文章编号：1001-4632（2025）06-0034-10
引用格式：白堂博，刘伟峰，宫明明，等．基于改进YOLOv9的钢轨B显图像损伤识别算法[J]．中国铁道科学，2025，46(6)：34-43.
Citation：BAI Tangbo，LIU Weifeng，GONG Mingming，et al. Research on Track B Image Damage Recognition Algorithm Based on Improved YOLOv9 [J]. China Railway Science，2025，46 (6)：34-43.

基于改进YOLOv9的钢轨B显图像损伤识别算法

白堂博[1,2]，刘伟峰[1,2]，宫明明[3]，张玉华[4]，黄筱妍[4]

（1. 北京建筑大学 机电与车辆工程学院，北京 100044；
2. 北京建筑大学 城市轨道交通车辆服役性能保障北京市重点实验室，北京 100044；
3. 青岛职业技术学院 信息学院，山东 青岛 266555；
4. 中国铁道科学研究院集团有限公司 基础设施检测研究所，北京 100081）

摘 要：B显图像的目标检测是目前较为有效的钢轨探伤方法，为解决传统目标检测算法在检测B显图像时对于不同类型损伤容易产生误判漏报等问题，提出一种基于改进YOLOv9的钢轨B显图像损伤识别算法。首先，针对漏报误报问题，提出一种新型多层次特征融合机制，提高模型精度，减少漏报误报；其次，针对传统算法较为依赖高质量数据集和模型计算量较大的问题，优化损失函数并引入深度可分离卷积，提高模型训练效率；最后，在B显图像数据集上测试改进前后YOLOv9算法的各项检测数据进行改进YOLOv9算法验证。结果表明，经过各项改进后的YOLOv9模型检测平均精度达到99.5%，性能优于其他模型。

关键词：钢轨；探伤；B显图像；YOLOv9；目标检测；损伤识别
中图分类号：U216.3 **文献标识码**：A **doi**：10.3969/j.issn.1001-4632.2025.06.04

近年来，中国铁路取得了显著的发展，建设了世界上最庞大的高速铁路网络。截至2024年，高速铁路的里程已经超过4.8万km[1]。中国铁路的发展不仅在于数量上的增加，还在于技术的不断进步和运营效率的提升。高铁已经成为中国主要的长途交通方式之一，连接了全国的主要城市，同时也在向更偏远的地区延伸。随着铁路网络的迅速扩展和运载量的增加，钢轨的安全和维护成了一个关键问题。当前使用的钢轨检测基础方法依赖于人工检查和传统传感器技术，这些方法在效率和准确性上都有所限制。

基于深度学习的目标检测技术在检测精度和检测效率等方面比传统人工检测具有显著优势。B显图像是由搭载在钢轨探伤车或探伤仪上的依据超声波检测数据形成图像的超声波检测系统[2]。以B显图像作为研究对象对钢轨螺孔进行检测，可使用的深度学习模型包括YOLOv3模型[3]、BP神经网络模型[4]和AlexNet模型[5]等。目前常见目标检测模型主要以Fast R-CNN[6]、Faster R-CNN[7]和YOLO[8-12]为主流。如文献［13］通过优化YOLO神经网络的卷积层并运用反向传播算法对损失函数权重参数进行更新提升检测精度。文献［14］采用DenseBlock模块代替YOLOv5s网络中的Focus模块，并替换主干网络中的Bottleneck模块实现扣件状态的检测。文献［15］使用轻量主干网络替换YOLOv5的主干网络降低模型大小，并采用稀疏蒸馏方法压缩网络模型。史天运等[16]针对铁路接触网复杂场景的识别检测问题，引入了BiFPN特征融合模块和CBAM注意力机制模块，有效提高了异物识别精度。侯斐斐等[17]提出了一种基于Transformer框架的雷达图像隐藏缺陷自动检测算法，在DETR架构上创新性的嵌入了多尺度注意力模块并进行数据增强，以提高模型检测精度和鲁棒性，为复杂隧道环境下的缺陷检测提供了可行方

收稿日期：2024-11-03；修订日期：2025-05-15
基金项目：北京市自然科学基金资助项目（L211007，L221027）
第一作者：白堂博（1985—），男，山东泰安人，副教授，博士。E-mail：baitangbo@bucea.edu.cn

法。针对地下目标的精确检测和关键定位方面，该团队提出了一种双重 YOLO 关键点定位方法，在目标的检测和定位方面取得了显著进步，为地下目标识别领域提供新方法和思路[18]。梅田等[19]在钢轨浅表层损伤评估中综合利用超声波、漏磁和图像检测 3 种技术进行探伤，提出了多维伤损评价指标，并创新性地利用熵权法确定各指标权重。该研究提供了一种新的技术方法和评价模型，有助于提高伤损检测的准确性和效率，对铁路安全运营具有重要意义。

目前针对钢轨 B 显图像的检测方法研究较少，且不同损伤类型的 B 显图像差别较小，分类较为模糊，该领域缺乏有效的自动化图像检测手段。传统人工判伤虽然精度较高但依靠人工经验检测效率较低。以北京、上海、广州等大型城市为例，其城轨里程往往超过 600 km，以每张单轨检测图片长度 2 m 计算，检测 1 次即有 60 万张图片的检测任务，如果推广到货运线路则有更多的图像需要检测。传统基于人工的判伤方法难以适应目前的钢轨检测规模，所以提高 B 显图像检测的自动化程度具有很大实际意义。另外当前深度学习方法检测效率较高，但易产生漏报误报等问题，因此缺少一种针对 B 显图像且实用有效的检测模型。上述单阶段和双阶段检测方法虽然分别在检测速度和精度方面进行了优化，但大多数改进以及现有的最新模型的精度提高有限，主要改进点在轻量化方面，因此现有模型检测钢轨 B 显图像时，检测准确性仍存在提升空间。

