

# 基于 MSAF-DeSTSeg 的微弱缺陷分割算法

顾 懿<sup>1,2</sup>, 童 浩<sup>1,2</sup>, 吴静静<sup>1,2</sup>, 赵迎龙<sup>3</sup>, 魏 斌<sup>3</sup>

(1. 江南大学 机械工程学院, 江苏 无锡 214122;

2. 江苏省食品先进制造装备技术重点实验室, 江苏 无锡 214122;

3. 江苏省特种设备安全监督检验研究院 无锡分院, 江苏 无锡 214000)

**摘要:** 晶圆表面质量影响产品寿命, 需及时检测异常以降低成本, 但异常样本难收集且形态多样, 有监督学习算法受限, 为此提出了一种基于 MSAF-DeSTSeg 的晶圆表面异常检测算法; 利用知识蒸馏 DeSTSeg 网络分割晶圆异常区域, 引入多尺度技术用于特征输出阶段防止出现特征丢失, 在网络的分割头位置设计可变形卷积空间金字塔池化模块, 增强复杂异常感知并抑制背景干扰; 技术创新点包括多尺度特征融合技术和可变形卷积快速空间金字塔池化模块的应用; 实验结果表明, 在晶粒数据集上, 改进后的模型在图像 AUC、平均像素精度和实例像素精度上分别达到了 97.79%、73.06% 和 71.77%; 经实际应用, 该算法在无缺陷样本下满足晶圆异常检测需求, 性能优于原模型。

**关键词:** 晶圆; 无监督异常检测; 知识蒸馏; 多尺度融合; 可变形卷积注意力

## Weak Defect Segmentation Algorithm Based on MSAF-DeSTSeg

GU Yi<sup>1,2</sup>, TONG Hao<sup>1,2</sup>, WU Jingjing<sup>1,2</sup>, ZHAO Yinglong<sup>3</sup>, WEI Bin<sup>3</sup>

(1. School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China;

2. Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment and Technology, Wuxi 214122, China;

3. Wuxi Branch of Jiangsu Institute of Special Equipment Safety Supervision and Inspection, Wuxi 214000, China)

**Abstract:** The quality of wafer surfaces directly affects product lifespan, which requires timely anomaly detection to reduce costs. However, it is difficult to collect abnormal samples with diverse morphologies, limiting the effectiveness of supervised learning algorithms. To address this, an MSAF-DeSTSeg-based algorithm for detecting wafer surface anomalies is proposed. This approach utilizes the knowledge distillation network DeSTSeg to segment anomaly regions on wafers, incorporating multi-scale technology during the feature output stage to prevent feature loss. A deformable convolutional spatial pyramid pooling module is designed at the segmentation head of the network to enhance the perception of complex anomalies and suppress background interference. The technical innovations include the application of the multi-scale feature fusion technology and the deformable convolutional fast spatial pyramid pooling module. Experimental results indicate that on a grain dataset, the improved model achieves the accuracy rates of 97.79%, 73.06%, and 71.77% in terms of image AUC, mean pixel accuracy, and instance pixel accuracy, respectively. Through practical application, the algorithm meets the demand for detecting wafer anomalies in the absence of defect-free samples, outperforming the original model.

**Keywords:** wafer; unsupervised anomaly detection; knowledge distillation; multi-scale fusion; deformable convolutional attention

## 0 引言

晶圆异常的情况极为复杂多变, 它们会在诸如光刻、化学腐蚀等一系列精密工艺过程中, 产生各种难以预测且形态无规则的异常缺陷。这些缺陷不仅种类繁

多, 而且往往呈现出高度随机性和不可预见性。这些异常问题的存在, 会严重削弱后续产品的使用性能, 甚至在某些极端情况下, 可能导致安全隐患的出现。因此, 对晶圆表面质量进行严格的异常缺陷检测, 就显得尤为重要且迫切<sup>[1]</sup>。

收稿日期:2024-10-21; 修回日期:2024-12-02。

作者简介:顾 懿(2000-),男,硕士研究生。

通讯作者:吴静静(1982-),女,博士,副教授,硕士生导师。

引用格式:顾 懿,童 浩,吴静静,等. 基于 MSAF-DeSTSeg 的微弱缺陷分割算法[J]. 计算机测量与控制, 2025, 33(12):189-195, 214.

