

基于改进YOLOv8n的轻量化PCB板表面缺陷检测算法

朱泽宇, 肖满生, 徐 萌, 王瑶瑶, 颜 谨

(湖南工业大学 计算机学院, 湖南 株洲 412007)

摘要: 针对目前PCB板缺陷检测算法存在的检测精度低、计算量大等问题,提出了一种改进YOLOv8n的PCB板表面缺陷检测算法。首先,将主干部分网络替换为MobileNetV3网络,以降低模型参数量,提升检测速度与精度;其次,设计了CA_C2f模块用来替换原C2f模块,以提升网络提取特征能力并提高模型对小目标的检测能力;最后,提出了DFL和改进Focal-EIoU的组合,以优化对损失函数中边界框回归的计算。实验结果表明,改进的YOLOv8n算法在PCB板缺陷数据集上得到的实验结果,较原YOLOv8n算法在精确度、mAP、计算量和参数量上都有显著优化,其中mAP达到96.6%。

关键词: PCB板;表面缺陷检测;模型轻量化;YOLOv8n;MobileNet;注意力机制

DOI: 10.11907/rjtk.241817

开放科学(资源服务)标识码(OSID):

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)004-0069-06



Lightweight PCB Surface Defect Detection Algorithm Based on Improved YOLOv8n

ZHU Zeyu, XIAO Mansheng, XU Meng, WANG Yaoyao, YAN Jin

(College of Computer Science, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: A modified YOLOv8n algorithm was proposed to address the low detection accuracy and high computational cost in PCB surface defect detection. The backbone network was replaced with MobileNetV3 to reduce the number of model parameters and improve detection speed and accuracy. A CA_C2f module was designed to replace the original C2f module, enhancing feature extraction and small object detection. The combination of DFL and an improved Focal-EIoU was introduced to optimize the bounding box regression in the loss function. Experimental results showed that the improved YOLOv8n achieved better accuracy, mAP, computational cost, and parameter count compared to the original YOLOv8n on the PCB defect dataset, with a mAP of 96.6%.

Key Words: PCB boards; surface defect detection; model lightweight; YOLOv8n; MobileNet; attention mechanism

0 引言

印制电路板(Printed Circuit Board, PCB)是电子工业的重要部件之一,随着技术的快速发展,其轻量化、高密集化和高集成化趋势明显,质量控制难度也随之增加。PCB板上若出现空洞、断路、蚀刻不足、缺损、凸起、短路、余铜、蚀刻过度等任何问题,都可能导致电路板不稳定,甚至损坏

整个电路板^[1-2]。因此,为确保电子产品可靠性,对PCB板缺陷检测非常重要。

早期,大部分公司依赖传统的人工检测判断PCB板是否存在缺陷。但这种方法效率低、依赖工人经验且准确性不稳定,难以适应大规模生产。为解决这一问题,业界开始探索自动化检测方法,如功能测试法和自动光学检测法(AOI)。功能测试法通过专用设备评估电路板性能并识别潜在缺陷,尽管其可靠性和准确性值得称赞,但需要专门

收稿日期: 2024-10-28

扫描二维码阅读全文:



基金项目: 湖南省自然科学基金项目(2022JJ50077);湖南省教育厅科学研究项目(21A0607, 22C1027)

作者简介: 朱泽宇(1996-),男,CCF会员,湖南工业大学计算机学院硕士研究生,研究方向为机器视觉;肖满生(1968-),男,湖南工业大学计算机学院教授、硕士生导师,研究方向为智能计算和智能信息处理。本文通讯作者: 肖满生。

设计的测试流程和复杂的测试程序,过程费力且耗时^[3]。自动光学检测法利用机器视觉对比PCB板测试图像与原始样品图像以识别缺陷。尽管该方法准确性高,但测试时产品是否精确对准,以及检测设备的分辨率和色标差异都会影响检测精度^[4]。

