

文章编号 1004-924X(2025)12-1984-15

改进 YOLOv8n 的复杂环境下垃圾轻量化检测

孙世政^{1*}, 何玲玲¹, 郑 帅², 何泽银¹

(1. 重庆交通大学 机电与车辆工程学院, 重庆 400074;

2. 重庆交通大学 航运与船舶工程学院, 重庆 400074)

摘要:针对复杂环境下垃圾检测模型参数量大以及存在误检和漏检等问题,本文提出了基于改进 YOLOv8n 的轻量化垃圾检测模型。首先,提出一种 MobileNet V3_ECA 轻量级网络结构作为 YOLOv8n 的骨干网络,提升模型对垃圾特征区域的表达能力,同时减少模型参数量;其次,在骨干网络引入上下文锚点注意力机制,增强模型对垃圾特征的提取能力;然后,在颈部网络采用全维动态卷积替换标准卷积,细化局部特征映射,实现垃圾局部细粒度特征的融合能力;最后,采用 WIoU v3 边界损失函数提升网络边界框回归性能。在自建复杂背景下的垃圾数据集进行模型验证实验,改进后模型相比原 YOLOv8n, mAP@0.5 提升了 1.1%, 检测速度 FPS 提高 11.7%, 参数量 Params、模型大小 Size 和浮点运算量 FLOPs 分别降低了 70.8%, 66.1% 和 70.7%。实验结果表明,本文改进模型能有效提升检测精度并显著降低模型复杂度,对模型部署与应用至边缘端检测装备具有重要的工程意义。

关键词:垃圾检测;轻量化;MobileNet V3_ECA;YOLOv8n;深度学习

中图分类号: TP391.41 **文献标识码:** A

doi: 10.37188/OPE.20253312.1984

CSTR: 32169.14.OPE.20253312.1984

Improved lightweight garbage detection method for YOLOv8n in complex environments

SUN Shizheng^{1*}, HE Lingling¹, ZHENG Shuai², HE Zeyin¹

(1. School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University,
Chongqing 400074, China;

2. School of Shipping and Naval Architecture, Chongqing Jiaotong University,
Chongqing 400074, China)

* Corresponding author, E-mail: ssz091011@163.com

Abstract: To address the issues of a large number of parameters and false or missed detections by garbage-detection models in complex environments, this paper proposed a lightweight garbage-detection model based on an improved YOLOv8n. First, a lightweight network structure, MobileNet V3_ECA, was introduced as the backbone of YOLOv8n, which enhanced the model's ability to represent garbage-feature regions and reduced the model's parameter count. Second, the Context Anchor Attention (CAA) mecha-

收稿日期: 2024-12-04; 修订日期: 2025-02-22.

基金项目: 重庆市技术创新与应用发展专项重大项目 (No. CSTB2023TIAD-STX0016); 重庆市自然科学基金创新发展联合基金项目 (No. CSTB2023NSCQ-LZX0081); 重庆市教委科学技术研究项目 (No. KJZD-K202200705)

nism was integrated into the backbone to strengthen the extraction of garbage-related features. Next, Omni-Dimensional Dynamic Convolution (ODConv) replaced the standard convolutions in the neck network, refining local feature mapping and enabling the fusion of fine-grained local garbage features. Finally, the Wise Intersection over Union (WIoU v3) bounding-box loss function was adopted to improve the regression performance of the network's bounding boxes. Compared with the original YOLOv8n, the improved model is improved by 1.1% in mAP@0.5, the detection speed is increased by 11.7%, and the parameter Params, model size and floating-point operation FLOPs are reduced by 70.8%, 66.1% and 70.7%, respectively. Experimental results demonstrate that the improved model can effectively improve the detection accuracy and significantly reduce the complexity of the model, which has important engineering significance for the deployment and application of the model to the edge detection equipment.

Key words: garbage detection; lightweight; MobileNet V3_ECA; YOLOv8n; deep learning

1 引言

垃圾检测与分类是实现资源循环利用、减少环境污染和保护人类健康的重要措施。垃圾多处于复杂非结构化场景下,即包含多种元素、光照变化和不规则结构的场景,传统的垃圾检测与分类方式耗费人力和物力,危害身体健康^[1]。基于深度学习的目标检测技术逐渐成为垃圾检测领域的主流选择,尤其是一阶段检测方法中 YOLO 系列模型,具有结构简单、高效检测的特点,被广泛应用于边缘端实时检测装备。

在边缘端设备部署垃圾目标检测模型时,需要对模型进行轻量化,确保满足实际应用场景下垃圾检测的实时性。国内外学者基于机器视觉技术或深度学习技术,在解决目标检测模型在边缘端设备的部署问题方面取得了一定的进展。罗志聪等^[2]使用基于层自适应幅度的剪枝修剪模型,实现基于 YOLOv8 的轻量化百香果检测,但检测精度有一定损失;张新月等^[3]应用 Vanillanet 轻量化网络结构替换 YOLOv8n 的骨干特征提取网络,降低了模型的复杂程度,但检测精度降低 1.5%;黄丹丹等^[4]基于 YOLOv5l 提出轻量化改进模型,引入 FasterNet 网络结构与 C3 网络结构融合,降低模型参数量,但在轻量化方面还有待改进;梁礼明等^[5]提出基于 YOLOv7-tiny 的轻量化改进模型,将 GhostConv 卷积模块引入到骨干网络,降低模型参数量和浮点运算量;Zeng T 等^[6]提出基于 YOLOv5s 的轻量化番茄检测算法,通过重构主干网络、通道剪枝和超参数优化,提高检测精度并减少计算量;周颖等^[7]提出融合多尺度特征

与注意力机制改进 YOLOv8n,设计可形变幽灵卷积模块,优化特征提取并降低计算复杂度,提高了检测精度,浮点运算量增加了 34.31%;蔡逢煌等^[8]引入通道注意力机制 CA 改进 MobileNet V3 的反转残差块,有效降低 YOLOv5s 的模型参数量,但浮点运算量显著增加;林珊玲等^[9]基于 YOLOv8n 提出融合全局信息与双域注意力机制的轻量化方法,提升小目标检测能力与识别精度,同时参数量和运算量降低 6.6% 和 3.7%。

