

基于改进 YOLOv8n 的 PCB 缺陷检测算法^{*}

姜源 付波 权轶 李昊

(湖北工业大学电气与电子工程学院 武汉 430068)

摘要:针对现有的印刷电路板(PCB)缺陷检测方法计算量大、小目标缺陷易漏检、检测速度较慢等问题,提出 YOLOv8n-4SCDP 缺陷检测算法。首先,在 YOLOv8n 颈部网络增加上采样,融合 Backbone 中浅层语义信息,同时增加微小目标检测层降低 PCB 小目标缺陷漏检率;其次,在 Backbone 中融入坐标注意力(CA)机制,强化特征语义和位置信息,提高了模型特征融合能力;另外,设计密集连接机构,提高模型的缺陷特征利用率,采用 PConv 对模型进行压缩,既保证了模型的准确性,又大大减小了模型的尺寸;最后,针对难易样本不平衡的问题,采用线性区间映射法重新定义回归损失函数(Focaler-SIoU),提高模型收敛速度和回归精度。实验结果表明,YOLOv8n-4SCDP 算法的整体缺陷的平均精度均值(mAP)达到 95.8%,检测帧率达到了 65 fps。有效改善 YOLOv8n 对于 PCB 小目标缺陷漏检率高、检测精度低等问题。

关键词: YOLOv8n; PCB 缺陷; 小目标缺陷检测; 密集连接; 注意力机制

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.60

PCB defect detection algorithm based on improved YOLOv8n

Jiang Yuan Fu Bo Quan Yi Li Hao

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China)

Abstract: In response to the issues of large computational load, easy omission of small target defects, and slow detection speed in existing PCB defect detection methods, this paper proposes the YOLOv8n-4SCDP defect detection algorithm. Firstly, upsampling is added to the neck network of YOLOv8n, integrating shallow semantic information in the Backbone, and a small target detection head is added to reduce the omission rate of small target defects in PCBs. Secondly, the CA attention mechanism is integrated into the Backbone to enhance the semantic and positional information of features, thereby improving the feature fusion capability of the model. Thirdly, a dense connection mechanism was designed to enhance the utilization of defect features in the model. Additionally, PConv was employed to compress the model, ensuring both accuracy and significantly reducing the model's size. Finally, to address the issue of imbalanced difficult and easy samples, we employ a linear interval mapping method to redefine the Focaler-SIoU regression loss function. This approach enhances both model convergence speed and regression accuracy. The experimental results indicate that the YOLOv8n-4SCDP algorithm achieves an accuracy of 95.8% and a frame rate of 65 fps. This effectively addresses YOLOv8n's issues related to high defect omission rates and low detection accuracy for small PCB targets.

Keywords: YOLOv8n; PCB defection; small target defect detection; dense connection; attention mechanism

0 引言

印刷电路板(printed circuit board, PCB)是当今电子产品中最基础、最重要的部件。PCB 上的任何元器件安装错误,如元器件遗漏、元器件翻转、元器件移位、短路等,都

会导致电路运行失败,使电子产品出现严重缺陷。因此,为保证电子设备的性能,PCB 缺陷检测已成为现代电子产品制造过程中至关重要的一步^[1]。传统的人工检测容易受到外界环境因素的干扰,影响缺陷检测的效率。此外,细小缺陷的检测会引起视觉疲劳,容易导致误分类^[2]。为

收稿日期:2023-12-27

^{*} 基金项目:湖北省重点研发计划(2021BAA193)项目资助

了解决这些问题,一些学者将机器视觉引入到 PCB 检测中,并取得了很大的进展。

深度学习算法的出现解决了上述算法的缺点,例如依赖先验模板、高计算量和冗余步骤。与传统方法不同,深度学习算法主要使用卷积神经网络(convolutional neural network, CNN)进行特征提取。通过一系列卷积、激活函数、池化等操作生成输入图像的层次化特征映射。基于 CNN 的深度学习模型具有强大的特征学习能力,已广泛应用于缺陷检测的各个子领域,如 PCB 缺陷检测、锂电池缺陷检测、钢材表面缺陷检测等^[3]。

