

基于改进 YOLOv5 的轻量级芯片封装缺陷检测方法

赖武刚, 李家楠, 林凡强

(成都理工大学 机电工程学院, 成都 610059)

摘要: **目的** 针对芯片封装缺陷检测过程中检测精度低与模型难部署的问题, 提出 YOLOv5-SPM 检测网络, 旨在提高检测精度并实现模型轻量化。**方法** 首先, 通过在特征提取模块后增加通道注意力机制, 提高缺陷通道的关注度, 减少冗余特征的干扰, 进而提升目标的检测精度。其次, 在主干网络与颈部网络连接处使用快速特征金字塔结构, 更好地融合了自建芯片数据集的多尺度特征信息。最后, 将主干网络的特征提取模块更换为 MobileNetV3, 将常规卷积更换为深度卷积和点卷积, 有效降低了模型尺寸和计算量。**结果** 经过改进后的新网络 YOLOv5s-SPM 在模型参数下降 29.5% 的情况下, 平均精度较原网络提高了 0.6%, 准确率提高了 3.2%。**结论** 新网络相较于传统网络在芯片缺陷检测任务中实现了模型精度与速度的统一提高, 同时由于模型参数减小了 29.5%, 更适合部署在资源有限的工业嵌入式设备上。

关键词: YOLOv5; 芯片封装缺陷检测; 通道注意力机制; 特征金字塔池化; 轻量化

中图分类号: TB487 文献标识码: A 文章编号: 1001-3563(2023)17-0189-08

DOI: 10.19554/j.cnki.1001-3563.2023.17.023

Lightweight Chip Package Defect Detection Method Based on Improved YOLOv5

LAI Wu-gang, LI Jia-nan, LIN Fan-qiang

(College of Mechanical and Electrical Engineering, Chengdu University of Technology, Chengdu 610059, China)

ABSTRACT: The work aims to propose a YOLOv5-SPM detection network, solve the challenges concerning diminished detection accuracy and complex model deployment encountered in chip packaging defect detection, to enhance detection accuracy and facilitate the implementation of lightweight models. The channel attention mechanism was placed after each feature extraction module to increase the importance of defect-related channels, reduce the interference of redundant features and improve the target detection accuracy. Then, the SimSPPF pyramid pooling structure was used in the connection of the backbone network and the neck network to integrate multi-resolution features of the self-built chip data set more effectively. After that, the feature extraction module of the backbone network was replaced with MobileNetV3 and the conventional convolution was replaced with deep convolution and point convolution to significantly reduce the model size and calculation scale. The improved new network YOLOv5s-SPM achieved a 0.6% increase in mean average precision and a 3.2% increase in accuracy compared with the original network, while reducing the model parameters by 29.5%. The experimental results validate the superiority of the proposed network in achieving higher accuracy and faster detection speed in the task of chip defect detection. Since the model parameters are reduced by 29.5%, it can also be deployed on industrial embedded devices.

KEY WORDS: YOLOv5; chip package defect detection; channel attention mechanism; simplified spatial pyramid pooling-fast; lightweight

芯片技术是当今高新技术中的重要组成部分,其中封装是芯片从制造到成品不可或缺的关键环节之一。然而在工厂加工生产中时常会出现划痕或缺脚等各种封装缺陷,对芯片的丝印识别和实际使用都会造成巨大影响,从而降低良品率。因此,对芯片封装缺陷进行检测有着重要的现实意义。

传统方法对芯片封装缺陷的检测一般使用数字图像处理技术^[1],但近年来随着神经网络技术的发展,逐渐引入深度学习来进行缺陷识别,其中大致分为两阶段模型 Faster R-CNN 和单阶段模型 YOLO 系列。对于两阶段模型, Zhang 等^[2]利用改进后的 Faster R-CNN,提出了一种全新的 LED 芯片表面缺陷检测方法。该方法首先在 COCO 数据集上完成了预训练,然后再在收集的 LED 芯片表面数据集上完成了微调。实验结果表明,该方法在生产线上具有良好的检测效果。

考虑到两阶段网络的检测速度相对较慢,有许多学者采用单阶段模型。Liu 等^[3]提出了一种基于 YOLOv3 的小目标检测方法 UAV-YOLO,通过对网络浅层添加额外的卷积层来丰富空间信息,并优化了网络训练方法,能够适应不同环境下的小目标检测任务。周天宇等^[4]改进了 YOLOv3 的特征提取网络,设计了 4 个检测尺度,并优化了网络的初始检测框,实现了对多种载波芯片缺陷的高精度检测。相似地, Wang 等^[5]提出了一种名为 YOLOv4-SA 的目标检测网络,通过将注意力机制与 YOLOv4 相结合,用于微小缺陷的检测。该网络由特征提取主干、空间注意模块(SAM)和特征融合模块组成。通过 SAM 的校正,使特征图能够突出缺陷区域,从而更有效地识别微小缺陷。实验证明,该网络可以有效提高平均精度均值(m_{AP})。

