

# 光学学报

## 基于改进 YOLOv3 的光刻热点检测方法

林牧, 曾范文清, 刘泉旋, 李芬成, 骆骏, 沈逸江\*

广东工业大学自动化学院, 广东 广州 510006

**摘要** 随着集成电路特征尺寸不断缩小, 光刻系统分辨率与特征尺寸之间不匹配导致晶圆成像结果出现不必要的形状变形。这些会产生形状变形的区域就是俗称的光刻热点。为提高集成电路生产的良品率, 在掩模板制造之前, 需要对晶圆成像结果进行光刻热点检测。提出一种基于深度学习的热点检测方法, 通过将挤压和激励网络 (SENet) 输入预先训练的 YOLOv3 模型来提高光刻热点检测的精确率和召回率。实验结果表明, 在 2012 国际计算机辅助设计会议 (ICCAD 2012) 数据集上, 所提方法优于其他基于深度或具有代表性的基于机器学习的方法, 最终的平均召回率为 1.00, 精确率为 0.45, F1 分数为 0.62。

**关键词** 光刻; 热点; 深度学习; YOLOv3; 挤压和激励网络

**中图分类号** TN305.7 **文献标志码** A

**DOI:** 10.3788/AOS230928

### 1 引言

随着芯片设计和半导体制造技术节点的特征尺寸进一步缩小, 对芯片可制造性的相关设计提出更高的要求。开发技术人员应用分辨率增强技术 (RET), 如光学邻近校正 (OPC)、相移掩模 (PSM) 和亚分辨率辅助图形 (SRAF) 等, 来提高光刻成像的掩模可打印性。但是由于这些技术受到许多光刻工艺参数的影响以及在晶圆成像过程对这些工艺参数的敏感, 在光刻之后的图案仍然会出现开路 and 短路的电路故障, 严重影响芯片制造的良品率<sup>[1]</sup>。因此, 在制造掩模板之前需要找出此类的光刻热点。

目前, 光刻热点检测方法主要有 4 种, 包括光刻仿真<sup>[2-3]</sup>、模式匹配<sup>[4-5]</sup>、机器学习<sup>[6-7]</sup>和深度学习<sup>[8-10]</sup>。使用光刻仿真技术对光刻热点进行识别具有较高的精度, 能够较好地识别光刻热点。然而, 光刻仿真技术需要消耗大量的计算资源和时间成本, 在集成电路高速发展的今天已经变得不可接受; 基于模式匹配的光刻热点检测方法需要事先构建热点库, 通过对待检测图形与热点库进行对比从而识别出光刻热点图形, 该方法识别速度非常快, 但无法友好识别热点库中不存在的热点; 机器学习虽然擅长检测未知热点, 具有快速检测的优势, 但是很难准确定义热点和非热点的几何特征, 其次机器学习需要频繁进行手动提取热点特征, 抑制了机器学习的实际应用。

近年来, 深度学习在机器视觉任务中表现非常优

异, 作为机器学习的分支, 它继承了机器学习的优点并且能够自我学习热点和非热点的几何特征, 不需要繁琐的手动提取特征过程, 因此深度学习也越来越多地应用在热点检测领域。Yang 等<sup>[11]</sup>研究了卷积神经网络 (CNN) 超参数对光刻热点检测任务的影响, 并应用采样来解决光刻热点数据不平衡的问题。Xiao 等<sup>[12]</sup>探讨了将经过 ImageNet 数据集训练过的神经网络用于光刻热点检测的可能性。一般来说, 光刻热点检测任务中的网络模型应该学习关于特征相似性和数据不平衡的热点检测的底层模式的复杂性。晶圆上的平版印刷容易受到光刻工艺的影响, 敏感版图上的图形会产生不希望热点图形。热点和非热点图形的几何特征具有高度的相似性, 虽然能够将网络做得更深来提高网络的学习能力, 但是网络会有更大的过拟合风险。此外, 光刻热点检测模型的输入数据是高度不平衡的, 其中非热点的数据远超热点数据。因此, 大多数深度学习分类器都有偏倚, 对较小类的分类性能较差。在光刻热点检测任务中, 网络应该能够标注光刻热点所在的区域和概率。

为解决上述问题, 本文引入基于 YOLOv3 的热点检测方法。YOLOv3 可以使用一个单一的网络来预测热点, 并给出热点的位置。为保证准确性, 本文在 YOLOv3 中嵌入注意力机制, 同时为了提高模型的泛化性能, 通过数据增强策略增加了训练样本的数量, 还使用完全交并比 (CIoU) 函数和预训练的模型来提高模型的检测性能和速度。

收稿日期: 2023-05-05; 修回日期: 2023-07-18; 录用日期: 2023-08-29; 网络首发日期: 2023-09-22

基金项目: 国家自然科学基金 (62174037)、广东省自然科学基金 (2021A1515012000, 2020A1515010633)

通信作者: \*yjshen@gdut.edu.cn

## 2 光刻热点检测任务描述

图 1 左侧是包含有热点的掩模板版图。图 1 右侧方框区域是掩模板版图中存在热点的位置,将原始掩模板输入到经过训练的网络模型后,网络能够检测出图 1 右




图 1 热点检测任务,左图为原始掩模板版图,右图方框为掩模板版图热点区域

Fig. 1 Hotspot detection task, the left figure is the mask, the block area on the right is the hotspot area

