

中图法分类号: TP18 文献标识码: A 文章编号: 1006-8961(2025)06-1661-29

论文引用格式: Ye B H, Kang D Q, Xie X H and Lai J H. 2025. Review of vision-based surface defect inspection methods with incomplete annotations. *Journal of Image and Graphics*, 30(6):1661-1689(叶标华, 康丹青, 谢晓华, 赖剑煌. 2025. 基于视觉的非完全标注表面缺陷检测综述. *中国图象图形学报*, 30(6):1661-1689)[DOI:10.11834/jig.240434]

基于视觉的非完全标注表面缺陷检测综述

叶标华¹, 康丹青¹, 谢晓华^{1,2,3}, 赖剑煌^{1,2,3*}

1. 中山大学计算机学院, 广州 510006; 2. 琶洲实验室(黄埔), 广州 510555; 3. 广东省信息安全技术重点实验室, 广州 510006

摘要: 在现代制造业中, 基于机器视觉的表面缺陷检测是保证产品质量的关键, 在工业智能化发展中发挥着重要作用。然而, 获取缺陷数据的标注需要花费大量人力和时间成本。随着深度学习、大数据和传感器等技术的发展, 如何在非完全标注的情况下实现准确、快速和鲁棒的缺陷识别成为当前的研究热点。鉴于此, 对非完全标注场景下的表面缺陷检测技术的研究进展进行全面的梳理回顾。首先简要介绍缺陷检测领域的研究背景、基础概念的定义、常用数据集和相关技术。在此基础上, 从标签策略以及任务策略两个角度介绍多种非完全标注场景下的缺陷检测技术。在标签策略中, 比较了基于无监督、半监督和弱监督学习下的不同缺陷检测算法的研究思路。在任务策略中, 总结了领域自适应、小样本以及大模型的表面缺陷检测算法的最新进展。接着, 在多个数据集上横向对比不同标签策略以及任务策略中前沿算法的性能。最后, 对该任务中的弱小目标检测、伪标签质量评估以及大模型的知识迁移等问题进行总结和展望。总体而言, 非完全标注的表面缺陷检测是一个充满挑战且技术性极强的问题。同时, 如何进一步推动表面缺陷检测技术进一步利用非完全标注的数据, 并切实在工业制造场景中落地应用还需要更深入的研究。

关键词: 表面缺陷检测; 非完全标注; 无监督学习; 弱监督学习; 半监督学习; 域适应; 小样本

Review of vision-based surface defect inspection methods with incomplete annotations

Ye Biaohua¹, Kang Danqing¹, Xie Xiaohua^{1,2,3}, Lai Jianhuang^{1,2,3*}

1. School of Computer Science and Engineering, Sun Yat-sen University, Guangzhou 510006, China; 2. Pazhou Laboratory (HuangPu), Guangzhou 510555, China; 3. Guangdong Provincial Key Laboratory of Information Security Technology, Guangzhou 510006, China

Abstract: Surface defect inspection is a key aspect of industrial automation, primarily focused on detecting and evaluating defects or anomalies in products or materials. This technology mainly aims to ensure product quality, reduce production costs, and improve production efficiency by obtaining relevant information, such as the coordinates, categories, sizes, and contours of defects. In industrial settings, defects are generally seen as missing parts, flaws, damages, errors, or anomalies compared to normal samples. Defect information annotation can be categorized based on the level of annotation granularity in the dataset: image-level annotation, instance-level annotation, and pixel-level annotation, which correspond to classification, detection, and segmentation tasks in computer vision. In recent years, with the rapid advancements in machine vision, big data, and sensor technologies, the automation of surface defect inspection has become feasible, shifting the traditional reliance on human labor. The use of machine vision systems to replace manual inspections for surface

收稿日期: 2024-07-27; 修回日期: 2024-10-01; 预印本日期: 2024-10-08

* 通信作者: 赖剑煌 stsljh@mail.sysu.edu.cn

基金项目: 国家自然科学基金项目(62076258); 广东省特支人才项目(2021JC06X667); 广州市重点领域研发计划(2023B01J0029)

Supported by: National Natural Science Foundation of China (62076258); Guangdong Special Support Program (2021JC06X667); Key Areas Research and Development Program of Guangzhou (2023B01J0029)

defects in industrial products has rapidly gained popularity and become the norm. However, in industrial settings, the detailed annotation of defect data is time-consuming and labor-intensive; thus, a large amount of unannotated historical data often exists in these settings. The challenge of surface defect inspection with incomplete annotations focuses on how to effectively utilize this rich unannotated data or leverage a small amount of annotated data to improve inspection accuracy. Automated visual inspection systems play a crucial role in modern industrial manufacturing, gradually replacing manual quality control processes and supporting the development of smart manufacturing systems. While researchers have explored various deep learning-based surface defect inspection technologies, comprehensive reviews specifically addressing methods for handling incomplete annotations in the field of industrial product surface defect detection are still lacking. This paper aims to fill the gap by systematically reviewing the research background, foundational concepts, commonly used datasets, and related technologies in the field of surface defect inspection with incomplete annotations. Additionally, based on specific industrial contexts, commonly used datasets in fields such as metal surfaces, fabrics, building materials, and 3C electronic products have been collected and organized. The paper meticulously categorizes various surface defect inspection techniques by examining them from two key perspectives: label strategies and task strategies, highlighting the characteristics, advantages, and disadvantages of each method. Based on the types of available labels, methods for surface defect inspection with incomplete annotations are classified into three main categories: unsupervised learning, semi-supervised learning, and weakly supervised learning. Unsupervised learning methods mainly include strategies such as clustering, positive sample modeling, and template matching. Semi-supervised learning methods primarily include techniques such as image reconstruction, pseudo-label generation, and data augmentation. Weakly supervised learning methods mainly involve the use of class activation maps and similar techniques. Based on different task strategies, surface defect inspection tasks with incomplete annotations can be categorized into domain adaptation-based methods, few-shot learning-based methods, and large model-based methods. Domain adaptation methods primarily include approaches such as distribution alignment, learning domain-invariant features, and dynamically adjusting hyperparameters. Few-shot learning methods primarily include techniques such as meta-learning, metric learning, and graph neural networks. Large model-based methods mainly involve the use of large models such as segment anything model (SAM), contrastive language-image pre-training model (CLIP), large language model (LLM), and vision-language model (VLM). Subsequently, this paper compares the performance of cutting-edge unsupervised, semi-supervised, and weakly supervised algorithms across multiple datasets. Finally, the paper discusses and predicts future research trends in surface defect inspection with incomplete annotations, including the detection of small, weak targets, efficient utilization of unannotated defect images, and the application of language models and vision-language models in defect inspection. Surface defect inspection tasks with incomplete annotations are commonly encountered in industry, holding substantial research and application value, and deserve increased attention and promotion from the industrial and academic communities.

Key words: surface defect inspection; incomplete annotations; unsupervised learning; weak-supervised learning; semi-supervised learning; domain adaptation; few-shot

0 引言

在工业生产过程中,工艺技术、生产环境等因素的不足和限制极易影响制成品的质量,其中表面缺陷是产品质量受到影响的最直观表现。因此,为了保证产品质量和合格率,必须进行产品表面缺陷的检测(de Vitis等,2020;Rasheed等,2020)。人工手动检测曾经是主流的缺陷检测方法,但检测结果容易受人为主观因素影响,效率低下不能满足实时检测的要求,已逐渐为其他方法所取代。近年来,随着机器视觉、大数据和传感器等技术的迅速发展,机器

换人成为可能。使用机器视觉技术取代人工进行工业产品的表面缺陷检测已日益成为趋势和主流。

基于机器视觉的表面缺陷检测系统,也简称为自动视觉检查(automatic visual inspection, AVI)系统,其设计的主要目的就是完全替代和模拟人工的检测过程(卢荣胜等,2018)。一般来说,AVI主要由以下几个过程组成:图像采集、缺陷检测和质量控制。图像采集过程的目的是获得包含缺陷特征的待检查产品的表面图像,这就要求必须根据产品的表面属性和缺陷的特点,构筑合适的光照和成像系统,并依托机器传动、光源和相机等组件的相互配合来完成最终的取像。缺陷检测过程是指使用图像处理

技术进行缺陷的精准检测和识别,包含图像预处理、特征提取和分类等。

AVI系统是工业生产制造过程代替人工进行质检的重要一步,是实现智能制造的关键技术之一。目前,已有学者开展了基于深度学习的表面缺陷检测技术的相关研究,涉及最新的方法、应用和挑战等诸多方面。张辉等人(2022)对铸件铸造过程以及服役过程中各类缺陷的形成机理进行分析,然后阐述了基于声学、光学和磁学等主流检测技术及其常规信号处理方法。汤勃等人(2017)分析了典型机器视觉表面缺陷检测系统的工作原理和基本结构,阐述了表面缺陷视觉检测的研究现状、现有视觉软件和硬件平台,综述了相关理论和算法研究。Yang等人(2020)首先展示了缺陷领域的不同应用场景,介绍和比较了用于缺陷检测的主流技术,然后分析了超声波检测和深度学习方法在缺陷检测中的应用。李少波等人(2020)对缺陷检测技术的研究现状、典型方法和应用进行梳理,梳理了缺陷检测技术在电子元器件、管道、焊接件、机械零件和质量控制中的典型应用。陶显等人(2021)介绍了各种基于深度学习的表面异常检测技术的进展,并就检测过程中可能遇到的关键问题进行了讨论。Liu等人(2024)系统地描述了自动视觉检测系统在表面缺陷检测任务上的几个步骤和相关方法。

本文发现在工业产品表面缺陷检测领域,目前非完全标注的表面缺陷检测方法的文献综述还很少。Simmler等人(2021)总结了工业产品表面缺陷检测中无监督、弱监督和半监督方法。然而,他们仅从标注的角度分析表面缺陷检测的解决方案,总体而言还不够系统和全面。因此,为了解决上述问题,本文围绕非完全标注场景下的表面缺陷检测技术,系统总结了缺陷检测领域的研究背景、基础概念的定义、常用数据集和相关技术。本文从标签策略以及任务策略两个角度细致梳理了多种非完全标注场景下的缺陷检测技术,并指出了各类深度学习方法的特点和优缺点。接着,本文在多个数据集上对比了前沿算法的性能,并对未来的研究趋势进行讨论和展望。

1 缺陷检测问题及技术概览

表面缺陷检测是一种工业自动化技术,主要用

于识别和评估产品或材料中的缺陷和异常。其目的是确保产品质量,减少生产成本,并提高生产效率,获得缺陷的坐标、类别、尺寸和轮廓等相关信息(Jain等,2022)。在工业场景中,缺陷一般可以理解为与正常样品相比存在的缺失、缺陷、损伤、错误和异常等。不同产品以及同产品不同产线的缺陷种类和分布都可能存在差异,所以需要根据具体场景方可定义缺陷。不同任务所关注的缺陷粒度是不同的。

根据数据集的标注粒度不同,本文可以将缺陷信息的标注方式分为3类:图像级标注、实例级标注和像素级标注,分别对应着计算机视觉的3种任务:分类、检测以及分割。图1以磁瓦缺陷检测数据集(Magnetic-tile数据集)的图像为例说明不同的标注方式。图像级标注是粗粒度的标注,只需标注当前图像存在缺陷的类别即可。实例级标注更为细致,提供更加具体的缺陷信息。在给出缺陷类别的基础上,利用矩形框或多边形等方式来标注缺陷在图像中的位置。像素级标注则是粒度最细的标注方式。通过掩码的方式说明每个像素是否属于缺陷以及缺陷的类别。与实例级标注相比,像素级标注的成本更高,但能更精准地区分缺陷和样本背景。




图1 缺陷的不同标注方式

Fig. 1 Different types of defect labels

在工业场景中,对缺陷数据都进行精细的标注有很大的时间和成本压力。同时,工业场景有着丰富的历史未标注数据。非完全监督的表面缺陷检测问题研究的是如何利用丰富的未标注数据,或者借助少量的标注来提高表面缺陷检测效果。非完全标注场景下的标签缺陷检测任务按照标签类型和任务策略的不同可以划分为不同子任务,如图2所示,但是本质都是在围绕如何针对上述两种变动提高模型对检测缺陷的效果。

根据标签类型的不同,非完全标注的缺陷检测任务可以分为基于无监督学习、半监督学习以及弱

监督学习的方法。基于无监督学习的方法主要包括聚类(Volkau等,2019;Sresakoolchai和Kaewunruen,2022)、正样本建模(Szarski和Chauhan,2022)和模板匹配(Fridman等,2021)等策略。基于半监督学习的方法主要包括图像重构(Zhou等,2021;Zhang等,2019a;Ai等,2020)、伪标签生成(Liu和Ye,2022;Manivannan,2024)以及数据增广(Zhang等,2019b;Lee和Kim,2020)等方法。基于弱监督学习的方法主要包括利用类激活图(König等,2022;Huang等,2023;He等,2024)、迭代优化(Qi等,2023)等方法。

根据任务策略的不同,非完全标注的缺陷检测任务可以分为基于域适应、基于少样本以及基于大模型的缺陷检测方法。基于域适应的方法主要包括分布对齐(Song等,2021;Zhang等,2024b;Yan等,2024)、学习域不变特征(Wang等,2022c;Duan等,

2023)以及动态调整超参(Zhang等,2022;Shi等,2023a)等方式。基于少样本的方法主要包括元学习(Cheng等,2021;Yu等,2022;Lee等,2023)、度量学习(Yu等,2022;Min等,2023)以及图神经网络(Bao等,2021;Deng和Song,2023)的方法。基于大模型的方法主要包括借助“分割一切模型”(segment anything model, SAM)、“对比图形语言预训练模型”(contrastive language-image pretraining, CLIP)模型(Jeong等,2023;Zhou等,2024)或者大语言模型(large language model, LLM)、视觉—语言模型(vision language model, VLM)等大模型(Laurençon等,2024;Wang等,2024a)等方法。从标签类型和任务策略两个角度出发,本文对非完全标注的表面缺陷检测进行了详细的分析和总结。接下来,本文介绍缺陷检测领域的常用数据集。




图2 非完全标注的表面缺陷检测技术总结

Fig 2 Technology summary of surface defect inspection with incomplete annotations

2 缺陷检测相关数据集

数据集是研究工作的基础,一个好的数据集是衡量算法优劣的基准,更有利于发现、总结和解决问题。下面从金属、布匹、建筑材料、3C(computers/communications/consumer electronics)产品以及其他

数据集的角度介绍缺陷检测相关数据集。目前,工业产品表面缺陷检测领域尚无一个统一的大规模数据集,对于特定的研究对象和研究场景,也经常需要使用不同的数据集。根据任务和应用场景的不同,表1对工业领域常用的数据集进行简单分类,包括热轧带钢、铁轨、电子换向器、太阳能电池板、印刷电路板、磁瓦、布匹等工业领域。表1

详细列举了数据集的应用任务、名字、应用场景和下载方式,希望能够促进 AVI 社区或深度学习社区在解决传统 AVI 问题方面进一步创新和应用。

2.1 缺陷检测数据集

缺陷检测数据集包含缺陷的数据和正常的数据,分为训练集和测试集,部分数据集带有验证集。视觉任务包含分类、检测和语义分割。

2.1.1 金属

金属制造是常见的工业制造场景,也开源了很

多缺陷检测的数据集。

Song 和 Yan(2013)提出一个热轧带钢数据集,称为东北大学数据集(Northeastern University, NEU),数据集涉及轧制氧化皮(rolled-in-scale)、斑块(patchs)、开裂(crazing)、点蚀表面(pitted-surface)、内含物(inclusion)和划痕(scratch)6种热轧带钢上观察到的缺陷,每个类型均包含 300 个样本,所有样本分辨率均为 200 × 200 像素,并提供边界框标注。标注方式为较精确的掩膜(像素级标注)。此外,NEU 数据集有一个检测版本,称为 NEU-DET(North-

