

# 基于改进 RetinaNet 的列车关键部件检测研究

杨凯<sup>1</sup>, 李锐<sup>1\*</sup>, 罗林<sup>1</sup>, 谢利明<sup>2</sup>

<sup>1</sup>西南交通大学物理科学与技术学院, 四川 成都 610031;

<sup>2</sup>成都主导科技有限公司, 四川 成都 610073

**摘要** 列车关键部件对列车的安全运行具有重要保障作用,在光照环境较差以及部件尺寸较小时,当前基于深度学习的目标检测算法无法很好地进行检测。针对这一问题,提出一种基于改进 RetinaNet 的列车关键部件检测算法。首先,为了提高小尺寸部件的检测效果,在浅层特征 P3 后引入感受野模块,提升 P3 特征层的感受野及特征质量;进而将特征金字塔网络替换为像素聚合网模块,通过增加自底向上的特征融合路径,增强特征金字塔的定位能力;最后通过调节实验参数以及网络检测层的位置,得到适用于列车关键部件检测的网络模型。经验证,所提模型在公开数据集 PASCAL VOC 上的效果优于原始 RetinaNet 网络,且所提方法在列车关键部件检测任务上优于当前的主流算法。

**关键词** 机器视觉; 关键部件检测; 深度学习; 目标检测; 图像识别; RetinaNet

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1215006

## Research on Train Key Components Detection Based on Improved RetinaNet

Yang Kai<sup>1</sup>, Li Rui<sup>1\*</sup>, Luo Lin<sup>1</sup>, Xie Liming<sup>2</sup>

<sup>1</sup>School of Physical Science and Technology, Southwest Jiaotong University, Chengdu 610031, Sichuan, China;

<sup>2</sup>Chengdu Leading Technology Co., Ltd., Chengdu 610073, Sichuan, China

**Abstract** The key components of the train are essential for ensuring the safe operation of the train. The current detection algorithm based on deep learning has poor detectability under poor lighting conditions and small component size. To solve this problem, this study proposes a detection algorithm for key components of a train based on improved RetinaNet. First, a receptive field block module was introduced after shallow feature P3 to improve the receptive field and feature quality of the P3 feature layer. Then, the feature pyramid network was replaced with a pixel aggregation net and the positioning ability of the feature pyramid was enhanced by adding a bottom-up feature fusion path. Finally, by adjusting the experimental parameters and the location of the network detection layer, a network model suitable for detecting key components of the train was obtained. Results show that the proposed model is superior to the original RetinaNet in the open dataset PASCAL VOC. Furthermore, it is superior to the current mainstream algorithm in detecting the key components of the train.

**Key words** machine vision; key components detection; deep learning; object detection; image recognition; RetinaNet

## 1 引言

高速列车是由多个部件构成的有机整体<sup>[1]</sup>,各

个部件均具有重要的作用。例如闸片部件具有制动功能;螺栓、U型锁、开口销、六棱锁等部件具有紧固作用;铭牌具有标记、示警等作用。传统的人工

收稿日期: 2021-05-06; 修回日期: 2021-06-01; 录用日期: 2021-06-19

基金项目: 国家自然科学基金重点国际(地区)合作与交流项目(61960206010)

通信作者: \*14781866710@163.com

巡检方法难以适应当前铁路行业的高速发展,且易受检测人员自身主观因素的影响。图像检测是替代人工检测的重要方式,其中的目标检测方法能对待检测物体进行分类定位,便于后续的检测。

