

DOI: 10.13382/j.jemi.B2003691

# 改进型 Faster R-CNN 网络在电子元件 LED 气泡缺陷检测中的应用\*

王 标 周雅兰 王永红

(合肥工业大学 仪器科学与光电工程学院 合肥 230009)

**摘要:**电子元件 LED 缺陷当前主要检测方法是通过效率低下的人工目检,而传统机器视觉检测速度慢,且识别精度通常难以满足实际应用要求。为了克服这些缺点,提出了一种改进的 Faster R-CNN 网络为框架的电子元件气泡缺陷检测方法。为了提高网络的鲁棒性和泛化能力,对数据集以添加噪声、改变亮度的方式进行扩充。以 Resnet50 和 FPN 网络作为主干网络提取图像特征,并根据其特征金字塔不同特征预测层的特性调整 anchor 的尺度,构建网络进行训练。最后在数据集上通过对试验结果定量分析表明,该方法对 LED 元件气泡缺陷的总体准确率达到了 95.6%,召回率提高 20.8%,单幅图片检测时间约为 100 ms,满足生产中自动化检测的要求。

**关键词:**缺陷检测;Faster R-CNN;深度学习;电子元件;LED 瑕疵

**中图分类号:** TH164;TN911 **文献标识码:** A **国家标准学科分类代码:** 520.99

## Application of improved faster R-CNN network in bubbles defect detection of electronic component LED

Wang Biao Zhou Yalan Wang Yonghong

(School of Instrument Science and Opto-electronics Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** Nowadays, the mainstream method of LED defects detection is low-efficiency manual visual inspection. And the traditional machine visual detection cannot meet its application's standard with its low precision. To deal with these issues, a LED defects detection method is proposed based on improved faster R-CNN network framework. In order to improve the robustness and generalization capability of the network, the dataset is expanded by adding noise and changing the brightness. Resnet50 and FPN network are the backbone network to extract the characteristics, and the anchor scale is adjusted according to the characteristics of its different feature prediction layers of the feature pyramid, to construct and train the network. Eventually, the quantitative analysis of the test results on the dataset testing shows that the method of LED bubble-like defects detection can achieve an overall accuracy of 95.6%, and the recall rate has a 20.8% increase. Single-picture detection time is about 100 ms. It can be affirmed that this method can meet the needs of the automatic detection in manufacture.

**Keywords:** defect detection; faster R-CNN; deep learning; electronic component; LED defects

## 0 引言

电子元器件制造业是电子信息产业的基础支撑产业,是在我国电子科技不断进步的基础上发展起来的,对提高现代化工业水平具有重要促进作用。在工业生产中,由于材料限制和加工工艺等原因,往往会导致产品出现缺陷,为了保障产品的质量,缺陷检测与识别是工业上

非常重要的一个应用。LED 属于半导体照明器件,生产过程中在一片半导体发光器件外涂具有高折射率和高透光率的封装胶,可以增加 LED 的光通量<sup>[1]</sup>。封装胶涂覆厚度不均匀、夹带异物、胶变色、半导体发光器件引脚通电失败等均会影响 LED 的发光效果,导致 LED 光效低、色度不均、热量难以散失、寿命短,甚至不能发光等问题。当前的主要检测方法是通过人工目检的方式剔除缺陷 LED,封装胶液态均为无色透明,外观无法 100% 识别。

收稿日期: 2020-11-14 Received Date: 2020-11-14

\* 基金项目: 国家重点研发计划(2016YFF0101803)项目资助

LED 本身尺寸小,缺陷的尺寸更小,连续工作必然会导致检测人员的视觉疲劳、降低产品质量,造成人力成本的浪费和生产成本的增加。机器视觉技术具有非接触、自动化、能够快速检测小尺寸零件等优点,能很好地满足产品质量和速度的检测要求。视觉表面缺陷检测系统基本组成主要包括图像获取模块、图像处理模块、图像分析模块、数据管理及人机接口模块<sup>[2]</sup>。目前利用机器视觉检测 LED 的方法主要有模板匹配法、亮度分析法、缺陷分割法等<sup>[3]</sup>。传统的机器视觉方法通常依赖于大量人工提取的特征来检测电子元件图像中的缺陷,对于与非缺陷样本和噪声差异较小的缺陷样本,检测速度慢、识别精度不够,通常难以满足实际应用的精度要求。

随着人工智能的快速发展和“中国制造 2025”的深入推进,深度学习方法能够提取图像中更深层次的复杂特征,在图像分类中表现更好。缺陷检测深度学习方法主要分为全监督学习模型、无监督学习模型、半监督学习模型和弱监督学习模型<sup>[4]</sup>,目前阶段基于有监督的表征学习网络结构是在工业领域中一个较好的应用。在表征学习网络中,根据检测方式和目的的不同,进一步分为分类网络、分割网络和检测网络。