针对以上问题，提出一种基于 YOLOv9 模型的改进方法，以提高钢轨损伤的检测精度和效率，从而保障铁路系统运行安全。

1　B 显图像

1.1　成像原理及过程

钢轨超声波探伤是应用超声波技术对钢轨进行无损检测的一种方法，具体成像过程如图 1 所示。这种方法通过超声波回波检测和评估钢轨内部是否存在缺陷，如裂纹、夹杂、脱碳、腐蚀等，以确保铁路安全运营。由于铁路运输对安全性的要求极高，定期的钢轨检测必不可少。其基本原理是超声波在均匀材料中会以一定的速度直线传播，当遇到界面或缺陷时会发生反射、折射或散射，此时产生的缺陷回波极值与正常回波极值存在明显差距，因此通过将回波转换为电信号并进一步处理可得到与钢轨损伤有关的 B 显图像，将损伤部位图像整理后可得到损伤数据集。

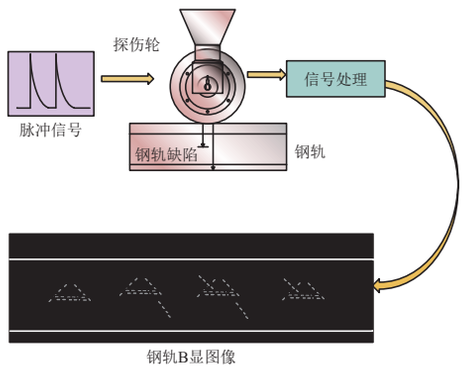

图 1　钢轨 B 显图像成像过程

1.2　损伤类别

在不同区域超声波探头的探测角度有较大区别，轨头部分设置 6 个 70°通道探头，轨腰部分设置 2 个 37°通道探头和 1 个 0°通道探头，轨底区域设置 1 个 37°通道探头，因此钢轨 B 显图像可被分为轨头，轨腰和轨底 3 部分，其中轨腰区域的损伤主要以螺孔上裂（sl）、螺孔水平裂纹（sp）、螺孔下裂（xl）、正常螺孔（zc）和螺孔组合裂纹（zh）为主。

2　基于改进 YOLOv9 的钢轨 B 显图像损伤识别算法

YOLOv10 和 YOLO11 与前代模型的提升主要在检测速度和检测效率方面，而对于 B 显图像检测过程中漏报误报问题，2 种模型未有针对性改进。考虑到钢轨 B 显图像中各类损伤之间差异较小、分类较为模糊，且实际检测过程中对于精度要求较高，因此本文采用实际检测精度较高的 YOLOv9 作为模型基本架构进行改进，结合空间通道重构卷积（Spatial and Channel reconstruction Convolution，SCConv）和多层次特征融合模块（Semantics and Detail Infusion，SDI）构建 1 种多层次特征提取体系。

首先，改进 C2f 融合空间通道重构卷积，提高单一特征提取层的特征提取效率，并将其输出作为 SDI 模块的输入进一步融合不同层级特征，获取更加全面的特征信息

此外，引入深度可分离卷积（Depth Wiseseparable Convolution，DWConv）以减少过拟合风险，提高模型的泛化能力。缓解检测中出现的梯度消失

问题，提高特征提取效率。

最后，对损失函数进行优化，引入辅助柔性损失函数（Inner-Soft Intersection over Union loss，Inner-SIoU），通过整合角度、距离、形状使模型能够提高对B显图像损伤的检测精度和收敛速度。

改进后的网络模型如图2所示。

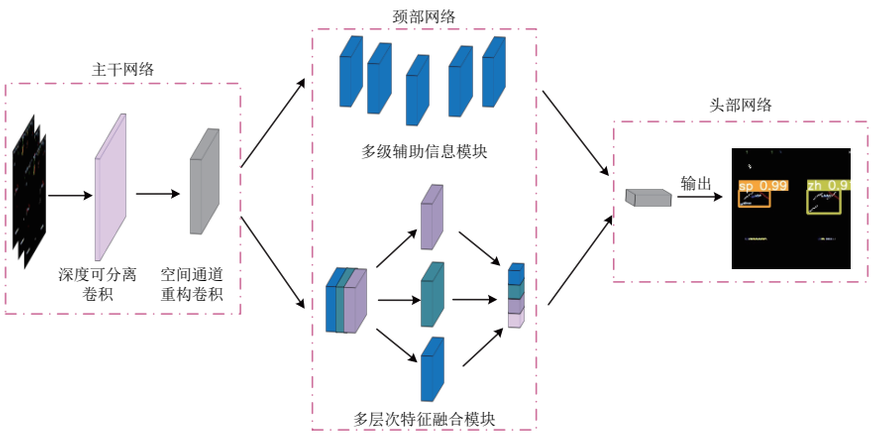

图2 改进后 YOLOv9模型

2.1 改进特征提取模块

为解决检测过程中存在的漏报误报问题，提出1种新型SCConv模块，可有效提高检测精度。SCConv中空间重构单元SRU利用归一化后的特征和激活函数（Sigmoid）生成权重，根据权重大小将特征图分离为信息量较大和较小的部分。通过交叉重组的方式，将分离出的特征重构减少空间维度上的多余信息。通道重构单元CRU将经过SRU处理的特征进一步分割，对分割后特征分别进行全局卷积和点卷积操作。最后，将变换后的特征合并，形成最终的通道精炼特征，如图3所示。图中γ为空间像素方差，将输入特征w_1和w_2分别与Threshold函数计算结果相乘得到x_{w1}和x_{w2}，用于表示价值较高的信息和价值较低的信息并进行拼接重构，达到初步区分信息价值的目的并得到空间细化特征x_w，随后对其进行分割得到x_{up}和x_{low}，前者x_{up}作为高价值特征提取的输入，后者x_{low}作为x_{up}的补充。

