

DOI:10.19651/j.cnki.emt.2211700

基于改进 YOLOv5 的 PCB 缺陷检测方法 *

时造雄 瞿正冲

(江南大学物联网工程学院 无锡 214000)

摘要: 印刷电路板作为电子产品不可或缺的重要组成部分,其市场需求量与日俱增,因此制造无缺陷的 PCB 具有重要意义;针对 PCB 缺陷检测中待检测的缺陷目标较小且多数检测目标与背景容易混淆导致的误检漏检,改进的算法在原生 YOLOv5 算法的骨干网络中引入坐标注意力机制,在颈部网络中引入 Transformer Encoder 并增加一个适用于小目标的高分辨率检测头,并且将选定锚框的交并比算法部分改为更先进的 E-IoU。相较于原生 YOLOv5 算法,根据算法评价指标精确率,召回率和平均检测精度均值的结果,改进后的算法性能有显著提升,其中平均检测精度均值更是高达 98.46%,且检测速度也达到了 72.4 Hz,可以满足工业现场对 PCB 缺陷检测的精度要求。

关键词: 缺陷检测;YOLOv5;注意力机制;Transformer 编码器;交并比

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 520

Improved PCB defect detection method based on YOLOv5

Shi Zaoxiong Mao Zhengchong

(School of Internet of Things, Jiangnan University, Wuxi 214000, China)

Abstract: Printed Circuit board is an indispensable part of electronic products, and its market demand is increasing day by day. Therefore, it is of great significance to manufacture PCB without defects. In the PCB defect detection, the defect targets to be detected are small and most of the detection targets are easily confused with the background, so the improved algorithm introduces the Coordinate Attention mechanism into the backbone network of the native YOLOv5 algorithm. A Transformer Encoder was introduced into the neck network and a high-resolution detection head suitable for small targets was added. The Intersection over Union algorithm of selected anchor frames was changed to a more advanced E-IoU. Compared with the original YOLOv5 algorithm, the performance of the improved algorithm is significantly improved according to the results of Precision, recall and mean Average Precision of the algorithm evaluation index, and the mean Average Precision is 98.46%. It can meet the precision requirement of PCB defect detection in industrial field.

Keywords: defect detection; YOLOv5; attention mechanism; Transformer encoder; IoU

0 引言

印刷电路板(printed circuit board, PCB)在生产过程中会出现的主要缺陷种类有缺孔、鼠噬、开路、毛刺、多铜、及短路等^[1],其中多铜和毛刺这两种缺陷与背景极为相似,使得其识别的难度较大,而鼠噬的种类又较为丰富,形状各异,且不同缺陷在整张 PCB 上均占比很小,这些缺陷的不同特点加大了 PCB 缺陷检测的难度^[2]。

深度学习在计算机视觉界近年来得到了蓬勃发展,其任务主要分为图像分类和目标检测,YOLO(you only look once)系列目标检测算法作为单阶段目标检测算法中的佼佼者,其具有速度快、准确率高等特点,该系列算法目前已

被应用于多种场景检测任务中^[3],针对 PCB 缺陷检测,何国忠等^[4]基于 YOLOv4 网络进行优化改造,在优化后的网络中加入了基于细粒度空间域的长距离全局注意力机制,同时在原网络中 SPP(spatial pyramid pooling)模块的基础上进行特征图重组作为各个检测头的输入,从而提高对于 PCB 缺陷检测的精度;伍济钢等^[5]也提出了基于改进 YOLOv4 算法的 PCB 缺陷检测研究,使用改进二分 K-means 聚类结合交并比(intersection over union,IoU)损失函数确定锚框,解决预设锚框不适用 PCB 小目标缺陷检测的问题,并使用 MobileNetV3 作为特征提取网络、Inceptionv3 作为检测网络,利用多种卷积核进行运算满足

