

DOI:10.19651/j.cnki.emt.2416104

基于改进 YOLOv8n 的施工现场安全帽检测算法^{*}

齐瑞洁 袁玉英 孙立云 乔世超

(山东理工大学计算机与技术学院 淄博 255022)

摘要: 建筑、采矿、勘探等施工现场是非常复杂且多样化的区域,在这类场景下进行安全帽佩戴检测时,会存在图像遮挡严重、小目标信息容易丢失的问题。为此本文提出了一种基于改进 YOLOv8n 的安全帽佩戴检测算法。首先,对 YOLOv8n 模型的 C2f 模块进行改进,融入改进后的倒置残差块注意力机制,使模型能够高效捕获全局特征,充分利用安全帽特征的关键信息;其次,结合 SPPF 模块和 LSKA 注意力机制,提出了 SPPF-LSKA 模块,提升网络对安全帽关键信息的关注度,避免实际复杂场景中背景信息对安全帽佩戴状态检测的影响;最后,使用 Inner-SIoU 损失函数优化网络模型,提升模型对安全帽佩戴状态检测的稳定性。实验结果表明,最终本文算法在复杂环境下安全帽佩戴状态检测的 mAP@0.5 达到了 93.7%,较原 YOLOv8 算法的 P、R、mAP@0.5 和 mAP@0.5:0.95 分别提高了 2.4%、4.0%、3.4%和 5.3%,参数量降低了 3.5%,计算量降低了 5.9%,改善了安全帽佩戴状态检测误检和漏检的状况,便于实际检测应用的部署。

关键词: 深度学习;YOLOv8;安全帽检测;注意力机制;损失函数

中图分类号: TN919.8 **文献标识码:** A **国家标准学科分类代码:** 510.4050

A construction site safety helmet detection algorithm based on improved YOLOv8n

Qi Ruijie Yuan Yuying Sun Liyun Qiao Shichao

(College of Computer Science and Technology, Shandong University of Technology, Zibo 255022, China)

Abstract: Construction sites such as construction, mining, and exploration are very complex and diverse areas. When conducting helmet wearing detection in such scenarios, there are problems such as severe image occlusion and easy loss of small target information. This article proposes a helmet wearing detection algorithm based on improved YOLOv8n. Firstly, the C2f module of the YOLOv8n model is improved by incorporating an improved inverted residual block attention mechanism, enabling the model to efficiently capture global features and fully utilize the key information of safety helmet features; secondly, by combining the SPPF module and LSKA attention mechanism, the SPPF-LSKA module is proposed to enhance the network's attention to key information of safety helmets and avoid the influence of background information on the detection of safety helmet wearing status in practical complex scenarios; finally, the Inner-SIoU loss function is used to optimize the network model and improve the stability of the model in detecting the wearing status of safety helmets. The experimental results show that the algorithm proposed in this paper can effectively detect the wearing status of helmets in complex environments mAP@0.5 has reached 93.7%, compared to the original YOLOv8 algorithm's P, R, mAP@0.5 and mAP@0.5:0.95 has increased by 2.4%, 4.0%, 3.4%, and 5.3% respectively, the number of parameters has decreased by 6.7%, and the computational workload has decreased by 4.8%, improving the detection of false and missed safety helmet wearing status, facilitating the deployment of practical detection applications.

Keywords: deep learning; YOLOv8; safety helmet inspection; attention mechanism; loss function module

0 引言

建筑、采矿、勘探等行业的工程实施是一项高风险的工

作,各种危险因素都有可能导致事故发生和人员受伤。因此,施工人员的安全意识和安全措施必须高度关注。研究数据表明,在施工场地作业人员的不安全行为是导致安全

收稿日期:2024-05-23

^{*} 基金项目:国家自然科学基金(62076152)、淄博市科技型中小企业创新能力提升工程项目(2023tsge0043)、张店区校城融合发展计划项目(2021JSCG0018)资助

事故发生的主要原因,约占总体事故的 88%^[1]。众多不安全行为中,施工人员未佩戴安全帽最容易导致施工安全事故的发生。进入施工现场的人员安全意识普遍不够强烈,因此在施工现场检测人员是否佩戴安全帽是非常重要的,能够有效减少施工场地事故的发生,保障施工人员的安全。

目前,用于检测施工人员是否佩戴安全帽的经典检测算法共有两类:单阶段和两阶段目标检测算法^[2]。

其中两阶段检测算法包括 R-CNN^[3]、Fast-RCNN^[4]、Faster-RCNN^[5]等,这种算法需要对大量的候选区域进行分类和回归,这样会网络结构复杂化,使算法训练和推理的速度变慢。在实际应用中,特别是对于需要实时检测的场景,这种较慢的检测速度可能会成为限制因素。