缺陷检测算法作为深度学习的一个分支,可以分为两大类,基于边框回归的单阶段算法和基于区域建议的两阶段算法。单阶段算法主要包含 YOLO(you only look once)^[4]系列和单点多盒检测(single shot multibox detector, SSD)^[5]系列算法,两阶段算法主要指 Region proposal 结合卷积神经网络(R-CNN)系列算法^[6-8]。两阶段算法将区域建议与对象检测分开,第 1 阶段使用单独的算法或网络生成区域建议;第 2 阶段在这些建议区域内执行对象检测。胡江宇等^[9]提出一种改进级联 Faster R-CNN 的 PCB 缺陷检测算法,该改进算法通过引用 MobileNetV3 改进特征提取网络,可以有效对 PCB 板缺陷进行检测,但检测速度较慢,无法满足工业生产过程中实时检测的需求。为提高目标物体的检测速度,使得目标检测模型更好地应用到实际场景中去,国内外很多学者基于直接对目标物体定位和分类的单阶段检测算法提出了大量改进优化算法。Shi 等^[10]提出了一种用于 PCB 中微小缺陷检测的新型单目标检测器(SSDT),该算法对小目标缺陷检测较好,但平均均值精度较低,检测精度无法满足要求。Zhuo 等^[11]通过将 K-means++ 聚类算法融入 YOLOv3,其平均精度均值(mAP)达到了 92.13%,但检测速度较慢,模型较大部署困难。刘涛等^[12]提出一种基于 GhostNet-YOLOv4 的 PCB 板检测算法,其 mAP 为 86.68%,帧率达到了 25.43 fps,检测精度较低,无法满足要求。卞佰成等^[13]对 YOLOv3 进行了改进,将主干网络替换为 ResNeSt50,同时添加 SE 注意力机制,提升对 PCB 小目标物体的敏感程度,在检测精度上取得较高的精度均值,但网络参数较大。何国忠等^[14]针对 PCB 制作精密、复杂,各类缺陷不易检测的难点,基于 YOLOv4 网络进行优化改进,加入全局注意力机制,同时在 SPP(spatial pyramid pooling)模块基础上进行了特征图重组,从而提升特征信息丰富度。杨永跃等^[15]针对 PCB 背景复杂的问题,在 YOLOv5x 基础模型中引入了卷积块注意模块(convolutional block attention module, CBAM)注意力模块,以提高捕捉不同位置的 PCB 缺陷信息的能力。伍济钢等^[16]在 YOLOv4 算法的基础上,使用二分聚类方法 K-means 并结合损失函数交并比(IoU)确定锚框,使用 MobileNetV3 作为主干特征提取网络,在 PCB 缺陷检测精度提高的同时也加快了检测速度。

时造雄等^[17]在 YOLOv5l 骨干网络中引入注意力机制,并在颈部网络融合 Transformer 编码器结构,并且使用 E-IoU 方法选定锚框,以提升 PCB 缺陷检测的速度和精度,但 YOLOv5l 同样存在参数量过大问题。上述成果证明网络模型轻量化,添加注意力机制,以及针对检测目标采用更适宜的 IoU 来进行模型改进,能够有效解决目标检测过程中的速度与精度问题,为本文研究奠定了基础。

根据以上改进卷积神经网络在 PCB 缺陷检测中的应用分析,本文设计了一种基于 YOLOv8n 改进的 PCB 缺陷检测算法。

本文对 YOLOv8n 的结构进行修改,增加一层小目标检测层,降低对小目标 PCB 缺陷的漏检率。在特征提取网络 P2、P4、P6 中引入 C2F_CA 注意力模块,提高复杂背景下小目标缺陷的定位和识别。设计密集连接机构,提高模型的缺陷特征利用率,采用 PConv 对模型进行压缩,既保证了模型的准确性,又大大减小了模型的尺寸。采用线性区间映射法重新定义 Focaler-SIoU 损失函数,提高模型收敛速度和回归精度。采用 Copy-Pasting 图像增强策略,通过将不同尺度的实例对象粘贴到新的背景图像中来生成新样本,同时提高了数据集样本数量以及缺陷标签数量,以达到数据增强的目的。

1 YOLOv8 算法

YOLOv8 是 YOLO 系列的第 8 个版本,可用于对象检测,图像分类和实例分割任务。根据网络中特征提取模块和卷积核的数量,YOLOv8 包括 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x 五种网络模型。模型大小分别为 6.3、22.5、52.1、87.7 和 136.8 Mb。随着网络模型参数数量的增加,基本网络模型的复杂性增加,模型的精度提高,但需要更多的计算和硬件资源,推理速度下降。网络结构如图 1 所示。

2 算法模型改进

2.1 增加微小检测层

YOLOv8n 提取了 3 个不同级别尺度特征图的网络进行检测,分别是(80,80)、(40,40)和(20,20),分别对应的目标大小为 8×8 、 16×16 、 32×32 (小、中、大)。PCB 板缺陷具有较小的尺寸和低分辨率,而 YOLOv8n 的下采样倍数比较大,较深的特征图很难学习到小目标的特征信息,使得 YOLOv8n 算法对其检测效果不佳。

