

DOI:10.19651/j.cnki.emt.2415625

面向复杂环境的 YOLOv8 安全装备检测^{*}

许迪 张淑卿 葛超

(华北理工大学电气工程学院 唐山 063210)

摘要:为解决现有安全帽和反光衣检测模型对小目标和复杂天气中目标检测精度低、环境干扰因素大、难以在性能一般移动设备部署等问题,设计实现一种改进 YOLOv8 安全装备检测模型 YOLOv8-DSI。首先,设计基于残差思想和并行空洞卷积的 DR-SPPF 模块,进一步扩大感受野且不损失图像分辨率,显著提升复杂天气检测精度;其次,在特征融合阶段设计结构轻量特征金字塔网络 ST-BiFPN,进一步减小模型参数量,实现高效多尺度特征融合;最后,引入 Inner-ShapeIoU 损失函数,使得边界框回归更加准确,增强检测效果。在自建数据集上,相较于基线模型 mAP50 和 mAP50.95 分别提升了 2.1% 和 4.7%,而模型参数量仅为 2.4 M,计算量仅为 7.3 G,分别降低了 10.9% 和 20.0%。最终将改进模型部署到 Jetson Orin Nano 边缘设备,通过在开发板实际运行证明,改进后模型在复杂场景下有效性和可应用性。

关键词:安全装备检测;目标检测;深度学习;YOLOv8;特征金字塔网络

中图分类号: TP391; TN60 文献标识码: A 国家标准学科分类代码: 520.6040

YOLOv8 security equipment inspection for complex environments

Xu Di Zhang Shuqing Ge Chao

(School of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China)

Abstract: In order to solve the problems of low detection accuracy, large environmental interference factors, and difficult deployment in mobile devices with average performance of the existing detection algorithms for hard hats and reflective clothing on small targets and complex weather, an improved detection algorithm for YOLOv8 safety equipment, YOLOv8-DSI, was designed and implemented. Firstly, the DR-SPPF module based on residual idea and parallel cavity convolution is designed to further expand the receptive field without loss of image resolution, and significantly improve the precision of complex weather detection. Secondly, ST-BiFPN is designed in the feature fusion stage to further reduce the number of model parameters and achieve efficient multi-scale feature fusion. Finally, Inner-ShapeIoU loss function is introduced to make bounding box regression more accurate and enhance the detection effect. Compared with the baseline model mAP50 and MAP50.95, the self-built data set increased by 2.1% and 4.7% respectively, while the model parameter number was only 2.4 M and the calculation amount was only 7.3 G, which decreased by 10.9% and 20.0% respectively. Finally, the improved model was deployed to the edge device of Jetson Orin Nano. The actual operation on the development board proved that the improved model of YOLOv8 was effective and applicable in complex scenarios.

Keywords: safety equipment testing; object detection; deep learning; YOLOv8; characteristic pyramid network

0 引言

施工过程因违规作业造成安全事故占全部事故比例很高,安全帽和反光衣作为至关重要的安全防护装备,广泛用于建筑、电力、制造业和交通运输等领域。实际施工现场常因施工人员贪图便利未佩戴安全帽和反光衣导致严重安全

事故发生。因此,对安全帽和反光衣穿戴进行检测,降低相关安全事故发生率保障人员安全成为研究必要。其次,安全装备检测技术还可为未来智慧工地提供技术支持,为其安全性和智能化发展提供重要保障,推动行业数字化转型和智能化升级^[1]。

传统安全装备检测主要涵盖两种途径:第一种是依赖

收稿日期:2024-03-13

*基金项目:河北省自然科学基金(F2021209006)项目资助

人工巡检来确认安全装备穿戴与记录,该方法耗时耗力,还可能对施工正常运转造成一定干扰和不便;第二种是通过安装传感器实现对安全帽检测,如周圩颖等^[2]在安全帽中安装传感器,获取施工人员是否佩戴安全帽信息。但由于涉及部件繁多,使用与维护成本高昂。同时需建立基站来维持信号稳定,使其在大范围推广使用受到限制,难以得到广泛普及。

传统目标检测模型依赖手工特征提取的方式,其准确性受到明显限制。随着计算机性能显著提升,深度学习模型被广泛用于安全帽佩戴检测任务中。何国立等^[3]提出基于关键点检测和注意力机制的安全装备识别算法,在应对多种人体姿态和不同拍摄角度情况展现适用性,但关于应对遮挡情况效果如何尚未提及。常见模型分为单阶段和二阶段检测模型,二阶段检测模型主要有 Faster-RCNN^[4]等,徐守坤等^[5]基于 Faster RCNN 模型进行改进,运用多尺度训练和引入在线困难样本挖掘方法来检测安全帽。此类模型精度较高,但检测速度较低。单阶段模型主要包括 SSD 和 YOLO^[6-7]系列,储岳中等^[8]对 SSD 模型进行改进,添加自注意力模块计算像素点间关系来提高检测关注度。程换新等^[9]对 YOLOX 网络检测安全装备进行优化,采用 Mosaic 方法进行训练,但在较高准确率前提下,无法在推理速度达到理想平衡。谢国波等^[10]对 YOLOX 模型进行改进检测安全装备,通过优化损失函数提高模型对数据集中类别不平衡适应能力。此类模型检测速度较快,检测精度未达到平衡。

