

基于预训练 VGG11 模型的光刻坏点检测方法

廖陆峰^{1,2}, 李思坤^{1,2*}, 王向朝^{1,2**}¹中国科学院上海光学精密机械研究所信息光学与光电技术实验室, 上海 201800;²中国科学院大学材料与光电研究中心, 北京 100049

摘要 模型性能表现和模型训练时间影响着基于迁移学习坏点检测方法的应用,而选用模型和迁移学习策略是模型性能表现和模型训练时间的重要影响因素。提出了一种基于预训练 VGG11 模型的坏点检测方法,通过微调基于 ImageNet 数据集预训练的 VGG11 模型获得坏点检测的待训练模型。采用保留预训练模型权重、冻结卷积层的策略进行模型训练,采用 ICCAD 2012 数据集进行模型训练和测试。与现有方法相比,所提方法的模型综合性能表现更好,所需的模型训练时间更少。所提方法有助于提高掩模版图的坏点检测效率,缩短集成电路生产的周期。

关键词 测量; 光刻; 坏点检测; 机器学习; 迁移学习

中图分类号 TN305.7 **文献标志码** A

DOI: 10.3788/AOS221429

1 引言

光刻机是集成电路制造的核心装备,其作用是将承载集成电路版图信息的掩模图形以成像的方式转移至硅片面的光刻胶内^[1]。如今,单个集成电路芯片上的晶体管数量达到百亿级别,集成电路特征尺寸已经发展到 10 nm 以下^[2-3]。随着集成电路向更高集成度发展,以及设计尺寸不断减小,光刻可制造性成为集成电路设计与制造的关键问题之一^[4-5]。受版图设计影响,在掩模版图中存在一些工艺窗口受限的区域,称为坏点^[6-7]。坏点的光刻结果与目标图形差异较大,容易造成短路或开路问题。为了避免坏点的产生,在版图设计阶段需要对版图反复进行坏点检测和版图修正。坏点检测影响着集成电路生产的周期与良率,是集成电路设计与制造的关键技术之一^[4-6, 8]。

现有的坏点检测方法主要包括基于光刻仿真的坏点检测方法^[7, 9]、基于图形匹配的坏点检测方法^[10-11]和基于机器学习的坏点检测方法^[12-13]。基于光刻仿真的坏点检测方法通过对光刻结果进行物理仿真找到版图中的坏点,该方法检测精度高,但是计算量大,时间成本高^[14]。基于图形匹配的坏点检测方法通过评估待测图形与被收录的坏点图形的相似度来检测版图中的坏点图形,该方法检测速度快,但是只能检测出被收录的坏点图形,对未收录的坏点图形无法识别^[12, 14-17]。基于机器学习的坏点检测方法采用坏点与非坏点版图图形数据集训练神经网络模型,通过使用训练好的模型

对待测版图数据进行坏点检测,该方法具有较快的检测速度,且可以检测出未出现过的坏点图形,目前已获得广泛关注^[12-15, 17]。

基于机器学习的坏点检测方法将从原始版图数据提取的特征作为模型的输入,采用带标签的数据对模型进行训练,获得适用于坏点检测的模型^[15, 18-19]。卷积神经网络以图形为输入,可以实现自动提取图形特征,在坏点检测中获得应用^[17, 20]。随着用于坏点检测的模型由浅层网络向深层网络发展,深度卷积神经网络在坏点检测中获得应用,基于深度学习的坏点检测技术不断发展^[17, 21-22]。众所周知,深度学习采用的模型网络层数多,训练的时间成本高。迁移学习将基于其他数据集训练好的模型作为预训练模型,将预训练模型在目标数据集上进行训练,可以获得适用于目标任务的模型。采用迁移学习策略可以缩短深度学习模型的训练时间。近年来,迁移学习策略在坏点检测方法中获得应用^[23-24]。基于 ImageNet 数据集^[25]预训练的深度卷积神经网络被广泛用于坏点检测^[23-24, 26]。准确率、查全率、查准率和 F_1 分数是常用的模型性能评价指标^[27]。基于预训练 GoogLeNet 模型的坏点检测方法取得了较好的模型性能表现^[24]。王向朝团队提出的基于预训练 VGG13 模型的坏点检测方法提升了查准率和 F_1 分数,进一步提升了模型的综合性能表现^[26]。对于基于预训练 VGG 模型的坏点检测方法,选用模型和迁移学习策略是模型性能表现和模型训练时间的重要影响因素。模型性能表现和模型训练时间影响着

收稿日期: 2022-07-06; 修回日期: 2022-08-21; 录用日期: 2022-08-31; 网络首发日期: 2022-09-10

基金项目: 国家科技重大专项(2017ZX02101004-002, 2017ZX02101004)、国家自然科学基金(U22A2070)

通信作者: *lisikun@siom.ac.cn; **wxz26267@siom.ac.cn

基于迁移学习坏点检测方法的应用,现有方法的模型性能表现和模型训练时间仍存在提升空间^[17, 23-24, 26]。本文提出一种基于预训练 VGG11 模型的坏点检测方法,通过微调基于 ImageNet 数据集预训练的 VGG11 模型网络结构获得坏点检测的待训练模型,并采用保留预训练模型权重、冻结卷积层的策略进行模型训练。由于 VGG11 模型网络层数更少,所需的模型训练时间减少。采用 ICCAD 2012 数据集^[28]进行模型训练和模型测试。与现有方法^[23-24, 26]相比,所提模型的综合性能表现更好,所需的模型训练时间更少。所提模型可以减少坏点检测的漏报和误报现象,缩短坏点检测和坏点修正的周期;减少模型训练时间,从而减少坏点检测的时间;提高掩模版图的坏点检测效率,缩短集成电路生产周期。

