

# 基于融合注意力的多尺度芯片缺陷检测算法

韩明桥 蒋三新

(上海电力大学电子与信息工程学院 上海 201306)

**摘要:**芯片的表面缺陷检测在半导体制造中具有重要意义,针对目前芯片表面缺陷面积小,缺陷外形多变,缺陷尺寸跨度大的情况,提出一种基于YOLOv5改进的芯片表面缺陷检测算法,首先基于ConvNext网络改进特征提取模块,提升网络稳定性和特征表达能力,同时提出增强卷积注意力模块(enhanced convolutional block attention module,E\_CBAM),将更详细的位置信息嵌入到卷积注意力(convolutional block attention module,CBAM)之中,提升整个网络对于小面积及边缘缺陷的检测能力,而针对芯片缺陷多变尺寸跨度大的问题,研究引入了可变形卷积和双向特征金字塔网络(bi-directional feature pyramid network,BiFPN),一方面可变形卷积对于外形不规则的卷积有更好的提取能力,另一方面Neck部分的BiFPN在简化结构的同时保证了多尺度融合的准确性。经过实验表明,改进后的网络在芯片表面缺陷数据集(chip defect dataset,CDD)上,平均精度均值(mAP)mAP@0.5指标达到95.3%,相较于原始的YOLOv5s网络提升了3.1%,在没有过多增加网络参数的情况下,对芯片表面缺陷的精度更高,鲁棒性更强。

**关键词:**芯片表面缺陷检测;ConvNext网络;可变形卷积;小目标检测;特征融合

中图分类号: TP391.1 文献标识码:A 国家标准学科分类代码: 520.6040

## Multi-scale chip defect detection algorithm based on fused attention

Han Mingqiao Jiang Sanxin

(College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 201306, China)

**Abstract:** Chip surface defect detection is of great significance in semiconductor manufacturing, for the current chip surface defect area is small, defect shape is variable, defect size spanning a large situation, put forward an improved chip surface defect detection algorithm based on YOLOv5, first of all, based on the CnovNext network to improve the feature extraction module, improve the stability of the network and the ability of feature expression, and at the same time put forward the ehanced convolutional block attention module (E\_CBAM) module is proposed to embed more detailed location information into convolutional block attention module (CBAM) to improve the detection capability of the whole network for small area and edge defects. For the problem of large size span of chip defects, the study introduces deformable convolution and BiFPN module, on the one hand, the deformable convolution has better extraction ability for irregular shape convolution, on the other hand, the BiFPN in the Neck part simplifies the structure and ensures the accuracy of multi-scale fusion. After the experiments, it is shown that the improved network achieves a mAP@0.5 index of 95.3% on chip surface defect dataset (CDD), which is 3.1% higher compared to the original YOLOv5s network, which is more accurate and robust to the chip surface defects without too much increase in the network parameters.

**Keywords:** chip surface defect detection; ConvNext network; deformable convolution; small-object detection; feature fusion

## 0 引言

由于我国近年来在智能手机、物联网、5G通信、人工

智能、远程办公等领域的需求增长,半导体产业得到快速发展,同时带动了半导体设备市场的增长。在芯片生产制造过程中,各工艺流程环环相扣。技术复杂,材料、环

境、工艺参数等因素的微变常导致芯片产生缺陷，影响产品良率。芯片质量检测作为芯片生产线中的关键环节，可以积极地反馈产品质量信息，以便人们及时掌控各生产环节的良品状况<sup>[1]</sup>，早期的人工目视检测方法精度不高，效率较差，现如今基于机器视觉的检测手段已成为主流。

随着深度学习技术的发展，近年来自动检测技术在芯片生产线上得到了广泛应用。机器视觉技术，尤其是以卷积神经网络(convolutional neural networks, CNN)为代表的深度学习模型，成为缺陷检测的新方向。传统的目标检测算法基于滑窗遍历选择区域，然后进行特征提取和分类，但存在计算复杂度高、手动特征提取复杂和检测精度提升有限的问题。深度学习卷积神经网络通过学习数据特征，能够提取更抽象、更深层次的特征，具有更好的泛化能力。

