

DOI:10.19651/j.cnki.emt.2209991

基于改进 YOLOv4-tiny 的印刷电路板缺陷检测研究

马进 王超

(华北电力大学自动化系 保定 071003)

摘要: 印刷电路板是众多电子产品的核心和最基本的组成部分,其缺陷检测存在复杂度高和缺陷目标较小的特点,提出一种改进 YOLOv4-tiny 的印刷电路板缺陷检测方法,在满足检测速度的前提下,提高检测精度。首先,在主干网络的基础上添加空间金字塔池化模块,减少网络参数和提高网络预测速度的同时利用图像的局部和全局特征融合多重感受野;其次,在 FPN 部分增加卷积注意力模块,进一步增强不同阶段的特征融合效果,提升对小目标缺陷的目标检测准确度;最后,使用 Adam 优化器以提升回归过程的收敛速度与准确性,同时使用余弦退火衰减和标签平滑策略优化网络损失函数,以抑制网络训练过程中的过拟合问题。通过使用改进算法在印刷电路板缺陷数据集上进行对比实验验证表明,该文算法模型大小仅为 22.85 M,平均检测精度均值较原算法提升了 13.38%,检测速度达到了 149.03 FPS(on GeForce RTX3060),具有较好的有效性和可行性。

关键词: 印刷电路板;缺陷检测;小目标;卷积注意力;Adam 优化器

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Research on printed circuit board defect detection based on improved YOLOv4-tiny algorithm

Ma Jin Wang Chao

(Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: Printed circuit boards are the core and most basic components of many electronic products, and their defect detection has the characteristics of high complexity and small defect targets. An improved YOLOv4-tiny printed circuit board defect detection method is proposed to meet the detection speed. On the premise of improving the detection accuracy. First, a spatial pyramid pooling module is added to the backbone network to reduce network parameters and improve network prediction speed while using the local and global features of the image to fuse multiple receptive fields; secondly, add a convolutional block attention module in the FPN part to further Enhance the effect of feature fusion at different stages and improve the accuracy of target detection for small target defects. Finally, Adam optimizer is used to improve the convergence speed and accuracy of the regression process, and the cosine annealing decay and label smoothing strategies are used to optimize the network loss function. In order to suppress the overfitting problem during network training. By using the improved algorithm to conduct comparative experiments on the printed circuit board defect data set, it shows that the weight file of the algorithm in this paper is only 22.85 M, the average detection accuracy is improved by 13.38% compared with the original algorithm, and the detection speed reaches 149.03 FPS (on GeForce RTX3060)., with better effectiveness and feasibility.

Keywords: printed circuit board; defect detection; small object; attention mechanism; adam optimizer

0 引言

印刷电路板是大多数电子产品最基本的一项组件,但是由于生产过程中存在处理不当或技术故障,许多印刷电路板会产生短路、漏孔、余铜、毛刺、缺口、开路等复杂多变的缺陷^[1]。随着电子产品的普及,必须以高精度设计和制

造以满足需求和要求,但是保证质量达到标准却是一项具有挑战性的工作,因此通过研究和开发新的印刷电路板缺陷检测方法来实现对印刷电路板的质量控制具有重要意义。目前,印刷电路板缺陷检测主要还是依靠人工目视主观判定法、仪器线上检测法和功能测试法等传统的方法检测^[2]。传统的方法难以应对具有多样种类缺陷的印刷电路

板,而且在传统的检测流程之后必然会涉及大量人力进行质量检测,需要依赖训练有素的技术人员,并且准确性不一致导致消耗更多时间,检测效率和检测速度低下,从而延迟生产。

与传统方法相比,随着图像识别和目标检测的蓬勃发展,使用深度学习的图像检测技术在印刷电路板缺陷检测中可以达到更高的效率和更好的准确度^[3-4]。近年来提出了很多使用深度卷积神经网络去检测印刷电路板缺陷的方法^[5-7],其中较为成熟的算法可以分为两大类:一类是以 Faster RCNN 为代表的两阶段检测算法^[8],例如:Chen 等^[9]通过在 Faster RCNN 网络中引入多注意力机制实现了在噪声干扰下的印刷电路板缺陷检测。另一类是以 SSD 和 YOLO 为代表的单阶段检测算法^[10-11],例如:李闻等^[12]提出了一种改进 YOLO-v3 算法的缺陷检测网络,通过增加 SE Block 模块实现不同的特征通道重要程度不同,从而提高了印刷电路板缺陷检测的性能;李澄非等^[13]提出了一种在 YOLO-v4 基础上改进的缺陷检测算法,通过进一步提升网络的特征提取能力,实现了对印刷电路板的缺陷检测。但是这些网络不断变得更加复杂,权重参数和计算成本越来越高。这不仅使得在现实生活中将这些模型部署到工业检测的设备上变得越来越困难,而且随着网络的加深导致更加关注高层语义信息,忽视了细节信息的重要性,但是对于缺陷检测来说细节是很重要的信息。