## 3 研究方法

### 3.1 YOLOv3

YOLOv3 通过使用单个网络能够在目标检测任务中判定候选区域并能够同时对候选区域内的目标进行位置和类别的判别。YOLOv3 网络结构主要由输入端、主干、颈部和头部构成。在输入端部分,网络对热点和非热点的数据进行加载,可以根据需求对加载

侧的热点区域。热点检测任务可以描述为:给定的包含有热点和非热点的数据集经过网络训练后,模型可以预测出热点的位置和概率。网络模型应该尽可能地提高检测热点能力和降低虚假热点能力,过多的虚假热点会导致在后续的版图优化过程中发生过度优化现象。

后的数据进行 Mosaic 数据扩增、自适应锚框计算、自适应缩放等预处理操作。主干的主要功能是对热点和非热点图像的特征信息进行提取。在颈部结构中,对主干部分上的多个层级的特征图进行融合加工,提高网络的表达能力,并将融合后的特征图传递到头部进行预测。在头部结构中,生成预测框和预测类别。YOLOv3 的结构如图 2 所示。

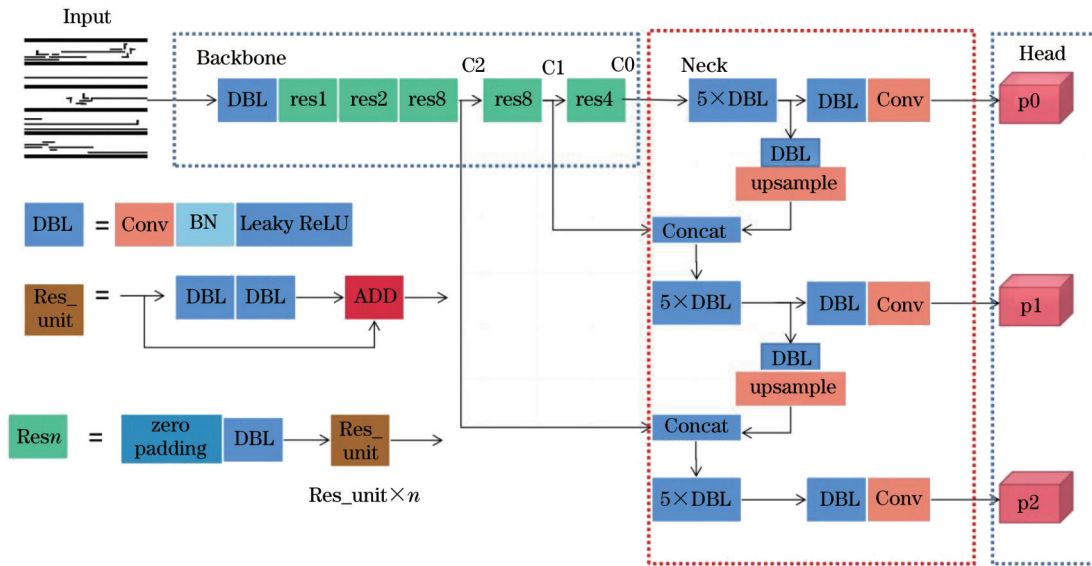


图 2 YOLOv3 结构

Fig. 2 Structure of YOLOv3

### 3.2 SENet

挤压和激励网络 (SENet) 是专注于特征通道的注意力机制。SENet 提供网络各个特征通道的重要程度,使得网络模型关注重要的特征通道,对不重要的特征通道进行抑制<sup>[13]</sup>。SENet 结构如图 3 所示,结构主

要分为压缩 (squeeze)、激励 (excitation) 和 scale 模块。压缩模块的主要作用是使用全局平均池化将  $W \times H \times C$  特征图压缩为  $1 \times 1 \times C$  的特征图,压缩后的特征图的感受野更广。之后将特征图输入激励模块,激励模块有 2 个全连接层,第一个全连接层对特征图进

行进一步的压缩,第二个全连接层将特征图的维度还原到  $1 \times 1 \times C$ ,通过 ReLU 激活函数和 Sigmoid 激活函数得到特征通道的权重信息。scale 模块对得到的权重信息与原特征图  $u_c$  进行加权,更新得到新的  $W \times H \times C$  大小特征图。经过上述阶段,网络模型通过 SENet 对原始特征图  $u_c$  进行处理,得到一个新的特征图  $\tilde{X}_c$ ,

$$\tilde{X}_c = F_{scale}(u_c, s_c) = u_c \cdot s_c = u_c \cdot \sigma[W_2 \delta(W_1 Z)], \quad (1)$$

式中:  $s_c$  是经 SENet 模块后得到的通道权重;  $\sigma$  为

Sigmoid 激活函数;  $W_1$  和  $W_2$  是全连接层,其中  $W_1 \in \mathbb{R}^{\frac{c}{r} \times c}$ ,  $W_2 \in \mathbb{R}^{c \times \frac{c}{r}}$ ,  $r$  是一个可以减少 SENet 计算量的参数;  $\delta$  是 ReLU 激活函数。式(1)能够使网络可以学习到更加重要的热点特征,从而抑制多余特征。

