

# 基于深度学习的铁路货车关键零部件故障图像检测算法研究

赖陟斌, 史红梅\*

(北京交通大学轨道交通智能检测技术研究所, 北京 100091)

**摘要:**铁路货车零部件故障是造成货车事故的主要原因之一,当前列检工作多采用“人眼识图”判断零部件故障,无法实现故障自动识别。针对关键零部件故障自动识别的问题,根据“先定位,后识别”的思路提出基于深度学习和图像处理技术结合的图像检测算法。首先,构建零部件检测数据集和零部件故障识别数据集。其次,融合小目标检测层、卷积注意力模块,提出改进的 Small-Target-Detect-Layer and CBAM YOLOv5s(SC-YOLOv5s),实现多尺度关键零部件的定位、分类、裁剪。最后,提出基于目标检测结果与先验知识的算法直接判断丢失类型故障,改进的 MobileNetV3 分类算法实现滚动轴承甩油、锁紧板松动、摇枕弹簧断裂三种故障的自动识别,以及图像处理实现交叉杆弯曲、滚动轴承前盖破损两种故障的自动识别。结果表明,SC-YOLOv5s 算法的 mAP@0.5 和 mAP@0.5:0.95 分别可达 99.3%、74.9%,检测速度可达 36.09FPS;改进的 MobileNetV3 算法对轴承甩油、锁紧板松动、摇枕弹簧断裂的识别准确率分别可达 98.63%、99.34%、90.21%;图像处理法对交叉杆弯曲、滚动轴承前盖破损识别准确率分别可达 95.32%、82.88%。

**关键词:**铁路货车;故障检测;目标检测

**DOI:**10.48014/fcmet.20231109001

**引用格式:**赖陟斌,史红梅. 基于深度学习的铁路货车关键零部件故障图像检测算法研究[J]. 中国机械工程学报,2024,3(1):11-22.

## 0 引言

随着我国重载铁路的发展,为保障铁路货车运行安全,在铁路沿线布置了多套货车运行故障动态图像检测系统(Trouble of moving freight car detection system, TFDS)采集货车零部件图像,对图像进行智能分析实现货车关键零部件故障检测。TFDS是一套集成计算机技术、图像采集技术、通信技术、模式识别技术的智能检测系统,同时也是铁路运输安全防范的“5T”系统之一<sup>[1,2]</sup>。然而,目前绝大多数 TFDS 仍然采用“人眼识图”的判断方式在车辆运行过程中对零部件进行故障检测,该方法需要耗费大量的人力物力、工作效率低且误报、漏

报现象时有发生<sup>[3,4]</sup>。因此,TFDS 迫切需要一种可以在降低列检工作人员工作量的同时提高 TFDS 工作效率和工作质量的智能化检测方法。

近年来,随着人工智能技术在零部件故障检测领域的发展,许多大学和研究机构的学者通过深度学习算法和图像处理技术来实现铁路货车关键零部件的定位、分类、故障检测等功能,并且取得了显著的成果。费垚东等<sup>[5]</sup>提出一种基于图像处理的螺栓故障自动识别算法,该方法先使用模板匹配技术和改进的自适应 LTP 算子提取螺栓子图的特征直方图,并利用支持向量机识别螺栓故障,但该方法用于其他零部件时需要重新设计模板图像。雷蕾等<sup>[6]</sup>提出一种基于 Hough 变换、Canny 边缘检测和

\* 通讯作者 Corresponding author: 史红梅, hms@bjtu.edu.cn

收稿日期:2023-11-09; 录用日期:2023-11-28; 发表日期:2024-03-28

形状模板相结合的锁紧板偏转故障检测算法,可以实现锁紧板偏转角度 $>5^\circ$ 的检测,但受图像内噪声边缘干扰该方法对图像质量要求极高、可靠性较差。此外,由于交叉杆边缘正常状态下为直线,其斜率为一个固定常数,而如果出现弯曲则斜率发生变化产生夹角<sup>[7]</sup>。北京航空航天大学团队<sup>[8]</sup>首次将深度学习算法引入 TFDS 故障自动识别中,提出一种基于卷积神经网络的 TFDS 多故障自动识别系统(Automatic fault recognition system,AFRS),但它只对两种典型故障进行识别,且算法步骤繁琐,通用性和实时性目前无法得到保证。李萍等<sup>[9]</sup>提出一种基于深度学习的列车关键零部件图像故障视觉检测算法,先利用区域建议网络(RPN 网络)生成感兴趣区域,再利用多尺度的故障检测网络实现零部件的定位和检测,但该算法只进行定位未进行进一步的故障检测。王苗等<sup>[10]</sup>提出一种基于 YOLOv4 的锁紧板松动故障检测算法,但由于将定位和故障识别集成在同一网络结构内导致识别准确率无法满足实际工程应用。符潇等<sup>[11]</sup>结合目标检测算法 Faster-RCNN 和注意力分割网络 APP-UNet16 的提出一种多阶段的轴承甩油故障检测方法,该方法检测精度较高但计算量较大无法满足

