

基于数据增强和改进 YOLOv8 的轨道扣件检测方法^{*}

刘亚好 任愈

(西南交通大学轨道交通运载系统全国重点实验室 成都 610031)

摘要: 随着深度学习技术在轨道巡检中的广泛应用,轨道扣件领域的视觉检测方法得到越来越多的研究。针对当前轨道扣件数据集中构建缺陷样本的效率瓶颈、以及基于图像数据展开部件松动检测手段相对匮乏的现状,本文提出了一种基于数据增强和 YOLOv8 模型的轨道扣件检测方法。本研究通过搭载于检测车上的线阵相机采集图像获取原始数据和纹理信息,利用图像的先验信息控制点云数据高效生成包含轮廓信息的掩膜图像及标签文件,基于风格迁移模型实现了纹理信息的迁移和融合。针对基于图像数据同步实现缺失等状态和松动状态检测的需求,引入注意力机制和自适应拼接层,构建多任务检测模型实现了扣件状态的快速识别与螺栓区域的精确分割,目标检测的平均精度达到了 92.14%,语义分割的交并比达到了 89.60%。本文方法有效提升了数据增强的效率,降低了二维图像领域对于螺栓状态的漏检概率。

关键词: 轨道扣件;智能检测;数据增强;线阵相机;YOLOv8

中图分类号: TN919.5; TP274 文献标识码: A 国家标准学科分类代码: 580.99

Track fastener detection based on data enhancement and improved YOLOv8

Liu Yahao Ren Yu

(State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: With the wide application of deep learning technology in rail inspection, visual inspection methods in the field of rail fasteners have been increasingly studied. Aiming at the efficiency bottleneck of constructing defective samples in the current rail fastener data set, and the relative lack of means to detect loose parts based on image data, this paper proposes a rail fastener detection method based on data enhancement and YOLO model. In this study, the line array camera mounted on the inspection vehicle collects images to obtain raw data and texture information, uses the a priori information of the image to control the point cloud data to efficiently generate mask images and label files containing contour information, and realizes the migration and fusion of texture information based on the style migration model. Aiming at the demand of synchronization based on image data to realize the detection of missing and other states and loose states, the attention mechanism and adaptive splicing layer are introduced, and the multi-task detection model is constructed to realize the rapid identification of fastener states and the accurate segmentation of the bolt region, and the average accuracy of target detection reaches 92.14%, and the pixel accuracy of semantic segmentation reaches 89.6%. The method in this paper effectively improves the efficiency of data enhancement and reduces the probability of leakage detection for bolt states in the field of 2D images.

Keywords: rail fasteners; intelligent inspection; data enhancement; line array camera; YOLOv8

0 引言

随着轨道交通的迅速发展,轨道扣件系统在高频轮轨摩擦、振动和冲击的运行条件下,难以避免出现性能劣化等问题,直接影响轨道结构的正常运行状态,严重时甚至可能对列车的运行安全性和稳定性构成威胁^[1]。及时检测和控制这些问

题对铁路维护、确保行车安全至关重要。人工巡检存在人为误差大、劳动强度大、工作效率低等问题^[2],在天窗期缩短^[3]、复杂地质环境的背景下,亟需更先进、更有效的探测方法。

随着深度学习技术的在巡检领域的迅速发展,针对轨道扣件检测的深度学习方法也得到广泛研究。陈文婷等^[4]将三维深度信息融合在二维图像上,利用 YOLOv5 模型实

现扣件状态检测及螺栓定位,在提取像素的深度信息后通过计算高度差实现螺栓松动检测;邹文武等^[5]利用信道修剪算法对 EfficientDet 网络进行优化;李清勇等^[6]引入结构化损失计算基于深度卷积自编码实现异常扣件检测;高洪等^[7]基于线结构激光测量技术得到轨道扣件点云数据,基于决策树分类和区域生长算法实现部件点云部件级分割、几何参数检测以及扣件完整性检测;袁小翠等^[8]基于 PointNet++ 网络提取的弹条点云数据提取二维图像上弹条骨架,融合二维图像和三维点云数据提取弹条特征点,基于弹条缝隙检测扣件结构缺陷。

目前针对轨道扣件检测主要基于二维图像和三维点云数据进行研究,数据多呈现正负样本不均衡、缺陷类型匮乏等情况。普遍认为,更好的数据集是获取更好的深度学习模型的基础^[9],轨道扣件的数据增强手段就随之发展。主要有两类:一是从图像像素发展而来控制部件像素的方法,需区分前后景、步骤繁琐,涵盖传统人为控制与深度学习像素生成,如 Liu 等^[10]和 Su 等^[11]分割图像上弹条区域和背景,经过区域调整后再融合生成缺陷图像。其中,Liu 等通过提取弹条区域的骨架线实现调整弹条状态的自动化,提高图像生成效率。Qiu 等^[12]借助调整分割输出的标签文件生成掩膜(Mask)图像,借助风格迁移赋予掩膜特征信息,将缺陷图像生成问题拆解为轮廓信息的控制和纹理信息的迁移;二是借助成熟的三维建模和纹理渲染的方法,可获得逼近真实情况的模型,Qiu 等^[12]通过三维建模和纹理渲染输出虚拟检测图像。无论是图像还是三维模型,手动调整部件轮廓(即缺陷程度)步骤繁琐,即使提取出区域的骨架线也面临区域中螺栓和弹条没有区分映射导致去除区域时螺栓和弹条区域没有分割的情况,会导致去除临近螺栓的弹条区域时附带去除部分螺栓区域的情况或限制无法去除临近螺栓的弹条区域。

