基于改进 YOLOv11 的铁路紧固件与接头检测算法

李兴浩 [1]
LI Xinghao

摘 要 针对铁路巡检中紧固件与接头缺陷检测存在目标尺寸小、道砟背景复杂等问题，文章提出一种铁路紧固件与接头缺陷检测算法 YOLOv11n-BLP。该算法在颈部引入双向特征金字塔网络（BiFPN），以优化跨尺度特征融合路径；将主干网络末端的 C2PSA 模块替换为 C2PSA-LRSA 低分辨率自注意力模块，以增强小目标缺陷特征表征能力并抑制背景噪声干扰；同时，采用内部嵌入残差连接机制的 C3k2-PFDConv 对主干与颈部关键特征提取结构进行重构，进一步降低模型参数量与计算量。实验结果表明，改进后算法的精确率和召回率分别达到 89.5% 和 91.5%；与基础 YOLOv11n 模型相比，mAP@0.5 提升 1.2%，参数量和计算量分别降低 27.1% 和 7.9%。该算法在保证检测精度的同时实现了模型轻量化，为铁路紧固件与接头的自动化检测提供了有效的技术方案。

关键词 铁路紧固件；铁路接头；缺陷检测；YOLOv11n；轻量化

doi：10.3969/j.issn.1672-9528.2026.08.002

0 引言

铁路是国民经济的重要基础设施，运行安全至关重要。紧固件和接头是轨道结构中的关键连接部件，关系到列车运行安全 [1]。在长期列车动荷载作用及复杂自然环境侵蚀下，紧固件与接头易出现松动、缺失和损伤等异常。传统铁路巡检主要依赖人工检查和简单图像处理方法，不仅检测效率较低，而且在复杂背景与光照变化条件下稳定性不足，难以满足现代铁路线路巡检需求 [2]。相关研究表明，遮挡、背景纹理复杂及光照干扰是影响轨道部件视觉检测精度的重要因素，复杂工况下自动化检测仍面临工程应用挑战 [3]。

近年来，深度学习目标检测方法在铁路视觉巡检领域得到广泛应用。牛宏侠等 [4] 针对低照度、遮挡和远景小目标场景，提出 MDQF-YOLO，提升了复杂环境下多尺度目标的检测性能；Zhou 等 [5] 提出 RFD-DETR，通过多尺度特征提取和跨尺度特征融合兼顾了检测精度与轻量化部署需求；Ma 等 [6] 提出 PGCI-YOLO，引入注意力机制、内容感知上采样和改进损失函数，在轻量化条件下实现了铁路扣件缺陷的高效检测；Lü 等 [7] 结合双注意力机制与 MobileNetV3 主干网络，进一步提升了铁路扣件缺陷检测精度和边缘部署能力。

尽管现有研究取得了一定进展，但复杂道砟背景下微小缺陷目标易出现特征弱化，影响检测性能，同时模型在平衡检测精度与计算量方面仍存在不足。针对上述问题，本文以 YOLOv11n 为基线模型，从多尺度特征融合、高层语义增强和关键特征提取单元重构三个方面进行改进：在颈部引入 BiFPN 结构 [8]，增强跨尺度特征融合能力；在主干末端嵌入 LRSA 机制 [9]，提升高层语义特征对小目标缺陷区域的响应能力；在关键特征提取单元中融入频率动态卷积思想 [10]，增强模型对不同频率成分的自适应建模能力。基于上述改进，本文构建了一种兼顾检测精度与轻量化的铁路紧固件与接头缺陷检测模型。