目标检测是计算机视觉领域中的研究热点,在诸多领域中被广泛应用。传统方法中,田丽丽等<sup>[2]</sup>利用边缘检测以及平稳小波算法对列车踏面表面缺陷进行检测;王耀东等<sup>[3]</sup>利用图像局部纹理特征检测隧道裂缝;杨红梅等<sup>[4]</sup>通过尺度不变特征变换(SIFT)算子对旋转双耳进行关键点匹配并通过Hough变换的方式进行裂纹检测;韩焯等<sup>[5]</sup>通过方向梯度直方图(HOG)的方式对旋转双耳耳片进行特征提取,并通过支持向量机(SVM)分类器进行分类识别。得益于深度学习的高速发展,基于深度学习的目标检测算法在多个数据集上效果优异,具有代表性的深度学习检测算法包括FasterRCNN<sup>[6]</sup>、SSD<sup>[7]</sup>、YOLOV3<sup>[8]</sup>、YOLOV4<sup>[9]</sup>、RetinaNet<sup>[10]</sup>等。在工业上,基于深度学习的目标检测算法已经有许多成功案例,高钦泉等<sup>[11]</sup>提出一种结合目标检测网络以及辅助网络的竹条表面缺陷检测方法;吴华运等<sup>[12]</sup>通过添加空洞卷积的RetinaNet进行医药空瓶的表面缺陷检测;耿鹏志等<sup>[13]</sup>将改进的SSD网络运用于行人鞋子检测;徐志京等<sup>[14]</sup>提出一种基于Faster-RCNN的自适应旋转区域生成网络用于遥

感图像舰船目标检测;苗壮等<sup>[15]</sup>提出一种基于关键点检测的快速红外目标识别方法;王文庆等<sup>[16]</sup>将DenseNet作为特征提取器并结合注意力机制,实现了一种高精度的地对空目标检测算法。

关键部件具有分布密集、许多部件尺寸较小、检测环境复杂、光照不均匀等特征,若直接使用当前的先进目标检测网络进行检测,则达不到理想的效果,因此本文提出一种基于改进RetinaNet的目标检测方法,该方法通过在ResNet-50的block2后引入感受野块(RFB)<sup>[17]</sup>模块,提升浅层特征的感受野,并将特征金字塔融合模块由特征金字塔网络(FPN)改进为像素聚合网络(PAN)<sup>[18]</sup>,增强浅层特征与深层特征之间的信息流动,从而加强特征金字塔的特征。经过实验验证,所提出的改进方法相比原网络以及多个其他网络在关键部件上的检测效果更优。

