

目标检测与图像分类网络融合的金属化陶瓷环缺陷检测

满英杰¹, 王宪^{1*}, 孙冬悦¹, 邓宁道¹, 吴士旭²

¹湖南科技大学机电工程学院, 湖南 湘潭 411201;

²长沙视浪科技有限公司, 湖南 长沙 410006

摘要 针对金属化陶瓷环缺陷面积小、可利用信息少的特点和缺陷检测精度低的问题,提出一种目标检测与图像分类网络融合的金属化陶瓷环缺陷检测方法。首先,使用针对小面积目标检测特点改进的 Faster-RCNN 目标检测网络实现对缺陷的初步识别与定位。接着,使用插值方法将定位到的缺陷区域放大,利用图像相邻像素之间的信息关联,增加缺陷检测的特征信息量。然后,使用 ResNet 图像分类网络对放大后的区域进行缺陷类别判断。最后,融合目标检测网络和图像分类网络的结果,获得最终的缺陷检测结果。实验结果表明,所提方法能在保障缺陷检测查全率的同时有效提升查准率,且能准确定位缺陷区域。

关键词 金属化陶瓷环; 缺陷检测; Faster-RCNN; 模型融合; 小目标检测

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP222981

Defect Detection of Metallized-Ceramic Rings Based on Fusion of Object Detection and Image Classification Networks

Man Yingjie¹, Wang Xian^{1*}, Sun Dongyue¹, Deng Ningdao¹, Wu Shixu²

¹*School of Mechanical Engineering, Hunan University of Science and Technology, Xiangtan 411201, Hunan, China;*

²*Changsha Shi-lang Technology Co., Ltd., Changsha 410006, Hunan, China*

Abstract Aiming at the characteristics of small defect areas and less available information of metallized-ceramic rings, and the problem of low defect detection accuracy, a defect detection method of metallized-ceramic rings based on the fusion of target detection and image classification networks is proposed. First, an improved Faster-RCNN target detection network for small-area target detection is used to realize the preliminary identification and location of the defects. Then, the interpolation method is used to enlarge the located defect area, and the information association between the adjacent pixels of the image increases the feature information of the defect detection. Moreover, the ResNet image classification network is used to judge the defect category of the enlarged area. Finally, the final defect detection results were obtained using the target detection and image classification network results. The experimental results show that the proposed method can effectively improve the precision while ensuring defect detection recall and accurately locate the defect area.

Key words metallized ceramic ring; defect detection; Faster-RCNN; model fusion; small object detection

1 引言

金属化陶瓷环作为一种新型器件,广泛应用于 5G 基站、新能源汽车等领域^[1]。由于金属化陶瓷环生产工艺复杂、体积小、陶瓷原料加工难度大,生产过程中

不可避免地会出现各种缺陷。包含缺陷的金属化陶瓷环如果投入使用将会带来多种问题,如缺损(lack)会使导电陶瓷环发生短路,浆点(pulp point)会使得其作为滤波器元件时滤波效果不明显,有必要在出产前对其进行缺陷检测。目前,金属化陶瓷环缺陷检测主要

收稿日期: 2022-11-07; 修回日期: 2022-12-11; 录用日期: 2022-12-23; 网络首发日期: 2023-01-05

基金项目: 国家重点研发计划(2018YFB1308200)、国家自然科学基金(51405154)、湖南省自然科学基金(2021JJ30251, 2018JJ3167)、国家留学基金委公派访问学者项目(202008430103)

