

# 基于改进YOLOv5的PCB板缺陷检测方法

王自源

(池州学院 安徽 池州 247100)

**【摘要】**印刷电路板(PCB, Printed Circuit Board)的缺陷检测一直是工业领域很有价值的研究方向。PCB中缺陷目标的像素占整张图像的比例非常小,所以很容易在检测中被漏检或错检。因此,本文提出了ATCSP-YOLOv5用于PCB中的小目标检测。本文将跨阶段局部网络(CSPNet)的思想和Transformer中多头自注意力机制(Multi-Head Attention)相结合,在YOLOv5的主干网络中加入多头自注意力跨阶段局部网络(ATCSP)模块,同时在特征金字塔部分融合生成感受野更小的目标检测层,用于添加小目标探测头。除此之外,本文还使用了GANs和数据增强来扩充数据集,更好的实现了缺陷检测。在实验中ATCSP-YOLOv5的mAP@0.5为98.04%,相较于原始的YOLOv5s提升了2.21%,同时检测速度没有明显下降。

**【关键词】**改进yolov5;计算机视觉;Pcb板缺陷检测

## 1. 介绍

缺陷目标检测一直是工业领域很有价值的研究方向。其中印刷电路板(PCB, Printed Circuit Board)裸板的缺陷检测是一个值得优化改进的分支。传统的PCB裸板缺陷检测方法存在检测速度慢、漏检率高、鲁棒性不佳、泛化能力弱的种种问题。现代的基于CNN的深度学习目标检测算法对于大目标有很强的检测能力,但对于PCB中这种小目标缺陷检测能较弱,直接将现有的目标检测框架应用于含有小目标的数据集,无法达到很好的检测效果。小目标不易于检测的原因是,缺陷目标像素过少,在不断卷积的过程中,随着特征图尺寸不断变小,缺陷像素被不断压缩,特征图中的缺陷目标失去了大部分的有效特征和细节特征。因此,无论是对于传统检测技术还是现代检测技术,小目标检测都是亟待解决的问题。

为了解决上述问题,本文提出ATCSP-YOLOv5用于PCB的缺陷检测。本文所使用的PCB数据集中的图片具有分辨率高但缺陷目标与图像的相对比例却非常小的特点,其中最小的一类缺陷占整个图像的比例仅为0.00997% ( $20 \times 24 \div (1586 \times 3034) = 0.00997\%$ )。结合数据集的特点,在降低模型计算量的同时,还一定程度上提升了检测精度。本文将Transformer中多头自注意力机制(Multi-Head Attention)和SCPNet结合的模块称之为ATCSP(多头自注意力跨阶段局部网络)。

本文所做出的贡献如下:

(1) 将Transformer中多头自注意力机制(Multi-Head Attention)和SCPNet的思想结合,生成ATCSP(多头自注意力跨阶段局部网络)模块。显著提高了模型的小目标检测性能。

(2) 在特征金字塔部分融合生成感受野更小的目标检测层,添加了一个用于小目标检测的探测头,同时去掉了原本感受野最大的探测头,减少了计算量。

(3) 通过使用特定的数据增强方法和GANs(Pix2Pix)来预处理和扩充数据集,为PCB数据集的扩充和预处理提供了有效策略。

(4) 将训练好的ATCSP-YOLOv5模型中的PANet换成FPN,再对模型进行微调训练,降低了模型的计算量和大小,同时还小幅度提升了模型的检测精度。

## 2. 相关研究

前人对基于深度学习的小目标检测方法主要从以下七个方面进行了研究,有数据增强、多尺度特征融合、超分辨率、上下文信息学习、锚框机制、注意力机制和其他方法。本文主要对于注意力机制领域,对小目标检测的能力提高,做出了创新性的研究方法,并在方法中融合了其他六个研究方向中有效的方法进行了算法改进。

