

DOI: 10.13382/j.jemi.B2508194

改进 YOLOv8n 的电路板缺陷检测算法*

王彩霞 郭鑫鹏 刘 鹏

(长春理工大学电子信息工程学院 长春 130022)

摘要:针对工业印制电路板(PCB)缺陷面积小、背景干扰导致误检漏检率高、缺陷定位难等问题,提出一种改进 YOLOv8n 的电路板缺陷检测算法。首先,通过调整骨干网络(backbone)中特征金字塔网络(feature pyramid networks, FPN)的特征融合层级,引入 160×160 微小目标特征层及检测头(head)替代原 20×20 大目标特征层及检测头,增强网络对小目标的特征提取能力。其次,在 Backbone 与颈部网络(neck)间引入并行补丁感知注意模块(parallelized patch-aware, PPA),通过多分支特征提取部分捕获目标不同尺度、不同级别的特征,加强模型局部和全局信息提取及融合能力,避免复杂背景特征干扰的同时提升了目标特征信息的利用效率。再者,在 Neck 端引入高效的多尺度注意模块(efficient multi-scale attention, EMA),避免更多顺序处理及模型深度的同时,增强了网络的跨空间学习能力。最后,采用 NWD-EIoU(normalized wasserstein distance-efficient intersection over union)作为边界框回归损失函数,通过归一化 Wasserstein 距离构建几何感知的相似性度量,缓解检测框微小偏移导致的定位误差累积,提升模型对 PCB 微小缺陷的定位精度,并加速收敛。在公开电路板缺陷数据集 PKU-Market-PCB 上的实验结果表明,改进方法的平均精度均值(mAP)mAP@0.5 相较于原始算法提升了 4.2%,精度和召回率指标分别提升了 7.7%、4.3%。与同类型单阶段目标检测方法相比,改进方法满足高精度电路板缺陷检测需求。

关键词: YOLOv8n; 并行补丁感知注意模块; 多尺度注意模块; NWD-EIoU; PCB 微小缺陷

中图分类号: TM93; TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Improved YOLOv8n algorithm for PCB flaws detection

Wang Caixia Guo Xinpeng Liu Peng

(School of Electronic and Information Engineering, Changchun University of Science and Technology, Changchun 130022, China)

Abstract: In order to solve the problems of small defect area of industrial printed circuit boards (PCB), high false detection and missed detection rate caused by background interference, and difficult defect location, an improved circuit board defect detection algorithm based on YOLOv8n was proposed. First, by adjusting the feature fusion levels of the feature pyramid networks (FPN) in the backbone network, introduce a 160×160 tiny-target feature layer and detection head to replace the original 20×20 large-target feature layer and detection head., which enhances the network's ability to extract features of small targets. Secondly, a parallelized patch-aware (PPA) attention module is introduced between the backbone and the neck. Through the multi-branch feature extraction part, it captures features of different scales and levels of the target, strengthening the model's ability to extract and fuse local and global information. While avoiding the interference of complex background features, it also improves the utilization efficiency of the target feature information. Furthermore, the efficient multi-scale attention module (EMA) is introduced at the neck end to avoid more sequential processing and model depth, and at the same time, the cross-space learning ability of the network is enhanced. Finally, normalized wasserstein distance-efficient intersection over union) is employed as the bounding box regression loss function (NWD-EIoU). By introducing the normalized Wasserstein distance (NWD) to construct a geometrically-aware similarity metric, it alleviates the cumulative localization errors caused by minor offsets of detection boxes, improves the model's positioning accuracy for micro-defects on PCBs, and accelerates convergence. The experimental results on the publicly available PCB defect dataset PKU-Market-PCB show that the mAP@0.5 of the

收稿日期: 2024-02-27 Received Date: 2024-02-27

* 基金项目: 吉林省科技发展计划项目(20210201021GX)、国家重点研发计划项目(2018YFB1107600)资助

improved method has increased by 4.2% compared with the original algorithm. The Precision and Recall metrics have increased by 7.7% and 4.3% respectively. Compared with the same type of single-stage object detection methods, the improved method meets the requirements of high-precision PCB defect detection.

Keywords: YOLOv8n; PPA; EMA; NWD-EIoU; tiny defects of printed circuit board

0 引言

在电子制造业中,印制电路板(printed circuit board, PCB)的微小缺陷(像素小于 32×32 的目标或基于图像分辨率占比小于0.1%的缺陷目标),常见的如焊点缺口(missing_hole)、鼠咬(mouse_bite)、开路(open_circuit)、短路(short)、板面毛刺(spur)、余铜(spurious_copper)等缺陷,这些缺陷因面积小、特征弱、易被复杂背景干扰(图像中目标周围环境信息与目标特征相似或干扰的冗余信息,掩盖目标的有效特征,降低检测精度)的特点,使传统的检测方法难以保证较高的准确性和高效性,为了提高生产效率和产品可靠性,业界需要一种快速而精准的检测方法。

传统方法中电路板缺陷检测主要通过基于图像处理的检测方法,该方法主要包含4种,即傅里叶变换、主成分分析、小波变换、图像模式匹配方法。较为普遍的做法是把其他相关检测方法融入到图像模式匹配中,以此来实现对电路板质量的评估。2020年,Melnyk等^[1]提出了一种基于聚类的比较方法来检测裸板PCB上的缺陷,为避免传统差分方法中线路路径和接触点的微小偏移被视为缺陷,在比较前对标准图像和待检测图像进行了聚类。2022年,Onshaunjit等^[2]提出了一种可以检测和分类14种PCB缺陷类型的算法,该算法使用中值滤波减少噪声后,对图像进行仿射变换和模糊c均值聚类分割来进行缺陷检测,通过图像减法来判断缺陷是否存在。然而传统图像处理方法的检测精度依赖于技术人员的专业知识和经验积累,通用性差、效率低、鲁棒性不强。

目前,基于深度学习的电路板缺陷检测应用十分广泛。该方法主要分为两类:双阶段目标检测算法(如RCNN^[3]、Fast RCNN、Faster RCNN^[4]、Mask RCNN等)和单阶段目标检测算法(如YOLO系列、SSD^[5]、CornerNet^[6]、CenterNet^[7]等)。尹嘉超等^[8]针对印刷电路板缺陷定位不够精确等问题,提出改进Faster RCNN网络,选用特征提取能力更强的EfficientNetV2_M作为特征提取网络,实现了高精度的PCB缺陷检测。龚陈博等^[9]针对误检率和漏检率高等问题,提出改进Faster RCNN网络,将扩展特征金字塔网络(EFPN)引入Faster RCNN框架,提升网络模型的多尺度检测能力。陈锦妮等^[10]针对电路板布局复杂导致的部分特征随网络深度丢失问题,提出PA-YOLOv5(precision and attention-YOLOv5)网