在过去,传统的检测方法主要依赖于人工目视检测。然而,这种方法存在诸多弊端。一方面,工人的培训难度较大,需要花费大量的时间和精力来熟悉和掌握检测技能;另一方面,人工检测容易受到视觉疲劳和生理困乏等主观因素的影响,难以长时间保持高标准的检测状态<sup>[2]</sup>。因此,检测结果的客观性和准确性往往无法得到较好的保证。并且,晶圆异常形态各异,种类繁多,同时这些区域还具有复杂背景的情况,会对缺陷的成像造成干扰<sup>[3]</sup>,晶圆在制造过程中,对工艺控制和缺陷标准的要求极为严苛,即便是最微小的缺陷也可能对最终产品的性能和可靠性产生重大影响。因此,在复杂多变的背景环境下,需准确识别并检测这些微弱的缺陷,这对缺陷识别技术提出了前所未有的挑战<sup>[4]</sup>。传统的图像滤波方法虽然在一定程度上能够抑制背景噪声的干扰<sup>[5]</sup>,但在面对缺陷极其微弱且与背景差异细微的情况时,这类方法往往难以在保证背景抑制的同时,有效地保留缺陷目标的完整信息<sup>[6]</sup>。

随着科技的进步和自动化技术的发展,目前外观表面检测领域已经逐渐转向采用无接触的方法。其中,机器视觉作为这一领域的代表技术,具有操作简便、维护成本低以及检测精度高等显著优势。自动光学检测平台通过配备高性能的相机等硬件设备,不仅降低了检测成本,还成功克服了人类易于疲劳从而影响检测精度的问题。这些平台可以实现 24 小时不间断地检测运行,大大提高了检测效率和准确性。此外,高精度相机与深度学习技术的结合,更是为晶圆异常缺陷的检测带来了革命性的突破。深度学习算法能够通过对大量样本的学习和分析,提取出缺陷的细微特征和规律,从而对一些复杂且微弱的缺陷实现良好的检测识别精度。这种技术的引入,使得晶圆缺陷检测的效率和准确性得到了显著提升,相较于传统的人工视觉检测方法,展现出明显的优势。早期的研究,如李鹤喜等人<sup>[7]</sup>利用自组织神经网络,证明了无监督聚类在硅片缺陷识别中的有效性。随着深度学习技术的发展,尤其是卷积神经网络(CNN)的应用,晶圆缺陷检测取得了显著进步。深度学习能够自动从数据中提取有效特征,通过多层网络结构逐步抽象出高级特征,有助于更深入地理解图像特征。例如,有学者设计了 CNN-WDI 网络用于晶圆图模式缺陷的识别分类,显著提高了分类准确率<sup>[8]</sup>。Lin 等人<sup>[9]</sup>则利用生成对抗网络(GAN)生成伪缺陷数据集与真实数据集混合训练,结合 YOLOv3 网络提升了晶粒缺陷检测的精度。针对数据不均衡的问题,有研究者采用了过采样或欠采样的方法,并结合基于堆叠的分类器来进行晶圆缺陷的检测和分类<sup>[10]</sup>。然而,这些方法主要针对简单缺陷类型,对于微弱缺陷的检测研究尚显不足,且高度依赖大规模人工标注数据集,这在工业应用中难以

实现。

晶圆表面缺陷具有复杂纹理背景和微弱缺陷的特点,目前国内对于晶圆表面缺陷的研究相比于国外较少,现有主流的缺陷检测方法无法很好地解决复杂晶圆缺陷检测难题。因此,本文针对晶圆缺陷对比度微弱,背景纹理复杂变化等干扰的问题,对原始 DeSTSeg 进行了改进,使用多尺度融合模块对来自教师和学生网络的不同尺度特征图进行有效融合,并加入通道注意力机制增强特征,在分割网络位置加入可变形卷积空间注意力金字塔池化模块,在融合不同尺度特征的同时,有效抑制背景纹理干扰噪声,因此晶圆微弱缺陷得到了较好的分割。最后对网络进行了消融和对比试验验证,对比了不同网络结构模型对于晶圆微弱缺陷的识别精度和效果。

## 1 检测方法

如图 1 所示,晶圆缺陷种类繁多,形态各异。本文拟研究一种基于知识蒸馏的融合多尺度注意力机制的端到端缺陷分割网络模型 MSAF-DeSTSeg 网络,整体流程如图 2 所示。




图 1 复杂背景干扰下的晶粒表面微弱缺陷

此模型基于 DeSTSeg 网络<sup>[11]</sup>,首先在教师网络和学生网络的多层特征输出融合过程中,加入设计的多尺度特征融合模块;其次在分割网络中加入空间金字塔池化可变形卷积注意力机制融合模块,在普通的 SPPF 模块中加入 3 个可变形卷积注意力模块,提升缺陷特征信息的提取能力。通过知识蒸馏的网络结构,从教师网络中获取特征信息,MSAF-DeSTSeg 可以实现无监督异常检测,无需大量标注数据集,即可完成缺陷检测,这对工业场景十分友好,可以有效解决数据标注困难以及未知缺陷检测难的问题。