## 2 基本原理

### 2.1 RetinaNet算法

如图1所示,RetinaNet使用残差网络(ResNet50)进行特征提取,并通过特征金字塔结构融合不同尺度的特征,最后使用检测头输出检测结果。

ResNet-50主要由4个模块堆叠组成,每个模块

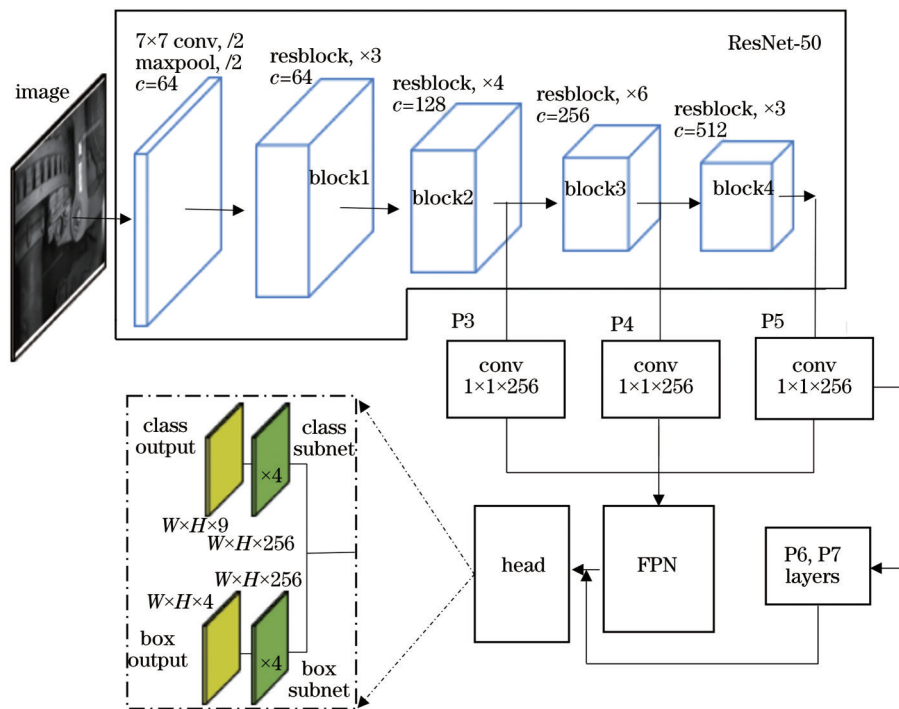


图1 RetinaNet网络结构

Fig. 1 RetinaNet network structure

由多个瓶颈结构组成,其中 block1 包含 3 个瓶颈结构, block2、block3、block4 分别包含 4、6、3 个瓶颈结构。瓶颈结构如图 2 所示,通过使用  $1 \times 1$ 、 $3 \times 3$  卷积能极大减少网络参数,并且增加网络深度,图 2 中虚线是一种跳跃连接,可以直接和上一个瓶颈结构相连,该结构能有效解决深层网络的梯度消失问题, $c$  代表网络宽度,在 block1~block4 中, $c$  分别为 64、128、256、512。FPN 的特征分别来源于 block2、block3、block4,特征在输入到 FPN 之前通过  $1 \times 1$  卷积将通道数变换为 256,通道变换后的特征为 P3、P4、P5。在 P5 后采用步长为 2 的  $3 \times 3$  卷积生成 P6 特征层,P7 特征层则是在 P6 的基础之上添加 ReLU 激活层以及步长为 2 的  $3 \times 3$  卷积生成的。P6 和 P7 特征层的感受野较大,用于检测较大的目标,其结构如图 3 所示。FPN 以及 P6、P7 特征层之后连接 Head 模块,该模块包含目标分类分支和定位分支,分别由 4 个  $3 \times 3$  的卷积层连接而成,且各检测层共用两个分类分支与定位分支,最后两个分支分别连接分类输出和边框输出。




图 2 瓶颈结构

Fig. 2 Bottleneck structure




图 3 P6 和 P7 层结构

Fig. 3 P6 and P7 layers structure

## 2.2 引入 RFB 模块

综上所述,RetinaNet 使用多尺度特征进行目标检测,其中浅层特征层 block2 分辨率较大,用于检测较小的目标;较深层的特征如 block3、block4、P6、P7 等分辨率较小,用于检测较大的目标。浅层特征感受野较小,语义信息也不及深层特征丰富,因此在实际任务中小目标的检测精度较差。由于关键部件数据中小目标较多,因此在 block2 特征层与 P3 层之间引入 RFB 模块,增强检测特征的语义信息和感受野,从而提升 RetinaNet 对小目标的检测效果。

RFB 模块的结构如图 4 所示。RFB 参考了 Inception 结构,设置了多个卷积分支,使网络自适应地学习所需要的信息。图 4 中,每个分支均采用多个  $3 \times 3$  卷积堆叠的方式,从左至右分别等价于  $3 \times 3$  卷积、 $5 \times 5$  卷积以及  $7 \times 7$  卷积,这种卷积方式能减少大卷积核带来的参数量,然后分别引入空洞率为 1、3、5 的空洞卷积提升感受野。RFB 通过特征拼接

