

基于主动学习和U-Net++分割的芯片封装空洞率的研究

齐选龙, 陈弘扬, 赵文兵, 赵地, 高敬阳

引用本文

齐选龙, 陈弘扬, 赵文兵, 赵地, 高敬阳. 基于主动学习和U-Net++分割的芯片封装空洞率的研究[J]. 计算机科学, 2023, 50(6A): 220200092-6.

Qi Xuanlong, CHEN Hongyang, ZHAO Wenbing, ZHAO Di, GAO Jingyang. Study on BGA Packaging Void Rate Detection Based on Active Learning and U-Net++ Segmentation [J]. Computer Science, 2023, 50(6A): 220200092-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于改进Yolov4-tiny的轻量型目标检测算法](#)

Lightweight Target Detection Algorithm Based on Improved Yolov4-tiny

计算机科学, 2023, 50(6A): 220700006-7. <https://doi.org/10.11896/jsjcx.220700006>

[CT影像阶段化目标检测方法研究](#)

Study on Phased Target Detection in CT Image

计算机科学, 2023, 50(6A): 220200063-10. <https://doi.org/10.11896/jsjcx.220200063>

[基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测](#)

Defect Detection of Transmission Line Bolt Based on Region Attention Mechanism and Multi-scale Feature Fusion

计算机科学, 2023, 50(6A): 220200096-7. <https://doi.org/10.11896/jsjcx.220200096>

[基于SegFormer的超声影像图像分割](#)

Ultrasonic Image Segmentation Based on SegFormer

计算机科学, 2023, 50(6A): 220400273-6. <https://doi.org/10.11896/jsjcx.220400273>

[基于球簇聚类的超像素分割迭代算法](#)

Superpixel Segmentation Iterative Algorithm Based on Ball-k-means Clustering

计算机科学, 2023, 50(6A): 220600114-7. <https://doi.org/10.11896/jsjcx.220600114>

基于主动学习和 U-Net++ 分割的芯片封装空洞率的研究

齐选龙¹ 陈弘扬² 赵文兵¹ 赵地^{3,4} 高敬阳²

1 北京工业大学 北京 100124

2 北京化工大学 北京 100029

3 中国科学院计算技术研究所 北京 100080

4 中国科学院大学 北京 100049

(victorqi0712@gmail.com)

摘要 内焊球空洞是 BGA 封装芯片的主要缺陷,可能会导致电气故障。目前,常用的检测方法是人工对照芯片 X 光影像检查,此类方法检测准确率且时间、人力资源消耗大。因此,基于深度学习的自动化芯片缺陷检测方法越来越受到关注。芯片空洞检测与语义分割任务对应,但受限于数据缺乏高质量标注,模型准确率通常偏低,主动学习框架是潜在的解决方案。文中基于主动学习和 U-Net++ 构建了芯片空洞率检测模型,通过等距划分将数据集分为多个子集,每个子集采用训练-预测-标注-扩展的框架循环优化 U-Net++ 模型。在 BGA 封装芯片数据集上进行实验,模型分割平均 Dice 系数达到了 80.99%,总体准确率达到了 94.89%,达到了预定目标。首次将主动学习引入芯片检测领域,经实验验证可以有效提升芯片数据的标注水平,使得模型的分割准确率有所提高。

关键词: 内焊球空洞;主动学习;图像分割;目标检测

中图法分类号 TP399

Study on BGA Packaging Void Rate Detection Based on Active Learning and U-Net++ Segmentation

QI Xuanlong¹, CHEN Hongyang², ZHAO Wenbing¹, ZHAO Di^{3,4} and GAO Jingyang²

1 Beijing University of Technology, Beijing 100124, China

2 Beijing University of Chemical Technology, Beijing 100029, China

3 Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100080, China

4 Chinese Academy of Sciences, Beijing 100049, China

Abstract Bump void is one of the most common physical defects in BGA packaging, which may lead to electrical failures and shortened lifetime. At present, the commonly used quality inspection is based on manual check on X-ray images, which has low accuracy and high time consumption. Therefore, automated chip detection methods based on deep learning draws increasing attention in industry. This paper proposes an active learning and U-Net++ based void rate detection network. Based on active learning, we apply equidistant partition for the whole dataset. For each sub-dataset, we take training-prediction-labeling-extension as pattern to optimize U-Net++ network. The average dice coefficient on separated model sets reaches 80.99% on test set, while the overall accuracy rate reaches 94.89%. We innovatively apply active learning in in-line defect detection, and the result shows that, it can effectively enhance the labeling standard of data and model's division precision.

