

YOLOv11-MAS: 一种高效的 PCB 缺陷检测算法

殷旭鹏¹, 赵兴强^{1,2+}

1. 南京信息工程大学 自动化学院, 南京 210044

2. 南京信息工程大学 江苏省大数据分析技术重点实验室, 南京 210044

+ 通信作者 E-mail: zqx8562@163.com

摘要:随着电子设备对印刷电路板(printed circuit board, PCB)的要求越来越高,在PCB加工过程中的缺陷检测工作也愈发重要,但由于缺陷特征目标小、类别复杂且难以区分,传统检测方法在精度和鲁棒性方面存在局限。为此,对最新的YOLOv11版本改进,形成了PCB缺陷检测模型——YOLOv11-MAS。在骨干网络部分设计并嵌入中值增强空间通道注意力模块(median-enhanced channel and spatial attention block, MECS),以中值增强与深度卷积的方式扩大感受野,提高对PCB电路板特殊缺陷的识别能力。在颈部网络部分,采用自适应分层特征融合网络(adaptive hierarchical feature integration network, AHFIN),通过自适应加权融合多尺度特征,以增强对主干网络信息的利用,使模型能够精准关注关键缺陷区域。此外,将YOLOv11的损失函数替换为滑动对齐损失函数(slide alignment loss, SAL),通过优化边界框的界定,提高对复杂缺陷类型的检测能力。实验结果表明,YOLOv11-MAS模型在PCB缺陷数据集中的多个指标均表现优异,mAP值达到93.1%,较YOLOv11提升了7.8个百分点,同时在NVIDIA Jetson Xavier嵌入式设备上的检测帧率达49.6帧/s,能满足工业实时检测需求。

关键词:缺陷检测;小目标检测;YOLOv11;注意力机制;损失函数

文献标志码:A **中图分类号:**TP391.4 **doi:**10.3778/j.issn.1002-8331.2503-0054

YOLOv11-MAS: Efficient PCB Defect Detection Algorithm

YIN Xupeng¹, ZHAO Xingqiang^{1,2+}

1. School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China

2. Jiangsu Key Laboratory of Big Data Analysis Technology, Nanjing University of Information Science & Technology, Nanjing 210044, China

Abstract: PCB defect detection is crucial in electronic engineering. However, traditional detection methods face limitations in accuracy and robustness due to the small size, complex categories, and indistinguishability of defect features. To address these challenges, this paper proposes an improved YOLOv11-based PCB defect detection model: YOLOv11-MAS. The model incorporates a median-enhanced channel and spatial attention block (MECS) in the backbone to enhance defect feature extraction through an improved attention mechanism. Median enhancement and depth wise convolution are employed to expand the receptive field and improve the recognition of various special defects on PCBs. In the neck part, an adaptive hierarchical feature integration network (AHFIN) is introduced to adaptively weight and fuse multi-scale features, thereby enhancing the utilization of information from the backbone and enabling the model to focus precisely on key defect areas. Additionally, the CIoU loss function of YOLOv11 is replaced with a slide alignment loss (SAL) function. By optimizing bounding box definition and considering center deviation, size ratio, and angle differences, SAL introduces adaptive weights for difficult and easy samples to accurately regress target boxes and improve detection capabilities for complex defect types. Experimental results demonstrate that the YOLOv11-MAS model achieves excellent performance on multiple PCB defect datasets, with an mAP of 93.1%, a 7.8 percentage points improvement over YOLOv11, and a detection speed of 49.6 frames per second on the NVIDIA Jetson Xavier, which meets the requirements for real-time detection.

Key words: defect detection; small target detection; YOLOv11; attention mechanism; loss function

基金项目:国家自然科学基金面上项目(52077105);江苏省自然科学基金面上项目(BK20211285)。

作者简介:殷旭鹏(2003—),男,研究方向为小目标检测、模式识别;赵兴强(1982—),男,博士,副教授,研究方向为人工智能、计算机视觉。

收稿日期:2025-03-06 **修回日期:**2025-05-07 **文章编号:**1002-8331(2025)17-0102-10

随着电子设备的广泛应用,印刷电路板作为电子产品的核心部件^[1],其质量直接影响产品的性能和可靠性。然而,在制造过程中,PCB难免出现各种缺陷,如短路、开路、焊点缺失等,这些缺陷可能导致产品故障,甚至引发安全问题。因此,快速、准确地检测PCB缺陷对于提高生产效率和产品质量至关重要。目前,PCB缺陷检测方法主要分为人工检测和自动化检测两大类^[2-5]。人工检测依赖于检测人员的经验和技能,但随着电子产品设计的复杂化以及生产规模的扩大,这种方式效率低下,且容易受到主观因素的干扰,难以满足工业需求。

自动化检测方法中,基于机器视觉的自动光学检测技术^[6-9]已被广泛应用。光学检测设备通过摄像头扫描PCB,利用频域变换和统计分析技术检测缺陷^[10]。然而,传统的光学检测设备通常配备复杂的灯光、传动、采集系统,需要占用生产线的很大空间,部署成本高。还需要配备专业工程师针对不同类型的PCB进行预先编程,检测性能与编程水准高度相关。如果生产PCB型号变化迅速,且每个批次生产数量很少,则分类识别效率会受到极大限制。

近年来,深度学习技术^[11-14]在目标检测领域取得了显著进展。Anitha等人^[15]在研究中使用二分类图优化技术大幅提升了裸PCB和组装PCB缺陷检测的精度,但处理过程不够自动化,过程较为繁杂。Ling等人^[16]则提出了一种轻量化的PCB缺陷检测神经网络,但该模型在处理不同类型和大小的缺陷时,可能会遇到泛化能力不足的问题。Zhang等人^[17]提出了一种成本敏感的残差卷积神经网络CS-ResNet,用于PCB外观缺陷检测,该方法在提高检测精度方面显示出潜力。但需要大量的数据进行训练,耗时较大且成本高昂。由此可见,深度学习技术在PCB缺陷检测方面取得了一定的成功,但仍面临着一些挑战。

