

## 基于改进 Ghost 的半监督光刻热点检测方法

肖鑫忠, 马瑞君, 徐辉, 黄文馨, 袁野

安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001

**摘要:**目的 鉴于传统的半监督光刻热点检测方法逐渐无法满足集成电路制造对检测精度的要求,且难以解决因数据集不平衡引起的精度损失问题,提出一种新的半监督光刻热点检测模型 GSSL。方法 在该模型中,将卷积注意力模块(Convolutional Block Attention Module, CBAM)引入到 Ghost 模块的线性变化中,设计了 Ghost\_CBAM 模块;将该模块与压缩激励网络(Squeeze-and-Excitation, SE)结合设计了 GhostNeck 模块,实现特征图先降维再升维,建立各个通道之间的关联性;再通过 GhostNeck 构建整个光刻热点检测模型 GSSL,实现逐步引入无标记数据进入训练的半监督学习方式;通过集成数据增强方法对数据集中的热点版图进行数据增强,缓解数据不平衡问题;并应用加权交叉熵损失函数,进一步提升模型对于热点类别的关注度。结果 在 ICCAD(The International Conference on Computer-Aided Design) 2012 竞赛基准数据集上进行评估,在标记数据占比为 10%~50%的情况下预测热点的平均准确率为 91.73%,平均误报为 680。结论 与其他传统方法相比,GSSL 可以有效应对数据集不平衡的问题,提升光刻热点检测精度的同时,显著降低了误报率,在光刻热点检测上具有一定的应用价值。

**关键词:**光刻热点检测;集成电路;半监督学习;改进 Ghost 模块

**中图分类号:**TN406 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0002.014

### Semi-supervised Lithography Hotspot Detection Based on Improved Ghost

XIAO Xinzong, MA Ruijun, XU Hui, HUANG Wenxin, YUAN Ye

School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

**Abstract: Objective** Given that traditional semi-supervised lithography hotspot detection methods are gradually unable to meet the precision requirements for integrated circuit manufacturing and has difficulty addressing accuracy loss caused by dataset imbalance, a new semi-supervised lithography hotspot detection model, GSSL, is proposed. **Methods** In this model, the Ghost\_CBAM was designed by introducing the convolutional block attention module (CBAM) into the linear change of the Ghost module. The GhostNeck module was designed by combining the Ghost\_CBAM module with the squeeze-and-excitation (SE) network, which enabled dimensionality reduction followed by dimensionality expansion of feature maps and established correlations between channels. Then, the whole lithography hotspot detection model, GSSL, was constructed by GhostNeck to realize the semi-supervised learning method of gradually introducing unlabeled data into the training. Data augmentation methods were integrated to augment hotspot layouts in the dataset to alleviate dataset imbalance. Besides, a weighted cross-entropy loss function was applied to further improve the model's focus on hotspot categories. **Results** The model was evaluated on the benchmark dataset of the 2012 International Conference on Computer-Aided Design (ICCAD) competition, achieving an average accuracy of 91.73% and an average false alarm of 680 when the proportion of labeled data ranged from 10% to 50%. **Conclusion** Compared with other traditional methods,

收稿日期:2024-03-05 修回日期:2024-05-18 文章编号:1672-058X(2026)02-0108-08

作者简介:肖鑫忠(1988—),男,安徽六安人,硕士研究生,从事集成电路可制造性研究。

通信作者:徐辉(1979—),男,安徽淮南人,教授,博士,从事集成电路可制造性设计与辐射加固设计研究。Email:austxuhui@163.com。

引用格式:肖鑫忠,马瑞君,徐辉,等.基于改进 Ghost 的半监督光刻热点检测方法[J].重庆工商大学学报(自然科学版),2026,43(2):108-115.

XIAO Xinzong, MA Ruijun, XU Hui, et al. Semi-supervised lithography hotspot detection based on improved Ghost[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 108-115.

GSSL adeptly tackles the challenge of imbalanced datasets, improving accuracy in lithography hotspot detection while significantly reducing false alarms. Therefore, this study holds considerable application value in lithography hotspot detection.

**Keywords:** lithography hotspot detection; integrated circuit; semi-supervised learning; improved Ghost module

随着集成电路(Integrated Circuit, IC)工艺节点的持续减小,光刻版图中纳米结构的关键尺寸已达到照明光波长以下,由于光的衍射效应,曝光系统无法对掩模版图进行理想成像,导致硅片上曝光图形失真的现象被称为光学邻近效应<sup>[1]</sup>(Optical Proximity Effect, OPE)。为解决上述问题,业界通常采用一系列分辨增强技术,如光学邻近校正<sup>[2]</sup>(Optical Proximity Correction, OPC),通过优化光刻工艺和掩模设计,以补偿光学邻近效应。然而,即使经过 OPC 掩模优化,版图中仍可能存在出现短路或开路等缺陷的区域,称之为光刻热点。光刻热点是晶圆缺陷中最容易导致集成电路芯片可靠性降低的原因之一。因此,光刻热点检测是确保芯片性能的关键步骤之一。

