

文章编号 1004-924X(2024)11-1788-13

基于圆卷积神经网络的粘连导电粒子检测

刘子龙^{1,2}, 罗 晨^{1,2*}, 周怡君^{1,2}, 贾 磊^{1,2}

(1. 东南大学 机械工程学院, 江苏 南京 211189;

2. 无锡尚实电子科技有限公司, 江苏 无锡 214174)

摘要: 为了提高粘连导电粒子检测的精度和稳定性, 提高评价指标的客观性和与实际生产需求的适配度, 提出了基于圆卷积神经网络的粘连粒子检测。首先提出了更适合粒子检测的圆卷积, 修改可变形卷积的采样策略, 限制采样点偏移量 x, y 坐标的自由度, 增加尺寸控制参数作为补偿。然后, 基于 U-MultiNet 网络架构将圆卷积替代原有卷积形式, 并增加注意力机制, 通过标签图计算自注意力, 以此作为权重修改损失函数和标签图。最后, 提出可重复性和可再现性指标综合评价算法的精度和稳定性。实验结果表明, 本文方法的可重复性和可再现性分别为 0.809 2 和 0.705 1, 相比现有主流方法提高了 4.52% 和 1.74%; 精确度和召回率分别为 0.712 8 和 0.697 4, 准确度为 0.834 1, 比现有主流方法高 1.68%。相比于现有主流方法, 该方法对于粘连干扰的粒子检测效果有明显提升, 可以满足工业上对粒子检测精度、稳定性和实时性的要求。

关 键 词: 机器视觉; 深度学习; 神经网络; 导电粒子检测; 圆卷积

中图分类号: TP394.1 **文献标识码:** A **doi:** 10.37188/OPE.20243211.1788

Detection of conductive multi-particles based on circular convolutional neural network

LIU Zilong^{1,2}, LUO Chen^{1,2*}, ZHOU Yijun^{1,2}, JIA Lei^{1,2}

(1. College of Mechanical Engineering, Southeast University, Nanjing 211189, China;

2. Wuxi Shangshi-finevision Technology Co., Ltd, Wuxi 214174, China)

* Corresponding author, E-mail: chenluo@seu.edu.cn

Abstract: To enhance the accuracy and stability of conductive particle detection and to meet actual production demands, a multi-particle detection method based on a simplified deformable convolutional (circular convolutional) neural network is proposed. First, an appropriate model and network are chosen based on the characteristics of the detection task and target. Then, a deformable convolution sampling strategy is introduced and modified to restrict the sampling point offset, with added size control parameters. A circular convolution, more suitable for particle detection, replaces some convolutional layers of the original network. Additionally, an attention mechanism is introduced to calculate self-attention through label graphs, which serve as weight modification loss functions and label graphs. Finally, a comprehensive evaluation algorithm for the accuracy and stability of repeatability and reproducibility indicators is proposed. The results show that the repeatability and reproducibility indicators of our method are 0.809 2 and 0.705 1, respective-

收稿日期: 2023-12-25; 修订日期: 2024-02-20.

基金项目: 国家自然科学基金资助项目 (No. 51975119, No. 52375487); 江苏省重点研发计划资助项目 (No. BE2023041)

ly, outperforming existing mainstream methods by 4.52% and 1.74%. The accuracy and recall rates are 0.712 8 and 0.697 4, respectively, with an overall accuracy of 0.834 1, surpassing existing methods by 1.68%. Compared to existing mainstream methods, our approach significantly improves the particle detection performance under adhesion interference, meeting industrial requirements for accuracy, stability, and real-time processing.

Key words: machine vision; deep learning; neural network; conductive particle detection; circular convolution

1 引言

TFT-LCD 通常使用各向异性导电胶 (Anisotropic Conductive Film, ACF) 互连的玻璃覆晶封装 (Chip on Glass, COG) 工艺^[1], ACF 互连工艺具有简单、良好的连接性、低成本和环保等特点, 因此被广泛应用于生产 TFT-LCD 面板。ACF 主要包括树脂黏着剂和导电粒子。树脂黏着剂在常温下略带黏性, 能够将 IC 器件与玻璃基片连接, 同时非导电粒子区域具有绝缘性。在这种封装工艺中, ACF 与面板对齐后加热, 固化 ACF 内的高分子聚合物, 从而在基板和电极间形成电气连接^[2], 捕获导电粒子。导电粒子一般是微小的树脂颗粒, 外层覆盖着由镍和金构成的金属层, 外部再涂覆一层绝缘膜。导电粒子承受压力时会被压扁, 过大的压力甚至可能导致其破裂。导电粒子的数量、位置和分布都会影响电路的连接性能, TFT-LCD 面板的导电性也直接影响着其性能^[3]。工业中对面板导电性的测试主要通过测量其导电通道上导电粒子的数量间接获得^[4]。测量方法通常是在经成像系统拍摄后, 对相关区域图像中的导电粒子识别和计数。图像的细微对比度差异和模糊会通过影响像素的分布, 显著影响检测结果, 进而严重影响结果的稳定性; 热压会造成导电粒子的变形^[5], 受压后的粒子直径会变大, 当粒子距离较近时, 面板上的粒子不可避免地会粘连, 粘连会影响对粒子计数的准确性, 如何准确地分离粘连的粒子也是挑战之一。

在工业实际应用中, 最初计数导电粒子的方法是在显微镜下人工计数, 但该方法会耗费大量的时间和人力。随着自动化技术的发展, 导电粒子检测可采用相关图像处理方法来完成。根据导电粒子一般为圆形, 且在光照下呈现一侧亮一

