

DOI: 10.13382/j.jemi.B2408001

CCM-YOLO: 一种改进的电路板密集区域 元件检测方法^{*}

吴必胜¹ 高康松¹ 陈松¹ 徐浩飞¹ 谢凯¹ 贺建彪²

(1. 长江大学电子信息与电气工程学院 荆州 434023; 2. 中南大学计算机学院 长沙 410083)

摘要:以 YOLOv5 为基准模型,针对电子元件在电路板上检测容易出现漏检、精度较低的问题。通过使用卷积块注意力模块(convolutional block attention module, CBAM)在进行特征提取过程中提升检测精度,改进边界回归损失函数的方法来改善模型在检测中出现的漏检问题。首先,利用卷积层提取元件的特征信息;其次,在路径聚合网络(path aggregation network, PANet)中引入了 CBAM 模块,既丰富了元件特征信息,又改善了模型精度较低的问题;最后,通过多尺度预测和自适应的锚框来实现对不同尺度元件的准确检测。实验结果表明,改进后的 CCM-YOLO 算法在自制的数据集上的均值平均精度(mean average precision, mAP)值达到 96.8%,它的漏检率达到 4.5%,相较于 YOLOv5 网络均值平均精度的 88.8%,提高了 8.3%的数值,在漏检率上由原基准模型的 13.7%降低了 9.2%。因此,该算法有效提高了检测精度,并显著减少了漏检,为元件检测提供了一种有效的检测方案。

关键词:目标检测;深度学习;电子元件;可分离卷积;YOLOv5

中图分类号: TN609

文献标识码: A

国家标准学科分类代码: 520.20

CCM-YOLO: An improved component detection method for dense regions of circuit boards

Wu Bisheng¹ Gao Kangsong¹ Chen Song¹ Xu Haoifei¹ Xie Kai¹ He Jianbiao²

(1. School of Electronic Information and Electrical Engineering, Yangtze University, Jingzhou 434023, China;

2. School of Computer Science, Central South University, Changsha 410083, China)

Abstract: In this paper, YOLOv5 is used as a benchmark model to address the problem of easy leakage and low accuracy of electronic components detection on circuit boards. The leakage problem of the model in detection is improved by using the convolutional block attention module (CBAM) to enhance the detection accuracy in the process of feature extraction and improving the boundary regression loss function. Firstly, the feature information of components is extracted using convolutional layers. Secondly, the CBAM module is introduced into the path aggregation network (PANet), which enriches the feature information of components and improves the problem of lower accuracy of the model. Finally, accurate detection of components of different scales is achieved by multi-scale prediction and adaptive anchor frames. The experimental results show that the improved CCM-YOLO algorithm achieves a mean average precision (mAP) value of 96.8% on the homemade dataset, and it achieves a leakage detection rate of 4.5%, which is an improvement of 8.3% value compared to the 88.8% of the mean average precision of the YOLOv5 network, and the leakage detection rate is reduced from 13.7% of the original baseline model is reduced by 9.2%. Therefore, the algorithm in this paper effectively improves the detection accuracy and significantly reduces the leakage detection, providing an effective detection scheme for component detection.

Keywords: object detection; deep learning; electronic components; separable convolution; YOLOv5

0 引言

在当今信息爆炸时代,电子产品已成为人类生活不可或缺的组成部分。这些精密设备由数以万计的微型电子元件构成,从微型贴片元件到电路板的组装,均需通过精密焊接工艺实现电气连接。然而,在微米级焊接过程中极易出现焊点虚焊、元件位移等问题,特别是在震动或热应力条件下,电路板上的微型元器件易发生脱落现象,导致产品合格率下降,显著增加人工返修成本与生产损耗。而在工业自动化领域,目标检测技术是实现电路板元件高效识别的关键环节。随着电子设备微型化与集成化的发展,电路板元件呈现高密度分布特性,导致检测过程中易出现遮挡、误检及漏检问题。因此,迫切需要一种高精度、低漏检率的检测方法来提高电路板的自动化生产水平。

对于元件检测早期的传统方法,绝大多数企业采用人工目视检测,但准确率和效率极大地依赖检验人员的工作状态和经验水平,长时间工作会对视力有损伤^[1],且这种持续负面的工作状态使元件检测的漏检率和误检率大幅提高。目前,机器视觉是元件识别的主流技术,边缘检测^[2]等目标检测算法虽然模型简单,但对噪声信息敏感、检测精度低,对于高分辨率图像需要大量计算资源,难以满足元件检测的需求。随着深度学习技术的发展和计算机算力的提升,卷积神经网络(CNN)开始应用于目标检测领域,这在一定程度上提高了目标检测的精度和性能。主流的深度学习目标检测算法又分为两大类。第1类是以 Fast R-CNN^[3]和 Faster R-CNN^[4]为代表的基于两阶段的目标检测算法,该类算法还有 R-CNN^[5]、Mask R-CNN^[6]、R-FCN^[7]、Detecron2 等;第2类是基于单阶段的目标检测算法,这类算法有 SSD^[8]、RetinaNet^[9]、YOLO^[10]、YOLOv2^[11]、YOLOv3^[12]、YOLOv4^[13-14]、YOLOv5^[15-16]等。但检测目标针对的是电路板上的元件,其分布密集,因此要求检测算法能够拥有更高的检测精度。

