

DOI: 10.13382/j.jemi.B2407985

# 基于 ABI-RTLSeg 的轨道线路多关键部件 精细化检测及缺陷分析\*

魏德华<sup>1,2</sup> 魏秀琨<sup>3</sup>

(1. 兰州交通大学交通运输学院 兰州 730070; 2. 高原铁路运输智慧管控铁路行业重点实验室 兰州 730070;

3. 北京交通大学交通运输学院 北京 100044)

**摘要:**城轨轨道线路状态监测是确保铁路运输系统安全的关键任务之一。城轨轨道线路包括钢轨、扣件、螺栓和垫板等关键部件。针对实时精细化检测的需求,在前期工作的基础上,进一步研究并提出了一种基于实例分割的创新智能方法,用于快速精细化识别城市轨道交通线路的多关键部件,并分析量化常见缺陷的检测结果。在已有的 RTLSeg 模型基础上,融合感受野增强和图像后处理技术,提出了一种改进的轨道线路图像分割评估模型(ABI-RTLSeg)。首先,为了增强模型对高级语义信息的学习,在深层骨干网络中引入了空洞空间金字塔池化模块(ASPP);其次,在 Coord-Protonet 中引入了基于卷积的双线性插值结构,以获得更高质量的原型掩模和语义信息感知;最后,根据缺陷分割掩模的视觉特征,构建了分割结果分析模块,综合运用椭圆拟合和形态学分析方法,分析常见缺陷的安全状态。实验结果表明,该方法在快速精细化检测、分割以及分析铁路轨道线路的多目标关键部件和常见缺陷方面是可行的,并且其性能优于比较的基线模型。ABI-RTLSeg 在所构建的数据集上能够达到 90.91% 的边界框平均精度(bbox mAP)和 91.67% 的掩码平均精度(mask mAP)。同时,平均推理速度达到 25.62 fps,平均检测准确率和召回率分别为 100% 和 99.85%。此外,通过多个实例研究,探讨了所提方法在评估扣件损坏严重程度和估算轨道波磨关键参数方面的可行性,为城市轨道交通线路的安全状态监测提供了一种有效方案,为城市轨道交通的智能化发展提供了重要技术支撑。

**关键词:** 多部件检测;缺陷分析;实例分割;ASPP;形态学分析;椭圆拟合

**中图分类号:** TN911.72

**文献标识码:** A

**国家标准学科分类代码:** 510.4099

## Fine-grained detection and defect analysis for multiple key components in railway tracks based on ABI-RTLSeg

Wei Dehua<sup>1,2</sup> Wei Xiukun<sup>3</sup>

(1. School of Traffic and Transportation, Lanzhou Jiaotong University, Lanzhou 730070, China; 2. Key Laboratory of Railway Industry on Plateau Railway Transportation Intelligent Management and Control, Lanzhou 730070, China; 3. School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** Urban rail transit track condition monitoring is one of the critical tasks for ensuring the safety of railway transportation systems. The urban rail transit track includes key components such as rails, fasteners, bolts, and sleepers. In response to the demand for real-time and refined detection, this study, building on previous work, further investigates and proposes an innovative intelligent method based on instance segmentation for the rapid and refined identification of multiple key components of urban rail transit tracks, analyzes, and quantifies the detection results of common defects. Specifically, this research, based on the existing RTLSeg model, integrates field-of-view enhancement and image post-processing techniques, proposing an improved track image segmentation and evaluation model (ABI-RTLSeg). Firstly, to enhance the model's learning of high-level semantic information, this study introduces a dilated spatial pyramid pooling (ASPP) module into the deep backbone network. Secondly, a convolution-based bilinear interpolation structure is incorporated into the Coord-Protonet to obtain higher-quality prototype masks and semantic information awareness. Lastly, based on the visual features of defect segmentation masks, a segmentation result analysis module is constructed, employing ellipse fitting

收稿日期: 2024-11-25 Received Date: 2024-11-25

\* 基金项目: 国家自然科学基金(52462047)、甘肃省自然科学基金(24JRRA277)项目资助

and morphological analysis methods to analyze the safety status of common defects. Experimental results demonstrate that this method is feasible for rapid and refined detection, segmentation, and analysis of multiple target key components and common defects of railway track lines, and its performance surpasses that of the comparative baseline models. In particular, ABI-RTLSeg is able to achieve 90.91% bbox mAP and 91.67% mask mAP with the customized dataset. Meanwhile, the average inference speed reaches 25.62 fps. The average detection accuracy and recall are 100% and 99.85%, respectively. Furthermore, the feasibility of the proposed methods for assessing the severity of fastener damage and estimating key parameters of rail corrugation has been explored through multiple case studies. In summary, this study provides a new technical approach for the intelligent monitoring of rail transit track lines, which is of great significance for improving the safety and reliability of the railway transportation system.

**Keywords:** multi-component inspection; defect analysis; instance segmentation; ASPP; morphological analysis; ellipse fitting

## 0 引言

随着城市轨道交通的迅猛发展和运营里程的快速延伸,对运输安全和运维质量的要求日益严格。铁路轨道线路基础设施关键部件的定期检查对于保障列车的高效运行至关重要<sup>[1]</sup>。城轨轨道线路主要由钢轨、扣件、螺栓和垫板等部件组成,这些部件在列车车轮与钢轨的接触摩擦、振动以及现场运行环境的影响下,可能会出现波磨、扣件断裂和缺失等缺陷,影响车辆运行安全和乘客舒适度,甚至可能引发重大安全事故。此外,随着线路缺陷的发生、演变乃至恶化,运维成本和难度也会随之增加。目前,城轨轨道线路的检查主要依赖人工巡检或轨检车,这些方法劳动强度大、耗时长,且自动化和智能化水平有限。轨道检测车虽能提供一定程度的自动化检测,但其制造成本高,检测过程中还需占用运营线路,无法实现对关键部件的精细化检测。因此,开发利用人工智能、深度学习等先进技术的轨道线路检测系统,对于提升轨道交通的安全性和稳定性、缩短检测时间、降低检测成本具有重要意义<sup>[2]</sup>。不仅可以自动、智能识别轨道线路关键部件,同时还可以检测和分析轨道线路的常见缺陷。

近年来,众多研究者及机构致力于开发自动化铁路安全状态检测方法与系统,旨在提升铁路运输的安全性与可靠性<sup>[3]</sup>。这些研究主要集中在钢轨扣件和钢轨表面的缺陷检测上,涉及图像处理技术和深度学习技术<sup>[4]</sup>。本文综述了基于深度学习的若干代表性研究成果。在钢轨扣件缺陷检测方面,Wei 等<sup>[5]</sup>、Bai 等<sup>[6]</sup>、Hu 等<sup>[7]</sup>以及 Liu 等<sup>[8]</sup>研究者分别利用 Faster R-CNN、YOLOX 和 YOLOv4 网络构建了具有良好检测性能的扣件缺陷检测框架。Gao 等<sup>[9]</sup>提出了一种基于多传感器融合和自驱动损失权重调整的铁路扣件异常检测方法,实现了较高的识别精度和检测速度。Qiu 等<sup>[10]</sup>针对铁路扣件异常检测中的样本不平衡问题,提出了一种基于深度度量学习损失函数-中心三元损失(center-triplet loss)。Ye 等<sup>[11]</sup>开发了一种名为 YOLO-Fastener 的智能算法,用于检测无砟轨道系统中的扣件缺陷,并通过热图可视化技术增强了模型的可解释性。在钢轨表面缺陷检测领域,通常将缺陷

