

# 基于改进 YOLOv8s 的恶劣天气车辆行人检测方法<sup>\*</sup>

梁天添 杨淞淇 钱振明

(大连交通大学自动化与电气工程学院 大连 116028)

**摘要:** 针对恶劣天气条件下摄像头捕获图像时存在图像模糊以及光照分布不均等问题,导致了场景对比度的下降,进而增加了在图像中区分检测目标与背景的难度。为了提高在恶劣天气环境下车辆和行人的检测能力,本文提出了一种改进的 YOLOv8s 算法。首先,本文在 YOLOv8s 算法的基础上,利用可扩张残差结构对主干网络中的 C2F 模块进行了优化,增强了模型对环境变化的适应能力。同时,在主干网络的 SPPF 模块前置层引入了高效多尺度注意力机制,该机制能够更有效地捕获图像中丰富多变的多尺度特征。其次,针对 YOLOv8s 算法的检测头部进行了重新设计,在保持模型准确性的前提下,降低了模型的复杂度。最后,引入 Wise-IoU 改进 YOLOv8s 算法的回归损失函数,提高了算法的收敛速度和检测精度。实验结果表明,改进的 YOLOv8s 算法在恶劣天气条件下对车辆和行人检测的平均精度均值达到 91.41%,相比原始算法提升了 2.56%,同时模型参数量减少了 8%,计算量降低了 4.9 GFLOPs。相比于其他主流的目标检测算法,改进后的 YOLOv8s 算法在保证了实时性能的同时,满足了恶劣天气条件下的车辆和行人检测需求。

**关键词:** 恶劣天气条件; YOLOv8s; 目标检测; 注意力机制; Wise-IoU

中图分类号: TP391.4; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

## Improved YOLOv8s method for vehicle and pedestrian detection in adverse weather

Liang Tiantian Yang Songqi Qian Zhenming

(School of Automation and Electrical Engineering, Dalian Jiaotong University, Dalian 116028, China)

**Abstract:** Addressing the issues of image blurring and uneven light distribution encountered when capturing images in adverse weather conditions, which lead to decreased scene contrast and subsequently increase the difficulty of distinguishing detection targets from the background in images, this paper proposes an improved YOLOv8s algorithm to enhance the detection capability of vehicles and pedestrians in harsh weather environments. Firstly, based on the YOLOv8s algorithm, this paper optimizes the C2F module in the backbone network with an expandable residual structure, enhancing the model's adaptability to environmental changes. At the same time, an efficient multi-scale attention mechanism is introduced before the SPPF module in the backbone network, which can more effectively capture the rich and varied multi-scale features in images. Secondly, the detection head of the YOLOv8s algorithm is redesigned to reduce the model's complexity while maintaining accuracy. Finally, the introduction of Wise-IoU improves the regression loss function of the YOLOv8s algorithm, enhancing the algorithm's convergence speed and detection accuracy. Experimental results show that the improved YOLOv8s algorithm achieves a mean average precision of 91.41% on datasets for vehicle and pedestrian detection under adverse weather conditions, which is a 2.56% improvement over the original algorithm, with a model parameter reduction of 8% and a computational reduction of 4.9 GFLOPs. Compared to other mainstream object detection algorithms, the significantly improved YOLOv8s algorithm not only ensures real-time performance but also effectively meets the challenging requirements for vehicle and pedestrian detection under adverse weather conditions.

**Keywords:** adverse weather conditions; YOLOv8s; object detection; attention mechanism; Wise-IoU

## 0 引言

近年来,目标检测技术在交通监控和自动驾驶领域的

应用已经实现了突破性进展,这不仅促进了智能交通系统的发展,还显著提升了道路安全水平。随着人们对车辆行驶安全的关注日益增加,自动驾驶汽车在恶劣天气条件下

的目标检测性能已成为该研究领域的焦点。尽管如此,目前大多数目标检测算法主要在理想光照和气候条件下进行测试与优化,这种局限性在实际应用中变得尤为突出。例如,在夜间、雨天、雾天和雪天等恶劣天气条件下,摄像头捕获的图像往往因模糊和光照不均等因素而严重影响目标检测的精确度和稳定性<sup>[1-2]</sup>。