通信作者: *15111388435@163.com

通过人工肉眼观察实现,检测效率低、稳定性差、精度难以保证。因此,发展金属化陶瓷环自动缺陷检测技术具有重要的实际意义。

近年,基于机器视觉的缺陷检测技术发展迅速,已经成为缺陷检测的主流方法^[2]。机器视觉缺陷检测可分为传统方法和基于深度学习的方法两大类^[3]。传统方法依据缺陷特点,采用人工设计的图像特征和判断准则完成缺陷检测,可分为统计法、滤波法、模型法等。统计法根据图像的统计分布特征对缺陷进行特征分析和识别。Boukouvalas 等^[4]提出了一种利用图像直方图特征的瓷砖缺陷检测方法;Nand 等^[5]通过使用图像直方图特征来识别钢表面的水滴、划伤等缺陷。滤波法通过分析缺陷与正常图像的不同响应来识别缺陷。Tsai 等^[6]提出了一种基于傅里叶变换的纺织物和木材缺陷检测方法;Choi 等^[7]通过组合两个滤波器,有效提升了缺陷检测的准确率。模型法通过分析纹理的属性并建立纹理的图像表征,用识别异常纹理进行缺陷检测。徐科等^[8]提出一种基于隐马尔可夫树模型的带钢表面缺陷检测方法;Xie 等^[9]利用纹理范式模型实现了对陶瓷表面的缺陷检测。

与传统方法相比,深度学习方法利用标注数据自动提取图像的特征,不需要人工设计特征。近年,基于深度学习的方法在大多数应用场合均表现出了显著优于传统方法的性能,国内外学者使用图像分类网络、图像分割网络和目标检测网络等发展了大量缺陷检测方法。Shang 等^[10]应用图像分类网络实现对钢轨表面缺陷的检测。Natarajan 等^[11]提出一种传统方法与图像分类方法结合的钢轨表面缺陷检测方法。Liang^[12]将图像分类、目标检测和网络分割网络同时用于桥表面缺陷检测。郭龙源等^[13]利用改进的图像分割网络 Mask R-CNN,实现了对磁瓦表面缺陷的检测。

与其他网络相比,目标检测网络在缺陷检测领域的应用更为成功。以 SSD^[14]和 YOLO^[15]为代表的单阶段目标检测网络和以 Faster-RCNN^[16]为代表的两阶段目标检测网络均广泛应用于缺陷检测,单阶段检测网络检测速度更快,两阶段检测网络精度更高。李瑞生等^[17]利用改进的 SSD 网络进行输电线路销钉的缺陷检测。Zhang 等^[18]采用 YOLOv3 目标检测网络实现了对桥梁表面的缺陷检测。陈仁祥等^[19]针对噪声干扰下的印刷电路板,提出一种基于多注意力 Faster-RCNN 的缺陷检测方法。Tao 等^[20]设计了一种用于无人机电力巡检绝缘子缺陷的 Faster-RCNN。目标检测网络用于特征信息较为丰富的缺陷检测时能获得较好的效果,但用于小缺陷识别时表现较差。金属化陶瓷环自身体积较小,缺陷面积更为微小;以 2448×2048 像素的分辨率采集的金属化陶瓷环图像中,某些缺陷只有 8×8 像素左右;能够用于缺陷检测的特征信息极少。现有基于目标检测网络的缺陷检

测方法尚不能满足金属化陶瓷环自动缺陷检测的要求。

针对上述问题,本文提出了一种目标检测与图像分类网络融合的缺陷检测方法。该方法首先使用针对小面积目标检测特点改进的 Faster-RCNN 对缺陷进行初步识别与定位;接着,使用插值方法放大目标检测网络定位到的缺陷区域,利用图像相邻像素之间的信息关联,增加小面积缺陷检测的特征信息量;然后,使用 ResNet 图像分类网络对放大后的缺陷区域进行缺陷类别判断;最后,融合目标检测网络和图像分类网络的输出,修改结果,获得最终的缺陷检测结果。实验结果表明,所提方法能在保障缺陷检测查全率的同时有效提升查准率,且缺陷区域定位准确。

2 金属化陶瓷环缺陷分析

2.1 缺陷种类

现场采集的金属化陶瓷环图像如图 1 所示,金属化陶瓷环由金属层(metal layer)和陶瓷层(ceramic layer)两部分组成。缺陷主要可分为 5 种类型,分别是黑斑(black spot)、缺损(lack)、针孔(pinhole)、浆点(pulp point)、脱落(fall off)。如图 2 所示,黑斑是指陶瓷层出现的黑色斑点,形状一般为圆形;缺损是指部分金属层边缘的缺失;针孔是指金属层表面出现小而深的缺陷;浆点是指金属层表面的坑洼,形状多为圆形且缺陷边缘会凸起;脱落是指金属层较大面积的缺失。缺损、针孔、浆点、脱落 4 类缺陷均出现在金属层上,黑斑缺陷出现在陶瓷层上。




