线平滑,能够收敛,表明模型具有良好的学习能力。




图7 YOLO-EWS模型300轮训练结果

Fig.7 YOLO-EWS model 300 epoch training results

为了验证YOLO-EWS模型的适用性,在“DsLMF+”数据集上,对单、双阶段目标检测模型、基于Transformer的目标检测大模型,以及煤矿领域检测模型和基准模型进行对比实验。实验

硬件环境和基本参数设置保持一致。不同模型对比结果见表 1。相较于其他模型, YOLO-EWS 模型的精度优于其他模型, mAP_{50} 提升的百分点数分别为 7.3、0.2、1.6、2.8、1.5、1.7、1.6、1.4, mAP_{50-95} 提升的百分点数分别为 8.8、5.3、4.9、2.7、1.6、1.5、1.3、1.2。同时, 相较于 YOLOv8s

基准模型, YOLO-EWS 模型的参数量减少了 17%, 模型计算量减少了 16×10^9 次。对比实验结果表明, YOLO-EWS 模型具有较小的模型参数和较高的检测精度, 推理时间仅为 4.0 ms, 能够有效适配井下复杂环境和计算、存储资源不足场景下的矿工行为实时检测任务。

表 1 不同模型对比结果

Tab.1 comparison results of different models

模型	$mAP_{50}/\%$	$mAP_{50-95}/\%$	参数量/ 10^6	计算量/ 10^9	推理时间/ms
Faster-RCNN(双)	85.7	67.9	137.1	370.2	56.2
ViT Adapter-L(大模型)	92.8	71.4	327.0	1 080.0	161.0
DETA(大模型)	91.4	71.8	52.0	458.0	44.7
YOLOv5s(单)	90.2	73.3	7.2	16.5	2.8
YOLOv5m(单)	91.5	75.1	21.2	49.0	5.5
YOLOv7(单)	91.3	75.2	36.9	104.7	8.1
CM-YOLO ^[24] (煤矿)	92.4	75.4	15.6	43.7	
YOLOv8s(基准)	91.6	75.5	11.2	28.6	3.4
YOLO-EWS(本文模型)	93.0	76.7	9.3	27.0	4.0

3.2 消融实验

为探究本文改进模块对基准模型 YOLOv8s 性能的影响以及各模块之间的作用关系, 验证各模块的有效性, 以 mAP_{50} 、 mAP_{50-95} 和参数量作为评价指标^[25-26], 对模型进行消融实验。

WIoU 消融实验结果见表 2。WIoU v2 更快达到模型最优训练轮数, 检测精度最高。各模块消融实验结果见表 3。

表 2 Wiou 消融实验结果

Tab.2 results of ablation experiment for Wiou

损失函数	最佳精度训练轮数	$mAP_{50-95}/\%$
WIoU v1	284	75.7
WIoU v2	271	76.2
WIoU v3	296	75.9

表 3 各模块消融实验结果

Tab.3 results of ablation experiment

实验 编号	模块			评价指标		
	EMA	WIoU	C2f_ScConv	mAP_{50}	mAP_{50-95}	参数量/ 10^6
1	×	×	×	91.6	75.5	11.2
2	✓	×	×	92.0	76.3	11.3
3	×	✓	×	92.1	76.2	11.2
4	×	×	✓	91.9	75.4	9.2
5	✓	✓	×	92.2	76.6	11.3
6	✓	×	✓	92.3	75.4	9.3
7	✓	✓	✓	93.0	76.7	9.3


注: ✓表示采用该模块, ×表示未采用该模块。

由表 3 可知, EMA 的引入能够有效提升模型精度, 几乎不增加模型参数量。WIoU 能够提升模型

精度, 对参数量影响极小。单独引入 C2f_ScConv 可以减少模型参数量, 但是准确度提升效果不明显, mAP_{50-95} 反而有所下降。三者组合能够使模型达到最佳性能, 平均检测精度最优化, 同时实现了模型轻量化。

3.3 可视化分析

相较于 YOLOv8s 模型, 通过热力图和煤矿综采场景对本文模型检测效果进行可视化定性分析, 见图 8 和图 9。



(a) 原始图像 (b)YOLOv8s (c)YOLO-EWS

图 8 热力图

Fig.8 heat map

由图 8 可知, YOLO-EWS 模型的注意力对图像中待检测目标的形状关注更全面, 协调全局和局部特征, 表明 YOLO-EWS 模型对于井下矿工行为姿势的特征提取更具优势。