在目标检测算法中，一系列的改进算法相继提出，如 R-CNN、Fast R-CNN<sup>[2]</sup>、Faster R-CNN<sup>[3]</sup>、YOLO 等。这些算法在提高检测精度和速度方面取得了显著成果，并逐渐成为芯片质量检测中的重要工具。

此外，研究人员还针对特定领域的芯片缺陷检测问题提出了相应的算法。郑亚睿等<sup>[4]</sup>结合双动态头提出了 Sparse R-CNN 的缺陷检测算法，减少了缺陷检测中的冗余检测。付强等<sup>[5]</sup>引入深度可分离卷积和注意力机制，实现了对半导体晶圆的表面缺陷的快速检测。李阳等<sup>[6]</sup>改进生成对抗网络，提出了无监督晶圆表面缺陷检测模型，

实现了晶圆表面缺陷的无监督检测。周天宇等<sup>[7]</sup>提出了轻量级卷积神经网络算法 YOLO Efficientnet，应用于载波芯片(chip on carrier, COC)缺陷检测。

总结而言，深度学习技术在芯片质量检测中的应用逐渐取代了传统的人工目视检测方法。随着技术的不断进步和算法的改进，未来芯片质量检测技术将继续发展，以满足对精度、效率和可靠性的不断提高的需求。因此本文针对芯片表面缺陷的特点，基于 YOLO 系列中实验数据集上表现最好的 YOLOv5，提出一种芯片表面缺陷检测方法，结合 ConvNext 网络、E\_CBAM 等机制改进了网络，实现了芯片缺陷的分类识别和定位功能。

## 1 基于 YOLOv5 的芯片表面缺陷模型

### 1.1 网络结构

网络总体结构如图 1 所示。对于芯片表面缺陷的检测任务，既需要考虑网络的精度，也需要考虑网络的运算速度，对比了 Faster R-CNN、SSD、YOLO 系列等网络后，最终选择了 YOLOv5 目标检测算法<sup>[8]</sup>。其是 YOLO 各版本中(包括 v7<sup>[9]</sup>、v8<sup>[10]</sup> 版本)，在实验数据集上检测精度最好的一个版本，其中依据模型的深度和宽度，v5 又分为 v5s、v5m、v5l 和 v5x 4 个版本，YOLOv5s 的速度最快，模型文件小。因此本文选用了 YOLOv5s 作为晶圆缺陷的基础模型，但是对于小目标、少样本且背景复杂的晶圆缺陷图像，YOLOv5 的检测识别性能并不理想，最终的模型是在其基础上改进产生。

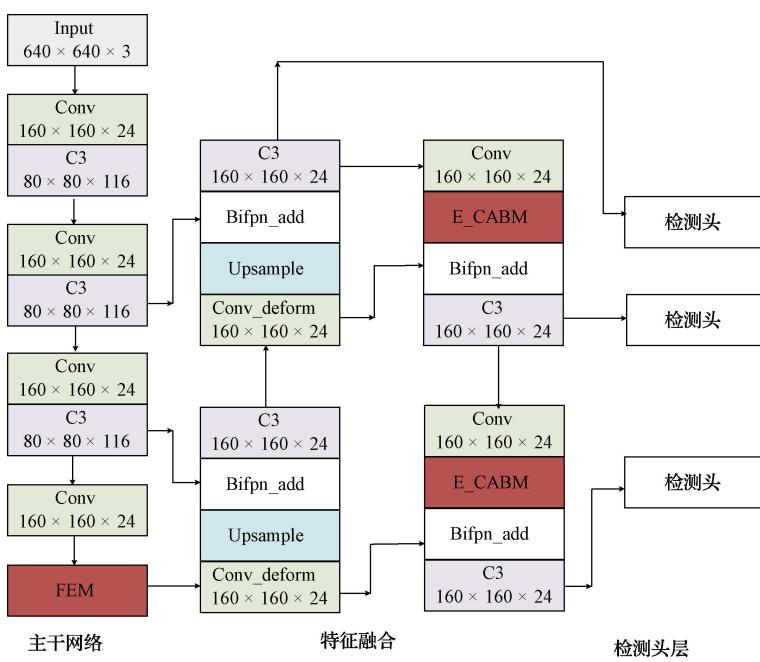


图 1 网络总体结构

### 1.2 改进特征提取模块

在 YOLOv5 中特征提取部分采用了快速空间金字塔

池化模块(spatial pyramid pooling-fast, SPPF)，输入进入该模块后被分为 4 部分，分别进行 4 个尺度( $1 \times 1$ 、 $5 \times 5$ 、