传统光刻热点检测方法主要包括基于光刻模拟的热点检测方法<sup>[3]</sup>、基于模式匹配的热点检测方法<sup>[4]</sup>与基于机器学习的热点检测方法<sup>[5-6]</sup>。这些方法都受到时间和计算资源消耗等方面的限制。为应对上述传统方法的局限性,基于深度学习的光刻热点检测技术<sup>[7-10]</sup>应运而生。Wu 等<sup>[1]</sup>将 YOLOv5s 网络模型引入光刻热点检测任务,并通过坐标注意力机制、SiLU 激活函数和 SiLU 损失函数对 YOLOv5s 网络进行改进,与传统的基于机器学习的方法相比,检测精度显著提升。Yang 等<sup>[9]</sup>探索了卷积神经网络相关的超参数对光刻热点检测任务的影响,并通过采样技术来解决数据集不平衡的问题。Jiang 等<sup>[10]</sup>将布局版图简化为二值图像,并采用二值化神经网络提高检测效率。

上述方法虽然对光刻热点的检测结果起到了一定的改善作用,但是仍然存在一些不足:(1)传统方法只能检测已知热点,并且需要大量的时间与计算资源;(2)基于机器学习的方法需要对版图数据手动提取特征,操作过程比较烦琐,效率低;(3)基于深度学习的方法在能够获取大量可用的标记数据的前提下,通过充分利用这些数据来训练模型,可以有效提高光刻热点检测的准确性。然而,对于新技术节点,标记数据样本的数量逐渐受到限制,而无标记数据样本则相对容易获取<sup>[11]</sup>。监督学习只能利用标记数据来训练模型,而使用数量不足的标记数据来训练模型会导致模型检测性能显著下降,从而影响光刻热点检测的准确性。

针对上述问题,本研究提出了基于改进 Ghost 与集成数据增强的半监督光刻热点检测模型(Ghost Semisupervised Self-Paced Learning, GSSL)。该方法将

卷积注意力<sup>[12]</sup>融入 Ghost 模块的线性变化中,自适应地调整特征图的通道和空间维度上的重要性,对每个通道和空间位置进行加权,提高了模型对特征的辨别能力和表达能力。将由改进 Ghost 模块构成的 GhostNeck 网络与 SE 模块进行叠加,构建自步多任务学习的网络架构,实现逐步引入高置信度的无标记数据进入训练,提高了在标记数据不足情况下光刻热点检测的准确性。在镜像翻转的基础上,通过在版图中引入高斯噪声和版图平移技术对热点版图进行增强,利用集成数据增强方法(Integrated Data Augmentation, IDA)与加权交叉熵损失函数进一步缓解了数据不平衡问题。在 ICCAD 2012 数据集上进行了实验,结果表明:GSSL 在更低的误报水平下实现了更高的检测精度。

## 1 系统结构设计

### 1.1 改进 Ghost 模块结构

传统的卷积神经网络通常需要大量的参数和浮点运算(FLOPs)才能达到更优的精度,例如 ResNet-50<sup>[13]</sup>大约有 2500 万个参数。在训练良好的深度神经网络中,每一层网络所捕获的冗余特征信息通常有助于确保网络更全面地理解输入数据。Ghost 模块<sup>[14]</sup>通过简单的线性操作生成更多的特征图,可以显著减少网络的参数数量和计算复杂度。

通过在 Ghost 模块中引入 CBAM 注意力机制得到 Ghost\_CBAM 模块,该模块分别应用了通道注意力和空间注意力。通道注意力的输入是一个形状为  $H \times W \times C$  的特征图,对该特征图执行平均池化和最大池化得到两个大小为  $1 \times 1 \times C$  的特征张量,再经过一个两层的网络,得到的两个特征相加后经过一个 Sigmoid 激活函数得到权重系数  $M$ ,最后将权重系数  $M$  和原来的特征  $F$  相乘即可得到新特征<sup>[15]</sup>。空间注意力同样经过类似操作得到权重系数  $M'$ 。最后,将权重系数  $M'$  和特征  $F'$  相乘即可得到新特征。该模块能够自适应地调整特征图在通道和空间维度上的重要性,从而增强了模型的表征能力。通过对每个通道和空间位置进行加权,CBAM 模块可以使网络更加关注重要的特征信息,提高了对特征的辨别能力和表达能力。