单阶段检测算法包括 SSD^[6]、YOLO^[7]等,其主要思想是通过一个网络在输入图像上进行密集的预测,实现对目标的检测和定位。其中 YOLO 系列网络模型非常适用于实时应用场景的检测任务,主要包括 YOLOv3、YOLOv5、YOLOv7、YOLOv8 等。杨永波等^[8]通过使用 MobileNetV3 代替 YOLOv5s 主干网络进而实现网络模型的轻量化,但同时也降低了检测精度;丁田等^[9]构建了一个真实施工场景下的小目标安全帽数据集,并且在 YOLOX 算法的基础上引入 ECA-Net 注意力机制和 Ciou 损失函数,提高特征提取能力的同时加快模型收敛速度;Lin 等^[10]在 YOLOv5 骨干网络中增加了扩展卷积坐标内注意(dilated convolution coordinate attention, DICA)层,以获得更多的上下文信息,使用重建双向特征金字塔网络(rebuild bidirectional feature pyramid network, Re-BiFPN)作为特征提取网络,便于模型学习不同尺度的对象特征;杜青等^[11]自建了矿山安全帽佩戴数据集,并且在 YOLOX 算法的基础上融合注意力机制,构建了 YOLOX-A 模型,大大

提升了模型在亮度低、清晰度低、遮挡等复杂环境下的检测精度;张欣毅等^[12]针对轧钢车间作业设备繁多、环境杂乱、昼夜光照差别大等问题,设计了一种基于改进 YOLOv7 模型改进的算法,该算法使用 NWD 方法对损失函数进行改进,并且在 SPPCSPC 模块的基础上融合 BiFormer 模块,在不增加运算负担的同时提高模型对小目标的检测精度;Wu 等^[13]设计了一个基于 YOLOv5 的轻量级模型 YOLO_CA,用于建筑工人头盔佩戴的自动检测。在主干部分引入坐标注意力的同时用 Ghost 模块替换 C3,减少了特征通道融合所需的浮点运算。虽然上述改进后的算法从不同方面提升了检测性能,但在面对实际安全帽检测的复杂场景时,检测效果并不理想。

因此本文针对以上安全帽佩戴检测存在的问题,在 YOLOv8n 的基础上进行改进。首先,在倒置残差块注意力机制(inverted residual mobile block, iRMB)基础上融合 shift-wise conv,设计了轻量 C2f-iRMB-SWC 模块,提升模型对小目标的检测能力;其次,将模型的 SPPF 模块结合大核可分离注意力模块(large separable kernel attention, LSKA),提升网络在多个尺度上聚合特征的能力,来减少复杂背景对安全帽检测的干扰;最后,采用 Inner-SIoU 损失函数替换完全交并比损失函数(complete intersection over union loss, Ciou Loss)^[14],进一步提升模型的检测效果。

1 本文提出的模型

为解决当前算法在面对实际复杂检测场景时,检测效果不理想,容易出现误检和漏检的问题,本文提出了一种基于 YOLOv8n 改进的安全帽佩戴状态检测模型,该模型在密集、遮挡、低光照等场景中具有较高的性能和鲁棒性,网络模型总体结构如图 1 所示。

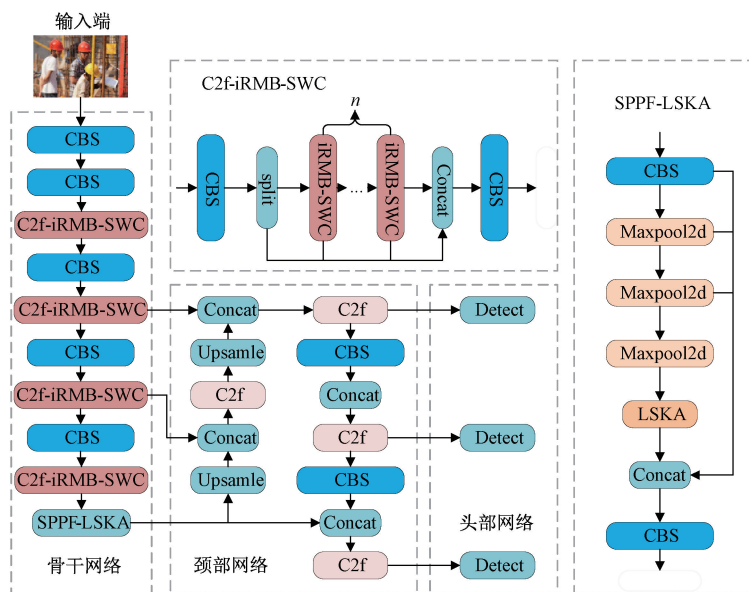


图 1 改进后的网络结构

Fig. 1 Improved network structure

1.1 YOLOv8 基准模型

YOLOv8 在先前 YOLO 成功的基础上引入新的功能,进一步提升了模型的性能,无论是在检测精度还是速度方面都毋庸置疑。YOLOv8 根据网络深度和检测精度的需求,提供了不同大小的模型。一般而言,模型大小(如 n 、 s 、 m 、 l 、 x)与

其参数数量和计算复杂度相关联,随着模型大小的增加,检测精度可能会提高,但相应地,模型的计算量也会增加。由于 YOLOv8n 具有最小的参数数量和最快的检测速度,满足安全帽检测实际应用对实时性的要求,因此本文选择 YOLOv8n 作为基准模型进行研究,网络模型结构如图 2 所示。