近年来,深度学习算法迅速发展,并在各领域得到广泛应用。在PCB缺陷检测领域,有不少研究对基于深度学习的缺陷检测模型进行改进,得到了更好的检测效果。卞佰成等^[5]针对现有模型检测精度低的问题,在YOLOv3模型基础上,通过将主干网络替换为DarkNet53网络,在颈部引入FPN结构,并额外增加了2个检测头,使检测精度得到了提升;廖鑫婷等^[6]针对PCB表面缺陷尺寸微小的问题,在YOLOv5模型基础上,在颈部引入特征融合模块,提升了微小缺陷特征信息流通效率,并在模型中引入SE-SiLU注意力机制模块,提升了对微小缺陷的检测精度。胡欣等^[7]针对实际生产过程中易产生误检、漏检等问题,通过引入多分支注意力模块(MBAM)的方法以改进YOLOv5模型,该方法从3个不同的维度对特征图进行分析,对缺陷区域给予更多注意力,提升了检测准确性。陈锦妮等^[8]针对PCB板裸板布局复杂、表面缺陷多样等问题,提出一种融合了混合注意力机制与自适应双向特征融合模块的PA-YOLOv5检测模型,该模型能够抑制一般特征的干扰,提高特征提取能力。王艳等^[9]提出一种YOLOv8-PCB缺陷检测模型,该模型通过改进损失函数和检测头,提升了模型对缺陷的检测能力。尽管上述模型在检测精度上取得了一定进展,但在实际工业生产中,终端设备的计算能力有限,模型参数量过大不仅影响其部署,还会显著降低检测速度。精度提升往往伴随着计算开销的增加,导致模型难以同时兼顾检测精度与速度,无法满足生产环境中对高效检测的需求,这些因素限制了这些模型在PCB缺陷检测中的广泛应用。为解决上述问题,本文设计了一种改进YOLOv8n模型,具体改进体现在以下3个方面:①针对模型参数量过大而影响部署的问题,将主干网络替换为轻量级的MobileNetV3网络,在降低模型参数数量的同时提高了模型检测速度与精度;②为使模型在保持轻量化的基础上提高特征提取能力,对C2f模块进行改进,得到的C2f_CA模块能够提升对PCB板缺陷特征的关注度,提高模型对小目标的检测能力;③为进一步提高模型性能,改进了损失函数,使用改进的Focal-EIoU以优化对损失函数中边界框回归的计算,提高模型对PCB板缺陷目标进行定位的性能。

1 YOLOv8n算法模型

YOLOv8算法模型是Ultralytics公司在开发YOLOv5后的又一新版本^[10]。YOLOv8所使用的网络结构与YOLOv5相似,主要由输入(Input)、主干(Backbone)、颈部(Neck)和

头部(Head)构成。YOLOv8算法模型有5个版本,分别为YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l和YOLOv8x,模型体积依次增大。考虑到终端设备计算能力有限,本文采用了YOLOv8n模型进行改进。

主干采用Darknet-53网络,通过卷积操作,C2f模块及特征融合模块SPPF对输入图像进行特征提取^[11]。颈部采用PANet结构进行路径聚合,通过上采样和下采样操作,将多层次的特征进行融合。头部采用了目前主流的解耦头结构(Decoupled-Head),这种结构中每个尺度都有独立的检测器,意味着YOLOv8对不同尺度的目标都有良好检测效果^[12]。头部会基于特征图进行分类和边界框回归,进而生成最终检测结果。