收稿日期:2022-10-14

*基金项目:国家自然科学基金青年项目(6170185)资助

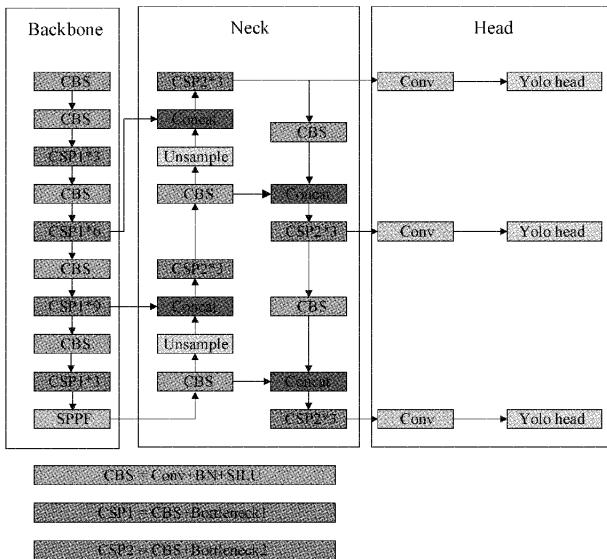
PCB 缺陷多类别的检测要求;而王恒涛等^[6]在 YOLOv5 算法的基础上,以轻量化为主要目标,通过剪枝对模型进行压缩,在保证检测精度的前提下,降低计算量,提高推理速度。刘涛等^[7]修改了 YOLOv4 算法中的主干网络以增强特征提取能力,并且加入了注意力机制,提高了检测精度和速度。针对工业环境中噪声干扰导致的印刷电路板缺陷检测困难的问题,陈仁祥等^[8]提出基于多注意力 Faster RCNN 的印刷电路板缺陷检测方法,该方法主要是在特征提取以及特征融合部分引入注意力机制以提升检测效果。

以上研究对 PCB 缺陷检测已经奠定了初步的基础,主要研究的网络为 Faster RCNN 和 YOLOv4 系列,本文主要研究最新的 YOLOv5 网络模型,该网络模型在速度上比上述模型有较大提升,但是由于缺陷检测过程中网络层数依旧较深,浅层信息丢失较为严重,导致已有的网络模型中检测效果不理想,因此本文在 YOLOv5 网络模型的基础上,在骨干网络中引入注意力机制,在颈部网络融合了 Transformer 中的编码器结构,并且使用最新的 E-IoU 交并比方法选定锚框,最终提出了一种基于改进 YOLOv5 的 PCB 缺陷检测方法,在速度和检测精度上均有较大优势。

1 YOLOv5 网络模型及改进

1.1 原模型介绍

YOLOv5 系列模型整体沿用前系 YOLOv3、YOLOv4 整体布局,主要包括 Input、Backbone、Neck、Head 4 个部分,YOLOv5 系列可以通过调节网络模型中的长宽参数来调节网络的宽度和深度,主要分成 YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x,其中标准 YOLOv5l 结构如图 1 所示。



1) 骨干网络(Backbone)结构分析

该部分由 CBS(Conv+Batch Normalization+SILU)和

CSP1 (CBS + BottleNeck1) 和 SPPF (Spatial Pyramid Pooling-Fast)组成。

CBS 模块由一个标准的卷积(Conv)模块,一个批量规范化模块(batch normalization)和一个非线性激活模块 SILU 组成;CSP1 模块由 CBS 模块和 BottleNeck1 模块组成,CSP1 模块主要借鉴了 Resnet 中残差网络的思想。

CSP1 模块和 BottleNeck1 模块结构如图 2 和 3 所示。

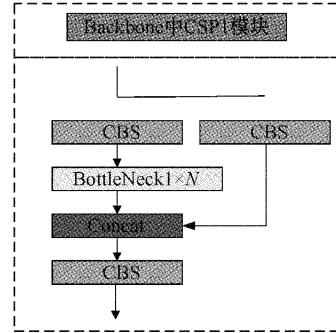


图 2 CSP1 模块

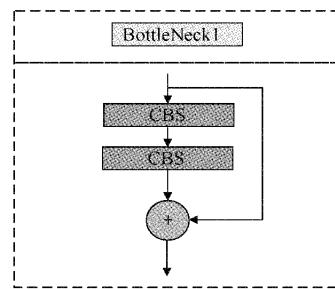


图 3 BottleNeck1 模块

在 Resnet 出现之前,人们普遍认为网络越深获取信息也越多,模型泛化效果越好。然而随后大量的研究表明,网络深度到达一定的程度后,模型的准确率反而大大降低。这是由于反向传播过程中的梯度爆炸和梯度消失所造成。也就是说,网络越深,模型越难优化。为了能让深层次的网络模型达到更好的训练效果,残差网络中提出由残差映射替换了以往的基础映射。

SPPF 模块结构如图 4 所示,该模块由 CBS 模块和最大池化层(Maxpool)组成,其主要作用是对高层特征进行提取并融合,在融合的过程中多次运用最大池化,尽可能多地去提取高层次的语义特征。

