

# 基于改进 YOLOV3 的载波芯片缺陷检测

周天宇<sup>1</sup>, 朱启兵<sup>1\*</sup>, 黄敏<sup>1</sup>, 蔡贵良<sup>1</sup>, 徐晓祥<sup>2</sup>

<sup>1</sup>江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122;

<sup>2</sup>无锡市创凯电气控制设备有限公司, 江苏 无锡 214400

**摘要** 载波芯片(COC)是光发射次模块的重要组成部分,随着芯片制造工艺的进步,COC 向着微型化、高密度的方向发展,缺陷的种类变得更加复杂多样,基于传统图像处理方法的光学检测技术已无法满足 COC 多类别缺陷检测的需求。为此,将 YOLOV3 网络引入到 COC 的典型缺陷(崩口、定位柱破损以及波导污渍)检测。针对波导污渍缺陷目标较小,且不同类型缺陷之间尺度变化较大的问题,改进了原有 YOLOV3 的特征提取网络,兼顾目标的多尺度特性设计了 4 个检测尺度,并通过增强特征融合来改进多尺度检测;利用 K-means 方法对数据集进行聚类分析,选取优化的初始先验框。实验结果表明,本文基于改进 YOLOV3 的 COC 缺陷检测方法 YOLOV3-COC 对于 COC 崩口、定位柱破损以及波导污渍这三类缺陷检测的准确性达到 97.4%。

**关键词** 图像处理; 图像识别; 载波芯片缺陷检测; 目标检测; YOLOV3; 光发射次模块

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1210002

## Defect Detection of Chip on Carrier Based on Improved YOLOV3

Zhou Tianyu<sup>1</sup>, Zhu Qibing<sup>1\*</sup>, Huang Min<sup>1</sup>, Cai Guiliang<sup>1</sup>, Xu Xiaoxiang<sup>2</sup>

<sup>1</sup>Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education, Jiangnan University, Wuxi, Jiangsu 214122, China;

<sup>2</sup>Wuxi CK Electric Control Equipment Co., Ltd., Wuxi, Jiangsu 214400, China

**Abstract** Chip on carrier (COC) is an important component of transmitter optical subassembly and is widely used in the field of optical communication. With the progress of chip manufacturing process, COC is developing towards miniaturization and high density, and the types of defects become more complex and diverse. Optical inspection technology based on traditional image processing methods can no longer meet the requirements of COC multi-category defect detection. In this paper, YOLOV3 is introduced into the detection of typical defects of COC, such as collapse, positioning column damage, and waveguide stain. Aiming at the problem that the waveguide stain defect target is small and the scale changes greatly among different types of defects, the original YOLOV3 feature extraction network is improved, and the 4 detection scales are designed taking into account the multi-scale characteristics of the target, and the multi-scale detection is improved by enhancing feature fusion. The K-means method is used to perform cluster analysis on the data set, and select the optimized initial prior frame. Experimental results show that the accuracy of YOLOV3-COC, a COC defect detection method based on improved YOLOV3, is 97.4% for the detection of 3 types of defects: COC chipping, broken positioning pillars, and waveguide stain.

**Key words** image processing; image recognition; defect detection of chip on carrier; object detection; YOLOV3; transmitter optical subassembly

**OCIS codes** 100.3008; 100.4996; 150.1135

收稿日期: 2020-08-24; 修回日期: 2020-09-09; 录用日期: 2020-10-14

基金项目: 国家自然科学基金(61775086)

\*E-mail: zhuqib@163.com

## 1 引言

光发射次模块(TOSA)可以实现光电信号的转换,在光通信领域具有广泛的应用。作为 TOSA 的重要组成部分,载波芯片(COC)的质量好坏对 TOSA 是否能够长期稳定地工作有着很大的影响。由于制造工艺和生产环境的影响,COC 在生产过程中会出现各种各样的缺陷。传统的 COC 缺陷检测方法多是人工视觉检测法,该方法的检测效率低,检测准确性易受检测人员的经验、情绪和视觉疲劳等因素的影响,难以适用于大规模的 COC 缺陷检测。

