

# 语义数据标注的轻量化轨道扣件故障检测方法\*

姚德臣<sup>1,2</sup>, 王琰亮<sup>1,2</sup>, 杨建伟<sup>1,2</sup>, 徐立新<sup>3</sup>, 张帆<sup>1,2</sup>

(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.东平湖管理局供水局陈垓闸管理所 泰安,271599)

**摘要** 针对常规深度学习网络规模大、对现场设备硬件要求高且人工标注位置数据复杂费时等问题,提出了一种语义数据标注的轻量化轨道扣件故障检测方法。该方法仅对训练数据做语义标注,改进轻量化 Transformer 模型,嵌入梯度加权类激活映射(gradient-weighted class activation mapping,简称 Grad-CAM)模块对模型输出的特征图权重作映射处理,可将模型对轨道扣件检测效果可视化。将获得的激活图进行二值化定位检测目标位置,实验结果表明,在真实铁路环境下,改进的轻量化轨道扣件模型的准确率为 94.31%。

**关键词** 轨道扣件;智能故障诊断;深度学习;轻量化网络

**中图分类号** U216.3;TH17

## 引言

截至 2022 年底,全国城轨交通运营线路有 308 条,运营线路总长度达 10 287.45 km,这对轨道交通安全是一个巨大挑战<sup>[1]</sup>。轨道扣件是轨道车辆传动装置的主要部件,其状态影响轨道车辆的安全性<sup>[2]</sup>。扣件在长期的复归过程中承受着交变应力的变化,容易发生断裂、偏移和缺失等故障<sup>[3-4]</sup>。

传统故障检测方法具有任务重、成本高和效率低等问题,且依赖巡检人员的经验。陈宗平等<sup>[5]</sup>采用力锤激励,测试了多种扣件在不同温度下的动态响应,提出的模型确定了铁路扣件的刚度,为极端低温环境下的扣件设计和选择提供参考。随着深度学习、计算机视觉和人工智能研究的快速发展,研究人员对故障诊断技术进行研究<sup>[6]</sup>,并在铁路巡检机器人上部署这些智能算法<sup>[7-9]</sup>。邵海东等<sup>[10]</sup>提出了一种改进损失函数,即嵌入联合最大均值差异用于无监督场景,该方法能够实现无监督的轴承跨域故障诊断边缘分布和条件分布的同时对齐。Liu 等<sup>[11]</sup>提出了基于多尺度特征的深度检测网络,从轨道图像中检测故障。Wu 等<sup>[12]</sup>针对铁路及地铁沿线经常受到自然环境因素的影响,提出使用去雾模型获取无人机的无雾图像,再使用三维点云深度残差网络<sup>[13]</sup>

进行故障检测。Wu 等<sup>[14]</sup>提出了一种基于 YOLOv3 模型的定制旋转视网膜网络方法对高速铁路任意方向扣件进行检测。

Cheng 等<sup>[15]</sup>提出使用混合生成对抗网络,将增强超分辨率生成对抗网络和去模糊生成对抗网络相结合,在分辨率和模糊度方面提高动态采集图像的质量,并使用 YOLOv4 模型分别在原始数据集和改进数据集上训练和测试获得的结果,实现自动铁路轨道缺陷识别。Yao 等<sup>[16]</sup>提出先使用生成对抗网络获得额外的真实故障样本,再使用残差网络进行轨道扣件的分类检测。在故障数据严重不足的情况下,该方法可以显著提高轨道扣件的故障检测精度,但是生成对抗网络系列模型的训练相比变分自编码器(variational auto-encoder,简称 VAE)或像素递归神经网络是不稳定的,难以达到纳什均衡。Bai 等<sup>[17]</sup>提出一种优化的区域卷积神经网络(regions with convolutional neural network,简称 R-CNN)特色模型用于轨道紧固件检测,减少了无效锚框,提高了效率和准确性。上述研究基于两步锚框的检测算法,其结构复杂、定位速度慢,难以满足实时性要求。Cao 等<sup>[18]</sup>使用 YOLOv5 模型嵌入卷积注意力模块以提高速度和精度,直接检测有缺陷的紧固件。吴送英等<sup>[19]</sup>提出一种基于附源代码 DenseNet201 迁移学习

