

基于 CycleGAN 改进的晶圆缺陷图 数据增强方法

王子嘉, 王昊燃, 冯晨, 梁哲涵, 刘晓宇

(四川大学 机械工程学院, 成都 610000)

摘要: 针对某些晶圆图故障图案类型样本量较少导致的数据集不平衡问题进行研究, 提出了一种基于 CycleGAN 改进的晶圆缺陷图数据增强方法; 在生成器中引入 ULSAM 注意力机制, 以增强跨通道特征提取能力; 对判别器优化结构, 以减少关键信息丢失, 并在模型中采用 PReLU 激活函数以提升梯度稳定性与收敛速度; 实验结果表明, 所提方法在 Donut 类别 SSIM 提升 0.203 4, FID 降低 84.95; 基于增强前后的数据集分别训练晶圆缺陷分类模型, Donut 类和 Random 类的分类准确率分别提高 1.1% 和 7.2%; 该方法在提升少数类缺陷图生成质量的同时, 为提升晶圆缺陷分类检测模型的精度提供了数据支撑。

关键词: 晶圆缺陷; CycleGAN; 数据增强; ULSAM

Image Data Augmentation Method for Wafer Defects Based on Improved CycleGAN

WANG Zijia, WANG Haoran, FENG Chen, LIANG Zhehan, LIU Xiaoyu

(School of Mechanical Engineering, Sichuan University, Chengdu 610000, China)

Abstract: To address the data imbalance caused by the limited number of samples in certain wafer defect pattern categories, a defect image augmentation method based on an improved cycle-consistent adversarial network (CycleGAN) framework was proposed. The ultra-lightweight subspace attention module (ULSAM) attention mechanism is introduced in the generator to enhance the extraction capability of cross-channel features. The discriminator is structurally optimized to reduce the loss of critical information, and the PReLU activation function is employed to improve the gradient stability and accelerate the convergence of the model. Experimental results show that the proposed method increases the structural similarity index (SSIM) by 0.203 4 and reduces the Fréchet inception distance (FID) by 84.95 for the Donut category. Classification models for wafer defects are trained on the datasets before and after augmentation, the accuracies of the Donut and Random categories are increased by 1.1% and 7.2%, respectively. The method enhances the generation quality of minority-class defect images while also providing a data support for improving the classification accuracy of wafer defect detection models.

Keywords: wafer defects; CycleGAN; data augmentation; ULSAM

0 引言

芯片产业是我国实现科技强国的关键支撑力量, 是我国“十四五”规划提出的科研攻坚重点领域之一, 具有重要战略意义^[1]。晶圆作为芯片的载体, 其高良率是衡量芯片质量的重要指标。为了更直观地检测晶圆质

量, 把在测量环节用晶圆探针检查每一个晶粒的功能结果绘制成晶圆图^[2]。晶圆表面缺陷的分类检测是通过对晶圆图像中空间图案的分析, 将相似的图样归类为对应类型, 从而有助于深入研究缺陷成因, 进一步提升晶圆制造过程中的成品率^[3]。随着集成电路的高度发展, 晶圆制造出现缺陷的概率和缺陷种类也随之增加, 传统人

收稿日期: 2025-05-15; 修回日期: 2025-06-12。

基金项目: 2025 年“大学生创新创业训练计划项目”(S202510610343)。

作者简介: 王子嘉(2004-), 女, 大学本科。

通讯作者: 刘晓宇(1987-), 女, 博士, 副教授。

引用格式: 王子嘉, 王昊燃, 冯晨, 等. 基于 CycleGAN 改进的晶圆缺陷图数据增强方法[J]. 计算机测量与控制, 2026, 34(4): 208-214, 223.

工和浅层学习已经不能满足识别需求。近年来, 基于机器学习的识别方法在识别晶圆模式缺陷上取得了一定进展, 研究者们基于 CAMNet^[4], ResNet^[5], YOLO^[6], U-Net^[7]等卷积神经网络框架实现了晶圆缺陷的分类检测, 深度残差和注意力模块的加入增加了模型的特征提取能力, 模型平均精确度提高。但是由于在高端工艺的半导体制造领域事故发生的概率低且收集缺陷数据成本高, 不同事故出现的概率相差极大, 晶圆缺陷数据集有个数少和极不均衡的特点。由于深度学习模型训练的效果很大程度上依赖于数据集, 很多方法广泛地出现样本数较少的缺陷模式识别精确度较低的问题。