1 YOLOv11n 网络结构

YOLOv11 是 Ultralytics 公司发布的一种单阶段目标检测算法，在工业视觉领域得到了广泛应用。其网络主要由骨干网络（Backbone）、颈部网络（Neck）和检测头（Head）三部分组成。骨干网络以 C3k2 模块为核心进行特征提取，并在末端结合 SPPF 与 C2PSA 模块，以增强多尺度上下文信息建模能力和全局关键特征感知能力；颈部网络采用 PANet 结构进行多尺度特征融合，以实现浅层空间信息与深层语义信息的有效交互；检测头对不同尺度特征进行预测，从而完成目标分类与定位任务。尽管原始 YOLOv11n 在通用目标检测任务中表现较好，但在铁路巡检场景下，紧固件与接头缺陷通常具有目标尺度小、背景干扰强、类别间相似性高等特点，原始网络在特征传递过程中仍易造成局部细节信息弱化，影响检测性能 [11]。因此，需针对该任务对 YOLOv11n 进行有针对性的特征增强与轻量化改进。

1. 武汉轻工大学电气与电子工程学院 湖北武汉 430023

2 改进 YOLOv11n 模型

2.1 改进算法整体网络结构

YOLOv11n 在目标检测任务中具有较好的检测性能和推理速度，但在铁路紧固件与接头检测场景中仍存在一定局限性。本文以 YOLOv11n 为基线网络，在保持整体检测框架不变的基础上，对主干网络、颈部网络及关键特征提取单元进行了改进，改进后的整体网络结构如图 1 所示。PFDConv 表示对原有 C3k2 单元进行重构后的关键特征提取模块，LRSA 表示用于替换主干网络末端 C2PSA 的低分辨率自注意力模块，BiFPN 表示颈部中的双向特征金字塔融合结构。其中，在颈部引入 BiFPN 模块以增强跨尺度特征融合能力；将主干网络末端的 C2PSA 模块替换为 C2PSA-LRSA 模块，以提升小目标缺陷区域的特征表征能力；同时，采用 C3k2-PFDConv 对主干与颈部中的关键特征提取单元进行重构，以进一步降低模型参数量与计算量。

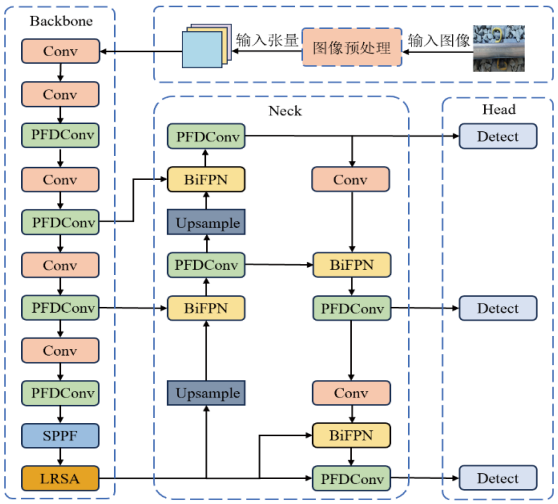


图 1 YOLOv11n-BLP 网络结构

2.2 BiFPN 模块：跨尺度特征融合

在铁路紧固件与接头缺陷检测任务中，待检测目标多为紧固件缺失和接头异常等小尺寸目标，易受道砟复杂背景和光照变化影响。原始 YOLOv11n 颈部采用 PANet 特征融合结构，在多层下采样与跨层传递过程中，容易导致小目标细节信息衰减。为增强网络对小目标缺陷的表征能力，本文引入双向特征金字塔网络（BiFPN）对原始颈部结构进行重构，在强化跨尺度特征交互的同时简化融合路径，在控制计算量的同时降低参数量，并提高浅层特征中小目标信息的保留能力。

BiFPN 以骨干网络输出的 P3、P4 和 P5 作为主要融合层，并引入由 P2 下采样后得到的辅助分支参与低层特征融合。首先，通过 1×1 卷积实现不同尺度特征的通道对齐；随后，构建自顶向下与自底向上的双向融合路径。与原始 PANet 相比，该结构移除了未参与融合的冗余节点，并增加了同尺度输入与输出节点之间的横向连接，从而优化特征信息流传递过程。原始 PANet 与改进后 BiFPN 的结构对比如图 2 所示。