实时需求。目前已有的研究方法中无法在检测准确性、实时性、通用性、多样性等方面实现较好的平衡。

为进一步提高检测准确性、实时性等多方面性能,本文采用基于深度学习的目标检测算法、分类算法和传统图像处理技术相结合的方式提出了一种“先定位,后识别”的多阶段故障自动识别方法,实现多种关键零部件的故障自动识别。首先,本文构建了铁路场景中的零部件数据集。其次,设计了可以实现多尺度零部件定位和检测的 SC-YOLOv5s 算法,并根据待测零部件的故障特征和数据集规模分别设计了改进的 MobileNetV3 分类算法、传统图像处理技术法实现不同待测关键零部件,提高了列检工作的效率和质量,可以投入实际工程应用。

## 1 零部件故障自动识别算法整体方案

本文提出的基于深度学习和图像处理技术的关键零部件故障自动识别算法由三个部分组成:数据集构建模块、目标检测模块、故障识别分类模块,整体流程如图 1 所示。

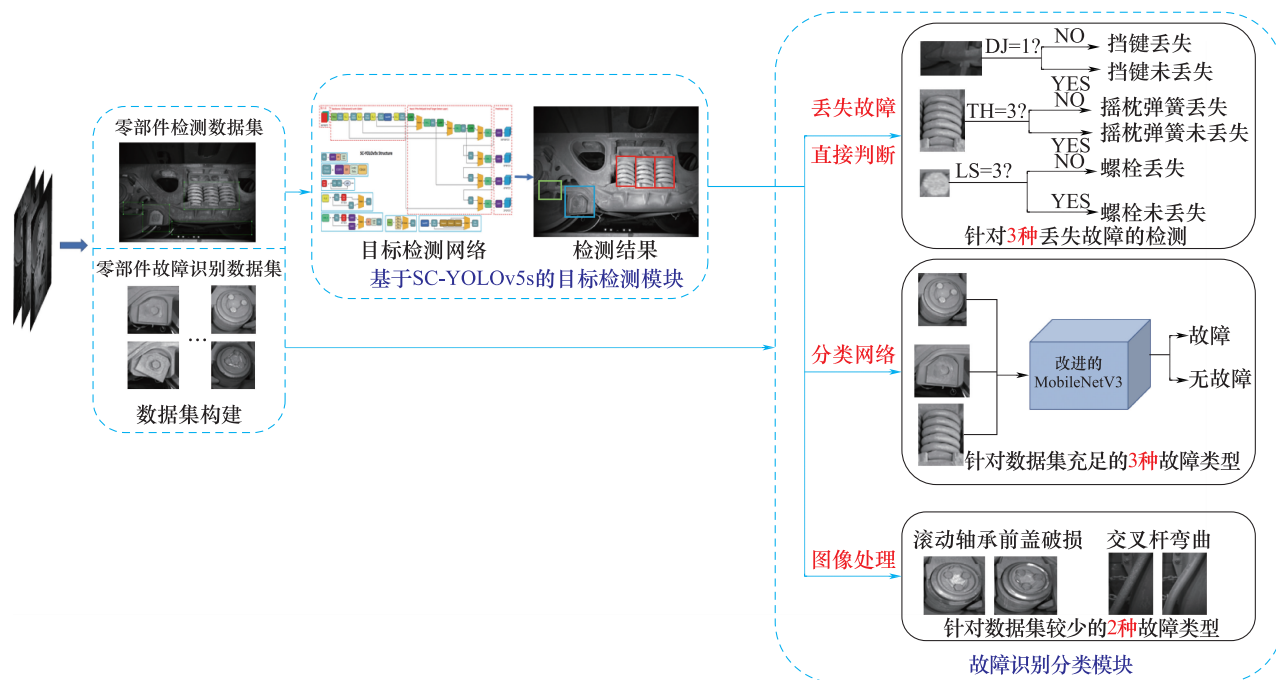


图 1 整体流程图

Fig. 1 Overall flowchart

首先,构建零部件检测数据集和零部件故障识别数据集。通过 TFDS 系统采集 C80 型重载货车的图像并进行手工标注的方式构建含 10572 张训练图像、1068 张测试图像的零部件检测数据集应用于目标检测模块的训练和测试,并且数据集内图像覆盖了晴天、阴天、雨雾、雪天等不同的天气条件和光照环境;采集各关键零部件故障图像并进行数据增强构建零部件故障识别数据集应用于故障识别分类模块训练和测试,数据集详情如表 1 所示。

表 1 零部件故障识别数据集样本数量表  
Table 1 Sample size table for component fault identification dataset

编号	图像类别	数量/张
1	滚动轴承甩油	15616
2	滚动轴承无故障	15616
3	锁紧板松动	13673
4	锁紧板无故障	13673
5	摇枕弹簧断裂	11070
6	摇枕弹簧无故障	11070
7	交叉杆弯曲	72
8	交叉杆无故障	16416
9	滚动轴承前盖破损	41
10	滚动轴承前盖无故障	1057

