

DOI:10.19651/j.cnki.emt.2209459

基于多尺度特征融合网络的铁路工机具目标检测^{*}

杨瑾¹ 陈灯¹ 张彦铎¹ 刘伟¹ 郑朝晖²

(1. 武汉工程大学智能机器人湖北省重点实验室 武汉 430205; 2. 武汉工程大学数理学院 武汉 430205)

摘要: 图像目标检测是铁路工机具实现自动清点的关键技术。由于铁路运维工作的特殊性,采集的工机具图像通常存在光照度低、目标尺度差异大以及背景复杂等问题。已有的图像目标检测模型无法在铁路工机具检测中获得满意的效果。本文提出一种基于多尺度特征融合增强网络模型,以深度学习目标检测网络 Retinanet 为基础,构造了特征融合增强模块,可实现对不同尺度铁路工机具的高精度检测。以真实的铁路工机具图像作为数据集开展了实验研究,结果表明提出的模型较 Retinanet 具有更好的目标检测效果,mAP 从 97.85% 提高到了 98.11%,解决了复杂背景下铁路工机具的精确检测难题,为铁路智能运维奠定了技术基础。

关键词: 铁路运维;深度学习;目标检测;特征融合;特征增强

中国分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.6040

Object detection of railway tool based on multi-scale feature fusion network

Yang Jin¹ Chen Deng¹ Zhang Yanduo¹ Liu Wei¹ Zheng Zhaohui²

(1. Hubei Province Key Laboratory of Intelligent Robot, Wuhan Institute of Technology, Wuhan 430205, China;

2. School of Mathematics and Physics, Wuhan Institute of Technology, Wuhan 430205, China)

Abstract: Image object detection is crucial for the automatic counting of railway tools. However, collected images of railway tools have the characteristics of low illumination, huge difference in the scale of different objects and complex backgrounds. Existing image object detection methods cannot detect railway tools efficiently. In this paper, we propose a novel object detection model which is able to enhance the object-detection ability by fusing multi-scale features. Based on the object detection deep learning model Retinanet, we construct a feature fusion enhancement module. By fusing features, our model can efficiently detect railway tools with different scales. Experiments were conducted based on real-world datasets. Results show that our method is more efficient than Retinanet, and the mAP is increased from 97.85% to 98.11%. By the accurate detection of railway tools in complex backgrounds, our approach can lay the technical foundation for intelligent railway operation and maintenance.

Keywords: railway operation and maintenance;deep learning;object detection;feature fusion;feature enhancement

0 引言

铁路是交通系统的重要组成部分。为了保障铁路的安全运行,铁路部门通常在夜间开展运维工作。运维工作中工机具的大量遗失给铁路部门造成了巨大的经济损失。当前的解决方案是对工人领取和归还的工机具进行拍照留存,通过人工对比分析,发现遗失的工机具,但这种方法存在主观误差问题,无法满足人力资源受限情况下铁路运维的智能化要求。基于图像目标检测技术可实现铁路工机具的自动清点^[1-5],但铁路工机具种类繁多,形状和尺度差异大,且铁路运维通常在夜间进行,光源辅助下采集的工机具图像存在光照度低、光照不均以及背景复杂等问题。已有

的图像目标检测模型无法在铁路工机具检测中获得满意的效果。

为提高目标检测算法的检测精度并解决多尺度目标检测问题,2016 年 Redmon 等^[6]提出了 YOLOv1,将特征提取、候选框分类和回归在一个深度卷积网络中实现,简化了网络结构,提高了检测速度。尽管速度上有所提升,但其在定位方面不够准确。2016 年 Liu 等^[7]提出了单发多框检测器(single shot multibox detector, SSD),使用一系列依次变小的卷积层生成金字塔特征图来预测各种不同尺度的目标,大尺度特征图检测小目标,小尺度特征图检测大目标。但是,SSD 模型忽略了不同尺度特征之间的相关性,而且浅