2 改进的YOLOv8n算法模型

本文对原有YOLOv8n模型的网络结构进行了改进,使模型更加轻量化的同时,尽可能提升对PCB缺陷的检测精度。改进后的模型网络结构如图1所示。




Fig. 1 Improved YOLOv8n network structure

图1 改进YOLOv8n网络结构

2.1 轻量化主干网络

考虑到PCB板缺陷检测领域所使用的终端检测设备计算能力受限,本文采用MobileNet系列的MobileNetV3作为主干网络,MobileNet系列网络是由Google为手机和其他嵌入式设备提出的一种轻量级的深层神经网络。与传统的卷积神经网络相比,MobileNet在略牺牲准确率的前提下,显著减少了模型参数量和计算量^[13]。这一成就主要得益于MobileNet所采用的深度可分离卷积(Depthwise Separable Convolution)思想^[14]。这种思想将传统的卷积分解为两个步骤,首先对输入的每个通道分别进行卷积操作并输出特征图,然后对卷积输出的特征图进行1×1的卷积操作,以融合信息并调整输出通道的数量,从而大幅降低了模型复杂度。

MobileNetV3是在前两个版本MobileNetV1和MobileNetV2的基础上,引入了SE(Squeeze-and-Excite)注意力机制模块,使模型更聚焦于重要特征^[15]。同时,设计了

Hard-sigmoid 和 Hard-swish 作为新的激活函数,以提高计算效率和模型性能。MobileNetV3分为 Small 和 Large 两个版本,本文选用计算能力要求更低的 MobileNetV3-Small 版本,其网络结构如图2所示。




Fig. 2 MobileNetV3-Small structure

图2 MobileNetV3-Small 结构

2.2 改进 C2f 模块

传统的 C2f 模块中,由于特征图之间的信息交流相对有限,可能导致识别精度不足。为了使模型在保持轻量化的同时,达到更高的检测精度,本文将 CA 注意力机制融入 C2f 模块中。CA (CoordAttention) 注意力机制是由 Hou 等^[16]提出的一种轻量化的注意力机制,其不仅能捕捉输入通道的特征信息,还同时考虑了每个像素的位置信息。C2f_CA 模块结构如图3所示。




Fig. 3 The block structure of C2f_CA

图3 C2f_CA 模块结构

首先对特征图在 X 和 Y 方向上分别进行平均池化,得到两个池化结果,并在第三维度上将池化结果进行拼接。拼接得到的结果经过通道卷积、标准化和激活等一系列操作后被分割。分割后的部分各自独立进行通道卷积和激活操作,各部分结果与原始输入特征图相乘生成得到最终输出,如图4所示。




Fig. 4 CA attention mechanism

图4 CA 注意力机制

2.3 改进损失函数

由于PCB板缺陷较小,且形状差异、识别难度大,因而对模型检测精度要求高,损失函数对模型性能影响很大,故选择合适的损失函数非常重要。YOLOv8使用 DFL 和 CIoU^[17]组合以计算边界框的回归损失,然而 CIoU 的公式

计算涉及反三角函数,会导致模型计算量增大。并且,CIoU 使用纵横比作为损失函数的惩罚因子,但如果真实框和预测框的纵横比相同,而宽度和高度的值不同,惩罚因子就无法准确反映两者之间的实际差异。此外,CIoU 并未考虑难易样本之间的平衡问题,可能导致模型在预测简单样本时表现良好,但在面对复杂或难以区分的样本时表现不佳。CIoU 的计算公式如式(1)所示。

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{(h^c)^2 + (w^c)^2} + \frac{v^2}{(1 - IoU) + v} \quad (1)$$

其中, v 是纵横比相似性因子,通过真实框和预测框纵横比的反正切值之差评估框之间的相似性,计算公式如式(2)所示。

$$v = \frac{4}{\pi^2} (\tan^{-1} \frac{w^{gt}}{h^{gt}} - \tan^{-1} \frac{w}{h})^2 \quad (2)$$

式(1)和式(2)中, b 和 b^{gt} 分别为预测框与真实框的中心坐标, $\rho^2(b, b^{gt})$ 为两中心点直线距离, $1 - IoU$ 是预测框与真实框交并比,用来衡量两者的重叠程度, h^c 和 w^c 为包含预测框和真实框最小边界框的高和宽, w, w^{gt}, h, h^{gt} 分别为预测框和真实框的宽度和高度,如图5所示。




