

DOI:10.19651/j.cnki.emt.2211195

改进 YOLOv5 的路面缺陷快速检测方法研究^{*}

陈建瑜 邹春龙 王生怀 夏力 陈哲

(湖北汽车工业学院机械工程学院 十堰 442002)

摘要: 为了实现路面缺陷的智能快速化检测,对深度学习目标检测算法 YOLOv5 进行改进,得到的 3 种检测模型 (YOLOv5-A, YOLOv5-C, YOLOv5-AC) 均可采用视频检测的方式对路面 5 类缺陷进行快速检测。采用智能手机和数码相机采集路面缺陷图像并制作数据集,在满足视频检测的需求下,使用 K-means 算法和 1-IoU 作为样本距离重新聚类 anchor,得到更优的锚框参数;在网络多个结构中引入 CBAM 注意力机制,增强模型的特征提取能力。实验结果表明,YOLOv5-C 算法在训练集上的平均精度达到 91.8%,相较于原模型提高 1%;YOLOv5-A 算法在验证集上的平均精度达到 92.7%,相较于原模型提高 1.7%;在实际检测效果上,YOLOv5-AC 算法在裂缝、破碎板和坑洞的识别准确度上达到 89%、62%、90%,相较于原模型提高了 45%、4%、5%,且模型的检测速度达到 40 FPS。YOLOv5-AC 算法具有较高的检测精度和识别速度,一定条件下可以满足在道路缺陷检测中的智能化实时检测需求。

关键词: 道路工程;路面缺陷;YOLOv5;缺陷检测

中图分类号: TP391;U418 文献标识码: A 国家标准学科分类代码: 510.4050

Research on rapid detection method of pavement defects by
improving YOLOv5

Chen Jianyu Zou Chunlong Wang Shenghuai Xia Li Chen Zhe

(School of Mechanical Engineering, Hubei University of Automotive Technology, Shiyan 442002, China)

Abstract: In order to achieve intelligent rapid detection of pavement defects, the deep learning object detection algorithm YOLOv5 is improved, and the three detection models (YOLOv5-A, YOLOv5-C, YOLOv5-AC) can be quickly detected by video detection. Using smart phones and digital cameras to collect road defect images and make data sets, to meet the needs of video detection, the use of K-means algorithm and 1-IoU as sample distance recluster anchor, to obtain better anchor frame parameters; the introduction of CBAM attention mechanism in multiple structures of the network, enhance the feature extraction ability of the model. The experimental results show that the average accuracy of the YOLOv5-C algorithm on the training set reaches 91.8%, which is 1% higher than that of the original model. The average accuracy of the YOLOv5-A algorithm on the verification set reaches 92.7%, which is 1.7% higher than that of the original model. In terms of actual detection effect, the YOLOv5-AC algorithm achieves 89%, 62%, and 90% in the identification accuracy of cracks, broken plates and pits, which is 45%, 4%, and 5% higher than the original model. And the detection speed of the model reaches 40 FPS. YOLOv5-AC algorithm has high detection accuracy and recognition speed, and can meet the intelligent real-time detection requirements in road defect detection under certain conditions.

Keywords: road engineering; pavement defects; YOLOv5; defect detection

0 引 言

近年来,车辆急剧增多、货车超限超载、恶劣天气以及路面的自然退化等因素均对路面结构造成不同程度的损

害,甚至形成路面破损,如坑槽、裂缝以及塌陷,若不及时发现并修复这些缺陷,将会直接影响到交通效率和行车安全。为了营造良好的道路交通环境,更好地保障道路性能和交通安全,对路面缺陷进行快速而准确的检测和定位具有十

收稿日期:2022-08-27

^{*} 基金项目:国家自然科学基金(51675167)、湖北省重点研发计划项目(2021BAA056)、湖北省高等学校优秀中青年科技创新团队计划项目(T2020018)、湖北省自然科学基金(2020CFB755)、湖北省教育厅科研项目(Q20191801)资助