Soukup 和 Huber-Mörk 在 2014 年首次将卷积神经网络(CNN)应用于表面缺陷检测,用纯监督方式训练的经典 CNN 进行了实验,并探讨了无监督分层预训练和训练数据集扩充等正则化方法的影响<sup>[5]</sup>。在钢轨表面数据集上,CNN 已经明显优于基于传统模型的方法,经过加载预训练的模型错误率只有 0.67%。Liang 等<sup>[6]</sup>针对饮料包装等塑料容器在复杂背景下的检测问题,提出了一种基于深度学习的高效、准确的检测方案。采用图像处理算法生成合成缺陷样本,缓解了类不平衡问题。采用 ShuffleNet V2 框架对复杂背景下的喷墨代码进行检测,并利用迁移学习法将训练好的模型转移到不同包装的其他检验任务中,大大降低了不同类型饮料包装新检测系统的开发成本。Tabernik 等<sup>[7]</sup>提出了一种基于分割的深度学习体系结构,用于表面异常的检测和分割,并在表面裂纹检测的特定领域进行了试验,该方法能够在少量缺陷表面上学习,仅使用大约 25~30 个缺陷训练样本,这使得深度学习方法在可用缺陷样本数量有限的行业中具有实用性,准确识别率超过了商业软件。分类网络需要依赖于其他技术手段,不能实现端到端的结构。

图像分类任务是把一张图片划分为某个类别,而语义分割则是更进一步的在像素级别上的分类。分割网络将表面缺陷检测任务转化为缺陷与正常区域的语义分割甚至实例分割问题,不但能精细分割出缺陷区域,而且可以获取缺陷的位置、类别以及相应的几何属性。按照分割功能的区别,其大致可以分为 FCN<sup>[8]</sup>(fully convolutional networks)方法和 Mask R-CNN<sup>[9]</sup>方法两种。

相比分类和检测网络方法,分割方法在缺陷信息获取上有其优势。但需要大量的标注数据,其标注信息是逐像素,往往花费大量的标注精力和成本<sup>[10]</sup>。

目标定位是计算机视觉领域中最基本的任务之一,其目的是获得目标精准的位置和类别信息。一般来说,基于深度学习的缺陷检测网络从结构上可以划分为以 Faster R-CNN<sup>[11]</sup>为代表的两阶段网络和以 SSD<sup>[12]</sup>或 YOLO<sup>[13]</sup>为代表的一阶段网络,两者的主要差异在于两阶段网络需要首先生成可能包含缺陷的候选框(proposal),然后再进一步进行目标检测。一阶段网络直接利用网络中提取的特征来预测缺陷的位置和类别。在现阶段追求检测速度的缺陷检测领域,基于一阶段的模型应用较多,在强调检测精度的缺陷检测领域,基于两阶段的模型采用较多<sup>[14]</sup>。

目前大多数研究内容对电子元器件进行缺陷检测的技术,主要是基于传统的机器视觉图像处理和特征提取方法,与深度学习技术相结合的实际应用比较少<sup>[15]</sup>,且传统方法不仅要对图像进行大量的预处理,对图像质量也有比较高的要求。在总结前人工作的基础上,本文使用基于 Faster R-CNN 两阶段的检测方法对电子元器件进行缺陷检测,将标记好的数据集输入网络进行训练,无需对图片进行大量数据增强、裁剪图片至相同尺寸等预处理。所提出的 Faster R-CNN 的电子元件缺陷检测方法,避免了传统缺陷检测需要手动选取目标特征的问题,缺陷的识别与定位过程的自动化程度更高;该方法检测效果良好,如果需要检测更多种类的缺陷,只需要对网络进行微调训练即可获得新的检测模型。本文为电子元器件进行缺陷检测问题提供了更为精确高效的方法。

## 1 Faster R-CNN 网络结构模型

Faster R-CNN 采用 VGG16 作为网络特征提取的主干网络(backbone),准确率进一步提升,在 2015 年 ILSVRC 以及 COCO 竞赛中获得多个项目的第一名,Faster R-CNN 结合了 RPN 网络和 Fast R-CNN<sup>[16]</sup>。

### 1.1 RPN 网络

在 Fast R-CNN 中使用 SS(selective search)<sup>[17]</sup>算法将一张图片生成 1~2 K 个候选区域,再将图片输入网络得到相应的特征图,将 SS 算法生成的候选框投影到特征图上获取相应的特征矩阵。这种由候选区域—特征图—特征矩阵的生成方式,包含了大量冗余重复的计算,耗时较长。