Ghost\_CBAM 模块结构如图 1 所示,输入数据  $X \in R^{c \times h \times m}$ ,对  $X$  应用较小的卷积核  $f' \in R^{c' \times k \times k \times m}$  得到原始特征图  $Y'$ ,其计算过程如式(1)所示:

$$Y' = X \otimes f' \quad (1)$$

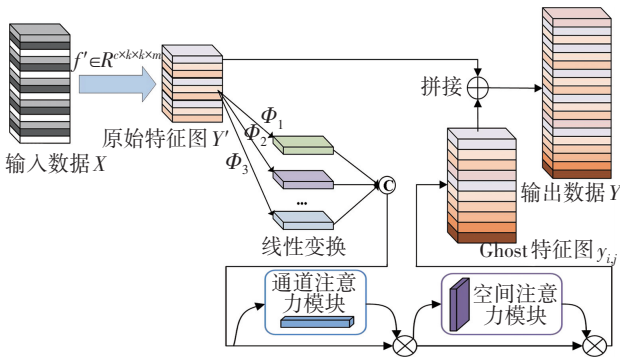


图 1 Ghost\_CBAM 模块结构图

Fig. 1 Structure diagram of Ghost\_CBAM module

最终输出的特征图  $Y$  是由原始特征图  $Y'$  经过一系列简单的线性变换  $\phi$  和 CBAM 模块得到的特征图与其经过恒等映射得到的特征图进行拼接 (Concat) 得到的, 其计算过程如式 (2) 所示:

$$y_{i,j} = \text{CBAM}(\phi_{i,j}(y'_i)), \forall i = 1, 2, \dots, m \quad (2)$$

$$j = 1, 2, \dots, m$$

式 (2) 中,  $y'_i$  是原始特征图  $Y'$  中第  $i$  个特征图,  $\phi_{i,j}$  是第  $j$  个线性运算, 用于生成第  $j$  个 Ghost 特征图, 最终的输出  $Y$  由  $y_{i,j}$  与  $Y'$  在通道维度上进行拼接得到。

在上述操作中, Ghost 模块中的原始特征图在简单的线性操作后, 经过 CBAM 模块以实现对不同通道特征图的赋权重的操作。这里简单的线性操作是对每个特征图执行相比于普通卷积所需参数量更小的深度可分离卷积。

### 1.2 GhostNeck 模块结构

由改进后的 Ghost 模块构成的新的颈部网络 GhostNeck, 其结构如图 2 所示。GhostNeck 类似于 Resnet 中的残差模块, 其中集成了数个卷积层和跳跃连接通路。本文使用的 GhostNeck 将经过  $1 \times 1$  普通卷积进行通道调整的数据输入到两个改进后的 Ghost\_CBAM 模块。第一个模块的作用是充当扩展层, 用以增加通道数量, 可以生成更多的特征图, 提高模型的代表能力; 第二个模块的作用是将上述操作生成的特征图通道数减少到与前一个模块的输入特征图通道数相一致, 以便实现跳跃连接的需求。

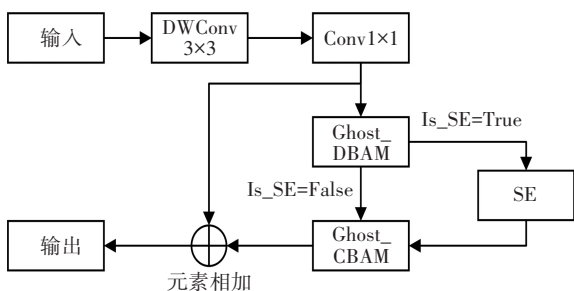


图 2 GhostNeck 模块结构图

Fig. 2 Structure diagram of GhostNeck module

在两个 Ghost 模块之间利用如图 3 所示的 SE 模块<sup>[16]</sup>建立了各个通道之间的关联性, 之后通过对不同通道特征的不同响应完成自适应的校准后, 以此加强重要通道的权重, 降低不重要通道的权重, 提升网络的性能。在 SE 模块中, 先将特征图进行全局平均池化, 然后经过两个全连接层, 第一个全连接层的输出通道数是原输入的  $1/4$ , 并执行 ReLU 激活, 第二个全连接层的输出通道数等于原输入的通道数, 并执行 Sigmoid 激活, 实现先降维再升维。最后将全连接层的输出看作是对应通道的权重, 与原特征图相乘即可得到新的特征图数据。在 GhostNeck 网络中, 通过参数  $Is\_SE$  决定是否使用 SE 模块。最后将经过两个 Ghost\_CBAM 模块的输出与经过  $1 \times 1$  普通卷积进行通道调整之后的输出进行元素级的相加得到整个 GhostNeck 网络的输出。