$9 \times 9$  和  $13 \times 13$ )的最大池化操作后,最后通过 ConCat 操作进行拼接,从而实现多尺度信息融合。但是很多类型的芯片表面缺陷尺寸较小,SPPF 的池化操作会使网络丢失缺陷的细节信息,导致部分缺陷类型的检测精度较差,降低小目标的检测性能。为了达到既能避免细节信息丢失,又能增大感受野的目的。本文将 ConvNext 网络与感受野模块(receptive field block,RFB)<sup>[11]</sup>串联整合,作为缺陷检测网络的特征提取模块。

ConvNext<sup>[12]</sup> 网络由纯卷积构成,将 Transformer 网络新颖的思想引入到 CNN 中,一方面保留了 CNN 滑窗机制其平移不变性在缺陷检测任务中的优势,另一方面提升了传统 CNN 的网络性能。提升小目标缺陷的检测能力。结构上使用了倒置设计<sup>[13]</sup>,隐藏层信息维度是输入维度的 4 倍,倒置的瓶颈结构能够在降低模型参数的同时,提升模型的准确率,避免了小目标芯片缺陷信息的丢失。最后 ConvNext 在激活函数的选择上,将 ReLU 激活函数换为了 GeLU,同时将 Batch Normalization 换为了 Normalization Layer,增加了网络的稳定性,训练时 loss 的振荡减少。准确率提升的同时,降低了浮点运算数。基于组卷积和交叉连接的结构,能够充分利用不同组之间的信息交互,将 ConvNext 作为 RFB 的前置部分可以进一步提升网络的非线性和特征表达能力。

RFB 网络(图 2),多用于 Single Shot MultiBox Detector 网络中模拟人类视觉感受野来提高特征提取能力。结构上,在继承卷积尺度递减机制的同时 RFB 网络也借鉴了 Inception 算法的思想,采用了多分支卷积层的结构,有效扩大了网络的感受野,能够更好地捕捉到不同尺度的特征信息。多尺度的感受野,使网络对于不同尺度和大小的目标物体具有更好的适应能力。这提高了 YOLO 网络不同尺度目标物体上的泛化能力。相比于 SPPF 模块<sup>[13]</sup>采用了多次池化的方法具有更强的感知能力,能够更好地检测和定位小尺寸的目标物体。而体积上 RFB 模块采用了

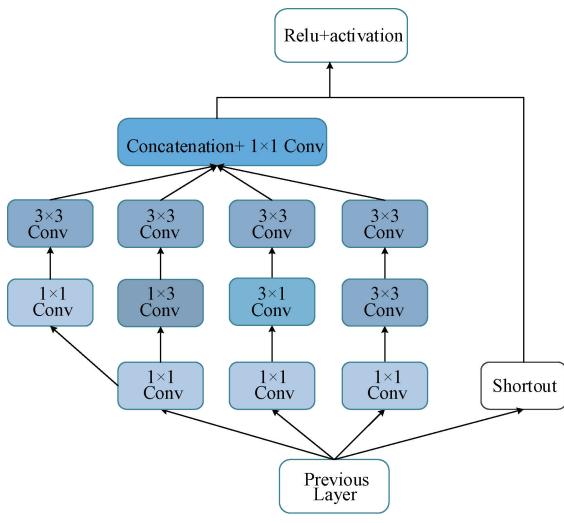


图 2 RFB 网络

轻量级的网络结构,通过减少参数量和计算量的方式来提高网络的推理速度。相比于 SPPF 模块,RFB 模块在保持相近的检测精度的同时,能够提升检测的速度和效率。配合前置的 ConvNext 网络,RFB 模块能够更好地捕捉目标物体的上下文信息,从而提高了检测的准确性和稳定性。

