

DOI:10.3969/j.issn.1671-024x.2024.03.007

基于 RT-YOLO-V5 的芯片外观缺陷检测

郭翠娟^{1,2}, 王妍^{1,2}, 刘净月³, 席雨³, 徐伟^{1,2}, 王坦³

(1. 天津工业大学 电子与信息工程学院, 天津 300387; 2. 天津工业大学 天津光电探测技术与系统重点实验室, 天津 300387; 3. 中国航天科工防御技术研究院 微电子器件可靠性实验室研究与试验中心, 北京 100854)

摘要: 针对传统的人工芯片检测方法效率低、过分依赖人为操作且误检率高等产生的问题, 提出了一种基于 Res-CBS 模块与增加微检测层(Tiny-scale detection layer)的 RT-YOLO-V5 检测方法用于检测芯片外观缺陷。首先搭建了图像采集系统, 并制作了芯片外观缺陷检测数据集。为解决芯片外观缺陷形状不规则、大小不统一、位置不确定带来的检测精度低等问题, 在 CBS 模块中增加短连接, 融合输入输出的特征信息, 减少信息损失, 优化推理速度; 其次, 增加一个微小尺度的检测层, 提高模型对微小目标的特征提取能力。实验结果表明: 使用改进后的网络对芯片外观缺陷进行检测, 平均精度(mAP)达到 95.5%, 相对于原始网络提升了 5.7%; 除此之外, 改进后的 RT-YOLO-V5 在先验框损失(Box_loss)与小目标缺陷的检测精度上都得到了一定的提升。

关键词: YOLO-V5; 芯片; 缺陷检测; 特征融合; 卷积神经网络

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1671-024X(2024)02-0050-08

Chip appearance defect detection based on RT-YOLO-V5

GUO Cuijuan^{1,2}, WANG Yan^{1,2}, LIU Jingyue³, XI Yu³, XU Wei^{1,2}, WANG Tan³

(1. School of Electronics and Information Engineering, Tiangong University, Tianjin 300387, China; 2. Tianjin Key Laboratory of Optoelectronic Detection Technology and System, Tiangong University, Tianjin 300387, China; 3. Microelectronic Device Reliability Laboratory Research and Test Center of Defense Technology for Aerospace Science and Industry, Beijing 100854, China)

Abstract: Aiming at the problems caused by traditional manual chip detection, with low efficiency, excessive dependence on human operation and high misdetection rate, an RT-YOLO-V5 detection method was proposed to detect chip appearance defects based on the Res-CBS module and an additional Tiny-scale detection layer. First of all, an image acquisition system was built, and a chip appearance defect detection dataset was produced. Due to the defects are irregular in shape, inconsistent in size and uncertain in location, the performance of YOLO-V5 network can no longer meet the detection requirements. A short connection was added to the CBS module, fusing the feature information of input and output, reducing the information loss and optimizing the inference speed. In addition, a tiny-scale detection layer is added as well, to improve the feature extraction capability of the model for tiny targets. The experimental results show that using the improved network for chip appearance defect detection, mAP reached 95.5%, which was a 5.7% improvement compared to the original network. In addition, the improved RT-YOLO-V5 has gained some improvement in both Box_loss and the accuracy of tiny-scale defect detection.

Key words: YOLO-V5; chip; defect detecting; feature fusion; convolutional neural network

近年来, 随着数字化时代及集成电路的蓬勃发展, 芯片的需求量越来越大。同时, 芯片向着小型化、高集成度方向发展, 且广泛应用于电子设备、计算机

及工业等领域。芯片的制作要经过数道工艺流程, 生产过程复杂。芯片的运输需要使用专用包装, 以保证产品不会因外力作用而产生损伤。在生产及运输过程

收稿日期: 2022-10-20

基金项目: 中国博士后科学基金面上基金资助项目(2019M661013); 天津市科技计划资助项目(20YDTPJC01090; 22YDTPJC00090)

第一作者: 郭翠娟(1975—), 女, 博士, 副教授, 主要研究方向为现代通信网络与系统、通信设备设计等。E-mail: guocuijuan@tiangong.edu.cn