为了设计精度更高的目标检测算法,学者们对现有算法进行了许多改进,如传统 NMS 进行改进,2017 年, Bodla 等^[17]提出了 Soft-NMS,相较传统 NMS 方法,能够将重叠度较高的检测框筛选出来;2019 年, Liu 等^[18]提出了 Adaptive NMS,它依据目标的密度动态调整抑制阈值,能够更显著地减少了误检情况。检测性能的持续优化必须依托于损失函数的系统性创新,2017 年, Lin 等^[19]提出了 Focal Loss,有效解决了训练过程中的类别不平衡问题;2018 年, Wang 等^[20]提出了 Repulsion Loss,通过引入 Repulsion Loss,检测模型能够减少因遮挡引起的误检和漏检;同一年, Zhang 等^[21]提出了 AggLoss,它有助于减少

相互遮挡而产生的误检;2022 年,吴一全等^[22]提出了多尺度融合、注意力机制等改进方法解决了工业场景下 PCB 缺陷检测的精度与适应性不足的问题;张志杰等^[23]提出了 ETS-Net 轻量化模型与优化策略,解决了电子元器件类间区分度低、实时性差的问题。总体来说,这些改进都提高了检测算法的性能,但在元件检测任务中仍然存在一些问题:1)传统检测算法的漏检率还可以进一步降低;2)传统机器学习算法应用在元件检测的检测精度较低。

为了有效解决电路板上元件的密集分布对元件检测模型性能产生影响的问题,本文以检测性能较好的 YOLOv5 作为基准模型进行进一步的研究和改进,设计出一种新型元件检测算法,改进部分如下:1)在特征融合网络中添加卷积注意力机制模块(convolutional block attention module, CBAM)^[24],以此能有效地提取元件特征信息,增加模型检测的精度;2)用改进的边界回归损失函数替换原边界回归损失函数,能够有效降低模型的漏检率。

1 相关工作

1.1 YOLOv5 算法

YOLOv5 是一种单阶段目标检测算法。它在 YOLOv4 的基础上进行了改进,相比 YOLOv4,它的检测性能提高了。YOLOv5 重新构建了传统的目标检测任务,将其视为一个边界框的回归问题。它接受目标图像并将其作为输入特征,通过模型的输出层,能够输出目标的边界框、类别和位置信息。此外,YOLOv5 还能够实现对目标的实时检测。YOLOv5 结构如图 1 所示。

YOLOv5 的架构由 4 个主要环节构成:数据输入、核心网络、特征融合和目标检测。相较于 YOLOv3 和 YOLOv4 在处理不同目标检测数据集时,其锚框的初始化策略更为先进。它将锚框计算逻辑直接集成在训练过程中,能够自动为不同的数据集调整并确定最佳的锚框参数。这意味着,YOLOv5 无需像其前身那样,依赖额外的程序来预先计算并确定最优的锚框值,从而提高了训练的自动化程度和效率。

主干网络部分^[25](backbone)主要进行特征处理的过程,采用 CSPDarkNet53^[16]网络去处理尺寸不同的特征图。它主要包含 CBS 卷积模块、C3 模块以及 SPPF 模块,CBS 模块有 3 个部分构成,有卷积操作(Conv)、批标准化层(BN)和激活函数层(SiLU)串联构成。批标准化层能防止梯度的消失。而激活函数能一定程度防止网络层数叠加后的梯度爆炸与消失。