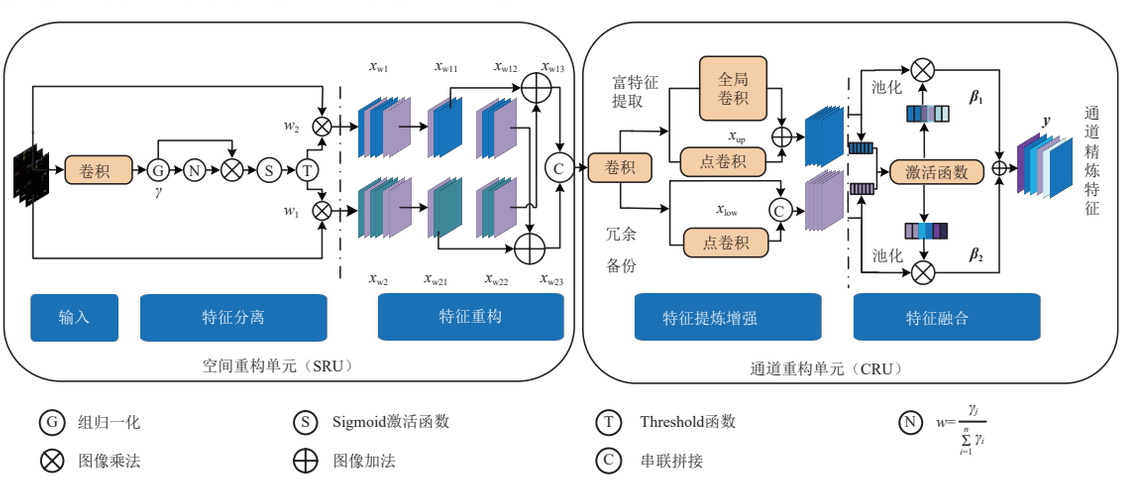

图3 SCConv结构

对高价值特征提取的输入进行全局卷积和点卷积，全局卷积操作将特征分为多组进行相关性计算，将计算结果用于后续的特征提炼，增强特征通道表示；点卷积操作则通过1×1的卷积核，实现通道维度的降维或升维。对x_{low}进行点卷积。随后同时使用全局平均池化和Softmax激活函数合并计算结果得到特征权重向量β_1和β_2，最后将β_1和β_2进一步合并得到通道精炼特征Y。这种结构使得特征提取模块有效减少特征之间冗余，并提高模型特征提取性能。

2.2 引入多层次特征融合模块

由于不同损伤类型的目标尺寸区别较小，分类

较为模糊，为对不同类型的目标实现更好检测效果，引入多层次特征融合（Semantics and Detail Infusion，SDI）模块。其机制是在输入特征图的基础上，对每个输入层次的特征应用空间注意力机制和通道注意力机制，即

$$f_{X_1}=\alpha_{X_1}\beta_{X_1}f_{X_0} \tag{1}$$

式中：f_{X_0}和f_{X_1}分别为第X_0和X_1层处理后得到的特征图；α_{X_1}和β_{X_1}分别为第X_1层中空间注意力参数和通道注意力参数。

SDI 模块结构图 4 所示。第 1 步输入原始 B 显图像，该图像首先在图中主干网络第 2 层、第 4 层和第 6 层中完成特征提取。主干网络中不同层级的特征提取尺度不同，第 2 层、第 4 层和第 6 层分别完成从全局到局部的特征提取。第 2 步将不同层级的特征输入 SDI 模块，SDI 模块统一对输入特征使用空间注意力机制和通道注意力机制，对第 2 层输入特征进行下采样以缩小特征尺度，对第 4 层输入特征使用映射特征尺度不变，对第 6 层输入特征使用上采样以放大特征尺度，最后对各层特征使用平滑卷积，并进行特征融合。

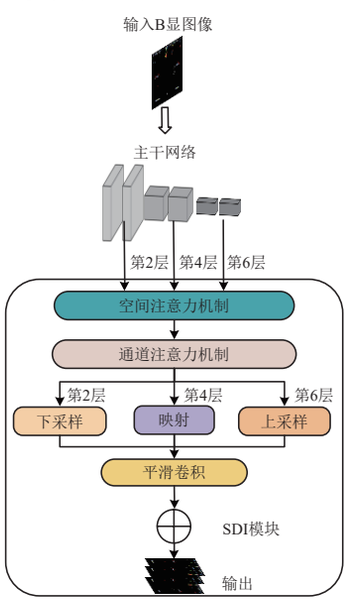

图 4　SDI 模块

2.3　优化损失函数

检测算法中交并比（Intersection over Union，IoU）代表预测框和目标框的交并比值，其数值越大，意味着预测的精度越高。而对应损失函数则为 1 减去交并比。