图 1 金属化陶瓷环

Fig. 1 Metallized ceramic ring

2.2 缺陷检测难点

金属化陶瓷环的缺陷检测存在几个难点。1)缺陷面积极小。采用高分辨率工业相机采集的金属化陶瓷环样本的大小为 2448×2048 像素,大多数缺陷的大小在 32×32 像素以下,特别是针孔缺陷,只有 8×8 像素左右。2)部分缺陷样本数量少。从车间采集到的样本有 2235 个,共存在 3399 个缺陷,其中脱落缺陷最常见,




图2 缺陷种类。(a)黑斑;(b)缺损;(c)浆点;(d)针孔;(e)脱落

Fig. 2 Defect category. (a) Black spot; (b) lack; (c) pulp point; (d) pinhole; (e) fall off

在所有缺陷中占比 79.1%，而针孔、浆点、黑斑、缺损 4 类缺陷的占比分别只有 10.7%、6.9%、1.7%、1.6%。3)金属层缺陷类间差距小。金属层上可能出现的缺陷有 4 种，一些样本的不同类型缺陷非常相似，难以区分。

小目标检测与识别一直都是计算机视觉的难点。缺陷面积小是实现金属化陶瓷环缺陷视觉检测面临的障碍。

3 所提方法内容

3.1 整体框架

所提缺陷检测方法的整体框架如图 3 所示，分为离线训练和在线检测两个阶段。离线训练阶段，采用迁移学习和数据集增强解决样本相对较少和不同类别缺陷样本不平衡的问题。在线检测阶段，使用设置了低置信度阈值 T_s 的目标检测网络来初步识别与定位