侧暗的特征, Lin 等提出通过计算梯度算子比较粒子图像与背景图的差异的方法得到使粒子更突出的二值图, 再通过模板与部分样本的比较确定最佳阈值分离和去伪^[6]。该方法显著提升了粒子检测的自动化程度, 但所涉及到的相关参数和阈值特异性较高, 难以向其他类型的粒子图像推广。为了提高粒子检测算法的普适性和稳定性, 人们将深度学习引入粒子检测中。

CNN 和 Transformer 是目前目标检测任务应用较多的两种架构^[7]。Transformer 的优势在大数据, 自适应注意力和大目标检测, 是面向特征的检测模型。CNN 系列的优势在于具有一系列不变性的兴趣点和从像素到全局的检测特点, 是面向像素的检测模型。整体来看, 对粒子检测这种小目标任务, CNN 比 Transformer 更有优势。而且 Transformer 最初应用于自然语言处理领域, 尽管已经有 DETR^[8]及其变体的出现, 在图像领域其发展依然不如 CNN 成熟。

常用于检测小目标的 CNN 模型是 U-Net^[9], 最初用于检测容易混淆的密集医学目标中的异常。该模型是由可以捕获上下文信息的下采样路径和可以获得精确定位的上采样路径组成的对称结构网络, 在细小且紧邻细胞跟踪上取得了较好的结果, 但是该方法存在模型过大、参数量过多的问题。Wang 等以此为基础, 提出了 U-MultiNet^[10], 该方法大大减少了每层卷积的通道数, 相应地增加了层内拼接, 虽然在导电粒子检测中取得了较好的效果, 但 dice score 依然不够理想。作者继续改进网络, 使用 GAN 架构^[11], 生成器为原 U-MultiNet 网络, 判别器为多层卷积网络, 生成器负责预测, 判别器检验结果是由生成器生成还是人工提供的真值, 通过生成器与判别器对抗优化生成器的预测结果。该方法相比 U-MultiNet 预测精度有所提升, 但训练时间和成本

大幅增加。Liu 等提出了 U-ResNet^[12], 受残差块启发, 对 U-Net 进行了与 U-MultiNet 相似的改进。基于 U-Net 中 encoder-decoder 的结构, 也有研究者提出了类似架构的网络。Wang 等提出了轻量化模型 PAD-Net^[13], 并使用自适应注意力损失函数和知识蒸馏策略, 取得了较好的效果。Tao 等提出了 CPNet^[14], 使用多频信息融合的 MFM 模块, 并提出了灵活度更高的无边缘活动边界损失函数 (ACWE), 在多种拍摄条件的粒子图中均取得了较好的效果。

除上述语义分割模型外, 也使用目标检测模型的网络。Luo 等提出了一种改进的 Mask-RCNN 网络^[15]。该方法通过标签保留变换, 应用新型的参数空间包络技术扩充数据集, 在数据集样本数量和种类较少的情况下也能获得不错的训练效果。该方法使用的实例分割模型可以直接标注出粒子的轮廓, 便于粒子计数, 实现了端到端的粒子检测。但该方法的测试样本图像都很清晰, 且粒子粘连情况较少, 对工业现场中质量较低的图像可能效果不佳。

尽管深度学习的方法大大提高了粒子检测的精度和普适性, 但对较模糊的图像以及粘连粒子的检测效果依然不佳。为了更有针对性地提升粒子检测效果, 首先从现场获取的粒子图像分析。粒子在导电通道上随机分布, 由于导电粒子原尺寸较小, 经光学设备采集并放大后整体图像模糊, 会影响粒子检测精度; 粒子尺寸不一, 无法用固定大小的算子或卷积核提取粒子特征; 粒子数量较多, 粒子之间互相重叠, 给粒子计数带来困难; 部分粒子重叠区域较大, 而模糊不清的边界则将解决该问题的难度提升, 给粘连粒子的分离造成了更大的困难。综上, 本粒子样本检测精度的影响因素主要是图像和粒子本身的特征: 粒子过小, 获取粒子图像的设备精度不足, 图像本身模糊不清, 需要模型能抵抗模糊和噪声的干扰; 粒子尺寸小, 需要模型的检测性能更侧重于小目标; 粒子数量大、多粘连, 需要模型具有多目标、分离目标的检测能力。此外, 相比于常规目标检测任务, 粒子本身特征较少、较简单, 在模型总开销不变的条件下, 需要将模型对目标本身特征的提取能力向模型抗干扰、抗粘连的能力转移, 重点提高影响检测精度重要因素的特征提取

能力。

综上, 本文在 U-MultiNet 网络的基础上, 引入圆卷积采样策略和注意力损失函数, 在保证稳定性的同时提升对模糊和粘连的粒子图像检测效果。提出了圆卷积形式, 设置初始采样点排布形状为近似圆形, 并降低采样点偏移量 x, y 坐标的自由度, 并增加尺寸控制参数作为补偿, 使采样点可以在限定的范围内自适应调整, 保证网络能够获得足够粒子特征的同时, 减少卷积的参数量, 并提高网络对不规则形状的粘连粒子的识别能力。引入注意力机制, 修改损失函数和标签图。通过对标签图平均池化和归一化计算自注意力, 作为计算对应像素点损失函数的权重; 将自注意力权重以相同方式赋给标签图后再用阈值处理得到新标签图。自注意力机制可以让标签中有粒子的部分, 尤其是粒子中心部分拥有更大的权重, 提高网络对不同粒子边界和模糊干扰的区分度。提出了更适应于工业要求的可重复性和可再现性评价指标。对经相同设备在相同环境下获取粒子图像的检测结果, 可重复性为相同位置不同批次之间的比较 (横向比较), 可再现性为相同批次不同位置的比较 (纵向比较)。在覆盖准确率和召回率等经典指标的基础上, 该指标对网络稳定性进行评价, 与工业生产的要求更接近。