为解决以上问题,通过 P2 层特征引出新的检测头,相当于在主干网络中只进行了 2 次下采样操作,含有目标更为丰富的底层特征信息。同时颈部网络中通过上采样和下采样得到的特征层与主干网络中同尺度特征通过 concat 形式进行特征融合,从而可以将底层高分辨率和深层特征高语义信息充分利用,得到可以检测 4×4 大小的目标,形成具有 4 层检测层的网络,如图 2 所示(A 区)。




图1 YOLOv8n 网络结构

Fig. 1 YOLOv8n network structure diagram




图2 改进的 YOLOv8n 网络结构

Fig. 2 Improved YOLOv8n network structure diagram

2.2 融合 C2F_CA 注意力机制

在 PCB 板缺陷检测中本身背景很复杂,不易将缺陷与背景分开,另一方面对于 PCB 板的小目标缺陷,其精确定位的要求更高。在深度学习目标检测中使用注意力机制,能够帮助模型更好地聚焦关键特征,并且消弱无关信息在特征图上的权重,从而提高识别准确率,对网络性能

的提升有很大帮助。目前提出的注意机制主要有 3 种类型,通道注意、空间注意和两者兼而有之。作为通道注意力的代表,挤压-激励(squeeze-and-excitation, SE)^[18]明确地模拟了跨维交互作用,用于提取通道注意力。CBAM^[19]利用特征图中空间维度和通道维度之间的语义相互依赖关系建立了跨通道和跨空间的信息。CBAM 在将跨维注

意权重整合到输入特征中显示出巨大的潜力。然而池操作的手动设计涉及复杂的处理,带来了一些计算开销。本文使用坐标注意力(coordinate attention, CA)^[20],不仅考虑网络通道间的信息,还考虑了与方向相关的位置信

息,能够将注意力资源分配给关键区域,从而在复杂环境中降低背景的干扰,有助于模型更好地定位和识别目标特征。帮助网络更好的自主学习特征权重,其结构如图3所示。




图3 CA注意力机制示意图

Fig. 3 Schematic diagram of CA mechanism

为了更好地帮助YOLOV8n网络在PCB板缺陷检测中准确定位缺陷所在位置,通过在特征提取网络(Backbone)中添加CA注意力机制的方式对原网络模型进行改进。其具体实施如下:在YOLOv8n网络P2、P4、P6中构建C2F_CA注意力机制模块,如图4所示。通过在特征提取网络C2F中添加CA模块,通过特殊的一维特征编码操作来增强模型对重要空间位置的关注,并且能够捕获具有精确位置信息的长期依赖关系,使特征提取网络更加关注特征图中像素点之间的关系,从而提高模型的性能和准确度。

为验证所提C2F_CA注意模块的有效性,本文通过在YOLOv8n基础模型主干特征提取网络的相同位置,分别添加3种注意力机制进行对比实验。通过比较不同注意力机制嵌入到网络模型所增加的计算量以及最终的检测精度,来验证所提模块的有效性。所有实验均在同一PCB板缺陷数据集集中进行训练,并选择YOLOv8n作为基线对比。通过对比实验可以看出,SE相对于CA增加的计算量较少,但提升的检测精度没有CA高;CBAM增加量参数计算量最大,但mAP@0.5提升不大;CA增加参数计算量不明显,但相对于其他注意力机制所提高的




图4 C2F_CA模块示意图

Fig. 4 Schematic diagram of C2F_CA module

检测精度最大。因此本文选用CA注意力机制。对比实验数据如表1所示。

表1 YOLOv8n分别添加各注意力机制

Table 1 YOLOv8n with various attention mechanisms added separately

模型	精度	召回率	mAP@0.5/%	浮占数/GFLOPs	参数量	模型大小/MB
YOLOv8n	0.902	0.920	89.9	8.1	3 006 818	5.9
YOLOv8n-SE	0.832	0.930	91.3	8.1	3 008 130	6.0
YOLOv8n-CBAM	0.842	0.930	90.4	8.1	3 018 012	6.0
YOLOv8n-CA	0.832	0.940	91.5	8.1	3 012 346	6.0

2.3 网络密集连接模块

密集连接是2017年Huang等^[21]提出的一种全新网络连接方式。在保证网络中层与层之间最大程度的信息传输的前提下,将所有卷积模块两两之间都进行了连接,最大化网络中所有卷积模块和相关层之间的信息流,使得网络中的每个模块都接受它前面所有层的特征作为输入。

由于网络中存在大量密集的连接,这种网络结构称为DenseNet。

本文提出的C2f_Dense模块其内部卷积层之间采用密集连接的方式,如图5所示。将原YOLOV8n网络模型P8层C2f替换为C2f_Dense,这样既实现了前面卷积模块提取出来特征的复用,而且一定程度上减轻在训练过程中