表 1 缺陷检测数据集概览
Table 1 Abstract of the defect inspection datasets

领域	数据集	任务	超链接
热轧带钢	NEU	分类	http://faculty.neu.edu.cn/yunhyan/NEU_surface_defect_database.html
铁轨	RSDDs	分割	http://icn.bjtu.edu.cn/Visint/resources/RSDDs.aspx
带钢	Steel Plates Faults	分类	https://archive.ics.uci.edu/mL/datasets/Steel+Plates+Faults
带钢	Severstal steel	分割	https://www.kaggle.com/c/severstal-steel-defect-detection/data
金属	Industrial metallic	检测	https://www.kaggle.com/ujik132016/industrial-metallic-surface-dataset
金属	GC10-Det	检测	https://www.kaggle.com/alex000kim/gc10det
铝型材	天池铝材数据集	检测	https://tianchi.aliyun.com/competition/entrance/231682/information
布匹	DAGM 2007	检测	https://hci.iwr.uni-heidelberg.de/node/3616
布匹	AITEX	分割	https://www.aitex.es/afid/
布匹	TILDA	分割	https://lmb.informatik.uni-freiburg.de/resources/datasets/tilda.en.html
布匹	布匹缺陷数据集	检测	https://www.kaggle.com/rmshashi/fabric-defect-dataset
布匹	布匹污渍数据集	检测	https://www.kaggle.com/priemshpathirana/fabric-stain-dataset
布匹	天池布匹缺陷数据集	检测	https://tianchi.aliyun.com/competition/entrance/231666/information
裂缝	人行道表面裂缝	分割	https://www.kaggle.com/arunrk7/surface-crack-detection
裂缝	CrackForest	分割	https://github.com/cuilimeng/CrackForest-dataset
裂缝	道路裂缝数据集	检测	https://github.com/sekilab/RoadDamageDetector
裂缝	桥梁裂缝数据集	分类	https://github.com/Iskysir/Bridge_Crack_Image_Data
磁瓦	Magnetic-tile	分割	https://www.kaggle.com/alex000kim/magnetic-tile-surface-defects
印刷电路板	DeepPCB	分割	https://github.com/tangsanli5201/DeepPCB
印刷电路板	PCB	检测	https://robotics.pkusz.edu.cn/resources/dataset/
光伏	Elpv	分类	https://github.com/zae-bayern/elpv-dataset
塑料	KolektorSSD	分割	https://www.vicos.si/resources/kolektorsdd/
绝缘子	CPLID	检测	https://github.com/InsulatorData/InsulatorDataSet
扫描隧道显微镜	NanoTWICE	分割	http://www.mi.imati.cnr.it/ettore/NanoTWICE/
铸造件 X 光片	GDXray Casting	检测	https://domingomery.ing.puc.cl/material/gdxray/

easter University detection dataset)(He等, 2020),标注了每个图像中缺陷的位置。在近期工作中, Song等人(2020)针对钢带表面杂质、斑块、划伤3类缺陷建立了数据集SD-saliency-900。该数据集与NEU数据集类似, 图像分辨率为 200×200 像素, 每类缺陷包含300个样本, 共计900个样本, 提供缺陷的像素分割标注。

Gan等人(2017)发布了铁轨表面缺陷数据集RSDD(rail surface defect detection dataset), 包含78幅高速铁轨图像和128幅普通铁轨图像, 该数据集中的所有图像分辨率不同。缺陷的类别为1类, 并包含相应的像素级分割标注。Niu等人(2021)建立了钢轨表面图像数据集RSDDS-113(rail surface defect detection 113 dataset), 利用双目视觉系统采集了113幅缺陷图像, 并且使用双目视觉系统获得了对应的深度图像, 从而可以确定缺陷的三维信息, 该方法在相似的任务上表现优异。同时, 很多金属缺陷检测的数据集陆续提出, 包括Steel Plates Faults数据集、Severstal数据集、Industrial metallic数据集以及天池铝材数据集。

2.1.2 布匹

纺织和布匹的缺陷数据研究是常见的研究方向。DAGM 2007纹理数据库由DAGM(国际模式识别协会德国分会)和GNSS(欧洲神经网络协会德国分会)组织的公开竞赛“工业光学检测弱监督学习”提供。DAGM数据集由6种人工生成的纹理图像组成, 共有10类不同的缺陷。每种缺陷都有1 000幅无缺陷图像和150幅在背景纹理上带有标记缺陷的缺陷图像, 图像分辨率为 512×512 像素且均使用椭圆框进行标注。椭圆框相对比较粗糙, 会包含较多的背景区域。

Silvestre-Blanes等人(2019)公布一个织物图像基准数据集AITEX。该数据集由245幅分辨率为 $4\,096 \times 256$ 像素的图像组成, 其中140幅是无缺陷图像, 105幅是缺陷图像, 包含了12种不同类型的缺陷。

TILDA(textile texture database)(Silvestre-Blanes等, 2019)是用于布匹缺陷检测的公开数据库, 包含8种代表性纺织品类型的3 200幅图像。每种纺织品分为7种缺陷类型和1种无缺陷类型, 每种类型由50幅 768×512 像素大小的8位灰度图像组成。

2.1.3 建筑材料

建筑裂缝数据集也是一类很经典的数据集。这类数据集包含建筑、桥梁以及道路等设施的表面缺陷的样本。较多的建筑表面裂缝数据集都是像素级别标注, 且类别只有裂缝这一个单类。

Zhang等人(2016)提出一个人行道表面裂缝数据集, 包含500幅分辨率为 $3\,264 \times 2\,448$ 像素的人行道图像, 数据集的标注方式为像素级标注, 标注质量很高。Shi等人(2016)提出一个混凝土裂缝数据集CrackForest, 包含329幅道路裂缝图以及它们的像素级标注。Maeda等人(2018)建立的道路裂缝数据集, 包括9 053幅缺陷图像, 涉及8类缺陷, 该数据集的图像分辨率均为 600×600 像素, 采用外接矩形进行标注。李良福等人(2019)提出一个桥梁裂缝面元的数据集, 包括2 068幅分辨率为 $1\,024 \times 1\,024$ 像素的桥梁裂缝的图像。Huang等人(2020)提出一个磁瓦缺陷数据集, 包含5种常见磁瓦缺陷和正常的图像, 共2 688幅缺陷图像, 数据集采用较为精确的像素级标注方式, 5个缺陷类别包括57幅裂缝图、115幅空洞图、103幅不平图、32幅油污图以及85幅破损图, 同时数据集中包含正常的磁瓦图像。

总体而言, 这类数据集包含人行道、桥梁、道路等设施的表面裂缝的样本。这类裂缝数据集普遍偏小, 且缺陷类别通常局限于裂缝本身。

2.1.4 3C产品

3C产品是对电脑及其周边、通讯(如手机)和消费电子3种家用电器产品的代称, 是制造业非常重要的一环。由于电子产品的精细工艺以及较高的产品溢价, 导致生产环节对缺陷容忍度较低, 催生了不少电子产品缺陷的数据集。

DeepPCB(deep printed circuit board dataset)数据集(Tang等, 2019)包含1 500个印刷电路板(printed circuit board, PCB)图像对, 每个图像对都包含1幅无缺陷的模板图像和1幅对齐的测试图像, 后者带有包括位置信息在内的注释。该数据集提供了6种常见的PCB缺陷类型: 1 942个开路标注、1 506个短路标注、1 965个鼠咬标注、1 625个支线标注、1 501个针孔和1 474个伪铜标注。同时, Ding等人(2019)提出一个合成的PCB缺陷数据集, 同样包含上面的6类缺陷, 包括115幅针孔图和鼠咬图、116幅开路图和短路图以及115幅杂铜和支线图。每幅图像包含若干个合成的缺陷, 标注方式为检测框。检

测框包含很多背景部分,标注质量较为粗糙。数据集共有693幅分辨率为 $2\,777 \times 2\,138$ 像素的PCB的缺陷图以及它们的检测标签。该数据集的缺陷在全图中的占比都很小,很适合进行弱小缺陷检测的研究。

Deitsch 等人(2019)提出一个光伏缺陷数据集 Elpv (electroluminescence image of photovoltaic module dataset),包含2 624幅 300×300 像素大小的8位灰度图像。这些样本是从44个具有不同程度的退化现象光伏系统中拍摄的(18个为单晶型,26个为多晶型)。Tabernik 等人(2020)在真实世界的受控工业环境中收集并建立一个表面缺陷数据集 Kolektor SSD (Kolektor surface defect dataset),该数据集包括一个类别,可在塑料表面观察到微观碎片和裂纹等缺陷,包含52幅有缺陷的样本以及347幅正常的样本。样本的宽为500像素、长介于1 240~1 270像素之间。

总体而言,3C产品的数据集包含印刷电路板(PCB)、光伏组件、塑料表面等缺陷图像,缺陷的种类各不相同,具有很强的产品相关性。

2.1.5 其他

Tao 等人(2020)收集了提供无人机拍摄的正常绝缘体图像和合成的缺陷绝缘体图像 CPLID (composite insulator partial discharge and defect dataset),包含600幅正常图像以及248幅合成的图像。数据集提供了PASCAL VOC2007 (pattern analysis, statistical modeling and computational learning visual object classes 2007)格式的标注信息。这个数据集对研究户外情况的缺陷检测具有很高的价值。

Carrera 等人(2017)提出一个 NanoTWICE (nano-textured wire insulation composite electronics)数据集,该数据集收集了纳米纤维材料的扫描电子显微镜 (scanning electron microscope, SEM) 图像,并标注了其中的异常。数据集包含5幅正常图像以及40幅带有像素级标注的测试图像,图像的大小为 $1\,024 \times 696$ 像素,此数据集补充了检测材料内部的缺陷的领域。

在X光领域,Mery 等人(2015)提出一个由19 407幅X射线图像组成的新数据集 GDXray (geometric distortion X-ray)。数据集包括5组X射线图像:铸件、焊缝、行李、自然物体和校准,分别为2 727、88、850、8 290以及152幅图像。设置物体类别包含不同的物体用于校准,包括检查板以及带有

常规模式的3D物体。每组有若干个系列,每个系列有若干幅X射线图像。大多数系列都有注释或标记。

异常检测数据集的训练集仅包含正常的图像,测试集为带有异常的图像。算法需要根据正常的样本进行建模,从而定位异常图像中的缺陷位置。MVTec AD (MVTec anomaly detection dataset) (Bergmann 等,2019a)是一个模拟真实工业检测场景的缺陷检测数据集。该数据集共包含15个类别,其中5个类别为不同类型的纹理,其余10个类别为10种不同类型的物体。在MVTec AD数据集中,共有3 629幅图像用于训练和验证,1 725幅图像用于测试,训练集仅包含无缺陷图像,而测试集包含无缺陷图像和各种类型的缺陷图像,该数据集通常用于无监督缺陷/异常检测。

总体而言,从户外大工业制品到微观材料结构等工业领域中,研究者提出各式各样的数据集,以供大家研究。

2.2 小结

按照数据集的物体类别,缺陷检测的数据集主要可分为异常检测数据集以及缺陷检测数据集。异常检测数据集种类较多且具有相对统一的风格,而缺陷检测数据集针对不同的工业领域有着多种风格。普通数据集按照工业的领域,又可分为金属制造业、布匹、建筑材料以及3C产品等不同领域。图3给出了部分缺陷检测数据集的实例。

3 非完全标注的缺陷检测算法

根据实际需要,本文采用不同的数据集和训练方法来训练缺陷检测的神经网络。因此,本节从数据集和训练方法两个维度出发,即标签策略和任务策略,对现有的缺陷检测方法进行介绍。标签策略根据训练模型时的数据集的不同类型的标注进行区别。在本文中,标签策略可以分为基于无监督学习、半监督学习以及弱监督学习的方法。任务策略根据缺陷检测的任务场景进行区分。在本文中,模型策略可以分为基于域适应、少样本以及大模型的方法。

3.1 标签类型

本节从无监督、半监督和弱监督学习3个思路出发,对现有的缺陷检测方法进行介绍。表2总结了不同标签类型下的技术路线的描述和特点。




图3 缺陷检测数据集展示

Fig. 3 Visualization of some defect inspection datasets

((a) NEU; (b) DeepPCB; (c) CrackForest; (d) DAGM 2007; (e) KolektorSSD; (f) Magnetic-tile)

表2 非完全标注的表面缺陷检测中不同标签类型的技术路线总结

Table 2 Technical summary under different label strategies for incompletely labeled surface defect detection

标签策略	使用场景	技术路线	介绍	优缺点
无监督	适用于数据集没有标注的场景	聚类	将数据集中的样本划分为若干个组别,使得同一个簇内的样本相似度较高,而不同簇之间的样本相似度较低。	优点为解释性强。缺点为超参数对算法效果影响较大。
		正样本建模	让模型学习建立正常样本的分布,通过分布外检测是否存在缺陷。	优点为只需要正常样本即可训练。缺点为对弱小缺陷检测能力较差。
		模板匹配	匹配模板图像与目标图像,从而定位模板在目标图像中的位置。	优点为检测效果比较好。缺点为很多工业场景下缺乏模板图像,导致算法无法使用。
半监督	适用于数据集部分图像有完全的标注、部分图像没有标注的场景	图像重构	使用模型重构出没有缺陷的图像,利用重构前后的差别定位缺陷。	优点为只需要正常样本或无标签的样本即可训练,对显著的缺陷更加有效。缺点为训练速度较慢。
		伪标签生成	利用没有标注的数据的输出生成伪标签,用于辅助训练。	优点为能够有效利用未标注的数据。缺点为很依赖伪标签的质量。
		数据增广	结合少量缺陷数据、大量的无标注数据以及数据集的先验信息,提出数据生成的策略,提高模型的缺陷检测能力。	优点为能够提高模型的鲁棒性。缺点为生成数据的分布很难贴近真实数据的分布。
弱监督	适用于数据集的图像只有弱标注的场景	类激活图	通过可视化网络中特定类别的激活,理解模型在做出预测时依赖的特征区域,从而定位缺陷。	优点为可解释性强。缺点为缺陷边缘的检测效果不佳。
		迭代优化	通过多次预测,迭代优化模型的预测效果。	优点为检测效果好。缺点为速度慢,训练和推理的成本高。

3.1.1 基于无监督学习的缺陷检测方法

基于无监督学习的方法不依赖缺陷的标注,仅使用数据集中提供的无缺陷数据,主流的研究思路为聚类和图像重构,也有部分方法使用模板匹配、显

著性等方式检测缺陷。

聚类是一种无监督学习算法,它的目标是将数据集中的样本划分为若干个组别或“簇”,使得同一个簇内的样本相似度较高,而不同簇之间的样本相

似度较低。Yang 和 Qian(2016)提出一种基于无监督聚类的新方法,用于未标记数据集的缺陷预测。该模型在多个开源项目的实证研究中显示出与监督学习模型相当的预测性能,特别是在处理项目间数据分布差异时显示出优势。Hamdi 等人(2018)介绍了一种用于检测有图案织物缺陷的无监督算法,结合了标准差滤波和 K-means 聚类,有效突出异常变化并减弱周期性图案,整体检测成功率达到 95%。Volkau 等人(2019)提出一种新颖的无监督深度学习模型,该模型利用 VGG16(Visual Geometry Group)迁移学习变体和 ImageNet 预训练权重系数,通过高维特征空间的聚类来检测印刷电路板缺陷。Kuric 等人(2021)对基于激光传感器的数据则使用无监督聚类方法检测异常,随后使用 VGG16 神经网络进行缺陷分类。Xu 等人(2021b)进行了一项比较研究,发现基于实例违规分数的聚类模型在缺陷预测性能上优于其他类型的聚类模型。Taherkhani 等人(2022)研究了一种基于机器学习的无监督算法,用于检测激光粉末床熔化过程中的孔隙。通过彻底定制的自组织映射算法对光强度信号中的扰动进行分类,并将聚类扰动与缺陷的几何特征和位置映射起来。Sresakoolchai 和 Kaewunruen(2022)提出一种结合有监督和无监督机器学习技术的铁路缺陷检测方法。通过 K-means 聚类分析缺陷之间的关系,该方法能够有效地检测轨道组件缺陷,并且模型的准确率超过 90%。Wang 等人(2023b)提出一种用于选择性激光熔化过程中的无监督缺陷分割方法。该方法包含特征学习、自注意力和聚类模块,仅需单幅扫描图像即可检测出增材制造表面上的缺陷。这些研究表明,在缺乏大量标记数据的情况下,聚类方法能够提供高效、准确的缺陷识别能力。Yang 等人(2024)研究了 22 种无监督聚类技术在无监督缺陷预测中的相对价值。研究发现, K-medoids 聚类技术在减少初始误报方面表现显著,并且与一些监督 EADP 方法相比具有竞争力。聚类算法的可解释性很强,但是预设的类别数量对算法效果影响较大。

正样本建模的思路则是让模型学习建立正常样本的分布,从而恢复图像。比较输入图像和恢复图像的差异从而定位缺陷。部分方法对正常样本进行概率建模或者特征提取和融合的方式。Mei 等人(2018)通过在不同高斯金字塔级别的图像块上重建卷积去噪自编码器网络,并综合这些不同分辨率通

道的信息中获取缺陷检测的结果。Szarski 和 Chauhān(2022)结合了视觉变换器编码器和归一化流,仅使用正常数据训练,就能实现高准确率的可解释的缺陷检测。Mujeeb 等人(2018)提出一种基于深度的无监督表面缺陷检测方法。在测试阶段,将同一产品的测试图像发送至训练好的网络中生成测试图像描述符,并通过比较参考和测试描述符的相似度得分来判断是否存在缺陷。

也有一些方法使用自编码器(autoencoder, AE)以及流模型(flow)来重建图像。Bergmann 等人(2019b)通过将结构相似性(structural similarity, SSIM)应用于自编码器,提出一种改进的无监督缺陷分割方法。该方法使用感知损失函数来衡量局部图像区域之间的相互依赖性,从而更准确地检测出在结构上发生视觉变化的缺陷区域。Liu 等人(2020)提出一个重建和分类卷积自编码器网络来提取缺陷区域。该方法通过基于密度的聚类算法对缺陷等级进行评估,在输入图像后添加了 dropout 层以增强网络对噪声的鲁棒性。Xu 等人(2021a)提出一种基于无监督神经网络的轴承缺陷检测方法。该方法使用未标记数据的梯度作为标签,并结合 U-Net 创建自编码器网络来预测输出。Min 和 Li(2022)提出一种缺陷移除变分自编码器用于铁路表面图像的背景重建,通过自监督学习检测缺陷。Wang 等人(2022a)提出一种基于无监督学习的纺织品缺陷检测算法。该算法基于自编码器和形态学,仅使用正常样本数据集进行训练能够在像素级别实时检测各种尺寸的纺织品缺陷。Peng 等人(2024)提出一种基于 2-D 流(flow)的轻量级无监督缺陷检测方法,名为 LightFlow。该方法通过集成 FastFlow 模型插件,使用简化的卷积神经网络(convolutional neural network, CNN)预训练骨干网络,优化 2-D Flow 模块,并采用不同的训练策略来提高模型性能。