2 基本网络结构

U-MultiNet 是由 Wang 等最初在 ISNE2019 上提出的^[11], 该网络在 U-Net 的基础上, 通过降低每个卷积层的通道数, 实现了轻量化网络结构, 提高网络预测的速度; 作为精度补偿, 引入了多尺度卷积模块 (Multi-scale convolution block), 模仿 GoogLeNet^[16] 中 Inception module 的思路, 在每一层卷积内部增加拼接, 保留同层的多尺度信息, 以更好地提取多尺度空间特征, 同时减少小粒子特征的丢失。

具体网络结构如图 1 所示。首先在下采样阶段, 输入的图像在每个多尺度卷积模块中经过连续三次的 3×3 卷积, 并在卷积后紧随批归一化 (Batch Normalization, BN) 和 RELU 激活函数。将每次卷积得到的中间特征图裁剪拼接后经过 2×2 最大池化, 特征图的通道数翻倍, 得到最终

的特征图,并在下一个多尺度卷积模块进行相同操作。在进行4次多尺度卷积模块后,进入上采样阶段。通过上采样卷积使通道数减半,再与下采样阶段对应层拼接得到的特征图经跳跃连接过程拼接合并,作为下一个多尺度卷积模块的输入特征图。经过与下采样阶段通道数对称的三次多尺度卷积模块得到的特征图,通过一次 1×1 的单通道卷积层整合和 Sigmoid 激活函数归一化,得到最终的特征图,作为该模型的输出。

U-MultiNet 的网络结构结合了多尺度和跳跃连接:多尺度网络有利于小目标的检测;跳跃连接将同层的特征图裁剪连接,共享特征。与 U-Net 不同的是,在每层做完卷积操作后,额外将层内三次卷积后的特征图拼接,将多尺度从层间扩展到层内,更适用于密集和小目标检测。但这样的层内连接对模糊较严重、粘连较多的粒子检测效果依然不佳,需要改进。

3 本文网络结构

如图 1 所示,本文网络与 U-MultiNet 基础网络的差别在于使用圆卷积模块替换普通卷积模块。圆卷积调整了卷积的采样方式,使其采样位置由预先确定变为可学习状态,更加灵活;又改进了网络中原有的损失函数,增加了注意力机制,使网络的学习更有针对性。

3.1 圆卷积

受可变形卷积^[17]启发,并结合粒子本身特征,为了提高网络对不规则形状粒子的识别能力,并在达到相似精度的前提下减少可变形卷积的参数量,简化可变形卷积,改用圆卷积。

圆卷积将卷积的采样点数固定为 9(类比普通 3×3 卷积)。圆卷积与可变形卷积的公式分别为:

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + (p_n + \Delta p_n) \cdot scale_n), \quad (1)$$

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n), \quad (2)$$

式中: $w(p_n)$ 为各采样点的权重, p_0 为采样中心, p_n 为采样点, Δp_n 为采样点偏移量, x 为对应点的像素值。为了更直观地体现 3 种卷积的比较,普通卷积、可变形卷积和圆卷积的示意图如图 2 所




图 1 U-MultiNet 与本文网络结构

Fig. 1 Architecture of U-MultiNet and ours

示(彩图见期刊电子版),它们的不同主要体现在采样点的选择上。普通卷积的采样点是固定的,可变形卷积和圆卷积增加了额外的参数,以控制采样点的位置变化即采样点偏移: $(p_n + \Delta p_n)$,使其不受固定采样规则的约束,可以随目标的特征调整变化。额外的参数是原始特征图经由额外的普通卷积得到的,可变形卷积与圆卷积的差别也体现在控制采样点位置变化的额外参数上。图 3 为两者的差异。可变形卷积通过额外的卷积层学习每个采样点 x, y 坐标偏移量参数,圆卷积将各采样点偏移中 x, y 坐标的比值预先设置固定,即 $\frac{x(p_n + \Delta p_n)}{y(p_n + \Delta p_n)}$ 为定值,降低采样点坐标的自由度。为了补偿自由度的损失,圆卷积增加新的控制参数:尺寸控制参数 $scale_n$ 控制每个采样点到采样中心的距离,这样采样点只能在该点与采样中心的连线方向上(即图 2 中的蓝色虚线)移动。用于确定每个采样点的位置需要的参数数量由 2




图2 三种卷积示意图

Fig. 2 Schematic diagram of three kinds of convolution




图3 计算控制参数过程的比较

Fig. 3 Comparison of process of calculating control parameters

减少到1,每次卷积的总参数由18(每个采样点都有两个 x,y 坐标偏移参数)减少到9。

现为采样点选择初始排布规则。考虑到粒子本身近似圆形,设定采样点的初始排布方式为绕采样中心平均分布,并使其也近似圆形,采样中心即为圆心对应像素。这样有两种排布方案选择,如图4所示。图中蓝色区域为初始圆卷积采样区域。前一种采样方式更偏向于传统采样方式,只是改变了传统卷积的采样规则,但像素值的计算更方便简单;后一种采样区域更接近圆形,而且突破了整数像素点的限制,将像素点的坐标值由整数扩展到小数,使采样点的位置变化更加灵活。非整数像素点的计算参考了可变形卷积的双线性插值法^[17]。为保证圆卷积的精度,选用采样方式图4(b)。




