

DOI: 10.13382/j.jemi.B2206017

PCB缺陷检测深度学习算法的精度改进*

杨永跃 夏远超

(合肥工业大学仪器科学与光电工程学院 合肥 230009)

摘要:本文以YOLOv5目标检测算法为基础算法,针对PCB缺陷检测进行了提高精度的改进。首先通过实验选取了合适的数据增强方法。针对PCB缺陷尺寸小的问题,在原有的3个检测头基础上增加了 P_2 检测头。设计全新的PANet多特征融合结构,实现高效的双向跨尺度连接和加权特征层融合。针对PCB背景复杂的问题,引入了CBAM注意力模块以增强图像信息。引入了Transformer模块来增强算法,以提高捕捉不同位置的PCB缺陷信息的能力。最终通过这些改进,在检测速度FPS仅下降7.2的情况下,检测算法的mAP精度提高了11.3%。

关键词: PCB; 缺陷检测; 目标检测; 深度学习; YOLO

中图分类号: TP182; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 540.4050

Accuracy improvement of deep learning algorithm for PCB defect detection

Yang Yongyue Xia Yuanchao

(School of Instrument Science and Opto-Electronics Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: In this paper, the YOLOv5 target detection algorithm was used as the base algorithm to improve accuracy for PCB defect detection. Firstly, an appropriate data augmentation method is selected through experiments. For the problem of small PCB defect size, the P_2 detection head was added to the original three detection heads. A new PANet multi-feature fusion structure was designed to realize efficient two-way cross-scale connection and weighted feature layer fusion. For the problem of the complex PCB background, the CBAM attention module is introduced to enhance image information, the Transformer module is introduced to enhance the algorithm's ability to capture PCB defect information at different locations. Finally, through these improvements, the mAP accuracy of the algorithm increased by 11.3% while the FPS dropped by only 7.2.

Keywords: PCB; defect detection; object detection; deep learning; YOLO

0 引言

印刷电路板(printed circuit boards, PCB)的设计制造在电子信息产业中占有重要地位,PCB制造的缺陷检测更为关键。自动光学检测(automated optical inspection, AOI)基于图像处理技术对PCB缺陷进行检测,具有自动化程度高、实时性好、精度高、零损伤等优点^[1]。对于PCB的缺陷检测,图像处理算法是核心,主要有角点检测算法、图像配准、边缘检测等。

Kim等^[2]通过对各种深度学习算法进行比对,分析

了各种算法的不足,提出了一种基于形态学的识别算法。Ding等^[3]提出一种端到端的深度学习算法,以空间金字塔池化结构(spatial pyramid pooling, SPP)为基础,使用多特征信息融合结构,通过滑动窗口的方法对PCB中的缺陷进行检测,该方法性能稳定,鲁棒性高。Huang等^[4]提出一种基于深度学习的特征分类器,对定位的PCB缺陷区域进行分类,在自定义数据集上有着优异的表现。王永利等^[5]设计了多层卷积神经网络,检测速度较传统图像处理算法提升明显。伍济钢等^[6]对YOLOv4(you only look once)算法进行了改进,使用二分聚类方法(K-means)并结合损失函数(IoU)确定锚框,使用

MobileNetV3 作为特征提取网络,在检测精度提高的同时也加快了检测速度。李澄非等^[7]同样对 YOLOv4 算法进行了改进,使用 K-means++对先验框进行聚类,并将模型中的 5 次卷积改进为网络结构 CSP (cross stage partial) 的残差单元,在精度上明显提高。胡珊珊等^[8]提出目标检测网络(UF-Net),该网络使用上采样和跳层连接实现多尺度特征信息融合,使用 RPN 网络生成 ROI,再通过 ROI-Pooling 层实现 ROI 特征提取。不管是在速度还是精度上,基于深度学习的检测算法都超越了基于传统图像处理算法的检测算法。