Keywords Bump void, Active learning, Image segmentation, Object Detection

1 引言

1.1 BGA 封装内焊球空洞

随着电子电路趋向于高度集成化,球栅阵列封装(Ball Grid Array,下文简称为 BGA 技术)已在高性能芯片制造领域得到了广泛的应用。BGA 封装技术具有优异的电性能,并能降低引脚延迟。同时,内焊球在基板是平面阵列排布,在相同的面积下,BGA 封装可以容纳更多的引脚。此外,BGA 技术

与 PCB(Printed Circuit Board)组装工艺具有较强的适配性,能够提高封装技术的可靠性及组装的效率。然而 BGA 封装技术对工艺水平有较高要求,不完善的加工过程会导致内焊球空洞,该问题是 BGA 产品的主要缺陷。未在焊点形成前有效排出气体或采用不当的回流曲线都是可能导致空洞出现的原因,空洞的 X 射线图像如图 1 所示,

该缺陷可能对芯片的寿命及性能产生极大的不良影响。文献[1-2]证实了空洞会导致焊点强度降低、寿命减损。取决

基金项目:中国科学院计算技术研究所-华为联合实验室项目(YBN2020055088)

This work was supported by the Institute of Computing Technology, Chinese Academy of Sciences-Huawei Joint Laboratory Project (YBN2020055088).

通信作者:赵文兵(zhaowb@bjut.edu.cn)

于空洞不同的出现频率及位置,即便是小空隙也会对产品可靠性产生较大的影响。工业界采用空洞率,即空洞与内焊球面积比对空洞级别进行量化,空洞率检测目前已成为 BGA 芯片质量检测的必要步骤。




图 1 BGA 封装内焊球空洞
Fig. 1 BGA packaging bump void

1.2 已有工作

芯片质量检测通常采用二维或三维 x 射线影像进行^[4-6],如文献[7]使用激光超声和干涉仪构建的空洞检测系统。传统检测方法主要由人工专家进行检测,但由于内焊球与空洞之间对比度较低,x 射线图像中存在许多人眼难以分辨的空洞边缘。此外,个体间的感知差异也使得传统检测方法无法实现高准确率的缺陷检测。其次,每个芯片具有多个内焊球,其中有若干个空洞,串行检查对于人力资源及时间成本都造成了极大的挑战。因此,一种具有低延迟、高准确率、良好扩展性和鲁棒性的空洞率检测方法显得尤为必要。

计算机视觉技术已经在多个医学、工业缺陷检测领域得到广泛应用,文献[8-9]应用 AlexNet 构建模型,文献[10]构建了分割及决策网络模型,应用于产品表面检测。文献[11]使用深度神经网络进行自动化诊断。语义分割是计算机视觉的重要研究方向,目标为对图像实现像素级的类别预测。目前已经衍生出许多基于卷积神经网络的具有出色表现的模型。芯片空洞检测过程可分为两个步骤:1)从输入图像中分割得到内焊球;2)从每一个内焊球中分割得到空洞。由此可见,芯片检测的任务与计算机视觉中的语义分割任务一致。

现有的自动化检测模型可分为 3 类。1)基于数字图像处理的检测方法,如文献[13-15]提出了基于滤波器和阈值的空洞提取方法,使用高斯算子降噪及拉普拉斯算子、罗伯特算子等边缘模版实现内焊球和空洞的检测。2)结合数字图像处理技术和神经网络的模型,文献[15-16]提出了阈值法结合人工神经网络的检测模型。3)基于端到端深度学习的检测方法,如 Mask-RCNN 模型^[17-18]使用 U-Net 实现了内焊球空洞的自动分割,文献[19]进一步测试了 U-Net 等模型在不同重合率芯片数据上的表现,发现 U-Net 在低空洞重合率数据中表现优秀,但随着图像中空洞重合率的上升,IoU 指数出现了线性下降。

1.3 基于 U-Net++ 的主动学习

主动学习是一种基于人工和机器学习模型交互的优化模型。该模型的目标为使用较少数量的标注数据达到接近最佳的模型准确率。文献[20]通过设计查询函数选择待标注数据进行人工标注,采用增量学习的方式更新模型,通过循环迭代得到最优表现。现有的主要查询方法有基于不确定性、多样性的查找策略。传统主动学习的模型部分为机器学习模型,