络,引入自适应双向特征融合模块(BiFPN)网络,通过对不同尺寸特征图里的有效特征进行提取与应用,显著增强了网络的特征表达能力。针对当下存在的检测模型较大,难以在边缘端实现部署的难题,张淑卿等^[11]提出了一种YOLOv8-t网络模型。该模型运用FasterNet Block以及Slim-Neck结构,分别对骨干网络(backbone)和颈部网络(neck)部分进行结构层面的优化,有效削减了冗余计算以及内存访问,解决了因特征冗余而致使检测精度不高的问题。王健等^[12]针对PCB缺陷检测中形态复杂、目标小等问题,提出了一种基于改进YOLOv8s的小目标缺陷检测算法,通过在Backbone中引入可选择空洞卷积(S-Conv)与CAFM(context-aware feature modulation)卷积和注意力融合模块,扩大感受野,在提升特征表示能力的同时增强对各尺度特征进行融合,并引入更适用于密集小目标检测的VFWD-CIoU代替原损失函数,有效解决了因检测目标小而导致的检出率、准确率低的问题。

YOLOv8作为YOLO算法的新迭代,继承了YOLO系列的快速和实时的检测特性,同时在准确性和灵活性方面进行了显著的改进。YOLOv8采用了先进的网络架构和训练策略,包括更好的特征融合机制、更有效的损失函数设计以及更强大的数据增强方法,使其在多种视觉任务中表现出色。为应对PCB缺陷^[13]场景中缺陷面积小、复杂背景干扰等挑战并解决由此导致的检测精度低、误检漏检等问题,在YOLOv8n算法的基础上进行改进。

本文改进特征金字塔网络(feature pyramid networks, FPN)^[14],将包含丰富小目标^[15]信息的 160×160 浅层特征替代 20×20 深层特征融入到Neck端,同时为提高模型推理速度并减少参数量,采用 160×160 检测头(head)替代 20×20 检测头,使模型更专注于小目标特征提取;引入并行补丁感知注意模块(parallelized patch-aware attention, PPA)^[16]于Backbone与Neck间,其通过串行卷积深化特征、局部/全局分支聚焦目标区域以提取多尺度特征,结合空间与通道注意力强化目标特征、抑制背景噪声,有效减少复杂背景干扰,更精准地适配电路板微小缺陷检测场景;引入多尺度注意模块(efficient multi-scale attention, EMA)^[17]于Neck端,其通过通道、空间维度的因子分解及局部窗口约束,增强对多尺度特征图关键区域的关注能力,从而提升模型的特征聚合效果;采用NWD-EIoU^[18](normalized wasserstein distance-efficient intersection over union)作为边界框回归损失函数,其通过引入归一化Wasserstein距离(NWD)精确捕捉真实框与

检测框的形状及位置相似性,从而加快模型收敛,提升边界框回归精度与检测效果。

1 改进方法

1.1 改进算法整体结构

YOLOv8n 是一种基于 YOLO 系列的目标检测模型,在对实时性、精确性要求高的场景中展现出了一定的优势。然而在面临像素点极少的 PCB 微小缺陷时,往往由于缺陷特征表示不足、下采样后特征消失、复杂背景干扰等问题而表现出较差的检测性能。为此,在 YOLOv8n 算法的基础上进行针对性改进。

首先,工业生产中 PCB 板的大面积损伤通常可以被肉眼察觉,而 PCB 板的微小缺陷往往不容易通过肉眼发现。在工业检测相机中 PCB 板的微小缺陷表现为极少

像素点的小目标,故应加强网络对小目标特征信息的充分利用,将 YOLOv8n 中的 FPN 进行改进,引入浅层特征层以提取更多 PCB 微小缺陷的特征信息。其次,针对 PCB 微小缺陷特征易丢失问题,引入 PPA 模块提升多尺度特征的提取能力,并通过补丁机制加强有效信息的传输,抑制复杂背景对 PCB 微小缺陷检测的影响,以提高网络对 PCB 微小缺陷检测的准确性。此外,引入 EMA 注意力模块,其多尺度跨空间学习方法能更好的捕捉全局特征^[19],结合局部窗口约束聚焦于缺陷特征密集的关键区域,增强对 PCB 微小缺陷特征的辨别能力。最后,针对微小缺陷定位精度不足的问题,采用更适配小目标检测的 NWD-EIoU^[20] 边界框损失函数替代 CIoU^[21],该损失函数通过优化边界框回归的度量方式,能更精确地定位 PCB 板微小缺陷,同时减少回归损失值并加速模型收敛过程。改进后的算法整体结构如图 1 所示。

