

施工环境中安全帽和反光衣轻量化检测方法^{*}张 羽¹ 刘皓洋¹ 贾升凯² 翁 乾² 张河山³

(1. 重庆交通大学经济与管理学院 重庆 400074; 2. 重庆渝湘复线高速公路有限公司 重庆 401121;

3. 重庆交通大学交通运输学院 重庆 400074)

摘 要: 为了解决施工环境中现有安全帽和反光衣检测算法参数量和计算量大、检测精度低以及模型较大难以高效部署等问题,提出改进 CCEI-YOLOv8 轻量化检测算法。在骨干网络和颈部网络中采用 C2f-CIB 模块;重构颈部网络,形成跨尺度特征融合模块(CCFM);引入 EMA 坐标注意力机制;将 CIoU 替换为 Inner-ElIoU,提高回归定位精确度。以 Roboflow 开源安全帽和反光衣数据集为基础,验证改进方法的有效性。实验结果表明,CCEI-YOLOv8 检测算法相较于原始 YOLOv8n,参数量降低了 48.3%、计算量下降了 32.1%、平均检测精度均值 mAP@50 提高了 0.5%,达到了 91.7%,模型仅为 3.442 MB,减少了 45%。CCEI-YOLOv8 检测算法在检测性能和轻量化方面均优于原始 YOLOv8n 检测算法和其他主流的目标检测算法,更适用于项目的实时检测和部署,为安全帽和反光衣的实时检测提供参考。

关键词: 轻量化;YOLOv8;安全帽;反光衣;目标检测;施工安全

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

Lightweight detection method for safety helmet and reflective vest in
construction environmentsZhang Yu¹ Liu Haoyang¹ Jia Shengkai² Weng Qian² Zhang Heshan³

(1. School of Economics and Management, Chongqing Jiaotong University, Chongqing 400074, China;

2. Chongqing Yuxiang Double-Track Expressway Co., Ltd., Chongqing 401121, China;

3. School of Traffic & Transportation, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: To address the issues of large parameter and computation requirements, low detection accuracy, and the difficulty of efficiently deploying large models in safety helmet and reflective vest detection, an improved lightweight detection algorithm, CCEI-YOLOv8, is proposed. In this algorithm, the C2f-CIB module is adopted in the backbone and neck networks; the neck network is reconstructed with a cross-scale feature fusion module(CCFM); the EMA coordinate attention mechanism is introduced; and CIoU is replaced with Inner-ElIoU to enhance regression localization accuracy. The effectiveness of the proposed algorithm is demonstrated through experiments conducted on the open-source Roboflow dataset for safety helmets and reflective vests. The results show that the algorithm achieves significant improvements: Parameters are reduced by 48.3%; computation is decreased by 32.1%; and the mean Average Precision(mAP@50) is increased by 0.5%, reaching 91.7%. The model size is reduced to only 3.442 MB, a decrease of 45%. Compared to the original YOLOv8n and other mainstream detection algorithms, CCEI-YOLOv8 demonstrates superior detection accuracy and lightweight design. This makes it highly suitable for real-time detection and deployment, providing a valuable reference for the real-time detection of safety helmets and reflective vests.

Keywords: lightweight; YOLOv8; safety helmet; reflective vest; object detection; construction safety

0 引 言

自动化安全预警技术能有效保障人员安全,减少安全

事故,提高生产效率。安全帽和反光衣可以在最大限度上降低施工过程的安全风险。然而,传统的施工安全管理往往采用人工监管的方式判断施工人员是否穿戴安全帽和反

收稿日期:2024-11-23

^{*} 基金项目:国家自然科学基金青年项目(72204033)、重庆市交通科技自筹项目(CQJT2022ZC23)、教育部人文社会科学研究青年基金项目(21YJC630169)、中国博士后科学基金面上项目(2022M711457)、重庆市自然科学基金面上项目(cstc2021jcyj-msxmX1010)资助

光衣,由于工地环境复杂,施工作业面积大,人员流动量大,仅依赖人工监管的方式进行施工安全管理存在效率低、监管力度及效果差等不利因素。随着深度学习的迅速发展,计算机视觉技术逐步成为建筑工程领域研究人员的热门方向^[1]。利用计算机视觉技术实现对工人安全设施佩戴情况的自动检测,能够有效降低工人受伤的可能性^[2]。因此,在资源条件有限的施工环境中,高效实时检测施工人员是否穿戴安全帽和反光衣具有重要意义。

基于深度学习的目标检测技术按照设计思路主要分为两类,一类是以 R-CNN^[3]、Fast R-CNN^[4] 和 Faster R-CNN^[5] 等为代表的两阶段检测算法;另一类是以 SSD^[6]、RetinaNet^[7]、YOLO^[8] 等基于卷积神经网络的单阶段检测算法。前者先确定候选区域后,再对候选区域进行检测和分类,并对边界框的回归进行优化目标位置。两阶段检测算法目标检测精度较低、检测速度较慢,无法达到实时检测的要求,而单阶段 YOLO 系列检测算法因其高精度、高速度及多尺度检测等特点,已广泛应用于建筑施工领域。