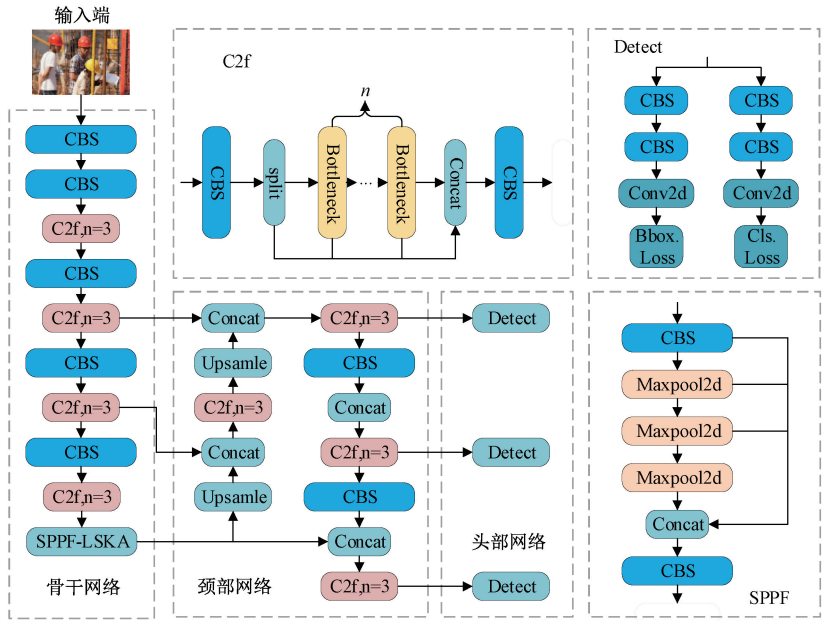


图 2 YOLOv8 结构
Fig. 2 YOLOv8 structure diagram

YOLOv8 网络分为输入端 (input)、骨干网络 (backbone)、颈部网络 (neck) 和头部网络 (head)^[15], 其中 input 部分主要有 mosaic、自适应锚框计算和自适应灰度填充这 3 种数据增强技术。Backbone 部分借鉴了 YOLOv7 中 ELAN 多分支跨层连接的设计思想, 设计了 C2f 结构, 使模型具有更为丰富的梯度流, 对目标特征具有较强的提取能力^[16]。Neck 部分采用路径聚合网络 (path aggregation network, PAN) 结构, 提高模型对不同尺度目标的特征融合能力^[17]; 头部网络部分采用解耦头结构, 把分类和检测头分离; 在 Loss 部分, 采用 Task Aligned Assigner 分配策略, 根据分类与回归的分数加权结果直接选择正样本; 损失计算分为分类和回归两部分: 分类部分采用了二元交叉熵损失 (binary cross entropy loss, BCE Loss) 进行训练; 回归部分融合分布焦点损失 (distribution focal loss, DF Loss) 和 CIoU Loss, 以提升模型对边界框预测的准确性^[18]。

1.2 C2f-iRMB-SWC 模块

1) 倒置残差块注意力机制 iRMB

在当前的目标检测任务中, 模型一般通过引入注意力机制来提高其在处理复杂数据时的效率和精度。但安全帽检测的实际场景中存在众多复杂的小目标, 在检测时容易出现漏检、误检的问题。而 iRMB^[19] 就是针对密集预测

任务而设计的一款轻量化注意力机制, 兼顾动态全局建模和静态局部信息融合的优势, 能够更好地捕捉目标特征信息来适应不同尺度的安全帽目标, 同时能够有效地增加模型的感受野, 提升对于下游任务的能力。iRMB 结构如图 3 所示。




图 3 iRMB 结构
Fig. 3 iRMB structure

首先使用联合多层感知器 (combined multi-layer perception, CMLP) 生成注意力矩阵 Q 和 K , 然后使用一

个膨胀卷积来生成注意力矩阵 V , 然后对 Q 和 K 使用窗口自注意力机制来进行远程交互, 紧接着使用一个 DWConv 来建模局部特征, 最后使用压缩卷积来恢复通道数, 并与输入相加, 得到最终结果。

2) shift-wise conv

大核卷积能够高效捕获更大范围的特征, 有助于理解输入数据中的全局结构和关系。但由于大核卷积的卷积核很大, 会导致模型处理细节信息和保持网络稳定性方面可能存在一些挑战, 而且大核卷积需要处理更大的输入数据范围, 因此计算量会增加, 导致训练和推理时间增加。为了解决上述问题, 本文采用了一种 shift-wise 操作, 借助稀疏机制确保 CNN 捕获长短距离依赖关系, 使小卷积核也能更高效捕获全局特征, 同时保持对硬件的友好性, shift-wise 操作过程如图 4 所示。

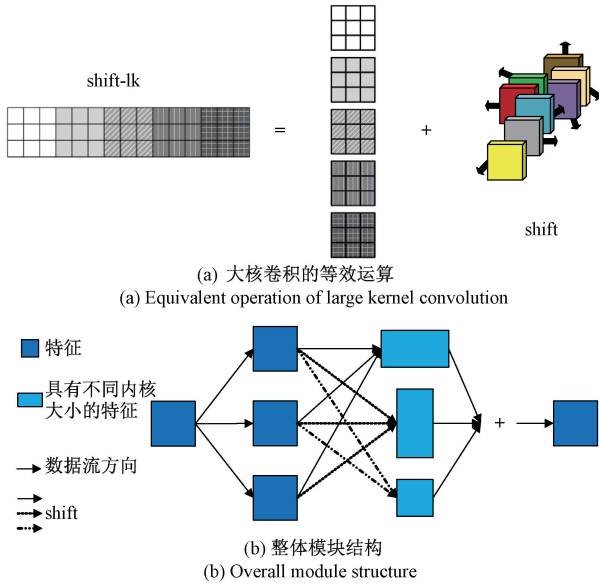


图 4 方法示意图

Fig. 4 Method diagram

图 4(a) 表示将一个 $M \times N$ 卷积核分解为 k 个 $N \times N$ 卷积核, 利用移位运算完成大卷积核的等效运算; 图 4(b) 是整体模块结构。