利用数据集训练算法模型,在实际使用中待测图像输入 SC-YOLOv5s 目标检测模块实现待测零部件的定位、分类和裁剪,得到滚动轴承、锁紧板、挡键、滚动轴承螺栓、摇枕弹簧、交叉杆 6 种待测零部件的子图像。其中,比较目标检测结果与先验知识可直接判断滚动轴承螺栓、挡键、摇枕弹簧是否丢失。然后,将各待测零部件子图像输入故障识别分类模块进一步判断是否发生故障,该模块根据零部件故障特征和数据集规模分别设计了基于改进 MobileNetV3 的识别网络和基于传统图像处理技术的识别方法。最后,融合各待测零部件的状态输出该输入图像的最终检测结果。

## 2 关键零部件检测算法设计

### 2.1 SC-YOLOv5s 算法设计

YOLO 是目标检测领域经典的 One-stage 算法<sup>[12]</sup>,其中 YOLOv5s 在精确度和速度两方面均具有较好的优势。在铁路场景中,由于 TFDS 采集图像质量较差、背景较暗等原因,并且存在如滚动轴承螺栓等小尺寸零部件,原始 YOLOv5s 容易出现误检、漏检等现象,如图 2 所示,三个滚动轴承螺栓漏检一个,锁紧板误检为滚动轴承。




图 2 原始 YOLOv5s 漏检、误检现象

Fig. 2 Phenomenon of original YOLOv5s leakage and false detection

为提高算法对小目标的检测能力和特征提取能力,本文通过增加小目标检测层和卷积注意力模块的方法(Convolutional Block Attention Module, CBAM)提出了改进的 Small-Target-Detect-Layer and CBAM YOLOv5s(SC-YOLOv5s)。

#### 2.1.1 小目标检测层

增加小目标检测层结构如图 3 所示,增加层的

特征图为特征提取网络第二次下采样的输出特征图,该特征图保留了更丰富的小目标特征信息,解决原始 YOLOv5s 由于下采样倍数过多导致的小目标特征消失问题。增加的小目标检测层融合 4 种不同尺度大小的特征图,进一步提高了低层语义信息和高层位置信息充分融合的能力,以此提高对小目标的检测能力。

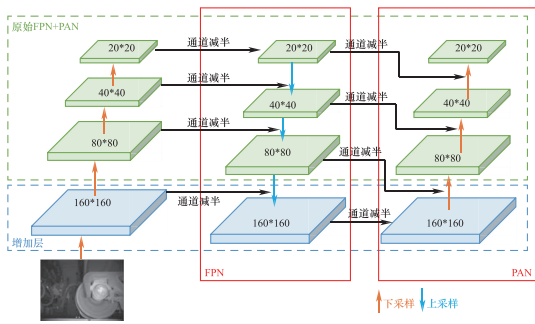


图 3 增加小目标检测层结构

Fig. 3 Structure of the added small target detection layer

2.1.2 CBAM 模块

CBAM 模块是一种典型的轻量级注意力机制模块,其结构如图 4 所示,由通道注意力模块和空间注意力模块串联组成,在通道维度和空间维度上自适应提取重要特征信息。




图 4 CBAM 模块结构图

Fig. 4 Structure of CBAM model

其中通道注意力模块动态选择,加强对输入特

征图内部包含重要信息通道的学习,对包含无关信息通道进行抑制,输出一维通道注意力特征后与原输入特征图相乘达到自适应修正目的;空间注意力模块则进一步加强网络模型在空间维度上加强对包含重要信息位置的学习,对包含无关信息的位置进行抑制。

SC-YOLOv5s 网络结构如图 5 所示,为提高网络模型的特征提取能力,将 CBAM 模块与原始基本组件 CBL 模块串联组成 ConvCBAM 模块,该模块可以在一次特征提取之后进行二次关键特征提取。

2.2 零部件检测算法实验结果与分析

本文在 Windows 平台和 Pytorch 框架下实现训练和测试, GPU 选用显存大小为 6GB 的 NVIDIA GeForce GTX1060, batch\_size 设置为 16。此外,在检测阶段,将待测图像输入“异物检测系统”,将无异物图像输入本文检测算法,且 SC-YOLOv5s 算法会对输入图像进行去噪、提升对比图等预处理以提高其成像质量。为进一步验证小目标检测层和 CBAM 模块对算法检测能力的提升,本文进行了对比实验和消融实验,实验结果如表 2 所示。