## 2 晶圆微弱缺陷分割网络模型

### 2.1 MSAF-DeSTSeg 模型总体结构

基于原始 DeSTSeg 模型进行优化改进设计了微弱缺陷分割网络 MSAF-DeSTSeg,整体网络结构如图 3 所示,整体结构使用知识蒸馏的教师-学生网络框架<sup>[12]</sup>,使用合成人工异常图像方法进行训练<sup>[13]</sup>,在学生网络与教师网络输出的部分设计多尺度融合模块(MFFM, multiscale feature fusion module)将来自不同网络的多张特征图有效融合,增强提取长距离上下文信息,加强不同尺度缺陷的特征。经过特征融合后,在分

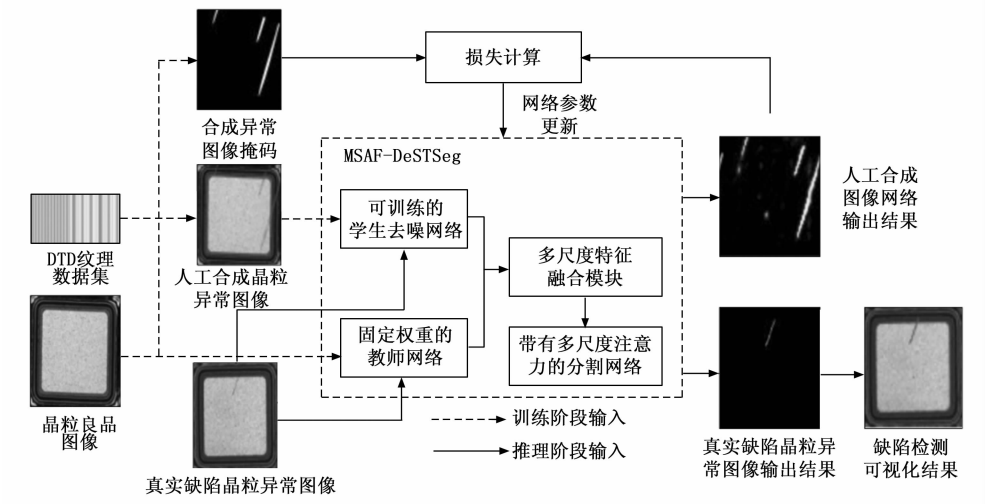


图 2 MSAF-DeSTSeg 晶圆缺陷检测流程图

割网络中加入可变形卷积注意力的空间金字塔池化模块 (DCSASPPF, deformable convolution spatial attention pyramid pooling fast) 进一步融合多尺度特征, 同时模块中的空间可变形卷积注意力机制可以有效区分背景和 目标特征, 抑制背景复杂干扰。

教师模型使用 ResNet18 模型的前 3 个 layer 进行构成, 并使用了基于 ImageNet 数据集预训练的权重。学生模型使用标准 ResNet18 作为编码器, 解码器部分采用与编码器对称的上采样结构<sup>[14]</sup>。教师和学生模型的输出特征图经过融合后, 经过设计的 MFFM 增强模块送入模型训练分为两个阶段, 分别计算不同的损失, 完成相应的蒸馏和分割任务。

第一阶段, 固定教师模型参数, 训练学生模型。教

师模型输入为真实无缺陷图像, 学生模型输入为合成的异常缺陷图像。学生与教师模型输出的 3 张不同尺度的特征图与  $S^1_D, S^2_D, S^3_D$  与  $T^1, T^2, T^3$ , 通过构建  $S$  和  $T$  两部分特征图之间的余弦距离损失, 训练学生网络对于异常区域的去噪能力。

第二阶段, 固定教师和学生模型参数, 训练分割网络。这一阶段的训练过程中, 教师和学生模型的输入数据均为合成的异常缺陷图像, 这些图像旨在模拟实际生产中可能遇到的各种复杂场景和微弱缺陷, 从而确保训练的有效性和针对性<sup>[15]</sup>。由于教师模型是在海量数据集上训练的, 它在异常区域会生成与去噪学生模型不同的特征表示, 再将教师模型 ( $T$ ) 和学生模型 ( $S$ ) 的特征图进行融合, 通过优化分割网络来进一步优化融合