为进一步提升对光刻热点的检测能力,提出一种将 SENet 注意力机制引入到 YOLOv3 的光刻热点检测算法,提升特征图中不同通道间的特征表达能力。网络模型结构更改后的结构如图 4 所示,其中虚线框区域为添加的 SENet 结构位置。

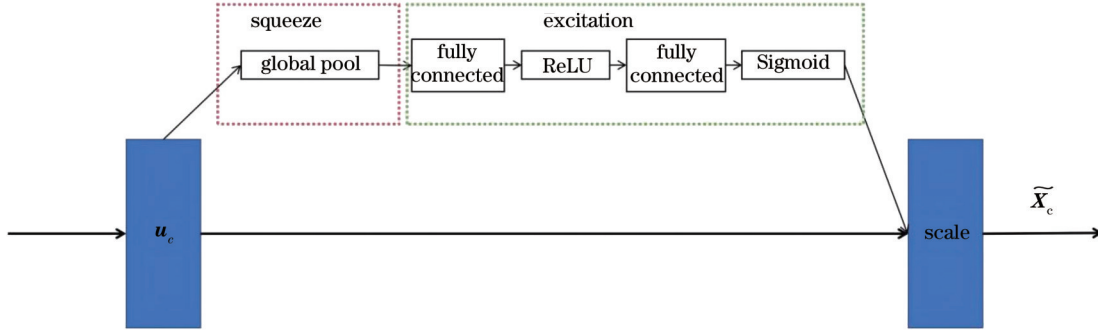


图 3 SENet 中压缩、激励和 scale 模块结构

Fig. 3 Structure of squeeze, excitation, and scale modules in the SENet

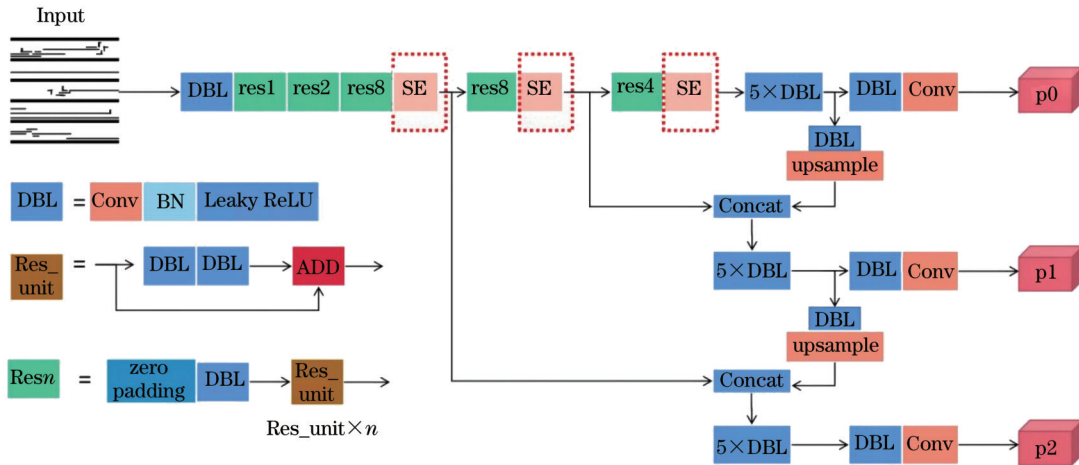


图 4 YOLOv3 改进模型结构

Fig. 4 YOLOv3 improved model structure

### 3.3 预训练

迁移学习已经在大量的实验中被证明是一种有效的模型改进方法。当数据不足时,迁移学习可以获得更好的训练结果,提高训练能力的准确性和模型的鲁棒性。迁移学习是对模型训练的一种推广。深度学习的性能取决于数据的数量。只有基于大量的数据,才能训练出一个性能良好的神经网络模型。如果数据不足,很难对模型进行充分训练,训练后的模型存在严重的过拟合,泛化能力较差<sup>[14]</sup>。

在光刻热点检测数据集中,数据集的数量通常很小。如果使用数据增强来增加数据集的数量,扩增后的数据也依旧比较少。同时若将扩增后的光刻热点数

据直接用于训练热点检测网络,训练收敛速度较慢,性能较差。为加快训练速度,提高模型的性能,可以预训练模型加快网络的收敛速度,减小训练成本。

## 4 模型训练

### 4.1 实验环境

实验配置: CPU 是 6 核 3.6 GHz, GPU 是 NVIDIA GTX 1080Ti, Torch 版本为 1.13.13.1 框架, CUDA 版本是 11.7, 编程语言是 Python 3.8, 操作系统是 Windows 10。

### 4.2 数据集获取

本文的数据集来源于 ICCAD 2012 竞赛,该数据



集的相关参数如表 1 所示,训练集的热点数量(HS)远远小于非热点数量(NHS),如基准 2 中非热点的数量是热点数量的 30 倍,在实际芯片设计中,经过分辨率增强技术处理之后热点数量也是始终远小于非热点数量。不平衡样本会导致训练模型侧重学习非热点图形,这样模型在测试数据上的泛化能力就会受到影响,为此需要对数据进行数据扩增的处理。此外,ICCAD 2012 提供基准 1 到基准 5 的数据,基准 1 技术节点是 32 nm,基准 2 到基准 5 技术节点是 28 nm,为充分验证网络模型的有效性,对同一技术节点的基准 2 到基准 5 数据进行叠加,得到基准 6。