### 1.3 E\_CBAM 模块

CBAM 是一种双重注意力机制<sup>[14]</sup>,得益于 CBAM 的结构(图 3)同时涵盖了通道和空间信息,因此可以更好地适应不同的图像场景,并且对于目标的细节信息也有较好的处理能力。此外 CBAM 可以在不增加过多计算复杂度的情况下提高网络的精度,可适用于对计算速度和精度要求较高的场合。

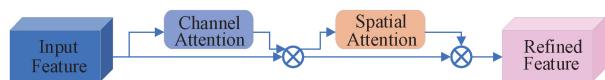


图 3 CBAM 结构

在芯片表面缺陷检测任务中,由于存在大量小目标缺陷,CBAM 也表现出很多局限性。由于 CBAM 的空间注意力通道使用平均池化和最大池化得到的位置信息较为模糊,面对复杂环境时 CBAM 可能会过度关注芯片缺陷周围的背景信息,而对缺陷本身的特征提取不足;此外 CBAM 也可能忽略一些范围很小且分布在边缘的缺陷。因此,本文将 CA(coordinate attention)(图 4)注意力机制<sup>[15]</sup>与其相结合,提出了一种 E\_CBAM 注意力机制(图 5)。将更详细位置信息嵌入其中,其坐标关注将信道关注分解为两个 1 维特征编码过程,分别沿两个空间方向聚合特征。通过这种方式,可以沿一个空间方向捕获长距离相关性,同时可以沿另一空间方向保留较为精确的位置信息。新增注意力机制可以在空间维度上对 CBAM 进行详细的补充,使网络更好地适应不同尺度的目标,而 CBAM 原有的通道注意力可以帮助网络捕捉总体信息,所以 E\_CBAM 更能平衡通道和空间信息,最终提高网络的检测精度和对小目标缺陷以及边缘缺陷的检测能力,取得比 CBAM 更好的效果。此外该种位置信息编码方式的计算量较小,依然可灵活地嵌入网络当中。

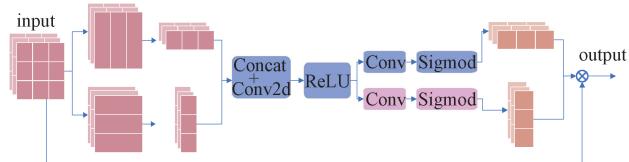


图 4 CA 注意力结构

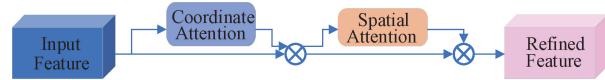


图 5 E\_CBAM 结构

#### 1.4 Neck 的改进

一般来说,随着网络层数的加深,语义信息会更加抽象,芯片表面缺陷的位置信息损失也会增大。因此网络中需要 Neck 部分进行信息融合,来提高 Head 对小目标检测的准确性。在 YOLOv5 网络中,使用了特征金字塔(feature pyramid networks, FPN)与金字塔注意力网络(pyramid attention network, PAN)相结合的方式来作为 Neck 进行特征的融合<sup>[16]</sup>。增加自下而上的信息流分支,对比传统 FPN 的精度有所提升,但 PAN 的参数量大大增加。为了在节省计算量的同时,尽可能的保持网络的精度,避免晶圆缺陷小目标位置信息的丢失,本文采用了双向特征金字塔网络(BiFPN)<sup>[17]</sup>作为网络的 Neck 部分。对比 PAN,删去了仅有一个输入的节点,使得网络结构得到了简化。此外将原始输入与之后的节点进行跳连,引入了残差结构增强表征能力。此外 BiFPN 结构认为,不同尺寸的特征,他们贡献的输出不平等,不该只是划归到同一分辨率后进行对等的融合,所以提出了权值融合的方法,为每个输入增加一个权重,并通过网络的学习来更新权重的大小。