随着深度学习技术的快速发展,基于深度神经网络的目标检测方法已经逐渐占据了该研究领域的前沿,特别是两阶段目标检测算法如 R-CNN(region-based convolutional neural network)系列和单阶段目标检测算法如 YOLO(you only look once)<sup>[3]</sup> 系列和 SSD (single shot multibox detector)<sup>[4]</sup>,这两类算法分别在精度与检测速度方面展现出了各自的优势。Yao 等<sup>[5]</sup>提出了一种自适应颜色级别矫正的数据处理方法来增加自动驾驶车辆在恶劣天气条件下的目标检测能力。该数据处理方法有效提高了恶劣天气条件下待检测目标的清晰度,并将 Transformer 和卷积注意力模块(convolutional block attention module, CBAM)结合到 YOLOv5 算法中来优化算法的主干网络,提升了恶劣天气条件下的目标检测精度。张蕊等<sup>[6]</sup>针对夜间行驶车辆面临的车辆检测难题,提出了一种基于改进 YOLOv5s 算法的解决方案,构建了基于注意力机制的特征金字塔网络(feature pyramid network, FPN)结构,同时在路径聚合网络(path aggregation network, PAN)中引入了空洞卷积(dilated convolution, DConv),提升了检测精度。隗寒冰等<sup>[7]</sup>提出了一种考虑目标遮挡和融合历史轨迹的智能车辆多目标检测算法,通过应用网状分类器和多尺度滑动窗口技术,成功地实现了在光照突变、阴雨天气等复杂条件下的高效检测。周飞等<sup>[8]</sup>提出了一种改进的 YOLOv8 算法,有效解决了复杂交通监控场景下车辆检测精度不足的问题。该算法通过改进原始模型的主干网络并增加小目标检测层实现检测精度的提升,但其并未考虑到引入小目标检测层后大幅增加了模型计算量。岳凯等<sup>[9]</sup>提出了 YOLOv8-MEIN,通过设计高效卷积模块和引入 Inner-CIoU 损失函数,有效解决了目标存在重叠或遮挡的检测难题,但面对目标特征模糊及图像质量下降的问题,检测精度仍有进一步提升的空间。

尽管上述研究都取得了一定的进展,但在面对恶劣天气条件下的目标检测任务时仍存在一些问题需要解决。首先,现有的方法在应对恶劣天气下众多复杂背景和低对比度场景时,检测精度和泛化性能仍有待提高。其次,现有改进方案往往增加了模型的计算复杂度和参数量,影响了实际应用中的实时性能。因此,针对 YOLOv8s 原始模型在面对遮挡和反光等复杂背景时的特征提取能力有限、检测头部的双分支解耦结构大幅增加模型复杂度等问题,本文基于 YOLOv8s 模型提出了一种改进的目标检测算法,相比于现有的改进方案,本文改进算法不仅关注模型在多种恶劣天气下的检测精度,同时兼顾了模型的实时性能,本文

的主要贡献如下:首先,由于恶劣天气条件下的车辆行人数据集不足,使用工业相机在雨、雪、雾以及夜间等多种恶劣天气条件下,对不同的道路场景进行了广泛的图像采集。并对采集到的图像进行了精确的人工标注,主要包括车辆、行人以及其他可能的障碍物,创建了恶劣天气条件下的车辆和行人检测数据集;然后,在模型主干网络中引入基于可扩张残差(dilation-wise residual, DWR)结构的 C2F-DWR 模块,用于提高网络的特征提取能力,并在 SPPF 模块的前置层引入高效多尺度注意力 (efficient multi-scale attention, EMA)机制<sup>[10]</sup>,捕获图像中不同尺度的上下文信息,进而增强算法在恶劣天气条件下的鲁棒性;其次,通过引入 FasterNet Block,对原有算法的检测头部进行重新设计,此项改进旨在不过多牺牲模型精度的情况下,有效减少 YOLOv8s 模型检测头部的冗余参数;最后,通过引入 WIoU(wise-iou)<sup>[11]</sup> 损失函数对算法的回归损失函数 CIoU 进行优化。使得模型能够聚焦于质量较低的困难样本,进一步增强了模型的泛化性能。

## 1 YOLOv8s 基础模型

YOLOv8s 作为 YOLO 系列算法的代表模型,继承并优化了之前的设计理念,该模型能够在目标检测任务中达到更高的准确度与速度。YOLOv8s 总体架构被划分为 3 个主要部分:主干网络、颈部网络和头部网络<sup>[12]</sup>。在主干网络部分,YOLOv8s 引进了梯度流更为丰富的 C2F 结构和 SPPF 模块。颈部网络仍是基于 FPN 和 PAN 构建;FPN 通过融合多个尺度的特征图来增强模型对不同尺寸物体的检测能力,而 PAN 通过自上而下与自下而上的路径聚合进一步改善了特征间的信息流动,提升了特征融合的效率和有效性。头部网络采用了 Anchor-free 的检测机制,能够直接预测目标的中心位置及其宽高比,显著减少了模型对边界框的依赖。此外,使用解耦头设计,通过两个独立的卷积分支分别进行分类任务和回归任务,分类任务采用 VFL Loss,回归任务将 DFL Loss 和 CIoU 损失函数结合使用,YOLOv8s 的具体网络结构如图 1 所示。

## 2 YOLOv8s 改进模型

### 2.1 改进模型介绍

本文深入研究并改进了 YOLOv8s 网络模型,主要从主干网络、检测头及损失函数 3 个方面进行了针对性的优化。改进后的 YOLOv8s 模型结构如图 2 所示。

首先,在主干网络中引入了基于可扩张残差结构的 C2F-DWR 模块,以及在 SPPF 模块的前置层加入了 EMA 机制,用于增强网络的特征提取能力。其次,通过引入 FasterNet Block 对模型的检测头部进行了优化,有效减少了模型检测头的冗余参数。最后,采用 WIoU 损失函数替代传统的 CIoU 损失函数,用于优化模型的回归损失,以提升模型在恶劣天气条件下的检测精度。