分为钢轨波磨和表面离散缺陷两类<sup>[12]</sup>。Wu 等<sup>[13]</sup>开发了一种创新的轨道边界引导网络(rail boundary guidance network, RBGNet),实现了良好的钢轨表面分割性能。Yang 等<sup>[14]</sup>介绍了一种结合深度信息的轮廓和语义特征对齐融合网络(contour and semantic feature alignment fusion network, CSANet),提升了检测精度。Luo 等<sup>[15]</sup>提出了一种基于改进 YOLOv5s<sup>[16]</sup>算法的铁路表面缺陷检测方法,通过融合 Swin Transformer 提升了全局信息和上下文信息感知。Guo 等<sup>[17]</sup>提出了一种基于像素级语义分割模型 Deeplabv3-plus 的自动铁路表面缺陷检测方法,提高了特定铁路应用中的准确性。Zhou 等<sup>[18]</sup>研究并提出了一种轻量级特征层次探索网络(feature hierarchical exploration network, FHENet),通过改进的特征提取和层次探索策略,提高了缺陷检测的准确性和效率。

已有研究在铁路安全状态检测技术方面取得了显著进展,然而在全面性和精细度等方面仍有改进空间。鉴于此,在先前的工作中,基于改进的端到端实例分割模型并结合先验知识,提出了一种城轨轨道线路图像分割模型(railway track line image segmentation model, RTLSeg)<sup>[19]</sup>,实现了对城轨轨道线路部件和常见缺陷在像素级的自动精准检测。具体而言,借鉴 YOLACT 类网络的精巧设计方法,将实例分割分为两个并行的任务,即原型掩码生成(由 Coord-Protonet 完成)以及对象定位、分类和掩码系数生成(由增强优化预测头完成)。依据实验结果,所提出的 RTLSeg 模型虽然在分割精度上超越了基准模型,实现了自动且准确地在像素级检测城轨轨道线路关键部件和常见缺陷,但是检测和分割速度未能满足现场对实时性的要求,仍有较大提升的潜力。此外,对于扣件损坏、钢轨表面波磨等常见缺陷尚未能实现安全状态评估,其精细化程度有待进一步提高。因此,为实现城轨轨道线路关键部件的实时像素级分割以及常见缺陷的安全状态分析,本文在 RTLSeg 模型研究的基础上,进一步设计了基于空洞空间金字塔池化的感受野增强模块、基于卷积的双线性插值结构以及基于椭圆拟合和形态学分析的分割结果分析模块,提出了改进的城轨轨道线路图像分割模型(ABI-RTLSeg),实现了城轨轨道线路多关键部件及常见缺陷的实时精细化检测与分析。最

后,通过多次实验分析证明了所提出的 ABI-RTLSeg 模型的有效性,该模型是实际应用中的良好替代方案。

## 1 轨道线路图像分割评估模型

为了实现对轨道交通线路多关键部件的实时高效识别以及对常见缺陷的检测与分析,本文在前期研究提出的城轨轨道线路图像分割模型的基础上,进一步构建了 (ABI-RTLSeg) 模型,并对其进行了深入的实验分析。

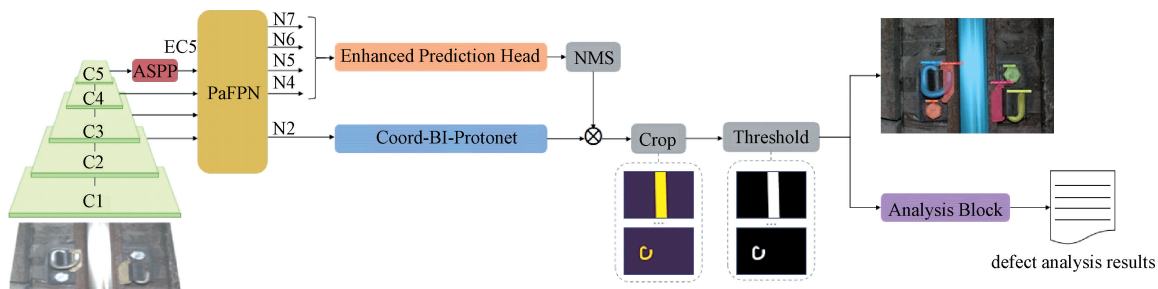


图 1 ABI-RTLSeg 模型的主要结构框架

Fig. 1 The main structure of the proposed ABI-RTLSeg model

### 1.1 感受野增强的骨干网络

在计算机视觉任务中,骨干网络扮演着至关重要的角色,主要负责从输入图像中提取特征并生成特征图<sup>[20]</sup>。骨干网络的性能直接决定了特征图的质量。在实际应用中,可以根据对模型精度和效率的不同需求,对骨干网络进行相应的修改或调整,以开发出适合特定任务的网络结构。例如,为了实现高精度的特征感知,可以选用深度密集连接的网络结构,如 ResNet 和 DenseNet。特别是 ResNet-101,因其出色的性能,已被广泛应用于多种视觉任务<sup>[21]</sup>,并在 He 等<sup>[22]</sup>的研究中得到了验证。为了降低推理计算的复杂度,ResNet-101 采用了瓶颈结构,如图 2 所示。该结构使得网络在经过 5 个阶段 (stage) 处理后,将输入图像的尺寸依次缩小至原图的 1/2、1/4、1/8、1/16 和 1/32。

在 ABI-RTLSeg 模型的设计中,遵循了 Bolya 等<sup>[23]</sup>提出的骨干网络设计原则,采用了结合可变形卷积的 ResNet-101 (ResNet-101-DCN) 作为基础骨干网络,以实现图像特征的更准确、更丰富的提取。具体地,可变形卷积被配置在 ResNet-101 的最后 3 个阶段,间隔为 3,共包含 11 个可变形卷积层。可变形卷积能够提供更灵活的特征采样,增强模型处理不同尺度、长宽比和旋转变化的能力<sup>[24-25]</sup>。此外,为了进一步增强网络对语义信息的感知,并提升轨道线路关键部件的检测和分割精度,本文在 ResNet-101-DCN 的基础上引入了空洞空间金字塔池化模块 (atrous spatial pyramid pooling, ASPP)<sup>[26]</sup>。ASPP 模块由 4 个并行的空洞卷积子模块组成,它们共同作用