着眼于螺栓松动状态的检测对当前轨道扣件领域的检测手段分类的结果基本等同于按照二维和三维数据划分检测方法。大部分轨道扣件的缺陷状态可通过二维图像实现检测,针对松动状态的检测多依赖三维点云数据实现。李胜腾等^[13]学者同时获取图像的三维点云模型,利用 YOLOv5 网络进行部件丢失检测,利用三维点云和不见相对位置固定的特点进行部件松动检测。综合单目测距和螺栓松动在图像上呈现的角点变动情况,通过图像数据实现螺栓松动状态检测具有可行性。

本文针对数据增强效率瓶颈、螺栓松动图像检测手段匮乏的问题,提出基于数据增强和 YOLOv8 的轨道扣件检测方案,高效生成缺陷图像,并构建多任务检测网络降低螺栓松动状态漏检情况。

1 轨道扣件检测方案及研究思路

1.1 基本框架

本文提出的检测方案围绕数据集构建以及检测网络的

设计展开,采用了基于风格迁移网络模型的数据增强方法和多任务检测网络的异常识别方法。本文基本框架如图 1 所示。

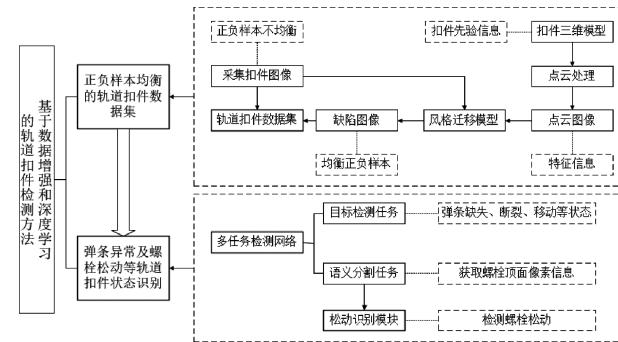


图 1 检测方案基本框架

Fig. 1 Basic framework of the testing program

1.2 基于循环生成对抗网络的数据增强方法

轨道扣件各类状态效果如图 2,包括图 2(a)正常状态、图 2(b)弹条位移、图 2(c)弹条断裂和图 2(d)弹条缺失状态。为提高数据增强方法的通用性,实现操作步骤高度模块化,将数据增强方法各环节拆解,整体流程如图 3,涉及到真实数据采集及预处理、掩膜图像生成和风格迁移 3 个步骤:

1) 建立整套采集装置实现线阵相机匀速运行条件高分辨率的图像采集,提取方向梯度直方图特征对图像进行预处理剔除无效背景的数据段,以成对的扣件图像形式输出。

2) 通过分析轨道扣件的几何信息,控制部件点云数据移动、旋转等批量生成掩膜图像,作为风格迁移过程中部件位置和几何信息的约束,同步输出标签信息。

3) 基于两类风格域的图像通过循环生成对抗网络实现掩膜图像的风格化迁移,批量生成缺陷图像数据。结合风格迁移过程中部件位置信息的变化调整标签信息,输出其对应的标注文件。