\* 国家自然科学基金面上资助项目(51975038,52272385);国家自然科学基金青年科学基金资助项目(52205083);北京市自然科学基金资助项目(L211008,L221027,L211007);北京市自然科学基金青年基金资助项目(3214042);北京建筑大学青年教师科研能力提升计划资助(X21055)

收稿日期:2023-06-12;修回日期:2023-08-08

的扣件故障诊断方法,并在最后 1 层嵌入 Grad-CAM 模块来验证 WJ-8 型扣件的检测效果。上述研究提高了检测精度,但也出现检测模型参数量过大、对现场设备的性能要求高及数据标注耗费成本过大等问题。

笔者提出了一种语义数据标注的轻量化轨道扣件故障检测方法。使用 Shuffle 模块对模型 MobileVit 进行改进,串行 Grad-CAM 模块基于的梯度信息,将分类结果反向传播回卷积层,通过梯度权重对特征图进行加权平均,生成热力图,并将热力图进行二值化,连通区域分析定位目标生成检测框。最后,与主流深度学习模型进行比较,验证所提出方法的性能。

## 1 模型搭建

### 1.1 Transformer 编码层

数据通过 Transformer 编码层的点积运算从而产生对数据的注意力,通过重复堆叠 Transformer 编码层  $L$  次,实现对扣件特征的提取。构成 Transformer 编码层的主要结构是多层感知机层、归一化层和多头注意力机制。多层感知机层由全连接、GELU 激活函数和暂退法组成。层规范化操作是经过层规范化处理的数据能降低梯度爆等问题,提升网络的稳定性。在数据处理过程中一定程度地保留了原始数据特征,编码层加入 2 个线性相加层,实现提升模型特征学习的效果。Transformer 编码层结构如图 1 所示。

编码层的核心部分是多头注意机制,其为转换器模型实现特征提取的关键组成部分。多头注意力机制由多个具有自注意力的注意头组成。在多头注

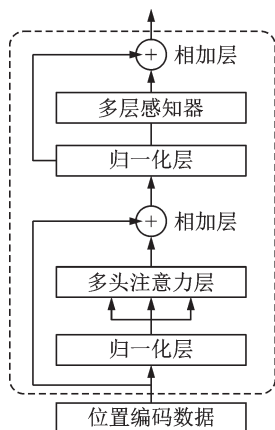


图 1 Transformer 编码层结构

Fig.1 Transformer encoder layer structure

意力机制中,自注意力的过程可以被描述为一种由查询向量和一组键-值向量矩阵求解的过程。查询向量( $Q$ )、键向量( $K$ )和值向量( $V$ )都是由前一层的输出转换而来。在实际计算中,模型同时计算一组查询向量的注意力函数,并将其打包成 $Q$ ,将键向量和值向量打包成 $K$ 和 $V$ 。查询向量的输出结果实际上是由前一层编码的隐藏向量所决定的,而 $K$ 和 $V$ 在自注意力中被赋予与 $Q$ 相同的值。

输出计算结果为权重加权值,该权重由查询向量与键向量的兼容性运算求得。键向量、值向量和查询向量计算公式分别为

$$K_j = fW_j^k \quad (1)$$

$$V_j = fW_j^v \quad (2)$$

$$Q_j = fW_j^q \quad (3)$$

其中: $f = \{f_i\}_{i=1}^l$ ,为多头自注意模块的输入; $W_j^k$ , $W_j^v$ , $W_j^q \in R^{d \times d_k}$ 为可训练投影矩阵。

比例点积注意力计算公式为

$$\text{Attention}(Q, K, V)_j = \text{softmax}\left(\frac{Q_j K_j^T}{\sqrt{d_k}}\right) V_j \quad (4)$$