2 基本原理

卷积神经网络以图像为输入,通过卷积层的卷积核实现图像特征提取,将提取的特征进行组合后得到相应的输出。版图数据可以表示为图形数据,卷积神经网络适用于坏点检测^[20]。基于卷积神经网络的坏点检测原理如图 1 所示,主要包含模型训练阶段和坏点检测阶段。在模型训练阶段,使用带标签的版图图形数据集对待训练模型进行模型训练。通过模型训练确定模型中的参数,卷积层中卷积核的确定使得模型具有相应的特征提取能力,进而实现坏点检测。在坏点检测阶段,使用训练好的模型对待测的版图图形进行

坏点检测。坏点检测的结果分为以下情况:

真正例(TP)——将坏点图形识别为坏点图形,其数量为 N_{TP} 。

真反例(TN)——将非坏点图形识别为非坏点图形,其数量为 N_{TN} 。

假正例(FP)——将非坏点图形识别为坏点图形,其数量为 N_{FP} 。

假反例(FN)——将坏点图形识别为非坏点图形,其数量为 N_{FN} 。

为了评估模型的性能表现,需要从准确率(A)、查全率(R)、查准率(P)和 F_1 分数进行评价。准确率、查全率、查准率和 F_1 分数的定义为

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (1)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (2)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (3)$$

$$F_1 = 2 \times \frac{P \times R}{P + R}. \quad (4)$$

其中,准确率是指被正确识别的图形占全部图形的比例,查全率是指被正确识别的坏点图形占全部坏点图形的比例,查准率是指被识别为坏点图形的图形中真正是坏点图形的比例, F_1 分数是综合评价查全率和查准率的因子。准确率、查全率、查准率和 F_1 分数的取值均在 0 和 1 之间,值越大,则模型的性能表现越好。

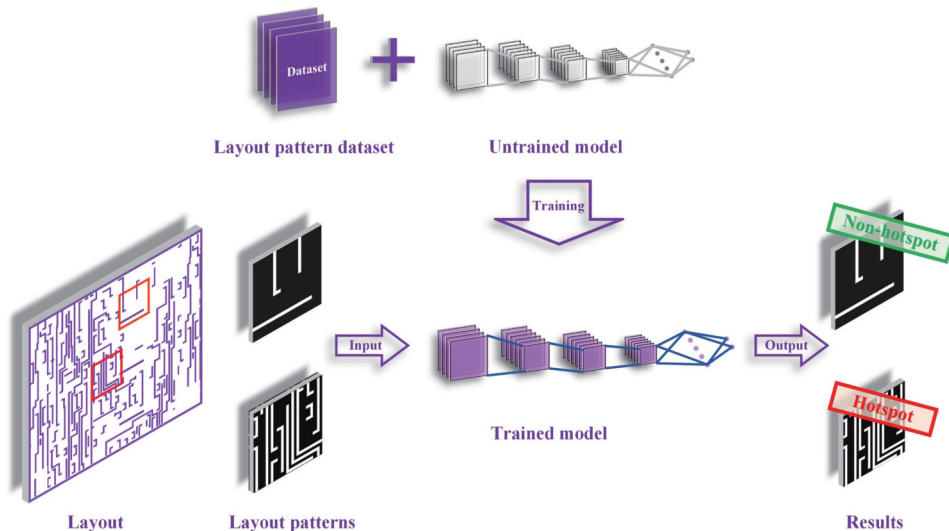


图 1 基于卷积神经网络的坏点检测方法示意图

Fig. 1 Schematic of hotspot detection method based on convolutional neural network

2.1 工作流程

所提出的基于预训练 VGG11 模型的坏点检测方法采用基于 ImageNet 数据集预训练的 VGG11 模型作为坏点检测的待训练模型,采用迁移学习策略对待训练模型进行模型调整和模型训练,从而得到适用于坏

点检测的 VGG11 模型。基于 ImageNet 数据集预训练的 VGG11 模型的输入为 $224 \text{ pixel} \times 224 \text{ pixel}$ 的图形数据,其输出为 1000 维的图形分类结果。高分辨率的版图图形需要进行数据压缩,使其分辨率与 ImageNet 数据集的分辨率相近,从而可以作为预训练 VGG11

模型的输入。坏点检测属于二分类任务,预训练 VGG11 模型需要对网络结构进行微调,使其适用于坏点检测。在模型训练时,所提方法采用迁移学习策略保留预训练权重作为模型训练的初始权重。基于版图数据训练好的 VGG11 模型可以用于坏点检测。所提出的基于预训练 VGG11 模型的坏点检测方法工作流

程如图 2 所示,包含准备阶段、模型训练阶段和模型测试阶段。在准备阶段,需要对版图数据和待训练模型进行准备。在模型训练阶段,采用迁移学习策略对待训练的模型进行训练。在模型测试阶段,采用训练好的模型对待测版图数据进行坏点检测,评估模型的性能表现。