部分研究者使用生成对抗网络(generative adversarial network, GAN)重建图像。Hu 等人(2020)引入一个新的编码器组件扩展了标准的深度卷积生成对抗网络(deep convolution GAN, DCGAN),协助模型重建查询图像,使得重建图像仅保留正常纹理而不包含缺陷。通过从原始图像中减去重建图像,可以创建残差图以突出潜在的缺陷区域。Wang 等人(2020a)提出一种基于无监督生成对抗网络(deep convolutional generative adversarial network, DCGAN)

的纹理表面缺陷检测方法。该方法在训练阶段只需要适度数量的无缺陷样本,通过扩展的DCGAN重建输入图像块,利用残差图实现初始缺陷分割。Wang等人(2021c)提出一种基于GAN的无监督学习方法,用于从X射线图像中自动检测轮胎缺陷。在训练阶段,仅使用无缺陷样本来训练模型,并更新记忆模块中的记忆项,这样在测试阶段重现的图像将必然类似于无缺陷图像。Guo等人(2022)提出一种新的无监督小样本缺陷检测模型——ISU-GAN(image-to-surface unsupervised generative adversarial network)。该模型基于CycleGAN架构,并添加了跳跃连接、SE(squeeze-and-excitation)模块和Involution模块,显著提升了模型的特征提取能力和重构能力。Cheng等人(2023)提出AtomGAN,用于快速准确地检测二维材料中的缺陷。该方法使用模拟的透射电子显微镜图像和相应的缺陷分割图像进行训练,通过生成对抗网络学习原子排列规则,以区分有缺陷和无缺陷的区域。总体而言,正样本建模只需要接触正常样本即可学习。但对弱小缺陷检测能力较差。

除了聚类以及图像重构的方式以外,如模板匹配和显著性检测等方式也用于精确识别和定位图像中的特定缺陷。Niu等人(2021)利用双目线扫描系统进行无监督立体显著性检测,可以获取高精度的铁路表面图像和轮廓信息,同时避免了传统重建方法的解码失真问题。Liu等人(2019)提出一种基于无监督分割和极限学习机(extreme learning machine, ELM)的新型织物缺陷分类方法,通过无监督分割、特征提取、ELM分类器训练和贝叶斯概率融合的步骤,结合多分辨率小波包分解和Hu不变矩提高分类精度。Yu等人(2020)提出一种基于对抗性图像到频率变换(adversarial image-to-frequency transform, AIFT)的无监督道路缺陷检测方法,通过在频率域中使用生成器和鉴别器进行对抗性学习,其性能在多种情况下超过了现有最先进方法。Koulali和Eskil(2021)结合CNN的优势和无监督学习,采用动态和启发式的特征选择,提出一种新颖的基于图案的无监督织物缺陷检测方法,避免了传统CNN中初始化滤波器数量和权重的问题,减少了超参数调整的工作量。Fridman等人(2021)通过比较“完美”的参考PCB图像与被检测的PCB图像来实现高质量的缺陷检测,包括焊接缺陷、缺失或错位的电

子元件。该研究还引入了CD-PCB数据集,由20对PCB图像组成,用于评估缺陷检测算法的性能。Lyu等人(2023)提出一个工业生产中表面缺陷的无监督缺陷检测方法。该方法由图像匹配模块和异常定位模块组成,其中图像匹配模块负责将输入图像与预设模板对齐,异常定位模块通过为局部图像区域分配特征中心来提高特征紧凑性,从而更有效地检测潜在异常目标。Zhao等人(2023)的方法通过多级空间域显著性方法和织物特征提取方法来识别潜在的缺陷区域,并使用自适应织物特征聚类算法来调整特征权重,实现精确的织物缺陷分类。Zhang等人(2023a)提出一种基于PCA和基于直方图的异常分数的无监督纹理缺陷检测方法。该方法通过PCA提取特征,增强缺陷与背景的差异,并通过HBOS(histogram-based outlier score)定位缺陷,为电力设备等领域提供了一种有效的解决方案。

总体而言,无监督的方法有着广阔的应用前景。但由于模型只能接触到正常样本,无法接触到缺陷标注,削弱了其缺陷检测的学习能力。

3.1.2 基于半监督学习的缺陷检测方法

半监督学习是一种经典的学习范式,它结合了少量标记数据和大量未标记数据来训练模型。半监督学习的核心思想是利用未标记数据来提高学习算法的性能,尤其是在标记数据稀缺时。

有部分研究方法使用自编码器、生成对抗网络以及归一化流等方法来学习缺陷数据的图像重建工作。让模型自主学习如何重构出没有缺陷的图像,从而定位缺陷,对显著的缺陷更加有效。He等人(2019a)提出的CAE-SGAN方法结合了卷积自编码器(convolutional auto-encode, CAE)和半监督生成对抗网络,通过大量未标记数据训练和传递层特征提取,提高了钢铁表面缺陷分类的泛化能力,尤其在热轧钢板上分类率显著提升。Zhang等人(2019a)开发的基于深度变分自编码器的轴承异常检测方法,允许在少量标记数据的情况下有效利用数据集。Ai等人(2020)提出的基于CycleGANs的半监督缺陷分割方法,通过少量像素级标注数据和无监督学习补充,有效降低了对大规模标注数据集的需求,提高了分割性能,GDXray数据集上的实验验证了框架的有效性。Zhou等人(2021)提出的半监督织物缺陷检测方法利用变分自编码器(variational autoencoder, VAE)进行特征提取和图像重建,结合高斯混合模型

(Gaussian mixture model, GMM)进行密度估计,有效提升了缺陷区域边界的构建精度。Zhang 等人(2021a)开发的半监督生成对抗网络通过双重注意力机制和全卷积判别器网络,实现了更精确的缺陷分割和未标记图像的置信度图生成,减轻了数据标记负担,提高了分割性能。He 等人(2019b)提出的基于多训练和GAN的半监督钢表面缺陷分类方法,通过生成大量未标记样本和多次训练过程,实现了比监督学习更高的准确性和鲁棒性,分类准确率达到99.56%。Jing 等人(2022)提出的热轧带钢卷形缺陷预测算法,基于连体半监督去噪自编码器—卷积神经网络,通过重建信息特征向量和跳跃连接,展现了强大的泛化能力。Minhas 和 Zelek(2020)介绍了一种基于卷积自编码器的半监督异常检测架构,该架构仅使用正常样本进行训练,通过残差图和阈值处理得到缺陷分割图。Liu 等人(2021)提出一种称为双原型自动编码器的半监督异常检测方法,通过双原型损失和重建损失鼓励潜在向量的接近性,减少正常样本内部差异。Sae-Ang 等人(2022)利用自编码器辅助模块进行缺陷分割,结合少量标记样本和大量未标记样本,通过重建无缺陷图像和差异图的输入。Rudolph 等人(2021)提出一种名为 DifferNet 的半监督缺陷检测方法,使用卷积神经网络和归一化流来估计特征的概率密度,通过多尺度特征提取器处理高维数据分布,实现像素级的缺陷定位。Li 等人(2022a)通过标记晶圆图训练预测模型并排除可疑样本,然后对未标记数据进行分类,使用无监督学习算法提取更多缺陷模式,提高了缺陷识别的准确性和效率。Park 和 Kim(2025)提出一种半监督学习模型,利用自编码器降低磁通泄漏信号的特征维度,并结合半监督支持向量机对钢铁表面的多缺陷进行分类和定位。Huang 等人(2024)提出的基于YOLOv4的半监督目标检测网络,结合GAN和注意力模块,有效提高了风电叶片表面缺陷检测的泛化能力和识别精度,改进的损失函数平衡了缺陷种类不平衡问题。

有部分研究方法利用部分缺陷数据进行训练,接着对没有标注的数据打上伪标签,用于辅助训练。Gao 等人(2020)提出的基于半监督卷积神经网络的钢表面缺陷识别方法,采用伪标签技术有效解决了样本收集和标记难题。Chen 等人(2021)提出一种增强的标记技术,通过训练模型对未标记数据进行

分类,并使用无监督学习算法提取和分类难以识别的缺陷模式。Liu 等人(2022)使用软伪标签和相互校正分类器,在标记样本有限的情况下显著提高了缺陷检测准确率。Sime 等人(2023a)通过不确定性感知和动态混合伪标签来提高性能,解决了未标记样本预测中的噪声和不确定性问题。Zhang 等人(2024c)提出的半监督飞机机身缺陷检测网络利用动态注意力和类别感知的自适应伪标签分配策略,提升了小缺陷的检测准确率,并通过自适应获取伪标签过滤阈值优化了半监督学习过程。Manivannan(2024)提出的双头卷积神经网络,通过两个分类器头平衡多数类和少数类的关注,有效处理类别不平衡问题,并通过基于这两个分类器的输出选择伪标签,扩大了标记训练集,并用于重新训练CNN。

有部分研究方法进一步发展伪标签的技术,使用均值教师网络生成伪标签,用于训练学生网络。Shao 等人(2022)结合多任务均值教师网络的像素级半监督织物缺陷检测方法,通过多任务学习改善了缺陷分割效果。Liu 和 Ye(2022)提出的半监督学习方法采用教师—学生模型和课程学习策略,通过交替优化生成伪标签,并利用mixup技术减少标签噪声。Ozdemir 和 Koc(2024)使用YOLOv4(you only look once v4)和伪标签的半监督学习方法通过学生—教师模型自动标记图像,通过伪标记图像扩展训练集,提升了检测性能。Wang 等人(2024b)模型通过均值教师架构为未标记图像分配伪标签,并执行像素级对比学习,显著提升了混凝土缺陷分割的准确性。Wu 等人(2024)通过两阶段训练和教师—学生网络解决标记数据稀缺问题,引入自信息排名和扰动方法,减轻了伪标签噪声的影响,并逐步提高了缺陷特征表示,优化半监督缺陷分割过程。伪标签的生成能够有效利用未标注的数据,但是很依赖伪标签的质量。

有部分研究结合少量缺陷数据、大量的无标注数据以及数据集的先验信息,提出数据生成的策略,提高模型的缺陷检测能力。EATT(exemplary anomaly target training)方法(Zhang 等, 2019b)专注于即时缺陷预测,通过样本选择提高预测精度,尤其在标签信息稀缺时表现卓越。Lee 和 Kim(2020)提出的一个半监督深度卷积生成模型(semi-supervised convolutional deep generative model, SS-CDGM)针对具有混合型缺陷模式的晶圆箱图(wafer box map,

WBM)进行多标签分类,通过深度卷积神经网络提取特征并引入多个判别网络提高分类性能,同时作为生成模型解决了数据收集难题。Wan 等人(2022)提出一种用于PCB质量检测的数据扩展策略,通过结合批量添加和数据扩展策略减少对标记样本的依赖,并降低未标记样本的干扰,显著提升了DeepPCB数据集上的缺陷检测性能。MemSeg(memory segmentation)方法(Yang 等, 2023)利用人工模拟的异常样本和记忆样本,通过学习正常与异常图像间的差异获得稳健分类超平面,并使用记忆池猜测异常区域,实现了在MVTec AD数据集上的最先进性能。SSAL(semi-supervised auxiliary learning)(Yu 等, 2024)通过整合产品形态信息和无缺陷样本的半监督辅助学习,减少了对大量标记数据的需求,同时降低了过拟合风险,并在开源数据集上实现了优于多种方法的性能。SAIT(sparse annotations and intrinsic tasks)方法(Qi 等, 2024b)通过稀疏注释和内在任务,利用视觉变换器和随机失真增强,以及定制的联合目标函数和特制的主干网络,提高了航空发动机缺陷的语义分割能力。数据增广是一种广泛使用的提高模型检测能力的手段,合成数据能够提高模型的鲁棒性,但是生成数据的分布很难贴近真实数据的分布,从而影响了模型的效果。

3.1.3 基于弱监督学习的缺陷检测方法

弱监督学习是一种监督学习方法,它使用不完整或不精确的标签来训练模型。与完全监督学习相比,弱监督学习中的标签可能包含噪声或不精确的信息。

使用类激活图(class activation mapping, CAM)提高标签的精确性是弱监督学习方法的一个主流方向。通过可视化网络中特定类别的激活,能够揭示网络是如何识别和区分不同类别的,这有助于理解模型在做出预测时依赖的特征区域,从而定位缺陷。Yi 等人(2019)提出的基于选择性搜索和CAM的弱监督表面缺陷检测方法,利用选择性搜索生成缺陷边界框,并通过训练好的模型预测缺陷的分类和CAM。使用分类信息过滤边界框,并映射到相应缺陷的CAM上,通过全局空间池化选择得分最高的边界框作为检测结果,提高了缺陷定位的准确性。Marino 等人(2019)创建了大规模图像级标注数据集用于马铃薯缺陷分割。他们利用CNN激活图中的判别区域来定位缺陷,提出由粗到细的分割方法,以

获得更精确的缺陷大小。König 等人(2022)通过CNN分类器生成的粗糙裂缝定位图,结合类激活图和基于补丁的分类方法,再通过基于阈值的方法进行融合,有效地分割出较暗的裂缝像素。Wang 等人(2021b)提出的框架结合了弱监督 and 全监督学习方法,用于隧道图像中裂缝的检测和分割。他们自动注释数据集,代替了传统的手动注释过程,并通过后处理评估了检测到的裂缝的损坏程度,节省了人力和时间成本。Jiang 等人(2021)提出的基于弱监督学习的卷积神经网络模型,用于X射线图像中的铸件缺陷检测。他们使用注意力图来表示图像中的缺陷部分,并通过注意力引导的数据增强方法扩大数据集。Xie 和 Lin(2021)提出的双路径缺陷检测网络(DPNET网络)基于弱监督目标检测模型,通过图像级标签识别缺陷的分类标签并进行定位。引入增强特征图通道的权重的模块,提出GAM-CAM模块改善小目标缺陷的定位能力,有效减少了人工标注成本。Wu 等人(2022b)提出的基于CAM的弱监督表面缺陷检测方法,使用连体网络和自动聚焦子区域损失、非局部注意力以及对数求和指数全局池化模块增强检测性能。Nie 等人(2023)通过引入加权激活图融合技术和类激活图(CAM),突出显示特定于类的区域,并采用优化的区域生长操作来消除缺陷区域的噪声。此外,他们提出一种优化的推理方法,为缺陷识别提供有意义的视觉解释,显著提高了缺陷识别能力。Jamali 等人(2023)提出一种基于弱监督深度学习的道路缺陷分类和定位框架,结合了弱监督和监督方法的优势。使用基于弱监督方法提取的特征图(如CAM)来训练分割网络,实现了在图像中对缺陷的高效定位和分割。He 等人(2024)提出一种创新的弱监督路面裂缝分割方法,利用生成对抗网络和目标重新优化技术。通过模型和图像级标签生成类激活图,然后通过擦除和重新检测裂缝的方法来细化CAM,有效提升了路面裂缝检测的性能。FBSFormer(foreground-background separation Transformer)方法(Jiang 等, 2024)提出前景—背景分离(foreground-background separation, FBS)模块和注意力图细化(attention map refinement, AMR)模块。前景—背景分离模块利用注意力图分离前景缺陷特征和背景特征,而注意力图细化模块生成更准确的注意力图,以指导缺陷和背景特征的分离,提升了缺陷检测的性能。类激活图方法的可解释性强,但是

缺陷边缘的检测效果不佳。

迭代学习也被用于弱监督的缺陷检测中。Qi等人(2024a)提出一种名为弱监督深度水平集学习的连续可微且统一的航空发动机缺陷分割框架。WDLS结合了多分支结构和迭代学习策略,将高性能的CNN架构与水平集演化相结合,引入了一种自监督的目标函数,名为凸化水平集,以改进水平集公式并获得最终分割。Zhang等人(2024d)提出一种结合异常感知的弱监督轻量级模型,采用了多重监督以充分利用数据。该模型首先设计了一个轻量级主干网络来获取特征图,然后提出一种新颖的弱监督定位(weakly supervised localization weakly supervised localization, WSL)方法来获取异常响应,将其作为下游网络的先验知识。He等人(2021)提出一种基于多任务学习的神经网络方法,用于在弱监督下对纹理表面的缺陷进行检测。他们设计了一个编码器提取特征和两个解码器用于恢复纹理表面的缺陷以及获取感兴趣区域(region of interest, ROI)这两个相关任务,通过共享编码器实现多任务学习的优势。Wang等人(2023a)提出一种基于弱监督学习的工业产品表面缺陷检测的深度学习架构。他们提出一种新颖的多任务框架,利用图像级标签训练缺陷分割,并通过引入通道空域注意力模块(channel and spatial attention module, CBAM)增强分类性能,同时采用粗粒度注释以最小化注释成本。迭代训练方法的检测效果好,但是速度慢,训练和推理的成本高。

