

# 基于改进 YOLOv5s 算法的轨道扣件缺陷检测

张兴盛,阮久宏\*,沈本兰,李金城,华超

山东交通学院轨道交通学院,山东 济南 250357

**摘要:**针对轨道扣件缺陷复杂程度较高、严重影响列车行车安全、人工巡检效率较低等问题,提出一种基于计算机视觉的轨道扣件缺陷检测算法。考虑轨道扣件缺陷的特征以及检测时所处复杂作业环境,采用 ConvNeXt V2 模块代替 YOLOv5s 算法主干网络前端 C3 模块,采用 Efficient Rep 网络改进 YOLOv5s 算法主干网络末端,引入具有动态非聚焦机制的损失函数 WIoU 加快 YOLOv5s 算法模型计算收敛速度,形成改进 YOLOv5s 算法(CR-YOLOv5s 算法),检测轨道扣件缺陷状态,开展消融试验,并与快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)算法、单阶多层检测(single shot multibox detector, SSD)算法、YOLOv3 算法、YOLOv4 算法检测进行对比试验。试验结果表明:CR-YOLOv5s 算法的召回率为 89.3%,平均检测精度均值为 95.8%,平均检测时间为 10.1 ms,3 项指标均优于其他 4 种算法;与 YOLOv5s 算法相比,CR-YOLOv5s 算法的召回率均值提高 5.7%,平均检测精度均值提高 4.0%,平均检测时间延长 1.0 ms。综合考虑轨道扣件状态检测任务要求、召回率、平均检测精度均值、平均检测时间等因素,采用 CR-YOLOv5s 算法检测轨道扣件缺陷状态更具优势。

**关键词:**轨道扣件;缺陷检测;YOLOv5s 算法;ConvNeXt V2 模块;Efficient Rep 网络;损失函数 WIoU

中图分类号:U216.3

文献标志码:A

文章编号:1672-0032(2025)02-0010-09

引用格式:张兴盛,阮久宏,沈本兰,等. 基于改进 YOLOv5s 算法的轨道扣件缺陷检测[J]. 山东交通学院学报, 2025, 33(2):10-18.

ZHANG Xingsheng, RUAN Juhong, SHEN Benlan, et al. Track fastener defect detection based on improved YOLOv5s algorithm[J]. Journal of Shandong Jiaotong University, 2025, 33(2):10-18.

## 0 引言

轨道扣件长期受车辆荷载、振动及外界环境影响,易出现扣件断裂、损伤、移位、缺失等问题,严重影响列车运行安全<sup>[1]</sup>。传统的扣件缺陷检测方法主要是人工巡检,工作量较大、效率较低,作业时间严重受限,只能在列车运行天窗期作业。人工巡检的检测精度主要依赖巡检人员的工作经验,受主观因素影响较大,易出现漏检和错检,无法满足日益增长的铁路日常养护工作要求<sup>[2]</sup>。随着计算机视觉技术的快速发展,现有传统的图像处理和机器学习技术已广泛应用于轨道扣件检测<sup>[3]</sup>。传统的图像处理技术在检测轨道扣件时,首先通过扣件间的几何信息获取目标位置,并对扣件图像采取去噪、裁剪等预处理操作,然后采用多种特征提取方法(如尺度不变特征转换(scale-invariant feature transform, SIFT)、方向梯度直方图(histogram of oriented gradient, HOG)、局部二值模式(local binary patterns, LBP)等)从图像中提取关键特征,最后通过分类识别扣件缺陷状态<sup>[4]</sup>。采用机器学习技术的扣件缺陷检测方法是在传统图像处理基础上通过支持向量机(support vector machine, SVM)或聚类方式对不同特征的图像进行分类,实现扣件缺陷

收稿日期:2024-02-29

基金项目:山东省自然科学基金青年基金项目(ZR2022QF107)

第一作者简介:张兴盛(1998—),男,山东潍坊人,硕士研究生,主要研究方向为轨道交通检测技术,E-mail:254937441@qq.com。

\*通信作者简介:阮久宏(1971—),男,济南人,教授,硕士研究生导师,工学博士,主要研究方向为先进车辆技术、机器人技术和轨道交通技术,E-mail:ruanjh2011@163.com。

检测。Liu 等<sup>[5]</sup>通过对称图像及增强算法方向梯度直方图 (enhancement algorithm-histogram of oriented gradient, EA-HOG) 特征分析检测扣件图像特征;Yang 等<sup>[6]</sup>将扣件图像的方向场作为特征描述符,采用方向场模板匹配技术实现扣件特征识别;代先星等<sup>[7]</sup>基于先验知识验证方法对扣件精确定位,采用完整剪辑图像模拟损坏的扣件,采用特殊分类器对不同状态特征的扣件进行分类;Liu 等<sup>[8]</sup>采用具备多尺度特征的深度检测网络 (metasploit framework of deep detection network, MSF-DDN) 精确定位扣件区域,通过构建区域网络实现扣件检测。