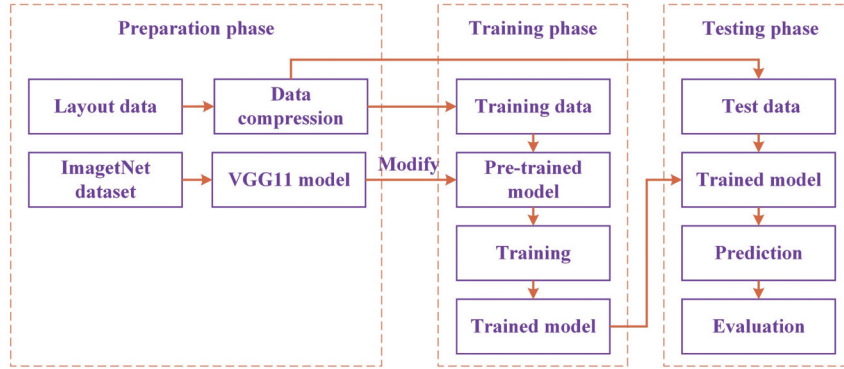


图 2 所提方法工作流程

Fig. 2 Workflow of the proposed method

2.2 准备阶段

在所提方法的准备阶段,需要对模型训练的数据和待训练模型进行准备。

2.2.1 数据准备

在所提方法中,原始数据为 GDS 格式的版图数据。所提方法采用 ICCAD 2012 数据集作为模型训练和模型测试的数据集,数据集的数据构成如表 1 所示。该数据集包含 32 nm 和 28 nm 技术节点的版图数据,其中 Benchmark 1 属于 32 nm 技术节点的版图数据, Benchmark 2 到 Benchmark 5 属于 28 nm 技术节点的版图数据。用于 VGG11 模型预训练的 ImageNet 数据集的图形数据分辨率为 224 pixel × 224 pixel,用于坏点检测模型训练的数据分辨率要与 224 pixel × 224 pixel 相近。ICCAD 2012 数据集的版图数据的分辨率高达 1 nm,若直接以 1 nm 分辨率进行转换,获得的图形数据为 1200 pixel × 1200 pixel,无法作为预训练 VGG11 模型的输入。所提方法采用计算图形局部密度的方式^[21-22]进行图形下采样,从而实现数据压缩。下采样后的图形分辨率为 240 pixel × 240 pixel,与 ImageNet 数据集图形分辨率相近。

在集成电路版图中,非坏点图形比坏点图形多,存在正负样本不平衡现象^[28]。在 ICCAD 2012 训练数据集中也存在坏点数据和非坏点数据不平衡问题。对于基于机器学习的坏点检测方法,训练数据的正负样本不平衡会影响训练得到模型的性能表现^[29]。针对正负样本不平衡问题,所提方法采用欠采样策略^[26,30]对非坏点数据进行随机采样。在 ICCAD 2012 训练数据中,随机采样非坏点数据与所有坏点数据构成一个完

表 1 ICCAD 2012 数据集的数据构成

Table 1 Data composition of ICCAD 2012 benchmark suite

Benchmark	Training data		Test data	
	Hotspots	Non-hotspots	Hotspots	Non-hotspots
Benchmark 1 (B1)	99	340	226	319
Benchmark 2 (B2)	174	5258	498	4146
Benchmark 3 (B3)	909	4643	1808	3541
Benchmark 4 (B4)	95	4452	171	3386
Benchmark 5 (B5)	26	2716	41	2111

整的训练数据集。

2.2.2 模型准备

VGG 模型属于深度卷积神经网络模型,包括 VGG11、VGG13、VGG16 和 VGG19 模型。VGG 模型的网络结构信息如图 3^[31]所示。VGG11 模型的网络层数最少,网络参数量少,训练的时间成本低。所提方法采用基于 ImageNet 数据集预训练的 VGG11 模型作为坏点检测的待训练模型。VGG11 模型包含卷积层、池化层和全连接层,其中卷积层和全连接层总计 11 层。VGG11 模型卷积层的卷积核数量逐层增多,从第一层的 64 个增加到最后一层的 512 个。卷积层起到对输入进行特征提取的作用,其输出为提取获得的特征图。池化层起到对特征图下采样的作用。全连接层充当分类器,将输入的展平特征向前传输,从而获得最终分类输出。

基于 ImageNet 数据集预训练的 VGG11 模型的输出为 1000 维的图形分类结果。预训练 VGG11 模型的输出层维度为 1000,而坏点检测属于二分类任务,基于 ImageNet 数据集训练的 VGG11 模型无法直接用于

ConvNet Configuration			
VGG11	VGG13	VGG16	VGG19
11 weight layers	13 weight layers	16 weight layers	19 weight layers
Input			
Conv3-64	Conv3-64 Conv3-64	Conv3-64 Conv3-64	Conv3-64 Conv3-64
Maxpool			
Conv3-128	Conv3-128 Conv3-128	Conv3-128 Conv3-128	Conv3-128 Conv3-128
Maxpool			
Conv3-256 Conv3-256	Conv3-256 Conv3-256	Conv3-256 Conv3-256 Conv3-256	Conv3-256 Conv3-256 Conv3-256
Maxpool			
Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512 Conv3-512	Conv3-512 Conv3-512 Conv3-512
Maxpool			
Conv3-512 Conv3-512	Conv3-512 Conv3-512	Conv3-512 Conv3-512 Conv3-512	Conv3-512 Conv3-512 Conv3-512
Maxpool			
FC-4096			
FC-4096			
FC-1000			
Soft-max			

图 3 VGG 模型网络结构示意图^[31]

Fig. 3 Diagram of VGG models' network architecture^[31]

坏点检测。全连接层的最后一层维度与输出分类数相关。因此,预训练 VGG11 模型对全连接层进行调整即可适用于坏点检测。调整后的 VGG11 模型的网络

结构如图 4 所示。用于坏点检测的 VGG11 模型的全连接层的输出层维度为 2, 对应于坏点图形和非坏点图形两种结果。




图 4 调整后的 VGG11 模型网络结构示意图

Fig. 4 Schematic of network architecture of the modified VGG11 model

2.3 模型训练

在训练数据和待训练模型准备好后,采用准备好的版图图形数据对待训练模型进行训练,并将训练好的 VGG11 模型用于坏点检测。在所提方法的模型训练阶段,采用迁移学习策略对待训练模型进行模型训练,将基于 ImageNet 数据集预训练的模型权重作为坏点检测模型训练的初始权重。基于 ImageNet 数据集预训练的模型具有良好的特征提取能力和分类能力,在坏点检测中获得应用并取得良好的模型性能表