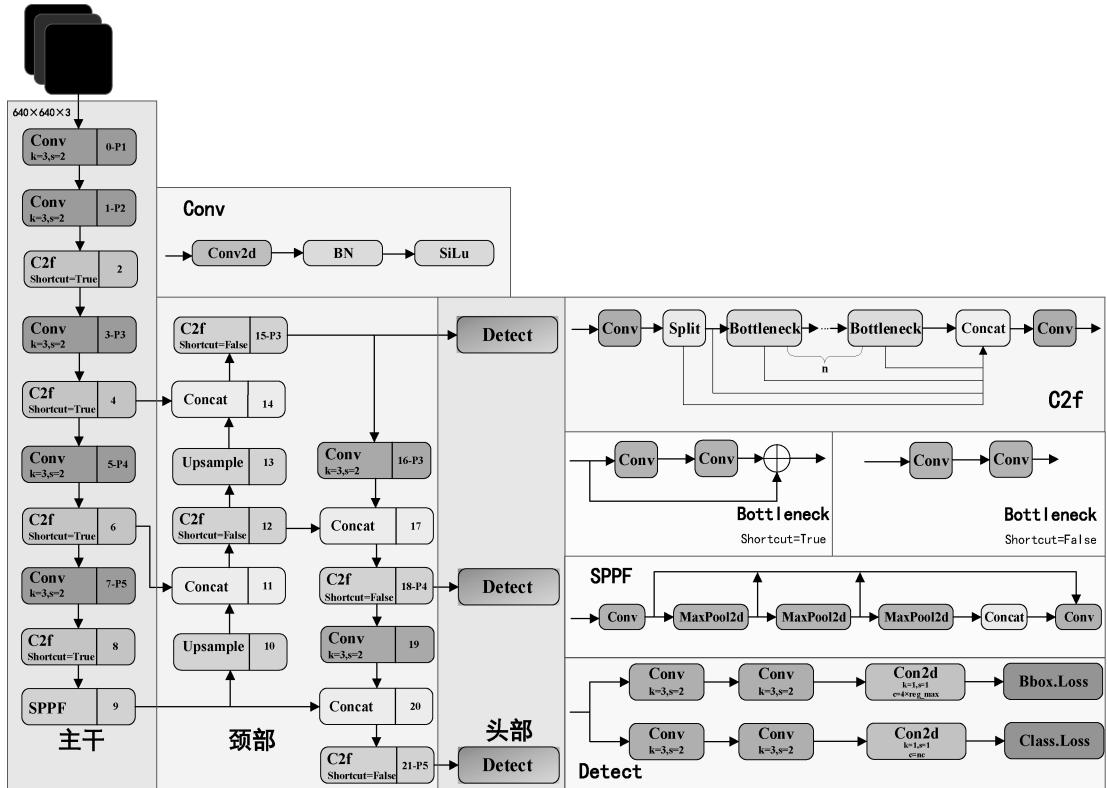


图 1 YOLOv8s 网络结构图

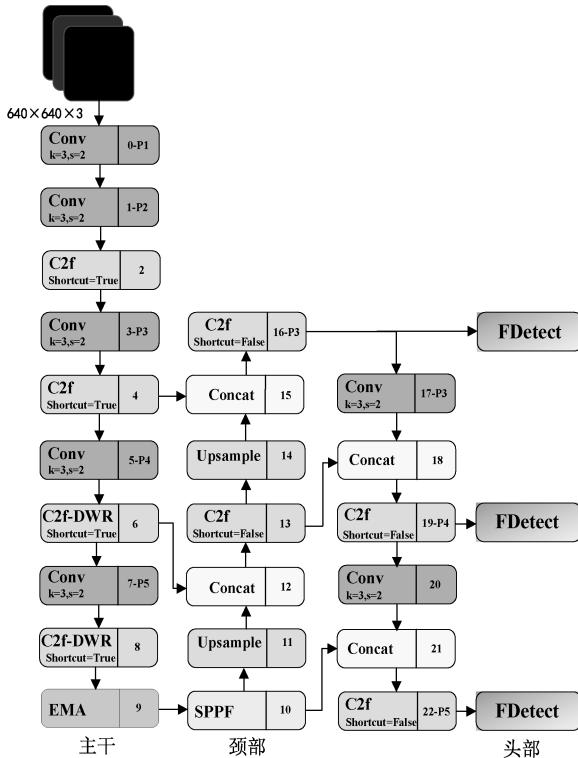


图 2 改进 YOLOv8s 模型结构图

## 2.2 C2F-DWR 模块

通过替换原 YOLOv8s 模型 C2F 模块中的瓶颈结构

为 DWR 结构, 构建了 C2F-DWR 模块。同时考虑到模型复杂度的因素, 最终决定在模型主干网络的第 6 和 8 层使用 C2F-DWR 模块。

在恶劣天气条件下的目标检测任务中, 由于图像质量显著降低, 不仅增加了从图像中提取特征的难度, 还可能导致图像中的局部信息被遮挡或模糊。然而, DWR 模块凭借其创新的两步法——区域残差化和语义残差化, 有效地捕捉了不同尺度的特征信息, DWR 模块的完整结构如图 3 所示。