因此,研究一种在不影响缺陷检测质量情况下更加高效快速的缺陷检测模型至关重要。针对这些问题该文提出

了一种基于改进 YOLOv4-tiny 的缺陷检测模型,它在保持检测速度的同时平均精确度明显提升,并减少了参数数量和计算成本。该文所提出的算法在印刷电路板缺陷数据集评估的平均精确度达到了 97.53%,与 YOLOv4 相比模型大小减少了 221.64 M,检测速度提升了 108.74 FPS,而平均精确度仅降低了 0.12%。

1 基于 YOLOv4-tiny 算法的检测模型

YOLOv4 是一个一阶段的目标检测算法,在 YOLOv3 的基础上增加了很多提升模型性能的方法,为 YOLOv3 的改进版本^[14]。而 YOLOv4-tiny 是 YOLOv4 的简化版,是一种适用于嵌入式平台的轻量级实时检测算法,分为特征提取、特征融合和检测头三个部分,网络结构如图 1(a)所示。其特征提取网络使用的是 CSPDarkNet53-tiny 结构^[15],由 3 个 CBL 模块和 3 个 Resblock 模块构成,采用 Leaky Relu 激活函数,网络结构分别如图 1(b)和(c)所示;接着在特征提取后使用特征金字塔网络(feature pyramid network,FPN)进行特征融合;YOLOv4-tiny 的检测头部分由 YOLOv4 的 3 个分支改为了两个,取 13×13 和 26×26 两种不同比例的特征图去进行目标的预测,虽然检测精度有所降低,但是参数量显著减少和检测速度大大增加。

2 改进 YOLOv4-tiny 算法的印刷电路板缺陷检测模型

改进后的网络结构如图 2 所示。

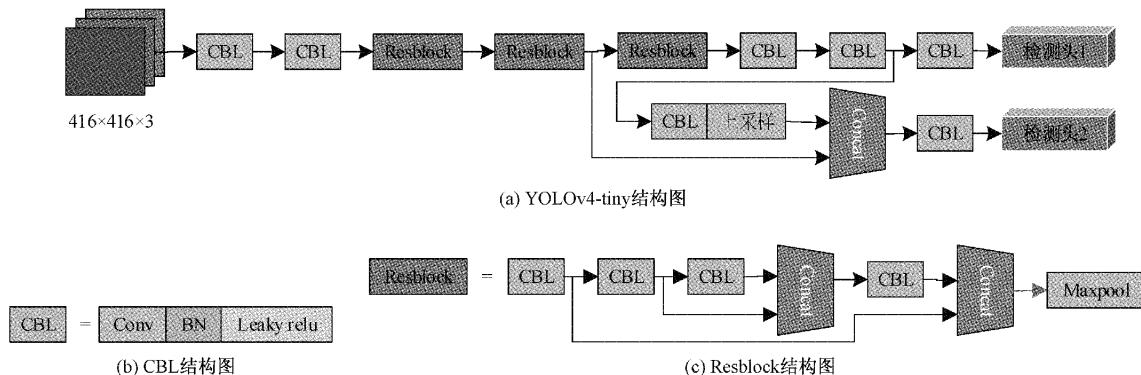


图 1 YOLOv4-tiny 结构图

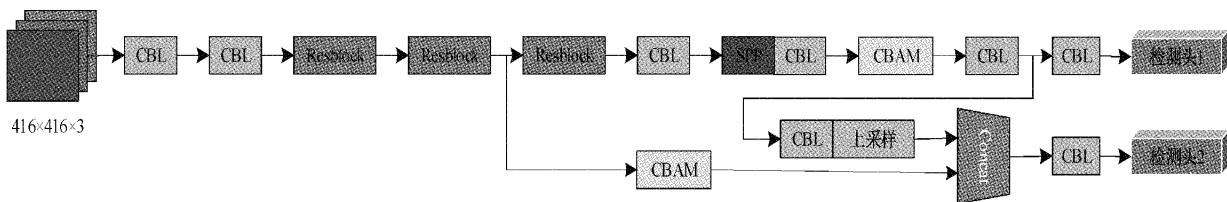


图 2 改进的 YOLOv4-tiny 结构

2.1 空间金字塔池化结构

在实际中,网络中往往要求全连接层的输入特征数是固定的,因此需要输入固定大小的图像,而输入的图像大

小并不会统一,所以图像在输入前需要改变原有的纵横比和尺寸,从而导致原始的图像会发生变形。而 He 等^[16]在这里提出了一个空间金字塔池化层(spatial pyramid

pooling, SPP)能很好的解决这种问题,结构如图 3(a)所示。SPP 不仅不需要输入图片的尺寸发生改变之后再进行输入,而且可以产生要求大小的输出。SPP 也可以在输入改变了尺寸的同一图像后得到相同大小的池化特征,不仅提高了网络的泛化能力,也使得网络变得更加容易收敛,在目标检测算法中 SPP 是对高层特征进行多尺度池化以增加感受野的重要措施之一。

由于印刷电路板背景复杂而且缺陷属于较小目标的检测,而原 YOLOv4-tiny 网络模型的特征提取网络 CSPDarknet53-tiny 并不能充分利用各尺度信息,故该文在原 CSPdarknet53-tiny 的最后一个卷积后面增加了改进后的 SPP 模块,增强模型对小缺陷的特征提取能力,结构如图 3(b)所示。改进后的 SPP 模块将原 SPP 模块池化核大小改为利用 13×13 、 9×9 、 5×5 、 1×1 四种不同尺度的最大池化进行处理,它能够极大地增加感受野,分离出最显著的上下文特征,最后通过在其后面增加 1×1 的卷积模块来减少参数量和提高检测速度。