采用 RPN 来计算候选框的位置,它可以与 Fast R-CNN 共享卷积层从而降低计算成本。RPN 结构如图 1 所示,先经过 3×3 卷积,再经过 1×1 卷积。上面一条线是通过 Softmax 分类 anchor,获得前景和背景,下面计算

anchor 的边框回归参数,然后计算出来 Proposal。

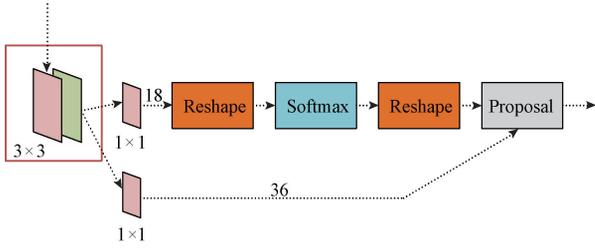


图 1 RPN 结构

Fig. 1 RPN architectural

对于特征图上的每个  $3 \times 3$  的滑动窗口,计算处滑动窗口中心点对应原始图像上的中心点,并计算  $k$  个 anchor boxes。通常 anchor 的选择分别有 3 种尺度  $128^2$ 、 $256^2$  和  $512^2$  和 3 种比例  $1:1$ 、 $1:2$  和  $2:1$ ,则每个位置在原图上对应 9 个 anchor,如图 2 所示。

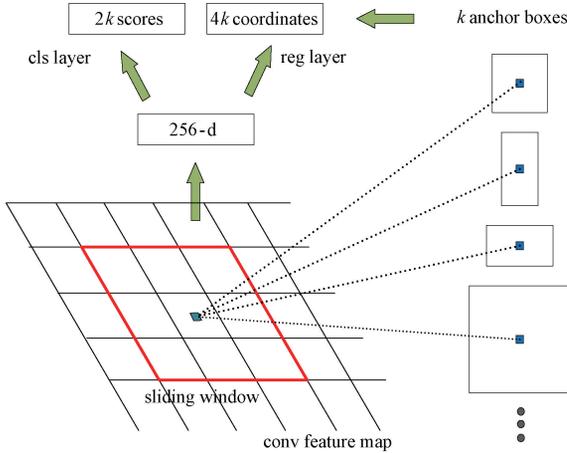


图 2 卷积特征图

Fig. 2 Conv feature map

对于一张  $1\ 000 \times 600 \times 3$  的图像,大约有  $60 \times 40 \times 9$  (20 K) 个 anchor,忽略跨越边界的 anchor 后,剩下约 6 K 个 anchor。对于 RPN 生成的候选框之间存在大量重叠,基于候选框的 cls 得分,采用非极大值抑制,IOU 设为 0.7,这样每张图只剩 2 K 个候选框。

RPN 网络的损失函数为:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

式中: $p_i$  表示第  $i$  个 anchor 预测为真实标签的概率; $p_i^*$  当为正样本时为 1,当为负样本时为 0; $t_i$  表示预测第  $i$  个 anchor 的边框回归参数; $t_i^*$  表示第  $i$  个 anchor 对应的标注数据 (GT Box) 的边框回归参数; $N_{cls}$  表示一个 mini-batch 中的所有样本数量 256; $N_{reg}$  表示 anchor 位置

的个数约 2 400。

$\sum_i L_{cls}(p_i, p_i^*)$  代表分类损失,其中:

$$L_{cls} = - [p_i^* \log(p_i) + (1 - p_i^*) \log(1 - p_i)] \quad (2)$$

$\sum_i p_i^* L_{reg}(t_i, t_i^*)$  代表边框回归损失,其中:

$$L_{reg}(t_i, t_i^*) = \sum_i smooth_{L1}(t_i - t_i^*) \quad (3)$$

$$t_i = [t_x, t_y, t_w, t_h], t_i^* = [t_x^*, t_y^*, t_w^*, t_h^*] \quad (4)$$

式中: $x, y, w, h$  分别为每个 anchor 的中心坐标、宽和高。

## 1.2 Faster R-CNN 网络

经过 R-CNN 和 Fast R-CNN 网络的研究及应用, Faster R-CNN 在结构上将特征提取、候选框生成、边框预测和目标分类整合在一个网络中,使得检测速度和综合性能有较大提高。Faster R-CNN 网络结构如图 3 所示。

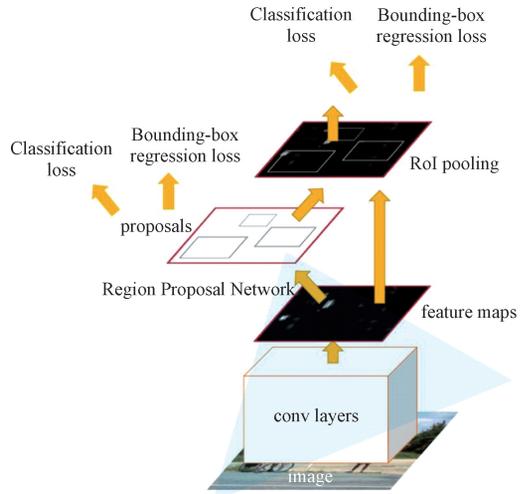


图 3 Faster R-CNN 网络结构

Fig. 3 Faster R-CNN architecture

Faster R-CNN 算法流程可分为如下 3 个步骤。

- 1) 将图像输入网络得到相应的特征图;
- 2) 使用 RPN 结构生成候选框,将 RPN 生成的候选框投影到特征图上获得相应的特征矩阵;
- 3) 将每个特征矩阵通过 ROI pooling 层缩放到  $7 \times 7$  大小的特征图,接着将特征图展平通过一系列全连接层得到预测结果。