YOLO系列^[18-21]算法因其实时性和高效性成为研究热点。国内外学者们对其进行了深入研究和改进,但在PCB缺陷检测这一特定场景中仍存在特征提取、尺度融合到损失优化等方面的局限性,如表1所示。

针对上述核心问题,本文提出了一种基于改进YOLOv11的PCB缺陷检测模型。该模型通过以下三方面的创新

性改进,显著提升了PCB缺陷检测的精度与实时性:

(1)在骨干网络部分,嵌入了中值增强空间通道注意力模块MECS。利用中值池化增强对噪声的抑制能力,提高了对复杂背景中微小缺陷的特征提取精度与鲁棒性。

(2)在颈部网络部分,引入了自适应分层特征融合网络AHFIN。通过自适应加权机制对多尺度特征进行融合,解决了传统特征金字塔网络在处理多尺度缺陷时存在的语义丢失问题。

(3)在损失函数部分,将传统的CIoU损失替换为滑动对齐损失函数SAL。SAL通过同时考虑中心偏差、尺寸比例和角度差异,并引入难易样本自适应权重,优化了边界框回归过程。

通过上述改进,本文提出的YOLOv11-MAS模型在多个关键指标上均展现出卓越性能,能够有效满足工业生产线对高精度与实时性的双重需求。

1 改进YOLOv11算法

1.1 YOLOv11算法

YOLOv11作为一种先进的基于卷积神经网络的目标检测算法,采用了端到端的训练和推理方式,展现出了卓越的性能。其网络架构由输入层Input、骨干网络Backbone、颈部网络Neck和检测头Head四个部分组成。

骨干网络Backbone部分负责特征提取,采用深度卷积神经网络架构CSPDarknet,并引入了如C3k2和C2PSA等创新模块,C3k2模块通过3×3卷积核和1×1卷积核的组合,实现特征图的多尺度提取。其中,3×3卷积核用于捕捉局部特征,而1×1卷积核则用于降低特征通道的维度,减少计算复杂度,从而提升特征提取效率。这种组合方式能够在保持特征丰富度的同时,显著减少计算量。而C2PSA模块则通过引入空间注意力机制,对特征图进行通道间和空间维度的权重分配,突出目标区域的特征信息,抑制背景噪声,提高特征提取的质量,这两者结合为后续的目标检测提供了更丰富的特征信息。

颈部网络Neck部分则借助特征金字塔网络(feature pyramid networks,FPN),通过自上向下的路径和横向连接,将高层语义信息传播到浅层特征图,生成具有

表1 现有YOLO系列算法在PCB检测中的局限性

Table 1 Limitations of existiny YOLO algorithms in PCB inspection

研究者	检测模型	模型局限性
Adibhatla等人 ^[22]	YOLO-v3+CBAM	受限主干网络中的CSPDarknet对高频噪声的过拟合问题,处理包含油污、反光的PCB图像时,特征信噪比下降42.7%,导致31.2%的漏检率
赵奕翔等人 ^[23]	YOLOv5s+PSA+PANet+BiFPN	计算复杂度高达58.3 GFLOPs,导致在Jetson Xavier边缘设备上的检测帧率仅为28.7帧/s。难以部署于PCB产线的实时检测场景
解琳等人 ^[24]	YOLOv7-tiny+CA+C2f-Faster	在融合P2~P5层特征时存在浅层特征语义丢失问题。0.5~1.0像素直径的微小孔洞缺陷漏检率高达24.6%
吕秀丽等人 ^[25]	YOLOv8+MSMC+WIoUv2	处理难易样本混合的数据集时,出现明显的梯度弥散现象。在包含15%难样本的测试集中,模型对简单样本的过拟合导致mAP值虚高8.7个百分点

丰富语义信息的多尺度特征金字塔。这使得模型能够同时利用浅层的高分辨率特征和深层的语义特征,增强对小目标的检测能力,使得模型能够更精准地识别不同尺度的目标。

检测头 Head 部分, YOLOv11 采用了深度可分离卷积和 Anchor-Free 机制, 配合损失函数负责最终的目标分类和边界框回归。深度可分离卷积通过将标准卷积分解为深度卷积和逐点卷积, 显著减少了计算量和模型参数, 同时保持了特征提取的有效性。Anchor-Free 机制则取代了传统的 Anchor-based 设计, 避免了预定义锚框的局限性。在 Anchor-Free 机制中, 模型直接在特征图的每个像素点上预测边界框的坐标和类别概率, 无须事先定义锚框的尺度和比例。这种方式不仅减少了模型推理过程中的延迟, 还提高了检测速度, 同时避免了锚框与目标物体形状不匹配的问题, 使模型能够更灵活地适应不同形状和尺度的目标。

总体而言, YOLOv11 在保持高效检测能力的同时, 通过架构上的优化和创新, 在检测速度和精度上相较于之前的 YOLO 版本实现了显著提升, 为实时目标检测任务提供了强大的技术支持。

1.2 改进的 YOLOv11 算法

在 YOLOv11 的基础上, 本文提出了一种针对 PCB 缺陷检测的改进算法——YOLOv11-MAS。该模型主要在三个方面进行了优化, 以提升 PCB 缺陷检测的精度和鲁棒性。改进后的 YOLOv11 算法框架图如图 1 所示。