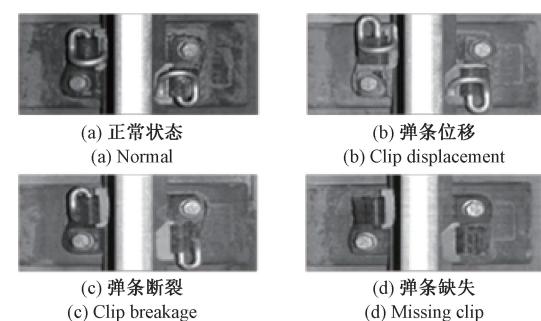


图 2 轨道扣件状态

Fig. 2 Track fastener status

1.3 基于多任务检测网络的扣件异常状态识别

螺栓松动状态在检测时主要呈现为高度方向的变化以及螺栓顶面的旋转,为了有效识别这一异常状态,本文提出融合目标检测和语义分割的多任务检测网络,在实现目标

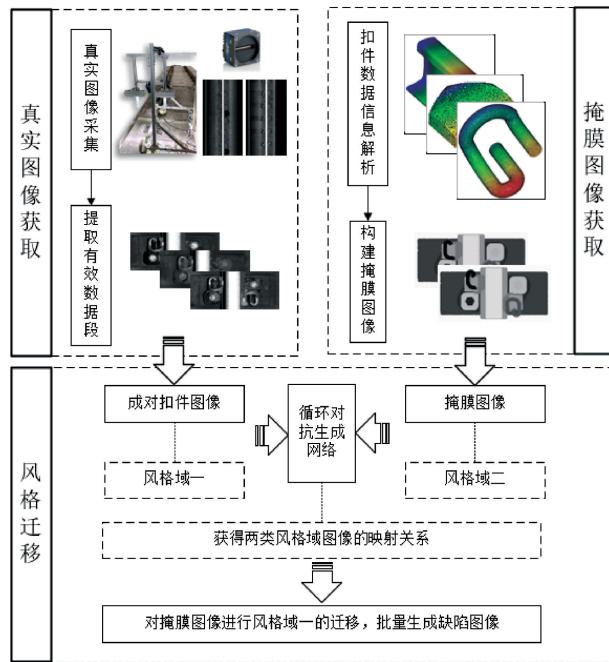


图3 数据增强流程图

Fig. 3 Data enhancement flowchart

检测的基础上提升模型对螺栓松动状态的识别能力。多任务检测网络结构包括目标检测任务和语义分割任务两个分支,目标检测分支负责定位和识别扣件状态及具体位置,而语义分割分支则负责识别出螺栓顶面的像素。通过结合这两种任务,网络不仅能识别和定位目标螺栓,还能够对螺栓的状态进行细化分析。

目标检测网络基于提取并融合的不同尺度的特征图进行目标的分类、定位等任务的输出。语义分割分支通过对图像中每个像素进行分类,能够精确地分割出螺栓区域,获得其顶面位置信息。多任务学习框架在完成常规的目标检测任务的同时处理螺栓松动状态的语义分割任务,进一步优化网络模型对轨道扣件状态的检测精度。

为量化螺栓松动的情况,设计了松动识别模块对比螺栓在图像中的特征差异,最终实现对螺栓松动状态的精确识别。具体而言,结合目标检测和语义分割分支的输出结果,该松动模块通过比较两张图像上螺栓相邻角点的向量角度最终实现对松动状态的精确识别。通过上述多任务学习网络和松动模块的结合,进一步优化轨道扣件图像的检测精度,细化对于螺栓松动的识别程度,降低漏检和误检的概率。

2 数据获取及数据增强

2.1 轨道扣件数据采集与处理

采集系统包括线阵相机、光源和编码器等设备,整体结构示意图如图4所示。其中,两个光源对称分布在线阵相机左右两侧,为检测区域提供稳定且充分的照明。同时,线阵相机在编码器的触发控制下沿轨道方向逐行采集扣件图

像,能够实现采集与被测物移动速度的同步,以保证采集过程的平稳性和高效性。

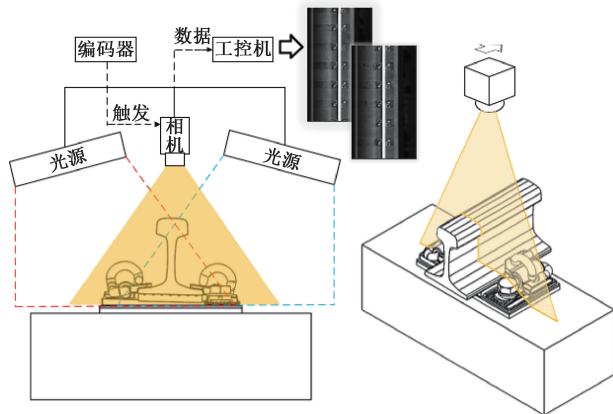


图4 采集系统示意图

Fig. 4 Schematic diagram of the acquisition system

采集到的图像数据大多为正常状态的扣件,且扣件区域中少有杂物遮挡影响。由于标准件的规格严格,扣件区域的形态和尺寸保持一致,图像在空间分布和纹理特征上具有高度的相似性和规律性。这种一致性使得图像中的扣件区域在不同采集场景下表现出较为稳定的视觉特征,便于后续的图像处理和特征提取。

为快速提取处采集到的大量图像数据中提取有效的目标数据段,本文基于方向梯度直方图(histogram of oriented gradients, HOG)^[14]特征匹配的方法,快速地获取采集图像中有效的成对扣件区域并裁剪保留,过滤背景中的无效数据。图像中局部区域的边缘信息能够被梯度或边缘方向密度分布很好地描述,HOG特征通过计算统计图像局部区域的梯度方向直方图构成特征。具体而言,是将图像切分为小目标区域并统计该区域内的梯度方向和梯度幅值,将区域内各像素点的直方图组合构成特征描述器。流程图如图5所示,对采集图像中的成对扣件区域进行HOG提取,采用特征匹配完成提取,为后续的数据增强提供高质量的样本。

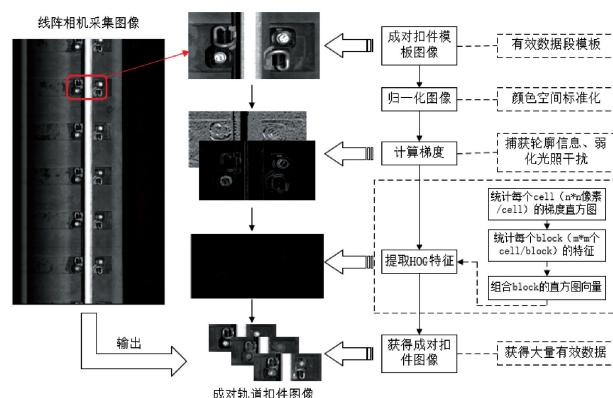
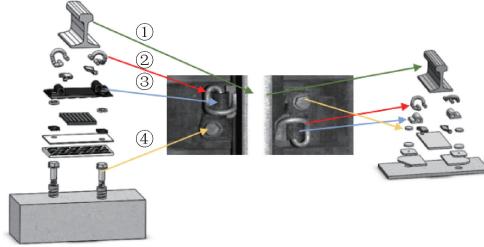


