

复杂天气下融合边缘增强与内容感知特征重构的道路目标检测方法

董林林, 徐长波*

北京印刷学院信息工程学院, 北京

收稿日期: 2026年5月29日; 录用日期: 2026年7月10日; 发布日期: 2026年7月22日

摘要

复杂天气条件下, 道路图像容易出现对比度下降、边缘模糊和雨雪噪声干扰等退化现象, 导致目标检测模型出现漏检、误检和定位不稳定等问题。针对上述问题, 本文基于YOLO11提出一种融合边缘增强与内容感知特征重构的道路目标检测方法WRA-YOLO。首先, 在骨干网络前端引入深度可分离小波卷积模块(Depthwise Wavelet Transform Convolution, DW-WTConv), 通过离散小波变换显式分解低频结构与高频边缘信息, 缓解下采样造成的细节丢失; 其次, 设计内容自适应特征重校准模块(Block Attention Residual, BlockAttnRes), 利用可学习伪查询向量与RMSNorm对多层特征进行动态加权融合, 降低复杂天气背景噪声对特征融合的干扰; 最后, 引入最小点距离交并比(Minimum Point Distance IoU, MPDIoU)损失函数, 以角点距离约束优化边界框回归。实验结果表明, WRA-YOLO在DAWN数据集上的mAP@0.5由72.28%提升至75.42%, 在RTTS数据集上的mAP@0.5由63.40%提升至65.56%, 说明该方法在雾、雨、雪和沙尘暴等复杂天气道路场景中具有较好的检测适应性。

关键词

目标检测, 复杂天气, YOLO11, 小波卷积, 特征融合, MPDIoU

Edge-Enhanced and Content-Aware Feature Reconstruction for Road Object Detection in Adverse Weather

Linlin Dong, Changbo Xu*

School of Information Engineering, Beijing Institute of Graphic Communication, Beijing

Received: May 29, 2026; accepted: July 10, 2026; published: July 22, 2026

*通讯作者。

文章引用: 董林林, 徐长波. 复杂天气下融合边缘增强与内容感知特征重构的道路目标检测方法[J]. 人工智能与机器人研究, 2026, 15(4): 1075-1084. DOI: 10.12677/airr.2026.154097

Abstract

Road images captured under adverse weather often suffer from low contrast, blurred boundaries and rain/snow noise, which degrades the robustness of object detectors. To address this issue, this paper proposes WRA-YOLO, an improved YOLO11-based detector integrating edge enhancement and content-aware feature reconstruction. First, a depthwise wavelet transform convolution module (DW-WTConv) is introduced into the early backbone to explicitly decompose low-frequency structures and high-frequency edge details, thereby reducing detail loss caused by downsampling. Second, a content-adaptive feature recalibration module (BlockAttnRes) is designed to dynamically fuse multi-level features using learnable pseudo-query vectors and RMSNorm, suppressing noisy semantic responses in adverse weather. Finally, MPDIoU loss is employed to improve bounding box regression by constraining corner-point distances. Experiments show that WRA-YOLO improves mAP@0.5 from 72.28% to 75.42% on DAWN and from 63.40% to 65.56% on RTTS, demonstrating better adaptability to road scenes under fog, rain, snow and sandstorm conditions.

Keywords

Object Detection, Adverse Weather, YOLO11, Wavelet Convolution, Feature Fusion, MPDIoU

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

道路目标检测是自动驾驶和智能交通感知系统中的基础任务,其核心目标是在图像中准确定位车辆、行人、骑行者等交通参与对象。近年来, YOLO 系列单阶段检测算法因具有端到端预测、推理速度快和工程部署便利等特点,在实时检测场景中得到广泛应用[1]。然而,真实道路环境并非始终处于清晰成像条件下,雾、雨、雪和沙尘暴场景等复杂天气会改变图像的亮度分布与局部纹理结构,使目标边缘弱化、背景噪声增强,从而显著降低检测模型的鲁棒性[2]-[4]。