Fig. 5 Schematic diagram of IoU parameters

图5 IoU 参数示意图

为避免 CIoU 的问题,本文设计了 DFL 和改进 Focal-ElIoU 组合计算损失的方法, Focal-ElIoU 明确测量了边界框中3个几何因素的差异,即重叠面积、中心点和边长。在多个目标检测数据集和模型上, Focal-ElIoU 损失优于现有基于 IoU 的损失,并为小型数据集和嘈杂的边界框提供了更高的鲁棒性^[18]。Focal-ElIoU 的计算公式如式(3)所示。

$$L_{ElIoU} = L_{dis} + L_{asp} = 1 - IoU + \frac{d^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} + \frac{d^2(w, w^{gt})}{(w^c)^2} + \frac{d^2(h, h^{gt})}{(h^c)^2} \quad (3)$$

$$L_{Focal-ElIoU} = IoU^\gamma L_{ElIoU} \quad (4)$$

其中, $d^2(b, b^{gt})$ 是预测框和真实框的中心点间距,反映模型预测准确性, $d^2(w, w^{gt})$ 和 $d^2(h, h^{gt})$ 分别是预测框与真实框的宽度比和高度比的平方差,使模型在宽和高上都有较高的重合度, h^c 和 w^c 为包含预测框和真实框的最小边界框的高和宽, IoU 是交并比,用来衡量预测框和真实框的重

叠程度, γ 是用于控制曲线曲率的超参数。

Focal Loss 的一个关键特性是它关注高质量的样本, 减少低质量样本对模型训练的影响。然而, 过度关注高质量样本可能导致模型忽视部分有价值的低质量样本。因此, 本文通过引入动态权重以平衡损失函数对高质量和低质量样本的关注, 以提高模型鲁棒性, 如式(5)所示。

$$L_{改进Focal-EIoU} = [\alpha(IoU^\gamma) + \beta] L_{EIou} \quad (5)$$

其中, α 是权重的调节因子, 取值范围为(0, 1]。初始值通常设为 0.5。当样本质量普遍较好时, 可以适当减小 α , 以避免模型过度关注表现优异的高质量样本, 而忽略可能存在的边缘情况。反之, 若样本质量较差, 则可以适当增大 α 以增强模型对高质量样本的关注。 β 是偏置项, 一般设为 0.1, 以确保低质量样本不会被完全忽略。

3 实验与结果分析

3.1 数据集准备

本文选择的 DeepPCB 数据集^[19]是一个在 PCB 板缺陷检测广泛使用的数据集, 数据集样本是通过线性扫描 CCD 收集, 共有 1 500 个样本, 数据集将缺陷分为最具代表性的 6 种类型: 开路(open)、短路(short)、鼠咬(mousebite)、杂散(spur)、杂铜(copper)和针孔(pin-hole)。当出现走线断裂或焊盘脱落等问题时会出现开路。当电路板上两个本应彼此绝缘的导体意外接触在一起会出现短路。鼠咬是指 PCB 板分板后沿边缘留下的一些小缺口。杂散和杂铜是指电路板上意外出现的导电材料, 可能影响电路的正常工作。针孔是在焊接过程中由于气体逸出而在焊点中形成的小孔。考虑到样本数据集较小, 本文采用了 Mosaic 数据增强方法, 通过随机读取 4 张图片, 分别进行翻转、缩放、色域变化等操作后, 将其拼接成一张新图, 保留原有的框信息, 从而丰富模型训练的数据样本^[20]。本文数据集按照 8:1:1 的比例划分为训练集、验证集和测试集, 以确保模型的训练、调优与评估具有良好的平衡性和泛化能力。