图 2 瓶颈结构示意图

Fig. 2 Structure of bottleneck design

于扩大感受野,捕获更多的上下文信息,结构如图 3 所示。

### 1.2 语义感知增强的原型生成分支

在 YOLACT 类型的模型架构中,引入了原型生成分支,用于预测整个图像的  $k$  个原型掩码,这一过程无需进行损失计算。这些原型掩码是通过 Protonet 利用全卷积网络 (fully convolutional network, FCN) 机制生成的,其中最后一层是核为  $k$  的  $1 \times 1$  卷积层。值得注意的是,原型的数量  $k$  与目标类别的数量无关,这为生成的原型提供了分布式表示,即每个实例是通过跨类别共享的原型组合来实现分割的。近年来,基于 FCN 的语义分割取得了显著成功并被广泛应用。然而,FCN 的平移不变性使其






图 3 ASPP 结构示意图

Fig. 3 Structure of ASPP

不能直接应用于实例分割任务,因为位置感知在实例分割任务中扮演者至关重要的角色。为此,模型如 Mask R-CNN<sup>[27]</sup> 和 SOLO<sup>[28-29]</sup> 尝试通过明确地向网络添加位置感知来解决这一问题,并取得了良好的结果。尽管 YOLACT 类型的模型利用了 ResNet 的平移变化特性,但在使用 FCN 生成针对本文特定任务的原型方面,仍存在改进空间。

因此,为了获得鲁棒性更高的分割掩码,在 ABI-RTLSeg 模型的原型生成分支中融合了“CoordConv”算子<sup>[30]</sup>,将归一化的像素坐标直接嵌入到 Protonet 的初始阶段,并命名为 Coord-Protonet。具体地,首先构建一个与空间维度相匹配的张量,该张量内含归一化至  $[-1, 1]$  区间内的像素坐标。然后,将该张量与输入特征图进行拼接,并传递给网络的后续层级。通过这种方式,卷积操作得以获取其自身的输入坐标信息,从而为传统的 FCN 模型增添位置感知能力。Coord-Protonet 结构的有效性已在 RTLSeg 模型的实验中得到充分验证。为了进一步提升掩码质量及模型性能,将 Coord-Protonet 与 PaFPN 中 N2 层相连,并通过基于卷积的双线性插值 (bilinear interpolation, BI) 结构将生成的原型掩码上采样至输入图像的尺寸,以此获得更强的语义感知能力,该结构被命名为 Coord-BI-Protonet,如图 4 所示。通过这种结构设计,Coord-BI-Protonet 不仅继承了 Coord-Protonet 的位置感知优势,而且通过双线性插值上采样进一步增强了模型对输入图像语义信息的捕捉能力。

### 1.3 分割结果分析模块

#### 1) 扣件损坏程度评估

本文扣件的丢失状态可以通过分割识别结果直接判定,而扣件的损坏程度则需要基于分割掩模结果进行进一步的分析评估。在深入探究分割掩模的视觉特性时,发现无论是完好还是破损的扣件,在图像中均以黑色背




图 4 Coord-BI-Prototype 网络结构

Fig. 4 Coord-BI-Prototype architecture

景上的白色闭合区域呈现(图 5)。基于此特征,本文采用形态学联通域分析 (morphological connected component analysis, MCCA)<sup>[31]</sup> 方法,通过比较损坏扣件与标准正常扣件的分割掩模面积,来评估扣件的损坏程度。在形态学联通域分析中,联通域 (也称为连通分量或联通组件) 是指图像中彼此相连的、具有相同像素值的像素点的集合。此外,考虑到图像采集过程中关键部件如扣件的尺度会受到采集设备的高度和角度变化的影响,且人工手持采集设备的方式无法保证设备始终保持在同一水平线上,可能导致图像尺度的变化。为了消除这种尺度变化对分析结果的影响,本研究引入了放缩因子  $\omega$ , 先对 MCCA 的计算结果进行标准化处理,确保所有数据在同一量纲下进行比较和分析。


(a) 正常弹条  
(a) Normal clip(b) 断裂弹条  
(b) Fractured clip

图 5 扣件分割掩模结果

Fig. 5 Fastener segmentation mask result

在获得标准化处理的分割掩模面积结果后,本文基于模糊理论对扣件的损坏程度进行评估。模糊理论是处理不确定信息的有效工具<sup>[32]</sup>。因此,它适合解决具有模糊性的扣件损坏严重程度评估问题。本文综合考虑分割掩模面积和损坏状态的关系,计算损坏扣件相对于标准正常扣件的分割掩模面积比,即闭合区域像素点个数的比值,以量化扣件的损伤程度。本文将这一量化指标定义为损伤度 (damage degree, DD), 其计算公式如下:

$$DD = 1 - \frac{\text{损伤扣件的分割掩模面积}}{\text{标准正常扣件的分割掩模面积}} \quad (1)$$

根据定义,损伤度越接近 0,表示扣件基本完好无损坏;相对应地,损伤度越接近 1,表示扣件损坏较严重。本文将扣件损坏分为 3 个损坏等级,分别为 1 级 (轻



微损坏)、2级(中度损坏)和3级(严重损坏)。为此,设计了三级隶属函数,如图6所示。最终,利用最大隶属度原则确定扣件的损坏严重程度等级,定义为:

$$\max(\mu_{\text{slight}}, \mu_{\text{medium}}, \mu_{\text{severe}}) = \begin{cases} \mu_{\text{slight}}, \text{level1} \\ \mu_{\text{medium}}, \text{level2} \\ \mu_{\text{severe}}, \text{level3} \end{cases} \quad (2)$$

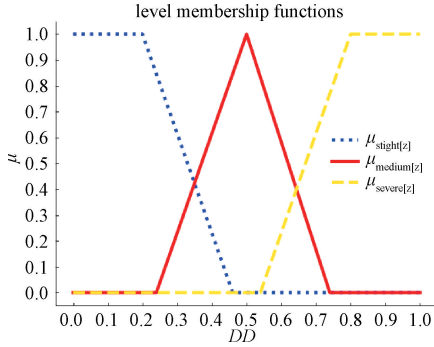


图6 三级隶属函数图

Fig. 6 Three-level membership function diagram

## 2) 波磨关键参数估计

本文钢轨表面是否存在波磨可以通过分割识别结果直接判定。若波磨存在,则需基于分割结果进一步计算其关键参数。一般而言,波磨的严重程度与波磨的深度、波长、波峰波谷等关键参数正相关<sup>[32]</sup>。由于现场采集的轨道线路图像通常为缺失深度信息的单目视觉图像,本文借鉴了检修人员在日常巡检中仅依靠视觉观察来评估波磨严重程度的方法。因此,通过对分割掩模结果的分析,计算波长和波峰波谷等关键参数的参考值,对于利用单目图像进行波磨严重程度的评估具有重要的辅助作用。