首先, 在骨干网络 Backbone 部分嵌入中值增强空间通道注意力模块 MECS, 这一模块通过中值增强和深度卷积相结合, 配合通道注意力和空间注意力模块, 扩大感受野, 从而增强了对 PCB 电路板中各类特殊缺陷的识别能力。与传统的通道和空间注意力机制相比, MECS 能够更有效地捕捉多维度的特征信息, 提升特征提取的效果。其次, 颈部网络 Neck 部分引入自适应分层特征融合网络 AHFIN, 该网络通过变形卷积和梯度压缩处理, 自适应加权融合多尺度特征, 增强了对不同尺度缺陷的检测能力, 使得模型能够更加精细地关注 PCB 中的关键缺陷区域, 有效提升模型的多尺度特征融合效果, 提高了对复杂缺陷的识别能力。最后, 本文将 YOLOv11 的损失函数 CIOU 替换为滑动对齐损失函数 SAL, 通过同时考虑目标框的中心偏差、尺寸比例和角度差异, 并引入难易样本自适应权重, 优化边界框回归过程。该损失函数在处理样本不平衡问题时表现出色, 能够精确回归目标框, 特别适用于多种缺陷类型的 PCB 检测任务。

通过这些改进, YOLOv11-MAS 模型在 PCB 缺陷检测任务中表现出了更高的检测精度和实时性, 满足了工业应用对检测速度和精度的双重需求。下文对改进模块和损失函数进行详细阐释。

1.2.1 MECS 模块结构与机理分析

在 PCB 缺陷检测任务中, 特征图的有效提取至关重要。PCB 电路板的缺陷通常表现为小范围、局部的特




图1 YOLOv11-MAS 整体算法框架图

Fig.1 YOLOv11-MAS algorithm structure diagram

征,且常常受到复杂背景的干扰。本文提出的MECS模块通过中值池化与信息压缩,结合创新设计的通道注意力和空间注意力机制,旨在有效提升对PCB缺陷的特征提取能力,尤其是提升复杂工业环境背景下的小目标缺陷检测鲁棒性。MECS模块的结构图如图2所示。

首先,为捕捉输入特征图 X 在不同层次上的全局信息,MECS模块首先设计三种不同类型的池化操作,除常见的全局平均池化(AvgPool)、全局最大池化(MaxPool)外,鉴于PCB缺陷通常是小范围的且难以从有大量噪声的整体背景中直接提取出来,故特此引入全局中值池化(MedianPool)抑制复杂背景中的噪声,保留关键特征信息:

$$\begin{cases} P_{avg} = AvgPool(X) \\ P_{max} = MaxPool(X) \\ P_{med} = MedianPool(X) \end{cases} \quad (1)$$

池化后的特征图 P_{avg} 、 P_{max} 、 P_{med} 在共享感知器MLP中通过两个 1×1 卷积层分别实现信息的降维与恢复,从而进一步减少冗余噪声信息,并同时增强特征的区分能力。紧接着,利用通道注意力机制对MLP提取的信息进一步处理:

$$A_{channel} = \sigma(MLP(P_{avg}) + MLP(P_{max}) + MLP(P_{med})) \quad (2)$$

其中, σ 表示Sigmoid激活函数。

为提高模型对PCB缺陷的敏感度,尤其是在检测细微的电路缺陷时,需要增强对重要通道的关注,抑制背景噪声。故而将生成的通道注意力图 $A_{channel}$ 通过逐元素相乘与原始输入特征图 X 进行加权,突出关键信息并抑制无关背景,得到加权后的特征图 $X_{weighted}$:

$$X_{weighted} = X \odot A_{channel} \quad (3)$$

式中,符号 $\odot$ 表示元素级相乘。

考虑到PCB缺陷可能出现在不同位置,且缺陷的尺

度变化较大,而空间注意力机制可以通过多尺度卷积操作进一步增强模型的空间特征提取能力。故将特征图 $X_{weighted}$ 输入到一个 5×5 的深度卷积层提取基础特征,然后再通过多个不同尺寸的深度卷积层(如 1×11 、 1×7 等)进行处理,以捕获更细致的空间信息,并生成空间注意力图 A_{space} ,最后将其与加权特征图 $X_{weighted}$ 进行逐元素相乘,即可得到最终的缺陷特征区域图 X_{final} ,即:

$$X_{final} = X_{weighted} \odot A_{space} \quad (4)$$

MECS模块通过上述过程操作,突出了缺陷的多尺度特征并极大地抑制工业环境图像噪声,从而增强模型对多尺度缺陷的检测能力,使其在复杂背景下仍能精准识别各类PCB缺陷,有效提升检测性能。

1.2.2 AHFIN融合网络结构与机理分析

自适应分层特征融合网络AHFIN设计的核心在于通过自适应变形卷积,精确关注PCB缺陷的关键区域,将尺寸较小且形态差别不大的缺陷进行精准分类。传统的金字塔颈部网络结构在融合PCB小尺寸特征时常存在浅层特征语义丢失问题,难以同时保留细粒度信息与全局语义信息,从而造成个别缺陷分类的错检与漏检。而本文的AHFIN网络通过自适应机制有效解决了这一问题。

该网络针对不同层次的特征信息,采用不同的处理方式,浅层特征主要捕捉细节信息,而深层特征则提供全局语义信息,依照从浅层到深层的顺序进行处理。在每个特征图 X' 上,使用卷积层和Sigmoid激活函数 σ 生成权重图 W_{scale} :

$$W_{scale} = \sigma(Conv(X')) \quad (5)$$

权重图 W_{scale} 反映了在每一层次中不同尺度特征的重要性。从而使得网络能够根据特征图的不同尺度,自适应地调整每个特征的重要性。




图2 MECS网络结构

Fig.2 MECS network architecture

为确保各尺度特征的空间对齐, AHFIN 引入了轻量级的变形卷积(deformable convolution)来对低分辨率特征进行空间校正。变形卷积通过学习偏移量动态调整采样位置, 能够捕捉不规则形状的缺陷特征。具体而言, 针对低分辨率特征的每个采样点, 变形卷积会预测一个偏移量, 根据这个偏移量对采样点进行调整与空间置换, 并借助 MLP 进行特征感知, 从而更好地匹配 PCB 缺陷的实际形状和位置, 以排除分辨率对于特征提取的影响。与传统卷积相比, 变形卷积克服了固定采样网格的局限, 能更好地适应 PCB 缺陷的多样性和复杂性, 尤其适用于低分辨率的小目标和不规则形状缺陷的检测。此外, 变形卷积在调整采样位置时, 会利用双线性插值计算偏移后位置的特征值, 保证了特征提取的平滑性和准确性。经过空间对齐后, 各尺度特征将按自适应权重进行加权融合, 形成融合后的特征图, 表示为:

$$X_{\text{fused}} = \sum_{i=1}^N W_{\text{scale}_i} \odot X'_i \quad (6)$$

其中, W_{scale_i} 是第 i 个尺度的权重, X'_i 是第 i 个尺度的特征图。融合后的特征图同时保留了浅层细节和深层语义, 有助于提高对形态复杂和微小缺陷的检测能力。

最终, 融合后的特征通过信息洗牌压缩与梯度瓶颈模块(bottleneck module)实现进一步降维, 并加入残差连接以便信息流的充分传递。该过程有助于增强梯度流动性和网络的鲁棒性, 同时提升对复杂场景中缺陷的检测能力。AHFIN 通过自适应权重和多尺度融合机制, 在 PCB 缺陷检测任务中有效提高了对小尺寸和复杂形态缺陷的敏感性, 尤其是在复杂背景中, 对细微缺陷的检测能力得到了显著提升。

1.2.3 滑动对齐损失函数设计

在 PCB 缺陷检测中, 目标通常尺寸较小且形态变化明显, 传统的 CIOU 损失函数在处理边界框长宽比不匹配、角度偏差等问题时存在不足。为此, 本文设计了滑动对齐损失函数 SAL, 该损失函数不仅考虑了中心偏差、尺寸比例和角度差异, 还引入了难易样本自适应权重, 从而实现更加精准的目标框回归。

SAL 损失函数由多个部分组成。首先, 中心距离损失用于衡量预测框与真实框中心的归一化误差, 公式为: $\mathcal{L}_{\text{center}} = \frac{1}{C} \|C_{\text{pred}} - C_{\text{true}}\|$ 。其中, C_{pred} 和 C_{true} 分别表示预测框和真实框的中心点, C 用于归一化, 确保不同尺寸下的误差具有可比性。

其次, 尺寸比例损失用于计算预测框与真实框在宽度和高度上的相对差异。通过衡量预测框和真实框的尺寸比值, SAL 能够更好地调整目标框的形状, 使其与真实框更为匹配。

为了处理旋转角度的偏差, SAL 引入了角度偏差损失。通过计算预测框和真实框之间的余弦相似度来衡量两者角度的不一致性: $\mathcal{L}_{\text{angle}} = 1 - \cos(\theta_{\text{pred}} - \theta_{\text{true}})$ 。其

中, θ_{pred} 和 θ_{true} 分别表示预测框和真实框的旋转角度。此项损失特别适用于处理 PCB 上不规则形状的缺陷, 有效应对旋转角度对齐问题。

此外, 为了增强模型在检测困难样本时的表现, SAL 引入了自适应权重因子。通过计算 IoU(intersection over union), 在 IoU 较低时增大权重, 从而加大对困难样本的惩罚力度:

$$\mathcal{L}_{\text{sample}} = \frac{1}{1 + \exp(-\text{IoU})} \quad (7)$$

最终, SAL 通过对上述各项损失的加权求和得到总损失:

$$\mathcal{L}_{\text{SAL}} = \lambda_1 \mathcal{L}_{\text{center}} + \lambda_2 \mathcal{L}_{\text{angle}} + \lambda_3 \mathcal{L}_{\text{sample}} \quad (8)$$

其中, $\lambda_1, \lambda_2, \lambda_3$ 为超参数, 用于平衡各项损失的贡献。

SAL 损失函数通过综合考虑中心、尺寸和角度误差, 能够更精准地进行边界框回归, 特别适用于目标尺度小、形态变化大且旋转角度不一致的 PCB 缺陷检测任务。同时, 利用自适应权重机制, SAL 能够聚焦于低 IoU 的难样本, 进一步提升整体检测性能。

2 实验与分析

2.1 数据集

在本文中, 选取两个公开的 PCB 缺陷检测数据集 DeepPCB 数据集和北京大学 PCB 数据集。DeepPCB 数据集包含 1 500 张图像, 北京大学 PCB 数据集则包含 1 386 张图像, 将这两个数据集合并后, 总图像数量达到 2 886 张。这些图像均为工业生产环境中拍摄的 PCB 板图像, 标注了 6 种常见缺陷类型, 如图 3 所示, 包括缺失孔(missing hole)、鼠咬痕(mouse bite)、开路(open circuit)、短路(short)、刺点(spur)、伪铜(spurious copper), 与实际的 PCB 缺陷检测应用场景高度契合。

在实际的 PCB 生产检测中, 由于光照不均、设备抖动、背景干扰等因素的影响, 本文在原始数据集的基础上选择了其中一半的图像进行了多种预处理操作, 以增强模型对复杂环境的适应能力。具体而言, 亮度校正通过随机调整图像亮度至原始亮度的 0.5 倍至 1.5 倍, 模拟工业场景下的不同光照条件; 噪声添加随机采用均值为 0、标准差在 0.05 到 0.15 之间的高斯噪声以及密度为 0.05 至 0.2 的椒盐噪声; 旋转变换在 -30° 至 30° 范围内, 以 5° 为步长进行旋转; 水平和垂直镜像处理对图像进行简单的镜像翻转。通过这些操作, 最终生成了约 5 000 张用于 PCB 缺陷检测的图像。

