

复杂天气下铁轨异物入侵目标检测 研究

魏雨桐 侯涛 牛宏侠

(兰州交通大学自动化与电气工程学院, 730070, 兰州)

摘要: 为保障复杂天气下列车运行安全, 针对复杂天气下, 铁轨异物入侵目标检测清晰度低, 容易出现误检漏检及参数量大与推理速度慢等问题, 提出基于改进YOLOv11n的复杂天气铁路轨道异物入侵检测算法RCW-YOLO。首先, 新建雨雾感知动态融合门控, 设计雨雾浓度估计器模块, 提高检测精度。然后在检测头DynamicHead中新增雨雾注意力分支, 并在卷积偏移量中融入雨雾浓度系数, 减少误检率和漏检率。其次, 在骨干和颈部网络中使用注意力增强多子带融合小波池化模块替代YOLOv11n现有卷积模块, 在保持检测效果的同时减少参数量, 提高推理速度。最后, 引入新设计的损失函数EW-MPDIoU替代原损失函数CIOU, 提高检测精度。实验结果表明, RCW-YOLO的处理结果的平均精度为84.6%, 较YOLOv11n提升了9.2%, 参数量下降了18.15%。与主流目标检测算法相比, RCW-YOLO的处理结果的平均精度较YOLOv9t、YOLOv10n分别提升了11.3%、11.3%, 参数量较YOLOv9t、YOLOv10n分别下降了21.63%、25.34%, 相比最新的YOLOv12、YOLOv13, 平均精度分别提高了7.8%、7.0%, 参数量分别下降了22.18%、19.93%。

关键词: 铁路轨道; 异物入侵; 复杂天气; 目标检测

中图分类号: TP391.41;U298 **文献标志码:** AA

文章编号: 0253-987X(XXXX)XX-0001-17

Research on Target Detection of Foreign Objects Intruding onto Railway Tracks under Complex Weather Conditions

WEI Yutong, HOU Tao, NIU Hongxia

(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou
730070, China)

Abstract: To ensure the safety of train operation under complex weather conditions, considering the low clarity of target detection for foreign objects invading the railway tracks under such conditions, and the problems of frequent false detections, missed detections, large parameter quantity and slow inference speed, a complex weather railway track foreign object intrusion detection algorithm RCW-YOLO(Railway Complex Weather-YOLO) based on improved YOLOv11n is proposed. Firstly, a rain and fog perception dynamic fusion gating is established, and a rain and fog concentration estimator module is designed to improve the detection accuracy. Then, a rain and fog attention branch is added to

收稿日期: 2026-03-10。

the detection head DynamicHead, and the rain and fog concentration coefficient is integrated into the convolution offset to reduce the false detection rate and missed detection rate. Secondly, the attention-enhanced multi-subband fusion wavelet pooling module is used instead of the existing convolution module in the backbone and neck networks to replace the YOLOv11n, maintaining the detection effect while reducing the parameter quantity and improving the inference speed. Finally, the newly designed loss function Edge-Weighted Minimum Point Distance Intersection over Union (EW-MPDIoU) is introduced to replace the original loss function CIOU, improving the detection accuracy. Experimental results show that the $mAP@0.5$ of the processing results of RCW-YOLO is 84.6%, which is 9.2% higher than that of YOLOv11n, and the parameter quantity is 18.15% lower than that of YOLOv11n. Compared with mainstream object detection algorithms, the $mAP@0.5$ of the processing results of RCW-YOLO is 11.3% higher than that of YOLOv9t and 11.3% higher than that of YOLOv10n, and the parameter quantity is 21.63% lower than that of YOLOv9t and 25.34% lower than that of YOLOv10n. Compared with the latest YOLOv12 and YOLOv13, the $mAP@0.5$ is 7.8% higher and the parameter quantity is 22.18% lower.

Keywords: Railway tracks; Foreign object intrusion; Complex weather; Object Detection

随着铁路的快速发展,铁路沿线环境安全问题日益受到关注。由于不可抗力因素造成的异物非法闯入轨道区域^[1],例如山石滚落^[2],列车侧翻等,不仅严重威胁列车安全运行,还可能造成重大人员伤亡。雨雾天气下的铁轨异物入侵检测^[3-4]存在一定难度,再加之低照度^[5]因素影响,检测难度大大提升,且误检漏检情况频发,严重影响行车安全。因此,研究低照度下雨雾天气铁轨异物检测刻不容缓。

当前已有部分目标检测研究通过引入或优化注意力机制、多尺度特征融合结构^[6]、图像增强^[7]与仿真技术等手段来提升模型的鲁棒性与实用性。但部分研究的检测精度仍有待提升^[8-15]。柳长源等^[8]提出了MEC-YOLO算法,在处理雨雪雾等恶劣天气中有良好的检测效果,减少了误检、漏检的发生。王诚

等^[9]针对无人机在雾天场景下容易受图像退化影响而造成多尺度目标检测精度低、特征对比度不足以及计算资源受限等问题,提出了一种改进YOLOv11的轻量化雾天车辆检测算法,提升了在遮挡场景下的稳定性,显著降低漏检与误检概率。王井阳等^[10]针对现有道路裂缝检测模型不能有效平衡检测精度、计算复杂度与检测速度的问题,使用ECIoU代替原损失函数,提高检测框定位精度和收敛速度。郭家虎等^[11]针对煤矿井下环境中存在的低照度成像质量差、小尺度异物漏检率高以及目标遮挡导致的特征信息缺失等问题,提出了一种基于YOLOv11s的低照度轻量化异物检测模型DEL-YOLO,有效提升了暗区异物可见性。孙修宇等^[12]等针对低光照环境中的目标检测效果不佳的问题,所提改进YOLO11算法在不显著增加计算复杂

