

DOI:10.19651/j.cnki.emt.2210612

一种射频芯片检测中的邦球邦线识别方法

曾子炀¹ 成汉林¹ 周静¹ 刘鹏飞² 罗守华¹

(1. 东南大学生物科学与医学工程学院 南京 210096; 2. 明锐理想科技有限公司 深圳 518000)

摘要: 针对引线键合效果的判定,本文提出了一种基于 AI 的 AOI 检测射频芯片引线键合效果的邦球邦线识别方法。该方法根据邦球邦线识别任务特点,改进了 Mask R-CNN 中特征金字塔层先验框生成机制,同时引入了基于碰撞检测的数据增强方式,提升了网络性能和效率,降低了人工标注成本。结果表明,改进后的 Mask R-CNN 模型可获取射频芯片中邦球和邦线的准确分割位置, mAP 为 85.23%, mIoU 为 71.27%, 单幅射频芯片图像推理耗时约为 1.168 s, 基本满足生产中对于射频芯片装配精度以及速度的要求。通过本方法分割出邦球邦线, 可辅助引线键合效果判断, 在一定程度上提升了效率降低了人工成本。

关键词: 工业应用; 数据增强; AOI; 深度学习; Mask R-CNN

中国分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.604

A recognition method for detecting the solder joint and wire bonding of RF chips

Zeng Ziyang¹ Cheng Hanlin¹ Zhou Jing¹ Liu Pengfei² Luo Shouhua¹

(1. School of Biological Science and Medical Engineering, Southeast University, Nanjing 210096, China;

2. Magic Ray Technology Co., Ltd., Shenzhen 518000, China)

Abstract: This paper proposed a solder joint and wire bonding segmentation approach for detecting the bonding effect of RF chip based on AOI. According to the characteristics of solder joint and wire bonding segmentation task, this method improves the prior frame generation mechanism of the feature pyramid layer in Mask R-CNN. Also, it introduces a data enhancement method based on collision detection, which reduces manual annotation cost. The results show that the improved Mask R-CNN model can obtain the accurate segmentation positions of the solder joint and wire bonding in RF chips with mAP of 85.23% and mIoU of 71.27%. Meanwhile, this method speeds up to 1.168 per image, which basically meets the requirements for RF chip speed in production. Overall, the proposed method achieves high segmentation accuracy and meets the industrial production requirements for timeliness to a certain extent in the solder joint and wire bonding segmentation task.

Keywords: industrial application; data augmentation; AOI; deep learning; Mask R-CNN

0 引言

引线键合是芯片封测领域的芯片焊接和膜片键合工艺中的重要一步,通常指使用金属丝(金线、铝线等)利用热压或超声能源,完成微电子器件中固态电路内部互连接线的连接,即芯片与电路或引线框架之间的连接。通常将需进行引线键合的射频芯片的焊点和焊线细分为第一焊点邦球(靠近芯片本体)、第二焊点邦球(远离芯片本体)以及邦线三部分。工业生产中难免会出现引线键合效果不好的情况,为了防止引线键合不良的芯片流出,多使用自动光学检测(automated optical inspection, AOI)对引线键合效果进

行评估。但实际生产环节中的异常如物料与工艺变换导致的热压过程中焊点变化及邦线断连,会大幅提升引线键合的 AOI 检测误报率^[1],因此需要人工二次核验,造成人力成本的增加。

引线键合 AOI 检测中,邦球与邦线的引线键合效果自动判定一般设置为两步:第一步定位并分割邦球和邦线区域以去除无用的背景信息,第二步在分割后的区域上进行合格性判定^[2]。其中邦球和邦线的分割在整个引线键合效果判定部分起到了关键作用,目前常见的方法有阈值法^[3]、聚类法^[4]、区域生长法^[5]等,而这些传统分割方法精度不足以匹配后续的合格性判定。

随着人工智能(artificial intelligence, AI)技术的蓬勃发展,AI 辅助方法已能一定程度上取代传统 AOI 检测方法的部分环节,如焊点缺陷主动红外检测^[6]与元件焊接 AOI 复判检测^[7]。同时,AI 辅助判定方法也被引入到引线键合效果判定上,Dai 等使用 YOLO 算法对焊盘与引线进行定位并基于定位框判定引线键合效果,但定位框内除焊球与引线之外的背景会影响后续合格性判定^[8];邹德翔使用 Faster R-CNN 定位引线和焊盘,并使用基于 DeepLab-v3+ 算法进行分割^[9],通过二级级联的方式明显不足以满足工业生产的实时性需求。