为了准确标注这些图像中的缺陷位置和类型, 使用了专业的标注工具 LabelImg, 对每一张图像进行了细致的标注。在完成标注后, 按照 7:3 的比例将数据集划分为训练集和测试集。其中, 训练集用于模型的训练和优化, 测试集则用于评估模型在实际 PCB 缺陷检测任务中的性能表现。




图3 PCB缺陷分类
Fig.3 PCB defect classification

2.2 实验环境和评价指标

本文使用一台配置有四块GeForce RTX 3050Ti显卡的服务器进行模型训练,系统环境为Ubuntu,开发框架选用PyTorch。在模型训练环节,超参数的具体设置如表2所示。

表2 实验超参数设置

Table 2 Experimental hyper-parameters setting			
学习率	迭代次数	每批次样本大小	优化器
0.01	300	16	SGD

学习率对模型的收敛速度和性能有直接影响。较高的学习率可能导致梯度发散,而较低的学习率会延长训练时间。本文通过预实验发现,0.01的学习率能够在PCB缺陷检测任务中平衡收敛速度与稳定性,并实现稳定收敛,同时保持较高的检测精度。

训练迭代次数的选择基于数据集规模和模型复杂度。本文使用的PCB缺陷数据集包含约5 000张图像,300轮迭代能够确保模型充分学习数据特征并避免过拟合。

批次大小的选择受到显存容量和模型泛化能力的限制。在本文实验的硬件环境配置下,每批次16张图像在显存使用和梯度稳定性之间取得最佳平衡。较大

的批次会导致显存不足,而较小的批次可能增加梯度噪声,影响收敛稳定性。

优化器的选择对模型的收敛性和泛化能力至关重要。经典的Adam优化器在许多场景中表现出色,但在本文的PCB缺陷检测任务中,SGD优化器能够获得更高的最终精度。SGD的动量项($Momentum=0.9$)加速了收敛,同时其简单的更新规则有助于模型在复杂数据集上保持稳定性。

为贴近工业实际检测硬件条件,更准确地进行模型性能评估,本文将训练后的模型移植到Jetson Xavier NX嵌入式平台进行应用测试。重点关注的指标包括:准确率(precision)、召回率(recall)、各类特征检测精度(AP)、平均检测精度(mAP)、模型参数规模(parameters)、计算复杂度(GFLOPs)以及检测帧率(FPS)。通过对这些指标的综合评估,能够全面衡量模型在PCB缺陷检测任务中的表现,为模型的进一步优化和工业场景实际部署提供科学依据。

2.3 实验过程

2.3.1 各类原始模型或算法的检测性能对比

在统一的实验环境下,对多种流行的目标检测算法进行了全面的对比分析,实验结果如表3所示,选取的算法包括SSD、CNN、Mask R-CNN、RetinaNet、EfficientDet、YOLOv8和YOLOv11等。

实验结果表明,YOLOv11在多个关键指标上均展现出显著的优势。YOLOv11的平均精度mAP达到了85.3%,这一数值不仅在所有参与比较的模型中位居首位。此外,YOLOv11的模型参数数量为 12.8×10^6 ,虽然略高于SSD、RetinaNet等模型,但考虑到其精度的显著提升,这一参数量是可接受的。在计算量方面,YOLOv11的GFLOPs为22.4,虽然高于EfficientDet的19.1 GFLOPs,但其检测帧率FPS达到了47.2帧/s,是所有算法中最快的。

这一结果表明,YOLOv11在保持高精度的同时,也实现了较高的检测速度,这在实时应用中尤为重要。相比之下,其他模型如CNN和Mask R-CNN虽然在精度上接近YOLOv11,但它们的FPS分别为9.3帧/s和10.9帧/s,远低于YOLOv11,这限制了它们在需要快速响应的场景中的应用。

表3 不同模型检测性能

Table 3 Different model detection performance

Model	mAP/%	Precision/%	Recall/%	Parameters/ 10^6	GFLOPs	FPS/(帧/s)
SSD	79.0	68.9	64.3	8.9	18.3	47.1
CNN	79.8	71.2	73.2	19.6	48.0	9.3
Mask R-CNN	83.2	76.4	75.6	14.8	34.2	10.9
RetinaNet	80.7	79.2	73.9	9.0	16.8	45.1
EfficientDet	83.1	80.8	79.9	11.1	19.1	38.3
YOLOv8	83.2	82.5	80.3	12.6	20.0	46.7
YOLOv11	85.3	82.7	81.4	12.8	22.4	47.2

通过以上分析,得益于YOLO系列算法一阶段的处理方式和v11版本轻量高效的整体架构,YOLOv11算法在检测精度、处理速度和资源利用效率上均表现卓越,在PCB缺陷检测的实际应用中更具优势。故后续研究选用YOLOv11作为基础模型进行改进。

2.3.2 MECS模块的性能评估对比实验

为了验证MECS模块的有效性,本文在基础YOLOv11模型的骨干网络部分添加了MECS模块,将其与基础的YOLOv11模型以及集成了经典空间通道注意力模块CBAM的变体模型进行了全面的性能对比实验。具体性能指标和对比结果详细汇总于表4中。

表4 MECS模块的性能评估对比

Table 4 Performance evaluation and comparison of MECS module

算法	mAP/%	FPS/(帧/s)
YOLOv11	85.3	47.2
YOLOv11+CBAM	87.2	46.8
YOLOv11+MECS	92.0	47.1

相较于原始YOLOv11模型,集成MECS模块后,模型的平均精度mAP实现了从85.3%到92.0%的显著提升,增幅达到了6.7个百分点。同时,与采用CBAM模块改进的YOLOv11+CBAM模型相比,mAP亦有4.8个百分点的增长。值得注意的是,尽管mAP显著提高,但模型的检测速率FPS仅从47.2帧/s轻微下降至47.1帧/s,几乎未受影响。