不平衡的数据集会导致热点检测模型更加注重学习非热点,热点检测模型的性能会降低。常见的不平衡数据集的处理方法有多标签学习、多数下采样和伪实例生成等<sup>[11]</sup>,但是由于光的衍射现象和深度学习的本质,这些方法并不能直接使用,例如 Zhang 等<sup>[15]</sup>提出了交叉解耦聚集的多标签学习方法,以平衡每个类别

表 1 ICCAD 2012 数据  
Table 1 Data of ICCAD 2012 dataset

| Name        | Tech / nm | Training dataset |       | Testing dataset |                       |
|-------------|-----------|------------------|-------|-----------------|-----------------------|
|             |           | HS               | NHS   | HS              | Area /nm <sup>2</sup> |
| Benchmark 1 | 32        | 99               | 340   | 226             | 12516                 |
| Benchmark 2 | 28        | 174              | 5285  | 498             | 106954                |
| Benchmark 3 | 28        | 905              | 4642  | 1796            | 122565                |
| Benchmark 4 | 28        | 95               | 4453  | 177             | 82010                 |
| Benchmark 5 | 28        | 26               | 2716  | 41              | 49583                 |
| Benchmark 6 | 28        | 1200             | 17096 | 2512            | 361112                |

中的实例数量。然而,这可能导致单个类别的训练样本不足,因此需要大的训练集来有效地训练深度神经网络。类似地,多数下采样也不能应用于基于深度神经网络的方法。在光刻过程中,考虑到光源的对称性,改变布局图形的方向并不会影响其属性,因此,可以通过翻转原始布局图形对 ICCAD 2012 数据进行扩增。图 5 展示翻转的数据增强方法。

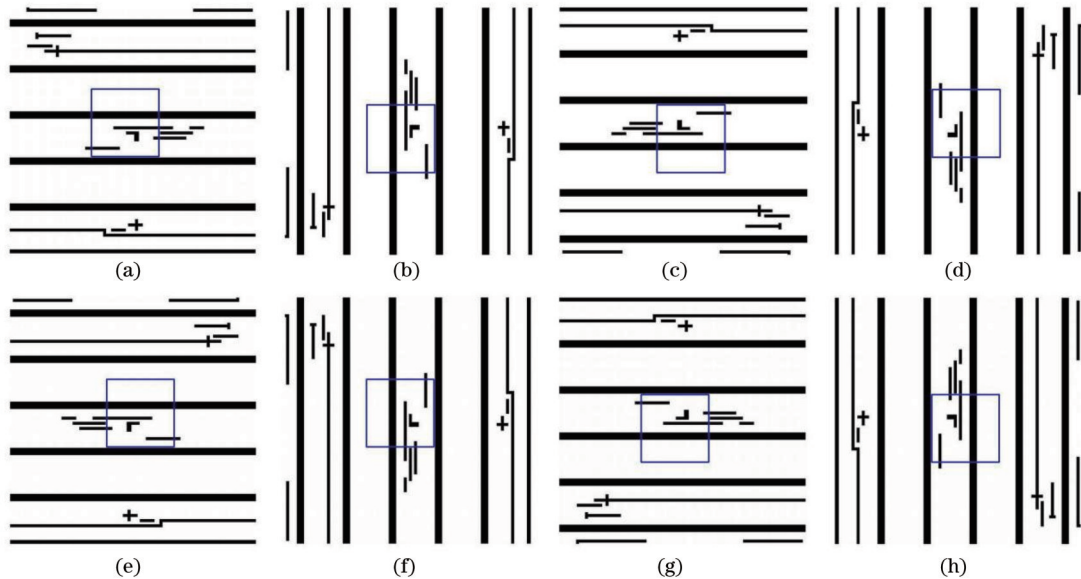


图 5 翻转的数据增强方法  
Fig. 5 Flip of data augmentation method

图 5(a)是原始图像,图 5(b)~(d)是图 5(a)分别逆时针旋转 90°、180°、270°得到的。图 5(e)是图 5(a)水平翻转得来的,图 5(f)~(h)是图 5(e)分别逆时针旋转 90°、180°、270°得到的。对比原始图形的水平翻转、垂直翻转和水平垂直翻转,可以看出,图 5(g)可以看作是通过垂直翻转图 2(a)获得的图像,图 5(c)可以看作是在垂直和水平方向上通过翻转图 5(a)获得的图像。综上所述,本文在原有的基础上增加 4 种数据几何增强方法。

由于 ICCAD 2012 数据集所具有的不平衡性,没有验证集,验证集主要用于验证模型的训练和超参数的设置。因此训练数据集进行扩增后的数据应该分为两个部分:90% 的样本用于训练,10% 的样本用于验