度的前提下动态调整感受野以更好地检测模糊目标。春良阮等^[13]针对海上目标检测存在恶劣天气、照明变化、物体尺度大变化以及小目标未被发现等问题,提出了基于YOLOv11的Marine-YOLO,提升了复杂海表环境中的探测准确性和稳定性。张瑞芳等^[14]针对传统的低照度目标检测中因光照不均,噪声干扰和边缘模糊等问题,提出MSDE-YOLO目标检测算法,提升了模型对小目标的检测能力。周强^[15]引入MPDIoU损失函数,在简化计算过程的同时改进了小目标定位不足的问题,整体提升了模型的收敛速度。部分研究难以同时对低照度叠加雨雾的双重干扰,易出现误检与漏检^[16-21]。王轩楷等^[16]针对水下环境光照不足导致的遮挡问题,引入回归损失函数Wise-inner-MPDIoU,提高了模型的检测精度。牛为华等^[17]针对遥感图像中目标背景复杂和小目标物体检测困难等问题,采用Haar小波变换分离图像高低频信息,增强模型对目标边缘与纹理细节的感知能力,抑制了复杂背景的干扰。王楠等^[18]针对铁轨异物检测中不同尺度异物目标的检测易受复杂环境的影响,导致出现检测精度低及检测速度慢等问题,提出一种多尺度特征融合的铁轨异物检测算法,提升了模型的检测精度与检测速度。张凡等^[19]针对当前朱鹮检测算法模型参数较多、计算量大的问题,设计了一种基于YOLOv5s的高性能轻量化网络模型,在大幅降低网络计算量的同时保持较高的目标检

测性能。侯涛等^[20]针对现有铁轨异物入侵检测算法易受到复杂环境的影响,导致检测精度低、计算量较大的问题,提出一种改进YOLOv12n的复杂环境下铁路轨道异物入侵检测方法RL-YOLO,实现了轻量级部署。郝芝建等^[21]针对光照不均造成目标与背景对比度低等问题提出了一种基于改进YOLOv10的隧道渗漏水智能检测方法LPM-YOLO,提高了目标检测结果的准确性和有效性。部分研究模型轻量化不足,参数量大、推理速度慢,难以满足轨道实时检测需求^[22-24]。刘晓雅等^[22]等针对铁路沿线隐患物检测中存在的复杂背景干扰问题,在算法中引入了MPDIoU损失函数,在优化回归精度的同时增强了对目标真实形状的匹配能力。张红瑞等^[23]引入MPDIoU损失函数优化小目标边界框回归,增强模型对复杂水下环境的适应性,提高了小目标的定位精度。张涛等^[24]为应对铁路复杂场景下人员入侵检测在时效性、抗干扰性和遮挡识别方面的挑战,提出一种融合Rail-YOLO深度学习框架与多级智能预警机制的综合方案,入侵检测预警平均精度为94.99%。

低照度雨雾天气会造成图像对比度下降、噪声增强,相比一般目标检测任务,更容易导致异物特征被淹没、误检漏检率升高,同时铁路检测场景对模型的轻量化与实时性有更高要求,现有算法难以同时兼顾精度与速度。本文针对现有铁轨异物入侵检测算法在低照度叠

加雨雾的双重干扰场景下,易出现误检与漏检、检测精度不足,同时存在参数量大、推理速度慢、难以满足轨道实时检测需求的问题,提出了一种面向低照度雨雾天气的铁轨异物入侵目标检测算法 RCW-YOLO。该算法旨在提升低照度雨雾天气下的铁轨异物入侵检测精度,减少误检与漏检问题,降低计算成本,保障铁路轨道的行车安全。

1 RCW-YOLO

低照度和雨雾天气会对铁轨异物目

标检测造成双重干扰,铁轨异物包括人类、动物、落石、车辆等,形状各有差异且活物的行为又难以预测,从而大大增加目标检测的难度。为了提升低照度雨雾天气下铁轨异物入侵检测的精度,降低计算成本,本文对YOLOv11n进行改进,提出复杂天气下铁轨异物入侵目标检测算法(Railway Complex Weather-YOLO, RCW-YOLO),其结构如图1所示。




图1 RCW-YOLO 算法结构图

Fig. 1 Structural diagram of the RCW-YOLO algorithm

1.1 新建雨雾感知动态融合门控

在低照度雨雾天气下铁轨异物检测场景中,雨雾等级是动态变化的,固定强度的光照矫正和特征建模无法适配所有场景,如大雨雾场景需要强光照矫正和强特征关联建模,否则雨雾散射导致的亮度不均和特征模糊无法解决,然而在小雨雾场景中过度的光照矫正会导致

图像过曝、噪声放大,过度的注意力建模会引入背景冗余特征,反而降低检测精度。

新建雨雾感知动态融合门控(RainFog-Gate, RF-G),通过“雨雾浓度估计-双模块动态调节-特征融合”的闭环逻辑实现自适应检测,可适配混合雨雾强度场景下的目标检测,其轻量级

设计增加额外计算量小于5%,可精准感知输入图像的雨雾强度,实现0~1范围内量化,0代表弱雨雾,1代表强雨雾。

1.1.1 设计雨雾浓度估计器

低光照雨雾图像的核心特征包括对比度低、边缘模糊、全局亮度偏暗等。基于此设计雨雾浓度估计器(RainFog-Estimator, RF-E),采样快速下采样加全局池化的轻量结构,避免复杂计算,用