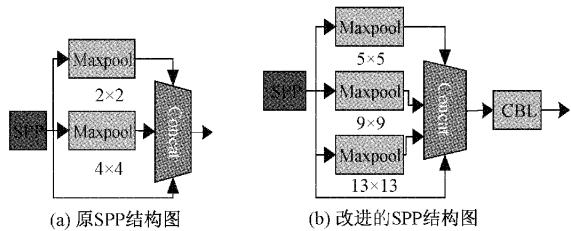
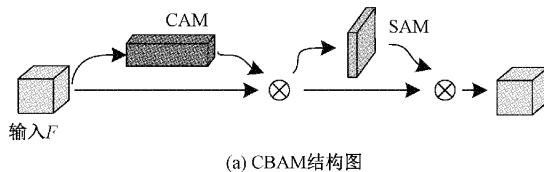


图 3 SPP 结构图



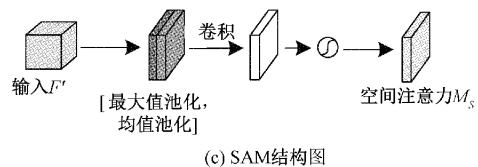
(a) CBAM 结构图

$$F' = M_c(F) \otimes F \quad (1)$$

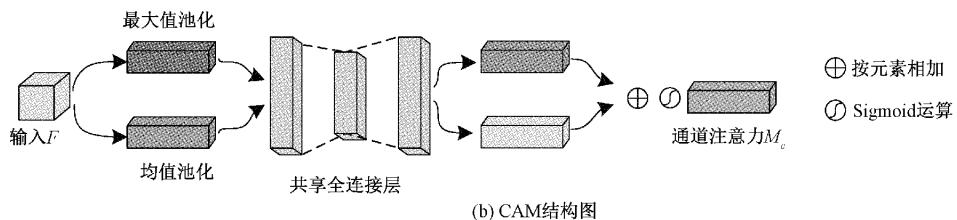
$$F'' = M_c(F') \otimes F' \quad (2)$$

一个通道都代表着一个专门的检测器,CAM 用来关注什么样的特征是有意义的,为了汇总空间特征,CAM 采用了全局平均池化和最大池化两种方式分别处理不同的信息。接着在 CAM 模块之后再引入 SAM,用来关注哪里的特征是有意义的。为了更好的节省参数量和提升检测速度,该文提出了改进的 CBAM,用卷积块将 CBAM 中 CAM 模块的共享全连接层代替,结构如图 5 所示。

在 YOLOv4-tiny 中,FPN 结构用于对输出的两个有效要素图层执行简单的要素融合,导致小目标相关信息极度缺乏。而印刷电路板缺陷属于小目标范围的检测,最终导致检测性能较差,所以该文在原 YOLOv4-tiny 网络的



(c) SAM 结构图



(b) CAM 结构图

图 4 CBAM 结构图

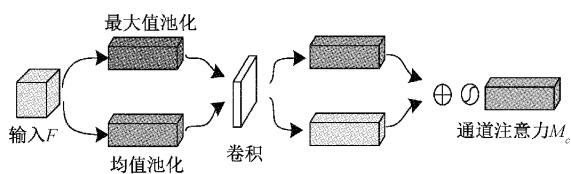


图 5 改进的 CAM 结构图

FPN 部分插入改进的 CBAM,用 CBAM 强化小目标特征信息,并抑制不必要的背景噪声。其过程为:首先通过改

进的 CAM 以更快的速度将注意力关注在比较有意义的内容特征上,随后与通过 SAM 关注到的有意义特征的位置信息结合起来,从而提升网络检测小缺陷的准确度和性能。在这一部分中,基于 YOLOv4-tiny 网络的 FPN 引入了改进的注意力模块增强 FPN 的特征融合能力,能够很好地学习利用缺陷区域的信息,增强模型的表达能力并从中聚合特征,同时实现小缺陷、密集缺陷、模糊缺陷等较难检测缺陷的特征增强,降低复杂背景的干扰,更好地捕获特征原有的丰富信息,从而进一步提高整体精度。

2.3 Adam 优化器

深度学习的任务就是优化参数使之达到最合适的值, 同时也就是使损失函数达到最小。损失函数即目标函数的值与真实值的差值函数, 而优化器的任务就是在网络训练的每一轮中计算损失函数的梯度, 进而更新参数。Adam 优化器是一种在深度学习模型中用来替代随机梯度下降的优化算法^[18-19], 在全面考虑梯度的一阶矩估计和二阶矩估计后, 计算出更新步长。不仅具有计算高效的优点, 而且梯度的伸缩变换并不会对参数的更新造成影响, 也能够使更新的步长在一定的区间内变化, 吸收了自适应学习率的梯度下降算法和动量梯度下降算法的优点, 既能适应稀疏梯度, 又能缓解梯度震荡的问题。一般过程描述如式(3)~(8)所示, 式(3)表示时间步长为 t 的随机目标, 式(4)和式(5)分别为对梯度的一阶矩估计和二阶矩估计, 式(6)和式(7)分别用来修正一阶矩估计和二阶矩估计, 式(8)用来更新参数。其中 t 为时间步长, $f(\theta)$ 是参数 θ 为的随机目标函数, g_t 为梯度, μ 和 ν 为矩估计的指数衰减率, m 为一阶矩估计, n 为二阶矩估计, η 为学习率, ϵ 为保证分母非 0 的常数。