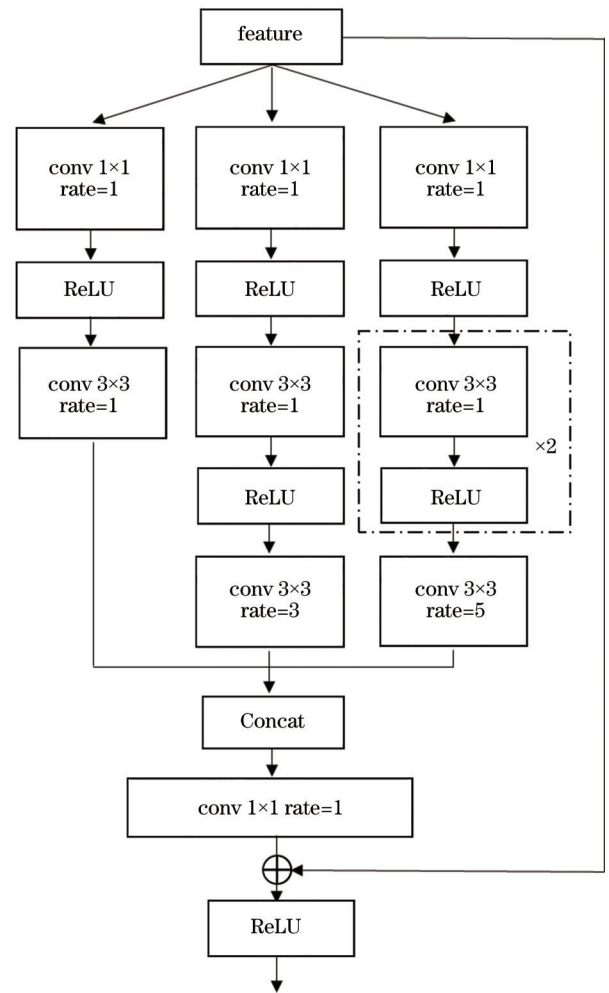


图 4 RFB 模块

Fig. 4 RFB module

的方式将不同感受野的特征融合在一起,并后接  $1 \times 1$  卷积减少通道数量,提升 RFB 模块的检测速度。

### 2.3 引入 PAN 模块

如图 5 所示,FPN 通过横向连接以及自顶向下的特征融合方式丰富了浅层特征的语义信息,其中  $P5_1$  等价于  $P5$ ,  $P4_1$  通过  $P5_1$  上采样后与  $P4$  逐通道相加得到;  $P3_1$  由  $P4_1$  上采样和  $P3$  特征相加得到;通过将深层特征与浅层特征逐步融合,从而将深层的语义信息传递到浅层,增强浅层特征的语义。

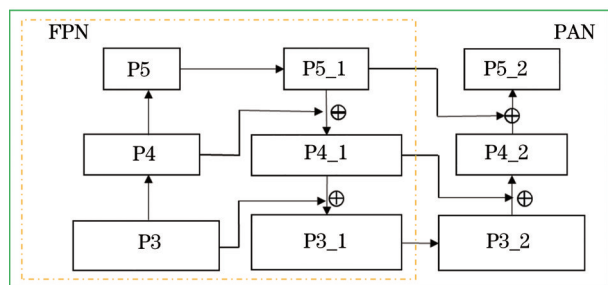


图 5 PAN 模块  
Fig. 5 PAN module

FPN 的这种自顶向下的融合方式只能对浅层特征进行增强,相比深层特征,浅层特征尺寸更大,包含的定位信息更丰富。为了进一步增强深层特征,缩短深层特征与浅层特征之间的信息流动路径,将 FPN 模块改进为 PAN 模块, PAN 在 FPN 的基础上增加了自底向上的特征融合路径,将浅层的特征进行下采样并与相邻的深层特征相加,达到向深层特征传递浅层定位信息的目的,从而有效地增强整个金字塔特征层,最后用于检测的特征分别是  $P3_2$ 、 $P4_2$ 、 $P5_2$ 。

## 3 实验设计以及实验结果分析

### 3.1 实验环境以及评价指标

所有实验均在相同的计算环境中进行训练以及测试,环境信息如表 1 所示。实验采用平均精确

度 (AP) 来衡量单个类别的检测效果,使用所有类别 AP 的平均值 (mAP) 评价所有类别的性能。AP 综合考虑了召回率  $R$  和精确度  $P$  两个指标,表示为不同置信度阈值条件形成的  $P$ - $R$  曲线与坐标轴围成的面积,如下式所示。

$$P_{AP} = \int P dR. \quad (1)$$

表 1 计算环境配置

Table 1 Computing environment configuration	
Name	Configuration
CPU	Intel i5-8300H
GPU	GTX1060, 6GB
System	Windows10
Cuda/cuDNN	9.0/9.0
Framework	Python3/Tensorflow1.4