BiFPN 权值融合的公式为:

$$O = \sum_i \frac{w_i}{e + \sum_j w_j} \cdot I_i \quad (1)$$

式中:  $I_i$  表示输入特征;  $w_i$  为权值,用于衡量不同分辨率的特征对特征融合的贡献情况;  $w_j$  为权值,用于衡量不同分辨率的特征对特征融合的贡献情况;  $e$  为数值极小的学习率,用以约束数值的振荡;  $O$  为输出。加权特征融合的值 BiFPN 在第 6 层的融合特征的计算公式为:

$$P_6^{id} = \text{Conv}\left(\frac{w_1 P_6^{in} + w_2 \text{Resize}(P_7^{in})}{w_1 + w_2 + e}\right) \quad (2)$$

$$P_6^{out} = \text{Conv}\left(\frac{w'_1 P_6^{in} + w'_2 P_6^{id} + w'_3 \text{Resize}(P_5^{out})}{w'_1 + w'_2 + w'_3 + e}\right) \quad (3)$$

式中:  $P_6^{id}$  代表自顶向下特征融合路径中产生的中间特征;  $P_6^{out}$  代表自底向上特征路径中产生的输出特征;  $P_6^{in}$  代表对输入进行下采样操作; Resize 代表上采样函数。

得益于 BiFPN 独特的结构,残差模块的加入,以及权值融合的设计,减少了小目标芯片缺陷的丢失。较好的解决了晶圆缺陷尺寸变化较大的问题。

#### 1.5 可变形卷积

现如今大多数网络都是构建在 CNN 基础之上的,其在分类任务、检测任务等方面有重要地位。但 CNN 也有其局限性,固定的卷积核来提取特征,导致高级神经元的接受野是固定的,无法根据下游任务有效编码可变形的信息<sup>[18]</sup>。在晶圆缺陷检测任务中,几何形状不规则的缺陷难以被准确识别出来,而通常使用的增强数据集适应缺陷的形态差异的方法,对非固定的复杂形变依然难以识别。为了解决芯片缺陷的不规则性和多样性,本研究引入了可

变形卷积来替换常规的卷积,以此增加网络对于不规则缺陷的提取能力,可变形卷积的运算过程,如图 6 所示。

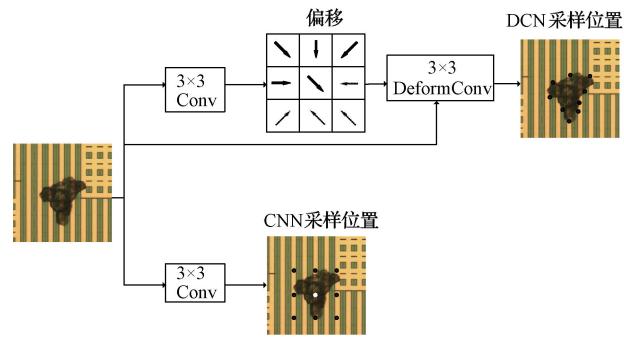


图 6 可变形卷积工作原理

在标准的 CNN 的卷积过程中<sup>[19]</sup>,对于输出特征图每一个每一个位置的  $P_o$  为:

$$y(P_o) = \sum_{P_n \in R} w(P_n) x(P_o + P_n) \quad (4)$$

式中:  $w(P_n)$  代表该采样位置的卷积核权重;  $x(P_o + P_n)$  代表采样位置的输入特征值;  $P_n$  代表感受野区域中的所有采样位置;  $R$  代表感受野域。

而在可变形卷积中,其计算方法为:

$$y(P_o) = \sum_{P_n \in R} w(P_n) x(P_o + P_n + \Delta P_n) \quad (5)$$

式中:  $x(P_o + P_n + \Delta P_n)$  为采样偏移位置的输入特征值;  $\Delta P_n$  为采样点位置的偏移量。

由计算过程可见,可变形卷积(deformable convolution)<sup>[20]</sup>是一种较为独特的卷积结构,其允许卷积核的特征点在临近位置上发生偏移,以更好地提取局部特征。与传统 CNN 卷积相比增加了采样位置,利用从检测任务中学到的偏移量计算的过程中计算每个点位置,然后提取特征进行卷积。对于任务中形状不定的芯片缺陷外形,有着更好的适应性,一定程度上提高了检测精度。

