

中图法分类号: TP18; TP391 文献标识码: A 文章编号: 1006-8961(2026)02-0374-17

论文引用格式: Wang C R, Chen Y J, Liu S H and Chen D L. 2026. Review of the progress in 3D defect detection methods. Journal of Image and Graphics, 31(2):0374-0390(王从容, 陈亚军, 刘善慧, 陈冬乐. 2026. 三维缺陷检测技术研究进展. 中国图象图形学报, 31(2):0374-0390)
[DOI:10.11834/jig.250111]

三维缺陷检测技术研究进展

王从容, 陈亚军*, 刘善慧, 陈冬乐

西安理工大学印刷包装与数字媒体学院, 西安 710054

摘要: 随着工业制造技术的不断进步, 产品质量控制对缺陷检测技术提出更高的要求。传统二维缺陷检测算法在处理复杂表面结构和形状时存在局限性, 难以满足高精度、高鲁棒性的检测需求。相比之下, 三维缺陷检测算法因具有更全面的信息、更高的准确率和更强的抗干扰性等优点, 近年来受到广泛关注和深入研究。及时追踪该领域的最新动态并紧跟学术前沿, 是推动三维缺陷检测技术不断突破、应对新挑战的必然要求。基于此, 本文系统总结了三维缺陷检测领域的研究进展与发展趋势。从工业需求和技术挑战的角度阐述了缺陷检测的研究背景与意义。从传统机器学习方法出发, 详细梳理了基于点云局部特征、点云配准和点云分割的三维缺陷检测方法, 分析其技术原理与经典方法。针对深度学习技术在三维缺陷检测中的创新应用, 从基于点云和基于多模态两个维度, 深入探讨了当前的研究现状与技术突破。本文还对常用的三维缺陷检测基准数据集进行了全面分析, 为研究者开展相关方法验证与性能评估提供参考。讨论了三维缺陷检测的主要挑战和未来发展趋势, 为推动三维缺陷检测技术的进一步发展提供了指导。

关键词: 缺陷检测; 计算机视觉; 三维视觉; 深度学习; 多模态; 综述

Review of the progress in 3D defect detection methods

Wang Congrong, Chen Yajun*, Liu Shanhui, Chen Dongle

Faculty of Printing, Packaging and Digital Media, Xi'an University of Technology, Xi'an 710054, China

Abstract: With the rapid development of modern manufacturing, consumers and producers have increasingly higher demands for product quality and safety. However, various defects such as dents, cracks, and bubbles inevitably occur during production, which may directly affect product performance. Therefore, early detection and accurate identification of defects are crucial for ensuring product quality and improving production efficiency. Traditional 2D defect detection methods only provide surface information of objects, making them inconsiderably effective in detecting deep or internal defects. Additionally, factors such as lighting, texture, and shadows can significantly influence the stability and robustness of 2D images in complex environments. In recent years, 3D defect detection technology has gradually become a research hotspot. By utilizing 3D data, such as point clouds and depth maps, it provides more comprehensive and accurate information, capturing the geometric shape, spatial distribution, and depth of objects, thereby enhancing detection accuracy and reliability. However, there is currently no systematic and comprehensive review article that tackles 3D defect detection technologies. This study aims to fill this gap by providing a thorough review of existing 3D defect detection methods and exploring

收稿日期: 2025-06-19; 修回日期: 2025-08-18; 预印本日期: 2025-08-25

* 通信作者: 陈亚军 chenyj@xaut.edu.cn

基金项目: 国家自然科学基金项目(62273273); 陕西省重点研发计划资助(2024GX-ZDCYL-02-02, 2023-YBNY-203)

Supported by: National Natural Science Foundation of China(62273273); Key R&D Program of Shaanxi Province, China(2024GX-ZDCYL-02-02, 2023-YBNY-203)

future research directions. This paper first introduces the background of defect detection, highlighting the limitations of 2D defect detection technologies in detecting complex 3D objects and deep defects, and emphasizes the advantages of 3D defect detection technologies. Traditional 2D methods, which rely on image features such as texture analysis, edge detection, and morphological processing, have achieved certain success in surface defect detection. However, they struggle with complex 3D objects and internal defects because of their reliance on 2D images. By contrast, 3D defect detection technologies leverage point clouds and depth maps to provide a more comprehensive analysis of surface and internal structures, making them more suitable for modern industrial applications. Subsequently, this paper systematically summarizes the current research status of 3D defect detection from two perspectives: traditional and deep learning. In traditional methods, 3D defect detection is mainly divided into three categories: methods based on local features in point clouds, methods based on point cloud registration, and methods based on point cloud segmentation. Methods based on local features in point clouds detect defects by extracting local features such as depth, area, and slope, combined with threshold settings. These methods exhibit robustness and computational efficiency but lack utilization of global contextual information. For example, they can effectively detect common industrial defects like dents and protrusions but may miss defects that require a global understanding of the object's structure. Methods based on point cloud registration align target point clouds with model data and identify defects by comparing differences. Their performance depends on the accuracy and efficiency of the registration algorithm. While these methods excel in utilizing global information and shape consistency, they face challenges in computational complexity and error accumulation. Methods based on point cloud segmentation detect defects by segmenting point clouds and extracting regional features. They excel in local feature extraction and fine-grained localization but may lose global information. These methods are computationally efficient in the preprocessing stage but may suffer from segmentation errors and parameter sensitivity. In deep learning methods, 3D defect detection is divided into point cloud-based methods and multimodal fusion-based methods. Point cloud-based methods automatically learn point cloud features through neural networks, making them suitable for complex surfaces. However, they involve intricate data processing and require significant computational resources. For instance, these methods can handle irregular shapes and textures but may struggle with real-time applications owing to their computational demands. Multimodal fusion-based methods combine information from multiple modalities such as RGB images and point cloud data, significantly improving detection accuracy and robustness. Specific methods include teacher-student network-based methods, memory bank-based methods, reconstruction-based methods, and methods leveraging contrastive language-image pretraining (CLIP). Teacher-student network-based methods achieve efficient feature learning through knowledge distillation or reverse distillation, offering advantages such as model lightweighting and high detection sensitivity. However, their performance heavily depends on the quality of the teacher network and the precision of feature matching. Memory bank-based methods enable rapid detection by storing multimodal features but incur high storage costs. Reconstruction-based methods analyze defect locations through reconstruction errors but exhibit low sensitivity to minor defects. These methods leverage the spatial and texture features of 3D data but require complex model training and high-quality reconstruction networks. CLIP-based methods leverage cross-modal characteristics for zero-shot detection, offering strong adaptability but requiring high computational costs. They are promising for their ability to generalize across different defect types but may need task-specific optimizations to improve performance. Moreover, this paper summarizes commonly used public datasets in the field of 3D defect detection, including the MVTec 3D Anomaly Detection (MVTec 3D-AD), Eyecandies, Real 3D-AD, Play-Doh made (PD-REAL), Anomaly ShapeNet, and Multi-pose Anomaly Detection datasets. These datasets provide various samples and annotations, enabling researchers to train, validate, and evaluate their methods effectively. This paper also introduces evaluation metrics such as the image-level area under the receiver operating characteristic curve (I-AUROC), pixel-level area under the receiver operating characteristic curve (P-AUROC), and area under the precision-recall operating curve (AUPRO), along with their definitions and calculation methods. I-AUROC measures a model's ability to distinguish between normal and defective images at the image level, while P-AUROC evaluates pixel-level defect localization. AUPRO focuses on the overlap between predicted and actual defect regions, providing a more detailed assessment of detection performance. Finally, this study analyzes the current challenges in 3D defect detection, including data quality, large-scale data processing, real-time performance, and the integration of domain knowledge with algorithms. Data quality remains a critical issue, given that noisy or incomplete

data can significantly affect detection accuracy. Large-scale data processing is another challenge, especially in industrial applications where real-time performance is essential. The integration of domain knowledge with advanced algorithms can enhance detection performance but requires interdisciplinary collaboration. This study further explores future research directions, such as cross-modal information fusion, the application of augmented reality and virtual reality technologies, and the optimization of real-time performance and efficiency. Cross-modal fusion can improve detection accuracy by combining complementary information from different data sources. Augmented reality and virtual reality technologies can enhance defect visualization and interaction, providing intuitive solutions for industrial applications. Real-time performance optimization is crucial for deploying 3D defect detection systems in production lines, where efficiency and speed are paramount. In conclusion, 3D defect detection is a critical and challenging task with broad applications in various fields. This paper provides a comprehensive review of traditional and deep learning methods in 3D defect detection, summarizes existing datasets and evaluation metrics, and discusses current challenges and future directions. By addressing these challenges and exploring new research avenues, this study aims to inspire further advancements in 3D defect detection technologies, ultimately contributing to improved product quality and manufacturing efficiency.