### 1) 区域残差化

区域残差化旨在通过输入特征生成具有简洁区域表达的特征图, 这些特征图反映了图像中不同大小的区域。此过程主要通过应用  $3 \times 3$  的卷积层、批量归一化层以及  $ReLU$  激活层实现, 输出区域特征图  $C_1(x)$  可以表示为:

$$C_1(x) = ReLU(BN(Conv^{3 \times 3}(x))) \quad (1)$$

式中:  $x$  表示输入特征图,  $Conv^{3 \times 3}(\cdot)$  表示  $3 \times 3$  卷积,  $BN(\cdot)$  表示批量归一化,  $ReLU(\cdot)$  表示激活操作。

### 2) 语义残差化

语义残差化通过使用不同空洞率的 DConv 对分成 3 组的区域特征图进行处理。每个不同空洞率的 DConv 相当于在不同尺度上进行特征提取。通过这种方式, DWR 能够对每个特征通道应用最合适的感受野大小, 从而有效地聚合多尺度信息。输出  $C_2(x, d)$  表示为:

$$C_2(x, d) = DConv_d(C_1(x)) \quad (2)$$

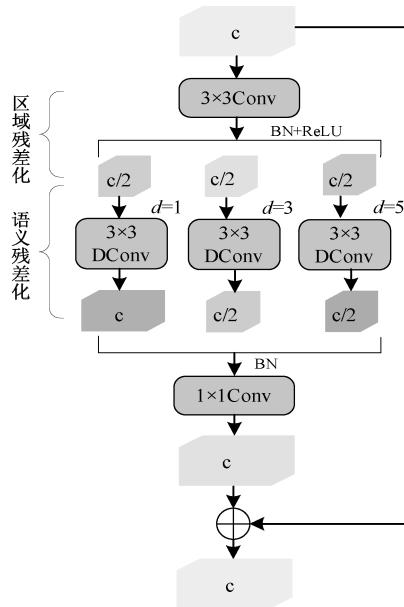


图 3 DWR 模块结构图

式中:  $d$  表示空洞率,  $DConv_d(\cdot)$  表示空洞率为  $d$  的  $3 \times 3$  空洞卷积。

在输入特征图经过区域残差化与语义残差化提取多尺度特征之后将不同分支进行拼接,再通过  $1 \times 1$  卷积层进行融合,同时将通道数降维至原始形状。此过程完成后,将处理后的特征图与原始特征图进行残差连接,最终输出结果  $DWR(x)$  可以表示为:

$$DWR(x) = Conv^{1 \times 1}(BN(\Gamma_d\{C_2(x, d)\})) + x \quad (3)$$

式中:  $Conv^{1 \times 1}(\cdot)$  表示  $1 \times 1$  卷积,  $\Gamma_d(\cdot)$  表示所有不同空洞率空洞卷积的级联运算。

### 2.3 EMA 机制

EMA 采用跨空间学习方法,通过将特征图按通道维度分成多个子特征,使得空间特征在每个特征组内均匀分布。这种设计使得 EMA 能够更加有效的利用空间语义信息。EMA 与传统的注意力机制通过降维来减少计算量不同,它在并行分支中编码全局信息来重新校准每个通道的注意力权重。这种设计不仅增强了模型对多尺度特征的提取能力,同时节约了计算成本,其结构如图 4 所示。

由于恶劣天气条件下图像的数据分布可能与训练数据集存在一定差异,本文引入的 EMA 机制能够有效地融合跨空间信息和多尺度特征,进一步增强模型的泛化能力,使得模型能够更加灵活地适应于多变的视觉环境。

如图 4 所示,针对给定输入特征图  $X \in \mathbf{R}^{C \times W \times H}$ , EMA 将会把  $X$  沿着跨通道维度方向分割为  $G$  组子特征,用于学习不同的语义信息,其中每个分组的样式可以表示为  $X = [X_0, X_1, \dots, X_{G-1}]$ ,  $X_i \in \mathbf{R}^{C/G \times H \times W}$ , 通过学习到的注意力权重,增强每组子特征中重要区域的表达能力。对于每组子特征,采用 3 条并行路径分别提取注意力权重,其中包括两个  $1 \times 1$  卷积分支和一个  $3 \times 3$  卷积分支。 $1 \times 1$  卷积