## 2 实验与结果分析

本文对采集的芯片表面缺陷数据进行预处理后制作了 CDD<sup>[21]</sup>,CDD 图像中的各类目标如图 7 所示,共包含 11 类、6 030 张缺陷图像(512×512 pixels),缺陷名称为外来异物(Foreign)、金属残留(Gold)、元件缺损(Incomp)、凹陷凸起(Lump)、药液残留(Res)、元件划伤(Scrach)、漏刻蚀(UBM)和 4 种类型原料不良(Raw I、Raw II、Raw III、Raw IV)。在实验过程中按照 9 : 1 的方式划分训练集以及测试集,同时采用 Adam 优化器,模型的迭代过程,中的损失函数收敛情况,如图 8 所示,由图 8 可知,连续迭代 100 轮后模型基本收敛。

### 2.1 评价指标

本文研究结果采用精确度(precision, P)、召回率(recall, R)和平均精度均值(mean average precision, mAP)等作为评价指标,计算公式如下:

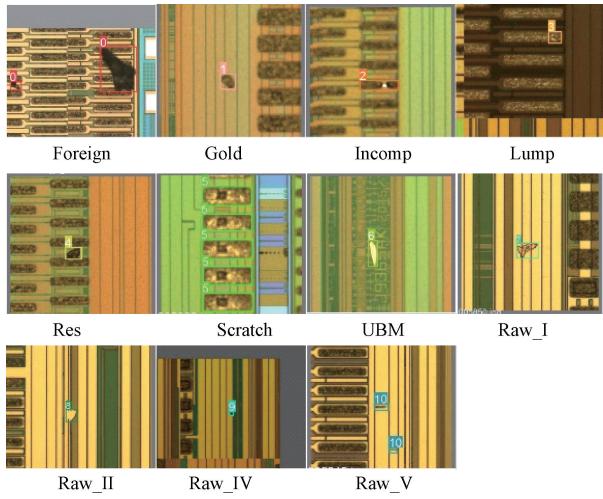


图 7 数据集缺陷类型

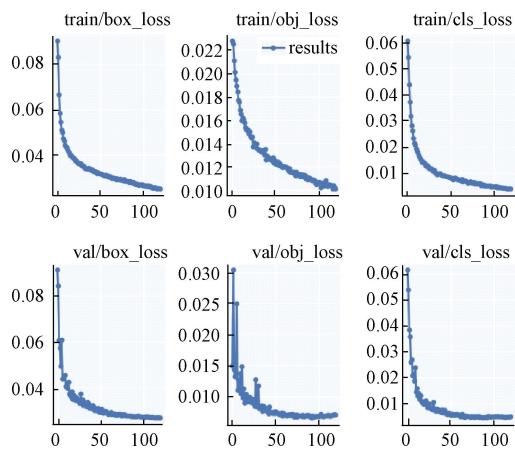


图 8 训练损失变化

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$AP = \int_0^1 P(R) dR \quad (8)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (9)$$

式中: TP (true postives) 为预测正确的正类样本数量; FP (false postives) 为预测错误的正类样本数量; FN (false negatives) 为预测错误的负类样本数量;  $n$  为数据集中的类别数。设定 AP 的 IoU 检测阈值为 0.5, 即评价指标为 AP@0.5 与 mAP@0.5。

## 2.2 实验配置

本文模型的训练和测试均在 Linux 操作系统上完成, 选用 Pytorch1.9 框架, 实验环境配置如表 1 所示。

## 2.3 对比试验

为验证本文算法的优越性, 进行如下对比实验, 实验结果如表 2 所示。

表 1 实验环境配置

配置名称	配置信息
操作系统	Linux
CPU	Intel(R) Xeon(R) Gold 5218R
GPU	Nvidia GeForce RTX 3090
Python 版本	3.7
CUDA 版本	11.4

表 2 对比试验

网络名称	P/%	R/%	mAP/%	速度/fps
Faster R-CNN	61.47	78.03	79.6	15
RetainNet	64.25	71.83	72.1	34
YOLOv4	88.6	84.4	89.1	57
YOLOv5	90.1	87.9	92.2	76
YOLOv7	84.7	78.8	86.1	100
YOLOv8	88.6	84.9	90.7	109
本文	92.9	91.1	95.3	85