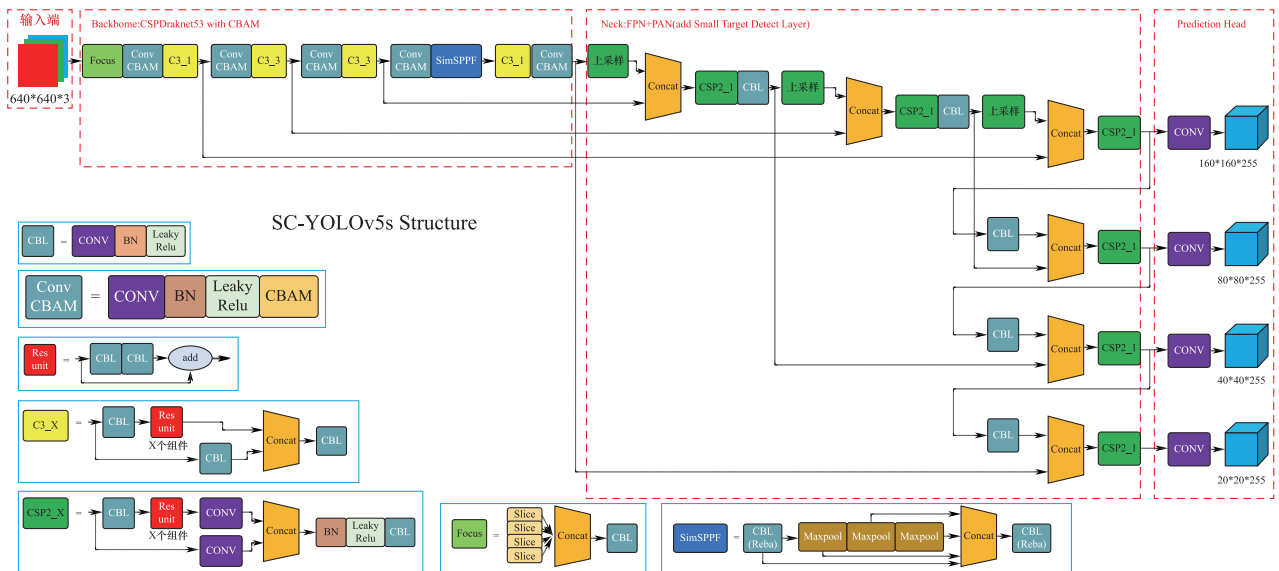


图 5 SC-YOLOv5s 网络结构图

Fig. 5 Structure of the SC-YOLOv5s network

表 2 改进前后 YOLOv5s 算法性能结果对比  
Table 2 Comparison of performance results of YOLOv5s algorithm before and after improvement

网络模型	小目标检测层	CBAM	mAP @0.5	mAP @0.5:0.95	FPS
YOLOV5S			97.2%	63.6%	49.25
SC-YOLOV5S	✓		98.8%	72.9%	42.60
		✓	98.7%	72.2%	47.84
	✓	✓	99.3%	75.2%	36.09

从实验结果中可见小目标检测层与 CBAM 模块的添加均能提高模型的检测能力,改进后的 SC-YOLOv5s 的 mAP@0.5 与 mAP@0.5:0.95 比原始 YOLOv5s 分别提高了 2.1% 和 11.3%。为进一步验证 SC-YOLOv5s 对小目标检测能力的提升,本文统计了改进前后算法对各待测零部件的结果,如表 3 所示。

表 3 改进前后算法对各待测目标 AP 对比  
Table 3 Comparison of the AP of the algorithm before and after improvement for each target to be measured

待测零部件类别	YOLOv5s	SC-YOLOv5s
滚动轴承	98.9%	98.9%
挡键	92.1%	99.6%
锁紧板	99.9%	99.0%
摇枕弹簧	99.7%	99.5%
交叉杆	99.6%	99.4%
滚动轴承螺栓	93.0%	99.6%

其中滚动轴承螺栓和挡键的 AP 值分别提高了 7.5% 和 6.6%,同时保持了大尺寸零部件的检测准确率,并且准确裁剪出各待测零部件的子图像,可见改进后的 SC-YOLOv5s 算法有效提升了多尺度目标的检测能力。此外,比较零部件检测算法结果与先验知识理论数量,在测试集中准确识别出 1 处滚动轴承螺栓漏检、11 处挡键漏检,且误检率为 0,可以准确实现丢失类型故障识别。

### 3 关键零部件故障类型分析

对比零部件检测算法裁剪所得各零部件子图像,如图 6 所示,滚动轴承甩油故障特征表现为四周出现颜色较暗的油渍、锁紧板松动出现明显旋转、摇枕弹簧断裂其上端表现出明显断痕,且这三类故

障类型数据集充足,适合卷积神经网络自动提取和学习故障特征实现故障判断。

对于故障特征不适用于卷积神经网络自主提取和学习并且数据集规模较小的故障类型,本文选用基于图像处理技术的识别算法手动提取故障特征进行故障判断。如图 7 所示,滚动轴承前盖红色圆环内为故障区域,可见破损部位颜色泛白、亮度较高;交叉杆弯曲故障时表现为直线与曲线相连而非完整的直线。

## 4 改进 MobileNetV3 故障识别算法

### 4.1 改进 MobileNetV3 算法设计

以肃宁北站为例平均过车时间为 14 分钟、最短过车时间仅为 6 分钟,单趟列车最多采集 15000 张图像需进行故障判别,且单张图像将产生多张待判断子图像,因此识别算法对实时性要求较高。MobileNetV3<sup>[16]</sup>是轻量型的卷积神经网络,具有检测速度较快的特点,很好地平衡了准确性和实时性的需求。由于轻量化的设置导致 MobileNetV3 与传统大型卷积神经网络相比识别准确率略有下降,为进一步提高其识别准确率,本文对其基本单元、连接结构、分类器进行优化提出了改进的 MobileNetV3 算法。

原始 MobileNetV3 基本单元保留 MobileNetV2 中的深度可分离卷积和倒残差连接结构<sup>[17]</sup>,并借鉴 SENet 的思想集成了 SE 自注意力机制模块,但该模块只关注了通道维度的重要性,忽略了空间维度位置信息的重要性。因此,与 SC-YOLOV5s 相同利用兼顾通道维度和空间维度特征重要性的 CBAM 模块代替 SE 模块,提高网络模型对故障特征的提取能力。