轻量级网络提取图像的雨雾特征,量化输出雨雾浓度系数 $\rho(X)$, $\rho(X) \in [0, 1]$,公式如式1所示。

$$\rho(X) = \sigma(F_{fc}(F_{gap}(Conv_2(Conv_1(X))))) \quad (1)$$

其中, X 为原始低照度雨雾图像, $Conv_1$ 、 $Conv_2$ 为轻量化卷积, F_{gap} 为全局平均池化, F_{fc} 为单输出全连接层, $\sigma(X)$ 为Sigmoid激活函数。雨雾浓度估计器结构如图3所示。




图3 雨雾浓度估计器结构图

Fig. 3 Structural diagram of RainFog-Estimator

1.1.2 引入双模块 IAT 和 MB-TaylorFormer

变换器(Illumination Adaptive Transformer, IAT)的核心作用是矫正低光照叠加雨雾散射导致的亮度问题,但过度矫正会引入噪声。因此根据雨雾浓度系数,线性混合原始图像和IAT矫正图像,实现光照矫正强度的自适应调节。公式如式2所示。

$$X_{iat} = X(0.1 + 0.9(1 - \rho(X))) + I(X)(0.9\rho(X)) \quad (2)$$

其中, X_{iat} 是IAT模块亮度矫正后的特征, $I(X)$ 为IAT模块输出的矫正图像,0.1为原始图像残差权重,0.9为调节衰减系数。

网络(MB-TaylorFormer, MB-TF)的核心作用是通过泰勒注意力建模特征间的长距离依赖,还原低光照雨雾下模糊

异物的特征,雨雾越强,特征越模糊,越需要强注意力建模;雨雾越弱,特征相对清晰,注意力建模可弱化。因此,根据雨雾浓度系数,动态加权MB-TF的输出特征,实现注意力建模强度的自适应调节。公式如式3所示。

$$F_f = F_t = Conv(X_{iat}) + T(Conv(X_{iat}))(0.8\rho(X)) \quad (3)$$

其中, F_t 是门控模块输出的融合特征, F_t 是 X_{iat} 经 1×1 卷积适配后,由MB-TF提取并结合 $\rho(X)$ 动态加权的注意力增强特征, $Conv(X_{iat})$ 为 1×1 升维卷积,实现维度匹配, $T(Conv(X_{iat}))$ 为MB-TF模块输出特征,0.8为注意力权重衰减系数。

雨雾感知动态融合门控结构图如图2所示。图中, F 是卷积适配后特征,

$T(F)$ 是MB-TF 输出, F_{taylor} 是最终融合特征。




图2 RainFog-Gate 结构图

Fig. 2 Structural diagram of RainFog-Gate

1.2 新建SDynamicHead检测头

DynamicHead 原有的注意力分支 ($\pi_L/\pi_S/\pi_C$)是无场景感知的固定结构,无法适配雨雾场景的低对比度、边缘模糊、亮度不均等特征,强降雨雾时低对比度区域的特征易被忽略,导致小异物误检或者漏检,检测精度下降。新建SDynamicHead,通过RF-G输出的雨雾浓度系数,引导DynamicHead 动态增强低对比度区域的特征权重,实现雨雾强度到注意力权重的自适应调节,利用 $\rho(X) \in [0,1]$ 的量化结果,构建雨雾注意力分支 π_R ,其输出权重与DynamicHead 的注意力权重逐元素相乘,公式如下。

$$A_f = A_o \pi_R(F_{feat}, \rho(X)) \quad (4)$$

$$\pi_R = \sigma(F_{fc2}(\text{ReLU}(F_{fc1}(F_{gap}^{feat})))) + 0.5\rho(X) \quad (5)$$

其中, A_f 是最终注意力权重, A_o 是DynamicHead 的注意力权重, $\pi_R(F_{feat}, \rho(X))$ 是雨雾注意力分支的输出, 0.5为雨雾增强系数。强降雨雾时 $\rho(X)$ 趋近于1, π_R 权重提升50%, F_{fc1} 和 F_{fc2} 是

两个全连接层, $\text{ReLU}(X)$ 是ReLU激活函数, F_{feat} 是输入到 π_R 分支的特征, F_{gap}^{feat} 是对输入特征做全局平均池化。

针对式(5)中雨雾增强系数的设定,以YOLOv11n+SDynamicHead 为基准,开展了不同系数(0.3/0.5/0.7/1.0)的消融实验,结果如表1所示。实验结果表明当系数为0.3时,增强幅度不足,强降雨雾场景下漏检增加,平均精度(mAP@0.5)降至0.735;当系数为0.5时,模型在强降雨雾场景下的mAP@0.5达到最优,同时准确率(Precision, P)和召回率(Recall, R)保持均衡;当系数大于0.5时,过增强导致误检增加。综上,0.5为最优增强系数,既有效补偿了强降雨雾场景的特征损失,又避免了过增强带来的负影响。

表1 雨雾增强系数消融实验结果

Table 1 The experimental results of the rain and fog enhancement coefficient dissipation

组	雨雾增强系数	mAP@0.5	P	R
1	0.3	0.735	0.835	0.782
2	0.5	0.743	0.831	0.791
3	0.7	0.738	0.822	0.794
4	1.0	0.729	0.808	0.797