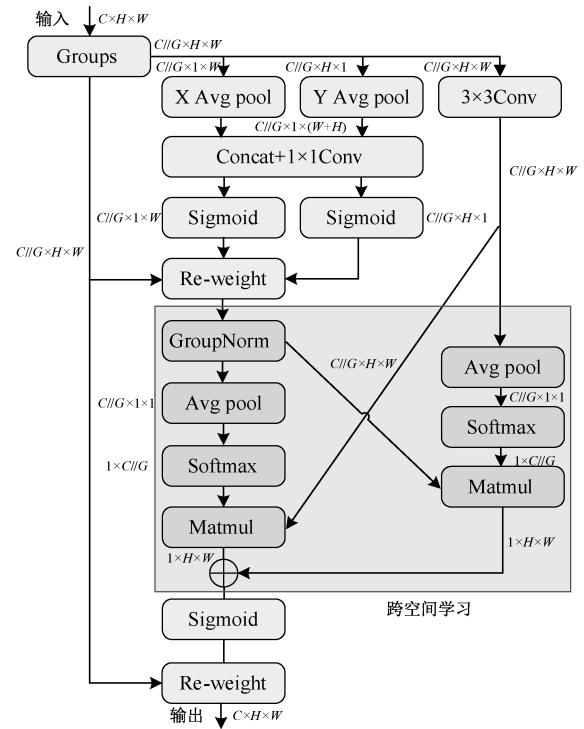


图 4 EMA 机制结构图

分支使用自适应全局平均池化分别沿水平和竖直方向进行池化操作,然后对两个分支的输出进行拼接,并经过共享  $1 \times 1$  卷积进行聚合,最后分别经过激活层进行非线性拟合;第 3 个分支通过单个  $3 \times 3$  卷积捕获多尺度特征表示。在跨空间学习部分,通过对  $1 \times 1$  卷积分支和  $3 \times 3$  卷积分支的输出进行全局平均池化编码,随后使用矩阵乘法操作融合不同分支的注意力权重<sup>[13]</sup>。这一过程有效地聚合了来自不同尺度的空间信息,得到了最终的特征表示。

### 2.4 检测头改进

对原始 YOLOv8s 模型的检测头进行优化,将其由双分支解耦结构改进为单分支结构,并引入 FasterNet Block 构建 FDetect(faster detect),用于降低模型复杂度,从而加速模型运算。特征图在经过 FasterNet Block 处理后,再经  $1 \times 1$  卷积层对输出特征图进行特征融合,最后通过维度变换,分别执行分类和回归任务, FDetect 结构如图 5 所示。

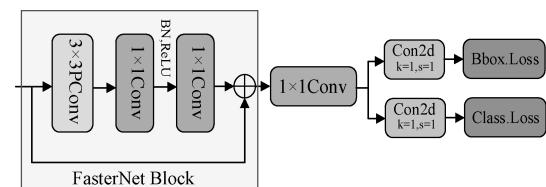


图 5 FDetect 结构图

FasterNet Block 是 Chen 等<sup>[14]</sup>提出的一种高效的神经网络模块,专门设计用于加速深度学习模型的推理速度,同时保持甚至提高模型的性能。FasterNet Block 的基本结构采用了部分卷积(partial convolution, PConv)加  $1 \times 1$

卷积的结构, PConv 的核心思想是通过对输入特征图的一个子集进行卷积操作, 以此来减少计算负担同时保证关键信息的传递, PConv 的结构如图 6 所示。

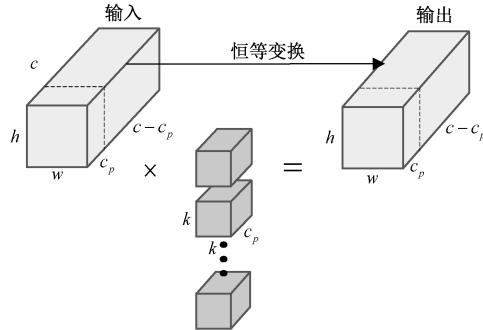


图 6 PConv 结构图

如图 6 所示, 假定输入和输出的特征图的尺寸为  $X \in \mathbf{R}^{H \times W \times c}$ , 卷积核的尺寸为  $F \in \mathbf{R}^{k \times k}$ , 则传统卷积操作的计算量 FLOPs 可以表示为:

$$FLOPs = H \times W \times c \times k^2 \times c \quad (4)$$

式中:  $H$  和  $W$  分别表示特征图的高和宽,  $c$  表示特征图的通道数,  $k$  表示卷积核的尺寸。

PConv 的 FLOPs 可以表示为:

$$FLOPs = H \times W \times c_p \times k^2 \times c_p \quad (5)$$

式中:  $c_p$  表示特征图中进行卷积操作的通道数。

## 2.5 Wise-IoU 损失函数

在 YOLOv8s 算法中, 损失函数由分类损失与回归损失两部分构成。回归损失将 DFL Loss 与 CIoU 损失结合使用。CIoU 在处理边界框时采用了相对静态的方法, 并不具有专门的机制来加强对中等质量边界框的关注。这种做法可能导致无法充分利用某些数据资源, 并且在处理低质量训练数据时, 模型的泛化能力可能会受到较大影响。由于在恶劣天气条件下的数据质量通常较差, 本文采用 WIoUv3 损失来改进 CIoU 损失, 确保有效关注那些质量中等的边界框, 同时减少低质量样本对模型训练的负面影响<sup>[15]</sup>。WIoU 参数示意图如图 7 所示, WIoU 共有 3 个版本, 分别是 WIoUv1、WIoUv2、WIoUv3, v1 版本引入了两层注意力机制, 通过动态调整来加强对特定质量锚框的关注,  $L_{WIoUv1}$  可以表示为:

$$L_{WIoUv1} = R_{WIoU} L_{IoU} \quad (6)$$

$$R_{WIoU} = \exp \left( \frac{(x - x^{gt})^2 + (y - y^{gt})^2}{(W_g^2 + H_g^2)^*} \right) \quad (7)$$

