

DOI: 10.19650/j.cnki.cjsi.J2514306

融合小波变换卷积和知识蒸馏的 PCB 缺陷检测模型*

刘春娟, 赵浩然, 张明璇, 闫浩文, 吴小所

(兰州交通大学电子与信息工程学院 兰州 730070)

摘要:针对印制电路板 (PCB) 缺陷检测任务中存在的缺陷形态复杂、背景干扰强以及工业现场对实时性与轻量化部署的严苛需求,提出了一种融合小波变换与知识蒸馏的高效轻量化检测模型——KDYOLOv8。首先,设计 Star-YOLO 主干网络,利用星形操作将输入特征映射至高维非线性空间,在大幅降低计算冗余的同时增强对复杂缺陷模式的特征提取能力。其次,引入小波变换卷积 (WTConv),通过多分辨率分析技术解耦图像的高频缺陷细节与低频背景纹理,在不显著增加参数数量的前提下有效抑制噪声干扰并扩展感受野。同时,构建增强型多尺度双向特征金字塔网络 (EMBFPN),利用双向信息流交互机制强化深浅层特征融合,解决深层网络中微小缺陷特征稀释的问题。此外,采用通道级知识蒸馏策略 (CWD),引导轻量化模型学习教师网络的通道注意力分布,补偿模型压缩带来的精度损失。实验结果表明,在公开 PCB 缺陷数据集上,KDYOLOv8 的平均精度均值 (mAP) 达到 97.1%,模型体积仅 2.9 MB,推理速度高达 117.3 fps;相较于基线 YOLOv8n,在体积缩减 52.5% 的情况下依然保持了高精度。在跨数据集泛化实验中,模型对“鼠咬”和“短路”等细微缺陷的检测精度分别提升了 1.9% 和 1.6%。有效平衡了检测速度、精度与资源消耗,能够为算力受限环境下的工业部署提供有力支持。

关键词: PCB 缺陷检测;目标检测;轻量化模型;知识蒸馏;KDYOLOv8;实时检测

中图分类号: TP391 TH862 **文献标识码:** A **国家标准学科分类代码:** 510.40

Integrating wavelet transform convolution and knowledge distillation for efficient PCB defect detection

Liu Chunjuan, Zhao Haoran, Zhang Mingxuan, Yan Haowen, Wu Xiaosuo

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: To address the challenges of complex defect morphology, strong background interference, and the strict requirements for real-time performance and lightweight deployment in printed circuit board (PCB) defect detection, an efficient lightweight detection model named KDYOLOv8 is proposed in this article, which integrates wavelet transform and knowledge distillation. Firstly, a Star-YOLO backbone network is designed, utilizing star operation to map input features into a high-dimensional non-linear space, thereby enhancing feature extraction capabilities for complex defect patterns while significantly reducing computational redundancy. Secondly, the wavelet transform convolution (WTConv) is introduced to decouple high-frequency defect details from low-frequency background textures through multi-resolution analysis, effectively suppressing noise interference and expanding the receptive field without significantly increasing parameters. Meanwhile, an EMBFPN enhanced multi-scale bi-directional feature pyramid network is constructed, employing a bi-directional information flow interaction mechanism to strengthen the fusion of deep and shallow features, addressing the problem of small defect feature dilution in deep networks. Furthermore, a channel-wise knowledge distillation (CWD) strategy is adopted to guide the lightweight model in learning the channel attention distribution of the teacher network, compensating for accuracy loss caused by model compression. Experimental results show that, on a public PCB defect dataset, KDYOLOv8 achieves a mean average precision (mAP) of 97.1%, with a model size of only 2.9 MB and an inference speed of 117.3 fps. Compared with the baseline YOLOv8n, it maintains high accuracy while reducing the volume by 52.5%. In cross-dataset generalization experiments, the detection accuracy for subtle defects such as “mouse bite” and “short” improved by 1.9% and 1.6%, respectively. This study effectively balances detection speed,

收稿日期:2025-07-23 Received Date: 2025-07-23

* 基金项目:青海理工大学“昆仑英才”人才引进科研项目(W2023-QLGKLYCZX-034)资助

accuracy, and resource consumption, providing strong support for industrial deployment in resource-constrained environments.

Keywords: PCB defect detection; object detection; lightweight model; knowledge distillation; KDYOLOv8; real-time detection

0 引言

随着工业 4.0 的深入发展,高精度、自动化的质量控制已成为电子制造业核心竞争力的重要体现^[1]。作为电子产品的基础,印制电路板(printed circuit board, PCB)的质量直接决定了终端产品的可靠性与性能^[2]。然而,PCB 制造过程复杂多变,极易产生形态各异、尺寸悬殊的缺陷,例如微米级的毛刺、细小开路及大面积假铜等,这对检测算法提出了严峻挑战。传统的自动光学检测(automated optical inspection, AOI)方法依赖人工设计的规则和模板匹配,泛化能力有限,面对复杂多样的缺陷模式时易出现漏检或误检,难以满足现代生产线上对高检测效率和低误报率的严格要求^[3]。

为突破这一瓶颈,深度学习驱动的目标检测技术成为解决方案的核心。基于卷积神经网络(convolutional neural network, CNN)的检测器,例如 Faster R-CNN^[4]和 YOLO 系列^[5-6],通过数据驱动的特征学习彻底颠覆了传统方法。然而,CNN 的局部感受野限制了其对缺陷与周围复杂布线之间全局依赖关系的建模能力,尤其在处理大面积缺陷或密集背景干扰时易产生误判。为缓解这一问题,研究者广泛引入特征金字塔网络(feature pyramid network, FPN)^[7-8]及其变体,通过多尺度特征融合提升对尺寸变化剧烈缺陷的适应性。但 FPN 自顶向下的信息流路径存在微小目标特征易被深层网络稀释的缺陷,且跨层语义鸿沟未能彻底解决,最终影响定位精度。进一步地,集成注意力机制或采用更强大的骨干网络(如 EfficientNetV2^[9]、Vision Transformer (ViT)^[10]、Swin Transformer^[11-12])虽提升了检测精度,却往往降低计算效率,导致模型参数量与计算复杂度(giga floating-point operations per second, GFLOPs)急剧增加,与工业场景对轻量化^[13]部署的需求产生直接冲突。新近涌现的 Transformer 架构,如检测转换器(detection transformer, DETR)^[14],虽提供了无需非极大值抑制的端到端检测方案,但其对小目标的检测性能欠佳,且训练周期长、收敛速度慢,不适合工业中需要快速迭代与部署的场景。

综上所述,现有研究路径普遍呈现出“性能提升依赖模型复杂度增加”的趋势,这与工业边缘计算场景对模型体积、推理延迟和功耗的严格要求形成了突出矛盾^[15]。在实际生产线上,检测算法必须在嵌入式图形处理器(graphics processing unit, GPU)或现场可编程逻辑门阵列(field programmable gate array, FPGA)等资源受限硬件

上实现高吞吐量、低延迟的实时处理。因此,如何在保持较高检测精度的同时,显著降低模型复杂度与计算消耗,构建兼具高精度、高速度与低资源消耗的轻量化检测模型,已成为该领域实现从理论创新到产业落地的关键技术瓶颈。

为应对这一挑战,本文提出了一种融合小波变换与知识蒸馏的轻量化 PCB 缺陷检测网络——KDYOLOv8,旨在实现检测精度、推理速度与资源消耗之间的理想平衡。本文的主要贡献为:

1) 高效轻量化骨干网络(Star-YOLO):采用独特的星形拓扑结构,以极低的计算成本将特征映射至高维非线性空间,从而高效建模复杂缺陷模式,提高特征表达能力。

2) 增强型多尺度双向特征金字塔网络(enhanced multi-scale bi-directional feature pyramid network, EMBFPN):设计了一种专为 PCB 缺陷大尺度方差优化的多尺度特征融合网络,通过优化的双向信息流,有效缓解微小缺陷特征在深层网络中的稀释问题。