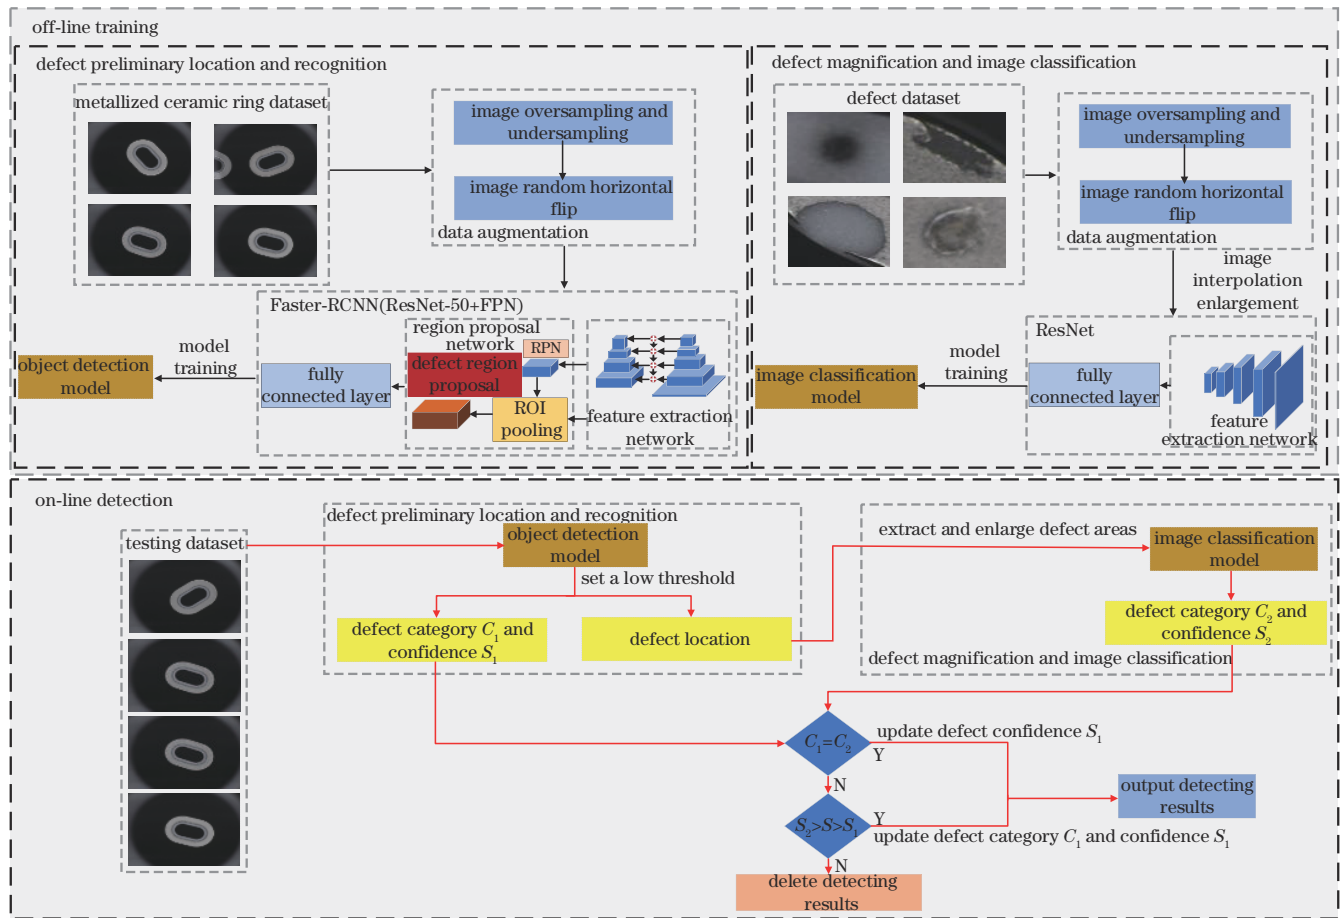


图3 所提缺陷检测方法的整体框架

Fig. 3 Overall framework of the proposed defect detection method

金属化陶瓷环的 5 类缺陷,避免漏检。接着,将定位到的所有缺陷区域提取为图像,对这些图像进行线性插值,放大 G 倍,利用相邻像素之间的信息关联来增加缺陷的特征信息量。然后,将放大后的缺陷图像输入到图像分类网络,进行缺陷分类。最后,融合目标检测模型和图像分类模型得到的结果,输出最终缺陷检测结果,从而在保障缺陷检测查全率的同时有效提升查准率。

3.2 离线训练阶段

针对金属化陶瓷环部分缺陷样本数量少的检测难点,在模型离线训练阶段使用图像欠采样与过采样的方法对数据集进行数据增强。其中,采用图像过采样增加 black spot、pinhole、pulp point、lack 4 种数量少的缺陷样本数量,使用图像欠采样减少 fall off 这类数量过多的缺陷样本数量。数据增强前后的缺陷类别分布如图 4 所示。

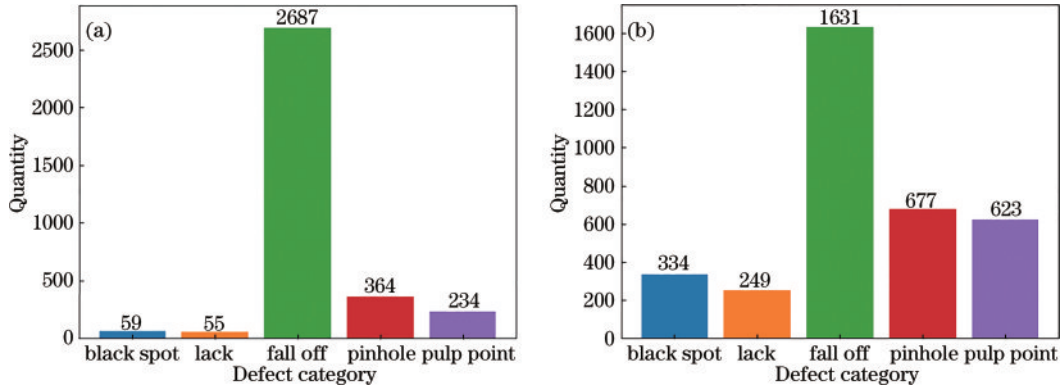


图 4 数据增强前后的缺陷类型分布。(a)数据增强前的缺陷类型分布;(b)数据增强后的缺陷类型分布
Fig. 4 Defect category distribution before and after data augmentation. (a) Defect category distribution before data augmentation; (b) defect category distribution after data augmentation

