E-mail: csa@iscas.ac.cn http://www.c-s-a.org.cn Tel: +86-10-62661041

基于改进 YOLOv8s 的矿井下安全帽佩戴检测^①

凌 港,赵 杰,莫定界,张冬青

(黑龙江科技大学 电气与控制工程学院, 哈尔滨 150022) 通信作者: 赵 杰, E-mail: zhao_xxsc@163.com

摘 要: 矿井下光照缺失、环境复杂, 安全帽目标尺寸较小, 导致一般目标检测模型对安全帽的检测效果不佳. 针对 上述问题, 提出了一种基于改进 YOLOv8s 的矿井下安全帽佩戴检测模型. 首先, 将 effectiveSE 模块和 YOLOv8s Neck 层中的 C2f 模块相结合, 设计得到新的 C2f-eSE 模块, 提高了网络结构的特征提取能力, 并用 Wise-EIoU 损失 函数替代 CIoU 损失函数, 提高了模型的鲁棒性; 其次, 在检测头中引入空间和通道重建卷积模块 SCConv, 并根据 参数共享思想设计了新的轻量化 SPS 检测头, 降低了模型的参数量和计算复杂度; 最后在模型中增加一层 P2 检测 层, 使模型的特征提取网络融入更多的浅层信息, 提高了对小尺寸目标的检测能力. 实验结果表明, 改进后模型的 *mAP50* 指标提升了 3.2%, 参数量降低了 1.6%, GFLOPs 降低了 5.6%.

关键词: YOLOv8s; 目标检测; 矿井; effectiveSE; 安全帽检测

引用格式: 凌港,赵杰,莫定界,张冬青.基于改进 YOLOv8s 的矿井下安全帽佩戴检测.计算机系统应用,2025,34(2):19-27. http://www.c-s-a.org.cn/1003-3254/9743.html

Wearing Safety Helmet Detection Under Mine Based on Improved YOLOv8s

LING Gang, ZHAO Jie, MO Ding-Jie, ZHANG Dong-Qing

(School of Electrical and Control Engineering, Heilongjiang University of Science and Technology, Harbin 150022, China)

Abstract: The lack of lighting and the complex environment in the mine, coupled with the small target size of safety helmets, lead to poor detection performance of safety helmets by general object detection models. To solve these issues, an improved mine safety helmet wearing detection model based on YOLOv8s is proposed. Firstly, the effectiveSE module is combined with the C2f module in the neck network of YOLOv8s to design a new C2f-eSE module, improving the feature extraction ability of the network structure. The CIoU loss function is replaced by the Wise-EIoU loss function to improve the model's robustness. In addition, the spatial and channel reconstruction convolution (SCConv) module is introduced into the detection head. A new lightweight SPS detection head is designed based on the parameter sharing concept, reducing the number of parameters and computational complexity of the model. Finally, adding a P2 detection layer to the model enables the feature extraction network to incorporate more shallow information and improves the detection ability for small-sized targets. Experimental results show that the *mAP50* index of the improved model increases by 3.2%, the number of parameters decreases by 1.6%, and GFLOPs decreases by 5.6%.

Key words: YOLOv8s; object detection; mine; effectiveSE; safety helmet detection

佩戴安全帽能保护矿工头部,增加矿工在矿井昏 暗环境下的可见性,是保障矿工人身安全的有效措施. 然而,部分矿工安全意识淡薄,在矿井下工作时佩戴安 全帽不规范或不佩戴安全帽,导致风险事故发生的概

① 基金项目: 黑龙江省属高校基本科研业务费 (2022-KYYWF-0551)

收稿时间: 2024-06-16; 修改时间: 2024-07-10; 采用时间: 2024-08-01; csa 在线出版时间: 2024-12-19 CNKI 网络首发时间: 2024-12-20



率大幅提高, 危及矿工自身安全, 影响矿业生产活动的 正常运作. 因此, 研究可靠准确的矿工安全帽佩戴检测 技术具有重要意义^[1].