通过优化损失函数可有效降低训练中模型对数据集的依赖。由于 YOLOv9 中使用完全交并比损失函数（Complete Intersection over Union loss，CIoU），其参数只能反应宽高比而无法反应目标框与预测框的真实大小，且实际工况下钢轨 B 显图像中各类损伤面积存在一定差异。此种情况在检测简单损伤（如螺孔上裂，螺孔下裂等）和复杂损伤（螺孔组合裂纹）时体现尤为明显，使得模型在检测过程中难以判定目标框和预测框的差异，导致其泛化能力较弱。为弥补现有 CIoU 的缺陷，引入辅助边界框（Inner-Intersection over Union，Inner-IoU）和柔性损失函数（Soft Intersection over Union loss，SIoU）计算损失，以加速边界框定位准确性。前者 Inner-IoU 引入尺度因子比，控制辅助边界框的尺度大小，从而解决不同损伤面积差异带来的检测困难问题，通过对不同类型的损伤使用不同尺度因子辅助边界框，可以克服现有方法在泛化能力方面的局限；后者 SIoU 则直接优化交并比计算方式，从根本上解决预测框与目标框定位问题。其计算方式综合考量预测框与真实框之间的角度、中心距离和形状差异多种因素，而 CIoU 计算过程中只考虑宽高比，因此 SIoU 优势明显。为结合 Inner-IoU 与 SIoU 优势，将二者结合为辅助柔性损失函数（Inner-Soft Intersection over Union loss，Inner-SIoU）。

当尺度因子小于 1 时，辅助框小于实际边界框，辅助边界框交并比I_{inner}计算式为

$$I_{\text{inner}}=\frac{S_{\text{inner}-\text{box}}}{S_{\text{box}}} \tag{2}$$

式中：$S_{\text{inner}-\text{box}}$为辅助边界框与真实框重叠面积；$S_{\text{box}}$为目标框与预测框重叠面积。

当尺度因子大于 1 时，辅助边界框大于实际边界框，辅助边界框交并比I_{inner}计算式为

$$I_{\text{inner}}=\frac{S_{\text{box}}}{S_{\text{inner}-\text{box}}} \tag{3}$$

柔性交并比损失函数L_{SIoU}和搭配使用辅助柔性损失函数$L_{\text{Inner}-\text{SIoU}}$的计算式分别为

$$L_{\text{SIoU}}=1-I+\frac{\Delta+\text{ʊ}}{2} \tag{4}$$

$$L_{\text{Inner}-\text{SIoU}}=L_{\text{SIoU}}+I-I_{\text{inner}} \tag{5}$$

式中：I为预测框与目标框交并比；Δ为中心点距离控制因子，用于衡量预测框中心点距离和角度偏差；ʊ为形状偏差因子。

形状偏差因子用于处理矩形预测框长宽比值，使其与目标框更容易重叠。

使用 Inner-SIoU 可进一步减少检测过程中的

损失率，从而解决训练时由于低质量实例导致收敛速度较慢的问题，并且使模型可以更有效地从有限的数据中学习，减少过拟合的风险。

2.4 引入深度可分离卷积

YOLOv9 主干网络中使用的卷积模块局限于特征局部。这种局限性使得模型在处理复杂场景时，无法有效捕捉全局特征。

原模型处理螺孔上裂和下裂时，传统卷积的局限性体现较为明显，由于螺孔上裂和下裂通常具有一定随机性损伤特征，可能出现在较远位置，传统卷积难以有效提取损伤全局信息，会出现漏检或误检的情况，从而影响检测精度。

本文引入深度可分离卷积（Depth Wiseseparable Convolution，DWConv）进一步提高检测精度。深度可分离卷积由 2 部分组成：深度卷积和逐点卷积。逐点卷积通过引入通道间的线性组合，可提取和组合不同通道的特征，从而提升模型的特征表达能力，这对于提高模型检测螺孔上裂和下裂时的精度较为重要。DWConv 模块详细计算过程如下。

（1）输入数据。模块接收 1 个多通道的特征图作为输入。

（2）深度卷积。在深度卷积阶段，每个输入通道都与 1 个独立的卷积核进行卷积操作。深度卷积主要用于提取空间特征，每个通道独立处理，不混合通道信息。

（3）逐点卷积。深度卷积的输出将作为逐点卷积的输入，逐点卷积用于混合通道信息，将深度卷积生成的各个通道特征进行线性组合，以提取通道特征。

（4）非线性激活函数。在逐点卷积后，将会应用非线性激活函数以及批量归一化层以增加网络的非线性表达能力。

（5）输出。经过前几个步骤处理后得到的特征图，将其输入到下一层网络，作为下一阶段特征提取模块的输入。

DWConv 模块的优势在于提高了模型对于螺孔上裂以及下裂的检测精度的同时，可略降计算量。

3 试验与结果分析

试验中主要采用准确度 P、召回率 R，F_1 分数、IoU 为 0.5 时的均值平均精度（Mean Average Precision0.5，$mAP_{0.5}$）和 IoU 为 0.5 到 0.95 时的均值平均精度（Mean Average Precision0.95：0.5，$mAP_{0.5:0.95}$）5 种评价指标比较不同模型的检测效果，测试的模型主要包括 Faster-R-CNN，YOLOv5，YOLOv7，YOLOv8，YOLOv9 和改进 YOLOv9。数据集的测试和训练在 Windows11 系统和 Pycharm 集成开发环境完成，显卡为 RTX4060，CUDA11.8，Torch 2.1.2。

3.1 损失函数

为了方便分析训练时模型的损失值随训练批次的变化情况，将改进后使用 Inner-SIoU 损失函数模型与改进前使用 CIoU 损失函数模型训练过程中损失值绘制成曲线观察其变化，如图 5 所示。

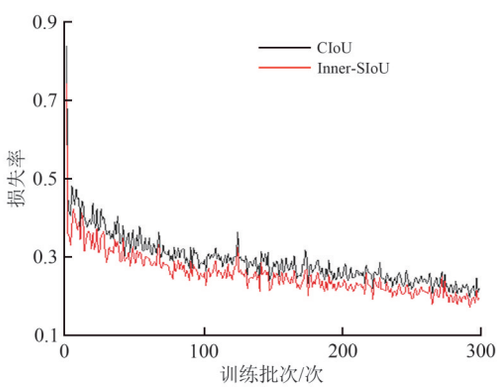

图 5 改进前后损失率对比

由图 5 可知：改进后的 YOLOv9 模型与改进前相比其损失率收敛速度明显提高，在训练 190 批次后已经基本收敛，而使用 CIoU 时当训练批次达到 280 批次才基本收敛。训练过程中，使用 Inner-SIoU 损失率相比改进前更少，这说明模型在更少的数据上达到相同的性能，从而降低了模型对数据集的需求，证明改进后模型性能有所提高以及训练过程的可靠。