分重要的意义。

目前在缺陷检测领域主要有以下两大类算法。One-stage 检测的 YOLO 系列:马燕婷等^[1]在 YOLOv5 主干网络中引入 Transformer 自注意力机制对带钢表面缺陷进行识别,图片尺寸为 256×256 时每秒传输帧数(frames per second, FPS)达到 65.4。李衍照等^[2]引入轻量型的 GhostNet 网络代替 YOLOv5 主干网络中 CSP1 模块下的残差模块,进而对金属焊缝进行检测。许思昂等^[3]通过增加 YOLOv5 的注意力机制 SE_block,使模型识别 PCB 板的平均精度提高了 1.8%。王淑青等^[4]对瓷砖缺陷数据集进行切图分割与数据增强处理,在 YOLOv5 模型上的平均检测时间仅有 14 ms。颜学坤等^[5]通过调整 YOLOv5 网络的检测头个数和尺寸来解决印花疵点目标较小的问题。Sun 等^[6]为提高 YOLOv5 在不同尺度下对光伏板热斑的检测精度,采用 K-means 聚类算法对数据标注帧的长宽比进行聚类,并添加一组值较小的锚点,通过优化聚类数量来实现对小目标的检测。余加勇等^[7]通过集成深度学习 YOLOv5 和 U-Net3+ 算法一体化的方法实现桥梁裂缝智能检测。Liu 等^[8]提出一种裂缝数据的图像增强算法,使得 YOLOv5 对裂纹的识别精度达到 84%。郝帅等^[9]改进 YOLOv5 检测框架 neck 中的结构,增强输电线路故障语义信息的跨尺度特征融合。史梦圆等^[10]用轻量化模块组合作为主干检测网络对建筑物破损进行检测,降低 YOLOv5 的网络参数,提高了网络运行速度;Two-stage 检测的 RCNN 系列:向宽等^[11]在 Faster R-CNN 主干网络加入特征金字塔网络结构以加强对小缺陷的特征提取能力,不过每张图的检测时间至少需要 0.257 s。伊欣同等^[12]基于 Faster R-CNN 引入残差通道注意力机制提高其精度,但是每张照片的检测时长超过 130 ms。当前缺陷检测的研究对象主要是金属表面、PCB 板表面、瓷砖印花表面、桥梁建筑表面,而在路面缺陷检测上研究较少,且存在路面缺陷识别种类少、无法满足 $1\ 920 \times 1\ 080$ 大尺寸图像实时检测的问题。

为了解决以上问题,本文提出一种改进 YOLOv5 的路面缺陷实时检测算法。实验对象主要为公路路面中的水泥

混凝土路面,根据 JTG 5210-2018《公路技术状况评定标准》^[13],对生活中常见的裂缝、破碎板、坑洞、修补这 4 类损坏进行检测,为了降低算法对道路分界线的误识率,将分界线也作为缺陷进行训练,总共涉及 5 类目标检测。

1 数据集制作

水泥混凝土路面缺陷图像数据来源于当地普通公路,采集的方式主要包括两种:一种是将手机固定在汽车副驾驶遮阳板位置,随着汽车的前进拍摄路面各种缺陷情况;另一种是将手机固定在手机支架上,手持支架沿缺陷路面向前平推。采集后的视频数据通过 Python 脚本切分成图片,图像分辨率为 $1\ 920 \times 1\ 080$,后期经过筛选得到 2 600 张,其中裂缝照片 610 张、破碎板 500 张、坑洞 550 张、修补 470 张、分界线 470 张,且大多数图片里面的缺陷数量不止一个,采用开源图像标注工具 LabelImg 对这 2 600 张照片进行标注,将缺陷图像分为训练集和验证集,划分比例为 9:1,其中训练集 2 340 张,验证集 260 张,由 Python 统计划分后的训练和验证标注文件得到各自的分类结果如表 1 所示。

表 1 数据集中各类图像及缺陷数量

缺陷类型	简写	图像数量	训练集	验证集	缺陷总计
裂缝	LF	610	1 660	184	1 844
破碎板	PSB	500	757	71	828
坑洞	KD	550	1 085	122	1 207
修补	XB	470	546	57	603
分界线	FJX	470	2 324	264	2 588
合计		2 600	6 372	698	7 070

