

基于 YOLOv10-vehicle 算法的复杂天气 情况下车辆目标检测方法

杜 宏, 顾宸瑜, 张孝峥, 刘高天, 李兴鑫, 杨忠琳

(中国北方车辆研究所, 北京 100072)

摘 要: 针对在阴天、雨天、夜晚等复杂天气情况下, 车辆目标检测受到光照、雨雪、沙尘等因素影响, 出现错检、漏检等问题, 提出了一种 YOLOv10-vehicle 目标检测算法。首先, 设计了一种新的注意力机制模块 WT-PSA, 在复杂天气下提高模型对车辆目标的关注度; 其次, 改进了 SPPF 模块, 通过引入平均池化操作, 改善因最大池化操作导致的特征信息提取不足问题; 然后, 设计了改进的 C2f-OD 模块, 提升主干网络提取图片特征信息的能力; 最后, 将模型损失函数替换为 Focal EIou, 以加快收敛速度并降低损失值; 在车辆数据集 UA-DETRAC 上进行对比实验, 改进后的算法平均准确率 (mAP@0.5) 相较原算法提升了 5.1%, 证明了 YOLOv10-vehicle 算法在复杂天气、恶劣天气下车辆检测方面的优越性。同时, 在 VOC 公共数据集上进行实验验证, YOLOv10-vehicle 算法在检测车辆目标时检测精度提高了 2.8%, 证明了本文改进算法的泛化性。

关键词: 车辆目标检测; YOLOv10n; C2f 模块; 恶劣天气

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1671-5497(2025)10-3309-10

DOI: 10.13229/j.cnki.jdxbgxb.20250016

Vehicle target detection method based on the YOLOv10-vehicle algorithm under complex weather conditions

DU Hong, GU Chen-yu, ZHANG Xiao-zheng, LIU Gao-tian, LI Xing-xin, YANG Zhong-lin

(China Northern Vehicle Research Institute, Beijing 100072, China)

Abstract: In the face of complex weather conditions such as cloudy days, rainy days, and nights, vehicle target detection is affected by factors such as lighting, rain, snow, and dust. As a result, problems like false detections and missed detections occur. To address these issues, a YOLOv10-vehicle target detection algorithm is proposed. Firstly, a new attention mechanism module named WT-PSA is designed to improve the model's attention to vehicle targets under complex weather. Secondly, the SPPF module is improved by introducing the average pooling operation to address the problem of insufficient feature information extraction caused by the max pooling operation. Then, an improved C2f-OD module is put forward to enhance the ability of the backbone network to extract image feature information. Finally, the model's loss function is replaced with Focal EIou to accelerate the convergence speed and reduce the loss

收稿日期: 2025-01-06.

基金项目: 国家自然科学基金项目 (62206257).

作者简介: 杜宏 (1968-), 男, 研究员. 研究方向: 控制系统. E-mail: 13910822893@139.com

value. Comparative experiments are conducted on the vehicle dataset UA-DETRAC. The mean average precision (mAP@0.5) of the improved algorithm is increased by 5.1% compared with that of the original algorithm, demonstrating the superiority of the YOLOv10-vehicle algorithm in vehicle detection under complex and severe weather conditions. Meanwhile, experiments are also carried out on the VOC public dataset. The detection accuracy of the YOLOv10-vehicle algorithm in detecting vehicle targets is improved by 2.8%, which verifies the generalization ability of the improved algorithm in this paper.

Key words: vehicle target detection; YOLOv10n; C2f module; severe weather

0 引言

车辆普及带来的便利越来越多,但是车辆事故也日益增多,尤其是在恶劣天气、复杂天气情况下车辆交通事故更为集中。在恶劣天气下的车辆目标检测成为亟待解决的问题。

随着基于深度学习的车辆检测技术的更新,它在智能交通中发挥着越来越重要的作用^[1]。但是在复杂天气和恶劣天气下,该算法输入信息往往存在大量的噪声和干扰,以至于检测常出现错检、漏检问题。如何解决复杂天气、恶劣天气状况下车辆目标的错检、漏检问题成为研究的热点。