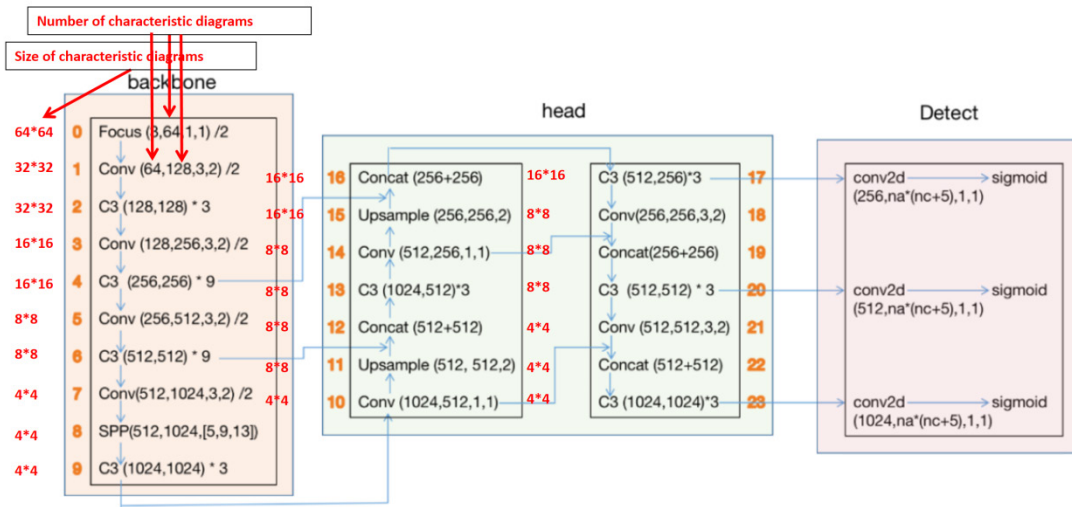
目标检测是计算机视觉领域的基础任务之一,该领域已有近二十年的研究历史。随着快速发展,

基于深度学习的算法应运而生，如 R-CNN、快速 / 更快 R-CNN、SSD 和 YOLO 系列，它们比传统的手动特征方式对目标检测有更好的效果<sup>[1]</sup>。为了提高检测的可信度，2013 年提出了 ConvNet<sup>[2]</sup> 中的 OverFeat 特征提取器和多尺度滑动窗口。后来，在 Fast R-CNN 上使用区域平均池化来更好地检测区域环境<sup>[3]</sup>，学习 RoI 变压器是为了在不添加锚点的情况下改进密集目标检测<sup>[4]</sup>。

特征金字塔网络 (FPN)<sup>[5]</sup> 作为一种经典的特征提取方法，在目标检测方面也有许多扩展算法。

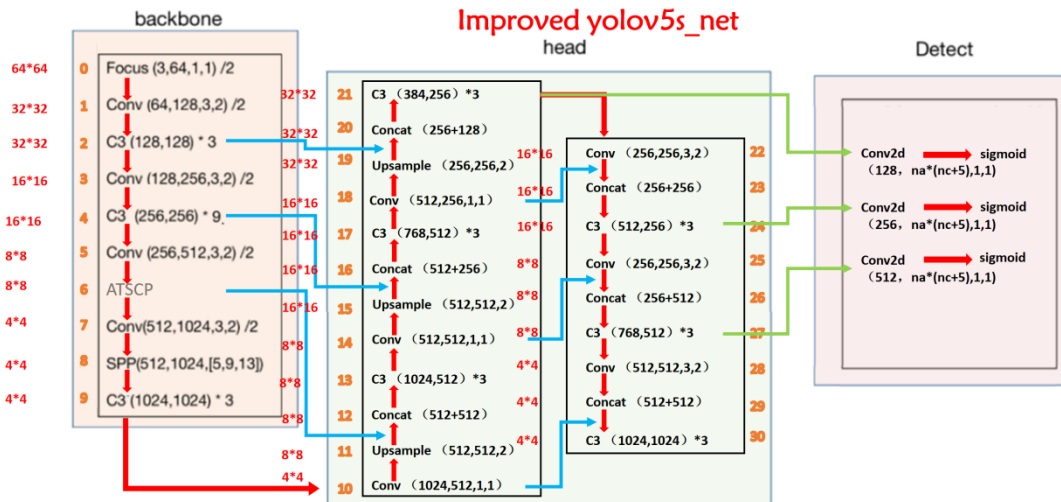
从轻量级的角度来看，小金字塔可以用来模拟大金字塔和树网计算<sup>[6]</sup>。从召回率低的问题出发，全卷积轻量级金字塔网络 (FCLPN) 可以在像素水平上改善无人机图像的位置和分类结果<sup>[7]</sup>。此外，双向特征金字塔网络 (BiFPN) 在多尺度特征融合和效率方面均优于 FPN<sup>[8]</sup>,<sup>[9]</sup>。2018 年提出的图像金字塔尺度归一化 (SNIP) 可以根据大小区分目标并优化目标<sup>[10]</sup>。感知生成对抗网络 (感知 GAN) 通过允许机器学习感知小物体并自动超分辨率来增加小物体的大小<sup>[11]</sup>。为了防止池化中的小目标