目前,国内外诸多学者对 YOLOv8 目标检测算法进行了研究和改进,应用于施工人员的安全设施佩戴情况检测。薛小勇等^[9]在 YOLOv8 骨干网络 C2f 模块中融合了动态蛇形卷积,提高模型提取安全防护装置多尺度特征的能力。张国鹏等^[10]采用 MobileNetV3 替换 YOLOv8 骨干网络,降低了安全帽检测算法的参数数量和计算量。针对安全帽和反光衣检测模型在复杂环境中难以部署的问题,许迪等^[11]在特征融合部分采用轻量特征金字塔网络(ST-BiFPN),减小了模型参数量。Wang 等^[12]在 YOLOv8 骨干网络采用全维动态卷积,避免产生冗余特征,加快在高危环境中对个人防护装备的检测速度。Song 等^[13]将 YOLOv8 空间金字塔池化(SPPF)替换为带孔空间金字塔池化(ASPP),提高了模型捕捉小目标安全帽的能力,减少了误检和漏检。Di 等^[14]在 YOLOv8s 基础上引入了由 MobileOne-S0 和深度空间注意力模块(AS-Block)组成的骨干网络,极大提高了在复杂环境下对个人防护装备的特征提取,但其模型规模大,检测速度略有降低。Lin^[15]将颈部网络替换成轻量级 Slim-neck 网络,以降低参数量,并增加小目标检测层,提高了复杂背景中远距离安全帽的检测性能,但模型计算复杂

度都有所增加。综上,现有 YOLOv8 施工人员安全设施佩戴情况检测算法存在着模型复杂、参数量和计算量仍然较大以及对硬件设备要求高等问题,难以在资源有限的施工环境下实现高效地项目部署。大部分检测算法仅仅是对安全帽单一类别进行检测,而忽略了对反光衣的检测,应用范围相对较小,泛化能力较差。

针对上述问题,改进算法以 YOLOv8n 为基础,在网络结构中采用紧凑倒置模块,重构颈部网络,引入高效多尺度注意力并使用 Inner-ElIoU 损失函数,提高检测精度的同时,进一步使模型轻量化。

1 YOLOv8 网络结构

2023 年 1 月,Ultralytics 推出 YOLOv8 检测算法模型,继承了前代 YOLO 系列检测算法模型优点的基础上,在实时性能、检测精度、多尺度预测等方面都取得了显著的提升,其网络结构如图 1 所示。YOLOv8 网络结构主要由 4 个部分组成:输入端(Input)、骨干网络(Backbone)、颈部网络(Neck)以及检测头(Head)。骨干网络用于图像特征提取,采用 CSPDarknet^[16]架构,将 YOLOv5 中 C3 模块与 YOLOv7 中 ELAN 结合形成梯度流更丰富的 C2f 模块,替换了 Backbone 的 C3 模块,增加更多的跳层连接,取消分支卷积操作,进一步实现 YOLOv8 模型的轻量化;颈部网络连接骨干网络和检测头,对高层和低层的特征信息流进行融合,其 PANet 结构中去除了路径聚合网络(PAN)^[17]上采样后的卷积运算,并与特征金字塔(FPN)^[18]组成特征融合(PAN-FPN)模块,实现多尺度特征融合,通过上采样和通道将融合的特征信息流传入到检测头;检测头结构中,YOLOv8 采用 YOLOX 的解耦头技术^[19],将分类和回归分别进行解耦,可直接预测目标的中心点和边界框的定位;同时采用了 Task-Aligned Assigner^[20]方法,根据分类和回归的加权分数进行正负样本匹配,引入了 DFL(distribution focal loss)交叉熵损失函数。DFL 交叉熵损失函数以概率方式对预测框进行回归,其计算如式(1)所示。

$$DFL(S_i, S_{i+1}) = -(y_{i+1} - y) \times \log(S_i) - (y - y_i) \times \log(S_{i+1}) \quad (1)$$

式中: S_i 和 S_{i+1} 是 y_i 和 y_{i+1} 的一般分布。




图 1 YOLOv8 网络结构

Fig. 1 Network structure of YOLOv8

上述文献均以 YOLOv8 为基础,通过实施各种改进策略,提高目标检测精度,应用于不同的检测任务,如表 1 所

示。然而,大量研究忽略了自身改进算法在资源有限的施工环境下能否高效项目部署的问题。因此,本文提出 4 种

改进策略,以实现施工环境中安全帽和反光衣轻量化检测。

表 1 改进策略与检测任务对比

Table 1 Comparison of improvement strategies and detection tasks

文献	改进策略	检测任务
文献[9]	骨干采用 C2f-DSConv;颈部引入 PSA;增设小目标检测头	提高矿井工作人员安全防护装置检测
文献[10]	骨干采用 MobileNetV3;颈部采用 BiFPN 并增设 SimAM	轻量化安全帽检测模型
文献[11]	骨干采用 DR-SPFP;颈部采用 ST-BiFPN;损失函数采用 Inner-ShapeIoU	提高复杂环境中安全帽和反光衣检测
文献[12]	骨干采用 ODConv 并增设 SimAM;颈部采用跨级路径聚合;检测头采用 DWConv	提高煤矿环境中 PPE 检测
文献[13]	颈部采用 DWR 和 ASPP;损失函数采用 NWD	提高施工环境中安全帽检测
文献[14]	骨干采用 MobileOne-S0 和 AS-Block;颈部采用 R-C2f;检测头采用 ASFF	提高施工环境中 PPE 检测
文献[15]	骨干增设 CA;颈部采用 Slim-neck;增设小目标检测头	提高施工环境中安全帽检测
本文模型	骨干采用 C2f-CIB;颈部采用 CCFM 并增设 EMA;损失函数采用 Inner-ElIoU	轻量化安全帽和反光衣模型

2 CCEI-YOLOv8

2.1 CCEI-YOLOv8 算法结构

为了提高建筑施工人员佩戴安全帽和反光衣的检测效果,本文提出轻量化 CCEI-YOLOv8 检测算法,使模型更高效地实现项目部署,其网络结构如图 2 所示。该检测算法网络由输入端、骨干网络、颈部网络及检测头四部分组成。在骨干网络与颈部网络引入 CIB 模块^[21],并将其与 C2f 融合构成 C2f_CIB 模块。通过紧凑反向结构,减少模型计算冗余。同时,采用深度卷积与点卷积分别进行空间