综上,现有引线键合 AOI 检测中邦球邦线分割方法,无法同时满足工业生产中对于精度与实时性的要求。因此,本研究将问题聚焦于兼顾其分割精度与检测速度要求的邦球邦线分割任务。针对以上任务需求,本文在实际分析任务需求并选择合适解决方案中,均衡考虑了 AOI 检测中的实际应用能力及模型的准确率和实时性,提出一种基于 Mask R-CNN 改进的邦球与邦线的定位与分割新方法。与此同时,本文重点关注方法的精度与实时性,设计了一系列研究实践,研究过程中使用的射频芯片均从实际生产中引线键合过程后直接获取,数据多,实际情况覆盖面大。最终实践结果表明,该方法有效的提升了邦球邦线分割精度以及分割效率,进一步提升了引线键合 AOI 检测效果,从而减少了人力成本。

1 基于 Mask R-CNN 的邦球邦线分割方法

文中提及的射频芯片的邦球邦线示意图与其常见连接状态如图 1 所示。

本文提出的邦球邦线分割方法的构建路线如图 2 所示。首先,通过本文提出的数据增强方式对原始数据进行

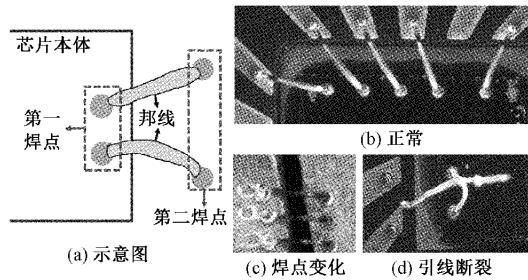


图 1 射频芯片邦球邦线示意图

增强。然后,将数据集中增强数据和原始数据调整为合适比例。最后,使用该数据集训练改进后的 Mask R-CNN 分割网络,并最终构建出邦球邦线分割模型。在神经网络推理阶段,将数据输入至训练好的改进 Mask R-CNN 模型,经由该模型,得到最终分割结果。

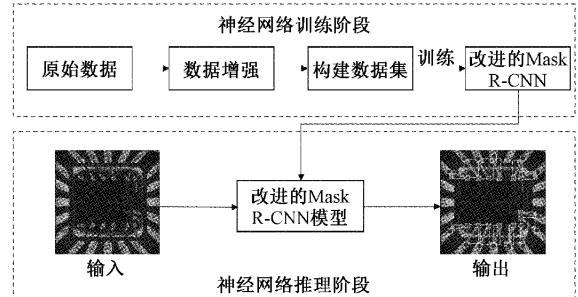


图 2 分割方法构建路线流程图

1.1 针对邦球邦线分割任务的 Mask R-CNN 结构改进

Mask R-CNN 在 Faster R-CNN^[10]基础上,利用特征金字塔(feature pyramid networks, FPN)增加了一些公用特征层,添加了一个语义分割分支,同时将 RoI Pooling 层替换成 RoIAlign 层^[11-12]。Mask R-CNN 的具体结构如图 3 所示。

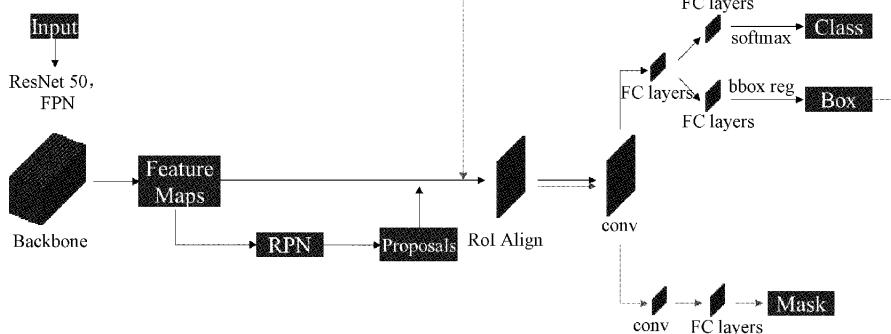


图 3 Mask R-CNN 网络模型结构

原 Mask R-CNN 中的 ResNet+FPN,P2,P3,P4,P5、P6 五个特征层中,对每一个对应层对应的网格点,都生成 3 个先验框,5 层特征层一共生成了约 2.6×10^5 个先验框^[13-14]。其中 P2~P6 层,经过采样层后每一层特征空间包含的采样点逐渐减少。这使得 P2 层框出的先验框占据