现^[23]。为了更好地利用预训练获得的权重,所提方法保留全部卷积层和全连接层的预训练权重作为模型训练的初始权重。在模型训练时,所提方法采用冻结卷积层的策略进行模型训练。当冻结全部卷积层时,仅对全连接层的权重进行训练更新。当冻结部分卷积层时,可以对全连接层和最后几层卷积层的权重进行训练更新。

在模型训练阶段,需要确定模型训练的损失函数。所提方法采用交叉熵(E_{CE})作为模型训练的损失函数。

交叉熵的定义为

$$E_{CE} = - \sum_{i=1}^n p_i \log q_i, \quad (5)$$

式中: n 为数据分类总数; p_i 为样本在分类 i 的实际概率; q_i 为样本在分类 i 的模型输出概率。对于一个输入数据, 模型的输出结果是该输入在每个分类上的概率分布。训练数据的标签已知, 每个数据在每个分类的实际概率分布是确定的。相对熵是两个随机分布间距离的度量, 其定义式为

$$D(p // q) = \sum_{i=1}^n p_i \log \left(\frac{p_i}{q_i} \right) = \sum_{i=1}^n p_i \log p_i - \sum_{i=1}^n p_i \log q_i. \quad (6)$$

由于训练数据的实际标签已知, 实际概率分布 p_i 为常量, 因此 $\sum_{i=1}^n p_i \log p_i$ 为常量。相对熵可以表示为交叉熵与常量之和。采用交叉熵损失函数进行模型训练, 减小交叉熵即减小相对熵, 从而实现缩小模型输出结果的概率分布与实际概率分布的差距。坏点检测属于二分问题, 单个数据的交叉熵损失函数为

$$f_{\text{Loss-binary}} = - [p_1 \log q_1 + (1 - p_1) \log (1 - q_1)]. \quad (7)$$

在模型训练中, 对于一个 batch 内的所有数据, 其交叉熵损失的计算公式为

$$f_{\text{Loss-batch}} = - \frac{1}{m} \sum_{i=1}^m [p_i^i \log (q_i^i) + (1 - p_i^i) \log (1 - q_i^i)], \quad (8)$$

式中: m 为 batch 中样本数量。

3 结果与讨论

为了验证所提方法的有效性, 采用 ICCAD 2012 数据集^[28]进行模型训练和模型测试。ICCAD 2012 数据集包含 5 个数据子集, 每个子集包含训练数据和测试数据两部分, 其中的坏点数据和非坏点数据如表 1 所示。基于所提方法准备阶段的数据压缩方法, ICCAD 2012 数据集中的版图数据转化为 240 pixel × 240 pixel 的图形数据。根据所提方法的数据平衡方法, 在 ICCAD 2012 训练数据中随机采样非坏点数据与所有坏点数据构成一个数量为 5054 的训练数据集。模型测试数据为 ICCAD 2012 数据集中所有的测试数据。基于 ImageNet 数据集预训练的 VGG11 模型经过模型调整后作为待训练模型, 采用准备好的训练数据集对待训练模型进行模型训练。模型训练和模型测试在 CPU 为 Intel Xeon Gold 5118、内存为 128 GB 和 GPU 为 Nvidia Tesla V100 的服务器平台上进行。

预训练 VGG11 模型采用准备好的训练数据集进行模型训练, 经过 10 次训练后模型已经收敛。因此, 采用训练 10 轮的模型进行模型测试, 评价模型性能表现。为了验证利用所提方法获得的模型性能表现提升以及模型训练时间的降低, 与现有方法进行了对比。

对比实验包含 VGG 模型对比和坏点检测实验两部分。在 VGG 模型对比中, 为了验证模型选择对模型性能表现和模型训练时间的影响, 采用不同的预训练 VGG 模型进行实验与分析。其中基于预训练 VGG13 模型的坏点检测方法是王向朝团队的先前研究工作^[26], 具有较好的模型综合性能表现。在坏点检测实验中, 为了验证所提方法带来的模型性能表现提升, 采用近两年基于迁移学习的坏点检测方法^[23-24]作为参考, 对比了不同方法在准确率、查全率、查准率和 F_1 分数上的模型性能表现。

3.1 VGG 模型对比

基于 ImageNet 数据集预训练的卷积神经网络在坏点检测中获得应用。基于预训练 VGG13 模型的坏点检测方法具有较好的模型性能表现^[26]。VGG 模型包括 VGG11、VGG13、VGG16 和 VGG19 模型, 不同模型在坏点检测方法中的模型性能表现和模型训练时间存在差异。基于所提方法的工作流程, 采用不同预训练 VGG 模型进行模型训练和模型测试。根据文献^[26]的实验结果, 释放部分卷积层进行模型训练时对模型性能表现影响较小, VGG 模型对比实验采用冻结全部卷积层的方式进行模型训练和模型测试。对比结果如图 5 和表 2 所示。在 ICCAD 2012 的 5 个测试集中, 基于预训练 VGG11 模型的坏点检测方法的准确率、查全率、查准率和 F_1 分数最高, 平均准确率、平均查全率、平均查准率和平均 F_1 分数分别达到了 98.9%、98.2%、89.5% 和 93.3%。在所提方法中, 预训练 VGG11 模型的性能表现最好, 预训练 VGG19 模型的性能表现最差, 模型的网络深度加深并未带来更好的模型性能表现。基于所提方法的工作流程, 不同预训练 VGG 模型的训练时间对比如表 3 所示。可以看出, 模型的网络层数越少, 所需训练时间越少, 预训练 VGG11 模型的训练时间最少。预训练 VGG11 模型的训练时间为 279 s。与预训练 VGG13 模型相比, 预训练 VGG11 模型的训练时间下降了 12.0%。所提方法基于预训练 VGG11 模型进行坏点检测, 模型的综合性能表现更好, 所需的训练时间更少。模型性能表现提升可以提高坏点检测的准确率、查全率和查准率, 有助于减少坏点检测和坏点修正的后续步骤, 可以缩短掩模制备的周期。模型训练时间缩短, 可以减少坏点检测的时间。因此, 所提方法有助于提高掩模版图坏点检测的效率, 缩短集成电路生产的周期。