随着机器视觉技术的发展<sup>[1-3]</sup>,一些基于机器视觉的光学检测法被引入到芯片的缺陷检测<sup>[4-10]</sup>。其中,Chen 等<sup>[5]</sup>提出的半导体芯片的混合缺陷检测方法将图像对准策略和自适应图像差分方法应用于芯片表面凸块的检测。刘琛等<sup>[10]</sup>提出了一种基于方位环境特征的点模式匹配定位算法实现芯片引脚缺陷检测。上述光学检测算法大多通过待检测芯片图像和标准芯片图像进行模板匹配来实现缺陷检测。由于 COC 缺陷目标较小,不同类型缺陷之间尺度变化较大,基于上述方法的芯片检测技术难以满足 COC 缺陷检测准确性的需求。

近年来,随着深度学习的发展,多种基于深度卷积神经网络的目标检测方法被提出,并被成功地应用于产品的缺陷检测。例如:李宜汀等<sup>[11]</sup>利用 Faster R-CNN 进行油辣椒灌装生产线的封盖面的缺陷检测;吴涛等<sup>[12]</sup>提出了一种轻量级 YOLOV3 的绝缘子缺陷检测方法;钟嘉俊等<sup>[13]</sup>提出了改进的 Faster R-CNN 方法,对地铁车辆焊缝进行缺陷检测。但就作者所掌握的文献来看,利用深度学习算法对 COC 图像进行缺陷检测的研究还未见报道。

基于深度卷积神经网络的目标检测方法主要可以分为两类。一类是基于区域推荐的双阶段分类算法,代表性算法有 R-CNN<sup>[14]</sup>、Fast R-CNN<sup>[15]</sup> 和 Faster R-CNN<sup>[16]</sup> 等。另一类是基于端到端的单阶段回归算法,代表性算法有 SSD<sup>[17]</sup>、YOLO<sup>[18]</sup>、YOLOV2<sup>[19]</sup> 和 YOLOV3<sup>[20]</sup> 等。其中双阶段分类算法具有较高的检测准确性而单阶段回归算法具有更快的检测速度。YOLOV3 借鉴了残差网络结构,形成更深的网络层次,在保持单阶段回归算法速度优势的前提下,提高了检测准确性和小目标的检测能力,因此本文将 YOLOV3 算法引入到 COC 缺陷检测。针对波导污渍缺陷目标较小,且不同类型缺陷之间尺度变化较大的问题,对原有 YOLOV3 算法的特征提

取网络、多尺度特征融合和先验目标框的设计进行改进。实验结果表明,本文提出的 COC 缺陷检测方法 YOLOV3-COC 具有较高的检测准确性。

## 2 COC 缺陷特征分析

图 1 所示为一个完好的 COC,实线框表示定位柱区域,虚线框表示波导区域。在 COC 的生产过程中,由于制造工艺和设备老化的影响,会出现崩口和定位柱破损的缺陷。此外,COC 的生产对环境要求十分苛刻,由于温度以及生产环境的影响,还会出现波导区域污渍的缺陷。图 2 所示为 COC 崩口、定位柱破损以及波导区域污渍三种类别的缺陷,点划线框表示崩口,实线框表示定位柱破损,虚线框表示波导污渍。COC 的缺陷尺度变化大,波导区域污渍目标小,崩口最大尺寸达到  $33 \times 282$ ,而波导污渍最小尺寸为  $19 \times 23$ ,这正是 COC 缺陷检测的难点所在。




图 1 完好 COC

Fig. 1 Intact COC




图 2 COC 缺陷

Fig. 2 COC defect

## 3 YOLOV3 原理

为了加强对小目标的检测准确性,YOLOV3 采用了类似特征金字塔网络(FPN)的思想,对输入图片经过主干网络 32、16、8 倍降采样得到的三种尺度的特征图进行特征融合,从而实现多尺度预测。YOLOV3 的结构如图 3 所示,DBL(Darknetconv2d\_

BN\_Leaky)是YOLOV3的基本组件,如图3左下角虚线框所示,由卷积层(Conv)、批标准化层(BN)和激活层(Leaky Relu)组成。图3正下方虚线框中的 $Res_n(n=1,2,3,\dots)$ 是YOLOV3的大组件,包含 $n$ 个引入了残差结构的 $Res\_unit$ 。 $Res\_unit$ 的结构如图3右下角虚线框所示,借鉴了ResNet的思想,在两个DBL之后进行一次残差跳层连接。