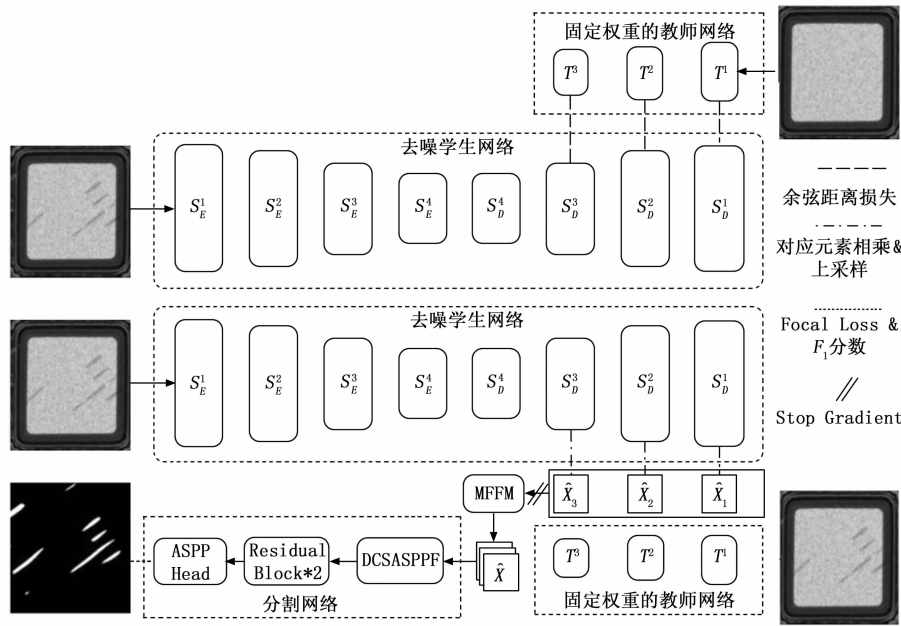


图 3 MSAF-DeSTSeg 模型整体框架

模块的参数, 分割网络的损失为 L1 loss 和 Focal loss。

正常推理过程中, 模型输入为真实的缺陷图像, 通过端到端的模型生成像素级的异常分割图像, 并计算对应的图像级异常得分。

## 2.2 多尺度特征融合模块

多尺度特征融合模块 (MFFM) 目的是解决微弱目标特征在教师模型和学生模型融合下采样后带来的特征丢失问题, 实现微弱目标的语义信息由深层向浅层流动。对应的模块结构如图 4 所示, 首先对最深层语义特征最丰富的特征图进行进一步处理, 使用 YOLOv5 网络中的 CSPBottleneck 结构进行特征提取, CSPBottleneck 加强 CNN 的学习能力, 减少内存消耗, 减少计算瓶颈<sup>[16]</sup>。然后引入通道注意力机制 (CAM, channel attention module) 调整各通道特征权重, 提升对感兴趣区域的关注程度, 抑制其它区域对分割任务带来的干扰。经过通道注意力模块增强后的特征图经过双线性插值上采样 2 倍后与浅层特征图进行拼接操作得到新的特征图, 然后重复之前的操作, 最终输出结果。本文使用的通道注意力模块为高效通道注意力模块 (ECA, efficient channel attention)<sup>[17]</sup>, 其注意力机制的计算公式如下:

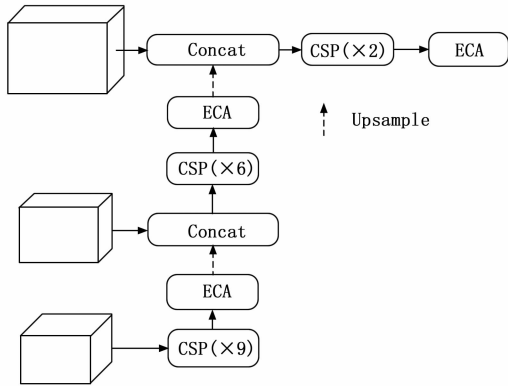


图 4 多尺度特征融合模块

$$\begin{cases} y' = \text{AvgPool}(x) \\ \omega = \sigma[C_1 D_k(y')] \\ y = \omega \otimes x \end{cases} \quad (1)$$

其中:  $x$  为输入特征图,  $\text{AvgPool}$  为平均池化操作,  $C_1 D_k$  为一维卷积,  $k$  为卷积核大小, 根据特征图尺寸可自适应调整核大小,  $\sigma$  为 ReLU 激活函数。经过计算得到各通道权重  $\omega$ , 通过  $\omega$  和输入特征图  $x$  进行按位相乘操作得到最终的输出特征图  $y$ 。

基于多尺度特征融合模块 MFFM 增强网络对不同尺度特征信息的融合处理能力, 相比于原 DeSTSeg 网络直接拼接的方式, 可以更加精确有效地获取信息, 在上采样的过程中使用注意力机制, 其它冗余的无关信息被抑制, 提升后续网络对目标的分割检测能力。