图5 C2f_Dense 结构

Fig.5 C2f_Dense structure diagram

梯度消失的问题。每一个卷积块都会提取到前面卷积块的图像特征,这些细节特征以前馈的方式将每一层连接到其后的每一层。在网络的后向传播中,由于采用密集连接的方式,并不会被丢弃,而会被不断地重复利用,使得每一个卷积块都可以发挥最高效的作用,可以全方面有效提取PCB板图像的细节特征。

2.4 网络轻量化模块 C2F_PC

在YOLOv8网络中,C2f模块串联大量的Bottleneck进行分支跨层连接,通过增加Split操作,丰富特征图信息。在这个过程中,每增加一个Bottleneck就会有更大的计算量。随着网络结构深入,模型参数量急剧增大,表达能力越强,存储信息越易过载。为平衡网络检测速度与精度,通过融入部分卷积(PCConv)来减少计算量和模型大小。Chen等^[22]在2023年提出一种部分卷积,通过减少冗余计算和存储访问,有效地提取空间特征,同时在PCConv的基础上设计一种快速神经网络(FasterNet),在运行速度与准确性上相比于其他神经网络取得了不错的效果。其卷积示意图如图6所示。




图6 标准卷积与部分卷积示意图

Fig.6 Schematic diagram of standard convolution and partial convolution

普通卷积结构如图6(a)所示,对于给定的输入数据 $I \in R^{c \times h \times w}$,使用一个 $k \times k$ 普通卷积计算输出 $O \in$

$R^{c' \times h \times w}$,完成一次卷积所需的计算量与内存访问量计算式如式(1)、(2)所示。

$$FLOPs_1 = h \times w \times k^2 \times c^2 \quad (1)$$

$$m_1 = h \times w \times 2c + k^2 \times c^2 \quad (2)$$

式中: $FLOPs_1$ 为普通卷积完成一次卷积所需的计算量; c 为进行卷积运算的通道数; h 为高度; w 为宽度; k 为卷积核大小; m_1 为普通卷积完成一次卷积所需的内存访问量。

部分卷积只对部分输入通道进行常规卷积来提取空间特征,而对其余通道保持不变。结构如图6(b)所示。假设对 c_2 ($c_2 < c$)个连续通道作为整个特征映射的代表进行计算,完成一次卷积所需计算量与内存访问量计算式如式(3)、(4)所示。

$$FLOPs_2 = h \times w \times k^2 \times c_2^2 \quad (3)$$

$$m_2 = h \times w \times 2c_2 + k^2 \times c_2^2 \quad (4)$$

式中: $FLOPs_2$ 为部分卷积完成一次卷积所需内存访问量; m_2 为部分卷积完成一次卷积所需的内存访问量; c_2 为进行卷积运算的通道数。

通过对比公式可知,当部分卷积只对1/4通道数进行卷积计算时,及 $c_2 = \frac{1}{4}c_1$, $FLOPs_2$ 的值仅为 $FLOPs_1$ 的1/16。且部分卷积比普通卷积具有更低的浮点运算量。

利用以上部分卷积的优势,构建一种PCC Block模块来实现网络的轻量化,如图7所示。本文将YOLOv8网络中的Bottleneck部分替换为PCC Block模块,同时将网络中的P12、P15、P18、P21、P24、P27位置替换为C2F_PC模块,减少网络参数计算量,从而提高太阳能电池板缺陷检测效率,C2F_PC如图5所示。在本模块中,部分卷积比常规卷积具有更低的浮点数,在提取空间特征方面非常简洁有效。

2.5 损失函数优化

YOLOv8的边界框回归损失函数为CIoU^[23]。CIoU损失函数只考虑了3个几何因素,重叠面积、中心点距离和长宽比。本文引入SIoU损失函数^[24],这种损失函数考虑了回归之间的向量角度,重新定义了惩罚指标。与CI-




图7 C2F_PC模块
Fig. 7 C2F_PC module

oU 损失函数相比,SIoU 损失函数由角度损失、距离损失、形状损失和 IoU 损失 4 个部分组成。SIoU 损失函数 L_{SIoU} 定义如下:

$$L_{SIoU} = 1 - L_{IoU} + \frac{\Delta + \Omega}{2} \quad (5)$$

$$L_{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

$$\Delta = (1 - e^{(\varphi-2)\rho_x}) + (1 - e^{(\varphi-2)\rho_y}) \quad (7)$$

$$\Omega = (1 - e^{-w_w})^\theta + (1 - e^{-w_h})^\theta \quad (8)$$

式中: A 表示预测框; B 表示真实框; Δ 表示距离损失; Ω 表示形状损失; φ 与角度损失相关。此外,根据模型对 PCB 数据集中困难样本与简单样本关注数量不均衡的问题,在改进 SIoU 损失函数的基础上,利用线性区间映射法重建损失函数 Focaler-IoU,公式定义如下:

$$IoU^{focaler} = \begin{cases} 0, & IoU < d \\ \frac{IoU - d}{u - d}, & d \ll IoU \ll u \\ 1, & IoU > u \end{cases} \quad (9)$$