收稿日期:2022-03-30

*基金项目:国家自然科学基金(62171328)、湖北省教育科学规划课题(2019GA090)项目资助

层特征空间的细节信息和高层的语义信息没有获得充分的应用,进而导致其对小目标的检测精度较低。随后,Redmon 等^[8]提出了改进的 YOLOv2 模型,利用批归一化(batch-normalization)、高分辨率分类器 5 (high resolution classifier)、直接位置预测(location prediction)、多尺度训练(multi-scale)等操作来提高模型的检测精度。达到了速度与精度的平衡,但对多尺度目标检测效果提升不明显。随后^[9-10]等提出 DSSD 检测模型,引入 Resnet-101 作为 SSD 骨干网络,在 SSD 的辅助卷积层后添加了反卷积层,并在分类回归之前引入残差模块,提高了小目标检测精度,但速度比 SSD 慢。此后,Lin 等^[11]提出 Retinanet 检测模型,引入 Focal Loss 损失函数解决之前模型存在的训练过程中类别不均衡的问题,对小目标的检测有明显提升。随后,Redmon 等^[12-14]提出了 YOLO 系列更进一步的改进模型,在 YOLOv2 基础上,引入特征金字塔网络(feature pyramid network,FPN)^[15]进行多尺度融合预测,并在融合的特征图上分别独立做检测,能明显提升对小目标的检测效果。2018 年 Liu 等^[16]提出通过增加感受野提高目标检测网络的特征提取能力的网络(receptive field block network, RFB)。上述方法的主要思路是采用不同的特征融合方式提升模型对不同尺度特征的表征能力,从而提高模型对多

尺度目标检测的鲁棒性。虽然这些方法一定程度上提高了对小目标的检测效果,但仍然无法达到在复杂背景下小目标精确检测的实际应用需求。

为了提高多尺度目标的检测精度,本文提出了一种基于多尺度特征融合增强的网络模型。以深度学习目标检测网络 Retinanet 为基础,在对多尺度特征进行逐层融合的同时应用特征增强方法使目标特征靠近感受野中心,从而使特征对目标的细节信息具有更好的表征能力,可有效提高多尺度目标的检测精度。

1 铁路工机具检测方法

1.1 总体框架

如图 1 所示,为了对铁路工机具目标进行检测,采集了大量铁路工机具图像,经过数据集增强后,形成训练数据集。为提高对多尺度铁路工机具的检测效果,以 Retinanet 为基础,增加了特征融合增强模块,构建了改进的铁路工机具目标检测深度模型。经过训练的模型可有效识别图像中铁路工机具的类别和位置。改进的目标检测深度模型构建了多尺度特征金字塔,并采用特征融合增强模块提高了特征对目标的表征能力,可对不同尺度铁路工机具进行有效检测。