同时,很多研究者采用知识蒸馏、联邦学习、聚类以及多视角分析等不同的方法提高弱监督的缺陷检测的效果。Minhas和Zeleg(2019)提出一个用于在纹理表面上检测异常的轻量化弱监督学习系统。Anonet方法是一个全卷积网络,结构紧凑且浅层,模型体积小,并且即使在弱标注的情况下也能检测和定位异常。Anonet通过使用工程化的滤波器库初始化技术减少了训练所需的样本数量,并达到了最先进的性能。Zhang等人(2021b)通过在分类流程中提取类别感知的空间信息实现弱监督学习,并采用知识蒸馏策略,迫使轻量级CADN(category-aware object detection network)学习到的特征模仿大型CADN的特征,从而在保持高实时性能的同时提高准确性。Kasahara等人(2021)提出一种基于聚类的弱监督增强方法,用于在只有少量人工弱监督的情况下,提高混凝土结构声学缺陷检测的性能。同时,

他们通过细粒度的聚类划分,将人工提供的弱监督对扩展到聚类层面,生成新的监督对,以增强现有的监督信息。Yao等人(2021)提出一种基于质心损失的弱监督语义分割方法。该方法通过弱注释方法,显著减少了为达到竞争性能所需的图像注释数量,并在两个与工业相关的案例研究中评估了该方法的性能。Phalawan等人(2023)提出一种基于多视角分析的两阶段弱监督缺陷检测系统,包括标签恢复和分类器训练。系统设计了一个基于物联网的图像采集系统,使用单个摄像头通过旋转瓶子获取多视角图像。Zakharov等人(2023)利用图的谱卷积方法,通过将图像区域作为图中的节点,并将相邻区域用图的边连接起来,从而实现对缺陷的识别。Qi等人(2023)提出一种名为渐进学习动态水平集的弱监督工业缺陷分割框架。该方法仅使用图像级标签作为输入,迭代地细化对象边界,动态优化训练过程,并生成像素级输出。该方法集成了两个并行学习模块和一个可微水平集模块,这些模块通过创新的损失函数促进渐进学习策略相互连接。Guo和Jiang(2024)提出一种新框架,将弱监督异常检测与联邦学习相结合,在第1层使用弱监督异常检测在联邦学习机制下训练深度异常检测模型,识别并标记异常;在第2层使用标记的异常和正常数据在FL机制下训练多分类模型。

3.2 任务策略

本小节从域适应、少样本和大模型3个任务策略出发,对现有的缺陷检测方法进行介绍。表3总结了不同类型下的技术路线的描述和特点。

3.2.1 基于域适应的缺陷检测方法

域适应(domain adaptation, DA)是机器学习领域中的一个重要研究方向,主要关注如何将一个在特定源域(source domain)上训练好的模型迁移到一个标签缺失或标签稀缺的目标域(target domain),其中源域和目标域的数据分布是不同的。域适应的目标是使模型在目标域上也能有良好的性能,即便目标域的数据与源域的数据在特征分布上存在差异。在缺陷检测的场景中,不同产线的产品不同的缺陷分布,使得域适应有着广阔的应用前景。

在域适应缺陷检测领域,研究人员通过对齐源域和目标域的分布,实现模型从源域迁移至目标域的效果。Marino等人(2020)提出的无监督深度领域自适应方法,通过对抗训练和伪标签损失,显著提

表3 非完全标注的表面缺陷检测中不同任务策略的技术路线总结

Table 3 Technical summary under different task strategies for incompletely labeled surface defect detection

任务策略	适用场景	技术路线	介绍	优缺点
域适应	适用于旧产线有完全的标注,但新产线的数据没有标注的场景	分布对齐	对齐源域和目标域的分布,实现模型从源域迁移至目标域的效果。	优点为方法简单有效。缺点为源域和目标域的分布很难完全对齐,从而降低了模型在目标域的检测效果。
		学习域不变特征	通过学习源域和目标域通用的特征,实现模型从源域迁移至目标域的效果。	优点为能够提取鲁棒的特征。缺点为难以完全消除源域和目标域的差异性,导致模型在目标域的适应性不足。
		动态参数调整	通过调整模型的部分参数和超参数,实现模型迁移至目标域的效果。	优点为迁移速度快。缺点为检测效果一般,且需要精细搜索更合适的超参数。
少样本	适用于旧产线有完全的标注,但新产线只有少量数据的场景	元学习	通过学习任务之间的共同模式来提高学习效率。	优点为能够快速适应新任务。缺点为在泛化能力上受限,且模型的解释性可能不如传统机器学习方法。
		度量学习	学习一个距离度量或相似性度量,使得相似的数据点在度量空间中彼此靠近,而不同的数据点则相互远离。	优点为可以针对特定任务定制合适的距离度量。缺点为对超参数的选择非常敏感。
		图神经网络	通过学习图像中像素或区域之间的相互关系。	优点为能够有效学习样本间的关系。缺点为图神经网络的训练和推理过程可能需要较高的计算资源。
大模型	适用于新产线的信息缺乏,需要强大泛化性的场景	SAM、CLIP	使用SAM和CLIP的强大的零样本泛化能力以及文本的特征提高缺陷的检测效果。	优点为能够实现零样本泛化。缺点为在低对比度或复杂场景中可能需要特定领域的先验知识来支持。
		LLM、VLM	迁移LLM、VLM的知识提高模型的缺陷检测效果。	优点为能够有效结合多模态的数据。缺点为性能很大程度上依赖于预训练数据的质量和多样性,数据不足或偏差可能导致模型性能下降。

高了土豆缺陷分类的F1分数。Wang等人(2023c)结合图卷积网络和领域对抗训练,解决了小样本问题,提高了气体绝缘变电站绝缘缺陷的诊断能力。Zhang和Zhang(2023a)通过多目标领域分层动态实例分割,实现了多源领域的有效迁移和缺陷识别精度的提升。Yan等人(2024)通过不确定性启发的自训练策略,提高了铁路表面缺陷检测的泛化能力和分割精度。Zhang等人(2024b)通过类别选择性双重对抗网络和重要性增强机制,实现了领域对齐和类别级对齐,提高了表面缺陷检测的泛化能力。

进一步,在多个尺度对齐源域和目标域的分布能够提高模型对目标域的缺陷检测效果。Song等人(2021)通过多尺度对抗性和加权梯度领域自适应,解决了数据稀缺情况下的表面缺陷检测问题。Ma等人(2024b)通过跨尺度融合和领域对抗学习,提高了铁路表面缺陷分割任务在未见过数据集上的泛化能力。Ye等人(2024)通过原型引导和领域自适应

单阶段目标检测,实现了多领域自适应缺陷检测中的高性能。总体而言,源域和目标域的分布很难完全对齐,从而降低了模型在目标域的缺陷检测效果。

在域适应缺陷检测领域,学习域不变特征是提升模型泛化能力的关键。通过学习鲁棒的域和目标域公用的特征,实现模型从源域迁移至目标域的效果。Wang等人(2022c)将图信号和图卷积网络(graph convolutional network, GCN)应用于绝缘缺陷诊断,利用特征空间局部区域之间的相关性,并通过领域自适应迁移学习(transfer learning, TL)提高了少样本现场条件下的诊断精度和鲁棒性。Wu等人(2022a)提出一种跨域少样本学习方法,用于锂离子电池表面缺陷分类。创新之处在于使用改进的孪生网络和多曝光结构光方法获取3D表面信息,并引入批量光谱正则化(BSR)避免目标域中的负面迁移。Li等人(2022b)提出一个两阶段的迁移学习策略,包括跨域和领域内迁移学习,以适应结构裂缝图像与

自然图像的差异。该方法引入梯度加权类激活映射(Grad-CAM)提高模型的可解释性,实现了无需精细手动数据注释的裂缝分类和定位。Ma等人(2023)提出一种新颖的一次性无监督领域自适应框架,用于铁路表面缺陷分割。创新之处在于引入形状一致的风格转换模块进行像素级分布对齐,以及采用多任务学习策略防止重建图像内容失真,提高了模型对分布差异的鲁棒性。Duan等人(2023)提出一种新颖的跨领域小样本缺陷识别方法,解决工业场景中缺陷数据稀缺的问题。创新点包括元增强方法和类协方差引导的特征扰动方法,通过扰动特征分布来增强跨领域泛化能力。Zhang等人(2023c)提出的TST(Transferable swin Transformer)方法通过区域对抗性对齐和基于语义的子域自适应策略,学习到在域偏移情况下可转移和具有辨别性的特征。TST利用区域级加权机制来考虑图像区域在域转移时的差异性,证明了其在轮胎缺陷检测任务中的有效性和泛化能力。Ma等人(2024a)通过引入两个编码器将缺陷图像分解为域不变结构特征和域特定风格特征,仅使用域不变特征进行缺陷识别。通过风格变分自编码器随机生成新的缺陷风格,从而提高了模型在未知场景下的泛化能力。学习源域和目标域共有特征可能无法完全捕捉源域和目标域的差异性,导致模型在目标域的适应性不足。

部分研究方法探究设置部分自适应因子或者模型参数来实现缺陷检测的域适应。Zhang等人(2022)提出一种基于双域自适应的迁移学习策略,用于轮胎缺陷检测。该方法使用动态自适应因子衡量边际分布和条件分布的相对重要性,并通过多头自注意力机制捕捉全局上下文信息,显著提升了域偏移情况下的检测准确率。Li等人(2023a)通过超参数 α 实现知识转移,优化了工业缺陷检测中的泛化能力。该方法通过最小化源域和目标域的分布差异来提升检测性能。Zhang等人(2023b)提出一种基于多领域特征表达和自优化的不锈钢焊缝缺陷识别方法。创新点在于构建多空间域数据集的轻量级网络,并通过麻雀搜索算法进行自适应压缩和参数优化,实现了高准确率和快速检测。Shi等人(2023a)通过动态调整模型参数以适应不断变化的数据,利用批量归一化层存储领域知识,实现了无需重新训练即可适应新领域的能力。Zhang等人(2023d)通过混合权重机制处理源域中的异常类别,

并采用细粒度域自适应策略减轻负迁移影响,提升了缺陷检测任务的平均准确率。设置部分自适应因子或者模型参数来实现缺陷检测的域适应的方法速度快,但是需要搜索更合适的超参数,且检测效果一般。

3.2.2 基于少样本的缺陷检测方法

少样本学习关注于在只有少量缺陷样本的情况下训练模型,使其能够对新的或未见过的缺陷类别进行有效的泛化。这种学习方式对于缺陷检测中的许多应用非常重要,因为在工业场景中获取大量标记数据可能成本高昂或不可行。少样本学习的关键挑战在于如何利用有限的学习数据来学习足够泛化的特征表示,同时避免过拟合。

针对少样本缺陷检测的问题,一个直接的解决方案是元学习。元学习通过学习任务之间的共同模式来提高学习效率。Zhang等人(2020)提出一种基于模型忽略的元学习(model-agnostic meta-learning, MAML)的少样本轴承异常检测框架。该方法的创新之处在于其在新的人工故障泛化上实现了比传统方法高出25%的准确率,展现了在现实世界轴承损伤识别中的竞争力。Lee等人(2023)提出一个跨域元学习框架用于使用少量标记样本解决缺陷分类问题,结合了元学习、无监督学习和特征表示技术,显著提高了工业视觉检查任务中的缺陷分类性能。Yu等人(2022)提出一种新框架,用于风力涡轮表面缺陷的少样本检测,采用元学习思想和跨任务训练策略,以及实时反馈环节,进行信息增强和筛选。Hu等人(2022)提出一种任务排序元学习方法,用于解决工业生产中故障数据收集困难的问题。该方法通过任务排序算法模仿人类获取知识的方式,提高模型的适应性和泛化能力。Shi等人(2023b)提出一种基于元学习的方法Meta PowerNet,用于输电线路的缺陷检测。该方法设计缺陷特征重建模块,提高了对缺陷类别的注意力和检测精度。Liu等人(2023)提出一种针对金属表面缺陷识别的少样本学习方法,通过注意力嵌入和自监督学习进行。该方法能够在没有标注数据的情况下训练鲁棒的注意力嵌入网络,并在元学习阶段通过查询引导权重解决特征向量偏差问题。Pang等人(2024)探索了一种改进的MAML框架,称为Permute-MAML,用于工业表面缺陷检测的少样本学习问题。该方法显著提高了MAML框架的稳定性,并在工业表面缺陷检测中

实现了高准确度,同时不需要广泛的预训练或额外的图像输入。元学习能够快速适应新任务、减少对大量标注数据的需求,但可能在泛化能力上受限,且模型的解释性可能不如传统机器学习方法。元学习的思路能够快速适应新任务、减少对大量标注数据的需求,但缺点是可能在泛化能力上受限,且模型的解释性可能不如传统机器学习方法

在缺陷检测领域,度量学习技术正在帮助模型在少量数据的情况下快速适应新任务。度量学习通过学习一个距离度量或相似性度量,使得相似的数据点在度量空间中彼此靠近,而不同的数据点则相互远离。Wang 等人(2020b)提出一种基于度量的元学习方法,用于少样本滚动轴承故障诊断。该方法使用一维卷积神经网络提取特征,并通过度量学习器预测样本间的相似性,采用标签平滑和 Adabound 算法提高分类性能。Cheng 等人(2021)采用基于迁移学习的两阶段训练方案,将知识从常见缺陷类别迁移到罕见缺陷类别。他们通过特征提取、重新加权 and 距离度量模块,提高了对罕见缺陷的检测性能,同时减少了过拟合风险。Wang 等人(2021a)提出一种结合监督学习和度量元学习的少样本故障诊断方法,利用个体样本和样本组的相似性信息,在 1-shot 和 5-shot 学习任务中表现优于多个基线方法。Yu 等人(2022)设计了基于深度度量的分类方法,在模型训练中加入实时反馈环节,提高了训练效率和缺陷识别速度。Song 等人(2022)提出一种新的少样本缺陷识别方法,采用粗到细的识别方式和动态加权。该方法提出仿射动态加权模块和基于 KL(Kullback-Leibler)散度的联合度量方法,提高了特征的区分性和相似性测量的精确度。Min 等人(2023)提出一种少样本铁路表面缺陷检测模型,利用预训练模型提取特征,然后通过无监督学习技术学习特征分布,创建特征原型记忆库。度量学习可以针对特定任务定制距离度量,提高缺陷检测的准确性,但对超参数的选择非常敏感,需要仔细调整以获得最佳效果。

在少样本缺陷检测领域,GNN 因强大的特征聚合和关系建模能力而展现出创新的应用。GNN 通过过学习图像中像素或区域之间的相互关系,通过学习少量样本中的模式来泛化到新的、未见过的数据上。Bao 等人(2021)提出专门针对金属表面缺陷的少样本分割方法,引入表面缺陷三元组、多图推理模块以及自适应辅助预测模块,提高了分割的准确

性和泛化能力。Xiao 等人(2022)提出一种结合图嵌入和最优传输的少样本缺陷分类方法,利用图嵌入和分布转换模块以及最优传输模块,以归纳方式实现少样本分类,确保了图嵌入结果的一致性分布。Deng 和 Song(2023)提出一种结合元学习与图神经网络的少样本检测方法。该方法通过多关系聚合模块,从不同角度聚合查询和支持特征,以及自适应支持学习模块动态调整权重,创新性地解决了类别独立的特征聚合和内部类外观差异问题。Zhang 等人(2024a)提出一种基于图神经网络的少样本表面缺陷分类方法。该方法通过实例级和分布级的双重图结构提高分类性能,引入类中心特征到特征聚合中,以纠正边缘样本位置,减少未标记样本的影响。图神经网络的训练和推理过程可能需要较高的计算资源,这在处理大规模图数据时尤为明显。

3.2.3 基于大模型的缺陷检测方法

在缺陷检测领域,多种创新方法正在推动非完全标注场景下检测技术的发展,尤其在利用视觉-语言模型(VLM)方面。

CLIP 和 SAM 模型在缺陷检测领域得到了广泛的应用。Jeong 等人(2023)引入一种新的基于窗口的模型 WinCLIP(window-based contrastive language-image pretraining),用于零样本和少样本的异常分类和分割。WinCLIP 组合了提示集合和多尺度特征聚合,这使得它能够有效地进行零样本异常分割。该方法结合语言引导的预测和视觉参考关联,进一步提高了少样本异常识别的准确性。Ji 等人(2024)对 SAM 在多个实际应用场景中的性能进行了全面评估。SAM 作为一个在大规模分割数据集上预训练的通用模型,展示了在缺陷检测等领域的广泛应用潜力。该研究为未来改进 SAM 提供了宝贵的见解。Era 等人(2023)介绍了一种无监督方法,利用 SAM 和视觉变换器基础模型,通过无监督聚类生成提示来实现激光增材制造中孔隙率的实时分割。这项研究的创新之处在于自动化策略的应用,它从数据直接生成提示,提高了实时异常检测的潜力。Chen 等人(2023)提出一种将特定于织物缺陷的专业知识注入 SAM 的方法,通过引入特定参数集,提高了织物缺陷分割的性能。这种方法的创新之处在于无需大量修改现有模型参数,即可实现领域特定知识的集成。Ahmadi 等人(2023)评估了 SAM 和 U-Net 在混凝土结构裂缝检测中的性能。SAM 在检测纵向裂