为了共同关注来自不同位置的子空间信息,需要进一步优化,采用 $H$ 个并行注意力计算,在 $W^A \in R^{H(d_k \times d)}$ 情况下,多头注意力机制的计算公式为

$$\text{MultiHead}(Q, K, V) = \text{Concat}\left(\left\{\text{head}_j\right\}_{j=1}^H\right) W^A \quad (5)$$

### 1.2 MobileVit 模块

MobileVit 是一种基于转换器的轻量级视觉转换器模型,用于移动设备上的计算机视觉任务。MobileVit 模块是 MobileVit 模型的基本组成单元,如图 2 所示,MobileVit 模块由 3 个子模块组成,分别为局部信息编码模块、全局信息编码模块和特征融合模块。局部信息编码模块的作用是提取局部特征信息,通过一个卷积核大小为  $3 \times 3$  的卷积层完成。全局信息编码模块能够提取全局特征信息,通过展开、Transformer 和折叠结构来完成,其中,展开是将输入的特征图划分为一个个的小块,并将其展开成 1 个二维矩阵,以便于在 Transformer 编码器中处理。特征融合模块是对前 2 个模块的特征信息进行融合,将捷径分支与原始输入特征图沿通道方向拼接,通过一个卷积核大小为  $3 \times 3$  的卷积层进行特征融合,得到在较少参数的情况下充分提取图像的特征信息。

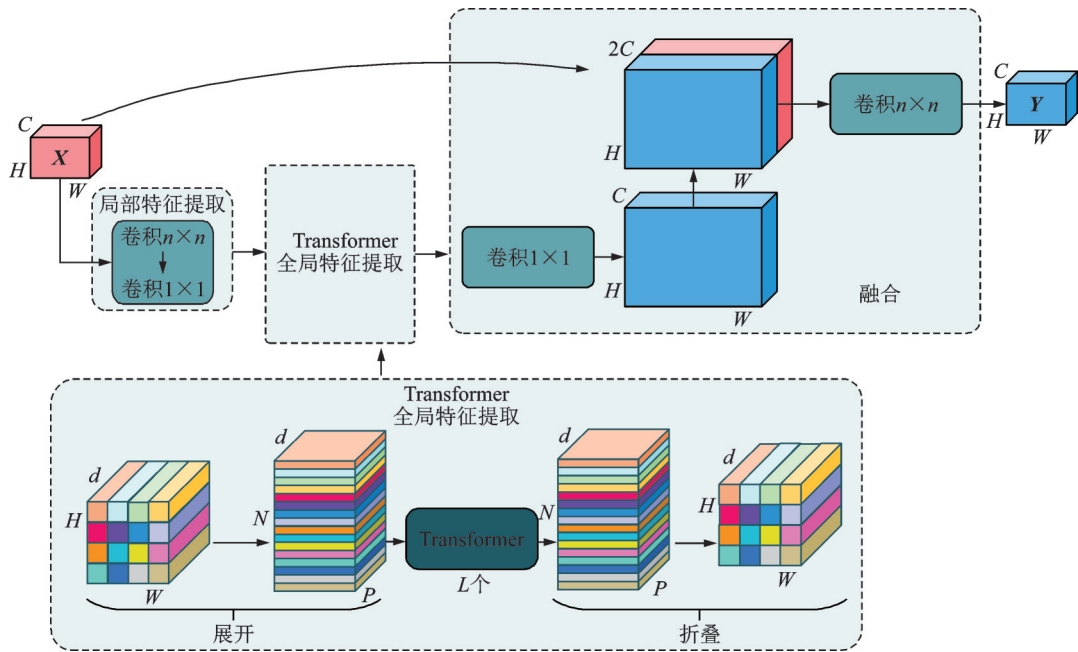


图 2 MobileViT 模块

Fig.2 MobileViT block

### 1.3 Shuffle 模块

ShuffleNet 是一种轻量级卷积神经网络结构,主要针对移动端设备和嵌入式设备的计算资源有限场景,以及在计算资源受限的情况下需要高效训练模型的场景。ShuffleNet 引入了 Shuffle 模块的卷积块结构,可以在保持准确性的同时,大大减少模型的计算复杂度。如图 3 所示,Shuffle 模块主要有 2 部分组成:逐点卷积层和通道重排层。