1 YOLO 系列目标检测算法

Redmon 等^[9]于 2016 年提出初代 YOLO 检测模型算法 YOLOv1,将目标检测问题转化为回归问题。YOLOv1

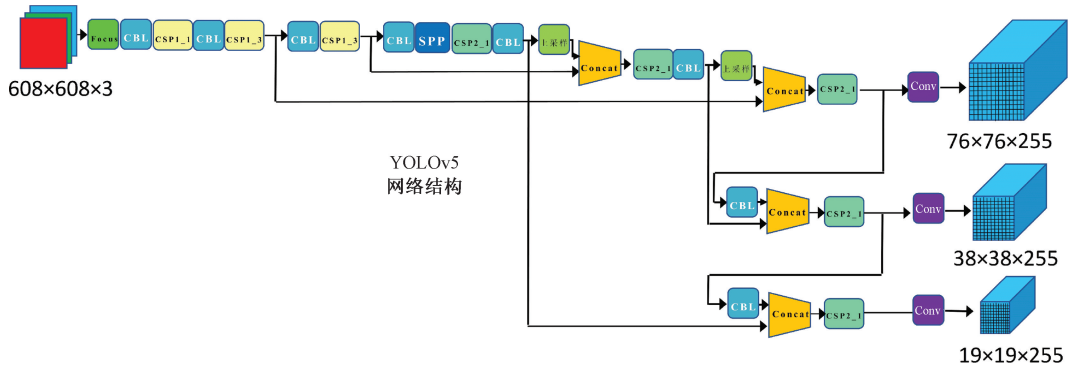


图 1 YOLOv5 网络结构
Fig. 1 YOLOv5 network structure diagram

2 数据集的制作

使用的 PCB 数据集来自北京大学智能机器人开放实验室^[10]。原始数据集共有 693 张图片,主要包括 6 类缺陷: 穿孔 (missing hole)、缺口 (mouse bite)、开路 (open circuit)、短路 (short)、毛刺 (spur)、杂铜 (spurious copper) 等,如图 2 所示。

使用的数据集在统一裁剪成 600x600 后共有 2 672 张,数据量偏少,要进行数据扩充。选择对图像旋转的扩充方式,对图片分别进行顺时针 90°、180°、270° 的旋转。最终将数据集扩大了 4 倍,扩充后的数据集共有 10 668 张。

采用图像标注软件 (LabelImage) 对含有缺陷的 10 688 张 PCB 图像进行标注,获取目标真实框的四角位置以及对应的缺陷类别,并生成对应的训练所需要的 xml 格式文件。最终生成的数据集所包含的 PCB 缺陷实例数如表 1 所示。

将图片划分了 7x7 共 49 个负责区域,每个区域负责预测物体中心落在该区域的目标,每个区域有 2 个先验框,一共有 98 个先验框。每个先验框负责预测位置 x, y 和宽高 w, h 与置信度 $confidence$ 5 个值,此外每个区域还要负责预测目标的类别信息,共有 20 个类别,输出的就是一个大小为 $7 \times 7 \times (2 \times 5 + 20) = 1\,470$ 的维度向量。通过这些信息共同确定目标的位置与类别。

到了 2020 年,Ultralytics 团队进展到 YOLOv5 算法。YOLOv5 在前面算法的基础上使用了预测框的损失函数 (GIoU),并且采用了新的加权极大值抑制 (NMS) 方法去筛选框,使用了自适应锚框计算,在颈部区域也使用了 CSP 结构,引入了数据增强 (Mixup) 方法,使用了自适应图片缩放方法,减小了图像黑边区域,减小了计算量。其网络结构如图 1 所示。

表 1 缺陷种类个数

Table 1 Number of types of defects

缺陷	穿孔	缺口	开路	短路	毛刺	溢铜
数量	3 924	3 832	3 666	3 864	4 028	4 056

从表 1 可以看出,6 种缺陷个数都在 4 000 个左右,较为平均。缺陷在图片中的分布位置也较为均匀(如图 3 所示,颜色越深代表分布数量越多),这有利于提高模型的泛化能力。

将数据集按照训练集:验证集:测试集=6:2:2 的比例进行划分,训练集是用来训练模型,验证集是为了调整模型的超参数并对模型的性能进行初步评估,测试集是用来评估模型最终的性能。最终训练集图片为 6 412 张,验证集图片数量为 2 138 张,测试集图片数量为 2 138 张。