尽管现有研究在目标检测模型的轻量化方面取得了显著进展,但模型轻量化与检测精度之间未能得到充分平衡。此外,目前的研究大多聚焦于单一背景下的垃圾目标检测,忽视了多样化背景环境给模型性能带来的挑战。因此,本文提出一种轻量化模型 MCO-YOLOv8n 用于复杂场景下的垃圾检测,结合 Taco 数据集^[10]与人工采集图片建立背景环境多样化的数据集,其中包含 2742 张存在垃圾的实际生活场景图片,将改进模型在自建数据集上进行验证实验,实现在垃圾目标检测模型的轻量化与高精度检测之间找到更合理的平衡,有利于模型在边缘端设备的部署与应用。本文主要研究工作如下:

(1) 基于高效通道注意力机制^[11](Efficient Channel Attention, ECA)提出一种轻量级网络结构 MobileNet V3_ECA^[12],并将该结构引入骨干网络,提升模型对垃圾目标的表达能力同时显著降低模型复杂度。

(2) 引入上下文锚点注意力^[13](Context Anchor Attention, CAA)模块嵌入骨干网络,增强模型对垃圾特征的提取能力。

(3)引入全维动态卷积^[14](Omni-Dimensional Dynamic Convolution, ODCnv)替换颈部网络的标准卷积,增强网络对小目标特征的融合能力。

(4)替换CIoU损失函数为WIoU v3^[15]损失函数,提升网络边界框回归性能和垃圾目标检测效果。

2 YOLOv8n 网络结构

YOLOv8相较于其他YOLO系列目标检测模型^[16-17],在检测精度和检测速度上更具优势,特别是在复杂场景下的多目标垃圾检测任务中,YOLOv8通过自适应锚框和多尺度特征融合机制,能够有效提升检测性能,增强对不同尺度目标的识别能力。YOLOv8包括n,s,m,l,x五个尺寸大小不同的模型,模型的深度和宽度按照顺序依次增加,检测精度也随之提升,但训练和检测所花费的时间也增多。因此,为更好平衡模型轻量化和目标检测精度,本文选用YOLOv8n作为基准模型。

YOLOv8n的网络结构包括输入端Input、骨

干网络Backbone、颈部网络Neck和检测头,其模型结构如图1所示^[18]。输入端进行Mosaic数据增强以及自适应图片缩放,增强模型鲁棒性,简化模型复杂度,提升检测精度。YOLOv8n采用CSPDarkNet结构作为骨干网络,用于图像的特征提取,采用梯度流更为丰富的C2f模块作为提取特征的主要模块,SPPF模块用于提取不同感受野特征,提升网络对不同尺度目标的适应性。颈部网络采用路径聚合网络(Path Aggregation Network, PAN)结构,增强网络的特征融合能力,YOLOv8n是一种无锚框检测模型,检测头部分使用了主流的解耦头结构,这种结构只需对不同尺度特征图的目标中心点和宽高进行回归,极大地减少耗时,精确地获取大、中、小尺寸目标物体的分类和位置信息。

尽管YOLOv8n模型在目标检测速度和精度方面表现出色,但在复杂场景时仍存在误检和漏检问题。在卷积神经网络进行特征提取时,部分目标可能会由于其他目标或背景杂物的遮挡,导




图1 YOLOv8n网络结构

Fig. 1 YOLOv8n network structure

致在深层次特征提取时未能充分捕捉被遮挡目标。此外,由于小目标的像素较少,在卷积过程中图像分辨率降低,特征信息也随之减弱。特征融合过程中部分信息的丢失进一步加剧目标检测模型误检、漏检的问题,最终影响复杂场景下垃圾目标的检测效果。

3 改进 YOLOv8n 垃圾目标检测模型

为实现复杂背景环境下垃圾检测模型的轻量化,同时提升目标检测精度,改善目标检测模型的误检、漏检问题,本文对 YOLOv8n 模型结构进行改进。首先,将改进后的 MobileNet

V3_ECA 结构作为 YOLOv8n 的骨干网络,通过引入高效的 ECA 模块替换 MobileNet V3-Small 结构中的 SE 模块,改进后的 Bneck_ECA 模块进行垃圾目标的特征提取,实现模型轻量化与检测精度之间的平衡;其次在骨干网络中引入上下文锚点注意力机制 CAA,捕获远程上下文信息,增强模型对目标特征区域的感知,减少遮挡现象导致的误检与漏检问题,提升垃圾目标检测精度;然后引入全维动态卷积 ODConv 替换颈部网络的标准卷积 Conv,增强对小目标、遮挡目标垃圾特征的融合能力,提升模型的检测精度;最后,采用 WIoU v3 损失函数替代 CIoU 损失函数,提高模型收敛速度和检测精度。改进后的 MCO-YOLOv8n 网络结构如图 2 所示。




图 2 MCO-YOLOv8n 网络结构

Fig. 2 MCO-YOLOv8n network structure

3.1 MobileNet V3轻量级网络

MobileNet V3^[19]是一种轻量级卷积神经网络架构,常应用于移动设备和嵌入式设备的计算机视觉任务。该模型分为Large和Small两种,本研究选用MobileNet V3-Small,其特点是参数量少、运算量小,并提供高性能和低延迟的模型,适用于资源有限的场景。

表 1 MobileNet V3-Small网络结构

Tab. 1 MobileNet V3-Small network structure

操作	输入 通道	输入大小	激活 函数	SE
Conv2d, 3×3	3	224×224	HS	—
Bneck, 3×3	16	112×112	RE	✓
Bneck, 3×3	16	56×56	RE	—
Bneck, 3×3	24	28×28	RE	✓
Bneck, 5×5	24	28×28	HS	✓
Bneck, 5×5	40	14×14	HS	✓
Bneck, 5×5	40	14×14	HS	✓
Bneck, 5×5	40	14×14	HS	✓
Bneck, 5×5	48	14×14	HS	✓
Bneck, 5×5	48	14×14	HS	✓
Bneck, 5×5	96	7×7	HS	✓
Bneck, 5×5	96	7×7	HS	✓
Conv2d, 1×1	96	7×7	HS	✓
Pool, 7×7	576	7×7	—	—
Conv2d, 1×1 , NBN	576	1×1	HS	—
Conv2d, 1×1 , NBN	1 024	1×1	—	—