$$g_t = \nabla_{\theta} f_t(\theta_{t-1}) \quad (3)$$

$$m_t = \mu \times m_{t-1} + (1 - \mu) \times g_t \quad (4)$$

$$n_t = \nu \times n_{t-1} + (1 - \nu) \times g_t^2 \quad (5)$$

$$\hat{m}_t = \frac{m_t}{1 - \mu^t} \quad (6)$$

$$\hat{n}_t = \frac{n_t}{1 - \nu^t} \quad (7)$$

$$\Delta\theta_t = -\frac{\hat{m}_t}{\sqrt{\hat{n}_t} + \epsilon} \times \eta \quad (8)$$

2.4 学习率余弦退火衰减

余弦退火是一种在训练过程中通过余弦函数来调整学习率的方法^[20], 随着训练周期的增加, 余弦函数中随着变量值的增加余弦值首先急速下降, 然后加速上升, 再次急速下降, 然后不断重复这个过程。当损失值逐渐接近全局最小值时, 学习率应该变得更小从而使损失值更加接近最小值, 而余弦退火中的下降模式可以和学习率配合, 以一种十分有效的计算方式来产生很好的效果。余弦退火

方法的目的在于逃离当前局部最优点, 寻找新的局部最优点。在每个周期计算完成后, 保存不同局部最优点的模型参数。余弦退火衰减的原理如式(9)所示, 其中, i 当前迭代次数, η 为学习率, η_{\max} 最大学习率, η_{\min} 最小学习率, T_{cur} 重启后的迭代次数, T_i 当前的训练周期数。

$$\eta_t = \eta_{\min} + \frac{1}{2} (\eta_{\max} - \eta_{\min}) (1 + \cos(\frac{T_{\text{cur}}}{T_i} \pi)) \quad (9)$$

2.5 标签平滑

在深度学习的样本训练过程中, 由于只考虑到训练样本中正确标签位置的损失, 忽略了错误标签位置的损失, 从而导致训练的模型在训练集上拟合的很好, 但是预测的时候错误率较大。为了解决这一问题, 标签平滑的正则化方法便应运而生^[21], 以此提高模型的泛化能力, 其计算公式如式(10)所示, 其中 y' 为标签平滑操作后的样本标签, y 为标签平滑操作前的样本标签, ϵ 为平滑因子, u 为总类别数。

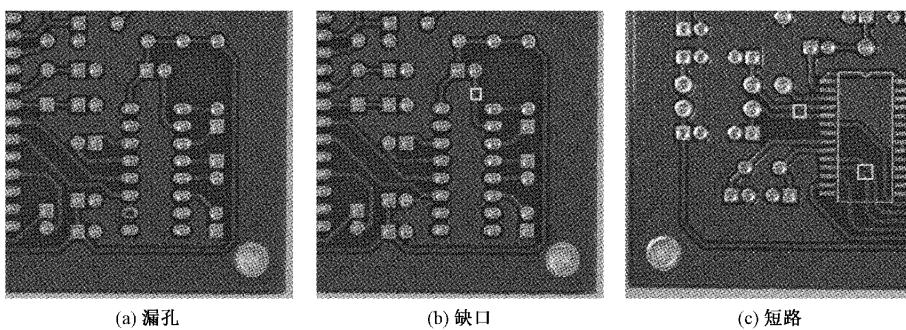
$$y' = (1 - \epsilon) \times y + \frac{\epsilon}{u} \quad (10)$$

标签平滑是一种正则化技术, 它将目标向量改变少量, 限制了分类函数的最大概率使得最大概率不会比其他标签大得多, 从而使模型对其预测的确定性降低。此时可以看出, 平滑过后的样本训练中不仅权衡训练样本中正确的标签位置的损失, 同时也权衡了错误标签位置的损失, 即在训练时假设标签可能存在错误, 避免过度相信训练样本的标签, 从而使模型的学习能力提高。

3 实验及结果分析

3.1 实验数据集

实验中使用的数据集来自于北京大学智能机器人开放实验室公开的印刷电路板缺陷数据集^[22], 共有 10 668 张图片, 漏孔 (missing hole)、缺口 (mouse bite)、短路 (short)、开路 (open circuit)、余铜 (spurious copper)、毛刺 (spur) 6 种缺陷类别, 这些缺陷是由不同的原因造成的, 表现出的不同特征主要包括色彩特征和形状特征, 分别如图 6 所示。其中包括 8 640 幅训练图像、961 幅验证图像和 1 067 幅测试图像。