目前针对车辆目标检测问题,许多国内外学者^[2]进行了深入研究,提出包括数据增强技术、锚框设计、多尺度检测和上下文信息利用等改进方法。VGG^[3]和 Alex Net^[4]算法分别采用了随机裁剪、随机缩放再裁剪、图片翻转等数据增强技术。锚框设计则最早应用于 Faster RCNN^[5]算法,通过设计不同大小和宽高比的锚框适配不同大小的目标。薛珊等^[6-8]使用 K-means 方法重新设计先验框,提出了针对无人机的目标检测算法,提高了原模型在复杂背景、遮挡情况下检测无人机的精度。周飞等^[9]提出一种改进 YOLOv8 的车辆目标检测算法。通过添加 SimAM 注意力模块增强了目标车辆的重要特征,提高了模型的特征融合能力,改善了复杂交通监控场景下车辆检测精度不足、检测速度慢的问题。针对复杂交通场景下城市车辆目标检测算法存在漏检、精度低、泛化能力弱的问题,许德刚等^[10]提出一种改进的 YOLOv8 城市车辆目标检测算法,采用一种改进的 GAM-C2f 结构来代替主干网络中的 C2f 模块,平衡模型的计算效率和准确性,改善了城市交通场景下小目标车辆检测性能不佳的问题。张利丰等^[11]在多层级特征融合方面做出改进,提出了改进 YOLOv8 的车辆目标检测算法 RBT-YOLO。采用

多尺度融合的方式对主干网络进行重构,对 BiF-PN 进行改进,增加卷积操作以及调整输入输出通道个数以适应 YOLOv8,加强其特征融合能力,以解决传统车辆目标检测模型设备需求高、检测精度低、重叠目标漏检率高等问题。

虽然上述算法已应用于车辆目标检测方向,但在车辆所处天气情况恶劣时,图像输入模糊,噪声过大,光线变暗时,算法检测容易产生漏检、误检的问题。本文针对车辆目标在复杂天气、恶劣天气情况下易漏检、错检、目标特征表达不充分等问题,以轻量化性能良好的 YOLOv10n 单阶段目标检测网络为基础框架进行改进研究。通过改进注意力机制、空间金字塔池化模块、C2f 模块、引进新损失函数,提出一种改进的车辆目标检测算法 YOLOv10-vehicle,解决了恶劣天气条件下车辆易漏检、误检的问题,提高了模型的平均准确率。

1 基于 YOLOv10n 的检测算法设计

YOLO 系列算法作为当前主流的目标检测算法,近年来得到了不断的发展,从 YOLOv1 到 YOLOv10, YOLO 网络的性能逐渐提高,在保证实时性的前提下,使网络拥有较高的识别精度^[11-15]。目前, YOLOv10 算法被广泛应用在各种视觉场合。其网络结构如图 1 所示。

1.1 Backbone 主干网络

YOLOv10 以增强版 CSPNet 作为主干网络, 将其 CSPNet 中第四、五个标准卷积模块 CBS 更换为 SCDown (Selective channel down-sampling)。每次卷积后利用 C2f 模块提取和转换输入数据的特征,生成更具表征能力的输出。并在 Backbone 的最后加入快速空间金字塔池化 (SP-PF) 模块和高效的部分自注意力机制 (PSA), 进一步整合提取特征信息,最终输出 3 个不同尺寸的特征信息。




图 1 YOLOv10n 网络结构示意图

Fig. 1 Diagram of YOLOv10n network structure

1.2 Neck 特征融合层

YOLOv10 的 Neck 部分主要负责特征融合,连接骨干网络(Backbone)和检测头(Head),其设计目的是在不同尺度上有效整合特征,以便进行更准确的目标检测。

Neck 部分应用路径聚合网络(PANet),PANet 通过上采样(如双线性插值)将低层特征图提升到与高层特征图相同的空间尺寸,通过加法或拼接操作,将底层特征(含有更多细节)与顶层特征(包含丰富语义信息)结合,增强了信息流动。同时 PANet 还采用了横向连接(Lateral connections),使得低层和高层特征可以直接相互影响。最终生成的融合特征图将传递给后续的检测头,用于目标检测。