## 2.3 多尺度可变形卷积空间注意力模块

MFFM 模块将来自不同网络 and 不同层级的特征融合后, 对特征语义上的描述能力仍有不足。由于晶粒上的缺陷具有空间尺度跨度大的特点, 后续为了完成高精度的分割任务, 需要对缺陷上下文信息进行增强。空间金字塔池化<sup>[18]</sup> (SPP, spatial pyramid pooling) 是一种通过不同核尺寸的池化操作组合后再进行特征拼接的模块, 最开始是用于处理输出尺寸变化的特征图, 在 YOLOv5 中发展成快速空间金字塔池化 (SPPF, spatial pyramid pooling fast), 实现了局部特征核全局特征的 featureMap 级别的融合, 同时串联的池化方式可以大幅减小计算量, 提升检测速度<sup>[19]</sup>。

空间注意力机制<sup>[20]</sup>可以有效地增强目标的特征信息, 抑制背景干扰。在微弱缺陷分割任务中, 空间注意力机制有效抑制晶粒台面纹理等背景的特征干扰。传统的空间注意力机制中采用普通卷积进行捕捉特征图的位置和语义信息, 这种固定矩形形状的卷积核不利于复杂形状, 特别是修长的目标的特征提取, 会带来很多背景干扰, 普通卷积公式如下:

$$y(p_0) = \sum_{p_n \in R} \omega(p_n) * x(p_0 + p_n) \quad (2)$$

其中:  $p_0$  对应输出特征图上的任意一点, 一般为卷积核的中心点,  $p_n$  为卷积核上每一个点相比较于中心点的偏移量, 该偏移量为固定的整数,  $R$  为偏移量的集合,  $\omega(p_n)$  是该点卷积核上的权重,  $x(p_0 + p_n)$  为特征图上  $p_0 + p_n$  位置的元素值, 最后输出得到  $y(p_0)$ 。

可变形卷积<sup>[21]</sup> (DCN, deformable convolutional network) 是一种通过对卷积核加入额外的偏移量, 该偏移量是通过另一个卷积计算得到, 有额外偏移的卷积方式使其可以自动调整尺度和感受野, 在对目标特征进行采样时可以更贴近物体的形状和尺寸, 计算公式如下:

$$y(p_0) = \sum_{p_n \in R} \omega(p_n) * x(p_0 + p_n + \Delta p_n) \quad (3)$$

式 (3) 在普通卷积公式 (2) 的基础上为每一个偏移点, 再增加一个新的偏移量, 通常是小数。

本文设计一种具有可变形卷积的空间注意力机制 (DCSAM, deformable convolutional spatial attention mechanism), 其具有自适应的感受野调整能力, 同时空间注意力机制可以有效抑制背景干扰, 两者结合能够捕捉到更精细的特征, 提升模型的特征提取能力, 其公式如下:

$$\begin{cases} X' = \text{Concat}[\text{AvgPool}(X), \text{MaxPool}(X)] \\ \omega_s = \text{Sigmoid}[\text{DCN}(X')] \\ y_s = \omega_s \otimes X \end{cases} \quad (4)$$

其中:  $\text{AvgPool}$  为平均池化操作,  $\text{MaxPool}$  为最大池化操作,  $\text{DCN}$  为可变形卷积,  $\omega_s$  为空间注意力机制学习得到的权重,  $X$  为输入特征图,  $X'$  为池化后拼

接后的特征图， $y_s$  为经过空间注意力机制后的输出特征图。

本文设计的带有可变形卷积空间注意力机制的 SP-PF 模块 (DCSASPPF)，具有自适应的不同尺度空间特征表达能力，其结构如图 5 所示。SPPDAM 模块中首先使用 CBS 模块进行处理，然后接 MaxPool 层和 DCAM 模块顺序构成，最后抽取经过不同层处理后的特征图进行拼接操作，最后通过一个 CBS 模块输出。CBS 是由标准卷积 (Convconvolution) 和批量归一化 (BN, batch normalize) 以及 Sigmoid 线性单元 (SiLU, sigmoid linear unit) 顺序构成。为了获取具有不同感受野的特征图，使用 3 个串联的 MaxPool 层，并在每个池化层后面增加设计的可变形卷积空间注意力机制，使得特征图感受野更偏向于目标缺陷形状。通过串联的 3 次池化将得到 4 个不同感受野的特征图，在模块的最后通过拼接操作，并使用 CBS 模块进行进一步融合。DCSASPPF 中最大池化核大小设置为 3，得到的特征图可以较好地表征缺陷的尺度信息，DCSA 的可变形卷积核大小设置为 3，可以对噪声起到抑制作用，进一步强化缺陷特征的提取能力。