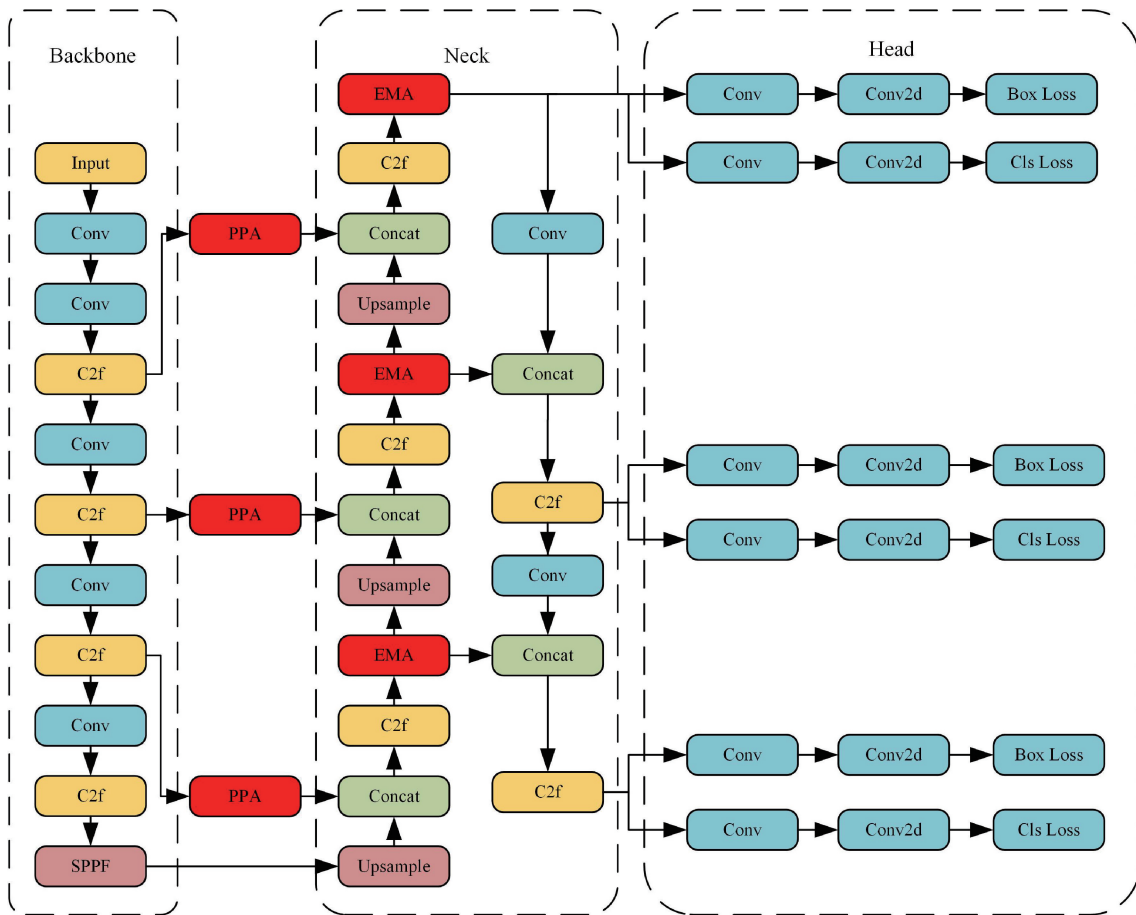


图 1 改进的 YOLOv8n 模型结构

Fig. 1 Improved YOLOv8n model structure

1.2 加强小目标特征信息提取的改进 FPN

小目标在整张图片中占有极少的像素点,并且其纹理特征较弱容易被复杂背景所掩盖,如何更加高效的捕

捉小目标信息成为了重要问题。随着卷积层数的加深,小目标特征变得越来越微弱,对此使网络更专注于提取浅层特征在 PCB 缺陷检测中尤为重要。

FPN 通过构建特征金字塔以实现多尺度特征融合,其过程分自底向上和自顶向下路径。自底向上经卷积和下采样操作,从输入生成高层特征图,特征图尺寸减小、语义信息丰富。自顶向下将顶层语义特征图上采样,把语义信息传至低层特征图。如此,FPN 通过融合高层语义信息与低层空间信息,实现多尺度特征的有效融合。YOLOv8 中使用 20×20 、 40×40 、 80×80 大小的特征层作为有效特征层,如图 2 所示。




图 2 原始 FPN

Fig. 2 Original FPN

改进 FPN 为提高小目标信息提取加入了更浅层的 160×160 特征层,减少了 20×20 特征层的下采样,从 Backbone 提取更多小目标信息,在 Neck 端进行上采样和特征融合。YOLOv8 中的检测头被分为大目标、中目标和小目标的检测头,以更好地适应不同尺寸目标的检测需求。在不同场景中多头检测头都能够提供更好的性能,特别是在处理小目标时表现出色,改进后的网络加入 160×160 特征大小的检测头,同时,为了提高模型的速度,除去 20×20 特征大小的检测头。改进后的 FPN 如图 3 所示。




图 3 改进 FPN

Fig. 3 Improved FPN

1.3 PPA 并行补丁感知注意模块

YOLOv8 的 Neck 端直接采用拼接的方式将骨干中的有效特征层与多层卷积后的特征进行融合,这样的融合方式不足以加强小目标的特征信息,且会引入背景信息干扰目标信息,为此在 Backbone 与 Neck 间加入 PPA 模块^[22],更有效的减少小目标特征丢失和复杂背景干扰等情况,其结构框图如图 4 所示。

PPA 模块主要分为多分支特征提取部分以及特征融合^[23]和注意力部分。

1) 多分支特征提取部分。PPA 采用并行多分支方




图 4 PPA 结构

Fig. 4 PPA structure diagram

法,捕获目标不同尺度、不同级别的特征,进而加强小目标检测的准确性。该策略主要为 3 个并行分支,即串行卷积分支、局部分支、全局分支。串行卷积分支首先通过一个 $PWConv_{1 \times 1}$ 卷积将不同层的特征图在通道维度上进行合并,再通过 3 个 3×3 卷积组成的串行卷积替换 7×7 、 5×5 和 3×3 卷积层提取更深层次的特征信息并求和得到串行卷积分支的输出。局部分支和全局分支结构如图 5 所示。




图 5 局部分支与全局分支

Fig. 5 Local and global branches

通过 *Unfold* 和重塑将特征图分割成不同大小的块(patch),然后对特征进行重塑并进行通道平均,如式(1)所示。

$$\begin{cases} \mathbf{L} = \text{Unfold}(\mathbf{X}, P, P) \\ \mathbf{L}_{flat} = \text{Reshape}(\mathbf{L}, (\mathbf{B}, \frac{H}{P} \cdot \frac{W}{P}, P \cdot P, C)) \\ m = \text{Mean}(\mathbf{L}_{flat}, C) \end{cases} \quad (1)$$

然后通过两个全连接层和层归一化处理局部均值特征,如式(2)所示。

$$\begin{cases} \mathbf{h}_1 = \text{MLP}_1(m) \\ \mathbf{h}_2 = \text{Norm}(\mathbf{h}_1) \\ \mathbf{h}_3 = \text{MLP}_2(\mathbf{h}_2) \end{cases} \quad (2)$$

再应用激活函数来获得线性计算特征的空间维度的概率分布并调整它们的权重,如式(3)所示。

$$\begin{cases} \text{attn} = \text{Softmax}(\mathbf{h}_3, C) \\ \mathbf{L}_{attn} = \mathbf{h}_3 \odot \text{attn} \end{cases} \quad (3)$$

随后计算输出特征与可学习的全局 *promot* 向量之间的余弦相似度,生成一个掩码用于调节局部特征表示,

使模型更关注于与 *prompt* 向量相似度更高的局部特征, 如式(4)所示。

$$\begin{cases} sim = \frac{L_{attn}}{\|L_{attn}\|} \cdot \frac{prompt}{\|prompt\|} \\ mask = Clamp(sim, 0, 1) \\ mask_{out} = L_{attn} \odot mask \\ L_{out} = mask_{out} \cdot top_down_{transform} \end{cases} \quad (4)$$

接着通过一个可学习的变换矩阵对局部特征进行进一步的处理以实现局部特征的增强和全局信息的融合, 特征选择模块如图 6 所示。最后, 将 3 个分支的输出进行拼接, 传入特征融合和注意力部分。

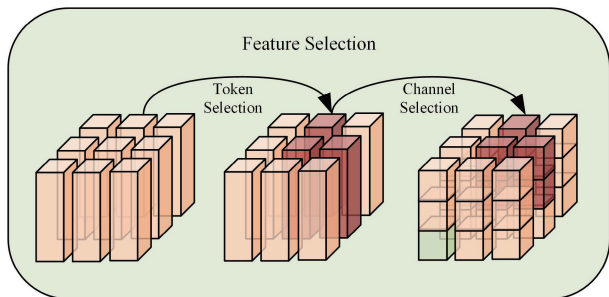


图 6 特征选择模块

Fig. 6 Feature selection module

2) 特征融合和注意力部分。通过多分支进行特征提取后, 使用注意力机制进行进一步的自适应性增强。注意力模块包含空间注意力和通道注意力两部分, 空间注意力先在通道维度上计算输入特征图的平均值与最大值, 接着将这两个值在通道维度进行拼接, 随后利用一个 2D 卷积层对拼接后的特征做处理, 再经 Sigmoid 激活函数激活卷积输出, 从而得到最终的空间注意力权重。最后, 将该权重与原始输入特征图加权, 以此增强模型对关键空间位置的感知。采用高效通道注意力模块 (efficient channel attention, ECA)^[24]。ECA 注意力机制通过一维卷积捕捉通道间的依赖关系, 学习各通道特征的重要程度, 并依此调整不同通道的输出权重。该机制有效规避了复杂的降维和升维过程。在不降维的同时只增加了少量参数, 有效增强了模型对有用特征的关注度, 其结构如图 7 所示。