逐点卷积层是指卷积核的大小为  $1 \times 1$ ,可有效降低卷积层的计算量,只需对输入特征图的每个通道进行线性组合,从而得到输出特征图的每个通

道。逐点卷积层还可以用来增加通道的数量,将输入特征图的每个通道与一组可学习的卷积核相乘,将乘积相加得到新的通道。

通道重排层是将输入特征图的通道重排为不同的组,目的是为了在逐点卷积层前引入组卷积,从而将计算量分摊到不同的组上。通道重排层先将输入特征图的通道分为若干组,然后将每个组中的通道重新排列,最后将所有组中的通道连接起来,得到新的输出特征图。通道重排层的操作表示为

$$\text{channel shuffle}(x) = \text{concat}(\text{shuffle}(x^1), \text{shuffle}(x^2), \dots, \text{shuffle}(x^G)) \quad (6)$$




图 3 Shuffle 模块

Fig.3 Shuffle block

### 1.4 Grad-CAM

Grad-CAM 是一种深度学习网络技术,通过生成梯度加权的类激活映射图,在执行检测、分类和预测等任务时,能够提供更丰富的特征提取,有助于解释卷积神经网络的信息。笔者将 Grad-CAM 技术用于轨道扣件故障诊断研究。由于只对真实样本图

片进行语义标注,没有进行位置标注,所以需要通过 Grad-CAM 生成的加权类激活映射图来观察训练好的模型是否提取到样本扣件的特征,避免造成模型过拟合,且突显扣件的重要区域,可使故障检测过程更加可视化。Grad-CAM 模块如图 4 所示。通过计算扣件特征图中像素对故障分类概率的梯度,可以表示特征图对检测结果的影响程度。




图 4 Grad-CAM 模块  
Fig.4 Grad-CAM block

Grad-CAM 模块通过反向传播算法输出模型最后一层卷积目标类别的梯度,对于每个空间位置计算所有通道梯度权重的平均值,使用这些平均权重,将每个卷积层通道的特征图加权平均,得到加权特征图。再将其进行逐通道的线性组合,得到一个梯度加权类激活映射图,用来表示空间位置对于特定类别预测起到了关键作用。最后求加权和,进行上采样叠加到原图像上,计算公式为

$$\alpha_k^c = \frac{1}{Z} \sum_l \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (7)$$

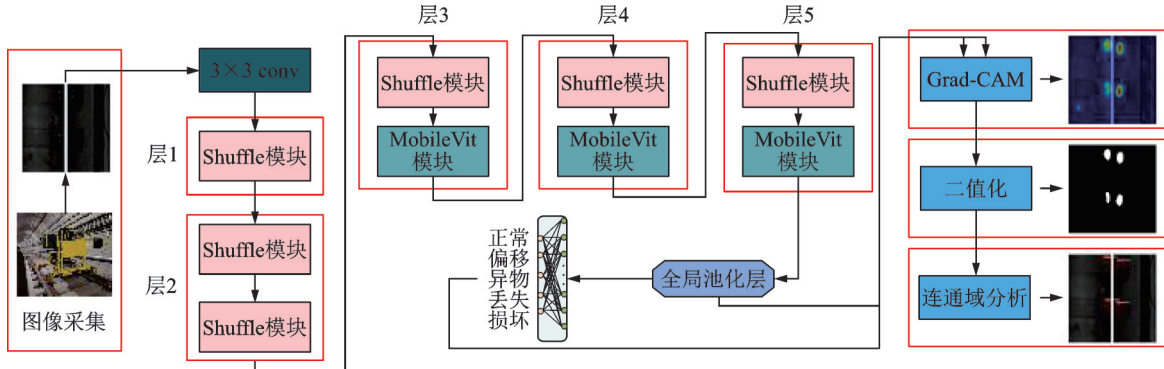


图 5 模型总结构  
Fig.5 The structure of the model

表 1 模型参数  
Tab.1 Model parameters

层数	输出通道数	特征图通道数	中间层序列长度	尺寸	多头注意力个数
1	16	—	—	—	—
2	24	—	—	—	—
3	48	64	128	2×2	4
4	64	80	160	2×2	4
5	80	96	192	2×2	4