3 YOLOv5 算法精度的改进

PCB 缺陷目标检测算法需要针对 PCB 数据集的特

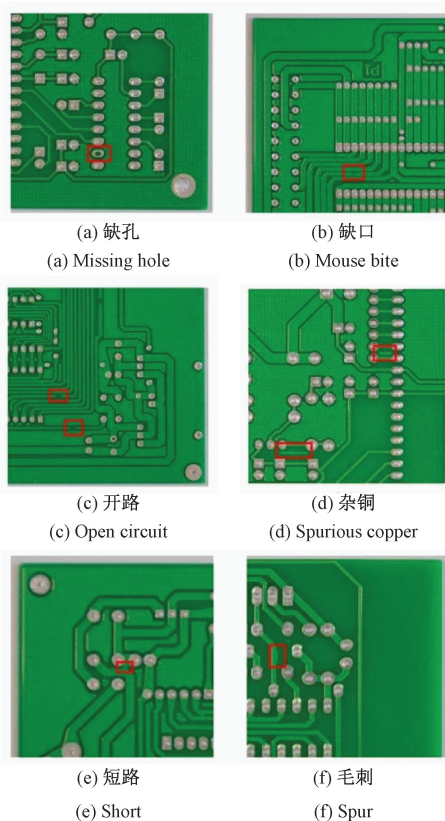


图2 缺陷类型

Fig. 2 Defect types




图3 缺陷在图片的位置分布

Fig. 3 The location of defects in the picture

点进行针对性改进,以达到更好的检测效果。

3.1 数据增强方法

使用数据增强(Mosaic)方法^[11],在一个批量的图像样本内随机取出4张样本图像,将4张图像随机裁剪,再将裁剪的图像拼接为一张新的图像上作为新的训练样本。

Mosaic 数据增强方法极大丰富被检测物体的背景,增强模型的鲁棒性;不会引入冗余信息,在提高效率的同

时使得模型训练以及推理的运算量保持不变;对图片的裁剪排列迫使模型从局部视图去学习目标信息,加强模型的定位能力,提高模型的分类能力。

Mixup 数据增强方法^[12]是一种数据无关的增强方式,将不同类之间的图像混合,构建虚拟的训练样本,从而扩充训练数据集,且不会增加模型的复杂性。

Mixup 数据增强方法是在所有层中随机选取一个 k 层,然后使用不同的数据前向传播到 k 层,对这两组数据进行融合得到新的样本和新的标签。新的样本继续在后面的网络进行计算传播,直到计算出预测值和新的标签所产生的 loss 值,再进行反向传播。

Mixup 数据增强方法可以显著削弱模型对于错误样本的记忆,从而减小模型对特定样本的敏感性,进而增强模型的泛化能力和鲁棒性。

将 Mosaic 数据增强方法与 Mixup 数据增强方法相结合,流程如图4所示。




图4 Mosaic 算法与 Mixup 算法混合过程

Fig. 4 Mosaic algorithm and Mixup algorithm mixing process

通过对这两种数据增强算法的结合,YOLOv5 算法在数据集上得到了显著的增强。

3.2 增加 P_2 检测头

目标检测有一个难点就是对尺寸大小不同的检测目标做到同时兼顾的问题,尤其对尺寸小于 32×32 pixels 小目标的准确检测。YOLO 检测算法利用多个不同尺度大小的检测头来检测不同尺寸大小的目标^[13]。

YOLOv5 的网络结构可以根据其功能的不同划分为4个部分,分别是输入部分(input)、主干网络部分(backbone)、颈部部分(neck)和预测部分(prediction),如图5所示。

YOLOv5 在预测部分使用了3个尺度的检测头 P_3 、 P_4 和 P_5 来对不同尺寸大小的目标进行检测。这也对应了颈部网络结构的3个预测分支 C_3 、 C_4 和 C_5 ,其中的数字与特征层编号相同,代表的是尺寸减半的次数,第 C_i 层的大小是输入图像大小的 $1/2^i$ 。越小的检测尺度代表采样的倍数越高,其感受野也就越大。通过多个不同大小的检测尺寸对图像特征的提取,可以对不同尺寸的目标分别进行检测。

在 PCB 缺陷检测问题中,缺陷大多较小,尺寸在 $30 \times$

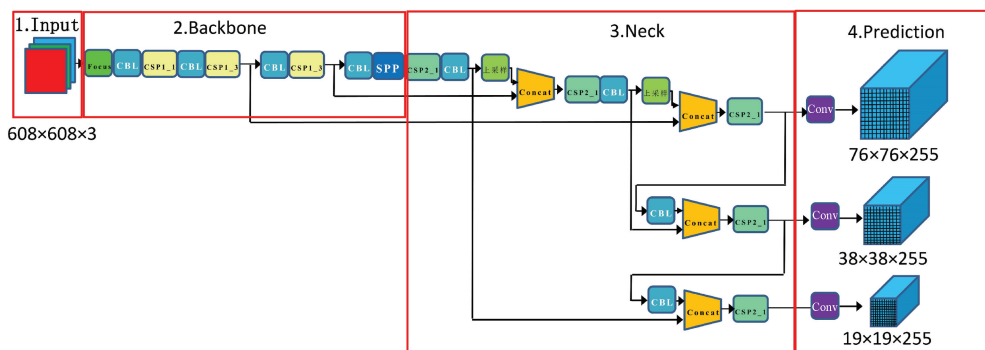


图 5 YOLOv5 网络组成部分
Fig. 5 YOLOv5 network components

30 pixels 以内。为此,对 YOLOv5 的网络结构进行改进,在预测部分增加一个全新的 P_2 检测头,同时在颈部增加相应的 C_2 预测分支。这个新的预测分支将原有的大小为 76×76 的预测分支经过上采样,再与主干网络提取的