式中:  $R_{WIoU}$  表示基于距离的惩罚项,  $L_{IoU}$  表示边界框损失,  $W_g$  和  $H_g$  分别表示最小包围框的宽和高,  $x$  和  $y$  分别表示预测框中点的横纵坐标,  $x^{gt}$  和  $y^{gt}$  分别表示真实框的中心点坐标,  $*$  表示将  $W_g$  和  $H_g$  从计算图中分离。

v3 版本则引入了动态非单调聚焦机制, 通过评估边界框的离群度来动态调整梯度增益,  $L_{WIoUv3}$  可以表示为:

$$L_{WIoUv3} = r L_{WIoUv1} \quad (8)$$

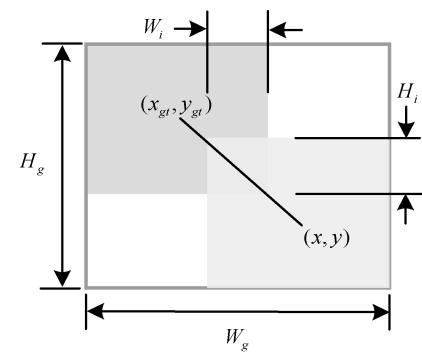


图 7 WIoU 参数示意图

$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (9)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (10)$$

式中:  $r$  是根据离群度  $\beta$  动态计算的非单调聚焦系数,  $\alpha$  和  $\delta$  是用于控制聚焦强度的超参数, 本文实验中分别将  $\alpha$  和  $\delta$  设置为 1.7 和 2.7,  $L_{IoU}^*$  表示滑动平均值。

在训练过程中,  $L_{IoU}$  是动态变化的, 因此边界框的质量划分标准也是动态的, 这使得 WIoUv3 可以动态的聚焦于数据集中的中低质量样本。

## 3 实验分析

### 3.1 实验环境与数据

操作系统采用 Windows 10, 搭载 NVIDIA GeForce RTX 3080 Ti GPU, 12 GB 显存。处理器为 Intel(R) Core (TM) i7-10700 2.90 GHz, 配备 64 GB 运行内存。本实验基于 CUDA 11.7 和 Pytorch 1.13 版本, 使用 Python 3.8 作为编程语言, 编译器为 Pycharm。

本文针对恶劣天气条件下的路面信息自制了共 7 357 张图像的数据集。这些图像覆盖了雪天、夜间、雾天和雨天 4 种不同的恶劣天气情况。数据集被划分为 4 个主要类别: 人、车辆、摩托车、狗。所有图像均在辽宁省大连市不同街道采集, 并自主完成图像的标注工作, 数据集部分样本如图 8 所示。



图 8 数据集部分样本图

数据集按照 8:2 的比例划分为训练集和验证集, 输入图像的尺寸设定为  $640 \times 640$ 。训练过程将批次大小设为 32, 共进行 200 轮训练, 初始学习率设定为 0.01, 并使用随机梯度下降作为优化算法, 后续实验均使用相同参数。

### 3.2 评价指标

本文采用平均精度均值 (mean average precision, mAP) 评价模型的性能。模型参数量、每秒十亿次的浮点计算数 (GFLOPs) 评价的模型复杂度。mAP 表示每个类别平均精度 (average precision, AP) 的平均值。AP 表示精度-召回率曲线下的面积, AP、mAP 计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

$$AP = \int_0^1 P(R) dR \quad (13)$$

$$mAP = \frac{\sum P}{Num(class)} \quad (14)$$

式中:  $P$  表示精度,  $R$  表示召回率,  $TP$  代表正确预测正样本的数量, 反映模型正确识别正样本的能力。 $FP$  代表被错误预测为正样本的负样本数,  $FP$  较高表示模型容易出现误报。 $FN$  代表被错误预测为负样本的正样本数,  $FN$  较高表示模型容易出现漏报<sup>[16]</sup>,  $class$  代表类别。

### 3.3 损失函数对比实验

为了验证不同损失函数对模型的影响, 使用 YOLOv8s 作为基准模型, 分别选择 SIoU、EIoU、DIoU, 以及 WIoU 的 3 个版本进行对比实验, 实验结果如表 1 所示。

表 1 不同损失函数对比

基准模型	损失函数	mAP0.5/%
YOLOv8s	CIoU	88.85
	SIoU	88.78
	EIoU	88.67
	DIoU	88.95
	WIoUv1	89.91
	WIoUv2	89.95
	WIoUv3	90.08

由表 1 数据分析可得, WIoUv3 在对比实验中展现出了显著优于其他损失函数的性能。鉴于实验数据集中包含大量中低质量样本数据, WIoUv3 相较于原始的 CIoU 损失函数, 在 mAP@0.5 指标上提升了 1.23%。因此, 经过综合考量, 最终选择引入了动态非单调聚焦机制的 WIoUv3 作为改进模型的损失函数。

### 3.4 注意力机制对比实验

在注意力机制的对比实验中, 将加入 WIoU 损失函数的 YOLOv8s 模型作为基准模型, 共使用 7 种注意力机制进行对比, 包括 SEAttention, EffectiveSE, SimAM, BAM,

