

基于改进 YOLOv5s 的光刻热点检测算法

吴清岳¹, 刘佳敏^{1*}, 张松¹, 江浩¹, 刘世元^{1,2**}¹华中科技大学智能制造装备与技术全国重点实验室, 湖北 武汉 430074;²湖北光谷实验室, 湖北 武汉 430074

摘要 光刻热点检测是实现集成电路可制造性设计,保障集成电路芯片最终良率的关键。鉴于传统基于深度学习的光刻热点检测方法难以满足先进集成电路制造对检测精度的要求,提出了一种基于改进 YOLOv5s 的检测算法,用于光刻版图热点缺陷的精确检测。通过将坐标注意力机制引入骨干网络,提高了 YOLOv5s 模型对版图图形区域的关注度,进而极大地改善了基于 YOLOv5s 的检测算法的光刻热点检测性能。与此同时,采用 Sigmoid 线性单元激活函数进一步完善整个神经网络的非线性表达,利用 Scylla 交并比损失函数更快速地定量评估边界框回归损失,提高了热点检测算法的收敛速度和精度。将 ICCAD(The International Conference on Computer-Aided Design) 2012 竞赛基准、经光学邻近校正优化后的光刻图形作为数据集对所提算法开展性能测试实验,验证了热点检测算法的优异检测精度。实验结果表明,该算法的平均准确率、平均召回率、平均 F1-score 和均值平均精度分别达到 97.7%、98.0%、97.8% 和 98.4%,显著优于其他光刻热点检测算法,展示了良好的应用前景。

关键词 光刻热点检测; 改进 YOLOv5s; 检测精度; 坐标注意力机制; Sigmoid 线性单元激活函数; Scylla 交并比损失函数

中图分类号 TN406

文献标志码 A

DOI: 10.3788/LOP231038

Lithography Hotspot Detection Based on Improved YOLOv5s

Wu Qingyue¹, Liu Jiamin^{1*}, Zhang Song¹, Jiang Hao¹, Liu Shiyuan^{1,2**}¹State Key Laboratory of Intelligent Manufacturing Equipment and Technology, Huazhong University of Science and Technology, Wuhan 430074, Hubei, China;²Hubei Optics Valley Laboratory, Wuhan 430074, Hubei, China

Abstract Lithography hotspot detection plays a critical role in realizing the manufacturability design of integrated circuits (IC) and ensuring the final yield of IC chips. Considering that conventional lithography hotspot detection methods based on deep learning are challenging to meet the inspection precision requirement of advanced IC manufacturing, we propose a detection algorithm based on improved YOLOv5s for the precise detection of hotspot defects in the lithography layout. In the algorithm, a coordinate attention mechanism is introduced into the backbone network, which can improve the attention of the YOLOv5s model to the patterned area in the layout. Thereby, the performance of the lithography hotspots based on the YOLOv5s detection algorithm can be greatly promoted. Meanwhile, the Sigmoid linear unit activation function is used to improve the nonlinear expression of the entire neural network, and the Scylla intersection over union loss function is adopted to realize the quantitative evaluation of the bounding box regression loss more quickly, which can enhance the convergence speed and accuracy of the algorithm. Using the ICCAD (The International Conference on Computer-Aided Design) 2012 contest benchmark and the optical proximity correction optimized lithography patterns as the dataset, performance test experiments are carried out to verify the excellent detection accuracy of the proposed algorithm. The experimental results indicate that the mean precision, mean recall, mean F1-score, and mean average precision of the algorithm reach 97.7%, 98.0%, 97.8%, and 98.4%, respectively, which are significantly better than those of other hotspot detection algorithms and show its good application prospects.

Key words lithography hotspot detection; improved YOLOv5s; inspection precision; coordinate attention mechanism; Sigmoid linear unit activation function; Scylla intersection over union loss function

收稿日期: 2023-04-06; 修回日期: 2023-04-29; 录用日期: 2023-05-15; 网络首发日期: 2023-05-25

基金项目: 国家自然科学基金(52130504, 51975232, 52205592)、湖北省重点研发计划(2022BAA013)

通信作者: *jiaminliu@hust.edu.cn; **shyliu@hust.edu.cn

1 引言

半导体集成电路(IC)是电子信息产业的核心,而光刻是极大规模 IC 制造的核心技术之一,直接决定了 IC 工艺的先进水平。伴随 IC 工艺节点的持续微缩,光刻图案中纳米结构关键尺寸达到照明光波长以下,曝光系统因光的衍射效应无法对掩模图案进行理想成像,这种被称为光学邻近效应(OPE)的现象将导致硅片上曝光图形的失真^[1]。为解决上述问题,业界通常采用光学邻近校正(OPC)技术^[2]修正此类硅片图形的曝光误差,其原理是通过修改掩模布局来补偿由 OPE 引起的成像误差,使实际曝光图形更逼近于目标图形。OPC 技术无法完全应对掩模版图复杂度带来的曝光失真挑战,经过 OPC 掩模优化后的光刻图形仍可能存在桥接、夹断、缺失等系统缺陷,这些被称为光刻热点(LHS)的晶圆缺陷极易造成 IC 芯片的功能故障和良率下降。因此,为保障 IC 芯片的最终性能与良率,必须在实际 IC 制造之前进行光刻热点检测。