YOLOV3的主干网络Darknet-53使用了 $Res1, Res2, Res8, Res8$ 和 $Res4$ 五个 $Res_n$ 结构,对尺寸为 $416 \times 416$ 的输入图片进行特征提取,经过32倍、16倍和8倍降采样得到 $13 \times 13, 26 \times 26$ 和 $52 \times 52$ 三种尺寸的特征图。然后分别对低层特征图进行2倍上采样之后与上层特征图进行张量拼接,最终得到3个不同尺度的输出 $y_1, y_2, y_3$ 。

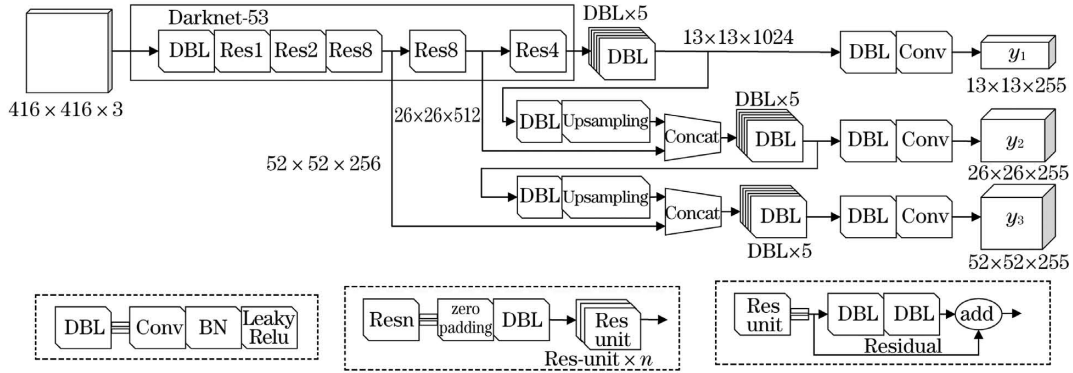


图 3 YOLOV3 结构图

Fig. 3 Structure of YOLOV3

在预测阶段,对于每张输入图像,预测包括目标边界框位置、目标类别和置信度的三维张量。将 $13 \times 13, 26 \times 26$ 和 $52 \times 52$ 三种尺寸的特征图划分为 $S \times S$ 个单元格( $S$ 分别取13、26和52),给每个网格设置3个先验框来预测3个边界框,输出维度为 $S \times S \times [3 \times (4+1+M)]$ ,即4个边界框的偏移量、1个缺陷目标置信度和 $M$ 个缺陷类型。最后通过非极大值抑制(NMS)的方法剔除重复的边界框,从而实现目标检测。

### 4 COC 缺陷检测方法

#### 4.1 特征提取网络改进

YOLOV3的特征提取网络Darknet-53如表1所示,对尺寸为 $416 \times 416$ 的输入图片进行特征提取,采用了32倍、16倍以及8倍降采样得到 $13 \times 13, 26 \times 26$ 和 $52 \times 52$ 的特征图进行预测。浅层特征图包含更多的位置信息,适合小目标的检测;深层特征图语义信息较多,适合大目标的检测。由于本文的COC待检测区域图像尺寸在 $500 \times 500$ 左右,如果压缩到 $416 \times 416$ 作为输入,使得原本就很小的目标变得更小,不利于检测。此外, $52 \times 52$ 的特征图对于波导区域污渍这类小目标缺陷的检测是不够的,需要选用更大的特征图,如果直接选用更浅层的 $104 \times 104$ 的特征图又会引入大量的计算量,对检测速度产生很大的影响。

表 1 Darknet-53

Table 1 Darknet-53

Res	Type	Filters	Size(stride)	Output
1×	Conv	32	3×3	416×416×32
	Conv	64	3×3(2)	208×208×64
	Conv	32	1×1	208×208×64
	Conv	64	3×3	
	Residual			208×208×64
2×	Conv	128	3×3(2)	104×104×128
	Conv	64	1×1	104×104×128
	Conv	128	3×3	
	Residual			104×104×128
8×	Conv	256	3×3(2)	52×52×256
	Conv	128	1×1	52×52×256
	Conv	256	3×3	
	Residual			52×52×256
8×	Conv	512	3×3(2)	26×26×512
	Conv	256	1×1	26×26×512
	Conv	512	3×3	
	Residual			26×26×512
4×	Conv	1024	3×3(2)	13×13×1024
	Conv	512	1×1	13×13×1024
	Conv	1024	3×3	
	Residual			13×13×1024