3.2 对比试验

采用的数据集来自某高铁实际线路，数据集包括 303 张 B 显图像，将数据集按照 7：2：1 的比例划分为训练集、测试集和验证集。数据集中的目标类别共有 5 类，分别为螺孔上裂，螺孔水平裂纹，螺孔下裂，正常螺孔和螺孔组合裂纹，且存在单个图像出现多个损伤。各类型损伤数量为螺孔正常 154 张、螺孔下裂 53 张、螺孔上裂 51 张、螺孔水平裂纹 56 张和螺孔组合裂纹 76 张。训练批次为 100，YOLOv9 改进前后的 $mAP_{0.5}$ 如图 6 所示，当训练批次达到 70 次时改进后 YOLOv9 的结果已基本收敛且精度维持在 99.5% 附近，而改进前在训练批次达到 95 时 $mAP_{0.5}$ 达到 96.7%，经过 4 项改

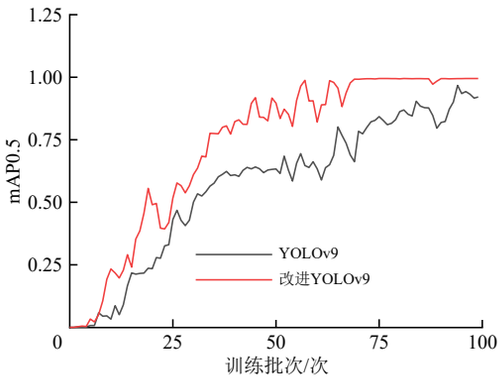

图 6　改进前后检测精度对比

进后模型精度更高且收敛速度更快，验证了改进的有效性。

通过对比图 7 改进前后各评价指标可知：改进后模型的 $mAP_{0.5}$ 提高 2.8%，$mAP_{0.5:0.95}$ 提高 3.5%，准确率提高 6.9%，F_1 分数提高 11%，召回率提高 0.9%。

经过试验检测，改进的 YOLOv9 能够精确检测出各个损伤类型，包括螺孔上裂、螺孔水平裂纹、螺孔正常、螺孔组合裂纹、螺孔下裂。检测结果如图 8 和图 9 所示。由图 8 和图 9 可知：改进后模型对各类较为典型的损伤检测置信度接近 100%，

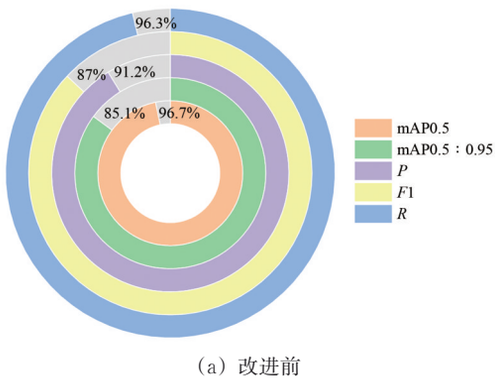

（a）改进前

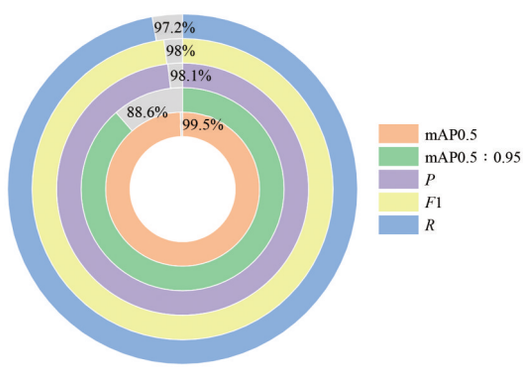

（b）改进后

图 7　改进前后评价指标对比

对于各类损伤均有较强的损伤识别能力，能够较好地完成损伤检测任务。

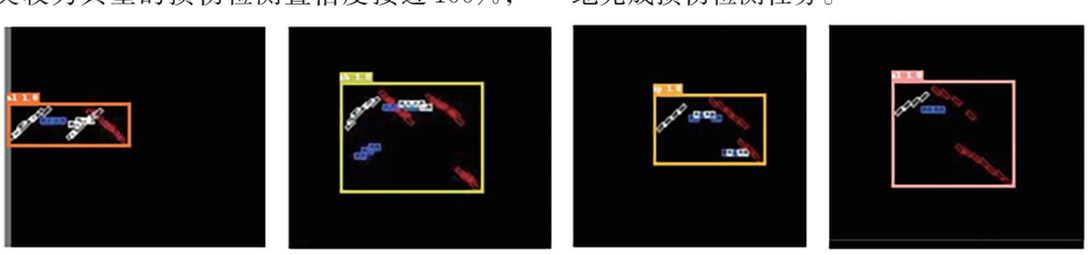

（a）螺孔上裂　（b）螺孔组合裂纹　（c）螺孔水平裂纹　（d）螺孔下裂

图 8　改进后不同损伤类型检测效果

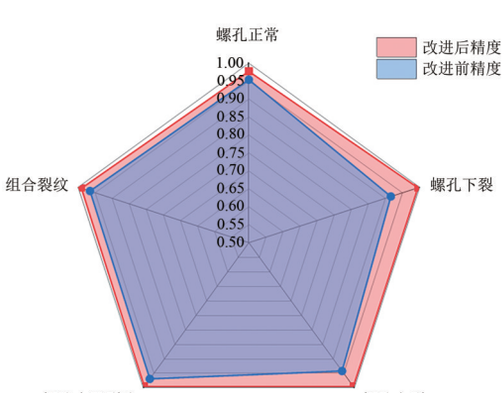

图 9　改进前后不同损伤类型精度对比

由图 9 可知：改进后各损伤类型检测精度均有提高，其中螺孔下裂精度提高 7.9%，螺孔上裂检测精度提高 5.3%，螺孔水平裂纹检测精度提高 2.6%，螺孔组合裂纹检测精度提高 2.5%，螺孔正常检测精度提高 2.3%。