MobileNet V3模型沿用了MobileNet V1的深度可分离卷积(Depthwise Separable Convolution, DWConv)模块和MobileNet V2中具有线性瓶颈的残差结构,并在此基础上做了更新改进,提升检测精度与速度。MobileNet V3-Small的网络结构如表1所示,其中Conv表示普通卷积,HS表示Hard-Swish激活函数,RE表示ReLU激活函数,Pool表示池化层,BN(Batch Normalization, BN)表示批量归一化,NBN(No Batch Normalization, NBN)表示不使用批量归一化,Bneck表示Bottleneck模块。

Bneck是MobileNet V3的核心模块,主要实现了通道可分离卷积、压缩与激励网络^[20](Squeeze-and-Excitation Networks, SE)和残差连接,其结构如图3所示。首先使用 1×1 普通卷

积丰富特征表达能力,其次使用 3×3 深度可分离卷积减少模型参数量和浮点运算量,然后在倒残差结构中引入SE增强网络的特征表达能力,最后使用 1×1 普通卷积将通道维度恢复到最小值,进一步简化模型复杂度。




图 3 Bneck 模块

Fig. 3 Bneck module

SE模块通过全局平均池化操作在每个通道上进行压缩,然后利用多层感知机结构生成通道注意力权重,在这过程中SE模块通过降维控制模型复杂度,但降维通常会削弱通道注意力的准确性。

为实现模型轻量化与检测精度之间的平衡,本文引入ECA模块替代SE模块,该模块通过对每个通道的特征图进行加权处理来引入通道注意力,旨在降低浮点运算量和模型参数量的同时确保优异的性能表现。与其他注意力机制相比,ECA模块不依赖全局池化和降维操作,因此能够在保持较高检测精度的同时提高计算效率。ECA模块凭借其轻量级特性,能够在MobileNetV3网络中实现更高效的特征提取。

ECA模块的结构如图4所示,首先ECA模块在没有降维的前提下对每个通道进行全局平均池化(Global Average Pool, GAP),将大小为 $C \times H \times W$ (C 表示特征图通道数、 H 表示特征图的高、 W 表示特征图的宽)转化为 $1 \times 1 \times C$;其次使用卷积核大小为 k 的一维卷积操作,实现局部




图 4 ECA 模块

Fig. 4 ECA module

通道之间的跨通道交互;然后通过 Sigmoid 激活函数得到各个通道的权重;最后将权重与原始输入特征图对应元素相乘,得到最终输出特征图。这种结构既保留了输入特征图的空间结构信息,又通过增强或抑制特定通道的信息来优化模型的特征表示能力,从而提高了模型的性能和效率。

3.2 CAA 注意力机制

在复杂场景下的垃圾检测任务中,检测目标之间的尺度大小不一,且背景噪声干扰较强。为进一步提升模型对目标的定位能力,引入上下文锚点注意力机制 CAA,该机制通过捕捉远距离的上下文信息来增强中心特征的特征,减少误检与漏检现象。如图 5 所示,该机制的实现分为三个关键步骤:首先,通过平均池化(Average Pooling, AvgPool)和常规卷积操作来提取局部特征;随后,采用两层深度可分离卷积 DWConv 来捕获长距离依赖关系,进一步实现模型的轻量化设计;最后,生成注意力权重图以提升特征表示能力。CAA 的核心在于增强模型对长距离依赖信息的捕获,从而在复杂环境下的垃圾检测任务中提高检测性能。



图 5 CAA 注意力机制

Fig. 5 Context Anchor Attention(CAA) mechanism

在 YOLOv8n 模型的骨干网络中引入 CAA 注意力机制,能够显著提升模型对多尺度目标的识别和定位精度,且计算成本几乎不变。这一优化不仅增强了模型在复杂环境中目标检测的鲁棒性,还提高了整体检测性能。具体而言,CAA 注意力机制通过捕捉长距离的上下文信息,增强垃圾目标特征的表达能力,使得模型在面对不同大小和形状的目标时展现出更强的适应性。

3.3 全维动态卷积 ODConv

在复杂非结构化场景下,提高模型垃圾目标检测性能的关键在于抑制杂乱背景信息的干扰,使模型关注不同尺寸、形状的垃圾目标特征,并有效融合多尺度的目标特征。全维动态卷积 ODConv 是通过并行策略,利用多维注意力机制在卷积核的四个维度上进行学习,既考

虑了输入和输出通道的维度,也兼顾了空间维度以及卷积核的形状和尺寸。这种方法能够增强模型对垃圾目标特征的关注,从而提高识别的准确率。

全维动态卷积 ODConv 的结构如图 6 所示。首先,输入特征 x 通过全局平均池化层 GAP 被压缩为一个长度为 c_m 的特征向量。接着,该特征向量经过一个全连接层(Fully Connected Layer, FC)和修正线性单元 ReLU 处理,其中 FC 层以 1/16 的压缩率将特征向量映射到低维空间,从而简化动态卷积的复杂性,同时 ReLU 激活函数将特征向量中的负值置为零。最后,构建四个头部分支,每个分支包含一个全连接层 FC 和一个 Sigmoid 或 Softmax 函数,从而生成 ODConv 卷积模块的四类注意力。 y 表示输出特征, α_{si} 表示对卷积核空间上的注意力, α_{ci} 表示对输入通道的注意力, α_{fi} 表示对输出通道的注意力, α_{wi} 表示对卷积核 W_i 的注意力。全维动态卷积 ODConv 的公式定义如下:

$$y = \left(\sum_{i=1}^n \alpha_{wi} \odot \alpha_{fi} \odot \alpha_{ci} \odot \alpha_{si} \odot W_i \right) * x, \quad (1)$$

其中: $\odot$ 表示乘法操作,即沿着核空间的不同维度进行的乘法运算; $*$ 表示卷积运算。




图 6 ODConv 结构

Fig. 6 ODConv structure

图 7 展示了这四种类型注意力乘以卷积核的过程,以位置、通道、滤波器和卷积核权重依次乘以卷积核 W_i ,通过这种方式将四种类型的注意力考虑进来,使卷积操作对输入信息存在各个维度的差异。