复杂天气对目标检测的影响主要体现在三个方面:其一,目标边缘与纹理信息退化。雾霾和降雪会降低图像对比度,雨滴和雪花会造成局部遮挡,使原本依赖高频分量表达的目标轮廓变得模糊;其二,特征分布发生偏移。模型在清晰图像或常规场景中学习到的纹理、颜色与空间结构,在复杂天气中可能出现统计分布差异,导致泛化性能下降;其三,背景噪声干扰增强。雨雪颗粒、雾气纹理和沙尘颗粒容易在深层特征中产生误响应,使检测头对非目标区域产生误检。针对复杂天气道路目标检测,多域自适应、动态教师模型和伪标签学习等方法也被用于提升模型跨天气泛化能力[5]。

针对上述退化问题,面向复杂天气场景的目标检测研究主要可分为三类。第一类方法通过图像增强或退化恢复改善输入图像质量,例如 IA-YOLO [6]通过图像自适应增强模块提升不同天气条件下的检测性能。第二类方法针对特定天气退化设计检测结构,例如 CF-YOLO [7]通过跨层特征融合改善雪天道路目标检测效果。第三类方法将多种图像处理操作或跨域学习机制引入检测框架,例如 ERUP-YOLO [8]通过统一图像自适应处理增强恶劣天气下的检测鲁棒性。上述方法在复杂天气检测中取得了较好效果,但多数工作更侧重于输入增强、单一天气适配或单一网络模块改进,对复杂天气下“边缘退化、特征融合噪声和边界回归不稳定”之间的层次关系讨论不足。

现有 YOLO 改进方法通常从轻量化卷积、注意力机制和特征金字塔融合等角度提升模型性能[1]。FPN 和 PAN 等结构通过自顶向下与自底向上的路径融合浅层空间信息和深层语义信息[9] [10], 但其常用的 Concat 或逐元素相加属于静态融合方式, 在复杂天气下容易将有效边缘细节与背景噪声同时引入。另一方面, 标准卷积和步长下采样具有明显的局部平滑特征, 弱边缘信息在早期特征提取阶段容易被抑制, 进而影响远距离小目标和低对比度目标的检测。

针对上述问题, 本文提出 WRA-YOLO 道路目标检测方法。与仅依赖图像增强或单一注意力模块的改进方法不同, 本文从复杂天气造成的检测退化机理出发, 将问题分解为边缘信息保留、内容感知特征融合和模糊边界优化三个层次, 并分别设计 DW-WTConv、BlockAttnRes 和 MPDIoU 进行对应处理。该方法围绕“边缘信息保留”和“内容感知融合”两个关键问题, 对 YOLO11 进行针对性改进: 在骨干网络前端利用小波变换进行频域分解, 增强高频边缘表达; 在颈部融合阶段通过 BlockAttnRes 对不同层级特征进行空间自适应加权; 在边界框回归阶段引入 MPDIoU 损失函数, 提高模糊边界条件下的定位稳定性。因此, WRA-YOLO 并非简单堆叠网络模块, 而是形成了“边缘增强 - 特征重构 - 边界优化”的系统化检测框架。

本文主要贡献如下:

- 1) 提出 DW-WTConv 边缘增强模块, 在下采样前显式分解并建模高频边缘子带, 提高复杂天气下低对比度目标的可分辨性。
- 2) 设计 BlockAttnRes 内容自适应特征重校准模块, 通过可学习伪查询向量和 RMSNorm 实现跨层特征的动态加权融合, 降低噪声特征对检测结果的干扰。
- 3) 在 YOLO11 检测框架中引入 MPDIoU 损失函数, 通过最小点距离约束提升目标边界回归精度, 并在 DAWN 和 RTTS 数据集上验证所提方法的有效性。

2. 本文算法原理

2.1. WRA-YOLO 整体网络结构

WRA-YOLO 以 YOLO11n 为基线模型, 整体仍采用 Backbone、Neck 和 Head 三段式结构。Backbone 负责提取多尺度语义特征, Neck 负责进行多层特征融合, Head 负责完成类别预测与边界框回归。与原始 YOLO11 相比, 本文主要在三个位置进行改进: 第一, 在骨干网络前端或早期下采样层前嵌入 DW-WTConv 模块, 增强输入特征中的边缘与纹理信息; 第二, 在高层特征融合位置引入 BlockAttnRes 模块, 用动态加权替代简单拼接; 第三, 在边界框回归损失中采用 MPDIoU, 以角点距离改善复杂天气下的定位精度。WRA-YOLO 整体网络结构见图 1。