目前,常见的光刻热点检测方法有三类,分别是基于光刻仿真、基于模式匹配和基于机器学习的光刻热点检测方法^[3-7]。基于光刻仿真的热点检测方法^[3]通过设定一系列光刻工艺参数,利用光刻仿真获取硅片上的模拟曝光轮廓,然后利用典型几何验证算法^[4]评估模拟轮廓与设计布局之间的匹配程度,进而捕获光刻热点。尽管基于光刻仿真的热点检测方法具有精度高、检测过程直观等优势,但其往往存在计算复杂度高、计算效率低、计算成本昂贵等局限。为克服该热点检测方法在检测效率与成本等方面的不足,研究人员先后提出了基于模式匹配^[5]和基于机器学习的热点检测方法^[6]。基于模式匹配的检测方法依靠预先构建的热点数据库来识别光刻热点^[5],但无法辨识数据库之外的热点缺陷。而基于机器学习的光刻热点检测方法能够有效应对上述两类方法存在的不足^[6-7],其核心在于将光刻热点检测定义为一个图像分类问题,并依靠监督学习训练分类模型使其能够有效甄别版图中的光刻热点。但该方法涉及的版图特征提取过程极其复杂,使得分类模型在训练和测试过程中的预处理十分耗时。

近年来,伴随计算硬件性能的提升及人工智能技术的迅猛发展,基于深度学习的光刻热点检测技术受到了广泛的关注。Shin 等^[8]将卷积神经网络(CNN)算法应用于光刻热点检测中,并将热点检测问题转化为典型图像分类问题,相比于传统基于机器学习的方法,检测精度显著提升。Jiang 等^[9]将版图布局简化为二值图像,利用二值化神经网络构建热点检测模型以提高检测效率。廖陆峰等^[10]提出了一种基于预训练 VGG11(visual geometry group-11)模型的光刻热点检测方法,通过迁移学习将预训练的 VGG11 模型应用于光刻热点检测中。随后,Chen 等^[11]提出了一种基于

区域的光刻热点检测方法,其实质在于将热点检测问题转化为目标检测问题,以提高光刻热点的检测精度。然而,上述基于深度学习的光刻热点检测方法均采用掩模版图来预测可能的热点区域,这类技术虽然节省了光刻仿真的时间,加快了热点检测速度,但因其检测准确率不高极易造成热点缺陷漏检、误检现象,并且从原理上难以将热点缺陷分类。

因此,面向光刻热点检测精度和速度的需求,本文提出了一种基于改进 YOLOv5s 的光刻热点智能检测算法,充分整合光刻仿真、深度学习的技术优势,系统优化了 YOLOv5s 网络模型结构,并采用包含原始掩模版图、OPC 修正后的晶圆模拟曝光图案等更丰富信息的数据集训练所提网络模型,最终实现了光刻热点缺陷的精确、高效检测。通过在骨干网络中引入坐标注意力(CA)机制,显著地提高了网络模型对版图中图案区域的敏感程度。利用 Sigmoid 线性单元(SiLU)激活函数代替传统泄漏修正线性单元(Leaky ReLU)激活函数,能够改善网络模型的非线性表达能力。与此同时,将原始 YOLOv5s 网络模型中的完全交并比(CIoU)损失函数替换为 Scylla 交并比(SIoU)损失函数,实现了边界框回归损失的更精确评估,进一步提高网络模型的收敛速度和检测精度。

2 YOLOv5s 网络模型

YOLOv5 算法是 YOLO 系列算法的第 5 代版本,其凭借强稳定性、高检测精度等优点已成为目标检测的首选模型^[12-14]。根据网络深度的差异,YOLOv5 主要分为 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 等 5 种模型,它们的模型网络深度依次递增。通常,网络深度更大的模型往往在大规模、复杂数据集的处理中具有良好的检测精度,但在简单数据集的处理中易导致过拟合现象。因此,模型网络深度需依据数据集规模、检测对象复杂度、计算硬件资源进行合理选择。通过综合考虑模型网络深度与数据集规模、检测精度、检测速度之间的适应性,选择 YOLOv5s 作为光刻热点检测算法验证实验的基础模型。

YOLOv5s 的网络结构包含输入端(input)、骨干网络(backbone)、颈部网络(neck)和预测端(prediction)等 4 个部分,具体网络结构如图 1 所示。

输入端主要用于原始热点图像数据集的数据增强、预处理。骨干网络主要用于图像特征的筛选与提取,其包含 Focus、CBL [Conv+batch normalization (BN)+Leaky ReLU]、C3 (cross stage partial network with 3 convolutions)和 SPPF (spatial pyramid pooling fast)等 4 个模块。其中:Focus 模块用于图像切片操作,以实现图像特征的信息转换;CBL 模块是 YOLOv5s 的基本卷积单元,由卷积层、批量归一化(BN)层、Leaky ReLU 激活函数组成,用于网络的非线性表达;C3 模块采用残差网络框架技术增强网络的学习能力,