浅层特征融合,经过卷积形成新的大小为 152×152 预测分支,从主干网络中的较浅层引出浅层特征。对新的检测头设计了 3 个尺寸大小的先验框,尺寸分别为 $5 \times 6, 8 \times 14, 15 \times 11$,改进后的 YOLOv5 网络如图 6 所示。

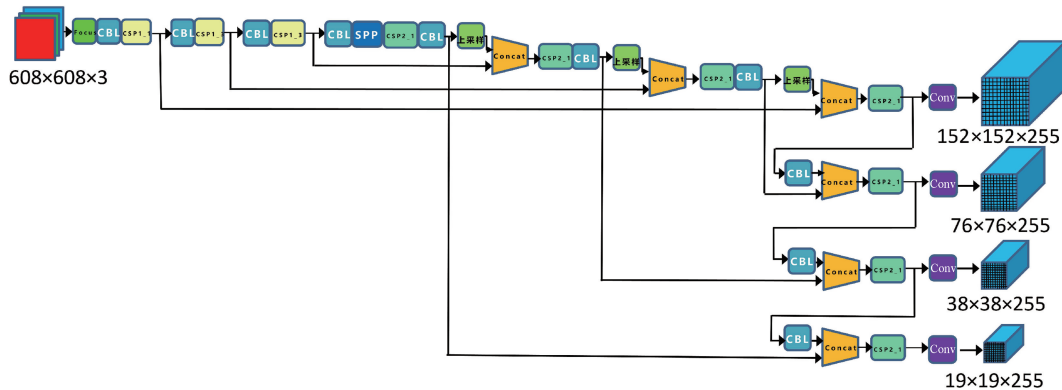


图 6 改进后的网络结构
Fig. 6 Improved network structure

新的尺寸大小为 152×152 检测头不仅继承了原来的主干网络提取的图像深层特征,同时也融合了图像在主干网络较浅时提取的浅层特征,使得改进后的网络检测尺度更为丰富。检测头数量的增加可以更好地识别小目标缺陷特征,增强模型对小目标缺陷的检测能力。先验框数量的提高可以大幅度提高检测密度,防止对目标的漏检。

3.3 改进多特征融合结构

检测小目标的特征信息从浅层网络中提取,经过与深层网络提取的深层特征融合后形成,改进不同尺度特征信息的融合结构,可以有效提高小目标的检测精度。

在 YOLOv5 算法中以 C_3, C_4, C_5 为 3 个特征层为输入,它通过侧向连接的方式与更浅层的 N_i 和深层的 F_{i+1} 融合的方式得到 N_{i+1} , N_i 首先通过一个步长为 2 的 3×3 卷积再与 F_{i+1} 通过横向连接进行特征融合,接着再经过一个 3×3 卷积得到最后的输出。最后使用激活函数

(ReLU)对特征进行非线性化处理。但这种融合只能逐层进行,无法直接融合跨尺度间特征。

在路径聚合网络(PANet)的基础进行改进,结合网络结构搜索(NAS-FPN)的思路^[11,14]设计出一种新的多特征融合结构来实现高效的双向跨尺度连接和加权特征层融合。

改进点 1:删除最底层和最顶层的特征层,因为这两个特征层只有一个输入并且没有进行特征融合,所以两个节点对旨在融合不同特征的网络贡献比较小。

改进点 2:增加跳跃连接。在同一层的原始输入和输出节点之间增加一条额外的融合路径,以便在不增加额外成本的情况下融合更多特征。

改进点 3:结合 NAS-FPN 的思路,将改进后的 PANet 结构当做一个基本单元,重复堆叠将一组路径视作一个特征层,重复循环多次以得到更多的特征融合。改进后的结构如图 7 所示。

