

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算法参数量大、清晰度低、易出现误检漏检及推理速度慢等问题, 提出基于改进 YOLOv11n 算法的复杂天气铁路轨道异物入侵检测算法(RCW-YOLO)。首先, 在 YOLOv11n 算法基础上新增雨雾感知动态融合门控, 并设计了雨雾浓度估计器模块; 然后, 在目标检测头框架 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: 采用所提 RCW-YOLO 算法的平均检测精度为 84.6%, 较 YOLOv11n 算法提升了 9.2%, 参数量下降了 18.15%; 与主流目标检测算法 YOLOv9t 和 YOLOv10n 相比, 采用 RCW-YOLO 算法的平均检测精度分别提升了 11.3% 和 11.3%, 参数量分别下降了 21.63%、25.34%; 相比最新的 YOLOv12 和 YOLOv13 算法, 平均检测精度分别提高了 7.8%、7.0%, 参数量分别下降了 22.18% 和 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 **文献标志码:** A

DOI: 10.7652/xjtuxb202610010 **文章编号:** 0253-987X(2026)10-0113-12

Research on Object Detection for Foreign Object Intrusion on 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 operations under complex weather conditions, and to address the issues of existing object detection algorithms for foreign object intrusion on railway tracks, such as a large number of parameters, poor image clarity, high rates of false and missed detections, and slow inference speed, a foreign object intrusion detection algorithm for railway tracks under complex weather conditions (RCW-YOLO) based on the improved YOLOv11n is proposed. First, based on the YOLOv11n algorithm, a rain-fog perception dynamic fusion gating mechanism is introduced, and a rain-fog density estimator module is designed. Second, a rain-fog attention branch is added to the object detection head framework DynamicHead, and a rain-fog density coefficient is integrated into the convolutional offset to reduce the false and missed detection rates. Third, in the backbone and neck networks, an attention-enhanced multi-subband

收稿日期: 2026-03-10。 作者简介: 魏雨桐(2003—), 女, 硕士生; 侯涛(通信作者), 男, 教授, 硕士生导师。 基金项目: 甘肃省科技计划资助项目(23YFGA0049)。

网络出版时间: 2026-05-07

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20260506.1926.002>

fusion wavelet pooling module is utilized to replace the existing convolutional modules of YOLOv11n, which reduces the number of parameters and improves inference speed while maintaining detection performance. Finally, a newly designed loss function, EW-MPDIoU, is introduced to replace the original CIoU loss function, thereby improving detection accuracy. Experimental results show that the proposed RCW-YOLO algorithm achieves an average detection accuracy of 84.6%, which is 9.2% higher than that of the YOLOv11n algorithm, while the number of parameters is reduced by 18.15%. Compared with the mainstream object detection algorithms YOLOv9t and YOLOv10n, the average detection accuracy of the RCW-YOLO algorithm is improved by 11.3% and 11.3%, respectively, and the number of parameters is reduced by 21.63% and 25.34%, respectively. Furthermore, compared with the latest YOLOv12 and YOLOv13 algorithms, the average detection accuracy is improved by 7.8% and 7.0%, respectively, and the number of parameters is reduced by 22.18% and 19.93%, respectively.

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],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,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,显著降低漏检率与误检率。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。

Ruan 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。部分研究难以同时应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 算法

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,从而大大增加了目标检测的难度。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 算法进行改进,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。



C3k2—特征提取模块;C2PSA—增强特征提取模块。

图 1 RCW-YOLO 算法结构图

Fig. 1 Structural diagram of the RCW-YOLO algorithm

1.1 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(rain fog-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 代表强降雨雾。

1.1.1 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(rain fog-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 $\rho(X)$, $\rho(X) \in [0, 1]$, 公式如下

$$\rho(X) = \sigma(F_{fc}(F_{gap}(\text{Conv}_2(\text{Conv}_1(X)))))) \quad (1)$$

式中: 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 2 所示。




图 2 雨雾浓度估计器结构图

Fig. 2 Structural diagram of RainFog-Estimator

1.1.2 双模块照明自适应变换器和泰勒公式展开多分支变换器网络

照明自适应变换器(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, 公式如下

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

式中: 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。

泰勒公式展开多分支变换器网络(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, 公式如下

$$F_g = F_b = \text{Conv}(X_{iat}) + T(\text{Conv}(X_{iat}))(0.8\rho(X)) \quad (3)$$

式中: F_g 是门控模块输出的融合特征; F_b 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; $\text{Conv}(X_{iat})$ 为 1×1 升维卷积, 实现维度匹配; $T(\text{Conv}(X_{iat}))$ 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 3 所示。图中: F 是卷积适配后特征; F_{taylor} 是最终融合特征。