倒残差连接结构可以加深网络模型,同时避免网络退化等现象,但其仅适用于基本单元输入和输出特征图维度大小完全一致的情况。为提高倒残差连接方式的适用性,本文针对性地提出了另外三种改进的连接结构,保证基本单元输入和输出特征图大小一致,三种连接结构如图 8 所示。Residual connection\_1 为原始倒残差连接结构;Residual connection\_2 在连接通道使用平均池化层和 Point-




图 6 甩油、锁紧板故障、摇枕弹簧断裂

Fig. 6 Oil dumping, locking plate failure, broken rocker spring




图 7 滚动轴承前盖破损与交叉杆弯曲

Fig. 7 Schematic diagram of a broken rolling bearing front cover with a bent cross bar

Wise 卷积(PW 卷积)压缩输入特征图空间维度大小、扩充通道数目;Residual connection\_3 则单独利用 PW 卷积扩充通道数目;Residual connection\_4

单独利用平均池化层压缩空间维度大小。

此外,原始 MobileNetV3 的分类器是针对 ImageNet 数据集进行设计,该数据集中存在 1000 个不

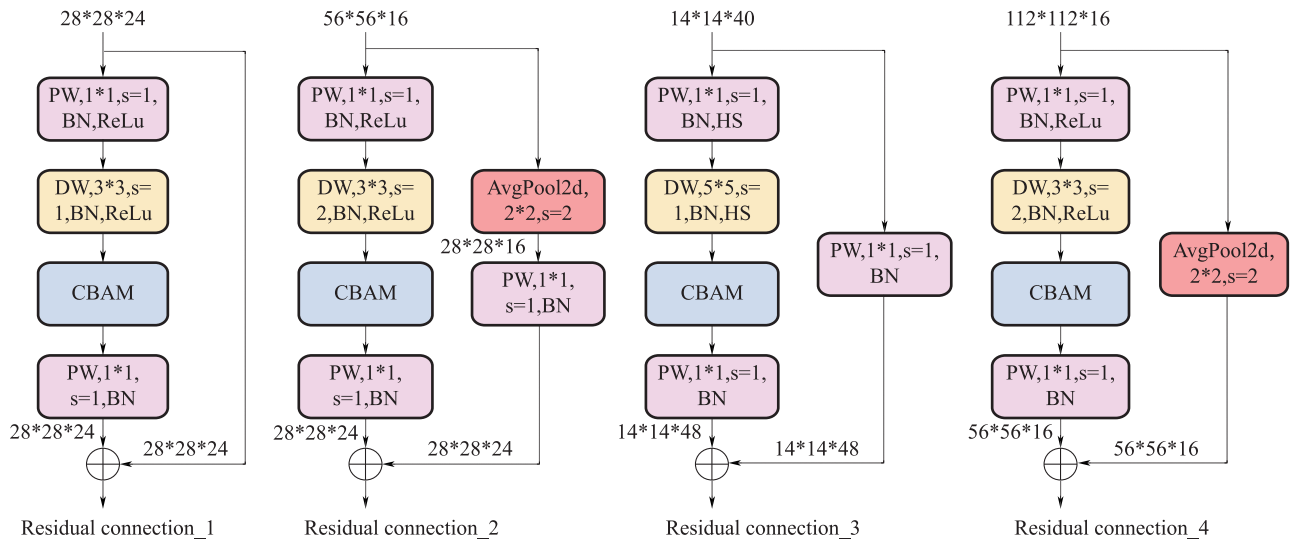


图 8 倒残差连接结构

Fig. 8 Structure of the inverted residual link

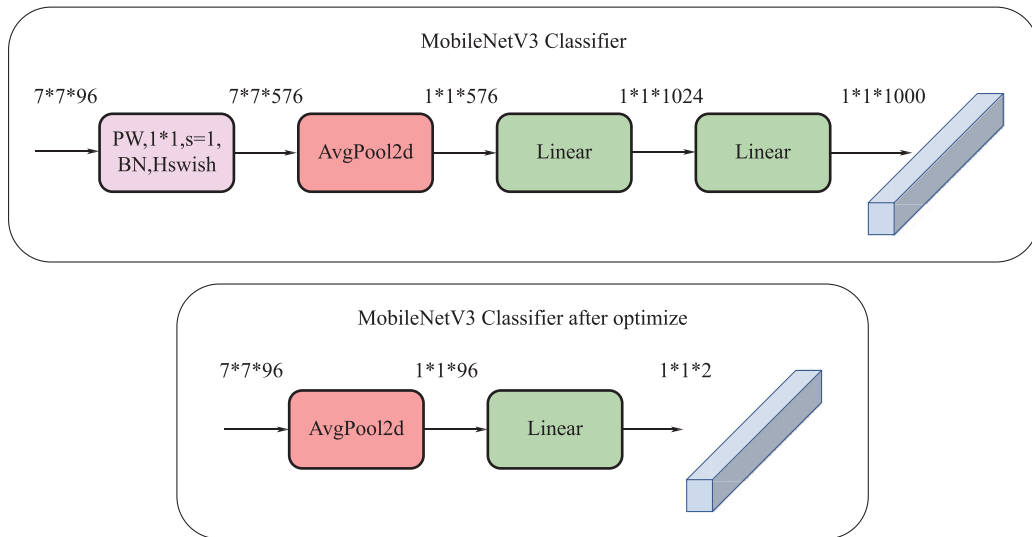


图 9 分类器结构图

Fig. 9 Structure of the classifier

同类别物体,因此要求分类器复杂度较高从而导致计算量较大。本文故障识别算法仅需针对各类零部件二分类识别是否故障,因此简化分类器可以在保证识别准确率的同时提高检测速度,弥补改进基本单元和倒残差连接结构带来的额外计算量,简化前后分类器结构如图 9 所示。简化分类器去除原分类器繁琐的升维操作,仅通过一个平均池化层和一个全连接层串联将特征向量映射为分类标签。