YOLO 模型作为目前热门单阶段模型,其核心策略是将目标检测挑战转化为回归问题形式,并采用一个集成的前沿网络来处理从原始图像的输入到物体精准定位及分类输出整个过程,诸多学者选择在其基础上进行改进。Wang 等^[11]改进 YOLOv3 网络检测反光衣,在算法后处理阶段改进 NMS 缓解密集目标检测漏检问题,但 YOLOv3 网络结构相对复杂,导致部署到边缘端设备面临严峻挑战;YOLOv4 模型^[12]用遗传模型进行超参数优化,提高准确率。李天宇等^[13]采用多尺度池化操作改进空间金字塔池化层,由分层卷积与 scSE 注意力模块组成特征增强模块,提高模型检测精度,但模型参数量较大,同样难以部署。YOLOv5 采用了 CSPDarkNet53+Focus 的结构和引入 C3 模块,提高模型检测精度和速度。候公羽等^[14]提出了 Beta-WIoU 作为边框损失函数,采用动态非单调聚焦机制并引入对锚框特征的计算,提高模型收敛速度;对骨干网络进行重构提高模型检测精度;张学立等^[15]提出 YOLOv5s 改进算法,引入 GhostNet 网络结构中 Ghost 模块,并引入 CA 注意力机制,实现检测算法轻量化,但并未考虑实际生产生活中复杂天气对于检测网络效果影响。YOLOv6^[16]采用基于 RepVGG 的新框架 EfficientRep,比之前框架具有更高并行性,进一步提升目标检测精度。纪超等^[17]基于 YOLOv7 网络,提出多分支深度卷积网络,并将 MIA 机制

结合高效通道注意力机制构建双重注意力机制,实现对安全装备穿戴高效检测。

本文以施工人员是否穿戴安全帽和反光衣为检测对象,由于施工现场环境多变,图像在采集过程中受拍摄角度和环境影响较大,使得图像模糊和目标存在遮挡及尺度较小情况,故提出 YOLOv8-DSI 模型来实现复杂环境下安全帽和反光衣检测。

1) 针对复杂环境下图像中安全帽和反光衣目标模糊难以检测到情况,在 YOLOv8n 主干网络将 SPPF 模块替换为设计的 DR-SPPF 模块,增加网络深度,提高模型学习更复杂特征能力,加强处理不同尺度间特征信息,使模型更好检测到图像中因天气和光照等原因导致模糊安全帽目标。

2) 针对因拍摄角度使得安全帽目标尺寸较小和遮挡情况,将 YOLOv8n 原颈部网络结构替换为设计的 ST-BiFPN 结构,在大幅减少网络参数量情况下,进一步提升网络对不同尺度安全装备目标检测精度。

3) 针对在实际生产中安全装备目标尺度变化较大,且 CIoU 损失函数难以平衡难易样本差异,导致网络产生有害梯度。故替换为 Inner-ShapeIoU 损失函数^[18],通过辅助边框计算损失,更关注边界框自身形状大小,实现网络动态学习,增强模型泛化能力。

1 YOLOv8n 网络架构

YOLO 模型作为单阶段检测代表模型,已经发展到 v8 版本。YOLO 模型将原始图像划分为多个网格,每个网格预测出边界框及其内部物体所属的类别,并使用非极大值抑制模型消除多余重叠率较高的边界框。图 1 为 YOLOv8n 网络结构图,主干网络由 Conv 模块、C2f 模块和 SPPF 模块组成。SPPF 模块主要作用是融合多尺度特征,实现局部和全局特征融合对不同尺寸目标特征信息提取。C2f 模块在精度上有显著提升,但对小目标和遮挡目标检测尚不够精确。

2 YOLOv8-DSI 网络结构

将 YOLO 应用安全帽和反光衣佩戴检测系统时,需要考虑移动端或边缘设备的设备性能和 YOLO 模型大小之间的平衡。故不能选择精确度最高的 YOLOv8x 模型, YOLOv8x 模型检测精度高,但模型很大。故选择 YOLOv8 系列模型最小的 YOLOv8n 来检测穿戴安全装备目标。但 YOLOv8n 存在一些问题,首先因施工现场多为露天场地,受复杂天气影响较大存在拍摄图像分辨率不高或目标模糊等情况;其次, YOLOv8n 使用较多 C2f 模块,虽然提高了目标检测的性能,但使运算速度较低,同时计算复杂度和运算量增加;最后,检测图像由于拍摄角度的问题,存在尺寸较小和遮挡目标,使得 YOLOv8n 对于安全装备佩戴检测会出现漏检和误检情况的发生。