通信作者: 徐伟(1984—), 男, 博士, 副教授, 主要研究方向为图像处理与人工智能、光纤传感器与光谱检测、电路与系统。E-mail: xuwei@tiangong.edu.cn

中难免会存在磕碰,从而产生一些外观缺陷,如污迹、划痕、缺损以及引脚缺失等。随着芯片尺寸的小型化发展,芯片外观的缺陷检测也变得愈发困难。芯片外观存在缺陷会影响产品质量和芯片性能,损坏严重的芯片在后续的使用中会产生负面影响。芯片的应用领域对芯片的高稳定性及外观一致性要求较高。因此,在质量检测过程中将存在缺陷的芯片挑出至关重要^[1]。

为了减少芯片外观缺陷带来的损失,目前主要采用传统的人工检测方法进行检测,利用肉眼观察工件照片,发现缺陷进而筛选工件。然而,该方法检测速度慢,多依赖于检测人员的经验判断。除此之外,人工检测方法还容易受人为因素影响,误判率高,检测精度低且易造成检测人员的用眼疲劳。为弥补人工检测方法的不足,Chiou等^[2]首先对彩色图像中提取镀金区域,然后采用形态学操作等技术对区域内的缺陷定位,并提取特征信息,对缺陷进行分类。Jin等^[3]引入了一种自适应阈值法和一种无参考的路径行走机制,计算芯片的位置和方向,并进行特征提取与缺陷检测。研究人员还采用点模式匹配、点云与图像融合等机器视觉方法对芯片存在的缺陷进行检测。机器视觉检测方法正在逐步取代人工检测的方法,但是仍存在计算时间长、效率低、计算量大、灵活性低的问题。机器视觉检测方法容易受到光照条件的影响,而且步骤复杂,每种算法只能检测芯片上的某一特定的缺陷^[4],需要检测多种缺陷时只能利用多种不同算法分别检测,精度与速度无法同时满足。

近年来,涉及深度学习方法的图像处理表现出了优异的性能,并广泛应用于工业^[5-7]、农业^[8-9]等领域。与传统的机器视觉方法相比,深度学习具有运行速度快、精度高、泛化能力强、灵活性好等优势。为提高工业缺陷的检测精度,Li等^[10]提出一种基于改进的

YOLO-V5和Optimized-Inception-ResnetV2的两阶段工业检测框架,该框架通过使用YOLO-V5实现对缺陷的定位,而Optimized-Inception-ResnetV2提取缺陷的特征,实现准确的分类,但2个模型实施起来是比较繁琐的。Xu等^[11]在VGG-16中使用特征级联,以提高检测性能。Huang等^[12]使用YOLO-V4模型对芯片缺陷进行检测,通过扩展浅层特征的特征融合,利用K-means++聚类方法对先验框进行优化,提高了小目标检测精度。Shu等^[13]利用空间金字塔池化(SPP-net)的优势,提出一种并行空间金字塔池化网络(PSPP-net),解决了LED芯片表面质量安全检查中的离线特征训练提取和在线缺陷识别问题。上述研究充分验证了深度学习在检测外观缺陷方面的优异性能,但深度学习方法仍然存在小目标检测精度低的问题,因此需要一种小目标检测精度高、速度快的芯片外观缺陷检测方法。本文提出了一种RT-YOLO-V5的芯片缺陷检测模型,并针对小目标检测存在的不足进行改进。相对于其他检测模型,该模型具有非接触性、灵活性、精度高、速度快等优势,可以降低算法复杂度,提高芯片质量检测的效率,降低人力成本。

1 网络结构

1.1 YOLO-V5模型

YOLO(you only look once)系列的网络检测模型可以直接检测到边界框的位置及其类别信息,简化计算的过程。该系列包括YOLO^[14]、YOLO-V3^[15]、YOLO-V4^[15]以及YOLO-V5^[15]等,本文使用YOLO-V5网络模型实现对芯片外观缺陷的检测。该检测模型具有速度快、精度高等优点,适合部署到嵌入式设备上,以实现实时检测^[16]。YOLO-V5模型包括BackBone网络、Neck网络以及Head网络,如图1所示。