图 10—图 13 给出了模型改进前后各类损伤置信度对比。

由图 10—图 13 可知：改进后水平裂纹置信度从 0.94 提升至 0.97，正常螺孔置信度从 0.93 提升

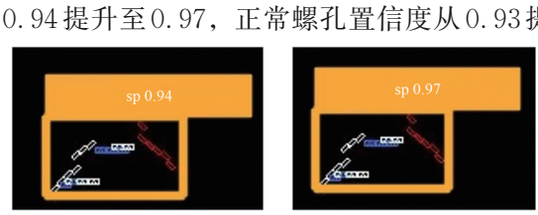

（a）改进前　（b）改进后

图 10　改进前后螺孔水平裂纹损伤置信度对比



（a）改进前 （b）改进后

图 11 改进前后正常螺孔损伤置信度对比



（a）改进前 （b）改进后

图 12 改进前后螺孔上裂损伤置信度对比



图 13 改进前后螺孔组合裂纹损伤置信度对比

至 0.94。螺孔上裂试验中改进前模型将其误判为正常螺孔，而改进后模型则正确识别出损伤类型且置信度为 0.98，对组合损伤类型，置信度由 0.88 提高至 0.98。以上结果说明改进后算法有效减少了误报。

为进一步评估改进后算法的性能，本文将对比目前主流算法和本文算法，结果见表 1。改进后的 YOLOv9 在 $mAP_{0.5}$，$mAP_{0.5:0.95}$、准确度、F1 分数均有所提高，与 YOLOv10x，YOLOv10l，YOLO11 模型相比本文方法的 $mAP_{0.5}$，$mAP_{0.5:0.95}$ 以及 F1 分数方面有一定优势，证明了本文方法的优越性。

表 1 不同模型性能对比

评价指标	$mAP_{0.5}$	$mAP_{0.5:0.95}$	准确度	F1 分数
Faster-R-CNN	0.803	0.647	0.745	0.72
YOLOv5n	0.822	0.671	0.853	0.74
YOLOv5n	0.861	0.685	0.816	0.61
YOLOv7	0.963	0.773	0.905	0.95
YOLOv8	0.962	0.850	0.911	0.96
YOLOv10n	0.834	0.683	0.865	0.65
YOLOv10s	0.887	0.778	0.874	0.75
YOLOv10x	0.918	0.771	0.928	0.79
YOLOv10l	0.941	0.821	0.946	0.84
YOLOv10b	0.949	0.826	0.948	0.82
YOLO11	0.943	0.811	0.935	0.83
本文方法	0.995	0.886	0.927	0.98

为进一步验证改进方法的有效性，本文将对比目前 YOLO 系列最新模型 YOLO11 与本文改进方法的混淆矩阵，结果如图 14 所示。

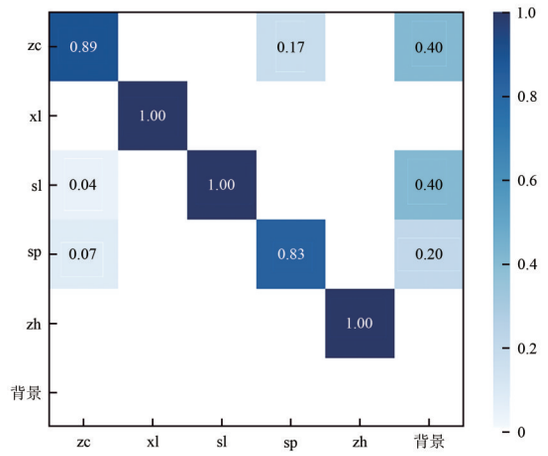

（a）YOLO11

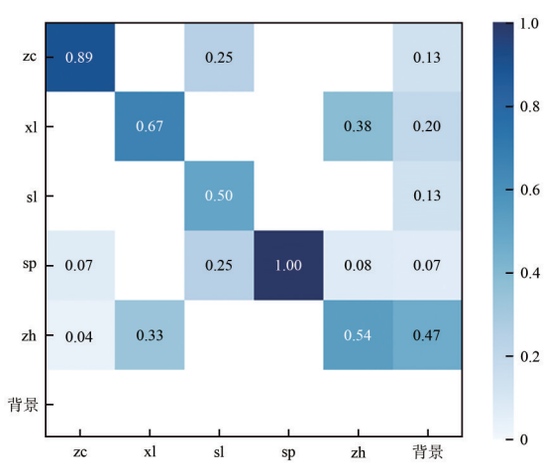

（b）本文方法

图 14 YOLO11 与本文方法混淆矩阵对比

由图 14 可知：本文方法混淆矩阵的正确分类的比例普遍较高，分类错误明显减少。

以上数据说明有效改善了检测过程中的漏判误判问题，在螺孔下裂、螺孔上裂和螺孔组合裂纹损伤类型的识别方面体现尤为明显，这表明模型在这些类型的损伤上能够完全正确地进行分类。