混合与通道混合,提高模型运行效率,以提高检测算法对安全帽和反光衣的检测效率和特征提取;结合 RT-DETR 颈部网络的缩放思想,对 YOLOv8 颈部网络进行重构,形成跨尺度特征融合(CCFM)模块^[22],大幅减少参数数量和计算量,使模型达到轻量化水平;在颈部网络中,添加 EMA 注意力机制^[23],以提高模型特征提取能力和泛化能力;引入 Inner-ElIoU 损失函数^[24],替换原始模型中 CIoU 损失函数,提高模型对安全帽和反光衣边界框的回归精度,从而更好地识别目标。

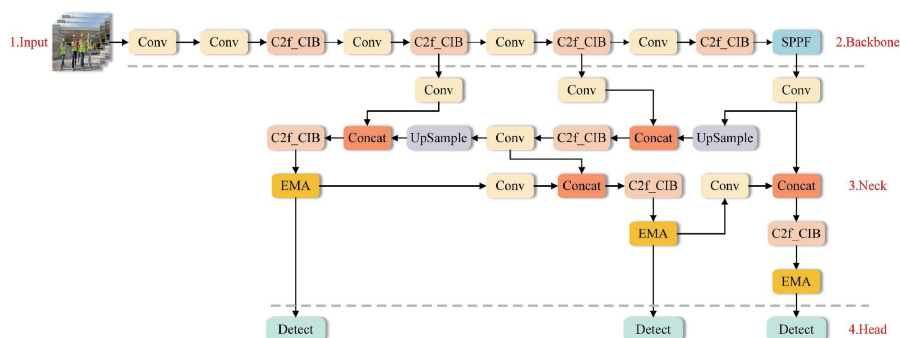


图 2 改进 YOLOv8 网络结构

Fig. 2 Improved network structure of YOLOv8

2.2 C2f CIB 模块

为了减少原始 YOLOv8 的计算冗余,本文引入 CIB 结构替换 C2f 中的 Bottleneck 瓶颈块,形成 C2f-CIB 模块,如图 3 所示。该模块能够有效减少参数量和计算量,减少冗余阶段的复杂性,提高模型的检测效率。原始 C2f 模块采用 Bottleneck 瓶颈块,用来特征提取和残差连接,通过压缩和扩展通道数,有效捕捉并融合检测网络中不同的特征信息,但是该瓶颈块使用的是标准卷积层,在计算过程中容易出现计算冗余现象,难以实现模型检测精度与效率之间的平衡。

CIB 模块通过灵活应用深度卷积和点卷积,能够实现




图 3 C2f-CIB 结构

更高效地特征提取和特征融合,其结构如图4所示。使用深度卷积在每个输入通道上独立进行卷积操作,可以看作是对每个特征图的子区域进行处理,从而捕捉空间特征信息,有利于提取精细特征。同时,该模块能够有效减少模型参数数量和计算量,有助于降低过拟合的风险,减少存储空间,降低计算成本,实现在资源有限的移动设备上部署

模型。点卷积通过使用 1×1 的卷积核,在保持空间信息不变的情况下调整通道数,实现特征通道的升维和降维,从而高效融合不同的通道信息。点卷积对每个像素点进行卷积操作,提取更丰富的全局特征,提高模型特征提取能力。




图 4 CIB 结构
Fig. 4 Structure of CIB

图 4 中,1K 指的是布尔变量,即当 1K 为 False 时,使用 3×3 的深度卷积,而当 1K 为 True 时,则使用 RepVGG 深度卷积。在 RepVGGs 深度卷积中,包含两个并行的深度卷积层,一个是 7×7 的大核深度卷积层,另一个是 3×3 的深度卷积层。模型训练时,二者分别对特征信息进行卷积操作,然后对二者卷积结果相加,并使用 SiLU 激活函数进行非线性化操作,其结构如图 5 所示。




图 5 RepVGG 结构
Fig. 5 Structure of RepVGG

同时,在推理期间将二者融合成一个 7×7 的深度卷积层,其卷积结果也是运用 SiLU 激活函数进行非线性化操作,如式(2)所示。

$$\text{SiLU}(\mathbf{W}_a) = \mathbf{W}_a \times \sigma(\mathbf{W}_a) = \frac{\mathbf{W}_a}{1 + e^{-\mathbf{W}_a}} \quad (2)$$

式中: \mathbf{W}_a 为将两个卷积层融合后的卷积结果, σ 为 Sigmoid 激活函数。

2.3 CCFM 模块

由于安全帽和反光衣的特征信息尺度不一,在特征融合过程中容易造成特征信息丢失,从而增加误检、漏检情况。基于此,本文改进算法结合 RT-DETR 颈部网络的缩放思想,重构 YOLOv8 颈部网络,形成跨尺度特征融合(CNN-based cross-scale feature fusion module, CCFM)模块,增强模型对不同尺度特征信息的融合能力。CCFM 模块是在颈部网络的特征融合路径中插入多个卷积结构组成,将多尺度特征信息进行有效整合,促进模型有效捕获细节特征信息,提高模型对多尺度特征提取的适应能力。其 CCEI-YOLOv8 颈部网络如图 6 所示。

2.4 EMA 注意力机制

在施工环境中,施工人员佩戴的安全帽和反光衣所含特征信息少、分辨率低,从而会降低 YOLOv8 捕捉特征信息的能力,同时,在通道传递过程中容易发生特征信息丢失现象。为此,本文引入跨空间学习高效多尺度注意力模




图 6 CCFM(CCEI-YOLOv8)
Fig. 6 CCFM(CCEI-YOLOv8)