缝方面表现出独特优势,而U-Net在识别剥落裂缝方面更为准确。Hu等人(2023)提出的DefectSAM利用策划的数据集和专家提示,显著提高了缺陷检测率,减少了漏检,并提供了更精确的缺陷尺寸估计。Zhou等人(2024)通过学习与对象无关的文本提示来适应CLIP模型,实现了不同领域中准确的零样本异常检测,展现了卓越的零样本性能。SAM和CLIP能够实现零样本泛化,但在低对比度或复杂场景中可能需要特定领域的先验知识来支持。

大语言模型(LLM)以及视觉—语言模型(VLM)的卓越泛化能力降低了模型对缺陷标注的依赖。Yong等人(2023)研究了使用视觉—语言预训练模型进行零样本和少样本缺陷检测的提示工程方法。通过优化提示,研究结果表明该方法的检测性能超过了现有的监督模型。Laurençon等人(2024)深入探讨了构建视觉—语言模型(VLM)时的关键决策因素,通过实验对比,发现预训练单模态背骨的进步显著推动了VLM的发展,此外还提出Idefix2,这是一个高效的8亿参数基础VLM,在多模态基准测试中展现出与规模更大的模型相媲美的性能,为VLM的设计和 optimization 提供了新的方向。Wang等人(2024a)提出一个结合了大型语言模型(LLM)和实时对象检测模型Yolo-World的框架,用于零样本异常检测。该框架通过利用LLM和开放词汇对象检测模型的优势,为LLM在视频异常检测和视觉—语言理解方面的应用提供了新的思路。Gu等人(2024)提出AnomalyGPT(anomaly generative pre-trained Transformer),将大型视觉—语言模型进行工业异常检测,通过模拟异常图像和生成文本描述来生成训练数据。AnomalyGPT的创新之处在于其微调方法和多轮对话能力,显著提高了少样本学习能力。Zhu等人(2024)提出一种新型训练自由方法,利用大型语言模型生成异常提示,并引入上下文评分机制,实现精确的异常定位。应用LLM和VLM需要大量的计算资源进行训练和推理,性能很大程度上依赖于预训练数据的质量和多样性,数据不足或偏差可能导致模型性能下降。总体而言,这些方法在CLIP、SAM以及大模型上的创新,不仅提高了缺陷检测的准确性和效率,也为未来在更广泛领域的应用奠定了基础。

3.3 小结

非完全标注的缺陷检测算法在标注策略上可分

为无监督、半监督和弱监督的缺陷检测方法;在任务策略上可分为基于域适应、基于少样本和基于大模型的缺陷检测方法。

4 代表算法在现有数据集的性能

4.1 性能评估指标

与缺陷检测算法一样,非完全标注的缺陷检测算法会根据具体的视觉任务选择合适的指标。分类任务常用的指标准确率(accuracy)以及ROC曲线下的面积(receiver operating characteristic-area under the curve, ROC-AUC)。ROC-AUC指标衡量的是分类器在所有可能的分类阈值下的性能。语义分割任务常用的指标有平均交并比(mean intersection over union, mIoU)。目标检测任务常用指标有平均精确率均值(mean average precision, mAP)。此外,检测效率也是缺陷检测任务中的非常重要的因素,因此也会使用每秒平均帧率(frame per second, FPS)来衡量网络的推理速度。

4.2 性能评估结果

值得注意的是,由于缺陷检测任务和检测场景强相关,因此缺陷检测领域的文献会使用众多数据集验证自己算法的效果。有很多数据集只在对应的工业场景中得到使用,因此本文根据第2节总结的工业场景,统计了现有的前沿代表算法在这些工业场景中的数据集上的模型性能。此外,域适应和少样本的任务以及无监督、半监督和弱监督的场景并非完全独立。为了方便整理,基于标签策略统计数据集的性能,前沿算法的性能统计结果如表4—表6所示。基于任务策略统计前沿算法在数据集上性能统计结果,如表7—表9所示。

首先,可以发现基于深度学习的方法已经成为解决缺陷检测任务的主流趋势,前沿算法都是基于深度学习的方法。深度学习模型能够自动学习缺陷数据中的复杂特征,降低了对专业知识的依赖,并提高了特征提取的效果。同时深度学习模型通过在大量数据上训练,能够学习到泛化的特征,这使得模型能够进行有效的缺陷检测。

同时,相当多的缺陷方法的FPS都很高。观察表4—表6的算法,算法的帧率在20~170帧/s,具有一定的实时性。在实际情况中,缺陷检测模型需要嵌入工厂的生产线上,而工厂生产线上的工业制

表 4 基于无监督的缺陷检测算法性能评测

Table 4 Performance evaluation of defect inspection algorithm based on unsupervised learning

方法	FPS	指标	数据集						
			NEU-DET	Severstal Steel	RSDD	MT	CrackForest	KolektorSSD	DAGM
Wu 等人(2023)	—	mIoU	0.89	0.61	0.87	0.77	—	—	—
Zhang 和 Zhang(2023b)	—	mIoU	—	—	0.86	—	—	—	—
Xu 等人(2022)	3.1	mIoU	—	—	—	—	0.61	0.81	—
Wang 等人(2022d)	—	mIoU	—	—	—	—	—	—	0.92
Wang 等人(2022a)	36.2	Accuracy	—	—	—	—	—	—	1.00
Luo 等人(2023)	24.0	ROC-AUC	—	—	—	—	—	—	0.97

注:加粗字体表示该指标下的最优结果。“—”表示该方法暂无对应指标数据。

表 5 基于半监督的缺陷检测算法性能评测

Table 5 Performance evaluation of defect inspection algorithm based on semi-supervised learning

方法	指标	MVTec AD	数据集									
			DAGM			NEU-seg				KolektorSDD		
			10	30	50	1	10	30	50	5	10	33
Yang 等人(2023)	ROC-AUC	0.99	—	—	—	—	—	—	—	—	—	—
Sime 等人(2023a)	mIoU	—	0.74	0.77	0.80	0.70	0.76	0.78	0.80	—	—	—
Sime 等人(2023b)	mIoU	0.65	0.74	—	—	0.70	0.76	0.79	0.76	—	—	—
Manivannan(2023)	Accuracy	—	—	—	—	—	0.99	0.99	0.99	0.88	1.00	1.00

注:加粗字体表示该指标下的最优结果。“—”表示该方法暂无对应指标数据。DAGM、NEU-seg、KolektorSDD 下的数字表示标注数据占整个数据集的比例。

品的生产速度很快。因此,缺陷检测的算法需要具有一定的实时性,才能够及时找出具有缺陷的产品。

观察表 4—表 6 可知,横向对比不同文献中的算法存在一定的困难,这是因为在缺陷检测领域,目前还没有完全统一的框架,例如通用的数据集、骨干网络以及比较指标等。由于不同场景会产生不同的缺陷数据,很多文献都会选择私有数据集进行研究。虽然公开数据集也会被使用,但是不同算法会选择不同的数据集。同时,缺陷检测任务是直接面向工业场景的计算机视觉任务,随着计算机视觉的发展,不同的算法会选择不同的骨干网络,使得较难区分指标的提升是来源于更优的算法抑或更优的骨干网络。再者,不同的数据集和不同的视觉任务,使得不同文献中应用的指标并不一致。以上几点导致横向对比不同文献中的算法存在一定的困难。

4.3 小结

本节主要论述了非完全标注的缺陷检测模型在

常用的几个公开数据集上的性能评估指标以及主流算法在这些数据集上的性能评测结果。

5 展 望

随着神经网络以及缺陷检测算法的发展,非完全标注的缺陷检测研究也会遇到新的困难,有一些潜在的问题和发展方向值得注意:

1)弱小目标检测问题。小缺陷指的是在图像中占据相对较小面积的缺陷。在缺陷检测任务中,弱小缺陷检测是一个特别具有挑战性的问题。弱小缺陷在图像中可能只占据几个像素,这使得它们很难被传统的图像处理算法以及神经网络模型检测到。由于尺寸小,小目标的特征不明显,容易被背景噪声掩盖。弱小缺陷周围的背景可能非常复杂。例如,工业生产线上,小缺陷可能与产品的正常纹理相似,导致误判。同时,检测效果会受到图像分辨率限制。高分辨率图像可以提供更多的细节,但同时也增加

表 6 基于弱监督的缺陷检测算法性能评测
Table 6 Performance evaluation of defect inspection algorithm based on weak-supervised learning

方法	FPS	指标	数据集					
			KolektorSDD	KolektorSDD2	DAGM	Crack 500	Magnetic-tile	NEU-Seg
Zhang 等人(2024d)	176.9	mIoU	0.84	0.86	—	—	—	—
Yu 和 Guo(2024)	—	mIoU	0.75	—	—	—	0.54	0.86
Qi 等人(2024a)	20.8	mIoU	—	—	—	—	0.65	—
Jiang 等人(2024)	60.1	mIoU	—	0.79	0.79	—	0.65	—
He 等人(2024)	—	Precision	—	—	—	0.70	—	—
Wang 等人(2024c)	—	Precision	—	—	—	0.69	—	—
Xie 等人(2023)	—	ROC-AUC	1.00	—	—	—	—	—
Wang 等人(2023a)	—	mIoU	0.97	0.83	—	—	—	—
Qi 等人(2023)	37.0	mIoU	—	—	0.69	—	0.70	0.74
Li 等人(2023b)	19.2	mAP	0.63	0.57	0.84	—	—	—
Wu 等人(2022b)	—	mIoU	0.69	—	0.80	—	—	—
Niu 等人(2022)	—	mIoU	0.59	—	0.78	—	—	—
König 等人(2022)	—	mAP	—	—	—	0.80	—	—

注:加粗字体表示该指标下的最优结果。“—”表示该方法暂无对应指标数据。

表 7 基于域适应的缺陷检测算法性能评测
Table 7 Performance evaluation of defect inspection algorithm based on domain adaptation method

方法	源域数据集	目标域数据集	指标值	指标
Duan 等人(2023)	DAGM 2007	NEU 数据集	0.88	Accuracy
Ma 等人(2024b)	NEU、RSDD II、FRSD、SD saliency	RSDD I	0.78	mIoU
Ma 等人(2024a)	NEU、RSDD I、SD saliency	RSDD II	0.82	mIoU
Zhang 等人(2023a)	Severstal steel defect dataset	NEU	0.64	mIoU
Wu 等人(2022a)	DAGM 2007	锂离子电池缺陷图像	0.90	Precision
Zhang 等人(2023d)	office-31	轮胎缺陷数据集	0.94	Accuracy
Zhang 等人(2023c)	office-31	轮胎缺陷数据集	0.96	Accuracy
Li 等人(2023a)	9个磁砖制造商的数据	3个磁砖制造商的数据	0.79	mAP
Shi 等人(2023a)	光伏数据集(第一批)	光伏数据集(第2、3批)	0.54	mAP
Ye 等人(2024)	RSDDII	RSDDIIAdjust	0.96	mAP

注:加粗字体表示该指标下的最优结果。

了计算和存储的负担。同时,非完全标注的情况使得弱小目标的检测变得更加困难。小缺陷的标注需要非常精细的工作,这使得获取大量标注数据变得困难和昂贵。在标注数据稀疏的情况下,容易导致训练的模型过拟合。同时,小目标的标注和目标的位置很容易发生大比例的偏移,这些大比例偏移的标注反而会影响模型的检测效果。

在探索弱小目标检测问题时,可以从多个维度进行深入研究和优化。首先,利用自注意力机制或GNN来加强特征融合,从而提升模型捕捉小目标细节的能力。其次,开发半自动化标注工具,如利用SAM等模型进行交互式标注,不仅可以减轻人工标注的负担,还能提高标注的准确性。另外,采用主动学习策略,从未标注数据中筛选出最具代表性和挑

表 8 基于少样本的缺陷检测算法性能评测

Table 8 Performance evaluation of defect inspection algorithm based on few-shot method

方法	指标	数据集					MVTec AD
		NEU-CLS		NEU-DET			
		1 shot	5 shot	5 shot	10 shot	30 shot	
Wang 等人(2022b)	mAP	–	–	0.52	0.58	0.64	–
Sun 等人(2022)	mAP	–	–	0.54	0.56	0.58	–
Xiao 等人(2022)	Accuracy	0.77	0.82				–
Zhao 等人(2024)	Accuracy, mAP	0.97	0.98	0.50	0.50	0.58	–
Duan 等人(2023)	Accuracy	0.88	0.90	–	–	–	–
Pang 等人(2024)	Accuracy	0.88	0.99	–	–	–	–
Zhou 等人(2023)	Accuracy	0.99	0.98	–	–	–	0.99
Hu 等人(2024)	AUC-ROC	–	–	–	–	–	0.91
Xiao 等人(2022)	AUC-ROC	–	–	–	–	–	0.92
Lin 等人(2021)	AUC-ROC	–	–	–	–	–	0.78
Sheynin 等人(2021)	AUC-ROC	–	–	–	–	–	0.95

注:加粗字体表示该指标下的最优结果。“–”表示该方法暂无对应指标数据。NEU-CLS与NEU-DET下的数字表示训练模型的每类图片数。

表 9 基于大模型的缺陷检测算法性能评测

Table 9 Performance evaluation of defect inspection algorithm based on large models

方法	方法类别	数据集	是否开源	指标值	指标
Era 等人(2023)	SAM-based	钴铬合金图像	未开源	0.82	Dice Similarity Coefficient (DSC)
Chen 等人(2023)	VLM-based	Fabric Stain dataset	开源	0.76	mIoU
Chen 等人(2023)	VLM-based	Self-collected	未开源	0.58	mIoU
Zhu 等人(2024)	LLM-based	MVTec	开源	0.93	AUROC
Gu 等人(2024)	VLM-based	MVTec	开源	0.94	AUROC
Zhou 等人(2024)	CLIP-based	MVTec	开源	0.91	AUROC

注:加粗字体表示该指标下的最优结果。DSC为评估预测结果与真实结果相似度的指标,值越高越好。

战性的样本进行标注,这将显著提升标注的效率和数据的质量。

2)伪标签可靠性问题。在缺陷检测领域,高效地利用未标注的缺陷图像是一个充满挑战且技术性极强的问题。特别是在半监督和弱监督学习的场景中,生成伪标签以利用这些未标注数据成为一种常见的策略。然而,生成高质量的伪标签是一项极具挑战性的任务,因为在模型训练的早期阶段,其准确性往往不足,这可能导致生成的伪标签包含大量噪声。例如,背景区域可能被错误地识别为缺陷区域,

而实际的缺陷区域则可能被忽略或被错误地分类。此外,在生成用于检测任务的伪标签时,还存在着分类置信度和定位质量不匹配的问题。这种不匹配可能导致筛选出的伪标签不够准确,从而影响模型的训练效果。随着训练过程的进行,这些噪声的累积可能会逐渐削弱模型的整体性能。因此,精确评估伪标签的准确性,赋予模型自我修正的能力,并增强模型对噪声标签的鲁棒性,构成了缺陷检测领域中值得深入探究的方向。

解决伪标签的可靠性问题,需要通过多模型和

多视角融合以及不一致性检测与修正的方法。具体来说,可以利用不同架构或不同初始化的多个模型来生成伪标签,并通过集成学习方法来提高这些伪标签的一致性。同时,通过对同一数据进行多次预测并取其共识结果作为伪标签,进一步增强其可靠性。此外,通过数据增强技术生成多视角的输入图像,并将这些多视角的伪标签进行融合,可以有效提高伪标签的整体可靠性。另外,可以引入一致性正则化策略,对比同一图像的不同增强版本生成的伪标签,确保其一致性,减少噪声。

3)大模型的知识迁移问题。在缺陷检测领域,尽管大语言模型和视觉语言模型(如基于深度学习的图像识别和处理模型)展现出巨大的潜力,但它们在实际应用中仍面临一些挑战。大规模、高质量的标注数据是训练有效大模型的基础。然而,在缺陷检测中获取精确标注的数据集非常困难且成本高昂。尤其是在工业环境中,缺陷类型多样且复杂,标注工作需要专业知识。另一方面,尽管大模型在特定任务上表现出色,但它们往往在泛化到新的、未见过的数据上时表现不佳。工业环境中的缺陷类型和背景可能与训练数据差异较大,直接使用大模型效果并不好。如何利用少量的标注将大模型内的知识高效泛化到工业检测领域,是利用大语言模型和视觉语言模型的关键。

应对大模型的知识迁移挑战,可以采取以下方法进行探索。首先,通过精细调整大模型,结合当前的缺陷数据和领域自适应技术,利用对抗训练和领域对齐等先进技术,确保模型在新的应用场景中维持其卓越的性能。进一步地,可以融合领域专家的丰富知识,构建一套基于规则的系统,以辅助大模型进行更为精准的缺陷检测。例如,通过在模型的输出结果中融入专家的规则,能够显著提升模型的准确性和可靠性。此外,通过精心设计的人机协作系统,促进模型与人工智能专家之间的协同工作,共同完成缺陷检测任务。在这个系统中,大模型负责识别和处理大部分常见缺陷,而对于那些复杂和罕见的缺陷,人类专家将发挥其不可替代的作用,进行深入分析和处理。