式中: $IoU^{focaler}$ 为重构后的 Focaler-IoU; $[d, u] \in [0, 1]$ 。通过调整 d 和 u 的值,使 $IoU^{focaler}$ 聚焦于不同的回归样本。将 Focaler-IoU 损失应用于已有的基于 SIoU 的边界盒回归损失函数,定义了新的边界盒损失函数如下式所示:

$$L_{Focaler-SIoU} = L_{SIoU} + IoU - IoU^{focaler} \quad (10)$$

3 实验与结果分析

3.1 实验环境

实验采用 windows11 操作系统,配备 12th Gen Intel (R) Core(TM) i9-12900H@2.50 GHz 处理器。显卡选

用 NVIDIA RTX3070,运行内存 64GB。深度学习框架为 PyTorch1.13.0,编程语言为 Python 3.8.13,CUDA 版本为 11.3,并使用 cudnn 版本为 8.2 进行 GPU 加速。实验过程中采用 SGD 优化器来进行优化。

3.2 数据介绍及增强

本文使用北京大学智能机器人开放实验室的开源数据集^[25],该数据集含有 6 种 PCB 缺陷,分别是漏孔、鼠咬、开路、短路、杂散、杂铜。该公开数据集一共包含 693 张图片,像素值为 2777×2138 ,每张图片的缺陷数量为 3~6 个缺陷,且缺陷大小占图片像素大小的 0.24%。

缺陷目标检测中常常存在着数据集规模偏小的问题,考虑于此,采用数据集增强技术对数据集进行扩充增强以提高泛化能力。本文除了采用 YOLOv8 本身的增强策略 Mosaic、MixUp,还引入了 Copy-Pasting 增强方法。Copy-Pasting 增强策略是 Ghiasi^[26]提出的一种数据增强方法,用于实例分割技术,通过将不同尺度的实例对象粘贴到新的背景图像中来生成新样本,以达到数据增强的目的。Copy-Pasting 增强策略利用式(11)将两幅图混合在一起。

$$I_1 \times \alpha + I_2 \times (1 - \alpha) \quad (11)$$

式中: I_1 代表粘贴对象所在的图像; I_2 代表主图像; α 代表 mask 的掩模。式(11)就是将 I_1 中的 mask 部分像素扣出来,然后与 I_2 混合粘贴。Copy-Pasting 增强的过程图如图 8 所示。




图8 Copy-Pasting 增强过程
Fig. 8 Copy-Pasting enhancement process

采用 Copy-Pasting 扩充后的数据集,除了在图片数量上有了较大提高,并且在每张 PCB 图片上的缺陷种类数量也得到了增加。这使得本文的 PCB 数据集包含了足够多的缺陷特征来进行卷积神经网络的训练。增强后的数据集标签及对应的数量如表 2 所示。

3.3 性能评价指标及实验参数

本文选择精度(P)、召回率(R)、平衡分数(F1)、mAP 4 个评价指标对算法进行评价。其中,精度即为预测为正确的数据中,真实值为正确的比例,衡量分类的准确度,如

表2 PCB板缺陷标签对应

Table 2 Corresponding table of PCB board defect labels

种类	对应标签	对应标签号	图片数量	标签数量
漏孔	missing hole	0	230	1 520
鼠咬	mouse bite	1	230	1 000
开路	open circuit	2	232	1 500
短路	short	3	232	1 420
杂散	spur	4	230	1 100
杂铜	spurious copper	5	232	1 200

式(12)所示。召回率为在所有的真实值为正确的数据中,有多少能预测正确,衡量了检测的查全率,定义如式(13)。AP表示模型在给定类别中的精度,定义如式(14)。mAP为AP的平均值,表示所有类别的平均精度均值。

$$P = \frac{TP}{TP + FP} \quad (12)$$

$$R = \frac{TP}{FN + TP} \quad (13)$$

$$AP = \frac{\sum_{i=1}^n P_i}{n} \quad (14)$$

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (15)$$

式中:TP表示模型正确识别到的缺陷数量;FP表示模型未正确识别或未识别到的缺陷数量;FN表示模型错误检测到的目标数量。

模型训练参数的设置,直接会影响模型的好坏,并且为了保证训练结果的准确性,将不同算法在相同的训练参数下进行测试。具体参数设置如下:批量大小(batch_size)为16,学习率(lr)为0.0025,动量因子(momentum)为0.937,优化器权重衰减(weight_decay)为0.0005。均不使用与训练权重进行训练。在YOLOv8n-C4PD训练过程中,其边界框损失(box_loss)、分类损失(cls_loss)和损失函数(dfl_loss)值的变化曲线如图9所示。