于是, 克服晶圆数据集不平衡问题成为研究晶圆缺陷分类检测的关键, 研究者们通过多图像裁剪分割^[8], 降噪数据增强框架^[9], 卷积自编码器^[10]等方法实现晶圆数据库的扩张, 虽然在一定程度上提升了晶圆图识别模型的识别性能, 但是生成样本多样性低且有失真现象, 容易破坏原图中的重要特征。针对这些问题, 近年来基于生成对抗网络 (GAN, generative adversarial network) 的数据增强技术不断发展, GAN 网络通过生成器和判别器的博弈进行训练, 可以通过学习图像特征将随机噪声迁移为目标图像, 被广泛应用到了数据增强中。但是传统的 GAN 模型需要用大量的数据库进行训练, 用于小规模数据集则与增强的目的矛盾, 于是研究者们对 GAN 模型进行了改造, 文献 [11] 以循环一致性对抗网络 (CycleGAN, cycle-consistent adversarial network) 为基本框架, 将 CBAM 注意力机制嵌入到生成器的残差模块中, 成功实现了对于极少数量的水稻叶片病害图像增强, 使 YOLOv5s 模型的病害检测精度从 79.7% 提升至 93.8%。文献 [12] 将渐进式解码特征融合策略和多尺度特征融合技术与 GAN 融合, 用于两个独立的小样本行星齿轮箱故障数据集增强, 显著降低了生成图像的 FID 指数。文献 [13] 在 DCGAN 模型框架下提出一种用于工件数据集的数据增广方法 MSR-GAN, 有效解决了工业图像收集难样本少的问题。在晶圆缺陷的数据扩张上 GAN 也有了一定的应用, 文献 [14] 在研究 YOLOv3 网络提升晶粒缺陷检测训练前, 使用 GAN 网络生成伪缺陷数据集与真实数据集混合训练。文献 [15] 结合 LSGAN 理论及深度残差网络思想基于 CycleGAN 提出了晶圆图故障图案数据增强模型 CycleGAN-WMG, 使得两种少数类样本类型的分类 F_1 值相较于数据增强前分别提高了 5.5% 和 7.2%。

这些研究虽然对晶圆缺陷数据用到了基于 GAN 的处理方法, 但是都作为训练模型前的预备步骤, 研究重点不在图像增强, 实验验证重点都在对最后模型精度的提高, 缺乏生成晶圆缺陷图像质量指标。为此本文提出了一种基于 CycleGAN 改进的晶圆缺陷图数据增强方

法。基于 CycleGAN 的框架, 在生成器残差模块中引入超轻量级子空间注意力机制 (ULSAM, ultra-light-weight subspace attention module), 有效捕捉特征图跨通道信息, 以较少参数和计算量实现多尺度和多频率特征学习。在判断器中加入全局平均池化层和全连接层减少局部过拟合, 减少判断信息丢失。通过使用激活函数 PReLU 帮助更好的收敛模型。训练模型完成后, 借助图像质量评价指标 SSIM 和 FID 评价生成图像的相似性和多样性, 设置多个对比实验验证模型效果。最后, 将数据增强处理前后的数据集分别投入百度 AI 平台进行分类检测模型训练, 验证迁移前后对于模型检测精度的提升。

1 对 CycleGAN 模型改进的核心技术原理

1.1 循环一致性对抗网络结构与原理

CycleGAN^[16]是一种生成式对抗网络的变体, 近年来在图像风格迁移等领域得到广泛应用。区别于其余 GAN 模型, 它不再是从零开始创建数据样本, 而是通过两套生成器和判别器的交叉博弈学习两个域之间的数据转换映射关系, 同时循环一致损失函数和一致性损失函数的加入实现了无配对数据的领域迁移。

CycleGAN 的模型结构能很好地实现从一个域到另外一个域的风格迁移, 但是由于本研究利用 CycleGAN 结构进行图像增强, 本质上是对一类图像的处理, 所以让生成器的源域和目标域都直接来自实际待增强的晶圆缺陷图像, 通过类内风格迁移来完成数据增强。这种做法借鉴了图像风格迁移领域的研究, 避免从随机噪声出发带来的生成不稳定问题, 同时也能保证生成图在纹理和结构上更贴近真实图像, 这样不仅可以大幅度增加模型训练的速度, 还可以减小生成器生成图像的难度, 提高生成效果。本研究的 CycleGAN 模型结构设计如下: 将一类晶圆图训练集随机平分成两半, 分别作为 A 域和 B 域, 将 A 域中的晶圆图 a 输入生成器 A2B 得到具有 B 域中晶圆图故障图案特征的伪造晶圆图 a2b, 与 B 域中的真实晶圆图 b 一起输入判别器 B 进行判断, 使得生成器 A2B 及判别器 B 在博弈中进行训练; 然后让生成器 B2A 学习到从伪造的晶圆图样本 a2b 到 A 域的映射, 实现 A 域中的图像 a 经过两个生成器生成一个具有 a 特征的图像 a', 最后加入循环一致性损失函数进行检验, 达到纳什均衡, 则为训练完成, B 域的数据训练方式同理, 本研究模型结构如图 1 所示。