图 7(a)展示了 ODConv 在空间维度上的卷




图 7 ODCnv 计算流程

Fig. 7 ODCnv Calculation process

积注意力运算,使模型更加关注输入图像的空间位置,从而捕捉垃圾目标特征的空间分布和变化。图 7(b)展示了 ODCnv 在输入通道维度上的运算,使模型能够专注于不同通道之间的特征关系,进而更好地提取和组合通道信息,关注特定颜色和纹理特征,以应对不同光照条件。图 7(c)展示了 ODCnv 在输出通道维度的运算,使模型能够在不同输出通道之间进行有针对性的特征选择,增强对不同类别垃圾目标特征的提取能力,以应对光照变化。图 7(d)展示了 ODCnv 在卷积核空间维度的运算,使模型全面执行卷积操作,从而更好地获取整体特征,提升对小目标、遮挡目标的检测精度。这四种注意力机制相辅

相成,使 ODCnv 模块能够显著增强模型的特征提取能力以及提高特征融合的灵活性,捕获丰富的上下文信息,从而提高模型性能和泛化能力。

3.4 损失函数改进

YOLOv8n 网络模型采用的 CIoU 损失函数是 IoU 的一种改进版本,用于计算边界框的回归损失,CIoU 损失函数根据预测框和真实框之间的相似性进行评估,当两者长宽比相同时,CIoU 的结果会相同。在实际目标检测应用中,样本容易受到环境因素的影响导致物体尺度出现较大变化,尤其是在小目标检测中,光照、遮挡和视角等变化可能会导致目标的尺寸和形状发生变化,影响模型检测性能。所以纵横比和距离等几何指标会放大低质量样本的负梯度,进而对模型泛化能力造成不良影响。

针对上述局限性,本文采用具有动态非单调聚焦机制的 WIoU v3 损失函数替换 CIoU,该损失函数通过构造动态梯度增益系数,提供更细致的梯度

调整,帮助模型更精准地定位目标,提升检测性能。WIoU v3 损失函数计算公式为:

$$L_{\text{WIoUv3}} = r R_{\text{WIoUv3}} L_{\text{IoU}}, \quad (2)$$

$$r = \frac{\beta}{\delta \alpha^{\beta - \delta}}, \quad (3)$$

$$\beta = \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \in [0, +\infty), \quad (4)$$

$$R_{\text{WIoUv3}} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right), \quad (5)$$

$$L_{\text{IoU}} = 1 - \text{IoU}, \quad (6)$$

其中: r 为非单调聚焦系数; $R_{\text{WIoUv3}} \in [1, e)$ 为惩罚项; L_{IoU}^* 为单调聚焦系数; x, y 为预测框的中心坐标; x_{gt}, y_{gt} 为真实框的中心坐标; W_g 和 H_g 为真实框的宽和高; $L_{\text{IoU}} \in [0, 1]$ 为 IoU 损失; β 为离群度; δ 为梯度增益; α 为平衡因子; L_{IoU}^* 为归一化因子,即动量的滑动平均值;上标*表示进行分离操作。

相较于传统的 CIoU 损失函数, WIoU v3 通过构造梯度增益的计算方法,旨在平衡高质量和低质量锚框对模型回归的影响,使得模型具有更好的泛化能力,在多样化的场景下表现尤为出色,例如面对光照变化、部分遮挡及不同尺度大小的目标等情况,目标检测模型的整体性能也有所提升。

4 实验数据与评价指标

4.1 实验数据集

针对检测目标处于复杂场景下,本文结合人工采集的图片与 Taco 数据集,开展相关实验,合成了一个包含 2 742 张图像的垃圾分类数据集。该数据集包含自然环境中拍摄的垃圾图像,其场景多样化,涵盖室内与室外环境,如瓷砖、街道、草地和沙滩等,图像在不同场景下的具体分布数量如表 2 所示。

表 2 不同场景的图像分布数量

Tab. 2 Distribution of images across different scenes

背景环境	室内环境	室外环境		
		草地	沙滩	道路
图像数量/张	823	749	159	811

此外,该数据集中垃圾图像的光照条件、拍摄角度以及目标尺寸各异,这些因素使得数据集更贴近实际生活环境中的复杂情况。数据类别包含 9 种常见垃圾物品,分别是餐盒、易拉罐、果皮、垃圾袋、塑料包装袋、烟蒂、塑料瓶、瓶盖和纸盒,每张图像的物品标注数量不一,充分反映了实际环境中垃圾分布的不均匀性和多样性,数据集部分图像如图 8 所示。

为验证模型的改进效果,将数据集按 8:1:1 比例划分为训练集、验证集和测试集,即 2 194 张



图 8 部分数据集图片

Fig. 8 Some sample images of the dataset

图片用于训练,274 张图片用于验证,274 张用于测试。各样本数量分布如图 9 所示。




图 9 数据集各类别样本数量

Fig. 9 Number of samples per category in the dataset

4.2 评价指标

本文采用精确度 (Precision, P)、召回率 (Recall, R)、平均精度 (Average Precision, AP)、平均精度均值 (mean AP, mAP)、参数量 (Params)、每秒检测帧数 (Frames Per Second, FPS) 浮点运算量 (FLOPs) 和模型大小 (Size) 作为评价指标。FPS 表示每秒内可以检测的图片数量,是衡量模型检测速度的指标,确保模型在检测任务中实现实时响应与较高精度的平衡;参数量 (Params) 表示一个模型包含参数的数量,单位 M;浮点运算数 (FLOPs) 指每秒浮点运算次数,理解为计算量,用于衡量模型复杂度,单位 G;模型大小 (Size) 表示模型所占的存储空间大小,单位为 MB (Million Byte)。改进模型实现轻量化的关键在于模型保持较高检测精度的同时,所需的计算资源和参数量显著减少,即模型的浮点运算数 FLOPs、参数量 Params 的减少。