3) C2f-iRMB-SWC 模块

建筑、采矿、勘探等是施工现场是复杂且多样化的区域, 因此监控画面中存在众多复杂小目标场景, 在这类场景下进行安全帽佩戴检测时, 会存在图像遮挡严重、目标信息容易丢失的问题。

因此本文在 iRMB 的基础上融合 shift-wise conv 构建了新的模块 iRMB-SWC, 并结合 C2f, 设计了全新的 C2f-iRMB-SWC 模块, 结构如图 5 所示。在 iRMB 模块中使用 shift-wise 优化普通卷积, 使模型能够更加高效地捕获全局特征, 更好的学习到目标物体的尺度、背景等信息, 提升模型检测安全帽的性能的同时降低了模型参数。本文通过

iRMB-SWC 模块对 C2f 改进得到 C2f-iRMB-SWC 模块, 使模型在复杂多变的实际场景下, 也能正确捕获安全帽细小、遮挡等特征的关键信息, 具有更强的鲁棒性和泛化能力。

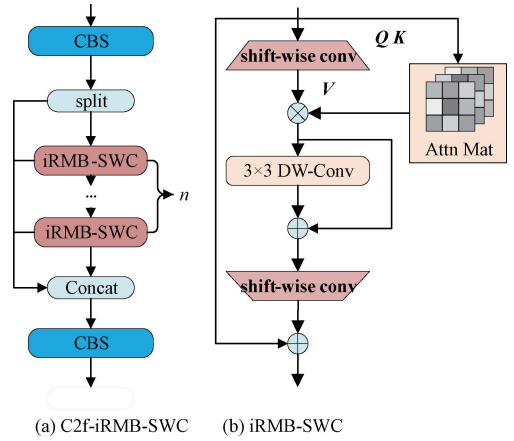


图 5 C2f-iRMB-SWC 结构

Fig. 5 C2f-iRMB-SWC structure


1.3 SPPF-LSKA 模块

自注意力机制将 2D 图像视为 1D 序列, 只考虑了空间维度的适应性, 而忽略了通道维度的适应性。大核注意力 (large kernel attention, LKA) 解决了自注意力机制忽略 2D 结构的问题, 结合了自注意力和大核卷积的优点, 对大核卷积操作进行分解来捕获长程依赖性和通道适应性, 其过程结构如图 6 所示。

大型内核卷积可分为 3 个部分: 空间局部卷积 (深度卷积)、空间远程卷积 (深度扩展卷积) 和通道卷积 (普通 1×1 卷积)。大核分解就是将一个 $K \times K$ 卷积分解为一个膨胀系数为 d 的 $(k/d) \times (k/d)$ 深度方向的膨胀卷积, 一个 $(2d-1) \times (2d-1)$ 深度卷积和 1×1 卷积。但是 LKA 模块中的深度卷积层会随着卷积核大小的增加而导致计算量和内存占用呈二次增加, 从而增加模型计算的负担。为了解决上述问题, 本文采用 LSKA 注意力机制, 保留了 LKA 注意力机制的优点, 降低计算复杂性的同时提升捕获长程依赖性的能力, 进而提高模型检测安全帽的精度。

LSKA 也是一种大型可分离核注意力模块, 它是在 LKA 注意力模块的基础上, 将深度卷积层的二维卷积核分解为级联的水平和垂直一维卷积核, 既保留了 LKA 大核卷积捕获长程依赖性和适应性的优势, 又能降低计算复杂度从而满足内存需求, 其过程结构如图 7 所示。

由于实际的安全帽佩戴状态检测背景环境是非常复杂的, 可能会存在光照不均、小目标密集、安全帽颜色和背景颜色不好区分等问题, 本文在空间金字塔模块 (spatial pyramid pooling fusion, SPPF) 的基础上引入 LSKA 注意



(a) 大核分解过程
(a) Large nuclear decomposition process





图 6 LKA 注意力结构
Fig. 6 LKA attention structure



(a) 2D卷积分离为1D过程
(a) 2D convolution separation into 1D process





图 7 LSKA 注意力结构
Fig. 7 LSKA attention structure

力机制,提出了 SPPF-LSKA 模块,提升网络在多个尺度上聚合特征的能力,增强网络对于安全帽重要特征的关注意度,降低无用复杂背景信息对安全帽佩戴检测的干扰,结果如图 8 所示。