3.2 坏点检测实验

在现有方法中, 基于预训练 GoogLeNet 模型^[24]和基于预训练 VGG16 模型^[23]的坏点检测方法也取得了不错的模型性能表现。这些方法的查全率较高, 但查准率存在不足。为了验证所提方法具有较好的模型性能表现, 与上述现有方法进行了对比。采用 ICCAD 2012 数据集进行了坏点检测实验, 对比不同方法在准确率、查全率、查准率和 F_1 分数上的模型性能表现。

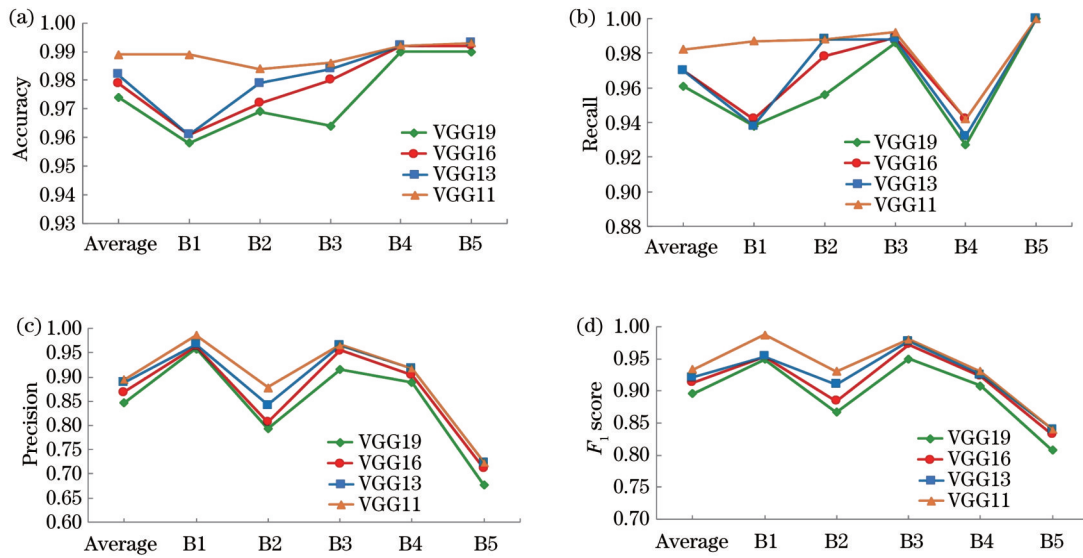


图 5 不同预训练 VGG 模型的模型性能表现对比。(a) 准确率; (b) 查全率; (c) 查准率; (d) F_1 分数

Fig. 5 Model performance comparison of different pre-trained VGG models. (a) Accuracy; (b) recall; (c) precision; (d) F_1 score

表 2 不同预训练 VGG 模型的模型性能表现对比

Table 2 Model performance comparison of different pre-trained VGG models

Benchmark	Model	Accuracy	Recall	Precision	F_1 score
Benchmark 1 (B1)	VGG11	0.989	0.987	0.987	0.987
	VGG13	0.961	0.938	0.968	0.953
	VGG16	0.961	0.942	0.964	0.953
	VGG19	0.958	0.938	0.959	0.949
Benchmark 2 (B2)	VGG11	0.984	0.988	0.879	0.930
	VGG13	0.979	0.988	0.843	0.910
	VGG16	0.972	0.978	0.807	0.884
	VGG19	0.969	0.956	0.794	0.867
Benchmark 3 (B3)	VGG11	0.986	0.992	0.967	0.980
	VGG13	0.984	0.988	0.966	0.977
	VGG16	0.980	0.989	0.955	0.972
	VGG19	0.964	0.986	0.916	0.950
Benchmark 4 (B4)	VGG11	0.992	0.942	0.918	0.930
	VGG13	0.992	0.932	0.918	0.925
	VGG16	0.992	0.942	0.905	0.923
	VGG19	0.990	0.927	0.889	0.908
Benchmark 5 (B5)	VGG11	0.993	1.000	0.724	0.840
	VGG13	0.993	1.000	0.724	0.840
	VGG16	0.992	1.000	0.712	0.832
	VGG19	0.990	1.000	0.677	0.808
Average	VGG11	0.989	0.982	0.895	0.933
	VGG13	0.982	0.969	0.884	0.921
	VGG16	0.979	0.970	0.869	0.913
	VGG19	0.974	0.961	0.847	0.896

由于在模型训练中可以释放部分卷积层,所提方法的模型训练和模型测试分为以下 3 种情形进行:

Case 1: 在模型训练时,预训练 VGG11 模型冻结

卷积层。模型训练 10 次后,进行模型测试。

Case 2: 在模型训练时,预训练 VGG11 模型释放全连接层和最后 2 层卷积层。模型训练 10 次后,进行

表 3 不同预训练 VGG 模型的训练时间对比

Model	VGG11	VGG13	VGG16	VGG19
Training time /s	279	317	359	497

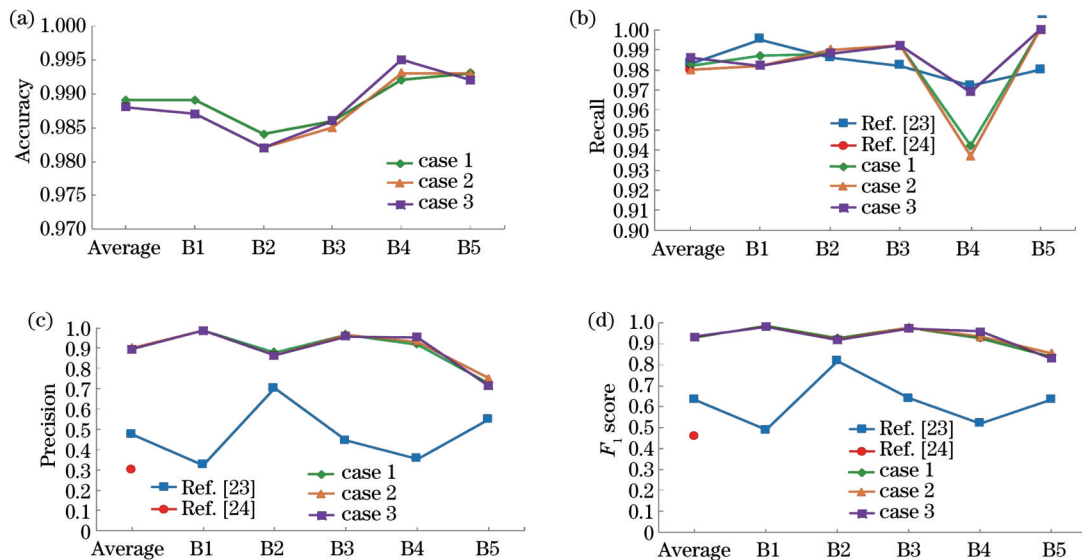
模型测试。

Case 3: 在模型训练时, 预训练 VGG11 模型释放全连接层和最后 5 层卷积层。模型训练 10 次后, 进行模型测试。

在模型训练时, 冻结预训练 VGG11 模型所有卷积层, 只释放模型的全连接层, 使得预训练 VGG11 模型的全部特征提取权重都应用到坏点检测中。经过 10 次模型训练后, 使用测试数据集对模型进行测试, 结果如图 6 和表 4 所示。由于参考方法仅给出了查全率、查准率和 F_1 分数, 在图 6(a) 中仅展示了所提方法获得的模型准确率。所提方法在准确率上获得良好性能表现, 准确率在 98.4%~99.3% 范围内, 平均准确率达到 98.9%; 所提方法在查全率上与参考方法相当, 查全率在 94.1%~100.0% 范围内, 平均查全率达到 98.2%; 所提方法在查准率和 F_1 分数上获得明显提升, 平均查准率和平均 F_1 分数分别达到 89.5% 和 93.3%。与参考文献中最好的结果相比, 平均查准率和平均 F_1 分数分别提升了 88.4% 和 46.9%。对比结

果显示, 所提方法在准确率、查全率、查准率和 F_1 分数方面具有更好的表现。查全率影响坏点检测结果的漏报率, 查准率影响坏点检测结果的误报率。查准率的提升可以有效减少坏点检测的误报率, 从而缩短坏点检测和坏点修正的周期。 F_1 分数的提升表明所提方法在坏点检测的查全率和查准率上具有更好的表现。较好的模型性能表现提升可以减少坏点检测的漏报和误报, 减少掩模版图坏点检测和坏点修正的后续工作步骤。所提方法有助于提高掩模版图的坏点检测效率, 缩短集成电路生产的周期。

采用释放部分卷积层的方式进行了模型训练和模型测试, 结果如图 6 和表 4 所示。从对比结果可以看出, 所提方法的准确率、查全率、查准率和 F_1 分数的综合表现更好。在 case 2 中, 平均准确率、平均查全率、平均查准率和平均 F_1 分数分别达到 98.8%、98.0%、90.0% 和 93.5%。在 case 3 中, 平均准确率、平均查全率、平均查准率和平均 F_1 分数分别达到 98.8%、98.6%、89.5% 和 93.5%。从 case 1、case 2 和 case 3 的对比结果可以看出, 释放卷积层的数量对模型性能表现影响不大。与冻结预训练模型卷积层的情况相比, 释放卷积层的模型性能表现变化不大。所提方法在模型训练时, 仅对预训练模型的全连接层权重进行更新, 即可获得适用于坏点检测的模型。

图 6 不同方法的模型性能表现对比。(a) 准确率; (b) 查全率; (c) 查准率; (d) F_1 分数Fig. 6 Model performance comparison of different methods. (a) Accuracy; (b) recall; (c) precision; (d) F_1 score

4 结 论

提出了一种基于预训练 VGG11 模型的光刻坏点检测方法。所提出的方法通过微调基于 ImageNet 数据集预训练的 VGG11 模型获得坏点检测的待训练模型。采用保留预训练模型权重、冻结卷积层的策略进行模型训练, 采用 ICCAD 2012 数据集进行模型训练

和模型测试。将现有方法作为参考, 进行了坏点检测实验和 VGG 模型对比。结果表明, 在具有更好的模型综合性能表现前提下, 所提方法所需的模型训练时间更少。模型性能表现提升可以减少坏点检测的漏报和误报, 从而缩短坏点检测和坏点修正的周期; 模型训练时间降低可以减少坏点检测时间。因此, 所提方法有助于提高掩模版图的坏点检测效率, 缩短集成电路

