

基于轻量化重参数化 YOLOv11 的铁轨障碍物检测方法

姜 杨, 王长征, 周会祥

(华东交通大学信息与软件工程学院, 江西 南昌 330013)

摘要: 针对铁轨障碍物检测模型在边缘设备部署时面临的模型体积大、计算剪复杂度剪、精度损失显著等问题, 本文提出一种轻量化重参数化网络 YOLOv11s-Slim-Rep。该网络通过两项核心改进实现精度与效率的协同优化: 将网络宽度缩放因子由 0.50 调整为 0.35, 使模型大小压缩 44.8%, 参数量减少 45.4%; 采用 RepConvCustom 模块替换全部 stride=2 下采样卷积层, 通过结构重参数化技术融合为单个卷积, 实现推理阶段零额外开销。在 NewData 和 Railway 两个铁路轨道障碍物数据集上, 与 YOLOv11s 基线模型相比, mAP50 仅下降约 1.1%, 模型压缩近 45%; 与 YOLOv11n 相比, 在复杂场景下 mAP50 提升 4.7%, 跨数据集 mAP50 波动仅 0.6%。所提方法在显著压缩模型的同时保持了较高的检测精度, 展现出良好的边缘设备部署潜力。

关键词: 目标检测; YOLOv11; 模型轻量化; 结构重参数化; 铁轨障碍物检测; 边缘部署

中图分类号: TP391 文献标识码: A

A Lightweight Re-parameterized YOLOv11-Based Method for Railway Obstacle Detection

Jiang Yang, Wang Changzheng, Zhou Huixiang

(School of Information and Software Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: To address the challenges of large model size, high computational complexity, and notable accuracy degradation when deploying railway track obstacle detection models on edge devices, this paper proposes a lightweight re-parameterized network, YOLOv11s-Slim-Rep. The network achieves synergistic optimization of accuracy and efficiency through two core improvements: adjusting the network width scaling factor from 0.50 to 0.35, resulting in a 44.8% reduction in model size and a 45.4% decrease in parameter count; and replacing all stride=2 downsampling convolutional layers with a RepConvCustom module, which is fused into a single convolution via structural re-parameterization, incurring zero additional inference overhead. On two railway track obstacle datasets (NewData and Railway), compared to the YOLOv11s baseline, the mAP50 decreases by only approximately 1.1% while achieving nearly 45% model compression. Compared to YOLOv11n, it improves mAP50 by 4.7% in complex scenarios, with a cross-dataset mAP50 fluctuation of only 0.6%. The proposed method maintains high detection accuracy while significantly compressing the model, demonstrating strong potential for edge deployment.

Key words: object detection; YOLOv11; model lightweight; structural re-parameterization; railway obstacle detection; edge deployment

铁路交通是现代综合交通运输体系的重要组成部分, 其运营安全直接关系到人民生命财产安全与国民经济稳定运行。随着铁路网络规模持续扩张和列车运行速度不断提升, 铁轨障碍物引发的安全事故风险日益突出^[1]。树枝、石块、铁棒、桶状物及人员侵入等一旦出现在轨道区间, 极易造成列车脱轨或碰撞等重大事故。无人驾驶技术的推进进一步凸显了对铁轨障碍物自动化、实时化、智能化检测的迫切需求^[2]。因此, 研究能够在边缘设备上高效运行的铁轨障碍物实时检测方法, 具有重要的工程应用价值与现实意义^[3]。

传统障碍物检测方法主要依赖人工巡检或基于机器视觉的规则算法, 通过背景差分、边缘检测等手段识别轨道区域异常, 存在检测效率低、漏检率高、对复杂光照与遮挡场景适应能力差等局限性。以 YOLO 系列为代表的单阶段检测器凭借高效的端到端推理架构, 成为实时检测领域的主流方案。自 Redmon 等首次提出 YOLO 框架以来, 该系列持续演进: YOLOv5 引入灵活的宽度与深度缩放策略^[4], YOLOv8 全面重构骨干网络与检测头并采用无锚点机制^[5], YOLOv11 进一步引入 C3k2 与 C2PSA 模块^[6], 在精度与速度间取得较好平衡。然而, 此类方法侧重性能增强, 模型体积较大, 难以满足车载嵌入式等资源受限环境的部