的原图像空间像素点与其他 4 层相比最少,而 P3~P6 生成的先验框对于原图占据的空间像素点数目依次递增,即 P2~P6 特征层对应的空间尺度呈上升的趋势。对于本研究中的研究对象射频芯片,邦球邦线占整个射频芯片的比例偏小,即分割目标空间尺度较小。然而,先验框生成网

络中,P6、P5 特征层生成的预选框恢复至原始空间尺度后,占据空间远大于实际需要检测和分割的邦球与邦线。因此,空间尺度较大的 P6、P5 特征层中生成的先验框可以在原文基础上进行适当的缩减。本研究考虑到特殊的细长型邦线,将 P6 层设置为仅生成正方形先验框,而将 P5 层设置为仅生成长方形先验框^[15-16],如图 4 所示。同时,为

了满足实际工厂运用对时效性的高要求,将 P2 先验框修改为仅生成两组长方形先验框,先验框数量由原来的 2.6×10^5 个下降至 1.9×10^5 个,减少了先验框生成、筛选等 Mask R-CNN 网络中的处理时间。这将在模型对邦球邦线识别与分割精度下降保持在一个可接受的范围内同时,大幅提升模型检测邦球邦线的速度。

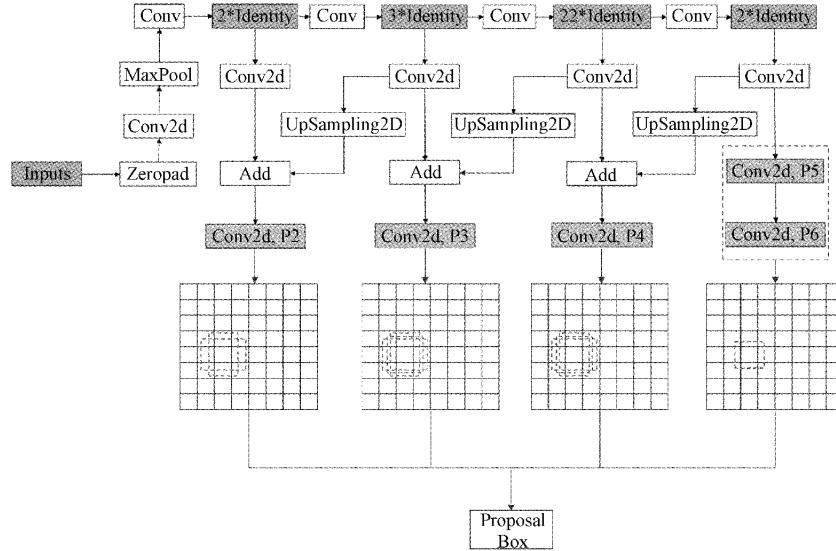


图 4 基于 Mask R-CNN 中 FPN 改进的先验框生成方法

1.2 适用于射频芯片的数据增强方法

在使用上述基于 Mask R-CNN 网络训练时,获取训练所需的目标图像标签需要基于人工手动标注,时间成本与

经济成本较高。为了减少图像标注的人工成本,本文提出了一种适用于射频芯片的数据增强方法,该方案的整体流程如图 5 所示。

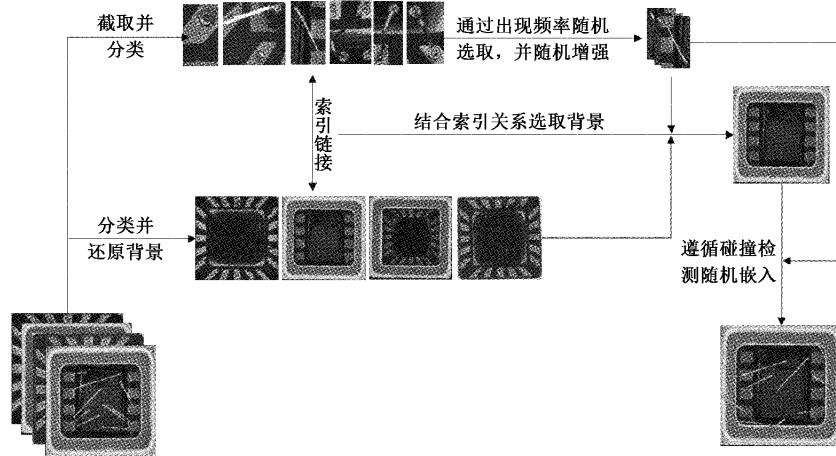


图 5 本文提出的随机增强流程

本文提出的数据增强方法实现路线如下:首先,获取不同类型的单个邦球、邦线以及不同芯片背景的数据,并建立邦球和邦线与背景的索引。然后,结合邦球邦线所处背景的先验知识,以及邦球邦线的出现频率,设计数据采样规则。最后,对采样中提取的邦球邦线进行随机拉伸、随机旋转、随机反转以及随机模糊等操作,并将操作后的邦球邦线随机嵌入至相对应类别的背景,组成新的数