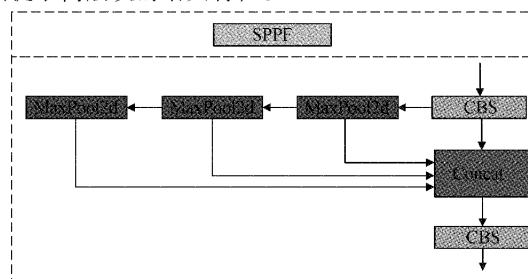


图 4 SPPF 模块

2) 颈部网络(Neck)结构分析

YOLOv5 中的颈部网络部分采用的是 FPN (feature pyramid network) 结合 PAN (path aggregation network) 的设计。

FPN^[9]即为金字塔结构,是使用一种自顶向下的侧边连接,在所有尺度上构建出高级语义特征图的结构,FPN 中间经过多层的网络后,底层的目标信息已经非常模糊了,因此在 Neck 中又结合了 PAN^[10] 结构,加入了自底向上的路线,弥补并加强了定位信息。

Neck 中 CSP2 模块与 Backbone 中 CSP1 模块主要不同点在于 BottleNeck1 与 BottleNeck2 的不同,其结构如图 5 和 6 所示。在颈部网络阶段并不需要再一味地加深网络,而是需要增强神经网络的特征融合能力,故在此处网络采取不带残差的 CSP2 模块。

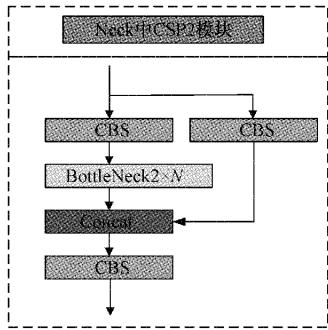


图 5 CSP2 模块

3) 检测头部分(Head)结构分析

该部分主要包括边界损失函数(C-IoU 等)与非极大值抑制(non maximum suppression, NMS),该部分的目标是通过降低预测框和真实框的损失函数来获得最佳的目标检测框。

1.2 改进措施

1) 增加检测头

在 PCB 板缺陷检测中,绝大部分缺陷面积较小,当深度学习网络层数较深时容易丢失浅层信息,故本文首先在检测部分增加了一个低维且高分辨率的检测头,这样就能更好的处理小目标,有效提高检测准确率。

该检测头由低层高分辨率的特征图生成,当网络的输入图像尺寸为 960×960 时,原算法中的 3 个检测头对应的特征图大小分别为 120×120,60×60,30×30,本文中增加的检测头特征图大小为 240×240,相较于原网络模型,增加的检测头能充分利用到浅层特征信息,能够明显降低卷积带来的小目标区域特征信息丢失的影响,增加后的网络虽然在计算量上有所增加,但是对小目标的检测精度有明显改善。

2) 坐标注意力机制

为了更好地帮助网络在整张图中准确定位缺陷所在位置,通过在骨干网络中每个 CSP1 模块后添加注意力机制

(attention mechanism)的方式对原网络模型进行改进。

注意力机制源于对人类视觉的研究。由于信息处理的瓶颈,人类会选择性地关注所有信息的一部分并忽略其他可见的信息。为了合理利用有限的视觉信息处理资源,人类需要选择视觉区域中的特定部分,然后集中关注它。本文使用坐标注意力(coordinate attention, CA)机制^[11]帮助网络更好的自主学习特征权重,其结构如图 6 所示。

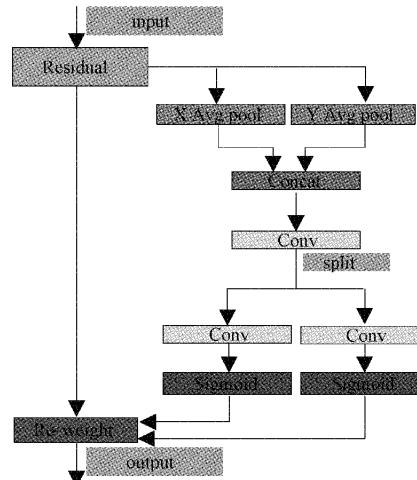


图 6 坐标注意力机制结构

通过结构图可以看出该机制将通道注意力分解为两个一维特征编码过程,分别沿两个空间方向聚合特征。这样,可以沿一个空间方向捕获远程依赖关系,同时可以沿另一空间方向保留精确的位置信息。然后将生成的特征图分别编码为一对方向感知和位置敏感的注意力映射,可以将其互补地应用于输入特征图,以增强关注对象的表示。