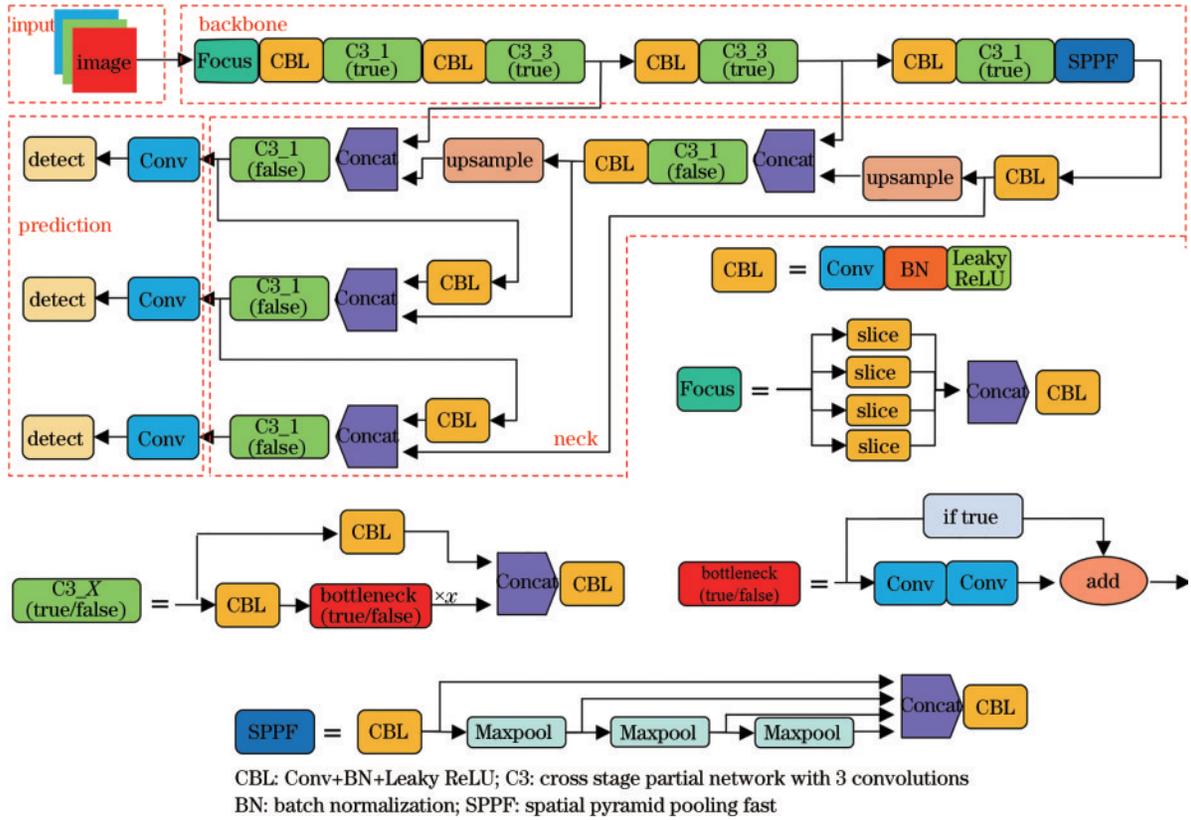


图 1 Yolov5s 的网络结构示意图
 Fig. 1 Network structure of Yolov5s

在不损失精度的前提下能够极大地降低模型网络深度,进而提高网络的训练速度;SPPF 模块采用串行池化层拼接不同感受野的特征图,以实现目标的多尺度特征融合。

颈部网络采用特征金字塔网络和路径聚合网络双层架构,前者能够将高层强语义特征信息传递至网络底层,后者能够将所提取的底层强定位特征信息反向传递至网络高层,以实现语义表达和定位信息的双向加强。预测端通常在三个尺度上对特征图进行预测,随后利用特定损失函数来评估预测值和实际值之间的误差。在 Yolov5s 网络中,典型损失函数包含边界框回归损失、目标置信度损失、分类损失等三个部分。其中,边界框回归损失通常采用 CIoU 损失函数^[15]来计算网络模型预测框与目标框之间的误差,其核心思想是通过引入中心点距离比、边界框宽高比等惩罚项以增强预测框与目标框重叠区域交并比(IoU)的计算收敛性,CIoU 损失函数的具体表达式为

$$L_{CIoU} = L_{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha \cdot \nu, \quad (1)$$

$$L_{IoU} = 1 - \frac{B^{gt} \cap B}{B^{gt} \cup B}, \quad (2)$$

$$\alpha = \frac{\nu}{L_{IoU} + \nu}, \quad (3)$$

$$\nu = \frac{4}{\pi^2} \left[\arctan(w^{gt}/h^{gt}) - \arctan(w/h) \right]^2, \quad (4)$$

式中: L_{IoU} 为预测框和目标框之间面积 IoU 的损失; $\rho(b, b^{gt})$ 为预测框中心点与目标框中心点之间的欧氏距离; c 为预测框与目标框最小外接矩形的对角线距离; α 为权重参数; ν 为宽高差异性的评价因子; B 和 B^{gt} 分别为预测框和目标框区域; \cap 和 \cup 分别为交集和并集算符; (w, h) 和 (w^{gt}, h^{gt}) 分别为预测框和目标框的宽和高。

至于目标置信度损失和分类损失函数,前者用于评估目标的置信度水平,后者用于评估分类结果的可靠性。

3 Yolov5s 网络改进

为使 Yolov5s 网络更恰当地应用于光刻热点检测,并使其达到更高的热点检测精度,引入了一系列改进措施。

3.1 引入 CA 机制

通过在 Yolov5s 网络中引入 CA 模块^[16],将特征图的位置信息编码至通道注意力中,进而显著增强 Yolov5s 网络模型对光刻版图中图形区域的关注度,其具体结构如图 2 所示。

CA 模块首先对 $C \times H \times W$ 的输入特征图分别在 W 和 H 方向实施平均池化,以产生 $C \times H \times 1$ 和 $C \times 1 \times W$ 的特征图 z^w 和 z^h ,使模块在单一方向(W 方向或 H 方向)上获取特征图的整体依赖关系,并在另一方向(H 方向或 W 方向)上保存精确的位置信息,进而使网络在不同方向上对关注信息进行准确定位。随

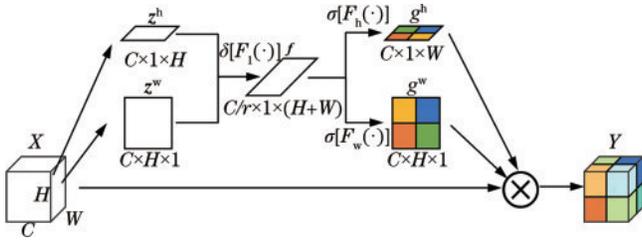


图 2 CA 模块结构示意图
Fig. 2 CA module structure

后,将上述两特征图实施拼接,并采用 1×1 卷积函数 F_1 对通道 C 进行压缩,随即进行归一化、非线性处理操作 $\delta(\cdot)$,以产生特征图 $f \in \mathbf{R}^{C/r \times (H+W)}$,其中, r 为通道压缩比例。将特征图 f 再次分割为沿 H 和 W 方向的