处于 Backbone 和头部(head)中间部分的颈部(neck)部分,使用了特征金字塔网络-路径聚合网

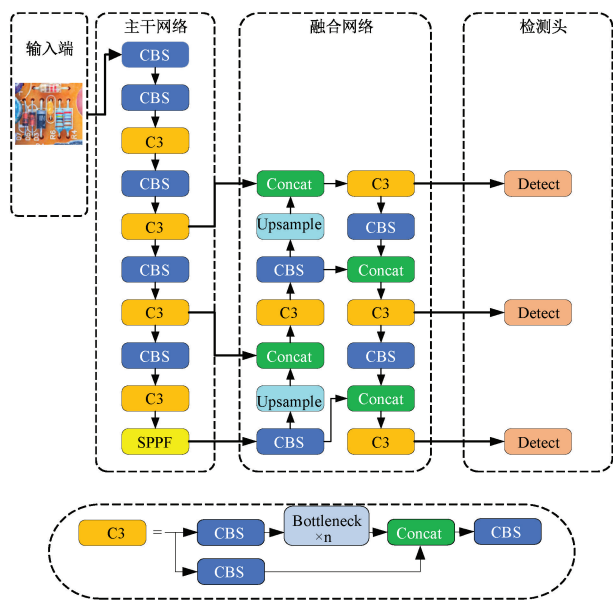


图1 YOLOv5的算法框架

Fig. 1 The module structure of YOLOv5

络(FPN-PAN)结构,FPN结构主要是自顶向下,不仅将高层的语义信息传递下来,还能对其语义信息进行增强,但它对定位信息没有传递。为了弥补这一点,PAN结构就是对FPN的补充,通过自底向上将低层的强定位特征向上传递,它们又被称之为双塔战术,添加它们的目的是在这个地方进行多层次的特征合并。

Head部分通过卷积操作完成目标检测的结果输出。最新版的YOLOv5采用一个新的CIoU (complete intersection over union)^[26]损失函数,该损失函数考虑到了边界框的损失,以解决边界框不重合问题。还考虑到进一步提高检测速度和精度,在原始边界框中间点距离的基础上添加了长宽比的惩罚项,能够更好的将多余且重复的框去掉,通过这种做法提准确率并能使得检测人员更好的进行识别要检测的物品。

为了提高对元件图像目标的检测性能,解决模型漏检、精度较低的问题,根据元件检测模型特点,在YOLOv5模型的基础上进行改进。改进分为两个方面:首先,在特征融合网络中引入CBAM注意力机制模块,改进模型的检测精度;其次,本文设计了一种新型边界回归损失函数,帮助模型向准确度更高的方向靠近,提高模型的收敛速度,并改善网络的漏检问题。改进模型与基准模型相比,检测精度得到提高,漏检问题得到改善。

1.2 CBAM 模块

CBAM模块是一个专为卷积神经网络设计的注意力机制组件。它是一种混合域注意力机制,通过引入了通道注意力模块(CAM)和空间注意力模块(SAM),添加CBAM模块能让算法从图像的全局感受野中有差别地感

知图像信息,关注需要检测的区域,增强模型的检测精度。它结合最大池化和平均池化,弥补了仅使用平均池化过程中缺失的特征信息,CBAM模块结构如图2所示。

在CBAM模块中,输入特征会通过CAM和SAM两个模块,这样可以使模块同时关注空间和通道信息,使网络提取到更丰富、关键的高层特征。CAM会让模型注意力关注特征通道,负责让输入特征图T并行进行最大池化(max pool)和平均池化(avg pool),将得到的两个权重矩阵经过Shared MLP得到特征图 $M_p(T)$ 和 $M_g(T)$,最后经过Sigmoid激活函数得到通道注意力权重 $M_c(T)$,则可以描述为:

$$M_c(T) = \sigma W_1 [W_0(T_{max}^c)] + W_1 [W_0(T_{avg}^c)] \quad (1)$$

式中: σ 为Sigmoid激活函数; T_{max}^c 是经过最大池化后生成的特征图; T_{avg}^c 是经过平均池化后生成的特征图,然后经过“卷积层-ReLU-卷积层”组成的多层感知器(multi-layer perception, MLP) ReLU是一种激活函数,具有负值变0,正值不变的单侧抑制性能,单侧抑制的作用能使神经网络中部分神经元的输出为0,这样能增加网络的稀疏程度,在加快网络训练的同时,在一定程度上减少了过拟合现象的产生。其中 $W_0 \in R^{C/(r \times C)}$ 和 $W_1 \in R^{C \times C/r}$ 分别为MLP中隐藏层和输出层的权重, W_0 后面跟ReLU激活函数, C 为通道数, r 为通道减速比。

SAM会让模型注意力关注有意义的空间位置。CAM的输出会作为SAM的输入,SAM对输入特征图进行最大池化和平均池化,将得到的特征图进行拼接,再通过一个卷积层和Sigmoid激活函数得到空间注意力权重 $M_s(T)$,其原理公式为:

$$M_s(T) = \sigma [f^{(7 \times 7)}(T_{max}^s; T_{avg}^s)] \quad (2)$$

2 改进后的模型 CCM-YOLO

本文以YOLOv5为基准模型,提出一种CCM-YOLOv5算法,改进后的算法结构如图3所示,首先在特征融合网络(path aggregation network, PANet)中原有的C3模块上引入CBAM注意力机制模块,生成CBAM_C3结构,将其命名为CCM(convolutional block attention module with 3 convolutions module)模块,并替换原模型上所有的C3模块。CBAM由通道注意力机制和空间注意力机制两个核心组件构成:通道注意力机制通过建模通道间的依赖关系,实现通道维度自适应特征重标定,能够动态增强与目标元件相关的特征通道响应,抑制产生干扰的通道,赋予模型在具有优秀的多尺度适应性同时拥有良好的抗干扰能力;空间注意力机制通过空间维度的信息聚合,生成空间注意力权重,实现突出目标区域,弱化无关信息的功能,使模型更加适用于元件检测这一具有精细几何特征的目标检测。通过在C3模块中引入