署需求。在轨道交通目标检测领域，Niu 等提出 MSL-YOLO^[7]、Meng 等提出的 SDRC-YOLO^[8]、Ning 等改进 YOLOv5s^[9]、Pan 等采用 RepVGG 骨干网络^[10]的工作，验证了多尺度融合、注意力机制与重参数化技术在铁路异物入侵检测中的有效性。MobileNet^[11]、ShuffleNet、EfficientNet 等轻量化范式及 RepVGG 结构重参数化思想虽已广泛应用于 YOLO 框架，但现有方法对 stride=2 下采样层的适配仍存在不足，难以在显著压缩模型的同时保持复杂场景下的检测精度与跨数据集泛化稳定性^[12]。

当前铁轨障碍物检测模型主要面临模型体积与计算量过大、原生轻量化方案精度损失明显以及压缩方法难以兼顾推理开销与精度保持等问题^[13]。如何在有限计算资源约束下实现模型压缩与检测精度的协同优化，已成为面向边缘部署的铁轨障碍物检测研究亟待解决的核心挑战。

针对上述问题，本文提出一种轻量化重参数化目标检测网络 YOLOv11s-Slim-Rep。该网络通过网络宽度结构化缩放与适用于下采样场景的 RepConvCustom 重参数化卷积相结合，在显著降低模型复杂度的同时保持较高检测性能。实验验证表明，所提方法在两个铁路障碍物数据集上实现了压缩与精度的良好平衡，并具备良好的边缘部署潜力。

1 YOLOv11s-Slim-Rep

1.1 YOLOv11s-Slim-Rep 整体结构

YOLOv11s-Slim-Rep 是在 YOLOv11s 基础网络上^[14]，通过网络宽度结构化压缩（Slim）和 RepConvCustom 重参数化卷积两项核心改进构建的网络。如图 1 所示，其骨干网络与颈部网络中全部 7 处 stride=2 下采样卷积均替换为 RepConvCustom，具体位置如下：骨干网络中 P1/2、P2/4、P3/8、P4/16、P5/32 共 5 处下采样层，以及颈部 PANet 中 P3→P4 与 P4→P5 共 2 处上行下采样层。其余特征提取模块（C3k2、SPPF）与检测头结构保持不变^[15]。

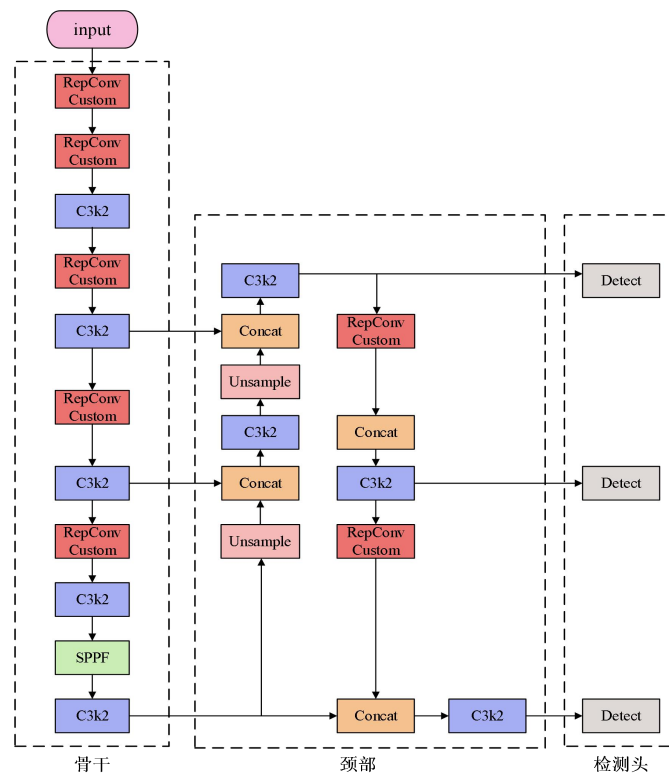


图 1 YOLOv11s-Slim-Rep 结构图

Fig.1 YOLOv11s-Slim-Rep Structure Diagram

1.2 网络宽度结构化压缩 (Slim)

网络宽度缩放 (Width Scaling) 是 YOLO 系列中常用的结构化压缩手段, 通过统一缩小各层输出通道数实现模型整体压缩^[6]。在具体实现中, 本文采用统一的宽度缩放策略对网络各层通道数进行调整。设原始第 i 层的输出通道数为 C_i , 则经宽度因子 w 缩放后的通道数可表示为

$$C_i' = \text{Align}(C_i \times w) C_i' \quad (1)$$

其中 $\text{Align}(\cdot)$ 表示通道对齐规则, 用于保证缩放后的通道数满足网络结构构建过程中的整数约束。通过该方式, 网络在保持主干拓扑结构不变的前提下实现整体宽度压缩, 从而显著降低参数量与计算量。