据^[17]。其中嵌入这一步骤需满足本论文设计的一种碰撞检测的方式。

碰撞检测的第 1 个条件要求嵌入过程邦球邦线不得超出背景图片范围。假设 T 为背景集合, F_i 为嵌入背景的第 i 张邦球邦线,则需满足以下条件:

$$\begin{cases} T \cup F_i = T \\ T \cap F_i = F_i \end{cases} \quad (1)$$

碰撞检测第 2 个条件要求任意两个邦球邦线之间没有重叠。假设 F_i 为第 i 个邦球邦线, F 为除 F_i 外的其余需嵌入的邦球邦线集合, 即 $F = (\bigcup_{j=1}^{i-1} F_j) \cup (\bigcup_{j=i+1}^n F_j)$, 则碰撞检测的第 2 个条件为:

$$F \cap F_i = \emptyset \quad (2)$$

通过本文所提的数据增强方式对射频芯片上的邦球邦线进行数据增强后如图 6 所示。本文提出的数据增强在一定程度上还原了原始数据的真实图片环境, 并平衡了数据中不同类型邦球邦线出现频率。

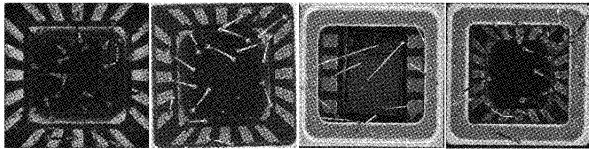


图 6 模拟数据增强结果图

2 实验结果

2.1 实验准备以及评价指标

本文涉及的射频芯片数据由工厂实际提供, 由 1 200 万像素工业相机拍摄。如图 7 所示, 图中可知邦球邦线形态可归为单个邦球类、断连类、细长型类、弯曲类、邦球缺失类、正常状态等 6 种类型, 射频芯片的背景通过分析实际工厂给到的射频芯片数据, 共有 4 种情况。

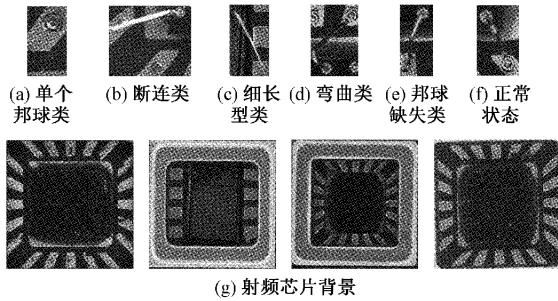


图 7 6 种邦球邦线形态和 4 种射频芯片背景

首先, 将射频芯片数据通过人工先验知识对其中的邦球(包括第一焊点和第二焊点)、邦线进行标注, 标注示例如图 8 所示。数据集中包括 190 个原始数据, 其中 140 个样本用于网络训练, 50 个样本用于网络测试。图像在传入网络统一处理为 512×512 像素大小的图片后传入分割网络。