除此之外,罗月童等^[6]提出一种无监督学习的方法,对含有缺陷的芯片图像利用卷积去噪自编码器进

行重构,再将重构后的新图像与输入图像相减,得到的结果被称为“残差图”。这种方法能够提取出包含缺陷信息的特征图,从而更容易地进行缺陷检测。

可以看出,在使用深度学习技术进行芯片封装缺陷检测的任务中,监督学习占主流趋势,而模型的检测速度与精度,还有模型大小一直都是学者们关注的重点。为进一步解决这些问题,本文以更先进的 YOLOv5 网络为基础,进一步提升模型性能指标,实现模型的轻量化,进而降低芯片封装缺陷检测设备的部署门槛。

1 YOLOv5 原网络介绍

YOLOv5 是一种快速的目标检测算法^[7],能够实时地对图像中的物体进行分类和定位。其网络结构如图 1 所示。

YOLOv5 网络结构包含 4 个部分:Input、Backbone、Neck 和 Head^[8]。

Input 部分:根据真实框分布使用 k-means 聚类算法进行自适应锚框计算,并采用与 YOLOv4 相同的数据增强方式。

Backbone 部分:主要由 CBS、C3、SPPF 等模块组成。其中 C3 模块包含 3 个 CBS 层和多个 Bottleneck 层,将原有特征图分为两部分,分别为正常卷积和残差卷积,然后将两者拼接,从而对残差特征进行学习。SPPF 模块(空间金字塔池化)对特征图进行卷积和串行最大池化,生成包含多尺度信息的最终特征图。

Neck 部分:主要采用了 FPN (Feature Pyramid Networks) 来获取多级特征图并接入 PAN (Path Aggregation Network) 模块进行特征聚合,以增强模型对不同尺度目标特征的融合。

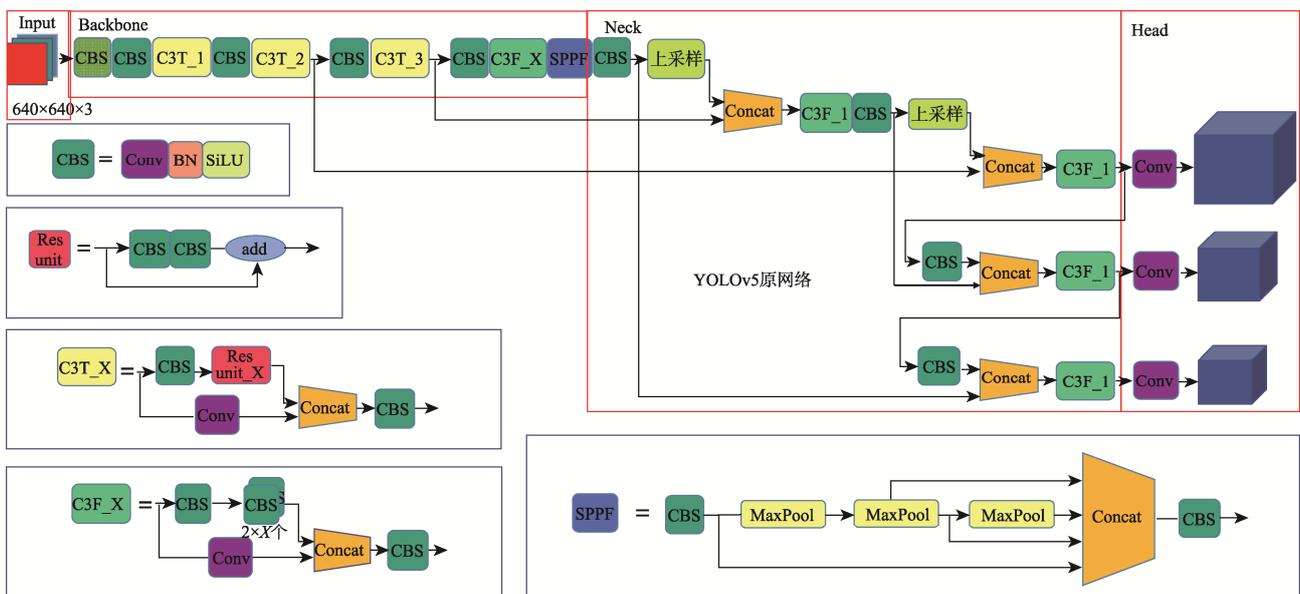


图 1 YOLOv5 原网络
Fig.1 YOLOv5 original network

Head 部分: 用于完成预测的任务。输出端包含损失函数的计算和非极大值抑制 (NMS), NMS 用于在目标检测任务中解决生成多个预测框的问题, 有效解决冗余^[9]。

2 本文改进的 YOLOv5 网络

本文改进的 YOLOv5 网络模型结构如图 2 所示。网络采用 MobileBlock (MobilenetV3 Block) 更换了网络主干部分的特征提取模块, 使用深度卷积和点卷积的耦合取代常规卷积, 实现了模型的轻量化。此外, 在 MobileBlock 的输出特征图进行特征融合之前, 使用 SE 通道注意力机制强化目标的特征信息, 从而提高网络检测精度。同时, 本网络使用 SimSPPF 特征金字塔模块对多尺度信息进行融合, 提高了模型的鲁棒性, 从而提高模型对芯片封装缺陷的检测精度。

