

DOI: 10.13382/j.jemi.B2407991

基于 SOP 芯片三维点云图像的引脚缺陷检测方法^{*}

林冬梅 樊煜杰 陈晓雷 杨富龙 李 策

(兰州理工大学电气工程与信息工程学院 兰州 730050)

摘要:针对目前小外形封装(SOP)芯片引脚的三维缺陷检测任务,现有的点云深度学习方法难以有效检测常见的引脚缺陷。为解决这一问题,定义了一种有缺陷的芯片引脚点云(DCPP)图像,并创建了相应的DCPP数据集。同时提出了一种面向DCPP图像的DCPP-PointNet缺陷检测算法。该算法新增加的局部-空间特征提取(LSFE)网络,可有效提高模型的旋转鲁棒性,使得模型在面对旋转的芯片点云数据时仍能保持良好的检测性能;其次设计全新的倒残差多尺度卷积网络(iRMSC-Net)替换PointNet++中的特征编码器,通过加强对点云边缘局部信息的学习能力,从而实现 SOP 芯片引脚常见缺陷的精确分类和定位;最后采用 Focal 损失函数解决了正负样本不平衡的问题,使得模型能够更加关注难以区分的缺陷样本,提高检测精度。在自建的DCPP数据集上进行的实验结果表明,DCPP-PointNet网络在总体准确率(OA)和平均交并比(mIoU)等评估指标上均优于现有的PointNet、PointNet++、DGCNN等经典点云分割模型,展现了高达98.9%的OA和93.7%的mIoU。消融实验进一步验证了DCPP-PointNet中各个改进模块的有效性,LSFE网络、iRMSC-Net特征编码器和Focal损失函数三者共同作用,对提高模型的检测精度和鲁棒性具有重要意义。

关键词:小外形封装芯片引脚;三维缺陷检测;点云处理;DCPP-PointNet

中图分类号: TP391.4; TN307 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Pin defect detection method based on 3D point cloud image of SOP chip

Lin Dongmei Fan Yujie Chen Xiaolei Yang Fulong Li Ce

(School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: For the three-dimensional defect detection task of SOP chip pins, existing point cloud deep learning methods struggle to effectively detect common pin defects. To address this issue, a DCPP image is defined and a corresponding DCPP dataset is created. A DCPP-PointNet defect detection algorithm is also proposed, specifically designed for DCPP images. This algorithm incorporates a LSEF network, which enhances the model's rotational robustness and ensures good detection performance even with rotated point cloud data. Additionally, a new iRMSC-Net network is designed to replace the feature encoder in PointNet++, improving the model's ability to learn local edge features of point clouds and enabling precise classification and location of common SOP chip pin defects. Focal loss function is employed to tackle the imbalance between positive and negative samples, allowing the model to focus more on hard-to-distinguish defect samples and thus improving detection accuracy. Experimental results on the self-built DCPP dataset show that the DCPP-PointNet network surpasses existing point cloud segmentation models such as PointNet, PointNet++, and DGCNN in terms of OA and mIoU. It achieved an OA of 98.9% and an mIoU of 93.7%. Ablation studies further confirm the effectiveness of the improvements in DCPP-PointNet, where the combined action of the LSFE network, iRMSC-Net feature encoder, and Focal loss function significantly enhances the model's detection accuracy and robustness.

Keywords: small out-line package chip pins; three-dimensional defect detection; point cloud processing; DCPP-PointNet

收稿日期:2024-11-27 Received Date: 2024-11-27

^{*} 基金项目: 国家自然科学基金(62361038, 62363025)、甘肃省集成电路制造材料创新联合体项目(23ZDGE001)、甘肃省科技计划(24JRRA181)、甘肃省教育厅高校教师创新基金(2023A-019)项目资助

0 引言

小外形封装 (small out-line package, SOP)^[1] 是一种很常见的元器件封装形式,表面贴装型封装之一,引脚从封装体两侧引出呈海鸥翼状(L 字形)。为了更好地存储芯片引脚,需要使用保护层,并在芯片安装前通过镀锡工艺进行镀锡。在这个过程中,芯片的引脚很容易因为高温而发生轻微的变形。表面贴装技术的成功率不仅由贴装工艺决定,贴片芯片引脚的质量也起着决定性的作用^[2]。所以在芯片封装出厂前和贴装到印制电路板 (printed circuit board, PCB) 前对其引脚进行检测是十分必要的。

SOP 芯片引脚的检测主要分为二维和三维两种方式。二维检测技术已比较成熟,方法大致有机器学习和深度学习算法两种。其中, Han 等^[3] 使用最小二乘法计算芯片引脚的中心坐标和角度来进行缺陷检测。Ou 等^[4] 提出了基于动态阈值的快速分割算法来获取芯片特征图像,并设计了一种基于灰度跳变检测的芯片引脚缺陷检测方法。Qiao 等^[5] 利用自动视觉对芯片引脚进行特征提取,提高了芯片引脚缺失、弯曲和粘连引脚缺陷检测的效率。Chen 等^[6] 设计了一种基于 YOLOv4-tiny 算法的轻量级检测算法,用于检测不同尺寸芯片中的漏针缺陷。张恒等^[7] 提出基于 YOLOv5 改进的缺陷检测方法,提出新增小目标特征检测器,提升模型对小目标缺陷的学习能力。但基于二维图像的缺陷检测对环境的要求较为严格,如果光照条件太暗或太亮,基于二维图像就难以识别缺陷。同时,由于 SOP 芯片引脚本身过于细小,其缺陷的特征往往需要从三维空间中进行检测,用以判断缺陷是否符合标准。例如, Lu 等^[8] 采用双目视觉检测系统对芯片引脚三维重构,结合角点检测算法和梯度相关矩阵预处理算法,对传送带上的芯片进行自动识别。Du 等^[9] 针对现有目标检测算法在检测引脚微小变形时的不足,提出了一种基于深度直方图和目标导向多模态自注意机制的实时检测方法。但其本质上还是基于像素的方法,测量的效果很大程度上依赖于测量的环境。线激光传感器作为主动视觉技术之一,可以提供高密度点云数据,完美反映了 SOP 芯片精细的三维引脚表面。例如,宋丽梅等^[10] 利用高精度轮廓线激光采集 SOP 芯片点云数据,通过点云处理技术对引脚共面度进行检测。梁天为等^[11] 利用点云处理对 QFP 芯片引脚平面度进行评估。然而,现有研究主要集中于芯片引脚的平面度测量,对芯片引脚缺陷进行精确分类的研究相对较少。例如,引脚间相互粘连、弯斜或残缺等常见缺陷的三维检测。如果能将上述芯片引脚缺陷精准分类,就能很大程度上避免由芯片质量问题造成的 PCB 板装贴成品质量下降的问题。