Key words: defect detection; computer vision; 3D vision; deep learning; multimodal; review

0 引言

随着现代制造业的快速发展,消费者和生产企业对产品质量和安全性的要求不断提高。然而,在生产过程中难免会出现各种缺陷,如凹陷、裂缝、气泡等。这些缺陷可能会直接影响到产品的性能,甚至导致产品在使用过程中出现故障或安全隐患。因此,及早发现和准确地识别缺陷对于确保产品质量、提高生产效率以及降低生产成本至关重要。这也对缺陷检测技术提出更高的要求。

传统二维缺陷检测方法仅提供物体表面信息,在探测深层或内部缺陷时效果往往不佳。此外,光照、纹理、阴影等因素也会对二维图像在复杂环境下的稳定性和鲁棒性造成不小的挑战。因此,为了克服上述限制,近年来,学者们逐渐开始研究三维缺陷检测技术。该技术利用三维数据提供更加全面准确的信息,通过捕捉物体的几何形状、空间分布和深度信息,为缺陷检测提供更多的特征和依据,进而提升检测的准确性和可靠性。然而,目前关于缺陷检测的综述大多基于二维缺陷检测(陶显等,2021;罗东亮等,2022;林思媛和吴一全,2024;Liu等,2024a;郭新茹等,2025;胡志强和吴一全,2025),尚无综述对三维缺陷检测进行系统全面的梳理,现有综述(Lin等,2025)仅在深度学习背景下对三维缺陷检测略有提及,但描述较少。因此,对该领域进行全面综合调研,总结最新研究进展和面临的挑战,将对促进三维缺陷检测技术的发展起到至关重要的作用。

作用。

本文旨在对现有的三维缺陷检测方法进行全面回顾,并深入探讨未来该领域的研究方向。通过对相关文献的分析总结,希望为研究者提供有益的参考和启发,推动三维缺陷检测领域的进一步研究和创新。

1 缺陷检测的背景

缺陷检测是指在生产制造过程中,通过各种技术和方法对产品或物体进行检测分析,以便发现和定位其中的缺陷或异常。缺陷可以是凹陷、划痕、裂缝之类的表面缺陷,也可以是气泡、空洞等内部缺陷。这些缺陷如果不及时发现和处理,可能会导致产品性能下降、寿命缩短,甚至增加安全风险。因此,缺陷检测工作不仅可以提高产品的质量和可靠性,还能为企业避免潜在的损失和安全隐患。

二维缺陷检测是最早应用于工业生产中的检测技术之一。它主要针对平面图像进行缺陷检测,通常应用于工业生产中表面缺陷的检测,例如玻璃、纺织品、金属制品等。二维缺陷检测技术主要分为基于图像特征的传统方法和基于深度学习的方法。传统方法主要利用纹理分析、边缘检测和形态学处理等技术,提取图像特征进行缺陷检测。Chetverikov和Hanbury(2002)利用规律性和各向异性两个基本结构属性来处理纹理缺陷;Mark等人(2009)使用预训练的Gabor小波网络提取织物纹理特征,并且利用这些特征构建结构元素,以便在后续的形态学处

理中去除织物背景并隔离缺陷;Song 等人(2015)使用图像块百分位颜色直方图和特征向量纹理特征进行木材表面缺陷的检测。相比之下,基于深度学习的方法则通过对丰富的标注数据进行训练学习,建立模型自动检测缺陷。Tabernik 等人(2020)设计了一种分割网络,通过像素级损失进行训练,显著提升了面料缺陷检测的效果;Hu 等人(2020)在深度卷积生成对抗网络的基础上引入了一个编码器,使得模型能够重建给定图像,仅保留正常纹理而去除缺陷。通过从重建中减去原始图像,可以得到一个残差图来突出缺陷区域;Lyu 等人(2020)使用改进的深度卷积自编码器重建原始图像的纹理背景,作为无缺陷的参考。并利用离散余弦变换分析差异,以便准确分割缺陷区域。尽管二维缺陷检测技术取得了一定成就,但由于图像本身的限制,处理复杂的三维物体和深层次缺陷仍然面临困难。

3D 缺陷检测是利用点云、深度图等三维数据进行缺陷检测。相较于 2D 缺陷检测,它可以对被测物体的表面及内部结果进行更加全面的分析,进而检测和识别缺陷。如图 1 所示,在工业制造中,该技术可用于质量控制和缺陷分析,从而提高生产效率和安全性。近年来,3D 缺陷检测方法逐渐成为研究热点,并取得了显著进展。随着深度学习和人工智能技术的发展,基于深度学习的方法有望在 3D 缺陷检测领域实现更多突破,为各领域带来性能更为优异的缺陷检测方法。




图 1 工业制造中常见三维缺陷

Fig. 1 Common 3D defects in industrial manufacturing

2 基于传统方法的 3D 缺陷检测

传统的 3D 缺陷检测算法通常依赖于点云数据,在一段时间内发挥了巨大的作用。基于传统方法的

3D 缺陷检测方法主要分为三大类:第 1 类是基于点云局部特征,利用点云数据自身的局部特征进行检测,如高度、面积、体积和曲率等;第 2 类是基于点云配准,将标准的点云模型与输入模型进行配准后检测;第 3 类是基于点云分割,通过对点云分割进行缺陷检测。

2.1 基于点云局部特征的缺陷检测

基于点云局部特征的缺陷检测方法是通过提取点云的局部细节特征,包括深度、面积和斜率等,然后针对性地设置阈值,结合一些普遍算法,可以有效地检测工业上常见的凹坑、凸起和残缺等缺陷。常见的点云局部特征包括法向量、曲率、PFH(point feature histogram)、FPPH(fast PFH)、SHOT(signature of histograms of orientations)等,具体如表 1 所示。

郭杰(2020)利用点云数据的几何特征,结合机器学习分类器,对受电弓表面进行缺陷检测。通过构建局部参考坐标系,对点云进行投影和特征提取,有效描述点云的空间分布。采用随机森林作为分类模型,提高检测的泛化能力和鲁棒性。张研(2022)利用改进的局部对比度显著性模型和自适应阈值的边缘检测算法,有效识别和提取图像中的缺陷特征。通过计算缺陷区域的深度和面积,为飞机蒙皮的磨损评估提供了量化数据。

基于点云局部特征的缺陷检测方法在鲁棒性和运算速度上表现出色,但在全局上下文信息的利用和特征完备性方面尚有提升空间,可以结合其他方法提高缺陷检测的准确性和全面性。

表 1 点云局部特征
Table 1 Point cloud local features

局部特征	优点	缺点
法向量	计算简单,易于实现	对复杂形状不准确
曲率	计算量小	对噪声敏感
PFH	鲁棒性强	计算耗时
FPPH	鲁棒性强,计算快	对非刚性物体鲁棒性差
SHOT	旋转不变性和鲁棒性	计算复杂且对尺度变化敏感

2.2 基于点云配准的缺陷检测

基于点云配准的缺陷检测方法主要是利用配准算法将目标点云与模型数据在同一坐标系下进行对齐,通过比较两者之间的差异识别出缺陷,如图 2 所

示。该方法的关键优势在于配准算法的不断改进：配准算法精度越高,运算速度也就越快,因此能够取得更好的效果。

Xiong 等人(2017)通过计算测量点云与标准铁轨点云模型之间的偏差,识别并标记出潜在的缺陷点。利用 K-means 聚类算法对缺陷点进行聚合,形成候选缺陷区域,并通过决策树分类器对这些区域进行分类,实现对铁路表面缺陷的精确定位和类型识别。曾征(2020)利用改进的迭代最近点(iterative closest point, ICP)算法进行点云数据的精确配准,确保涂胶点云与标准模型之间的对齐。通过计算点对之间的偏差,检测出涂胶缺陷(如凹胶、凸胶和断胶)。Li 等人(2021)对转子的表面缺陷进行检测,首先对采集的点云数据进行局部注册,然后与标准点云进行拼接和整体注册。在配准过程中,通过比较点云之间的不均匀性检测缺陷。

基于点云配准的缺陷检测方法可以充分利用全局信息和形状一致性,但在处理运算的复杂性及误差累积方面面临挑战。在实际应用中,需要平衡配准精度与运算效率之间的关系,根据数据特点选择恰当的配准策略。




图2 基于点云配准的缺陷检测流程
Fig. 2 Defect detection process based on point cloud registration