所有的输入图片均缩放到  $640 \text{ pixel} \times 640 \text{ pixel}$  大小,特征提取网络 ResNet50 在训练时采用在 ImageNet 上预训练后的权重进行初始化。采用带动量 (动量率为 0.9) 的随机梯度下降 (SGD) 优化器进行训练优化,初始学习率为  $4 \times 10^{-5}$ ,并通过 2000 步的 warmup 方式逐步线性增加至  $1.3 \times 10^{-3}$ ,随后通过余弦退火的方式逐步下降至 0。权重衰减系数设置为  $4 \times 10^{-5}$ ,公开数据集中迭代 70000 步,关键部件数据集中迭代 56000 步。

### 3.2 所提网络在公开数据集 PASCAL VOC 上的实验结果

为了验证所提出网络的有效性,首先在公开数据集 PASCAL VOC 上进行验证实验, PASCAL VOC 数据集共包含 20 个检测类别,本实验中将 PASCAL VOC2007 与 PASCAL VOC2012 的训练数据合并,并使用 VOC2007 的测试数据进行测试。受实验显存所限,实验中采用的 batch size 为 4。实验结果如表 2 所示。在训练设置相同的条件下,所提出的方法在多个类别上的表现更好,相比原 RetinaNet, mAP 提升 0.7%。图 6(a)、图 6(b) 分别表示基于改进 RetinaNet 在公开数据集上与原网络

表 2 PASCAL VOC 数据集上验证结果 (AP)  
Table 2 Validation results on PASCAL VOC dataset (AP)

Method	mAP	Aero	Bike	Bird	Boat	Bottle	Bus	Car	Cat	Chair	Cow
RetinaNet	0.770	0.88	0.84	0.80	0.67	0.50	0.81	0.85	0.93	0.56	0.83
Proposed	0.776	0.89	0.84	0.81	0.66	0.52	0.81	0.86	0.94	0.57	0.85
Method	Table	Dog	Horse	Mbike	Person	Plant	Sheep	Sofa	Train	TV	
RetinaNet	0.64	0.90	0.83	0.84	0.81	0.52	0.77	0.74	0.89	0.79	
Proposed	0.66	0.90	0.85	0.83	0.82	0.52	0.77	0.73	0.89	0.79	