PPA 模块通过结合不同尺度的特征信息来提高模型对空间和通道信息的理解能力, 更有效地将主干部分的有用特征传入到颈部, 为后续特征融合提供更多重要目标的特征信息, 在 PCB 小目标缺陷检测模型中, 可以帮助模型更好的定位识别微小缺陷目标。

1.4 EMA 注意力模块

注意力机制能够帮助模型捕捉图像中的重要特征信息, 提高对重要信息的关注度, 一定程度上增强对输入数

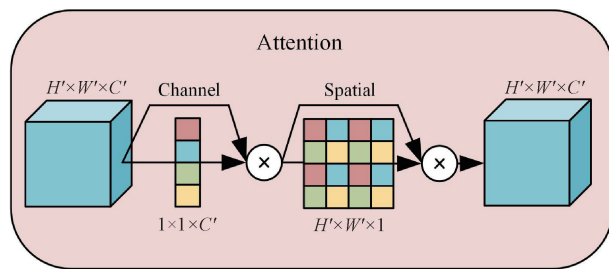


图 7 注意力模块

Fig. 7 Attention module

据的理解和表征能力。在基础 YOLOv8n 模型的 Neck 端应用简单的特征拼接方式将特征信息进行传播, 这会使模型在信息传播中产生很多不必要的冗余且无法专注于有效特征的捕捉。在 PCB 板缺陷检测中, 复杂背景的影响下, 微小缺陷目标可提取的特征较少, 并且没有足够的上下文信息, 导致目标信息难以在复杂背景中被捕捉。故本文在 Neck 端引入 EMA 注意力机制, 其将输入特征图分成多个子特征组, 使空间特征均匀分布于特征组内, 其并行信息传输方式有助于捕获跨维度的信息依赖关系, 丰富了特征聚合且增强了模型对长距离依赖关系的建模能力。

EMA 的具体结构如图 8 所示, 首先将输入特征图分成 G 组, 然后对分组后的特征图进行 1×1 和 3×3 卷积操作, 1×1 卷积后同时进行横向和纵向的一维全局平均池化操作并沿横向进行拼接, 再进行一次 1×1 卷积操作后将输出分解成两个向量, 分别进行 Sigmoid 操作来获得特征图不同部分的重要性权重, 再通过 Re-weight 对特征图进行加权, 以实现通道上的特征交互。 3×3 卷积子网络使模型获得更大感受野, 为模型提供不同尺度的特征信息, 从而捕获更丰富的空间结构信息。EMA 在不同空间维度上进行跨空间的信息聚合以丰富特征的交互, 1×1 和 3×3 卷积子网络分别对上层输出通过自适应池化和 softmax 操作, 将局部特征和全局特征通过生成的空间注意力权重值的 Sigmoid 函数进行相互加权, 再通过矩阵点积操作聚合这些输出, 以捕获微小特征配对关系, 突出特征的上下文关系。最后再将含有通道注意与空间注意的权重的权重值加权到原始的输入特征中, 进而实现上下文信息的交互, 以满足模型对检测目标的关注度, 提升特征提取效率。

1.5 NWD_EIoU 损失函数

损失函数在目标检测中十分重要, 其主要用于度量模型的预测结果与真实值之间的偏差程度, 同时还能指引模型参数的优化方向, 并在反向传播算法中为梯度计算提供依据。损失函数的选择应该取决于被检测目标的特点, 有针对性的提升检测精度。IoU 损失函数广泛应

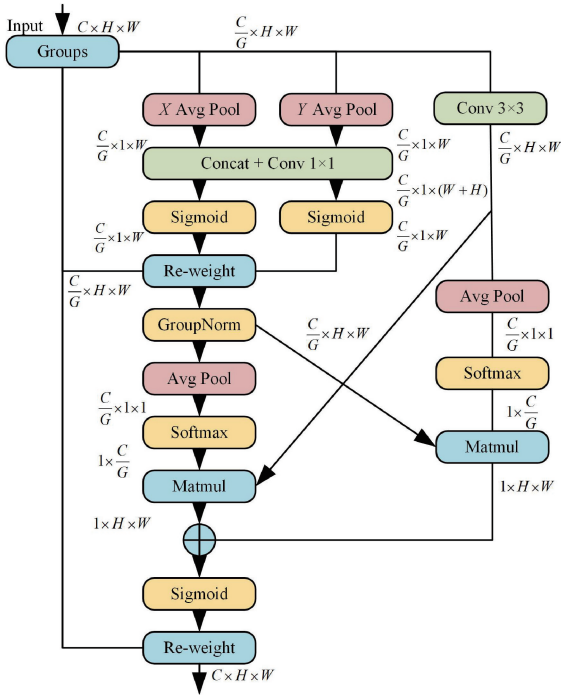


图 8 EMA 结构

Fig. 8 EMA structure diagram

用于目标检测领域,用于测量预测边界框与真实目标边界框的重叠程度,从而精确地确定预测边界框位置。公式如式(5)所示。

$$IoU = \frac{|b \cap b^{gt}|}{|b \cup b^{gt}|} \quad (5)$$

但 IoU 损失函数存在一定的问题,当预测框与真实框没有重叠时会产生梯度消失,减缓网络收敛速度。目前,主流的 IoU 损失函数主要有 GIoU Loss、DIoU Loss、CIoU Loss、EIoU Loss、SIoU Loss^[25]等。YOLOv8 模型边界框使用的是 CIoU Loss 作为边界框损失函数,公式如式(6)所示。

$$\begin{cases} CIoU_{Loss} = 1 - CIoU(A, B) \\ CIoU(A, B) = IoU(A, B) - \frac{\rho^2(C_A, C_B)}{d^2} - \alpha v \\ \alpha = \frac{v}{(1 - IoU + v)} \\ v = \frac{4}{\pi^2} \left(\arctan \frac{w_g}{h_g} - \arctan \frac{w_p}{h_p} \right)^2 \end{cases} \quad (6)$$

式中: v 用来衡量长宽比; α 是一个正的权重系数,用于平衡中心点距离和长宽比差异的影响; $\rho^2(C_A, C_B)$ 是边界框 A 和 B 的中心点之间的欧氏距离的平方; d^2 是包含边界框 A 和 B 的最小外接矩形对角线长度的平方。CIoU 在 IoU 的基础上引入了目标框中心点距离和高宽比的尺度信息,有效的评估了两个边界框的相似度。

CIoU Loss 虽然考虑了中心边距离和长宽比来解决 IoU 算法存在的问题,但在处理 PCB 微小缺陷目标时,精度和效率依然有待提高。因此本文将 CIoU loss 更改为收敛速度更快的 NWD-EIoU Loss。其中 EIoU 的计算公式如式(7)所示。

$$L_{EIoU} = L_{IoU} + L_{dis} + L_{asp} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{gt})}{(w^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2} \quad (7)$$