2.3 基于点云分割的缺陷检测

基于点云分割的缺陷检测方法是利用分割算法将点云分割成不同的区域部分,并对这些部分进行特征提取和分析,以识别其中存在的缺陷。在预处理阶段,点云分割算法简单且运算成本低,能有效提高后续算法的效果。

Shi 等人(2021)利用基于体素云连通性分割算法对点云进行过分割,并根据分割区域间的凹凸属性实现微硬度压痕的检测。李锦达(2022)采用改进的渐进式形态学和 RANSAC(random sample consensus)算法对钢板点云数据进行分割,以完整地提取出钢板缺陷点云。通过法线微分方法优化形态学滤波,结合欧氏聚类,更加准确地分割出各类钢板缺陷。

基于点云分割的缺陷检测方法具有局部特征提取和精细化定位的优势,但也存在着分割误差和参数设定上的挑战,同时可能会丢失一部分全局上下文信息。为达到更高的检测准确性和综合性,还需配合运用其他技术方法。

3 基于深度学习的3D缺陷检测

深度学习的快速发展使其在缺陷检测领域的应用越来越广泛,不仅能够处理大规模数据、自动学习特征表示,还能适应各种复杂的缺陷形态。本节简要介绍了基于深度学习的3D缺陷检测方法研究现状,分为基于点云和基于多模态融合两大类。

3.1 基于点云的缺陷检测

基于点云的缺陷检测方法是通过对神经网络模型来自动学习和提取点云数据中的特征,从而实现高效的缺陷检测,如图3所示。目前基于点云的纯三维异常检测方法较少。



图3 基于点云的缺陷检测流程
Fig. 3 Defect detection process based on point cloud

Nasrollahi 等人(2019)通过 LiDAR(light detection and ranging)扫描收集混凝土点云数据,采用 PointNet 网络(Qi 等,2017)提取点云特征,并识别潜在的缺陷区域。通过设置阈值确定混凝土表面的缺

陷位置。Bergmann 和 Sattlegger(2023)提出基于深度几何描述符的3D点云缺陷检测方法,通过自监督学习预训练一个教师网络用于提取点云的局部几何特征,然后训练一个学生网络用于匹配教师网络在无异常数据上的输出。测试时,通过计算两个网络输出之间的回归误差为每个点分配异常分数,有效定位点云中的异常结构。Cao 等人(2024)提出一种基于多模态特征的3D缺陷检测算法,通过手工制作3D点云描述符 FPFH,从点云中提取局部几何特征,并将点云投影生成多视图图像,利用2D神经网络提取全局语义特征。为解决小区域缺陷定位难题,该方法将2D与3D特征对齐聚合,借助记忆库和最近邻搜索计算异常分数,通过多模态特征的互补性增强对微小缺陷区域的敏感度。Li 等人(2024a)研究了一种自监督学习方法用于3D缺陷定位,通过迭代掩膜重建网络来实现。该网络在训练期间通过迭代掩膜和重建点云学习异常特征,测试时点云多次通过掩膜重建网络,将每次迭代的输出作为下一次输入,对比最终重建与初始点云,利用重建误差的空间分布精准锁定缺陷区域。Zhao 等人(2024)提出一种无监督点云缺陷检测框架。该方法通过整合局部坐标特征和全局 PointMAE(point masked auto-encoder)特征到单一记忆库中,为不同量级特征赋予权重,并引入排名归一化方法平衡数据分布。在此基础上,通过计算特征与记忆库的坐标距离得到异常分数,实现缺陷区域的精确定位。Liu 等人(2023)提出 Reg3D-AD(registration-based 3D anomaly detection)方法,利用坐标特征和 PointMAE 特征表示点云,分别捕捉点云的局部定位属性和整体特征,并构建双记忆库。通过比较测试对象的特征与记忆库中的特征,有效地检测和定位点云缺陷。Liu 等人(2025)提出 Uni-3DAD(universal 3D anomaly detection)方法,创新性地融合基于特征和基于重建两个检测模块。前者提取 FPFH 特征并结合 PatchCore 算法检测几何缺陷;后者生成相似样本对比检测缺失区域,最终经 OCSVM(one-class support vector machine)融合分支异常分数。这种多模块协同机制,从几何特征和结构完整性两个维度强化对小缺陷区域的定位能力,提升检测精度。Ye 等人(2024)提出一种3D点云缺陷检测框架,通过预测伪异常点云中的点偏移量,引导模型聚焦异常区域特征学习,并改进伪异常点云生成方法提升训练效率,在定位

微小缺陷时,利用偏移量的梯度变化精准划定缺陷边界。Zhou 等人(2025)提出 R3D-AD(reconstruction-based 3D anomaly detection)方法,利用扩散模型重建异常点云以实现精确的三维缺陷检测。通过 Patch-Gen 策略模拟缺陷来增强数据,采用 PointNet 提取输入点云的潜在形状嵌入,在反向扩散过程中注入该嵌入并逐步学习点位移以重建无异常形状。最终通过计算重建点云与原始点云的距离,以空间度量差异的方式实现缺陷区域的精确定位。Zhu 等人(2024)提出一种基于组级特征对比学习的高分辨率三维点云异常检测框架,通过优化特征簇在特征空间中的分布,分析几何信息来动态关注潜在异常区域,利用特征对比的显著性差异精确定位缺陷,有效解决高分辨率点云中微小缺陷难以捕捉的问题。

基于点云的缺陷检测方法充分利用了丰富的几何信息,不受光照的影响,适用于复杂表面。但此类方法数据处理复杂,需要大量计算资源和时间,尚有较大提升空间。

3.2 基于多模态的缺陷检测

基于多模态融合的缺陷检测方法是利用多种数据模态(如RGB图像、点云数据和文本等)进行缺陷检测。通过将不同模态的信息进行融合,可以提高缺陷检测的准确性和鲁棒性。根据所用方法思想的不同,分为师生网络、记忆库、重建和 CLIP(contrastive language-image pre-training)4个部分进行介绍。

3.2.1 基于师生网络架构的方法

基于师生网络架构的三维缺陷检测方法主要通过知识蒸馏或反向蒸馏进行高效缺陷识别。知识蒸馏中,学生网络通过模仿教师网络的特征表示与预测,达到精准异常检测;反向蒸馏则采用编码器—解码结构,学生解码器通过重建教师编码器的输出特征进行训练,在推理阶段比较重建特征与目标特征之间的相似性检测异常。具体的检测流程如图4所示。

Rudolph 等人(2023)提出一种非对称的师生网络,采用归一化流作为教师网络对数据进行密度估计,传统的前馈神经网络作为学生网络,这种不对称的网络结构旨在通过学生网络对教师网络输出的模仿来检测那些在训练数据中未出现的异常。深度图和RGB图像一起用于训练,测试时通过计算学生网




图4 基于师生网络的三维缺陷检测流程
Fig. 4 3D defect detection process based on teacher-student network

络和教师网络的输出距离检测缺陷。Gu 等人(2024)提出一种多模态逆向蒸馏框架,其中教师编码器利用孪生网络从 RGB 图像及其他辅助模态中提取互补的视觉信息,并通过一种无参数的融合策略,将这些信息整合为蒸馏目标。学生解码器则学习从正常样本的教师表示中提取模态相关的先验知识,并通过这些知识的交互作用,形成用于目标重建的多模态特征表示。通过计算教师和学生特征之间的像素级余弦相似度,实现缺陷区域的检测和定位。Liu 等人(2024b)提出跨模态反向蒸馏方法,该方法采用多分支设计,为每种模态分配独立的分支。通过反向蒸馏机制,使学生网络在训练过程中学习教师网络的正常特征表示能力。同时,在每个分支中引入跨模态过滤器和跨模态放大器,增强模态间的交互,并计算教师与学生特征之间的余弦距离生成异常图。最后将所有分支的异常图归一化后融合,得到最终的缺陷检测结果。Sun 等人(2024)提出一种无记忆的多模态缺陷检测方法,使用正常 RGB 图像和由点云生成的掩码,通过师生网络输出差异生成 RGB 异常得分图。同时,利用有符号距离函数从正常点云学习预测点到表面的距离,以此生成 3D 异常得分图;最后对齐得分图,融合 RGB 和 3D 异常信息用于检测缺陷。

此类方法通过知识蒸馏或反向蒸馏实现高效特征学习,具有模型轻量化、检测灵敏度高及适应性强的优势。然而,其性能依赖教师网络质量和特征匹配精度,训练过程复杂,尚有提升空间。

3.2.2 基于记忆库的方法

基于记忆库的三维缺陷检测方法通常结合了 RGB 和点云信息,利用预训练网络提取特征表示,构建存储多模态特征的记忆库。在推理阶段,通过查询记忆库中的特征,计算目标特征与记忆库特征之间的相似度,从而识别和定位缺陷。具体的检测过程如图 5 所示。