3) 增强特征表达:创新性地引入小波变换卷积(wavelet transform convolution, WTConv),利用其多分辨率分析特性,在不显著增加参数数量的前提下扩展有效感受野,提升模型对结构与细节的表征能力。

4) 知识蒸馏精度补偿:应用通道级知识蒸馏(channel-wise knowledge distillation, CWD)策略,将教师网络中精炼的知识迁移至轻量化学生网络,有效弥补因模型结构简化而可能带来的精度损失。

在公开 PCB 缺陷数据集上的综合实验结果表明, KDYOLOv8 在实现模型体积仅 2.9 MB 的同时,取得了 97.1% 的平均精度(mean Average Precision, mAP)和 117.3 fps 的推理速度,较基线模型 YOLOv8n 体积压缩了 52.5%。此外, KDYOLOv8 在跨数据集的泛化性能同样优异,证明了其在工业实时检测场景中的应用潜力与推广价值。

1 KDYOLOv8 网络模型设计

针对工业环境下 PCB 缺陷检测任务中普遍存在的缺陷形态多样、尺寸跨度大、背景复杂等挑战,综合考虑高实时性与低部署成本的需求,提出了一种轻量化检测模型——KDYOLOv8。该模型的整体架构如图 1 所示,遵循“主干提取特征—颈部融合特征—检测头预测输出”的经典检测框架,并围绕 PCB 检测任务的特性进行了有针对性的深度优化。

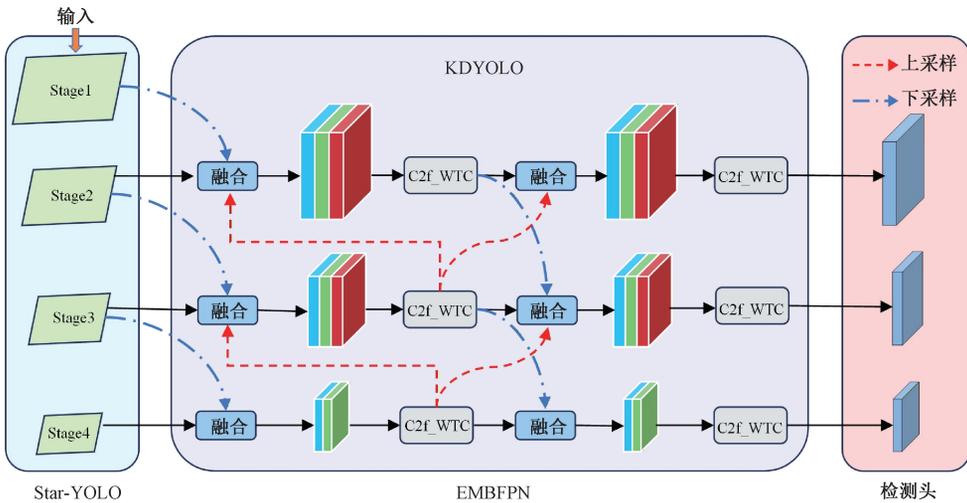


图 1 KDYOLOv8 网络结构

Fig. 1 KDYOLOv8 network architecture

具体而言,输入的 PCB 图像首先由轻量且高效的 Star-YOLO 主干网络处理,用于提取基础特征。Star-YOLO 模块的引入旨在从架构源头有效降低模型计算复杂度,同时保留对复杂缺陷模式的强表达能力,为后续特征处理奠定坚实基础。接着,模型将各层次的特征图输入到专门为多尺度目标设计的 EMBFPN 中。该模块通过独特的双向信息流通道,实现了浅层局部细节与深层全局语义的高效交互,显著强化了对 PCB 中微小缺陷(如针孔、细微划痕)与大尺度缺陷(如污渍、大面积短路)的综合表征与感知能力。

在完成多尺度特征融合后,检测头(Head)在高信息密度的特征图上执行最终的目标检测任务,输出缺陷的精确位置、类别及相关置信度分数。训练过程中,模型通过联合回归与分类损失函数对检测性能进行优化,以确保网络能够在保持高精度的前提下实现实时检测的工业应用需求。

综上所述,KDYOLOv8 在整体设计上不仅注重网络的轻量化与高效性,还通过针对性的多模块协同优化,使其具备了出色的缺陷适应能力、优异的推理速度与极低的资源消耗,为算力受限场景下的高性能 PCB 缺陷检测提供了一种切实可行的解决方案。

1.1 Star-YOLO 主干网络

在工业检测场景中,PCB 缺陷的形态不规则,且常伴随光照变化、材料反光等复杂噪声干扰,使得缺陷特征呈现显著的非线性与多样性。传统卷积网络在应对此类复杂模式时,通常需要堆叠大量深层结构以提升特征表达能力,但由此带来的参数冗余和计算开销,难以满足工业现场对实时性与资源受限环境的要求。

StarNet 架构^[16] 通过其核心的星形操作 (star

operation) 创新性地解决了这一问题。该操作通过像素级乘法引入特征的二阶项,能够在不显著增加计算负担的前提下,将输入特征映射至更高维的非线性空间,从而高效地捕捉复杂数据分布的细节特征。基于此思想,本文将 StarNet 与 YOLOv8 结构深度融合,构建了轻量化的 Star-YOLO 主干网络,以针对 PCB 缺陷检测中的两大核心挑战进行优化,即:

1) 特征复杂性建模:星形操作能够生成丰富的高维非线性特征,更精准地刻画不同类型 PCB 缺陷(如毛刺、开路、短路)之间细微却关键的形态差异,提升模型对复杂背景中缺陷的辨识能力。

2) 模型轻量化设计:Star-YOLO 的紧凑网络结构与高效计算特性,使其成为轻量化检测模型的理想基础。其低参数量和低计算量为后续模块(例如知识蒸馏部分)中的学生网络提供了良好的结构支撑,有助于在保持精度的同时大幅降低资源消耗。

如图 2 所示,Star-YOLO 采用了一种 4 阶段的层次化架构,每个阶段包括用于下采样卷积层和用于特征提取的星操作块(star block)。

为了实现空间信息的交互,增强特征表示能力,深度可分离卷层提取后的特征送入两个逐点卷积 FC 生成中间特征图进行星操作,实现像素级乘法,如式(1)所示。

$$(\mathbf{W}_1^T \mathbf{X} + \mathbf{B}_1) \times (\mathbf{W}_2^T \mathbf{X} + \mathbf{B}_2) \quad (1)$$

其中, \mathbf{W}_1 和 \mathbf{W}_2 是权重矩阵, \mathbf{B}_1 和 \mathbf{B}_2 是偏置项, \mathbf{X} 是输入特征。为了简化分析,本文将权重矩阵和偏置项合并为 $\mathbf{W} = [\mathbf{W}, \mathbf{B}]^T$, 输入特征 \mathbf{X} 扩展为 $\mathbf{X} = [\mathbf{X}, 1]^T$ 重构了星操作,如式(2)所示。