基于以上问题,提出一种改进模型 YOLOv8-DSI,不仅

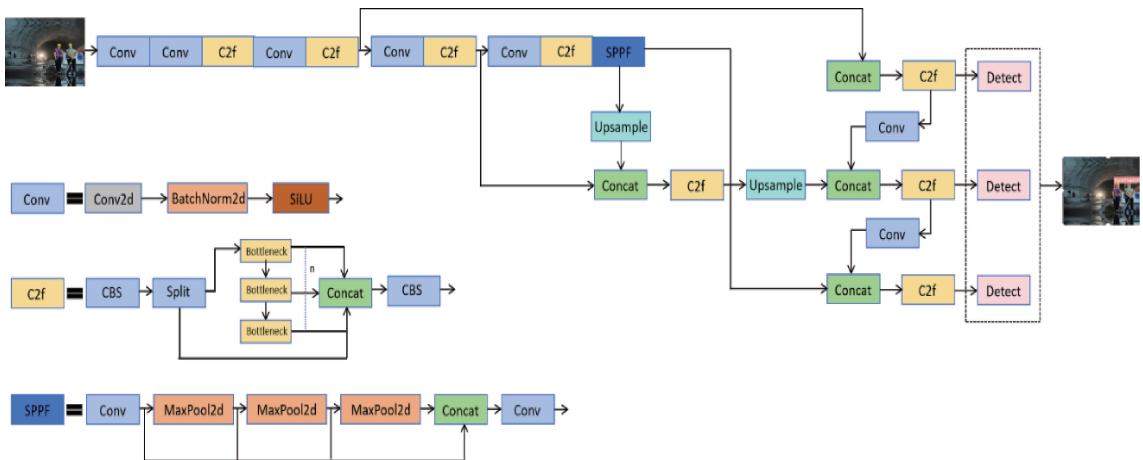


图1 YOLOv8n网络结构图

提高了目标检测精度,而且实现计算量、参数量最小化。

图2为改进后YOLOv8-DSI网络结构图。首先将YOLOv8n主干网络中SPPF模块替换为DR-SPPF模块,使得模型学习到更深层次特征信息,同时并行的空洞卷积模块较好保留图像空间特征,有助于提高模型在复杂天气下检测精度;其次,在YOLOv8n颈部网络引入ST-BiFPN结构,额外增加小尺度检测层获取更多目标特征信息以此加强对小目标和遮挡目标检测能力,在实现模型轻量的同时保证检测精度,使得模型在性能一般的边缘设备部署具有更好优势;最后,引入Inner-ShapeIoU替换CIoU,提升现存方法泛化能力,提高检测框准确性。

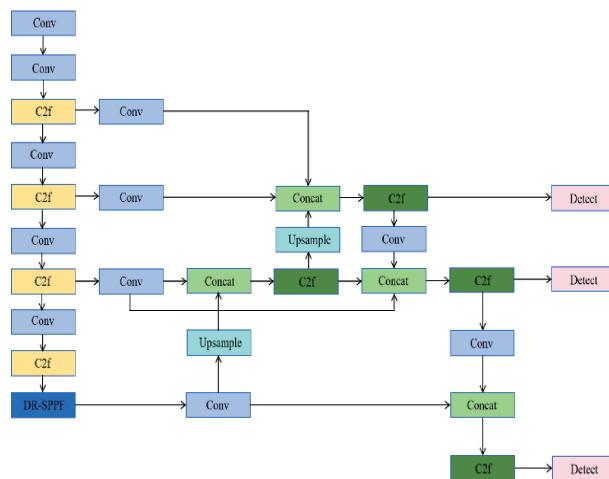


图2 YOLOv8-DSI网络结构图

2.1 DR-SPPF模块

YOLOv8主干网络使用的是SPPF模块,通过一个卷积层将输入特征图降到不同尺度,然后使用不同尺度池化层进行特征提取,这种操作可能会导致一些细节信息丢失;同时SPPF模块将任意大小输入图像缩放到固定大小,并生成固定长度特征向量,这种操作会致使图像分辨率降低使得模型无法较好解决因天气原因导致图像目标模糊

情况。为解决该问题设计了DR-SPPF模块,模块如图3所示,通过并行空洞卷积模块增加网络模型深度去发掘更深层次的细节特征信息;并设计残差防止因层次过深导致模型产生梯度爆炸问题。

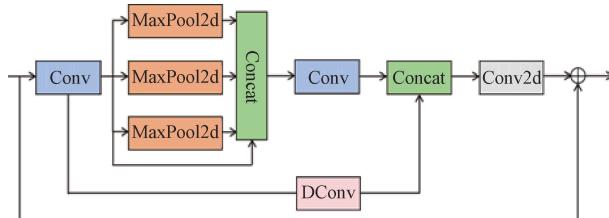


图3 DR-SPPF模块

最大池化可以扩大感受野,但会使空间分辨率降低。并行空洞卷积模块可以使模型进一步扩大感受野,使得模型识别到更多层次的目标信息;空洞卷积模块可以在扩大感受野的同时不丢失分辨率,且保持像素的相对空间位置不变,使得模型更好检测到复杂天气下图像中不清晰目标。

空洞卷积模块其卷积核大小为 3×3 ,步长设置为1,该模块与普通卷积的主要差异体现在膨胀因子 r 的引入上,通过调整膨胀因子 r ,控制卷积核的感受野大小。

表1 膨胀因子大小影响对比

膨胀因子大小	mAP50/%	mAP50-95/%
$r=1$	85.8	61.1
$r=2$	86.0	61.4
$r=5$	85.7	61.2

从表1可看出,膨胀因子 $r=1$ 过小会限制卷积核的感受野范围,模型在捕获全局信息时表现不佳;膨胀因子 $r=5$ 过大致卷积核过于稀疏,影响捕捉一些细节信息。综合考虑下,当膨胀因子 r 设置为2时性能最佳,空洞卷积模块能够达到最佳性能表现。