上述评价指标的计算式分别为:

$$Precision = \frac{TP}{TP + FP}, \quad (7)$$

$$Recall = \frac{TP}{TP + FN}, \quad (8)$$

$$AP = \int_0^1 P(R) dR, \quad (9)$$

$$mAP=\frac{1}{N}\sum_{i=1}^NAP_i, \tag{10}$$

$$FPS=\frac{Framenum}{ElapsedTime}, \tag{11}$$

其中:TP 为正确检测的样本数;FP 为检测错误的样本数;FN 为漏检的样本数;AP 值为 P-R 曲线和坐标轴所围成的面积;mAP 是对所有类别的 AP 求均值;AP_i 为数据集某个类别的平均精度;N 为检测的类别数,本文 N 取值为 9;Framenum 为需要检测图片的数量;ElapsedTime 为检测所需花费的时间。

5 实验结果与分析

5.1 实验配置

实验中垃圾目标检测模型的训练和测试环境为:CPU 为 Intel Xeon Platinum 8255C CPU @ 2.50 GHz,GPU 为 NVIDIA GeForce RTX2080 Ti,内存为 40 GB,深度学习框架为 PyTorch2.0,CUDA 版本 11.8。输入图像大小为 640×640,所有实验均训练 300 个 epoch,批量大小设置 16,IoU 阈值设置 0.5,初始学习率设置为 0.01,动量为 0.937,使用权重衰减率为 0.000 5 的随机梯度

下降优化器 SGD。

5.2 轻量化改进对比实验

为了验证本文选取 MobileNet V3 作为特征提取网络的合理性与改进 MobileNet V3 的有效性,首先采用 GhostNet^[21],ShuffleNet V2^[22],EfficientNet V2^[23],MobileNet V3 四种轻量级网络到骨干网络进行轻量化对比实验,其次基于不同注意力机制改进 MobileNet V3 网络,将 MobileNet V3_ECA,MobileNet V3_CA,MobileNet V3_CAA,MobileNet V3_EMA 进行对比实验,实验结果如表 3 所示。

实验结果显示,GhostNet 在轻量化网络中 mAP@0.5 值最高,达到 82.9%,相较于原模型,其参数量 Params、模型大小 Size 和浮点运算量 FLOPs 均有所下降,但轻量化效果不及其他结构。虽然 MobileNet V3 的 mAP@0.5 比 GhostNet 低 1.2%,但该模型的参数量 Params 分别为 GhostNet 的 0.52 倍、ShuffleNet V2 的 0.65 倍、EfficientNet V2 的 0.48 倍。这表明 MobileNet V3 在实现显著轻量化方面具有优势,原因在于 MobileNet V3 采用深度可分离卷积,在维持卷积效果的同时实现轻量化,显著减少模型在卷积运算时的参数量和浮点运算数。

表 3 轻量化对比实验结果

Tab. 3 Experimental results of different backbone networks

Models	P/%	R/%	Params/M	Size/MB	FLOPs/G	mAP@0.5/%	FPS/ (frame·s ⁻¹)
YOLOv8n(Baseline)	88.7	78.4	3.01	6.2	8.2	85.1	120
Baseline+GhostNet	91.1	76.6	2.30	4.9	6.3	82.9	128
Baseline+ShuffleNet V2	82.5	72.7	1.84	3.9	5.1	78.8	153
Baseline+EfficientNet V2	88.7	71	2.50	5.3	2.7	79.9	125
Baseline+MobileNet V3	85.4	75.5	1.19	2.7	2.8	81.7	131
Baseline+MobileNet V3_ECA	88.6	75	0.74	1.7	2.5	82.3	149
Baseline+MobileNet V3_CA	86.7	73.2	0.83	2.0	2.6	81.1	133
Baseline+MobileNet V3_CAA	87.1	78.9	2.61	5.6	4.8	83.5	121
Baseline+MobileNet V3_EMA	89.6	73.5	0.88	2.0	3.9	81.5	140

采用高效通道注意力机制 ECA、通道注意力机制^[24](Coordinate Attention, CA)、上下文锚点注意力机制 CAA 和高效多尺度注意力机制^[25](Efficient Multi-Scale Attention, EMA)四个注意

力机制对 MobileNet V3 轻量化网络进行改进,由表 3 可知,引入 CAA 改进 MobileNet V3 轻量化网络时,检测效果在轻量化模型中最好,mAP@0.5 为 83.5%,但改进后结构轻量化效果不如

MobileNet V3 结构。引入 ECA 改进 MobileNet V3 时,模型轻量化效果最佳,并且检测速度和精度都有所提升,MobileNet V3_ECA 模型的参数量 Params、模型大小 Size 和浮点运算量 FLOPs 分别是 YOLOv8n 模型的 0.25 倍、0.27 倍和 0.30 倍,检测速度是原模型的 1.24 倍,显著实现模型轻量化的同时保持目标检测精度。

5.3 注意力机制对比实验

为验证 CAA 注意力机制在复杂场景下垃圾目标检测中的有效性,本文在 MobileNet V3_ECA 轻量化骨干网络基础上,分别与全局注意力机制^[26](Global Attention Mechanism, GAM)、通道注意力机制 CA、压缩与激励网络 SE、卷积注意

力模块^[27](Convolutional Block Attention Module, CBAM),高效多尺度注意力机制 EMA 进行了对比实验。

实验结果如表 4 显示,添加注意力机制后,模型的参数量、模型大小和浮点运算量变化不大,检测性能成为主要评价指标。引入 CAA 注意力机制后,模型的 mAP@0.5 达到了 84.1%,较基准模型提高 1.8%,且优于其他注意力机制表现,原因在于 CAA 模块能够捕捉远距离的上下文信息来增强中心特征的特征,帮助模型在复杂场景下准确定位目标,减少小目标与部分遮挡情况下导致的误检、漏检现象,从而提升目标检测精度。

表 4 注意力机制对比实验结果
Tab. 4 Comparison of attention mechanisms with experimental results

Models	P/%	R/%	Params/M	Size/MB	FLOPs/G	mAP@0.5/%
YOLOv8n+MobileNet V3_ECA(Baseline)	88.6	75	0.74	1.7	2.5	82.3
Baseline+GAM	86.7	73.2	0.75	1.8	2.5	81.1
Baseline+CA	89.7	73.1	0.74	1.8	2.5	82.5
Baseline+CBAM	89.1	78.6	2.61	5.6	4.8	83.3
Baseline+SE	89.6	73.5	0.74	1.8	2.5	81.5
Baseline+EMA	87.7	76.6	0.74	1.8	2.5	83.4
Baseline+CAA	82.5	79.9	0.74	1.8	2.5	84.1