试验表明：本文模型在损伤分类准确率、减少损伤类型的误判、处理背景噪音以及降低损伤间混淆等方面都显示出了优越性。

3.3 消融试验

为进一步验证改进模型的性能，进行了消融试验，将 SCConv，DWConv，Inner-SIoU，SDI 融入模型，试验设置了 5 组模型，见表 2。消融试验结果见表 3。

在主干网络中融入 SCConv 后，模型大小基本

表 2　消融试验模型设置

模型	SCConv	DWConv	Inner-SIOU	SDI
YOLOv9c	—	—	—	—
YOLOv9c-1	√	—	—	—
YOLOv9c-2	√	√	—	—
YOLOv9c-3	√	√	√	—
YOLOv9c-4	√	√	√	√

表 3　消融试验结果

模型	GFLOPS	$mAP_{0.5}$	$mAP_{0.5:0.95}$	准确率
YOLOv9c	239.0	0.967	0.851	0.912
YOLOv9c-1	235.9	0.981	0.852	0.921
YOLOv9c-2	223.8	0.988	0.869	0.923
YOLOv9c-3	223.8	0.992	0.873	0.925
YOLOv9c-4	227.5	0.995	0.886	0.927

不变，检测精度有较大提高；引入 DWConv 后，模型大小有所减少，检测精度进一步提高；在此基础上将 CIoU 替换，检测精度进一步提高；最后，添加 SDI，模型精度进一步提高。由于在实际检测过程中检测时间较为充裕，因此提高精度比提高检测速度更为重要，本文方法在略微降低模型大小的同时在精度方面提高明显，十分适用于实际使用场景。

3.4　数据增强试验

为防止数据集过小对试验造成影响，本文进行数据增强以验证实际性能，图像增强手段主要包括：锐化图像、调整亮度和图像雾化。增强后各类型损伤数量包括：螺孔正常 403 张，螺孔下裂 332 张，螺孔上裂 267 张，螺孔水平裂纹 342 张，螺孔组合裂纹 586 张。试验结果见表 4。

以上试验表明：本文方法的 mAP0.5 和 mAP0.5∶0.95 优于 YOLOv9，YOLOv10 和 YOLO11，F1 分数均优于 YOLOv9 和 YOLOv10。本试验通过数据扩增手段，改善数据集多样性和规模，验证了本文方法改进的有效性。

表 4　实验结果

模型	$mAP_{0.5}$	$mAP_{0.5:0.95}$	F1 分数
YOLOv9	0.972	0.846	0.92
YOLOv10	0.968	0.835	0.88
YOLO11	0.966	0.801	0.96
本文方法	0.988	0.859	0.96

4　结　论

（1）将主干网络中的卷积模块替换为深度可变卷积模块，模型大小略微减少并提高了检测精度，使模型可以更好地满足实际工况中对于图像的检测需求。

（2）构建基于改进 YOLOv9 的钢轨 B 显图像损伤识别算法，提出一种基于 C2f 的改进特征提取模块，将 SCConv 融入特征提取模块，提高了其特征提取能力。

（3）引入 SDI 通过将不同层次的特征信息进一步融合，从而使模型更加全面的提取目标特征，实现可高效识别分析 B 显图像中各类损伤，与其他方法相比准确率较高，有效减少了漏报误报。

（4）通过优化损失函数，降低了训练过程中的损失率并使模型收敛速度更快，有效降低了对高质量数据集的依赖。

（5）几种常用检测方法与本文方法对比试验结果表明，本文方法对各类损伤的检测精度均有提高，验证了本文提出改进算法的准确性。解决了钢轨 B 显图像自动化检测与分析精度较低的问题。

参　考　文　献

[1] 韩宝明，习喆，孙亚洁，等.2022 年世界城市轨道交通运营统计与分析综述[J].都市快轨交通，2023，36(1)：1-8.
（HAN Baoming，XI Zhe，SUN Yajie，et al. Statistical Analysis of Urban Rail Transit Operation in the World in 2022：a Review [J]. Urban Rapid Rail Transit，2023，36 (1)：1-8. in Chinese）

[2] 张玉华，许贵阳，李培，等.钢轨探伤车自主化超声检测系统的关键技术[J].中国铁道科学，2015，36(5)：131-136.
（ZHANG Yuhua，XU Guiyang，LI Pei，et al. Key Technology to Autonomous Ultrasonic Detection System of Rail Flaw Detection Car [J]. China Railway Science，2015，36 (5)：131-136. in Chinese）

[3] 何庆，陈正兴，王启航，等.基于改进 YOLO V3 的钢轨伤损 B 显图像识别研究[J].铁道学报，2022，44(12)：82-88.
（HE Qing，CHEN Zhengxing，WANG Qihang，et al. Research on B-Scan Image Recognition of Rail Defect Based on Improved YOLO V3 [J]. Journal of the China Railway Society，2022，44 (12)：82-88. in Chinese）

[4] 黄筱妍，石永生，张玉华，等.超声波钢轨探伤车 B 显数据伤损模式分类技术研究[J].中国铁路，2018(3)：82-87.

(HUANG Xiaoyan, SHI Yongsheng, ZHANG Yuhua, et al. BP Neural Network Based on Rail Flaw Classification of RFD Car's B-Scan Data [J]. China Railway, 2018 (3): 82-87. in Chinese)

[5] 孙次锁,刘军,秦勇,等.基于深度学习的钢轨伤损智能识别方法[J].中国铁道科学,2018,39(5):51-57.
(SUN Cisuo, LIU Jun, QIN Yong, et al. Intelligent Detection Method for Rail Flaw Based on Deep Learning [J]. China Railway Science, 2018, 39 (5): 51-57. in Chinese)

[6] GIRSHICK R. Fast R-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE, 2015: 1440-1448.