神经网络每一层分别对应提取不同层次特征信息,而网络越深时,提取到不同层次间信息组合也会越多。但随着网络越深,会遇到梯度爆炸情况,故设计用残差来解决该问题,使得网络的性能也进一步提升。

基于此设计 DR-SPPF 模块在提升少量参数量前提下,显著提升模型检测精度,充分解决在复杂天下情况下施工现场图像分辨率不高和目标模糊所引起模型检测效果不佳情况。

2.2 ST-BiFPN 结构

原始 YOLOv8n 采用的颈部网络为路径聚合网络(pyramid attention network, PANet),其引入一种路径聚合机制,以更好地捕获和整合多尺度信息,并通过采用自顶向下和自底向上的双向融合方式,缩短了各特征层之间的路径。设计目的是解决特征金字塔网络(feature pyramid network, FPN)在处理尺度特征时对于图中中小目标和遮挡目标时的性能问题。

为了使得模型性能得到提升,本文选择采用 BiFPN 代替 PANet。BiFPN^[19]将 P3 至 P7 所有层特征信息进行融合,在 PANet 基础上将输入仅有一条支路且未参与融合的节点进行删除,简化 PANet 模型以此降低计算参数量。BiFPN 对不同层次特征图间采用高效的跨尺度加权连接机制—快速归一融合,如式(1)所示,结构如图 4(a)所示。

$$O = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot I_i \quad (1)$$

其中, i, j 为特征节点输入层个数, $i = j$; ω 为各输入特征层权重; I 为输入特征图。

由于施工人员所处现场比较复杂,其中遮挡物较多且由于拍摄角度问题安全帽和反光衣目标尺度也会出现较小情况。为解决该情况,设计了 ST-BiFPN 对原结构进行优化,去除 BiFPN 结构中 P7 和 P6 大目标检测层,有效降低模型参数量,使得模型更加轻量化;额外添加 P2 小目标检测层,同时将 P2 和 P3 层相连接进行特征融合,在获取到较小目标重点特征信息的同时不引入额外参数量,以此优化模型对于小目标和遮挡检测效果不佳问题。ST-BiFPN 结构如图 4(b)所示。

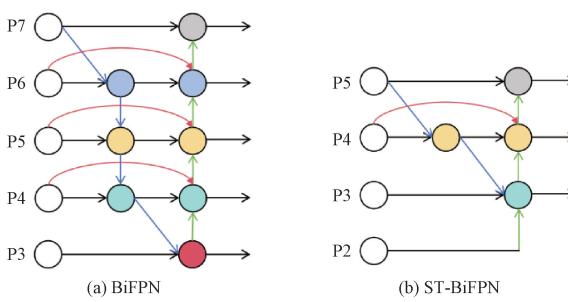


图 4 BiFPN 与 ST-BiFPN 结构图

对 BiFPN 和 ST-BiFPN 进行对比试验以证明改进有效性。

由表 2 中实验数据可知,ST-BiFPN 在降低参数量和计算量的同时,仍能保持较高精度,使得模型检测性能提升,同时模型轻量化,更容易部署到性能一般的移动端和边缘设备。

表 2 性能对比实验

结构	mAP50/%	计算量	参数量/M
BiFPN	84.9	8.2	3.0
ST-BiFPN	85.2	7.0	2.0

2.3 Inner-ShapeIoU

原始 YOLOv8 采用 CIoU Loss,同时考虑重叠面积和中心距离,能很好处理检测框之间重叠以及交错情况,提高模型性能。CIoU Loss 计算式如式(2)所示。

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{C^2} + \alpha\nu \quad (2)$$

其中, ν 用来衡量预测框和目标框之间横纵比例是否一致,利用相对位置和形状来计算损失,忽略固有属性。由于实际劳作中因拍摄角度导致图像中目标尺度变化较大,更应考虑边界框本身形状大小对于检测效果影响,导致 CIoU 无法很好对应相对位置,可能会有一定局限性;同时未考虑难以样本之间平衡性问题,当样本检测难度差异较大时,也会影响模型收敛速度,故 CIoU 在小目标检测中不具备良好识别能力。

为解决上述问题,引入基于辅助边框 Inner-ShapeIoU 损失函数,通过辅助边界框来计算损失,使用较小尺度辅助边界框计算高 IoU 图像数据,使用较大尺度辅助边界框计算低 IoU 图像数据,从而使边界框回归加速收敛使得检测效果更加准确。

图 5 为较小尺寸和较大尺寸下 Inner-ShapeIoU 边框计算示意图,Inner-ShapeIoU 计算公式如式(3)~(16)所示。

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (3)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (4)$$