图 3 SE 模块结构图

Fig. 3 Structure diagram of SE module

### 1.3 分类聚类联合多任务网络 GSSL

本研究提出的基于半监督学习的光刻热点检测方法采用的是 Chen 等<sup>[17]</sup>提出的一个联合多任务的网络结构 SPL 作为基础框架, 通过联合学习的分类和聚类模型缓解伪标签分配错误问题。网络的结构如图 4 所示, 该方法分为两个阶段, 第一阶段是数据处理阶段, 将大小为  $1\ 200 \times 1\ 200$  像素的初始版图进行集成数据增强, 增加数据集中的热点样本的数量, 再将增强后的版图数据经过离散余弦变换<sup>[18]</sup> (Discrete Cosine Transform, DCT) 技术进行处理, 得到压缩后大小为  $12 \times 12 \times 32$  的特征数据; 第二阶段是网络训练与测试阶段。该网络有两个分支, 分别是执行分类任务的分类流与提供伪标签置信度的聚类流, 这两个分支网络共享特征提取层。特征提取层主要由两个 GhostNeck 网络、BatchNorm 批归一化层与 Maxpool 最大池化层组成, 分类流与聚类流有相同的网络结构, 同样由两个 GhostNeck 网络、BatchNorm 批归一化层与 Maxpool 最大池化层组成, 最后将输出的特征图传入到具有 250 个神经元的全连接层 (Fully Connected, FC) 中增加模型的非线性能力, 再经过 2 个神经元的 FC 进行输出。其中分类任务主要

包括前期通过部分标记数据训练模型后,再对无标记数据进行伪标签的预测任务以及最终的分类任务。聚类任务通过对无标记数据与分类流预测的伪标签计算置信度,通过置信度对无标记数据进行排序,选择置信度高的样本进入下一轮训练。

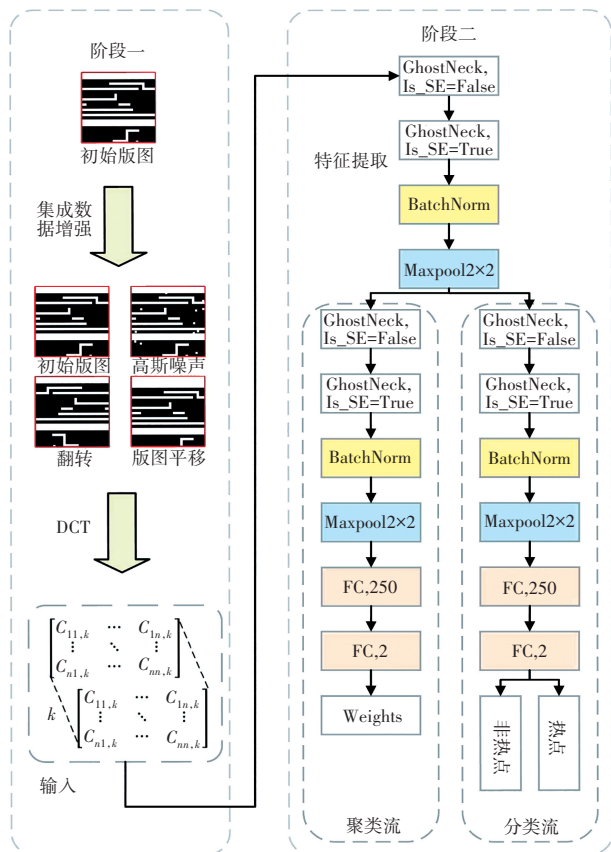


图 4 GSSL 网络结构图

Fig. 4 Structure diagram of GSSL module

分类流是一个执行普通二进制任务的分类网络,采用加权交叉熵损失( $W_{loss}$ )作为训练的损失函数,该函数的权重  $w_i^2$  由训练数据集中光刻热点与非热点的数量进行计算,使得模型更加关注数量相对较少的热点类别。加权交叉熵损失函数的引入有效地缓解了由数据集类别不平衡带来的影响,其计算过程如式(3)所示:

$$L_{class} = - \sum_{i=1}^N w_i^1 \left( \sum_{k=1}^K w_i^2 y_i^k \log \hat{y}_i^k \right) \quad (3)$$

式(3)中, $N$  是输入的样本总数, $K$  是训练数据的类别数量,在光刻热点检测任务中  $K=2$ 。 $y_i$  和  $\hat{y}_i$  分别是第  $i$  个样本的真实标签和模型输出的独热编码。 $w_i^1$  是第  $i$  个样本的置信度,其中标记样本的置信度为 1,未标记样本的置信度由聚类流提供。 $w_i^2$  是加权交叉熵损失中的权重,该参数是一个包含两个元素的张量,第一个元素是热点样本的权重,第二个元素是非热点样本的权