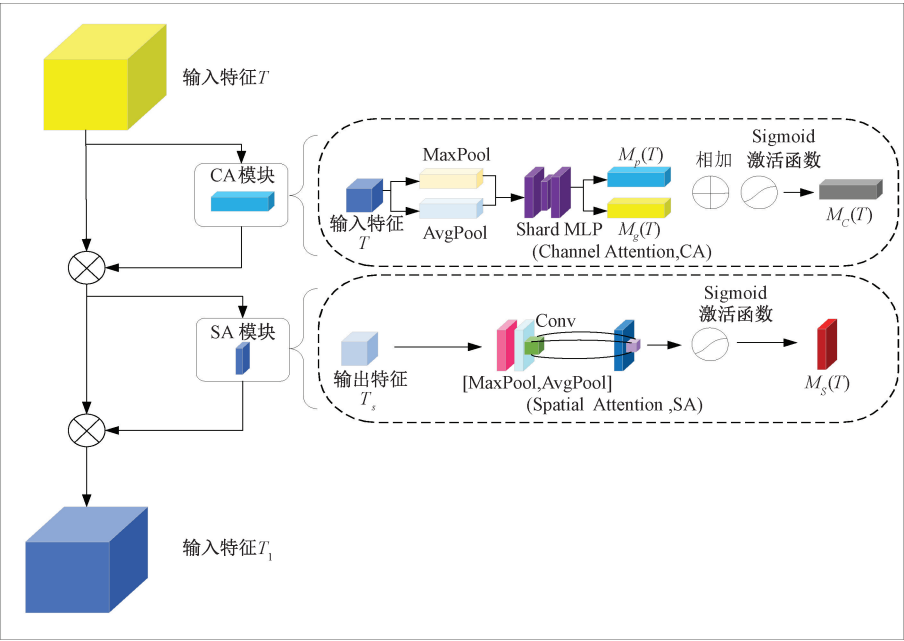


图 2 CBAM 模块结构
Fig. 2 The module structure of CBAM

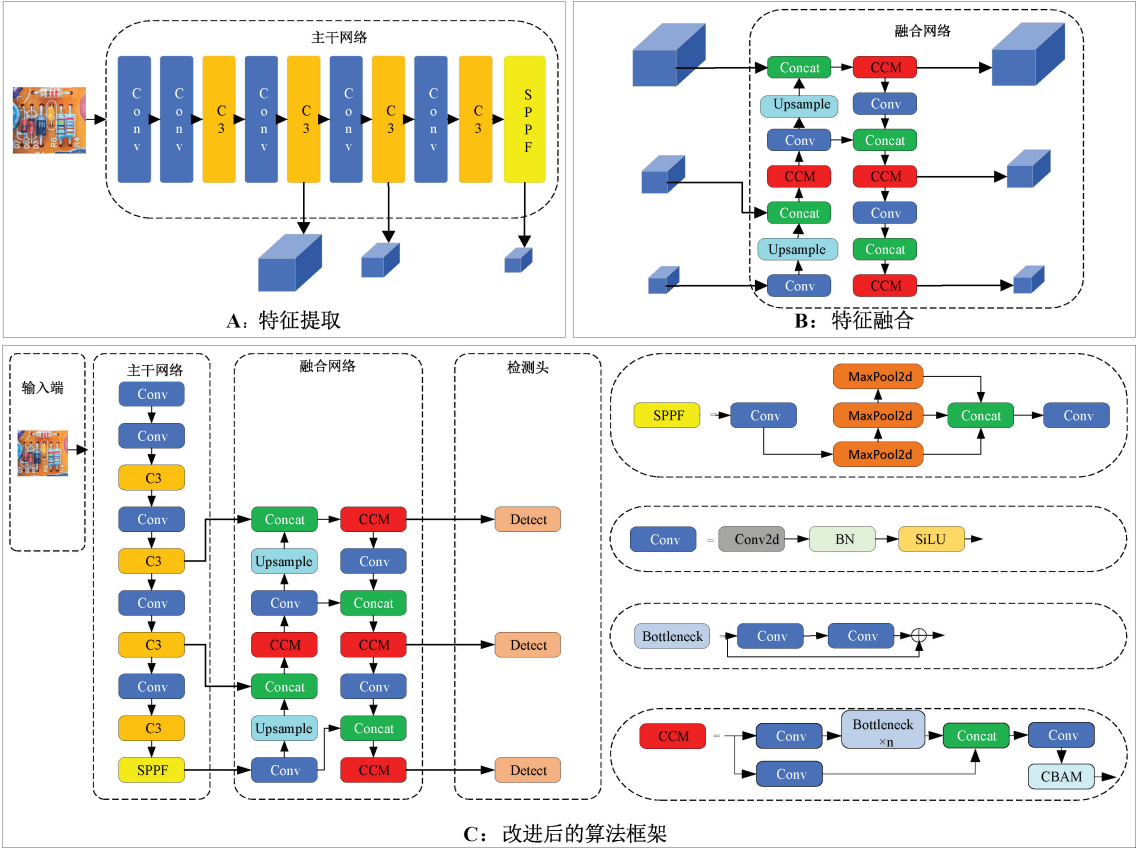


图 3 改进后的算法模型
Fig. 3 The improved algorithm mode

CBAM 能更有效地提取多尺度电子元件的关键特征信息,在保证计算效率的同时改善模型的检测性能这样做能有效捕捉不同形状、不同尺寸的电子元器件更高层、关键的特征信息,提高了特征提取的能力与目标检测的准确性。目标检测中比较新颖的损失函数有 CIoU、DIoU^[26]等。在对常规的检测任务中表现优异,但对于密集电路板上的元器件的检测任务往往会出现很大的遗漏,特别是对又小又密集的元素而言。对于此,考虑到电路板图像存在正负样本不平衡问题,采用基于 Focal Loss 和 DIoU 两种损失函数的思想方法,在边界损失函数中引入权重,降低简单样本带来的影响,增加困难样本的权重,同时考虑预测框和真实框之间的距离和尺度。将该损失函数取名为 Focal-DIoU 损失函数。经过实验证实,在检测头部引入该损失函数这样做既能有效降低元件的漏检率,也能显著提高模型的检测精度。

2.1 CCM 模块

由于元件安装密集,元件之间相互遮挡,一些元件的特征信息较少,导致部分特征信息容易在深层网络中丢失,造成模型检测精度较低等问题。因此,在特征融合网络 PANet 中原有的 C3 模块上引入 CBAM 注意力机制模块,记作 CCM,能有效帮助模型对图片的重要位置和内容进行关注,使元件信息更容易在网络中学习得到,以此改善模型的检测精度,原始的 C3 模块如图 4 所示,添加 CBAM 模块后的 C3 模块如图 5 所示。




图 4 C3 模块结构

Fig. 4 The module structure of C3




图 5 CCM 模块结构

Fig. 5 The module structure of CCM

2.2 Focal-DIoU 损失函数

YOLOv5 模型的边界回归损失只与交并比(intersection over union, IoU)有关,而交并比是一个衡量预测边界框与真实边界框之间重叠程度的指标,通过计算两者交集面积与并集面积的比值来评估预测框的定位精度,即预测框与实际框的匹配程度。