整个坐标注意力机制可分解为两个部分:

首先是坐标信息嵌入,这个阶段给定输入 x , 使用大小为 $(H, 1)$ 或 $(1, W)$ 的池化核沿水平和垂直两个坐标对每个通道进行编码。此时高度为 h 的第 c 通道的输出可以表示为:

$$Z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \quad (1)$$

类似地,宽度为 w 的第 c 通道的输出为:

$$Z_c^w(w) = \frac{1}{H} \sum_{0 \leq i \leq H} x_c(w, i) \quad (2)$$

以上两种变换分别沿两个空间方向聚合特征,得到一对方向感知的特征图。这两种变换允许注意力模块捕捉到沿着一个空间方向的长期依赖关系,并保存沿着另一个空间方向的精确位置信息,有助于网络准确定位感兴趣的目标。

然后是坐标注意力生成,通过信息嵌入中的变换后,该部分将上面的变换进行连接操作,然后进行 1×1 卷积:

$$f = \delta(F_1([Z^h, Z^w])) \quad (3)$$

式中: $[Z^h, Z^w]$ 表示沿空间维数的连接操作, δ 为非线性

激活函数, f 为对空间信息在水平方向和垂直方向进行编码的中间特征映射。利用两个 1×1 卷积变换函数 F_h 和 F_w 将特征图 f^h 和 f^w 变换到和输入同样的通道数, 如下式所示:

$$f = \delta(F_1([Z^h, Z^w])) \quad (4)$$

式中: $[Z^h, Z^w]$ 表示沿空间维数的连接操作, δ 为非线性激活函数, f 为对空间信息在水平方向和垂直方向进行编码的中间特征映射。利用两个 1×1 卷积变换函数 F_h 和 F_w 将特征图 f^h 和 f^w 变换到和输入同样的通道数, 如下式所示:

$$g^h = \sigma(F_h(f^h)) \quad (5)$$

$$g^w = \sigma(F_w(f^w)) \quad (6)$$

最后对 g^h 和 g^w 进行拓展, 作为注意力权重, 该模块最终输出可以表达为下式:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (7)$$

至此 CA 注意力机制同时完成了水平和竖直两个方向的注意力, 可有效帮助网络在整张图中获得关于目标的信息。

3) Transformer Encoder 模块

由于 PCB 板缺陷较小且部分缺陷与背景相似度高, 极易与背景混淆, 为了提升网络对缺陷的识别率, 本文主要应用 Transformer 中的编码模块^[12] 替换原网络中颈部网络中的 CSP2 模块, 并与最终的检测头直接连接 Transformer Encoder 模块结构如图 7 所示。

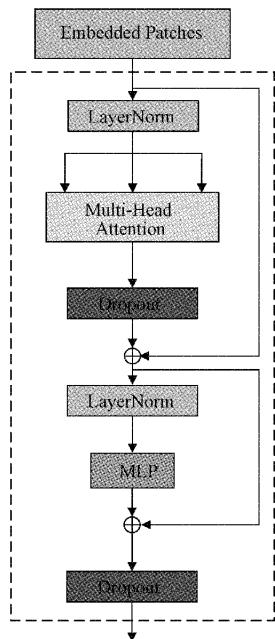


图 7 Transformer Encoder 结构

通过结构图可以得知, 每个 Transformer Encoder 模块包含两个子层, 第 1 子层为多头注意力层 (multi-head attention layer), 第 2 子层为全连接层 (multilayer perceptron, MLP)。每个子层之间使用残差连接, 增加了

捕获不同局部信息的能力。它还可以利用自注意力机制来挖掘特征表征潜能。

其中, Layer Norm 和 Drop out 层有助于网络模型更好的收敛, 防止网络过度拟合, 多头注意力模块不仅可以帮助当前节点关注当前像素, 还可以获取上下文的语义, 这样就能更有效的捕获全局信息和充足的背景信息, 增加神经网络中的深层语义和浅层语义的融合, 进一步提升检测能力。从而提升对缺陷的捕捉效果。

4) E-IoU

IoU(intersection over union) 表示真实框与预测框交集部分与并集部分的比值, 是目标检测算法中重要的一部分^[13]。由于待研究的缺陷较小, 其真实框的大小仅占很小的一部分, 故对于 IoU 的选择会显著影响最后预测的准确率与召回率。