传统的矿工安全帽佩戴检测方法是人工检查,存 在着客观性缺乏、人力资源浪费、在黑暗环境中难以 辨清等诸多问题.近年来,随着深度学习技术的飞速发 展,高检测效率的机器视觉逐步取代传统的人眼观测, 广泛应用于安全帽佩戴检测任务中.张旭等人[2]引入空 间金字塔池化模块对 YOLOv3 进行改进,提高了对安 全帽的识别精度; Shen 等人^[3]通过相互蒸馏来训练具 有两个对等 DenseNet 的网络模型,并将其与卷积网络 相结合,提出了一种具有多尺度检测效果的安全帽检 测方法,但上述两种模型仅针对户外情况下安全帽佩 戴的检测,难以应用到复杂的矿井环境下;白培瑞等人4 将改进的 Deep SORT 多目标跟踪算法与 YOLOv5 相 结合,提出一种 DS-YOLOv5 安全帽检测模型,提高了 遮挡情况下对安全帽的识别准确率,但该模型较为复 杂,实时性差;孙迟等人^[5]将 SimAM 无参注意力机制 添加进 YOLOv7-tiny 的 Backbone 层和 Neck 层中,并 在 Neck 层中融入新的特征层, 减小了算法漏检和误检 的概率; 董彦强等人^[6]采用轻量级网络 MobileNeXt 替换 YOLOv4 模型主干,并在特征网络中融入 ULSAM-4 注意力模块和深度可分离卷积,在减轻模型重量的前 提下提高模型的实时检测速度,但并未针对小目标场 景进行优化.

为解决上述算法中存在的问题,本文以YOLOv8s 模型为基础进行改进,在Neck 层中融入 effectiveSE 注 意力机制,提高了网络结构的特征提取能力;用 Wise-EloU 损失函数替代 YOLOv8s 原有的 CloU 损失函数, 减小了低质量图片对检测算法的负面影响,提高了算 法的鲁棒性;最后,将检测头中的普通卷积替换为 SCConv 卷积,根据参数共享思想重构新的 SPS 检测头 模块,并增加一层小目标检测层以解决安全帽目标尺 寸过小的问题.

1 YOLOv8s 模型介绍

YOLOv8^[7]是 YOLO 系列目标检测算法的第8个版本,它通过结合 YOLOv4 和 YOLOv5 的优点,获得了更高的检测性能. YOLOv8 有 5 个不同大小的预训练模型: n、s、m、l和 x. 在上述 5 种预训练模型中, YOLOv8s 兼具较快的检测速度和较高的精度,适合应

用在矿井环境下.

YOLOv8s 从结构上分为 Backbone 层、Neck 层、 Head 层 3 个部分.

Backbone 层是 YOLOv8s 网络结构中的核心部分, 采用 CSPDarknet53, 结合了 CSPNet 和 Darknet53 的优 点, 用于提取输入图像中的高级特征, 减少图像中的冗 余信息.

YOLOv8s 的 Neck 层用于将主干网络输出的特征 进行二次处理, 采用了 PANet 结构, 增强了模型的多尺 度信息融合能力. 在 Backbone 层和 Neck 层均使用了 由 YOLOv5 中的 C3 模块改进得到的 C2f 模块, C2f 模块能在减少模型参数量的同时提高所获特征图的信 息丰富度, 其结构组成如图 1 所示.



YOLOv8s 的 Head 层用于对目标进行最终检测和 分类,为提高检测的准确性和稳定性,Head 层引入了 改进的多尺度预测技术,分出 3 个不同尺度的检测层, 可以更好地检测不同大小的对象.

YOLOv8s 提供了更加丰富的超参数和模型结构 选项,使得用户可以更加方便地进行模型调整和优化. 和以前的 YOLO 算法相比较,YOLOv8s 具有更快的推 理速度、更高的精度、更广泛的硬件支持以及原生支 持自定义数据集等优势.这些优势使得 YOLOv8s 成为 目前业界最流行和成功的目标检测算法之一.

2 YOLOv8s 模型改进

2.1 改进 YOLOv8s 模型整体结构

改进的 YOLOv8s 模型整体结构如图 2 所示. 为提

高模型网络结构的特征提取能力,首先在 Neck 层中的 C2f 模块中融入 eSE 注意力机制,构成新的 C2f-eSE 模块;同时,在特征网络中添加 P2 小目标检测层, P2 检测层和原来的 P3、P4、P5 检测层分别接收来自

主干的尺寸为 160×160、80×80、40×40、20×20 的特 征信息, 并通过 PAN 特征融合金字塔对 4 个不同尺度 的信息进行融合, 通过 Concat 操作形成融合特征图, 提高了模型对小尺寸目标的检测能力.