1.2 超轻量级子空间注意力机制

ULSAM^[17]是一种专为紧凑型卷积神经网络 (CNN, convolutional neural network) 设计的新型注意力模块, 旨在高效学习跨通道信息, 实现多尺度和多频率特征表示, ULSAM 机制模型结构如图 2 所示。

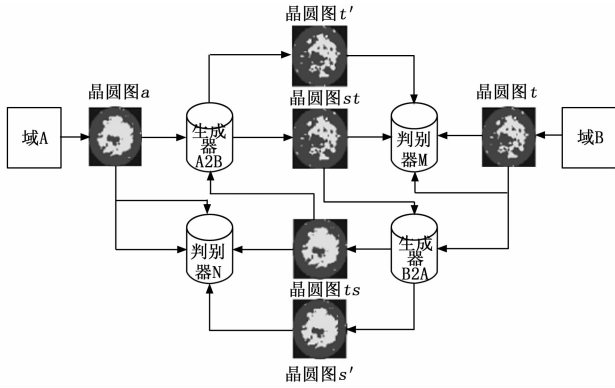


图 1 基于循环一致性对抗网络设计的模型结构

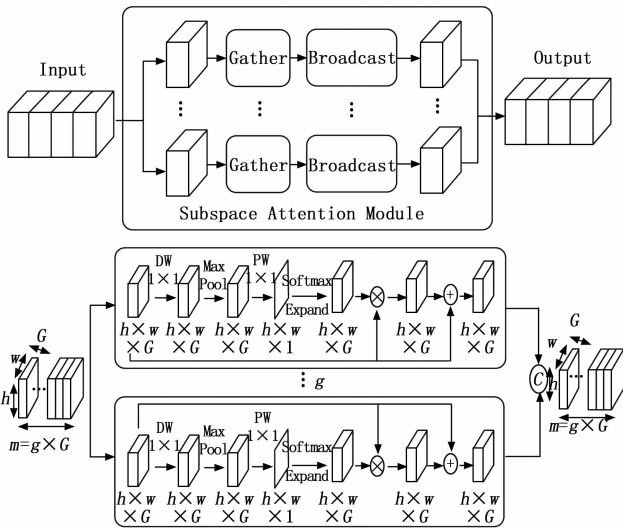


图 2 超轻量级子空间注意力机制模型结构图

其网络结构中输入来自中间卷积层的特征图 $F \in Rm \times h \times w$ ，其中 m 为输入通道数， h 、 w 为特征图空间维度。ULSAM 将其划分为 g 个互斥组 $[F_1, F_2, \dots, F_n, \dots, F_g]$ ，每组有 G 个特征图 ($m = g \times G$)。对每组 F_n ，先进行 1×1 深度卷积，再用核大小为 3×3 、填充为 1 的最大池化突出局部信息区域，接着进行仅含一个滤波器的点卷积，最后经 softmax 激活得到注意力图 A_n ，公式为：

$$\hat{A}_n = \text{softmax}\{PW1 \{ \max\text{pool}^{3 \times 3, 1} [DW^{1 \times 1} (F_n)] \}\} \quad (1)$$

将注意力图 A_n 与原特征图组 F_n 进行元素相乘 (\otimes) 后再元素相加 (\oplus)，得到细化后的特征图组 F_n ，即：

$$\tilde{F}_n = (A_n \otimes F_n \tilde{n}) \oplus F_n \quad (2)$$

最后将所有组的细化特征图按通道维度拼接，得到 ULSAM 的最终输出：

$$\tilde{F} = \text{concat}[\tilde{F}_1, \tilde{F}_2, \dots, \tilde{F}_n, \dots, \tilde{F}_g] \quad (3)$$

在晶圆表面缺陷图像预处理领域，ULSAM 优势显著。在注意力图生成阶段，ULSAM 先执行深度卷积，

后续点卷积仅采用单个滤波器，且每个特征子空间仅生成一个注意力图，大幅降低计算量。在特征表示方面，ULSAM 通过将特征图划分子空间并推断独立注意力图，高效生成多尺度特征，有助于在多缺陷检测中精准定位。同时，ULSAM 为不同特征子空间的注意力图赋予特定权重，实现对高低频特征的差异化学习，能够敏锐捕捉细微缺陷，提升检测的准确性与可靠性。

1.3 PReLU 激活函数函数

PReLU 函数^[18]是一种 ReLU 的改进函数，函数图像如图 3 所示，函数表达式为：

$$\text{PReLU}(x) = \begin{cases} x, & x > 0 \\ ax, & x < 0 \end{cases} \quad (4)$$