块(efficient multi-scale attention module with cross-spatial learning, EMA),以增强网络通道依赖关系和全局学习能力,从而提高模型适应不同特征的能力。EMA 通过建立特征分组和聚合多尺度分支并行结构,在减少计算冗余的同时,促进特征映射通道之间的短程与长程依赖关系,从而提高模型检测性能。EMA 对输入特征映射分成多个子特征映射,并运用 3 组并行分支进行重构,分别是两组一维空间方向全局平均池化分支和一组 3×3 的卷积分支,以提取输入特征映射的注意力权重,其网络结构如图 7 所示。

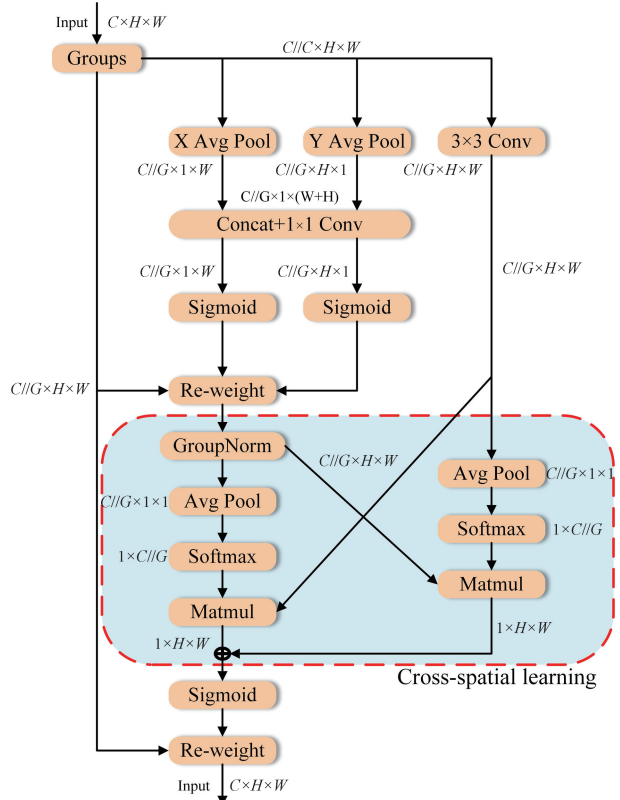


图 7 EMA 结构
Fig. 7 Structure of EMA

EMA 对任意给定的输入特征映射 $\mathbf{X} \in \mathbf{R}^{C \times H \times W}$,在通道维度方向上分成 G 个子特征映射 $\mathbf{X}_i \in \mathbf{R}^{\frac{C}{G} \times H \times W}$,即 $\mathbf{X} = [\mathbf{X}_0, \mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_i, \dots, \mathbf{X}_{G-1}]$ 。其中, G 要小于通道维度 C ,以确保 \mathbf{X} 的通道维度能够分成整数个子特征组。该分组方法能够促进网络对每个特征映射的不同区域进行特征提取,以提高模型表达能力。

对输入特征映射 \mathbf{X} 分组后,在分组特征映射 \mathbf{X}_i 上分别采用两组空间维度全局平均池化对垂直方向 H 与水平方向 W 两个空间维度的全局信息进行编码,从而生成带有注意力权重的像素级通道信息。采用 1×1 的卷积核与 Concat 函数将二者生成的通道信息进行拼接,随即运用 Sigmoid 激活函数拟合线性卷积后的二维二项分布。其一维空间维度全局平均池化如式(3)、(4)所示。

$$\mathbf{Z}_m^H = \frac{1}{W} \sum_{0 \leq i \leq W} \mathbf{x}_m(H, i) \quad (3)$$

$$\mathbf{Z}_n^W = \frac{1}{H} \sum_{0 \leq j \leq H} \mathbf{x}_n(j, W) \quad (4)$$

式中: $\mathbf{x}_m, \mathbf{x}_n$ 分别表示在分组特征映射 \mathbf{X}_i 上,进行垂直方向 H 与水平方向 W 空间维度全局平均池化的第 m 个通道和第 n 个通道的特征输入; i, j 分别表示各自特征输入 W 和 H 空间维度上的位置; $\mathbf{Z}_m^H, \mathbf{Z}_n^W$ 分别表示进行一维全局平均池化的输出。

3×3 的卷积分支则是运用 3×3 的卷积核捕捉分组特征映射的多尺度特征信息,实现跨通道交互,从而提高模型对多尺度特征信息的适应能力。

EMA 提出了一种不同空间维度的跨空间特征信息聚合方法。采用二维全局平均池化对组归一化后的两组全局平均池化输出变量和 3×3 卷积分支的输出变量进行全局空间信息编码。其二维全局平均池化如式(5)所示。

$$\mathbf{Z}_i = \frac{1}{H \times W} \sum_j^H \sum_i^W \mathbf{x}_i(i, j) \quad (5)$$

EMA 引入了二维高斯自然非线性 Softmax 函数,将上述编码的特征信息转换成概率分布,从而生成空间位置的注意力权重,以反映不同空间位置的重要性。随即应用矩阵乘法 Matmul 实现一维空间方向全局平均池化分支和 3×3 的卷积分支的跨通道交互,扩大特征映射空间,如式(6)所示。

$$\widehat{\mathbf{X}}_i = \mathbf{z}_i \cdot \mathbf{X}_i \quad (6)$$

式中: $\widehat{\mathbf{X}}_i \in \mathbf{R}^{1 \times H \times W}$ 表示经跨通道交互后带有空间注意力的输出特征映射; $\mathbf{z}_i \in \mathbf{R}^{1 \times \frac{C}{G}}$ 表示 \mathbf{Z}_i 经 Softmax 转换后的概率分布; $\mathbf{X}_i \in \mathbf{R}^{\frac{C}{G} \times H \times W}$ 表示组归一化全局平均池化分支上的分组特征映射和 3×3 卷积分支上的分组特征映射。