图5 成对轨道扣件获取流程

Fig. 5 Acquisition process for paired rail fasteners

构建掩膜图像即另一个风格域的图像作为风格迁移网络模型的训练输入,通过分析扣件图纸信息以及其在线阵相机视角下部件的数据信息,灵活控制部件的三维信息,实现此风格域图像的生成。轨道扣件系统包含弹条、螺栓、绝缘块等众多部件,在检测需求和成像视角影响下更侧重关注弹条和螺栓的状态,因此进行必要的部件简化,如图 6 所示,①~④依次对应钢轨、弹条、铁垫板和螺栓部件模型。根据扣件部件的尺寸、形状以及其在相机视角下的投影,构建出含轮廓标注的掩膜图像。



①钢轨;②弹条;③铁垫板;④螺栓

图 6 扣件简化情况

Fig. 6 Simplification of fasteners

2.2 基于循环生成对抗网络的数据增强过程

循环生成对抗网络 (cycle generative adversarial network, CycleGAN)^[15] 是一种基于生成对抗网络的深度学习模型,主要用于图像风格迁移或图像到图像的转换。其关键特点在于能够在不需要成对图像样本的情况下,实现一种图像风格到另一种图像风格的无监督转换^[16]。循环生成对抗网络模型架构如图 7 所示,由两组生成器和判别器实现掩膜图像与采集图像的相互映射。

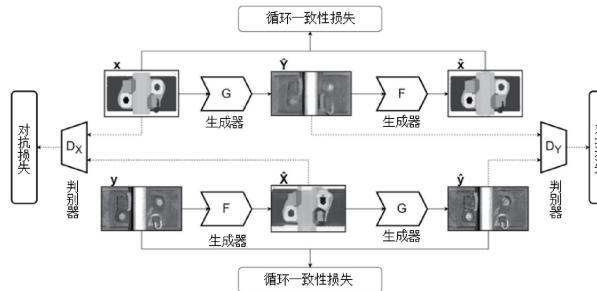


图 7 循环生成对抗网络结构

Fig. 7 Network structure of cyclegan

对抗损失是生成器和判别器相互博弈的核心机制,旨在让生成器生成的图像越来越逼真,同时判别器也能越来越精确地分辨出真实图像和伪造图像。针对生成器 G 和判别器 D_Y 的对抗损失可以表示为

$$L_{GAN}(G, D_Y, X, Y) = E_{y \sim p_{data}(y)}[\log D_Y(y)] + E_{x \sim p_{data}(x)}[\log(1 - D_Y(G(x)))] \quad (1)$$

其中,第一项 $E_{y \sim p_{data}(y)}[\log D_Y(y)]$ 是判别器 D_Y 对真实图像 y 的判断,期望它输出接近于 1,表示它能够识别出真实图像;第二项 $E_{x \sim p_{data}(x)}[\log(1 - D_Y(G(x)))]$ 则是判

别器对生成器 $G(x)$ 输出的伪造图像的判断,期望判别器能够识别出伪造图像并输出接近于 0。对抗损失约束下,生成器试图不断提高生成图像的质量,而判别器则努力提高其对真实图像和伪造图像的辨别能力。

循环一致性损失强制生成器不仅要生成具有目标域风格的图像,还必须保证生成的图像能够通过另一个生成器转换回原始图像。因此,在没有成对数据的情况下,仍然保持转换后的图像在语义内容上与输入图像相似。循环一致性损失公式为:

$$L_{cyc}(G, F) = E_{x \sim p_{data}(x)}[\|F(G(x)) - x\|_1] + E_{y \sim p_{data}(y)}[\|G(F(y)) - y\|_1] \quad (2)$$

其中, $\|\cdot\|_1$ 是 L1 范数,用于衡量生成图像与真实图像之间的差异。

利用掩膜图像和采集图像的映射关系可高效合成缺陷的扣件图像,数据集增强前后各类图像数据的规模如表 1 所示。

表 1 数据集增强前后规模

Table 1 Size of dataset before and after enhancement

类别	采集数据集	数据增强后数据集
正常	4 300	4 488
弹条丢失	0	269
弹条断裂	0	649
弹条断裂且丢失	0	554
弹条缺失	0	288

3 轨道扣件状态检测

“你只看一次”(you only look once, YOLO) 算法系列^[17] 模型作为目标检测领域的主流模型之一,以其速度快、准确率高和易于部署的特点深受研究者和工业界的青睐。YOLOv8 模型整体由 3 部分组成,分别是主干网络、颈部网络和头部网络。主干网络通过卷积操作提取输入图像的高维语义特征,在训练过程中逐渐强化目标的特征信息。颈部网络将不同维度的特征信息进行融合,减少特征提取中缺失的细节信息。由头部网络基于融合的 3 个维度的特征图输出目标位置坐标和类别概率,实现目标检测。