强降雨雾时目标边缘模糊,DynamicHead 中 π_S 分支的卷积是固定卷积核其采样范围无法覆盖有效特征,对雨雾场景的模糊边缘、形变目标建模能力弱,导致检测精度下降。在卷积的偏移量计算中融入 $\rho(X)$,如公式6所示。

$$O_r = \text{Conv}_{3 \times 3}(F_{\text{feat}})(1 + \alpha \rho(X)) \quad (6)$$

其中, O_r 为雨雾适配的偏移量, α 为雨雾扩张系数。SDynamicHead 结构图如

图 4 所示, 紫色部分是新建的注意力分支 π_R 。




图 4 SDynamicHead 的结构图

Fig. 4 Structural diagram of SDynamicHead

1.3 新建注意力增强多子带融合小波池化

小波池化仅保留低频轮廓子带, 未针对 YOLOv11n 的特征流和四类检测目标做适配, 无法发挥小波多尺度优势。用注意力增强的多子带融合小波池化 (Haar Discrete Wavelet Transform, Haar-DWT) 替代小波池化, 用小波基 (Haar) 做离散小波变换 (Discrete Wavelet Transform, DWT), 基于离散小波变换实现小波池化, 融合其他子带并加入通道注意力, 可以更好地适配目标检测需求, 提高模型推理速度的同时降低计算量和参数量。离散小波变换将特征图分解为四个多尺度子带, 针对 2×2 下采样的二维特征图, 小波基的分解公式

如下。

$$F_{LL}(i, j) = \frac{1}{2} [x(2i, 2j) + x(2i, 2j+1) + x(2i+1, 2j) + x(2i+1, 2j+1)] \quad (7)$$

$$F_{LH}(i, j) = \frac{1}{\sqrt{2}} [x(2i, 2j) + x(2i, 2j+1) - x(2i+1, 2j) - x(2i+1, 2j+1)] \quad (8)$$

$$F_{HL}(i, j) = \frac{1}{\sqrt{2}} [x(2i, 2j) - x(2i, 2j+1) + x(2i+1, 2j) - x(2i+1, 2j+1)] \quad (9)$$

$$F_{HH}(i, j) = \frac{1}{2} [x(2i, 2j) - x(2i, 2j+1) - x(2i+1, 2j) + x(2i+1, 2j+1)] \quad (10)$$

其中, $x(a, b)$ 为原特征图在 (a, b) 位置的像素值, F_{LL} 、 F_{LH} 、 F_{HL} 、 F_{HH} 分别为低频轮廓、垂直边缘、水平边缘、对角细节子带。将 4 个子带按通道维度拼接,

通过 1×1 卷积融合为与原池化层相同通道数的特征图，公式为。

$$F_f = \text{Conv}_{1 \times 1}([F_{LL} \oplus F_{LH} \oplus F_{HL} + F_{HH}]) \quad (11)$$

其中, F_f 是小波池化模块的输入特征, $\oplus$ 为通道拼接操作, $\text{Conv}_{1 \times 1}$ 为 1×1 卷积, 用于通道对齐。引入通道注意力模块, 自动为不同通道的特征分配权重, 突出动物和人的边缘细节特征, 公式如下。

$$M_c = \sigma(\text{Conv}_{1 \times 1}(\text{ReLU}(\text{Conv}_{1 \times 1}(F_{\text{gap}}(F_f)))) \quad (12)$$

$$F_o = F_f \odot M_c \quad (13)$$

其中, M_c 是通道注意力权重矩阵, F_o 是小波池化模块的输出特征, 即门控模块输出的融合特征, $\odot$ 代表逐通道相乘。改进的小波池化内部结构如图5所示。




图5 改进的小波池化内部的结构图

Fig. 5 Improved structure diagram of the internal part of the wavelet pooling

改进的主要目的是针对低照度雨雾天气铁轨异物入侵检测任务来改进下采样单元, 用于替换YOLOv11n骨干网络中的最大池化层。输入特征图首先判断下采样步距是否为2, 若步距非2则直接输出; 若步距为2, 则通过小波变换将特征分解为 F_{LL} 、 F_{LH} 、 F_{HL} 、 F_{HH} 四个多尺度子带, 经通道拼接与 1×1 卷积融合后, 引入轻量级通道注意力模块对复杂轮廓目标的边缘特征进行加权增强, 最后通过SiLU激活函数输出与原池化层维度匹配的特征图。相较于最大池化的局部最大值采样, 该模块通过多子带融合保留目标细节信息, 通过注意力机制放大有效特征, 在提升低照度雨雾场景下异物检测精度的同时, 保证了模型推理效率。

1.4 新建损失函数EW-MPDIoU

低照度雨雾天气下, 目标的边缘特征比中心特征更易模糊, 导致预测框的边缘偏移比中心偏移更影响检测精度。最小点距离交并比 (Minimum Point Distance Intersection over Union, MPDIoU) 仅关注框的4个角点距离, 角点数量少且易受噪声干扰, 无法全面反映边缘对齐情况, 通过新增4个边缘中点, 覆盖上下左右关键边缘的距离计算, 并赋予边缘中点距离更高权重, 强制模型聚焦边缘对齐得到边缘加权最小点距离交并比 (Edge-Weighted Minimum Point Distance Intersection over Union, EW-MPDIoU), 用 $F_{EW-MPDIoU}$ 表示, 公式如下。

$$F_{EW-MPDIoU} = F_{IoU} \times \exp(-\lambda \frac{\sum_{i=1}^4 w_i \cdot d_i^2}{S}) \quad (14)$$