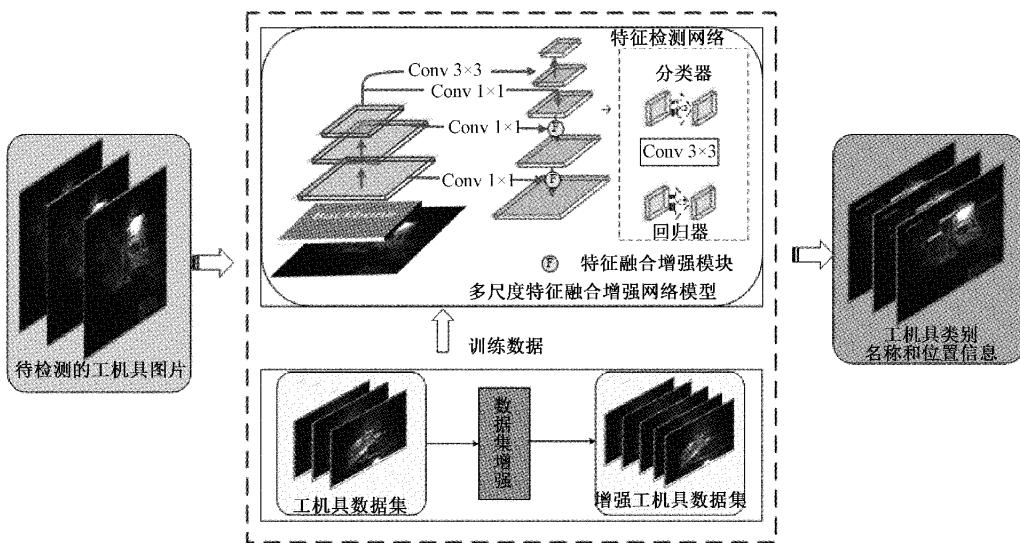


图 1 铁路工机具目标检测总体框架

1.2 多尺度特征融合增强网络模型

如图 2 所示,基于 RetinaNet^[11]提出了改进的多尺度特征融合增强网络模型(Multi-scale feature fusion enhanced network, MSFFEN)。MSFFEN 模型由特征提取网络 ResNet-50^[17]、特征金字塔(feature pyramid networks, FPN)^[15]、特征融合增强模块(feature fusion and enhancement module, FFEM) 和全卷积(fully convolutional networks, FCN) 分类网络^[18]构成。其中, FPN 由 P3, P4, …, P7 共 5 个尺度依次减小的特征层构成,且 FFEM 主要融合在生成 P3 和生成 P4 的过程中,其具体

计算方法如下:

- 1) 通过对 ResNet-50 中的卷积层 C5_3 进行 3×3 的卷积操作得到 P6;
- 2) 对 FPN 中的 P6 进行 3×3 卷积得到 P7;
- 3) ResNet-50 中的卷积层 C5_3 通过横向连接形成 P5;
- 4) ResNet-50 中的卷积层 C4_6 和 FPN 中的 P5 通过特征融合增强模块进行融合生成 P4;
- 5) ResNet-50 中的卷积层 C3_4 和 FPN 中的 P4 通过 FFEM 特征融合后生成 P3。

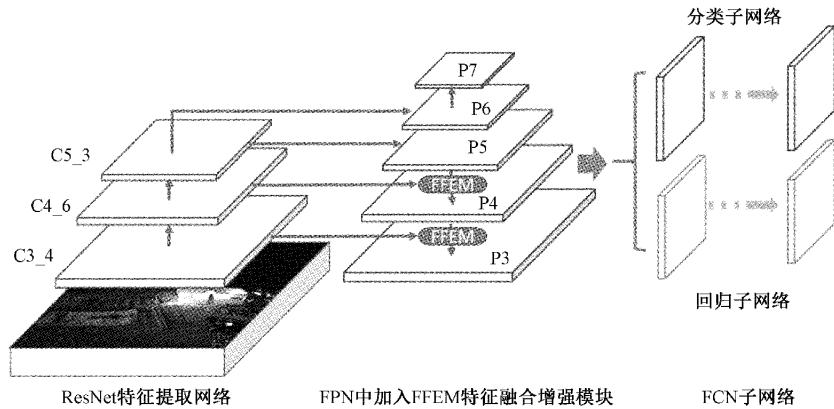


图 2 多尺度特征融合增强网络框架

最后基于 FPN 的特征映射集合, 分别使用两个结构相同但参数不共享的 FCN 子网络进行目标分类和位置回归。RetinaNet 目标检测网络大量的成功应用说明了其对小目标检测的有效性。通过在 FPN 中应用特征融合增强模块 FFEM, 可生成不同尺度的融合特征层, 提升模型对不同尺度铁路工机具的精确检测能力。

1.3 特征融合增强模块

如图 3 所示, FFEM 以来自 ResNet 特征提取网络的原始特征映射层 **OC** 和 FPN 中的特征映射层 **NC** 作为输入

进行特征融合和增强。如式(1)所示, 特征融合方法首先采用 1×1 卷积核分别对 **OC** 和 **NC** 进行特征映射, 减少输入通道数, 避免计算量过大。由于 FPN 中的 **NC** 层尺度比 **OC** 层小, 为此, 对 **NC** 进行双线性插值的上采样操作, 使特征图尺度保持一致。最后基于逐点相乘 (Eltw product) 操作获得融合特征层 **FC**。