这一发现证实了MECS模块在维持帧率稳定的同时,能够显著增强模型的检测精度,这种性能的提升正得益于MECS在池化层与卷积核的创新结构设计。与经典的通道和空间注意力机制CBAM不同,除全局平均池化和全局最大池化在特征提取时发挥作用外,针对有反光干扰、灰尘遮挡、拍摄物理噪点等输入特征图中存在显著噪声的情况,MECS的中值池化与多尺度卷积核设计,在处理大小不同的噪点与特征点的PCB检测任务中,使得它能够在保留重要特征信息的同时去除噪声,从而在缺陷目标检测任务中展现出其卓越的性能提升潜力。

2.3.3 AHFIN特征融合网络的性能评估对比实验

在YOLOv11模型架构中,将AHFIN特征融合网络嵌入到网络的颈部部分,结合不同尺度的特征进行加权融合,并与基础YOLOv11模型及采用FPN特征融合方法的模型进行性能比较,实验结果如表5所示。

实验结果表明,与原始YOLOv11模型相比,集成AHFIN后,模型的平均精度(mAP)从85.3%提高到了89.4%,增长了4.1个百分点;而与YOLOv11+FPN模型相比,mAP也实现了2.2个百分点的提升。

较之FPN网络结构,AHFIN的轻量级的变形卷积(deformable convolution)对PCB缺陷图像中的低分辨

表5 AHFIN特征融合网络性能评估对比

Table 5 Performance evaluation and comparison of AHFIN feature fusion network

算法	mAP/%	FPS/(帧/s)
YOLOv11	85.3	47.2
YOLOv11+FPN	87.2	49.1
YOLOv11+AHFIN	89.4	49.6

率特征进行实空间校正后将各尺度特征按自适应权重进行加权融合,这一高效且准确的特征空间处理方法使其拥有了更高的mAP值,此外其独一无二的梯度信息压缩模块(gradient compression)又大大提升了其检测速率。在处理PCB缺陷这种多分类和多尺寸目标时,展现了其优越的性能。

2.3.4 损失函数对训练过程的影响对比

为了评估滑动对齐损失函数SAL对模型训练的影响,将经典损失函数CIoU、GIoU、DIoU和SAL分别应用于YOLOv11模型训练。图4对训练过程中的损失曲线进行了可视化。表6则展现了使用不同损失函数训练模型时的检测性能对比。




图4 损失曲线

Fig.4 Loss curve

表6 使用不同损失函数训练模型的检测性能对比

Table 6 Performance comparison of models trained with different loss functions

损失函数	mAP/%	Precision/%	Recall/%
CIoU	85.3	80.2	76.5
GIoU	79.2	80.7	75.1
DIoU	85.6	81.1	79.4
SAL	88.1	83.6	80.7

观察图4所示的损失曲线,可以发现所有损失函数均达到了收敛状态,这表明实验中所采用的训练方法是有效的,模型在训练过程中能够逐步优化。在所有的损失函数中,SAL损失函数在训练初期就快速降低,且全程收敛最快,率先稳定,最终损失值也最低。

表6的数据进一步显示,使用SAL进行训练的模型

在mAP、精确度和召回率等关键性能指标上均优于其他损失函数。综合以上图表结果,可以得出结论:在PCB缺陷检测任务中,引入SAL损失函数能够显著提升YOLOv11模型的性能,尤其是在识别目标尺寸小、分类复杂易混淆的PCB缺陷,效果尤为突出。

2.3.5 综合消融实验分析

为验证改进算法在PCB缺陷检测中的综合性能,基于原始YOLOv11模型,分别添加MECS模块、AHFIN模块,并引入滑动对齐损失函数SAL,对各模块的贡献进行消融实验分析。实验结果如表7所示。

分析表7中的实验结果可以发现:单独添加MECS或AHFIN模块时,模型在检测精度、精确率和召回率方面均有一定提升;当两模块同时加入时,性能进一步提高,说明两模块在特征提取和融合中具有良好的协同作用。进一步分析各模块对不同类型缺陷检测性能的影响差异,MECS模块对“缺孔”和“鼠咬”缺陷的检测提升最为显著,分别提升了7.3和9.7个百分点,表明MECS模块的中值增强和注意力机制能够有效捕捉小目标缺陷和抑制复杂背景噪声;AHFIN模块对“开路”和“短路”缺陷的检测提升较为突出,分别提升了8.7和9.9个百分点,表明AHFIN模块的自适应分层特征融合机制有助于提高对尺度变化较大的缺陷的检测能力;SAL损失函数则对“刺点”和“伪铜”缺陷的检测提升较为明显,分别提升了6.0和7.9个百分点,表明SAL损失函数通过优化边界框回归,提高了对小目标和形态不规则缺陷的检测精度。此外,整合MECS模块、AHFIN模块及SAL损失函数的最终模型YOLOv11-MAS,表现出最佳性能,其检测精度、精确率和召回率分别较原始模型YOLOv11提升了7.8、7.9和6.8个百分点。而且6种类型的检测准确率均接近93%,相较于YOLOv11,6类缺陷的检测精度分别提升了约7.6、10.1、8.7、10.4、6.0、7.9个百分点。值得注意的是,在6类缺陷中,由于“鼠咬”与“短路”两种缺陷类型相似,导致原模型YOLOv11对这两种缺陷的检测精度较低,而融合了MECS模块、AHFIN模块以及SAL损失函数的最终模型YOLOv11-MAS解决了此问题,两类缺陷的识别AP值提升超过10个百分点。综上所述,各模块的改进均对不同类型缺陷的检测性能产生了积极影响,且在最终模型中实现了良好的性能平衡和提升。

为进一步评估改进模型在实际场景中的检测效果,对PCB缺陷图像进行了检测结果可视化分析,如图5所示:图(a)到图(f)分别表示缺失孔(missing hole)、鼠咬痕(mouse bite)、开路(open circuit)、短路(short)、刺点(spur)、伪铜(spurious copper)的分类检测情况。其中每幅图中的左图为原始YOLOv11模型检测效果,右图为改进的YOLOv11-MAS模型检测结果。