为降低模型的参数量和计算复杂度,用 SCConv 替换 Head 部分中的标准 3×3 卷积,并根据参数共享的 思想重构新的 SPS 检测头,同时在训练过程中将 CloU 损失^[8]替换为 Wise-EloU 损失,进一步提高模型的检测 精度.

2.2 C2f-eSE 模块

人类的视觉系统在观看图像时会忽略图像中的无 关内容,把注意力放在重点信息上.注意力机制就是对 这种信息选择方式的模仿,通过引入注意力机制,模型 能够自动地从众多信息中筛选出最为关键的信息,进 而提高自身的特征提取能力和性能.

Effective squeeze-excitation (eSE)^[9]是 Lee 等人提 出的一种用于图像分类的卷积神经网络结构,在 squeezeand-excitation network (SENet) 的基础上, eSE 通过学 习一种"通道注意力",来自适应地调整每个通道的权 重, 从而解决了 SENet 信道信息丢失问题, 提高了检测 性能. eSE 的公式定义如下:

$$A_{eSE}(X_{div}) = \sigma \left(W_C \left(\mathcal{F}_{gap} \left(X_{div} \right) \right) \right)$$
(1)

$$X_{\text{refine}} = A_{\text{eSE}}(X_{\text{div}}) \otimes X_{\text{div}}$$
(2)

其中, $X_{div} \in \mathbb{R}^{H \times W \times C}$ 为 OSA 模块中 1×1 卷积计算得到 的多元特征图. $A_{eSE} \in \mathbb{R}^{C \times 1 \times 1}$ 作为通道关注特征标识 符, 应用于多元特征图 X_{div} , 使多元特征更具信息量. \otimes 表示按元素相乘. 最后, 在使用残差连接时, 输入特征 图按元素相加到提纯特征图 X_{refine} 中.

将 eSE 模块与 YOLOv8s Neck 层中的 C2f 模块 相结合,能加强模型对检测目标关键特征的信息提 取能力,减少不必要的计算量,保留更多的有效特征, 从而提高检测精度. C2f-eSE 模块结构如图 3 所示, 输入特征在完成 C2f 模块的一系列卷积和特征融合

操作后,再经过最大池化和平均池化的整合处理,经 由两次1×1卷积操作,在保持特征图空间维度不变的 情况下和原特征进行特征相乘,从而得到最终的输 出特征.



图 3 C2f-eSE 结构图

2.3 Wise-EIoU 损失函数

YOLO 中的损失函数用于计算模型的预测误差. 在一轮又一轮的迭代训练中,模型以最小化损失函数 为目标不断地优化参数,从而提高模型的性能和泛化 能力.

YOLOv8s 使用 CIoU 作为回归损失函数. CIoU 在 DIoU 的基础上添加了一项用于度量检测框的尺度, 能综合地考虑位置、形状和方向等多个因素,使得模 型更全面地学习目标框的特征,提高了模型在复杂场 景中的性能,但 CIoU 也存在着计算复杂、训练时间 长、参数敏感度高等缺点,

为解决以上问题,本文采用 Wise-EIoU 替代 CIoU. Wise-EIoU 由 Wise-IoU 和 EIoU 结合而成,其中, EIoU 是由 Zhang 等人^[10]于 2022 年提出的一种改进 IoU, 它在 CIoU 的惩罚项基础上将预测框和真实框的 纵横比的影响因子拆开,分别计算预测框和真实框的 长和宽,从而提高了预测精度. EIoU 分为 *IoU* 损失 *L*_{IoU}, 距离损失 *L*_{dis}, 边长损失 *L*_{asp}, 其公式如下所示:

$$L_{\text{EloU}} = L_{\text{IoU}} + L_{\text{dis}} + L_{\text{asp}}$$

= 1 - IoU + $\frac{\rho^2(b, b^{\text{gt}})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{\text{gt}})}{(w^c)^2} + \frac{\rho^2(h, h^{\text{gt}})}{(h^c)^2}$ (3)

其中, *IoU* 为交并比, 1-*IoU* 表示预测框和真实框之间 的重叠损失, b 和 b^{gt} 代表预测框和真实框, w、h 和 w^{gt}、h^{gt} 分别代表预测框的高宽和真实框的高宽. h^c 和 w^c 为最小包围框的高和宽.