特征图 f^h 和 f^w ,并分别利用 1×1 的卷积函数 F_h 和 F_w 将通道扩展回 C ,进而依靠 Sigmoid 函数 $\sigma(\cdot)$ 输出权重分布图 g^h 和 g^w 。利用此权重分布图产生 H 和 W 方向的权重,并与输入特征图相乘即可获得添加 CA 模块后的输出特征图,此操作为

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j), \quad (5)$$

式中, $y_c(i, j)$ 、 $x_c(i, j)$ 、 $g_c^h(i)$ 、 $g_c^w(j)$ 分别为输出特征图 Y 、输入特征图 X 、权重分布图 g^h 、权重分布图 g^w 的第 c 个通道子图中索引 (i, j) 处的值。

在上述操作中,原始 YOLOv5s 网络的骨干网络中各个 C3 模块均会衔接一个 CA 模块,以实现针对不同尺寸特征图的赋权重操作。相应改进后的 C3_CA 模块结构如图 3 所示。

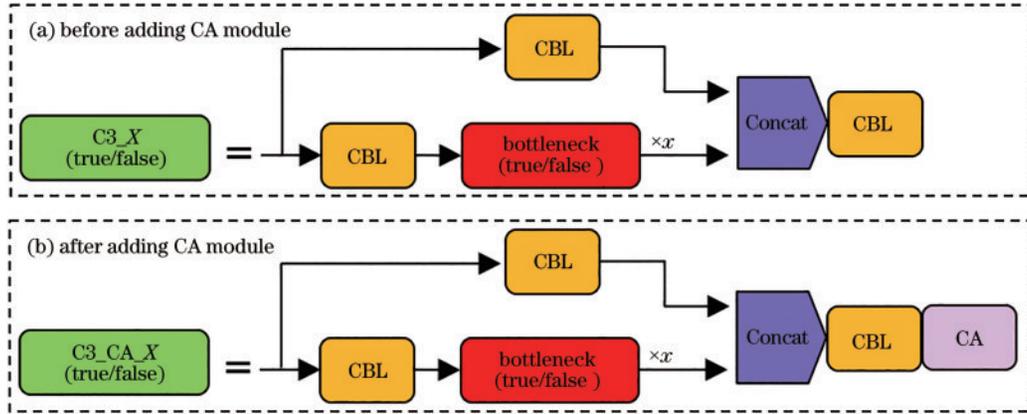


图 3 引入 CA 机制前后 C3 模块结构示意图。(a)引入 CA 前 C3 模块结构;(b)引入 CA 后 C3 模块结构

Fig. 3 C3 module structure before and after introduction of CA mechanism. (a) C3 module structure before introduction of CA; (b) C3 module structure after introduction of CA

3.2 改进激活函数

传统 YOLOv5s 网络的 CBL 模块往往采用 Leaky ReLU 激活函数作为非线性激活函数,其表达式为

$$y = \max(0, x) + a \times \min(0, x), \quad (6)$$

式中, a 是一个小常数(约 0.1),其使得 Leaky ReLU 激活函数能够保留负值输入信息,进而解决负值输入情形中因“神经元死亡”而造成的梯度消失问题。然而, Leaky ReLU 激活函数不是连续可微的,其在 $x=0$ 处具有奇异点,并且函数取值无下界,因此易在大负值输入、零值输入等情形中出现梯度传播失稳现象,进而造成网络模型在训练环节难以收敛。

为避免上述现象的发生,利用 SiLU 激活函数^[17]取代 Leaky ReLU 激活函数作为网络模型的非线性激活函数,其函数表达式为

$$f(x) = x \cdot \text{sig}(x) = \frac{x}{1 + e^{-x}}, \quad (7)$$

式中, $\text{sig}(\cdot)$ 为 SiLU 激活函数。

图 4 为 Leaky ReLU 与 SiLU 激活函数及相应一阶导数的对比结果。与 Leaky ReLU 激活函数相比, SiLU 激活函数具有函数取值有下界、负半轴输入的权重因子小等优点,不仅保留了少量的负值输入信息,也

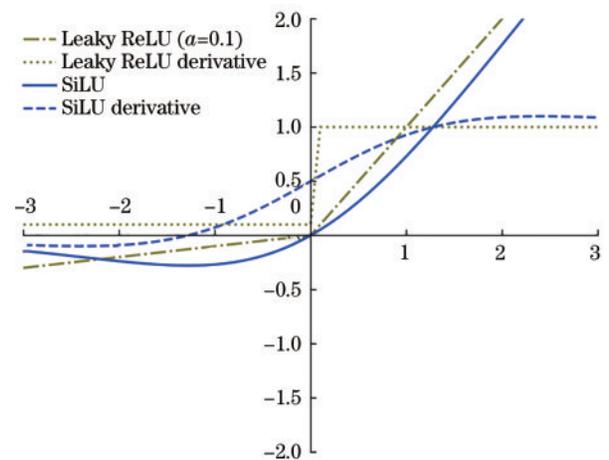


图 4 SiLU 和 Leaky ReLU 激活函数的对比示意图
Fig. 4 Comparison between SiLU function and Leaky ReLU function

产生了更强的正则化效果。同时, SiLU 激活函数作为连续可微函数,具有平滑、非单调、无奇异点等特性,有利于网络的非线性表达和信息流动,并且能够增强网络的泛化能力,提高网络模型的表现效果。改进后的 CBS 模块如图 5 所示。



图5 改进后的CBS模块

Fig. 5 Improved CBS module structure

3.3 改进损失函数

传统 Yolov5s 网络通常采用 CIoU 损失函数来定量评估边界框回归损失,虽然考虑了预测框和目标框之间 IoU、中心距离和宽高比等因素的影响,但忽视了宽度和高度的实际数值,极易在宽高比相同、宽高值不同的情形中阻碍网络模型的有效优化。同时,CIoU 损失函数未能考虑预测框与目标框之间的方向匹配关系,容易造成预测框在训练过程中的“四处游荡”行为,进而降低网络模型的收敛性和训练效率。