在 YOLOv8 目标检测模型基础上增加语义分割作为分支任务^[18] 实现螺栓顶面和钢轨顶面的像素级分割,作为固定视角下角点位置检测的基础。考虑到螺栓是小目标的情况,提取并融合了较低维的特征图作为分支的特征基础,并增加残差卷积注意力 (residual block-convolutional block attention module, ResBlock-CBAM) 模块^[19] 和自适应拼接层,增强网络特征提取能力,拼接时增加对于特征图权值的考量,网络架构如图 8 所示。通过构建多任务检测的网络结构,实现扣件状态的目标检测以及螺栓和钢轨顶面的语义分割。

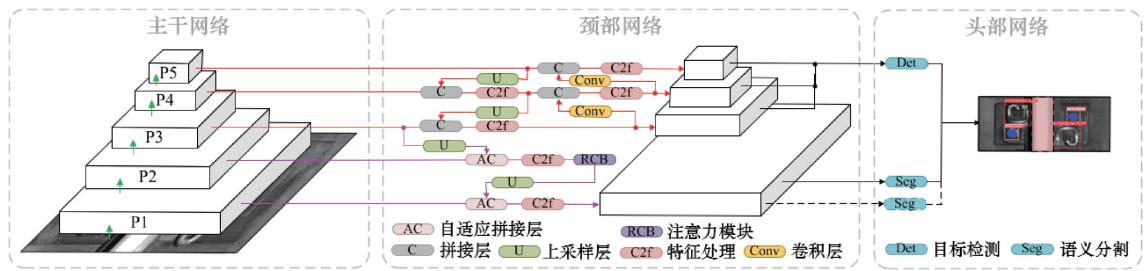


图8 多任务网络架构

Fig. 8 Multitasking network architecture

双分支网络结构的损失函数包括目标检测和语义分割的两部分损失。其中,目标检测任务的损失函数包括边界框回归损失和分类损失,包括二元交叉熵损失 L_{BCE} 、分布焦点损失 L_{DFL} ^[20] 和综合交并比(complete intersection over union, CIoU)损失 L_{CIoU} ^[21],设置权重系数 λ 后检测损失 L_{det} 为

$$L_{det} = \lambda_1 L_{BCE} + \lambda_2 L_{DFL} + \lambda_3 L_{CIoU} \quad (3)$$

其中各个部分损失函数展开如下:

$$L_{BCE} = -[y_n \log x_n + (1 - y_n) \log(1 - x_n)] \quad (4)$$

其中, x_n 是预测分类, y_n 是真实分类, L_{BCE} 衡量分类误差。

$$L_{DFL}(S_i, S_{i+1}) = -[(y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1})] \quad (5)$$

$$S_i = \frac{y_{i+1} - y}{y_{i+1} - y_i}, S_{i+1} = \frac{y_i - y}{y_i - y_{i+1}}$$

其中, y_i 和 y_{i+1} 代表连续输出的真实标签, y 为预测标签, L_{DFL} 是对连续输出值 S_i 和 S_{i+1} 的加权调整, 动态计算模型预测与真实标签的误差。

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha\nu \quad (6)$$

$$\nu = \frac{4}{\pi^2} (\arctan \frac{\omega^{gt}}{h^{gt}} - \arctan \frac{\omega}{h})^2$$

$$\alpha = \frac{\nu}{(1 - IoU) + \nu}$$

其中, IoU 是交并比, 表示预测框与真实框的交集面积与并集面积之比; ν 是宽高比一致性, $\omega^{gt}, h^{gt}, \omega, h$ 分别是真实框和预测框的宽度和高度, α 是权重系数。

考虑到目标与背景的平衡关系,语义分割任务的损失函数设计包括戴斯(dice coefficient, Dice)损失 L_{Dice} ^[22] 和交并比损失 L_{IoU} ^[23], 设置相应的权重系数 λ 得检测损失 L_{seg} 为:

$$L_{seg} = \lambda_4 L_{Dice} + \lambda_5 L_{IoU} \quad (7)$$

$$L_{Dice} = 1 - \frac{2 |X \cap Y|}{|X| + |Y|}$$

其中, $|X \cap Y|$ 是 X 和 Y 的交集, 即预测区域与真实区域的重叠面积, $|X|$ 是语义分割的真实标注区域, $|Y|$ 是预测的区域。Dice 损失能缓解图像分割过程中标注面

积与背景面积不平衡的影响。

$$L_{IoU} = 1 - \frac{|X \cap Y|}{|X \cup Y|} \quad (8)$$

其中, $|X \cup Y|$ 是 X 和 Y 的并集, 即真实区域和预测区域标注的总区域。Dice 损失关注小物体检测的表现, 交并比关注精确的边界优化。

图像检测过程中,螺栓和钢轨的顶面位置信息通过多任务检测模型进行精准输出,可进一步提取螺栓的边缘信息和部分角点的坐标等特征,利用先验信息计算螺栓和钢轨顶面的相对距离作为螺栓的特征。通过对比多次图像采集数据中同位置的螺栓顶面的特征信息,有效捕捉螺栓的状态变化。