最终,改进 MobileNetV3 结构如图 10 所示,其

由 11 个基本单元通过四种不同残差连接结构以及简化分类器串联组成。

## 4.2 改进 MobileNetV3s 实验结果分析

故障识别算法实验平台与零部件检测算法一致,其中 batch\_size 设置为 64。为验证改进 MobileNetV3 的综合性能,将其与原始 MobileNetV3 和传统经典大型卷积神经网络 VGG16 进行对比实验,实验结果如表 4 所示。

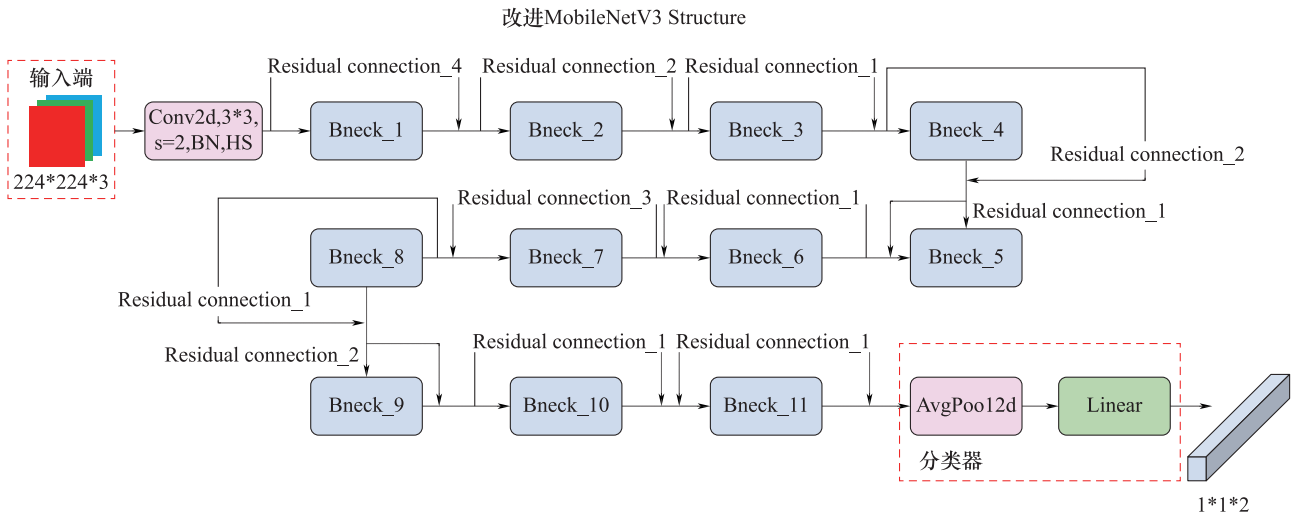


图 10 改进 MobileNetV3 网络结构

Fig. 10 Structure of the improved MobileNetV3 network

表 4 改进 MobileNetV3 算法实验结果  
Table 4 Experimental results of the improved MobileNetV3 algorithm

网络模型	故障类型	准确率	FPS
VGG16	滚动轴承甩油	97.65%	48.8
	锁紧板松动	99.83%	
	摇枕弹簧断裂	93.19%	
MOBILENETV3	滚动轴承甩油	98.94%	87.7
	锁紧板松动	99.15%	
	摇枕弹簧断裂	82.71%	
改进 MOBILENETV3	滚动轴承甩油	98.63%	57.1
	锁紧板松动	99.34%	
	摇枕弹簧断裂	90.21%	

后 MobileNetV3 识别准确率差距较小,但对于摇枕弹簧断裂而言,改进后的 MobileNetV3 识别准确率提高 7.50%,且其识别速度比 VGG16 高 8.3FPS。可见,改进后的 MobileNetV3 提高了关键零部件故障识别的准确率和速度之间的平衡。

## 5 基于图像处理技术的故障识别算法

### 5.1 滚动轴承前盖破损故障识别算法设计

滚动轴承前盖破损故障识别只需关注故障易发区域,识别算法流程如图 11 所示。首先,实现易发区域定位,其次对该区域进行二值化处理,最后统计白色像素个数判断是否发生破损故障。