$$(\mathbf{W}_1^T \mathbf{X}) \times (\mathbf{W}_2^T \mathbf{X}) \quad (2)$$

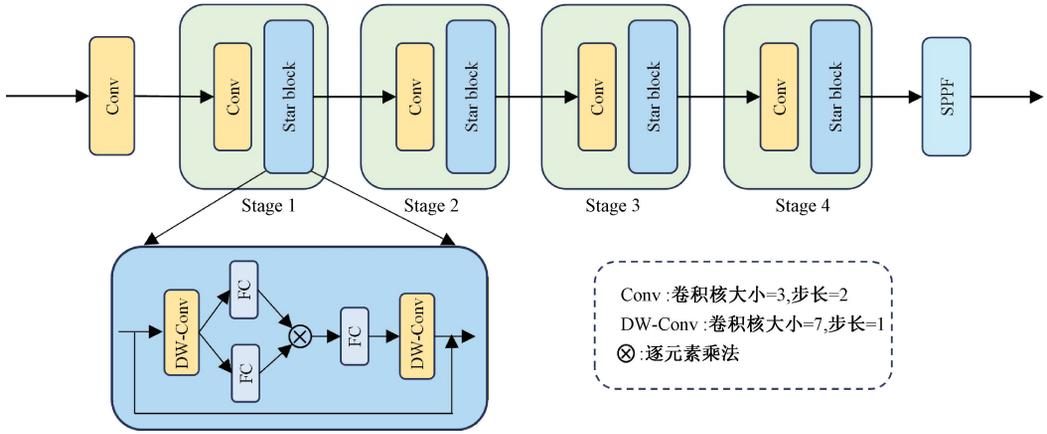


图2 Star-YOLO 主干网络结构

Fig. 2 Star-YOLO backbone network architecture

假设 $w_1, w_2, x \in \mathbb{R}^{(d+1) \times 1}$, 其中 d 是输入通道数, 则式(2)可以展开为式(3), 即:

$$w_1^T x \times w_2^T x = \left(\sum_{i=1}^{d+1} w_{1i} x_i \right) \times \left(\sum_{j=1}^{d+1} w_{2j} x_j \right) = \sum_{i=1}^{d+1} \sum_{j=1}^{d+1} w_{1i} w_{2j} x_i x_j \quad (3)$$

若用 $\alpha(i, j)$ 表示每一项的系数, 则星操作可以进一步展开, 如式(4)所示。

$$\alpha(1, 1)x_1x_1 + \dots + \alpha(4, 5)x_4x_5 + \dots + \alpha(d+1, d+1)x_{d+1}x_{d+1} \quad (4)$$

星操作得到的特征图送入另一个深度可分离卷积层实现进一步的特征提取和变换。每个阶段的星操作块得到的特征图与原输入进行残差连接与路径丢弃, 在保留原始信息的同时防止过拟合, 增加模型鲁棒性。经过4个阶段特征提取得到的多层次、非线性特征图为后续的缺陷检测奠定了基础。

因此, Star-YOLO 主干网络不仅在特征表达上具备更强的非线性建模能力, 同时在硬件友好性方面显著优于传统深层卷积结构, 为 KDYOLOv8 整体架构的轻量化与高精度提供了关键技术基础。

1.2 增强型多尺度双向特征金字塔网络

PCB 缺陷检测的一个核心挑战在于目标尺度的高度变化特性: 缺陷既包括像素级的微小针孔、断路, 也可能涵盖占据图像大面积的铜箔缺失或污渍。在标准深度卷积网络中, 随着网络深度的增加, 用于精确定位的小尺寸目标的特征易在逐层下采样过程中被稀释或丢失, 而深层语义信息又难以覆盖所有尺度的缺陷, 导致小目标检测性能明显下降。

为解决这一问题, 本文设计了 EMBFPN, 其结构如图3所示。EMBFPN 的核心优势在于高效的双向信息交互路径设计, 使网络能够充分整合多尺度上下文信息与细节特征。

其中自下而上的路径(图3中虚线箭头所示)负责传递深层网络提取的、用于缺陷分类的强语义信息; 自上而下的路径(图3中点画线箭头所示)则通过更密集的跨层连接, 将高层的全局语义有效地回传, 用以指导浅层高分辨率特征图的选择与增强。该双向信息流机制确保了如“针孔”等微小缺陷的位置信息不会在深层网络中被稀释。

此外, EMBFPN 网络路径中的所有特征提取模块均采用 C2f_WTConv 模块, 如图3所示。该模块将输入通过 1×1 卷积分成两个分支, 完成特征分流。其中一个分支通过 n 个由卷积组成的 Bottleneck 进行逐级特征提取, 并将所有分支特征拼接后通过 1×1 卷积融合。该设计是将原本 C2f 的 Bottleneck 中的普通卷积换成了小波卷积, 使得网络在全局感受野之下融合不同尺度空间特征的同时, 能够引入频率域的考量, 对缺陷的边缘(高频信息)和背景纹理(低频信息)进行差异化处理, 从而提升融合后特征的质量与表达能力。

最终, EMBFPN 通过多分辨率输出引导检测头进行精确预测。其高效的双向信息流与多层次交互设计, 使网络输出的特征图兼具全局上下文感知与局部细节分辨能力。这不仅弥补了传统 FPN 在微小目标特征表达上的不足, 还通过与小波变换卷积的有机结合, 显著提升了模型对多尺度缺陷的检测鲁棒性, 是 KDYOLOv8 提升多尺度检测性能的关键组件。

为了匹配后续跳跃连接中特征图的维度和分辨率, EMBFPN 结构中引入了一种高效上卷积模块(efficient Up-convolution block, EUCB)^[17], 用于特征图的上采样与特征增强。EUCB 首先通过缩放因子为2的上采样操作 $Up(\cdot)$ 对特征图进行空间尺寸放大。随后, 采用一个 3×3 的深度可分离卷积 $DWC(\cdot)$ 处理上采样后的特征图, 并结合批量归一化 $BN(\cdot)$ 与 ReLU 激活函数 $ReLU(\cdot)$, 增强

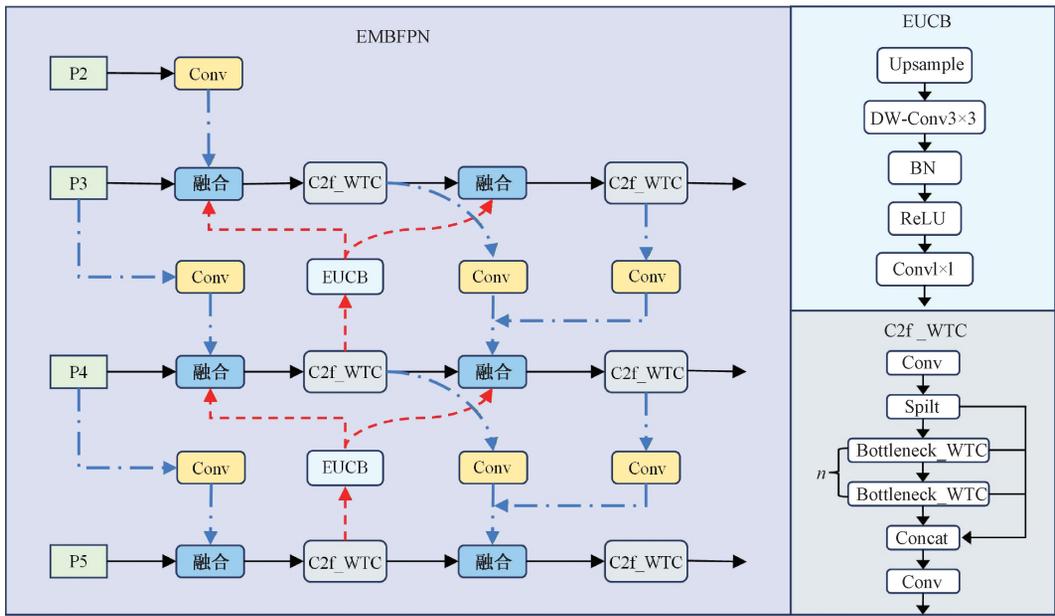


图 3 EMBFPN 网络结构
Fig. 3 EMBFPN network architecture

放大后特征的表达能力与稳定性。最后,通过一个 1×1 的卷积 $C_{1 \times 1}(\cdot)$ 对通道数进行压缩,使输出特征图的维度与下一个阶段的输入要求保持一致。EUCB 的整体计算流程可描述如式(5)所示。

$$EUCB(x) = C_{1 \times 1}(ReLU(BN(DWC(Up(x)))))) \quad (5)$$

该模块在保证较低计算开销的前提下,有效提升了特征图的空间分辨率和语义一致性,为 EMBFPN 中不同尺度特征的高效融合提供了重要支撑。

1.3 小波变换卷积

传统卷积在扩展感受野时,通常依赖于加深网络层数或采用更大的卷积核,这不仅带来显著的计算开销,还容

易忽略图像内部的频率结构信息。在 PCB 图像中,电路板的背景纹理和走线布局主要表现为低频信息,构成了图像的全局结构;而缺陷本身,例如尖锐的毛刺或断裂痕迹,则往往呈现为高频信号。为了实现 PCB 图像的精准缺陷识别,模型需要能够同时高效地处理低频与高频成分。