图 3 RainFog-Gate 结构图

Fig. 3 Structural diagram of RainFog-Gate

1.2 目标检测统一注意力检测头

目标检测统一注意力检测头(DynamicHead)原有的注意力分支(π_L 、 π_S 、 π_C)是无场景感知的固定结构, π_L 是局部定位分支, π_S 是形状分支, π_C 是分类置信度分支, 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

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

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

式中: 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, $F_{feat, gap}$ 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(重叠度大于等于 50% 才能断定检测正确)降至 73.5%; 当系数为 0.5 时, 模型在强降雨雾场景下的平均精度达到最优, 同时准确率(P)和召回率(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 Experimental results of the rain and fog enhancement coefficient dissipation

实验组	雨雾增强系数	平均精度/%	准确率/%	召回率/%
1	0.3	73.5	83.5	78.2
2	0.5	74.3	83.1	79.1
3	0.7	73.8	82.2	79.4
4	1.0	72.9	80.8	79.7

强降雨雾时目标边缘模糊,DynamicHead 检测头中 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 $\rho(X)$, 表达式如下

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

式中: 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 检测头模型的结构图

Fig. 4 Structural diagram of SDynamicHead detection head model

1.3 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 4 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 作离散小波变换

(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 4 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

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

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

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

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

式中: $x(a, b)$ 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,公式如下

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

式中: 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。

$$M_c \in \mathbf{R}^{C \times 1 \times 1} =$$

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

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

式中: M_c 是通道注意力权重张量; 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} 4 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 损失函数

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 $F_{\text{EW-MPDIoU}}$ 表示,计算公式如下

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

式中: F_{IoU} 是交并比; d_i^2 是真实框与预测框的 4 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 3 134 张,图像增强后得到 11 788 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 0~1 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 (24 GB), 编译环境是 Python3.8, CUDA 版本是 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:平均精度、准确率 P 、召回率 R 、帧率、计算量和参数量。

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 模块损失函数,实验结果见表 2。

表 2 消融实验结果

Table 2 Ablation experiment results

实验组	引入模块				平均 精度/%	准确率/%	召回率/%	帧率/ (帧·s ⁻¹)	计算量/ 10 ⁹	参数量/ 10 ⁶
	雨雾感知 动态融合 门控	SDynamic 检测头	哈尔离 散小波 变换	EW-MPD IoU 损失 函数						
1	×	×	×	×	75.4	74.6	73.2	68.6	6.2	2.70
2	√	×	×	×	85.7	81.6	74.8	68.2	6.2	2.68
3	×	√	×	×	74.3	83.1	79.1	65.2	6.6	2.72
4	×	×	√	×	78.3	77.2	75.9	121.2	5.4	2.51
5	×	×	×	√	86.2	75.0	74.4	71.2	6.1	2.58
6	√	√	×	×	85.3	82.9	78.8	67.4	6.4	2.73
7	√	√	√	×	82.9	81.7	78.1	105.2	5.3	2.20
8	√	√	√	√	84.6	84.9	79.3	114.9	5.4	2.21

注:√代表采用该模块,×代表不采用该模块。

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 算法作为基线,其平均精度为 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,平均精度提升 10.3%。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(误检率=1-准确率,反映把背景判成目标的概率)与漏检率(漏检率=1-召回率,反映真实物体没有被检测出来的概率)分别降低 8.5% 和 5.9%,该模块通过雨雾浓度系数动态增强低照度区域特征权重,以平均精度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 模块主要改善了特定阈值下的检测表现,未能提升整体综合检测性能,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,帧率提升至 121.2 帧/s,计算量由 6.2×10^9 降至 5.4×10^9 ,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 8.25 ms、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,实现了平均精度的显著提升,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,因此准确率和召回率仅呈现微弱提升,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,从而提高了帧率。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 组为完整的 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。4 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,RainFogGate 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 5.4×10^9 ,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,最终将平均精度提升至 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。

2.4 对比实验

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 算法进行测试,结果如图 6 所示。通过对比可见,RCW-YOLO 算法的检测精度显著优于基准模型。图 6 的 YOLOv11n 算法检测结果中虚线标注区域出现误检,实线标注区域出现漏检;而

在图 6 的 RCW-YOLO 算法检测结果中,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率与漏检率,显著提升整体检测精度。但该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。




图 6 本文算法与 YOLOv11 算法检测效果可视化对比图

Fig. 6 Visualization comparison of detection results between this algorithm and the YOLOv11 algorithm