为解决上述问题,利用 SIoU 损失函数^[18]取代 CIoU 损失函数来定量评估网络模型的边界框回归损失,该损失函数由角度损失 Δ 、中心点距离损失 Δ 、宽高(形状)损失 Ω 、IoU 损失 L_{IoU} 等 4 部分组成,具体表达式为

$$\Delta = 1 - 2 \times \sin^2[\arcsin(x) - \pi/4] = \sin(2\beta), \quad (8)$$

$$\Delta = \sum_{i=x,y} (1 - e^{-\gamma \rho_i}) = \sum_{i=x,y} \left\{ 1 - \exp \left[-(2 - \Delta) \left(\frac{b_i^{gt} - b_i}{c_i} \right)^2 \right] \right\}, \quad (9)$$

$$\Omega = \sum_{i=w,h} (1 - e^{-\theta \rho_i}) = \sum_{i=w,h} \left\{ 1 - \exp \left[-\frac{|i^{gt} - i|}{\max(i^{gt}, i)} \right] \right\}^\theta, \quad (10)$$

式中: β 为预测框和目标框中心点连线与 X 轴之间的夹角; γ 为角度损失 Δ 所贡献的权重; ρ_x 为预测框和目标框中心点之间距离在 X 轴方向投影分量与最小外接矩形宽度之间的比值; ρ_y 为预测框和目标框中心点之间距离在 Y 轴方向投影分量与最小外接矩形高度之间的比值; (b_x, b_y) 和 (b_x^{gt}, b_y^{gt}) 分别为预测框和目标框的中心点坐标; c_x 和 c_y 分别为预测框和目标框最小外接矩形的宽和高; (w, h) 和 (w^{gt}, h^{gt}) 分别为预测框和目标框的宽和高; θ 作为可调参数,表示网络模型对宽高损失所赋予的权重(本文取 $\theta=4$)。则 SIoU 损失函数的计算表达式为

$$L_{Siou} = L_{IoU} + (\Delta + \Omega)/2. \quad (11)$$

根据以上改进措施,所提热点检测网络模型结构如图 6 所示。

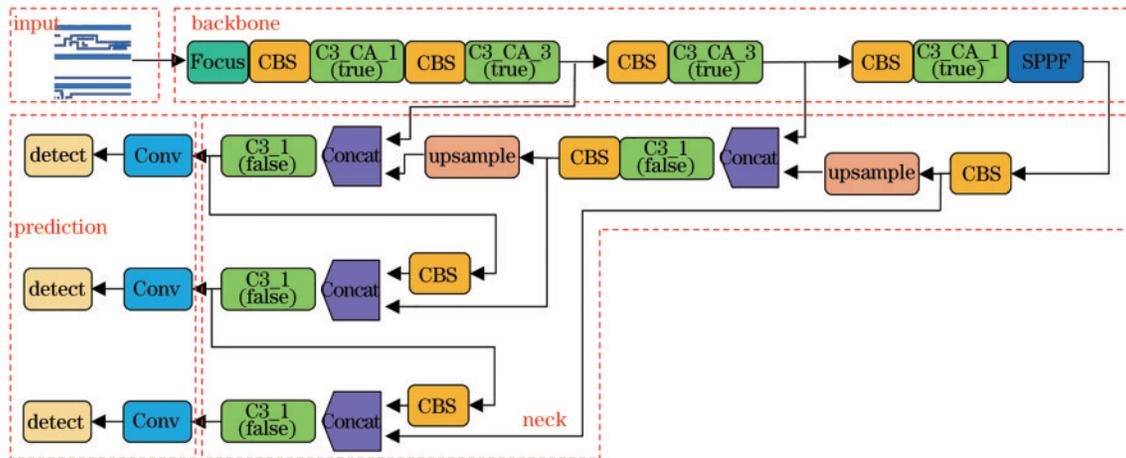


图6 改进后的热点检测网络模型结构示意图

Fig. 6 Improved hotspot detection network model structure

4 实验结果与分析

4.1 数据集的建立

为验证所提方法的有效性,以 ICCAD (The International Conference on Computer-Aided Design) 2012 竞赛版图基准^[19]为基础数据,将其与 OPC 修正后的晶圆模拟曝光图案进行叠加,并利用密度编码将叠加图形转化为二维图像,随即实施 90° 、 180° 、 270° 旋转和镜像操作等数据增强技术,以解决光刻热点图像的数据不平衡问题,最终产生 1200 幅包含光刻热点的图像数据集。

依据空间几何拓扑关系,将典型光刻热点划分为

如下 6 类热点缺陷:缺失(missing)、冗余(extra)、软桥接(soft bridging)、硬桥接(hard bridging)、软夹断(soft pinching)、硬夹断(hard pinching)。这些光刻热点的几何特征如图 7 所示,其中矩形边框为掩模版图,实心图形为晶圆模拟曝光图案,虚线框为热点区域。

利用 Labeling 软件对数据集进行标注,生成 6 种标签,记为 0~5。其中,标签“0”“1”“2”“3”“4”“5”分别表示缺失、冗余、软桥接、硬桥接、软夹断和硬夹断,其分布信息如图 8 所示。采用 8:2 数据规模比对上述数据集进行分割,可产生网络模型的训练集和验证集。