最后,对两条带有空间注意力权重的特征映射进行聚合,并用 Sigmoid 激活函数计算,以捕捉像素级的成对关系及突出所有像素的全局背景。

2.5 Inner-ElIoU

YOLOv8 的回归分支中,采用 CIoU 损失函数^[25]测量目标边界框与预测边界框之间的重叠程度,并添加 DFL 损失函数提高其泛化能力。CIoU 损失函数综合考虑了复杂背景下目标的重叠区域、形状及中心点,但其只考虑了长宽比的相对差异,并没有合理地反映真实差异由于施工环

境下的安全帽和反光衣会存在与建筑物相互重叠的问题,使得目标边界框的回归准确性低。基于此,本文采用 Inner-ElIoU 损失函数替换 CIoU 损失函数。

ElIoU 损失函数保留了 CIoU 损失函数的优势,将目标边界框与预测边界框的宽度之差与高度之差均为最小化,提高了检测回归的精度,如图 8 所示。其计算如式(7)所示。




图8 ElIoU

Fig. 8 ElIoU

$$Loss_{ElIoU} = 1 - \frac{|A \cap B|}{|A \cup B|} + \frac{\rho^2(b, b^{gt})}{(\omega^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{gt})}{(\omega^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2} \quad (7)$$

式中: ρ 表示欧式距离算子。

Inner 的思想是引入内部辅助边界框,以加快模型检测的回归过程^[26]。通过控制尺度因子(ratio),调节辅助边界框的比例来计算目标损失,如图 9 所示。Inner 计算如式(8)~(14)所示。

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (8)$$

$$b_l^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (9)$$

$$b_l^l = x_c - \frac{w \times ratio}{2}, b_r^l = x_c + \frac{w \times ratio}{2} \quad (10)$$

$$b_l^l = y_c - \frac{h \times ratio}{2}, b_b^l = y_c + \frac{h \times ratio}{2} \quad (11)$$

$$inter = (\min(b_r^{gt}, b_r) - \max(b_l^l, b_l)) \times (\min(b_b^{gt}, b_b) - \max(b_l^l, b_l)) \quad (12)$$

$$union = (\omega^{gt} \times h^{gt}) \times (ratio)^2 + (\omega \times h) \times (ratio)^2 - inter \quad (13)$$

$$IoU^{inner} = \frac{inter}{union} \quad (14)$$

式中: $b_l^{gt}, b_r^{gt}, b_l^{gt}, b_b^{gt}$ 分别表示目标边界框的 4 个角坐标; b_l, b_r, b_l, b_b 分别表示预测边界框的 4 个角坐标; ω^{gt}, h^{gt} 分别表示目标边界框的宽度和高度; ω, h 分别表示预测边界框的宽度和高度。

Inner-ElIoU 损失函数则是将 Inner 思想运用于 ElIoU




图 9 Inner 辅助边界框
Fig. 9 Inner auxiliary bounding box

损失函数当中。通过增加辅助边界框,优化目标边界框与预测边界框的宽度和高度的差异,提高回归定位的准确性,以确保预测边界框更接近于目标边界框,使回归过程更加敏感于边界框的尺寸和位置,从而提高模型检测性能。Inner-ElIoU 计算如式(15)所示。

$$Loss_{Inner-ElIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{gt})}{(w^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2} + IoU - IoU^{inner} \quad (15)$$

式中: IoU 表示交并比,即 $\frac{|A \cap B|}{|A \cup B|}$ 。

3 实验

3.1 实验环境

本实验配置为 Linux 系统,处理器 Intel(R) Xeon (R) CPU E5-2686 v4,显卡为 Nvidia GeForce RTX3090,其显存为 24 G;使用 Pytorch2.2.1 版本为深度学习框架, CUDA 版本为 12.1.1,编程语言为 Python3.11。为保证改进模块的有效性,所有模型训练均设置为相同的参数。

3.2 参数设置及数据集

为保证改进模块的有效性,所有模型训练均设置为相同的参数。具体模型训练超参数设置如表 2 所示。

表 2 模型训练超参数设置

Table 2 Training hyperparameter settings for the model

参数	取值
Imgsize(图片大小)	640×640
Epoch(迭代次数)	150
Batch size(批次大小)	16
Optimizer(优化器)	SGD
Lr0(初始学习率)	0.01
Lrf(最终学习率)	0.000 1
Cos lr(余弦衰减函数)	True
Momentum(动量)	0.937
Weight decay(权重衰减)	0.000 5
Workers(线程数)	16
Close mosaic(关闭马赛克)	10

本文安全帽和反光衣数据集是由 Roboflow 开源安全帽和反光衣检测数据,共 4 408 张图片,其中包含 helmet(佩戴安全帽)、no-helmet(未佩戴安全帽)、vest(穿着反光衣)及 no-vest(未穿着反光衣)4 个类别,按照 8:1.5:0.5 的比例将安全帽和反光衣数据集划分为训练集、验证集及测试集。该数据集包含以下几个特点:1)数据集涵盖了建筑施工、开挖隧道、道路勘察等常见施工场景,有利于提高算法在真实施工环境的泛化能力;2)数据集采用随机旋转、椒盐噪声、错位切换等数据增强技术,有利于提高算法的鲁棒性;3)数据集的检测目标密集,存在相互遮挡、多尺度、小目标占比较大等情况,符合真实施工场景。数据集样例如图 10 所示。