上述设计并非简单叠加模块, 而是分别对应复杂天气目标检测中的三个关键瓶颈: DW-WTConv 用于缓解边缘退化, BlockAttnRes 用于缓解特征融合失效, MPDIoU 用于缓解边界模糊导致的回归不稳定。三者共同构成“边缘增强 - 特征重构 - 边界优化”的检测流程。

2.2. 深度可分离小波卷积模块

复杂天气环境下, 目标边缘通常表现为弱高频响应, 而传统卷积下采样容易削弱这些高频细节。为此, 本文设计深度可分离小波卷积模块 DW-WTConv, 将小波变换引入卷积特征提取过程。小波变换能够将输入特征显式分解为低频结构分量和多个方向的高频细节分量, 从而使模型在早期阶段获得更清晰的边缘表达[11] [12]。

给定输入特征 X , 首先采用离散小波变换 DWT 将其分解为四个子带:

WRA-YOLO 总体网络结构图




Figure 1. Overall network architecture of WRA-YOLO

图 1. WRA-YOLO 整体网络结构图

$$X_{LL}, X_{LH}, X_{HL}, X_{HH} = \text{DWT}(X) \quad (1)$$

其中, X_{LL} 表示低频结构信息, X_{LH} 、 X_{HL} 和 X_{HH} 分别表示水平、垂直和对角方向的高频边缘信息。随后, 对不同子带分别采用深度卷积进行轻量化特征增强, 并通过逐点卷积完成通道交互。最后, 利用逆小波变换 IDWT 恢复空间分辨率, 并与主干分支形成残差融合:

$$Y = \text{Conv}_{1 \times 1}(X + \text{IDWT}(\varphi(X_{LL}), \varphi(X_{LH}), \varphi(X_{HL}), \varphi(X_{HH}))) \quad (2)$$

式中, $\varphi(\cdot)$ 表示深度卷积与非线性变换。该设计具有两个优势: 一方面, DWT/IDWT 本身不引入大量可学习参数, 能够保持较低计算开销; 另一方面, 高频子带的显式建模可增强目标轮廓与细节纹理, 对雾天、雪天和低照度场景中的弱边缘目标更为有利。

在具体实现中, DW-WTConv 采用 db1 小波基进行一级离散小波分解, 将输入特征分解为 LL、LH、HL 和 HH 四个子带。其中 LL 子带主要保留低频结构信息, LH、HL 和 HH 子带分别刻画不同方向的高频边缘细节。各子带经 5×5 深度卷积进行轻量化特征建模, 高频分支的可学习缩放因子初始化为 0.1, 以避免训练初期高频噪声对主干特征造成过强扰动。随后通过逆小波变换恢复空间分辨率, 并结合轻量通道门控对重构特征进行自适应校准。该设计能够在较小参数增量下增强目标轮廓表达, 尤其适合雾、雪和沙尘等低对比度场景。DW-WTConv 模块结构见图 2。




Figure 2. Architecture of the DW-WTConv module

图 2. DW-WTConv 模块结构图

2.3. 内容自适应特征重校准模块

在 YOLO 类检测器中, Neck 部分通常将不同尺度的特征进行拼接或相加, 以增强多尺度目标表达。然而, 复杂天气场景中的深层特征可能包含较多雾气、雨雪和沙尘等噪声语义, 浅层特征虽然保留边缘信息, 但也容易包含背景纹理干扰。若直接采用 Concat 融合, 不同层级特征的贡献无法随输入内容变化而调整, 容易出现有效信息被稀释的问题。