4.2 实验环境及参数配置

验证实验实施于 Windows 11 \times 64 操作系统,深

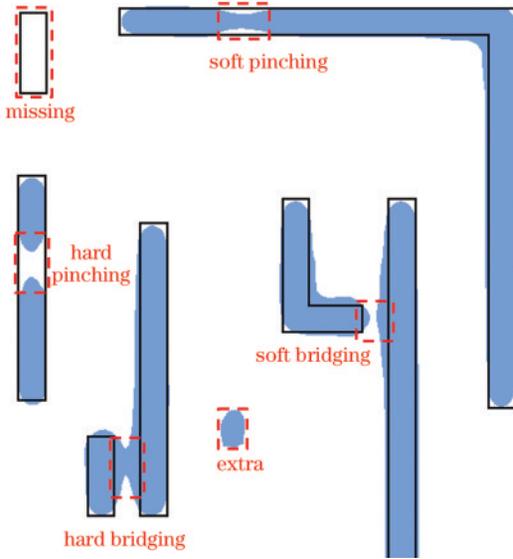


图 7 不同类型光刻热点几何特征

Fig. 7 Geometric features of different types of lithography hotspots

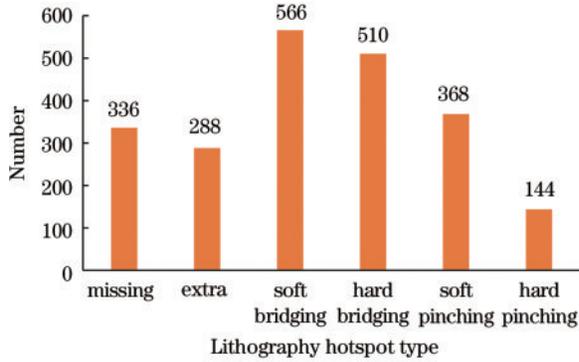


图 8 6类光刻热点的分布信息

Fig. 8 Distribution information of six types of lithography hotspots

度学习库利用 PyTorch 搭建, 编程语言为 Python, 软件平台为 Windows 11+Pytorch 1.7.1+CUDA 11.0+cuDNN 8.0.5+PyCharm, 硬件平台为 Intel® Core™ i7-11800H 2.3 GHz CPU、16 GB 内存与 NVIDIA GeForce RTX3060 6 GB GPU、1 TB 固态存储的组合。

模型网络的训练参数如表 1 所示。值得注意的是, 上述光刻热点图像数据集需避免采用随机裁剪、缩放和色域变化等数据增强操作, 因此需将模型网络输入端的 Mosaic 数据增强参数设置为 0, 以避免 Mosaic 数据增强。

4.3 评价指标

利用准确率(P)、召回率(R)、F1 分数($f_{F1-score}$)、平均精度(f_{AP})和均值平均精度(f_{mAP})共 5 个指标来评估热点检测模型的检测性能, 具体计算公式为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\%, \quad (12)$$

表 1 网络训练参数

Table 1 Network training parameters

Parameter	Value
Epoch	500
Batch size	16
IoU threshold	0.65
Initial learning rate	0.01
Minimum learning rate	0.002
Momentum	0.937
Weight decay	0.0005

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\%, \quad (13)$$

$$f_{F1-score} = \frac{2 \times P \times R}{P + R}, \quad (14)$$

$$f_{AP} = \int_0^1 P(R) dR, \quad (15)$$

$$f_{mAP} = \frac{1}{S} \sum_{i=1}^S f_{AP_i}, \quad (16)$$

式中: N_{TP} 为实际为正样本且被模型预测为正样本的样本数量; N_{FP} 为实际为负样本但被模型预测为正样本的样本数量; N_{FN} 为实际为正样本但被模型预测为负样本的样本数量。那么, 准确率 P 是指模型预测为正样本中, 实际也是正样本的检测样本所占的比例; 召回率 R 是指实际为正样本中, 模型预测也是正样本的检测样本所占的比例。 $f_{F1-score}$ 为准确率 P 和召回率 R 的调和平均数; f_{AP} 为光刻热点的平均精度, 是通过计算由 P 和 R 构成 XY 轴所绘制的 $P-R$ 曲线与相应坐标轴所围成图形的面积得到的, 每一类光刻热点均对应一个 f_{AP} 数值; f_{mAP} 为所有类别光刻热点的平均精度 f_{AP} 的平均值, 其中, S 为模型检测的类别总数。

4.4 实验结果

所提方法在测试集上的实验结果如表 2 所示。由表 2 中的结果可知, 基于改进 Yolov5s 的光刻热点检测算法对全部 6 类热点均展现出良好的检测准确性, 其平均准确率、平均召回率、平均 F1 分数、均值平均精度分别达到 97.7%、98.0%、97.8% 和 98.4%。为了更好地展示所提方法的光刻热点检测效果, 分别使用 Yolov5s 和改进 Yolov5s 算法对多张实际光刻版图进行热点检测, 相应可视化结果如图 9 所示。以图 9(a) 结果

表 2 模型检测结果

Table 2 Model detection results

Type	$P / \%$	$R / \%$	$f_{F1-score} / \%$	$f_{mAP} / \%$
Missing	99.7	95.2	97.4	95.7
Extra	100.0	92.8	96.3	97.3
Soft bridging	93.4	100.0	96.0	98.9
Hard bridging	97.9	100.0	98.9	99.5
Soft pinching	97.2	100.0	98.6	99.5
Hard pinching	97.9	100.0	98.6	99.5
Average	97.7	98.0	97.8	98.4

为例, YOLOv5s 算法出现了光刻热点的漏检、错检现象, 而改进 YOLOv5s 算法能准确地识别所有光刻热点。而图 9(b)~(f) 的结果则反映出改进 YOLOv5s 算法提高了