之前主流使用的 IoU 为 G-IoU, 后面又在前代基础上衍生出了 D-IoU 和 C-IoU, 解决了部分精确度方面的问题, 考虑到 C-IoU 仍存在以下两个缺点: (1) 纵横比描述的是相对值, 存在一定的模糊; (2) 未考虑难易样本的平衡问题。本文使用最新改进的 E-IoU^[14], 在 C-IoU 的基础上分别计算宽高的差异值取代了纵横比, 同时引入 Focal Loss 解决难易样本不平衡的问题。

E-IoU 的惩罚项是在 C-IoU 的惩罚项基础上将纵横比的影响因子拆开分别计算目标框和锚框的长和宽, 该损失函数包含 3 个部分: 重叠损失, 中心距离损失, 宽高损失, 前两部分延续 C-IoU 中的方法, 但是宽高损失直接使目标框与锚框的宽度和高度之差最小, 使得收敛速度更快。

另外考虑到边界框的回归中也存在训练样本不平衡的问题, 即在一张图像中回归误差小的高质量锚框的数量远少于误差大的低质量样本, 质量较差的样本会产生过大的梯度影响训练过程。故在 E-IoU 中提出一种 Focal-EIOU Loss, 从梯度的角度出发, 把高质量的锚框和低质量的锚框分开, 惩罚项公式如下:

$$L_{Focal-EIOU} = IOU^\gamma L_{EIOU} \quad (8)$$

其中, γ 为控制异常值抑制程度的参数, 根据该公式可知当 IoU 越大时, 损失越大, 即相当于加权作用, 有助于提高回归精度。

1.3 改进后的网络结构图

针对 PCB 裸板缺陷检测中缺陷与背景相似度高、缺陷种类丰富且大小各异、缺陷占整张图片占比较小等特点, 综合改进后的网络结构如图 8 所示。

2 实验结果与分析

2.1 数据集及缺陷扩充

本次实验数据集来源于北京大学智能机器人开放实验室发布的 PCB 缺陷检测公开数据集^[15], 该数据集共 6 个类别, 1 386 张图片, 由于原数据集缺陷种类不全且图片数量较少, 实验过程中经过图像裁剪等图像预处理后, 处理后的

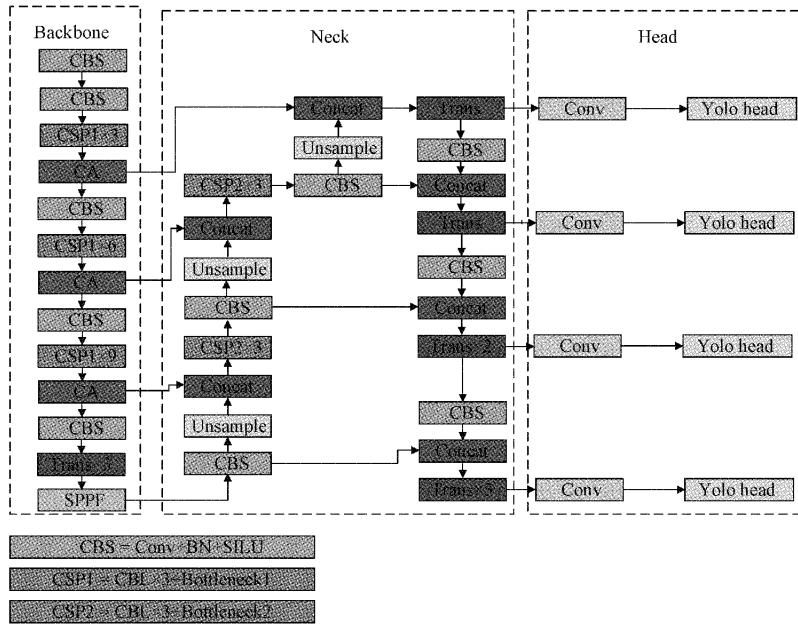


图 8 改进后的网络结构

数据集包含种类和数量如表 1 所示。

表 1 缺陷种类

缺陷类型	原图数量	本文数量
缺孔	230	920
鼠噬	230	920
开路	232	928
毛刺	230	920
多铜	232	928
短路	232	928

2.2 实验环境

本文实验环境如表 2 所示。

表 2 实验环境

系统	Windows 11 (64 位)
CPU	Intel Core i7-12700F@2.1 GHz
RAM	32.0 GB
GPU	NVIDIA RTX 3070Ti
深度学习框架	PyTorch
GPU 加速库	CUDA 11.0