Wise-IoU 具有双层注意力机制,其中一层注意力 机制用于降低模型对低质量示例的聚焦度,另一层注 意力机制增大了普通质量示例对损失函数的影响,进 而提高了模型的检测性能.Wise-IoU 有 v1、v2、v3

22 专论•综述 Special Issue

这 3 个版本,将 EIoU 引入 Wise-IoU 中后, Wise-EIoU v1 版本的公式如下所示:

$$L_{\rm WEIoUv1} = R_{\rm WIoU} L_{\rm EIoU} \tag{4}$$

$$R_{\rm WIoU} = \exp\left(\frac{(x - x^{\rm gt})^2 + (y - y^{\rm gt})^2}{\left(W_g^2 + H_g^2\right)^*}\right)$$
(5)

其中, *L*_{EloU} 代表 EloU 损失, *W_g* 和 *H_g* 代表最小包围框的宽度和高度, *x、y* 和 *xst、yst* 分别代表预测框中心点的横纵坐标和真实框中心点的横纵坐标.

Wise-EIoU v3 版本在 v1 版本的基础上增添了非 单调聚焦系数 r,使得梯度增益随损失值的增加呈非单 调变化,其公式如下所示:

$$L_{\text{WEIoUv3}} = rL_{\text{WEIoUv1}}, \ r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{6}$$

$$\beta = \frac{L_{\rm IoU}}{\bar{L}_{\rm IoU}} \in [0, +\infty) \tag{7}$$

其中, α 和 δ 是可调节的超参数, L^{*}_{loU}中的上标*表示将 从 L_{loU} 计算图中分离.

2.4 P2 检测层

YOLOv8s 拥有 P3、P4、P5 这 3 个不同检测尺度 的检测头, 它们分别用于检测小尺度、中尺度、大尺 度的目标, 其中最小尺度的 P3 检测头所对应的特征图 大小为 80×80^[11], 相比于原有的输入特征图, 下采样倍 数为 8 倍, 多数情况下能在减少计算量的同时对目标 进行准确检测. 然而矿工佩戴的安全帽在视频监控图 像中所占的比例非常小, 即使是 80×80 的特征图也难 以提取到全面的安全帽特征, 进而导致 P3 检测头对矿 井下安全帽图像的检测精度下降.

因此,本文在 YOLOv8s 中增加一个 P2 小目标检测层,该检测层对应的特征图大小为 160×160,下采样

倍数为4倍.YOLOv8s 在添加P2检测层后的特征网络结构如图4所示.



图 4 改进的 YOLOv8s 特征网络结构

C2、C3、C4、C5所对应的特征图尺寸为160×160、 80×80、40×40、20×20.改进后网络里的P3、P4、P5 检测层均融入了浅层的特征信息,这有助于模型更敏锐 地检测和定位小目标,减少对安全帽的漏检,避免因视 频图像中安全帽像素过小而产生的特征丢失.

2.5 SPS 检测头

YOLOv8s 采用了目前主流的解耦头结构,解耦头 由分类分支和回归分支组成,前者用于确定目标类别 信息并进行分类,后者用于定位目标位置并计算边界 框的回归坐标.其中,分类损失函数采用改进交叉熵 损失^[12],用于衡量模型对每个目标物体类别预测准确 性;回归损失函数使用 DFL Loss + CloU Loss,用于衡 量模型对目标物体实际边界框与预测边界框之间的 差距.

解耦头可以使两个分支专注于自己的任务, 避免 分支间的相互干扰, 提高检测的准确性, 但是两个分支 包含双倍数量的卷积, 导致 YOLOv8s 的参数量较高, 网络结构变得复杂. 为解决上述问题, 首先用 SCConv^[13] 和标准 1×1 卷积来替换解耦头中的两个标准 3×3 卷 积, 再根据参数共享 (parameter sharing) 的思想让两个 分支共用替换后的卷积, 构成新的 SPS 检测头, 从而减 少模型的参数量和计算复杂度.