3.2 训练流程

在进行 PCB 板缺陷检测时, 首先, 对输入的数据集进行 Mosaic 数据增强, 以增加训练数据的多样性和鲁棒性; 其次, 将处理后的数据传入主干网络, 提取图像特征; 再次, 将提取到的图像特征在颈部网络中进行不同层次的融合处理, 从而提升目标检测性能; 接着, 预测头将处理这些特征图, 输出目标的类别概率、边界框坐标等信息, 损失函数会将预测头输出的信息与真实标签进行比较, 以优化模型参数; 最后, 输出包含目标类别和边界框的检测结果。算法流程如图 6 所示。

3.3 实验平台与参数

本文实验在 Windows11 操作系统下进行, 使用了 Python-3.8.17 和 Pytorch1.8.0 深度学习框架, 使用 Pycharm 作为开发环境, 使用 CUDA10.2 加速 GPU, CPU 为 Intel(R)




Fig. 6 Algorithm flow

图 6 算法流程

Core (TM) i5-9400F, GPU 为 NVIDIA GeForce GTX 1660 SUPER。实验所使用的参数如表 1 所示。

Table 1 Experimental parameter settings

表 1 实验参数设置

输入图片大小	批大小	迭代次数	学习率	动量值	权重衰减	优化器
640×640	16	200	0.001	0.937	0.000 5	AdamW

3.4 实验评价指标

实验中使用以下 5 个指标对算法进行评估: ①反映计算复杂度的浮点运算次数 (GFLOPs), 表示模型计算资源需求; ②平均精度均值 (mAP), 衡量模型在所有类别上的总体检测性能; ③召回率 (Recall, R), 反映所有实际正样本中被成功检测到的比例; ④准确率 (Precision, P), 表示检测到的正样本中实际为正样本的比例; ⑤参数量 (Params), 表示模型中可训练参数的数量, 反映算法的内存占用大小。

3.5 消融实验

为了验证各改进模块在该模型中的有效性, 本文进行了消融实验, 具体结果如表 2 所示。首先, 以 YOLOv8n 作为基线模型, 实验一仅融合 MobileNetV3 模块, 尽管 P 和 mAP 分别下降了 1.6% 和 0.8%, 但 GFLOPs 显著降低了 40.7% (由 8.1 降至 4.8), 表明 MobileNetV3 在减少计算量方面表现出色。实验二仅融合 Focal-EIoU 模块, P 和 mAP 分别提升了 3.0% 和 1.4%, 表明损失函数的优化效果明显。实验三引入 C2F_CA 模块后, P、R 和 mAP 分别提升了 3.5%、3.4% 和 2.4%, 充分证明了 C2F_CA 模块在提升模型性能方面的显著效果。实验四结合了 MobileNetV3、Focal-EIoU 和 C2F_CA 3 个模块, 与基线模型相比, P、R 和 mAP 分别提升了 0.9%、0.3% 和 1.1%, 同时 GFLOPs 大幅减少了 39.5% (由 8.1 降至 4.9)。该结果表明, 多模块协同优化在保持高精度的同时, 极大降低了计算复杂度, 验证了整体改进方案的有效性。

Table 2 Results of ablation experiments

表 2 消融实验结果

基线模型	MobileNetV3	Focal-EIoU	C2F_CA	P	R	mAP	GFLOPs
YOLOv8n	×	×	×	0.94	0.906	0.956	8.1
实验一	√	×	×	0.925	0.899	0.948	4.8
实验二	×	√	×	0.968	0.921	0.970	8.1
实验三	×	×	√	0.973	0.937	0.979	8.2
实验四	√	√	√	0.948	0.909	0.966	4.9

PR 曲线反映了精确率与召回率之间的关系, 曲线越接近右上角, 算法性能越佳。优化前后的 P-R 结果对比如图 7 所示, 可以看出, 改进后的算法在检测 PCB 板各类缺陷时表现出良好效果, 且检测效果优于原 YOLOv8n 算法。




Fig. 7 Comparison of P-R results before and after optimization
图 7 优化前后的 P-R 结果对比