随着非结构化数据的增大及深度学习模型出色的特征提取能力,深度主动学习成为了研究的重点。

芯片领域缺乏如 ImageNet,CoCo 等拥有良好标注的公开数据集,且不具备医学图像领域的精准专家意见。因此主要挑战是其不良的视觉效果所导致的标注困难,进而使得模型准确率低。主动学习人工标注过程是基于模型预测结果的修正,标注水平应优于人工直接标注,且主动学习模型可以多次循环,在优化模型的同时优化标注。

U-Net++ 是由文献[21]发表的模型,该模型的核心思路为通过修改 U-Net 网络^[22]的拓扑结构,增强不同维度特征信息的融合。U-Net 是语义分割任务的经典模型,随着 GPU 并行计算技术的进步^[23],目前已衍生出多个基于 U-Net 的网络结构^[24],相比传统 U-Net,U-Net++ 模型有 3 个主要特点。1)在保留 U-Net 模型长跳跃连接的基础上,引入多个短连接,增强了不同维度特征的叠加融合能力。2)引入了深度监督机制,在不同深度 U-Net 的输出层后加入 1×1 的卷积,由此来监督不同 U-Net 的输出,解决梯度无法回传的问题。3)U-Net++ 中不同深度的 U-Net 共享编码器,有效降低了训练难度,且可在低深度模型预测结果达到标准后通过剪枝降低计算量。U-Net++ 继承了 U-Net 灵活的网络框架,文献[25]使用 ImageNet 上预训练的 VGG11 模型作为编码器构建 U-Net。诸如 ResNet,MobileNet 等大量具有优秀特征提取效果的骨干网络可以将编码器与 U-Net++ 结合。

本文以 U-Net++ 分割框架为基础,构建深度主动学习模型,在 BGA 封装芯片数据集上进行实验,提出了基于主动学习和 U-Net++ 分割的芯片封装空洞率的研究。

2 方法

2.1 基于 U-Net++ 的深度主动学习模型

将 U-Net++ 分割网络作为待优化模型,构建深度主动学习框架,本文模型的结构如图 2 所示。

该模型由两条数据路径构成:1)蓝色为分割网络数据路径;2)黄色为深度主动学习优化框架。分割网络路径实现数据集的划分,合并已标注数据与本轮人工标注数据,并完成分割网络的训练及测试。主动学习路径接收分割网络在测试集上的预测结果,经人工标注后加入更新标注数据池中。

子集查找策略如下。将数据等数量划分为多个子集,本文采用的子集数目为 10。初始状态下,人工手动标注第一个子集,该部分数据进入已标注数据池并作为训练集。使用第二个子集进入未标注的数据池,作为测试集。使用训练完的模型对测试集作出预测,人工对预测结果进行标注和修正。标注完成后将第二个子集与已标注的数据合并至更新标注数据池中,使用其中前两个子集构建训练集进行监督学习,将第三个子集作为测试集进行预测并人工标注,依次进行直至 10 个子集全部被合并至标注池中第一轮即为结束。为解决前三个子集标注效果不如后续子集的情况,第一轮结束后,将一至三号子集采用上述模式重新标志,即达到预计标注水平。

本文模型的分割网络为 U-Net++,该模型实现了深度为一至四的 U-Net 级连,并采用稠密连接来融合多维特征。

本文选用 EfficientNet-b6^[26-27] 作为 U-Net++ 的骨干

网络,并加载 ImageNet 预训练的权重,使其具有更强的特征提取能力并降低计算资源消耗。




图 2 基于 U-Net++ 的深度主动学习框架结构(电子版为彩图)

Fig. 2 U-Net++ based deep active learning framework

2.2 基于目标检测的深度主动学习模型

实验过程中发现芯片数据图像大小为 2792×2400 , 计算资源不足以直接支持语义分割。因此,本文在主动学习模块前引入目标检测网络。本文将空洞率检测分为两个步骤:1)通过目标检测网络对单个内焊球实现准确定位,并根据边界框将原始图片切割成单一内焊球图像,以此构建新的分割数据集;2)使用 U-Net++ 实现空洞分割。该方法有效地减小了计算资源开销。基于目标检测的主动学习模型如图 3 所示,