综上所述,为了解决对芯片引脚高密度点云数据的分类和定位问题,需要高效的处理算法支持。最近几年随着深度学习在点云领域的发展,其分割与分类方法也越来越多,如 PointNet++^[12]、PointGMM^[13]、PointCNN^[14]、PointConv^[15]、DGCNN^[16] 等,已经有越来越多学者将其应用于工业缺陷检测领域。Park 等^[17] 引入了双级点云缺陷检测网络,通过点云分割来检测 PCB 板中的锡膏缺陷。张臣等^[18] 针对铝合金薄板激光焊接经常会出现咬边、凹陷这两种尺寸小、特征相似的表面缺陷,开发了一种基于深度学习缺陷分类一点云测量的在线监测系统,利用高密度的点云数据对缺陷进行识别、分类与测量。Wang 等^[19] 提出了一种新的改进的 PointNet++, 用于对排水管道中不同形状和大小的缺陷进行分类和分割。Wang 等^[20] 提出基于多个视点之间的关系学习区分形状描述符和多视点 GCN,用于对飞机机身上综合生成的点云数据集中的缺陷(划痕、凹痕、突出)进行分类。

目前,尚未发现利用点云深度学习技术进行 SOP 芯片引脚缺陷检测的相关公开文献报道。而且现有的方法在处理 SOP 芯片引脚缺陷检测时仍存在旋转鲁棒性不足、边缘特征提取能力有限和样本不平衡等问题。因此,本文提出了一种专门针对 SOP 芯片引脚的点云缺陷检测算法。首先,定义了有缺陷的芯片引脚点云(defective chip pin point, DCP)图像并构建相应的数据集。然后,设计了 DCP-PointNet 缺陷检测模型,该模型新增了局部-空间特征提取(local-spatial feature extraction, LSFE)网络以解决点云数据的旋转不变性问题,并采用倒残差多尺度卷积网络(inverted residual multi-scale convolutional net, iRMSC-Net)编码器提升特征鲁棒性,同时使用 Focal 损失函数^[21]解决了正负样本不平衡的问题。

综上所述,本文的研究不仅填补了 SOP 芯片引脚三维缺陷检测领域的空白,还为工业检测提供了一种高效、准确的解决方案,具有重要的理论意义和实际应用价值。

1 DCP 图像的获取

通过线激光轮廓传感器采集到的芯片点云图像通常数据量庞大,直接输入网络模型会消耗大量的时间和计算资源。而且,由于受到设备采集精度和芯片引脚表面特性影响,点云表面容易出现离目标点云较远以及相互混杂的点云噪声。因此,需要通过点云图像预处理,得到含有高度信息的芯片引脚及封装体表面的点云图像,本文称之为 DCP 图像。

DCP 图像获取示意图如图 1 所示。其中检测设备主要由线激光轮廓传感器、计算机和传送带组成。线激光轮廓传感器通过内置激光发生器发射线激光,照射到待测芯片表面。传感器内置的相机从一个角度获得芯片

表面上反射回来的激光。由于芯片不同位置到传感器的距离不同,反射回来的激光会落在相机成像区域的不同位置上。传感器的激光发射器、相机和待测芯片形成一个三角形,通过预先标定的传感器参数,可以计算出激光照射在芯片表面所形成激光轮廓上各点的高度,通过传送带移动使传感器可以采集到完整的芯片表面轮廓后输

出原始的芯片点云图像。原始的点云图像拥有很多杂乱的干扰点以及庞大的载物平台点云数据,这对后期的缺陷检测精度有着或多或少的影响。因此,本文首先对芯片点云图像进行预处理,得到 DCPD 图像后再对其进行缺陷检测。

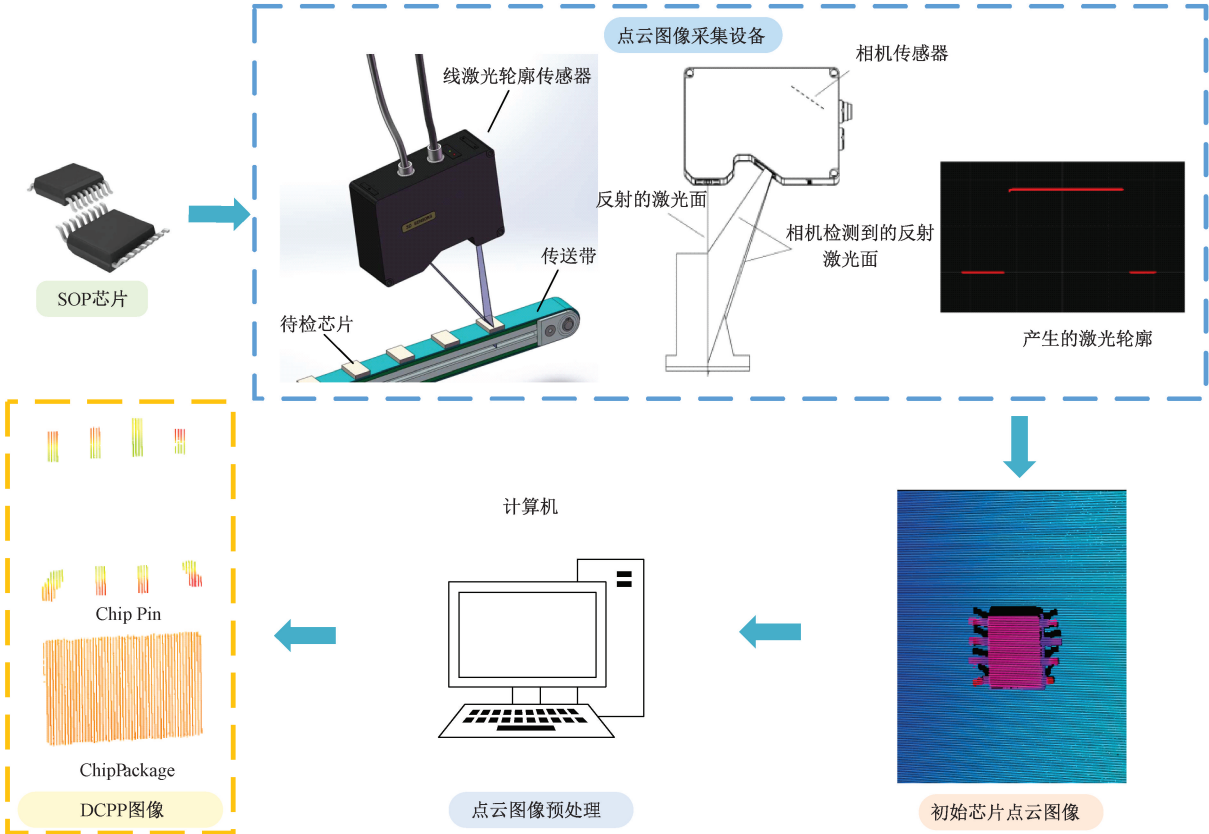


图 1 DCPD 图像获取示意图
Fig. 1 Schematic diagram of DCPD image acquisition

芯片点云图像预处理如图 2 所示。首先,利用基于统计学方法的离群点算法和基于法线的双边滤波算法^[22-23],去除由于激光扫描产生的不均匀点云噪声并且对点云表面进行平滑处理。然后,将降噪处理后的芯片点云图像根据高度信息进行颜色渲染,得到渲染处理芯片点云图像。最后,经过基于颜色的区域生长分割后,芯片引脚点云图像、芯片封装体点云图像和载物平台表面点云图像可以快速分离,并且通过设置合理的阈值范围就可以得到仅保留芯片引脚和封装体表面的点云图像,即 DCPD 图像。