本文所新增的 RepConvCustom 模块同样遵循这一统一的宽度缩放规则, 其输入通道数与输出通道数均按照相同的缩放策略进行调整, 仅在卷积实现形式上由原始单分支卷积替换为训练期双分支、推理期单分支的重参数化结构, 因此不会破坏 Slim 模块的整体缩放逻辑。

为确定最优宽度参数, 本文在 NewData 数据集上对 $w \in \{0.50, 0.45, 0.40, 0.35\}$ 四种配置进行实验, 结果如图 2 所示。定义压缩后模型相对基线的模型大小压缩率 r_{size} 为:

$$r_{size} = 1 - \frac{|\hat{\Theta}|}{|\Theta|} \quad (2)$$

其中 Θ 与 $\hat{\Theta}$ 分别为压缩前后的模型权重集合。

随着 w 降低, 模型体积持续压缩: $w=0.35$ 时压缩率最高, $r_{size}=44.8\%$ (18.28 MB \rightarrow 10.10 MB)。在检测精度方面, 其中 $w=0.35$ 的 mAP50 最高。综合压缩率与精度, 本文选定 $w=0.35$ 为最优宽度配置。

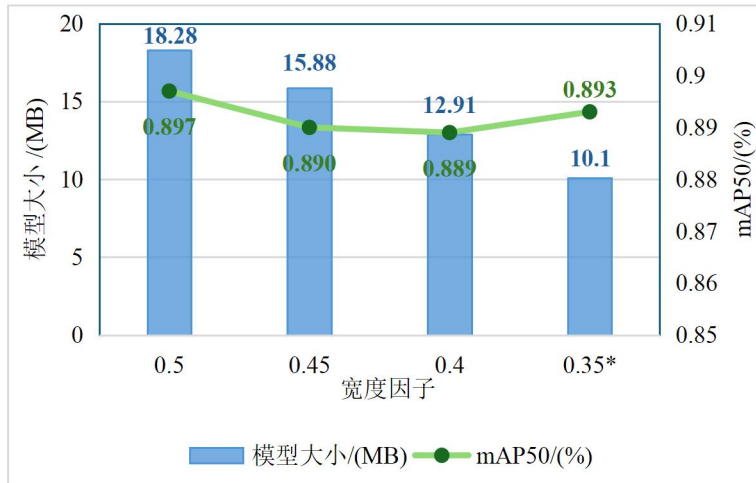


图 2 不同宽度因子下模型大小与 mAP50 对比

Fig.2 Comparison of Model Size and mAP50 Under Different Width Factors

经压缩后, YOLOv11s-Slim 的模型大小从 18.28 MB 压缩至 10.10 MB ($r_{size}=44.8\%$), 实现了真正意义上的结构化轻量化, 为后续引入 RepConvCustom 重参数化模块奠定基础。

1.3 RepConvCustom 重参数化卷积

结构化压缩在降低模型复杂度的同时, 不可避免地削弱了各层的特征提取能力^[17]。为此, 本文提出 RepConvCustom 模块, 通过重参数化技术对压缩后模型的关键下采样层进行增强, 在不增加推理开销的前提下提升模型表达能力。

RepConvCustom 的核心思想是将训练阶段与推理阶段的网络结构解耦, 如图 3 所示。标准卷积 (图 3 左) 在训练与推理阶段使用同一个 3×3 单分支结构, 特征提取能力受限于固定的单一卷积核感受野。

RepConvCustom (图 3 右) 在训练阶段将单一分支扩展为 3×3 Conv+BN 与 1×1 Conv+BN 双分支并行结构, 两路卷积输出逐元素相加后经激活函数处理, 其中 3×3 分支负责捕获局部空间特征, 1×1 分支负责跨通道线性变换, 双分支的互补作用增强了轻量化骨干在下采样节点处的特征提取能力。值得注意的是, 由于本文所针对的下采样层均为 $s=2$ (stride=2), 输入输出空间尺寸不同, 无法引入恒等映射分支, 因此采用双分支而非 RepVGG 的三分支设计。类似王瑞峰等^[18]引入 CBAM 注意力与 CIOU 损失提升小目标检测精度的思路, 本文 RepConvCustom 通过训练时双分支并行结构实现特征互补, 且推理阶段零额外开销。