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

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

$$inter = (\min(b_r^{gt}, b_r) - \max(b_l^{gt}, b_l))^* \\ (\min(b_b^{gt}, b_b) - \max(b_l^{gt}, b_t)) \quad (7)$$

$$union = (w^{gt} \times h^{gt}) \times (ratio)^2 + (w \times h) \times (ratio)^2 - inter \quad (8)$$

$$IoU_{inner} = \frac{inter}{union} \quad (9)$$

$$L_{inner-IoU} = L_{IoU} + IoU - IoU_{inner} \quad (10)$$

$$ww = \frac{2 \times (w^{gt})^{scale}}{(w^{gt})^{scale} + (h^{gt})^{scale}} \quad (11)$$

$$hh = \frac{2 \times (h^{gt})^{scale}}{(w^{gt})^{scale} + (h^{gt})^{scale}} \quad (12)$$

$$disance^{shape} = hh \times (x_c - x_c^{gt})^2/c^2 + ww \times (y_c - y_c^{gt})^2/c^2 \quad (13)$$

$$\Omega^{shape} = \sum_{t=w,h} (1 - e^{-w_t})^\theta, \theta = 4 \quad (14)$$

$$L_{ShapeIoU} = 1 - IoU + disance^{shape} + 0.5 \times \Omega^{shape} \quad (15)$$

$$L_{Inner-ShapeIoU} = L_{ShapeIoU} + IoU - IoU_{inner} \quad (16)$$

其中, $ratio$ 为可调节因子, $scale$ 为尺度因子, 充分平衡数据集中目标尺度变化较大情况; B^{gt} 和 B 分别为目标框和锚框; (x_c, y_c) 为锚框中心点坐标, (x_c^{gt}, y_c^{gt}) 为标注框中心点坐标; ww 和 hh 分别为横向和竖向权重系数, 取值与边界框大小有关。

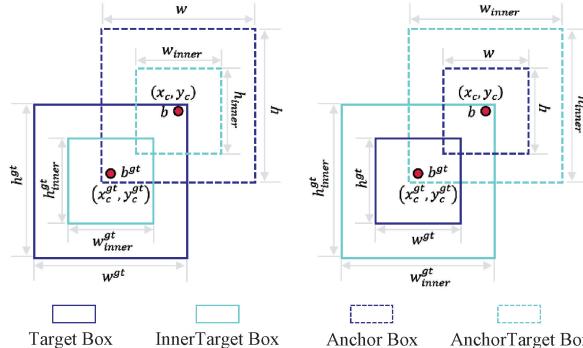


图 5 Inner-ShapeIoU 示意图

与传统 IoU 计算方法相比, Inner-ShapeIoU 通过关注边界框本身不同形状和尺度以及核心部分, 提供对重叠面积更准确判断, 通过可调节尺度因子动态调节边框以此实现对尺度变化较大检测目标准确检测, 更好检测到容易忽略的小目标, 使得模型具有较强泛化能力。

3 实验结果与分析

3.1 数据集

本文从网络选取符合施工现场图像, 通过 labelimg 工具对选取图像进行标注, 其中有四种标识, 分别为安全帽、未佩戴安全帽、反光衣和未穿戴反光衣。其次, 为提高数据集场景复杂性, 通过基于 python 下 imgaug 库进行数据增强操作, 随机引入下雨、下雪、雾化天气效果增强, 引入曝光、高斯模糊、旋转和缩小基础图像增强, 可用于生成具有各种天气效果和基础图像变换的增强图像, 组成自建数据集。数据集含 11 744 张图像, 按照 8 : 2 比例划分为训练集和验证集。

3.2 实验环境

模型开发语言为 Python, 编译环境 Python 3.8.0, 深度学习框架 Pytorch 1.11.0, CUDA 版本 11.3。实验在 Windows 10 操作系统中进行, CPU 选用 Intel (R)

Xeon(R) Platinum 8255C CPU @ 2.50 GHz, GPU 选用 NVIDIA RTX 3080, 16 G 显存。

训练过程中根据数据集训练效果对参数进行微调, 以达到整个网络最佳检测效果, 优化器选择 SGD, 在前 95% epoch 中采取 Mosaic 数据增强, 表 3 为训练具体参数:

表 3 训练参数

参数	参数值
Epoch	200
Image input	640×640
Momentum	0.937
Weight decay	0.000 5
Learn rate	0.01
Batch size	16

通过观察模型训练过程中损失曲线, 可发现训练次数为 200 时模型趋于收敛, 已达到理想性能水平, 进一步增加训练次数不会显著提升模型性能; 同时考虑数据集大小和显存限制, 经过实验, 保证训练稳定性的前提下 Batch size 为 16 可获得良好训练效果, 使得设备性能同训练收敛速度及效果达到平衡。

3.3 评估指标

为评估 YOLOv8-DSI 模型性能和对安全装备检测准确性, 采用均值平均精度(mAP)、计算量(GFLOPs)、模型参数量(Params)、帧率(FPS)作为模型性能评估指标。在计算 mAP 之前, 首先需要计算准确率(P)和召回率(R), P 和 R 计算式分别如式(17)、(18)所示。

$$P = \frac{TP}{TP + FP} \quad (17)$$

$$R = \frac{TP}{TP + FN} \quad (18)$$

目标检测中 mAP 是最常见评价指标之一, 用于衡量模型在多个类别上的平均性能指标, 计算公式如式(19)所示。

$$mAP = \frac{\sum_{i=1}^n \int_0^1 P(R) dR}{n} \quad (19)$$

其中, n 为数据集图像总张数。

计算量(GFLOPs)为每秒浮点运算次数, 用来衡量计算机系统性能模型参数量(Params)即网络模型需要训练参数总数, 用于衡量模型复杂度。帧率(FPS)即每秒钟可以传输或处理图像或视频帧数, 其大小不仅与网络结构有关, 还与实验设备中处理器性能、内存大小等有关。