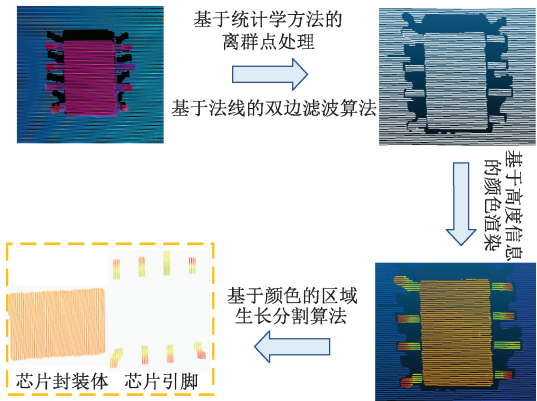


图 2 芯片点云预处理流程
Fig. 2 Chip point cloud preprocessing flowchart

2 DCPD-PointNet 缺陷检测模型

PointNet++算法是目前点云深度学习领域的典型算法,近几年其改进模型在缺陷检测领域取得了不错的成

果。本文提出的 DCPD-PointNet 改进了 PointNet++中的

点云特征编码器并重新设计了点云空间变换环节,以 DCPD 图像 $I \in R^N$ 为输入,输出每点分割检测结果 $M_{\text{seg}} \in R^{N \times C}$ 。这里, N 相当于 DCPD 图像中的点云点数, $C = m + 1$ 是引脚类别与封装体的数量,其中, m 表示缺陷类别的数量。其整体网络结构如图 3 所示,首先提取 DCPD 图像的局部特征与空间特征进行点云空间变换

以实现旋转鲁棒性。其次,提出适用于点云分割的 iRMSC-Net 提取 DCPD 图像的层次特征,并不断重复 4 次用以实现对局部特征不断的提取,加强对点云的特征学习。而后通过残差跳连接进行特征链接,将分层特征反馈给分割解码器,最终生成 M_{seg} 。

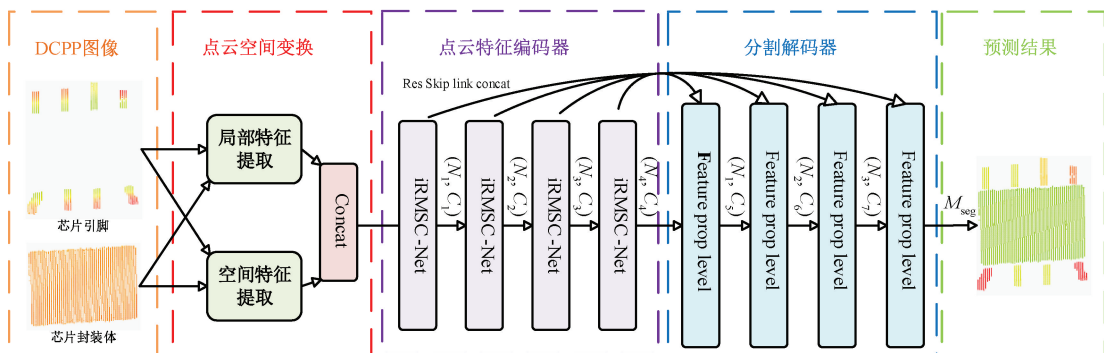


图 3 DCPD-PointNet 整体网络结构

Fig. 3 The overall network structure of DCPD-PointNet

2.1 点云空间变换网络

在实际的生产过程中,位于传送带上的 SOP 芯片发生任意旋转是时常发生的,而任意倾斜的芯片点云数据直接输入一般的分割网络中,其性能将会出现大幅下降。针对此类问题,需要改变输入的特征,即不直接输入绝对坐标到网络中,并且使网络学习到的特征不论如何旋转都是一致的。虽然原有的 PointNet++ 使用了 T-Net 用于生成一个仿射变换矩阵来对点云的旋转、平移等变化进行规范化处理,但是其对于分割任务几乎没有帮助。所以本文提出了 LSFE 网络,来构建 DCPD 图像的相对几何特征。

1) 局部特征提取

由于 DCPD 图像特性,其局部特征的提取对于最终的检测精度尤为关键。考虑到旋转不变性,本文参考了先前的一些经验,使用相对距离和角度作为基本的边缘描述符。同时,为了拥有更丰富的局部形状描述集合,参考内核关联层 (kernel correlation, KC)^[24],通过如下描述旋转不变几何属性 (距离和角度) 间的高阶关系。

如图 4 所示,对于查询点 $u_q = d \times n_q$,通过 K 近邻域点 (k-nearest neighbor, KNN) 采样算法生成局部图,并且假设邻域点 P_k 是 KNN 生成的局部点之一。 $u_q = d \times n_q$ 和 P_k 之间的相对位置被描述为 $u_q = d \times n_q$ 。然而, P_k 的位置没有考虑方向。因此,通过计算以 $u_q = d \times n_q$ 和 P_k 为中心的局部坐标之间的高阶关系来估计 P_k 的方向。查询点坐标 $u_q = d \times n_q$ 被生成为:

$$u_q = d \times n_q \quad (1)$$

$$v_q = u_q \times n_q \quad (2)$$




图 4 局部特征的提取

Fig. 4 Extraction of local features

式中: \times 表示叉积。 $[d, (n_q, u_q, v_q), (n_k, u_k, v_k)]$ 用作表征高阶相对关系的结构; (n_k, u_k, v_k) 表示邻域点坐标。 P_k 的方位由 7 维矢量 $F_a = \text{MLP}_a(F) (\in R^{N_f})$ 计算,其中每个 θ 分别表示一对特征描述符 (d, n_q) 、 (d, n_k) 、 (n_q, n_k) 、 (u_q, n_k) 、 (v_q, v_k) 、 (u_q, v_k) 、 (v_q, u_k) 之间的角度。此外,每个角度描述符由两个低阶特征描述符之间的 $\cos \theta_1 = \frac{d \cdot n_q}{\|d\| \|n_q\|}$ 相似度来定义,以 θ_1 为例,如式(3)所示。而 θ_6 和 θ_7 是为了解决因局部曲面方向而引起的歧义。

$$\cos \theta_1 = \frac{d \cdot n_q}{\|d\| \|n_q\|} \quad (3)$$

2) 空间特征提取

由于缺乏独特的空间属性,仅使用局部特征描述是不够的。考虑到位于平面上的点,局部几何属性往往是相似的,并且不可避免地造成混淆。因此,一般利用旋转不变的空间属性解决这个问题。