1.3 Head 检测头部分

检测头接收来自 Neck 部分的多尺度特征图(包括来自不同尺度的特征融合结果),负责对输入的特征图进行处理。检测头采用了 One-to-many Head 和 One-to-one Head 并行部署的双头结构。在训练时,One-to-many Head 会为每个目标分配多个 Anchor 或参考点(Anchor-free 设计),生成多个预测框,覆盖目标的不同位置和尺度变化,提升训练稳定性。而 One-to-one Head 每个目标仅分配一个最优预测框,通过优化标签匹配策略(如匈牙利匹配)直接筛选出最可靠的预测。两个头同时参与与

算损失,模型能够利用 One-to-many Head 的丰富监督信号来优化模型参数;而在推理预测时,只需使用 One-to-one Head,从而绕过了非极大值抑制(NMS)过程,在不增加额外推理成本的情况下提高了效率,实现了 NMS-free 的高效推理^[16]。

2 基于改进的 YOLOv10-vehicle 车辆目标检测算法设计

针对城市环境中不同天气情况下,车辆目标在拍摄图像中分布随机,以及易受复杂背景信息影响的现象,从主干网络、特征融合网络和损失函数 3 个方面对 YOLOv10n 进行改进,提出 YOLOv10n-vehicle 算法,达到复杂天气、恶劣天气情况下目标检测算法要求的高精度以及实时性。改进后的算法结构如图 2 所示。

考虑到在恶劣天气情况下城市车辆目标检测存在漏检、误检、检测准确度偏低的问题,在 YOLOv10n 网络基础上,提出一种改进算法。设计了一种新的注意力机制模块 WT-PSA,在复杂天气下提高网络模型对车辆目标的关注度。其次,采用改进的 SPPF_A 模块,在增强主干网络特征提取能力的同时,缓解了原有 SPPF 应用最大池化所导致的局部特征信息丢失问题。然后,改进模型中的 C2f 模块,通过添加全维度动态卷积模块(ODConv)来提升主干网络提取图片特征信息的




图 2 YOLOv10-vehicle 网络结构图

Fig. 2 Diagram of YOLOv10-vehicle network structure

能力,提高模型的鲁棒性。最后,采用Focal EIoU损失函数提升模型的回归精度并提高收敛速度。

2.1 WT-PSA 注意力模块设计

PSA 模块中通过 1×1 的卷积将特征通道分为两份,一份进入由多头自注意力模块(MHSA)和前馈网络(FFN)组成的NPSA块,之后与另一份未处理的特征连接融合,得到最终的输出特征。

本文针对不良天气条件下的车辆目标检测问题,在PSA模块基础上进行改进,构建了WT-PSA模块,首先采用两个 3×3 卷积核叠加的卷积方式,与单个 3×3 卷积核并行进行多尺度的特征提取,获得多种尺度的特征图。其次,将支路中的第二个常规卷积替换为小波卷积(WT-Conv)^[17],小波卷积的示例如图3所示。通过小波变换将输入图像分解为不同的频率成分,然后在每个频率子带上应用小尺寸的深度卷积核进行卷积操作,实现对图像的多尺度分析,从而能够提取到更丰富、更全面的图像特征。

将PSA的输入替换为多尺度卷积结果,得到WT-PSA模块,其结构如图4所示。通过对PSA




图 3 小波卷积示例图

Fig. 3 Example diagram of wavelet convolution

模块输入部分的改进实现在复杂天气下视野模糊时,提高模型对车辆目标的关注度。

2.2 C2f-OD 模块设计

YOLOv10n模型主干网络中重复使用C2f模块可以将浅层具有高空间分辨率的特征与深层具有丰富语义信息的特征进行融合,从而在保持空间细节的同时,增强特征的语义表达能力,提高对目标物体的定位和识别精度。通过部分连接的方式,C2f模块在一定程度上借鉴了DenseNet的特征重用策略,但又结合了YOLO系列模型的目标检测需求,