WTConv^[18] 为此提供了解决方案。该模块利用小波变换的多分辨率分析特性,将输入特征图解耦为低频与高频分量。本文选用计算高效的 Haar 小波基,因其擅长捕捉信号的阶跃变化,与 PCB 图像中电路走线的清晰边缘及缺陷的突变特征高度吻合。

WTConv 的单级小波变换的流程如图 4 所示。

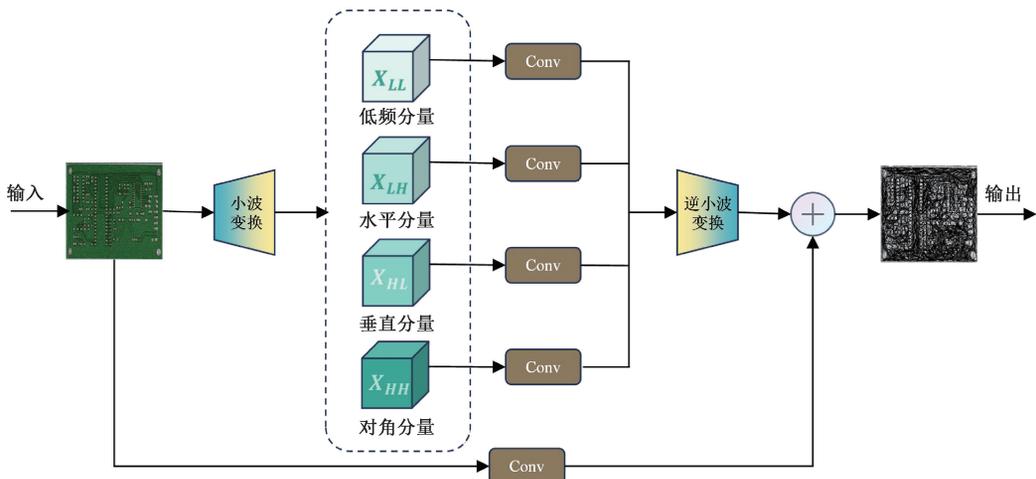


图 4 小波变换卷积流程
Fig. 4 Flowchart of wavelet transform convolution

对输入 PCB 图像 X 进行多级小波分解。在每一级分解中,采用 Haar 小波对低频成分进行深度可分离卷积操作,得到更细粒度的低频和低频成分。具体来说,对于第 i 级分解,输入是上一级的低频成分 $X_{LL}^{(i-1)}$,输出包括当前级的低频成分 $X_{LL}^{(i)}$ 和水平、垂直和对角 3 个方向的高频成分 $X_{LH}^{(i)}$ 、 $X_{HL}^{(i)}$ 、 $X_{HH}^{(i)}$,如式(6)所示。

$$X_{LL}^{(i)}, X_{LH}^{(i)}, X_{HL}^{(i)}, X_{HH}^{(i)} = WT(X_{LL}^{(i-1)}) \quad (6)$$

其中, $X_{LL}^{(0)} = X$, 为原始图像。对每一级分解得到的低频和低频成分,分别应用 3×3 的深度可分离卷积核 $W^{(i)}$ 进行卷积操作,得到对应的特征图 $Y_{LL}^{(i)}$ 、 $Y_{LH}^{(i)}$ 、 $Y_{HL}^{(i)}$ 、 $Y_{HH}^{(i)}$,该操作如式(7)所示。

$$Y_{LL}^{(i)}, Y_{LH}^{(i)}, Y_{HL}^{(i)}, Y_{HH}^{(i)} = Conv(W^{(i)}, (X_{LL}^{(i)}, X_{LH}^{(i)}, X_{HL}^{(i)}, X_{HH}^{(i)})) \quad (7)$$

最后从最高级的高频成分和低频成分开始,逐级进行逆小波变换,将不同级别的特征图进行融合。最终得到的输出特征图 $Z^{(0)}$,如式(8)所示。

$$Z^{(i)} = IWT(Y_{LL}^{(i)} + Z^{(i+1)}, Y_{LH}^{(i)}, Y_{HL}^{(i)}, Y_{HH}^{(i)}) \quad (8)$$

其中, i 逐渐递减为 1, l 为小波分解的级数。最终输出 $Z^{(0)} = Y_{LL}^{(0)} + Z^{(1)}$ 。

上述基于频率分离的模式在低频分量上卷积能以低计算成本获取巨大感受野以增强全局定位;同时,对高频分量的独立处理则保留了精细特征,解决了传统卷积为扩大感受野而牺牲分辨率的固有矛盾。此外,通过解耦使得模型能有效增强关键缺陷的高频信号,并抑制背景的低频噪声干扰。因此,WTConv 在几乎不增加额外参数量的前提下,为 KDYOLOv8 的轻量化与高性能提供了有力支持。

1.4 通道级知识蒸馏

为了实现模型轻量化的同时最大限度地保留检测精度,本文引入了知识蒸馏策略。其核心思想是通过性能更优、结构更复杂的教师网络“指导”本文设计的轻量化学生网络(KDYOLOv8)进行训练,使后者能够在较小模型容量的条件下继承教师模型的判别能力。

在 PCB 缺陷检测任务中,教师网络经过训练后,其不同特征层的通道会自适应地对特定缺陷模式形成差异化响应。例如,部分通道可能对“开路”缺陷的线性特征尤为敏感,而另一些通道则对“短路”缺陷的团簇状特征产生强烈激活。这种通道级别的激活模式本身蕴含了宝贵的、高度凝练的先验知识。

本文采用的 CWD^[19] 方法,正是为了高效迁移这类精细化知识,具体流程如图 5 所示。其过程包括两个关键步骤,即:

1) 构建通道级空间概率分布。如式(9)所示,CWD 将教师网络与学生网络在特定特征层中的各通道激活图 y_c 视为一个二维空间分布。并通过一个带有蒸馏温度 T 的

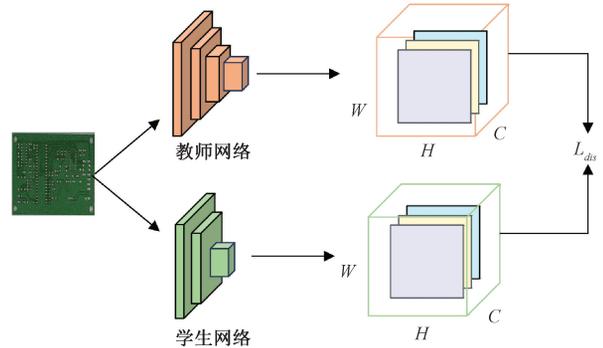


图5 CWD 结构

Fig. 5 Diagram of CWD architecture

Softmax 函数,将每个通道内的激活值 $y_{c,i}$ 转换为一个概率分布 $\phi(y_c)$, 即:

$$\phi(y_c) = \frac{\exp\left(\frac{y_{c,i}}{T}\right)}{\sum_{i=1}^{W \cdot H} \exp\left(\frac{y_{c,i}}{T}\right)} \quad (9)$$