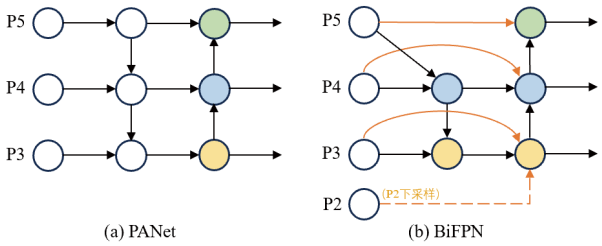


图 2 特征融合结构对比

此外，为提高不同尺度特征融合的自适应性，BiFPN 引入快速归一化融合策略，其表达式为：

$$\boldsymbol{O}=\sum_i \frac{\boldsymbol{w}_i}{\varepsilon+\sum_j \boldsymbol{w}_j}\cdot \boldsymbol{I}_i \tag{1}$$

式中：$\boldsymbol{O}$ 为融合后的输出特征图，$\boldsymbol{I}_i$ 为第 i 个输入分支的特征图，$\boldsymbol{w}_i$ 和 $\boldsymbol{w}_j$ 为自适应学习得到的特征权重，ε 为防止分母为 0 的极小常量。为保证数值稳定性，采用 ReLU 函数约束权重非负，即 $\boldsymbol{w}_i \geq 0$，该机制能够根据不同输入特征的贡献程度动态分配融合权重，从而提高多尺度特征融合效率。

2.3 C2PSA-LRSA 模块：低分辨率自注意力

在铁路紧固件与接头缺陷检测场景中，原始 C2PSA 模块在复杂背景条件下对小尺寸异常区域的聚焦能力有限。本文将低分辨率自注意力（LRSA）机制引入 C2PSA 模块，并对其进行重构。该模块在保留 C2PSA 原有通道分流聚合结构的基础上，将注意力计算转移到固定低分辨率空间中进行，从而在控制计算量的同时增强高层语义特征对缺陷区域的响应能力。图 3（a）为 LRSA 注意力分支的计算流程，其中 $\boldsymbol{F}_{\text{in}}$ 和 $\boldsymbol{F}_{\text{out}}$ 分别表示该分支的输入与输出，图 3（b）为 LRSA 嵌入 C2PSA 通道分流聚合结构后形成的 C2PSA-LRSA 模块。

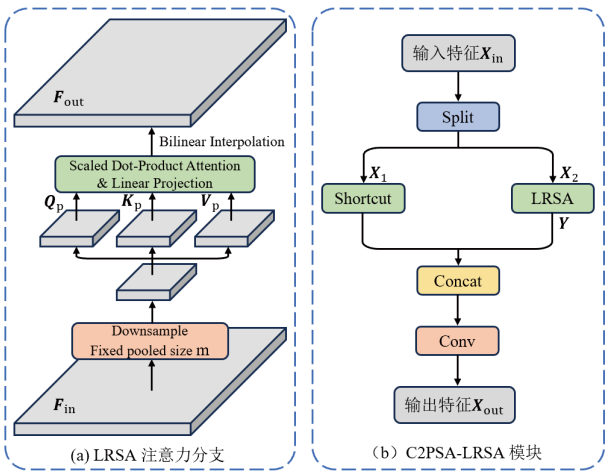


图 3 LRSA 注意力分支及 C2PSA-LRSA 模块结构

设输入特征为 $\boldsymbol{X}\in\mathbf{R}^{C\times H\times W}$，沿通道维度将其划分为两部分：

$$\boldsymbol{X}=[\boldsymbol{X}_1,\boldsymbol{X}_2] \tag{2}$$

式中：$\boldsymbol{X}_1$ 为捷径分支，用于保留原始语义信息；$\boldsymbol{X}_2$ 为注意力分支输入。对 $\boldsymbol{X}_2$ 进行池化下采样，得到固定低分辨率特征