证。最终数据如表 2 所示。其中基准 2 的热点和非热点数量的比例从表 1 的 1:30 减少到表 2 的 1:4,极大地缓解了数据中的不平衡现象。

#### 4.3 评价指标

采用三个评价因素,即召回率(recall)、精确率(precision)和 F1 分数,评估热点检测模型的性能。召回率是评价网络预测真实光刻热点占所有真实热点的比例,精确率是评价网络预测真实光刻热点占预测光刻热点的比例,F1 分数是召回率和精确率的平衡。F1 分数较高,则该模型的鲁棒性较强。它们的表达式分别为

$$R_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (2)$$

表 2 经过数据增强后的数据集  
Table 2 Dataset after data augmentation

| Name        | Tech /nm | Training dataset |       | Validation dataset |      | Testing dataset |                       |
|-------------|----------|------------------|-------|--------------------|------|-----------------|-----------------------|
|             |          | HS               | NHS   | HS                 | NHS  | HS              | Area /nm <sup>2</sup> |
| Benchmark 1 | 32       | 743              | 2579  | 33                 | 141  | 226             | 12516                 |
| Benchmark 2 | 28       | 1251             | 4776  | 141                | 509  | 498             | 106954                |
| Benchmark 3 | 28       | 6421             | 33428 | 728                | 3708 | 1796            | 122565                |
| Benchmark 4 | 28       | 673              | 4013  | 79                 | 440  | 177             | 82010                 |
| Benchmark 5 | 28       | 187              | 2445  | 21                 | 271  | 41              | 49583                 |
| Benchmark 6 | 28       | 8616             | 15378 | 948                | 1718 | 2512            | 361112                |

$$R_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (3)$$

$$F_1 = 2 \times \frac{R_{\text{precision}} \times R_{\text{recall}}}{R_{\text{precision}} + R_{\text{recall}}}, \quad (4)$$

式中:  $N_{\text{TP}}$ (真阳性)表示正确检测到的热点数量;  $N_{\text{FP}}$ (假阳性)表示错误检测到的热点数量;  $N_{\text{FN}}$ (假阴性)表示未检测到的热点数量。

## 5 实验结果

### 5.1 模型训练

使用官方提供的 YOLOv3 的预训练 YOLOv3 模型对基准 1 进行训练,其他训练设置如下:迭代次数设置为 100,批大小设置为 10,图像大小设置为 640 × 640。由于热点图形和其他数据集的类型具有较大差异,基准 2 到基准 6 跟基准 1 的技术节点不同,基于迁移学习的思想,将训练后的基准 1 的权重作为基准 2 到基准 6 训练的初始权重。图 6 是使用两种不同的方法对基准 2 进行训练得到的损失,其中虚线是采用官方预训练权重训练基准 2 的损失曲线,实线是采用经过训练的基准 1 的权重作为初始权重训练基准 2 的损失曲线。通过对比这两条损失函数曲线可以看出:曲线都呈现下降的趋势;从迭代次数 0 到迭代次数 60 的区域,实线的变化趋势比较平稳,虚线从一开始就迅速下降,后面趋于平稳;当迭代次数达 60 时,损失函数曲线

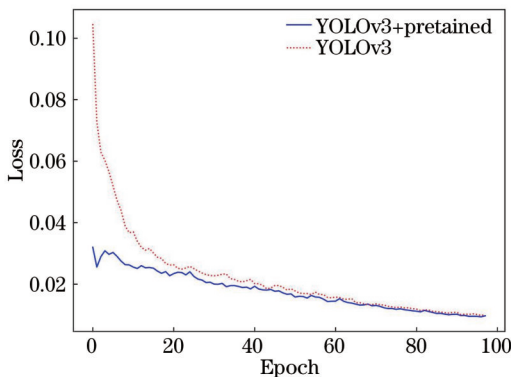


图 6 使用两种不同方法对基准 2 进行训练的损失曲线  
Fig. 6 Loss curves of two different methods to train benchmark 2

趋于平滑且两个损失函数数值十分相近甚至开始交融。这验证了迁移学习方法在光刻热点检测任务中的有效性。因此,在后续网络训练中,对基准 2 到基准 6 的迭代次数设置为 30,降低训练成本。

### 5.2 实验结果分析

网络模型训练完毕,将表 2 中的测试数据集输入到经过训练的网络模型中,得到该网络模型的检测性能。为验证在光刻热点检测任务中应用注意力机制的 SENet 的有效性,对比嵌入 SENet 的检测网络模型和 YOLOv3 模型,在测试中将 IoU 阈值设置为 0.5,置信度阈值设置为 0.8,测试结果如表 3 所示。无论是嵌入 SENet 的检测网络还是 YOLOv3 网络模型,都能够检测出光刻热点,但是在精确率方面,嵌入 SENet 的网络在基准 1、基准 2 和基准 4 上与 YOLOv3 的网络模型的精确率相差不大,但是在基准 3、基准 5 和基准 6 方面,嵌入 SENet 的检测网络的精确率明显大于 YOLOv3 网络模型。在基准 3 和基准 6,嵌入 SENet 的光刻热点检测网络的检测性能比在其他基准的性能低,这是由于为确保检测网络能够将掩模板中的热点检测出来,在检测过程中,没有对热点和非热点的概率进行对比并从中挑选出概率最高的类别,而是在检测过程中只要热点的概率大于置信度阈值 0.8 就算为热点,置信度阈值过低,可能会导致精确率降低,置信度阈值过高,可能会导致召回率的降低。在光刻热点检测任务中,网络模型应该尽可能找出掩模中存在的光刻热点,并尽可能减少将非光刻热点误判为光刻热点的情况<sup>[16]</sup>。这证明带有 SENet 的网络模型能够在光刻热点检测任务中具有较好的检测性能。