该损失函数包含 3 个部分,即 IOU 损失、距离损失和方向损失, b 和 b^{gt} 分别表示预测框和真实框的中心点, w 和 w^{gt} 分别代表预测框和真实框的宽度, h 和 h^{gt} 分别表示预测框和真实框的高度, w^c 和 h^c 是预测边界框与真实边界框的最小外接矩形的宽度和高度, ρ 是两点之间的欧氏距离。EIoU 通过使预测框的宽高与最小外接框的宽高差值最小化的方法,能使收敛速度更快,定位更高效。

小目标像素点极少,当检测框与真实框有重叠时,检测框轻微的位置偏差可能导致 IoU 值的大幅度变化,为防止小目标检测框轻微移动导致的误测问题,引入归一化 Wasserstein 距离,以正确捕捉真实框与检测框形状和位置的相似性,从而提高 PCB 微小缺陷检测的准确性。NWD 损失函数的计算公式如式(8)所示。

$$L_{NWD} = 1 - \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (8)$$

式中: \exp 表示归一化后的损失函数。

2 阶 Wasserstein 距离如式(9)所示。

$$W_2^2(N_a, N_b) = \left\| \left(\left[cx_a, cy_a, \frac{w_a}{2}, \frac{h_a}{2} \right]^T, \left[cx_b, cy_b, \frac{w_b}{2}, \frac{h_b}{2} \right]^T \right) \right\|_F \quad (9)$$

式中: c 是代表数据集检测的种类数; $W_2^2(N_a, N_b)$ 是一个二阶 Wasserstein 距离定义,其中 N_a 和 N_b 分别代表边界框 A 和边界框 B 的高斯建模分布; $\|\cdot\|_F$ 是 Frobenius 范数。

针对于 PCB 小目标缺陷,结合 EIoU 损失函数和 NWD 损失函数,NWD-EIoU 如式(10)所示。

$$L_{NWD-EIoU} = \alpha \times L_{EIoU} + (1 - \alpha) \times L_{NWD} \quad (10)$$

式中: α 表示 NWD 损失函数和 EIoU 损失函数的权重。

NWD-EIoU 损失函数能够更好地捕捉 PCB 小目标缺陷,提高小目标检测定位速度^[26]的同时,提升了检测精度。

2 实验与分析







2.1 数据集

实验数据集采用北京大学智能机器人开放实验室提

供的 PCB 缺陷数据集 (PKU-Market-PCB), 该数据集包含 10 668 张图片, 包含了焊点缺口、鼠咬、开路、短路、板面毛刺、余铜 6 种工业常见缺陷。本文采用未经旋转的 PCB 缺陷图片进行检测, 共 693 张图片, 详细信息如表 1 所示。为方便基于 PyTorch 的 YOLOv8n 框架对图片进行检测, 将数据集的标注信息从 XML 格式转换为 TXT 格式。并将图片以 8:1:1 的比例随机划分为训练集、验证集和测试集, 其中训练集 559 张图片, 验证集 68 张图片, 测试集 66 张图片。

表 1 PKU-Market-PCB 数据集详细信息

Table 1 PKU-Market-PCB dataset details

缺陷类别	缺陷样例	标签名称	缺陷图像数	缺陷数
焊点缺口		Missing hole	115	497
鼠咬		Mouse bite	115	492
开路		Open circuit	116	482
短路		Short	116	491
板面毛刺		Spur	115	488
余铜		Spurious copper	116	503
总计			693	2 953

2.2 实验环境及参数配置

实验环境为 Ubuntu 20.04 操作系统, GPU 型号为 NVIDIA RTX 2080 Ti 11 G, CPU 型号为 Intel (R) Xeon(R) Platinum 8255C, 实验基于 PyTorch1.11.0 框架, Python 3.8 版本, CUDA 的版本为 11.3。

在实验过程中保持实验环境一致, 将所有输入图片的尺寸设置为 640×640 pixels, 训练次数 (epoch) 均为 300 轮, 批量大小 (batch size) 为 16, 优化器 (optimizer) 选择 Adam, 初始学习率 (lr0) 为 0.01, 最终学习率 (lrf) 为 0.01, Adam 的 beta1 优化启动量 (momentum) 为 0.937, 权重衰减系数 (weight_decay) 为 0.000 5, 损失函数 NWD_EIoU 的比例因子 (ratio) 为 0.35, 实验参数设置详如表 2 所示。

2.3 评估指标

为了验证改进 YOLOv8n 算法对 PCB 微小缺陷的检测效果, 本文选择精确度 (precision, P), 召回率 (recall, R), 平均精度值 (mean average precision, mAP), 参数量 (Params), 计算量 (GFLOPs), 帧率 (frame per second,

FPS) 作为模型评价指标。精确度 (P) 表示预测的正样本中实际为真的比例; 召回率表示真实为正的样本中被正确预测为真的比例; mAP 表示所有类别的平均精度 (AP) 的平均值; 参数量表示模型中所有可学习参数的总数; 计算量表示一次前向传播所需的计算操作总数, 即模型的推理速度; 帧率表示模型每秒能够处理的图像数。精确度、召回率、mAP 具体公式如下:

表 2 训练参数设置

Table 2 Training parameter settings

实验参数	参数值
输入图片尺寸	640×640
训练次数	300
批量大小	16
优化器	Adam
初始学习率	0.01
最终学习率	0.01
优化启动量	0.937
权重衰减	0.000 5
比例因子	0.35

$$R = \frac{TP}{TP + FN} \quad (11)$$

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

$$AP = \int_0^1 P(R) dR \quad (13)$$

$$mAP = \frac{\sum_{j=1}^c AP_j}{C} \quad (14)$$

式中: TP (true positive) 表示将正类预测为正类数; FN (false negative) 表示将正类预测为负类数; FP (false positive) 表示将负类预测为正类数; TN (true negative) 表示将负类预测为负类数; AP 表示单个类别的平均精度; C 表示类别总数。

2.4 消融实验

对改进 YOLOv8n 模型基于 PCB 缺陷数据集进行消融实验, 对模型各模块进行性能评估, 以验证改进模块的有效性, 消融实验结果如表 3 所示。其中 A、B、C、D 表示 YOLOv8n 基础上引入改进 FPN、PPA、EMA 模块和 NWD-EIoU 损失函数的实验结果。

由表 3 可见, 实验 1 为原 YOLOv8n 模型的实验结果, 作为对照组与以下 6 组实验进行对比, 该模型的 mAP@0.5 为 88.0%。

实验 2 加入了模块 A, 可见针对于小目标, 模块 A 有效提高了改进模型的检测精度, 相较基线模型提升了 1.4%, PCB 缺陷检测精度为 89.4%, 参数量降低了 49.8%。