提取空间属性的直观解决方案是使用球坐标系中的点位置。然而,原始位置对旋转很敏感。为了获得旋转不变的空间属性,本文使用了奇异值分解(singular value decomposition, SVD),其能够寻找正交旋转变换方向。因此,本文对原始点云 P_0 进行奇异值分解,如式(4)所示。

$$P_0 = U \Sigma V^T \quad (4)$$

式中: U 是一个 $m \times m$ 的矩阵; Σ 是一个 $m \times n$ 的矩阵,除了主对角线上的元素以外全为 0,主对角线上的每个元素都称为奇异值; V 是一个 $n \times n$ 的矩阵, U 和 V 包含 3 个与旋转等变的正交轴。为了实现旋转不变性,将点从原始模型变换到新建的全局坐标系,如式(5)所示。

$$\hat{P} = P_0 \cdot V \quad (5)$$

式中: \hat{P} 描述所需的空间旋转不变属性。此外,由于原始奇异值分解技术容易受到符号翻转的影响,本文通过估计每个正交轴和距离质心最远的点之间的角度来确定 3 个正交轴的最终方向。如图 5 所示,如果对应的角度大于 90° ,则正交轴将发生翻转。




图 5 确定位置提取中正交轴的最终方向

Fig. 5 Determining the final pattern of the orthogonal axis in position extraction

2.2 点云特征编码器

由于 DCPD 图像中引脚都位于图像边缘,且相较于整体点数较少,如果直接应用 PointNet++ 中的特征提取模块,难以提取有效的引脚特征,为了加强对小目标特征信息的利用,需要增强对点云边缘局部信息的学习能力。

因此本文采用新设计的 iRMSC-Net 作为点云特征编码器,如图 6 所示,输入点云通过最远点采样算法(farthest point sampling, FPS)来实现从 N 个点中采样 N_f 个点,再通过 KNN 进行降采样将 DCPD 图像分组为局部区域。受倒移动残差块(inverted residual mobile block, iRMB)^[25]和 SegNext^[26]的启发,将 iRMB 和多尺度卷积注意力(multi-scale convolutional attention, MSCA)操作相融合引入特征提取部分,提出了 iRMSC-Net,在不增加模型复杂度的同时提升芯片引脚缺陷识别精度。加入 iRMSC-Net 模块后模型更加注重引脚及封装体边缘特征的提取。最后,通过最大池化操作对提取特征进行融合。

本文提出的 iRMSC-Net 主要由 3 个部分组成:首先,输入特征通过多层感知器进行升维操作:

$$F_a = \text{MLP}_a(F) (\in R^{N_f}) \quad (6)$$

然后,利用中间算子对点云特征 F_a 进行增强:

$$F_m = M(F_a) (\in R^{N_f}) \quad (7)$$

本文选用多尺度卷积注意力作为中间算子 M ,多尺度卷积注意力主要由用于聚集局部信息的深度卷积,用来提取芯片引脚特征的多分支深度条状卷积,以及用于对不同通道之间的关系进行建模的 1×1 卷积组成,其公式如下:

$$M = \text{conv}_{1 \times 1} \left(\sum_{i=0}^3 \text{Scale}_i(\text{DW-Conv}(F_a)) \right) \otimes F_a \quad (8)$$

式中: \otimes 是逐个元素的矩阵乘法运算; DW-Conv 表示深度卷积; $\text{Scale}_i, i \in \{1, 2, 3\}$ 表示第 i 个分支。

最后,通过多层感知器进行降维操作,减小通道数:

$$F_r = \text{MLP}_r(F_m) (\in R^{N_f}) \quad (9)$$

并且通过残差连接初始点云特征 F 和降维点云特征 F_r 得到最终结果 E :

$$E = F \oplus F_r (\in R^{N_f}) \quad (10)$$

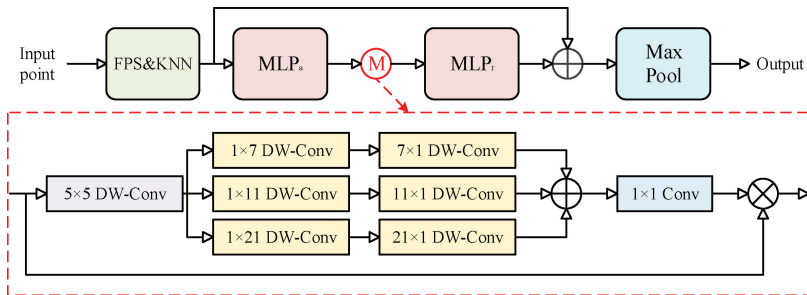


图 6 iRMSC-Net 整体网络结构

Fig. 6 The overall network structure of iRMSC-Net

2.3 分割解码器

如图 7 所示,分割解码器由特征传播层堆叠而成,其中特征传播层由 Interpolate 和 Unitpointnet (1×1 卷积网

络)组成。当点云特征被输送到插值层,它们就从 $N_l \times C_l$ 传播到 $N_{l-1} \times C_{l-1}$ 。这里,新创建的点云特征是通过 KNN 选择的周围点的反距离加权平均来计算的。然后,

通过残差跳连接将大小为 $N_{l-1} \times C_l$ 的插值特征与 iRMS-Net 层 $l-1$ 中的点云特征连接起来。然后,将大小为 $N_{l-1} \times (C_l + C_{l-1})$ 的特征输入 Unitpointnet,对其中每个点应用 1×1 卷积网络,更新每个点的特征向量。重复该特征传播过程,得到的点集中的点数变为原始输入点集的点数。




图 7 分割解码器结构

Fig. 7 Structure of the segmentation decoder

2.4 Focal 损失函数

损失函数的设计是影响模型性能的重要原因之一, PointNet++ 使用的是 NLL Loss,但是由于 DCPD 图像缺陷样本远小于正常样本,DCPD 数据集中不同类别引脚分布情况如图 8 所示,大量冗余的正常样本不仅无法显著提升模型的泛化能力,反而可能因样本分布失衡而掩盖少量关键缺陷样本的特征信息(正样本表示正常样本,负样本表示缺陷样本),从而削弱模型对异常模式的识别精度。所以为了解决正负样本不平衡的问题,本文使用了 Focal loss 替换掉原来的 NLL Loss。Focal loss 是在交叉熵(cross entropy, CE)损失的基础上进行改进的一种损失函数。它是一个动态缩放的交叉熵损失,通过一个动态缩放因子,可以动态降低训练过程中易区分样本的权重,从而将重心快速聚焦在那些难区分的样本。Focal loss 的公式如下:

$$FL(p_i) = -\alpha_i(1-p_i)^\gamma \log(p_i) \quad (11)$$

为解决正负样本不平衡问题,引入一个权重因子 α_i 。同时,为了区分样本的难易程度,引入了一个调制因子 γ ,用来聚焦难分样本。即通过 α_i 可以抑制正负样本的数量失衡,通过 γ 可以控制难易区分样本数量失衡。在本文中,根据 DCPD 图像样本难易分类样本和正负样本数量,取 $\alpha_i = 0.25, \gamma = 2$ 。