为进一步验证所提注意力机制 SENet 在光刻热点检测任务中的有效性,在图 4 中将嵌入的 SENet 注意力机制更改为卷积块注意力模块(CBAM)机制,CBAM 机制是一种混合注意力机制,其中包括空间注意力机制和通道注意力机制。将 CBAM 机制的训练测试设置与 SENet 注意力机制的训练测试设置保持一致。测试结果如表 4 所示,嵌入 CBAM 机制的光刻热点检测网络依旧能够准确地识别出光刻热点,在精确率方面,嵌入 CBAM 的网络模型在基准 1、基准 3、

表 3 实验结果

Table 3 Experimental result

| Name        | Method       | Recall | Rrecision | F1    |
|-------------|--------------|--------|-----------|-------|
| Benchmark 1 | YOLOv3       | 1.00   | 0.97      | 0.98  |
|             | YOLOv3+SENet | 1.00   | 0.98      | 0.99  |
| Benchmark 2 | YOLOv3       | 1.00   | 1.00      | 1.00  |
|             | YOLOv3+SENet | 1.00   | 1.00      | 1.00  |
| Benchmark 3 | YOLOv3       | 1.00   | 0.38      | 0.55  |
|             | YOLOv3+SENet | 1.00   | 0.44      | 0.61  |
| Benchmark 4 | YOLOv3       | 1.00   | 0.98      | 0.99  |
|             | YOLOv3+SENet | 1.00   | 0.97      | 0.98  |
| Benchmark 5 | YOLOv3       | 1.00   | 0.93      | 0.965 |
|             | YOLOv3+SENet | 1.00   | 1.00      | 1.00  |
| Benchmark 6 | YOLOv3       | 1.00   | 0.35      | 0.52  |
|             | YOLOv3+SENet | 1.00   | 0.45      | 0.62  |

基准 5 与嵌入 SENet 的网络模型的性能基本一致,但是在基准 2、基准 4、基准 6,嵌入 CBAM 的检测网络的精确率明显比嵌入 SENet 的检测网络低,认为由于在光刻热点检测任务中非热点和热点的几何特征相似度高,采用空间注意力机制可能无法对热点和非热点的几何特征进行有效学习,如表 4 所示,嵌入 SENet 的光刻热点检测网络的性能明显优于嵌入 CBAM 的光刻热点检测网络的性能。

### 5.3 实验结果对比

为证明所提方法在热点检测任务中的有效性,对所提方法与其他方法进行对比,结果如表 5 所示。Shin 等<sup>[9]</sup>使用了一个基于卷积神经网络的精确热点检

表 4 不同注意力机制的实验结果

Table 4 Experimental result for different attention mechanisms

| Name        | Method       | Recall | Rrecision | F1   |
|-------------|--------------|--------|-----------|------|
| Benchmark 1 | YOLOv3+CBAM  | 1.00   | 1.00      | 1.00 |
|             | YOLOv3+SENet | 1.00   | 0.98      | 0.99 |
| Benchmark 2 | YOLOv3+CBAM  | 1.00   | 0.93      | 0.97 |
|             | YOLOv3+SENet | 1.00   | 1.00      | 1.00 |
| Benchmark 3 | YOLOv3+CBAM  | 1.00   | 0.44      | 0.61 |
|             | YOLOv3+SENet | 1.00   | 0.44      | 0.61 |
| Benchmark 4 | YOLOv3+CBAM  | 1.00   | 0.51      | 0.68 |
|             | YOLOv3+SENet | 1.00   | 0.97      | 0.98 |
| Benchmark 5 | YOLOv3+CBAM  | 1.00   | 1.00      | 1.00 |
|             | YOLOv3+SENet | 1.00   | 1.00      | 1.00 |
| Benchmark 6 | YOLOv3+CBAM  | 1.00   | 0.24      | 0.38 |
|             | YOLOv3+SENet | 1.00   | 0.45      | 0.62 |

测框架。它结合 CNN 强大的分类性能、训练数据增强、候选区域使用和 DBSCAN 聚类来实现光刻热点检测工作。Zhou 等<sup>[14]</sup>针对数据不平衡和布局尺寸大这两个问题,研究深度学习在光刻热点检测中的可行性,并提出了一种用混合数据增强方法(HDEM)来处理数据不平衡的方法,从而弥补热点数据的不足并且采用数据压缩和预训练 GoogLeNet 模型来提高热点检测模型的性能。不同方法的对比结果如表 5 所示。从表 5 可以看出:基于注意力机制 SENet 的 YOLOv3 光刻热点检测网络能够对光刻热点进行有效检测,检测网络在基准 1 到基准 6 的精确率分别为 0.98、1.00、0.44、0.97、1.00、0.45;Zhou 方法进行光刻热点检测