图4 圆卷积采样点初始排布方式

Fig. 4 Initial layout of sampling points in circular convolution

关于尺寸控制参数 $scale_n$ 的计算,以可变形卷积中对采样点偏移量 Δp_n 的计算方法为参考。在可变形卷积中,采样点偏移量由原特征图经过一次额外的卷积得到,该步卷积的卷积核尺寸与可变形卷积核尺寸相同(以 3×3 为例),通道数与可变形卷积参数量相同($(3 \times 3)2=18$)。采样点偏移量的计算主要由额外的卷积过程得到,该卷积过程存在两个可变参数:采样通道数(下文中简称为chn)和卷积核尺寸(下文中简称为size)。对于通道数的选择,圆卷积依旧遵循“一个参数对应一个卷积通道”的原则,由于每次圆卷积所需的参数量为9,故圆卷积的通道数也需从18调整为9。考虑到该步卷积的目的是计算

尺寸控制参数,需要获取特征图的更多信息,因此该步卷积需要更大的感受野,而感受野可以用更大的卷积核获得,故在卷积核尺寸的选择原则与可变形卷积的“额外卷积与可变形卷积的卷积核尺寸相同”不同,本文使用更大的卷积核。但由于部分导电粒子距离较近,过大的卷积核,即过大的感受野可能会导致单次卷积采样范围内的粒子过多,可能影响粒子特征的提取。为了验证上述分析,尤其是卷积核尺寸对特征提取过程的影响,在实验部分会进一步比较使用不同通道数和卷积核尺寸训练后网络的检测效果。

3.2 注意力损失函数

根据注意力机制的原理^[18]和粒子分布密集的特点,为损失函数的计算加权并修改标签。损失函数由二元交叉熵损失和位置损失两部分组成,可表示为:

$$loss_{total} = loss_{CE} + loss_{dice}, \quad (3)$$

其中: $loss_{total}$ 表示总损失, $loss_{CE}$ 表示二元交叉熵损失, $loss_{dice}$ 表示位置损失。交叉熵损失监督的是每个像素点的预测情况,而位置损失监督的是粒子的位置预测情况。二元交叉熵损失采用经典损失函数,即:

$$loss_{CE} = -\frac{1}{wh} \sum_{x=1}^w \sum_{y=1}^h [p(x,y) \cdot \log(p'(x,y)) + (1-p(x,y)) \cdot \log(1-p'(x,y))], \quad (4)$$

式中 $p(x,y)$ 和 $p'(x,y)$ 分别表示预测结果和标签结果。位置损失最常用的是dice score,可表示为:

$$loss_{dice} = \frac{2|X \cap X'|}{|X| + |X'|}, \quad (5)$$

式中 X 和 X' 分别表示预测图像和标签图像。注意力机制可以根据原图的局部像素分布加强损失函数对局部的约束作用,提升重叠粒子检出的稳定性。此外,对于粘连或距离较近的粒子,如果可以在检测阶段将粒子标记的区域由整个粒子缩小为仅粒子中心附近的区域,粘连粒子的检测效果就会有较大提升。因此,这里选择为位置损失函数引入注意力机制并作为其权重,以突出粒子中心的检测效果对结果的重要程度。加入的注意力为自注意力,即根据标签

的粒子分布情况,在为每个像素计算位置损失函数时给予对应的权重。具体做法为:对标签图做平均池化,将归一化后的结果加 I 得到注意力矩阵 A :

$$A = I + AvgPool(X'), \quad (6)$$

式中 X' 表示标签图。将注意力矩阵视为权重式(6)加入二元交叉熵损失函数的计算中:

$$loss_{CE_adapted} = -\frac{1}{wh} \sum_{x=1}^w \sum_{y=1}^h A(x,y) [p(x,y) \log(p'(x,y)) + (1-p(x,y)) \log(1-p'(x,y))]. \quad (7)$$

对标签也进行类似修改:

$$X'_{adapted} = A \times X'. \quad (8)$$

但对于密集的目标,计算注意力矩阵时由于采用的是平均池化操作,标签中原清晰的粒子边界一定会引入模糊。注意力矩阵的权重值的边界可以模糊,标签图有粘连会大幅降低粘连的分离,故使用阈值尽量保留粒子中心,去除边缘模糊不清的粘连。具体处理为:在平均池化后进行阈值处理,使标签图中的粒子中心为1,越接近粒子边缘值越小。在计算位置损失函数时使用经注意力机制改动后的标签:

$$loss_{dice_adapted} = \frac{2|(X) \cap (X'_{adapted})|}{|X| + |X'_{adapted}| + \delta}, \quad (9)$$

式中: δ 为平滑系数,防止奇异值出现,取0.01。

以标签图为例,图5(a)为修改之前的标签图,图5(b)为加入注意力机制后的标签图,也表




图5 用注意力机制处理标签图

Fig. 5 Labels processed by attention

示对应位置各像素点损失函数的权重值。图 5(b)中局部放大,经注意力机制处理后粒子的效果为中心亮轮廓暗,即粒子中心的权重和像素值较大,轮廓处的权重和像素值较小。图 5(c)为去除模糊边界后的标签图,标签图中粒子的粘连程度明显降低。