为解决该问题, 本文提出 BlockAttnRes 模块。设来自不同层级的输入特征为 $\{F_i\}_{i=1}^N$, 首先通过 1×1 卷积和尺度对齐操作将各分支映射到统一通道数和空间尺寸, 得到对齐后的特征。随后, 对每个分支引入 RMSNorm 以稳定不同层级特征的幅值分布:

$$\hat{F}_i = \text{RMSNorm}(F'_i) \quad (3)$$

在权重计算阶段, 本文为每个输入分支设置可学习伪查询向量 q_i , 并通过内积计算其在空间位置 (h, w) 处的重要性得分:

$$s_i(h, w) = q_i^T \hat{F}_i(h, w) \quad (4)$$

然后对所有分支的重要性得分进行 Softmax 归一化, 得到空间自适应融合权重:

$$\alpha_i(h, w) = \frac{\exp(s_i(h, w))}{\sum_j \exp(s_j(h, w))} \quad (5)$$

最终输出特征由各分支加权求和并经卷积整合得到:

$$Y = \text{Conv}\left(\sum_i \alpha_i \cdot F'_i\right) + R \quad (6)$$

在本文实验配置中, BlockAttnRes 主要用于颈部 P4 尺度特征融合位置。输入分支首先通过 1×1 卷积映射到统一通道数 c_2 , 并采用最近邻插值对齐空间尺寸。以本文模型为例, 该位置的输出通道数 c_2 为 512, 因此每个输入分支对应的可学习伪查询向量维度为 512。伪查询向量初始化为全零, 使训练初期各分支具有相对均衡的融合权重, 随后在反向传播过程中逐渐学习不同输入内容下的分支重要性。RMSNorm 作用于通道维度, 用于稳定不同层级特征的幅值分布; Softmax 则在输入分支维度上进行归一化, 使每个空间位置能够根据图像内容自适应选择更有效的特征来源。

其中 R 表示残差分支。与静态拼接相比, **BlockAttnRes** 能够根据输入图像内容动态调整不同层级特征的贡献。在雾天和雪天场景中, 模型可提高边缘细节分支权重; 在目标尺度较大或语义明确时, 可增强深层语义分支响应, 从而提高复杂场景下的鲁棒性[13]。**BlockAttnRes** 模块结构见图 3。




Figure 3. Architecture of the BlockAttnRes module

图 3. BlockAttnRes 模块结构图

2.4. MPDIoU 损失函数

复杂天气会使目标边界模糊, 导致预测框与真实框之间的重叠区域难以稳定优化。传统 IoU 类损失主要关注重叠面积, 当预测框与真实框重叠不足或具有相似宽高比但位置偏差较大时, 梯度信息可能不充分。**MPDIoU** 通过最小点距离约束直接刻画预测框与真实框角点之间的几何差异, 可同时考虑重叠区域、中心距离以及宽高偏差[14] [15]。

设预测框 $B_p = (x_1^p, y_1^p, x_2^p, y_2^p)$, 真实框 $B_g = (x_1^g, y_1^g, x_2^g, y_2^g)$, 两组对应角点距离定义为:

$$d_1^2 = (x_1^p - x_1^g)^2 + (y_1^p - y_1^g)^2 \quad (7)$$

$$d_2^2 = (x_2^p - x_2^g)^2 + (y_2^p - y_2^g)^2 \quad (8)$$

则 **MPDIoU** 可表示为:

$$\text{MPDIoU} = \text{IoU} - \frac{d_1^2 + d_2^2}{W^2 + H^2} \quad (9)$$

其中 W 和 H 为输入图像宽度和高度。对应的回归损失为:

$$L_{\text{MPDIoU}} = 1 - \text{MPDIoU} \quad (10)$$

该损失函数能够在预测框与真实框重叠不足时提供更连续的优化方向, 并对模糊边界条件下的框偏移进行惩罚, 因此适合复杂天气下的道路目标定位任务。

3. 实验与结果分析

3.1. 数据集与实验设置

本文选用 DAWN 和 RTTS 两个恶劣天气道路目标检测数据集进行实验验证。DAWN 数据集包含雾、雨、雪和沙尘暴等多种典型恶劣天气道路图像,能够用于评估模型在不同天气退化条件下的鲁棒性;RTTS 数据集主要包含真实雾天道路场景,适合进一步验证模型在低能见度条件下的泛化能力。所有图像统一缩放至 640×640 输入,训练集、验证集和测试集按统一划分方式进行组织,保证不同模型在相同数据条件下比较。数据集样本与复杂天气场景示例见图 4。