目标检测模型和图像分类模型的离线训练流程如图 5 所示。1)通过欠采样与过采样、随机水平翻转等方法对原始数据集进行增强,其中图像分类网络在数据增强后还会进行图像放大;2)划分数据集;3)构建网络并加载网络预训练权重,预训练权重由 Common Objects in Context (COCO) 2017 数据集训练得到;4)将训练集数据和验证集数据批量输入到网络中,计算损失,反向传播以更新网络参数;5)达到迭代次数后,保存最终的模型参数。

3.3 在线检测阶段

3.3.1 缺陷初步定位与分类

Faster-RCNN^[16]是一种典型的两阶段目标检测网络。在检测阶段,首先将图像输入特征提取网络得到特征图;然后使用区域候选网络(RPN)生成候选框,并将生成的候选框映射到特征图上;接着使用感兴趣区域池化(ROI pooling)将所有的特征图缩放到相同尺寸;最后,由一系列的全连接层得到目标检测结果。

原始 Faster-RCNN 框架使用 VGG^[21]作为特征提取网络,由于金属化陶瓷环的缺陷面积小,检测难度大,因此本文使用更深层、特征提取能力更强的 ResNet-50^[22]代替 VGG 网络作为特征提取网络。此外,增加了特征金字塔网络(FPN)^[23]实现网络浅层特征和深层特征的融合。改进的特征提取网络如图 6 所示,其中 CBL 模块由卷积层(Conv)、批归一化(BN)、ReLU 激活函数组成。Res 表示一个残差网络结构,可以解决网络层数太深而引起的网络退化问题。增加

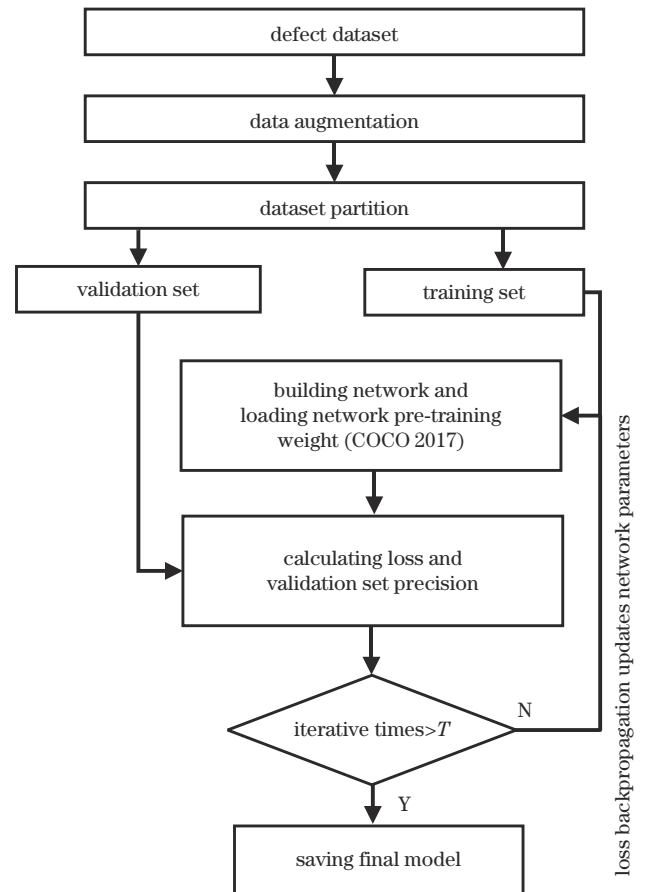


图 5 模型训练流程
Fig. 5 Model training process

置信度为 S_1 ; 如果 S_1 小于 S_2 , 最终检测结果的缺陷类别为 C_2 , 缺陷置信度为 S_2 。

4 实验及分析

4.1 缺陷数据集

实验中所使用的缺陷数据集是研究团队在某金属化陶瓷环生产企业采集实物图片后通过人工标注构建的, 共包含 2235 张分辨率为 $2448 \text{ pixel} \times 2048 \text{ pixel}$ 的样本。经过数据增强后, 按照 8:1:1 划分训练集、验证集和测试集。为了确保训练集、验证集和测试集中均包含一定数量的 5 类缺陷样本, 在随机抽取后对 3 类数据集的样本构成进行了人工微调。