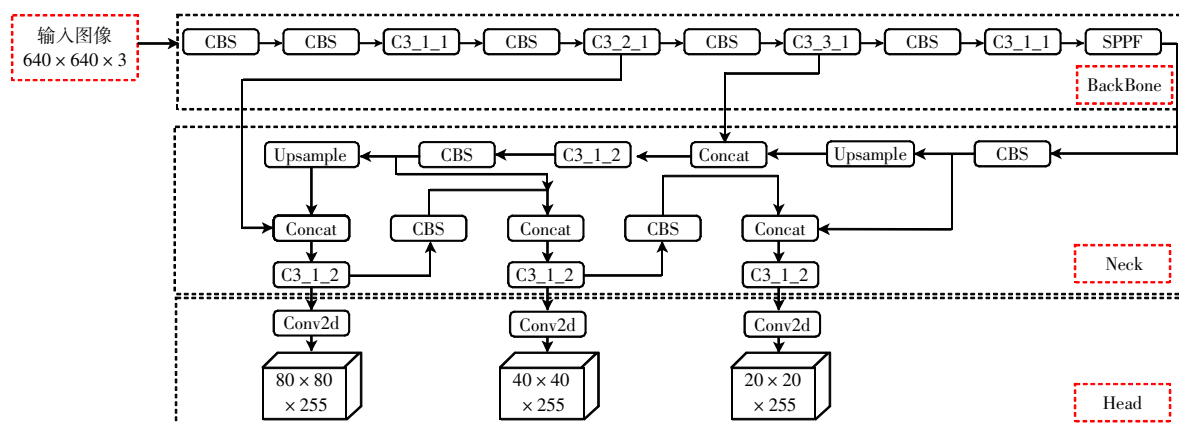


图1 原始的YOLO-V5架构

Fig.1 Original YOLO-V5 network framework

由图 1 可知,BackBone 网络主要由 CBS (CONV-BN-SiLU)模块、C3 模块与 SPPF(spatial pyramid pooling-fast)模块组成,主要功能为提取输入图像中的特征信息。Neck 网络将高级特征与低级特征融合,以丰富模型的语义信息。Head 网络用于生成最终的检测框^[7],对不同尺度大小的目标进行检测。与其他YOLO 系列的检测模型相比,YOLO-V5 对小目标物体的检测效果

更佳,且计算量小。

针对芯片外观的缺陷形状不规则、大小不统一、位置不确定、而且存在很多尺寸较小的缺陷,原始的网络模型存在小目标检测精度较低,收敛速度较慢的问题,已经不能满足芯片外观缺陷检测的要求,因此,本文对原始 YOLO-V5 进行了改进,提出了一种基于RT-YOLO-V5 模型的芯片外观缺陷检测方法,如图 2 所示。