1.4 Inner-SIoU 损失函数

YOLOv8 的回归损失函数是 CIoU,这个损失函数会被预测框与真实框之间距离、重叠度和长宽比影响,且没有考虑到它们之间的方向匹配问题,即预测框的宽高不能同步增加或减少,这样会使模型在训练时出现回归误差较大、收敛速度缓慢以及收敛后数据不稳定的现象。因此本

文采用 Inner-SIoU^[20] 作为模型回归损失函数,其引入了一个尺度因子比,通过控制辅助边界框的尺度大小来计算损失,辅助边界框描绘如图 9 所示。

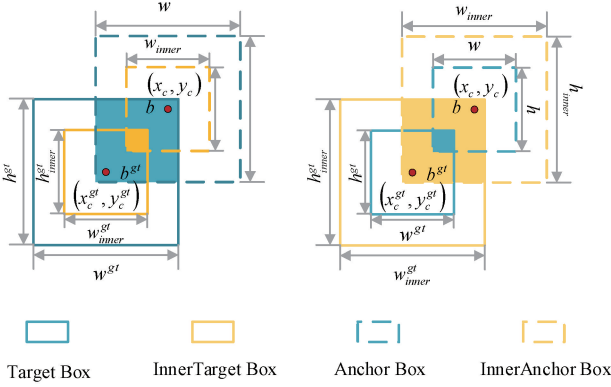


图 9 辅助边界框描绘

Fig. 9 Auxiliary bounding box drawing

真实框和预测框分别表示为 B^{gt} 和 B 。真实框质心坐标用 (x_c^{gt}, y_c^{gt}) 表示,而 (x_c, y_c) 则表示预测框质心坐标。真实框的宽度和高度分别表示为 w^{gt} 和 h^{gt} ,而预测框的宽度和高度分别表示为 w 和 h 。

Inner-SIoU 损失函数计算公式为:

$$L_{Inner-SIoU} = L_{SIoU} + IoU - IoU^{inner} \quad (1)$$

式中: L_{SIoU} 表示 SiIoU 损失函数, IoU 表示预测框与真实框的交并比, IoU^{inner} 的定义如式(2)所示。

$$IoU^{inner} = \frac{inter}{union} \quad (2)$$

式中: $inter$ 和 $union$ 的定义为:

$$inter = (\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l)) \times (\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)) \quad (3)$$

$$union = (w^{gt} \times h^{gt}) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inter \quad (4)$$

式中: $ratio$ 为生成辅助边界框的尺度因子,通常取范围为 $[0.5, 1.5]$ 。 $b_r^{gt}, b_r, b_l^{gt}, b_l, b_b^{gt}, b_b, b_t^{gt}, b_t$ 的定义如下:

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (5)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (6)$$

$$b_l = x_c - \frac{w \times ratio}{2}, b_r = x_c + \frac{w \times ratio}{2} \quad (7)$$

$$b_t = y_c - \frac{h \times ratio}{2}, b_b = y_c + \frac{h \times ratio}{2} \quad (8)$$

使用 Inner-SIoU 作为本文的损失函数有助于提升本文模型检测性能和泛化能力。

2 实验数据及处理

本文实验使用公开的安全帽佩戴检测数据集(safety helmet wearing detect dataset, SHWD)^[21]。该数据集收

集了各种场所人员安全帽佩戴数据,共有 7 581 张图片,使用 Labeling 图像标注软件进行标注,标注的内容为“hat”和“person”两类,其中“hat”代表正样本(佩戴安全帽的对象),共 9 044 个;“person”代表负样本(未佩戴安全帽的对象),共 111 514 个。实验按照 6 : 2 : 2 的比例将数据集划分为训练集、验证集和测试集。

2.1 评价指标

本文实验使用精确率(precision, P)、召回率(recall, R)、平均均值精度(mean average precision, mAP)来衡量改进后 YOLOv8 网络模型对安全帽佩戴的检测性能。

其中,精确率 P 表示预测为正样本中实际正样本所占比例,其计算公式为:

$$P = \frac{TP}{TP + FP} \quad (9)$$

式中: TP (true positive)表示正确分类的正样本数,即佩戴安全帽的目标被检测为佩戴了安全帽; FP (false positive)表示误报的负样本数,即为未佩戴安全帽的目标被检测为戴了安全帽。

召回率 R 的计算公式如下:

$$R = \frac{TP}{TP + FN} \quad (10)$$

式中: FN (false negative)表示在漏报的正样本数,即为佩戴安全帽的目标被检测为未佩戴安全帽。

平均精度均值 mAP 采用 $mAP@0.5$ (IoU 阈值为 0.5)和 $mAP@0.5 : 0.95$ (IoU 阈值在 0.5~0.95 之间)作为评价指标。其中, mAP 计算公式如下:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (11)$$

式中: N 是检测目标的类别数,本文设置 $N=2$, AP_i 为类别 i 的平均精度,其计算公式为:

$$AP_i = \int_0^1 P_i \cdot R_i \quad (12)$$

式中: P_i 和 R_i 分别表示检测类别 i 的准确率和召回率。

2.2 实验平台

本实验运行环境的 CPU 为 Intel(R) Xeon(R) Platinum 8255C 2.50 GHz 12 核处理器,43 GB 内存, GPU 为英伟达 RTX3090,显存为 24 GB。操作系统为 Ubuntu 20.04,加速环境为 CUDA11.3。编程语言为 Python3.8,深度学习框架为 Pytorch1.10.0。实验参数设置如表 1 所示。