4 性能评价与数据分析

4.1 合成图像质量评价和自动标注精度评估

从感知质量、图像细节、人类感知的角度出发,选择感知相似度指标作为合成图像与实采图像质量评估的指标。感知相似度指标(learned perceptual image patch similarity, LPIPS)是一个用于衡量图像感知相似度的指标,专注于反映图像在人类视觉系统中的感知差异^[24]。通过深度卷积神经网络捕获的特征来进行图像相似性计算,能够更好地捕捉图像的高层次特征。

通过预训练的卷积神经网络提取图像的高层次特征,并计算生成图像和训练图像间的感知差异,对于每一层 l 提取的特征图,感知相似度指标计算这两幅图像在该层特征上的差异:

$$d_l(x, x') = \|w_l \cdot (f_l(x) - f_l(x'))\|_2 \quad (9)$$

其中, $f_l(x)$ 和 $f_l(x')$ 是图像 x 和 x' 在第 l 层的特征, w_l 是针对不同通道的权重,用于调整不同层特征图的重要性。这个差异值可以看作是两幅图像在高维特征空间中的距离。在各个卷积层上计算的特征差异 $d_l(x, x')$ 被加权求和,得到最终的感知相似度量:

$$D(x, x') = \sum_l \lambda_l d_l(x, x') \quad (10)$$

其中, λ_l 是每一层的权重,用于平衡不同层次的特征差异对感知相似度的贡献。高层特征通常捕捉到图像的全局信息,而低层特征更关注局部的细节,因此感知相似度指标会结合各层特征进行综合度量。

计算结果如图 9, 平均感知相似度指标为 0.3385, 表示图像之间的感知差异处于中等水平。

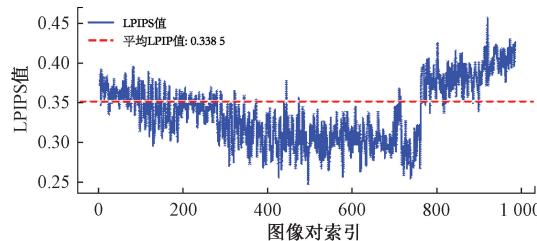


图 9 感知相似度指标

Fig. 9 Lpips

控制生成掩膜图像的过程中根据几何约束和位置信息自动生成对应标注, 与手动标注的标签进行精度比较。采用了召回率、精确率和交并比描述自动标签的精度。召回率指自动标注正确的目标在所有目标中所占比例; 精确率指自动标注中正确的标签占所有自动标注标签的比例; 交并比用于评估自动标注区域与手动标注区域的重叠程度。统计自动标注的统计结果如图 10, 自动标签分类正确、交并比稳定在 80%。

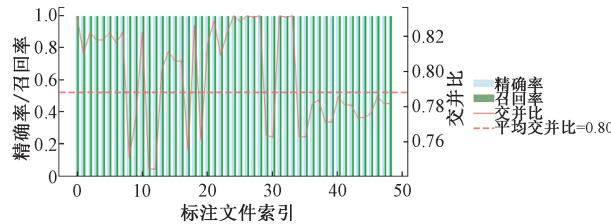


图 10 标签精度对比图

Fig. 10 Label accuracy comparison chart

4.2 实验设置及对比分析

经数据增强扩增后的数据集包含 3 124 张图像, 即 6 248 个完整扣件, 将各类状态下的图像数量近似按照 9:1 的比例划分为了训练集和测试集。制作数据集时, 使用 Labelme 软件对采集图像进行标注, 目标检测标签如图 11(a)~(c) 所示, 语义分割标签如图 11(d) 所示。合成图像的标注由掩膜图像生成过程中控制获得。

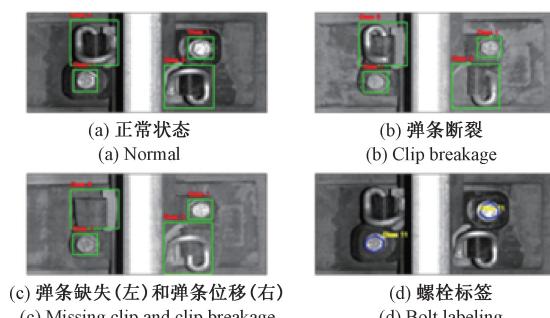


图 11 图像标注示例

Fig. 11 Example of image annotation

模型运行硬件环境为 GPU: NVIDIA GTX3060Ti, CPU: Intel i5-12400F, 内存 32 GB; 软件环境为 Windows11, Pytorch, Python3.7, CUDA 多任务检测网络运行硬件环境为 GPU: 11.6, cuDNN8.3.2。

模型训练过程中的学习率设置为 0.01, 模型训练过程中按照比例因子为 0.01 的余弦方式逐渐衰减至训练结束, 并设置早停机制。训练结果如图 12 所示, 图 12(a) 为目标检测分支训练结果, 图 12(b) 为语义分割分支训练结果。数据表明, 模型在训练过程中损失逐渐下降并收敛, 评价指标逐渐上升并趋于稳定, 训练效果良好。