5.4 损失函数对比实验

为验证 WIoU v3 损失函数的有效性,在原 YOLOv8n 模型基础上将 CIoU, SIoU^[28]及 WIoU v1, v2, v3 损失函数进行对比实验。实验结果如表 5 所示,相较于 CIoU 损失函数,采用 WIoU v3 损失函数后 mAP@0.5 提高了 0.5%,召回率 R

提高了 0.9%,检测精度也优于其他损失函数, mAP@0.5 分别比 SIoU, WIoU v1 和 WIoU v2 高 1.1%, 0.9%, 0.7%。证明 WIoU v3 损失函数能有效提升检测精度。

5.5 消融实验

为了验证本文提出的所有改进模块的有效性,以原 YOLOv8n 网络模型为基线模型,在相同实验条件下进行消融实验,并以精确度 P、召回率 R、参数量 Params、浮点运算量 FLOPs 和 mAP@0.5 作为评价指标,通过逐一消融的方式进行实验。

实验结果如表 6 所示,改进 A 表示采用改进的 MobileNet V3_ECA 网络结构替换 YOLOv8n 的特征提取骨干网络;改进 B 表示在 A 模型的基础上,引入上下文锚点注意力机制 CAA 到骨干网络;改进 C 表示在 A 模型的基础上,颈部网络的普通卷积采用全维动态卷积 ODConv 替换;改

表 5 损失函数实验结果

Tab. 5 Experimental results of the loss function

Models	P/%	R/%	Param/M	mAP@0.5/%
CIoU	88.7	78.4	3.01	85.1
SIoU	88.6	78	3.01	84.5
WIoU v1	90.5	78.1	3.01	84.7
WIoU v2	89.3	76.8	3.01	84.9
WIoU v3	87.7	79.3	3.01	85.6

进 D 表示在 B 模型的基础上,颈部网络的普通卷积采用全维动态卷积 ODConv 替换;本文改进模

型表示在 D 模型的基础上使用 WIoU v3 替换 CIoU 损失函数。

表 6 消融实验

Tab. 6 Ablation experiments

Models	Base- line	MobileNet V3_ECA	CAA	ODC onv	WIoU	P/%	R/ %	Param s/M	FLOPs /G	Size/ MB	mAP@0.5 /%	FPS/ (frame·s ⁻¹)
Baseline	✓					88.7	78.4	3.01	8.2	6.2	85.1	120
A	✓	✓				88.6	75	0.74	2.5	1.7	82.3	149
B	✓	✓	✓			82.5	79.9	0.74	2.5	1.8	84.1	118
C	✓	✓		✓		88.6	78	0.88	2.4	2.0	84.5	121
D	✓	✓	✓	✓		87.1	80.8	0.88	2.4	2.1	86	131
Ours	✓	✓	✓	✓	✓	87.8	80	0.88	2.4	2.1	86.2	134

实验结果分析可知,使用改进的 MobileNet V3_ECA 作为 YOLOv8n 的骨干网络,虽然模型精度出现下降,但模型参数量 Params、模型大小 Size 和浮点运算量 FLOPs 均大幅减少,分别从 3.01 M, 6.2 MB 和 8.2 G 下降到 0.74 M, 1.7 MB 和 2.5 G。在骨干网络中引入 CAA 模块,不增加模型复杂度,提升检测效果, mAP@0.5 达到 84.1%, 相较于 A 模型检测精度提高了 1.8%。为了改善对小目标的检测效果,本文采用全维动态卷积 ODConv 替换颈部网络的卷积模块,模型参数量 Params、模型大小 Size 分别从 0.74 M, 1.7 MB 增加到 0.88 M, 2.0 MB, 检测效果也有所提升。为了进一步提升复杂环境下垃圾目标的检测效果,同时采用 CAA 和 ODConv 模块改进模型,在细微增加模型大小的情况下提升检测精度, mAP@0.5 达到 86%, 相较于基线模型,提高了 0.9%。添加 WIoU v3 损失函数后, mAP@0.5 提升了 0.2%。

综上,本文改进模型相较于基线模型,虽然精确度略微降低,但召回率、mAP@0.5 和帧率分别提高了 1.6%, 1.1% 和 11.7%, 并且参数量 Params、模型大小 Size 和浮点运算量 FLOPs 分别降低了 70.8%, 66.1% 和 70.7%, 本文改进模型在显著实现模型轻量化的同时提升模型检测效果,改进后模型的消融实验结果对比如图 10 所示。

图 11 为 YOLOv8n 优化前后的 mAP@0.5 和定位损失曲线对比图,由图可以清晰地看出本文




图 10 消融实验结果对比

Fig. 10 Comparison of ablation experiment results

所提优化方案检测性能的提升效果,并且本文模型对目标位置和大小的预测更准确。

为了评估改进模型在不同类别垃圾检测任务中的性能,在相同实验条件下,采用自建垃圾数据集对原始模型与改进模型进行对比实验。通过精确度 P 、召回率 R 和平均精度均值 mAP@0.5 等关键指标进行分析,实验结果如表 7 所示。

实验结果表明,改进模型在八类垃圾的平均检测精度上均有所提升,尤其在烟蒂和瓶盖等小目标的检测上, mAP@0.5 分别提升了 2.1% 和 4.7%。这些实验结果表明,改进后的模型在复杂环境下能够显著提高各类垃圾的检测精度,特别是在小目标的识别能力上表现尤为突出。




图 11 改进前后模型精度与定位损失曲线对比

Fig. 11 Comparison of model accuracy and positioning loss curve before and after improvemen