重。假设训练数据中热点样本与非热点样本的数量分别是  $a$  和  $b$ ,那么  $w_i^2 = [b/(a+b), a/(a+b)]$ 。

聚类流的主要目标是根据标记样本簇与预测标签之间的距离来确定每个未标记样本的权重。该距离由 Kullback-Leibler (KL) 散度<sup>[19]</sup> 获取,这是一种衡量两个概率分布相似性的指标,两种分布之间的差异越大,KL 散度越大,即相似性越小。聚类流的输出 Weights 是针对分类流预测伪标签的置信度,即权重矩阵。与对应类别的标记样本簇更接近的未标记样本的伪标签具有更高的置信度。因此,对于第  $i$  个样本,其置信度是通过其自身到同一类别的簇中其他样本的平均 KL 散度来衡量的。相关参数与损失函数设置与 SPL 相同,根据聚类流输出的样本权重对未标记样本进行排序,选择一定数量的置信度较高的未标记样本与原始的标记样本一起进入下一轮训练,从而实现逐步引入无标记数据进入训练的策略。

#### 1.4 集成数据增强方法 IDA

本研究以 ICCAD 2012 竞赛版图基准<sup>[20]</sup> 为初始版图,该数据集不同基准统计如表 1 所示。包含 18 739 个训练用例,146 277 个测试用例,使用包含大量样本的数据集训练的模型可以更早、更准确地检测出光刻过程中的潜在热点,预防生产中的缺陷,提升整体生产效率 and 优良率。在训练集中,热点样本的数量远少于非热点样本的数量,以基准 2 为例,热点和非热点数量的比值达到了 1 : 30。为了避免不平衡的数据样本对模型的训练产生影响,导致模型泛化能力不高,因此需要对初始版图进行数据增强。

表 1 ICCAD 2012 基准数据集统计

Table 1 ICCAD 2012 benchmark dataset statistics

名称	工艺/nm	比例	训练集		测试集	
			热点 /个	非热点 /个	热点 /个	非热点 /个
基准 1	32	3	99	340	226	4 679
基准 2	28	30	174	5 285	498	41 298
基准 3	28	5	909	4 643	1 808	46 333
基准 4	28	47	95	4 452	177	31 890
基准 5	28	105	26	2 716	41	19 327

本研究所采用的集成数据增强方法包括,先对初始版图进行镜像翻转,再分别对原始版图和翻转后的版图同时进行版图平移操作和引入高斯噪声操作(图 5)。

采用的版图平移技术会对图像的边缘进行扩展,

以防止图像特征产生畸变,效果如图 5(b)所示。通过距离比<sup>[21]</sup>( $R_{\text{distance}}$ )控制平移的距离,采用的版图平移的距离比控制在 20%以内进行随机,避免热点位置偏离布局图像中心过多而导致标签的变化,其计算公式如式(4)所示:

$$R_{\text{distance}} = \frac{\Delta L}{L} \quad (4)$$

式(4)中, $\Delta L$ 是平移的距离, $L$ 是图像的宽或高。

此外,向原始布局图像中添加一定噪声比( $R_{\text{noise}}$ )的随机噪声像素<sup>[21]</sup>,同时保持图像标签不变,效果如图 5(c)所示,同样为了避免添加像素过多导致图像特征产生畸变而引起图像标签的变化,采用的噪声比控制在 5%以内进行随机,其计算公式如式(5)所示:

$$R_{\text{noise}} = \frac{P_{\text{noise}}}{P_{\text{image}}} \quad (5)$$

式(5)中, $P_{\text{noise}}$ 表示添加的像素数量, $P_{\text{image}}$ 表示初始版图的像素数量。




图 5 集成数据增强示意图

Fig. 5 Diagram of integrated data augmentation

## 2 仿真实验与结果分析

### 2.1 实验环境及模型超参数

实验配置:CPU 为 8 核 3.2GHz, GPU 为 NVIDIA RTX 3060, Tensorflow 版本为 2.4.0, CUDA 版本为 11.4, 编程语言为 Python3.8, 操作系统为 Windows 11。模型超参数配置如表 2 所示。

表 2 模型超参数配置

Table 2 Configuration of model hyperparameters

Training configurations	Value
Optimizer	Adam
Initial learning rate	0.001
Learning rate decay	0.65
Learning rate decay step	3200
Batch size	32
Dropout ratio	0.5
Training round	4

### 2.2 数据集的建立

为验证所提方法的有效性,以 ICCAD 2012 竞赛版

图基准为初始版图。虽然认识到 ICCAD 2012 竞赛数据集有着固有局限性,但本文使用它有两个主要原因。首先,ICCAD 2019 数据集的商业价值限制了直接访问,使其不适合本研究。其次,考虑到本文对比的传统半监督光刻热点检测方法完全依赖于 ICCAD 2012 数据集,因此选择不合并该数据集的多个基准,以确保更细致地比较实验结果。