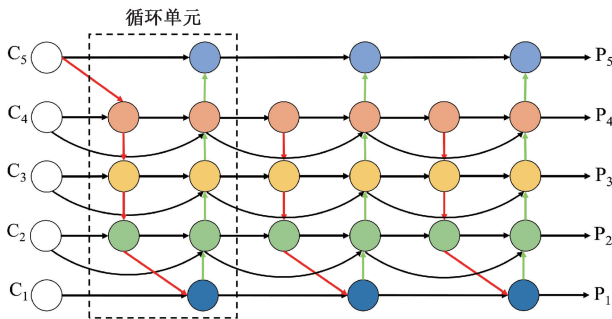


图 7 基于 PANet 改进的结构示意图

Fig. 7 Schematic diagram of the improved structure of PANet

由于不同的特征层具有不同大小的尺度,因此在特征融合阶段给每个输入赋予一个额外的权重,让网络自己去学习权重的大小,进而计算得出最优的网络模型。其快速归一化加权公式如式(1)为:

$$W = \sum_i \frac{W_i}{\varepsilon + \sum_j W_j} \times I_i \quad (1)$$


其中, W_i 是一个可学习的权重,是一个标量。当 $W_i \geq 0$ 时在每个 W_i 后应用 ReLU 激活函数, ε 是一个很小的数,设置为 0.000 1 来确保数值的稳定性,每个权重标准化后都在 0~1 之间,这样所有的权重都被归一化到 0~1 之间的值,具有更高的效率。

在 P_2, P_3, P_4, P_5 4 个层级上使用了双向特征融合方法,而没有在 P_1 上使用。充分利用低层级的 P_1 特征信息会提高模型的小目标检测能力。

3.4 增加注意力模块

在 PCB 图像中缺陷部分只占图像很小的部分,引入注意力机制来提取图像中重要程度高的信息和特征中有利于检测的部分。注意力机制的本质就是利用相关特征学习权重分布,再用学习到的权重施加在原特征图上进

行加权处理。注意力机制可以让模型对图像进行有区别的检测,提高模型的检测性能。其可视化示意图如图 8 所示。



(a) 原始图像
(a) Original image
(b) 添加注意力机制后的图像
(b) Add attention module image

图 8 添加注意力机制前后的图像

Fig. 8 Visualized images before and after adding attention mechanism

注意力机制根据原理不同可分为通道注意力机制和空间注意力机制,通道注意力关注不同通道间的重要性差异,而空间注意力关注同一通道内不同位置像素的重要性差异。目前在计算机视觉领域使用最多的两种注意力模块为 SE (squeeze-and-excitation) 模块^[15] 和 CBAM (convolution block attention block) 模块^[16]。

SE 模块对图像特征通道间的相互依赖关系建立模型,通过自主学习的方式,让模型采用特征重标定的策略学习到每个特征通道的重要程度,然后根据这个重要程度去增强重要的特征信息并且抑制无用的特征信息。

CBAM 注意力模块则在 SE 注意力模块的基础上做了调整,不仅关注通道间的相互依赖关系,还关注同一通道里的不同位置的相互依赖关系。

在 YOLOv5 网络结构颈部部分的 CSP 结构后分别添加两种注意力模块,添加注意力模块后的网络结构示意图如图 9 所示。




图 9 添加注意力模块后的 YOLOv5 网络结构

Fig. 9 YOLOv5 network structure diagram after adding attention module

3.5 增加 Transformer 模块

深度学习模型 (Transformer) 使用编码器-解码器的

结构^[17],将注意力网络和全连接层进行叠加,去关注序列中的每一部分信息与其他部分信息的关系。本文使用

的编码器模型结构如图 10 所示。




图 10 Transformer 编码器结构

Fig. 10 Structure diagram of Transformer encoder

该编码器主要由两个子层组成,第 1 层是多头注意力层 (multi-head attention), 第 2 层是 (multilayer perceptron) MLP 多层感知器全连接层,每个子层使用残差连接。此外还包括 Embedded Patches 输入层、Norm 层、Dropout 层。

编码器的输入维度和输出维度都是一致的,所以理论上可以叠加无数个编码器模块。

使用编码器模块替代 YOLOv5 的部分 CSP 结构^[18],将网络提取的特征图作为输入送入到编码器模块中。因为原始图像分辨率很大,包含很多信息,直接将原始图像送入到编码器模块会造成很大的计算开销和内存开销,所以只在主干网络末端和检测头前使用了编码器模块。因为在这些部位特征图的分辨率很低,能大幅度减少计算开销和内存开销。添加编码器模块后的 YOLOv5 结构如图 11 所示。




图 11 添加编码器模块后的 YOLOv5 网络结构

Fig. 11 YOLOv5 network structure diagram after adding encoder module

如图 11 中实线框所示,把主干网络末端 CSP 结构替换掉,并叠加了 3 个编码器模块,将 4 个预测头前的 CSP 结构替换为了编码器模块。将 YOLOv5 神经网络与 Transformer 编码器相结合,神经网络用来提取图像特征,编码器将图像特征进行融合。