表 7 原模型与改进模型对各类垃圾检测对比

Category	YOLOv8n			Improved-YOLOv8n		
	<i>P</i> /%	<i>R</i> /%	mAP@0. 5/ %	<i>P</i> /%	<i>R</i> /%	mAP@0. 5/ %
Lunch boxes	73. 4	64. 3	69. 3	72. 4	65. 7	72. 8 ↑
Can	92. 1	81	86. 7	88. 8	81	88. 1 ↑
Peel	88. 9	81. 6	88. 2	90. 9	81. 5	88. 3 ↑
Garbage bags	91. 5	71. 8	83. 5	92. 4	74. 4	80. 8
Butt	93. 6	80. 3	84. 9	97. 4	78. 2	87 ↑
Plastic bottles	94. 9	83. 2	91. 9	93. 3	83. 5	92 ↑
Caps	87. 3	66. 7	74. 7	87. 2	71. 6	79. 4 ↑
Plastic bags	83	92. 3	93. 2	73	92. 3	93. 3 ↑
Carton	93. 5	84. 2	93. 3	94. 4	92. 1	94. 4 ↑

5. 6 不同模型对比实验

为综合验证本文改进模型的性能,以精确度 *P*、召回率 *R*、平均精度均值 mAP@0. 5、模型参数量 Params、模型大小 Size 和浮点运算量 FLOPs 作为评价指标,将本文改进模型与 YOLOv5s, YOLOv5n, YOLOv10n, Faster R-CNN, SSD, YOLOv7-tiny, YOLOv8s, YOLOv8n 在相同条件下进行对比实验,实验结果如表 8 所示。

实验结果显示, YOLOv5n 的模型参数量、模型大小和浮点运算量均小于其他七个网络模型,并且其检测精度与 YOLOv8n 模型相当。虽然 YOLOv5s 的检测精度是八个目标检测模型中最高的,但其模型大小和浮点运算量较大。相较于 YOLO 系列模型, Faster R-CNN, SSD 两个目标检测模型在检测精度与轻量化方面均无优势,原因在于面向复杂场景下的垃圾目标检测存在大

量噪声与部分目标存在遮挡现象,模型所需的计算资源较大,难以实现在边缘端设备的部署。

改进后的模型与基线模型 YOLOv8n 相比,模型参数量、模型大小和浮点运算量上更小,分别为 0. 88 M, 2. 1 MB 和 2. 4 G,并且精确度和 mAP@0. 5 均优于 YOLOv8n 模型。通过以上分析可以看出,本文改进模型在多个评价指标上展现出优越性,面向复杂场景下的垃圾检测更具优势。

为对比基线模型 YOLOv8n(左图)与改进模型(右图)的检测效果,选取不同光线、不同场景的多目标图像进行可视化对比,检测结果如图 12 所示。

由可视化对比图可知,在草丛环境下,原 YOLOv8n 模型未检测到被遮挡的易拉罐,而改进模型正确检测到该目标;在多目标和光照环境下,改进模型展现出更高的检测精度;在存在背景干扰的场景下,原模型将背景环境中的枯叶误

表 8 不同模型对比实验结果

Tab. 8 Comparison of experimental results of different models

Models	$P/\%$	$R/\%$	Params/M	Size/MB	FLOPs/G	mAP@0.5/%
YOLOv5s	87.7	79.3	7.04	14.4	15.8	85.6
YOLOv5n	85.6	80.2	1.77	3.8	4.3	85.1
YOLOv10n	92.8	80.9	2.7	5.6	8.2	85.3
YOLOv7-tiny	86.1	79.2	6.03	12.3	13.2	84.7
Faster R-CNN	47.3	79.4	137.1	108.5	370.2	74.6
SSD	82.4	71.9	26.3	94.7	62.7	76.9
YOLOv8s	90.8	75.5	11.1	22.6	28.7	85.2
YOLOv8n	88.7	78.4	3.01	6.2	8.1	85.1
Ours	87.8	80	0.88	2.1	2.4	86.2

检为垃圾目标,而改进模型能正确区分垃圾目标与背景环境。这表明改进模型通过引入上下文锚点注意力机制CAA更好地提取垃圾目标特征信息,采用全维动态

卷积ODConv增强模型的融合能力,减小特征信息在融合过程中的丢失,有效降低了小目标、目标遮挡与背景干扰带来的漏检与误检问题。综合可视化对比图及上述分析可知,本文改进模型相较于基线模型YOLOv8n拥有更好地目标检测性能,更适合在复杂场景下进行垃圾目标检测任务。

6 结 论

本文基于YOLOv8n模型提出一种适用于复杂环境下的垃圾目标检测模型,目的在于解决目标检测模型在复杂环境下垃圾检测存在误检的问题,实现目标检测模型轻量化与检测精度之间的平衡。本文改进模型通过引入改进的MobileNet V3_ECA结构到骨干网络,并添加CAA注意力机制,显著实现模型轻量化;在颈部网络引入全维动态卷积ODConv替换颈部网络的标准卷积,采用WIoU v3损失函数替换CIoU,提升检测精度。改进模型在自建垃圾数据集上mAP@0.5达到了86.2%,检测速度FPS达到了134,相较于原YOLOv8n模型,mAP@0.5提高了1.1%,检测速度提高了11.7%,模型参数量Params、模型大小Size和浮点运算量FLOPs分别降低了70.8%,66.1%和70.7%,在遮挡及复杂场景下的检测效果也得到了显著提升,但改进模型在复杂场景下进行多目标检测时仍偶有发生漏检情况。后续工作将进一步优化模型结构,提升检测精度,将模型部署至边缘端,应用于复杂场景进行垃圾目标实时检测。



图 12 检测结果对比

Fig. 12 Detection result comparison

作者贡献声明:

孙世政:检测方法的提出;

何玲玲:模型改进方法提出,论文构思和撰写;

郑帅:数据整理与分析;

何泽银:实验方法的指导。

参考文献:

- [1] 于锴,沈东升,邢筱静,等. 居民区生活垃圾房及周边环境的微生物污染特征与健康风险评估[J]. 环境科学学报, 2024, 44(8): 477-487.
YU Q, SHEN D S, XING X J, *et al.* Microbial contamination characteristics and health risk assessment of residential domestic garbage room and surrounding environment [J]. *Acta Scientiae Circumstantiae*, 2024, 44(8): 477-487. (in Chinese)
- [2] 罗志聪,何陈涛,陈登捷,等. 基于轻量化 YOLO v8s-GD 的自然环境下百香果快速检测模型[J]. 农业机械学报, 2024, 55(8): 291-300.
LUO Z C, HE C T, CHEN D J, *et al.* Passion fruit rapid detection model based on lightweight YOLO v8s-GD[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(8): 291-300. (in Chinese)
- [3] 张新月,胡广锐,李浦航,等. 基于改进 YOLOv8n 的轻量化红花识别方法[J]. 农业工程学报, 2024, 40(13): 163-170.
ZHANG X Y, HU G R, LI P H, *et al.* Recognizing safflower using improved lightweight YOLOv8n [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2024, 40(13): 163-170. (in Chinese)
- [4] 黄丹丹,高晗,刘智,等. 面向无人机平台的轻量化目标检测网络[J]. 光学精密工程, 2023, 31(20): 3021-3033.
HUANG D D, GAO H, LIU ZH, *et al.* Lightweight target detection network for UAV platforms [J]. *Opt. Precision Eng.*, 2023, 31(20): 3021-3033. (in Chinese)
- [5] 梁礼明,龙鹏威,冯耀,等. 改进轻量化 VTG-YOLOv7-tiny 的钢材表面缺陷检测[J]. 光学精密工程, 2024, 32(8): 1227-1240.
LIANG L M, LONG P W, FENG Y, *et al.* Improving the lightweight VTG-YOLOv7-tiny for steel surface defect detection [J]. *Opt. Precision Eng.*, 2024, 32(8): 1227-1240. (in Chinese)
- [6] ZENG T H, LI S Y, SONG Q M, *et al.* Lightweight tomato real-time detection method based on improved YOLO and mobile deployment[J]. *Computers and Electronics in Agriculture*, 2023, 205: 107625.
- [7] 周颖,许士博,陈海永,等. 融合多尺度特征与注意力的太阳能电池表面缺陷检测[J]. 光学精密工程, 2024, 32(14): 2286-2298.
- [8] 蔡逢煌,张家翔,黄捷. 基于图像低维特征融合的航拍小目标检测模型[J]. 模式识别与人工智能, 2024, 37(2): 162-171.
CAI F H, ZHANG J X, HUANG J. Model for small object detection in aerial photography based on low dimensional image feature fusion [J]. *Pattern Recognition and Artificial Intelligence*, 2024, 37(2): 162-171. (in Chinese)
- [9] 林珊玲,张雪,陈燕,等. 融合全局信息与双域注意力机制的光学遥感飞机目标检测[J]. 光学精密工程, 2024, 32(20): 3085-3098.
LIN S L, ZHANG X, CHEN Y, *et al.* Integrating global information and dual-domain attention mechanism for optical remote sensing aircraft target detection [J]. *Opt. Precision Eng.*, 2024, 32(20): 3085-3098. (in Chinese)
- [10] PROENÇA P F, SIMÕES P. Taco: Trash annotations in context for litter detection [J]. *arXiv Preprint arXiv*: 2003. 06975, 2020.
- [11] WANG Q L, WU B G, ZHU P F, *et al.* ECA-net: efficient channel attention for deep convolutional neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 11534-11542.
- [12] 张倡倡,吕卫东,蔡子杰,等. 基于域泛化的轻量化图像分类算法[J]. 计算机工程, 2025, 51(1): 182-189.
ZHANG C C, LÜ W D, CAI Z J, *et al.* Lightweight image classification algorithm based on domain generalization [J]. *Computer Engineering*, 2025, 51(1): 182-189. (in Chinese)
- [13] CAI X H, LAI Q X, WANG Y W, *et al.* Poly kernel inception network for remote sensing detection[C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 27706-27716.
- [14] LI C, ZHOU A J, YAO A B. Omni-dimensional dynamic convolution [J]. *arXiv Preprint arXiv*: 2209. 07947, 2022.
- [15] TONG Z, CHEN Y, XU Z, *et al.* Wise-IoU:

- bounding box regression loss with dynamic focusing mechanism [J]. *arXiv Preprint arXiv*: 23-01.10051, 2023.
- [16] ZHU X K, LYU S C, WANG X, *et al.* TPH-YOLOv5: Improved YOLOv5 based on Transformer Prediction Head for Object Detection on Drone-Captured Scenarios [C]. 2021 *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*. October 11-17, 2021. Montreal, BC, Canada. IEEE, 2021: 2778-2788.
- [17] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 7464-7475.
- [18] JI B, XU J F, LIU Y, *et al.* Improved YOLOv8 for small traffic sign detection under complex environmental conditions [J]. *Franklin Open*, 2024, 8: 100167.
- [19] HOWARD A, SANDLER M, CHEN B, *et al.* Searching for MobileNetV3 [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019. Seoul, Korea (South). IEEE, 2019: 1314-1324.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation Networks [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 7132-7141.
- [21] HAN K, WANG Y H, TIAN Q, *et al.* GhostNet: more features from cheap operations [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 1577-1586.
- [22] MA N N, ZHANG X Y, ZHENG H T, *et al.* ShuffleNet V2: Practical Guidelines for Efficient Cnn Architecture Design [M]. Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 122-138.
- [23] TAN M, LE Q V. EfficientNetV2: smaller models and faster training [C]. *International Conference on Machine Learning*. Princeton, NJ, USA. 2021: 10096-10106.
- [24] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021, Nashville, TN, USA. IEEE, 2021: 13708-13717.
- [25] OUYANG D L, HE S, ZHANG G Z, *et al.* Efficient multi-scale attention module with cross-spatial learning [C]. *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. June 4-10, 2023, Rhodes Island, Greece. IEEE, 2023: 1-5.
- [126] LIU Y C, SHAO Z R, HOFFMANN N. Global attention mechanism: retain information to enhance channel-spatial interactions [J]. *arXiv*: 2112.05561, 2021.
- [27] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module [C]. *Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 3-19.
- [28] GEVORGYAN Z. Siou loss: More powerful learning for bounding box regression [J]. *arXiv Preprint arXiv*: 2205.12740, 2022.

作者简介:



孙世政(1986—),男,山东烟台人,教授,硕士生导师,2015年于合肥工业大学获得博士学位,现为重庆交通大学教授,主要研究方向为精密仪器与机械、智能传感技术。E-mail: ssz091011@163.com