3 实验结果与分析

3.1 DCPD 数据集

SOP 芯片引脚缺陷样品主要来源于封装生产线,均为 SOP-8 芯片,芯片尺寸为 $4.9 \text{ mm} \times 6.0 \text{ mm}$,厚度为 1.5 mm ,采用 8 引脚封装,单个引脚宽度为 0.51 mm 。引脚缺陷包括常见的引脚上翘或下折、引脚弯斜和引脚缺损,共 715 个样品。收集到的样品通过线激光轮廓传感器采集到高密度点云,再通过预处理操作得到 DCPD 图像。每张 DCPD 图像由一个封装体图像和 8 个引脚组




图 8 DCPD 数据集中不同类别引脚分布情况

Fig. 8 Distribution of pins of different categories in the DCPD dataset

成,因此共采集了 715 组封装体数据,1 980 组正常引脚数据,1 040 组上翘引脚数据,966 组下折引脚数据,772 组弯斜引脚数据和 962 组缺损引脚数据。

根据实际情况对 DCPD 图像根据缺陷种类标注标签,标签包括:封装体、正常引脚、上翘引脚、下折引脚、弯斜引脚与缺损引脚。DCPD 标注示例如图 9 所示。




图 9 DCPD 标注示例

Fig. 9 DCPD annotation examples

同时为了使模型更容易收敛到正确的最优解,对标签图像采用点云归一化操作,将所有点的坐标和尺寸归一化到相同的坐标系下,从而避免了不同坐标系下的误差。归一化后的图像随机选取 492 张作为训练数据集。为了提高模型鲁棒性,增加数据多样性,在训练数据集上

采用随机旋转的数据增强操作。其余 DCPD 图像作为测试集。SOP 芯片所需检测的缺陷类别、点云组数及对应的训练集和测试集的数量如表 1 所示。

表 1 SOP 芯片所需检测的缺陷类别、点云组数及对应的训练集和测试集的数量

Table 1 The type of defect, number of point cloud groups and the corresponding number of training sets and test sets that SOP chips need to detect

类别	点云组数	训练集中点云组数	测试集中点云组数
封装体	715	572	143
正常引脚	1 980	1 584	396
上翘引脚	1 040	832	208
下折引脚	966	773	193
弯斜引脚	772	618	154
缺损引脚	962	769	193

3.2 实验结果与讨论

本文数据采集所使用的操作系统为 Windows, 实验所使用的芯片缺陷检测实验平台如图 10 所示, 其中线激光轮廓传感器采用的是 PMS-PL-08, 具体参数如表 2 所示。




图 10 芯片缺陷检测实验平台

Fig. 10 Chip defect detection experiment platform

模型训练所使用的操作系统为 Ubuntu, 本文网络使用 Python 3.9 和 PyTorch 1.10.1 实现。模型训练使用 NVIDIA RTX 3090Ti (24 GB 内存) 系统和 CUDA 11.3 进行。采用 Adam 优化器用于训练; 批处理大小为 8; 动量优化算法为 0.9; 采用指数衰减方法控制学习率变化, 衰减率为 0.000 1, 初始学习率设定为 0.001, 每次训练 50

个 epoch。

表 2 线激光轮廓传感器的具体参数

Table 2 Specific parameters of line laser profile sensor

指标	参数
激光线轮廓点的数目	1 920
视场/mm	26~32
分辨率 X/mm	0.014~0.017
分辨率 Y/mm	0.002~0.003 5
z 方向可重复性/μm	0.8
测量范围/mm	20
激光类	2 M
扫描速度	200 Hz

3.3 评估指标

为了评估芯片引脚分割性能, 本文按照点云分割领域的常规设置测量了总体准确率 (overall accuracy, OA) 和平均交互比 (mean intersection over union, mIoU)。同时, 为了评估不同芯片缺陷引脚分割精度, 本文还对每一类引脚测量了其交互比 (intersection over union, IoU)。其计算公式如下:

$$OA = \frac{n}{N}$$
 (12)

$$IoU = \frac{TP}{TP + FP + FN}$$
 (13)

$$mIoU = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FP_i + FN_i}, i \in C$$
 (14)

式中: C 表示数据集中芯片点云的分割类别 (包含封装体、正常引脚与缺陷引脚); TP 表示预测正确, 真正例, 模型预测为正例, 实际是正例; FP 表示预测错误, 假正例, 模型预测为正例, 实际是反例; FN 表示预测错误, 假反例, 模型预测为反例, 实际是正例; n 表示所有正确预测点的数量; N 表示点云模型所有点数; mIoU 值与 OA 值越接近 1, 则缺陷分割效果越好, 且有 $mIoU \leq OA$ 。

3.4 检测精度分析

使用 DCPD 数据集训练 DCPD-PointNet 模型, 模型在测试数据集上的典型检测结果如表 3 所示, 本文将所提出的缺陷分割模型与常见的点云语义分割模型进行了比较, 包括 PointNet、PointNet++、DGCNN 等经典点云分割模型。

表 3 使用 DCPD 数据集的模型缺陷分割结果

Table 3 The test results of DCPD dataset for model defect segmentation (%)

模型	IoU						mIoU	OA
	封装体	正常引脚	上翘引脚	下折引脚	弯斜引脚	缺损引脚		
PointNet	62.1	8.3	0	0	0	0	11.7	59.9
PointNet++	70.4	10.9	1.8	1.5	0.9	1.1	14.1	69.4
DGCNN	88.5	49.0	35.1	30.6	25.4	27.8	42.7	88.5
DCPD-PointNet	99.9	95.1	93.9	90.0	88.9	91.2	93.7	98.9

由表 3 的实验数据可以看出,相比于 PointNet 系列,本文所提出的网络模型在整体精度上最大提升了 39%,同时 DCPD-PointNet 可以达到 99.9% 的封装体识别准确率,而且对正常引脚的检测精度达到了 95.1%,对缺陷引脚的平均检测精度也达到了 93.7%,其中对缺损引脚和上翘引脚的识别精度略好于下折引脚和弯斜引脚。

为了进一步对缺陷分割后的结果进行说明,将 DCPD 图像、真实语义标签、PointNet 系列、DCPD-PointNet 分割出的部分结果进行可视化操作并进行比较,如图 11 所示。图 11(a) 为 DCPD 原始图像。图 11(b) 为真实的语义标签信息。图 11(c) 为 PointNet++ 检测的结果,可以明显观察到 PointNet 系列无法实现对芯片的有效分割,这主要是因为该系列算法未能充分学习局部特征。由图 11(d) 可知,除了一些边缘细节存在个别点的误检外,整体上与真实标签结果较为接近。因此,本文提出的 DCPD-PointNet 新增 LSFE 网络用以提高缺陷检测鲁棒性,同时采用新设计的 iRMS-Net 作为点云特征编码器,利用倒残差多尺度卷积聚合芯片边缘点云特征,提升模型对芯片引脚缺陷检测精度。最后更换 Focal 损失函数用以平衡正负样本不均的问题。总之,DCPD-PointNet 相比现有技术,展现了更高的缺陷检测精度。