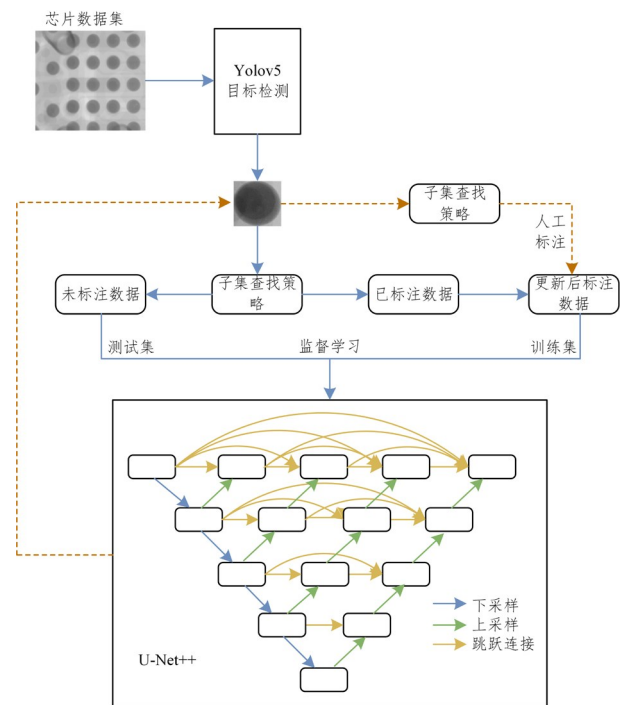


图 3 预计目标检测的主动学习模型

Fig. 3 Object detection based active learning model

目标检测网络采用 Yolov5 实现,该模型由输入、骨干网络、颈网络及预测 4 部分构成^[28-29]。相比 Yolov4 算法, Yolov5 在 Backbone 网络开始处引入 Focus 模块,该模块由切片-整合-卷积层-BN-HardSwish 激活构成,扩展维度的同时快速降低特征图大小。Yolov5 延续了 CSPNet 拆分特征图的思想,将计算分支的输出特征图与原始特征图叠加。Yolov5 模型包含了两种 CSPNet 模块,分别对应于 Backbone 网络及 Neck 网络。Backbone 网络中的 CSP1_X 模块,由 X 个残差块构成,每个残差块包含两个卷积-批归一化-HardSwish 激活。Neck 网络中新增的 CSP2_X 模型同样由两通路构成,卷积通道由 2X 个卷积-批归一化-HardSwish 构成,之后与原始特征图叠加。该结构替代了原先 Neck 网络的卷积层。Yolov5 模型在保持轻量化的基础上增强网络的特征学习及融合能力。Yolov5 在输出端使用 GIoU Loss^[30] 作为边界框损失。目标检测后续模型与前文中的基于 U-Net++ 的主动学习模型结构一致,输入数据为剪裁后的图像。

3 实验

3.1 数据集

实验使用 BGA 封装芯片 X 光影像作为数据集(简称为芯片数据集),其中共有 508 张二维 X 射线图像,均为 JPG 格式。目标检测真实锚框图像通过 Labelme 手动进行标注,标注结果为 txt 文件,每个锚框由 5 个数值表示,分别为其所属类别,锚框左上及右下两个点的二维坐标。

本文将目标检测模型输出的输出图像作为空洞率分割的数据集(简称为分割数据集),本文使用 Labelme 对该输出图像进行标注,其中有两个类别,即 bump 及 ins,分别表示内焊球及空洞,标注结果为 json 文件,并通过进一步处理转化为掩膜图像。

本文实验共进行了两次标注,每次标注由 10 人共同完成,标注完成后经历三步审核:标注者自审核、项目组成员审核及项目负责老师审核。第一次标注方案为全部标注,在整个数据集上进行训练,由于标注水平低导致分割结果不佳。第二次采用本文提出的主动学习方案,有效提升了模型的分割效果。

3.2 实验流程

本实验的流程如图 4 所示。




图 4 实验流程

Fig. 4 Experiment workflow

首先对芯片数据集中的数据进行对比度增强以提升数据的视觉效果。本文最终采用的强化因子为 2.4,实验中该参数具有最优的增强效果。随后在芯片数据集中训练 Yolov5 目标检测模型,对所有样本进行随机划分,数据集采用 7:3 划分训练集和测试集。训练使用的损失函数由置信度损失、类别损失及边界框损失 3 部分构成,分别采用 BECLogits loss、交叉熵损失函数及 GIoU loss。