SPS 检测头结构如图 5, 其中 SCConv 由空间重构 单元 (SRU) 和信道重构单元 (CRU) 两个单元组成. SRU 采用分离重构的方法来抑制空间冗余, CRU 采用 分离变换融合的策略来减少信道冗余. 特征输入 SCConv 模块后, 先经过 SRU 进行空间细化, 再经过 CRU 进行 通道提炼, 输出得到冗余度更低的新特征.



Special Issue 专论•综述 23

3 实验与结果分析

3.1 实验环境及实验数据集

模型训练使用的软硬件环境配置如表1所示.

	11 1	大孤行党癿且
配置名称		版本/参数
操作系统		Ubuntu 20.04
CPU		Intel(R) Xeon(R) Gold 6330 CPU
GPU		RTX 3090 (24 GB)
内存大小		80 GB
深度学习框架		PyTorch 1.11.0
Python		Python 3.8

实验过程中的超参数设置情况为:输入图片尺寸为 640×640×3,批量大小为 16,优化器使用 SGD,迭代 轮次为 200 次,禁用 mosaic 增强轮次数为 10,并行加载进程数设置为 8.

本文所使用的数据集为 CUMT-HelmeT 和 SHWD 数据集. CUMT-HelmeT 数据集来源于中国矿业大学智 能检测与模式识别研究中心公开发布的井下安全帽检 测数据集. 该数据集收集了地面、井下磅房、井下变 电所、井下二次设备室等环境中工作人员安全帽佩戴 数据.数据集共有6421图片,去掉其中与安全帽无关 的图片后,将剩余的5762张图片作为实验数据集,该 数据集共包含 helmet 和 no-helmet 两种数据类型, 按 7:2:1 的比例将数据集划分为训练集、验证集和测试 集. SHWD 开源数据集收集了各类建筑施工工地、电 力工作场所、日常生活中的安全帽佩戴数据,数据集 中的图片不包含矿井下场景,数据类型为 hat 和 person 两种. SHWD 数据集共有 7581 张图像, 其中 9044 个 安全头盔佩戴对象和 111 514 个未佩戴安全帽对象, 按 7:2:1 的比例将数据集划分为训练集、验证集和测 试集.

3.2 评价指标

本文使用的评价指标有反应模型精度的精确率 P (Precision)、召回率 R (Recall)、平均精度均值 mAP (mean average precision),反应模型运算速度的每秒传 输帧数 (FPS),以及反应模型大小的参数量 (Params) 和 浮点运算量 (GFLOPs) 指标.精确率 P 和召回率 R 的 公式^[14]如下所示:

$$P = \frac{TP}{TP + FP} \tag{8}$$

$$R = \frac{TP}{TP + FN} \tag{9}$$

其中, *TP、FP、FN*分别代表真正例、假正例、假负例. 精确率 *P*主要用于评估模型对正例的预测准确性, 召回率 *R*用于评估模型对正例的覆盖能力.

平均精度均值 mAP 的计算公式如下所示:

$$mAP = \frac{1}{n} \sum_{i=1}^{n} \int_{0}^{1} P(R) d(R)$$
(10)

*mAP*是对每一个数据类别的 AP (平均精确度)进行求平均处理得到的指标,分为 *mAP50* 和 *mAP50-95*. *mAP50*是在预测框与标注框有 50% 的重合就认为预测成功的前提下得到的均值平均精度,*mAP50-95* 是在预测框与标注框有 50%-95% 的重合 (每次增加 5%)就认为预测成功的前提下得到的均值平均精度.

3.3 注意力对比实验

注意力机制有多种,为对比 eSE 与其他注意力机 制对模型各个性能指标的影响,在相同的实验环境下, 将加入 eSE 注意力机制的模型与加入多尺度注意力机 制 MPCA、SEAttention^[15]、CoordAttention 和 ELA 的其余 4 个模型对 CUMT-HelmeT 数据集进行目标检 测对比实验,结果如表 2 所示.