6 结 语

本文全面梳理回顾了非完全标注的缺陷检测的

研究进展,简要总结了该任务的基本概念、数据集、相关技术及未来发展趋势。在此基础上,本文详细介绍了基于无监督、半监督、弱监督、域适应、小样本以及大模型的缺陷检测算法,并在多个缺陷数据集上对比了前沿算法的性能。非完全标注的缺陷检测任务是工业界经常会遇到的场景,具有重要的研究意义和应用价值,值得工业界和学术界更多的关注和推动。

参考文献(References)

- Ahmadi M, Lonbar A G, Sharifi A, Beris A T, Nouri M and Javidi A S. 2023. Application of segment anything model for civil infrastructure defect assessment [EB/OL]. [2024-03-17].
<https://arxiv.org/pdf/2304.12600v1.pdf>
- Ai J S, Chen S H, Deng P, Bai L B, Tian L L and Zhang J. 2020. CycleGANs for semi-supervised defects segmentation//Proceedings of 2020 International Conference on Sensing, Measurement and Data Analytics in the era of Artificial Intelligence. Xi'an, China: IEEE: 611-616 [DOI: 10.1109/ICSMDS0554.2020.9261743]
- Bao Y Q, Song K C, Liu J, Wang Y Y, Yan Y H, Yu H and Li X J. 2021. Triplet-graph reasoning network for few-shot metal generic surface defect segmentation. IEEE Transactions on Instrumentation and Measurement, 70: #5011111 [DOI: 10.1109/TIM. 2021. 3083561]
- Bergmann P, Fauser M, Sattlegger D and Steger C. 2019a. MVTec AD — A comprehensive real-world dataset for unsupervised anomaly detection//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 9584-9592 [DOI: 10.1109/CVPR.2019.00982]
- Bergmann P, Löwe S, Fauser M, Sattlegger D and Steger C. 2019b. Improving unsupervised defect segmentation by applying structural similarity to autoencoders//Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications. Prague, Czech Republic: SciTePress: 372-380 [DOI: 10.5220/0007364503720380]
- Carrera D, Manganini F, Boracchi G and Lanzarone E. 2017. Defect detection in SEM images of nanofibrous materials. IEEE Transactions on Industrial Informatics, 13(2): 551-561 [DOI: 10.1109/TII.2016.2641472]
- Chen L L Y, Li K S M, Jiang X H, Wang S J, Huang A Y A, Chen J E, Liang H C and Hsu C L. 2021. Semi-supervised framework for wafer defect pattern recognition with enhanced labeling//Proceedings of 2021 IEEE International Test Conference. Anaheim, USA: IEEE: 208-212 [DOI: 10.1109/ITC50571.2021.00029]
- Chen Z W, Wong W K, Zhong Z F, Liao J P and Qu Y. 2023. Effective transfer of pretrained large visual model for fabric defect segmenta-

- tion via specific knowledge injection [EB/OL]. [2024-03-17].
<http://arxiv.org/pdf/2306.16186.pdf>
- Cheng D P, Sha W X, Xu Z, Li S D, Yin Z G, Lang Y L, Tang S and Cao Y C. 2023. AtomGAN: unsupervised deep learning for fast and accurate defect detection of 2D materials at the atomic scale. *Science China Information Sciences*, 66 (6) : #160410 [DOI: 10.1007/s11432-022-3757-x]
- Cheng J H, Guo B, Liu J Q, Liu S C, Wu G Z, Sun Y Q and Yu Z W. 2021. TL-SDD: a transfer learning-based method for surface defect detection with few samples//*Proceedings of the 7th International Conference on Big Data Computing and Communications*. Deqing, China: IEEE: 136-143 [DOI: 10.1109/BigCom53800.2021.00023]
- de Vitis G A, Foglia P and Prete C A. 2020. Row-level algorithm to improve real-time performance of glass tube defect detection in the production phase. *IET Image Processing*, 14 (12) : 2911-2921 [DOI: 10.1049/iet-ipr.2019.1506]
- Deutsch S, Christlein V, Berger S, Buerhop-Lutz C, Maier A, Gallwitz F and Riess C. 2019. Automatic classification of defective photovoltaic module cells in electroluminescence images. *Solar Energy*, 185: 455-468 [DOI: 10.1016/j.solener.2019.02.067]
- Deng Y B and Song Y H. 2023. Few-shot steel plate surface defect detection with multi-relation aggregation and adaptive support learning. *ISIJ International*, 63(10) : 1727-1737 [DOI: 10.2355/isijinternational.ISIJINT-2023-118]
- Ding R W, Dai L H, Li G P and Liu H. 2019. TDD-net: a tiny defect detection network for printed circuit boards. *CAAI Transactions on Intelligence Technology*, 4(2) : 110-116 [DOI: 10.1049/trit.2019.0019]
- Duan G F, Song Y G, Liu Z Y, Ling S Q and Tan J R. 2023. Cross-domain few-shot defect recognition for metal surfaces. *Measurement Science and Technology*, 34(1) : #015202 [DOI: 10.1088/1361-6501/ac90de]
- Era I Z, Ahmed I, Liu Z C and Das S. 2023. An unsupervised approach towards promptable defect segmentation in laser-based additive manufacturing by segment anything [EB/OL]. [2024-03-17].
<http://arxiv.org/pdf/2312.04063.pdf>
- Fridman Y, Rusanovsky M T and Oren G. 2021. ChangeChip: a reference-based unsupervised change detection for PCB defect detection//*Proceedings of 2021 IEEE Physical Assurance and Inspection of Electronics*. Washington, USA: IEEE: 1-8 [DOI: 10.1109/PAINE54418.2021.9707699]
- Gan J R, Li Q Y, Wang J Z and Yu H M. 2017. A hierarchical extractor-based visual rail surface inspection system. *IEEE Sensors Journal*, 17(23) : 7935-7944 [DOI: 10.1109/JSEN.2017.2761858]
- Gao Y P, Gao L, Li X Y and Yan X G. 2020. A semi-supervised convolutional neural network-based method for steel surface defect recognition. *Robotics and Computer-Integrated Manufacturing*, 61: #101825 [DOI: 10.1016/j.rcim.2019.101825]
- Gu Z P, Zhu B K, Zhu G B, Chen Y Y, Tang M and Wang J Q. 2024. AnomalyGPT: detecting industrial anomalies using large vision-language models//*Proceedings of the 38th AAAI Conference on Artificial Intelligence*. Vancouver, Canada: AAAI Press: 1932-1940 [DOI: 10.1609/aaai.v38i3.27963]
- Guo W and Jiang P Y. 2024. Weakly supervised anomaly detection with privacy preservation under a bi-level federated learning framework. *Expert Systems with Applications*, 254: #124450 [DOI: 10.1016/j.eswa.2024.124450]
- Guo Y J, Zhong L W, Qiu Y, Wang H W, Gao F Q, Wen Z H and Zhan C J. 2022. Using ISU-GAN for unsupervised small sample defect detection. *Scientific Reports*, 12 (1) : #11604 [DOI: 10.1038/s41598-022-15855-7]
- Hamdi A A, Sayed M S, Fouad M M and Hadhoud M M. 2018. Unsupervised patterned fabric defect detection using texture filtering and k-means clustering//*Proceedings of 2018 International Conference on Innovative Trends in Computer Engineering*. Aswan, Egypt: IEEE: 130-144 [DOI: 10.1109/ITCE.2018.8316611]
- He D, Xu K, Zhou P and Zhou D D. 2019a. Surface defect classification of steels with a new semi-supervised learning method. *Optics and Lasers in Engineering*, 117: 40-48 [DOI: 10.1016/j.optlaseng.2019.01.011]
- He K K, Liu X T, Liu J and Wu P. 2021. A multitask learning-based neural network for defect detection on textured surfaces under weak supervision. *IEEE Transactions on Instrumentation and Measurement*, 70: #5016914 [DOI: 10.1109/TIM.2021.3112784]
- He T J, Li H E, Qian Z D, Niu C Y and Huang R H. 2024. Research on weakly supervised pavement crack segmentation based on defect location by generative adversarial network and target re-optimization. *Construction and Building Materials*, 411: #134668 [DOI: 10.1016/j.conbuildmat.2023.134668]
- He Y, Song K C, Dong H W and Yan Y H. 2019b. Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network. *Optics and Lasers in Engineering*, 122: 294-302 [DOI: 10.1016/j.optlaseng.2019.06.020]
- He Y, Song K C, Meng Q G and Yan Y H. 2020. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features. *IEEE Transactions on Instrumentation and Measurement*, 69(4) : 1493-1504 [DOI: 10.1109/tim.2019.2915404]
- Hu B Z, Gao B, Tan C, Wu T L and Li S Z. 2023. Segment anything in defect detection [EB/OL]. [2024-03-17].
<http://arxiv.org/pdf/2311.10245.pdf>
- 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 T, Zhang J N, Yi R, Du Y Z, Chen X, Liu L, Wang Y B and Wang C J. 2024. AnomalyDiffusion: few-shot anomaly image generation with diffusion model//*Proceedings of the 38th AAAI Conference on*

- Artificial Intelligence. Vancouver, Canada: AAAI Press: 8526-8534 [DOI: 10.1609/aaai.v38i8.28696]
- Hu Y D, Liu R N, Li X L, Chen D Y and Hu Q H. 2022. Task-sequencing meta learning for intelligent few-shot fault diagnosis with limited data. *IEEE Transactions on Industrial Informatics*, 18(6): 3894-3904 [DOI: 10.1109/TII.2021.3112504]
- Huang C, Chen M H and Wang L. 2024. Semi-supervised surface defect detection of wind turbine blades with YOLOv4. *Global Energy Interconnection*, 7(3): 284-292 [DOI: 10.1016/j.gloi.2024.06.010]
- Huang Y B, Qiu C Y and Yuan K. 2020. Surface defect saliency of magnetic tile. *The Visual Computer*, 36(1): 85-96 [DOI: 10.1007/s00371-018-1588-5]
- Huang Y Y, Liu B G, Dong H C, Lu B H, Jiang Y H and Liu G D. 2023. A novel weakly supervised learning method for industrial surface defect detection//*Proceedings of the 6th International Conference on Artificial Intelligence and Big Data*. Chengdu, China: IEEE: 741-745 [DOI: 10.1109/ICAIBD57115.2023.10206091]
- Jain S, Seth G, Paruthi A, Soni U and Kumar G. 2022. Synthetic data augmentation for surface defect detection and classification using deep learning. *Journal of Intelligent Manufacturing*, 33(4): 1007-1020 [DOI: 10.1007/s10845-020-01710-x]
- Jamali A, Laflamme C, Huber R and Hammad A M. 2023. Pavement defect classification and localization using weakly supervised deep learning//*Proceedings of 2023 Creative Construction Conference*. Keszthely, Hungary: Budapest University of Technology and Economics: 506-514 [DOI: 10.3311/CCC2023-067]
- Jeong J, Zou Y, Kim T, Zhang D Q, Ravichandran A and Dabeer O. 2023. WinCLIP: zero-/few-shot anomaly classification and segmentation//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada: IEEE: 19606-19616 [DOI: 10.1109/CVPR52729.2023.01878]
- Ji W, Li J J, Bi Q, Liu T W, Li W B and Cheng L. 2024. Segment anything is not always perfect: an investigation of SAM on different real-world applications. *Machine Intelligence Research*, 21(4): 617-630 [DOI: 10.1007/s11633-023-1385-0]
- Jiang L L, Wang Y X, Tang Z H, Miao Y L and Chen S Y. 2021. Casting defect detection in x-ray images using convolutional neural networks and attention-guided data augmentation. *Measurement*, 170: #108736 [DOI: 10.1016/j.measurement.2020.108736]
- Jiang X H, Feng J, Yan F, Lu Y, Fa Q H, Zhang W J and Xu M L. 2024. Foreground-background separation transformer for weakly supervised surface defect detection. *Journal of Intelligent Manufacturing*, 1: 1-16 [DOI: 10.1007/s10845-024-02446-8]
- Jing F W, Zhang M Y, Li J, Xu G Z and Wang J. 2022. Coil shape defects prediction algorithm for hot strip rolling based on Siamese semi-supervised DAE-CNN model. *Assembly Automation*, 42(6): 773-781 [DOI: 10.1108/AA-07-2022-0179]
- Kasahara J Y L, Fujii H, Yamashita A and Asama H. 2021. Weakly supervised acoustic defect detection in concrete structures using clustering-based augmentation. *IEEE/ASME Transactions on Mechatronics*, 26(6): 2826-2834 [DOI: 10.1109/TMECH.2021.307-7496]
- König J, Jenkins M D, Mannion M, Barrie P and Morison G. 2022. Weakly-supervised surface crack segmentation by generating pseudo-labels using localization with a classifier and thresholding. *IEEE Transactions on Intelligent Transportation Systems*, 23(12): 24083-24094 [DOI: 10.1109/TITS.2022.3204853]
- Koulali I and Eskil M T. 2021. Unsupervised textile defect detection using convolutional neural networks. *Applied Soft Computing*, 113: #107913 [DOI: 10.1016/j.asoc.2021.107913]
- Kuric I, Klarák J, Sága M, Císar M, Hajdučík A and Wiecek D. 2021. Analysis of the possibilities of tire-defect inspection based on unsupervised learning and deep learning. *Sensors*, 21(21): #7073 [DOI: 10.3390/s21217073]
- Laurençon H, Tronchon L, Cord M and Sanh V. 2024. What matters when building vision-language models? [EB/OL]. [2024-07-11]. <https://arxiv.org/pdf/2405.02246.pdf>
- Lee H and Kim H. 2020. Semi-supervised multi-label learning for classification of wafer bin maps with mixed-type defect patterns. *IEEE Transactions on Semiconductor Manufacturing*, 33(4): 653-662 [DOI: 10.1109/TSM.2020.3027431]
- Lee X Y, Vidyaratne L, Alam M, Farahat A, Ghosh D, Diaz T G and Gupta C. 2023. XDNet: a few-shot meta-learning approach for cross-domain visual inspection//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Vancouver, Canada: IEEE: 4375-4384 [DOI: 10.1109/CVPRW59228.2023.00460]
- Li C, Yan H X, Qian X, Zhu S D, Zhu P Y A, Liao C W, Tian H Y, Li X, Wang X H and Li X H. 2023a. A domain adaptation yolov5 model for industrial defect inspection. *Measurement*, 213: #112725 [DOI: 10.1016/j.measurement.2023.112725]
- Li K S M, Jiang X H, Chen L L Y, Wang S J, Huang A Y A, Chen J E, Liang H C and Hsu C L. 2022a. Wafer defect pattern labeling and recognition using semi-supervised learning. *IEEE Transactions on Semiconductor Manufacturing*, 35(2): 291-299 [DOI: 10.1109/TSM.2022.3159246]
- Li L F, Ma W F, Li L and Lu C. 2019. Research on detection algorithm for bridge cracks based on deep learning. *Acta Automatica Sinica*, 45(9): 1727-1742 (李良福, 马卫飞, 李丽, 陆铖. 2019. 基于深度学习的桥梁裂缝检测算法研究. *自动化学报*, 45(9): 1727-1742) [DOI: 10.16383/j.aas.2018.c170052]
- Li S B, Yang J, Wang Z, Zhu S D and Yang G C. 2020. Review of development and application of defect detection technology. *Acta Automatica Sinica*, 46(11): 2319-2336 (李少波, 杨静, 王铮, 朱书德, 杨观赐. 2020. 缺陷检测技术的发展与应用研究综述. *自动化学报*, 46(11): 2319-2336) [DOI: 10.16383/j.aas.c180538]
- Li Y M, Wu X J, Li P and Liu Y H. 2023b. Ferrite beads surface defect