## 2 实验验证

### 2.1 数据采集

数据采集设备如图 6 所示。该设备可适应正常

$$L_{\text{Grad-CAM}}^c = \text{ReLU} \left( \sum_k \alpha_k^c A^k \right) \quad (8)$$

其中: $y^c$ 为对于类别  $c$  的权重; $Z$ 为特征图的个数; $A_{ij}^k$ 为特征图  $k$  中坐标  $(i, j)$  的像素值; $\alpha_k^c$ 为特征图  $k$  对于类别  $c$  的神经元重要性权重; $A^k$ 为特征图  $k$  的激活值。

为了得到对检测结果产生正影响的像素,使用 ReLU 函数对结果进行单侧抑制,得到的结果为 1 个二维特征图,即输入图像的类激活映射图。

### 1.5 模型总结构

图 5 为模型总结构。轨道扣件图片通过数据采集设备获取并送入模型中,模型参数如表 1 所示。首先,将模型最后一层特征输入 Grad-CAM 模块生成热力图,并将热力图结果进行数值分析得到 1 个阈值;然后,将大于阈值的区域设置为 1,小于阈值的区域设置为 0,得到 1 个基本的灰度图;最后,对灰度图进行连通域分析,生成检测框图和标签。



图 6 数据采集设备  
Fig.6 Data acquisition equipment

轨距的轨道数据采集,通过在采集设备上安装电荷耦合器件线阵相机进行图像采集,采集的图像视野包括两侧的导轨和紧固件。对图像进行预处理,提取扣件区域,建立扣件特征描述。

本次实验数据为北京某铁路运营线轨道扣件图片,扣件故障分为正常、偏移、异物、丢失和损坏。图7为一组真实的数据样本。



图7 真实数据样本  
Fig.7 Real samples

## 2.2 数据处理

针对轨道扣件数据正常样本多、故障样本少的特点,为解决数据不平衡问题和防止训练时神经网络过拟合,笔者采用数据增强的方法,从有限的数据中生成更多样本,增加训练样本的数量和多样性,从而提升模型的鲁棒性。神经网络需要大量参数,而使这些参数正确工作则需要大量的数据进行训练。通过随机改变训练样本,可以减少模型对某些属性的依赖,从而提高模型的泛化能力。

数据增强可分为离线增强和在线增强2类。笔者采用离线增强,即在训练前直接对数据集进行处理。通过对图像进行不同方式的裁剪和平移,让轨道扣件出现在采集图像的不同位置,从而降低模型对目标位置的敏感性。同时,加入高斯噪声和脉冲噪声,提升模型的抗干扰能力。此外,调整亮度和对比度等属性来降低模型对这些因素的敏感度。增强方法及示例如表2所示。

表2 增强方法及示例

Tab.2 Augmentation methods and examples

增强方法	示例
平移裁剪	
镜像旋转	
噪声	
对比度亮度	

在对原始图像预处理过程中,经过以上4种数据增强方式扩充数据集,将原始975张图片扩充至3900张,并降低了位置、噪声和亮度等因素的干扰,在一定程度上避免模型过拟合。

## 2.3 实验过程

实验用计算机的硬件配置为AMD R7-3700X,32G RAM和RTX3070。深度学习网络框架由Pytorch开发,编程语言为Python3.8。在训练期间,为了平衡内存使用量和训练速度,批大小设置为64,学习率设置为0.01,优化器的动量值为0.9,权重衰减为0.0004,训练的迭代轮次为300。软件TensorBoard用于监控训练过程,并将训练后的评估指标导出,用软件Matlab2021a和Origin Pro2021将数据可视化。共有2600张轨道扣件图片用于训练,650张扣件图片用于验证,650张随机图像用于测试。