	1	衣 2	注息力对比头验			
注意力名称	Precision (%)	Recall (%)	mAP50 (%)	Params	GFLOPs	FPS (f/s)
无注意力	89.7	81.4	88.2	11 126 358	28.6	128.4
MPCA	89.6	82.7	88.8	12438614	28.7	124.7
SEAttention	89.0	82.5	88.2	11210326	28.6	131.4
CoordAttention	89.5	82.2	88.4	11 189 374	28.7	117.8
ELA	89.5	83.0	88.8	11803094	28.7	124.3
eSE	90.6	83.3	89.1	11 799 766	28.6	125.0

实验结果表明,除了加入 SEAttention 的模型外, 其余 4 个添加注意力机制的模型的检测精度均有一 定提升,但 eSE 注意力机制对检测精度的提升最大. 相较于原始模型,加入了 eSE 注意力的模型虽然让参 数量增加了 6%, 但 Precision 指标由 89.7% 提升到 90.6%, 提升了 0.9%; Recall 指标从 81.4% 提升到 83.3%, 提升了 1.9%; *mAP*50 指标由原来的 88.2% 提升到 89.1%, 提升了 0.9%.

24 专论•综述 Special Issue

3.4 消融实验

为验证各个改进点对模型的性能提升效果,在 YOLOv8s 模型的基础上,以替换 C2f-eSE 模块、替换 Wise-EIoU 损失、增加 P2 检测层、替换 SPS 检测头 4 个改进点作为变量在 CUMT-HelmeT 数据集上进行 消融实验,得到的结果如表 3 所示.

表 3 消融头验							
C2f-eSE	Wise-EIoU	P2检测层	SPS检测头	mAP50 (%)	Params	GFLOPs	FPS (f/s)
_	—	_	—	88.2	11 126 358	28.6	128.4
\checkmark	—	—	—	89.1	11799766	28.6	125.0
—	\checkmark	—	—	89.2	11 126 358	28.6	130.3
—	—	\checkmark	—	90.1	10626968	36.6	93.3
—	—	—	\checkmark	88.7	10041302	22.3	143.2
\checkmark	\checkmark	—	_	89.8	11733974	28.6	129.4
\checkmark	\checkmark	\checkmark	_	91.4	11321048	36.6	109.8
\checkmark	—	\checkmark	\checkmark	91.0	10948696	27.0	120.9
\checkmark	\checkmark	\checkmark	\checkmark	91.4	10948696	27.0	123.5

从实验结果可知,将模型中的C2f模块替换为 C2f-eSE模块并将损失函数替换为Wise-EloU后,模型的mAP50指标提高到89.8%,说明eSE和Wise-EloU组合起来能更有效地提升模型的检测精度;在上述两个改动的基础上加入P2检测层后,模型的 mAP50指标进一步提高到91.4%,然而参数量大幅增加的缺点依旧存在;将4个改进全部加在模型上后,模型的mAP50指标为91.4%,参数量指标为10.94M,相比YOLOv8s原模型下降1.5%,GFLOPs指标为27.0, 比YOLOv8s原模型下降5.6%,说明本文提出的改进模型相比原始模型体积更小,模型复杂度更低,满足嵌入式系统低功耗、小内存的需求.改进模型的FPS指标为123.5 (f/s),远高于保持视频连续的最低15 (f/s),满足作业现场对实时性的需求.

为更好地研究各个模块加入后对模型检测精度产生的影响,以训练轮次为横坐标,mAP50指标为纵坐标,得到对应的曲线图,如图 6 所示.



由图 6 可知, P2 检测层提升 mAP50 指标值的效果 最强,但也使得曲线的平滑度下降,在 P2 检测层的基 础上将模型的检测头替换为 SPS 检测头后,降低了曲 线在迭代后期的波动程度.