[7] GAVRILESCU R, ZET C, FOŞALĂU C, et al. Faster R-CNN: an Approach to Real-Time Object Detection [C] // 2018 International Conference and Exposition on Electrical and Power Engineering (EPE). New York: IEEE Press, 2018: 165-168.

[8] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only Look Once: Unified, Real-Time Object Detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 779-788.

[9] REDMON J, FARHADI A. YOLOv3: an Incremental Improvement [EB/OL]. [2018-04-08]. https: //arxiv.org/abs/1804.02767.

[10] BOCHKOVSKIY A, WANG C, LIAO H M. YOLOv4: Optimal Speed and Accuracy of Object Detection [J]. 2020. DOI: 10.48550/arXiv.2004.10934.

[11] LI C Y, LI L L, JIANG H L, et al. YOLOv6: a Single-Stage Object Detection Framework for Industrial Applications [EB/OL]. [2024-03-19]. https://doi.org/10.48550/arXiv.2209.02976.

[12] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2023: 7464-7475.

[13] 王兵水,郑树彬,柴晓冬,等.基于YOLO的轨道扣件状态检测[J].传感器与微系统,2021,40(4):135-138.
(WANG Bingshui, ZHENG Shubin, CHAI Xiaodong, et al. State Detection of Track Fastener Based on YOLO [J]. Transducer and Microsystem Technologies, 2021, 40 (4): 135-138. in Chinese)

[14] 李兆洋,李柏林,罗建桥,等.基于改进SSD模型的高铁扣件定位算法[J].铁道标准设计,2020,64(5):24-29.
(LI Zhaoyang, LI Bailin, LUO Jianqiao, et al. High-Speed Rail Fastener Positioning Algorithm Based on Improved SSD Model [J]. Railway Standard Design, 2020, 64 (5): 24-29. in Chinese)

[15] 杨佳昊,左昊轩,黄祺成,等.基于YOLO v5s的作物叶片病害检测模型轻量化方法[J].农业机械学报,2023,54(增1):222-229.
(YANG Jiahao, ZUO Haoxuan, HUANG Qicheng, et al. Lightweight Method for Crop Leaf Disease Detection Model Based on YOLO v5s [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54 (Supplement 1): 222-229. in Chinese)

[16] 史天运,侯博,李国华,等.基于改进DINO的铁路接触网异物检测方法[J].中国铁道科学,2024,45(4):158-167.
(SHI Tianyun, HOU Bo, LI Guohua, et al. Foreign Object Detection Method for Railway Contact Network Based on Improved DINO [J]. China Railway Science, 2024, 45 (4): 158-167. in Chinese)

[17] 侯斐斐,张智轩,崔广炎,等.DETR-MCA:基于探地雷达图像的隧道衬砌内部缺陷的智能检测算法[J].铁道科学与工程学报,2025,22(4):1840-1852.
(HOU Feifei, ZHANG Zhixuan, CUI Guangyan, et al. DETR-MCA: Intelligent Detection Algorithm for Tunnel Lining Defects Based on GPR Images [J]. Journal of Railway Science and Engineering, 2025, 22 (4): 1840-1852. in Chinese)

[18] 侯斐斐,彭应昊,董健,等.基于双重YOLOv8-pose模型的探地雷达双曲线关键点检测与目标定位[J].电子与信息学报,2024,46(11):4305-4316.
(HOU Feifei, PENG Yinghao, DONG Jian, et al. Ground Penetrating Radar Hyperbolic Keypoint Detection and Object Localization Based on Dual YOLOv8-Pose Model [J]. Journal of Electronics & Information Technology, 2024, 46 (11): 4305-4316. in Chinese)

[19] 梅田,张玉华,熊龙辉,等.基于熵权法的高速铁路钢轨浅表层伤损分级评价研究[J].铁道科学与工程学报,2025, 22 (4):1420-1431.
(MEI Tian, ZHANG Yuhua, XIONG Longhui, et al. Research on Shallow Surface Flaw Classification and Evaluation of High-Speed Railway Based on Entropy Method [J]. Journal of Railway Science and Engineering, 2025, 22 (4): 1420-1431. in Chinese)

Research on Track B Image Damage Recognition Algorithm Based on Improved YOLOv9

BAI Tangbo[1,2], LIU Weifeng[1,2], GONG Mingming[3], ZHANG Yuhua[4], HUANG Xiaoyan[4]

(1. School of Mechanical-Electronic and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;
2. Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicle, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;
3. School of Information, Qingdao Technical College, Qingdao Shandong 266555, China;
4. Infrastructure Inspection Research Institute, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China)

Abstract: Target Detection in B-scan images is currently a relatively effective method for rail flaw detection. To address the problem that traditional object detection algorithms tend to produce misjudgments and omissions for different types of flaws when detecting B-scan images, this paper proposes a flaw recognition algorithm for rail B-scan images based on the improved YOLOv9. Firstly, aiming at the problem of omissions and misjudgments, a novel multi-level feature fusion mechanism is proposed to improve model accuracy and reduce omissions and misjudgments. Then, aiming at the problems that traditional algorithms rely heavily on high-quality datasets and have a large model computational load, the loss function is optimized and the depthwise separable convolution is introduced to improve model training efficiency. Finally, verification of the improved YOLOv9 algorithm is conducted by testing various detection metrics of the YOLOv9 algorithm (before and after improvement) on the B-scan image dataset. The results show that the detection average precision (AP) of the YOLOv9 model after various improvements reaches 99.5%, and its performance outperforms other models.

Key words: Rail; Flaw detection; B-scan image; YOLOv9; Object detection; Flaw recognition

（责任编辑　吴　彬）