2.1 SE 模块的引入

通道注意力机制可以帮助模型更好地学习目标特征。具体来说, 在使用大量的芯片缺陷训练数据后, 网络会自适应地决定哪些通道对检测结果的影响更显著, 从而使模型更加专注于学习目标特征, 减少对冗余信息的依赖, 进而提高检测精度^[10]。

SE 模块 (Squeeze-and-Excitation) 的结构如图 3 所示。对于特征图 U , 先通过 Squeeze 操作, 采用

全局平均池化, 将 C 通道 $H \times W$ 尺寸的特征图在通道数不变的情况下压缩成 1×1 的特征图, 公式见式 (1)。

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

式中: u_c 为输入特征图; Z_c 为压缩特征信息; $F_{sq}()$ 为 Squeeze 操作; $H \times W$ 为输入特征图的尺寸大小; (i, j) 为特征图的纵横坐标信息。

再使用 excitation 操作, 构建全连接网络, 从而获取特征图每个通道的重要程度:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

式中: W 为维度信息; s 为输出的通道重要程度; $F_{ex}()$ 为 excitation 操作; $\sigma()$ 为 Sigmoid 激活函数; $\delta()$ 为 ReLU 激活函数。

2.2 SimSPPF 空间金字塔池化

SPP (Spatial Pyramid Pooling) 空间金字塔池化是一种广泛应用于各种深度学习模型中的特征池化模块^[11]。在该模块的基础上, 本文使用了 SimSPPF 模块, 该模块主要优化了 SPP 模块中的并行池化操作。由于并行池化操作需要同时处理多个池化层, 因此计算量较大, 处理速度较慢。SimSPPF 模块将并行池化操作变为串行操作, 同时将激活函数从 SiLU 替换为 Relu, 大大降低了计算量, 提高了处理速度。SPP 与 SimSPPF 结构见图 4。

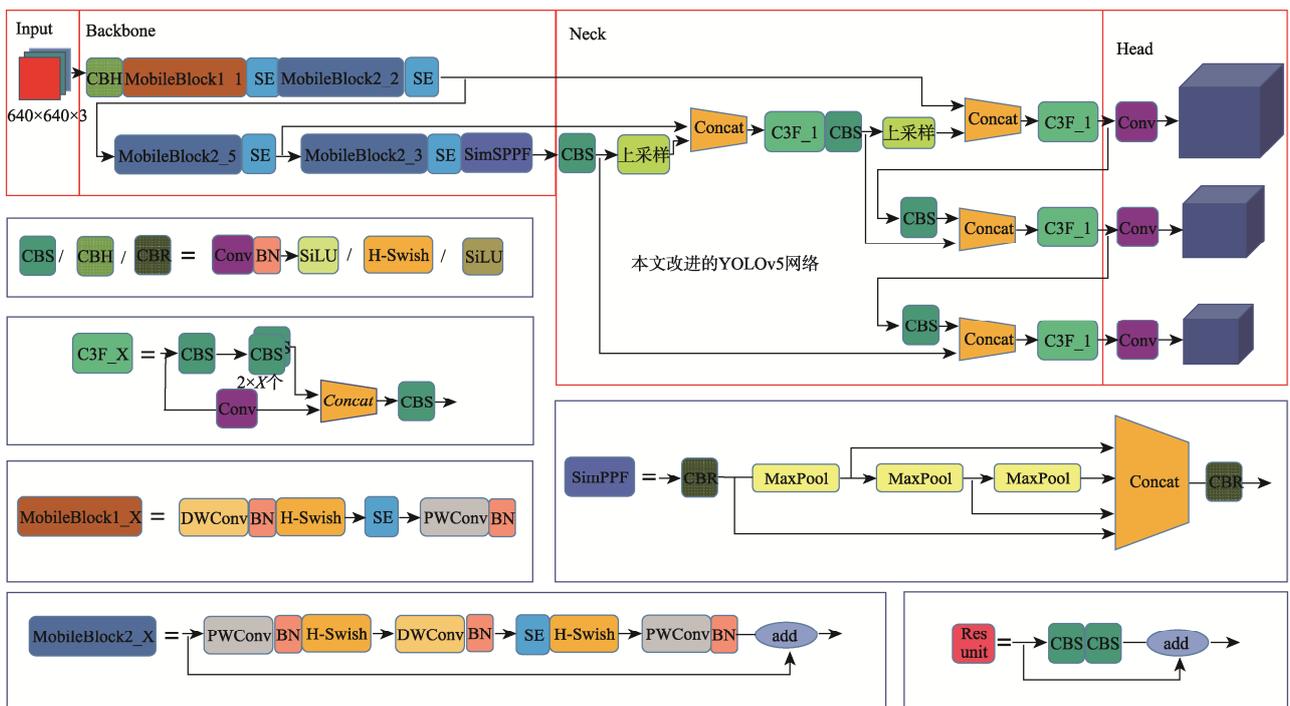


图 2 本文改进的 YOLOv5 网络
Fig.2 Improved YOLOv5 network

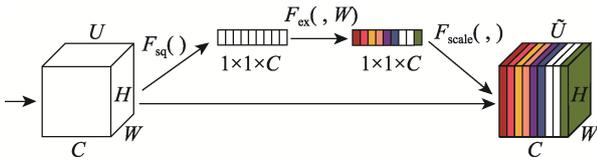


图3 SE模块结构
Fig.3 Structure of SE module

2.3 主干网络 MobileBlock 模块

本文使用的 MobileBlock 模块由 MobilenetV3 网络构成^[12]。模块如图 5 所示，该模块极大地降低了网络的计算量，同时经过后续的实验验证，使用 MobileBlock 模块能保证对芯片封装缺陷的检测效果，同时使得模型更加轻量化。