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 的平均精度显著优于其他对

比算法,较 YOLOv9t、YOLOv8n、YOLOv10n 分别高出 11.3%、11.0%、11.3%。在准确率与召回率方面,RCW-YOLO 相比 YOLOv8n 分别提升了 12.5%、8.4%,相比 YOLOv10n 分别提升 12.1%、7.2%。与 YOLOv12、YOLOv13 等最新算法相比,RCW-YOLO

的计算量分别降低 0.9×10^9 与 0.8×10^9 , 同时在检测精度、准确率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 本文算法与几种主流目标检测算法处理结果的对比

Table 3 Comparison of this algorithm with the processing results of several mainstream object detection algorithms

算法	平均精度/%	准确率/%	召回率/%	帧率/(帧 $\cdot$ s $^{-1}$)	计算量/ 10^9	参数量/ 10^6
YOLOv8n	73.6	72.4	70.9	66.63	6.7	3.04
YOLOv9t	73.3	73.6	72.1	67.05	6.4	2.82
YOLOv10n	73.3	72.8	71.6	66.93	6.8	2.96
YOLOv11n	75.4	74.6	73.2	68.6	6.2	2.7
YOLOv12	76.8	73.3	73.8	69.43	6.1	2.84
YOLOv13	77.6	74.1	72.9	69.01	6.2	2.76
RCW-YOLO	84.6	84.9	79.3	114.9	5.4	2.21

为进一步验证 RCW-YOLO 算法的泛化能力,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 算法的平均精度为 80.2%,准确率为 81.0%,召回率为 79.0%,RCW-YOLO 算法的平均精度达到 85.6%,准确率为 83.6%,召回率为 82.9%。表明 RCW-YOLO 算法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 7 展示了主流目标检测算法与 RCW-YOLO 算法在自建数据集上的检测效果可视化对比。可见,主流目标检测算法 YOLOv8、YOLOv10、YOLOv12 存在明显的误检与漏检现象;而本文所提 RCW-YOLO 算法能够对各类异物实现准确、高精度识别。此外,YOLOv12 算法与 RCW-YOLO 算法的第 3 行检测结果均为遮挡状态下的异物样本,对比可知 RCW-YOLO 算法显著提升了模型对遮挡异物的检测性能。






图 7 主流目标算法检测可视效果对比

Fig. 7 Comparison of visual effects for mainstream object detection algorithms

3 结 论

(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 算法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 算法进行系统性优化, 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 YOLOv11n 算法, 平均精度提升了 9.2%, 参数量降低了 18.15%。与 YOLOv8n、YOLOv9t、YOLOv10n、YOLOv12、YOLOv13 算法相比, 平均精度分别提升了 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: 沈阳工业大学, 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.

- Zhao Yongchao, Ding Dong, Wang Hance, et al. Intelligent monitoring method for railway slope encroaching rockfall based on unattended visual sensing system [J]. Science and Innovation, 2025, (20): 77-79.
- [3] Hou Pengfei, Chen Li. 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.
- [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: 西安交通大学, 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(4): 158-169.
- Yang Wei, Wang Shuai, Wu Jiaqi, et al. A zero-reference low-light image enhancement method from local to global [J]. Journal of Xi'an Jiaotong University, 2024, 58(4): 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(6): 111-115.
- Gao Xiuqiang, Yu Xingyang, Liu Bokun, et al. Research on foreign object intrusion model for rail transit based on improved mask R-CNN [J]. Automation & Instrumentation, 2025, 40(6): 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.
- [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. (2025-12-25) [2026-01-14]. <https://doi.org/10.13700/j.bh.1001-5965.2025.0471>.
- Liu Changyuan, Xia Suhui, Lan Chaofeng. Algorithm for aerial vehicle object detection under adverse weather [J/OL]. Journal of Beijing University of Aeronautics