为进一步明确 RepConvCustom 的结构形式, 本文将其应用于 YOLOv11s-Slim 中所有 stride=2 的下采样卷积层。该模块在训练阶段采用双分支并行结构, 由一个 3×3 卷积分支和一个 1×1 卷积分支组成, 两分支均采用“Conv+BN”的基本形式, 其中卷积层不使用偏置项, BN 层用于对分支输出进行归一化与尺度校正。两个分支输出在通道维度一致的前提下进行逐元素相加, 再经激活函数输出, 其中 3×3 分支主要用于提取局部空间上下文信息, 1×1 分支用于补充通道维度的线性变换能力, 从而增强下采样节点处的特征表达能力。

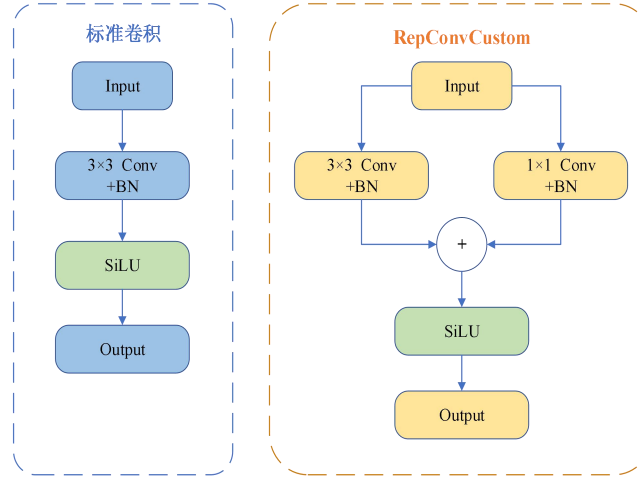


图 3 标准卷积 (左) 与 RepConvCustom (右) 的结构对比

Fig.3 Comparison of Structures Between Standard Convolution (Left) and RepConvCustom (Right)

推理阶段, RepConvCustom 通过结构重参数化技术将双分支融合为单个等价 3×3 卷积。首先将每个分支的批归一化 (BN) 层参数吸收进对应卷积权重。设第 k 分支卷积权重为 $W^{(k)}$, 偏置为 $b^{(k)}$, BN 层参数为 $(\mu^{(k)}, \sigma^{(k)}, \gamma^{(k)}, \beta^{(k)})$, 则 BN 吸收后的等价卷积权重 $\tilde{W}^{(k)}$ 与偏置 $\tilde{b}^{(k)}$ 为

$$\tilde{W}^{(k)} = \frac{\gamma^{(k)}}{\sigma^{(k)}} W^{(k)} \quad (3)$$

$$\tilde{b}^{(k)} = \beta^{(k)} - \frac{\gamma^{(k)} \mu^{(k)}}{\sigma^{(k)}} \quad (4)$$

随后将 1×1 卷积权重零填充扩展为 3×3 大小, 记为 $P(\tilde{W}^{(1 \times 1)})$, 最终将两分支权重直接相加得到融合后的等价单卷积权重 W_{fused} 与偏置 b_{fused}

$$W_{fused} = \tilde{W}^{(3 \times 3)} + P(\tilde{W}^{(1 \times 1)}) \quad (5)$$

$$b_{fused} = \tilde{b}^{(3 \times 3)} + \tilde{b}^{(1 \times 1)} \quad (6)$$

融合过程在模型部署前离线完成, 推理阶段的网络结构与标准卷积完全相同, 参数量无任何增加, 推理开销为零。

本文将 RepConvCustom 应用于 YOLOv11s-Slim 骨干网络与颈部网络中全部 7 处 $s=2$ 下采样卷积层，以系统地弥补宽度压缩导致的特征损失。在 NewData 和 Railway 两个数据集上，引入 RepConvCustom 后 mAP50-95 分别提升 1.6% 和 15.7%，验证了该模块对精确边框定位能力的一致性增益。