$$\mathbf{FC} = f_{product}(\mathbf{OC}, f_{upsampling}\mathbf{NC}) \quad (1)$$

其中, $f_{product}$ 表示逐点相乘操作, $f_{upsampling}$ 表示双线性插值上采样操作。

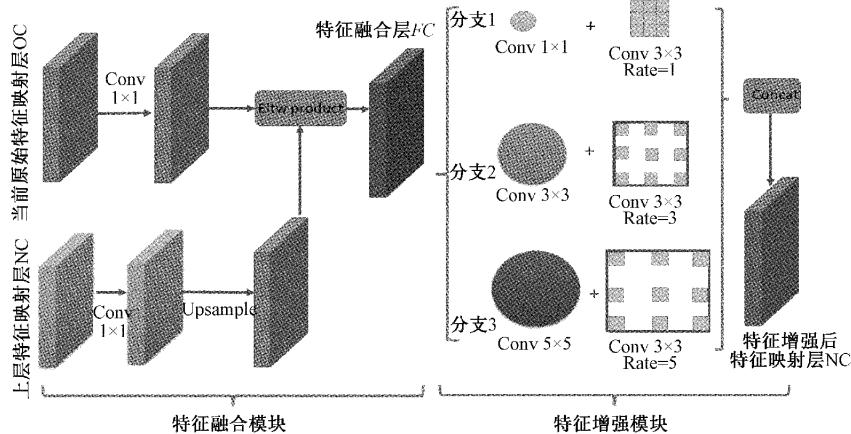


图 3 特征融合增强模块

为了使目标区域尽可能靠近感受野中心, 提高模型对细节信息的表征能力, 采用了 RFB^[16] 方法对融合后的特征层 **FC** 进行增强。RFB 借鉴了 Inception^[19] 的思想, 将特征融合层 **FC** 按通道数划分为三等分, 并对这三等分分别采用卷积核大小为 1×1 、 3×3 、 5×5 的卷积层构建分支结构。然后在分支结构后引入卷积核大小为 3×3 , 膨胀率分别为 1、3 和 5 的膨胀卷积层。采用式(2)所示的方法对融合特征层 **FC** 进行特征增强, 将不同尺度卷积层预处理成相同尺度后进行通道连接, 从而获得增强的特征映射层 **NC**。

$$\mathbf{NC} = f_{concat}(f_{fem}(\mathbf{FC})) \quad (2)$$

其中, f_{concat} 表示通道连接操作, f_{fem} 表示特征增强操作。

特征融合增强模块 FFEM 充分利用了多尺度特征图之间的上下文信息, 同时使目标区域尽可能靠近感受野中心, 可提升模型对不同尺度目标细节信息的表征能力, 实现复杂背景下不同尺度目标的精确检测。

2 实验评估

2.1 数据集

从铁路系统获取了真实工机具图像共计 1 208 张。图像由铁路工人在夜间运维时采用手电筒补光的方式拍摄所得, 存在光照度低和光照不均等问题。此外, 采集的图像中包含上千种工机具, 分别有钉锤、道镐、道碴叉、棘轮扳手、电机、编织袋、铲子、铁丝、电线、电钻、工具包、桶、信

号灯和照明灯等。这些工机具尺度差异较大,包含电机、编织袋等大尺度目标以及电线、电钻、信号灯等小尺度目标。为了增加图像样本数量,对采集的图像应用了旋转变换、平移变换、亮度变换、缩放变换、切变变换等数据集增强^[20]操作,共获得工机具图像7 248张。增强后的图像在保持原始图像基本结构和颜色分布的基础上,在空间几何和像素颜色值上进行了微调,增加了样本的多样性。采用LabelImage软件对增强后的工机具图像数据集进行人工标注。然后,将工机具数据集按照6:2:2的比例随机划分为训练集、验证集和测试集。由于铁路工机具种类繁多,实验以10类尺度差异较大的铁路工机具作为主要分析对象,其中大尺度目标为电机和编织袋,中等尺度目标为铲子和铁丝,小尺度目标为电线、电钻、工具包、桶、信号灯以及照明灯。

2.2 实验配置

实验在显卡服务器上进行,其软硬件配置如下:

- 处理器: Intel® Core™ i7-8700 CPU@3.20 GHz;
- 内存: 16 GB DDR3;
- 显卡: GeForce GTX-1080Ti
- 软件环境: Ubuntu 18.04 LTS, PyTorch1.7.0, OpenCV3.4.4, Python3.7

2.3 实验方法

为了验证模型对铁路工机具检测的有效性,本文开展了3项实验研究。实验一是验证FFEM模块对模型的影响,实验二是验证不同特征提取网络对模型的影响,实验三是本文模型与其他网络模型的检测结果对比。

实验一构造了以ResNet-50为特征提取网络的Retinanet模型(记作Retinanet-50)和采用ResNet-50作为特征提取网络并集成有FFEM模块的MSFFEN模型(记作MSFFEN-50)。通过预测性能对比分析FFEM模块的有效性。

实验二构造了以ResNet-50为特征提取网络的MSFFEN模型(记作MSFFEN-50)和采用ResNet-101作为特征提取网络的MSFFEN模型(记作MSFFEN-101)。通过预测性能对比分析,评估不同主干网络的有效性。

实验三基于SSD^[7]、FSSD^[20]、RFBNet^[16]和Retinanet-101^[11]、MSFFEN-101等模型开展了对比实验研究,验证本文方法的有效性。

分别在上述模型均在增强后的铁路工机具数据集上,应用牛顿动量(Nesterov momentum)^[21]优化后的随机梯度下降算法(stochastic gradient descent, SGD)进行训练。其中,批大小设置为8,动量值设置为0.9,权重衰减设为0.0005,学习率衰减率设为0.1,学习速率前80k次迭代为0.001,随后每20k次迭代改变一次学习速率,经过120k次迭代,得到最终的训练模型。Retinanet-50的最终损失为0.18,MSFFEN-50的最终损失为0.16,MSFFEN-101的最终损失为0.13,SSD的最终损失为0.22,FSSD的

最终损失为0.16,RFBNet的最终损失为0.18和Retinanet-101的最终损失为0.20。

2.4 实验结果分析

1) 特征融合增强模块效果分析

表1展示了Retinanet-50和MSFFEN-50模型对各类工机具平均检测精度。由表1可以看出,Retinanet-50检测结果中,所有类的AP均在86%以上,最高接近99%,总的mAP为95.33%。其中信号灯和工具包这类小尺度目标的AP达到了98.94%和97.90%,电机和编织袋这类大尺度目标的AP分别为97.90%和97.54%。铲子这类目标AP则较低,为86.89%。MSFFEN-50检测结果中,所有类的AP均在92%以上,最高接近100%,总的mAP为97.44%。其中信号灯和工具包这类小尺度目标的AP达到了99.38%和99.23%,电机和编织袋这类大尺度目标的AP分别为99.35%和98.38%。铲子这类目标AP则较低,为92.08%,原因是铲子这类目标大多正位于手电筒补光附近,受到了光照不均影响。对比分析可以发现,MSFFEN-50对各类不同尺度铁路工机具的检测精度均优于Retinanet-50。对比实验结果表明本文提出的特征融合增强模块FFEM可有效提高模型对不同尺度铁路工机具目标检测的精度,mAP提高了2.11%。

表1 工机具检测结果对比分析

工机具类型	平均精度/%	
	Retinanet-50	MSFFEN-50
铲子	86.89	92.08
电机	97.90	99.35
电线	96.01	98.14
电钻	93.88	95.20
工具包	97.90	99.23
编织袋	97.54	98.38
铁丝	98.31	99.84
桶	91.76	94.14
信号灯	98.94	99.38
照明灯	94.21	98.69
mAP	95.33	97.44

2) 特征提取网络对检测效果的影响分析

表2展示了ResNet-50和ResNet-101模型对各类工机具的平均检测精度。由表可见,MSFFEN-50检测结果中,所有类的AP均在92%以上,最高为99.38%。MSFFEN-101检测结果中,所有类的AP均在93%以上,最高接近100%。对比分析可以发现,采用基于ResNet-101的多尺度特征融合网络模型MSFFEN-101对各类不同尺度铁路工机具的检测精度普遍优于采用基于ResNet-50的多尺度特征融合网络模型MSFFEN-50,mAP提高了0.67%。实验结果表明更复杂的特征提取网络可能更利