综合考虑 COC 图像尺寸和缺陷的大小,如表 2 所示,本文选取  $576 \times 576$  作为输入图像的尺寸,增加了特征提取网络的深度,选用  $9 \times 9$ 、 $18 \times 18$ 、 $36 \times 36$  和  $72 \times 72$  四个不同尺度的特征图进行特征融合。由于引入深层网络增加额外的计算量,考虑到检测速度的需求,减少 16 倍降采样后的残差块数量。本文改进的特征提取网络 Darknet-49 在原有的 Darknet-53 的基础上,使用更少的卷积层提取到更深层的特征图并且对浅层特征进行更好的融合。

表 2 改进的特征提取网络 Darknet-49

Table 2 Improved feature extraction network Darknet-49

Res	Type	Filters	Size(stride)	Output
1×	Conv	32	$3 \times 3$	$576 \times 576 \times 32$
	Conv	64	$3 \times 3(2)$	$288 \times 288 \times 64$
	Conv	32	$1 \times 1$	$288 \times 288 \times 64$
	Conv	64	$3 \times 3$	
Residual				$288 \times 288 \times 64$
2×	Conv	128	$3 \times 3(2)$	$144 \times 144 \times 128$
	Conv	64	$1 \times 1$	$144 \times 144 \times 128$
	Conv	128	$3 \times 3$	
Residual				$144 \times 144 \times 128$
8×	Conv	256	$3 \times 3(2)$	$72 \times 72 \times 256$
	Conv	128	$1 \times 1$	$72 \times 72 \times 256$
	Conv	256	$3 \times 3$	
Residual				$72 \times 72 \times 256$
4×	Conv	512	$3 \times 3(2)$	$36 \times 36 \times 512$
	Conv	256	$1 \times 1$	$36 \times 36 \times 512$
	Conv	512	$3 \times 3$	
Residual				$36 \times 36 \times 512$
4×	Conv	1024	$3 \times 3(2)$	$18 \times 18 \times 1024$
	Conv	512	$1 \times 1$	$18 \times 18 \times 1024$
	Conv	1024	$3 \times 3$	
Residual				$18 \times 18 \times 1024$
2×	Conv	2048	$3 \times 3(2)$	$9 \times 9 \times 2048$
	Conv	1024	$1 \times 1$	$9 \times 9 \times 2048$
	Conv	2048	$3 \times 3$	
Residual				$9 \times 9 \times 2048$

### 4.2 多尺度特征融合改进

为了解决 YOLOV3 算法对 COC 小目标缺陷检测准确性低的问题,本文改进了原有的特征提取网络,对输入图片进行 64 倍、32 倍、16 倍和 8 倍降采样得到  $9 \times 9$ 、 $18 \times 18$ 、 $36 \times 36$  和  $72 \times 72$  四个不同尺度

的特征图,将原有的 3 尺度检测改进为 4 尺度检测。

YOLOV3 的多尺度特征融合如图 4 所示,分别对 32 倍和 16 降采样得到的特征图进行 2 倍上采样,与上层特征图进行张量拼接,最终得到 3 个不同尺度的输出。本文采用了 4 个不同尺度的特征图,为了更好地融合浅层特征图和深层特征图信息,使得大目标和小目标都能被精确检测,采取增强特征融合。在现有 2 倍上采样的基础上,增加 4 倍和 8 倍上采样,更加充分地融合 4 个不同尺度特征图的特征信息。改进的多尺度特征融合方法如图 5 所