Horwitz 和 Hoshen (2023) 提出 BTF (back to the feature) 方法,通过结合经典的手工 3D 特征 (FPFH) 和基于深度学习的 RGB 特征 (PatchCore),形成联合特征表示。在测试阶段,计算测试样本的联合特征与训练样本特征的 KNN (K-nearest neighbor) 距离生成异常图,从而实现对缺陷的精准定位。Wang 等人(2023)通过混合融合方案结合 RGB 图像和 3D 点云数据实现缺陷检测。该方案使用预训练的 Transformer 模型从 RGB 图像和 3D 点云中提取特征,对齐 3D 和 2D 特征,然后用无监督特征融合模块整合多模态特征,并通过多个记忆库存储和对比 RGB、3D 和融合后的特征,最终根据对比结果进行缺陷检测和分割。曲海成和林俊杰(2025)基于 M3DM (multi-3D-memory) 方法进行了改进,将信息瓶颈机制扩展到了无监督领域,并且使用多尺度归一化流结构提取不同尺度的特征信息,实现不同尺度特征之间的交互。通过融合不同尺度的归一化流结果,得到最终的缺陷检测和定位结果。Chu 等人(2023)提出一种基于形状引导的双记忆学习框架,利用两个专家模型(形状和外观)分别提取 3D 几何信息和 RGB 特征,并构建双记忆库存储特征。测试时结合形状和颜色特征进行缺陷检测推理,通过计算特征的稀疏表示和对齐分数图生成异常分数图。Wang 等人(2024b)提出一种增量模板邻域匹配方法,该方法通过加权特征融合 RGB 图像与点云信息,并采用像素级核心集选择 (pixel-wise coreset selection, PCS) 在训练阶段压缩模板集,有效控制内存的同时保留关键特征分布。在推理阶段,ITNM 利用模板邻域匹配 (template neighborhood matching, TNM) 策略,通过计算查询特征与最相似模板特征之间的距离作为异常得分,从而定位缺陷区域。Tu 等人(2025)提出一种自监督特征适配框架 LSFA (local-to-global self-supervised feature adaptation),用于三维工业产品的缺陷检测任务。通过模态内特征紧凑性优化和跨模态局部到全局一致性对齐,实现从局部到全局的特




图5 基于记忆库的三维缺陷检测流程

Fig. 5 3D defect detection process based on memory bank

征适配。该方法通过自监督学习策略,对预训练模型进行微调,以学习面向任务的特征表示,从而提高异常检测的性能。Sui 等人(2024)提出一种跨模态蒸馏框架,利用预训练网络提取RGB图像和点云特征构建记忆库;通过跨模态蒸馏网络生成缺失模态的幻觉信息;采用贪婪算法进行核心集选择优化记忆库;最后在决策层融合阶段,利用多个记忆库和一类支持向量机计算异常分数。Wang 等人(2024a)提出一种新型三维工业缺陷检测方法,该方法分为3个阶段,首先通过对输入图像、点云和文本进行初始特征提取和可疑异常图计算,筛选出正常样本并生成可疑异常图,以集中关注缺陷区域。然后利用这些异常图作为参考,通过模态内比较和多尺度聚合操作对训练样本去噪。最后在M3DM方法的基础上引入噪声判别性核心集选择,过滤掉噪声,实现缺陷检测和分割。

此类方法通过记忆库存储多模态特征,具有检测速度快、少样本、适应性强和灵活性高的优势。但同时其存储成本较高,性能依赖特征提取质量。大规模记忆库可能导致查询效率下降,对异常分布复杂性较敏感。

3.2.3 基于重建的方法

基于重建的三维缺陷检测方法通常包括生成器、重建网络和判别器等模块。首先,通过生成器生成异常样本,利用重建网络将异常样本恢复正常;其次,计算原始数据与重建数据之间的差异,通过损失函数优化模型,使重建更准确。判别器进一步区分正常与异常样本。具体的检测过程如图6所示。

Chen 等人(2023)提出一个用于3D缺陷检测的网络EasyNet。该网络利用编码器—解码器结构从RGB图像和深度图像中提取特征,并重建出无异常的图像。分割网络通过处理重建网络提取的多尺度重建特征和增强特征,比较这些特征之间的差异定位缺陷区域。Zavrtanik 等人(2024a)提出一种新型3D表面缺陷检测方法,利用深度感知离散自编码器学习RGB和深度数据的一般离散潜在空间,将DADA(depth-aware discrete autoencoder)集成到双子空间重投影网络框架中,根据两个重投影之间的差异分割缺陷区域。Zavrtanik 等人(2024b)突破了传统依赖预训练模型的限制,转而采用异常模拟策略训练模型。通过异常模拟过程,生成与工业深度数据特性相匹配的多样化异常,从而有效训练出具有高度辨别力的缺陷检测模型。Costanzino 等人




图6 基于重建的三维缺陷检测流程
Fig. 6 3D defect detection process based on reconstruction

(2024)研究了基于跨模态映射的3D缺陷检测方法,使用预训练模型从RGB图像和3D点云中提取特征,然后训练两个轻量级多层感知机(multilayer perceptron, MLP)网络学习2D到3D和3D到2D的跨模态映射并对齐特征,通过比较实际特征与映射预测特征的差异检测缺陷。Bi等人(2024)提出DBRN(dual-branch reconstruction network)方法,该方法采用自监督方式,利用双分支重建网络分别重建RGB图像和深度图,并利用判别网络进行缺陷定位。此外,引入了重要性评分模块,用于融合RGB和深度特征,从而获得更全面的判别结果。Li等人(2025)提出一种双模态异常合成方法,首先通过特定流程生成双模态异常样本,利用两个重建子网络分别对异常的RGB和深度图像进行重建。然后引入一个基于重建的判别性异常检测网络,该网络通过双模态判别器融合原始和重建的嵌入特征,以实现准确的缺陷分割。Li等人(2024b)提出一种用于三维工业缺陷检测的方法,该方法利用基于U形的编码器—解码器网络分别重建RGB和深度图像,并通过一个三维分割网络实现精确的缺陷分割。为了增强分割性能,引入了一个轻量化的MLP模块捕捉重建图像中的长距离依赖关系。

该类方法通过深度学习的重建误差分析缺陷位置,充分利用三维信息的空间与纹理特征,有效实现对工业产品的精准缺陷检测。但其模型训练复杂,对微小缺陷的敏感性较低,且检测性能依赖重建质量,对网络结构与损失函数设计有较高要求。

3.2.4 基于CLIP的方法

CLIP是一种跨模态对比学习模型,核心思想是

联合图像和文本,通过对比损失函数,使匹配的图像—文本对在特征空间中更接近、非匹配对更远离。CLIP可以有效理解图像和文本间的语义关联,支持零样本分类、图像检索等任务,广泛应用于多模态理解与分析领域。基于CLIP的三维缺陷检测方法通过对点云进行多视图投影,生成二维图像输入CLIP模型,同时结合预定义的文本提示进行特征提取。模型通过对图像与文本特征的匹配度计算异常分数,从而定位异常区域。具体的检测过程如图7所示。

Zuo等人(2024)提出一种名为CLIP3D-AD的方法,用于三维少样本缺陷检测。该方法基于CLIP模型,通过对给定正常图像合成异常图像构建样本对,利用冻结的CLIP图像和文本编码器提取特征,并且引入图像适配器和文本适配器微调全局视觉特征和文本特征,从而适应三维缺陷分类和分割任务。此外,充分利用点云几何信息,将点云投影渲染为多视图图像,并设计了多视图融合模块融合由CLIP提取的多视图图像特征,以增强视觉表示和视觉—语言相关性。Zhou等人(2024)提出用于零样本3D缺陷检测的PointAD方法。该方法将CLIP的强大泛化能力应用于三维点云,通过其预训练的视觉编码器和文本编码器,能够将三维点云渲染出的二维图像转换为视觉表示,并与文本提示相结合,从而识别和理解三维缺陷。同时,引入了混合表示学习,通过优化可学习的文本提示来整合三维和二维的正常和异常语义。此外,PointAD可以直接整合RGB信息,以提升检测性能。Cheng等人(2024)同样针对零样本点云缺陷检测提出MVP-PCLIP方法,该方法首先利用




图7 基于CLIP的三维缺陷检测流程

Fig. 7 3D defect detection process based on CLIP

MVP(multi-view projection)框架将点云投影为多视图深度图像,转换为图像缺陷检测问题。接着CLIP通过其强大的图像和文本编码器,将投影后的深度图像与设计的文本提示相结合,计算图像特征和文本特征之间的相似性。最后通过比较图像特征与表示正常和异常状态的文本特征的相似性,识别出图像中的缺陷区域。