4.2 评价指标

选取查准率 (precision, P)、查全率 (recall, R)、平均精度 (AP) 和各类别平均精度的均值 (mAP) 作为评价指标对模型性能进行验证。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (2)$$

式中: N_{TP} 为真正例 (true-positive) 的数量; N_{FP} 为假正例 (false-positive) 的数量。模型的查全率通过计算检测结果中正确的缺陷数量和图像中所有的缺陷数量的比例得到, 计算表达式为

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (3)$$

式中: N_{FN} 为假反例 (false-negative) 的数量。根据计算得到的查准率 (P) 和查全率 (R), 绘制 P-R 曲线, 曲线下所围成的面积为平均精度。AP 和 mAP 的计算表达式为

$$R_{AP} = \int_0^1 p(r) dr, \quad (4)$$

$$R_{mAP} = \frac{\sum_{i=1}^C R_{AP_i}}{C}, \quad (5)$$

式中: $p(r)$ 表示 P-R 曲线; C 表示缺陷类别总数。本文使用的数据集包含 5 类不同的缺陷, C 取 5。

4.3 实验环境与参数

实验所有算法均是在深度学习工作站上采用 PyTorch 1.7.1 深度学习平台进行的。深度学习工作站使用 Window 10 操作系统, CPU 为 Intel® Xeon (R)

Gold 6139M, 内存为 128 GB, 装有 Nvidia GTX3080 GPU 执行并行计算。

网络模型训练时的超参数设置如下: 目标检测模型使用随机梯度下降 (SGD) 算法作为优化算法, 设置初始学习率为 0.005, 动量设为 0.9, 权值衰减设置为 0.0005; 采用学习率衰减策略, 每迭代 5 次学习率就衰减 1 次, 衰减率为 0.33; 根据 GPU 内存和图像大小, 批处理大小 (batch size) 设置为 8, 训练中的迭代次数 epoch 设为 50; 图像分类模型使用 Adam 算法作为优化算法, 权重更新比例设置为 0.0001, batch size 设置为 4, epoch 设为 30。

所提算法的其他参数设置如下: 图像方法倍数 G 为 10、目标检测网络的置信度阈值 T_s 为 0.01、模型融合时的参数 S 为 0.9、输出最终检测结果时的置信度阈值 E_s 为 0.5。

4.4 实验结果及讨论

4.4.1 定量对比

为了验证所提方法的有效性, 使用所提方法和改进的目标检测模型与现有主流缺陷检测模型进行实验对比。精度和计算资源需求对比如表 1 所示。从表 1 可知: 所提目标检测网络与图像分类网络融合的金属化陶瓷环的缺陷检测方法性能更好, 对 5 类缺陷的 AP 和 mAP 均最高; mAP 比排名第二的网络高 8.7 个百分点。mAP 排名第二的 Faster-RCNN (ResNet-50+FPN) 正是所提方法的目标检测网络, 即使单独使用, 精度也比其他主流缺陷检测模型高, mAP 比原始的 Faster-RCNN (VGG-16) 高 17.5 个百分点。计算资源需求方面, 所提方法不会大幅增加模型参数量 (parameters)、模型体积 (volume) 和模型推理时间 (inference time), 具有较好的计算效率。

为了验证所提方法使用的图像分类网络的合理性, 将目标检测网络 Faster-RCNN (ResNet-50+FPN) 与不同的图像分类网络组合, 得到的实验测试结果如表 2 所示。作为图像分类网络的 ResNet 得到的缺陷检测精度最高, 而使用 VGG 和 AlexNet 网络得到的精度相差不多, 均明显低于 ResNet。

表 1 不同方法的精度和计算资源需求对比

Table 1 Comparison of the precision and computing resource requirement between different methods

Parameter	YOLOv3	SSD	Faster-RCNN (VGG-16)	Faster-RCNN (ResNet-50+FPN)	Proposed method	
AP/%	Pulp point	66.7	78.3	81.2	82.3	96.1
	Pinhole	0	6.8	22.9	75.3	80.5
	Black spot	50.6	90.6	91.2	94.8	100
	Lack	57.1	47.3	56.4	61.0	68.9
	Fall off	36.7	34.9	39.4	65.1	76.7
mAP / %	42.2	51.6	58.2	75.7	84.4	
Parameters / 10^6	62.6	13.7	43.9	41.3	64.8	
Volume / MB	323	105	334	315	405	
Inference time / ms	16.1	18.9	69.9	74.8	146.4	