3.5 消融实验

为验证改进部分对模型检测效果提升的有效性,本文进行了消融测试来对比改进模块后的检测效果。将新增 LSFE 网络、替换 MSC-Net 特征编码器、替换 iRMS-Net 特征编码器与更换 Focal 损失函数分别添加到 PointNet++ 模型中,并将 PointNet++ 作为基线模型用作对比,先后输入用于测试的 DCPD 图像,并给出多个改进模块组合的实验结果。

消融实验结果如表 4 所示。观察可知,单独添加 LSFE 网络后,由于 LSFE 对模型进行了预训练,OA 与 mIoU 分别从 69.4% 和 14.1% 上升到 74.5% 和 22.3%,但对引脚缺陷的检测没有明显帮助,同时参数量和计算量增加到 3.47×10^6 和 2.43 GFLOPs。将特征编码器替换为 iR-Net 后,新的特征提取模块使网络具备了对芯片引脚的检测能力,OA 与 mIoU 分别从 69.4% 和 14.1% 提升到 86.1% 和 76.3%,同时倒残差模块使模型在轻量化方面得到了提升,参数量从 3.47×10^6 降低到 2.40×10^6 ,计算量从 2.43 GFLOPs 降低到 0.98 GFLOPs,但多头注意力对相似的引脚特征提取能力有限。因此本文最终使用了 iRMS-Net 作为特征编码器,iRMS 模块不仅使 OA 从 69.4% 提升到 98.1%,对于业界最为关心的 mIoU 从 14.1% 提升到了 85.5%,参数量增加到 2.53×10^6 ,计算量增加到 1.45 GFLOPs,但对引脚的检测能力却有较大提升。

将 PointNet++ 中的 NLL Loss 替换为 Focal loss,由于

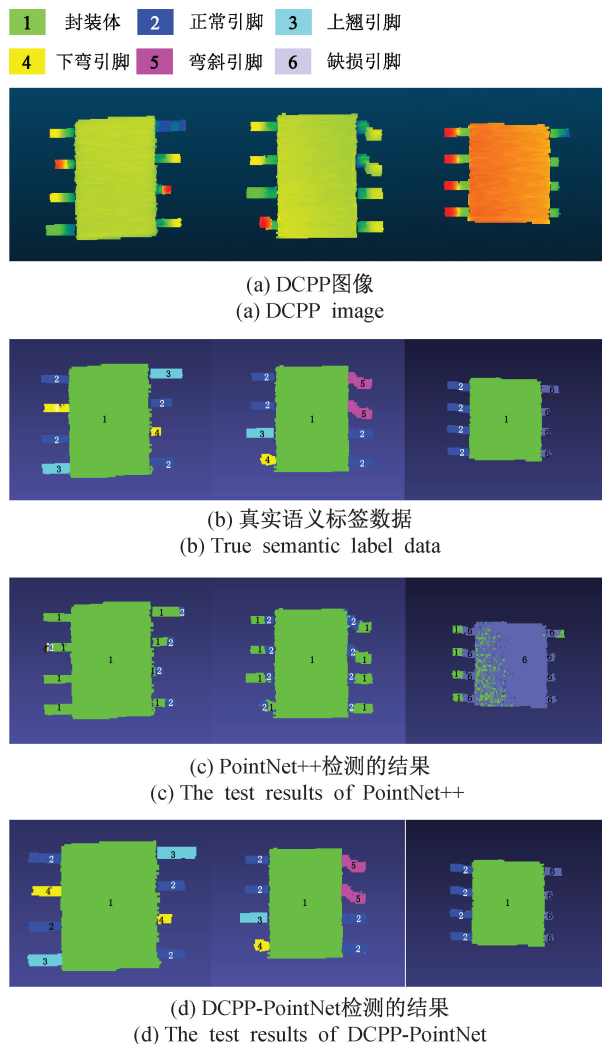


图 11 模型预测结果可视化图

Fig. 11 Visualization of model prediction results

Focal loss 主要是为了解决正负样本不平衡的问题,因此单独添加对网络检测精度并没有提升,OA 和 mIoU 与对比基线模型提升并不明显,仅为 8.4% 和 12.5%。在使用 iRMS-Net 的基础上替换 Focal loss 后,对比使用了 iRMS-Net 作为特征编码器的网络发现虽然 OA 从 98.1% 提升到 98.8%,并没有明显增长,但 mIoU 从 85.5% 提高到 90.8%,提升了 2.9%。最后,再添加上 LSFE 后,在不提升模型参数量和计算量的前提下,mIoU 分别从 69.4% 和 14.1% 提升到 98.9% 和 93.7%。

为了进一步验证 LSFE 网络的有效性,输入任意倾斜的 DCPD 图像。表 5 为关于删除 LSFE 网络后对倾斜数据的影响,删除 LSFE 网络后,模型对所有类别引脚的判别能力均显著下降。对于正常引脚、上翘引脚、下折引脚、弯斜引脚和缺损引脚的判别准确率分别从 96.2%、89.3%、85.5%、84.4% 和 87.2% 下降至 39.3%、14.2%、8.1%、8.5% 和 8.2%。

表 4 消融实验结果

Table 4 The test results of Ablation experiment

组别	LSFE	iR-Net	iRMSC-Net	Focal loss	OA/%	mIoU/%	参数量/($\times 10^6$)	计算量/GFLOPs
0					69.4	14.1	2.88	1.32
1	✓				74.5	22.3	3.47	2.43
2		✓			86.1	76.3	2.40	0.98
3			✓		98.1	85.5	2.53	1.45
4				✓	77.8	26.6	3.12	1.58
5			✓	✓	98.8	90.8	2.94	1.72
6	✓		✓	✓	98.9	93.7	2.89	1.80

表 5 LSFE 网络对模型的影响结果

Table 5 The impact of LSFE network on model results (%)

缺陷类型	DCPP-PointNet	Delete LSFE
正常引脚	96.2	39.3
上翘引脚	89.3	14.2
下折引脚	85.5	8.1
弯斜引脚	84.4	8.5
缺损引脚	87.2	8.2

图 12 所示为 LSEF 网络对倾斜图像的影响,图 12(a)为使用 LSEF 网络的倾斜图像检测结果,图 12(b)为删除此网络后的结果。对比图 12 可知,当不添加 LSFE 网络时,面对倾斜图像即使模型使用了 iRMSC-Net 和 Focal loss,模型依然无法准确判别各类引脚是否存在缺陷。