图 1 所示为数据集的 5 类缺陷,其中第 1 行是原始采集图像,第 2 行是标注后图像,可知图 1(a)标注 1 处裂缝,图 1(b)标注 2 处破碎板,图 1(c)标注 4 处坑洞,图 1(d)标注 1 处修补,图 1(e)标注 9 处分界线,其中分界线主要指白色和黄色的虚线。总共对 2 600 张照片进行标注,得到 7 070 处缺陷,将该数据集划分成训练集和验证集用于训练和检验。




图 1 原始图像及标注图

2 算法原理与改进

2.1 YOLOv5 原理

YOLOv5 是基于回归方法的端到端的目标检测算法,

其直接通过一个深度卷积神经网络将原始图像数据信息转变为目标物体的类别、位置和置信度信息,把目标检测问题转化为回归问题,得到边界框和类别置信度,这种端到端的一步式处理方法使检测速度得到极大提升,适用于

实时检测,并且该算法通用性强,检测准确率高。

YOLOv5 按照模型大小可分为 4 个版本,依次为 s、m、l、x,各模型仅在网络的深度和宽度上有所不同,且均由输入端、Backbone、Head 和 Detect 这 4 部分组成。输入端使用 Mosaic 数据增强、图片缩放等对图像进行预处理; Backbone 部分共有 10 层(0~9),采用 Focus 下采样、C3 模块、空间金字塔池化(spatial pyramid pooling, SPP)结构提取图片的特征信息; Head 部分共有 14 层(10~23),通过采用特征金字塔网络(feature pyramid network, FPN)和路径聚合网络(path aggregation network, PAN)的双向特征金字塔结构,实现不同尺寸目标特征信息的传递,解决了多尺度问题; Detect 部分采用 3 种损失函数分别计算分类、定位和置信度损失,并通过非极大值抑制(non-maximum suppression, NMS)提高网络预测的准确度。YOLOv5s 的具体网络结构如图 2 所示。

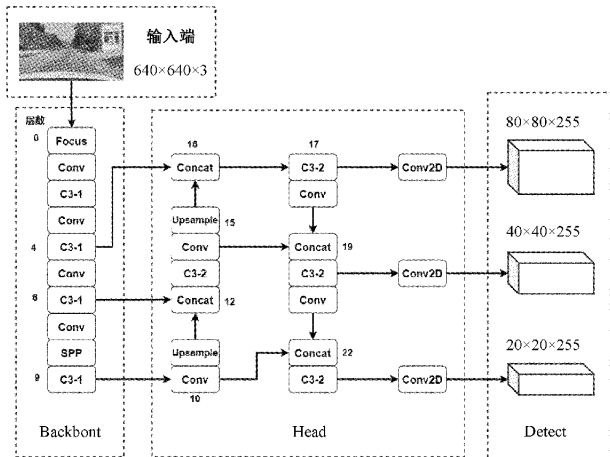


图 2 YOLOv5 架构

YOLOv5s 输入端的尺寸大小为 640×640 ,采用 3 通道 RGB。Backbone 中的 Conv 复合模块是卷积的基础模块也是核心模块,在这一模块将进行一系列的权重学习和非线性激活;Conv2D 赋予网络强大的学习能力,将信息提取转化为权重矩阵;批量归一化(batch normalization, BN)层可以加快网络的训练和收敛速度,防止网络过拟合;非线性激活函数使得网络能够学习实际中更加复杂的模型,该复合模块的具体结构如图 3 所示。




图 3 Conv 结构

Focus 模块是在图片进入 Backbone 之前,对图片进行切片操作,具体操作是在一张图片中每隔一个像素取一个值,这样做的结果是 W、H 分别减少为原来的一半,而通道数扩充为原来的 4 倍,目的是为了减少网络的参数量和计算量,提高网络速度,但相比于卷积模块降低了平均精度,其具体结构如图 4 所示。




图 4 Focus 结构

YOLOv5 网络的 C3 结构包含 3 个标准卷积层以及多个 Bottleneck 模块,如图 5 所示,输入特征首先被分成两个通道进行卷积,其中一个与多个 Bottleneck 模块相连,然后该通道与另外通道进行拼接,最后经过一个 Conv 模块进行输出。