在此过程中,作为平滑因子的蒸馏温度 T “软化”了概率分布,使得学生网络可以学习包含特征间相对关系的“暗知识(dark knowledge, DK)”。

2) 通过库尔贝克-莱布勒散度(kullback-leibler divergence, KL)对齐分布。如式(10)所示,CWD 通过最小化这两个“软化”后概率分布之间的 KL 散度来构建蒸馏损失函数 L , 即:

$$L = \frac{T^2}{C} \sum_{c=1}^C \sum_{i=1}^{W \cdot H} \phi(y_{c,i}^t) \cdot \log \left[\frac{\phi(y_{c,i}^t)}{\phi(y_{c,i}^s)} \right] \quad (10)$$

其中, $\phi(y_{c,i}^t)$ 和 $\phi(y_{c,i}^s)$ 分别代表教师网络和学生网络的概率分布, C 表示通道数。最小化该损失的过程中,CWD 能够引导学生网络精准地复现教师网络对空间关键区域的注意力分配策略,从而提升对重要细节的刻画能力与定位精度。

不同于 L1/L2 范数等直接对齐特征数值的传统蒸馏方法,CWD 的核心在于对齐通道级的注意力分配机制,更注重迁移通道间的结构化关系,从而能更有效地捕捉关键特征并抑制冗余信息。因此,这种基于通道级分布对齐的知识迁移方式,能够有效弥补轻量化学生网络因参数减少而导致的表征能力损失,使 KDYOLOv8 在保持计算高效性的前提下,实现对定位困难或易混淆缺陷的精准检测。

2 实验指标

2.1 数据集及实验环境

本实验采用的主要数据集为北京大学智能机器人开

放实验室提供的 PCB 缺陷数据集 (PCB_DATASET)。该数据集涵盖 6 种 PCB 缺陷类别,包括“missing hole (缺孔)”、“mouse bite (鼠咬)”、“open circuit (开路)”、“short (短路)”、“spur (毛刺)”及“spurious copper (假铜)”,共计 693 张图像。鉴于原始样本数量较少,为增强数据多样性与模型泛化能力,本文对数据集进行了数据增强处理,包括亮度调整、图像翻转、旋转、缩放和裁剪等操作,扩充后数据集总量达到 4 158 张图像。

此外,为进一步验证所提出算法在缺陷类目标检测任务中的有效性及泛化性能,本文还选用了公开数据集 GC10-DET 作为补充对比试验。本文实验所用硬件与软件环境配置如表 1 所示。

表 1 实验环境配置

Table 1 Configure the experimental environment

名称	型号
CPU	12 vCPU Intel(R) Xeon(R) Platinum 8255C CPU @ 2.50 GHz
GPU	NVIDIA GeForce RTX 3080, 显存 10 GB
编程软件	Python 3.8
训练框架	Pytorch 1.8.1 CUDA 11.1

2.2 实验细节

在训练过程中,输入图像的分辨率统一调整为 640 pixels×640 pixels,数据集按 7:1:2 的比例划分为训练集、验证集和测试集。模型训练采用随机梯度下降 (stochastic gradient descent, SGD) 优化算法,初始学习率设置为 0.01,动量系数为 0.937,权重衰减系数为 0.0005。批次大小 (batch size) 为 16,总训练轮次为 250。训练完成后,分别保存在验证集上性能最优的权重文件与最近一次训练的权重文件,以用于后续的测试与对比实验。

2.3 评价指标

采用多种评价指标对算法性能进行全面衡量。检测精度方面,选用准确率 (Precision)、召回率 (Recall) 与 mAP 作为主要指标,其中 mAP 指在交并比 (intersection over union, IoU) 阈值为 0.5 时各类别平均精度的均值,如式 (11)~(14) 所示。运行效率方面,使用单位时间内可检测图像数量 (frames per second, fps) 来衡量模型的检测速度;模型复杂度方面,则以浮点运算量 (FLOPs) 评价计算开销,以模型参数数量 (Parameters) 衡量模型的存储与部署成本。通过上述指标,从精度、速度与复杂度等维度综合评估模型在 PCB 缺陷检测任务中的实际表现。

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

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

$$mAP = \frac{\sum_{i=1}^n AP(i)}{n} \quad (13)$$

$$AP = \int_0^1 P(R) dR = \sum_{k=1}^N P(k) \Delta R(k) \quad (14)$$

式中: P 、 R 分别表示精确率和召回率,精确率反映检测准确率,召回率反映漏检情况; TP 表示真正例; FP 表示假正例; FN 表示假负例; n 表示缺陷类别数。

3 实验结果及分析

3.1 知识蒸馏策略分析

1) 不同蒸馏方法的性能对比

在该实验中,教师网络固定为 CSYOLOv8s,学生网络固定为 KDYOLOv8,蒸馏温度 $T=2.0$ 。在此设置下,分别采用多种主流蒸馏方法进行对比实验,结果如表 2 所示。比较对象包括 L1、L2、桥接跨任务蒸馏 (bridging cross-task distillation, BCKD)、保持相似性知识蒸馏 (similarity-preserving KD, SPKD)^[20] 及 CWD 等方法。

表 2 不同蒸馏方法的实验结果对比

Table 2 Comparison of experimental results of different distillation methods (%)

蒸馏方法	P	R	mAP
L1	96.1	92.3	95.7
L2	97.3	92.8	95.4
BCKD	97.5	93.0	96.5
SPKD	97.0	90.4	95.6
CWD	96.1	95.7	97.1

实验结果表明,CWD 方法在各项指标上均表现最优,其准确率达到 96.1%,召回率为 95.7%,mAP 高达 97.1%。这种性能优势主要归因于其独特的知识迁移机制:CWD 通过归一化通道激活值并最小化教师与学生网络间的 KL 散度,促使学生网络学习教师网络在通道级别的关键特征分布,而不仅仅是简单模仿全局特征的数值响应。

与仅进行特征值直接对齐的 L1/L2 蒸馏方法相比,CWD 更侧重于通道间关系的结构化学习,有效抑制了冗余信息干扰。同时,KL 散度计算过程中对高激活通道的隐式加权,进一步引导学生网络优先学习对缺陷敏感的关键区域。这种自适应的权重分配机制克服了传统蒸馏方法中权重僵化的问题,避免对次要但潜在有用特征的过度抑制。

综上,相较于其他蒸馏方法,CWD能够更充分地挖掘和利用教师网络中的细粒度知识,有效优化轻量化学生网络的检测能力。因此,本文最终选择CWD作为KDYOLOv8的知识蒸馏策略,以提升模型在PCB缺陷检测任务中的整体性能。

2) 不同教师网络的性能对比

在本实验中,固定蒸馏方法为CWD,学生网络为KDYOLOv8,蒸馏温度设置为 $T=2.0$ 。选用不同的教师网络进行蒸馏训练,实验结果如表3所示。

表3 不同教师网络的实验结果对比

Table 3 Comparison of experimental results from different teacher networks (%)

教师网络	P	R	mAP
YOLOv8s	95.8	87.6	92.7
GOLD-YOLO	92.0	93.2	95.0
Mamba-YOLO	94.9	92.7	93.4
LSKNet ^[21]	92.4	88.6	91.7
PKINet ^[22]	93.3	91.4	92.8
Swin Transformer	85.9	84.5	88.7
CSYOLOv8s	96.1	95.7	97.1

表4 不同学生网络的实验结果对比

Table 4 Comparison of experimental results with different student networks

学生网络	模型大小/MB	参数量/M	$GFLOPs$	$P/\%$	$R/\%$	$mAP/\%$	帧率/fps
EfficientViT ^[23]	8.4	4.01	9.4	94.3	90.0	93.4	39.1
Fasternet ^[24]	8.2	4.17	10.7	90.5	85.6	91.4	107.5
Ghostnet ^[25]	3.6	1.72	5.0	94.7	88.4	92.6	104.6
MobilenetV4	4.2	2.25	5.4	95.8	90.4	95.3	128.2
KDYOLOv8	2.9	1.36	5.5	96.1	95.7	97.1	117.3