其中, F_{IoU} 是交并比, d_i^2 是真实框与预测框的四个边缘中点的欧氏距离平方, w_i 是第 i 个边缘中点的权重, S 是真实框面积, λ 是惩罚系数。改进后, 即使雨雾导致边缘模糊, 模型也能通过多关键点加权重惩罚的方式, 精准捕捉边缘偏移, 提升定位稳定性, 提高检测精度。

2 实验结果和分析

2.1 建立数据集

由于目前尚无专门针对低照度与雨雾复合场景的开源铁轨异物入侵检测数据集, 现有公开数据集 MSCOCO^[25]、Pascal Voc^[26] 多以正常光照、晴朗天气场景为主, 无法满足本文研究需求, 因此需要自行采集并建立针对性数据集。数据集的收集途径主要包括在学校内部实际铁轨上拍摄的图像、公开数据集获取的图像, 共计 3134 张, 图像增强后得到 11788 张图像, 并使用 Roboflow 标注异物, 采用标准随机划分方式, 按 7:2:1 的比例将数据集划分为训练集、验证集和测试集, 划分过程中严格保证训练集、验证集、测试集的异物类别分布与原始数据集一致, 避免因数据分布偏差带来实验误差。数据集包含人、动物、落石、车辆四类异物, 覆盖了雨雾浓度系数从 0 到 1 的全强度区间, 以及夜间、早晨、傍晚、阴天等多种低照度场景。

2.2 实验平台和评估指标

操作系统是 Windows11, CPU 是 16 vCPU Intel(R) Xeon(R) Platinum 8481C, GPU 是 NVIDIA RTX 4090D (24GB), 编译环境是 Python3.8, CUDA 是 11.3, 深度学习框架是 Pytorch1.10, 编译器是 Pycharm2024, 批量大小是 16, 回合为 300, 优化器是 SGD。本文采用的评估指标如下: mAP@0.5、 P 、 R 、每秒帧数(FPS)、计算量(GFLOPs)和参数量(Parameters)。

2.3 消融实验

为评估 RCW-YOLO 在雨雾低照度场景下检测铁轨异物的性能, 开展消融实验。实验以 YOLOv11n 为基础, 逐步引入雨雾感知动态融合门控、SDynamicHead 检测头、Haar-DWT 及 EW-MPDIoU 损失函数, 实验结果见表 2。

从表 2 的消融结果可以看出, 对基础模型进行不同模块的改进, 会带来差异化的性能增益。第 1 组以原始 YOLOv11n 作为基线, 其 mAP@0.5 为 75.4%。第 2 组在骨干网络中加入雨雾感知动态融合门控后, 模型参数量略有下降, mAP@0.5 提升 10.3 个百分点。第 3 组在检测头位置替换为 SDynamicHead 结构, 由于资源重分配和难例驱动导致整体精度略有下降, 但误检率与漏检率分别降低 8.5% 和 1.9%, 该模块通过雨雾浓度系数动态增强低照度区域特征权重, 以 mAP@

0.5的微小下降为代价实现了雨雾场景下误检漏检的显著抑制,属于针对性优化而非负优化。该结果并不意味着SDynamicHead主要改善了特定阈值下的检测表现,而未能提升整体PR曲线性能,而是模块将优化重心聚焦于低照度雨雾天气下的低置信度难样本,使其检出能力明显提升。此外这一现象是与数据集分类别检测难度存在差异有关。由于新增雨雾注意力分支并引入浓度系数计算,模型参数数量与计算量出现小幅上升。第4组采用注意力增强多子带融合小波池化替换原有卷积模块,FPS提升至121.2,GFLOPs由6.2G降至5.4G,说明该模块在提速与降参的同时,能够有效保留目标关键特征信息。尽管小波变换、通道拼接与特征融合存在一定内存访问开销,但NVIDIA RTX 4090D平台实测表明,模型单帧延迟约8.25ms、带宽占用约10.1%,实际硬件推理性能高效。第5组引入EW-MPDIoU损失函数,使模型检测精度得到进一步提升。该损失函数通过优化边界框定位精度、提升预测框与真实框的IoU,实现了mAP@0.5的显著提升,由于其作用域聚焦于框的位置回归,对目标分类与检出能力影响有限,因此P、R仅呈现微弱提升,符合目标检测评价指标的内在逻辑。由于EW-MPDIoU使得模型的边界框预测更为精准,减少了不必要的重叠区域和冗余计算,后处理步骤NMS可以更加高效,从而提高了FPS。第6组在第2组基础上叠加SDynamicHead

检测头,准确率与召回率均有所上升,但推理速度变慢,参数量与计算量小幅上升,主要原因是两个模块均包含雨雾浓度系数的相关运算。第7组在第6组基础上加入注意力增强多子带融合小波池化模块,相比第6组推理速度显著提升,计算量与参数量进一步降低。第8组为完整RCW-YOLO模型,同时集成雨雾感知动态融合门控、SDynamicHead检测头、Haar-DWT模块与EW-MPDIoU损失函数。四类改进模块形成协同优化机制,以雨雾浓度系数为全局调控信号,实现精度与效率的同步提升。其中,RainFog-Gate可动态校正雨雾造成的特征模糊,Haar-DWT依靠多子带融合与轻量化下采样保留边缘细节,将计算量控制在5.4G,为后续检测提供高质量低冗余特征;Haar-DWT提取的多尺度边缘信息配合SDynamicHead的动态权重调节,能够有效捕捉模糊目标,使召回率达到79.3%;在目标定位阶段,EW-MPDIoU通过边缘中点加权约束边界框偏移,最终将mAP@0.5提升至84.6%,定位效果明显优化。综合实验结果表明,RCW-YOLO算法能够稳定适配低照度雨雾天气下的铁轨异物入侵检测任务。