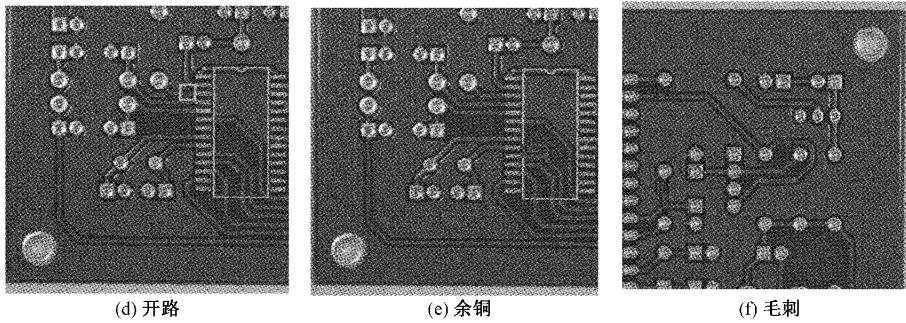


图 6 六种缺陷图

3.2 评价指标

该文将平均精度均值 (mean average precision, mAP)、查全率(recall, R)、R 曲线、模型大小和每秒传输速率(frames per second, FPS)指标去评价算法的优劣、检测精度和检测速度。

平均精度(average precision, AP)是对某类缺陷的查准率-查全率(precision-recall, P-R)曲线进行积分得到的面积,公式如式(11)所示,其中 i 表示某一类缺陷, $P(R)$ 是查准率与查全率之间的映射关系,反映了分类器对正例的识别准确程度和对正例的覆盖能力之间的权衡。而 mAP 为对每一类缺陷的平均精度求其平均值,是评价训练模型在所有缺陷类别总体上的好坏,是多类缺陷检测中一个十分重要的指标,公式如式(12)所示,其中 N 为缺陷类别数。

$$AP_i = \int_0^1 P(R) dR \quad (11)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (12)$$

查全率就是某种缺陷中被正确预测的数量与该缺陷样本总数的比值,代表着模型可以找出数据集中更多的缺陷,查全率越高,那么模型的性能就越好,公式如式(13)所示,其中 TP 表示缺陷类别与缺陷真实标签都为 i 的样本量, FN 表示缺陷类别不为 i 但是缺陷真实标签为 i 的样本量。

$$R_i = \frac{TP}{TP + FN} \quad (13)$$

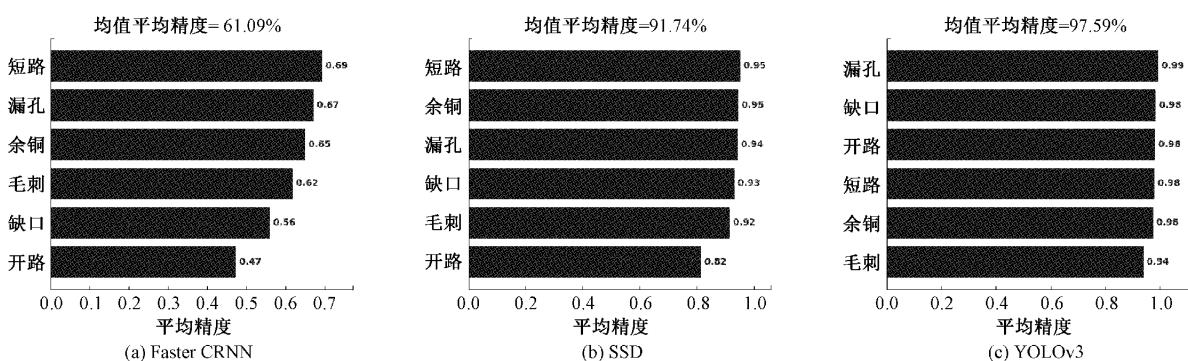
FPS 指画面每秒传输帧数,如果 FPS 值较低就会导致检测画面卡顿,相反检测画面就越流畅,对于实时性检测来讲是一个十分重要的指标。

3.3 实验平台与训练细节

实验环境配置如下: Windows11 操作系统, Intel i7-11800H CPU, NVIDIA GeForce RTX 3060 GPU, 16 G 内存, Pytorch 深度学习框架。网络训练中使用 Adam 优化器进行优化,标签平滑设置为 0.005,初始学习率为 0.001,最大小学习率为 0.000 01,权值衰减为 0.000 5,迭代次数为 100 轮。

3.4 检测方法实验性能分析

为了验证该文所改进的方法具有更好的有效性,分别使用以 Resnet50 为主干网络的 Faster CRNN、SSD、YOLOv3、YOLOv4、YOLOv4-tiny 和该文算法对印刷电路板缺陷数据集进行试验,图 7 所示为各类缺陷检测精度及平均精度比较。从图中可知,Faster CRNN 的检测效果最差,主要是因为丢失的细节信息过多,而印刷电路板不仅背景复杂而且缺陷目标较小所导致。SSD 的检测效果与 Faster CRNN 有很好的提升,但相对来说检测精度还是较低,无法满足工业要求,与原 YOLOv4-tiny 和 SSD 相比改进后的 YOLOv4-tiny 在每一类缺陷的检测精度都由明显的提升,而且 mAP 比 Faster CRNN 提升 36.44%,与 YOLOv3、YOLOv4 相比也仅降低了 0.06%、0.12%,说明改进后的网络对小目标的信息处理起到了很好的作用。