2 实验结果与分析

2.1 数据集

为验证所提方法在不同铁路场景下的适用性，本文选取两个具有代表性的数据集开展实验，分别为 NewData 数据集和 Railway 数据集。

NewData 数据集来源于 UAV-RSOD V2^[19]，于 2024 年 12 月发表在 Scientific Data (Nature 子刊) 上，由无人机在铁路周边区域采集的空中视角图像构成，属于典型的俯视式铁路障碍物检测场景。该数据集包含约 2000 张标注图像，覆盖 6 类常见铁轨障碍物，分别为树枝、铁棒、桶、石块、油桶和行人。

Railway 数据集由地面视角铁路场景图像组成，包含约 4000 张标注样本，覆盖 4 类目标，分别为杆状物、植物、棍棒和人员。该数据集模拟列车前向或轨旁视角，目标小、干扰强、遮挡多，能真实反映铁路障碍物入侵检测需求。

两个数据集均采用目标级边界框进行人工标注，标注结果以 YOLO 格式保存。为保证实验公平性与结果可重复性，本文按照 7:2:1 的比例将两个数据集划分为训练集、验证集和测试集，并确保各类别在不同子集中的分布相对一致。

2.2 实验设置

所有实验均在云平台上进行，具体配置如表 1 所示。

表 1 实验环境设置

Tab.1 Experimental Environment Setup

参数类别	具体配置
硬件环境	NVIDIA RTX 4090 GPU (显存 24 GB)
软件环境	PyTorch 2.4.1、ultralytics 8.3.0、Python 3.10
输入分辨率	640×640
批处理大小	24
早停耐心值	50
训练轮数	NewData 数据集: 100 轮; Railway 数据集: 200 轮

2.3 评价指标

本文采用目标检测领域的标准评价指标对模型性能进行量化评估。mAP50 为 IoU 阈值设为 0.5 时各类别平均精度 (AP) 的均值

$$mAP_{50} = \frac{1}{C} \sum_{i=1}^C AP_i^{IoU=0.5} \quad (7)$$

其中 C 为类别总数， $p_c(r)$ 为第 c 类在召回率 r 处的精确率。mAP50-95 为 IoU 阈值从 0.5 到 0.95 (步长 0.05) 共 10 个阈值下 mAP 的均值

$$mAP_{50-95} = \frac{1}{10} \sum_{t=0.5}^{0.95} mAP_t = \frac{1}{C} \sum_{t=1}^C \left(\frac{1}{10} \sum_{t \in \{0.5, 0.55, \dots, 0.95\}} AP'_t \right) \quad (8)$$

mAP50 反映模型的整体检测能力，mAP50-95 对高 IoU 阈值更为严格，能更精确地衡量模型的边框定位精度，是评估本文 RepConvCustom 改进效果的核心指标。模型复杂度以参数量（M）和模型文件大小（MB）衡量。

2.4 主实验结果

表 2 展示了 YOLOv11n、YOLOv11s 与本文方法 YOLOv11s-Slim-Rep 在 NewData 与 Railway 两个数据集上的综合性能对比。其中 Gap 表示模型在不同数据集上的 mAP50 差值，用于衡量模型的跨数据集泛化能力，Gap 越小表示泛化性能越稳定。从模型复杂度来看，YOLOv11s-Slim-Rep 在参数量和模型大小上相比 YOLOv11s 分别降低约 45.4% 和 44.8%，显著提升了模型的轻量化程度。

表 2 不同模型在 NewData 与 Railway 数据集上的综合性能对比

Tab.2 Comprehensive comparison on NewData and Railway datasets

Model	Params / M	Size / MB	NewData mAP50	NewData mAP50-95	Railway mAP50	Railway mAP50-95	Gap
YOLOv11n	2.59	5.21	0.840	0.592	0.899	0.768	0.059
YOLOv11s	9.43	18.28	0.897	0.630	0.904	0.775	0.007
YOLOv11s-Slim-Rep	5.15	10.10	0.887	0.627	0.893	0.753	0.006

在检测精度方面，YOLOv11s-Slim-Rep 在 NewData 数据集上仅比 YOLOv11s 下降 1.0%；在 Railway 数据集上仅下降 1.1%，说明在大幅压缩模型的同时仍能保持较高检测性能。

在泛化能力方面，YOLOv11s-Slim-Rep 的 Gap 为 0.006，小于 YOLOv11s(0.007) 和 YOLOv11n(0.059)，说明其在不同数据分布下具有更稳定的性能表现。