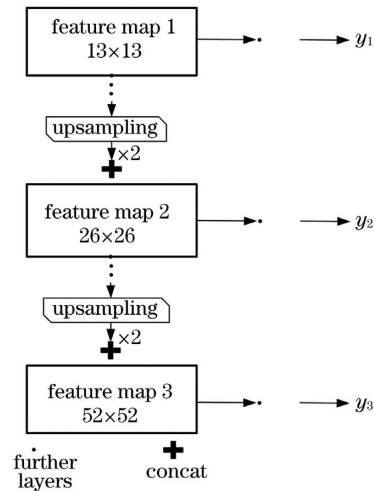


图 4 YOLOV3 多尺度特征融合

Fig. 4 Multi-scale feature fusion of YOLOV3

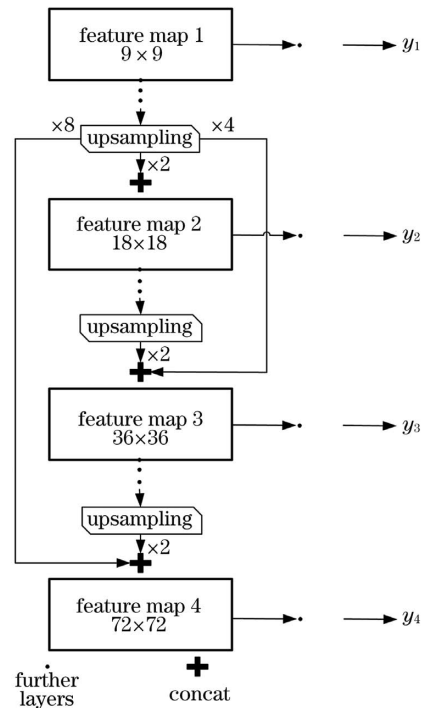


图 5 改进的多尺度特征融合

Fig. 5 Improved multi-scale feature fusion

示,最终得到 4 个不同尺度的输出  $y_1$ 、 $y_2$ 、 $y_3$  和  $y_4$ 。改进后的 4 尺度检测融合了更多的浅层信息并且更加重视深层特征,能够进一步提高对 COC 各类缺陷的检测效果。

### 4.3 COC 先验框设计

针对 COC 数据集,本文通过 K-means 算法对已标注的目标框进行聚类分析,综合考虑 3 种类别缺陷的大小和尺度变化范围,针对 4 种尺度的特征图分别设计 3 种尺度共 12 种尺度的先验框,如表 3 所示。

表 3 先验框  
Table 3 *A priori* box

Feature map size	Size	Number
9×9	(40×230);(58×343);(178×156)	9×9×3
18×18	(108×38);(45×136);(18×118)	18×18×3
36×36	(57×77);(90×18);(62×45)	36×36×3
72×72	(6×8);(13×10);(16×30)	72×72×3




图 6 COC 待检测区域提取。(a)原图;(b)边缘检测;(c)角点检测;(d)COC 待检测区域

Fig. 6 Extraction of the area to be detected on COC. (a) Original image; (b) edge detection; (c) corner detection;

(d) area to be detected on COC

得到 COC 区域的四个角点,如图 6(c)所示。最后,根据四个角点坐标进行仿射变换并且保留部分边界区域,提取到的 COC 待检测区域如图 6(d)所示。

### 5.2.2 数据集增强

本实验通过 200 倍显微相机采集得到 200 张 COC 图像,经过 COC 待检测区域提取之后得到

## 5 实验及结果分析

### 5.1 实验环境

本实验在 Windows 10(64 位)环境下基于 Python Keras 和 TensorFlow 深度学习框架实现,在配置有 Inter(R) Core(TM) i7-5930K CPU @ 3.50 GHz, 32 GB 内存,NVIDA GeForce GTX TITAN X 的服务器下进行,GPU 加速库为 CUDA9.0。

### 5.2 数据集

#### 5.2.1 COC 待检测区域提取

COC 经过 200 倍显微镜相机采集图像如图 6(a)所示,由于拍摄角度以及拍摄距离的影响,待检测区域周围存在太多边界无用区域,这对小目标缺陷占比和检测速度产生了很大的影响,不利于缺陷检测,因此,需要先对 COC 区域进行提取。由于 COC 区域的亮度高于周围区域,先进行 Canny 边缘检测,再进行轮廓检测找出最大的轮廓如图 6(b)所示。接着,对图 6(b)进行角点检测可以

COC 数据集,选取 150 张用作训练,50 张用作测试。对 150 张训练样本进行数据增强,首先,分别对原有数据采取水平翻转和垂直翻转。然后,考虑到 COC 图像缺陷特征不明显的特殊性,对图像中的每个像素乘以 1.2 来提高图片的亮度,使得缺陷特征更加明显。此外,引入高斯变换标准差为 1.2 的高

斯噪声以及锐化操作实现数据增强。使用以上五种增强方法,原有的 150 张图片增加到 4800 张。使用 labellmg 图像标注软件进行人工标注,数据集格式为 VOC2007。

### 5.3 模型训练

模型训练阶段,本实验的训练轮次设置为 300,批量大小为 16,动量为 0.9,衰变值为 0.0005,初始学习率为 0.001,在第 100 次 epoch 之后减小为 0.0001。本文提出的 YOLOV3-COC 模型训练的损失值曲线如图 7 所示,当 Epoch 达到 250 次时,损失值趋于稳定,最终下降到 0.4 左右。