使用基于 COCO 数据集获取的 Mask R-CNN 预训练模型进行网络初始化, 并在上述数据集进行微调。实验网络在 GTX 1080Ti 显卡, Python3.6 和 Tensorflow 深度学习平台上开发, 在 Intel Core i7-8700K 的 CPU 和 16 GB DDR4 2 400 MHz 的内存环境下测试。在实际训练过程中, 首先对 Mask R-CNN 的头部层进行 9×10^5 个 step 的训练, 初始学习率为 2×10^{-4} , 接着对整个网络进行 1.2×10^6 个 step 的训练, 学习率为 2×10^{-5} 。一共进行 1 000 个 epoch 的训练。

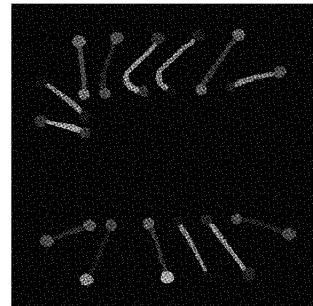


图 8 邦球数据的标签示例

为了对比本文提出的数据增强方式与传统的标注, 以及对比改进的 Mask R-CNN 网络模型以及原 Mask R-CNN 网络, 从而评判改进网络的分割性能以及提出的数据增强方式的效果。本文将使用平均精度均值 (mean average precision, mAP)、豪斯多夫距离 (Hausdorff distance, HD) 以及平均交并比 (mean intersection over union, mIoU) 进行度量。上述评价指标具体计算涉及召回率 (Recall)、准确率 (Precision)、真阳性 (true positive, TP)、假阳性 (false positive, FP)、真阴性 (true negative, TN) 以及假阴性 (false negative, FN), 具体计算方法如下所示:

1) mIoU 的计算公式如下:

$$mIoU = \frac{TP}{TP + FN + FP} \quad (3)$$

2) mAP 是所有类别的平均精度 (average precision, AP) 的平均值, 计算公式如下:

$$mAP = \frac{\sum_{i=1}^n \int_0^1 Precision_i(Recall_i) dRecall_i}{n} \quad (4)$$

3) HD 是描述两组点集合之间相似程度的一种度量, 假设存在集合 $A = \{a_1, a_2, \dots, a_n\}$ 和 $B = \{b_1, b_2, \dots, b_n\}$, 则豪斯多夫距离定义如下:

$$H(A, B) = \max\{h(A, B), h(B, A)\} \quad (5)$$

其中,

$$h(A, B) = \max_{n \in A} \min_{m \in B} \|n - m\| \quad (6)$$

$$h(B, A) = \max_{m \in B} \min_{n \in A} \|m - n\| \quad (7)$$

其中, $\|x - y\|$ 为分属于两个不同集合的点 x 与点 y 的距离^[18]。

2.2 提出的数据增强的效果

为了评估本文提出的数据增强方式应用于 Mask R-CNN 的射频芯片邦球、邦线的分割效果, 这个小节将控制原始数据与增强数据的比例, 同样使用上文中提到的参数, 对原 Mask R-CNN 进行训练。目前标注好的原始数据共 140 张, 本文在此基础上, 设计了原始数据和增强数据比例的对比试验, 拟测定训练集最佳原始数据和增强数据比例。不同原始数据与增强数据比例下 mAP 等衡量指标下的结果统计如表 1 所示。

表1 不同原始与增强数据比例训练集训练结果对比

训练集		mAP/%	HD	mIoU/%
总数	增强数据 : 原始数据	%		%
140	0 : 140	74.19	4.729	61.33
210	70 : 140	79.47	4.281	71.27
280	140 : 140	86.88	4.186	72.86
350	210 : 140	81.73	4.263	68.72

结果显示,在140张原始数据的基础上,增加增强数据,相较于仅包含140张原始数据的训练集的训练结果,mAP至少有4.3%以上的提升。增强数据与原始数据比例为3:2和为1:1的结果显示,在增强数据与原始数据比例为1:1的基础上,增强数据的增加反而影响了原始数据的数据分布,干扰了网络对原始数据的学习,进而对网络的分割性能产生负面影响。由此可知,在训练集中加入增强数据可提升网络的分割性能,且当增强数据与原始数据比值为1时,对Mask R-CNN网络的分割性能提升最为显著。