钢轨波磨在轨道线路图像中的视觉特征表现为周期性的、类似椭圆的纹理图案<sup>[32]</sup>。基于此特征,本文采用基于最小二乘法的椭圆拟合方法<sup>[33]</sup>,对波磨分割掩模结果进行深入分析,并据此推算波磨的波长等关键参数。首先,将钢轨表面图像范围内分割识别的每个波磨区域作为目标进行细化。假设目标区域内的点均匀分布,质心坐标的计算公式定义为:

$$(\bar{x}, \bar{y}) = \left( \frac{1}{n(n+1)/2} \sum_{i=1}^n x_i, \frac{1}{n(n+1)/2} \sum_{i=1}^n y_i \right) \quad (3)$$

式中:  $(x_i, y_i)$  为点  $i$  坐标;  $n$  表示区域内点的总数量。其次,掩模内的波磨边缘点作为椭圆拟合所需的测量点。椭圆曲线方程构造为:

$$x_i^2 + \lambda_1 x_i y_i + \lambda_2 y_i^2 + \lambda_3 x_i + \lambda_4 y_i + \lambda_5 = 0 \quad (4)$$

式中:  $\lambda_1 \sim \lambda_5$  为拟合系数。接着,根据最小二乘原理,构造椭圆拟合的目标函数为<sup>[34]</sup>:

$$\Phi(\lambda) = \sum_{i=1}^N (x_i^2 + \lambda_1 x_i y_i + \lambda_2 y_i^2 + \lambda_3 x_i + \lambda_4 y_i + \lambda_5)^2 \quad (5)$$

式中:  $N$  为测量点的个数;  $\Phi(\lambda)$  是目标函数。目标函数最优情况为  $\Phi(\lambda) = 0$ ; 即  $\Phi(\lambda)$  越小越好。由此可得方程:

$$\begin{bmatrix} \sum x_i^2 y_i^2 & \sum x_i y_i^3 & \sum x_i^2 y_i & \sum x_i y_i^2 & \sum x_i y_i \\ \sum x_i y_i^3 & \sum y_i^4 & \sum x_i y_i^2 & \sum y_i^3 & \sum y_i^2 \\ \sum x_i^2 y_i & \sum x_i y_i^2 & \sum x_i^2 & \sum x_i y_i & \sum x_i \\ \sum x_i y_i^2 & \sum y_i^3 & \sum x_i y_i & \sum y_i^2 & \sum y_i \\ \sum x_i y_i & \sum y_i^2 & \sum x_i & \sum y_i & N \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \lambda_4 \\ \lambda_5 \end{bmatrix} = \begin{bmatrix} \sum x_i^3 y_i \\ \sum x_i^2 y_i^2 \\ \sum x_i^3 \\ \sum x_i^2 y_i \\ \sum x_i^2 \end{bmatrix} \quad (6)$$

通过求解目标函数的最小值,可得拟合系数矩阵。进而依据式(7)和(8)求解得出拟合椭圆的长半轴长  $a$  和短半轴长  $b$ ,并依据定义计算出椭圆的倾斜角度。最终,根据这些参数推算出波磨的波长等关键参数的参考值。

$$a = \frac{\sqrt{2(\lambda_1 \lambda_3 \lambda_4 - \lambda_2 \lambda_3^2 - \lambda_4^2 + 4\lambda_2 \lambda_5 - \lambda_1^2 \lambda_5)}}{\sqrt{(\lambda_1^2 - 4\lambda_2) [\lambda_2 + 1 - \sqrt{\lambda_1^2 + (1 - \lambda_2)^2}]} } \quad (7)$$

$$b = \frac{\sqrt{2(\lambda_1 \lambda_3 \lambda_4 - \lambda_2 \lambda_3^2 - \lambda_4^2 + 4\lambda_2 \lambda_5 - \lambda_1^2 \lambda_5)}}{\sqrt{(\lambda_1^2 - 4\lambda_2) [\lambda_2 + 1 + \sqrt{\lambda_1^2 + (1 - \lambda_2)^2}]} } \quad (8)$$

## 2 实验与结果分析

### 2.1 实验环境及数据集介绍

#### 1) 实验环境

提出的 ABI-RTLseg 模型采用 Python 编程语言实现,并利用 Facebook 开发的 PyTorch 框架以及 NVIDIA 开发的 CUDA 11.8 和 Cudnn 8.6.0 软件包进行加速。所有的训练和测试均在一台实验室服务器上执行。该服务器运行 Ubuntu 20.04 操作系统,配备了 Inter i7 CPU 和 RTX 4070 Ti GPU<sup>[35]</sup>,以及相应的驱动程序版本 535.183。

在深度学习领域,训练过程的核心目标是通过调整模型参数以最小化模型的整体损失,从而提升模型性

能<sup>[36]</sup>。损失越低,通常意味着模型性能越佳。本文采用了自适应矩估计(adaptive moment estimation, Adam)算法来优化 ABI-RTLSeg 模型的权重。在参数配置中,“权重衰减”被设定为  $5 \times 10^{-4}$ ,一阶矩和二阶矩的指数衰减率分别设定为 0.9 和 0.999。初始学习率设置为  $1 \times 10^{-4}$ ,并随着训练的进行,通过余弦退火调度方法,结合“预热”策略<sup>[37]</sup>进行动态调整。除了这些关键参数外,其他参数均采用默认设置。此外,研究中应用了迁移学习的思想,在模型的初始化阶段使用了在 MS COCO 数据集<sup>[38]</sup>上预训练的 ABI-RTLSeg 模型的主干网络权重,以期实现快速收敛。在训练的后期,对这些预训练权重进行了微调,以进一步提升模型在特定任务上的表现。

2) 铁路轨道线路图像(RTL-I)数据集

RTL-I 数据集由北京地铁 6 号线南锣鼓巷站与东四站之间轨道沿线采集的图像构成。图像采集采用手持单

反相机(digital single lens reflex camera, DSLR),模拟实际运营环境下拍摄。采集时相机角度垂直于轨道线路,且在一定程度上保持相机与轨道线路钢轨表面之间的距离恒定不变。最终,经过筛选,共获得 322 张高质量的可用图像,每张图像均为高分辨率 RGB 格式。依据对铁路轨道线路的主要零部件及现场缺陷特征分析,RTL-I 数据集主要包括螺母(nut)、螺钉(screw)、螺栓(bolt)、正常弹条(normal\_clip)、断裂弹条(fractured\_clip)、正常钢轨(rail)、钢轨波磨(rail\_corrugation)、垫板(backing\_plate)、绝缘轨距块(gauge\_block)等 9 大类别,其中每个组件或每种缺陷类别的数量如表 1 所示。此外,根据线路巡检要求和现场调研结果,借助开源工具 LabelMe<sup>[39]</sup>对数据集中每张图像进行标注。RTL-I 数据集的标注示例如图 7 所示。