于工机具检测。

表 2 不同骨干网络下工机具检测精度

工机具类型	平均精度/%	
	MSFFEN-50	MSFFEN-101
铲子	92.08	93.65
电机	99.35	99.68
电线	98.14	98.36
电钻	95.20	97.42
铁丝	99.84	99.84
桶	94.14	95.92
工具包	99.23	99.38
编织袋	98.38	98.42
信号灯	99.38	99.69
照明灯	98.69	98.69
mAP	97.44	98.11

3) 模型对比实验结果分析

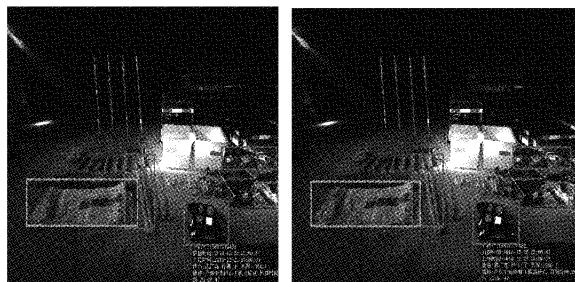
表 3 展示了 SSD、FSSD、RFBNet、Retinanet-101 和 MSFFEN-101 模型对各类工机具的平均检测精度。由表 3

可以看出,SSD 检测结果中,所有类的 AP 均在 63% 以上,最高为 100%。FSSD 检测结果中,所有类的 AP 均在 85% 以上,最高接近 97%。RFBNet 检测结果中,所有类的 AP 均在 71% 以上,最高接近 92%。Retinanet-101 检测结果中,所有类的 AP 均在 93% 以上,最高为 99.46%。MSFFEN-101 检测结果中,所有类的 AP 均在 93% 以上,最高为 99.68%。对比分析可以发现,与 SSD、FSSD、RFBNet 和 Retinanet-101 相比,MSFFEN-101 模型的 mAP 分别提高了 15.11%、7.95%、11.41% 和 0.26%,说明了本文方法的有效性。此外,MSFFEN-101 对信号灯这类小目标的检测 AP 达到了 99.69%,较 SSD、FSSD、RFBNet 和 Retinanet-101 分别提高了 36.17%、9.5%、9.64% 和 0.19%;MSFFEN-101 对电机这类大目标的检测 AP 为 99.68%,较 SSD、FSSD、RFBNet 和 Retinanet-101 分别提高了 6.95%、2.94%、14.37% 和 0.81%。MSFFEN-101 对铲子这类自身尺度大小不统一的目标的检测 AP 为 93.65%,较 SSD、FSSD、RFBNet 和 Retinanet-101 分别提高了 20.47%、7.38%、21.84%、0.49%。MSFFEN-101 对信号灯、电机和铲子等不同尺度目标的检测结果说明了本文方法对多尺度目标检测的有效性。

表 3 各目标检测算法结果对比

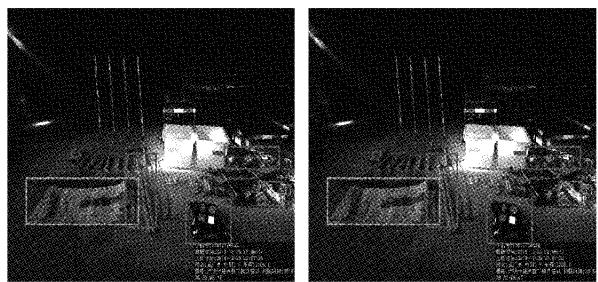
工机具类型	平均精度/%				
	SSD	FSSD	RFBNet	Retinanet-101	MSFFEN-101
铲子	73.18	86.27	71.81	93.16	93.65
电机	92.73	96.74	85.31	98.87	99.68
电线	79.67	84.96	82.80	98.07	98.36
电钻	81.02	95.11	87.84	96.65	97.42
铁丝	100.00	87.90	89.54	99.88	99.84
桶	79.33	89.67	88.26	95.76	95.92
工具包	90.08	90.75	90.69	99.46	99.38
编织袋	95.64	94.34	91.32	98.43	98.42
信号灯	63.52	90.19	90.05	99.50	99.69
照明灯	76.56	85.67	89.33	98.72	98.69
mAP	83.00	90.16	86.70	97.85	98.11