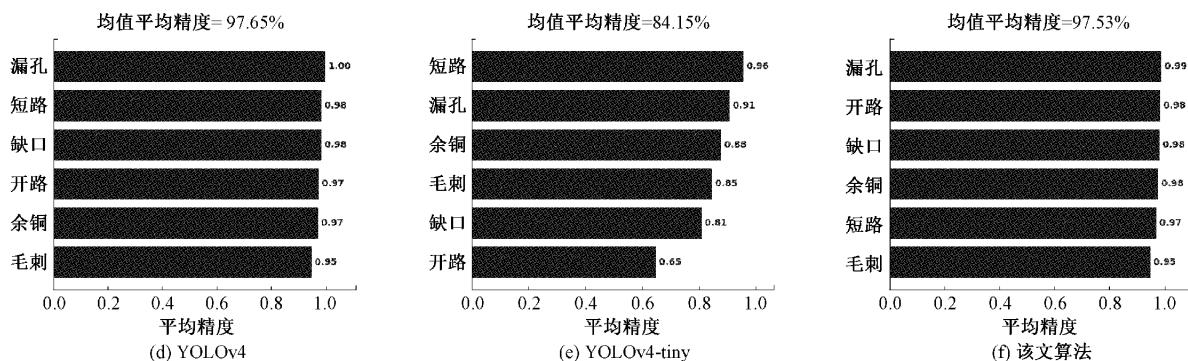


图 7 各算法 mAP 图

为了更好地把控印刷电路板的产品质量,查全率可以更好的评价该算法是否具有更好的实用性,本文所改进算法的各缺陷类别的 R 曲线如图 8 所示,从图中可以看出在一定的阈值范围内都有较好的查全率。表 1 所示为各类缺陷查全率对比结果。由表 1 分析可知,一阶段算法 SSD 的查全率最低。Faster CRNN、YOLOv3 和 YOLOv4 的查全率虽然较高,但是

无法在效率和速度之间达到一个很好的平衡。原 YOLOv4-tiny 网络的查全率虽然在短路类缺陷中达到了较高的水平,但在开路类缺陷中仅有 38.08%,改进后的 YOLOv4-tiny 网络与原 YOLOv4-tiny 网络相比对每一类缺陷的查全率全部得到明显的提升,而且是该文所提算法中效果最好的,证明了该文所提算法具有较好的实用性。

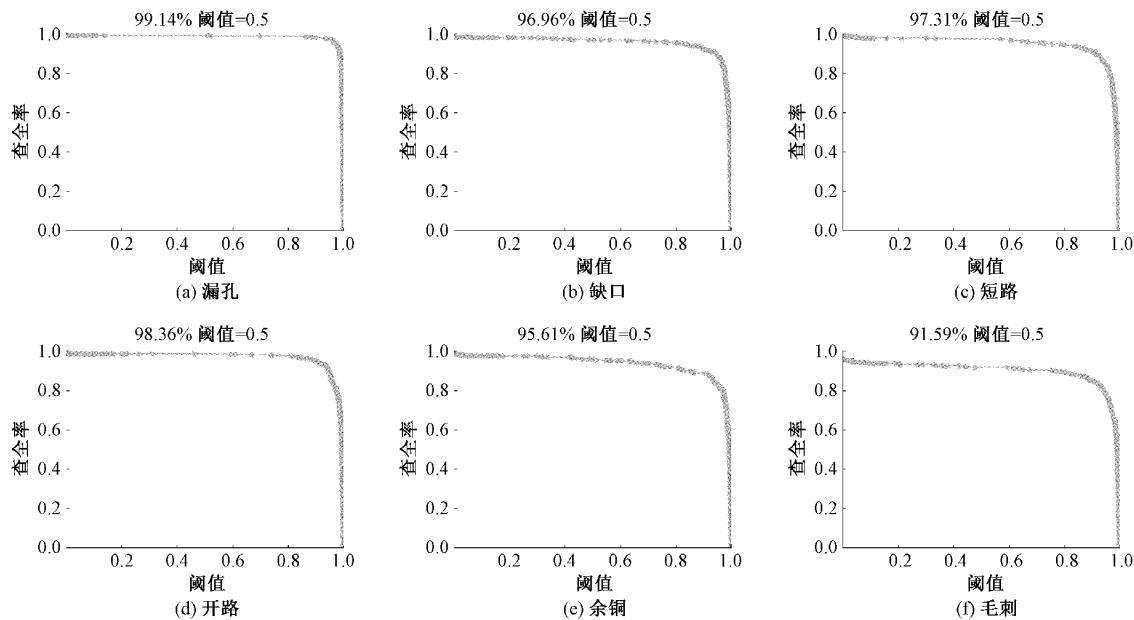


图 8 六种缺陷 R 曲线

表 1 不同算法各缺陷查全率对比

算法	Recall/%					
	漏孔	缺口	短路	开路	余铜	毛刺
Faster CRNN	99.14	93.67	96.41	91.78	93.02	90.69
SSD	23.34	15.19	35.93	15.07	19.12	15.02
YOLOv3	98.85	94.94	96.71	96.71	94.32	89.19
YOLOv4	98.85	94.43	96.41	96.71	92.76	90.99
YOLOv4-tiny	84.44	68.35	91.92	38.08	81.14	74.77
该文算法	99.14	96.96	97.31	98.36	95.61	91.59