在实验过程中,选择模型的准确率、召回率、特异度和模型大小作为评价指标,前3者的计算公式分别为

$$A_{\text{accuracy}} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (9)$$

$$R_{\text{recall}} = \frac{T_P}{T_P + F_N} \quad (10)$$

$$S_{\text{specificity}} = \frac{T_N}{T_N + F_P} \quad (11)$$

其中: $T_P$ 为分类器能准确识别出的正确数量; $F_P$ 为误报的负样本数量; $T_N$ 为分类器预测错误样本被正确识别的数量; $F_N$ 为分类器漏报的正确样本数量。

图8,9分别为笔者提出方法与MobileVit模型训练时的准确率和损失值对比。可见,改进后的模型在训练时收敛速度更快、更稳定。图10为混淆矩阵对比。模型性能指标如表3所示。可见,改进后模型的准确率提高了1.23%,召回率提高了1.84%,特异度提高了0.28%。经验证,笔者提出方法的网络改进性能是有效可靠的。




图8 准确率对比

Fig.8 Accuracy comparison

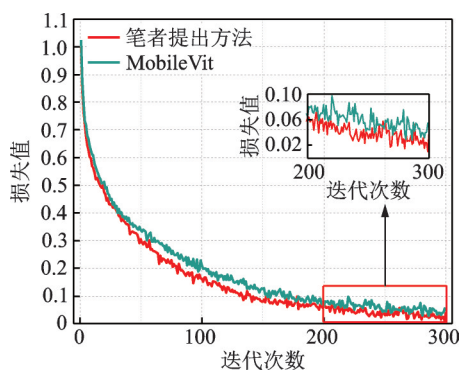




图9 损失值对比

Fig.9 Loss comparison



(a) 笔者提出方法混淆矩阵

(a) Confusion matrix of proposing method



(b) MobileVit混淆矩阵

(b) Confusion matrix of MobileVit

图10 混淆矩阵对比

Fig.10 Confusion matrix comparison

表3 模型性能指标

Tab.3 Performance metrics for the model %

模型	准确率	召回率	特异度
笔者提出方法	94.31	94.27	98.58
MobileVit	93.08	92.43	98.30

为了验证提出方法在准确性和模型大小方面的优势,笔者对故障诊断和图像分类方面性能良好的模型进行对比,包括广泛用于图像分类的深度学习模型,如 GoogleNet, VggNet16, ResNet 和 Efficient-Net,以及经典的轻量级模型 MobileNet v3。图 11