从表 2 可以看到, 本文改进的 YOLOv5 算法的精确率为 92.9%、召回率为 91.1%、检测速度为 85 fps。相对于未改进的 YOLOv5 有所提高, 明显高于 Faster R-CNN、RetainNet 和 YOLOv4 网络。改进的 YOLOv5 mAP@0.5 比传统的 YOLOv5 提高了 3.1%, 比 YOLOv4 模型高 6.1%, 比 YOLOv7 模型提高 9.2%, 比 YOLOv8 模型提高了 4.6%, 比 Fater R-CNN 网络高 19.7%; 改进的 YOLOv5 的 FPS 明显快于 Faster R-CNN、RetainNet, 比 YOLOv4 提高了 28 fps, 比未改进的 YOLOv5 提高 9 fps。而 YOLOv7、YOLOv8 虽然检测速度较快, 但精度无法满足检测要求。

检测效果对比如图 9(a)、(b)所示可以看出改进后的网络可以检测到原版 YOLOv5 网络无法检测出的缺陷; 混合芯片缺陷检测效果如图 10 所示, 可以直观看出本研究所提出算法对于混合缺陷的情况也有较好的检测效果。

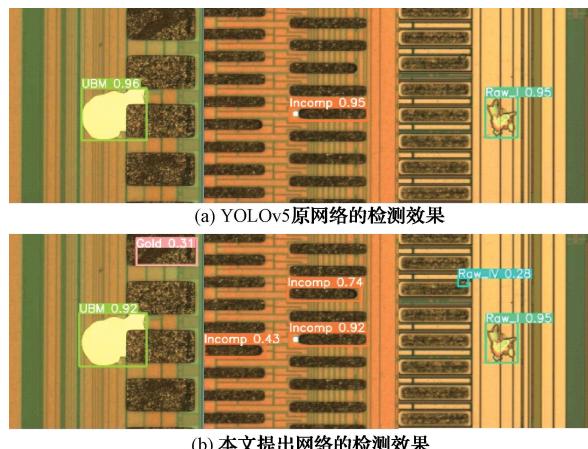


图 9 检测效果对比



图 10 混合芯片缺陷检测效果

从 7 种模型的对比结果来看,研究改进后的网络各项参数提升明显,效果较为理想。

#### 2.4 消融实验

消融实验结果如表 3 所示,A 代表基于 ConvNext 改进的 FEM 模块;B 代表 E\_CBAM 模块;C 代表 BiFPN 模块;D 代表可变形卷积;D1-D10 为不同的缺陷类型。为

了验证改进方法的有效性,本文以 YOLOv5s 算法为基础,每次累加一种改进方法,以验证不同改进方法同时作用对最终算法的影响程度。“√”表示引入该方法,从表 3 可以看出,研究所提出的 4 个改进方法在 CDD 数据集上,相比原始 YOLOv5s 算法,mAP@0.5 值都有不同程度的提升,其中改进的特征提取模块与 E\_CBAM 注意力对网络提升较为明显,平均精度分别提升了 1.2% 和 1.4%,其加强了网络整体的特征表达能力和鲁棒性;而单独引入可变形卷积和 BiFPN 后也对网络的平均精度有所提升,分别为 1.0% 和 0.9%。针对性的提升了网络对于不规则缺陷和跨尺度缺陷的检测能力。在多个方法共存时网络的平均精度对比 YOLOv5s 基础网络提升了 3.1%,证明了研究改进的方法对芯片缺陷检测有较好的准确性。

表 3 消融实验

A	B	C	D	D0/%	D1/%	D2/%	D3/%	D4/%	D5/%	D6/%	D7/%	D8/%	D9/%	D10/%	ALL/%
√				87.2	90.4	94.1	95.7	92.8	98.6	96.1	98.6	92.1	96.4	86.5	93.5
√	√			87.7	92.7	94.2	98.2	96.0	98.7	98.3	97.1	92.8	95.7	86.7	94.4
√	√	√		89.6	91.1	97.3	96.0	93.7	98.9	99.2	97.2	94.4	97.3	86.6	94.7
√	√	√	√	91.2	92.4	97.2	96.6	94.1	99.1	99.3	98.2	95.5	97.8	87.3	95.3