其中： a 表示第 i 个通道的输入，当 $a=0$ 时，退化成为 ReLU 函数，当 a 为固定小值时，则等价于 Leaky ReLU 函数。此函数的优点是在负数区域引入可学习的参数，而非零，即使输入为负时梯度也不为零，保证梯度的持续流动，减少神经元死亡的风险，帮助更好地收敛，并以可忽略不计的额外计算成本提高精度。




图 3 激活函数图像

2 模型设计

2.1 生成器设计

生成器的主要目的是学习晶圆缺陷图像特征，生成逼真的图像骗过判断器。生成器整体框架借鉴文献^[19]提出的轻量卷积网络结构，整体采用编码—译码的思路。生成器的模型结构如图 4 所示，首先在 第一层使用 7×7 大卷积核覆盖到晶圆图的更多像素，进行初次特征提取。接着用两层卷积层实现下采样，每次减少一半分辨率，提高感受野。中间的特征转换部分使用 9 个深度残差块^[20]，并在每一个残差块的两层卷积之间加入 ULSAM 注意力模块，高效生成多尺度特征，让残差网络选择性强化关键信息，而非盲目加深，有效提高特征表示能力。由于残差块通过恒等映射加快了前后特征图之间的信息流通，使特征学习更加高效，ULSAM 的引入进一步增强了这种信息传递的选择性，通过划分多个子空间并在各子空间内建模通道依赖关系，引导网络重点关注缺陷区域特征，有效提高了整体特征表示的精度与泛化能力。解码器的设计和编码器对应，采用两层反置卷积，在放大图像的同时，恢复更多高频信息，使图像更清晰。最后借助 Tanh 激活函数将数据归一到 $[-1, 1]$ ，使得输出图像的像素值适用于

标准化的图像数据格式。整个生成器层与层之间采用 PReLU 激活函数, 相较于 ReLU 而言, 解决了梯度消失和神经元死亡问题, 与 ULSAM 配合共同构成轻量化、高响应性的特征学习通路, 前者保障了梯度流动稳定性, 后者提升了空间特征选择性, 两者协同作用提高了模型收敛速度和训练稳定性。

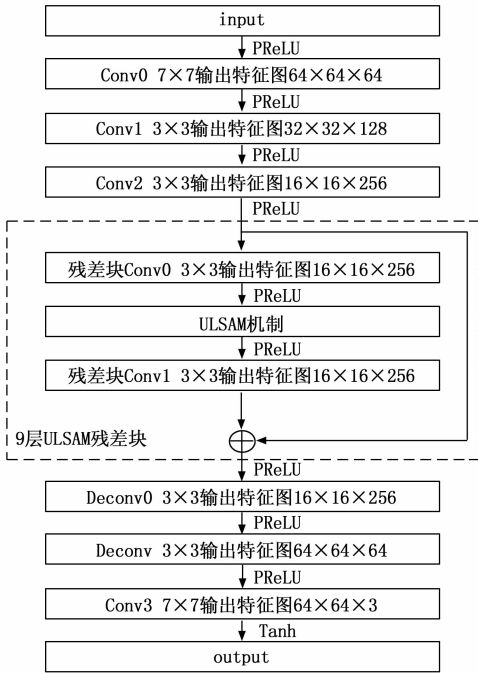


图 4 生成器结构图

2.2 判别器设计

原始 CycleGAN 的判别器设计首层粗略提取特征之后, 直接采用 3 层卷积进行下采样提取特征, 压缩太激进, 容易丢失细节信息。本研究考虑到晶圆图的特性, 采用 CycleGAN-WMG^[15] 的判别器设计, 先用两层卷积层来提取特征, 保持更多细节信息。在第三层加入一个 2×2 的最大池化层, 有效地减少冗余信息, 提高鲁棒性; 之后用两层卷积来进一步提取晶圆图特征; 卷积层后采用全局平均池化来将 8×8 的特征图降到一维, 避免过度依赖局部特征, 直接采用全连接层而导致判别器参数量暴涨; 其后加入 3 个全连接层平稳传递信息, 减速信息丢失。最后使用 Sigmoid 作为逻辑函数来将特征映射到 0 到 1 的概率中, 以便于判断晶圆图的真伪。这个判别器提取全局特征的能力更强, 能保留更多的判断信息, 训练出更好的生成器, 判别器模型结构如图 5 所示。

2.3 损失函数

在对 GAN 的训练中, 损失函数的设计对模型的性能至关重要。本研究采用的模型结合了 CycleGAN 的框架, 并引入了 ULSAM 模块以增强特征提取能力。损失函数主要由 3 部分组成: 对抗损失 (Adversarial Loss)、循环一致性损失 (Cycle-Consistency Loss) 和