Figure 4. Dataset samples and adverse-weather scene examples

图 4. 数据集样本与复杂天气场景示例

训练过程中,基线模型采用 YOLO11n,改进模型在相同训练策略下进行对比。为保证实验可复现性,所有模型均在相同数据划分、输入尺度和训练策略下进行训练与验证。输入图像尺寸统一设为 640×640 ,batch size 设为 32,训练轮数为 300,优化器采用 SGD,初始学习率为 0.01,动量为 0.937,权重衰减为 0.0005。推理阶段采用相同置信度阈值和 NMS 设置,评价指标包括 $mAP@0.5$ 、 $mAP@0.5:0.95$ 、Precision (P)和 Recall (R)。

3.2. DAWN 数据集消融实验

为验证各改进模块的有效性,本文在 DAWN 数据集上进行消融实验。实验以 YOLO11n 为基线,逐步加入 DW-WTConv、BlockAttnRes 和 MPDIoU,结果见表 1。

Table 1. Ablation results on the DAWN dataset
表 1. DAWN 数据集消融实验结果

模型	DW-WTConv	BlockAttnRes	MPDIoU	mAP@0.5	mAP@0.5:0.95	Precision	Recall
YOLO11n	-	-	-	0.7228	0.4511	0.6167	0.7415
模型 A	√	-	-	0.7370	0.4917	0.7438	0.6551
模型 B	-	√	-	0.6702	0.4689	0.8479	0.6007
WRA-YOLO	√	√	√	0.7542	0.5145	0.8843	0.6290

由表 1 可知,加入 DW-WTConv 后,模型 mAP@0.5 由 0.7228 提升至 0.7370,mAP@0.5:0.95 由 0.4511 提升至 0.4917,说明小波边缘增强能够改善复杂天气下目标边界与纹理细节表达。单独加入 BlockAttnRes 后,Precision 提升至 0.8479,mAP@0.5:0.95 提升至 0.4689,但 Recall 有所下降,表明动态特征融合能够增强高置信目标响应,但可能抑制部分弱目标。最终 WRA-YOLO 的 mAP@0.5 达到 0.7542,较基线提升 3.14 个百分点;mAP@0.5:0.95 达到 0.5145,较基线提升 6.34 个百分点;Precision 由 0.6167 提升至 0.8843。虽然 Recall 低于基线,但模型检测精度和边界定位质量明显提升。

需要注意的是,模型 B 在单独引入 BlockAttnRes 后,Precision 由 0.6167 提升至 0.8479,但 Recall 由 0.7415 下降至 0.6007,mAP@0.5 也低于基线模型。其原因在于,BlockAttnRes 本质上是一种内容自适应特征筛选机制,能够增强高置信、语义更明确区域的响应,同时抑制背景噪声。然而在缺少 DW-WTConv 前端边缘增强的情况下,复杂天气中的远距离目标、小尺度目标和低对比度目标本身特征响应较弱,容易在动态加权过程中被视为低贡献特征而受到抑制。因此,单独使用 BlockAttnRes 虽然减少了部分误检,提高了 Precision,但也带来了弱目标漏检增加的问题。这一现象说明 BlockAttnRes 更适合作为边缘增强后的特征重校准模块,而不是单独替代传统特征融合结构。

此外,BlockAttnRes 的潜在局限在于其权重分配依赖输入特征质量。当浅层边缘信息不足或目标区域响应过弱时,注意力机制可能过度偏向高置信语义区域,从而牺牲部分召回率。后续可考虑引入召回约束、低置信目标蒸馏或多尺度监督,以进一步缓解弱目标被抑制的问题。

3.3. RTTS 数据集泛化实验

为进一步验证模型在真实雾天场景中的泛化能力,本文在 RTTS 数据集上进行对比实验,结果见表 2。

Table 2. Experimental results on the RTTS dataset
表 2. RTTS 数据集实验结果

模型	mAP@0.5	mAP@0.5:0.95	Precision	Recall
YOLO11n	0.6340	0.3934	0.7416	0.5791
+DW-WTConv	0.6425	0.4079	0.7155	0.5907
+BlockAttnRes	0.6527	0.4088	0.7449	0.6047
WRA-YOLO	0.6556	0.4165	0.7129	0.6349