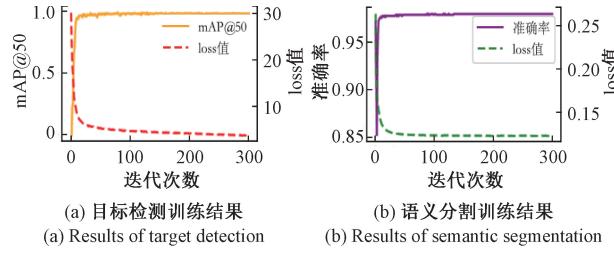


图 12 模型训练结果

Fig. 12 Model training results

为验证本文算法的优势, 与其他算法的检测效果进行对比。鉴于面向轨道扣件领域的检测方法针对螺栓松动状态的检测算法不一, 与数据类型关系密切, 受限于设备无法获得三维数据对比松动检测效果。本文的方法对比将利用同一图像数据集分别对比目标检测和语义分割的效果, 对比结果如表 2 所示。

表 2 同一数据集实验结果

Table 2 Experimental results on the same dataset

算法	Params	GFLOPs	mAP50	IoU
Faster-RCNN ^[25]	28 326 553	250.16	0.879	—
YOLOv8-det	3 006 818	8.1	0.861	—
YOLOv8-seg	3 258 259	12.0	—	0.928
RT-DETR ^[26]	41 947 014	125.6	0.899	—
本文方法	3 315 401	11.57	0.9214	0.896

表中 YOLOv8-det 和 YOLOv8-seg 是 YOLOv8 模型为基础实现目标检测和语义分割, Faster-RCNN 和 RT-DETR 是当前常用的目标检测网络。从检测数据来看, 本文方法在目标检测效果良好的同时, 能实现较好的语义分割效果。

为进一步验证方法的有效性, 本文以 YOLOv8 网络为基础设计消融实验, 验证多任务检测结构合理设计下权值共享的促进作用, 以及语义分割特征融合网络结构、自适应拼接层和注意力模块配合使用的有效性, 分别以 seg、Aconcat、ResCBAM 指代上述语义分割分支、自适应拼接层和注意力模块, 实验结果如表 3 所示。

从表 3 数据可以看出, 在 YOLOv8 目标检测的基础上

表 3 消融实验结果
Table 3 Ablation results

方法	Params	GFLOPs	mAP50	IoU
YOLOv8	3 006 818	8.1	0.861	—
YOLOv8+seg	3 161 791	10.05	0.847	0.831
YOLOv8+seg+Aconcat	3 216 005	10.92	0.876	0.902
YOLOv8+seg+ResCBAM	3 261 187	10.70	0.881	0.891
YOLOv8+seg+Aconcat+ResCBAM	3 315 401	11.57	0.921	0.896

增加语义分割分支会造成目标检测效果下降,对语义分割分支特征融合部分增加自适应拼接层后,合理利用权值共享的特点实现检测效果的提升,增加注意力模块后提升模型特征提取能力,进一步提升检测效果。目标检测精度达到 92.1%,顶面识别的语义分割交并比达到 89.6%。

5 结 论

构建基于线阵相机的轨道扣件采集系统。基于线阵相机和检测车的结构进行轨道扣件图像数据的采集,线阵相机具有高分辨率、高速度、少失真等优势,适合连续图像捕获,能够保证图像数据的质量,为数据增强和状态检测提供数据支持。

针对轨道扣件数据集正负样本不均衡的现象,提出了一种基于风格迁移的数据增强方法,高效实现缺陷样本的数据扩增。利用扣件的先验信息以及采集图像,构建可控的掩膜图像作为部件的几何约束,通过风格迁移模型批量生成缺陷数据样本,同步实现生成图像的自动标注。合成图像的感知损失为 0.338 5,自动标注精度稳定在 80%,满足图像数据的应用要求。

利用多任务检测网络模型实现扣件状态检测及螺栓松动检测。基于多任务检测网络模型实现目标状态检测以及螺栓顶面的像素信息输出,通过设计合理的松动检测模块在二维图像数据上实现固定视角下的螺栓松动检测。目标检测的平均检测精度达到 92.14%,语义分割的交并比达到 89.60%。