表 2 所示为各算法模型大小和检测速度的比较,从表中可以看出,YOLOv3 和 YOLOv4 模型的文件最大,检测速度较低,虽然其检测精度较高,但是在工业生产环境中必须在检测精度和检测效率之间取得平衡。Faster CRNN 和 SSD 的模型较大,其中 Faster CRNN 的单张检测时间更是仅为 10.59 FPS。YOLOv4-tiny 的权值文件大小在前者的十分之一左右,检测速度也有所提升,但是检测精度较低,与 YOLOv4 相比降低了 14.41%。而与 YOLOv4-tiny 相比,本文改进的 YOLOv4-tiny 方法在检测速度达到 149.03 FPS 时,并且检测准确率提高明显,而模型大小也

仅有 22.85 M,完全满足实时检测的需要。

表 2 各算法模型大小和检测速度对比

算法	模型大小/M	FPS/(f·s ⁻¹)
Faster CRNN	108.36	10.59
SSD	93.15	80.96
YOLOv3	235.15	52.87
YOLOv4	244.49	40.29
YOLOv4-tiny	22.52	149.25
该文算法	22.85	149.03

为了研究网络结构和训练策略的改进对模型的作用,进行了以下 3 种消融实验,实验结果与实验设置如表 3 所示,√ 表示使用了该改进方法,× 表示没有使用该改进方法。从表 3 中可以得知,在使用 SPP 和 CBAM 后的网络较 YOLOv4-tiny 原网络的平均精度均值提高了 7.08%,

主要是因为 SPP 和 CBAM 可以更好的提取特征,并增强模型对特征的利用;在第 2 组实验的基础上第 3 组实验又增加了 Adam 优化器等策略,可以看到,mAP 较 YOLOv4-tiny 原网络的平均精度均值提高了 13.38%。随着结构的变化,结果也逐渐改善,这一表现也证明了该文改进算法更加高效。图 9 为使用该文改进算法分别对 6 类缺陷进行检测的结果,可知该文算法可以对该 6 类缺陷进行准确的检测。

表 3 消融实验结果对比

ID	SPP	CBAM	Adam	余弦 退火	标签 平滑	mAP/ %
1	×	×	×	×	×	84.15
2	√	√	×	×	×	91.23
3	√	√	√	√	√	97.53

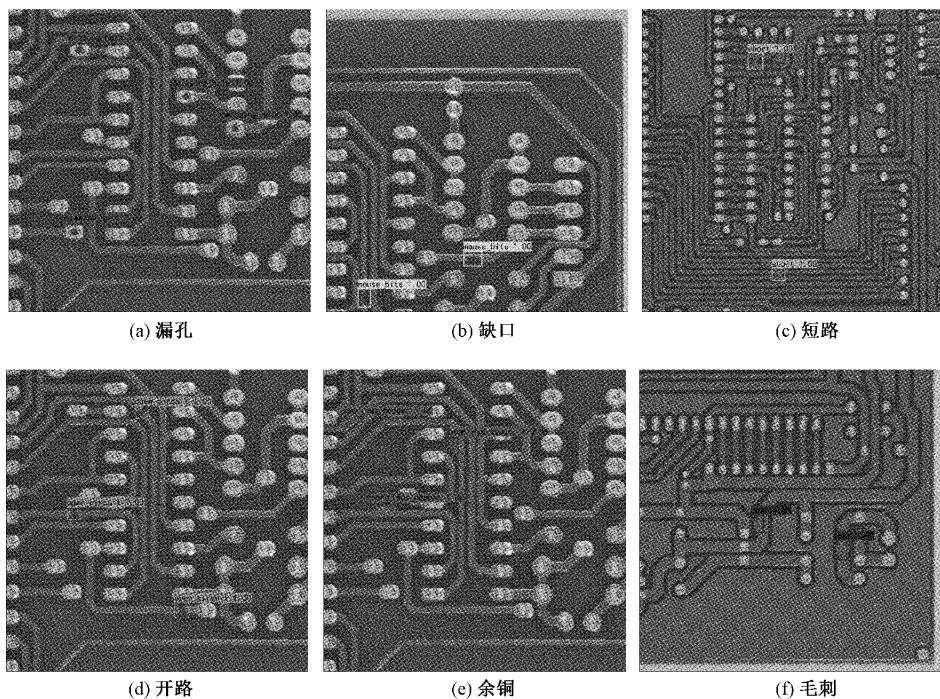


图 9 该文算法对六种缺陷检测结果

综上所述,在印刷电路板缺陷数据集上,Faster CRNN 仅具有查全率高的优点。YOLOv4-tiny 具有模型文件小和检测速度快的优点,但是检测精度较低,导致检测效果较差;SSD、YOLOv3 和 YOLOv4 虽然检测精度和查全率较高,但是模型文件较大和检测速度较慢。而该文所提出的改进算法后不仅保留了原 YOLOv4-tiny 检测速度快的优点,而且使检测精度和查全率都取得了大幅度的提升,可以更好的满足印刷电路板缺陷检测的要求。