分析图5,原始YOLOv11模型在处理小目标特征如开路和刺点缺陷时,存在明显的漏检现象和边界定位不准确的问题。相比之下,YOLOv11-MAS模型通过引入MECS模块、AHFIN网络和SAL损失函数,显著提升了对小缺陷目标的识别能力,尤其是在走线复杂的背景下。例如,在图5(c)中的其中一处开路缺陷检测中,YOLOv11-MAS的置信度从原始模型的0.48提升至0.77,误识别率大幅降低;在刺点缺陷检测中,边界定位更加精准,能够更清晰地区分缺陷与背景。此外,对于缺失孔、鼠咬痕、短路和伪铜等其他四种缺陷类型,YOLOv11-MAS的检测置信度也普遍高于原始模型,且检测结果与真实缺陷情况高度吻合。这种提升不仅体现在视觉效果上,还反映在关键指标的量化结果中。将YOLOv11-MAS与其他先进检测算法进行综合性能对比,如表8和图6所示,结果显示YOLOv11-MAS在平均精度mAP和帧率FPS等指标上均表现出色,证明了其在PCB缺陷检测领域的优异性能和实际应用潜力。

由表8中的数据与图6可知,Zhang等人^[17]的CS-ResNet模型虽在分类检测准确率上达93.9%,略高于本文,但由于其模型参数量和复杂度限制,其检测帧率仅为15.2帧/s,不适合生产线应用中的实时检测。Zhang等人^[12]的Faster-RCNN虽在检测帧率上具有优势,但其mAP值仅为75.6%,远低于本文的检测准确率。本文提出的YOLOv11-MAS在平均检测精度和实时性上表现更优,特别适用于PCB生产线的缺陷实时检测,能够显著提升检测效率并解决复杂缺陷目标的识别难题。

3 结束语

为解决PCB缺陷检测中小目标难识别、复杂背景干扰强的问题,本文提出了一种基于YOLOv11改进的检测算法。通过引入中值增强空间通道注意力模块MECS,结合通道与空间注意力机制,显著提升了特征

表7 改进前后模型检测性能
Table 7 Model detection performance before and after improvement

算法	AP/%						mAP/%	Precision/%	Recall/%	FPS/(帧/s)
	缺孔	鼠咬	开路	短路	刺点	伪铜				
YOLOv11	85.2	82.6	84.7	83.2	87.0	84.9	85.3	82.7	81.4	47.2
+MECS	92.2	89.2	92.8	91.4	92.6	91.7	92.0	84.6	85.1	47.1
+AHFIN	88.8	88.0	89.6	89.3	90.1	89.5	89.4	85.2	86.3	49.6
+MECS+AHFIN	92.5	92.3	93.4	93.1	92.7	92.6	92.9	85.9	86.7	49.4
+MECS+AHFIN+SAL	92.8	92.7	93.4	93.6	93.0	92.8	93.1	90.6	88.2	49.6




图5 各类别改进前后模型检测效果

Fig.5 Visualization results of model before and after improvement

表8 各模型及算法综合检测性能比较

Table 8 Comparison of comprehensive detection performance of various models and algorithms

研究者	模型	mAP/%	FPS/(帧/s)
Virasova 等人 ^[8]	ECG-SVM	87.2	18.2
Londe 等人 ^[10]	SSD	82.2	23.6
Zhang 等人 ^[12]	Faster-RCNN	75.6	50.2
Zhang 等人 ^[17]	CS-ResNet	93.9	15.2
吕秀丽等人 ^[25]	YOLOv8n	92.3	39.4
本文	YOLOv11-MAS	93.1	49.6




图6 各模型性能对比

Fig.6 Performance comparison of various models

提取能力,使检测精度比原始YOLOv11提高6.7个百分点。同时,设计了自适应分层特征融合网络AHFIN,实现了多尺度特征的自适应加权融合,有效增强了模型对小缺陷和复杂场景的适应能力,检测精度进一步提升4.1个百分点。此外,为优化边界框回归过程,克服传统损

失函数对小目标和形态不规则缺陷的局限性,引入滑动对齐损失函数(SAL),进一步提高了检测精度与鲁棒性。

改进后的模型YOLOv11-MAS在PCB缺陷检测任务中的平均检测精度(mAP)达到93.1%,较原始模型提升了7.8个百分点,同时保持49.6帧/s的实时检测速度,完全满足工业生产线的实时检测需求。改进模型不仅增强了小目标缺陷的识别能力,还能够更精准地适应复杂场景。

未来工作将聚焦于进一步优化模型轻量化设计,以推动该算法在PCB缺陷检测中的实际工业应用。初步设想包括:一是借鉴更轻量级的网络结构,如ShuffleNet或RepVGG等,替换部分骨干网络层,以减少参数量和计算量;二是应用模型剪枝策略,通过剪枝去除网络中的冗余连接或不重要的特征通道,从而降低模型复杂度;三是利用量化感知训练技术,将模型权重和激活值量化为低精度数据类型,以减少模型存储空间和推理时的计算资源消耗。此外,还可以探索知识蒸馏方法,将YOLOv11-MAS的知识迁移到一个更小的模型中,进一步提升轻量化效果,使其更易于部署在资源受限的嵌入式设备上。

参考文献:

- [1] CHEN I C, HWANG R C, HUANG H C. PCB defect detection based on deep learning algorithm[J]. Processes, 2023, 11(3): 775.
- [2] DENG L, MENG X Z, GUO X D, et al. Learned optical flow-based defect detection with coarse-to-fine nonrigid image alignment[J]. IEEE Sensors Journal, 2025, 25(5): 8684-8696.