图9 训练中各损失曲线

Fig. 9 Loss curve diagram during training

从图9可以看出,随着网络迭代次数的增加,模型的损失值逐渐减小。在初始训练阶段,模型的学习率较高,其损失曲线的收敛速度较快。经过200次迭代,训练损失曲线慢慢收敛。当训练迭代次数达到300次左右时,损失曲线趋于稳定。因此,本文将训练迭代次数(epoch)设置为300次。

3.4 性能对比

1) YOLOv8n-4SCDP算法与YOLOv8n算法精度、召回率对比

为了更好了解YOLOv8n-4SCDP算法与YOLOv8n算法之间存在的差异,将YOLOv8n-4SCDP算法与YOLOv8n算法训练过程中的P、R进行打印,其P、R对比如图10所示。

从图10可以看出,YOLOv8n在100轮左右P、R收敛趋于稳定,YOLOv8n-4SCDP在50轮左右P、R收敛趋于稳定,且YOLOv8n-4SCDP算法的P、R值比

YOLOv8n算法更高。因此说明本文提出的改进YOLOv8n-4SCDP算法相比YOLOv8n算法提高了网络的收敛速度,且精确率、召回率有所增加。

2) 消融实验

为验证本文改进模块对所提算法的有效性,进行了消融实验。所有实验均在同一PCB数据集上进行。通过设计5组实验来证明每个模块的有效性。为了保证实验的准确性,5组实验所采用的环境及训练参数均保持一致。增加不同模块的改进算法名称对应如表3所示,其中“√”表示模型融入该策略,“—”表示模型未使用该策略。由表3可以看出,加入部分卷积后,会使网络轻量化,相对于YOLOv8n,同时采用4检测头、CA注意力机制、密集连接和部分卷积的模型,其平均精度均值最高,为95.5%,相对于基线提高5.6%,同时又减小了参数计算量;其模型大小同样为最小,有利于模型的部署。

为了更加直观看出训练过程中,平均精度均值的变




图 10 YOLOv8n-4SCDP 算法与 YOLOv8n 算法 P 、 R 对比
Fig. 10 Comparison diagram of P and R between YOLOv8n-4SCDP algorithm and YOLOv8n algorithm

表 3 不同模块改进后算法性能对比

Table 3 Performance comparison of algorithms after different module improvements								
4scales	CA	Dense	PConv	Focaler-SIoU	浮点数/GFLOPs	参数量	模型大小/MB	mAP@0.5/%
—	—	—	—	—	8.1	3 006 818	5.9	89.9
✓	—	—	—	—	12.2	2 927 352	6.0	93.0
✓	✓	—	—	—	12.4	2 932 880	6.0	94.4
✓	✓	✓	—	—	12.3	3 022 208	6.2	95.3
✓	✓	✓	✓	—	11.0	2 567 936	5.3	95.5
✓	✓	✓	✓	✓	11.3	2 713 530	5.3	95.8

化,对训练过程中,mAP 的值进行打印,如图 11 所示。由图 11 可知,YOLOv8n-4SCDP 相比其他几种改进算法,在收敛速度上明显加快,在 mAP 上有所上升。




图 11 平均精度均值 mAP 对比
Fig. 11 Comparison diagram of mean average precision

3)主流算法对比实验

为了进一步证明本文提出 YOLOv8n-4SCDP 算法的先进性和优越性,将本文算法 YOLOv8n-4SCDP 与 Faster R-CNN、SSD、YOLOv3、YOLOv5s、YOLOv3^[13]、YOLOv4^[14]、YOLOv5s^[27]、YOLOv5l^[16]、YOLOv5x^[15] 以及 YOLOX-WSC^[28] 在同一场景下进行对比,并对算法的

性能进行比较。如表 4 所示。

表 4 主流算法之间性能对比

Table 4 Performance comparison among mainstream algorithms				
算法	模型大小 /MB	F1/%	mAP@0.5 /%	帧率 /fps
Faster R-CNN	452	64.3	67.3	11
改进级联 Faster R-CNN ^[9]	567	—	78.21	—
SSD	90.2	41.2	46.5	26
YOLOv3	271	48.3	57.9	29
文献[13]	—	—	98.42	36
文献[14]	—	92	91.4	—
YOLOv5s	15.8	92.0	93.0	35
文献[27]	92.3	—	95.0	—
文献[16]	142.8	—	98.46	—
文献[15]	177.3	—	90.8	13.2
文献[28]	70.3	—	96.65	17.8
YOLOv8n	5.9	89	89.9	70
YOLOv8n-4SCDP	5.3	94	95.8	65