3.3 评价指标

在理想情况下,使用相同的设备,在相同环境条件下对同一待测目标的检测结果应是相同的;但受光照,拍摄角度,以及轻微的振动变形等影响,引入了系统和偶然误差,得到的待测图像会有差异,因此,使用相同的模型对同一待测目标在不同批次中得到的图像预测时得到的结果也会有差异。为了衡量差异程度,除了最常用的准确度指标(Accuracy, Acc)外,仿照工业上常用于分析系统稳定性的方法,测量系统分析(Gauge Repeatability and Reproducibility)^[19]提出了稳定性指标:可重复性(Repeatability, Repeat)和可再现性(Reproducibility, Reproduce)。

通常可重复性为对同一对象的多次测量,可再现性为不同操作员对同一对象的多次测量。而本文用在相同位置,相同环境条件下采集到的不同图像的检测结果差异来衡量稳定性,即可重复性为对面板的相同位置不同批次获取的图像比较(横向比较),可再现性为相同批次获取的不同位置的图像比较(纵向比较)。图像比较即比较图像检测后输出图像的差异性。输出图像的差异性可以进一步用像素差异性、检出粒子数量和检测精度指标的差异性量化衡量。检出粒子数量是根据粒子检任务特点的直观指标。检测精度指标是针对模型而言的直观指标,可以用检测结果与人工标记对比得到的一系列精度指标表示,本文使用的精度指标是精确度(Precision, P)和召回率(Recall, R)。像素差异性指两张图像在像素层面上的差别程度,通常只有对结构有相似性的图像对才有意义。它表示可以参考图像相似度的指标 SSIM(structure similarity index)^[20]:

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma, \quad (10)$$

式中 x, y 表示比较的图像, $l(11), c(12), s(13)$ 分别为亮度、对比度和结构的比较, α, β, γ 为它们对

应的权重:

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (11)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (12)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3}, \quad (13)$$

式中: μ_x, μ_y 表示图像零阶特征,为图像平均强度,用像素均值计算; σ_x, σ_y 表示图像二阶特征,为图像像素标准差,用离散形式的无偏估计计算; σ_{xy} 表示图像之间的关系,用互相关系数计算。

由可重复性的定义,系统越稳定,一组用于计算可重复性的样本图像的检测结果相似度应更高,所以可重复性指标用像素差异性和检出粒子数量的波动程度评价。像素差异性用 SSIM 计算,检出粒子数量波动程度用组中检出粒子数的变异系数 CV_{count} 衡量。像素差异性是在学术界中用于比较待测图像与目标图像相似度的指标,检出粒子数量的波动程度是直接从检出粒子数量的角度对不同样本比较,是在实际检测任务中最核心的问题,因此为两项指标分量给予相同的权重。为了方便两项指标合并,对检出粒子数量波动程度的指标做了归一化处理,即:

$$S_{\text{repeat}} = 0.5 \times (S_{\text{SSIM}} + e^{-CV_{\text{count}}}). \quad (14)$$

变异系数为检出粒子数的标准差 σ_{count} 与均值 $mean_{\text{count}}$ 之比: $CV_{\text{count}} = \frac{\sigma_{\text{count}}}{mean_{\text{count}}}$, S_{SSIM} 表示相同位置不同批次所有结果图之间两两比较得到的 SSIM 的均值。

由可再现性的定义,无法通过相似性对一组无结构相关性的样本图像评价。该组样本的稳定性评价应当回归网络本身,故计算组内图像样本的检测精度。精确度和召回率为深度学习中评价模型性能的经典指标,因此,这两项指标对评估检测模型也具有相同的重要程度。这两项指标所涉及的概念与“可再现性”接近,故将二者合并成一项指标,并给予了二者相同的权重,即:

$$S_{\text{reproduce}} = 0.5 \times (mean_{\text{precision}} + mean_{\text{recall}}). \quad (15)$$

4 实 验

4.1 数据集和实验设计

当前没有关于粒子的公开数据集,故本文的

数据集从工业流水线中收集,经裁剪和 resize 后图像的尺寸为 $1\,024\times 256$,为了降低训练过程占用的内存,训练过程中的预处理会将每张图裁剪成 256×256 的小块。经实验,使用该方法训练也会提高模型的精度。数据集共 845 张图像,从中随机抽取 80% 用于训练,其余用于验证。

模型的训练在 Pytorch 框架上进行,实验设备为 Intel Core i7-8750H CPU, NVIDIA GeForce GTX 1060 GPU。训练中使用 Adam 优化器, batch size 设置为 4, 训练 epoch 设置为 20, 初始学习率为 2×10^{-4} 。

为了计算稳定性评价指标,需要对测试集的获取方法进行设计。计算可重复性,需要不同批次获取的相同位置的粒子图像;计算可再现性,需要相同批次获取的不同位置的图像。综合考虑,在最小测试成本的前提下,使用相同光学设备分不同批次对相同面板获取图像。由于面板相对于粒子通道部分很大,会给检测带来困难,需要从面板上单独截取有粒子分布的通道,而截取粒子通道的位置也应保持一致。实施方法为:根据面板上已有的标志位将面板对齐,在选定的面板通道位置截取对应图像区域。从 20 块面板上截取 10 个相同的面板通道,共 200 张图像参与测试。为了突出本文提出的方法在图像清晰度较低、图像质量较差和导电粒子互相粘连情况下的优越性,本文使用相同种类不同型号的芯片面板进行效果