MobileBlock 使用的深度可分离卷积是一种轻量化卷积操作，它将标准卷积划分为深度卷积和点卷积 2 个独立的层。其中深度卷积通过对每层特征图应用一个单独的卷积核来执行过滤步骤，而点卷积则通过输入通道的点对点线性计算来构建过滤后的新特征。这种分解方式可以大大减少参数数量和计算量，从而实现模型的轻量化。深度卷积计算式见式 (3)。

$$\hat{G}_{k,l,m} = \sum_{i,j} \hat{K}_{i,j,m} \cdot F_{k+i-1,l+j-1,m} \quad (3)$$

后接 1x1 卷积后总的计算量 D 见式 (4)。

$$D = D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F \quad (4)$$

式中：F 和 G 分别为输入和输出特征图；K 为深度卷积核；D_K 为卷积核的深度；M 和 N 分别为输入和输出通道数；D_F 为输入特征图的空间维度。通过将标准卷积表示为滤波和融合两步过程，可以在输出特征图大小不变的情况下，将计算量减少为原来的 $\frac{1}{N} + \frac{1}{D_K^2}$ ，降低计算复杂度，实现模型轻量化。

本文使用 MobileBlock 替换原 YOLOv5s 网络中的 C3 模块，并且对骨干网络进行精简处理，减少了特征提取的次数，进一步提升了芯片封装缺陷检测特征提取网络的轻量化程度。

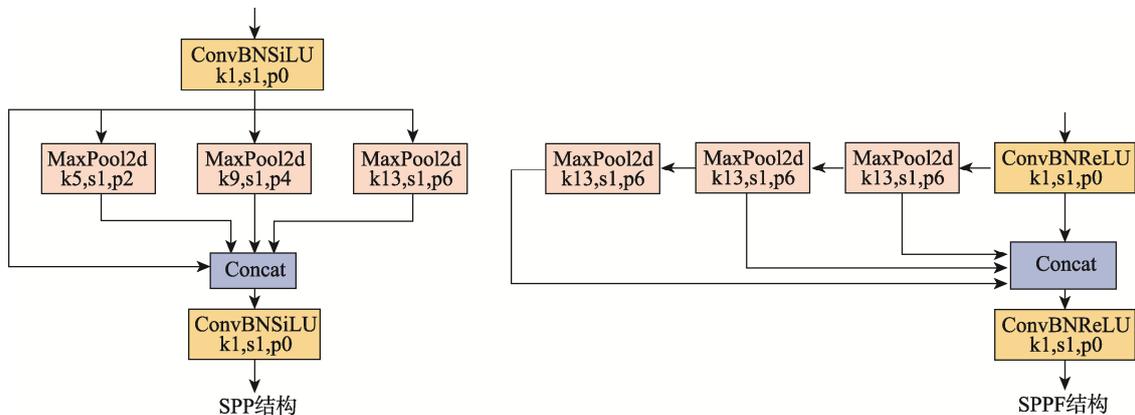


图4 SPP 和 SimSPPF 结构
Fig.4 Structure of SPP and SimSPPF

3 结果与分析

3.1 实验环境及数据集

本文的实验环境基于 AutoDL 云平台，使用 PyTorch 1.9.0 框架，Python 版本 3.8.10，CUDA 版本 12.0。GPU 为 RTX 3080，CPU 配置为 12 vCPU Intel(R) Xeon(R) Platinum 8255C CPU @ 2.50 GHz。实验在强聚光效果的点光源照射条件下，针对 SOT-89 封装的 AMS1117 稳压芯片使用图像采集与捕捉平台(图 6)搭载的工业智能相机采集芯片图像，建立自建芯片封装数据集。其中相机的处理器为 Intel 四核 1.9 GHz，CPU 为 4 GB 内存，相机帧频为 30 帧/s，分辨率为 2 592×2 048，后续处理成 640×640 大小。数据集中含有划痕(Scratch)和引脚缺损(Pin Defect) 2 种类型的缺陷，共计 535 张图片^[13]，使用 4-mosaic 数据增强方式提高数据集丰富程度，以防止模型过拟合。

图片为 640×640 的 RGB 三通道图，建立数据集过程中保证待检测芯片位于图片正中，还原工业检测流程，同时按照 8:2 的比例将数据集划分为训练集和验证集 2 个部分。其中，图 7 为拍摄的原图；图 8 为检测结果图，图 8 结果表明可以正确检测出所含有的缺陷。