目前,目标检测领域的神经网络模型主要分为一阶段模型和二阶段模型两类<sup>[9]</sup>。采用一阶段模型检测图像特征无需单独搜索获取候选区域,可直接获取候选区域进行分类,如单阶多层检测 (single shot multibox detector, SSD)<sup>[10]</sup>、YOLO (you only look once)<sup>[11]</sup>。采用二阶段模型检测图像特征分为两个阶段,第一阶段搜索获取候选区域,第二阶段对候选区域进行分类,如快速区域卷积神经网络 (faster region-based convolutional neural networks, Faster R-CNN)<sup>[12]</sup>。Wei 等<sup>[13]</sup>、黄牛祥等<sup>[14]</sup>采用 Faster R-CNN 算法检测扣件状态特征,检测精度比传统算法略高,但检测效率较低;李少佳等<sup>[15]</sup>设计一种轻量化 GoogleNet 网络模型检测扣件状态特征,检测效率明显提高,但检测精度较低;高嘉琳等<sup>[16]</sup>采用改进 YOLOv4 目标检测算法检测扣件状态特征,检测精度比 Faster R-CNN 算法高,但检测效率不满足巡检需求。随着检测算法不断改进,检测精度随之提高,但仍有较大提升空间。

结合扣件检测精度、巡检效率均较低,检测环境复杂,扣件结构缺陷特征多样化等问题,在 YOLOv5s 算法基础上引入 ConvNeXt V2 模块<sup>[17]</sup>和 Efficient Rep 网络<sup>[18]</sup>,分别改进 YOLOv5s 主干网络前端和末端,更有效地提取输入图像数据特征,为后续区域定位、特征分类等操作提供高效特征信息支持,采用损失函数 WIoU 加快 YOLOv5s 算法的计算收敛速度,形成 CR-YOLOv5s 算法,以期提高扣件状态特征检测精度和巡检效率。

## 1 改进 YOLOv5s 算法

### 1.1 引入 ConvNeXt V2 模块

现场采集的轨道扣件图像噪声较多,背景复杂且相似度较高,YOLOv5s 算法主干网络前端 C3 模块对轨道扣件图像特征提取不充分,未能准确检测扣件结构缺陷特征,易出现漏检和误检等情况。在 YOLOv5s 主干网络前端引入由编码器和解码器组成的 ConvNeXt V2 模块<sup>[17]</sup>,替换 C3 模块,其工作原理如图 1 所示。编码器和解码器均采用纯卷积网络结构,与传统神经网络相比,可扩展性更强。

在图像数据训练过程中将普通卷积转化为稀疏卷积,使 YOLOv5s 算法模型仅学习可见数据点,有效降低模型复杂度,增强网络学习泛化性,更快捕捉上、下层的语义信息。

ConvNeXt V2 模块采用残差连接的形式,其结构如图 2 所示。在主分支网络中,采用  $7 \times 7$  卷积核对输入特征逐通道进行深度卷积操作,通过层归一化处理加速网络收敛,减少梯度动荡。层归一化结果

$$y = \gamma \hat{x} + \beta \equiv L_{\gamma, \beta}(x),$$

式中: $x$  为特征图输入元素; $\hat{x}$  为  $x$  归一化结果; $\gamma, \beta$  为学习参数; $L_{\gamma, \beta}(x)$  为层归一化函数, $L_{\gamma, \beta}(x) = \beta + \gamma(x - \mu)/\sigma$ ,其中  $\mu$  为  $x$  的均值, $\sigma$  为  $x$  的标准差。

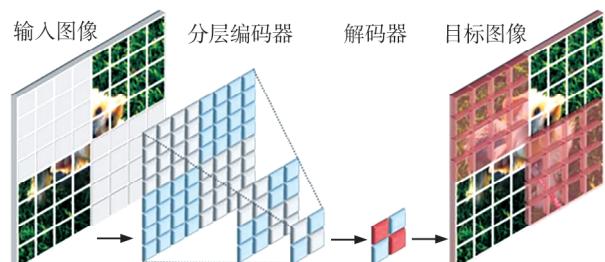
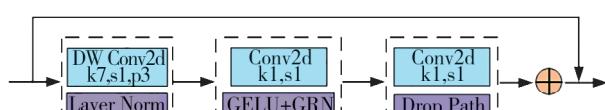


图 1 ConvNeXt V2 模块的工作原理



注:DW Conv2d 为深度可分离二维卷积操作;k7 表示卷积核的大小为  $7 \times 7$ ;s1 表示卷积操作的步长为 1;p3 表示在卷积操作之前,对输入图像的边界填充 3 个像素;Layer Norm 为层标准化;Conv2d 为二维卷积操作;k1 表示卷积核的大小为  $1 \times 1$ ;GELU 为激活函数;GRN 为全局响应归一化处理;Drop Path 为正则化处理。

图 2 ConvNeXt V2 模块结构

为提取更丰富的特征信息,通过卷积操作将特征逐通道数增至输入特征逐通道数的 4 倍,采用激活函数 GELU 增强模型的学习能力,进行全局响应归一化处理,扩大模型的感受野。