随后采用目标检测图输出图像构建分割数据集,依照

主动学习方法将数据集等距划分为 10 个子集,完成第一个子集标注后,将图像按照目标检测获得的边界进行剪裁,对掩码图像进行同样的处理,将剪裁后的图像作为输入训练 Efficient b6-U-Net++ 模型,将第二个子集的数据作为测试集,利用主动学习循环优化模型至测试结果不发生变化。训练过程采的损失函数为 Dice 损失函数,计算式为:

$$L_{Dice} = 1 - 2 * \frac{|y \cap p|}{|y| + |p|} \quad (1)$$

其中, y 为真实的掩膜图像, p 为网络预测的掩膜。最终将预测图像合并成原图,并根据其类别像素比列作为面积比得到 BGA 芯片空洞率。

本文中目标检测及语义分割模型均采用硬件团队预指定的 5 张图像作为测试集,模型在该测试集上的评估指标作为模型最终的性能指标。实验采用的 GPU 为 1 张 Nvidia Tesla P100 显卡,显存 16GB。实验代码基于 PyTorch 1.7.1 实现。

3.3 评价指标

本文提出的模型包含目标检测及语义分割两部分,故对其分别设计评价标准量化模型表现。

目标检测:设图像标注的边界框为 g ,预测得到的边界为 p ,分别用 TP, FP, FN 及 TN 表示预测结果为真阳性、假阳性、假阴性、真阴性的数目。

IoU 指数(交并比, Intersection over Union)是目标检测及分割任务中的常用标准,其衡量了预测值与真值的重叠度,本文中,其表示预测框与真实框相交部分的面积与并集部分面积的比,即:

$$IoU(g, p) = \frac{|TP|}{|TP| + |FP| + |FN|} \quad (2)$$

P-R 曲线的横坐标为召回率、纵坐标为精确率,该曲线描述了不同置信度下, Precision 与 Recall 值的变化。AP 是 P-R 曲线的积分结果,本文检测模型只有内焊球一个类别,即 AP 与 mAP 相等,AP 值大表示检测效果较好,其计算式如下:

$$AP = \sum P(k) * \delta R(k) \quad (3)$$

语义分割方式如下。本文采用了两部分衡量标准:1)将其看作分割任务;2)将其作为每个内焊球的分类任务^[32]。前者采用 Dice 系数,描述了像素级别的分割效果,后者将内焊球看作存在空洞及不存在空洞两类,使用精确率、召回率、mAP 量化模型来表现,具体如下。

设分割任务中的真值为 y ,预测结果为 p ,分别用 TP, FP, FN 及 TN 表示预测结果为真阳性、假阳性、假阴性、真阴性的数目。以 TP 为例,若该内焊球真实掩膜中存在空洞,且分割模型预测出了空洞,即作为一个 TP。

Dice 系数是一种用于计算两个样本集合相似度的度量函数,与上文提及的 IoU 指数类似,是图像分割领域的常用检测标准,其计算式如下:

$$Dice(y, p) = \frac{2 * |TP|}{|TP| + |FP| + |TP| + |FN|} \quad (4)$$

Dice 系数在 [0, 1] 之间,其数值越大则预测结果 p 与真实掩膜图像 y 的重合区域越大,即分割任务的表现越好,本文采用 Dice 系数作为语义分割的主要评价标准。

3.4 实验结果

本文提出的模型在芯片数据集及构建的分割数据集上的 mAP、Dice 系数、总体准确率、假阳性率及假阴性率如表 1 所列。

表 1 模型检测结果
Table 1 Model test results

Type	Standard	Target	Result
Object detection	mAP@0.5	大于等于 0.5	1
Segmentation	Dice	大于等于 0.8	0.81
Classification	Accuracy	大于等于 0.5	0.95
Classification	FNR	小于等于 0.01	0.07
Classification	FPR	小于等于 0.1	0

4 讨论及分析

4.1 实验结果分析

5 项指标中除假阴性率未达到预计标准外,其余 4 项标准均已高出目标。本文预设的目标是参考医学图像影像标准设计,芯片超声领域缺乏专家标注,且图像效果不佳导致其效果难以达到医学超声标准。

实验数据共进行两次标注,其中多次寻求硬件工程师的专业支持,反馈结果为多数数据边界标注范围太大,但就许多肉眼无法辨别的边界,该团队也未达成一致。本文遵循严格标注的原则,对可见的空洞边缘均进行了标注,其导致了存在一定数量边界不完整、不清晰的空洞。此类空洞难以被模型准确分割,导致了模型假阴性率高于标准。此外,假阳性率与假阴性率两指标间存在竞争关系,若强行降低假阴性率会导致假阳性率升高,且由于升高幅度大于降低幅度,会导致模型整体表现结果下降。