为各模型训练准确率对比。图 12 为对比模型混淆矩阵。各模型性能指标如表 4 所示。可见,改进后的模型不仅在准确率上有优势,在模型体积上也更






图11 各模型训练准确率对比

Fig.11 Accuracy comparison




(a) GoogleNet混淆矩阵

(a) Confusion matrix of GoogleNet



(b) VggNet16混淆矩阵

(b) Confusion matrix of VggNet16



(c) ResNet混淆矩阵

(c) Confusion matrix of ResNet

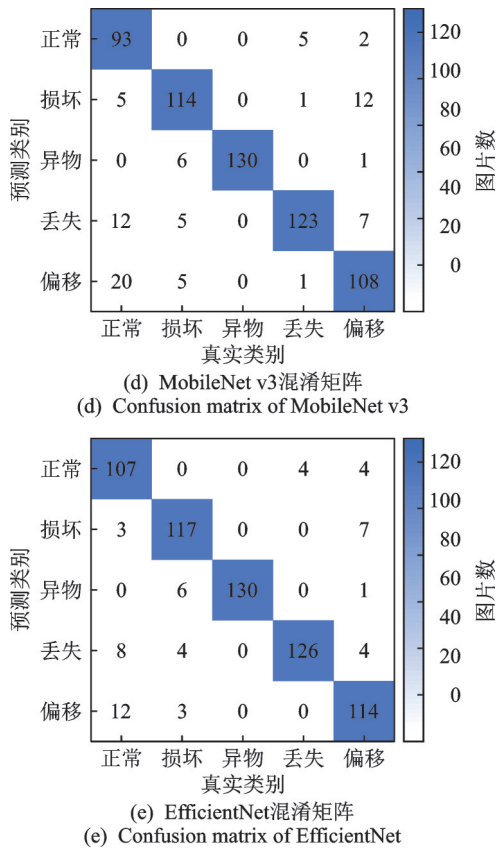


图 12 对比模型混淆矩阵

表 4 模型性能指标  
Tab.4 Performance metrics for the model

模型	准确率/ %	召回率/ %	特异度/ %	容量/ MB
笔者提出方法	94.31	94.40	98.58	3.75
GoogleNet	89.08	89.04	97.30	39.41
VggNet16	90.62	90.70	97.69	512.25
ResNet	91.08	91.17	97.80	85.29
MobileNet v3	87.38	87.70	96.91	16.25
EfficientNet	91.38	91.43	97.87	15.60

为小巧。这是因为模型中的 Transformer 和 Shuffle 模块发挥了重要作用,Transformer 编码层能够提供具有注意力的数据,Shuffle 模块可以让通道间的信息进行交互,减少无用特征对模型的影响。

### 2.4 检测效果

图 13 为模型检测效果,图中红色部分为模型关注的重点区域,其特征权重占比较大。可以发现,对于实际的铁轨图片,模型能关注到扣件区域,并通过二值化后对连通区域进行分析,能正确绘制出检测框图,证明了该方法的有效性。




图 13 模型检测效果

Fig.13 The effect of model detection

## 3 结 论

1) 基于常规深度学习模型数据标注复杂及模型大等问题,笔者提出了一种高效的轻量化深度学习模型。实验表明,该模型具有较高的准确率和体积小优势,具有一定的研究价值。

2) 热力图展示了模型所关注的重点区域都集中在扣件区间内,对检测的扣件生成检测框图,可用于真实铁路环境工况下的扣件故障检测。

3) 针对检测模型训练数据标记费时费力的问题,本研究方法的训练数据仅需做简单的语义标记即可通过模型生成位置检测图。改进的轻量化 Transformer 模型对现场设备要求低,同时让模型的关注点集中在扣件区间内,通过 Grad-CAM 生成热力图进行验证,有助于增强深度学习模型的可读性和可靠性。该方法适用于对不同形态的铁路扣件进行快速检测,具备一定的实用价值。

## 参 考 文 献

[1] CHELLASWAMY C, KRISHNASAMY M, BALAJI L, et al. Optimized railway track health monitoring system based on dynamic differential evolution algorithm [J]. Measurement, 2020, 152: 107332.

[2] PENG Z, WANG C, MA Z, et al. A multifeature hierarchical locating algorithm for hexagon nut of railway fasteners [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(3): 693-699.