表 1 实验参数设置

Table 1 Experimental parameter settings

参数名	参数值
输入分辨率	640×640
训练次数(epoch)	100
批处理量(bathsize)	8
初始学习率(Lr0)	0.01
权重衰减系数(weight_decay)	0.000 5

2.3 数据集

SHWD 数据集包含以下几个特点:1)数据集涵盖了常见的安全帽佩戴检测应用场景,如建筑工地、采矿和勘察等,数据集场景的代表性有利于提高算法在真实场景的泛化能力;2)数据集包含多种图像变化,如亮度、尺度和目标数量等变化。这些变化与实际安全帽检测场景的变化一致,有助于提高算法的鲁棒性;3)数据集图像的检测目标密集,存在相互遮挡的情况,小目标占比较大,与实际检测情况相符。数据集部分示例图像如图 10 所示。



图 10 数据集示例图像
Fig. 10 Dataset example image

本文对 SHWD 数据集进行分析,绘制了训练集标签相对于整幅图宽高比的分布图,如图 11 所示,0.2 以下的小目标占据比例较大。




图 11 目标宽高比的分布
Fig. 11 Distribution map of target aspect ratio

3 实验结果与分析

为验证本文提出的改进算法的有效性,本文在 SHWD 数据集上进行对比以及消融实验,实验过程中,控制设备、训练超参数、虚拟环境等实验条件保持一致,得出实验结果并进行对比和分析。

3.1 与基准模型对比实验

为了探究本文算法对 SHWD 数据集中佩戴安全帽和

未佩戴安全帽目标检测的具体提升情况,将本文算法与原 YOLOv8 模型进行实验对比。这两种算法在 SHWD 测试集上的数据如表 2 所示。

表 2 本文算法与 YOLOv8 检测性能对比

Table 2 Comparison of detection performance between the algorithm in this article and YOLOv8				
算法	分类	P/%	R/%	mAP@0.5/%
YOLOv8	hat	88.6	81.8	88.8
	person	89.7	85.8	91.8
	all	89.6	84.1	90.3
本文算法	hat	92.2	88.3	93.9
	person	91.7	88.0	93.4
	all	92.0	88.1	93.7

表 2 对比了 YOLOv8 和本文算法在 SHWD 测试集上的性能评估指标,综合 hat 和 person 这两类目标的检测结果可以看出,与原始 YOLOv8 算法对比,本文算法在各项指标均有所提升,其中佩戴安全帽的 mAP 提升了 5.1%,而未佩戴安全帽的 mAP 提升了 1.6%,综合 mAP 提升了 3.4%,由此可得本文算法优于原 YOLOv8 模型的性能。

3.2 不同损失函数对比实验

为了验证不同损失函数对于模型检测性能的影响,本文分别使用基于 CIoU、SIoU、EIoU 以及 Inner-SIoU 几种边界框损失函数的模型进行对比实验,其中 Inner-SIoU 的 ratio 值分别设置为 0.7、0.8、0.9 和 1.1,实验结果如表 3 所示。

表 3 不同损失函数性能对比

Table 3 Performance comparison of different loss functions				
损失函数	ratio	P/%	R/%	mAP@0.5/%
CIoU		89.6	84.1	90.3
SIoU		89.7	83.9	90.2
EIoU		89.9	84.3	90.4
Inner-SIoU	0.7	90.1	84.4	90.7
Inner-SIoU	0.8	90.5	84.6	90.9
Inner-SIoU	0.9	90.4	84.3	90.5
Inner-SIoU	1.1	90.2	84.4	90.5

从表 3 的实验结果可以看出,选择 Inner-SIoU 作为模型的损失函数时检测性能最佳,当比值参数设置为 0.8 时,P、R、mAP@50 也取得最优值。因此选择 Inner-SIoU 作为本文的损失函数,且 ratio 设置为 0.8。

3.3 消融实验

为了验证各个改进模块的优化作用,在 SHWD 数据集上进行消融实验。如表 4 所示,模型 1 为 YOLOv8 + C2f-iRMB-SWC;模型 2 为 YOLOv8 + C2f-iRMB-SWC +

SPPF-LSKA; 模型 3 为 YOLOv8 + C2f-iRMB-SWC + SPPF-LSKA + Inner-SIoU。由表 4 可以看到与原模型相比,模型 1 的 P、R、mAP@0.5 和 mAP@0.5:0.95 的值分别提高了 2.0%、2.6%、2.4%和 2.8%,并且降低了模型的大小、参数量和计算量,说明 C2f-iRMB-SWC 模块能够平衡好精度与速度之间的关系,在复杂多变的实际应用场景中,也能高效捕获安全帽细小、遮挡等特征信息;模型 2 的 P、R、mAP@0.5 和 mAP@0.5:0.95 的值分别提高了 2.1%、3.4%、3.0%和 4.7%,说明 SPPF-LSKA 模块能够进一步聚合各个尺度的安全帽特征,减少背景对检测的影