- 1


封装体
- 2

正常引脚
- 3


上翘引脚
- 4

下弯引脚
- 5

弯斜引脚



(a) DCPP-PointNet检测结果
(a) The test results of DCPP-PointNet



(b) 删除LSFE检测结果
(b) The test results obtained by deleting LSFE

图 12 LSFE 网络的影响结果

Fig. 12 The influence of LSFE point cloud spatial transformation network

表 6 为新增模块对上翘、下折、弯斜和缺损引脚的影响情况。图 13 所示为部分新增模块对检测结果的影响。由于每种缺陷拥有的特征不一致,对于不同的缺陷,各个

模块效果也不同。图 13(a)为使用基线模型 PointNet++ 检测结果,对比图 13 可知,当将特征编码器替换为 iR-Net 后,网络对正常引脚以及所有类型的缺陷引脚的检测精度都有较大提升,但是从图 13(b)也可以明显看到,模型对于封装体边缘特征以及引脚特征判别都有明显错误。随后,在特征编码器替换为 iRMSC-Net 后,网络对边缘和引脚特征识别更为准确,对于上翘、下折、弯斜和缺损引脚的 IoU 分别提升到了 88.5%、81.4%、72.6% 和 83.6%,但从图 13(c)还可以发现,对于弯斜引脚的检测仍有不准确的地方,分析数据后认为弯斜引脚的点云特征与其他引脚特征存在一定的相似性,同时弯斜引脚数据也少于其他缺陷。因此图 13(d)替换 Focal loss 使网络对不易分类样本和易分类样本进行了区别对待,把损失的焦点放在了不易分类样本上,降低对易分类样本的权重,从而平衡了不同缺陷间的检测精度。图 13(e)是加入 LSEF 网络后的完整 DCPP-PointNet 模型,可以看出,经过预处理后,模型的精度得到了进一步提升。

表 6 主要模块在各缺陷上的交互比

Table 6 The Intersection over Union of main modules in each defect (%)

缺陷类型	Point Net++	iR-Net	iRMSC-Net	iRMSC-Net+ Focal loss	DCPP-PointNet
上翘引脚	1.8	74.9	88.5	91.4	93.9
下折引脚	1.5	67.6	81.4	87.8	90.0
弯斜引脚	0.9	63.3	72.6	86.5	88.9
缺损引脚	1.1	76.2	83.6	89.2	91.2

综上所述,为了保证 SOP 芯片引脚缺陷检测精度,本文提出的 LSFE 网络和 iRMSC-Net 点云特征编码器以及用以平衡正负样本的 Focal 损失函数三者缺一不可。

4 结 论

本文针对 SOP 芯片引脚的缺陷检测需求,提出了一种基于深度学习的三维点云缺陷检测方法。通过构建专门的 DCPP 图像数据集和创新性地设计 DCPP-PointNet 网络,实现了对 SOP 芯片引脚常见缺陷的精确分类和定

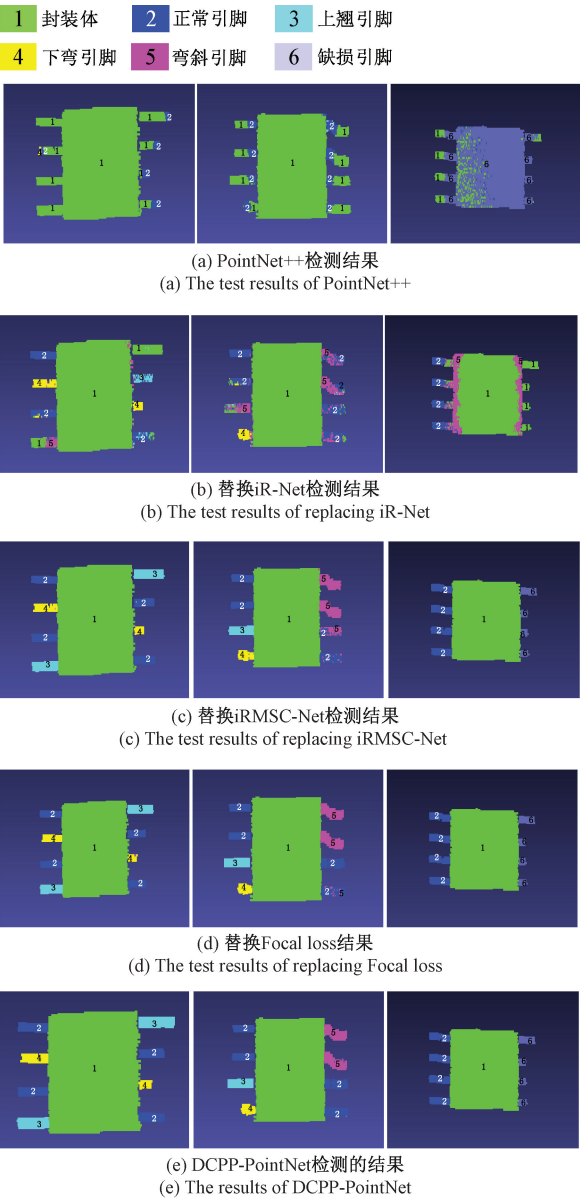


图 13 部分新增模块对检测结果的影响
Fig. 13 The impact of some new modules on the detection results

位。DCPP 图像数据集涵盖了多种常见引脚缺陷类型,经过处理去除了干扰信息,保留了关键形状与深度信息,为缺陷检测研究提供了高质量的数据支持。DCPP-PointNet 网络通过添加 LSFE 网络、替换特征编码器和损失函数等创新设计,加强了点云局部特征的提取能力,解决了正负样本不平衡的问题,提高了模型对缺陷的识别精度和检测的鲁棒性。综上所述,本文的研究为 SOP 芯片引脚的三维缺陷检测提供了一种高效、准确的解决方案,具有在实际工业检测流程中应用的潜力,有望提高检测效率 and 产品质量。未来的工作将进一步优化和扩展该模型,以适应更广泛的芯片检测场景。

参考文献

[1] 胡志强,吴一全. 基于机器视觉的芯片缺陷检测研究进展[J]. 仪器仪表学报, 2024, 45(7):1-26.
HU ZH Q, WU Y Q. Research progress in chip defect detection based on machine vision[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 1-26.

[2] ZHOU Y, YUAN M, ZHANG J, et al. Review of vision-based defect detection research and its perspectives for printed circuit board [J]. Journal of Manufacturing Systems, 2023, 70: 557-578.

[3] HAN B, YI M. A template matching based method for surface-mount rectangular-pin-chip positioning and defect detection [C]. 2018 Eighth International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC). IEEE, 2018: 1009-1014.

[4] OU X F, CHEN W, ZHANG M. Design of LQFP chip pin defect detection system based on machine vision[C]. 2021 Inter-national Conference on Machine Learning and Intelligent Systems Engineering (MLISE). IEEE, 2021: 69-76.

[5] QIAO X, CHEN T, ZHUANG W, et al. A Chip Defect Detection System Based on Machine Vision [M]. Proceedings of In-coME-VI and TEPEN 2021: Performance Engineering and Maintenance Engineering. Cham: Springer International Publishing, 2022: 555-568.

[6] CHEN S, LAI W, YE J, et al. A fast and low-power detection system for the missing pin chip based on YOLOv4-Tiny algorithm[J]. Sensors, 2023, 23(8): 3918.

[7] 张恒,程成,袁彪,等. 基于 YOLOv5-EA-FPNs 的芯片缺陷检测方法研究[J]. 电子测量与仪器学报, 2023, 37(5): 36-4.
ZHANG H, CHENG CH, YUAN B, et al. Research on chip defect detection method based on YOLOv5-EA-FPNs [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 36-4.