2.3 实验结果与分析

1) 评估标准

本文中为评估模型的检测性能引入以下评估标准:

平均精度均值 (mean average precision, mAP) 是评判模型性能的主要指标之一, 它是 C 个不同缺陷的平均精度 AP(average precision) 的平均值, 反映了网络整体缺陷检测的准确性。

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (9)$$

平均精度 AP 值由精确率和召回率计算得出。平均精度的一般定义根据召回率值绘出精确率的折线图, 然后计算出该折线下的面积。

$$AP = \int_0^1 p(r) dr = \sum_{k=1}^N P(k) \Delta r(k) \quad (10)$$

精确率 (Precision) 又称查准率, 指正确预测为正的占全部预测为正的比例。

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

召回率 (Recall) 指正确预测为正的占全部实际为正的比例, 衡量的是模型检测正确的能力, 故召回率又称查全率。

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

2) 实验结果展示

图 9~11 分别为不同本文算法的 PCB 缺陷检测的实际效果图。

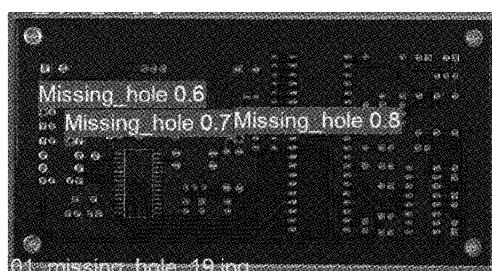


图 9 检测结果 1

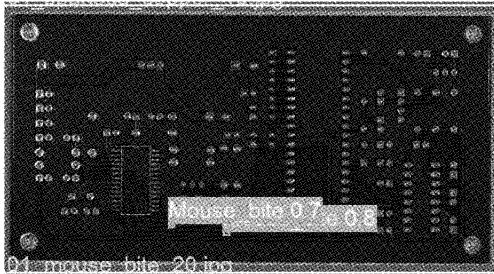


图 10 检测结果 2

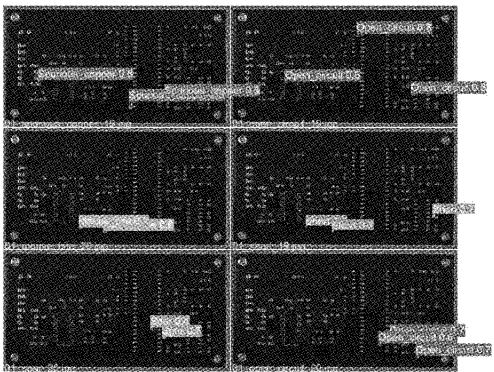


图 11 检测结果 3

通过图 9~11 的展示可以证明本文算法已经能够应对绝大部分 PCB 缺陷的检测,在检测出 PCB 存在的不同缺陷时效果也很显著。

3) 实验结果对比

首先针对本文第 2 章所述的改进进行消融实验,分析各项改进手法对网络的提升,数据如表 3 所示,其中各项数据为所有缺陷的平均数据。

表 3 消融实验 %

方法	准确率	召回率	mAP
YOLOv5l	94.50	93.63	93.81
YOLOv5l+检测头	99.17	92.38	95.75
YOLOv5l+Trans	94.56	98.25	96.13
YOLOv5l+CA	95.24	95.71	95.68
YOLOv5l+E-IoU	95.64	94.93	95.29
YOLOv5l+检测头+Trans	98.31	96.76	97.51
YOLOv5l+Trans+CA+检测头	98.52	97.82	97.94
YOLOv5l-pcb	99.05	98.27	98.46

从表 3 中的数据可以看出,第 2 章中对于改进网络引入的不同模块对 PCB 板缺陷的检测有各自不同的作用。

首先在网络中增加一个适用于小目标的检测头时,极大的加强了对网络浅层特征信息的利用,能明显提升对小目标的捕捉能力,此时网络检测的精确率有较大幅度的提升,但是由于浅层信息较多,且部分缺陷与背景难以区分,整个网络的复杂度又有所提高,使得召回率指标不升反