3.5 对比实验

为验证改进 YOLOv8s 模型的性能优劣,用改进 YOLOv8s 模型和 YOLOv3-tiny^[16]、YOLOv5s^[17]、 YOLOv7-tiny^[18]、Faster-RCNN、YOLOv8s 等几个模 型以及两个优化 YOLOv8s 模型在 CUMT-HelmeT 数 据集上进行对比实验,结果如表 4 所示.实验结果表明, 改进 YOLOv8s 在保持较低参数量的同时, *mAP50* 指 标比 YOLOv3-tiny 高出 17.5%,比 YOLOv5s 高出 3.7%,比 YOLOv7-tiny 高出 3.9%,比 Faster-RCNN 高 出 7.9%,比 YOLOv7-tiny 高出 3.2%,比用 RFCAConv 替 换主干层卷积的 YOLOv8s 模型高出 1.8%,比引入了 VoVGSCSP 模块的 YOLOv8s 模型高出 3.3%,说明改 进 YOLOv8s 模型在煤矿井下环境中对安全帽的漏检 误检概率更低,检测精度更高,更能满足对井下矿工安 全帽识别任务的需求.

	長4 对比实验	× ×	-
模型名称	mAP50 (%)	Params	GFLOPs
YOLOv3-tiny	73.9	8672186	13.0
YOLOv5s	83.7	7015519	16.0
YOLOv7-tiny	87.5	11210326	28.6
Faster-RCNN	83.5	41 383 451	208.3
YOLOv8s	88.2	11 126 358	28.6
YOLOv8s+RFCAConv	89.6	11186454	28.9
YOLOv8s+VoVGSCSP	88.1	10266070	25.1
改进YOLOv8s (本文)	91.4	10948696	27.0

为进一步验证改进 YOLOv8s 模型在各类环境中的泛化性,用 YOLOv8s 模型和改进 YOLOv8s 模型在

CUMT-HelmeT 数据集和 SHWD 数据集上进行安全帽 检测实验,其中,CUMT-HelmeT 数据集中的数据多为 井下磅房、井下变电所等矿井环境中的数据,SHWD 数据集中多为各类建筑施工工地、电力工作场所等地 面上的数据.实验结果如表 5 所示.

表 5 数据集实验						
数据集	模型名称	mAP50 (%)	Params	GFLOPs		
CUMT-HelmeT	YOLOv8s	88.2	11126358	28.6		
	改进YOLOv8s	91.4	10948696	27.0		
SHWD	YOLOv8s	93.4	11126358	28.6		
	改进YOLOv8s	95.0	10948696	27.0		

表 5 中实验结果表明, 改进 YOLOv8s 模型相对 于 YOLOv8s 模型, mAP50 指标在 CUMT-HelmeT 数 据上提高了 3.2%, 在 SHWD 数据集上提高了 1.6%, 均 实现了检测精度的提升, 说明改进 YOLOv8s 模型不仅 适用于井下磅房、井下变电所等矿井环境下的安全帽 检测, 同时也适用于建筑施工工地、电厂、电力巡检 现场等多种环境, 体现了模型的泛化性.

为更直观地显示模型改进后的实际检测效果,从 两个数据集中挑选施工工地、井下制冷硐室、中央泵 房、井下炸药库4个场景图片,分别用 YOLOv8s 模型 和改进 YOLOv8s 模型对它们进行安全帽检测,实验结 果如图7和图8所示,改进后的模型对4个场景中工 人佩戴的安全帽推理得出的置信度更高,得到的预测 边界框也更加贴近真实边界框.



图 7 YOLOv8s 模型检测效果



图 8 改进 YOLOv8s 模型检测效果

4 结论

针对矿井下矿工安全帽佩戴检测问题,本文提出 一种基于改进 YOLOv8s 的矿井下安全帽佩戴检测模 型.首先在模型 Neck 层中融入 effectiveSE 注意力机 制,设计了新的 C2f-eSE 特征提取模块,使得模型能更 加专注于对视频图像中安全帽的位置进行锚定;用 Wise-EIoU 损失函数替代 YOLOv8s 原有的 CIoU 损失 函数,减小了低质量图片对检测算法的负面影响,提高 了算法的鲁棒性;让检测分支和分类分支共用一个 SCConv 卷积和标准 1×1 卷积,根据参数共享思想重构 新的 SPS 检测头模块,优化模型结构,提高了模型性能; 在 Neck 层中增加一层 P2 检测层,使模型的特征提取 网络融入更多的浅层信息,避免因视频图像中安全帽 尺寸太小而产生的特征丢失,减少对安全帽的漏检.