本研究采用 IDA 方法对初始版图进行增强,得到的增强数据如表 3 所示。通过该方法,基准 2 和基准 5 的热点和非热点的数量之比分别从 1:30 和 1:105 调整到 1:5 和 1:17,显著缓解了数据集中的不平衡问题;相比较于基准 2、基准 4 和基准 5,基准 3 仅出现轻微的不平衡问题,因此并没有对基准 3 进行数据增强。此外,考虑到基准 1 的技术节点为 32 nm,而基准 2 至基准 5 的技术节点为 28 nm,因此本研究仅对基准 2 到基准 5 进行实验。最后,对上述方法得到的增强数据应用 DCT 方法进行特征提取得到最终的模型输入数据。

表 3 经过集成数据增强后的数据集统计  
Table 3 Statistics of dataset after integrated data augmentation

名称	工艺 /nm	比例	训练集		测试集	
			热点/个	非热点/个	热点/个	非热点/个
基准 2	28	5	1 044	5 285	498	41 298
基准 3	28	5	909	4 643	1 808	46 333
基准 4	28	8	570	4 452	177	31 890
基准 5	28	17	156	2 716	41	19 327

### 2.3 评价指标

光刻热点检测问题的混淆矩阵如表 4 所示, $T_P$ ( $F_N$ )是把真实热点预测为热点(非热点)的情况, $T_N$ ( $F_P$ )是把真实非热点预测为非热点(热点)的情况。

表 4 光刻热点检测问题混淆矩阵

Table 4 The confusion matrix of lithography hotspot detection problem

预测值	真实值	
	非热点	热点
非热点	$T_N$	$F_N$
热点	$F_P$	$T_P$

采用两个评价指标,准确率(Accuracy,  $\sigma_{\text{Acc}}$ )和误报(False alarms,  $\sigma_{\text{FA}}$ ),评估热点检测器性能。准确率

是正确预测热点的数量与实际热点数量的比值,误报是模型错误预测为热点的非热点数量,在更低误报的情况下实现更高的准确率表示该模型具有更强的检测性能。它们的计算公式分别如式(6)、式(7)所示:

$$\sigma_{Acc} = \frac{\sum T_p}{\sum (T_p + F_N)} \quad (6)$$

$$\sigma_{FA} = \sum F_p \quad (7)$$

### 2.4 对比实验

本研究对所提出的方法与 3 种传统的半监督光刻热点检测方法进行了性能比较。这 3 种热点检测方法分别是“DAC”代表 Yang 等<sup>[18]</sup>提出的基于 DCT 和偏置学习的光刻热点检测方法,“SSL”和“ISSL”分别代表 Chen 等<sup>[17]</sup>提出的基于自步多任务学习 SPL 的半监督光刻热点检测方法以及一种基于不平衡感知算法 ISPL

的半监督光刻热点检测方法,“GSSL”代表本研究提出的基于改进 Ghost 与集成数据增强的半监督光刻热点检测算法。

表 5 展示了所提方法与 3 种对比方法在标记数据占比为{0.1, 0.3, 0.5, 0.7, 0.9, 1.0}的情况下模型在测试集上的实验结果。所提方法在检测准确率和误报方面表现出明显的优势。具体而言,在数据集类别极度不平衡的基准 2、基准 4 和基准 5 上实现了更高的检测精度和更低的误报,证明了集成数据增强方法的有效性。特别地,在基准 3 中本研究在实现了与“ISSL”方法相似的检测精度的情况下实现了更低的误报。与上述 3 种传统的基于半监督学习的光刻热点检测方法相比,以标记数据比例为 0.1 为例,本文提出的检测方法在准确率方面分别提升了 28.7、20.5 和 17.7 个百分点,误报分别提升了 42.1、58.7、24.6 个百分点。