降,从而使得 mAP 虽有提升,但不能达到想要的效果,为进一步提升 mAP,此时在颈部网络中引入 Transformer Encoder 模块,利用自注意力机制来挖掘特征表征潜能,可以发现该模块有助于网络更好的收敛,防止网络过度拟合,且能更好的融合浅层信息和深层信息,使得各个检测头能得到相对应层次的图像特征,当单独使用该编码模块时,精确率提升较小,故同时增加检测头和引入 Transformer Encoder 模块,此时这两个模块能达到很好的融合效果,起到相辅相成的效果,使得网络在精确率和召回率上均有较为明显的提升,mAP 也有了显著提升。

其次通过表格中的数据还可以发现:在骨干网络中引入 CA 坐标注意力机制或者引入 E-IoU 均能小幅度提升精确率和召回率,故将上述几个改进融合成最后的 YOLOv5l-pcb 网络,此时的 mAP 较未改进前的 YOLOv5l 网络提升了 4.65%,精确率和召回率均达到了期望的程度,极大的改善了 PCB 板缺陷检测的漏检和错检情况。

综上,消融实验可以证明本文所设计的优化方案在针对 PCB 板的缺陷检测上检测的缺陷较小及缺陷与背景相似度高等难点有明显的改善作用。

从表 4 中的数据的横向对比可以发现,对于各大网络,多铜和毛刺等几个缺陷识别率均为缺陷中较低的部分,主要原因就是这几个缺陷不仅目标小,还与无缺陷部分的背景图极为相似,识别难度较大,这也是本文探讨的重点所在;纵向对比还可以发现 YOLO 系列网络在各项缺陷的识别方面均整体显著优于 Faster RCNN 和 SSD 网络,主要原因是 YOLO 系列网络的颈部 FPN 结合 PAN 的设计相较于 Faster RCNN 和 SSD 能显著提升对浅层特征的语义提取和识别,对小目标检测有了一定的提升,同时在 YOLO 系列网络的骨干网络中还借鉴了残差网络的思想,加深网络深度的同时能够达到更好的检测效果。

表 4 不同模型 AP 值对比

	AP/%					
	缺孔	鼠噬	开路	短路	多铜	毛刺
YOLOv4	95.32	92.56	92.35	95.20	85.87	88.46
YOLOv5l	94.20	95.21	95.20	96.86	93.43	92.65
Faster RCNN	85.50	82.59	73.28	84.45	78.92	79.96
SSD	83.15	81.34	75.79	81.25	76.74	82.69
YOLOv5l-pcb	99.67	99.20	98.56	98.41	95.06	96.26

如表 5 所示,由于 Faster RCNN 使用的是双阶段网络结构,采用候选框机制遍历特征图,故能将图中的目标较齐全的检测到,从而在召回率这项指标上优于其他未改进的网络,但 Faster RCNN 网络虽然具有较好的查全率,整体的 mAP 却并不高,尤其是在面对小目标时的 AP 明显低于其它网络,主要原因是 PCB 板很多缺陷区域与元件区域只有很小的差别,网络无法区分。从表中还可以发现双

阶段网络的检测速率是明显低于单阶段网络的。

表 5 不同算法其他性能指标均值对比

图片尺寸	精确率/召回率/ mAP/			每秒 检测 张数	
	%	%	%		
YOLOv4	608×608	90.64	90.37	89.63	38.7
YOLOv5l	960×960	94.50	93.62	93.81	76.9
Faster RCNN	600×600	75.83	94.28	82.57	27.2
SSD	512×512	92.17	68.46	79.23	59.4
YOLOv5l-pcb	960×960	99.05	98.27	98.46	72.4

另一方面单阶段网络的查全能力要逊于双阶段网络,且同样是单阶段网络,SSD 网络在查全方面效果比起 YOLO 系列差距较大,原因在于 SSD 的主干网络为 VGG 系列网络,网络层数较低,特征提取不全,故查全效果明显弱于 YOLO 系列网络。

从精确率角度看,Faster RCNN 网络则具有明显的短板,主要由于 Faster RCNN 网络在滑动时遍历得到的候选框同样也包含较多无缺陷区域,从而使得分类器无法正确识别缺陷,分类精度受到较大影响。而此时单阶段网络受背景区域影响较小,可以达到较好的分类精确率。YOLOv4 和 YOLOv5 网络在精确率和召回率上也有一定的差距,其主要来源于 YOLOv5 网络在骨干网络中引入的 SPPF 模块,其能够对高层特征进行提取并融合,在融合的过程中多次运用最大池化,尽可能多的去提取高层次的语义特征,从而在“多铜”和“毛刺”这种与背景较为相似的缺陷中达到较好的检测效果。