该类方法利用跨模态特性,结合多视图投影和文本提示实现零样本检测,适应性鲁棒性较强。然而,其性能依赖视图生成质量和文本提示设计,计算成本较高。由于CLIP是通用模型,可能需要针对三维缺陷检测任务进行针对性设计,以提升性能。

4 数据集与评价指标

4.1 3D缺陷检测数据集

为了研究有效的算法或模型,选择合适的数据集至关重要。3D缺陷检测的公开数据集较少,用到的三维数据格式通常是点云和深度图。目前已知的3D缺陷数据集主要有以下几种。

1)MVTec 3D-AD数据集。MVTec 3D-AD(Bergmann等,2022)是专门为无监督3D缺陷检测和定位开发的首个综合性数据集,已成为3D缺陷检测研究的基准数据集。该数据集使用Zivid One+ Medium 3D传感器获取数据,确保高分辨率和精确度,模拟实际工业检测环境,包含4 147个高分辨率的工业3D点云扫描,涵盖10种物体类别,如面包圈、胡萝卜、电缆等,每种类别都具有不同的表面特性和几何结构。数据样本划分为3部分,其中训练集和验证集仅包含无缺陷样本,测试集包含孔洞、划痕等缺陷。此外,数据集提供与点云对应的RGB值,使得

结合颜色信息进行缺陷检测成为可能。然而它的局限性在于它主要针对工业检测场景,可能不完全适用于所有3D视觉任务,且缺陷类型有限。尽管如此,该数据集仍然为3D缺陷检测技术的发展提供了宝贵的资源。

2)Eyecandies数据集。Eyecandies(Bonfiglioli和Sattlegger,2023)是用于无监督缺陷检测和定位的合成数据集,旨在通过提供逼真的合成图像和3D信息推动缺陷检测技术的发展。该数据集利用Blender软件生成,通过程序化渲染流程创建高度真实感图像,并自动生成精确的像素级标注,避免了人工标注的偏差,包含90 000多幅高质量的图像,涵盖10个类别的糖果。每个类别都具有独特的形状、材质和纹理。每个样本在不同光照条件下经过渲染,提供了深度图、RGB图像和法线图,支持2D和3D缺陷检测,为缺陷检测领域带来了新的挑战和机遇。由于数据集是合成生成的,可能无法完全捕捉到真实世界中的所有复杂性和变异性,且光照条件可能与实际工业环境有所不同。但它为研究人员提供了一个可控的测试环境,用于开发和评估新的异常检测方法。

3)Real 3D-AD数据集。Real 3D-AD(Liu等,2023)是一个高分辨率的3D点云数据集,用于真实世界中的缺陷检测任务。该数据集共包含1 254个样本,分布在12个不同的类别中。该数据集通过高分辨率激光扫描获取,确保了360度无死角的覆盖。同时,点云分辨率高达0.001 0~0.001 5 mm,有助于精确捕捉物体的几何细节。训练集为全视角扫描的完整原型,测试集模拟生产线单侧扫描。其点精度、空间距离分辨率较MVTec 3D-AD提升显著,能精准捕捉微米级缺陷。但数据集存在信息维度局限,缺乏RGB色彩数据,测试集单侧扫描可能致边

缘截断,且每类仅4个训练原型,对算法要求高。该数据集为3D点云异常检测提供了更贴近工业实际的基准,推动相关算法发展。

4) PD-REAL 数据集。PD-REAL (Qin 等, 2023) 是一个新颖的大规模3D缺陷检测数据集,旨在通过结合3D信息提高缺陷检测的性能。该数据集采用 Intel RealSense D405 相机采集数据,亚毫米级精度,光照条件覆盖可控。它涵盖了食品、水果、蔬菜和玩具等15个类别。每个类别都有正常样本和6种不同类型的缺陷样本。该数据集提供了RGB图像、深度图像,这些数据在不同光照条件下拍摄,以模拟现实世界的检测场景。但手工制作的 Play-Doh 缺陷与工业金属/陶瓷材质的真实缺陷存在物理特性差异,且混合光照场景下,阴影区域可能导致点云重构误差,需结合纹理信息优化。

5) Anomaly ShapeNet 数据集。Anomaly ShapeNet (Zhou 等, 2023) 是一个为3D缺陷检测任务构建的合成数据集,通过合成方法生成1 600个点云样本,包含40个不同类别,包括各种形状和结构,例如汽车、钻石、飞机等,旨在模拟工业质量检查中可能遇到的多样化场景。该数据集包含的异常类型丰富,包括凹陷、断裂、凸起、孔洞、裂纹和弯曲6种典型异常。这些异常在点云中以不同的比例和分布出现,模拟了现实世界中物体可能存在的缺陷。但合成数据可能无法完全捕捉到所有真实世界条件下的复杂缺陷,可能需要进一步扩展以覆盖更广泛的工业应用场景。

6) MAD (multi-pose anomaly detection) 数据集。MAD (Zhou 等, 2023) 是首个面向姿态无关异常检测的数据集,它同时包含模拟数据和真实数据,使用 Blender 生成模拟数据, RealSense 相机采集真实数

据。该数据集通过提供多种视角下的物体图像,模拟了实际工业环境中物体可能呈现的各种姿态。它包含20种复杂的乐高玩具模型(仅覆盖刚性物体,缺乏对非刚性材质的支持),每种模型都有超过4 000幅不同视角的高分辨率RGB图像。数据集不仅包含正常物体的多视角图像,还包含了具有各种异常(如污渍、划痕和缺失部分)的图像,通过这些异常类型反映模拟和真实世界环境中可能出现的问题,但真实样本受限于工业采集难度,对复杂缺陷的覆盖不足。此外,数据集提供了精确的像素级 ground-truth 标注,这对于评估异常检测算法的性能至关重要。

三维缺陷检测数据集图像示例见图8,数据集关键信息如表2所示。




图8 部分数据集图像示例

Fig. 8 Examples of partial dataset images
((a) Eyecandies dataset; (b) MVTec 3D-AD dataset;
(c) Real 3D-AD dataset)

表2 三维缺陷检测数据集
Table 2 3D defect detection datasets

名称	数据形式	样本数量	类别	发布时间	下载链接
MVTec 3D-AD	RGB+D	4 147	10	2021	https://www.mvtec.com/company/research/datasets/mvtec-3d-ad
Eyecandies	RGB+D+N	15 500	10	2022	https://eyecan-ai.github.io/eyecandies/download
Real 3D-AD	PC	1 254	12	2023	https://github.com/M-3LAB/Real3D-AD
PD-REAL	RGB+D	3 529	15	2023	https://github.com/Andy-cs008/PD-REAL
Anomaly ShapeNet	PC	1 931	40	2023	https://github.com/Chopper-233/Anomaly-ShapeNet
MAD	RGB	9 789	20	2023	https://github.com/EricLee0224/PAD

注:数据形式中,D代表深度图,N代表法线图,PC代表点云。

4.2 评价指标

在算法研究过程中,正确选择和应用评价指标是至关重要的。在三维缺陷检测领域中,AUROC (area under the receiver operating characteristic curve) 和 PRO (precision-recall operating curve) 是最常见且广泛采用的指标。

1)I-AUROC(image-level AUROC)是一个基于图像级别的缺陷检测性能评价指标,衡量模型在区分正常图像和缺陷图像时的能力。I-AUROC 越高,模型在区分正常和缺陷图像方面的性能越好。在纯点云的三维缺陷检测中,用 O-AUROC(即物体级别)衡量类似的性能。

2)P-AUROC(pixel-level AUROC)是一个基于像

素级别的缺陷检测性能评价指标,衡量模型在定位缺陷像素时的能力。P-AUROC 越高,模型在定位缺陷像素方面的性能越好。

3)AUPRO(area under the precision-recall operating curve)是一个基于像素级别的缺陷检测性能评价指标,衡量模型在检测缺陷区域时的能力。它特别关注模型预测的缺陷区域与真实缺陷区域的重叠情况。AUPRO 越高,模型在检测缺陷区域方面的性能越好。

由于 MVTec 3D-AD 和 Real 3D-AD 数据集是目前 3D 缺陷检测研究的两个基准数据集,具有很强的参考意义,因此本文以这两个数据集为例,分别对比了基于点云和基于多模态的三维缺陷检测方法在该数据集上的性能,对比结果如表 3 和表 4 所示。

表 3 基于点云的三维缺陷检测方法在不同数据集上的性能比较

Table 3 Comparison of performance of 3D defect detection methods based on point cloud on different datasets