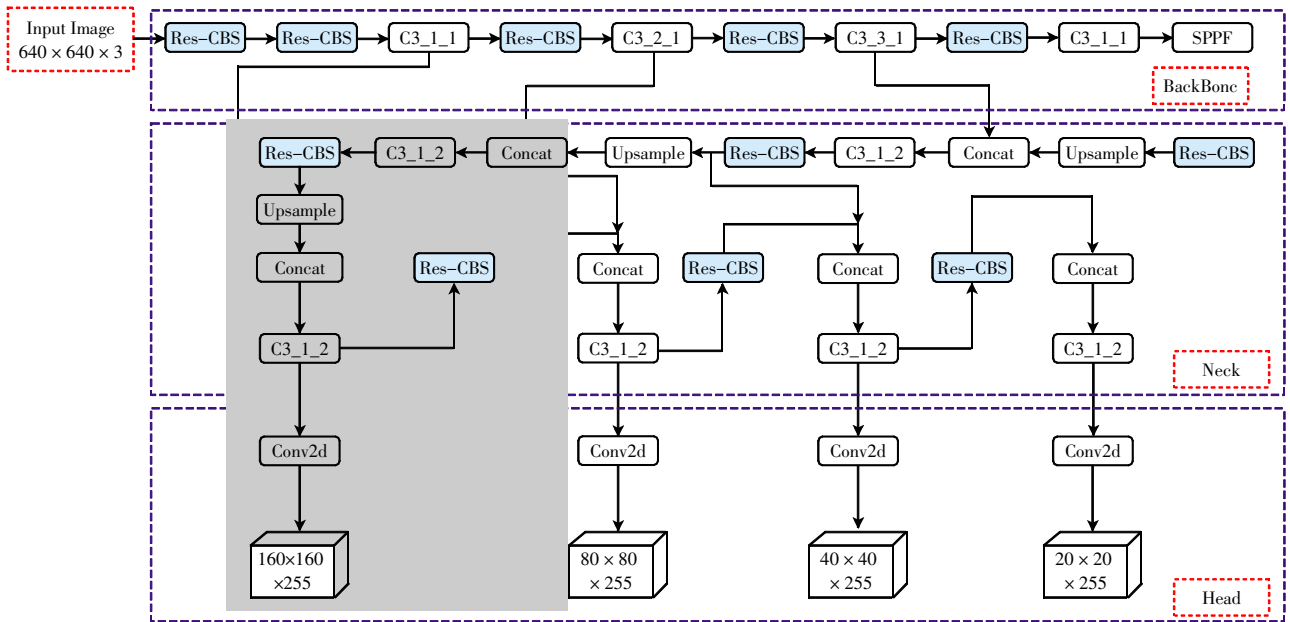


图 2 RT-YOLO-V5 架构

Fig.2 RT-YOLO-V5 network framework

为了优化推理速度,增加特征融合,在 CBS 模块中引入残差思想,并将改进的 CBS 模块命名为 Res-CBS,如图 2 中蓝色部分所示;为提高网络模型对芯片中微小尺度的目标的检测能力,增加了一个微小尺度检测层(Tiny-scale detection layer),如图 2 中灰色阴影部分所示。通过上述改进,特征融合层和多尺度检测层的特征尺度得到了进一步的优化,使检测模型能够更好地适应微小目标的缺陷检测,提高了检测性能^[3]。

1.2 Res-CBS 模块

CBS 模块不仅在 Backbone 网络和 Neck 网络中单独作用,在其他的模块如 SPPF、C3 中也被广泛使用,如图 3 所示。




图 3 原始 CBS 模块

Fig.3 Original CBS module

由图 3 可知,CBS 模块由 Conv、Batch Normalization^[18]及 SiLU 激活函数组成,分别对输入的特征图进行下

采样、批归一化(batch normalization, BN)以及加入非线性因素。其中,批归一化层和激活函数层都有助于提高训练过程中模型的收敛速度^[19]。

Conv3 × 3 为普通的二维卷积,卷积核大小为 3 × 3,功能为对输入特征图进行下采样提取特征。BN 操作是将每一层的输出都规范为均值为 0 且方差为 1 的正态分布,保证在训练过程中,每一层神经网络的输入都保持相同分布。当输入的变化较小时,损失函数的变化会相对变大,梯度随之变大,但又将梯度控制在一个合理的范围内。因此,BN 层在避免了梯度消失和梯度爆炸的同时,又加速了网络模型的收敛速度。将 BN 层放在卷积层与激活函数层之间,相当于在激活函数的输入与卷积层的输出之间加入一个计算层,既可以产生更稳定的分布,也可以防止梯度退化为 0,出现梯度消失现象。YOLO-V5 网络模型使用非线性激活函数可以增加网络表达能力,如下式和图 4 所示。

$$\text{Sigmoid}(x) = \frac{e^x}{e^x + 1} \tag{1}$$

$$\text{SiLU}(x) = x \cdot \text{Sigmoid}(x) \tag{2}$$




图4 SiLU 激活函数

Fig.4 Activation function of SiLU

式中:激活函数 SiLU 是一个平滑函数,处处可导,无上界,有下界,可以避免过拟合,产生更强的正则化效果,更容易训练。

传统的卷积层在信息传递时,会存在信息丢失、信息损耗等问题。当网络越深时,训练效果越差,梯度消失的现象也越来越明显,浅层的参数无法更新。同样的,随着网络深度增加,训练精度下降,网络产生退化现象。但这不是由过拟合产生的,而是由冗余的网络层学习了不是恒等映射的参数造成的。为解决上述问题,本文引入了残差^[20]的思想,即在输出与输入之间引入短连接,可以解决网络层数加深而出现梯度消失的问题。本文在原始 CBS 模块的基础上添加一个短连接,将输入信息直接恒等映射到输出中,如图 5 所示。