表 5 不同方法的实验结果对比

Table 5 Comparison of experimental results of different methods

| Name        | Method              | Recall | Precision | F1   |
|-------------|---------------------|--------|-----------|------|
| Benchmark 1 | Method in Ref. [9]  | 0.95   | 0.36      | 0.52 |
|             | Method in Ref. [14] | 1.00   | 0.32      | 0.49 |
|             | YOLOv3+SENet        | 1.00   | 0.98      | 0.99 |
| Benchmark 2 | Method in Ref. [9]  | 0.98   | 0.22      | 0.35 |
|             | Method in Ref. [14] | 0.99   | 0.70      | 0.82 |
|             | YOLOv3+SENet        | 1.00   | 1.00      | 1.00 |
| Benchmark 3 | Method in Ref. [9]  | 0.98   | 0.20      | 0.33 |
|             | Method in Ref. [14] | 0.98   | 0.44      | 0.64 |
|             | YOLOv3+SENet        | 1.00   | 0.44      | 0.61 |
| Benchmark 4 | Method in Ref. [9]  | 0.94   | 0.16      | 0.27 |
|             | Method in Ref. [14] | 0.97   | 0.36      | 0.52 |
|             | YOLOv3+SENet        | 1.00   | 0.97      | 0.98 |
| Benchmark 5 | Method in Ref. [9]  | 0.98   | 0.18      | 0.30 |
|             | Method in Ref. [14] | 1.00   | 0.55      | 0.70 |
|             | YOLOv3+SENet        | 1.00   | 1.00      | 1.00 |
| Benchmark 6 | Method in Ref. [9]  | 0.96   | 0.22      | 0.35 |
|             | Method in Ref. [14] | 0.98   | 0.48      | 0.64 |
|             | YOLOv3+SENet        | 1.00   | 0.45      | 0.62 |



时虽然召回率和所提方法相差无几,但是在基准 1 到基准 6 的精确率分别为 0.32、0.70、0.44、0.36、0.55、0.48,精确率普遍比所提方法低;同理,Shin 方法的精确率也普遍比所提方法低。综上所述,所提基于 YOLOv3 的光刻热点检测方法能够很好识别光刻热点,报告的虚假热点数量也相较而言较少,减少了后续

掩模板优化工作。

#### 5.4 热点检测测试示意图

图 7(a)是掩模板版图,将图 7(a)输入到经过训练的网络模型中,网络模型输出结果如图 7(b)所示。从图 7(b)可以看出,模型对图 7(a)的热点标注范围是方框区域,且方框区域的热点概率就是 0.92。




图 7 使用训练后的 YOLOv3 检测光刻热点的结果。(a)原始版图;(b)模型输出图像

Fig. 7 Results of using YOLOv3 after training to detect lithography hotspots. (a) Original mask; (b) output image of the model

## 6 结 论

光刻热点检测是超大规模集成电路物理验证流程中的一个关键步骤。晶圆上的平版印刷容易受到光刻工艺的影响,敏感的版图图形会产生不希望的热点,热点和非热点的几何特征具有极高的相似性,因此在 YOLOv3 网络中嵌入 SENet 注意力机制,能够使得网络模型更加关注热点和非热点特征图中重要的特征通道。利用光刻成像的对称性,通过翻转热点样本来解决数据不平衡问题。在 ICCAD 2012 竞赛中采用基准 1 训练权重作为基准 2 到基准 5 的初始权重,加快网络模型的训练速度,提高模型的性能。测试结果表明,所提方法的平均召回率为 1.00,精确率为 0.45,F1 分数为 0.62,相比其他算法,所提算法进一步提高了对光刻热点的检测能力。

#### 参 考 文 献

- [1] Yang H Y, Lin Y J, Yu B, et al. Lithography hotspot detection: from shallow to deep learning[C]//2017 30th IEEE International System-on-Chip Conference (SOCC), September 5-8, 2017, Munich, Germany. New York: IEEE Press, 2017: 233-238.
- [2] Kim J, Fan M H. Hotspot detection on post-OPC layout using full-chip simulation-based verification tool: a case study with aerial image simulation[J]. Proceedings of SPIE, 2003, 5256: 919-925.
- [3] Roseboom E, Rossman M, Chang F C, et al. Automated full-chip hotspot detection and removal flow for interconnect layers of cell-based designs[J]. Proceedings of SPIE, 2007, 6521: 65210C.
- [4] Yu Y T, Chan Y C, Sinha S, et al. Accurate process-hotspot detection using critical design rule extraction[C]//Proceedings of the 49th Annual Design Automation Conference, June 3-7, 2012, San Francisco, California. New York: ACM Press, 2012: 1167-1172.
- [5] Wen W Y, Li J C, Lin S Y, et al. A fuzzy-matching model with

grid reduction for lithography hotspot detection[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2014, 33(11): 1671-1680.

- [6] 曹葵康, 沈海斌, 杨祎巍. 基于支持向量机及遗传算法的光刻热点检测[J]. 浙江大学学报(理学版), 2011, 38(1): 41-45.  
Cao K K, Shen H B, Yang Y W. Lithographic hotspot detection based on SVM and genetic algorithm[J]. Journal of Zhejiang University (Science Edition), 2011, 38(1): 41-45.
- [7] Ding D, Torres J A, Pan D Z. High performance lithography hotspot detection with successively refined pattern identifications and machine learning[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2011, 30(11): 1621-1634.
- [8] 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.
- [9] Shin M, Lee J H. Accurate lithography hotspot detection using deep convolutional neural networks[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2016, 15(4): 043507.
- [10] Matsunawa T, Nojima S, Kotani T. Automatic layout feature extraction for lithography hotspot detection based on deep neural network[J]. Proceedings of SPIE, 2016, 9781: 97810H.
- [11] Yang H Y, Luo L Y, Su J, et al. Imbalance aware lithography hotspot detection: a deep learning approach[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2017, 16(3): 033504.
- [12] Xiao Y D, Huang X Q, Liu K. Model transferability from ImageNet to lithography hotspot detection[J]. Journal of Electronic Testing, 2021, 37(1): 141-149.
- [13] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [14] Zhou K B, Zhang K F, Liu J, 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.
- [15] Zhang M L, Li Y K, Yang H, et al. Towards class-imbalance aware multi-label learning[J]. IEEE Transactions on Cybernetics, 2022, 52(6): 4459-4471.