RCW-YOLO部分训练结果可视化图如图6所示,图6中红、蓝、绿、白四色标签分别对应人、动物、车辆、落石四类异物。

2.4 对比实验

表2 消融实验结果
Table 2 Ablation experiment results

组	RainFog- Gate	SDynamicHead	Haar- DWT	EW- MPDIoU	mAP @0.5	P	R	FPS	GFLOPs	Parameters
YOLOv11n(1)	×	×	×	×	0.754	0.746	0.732	68.6	6.2	2.7
YOLOv11n(2)	√	×	×	×	0.857	0.816	0.748	68.2	6.2	2.68
YOLOv11n(3)	×	√	×	×	0.743	0.831	0.791	65.2	6.6	2.72
YOLOv11n(4)	×	×	√	×	0.783	0.772	0.759	121.2	5.4	2.51
YOLOv11n(5)	×	×	×	√	0.862	0.75	0.744	71.2	6.1	2.58
YOLOv11n(6)	√	√	×	×	0.853	0.829	0.788	67.4	6.4	2.73
YOLOv11n(7)	√	√	√	×	0.829	0.817	0.781	105.2	5.3	2.2
YOLOv11n(8)	√	√	√	√	0.846	0.849	0.793	114.9	5.4	2.21



图6 RCW-YOLO 部分训练结果可视化图

Fig. 6 Visualization of some training results of RCW-YOLO

2.4.1 算法改进前后检测效果对比

为直观对比算法改进前后的检测效果，选取多组包含不同异物的图像，分别用 YOLOv11n 与 RCW-YOLO 模型进


行测试，结果如图 7 所示。其中图 7(a) 为 YOLOv11n 的检测结果，图 7(b) 为 RCW-YOLO 的检测结果。通过对比可见，RCW-YOLO 的检测精度显著优于

基准模型。图 7(a)中虚线标注区域出现误检,实线标注区域出现漏检;而在图 7(b)中,上述漏检目标均被有效检出,且类别判断准确。由此说明,RCW-YOLO在训练与推理过程中能够有效降低误检与漏检概率,整体检测精度得到明显提升。但研究仍存在一定局限性,模型在部分复杂场景下仍存在误检与漏检问题。


漏检主要集中于极端强降雨雾叠加超

远距小目标、以及高速运动模糊场景,其核心原因在于目标特征受环境干扰严重衰减,导致模型难以提取有效判别特征,且超小目标在采样过程中易出现特征丢失。

误检则多由相似背景干扰与雨雾噪声引起,阴影造成的遮挡及铁轨周边杂物与异物目标特征相近,雨雾形成的噪声干扰易被模型误判为目标特征,从而产生虚假检测。



(a) YOLOv11n



(b) RCW-YOLO

图7 算法改进前后检测效果可视化对比图

Fig. 7 Visualization comparison chart of detection effect before and after algorithm improvement

2.4.2 主流目标检测算法处理结果对比

为进一步验证所提RCW-YOLO算法的综合性能优势,将其与当前主流目标检测方法进行定量对比,实验数据如表3所示。根据表中各项指标的对比结果可知,RCW-YOLO的 $mAP@0.5$ 显著优于其他对比算法,较YOLOv9t、YOLOv8n、YOLOv10n分别高出11.3%、11%、11.3%。在P与R方面,RCW-YOLO相比YOLOv8n分别提升

12.5%、8.4%,相比YOLOv10n分别提升12.1%、7.2%。与YOLOv12、YOLOv13等最新模型相比,RCW-YOLO的计算量分别降低0.9G与0.8G,同时在检测精度、P及参数量等关键指标上均表现更优。综合对比结果表明,本文提出的算法在精度与效率上实现更好平衡,更能满足低照度雨雾天气下铁轨异物入侵检测在实时性与准确性方面的要求。YOLO系列算法相关代码与训练模型均托管于GitHub开源平台。

表3 与主流目标检测算法处理结果的对比实验

Table 3 Comparison experiments with the processing results of mainstream object detection algorithms

算法	$mAP@0.5$	P	R	FPS	GFLOPs	Parameters
YOLOv8n	0.736	0.724	0.709	66.63	6.7	3.04
YOLOv9t	0.733	0.736	0.721	67.05	6.4	2.82
YOLOv10n	0.733	0.728	0.716	66.93	6.8	2.96
YOLOv11n	0.754	0.746	0.732	68.6	6.2	2.7
YOLOv12	0.768	0.733	0.738	69.43	6.1	2.84
YOLOv13	0.776	0.741	0.729	69.01	6.2	2.76
RCW-YOLO	0.846	0.849	0.793	114.9	5.4	2.21

为进一步验证RCW-YOLO的泛化能力,在公开数据集Railway Dataset上进行了补充验证。由于公开数据集光照充足、无雨雾干扰,检测难度显著降低。实验结果表明,在公开数据集上YOLOv11n的 $mAP@0.5$ 为0.802,P为0.81,R为0.79,RCW-YOLO的 $mAP@0.5$ 达到0.856,P为0.836,R为0.829。表明RCW-YOLO不仅适用于低照度雨雾复杂场景,在常规晴朗天气下同样具备一定的检测能力和泛化性。