4 精度评估指标

交并比 (intersection over union, IoU) 是预测框与实际框交集与并集的比值,以此来衡量预测框和实际框的重合程度,即预测框的定位是否准确。

IoU 为 0~1 之间的常数。IoU 越大说明预测框与真实框重叠程度越高,模型预测性能越好。通常会设定一个 IoU 阈值,来判断预测框是正确的还是错误的。当 IoU 大于这个阈值说明这是预测正确的框,反之则是预测错误的框。根据预测框与实际框的关系,可以将预测

框划分成 4 类: TP (true positive) 表示被正确分类的正例, FP (false positive) 表示本来是负例,被错分为正例, FN (false negative) 表示本来是正例,被错分为负例, TN (true negative) 表示被正确分类的负例。由此得到以下概念:

查准率 (precision, Pr) 表示预测的正样本中预测正确的比例如式 (2) 所示:

$$Pr = \frac{TP}{TP + FP} \tag{2}$$

查全率 (Recall, Re) 表示实际的正样本中预测正确的比例如式 (3) 所示:

$$Re = \frac{TP}{TP + FN} \tag{3}$$

查准率表示在预测出的结果中预测正确的比例,查全率表示在所有真实目标中被正确检测的比例。查准率和查全率二者成负相关关系:当查全率越高时,则查准率越低;当查全率越低时,则查准率越高。这两个指标都不

能很好地反映模型的检测的性能,在此基础上提出了平均精度 (average preccision, AP)。

平均精度 AP 表示将置信度阈值 P_{th} 从 0~1 变化,计算每个阈值下对应的 Pr 和 Re,绘制某种类别的 PR 性能曲线,如图 12 所示。

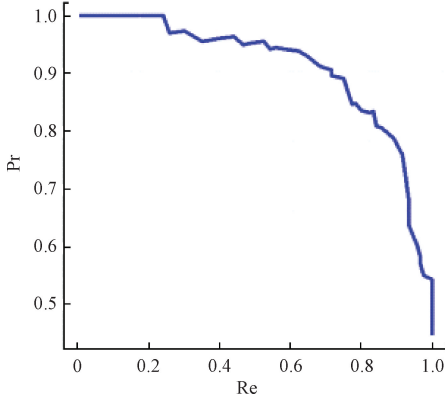


图 12 PR 性能曲线

Fig. 12 PR performance curve

其与坐标轴围成的面积即为该类别的 AP 值。公式如式(4)所示:

$$AP = \int_0^1 P_{th}(r) dr \quad (4)$$

取某个类别的 AP 和不同的 IoU 阈值 IoU_{thresh} ,可以

计算 $AP@0.5 : 0.95$ 。 $AP@0.5 : 0.95$ 为 IoU_{thresh} 的分别取以 0.5 为起点,0.95 为终点,0.05 为步长的 10 个数即 0.5、0.55、0.6、0.65、0.7、0.75、0.8、0.85、0.9、0.95 时某个类别 AP 的平均值,公式如式(5)所示:

$$AP@0.5 : 0.95 = \sum_j AP(IoU_{thresh} = j) \quad (5)$$

取所有类别的 $AP@0.5 : 0.95$,可以计算 $mAP@0.5 : 0.95$,公式如式(6)所示:

$$mAP@0.5 : 0.95 = \frac{1}{N} \sum_{i=1}^N \sum_j AP(IoU_{thresh} = j) \quad (6)$$

式中: N 为类别数量,本文为 PCB 缺陷种类数量 6。

这样,以 $AP@0.5 : 0.95$ 和 $mAP@0.5 : 0.95$ 来作为 PCB 缺陷检测的精度评价指标。为方便表达,下文中文 AP 表示 $AP@0.5 : 0.95$, mAP 表示 $mAP@0.5 : 0.95$ 。

5 算法改进实验与结果分析

5.1 数据增强方法的改进结果分析

对 YOLOv5x 分别不使用数据增强方法、使用 Mixup 数据增强方法、使用 Mosaic 数据增强方法和使用 Mixup 和 Mosaic 两种数据增强方法进行对比,结果如表 2 所示。