3.2 评估指标

通过从模型参数量、预测速度、运算量、准确率 P、召回率 R、平均精度 A_p、平均精度均值 m_{AP} 等方面综合评估模型性能及复杂度。其中准确率 P 表示预测正确的比例，召回率 R 表示预测的全面性；平均精度 A_p 通过计算 P-R 曲线下的面积，得到模型在所有置信度阈值下的平均精度^[14]，通过对每个类别的 A_p 求均值就可以得到所有类别的平均精度均值 m_{AP}^[15]。其中准确率 P、召回率 R、平均精度 A_p 和平均精度均值 m_{AP} 的计算公式如下：

$$P = \frac{T_p}{T_p + F_p} \quad (5)$$

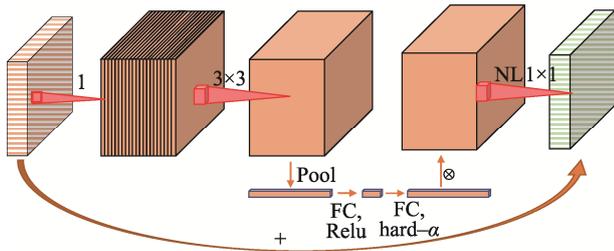
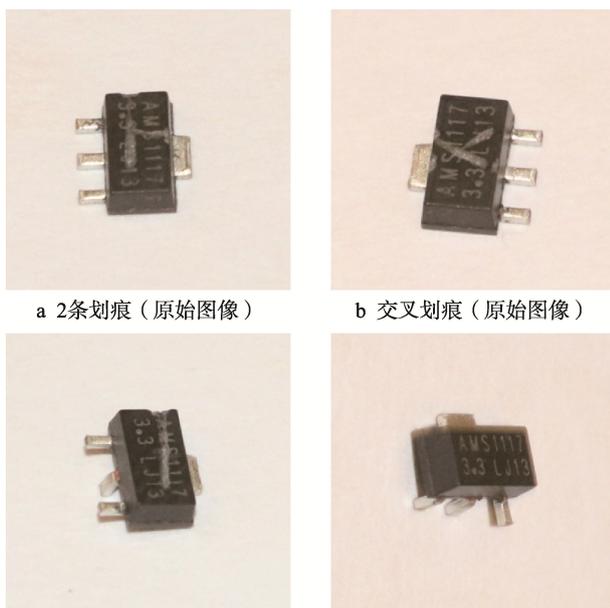


图 5 MobileBlock 模块
Fig.5 MobileBlock module

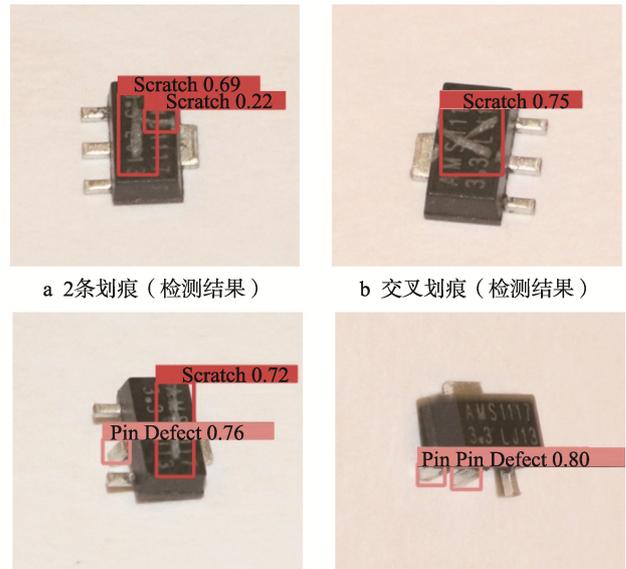


图 6 图像采集与捕捉平台
Fig.6 Image acquisition and capture platform



c 1个引脚缺陷1条划痕 (原始图像) d 2个引脚缺陷 (原始图像)

图 7 芯片封装缺陷检测原图
Fig.7 Original image of chip package defect detection



a 2条划痕 (检测结果) b 交叉划痕 (检测结果)
c 1个引脚缺陷1条划痕 (检测结果) d 2个引脚缺陷 (检测结果)

图 8 芯片封装缺陷检测结果
Fig.8 Result of chip package defect detection

$$R = \frac{T_p}{T_p + F_N} \quad (6)$$

$$A_p = \int_0^1 P(R) dR \quad (7)$$

$$m_{AP} = \frac{\sum_{i=1}^N A_p}{N} \quad (8)$$

式中: T 和 F 为实际结果正确与否; P 和 N 为推断为正或负样本; T_p 为推断为正样本且实际正确的数量; F_p 为推断为正样本但实际错误的数量; T_N 为推断为负样本但实际错误的数量^[16]; N 为总类别数。

3.3 实验结果与分析

3.3.1 模型复杂度与性能对比

为了验证单一结构改变对模型复杂度与性能的影响, 本文进行了一系列实验, 使用了 YOLOv5s 作为基准网络, 在此基础上进行了改进。各网络模型的复杂度与性能对比如表 1 和表 2 所示, 其中 $m_{AP@0.5}$ 值表示 I_{ou} 阈值为 0.5 时的平均精度均值, $m_{AP@0.5:0.95}$ 值为 I_{ou} 阈值从 0.5 变化到 0.95 上的平均精度均值。