3.3 评价指标

本文为 CCEI-YOLOv8 轻量化目标检测模型,因此本次实验采用的评价指标包括:准确率 P、召回率 R、F1 值、平均精度 mAP、浮点运算量(GFLOPs)、模型参数量(parameters)及模型大小(size)、每秒传输帧数 FPS(frames per second)。P、R、F1、mAP 的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (16)$$

$$R = \frac{TP}{TP + FN} \quad (17)$$

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (18)$$

$$AP = \int_0^1 P(R) dR \quad (19)$$

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

式中: TP 表示检测为真的正样本数量, FP 表示检测为真的负样本数量, FN 表示检测为假的正样本数量。 AP 为各类别的检测精度。

浮点运算量和模型参数量是用来衡量模型的复杂程度,即判断是否容易部署移动终端的指标。



图 10 数据集示例

Fig. 10 Examples of datasets

3.4 不同 Inner 损失函数对比实验

ratio 取值范围在 0.5~1.5,为了验证不同 ratio 及

Inner 损失函数对模型检测性能的影响,本文设计了 9 组 Inner 损失函数的对比实验,其中 ratio 分别设置为 0.5、0.67、0.75、1、1.33、1.5,实验结果如表 3 所示。

表 3 不同 Inner 损失函数性能对比

Table 3 Performance comparison of different Inner loss functions

损失函数	ratio	P/%	R/%	mAP@50/%
Inner-ElIoU	0.50	88.7	86.2	91.1
Inner-ElIoU	0.67	91.3	86.0	91.6
Inner-ElIoU	1.00	90.4	85.4	91.3
Inner-ElIoU	1.33	89.7	85.2	90.7
Inner-ElIoU	1.50	91.0	85.5	91.2
Inner-ElIoU	0.75	91.4	86.0	91.7
Inner-CIoU	0.75	89.9	86.1	91.1
Inner-DIoU	0.75	89.2	86.5	90.8
Inner-GIoU	0.75	90.4	85.4	91.1

由表 3 的实验结果可以得出,Inner-ElIoU 作为模型损失函数时性能最佳。当 ratio 取值 0.75 时,P、mAP@50 取得最优值,虽然 R 并不是最优值,但模型总体检测性能最佳。因此选择 Inner-ElIoU 作为模型损失函数,ratio 取值 0.75。

3.5 消融实验

为了分析不同改进模块对整体算法的有效性和合理性,在安全帽和反光衣数据集上设计了 6 组消融实验,所有实验均在相同配置环境和参数设置下进行训练,消融实验结果如表 4 所示。

表 4 消融实验

Table 4 Ablation experiment

Labels	Baseline	+CCFM	+CCFM+CIB	+CCFM+EMA	+CCFM+CIB+EMA	本文模型
P/%	85.3	88.8	89.0	89.3	89.4	91.4
R/%	87.5	86.2	85.1	85.8	85.6	86.0
F1	86.4	87.5	87.0	87.5	87.5	88.6
mAP@50/%	91.2	90.7	90.5	90.8	90.9	91.7
参数量/ 10^6	3.00	1.96	1.56	1.97	1.56	1.56
计算量/GFLOPs	8.1	6.6	5.4	6.6	5.5	5.5
FPS/帧	100.6	106.5	103.4	103.5	89.3	92.6
Size/MB	6.259	4.177	3.430	4.188	3.441	3.442

通过消融实验验证了运用 CIB 模块、CCFM 模块、EMA 注意力机制及 Inner-ElIoU 损失函数实现轻量化检测算法模型的有效性。由表 4 消融实验结果可知,对比原始 YOLOv8n,采用 CCFM 方法重构其颈部网络,能够大幅降低参数量和计算量,分别降低 34.7%和 18.5%,但其检测精度有所降低。在 CCFM 的基础上添加 CIB 模块,相较于

单独添加 CCFM 模块,参数量和计算量分别下降了 20.4%和 18.2%,但检测精度略微下降。而添加 CCFM 模块和 EMA 注意力机制,对比单独添加 CCFM,检测精度略微提高,但参数量提升了 0.01×10^6 。引入 Inner-ElIoU 损失函数后,对比原始 YOLOv8n,其平均检测精度 mAP@50 提高了 0.5%,参数量下降了 48.3%,计算量降低了

32.1%，模型减小了 45.0%。结合以上 4 种改进模块，本文 CCEI-YOLOv8 轻量化检测算法的总体性能均优于单独添加上述模块的检测算法，证明本文改进方法能够有效减少误检、漏检现象，提高对安全帽和反光衣的检测精度，