图5 Res-CBS 模块

Fig.5 Res-CBS module

通过对输入输出进行一个元素级(element-wise)的叠加,信息损失现象得到了缓解。短连接可以保持特征图尺寸不发生变化且维持上一层的通道数,在增加网络深度的同时令网络能够学习更为复杂的特征信息,提取更加丰富的高级语义特征。在 Res-CBS 模块的短连接上额外添加一个卷积核大小为 1×1 的卷积,可以调节通道数,并不改变特征图信息。Res-CBS 模块将输入信息直接绕道传输到输出中,保存了信息的完整性,同时在保证网络性能不受影响的情况下,提高了训练效果。

1.3 微检测层(Tiny-scale detection layer)

在网络模型的特征提取过程中,浅层特征图具有更多的细节特征,而深层特征图具有更多的语义信息,但细节感知能力较弱。在 Neck 网络中,每一次下采样都是特征提取的过程。通过对输入图像进行特征提取,从而获得更高层次的特征信息,但也会丢失一

部分浅层细节信息。Neck 网络中的上采样操作,将浅层细节特征与深层语义特征进行融合,生成新的特征图。融合后的特征图可以获得更强的深层语义特征,同时也保留了浅层细节特征^[21]。通过多尺度融合,网络对小目标的检测能力得到了有效地提升。

原始 YOLO-V5 网络分别对输入图像进行了 32 倍、16 倍和 8 倍下采样。假设输入图像大小为 640×640 ,模型将生成 3 个尺度大小分别为 20×20 、 40×40 、 80×80 的特征图。这 3 个特征图分别对应 3 个检测头,分别被用于大目标、中目标、小目标的检测。特征图的尺度越小,感受野将越大,包含的细节信息越少。但芯片本身尺寸较小,芯片表面更是存在很多微小尺寸的缺陷,这些缺陷分布在芯片表面,不容易被识别,但很容易影响芯片的性能及美观性。经过多次进行下采样操作后,特征图会丢失较多微小缺陷的特征信息,进一步导致微小目标检测精度下降。

原始模型中最小的下采样倍数为 8 倍,可以检测尺度大小为 8×8 的小目标。在特征提取过程中,当目标尺度小于 8×8 时,该目标的特征信息将会被过滤,从而导致目标被漏检,模型检测精度降低。因此,本文增加了一个如图 2 所示命名为 Tiny-scale detection layer 的检测层,该检测层对图像进行 4 倍下采样,生成一个尺度为 160×160 的检测头,用于检测尺度大小为 4×4 的微小目标。

模型识别缺陷的精确度和可靠性直接取决于所提取的特征和提取特征的方法^[22]。特征信息越详细,模型的精确度越高。新增加的检测层在大小为 80×80 的特征图基础上继续进行上采样,并融合来自 Backbone 网络的详细信息。融合后的特征图尺度大小为 160×160 ,包含更多的细节信息和更强的语义信息,有利于小目标的检测。改进后的检测层提升了模型对微小缺陷的敏感性,提高了模型的检测精度。

2 数据集

2.1 图像采集系统的搭建

本文搭建了一套芯片外观缺陷图像采集系统,如图 6 所示。

采用数码显微镜对图像进行采集,同时,使用 LED 光源和前向照明的方式对待测物表面进行照亮。然后,将显微镜看到的实物图像通过数模转换,成像在计算机上。数码显微镜具有微显摄像功能,可以将观察到的图像以不同的形式及不同的像素大小保存。数码显微镜操作方便、直观,适用于芯片外观的检测。