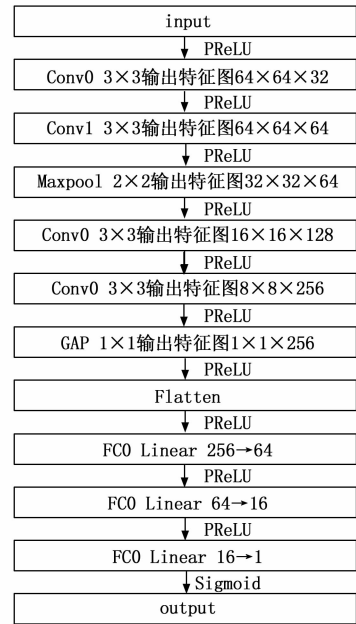


图 5 判别器设计图

身份损失 (Identity Loss)。通过这三者的结合, 实现了高质量的图像转换, 对抗损失确保生成图像的逼真性, 循环一致性损失保持图像内容的语义一致性, 身份损失则增强了生成器的稳定性。

生成器的总损失是上述 3 部分损失的加权和, 其表达式为:

$$L_G = L_{GAN(A \rightarrow B)} + L_{GAN(B \rightarrow A)} + \lambda L_{cycle} + \beta L_{identity} \quad (5)$$

其中: L_{GAN} 、 L_{cycle} 和 $L_{identity}$ 分别为生成对抗损失、循环一致性损失和身份一致性损失; λ 为循环一致性损失的权重系数; β 为身份一致性损失的权重系数。

判别器的总损失是对真实图像和生成图像的对抗损失的均值:

$$L_{DA} = \frac{1}{2} \{ E_{x_A \sim p_{data}(x_A)} \{ [D_A(x_A - 1)]^2 \} + \frac{1}{2} \{ E_{x_B \sim p_{data}(x_B)} \{ [D_A[G_{B \rightarrow A}(x_B)]^2 \} \quad (6)$$

其中: D_A 分别为域 A 的判别器; x_A 、 x_B 分别表示来自域 A 和域 B 的真实图像图像; $G_{B \rightarrow A}$ 表示从 B 域转化到 A 域的生成器, 判别器 B 的损失函数同理设计。

3 实验与结果

3.1 数据集预处理

本研究采用目前行业中规模最大的数据集 WM-811K^[19] 来进行训练和测试。该数据集共包含 811 457 个晶圆图数据, 其中有 172 950 张晶圆图由有经验的专家进行了标注。标签共分为 8 种缺陷类型: Center (中心缺陷)、Donut (甜甜圈缺陷)、Edge-local (边缘局部缺陷)、Edge-ring (边缘环状缺陷)、Local (局部缺陷)、Near-full (近全覆盖缺陷)、Random (随机缺陷)、

Scratch (划痕缺陷) 以及一种无缺陷类型: None (无缺陷)。其典型案例图以及缺陷数据分布饼状如图 6 所示。

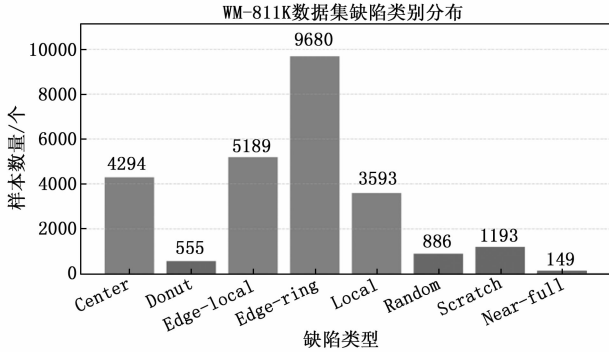


图 6 数据集缺陷分布张数分布图

从数据分布图中可以观察到, 该数据集存在严重的分布不均匀, 其中的 Donut 类、Random 类及 Nearfull 类数量远低于其余种类, 在多个现有研究中表明前两种类别由于数据不平衡的原因 Donut 类和 Random 类的分类精度不高, Nearfull 类虽然个数少但是特征特别明显所以在识别精度很高, 所以本研究选择 Donut 和 Random 两类为研究对象。由于初始数据集的晶圆图尺寸大小不同, 噪声较大, 本研究先在 MATLAB 上将这两类数据尺寸归一化为 64×64 , 再使用中值滤波对图像进行了降噪, 完成实验数据集预处理。在这两类缺陷图像中, 主特征区域轮廓较为清晰、结构稳定, 中值滤波能够有效去除边缘毛刺及局部伪影, 提升图像质量的同时基本不损失主特征信息。相比之下, 其他缺陷类型如 Scratch 类通常具有细长、边界模糊的特征结构, 若直接采用相同的降噪策略, 可能会导致特征模糊甚至关键信息丢失, 因此在本研究中未统一对所有类别使用该预处理流程。当前预处理策略主要服务于 Donut 与 Random 两类图像增强任务, 后续将针对不同缺陷类型设计更具针对性的预处理方案, 以避免潜在偏差并提升整体模型适应性。接着, 将原始数据集按照 4:1 的比例划分为训练集和后期评估集, 用于模型训练与效果验证。由于 CycleGAN 属于典型的无监督图像转换模型, 在训练过程中并不依赖于一一对应的图像对, 而是分别从源域和目标域中随机抽取图像进行学习, 从而大大简化了数据准备工作。相比传统的有监督学习方法, CycleGAN 无需手工标注或构建精确配对样本, 降低了数据构建的复杂性, 尤其适用于晶圆图像这类难以获得配对图像的任务。在模型训练完成之后, 采用独立划分的评估集进行生成图像的效果测试, 结合多项图像质量指标对模型性能进行量化分析。通过从未参与训练的数据上进行评估, 可以有效避免模型因过拟合训练集而导致的评估偏差, 从而更客观、真实地反映模型的泛化能力与实际应用价值。