实验 3、4 在实验 2 的基础上分别引入了模块 B 和

表 3 基于改进 YOLOv8n 的消融实验

Table 3 Ablation experiment based on improved YOLOv8n

消融实验	YOLOv8n	A	B	C	D	mAP@0.5/%	P/%	R/%	帧率/fps	Params/($\times 10^6$)	计算量/GFLOPs
实验 1	✓	×	×	×	×	88.0	87.3	83.0	77.60	3.20	8.70
实验 2	✓	✓	×	×	×	89.4	92.5	84.6	76.09	2.01	11.5
实验 3	✓	✓	✓	×	×	90.8	94.9	83.3	60.14	2.73	16.5
实验 4	✓	✓	×	✓	×	88.0	92.0	82.9	56.38	2.01	11.7
实验 5	✓	✓	×	×	✓	89.9	96.0	83.6	63.27	2.01	11.5
实验 6	✓	✓	✓	✓	×	92.0	94.5	86.1	45.75	2.73	16.7
实验 7	✓	✓	✓	✓	✓	92.2	95.0	87.3	49.47	2.73	16.7

C, 实验 3 模型相较于基线模型, mAP@0.5 提升了 2.8%, 精确度提升较高, 提升了 7.6%, 实验 4 模型相较于基线模型, mAP@0.5 没有明显提升, 在不引入多余参数量的同时, 精确度提升了 4.7%, 可见引入模块 B、C 分别对模型的精确度都有较大的提升, 但会因此提升模型的计算量, 导致检测速度下降。

实验 5 在实验 2 的基础上引入模块 D, 检测效果在不提升参数量和计算量的情况下有了进一步的提升, mAP@0.5 相较于实验 2 模型提升了 0.5%。

实验 6 同时引入模块 A、B、C, 相较于于基线模型 mAP@0.5 提升了 4%。最后, 实验 7 将模块 A、B、C、D 全部引入模型中, 结果表明, 最终改进模型相较于于基线模型, mAP@0.5 提升了 4.2%, 模型的精确度和召回率分别提升了 7.7% 和 4.3%, 参数量降低了 17.2%, 但改进后模型的深度和计算量有一定的提升, 导致帧率有一定程度的降低, 但依然能满足实时性检测要求。

2.5 NWD-EIoU 不同比例因子对比实验

NWD-EIoU 损失函数中的比例因子 $ratio \in [0, 1]$, 其取值会改变 NWD 损失函数和 EIoU 损失函数对模型影响的比例, 为了取得合适的比例因子, 在改进后的模型基础上选取不同比例因子进行对比实验。实验结果如表 4 所示, 当 ratio 为 0.35 时, 表示 NWD 损失函数对模型的影响比例为 65%, EIoU 损失函数对模型的影响比例为 35%, 此时模型检测效果相比于其他比例因子最佳, mAP@0.5 为最高的 92.2%, 可见 NWD-EIoU 损失函数更适用于小目标缺陷检测。

表 4 不同比例因子模型对比

Table 4 Comparison of models with different ratios (%)

ratio	mAP@0.5	P	R
0.30	91.2	91.6	88.4
0.35	92.2	95.0	87.3
0.40	91.5	93.6	85.7
0.45	90.9	91.8	87.7
0.50	89.1	94.0	94.0
0.55	90.5	90.9	87.7

2.6 损失函数对边界框回归的影响对比实验

为验证 NWD-EIoU 损失函数对边界框回归效率的影

响, 以 YOLOv8n 为基础模型, 在仅改变损失函数的前提下开展对比实验。将 NWD-EIoU 与经典的 CIoU、DIoU、GIoU、EIoU、SIoU 损失函数进行对比, 经 300 轮模型训练, 绘制出不同损失函数对应的边界框回归损失曲线, 如图 9 所示。

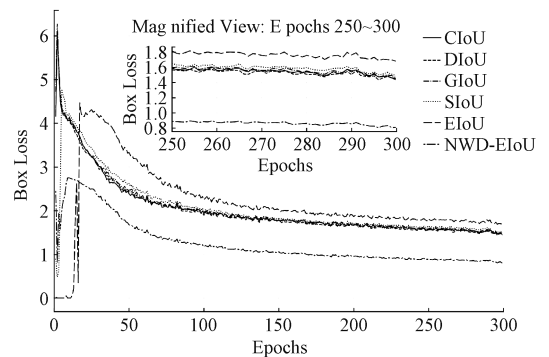


图 9 边界框回归损失对比

Fig. 9 Box regression loss comparison chart

NWD-EIoU 通过引入归一化 Wasserstein 距离, 优化了边界框回归的损失计算方式, 同时凭借 EIoU 对边界框长宽比、重叠度等因素的精准约束, 加速了损失收敛进程, 在 100 个 Epoch 内基本趋于稳定, 且框回归损失值最终稳定在 1 以下。反观 CIoU、DIoU、GIoU、EIoU、SIoU, 其边界框回归损失值虽也呈逐步下降趋势, 但整体下降幅度慢于 NWD-EIoU, 最终边界框回归损失值稳定在 1.4~1.8。这说明在微小缺陷检测的边界框回归任务中, NWD-EIoU 的收敛效率与最终效果均优于 CIoU、DIoU、GIoU、EIoU、SIoU, 能够使边界框更快速、精准地收敛至目标位置。

2.7 热力图可视化分析

在目标检测领域, 特征热力图^[27]的可视化可以洞悉模型内部特征提取和处理流程。通过实验, 借助特征热力图来呈现 YOLOv8n 改良模型在不同阶段的特征提取情况, 进而剖析并行 PPA 模块对于特征提取产生的作用。热力图可视化分析结果如图 10 所示。

Results 为模型所接收的初始图像的检测结果, 为后续特征提取和分析提供对比基础。Backbone 为主干特征




图 10 热力图可视化分析

Fig. 10 Heatmap visualization analysis

热力图,展现了经过模型主干网络处理后所得到的特征表达形式,主干特征图里留存了一部分背景信息所对应的特征,同时还存在一些未被充分挖掘提取的特征。当特征图经过 PPA 模块的处理后,背景特征信息得到了显著抑制,目标特征紧密地集中在检测框的范围之内,这一结果证实了 PPA 模块在抑制背景噪声干扰以及提升有用特征提取效率方面具备切实的有效性。

最后,检测头所输出的特征热力图呈现了模型最终的特征表达结果。与主干特征图相比较,改进模型更为全面地提取到了目标的特征信息,并且有效地抑制了繁杂的背景信息。该模型能够更为精准地对目标进行识别

与定位,从而有效地提升目标检测的整体性能表现。

2.8 模型对比实验

为方便展示模型改进效果,将模型大小接近的 YOLO 模型与改进模型进行 $P-R$ 曲线对比,结果如图 11 所示。

可以看出,随着 YOLO 系列的不断迭代,模型检测效果逐步提升。为验证改进模型在 PCB 微小缺陷检测中的先进性,将改进模型与 YOLOv5n、YOLOv5s、YOLOv7tiny^[28]、YOLOv8n、YOLOv9t 以及 YOLOv9s 进行主要性能参数对比,比较结果如表 5 所示。