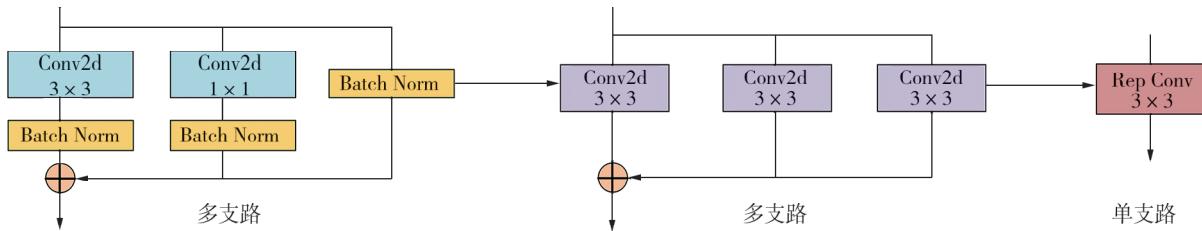
激活函数 GELU 公式为

$$f(x) = x \int_{-\infty}^x [e - 0.5(x - \mu)^2 / \sigma^2] dx / \sqrt{2\pi\sigma}.$$

为保证输入和输出特征逐通道数一致,通过卷积操作将特征逐通道数减至原输入特征逐通道数,采用正则化方法随机丢弃部分连接,增强 YOLOv5s 算法模型的泛化能力,提高 YOLOv5s 算法模型对复杂背景下轨道扣件图像特征的提取能力。

## 1.2 引入 Efficient Rep 网络

为确保扣件图像的特征信息在神经网络中高效传递,进一步提高检测精度,在 YOLOv5s 算法主干网络末端引入由 RepVGG 结构卷积层<sup>[19]</sup>构成的 Efficient Rep 网络,通过结构重参数化方式实现算法模型训练和推理解耦。在神经网络训练过程中,YOLOv5s 算法采用复杂的多支路网络结构,在推理时通过结构重参数化卷积操作将多支路结构转化为单支路结构,如图 3 所示。



注:Batch Norm 为批归一化;Rep Conv 为结构重参数化卷积。

图 3 结构重参数化流程

由图 3 可知,Efficient Rep 网络在训练时采用  $3 \times 3$  卷积、 $1 \times 1$  卷积和 Batch Norm 层组成的多支路网络结构。在结构重参数化过程中,将第一分支  $3 \times 3$  卷积层与 Batch Norm 层融合,得到一个  $3 \times 3$  卷积;将第二分支  $1 \times 1$  卷积层与 Batch Norm 层融合,扩展为  $3 \times 3$  卷积;将第三分支 Batch Norm 层通过恒等映射转化成  $3 \times 3$  卷积。最后,在推理阶段得到  $3 \times 3$  重参数化卷积。

## 1.3 改进损失函数

扣件定位是轨道扣件状态检测的关键步骤。合适的回归框损失函数能提高轨道扣件定位水平,有效训练算法模型神经网络,提高算法模型的收敛速度和精确率。轨道扣件状态检测中 YOLOv5s 算法采用损失函数 CIoU 计算边界回归框损失,检测物体形状差异较大时定位精度较低,且对目标检测中类别不均衡问题处理能力较差,产生收敛速度慢、计算结果不稳定等问题,定位效果不佳<sup>[20]</sup>。针对该问题引入具有动态非单调机制的损失函数 WIoU<sup>[21-22]</sup>,该损失函数采用梯度增益分配策略,通过调整目标检测中预测框与真实框的尺寸参数优化预测框的尺寸,加快 YOLOv5s 算法模型的计算收敛速度,提高检测精度。损失函数 WIoU 推理过程示意图如图 4 所示。

损失函数 WIoU 的计算结果

$$L_{\text{WIoU}} = 1 - (W_{\text{overlap}} + \epsilon) / (W_{\text{union}} + \epsilon),$$

式中:  $W_{\text{overlap}}$  为目标检测中预测框与真实框的交集面积;  $W_{\text{union}}$  为目标检测中预测框与真实框的并集面积;  $\epsilon$  为常数,取值较小,避免出现分母为 0 的情况。

## 1.4 CR-YOLOv5s 算法

在 YOLOv5s 算法基础上引入 ConvNeXt V2 模块和 Efficient Rep 网络,分别改进 YOLOv5s 主干网络前端和末端,更有效地提取输入数据特征,为后续区域定位、特征分类等操作提供高效特征信息支持,采用损失函数 WIoU 加快 YOLOv5s 算法计算收敛速度,形成 CR-YOLOv5s 算法。CR-YOLOv5s 算法由主干网络(Backbone Network)、中间网络(Neck Network)、输入端(Input Network)、快速空间金字塔池化(Spatial