表 2 网络融合结构中不同网络的精度对比

Table 2 Comparison of the precision of different networks in network fusion architecture

Parameter	Faster-RCNN (ResNet-50+FPN) + VGG		Faster-RCNN (ResNet-50+FPN) + AlexNet		Proposed method
Pulp point	86.6		85.1		96.1
Pinhole	77.2		76.6		80.5
AP/%	Black spot	100	98.9		100
	Lack	63.6	65.1		68.9
	Fall off	68.4	69.6		76.7
mAP/%	79.2		79.1		84.4

仅用精度作为评价指标,无法获得缺陷检测方法在漏检和误检方面的表现。为了更全面地评价所提方法用于缺陷检测的性能,在检测精度对比的基础上,进一步以查准率和查全率作为评价指标,对所提方法与精度较高的 Faster-RCNN(ResNet-50+FPN)模型进行对比,结果如表 3 所示。所提方法能有效提升缺陷的查准率,其中对 fall off 缺陷的查准率提升最明显,从 33.8% 提升到 76.3%;对 pinhole、lack、pulp point 3 类缺陷的查准率也分别提升了 9.4 个百分点、9.3 个百分点、4.2 个百分点;对 5 类缺陷的查全率除了 fall off 也都有一定程度的上升。可以看出,所提方法能保障查全率的同时有效提升查准率,表现出了良好的缺陷检测性能。

表 3 两种方法的查全率和查准率对比

Table 3 Comparison of the precision and recall of two methods units: %

Defect category	Faster-RCNN (ResNet-50+FPN)		Proposed method	
	Precision	Recall	Precision	Recall
	Pulp point	94.2	67.3	98.4
Pinhole	85.2	68.2	94.6	70.1
Black spot	100	62.3	100	62.7
Lack	82.3	73.1	91.6	90.0
Fall off	33.8	84.5	76.3	82.3

4.4.2 定性分析

不同模型的检测效果如图 8 所示。由图 8 可知:




图 8 缺陷检测模型效果对比。(a)YOLOv3;(b)SSD;(c)Faster-RCNN(VGG-16);(d)Faster-RCNN(ResNet-50+FPN);(e)所提方法
Fig. 8 Effect comparison of different defect detection models. (a) YOLOv3; (b) SSD; (c) Faster-RCNN(VGG-16); (d) Faster-RCNN (ResNet-50+FPN); (e) proposed method

YOLOv3 和 SSD 检测精度很低且缺陷定位误差较大; Faster-RCNN(VGG-16)检测精度明显高于 YOLOv3 和 SSD 模型,但是缺陷定位误差仍然较大;Faster-RCNN(ResNet-50+FPN)可以准确定位到缺陷区域,缺陷的漏检情况也较少,但是存在较多的误检;所提目标检测网络和图像分类网络融合的缺陷检测模型可以实现对缺陷区域的准确定位,缺陷的漏检和误检最少。

5 结 论

针对金属化陶瓷环缺陷检测的难点,提出了一种目标检测网络与图像分类网络融合的方法。该方法首先使用针对小面积目标检测特点改进的 Faster-RCNN 对缺陷进行初步识别与定位;接着,将定位到的缺陷区域使用线性插值方法放大,增加缺陷的特征信息量;然后,使用 ResNet 对放大后的缺陷区域进行缺陷分类;最后,融合目标检测网络和图像分类网络的结果,获得最终的缺陷检测结果。实验结果表明,所提方法的检测精度比其他主流缺陷检测模型更高,缺陷区域的定位更准确,缺陷的漏检和误检更少,表现出良好的检测性能。