### 5.4 实验结果

待检测图片数量共 50 张,每张图片包含 1~3 种类别的缺陷,波导区域污渍、崩口以及定位柱破损

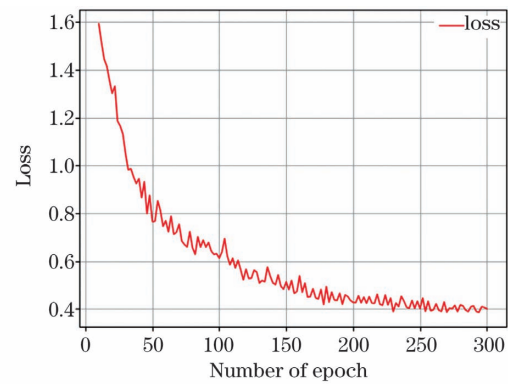


图 7 损失值曲线图

Fig. 7 Loss value graph

3 种缺陷的个数以及检测结果如表 4 所示,其中误检率表示对缺陷的类别进行误判的概率,漏检率表示对缺陷未能检测到的概率。

表 4 缺陷检测统计

Table 4 Defect detection statistics

Defect	Total	Correct detection	False detection	Missed detection	Accuracy	False detection rate	Missed detection rate
Waveguide stain	69	68	0	1	0.986	0	0.014
Collapse	98	95	0	3	0.969	0	0.031
Positioning column damage	27	26	0	1	0.963	0	0.037
Total	194	189	0	5	0.974	0	0.026

由表 4 可知,本文算法对于 COC 中波导污渍、崩口和定位柱破损三种不同种类缺陷的检测准确率分别达到了 98.6%、96.9% 和 96.3%,没有出现误检情况。

为了进一步验证本文算法在 COC 缺陷检测上的有效性,将本文算法与常见的目标检测算法

Faster R-CNN<sup>[16]</sup>、SSD<sup>[17]</sup>、YOLO<sup>[18]</sup>、YOLOV2<sup>[19]</sup>以及改进前的 YOLOV3<sup>[20]</sup>在相同的数据集上进行对比实验,采用原文作者的实验参数,选取平均准确率和每张图片的检测时间作为评价指标,不同算法的性能如表 5 所示。

表 5 不同算法 COC 缺陷检测结果

Table 5 COC defect detection results of different algorithms

Model	Backbone	Size	Accuracy /%	Time /s
Faster R-CNN	VGG-16	600×600	82.6	0.94
SSD	VGG-16	512×512	85.4	0.63
YOLO	Google-Net	448×448	74.8	0.65
YOLOV2	Darknet-19	416×416	76.3	0.68
YOLOV3	Darknet-53	416×416	92.5	0.76
YOLOV3-COC	Darknet-49	576×576	97.4	0.72

根据表 5 不同算法应用于 COC 缺陷检测结果可知,本文提出的 YOLOV3-COC 算法在现有 YOLOV3 基础上,检测准确性提高了 4.9%。相比经典的 Faster R-CNN、SSD 以及 YOLO 算法,本文算法检测准确性大幅提高,并且能够以 0.72 s 的时

间完成每张图片的检测,满足实时性检测要求。

根据以上实验表明,本文改进的 YOLOV3-COC 算法在满足检测实时性的要求下,对 COC 缺陷检测准确率达到 97.4%,检测结果如图 8 所示。




图 8 基于 YOLOV3-COC 的 COC 缺陷检测结果。(a)原图 1;(b)检测结果 1;(c)原图 2;(d)检测结果 2

Fig. 8 COC defect detection results based on YOLOV3-COC. (a) Original image 1; (b) detection result 1; (c) original image 1; (d) detection result 2

## 6 结 论

本文将深度网络引入到 COC 缺陷检测,针对原有 YOLOV3 在 COC 缺陷检测应用上的不足之处,改进了特征提取网络结构和多尺度预测,对 4 个不同尺度特征图进行增强特征融合,重新设计了 12 个不同尺度的先验框。实验结果表明,改进后的算法在保证实时性检测的前提下,对 COC 三种不同类型的缺陷取得更好的检测效果,平均准确率达到 97.4%。COC 上的字符代表型号信息,本文仅仅考虑了 COC 的缺陷检测,在后续的研究中,我们将对网络结构进行优化改进,同时实现 COC 的字符识别和缺陷检测。