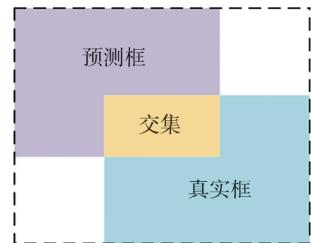
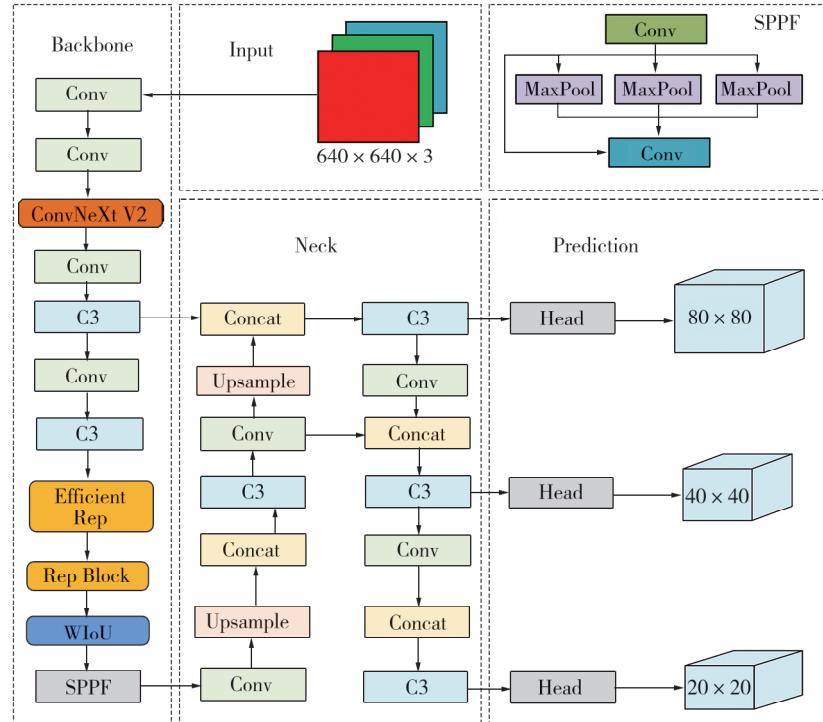


图 4 损失函数 WIoU  
推理过程示意图

Pyramid Pooling Fast, SPPF) 模块及预测(Prediction)模块组成, 算法结构如图 5 所示。



注:Conv 为卷积操作;ConvNeXt V2 为卷积神经网络算法模型;C3 为跨阶段连接的特征融合卷积模块;Efficient Rep 为融合硬件感知的卷积神经网络;Rep Block 为结构重参数化卷积构成的特征提取模块;640×640×3(宽高均为 640 像素,3 通道)为特征图输入数据大小(Byte);Concat 为拼接操作;Upsample 为上采样操作;MaxPool 为最大池化操作;Head 为根据提取的特征对目标检测结果进行预测;80×80、40×40、20×20(宽高为 80、40、20 像素)为特征图检测结果大小(Byte)。

图 5 CR-YOLOv5s 算法结构

ConvNeXt V2 模块应用于主干网络前端,凭借顺序结构优势在卷积层中得到较大感受野,增强通道间的特征竞争,减少内部协变量转移,有效提取网络特征信息;Efficient Rep 网络应用于主干网络的末端,凭借解耦训练和推理结构的优势,确保预测准确率较高,高效利用计算资源,增强关键特征提取的鲁棒性,优化信息传递路径,避免特征信息丢失;损失函数 WIoU 考虑目标区域与周围区域间的关联性,通过调整目标检测中预测框与真实框的尺寸参数优化预测框的尺寸(权重矩阵),可对不同区域的重要性灵活加权,有效节省计算资源和时间,加快计算收敛速度,提高检测精度。

## 2 轨道扣件缺陷检测试验

### 2.1 试验环境及参数

试验环境包括由 Windows10 操作系统、RTX3070Ti GPU 显卡、12th Gen Intel(R) Core(TM) i5-12400 2.50 GHz 处理器、8 GByte 内存、8 GByte 显存等组装的高性能计算机,深度学习框架 Pytorch 1.13.1,并行计算平台 CUDA 11.7 及编程软件 Python3.7。设置试验迭代 300 次,迭代 16 批次,学习率为 0.001,动量参数为 0.937,衰减权重为 0.0005,图像增强方式为马赛克(mosaic)增强方式。在预热学习(warm-up)操作中设置 CR-YOLOv5s 算法对训练数据集完成一次完整前向传播和反向传播的迭代周期(Epoch)为 3,预热学习完成后采用余弦退火算法<sup>[23]</sup>自动调整学习率。

### 2.2 试验数据集

试验数据集为本研究课题组采集的 700 张国内轨道扣件图片,包括正常扣件、移位扣件、损伤扣件和

缺失扣件 4 类,其中损伤扣件包括弹条断裂和弹条形变,部分轨道扣件图片如图 6 所示。



图 6 部分轨道扣件图片

为使 CR-YOLOv5s 算法获取丰富的图像特征信息并泛化到多种场景,采用 mosaic 图像增强方式对缺陷样本进行随机增强,包括旋转、曝光、色调处理、添加噪声等<sup>[24]</sup>。增强后共得到 1 780 张图片,将其分为训练、验证和测试数据集,各数据集图片数之比为 8 : 1 : 1。