表 1 模型复杂度对比
Tab.1 Comparison of model complexity

模型	参数量	运算量 (GFLOPs)	模型大小/ MB
YOLOv5s	7 015 519	15.8	14.5
YOLOv5s-S	7 059 039	15.8	14.6
YOLOv5s-P	7 016 287	15.8	14.5
YOLOv5s-M	5 020 893	11.3	10.5
YOLOv5s-SPM	5 045 741	11.3	10.6

注: 加粗字体均为表格中所有模型该项指标的最优值, 其中预测速度指标为 5 次实验结果的期望值。

表2 模型性能对比
Tab.2 Comparison of model performance

模型	准确率/%	召回率/%	$m_{AP@0.5}/\%$	$m_{AP@0.5:0.95}/\%$	预测速度/ms
YOLOv5s	91.1	79.2	85.4	44.0	10.6
YOLOv5s-S	91.7	77.5	86.6	46.1	11.2
YOLOv5s-P	90.0	79.6	86.2	44.7	10.48
YOLOv5s-M	92.6	75.5	84.3	43.3	14.42
YOLOv5s-SPM	94.3	75.3	86.0	44.8	15.7

分析实验结果可知, YOLOv5s-S 在少量提高模型复杂度的基础上, $m_{AP@0.5}$ 的数值上提升了 1.2%, $m_{AP@0.5:0.95}$ 的数值上提升了 2.1%, 说明通过在不同维度特征图后添加通道注意力机制能有效地对目标特征进行强化, 从而使得模型更好地识别出芯片封装缺陷。YOLOv5s-P 在复杂度不变的情况下, 略微提升模型预测速度, 且 m_{AP} 数值比原网络提高了 0.8%, 说明串行结构相较于并行结构的特征金字塔能更好地融合自建芯片数据集的尺度特征, 鲁棒性更强。YOLOv5s-M 在略微降低模型性能的同时, 只使用原模型 70% 的参数, 极大地降低了模型复杂度, 能更快地进行预测, 满足轻量化要求。本文提出的 YOLOv5s-SPM 在模型复杂度远低于 YOLOv5s 原模型的基础上, $m_{AP@0.5}$ 的数值提升了 0.6%, $m_{AP@0.5:0.95}$ 的数值提升了 0.8%, 进一步提升了对划痕与引脚损伤 2 种缺陷的定位与识别精确度。

3.3.2 损失函数分析

YOLOv5s 的损失函数分为 cls_loss、obj_loss 以及 box_loss 共 3 个部分^[17]。其中 cls_loss 和 obj_loss 均采用交叉熵损失, box_loss 则采用 CIoU 计算损失^[18], 相关公式如下:

$$y_i = \text{sigmoid}(x_i) = \frac{1}{1 + e^{-x_i}} \quad (9)$$

$$L_{\text{class}} = -\sum_{n=1}^N y_i * \ln(y_i) + (1 - y_i) * \ln(1 - y_i) \quad (10)$$

$$L_{\text{CIoU}} = 1 - I_{\text{IoU}} + \frac{\rho^2(b, b^{\text{gt}})}{C^2} + \alpha v \quad (11)$$

式中: ρ 为预测框与标定框中心点的距离; C 为预测框与标定框最小包围矩形对角线的长度; v 与预测框和标定框的宽高比相关; α 为 v 的影响因子^[18]。

本文提出的 YOLOv5s-SPM 网络在验证集上的损失函数如图 9 所示。

设置训练的迭代次数为 400 次, 在 0~100 次时损失函数剧烈下降, 之后训练速度放缓, 直至 400 轮迭代结束各损失函数均趋于平稳, 最终并未出现过拟合现象。