$\boldsymbol{X}_{\mathrm{p}}=\mathrm{Pool}(\boldsymbol{X}_2)$。随后，对下采样后的特征进行线性映射分别生成查询向量 $\boldsymbol{Q}_{\mathrm{p}}$、键向量 $\boldsymbol{K}_{\mathrm{p}}$ 与值向量 $\boldsymbol{V}_{\mathrm{p}}$，并在固定低分辨率空间内完成自注意力计算：

$$\mathrm{LRSA}(\boldsymbol{X}_2)=\mathrm{Softmax}\left(\frac{\boldsymbol{Q}_{\mathrm{p}}\boldsymbol{K}_{\mathrm{p}}^{\mathrm{T}}}{\sqrt{d_{\mathrm{k}}}}\right)\boldsymbol{V}_{\mathrm{p}} \tag{3}$$

式中：d_{k} 为键向量 $\boldsymbol{K}_{\mathrm{p}}$ 的维度，用于对点积结果进行缩放，避免数值过大影响训练稳定性。

经过低分辨率空间中的特征聚合后，通过双线性插值将特征恢复至原始分辨率得到增强特征 $\boldsymbol{Y}$，并与捷径分支融合，经卷积映射得到模块输出：

$$\boldsymbol{X}_{\mathrm{out}}=\mathrm{Conv}(\mathrm{Concat}(\boldsymbol{X}_1,\boldsymbol{Y})) \tag{4}$$

综上，C2PSA-LRSA 模块在保留 C2PSA 原有通道分流聚合结构的基础上，将 LRSA 引入主干网络末端的高层语义特征增强过程，在控制计算开销的前提下提升了模型对小尺寸异常区域的表征能力，并有效减弱了复杂背景干扰。

2.4 C3k2-PFDConv 模块：融合残差连接的局部特征增强

针对 YOLOv11 中 C3k2 模块在复杂背景下局部细节表征能力不足且存在一定计算冗余的问题，本文构建 C3k2-PFDConv 模块作为关键特征提取单元。该模块沿用 C3k2 的双分支结构，输入特征被划分为旁路分支与主分支，其中旁路分支用于保留原始特征信息，主分支进入 PFDConv 单元进行特征增强，其整体结构如图 4 所示。

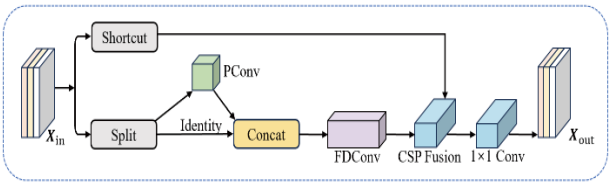


图 4 C3k2-PFDConv 模块结构

在 PFDConv 内部，首先采用部分卷积（partial convolution, PConv）进行空间特征提取。PConv 仅对 c_{p} 个通道执行卷积操作，其余通道保持恒等映射，从而在保留局部空间信息的同时降低计算开销，其计算量可表示为：

$$O_{\mathrm{PConv}}=h\times w\times k^2\times c_{\mathrm{p}}^{\,2} \tag{5}$$

式中：h 和 w 分别表示特征图的高和宽，k 表示卷积核尺寸，c_{p} 表示参与部分卷积运算的通道数。

拼接后的特征送入频率动态卷积（frequency dynamic convolution, FDConv）层，以增强网络对不同频率成分的自适应建模能力，从而提升对边缘、纹理及异常区域的特征表征效果。最后，主分支输出与旁路分支在 CSP Fusion 节点完成特征融合，并经 1×1 卷积进行通道调整后得到输出特征。同时，模块内部主分支与 Shortcut 支路之间构成局部残差连接，以增强特征复用能力并稳定网络的特征传递过程。

3 实验与结果分析

3.1 数据集与实验环境

本文采用 Roboflow Universe 平台公开发布的 Fastener Detection 数据集开展研究。该数据集共包含 2 571 张铁路紧固件与接头图像，涉及 5 个类别，分别为 Defective Joint、Good Fasteners、Good Joint、Missing Dogscrew 和 Missing Fastener，典型样本如图 5 所示。为保证模型训练与测试结果的客观性，本文按照 8∶1∶1 的比例将数据集划分为训练集、验证集和测试集。