目标检测表示检测速度的指标为 FPS (frames per second),表示模型每秒能够检测图像的数量。表中也给出了目标检测速度的实验对比结果。

表 2 不同数据增强方法结果对比

Table 2 Comparison of results of different data enhancement methods

数据增强方法	mAP/%	FPS	AP/%					
			穿孔	缺口	开路	短路	毛刺	杂铜
—	68.2	20.1	67.2	69.6	69.8	64.0	70.4	68.4
Mosaic	84.9	20.2	85.4	85.4	81.5	83.8	86.4	84.8
Mixup	65.7	20.5	67.4	66.8	66.7	60.8	66.7	67.4
Mixup+Mosaic	79.5	20.4	79.2	81.0	73.9	82.1	82.7	78.1

从表 2 可知,只使用 Mosaic 数据增强方法相较于使用 Mixup 和 Mosaic 两种数据增强方法模型精度大幅度提升, mAP 提高了 5.4%。本论文使用的 PCB 数据集背景则比较单一,而且绝大多数都为绿色,所以 Mixup 融合反而会使得图像信息冗余混乱,难以分辨。给网络的特征提取造成很大的障碍,最终使得模型性能下降。Mosaic 数据增强方法则是将 4 张不同的图片拼接在一

起,不会影响原始图像的质量,而是会丰富图像的背景信息,提高模型的鲁棒性。为此本文只使用 Mosaic 数据增强方法。

5.2 增加 P_2 检测头结果分析

在选择 Mosaic 数据增强方法的基础上进行实验,在 YOLOv5x 算法上增加额外的 P_2 检测头,改进后的实验结果如表 3 所示。

表 3 增加 P_2 检测头前后的网络检测性能对比

Table 3 Comparison of network detection performance before and after adding P_2 detection head

增加 P_2 检测头	mAP/%	FPS	AP/%					
			穿孔	缺口	开路	短路	毛刺	杂铜
改进前	84.9	20.2	85.4	85.4	81.5	83.8	86.4	84.8
改进后	87.4	19.1	87.9	89.2	84.4	87.0	88.3	87.6

通过表 3 可知,通过新增尺寸为 152×152 检测头使得模型的性能有了显著提升,mAP 提高了 2.5%。通过增加了一个检测头去检测小目标,提高了模型对于图像中尺寸较小的 PCB 缺陷的检测能力,新增一个检测头使

得模型的性能有了显著提高。

5.3 改进多尺度特征融合结构结果分析

在增加 P_2 检测头的基础上进行实验,在 YOLOv5x 算法上使用不同的特征融合结构,实验结果如表 4 所示。

表 4 不同特征融合方法结果对比

Table 4 Comparison of results of different feature fusion methods

特征融合结构	mAP/%	FPS	AP/%					
			缺孔	缺口	开路	短路	毛刺	杂铜
PANet	87.4	19.1	87.9	89.2	84.4	87.0	88.3	87.6
FPN	87.1	19.5	87.4	88.7	84.2	86.9	87.9	87.5
NAS-FPN	88.1	16.4	88.2	89.7	86.6	87.9	88.1	87.9
本文	88.7	17.1	88.7	88.1	87.4	88.6	89.1	88.3

由表 4 可知,新的特征融合结构相较于 PANet、FPN、NAS-FPN 结构 mAP 分别提高了 1.3%、1.6% 和 0.6%。新的特征结构通过双向跨尺度连接和加权特征融合的方式加强了特征层之间的信息融合,丰富了特征的语义信息,在精度上有了一定程度的提升。

5.4 增加注意力模块结果分析

在使用新的特征融合结构的基础上进行实验,在 YOLOv5x 算法上分别添加 SE 和 CBAM 两种注意力模块,其实验结果如表 5 所示。

表 5 添加不同注意力机制前后结果对比

Table 5 Comparison of results before and after adding different attention mechanisms

注意力类别	mAP/%	FPS	AP/%					
			缺孔	缺口	开路	短路	毛刺	杂铜
—	88.7	17.1	88.7	90.1	87.4	88.6	89.1	88.3
SE	89.2	15.7	89.1	91.0	88.3	89.2	89.4	88.3
CBAM	89.4	14.8	89.3	91.1	88.7	89.2	89.6	88.4

从表 5 可以看出,添加 SE、CBAM 注意力模块后模型的 mAP 值都有不同程度的提升,分别提高了 0.5% 和 0.7%。相较于 SE 模块,CBAM 模块对模型精度提升效果更为明显。