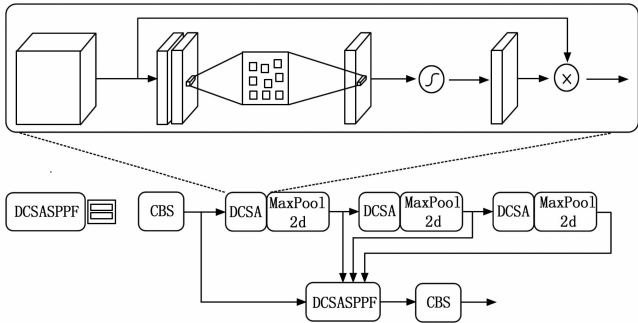


图 5 DCSASPPF 模块结构

3 试验结果与分析

3.1 检测系统搭建

为验证本文基于 MSAF-DeSTSeg 的微弱缺陷检测分割算法的有效性和准确性，以下是本文所搭建的试验平台计算机的详细配置环境：Intel (R) Core (TM) i9-13900K CPU，NVIDIA GeForce RTX 3090 GPU，32 G 内存，Win10 操作系统，Pycharm 集成开发环境，Python 3.10，PyTorch 2.0 等开源库。

网络训练过程使用小批量随机梯度下降法，批处理大小设置为 6，初始学习率根据网络模块分别对教师网络，学生网络，分割残差部分，分割头设置为 0.01，0.01，0.05，0.005，动量设置为 0.9，权重衰减为  $1 \times 10^{-4}$ 。

3.2 试验设置与评价指标

为评估 MFFM 模块和 DCASPPF 模块的有效性，

并验证本章 MSAF-DeSTSeg 模型的缺陷识别性能，分别设置消融试验和对比试验。其中消融试验将进行各改进模块单独增加至原网络中的性能提升对比试验。对比试验将验证与其它主流异常缺陷检测模型的性能对比。

无监督异常分割算法一般从 3 个尺度评价模型性能：图像级 (Image Level)，像素级 (Pixel Level)，实例级 (Instance Level)。图像级使用 AUC (Area Under Curve) 指标，AUC 即 ROC (Receiver Operating Characterist Curve) 曲线下的面积，可以评估模型的综合性能。AUC 的范围为 0~1，AUC 值越高，表明该模型对异常样本的识别能力越强，可以有效地发现异常样本。像素级使用更加准确的平均精度 (AP, average precision) 进行评价，其可以更好地反应分割区域样本的数据不平衡性。实例级是贴近工业生产评价的一个指标，当异常区域 50% 的像素被预测正确时，一般就可以认为该实例区域被正常检测到。通过调整判定阈值绘制精确率与召回率的曲线，这条曲线的平均精度为 IAP (Instance Average Precision)。相关计算公式如下：

$$Percision = \frac{TP}{TP + FP}$$
 (5)

$$TPR = Recall = \frac{TP}{TP + FN}$$
 (6)

$$FPR = \frac{FP}{TN + FP}$$
 (7)

$$AUC = \int_0^1 TPR(FPR) dFPR$$
 (8)

$$AP = \int_0^1 Percision (Recall) dRecall$$
 (9)

式中，*Percision* 表示精确率 (查准率)；*TPR* 表示真阳性；*Recall* 为召回率 (查全率)；*FPR* 为假阳性。

3.3 消融实验

本文设计的 MFFM 模块和 DCSASPPF 模块用于提升原始 DeSTSeg 的性能，为验证模块作用，进行消融试验。在原模型基础上分别添加 MFFM，DCSASPPF 改进项模块并进行组合搭配进行试验，数据集选用本课题的晶粒数据集，共进行 4 个试验，试验结果如表 1 所示，从表中可见，两个模块对网络性能起到了不同程度的作用。其中将学生和教师网络的多个不同层级的输出特征层后加入 MFFM 模块后，在像素级 AP 以及实例级 IAP 指标上均有较大提升，MFFM 模块替换原

表 1 试验结果表

Exp.	FFM	DSAMSPPF	img(AUC)	pix(AP)	ins(IAP)
1			96.91	65.10	66.81
2	✓		96.22	<b>75.23</b>	70.72
3		✓	96.94	68.37	67.91
4	✓	✓	<b>97.79</b>	73.06	<b>71.77</b>

注：✓ 表示加入此改进项，本文所有表中加粗字体均为最优值。

网络的拼接操作，3 项指标都创造了提升，表明多尺度特征融合有效提升网络缺陷识别精度。再将 DCSASP-PF 模块增加至原分割网络前之后，其中 AP 和 IAP 提升最明显，相比于原网络分别提升了 8.86% 和 4.96%，证明了 DCSA 模块对长距离上下文信息和局部特征有效结合和对晶圆缺陷的特征提取能力。