表 1 原始数据集中不同类别的数量

Table 1 The number of different categories in the original dataset

	Image	nut	screw	bolt	normal_clip	fractured_clip	rail	rail_corrugation	backing_plate	gauge_block
num	322	31	31	638	544	30	329	336	539	619




图 7 具有 7 个类别的原始图像和标记结果的示例

Fig. 7 Example of original image and labeling results with 7 categories

为增强图像数据的多样性和模型的泛化能力,采用了旋转、镜像、对比度受限的自适应直方图均衡

化(contrast limited adaptive histogram equalization, CLAHE)<sup>[40]</sup>,添加噪声、颜色扰动等图像增强方法。更确切地说,在噪声添加过程中,使用了椒盐噪声和具有均值为 0、方差为 0.05 的高斯噪声。颜色扰动则通过随机调整图像的亮度、对比度和清晰度实现。经过上述图像增强处理,最终得到了 1 251 张铁路轨道线路图像,其中每个组件或每种缺陷类别的数量如表 2 所示。根据交叉验证原则和先前研究的一般比例设置经验<sup>[19]</sup>,RTL-I 数据集划分为训练集和测试集,比例设置为 8 : 2。在模型训练阶段,考虑到模型性能、训练效率和图像尺度等多方面因素,输入图像的大小调整为沿短边 400 个像素、沿长边 600 个像素。

表 2 数据增强后数据集中不同类别的数量

Table 2 The number of different categories in the dataset after data augmentation

	Image	nut	screw	bolt	normal_clip	fractured_clip	rail	rail_corrugation	backing_plate	gauge_block
num	1 251	119	119	2 481	2 246	73	1 264	1 328	2 109	2 432

2.2 损失函数

ABI-RTLSeg 网络损失函数定义如式(9)所示,主要由 4 个子损失函数组成,包括类别置信度损失、边界框回归损失、掩模损失和语义分割损失。

$$Loss = \alpha_{cls} L_{cls} + \alpha_{box} L_{box} + \alpha_{mask} L_{mask} + \alpha_{segm} L_{segm} \quad (9)$$

式中:  $\alpha$  代表计算总损失值时各子损失值的权重,其预设值分别设置为  $\alpha_{cls} = 1, \alpha_{box} = 1.5, \alpha_{mask} = 6.125, \alpha_{segm} = 1$ 。此外,类别置信度损失和边界框回归损失的计算方式与

文献[41]相同。

类别置信度损失  $L_{cls}$  为多类别的 softmax 损失,其计算公式定义如下:

$$L_{cls}(x, c) = - \sum_{i \in Pos} x_{ij}^p \log(\hat{c}_i^p) - \sum_{i \in Neg} \log(\hat{c}_i^0) \quad (10)$$

where 
$$\hat{c}_i^p = \frac{\exp(\hat{c}_i^p)}{\sum_p \exp(\hat{c}_i^p)}$$

式中:  $i$  和  $j$  分别代表预测框和真实目标框的序号;  $p$  表示类别序号, 其中背景的序号为 0;  $x_{ij}^p$  是一个指示参数, 取值为 0 或 1, 当取值为 1 时表示预测框与类别号为  $p$  的真实目标框匹配;  $\hat{c}$  是通过 softmax 计算得到的类别置信度。

边界框回归损失  $L_{box}$  采用的是  $Smooth_{L1}$  损失, 计算公式定义如下:

$$L_{box}(x, l, g) = \sum_{i \in Pos} \sum_{m \in \{cx, cy, w, h\}} x_{ij}^k Smooth_{L1}(l_i^m - \hat{g}_j^m) \quad (11)$$

$$Smooth_{L1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & |x| \geq 1 \end{cases} \quad (12)$$

式中:  $l$  和  $\hat{g}$  分别代表目标边界框的预测值和真实值;  $x_{ij}^k$  的含义和类别置信度相同, 因此边界框回归损失的计算仅针对正样本进行。

掩模损失  $L_{mask}$  为二元交叉熵 (binary cross-entropy, BCE) 损失, 其计算公式定义如下:

$$L_{mask} = BCE(M, M_{gt}) \quad (13)$$

式中:  $M$  表示组合而成的预测掩模;  $M_{gt}$  代表掩模的真实值。

至于语义分割损失  $L_{segm}$ , 同样采用二元交叉熵损失, 能够在保持处理速度的同时提升特征的多样性。需要指出的是,  $L_{segm}$  的计算仅限于训练阶段。

### 2.3 评估指标

在评估不同模型的检测与分割性能时, 本文实验采用平均精度均值 (mean average precision, mAP) 作为评价指标。其中, 平均精度 (AP) 值的计算基于精确率-召回率 (P-R) 曲线。根据定义, 在 P-R 曲线中, “精确率” 作为纵坐标, “召回率” 作为横坐标, AP 值是 P-R 曲线下的面积。精确率是用来评估预测结果的准确性, 召回率则用来衡量正确预测的完整性。精确率和召回率的定义如下:

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

式中:  $TP$  和  $FP$  分别为正确和错误识别的正样本数量;  $FN$  表示错误识别的负样本数量。基于这些定义, AP 值的计算公式定义如下:

$$AP = \int_0^1 P(R) dR \quad (16)$$

式中:  $P$  和  $R$  分别指精确率和召回率;  $P(R)$  代表 PR 曲线。

本文采用了 MS COCO 数据集的评估方法。并为提高准确性, 在 P-R 曲线上采样了 100 个点进行计算。此外, 对交并比 (intersection over union, IoU) 的判定阈值进行动态调整, 从 0.5 开始, 以 0.05 为步长, 直至 0.95, 对

每个阈值下的 AP 值进行计算, 并取这些计算结果的平均值作为最终的评估结果。通常, AP 是针对单一类别的, 而 mAP 则是综合所有类别的 AP 值后得出的平均值, 则 mAP 定义如下:

$$mAP = \frac{1}{n_c} \int_0^1 P(R) dR \quad (17)$$

### 2.4 ABI-RTLSeg 模型性能评估

#### 1) 定量和定性实验结果

实验中, 将所提出的模型与 Mask R-CNN<sup>[27]</sup>、YOLOACT<sup>[42]</sup>、YOLOACT++<sup>[23]</sup> 及 RTLSeg<sup>[19]</sup> 进行了比较, 以验证 ABI-RTLSeg 模型的有效性和可行性。为确保比较结果的公正性, 所有对比的基线方法均采用相同的 ResNet-01-FPN 作为基础骨干网络, 并在相同的 RTL-I 训练集上进行训练。其他参数严格按照默认设置, 并在训练过程中进行优化。图 8 所示为 ABI-RTLSeg 模型在训练过程中总损失和各个损失的变化情况。此外, 图 9 所示为所提出的 ABI-RTLSeg 模型在训练过程中验证精度的变化。根据总损失和验证精度的数值, 可以观察到, 在经过 72 000 次迭代后, ABI-RTLSeg 模型呈现收敛的趋势。