图8展示了主流目标检测算法与

RCW-YOLO在自建数据集上的检测效果可视化对比。由图8(a)可见,对比算法存在明显的误检与漏检现象;而图8(b)中,本文所提RCW-YOLO模型能够对各类异物实现准确、高精度识别。此外,图8(a)与图8(b)第三行均为遮挡状态下的异物样本,对比结果表明,RCW-YOLO显著提升了模型对遮挡异物的检测性能。

3 结论



(a) 主流目标检测算法



(b) RCW-YOLO

图8 主流目标算法检测可视效果对比

Fig. 8 Comparison of visual effects for mainstream object detection algorithms

1) 针对低照度雨雾天气下铁轨异物入侵检测精度低, 计算成本高等问题, 开展了铁轨异物入侵检测研究, 提出了基于改进YOLOv11n的低照度下雨雾天气铁轨异物入侵检测算法RCW-

YOLO。

2) 本文通过设计雨雾感知动态融合门控、SDynamicHead检测头、注意力增强多子带融合小波池化结构以及EW-MPDIoU损失函数, 对YOLOv11n

模型进行系统性优化,在降低模型参数量与计算复杂度的同时,有效提升了检测精度与泛化能力。

3) 经消融实验与同等条件下的多组对照实验验证,RCW-YOLO相较于基础模型 YOLOv11n, mAP@0.5 提升 9.2%, 参数量降低 18.15%。与 YOLOv8n、YOLOv9t、YOLOv10n、YOLOv12、YOLOv13 相比, mAP@0.5 分别提升 11.0%、11.3%、11.3%、7.8%、7.0%, 参数量分别下降 27.3%、21.63%、25.34%、22.18%、19.93%。结果表明,本文构建的 RCW-YOLO 具备更高的检测精度、更少的参数量与更快的推理速度,可有效降低检测过程中的漏检与误检率,能够很好地适用于低照度雨雾天气下的铁轨异物入侵检测场景。

参考文献

- [1] 徐展. 基于轻量化目标检测的铁路周界异物入侵检测方法研究[D]. 沈阳工业大学, 2025.
- XU Z. Research on Railway Perimeter Foreign Object Intrusion Detection Method Based on Lightweight Object Detection [D]. Shenyang University of Technology, 2025.
- [2] 赵永超, 丁东, 王汉策, 等. 基于无人值守视觉传感系统的铁路边坡侵限落石智能监测方法[J]. 科技与创新, 2025, (20): 77-79+83.
- ZHAO Y, DING D, WANG H, et al. Intelligent Monitoring Method for Railway Slope Encroaching Rockfall Based on Unattended Visual Sensing System [J]. Science and Innovation, 2025, (20): 77-79+83.
- [3] HOU P, CHEN L. Rain-fog detection via spatial adaptive deformable network with multi-scale feature preservation and task-aware dynamic calibration[J]. Engineering Research Express, 2025, 7(3): 035248-035248.
- [4] 朱思远. 基于自适应变化检测和自监督机制的异物侵限检测方法研究[D]. 西安交通大学, 2022.
- ZHU S. Research on Foreign Object Intrusion Detection Method Based on Adaptive Change Detection and Self-supervision Mechanism [D]. Xi'an Jiaotong University, 2022.
- [5] 杨伟, 王帅, 吴佳奇, 等. 从局部到全局的零参考低照度图像增强方法[J]. 西安交通大学学报, 2024, 58(04): 158-169.
- YANG W, WANG S, WU J, et al. A Zero-Reference Low-Illumination Image Enhancement Method from Local to Global [J]. Journal of Xi'an Jiaotong University, 2024, 58(04): 158-169.
- [6] 高修强, 余星阳, 刘伯鹏, 等. 基于改进 Mask R-CNN 的轨道交通异物入侵模型研究[J]. 自动化与仪表, 2025, 40(06): 111-115.
- GAO X, YU X, LIU B, et al. Research on the Rail Transit Foreign Object Intrusion Model Based on Improved Mask R-CNN [J]. Automation and Instrumentation, 2025, 40(06): 111-115.
- [7] 陈俊明. 面向铁路异物入侵检测的图像数据扩增方法研究[D]. 北京: 北京交通大学, 2023.
- CHEN J. Research on Image Data Augmentation Methods for Railway Foreign Object Intrusion Detection [D]. Beijing: Beijing Jiaotong University, 2023.