从实验结果可以看出,KDYOLOv8以1.36 M的参数量和5.5 GFLOPs的计算量,取得了最佳性能,综合表现优于其他学生网络。相比之下,EfficientViT尽管通过其级联组注意力(cascaded group attention, CGA)模块优化了计算复杂度,但其Transformer架构在GPU上的内存带宽利用率较低,制约了实际运行效率。GhostNet则通过切除特征冗余实现参数压缩,但其深度可分离卷积的拆分操作易导致语义信息流失,特别是对于小尺寸PCB缺陷的捕捉效果下降明显。

KDYOLOv8的优越性能主要归因于其独特的设计优势。其核心的星操作能够将输入特征高效映射到高维非线性空间,突破了传统轻量化模型受限于线性变换的表达能力瓶颈,同时避免了显式注意力机制所带来的额外计算开销。此外,KDYOLOv8集成的EMBFPN实现了浅层空

结果显示,不同教师网络在知识蒸馏中的表现差异显著。其中,CSYOLOv8s作为教师网络时,学生网络的准确率(P)、召回率(R)和 mAP 分别达到96.1%、95.7%和97.1%,显著优于其他教师网络。这一结果得益于CSYOLOv8s针对PCB缺陷尤其是细长型和微小目标的优化设计,使学生网络在轻量化架构下能够更全面地捕捉目标细节信息,从而有效减少漏检和误检。

相比之下,采用YOLOv8s作为教师网络时,尽管学生网络保持了较高的准确率,但召回率和 mAP 表现均相对较低。这可能是由于YOLOv8s缺乏对多尺度特征的充分融合与优化,导致对小目标缺陷的检测敏感性不足,无法为学生网络提供足够的细粒度知识指导。

综合分析,CSYOLOv8s通过通道级知识蒸馏策略,显著提升了KDYOLOv8的整体性能,验证了其作为PCB缺陷检测任务中最优教师网络的有效性与适用性。因此,本文选择CSYOLOv8s作为KDYOLOv8的最终教师模型,以最大化蒸馏效果并提升轻量化模型在工业应用中的检测能力。

3) 不同学生网络的性能对比

在该实验中,固定蒸馏方法为CWD,教师网络为CSYOLOv8s,蒸馏温度设置为 $T=2.0$ 。选用多种主流轻量化模型作为学生网络,实验结果如表4所示。

间细节与深层语义信息的高效融合,有效缓解了采样过程中小目标特征信息的损失问题。

综上所述,KDYOLOv8学生网络不仅在轻量化与计算效率方面表现优异,还能更好地学习和模仿教师网络的深层次特征表示,为后续缺陷检测任务提供了强有力的技术支撑,充分体现了其在资源受限工业场景中的应用潜力。

4) 不同蒸馏温度的性能对比

当温度较低($T=1.0$)时,输出分布趋于“陡峭化”,学生模型过度聚焦于主要类别,难以学习教师模型对边缘案例的判别知识,从而降低整体泛化性能。而温度过高($T=3.0$)虽然可增强对负类别的关注,但过高的信息熵导致知识稀释,削弱了特征的判别性。

综上,实验结果充分表明选择合适的蒸馏温度对知

识迁移效果具有重要影响,如表 5 所示。适中的蒸馏温度(如 $T=2.0$)能够更好地引导教师网络的知识传递,帮助学生网络更准确地学习关键特征信息,从而显著提升模型的整体检测性能与鲁棒性。

表 5 不同蒸馏温度的实验结果对比

Table 5 Comparison of experimental results at different distillation temperatures (%)

蒸馏温度	P	R	mAP
1.0	96.1	92.2	95.5
2.0	96.1	95.7	97.1
3.0	95.4	91.3	95.9

3.2 消融实验

为验证各改进模块对模型性能的影响,本文以 YOLOv8n 作为基线模型,设计并实施了一组系统的消融实验。具体实验结果如表 6 所示,其中“√”表示在该实验中使用了对应模块。

从表 6 的结果可以看出,首先,单独在基线模型中集成 Star-YOLO 主干网络(模型 2)后,模型参数量与 GFLOPs 均显著下降,而 mAP 基本保持不变,验证了 Star-YOLO 在降低模型复杂度方面的有效性。EMBFPN 模块通过提升多尺度特征融合能力,使 mAP 提升了 3.8 个百分点,同时召回率大幅提高 8.0%,表明其能够有效整合空间与语义信息,显著改善对小目标缺陷的检测性能。

表 6 消融实验结果

Table 6 Ablation test results

模型	Star-YOLO	EMBFPN	WTConv	CWD	模型大小/MB	参数量/M	GFLOPs	$P/\%$	$R/\%$	$mAP/\%$	帧率/fps
Baseline					6.1	3.01	8.2	93.5	85.2	92.1	113.6
2	√				4.5	2.21	6.5	93.3	87.2	92.4	120.3
3		√			4.4	2.12	7.1	96.2	93.2	95.9	109.0
4			√		5.5	2.67	7.3	93.2	88.5	93.0	117.8
5				√	6.1	3.01	8.2	96.5	95.4	97.4	113.6
6	√		√		4.2	2.03	6.1	95.6	88.0	94.6	118.0
7	√	√			2.9	1.31	5.4	91.8	92.0	96.0	110.6
8	√	√	√		2.9	1.36	5.5	95.3	91.6	95.7	117.3
本文	√	√	√	√	2.9	1.36	5.5	96.1	95.7	97.1	117.3

尽管 EMBFPN 的结构微增加了计算复杂度,导致 fps 略有下降,但换来的精度收益显著。

WTConv 模块通过扩展有效感受野、强化对低频信息的建模,使召回率提升至 88.5%,验证了其多频响应特性在提升小目标检出能力方面的贡献。值得注意的是,单独在基线模型上应用 CWD 进行知识蒸馏(模型 5),在不增加任何参数量和计算量的情况下,将 mAP 提升至 97.4%,充分证明了知识蒸馏技术在弥补轻量化模型精度损失方面的显著作用。

最终,4 个模块协同集成后,模型在参数量仅为 1.36 M、GFLOPs 仅为 5.5 的条件下,达到了 97.1% 的 mAP ,体现了极低资源消耗与高检测性能之间的理想平衡。这充分说明各模块在特征提取、多尺度融合、感受野扩展与知识迁移方面的互补性与协同效应,为 KDYOLOv8 的卓越表现奠定了基础。

此外,表 7 展示了 KDYOLOv8 与 YOLOv8n 基线模型在 6 类 PCB 缺陷检测任务中的对比结果。实验表明, KDYOLOv8 在所有 6 类缺陷的检测中均优于基线模型,

尤其是在“鼠咬”、“开路”和“毛刺”类别上,分别提升了 11.0%、4.6% 和 9.0%。这些结果进一步验证了所提出改进方案在细粒度缺陷检测任务中的有效性与优势。

表 7 不同缺陷的 AP 结果对比

Table 7 Comparison of AP results for different defects (%)

缺陷类别	YOLOv8n	本文	提高
穿孔	99.3	99.5	0.2
鼠咬	86.8	97.8	11.0
开路	92.0	96.6	4.6
短路	93.3	94.8	1.5
毛刺	87.4	96.4	9.0
假铜	96.7	97.3	0.6