本文通过注意力机制对比实验、消融实验、多种

26 专论•综述 Special Issue

模型对比实验证明了改进模型在 mAP50、Precision、 Recall、GFLOPs、FPS 等检测指标上的提升,将改进 模型应用于矿井下矿工安全帽佩戴检测,能提高检测 精度,减少漏检、误检.

参考文献

- Vaishali, Shenoy MA, Betrabet PR, *et al.* Helmet detection using machine learning approach. Proceedings of the 2022 International Conference on Smart Electronics and Communication (ICOSEC). Trichy: IEEE, 2022. 1383–1388.
- 2 张旭, 董绍江, 胡小林, 等. 基于改进 YOLOv3 的安全帽佩 戴检测算法. 机床与液压, 2023, 51(24): 26-32.
- 3 Shen J, Xiong X, Li Y, *et al.* Detecting safety helmet wearing on construction sites with bounding-box regression and deep transfer learning. Computer-aided Civil and Infrastructure Engineering, 2021, 36(2): 180–196. [doi: 10.1111/mice.12579]

- 4 白培瑞, 王瑞, 刘庆一, 等. DS-YOLOv5: 一种实时的安全 帽佩戴检测与识别模型. 工程科学学报, 2023, 45(12): 2108-2117.
- 5 孙迟,刘晓文.基于 YOLOv7-tiny 改进的矿工安全帽检测. 中国科技论文, 2023, 18(11): 1250-1256, 1274. [doi: 10. 3969/j.issn.2095-2783.2023.11.013]
- 6 董彦强,程德强,张云鹤,等.基于注意力和重构特征融合 的轻量级煤矿安全帽检测方法.计算机工程与应用,2024, 60(15): 297-306.
- 7 Le HB, Kim TD, Ha MH, et al. Robust surgical tool detection in laparoscopic surgery using YOLOv8 model. Proceedings of the 2023 International Conference on System Science and Engineering (ICSSE). Ho Chi Minh: IEEE, 2023. 537-542.
- 8 Zheng ZH, Wang P, Ren DW, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation. IEEE Transactions Cybernetics, 2022, 52(8): 8574-8586. [doi: 10.1109/TCYB. 2021.3095305]
- 9 Lee Y, Park J. Centermask: Real-time anchor-free instance segmentation. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 13906-13915.
- ..-1260. (校对责编: 王欣欣) 10 Zhang YF, Ren WQ, Zhang Z, et al. Focal and efficient IoU loss for accurate bounding box regression. Neurocomputing, 2022, 506: 146-157. [doi: 10.1016/j.neucom.2022.07.042]

- 11 魏陈浩,杨睿,刘振丙,等.具有双层路由注意力的 YOLOv8 道路场景目标检测方法. 图学学报, 2023, 44(6): 1104-1111.
- 12 张倩, 刘紫燕, 陈运雷, 等. 融合 Transformer 和改进 PANet 的 YOLOv5s 交通标志检测. 传感技术学报, 2023, 36(2): 232-241.
- 13 成怡,张宇,李宝全.基于改进 CenterNet 的交通监控车辆 检测算法. 计算机仿真, 2023, 40(1): 131-136, 212.
- 14 贾可心,马正华,朱蓉,等.注意力机制改进轻量 SSD 模 型的海面小目标检测.中国图象图形学报,2022,27(4): 1161–1175.
- 15 Nguyen DL, Vo XT, Priadana A, et al. Car detector based on YOLOv5 for parking management. Proceedings of the 12th Conference on Information Technology and Its Applications. Cham: Springer, 2023. 102–113.
- 16 Redmon J, Farhadi A. YOLOv3: An incremental improvement. arXiv:1804.02767, 2018.
 - 17 Yadav PK, Thomasson JA, Searcy SW, et al. Assessing the performance of YOLOv5 algorithm for detecting volunteer cotton plants in corn fields at three different growth stages. Artificial Intelligence in Agriculture, 2022, 6: 292-303. [doi: 10.1016/j.aiia.2022.11.005]
 - 18 Reddy ESTK, Rajaram V. Pothole detection using CNN and YOLOv7 algorithm. Proceedings of the 6th International Conference on Electronics, Communication and Aerospace