对于滚动轴承甩油、锁紧板松动而言,改进前




图 11 滚动轴承前盖破损故障识别流程

Fig. 11 Recognition process for rolling bearing front cover breakage faults

在圆环区域定位阶段,利用三个滚动轴承螺栓组成三角形并确定其外接圆圆心,如图 12 所示,外接圆圆心 O 即为圆环区域圆心。通过多次实验设置圆环内圆半径为 67 像素,外圆半径为 92 像素。

其次,选用全局阈值法对圆环区域进行二值化处理,最后遍历图像统计白色像素个数,若大于 50 则判定为破损故障。

本文采用上述算法对测试集共 1098 张图像进



行检测,检测结果如表 5 所示。




图 12 圆环区域圆心示意图

Fig. 12 Schematic diagram of the center of the circular area

表 5 滚动轴承前盖破损故障实验结果  
Table 5 Experimental results of rolling bearing front cover breakage faults

图片类型	无故障/张	破损故障/张
预测无故障/张	831	17
预测破损故障/张	171	79

滚动轴承前盖破损故障识别准确率可达 82.88%,误报率为 17.07%,漏报率为 17.71%,单





图 13 交叉杆弯曲故障识别流程

Fig. 13 Recognition process for crossbar bend failure



(a)正常交叉杆 (a)Normal cross bar  
(b)交叉杆弯曲 (b)Cross bar bending

图 14 交叉杆直线检测结果

Fig. 14 Detection results of crossbar straight lines

张滚动轴承图片检测时间为 109ms,检测速度为 9.1FPS。

## 5.2 交叉杆弯曲故障识别算法设计

交叉杆发生弯曲时其轮廓最长直线段的长度与无弯曲故障相比较短,且弯曲故障多发于中间区段,因此通过提取并检测交叉杆边缘最长直线段长度是否大于指定阈值,即可判断其是否发生弯曲故障。交叉杆弯曲故障识别算法流程如图 13 所示。

首先,为更好提出交叉杆边缘,对输入图像进行直方图均衡化增强交叉杆与背景对比度,突出交叉杆直线边缘;其次,利用 Canny 边缘检测法剔除干扰线段并提高对交叉杆感兴趣区域的边缘信息的关注;最后,利用 Hough 直线检测法提取交叉杆边缘最长直线。当提取最长直线长度小于输入图像高度 2/3 时则判定为弯曲故障,正常交叉杆与弯曲交叉杆直线检测如图 14 所示。

本文采用该方法对测试集中共 16449 张图片进行测试,检测结果如表 6 所示。

表 6 交叉杆弯曲故障实验结果  
Table 6 Experimental results for crossbar bending faults

图片类型	无故障/张	弯曲故障/张
预测无故障/张	15647	0
预测弯曲故障/张	769	33

交叉杆弯曲故障识别准确率为 95.32%,误报率为 4.69%,漏报率为 0%,单张交叉杆图像检测时间为 47.7ms,检测速度为 21.28FPS。

## 6 结论

(1) 本文设计零部件故障自动识别算法整体方案,采集并标注 TFDS 图像,构建零部件检测数据集和零部件故障识别数据集。

(2) 融合小目标检测层和 CBAM 模块设计基于 SC-YOLOv5s 的目标检测模块。结果表明,改进的 SC-YOLOv5s 算法提高了对多尺度关键零部件的检测能力,针对性地解决了滚动轴承螺栓、挡键这类中小目标的漏检问题,直接实现丢失类型故障识别,且检测速度满足实际应用需求。

(3) 在实际应用中,需根据各零部件的故障特征及对应的数据集规模确定各零部件故障识别算法。改进 MobileNetV3 算法在故障识别准确率和检测速度之间取得较好的平衡,实现锁紧板松动、滚动轴承甩油、摇枕弹簧断裂三种故障的自动识别;利用目标检测结果、先验知识和二值化实现滚动轴承前盖破损故障识别;利用直方图均衡、Canny 边缘检测和 Hough 直线检测提取交叉杆边缘最长直线实现弯曲故障识别。算法实现对常见关键零部件的故障识别,可以满足实际工程应用。

本文设计的铁路货车关键零部件故障图像检测算法基本满足列检工作实际应用需求,但在未来的研究中仍需进一步提升。目前只针对列检工作中所列的几类关键零部件故障进行识别,可进一步提高算法通用性使其覆盖所有可能发生故障的零部件的检测识别,并且在保证算法精度的同时进一步提高检测速度,提高列检工作安全性和效率。

**利益冲突:**作者声明无利益冲突。

## 参考文献(References)

[1] 丁彦彬. 浅谈 TFDS 在货车运行安全管理中的应用[J]. 减速顶与调速技术, 2019(02): 23-25.  
<https://doi.org/10.3969/j.issn.1674-2427.2019.02.008>

[2] 曾广胜, 麦强. 提升 TFDS 发现故障功能的思考[J]. 铁道运营技术, 2020, 26(01): 35-38.  
<https://doi.org/10.13572/j.cnki.tdy.2020.01.011>

[3] 赵峰. 货车 TFDS 图像自动识别系统分析[J]. 智慧轨道

交通, 2022, 59(05): 49-52.  
<https://doi.org/10.3969/j.issn.2097-0366.2022.05.011>

[4] 李江昆. TFDS 车辆故障自动识别系统研究及应用[J]. 铁道车辆, 2021, 59(05): 125-127.  
<https://doi.org/10.3969/j.issn.1002-7602.2021.05.033>

[5] 费垚东, 李柏林, 范宏. TFDS 中螺栓故障的自动识别算法研究[J]. 机械设计与制造, 2021(10): 5.  
<https://doi.org/10.3969/j.issn.1001-3997.2021.10.021>

[6] 雷蕾, 宋冬利, 张卫华, 等. 基于 HCRD 的列车锁紧板偏转自动识别方法[J]. 铁道科学与工程学报, 2021, 18(07): 1895-1902.  
<https://doi.org/10.19713/j.cnki.43-1423/u.T20200854>

[7] 孙明. 基于图像处理的货车转向架故障检测[D]. 石家庄: 石家庄铁道大学, 2018.