所有类型热点的分类置信度, 正确识别热点的概率增大。以上结果充分表明, 改进 YOLOv5s 算法在不同版图图中均表现出优异的检测性能, 具有良好的鲁棒性。

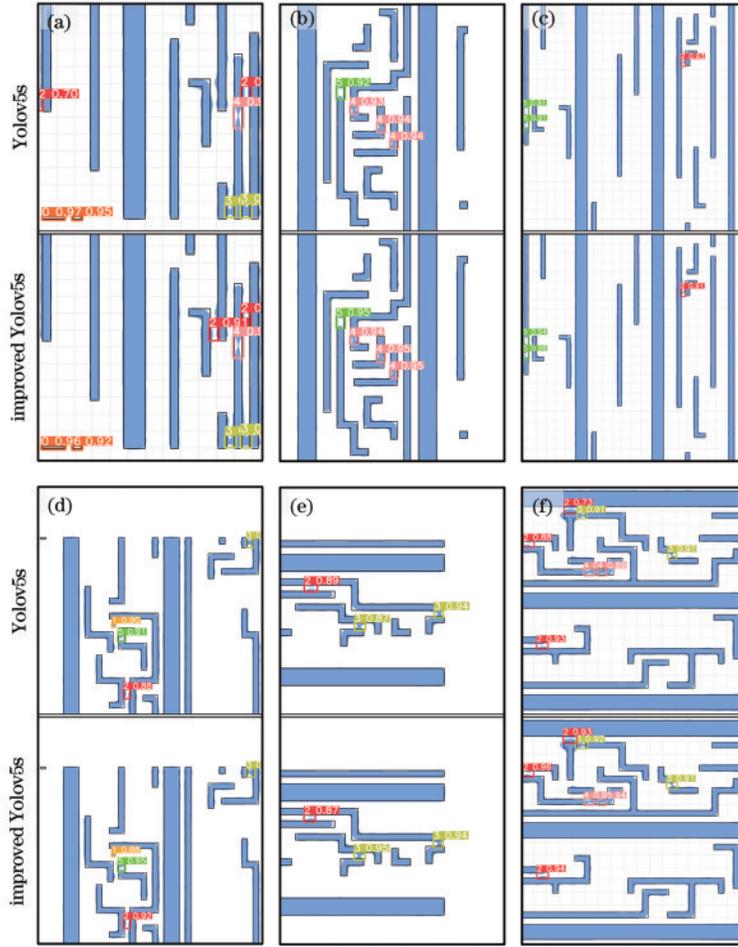


图 9 YOLOv5s 和改进 YOLOv5s 不同光刻热点版图检测结果对比。(a)~(f) 版图 1~6 检测结果

Fig. 9 Comparison of detection results of YOLOv5s and improved YOLOv5s in different lithography hotspot layouts. (a)~(f) Detection results of layout 1 to 6

4.5 消融实验

为了进一步验证 YOLOv5s 改进方法的有效性, 提出利用消融实验来测试不同改进措施所取得的效果。

相应地, 设计了 6 种消融实验方案以开展改进效果测试, 具体实验结果如表 3 所示。

表 3 消融实验结果
Table 3 Ablation experiment results

YOLOv5s	Method			$P / \%$	$R / \%$	$f_{F1-score} / \%$	$f_{mAP} / \%$	Runtime / (h·mm ⁻²)
	SiLU	SIoU	CA					
✓				96.4	95.2	95.8	97.3	0.687
✓	✓			95.6	97.2	96.4	97.9	0.610
✓		✓		96.9	96.9	96.9	98.1	0.687
✓			✓	98.6	96.0	97.3	98.0	0.625
✓	✓		✓	97.5	97.3	97.4	98.2	0.740
✓	✓	✓	✓	97.7	98.0	97.8	98.4	0.697

由表 3 结果可知, SiLU 激活函数虽然将 YOLOv5s 网络模型的准确率降低了 0.8 个百分点, 但将召回率提高了 2.0 个百分点, 降低了目标漏检事件的概率。

同时, $f_{F1-score}$ 和 f_{mAP} 均提高了 0.6 个百分点, 这表明改进后网络模型的整体检测性能得到了提升。SIoU 损失函数能够提高网络模型的准确率和召回率, 进而使

$f_{F1-score}$ 和 f_{mAP} 分别提升了 1.1 个百分点和 0.8 个百分点。而且,通过在 Yolov5s 网络模型中仅引入 CA 模块,能够将模型的准确率提高 2.2 个百分点。而如果在 Yolov5s+SiLU 的基础上增加 CA 模块,则不仅能够改善召回率,也能够提高准确率,这表明 SiLU 激活函数和 CA 模块的组合使用可显著改善网络模型的综合性能。实际上,在原始 Yolov5s 网络模型中依次加入 SiLU、SiIoU 和 CA,可将模型的检测性能提升至最优状态,表现为准确率提高 1.3 个百分点、召回率提高 2.8 个百分点、 $f_{F1-score}$ 提高 2.0 个百分点、 f_{mAP} 提高 1.1 个百分点。由此可见,采用的改进措施能够有效改善传统 Yolov5s 网络模型的整体性能,并且改进后的网络模型可充分发挥各改进模块的优势,实现改善网络模型综合检测性能的目的。此外,由表 3 的运行时间对比结果可知,改进模块未能提升 Yolov5s 算法的检测速度,其原因在于改进模块引入了更多的计算环节。

4.6 对比实验

进一步地,将所提方法与典型三类传统光刻热点检测算法进行了性能比较,以验证所提方法的优越性。这三类热点检测算法分别是 Shin 等^[8]提出的基于 CNN 的光刻热点检测方法、Zhou 等^[20]提出的基于 GoogLeNet 的光刻热点检测方法、Guo 等^[21]提出的基于 Faster R-CNN 的光刻热点检测方法。相应对比结果如表 4 所示。

表 4 不同方法实验结果对比

Table 4 Comparison of experimental results of different methods

Method	$P / \%$	$R / \%$	$f_{F1-score} / \%$	Runtime / (h·mm ⁻²)
CNN	16.0	97.8	26.5	25.2
GoogLeNet	47.5	98.3	63.5	—
Faster R-CNN	40.3	96.1	53.1	0.7
Proposed method	97.7	98.0	97.8	0.7

由表 4 结果可知,所提方法在检测准确率和 F1 分数方面展示了显著的优越性。具体而言,与基于 CNN、GoogLeNet 和 Faster R-CNN 的热点检测方法相比,基于改进 Yolov5s 的光刻热点检测算法在准确率方面分别提升了 81.7、50.2 和 57.4 个百分点,在 F1 分数方面分别提升了 71.3、34.3 和 44.7 个百分点。同时,与表 4 中其他基于深度学习的光刻热点检测方法相比,所提算法在检测速度方面也有一定的提升,平均检测耗时为 0.7 h/mm²。