方法	MVTec 3D-AD 数据集			Real 3D-AD 数据集			特点
	I-AUROC	P-AUROC	AUPRO	O-AUROC	P-AUROC	AUPRO	
3D-ST(Bergmann 和 Sattlegger, 2023)	0.833	-	0.833	-	-	-	基于学生-教师网络,利用自监督预训练的几何描述子实现检测
CPMF(Cao 等, 2024)	0.952	-	0.929	-	-	-	融合手工三维几何特征与预训练二维网络的语义特征,构建伪多模态特征
IMRNet(Li 等, 2024a)	-	-	-	0.725	-	-	通过几何感知采样、掩码重建和密集特征比较实现缺陷定位
PointCore(Zhao 等, 2024)	-	-	-	0.829	0.731	0.813	联合局部(坐标)与全局(PointMAE)特征,并引入归一化排序方法
Reg3D-AD(Liu 等, 2023)	-	-	-	0.704	0.705	0.723	采用基于配准的双特征表示方法,通过记忆库存储训练原型特征
Uni-3DAD(Liu 等, 2025)	-	-	0.93	-	-	-	融合特征检测和基于 GAN-Inversion 的重建检测,通过 OCSVM 融合结果
R3D-AD(Zhou 等, 2025)	-	-	-	0.734	0.592	-	利用扩散模型实现一步全遮罩重建,结合逐点位移和 Patch-Gen 策略
Group3AD(Zhu 等, 2024)	-	-	-	0.751	0.735	0.74	通过组级对比学习优化特征分布,结合 IUN、IAN 和 AGCS 提升检测性能

注:“-”表示无相关参考。

5 挑战与展望

尽管 3D 缺陷检测方法已经取得了显著进展,但该领域仍面临诸多挑战亟待解决,并且还有许多令人期待的发展方向值得关注。本节将重点探讨当前

面临的挑战,并展望未来的研究方向,旨在为该领域内的研究与实践提供指引。

5.1 当前挑战

1)数据质量。三维数据的质量对于缺陷检测至关重要。然而,实际采集到的数据可能受到噪声、遮挡、光照变化等因素的影响,导致数据质量不佳。这

表 4 基于多模态的三维缺陷检测方法在 MVTec 3D-AD 数据集上的性能比较
Table 4 Comparison of performance of 3D defect detection methods based on multimodel on MVTec 3D-AD dataset

方法	I-AUROC	P-AUROC	AUPRO	特点
AST(Rudolph 等, 2023)	0.937	0.976	0.944	非对称师生网络, 利用二者输出差异检测缺陷
MMRD(Gu 等, 2024)	0.950	-	0.976	多模态逆向蒸馏, 教师编码器生成蒸馏目标, 学生解码器恢复多模态表示
CRD(Liu 等, 2024b)	0.962	0.994	0.977	多分支设计独立处理各模态, 并引入跨模态助手增强模态间交互
BTF(Horwitz 和 Hoshen, 2023)	0.865	0.993	0.964	结合 3D 特征 FPFH 与 RGB 特征 PatchCore 实现缺陷检测
M3DM(Wang 等, 2023)	0.945	0.992	0.964	通过无监督特征融合和多记忆库决策融合提升检测性能
Shape-Guided(Chu 等, 2023)	0.947	0.996	0.976	融合颜色和几何信息, 通过神经隐式函数建模局部形状, 实现缺陷检测
ITNM(Wang 等, 2024b)	0.948	0.995	0.975	融合 RGB 和点云信息, 利用模板邻域匹配进行缺陷检测
LSFA(Tu 等, 2025)	0.971	0.993	0.968	通过优化模态内特征紧凑性和模态间一致性提升检测性能
CMDIAD(Sui 等, 2024)	0.938	0.992	0.962	通过多模态训练和少模态推理流程, 利用模态间的知识迁移进行缺陷检测
M3DM-NR(Wang 等, 2024a)	0.945	-	0.965	通过文本引导、跨模态对比和多尺度特征融合提升检测性能
EasyNet(Chen 等, 2023)	0.926	-	0.821	通过多模态重建和注意力信息熵融合模块, 实现缺陷检测
3DSR(Zavrtanik 等, 2024a)	0.978	0.995	0.972	通过深度感知离散自编码器和深度数据模拟, 提升检测性能
3DRÆM(Zavrtanik 等, 2024b)	0.97	0.994	0.969	通过结合重构网络和判别网络实现缺陷检测
CFM(Costanzino 等, 2024)	0.954	0.993	0.971	学习不同模态特征间的映射关系, 实现缺陷检测
DBRN(Bi 等, 2024)	0.928	0.982	-	轻量化双分支重建网络, 通过重要性评分模块融合多模态特征
DAS3D(Li 等, 2025)	0.982	0.993	0.975	通过深度驱动的异常生成和增强 dropout 机制, 提升模型性能
DRAIN(Li 等, 2024b)	0.943	-	0.892	通过轻量化 MLP 模块和双注意力融合模块融合 RGB 和深度特征
CLIP3D-AD(Zuo 等, 2024)	0.758	0.973	0.902	将点云投影为多视角图像, 结合图像和文本适配器, 实现缺陷检测
PointAD(Zhou 等, 2024)	0.869	0.972	0.902	将点云渲染为多视角 2D 图像并利用 CLIP 进行语义学习

注:“-”表示无相关参考。

会对缺陷检测的准确性和鲁棒性造成影响, 因此, 如何有效处理这些数据干扰问题并确保检测结果的可靠性, 成为当前研究和应用中需要重点解决的挑战。

2) 大规模数据与实时性。随着三维数据获取技术的发展, 处理大规模三维数据成为一项具有挑战性的任务。大规模数据的处理不仅需要高效的算法来满足实时或近实时的要求, 还面临高精度检测算法难以兼顾实时性的困境。因此如何在保证检测准确性的同时提高算法的实时性成为当前亟待解决的关键问题之一。

3) 多模态数据融合。不同模态数据(如 RGB 图像、深度信息、点云等)的特征分布和数据特性差异

较大, 难以实现有效的特征对齐与融合。现有的融合方法往往缺乏对模态间互补性和冗余性的深入挖掘, 导致融合效果不理想。因此如何设计高效稳定的融合策略仍是当前研究的难点。

4) 领域知识与算法结合。三维缺陷检测往往需要结合领域专业知识进行缺陷判定和分析。如何有效地融合领域知识与算法技术, 提高检测的准确性和鲁棒性, 是当前研究值得深入探索的重要问题。

5.2 未来研究方向

1) 跨模态信息融合。进一步研究如何有效融合来自不同传感器或不同数据模态的信息, 以提高缺陷检测的准确性和鲁棒性。具体而言, 可采用特征

对齐网络,通过空间—语义双重对齐解决视觉、红外等模态的尺度差异问题;运用分层融合策略,从数据层联合采样、特征层动态路由加权到决策层贝叶斯推理实现多模态信息深度整合;同时,通过设计跨模态对比学习任务,增强模型对跨模态语义一致性的捕捉能力。通过探索上述多模态数据的对齐和融合方法,以及利用多源信息进行联合学习和决策,有望突破单一模态的检测局限。

2)增强现实与虚拟现实技术。结合增强现实(augmented reality, AR)和虚拟现实(virtual reality, VR)技术,开发可视化和交互式的三维缺陷检测系统。在此过程中,可构建基于WebGL/Unity的轻量化三维缺陷可视化引擎,并通过SLAM(simultaneous localization and mapping)与IMU(inertial measurement unit)融合实现AR设备与检测对象的实时位姿匹配;同时集成手势识别与语音指令,开发支持三维空间操作的交互式系统,并利用光线追踪算法优化虚实融合渲染。这些系统可以提供更直观、更全面的检测结果展示,并支持用户在三维空间中进行实时分析和操作。

3)实时性与效率优化。进一步研究如何提高三维缺陷检测算法的实时性和效率。在技术实现上,可通过专用硬件设计、异构计算框架实现硬件加速;运用模型压缩、动态推理机制设计轻量化模型;并构建分布式计算架构,实现大规模检测任务的并行处理。通过探索硬件加速、分布式计算、轻量级模型设计等方法,可有效降低算法的计算成本和延迟,实现在实时场景下的高效检测。

4)三维数据增强与生成。通过生成对抗网络和扩散模型等技术,可以合成高质量的三维缺陷数据,解决真实数据稀缺的问题。具体可对生成模型进行改进,引入几何约束生成逼真缺陷数据;利用物理引擎模拟多工况下的数据,并结合对抗训练提升模型鲁棒性;同时结合元学习与数据增强构建少样本迁移学习框架。此外,数据增强技术能够提升模型的泛化能力,使其更好地适应复杂工业场景,为模型训练提供更丰富的数据集支撑。