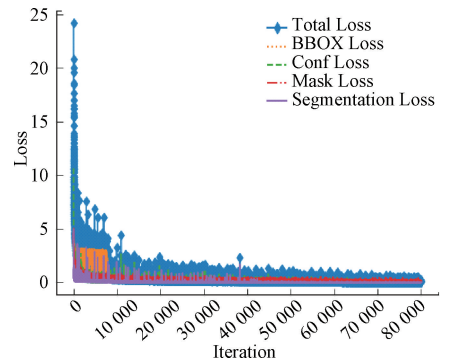


图 8 ABI-RTLSeg 模型的损失曲线

Fig. 8 Loss curves of the ABI-RTLSeg model

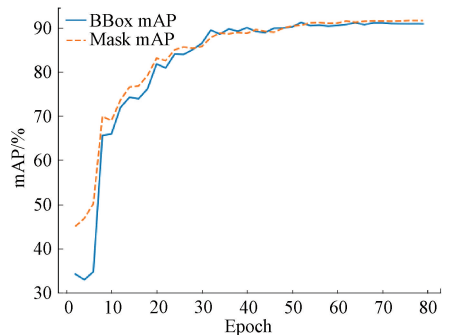


图 9 ABI-RTLSeg 模型的验证准确度

Fig. 9 Validation accuracy of the ABI-RTLSeg model

在 RTL-I 测试集上的检测和分割结果如表 3 所示,



以粗体突出显示了最佳结果。由表 3 数据可知,本文提出的 ABI-RTLSeg 模型在绝大多数的评估指标上都实现了最优性能,表明 ABI-RTLSeg 在边界框检测、掩模分割以及推理速度方面均展现出了不错的竞争力。在边界框检测方面,本文模型的 AP 值相较于原始 YOLACT 模型和 YOLACT++模型分别提升了 6.29%和 4.66%,略低于 RTLseg 模型 0.44%。尽管 Mask R-CNN 达到了最高的 mAP 值 93.59%,但在固定 IoU\_box = 0.5 和 IoU\_mask = 0.75 的条件下,ABI-RTLSeg 在 AP@ 0.5\_box 和 AP@ 0.75\_mask 指标上至少分别高出其他模型 0.07% 和 0.16%。在分割性能方面,尽管 ABI-RTLSeg 模型在 AP@ 0.5\_mask 和 AP@0.75\_mask 指标上相较于 RTLSeg 模型略有下降,但在 mAP 值上却实现了提升。在 AP 值上,

表 3 ABI-RTLSeg 模型与基线模型之间检测和分割性能的比较

Table 3 The comparison of detection and segmentation performance between the proposed model and the baselines								
方法	Backbone	bbox/%			mask/%			推理速度/fps
		AP	AP@ 0.5	AP@ 0.75	AP	AP@ 0.5	AP@ 0.75	
Mask R-CNN <sup>[27]</sup>	R-101-FPN	<b>93.59</b>	98.19	97.78	89.32	98.28	97.42	6.94
YOLACT <sup>[42]</sup>	R-101-FPN	84.62	97.88	94.98	85.91	98.09	95.34	21.46
YOLACT++ <sup>[23]</sup>	R-101-FPN	86.25	98.66	97.52	87.05	98.72	97.32	16.33
RTLSeg <sup>[19]</sup>	R-101-PaFPN	91.35	98.90	98.02	91.60	<b>99.14</b>	<b>98.14</b>	13.07
ABI-RTLSeg	R-101-ASPP-PaFPN	90.91	<b>98.97</b>	<b>98.18</b>	<b>91.67</b>	98.97	98.04	<b>25.62</b>

图 10 所示为模型之间的视觉比较结果 (GT 代表 Grounding truth), 这些示例从定性角度验证了 ABI-RTLSeg 模型在多种环境条件下 (包括光照变化、相机拍摄角度等因素) 的有效性和鲁棒性。通过直观的图像对比,可以看出 ABI-RTLSeg 在处理复杂场景时的优越性能。

2) 检测混淆矩阵

表 4 为基于本文研究所提出的 ABI-RTLSeg 模型的轨道线路多目标关键部件及常见缺陷检测的混淆矩阵,其中置信度阈值被设定为 0.5。分析结果表明,在该阈

表 4 ABI-RTLSeg 模型与基线模型之间检测和分割性能的比较

Table 4 The comparison of detection and segmentation performance between the proposed model and the baselines										
Actual class	Predicted class									召回率/%
	nut	screw	bolt	normal_clip	fractured_clip	rail	rail_corrugation	backing_plate	gauge_block	
nut	15									100
screw		15								100
bolt			502							100
normal_clip				446						100
fractured_clip					14					100
rail						251				100
rail_corrugation							216			99.08
backing_plate								420		100
gauge_block									477	99.58
精确率/%	100	100	100	100	100	100	100	100	100	

注:1. ‘N D’ represents ‘Not detected’

本文模型相较于 Mask R-CNN、YOLACT 和 YOLACT++分别提升了 2.35%、5.76%和 4.62%,并且相较于 RTLSeg 高出 0.07% AP。在固定 IoU\_mask = 0.5 和 IoU\_mask = 0.75 的条件下,ABI-RTLSeg 在 AP@ 0.5\_mask 和 AP@ 0.75\_mask 指标上至少比其他模型 (除 RTLSeg 外) 提升了 0.25% 和 0.62%,相较于 RTLSeg 模型仅下降了 0.17%和 0.1%。在模型推理速度方面,由表 3 可见,由于其检测策略,Mask R-CNN 的推理速度远低于其他模型,实验中平均为 6.94 fps。而本文研究提出的 ABI-RTLSeg 模型的平均推理速度达到了 25.62 fps,不仅超过了 YOLACT++模型的 16.33 fps 和 YOLACT 模型的 21.46 fps,而且几乎是 RTLSeg 模型的 2 倍,显示出在实时处理方面的显著优势。




图 10 ABI-RTLSeg 与基线模型之间分割结果的定性比较

Fig. 10 Qualitative comparison of segmentation results between baseline models and ABI-RTLSeg

2.5 缺陷分析实例分析

通过实例研究的形式,详细展示了所提出的扣件损坏严重评估方法和钢轨波磨关键参数估计方法的可视化过程及其实际应用的可行性。研究中所使用的图像,包括表现为中度损坏的扣件和存在波磨的钢轨,收集或模拟自北京地铁 6 号线南锣鼓巷站与东四站之间的小半径曲线路段。

对于扣件的安全状态检测,首先利用 ABI-RTLSeg 模

型对扣件进行检测识别,并获取分割掩模结果。随后,将分割结果输入至分割结果分析模块中。结合 MCCA 方法和放缩因子 (scale factor, SF),对分割掩模面积进行标准化处理。依据式 (1) 计算得到损坏扣件的损伤度 DD。最终,根据式 (2) 中定义的隶属度函数 (level membership function, LMF) 和最大隶属原则 (maximum subordination principle, MSP),确定扣件损坏的严重程度等级。详细的可视化过程和结果如图 11 所示。