假阳性率及假阴性率在不同的使用领域具有不同的重要性^[32],如在医学影像领域出现过高的假阴性,即未能检测出阳性患者会产生极大的代价,甚至危及病人生命。但在芯片超声任务中,综合指标(Dice 系数)更为重要,目标检测的相关标注仅为辅助指标。

4.2 未来优化方向

本文模型可整体划分为主动学习模型及深度学习模型两部分,因此针对两部分分别提供优化方向。

(1)主动学习。文献[33]提出了深度学习和主动学习存在冲突性,前者需要大量标注的数据进行训练,而后者寻求在最小化标注数据中的最优模型。本文验证了深度主动学习的有效性,但未对现有的主动学习查询策略进行实验,不同策略间的对比实验是重要的后续工作。

(2)深度学习。实验过程中发现,对于单个内焊球存在以下情况:位于其边缘处的空洞相比中间位置更难被分割,因此本文尝试构建了一个特化的 Loss 函数用于解决该问题。本文设计了距离权重矩阵,中心位置数值为 1,边界 4 个顶点数值为 1.5,用于矫正图像像素对 Loss 的贡献,提升网络对边缘空洞的捕捉能力。此外,实验过程中发现常规的 Dice 损失函数在权重矩阵的作用下会导致没有下确界,可以使用平方变形保证 Loss 的下界为 0。其计算方法如式(5)所示,其中 pr 表示预测结果中物体的像素点, gt 为真实掩膜中的像素点。

$$Dice = \frac{2\sum(pr-gt)^2}{\sum gt^2 + \sum pr^2} \quad (5)$$

本文实验过程中使用了上述损失函数,但由于数据集整体标注水平偏低,该损失相比常规 Dice 损失函数未展现出明显优势。后续研究在保证标注水平的同时,不同形式的距离监督可能是潜在的优化方向。

结束语 本文首次将主动学习方法应用于芯片超声领域,提出了基于主动学习和 U-Net++ 的芯片封装空洞率检测模型,目前已经完成了第一代软件原型的开发。为验证模型的有效性,在芯片数据集上进行了多组实验,得出以下结论。

本文验证了芯片领域主动学习方法的有效性,本文提出的模型具有以下优势:1)具有较强的分割和适应能力,在标注困难的芯片数据集上的表现达到了预期标准;2)模型轻量化,通过集联的方式有效降低了分割任务的计算资源开销,对未来压缩模型并迁移至移动端或嵌入式设备提供了参考。