如图 6 所示,改进后的 KDYOLOv8 模型不仅显著提升了整体检测精度,还有效减少了 YOLOv8n 基线模型在

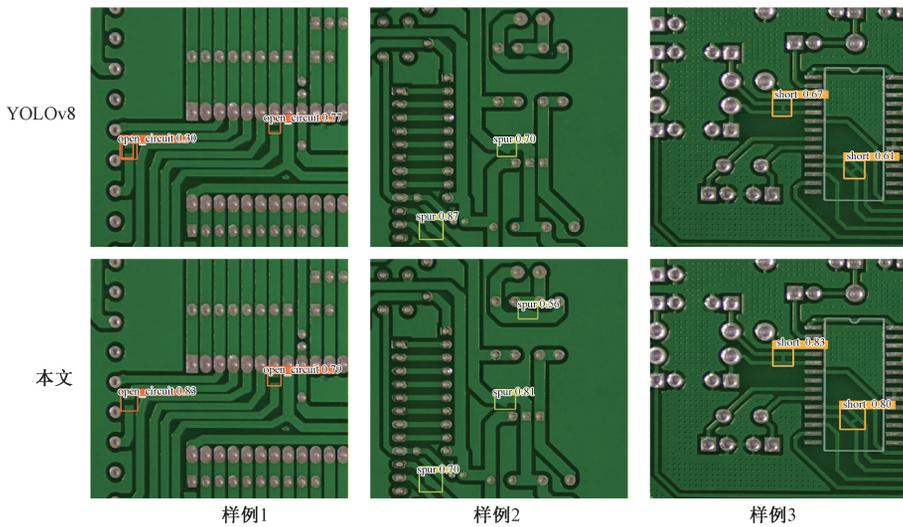


图6 缺陷检测结果对比

Fig. 6 Comparison of defect detection results

“开路”缺陷检测中的误检现象,以及对“毛刺”缺陷的漏检情况,极大地改善了 PCB 缺陷检测的准确性与可靠性,提升了整体检测效果和工程应用前景。

3.3 对比实验

为全面验证所提出模型的有效性,本文将基于 YOLOv8n 的改进模型 (KDYOLOv8) 与多种主流目标检测模型进行了对比分析,实验结果如表 8 所示。

表 8 对比实验结果

Table 8 Compare experimental results

模型	模型大小/MB	参数量/M	<i>GFLOPs</i>	<i>P</i> /%	<i>R</i> /%	<i>mAP</i> /%
RT-DETR	106.2	29.28	105.2	81.0	76.2	83.4
SSD	93.2	26.29	62.7	79.7	67.7	75.6
CenterNet	124.9	32.67	70.2	92.3	85.6	91.9
YOLOv5	5.3	2.50	7.1	95.2	87.3	91.7
YOLOv8n	6.1	3.01	8.2	93.5	85.2	92.1
YOLOv10n	5.8	2.27	6.5	91.3	88.0	94.4
本文	2.9	1.36	5.5	96.1	95.7	97.1

与对比模型相比, KDYOLOv8 在模型复杂度方面表现出明显优势。具体而言, KDYOLOv8 的模型大小仅为 2.9 MB, 参数量为 1.36 M, *GFLOPs* 为 5.5, 均显著小于其他对比模型, 充分体现了其在轻量化设计方面的突出效果, 能够更好地适配算力受限的工业设备与边缘计算环境。

在检测性能方面, KDYOLOv8 的准确率达到 96.1%, 召回率为 95.7%, *mAP* 高达 97.1%, 不仅保持了较小的

模型规模与计算复杂度, 同时在检测精度上实现了进一步提升。

综合来看, 这些结果充分证明了本文所提出的 PCB 缺陷检测模型在轻量化与高精度之间达成了良好的平衡, 具备良好的工程适用性与推广价值, 能够为工业现场 PCB 缺陷的实时高效检测提供有力支持。

3.4 泛化分析

为验证所提出模型的泛化能力, 本文在公开数据集 DeepPCB 上设计并开展了一组实验, 实验结果如表 9 所示。

表 9 DeepPCB 数据集对比实验结果

Table 9 DeepPCB dataset comparison experimental results

模型	鼠咬	短路	毛刺	假铜	针孔	开路	<i>mAP</i>
RT-DETR	94.4	91.2	94.4	94.1	94.1	95.3	94.8
SSD	91.4	93.5	92.7	95.2	93.2	95.3	93.2
CenterNet	98.3	92.3	96.4	97.4	97.1	97.6	96.5
YOLOv5	98.3	94.8	98.3	98.7	97.9	98.5	97.8
YOLOv8n	96.7	95.3	96.8	98.9	97.6	97.9	97.2
YOLOv10n	98.5	94.3	98.0	98.2	97.7	98.1	97.4
本文	98.6	96.9	98.2	98.1	98.0	98.7	98.1

与表 9 中的其他对比模型相比, KDYOLOv8 在 DeepPCB 数据集上表现优异, *mAP* 达到 98.1%, 较基线模型提升 0.9%。特别是在“鼠咬”和“短路”缺陷的检测中, 分别提升了 1.9% 和 1.6%, 显示出较强的细粒度缺陷检出能力。

图 7 展示了 KDYOLOv8 与基线模型在该数据集上的检测结果对比。可以看出, KDYOLOv8 有效缓解了基线模型中存在的漏检与误检问题, 显著提升了检测精度与

稳定性。这充分表明, 所提出的 KDYOLOv8 模型不仅在训练数据集上性能优异, 在不同数据集上的泛化能力同样出色, 具备较强的跨数据集迁移与推广应用潜力。

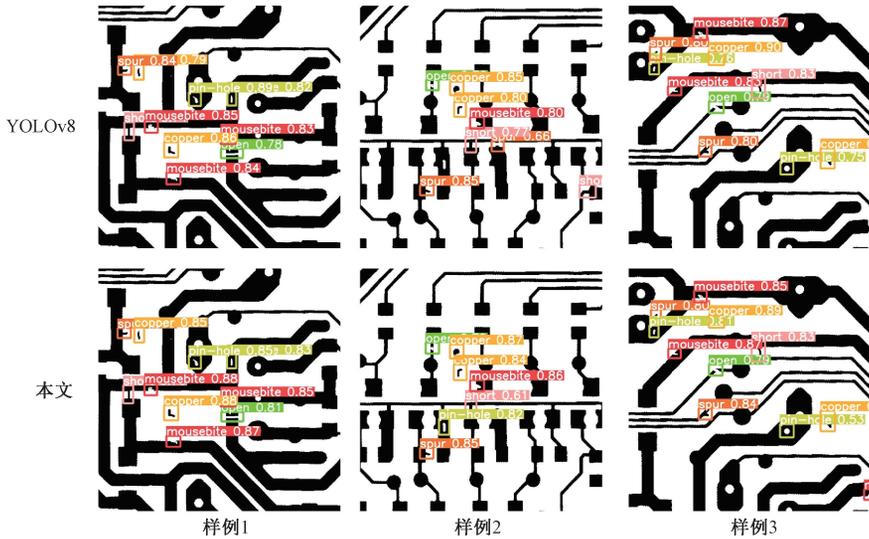


图 7 Deep PCB 数据集检测结果对比

Fig. 7 Comparison of inspection results of Deep PCB datasets

综上, 本文提出的 KDYOLOv8 模型在推理速度与参数体积方面均表现出较好特性, 能够在资源受限的嵌入式 GPU 或 FPGA 平台上^[26]实现低延迟部署, 满足高速在线检测的节拍要求。同时该模型可集成至 AOI 检测工位^[27], 实时捕获图像并于毫秒级内完成缺陷的定位与分类。而 KDYOLOv8 模型在跨数据集泛化能力实验结果预示着模型具备良好的普适性。在部署于新产线时, 仅需少量实际样本进行微调^[28], 即可快速适应新产品特性, 缩短算法的开发与部署周期。因此, 本文提出的 KDYOLOv8 模型能够满足工业现场实时高效的检测需求。