2.3 改进的Mask R-CNN 网络效果

减少生成的建议框数量可减少识别时间,从而提高实际应用部署时模型的识别效率,但也可能带来准确率和平均精度的降低。为了平衡三者的关系,本章节对生成建议框进行了对比试验,实验所用数据集包括280个训练样本以及50个测试样本,其中训练集中包括140个原始数据以及140个通过本文介绍的数据增强的方式模拟的数据。结果如表2所示。

表2 改进后的Mask R-CNN与原网络对比

网络结构	mAP/%	HD	mIoU/%	运行时间/s
Mask R-CNN	86.88	4.186	72.86	3.276
改进的Mask R-CNN	85.23	4.281	71.27	1.168

由表2结果可以看出,将P6、P5特征层中生成的先验框分别设置为仅生成正方形先验框以及仅生成长方形先验框,将P2生成先验框修改为仅生成两组长方形先验框,此方式相较于原Mask R-CNN而言,消耗时间由原来的3 s,下降至了1 s,而在时间下降的同时,mAP值从86.88%仅下降至85.23%。因此综合该方法的分割精度与推理耗时,可认为该方法满足了工厂应用的实际需求。

2.4 使用提出数据增强方式和改进后Mask R-CNN 的结果

在2.3中所述数据集上,综合使用数据增强构建的数据集训练改进后的Mask R-CNN网络,最终训练模型测试效果如图9所示。

使用上述数据集,改进后的Mask R-CNN与其他分割网络的表现如表3所示,对比实验中选用UNet^[19]和

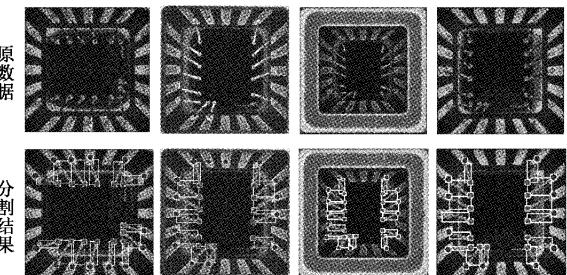


图9 测试数据以及其分割结果

FCN^[20]分割网络。从表中的结论可以看出,改进后的Mask R-CNN相较于FCN等其他分割方法而言,虽然时间略长于其他方法,但是其平均精度均值高于其他方法,分割效果更优。

表3 改进后的Mask R-CNN与其他方法对比

网络结构	mAP/%	mIoU/%	运行时间/s
改进的 Mask R-CNN	85.23	71.27	1.168
UNet	83.17	67.43	0.526
FCN	82.94	66.59	0.411

改进后的Mask R-CNN的训练结果,在不同类别下的AP以及交并比(intersection over union, IoU)如表4所示。从表4可以看到,该方法在目标尺度小的第一焊点邦球以及第二焊点邦球上表现出色,达到了较高的分割性能。而对于引线等空间跨度较大的目标,分割结果中包含部分错误预测值,像素级误差较大。造成这一现象的原因猜测是FPN中深层特征先验框过度缩减。在深层特征层生成先验框过程中,对原图进行采样时设置的采样点偏少,故通过该采样点生成的先验框不适用于大尺度目标的检测。因此,深层特征先验框的缩减将减弱模型对占比较大目标的感知能力,最终表现为网络对尺度较大的邦线目标的分割性能下降。后续工作中,拟将调整FPN中深层特征提取结果中的先验框数量,提升网络对于邦线的分割性能。

表4 改进后的Mask R-CNN对不同类别的分割效果

类别	AP/%	IoU/%
第一焊点邦球	89.36	77.67
第二焊点邦球	87.98	76.23
邦线	78.36	59.92

3 结论

本文结合工业上对分割的精度以及时效性的实际需求,应用本文改进的Mask R-CNN以及数据增强方式构建了射频芯片的邦球邦线的识别、分割系统。通过该数据增强方式构建的数据,可以接近同样数据量的原始数据的训

练效果。与此同时,改进后的 Mask R-CNN 相比于原 Mask R-CNN 的训练结果,提升了实时率,满足了实际生产需求。目前该方法已经在生产线上进行测试,测试结果表明,该方法可以有效检测出引线键合的效果,并降低了人工成本。但本文提出的方法对于空间尺度较大的目标的分割效果不是非常理想,在后续的工作中,拟将调整先验框生成机制,使其在达到高时效的情况下,提升对于中小型目标的检测能力。