### 3 结 论

芯片的表面缺陷检测在半导体制造中具有重要意义,为实现较高精度的芯片缺陷检测,降低跨尺度、不规则和小面积缺陷的对检测精度影响,现提出一种基于 YOLOv5 改进的芯片检测框架,基于 ConvNext 网络改进特征提取部分,增强网络的特征表达能力,留存更丰富的缺陷细节特征,提出 E\_CBAM 注意力机制,嵌入了更为准确的位置信息,优化对小目标缺陷的提取能力,同时针对不规则缺陷和多尺度问题,引入可变形卷积和 BiFPN 模块,来提升网络的多尺度信息融合融合能力。实验结果表明,相较于典型原始的 YOLOv5s 检测算法,研究所提出的算法的识别精度更高、稳定性、鲁棒性更强。在 CDC(芯片表面缺陷数据集)上,mAP@0.5 指标达到 95.3%,检测速度达到 85 fps,可为芯片表面缺陷质检提供精度较高、稳定性较好的检测方案。

### 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.
- [2] GRISHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition,2014.
- [3] 伊欣同,单亚峰.基于改进 Faster R-CNN 的光伏电池内部缺陷检测[J].电子测量与仪器学报,2021,
- 35(1):40-47.
- [4] 郑亚睿,蒋三新.基于双动态头 Sparse R-CNN 的表面缺陷检测算法[J].仪表技术与传感器,2023(5):97-105.
- [5] 付强,王红成.基于可分离卷积和注意力机制的晶圆缺陷检测[J].计算机系统应用,2023,32(5):20-27.
- [6] 李阳,蒋三新.基于改进生成对抗网络的无监督晶圆缺陷检测[J].电子测量技术,2023,46(6):91-99.
- [7] 周天宇,朱启兵,黄敏,等.基于轻量级卷积神经网络的载波芯片缺陷检测[J].计算机工程与应用,2022(7):213-219.
- [8] 郎松,曹选,张艳微,等.融合改进 YOLOv5 算法的图像全站仪全自动测量方法[J].仪器仪表学报,2022,43(5):120-127.
- [9] 谢康康,朱文忠,谢林森,等.基于改进 YOLOv7 的火焰烟雾检测算法[J].国外电子测量技术,2023,42(7):41-49.
- [10] 魏陈浩,杨睿,刘振丙,等.具有双层路由注意力的 YOLOv8 道路场景目标检测方法[J/OL].图学学报,1-9 [2023-12-11] <http://kns.cnki.net/kcms/detail/10.1034.T.20230925.1003.002.html>.
- [11] LIU S T, HUANG D, WANG Y H. Receptive field block net for accurate and fastobject detection [C]. European Conference on Computer Vision,2018.
- [12] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s [C]. IEEE Conference on Computer Vision

- and Pattern Recognition, 2022.
- [13] 马宏兴,张森,董凯兵,等.基于改进 YOLO v5 的宁夏草原蝗虫识别模型研究[J].农业机械学报,2022,53(11):270-279.
- [14] WOO S, PARKA J, LEE J, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision, 2018:3-19.
- [15] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021: 13708-13717.
- [16] 刘相云,郭呈渊,龚志辉,等.一种改进的 RFB Net 遥感影像目标识别算法[J].测绘科学技术学报,2019,36(2):179-184.
- [17] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020:10778-10787.
- [18] 朱红艳,李泽平,赵勇,等.基于多尺度融合和可变形卷积 PCB 缺陷检测算法[J].计算机工程与设计,2022,43(8):2188-2196.
- [19] 蒋晨,钱永明,姚兴田,等.基于可变形卷积改进 SSD 算法的目标检测方法[J].电子测量技术,2022,45(16):116-122.
- [20] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks[C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 764-773.
- [21] 王新宇,蒋三新.应用于产品表面缺陷检测的神经网络 IBS-Net[J].仪表技术与传感器, 2022(11): 101-107.

#### 作者简介

韩明桥,硕士,主要研究方向为图像处理与识别、缺陷检测技术等。

E-mail: 1136770381@qq.com

蒋三新(通信作者),博士,讲师,主要研究方向为机器视觉、深度增强学习等。

E-mail: samjoe\_2018@shiep.edu.cn