对比。图 6 为两组测试样本集。图 6(a)为主要测试样本,用于本文所有实验,白色方框部分为导电粒子通道;图 6(b)为较清晰、质量较高的测试样本,仅用作比较,后文简称为清晰组。




图 6 实验测试样本
Fig. 6 Test samples used in experiments

4.2 实验结果与分析

4.2.1 圆卷积参数影响

表 1 将提出的圆卷积部分参数的效果进行对比,分别为用于计算尺寸控制参数的通道数 (chn) 和卷积核尺寸 (size)。参与分析的模型为原模型+标准可变形卷积、原模型+圆卷积 (chn=1, size=7)、原模型+圆卷积 (chn=9, size=3)、原模型+圆卷积 (chn=9, size=7)、原模型+圆卷积 (chn=9, size=11)、原模型+圆卷积 (chn=18, size=7)。

表 1 圆卷积参数影响
Tab. 1 Effect of parameters(chn & size) on circular convolution

Parameter combination	Acc	Repeat	Reproduce
Deformable convolution	0.834 1	0.793 5	0.708 5
Circular convolution(chn=1,size=7)	0.810 5	0.752 6	0.665 8
Circular convolution(chn=9,size=3)	0.818 6	0.776 2	0.672 1
Circular convolution(chn=9,size=7)	0.825 5	0.803 0	0.710 4
Circular convolution(chn=9,size=11)	0.822 4	0.784 9	0.683 7
Circular convolution(chn=18,size=7)	0.825 9	0.803 5	0.706 5

由表 1 可知,通道数的增加(chn=9 与 chn=1)使网络获得了更多图像信息,有更多参数参与圆卷积尺寸控制参数的计算,圆卷积的效果显著提升,但继续增加通道数(chn=18)提升则不明显,说明 chn=9 时通道数对网络的提升就已经达到了饱和,继续增加通道数也会增加参数量,性价比不高;卷积核尺寸的增加(size=3 与 size=7)同样可以显

著提升检测效果,适当增加卷积的感受野可以让网络获取更多信息,但若继续增加(size=11),则会因为粘连粒子本身距离较近,使网络获取的内容混杂,有效信息被淹没,效果变差。

将圆卷积中效果最佳的 (chn=9, size=7) 与可变形卷积比较,圆卷积在减少一半参数量的前提下与可变形卷积相比,仅在准确度方面略有下

降,说明圆卷积的改进可行。

4. 2. 2 消融实验

如表 2 所示,消融实验包括 3 种模型:U-MultiNet (baseline), U-MultiNet+圆卷积,以及 U-MultiNet+注意力损失函数。所有的模型结果均优于基础模型,表明圆卷积和注意力损失函数有助于提升检测稳定性。通过模型在训练集上的

检测效果定性分析各模块的作用。图 7 展示了上述模型在同一小块区域的检测结果。与基础模型相比,分别加入圆卷积和加入注意力模块后检测得到的导电粒子更小,对不同粒子边界的判别能力更强,粒子之间的分离程度更高。最终,本文模型结合了圈卷积和注意力模块的优势,检测效果更佳。




图 7 消融实验各模块检测效果定性分析

Fig. 7 Qualitative analysis of each module in ablation experiment

表 2 消融实验结果

Tab. 2 Results of ablation experiments

Method	Acc	Repeat	Reproduce
U-MultiNet	0.805 4	0.723 5	0.674 4
U-MultiNet+ Circlular convolution	0.814 2	0.796 2	0.708 4
U-MultiNet+ Attention	0.813 3	0.775 4	0.697 1
Ours	0.825 5	0.803 0	0.710 4

4. 2. 3 对比实验

工业生产过程中,受保密措施限制,本文使用的数据集规模相对较小,可能会产生过拟合。但对于粒子检任务,考虑到导电粒子特征相对较少,且单张训练集样本图像通常包含大量可供网络学习的待检测目标(本文使用的训练集样本中每张图像约包含 40 个导电粒子,共约 35 000 个)。图 8 展示了训练过程中 4 种模型的 loss 曲线,从图中可以看出,各方法在训练中 40 epochs 内均已收敛,未发生过拟合现象,实验结果可靠。

表 3 展示了本文方法与多种现有方法的比较,包括使用 Sobel 算子提取特征的传统算法, U-Net, U-MultiNet, CPNet 等深度学习方法。结果显示,使用算子卷积的传统方法在可重复性方面和准确度方面均较好,说明对相似度较高的图像




图 8 训练过程中 4 种模型的 loss 曲线

Fig. 8 Loss curves of four methods during training

普适性可以接受,但可再现性较差,且漏检较多,对设置的参数要求比较高,对图像模糊的抗干扰能力较差。对于结构及明暗度上差别较大的粒子图像,在实际工业生产中需要频繁调整参数,

普适性较低,不宜推广。表 4 展示了可变形卷积与圆卷积在训练耗时和网络参数量方面的比较。分别使用可变形卷积和圆卷积代替基础网络 U-MultiNet 中的卷积层,从整体网络参数量上看,使用圆卷积的网络几乎只有可变形卷积网络的一半左右,训练一个完整 epoch 的时间和平均单

张耗时显著减少,结合前文圆卷积参数影响实验中圆卷积与标准可变形卷积的效果对比,可以得出:在粒子检测任务中,达到了减少卷积参数量,减轻训练成本的同时,训练后的圆卷积网络的检测精度高于 U-MultiNet 的基础网络,与用可变形卷积等效替代网络的检测精度接近的目标。