3.3.3 不同模型对比

为了进一步评估改进的模型在自建芯片数据集上的性能, 选取 YOLO 系列的其他模型以及经典的轻量化模型进行了对比实验, 用来验证所提出模型的

综合性能。不同模型检测结果的对比如表 3 所示, 其中 Ghostnet 为将 YOLOv5s 骨干网络替换对应轻量化网络的模型。

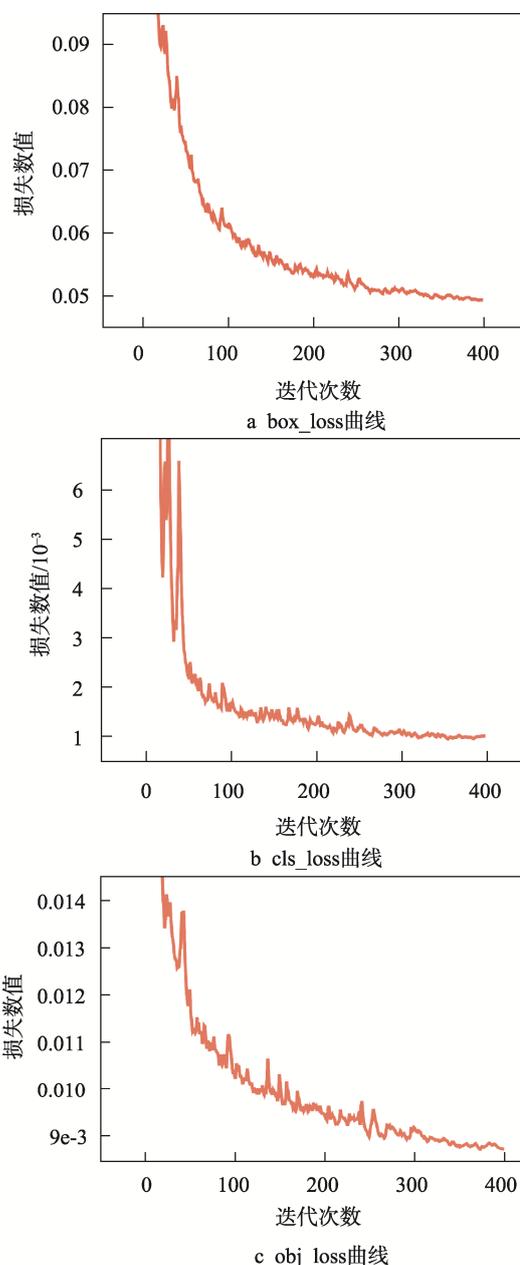


图9 YOLOv5-SPM 损失函数迭代曲线
Fig.9 YOLOv5-SPM loss function iteration curve

表 3 不同模型检测结果对比

Tab.3 Comparison of detection results of different models

模型	$A_p/\%$		$m_{AP@0.5}/\%$
	Pin Defect (引脚缺陷)	Scratch (丝印划痕)	
YOLOv5s	91.0	79.8	85.4
YOLOv7-tiny	83.6	55.9	69.7
GhostNet	90.2	76.1	83.1
YOLOv5s-SPM	91.2	80.9	86.0

分析 YOLOv5s、YOLOv7-tiny、GhostNet、YOLOv5s-SPM 模型各类型缺陷检测结果, 从表 3 可以看出, YOLOv5-SPM 的平均精度对比前 3 个模型分别提高了 0.6%、16.3%、2.9%, 且在 2 种类型的缺陷检测任务中的表现也更加优异。证明本文设计的 YOLOv5s-SPM 模型优于 YOLOv5s、YOLOv7-tiny、GhostNet 等 3 个模型。同时, 不同模型的性能对比结果如表 4 所示。

表 4 不同模型性能对比

Tab.4 Performance comparison of different models

模型	参数量	准确率/%	召回率/%	$m_{AP@0.5}/\%$	预测速度/ms
YOLOv7-tiny	6 010 302	81.5	63.3	69.7	6.12
GhostNet	4 745 411	88.3	76.0	83.1	14.22
YOLOv5s-SPM	5 045 741	94.3	75.3	86.0	15.7

通过对比可以看出, 相较于拥有最快预测速度的 YOLOv7-tiny, YOLOv5-SPM 在模型参数量、准确率、召回率以及 $m_{AP@0.5}$ 等多项指标表现更优。尽管改进后的网络预测速度低于 YOLOv7-tiny 的网络预测速度, 但在保证帧率为 60 帧/s 的情况下平均精度超过了 17%, 能满足芯片封装缺陷检测的实时性要求。与经典轻量级网络 GhostNet 相比, YOLOv5s-SPM 在模型参数量上仅相差 6%, 而准确率和 $m_{AP@0.5}$ 指标分别高出 6% 和 3%, 说明 MobilenetV3 在整体性能上的表现要优于 GhostNet。综合考虑, 本文提出的 YOLOv5s-SPM 模型与新版本的 YOLO 以及典型轻量化模型相比综合性能优秀, 平均精度、检测速度和模型复杂度均满足工业生产需求, 能够处理典型的生产关键问题(如实时性问题和小目标检测问题)^[19], 并且能够方便地在嵌入式设备中进行部署, 能良好地完成芯片封装缺陷检测任务。

4 结语

本文提出了一种基于改进 YOLOv5 的芯片封装缺陷检测方法, 通过在自建芯片数据集上进行训练、

对比和优化。通过引入 SE 通道注意力机制, 强化了目标特征的重要程度进而提高了检测精度; 在主干网络和颈部网络之间加入了 SimSPPF 特征金字塔结构用来融合不同尺度的特征信息; 将主干网络替换为 MobileNetV3, 并使用深度可分离卷积, 实现轻量化目标的同时, 性能优于原 YOLOv5 网络。后续将进行数据集的扩充工作, 增加可识别缺陷类别, 同时进一步提高模型的检测精度和速度, 并研究如何将模型部署在工业嵌入式设备上, 以进一步优化和完善芯片封装缺陷检测平台在实际封装缺陷检测应用中的表现, 拓展其应用场景。

参考文献:

- [1] 王新宇, 蒋三新. 芯片缺陷检测综述[J]. 现代制造技术与装备, 2022, 58(5): 94-98.
WANG Xin-yu, JIANG San-xin. Overview of Chip Defect Detection[J]. Modern Manufacturing Technology and Equipment, 2022, 58(5): 94-98.
- [2] ZHANG Zhi-wei, GONG Qian, CAO Yuan, et al. Detecting LED Chip Surface Defects with Modified Faster R-CNN[C]// 18th International SoC Design Conference, Jeju Island, 2021: 268-269.
- [3] LIU Ming-jie, WANG Xian-hao, ZHOU An-jian, et al. UAV-YOLO: Small Object Detection on Unmanned Aerial Vehicle Perspective[J]. Sensors, 2020, 20(8): 2238.
- [4] 周天宇, 朱启兵, 黄敏, 等. 基于改进 YOLOV3 的载波芯片缺陷检测[J]. 激光与光电子学进展, 2021, 58(12): 78-85.
ZHOU Tian-yu, ZHU Qi-bing, HUANG Min, et al. Defect Detection of Chip on Carrier Based on Improved YOLOV3[J]. Laser & Optoelectronics Progress, 2021, 58(12): 78-85.
- [5] WANG Shuo, WANG Hong-yu, YANG Fan, et al. Attention-Based Deep Learning for Chip-Surface-Defect Detection[J]. The International Journal of Advanced Manufacturing Technology, 2022, 121(3/4): 1957.
- [6] 罗月童, 卞景帅, 张蒙, 等. 基于卷积去噪自编码器的芯片表面弱缺陷检测方法[J]. 计算机科学, 2020, 47(2): 118-125.
LUO Yue-tong, BIAN Jing-shuai, ZHANG Meng, et al. Detection Method of Chip Surface Weak Defect Based on Convolution Denoising Auto-Encoders[J]. Computer Science, 2020, 47(2): 118-125.
- [7] WANG Min, YANG Wen-zhong, WANG Lie-jun, et al. FE-YOLOv5: Feature Enhancement Network Based on

- YOLOv5 for Small Object Detection[J]. Journal of Visual Communication and Image Representation, 2023, 90: 103752.
- [8] HE Di, XU Ke, ZHOU Peng. Defect Detection of Hot Rolled Steels with a New Object Detection Framework Called Classification Priority Network[J]. Computers & Industrial Engineering, 2018, 128: 290-297.
- [9] ROY A M, BOSE R, BHADURI J. A Fast Accurate Fine-Grain Object Detection Model Based on YOLOv4 Deep Neural Network[EB/OL]. 2021: arXiv: 2111.00298. <https://arxiv.org/abs/2111.00298>
- [10] 王一, 龚肖杰, 程佳, 等. 基于改进 YOLOv5 的金属工件表面缺陷检测[J]. 包装工程, 2022, 43(15): 54-60. WANG Yi, GONG Xiao-jie, CHENG Jia, et al. Surface Defect Detection of Metal Workpiece Based on Improved YOLOv5[J]. Packaging Engineering, 2022, 43(15): 54-60.
- [11] 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.
- [12] JIA Liang-quan, WANG Ya-wen, ZANG Ying, et al. MobilenetV3 With CBAM for Bamboo Stick Counting[J]. IEEE Access, 2022, 10: 53963-53971.
- [13] 武泽坤, 叶晓娴, 陈梦. 基于改进 YOLOv5 的药用胶囊表面缺陷检测方法[J]. 包装工程, 2022, 43(23): 297-304. WU Ze-kun, YE Xiao-xian, CHEN Meng. Surface Defect Detection Method for Pharmaceutical Capsules Based on Modified YOLOv5[J]. Packaging Engineering, 2022, 43(23): 297-304.
- [14] WAN Guang, FANG Hong-bo, WANG Deng-zhun, et al. Ceramic Tile Surface Defect Detection Based on Deep Learning[J]. Ceramics International, 2022, 48(8): 11085-11093.
- [15] 马学森, 马吉, 蒋功辉, 等. 基于注意力机制和多尺度特征融合的绝缘子缺陷检测方法[J]. 南京大学学报(自然科学), 2022, 58(6): 1020-1029. MA Xue-sen, MA Ji, JIANG Gong-hui, et al. Insulator Defect Detection Method Based on Attention Mechanism and Multi-Scale Feature Fusion[J]. Journal of Nanjing University (Natural Science), 2022, 58(6): 1020-1029.
- [16] 李鑫, 汪诚, 李彬, 等. 改进 YOLOv5 的钢材表面缺陷检测算法[J]. 空军工程大学学报(自然科学版), 2022, 23(2): 26-33. LI Xin, WANG Cheng, LI Bin, et al. Steel Surface Defect Detection Algorithm Based on Improved YOLOv5[J]. Journal of Air Force Engineering University (Natural Science Edition), 2022, 23(2): 26-33.
- [17] XUE Jin-lin, CHENG Feng, LI Yu-qing, et al. Detection of Farmland Obstacles Based on an Improved YOLOv5s Algorithm by Using CIoU and Anchor Box Scale Clustering[J]. Sensors, 2022, 22: 1790.
- [18] LIU Yuan-jie, LYU Zun-chao, HU Ying-yue, et al. Improved Cotton Seed Breakage Detection Based on YOLOv5s[J]. Agriculture, 2022, 12: 1630.
- [19] CHEN Ya-jun, DING Yuan-yuan, FAN Zhao, et al. Surface Defect Detection Methods for Industrial Products: A Review[J]. Applied Sciences, 2021, 11(16): 7657.

责任编辑: 曾钰婵