5 结 论

提出了一种基于改进 Yolov5s 网络模型的光刻热点检测算法。通过在 Yolov5s 骨干网络的 C3 模块中引入 CA 机制,在卷积模块中利用 SiLU 激活函数替代 Leaky ReLU 激活函数,并利用 SiIoU 损失函数定量评估边界框回归损失,改进了 Yolov5s 网络模型。将

ICCAD 2012 竞赛基准、经 OPC 优化后的光刻图形作为数据集对所提算法开展性能测试实验,验证了热点检测算法的优异检测精度。相应实验结果表明,所提热点检测算法对全部 6 类光刻热点均展示出良好的检测准确性,其平均准确率、平均召回率、平均 F1 分数和均值平均精度分别达到 97.7%、98.0%、97.8% 和 98.4%。由消融实验结果可知,改进后的网络模型在整体检测性能方面优于原始 Yolov5s 模型。同时,利用对比实验证实了所提方法相对于传统三类热点智能检测算法的优越性。以上结果充分验证了所提方法的有效性和可行性,在解决光刻领域中光刻热点检测问题方面具有良好的应用潜力。

参 考 文 献

- [1] Carre H, Doxtator R H, Duffy M C. Semiconductor manufacturing technology at IBM[J]. IBM Journal of Research and Development, 1982, 26(5): 528-531.
- [2] Chen A, Foong Y M, Thaler T, et al. Aerial image metrology for OPC modeling and mask qualification[J]. Proceedings of SPIE, 2017, 10446: 104460V.
- [3] Mitra J, Yu P, Pan D Z. RADAR: RET-aware detailed routing using fast lithography simulations[C]// Proceedings of the 42nd Annual Design Automation Conference, June 13-17, 2005, Anaheim, California, USA. New York: ACM Press, 2005: 369-372.
- [4] Cobb N B, Zakhor A, Miloslavsky E. Mathematical and CAD framework for proximity correction[J]. Proceedings of SPIE, 1996, 2726: 208-222.
- [5] Yao H, Sinha S, Chiang C, et al. Efficient process-hotspot detection using range pattern matching[C]// 2006 IEEE/ACM International Conference on Computer-Aided Design, November 5-9, 2006, San Jose, CA, USA. New York: IEEE Press, 2007: 625-632.
- [6] Yu Y T, Lin G H, Jiang I H R, et al. Machine-learning-based hotspot detection using topological classification and critical feature extraction[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2015, 34(3): 460-470.
- [7] Gao J R, Yu B, Pan D Z. Accurate lithography hotspot detection based on PCA-SVM classifier with hierarchical data clustering[J]. Proceedings of SPIE, 2014, 9053: 90530E.
- [8] Shin M, Lee J H. CNN based lithography hotspot detection[J]. International Journal of Fuzzy Logic and Intelligent Systems, 2016, 16(3): 208-215.
- [9] Jiang Y Y, Yang F, Yu B, et al. Efficient layout hotspot detection via binarized residual neural network ensemble [J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2021, 40(7): 1476-1488.
- [10] 廖陆峰, 李思坤, 王向朝. 基于预训练 VGG11 模型的光刻热点检测方法[J]. 光学学报, 2023, 43(3): 0312008. Liao L F, Li S K, Wang X Z. Lithography hotspot detection method based on pre-trained VGG11 model[J]. Acta Optica Sinica, 2023, 43(3): 0312008.

- [11] Chen R, Zhong W, Yang H Y, et al. Faster region-based hotspot detection[J]. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2022, 41(3): 669-680.
- [12] Zhu X K, Lyu S C, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), October 11-17, 2021, Montreal, BC, Canada. New York: IEEE Press, 2021: 2778-2788.
- [13] 王建楠, 吕胜涛, 牛健. 基于改进 YOLOv5 的无人机检测方法[J]. *光学与光电技术*, 2022, 20(5): 48-56.
Wang J N, Lü S T, Niu J. UAV detection method based on improved YOLOv5[J]. *Optics & Optoelectronic Technology*, 2022, 20(5): 48-56.
- [14] 舒子婷, 张泽斌, 宋尧哲, 等. 基于改进 YOLOv5 的低光照图像目标检测[J]. *激光与光电子学进展*, 2023, 60(4): 0404001.
Shu Z T, Zhang Z B, Song Y Z, et al. Low-light image object detection based on improved YOLOv5 algorithm [J]. *Laser & Optoelectronics Progress*, 2023, 60(4): 0404001.
- [15] Zheng Z H, Wang P, Ren D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8574-8586.
- [16] 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), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.
- [17] Elfving S, Uchibe E, Doya K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning[J]. *Neural Networks*, 2018, 107: 3-11.
- [18] Gevorgyan Z. SIOU loss: more powerful learning for bounding box regression[EB/OL]. (2022-05-25)[2023-04-02]. <https://arxiv.org/abs/2205.12740>.
- [19] Torres J A. ICCAD-2012 CAD contest in fuzzy pattern matching for physical verification and benchmark suite [C]//Proceedings of the International Conference on Computer-Aided Design, November 5-8, 2012, San Jose, California. New York: ACM Press, 2012: 349-350.
- [20] Zhou K B, Zhang K F, Liu J E, et al. An imbalance aware lithography hotspot detection method based on HDAM and pre-trained GoogLeNet[J]. *Measurement Science and Technology*, 2021, 32(12): 125008.
- [21] 郭求是, 史峥, 张培勇. 基于 Faster R-CNN 的光刻热点检测[J]. *微电子学*, 2018, 48(6): 834-838, 845.
Guo Q S, Shi Z, Zhang P Y. Lithographic hotspot detection based on faster R-CNN[J]. *Microelectronics*, 2018, 48(6): 834-838, 845.