对模型大小分析可知,两阶段检测算法 Faster R-CNN,以及文献[9]改进的 Faster R-CNN 检测算法,相比于其他单阶段检测算法,其模型体积大,不利于检测端的部署。文献[15-16]是基于 YOLOv5 较大版本改进的单阶段目标检测模型,同样存在基础模型较大,参数运算量大等问题,不利于模型的训练与部署。

从平均精度均值来看,文献[16]在 YOLOv5 较大模型版本的基础上进行改进,取得了较高的平均精度均值 98.46%,但模型大小在单阶段检测模型中同样也较大为 142.8 MB。本文改进算法在 YOLOv8 轻量级模型的基础上进行改进,同样取得了较高的平均精度均值提升,由 89.9%提升至 95.8%,相较于原 YOLOv8n 模型提升了 5.9%。文献[13]基于 YOLOv3 改进的 PCB 缺陷检测算法,其平均精度均值同样较高为 98.42%,但检测帧率只达到 36 fps。本文 YOLOv8n 改进算法检测帧率达到 65 fps,相比而言,本文改进 YOLOv8n 模型更有利于 PCB 缺陷实时检测。文献[28]基于 YOLOX 改进的 PCB 缺陷检测模型,模型大小为 70.3 MB, mAP@0.5 为 96.65%,在模型大小与平均精度均值上取得了较好的平衡,但帧率较低为 17.8 fps。

综合模型的检测速度与精度,以及模型大小分析可知,本文改进算法 YOLOv8n-4SCDP 模型小,易于部署,而且在平均精度均值与检测速度上取得了较好的平衡。为工业上 PCB 缺陷的实时检测提供了很好的参考价值。

3.5 检测结果对比

综上所述,YOLOv8n-4SCDP 算法精确率、效率较高,且更易于部署,更满足工业检测要求。为了更加直观的看出检测效果,选择 YOLOv8n-4SCDP 算法和 YOLOv8n 算法训练过程中 best.pt 权重,运用检测脚本对验证集进行检测。检测时,置信度(confidence)的阈值设置为 0.5, IoU 的阈值设置为 0.6。YOLOv8n-4SCDP 算法和 YOLOv8n 算法检测结果如图 12 所示。

采用 YOLOv8n-4SCDP 算法和 YOLOv8n 算法对含有杂散缺陷的 PCB 图像进行检测,YOLOv8n-4SCDP 算法识别该图像含有 3 处杂散缺陷,置信度分别为 68%、84%、81%(图 12(c))。YOLOv8n 算法识别该图像含有 1 处短路、1 处杂散缺陷,置信度分别为 43%、85%(图 12(a))。结果表明,YOLOv8n 出现了误检和漏检,而 YOLOv8n-4SCDP 算法检测准确,说明 YOLOv8n-4SCDP 算法检测更加准确,精度更高。

采用 YOLOv8n-4SCDP 算法和 YOLOv8n 算法对含有鼠咬缺陷的 PCB 板图像进行检测,YOLOv8n-4SCDP 算法识别该图像含有 5 处鼠咬缺陷,置信度分别为 93%、89%、69%、96%、96%(图 12(d))。YOLOv8n 算法识别该图像含有 4 处鼠咬缺陷,置信度分别为 80%、84%、67%、79%(图 12(b))。结果表明,YOLOv8n 未检测到 1 个鼠咬缺陷,而 YOLOv8n-4SCDP 算法检测准确,说明 YOLOv8n-4SCDP 有效改善了小目标漏检率高的缺陷。




图 12 YOLOv8n 算法与 YOLOv8n-4SCDP 算法检测结果对比

Fig. 12 Comparison of detection results between YOLOv8n algorithm and YOLOv8n-4SCDP algorithm

综上所述, YOLOv8n-4SCDP 算法相比原始 YOLOv8n 算法检测精度有明显提升,且在微小目标检测上也有较大的提升,对实际 PCB 板缺陷检测效果更好。

4 结 论

本文提出一种 YOLOv8n-4SCDP 算法,用于提高 PCB 缺陷检测效率。首先,在 PCB 缺陷检测中,由于原 YOLOv8n 检测小目标缺陷很容易产生漏检和误检,在此基础上,本文增加了微小检测头用于检测极小目标,以降低对小目标缺陷的漏检率。其次,引入 C2F_CA 注意力机制模块,实现 PCB 缺陷检测中目标缺陷特征位置的高效学习;随后在特征提取网络中加入一种密集连接机制,提高缺陷特征利用率;为了平衡模型参数与检测精度的关系,采用 C2F_PC 模块来减少计算量和模型大小。最后,为加快网络收敛速度,修改了边界框损失函数。研究表明,该 YOLOv8n-4SCDP 算法与其他 PCB 缺陷检测算法相比,该算法的 mAP@0.5 达到了 95.8%,检测帧率为 65 fps,模型大小仅为 5.3 MB,更易于工业实时检测部署。