参考文献

- [1] 戴久宏. 微波组件内引线常见键合故障分析及预防措施[J]. 电子工艺技术, 2017, 38(3):159-163.
- [2] 闵志先, 叶桢. 自动光学检测在引线键合中的应用[J]. 电子工艺技术, 2021, 42(4):195-197, 213.
- [3] WANG S Y, ZHAO Y, WEN L. PCB welding spot detection with image processing method based on automatic threshold image segmentation algorithm and mathematical morphology[J]. Circuit World, 2016, 42(3):97-103.
- [4] FONSEKA C, JAYASINGHE J. Implementation of an automatic optical inspection system for solder quality classification of THT solder joints[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2018, 9(2):353-366.
- [5] FAN S K S, TSAI D M, CHUANG W C. Automatic vision-based grain optimization and analysis of multi-crystalline solar wafers using hierarchical region growing[J]. Engineering Optimization, 2017, 49(4): 617-632.
- [6] 韩航迪, 徐亦睿, 孙博, 等. 基于改进 Tiny-YOLOv3 网络的航天电子焊点缺陷主动红外检测研究[J]. 仪器仪表学报, 2020, 41(11):42-49.
- [7] 王瑞丰, 魏嘉莉, 周静, 等. 一种基于 AI 的 Chip 类元件 AOI 自动复判方法[J]. 电子测量技术, 2021, 44(15): 114-121.
- [8] DAI W, MUJEEB A, ERDT M, et al. Towards automatic optical inspection of soldering defects[C]. 2018 International Conference on Cyberworlds (CW), 2018: 375-382, DOI: 10.1109/CW.2018.00074.
- [9] 邹德翔. 基于机器视觉的 TO56 型半导体激光器质量检测[D]. 长沙: 湖南大学, 2021, DOI: 10.27135/d.cnki.gghudu.2021.000200.
- [10] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 39 (6): 1137-1149.
- [11] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-cnn [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969, DOI: 10.48550/arXiv.1703.06870.
- [12] 袁春华, 周介祺, 刘桂雄. 基于 Mask R-CNN 实例分割的机械零件识别方法研究[J]. 电子测量技术, 2021, 44(22):32-36.
- [13] WU H, GAO W, XU X. Solder joint recognition using mask R-CNN method[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2019, 10(3): 525-530.
- [14] 王陶然, 王明泉, 张俊生, 等. 基于 Mask R-CNN 的轮毂缺陷分割技术[J]. 国外电子测量技术, 2021, 40(2):1-5.
- [15] 史晨晨, 张长伦, 何强, 等. 基于改进特征金字塔的目标检测[J]. 电子测量技术, 2021, 44(20):150-156.
- [16] 王标, 周雅兰, 王永红. 改进型 Faster RCNN 网络在电子元件 LED 气泡缺陷检测中的应用[J]. 电子测量与仪器学报, 2021, 35(9):136-143.
- [17] 乔雨轩, 方建安. 基于数据增强的小样本字符识别模型[J]. 计算机科学与应用, 2022, 12(5): 1280-1291.
- [18] 方新林, 方艳红, 王迪. 基于多模态特征融合的脑瘤图像分割方法[J]. 中国医学物理学杂志, 2022, 39(6): 682-689.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-assisted Intervention. Springer, Cham, 2015: 234-241, DOI: 10.48550/arXiv.1505.04597.
- [20] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440, DOI: 10.1109/TPAMI.2016.2572683.

作者简介

曾子炀,硕士,主要研究方向为计算机视觉、医学图像处理等。

E-mail: 220204677@seu.edu.cn

成汉林,博士,主要研究方向为计算机视觉、医学图像处理等。

E-mail: 230218830@seu.edu.cn

周静,硕士,主要研究方向为计算机视觉、人工智能、目标检测等。

E-mail: yee.zhoujing@gmail.com

刘鹏飞,主要从事自动光学检测相关研究。

E-mail: liupengfei@magic-ray.com

罗守华(通信作者),教授,博士生导师,主要研究方向为医学图像处理、CT 图像重建、模式识别。

E-mail: luoshouhua@seu.edu.cn