图 6 图像采集系统示意图

Fig.6 Schematic diagram of image acquisition system

2.2 数据处理

现有样本数量并不充足,无法满足模型的训练需求。因此,需要对现有图像进行扩充以增加样本数量。本文采用图像旋转、图像均衡化的方法实现图像的扩增。以图像中心点为原点,分别对图像进行 90°旋转和 180°旋转,增强模型的方向鲁棒性。图像均衡化操作可以增加图像对比度,增强局部信息,提高网络检测性能。基于现有图像建立芯片外观缺陷检测数据集,并将数据集按比例划分为训练集、测试集以及验证集。图 7 为缺陷类型样本示意图。




图 7 缺陷类型样本

Fig.7 Samples of defect types

图 7(f)为尺寸较小、不易识别的各种类型的微小缺陷。使用 Labelimg 对制作好的数据集进行标注,共包括引脚缺失、划痕、污迹、缺损、微小缺陷 5 种缺陷类型,但将其划分为 2 种标签类型,标注内容共分为 2 种:芯片引脚定位以及芯片表面缺陷,而芯片表面缺陷包括划痕、污迹、缺损、微小缺陷等。

3 实验环境及实验结果分析

3.1 环境配置及评价指标

本文的实验平台采用的 GPU 为 NVIDIA GeForce RTX 3060,Pytorch 版本为 1.10.0,Python 版本为3.6.12。实验训练参数如表 1 所示。

表 1 模型参数设置

Tab.1 Setting of model training parameter

参数	参数值	参数	参数值
Batch_size	16	Epoch	300
Img_size	640	Learning Rate	0.010
Weight_decay	5×10 ⁻⁴	Momentum	0.937

本文采用精确度 (precision, P) 和平均精度均值 (mean average precision, mAP) 对模型性能进行评估。其中,平均查准率 (average precision, AP) 是单个类别在所有识别为外观缺陷的情况下,正确识别缺陷所占的比例;mAP 为所有类别 AP 的平均值,常用于衡量网络模型性能的好坏。计算公式如下:

$$P = \frac{TP}{TP + FP} \tag{3}$$

$$AP = \frac{\sum P}{n} \tag{4}$$

$$mAP = \frac{1}{2} \times \sum AP \tag{5}$$

式中:TP 为正确识别芯片外观缺陷的数量;FP 为错误识别芯片外观的数量; n 为某单一标签类别的样本数量。

3.2 对比实验

为了进一步验证 RT-YOLO-V5 的优越性,本文选取 4 种不同的神经网络与 RT-YOLO-V5 进行对比实验,对比实验结果如表 2 所示。

表 2 对比实验结果


Tab.2 Results of comparative experiment

检测方法	mAP/%	权重文件大小/MB
SSD	80.8	91.6
Faster R-CNN	83.6	108
YOLO-V4-Tiny	84.8	22.4
YOLO-V5	89.8	25.7
RT-YOLO-V5	95.5	42.7


由表2可知,SSD^[23]算法精确度最低,小目标的检测能力较弱。Faster R-CNN^[24]与YOLO-V4-Tiny^[25]的mAP不相上下,但仍小于YOLO-V5网络。YOLO-V4-Tiny为轻量级网络,模型权重文件较小,但是该网络的小目标检测精度较低,无法满足实际检测环境的需求。以上实验表明,原始YOLO-V5网络模型的性能明显优于其他网络模型。其mAP为89.8%,且权重文件的大小远远小于其他网络模型。在原始网络的基础上,改进后的RT-YOLO-V5的mAP达到了95.5%。虽然改进后的网络模型权重增大,但仍小于其他网络,说明改进后的网络模型仍然可以满足实际检测环境中对网络模型权重文件大小的要求。