同时能够完全满足在不同环境和资源有限的设备情况下进行实时检测的需求。6 组消融实验的精确率、召回率、平均精度 mAP@50 曲线如图 11 所示。

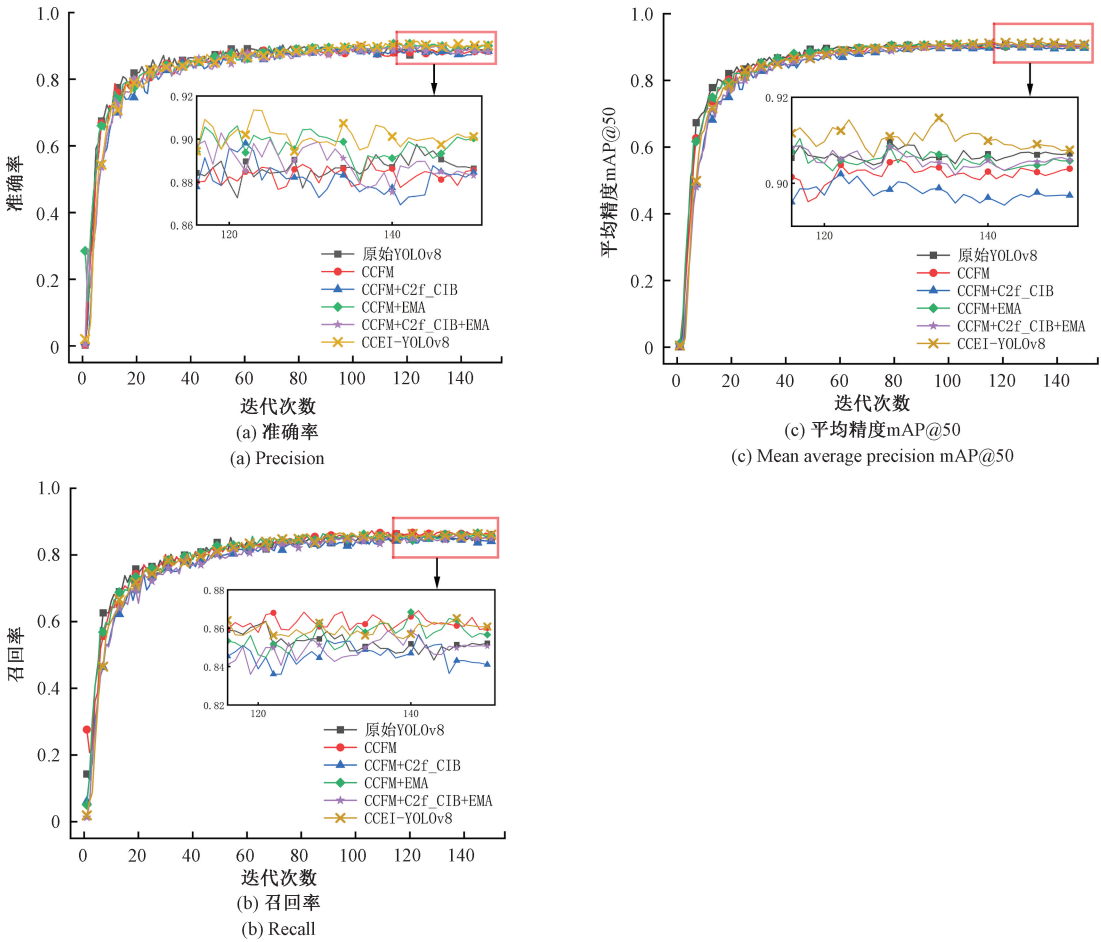


图 11 指标对比
Fig. 11 Comparison of indicators

3.6 对比实验

为了进一步验证 CCEI-YOLOv8 轻量化检测算法在安全帽和反光衣检测中的优劣，本文采用当前主流的目标检测算法 YOLOv3-tiny、YOLOv5、YOLOv6、YOLOv8、

YOLOv9 以及上述部分优秀改进算法进行对比实验。所有算法均在相同配置环境和参数设置下对相同的数据集进行训练，并设置相同参数，以保证对比实验的有效性。对比实验结果如表 5 所示。

表 5 对比实验
Table 5 Comparison experiment

评价指标	P/%	R/%	F1	mAP@50/%	参数量/10 ⁶	计算量/GFLOPs	FPS/帧	Size/MB
YOLOv3-tiny	87.1	80.7	83.8	87.0	9.52	14.3	184.3	18.736
YOLOv5n	88.5	86.0	87.2	90.5	2.50	7.1	94	5.279
YOLOv5s	90.0	85.7	87.8	91.1	7.82	18.7	90	15.613
YOLOv6n	89.4	85.9	87.6	90.7	4.23	11.8	110.0	8.700
YOLOv8n	85.3	87.5	86.4	91.2	3.00	8.1	100.6	6.259
YOLOv8s	88.9	86.1	87.5	91.0	9.83	23.4	97.3	19.514
YOLOv8m	90.6	86.1	88.3	91.6	23.21	67.4	79.4	45.729

续表 5

Continuation table 5

评价指标	P/%	R/%	F1	mAP@50/%	参数量/ 10^6	计算量/GFLOPs	FPS/帧	Size/MB
YOLOv9t	89.1	85.3	87.2	91.1	1.73	6.4	42.2	4.140
文献[10]	88.9	82.4	85.5	89.2	2.35	5.7	86.4	4.891
文献[12]	89.0	84.7	86.8	91.2	4.20	7.2	81.3	8.456
文献[15]	89.8	86.3	88.0	91.6	2.75	11.2	64.9	5.900
文献[27]	88.3	84.3	86.3	90.0	2.53	6.5	89.5	5.246
本文模型	91.4	86.0	88.6	91.7	1.56	5.5	92.6	3.442

由表 5 对比实验结果可知,CCEI-YOLOv8 轻量化检测算法相较于原始 YOLOv8n,在略微损失 FPS 的情况下,其 F1 值提高了 2.2,准确率和平均精度 mAP@50 分别提高 6.1% 和 0.5%,但召回率有所下降。同时,对比原始 YOLOv8n,本文改进算法模型的参数量和计算量分别降低 48.3% 和 32.1%,仅为 1.56×10^6 和 5.5 GFLOPs,减少

了内存占用,加快模型运算速度,且模型大小仅为 3.422 MB,充分证明本文改进算法在轻量化检测水平的优越性,能够在存储空间较小的移动终端和嵌入式设备等资源有限的环境中有效实现项目部署,满足实时监测的要求,具有实际应用意义。其可视化对比如图 12 所示。