[8] LU S, ZHANG J, HAO F, et al. Automatic detection of chip pin defect in semiconductor assembly using vision measurement[J]. Measurement Science Review, 2022, 22(5): 231-240.

[9] DU C, XU L, CHEN J, et al. Real-time detection method for chip pin with minor deformation defects based on depth-histogram modalities and target-oriented multi-modal self-attention mechanism [J/OL]. Available at

- SSRN, 2024, <https://doi.org/10.2139/ssrn.4790135>.
- [10] 宋丽梅, 杨宏超, 魏泽, 等. 基于高精度轮廓线激光的芯片引脚共面度视觉检测系统[J]. 光学技术, 2018, 44(6): 686-689.
- SONG L M, YANG H CH, WEI Z, et al. A vision detection system for chip coplanarity based on high precision contour laser[J]. Optical Technique, 2018, 44(6): 686-689.
- [11] 梁天为, 朱呈祥, 陈浩. 基于点云处理的 QFP 芯片引脚三维测量[J]. 应用激光, 2021, 41(3): 556-560.
- LIANG T W, ZHU CH X, CHEN H. Three-dimensional measurement of QFP chip pins based on point cloud processing[J]. Applied Laser, 2021, 41(3): 556-560.
- [12] QI C R, YI L, SU H, et al. Pointnet ++: Deep hierarchical feature learning on point sets in a metric space [C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 5105-5114.
- [13] HERTZ A, HANOCCA R, GIRYES R, et al. Pointgmm: A neural gmm network for point clouds[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 12054-12063.
- [14] LI Y, BU R, SUN M, et al. PointCNN: Convolution on X-transformed points [C]. Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018: 828-838.
- [15] WU W, QI Z, FUXIN L. Pointconv: Deep convolutional net-works on 3D point clouds[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9621-9630.
- [16] PHAN A V, LE NGUYEN M, NGUYEN Y L H, et al. DGCNN: A convolutional neural network over large-scale labeled graphs [J]. Neural Networks, 2018, 108: 533-543.
- [17] PARK J M, YOO Y H, KIM U H, et al. D 3 pointnet: Dual-level defect detection pointnet for solder paste printer in surface mount technology [J]. IEEE Access, 2020, 8: 140310-140322.
- [18] 张臣, 胡佩佩, 朱新旺, 等. 基于高密度点云的激光焊接缺陷智能在线检测(特邀)[J]. 中国激光, 2024, 51(04): 85-96.
- ZHANG CH, HU P P, ZHU X W, et al. Intelligent online detection of laser welding defects based on high density point clouds (Invited) [J]. Chinese Journal of Lasers, 2024, 51(4): 85-96.
- [19] WANG N, MA D, DU X, et al. An automatic defect classification and segmentation method on three-dimensional point clouds for sewer pipes[J]. Tunnelling and Underground Space Technology, 2024, 143: 105480.
- [20] WANG Y, SUN W, JIN J, et al. MVGCN: Multi-view graph convolutional neural network for surface defect identification using three-dimensional point cloud [J]. Journal of Manufacturing Science and Engineering, 2023, 145(3): 031004.
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [22] WANG L, SHENG Y. Fast bilateral filtering using the Padé approximation [J]. Electronics Letters, 2017, 53(6): 395-397.
- [23] 周航, 韩权. 具有去除椒盐噪声能力的改进双边滤波算法[J]. 北京交通大学学报, 2017, 41(5): 43-51.
- ZHOU H, HAN Q. An improved bilateral filtering algorithm having the ability to remove salt-and pepper noise[J]. Journal of Beijing Jiaotong University, 2017, 41(5): 43-51.
- [24] SHEN Y, FENG C, YANG Y, et al. Mining point cloud local structures by kernel correlation and graph pooling[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4548-4557.
- [25] ZHANG J, LI X, LI J, et al. Rethinking mobile block for efficient attention-based models [C]. 2023 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE Computer Society, 2023: 1389-1400.
- [26] GUO M H, LU C Z, HOU Q, et al. Segnext: Rethinking convolutional attention design for semantic segmentation[J]. Advances in Neural Information Processing Systems, 2022, 35: 1140-1156.

作者简介



林冬梅(通信作者), 2006 年于兰州大学获得学士学位, 2009 年于兰州大学获得硕士学位, 2017 年于兰州理工大学获得博士学位, 现为兰州理工大学副教授, 主要研究方向为机器视觉技术及应用、检测技术与智能信息处理。


E-mail: lindm1215@lut.edu.cn

Lin Dongmei (Corresponding author) received her B. Sc. degree from Lanzhou University in 2006, M. Sc. degree from

Lanzhou University in 2009, and Ph. D. degree from Lanzhou University of Technology in 2017, respectively. Now she is an associate professor in Lanzhou University of Technology. Her main research interests include machine vision technology and applications, detection technology and intelligent information processing.



Fan Yujie received her B. Sc. degree from Shaanxi University of Technology in 2022. Now he is a M. Sc. candidate in Lanzhou University of Technology. His main research interests include detection technology and intelligent information processing.



Chen Xiaolei received his B. Sc. degree from Lanzhou University in 2003, M. Sc. Degree from Lanzhou University in 2006 and Ph. D. degree from Lanzhou University of Technology in 2014, respectively. Now he is a professor at Lanzhou University of Technology. His main research interests include

樊煜杰, 2022 年于陕西理工大学大学获得学士学位, 现为兰州理工大学硕士研究生, 主要研究方向为检测技术与智能信息处理。

E-mail: 1027823135@qq.com

陈晓雷, 2003 年于兰州大学获得学士学位, 2006 年于兰州大学获得硕士学位, 2014 年于兰州理工大学获得博士学位, 现为兰州理工大学教授, 主要研究方向为人工智能、计算机视觉和虚拟现实。

E-mail: chenxl703@lut.edu.cn

artificial intelligence, computer vision and virtual reality.



E-mail: yangfulong1982@126.com

Yang Fulong received his B. Sc. degree from Lanzhou University in 2006, M. Sc. Degree from Lanzhou University in 2009 and Ph. D. degree from Lanzhou University in 2019, respectively. Now he is an associate professor at Lanzhou University of Technology. His main research interests include metamaterials, intelligent information processing and electromagnetic sensing.



E-mail: lice@lut.edu.cn

Li Ce received his B. Sc. degree from Hefei University of Technology in 1995, M. Sc. Degree from Xi'an Jiaotong University in 2003 and Ph. D. degree from Xi'an Jiaotong University in 2013, respectively. Now he is a professor at Lanzhou University of Technology. His main research interests include computer vision and pattern recognition and artificial intelligence.

杨富龙, 2006 年于兰州大学获得学士学位, 2009 年于兰州大学获得硕士学位, 2019 年于兰州大学获得博士学位, 现为兰州理工大学副教授, 主要研究方向为超材料、智能信息处理和电磁传感。

李策, 1995 年于合肥工业大学获得学士学位, 2003 年于西安交通大学获得硕士学位, 2013 年于西安交通大学得博士学位, 现为兰州理工大学教授, 主要研究方向为计算机视觉与模式识别、人工智能。