由表 2 可知,在 RTTS 雾天数据集上,单独加入 BlockAttnRes 后,mAP@0.5 由 0.6340 提升至 0.6527,mAP@0.5:0.95 由 0.3934 提升至 0.4088,说明动态特征融合对真实雾天场景具有一定适应性。加入 DW-WTConv 后,Recall 由 0.5791 提升至 0.5907,mAP@0.5:0.95 提升至 0.4079,表明频域边缘增强有助于改

善低能见度场景下的目标检出。最终 WRA-YOLO 取得最佳综合结果, $mAP@0.5$ 达到 0.6556, $mAP@0.5:0.95$ 达到 0.4165, Recall 提升至 0.6349, 说明其在真实雾天场景下能够检测出更多难样本目标, 同时提升边界定位质量。

3.4. Precision 与 Recall 权衡分析

从 DAWN 数据集结果可以看出, WRA-YOLO 显著提高了检测精确率(Precision)和 $mAP@0.5:0.95$, 但召回率(Recall)相比基线有所下降。这表明本文方法更倾向于增强可靠目标响应并抑制复杂天气背景中的伪目标响应, 从而减少误检并提升边界定位质量。对于交通监控、道路事件分析和车载辅助感知等场景, 较高精确率能够降低误报警频率, 提高检测结果的可信度; 同时 $mAP@0.5:0.95$ 的提升说明模型预测框与真实框之间具有更高的定位一致性。

另一方面, 召回率下降说明模型对部分低对比度、小尺度或远距离目标仍存在漏检风险。对于安全冗余要求更高的自动驾驶前端感知场景, 若系统更关注“尽可能不漏检”, 则可在部署阶段适当降低置信度阈值、调整 NMS 阈值, 或在后续研究中引入召回率导向的损失函数和小目标增强策略。因此, WRA-YOLO 当前更适用于误检成本较高、要求检测结果稳定可靠的复杂天气道路感知任务; 在召回优先的场景中仍有进一步优化空间。

3.5. 检测结果可视化分析

本文选取雾天、雨天、沙尘暴和雪天场景下的典型图像, 对 YOLO11n 和 WRA-YOLO 的检测结果进行可视化比较, 检测结果见图 5。图 5 采用“原图-YOLO11n (基线)-WRA-YOLO (本文)”的排列方式, 红色框表示 YOLO11n 检测结果, 黄色框表示 WRA-YOLO 检测结果。可以观察到, YOLO11n 在雾天远距离目标、沙尘暴低对比度目标和雪天小目标场景中更容易出现漏检或定位不完整, 而 WRA-YOLO 能够通过边缘增强和动态融合获得更完整的目标响应, 尤其对轮廓模糊的车辆和行人目标具有更好的检出能力。




Figure 5. Detection-result comparison under different weather conditions

图 5. 不同天气场景下的检测结果对比

4. 总结与展望

本文针对复杂天气道路目标检测中边缘信息退化、特征融合缺乏内容引导以及边界定位不稳定等问题, 基于 YOLO11 提出 WRA-YOLO 检测方法。该方法首先通过 DW-WTConv 在特征提取早期显式建模高频边缘信息, 缓解下采样过程中的细节丢失; 随后利用 BlockAttnRes 对多层特征进行动态加权融合, 增强有效目标特征并抑制天气噪声干扰; 最后采用 MPDIoU 损失函数提升模糊边界条件下的定位精度。

实验结果表明, WRA-YOLO 在 DAWN 数据集上的 $mAP@0.5$ 由 72.28% 提升至 75.42%, $mAP@0.5:0.95$ 由 45.11% 提升至 51.45%, Precision 由 61.67% 提升至 88.43%; 在 RTTS 数据集上的 $mAP@0.5$ 由 63.40% 提升至 65.56%, $mAP@0.5:0.95$ 由 39.34% 提升至 41.65%, Recall 由 57.91% 提升至 63.49%。可视化分析进一步表明, 该方法在雾天远距离目标、沙尘暴低对比度目标和雪天小目标场景中具有更完整的检测响应。