GAM, CA, EMA, 实验结果如表 2 所示。

表 2 注意力机制对比实验

注意力机制	参数量/M	mAP0.5/%	GFLOPs
SEAttention	11.19	89.82	28.8
EffectiveSE	11.42	89.73	28.8
SimAM	11.16	90.05	28.8
BAM	11.24	90.02	28.9
GAM	17.72	90.37	34.1
CA	11.19	90.61	28.8
EMA	11.20	91.06	29.1

由表 2 数据分析可得, 在加入不同注意力机制后, 网络模型的 mAP@0.5 指标变动幅度普遍较小。其中, EMA 机制的对模型性能的提升最为有效。尽管 EMA 机制使得模型的计算量略有增加, 但它确保了以最小的计算成本增量实现了模型性能的有效提升, 在权衡模型的检测性能和复杂度之后, 选用 EAM 机制对 YOLOv8s 模型进一步改进。

### 3.5 模型对比实验

为验证改进模型的有效性, 使用相同训练参数与当前主流的单阶段目标检测算法包括 SSD、YOLOv6、YOLOv7 和文献[8]等模型进行对比实验, 实验结果如表 3 所示。

表 3 不同模型对比实验

模型	参数量/M	mAP0.5/%	GFLOPs
SSD	26.4	79.81	63.9
YOLOv6s	18.6	87.61	46.9
YOLOv7	37.5	83.36	105.3
YOLOv8s	11.16	88.85	28.8
文献[8]	11.91	89.87	38.5
Ours	10.32	91.41	23.9

由表 3 数据分析可得, 本文改进模型的 mAP@0.5 指标达到了最高的 91.41%, 与其他模型相比具有较高的检测性能。在计算复杂度方面, YOLOv7、SSD 的计算量分别为 105.3 GFLOPs 和 63.9 GFLOPs, 表明这两种算法的模型复杂度较高。文献[8]中的模型计算量为 38.5 GFLOPs, 而改进后的模型计算量仅为 23.9 GFLOPs, 相比于原始模型降低了 17%。通过对比实验可以得出, 本文的改进模型在满足实时处理需求的同时具有较优的检测性能。

### 3.6 消融实验

为探究各项改进措施对模型性能的影响, 在自制数据集上进行消融实验。以 YOLOv8s 为基准模型, 分别引入 WIoUv3 损失函数、EMA 机制、C2F-DWR 模块以及 FDetect 检测头。如表 4 所示, 基准模型 YOLOv8s 在恶劣天气条件数据集中的 mAP@0.5 为 88.85%。通过将

ClIoU 损失函数改进为 WIoUv3, 模型的 mAP@0.5 指标提高至 90.08%, 这一结果证实了 WIoUv3 在减少数据集中低质量样本对模型训练干扰的有效性。进一步地, 在将 EMA 机制加入至模型的主干网络后, 模型参数量和计算量分别达到 11.2 M 和 29.1 GFLOPs, mAP@0.5 指标提升了 0.98%。表明 EMA 机制能够在小幅增加模型复杂度的情况下, 提高模型性能。通过将 C2F 模块替换为 C2F-DWR 模块, mAP@0.5 指标提升至 91.49%, 相较于

原始模型提高了 2.64%, 同时参数量和计算量均有所降低, 表明 DWR 模块能够通过其分阶段设计, 有效提升模型对多尺度特征的捕获能力同时减少计算复杂度。最后, 采用 FDetect 作为检测头, 虽然 mAP@0.5 下降了 0.08%, 但参数量和计算量相较于原始模型分别减少了 0.84 M 和 4.9 GFLOPs, 说明 FDetect 能在微小的精度损失下, 减少模型的复杂度。综上所述, 本文提出的改进模型满足了恶劣天气条件下目标检测任务的需求。

表 4 消融实验

实验次数	WIoUv3	EMA	C2F-DWR	FDetect	参数量/M	mAP0.5/%	GFLOPs
1	×	×	×	×	11.16	88.85	28.8
2	√	×	×	×	11.16	90.08	28.8
3	√	√	×	×	11.20	91.06	29.1
4	√	√	√	×	10.96	91.49	28.7
5	√	√	√	√	10.32	91.41	23.9

### 3.7 模型检测结果对比

为了进一步评估改进模型在实际应用场景中的性能, 从数据集中分别挑选了在雪天、夜间、雾天和雨天条件下的数据样本, 与文献[8]模型进行了对比实验。实验结果如图 9 所示。如图 9(a)所示, 展示了雪天条件下, 对比模型由于图像质量较低以及目标物体轮廓模糊, 将行人错误的识别为摩托车。如图 9(b)和(c)所示, 分别展示了在夜

间和雾天条件下, 由于能见度较低和光照不足等因素, 对比模型出现了漏检、错检问题。图 9(d)展示了在雨天条件下, 当视线被雨水遮挡时, 对比模型未能检测出距离较远的小型目标车辆, 而本文模型则能够成功识别这些车辆。通过上述对比实验结果, 充分验证了本文所提出的改进 YOLOv8s 模型在各种恶劣天气条件下的检测性能以及在实际应用场景中的有效性。