3.4 消融实验

为验证模型改进有效性, 消融实验结果如表 4 所示, 其中 YOLOv8n 为原始模型; YOLOv8n_D 是在主干网络中添加 DR-SPPF 模块; YOLOv8n_S 是在 YOLOv8n 颈部网络引入 ST-BiFPN 结构; YOLOv8n_I 是将 YOLOv8 中

CIoU 损失函数替换为 Inner-ShapeIoU 损失函数; Ours 是 YOLOv8-DSI 模型。

表 4 消融实验

模型	DR-SPPF	ST-BiFPN	Inner-ShapeIoU	mAP50/%	mAP50-95/%	计算量	参数量/M	帧率
YOLOv8n				84.7	58.1	8.2	3.0	102
YOLOv8n_D	✓			86.0	61.4	8.5	3.4	98
YOLOv8n_S		✓		85.2	60.7	7.0	2.0	99
YOLOv8n_I			✓	85.3	60.1	8.2	3.0	104
YOLOv8n_DS	✓	✓		86.3	62.1	7.3	2.4	96
Ours	✓	✓	✓	86.8	62.7	7.3	2.4	101

如表 4 所示,对 YOLOv8n 网络结构进行改进后提高检测精度,显著降低模型计算量和参数量。引入 ST-BiFPN 结构在不损失模型精度情况下,还会大幅减少模型计算量;引入 DR-SPPF 模块和 ST-BiFPN 结构显著降低模型参数量和计算量的同时,进一步提升检测精度。上述改进与 YOLOv8n 模型相结合,使得模型计算量减小,仅为 7.3 G,降低了 10.9%,改进模型在满足计算复杂度降低情况下检测精度还得到了提升。

3.5 鲁棒性对比分析

为验证模型对于不同天气下检测鲁棒性,用 YOLOv8n 模型和改进后 YOLOv8-DSI 模型分别对正常天气和复杂天气下图像目标进行检测。其中 Z 和 F 分别表示正常天气和复杂天气,YOLOv8-DSI 为改进后模型,结果如图 6 所示。

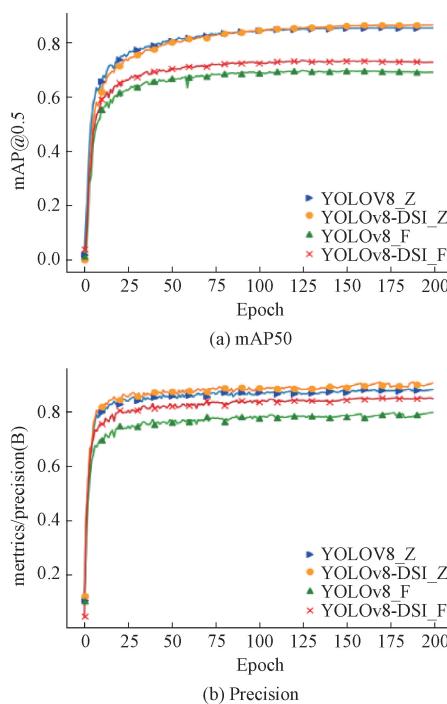


图 6 原模型与改进模型鲁棒性对比图

由图 6(a)可看出,在正常天气下 YOLOv8-DSI 模型比改进前模型 mAP @ 0.5 提升 1.2%;在复杂天气下

YOLOv8-DSI 模型比改进前模型 mAP@0.5 提升 3.7%。由图 6(b)可看出,YOLOv8-DSI 模型相较于改进前模型在正常和复杂天气中 P 都有所提升。证实改进后模型在复杂天气下有较好鲁棒性,能够保持稳定和可靠性能。