为验证 DCSASPPF 中各模块改进效果，验证 DC-SA 可变形卷积空间注意力机制对整体的提升作用，在网络包含 MFFM 模块的基础上，将使用 SA 空间注意力替换 DCSA 进行并构建 SASPPF 模块，并分别对单独 DCSA，单独 SA 和单独 SPPF 模块进行试验。从表 2 可见，单独的 DCSA 与 SA 相比，DCSA 在各项指标上具有优势，同时 DCSASPPF 与单独 SPPF 的对比数据表明前者更优，在 SPPF 模块中加入空间注意力机制，有助于模型精度的提升，这是因为注意力机制有助于金字塔不同尺度特征更有目的性的融合。从表中数据可以发现 DCSASPPF 在 AP 和 IAP 指标上，比 SASPPF 提升了 1.62% 和 1.76%，单独的 DCSA 比 SA 在多项指标上都有显著提升，其中 AP 提升最明显，提升了 3.58 个百分点，因此本章设计的 DCSA 相比于原始 SA 对于模型性能的提升更好。

表 2 DCSASPPF 有效性研究

	Img(AUC)	Pix(AP)	Ins(IAP)
DCSASPPF	<b>97.79</b>	73.06	<b>71.77</b>
SASPPF	97.73	71.44	70.01
DCSA	97.39	<b>74.26</b>	68.33
SA	96.70	70.68	65.30
SPPF	97.38	72.84	68.55

为了查看改进前后对复杂背景的抑制情况及复杂缺陷的增强效果，分别使用 Grad-Cam 方法绘制梯度热力图，Grad-Cam 是直观反映模型对特征图不同区域关注度的一种方法<sup>[22]</sup>，具体效果见图 6。通过热力图可以明显发现，DCSASPPF 相较于原始 SASPPF 模块和无注意力机制的原始模型可以更有效均匀地聚焦缺陷区域，对背景关注度较低，实现了对复杂背景纹理干扰的抑制目的，避免了网络对背景区域产生错误分割。这证明了基于可变形卷积注意力对于复杂形状目标的强大特征提取能力，可以根据目标形态自适应的调整卷积核减少了对背景区域采样的可能性，相较于原始 SA 注意力模块对微弱缺陷区域特征增强效果更具有优势。

3.4 改进 DeSTSeg 缺陷分割精度对比分析

为验证改进后的 DeSTSeg 算法的优越性，将本文与其他异常检测的先进工作的性能进行对比，对比模型分别为 UFlow<sup>[23]</sup>，FastFlow<sup>[24]</sup>，DRAEM 和原 DeST-Seg 网络模型。对比的评价指标仍然采用 AUC，AP 和 IAP 三个不同粗粒度上综合对比模型在图像级，像素级




图 6 Grad-Cam 注意力分布热力图


和实例级上的性能精度，所有试验均在相同硬件和软件环境下以及超参数环境下进行，均选择最优训练结果的权重在最终测试集上进行计算指标，在测试过程中，相关指标及可视化结果的计算阈值设置为 0.5，试验结果如表 3 所示，并将一些典型缺陷图像进行缺陷检测结果的可视化在图 7 上显示。缺陷异常类型主要包含了氧化膜残留、腐蚀坑、玻璃异常和划痕类型。

表 3 本方法与其他方法在晶圆数据集上 AUC/AP/IAP 指标对比试验结果 %

	U-Flow	Fast-Flow	DRAEM	本文方法
AUC	96.64	94.59	91.00	<b>97.79</b>
AP	36.83	43.76	68.25	<b>73.06</b>
IAP	30.28	41.21	62.38	<b>71.77</b>

从表 3 结果可以看出，本章在图像级，像素级和实例级 3 个指标上的检测性能上都达到了最优，相比于其他方法具有明显的优势。图 7 为各方法对于晶圆异常的分割结果图，预测结果图使用红色边界线将缺陷标识出，可以看出不同算法对于晶圆上异常的检测结果。图 7 结果表明不同网络均存在过检漏检情况，其中 U-Flow 模型对于晶圆缺陷虽然在图像级指标上表现较好，但是对于具体缺陷的分割效果同其他模型对比而言较差，存在细小微弱划痕的漏检，以及异常缺陷区域分割过大的问题。Fast-Flow 模型具有一定的复杂背景抗干扰能力，从图中对于较大的异常分割较好，但对于微弱缺陷分割精度较差。DRAEM 模型相比前者分割精度上较好，但是在玻璃区域和氧化膜区域存在错误分割的情况，同时对于微弱的划痕缺陷，其划痕分割的连续性不如本文方法。综合分析可得，在晶圆异常数据上，本文方法识别效果最好，在图像 AUC 指标上较 U-Flow 提升 1.15%，AP 指标相较于 DRAEM 提升 4.81%，而 IAP 指标相比于最优的 DRAEM 模型提升了 9.39%。本文方法在各晶粒示例异常图像中分割精度表现最好，除了个别极其微弱的缺陷外，均有效分割，对于微弱的