参考文献

- [1] 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.
- [2] PRANEETH C, JOHNNY A, FLORIAN T, et al. An investigation of railway fastener detection using image processing and augmented deep learning [J]. Sustainability, 2021, 13(21): 12051.
- [3] LI Y, HOANG T, NORMAN H, et al. Rail component detection, optimization, and assessment for automatic rail track inspection [J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(2): 760-770.
- [4] 陈文婷, 罗文婷, 李林, 等. 基于 2D 与 3D 激光图像的轨道扣件状态智能检测 [J]. 仪表技术与传感器, 2022, 11: 88-95.
- [5] CHEN W T, LUO W T, LI L, et al. Intelligent detection of track fastener status based on 2d and 3d laser images [J]. Instrument Technique and Sensor, 2022, 11: 88-95.
- [6] 邹文武, 许贵阳, 白堂博. 基于 EfficientDet 的轨道扣件识别与检测 [J]. 武汉大学学报(工学版), 2024, 57(7): 1006-1012.
- [7] ZOU W W, XU G Y, BAI T B. Track fastener identification and detection based on efficientdet [J]. Engineering Journal of Wuhan University, 2024, 57(7): 1006-1012.
- [8] 李清勇, 王建柱, 祝叶舟, 等. 基于结构相似深度卷积自编码的异常扣件检测模型 [J]. 交通运输工程学报, 2022, 22(4): 186-195.
- [9] LI Q Y, WANG J ZH, ZHU Y ZH, et al. Abnormal fastener detection model based on deep convolutional autoencoder with structural similarity [J]. Journal of Traffic and Transportation Engineering, 2022, 22(4): 186-195.
- [10] 高洪, 王勇, 唐超, 等. 结合决策树分类和区域生长的轨道扣件检测方法 [J]. 测绘通报, 2022(9): 18-22.
- [11] GAO H, WANG Y, TANG CH, et al. Track fastener detection method based on decision tree classification and region growth [J]. Bulletin of Surveying and Mapping, 2022(9): 18-22.
- [12] 袁小翠, 王咏涛, 刘宝玲, 等. 基于 3D 线激光传感器的轨道弹条扣件结构缺陷检测方法 [J]. 红外与激光工程, 2024, 53(7): 154-168.
- [13] YUAN X C, WANG Y T, LIU B L, et al. Detection method for structural defects of railway clip fastener based on 3d line laser sensor [J]. Infrared and Laser Engineering, 2024, 53(7): 154-168.
- [14] CHEN S, ABHINAV S, SAURABH S, et al. Revisiting unreasonable effectiveness of data in deep

- learning era [C]. Proceedings of the IEEE International Conference on Computer Vision. NEW YORK, 2017: 843-852.
- [10] LIU J W, TENG Y, NI X F, et al. A fastener inspection method based on defective sample generation and deep convolutional neural network[J]. IEEE Sensors Journal, 2021, 21(10): 12179-12188.
- [11] SU SH X, DU S L, LU X B. Geometric constraint and image inpainting-based railway track fastener sample generation for improving defect inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 23883-23895.
- [12] QIU SH, CAI B X, WANG W D, et al. Automated detection of railway defective fasteners based on yolov8-fam and synthetic data using style transfer[J]. Automation in Construction, 2024, 162: 105363.
- [13] 李胜腾,薛亚东,迟胜超,等.基于3D相机的轨道扣件部件丢失与松动智能检测[J].铁道科学与工程学报,2024,21(1):386-395.
- LI SH T, XUE Y D, CHI SH CH, et al. Intelligent lost and loose detection of track fastener components based on 3d camera[J]. Journal of Railway Science and Engineering, 2024, 21(1): 386-395.
- [14] 马浩,景军锋,苏泽斌,等.基于LBP和HOG特征的图案织物缺陷检测[J].电子测量与仪器学报,2018,32(4):95-102.
- MA H, JING J F, SU Z B, et al. Patterned fabric defect detection based on LBP and HOG feature[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(4): 95-102.
- [15] ZHU J Y, TAESUNG P, PHILLIP I, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [16] FUENTES R M, STEFAN A, NINA M, et al. Sar-to-optical image translation based on conditional generative adversarial networks—Optimization, opportunities and limits[J]. Remote Sensing, 2019, 11(17): 2067.
- [17] JOSEPH R, SANTOSH D, ROSS G, et al. You only look once: Unified, real-time object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [18] WANG J Y, JONATHAN W Q M, ZHANG N. You only look at once for real-time and generic multi-task[J]. IEEE Transactions on Vehicular Technology, 2024, 73(9): 12625-12637.
- [19] 胡久松,刘张驰,余谦,等.融入GhostNet和CBAM的YOLOv8烟雾识别算法[J].电子测量与仪器学报,2024,38(8):201-207.
- HU J S, LIU ZH CH, YU Q, et al. YOLOv8 smoke detection algorithm integrated with ghostNet and CBAM[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 201-207.
- [20] LI X, WANG W H, WU L J, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection [J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [21] ZHENG ZH H, WANG P, LIU W, et al. Distanceiou loss: Faster and better learning for bounding box regression[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 12993-13000.
- [22] FAUSTO M, NASSIR N, AHMAD A S. V-net: Fully convolutional neural networks for volumetric medical image segmentation [C]. 2016 Fourth International Conference on 3D Vision, 2016: 565-571.
- [23] NICOLAS C, FRANCISCO M, GABRIEL S, et al. End-to-end object detection with transformers [C]. European Conference on Computer Vision, 2020: 213-229.
- [24] RICHARD Z, PHILLIP I, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 586-59.
- [25] REN SH 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.
- [26] ZHAO Y, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

作者简介

刘亚好,硕士研究生,主要研究方向为机车车辆测控技术及故障诊断。

E-mail:1025440388@qq.com

任愈(通信作者),博士,副研究员,主要研究方向为车辆运行安全检测、故障诊断与性能评估等。

E-mail:jaderen@swjtu.edu.cn