图 5 C3 结构

在 YOLOv5 网络中,分支中使用 Bottleneck1 的为 C3-1 结构,其主要应用在 Backbone 中;分支中使用 Bottleneck2 的为 C3-2 结构,其主要应用在 Head 中, Bottleneck 的两种结构主要区别是否使用 shortcut 捷径分支,具体结构如图 6 所示。




图 6 Bottleneck 的两种形式

SPP 是空间金字塔池化的简称,其先通过一个标准卷积模块将输入通道减半,然后分别做卷积核大小为 5,9,13 的最大池化,对三次池化的结果与未进行池化操作的数据进行拼接,合并后通道数是原来的 2 倍,具体结构如图 7 所示。




图 7 SPP 结构

2.2 anchor 改进

anchor^[14]是一种先验框,YOLOv5 的 anchor 值是基于 COCO 数据集得到的,而针对本文数据集,因其裂缝缺

陷长宽比差异较大,所以有必要重新聚类本数据集的 anchor,选择合适的 anchor,有利于网络学习得到更好的检测器。传统的 K-means 算法聚类主要采用的是欧氏距离,但是通过实验发现采用 1-交并比(intersection over union, IoU)表示距离计算效果会更好,IoU 指的是 anchor 与物体边界框的交并比,如果簇中心的 anchor 与对应物体边界框的 IoU 越大,则 1-IoU 值越小,距离也就越近。YOLOv5 的 anchor 处理机制是首先会自动计算默认的 anchor 与数据集中最可能的召回率(best possible recall, BPR),当 $BPR < 0.98$ 才会根据数据集中的目标重新生成 anchor。采用欧氏距离的 K-means 算法训练时输出的 anchor 与匹配的目标框比值为 3.88, $BPR = 0.9932$,通过 1-IoU 作为距离表示的 K-means 聚类改进 anchor 后,anchor 与匹配的目标框比值达到 4.03, BPR 达到 0.9998,表明目标匹配的 anchor 数和 BPR 均得到了提升。输入参数的设置为图像大小 $img_size = 640$,生成 anchor 个数 $n = 9$,置信度阈值 $thr = 0.25$,变异次数 $gen = 1000$,新生成的 anchor 记为 anchor_new,其具体值如表 2 所示。

表 2 不同 anchor 对应的值

anchor 类型	尺寸值
原始 anchor	[10,13,16,30,33,23]
	[30,61,62,45,59,119]
	[116,90,156,198,373,326]
anchor_new	[12,7,24,10,40,17]
	[51,41,116,32,65,108]
	[208,78,142,190,372,212]

2.3 加入 CBAM 注意力机制

卷积注意力模块(convolutional block attention module, CBAM)^[45]是一种轻量的注意力模块,可以在通道和空间两个维度上进行关注,相比于只关注通道的注意力机制 SeNet 可以取得更好的效果,由于该模块更关注识别目标物体,这也使得 CBAM 具有更好的解释性。该模块有两个子模块:通道和空间,在深度网络的每个卷积块上,通过 CBAM 可以自适应地细化中间特征映射。

1) 通道注意力模块

将输入的特征图分别经过基于宽和高的全局最大池化和全局平均池化,然后分别经过多层感知器,将其输出的特征进行加和操作、Sigmoid 激活操作,生成最终的通道注意力特征图,将该特征图和输入的特征图做乘法操作,生成空间注意力模块需要的输入特征。

2) 空间注意力模块

将通道注意力模块输出的特征图作为本模块的输入特征图,首先经过基于通道的全局最大池化和全局平均池化,然后将这 2 个结果在通道上拼接,其次经过一个卷积操作,降维为 1 个通道,再经过 Sigmoid 生成空间注意力特

征图,最后将生成的特征图和该模块的输入特征图做乘法,得到最终生成的特征。

对于本次改进的 CBAM 模块,空间注意力的参数包括输入通道 $C1$,缩减率 $ratio = 16$,通道注意力模块的卷积运算 $Kernel_size = 7$ 。将 CBAM 加在 Conv 模块之后,使其构成 Conv_CBAM 复合模块,为了更清晰的了解该复合模块的功能,使用该复合模块分别替换 Backbone 的 4 个 Conv 层、Head 部分的第 3、4 个 Conv 层、Head 部分的第 2、3、4 个 Conv 层、Head 部分的 4 个 Conv 层,这些模型分别简记为 Backbone、Head34、Head234、Head,以期得到更高的检测平均精度,并在下文的试验中验证了其改进效果。