为直观展示检测效果,选取不同天气图像进行检测。其中,左侧为改进前模型检测效果,右侧为 YOLOv8-DSI 模型检测效果,效果如图 7 所示。

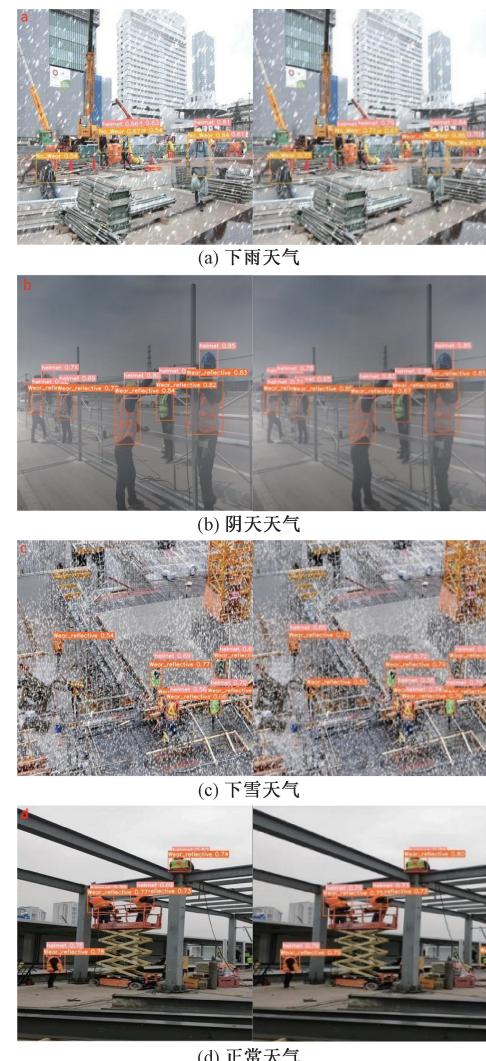


图 7 不同复杂天气下检测对比图

图7(a)为下雨天气图像,改进前模型未检测到中间穿戴反光衣目标,改进后模型可检测到该目标。图7(b)为阴天天气图像且存在较多遮挡目标,因光照等明暗不一背景下,改进前模型未检测到远处遮挡中佩戴安全帽目标,改进后模型可有效检测。图7(c)为下雪天气图像,原模型未识别到遮挡目标,改进模型发现更多不同层次特征信息,可有效检测到复杂天气下遮挡目标。图7(d)为正常天气图像,改进前算法未能检测到右侧穿戴反光衣小目标,改进后算法能准确识别该目标。

3.6 目标检测模型对比分析

为进一步证实模型改进有效性,将其与现阶段主流目标检测模型进行对比试验。其中训练参数和实验环境相同,分别对mAP、GFLOPs、参数量和FPS进行比较以证明改进后模型有效性。

从表5可以看出,改进后模型在保证精度前提下,降低模型参数量和计算量。mAP分别提升13.4%、8.6%、8.0%、6.2%、4.4%、4.0%。YOLOv4-tiny模型FPS较高,但模型精度比YOLOv8-DSI降低8.0%;YOLOv5n参数量和计算量较少,但模型精度比YOLOv8-DSI降低6.2%。

表5 主流目标检测模型对比

模型	mAP50/%	计算量	参数量/M	帧率
SSD	73.4	267.5	42.8	57
YOLOv3	78.2	282	103.7	51
YOLOv4-tiny	78.6	16.4	10.6	108
YOLOv5n	80.6	7.2	2.6	99
YOLOv6	82.4	11.8	4.2	95
YOLOv7-tiny	82.8	14.2	10.4	101
YOLOv8n	84.7	8.2	3.0	102
YOLOv8-DSI	86.8	7.3	2.4	101

实验结果表明,YOLOv8-DSI模型以较小模型参数量和计算量实现显著高精度检测效果,该模型在性能一般移动端和边缘设备上部署更为便利。

3.7 特征图可视化分析

YOLOv8n和YOLOv8-DSI模型在自建数据集检测效果如图8所示,图8左侧为原模型检测效果图,图8右侧为YOLOv8-DSI模型检测效果图。

图8(a)中改进前模型未能检测到左下角复杂天气情况下佩戴安全帽和未穿戴反光衣目标,改进后模型可检测到;图8(b)改进前模型未能检测到穿戴反光衣较小目标,改进后模型可检测到;图8(c)中改进前模型未能检测到网格后遮挡施工人员穿戴安全装备情况,而改进后模型检测到。本文改进后模型较改进前模型能较好识别复杂天气下目标、小目标和遮挡目标,证实本文改进模型检测有效性。



图8 目标检测效果图

3.8 移动端部署

Jetson Orin Nano是Nvidia新推出的边缘计算设备,是基于GPU处理器的嵌入式开发板,拥有4GB内存。将本文所设计的安全装备检测模型部署到该边缘设备上能够正常运行。Jetson Orin Nano实物如图9所示。

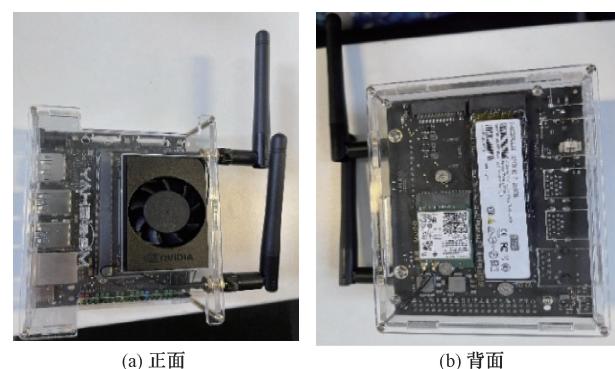


图9 Jetson Orin Nano实物图

为验证模型在边缘设备上的实际表现,选择参数量较少的YOLOv5n、YOLOv8n和YOLOv8-DSI模型分别部署到设备上进行对比实验,随机选择验证集200张图像进行测试,部分检测效果图如图10所示。