- [8] 柳长源,夏苏辉,兰朝凤.恶劣天气下的航拍车辆目标检测算法[J/OL].北京航空航天大学学报,1-14[2026-01-14].
LIU C, XIA S, LAN C. Algorithm for Detecting Aerial Vehicle Targets under Severe Weather Conditions [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-14 [2026-01-14].
- [9] 王诚,谢立云,李坤.基于改进YOLOv11的无人机雾天车辆目标检测算法研究[J/OL].南京邮电大学学报(自然科学版),1-9[2026-03-11].
WANG C, XIE L, LI K. Research on UAV Vehicle Target Detection Algorithm in Foggy Weather Based on Improved YOLOv11[J/OL]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 1-9[2026-03-11].
- [10] 王井阳,徐勇超,张波,等.改进YOLOv10n的轻量化道路裂缝检测模型[J/OL].郑州大学学报(工学版),1-8[2026-03-11].
WANG J, XU Y, ZHANG B, et al. Lightweight road crack detection model based on improved YOLOv10n[J/OL]. Journal of Zhengzhou University (Engineering Science), 1-8[2026-03-11].
- [11] 郭家虎,何磊.DEL-YOLO:低照度轻量级煤矿输送带异物检测[J/OL].电子测量与仪器学报,1-12[2026-01-14].
GUO J, HE L. DEL-YOLO: Lightweight Low-Illumination Coal Conveyor Belt Foreign Object Detection [J/OL]. Journal of Electronic Measurement and Instrumentation, 1-12[2026-01-14].
- [12] 孙修宇,毕楠.基于改进YOLO11的低光照环境目标检测算法[J].激光与光电子学进展,2025,62(22):426-436.
SUN X, BI N. Target Detection Algorithm in Low-Illumination Environments Based on Improved YOLO11 [J]. Laser and Optoelectronic Progress, 2025, 62(22): 426-436.
- [13] RUAN C, HONG L, GAO J. Marine-YOLO: A high-precision object detection algorithm for complex maritime environments[J]. Applied Ocean Research, 2026, 169104994-104994.
- [14] 张瑞芳,段世纪,刘占占,等. MSDE-YOLO: 低照度图像多尺度特征聚合目标检测算法[J/OL]. 光电与控制,1-9[2026-01-14].
ZHANG R, DUAN S, LIU Z, et al. MSDE-YOLO: Multi-scale Feature Aggregation for Target Detection in Low-Illumination Images [J/OL]. Opto-Electronics and Control, 1-9 [2026-01-14].
- [15] 周强. 低光图像目标检测的优化研究[J/OL]. 智能计算机与应用, 1-17[2026-01-14].
ZHOU Q. Optimization Research on Target Detection in Low-Light Images [J/OL]. Intelligent Computer and Applications, 1-17 [2026-01-14].
- [16] 王轩楷,潘广贞,陈新.改进YOLO11n的水下目标检测[J].计算机系统应用,2025, 34(10):76-85.
WANG X, PAN G, CHEN X. Improved YOLO11n for Underwater Object Detection [J]. Computer Systems Applications, 2025, 34(10): 76-85.
- [17] 牛为华,郭迅.融合分块注意力与小波特征聚合的遥感图像目标检测算法[J/OL].智能系统学报,1-12[2026-03-11].
NIU W, GUO X. Remote Sensing Image Target Detection Algorithm Combining Block Attention and Wavelet Feature Aggregation[J/OL]. Journal of Intelligent

- Systems, 1-12[2026-03-11].
- [18] 王楠,侯涛,牛宏侠. 多尺度特征融合的铁轨异物入侵检测研究[J]. 西安交通大学学报,2024,58(09):139-153.
- WANG N, HOU T, NIU H. Research on Railway Track Foreign Object Intrusion Detection with Multi-scale Feature Fusion [J]. Journal of Xi'an Jiao tong University, 2024, 58(09): 139-153.
- [19] 张凡,张鹏超,王磊,等. 基于YOLOv5s的轻量化朱鹮检测算法研究[J]. 西安交通大学学报,2023,57(01):110-121.
- ZHANG F, ZHANG P, WANG L, et al. Research on Lightweight Red-crowned Crane Detection Algorithm Based on YOLOv5s [J]. Journal of Xi'an Jiaotong University, 2023, 57(01): 110-121.
- [20] 侯涛,席超,牛宏侠. 复杂环境下铁路轨道异物入侵轻量化检测研究[J/OL]. 北京交通大学学报,1-14[2026-04-15].
- HOU T, XI C, NIU H. Research on Lightweight Detection of Foreign Objects Intruding into Railway Tracks in Complex Environments [J/OL]. Journal of Beijing Jiaotong University, 1-14 [2026-04-15].
- [21] 郝芝建,牟舵,王留毅,等. 基于改进YOLOv10的隧道渗漏水智能检测方法[J/OL]. 华南理工大学学报(自然科学版),1-10[2026-04-15].
- HAO Z, MU D, WANG L, et al. Intelligent Detection Method for Tunnel Leakage Water Based on Improved YOLOv10 [J/OL]. Journal of South China University of Technology (Natural Science Edition), 1-10 [2026-04-15].
- [22] 刘晓雅,许贵阳,白堂博,等. 基于YOLO11-DFI的铁路沿线隐患物智能检测算法[J/OL]. 铁道建筑,1-9[2026-01-14].
- LIU X, XU G, BAI T, et al. Intelligent Detection Algorithm for Hidden Hazards along Railway Lines Based on YOLO11-DFI [J/OL]. Railway Construction, 1-9 [2026-01-14].
- [23] 张红瑞,冯威铭,杨潞霞,等. 基于YOLO11改进的水下小目标检测算法CSAF-YOLO[J/OL]. 计算机应用, 1-12[2026-01-14].
- ZHANG H, FENG W, YANG L, et al. The underwater small target detection algorithm CSAF-YOLO based on the improvement of YOLO11 [J/OL]. Computer Applications, 1-12 [2026-01-14].
- [24] 张涛,田秀华,沈健,等. 基于Rail-YOLO的铁路限界入侵人员检测算法研究[J]. 铁道通信信号,2026,62(04):34-42.
- ZHANG T, TIAN X, SHEN J, et al. Research on Railway Boundary Intrusion Personnel Detection Algorithm Based on Rail-YOLO [J]. Railway Communication and Signal, 2026, 62(04): 34-42.
- [25] LIN T, MAIRE M, BELONGIE J S, et al. Microsoft COCO: Common Objects in Context.[J].CoRR,2014, abs/1405. 0312
- [26] EVERINGHAM M, ESLAMI A M S, GOOL L, et al. The Pascal Visual Object Classes Challenge: A Retrospective[J]. International Journal of Computer Vision, 2015,111(1):98-136.