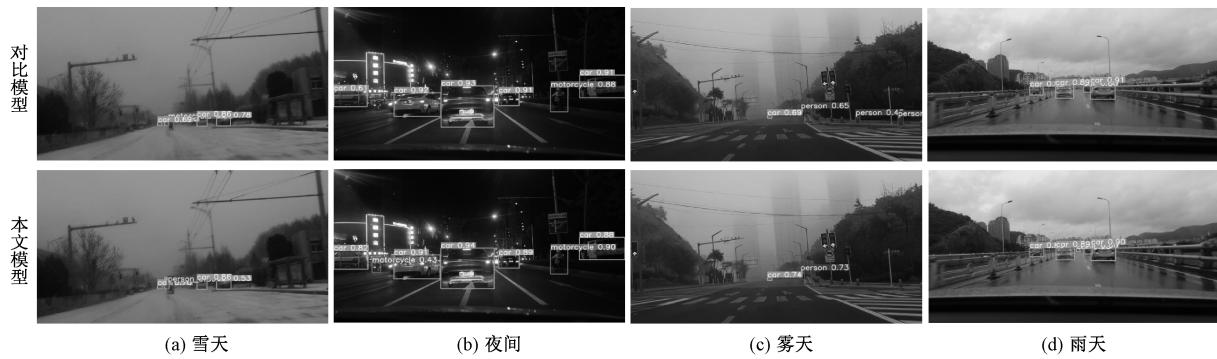


图 9 检测结果对比

## 4 结论

为在恶劣天气条件下提升车辆行人检测的准确性与实时处理能力, 本文提出了一种基于 YOLOv8s 的改进模型。通过引入可扩张残差结构, 构建 C2F-DWR 模块, 增强了模型对复杂环境变化的适应性。同时, 在 SPPF 模块的前置层引入了 EMA 机制, 可以使模型有效捕捉来自不同尺度的上下文信息。为了在不牺牲过多检测性能的前提下降低模型复杂度, 对检测头部进行了优化。采用 WIoU 损失函数对原始模型的损失函数进行改进, 提高模型的收敛速度和精度。实验结果表明, 改进后的模型在恶劣天气条件车辆行人数据集上的 mAP@0.5 指标提升了 2.56%。

同时, 模型的参数量和计算复杂度得到了有效控制和减少。因此, 本文提出的改进模型满足了恶劣天气条件下车辆与行人检测任务的需求, 为自动驾驶系统在复杂气候条件下的应用提供了支持。

未来的研究将专注于模型轻量化方向, 通过量化、网络剪枝、知识蒸馏等方式对复杂度较高的模型进行优化。进一步减少模型轻量化对精度造成的影响。

## 参考文献

- [1] 范佳琦, 李鑫, 霍天娇, 等. 基于单阶段算法的智能汽车跨域检测研究[J]. 中国公路学报, 2022, 35(3): 249-262.
- [2] 袁磊, 唐海, 陈彦蓉, 等. 改进 YOLOv5 的复杂环境

- 道路目标检测方法[J]. 计算机工程与应用, 2023, 59(16): 212-222.
- [3] REDMON J, DIVVALA S, GIRCHICK R, et al. You only look once Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016.
- [5] YAO J, FAN X, LI B, et al. Adverse weather target detection algorithm based on adaptive color levels and improved YOLOv5[J]. Sensors, 2022, 22(21): 8577.
- [6] 张蕊, 高诗博, 赵霞, 等. 基于改进 YOLOv5s 的无人驾驶夜间车辆目标检测算法[J]. 电子测量技术, 2023, 46(17): 87-93.
- [7] 魏寒冰, 陈尧, 贾志杰, 等. 融合历史轨迹的智能汽车城市复杂环境多目标检测与跟踪算法[J]. 西安交通大学学报, 2018, 52(10): 132-140.
- [8] 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.
- [9] 岳凯, 张鹏超, 王磊, 等. 基于改进 YOLOv8n 的复杂环境下柑橘识别[J]. 农业工程学报, 2024, 40(8): 1-7.
- [10] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE, 2023.
- [11] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [12] 陈伟, 王晓龙, 张晏玮, 等. 基于改进 YOLOv8 的高速公路服务区车辆违停检测[J]. 计算机工程, 2024, 50(4): 11-19.
- [13] 李韬, 任玲, 胡斌, 等. 改进 YOLOv5s 和迁移学习对番茄穴盘苗的分级检测[J]. 农业工程学报, 2023, 39(23): 174-184.
- [14] CHEN J H, KAO S, HE H, et al. Run, Don't walk: Chasing higher FLOPS for faster neural networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023.
- [15] 王铖浩, 骆忠强, 漆梓渊. 基于改进 YOLOv5 的变压器漏油检测[J]. 国外电子测量技术, 2023, 42(9): 169-176.
- [16] 张猛, 尹丽菊, 周辉, 等. 基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J]. 电子测量技术, 2023, 46(22): 17-25.

### 作者简介

梁天添, 博士, 副教授, 主要研究方向为高速列车故障诊断与容错控制, 基于人工智能的区域目标检测等。

E-mail: liangtiantian1122@163.com

杨淞淇, 硕士研究生, 主要研究方向为目标检测。

E-mail: m15241959226@163.com

钱振明(通信作者), 硕士, 讲师, 主要研究方向为图像识别、计算机视觉等。

E-mail: qianming868@163.com