参 考 文 献

- [1] 吴一全,赵朗月,苑玉彬,等. 基于机器视觉的 PCB 缺陷检测算法研究现状及展望[J]. 仪器仪表学报, 2022,43(8):1-17.
- [2] 侯学良,单腾飞,薛靖国. 深度学习的目标检测典型算法及其应用现状分析[J]. 国外电子测量技术, 2022, 41(6):165-174.
- [3] 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.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:779-788.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Proceedings of the Computer Vision-ECCV 2016: 14th European Conference, Part I. Springer, 2016: 21-37.
- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [7] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [8] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2017, 39(6): 1137-1149.
- [9] 胡江宇,贾树林,马双宝. 基于改进级联 Faster R-CNN 的 PCB 表面缺陷检测算法[J]. 仪表技术与传感器, 2022(7):106-110,126.
- [10] HU J Y, JIA S H, MA S H. PCB surface defect detection algorithm based on improved cascaded Faster R-CNN [J]. Instrument Technology and Sensors, 2022(7): 106-110,126.
- [11] SHI W, LU Z, WU W, et al. Single-shot detector with enriched semantics for PCB tiny defect detection[J]. The Journal of Engineering, 2020(13): 366-372.
- [12] ZHOU L, YANG H, YUAN L. An improved YOLOv3 method for PCB surface defect detection[C]. 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA). IEEE, 2021: 1009-1015.
- [13] 刘涛,张涛. 基于 GhostNet-YOLOv4 算法的印刷电路板缺陷检测[J]. 电子测量技术, 2022,45(16):61-70.
- [14] LIU T, ZHANG T. Defect detection in printed circuit boards based on the GhostNet-YOLOv4 algorithm[J]. Electronic Measurement Technology, 2022,45(16):61-70.
- [15] 卞佰成,陈田,吴入军,等. 基于改进 YOLOv3 的印刷电路板缺陷检测算法[J]. 浙江大学学报(工学版), 2023,57(4):735-743.
- [16] BIAN B CH, CHEN T, WU R J, et al. Improved YOLOv3-based defect detection algorithm for printed circuit boards [J]. Journal of Zhejiang University (Engineering Science Edition), 2023,57(4):735-743.
- [17] 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.
- [18] HE G ZH, LIANG Y. PCB defect detection based on convolutional neural network [J]. Journal of Graphics, 2022,43(1):21-27.
- [19] 杨永跃,夏远超. PCB 缺陷检测深度学习算法的精度改进[J]. 电子测量与仪器学报, 2023,37(5):11-19.

- YANG Y Y, XIA Y CH. Accuracy improvement of deep learning algorithm for PCB defect detection[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 11-19.
- [16] 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.
- WU J G, CHENG Y, SHAO J, et al. A defect detection method for PCB based on the improved YOLOv4 algorithm[J]. Journal of Instrumentation and Measurement, 2021, 42(10): 171-178.
- [17] 时造雄, 茅正冲. 基于改进 YOLOv5 的 PCB 缺陷检测方法[J]. 电子测量技术, 2023, 46(14): 123-130.
- SHI Z X, MAO ZH CH. Improved YOLOv5-based method for PCB defect detection [J]. Electronic Measurement Technology, 2023, 46(14): 123-130.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.
- [20] 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.
- [21] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [22] CHEN J, KAO S, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021-12031.
- [23] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [24] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv Preprint ArXiv: 2205.12740, 2022.
- [25] 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.
- [26] GHIASI G, CUI Y, SRINIVAS A, et al. Simple copy-paste is a strong data augmentation method for instance segmentation[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2918-2928.
- [27] TANG J, LIU S, ZHAO D, et al. PCB-YOLO: An improved detection algorithm of PCB surface defects based on YOLOv5[J]. Sustainability, 2023, 15(7): 5963.
- [28] 庾冰, 黄丽雯, 唐鑫, 等. 基于 YOLOX-WSC 的 PCB 缺陷检测算法研究[J]. 计算机工程与应用, 2023, 59(10): 236-243.
- TUO B, HUANG L W, TANG X, et al. Research on PCB defect detection algorithm based on YOLOX-WSC[J]. Computer Engineering and Applications, 2023, 59(10): 236-243.

作者简介

姜源, 硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: 102110273@hbut.edu.cn

付波, 博士, 教授, 主要研究方向为数字图像处理、模式识别。

E-mail: fubofanxx@mail.hbut.edu.cn

权轶(通信作者), 博士, 讲师, 主要研究方向为人工智能、目标检测。

E-mail: laistery.hust@gmail.com

李昊, 硕士研究生, 主要研究方向为深度学习、风能预测。

E-mail: 102110342@hbut.edu.cn