图 4 WT-PSA 模块结构图

Fig. 4 Structural diagram of WT-PSA module

使其在实际应用中更加高效。本文针对不良天气导致的车辆目标模糊、亮度不足、目标与背景易混淆的问题,提出 C2f-OD 模块,将全维度动态卷积(ODConv)^[18]引入 C2f 模块中。其中 ODConv 在卷

积核的 4 个维度上引入了注意力机制,分别是空间维度、输入通道维度、输出通道维度和卷积核维度,其结构如图 5 所示。




图 5 ODConv 网络结构图

Fig. 5 Structural diagram of ODConv

在目标检测任务中,对于物体形状、纹理等特征,ODConv 可以根据其重要性动态分配权重,从而更好地提取和表示这些特征,提高模型对复杂数据的理解能力。将输入信息降维处理后利用 ODConv 通过动态调整卷积核在不同维度上的权重,更精准地捕捉输入数据的特征,通过标准卷积模块将通道数提升,再将其与输入进行残差链接得到 ODBottleneck。最后,运用 ODBottleneck 模块替换 C2f 中的 Bottleneck,得到 C2f-OD 模块,提高模型的检测精度,使改进网络的性能得到进一步提升。模块结构如图 6 所示。




图 6 C2f-OD 模块结构图

Fig. 6 Structural diagram of C2f-OD module

2.3 SPPF_A 模块设计

SPPF 模块结合了空间金字塔池化(Spatial pyramid pooling)和快速卷积的思想,允许模型在不同的尺度上对输入特征进行处理。通过在多个尺度上进行 5×5 的最大池化, SPPF 模块能够捕捉到更丰富的上下文信息。虽然这种方式能很好地提取输入特征信息,但由于其仅利用最大池化操作来提取特征,导致部分全局特征信息丢失。

在复杂天气情况下,图像数据存在背景复杂、噪声较多的情况。平均池化的平滑特性可以起到一定的降噪作用,使后续特征提取更稳定。因此,本文设计了 SPPF_A 模块,网络结构如图 7 所示。SPPF_A 模块在连续的最大池化操作同时进行一次 5×5 的平均池化操作,用以加强对全局特征信息的提取能力,防止因最大池化操作导致的特征信息提取不足问题。然后通过 Concat 操作与连续的最大池化输出特征进行拼接融合,获得更加




图 7 SFPF_A 模块结构图

Fig. 7 Structural diagram of SFPF_A module

详细的全局特征。缓解了因天气情况不佳导致的车辆目标漏检、错检等问题。

2.4 Focal EIou 损失函数

YOLOv10 的预测框回归采用 CIoU 损失函数, CIoU 的计算公式如下:

$$1 - \text{IoU} + \frac{d^2(b, b^{\text{gt}})}{c^2} + \alpha v \quad (1)$$

$$\text{IoU} = \frac{|b \cap b^{\text{gt}}|}{|b \cup b^{\text{gt}}|} \quad (2)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (3)$$

式中: d 为真实框与预测框中心点的欧氏距离; b 为预测框; b^{gt} 为真实框; c 为真实框与预测框最小外接矩形的对角线距离; α 为权重参数; v 为度量宽高比一致性; IoU 为真实框与预测框的面积交并比; w^{gt} 为真实框的宽度; h^{gt} 为真实框的高度; w 为预测框的宽度; h 为预测框的高度。CIoU 不仅考虑了交并比, 还考虑了目标框和预测框的中心距离以及宽高比的差异。但是, CIoU 难以度量预测框与真实框宽高之间的真实差异, 且在预测框和目标框几乎完全重合 (IoU 接近 1) 时, CIoU 损失函数中的各项变化非常微小, 可能会导致梯度消失问题。因此, 本文引进 Focal EIou 损失函数进行预测框的回归损失计算。Focal EIou 将 CIoU 中预测框与真实框的宽高比损失项, 拆分成预测框与真实框的宽度差值和高度差值, 即用 $\frac{d^2(w, w^{\text{gt}})}{C_w^2} + \frac{d^2(h, h^{\text{gt}})}{C_h^2}$ 替换 CIoU 中的 αv 项, 加快模型收敛速度。同时, 引入 Focal Loss 优化预测框回归任务中的样本不平衡问题, 减少与真实框重叠较少的预测框对回归损失的影响, 使回归损失趋向高质量预测框。其计算式如式(4)(5)所示:

$$L_{\text{EIou}} = 1 - \text{IoU} + \frac{d^2(b, b^{\text{gt}})}{c^2} + \frac{d^2(w, w^{\text{gt}})}{C_w^2} + \frac{d^2(h, h^{\text{gt}})}{C_h^2} \quad (4)$$

EIoU 含义?

$$L_{\text{Focal-EIoU}} = \text{IoU}^\lambda \times L_{\text{EIou}} \quad (5)$$

式中: L_{EIou} 为 EIou 损失函数值; λ 为控制异常值抑制程度参数值; C_w 为预测框与真实框最小外接矩形的宽度; C_h 为预测框与真实框最小外接矩形的高度^[19]; $L_{\text{Focal-EIoU}}$ 为引入了 Focal Loss 优化的 EIou 损失函数值。

3 实验与结果分析

3.1 数据集的建立和预处理

针对城市环境不同天气状况下的车辆目标检测问题, 本文选用 UA-DETRAC 数据集, 该数据集中包含多种天气条件, 如夜晚、阴天、晴天、下雨和下雪等。其中包含使用佳能 EOS550D 相机在中国北京和天津的 24 个不同地点拍摄的 10 h 视频。视频以 25 帧/s 的速度录制, 分辨率为 960×540 像素。UA-DETRAC 数据集中有超过 14 万帧和 8 250 辆手动标注的车辆。考虑到数据集的特征冗余以及实验设备算力有限, 对 UA-DETRAC 数据集进行处理, 每 10 帧取 1 张图片对模型进行训练和验证。同时, 因数据集原有标签文件格式为 xml 格式, 不能用于 YOLOv10n 的训练, 所以将数据及标签转化为 YOLOv10n 所需的 txt 格式。因原有的 xml 文件中存在忽略的区域 (Ignored region), 忽略区域并不能在 txt 格式文件中体现出来。若直接训练, 则忽略区域中的车辆并没有与之对应的标签信息, 这会对模型训练造成很大的干扰。

为了保证数据集中的样本与标签能够正确匹配, 本文针对这种情况对数据集中的忽略区域进行了涂黑遮蔽处理。处理后的数据集包含训练集 8 639 张图片、验证集 2 231 张图片。部分车辆数据集如图 8 所示。

3.2 实验环境和参数设置

本次实验的操作系统为 Windows; CPU 为 13th Gen Intel(R) Core(TM) i5-13600KF; GPU 为显存 12 GB 的 NVIDIA GeForce RTX 4070; 深度学习框架选为 Pytorch。具体环境如表 1



图8 部分车辆数据集图

Fig. 8 Some figures of vehicle datasets

所示。

表1 模型训练环境

Table 1 Model training environment

环境项	环境规格
CPU	Intel(R) Core(TM) i5-13600KF
内存	32 GB
显卡	NVIDIA RTX 4070
操作系统	Windows 11
编程语言	Python 3.9.19
深度学习框架	Pytorch 2.4.0
集成开发环境	Pycharm 社区版
CUDA	12.1
CUDNN	9.0.0

深度学习模型中,超参数的取值会影响模型的检测性能。为了验证本文改进的泛化性,模型超参数均设为经验值。训练轮数为100轮,训练批次大小为16,图像输入尺寸为 640×640 像素,具体参数如表2所示。

3.3 评价指标

为了准确地表示模型在恶劣天气条件下的检测效果,本文采用平均精度均值(mAP@0.5)、模型参数量(Params)、浮点计算量(FLOPs)作为模型性能评价的相关指标。在目标检测算法中,平均精度均值(Mean average precision, mAP)是评价检测性能的重要指标^[20]。平均精度均值反映模型的检测精度,参数量和浮点计算量反映模型的大小和计算复杂度。其中平均精度均值和模型