### 2.3 评价指标

轨道扣件缺陷检测试验的评价指标为检测精度和平均检测时间,检测精度指标包括准确率  $p$ 、召回率  $r$  及平均检测精度均值  $E_{mAP}$ 。

准确率

$$p = N_{TP} / (N_{TP} + N_{FP}) \times 100\%,$$

式中: $N_{TP}$  为算法模型成功识别图像特征并确认轨道扣件处于正确状态的样本数, $N_{FP}$  为算法模型未能检测到轨道扣件或在检测过程中未准确识别轨道扣件状态的样本数。

召回率

$$r = N_{TP} / (N_{TP} + N_{FN}) \times 100\%,$$

式中  $N_{FN}$  为算法模型错误识别轨道扣件状态的样本数。

轨道扣件第  $i$  类缺陷的平均检测精度  $E_{AP_i} = \int_0^1 p(r) dr$ , 平均检测精度均值

$$E_{mAP} = \sum_{i=0}^N E_{AP_i} / N,$$

式中  $N$  为轨道扣件缺陷类别数。

### 2.4 消融试验

为验证 CR-YOLOv5s 算法的检测性能,探究 ConvNeXt V2 模块、Efficient Rep 网络和损失函数 WIoU 对 YOLOv5s 算法的改进效果,设计 8 组消融试验方案,选取召回率  $r$ 、平均检测精度均值  $E_{mAP}$  和平均检测时间  $t$  作为评价 8 组消融试验方案的指标,消融试验方案及结果如表 1 所示。

表 1 消融试验方案及结果

算法模型	试验方案				试验结果		
	YOLOv5s	ConvNeXt V2	Efficient Rep	WIoU 损失函数	$r/\%$	$E_{mAP}/\%$	$t/ms$
1	√	✗	✗	✗	83.6	91.8	9.1
2	√	√	✗	✗	88.2	94.2	10.2
3	√	✗	√	✗	86.0	92.6	10.0
4	√	✗	✗	√	86.7	93.4	8.8
5	√	√	√	✗	85.0	95.2	11.5
6	√	√	✗	√	84.1	92.8	8.6
7	√	✗	√	√	87.8	94.4	10.0
8	√	√	√	√	89.3	95.8	10.1

注:√为试验方案中包含该模块,✗为试验方案中不包含该模块。

由表 1 可知:在 YOLOv5s 算法基础上分别引入 ConvNeXt V2 模块和 Efficient Rep 网络,可小幅增大召回率和平均检测精度均值,但平均检测时间延长。在 YOLOv5s 算法基础上同时引入 ConvNeXt V2 模块和 Efficient Rep 网络,可大幅增大召回率和平均检测精度均值,但平均检测时间更长。在 YOLOv5s 算法基础上引入损失函数 WIoU,可明显缩短平均检测时间。

相较于算法模型 1(YOLOv5s 算法),算法模型 8(CR-YOLOv5s 算法)的召回率提高 5.7%,平均检测精度均值提高 4.0%,平均检测时间延长 1.0 ms。采用 ConvNeXt V2 模块与 Efficient Rep 网络增大召回率和平均检测精度均值,采用损失函数 WIoU 消除引入 ConvNeXt V2 模块与 Efficient Rep 网络后对平均检测时间的影响。在轨道扣件缺陷检测任务中,采用 CR-YOLOv5s 算法明显提高检测精度,且平均检测时间满足巡检要求。

## 2.5 算法改进分析

CR-YOLOv5s 算法和 YOLOv5s 算法在模型训练过程中的损失函数曲线如图 7 所示。由图 7 可知:算法改进前后在训练集和验证集上的整体损失均随迭代次数的增大而不断减小,表明算法模型的预测结果与真实结果间差距逐渐缩小。两种算法训练集的整体损失在迭代 0~50 次内迅速下降,迭代 51~150 次内下降缓慢,迭代 151~300 次内趋于稳定,CR-YOLOv5s 算法训练集整体损失稳定在 0.036,YOLOv5s 算法训练集整体损失稳定在 0.040。在迭代 0~50 次内,CR-YOLOv5s 算法验证集的整体损失下降速度较 YOLOv5s 算法快,且整体损失更低,表明 CR-YOLOv5s 算法在轨道扣件缺陷检测中学习能力较强,能更精准完成轨道扣件的定位和识别任务。

CR-YOLOv5s 算法和 YOLOv5s 算法的平均检测精度对比如图 8 所示。由图 8 可知:两种算法的平均检测精度均值曲线均在迭代 200 次后逐渐收敛,CR-YOLOv5s 算法的平均检测精度均值比 YOLOv5s 算法提高约 4.0%,能更精确地定位扣件位置。CR-YOLOv5s 算法和 YOLOv5s 算法的召回率对比如图 9 所示。由图 9 可知:CR-YOLOv5s 算法的召回率在迭代 25 次时超过 YOLOv5s 算法并持续增大,在迭代 250 次后逐渐收敛,CR-YOLOv5s 算法的召回率比 YOLOv5s 算法提高约 5.7%,能更准确地识别扣件状态,减小扣件漏检概率。