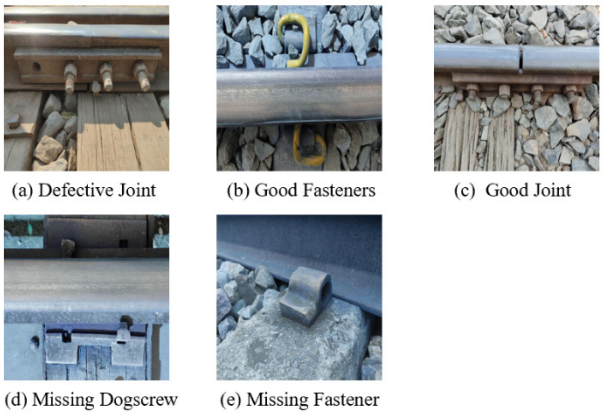


图 5 数据集示例

实验在 Ubuntu 22.04 环境下进行，软件环境为 Python 3.12、PyTorch 2.3.0 和 CUDA 12.1，硬件平台为 NVIDIA RTX 4090D GPU。模型基于 Ultralytics 框架进行训练，输入图像尺寸设置为 640×640，训练轮数设为 200，批大小设为 32，训练过程中采用 SGD 优化器，初始学习率设为 0.01。

3.2 评价指标

为验证本文所提算法的有效性，采用精确率（P）、召回率（R）、平均精度均值 mAP@0.5、参数量（Params）和计算量（GFLOPs）对模型性能进行评价。其中，P、R 和 mAP@0.5 用于衡量模型的检测精度，Params 和 GFLOPs 用于衡量模型的轻量化水平与计算复杂度。

3.3 消融实验

为验证本文提出的各改进模块（BiFPN、LRSA、PFDConv）对铁路紧固件与接头缺陷检测性能的有效性，在软硬件环境、超参数设置及数据集划分保持一致的条件下，以原始 YOLOv11n 为基线模型开展递进式消融实验，结果如表 1 所示。在基线模型基础上引入 BiFPN 后，模型的 mAP@0.5 由 91.3% 提升至 92.1%，参数量由 2.58×10^6 降至 1.92×10^6，说明该结构在增强多尺度特征融合能力的同时有效降低了模型参数规模。进一步引入 LRSA 后，模型精确率提升至 89.5%，mAP@0.5 提升至 92.3%，表明该模块能够增强复杂背景下高层语义特征对小目标缺陷区域的表征能力。继续引入 PFDConv 后，模型召回率提升至 91.5%，mAP@0.5 达

到 92.5%，同时参数量和计算量 FLOPs 分别降至 1.88×10^6 和 5.8×10^9，表现出较好的综合检测性能。综合来看，BiFPN、LRSA 和 PFDConv 具有较好的互补作用，提出的改进方法在提升检测性能的同时能进一步实现模型轻量化。

表 1 消融实验结果

模型	*P*/%	*R*/%	mAP@0.5 /%	Params /10^6	FLOPs /10^9
Base	88.6	90.5	91.3	2.58	6.3
+B	86.8	89.8	92.1	1.92	6.3
+B+L	89.5	89.5	92.3	1.94	6.3
+B+L+P（Ours）	89.5	91.5	92.5	1.88	5.8

注：Base 表示 YOLOv11n 基线模型；B、L 和 P 分别表示 BiFPN、LRSA 和 PFDConv；Ours 表示同时引入 B、L 和 P 的改进模型。

3.4 对比实验

为验证本文所提改进模型的综合性能，将其与典型 YOLO 系列检测模型进行对比实验，结果如表 2 所示。

表 2 对比实验结果

算法	*P*/%	*R*/%	mAP@0.5 /%	Params /10^6	FLOPs /10^9
YOLOv5n	86.6	88.6	90.4	2.50	7.1
YOLOv8n	86.0	89.6	90.4	3.00	8.1
YOLOv10n	91.5	87.5	91.5	2.27	6.5
YOLOv11n	88.6	90.5	91.3	2.58	6.3
Ours	89.5	91.5	92.5	1.88	5.8