3 试验结果与分析

3.1 实验环境与参数设置

路面缺陷快速智能化检测方法的数据集训练设备基于 Windows10、64 位专业版操作系统,处理器为 Intel(R) Core(TM) i7-9700 CPU@3.00 GHz (8 CPUs),GPU 为 NVIDIA GeForce RTX 2070,显卡内存为 16 G;深度学习环境为 Python 3.8、框架为 Pytorch 1.10.0、CUDA 10.2,所有模型采用的预训练权重均为 YOLOv5s.pt、批大小 Batchsize 为 32、训练代数 Epoch 为 150;验证集的权重为相应模型训练生成的最佳权重 best.pt,输入参数中的置信度阈值为 0.25, IoU 阈值为 0.45;实际照片或视频的检测设备为 2020 版华为 MateBook14 笔记本。

3.2 模型评价指标

采用精准率 P 、召回率 R 、 $mAP@.5$ 、 $mAP@.5:.95$ 、 $F1$ 、每张照片的检测总时间来衡量本次缺陷检测模型。其中,精准率、召回率分别反映模型的查准率和查全率, $F1$ 值是综合考虑精准率和召回率, $mAP@.5$ 表示 IoU 阈值为 0.5 时的平均精度, $mAP@.5:.95$ 代表 IoU 阈值从 0.5~0.95,步长为 0.05 时各个 mAP 的平均值,而每张照片检测所需的总时间是决定能否实现视频快速检测的关键参数。

3.3 实验结果分析

本次实验主要对 anchor 和 CBAM 注意力机制进行了改进,模型的参数量在 710 万左右,训练时间在 12~13 h 之间,最终生成的模型权重大小在 14 M 左右,其中改进 anchor 实验结果如表 3 所示,改进 CBAM 注意力机制结果如表 4 所示。

由表 3 可知,经过优化 anchor 后模型的精准率提高了 2.8%,而召回率仅降低 1.2%,mAP 在 IoU 为 0.5、0.5~0.95 时分别提高 0.6%、1.3%, $F1$ 值也提高了 0.9%,并且每张照片的检测总时间与原模型一致,将优化后的 anchor_new 模型称为 YOLOv5-A。

由表 4 可知,增加 CBAM 模块之后的网络相较于原网络的 mAP 均有所提升:最少为加在 Backbone 部分,其值

表3 不同 anchor 下的训练结果

模型	精准率	召回率	$mAP@.5$	$mAP@.5:.95$	F1	检测时间/s
YOLOv5	0.835	0.898	0.908	0.633	0.865	0.023
anchor_new	0.863	0.886	0.914	0.646	0.874	0.023

表4 Conv_CBAM 模块替换位置及其训练结果

模型	精准率	召回率	$mAP@.5$	$mAP@.5:.95$	F1	检测时间/s
YOLOv5	0.835	0.898	0.908	0.633	0.865	0.023
Backbone	0.860	0.872	0.910	0.642	0.866	0.030
Head34	0.863	0.877	0.913	0.641	0.870	0.027
Head234	0.848	0.901	0.918	0.637	0.874	0.025
Head	0.886	0.856	0.917	0.642	0.871	0.026
Backbone+Head	0.876	0.879	0.912	0.642	0.878	0.031

为91%,提升0.2%;最多为加在Head234部分,其值为91.8%,提升1%。在检测总时间上,由于视频实时检测至少需要30帧,因此每张照片的检测时间应小于0.033s,而表格中最大的检测时间不超过0.031s,因此均满足视频实时检测要求。此次模型最终的评价指标为 $mAP@.5$ 和检测时间,由表4结果可知将Conv_CBAM模块替换在Head234部分最合理,在满足视频检测的条件下又最大限度提升模型的识别精度,将这一网络用YOLOv5-C表示。