图 11 扣件损坏严重程度评估可视化过程和结果

Fig. 11 Visualization process and results of fastener damage severity assessment

针对钢轨波磨的检测,同样在应用 ABI-RTLSeg 模型获取分割掩模结果后,将其输入至分割结果分析模块中。进一步采用基于最小二乘法(least squares method, LSM)的椭圆拟合(ellipse fitting, EF)算法,对每个子波磨区域

的分割掩模结果进行拟合,从而计算得到每个子波磨区域的质心坐标、长轴长  $2a$ 、短轴长  $2b$  以及倾斜角度。基于这些参数,最终程和结果如图 12 所示。

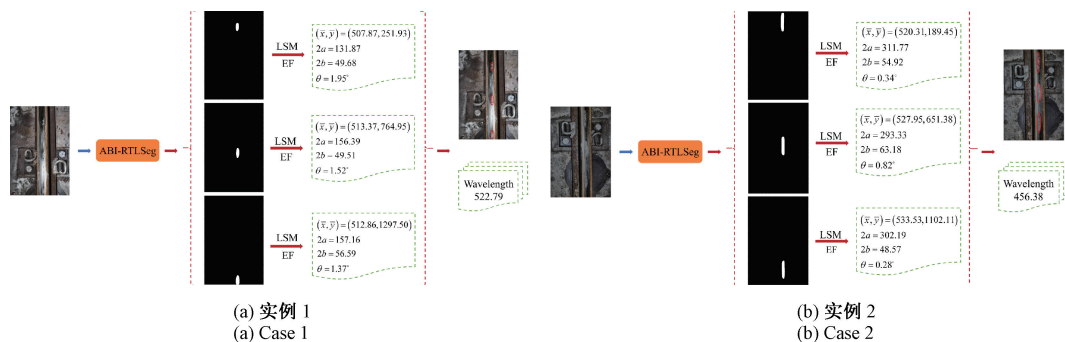


图 12 波磨关键参数估计可视化过程和结果

Fig. 12 Visualization process and results of corrugation key parameter estimation

根据现场实际和模拟情况,本实例的可视化处理过程与分析结果表明,所提出的方法为评估扣件损伤严重程度和钢轨波磨关键参数提供了一个可行的途径。

### 3 结 论

本文针对像素级别的轨道线路多目标关键部件快速精细化识别及常见缺陷检测与分析问题进行了系统性探讨。为此,构建了 RTL-I 数据集,并提出了一种 ABI-RTLSeg 模型。该模型首先引入空洞空间金字塔池化模块至深层骨干网络中,以增强对高级语义信息的学习。其次,在 Coord-Protonet 中引入基于卷积的双线性插值结构,旨在获取更高质量的原型掩模和增强的语义信息感知。最后,通过构建分割结果分析模块,综合运用椭圆拟合和形态学分析方法,对常见缺陷的安全状态进行可视化分析。实验结果表明,ABI-RTLSeg 模型在快速精细化检测、分割及分析轨道线路的多目标关键部件和常见缺陷方面具有有效性和可行性,且性能优于对比的基线模型。相比原始的 RTLSeg 模型,掩模平均精度和平均推理速度分别提升 0.07% 和 12.55 fps。本文方法为轨道线路的智能化监测提供了创新的技术途径,对提升铁路运输系统的安全性和可靠性具有重要的实际意义。

在未来的工作中,将对 RTL-I 数据集进行扩展,强化数据集的全面性,提升检测的普适性和鲁棒性,同时以实现现场轻量化部署为目标,进一步提升模型的推理速度。其次,本文提出的分割评估模型将通过现场测试进行验证与优化,探究开发更可靠的缺陷严重程度评估方法,并构建检测与评估的一体化体系,以实现轨道线路关键部件的高效精准管理,为后续的维护决策提供科学依据。此外,随着检测领域的发展,研究者也将探索将研究成果

扩展至 3D 工程应用,以进一步提高铁路轨道线路缺陷检测的自动化和智能化水平。

### 参考文献

- [1] GUO F, QIAN Y, SHI Y F. Real-time railroad track components inspection based on the improved YOLOv4 framework [J]. Automation in Construction, 2021, 125: 103596.
- [2] POPOV K, DE BOLD R, CHAI H K, et al. Big-data driven assessment of railway track and maintenance efficiency using artificial neural networks [J]. Construction and Building Materials, 2022, 349: 128786.
- [3] TANG R F, DE DONATO L, BESINOVIC N, et al. A literature review of Artificial Intelligence applications in railway systems [J]. Transportation Research Part C: Emerging Technologies, 2022, 140: 103679.
- [4] DI SUMMA M, GRISETA M E, MOSCA N, et al. A review on deep learning techniques for railway infrastructure monitoring [J]. IEEE Access, 2023, 11: 114638-114661.
- [5] 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.
- [6] BAI T B, YANG J W, XU G Y, et al. An optimized railway fastener detection method based on modified Faster R-CNN [J]. Measurement, 2021, 182: 109742.
- [7] HU J, QIAO P, LV H H, et al. High speed railway fastener defect detection by using improved YOLOX-nano model [J]. Sensors, 2022, 22(21): 8399.