图 12 可视化对比

Fig. 12 Comparisons of visualization

对比文献[10]、文献[12]、文献[15]及文献[27]优秀改进算法,本文改进算法模型在安全帽和反光衣的检测精

度及轻量化水平上面均为最优,充分验证了本文改进算法模型的优越性。其可视化对比如图 13 所示。






图 13 文献算法可视化对比

Fig. 13 Comparisons of literature algorithm visualization

4 结 论

CCEI-YOLOv8 轻量化检测算法采用了 CIB 模块优化 YOLOv8n 算法的骨干网络与颈部网络,通过灵活应用深度卷积和点卷积,能够实现更高效地特征提取和特征融合,减少计算冗余,并有助于降低过拟合的风险。结合 RT-DETR 模型思想,重构 YOLOv8 颈部网络形成 CCFM 模块,大幅减少参数数量和计算量达到轻量化,增强了检测算法对不同尺度的特征融合能力。引入 EMA 注意力机制,增强网络通道依赖关系和全局学习能力,从而提高模型适应不同特征的能力。最后,采用 Inner-ElIoU 损失函数,提升回归定位的精确度,确保两者之间的匹配度更高。实验结果表明,每种改进方法在检测性能和轻量化方面均得到提升,改进检测算法模型的准确率、召回率、平均精度 mAP@50 分别达到了 91.4%、86.0%、91.7%,F1 值为 88.6 分,参数量为 1.56×10^6 ,计算量为 5.5 GFLOPs,模型仅为 3.442 MB。

对原始 YOLOv8n 进行轻量化改进,设计了 CCEI-YOLOv8 轻量化检测算法,以大幅降低参数数量和计算量,提高检测精度,并与目前主流的目标检测算法进行对比,拥有更高的检测精度和更少的参数数量与计算量,可更好地在资源有限的移动终端和嵌入式硬件设备中高效项目部署,实现复杂环境中的实时检测。

参考文献

[1] 侯学良,单腾飞,薛靖国. 深度学习的目标检测典型算法及其应用现状分析[J]. 国外电子测量技术, 2022, 41(6): 165-174.
HOU X L, SHAN T F, XUE J G. Analysis of typical target detection algorithm based on deep learning and

its application status [J]. Foreign Electronic Measurement Technology, 2022, 41(6): 165-174.
[2] 韩飞腾,刘永强,房玉东,等. 基于注意力机制的安全帽佩戴状态检测模型[J]. 中国安全生产科学技术, 2024, 20(8): 196-202.
HAN F T, LIU Y Q, FANG Y D, et al. Detection model for wearing status of safety helmet based on attention mechanism[J]. Journal of Safety Science and Technology, 2024, 20(8): 196-202.
[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 defect inspection of power small fittings based on improved R-CNN and double feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 213-220.
[4] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
[5] REN SH Q, HE K M, 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]. European Conference on Computer Vision. Amsterdam, The Netherlands: Springer Cham, 2016: 21-37.
[7] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on

- Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [9] 薛小勇, 何新宇, 姚超修, 等. 基于改进 YOLOv8n 的采掘工作面小目标检测方法[J]. 工矿自动化, 2024, 50(8): 105-111.
- XUE X Y, HE X Y, YAO CH X, et al. Small object detection method for mining face based on improved YOLOv8n[J]. Journal of Mine Automation, 2024, 50(8): 105-111.
- [10] 张国鹏, 周金治, 马光岑, 等. 改进 YOLOv8 的轻量化安全帽佩戴检测算法[J]. 电子测量技术, 2024, 47(17): 147-154.
- ZHANG G P, ZHOU J ZH, MA G C, et al. Lightweight safety helmet wearing detection algorithm of improved YOLOv8[J]. Electronic Measurement Technology, 2024, 47(17): 147-154.
- [11] 许迪, 张淑卿, 葛超. 面向复杂环境的 YOLOv8 安全装备检测[J]. 电子测量技术, 2024, 47(7): 121-129.
- XU D, ZHANG SH Q, GE CH. YOLOv8 security equipment inspection for complex environments[J]. Electronic Measurement Technology, 2024, 47(7): 121-129.
- [12] WANG Z, ZHU Y, JI Z, et al. An efficient YOLOv8-based model with cross-level path aggregation enabling personal protective equipment detection [J]. IEEE Transactions on Industrial Informatics, 2024, 20(11): 13003-13014.
- [13] SONG X, ZHANG T, YI W. An improved YOLOv8 safety helmet wearing detection network[J]. Scientific Reports, 2024, 14(1): 1-14.
- [14] DI B, XIANG L, YANG D Q, et al. MARA-YOLO: An efficient method for multiclass personal protective equipment detection [J]. IEEE Access, 2024, 12: 24866-24878.
- [15] LIN B. Safety helmet detection based on improved YOLOv8[J]. IEEE Access, 2024, 12: 28260-28272.
- [16] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 1571-1580.
- [17] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [18] HUANG S, LI X, JIANG Z, et al. Hyper feature fusion pyramid network for object detection[C]. 2018 IEEE International Conference on Multimedia & Expo Workshops(ICMEW), 2018: 1-6.
- [19] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv preprint arXiv: 2107.08430, 2021.
- [20] FENG C, ZHONG Y, GAO Y, et al. TOOD: Task-aligned one-stage object detection [C]. 2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE Computer Society, 2021: 3490-3499.
- [21] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv: 2405.14458, 2024.
- [22] ZHAO Y, LYU W, XU S, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.
- [23] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574-8586.
- [24] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [25] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence, 2020: 12993-13000.
- [26] 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.
- [27] 韩博, 张婧婧, 鲁子翱. FEV-YOLOv8n: 轻量化安全帽佩戴检测方法[J]. 计算机测量与控制, 2025, 33(1): 69-77, 84.
- HAN B, ZHANG J J, LU Z AO. FEV-YOLOv8n: Lightweight helmet wearing detection methods [J]. Computer Measurement & Control, 2025, 33(1): 69-77, 84.

作者简介

张羽(通信作者), 博士, 副教授, 博士生导师, 主要研究方向为深度学习、可持续城市建设等。

E-mail: zy701@mails.cqjtu.edu.cn

刘皓洋, 硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: 19923878839@163.com