Fast R-CNN 网络的总体损失计算如下:

$$L(p, u, t^u, v) = L_{cls}(p, u) + \lambda [u \geq 1] L_{loc}(t^u, v) \quad (5)$$

式中: $L_{cls}(p, u)$  为分类损失,  $\lambda [u \geq 1] L_{loc}(t^u, v)$  为边框回归损失。

$$L_{loc}(t^u, v) = \sum_{i \in \{x, y, z, w\}} smooth_{L1}(t_i^u - v_i) \quad (6)$$

式中: $p$  是分类器预测的 softmax 概率分布  $p = (p^0, \dots, p^k)$ ;  $u$  对应目标真实类别标签;  $t^u$  为预测的对边框框对

应类别  $u$  的回归参数  $(t_x^u, t_y^u, t_w^u, t_h^u)$ ;  $v$  为真实目标的边界框回归参数  $(v_x, v_y, v_w, v_h)$ 。

Faster R-CNN 网络用 RPN 结构取代 SS 来直接生成待检测区域,生成建议框仅需 10 ms,真正实现了端到端的目标检测框架,提高了检测精度和速度,但是对小目标的检测能力不够好。

## 2 电子元件缺陷检测方法

### 2.1 网络设计

#### 1) 图像处理

工业生产线上相机所采集的图片的大小可能是不同的,在输入网络过程中,为了加速运算,通常缩放到同样的尺寸,以张量形式将多张图片打包成一个 batch 送入网络, batch 指每一次迭代传入网络的图片数量(批数量)。

本方法采用预处理方法如图 4 所示,首先分别获取所有图片高的最大值  $H$  和宽的最大值  $W$ ,以  $H$  和  $W$  调整图片大小(根据计算机计算原理,高和宽的值取整到 32 的倍数,计算机硬件容易计算),矩形框用 0 填充。每张图片与其左上角重合来保持所标记的目标缺陷框(bounding box)的坐标不变,就达到了缩放到统一高为  $H$  宽为  $W$  的图片。且该方法能够保持原始图像的比例,不会畸形,空出来的部分全是 0,对检测不会产生干扰。

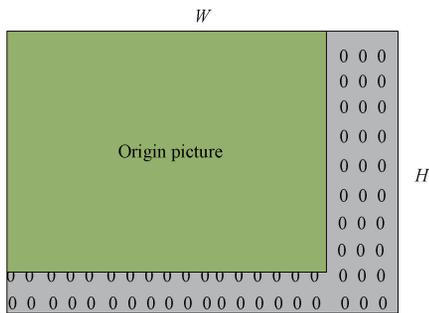


图 4 图片统一尺寸的方法

Fig. 4 The method to resize the pictures

对传入的照片进行标准化处理,为了提高训练效果,首先随机水平翻转图片,并计算出水平翻转之后的标注信息。对图像和标注信息进行打包成一个 batch 输入到网络进行正向传播,根据图像的缩放因子将结果映射到原始图片上。

#### 2) 迁移学习

Faster R-CNN 利用的是 vgg16 [18] 网络最后 conv5 卷积层的卷积特征,大小是  $7 \times 7 \times 512$ ,而这造成经过多次卷积之后的特征通常拥有很大的感受野,它们比较适合用来检测大物体,或者说,它们在检测小物体任务上效果差。

本文方法在特征提取部分中,选择 Resnet50 [19] 和 FPN [20] 作为特征提取的 backbone。Resnet50 为主干网络,主要是进行特征提取;FPN 主要用于构建特征金字塔给 RPN 提供输入特征图。加载预训练权重,然后利用迁移学习的方法对自建的实验数据集进行训练。

利用卷积网络本身的特性,即对原始图像进行卷积和池化操作,通过这种操作可以获得不同尺寸的特征图(feature map),类似于在图像的特征空间中构造金字塔,如图 5 所示。