- [ 8 ] LIU J W, QIU Y, NI X F, et al. Fast detection of railway fastener using a new lightweight network OP-YOLOv4-Tiny [ J ]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(1): 133-143.
- [ 9 ] GAO Y, CAO Z W, QIN Y, et al. Railway fastener anomaly detection via multi-sensor fusion and self-driven loss reweighting [ J ]. IEEE Sensors Journal, 2024, 24(2): 1812-1825.
- [ 10 ] QIU Y, LIU H L, LIU J W, et al. Center-triplet loss for railway defective fastener detection [ J ]. IEEE Sensors Journal, 2024, 24(3): 3180-3190.
- [ 11 ] YE W L, REN J J, LU C F, et al. Intelligent detection of fastener defects in ballastless tracks based on deep learning [ J ]. Automation in Construction, 2024, 159: 105280.
- [ 12 ] WEI X K, WEI D H, SUO D, et al. Multi-target defect identification for railway track line based on image processing and improved YOLOv3 model [ J ]. IEEE Access, 2020, 8: 61973-61988.
- [ 13 ] WU Y P, QIN Y, QIAN Y, et al. Hybrid deep learning architecture for rail surface segmentation and surface defect detection [ J ]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(2): 227-244.
- [ 14 ] YANG J X, ZHOU W J, WU R M, et al. CSANet: Contour and semantic feature alignment fusion network for rail surface defect detection [ J ]. IEEE Signal Processing Letters, 2023, 30: 972-976.
- [ 15 ] LUO H, CAI L M, LI C B. Rail surface defect detection based on an improved YOLOv5s [ J ]. Applied Sciences, 2023, 13(12): 7330.
- [ 16 ] 张银胜, 杨宇龙, 吉茹, 等. 改进 YOLOv5s 的风力涡轮机表面缺陷检测 [ J ]. 电子测量与仪器学报, 2023, 37(1): 40-49.
- ZHANG Y SH, YANG Y L, JI R, et al. Surface defect detection of wind turbine based on YOLOv5s [ J ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 40-49.
- [ 17 ] GUO F, QIAN Y, YU H Y. Automatic rail surface defect inspection using the pixelwise semantic segmentation model [ J ]. IEEE Sensors Journal, 2023, 23(13): 15010-15018.
- [ 18 ] ZHOU W J, HONG J K. FHENet: Lightweight feature hierarchical exploration network for real-time rail surface defect inspection in RGB-D images [ J ]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-8.
- [ 19 ] WEI D H, WEI X K, TANG Q F, et al. RTLSeg: A novel multi-component inspection network for railway track line based on instance segmentation [ J ]. Engineering Applications of Artificial Intelligence, 2023, 119: 105822.
- [ 20 ] ZOU Z X, CHEN K Y, SHI Z W, et al. Object detection in 20 years: A survey [ J ]. Proceedings of the IEEE, 2023, 111(3): 257-276.
- [ 21 ] 赵恩玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法 [ J ]. 仪器仪表学报, 2023, 44(11): 176-184.
- ZHAO EN X, HE Y Y, SHEN K, et al. Casting CT image segmentation algorithm based on deep learning [ J ]. Chinese Journal of Scientific Instrument, 2023, 44(11): 176-184.
- [ 22 ] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [ C ]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [ 23 ] BOLYA D, ZHOU C, XIAO F Y, et al. YOLACT++: Better real-time instance segmentation [ J ]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(2): 1108-1121.
- [ 24 ] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks [ C ]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 764-773.
- [ 25 ] ZHU X Z, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results [ C ]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308-9316.
- [ 26 ] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFS [ J ]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [ 27 ] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask r-cnn [ C ]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [ 28 ] WANG X L, KONG T, SHEN C H, et al. Solo: Segmenting objects by locations [ C ]. Computer Vision-ECCV 2020: 16th European Conference, 2020: 649-665.
- [ 29 ] WANG X L, ZHANG R F, KONG T, et al. Solov2: Dynamic and fast instance segmentation [ J ]. Advances in Neural Information Processing Systems, 2020, 33: 17721-17732.
- [ 30 ] LIU R, LEHMAN J, MOLINO P, et al. An intriguing failing of convolutional neural networks and the

- CoordConv solution[J]. Advances in Neural Information Processing Systems, 2018, 31.
- [31] ISLAM D, MAHMUD T, CHOWDHURY T. An efficient automated vehicle license plate recognition system under image processing[J]. Indonesian Journal of Electrical Engineering and Computer Science, 2023, 29(2): 1055-1062.
- [32] WEI D H, WEI X K, LIU Y X, et al. The identification and assessment of rail corrugation based on computer vision[J]. Applied Sciences, 2019, 9(18): 3913.
- [33] PANAGIOTAKIS C, ARGYROS A. Region-based fitting of overlapping ellipses and its application to cells segmentation[J]. Image and Vision Computing, 2020, 93: 103810.
- [34] ZHAO L F, LI G Q, WANG J. Tone mapping method based on the least squares method[J]. Electronics, 2022, 12(1): 31.
- [35] VAITHIANATHAN M, PATIL M, NG S F, et al. Comparative study of FPGA and GPU for high-performance computing and AI[J]. ESP International Journal of Advancements in Computational Technology (ESP-IJACT), 2023, 1(1): 37-46.
- [36] LI M Z, LI M C, REN Q B, et al. PipeTransUNet: CNN and Transformer fusion network for semantic segmentation and severity quantification of multiple sewer pipe defects[J]. Applied Soft Computing, 2024, 159: 111673.
- [37] ZHANG H R, WU C, ZHANG Z Y, et al. Resnest: Split-attention networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 2736-2746.
- [38] CHEN X, FANG H, LIN T Y, et al. Microsoft coco captions: Data collection and evaluation server[J]. ArXiv preprint arXiv:1504.00325, 2015.
- [39] ULLAH R, JAAFAR J, ABAS B. Semantic annotation model for objects classification[C]. 2015 IEEE Student Conference on Research and Development (SCOREd). IEEE, 2015: 87-92.
- [40] CHEN R C, DEWI C, ZHUANG Y C, et al. Contrast limited adaptive histogram equalization for recognizing road marking at night based on YOLO models[J]. IEEE Access, 2023, 11: 92926-92942.
- [41] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single

shot multibox detector[C]. Computer Vision-ECCV 2016: 14th European Conference, 2016: 21-37.

- [42] BOLYA D, ZHOU C, XIAO F Y, et al. Yolact: Real-time instance segmentation[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9157-9166.

## 作者简介



**魏德华** (通信作者), 2014 年于福州大学获得学士学位, 2017 年于福州大学获得硕士学位, 2023 年于北京交通大学获得博士学位, 现为兰州交通大学讲师, 主要研究方向: 铁路安全智能感知、铁路信息化、智能交通、计算机视觉等。

E-mail: wdh7016@lztu.edu.cn

**Wei Dehua** (Corresponding author) received his B. Sc. degree from Fuzhou University in 2014, M. Sc. degree from Fuzhou University in 2017, and Ph. D. degree from Beijing Jiaotong University in 2023. Now he is a lecturer in Lanzhou Jiaotong University. His main research interests include railway safety and intelligent perception, railway informatisation, intelligent transportation and computer vision, etc.



**魏秀琨**, 1992 年于兰州理工大学获得学士学位, 1995 年于兰州理工大学获得硕士学位, 2006 年于奥地利林茨大学获得博士学位, 2006 年至 2009 年于荷兰代尔夫特理工大学系统与控制中心从事博士后研究工作, 现为北京交通大学教授、博士生导师, 主要研究方向: 故障诊断及其应用、智能交通系统、状态监测及其在铁路交通控制、安全和运输等众多领域的应用。

E-mail: xkwei@bjtu.edu.cn

**Wei Xiukun** received his B. Sc. degree from Lanzhou University of Technology in 2014, M. Sc. degree from Lanzhou University of Technology in 2017 and Ph. D. degree from Johannes Kepler University Linz in Austria in 2023. From 2006 to 2009, he conducted postdoctoral research at the Delft Center for Systems and Control, Delft University of Technology, Netherlands. Now he is a professor and supervisor for Ph. D. student in Beijing Jiaotong University. His main research interests include fault diagnosis and its applications, intelligent transportation systems, and condition monitoring and its applications in a variety of fields, such as rail traffic control, safety, and transportation.