响;模型 3 的 mAP@0.5 和 mAP@0.5:0.95 的值分别提高了 3.4%和 5.3%,P 和 R 分别提高了 2.4%和 4.0%,参数量降低了 3.5%,计算量降低了 5.9%,说明模型 3 相对于原始 YOLOv8 模型提升了检测性能,降低了检测过程中出现漏检、误检可能性的同时降低了模型复杂度,便于应用部署到资源有限的检测设备上。综上所述,改进后的算法能够有效捕获和理解关键特征信息,在提升安全帽佩戴状态检测方面表现出色,且模型复杂度低,可以更好地应用于建筑、采矿、勘探等行业实际施工场景的安全帽检测中。

表 4 不同优化方式对模型性能影响

Table 4 The impact of different optimization methods on model performance										
模型	C2f-iRMB-SWC	SPPF-LSKA	Inner-SIoU	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	参数量/M	模型大小/MB	计算量/G
YOLOv8				89.6	84.1	90.3	55.5	3.16	6.3	8.9
模型 1	✓			91.6	86.7	92.7	58.7	2.83	5.5	7.8
模型 2	✓	✓		91.7	87.5	93.3	60.2	3.05	6.0	8.4
模型 3	✓	✓	✓	92.0	88.1	93.7	60.8	3.05	6.0	8.4

3.4 主流算法对比实验

为验证本文提出的算法对于作业人员的安全帽佩戴状态检测效果,将本文算法与当前主流目标检测算法在 SHWD 数据集上进行比较,选取 SDD、Faster-RCNN、YOLOv3-tiny、YOLOv4、YOLOv5n 和 YOLOv8 进行对比,对比结果如表 5 所示。

表 5 与主流模型对比结果

Table 5 Comparison results with mainstream models					
算法	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	帧率/fps
SDD	76.7	69.3	76.5	40.8	41
Faster-RCNN	84.4	74.4	82.0	45.1	13
YOLOv3-tiny	80.9	71.7	78.1	42.3	57
YOLOv4	85.2	77.5	84.8	49.0	61
YOLOv5n	87.9	81.5	88.5	53.1	73
YOLOv8	89.6	84.1	90.3	55.5	81
本文算法	92.0	88.1	93.7	60.8	85

由表 5 可以看出,在 SHWD 数据集上,本文算法较 YOLOv8 基准模型在准确率、召回率、mAP@0.5、mAP@0.5:0.95 上分别提升了 2.4%、4.0%、3.4%,提升了平均检测精度,降低了漏检率,且检测速度达到了 85 fps,可以满足实际场景对检测实时性以及精度的要求;相对于 YOLOv5n、YOLOv4、YOLOv3-tiny、Faster-RCNN、SDD 算法,本文提出的算法在检测精度方面也表现高的检测性能,进一步证明了本文所提算法的优越性。综上所述,本

文算法较其他主流算法在安全帽检测上表现优异,降低了误检、漏检发生的可能性,便于应用于实际的施工场景。

3.5 检测结果对比实验

为了验证本文算法在实际检测中的效果,本文对复杂场景下的图像进行测试。如图 12 所示,展示了本文算法和原 YOLOv8 基准算法在不同作业场景下的安全帽佩戴检测结果,左列是 YOLOv8 基准模型的检测结果图,右列是本文模型的检测结果图。通过结果图可以看出,左列检测结果图的检测结果置信度普遍低于右列,且左侧检测结果图出现多处漏检现象。通过对比这些结果,表明原始 YOLOv8 算法在复杂环境下容易出现误检和漏检现象,并且小目标检测精度不高,而本文算法比原始 YOLOv8 算法检测性能好,且能够有效的检测和判别到小目标的安全帽,证明改进后的 YOLOv8 算法具有较强的鲁棒性和准确性。





图 12 检测结果对比

Fig. 12 Comparison of test results

4 结 论

本文提出了一种基于改进 YOLOv8n 的安全帽佩戴状态检测算法,有效解决了原始 YOLOv8 算法在安全帽佩戴状态检测任务中复杂场景下小目标检测效果差的问题。在骨干网络部分,提出 C2f-iRMB-SWC 模块和 SPPF-LSKA 模块,其中 C2f-iRMB-SWC 模块增强了模型对安全帽特征的全局捕获能力,SPPF-LSKA 模块减少了背景环境对提取安全帽关键特征的干扰;在颈部网络,引入 Inner-SIoU 损失函数,提高模型稳定性。实验结果表明,本文算法相较于原 YOLOv8 算法的 P、R、mAP@0.5 和 mAP@0.5:0.95 分别提高了 2.4%、4.0%、3.4%和 5.3%,参数量降低了 3.5%,计算量降低了 5.9%,说明本文算法具有良好的理论性能。综上所述,本文提出的改进 YOLOv8n 的安全帽佩戴状态检测算法在检测任务中表现出了很好的性能,能够更好地应用于施工场地的安全帽佩戴状态检测中。

参考文献

[1] 高腾,张先武,李柏. 深度学习在安全帽佩戴检测中的应用研究综述[J]. 计算机工程与应用,2023,59(6): 13-29.
GAO T, ZHANG X W, LI B. A review of research on the application of deep learning in helmet wearing detection[J]. Computer Engineering and Applications, 2023, 59(6): 13-29.