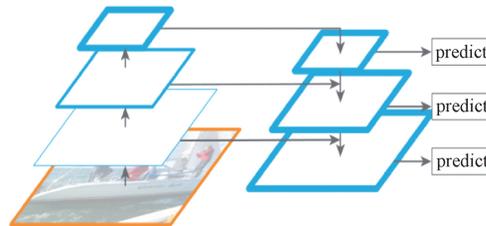


图 5 特征金字塔网络

Fig. 5 Feature pyramid networks

浅层的网络更关注于细节信息,高层的网络更关注于语义信息 [21]。低层特征可以提供更加准确的位置信息,而多次的降采样和上采样操作使得深层网络的定位信息存在误差,将处理过的低层特征和高层特征结合起来使用就构建了一个更深的特征金字塔,融合了多层特征信息,并在不同的特征进行输出。FPN 融合多层特征,以综合高层、低分辨率、强语义信息和低层、高分辨率、弱语义信息来增强网络对小目标的处理能力。FPN 在和 Faster R-CNN 结合后,和通常用多层融合的结果做预测的方法不同,FPN 在 5 个不同层独立进行预测。在基本不增加原有模型计算量的情况下,大幅提高对小目标的检测性能。

### 2.2 训练

#### 1) 实验环境

采取 Pytorch 深度学习框架进行网络结构的搭建和模型的训练。搭建环境包括使用的计算机 CPU 为 E5-1620 v4, 64 位操作系统, GPU 为 NVIDIA Tesla P4, Pytorch 版本为 1.5, 开发环境为 Pycharm 2019.1,

#### 2) 数据集

基于 Faster R-CNN 网络的电子元件缺陷检测是一种监督式学习,因此需要对图像添加标注信息,便于训练迭代。本文使用 LableImg 标注工具对样本进行信息标注,制作实验所需要的数据集。在界面打开数据样本文件夹目录,对图中有缺陷部位进行框图绘制并命名缺陷名称,标注完的样本生成关联的 xml 文件,该文件记录了含有缺陷部位的具体坐标信息。标注界面如图 6 所示。

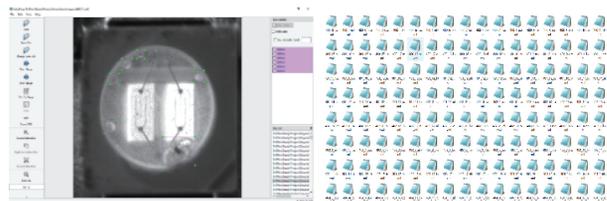


图 6 labelImg 样本标注

Fig. 6 Labeling sample annotation

### 3) 网络训练

优化器为 torch.optim.SGD, 动量因子 momentum 为 0.9, 权重衰减 (L2 惩罚) weigh\_decay 为 0.0005。学习率优化策略采用 torch.optim.lr\_scheduler.StepLR, 学习率更新公式如下:

$$new\_lr = initial\_lr \times gamma^{epoch/step\_size} \quad (7)$$

其中, 初始值 initial\_lr 为 0.005, step\_size 为 5, gamma 为 0.33, epoch 为训练总轮数。

本文在网络第 1 轮训练时采用 warmup 方式训练, 该方式有助于减缓模型在初始阶段的提前过拟合现象, 保持分布的平稳、有助于保持模型深层的稳定性。

## 3 实验测试与分析

### 3.1 评价指标

精确率 (AP) 是针对预测结果而言的, 表示的是预测为正的样本中有多少是真正的正样本。预测为正有两种可能, 一种是把正类预测为正类 (TP), 另一种是把负类预测为正类 (FP), 即:

$$P = \frac{TP}{TP + FP} \quad (8)$$

召回率 (Recall) 是针对原来的样本而言的, 它表示的是样本中的正例有多少被预测正确。一种是把原来的正类预测成 TP, 另一种是把原来的正类预测为负类 (FN), 即:

$$P = \frac{TP}{TP + FN} \quad (9)$$

### 3.2 实验结果

将原始数据集输入 Faster R-CNN 网络进行训练, 对得到的模型进行测试。当图片质量本身较高时, 检测效果尚可, 如图 7(a) 所示。

由于生产检测环境不受控, 往往会出现以下问题:

- 1) 图像传感器在拍摄时视场不够明亮、亮度不够均匀;
  - 2) 电路各元器件自身噪声和相互影响;
  - 3) 图像传感器长期工作, 温度过高。
- 获取到的图像可能明暗不均、成像清晰度不高。此

时检测效果如图 7(b) 所示, 几乎检测不出缺陷, 抗干扰性差。

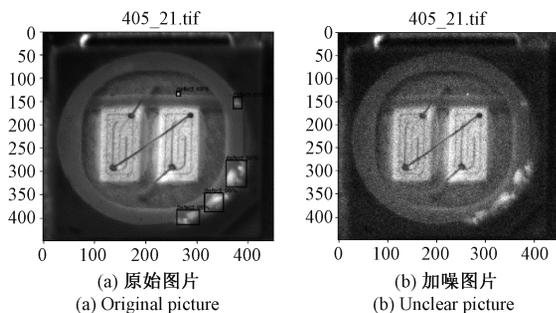


图 7 用原始数据集训练的 Faster R-CNN 网络的检测效果  
Fig. 7 Detection effect of faster R-CNN network trained with original dataset