6 结 语

3D缺陷检测是一个重要且具有挑战性的任务,在许多领域都有广泛应用。因此,对3D缺陷检测的

研究具有很强的现实意义。本文首先回顾了缺陷检测的背景,然后讨论了传统方法和深度学习方法在3D缺陷检测领域的应用。同时,将现有的3D缺陷检测数据集进行了全面整理与汇总。最后,分析了3D缺陷检测研究领域目前面临的挑战和后续展望,旨在为未来进行3D缺陷检测技术与方法的研究者提供一定的参考和启发。

参考文献

- Bergmann P, Jin X, Sattlegger D and Steger C. 2022. The MVTec 3D-AD dataset for unsupervised 3D anomaly detection and localization//Proceedings of the 17th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications. [s.l.]: VISAPP: 202-213
- Bergmann P and Sattlegger D. 2023. Anomaly detection in 3D point clouds using deep geometric descriptors//Proceedings of 2023 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE: 2612-2622 [DOI: 10.1109/wacv56688.2023.00264]
- Bi C Y, Li Y Y and Luo H C. 2024. Dual-branch reconstruction network for industrial anomaly detection with RGB-D data//Proceedings of 2024 SPIE 13180, International Conference on Image, Signal Processing, and Pattern Recognition. Guangzhou, China: SPIE: 1318033 [DOI: 10.1117/12.3033181]
- Bonfiglioli L, Toschi M, Silvestri D, Fioraio N and De Gregorio D. 2023. The eyecandies dataset for unsupervised multimodal anomaly detection and localization//Proceedings of the 16th Asian Conference on Computer Vision. Macau, China: Springer: 459-475 [DOI: 10.1007/978-3-031-26348-4_27]
- Cao Y K, Xu X H and Shen W M. 2024. Complementary pseudo multimodal feature for point cloud anomaly detection. Pattern Recognition, 156: #110761 [DOI: 10.1016/j.patcog.2024.110761]
- Chen R T, Xie G Y, Liu J Q, Wang J B, Luo Z Q, Wang J F, et al. 2023. EasyNet: an easy network for 3D industrial anomaly detection//Proceedings of the 31st ACM International Conference on Multimedia. Ottawa, Canada: ACM: 7038-7046 [DOI: 10.1145/3581783.3611876]
- Cheng Y Q, Cao Y K, Xie G Y, Lu Z C and Shen W M. 2024. Towards zero-shot point cloud anomaly detection: a multi-view projection framework [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2409.13162.pdf>
- Chetverikov D and Hanbury A. 2002. Finding defects in texture using regularity and local orientation. Pattern Recognition, 35 (10): 2165-2180 [DOI: 10.1016/S0031-3203(01)00188-1]
- Chu Y M, Liu C, Hsieh T I, Chen H T and Liu T L. 2023. Shape-guided dual-memory learning for 3D anomaly detection//Proceed-

- ings of the 40th International Conference on Machine Learning. Honolulu, USA; JMLR: #245
- Costanzino A, Ramirez P Z, Lisanti G and Di Stefano L. 2024. Multi-modal industrial anomaly detection by crossmodal feature mapping//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 17234-17243 [DOI: 10.1109/CVPR52733.2024.01631]
- Gu Z H, Zhang J N, Liu L, Chen X, Peng J L, Gan Z Y, et al. 2024. Rethinking reverse distillation for multi-modal anomaly detection//Proceedings of 2024 AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 8445-8453 [DOI: 10.1609/aaai.v38i8.28687]
- Guo J. 2020. Detection Method of Pantograph Defects Based on Point Cloud Features. Chengdu: Southwest Jiaotong University (郭杰. 2020. 基于点云局部特征的受电弓缺陷检测方法研究. 成都: 西南交通大学) [DOI: 10.27414/d.cnki.gxnju.2020.001801]
- Guo X R, Song L J, Zhu W Q, Du F and Ma Z R. 2025. Review of low-shot industrial image anomaly detection. Computer Engineering and Applications, 61(13): 26-45 (郭新茹, 宋丽娟, 朱文倩, 杜方, 马子睿. 2025. 面向低样本的工业图像异常检测综述. 计算机工程与应用, 61(13): 26-45) [DOI: 10.3778/j.issn.1002-8331.2408-0230]
- Horwitz E and Hoshen Y. 2023. Back to the feature: classical 3D features are (almost) all you need for 3d anomaly detection//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 2968-2977 [DOI: 10.1109/cvprw59228.2023.00298]
- Hu G H, Huang J F, Wang Q H, Li J R, Xu Z J and Huang X B. 2020. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network. Textile Research Journal, 90(3/4): 247-270 [DOI: 10.1177/0040517519862880]
- Hu Z Q and Wu Y Q. 2025. Survey of semiconductor wafer defect detection method based on machine vision. Journal of Image and Graphics, 30(1): 25-50 (胡志强, 吴一全. 2025. 基于机器视觉的半导体晶圆缺陷检测方法综述. 中国图象图形学报, 30(1): 25-50) [DOI: 10.11834/jig.240053]
- Li J D. 2022. 3D Defect Detection of Steel Plate Surface Based on Point Cloud Data. Wuhan: Wuhan University of Science and Technology (李锦达. 2022. 基于点云数据的钢板表面三维缺陷检测. 武汉: 武汉科技大学) [DOI: 10.27380/d.cnki.gwkju.2022.000387]
- Li K C, Dai B Q, Fu J J and Hou X W. 2025. DAS3D: dual-modality anomaly synthesis for 3D anomaly detection//Proceedings of 2025 International Conference on Computer Vision. Milan, Italy: Springer: 148-165 [DOI: 10.1007/978-3-031-92805-5_10]
- Li W Q, Xu X H, Gu Y, Zheng B Z, Gaol S and Wu Y N. 2024a. Towards scalable 3D anomaly detection and localization: a benchmark via 3D anomaly synthesis and a self-supervised learning network//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 22207-22216 [DOI: 10.1109/CVPR52733.2024.02096]
- Li Z, Ge Y F, Wang X and Meng L. 2024b. 3D industrial anomaly detection via dual reconstruction network. Applied Intelligence, 54(20): 9956-9970 [DOI: 10.1007/s10489-024-05700-x]
- Li Z X, Fang X, Shao X L and Chai Y. 2021. Rotor surface defect and symmetry detection based on point cloud registration//Proceedings of 2021 International Conference on Power Electronics, Computer Applications. Shenyang, China: IEEE: 115-118 [DOI: 10.1109/ICPECA51329.2021.9362590]
- Lin S Y and Wu Y Q. 2024. Vision-based LCD/OLED defect detection methods: a critical summary. Journal of Image and Graphics, 29(5): 1321-1345 (林思媛, 吴一全. 2024. 基于视觉的液晶屏/OLED屏缺陷检测方法综述. 中国图象图形学报, 29(5): 1321-1345) [DOI: 10.11834/jig.230518]
- Lin Y X, Chang Y, Tong X, Yu J W, Liotta A, Huang G F, et al. 2025. A survey on RGB, 3D, and multimodal approaches for unsupervised industrial image anomaly detection. Information Fusion, 121: #103139 [DOI: 10.1016/j.inffus.2025.103139]
- Liu J Q, Xie G Y, Chen R T, Li X P, Wang J B, Liu Y, et al. 2023. Real3D-AD: a dataset of point cloud anomaly detection//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: ACM: #1324
- Liu J Q, Xie G Y, Wang J B, Li S N, Wang C J, Zheng F, et al. 2024a. Deep industrial image anomaly detection: a survey. Machine Intelligence Research, 21(1): 104-135 [DOI: 10.1007/s11633-023-1459-z]
- Liu J Y, Mou S C, Gaw N and Wang Y N. 2025. Uni-3DAD: GAN-inversion aided universal 3D anomaly detection on model-free products. Expert Systems with Applications, 272: #126665 [DOI: 10.1016/j.eswa.2025.126665]
- Liu X Y, Wang J Y, Leng B and Zhang S. 2024b. Multimodal industrial anomaly detection by crossmodal reverse distillation [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2412.08949.pdf>
- Luo D L, Cai Y X, Yang Z H, Zhang Z Y, Zhou Y and Bai X. 2022. Survey on industrial defect detection with deep learning. SCIENTIA SINICA Informationis, 52(6): 1002-1039 (罗东亮, 蔡雨萱, 杨子豪, 章哲彦, 周瑜, 白翔. 2022. 工业缺陷检测深度学习方法综述. 中国科学: 信息科学), 52(6): 1002-1039 [DOI: 10.1360/SSI-2021-0336]
- Lyu C K, Zhang Z T, Shen F, Zhang F and Su H. 2020. A fast surface defect detection method based on background reconstruction. International Journal of Precision Engineering and Manufacturing, 21(3): 363-375 [DOI: 10.1007/s12541-019-00262-2]
- Mak K L, Peng P and Yiu K F C. 2009. Fabric defect detection using morphological filters. Image and Vision Computing, 27(10): 1585-1592 [DOI: 10.1016/j.imavis.2009.03.007]
- Nasrollahi M, Bolourian N and Hammad A. 2019. Concrete surface defect detection using deep neural network based on lidar scanning//Proceedings of 2019 CSCE Annual Conference. Laval,