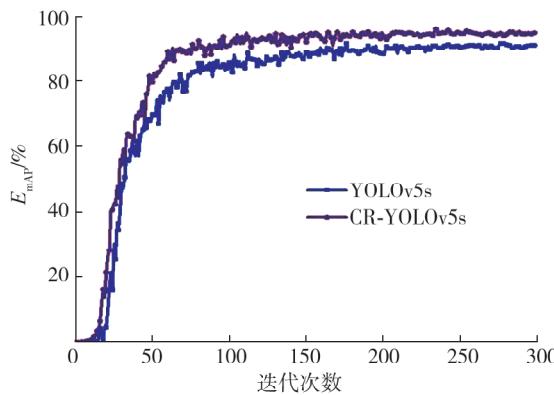


图 8 两种算法的平均检测精度均值对比

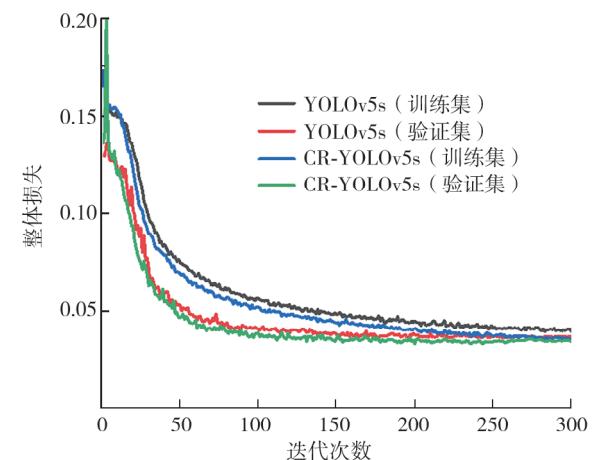


图 7 两种算法的损失函数曲线

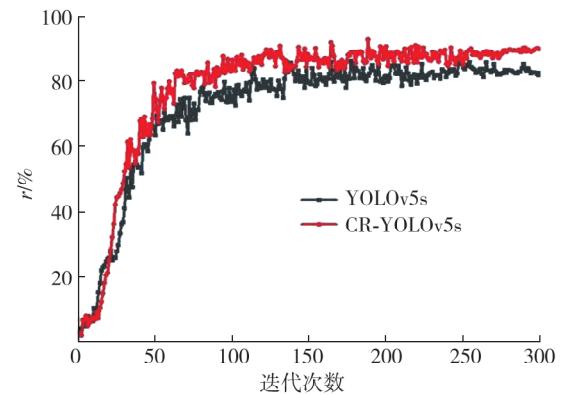
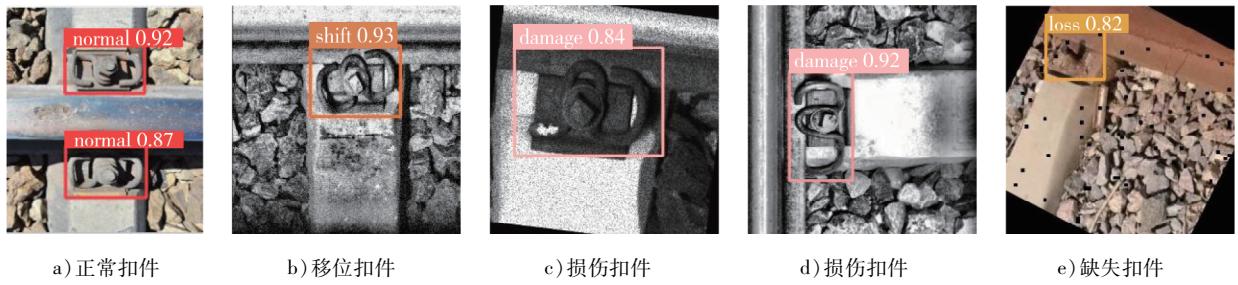


图 9 两种算法的召回率对比

CR-YOLOv5s 算法和 YOLOv5s 算法的扣件状态检测试验结果对比如图 10、11 所示。由图 10、11 可知:在不同扣件缺陷特征、不同检测环境及检测角度下,CR-YOLOv5s 算法均能准确检测扣件的各种状态,检测置信度较 YOLOv5s 算法明显提高。



注: normal 为正常, shift 为移位, damage 为损伤, loss 为缺失; 数字为检测置信度。

图 10 YOLOv5s 扣件状态检测试验结果

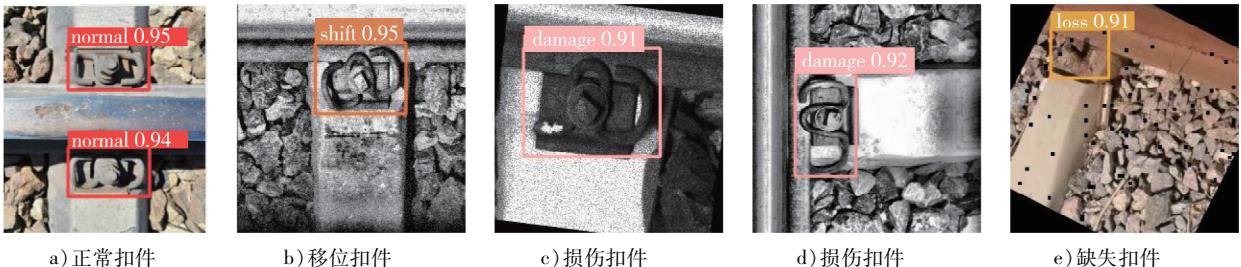


图 11 CR-YOLOv5s 扣件状态检测试验结果

## 2.6 多种算法对比分析

为进一步验证 CR-YOLOv5s 算法是否适用于扣件状态检测试验,采用相同试验平台、相同数据集对 CR-YOLOv5s 算法、Faster R-CNN 算法、SSD 算法、YOLOv3 算法、YOLOv4 算法和 YOLOv5s 算法分别进行扣件状态检测试验,检测结果对比如表 2 所示。