4 结 论

针对资源受限工业环境中部署 PCB 缺陷检测模型时面临的精度与效率难以兼顾的挑战, 本文提出了一种名为 KDYOLOv8 的轻量化目标检测模型。该模型通过精巧的网络架构设计与先进的模型压缩技术深度融合, 实现了在轻量化、检测精度与运行效率三者之间的全面提升和平衡。具体而言, KDYOLOv8 通过引入 Star-YOLO 主干网络、EMBFN 特征融合模块以及 WTConv 小波变换卷积, 显著增强了模型的特征提取能力、多尺度适应性与对复杂场景的鲁棒性。同时, 结合 CWD 通道级知识蒸馏技术, 有效弥补了轻量化带来的精度损失, 进一步提升了检测性能。

实验结果验证了所提出模型的有效性: KDYOLOv8

在公开 PCB 缺陷数据集上取得了 97.1% 的 mAP, 模型体积仅为 2.9 MB, 推理速度高达 117.3 fps, 相较基线模型 YOLOv8n, 模型体积压缩了 52.5%。综上, KDYOLOv8 在模型复杂度、检测精度与推理速度之间达成了优异的平衡, 为算力受限环境下高性能、实时 PCB 缺陷检测提供了一种行之有效的技术解决方案, 具备良好的工程适用性与广阔的实际应用价值。

参考文献

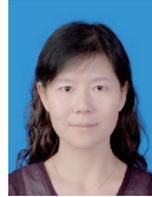
- [1] MITTAL S, KHAN M A, ROMERO D, et al. Smart manufacturing: Characteristics, technologies and enabling factors[J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2019, 233(5): 1342-1361.
- [2] ZHOU Y B, YUAN M H, ZHANG J, et al. Review of vision-based defect detection research and its perspectives for printed circuit board[J]. Journal of Manufacturing Systems, 2023, 70: 557-578.
- [3] 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.
- [4] 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.
- [4] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-

- CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(6): 1137-1149.
- [5] 高嘉, 刘涛, 王显峰, 等. TWRD-Net:一种用于曳引钢丝绳缺陷的实时检测网络算法[J]. *仪器仪表学报*, 2023, 44(6): 223-235.
- GAO J, LIU T, WANG X F, et al. TWRD-Net: A real-time detection network algorithm for traction wire rope defects [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(6): 223-235.
- [6] 黄志海, 邓耀华, 吴光栋. IC 器件表面缺陷多光谱图像特征融合检测方法[J]. *仪器仪表学报*, 2024, 45(9): 24-33.
- HUANG ZH H, DENG Y H, WU G D. Multispectral image feature fusion method for detecting surface defects in IC devices[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(9): 24-33.
- [7] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.
- [8] TAN M X, PANG R M, LE Q V. Efficientdet: Scalable and efficient object detection [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10778-10787.
- [9] 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. PCB defect detection algorithm based on EfficientNetV2[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2025, 37(7): 1260-1269.
- [10] 陈俊英, 李朝阳, 席月芸, 等. ViT 和注意力融合类别不平衡 PCB 缺陷检测方法[J]. *仪器仪表学报*, 2024, 45(4): 294-306.
- CHEN J Y, LI ZH Y, XI Y Y, et al. ViT and attention fusion for class-imbalanced PCB defect detection [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(4): 294-306.
- [11] 郭艳, 王智文, 赵润星. YOLO-POD:基于多维注意力机制的高精度 PCB 微小缺陷检测算法[J]. *电子学报*, 2024, 52(7): 2515-2528.
- GUO Y, WANG ZH W, ZHAO R X. YOLO-POD: High-precision PCB tiny-defect detection algorithm based on multi-dimensional attention mechanism [J]. *Acta Electronica Sinica*, 2024, 52(7): 2515-2528.
- [12] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: Hierarchical vision transformer using shifted windows [C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 9992-10002.
- [13] 陈方彬, 赵仲勇, 王建, 等. 基于 YOLO-MCSL 的轻量化智能电能表热缺陷目标检测方法[J]. *仪器仪表学报*, 2025, 46(8): 108-119.
- CHEN F B, ZHAO ZH Y, WANG J, et al. A lightweight thermal defect detection method for smart electricity meters based on YOLO-MCSL [J]. *Chinese Journal of Scientific Instrument*, 2025, 46(8): 108-119.
- [14] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. *Computer Vision-ECCV 2020*, 2020: 213-229.
- [15] CHEN J, RAN X K. Deep learning with edge computing: A review [J]. *Proceedings of the IEEE*, 2019, 107(8): 1655-1674.
- [16] MA X, DAI X Y, BAI Y, et al. Rewrite the stars [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [17] RAHMAN M M, MUNIR M, MARCULESCU R. Emcad: Efficient multi-scale convolutional attention decoding for medical image segmentation [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 11769-11779.
- [18] FINDER S E, AMOYAL R, TREISTER E, et al. Wavelet convolutions for large receptive fields [C]. *Computer Vision-ECCV 2024*, 2024: 363-380.
- [19] SHU CH Y, LIU Y F, GAO J F, et al. Channel-wise knowledge distillation for dense prediction* [C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 5291-5300.
- [20] YANG L R, ZHOU X P, LI X W, et al. Bridging cross-task protocol inconsistency for distillation in dense object detection [C]. 2023 IEEE/CVF International Conference on Computer Vision, 2023: 17129-17138.
- [21] LI Y X, HOU Q B, ZHENG ZH H, et al. Large selective kernel network for remote sensing object detection [C]. 2023 IEEE/CVF International Conference on Computer Vision, 2023: 16748-16759.
- [22] CAI X H, LAI Q X, WANG Y W, et al. Poly kernel inception network for remote sensing detection [C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern

Recognition, 2024; 27706-27716.

- [23] LIU X Y, PENG H W, ZHENG N X, et al. EfficientViT: Memory efficient vision transformer with cascaded group attention [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023; 14420-14430.
- [24] CHEN J R, KAO S-H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023; 12021-12031.
- [25] HAN K, WANG Y H, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020; 1577-1586.
- [26] AL AMIN R, HASAN M, WIESE V, et al. FPGA-based real-time object detection and classification system using YOLO for edge computing[J]. IEEE Access, 2024, 12: 73268-73278.
- [27] NI Y S, CHEN W L, LIU Y, et al. Optimizing automated optical inspection: An adaptive fusion and semi-supervised self-learning approach for elevated accuracy and efficiency in scenarios with scarce labeled data[J]. Sensors, 2024, 24(17): 5737.
- [28] LYU Z L, YU T, PAN F X, et al. A survey of model compression strategies for object detection[J]. Multimedia Tools and Applications, 2024, 83(16): 48165-48236.

作者简介



刘春娟,1996 年于兰州交通大学获得学士学位,2004 年于兰州交通大学获得硕士学位,现为兰州交通大学教授,主要研究方向为语义分割与变化检测技术应用。

E-mail:liuchj@mail.lzjtu.cn

Liu Chunjuan received her B.Sc. and M.Sc. degrees both from Lanzhou Jiaotong University in 1996 and 2004, respectively. She is currently a professor at Lanzhou Jiaotong University. Her main research interests include the application of semantic segmentation and change detection technology.



吴小所(通信作者),2004 年于兰州交通大学获得学士学位,2011 年于兰州交通大学获得硕士学位,2017 年于兰州大学获得博士学位,现为兰州交通大学副教授,主要研究方向为语义分割与变化检测技术应用。

E-mail:wuxs_laser@lzjtu.edu.cn

Wu Xiaosuo (Corresponding author) received his B.Sc. and M.Sc. degrees both from Lanzhou Jiaotong University in 2004 and 2011, respectively, and his Ph.D. degree from Lanzhou University in 2017. He is currently an associate professor at Lanzhou Jiaotong University. His main research interests include the application of semantic segmentation and change detection technology.