IoU 是介于 0~1 之间的常数^[25]。IoU 越大说明预测与真实两个框的重合度越高,模型预测性能越好。通常

会设定一个固定的 IoU 阈值,来判断预测框的正误性。当 IoU 大于该阈值说明为预测正确的框,相反则是预测错误的框^[25]。为了降低漏检率、提高模型检测精度、提高元件检测网络的收敛速度,本文改进算法的创新之一是基于 Focal Loss^[19]和 DIoU^[26]的思想方法,在边界回归损失中引入权重,降低简单样本带来的影响,增加困难样本的权重,同时考虑预测框与真实框的距离、尺度。具体如式(3)所示。

$$L_{IoU} = \begin{cases} 1 - IoU, & IoU < \alpha \\ R_{DIoU} \times W_1 \times (1 - IoU), & IoU > \alpha \end{cases} \quad (3)$$

式中:预测框用字母 A 表示;真实框用 B 表示;IoU 为交并比;如图 6 所示, R_{DIoU} 为 $\frac{\rho^2(A, B)}{c^2}$, $\rho^2(A, B)$ 是中心点坐标的欧氏距离, c 是最小外接矩形的对角线距离,为了更清楚的展现真实框与预测框。 α 为衡量样本难易程度的标准,通过实验得到衡量样本难度程度的标准值和权重 W_1 , 因此,在实验中设置 α 为 0.45, W_1 为 $0.5 \times e^{-6 \times IoU \times (1 - \alpha)}$, 消融实验的结果证实了该边界回归损失在训练中能够很好地提升模型的元件检测精度、加快元件检测网络收敛,也能降低元件检测网络的漏检率。




图 6 R_{DIoU} 计算示意图

Fig. 6 R_{DIoU} calculation diagram

3 实验结果与分析

3.1 数据集介绍

本文数据集为自建元器件数据集。数据集包括电容、二极管、发光二极管、电阻、晶体管、稳压二极管共 6 种类别,数据集一共 1 691 张图片,按照 8:2 划分为训练集和验证集。

3.2 实验环境搭建

本文实验环境配置及实验参数如表 1 所示。

3.3 评价指标

为了验证模型的可行性和有效性,通常采用不同性能指标对该算法进行综合评估。本文通过选取漏检率(false negative rate, FNR)、精确率(precision)和平均准确率均值(mean average precision, mAP)对元件检测结果进行评价,其具体表达式描述如下。