3.3 消融实验


为了更直接地观察不同改进对该检测方法性能的影响,本文进行了消融实验。各项指标如表3所示。




(a) 精确度对比



(b) Recall对比



(c) mAP平均精度对比



(d) Box-loss对比

图8 3种网络模型的结果对比

Fig.8 Comparison results of three network models

度与Recall都在一定程度上得到了提升。图8(c)表明,改进后的网络模型mAP要明显高于原始YOLO-V5,表明RT-YOLO-V5模型具有较好的精度和鲁棒性。Box_loss代表先验框损失,可以根据损失值的大小,判断预测框是否准确地定位了目标缺陷^[26]。损失值越小,模型的预测效果越好。由图8(d)可知,RT-YOLO-V5损失最小,证明模型的稳定性较好。在经过150个周期后开始收敛,损失值趋于稳定,模型达到最优状态。在0~50个周期时损失存在较大波动,模型可能存在过拟合现象。而随着迭代次数的增加,过拟合带来的影响减弱。

表3 对提出的模型进行消融实验

Tab.3 Ablation study of proposed model

YOLO-V5	Res-CBS	Tiny-scale detection layer	P	mAP/%
√			0.926	89.8
√	√		0.938	94.2
√	√	√	0.947	95.5

由表3可得,原始YOLO-V5网络的mAP为89.8%,加入Res-CBS模块后的mAP为94.2%,说明短连接增强了特征信息融合,减少了信息损失。在增加微检测层后,mAP达到95.5%,证明该检测层的增加提高了小目标的检测精度,也提升了训练效果。结果表明,RT-YOLO-V5不仅改善了检测时出现的重叠现象,还提升了对微小缺陷的检测能力。3种网络模型对比结果如图8所示。

图8(a)和图8(b)反映了改进后网络模型的精确

为了使结果更加直观,本文将其可视化,如图9所示。图9中,绿色为引脚定位,红色为芯片表面缺陷。由图9(a)可知,原始的YOLO-V5模型只能检测尺度较大、较明显的缺陷,存在漏检以及误检现象,且对小目标的敏感性较低。由图9(b)可知,通过改进Res-CBS模块,特征信息得到了进一步的融合,信息完整性也得到了保存,模型的检测效果明显提升。但在检测结果中,仍存在少许漏检现象及缺陷重复标记现象。而RT-YOLO-V5模型对小目标的检测更加敏感,由图9(c)可知,小目标检测效果得到明显提升,且重叠现象大幅下降。




图 9 结果可视化

Fig.9 Visualization of results

4 结束语

本文提出了一种基于 RT-YOLO-V5 网络模型的缺陷检测算法,并将其应用于芯片外观缺陷的识别与定位。该算法克服了由于芯片外观缺陷尺寸不一、类型多样等带来的检测困难的问题。本文首先通过图像采集系统进行图像采集,建立芯片外观缺陷检测数据集;同时,本文通过数据增强方法扩充数据集,防止网络过拟合;其次,本文引入残差思想,对 CBS 模块进行改进,并增加一个微小尺度检测层,用于检测尺度为 4×4 的微小目标。通过对原始网络进行改进,本文模型融合了浅层细节信息与深层语义信息,保存了信息的完整性。同时,该检测模型避免了重要的特征信息的丢失,提高了微小尺度目标的检测精度。改进后,模型的 mAP 达到了 95.5%,模型大小仅为 42.7 MB,远远小于其他模型。实验证明,改进后的模型快速、准确地识别芯片外观缺陷,比传统的工业缺陷检测方法更具有优势,更符合工业生产的要求。本文对芯片引脚的定位已达到较高精度,但是对表面缺陷检测的精度还有待提

升。为解决这一缺陷,未来将收集更多的数据集以提高网络模型的精度。

参考文献:

- [1] LIN H, LI B, WANG X G, et al. Automated defect inspection of LED chip using deep convolutional neural network [J]. Journal of Intelligent Manufacturing, 2019, 30(6): 2525-2534.
- [2] CHIOU Y C, LIN C S, CHIOU B C. The feature extraction and analysis of flaw detection and classification in BGA gold-plating areas [J]. Expert Systems with Applications, 2008, 35(4): 1771-1779.
- [3] JIN W X, LIN W Y, YANG X Q, et al. Reference-free path-walking method for ball grid array inspection in surface mounting machines [J]. IEEE Transactions on Industrial Electronics, 2017, 64(8): 6310-6318.
- [4] LI Y T, HUANG H S, XIE Q S, et al. Research on a surface defect detection algorithm based on MobileNet-SSD [J]. Applied Sciences, 2018, 8(9): 1678.
- [5] WEI R F, BI Y B. Research on recognition technology of aluminum profile surface defects based on deep learning [J]. Materials, 2019, 12(10): 1681.
- [6] GAO Y P, GAO L, LI X Y, et al. A multilevel information fu-