- Greater Montreal, QC, Canada: Springer: 12-15
- Qi Charles R, Hao S, Mo K and Guibas L J. 2017. PointNet: deep learning on point sets for 3D classification and segmentation//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 77-85 [DOI: 10.1109/CVPR.2017.16]
- Qin J J, Gu C Z, Yu J and Zhang C. 2023. Image-pointcloud fusion based anomaly detection using PD-REAL dataset [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2311.04095.pdf>
- Qu H C and Lin J J. 2025. Multimodal multiscale industrial anomaly detection via flows. *Journal of Image and Graphics*, 30(2): 451-466 (曲海成, 林俊杰. 2025. 基于归一化流的多模态多尺度工业场景缺陷检测. *中国图象图形学报*, 30(2): 451-466) [DOI: 10.11834/jig.240183]
- Rudolph M, Wehrbein T, Rosenhahn B and Wandt B. 2023. Asymmetric student-teacher networks for industrial anomaly detection//Proceedings of 2023 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE: 2591-2601 [DOI: 10.1109/WACV56688.2023.00262]
- Shi W, Shi C Y, Chen S L and Zhang K L. 2021. A microhardness indentation point cloud segmentation method based on voxel cloud connectivity segmentation. *Measurement: Sensors*, 18: #100124 [DOI: 10.1016/j.measen.2021.100124]
- Song W W, Chen T Y, Gu Z H, Gai W, Huang W K and Wang B. 2015. Wood materials defects detection using image block percentile color histogram and eigenvector texture feature//Proceedings of the 1st International Conference on Information Sciences, Machinery, Materials and Energy. Chongqing, China: Atlantis Press: 779-783 [DOI: 10.2991/icismme-15.2015.163]
- Sui W B, Lichau D, Lefèvre J and Phelippeau H. 2024. Cross-modal distillation in industrial anomaly detection: exploring efficient multi-modal IAD [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2405.13571.pdf>
- Sun Z B, Li X L, Li Y R and Ma Y. 2024. Memoryless multimodal anomaly detection via student-teacher network and signed distance learning. *Electronics*, 13(19): #3914 [DOI: 10.3390/electronics13193914]
- Tabernik D, Šela S, Skvarč J and Skočaj D. 2020. Segmentation-based deep-learning approach for surface-defect detection. *Journal of Intelligent Manufacturing*, 31(3): 759-776 [DOI: 10.1007/s10845-019-01476-x]
- Tao X, Hou W and Xu D. 2021. A survey of surface defect detection methods based on deep learning. *Acta Automatica Sinica*, 47(5): 1017-1034 (陶显, 侯伟, 徐德. 2021. 基于深度学习的表面缺陷检测方法综述. *自动化学报*, 47(5): 1017-1034) [DOI: 10.16383/j.aas.c190811]
- Tu Y P, Zhang B S, Liu L, Li Y X, Zhang J N, Wang Y B, et al. 2025. Self-supervised feature adaptation for 3D industrial anomaly detection//Proceedings of the 18th European Conference on Computer Vision. Milan, Italy: Springer: 75-91 [DOI: 10.1007/978-3-031-72627-9_5]
- Wang C J, Zhu H K, Peng J L, Wang Y, Yi R, Wu Y S, et al. 2024a. M3DM-NR: RGB-3D noisy-resistant industrial anomaly detection via multimodal denoising [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2406.02263.pdf>
- Wang J X, Wang X, Hao R Y, Yin H N, Huang B Q, Xu X, et al. 2024b. Incremental template neighborhood matching for 3D anomaly detection. *Neurocomputing*, 581: #127483 [DOI: 10.1016/j.neucom.2024.127483]
- Wang Y, Peng J L, Zhang J N, Yi R, Wang Y B and Wang C J. 2023. Multimodal industrial anomaly detection via hybrid fusion//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 8032-8041 [DOI: 10.1109/CVPR52729.2023.00776]
- Xiong Z M, Li Q Q, Mao Q Z and Zou Q. 2017. A 3D laser profiling system for rail surface defect detection. *Sensors*, 17(8): #1791 [DOI: 10.3390/s17081791]
- Ye J N, Zhao W G, Yang X, Cheng G L and Huang K Z. 2024. PO3AD: predicting point offsets toward better 3D point cloud anomaly detection//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 1353-1362 [DOI: 10.1109/CVPR52734.2025.00134]
- Zavrtanik V, Kristan M and Skočaj D. 2024a. Cheating depth: enhancing 3D surface anomaly detection via depth simulation//Proceedings of 2024 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE: 2153-2161 [DOI: 10.1109/WACV57701.2024.00216]
- Zavrtanik V, Kristan M and Skočaj D. 2024b. Keep DRÆMing: discriminative 3D anomaly detection through anomaly simulation. *Pattern Recognition Letters*, 181: 113-119 [DOI: 10.1016/j.patrec.2024.03.018]
- Zeng Z. 2020. Research on Detection Method of Quality Defect of Glue Based on 3D Vision. Changsha: Hunan University (曾征. 2020. 基于三维视觉的涂胶质量缺陷检测方法研究. 长沙: 湖南大学) [DOI: 10.27135/d.cnki.gghudu.2020.003062]
- Zhang Y. 2022. Detection and Characterization of Surface Defects of Aircraft Skin Based on 3D Point Cloud. Xi'an: Xi'an Technological University (张研. 2022. 基于三维点云的飞机蒙皮表面缺陷检测与表征. 西安: 西安工业大学) [DOI: 10.27391/d.cnki.gxagu.2022.000137]
- Zhao B Z, Xiong Q W, Zhang X H, Guo J F, Liu Q, Xing X F, et al. 2024. PointCore: efficient unsupervised point cloud anomaly detector using local-global features. [EB/OL]. [2025-06-19]. <https://arxiv.org/pdf/2403.01804.pdf>
- Zhou Q, Li W Z, Jiang L H, Wang G L, Zhou G Y, Zhang S H, et al. 2023. PAD: a dataset and benchmark for pose-agnostic anomaly detection//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: ACM:

#1930

Zhou Q H, Yan J T, He S B, Meng W C and Chen J M. 2024. PointAD: comprehending 3D anomalies from points and pixels for zero-shot 3D anomaly detection//Proceedings of the 38th International Conference on Neural Information Processing Systems. Vancouver, Canada: ACM: #2695

Zhou Z Y, Wang L, Fang N Y, Wang Z L, Qiu L M and Zhang S Y. 2025. R3D-AD: reconstruction via diffusion for 3D anomaly detection//Proceedings of the 18th European Conference on Computer Vision. Milan, Italy: Springer: 91-107 [DOI: 10.1007/978-3-031-72764-1_6]

Zhu H Z, Xie G Y, Hou C B, Dai T, Gao C, Wang J B, et al. 2024. Towards high-resolution 3D anomaly detection via group-level feature contrastive learning//Proceedings of the 32nd ACM International Conference on Multimedia. Melbourne, Australia: ACM: 4680-4689 [DOI: 10.1145/3664647.3680919]

Zuo Z, Dong J H, Wu Y, Qu Y Y and Wu Z Z. 2024. CLIP3D-AD: extending CLIP for 3D few-shot anomaly detection with multi-view images generation [EB/OL]. [2025-06-19].
<https://arxiv.org/pdf/2406.18941.pdf>

作者简介

王从容,女,硕士研究生,主要研究方向为工业品三维缺陷检测技术。E-mail: 1343698712@qq.com

陈亚军,通信作者,男,教授,博士生导师,主要研究方向为图像处理与机器视觉、人工智能与模式识别、智能视觉检测与智能装备技术。E-mail: chenyj@xaut.deu.cn

刘善慧,男,副教授,主要研究方向为智能印刷装备关键技术。E-mail: shanhuiliu@xaut.edu.cn

陈冬乐,女,硕士研究生,主要研究方向为图像处理与模式识别。E-mail: 2103465193@qq.com