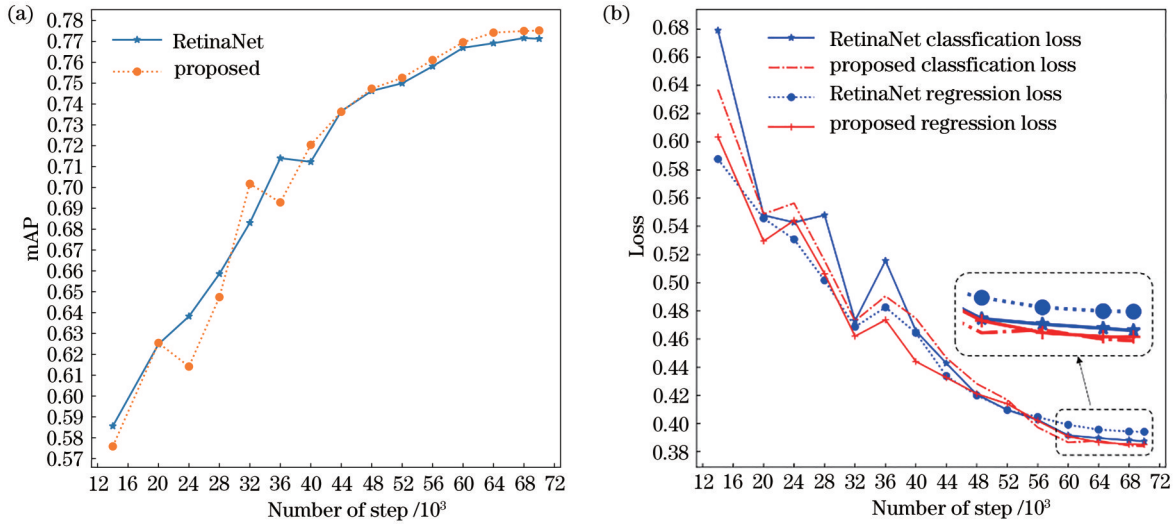


图 6 两种网络在 PASCAL VOC 数据集上的验证结果。(a)mAP; (b) 损失曲线

Fig. 6 Validation results of two networks on PASCAL VOC dataset. (a) mAP; (b) loss curves

在验证 mAP 以及验证损失曲线的对比, 所提出的网络在充分训练后 mAP 比 RetinaNet 更高, 且验证分类损失以及回归损失均更小, 证明了所提出方法的有效性。

### 3.3 关键部件数据集及训练超参数设置

数据集利用 CCD 相机采集得到, 闸片、U 型锁、开口销、螺栓、六棱锁以及铭牌 6 个类别共 1248 张图片。随机将数据集划分为训练集和测试集, 其中训练集包含 907 张图片, 测试集包含 341 张图片。数据集信息如表 3 所示, m-s ratio 表示小目标和中等目标数量占有所有目标数量的比例, 其中小目标指的是在 640 pixel × 640 pixel 分辨率下的目标面积小

表 3 关键部件数据集

Table 3 Key component dataset

Category	Training set		Testing set	
	Objects	m-s ratio	Objects	m-s ratio
		/ %		/ %
Brake	574	91	233	92
U-lock	194	94	99	89
Cotter pin	235	88	104	96
Bolt	4542	73	1436	64
Hexagonal lock	164	98	87	97
Nameplate	339	63	130	81

表 5 所提方法与 RetinaNet 的 AP 对比

Table 5 AP comparison between proposed method and RetinaNet

Model	mAP	Brake	U-lock	Cotter pin	Bolt	Hexagonal lock	Nameplate
RetinaNet	0.951	0.94	0.98	0.93	0.95	0.97	0.94
RetinaNet+RFB	0.958	0.95	0.99	0.95	0.95	0.96	0.95
Proposed	0.964	0.95	0.99	0.96	0.95	0.97	0.96

于 32 pixel × 32 pixel 的目标; 中等目标的面积大于 32 pixel × 32 pixel 且小于 64 pixel × 64 pixel。由表 3 可知, 数据集中的中、小目标较多。

### 3.4 不同特征层对关键部件检测的影响

由于不同的特征层对应检测不同尺度的目标, 而数据集中大部分均是中等以及小目标, 为了对比不同特征层对检测性能的影响, 使用原始 RetinaNet 进行对比实验, 实验结果如表 4 所示, 去除 P6、P7 层后模型权重大小从 116 MB 下降到 109 MB, 而在验证集上的 mAP 几乎不下降, 不影响检测效果, 因此去掉对检测性能贡献较小的 P6、P7 层。

表 4 不同特征层对检测效果的影响

Table 4 Influence of different feature layers on detection effect

P3、P4、P5、P6、P7	P3、P4、P5	mAP	Weight / MB
√		0.952	116
	√	0.951	109

### 3.5 所提方法和 RetinaNet 的对比

为验证所提出改进方法的有效性, 本文分别对不同的改进方法进行了对比实验, 如表 5 所示, RetinaNet 在测试集上的 mAP 是 0.951, 添加 RFB 模块后, mAP 提升为 0.958, 改进 FPN 为 PAN 后,

mAP为0.964。从表中数据可知,RFB模块对开口销的AP提升最大,添加RFB模块后,开口销的AP提升2%,PAN与RFB模块结合后开口销AP提升3%,除此之外,闸片、U型锁、铭牌等3个类别,AP分别提升1%、1%以及2%,该结果证明了所提方法的有效性。