表 1 实验环境及参数

配置名称	参数
系统	Windows 11 (64 位)
CPU	AMD Ryzen 7 4800H with Radeon Graphics
GPU	NVIDIA GeForce RTX 3050
深度学习框架	Pytorch 2.4.1+cuda 11.8
Optimizer	SGD
初始学习率	0.01
momentum	0.937

Precision 为:

$$Precision = \frac{TP}{TP + FP} \tag{4}$$

精确率代表分类模型预测出 True 样本的准确程度。

召回率 (Recall) 为:

$$Recall = \frac{TP}{TP + FN} \tag{5}$$

召回率代表分类模型识别出真实标签为 True 样本的能力,召回率越高,漏检率越低。

FNR 为:

$$FNR = 1 - Recall \tag{6}$$

漏检率代表模型正确预测负样本纯度的能力。

mAP 为:

$$mAP = \frac{\sum_i^N AP_i}{N} \tag{7}$$

平均准度表示多类别的平均准度的综合评价。

其中,Precision 为真正正确的占总体预测为正的比

例。Recall 为真正正确的占有所有实际为正的比例。mAP 指的是所有类型的平均精度。

3.4 消融实验

为了验证 CCM-YOLO 网络模型各组件的有效性,本文在相同参数条件下定量分析了 CCM 模块、Improved_Liou 损失函数以及双向特征金字塔 (BiFPN) 结构对模型漏检率和 mAP@0.5 的影响,设置输入图像大小为 640×640,训练轮数设置为 100 轮,mAP@0.5 为在 IoU 阈值为 0.5 时的 mAP。其中“√”表示添加相应模块,“×”表示不加模块和不加损失函数,实验结果如表 2 所示。首先,CCM 模块的引入增强了模型对元件的检测能力,其通过优化特征提取机制使漏检率降低了 0.8 个百分点,同时将 mAP@0.5 提升至 92.6%,证明该模块能有效改善复杂工业场景下的目标表征能力。其次,结合 Improved_Liou 损失函数后,模型性能得到进一步优化,mAP@0.5 和 Recall 指标分别提升至 97.1%和 95.5%,较基准模型实现了 8.3%和 9.2%的显著提升,这表明改进后的损失函数通过优化边界框回归过程,有效增强了模型对元件细节特征的捕捉能力。而当引入 BiFPN 进行多尺度特征融合时,模型在复杂背景下的精确率下降了 2.3%。通过消融实验,最终确定最优模型架构为 CCM 模块与 Improved_Liou 损失函数的组合方案。其在保持 96.8%高精确率的同时,将漏检率控制在 4.5%,较原始模型降低 9.2%。综上所述,基准模型融合 CCM 模块和 Improved_Liou 后,不仅有效解决了遮挡导致的漏检问题,同时通过增强特征判别性抑制了复杂背景干扰,为工业视觉检测任务提供了新的技术路径。

表 2 消融实验结果
Table 2 Ablation results

YOLOv5	CCM	Improved_Liou	BiFPN	Precision/%	Recall/%	mAP@0.5/%
√	×	×	×	87.8	86.3	88.8
√	√	×	×	92.6	87.1	92.6
√	×	√	×	90.7	88.0	93.1
√	√	×	√	90.3	87.4	91.8
√	√	√	×	96.8	95.5	97.1

3.5 边界回归损失函数收敛曲线

图 7 为基准算法和改进后的边界回归损失函数随着训练次数的收敛情况。通过下图对比可发现改进后的边界回归损失函数下降明显,改进后的网络整体收敛速度快于 YOLOv5 基准算法。

3.6 对比实验

为了进一步验证 CCM-YOLO 网络模型在元件检测方面的优越性和有效性,将改进后的算法与主流目标检测算法 YOLOv3^[12]、YOLOv5^[16]、Faster R-CNN^[3] 以及

YOLOv5-SE^[27]、YOLOv5-ECA^[28] 进行对比实验,网络设置输入图像大小为 640×640,训练轮数共 100 轮。使用 FNR、Precision、Recall、mAP@0.5 这 4 项指标进行对比,结果如表 3 所示。

从表 3 可以看出,在相同的参数下,本文在基准模型 YOLOv5 上融合了 3 种不同的注意力机制:YOLOv5-SE、YOLOv5-ECA、YOLOv5-CBAM。从表 3 数据可知,YOLOv5 在加入 SE^[27]、ECA^[28] 两种注意力机制后 4 项指标均有一定程度的降低,主要由于 SE 模块缺少空间注意力机制,当元件与背景在通道响应上相似时,其无法通过