参考文献

- [1] YUNUS M, SRIHARI K, PITARRESI J M, et al. Effect of voids on the reliability of BGA/CSP solder joints[J]. *Microelectronics Reliability*, 2003, 43(12): 2077-2086.
- [2] CHIU T C, ZENG K, STIERMAN R, et al. Effect of thermal aging on board level drop reliability for Pb-free BGA packages [C]// 54th Electronic Components and Technology Conference. 2004.
- [3] YANG T, ZHANG S S, JIANG F Z, et al. Brachial plexus ultrasound image optimization based on deep learning and adaptive contrast enhancement[J]. *Computer Science*, 2019, 46(11A): 236-240.
- [4] PETERSON B, KWAN M, DUEWER F, et al. Optimizing x-ray inspection for advanced packaging applications[C]// 2020 International Wafer Level Packaging Conference. 2020.
- [5] CHAO F, XIAOMIN L, KOW J. 3D package failure analysis challenge and solution[C]// 2015 IEEE 17th Electronics Packaging and Technology Conference. 2015.
- [6] VAGA R, BRYANT K. Recent advances in X-ray technology [C]// 2016 Pan Pacific Microelectronics Symposium. 2016.
- [7] GONG J, UME I C. Void inspection in lead-free solder bumps on ball grid array(BGA) packages using laser ultrasound technique [C]// ASME International Mechanical Engineering Congress and Exposition. 2011.
- [8] LV H M, ZHAO D, CHI X B. Deep learning for early diagnosis of Alzheimer's disease based on intensive AlexNet[J]. *Computer Science*, 2017, 44(Z6): 50-60.
- [9] CHEN S W, LIU Y J, LIU D, et al. AlexNet model and adaptive contrast enhancement based ultrasound Image classification[J]. *Computer Science*, 2019, 46(6A): 146-152.
- [10] TABERNIK D, ŠELA S, SKVARC J, et al. Segmentation-based deep-learning approach for surface-defect detection[J]. *Journal of Intelligent Manufacturing*, 2020, 31(3): 759-776.
- [11] ZHANG Z Z, GAO J Y, LV G, et al. Pathological image classification of gastric cancer based on deep learning[J]. *Computer Science*, 2018, 45(11A): 263-268.
- [12] SAID A F, BENNETT B L, KARAM L J, et al. Automated void detection in solder balls in the presence of vias and other artifacts[J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2012, 2(11): 1890-1901.
- [13] PENG S, NAM H D. Void defect detection in ball grid array X-ray images using a new blob filter[J]. *Journal of Zhejiang University Science C*, 2012, 13(11): 840-849.
- [14] WANG H, LIU D. A new threshold segmentation algorithm for segmenting micro-focus X-ray BGA solder joint image[C]// 4th International Conference on Information Technology and Management Innovation. 2015.
- [15] VAN V M. Void detection in solder bumps with deep learning [J]. *Microelectronics Reliability*, 2018, 88: 315-320.
- [16] WANG F, WANG F. Rapidly void detection in TSVs with 2-D X-ray imaging and artificial neural networks[J]. *IEEE Transactions on Semiconductor Manufacturing*, 2014, 27(2): 246-251.
- [17] HE K, GKIOXARI G, DOLLAR P, et al. Mask r-cnn[C]// Proceedings of the IEEE International Conference on Computer Vision. 2017.
- [18] NEELURU V K, AHUJA V. Void region segmentation in ball grid array using u-net approach and synthetic data[J]. arXiv: 1907.04222, 2019.
- [19] SCHIELE T, JANSCHKE A, BERNTHALER T, et al. Comparison of deep learning-based image segmentation methods for the detection of voids in X-ray images of microelectronic components [C]// 2021 IEEE 17th International Conference on Automation Science and Engineering. 2021.
- [20] SETTLES B. Active learning literature survey[R]. University of Wisconsin-Madison, 2009.
- [21] ZHOU Z, RAHMAN S M M, TAJBAKSHI N, et al. UNet++: A nested u-net architecture for medical image segmentation [M]// Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Cham: Springer, 2018.
- [22] 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. Cham: Springer, 2015.
- [23] SU H Q, FU J C, GU H, et al. Parallel algorithm design for assisted diagnosis of prostate cancer[J]. *Computer Science*, 2019, 46(11A): 524-527.
- [24] GAO Q, GAO J Y, ZHAO D. GNNI U-net: precise segmentation neural network of left ventricular contours for MRI image based on group normalization and nearest interpolation[J]. *Computer Science*, 2020, 47(8): 213-220.
- [25] IGLOVIKOV V, SHVETS A. Terausnet: U-net with vgg11 encoder pre-trained on imagenet for image segmentation [J]. arXiv: 1801.05746, 2018.
- [26] TAN M, LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. 2019.
- [27] KAMBLE R, SAMANTA P, SINGHAL N. Optic disc, cup and fovea detection from retinal images using U-Net++ with EfficientNet encoder[C]// International Workshop on Ophthalmic Medical Image Analysis. Cham: Springer, 2020.

[28] SONG Q, LI S, BAI Q, et al. Object detection method for grasping robot based on improved YOLOv5 [J]. *Micromachines*, 2021, 12(11): 1273.

[29] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. *arXiv*: 2004. 10934, 2020.

[30] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019.

[31] CHEN H Y, GAO J Y, ZHAO D, et al. LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms [J]. *Journal of Image and Graphics*, 2021, 26(9): 2121-2134.

[32] CHEN H Y, GAO J Y, ZHAO D, et al. Review of the research progress in deep learning and biomedical image analysis till 2020

[J]. *Journal of Image of Graphics*, 2021, 26(3): 475-486.

[33] REN P, XIAO Y, CHANG X, et al. A survey of deep active learning [J]. *ACM Computing Surveys*, 2021, 54(9): 1-40.



QI Xuanlong, born in 2000, undergraduate. His main research interests include deep learning, computer vision and so on.



ZHAO Wenbing, born in 1973, Ph. D, lecturer. Her main research interests include deep learning and medical image processing.