图 10 边缘设备检测效果

图 10(a) 分别为 YOLOv5n 和 YOLOv8-DSI 检测效果图, 第 1 张图像右下角施工人员未穿戴反光衣未能识别, 改进后模型实现了准确识别。图 10(b) 分别为 YOLOv8n 和 YOLOv8-DSI 检测效果图, 第 1 张图像施工人员未穿戴反光衣不能识别, 且安全帽识别置信度较低, 改进后模型可实现准确识别且置信度较高。通过在 Jetson Orin Nano 对比实验可看出, YOLOv8-DSI 模型检测效果得到提升, 同时在 TensorRT 加速情况下检测速度达到 48 帧/s, 满足实时检测需要。故 YOLOv8-DSI 模型可部署到性能一般边缘设备且检测效果良好, 对于复杂天气下遮挡和小目标的安全装备有较好识别能力, 具有可应用性。

4 结束语

YOLOv8-DSI 模型首先设计 DR-SPPF 模块更好处理最深特征层, 获得更丰富语义特征和更重要特征信息, 从而提高复杂环境中安全装备佩戴检测精度; 其次设计结构轻量特征金字塔网络, 大大减少参数量和计算量, 提高模型运行效率和降低检测设备部署难度; 最后利用 Inner-ShapeIoU 替换 CIoU 作为损失函数, 更加注重边界框本身不同大小形状来使用辅助边框计算损失, 有效提高模型检测准确度。

在自建数据集上进行测试和比较, 通过消融实验, 证实各部分改进有效性, YOLOv8-DSI 模型在平均精度和计算量等指标优于现主流目标检测模型, 复杂场景下遮挡和小目标也能准确检测到。YOLOv8-DSI 模型在具有较高检测精度同时还降低计算量和参数量, 解决部署检测系统对高性能要求, 使得安全帽和反光衣佩戴检测系统能更好部署到性能一般移动端和边缘设备。为智慧工地提供安全监控, 保障施工现场安全与施工效率, 推动未来智慧工地和智能制造等领域的创新与发展。

参考文献

- [1] 王宇向, 王贞, 吴斌, 等. 智慧工地的安全帽佩戴检测模型研究综述[J]. 武汉理工大学学报, 2021, 43(10): 56-62.
- [2] 周圩颖, 徐楠, 王辉, 等. 智能安全帽及其管控平台设计[J]. 物联网技术, 2023, 13(7): 98-100.
- [3] 何国立, 齐冬莲, 闫云凤. 一种基于关键点检测和注意力机制的违规着装识别算法及其应用[J]. 中国电机工程学报, 2022, 42(5): 1826-1837.
- [4] REN S, 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.
- [5] 徐守坤, 王雅如, 顾玉宛, 等. 基于改进 Faster RCNN 的安全帽佩戴检测研究[J]. 计算机应用研究, 2020, 37(3): 901-905.
- [6] GE Z, LIU S, WANG F, et al. Yolox: Exceeding yolo series in 2021 [J]. ArXiv Preprint, 2021, ArXiv:2107.08430.
- [7] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [8] 储岳中, 黄勇, 张学锋, 等. 基于自注意力的 SSD 图像目标检测模型[J]. 华中科技大学学报(自然科学版), 2020, 48(9): 70-75.
- [9] 程换新, 蒋泽芹, 程力, 等. 基于改进 YOLOX-S 的安全帽反光衣检测算法[J]. 电子测量技术, 2022, 45(6): 130-135.
- [10] 谢国波, 谢建辉, 林志毅, 等. 基于 CT-YOLOX 的反光衣与安全帽检测模型[J]. 国外电子测量技术, 2023,

- 42(10): 51-58.
- [11] WANG S, HAI X, CAO Y. Reflective safety clothes wearing detection in hydraulic engineering using YOLOv3-CCD[J]. Asian Journal of Research in Computer Science, 2023, 15(2): 11-24.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv:2004.10934.
- [13] 李天宇,吴浩,毛艳玲,等.改进YOLOv4的安全帽佩戴检测方法[J].计算机工程与设计,2023,44(8):2374-2381.
- [14] 侯公羽,陈钦煌,杨振华,等.基于改进YOLOv5的安全帽检测模型[J/OL].工程科学学报,1-15[2023-11-27].
- [15] 张学立,贾新春,王美刚,等.安全帽与反光衣的轻量化检测:改进YOLOv5s的算法[J].计算机工程与应用,2024,60(1): 104-109.
- [16] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications[J]. ArXiv Preprint, 2022, ArXiv:2209.02976.
- [17] 纪超,侯威,高鸣江,等.基于MBDC和双重注意力的变电站人员穿戴检测[J].电子测量与仪器学报,2023,37(6): 247-255.
- [18] ZHANG H, XU C, ZHANG S. Inneriou: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv Preprint, 2023, ArXiv:2311.02877.
- [19] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.

作者简介

许迪,硕士研究生,主要研究方向为深度学习、目标检测。

E-mail:xudi19990102@163.com

张淑卿(通信作者),副教授,硕士生导师,主要研究方向为深度学习、复杂系统建模与控制。

E-mail:88638696@qq.com

葛超,教授,硕士生导师,主要研究方向为网络控制系统稳定性分析、多智能体系统建模与控制。