表2 实验超参数

Table 2 Experimental hyperparameters

超参数	系数值
初始学习率 η_0	0.01
循环学习率 η	0.01
动量 β	0.937
批次大小	16
图片尺寸/像素	640×640
训练轮次	100
预热学习轮数	3.0
预热训练动量	0.8
IoU训练阈值	0.7

的准确率(P)、召回率(R)以及平均精度(AP)有关,准确率的计算公式为:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

召回率计算公式为:

$$R = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

平均精度的计算公式为:

$$AP = \int_0^1 P(R) dR \quad (8)$$

平均精度均值的计算公式为:


$$mAP = \frac{1}{cls} \sum_{i=1}^c AP_i \quad (9)$$

式中:TP为模型正确检测出的目标数;FP为模型错误检测出的目标数;FN为模型未能正确检测出的目标数; cls 为数据集中所有样本的类别数。

3.4 实验结果与分析

3.4.1 引入WT-PSA实验

为验证加入WT-PSA注意力模块后模型对复杂天气状况下的车辆目标检测性能,引入了类激活映射CAM(Class activation mapping)热力图可视化模块。其中,红色区域代表模型重点关注区域,颜色越深表示模型对此区域关注度越高。模型加入WT-PSA注意力模块前后热力图对比如图9所示。观察发现,加入WT-PSA后模型对目标区域的关注度明显提高。



(a) 原图

(b) 未加入WT-PSA时的热力图

(c) 加入WT-PSA时的热力图

图9 WT-PSA加入前后CAM对比图

Fig. 9 Comparison of CAM before and after addition of WT-PSA

3.4.2 消融实验

为了验证改进算法 YOLOv10-vehicle 模型的优化效果,以 YOLOv10n 为基准模型在 UA-DETRAC 数据集进行消融实验,观察模型的平均精度均值(mAP@0.5)、模型参数量(Params)和浮点计算量(FLOPs),实验结果如表 3 所示。由表 3 可知,每项改进都对模型的性能有一定的提升,由此能够证明改进方法的有效性和优越性。

表 3 消融实验结果对比表

Table 3 Comparison table of ablation experiment results

实验序号	WT-PSA	C2f-OD	SP-PF_A	Focal EIoU	Params/ 10 ⁶	FLOPs	mAP 0.5%
1	×	×	×	×	2.70	8.3	82.7
2	✓	×	×	×	3.33	8.8	83.9
3	✓	✓	×	×	3.70	9.0	86.5
4	✓	✓	✓	×	3.75	9.1	86.9
5	✓	✓	✓	✓	3.75	9.1	87.8

注:“✓”表示在模型中使用了该方法;“×”表示在模型中没有使用该方法。

3.4.3 不同目标检测算法对比实验

为进一步验证改进算法性能的优越性,将改进模型与近几年的热门目标检测模型 Faster-RCNN、YOLOv7tiny^[21]、YOLOv8n^[22]、YO-

LOv11n 等进行了对比实验,结果如表 4 所示。由表 4 可知,本文改进算法 YOLOv10-vehicle 相比其他模型,拥有更好的检测性能。为了验证本文改进算法的实际效果,将 YOLOv10n 与改进算法 YOLOv10-vehicle 进行可视化对比,检测结果如图 10 所示。

表 4 不同算法对比实验表

Table 4 Comparison experiment table of different algorithms

Model	Params/ 10 ⁶	GFLOPs	mAP 0.5%	mAP0.5% ~0.95%
Faster-RCNN	36.5	23.3	93.8	60.4
YOLOv7-tiny	6.01	13.2	82.9	54.7
YOLOv8n	3.01	8.2	78.7	50.0
YOLOv10n	2.70	8.3	82.7	57.6
YOLOv10s	8.04	24.6	86.7	59.2
YOLOv11n	2.58	6.3	78.3	50.2
Ours	3.75	9.1	87.8	60.2