- detection based on spatial attention under weakly supervised learning. *IEEE Transactions on Instrumentation and Measurement*, 72: #2506812 [DOI: 10.1109/TIM.2023.3246499]
- Li Y T, Bao T F, Xu B, Shu X S, Zhou Y H, Du Y, Wang R J and Zhang K. 2022b. A deep residual neural network framework with transfer learning for concrete dams patch-level crack classification and weakly-supervised localization. *Measurement*, 188: #110641 [DOI: 10.1016/j.measurement.2021.110641]
- Lin D Y, Cao Y P, Zhu W B and Li Y Q. 2021. Few-shot defect segmentation leveraging abundant defect-free training samples through normal background regularization and crop-and-paste operation//*Proceedings of 2021 IEEE International Conference on Multimedia and Expo*. Shenzhen, China: IEEE: 1-6 [DOI: 10.1109/ICME51207.2021.9428468]
- Liu J, Song K C, Feng M Z, Yan Y H, Tu Z B and Zhu L. 2021. Semi-supervised anomaly detection with dual prototypes autoencoder for industrial surface inspection. *Optics and Lasers in Engineering*, 136: #106324 [DOI: 10.1016/j.optlaseng.2020.106324]
- Liu J H, Guo F, Zhang Y, Hou B K and Zhou H M. 2022. Defect classification on limited labeled samples with multiscale feature fusion and semi-supervised learning. *Applied Intelligence*, 52(7): 8243-8258 [DOI: 10.1007/s10489-021-02917-y]
- Liu J Q, Xie G Y, Wang J B, Li S N, Wang C J, Zheng F and Jin Y C. 2024. Deep industrial image anomaly detection: a survey. *Machine Intelligence Research*, 21(1): 104-135 [DOI: 10.1007/s11633-023-1459-z]
- Liu L, Zhang J H, Fu X D, Liu L J and Huang Q S. 2019. Unsupervised segmentation and elm for fabric defect image classification. *Multimedia Tools and Applications*, 78(9): 12421-12449 [DOI: 10.1007/s11042-018-6786-7]
- Liu T and Ye W. 2022. A semi-supervised learning method for surface defect classification of magnetic tiles. *Machine Vision and Applications*, 33(2): #35 [DOI: 10.1007/s00138-022-01286-x]
- Liu W Q, Liu Z G, Wang H and Han Z W. 2020. An automated defect detection approach for catenary rod-insulator textured surfaces using unsupervised learning. *IEEE Transactions on Instrumentation and Measurement*, 69(10): 8411-8423 [DOI: 10.1109/tim.2020.2987503]
- Liu Z Y, Song Y G, Tang R N, Duan G F and Tan J R. 2023. Few-shot defect recognition of metal surfaces via attention-embedding and self-supervised learning. *Journal of Intelligent Manufacturing*, 34(8): 3507-3521 [DOI: 10.1007/s10845-022-02022-y]
- Lu R S, Wu A, Zhang T D and Wang Y H. 2018. Review on automated optical (visual) inspection and its applications in defect detection. *Acta Optica Sinica*, 38(8): #0815002 (卢荣胜, 吴昂, 张腾达, 王永红. 自动光学(视觉)检测技术及其在缺陷检测中的应用综述. *光学学报*, 38(8): #0815002 [DOI: 10.3788/aos201838.0815002])
- Luo W, Niu T Z, Yao H M, Tang L X, Yu W Y and Li B. 2023. Unsupervised defect segmentation via forgetting-inputting-based feature fusion and multiple hierarchical feature difference. *IEEE Sensors Journal*, 23(13): 14448-14459 [DOI: 10.1109/JSEN.2023.3276762]
- Lyu C K, Zhang Z T, Shen F and Zhang F. 2023. Unsupervised automatic defect inspection based on image matching and local one-class classification//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Vancouver, Canada: IEEE: 4435-4444 [DOI: 10.1109/CVPRW59228.2023.00466]
- Ma S, Song K C, Niu M H, Tian H K, Wang Y Y and Yan Y H. 2023. Shape-consistent one-shot unsupervised domain adaptation for rail surface defect segmentation. *IEEE Transactions on Industrial Informatics*, 19(9): 9667-9679 [DOI: 10.1109/TII.2022.3233654]
- Ma S, Song K C, Niu M H, Tian H K, Wang Y Y and Yan Y H. 2024a. Feature-based domain disentanglement and randomization: a generalized framework for rail surface defect segmentation in unseen scenarios. *Advanced Engineering Informatics*, 59: #102274 [DOI: 10.1016/j.aei.2023.102274]
- Ma S, Song K C, Niu M H, Tian H K and Yan Y H. 2024b. Cross-scale fusion and domain adversarial network for generalizable rail surface defect segmentation on unseen datasets. *Journal of Intelligent Manufacturing*, 35(1): 367-386 [DOI: 10.1007/s10845-022-02051-7]
- Maeda H, Sekimoto Y, Seto T, Kashiya T and Omata H. 2018. Road damage detection and classification using deep neural networks with smartphone images. *Computer-Aided Civil and Infrastructure Engineering*, 33(12): 1127-1141 [DOI: 10.1111/mice.12387]
- Manivannan S. 2023. Automatic quality inspection in additive manufacturing using semi-supervised deep learning. *Journal of Intelligent Manufacturing*, 34(7): 3091-3108 [DOI: 10.1007/s10845-022-02000-4]
- Manivannan S. 2024. Semi-supervised imbalanced classification of wafer bin map defects using a dual-head CNN. *Expert Systems with Applications*, 238: #122301 [DOI: 10.1016/j.eswa.2023.122301]
- Marino S, Beuseroy P and Smolarz A. 2019. Weakly-supervised learning approach for potato defects segmentation. *Engineering Applications of Artificial Intelligence*, 85: 337-346 [DOI: 10.1016/j.engappai.2019.06.024]
- Marino S, Beuseroy P and Smolarz A. 2020. Unsupervised adversarial deep domain adaptation method for potato defects classification. *Computers and Electronics in Agriculture*, 174: #105501 [DOI: 10.1016/j.compag.2020.105501]
- Mei S, Yang H and Yin Z P. 2018. An unsupervised-learning-based approach for automated defect inspection on textured surfaces. *IEEE Transactions on Instrumentation and Measurement*, 67(6): 1266-1277 [DOI: 10.1109/TIM.2018.2795178]
- Mery D, Rizzo V, Zscherpel U, Mondragón G, Lillo I, Zuccar I, Lobel H and Carrasco M. 2015. GDXray: the database of X-ray images for nondestructive testing. *Journal of Nondestructive Evaluation*,

- 34(4): #42 [DOI: 10.1007/s10921-015-0315-7]
- Min Y Z and Li Y X. 2022. Self-supervised railway surface defect detection with defect removal variational autoencoders. *Energies*, 15(10): #3592 [DOI: 10.3390/en15103592]
- Min Y Z, Wang Z W, Liu Y and Wang Z. 2023. FS-RSDD: few-shot rail surface defect detection with prototype learning. *Sensors*, 23(18): #7894 [DOI: 10.3390/s23187894]
- Minhas M S and Zelek J. 2020. Semi-supervised anomaly detection using AutoEncoders [EB/OL]. [2024-07-11].
<http://arxiv.org/pdf/2001.03674.pdf>
- Minhas M S and Zelek J S. 2019. AnoNet: weakly supervised anomaly detection in textured surfaces [EB/OL]. [2024-07-11].
<https://arxiv.org/pdf/1911.10608.pdf>
- Mujeeb A, Dai W T, Erdt M and Sourin A. 2018. Unsupervised surface defect detection using deep autoencoders and data augmentation// *Proceedings of 2018 International Conference on Cyberworlds*. Singapore, Singapore: IEEE: 391-398 [DOI: 10.1109/cw.2018.00076]
- Nie M, Jiang W, Yang W K, Wang S L, Wen X Q and Ni T M. 2023. Enhancing defect diagnosis and localization in wafer map testing through weakly supervised learning//*Proceedings of 2023 IEEE 32nd Asian Test Symposium*. Beijing, China: IEEE: 1-6 [DOI: 10.1109/ATS59501.2023.10317989]
- Niu M H, Song K C, Huang L M, Wang Q, Yan Y H and Meng Q G. 2021. Unsupervised saliency detection of rail surface defects using stereoscopic images. *IEEE Transactions on Industrial Informatics*, 17(3): 2271-2281 [DOI: 10.1109/tii.2020.3004397]
- Niu S L, Li B, Wang X G, He S P and Peng Y R. 2022. Defect attention template generation cycleGAN for weakly supervised surface defect segmentation. *Pattern Recognition*, 123: #108396 [DOI: 10.1016/j.patcog.2021.108396]
- Ozdemir R and Koc M. 2024. on the enhancement of semi-supervised deep learning-based railway defect detection using pseudo-labels. *Expert Systems with Applications*, 251: #124105 [DOI: 10.1016/j.eswa.2024.124105]
- Pang S C, Zhao W S, Wang S D, Zhang L and Wang S. 2024. Permute-MAML: exploring industrial surface defect detection algorithms for few-shot learning. *Complex and Intelligent Systems*, 10(1): 1473-1482 [DOI: 10.1007/s40747-023-01219-9]
- Park J E and Kim Y K. 2025. Semi-supervised learning for steel surface inspection using magnetic flux leakage signal. *Journal of Intelligent Manufacturing*, 36(2): 1021-1031 [DOI: 10.1007/s10845-023-02286-y]
- Peng C Q, Zhao L, Wang S, Abbas Z, Liang F and Islam M S. 2024. LightFlow: lightweight unsupervised defect detection based on 2-D flow. *IEEE Transactions on Instrumentation and Measurement*, 73: #2521912 [DOI: 10.1109/TIM.2024.3415769]
- Phalawan L, Phisanbut N and Piamsa-nga P. 2023. A weakly-supervised glass bottle defect detection system based on multi-view analysis// *Proceedings of the 20th International Joint Conference on Computer Science and Software Engineering*. Phitsanulok, Thailand: IEEE: 79-83 [DOI: 10.1109/JCSSE58229.2023.10201963]
- Qi H C, Cheng L, Kong X W, Zhang J Q and Gu J Y. 2024a. WDLS: deep level set learning for weakly supervised aeroengine defect segmentation. *IEEE Transactions on Industrial Informatics*, 20(1): 303-313 [DOI: 10.1109/TII.2023.3261889]
- Qi H C, Kong X W, Liu Z T, Gu J Y and Cheng L. 2024b. SAIT: harnessing sparse annotations and intrinsic tasks for semisupervised aeroengine defect segmentation. *IEEE Transactions on Industrial Informatics*, 20(8): 10463-10472 [DOI: 10.1109/TII.2024.3396550]
- Qi H C, Kong X W, Shen Z A, Liu Z T and Gu J Y. 2023. Progressively learning dynamic level set for weakly supervised industrial defect segmentation. *IEEE Transactions on Instrumentation and Measurement*, 72: #5026814 [DOI: 10.1109/TIM.2023.3316271]
- Rasheed A, Zafar B, Rasheed A, Ali N, Sajid M, Dar S H, Habib U, Shehryar T and Mahmood M T. 2020. Fabric defect detection using computer vision techniques: a comprehensive review. *Mathematical Problems in Engineering*, 2020: #8189403 [DOI: 10.1155/2020/8189403]
- Rudolph M, Wandt B and Rosenhahn B. 2021. Same same but DifferNet: semi-supervised defect detection with normalizing flows// *Proceedings of 2021 IEEE Winter Conference on Applications of Computer Vision*. Waikoloa, USA: IEEE: 1906-1915 [DOI: 10.1109/WACV48630.2021.00195]
- Sae-Ang B I, Kumwilaisak W and Kaewtrakulpong P. 2022. Semi-supervised learning for defect segmentation with autoencoder auxiliary module. *Sensors*, 22(8): #2915 [DOI: 10.3390/s22082915]
- Shao L H, Zhang E H, Ma Q R and Li M. 2022. Pixel-wise semisupervised fabric defect detection method combined with multitask mean teacher. *IEEE Transactions on Instrumentation and Measurement*, 71: #2506011 [DOI: 10.1109/TIM.2022.3162286]
- Sheynin S, Benaïm S and Wolf L. 2021. A hierarchical transformation-discriminating generative model for few shot anomaly detection// *Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, Canada: IEEE: 8475-8484 [DOI: 10.1109/ICCV48922.2021.00838]
- Shi S J, Tan J H and Chen H Y. 2023a. Dynamic domain adaptation object detection for photovoltaic cell defects//*Proceedings of the 42nd Chinese Control Conference*. Tianjin, China: IEEE: 6903-6907 [DOI: 10.23919/CCC58697.2023.10241054]
- Shi Y, Cui L M, Qi Z Q, Meng F and Chen Z S. 2016. Automatic road crack detection using random structured forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(12): 3434-3445 [DOI: 10.1109/TITS.2016.2552248]
- Shi Y D, Wang H M, Jing C and Zhang X Z. 2023b. A few-shot defect detection method for transmission lines based on meta-attention and feature reconstruction. *Applied Sciences*, 13(10): #5896 [DOI:

- 10.3390/app13105896]
- Silvestre-Blanes J, Alberro-Albero T, Miralles I, Pérez-Llorens R and Moreno J. 2019. A public fabric database for defect detection methods and results. *Autex Research Journal*, 19(4): 363-374 [DOI: 10.2478/aut-2019-0035]
- Sime D M, Wang G T, Zeng Z and Peng B. 2023a. Uncertainty-aware and dynamically-mixed pseudo-labels for semi-supervised defect segmentation. *Computers in Industry*, 152: #103995 [DOI: 10.1016/j.compind.2023.103995]
- Sime D M, Wang G T, Zeng Z, Wang W and Peng B. 2023b. Semisupervised defect segmentation with pairwise similarity map consistency and ensemble-based cross pseudolabels. *IEEE Transactions on Industrial Informatics*, 19(9): 9535-9545 [DOI: 10.1109/tii.2022.3230785]
- Simmler N, Sager P, andermatt P, Chavarriaga R, Schilling F P, Rosenthal M and Stadelmann T. 2021. A survey of un-, weakly-, and semi-supervised learning methods for noisy, missing and partial labels in industrial vision applications//*Proceedings of the 8th Swiss Conference on Data Science*. Lucerne, Switzerland: IEEE: 26-31 [DOI: 10.1109/SDS51136.2021.00012]
- Song K C and Yan Y H. 2013. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects. *Applied Surface Science*, 285: 858-864 [DOI: 10.1016/j.apsusc.2013.09.002]
- Song G R, Song K C and Yan Y H. 2020. Saliency detection for strip steel surface defects using multiple constraints and improved texture features. *Optics and Lasers In Engineering*, 128: #106000 [DOI: 10.1016/j.optlaseng.2019.106000]
- Song Y G, Liu Z Y, Ling S Q, Tang R N, Duan G F and Tan J R. 2022. Coarse-to-fine few-shot defect recognition with dynamic weighting and joint metric. *IEEE Transactions on Instrumentation and Measurement*, 71: #2514910 [DOI: 10.1109/TIM.2022.3193204]
- Song Y G, Liu Z Y, Wang J H, Tang R N, Duan G F and Tan J R. 2021. Multiscale adversarial and weighted gradient domain adaptive network for data scarcity surface defect detection. *IEEE Transactions on Instrumentation and Measurement*, 70: #5012810 [DOI: 10.1109/tim.2021.3096284]
- Sresakoolchai J and Kaewunruen S. 2022. Railway defect detection based on track geometry using supervised and unsupervised machine learning. *Structural Health Monitoring*, 21(4): 1757-1767 [DOI: 10.1177/14759217211044492]
- Sun C, Gao L, Li X Y and Gao Y P. 2022. A new knowledge distillation network for incremental few-shot surface defect detection [EB/OL]. [2024-08-22]. <https://arxiv.org/pdf/2209.00519.pdf>
- Szarski M and Chauhan S. 2022. An unsupervised defect detection model for a dry carbon fiber textile. *Journal of Intelligent Manufacturing*, 33(7): 2075-2092 [DOI: 10.1007/s10845-022-01964-7]
- Tabernik D, Šela S, Skvarč J and Škočaj 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]
- Taherkhani K, Eischer C and Toyserkani E. 2022. An unsupervised machine learning algorithm for in-situ defect-detection in laser powder-bed fusion. *Journal of Manufacturing Processes*, 81: 476-489 [DOI: 10.1016/j.jmapro.2022.06.074]
- Tang B, Kong J Y, Wu S Q. 2017. Review of surface defect detection based on machine vision. *Journal of Image and Graphics*, 22(12): 1640-1663 (汤勃, 孔建益, 伍世虔. 2017. 机器视觉表面缺陷检测综述. *中国图象图形学报*, 22(12): 1640-1663) [DOI: 10.11834/jig.160623]
- Tang S L, He F, Huang X L and Yang J. 2019. Online PCB defect detector on a new PCB defect dataset [EB/OL]. [2024-07-08]. <http://arxiv.org/pdf/1902.06197.pdf>
- 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]
- Tao X, Zhang D P, Wang Z H, Liu X L, Zhang H Y and Xu D. 2020. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 50(4): 1486-1498 [DOI: 10.1109/TSMC.2018.2871750]
- Volkau I, Mujeeb A, Wenting D, Marius E and Alexei S. 2019. Detection defect in printed circuit boards using unsupervised feature extraction upon transfer learning//*Proceedings of 2019 International Conference on Cyberworlds*. Kyoto, Japan: IEEE: 101-108 [DOI: 10.1109/CW.2019.00025]
- Wan Y S, Gao L, Li X Y and Gao Y P. 2022. Semi-supervised defect detection method with data-expanding strategy for PCB quality inspection. *Sensors*, 22(20): #7971 [DOI: 10.3390/s22207971]
- Wang D, Zhang M, Xu Y C, Lu W N, Yang J and Zhang T. 2021a. Metric-based meta-learning model for few-shot fault diagnosis under multiple limited data conditions. *Mechanical Systems and Signal Processing*, 155: #107510 [DOI: 10.1016/j.ymssp.2020.107510]
- Wang D T, Yu W J, Lian P Y and Zhang M J. 2022a. Textile defect detection algorithm based on unsupervised learning//*Proceedings of the 7th International Conference on Image, Vision and Computing*. Xi'an, China: IEEE: 81-86 [DOI: 10.1109/ICIVC55077.2022.9887216]
- Wang H, Qin J Y, Bastola A, Chen X W, Suchanek J, Gong Z H and Razi A. 2024a. VisionGPT: LLM-assisted real-time anomaly detection for safe visual navigation [EB/OL]. [2024-07-16]. <http://arxiv.org/pdf/2403.12415.pdf>
- Wang H H, Li Z L and Wang H Q. 2022b. Few-shot steel surface defect detection. *IEEE Transactions on Instrumentation and Measurement*, 71: #5003912 [DOI: 10.1109/TIM.2021.3128208]