由表 2 可知，本文算法在各对比模型中表现出较好的综合检测性能。与 YOLOv5n、YOLOv8n 和 YOLOv11n 相比，所提模型在召回率、mAP@0.5、参数量和计算量等指标上均具有一定优势。与 YOLOv10n 相比，虽然精确率略低，但召回率和 mAP@0.5 更高，且模型规模更小，说明本文方法在检测性能与轻量化之间取得了较好平衡。综合来看，所提方法在保证检测精度的同时有效控制了模型规模与计算开销，更适用于复杂场景下铁路紧固件与接头缺陷的自动化检测任务。

4 结语

针对铁路巡检场景下紧固件与接头缺陷检测中存在的目标尺寸小、道砟背景复杂等问题，本文提出了一种基于改进 YOLOv11n 的缺陷检测算法。该算法通过引入 BiFPN 优化多尺度特征融合路径，结合 C2PSA-LRSA 模块增强复杂背景下的小目标特征表征能力，并利用 C3k2-PFDConv 对关键特征提取单元进行轻量化重构，从而增强了模型的特征表征能力并降低了模型复杂度。实验结果表明，改进模型的精确率和召回率分别达到 89.5% 和 91.5%，与基线模型相比，mAP@0.5 提升了 1.2%，参数量和计算量分别降低了 27.1% 和 7.9%。综上所述，本文方法在提升检测性能的同时实现了模型的轻量化，可为铁路紧固件与接头缺陷的自动化检测提供技术参考。

参考文献：

[1] 沙伯男，白堂博，许贵阳，等．基于改进 YOLOv9 的铁路扣件状态检测方法 [J]. 北京交通大学学报，2025, 49(6): 75-84.

[2] 刘二林，李涛，冯海照．基于改进 FasterNet 和 YOLOv8s 的轨道扣件缺陷快速检测方法 [J]. 北京交通大学学报，2025, 49(6): 64-74.

[3] 侯涛，张云茜，牛宏侠．多尺度特征融合的铁路轨道扣件轻量化状态检测 [J]. 铁道科学与工程学报，2026,23(5):2454-2467.

[4] 牛宏侠，李朔，侯涛，等．MDQF-YOLO: 面向复杂环境的铁路异物检测算法 [J]. 计算机工程与应用，2026, 62(8): 116-129.

[5]Zhou Huixiang, Liu Yuhao, Wang Jian. Railway fastener defect detection using RFD-DETR: a lightweight real-time transformer-based approach[J/OL]. Plos One, 2025[2026-07-29]. https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0331513.

[6]Ma Siwei, Li Ronghua, Hu Henan. PGCI-YOLO: a railway fastener detection algorithm based on improved YOLOv8n[J]. Journal of Real-Time Image Processing, 2025, 22: 185.

[7]Lü Defang, Meng Jianjun, Meng Gaoyang, et al. Railway fastener defect detection model based on dual attention and MobileNet-v3[J]. World Electric Vehicle Journal, 2025, 16(9): 513.

[8]Tan Mingxing, Pang Ruoming, Le Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.Piscataway:IEEE, 2020: 10781-10790.

[9]Wu Yuhuan, Zhang Shichen, Liu Yun, et al. Low-resolution self-attention for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(9): 8180-8192.

[10]Chen Linwei, Gu Lin, Li Liang, et al. Frequency dynamic convolution for dense image prediction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2025: 30178-30188.

[11]Chen Mei, Zhang Maolin, Peng Jun, et al. A multi-category defect detection model for rail fastener based on optimized YOLOv8n[J]. Machines, 2025, 13(6): 511.

【作者简介】

李兴浩（2001—），男，重庆人，硕士研究生，研究方向：计算机视觉、目标检测。

（收稿日期：2026-07-01　修回日期：2026-08-05）