- [16] 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.

## Lithography Hotspot Detection Based on Improved YOLOv3

Lin Mu, Zeng Fanwenqing, Liu Xiaoxuan, Li Fencheng, Luo Jun, Shen Yijiang\*  
*School of Automation, Guangdong University of Technology, Guangzhou 510006, Guangdong, China*

### Abstract

**Objective** The ever-shrinking feature size of integrated circuits aggravates the subwavelength lithography gap, causing unwanted shape deformations of printed layout patterns. Although various resolution enhancement techniques (RETs) used to improve wafer printability are used to improve the imaging fidelity, certain layout regions may still be susceptible to the lithography process with pinching and bridging hotspots that may produce open or short circuits. Therefore, the identification of lithography hotspots is particularly important in physical verification. In this study, we propose a hotspot detection method to improve the precision and recall of pinching- and bridging-type areas by embedding squeeze-and-excitation networks (SENet) into a pretrained YOLOv3 model. We also address hotspot and non-hotspot data imbalances by data augmentation from a lithographic perspective. Experimental results on the 2012 International Conference on Computer-Aided Design (ICCAD 2012) dataset verify the merits of the proposed deep learning-based network.

**Methods** YOLOv3 uses a single network to generate candidate regions within which the locations and classifications of objects are detected and identified. The training of YOLOv3 is more effective with a single network structure. SENet is an attention mechanism that focuses on the channel features. SENet provides information regarding the importance of each channel in the feature map, enabling the network to focus on important channels while suppressing less important channels. To better distinguish lithographic hotspots from non-hotspots, SENet was embedded in the YOLOv3 network architecture to improve the representation ability between different channels in the feature map. The structure of the improved YOLOv3 is shown in Fig. 4, where SENet is enclosed in the dotted box. Imbalanced datasets cause the network to focus more on learning the features of non-hotspots, thereby reducing the performance of hotspot detection. Considering the symmetry and light source in the lithography process, a change in the direction of the layout pattern does not alter its properties, and the number of layout patterns can be increased by flipping the original layout pattern. Fig. 5 shows the flipping data augmentation method.

**Results and Discussions** In this study, the effectiveness of the lithographic hotspot detection task was verified by comparing the improved and the original YOLOv3 structures. In the experiments, the intersection over union threshold is set to 0.5, and the confidence threshold is set to 0.8. The experimental results are presented in Table 3. Although both the improved and original YOLOv3 networks show similar detection capabilities, the accuracy of the improved YOLOv3 is not significantly different from that of the original YOLOv3 on benchmarks 1, 2, and 4, and the accuracy of the improved YOLOv3 is significantly greater than that of the original YOLOv3 on benchmarks 3, 5, and 6. To verify the effectiveness of the SENet proposed in this study in the lithographic hotspot detection task, a reference attention mechanism, convolutional block attention module (CBAM), was also tested by replacing the SENet in the dotted box of Fig. 4. CBAM is an attention mechanism that includes both spatial and channel attention mechanisms. The training and test settings of the CBAM detection network are consistent with those of the SENet detection network. The test results are listed in Table 4. The lithographic hotspot detection network embedded with the CBAM can accurately identify hotspots. In terms of accuracy, the performance of YOLOv3 embedded with the CBAM is the same as that of YOLOv3 embedded with the SENet on benchmarks 1, 3, and 5. For the other benchmarks, the accuracy of YOLOv3 embedded with the CBAM is significantly lower than that of YOLOv3 embedded with the SENet. According to this analysis, the proposed method, in which YOLOv3 is embedded with the SENet, outperforms the CBAM and the prevailing methods in the literature.

**Conclusions** Lithographic hotspot detection is a key step in the physical verification process of very large-scale integration circuit (VLSI). The pattern on the wafer is easily affected by lithographic printing, and a sensitive layout pattern produces unwanted hotspots. The geometries of hotspots and non-hotspots are extremely similar, exacerbating



overfitting in deep learning-based approaches. In this study, embedding the SENet in the YOLOv3 network can focus the network on important channels in hotspot and non-hotspot feature maps. By taking advantage of the symmetry of lithography imaging, the problem of data imbalance can be addressed by flipping the hotspot samples. In the ICCAD 2012 dataset, benchmark 1 was pretrained, whose training parameters were used as the initial weights of benchmarks 2 to 6 to accelerate the training speed and improve the performance of the network. The test results show that the average recall of the proposed method is 1.00, accuracy is 0.45, and F1 score is 0.62. Compared with the prevailing methods in the literature, the proposed deep learning network with the SENet improves the detection performance of lithographic hotspots.

**Key words** lithography; hotspot; deep learning; YOLOv3; squeeze and excitation network