表 5 不同方法实验结果对比

Table 5 Comparison of experimental results of different methods

名称	比例 方法	0.1		0.3		0.5		0.7		0.9		1.0	
		$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$
基准 2	DAC	89.44	700	93.33	383	96.51	297	97.11	294	97.79	287	97.19	239
	SSL	97.99	1 643	98.11	643	97.67	425	97.87	265	97.51	211	97.75	231
	ISSL	96.91	968	96.95	305	97.99	307	97.51	227	97.47	212	97.79	207
	GSSL	99.40	722	98.40	293	99.00	197	98.60	182	98.20	209	98.80	166
基准 3	DAC	97.94	4 288	98.34	3 569	98.04	3 098	98.17	3 001	98.22	2 780	98.22	2 878
	SSL	98.47	5 130	98.43	3 593	98.26	3 083	98.15	2 740	98.24	2 665	98.27	2 854
	ISSL	97.77	2 524	97.83	2 345	97.83	2 513	97.95	2 701	98.25	2 618	98.16	2 938
	GSSL	98.22	1 726	98.55	1 983	98.64	1 924	98.82	1 930	98.60	2 034	98.66	2 318
基准 4	DAC	35.14	230	65.99	315	78.19	359	77.85	261	90.73	387	91.75	309
	SSL	52.66	536	73.45	342	81.69	379	84.29	261	88.81	317	90.62	306
	ISSL	54.35	454	72.54	282	81.69	309	81.24	256	82.82	272	89.60	343
	GSSL	80.65	530	90.32	315	88.71	303	93.55	239	96.77	249	96.24	294
基准 5	DAC	8.29	3	27.32	39	75.12	86	90.73	72	93.66	79	95.61	90
	SSL	14.63	11	40.00	73	84.88	104	96.59	141	94.71	100	95.12	94
	ISSL	25.85	59	40.49	43	88.29	107	93.17	97	95.12	75	93.17	87
	GSSL	67.44	43	90.70	66	90.70	60	97.67	70	97.67	38	97.67	43
平均	DAC	57.70	1 305	71.24	1 076	86.97	960	90.97	907	95.10	883	95.69	879
	SSL	65.94	1 830	77.50	1 163	90.63	998	94.23	852	94.82	823	95.44	871
	ISSL	68.72	1 001	76.95	744	91.45	809	92.47	820	93.42	794	94.68	894
	GSSL	86.43	755	94.49	664	94.26	621	97.16	605	97.81	633	97.84	705

### 2.5 消融实验

为了进一步验证 GSSL 方法中 3 个模块的有效性,

设计了 6 种针对这些模块的消融实验,实验结果如表 6 所示。

表 6 消融实验结果  
Table 6 Results of ablation experiments

方 法				比 例					
				0.1		0.5		1	
SPL	IDA	Ghost_CBAM	Wloss	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$	$\sigma_{Acc}(\%)$	$\sigma_{FA}$
✓				96.91	968	97.99	307	97.79	207
✓	✓			98.01	701	98.40	578	97.41	235
✓		✓		98.00	750	98.80	234	97.80	171
✓			✓	94.21	417	96.81	97	95.21	169
✓		✓	✓	97.60	760	98.00	204	98.00	137
✓	✓	✓	✓	99.40	722	99.00	197	98.80	166

在标记数据占比为 0.1 时,IDA 方法将初始模型的准确率和误报分别提升了 1.1% 和 27.6%,但是随着标记数据占比的提高,IDA 数据增强的效果逐渐减弱,这是由于标记数据占比较低时,标记数据内部的热点数量远远少于非热点数量,使数据不平衡问题更加严重,IDA 数据增强通过增加热点的数量,显著缓解了这一问题,使得模型在首轮训练中充分利用标记数据学习热点的特征,从而改善了模型在标记数据不足时性能较差的情况。Ghost\_CBAM 的应用在实现与初始模型相似的检测精度的同时,将不同标记数据占比下的误报平均降低了 21.2%,减少了模型错误地将非热点误判为热点的情况,从而提高了模型的准确性和可靠性。Wloss 损失函数的应用虽然将模型的检测精度平均降低了 2.2%,但是该模块同样大幅度降低了模型在不同标记数据占比下的误报。而如果在 Ghost\_CBAM 的基础上应用 Wloss 损失函数可以将模型的检测精度平均提升 0.3% 的同时,将模型的平均误报降低 29.6%。实际上,在原始模型 SPL 中依次应用 IDA 数据增强、Ghost\_CBAM 以及 Wloss 损失函数,可以将模型在不同标记数据占比下的检测性能提升至最优,表现为准确率和误报平均提升了 1.5% 和 27.1%。通过消融实验结果可以看到,采用的改进措施可以从不同角度改善传统 SPL 网络模型的性能,实现检测准确度提升的同时,大幅降低模型的误报。

### 3 结 论

光刻热点检测在集成电路可制造性设计中具有至关重要的作用。本研究提出了一种基于改进 Ghost 与集成数据增强的半监督光刻热点检测算法。采用

Ghost 模块构建轻量化网络的同时,将 CBAM 注意力机制引入 Ghost 模块的线性变化中,使模型自适应地调整特征图在通道和空间维度上的重要性。针对 ICCAD 2012 竞赛基准存在的数据集不平衡的问题,通过对基准 2、基准 4 和基准 5 应用集成数据增强方法,并利用加权交叉熵损失函数为每个类别赋予不同的损失权重,使模型在训练过程中更加关注少数类样本,极大地缓解了数据集中光刻热点与非热点数量不平衡的问题。实验结果显示:本研究提出的半监督光刻热点检测方法对光刻热点展示出良好的检测准确性,其在不同比例的标记数据占比下,平均准确率分别达到 86.43%、94.49%、94.26%、97.16%、97.81% 和 97.84%,平均误报分别为 755、664、621、605、633 和 705。实验结果充分证明了提出的基于改进 Ghost 与集成数据增强的半监督光刻热点检测方法的有效性,与其他方法相比,所提方法在更低的误报水平下实现了更高的检测精度,表明该方法在光刻热点检测领域具有一定的应用价值。