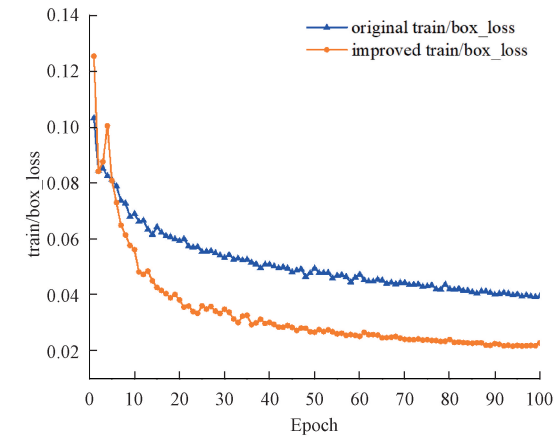


图 7 原始模型与改进模型的边界回归损失函数曲线

Fig. 7 Boundary regression loss function curves for the original and improved models

空间区分导致特征混淆;ECA 模块对于空间维度信息不敏感,缺少对整个图像场景的全局理解,因此抗干扰能力较差,易误将背景中的类似物体当作目标。本文算法在元件检测上的 mAP@0.5 值优于其他方法,同时其漏检率降低至 4.5%。本文算法 CCM-YOLO 与 YOLOv3、YOLOv5 相比,各项指标都得到了显著的提升;与 Faster-RCNN 相比,虽然在精确率指标上存在 0.2% 的微小差异,但在其他关键性能指标上均表现出显著优势。CCM-YOLO 与原始网络 YOLOv5 相比, mAP@0.5 提升了 8.3%,精确率提升了 9%,召回率提升了 9.2%。结果表明,CCM-YOLO 与其他模型相比具有更好的检测性能,在元件尺度差距较大、细小特征较多的检测任务中具有显著优势。

表 3 对比实验结果

Model	FNR	Precision	Recall	mAP@0.5
YOLOv3	31.2	86.7	68.8	82.5
YOLOv5	13.7	87.8	86.3	88.8
YOLOv5-SE	35.6	76.1	64.4	75.3
YOLOv5-ECA	31.4	85.6	68.6	82.9
YOLOv5-CBAM	12.9	92.6	87.1	92.6
Faster R-CNN	10.9	97.0	89.1	94.9
本文	4.5	96.8	95.5	97.1

3.7 模型实际预测结果

为了直观地描述出 CCM-YOLO 网络模型的检测效果,将改进前后模型在测试集上的检测结果图进行了直观的对比,如图 8 所示。首先,通过对比图可知由 YOLOv3 检测后的图 8(b1)左下角的晶体管、图 8(b2)左下角的二极管以及图 8(b3)中的两个黑色电容和左下角的电阻均未被检出;而由基准模型的 YOLOv5 检测后的图 8(c1)左上角的晶体管、图 8(c2)左下角的二极管以

及图 8(c3)左上角的电阻和右上角的电容未被检出。显然,本文算法优于前面两种模型的检测结果。其次,对比 YOLOv3、YOLOv5 两种模型的检测结果,本文算法的检测结果在置信度这一指标上表现出明显的优势。




图 8 模型实际预测结果

Fig. 8 The model actually predicts the results

4 结 论

本文针对元件检测过程中出现的漏检、精度较低的问题,基于 YOLOv5 算法提出了引入 CBAM 与 C3 结合的 CCM 模块、改进边界回归损失函数的元件检测算法。通过在原生 YOLOv5 头部网络中引入 CBAM 模块,与 C3 模块结合,提高模型对图片的重要位置和内容的关注度,将模型注意力集中在元件关键特征上,改善模型检测精度。通过改进边界回归损失函数,帮助模型的元件检测精度得到提升、改善模型漏检问题、加快元件检测网络收敛。实验结果验证了本文算法的有效性,其表明,本文模型收敛速度较快、检测精度较高,并且降低了漏检率,均优于其他传统深度学习元件检测算法,对元件检测提供了一定的参考价值。本文算法在轻量化上仍有较大进步空间,未来将会沿着当前的进展继续研究。

参考文献

[1] 马志程, 李丹, 张宝龙. 基于改进 Mask R-CNN 的光学元件划痕缺陷检测研究[J]. 电子测量与仪器学报, 2023, 37(4): 231-239.

MA ZH CH, LI D, ZH B L. Research on scratch defect detection of optical elements based on improved Mask R-CNN [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 231-239.