图 9 中, YOLO-EWS 模型在光照不均匀、噪声干扰失真的井下矿工工作行为姿态的图像检测中, 精度较高; 在处理受粉尘、水雾影响的模糊图像, 以及待检测目标被遮挡的图像时, 同样具备较高的检测精度。表明 YOLO-EWS 模型在井下矿工行为目标检测中, 具有高准确性和良好的鲁棒性。




图9 实际检测结果可视化

Fig.9 visualization of actual test results

4 结论

本文提出一种改进的YOLOv8s模型,用于煤矿井下复杂场景下矿工行为检测,实现井下矿工行为检测效果的优化,得出如下结论。

(1) 通过引入EMA改进主干网络,增强模型多尺度和细粒度特征提取能力;采用WIoU v2优化损失函数,提高模型对于井下低质量图像的检测准确性和稳定性;设计C2f_ScConv轻量化模块,提高颈部深层次网络的特征融合效率,减少模型的计算量和参数量。

(2) 在井下矿工行为检测数据集上,YOLO-EWS模型的平均检测精度达93%,平均检测精度均值达76.7%,相比YOLOv8s基准模型分别提高了1.4和1.2个百分点,模型参数量仅为9.3 M。

(3) 定量和可视化定性实验结果表明,相较于其他6种主流检测模型和基准模型,YOLO-EWS模型对矿工行为的平均检测精度最高,推理用时较少,更加适用于煤矿井下矿工行为检测。

(4) 本文模型的高检测精度依赖于人工标注的数据集,未来将考虑结合无监督学习方法,使本文模型更加高效,节省应用成本。

参考文献(References):

[1] 王国法. 煤矿智能化最新技术进展与问题探讨[J]. 煤炭科学技术, 2022,50(1):1-27.
WANG Guofa. New technological progress of coal mine intelligence and its problems[J]. Coal Science and Technology, 2022, 50(1):1-27.

[2] 葛庆楠,程刚,赵东洋. 基于KRB-YOLOv5s的煤矸识别方法[J]. 辽宁工程技术大学学报(自然科学版), 2024,43(4):385-392.
GE Qingnan, CHENG Gang, ZHAO Dongyang. Recognition method for coal and gangue based on KRB-YOLOv5s[J]. Journal of Liaoning Technical University(Natural Science), 2024,43(4):385-392.

[3] 程德强,钱建生,郭星歌,等. 煤矿安全生产视频AI识别关键技术研究综述[J]. 煤炭科学技术, 2023,51(2):349-365.
CHENG Deqiang, QIAN Jiansheng, GUO Xingge, et al. Review on key technologies of AI recognition for videos in coal mine [J]. Coal Science and Technology, 2023,51(2):349-365.

[4] 李瑞群. 煤矿员工行为安全管控研究[J]. 中国安全科学学报, 2022,32(增刊2):26-31.
LI Ruiqun. Research on behavioral safety control of employees in coal mines[J]. China Safety Science Journal, 2022,32(Suppl.2): 26-31.

[5] YANG L, BIRHANE G E, ZHU J Q, et al. Mining employees safety and the application of information technology in coal mining: review [J]. Frontiers in Public Health, 2021,9:709987.

[6] 成连华,张璇,郭慧敏,等. 智能化背景下矿工风险感知水平对不安全行为产生的影响[J]. 西安科技大学学报, 2024,44(6):1041-1049.
CHENG Lianhua, ZHANG Xuan, GUO Huimin, et al. Impact of miners' risk perception levels on unsafe behaviors in the context of intelligent mining[J]. Journal of Xi'an University of Science and Technology, 2024,44(6):1041-1049.

[7] WU X F, LI H X, WANG B L, et al. Review on improvements to the safety level of coal mines by applying intelligent coal mining[J]. Sustainability, 2022,14(24):16400.

[8] DU Y X, ZHANG H, LIANG L, et al. Applications of machine vision in coal mine fully mechanized tunneling faces: a review[J]. IEEE Access, 2023,11:102871-102898.

[9] LI C L, LIU J H, ZHU J J, et al. Mine image enhancement using adaptive bilateral gamma adjustment and double plateaus histogram equalization[J]. Multimedia Tools and Applications, 2022, 81(9): 12643-12660.