表 4 不同方法的模型性能表现对比
Table 4 Model performance comparison of different methods

Benchmark	Method	Accuracy	Recall	Precision	F_1 score
Benchmark 1 (B1)	Ref. [23]	—	0.995	0.324	0.489
	Case 1	0.989	0.987	0.987	0.987
	Case 2	0.987	0.982	0.987	0.984
	Case 3	0.987	0.982	0.987	0.984
Benchmark 2 (B2)	Ref. [23]	—	0.986	0.702	0.820
	Case 1	0.984	0.988	0.879	0.930
	Case 2	0.982	0.990	0.864	0.923
	Case 3	0.982	0.988	0.864	0.921
Benchmark 3 (B3)	Ref. [23]	—	0.982	0.443	0.640
	Case 1	0.986	0.992	0.967	0.980
	Case 2	0.985	0.992	0.965	0.978
	Case 3	0.986	0.992	0.958	0.975
Benchmark 4 (B4)	Ref. [23]	—	0.972	0.355	0.520
	Case 1	0.992	0.942	0.918	0.930
	Case 2	0.993	0.937	0.932	0.935
	Case 3	0.995	0.969	0.954	0.961
Benchmark 5 (B5)	Ref. [23]	—	0.980	0.549	0.635
	Case 1	0.993	1.000	0.724	0.840
	Case 2	0.993	1.000	0.750	0.857
	Case 3	0.992	1.000	0.712	0.832
Average	Ref. [24]	—	0.980	0.300	0.458
	Ref. [23]	—	0.983	0.475	0.635
	Case 1	0.989	0.982	0.895	0.933
	Case 2	0.988	0.980	0.900	0.935
	Case 3	0.988	0.986	0.895	0.935

生产的周期。

参 考 文 献

- [1] 王向朝, 戴凤钊, 李思坤, 等. 集成电路与光刻机[M]. 北京: 科学出版社, 2020.
Wang X Z, Dai F Z, Li S K, et al. Integrated circuit and lithographic tool[M]. Beijing: Science Press, 2020.
- [2] Neisser M. International roadmap for devices and systems lithography roadmap[J]. Journal of Micro/Nanopatterning, Materials, and Metrology, 2021, 20(4): 044601.
- [3] Wikipedia. Transistor count[EB/OL]. (2022-03-15) [2022-06-20]. https://en.wikipedia.org/wiki/Transistor_count.
- [4] Jochemsen M, Anunciado R, Timoshkov V, et al. Process window limiting hot spot monitoring for high-volume manufacturing[J]. Proceedings of SPIE, 2016, 9778: 97781R.
- [5] Hunsche S, Jochemsen M, Jain V, et al. A new paradigm for in-line detection and control of patterning defects[J]. Proceedings of SPIE, 2015, 9424: 94241B.
- [6] Weisbuch F, Thaler T, Buttgerit U, et al. Improving ORC methods and hotspot detection with the usage of aerial images metrology[J]. Proceedings of SPIE, 2020, 11327: 113270D.
- [7] 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.
- [8] Nosato H, Sakanashi H, Takahashi E, et al. Hotspot prevention and detection method using an image-recognition technique based on higher-order local autocorrelation[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2014, 13(1): 011007.
- [9] Gupta P, Kahng A B, Nakagawa S, et al. Lithography simulation-based full-chip design analyses[J]. Proceedings of SPIE, 2006, 6156: 61560T.
- [10] Yang F, Sinha S, Chiang C, et al. Improved tangent space based distance metric for lithographic hotspot classification[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2017, 36(9): 1545-1556.
- [11] 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, 2006: 625-632.
- [12] Ding D, Wu X, Ghosh J, et al. Machine learning based lithographic hotspot detection with critical-feature extraction and classification[C]//2009 IEEE International Conference on IC Design and Technology, May 18-20, 2009, Austin, TX, USA. New York: IEEE Press, 2009: 219-222.
- [13] Nagase N, Suzuki K, Takahashi K, et al. Study of hot spot detection using neural networks judgment[J]. Proceedings of SPIE, 2007, 6607: 66071B.
- [14] Nakamura S, Matsunawa T, Kodama C, et al. Clean pattern matching for full chip verification[J]. Proceedings of SPIE, 2012, 8327: 83270T.

- [15] 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*, 2013, 34(3): 460-470.
- [16] 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.
- [17] 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.
- [18] Zhang H, Yang H Y, Yu B, et al. VLSI layout hotspot detection based on discriminative feature extraction[C]//2016 IEEE Asia Pacific Conference on Circuits and Systems, October 25-28, 2016, Jeju, Korea (South). New York: IEEE Press, 2016: 542-545.
- [19] Yu B, Gao J R, Ding D, et al. Accurate lithography hotspot detection based on principal component analysis-support vector machine classifier with hierarchical data clustering[J]. *Journal of Micro/Nanolithography, MEMS, and MOEMS*, 2014, 14(1): 011003.
- [20] Shin M, Lee J H. CNN based lithography hotspot detection[J]. *The International Journal of Fuzzy Logic and Intelligent Systems*, 2016, 16(3): 208-215.
- [21] 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, September 5-8, 2017, Munich, Germany. New York: IEEE Press, 2017: 233-238.
- [22] 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.
- [23] Xiao Y D, Huang X Q. Learning lithography hotspot detection from ImageNet[C]//2019 14th IEEE International Conference on Electronic Measurement & Instruments, November 1-3, 2019, Changsha, China. New York: IEEE Press, 2019: 266-273.
- [24] 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.
- [25] Russakovsky O, Deng J, Su H, et al. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.
- [26] Liao L F, Li S K, Che Y Q, et al. Lithography hotspot detection method based on transfer learning using pre-trained deep convolutional neural network[J]. *Applied Sciences*, 2022, 12(4): 2192.
- [27] Zhou Z H. Model selection and evaluation[M]//*Machine learning*. Singapore: Springer Nature, 2021: 25-55.
- [28] Torres J A. ICCAD-2012 CAD contest in fuzzy pattern matching for physical verification and benchmark suite[C]//2012 IEEE/ACM International Conference on Computer-Aided Design (ICCAD), November 5-8, 2012, San Jose, CA, USA. New York: IEEE Press, 2012: 349-350.
- [29] 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.
- [30] Zhou Z H. Linear models[M]//*Machine learning*. Singapore: Springer Nature, 2021: 57-77.
- [31] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2022-02-04]. <https://arxiv.org/abs/1409.1556>.