3.6 对比实验

为了证明本文改进 YOLOv8n 算法对电路板缺陷检测效果的优势,将其与 YOLOv5n^[21]、SSD-ResNet50、YOLOv7-tiny^[22]、YOLOv8-PCB 及 YOLOv8n 在相同的 PCB 缺陷数据集上进行实验,实验结果如表 3 所示。

Table 3 Comparative experimental results of different models					
表 3 不同模型对比实验结果					
实验	P	R	mAP	GFLOPs	Params/M
YOLOv5n	0.919	0.924	0.947	4.5	1.9
SSD-ResNet50	0.914	0.898	0.926	35	23.6
YOLOv7-tiny	0.917	0.894	0.937	13.2	6.2
YOLOv8-PCB	0.956	0.928	0.972	11.7	2.6
YOLOv8n	0.94	0.906	0.956	8.1	3.1
改进 YOLOv8n	0.948	0.909	0.966	4.9	1.7

与 YOLOv5n、SSD-ResNet50、YOLOv7-tiny、YOLOv8-PCB 及 YOLOv8n 相比,改进后的 YOLOv8n 在网络性能的各方面都有显著增强。表 5 中的数据展示了各算法的检测性能和模型复杂度。在对比实验中,YOLOv5n 模型的浮点计算量和参数量很小,但检测准确度仅有 0.919;SSD-ResNet50 模型和 YOLOv7-tiny 模型复杂度高,而实验得到

的结果较差,表明这两者不适合针对 PCB 进行检测;YOLOv8-PCB 模型检测效果与 YOLOv8n 模型以及前 3 组相比,在检测精度上有很大优势,但参数量和计算量上仍具有提升空间。综合以上各项指标,改进 YOLOv8n 不仅在精度和召回率上取得了不错的性能,而且在计算效率和模型规模上也表现优异,证明了其在电路板缺陷检测中的出色性能。各模型对 PCB 板缺陷检测效果如图 8 所示。




Fig. 8 Comparison of PCB defect detection effect
图 8 PCB 板缺陷检测效果比较

4 结语

本文针对 PCB 板表面缺陷检测任务,提出了一种基于 YOLOv8n 的轻量化检测模型,通过引入 MobileNetV3 作为主干网络,显著减少了模型参数量,并提高了检测速度。此外,融合 CA 注意力机制的 C2f_CA 模块进一步增强了对缺陷特征的捕捉能力。最后,通过改进 Focal-EIoU 以优化损失函数,提升了模型在复杂缺陷检测场景下的精度。在 PCB 缺陷数据集上的实验结果显示,改进后的模型在轻量化和准确性方面均优于原 YOLOv8n 模型,尤其是在计算量上显著降低了 40.7%,对比其它检测模型也有明显优势。然而,模型在处理形态复杂的缺陷时仍存在一定的误检现象。后续将探索结合其他轻量化网络结构,以进一步提升检测性能。

参考文献:

- [1] XU Y Q, XIAO J Q, WANG Y C, et al. A comprehensive review of PCB surface defect detection based on machine vision[J/OL]. Microelectronics and Computer, 2024-08-04. <http://kns.cnki.net/kcms/detail/61.1123.TN.20240514.1043.004.html>.
徐一奇, 肖金球, 汪俞成, 等. 基于机器视觉的PCB表面缺陷检测研究综述[J/OL]. 微电子学与计算机, 2024-08-04. <http://kns.cnki.net/kcms/detail/61.1123.TN.20240514.1043.004.html>.
- [2] CAI X P. Research on PCB defect detection based on deep learning[J]. Yangtze Information Communication, 2023, 36(10): 38-42, 47.
蔡贤鹏. 基于深度学习的印刷电路板缺陷检测研究[J]. 长江信息通信, 2023, 36(10): 38-42, 47.
- [3] CHEN X, WU Y, HE X, et al. A comprehensive review of deep learning-based PCB defect detection[J]. IEEE Access, 2023, 11: 139017-139038.
- [4] CHEN I C, HWANG R C, HUANG H C. PCB defect detection based on deep learning algorithm[J]. Processes, 2023, 11(3): 775.
- [5] BIAN B C, CHEN T, WU R J, et al. PCB defect detection algorithm based on improved YOLOv3[J]. Journal of Zhejiang University (Engineering Edition), 2023, 57(4): 735-743.
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.
- [6] LIAO X T, ZHANG J, LYU S P. PCB defect detection method integrating shallow features and attention mechanism[J]. Computer Integrated Manufacturing Systems, 2024, 30(3): 1092-1104.
廖鑫婷, 张洁, 吕盛坪. 融合浅层特征和注意力机制的PCB缺陷检测方法[J]. 计算机集成制造系统, 2024, 30(3): 1092-1104.
- [7] HU X, HU S, MA L J, et al. PCB defect detection method based on the fusion of MBAM and YOLOv5[J]. Journal of Graphics, 2024, 45(1): 47-55.
胡欣, 胡帅, 马丽军, 等. 基于融合MBAM与YOLOv5的PCB缺陷检测方法[J]. 图学报, 2024, 45(1): 47-55.
- [8] CHEN J N, BAI X H, LI Y H, et al. PCB defect detection based on PA-YOLO v5[J]. Infrared Technology, 2024, 46(6): 654-662.
陈锦妮, 拜晓桦, 李云红, 等. 基于PA-YOLO v5的印制电路板缺陷检测[J]. 红外技术, 2024, 46(6): 654-662.
- [9] WANG Y, LUO J, TAO J, et al. Defect detection of printed circuit boards based on YOLOv8-PCB[J/OL]. Advances in Laser and Optoelectronics, 2024-10-12. <http://kns.cnki.net/kcms/detail/31.1690.TN.20240624.2254.060.html>.
王艳, 罗健, 陶金, 等. 基于YOLOv8-PCB的印制电路板缺陷检测[J/OL]. 激光与光电子学进展, 2024-10-12. <http://kns.cnki.net/kcms/detail/31.1690.TN.20240624.2254.060.html>.
- [10] JTEREVN J, CORDOVA-ESPARZA D M, ROMERO-GONZALEZ J A, et al. A comprehensive review of yolo architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS[J]. Machine Learning and Knowledge Extraction, 2023, 5(4): 1680-1716.
- [11] REDMON J. YOLOv3: an incremental improvement[DB/OL]. <https://arxiv.org/abs/1804.02767>, 2018.
- [12] GE Z. YOLOx: exceeding yolo series in 2021[DB/OL]. <https://arxiv.org/abs/2107.08430>, 2021.
- [13] GUO D L, ZHANG Y J. Image detection of coal gangue based on lightweight PAM-M-YOLO model[J]. Mining Research and Development, 2024, 44(5): 220-227.
郭栋梁, 张延军. 基于轻量化PAM-M-YOLO模型的煤矸石图像检测[J]. 矿业研究与开发, 2024, 44(5): 220-227.
- [14] LAURENT S, STÉPHANE M. Rigid-motion scattering for image classification[DB/OL]. <https://arxiv.org/abs/1403.1687>, 2014.
- [15] 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.
- [16] HOU Q, ZHOU D C, FENG J S. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [17] 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: 12993-13000.
- [18] ZHANG Y F, ZHANG Z, JIA Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-57.
- [19] TANG S, HE F, HUANG X, et al. Online PCB defect detector on a new PCB defect dataset[DB/OL]. <https://arxiv.org/abs/1902.06197>, 2019.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[DB/OL]. <https://arxiv.org/abs/2004.10934>, 2020.
- [21] HORVAT M, JELEČEVIĆ L, GLEDEC G, et al. A comparative study of YOLOv5 models performance for image localization and classification[C]//33rd Central European Conference on Information and Intelligent Systems (CECHS), 2022: 349-356.
- [22] WANG C Y, BOCHKOVSKIY A, LIAO H Y M, et al. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

(责任编辑: 孙 娟)