3.2 实验配置

本次实验的环境配置如表 1 所示。

表 1 实验环境配置表

名称	环境配置
操作系统	Windows 11 64 位
GPU	vGPU-32 GB
深度学习框架	Pytorch 2.3.0
Python	Python 3.12
CUDA	12.1

深度学习训练参数配置如表 2 所示, 前 100 轮学习率保持在 0.002, 100 轮后开始衰减。

表 2 训练参数配置表

名称	训练配置
batchsize	1
lr	0.002
n_epoch	200
decay_epoch	100

3.3 评价指标

评价 GAN 生成图像主要考虑逼真度、多样性、结构一致性等因素, 通常的评价指标包括常见指标包括结构相似性 (SSIM, structural similarity index)、峰值信噪比 (PSNR, peak signal-to-noise ratio) 与 Fréchet Inception 距离 (FID, Fréchetinception distance) 等。由于本研究针对的晶圆缺陷图像具有尺寸小、细节密集的特点, 使用 PSNR 等传统误差指标难以准确反映图像的结构质量与视觉感知效果, 且不能评估图像分布的多样性。相比之下, SSIM 强调结构保真性, FID 评估生成图像与真实图像在特征空间中的分布差异, 能够同时衡量图像的相似性和多样性。二者结合可从互补角度全面评估增强图像的质量与有效性, 因此被选为本研究的主评估指标。

FID^[20] 指标可评估生成的仿真缺陷图像与真实缺陷图像的相似程度。在使用生成对抗网络扩充晶圆缺陷数据集时, FID 指标能直观反映生成图像在特征层面与真实缺陷图像的匹配度。FID 值较低时, 生成的缺陷图像在大小、形状等特征上更接近真实情况, 用于训练模型可提升对晶圆表面缺陷的检测精度和识别能力, 避免模型误判或漏判。

SSIM^[21] 指标通过对比图像的亮度、对比度和结构 3 个关键要素, 综合判断图像之间的相似程度, 取值范围在 -1~1 之间, 越接近 1 表示图像越相似。在本研究中, SSIM 被用于评估 GAN 所生成的晶圆缺陷图像在结构层面与原始图像的一致性, 尤其关注缺陷区域的还原程度。较高的 SSIM 值说明生成图像能够有效保留缺陷的几何结构与纹理特征, 提升其在训练过程中的实用

性; 反之则可能表明模型未能充分学习到目标缺陷的结构特征。因此, SSIM 可作为衡量增强图像结构保真度的重要依据, 保障生成样本对下游分类任务的有效支持。

3.4 实验结果分析

3.4.1 不同模型性能对比

在训练集上分别训练本模型, 原始 CycleGAN 模型 CycleGAN-ResNet6, CycleGAN-ResNet9, CycleGAN-WMG, 在 Donut 和 Random 类别采用相同测试集进行晶圆缺陷图生成, 此处列出不同模型处理后得到的同源 9 张生成图片图像。

如图 7 所示, CycleGAN 基本框架的两类模型生成图片和本方法相比虽然相似度不低, 但是特征边缘非常模糊, 特征表达能力差。CycleGANWMG 处理后的模型, 分辨率很低, 图像失真严重。为了对生成图片进行质量客观评价, 本实验获取了 4 种网络的 SSIM 和 FID 值, 结果如表 3 所示, 在 Donut 类别中本模型的 SSIM 值相较于原始 CycleGAN 模型 6 残差块和 9 残差块结构分别提升 0.203 4 和 0.154 2, FID 值下降 84.95 和 104.40, 同样在 Random 中本研究的 SSIM 值高于另外 3 种, FID 值明显降低, 以上数据充分证明了生成图片相较于原数据集真实度和多样性提高, 特征提取的效果更准确, 结构相似度更高除了图像质量指标的对比, 本研究还对 4 种模型在训练效率和资源消耗方面进行了分析。同时, 在结构设计上, 本模型虽然引入了注意力机制, 但整体网络更加轻量, 在相同训练条件下的计算资源消耗低于原始 CycleGAN 的 9 残差块结构, 也优于 CycleGAN-WMG 模型。虽然只从训练时间上看, 6 残差块模型训练更快, 但综合稳定性表现, 本模型在保证图像生成质量提升的同时, 还实现了更高的计算效率和更好的模型鲁棒性, 更适合在资源有限的实际场景中部署使用。