为进一步验证所提方法的有效性，本文将 YOLOv11s-Slim-Rep 与主流目标检测模型进行对比，实验结果如表 3 所示。从表 3 可以看出，YOLOv11s-Slim-Rep 在模型规模显著小于多数对比模型的情况下，仍能保持具有竞争力的检测精度。相比于同类模型，本文方法在保持较高精度的同时，显著降低了参数量与模型大小，体现出更优的轻量化性能。

表 3 不同目标检测模型在 NewData 数据集上的性能对比

Tab.3 Performance Comparison of Different Object Detection Models on the NewData Dataset

Model	Params/M	Size/MB	mAP50	mAP50-95
Faster R-CNN	41.0	164.3	0.875	0.620
YOLOv5s	7.2	16.5	0.852	0.611
YOLOv6s	17.2	38.1	0.868	0.618
YOLOv7l	36.9	104.7	0.892	0.634
YOLOv8s	11.2	23.9	0.889	0.626
YOLOv9s	7.1	14.2	0.878	0.629
YOLOv10s	7.2	14.8	0.885	0.623
YOLOv11s	9.43	18.28	0.897	0.630

YOLOv11s-Slim-Rep(Ours) 5.15 10.10 0.887 0.627

综合来看，YOLOv11s-Slim-Rep 在模型压缩、检测精度与跨数据集泛化能力之间取得了良好平衡，验证了所提方法的有效性。

2.5 消融实验

为验证各改进组件的独立贡献，本文采用逐步增量式消融实验，从 YOLOv11s 基线出发，依次引入宽度压缩（Slim）与重参数化卷积（RepConvCustom），在 NewData 和 Railway 两个数据集上分别评估每个组件的效果，结果如表 4 所示，ND=NewData，RW=Railway。

需要说明的是，表 4 中的 Params 与 Size 统计的是结构重参数化融合后的推理模型规模，而非训练阶段的多分支结构规模。由于 RepConvCustom 在推理阶段可等效融合为单个 3×3 卷积，因此 YOLOv11s-Slim 与 YOLOv11s-Slim-Rep 在部署态具有相同的参数量和模型大小。二者性能差异主要来源于训练阶段不同的特征学习能力。

表 4 组件消融实验结果

Tab.4 Results of Component Ablation Experiment

模型	Slim	RepConv	Params /M	Size /MB	ND mAP50	ND mAP50-95	RW mAP50	RW mAP50-95
YOLOv11s			9.43	18.28	0.897	0.630	0.904	0.775
YOLOv11s-Slim	✓		5.15	10.10	0.893	0.611	0.882	0.596
YOLOv11s-Rep		✓	9.82	19.02	0.894	0.632	0.897	0.786
YOLOv11s-Slim-Rep	✓	✓	5.15	10.10	0.887	0.627	0.893	0.753

宽度压缩（Slim）的贡献：引入 Slim 后，模型大小从 18.28 MB 压缩至 10.10 MB，参数量从 9.43 M 降至 5.15 M。在 NewData 上 mAP50 仅下降 0.4%，但 mAP50-95 下降 1.9%；在 Railway 上 mAP50 下降 2.2%，mAP50-95 下降 17.9%。结果表明，宽度压缩在大幅减小模型体积的同时，对粗粒度检测精度（mAP50）影响有限，但对精细定位能力（mAP50-95）存在一定损失，尤其在 Railway 数据集上更为明显。

RepConvCustom 的贡献：为验证 RepConvCustom 的独立作用，本文引入 YOLOv11s-Rep 作为对比模型，即在保持 YOLOv11s 原始宽度配置不变的条件下，仅将所有 stride=2 下采样卷积替换为 RepConvCustom。实验结果表明，YOLOv11s-Rep 相较于 YOLOv11s 在参数量和模型大小上略有增加，但在 NewData 和 Railway 数据集上均表现出更优的精细定位能力，说明 RepConvCustom 能够在不依赖 Slim 压缩的情况下独立增强下采样节点的特征表达能力。该结果表明，重参数化结构不仅适用于轻量化组合模型，也可作为独立模块改善检测性能。

在此基础上，YOLOv11s-Slim-Rep 进一步结合宽度压缩与重参数化增强，在保持部署规模不变的前提下，mAP50-95 在 NewData 和 Railway 上相较于 YOLOv11s-Slim 分别提升 1.6%和 15.7%，恢复了因宽度压缩损失的大部分定位精度。这说明 RepConvCustom 主要通过提升训练阶段的特征表达能力改善精细定位性能，而不会引入额外的推理部署成本。Railway 数据集上 mAP50 同时提升 1.1%，进一步印证了 RepConvCustom 在多类别、大规模数据集场景下特征增强效果更为显著。上述结果说明，RepConvCustom