由表 2 可知:采用 CR-YOLOv5s 算法进行扣件状态检测试验的召回率比 Faster R-CNN 算法、SSD 算法、YOLOv3 算法、YOLOv4 算法和 YOLOv5s 算法分别提高 5.7%、8.9%、8.3%、7.1% 和 5.7%,平均检测精度均值分别提高 15.5%、13.6%、7.8%、9.0% 和 4.0%,平均检测时间比 Faster R-CNN 算法、SSD 算法、YOLOv3 算法和 YOLOv4 算法分别缩短 54.9、29.7、14.5、12.2 ms,比 YOLOv5s 算法延长 1 ms。

CR-YOLOv5s 算法在 YOLOv5s 算法的基础上引入 ConvNeXt V2 模块和 Efficient Rep 网络,增强特征提取能力,提高轨道扣件状态的检测精度,但增加算法模型的计算复杂度,延长平均检测时间;引入损失函数 WIoU 能提高扣件检测效率,缩短平均检测时间;两方面因素导致 CR-YOLOv5s 算法的平均检测时间比 YOLOv5s 算法延长 1 ms。综合考虑轨道扣件状态检测任务要求、召回率、平均检测精度均值、平均检测时间等因素,采用 CR-YOLOv5s 算法进行轨道扣件状态检测更具优势。

## 3 结论

在 YOLOv5s 算法基础上引入 ConvNeXt V2 模块和 Efficient Rep 网络,分别改进 YOLOv5s 主干网络前端和末端,更有效地提取输入数据特征,为后续区域定位、特征分类等操作提供高效特征信息支持,采用损失函数 WIoU 加快 YOLOv5s 算法计算收敛速度,形成 CR-YOLOv5s 算法,用于轨道扣件缺陷状态检测,开展消融试验及多种算法检测对比试验。

1) 消融试验结果表明:CR-YOLOv5s 算法中 ConvNeXt V2 模块与 Efficient Rep 网络可提高召回率和

表 2 多种算法扣件状态检测结果对比

检测算法	$r/\%$	$E_{mAP}/\%$	$t/ms$
Faster R-CNN	83.6	80.3	65.0
SSD	80.4	82.2	39.8
YOLOv3	81.0	88.0	24.6
YOLOv4	82.2	86.8	22.3
YOLOv5s	83.6	91.8	9.1
CR-YOLOv5s	89.3	95.8	10.1

平均检测精度均值,损失函数 WIoU 可提高算法模型计算效率,消除引入 ConvNeXt V2 模块与 Efficient Rep 网络后对平均检测时间的影响。

2) 多种算法检测对比试验结果表明:CR-YOLOv5s 算法在召回率、平均检测精度均值、平均检测时间等 3 个指标均优于 Faster R-CNN 算法、SSD 算法、YOLOv3 算法、YOLOv4 算法。

3) 由消融试验和多种算法检测对比试验可知,CR-YOLOv5s 算法的召回率比 YOLOv5s 算法增大 5.7%,平均检测精度均值增大 4.0%,平均检测时间延长 1.0 ms。综合考虑轨道扣件状态检测任务要求、召回率、平均检测精度均值、平均检测时间等因素,采用 CR-YOLOv5s 算法进行轨道扣件状态检测更具优势。