表 3 对比实验结果
Tab. 3 Results of comparison experiments

Method	Acc	Repeat	Reproduce	Average time/ms	Parameter number
Lin ^[6]	0.798 6	0.764 0	0.652 6	12.28	
U-Net	0.817 3	0.757 5	0.677 2	52.37	75 328
U-MultiNet	0.813 2	0.730 0	0.680 5	36.61	26 832
CPNet	0.801 7	0.665 5	0.687 7	41.75	48 864
Ours	0.834 1	0.809 2	0.705 1	39.94	35 888

表 4 可变形卷积与圆卷积的比较
Tab. 4 Comparison between deformable convolution and circular convolution (ours)

Method	Training time in 1 epoch/s	Average time per image/ms	Parameter number
Deformable convolution	162	47.93	62 528
Circular convolution(ours)	112	33.13	35 888

对比多种深度学习方法,U-Net是最先提出的基础框架,由于网络结构较简单,相同参数量下网络较深,故在准确度和可再现性方面较好,而由于缺少对粘连粒子和模糊的处理,重复性较差;U-MultiNet相比于U-Net网络结构更复杂,但作为轻量化网络卷积的通道数,相比U-Net减少很多,虽然增加了层内卷积次数并对层内的不同卷积之间裁剪拼接,但仅层内的信息融合对检测稳定性的提升贡献有限,不适合模糊和粘连的图像;CPNet虽然能够将不同频率的特征信息融合,损失函数也可以依据不同的目标形状改变,但该模型在图像模糊的问题上未做过多处理,误检较多,抗干扰性较差,表现为可重复性较低,即受图像变化的影响较大,在本数据集上表现不太理想;本文方法在U-MultiNet的基础上,没有增加通道或加深网络,只经过圆卷积和注意力损失函数的改进,可重复性提升了7.92%,可再现性提升了2.46%,说明抵抗模糊和粘连的方法能够增强检测稳定性。同时准确度也提高了2.09%,说明检测稳定性指标与准确度指标并不冲突,检测稳定性的指标也是合理的,提升检测稳定性的

方法与常规意义上提升准确度的方法具有相同效力。从预测单张所需的时间上,传统卷积方法的表现最好;对于深度学习方法,U-MultiNet虽然结构较复杂,但因为各卷积层通道数较少、参数量最少,也取得了不错的结果;本文方法因为将普通卷积替换成了圆卷积,参数量增加,所需时间稍有增加,但仍然可以满足工业上的实时性要求。模型的参数量决定模型的复杂度,本文用模型参数量指标表征模型大小。Lin的方法未使用网络模型故不考虑;其他使用网络模型的方法中,由于UNet网络结构较简单,故需要更深的网络以及更宽的特征通道才能达到与其他模型接近的检测效果,故UNet的参数量显著高于其他方法;而本文方法的参数量仅略高于基础模型,在模型复杂度方面有较大优势。

图 9 从检测效果角度对比上述方法的结果。图 10 为清晰组的检测效果,与图 9 互为对照。与图 9 中的结果不同,从清晰组的结果可以看出,不同方法的检测结果大致相同,说明导电粒子图像的清晰度和粒子分布情况较理想时,各方法均能取得较好的效果;而当图像质量恶化(如图像模




图 9 导电粒子的检测效果
Fig. 9 Results of conductive particle detection




图 10 清晰组导电粒子的检测效果
Fig. 10 Conductive particle detection results of easy-detecting group

糊、粒子粘连重叠较严重)时,各方法的检测效果均有不同程度的下降,而本文提出的方法仍能保持较好的检测效果,说明本文提出的方法对图像质量的稳定性更强,尤其对图像的模糊干扰和粒子的粘连重叠等因素具有更好的抵抗能力。图 11

从稳定性角度对比上述方法的结果,原图中的 5 张图为相同设备在不同批次下对面板相同位置读取得到的粒子图像。受篇幅限制,本文仅从待测样本中抽取部分结果展示。原图中的 5 张图为相同设备在不同批次下对面板相同位置读取得到的

粒子图像。图 12 是将图 11 列出的各方法结果的指标中表示稳定性的部分进行可视化。由于稳定

性指标是结果图之间两两比较得到的,故对参与测试的 10 张图,图像对的数量为 $C_{10}^2 = 45$ 。




图 11 稳定性比较

Fig. 11 Comparison of stability




图 12 稳定性比较的数据化

Fig. 12 Comparison of stability through data graph

5 结 论

为了提高粒子检测尤其是粘连粒子的精度

和稳定性,本文提出基于简化可变形卷积神经网络的粘连粒子检测。首先提出了更适合粒子检测的圆卷积,代替原网络的部分卷积层,引入并修改可变形卷积的采样策略,限制采样点偏移量的自由度,并增加尺寸控制参数。然后引入注意力机制,通过标签图计算自注意力,并作为权重修改损失函数和标签图。最后,在评价指标中增加稳定性以更加全面地评价网络。实验结果表明,本文方法的可重复性和可再现性指标分别为 0.809 2 和 0.705 1,分别优于现有最佳方法的 4.52% 和 1.74%;精确度和召回率分别为 0.712 8 和 0.697 4,准确率为 0.834 1,优于现有主流方法的 1.68%。该方法在粘连干扰的粒子图像上取得了较好的效果,可以满足工业上绝大多数情况下粒子检测精度和稳定性的要求。