- [3] FELICIANO F, LETA F, MARTINS F. Computer vision system for printed circuit board inspection[J]. ABCM Symposium Series in Mechatronics, 2018, 3: 623-632.
- [4] KAMALAJA N, SILVA D, TANTHIRIGE M. Printed circuit board defect detection and sorting using image processing techniques[J]. International Journal of Engineering Research in Electronic and Communication Engineering, 2016, 3(2): 78-90.
- [5] ZHOU Y B, YUAN M H, ZHANG J, et al. Review of vision-based defect detection research and its perspectives for printed circuit board[J]. Journal of Manufacturing Systems, 2023, 70: 557-578.
- [6] SILVA L H, AZEVEDO G O, FERNANDES B J T, et al. Automatic optical inspection for defective PCB detection using transfer learning[C]//Proceedings of the IEEE Latin American Conference on Computational Intelligence. Piscataway: IEEE, 2019: 1-6.
- [7] WAN Y, GAO L, LI X, et al. Semi-supervised defect detection method with data-expanding strategy for PCB quality inspection [J]. Sensors (Basel), 2022, 22(20): 7971.
- [8] VIRASOVA A Y, KLIMOV D I, KHROMOV O E, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[J]. Radioengineering, 2021: 115-126.
- [9] 颜豪男, 吕伏. 多尺度特征增强的PCB板表面缺陷检测算法[J/OL]. 信息与控制: 1-13[2025-08-20]. <https://doi.org/10.13976/j.cnki.xk.2024.4021>.
YAN H N, LYU F. Multi-scale feature enhancement for PCB defect detection algorithm[J]. Information and Control: 1-13 [2025-08-20]. <https://doi.org/10.13976/j.cnki.xk.2024.4021>.
- [10] LONDE P, CHAVAN S. Automatic PCB defects detection and classification using matlab[J]. International Journal of Current Engineering and Technology, 2014, 4: 78-90.
- [11] 向毅伟, 蒋瑜, 王琪凯, 等. 多尺度特征优化的实时Transformer在无人机航拍中的研究[J]. 计算机工程与应用, 2025, 61(9): 221-229.
XIANG Y W, JIANG Y, WANG Q K, et al. Research on real-time transformer for multi-scale feature optimization in drone aerial imaging[J]. Computer Engineering and Applications, 2025, 61(9): 221-229.
- [12] ZHANG K H, SHEN H K. Solder joint defect detection in the connectors using improved faster-RCNN algorithm[J]. Applied Sciences, 2021, 11(2): 576.
- [13] 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.
WU Y Q, ZHAO L Y, YUAN Y B, et al. Research status and the prospect of PCB defect detection algorithm based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 1-17.
- [14] RAN G Z, LEI X, LI D S, et al. Research on PCB defect detection using deep convolutional neural network[C]//Proceedings of the 5th International Conference on Mechanical, Control and Computer Engineering. Piscataway: IEEE, 2020: 1310-1314.
- [15] ANITHA D B, RAO M. A survey on defect detection in bare PCB and assembled PCB using image processing techniques[C]//Proceedings of the International Conference on Wireless Communications, Signal Processing and Networking. Piscataway: IEEE, 2017: 39-43.
- [16] LING Q, ISA N A M. Printed circuit board defect detection methods based on image processing, machine learning and deep learning: a survey[J]. IEEE Access, 2023, 11: 15921-15944.
- [17] ZHANG H, JIANG L X, LI C Q. CS-ResNet: cost-sensitive residual convolutional neural network for PCB cosmetic defect detection[J]. Expert Systems with Applications, 2021, 185: 115673.
- [18] 潘玮, 韦超, 钱春雨, 等. 面向无人机视角下小目标检测的YOLOv8s改进模型[J]. 计算机工程与应用, 2024, 60(9): 142-150.
PAN W, WEI C, QIAN C Y, et al. Improved YOLOv8s model for small object detection from perspective of drones[J]. Computer Engineering and Applications, 2024, 60(9): 142-150.
- [19] 窦智, 高浩然, 刘国奇, 等. 轻量化YOLOv8的小样本钢板缺陷检测算法[J]. 计算机工程与应用, 2024, 60(9): 90-100.
DOU Z, GAO H R, LIU G Q, et al. Small sample steel plate defect detection algorithm of lightweight YOLOv8[J]. Computer Engineering and Applications, 2024, 60(9): 90-100.
- [20] 胡峻峰, 李柏聪, 朱昊, 等. 改进YOLOv8的轻量化无人机目标检测算法[J]. 计算机工程与应用, 2024, 60(8): 182-191.
HU J F, LI B C, ZHU H, et al. Improved YOLOv8 lightweight UAV target detection algorithm[J]. Computer Engineering and Applications, 2024, 60(8): 182-191.
- [21] 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. Piscataway: IEEE, 2016: 779-788.
- [22] ADIBHATLA V A, CHIH H C, HSU C C, et al. Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once[J]. Mathematical Biosciences and Engineering, 2021, 18(4): 4411-4428.
- [23] 赵奕翔, 苏检德, 何富运, 等. 改进YOLOv5s算法的PCB缺陷检测方法[J]. 无线电工程, 2025, 55(5): 949-958.
ZHAO Y X, SU J D, HE F Y, et al. PCB defect detection method based on improved YOLOv5s algorithm[J]. Radio Engineering, 2025, 55(5): 949-958.
- [24] 解琳, 韩跃平, 翟倩, 等. 基于改进YOLOv7-tiny的PCB表面缺陷检测[J]. 测试技术学报, 2025, 39(1): 81-87.
XIE L, HAN Y P, ZHAI Q, et al. PCB surface defect detection based on improved YOLOv7-tiny[J]. Journal of Testing Technology, 2025, 39(1): 81-87.
- [25] 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.
LYU X L, YANG X S, CAO Z M. PCB surface defect detection algorithm based on improved YOLOv8[J]. Electronic Measurement Technology, 2024, 47(12): 100-108.