RetinaNet与所提方法在关键部件测试集上的可视化结果如图7和图8所示,关键部件目标分布

较密集,大部分目标较小,且部分图像中光照质量较差。两图中,绿色边框是检测正确的结果,红色粗线框代表漏检的目标,黄色虚线边框表示误检的目标,RetinaNet和改进方法相比,其漏检情况相对较严重,尤其是对尺寸较小的部件以及暗光条件下的部件,而改进方法中的RFB结构能很好地提升小目标检测层的感受野,且PAN结构能较好地增强特征金字塔,从而对较为极端目标的检测效果更优。




图7 RetinaNet的检测结果

Fig. 7 Detection results of RetinaNet




图8 改进方法的检测结果

Fig. 8 Detection results of improved method

### 3.6 与不同检测网络的对比

将所提出方法与当前主流方法在关键部件数据集上进行对比,所用方法包括YOLOV3、YOLOV4、FasterRCNN、SSD以及FCOS<sup>[19]</sup>,其中FasterRCNN的输入大小在600~800 pixel之间,将输入图像的短边缩放为600 pixel,长边的像素最大

为800 pixel;其他方法均采用640 pixel×640 pixel的输入。在列车关键部件数据集上进行训练和测试,结果如表6所示,所提出方法的mAP最高;在推理时间上,比FasterRCNN用时更少,相比YOLOV3、YOLOV4、SSD以及FCOS,本文方法耗时略高,但相差不大,可满足实时检测需求。

表 6 不同模型的检测速度以及效率对比

Table 6 Comparison of detection speed and efficiency of different models

Method	mAP	Inference time /s
YOLOV3	0.85	0.08
YOLOV4	0.93	0.10
FasterRCNN	0.92	0.25
FCOS	0.89	0.10
SSD	0.93	0.10
RetinaNet	0.95	0.11
Proposed	<b>0.96</b>	0.12

## 4 结 论

本文提出一种改进的 RetinaNet 算法用于列车关键部件的检测,采用 ResNet-RetinaNet 作为网络模型,在浅层特征 P3 层后引入 RFB 模块,并通过 PAN 模块增强了特征金字塔,对中小尺寸的部件目标有更好的检测效果。与此同时,通过观察不同特征层的检测效果,在关键部件检测数据集上去除了 P6、P7 预测特征层,减少了网络参数量。相比改进前,所提出模型在公开数据集 PASCAL VOC 上的测试 mAP 提升了 0.6%,在铁路关键部件检测任务上,所实验的 6 个类别在精度以及速度上均具有较高的水准,总体 mAP 为 0.964,相比改进前提高 1.3%,其中开口销部件提高 3%,铭牌部件提高 2%,闸片、U 型锁部件提高 1%。

本文虽然在采集到的关键部件数据集上检测速度及精度均较好,但铁路数据的采集环境复杂、数据光照差异大、待检测部件所处环境差异大等,在这些极端条件下检测效果会有所下降。未来的工作将收集更加充分的数据,从而得到更为鲁棒的检测模型;与此同时,本文模型的精度虽然相比其他网络更好,但仍有提升的空间,下一步工作将研究检测精度更高的算法。

## 参 考 文 献

- [1] 林帅,贾利民,王艳辉.基于区间直觉犹豫模糊集的高速列车系统关键部件辨识[J].控制理论与应用,2019,36(2):295-306.  
Lin S, Jia L M, Wang Y H. Identification of critical components of high-speed train system based on interval-value intuitionistic hesitant fuzzy set[J]. Control Theory & Applications, 2019, 36(2): 295-306.
- [2] 田丽丽,方宗德,赵勇.铁路货车车轮踏面损伤检测中剥离与擦伤定位方法[J].铁道学报,2009,31(5):

31-36.

Tian L L, Fang Z D, Zhao Y. Locating methods of peeling and flat spots in detection of wheel tread damages of railway wagons[J]. Journal of the China Railway Society, 2009, 31(5): 31-36.