参考文献:

- [1] HWANG H, KONG M, KIM K, *et al.* Stretchable anisotropic conductive film (S-ACF) for electrical interfacing in high-resolution stretchable circuits [J]. *Science Advances*, 2021, 7(32): eabh0171.
- [2] 贾磊. 面向超细间距玻璃覆晶封装的凸点植焊导电颗粒技术开发与研究[D]. 上海: 上海交通大学, 2014.
JIA L. *Development of Particle on Bump Method for Ultra-fine Pitch Chip on Glass Technology*[D]. Shanghai: Shanghai Jiao Tong University, 2014. (in Chinese)
- [3] GOYANES S. Conductive particles in anisotropic conductive films[J]. *Polymer Science: Peer Review Journal*, 2022, 3(1): 1-5.
- [4] 范凌霄. 基于机器视觉的 TFT-LCD 面板芯片在线检测技术研究[D]. 南京: 东南大学, 2022.
FAN T X. *Research on On-line Inspection Technology of TFT-LCD Panel Chip Based on Machine Vision*[D]. Nanjing: Southeast University, 2022. (in Chinese)
- [5] 夏衍, 罗晨, 周怡君, 等. 基于 Swin Transformer 轻量化的 TFT-LCD 面板缺陷分类算法[J]. *光学精密工程*, 2023, 31(22): 3357-3370.
XIA Y, LUO CH, ZHOU Y J, *et al.* A light-weight deep learning model for TFT-LCD circuits

- defect classification based on swin transformer[J]. *Opt. Precision Eng.*, 2023, 31(22): 3357-3370. (in Chinese)
- [6] LIN C S, HUANG K H, LIN T C, *et al.* An automatic inspection method for the fracture conditions of anisotropic conductive film in the TFT-LCD assembly process[J]. *International Journal of Optomechatronics*, 2011, 5(3): 286-298.
- [7] ARKIN E, YADIKAR N, MUHTAR Y, *et al.* A survey of object detection based on CNN and transformer[C]. 2021 *IEEE 2nd International Conference on Pattern Recognition and Machine Learning (PRML)*. Chengdu, China. IEEE, 2021: 99-108.
- [8] ZHU X Z, SU W J, LU L W, *et al.* Deformable DETR: Deformable Transformers for End-to-end Object Detection [EB/OL]. 2020: arXiv: 2010.04159. <http://arxiv.org/abs/2010.04159>.
- [9] WANG Y Y, MA L, JIAN L H, *et al.* Multi-scale deep adversarial network for particle detection in liquid crystal module[J]. *Applied Soft Computing*, 2022, 116: 108326.
- [10] WANG Y Y, MA L, JIANG H Q. Detecting conductive particles in TFT-LCD with U-MultiNet[C]. 2019 *8th International Symposium on Next Generation Electronics (ISNE)*. Zhengzhou, China. IEEE, 2019: 1-3.
- [11] WANG Y Y, MA L, JIU M Y, *et al.* Detection of conductive particles in TFT-LCD circuit using generative adversarial networks[J]. *IEEE Access*, 2020, 8: 101338-101350.
- [12] LIU E Y, CHEN K P, XIANG Z Y, *et al.* Conductive particle detection via deep learning for ACF bonding in TFT-LCD manufacturing[J]. *Journal of Intelligent Manufacturing*, 2020, 31(4): 1037-1049.
- [13] WANG Y Y, MA L, JIAN L H, *et al.* Conductive particle detection via efficient encoder-decoder network[J]. *Journal of Intelligent Manufacturing*, 2023, 34(8): 3563-3577.
- [14] TAO X, MA W Z, LU Z F, *et al.* Conductive particle detection for chip on glass using convolutional neural network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3519310.
- [15] LUO C, FAN T X, XIA Y, *et al.* Deep learning-based conductive particle inspection for TFT-LCDs inspired by parametric space envelope[J]. *Journal of Intelligent Manufacturing*, 2023, 1(1): 1-11.
- [16] LI T Y, ZHANG F, YANG H B, *et al.* A novel method for LCD module alignment and particle detection in anisotropic conductive film bonding[J]. *Machines*, 2023, 11(1): 49.
- [17] DAI J F, QI H Z, XIONG Y W, *et al.* Deformable convolutional networks[C]. 2017 *IEEE International Conference on Computer Vision (ICCV)*. Venice, Italy. IEEE, 2017: 764-773.
- [18] LI W, LIU K, ZHANG L Z, *et al.* Object detection based on an adaptive attention mechanism[J]. *Scientific Reports*, 2020, 10(1): 11307.
- [19] OSTHUS D, WEAVER B P, CASLETON E M, *et al.* On gauge repeatability and reproducibility studies for counts[J]. *Quality Engineering*, 2021, 33(4): 641-654.
- [20] WANG Z, BOVIK A C, SHEIKH H R, *et al.* Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2004, 13(4): 600-612.

作者简介:



刘子龙(2000—),男,河南安阳人,硕士研究生,2022年于东南大学获得学士学位,主要从事计算机视觉、机器视觉方面的研究。E-mail: 220220304@seu.edu.cn

通讯作者:



罗晨(1980—),女,江苏扬州人,博士,副教授,博士生导师,2005年、2010年于上海交通大学分别获得硕士和博士学位,主要从事机器视觉、三维重构和公差建模方面的研究。E-mail: chenluo@seu.edu.cn