图 11 各模型 P - R 曲线

Fig. 11 P - R curves of each model

表 5 不同模型模型对比实验

Table 5 Comparative experiments of different models

模型	mAP@0.5/%	P /%	R /%	Params/ ($\times 10^6$)	计算量/ GFLOPs
YOLOv5n	82.4	92.7	75.2	1.90	4.50
YOLOv5s	92.2	95.2	88.4	7.20	16.5
YOLOv7tiny	83.0	88.8	81.7	6.20	13.8
YOLOv8n	88.0	87.3	83.0	3.20	8.70
YOLOv9t	83.7	91.5	78.2	2.00	7.70
YOLOv9s	93.5	96.6	90.4	7.20	26.7
改进 YOLOv8n	92.2	95.0	87.3	2.73	16.7

参数量主要影响模型的存储和读取速度,进而影响检测速度和移动端部署的便捷性,计算量主要影响模型的运算时间,对检测速度和移动设备的计算负担有直接影响。YOLOv5n、YOLOv7tiny 和 YOLOv9t 都有着较少的参数量和计算量,适用于移动端部署,但由其 mAP@0.5 可见,对于微小目标检测,本文改进算法检测效果远优于其他轻量化算法,检测精度和召回率更高,能更有效

地满足 PCB 微小缺陷的检测标准。YOLOv5s 和 YOLOv9s 相比于对应轻量化版本有着更高的检测精度和召回率,但二者较高的参数量导致其无法满足在资源有限的硬件设备上进行移动端轻量化部署,YOLOv9s 较高的计算量难以满足工业 PCB 缺陷检测的实时性要求。

在经典的非 YOLO 算法中,如 Faster R-CNN 和 RetinaNet,前者检测精度尚可,但因复杂的区域候选机制,推理速度偏慢,难以适配 PCB 生产线的实时检测场景;后者虽借助 Focal Loss 缓解了类别不平衡问题,但其自上而下的特征融合方式对 PCB 微小缺陷的多尺度特征挖掘不够充分,且其检测速度虽优于 Faster R-CNN,但与 YOLOv8n 相比仍存在差距,因此未将此类算法纳入对比实验。最新的 YOLOv9 通过标签分配策略增强了复杂场景的适应性,但模型参数量较大,不利于在嵌入式设备上部署;YOLOv10 优化了检测头结构,提升了推理速度,但在微小缺陷特征提取上依然依赖于原始 FPN 架构。将本文改进的 YOLOv8n 算法和传统的 YOLOv8n 进行比较,减少参数量的同时提高了检测精度和召回率,完善了

原始算法对小目标检测精度低等短板,一定程度上保留了 YOLO 系列“单阶段检测”的速度优势,又通过特征增强实现了精度与效率的平衡,在 PCB 微小缺陷的特征提取与实时定位方面满足高精度、快速度、轻量级的协同优化。故对比结果表明,改进 YOLOv8n 算法在部署效率和检测精度上取得了更好的效果,相比于同类算法有一定的先进性。

从类别检测的细粒度表现来看,改进算法的优势同样显著,对比原始与改进 YOLOv8n 的混淆矩阵如图 12、13 所示。改进算法在 PCB 缺陷检测任务中展现出更优的综合性能。开路、短路、板面毛刺、余铜 4 类缺陷的正确识别数提升明显,开路、余铜与背景的交叉误判有所减少,短路与板面毛刺、余铜的交叉误判减少,但鼠咬与背景的交叉误判有所增多。




图 12 原始 YOLOv8n 的混淆矩阵

Fig. 12 Confusion matrix of the original YOLOv8n





图 13 改进 YOLOv8n 的混淆矩阵

Fig. 13 Confusion matrix of the improved YOLOv8n

2.9 缺陷检测可视化分析


如图 14 所示,与原始 YOLOv8n 相比,改进后的算法

在 PCB 缺陷检测中有着更好的效果,针对 6 类印制电路板的微小缺陷,分别进行检测对比(图 14(a1)~(f1)为原始算法检测结果,图 14(a2)~(f2)为改进算法检测结果),可见改进算法有着更高的检测分数,并且原始算法相比于改进算法出现了较多漏检情况,如图 14(c)、(d)、(f)所示。




(a1) (a2)

(a) 焊点缺口
(a) Missing_hole




(b1) (b2)

(b) 鼠咬
(b) Mouse_bite




(c1) (c2)

(c) 开路
(c) Open_circuit




(d1) (d2)

(d) 短路
(d) Short



(e1) (e2)

(e) 板面毛刺
(e) Spur



(f1) (f2)

(f) 余铜
(f) Spurious_copper

图 14 缺陷检测可视化分析

Fig. 14 Visual analysis of defect detection

通过目标检测需求改进算法,引入更适合小目标检测的特征融合机制和损失函数,改进算法可以更好的捕捉 PCB 微小缺陷的细节特征,进而提升检测效果,更好的满足工业应用的实际需求。

3 结 论

基于 YOLOv8n 算法,本文提出了一种针对 PCB 微小缺陷检测的改进算法,为提升算法对微小缺陷特征的捕捉能力,通过改进 FPN 引入微小目标特征层替代大目标特征层,并以小目标检测头替代大目标检测头,在提升小目标检测精度的情况下,精简了模型冗余参数。此外,引入 PPA 模块和 EMA 注意力机制,通过结合不同尺度的特征信息来提高模型对空间和通道信息的理解能力,更有效地将主干部分的有用特征传入到颈部,为后续特征融合提供更多有效目标的特征信息。最后引入 NWD-EIoU 损失函数,在加快模型收敛速度的同时提升边界框回归精度,从而更精准地定位 PCB 微小缺陷,进一步提高检测精度。在北京大学公开的 PCB 缺陷数据集 PKU-Market-PCB 上 mAP 达到了 92.2%,与当前典型的目标检测模型相比,本文提出的改进算法表现出更好的性能。然而,该算法在单一数据集上的优异性能难以完全覆盖实际工业场景的复杂性,PCB 缺陷常呈现多样的形态(如不规则形状、跨尺度尺寸及罕见类别),可能导致模型在未知缺陷类型或复杂背景下出现漏检、误检。因此,后续研究将从两方面推进:一方面,引入多源异构 PCB 缺陷数据集(涵盖不同生产场景、工艺参数下的样本),结合混淆矩阵深度分析各类缺陷与背景的误判模式,针对性优化样本均衡策略与模型注意力机制,增强模型对复杂场景的泛化能力;另一方面,针对实时性要求更高的移动端部署场景,将通过模型剪枝、知识蒸馏等轻量化技术精简参数与计算量,在保证检测精度的前提下提升算法的部署灵活性,扩展其工业应用范围。