- [10] 孙林, 陈圣, 姚旭龙, 等. 矿井智能监控目标识别的图像增强方法与应用[J]. 煤炭学报, 2024, 49(增刊1): 495-504.
SUN Lin, CHEN Sheng, YAO Xulong, et al. Image enhancement methods and applications for target recognition in intelligent mine monitoring[J]. Journal of China Coal Society, 2024, 49(Suppl. 1): 495-504.
- [11] 纪执安, 周云奕, 张玉媛, 等. 基于改进YOLOv5的工业现场不安全行为检测[J]. 中国安全科学学报, 2024, 34(7): 38-43.
JI Zh'an, ZHOU Yunyi, ZHANG Yuyuan, et al. Industrial site unsafe behavior detection based on improved YOLOv5[J]. China Safety Science Journal, 2024, 34(7): 38-43.
- [12] 孙继平. 矿井人员位置监测技术[J]. 工矿自动化, 2023, 49(6): 41-47.
SUN Jiping. Mine personnel position monitoring technology[J]. Journal of Mine Automation, 2023, 49(6): 41-47.
- [13] ZHANG K X, KANG L, CHEN X X, et al. A review of intelligent unmanned mining current situation and development trend[J]. Energies, 2022, 15(2): 513.
- [14] XU Z, LI J Z, MENG Y F, et al. CAP-YOLO: channel attention based pruning YOLO for coal mine real-time intelligent monitoring[J]. Sensors, 2022, 22(12): 4331.
- [15] 曹家乐, 李亚利, 孙汉卿, 等. 基于深度学习的视觉目标检测技术综述[J]. 中国图象图形学报, 2022, 27(6): 1697-1722.
CAO Jiale, LI Yali, SUN Hanqing, et al. A survey on deep learning based visual object detection[J]. Journal of Image and Graphics, 2022, 27(6): 1697-1722.
- [16] 温廷新, 王贵通, 孔祥博, 等. 基于迁移学习与残差网络的矿工不安全行为识别[J]. 中国安全科学学报, 2020, 30(3): 41-46.
WEN Tingxin, WANG Guitong, KONG Xiangbo, et al. Identification of miners' unsafe behaviors based on transfer learning and residual network[J]. China Safety Science Journal, 2020, 30(3): 41-46.
- [17] 刘浩, 刘海滨, 孙宇, 等. 煤矿井下员工不安全行为智能识别系统[J]. 煤炭学报, 2021, 46(增刊2): 1159-1169.
LIU Hao, LIU Haibin, SUN Yu, et al. Intelligent recognition system of unsafe behavior of underground coal miners[J]. Journal of China Coal Society, 2021, 46(Suppl.2): 1159-1169.
- [18] 王宇, 于春华, 陈晓青, 等. 基于多模态特征融合的井下人员不安全行为识别[J]. 工矿自动化, 2023, 49(11): 138-144.
WANG Yu, YU Chunhua, CHEN Xiaoqing, et al. Recognition of unsafe behaviors of underground personnel based on multi modal feature fusion[J]. Journal of Mine Automation, 2023, 49(11): 138-144.
- [19] YAO W, WANG A M, NIE Y F, et al. Study on the recognition of coal miners' unsafe behavior and status in the hoist cage based on machine vision[J]. Sensors, 2023, 23(21): 8794.
- [20] LIU M M, LI S, LIU B, et al. Single image super-resolution via global aware external attention and multi-scale residual channel attention network[J]. International Journal of Machine Learning and Cybernetics, 2024, 15(6): 2309-2321.
- [21] LIU Z G, SUN B S, BI K Y. Optimization of YOLOv7 based on PConv, SE attention and wise-IoU[J]. International Journal of Computational Intelligence and Applications, 2024, 23(1): 2350033.
- [22] LIU L J, ZHANG Y, KARIMI H R. Resilient machine learning for steel surface defect detection based on lightweight convolution[J]. The International Journal of Advanced Manufacturing Technology, 2024, 134(9): 4639-4650.
- [23] YANG W J, ZHANG X H, MA B, et al. An open dataset for intelligent recognition and classification of abnormal condition in longwall mining[J]. Scientific Data, 2023, 10(1): 416.
- [24] FAN Y B, MAO S J, LI M, et al. CM-YOLOv8: lightweight YOLO for coal mine fully mechanized mining face[J]. Sensors, 2024, 24(6): 1866.
- [25] 苏文博, 房群忠, 徐保树, 等. 基于SE-Hardnet网络的无人机图像目标匹配算法[J]. 沈阳工业大学学报, 2024, 46(5): 693-701.
SU Wenbo, FANG Qunzhong, XU Baoshu, et al. UAV image target matching algorithm based on SE-Hardnet network UAV image target matching algorithm based on SE-Hardnet network[J]. Journal of Shenyang University of Technology, 2024, 46(5): 693-701.
- [26] 黄丹丹, 汪梅, 张永高, 等. 基于改进DCGAN的对地观测图像生成方法[J]. 西安科技大学学报, 2024, 44(5): 985-995.
HUANG Dandan, WANG Mei, ZHANG Yonggao, et al. Earth observation image generation method based on improved DCGAN[J]. Journal of Xi'an University of Science and Technology, 2024, 44(5): 985-995.