图 7 不同模型生成图片对比

表 3 不同模型增强的图片 SSIM 和 FID 数据对比

不同模型	SSIM		FID	
	Donut	Random	Donut	Random
CycleGAN-ResNet9	0.724 3	0.802 2	153.31	161.91
CycleGAN-ResNet6	0.773 5	0.822 3	140.28	113.43
CycleGAN-WMG	0.851 5	0.916 4	184.09	207.71
Ours	0.927 7	0.958 6	68.36	57.51

3.4.2 不同注意力机制模块性能对比

为了充分验证本研究提出的 ULSAM 注意力模块

在晶圆缺陷特征提取方面的优势, 本文在其他条件保持一致的前提下, 设计了多组对照实验。具体而言, 本研究将 3 种典型的注意力机制, 即卷积块注意力机制 CBAM、通道注意力机制 ECA 以及本研究提出的不确定性感知局部空间注意力机制 ULSAM, 分别嵌入至原始 CycleGAN 模型以及改进后的 CycleGANWMG 模型的残差块中, 并采用与前述实验相同的评估方法进行性能比较。和上述实验采用相同的验证方式, 加入 ULSAM 之后的模型在 Donut 和 Random 两类中进行训练后生成的晶圆缺陷图, 由表 4 可以看出, 相较于其余两种注意力机制, 无论实在哪一种模型上面, SSIM 值最高, FID 最低, 说明生成图片的效果最好。

如表 4 所示, 实验结果充分验证了 ULSAM 注意力模块在晶圆缺陷图生成任务中的显著性能优势。与仅建模通道间依赖关系的 ECA 模块相比, ULSAM 通过引入独立的空间注意力图, 显著扩大了有效感受野, 增强了对局部细节的捕捉能力; 相比依赖全局池化提取特征的 CBAM 模块, ULSAM 能够针对不同特征子空间分配更加合理的注意力权重, 从而提升了特征学习效率与表示精度。综合来看, ULSAM 具有更强的特征感知能力与缺陷识别鲁棒性, 能够更加敏锐地捕捉晶圆图中复杂且细微的缺陷模式。

表 4 不同注意力模块增强的图片 SSIM 和 FID 数据对比

不同注意力模块	SSIM		FID	
	Donut	Random	Donut	Random
CycleGANWMG-CBAM	0.843 0	0.890 2	186.94	231.6
CycleGANWMG-ECA	0.842 4	0.917 7	180.14	252.75
CycleGANWMG-ULSAM	0.844 8	0.925 2	177.61	251.49
CycleGAN-CBAM	0.635 7	0.819 7	228.057	116.99
CycleGAN-ECA	0.742 7	0.875 5	143.69	93.45
CycleGAN-ULSAM	0.850 8	0.939 9	88.35	67.06

3.4.3 消融实验

为了系统验证本模型中各模块优化策略的有效性, 本研究设计了一组有针对性的消融实验。在原始的 CycleGAN 模型基础上, 依次引入 3 项结构改进, 包括激活函数的优化、判别器结构的调整以及注意力机制模块 ULSAM 的融合。每组实验在前一版本模型的基础上叠加一个改进项, 逐步评估各部分优化对图像生成性能的具体贡献。

实验结果如表 5 所示, 每引入一项优化后, 生成图像的结构相似度 SSIM 指标稳步提升, 说明图像与真实图像在结构信息上的一致性增强。同时, 生成图像的 FID 指标持续下降, 说明生成图与真实图在整体分布和视觉效果上更加接近。此外, 为更全面地评估各模块对模型整体性能的具体贡献, 进一步补充了 3 项模块的两

两组合实验,以分析不同组合策略对分类性能与生成效果的影响。实验结果表明,3者相互配合时的整体性能最优。其中,单独引入判别器结构改进虽然能够显著提升图像与真实图的结构相似度,但对生成图像的多样性改善作用有限;而仅增加注意力模块 ULSAM 而不配合判别器优化时,其性能提升并不显著;激活函数 PReLU 本身的优势也只有在与其它模块联动使用时才能充分发挥作用。

表 5 消融实验结果

消融实验类型	SSIM \uparrow		FID \uparrow	
	Donut	Random	Donut	Random
CycleGAN-ResNet9	0.724 3	0.802 2	153.31	161.91
CycleGAN+PRELU	0.780 8	0.827 2	139.65	135.75
CycleGAN+PRELU+ULSAM	0.831 9	0.905 2	121.35	107.34
CycleGAN+ULSAM+WMG-D	0.922 8	0.934 8	76.86	60.43
CycleGAN+PRELU+WMG-D	0.952 7	0.978 9	87.60	86.16
CycleGAN+PRELU+WMG-D+ULSAM	0.927 7	0.958 6	68.36	57.5