通过对比可以看出,YOLOv10n 算法在不良天气下有明显的错检、漏检情况发生,检测精度不高,相较之下,改进算法 YOLOv10-vehicle 在复杂的天气条件下对车辆目标的检测和定位能力更强,在一定程度上缓解了错检、漏检的问题,证明了本文改进算法的有效性。




图 10 YOLOv10-vehicle 模型效果对比图

Fig. 10 Comparison chart of performance of YOLOv10-vehicle model

3.4.4 泛化能力实验

为验证本文 YOLOv10-vehicle 算法的泛化能力,将训练好的模型迁移至公共数据集 VOC 进行实验。应用本文提出的 YOLOv10-vehicle 目标检测算法在 PASCAL VOC 公共数据集上进行实验验证。本文将改进后的 YOLOv10-vehicle 算法和 YOLOv10n 算法在 PASCAL VOC 数据集上进行对比实验。改进前后算法平均精度均值 (mAP@0.5) 对比表如表 5 所示。实验结果表明:虽然改进算法在平均精度均值略有降低,但是车辆类别的准确率提高了 2.8%,证明了本文改进算法对车辆目标检测的提升效果良好,具有一定的泛化能力。

表 5 VOC 数据集对比结果

Table 5 Comparison results on the VOC dataset

Model	mAP@0.5%	mAP@0.5-Car%
YOLOv10n	37.7	52.4
YOLOv10-vehicle	37.3	55.2

4 结束语

针对城市环境复杂天气状况下的车辆目标检测问题,基于 YOLOv10 算法提出了一种改进的 YOLOv10-vehicle 目标检测算法,从特征提取、注意力机制、回归损失函数 3 个方面进行改进。选用有不同天气状况的车辆数据集 UA-DETRAC,并对忽略区域进行了遮蔽处理。设计了改进的 WT-PSA 模块,将 PSA 模块的输入替换为多尺度的深度卷积结果,实现了在复杂天气下视野模糊时,提高模型对车辆目标的关注度。通过在 SPPF 模块中添加平均池化操作起到一定的降噪作用,缓解了因天气情况不佳导致的车辆目标漏检、错检等问题。改进了 C2f 模块,通过引入全维度动态卷积,对物体形状、纹理等特征根据重要性对其进行权重分配,更精准地捕捉输入数据的特征,提高模型的检测精度。最后,引入了 Focal EIoU 损失函数加快模型收敛速度。优化了预测框回归任务中的样本不平衡问题。将改进后的算法 YOLOv10-vehicle 与原算法 YOLOv10n 进行对比实验,实验结果表明:本文算法对城市环境不同天气情况下的车辆目标检测效果更好与不同目标检测算法 (Faster-RCNN、YOLOv7-tiny、YOLOv8n、YOLOv10n、YOLOv10s、YOLOv11n) 相比,本文算法具有更好的检测性能。同时,在视觉

公共数据集 PASCAL VOC 上进行了对比实验,实验结果表明:改进后的 YOLOv10-vehicle 算法相较于原算法在检测车辆目标方面仍具有较好的检测效果。

参考文献:

- [1] 赵奇慧,刘艳洋,项炎平. 基于深度学习的单阶段车辆检测算法综述[J]. 计算机应用, 2020, 40(增刊 2): 30-36.
Zhao Qi-hui, Liu Yan-yang, Xiang Yan-ping. A review of single-stage vehicle detection algorithms based on deep learning[J]. Journal of Computer Applications, 2020, 40 (Sup. 2): 30-36.
- [2] 梁鸿,王庆玮,张千,等. 小目标检测技术研究综述[J]. 计算机工程与应用, 2021, 57(1): 17-28.
Liang Hong, Wang Qing-wei, Zhang Qian, et al. A review of research on small object detection technology[J]. Computer Engineering and Applications, 2021, 57(1): 17-28.
- [3] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, 21(8): 91-103.
- [4] Krizhevsky A, Sutskever I, Hinton E G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [5] Ren S 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] 薛珊,王亚博,吕琼莹,等. 基于YOLOX-drone的反无人机系统抗遮挡目标检测算法[J]. 工程科学学报, 2023, 45(9): 1539-1549.
Xue Shan, Wang Ya-bo, Lü Qiong-ying, et al. Anti-occlusion target detection algorithm for Anti-UAV systems based on YOLOX-drone[J]. Journal of University of Science and Technology Beijing, 2023, 45 (9): 1539-1549.
- [7] 薛珊,卢涛,吕琼莹,等. 基于多尺度融合和轻量化网络的无人机目标检测算法[J]. 湖南大学学报: 自然科学版, 2023, 50(8): 82-93.
Xue Shan, Lu Tao, Lyu Qiong-ying, et al. UAV Target detection algorithm based on multi-scale fusion and lightweight network [J]. Journal of Hunan University(Natural Sciences), 2023, 50(8): 82-93.
- [8] 薛珊,张亚亮,吕琼莹,等. 复杂背景下的反无人机