4 结 论

由于 YOLOv4 等网络层较深和参数量太大,故该文重

点研究了轻量级印刷电路板缺陷检测算法模型的实现,在 YOLOv4-tiny 算法框架的基础上进行改进。针对印刷电路板缺陷数据集的特点和原有 YOLOv4-tiny 算法在印刷电路板缺陷检测中的不足,提出了三种可行的改进策略:在原骨干网络中添加改进的 SPP 结构,扩展模型的感受野,提取更多的有效特征,大规模优化特征映射策略;针对原结构在处理较小目标的不足,在网络的 FPN 部分增加改进的 CBAM 注意力机制,提升模型融合小目标特征的能力,从而在保证印刷电路板缺陷识别实时性的前提下提高检测精度;最后通过使用 Adam 优化器、余弦退火学习率和标签平滑大大提升了网络的精确度。实验表明,改进的

YOLOv4-tiny 算法在印刷电路板缺陷数据集上的 mAP 值比原 YOLOv4-tiny 算法模型提高了 13.38%，达到了 97.53%，各类缺陷查全率分别提高了 14.70%、28.61%、5.39%、60.28%、14.47%、16.82%，达到了 99.14%、96.96%、97.31%、98.36%、95.61%、91.59%，大大提高了检测准确率和查全率，可以满足现实中工业现场的检测要求，也为后续印刷电路板缺陷检测算法的实际应用提供了一定的实验依据。

参考文献

- [1] 胡珊珊, 肖勇, 王保帅, 等. 基于深度学习的 PCB 缺陷检测研究[J]. 电测与仪表, 2021, 58(3): 139-145.
- [2] WU X, GE Y, ZHANG Q, et al. Pcb defect detection using deep learning methods[C]. 2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design(CSCWD), IEEE, 2021: 873-876.
- [3] TANG S, HE F, HUANG X, et al. Online PCB defect detector on a new PCB defect dataset[J]. ArXiv Preprint, 2019, ArXiv:1902.06197.
- [4] REZA M A, CHEN Z, CRANDALL D J. Deep neural network-based detection and verification of microelectronic images[J]. Journal of Hardware and Systems Security, 2020, 4(1): 44-54.
- [5] ZHANG H, JIANG L, LI C. Cs-resnet: Cost-sensitive residual convolutional neural network for PCB cosmetic defect detection[J]. Expert Systems with Applications, 2021, 185: 115673.
- [6] KHALILIAN S, HALLAJ Y, BALOUCHESTANI A, et al. Pcb defect detection using denoising convolutional autoencoders [C]. 2020 International Conference on Machine Vision and Image Processing(MVIP), IEEE, 2020: 1-5.
- [7] 王永利, 曹江涛, 姬晓飞. 基于卷积神经网络的 PCB 缺陷检测与识别算法[J]. 电子测量与仪器学报, 2019, 33(8): 78-84.
- [8] HU B, WANG J. Detection of PCB surface defects with improved faster-RCNN and feature pyramid network[J]. Ieee Access, 2020, 8: 108335-108345.
- [9] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
- [10] LI D, XU L, RAN G, et al. Computer vision based research on PCB recognition using SSD neural network[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1815(1): 012005.
- [11] XIN H, CHEN Z, WANG B. PCB electronic component defect detection method based on improved YOLOv4 algorithm[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1827(1): 012167.
- [12] 李闻, 李小春, 闫昊雷. 基于改进 YOLO v3 的 PCB 缺陷检测[J/OL]. 电光与控制: 1-7[2022-03-27].
- [13] 李澄非, 蔡嘉伦, 邱世汉, 等. 基于改进 YOLOv4 算法的 PCB 缺陷检测[J]. 电子测量技术, 2021, 44(17): 146-153.
- [14] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv:2004.10934.
- [15] HOU X, MA J, ZANG S. Airborne infrared aircraft target detection algorithm based on YOLOv4-tiny[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1865(4): 042007.
- [16] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904-1916.
- [17] 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.
- [18] 刘嘉敏, 谢文杰, 黄鸿, 等. 基于空间和通道注意力机制的目标跟踪方法[J]. 电子与信息学报, 2021, 43(9): 2569-2576.
- [19] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. ArXiv Preprint, 2014, ArXiv: 1412.6980.
- [20] LOSHCHILOV I, HUTTER F. Sgdr: Stochastic gradient descent with warm restarts [J]. ArXiv Preprint, 2016, ArXiv:1608.03983.
- [21] MÜLLER R, KORNBLITH S, HINTON G E. When does label smoothing help? [J]. Advances in Neural Information Processing Systems, 2019, 32, DOI: 10.48550/arXiv.1906.02629.
- [22] DING R, DAI L, LI G, et al. TDD-net: A tiny defect detection network for printed circuit boards[J]. CAAI Transactions on Intelligence Technology, 2019, 4(2): 110-116.

作者简介

马进,博士,副教授,主要研究方向为图像处理、计算机视觉和计算机仿真等。

E-mail:majinwj@sina.com

王超,硕士,主要研究方向为图像处理,缺陷检测等。

E-mail:surpasswang@163.com