Lithography Hotspot Detection Method Based on Pre-trained VGG11 Model

Liao Lufeng^{1,2}, Li Sikun^{1,2*}, Wang Xiangzhao^{1,2**}

¹Laboratory of Information Optics and Opto-Electronic Technology, Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201800, China;

²Center of Materials Science and Optoelectronics Engineering, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract

Objective Lithographic tool is an important device for large-scale IC manufacturing. Its function is to transfer mask patterns into photoresists on wafers. Nowadays, the designed feature size of IC is below 10 nm, and the number of transistors of an IC is as high as tens of billions. With the demand for high integration and good performance, the physical design of IC continues to shrink, and lithographic printability has become one of the critical issues in IC design and manufacturing. Affected by the layout design and lithography process, the lithography results of some patterns in the layout are quite different from that of the target patterns, which results in short-circuit or open-circuit problems. These problems will cause lithography hotspots. In order to reduce lithography hotspots, hotspot detection and layout correction are carried out in turn in the layout design phase. The performance of the hotspot detection affects the period and yield of IC manufacturing. Hotspot detection is one of the important techniques for IC design and manufacturing. For available hotspot detection methods, the hotspot detection method based on lithography simulation is time-consuming, and the hotspot detection method based on pattern matching is invalid for unknown hotspot patterns. The hotspot detection method based on machine learning has good performance in speed and accuracy and has been widely studied. Transfer

learning has been applied in the hotspot detection method based on machine learning and achieved positive model performance. Model performance and model training time affect the application of the hotspot detection method based on transfer learning. In this study, a lithography hotspot detection method based on a pre-trained VGG11 model is proposed. The proposed method helps to improve the model performance and model training time.

Methods In this study, we adopt a transfer learning strategy for model training of hotspot detection. First, the ImageNet dataset is used to pre-train the VGG11 model, and the pre-trained VGG11 model is used as the model to be trained for hotspot detection. Then, the network architecture of the pre-trained VGG11 model is fine-tuned to make it suitable for hotspot detection. In the data preparation phase, pattern down-sampling and data balance are employed to prepare data for model training. In the model training phase, the strategy of preserving pre-trained model weights and freezing convolutional layers is adopted for model training. The trained model is suitable for hotspot detection.

Results and Discussions In this study, ICCAD 2012 benchmark suite is used for model training and model tests. The ICCAD 2012 benchmark suite contains five subsets. According to the data-balance method, non-hotspot data are randomly sampled in the training data of the ICCAD 2012 benchmark suite. The randomly sampled non-hotspot data and all hotspot data constitute a complete training dataset, and the number of training data in the training dataset is 5054. The model test data are the five test datasets in the ICCAD 2012 benchmark suite. With the pre-trained VGG13, VGG16, and VGG19 models as references, VGG model comparison experiments are conducted. As shown in Fig. 5 and Table 2, the comparison results indicate that the comprehensive performance of the model obtained by the proposed method is better, and the average accuracy, recall, precision, and F_1 score of the model reach 98.9%, 98.2%, 89.5%, and 93.3%, respectively. In addition, the hotspot detection method based on the pre-trained VGG11 model requires a shorter model training time of only 279 s. The improvement of the model performance and model training time helps to improve the efficiency of hotspot detection. Compared with the hotspot detection method based on the pre-trained GoogLeNet model and the pre-trained VGG16 model, the results show that the proposed method has better comprehensive model performance. As shown in Fig. 6 and Table 4, on the premise that the hotspot detection has a considerable recall, the proposed method can significantly improve the precision and F_1 score. Tests are carried out to release convolutional layers with different numbers for model training, and the results show that the release of the convolution layers has a slight effect on the model performance of the proposed method.

Conclusions A lithography hotspot detection method based on a pre-trained VGG11 model is proposed in this study. A transfer learning strategy is adopted for model training. The proposed method uses a VGG11 network trained by the ImageNet dataset as the pre-trained model, and the network architecture of the pre-trained VGG11 model is fine-tuned to make it suitable for hotspot detection. Model training is performed by using a strategy of preserving pre-trained model weights and freezing convolutional layers. ICCAD 2012 benchmark suite is used for model training and model tests. Compared with that of available methods, the results show that the model of the proposed method has better comprehensive performance and requires less model training time. The average accuracy, recall, precision, and F_1 score of the model reach 98.9%, 98.2%, 89.5%, and 93.3%. In addition, the model training time of the proposed method is only 279 s. The proposed method helps to improve the efficiency of hotspot detection and shortens the period of integrated circuit manufacturing.

Key words measurement; lithography; hotspot detection; machine learning; transfer learning