- [3] PAN Z, MENG Z, CHEN Z, et al. A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings[J]. *Mechanical Systems and Signal Processing*, 2020, 144: 106899.
- [4] QUIÑONES-GRUEIRO M, PRIETO-MORENO A, VERDE C, et al. Data-driven monitoring of multimode continuous processes: a review[J]. *Chemometrics and Intelligent Laboratory Systems*, 2019, 189: 56-71.
- [5] 陈宗平, 成功, 刘清源, 等. 高速铁路扣件动刚度频变和温变特性研究[J]. *振动、测试与诊断*, 2022, 42(3): 495-502.  
CHEN Zongping, CHENG Gong, LIU Qingyuan, et al. Study on dynamic stiffness frequency variation and temperature variation characteristics of fasteners of high-speed railway fasteners[J]. *Journal of Vibration, Measurement & Diagnostics*, 2022, 42(3): 495-502. (in Chinese)
- [6] 邵海东, 陈星恺, 曹鸿儒, 等. 内对抗指导无监督多域适配网络的轴承协同故障诊断[J]. *中国科学: 技术科学*, 2023, 53(7): 1229-1240.  
SHAO Haidong, CHEN Xingkai, CAO Hongru, et al. Cooperative fault diagnosis of bearings in unsupervised multi-domain adaptation network guided by internal countermeasures[J]. *Science China: Technological Sciences*, 2023, 53(7): 1229-1240. (in Chinese)
- [7] LI X, SHAO H, LU S, et al. Highly efficient fault diagnosis of rotating machinery under time-varying speeds using LSISMM and small infrared thermal images[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, 52(12): 7328-7340.
- [8] HE Z, SHAO H, JING L, et al. Transfer fault diagnosis of bearing installed in different machines using enhanced deep auto-encoder[J]. *Measurement*, 2020, 152: 107393.
- [9] JING G, QIN X, WANG H, et al. Developments, challenges, and perspectives of railway inspection robots [J]. *Automation in Construction*, 2022, 138: 104242.
- [10] 邵海东, 肖一鸣, 颜深. 仿真数据驱动的改进无监督域适应轴承故障诊断[J]. *机械工程学报*, 2023, 59(3): 76-85.  
SHAO Haidong, XIAO Yiming, YAN Shen. Simulation data-driven improvement unsupervised domain adaptation bearing fault diagnosis[J]. *Journal of Mechanical Engineering*, 2023, 59(3): 76-85. (in Chinese)
- [11] LIU J, TENG Y, SHI B, et al. A hierarchical learning approach for railway fastener detection using imbalanced samples[J]. *Measurement*, 2021, 186: 110240.
- [12] WU Y, QIN Y, WANG Z, et al. Densely pyramidal residual network for UAV-based railway images dehazing[J]. *Neurocomputing*, 2020, 371: 124-136.
- [13] ARSHAD S, SHAHZAD M, RIAZ Q, et al. Deep 3D point based residual network for semantic segmentation and classification of 3d point clouds[J]. *IEEE Access*, 2019, 7: 68892-68904.
- [14] WU Y, QIN Y, QIAN Y, et al. Automatic detection of arbitrarily oriented fastener defect in high-speed railway [J]. *Automation in Construction*, 2021, 131: 103913.
- [15] CHENG M Y, KHASANI R R, SETIONO K. Image quality enhancement using hybrid GAN for automated railway track defect recognition [J]. *Automation in Construction*, 2023, 146: 104669.
- [16] YAO D, SUN Q, YANG J, et al. Railway fastener fault diagnosis based on generative adversarial network and residual network model[J]. *Shock and Vibration*, 2020, 2020: 1-15.
- [17] BAI T, YANG J, XU G, et al. An optimized railway fastener detection method based on modified faster R-CNN[J]. *Measurement*, 2021, 182: 109742.
- [18] CAO Y, CHEN Z, WEN T, et al. Rail fastener detection of heavy railway based on deep learning[J]. *High-Speed Railway*, 2023, 1(1): 63-69.
- [19] 吴送英, 刘林芽, 张洪, 等. 基于迁移学习的铁路扣件缺陷形态检测算法研究[J]. *铁道科学与工程学报*, 2022, 19(12): 3612-3624.  
WU Songying, LIU Linya, ZHANG Hong, et al. Research on defect morphology of railway fasteners based on transfer learning [J]. *Journal of Railway Science & Engineering*, 2022, 19(12): 3612-3624. (in Chinese)



**第一作者简介:**姚德臣,男,1984年1月生,博士、教授。主要研究方向为机械设备状态监测与故障诊断、机械寿命预测。曾发表《Remaining useful life prediction of roller bearings based on improved 1D-CNN and simple recurrent unit》(《Measurement》2021, Vol. 175)等论文。

E-mail: yaodechen@bucea.edu.cn