综合以上结果,模型中的每一项结构优化都对生成质量产生了积极影响,各模块在生成与分类两个维度上具有明显的协同增强效应,3者协同作用后模型性能提升更加显著,这充分验证了所提出方法在提升晶圆缺陷图像生成质量方面的有效性和实用性。

3.4.4 数据增强效果验证

百度 AI 技术能够以快速而准确的方式,根据生产过程中的缺陷特征来进行缺陷检测和分类,为提高晶圆质量提供了可靠的技术支持^[24]。基于百度 AI 技术训练模型高效快捷的优势,本研究在百度智能云 EasyDL 开发平台验证本研究网络生成晶圆缺陷图像样本的有效性。首先取 Center,5类多数数据集各 1 000 张,3类好数据保留其原始张数,组成数据迁移前数据集,然后通过数据增强的方法仅处理 Donut 和 Random 类,扩张其数据集到 1 200 张,其余数据数量不变,得到数据迁移后数据集,将两数据集分别投入百度 AI 平台进行模型训练分类模型,如表 6 所示,两模型训练结果对比得出,经过数据处理后 Donut 和 Random 类别的准确度分别提高 1.1%和 7.2%, F_1 指数提高 1%和 4%,总模型的准确率提高 2.3%, F_1 提高 1.6%,由此验证了本数据增强方法的有效性,扩充后的数据集有效提升了模型的性能。

表 6 百度 AI 平台训练模型性能数据 %

迁移数据前	迁移数据后		数据类别	
	准确率	F_1	准确率	F_1
Donut	97.1	97.0	98.2	98.0
Random	88.5	93.0	95.7	97.0
总模型	91.6	92.2	93.9	93.8

4 结束语

晶圆缺陷的分类检测对于提升晶圆良率至关重要。然而,由于某些缺陷类型的样本量较少,数据集存在不平衡问题,导致单类识别精度下降。为此,本文提出了一种基于改进循环一致性对抗网络的晶圆缺陷图数据增强方法。在生成器的残差块中创新引入超轻量级子空间注意力机制,与现有研究相比增强了模型对晶圆缺陷细节特征的提取能力;在判别器结构和激活函数方面进行了优化,提升了模型训练的稳定性 and 图像生成质量。与现有对晶圆缺陷增强研究不同,本文用 SSIM 和 FID 指数对于增强后的图片质量进行了客观评价,并且在 Donut 和 Random 两类上分别进行了多模型对比实验,不同注意力模块对比实验,和消融实验,充分验证了所加模块的有效性,生成图片质量显著升高。此外,本文创新利用了百度 AI 平台进行了数据集扩展效果的验证与现有方法相比,效率更高,分类精度与 F_1 均显著提升。该方法不仅有效提升了少数类缺陷图的生成质量,也为缓解晶圆缺陷数据不平衡问题提供了可行路径。未来工作将进一步提升模型的稳定性,并扩展其在晶圆缺陷检测模型训练中的应用,为保障晶圆高良率、提升芯片质量提供技术支持。

参考文献:

- [1] 姜冠男,施 琴. 芯片产业国际化趋势及对我国芯片标准国际化发展的影响 [J]. 标准科学, 2024 (4): 10-15.
- [2] 王雨芹,粟雅娟,苏晓菁,等. 面向晶圆图缺陷模式识别的机器学习方法综述 [J]. 微纳电子与智能制造, 2023, 5 (2): 22-29.
- [3] 史浩琛,金致远,唐文婧,等. 基于深度学习的高精度晶圆缺陷检测方法研究 [J]. 电子测量与仪器学报, 2022, 36 (11): 79-90.
- [4] KANG D Q, LAI J H, HAN Y. Improving surface defect detection with context-guided asymmetric modulation networks and confidence-boosting loss [J]. Expert Syst. Appl., 2023, 225: 120121.
- [5] YUNG, LI X, XU Q, et al. Research on wafer surface defect pattern detection method based on incremental learning [J]. J. Phys. :Conf. Ser., 2021, 2078 (1): 012046.
- [6] 于志斌,胡 泓. 基于 YOLO 算法与机器视觉的晶圆片表面缺陷检测研究 [J]. 新型工业化, 2021, 11 (12): 114-117.
- [7] CHA J, JEONG J. Improved U-net with residual attention block for mixed-defect wafer maps [J]. Appl. Sci., 2022, 12 (4): 2209.
- [8] OCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [EB/OL]. ArXiv: 2004.10934, 2020.

(下转第 223 页)