### 参 考 文 献

- [1] Wang D Y, Wang X K, Yu W W, et al. Off-axis LED curved array lighting design for leather defect detection [J]. *Laser & Optoelectronics Progress*, 2019, 56(8): 082202.  
王德宇, 王雪琨, 于文文, 等. 面向皮革缺陷检测的离轴 LED 曲面阵列照明设计[J]. *激光与光电子学进展*, 2019, 56(8): 082202.
- [2] Li D J, Li R H. Mugdefect detection method based on improved Faster RCNN [J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041515.  
李东洁, 李若昊. 基于改进 Faster RCNN 的马克杯缺陷检测方法[J]. *激光与光电子学进展*, 2020, 57(4): 041515.
- [3] Zhang G S, Ge G Y, Zhu R H, et al. Geardefect detection based on the improved YOLOv3 network [J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121009.  
张广世, 葛广英, 朱荣华, 等. 基于改进 YOLOv3 网络的齿轮缺陷检测[J]. *激光与光电子学进展*, 2020, 57(12): 121009.
- [4] Liu J C, Shi T L, Wang K, et al. Defect detection of flip-chip solder joints using modal analysis [J]. *Microelectronics Reliability*, 2012, 52(12): 3002-3010.
- [5] Chen C S, Huang C L, Yeh C W. A hybrid defect detection for in-tray semiconductor chip [J]. *The International Journal of Advanced Manufacturing Technology*, 2013, 65(1/2/3/4): 43-56.
- [6] Liao G L, Du L, Su L, et al. Using RBF networks for detection and prediction of flip chip with missing bumps [J]. *Microelectronics Reliability*, 2015, 55(12): 2817-2825.
- [7] Xu Z S, Shi T L, Lu X N, et al. Using active thermography for defects inspection of flip chip [J]. *Microelectronics Reliability*, 2014, 54(4): 808-815.
- [8] Xu Z S, Shi T L, Lu X N, et al. Failures detection of flip-chip using active thermography method based on wavelet transform [J]. *Infrared and Laser Engineering*, 2014, 43(10): 3233-3237.

- 徐振淞, 史铁林, 陆向宁, 等. 基于小波分析的倒装芯片主动红外缺陷检测[J]. 红外与激光工程, 2014, 43(10): 3233-3237.
- [9] Feng L, Gong Z H. An algorithm for chip surface defect detection based on sequential similarity and light source automatic adjustment [J]. Modern Electronics Technique, 2017, 40(5): 58-62.
- 冯莉, 龚子华. 基于序贯相似性与光源自动调节的芯片表面缺陷检测算法[J]. 现代电子技术, 2017, 40(5): 58-62.
- [10] Liu C, Yuan X F, Tian Z M, et al. Research on chip defect detection algorithm based on point pattern matching[J]. Laser Journal, 2020, 41(1): 39-44.
- 刘琛, 袁小芳, 田争鸣, 等. 基于点模式匹配的芯片缺陷检测算法研究[J]. 激光杂志, 2020, 41(1): 39-44.
- [11] Li Y T, Xie Q S, Huang H S, et al. Surface defect detection based on fast regions with convolutional neural network [J]. Computer Integrated Manufacturing Systems, 2019, 25(8): 1897-1907.
- 李宜汀, 谢庆生, 黄海松, 等. 基于卷积神经网络快速区域标定的表面缺陷检测[J]. 计算机集成制造系统, 2019, 25(8): 1897-1907.
- [12] Wu T, Wang W B, Yu L, et al. Insulator defect detection method for lightweight YOLOv3 [J]. Computer Engineering, 2019, 45(8): 275-280.
- 吴涛, 王伟斌, 于力, 等. 轻量级 YOLOv3 的绝缘子缺陷检测方法[J]. 计算机工程, 2019, 45(8): 275-280.
- [13] Zhong J J, He D Q, Miao J, et al. Weld defect detection of metro vehicle based on improved faster R-CNN [J]. Journal of Railway Science and Engineering, 2020, 17(4): 996-1003.
- 钟嘉俊, 贺德强, 苗剑, 等. 基于改进 Faster R-CNN 的地铁车辆焊缝缺陷检测[J]. 铁道科学与工程学报, 2020, 17(4): 996-1003.
- [14] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [15] Girshick R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [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, 2017, 39(6): 1137-1149.
- [17] 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.
- [18] 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [19] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [20] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2020-08-20]. <https://arxiv.org/abs/1804.02767>.