- and Astronautics. (2025-12-25) [2026-01-14]. <https://doi.org/10.13700/j.bh.1001-5965.2025.0471>
- [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). (2026-03-09) [2026-03-11]. <https://link.cnki.net/urlid/32.1772.TN.20260307.1941.008>. Wang Cheng, Xie Liyun, Li Kun. 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). (2026-03-09) [2026-03-11]. <https://link.cnki.net/urlid/32.1772.TN.20260307.1941.008>.
- [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). (2026-02-28) [2026-03-11]. <https://doi.org/10.13705/j.issn.1671-6833.2026.04.007>. Wang Jingyang, Xu Yongchao, Zhang Bo, et al. Lightweight road crack detection model based on improved YOLOv10n [J/OL]. Journal of Zhengzhou University (Engineering Science). (2026-02-28) [2026-03-11]. <https://doi.org/10.13705/j.issn.1671-6833.2026.04.007>.
- [11] 郭家虎, 何磊. DEL-YOLO: 低照度轻量级煤矿输送带异物检测 [J]. 电子测量与仪器学报, 2025, 39 (12): 289-299. Guo Jiahu, He Lei. DEL-YOLO: low-illumination lightweight object detection for conveyor belts in coalmines [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(12): 289-299.
- [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): 417-427. Sun Xiuyu, Bi Nan. Low-light environment object detection algorithm based on improved YOLO11 [J]. Laser & Optoelectronics Progress, 2025, 62 (22): 417-427.
- [13] Ruan Chunliang, Hong Liang, Gao Junjie. Marine-YOLO: a high-precision object detection algorithm for complex maritime environments [J]. Applied Ocean Research, 2026, 169: 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. (2026-01-09) [2026-01-14]. <https://link.cnki.net/urlid/41.1227.tn.20260108.1603.004>. Zhang Ruifang, Duan Shiji, Liu Zhanzhan, et al. MSDE-YOLO: multi-scale feature aggregation for target detection in Low-Illumination images [J/OL]. Electronics Optics & Control. (2026-01-09) [2026-01-14]. <https://link.cnki.net/urlid/41.1227.tn.20260108.1603.004>.
- [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. (2025-12-31) [2026-01-14]. <https://doi.org/10.20169/j.issn.2095-2163.25120401>. Zhou Qiang. Research on optimization of object detection in low-light images [J/OL]. Intelligent Computer and Applications. (2025-12-31) [2026-01-14]. <https://doi.org/10.20169/j.issn.2095-2163.25120401>.
- [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 Xuankai, Pan Guangzhen, Chen Xin. Improved underwater target detection with YOLO11n [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. (2026-03-09) [2026-05-06]. <https://link.cnki.net/urlid/23.1538.tp.20260306.1518.004>. Niu Weihua, Guo Xun. Remote sensing object detection algorithm integrating block attention and wavelet feature aggregation [J/OL]. CAAI Transactions on Intelligent Systems. (2026-03-09) [2026-05-06]. <https://link.cnki.net/urlid/23.1538.tp.20260306.1518.004>.
- [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(9): 139-153. Wang Nan, Hou Tao, Niu Hongxia. Research on railway track foreign object intrusion detection based on multi-scale feature fusion [J]. Journal of Xi'an Jiaotong University, 2024, 58(9): 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(1): 110-121. Zhang Fan, Zhang Pengchao, Wang Lei, et al. Research on lightweight crested ibis detection algorithm based on YOLOv5s [J]. Journal of Xi'an Jiaotong University, 2023, 57(1): 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]. 北京交通大学学报, 2026, 50 (3): 164-174. Hou Tao, Xi Chao, Niu Hongxia. Research on lightweight detection of foreign objects intrusion on railway tracks with complex environments [J]. Journal of Beijing Jiaotong University, 2026, 50(3): 164-174.
- [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). (2026-04-13) [2026-04-15]. <https://link.cnki.net/urlid/44.1251.T.20260411.1642.002>.
- Hao Zhijian, Mu Duo, Wang Liuyi, 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). (2026-04-13) [2026-04-15]. <https://link.cnki.net/urlid/44.1251.T.20260411.1642.002>.
- [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. (2026-01-05) [2026-01-14]. <https://link.cnki.net/urlid/11.2027.U.20260401.0853.002>.
- Liu Xiaoya, Xu Guiyang, Bai Tangbo, et al. Intelligent detection algorithm for hidden hazards along railway lines based on YOLO11-DFI [J/OL]. Railway Engineering. (2026-01-05) [2026-01-14]. <https://link.cnki.net/urlid/11.2027.U.20260401.0853.002>.
- [23] 张红瑞, 冯威铭, 杨璐霞, 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. (2026-01-08) [2026-01-14]. <https://link.cnki.net/urlid/51.1307.TP.20260108.1256.004>.
- Zhang Hongrui, Feng Weiming, Yang Luxia, et al. CSAF-YOLO: improved YOLO11 algorithm for underwater small object detection [J/OL]. Journal of Computer Applications. (2026-01-08) [2026-01-14]. <https://link.cnki.net/urlid/51.1307.TP.20260108.1256.004>.
- [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(4): 34-42.
- Zhang Tao, Tian Xiuhua, Shen Jian, et al. Study on railway boundary intrusion personnel detection algorithm based on Rail-YOLO [J]. Railway Signalling & Communication, 2026, 62(4): 34-42.
- [25] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context [C]//Computer Vision-ECCV 2014. Cham, Germany: Springer International Publishing, 2014: 740-755.
- [26] Everingham M, Eslami S M A, Van Gool L, et al. The Pascal visual object classes challenge: a retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98-136.

(编辑 刘杨 陶晴)