[2] 雷源毅,朱文球,廖欢. 复杂场景下的改进 YOLOv8n 安全帽佩戴检测算法[J]. 软件工程,2023,26(12): 46-51.
LEI Y Y, ZHU W Q, LIAO H. Improved YOLOv8n helmet wearing detection algorithm in complex scenes[J]. Software Engineering, 2023, 26(12): 46-51.

[3] 叶飞,骆星智,宋永春,等. 基于双特征融合的改进 R-CNN 电力小金具缺陷检测方法研究[J]. 电子测量与

仪器学报,2023,37(7):213-220.

YE F, LUO X ZH, SONG Y CH, et al. Research on improved R-CNN defect detection method for power small fittings based on dual feature fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 213-220.

[4] 翟永杰,王璐瑶,郭聪彬. 基于 Faster R-CNN 的复杂背景下绝缘子目标检测[J]. 电子测量技术, 2023, 46(16):187-194.
ZHAI Y J, WANG L Y, GUO C B. Insulator target detection in complex backgrounds based on Faster R-CNN[J]. Electronic Measurement Technology, 2023, 46(16): 187-194.

[5] REN SH Q, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th European Conference on Computer Vision, Berlin: Springer International Publishing, 2016.

[7] REDMON J, DIVVALA S K, GIRSHICK R B, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016.

[8] 杨永波,李栋. 改进 YOLOv5 的轻量级安全帽佩戴检测算法[J]. 计算机工程与应用,2022,58(9):201-207.
YANG Y B, LI D. Improving the lightweight helmet wearing detection algorithm for YOLOv5 [J]. Computer Engineering and Applications, 2022, 58(9): 201-207.

[9] 丁田,陈向阳,周强,等. 基于改进 YOLOX 的安全帽佩戴实时检测[J]. 电子测量技术,2022,45(17):72-78.
DING T, CHEN X Y, ZHOU Q, et al. Real time detection of helmet wearing based on improved YOLOX [J]. Electronic Measurement Technology, 2022, 45(17): 72-78.

[10] LIN H Y, JIANG F, JIANG Y, et al. A model for helmet-wearing detection of non-motor drivers based on YOLOv5s[J]. Computers, Materials & Continua, 2023, 75(3): 5321-5336.

[11] 杜青,杨仕教,郭钦鹏,等. 地下矿山作业人员佩戴安全帽智能检测方法[J]. 工矿自动化,2023,49(7): 134-140.
DU Q, YANG SH J, GUO Q P, et al. Intelligent detection method for wearing safety helmets by underground mining operators [J]. Industrial and

- Mining Automation, 2023, 49(7): 134-140.
- [12] 张欣毅,张运楚,王菲,等.改进 YOLOv7 的轧钢车间安全帽佩戴检测算法[J/OL].计算机测量与控制,2024;1-10[2024-05-17]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20231019.1156.016.html>.
- ZHANG X Y, ZHANG Y CH, WANG F, et al. Improve the detection algorithm for wearing safety helmets in YOLOv7 steel rolling workshop[J/OL]. Computer Measurement and Control, 2024: 1-10 [2024-05-17]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20231019.1156.016.html>.
- [13] WU X Q, QIAN S R, YANG M. Detection of safety helmet-wearing based on the YOLO_CA model[J]. Computers, Materials & Continua, 2023, 77(3): 3349-3366.
- [14] ZHENG ZH H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence. 2020, 34(7): 12993-13000.
- [15] XIE SH, SUN H W. Tea-YOLOv8s: A tea bud detection model based on deep learning and computer vision[J]. Sensors, 2023, 23(14): 6576.
- [16] 王小荣,许燕,周建平,等.基于改进 YOLOv7 的复杂环境下红花采摘识别[J].农业工程学报,2023,39(6): 169-176.
- WANG X R, XU Y, ZHOU J P, et al. Identification of safflower picking in complex environments based on improved YOLOv7 [J]. Journal of Agricultural Engineering, 2023, 39(6): 169-176.
- [17] ZHOU L M, RAO X H, LI Y H, et al. A lightweight object detection method in aerial images based on dense feature fusion path aggregation network[J]. ISPRS International Journal of Geo-Information, 2022, 11(3): 189.
- [18] LOU H T, DUAN X H, GUO J M, et al. DC-YOLOv8: Small-size object detection algorithm based on camera sensor[J]. Electronics, 2023, 12(10): 2323.
- [19] ZHANG J N, LI X T, LI J, et al. Rethinking mobile block for efficient attention-based models[C]. 2023 IEEE/CVF International Conference on Computer Vision(ICCV), 2023: 1389-1400.
- [20] ZHANG H, XU C, ZHANG SH J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arxiv: 2311.02877,2023.
- [21] 李振华,张雷.改进 YOLOv3 的安全帽佩戴检测方法[J].国外电子测量技术,2022,41(12):148-155.
- LI ZH H, ZHANG L. Improving the detection method for wearing safety helmets in YOLOv3[J]. Foreign Electronic Measurement Technology, 2022, 41(12): 148-155.

作者简介

齐瑞洁,硕士研究生,主要研究方向为目标检测、图像处理。

E-mail:qi15082949019@163.com

袁玉英(通信作者),硕士研究生,副教授,主要研究方向为人工智能。

E-mail:88617060@qq.com