5.5 增加 Transformer 模块结果分析

在添加 CBAM 注意力模块的基础上进行实验,在 YOLOv5x 算法的基础上添加 Transformer 模块,改进后的实验结果如表 6 所示。

表 6 添加 Transformer 模块前后结果对比

Table 6 Comparison of results before and after adding the Transformer module

算法类别	mAP/%	FPS	AP/%					
			缺孔	缺口	开路	短路	毛刺	杂铜
改进前	89.4	14.8	89.3	91.1	88.7	89.2	89.8	88.4
改进后	90.8	13.2	90.4	93.6	90.2	89.4	92.6	88.7

从表 6 可以看出,增加 Transformer 模块后 mAP 提升了 1.4%,说明编码器模块能够很好地捕捉特征的全局信息,用编码器模块替代部分 CSP 结构,对于模型精度的提高是十分有效的。

6 结论

针对 PCB 缺陷数据集,对视觉检测 YOLOv5x 网络模型进行改进。通过实验比较,只使以 Mosaic 数据增强方法;针对 PCB 缺陷尺寸较小,增加对应合适尺度的 P_2 检测头,以提高模型对小尺寸 PCB 缺陷的检测能力;在

PANet 多特征融合结构的基础上,引入循环单元,增强同特征层的信息融合能力;通过实验比较,引入 CBAM 注意力模块;引入 Transformer 编码器模块。经过实验验证,通过这些改进最终将原始 YOLOv5x 模型的 mAP 精度提高了 11.3%,对原有 YOLOv5x 模型的精度改进效果明显。算法改进实验中检测速度 FPS 下降了 7.2,但仍然保持了较高的水平,不影响工业现场应用实时检测的要求。

参考文献

- [1] BLASCHECK T, KURZHALS K, RASCHKE M, et al. AOI hierarchies for visual exploration of fixation sequences[C]. Proceedings of the Ninth Biennial ACM

- Symposium on Eye Tracking Research & Applications, 2016: 111-118.
- [2] KIM S, KIM W, NOH Y K, et al. Transfer learning for automated optical inspection [C]. 2017 International Joint Conference on Neural Networks (IJCNN). IEEE, 2017:2517-2524.
- [3] DING R, ZHANG C, ZHU Q, et al. Unknown defect detection for printed circuit board based on multi-scale deep similarity measurement method[J]. The Journal of Engineering, 2020,13:388-393.
- [4] HUANG W, WEI P, ZHANG M, et al. HRIPCB: A challenging dataset for PCB defects detection and classification[J]. The Journal of Engineering, 2020, 13: 303-309.
- [5] 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.
- WANG Y L, CAO J T, JI X F. PCB defect detection and recognition algorithm based on convolution neural network[J]. Journal of Electronic Measurement and Instrumentation, 2019,33(8):78-84.
- [6] 伍济钢,成远,邵俊,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测研究[J]. 仪器仪表学报, 2021, 42(10): 171-178.
- WU J G, CHENG Y, SHAO J, et al. Research on PCB defect detection based on improved YOLOv4 algorithm[J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 171-178.
- [7] 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.
- LI CH F, CAI J L, QIU SH H, et al. PCB defect detection based on improved YOLOv4 algorithm [J]. Electronic Measurement Technology, 2021, 44 (17): 146-153.
- [8] 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.
- HU SH SH, XIAO Y, WANG B SH, et al. Research on PCB defect detection based on deep learning [J]. Electronic Measurement and Instrument, 2021, 58 (3): 139-145.
- [9] 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, 2016: 779-788.
- [10] 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.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934, 2020.
- [12] ZHANG H, CISSE M, DAUPHIN Y N, et al. mixup: Beyond empirical risk minimization [J]. arXiv preprint arXiv:1710.09412, 2017.
- [13] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. arXiv preprint arXiv: 1804. 02767, 2018.
- [14] GHIASI G, LIN T Y, LE Q V. Nas-fpn: Learning scalable feature pyramid architecture for object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 7036-7045.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [16] 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.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]. Advances in Neural Information Processing Systems, 2017: 5998-6008.
- [18] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390-391.

作者简介



杨永跃(通信作者), 2004 年于合肥工业大学获得博士学位, 现为合肥工业大学副教授, 主要研究方向为图像理解、模式识别和 3D 恢复。

E-mail: 737800933@qq.com

Yang Yongyue (Corresponding author)

received his Ph. D. degree from Hefei University of Technology in 2004. Now he is an associate professor in Hefei University of Technology. His main research interests include image understanding, pattern recognition and 3D reconstruction.

夏远超, 2022 年于合肥工业大学获得硕士学位, 主要研究方向为图像理解和模式识别。

E-mail: 1518978630@qq.com

Xia Yuanchao received his B. Sc. degree from Hefei University of Technology in 2022.

His main research interests include image understanding and pattern recognition.