- [3] 王耀东,朱力强,史红梅,等.基于局部图像纹理计算的隧道裂缝视觉检测技术[J].铁道学报,2018,40(2):82-90.  
Wang Y D, Zhu L Q, Shi H M, et al. Vision detection of tunnel cracks based on local image texture calculation[J]. Journal of the China Railway Society, 2018, 40(2): 82-90.
- [4] 杨红梅,刘志刚.基于 SURF 特征匹配的电气化铁路接触网支撑装置旋转双耳不良状态检测[J].铁道学报,2016,38(8):28-34.  
Yang H M, Liu Z G. Defective condition detection of rotary double ears of catenary support device of electrified railway based on feature matching of SURF[J]. Journal of the China Railway Society, 2016, 38(8): 28-34.
- [5] 韩焯,刘志刚,耿肖,等.基于 HOG 特征与二维 Gabor 小波变换的高铁接触网支撑装置耳片断裂故障检测[J].铁道学报,2017,39(2):52-57.  
Han Y, Liu Z G, Geng X, et al. Fracture detection of ear pieces in catenary support devices of high-speed railway based on HOG features and two-dimensional Gabor transform[J]. Journal of the China Railway Society, 2017, 39(2): 52-57.
- [6] 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.
- [7] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [8] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2021-02-01]. <https://arxiv.org/abs/1804.02767>.
- [9] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2021-02-10]. <https://arxiv.org/abs/2004.10934>.
- [10] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42

- (2): 318-327.
- [11] 高钦泉, 黄炳城, 刘文哲, 等. 基于改进 CenterNet 的竹条表面缺陷检测方法[J]. 计算机应用, 2021, 41(7): 1933-1938.  
Gao Q Q, Huang B C, Liu W Z, et al. Bamboo strip surface defect detection method based on improved CenterNet[J]. Journal of Computer Applications, 2021, 41(7): 1933-1938.
- [12] 吴华运, 任德均, 吕义钊, 等. 基于改进的 RetinaNet 医药空瓶表面气泡检测[J]. 四川大学学报(自然科学版), 2020, 57(6): 1090-1095.  
Wu H Y, Ren D J, Lü Y Z, et al. Bubble detection on the surface of medical empty bottles based on improved RetinaNet[J]. Journal of Sichuan University (Natural Science Edition), 2020, 57(6): 1090-1095.
- [13] 耿鹏志, 杨智雄, 张家钧, 等. 基于 SSD 的行人鞋子检测算法[J]. 激光与光电子学进展, 2021, 58(6): 0610009.  
Geng P Z, Yang Z X, Zhang J J, et al. Pedestrian shoes detection algorithm based on SSD[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0610009.
- [14] 徐志京, 丁莹. 自适应旋转区域生成网络的遥感图像舰船目标检测[J]. 激光与光电子学进展, 2020, 57(24): 242805.  
Xu Z J, Ding Y. Ship object detection of remote sensing images based on adaptive rotation region proposal network[J]. Laser & Optoelectronics Progress, 2020, 57(24): 242805.
- [15] 苗壮, 张湧, 陈瑞敏, 等. 基于关键点的快速红外目标检测方法[J]. 光学学报, 2020, 40(23): 2312006.  
Miao Z, Zhang Y, Chen R M, et al. Method for fast detection of infrared targets based on key points[J]. Acta Optica Sinica, 2020, 40(23): 2312006.
- [16] 王文庆, 丰林, 刘洋, 等. 结合 DenseNet 与通道注意力机制的空对地目标检测算法[J]. 激光与光电子学进展, 2020, 57(22): 221010.  
Wang W Q, Feng L, Liu Y, et al. Air-to-ground target detection algorithm based on DenseNet and channel attention mechanism[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221010.
- [17] Liu S T, Huang D, Wang Y H. Receptive field block net for accurate and fast object detection[M]// Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11215: 404-419.
- [18] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8759-8768.
- [19] Tian Z, Shen C H, Chen H, et al. FCOS: fully convolutional one-stage object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 9626-9635.