### 参考文献(References):

- [1] 吴清岳, 刘佳敏, 张松, 等. 基于改进 Yolov5s 的光刻热点检测算法[J]. 激光与光电子学进展, 2023, 60(24): 2422041.  
WU Qing-yue, LIU Jia-min, ZHANG Song, et al. Lithography hotspot detection based on improved Yolov5s[J]. Laser & Optoelectronics Progress, 2023, 60(24): 2422041.
- [2] CHEN G, LI S, WANG X. Efficient optical proximity correction based on virtual edge and mask pixelation with two-phase sampling[J]. Optics Express, 2021, 29(11): 17440-17463.
- [3] MITRA J, YU P, PAN D Z. RADAR: RET-aware detailed

- routing using fast lithography simulations[C]//Proceedings of the Proceedings of 42nd Design Automation Conference. Piscataway: IEEE Press, 2005: 369–372.
- [4] YAO H, SINHA S, CHIANG C, et al. Efficient process-hotspot detection using range pattern matching[C]//Proceedings of the 2006 IEEE/ACM international conference on Computer-aided design-ICCAD'06. New York: ACM, 2006: 625–632.
- [5] KATAOKA G, YAMAMOTO M, INAGI M, et al. Feature vectors based on wire width and distance for lithography hotspot detection[J]. *IPJS Transactions on System and LSI Design Methodology*, 2023, 16: 2–11.
- [6] LIU Y, LI X, PEI B, et al. Towards smart scanning probe lithography: A framework accelerating nano-fabrication process with *in situ* characterization via machine learning[J]. *Microsystems & Nanoengineering*, 2023, 9: 128.
- [7] LIAO L, LI S, CHE Y, et al. Lithography hotspot detection method based on transfer learning using pre-trained deep convolutional neural network[J]. *Applied Sciences*, 2022, 12(4): 2192.
- [8] 林牧, 曾范文清, 刘泉旋, 等. 基于改进 YOLOv3 的光刻热点检测方法[J]. *光学学报*, 2023, 43(23): 2315001.  
LIN Mu, ZENG Fanwen-qing, LIU Xiao-xuan, et al. Lithography hotspot detection based on improved YOLOv3[J]. *Acta Optica Sinica*, 2023, 43(23): 2315001.
- [9] YANG H, LUO L, SU J, et al. Imbalance aware lithography hotspot detection: a deep learning approach[J]. *Nanolithography, MEMS, and MOEMS*, 2017, 16(3): 1.
- [10] JIANG Y, YANG F, YU B, et al. Efficient layout hotspot detection via binarized residual neural network ensemble[C]//Proceedings of the IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems. Piscataway: IEEE Press, 2021: 1476–1488.
- [11] LIU Q, WANG X, YANG B, et al. FSR-SSL: A fault sample rebalancing framework based on semi-supervised learning for PV fault diagnosis[J]. *IET Renewable Power Generation*, 2022, 16(12): 2667–2681.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[M]. Cham: Springer International Publishing, 2018: 3–19.
- [13] HO M L, YI Y, HONGNI W, et al. Classification of the qilou (arcade building) using a robust image processing framework based on the Faster R-CNN with ResNet50[J]. *Journal of Asian Architecture and Building Engineering*, 2024, 23(2): 595–612.
- [14] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 1577–1586.
- [15] LAN Ping, LI Yan. Feature fusion-oriented image multi-tampering detection and localization algorithm[J]. *Application Research of Computers/Jisuanji Yingyong Yanjiu*, 2022, 39(12): 3791–3796.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132–7141.
- [17] CHEN Y, LIN Y, GAI T, et al. Semisupervised hotspot detection with self-paced multitask learning[J]. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2020, 39(7): 1511–1523.
- [18] YANG H, SU J, ZOU Y, et al. Layout hotspot detection with feature tensor generation and deep biased learning[C]//Proceedings of the IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems. Piscataway: IEEE Press, 2019: 1175–1187.
- [19] LI R, SHANG Z, ZHENG C, et al. Efficient distributional reinforcement learning with Kullback-Leibler divergence regularization[J]. *Applied Intelligence*, 2023, 53(21): 24847–24863.
- [20] TORRES J A. ICCAD-2012 CAD contest in fuzzy pattern matching for physical verification and benchmark suite[C]//Proceedings of the IEEE/ACM International Conference on Computer-Aided Design. Piscataway: IEEE Press, 2012: 349–350.
- [21] ZHANG Q, ZHANG Y, LI J, et al. Litho-NeuralODE 2.0: Improving hotspot detection accuracy with advanced data augmentation, DCT-based features, and neural ordinary differential equations[J]. *Integration*, 2022, 85: 10–19.

责任编辑:陈芳