划痕和玻璃异常等缺陷具有很好的敏感度。



(a)原图 (b)标签图 (c)DRAEM (d)U-Flow (e)Fast-Flow (f)本文方法

图 7 晶圆异常缺陷检测对比试验结果图

## 4 结束语

本文对晶圆的无监督异常检测方法进行了调研分析,结合晶圆缺陷特点,提出了一种改进 DeSTSeg 的晶圆微弱缺陷分割方法,运用合成异常和知识蒸馏结合的方法可以实现零负样本的晶圆缺陷检测。在网络中使用多尺度的特征融合机制,有效融合来自教师和学生模型的不同尺度特征信息。在分割网络中加入可变形卷积空间注意力机制,增强对复杂纹理背景干扰的抑制,提升分割准确率。对比试验数据表明 MSA-DeSTSeg 模型相较于原 DeSTSeg 模型在 AUC、AP 和 IAP 指标上分别提升了 0.88%、7.96% 和 4.96%,并与其他先进网络对比性能最优,证明了所设计多尺度融合模块和可变形卷积注意力机制在晶圆微弱缺陷分割的有效性,可以较好地满足晶圆缺陷检测要求。

## 参考文献:

- [1] CHANG C Y, LI C, CHANG J W, et al. An unsupervised neural network approach for automatic semiconductor wafer defect inspection [J]. Expert Systems with Applications, 2009, 36 (1): 950 - 958.
- [2] 吕承侃, 沈 飞, 张正涛, 等. 图像异常检测研究现状综述 [J]. 自动化学报, 2022, 48 (6): 1402 - 1428.
- [3] DELAHAYE B, BALTZINGER J L, DENIS L, et al. Edge and extreme edge wafer manufacturing on 200 mm wafer: methodology, yield challenges, cost effective solutions, limitations [C] //2009 IEEE/SEMI Advanced Semiconductor Manufacturing Conference, 2009: 100 - 105.
- [4] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述 [J]. 中国科学: 信息科学, 2022, 52 (6): 1002 - 1039.
- [5] SHAO L, YAN R, LI X, et al. From heuristic optimization to dictionary learning: a review and comprehensive comparison of image denoising algorithms [J]. IEEE Transactions on Cybernetics, 2014, 44 (7): 1001 - 1013.
- [6] 张 寅, 朱桂熠, 施天俊, 等. 基于特征融合与注意力的遥感图像小目标检测 [J]. 光学学报, 2022, 42 (24): 140 - 150.
- [7] 李鹤喜, 韩新乐, 杨铁牛. 基于频域互相关的 led 晶粒阵列快速视觉检测 [J]. 计量学报, 2018, 39 (4): 476 - 480.
- [8] 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.
- [9] LIN Y. Wafer pattern counting, detection and classification based on encoder-decoder CNN structure [C] //2022 IEEE International Conference on Electro Information Technology (eIT), 2022: 109 - 113.
- [10] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20: 273 - 297.
- [11] ZHANG X, LI S, LI X, et al. Destseg: segmentation guided denoising student-teacher for anomaly detection [C] //2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 3914 - 3923.
- [12] 蔡晓伟. 基于教师学生模型与强弱分支的半监督目标检测算法 [D]. 杭州: 浙江大学, 2023.
- [13] ZAVRTANIK V, KRISTAN M, SKOČAJ D. Draem-a discriminatively trained reconstruction embedding for surface anomaly detection [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 8330 - 8339.
- [14] 顾明珠, 明瑞成, 邱创一, 等. 一种多教师模型知识蒸馏深度神经网络模型压缩算法 [J]. 电子技术应用, 2023, 49 (8): 7 - 12.
- [15] YAO L, LU Y, QIAN Y, et al. High-accuracy classification of multiple distinct human emotions using EEG differential entropy features and ResNet18 [J]. Applied Sciences, 2024, 14 (14): 6175.
- [16] KHOKHAR S, KEDIAD. Integrating YOLOv8 and CSP-bottleneck based CNN for enhanced license plate character recognition [J]. Journal of Real-Time Image Processing, 2024, 21 (5): 168.
- [17] WANG Q, WU B, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [J]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 11531 - 11539.

(下转第 214 页)