通过训练阶段的多分支并行结构有效弥补了宽度压缩导致的特征提取能力损失，且增益在两个数据集上保持一致性，具有较强的鲁棒性。

2.6 检测效果可视化

为直观对比三种模型的实际检测效果，图 4 给出了 YOLOv11n、YOLOv11s 与 YOLOv11s-Slim-Rep 在 NewData 数据集验证集上两张典型图像的检测结果。从图中可以看出，模型不同场景下，检测边框的位置与置信度与 YOLOv11s 基线高度一致，而 YOLOv11n 在部分场景中存在置信度偏低的情况，进一步印证了本文方法在显著压缩模型体积的同时保持了较强的实际检测能力。




图 4 三种模型在 NewData 数据集上的检测效果对比

Fig.4 Detection results comparison of three models on the NewData dataset

3 结论

针对铁路场景中铁轨障碍物检测模型体积大、难以边缘部署的问题，本文提出了一种轻量化重参数化目标检测网络 YOLOv11s-Slim-Rep。通过网络宽度结构化压缩和适用于下采样层的 RepConvCustom 重参数化卷积相结合，实现了模型压缩与检测精度的协同优化。主要贡献如下：

1) 提出了一种面向铁路障碍物检测的轻量化 YOLOv11 改进框架。通过将宽度缩放因子由 0.50 调整为 0.35, 在保持网络结构完整性的前提下, 使参数量减少 45.4%、模型大小压缩 44.8%, 为资源受限的边缘设备部署提供了可行方案。

2) 设计了适用于 stride=2 下采样场景的重参数化卷积模块 RepConvCustom。该模块在训练阶段采用 3×3+1×1 双分支结构增强特征表达, 推理阶段通过结构重参数化融合为单一 3×3 卷积, 实现零额外推理开销, 有效弥补了宽度压缩导致的特征损失。

3) 验证了轻量化结构与重参数化机制的协同优化效果。在 NewData 和 Railway 两个数据集上, 所提模型较 YOLOv11s 基线 mAP50 仅分别下降 1.0%和 1.1%。RepConvCustom 模块在 Slim 压缩基础上, 使 mAP50-95 分别提升 1.6%和 15.7%, 有效恢复了因宽度压缩损失的定位精度; 与 YOLOv11n 相比, 复杂场景下 mAP50 高出 4.7%, 跨数据集 mAP50 波动仅 0.6%, 展现出优异的检测精度与泛化稳定性。

综上, YOLOv11s-Slim-Rep 在模型压缩与检测性能中取得了良好平衡, 为铁路场景下的实时障碍物检测提供了一种有效技术路线。未来可进一步结合模型蒸馏或硬件量化技术, 实现更高帧率与更低功耗的端侧部署。

参考文献:

- [1] 侯涛, 李俊昶, 牛宏侠. 基于浅层特征融合的轻量级铁路异物入侵检测研究[J]. 北京交通大学学报, 2025, 49(5): 209-220.
HOU T, Li J C, Niu H X. Research on lightweight rail foreign object intrusion detection based on shallow feature fusion[J]. Journal of Beijing Jiaotong University, 2025, 49(5): 209-220.
- [2] 陈永, 王镇, 周方春. 空间定位与特征泛化增强的铁路异物跟踪检测[J]. 北京航空航天大学学报, 2025, 51(1): 9-18.
CHEN Y, Wang Z, Zhou F C. Railway foreign object tracking detection enhanced by spatial positioning and feature generalization[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 9-18.
- [3] WU X, LI W, HONG D, et al. Deep learning for unmanned aerial vehicle-based object detection and tracking: a survey[J]. IEEE Geoscience and Remote Sensing Magazine, 2021, 10(1): 91-124.
- [4] 蔡鑫楠, 丁学文, 张子怡, 等. 基于 YOLOv5 的铁路异物入侵检测[J]. 智能计算机与应用, 2022, 12(11): 161-167.
CAI X N, Ding X W, Zhang Z Y, et al. Intrusion detection of rail foreign objects based on YOLOv5[J]. Intelligent Computer and Applications, 2022, 12(11): 161-167.
- [5] 刘仕兵, 林强. 基于改进 YOLOv8n 的接触网绝缘子检测算法研究[J]. 华东交通大学学报, 2026, 43(1): 57-63.
Liu S B, Lin Q. Improved YOLOv8n Algorithm for Contact Network Insulator Detection[J]. Journal of East China Jiaotong University, 2026, 43(1): 57-63.
- [6] Singh N, Maurya C P, Mahaur B, et al. Improved YOLOv11 with weights pruning for road object detection in rainy environment[J]. Signal, Image and Video Processing, 2025, 19(6): 1-9.
- [7] NIU H X, Feng D C, Hou T. Research on foreign object intrusion detection in railway tracks based on MSL-YOLO[J]. Journal of Engineering and Applied Science, 2025, 72: 136.
- [8] MENG C, WANG Z, SHI L, GAO Y, TAO Y, WEI L. SDRC-YOLO: a novel foreign object intrusion detection algorithm in railway scenarios[J]. Electronics, 2023, 12(5): 1256.
- [9] NING S, DING F, CHEN B. Research on the method of foreign object detection for railway tracks based on deep learning[J]. Sensors, 2024, 24(14): 4483.
- [10] PAN H, LI Y, WANG H, TIAN X. Railway obstacle intrusion detection based on convolution neural network multitask learning[J]. Electronics, 2022, 11(17): 2697.
- [11] 杜开华, 许贵阳, 白堂博. 基于特征降冗余的 Vanilla-YOLOv8 铁路异物入侵检测方法[J]. 北京交通大学学报, 2024, 48(5): 49-58.

- DU K H, XU G Y, BAI T B. Vanilla-YOLOv8 railway foreign object intrusion detection method based on feature redundancy reduction[J]. Journal of Beijing Jiaotong University, 2024, 48(5): 49-58.
- [12] ZHU H, XIE X. Enhanced YOLOv11n for small object detection in UAV imagery: higher accuracy with fewer parameters[J]. Scientific Reports, 2026, 16: 5536.
- [13] GUO N, HUANG M, WANG W. GA-YOLOv11: a lightweight subway foreign object detection model based on improved YOLOv11[J]. Sensors, 2025, 25(19): 6137.
- [14] LI G, FANG J. LCW-YOLO: a lightweight multi-scale object detection method based on YOLOv11 and its performance evaluation in complex natural scenes[J]. Sensors, 2025, 25(19): 6209.
- [15] 晏朋, 李遇鑫, 李治林, 等. 基于改进 YOLOv7 的高铁异物入侵检测算法[J]. 无线电工程, 2024, 54(5): 1099-1109.
YAN P, LI Y X, LI Z L, et al. High-speed rail foreign object intrusion detection algorithm based on improved YOLOv7[J]. Radio Engineering, 2024, 54(5): 1099-1109.
- [16] ZHU W G, HAN X J, ZHANG K H, LIN S Y, JIN J. Application of YOLOv11 model with spatial pyramid dilation convolution (SPD-Conv) and effective squeeze-excitation (EffectiveSE) fusion in rail track defect detection[J]. Sensors, 2025, 25(8): 2371.
- [17] 姜香菊, 冯海照, 李涛. 基于 FasterNet 和 YOLOv8s 改进的铁路异物入侵快速检测方法[J]. 北京交通大学学报, 2024, 48(5): 39-48.
JIANG X J, Feng H Z, Li T. Improved rapid detection method for foreign object intrusion on railroads based on FasterNet and YOLOv8s[J]. Journal of Beijing Jiaotong University, 2024, 48(5): 39-48.
- [18] 王瑞峰, 陈小屹. 基于改进 YOLOv5 的轨道异物入侵检测算法研究[J]. 云南大学学报(自然科学版), 2023, 45(4): 799-806.
WANG R F, Chen X Y. Research on orbital foreign object intrusion detection algorithm based on improved YOLOv5[J]. Journal of Yunnan University: Natural Sciences Edition, 2023, 45(4): 799-806.
- [19] RAMPRIYA R S, AL-SHEHARI T, NATHAN S A, et al. An unmanned aerial vehicle captured dataset for railroad segmentation and obstacle detection[J]. Scientific Data, 2024, 11: 1315.



第一作者: 姜杨 (2002—), 男, 硕士研究生, 研究方向为目标检测。



通信作者: 王长征 (1975—), 男, 讲师, 研究方向为传感器网络、网络空间治理、计算机视觉。