图 4 给出了上述模型的铁路工机具检测结果图,由

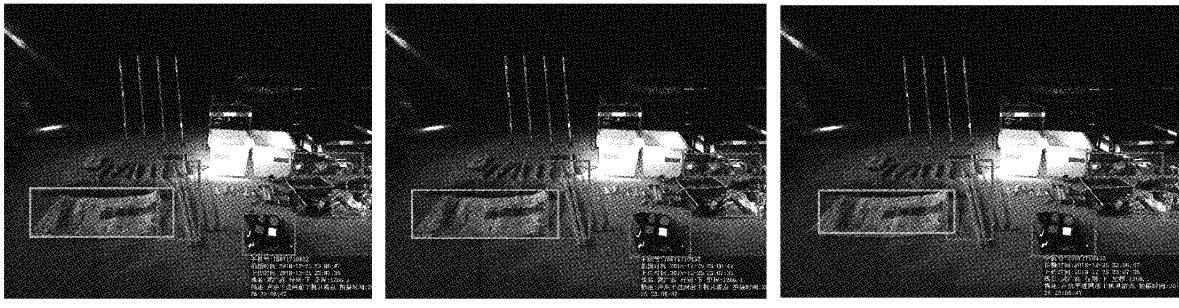


SSD 检测结果,包括: 编织袋、FSSD 检测结果,包括: 编织袋、铲子、照明灯、电机、电线(黄)

图 4 可知,模型 SSD、FSSD、RFBNet、Retinanet-50 和



RFBNet 检测结果,包括: 编织袋、Retinanet-50 检测结果,包括: 编织袋、铲子、照明灯、电机、电线(黄)



MSFFEN-50 检测结果, 包括: 编织袋、铲子、
照明灯、电机、电线 (黄)、电线 (黑)
Retinanet-101 检测结果, 包括: 编织袋、铲子、
照明灯、电机、电线 (黄)
MSFFEN-101 检测结果, 包括: 编织袋、铲子、
照明灯、电机、电线 (黄)、电线 (黑)

图 4 铁路工机具检测结果图

Retinanet-101 均只检测出了黄色电线这个小目标, 而 MSFFEN-50 和 MSFFEN-101 还检测出了黑色电线这个小目标。通过分析上述模型的检测结果, 可以发现 MSFFEN-50 和 MSFFEN-101 能检测出更多的小目标, 说明了本文方法能有效解决夜间复杂开放场景下多尺度目标检测, 特别是小目标检测难题, 基本满足铁路智能运维的实际应用需求。

3 结 论

本文提出了一种基于多尺度特征融合网络的铁路工机具目标检测方法。以 Retinanet 网络为基础框架, 构造了特征融合增强模块。在充分利用多尺度特征图之间的上下文信息的同时使目标区域尽可能靠近感受野中心, 加强了特征对目标信息的表征能力, 从而提升模型对不同尺度目标检测的鲁棒性。利用工机具数据集在 SSD、FSSD、RFBNet、Retinanet 和 MSFFEN 上进行了综合实验, 证明了提出的多尺度特征融合增强模型 MSFFEN 对于夜间复杂环境下, 多尺度, 特别是小尺度工机具目标检测具有良好的效果, 工机具检测 mAP 达到 98.11%, 基本满足铁路智能运维实际应用需求。