未来研究将从两个方面展开: 一是结合去雾、去雨、去雪或沙尘图像增强预处理模块, 进一步提升退化复杂天气场景下的检测能力; 二是结合模型剪枝、量化和知识蒸馏等方法降低计算开销, 提高模型在嵌入式平台和车载边缘设备上的部署效率。

参考文献

- [1] Jocher, G., Chaurasia, A. and Qiu, J. (2023) YOLO by Ultralytics. <https://github.com/ultralytics/ultralytics>
- [2] Narasimhan, S.G. and Nayar, S.K. (2002) Vision and the Atmosphere. *International Journal of Computer Vision*, **48**, 233-254. <https://doi.org/10.1023/a:1016328200723>
- [3] Sakaridis, C., Dai, D. and Van Gool, L. (2018) Semantic Foggy Scene Understanding with Synthetic Data. *International Journal of Computer Vision*, **126**, 973-992. <https://doi.org/10.1007/s11263-018-1072-8>
- [4] Michaelis, C., Mitzkus, B., Geirhos, R., et al. (2019) Benchmarking Robustness in Object Detection: Autonomous Driving When Winter Is Coming. arXiv: 1907.07484. <https://arxiv.org/abs/1907.07484>
- [5] 刘袁缘, 王超凡, 王文斌, 张浩宇, 罗忠文. 面向多种天气场景下目标检测的多域动态平均教师模型[J]. 计算机辅助设计与图形学学报, 2024, 36(3): 388-398.
- [6] Liu, W., Ren, G., Yu, R., Guo, S., Zhu, J. and Zhang, L. (2022) Image-Adaptive YOLO for Object Detection in Adverse Weather Conditions. *Proceedings of the AAAI Conference on Artificial Intelligence*, **36**, 1792-1800. <https://doi.org/10.1609/aaai.v36i2.20072>
- [7] Ding, Q., Li, P., Yan, X., Shi, D., Liang, L., Wang, W., et al. (2023) CF-YOLO: Cross Fusion YOLO for Object Detection in Adverse Weather with a High-Quality Real Snow Dataset. *IEEE Transactions on Intelligent Transportation Systems*, **24**, 10749-10759. <https://doi.org/10.1109/tits.2023.3285035>
- [8] Ogino, Y., Shoji, Y., Toizumi, T. and Ito, A. (2025) ERUP-YOLO: Enhancing Object Detection Robustness for Adverse Weather Condition by Unified Image-Adaptive Processing. 2025 *IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Tucson, 26 February-6 March 2025, 8597-8605. <https://doi.org/10.1109/wacv61041.2025.00833>
- [9] Lin, T., Dollar, P., Girshick, R., He, K., Hariharan, B. and Belongie, S. (2017) Feature Pyramid Networks for Object Detection. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21-26 July 2017, 936-944. <https://doi.org/10.1109/cvpr.2017.106>
- [10] Liu, S., Qi, L., Qin, H., Shi, J. and Jia, J. (2018) Path Aggregation Network for Instance Segmentation. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 8759-8768. <https://doi.org/10.1109/cvpr.2018.00913>
- [11] Mallat, S. (2008) A Wavelet Tour of Signal Processing. 3rd Edition, Academic Press.
- [12] Fujieda S, Takayama K, Hachisuka T. (2018) Wavelet Convolutional Neural Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Salt Lake City, 18-23 June 2018, 58-66.
- [13] Vaswani, A., Shazeer, N., Parmar, N., et al. (2017) Attention Is All You Need. *Advances in Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 5998-6008.
- [14] Ma, S. and Xu, Y. (2023) MPDIoU: A Loss for Efficient and Accurate Bounding Box Regression. arXiv: 2307.07662. <https://arxiv.org/abs/2307.07662>
- [15] Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I. and Savarese, S. (2019) Generalized Intersection over Union: A Metric and a Loss for Bounding Box Regression. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15-20 June 2019, 658-666. <https://doi.org/10.1109/cvpr.2019.00075>