- 系统目标检测算法[J]. 吉林大学学报:工学版, 2023, 53(3): 891-901.
- Xue Shan, Zhang Ya-liang, Lü Qiong-ying, et al. Target detection algorithm for Anti-UAV systems in complex backgrounds[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(3): 891-901.
- [9] 周飞, 郭杜杜, 王洋, 等. 基于改进YOLOv8的交通监控车辆检测算法[J]. 计算机工程与应用, 2024, 60(6): 110-120.
- Zhou Fei, Guo Du-du, Wang Yang, et al. Traffic monitoring vehicle detection algorithm based on improved YOLOv8[J]. Computer Engineering and Applications, 2024, 60(6): 110-120.
- [10] 许德刚, 王双臣, 王再庆, 等. 改进YOLOv8算法的城市车辆目标检测[J]. 计算机工程与应用, 2024, 60(18): 136-146.
- Xu De-gang, Wang Shuang-chen, Wang Zai-qing, et al. Urban Vehicle target detection algorithm based on improved YOLOv8[J]. Computer Engineering and Applications, 2024, 60(18): 136-146.
- [11] 张利丰, 田莹. 改进YOLOv8的多尺度轻量级车辆目标检测算法[J]. 计算机工程与应用, 2024, 60(3): 129-137.
- Zhang Li-feng, Tian Ying. An improved YOLOv8-based multi-scale lightweight vehicle object detection algorithm[J]. Computer Engineering and Applications, 2024, 60(3): 129-137.
- [12] 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, Las Vegas, USA, 2016: 779-788.
- [13] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017: 6517-6525.
- [14] Redmon J, Farhadi A. YOLOv3: an incremental improvement[C]//IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 774-782.
- [15] Bochkovskiy A, Wang C Y, Liao H. YOLOv4: optimal speed and accuracy of object detection[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2004.10934>.
- [16] 薛珊, 陈宇超, 吕琼莹, 等. 基于双支路神经网络的无人机图像识别方法[J]. 计算机仿真, 2023, 40(7): 233-238.
- Xue Shan, Chen Yu-chao, Lü Qiong-ying, et al. UAV Image recognition method based on dual-branch neural network[J]. Computer Simulation, 2023, 40(7): 233-238.
- [17] Wang A, Chen H, Liu L H, et al. YOLOv10: real-time end-to-end object detection[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2405.14458>.
- [18] Ben-Hamu H, Wolf L, Polyak A. Wavelet convolutions for large receptive fields[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2407.05848v2>.
- [19] Yao A, Shen Y, Guo Y. Omni-dimensional dynamic convolution[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2209.07947>.
- [20] Zhang Y, Ren W, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2101.08158>.
- [21] 薛珊, 张振, 吕琼莹, 等. 基于卷积神经网络的反无人机系统图像识别方法[J]. 红外与激光工程, 2020, 49(7): 250-257.
- Xue Shan, Zhang Zhen, Lü Qiong-ying, et al. Image recognition method of anti-UAV system based on convolutional neural network[J]. Infrared and Laser Engineering, 2020, 49(7): 250-257.
- [22] Jocher G, Chaurasia A, Qiu J. YOLO by ultralytics[J/OL]. [2020-04-23]. <https://arxiv.org/pdf/2305.06972>.