同时改进后的网络由于增加了针对小目标检测的检测头以及其他改进措施,使得整个网络的复杂程度有所提高,相应的每秒能检测的图片张数从 76.9 张降低到了 72.4 张,但本文算法比原生 YOLOv5 算法在精度上有着 12.5% 的提升,故综合精度和速度两方面,本文算法仍属于众多算法中的佼佼者。

整体来说,改进后的 YOLOv5 网络既能将绝大部分缺陷目标检测出来,尤其是对较小目标和与背景相似度高的缺陷检测精确度有明显提升。速度上,由于网络复杂度的提升,虽然要稍逊色于原生网络,但仍能满足工业现场检测的实际要求,可以认定本文所提出的算法完全能满足工业现场需要的检测效果。

3 结 论

本文针对 PCB 的缺陷检测提出了一种基于改进 YOLOv5 的检测方法,该算法重点解决了 PCB 缺陷面积较小即能提取的特征信息较少、且与背景相似度高难以分辨的问题。网络结构的改进主要为在原网络骨干部分引入坐标注意力机制,在网络特征提取阶段帮助网络在整张

图中更加准确的定位缺陷所在位置,又在颈部部分增加检测头并且引入 Transformer Encoder 模块融合成 4 个新的检测头,既丰富了特征的多样性,又极大的提升了对浅层和深层语义特征的提取和理解,同时还引入了 E-IoU 交并比计算方法,得到了更高质量的候选框,使得网络对于 PCB 板缺陷检测达到了较为理想的效果。经过测试,改进后的网络相较于未改进的网络 mAP 提升了 4.65%,且相较于之前的研究,在检测的精确方面,精确率和召回率都有较大提升,为后续阶段的研究提供了扎实基础

参考文献

- [1] DING R, DAI L, LI G, et al. TDD-net: A tiny defect detection network for printed circuit boards[J]. CAAI Transactions on Intelligence Technology, 2019, 4(2): 110-116.
- [2] LI Y, LI S. Defect detection of bare printed circuit boards based on gradient direction information entropy and uniform local binary patterns[J]. Circuit World, 2017, 43(6): 145-151.
- [3] 王宸,张秀峰,刘超,等.改进 YOLOv3 的轮廓焊缝缺陷检测[J].光学精密工程,2021, 29(8): 1942-1954.
- [4] 何国忠,梁宇.基于卷积神经网络的 PCB 缺陷检测[J].图学学报,2022,43(1):21-27.
- [5] 伍济钢,成远,邵俊,等.基于改进 YOLOv4 算法的 PCB 缺陷检测研究[J].仪器仪表学报,2021,42(10): 171-178,DOI:10.19650/j.cnki.cjsi.J2108244.
- [6] 王恒涛,张上,张朝阳,等.基于 YOLOv5 的轻量化 PCB 缺陷检测[J/OL].无线电工程. <http://kns.cnki.net/kcms/detail/13.1097.TN.20220509.1015.004.html>.
- [7] 刘涛,张涛.基于 GhostNet-YOLOv4 算法的印刷电路板缺陷检测[J/OL].电子测量技术. <https://kns.cnki.net/kcms/detail/11.2175.TN.20220725.1803.028.html>.
- [8] 陈仁祥,詹贊,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, DOI: 10.19650/j.cnki.cjsi.J2108477.
- [9] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), DOI:10.1109/cvpr.2017.106.
- [10] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, DOI:10.1109/cvpr.2018.00913.
- [11] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and

- Pattern Recognition, 2021; 13713-13722.
- [12] ZHU X K, LYU S C, WANG X, et al. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[J]. ArXiv Preprint, 2021, ArXiv:2108.11539.
- [13] YU J, JIANG Y, WANG Z, et al. UnitBox: An advanced object detection network[J]. ArXiv Preprint, 2016, ArXiv:1608.01471.
- [14] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IoU loss for accurate bounding box regression[J]. ArXiv Preprint, 2021, ArXiv:2101.0815.
- [15] HUANG W B, WEI P, ZHANG M H, et al. Hripcb: A challenging dataset for PCB defects detection and classification [J]. The Journal of Engineering, 2020(13):303-309.

作者简介

时造雄,硕士研究生,主要研究方向为图像处理,目标检测等。

E-mail: shizaoxiong@qq.com

茅正冲(通信作者),副教授,主要研究方向为嵌入式系统、工业物联网、农业物联网、工业自动化、机器人视听觉识别等。

E-mail: maozcxia@163.com