本文将原始数据集图片分别进行随机亮度改变、添加高斯噪声, 最终训练集包括 1610 张图片, 验证集包括 178 张图片。在网络训练在 25 个 epoch 时, loss 值和平均精确率 (mAP) 趋于稳定, 如图 8 所示。

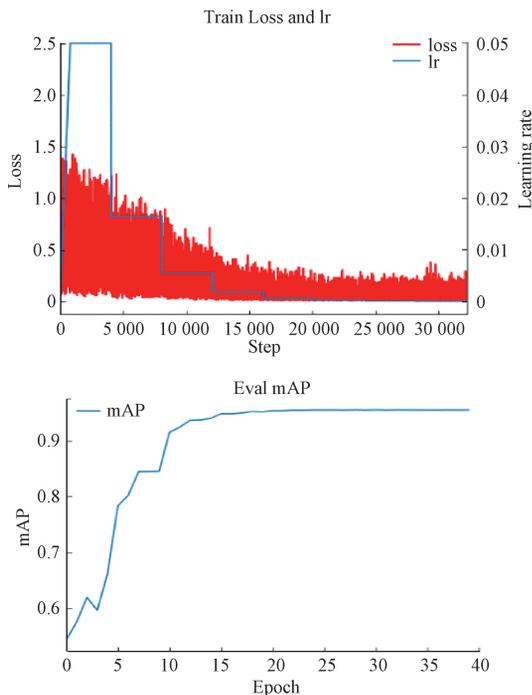


图 8 loss 值和 mAP 值曲线

Fig. 8 Loss value and map value curve

为了检测网络的能力, 在训练集内随机选取图片“1273\_1\_n1.tif”, 在数据集外随机选取图片“405\_21\_n1.tif”, 两种情况皆添加了噪声并随机改变了亮度。用传统的 Fast R-CNN 的检测效果如图 9 所示, 对于气泡这类小物体检测两种检测对象的检测效果都非常差, 没有检测到缺陷并将灯芯误认为缺陷。图 10 所示为以 Resnet50+

FPN 为 backbone 的网络检测效果,在特征提取阶段,利用池化金字塔结构的多尺度检测特性,检测效果有明显提升,但是检测效果仍不理想,泛化能力较差。

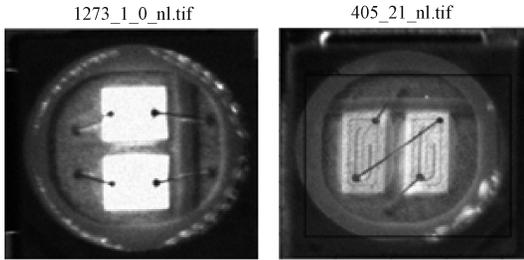


图 9 传统 R-CNN 网络效果

Fig. 9 Detection effect of traditional Fast R-CNN network

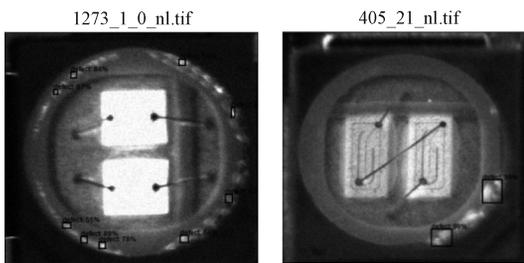


图 10 resnet50+FPN 的网络效果

Fig. 10 Detection effect of network with Resnet50+FPN

本文为了更加精准的标注聚集性气泡和单个气泡并提高网络泛化能力,选择将 anchor 的尺度种类扩大, Faster R-CNN 方法为  $128^2$ 、 $256^2$  和  $256^2$ 。经试验表明,过多的扩大尺度会让网络将图片边缘的非检测区域误检为缺陷,并会加大网络的计算量,选择 anchor 尺寸为  $16^2$ 、 $32^2$ 、 $64^2$ 、 $128^2$  和  $256^2$  五种,在更大的特征图获得更多关于小目标的有用信息。总体检测效果如图 11 所示,此时网络已经具有良好的检测精度,且数据集内外的图片检测效果都比较好,则该网络具有了一定的泛化能力。

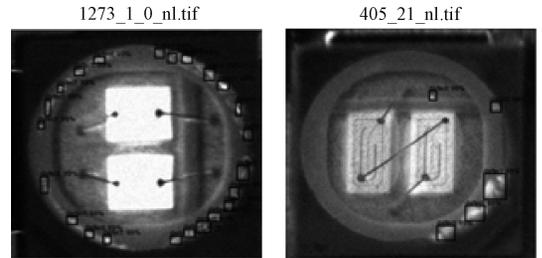


图 11 本文方法效果

Fig. 11 Detection effect of the method

图 12 所示为本文方法在无缺陷的检测图片上未产生误检,且对不同大小尺度气泡均可正确检测。针对聚集性气泡,本文方法可准确绘制多个小气泡聚集而成的外围轮廓,减少网络计算量对计算机硬件的要求。