[8] Sun J, Xiao Z, Xie Y. Automatic multi-fault recognition in TFDS based on convolutional neural network[J]. Neurocomputing, 2017, 222: 127-136.  
<https://doi.org/10.1016/j.neucom.2016.10.018>

[9] 李萍, 吴斌方, 刘默耘. 基于深度学习的铁路列车关键零部件图像故障检测[J]. 铁道科学与工程学报, 2019, 16(12): 3119-3125.  
<https://doi.org/10.19713/j.cnki.43-1423/u.2019.12.027>

[10] 王苗, 张龙信. 基于 YOLOv4 的列车锁紧板图像故障检测[J]. 现代信息科技, 2021, 5(20): 42-43, 49.  
<https://doi.org/10.19850/j.cnki.2096-4706.2021.20.012>

[11] 符潇. 基于 U-Net 的多阶段注意力感知列车图像识别与故障检测方法[D]. 长沙: 湖南大学, 2021.  
<https://doi.org/10.27135/d.cnki.ghudu.2020.001012>

[12] Redmon J, Divvala S, Girshick R, et al. You Only Look Once: Unified, Real-Time Object Detection [C]. // 2016 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA; 2016: 779-788.

[13] Redmon J, Farhadi A. YOLO9000: Better, Faster, Stronger [C]. // 2017 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA; 2017: 6517-6525.

[14] Redmon J, Farhadi A. YOLOv3: An Incremental Improvement [J]. arXiv preprint arXiv:1804.02767, 2018.

[15] Bochkovskiy A, Wang C Y, Liao H. YOLOv4: Optimal Speed and Accuracy of Object Detection [J]. arXiv preprint arXiv:2004.10934, 2020.

[16] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3 [C]. // 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, South Ko-

- 
- rea:IEEE,2019:1314-1324.  
<https://doi.org/10.1109/iccv.2019.00140>
- [17] Sandler M,Howard A,Zhu M,et al. MobileNetV2: Inverted residuals and linear bottlenecks [ C ].//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 4510-4520.  
<https://doi.org/10.1109/cvpr.2018.00474>

# Research on Image Detection Algorithm for Failure of Key Parts of Railway Freight Wagon Based on Deep Learning

LAI Zhibin, SHI Hongmei \*

(Institute of Intelligent Detection Technology of Rail Transit, Beijing Jiaotong University, Beijing 100091, China)

**Abstract:** The parts failure of railway freight wagon is one of the main causes of wagon accidents. Currently, train inspection work mostly uses "human eye recognition" to determine the part failures, which cannot realize the automatic fault identification. For the problem of automatic identification of key parts failure, an image detection algorithm based on is proposed based on the combination of deep learning and image processing technology according to the idea of "first locate, then identify". First, the parts detection data set and parts fault identification data set are constructed. Then, the Small-Target-Detect-Layer and CBAM YOLOv5s(SC-YOLOv5s) are integrated with the small target detection layer and Convolutional Block Attention Module to realize the localization, classification and cropping of multi-scale key parts. Finally, an algorithm based on object detection results and prior knowledge is proposed to directly determine the type of loss fault, and the improved MobileNetV3 classification algorithm is proposed to realize the automatic identification of three kinds of faults: oil dumping of rolling bearing, loosening of locking plate, and breakage of rocking pillow spring, as well as the image processing method to realize the automatic identification of two kinds of faults: bending of crossover rod and breakage of front cover of rolling bearing. The results show that SC-YOLOv5s mAP@0.5 and mAP@0.5:0.95 can reach 99.3% and 74.9% and the detection speed can reach 36.09 FPS; the improved MobileNetV3 algorithm can reach 98.63%, 99.34%, and 90.21% of the recognition accuracy of bearing oil dumping, locking plate loosening, and rocking pillow spring breakage; the recognition accuracy of the image processing method for crossbar bending and rolling bearing front cover breakage can reach 95.32% and 82.88%, respectively.

**Keywords:** Railway freight wagon; failure detection; target detection

**DOI:** 10.48014/fcmet.20231109001

**Citation:** LAI Zhibin, SHI Hongmei. Research on image detection algorithm for failure of key parts of railway freight wagon based on deep learning[J]. Frontiers of Chinese Mechanical Engineering and Technology, 2024, 3(1): 11-22.

Copyright © 2024 by author(s) and Science Footprint Press Co., Limited. This article is open accessed under the CC-BY License (<http://creativecommons.org/licenses/by/4.0/>).