参考文献

- [1] MELNYK R A, TUSHNYTSKYY R B. Detection of defects in printed circuit boards by clustering the etalon and defected samples[C]. 2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering. IEEE, 2020: 961-964.
- [2] ONSHAUNJIT J, SRINONCHAT J. Algorithmic scheme for concurrent detection and classification of printed circuit board defects [J]. Computers, Materials & Continua, 2022, 71(1): 355-367.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [4] REN SH Q, HE K M, GIRSHICK R, et al. Faster RCNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [5] YAN C H, ZHANG H, LI X L, et al. R-SSD: Refined single shot multibox detector for pedestrian detection[J]. Applied Intelligence, 2022, 52(9): 10430-10447.
- [6] LAW H, DENG J. CornerNet: Detecting objects as paired keypoints [J]. International Journal of Computer Vision, 2020, 128(3): 642-656.
- [7] ZHOU X, WANG D, KRHENBÜHL P. Objects as points [J]. ArXiv preprint arXiv:1904.07850, 2019.
- [8] 尹嘉超,吕耀文,索科,等. 基于 EfficientNetV2 的 PCB 缺陷检测算法 [J]. 计算机辅助设计与图形学学报, 2025, 37(7): 1260-1269.
- YIN J CH, LYU Y W, SUO K, et al. A PCB defect detection algorithm based on EfficientNetV2 [J]. Journal of Computer-Aided Design & Computer Graphics, 2025, 37(7): 1260-1269.
- [9] 龚陈博,南卓江,陶卫. 基于改进 Faster RCNN 的 PCB 表面缺陷检测研究 [J]. 自动化仪表, 2024, 45(7): 99-103.
- GONG CH B, NAN ZH J, TAO W. Research on PCB surface defect detection based on improved Faster RCNN [J]. Process Automation Instrumentation, 2024, 45(7): 99-103.
- [10] 陈锦妮,拜晓桦,李云红,等. 基于 PA-YOLOv5 的印制电路板缺陷检测 [J]. 红外技术, 2024, 46(6): 654-662.
- CHEN J N, BAI X H, LI Y H, et al. Printed circuit board defect detection based on PA-YOLOv5 [J]. Infrared Technology, 2024, 46(6): 654-662.
- [11] 张淑卿,孟昊,葛超. 改进 YOLOv8n 的轻量级 PCB 缺陷检测算法 [J]. 现代电子技术, 2024, 47(15): 115-121.
- ZHANG SH Q, MENG H, GE CH. A lightweight PCB defect detection algorithm with improved YOLOv8n [J]. Modern Electronics Technique, 2024, 47(15): 115-121.
- [12] 王健,肖迪,冯李航,等. 基于改进 YOLOv8s 的 PCB 小目标缺陷检测模型 [J]. 计算机工程与应用, 2025,

- 61(15):288-297.
- WANG J, XIAO D, FENG L H, et al. A PCB small target defect detection model based on improved YOLOv8s[J]. Computer Engineering and Applications, 2025, 61(15): 288-297.
- [13] 吕秀丽,杨昕升,曹志民.改进 YOLOv8 的 PCB 表面缺陷检测算法[J]. 电子测量技术, 2024, 47(12): 100-108.
- LVU X L, YANG X SH, CAO ZH M. A PCB surface defect detection algorithm based on improved YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(12): 100-108.
- [14] 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. IEEE, 2017: 936-944.
- [15] MIRZAEI B, NEZAMABADI-POUR H, RAOOF A, et al. Small object detection and tracking: A comprehensive review[J]. Sensors, 2023, 23(15): 5120-5158.
- [16] XU S, ZHENG S C, XU W, et al. HCF-Net: hierarchical context fusion network for infrared small object detection [C]. 2024 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2024: 1-6.
- [17] OUYANG D, HE S, ZHAN J, et al. Efficient multi-scale attention module with cross-spatial learning [J]. ArXiv preprint arXiv:2305.13563,2023.
- [18] WANG J, XU C, YANG W, et al. A normalized Gaussian Wasserstein distance for tiny object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 45(1): 630-643.
- [19] 苏怡萱,李智,盘书宝,等.一种基于改进 YOLOv8 神经网络的输电线路绝缘子设备及其缺陷检测方法: CN202410721188. 2[P]. 2024-08-16.
- SU Y X, LI ZH, PAN SH B, et al. A defect detection method for transmission line insulator equipment based on improved YOLOv8 neural network: CN202410721188. 2[P]. 2024-08-16.
- [20] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [21] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574-8586.
- [22] LIU J, SHEN D, WU Z, et al. Patch-aware deep hyperspectral and multispectral image fusion by unfolding subspace-based optimization model[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 1024-1038.
- [23] 张莹,邓华宣,王耀南,等.基于多通道特征融合学习的印制电路板小目标缺陷检测 [J]. 仪器仪表学报, 2024,45(5):189-198.
- ZHANG Y, DENG H X, WANG Y N, et al. Small target defect detection of printed circuit boards based on multi-channel feature fusion learning [J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 189-198.
- [24] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 11534-11542.
- [25] SMITH J. SiO loss: More powerful learning for bounding box regression [J]. Journal of Machine Learning Research, 2024, 25(3): 123-145.
- [26] 姜源,付波,权轶,等.基于改进 YOLOv8n 的 PCB 缺陷检测算法 [J]. 国外电子测量技术,2024,43(6): 22-32.
- JIANG Y, FU B, QUAN Y, et al. A PCB defect detection algorithm based on improved YOLOv8n [J]. Foreign Electronic Measurement Technology, 2024, 43(6): 22-32.
- [27] YANG J, LIU J, DU W, ZHANG S. A PCB defect detector based on coordinate feature refinement [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-10.
- [28] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.

作者简介



王彩霞(通信作者),2000年于长春光机学院获学士学位,2003年于长春理工大学获硕士学位,2009年于长春理工大学获博士学位,现为长春理工大学副教授,主要研究方向为光电检测、机器视觉与嵌入式图像处理等。

E-mail: wxhao@sina.com

Wang Caixia (Corresponding author) received her B. Sc. degree from Changchun Institute of Optics and Mechanics in


2000, M. Sc. degree from Changchun University of Science and Technology in 2003, and Ph. D. degree from Changchun University of Science and Technology in 2009. She is now an associate professor at Changchun University of Science and Technology. Her main research interests include photoelectric detection, machine vision, and embedded image processing.



郭鑫鹏, 2023 年于天津中德应用技术大学获学士学位, 现为长春理工大学硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: 2961282577@qq.com

Guo Xinpeng received his B. Sc. degree from Tianjin Sino-German University of Applied Sciences in 2023. He is now a M. Sc. candidate at Changchun University of Science and Technology. His main research interests include deep learning and object detection.



刘鹏, 2005 年于中北大学获学士学位, 2008 年于长春理工大学获硕士学位, 2015 年于长春理工大学获博士学位, 现为长春理工大学副研究员, 主要研究方向为军用光电装备测试技术、光电检测与智能信息处理、视频图像处理等。

E-mail: louis585760@126.com

Liu Peng received his B. Sc. degree from North University of China in 2005, M. Sc. degree from Changchun University of Science and Technology in 2008, and Ph. D. degree from Changchun University of Science and Technology in 2015. He is now an associate researcher at Changchun University of Science and Technology. His main research interests include military optoelectronic equipment testing technology, photoelectric detection and intelligent information processing, and video image processing.