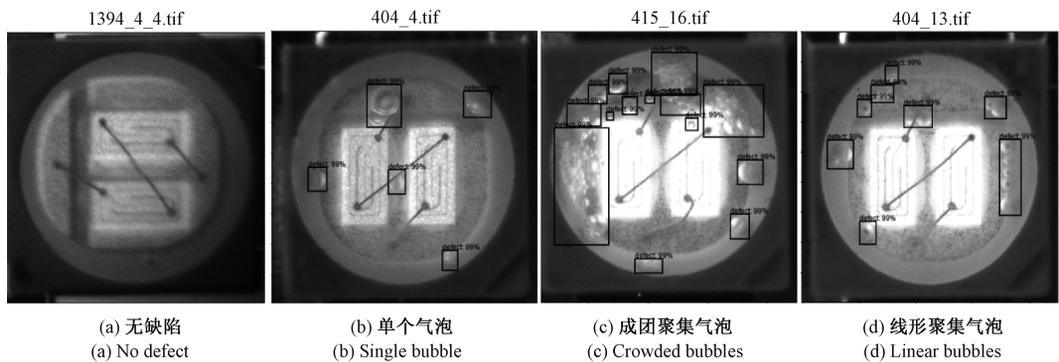


图 12 本文方法对不同缺陷的检测效果

Fig. 12 The detection effect of the method on different defects

为了减少检测时间,在 feature map 前 4 个特征层进行预测,舍去 pool 层,经实验表明可在检测时间上有一定的缩短,且不影响检测精度。

在不同方法模型上对 14 张数据集以外的图片进行单张检测,其平均检测时间如表 1 所示,其中精确率和召回率为不同方法模型在验证集中的定位结果。

### 3.3 结果分析

本文方法在针对不同尺度大小、形状的缺陷具有良好检测精度。通过对数据集进行加噪、改变亮度等处理,扩充 anchor 尺度大小范围在不同特征层进行缺陷检测使

表 1 检测效果汇总

Table 1 Summary of defect detection

方法	AP/%	Recall/%	Time/ms
Faster R-CNN	86.4	65.9	179
network with resnet50+FPN	94.5	83.8	119
本文	95.6	86.7	101

本文方法具有较好的泛化能力。虽然减少了预测特征的层数,但是由于 Faster R-CNN 这种两阶段目标检测网络的局限性,由表 1 可以看出,检测时间的提升不够理想。本文主要针对的是单张图片检测,在某些场合下会遇到

大视场多图同时检测,将会涉及到超分辨率检测技术。本文后续将进一步对这些方向进行研究。

## 4 结 论

本文提出了一种基于 Faster R-CNN 网络的电子元件缺陷检测方法。首先标注图片和气泡缺陷信息,然后针对缺陷区域,利用迁移学习设计相应的神经网络模型进行 LED 元件气泡缺陷识别,改变原 Faster R-CNN 网络的特征提取部分为 Resnet50 和 RPN 结构。通过对数据集进行加噪、改变亮度等处理,扩充 anchor 尺度大小范围使本文方法具有较好的泛化能力、鲁棒性强。减少在特征图上预测的层数,检测时间有一定的提升。实验结果表明,与传统的方法相比,本文提出的检测方法在本文数据集上对 LED 缺陷检测识别的准确率大幅度提高,达到了 95.6%,召回率提高 20.8%,泛化能力、抗噪性能较好;单张检测时间约为 100 ms,满足工业化生产的要求,为电子元件缺陷在线检测提供可有效的解决方案。

## 参考文献

- [ 1 ] 唐加良. 一种 LED 封装胶的检测方法:江苏省 CN111189853A[P]. 2020-05-22.  
TANG J L. A detection method of LED encapsulation adhesive;Jiangsu Province; CN111189853A[P]. 2020-05-22.
- [ 2 ] 汤勃,孔建益,伍世虔. 机器视觉表面缺陷检测综述[J]. 中国图象图形学报,2017,22(12):1640-1663.  
TANG B, KONG J Y, WU SH Q. A review of machine vision surface defect detection[J]. Chinese Journal of Graphics,2017,22(12):1640-1663.
- [ 3 ] 罗瑞荣,高健,郑卓璿,等. 自适应光亮度的 LED 缺陷检测算法[J]. 组合机床与自动化加工技术,2019(11):46-50.  
LUO R R, GAO J, ZHENG ZH J, et al. LED defect detection algorithm based on adaptive brightness[J]. Modular Machine Tool and Automatic Manufacturing Technology,2019(11):46-50.
- [ 4 ] 陶显,侯伟,徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报 2021, 47(5): 1017-1034.  
TAO X, HOU W, XU D. A review of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
- [ 5 ] LIN G F, SHEN W. Research on convolutional neural network based on improved Relu piecewise activation function[J]. Procedia Computer Science, 2018, 131: 977-984.
- [ 6 ] LIANG Q, ZHU W, SUN W, et al. In-line inspection solution for codes on complex backgrounds for the plastic