[2] YU X, LIN X, DAI Y, et al. Image edge detection

- based tool condition monitoring with morphological component analysis [J]. ISA transactions, 2017, 69: 315-322.
- [3] GIRSHICK R. Fast R-CNN[J]. ArXiv preprint arXiv: 1504.08083, 2015.
- [4] REN S, HE K, 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] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2014: 580-587.
- [6] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision. 2017: 2961-2969.
- [7] DAI J, LI Y, HE K, et al. R-FCN: Object detection via region-based fully convolutional networks [J]. Curran Associates Inc. 2016, DOI: 10. 48550/arXiv. 1605.06409.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11 - 14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [9] KANG M, JI K, LENG X, et al. Contextual region-based convolutional neural network with multilayer fusion for SAR ship detection [J]. Remote Sensing, 2017, 9(8): 860.
- [10] REDMON J. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016.
- [11] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 7263-7271.
- [12] REDMON J. YOLOv3: An incremental improvement[J]. ArXiv preprint arXiv:1804.02767, 2018.
- [13] 张明路, 郭策, 吕晓玲, 等. 改进的轻量化 YOLOv4 用于电子元件检测[J]. 电子测量与仪器学报, 2021, 35(10): 17-23.
- ZHANG M L, GUO C, LYU X L, et al. Improved lightweight YOLOv4 for electronic component detection [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 17-23.
- [14] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [15] 侯艳丽, 唐博华. 基于改进 YOLOv5 的 PCB 缺陷检测算法[J]. 国外电子测量技术, 2023, 42(11): 24-32.
- HOU Y L, TANG B H. PCB defect detection algorithm based on improved YOLOv5 [J]. Foreign Electronic Measurement Technology, 2023, 42(11): 24-32.
- [16] LI X, WANG C, JU H, et al. Surface defect detection model for aero-engine components based on improved YOLOv5[J]. Applied Sciences, 2022, 12(14): 7235.
- [17] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS—improving object detection with one line of code [C]. Proceedings of the IEEE International Conference on Computer Vision. 2017: 5561-5569.
- [18] LIU S HUANG D, WANG Y. Adaptive nms: Refining pedestrian detection in a crowd [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 6459-6468.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. Proceedings of the IEEE International Conference on Computer Vision. 2017: 2980-2988.
- [20] WANG X, XIAO T, JIANG Y, et al. Repulsion loss: Detecting pedestrians in a crowd [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7774-7783.
- [21] ZHANG S, WEN L, BIAN X, et al. Occlusion-aware R-CNN: Detecting pedestrians in a crowd [C]. Proceedings of the European Conference on Computer Vision (ECCV). 2018: 637-653.
- [22] 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 on PCB defect detection algorithm based on machine vision: Current status and prospects [J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 1-17.
- [23] 张志杰, 顾寄南, 李静, 等. 基于深度学习的电子元件快速检测算法研究 [J]. 电子测量技术, 2022, 45(10): 93-101.
- ZHANG ZH J, GU J N, LI J, et al. Research on the fast detection algorithm of electronic components based on deep learning [J]. Electronic Measurement Technology, 2022, 45(10): 93-101.
- [24] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C]. Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.
- [25] 杨永跃, 夏远超. PCB 缺陷检测深度学习算法的精度改进 [J]. 电子测量与仪器学报, 2023, 37(5): 11-19.

YANG Y Y, XIA Y CH. Accuracy improvement of deep learning algorithm for PCB defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 11-19.

- [26] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [27] 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.
- [28] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 11534-11542.

作者简介



吴必胜, 2022 年于长江大学获得学士学位, 现为长江大学硕士研究生, 主要研究方向为深度学习与图形图像处理。

E-mail: 2429536349@qq.com

Wu Bisheng received his B. Sc. degree from Yangtze University in 2022. He is now a M. Sc. candidate in Yangtze University. His main research interests include deep learning and graphics and image processing.



高康松, 现为长江大学本科生, 主要研究方向为深度学习与计算机视觉。

E-mail: 1391578495@qq.com

Gao Kangsong is now a B. Sc. candidate at Yangtze University. His main research interests include deep learning and computer

vision.



陈松, 2019 年于长江大学获得学士学位, 现为长江大学硕士研究生, 主要研究方向为图像处理与深度学习。

E-mail: webflex_cs@163.com

Chen Song received his B. Sc. degree from Yangtze University in 2019. He is now a M. Sc. candidate at Yangtze University. His main research interests include image processing and deep learning.



贺建彪, 1989 年于华中科技大学获得硕士学位, 现为中南大学副教授, 主要研究方向为人工智能与计算机视觉。

E-mail: hejianbiaopaper@163.com

He Jianbiao received his M. Sc. degree from Huazhong University of Science and Technology in 1989. He is now an associate professor at Central South University. His main research interests include artificial intelligence and computer vision.



谢凯(通信作者), 2006 年于上海交通大学获得博士学位, 现为长江大学教授, 主要研究方向为信号与信息处理、图形图像处理、人工智能以及大数据分析。

E-mail: pami2009@163.com

Xie Kai (Corresponding author) received his Ph. D. degree from Shanghai Jiao Tong University in 2006. He is now a professor at Yangtze University. His main research interests include signal and information processing, graphics and image processing, artificial intelligence, and big data analysis.



徐浩飞, 现为长江大学本科生, 主要研究方向为深度学习与计算机视觉。

E-mail: 3172187554@qq.com

Xu Haofei is now an B. Sc. candidate at Yangtze University. His main research interests include deep learning and computer vision.