## 参考文献:

- [1] 吴送英,刘林芽,江家明,等.复杂背景下铁路扣件的改进 YOLOv5s 检测算法[J].中国铁道科学,2023,44(3):53–63.
- [2] 范宏,侯云,李柏林,等.基于区域特征的缺陷扣件视觉检测[J].铁道学报,2021,43(8):132–138.
- [3] ZHUANG L, QI H Y, WANG T G, et al. A deep-learning-powered near-real-time detection of railway track major components: a two-stage computer-vision-based method [J]. IEEE Internet of Things Journal, 2022, 9 ( 19 ): 18806–18816.
- [4] 邱实,陈斌,胡文博,等.基于深度风格迁移合成数据的扣件异常状态检测[J].铁道学报,2024,46(10):122–131.
- [5] LIU J J, YUAN J Y, JIA Y F. A new method for railway fastener detection using the symmetrical image and its EA-HOG feature[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2020, 34 ( 2 ) :2055006.
- [6] YANG J F, LIU M H, ZHAO H, et al. An efficient image-based method for detection of fastener on railway[J]. Advanced Materials Research, 2011, 346:731–737.
- [7] 代先星,丁世海,阳恩慧,等.铁路扣件弹条伤损自动检测系统研发与验证[J].铁道科学与工程学报,2018,15(10):2478–2486.
- [8] LIU J W, TENG Y, SHI B, et al. A hierarchical learning approach for railway fastener detection using imbalanced samples [J]. Measurement, 2021, 186:110240.
- [9] AZIZ L, HAJI SALAMMd Sah Bin, SHEIKH U U, et al. Exploring deep learning-based architecture, strategies, applications and current trends in generic object detection: a comprehensive review[J]. IEEE Access, 2020, 8:170461–170495.
- [10] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN:towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137–1149.
- [11] LIU W, ANGUELOV D, ERHAN D, et al. SSD:single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham, Germany: Springer International Publishing, 2016:21–37.
- [12] REDMON J, FARHADI A. Yolov3: an incremental improvement[C]//Proceedings of 2018 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, USA: IEEE, 2018:1–6.
- [13] WEI X K, YANG Z M, LIU Y X, et al. Railway track fastener defect detection based on image processing and deep learning techniques:a comparative study[J]. Engineering Applications of Artificial Intelligence, 2019, 80:66–81.
- [14] 黄午祥,江南.基于改进 Faster R-CNN 算法的扣件缺陷检测[J].软件导刊,2023,22(5):190–197.
- [15] 李少佳,胡美振,陈辉东,等.基于轻量化 GoogLeNet 模型的轨道扣件缺陷状态识别[J].北京联合大学学报,2023,37(1):6–12.
- [16] 高嘉琳,白堂博,姚德臣,等.基于改进 YOLOv4 算法的铁路扣件检测[J].科学技术与工程,2022,22(7):2872–2877.
- [17] WOO S, DEBNATH S, HU R H, et al. ConvNeXt V2: co-designing and scaling ConvNets with masked autoencoders [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, BC, Canada: IEEE, 2023: 16133–16142.
- [18] WENG K H, CHU X X, XU X M, et al. EfficientRep:an efficient repvgg-style ConvNets with hardware-aware neural network design[EB/OL].(2023-02-01)[2024-01-26]. <https://arxiv.org/abs/2302.00386v1>.

- [19] DING X H, ZHANG X Y, MA N N, et al. RepVGG: making VGG-style ConvNets great again [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, TN, USA: IEEE, 2021: 13728–13737.
- [20] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. (2023-04-08) [2024-01-26]. <https://arxiv.org/abs/2301.10051v3>.
- [21] YU J H, JIANG Y N, WANG Z Y, et al. UnitBox: an advanced object detection network[C]//Proceedings of the 24th ACM International Conference on Multimedia. Amsterdam, Netherlands: ACM, 2016: 516–520.
- [22] 李烨恒,罗光圣,苏前敏.基于改进 YOLOv5 的 Logo 检测算法[J].计算机应用,2024,44(8):2580–2587.
- [23] 唐振超,韦蔚,罗蔚然,等.融合余弦退火与空洞卷积的遥感影像语义分割[J].遥感学报,2023,27(11):2579–2592.
- [24] 吴睿曦,肖秦琨.基于深度网络和数据增强的多物体图像识别[J].国外电子测量技术,2019,38(5):86–90.

## Track fastener defect detection based on improved YOLOv5s algorithm

ZHANG Xingsheng, RUAN Jiuhong\*, SHEN Benlan, LI Jincheng, HUA Chao

*School of Rail Transportation, Shandong Jiaotong University, Jinan 250357, China*

**Abstract:** Aiming at the problems of high complexity of track fastener defects, serious impact on train safety, and low efficiency of manual inspection, a track fastener defect detection algorithm based on computer vision is proposed. Considering the characteristics of track fastener defects and the complex working environment during detection, the ConvNeXt V2 module is used to replace the front-end C3 module of the YOLOv5s algorithm backbone network, the Efficient Rep network is used to improve the back-end of the YOLOv5s algorithm backbone network, and the WIoU loss function with dynamic non-focusing mechanism is introduced to accelerate the convergence speed of the YOLOv5s algorithm model, forming an improved YOLOv5s algorithm (CR-YOLOv5s algorithm) to detect track fastener defect states. Ablation experiments and comparative experiments with faster region-based convolutional neural networks(Faster R-CNN) algorithm, single shot multibox detector (SSD) algorithm, YOLOv3 algorithm, and YOLOv4 algorithm are conducted. The experimental results show that the recall rate of CR-YOLOv5s algorithm is 89.3%, the average detection accuracy is 95.8%, and the average detection time is 10.1 ms, all three indicators are superior to the other four algorithms. Compared with the YOLOv5s algorithm, the CR-YOLOv5s algorithm improves the recall rate by 5.7%, the average detection accuracy by 4.0%, and prolongs the average detection time by 1.0 ms. Considering factors such as track fastener state detection task requirements, recall rate, average detection accuracy, and average detection time, the CR-YOLOv5s algorithm is more advantageous for detecting track fastener defect states.

**Keywords:** track fastener; defect detection; YOLOv5s algorithm; ConvNeXt V2 module; Efficient Rep network; loss function WIoU

(责任编辑:边文超)