- container industry [ J ]. Measurement, 2019, 148:106965.
- [ 7 ] TABERNIK D, ŠELA S, SKVARČ J, et al. Segmentation-based deep-learning approach for surface-defect detection[J]. Journal of Intelligent Manufacturing, 2020, 31 ( 3 ): 759-776.
- [ 8 ] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [ J ]. IEEE Transactions On Pattern Analysis And Machine Intelligence, 2017, 39(4): 640-651. .
- [ 9 ] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [ C ]. IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [ 10 ] 吴静兰. 基于深度学习的电子元件缺陷检测关键问题研究[D]. 广州:华南理工大学,2019.  
WU J L. Research on key issues of electronic component defect detection based on deep learning[D]. Guangzhou: South China University of Technology, 2019.
- [ 11 ] 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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [ 12 ] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector [ C ]. Computer Vision-ECCV 2016, 2016: 21-37.
- [ 13 ] 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, 2016: 779-88.
- [ 14 ] 王永利,曹江涛,姬晓飞. 基于卷积神经网络的 PCB 缺陷检测与识别算法[J]. 电子测量与仪器学报, 2019, 33(8): 78-84.  
WANG Y L, CAO J T, JI X F. PCB defect detection and recognition algorithm based on convolutional neural network [ J ]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 78-84.
- [ 15 ] 王宏硕,杨永跃. 基于改进显著性模型的 TFT-LCD 面板缺陷检测[J]. 电子测量与仪器学报,2018,32(7): 29-35.  
WANG H SH, YANG Y Y. Detection of TFT-LCD panel defects based on improved saliency model[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(7):29-35.
- [ 16 ] GIRSHICK R, IEEE. Fast R-CNN [ C ]. 2015 IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [ 17 ] UIJLINGS J, SANDE K, GEVERS T, et al. Selective search for object recognition[J]. International Journal of

Computer Vision 2013, 104(2):154-171.

- [18] 袁功霖,尹奎英,李绮雪. 基于迁移学习的航拍图像车辆目标检测方法研究[J]. 电子测量技术, 2018, 41(22):77-81.  
YUAN G L, YIN K Y, LI Q X. Research on aerial image vehicle target detection method based on transfer learning[J]. Electronic Measurement Technology, 2018, 41(22): 77-81.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2016.
- [20] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-44.
- [21] 陈丹,林清泉. 基于级联式 Faster RCNN 的三维目标最优抓取方法研究[J]. 仪器仪表学报, 2019, 40(4): 229-237.  
CHEN D, LIN Q Q. Research on optimal capture method of 3D targets based on cascaded Faster RCNN [J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 229-237.

## 作者简介



王标, 2003 年于合肥工业大学获得学士学位, 2009 年于合肥工业大学获得博士学位, 现为合肥工业大学仪器科学与光电工程学院副教授, 主要研究领域为精密检测及在线测试、微构件材料特性测试和机器视觉与图像处理。

**Wang Biao** received his B. Sc. degree in 2003 from Hefei University of Technology, Ph. D. degree in 2009 from Hefei

University of Technology. Now he is an associate professor in School of Instrument Science and Opto-electronics Engineering, Hefei University of Technology. His main research interests include the precision detection and online measurement, micro-component material characteristic test, machine vision and image processing.



周雅兰, 2018 年于安徽大学获得学士学位, 现为合肥工业大学硕士研究生, 主要研究方向为基于深度学习的机器视觉与图像处理。

E-mail: zhouyalan78@126.com

**Zhou Yalan** received her B. Sc. degree in 2018 from Anhui University in 2018. Now she is a M. Sc. candidate in Hefei University of Technology. Her main research interests include machine vision and image processing based deep learning.



王永红(通信作者), 1994 年于合肥工业大学获得学士学位, 1997 年于中科院合肥物质科学研究院获得硕士学位, 2003 年于合肥工业大学获得博士学位, 现为合肥工业大学仪器科学与光电工程学院教授, 主要研究领域为光学精密测试技术、激光散斑干涉、机器视觉与图像处理。

E-mail: yhwang@hfut.edu.cn

**Wang Yonghong** (Corresponding author) received his B. Sc. degree from Hefei University of Technology in 1994, M. Sc. degree from Hefei Institutes of Physical Science, Chinese Academy of Sciences in 1997, and Ph. D. degree in 2003 from Hefei University of Technology. Now he is a professor in School of Instrument Science and Opto-electronics Engineering, Hefei University of Technology. His main research interests include optical precision testing technology, laser speckle interference, machine vision and image processing.