参考文献

- [1] WEI W, YANG J, WANG S, et al. Automatic counting of railway tools based on deep learning [M]. Security and Privacy in Social Networks and Big Data, 2020, DOI: 10.1007/978-981-15-9031-3_31.
- [2] 崔雪红, 刘云, 王传旭, 等. 基于卷积神经网络的轮胎缺陷 X 光图像分类 [J]. 电子测量技术, 2017, 40(5), DOI: 10.3969/j.issn.1002-7300.2017.05.035.
- [3] 陈庆, 吕斌, 叶润, 等. 航拍绝缘子卷积神经网络检测及自爆识别研究 [J]. 电子测量与仪器学报, 2017, 31(6), DOI: 10.13382/j.jemi.2017.06.018.
- [4] 刘云, 杨建滨, 王传旭. 基于卷积神经网络的苹果缺陷检测算法 [J]. 电子测量技术, 2017, 40(3), DOI: 10.3969/j.issn.1002-7300.2017.03.023.
- [5] 王飞, 张莹, 张东波, 等. 基于捷径的卷积神经网络在人脸识别中的应用研究 [J]. 电子测量与仪器学报, 2018(4), DOI: CNKI:SUN:DZIY.0.2018-04-012.
- [6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Washington, DC: IEEE Computer Society, 2016.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector [C]. European conference on computer vision. Springer, Cham, 2016: 21-37.
- [8] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Washington D.C., USA: IEEE Press, 2017.
- [9] FU C Y, LIU W, RANGA A, et al. DSSD: Deconvolutional single shot detector [C]. Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2017.
- [10] 周文军, 张勇, 王显洁. 基于 DSSD 的静态手势实时识别方法 [J]. 计算机工程, 2020, 46(2): 255-261.
- [11] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. 2017 IEEE International Conference on Computer Vision (ICCV), 2020(2), DOI: 10.1109/ICCV.2017.324.
- [12] 燕江云, 余雯瑾, 石亚军, 等. 基于 YOLOv3 算法检测经改良抗酸染色后脑脊液中分枝杆菌图像的研究 [J]. 中国医学前沿杂志, 2021, 13(2): 24-29.
- [13] DU J. AIVMAF: Automatic image quality estimation based on improved VMAF and YOLOv4 [J]. IOP Publishing Ltd, 2022, DOI: 10.1088/1742-6596/2289/1/012020.
- [14] WANG Q, SI G, QU K, et al. Transmission line foreign body fault detection using multi-feature fusion based on modified YOLOv5 [J]. IOP Publishing Ltd, 2022, DOI: 10.1088/1742-6596/2320/1/012028.

-
- [15] LIN T Y, DOLLAR P, GIRSHICK R B, et al. Feature pyramid networks for object detection[C]. CVPR2017: In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2017.
 - [16] LIU S, HUANG D, WANG Y. Receptive field block net for accurate and fast object detection. [C]. Proceedings of European Conference on Computer Vision, DOI: 2018. <https://doi.org/10.48550/arXiv.1711.07767>.
 - [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. CVPR2016: In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2016.
 - [18] LONG J, SHELHAMER E, and DARRELL T. Fully convolutional networks for semantic segmentation[C]. CVPR2015: In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2015.
 - [19] SZEGEDY C, LOFFFEE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]. AAAI (2017), DOI: <https://doi.org/10.48550/arXiv.1602.07261>.
 - [20] 马露, 裴伟, 朱永英, 等. 基于深度学习的跌倒行为识别[J]. 计算机科学, 2019, 46(9):7.
 - [21] STUKEVE R, ILY A. On the importance of initialization and momentum in deep learning [J]. ICML, 2013, 28 (3): 1139-1147.

作者简介

杨瑾,硕士研究生,主要研究方向为机器学习。

魏巍,博士,教授,主要研究方向为机器人及其自动化技术。

陈灯(通信作者),博士,副教授,主要研究方向为工业机器人智能化技术、多媒体数据处理。

张彦铎,博士,教授,主要研究方向为智能系统的理论研究与应用开发,研究方向包括智能计算(优化)、机器人路径规划、多机器人协作等。

吴云韬,博士,教授,主要研究方向为智能信息处理、智能计算、无线传感器网络技术。

刘玮,博士,教授,主要研究方向为智能软件工程、服务计算、语义计算等方向的研究。

郑朝晖,博士,讲师,主要研究方向为机器视觉、图像处理、生物特征识别等。

E-mail: dchen@wit.edu.cn