参 考 文 献

- [1] 李军,程健.复杂背景图像下基于边缘点校验的圆检测方法[J].计算机工程,2018,44(3):259-263.
Li J, Cheng J. Circle detection method based on the edge-point verification was applied to complex background image[J]. Computer Engineering, 2018, 44(3): 259-263.
- [2] Huang W B, Wei P, Zhang M H, et al. Hripcb: a challenging dataset for PCB defect detection and classification[J]. The Journal of Engineering, 2020, 2020(13): 303-309.
- [3] 苏虎,张家斌,张博豪,等.基于视觉感知的表面缺陷检测综述[J].计算机集成制造系统,2023,29(1):169-191.
Su H, Zhang J B, Zhang B H, et al. A review of research on the inspection of surface defects based on visual perception[J]. Computer Integrated Manufacturing Systems, 2023, 29(1): 169-191.
- [4] Boukouvalas C, Kittler J, Marik R, et al. Colour grading of randomly textured ceramic tiles using color histograms [J]. IEEE Transactions on Industrial Electronics, 1999, 46(1): 219-226.
- [5] Nand G K, Noopur, Neogi N. Defect detection of steel surface using entropy segmentation[C]//2014 Annual IEEE India Conference, December 11-13, 2014, Pune, India. New York: IEEE Press, 2014.
- [6] Tsai D M, Heish C. Automated surface inspection of statistical textures[J]. Image and Vision Computing, 2003, 21(4): 307-323.
- [7] Choi D C, Jeon Y J, Kim S H, et al. Detection of pinholes in steel slabs using Gabor filter combination and morphological features[J]. ISIJ International, 2017, 57(6): 1045-1053.
- [8] 徐科,宋敏,杨朝霖,等.隐马尔可夫树模型在带钢表面缺陷在线检测中的应用[J].机械工程学报,2013,49(22):34-40.
Xu K, Song M, Yang C L, et al. The application of a hidden Markov tree model to on-line detection of surface defects for steel strips[J]. Journal of Mechanical Engineering, 2013, 49(22): 34-40.
- [9] Xie X H, Mirmehdi M. TEXEMS: texture exemplars for defect detection on random textured surfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(8): 1454-1464.
- [10] Shang L D, Yang Q S, Wang J N, et al. Detection of rail surface defects based on CNN image recognition and classification[C]//2018 20th International Conference on Advanced Communication Technology (ICACT), February 11-14, 2018, Chuncheon, Republic of Korea. New York: IEEE Press, 2018: 45-51.
- [11] Natarajan V, Hung T Y, Vaikundam S, et al. Convolutional networks for voting-based anomaly classification in metal surface inspection[C]//2017 IEEE International Conference on Industrial Technology, March 22-25, 2017, Toronto, ON, Canada. New York: IEEE Press, 2017: 986-991.
- [12] Liang X. Image-based post-disaster inspection of reinforced concrete bridge systems using deep learning with Bayesian optimisation[J]. Computer-Aided Civil and Infrastructure Engineering, 2019, 34(5): 415-430.
- [13] 郭龙源,段厚裕,周武威,等.基于Mask R-CNN的磁瓦表面缺陷检测算法[J].计算机集成制造系统,2022,28(5):1393-1400.
Guo L Y, Duan H Y, Zhou W W, et al. Surface defect detection algorithm of magnetic tile based on Mask R-CNN[J]. Computer Integrated Manufacturing Systems, 2022, 28(5): 1393-1400.
- [14] 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.
- [15] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [16] 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, 2015, 39(6): 1137-1149.
- [17] 李瑞生,张彦龙,翟登辉,等.基于改进SSD的输电线路销钉缺陷检测[J].高电压技术,2021,47(11):3795-3802.
Li R S, Zhang Y L, Zhai D H, et al. Pin defect detection of the transmission line based on improved SSD[J]. High Voltage Engineering, 2021, 47(11): 3795-3802.
- [18] Zhang C B, Chang C C, Jamshidi M. Concrete bridge surface damage detection using a single-stage detector[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(4): 389-409.
- [19] 陈仁祥,詹赞,胡小林,等.基于多注意力 Faster

- RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
- Chen R X, Zhan Z, Hu X L, et al. Printed circuit board defect detection based on the multi-attentive faster RCNN under noise interference[J]. Chinese Journal of Scientific Instruments, 2021, 42(12): 167-174.
- [20] Tao X, Zhang D P, Wang Z H, et al. Detection of power line insulator defects using aerial images analysed using convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4): 1486-1498.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2022-08-09]. <https://arxiv.org/abs/1409.1556>.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [23] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.