- sion-based deep learning method for vision-based defect recognition[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(7): 3980-3991.
- [7] REN Q R, GENG J H, LI J Y. Slighter faster R-CNN for real-time detection of steel strip surface defects[C]//2018 Chinese Automation Congress (CAC). Xi'an: IEEE, 2018: 2173-2178.
- [8] ZHANG X, GAO Q M, PAN D, et al. Research on spatial positioning system of fruits to be picked in field based on binocular vision and SSD model[J]. *Journal of Physics: Conference Series*, 2021, 1748(4): 042011.
- [9] WU D H, LYU S C, JIANG M, et al. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments[J]. *Computers and Electronics in Agriculture*, 2020, 178(4): 105742.
- [10] LI Z, TIAN X C, LIU X, et al. A two-stage industrial defect detection framework based on improved-YOLOV5 and optimized-inception-ResnetV2 models[J]. *Applied Sciences*, 2022, 12(2): 834.
- [11] XU X J, LEI Y, YANG F. Railway subgrade defect automatic recognition method based on improved faster R-CNN[J]. *Scientific Programming*, 2018(6): 1-12.
- [12] HUANG H X, TANG X D, WEN F, et al. Small object detection method with shallow feature fusion network for chip surface defect detection[J]. *Scientific Reports*, 2022, 12: 3914.
- [13] SHU Y F, LI B, LIN H. Quality safety monitoring of LED chips using deep learning-based vision inspection methods[J]. *Measurements*, 2021, 168: 108123.
- [14] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [15] 高星. 基于深度学习的口罩佩戴目标检测研究[D]. 太原: 中北大学, 2023.
- GAO X. Research on mask wearing target detection based on deep learning[D]. Taiyuan: North University of China, 2023 (in Chinese).
- [16] LI S S, LI Y J, LI Y, et al. YOLO-FIRI: Improved YOLOV5 for infrared image object detection[J]. *IEEE Access*, 2021, 9: 141861-141875.
- [17] ZHAO J Q, ZHANG X H, YAN J W, et al. A wheat spike detection method in UAV images based on improved YOLOV5 [J]. *Remote Sensing*, 2021, 13(16): 3095.
- [18] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]// Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille, France: ACM, 2015: 448-456.
- [19] TABERNIK D, SELA S, ŠKVARČ J, et al. Segmentation-based deep-learning approach for surface-defect detection[J]. *Journal of Intelligent Manufacturing*, 2020, 31(3): 759-776.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [21] MA Z X, LI Y B, HUANG M H, et al. A lightweight detector based on attention mechanism for aluminum strip surface defect detection[J]. *Computers in Industry*, 2022, 136: 103585.
- [22] WONG N S, ROSDI B A, AKBAR M F, et al. FPGA implementation of convolutional neural network for defect identification on swiven cap[C]//Proceedings of the 6th International Conference on Electrical, Control and Computer Engineering. Singapore: Springer, 2022: 977-988.
- [23] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]//European Conference on Computer Vision. Cham: Springer, 2016: 21-37.
- [24] REN S Q, HE K M, 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*, 2017, 39(6): 1137-1149.
- [25] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Scaled-YOLOV4: Scaling cross stage partial network[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 13024-13033.
- [26] CHEN Z Y, WU R H, LIN Y Y, et al. Plant disease recognition model based on improved YOLOV5[J]. *Agronomy*, 2022, 12(2): 365.

本文引文格式:

郭翠娟,王妍,刘净月,等. 基于 RT-YOLO-V5 的芯片外观缺陷检测[J]. 天津工业大学学报, 2024, 43(3): 50-57.

GUO C J, WANG Y, LIU J Y, et al. Chip appearance defect detection based on RT-YOLO-V5[J]. *Journal of Tiangong University*, 2024, 43(3): 50-57(in Chinese).