- Wang H X, Li Y F, Dang L M, Lee S and Moon H. 2021b. Pixel-level tunnel crack segmentation using a weakly supervised annotation approach. *Computers in Industry*, 133: #103545 [DOI: 10.1016/j.compind.2021.103545]
- Wang J C, Yi G D, Zhang S Y and Wang Y. 2020a. An unsupervised generative adversarial network-based method for defect inspection of texture surfaces. *Applied Sciences*, 11(1): #283 [DOI: 10.3390/app11010283]
- Wang L, Jia K Y, Li M and Yin J. 2023a. Industrial product surface defects detection based on weakly supervised learning//*Proceedings of the 42nd Chinese Control Conference*. Tianjin, China: IEEE: 6987-6992 [DOI: 10.23919/CCC58697.2023.10240953]
- Wang R X, Cheung C F and Wang C J. 2023b. Unsupervised defect segmentation in selective laser melting. *IEEE Transactions on Instrumentation and Measurement*, 72: #2520010 [DOI: 10.1109/TIM.2023.3291002]
- Wang S H, Wang D Z, Kong D S, Wang J X, Li W H and Zhou S. 2020b. Few-shot rolling bearing fault diagnosis with metric-based meta learning. *Sensors*, 20(22): #6437 [DOI: 10.3390/s20226437]
- Wang W J, Su C, Han G H and Hu S P. 2024b. Semi-supervised learning for concrete defect segmentation from images. *Structural Health Monitoring*, 23(5): 3026-3045 [DOI: 10.1177/14759217231217097]
- Wang Y L, Zhang Y L, Zheng L, Yin L D, Chen J S and Lu J G. 2021c. Unsupervised learning with generative adversarial network for automatic tire defect detection from X-ray images. *Sensors*, 21(20): #6773 [DOI: 10.3390/s21206773]
- Wang Y X, Yan J, Yang Z, Qi Z K, Wang J H and Geng Y S. 2022c. Gas-insulated switchgear insulation defect diagnosis via a novel domain adaptive graph convolutional network. *IEEE Transactions on Instrumentation and Measurement*, 71: #3508910 [DOI: 10.1109/tim.2022.3160543]
- Wang Y X, Yan J, Yang Z, Qi Z K, Wang J H and Geng Y S. 2023c. A novel domain adversarial graph convolutional network for insulation defect diagnosis in gas-insulated substations. *IEEE Transactions on Power Delivery*, 38(1): 442-452 [DOI: 10.1109/tpwr.2022.3190938]
- Wang Y Y, Song K C, Niu M H, Bao Y Q, Dong H W and Yan Y H. 2022d. Unsupervised defect detection with patch-aware mutual reasoning network in image data. *Automation in Construction*, 142: #104472 [DOI: 10.1016/j.autcon.2022.104472]
- Wang Z L, Leng Z F and Zhang Z X. 2024c. A weakly-supervised transformer-based hybrid network with multi-attention for pavement crack detection. *Construction and Building Materials*, 411: #134134 [DOI: 10.1016/j.conbuildmat.2023.134134]
- Wu H Y, Li B, Tian L F, Sun Z Z, Dong C and Liao W Z. 2023. CoRe: contrastive and restorative self-supervised learning for surface defect inspection. *IEEE Transactions on Instrumentation and Measurement*, 72: #5020112 [DOI: 10.1109/TIM.2023.3291776]
- Wu K, Tan J and Liu C B. 2022a. Cross-domain few-shot learning approach for lithium-ion battery surface defects classification using an improved Siamese network. *IEEE Sensors Journal*, 22(12): 11847-11856 [DOI: 10.1109/JSEN.2022.3161331]
- Wu X J, Wang T, Li Y M, Li P and Liu Y H. 2022b. A CAM-based weakly supervised method for surface defect inspection. *IEEE Transactions on Instrumentation and Measurement*, 71: #3511410 [DOI: 10.1109/TIM.2022.3168895]
- Wu Y, Xing M W, Zhang Y C, Xie Y, Wu Z Z and Qu Y Y. 2024. Perturbed progressive learning for semisupervised defect segmentation. *IEEE Transactions on Neural Networks and Learning Systems*, 35(5): 6118-6132 [DOI: 10.1109/TNNLS.2023.3324188]
- Xiao W W, Song K C, Liu J and Yan Y H. 2022. Graph embedding and optimal transport for few-shot classification of metal surface defect. *IEEE Transactions on Instrumentation and Measurement*, 71: #5010310 [DOI: 10.1109/TIM.2022.3169547]
- Xie H S and Lin S F. 2021. A weakly supervised defect detection based on dual path networks and GMA-CAM//*Proceedings of the 11th International Conference on Image and Graphics*. Haikou, China: Springer: 467-478 [DOI: 10.1007/978-3-030-87355-4_39]
- Xie X, Li Z X, Huang Y H and Wu D Q. 2023. A weakly supervised anomaly detection method based on deep anomaly scoring network. *Signal, Image and Video Processing*, 17(8): 3903-3911 [DOI: 10.1007/s11760-023-02619-7]
- Xu J Q, Zuo Z L, Wu D C, Li B, Li X N and Kong D Y. 2021a. Bearing defect detection with unsupervised neural networks. *Shock and Vibration*, 2021: #9544809 [DOI: 10.1155/2021/9544809]
- Xu R G, Hao R Y and Huang B Q. 2022. Efficient surface defect detection using self-supervised learning strategy and segmentation network. *Advanced Engineering Informatics*, 52: #101566 [DOI: 10.1016/j.aei.2022.101566]
- Xu Z, Li L, Yan M, Liu J, Luo X P, Grundy J, Zhang Y F and Zhang X H. 2021b. A comprehensive comparative study of clustering-based unsupervised defect prediction models. *Journal of Systems and Software*, 172: #110862 [DOI: 10.1016/j.jss.2020.110862]
- Yan Y H, Ma S, Song K C, Wang Y Y, Tian H K and Guo J B. 2024. Uncertainty inspired domain adaptation network for rail surface defect segmentation. *Engineering Applications of Artificial Intelligence*, 135: #108860 [DOI: 10.1016/j.engappai.2024.108860]
- Yang J, Li S B, Wang Z, Dong H, Wang J and Tang S H. 2020. Using deep learning to detect defects in manufacturing: a comprehensive survey and current challenges. *Materials*, 13(24): #5755 [DOI: 10.3390/ma13245755]
- Yang J and Qian H B. 2016. Defect prediction on unlabeled datasets by using unsupervised clustering//*Proceedings of the 18th IEEE International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems*. Sydney, Australia: IEEE: 465-472 [DOI: 10.1109/HPCC-SmartCity-DSS.2016.0073]

- Yang M H, Wu P and Feng H. 2023. MemSeg: a semi-supervised method for image surface defect detection using differences and commonalities. *Engineering Applications of Artificial Intelligence*, 119: #105835 [DOI: 10.1016/j.engappai.2023.105835]
- Yang P X, Zhu L, Zhang Y J, Ma C X, Liu L M, Yu X and Hu W H. 2024. on the relative value of clustering techniques for unsupervised effort-aware defect prediction. *Expert Systems with Applications*, 245: #123041 [DOI: 10.1016/j.eswa.2023.123041]
- Yao K, Ortiz A and Bonnin-Pascual F. 2021. A weakly-supervised semantic segmentation approach based on the centroid loss: application to quality control and inspection. *IEEE Access*, 9: 69010-69026 [DOI: 10.1109/access.2021.3077847]
- Ye B H, Lai J H, Xie X H and Zhu J Y. 2024. Prototype-guided domain adaptive one-stage object detector for defect detection. *Advanced Engineering Informatics*, 62: #102618 [DOI: 10.1016/j.aei.2024.102618]
- Yi X, Song Y H and Tang X. 2019. Weak supervised surface defect detection method based on selective search and CAM//*Proceedings of 2019 Chinese Automation Congress*. Hangzhou, China: IEEE: 4386-4391 [DOI: 10.1109/CAC48633.2019.8996269]
- Yong G, Jeon K, Gil D and Lee G. 2023. Prompt engineering for zero-shot and few-shot defect detection and classification using a visual-language pretrained model. *Computer-Aided Civil and Infrastructure Engineering*, 38 (11): 1536-1554 [DOI: 10.1111/mice.12954]
- Yu J, Kim D Y, Lee Y and Jeon M. 2020. Unsupervised pixel-level road defect detection via adversarial image-to-frequency transform//*Proceedings of 2020 IEEE Intelligent Vehicles Symposium*. Las Vegas, USA: IEEE: 1708-1713 [DOI: 10.1109/IV47402.2020.9304843]
- Yu J Y, Liu K P, Qin L, Li Q, Zhao F, Wang Q L, Liu H F, Li B Q, Wang J and Li K X. 2022. DMnet: a new few-shot framework for wind turbine surface defect detection. *Machines*, 10 (6): #487 [DOI: 10.3390/machines10060487]
- Yu R Y and Guo B Y. 2024. Dynamic reasoning network for image-level supervised segmentation on metal surface defect. *IEEE Transactions on Instrumentation and Measurement*, 73: #5018010 [DOI: 10.1109/TIM.2024.3382737]
- Yu Z A, Zhang Y M, Zhang S Y, Yi G D and Qiu L M. 2024. Semi-supervised auxiliary learning for surface defect detection and segmentation of injection-molded products from small image datasets. *The International Journal of Advanced Manufacturing Technology*, 131(9/10): 5243-5264 [DOI: 10.1007/s00170-024-13275-7]
- Zakharov A, Pugin E and Zakharova M. 2023. Surface defect detection based on weakly supervised learning and graph convolutional network//*Proceedings of 2023 International Ural Conference on Electrical Power Engineering*. Magnitogorsk, Russian Federation: IEEE: 578-582 [DOI: 10.1109/UralCon59258.2023.10291095]
- Zhang C and Zhang X. 2023a. Multi-target domain-based hierarchical dynamic instance segmentation method for steel defects detection. *Neural Computing and Applications*, 35 (10): 7389-7406 [DOI: 10.1007/s00521-022-07990-z]
- Zhang G W, Pan Y and Zhang L M. 2021a. Semi-supervised learning with GAN for automatic defect detection from images. *Automation in Construction*, 128: #103764 [DOI: 10.1016/j.autcon.2021.103764]
- Zhang H, Zhang Z Q, Chen Y R, Wu T Y, Zhong H and Wang Y N. 2022. Application advance and prospect of nondestructive testing technology for industrial casting defects. *Acta Automatica Sinica*, 48(4): 935-956 (张辉, 张邹铨, 陈煜嵘, 吴天月, 钟杭, 王耀南. 2022. 工业铸件缺陷无损检测技术的应用进展与展望. *自动化学报*, 48(4): 935-956) [DOI: 10.16383/j.aas.c210161]
- Zhang J B, Su H, Zou W, Gong X Y, Zhang Z T and Shen F. 2021b. CADN: a weakly supervised learning-based category-aware object detection network for surface defect detection. *Pattern Recognition*, 109: #107571 [DOI: 10.1016/j.patcog.2020.107571]
- Zhang L, Yang F, Zhang Y D and Zhu Y J. 2016. Road crack detection using deep convolutional neural network//*Proceedings of 2016 IEEE International Conference on Image Processing*. Phoenix, USA: IEEE: 3708-3712 [DOI: 10.1109/ICIP.2016.7533052]
- Zhang N X, Zhong Y Z and Dian S Y. 2023a. Rethinking unsupervised texture defect detection using PCA. *Optics and Lasers in Engineering*, 163: #107470 [DOI: 10.1016/j.optlaseng.2022.107470]
- Zhang P C, Zheng P X, Guo X and Chen E Q. 2024a. Few-shot defect classification via feature aggregation based on graph neural network. *Journal of Visual Communication and Image Representation*, 101: #104172 [DOI: 10.1016/j.jvcir.2024.104172]
- Zhang R, Zhao N, Fu L H, Bai X L and Cai J H. 2023b. Recognizing defects in stainless steel welds based on multi-domain feature expression and self-optimization. *Journal of Intelligent Manufacturing*, 34(3): 1293-1309 [DOI: 10.1007/s10845-021-01849-1]
- Zhang S, Ye F, Wang B N and Habetler T G. 2019a. Semi-supervised learning of bearing anomaly detection via deep variational autoencoders [EB/OL]. [2024-07-11]. <http://arxiv.org/pdf/1912.01096.pdf>
- Zhang S, Ye F, Wang B N and Habetler T G. 2020. Few-shot bearing anomaly detection via model-agnostic meta-learning//*Proceedings of the 23rd International Conference on Electrical Machines and Systems*. Hamamatsu, Japan: IEEE: 1341-1346 [DOI: 10.23919/ICEMS50442.2020.9291099]
- Zhang S Y, Su L, Gu J F, Li K, Wu W T and Pecht M. 2024b. Category-level selective dual-adversarial network using significance-augmented unsupervised domain adaptation for surface defect detection. *Expert Systems with Applications*, 238: #121879 [DOI: 10.1016/j.eswa.2023.121879]
- Zhang W Z, Li W W and Jia X Y. 2019b. Effort-aware tri-training for semi-supervised just-in-time defect prediction//*Proceedings of the 23rd Pacific-Asia Conference on Advances in Knowledge Discovery*

- and Data Mining. Macau, China: Springer: 293-304 [DOI: 10.1007/978-3-030-16145-3_23]
- Zhang X Y, Zhang J P, Chen J S, Guo R X and Wu J. 2024c. A semisupervised aircraft fuselage defect detection network with dynamic attention and class-aware adaptive pseudolabel assignment. *IEEE Transactions on Artificial Intelligence*, 5(7): 3551-3563 [DOI: 10.1109/TAI.2024.3372474]
- Zhang Y L, Wang Y L, Jiang Z Q, Zheng L, Chen J S and Lu J A. 2022. Tire defect detection by dual-domain adaptation-based transfer learning strategy. *IEEE Sensors Journal*, 22(19): 18804-18814 [DOI: 10.1109/jsen.2022.3201201]
- Zhang Y L, Wang Y L, Jiang Z Q, Zheng L, Chen J S and Lu J A. 2023c. Domain adaptation via transferable swin transformer for tire defect detection. *Engineering Applications of Artificial Intelligence*, 122: #106109 [DOI: 10.1016/j.engappai.2023.106109]
- Zhang Y L, Wang Y L, Jiang Z Q, Zheng L, Chen J S and Lu J A. 2023d. A novel class-level weighted partial domain adaptation network for defect detection. *Applied Intelligence*, 53(20): 23083-23096 [DOI: 10.1007/s10489-023-04733-y]
- Zhang Z, Shang Z Q, Wang X and Ma J. 2024d. Combined anomaly aware weakly supervised lightweight model for surface defect inspection. *IEEE Transactions on Industrial Informatics*, 20(4): 6652-6663 [DOI: 10.1109/TII.2023.3348835]
- Zhang Z X and Zhang L M. 2023b. Unsupervised pixel-level detection of rail surface defects using multistep domain adaptation. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(9): 5784-5795 [DOI: 10.1109/TSMC.2023.3274878]
- Zhao J Q, Qian X L, Zhang Y Z, Shan D X, Liu X Z, Coleman S and Kerr D. 2024. A knowledge distillation-based multi-scale relation-prototypical network for cross-domain few-shot defect classification. *Journal of Intelligent Manufacturing*, 35(2): 841-857 [DOI: 10.1007/s10845-023-02080-w]
- Zhao S X, Zhong R Y, Wang J L, Xu C Q and Zhang J. 2023. Unsupervised fabric defects detection based on spatial domain saliency and features clustering. *Computers and Industrial Engineering*, 185: #109681 [DOI: 10.1016/j.cie.2023.109681]
- Zhou C F, Liu M Q, Zhang S L, Wei P and Chen B D. 2023. Few-shot classification of screen defects with class-agnostic mask and context-based classifier. *IEEE Transactions on Instrumentation and Measurement*, 72: #2517716 [DOI: 10.1109/TIM.2023.3280532]
- Zhou Q H, Mei J, Zhang Q, Wang S Z and Chen G. 2021. Semisupervised fabric defect detection based on image reconstruction and density estimation. *Textile Research Journal*, 91(9/10): 962-972 [DOI: 10.1177/0040517520966733]
- Zhou Q H, Pang G S, Tian Y, He S B and Chen J M. 2024. Anomaly-CLIP: object-agnostic prompt learning for zero-shot anomaly detection//*Proceedings of the 12th International Conference on Learning Representations*. Vienna, Austria: ICLR
- Zhu J Q, Cai S F, Deng F, Ooi B C and Wu J R. 2024. Do LLMs understand visual anomalies? Uncovering LLM's capabilities in zero-shot anomaly detection//*Proceedings of the 32nd ACM International Conference on Multimedia*. Melbourne, Australia: ACM: 48-57 [DOI: 10.1145/3664647.3681190]

作者简介

叶标华,男,博士研究生,主要研究方向为计算机视觉与模式识别。E-mail:yebh3@mail2.sysu.edu.cn

赖剑煌,通信作者,男,教授,博士生导师,主要研究方向为计算机视觉与模式识别。E-mail:stsljh@mail.sysu.edu.cn

康丹青,男,博士后,主要研究方向为计算机视觉与模式识别。E-mail:kangdq@mail2.sysu.edu.cn

谢晓华,男,副教授,博士生导师,主要研究方向为计算机视觉与模式识别。E-mail:xiexiaoh6@mail.sysu.edu.cn