为了直观展示改进算法在路面缺陷检测中的性能,以识别精度和速度为评价指标,本文进行了消融实验,IoU为0.5时的 mAP 和检测速度如表5所示。

表5 消融实验结果

组号	YOLOv5	anchor_new	Head234	$mAP/\%$	FPS
1	√	×	×	90.8	43
2	√	√	×	91.4	43
3	√	×	√	91.8	40
4	√	√	√	91.2	32

由表5可知,在识别精度方面,2、3、4组这3种改进模型相较于第1组均有提升,Head234模型提升最多,为1.0%;在检测速度方面,改进anchor后的模型检测速度与原始模型一致,第3、4组的值虽然比43稍低,但都满足视频30帧实时检测需求。

为了进一步观察上述模型在验证集上的效果,将同时改进anchor和CBAM注意力机制这种模型称为YOLOv5-AC,它们的P-R曲线如下图8所示。

从验证集的平均精度来看,图8(a)为原始算法P-R曲线图,图8(b)中改进anchor后的YOLOv5-A算法为4种模型中最优,置信度为0.5时 mAP 相较于原算法提升1.7%,对裂缝、破碎板和修补的识别精度分别提高3%、2.8%和1.9%,图8(c)中改进CBAM算法的 mAP 提升

1.1%,同时改进这两种优化方案的曲线图如图8(d)所示,其 mAP 与原始网络值一致。

为了测试以上模型的实际效果,用以下图像进行检测,这些图像均来自训练集和验证集之外,保证图像检验的可靠性与有效性,图9展示了上述4种模型对裂缝、破碎板和坑洞这3类缺陷的检测效果。

由图9可知,在裂缝检测方面,改进的3种算法检测效果均比原始算法好,尤其是YOLOv5-C和YOLOv5-AC算法还准确地多识别出一条裂缝,且在YOLOv5-AC算法中两条裂缝的识别准确率都最大,值得注意的是,模型并没有识别每段水泥路面正常的纵向和横向裂缝;在破碎板检测方面,YOLOv5-A和YOLOv5-AC算法均能识别出两块破碎板,不过YOLOv5-C算法能较完整识别出一整块破碎板;在坑洞检测方面,以上4种算法都能准确识别出5个小坑洞,准确度最高的还是YOLOv5-AC算法,在原始算法检测坑洞为85%的情况下仍能提升5%的准确率。从实际检测效果来说,YOLOv5-AC算法在以上3种缺陷检测方面都优于原始算法和改进的另外两种算法,证明该网络提取到了更加丰富的语义信息,进而表现出更好的性能。

3.4 不同算法对比

为了更好地展示YOLOv5的实验结果,在训练设备配置不变的条件下,通过自制的路面缺陷数据集分别在Faster R-CNN和YOLOv4模型上作对比实验,实验结果如表6所示。

由表6可知,从检测平均精度来看,文中所用模型的 mAP 值为91.8%,分别较Faster R-CNN、YOLOv4网络模型的 mAP 提高了3.2%、9.3%。同时,该模型每秒能检测的图片数量达到40,相较于其他2个网络模型的FPS分别提高了27、12。该结果表明本文所用算法优于Faster R-CNN和YOLOv4这2种目标检测算法,并且能够满足路面缺陷的实时检测需求。




图 8 各模型验证集的 P-R 曲线




图 9 4 种模型下的检测效果

表 6 对比实验结果

算法名称	主干网络	mAP/%	FPS
Faster R-CNN	ResNet50	88.6	13
YOLOv4	CSPDarkNet53	82.5	28
本文算法		91.8	40

4 结 论

针对道路缺陷的快速智能化检测,提出一种新的路面缺陷快速检测模型,基于目前检测速度较快的单阶段目标检测算法 YOLOv5,通过优化路面缺陷数据集的先验 anchor 和引入 CBAM 注意力机制来提高模型的检测精度,最终在训练集和验证集上的检测精度最高达到 91.8%、92.7%,实际照片中的裂缝、破碎板、坑洞的准确率识别达到 89%、83%、90%,并且检测速度达到 40 FPS,该模型基本能实现对路面常见缺陷的快速智能化检测。