Original yolov5s



图一：YOLOv5s 结构图

Improved yolov5s\_net



图二：ATCSP-YOLOv5 结构图

失真,提出了上下文感知的 RoI 轮询以保存必要的信息<sup>[12]</sup>。

### 3. ATCSP-YOLOv5 模型

#### 3.1 YOLOv5 简介

YOLOv5 有四种不同类型: YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。考虑到 PCB 在管道检测中的实时性要求,本文试图在允许的精度维护范围内尽可能提高模型的基本检测速度,并最终选择 YOLOv5 作为改进的基本框架。YOLOv5 的结构如图 1 所示。

#### 3.2 ATCSP-YOLOv5 模型结构

与 YOLOv5 相比, ATCSP-YOLOv5 在具有 ATCSP 模块的主干网络中以 80\*80 的特征图大小替换了 C3 结构。嵌入主干网络中的 ATCSP 模块的位置是经过多次测试后发现的最佳位置。同时,融合特征金字塔部分以生成具有 320\*320 特征图大小的小目标检测层。添加新 YOLOHead3,删除 YOLOv5 中的 YOLOHead1。ATCSP-YOLOv5 的结构如图 2 所示。

将训练好的 ATCSP-YOLOv5 模型中的 PANet 替换成 FPN 再进行模型参数微调得到 ATCSP-YOLOv5-Pruned。

#### 3.3 ATCSP

ATCSP 的基本层是前一卷积层的输出。第 1 部分和第 2 部分是特定卷积后基础层的两个部分。特定卷积的输入是基本层,输入通道的数量是基本层的通道数量,输出通道的数量为基本层通道数量的一半,卷积内核的大小为 1。不处理第 1 部分和第 2 部分,部分通过原始模块,然后在最后对两部分进行凹形。由于其中一半未被处理,原始模块的计算工作量减少,而 Concat 从头到尾将梯度变化集成到特征图中,并略微提高了检测精度。变压器层将在下一节中解释。

#### 3.4 Transformer Layer

Transformer Layer 的输入是 ATCSP 中的 Part2 特征图。将输入的特征图分割成多个 16\*16 像素的小块 (Patch),然后将各个小块通过卷积展平成特定维度的一维向量序列,再给每个向量加上位置向量 (position embedding) 后,便可以送入 Transformer Encoder 进行注意力机制的学习了。Transformer Encoder 输出的结果是一个一维向量需要通过卷积和上采样将其恢复成与输入尺寸相同的特征图。Transformer Layer 的内部结构示意图如图五所示。其中,Transformer Encoder 主要包

括两个模块,一个是多头注意力模块和一个是全连接层模块 (MLP),两个模块均使用残差连接。Norm 层负责归一化处理,有助于网络收敛,同时防止过拟合。将多头注意力模块和 MLP 作为一个子模块,进行 S 次堆叠最终形成 Transformer Encoder。

### 4. 总结

本文提出的 ATCSP-YOLOv5 是一种用于检测具有与 PCB 数据集相似特征的小目标的算法。首先,本文借鉴了一些有效的前沿技术的思想,如 Self Attention、ViT 和 CSPNet,并巧妙地将它们集成为算法的核心。然后,本文提出了许多有效的小目标数据集预处理策略。在此基础上,本文还通过网络替换微调尝试获得更高精度的 PCB 数据集检测模型,并将该模型制作成检测软件。最后,希望这一研究成果能够为从事小目标检测的研究人员提供更有效的参考经验。

#### 参考文献:

- [1] A review of object detection algorithms based on deep learning [J].
- [2] OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks [J].
- [3] Region average pooling for context-aware object detection [C].
- [4] Learning RoI Transformer for Detecting Oriented Objects in Aerial Images [J].
- [5] Feature Pyramid Networks for Object Detection [J].
- [6] Efficient mappings of pyramid networks [J].
- [7] Fully Convolutional Lightweight Pyramid Network for Vehicle Detection in Aerial Images [J].
- [8] EfficientDet: Scalable and Efficient Object Detection [J].
- [9] Using an EfficientNet-LSTM for the recognition of single Cow's motion behaviours in a complicated environ...
- [10] An Analysis of Scale Invariance in Object Detection - SNIP [C].
- [11] Li, X Liang, Y Wei et al., "Perceptual Generative Adversarial Networks for Small Object Detection [J]", 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [12] S D Jadhav, A Scale-Insensitive Convolutional Neural Network for Fast Vehicle Detection, 2019.