在上述试验结果中,破碎板和坑洞这两种缺陷的识别准确率虽然都超过 90%,但是裂缝检测的最高准确率也只有 81.3%,其主要原因可能是在标注时采用的两点形成矩形框,标注斜裂缝就会包含很多的背景干扰信息,影响网络对裂缝信息的提取,如果采取三点式平行四边形替代矩形,可能会显著提高裂缝的检测准确性;另外,缺陷在光照强度不足、局部被遮挡和复杂天气情况下,如雨雪、雾霾等,检测会部分失效,在未来工作中可考虑增加图片预处理将其亮度调至合适值,在数据集中增加缺陷被遮挡和特殊天气的缺陷照片,并且采用带定位的高清设备来采集图像,进而提高模型在实际复杂情况下的应用能力,这对减轻部分人工检测的工作量和降低路面缺陷的检测成本具有一定的参考意义。

参考文献

- [1] 马燕婷,赵红东,阎超,等.改进 YOLOv5 网络的带钢表面缺陷检测方法[J].电子测量与仪器学报,2022,36(8):150-157,DOI:10.13382/j.jemi.B2205354.
- [2] 李衍照,于镭,田金文.基于改进 YOLOv5 的金属焊缝缺陷检测[J].电子测量技术,2022,45(19):70-75,DOI:10.19651/j.cnki.emt.2209590.
- [3] 许思昂,李艺杰,梁桥康,等.基于改进 YOLOv5 算法的 PCB 裸板缺陷检测[J].包装工程,2022,43(15):33-41.
- [4] 王淑青,张鹏飞,要若天,等.基于改进 YOLOv5 的太阳能电池片表面缺陷检测[J].仪表技术与传感器,2022(5):111-116.

- [5] 颜学坤,楚建安.基于 YOLOv5 改进算法的印花图案疵点检测[J].电子测量技术,2022,45(4):59-65.
- [6] SUN T Y, XING H S, CAO S X, et al. A novel detection method for hot spots of photovoltaic (PV) panels using improved anchors and prediction heads of YOLOv5 network[J]. Energy Reports,2022,8(S13), DOI: 10.1016/J. EGYR. 2022. 08. 130.
- [7] 余加勇,刘宝麟,尹东,等.基于 YOLOv5 和 U-Net3+ 的桥梁裂缝智能识别与测量[J].湖南大学学报(自然科学版),2023,50(5):65-73,DOI:10.16339/j.cnki.hdxzbk.2023056.
- [8] LIU J, ZHAO Z Y, LYU C S, et al. An image enhancement algorithm to improve road tunnel crack transfer detection [J]. Construction and Building Materials, 2022, 348, DOI: 10.1016/J. CONBUILDMAT. 2022. 128583.
- [9] 郝帅,杨磊,马旭,等.基于注意力机制与跨尺度特征融合的 YOLOv5 输电线路故障检测[J].中国电机工程学报,2023,50(5):65-73,DOI:10.16339/j.cnki.hdxzbk.2023056.
- [10] 史梦圆,高俊钊.改进 YOLO v5 的建筑物破损检测算法研究[J].国外电子测量技术,2022,41(8):84-90.
- [11] 向宽,李松松,栾明慧,等.基于改进 Faster RCNN 的铝材表面缺陷检测方法[J].仪器仪表学报,2021,42(1):191-198.
- [12] 伊欣同,单亚峰.基于改进 Faster R-CNN 的光伏电池内部缺陷检测[J].电子测量与仪器学报,2021,35(1):40-47.
- [13] 交通运输部公路科学研究院.公路技术状况评定标准:JTG 5210-2018[S].北京:人民交通出版社,2018.
- [14] 伏轩仪,张鑫景,梁文科,等.锚点机制在目标检测领域的发展综述[J].计算机科学与探索,2022,16(4):791-805.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018, 1: 3-19.

作者简介

陈建瑜,硕士研究生,主要研究方向为人工智能与机器视觉技术。

E-mail:jy_chen331@qq.com

王生怀(通信作者),教授,博士,主要研究方向为精密测量。

E-mail:shwangkb@163.com