

基于深度智能视觉的表面缺陷检测研究进展

高艺平, 王浩, 李新宇, 高亮

(华中科技大学 机械科学与工程学院, 湖北 武汉 430074)

摘要: 基于深度智能视觉的表面缺陷检测研究在制造业中起着越发重要的作用, 本文阐述深度智能视觉的表面缺陷检测在现代工业质检中的重要性, 对现有研究进展进行梳理总结。深度智能视觉以机器视觉和深度学习为技术基础, 为不同工业场景提供高精高效的表面缺陷检测算法。本文从检测细粒度的角度将表面缺陷检测分为表面缺陷分类、定位、分割检测 3 个部分, 并分别对分类、定位、分割方法进行系统综述, 梳理现有表面缺陷检测研究的问题和思路。分类检测针对数据和缺陷图形特征问题进行研究, 因其基础性和易拓展性于不同工业场景的应用呈现分散发展; 定位检测以模型框架、矩形框检测和标注成本为主要问题, 表现出追求轻量化和特征融合机制的研究趋势; 分割检测更关注图像细节特征。通过研究分类、定位、分割的多任务模型框架以探索分类、分割检测之间的互补性。最后总结目前表面缺陷检测研究存在的问题, 并对发展趋势进行展望。

关键词: 表面缺陷检测; 缺陷分类; 缺陷定位; 缺陷分割

中图分类号: F406.3; TP183

文献标志码: A

文章编号: 1007-7375(2024)02-0027-10

A Review on Surface Defect Detection Based on Deep Intelligent Vision

GAO Yiping, WANG Hao, LI Xinyu, GAO Liang

(School of Mechanical Science & Engineering, Huazhong University of Science & Technology, Wuhan 430074, China)

Abstract: The exploration on surface defect detection based on deep intelligent vision plays an increasingly important role in the manufacturing industry. The importance of surface defect detection based on deep intelligent vision in modern industrial quality inspection is explained and the existing research progress is summarized in this paper. Deep intelligent vision provides high-precision and high-efficiency surface defect detection algorithms for different industrial scenarios based on the technologies of machine vision and deep learning. Surface defect detection can be divided into three categories: surface defect classification, localization, and segmentation from the perspective of detection fineness. The classification, localization, and segmentation methods are systematically reviewed, respectively, to sort out the problematic points and lines of the existing surface defect detection methods. Surface defect classification focuses on the problem of data and defective graphical features, which shows decentralized development due to its basic and easily expandable nature for application in different industrial scenarios. Surface defect localization takes the model framework, rectangular box detection mechanism, and annotation cost as the main problems, showing a research trend of pursuing lightweight and feature fusion mechanisms. Surface defect segmentation pays more attention to detailed features of an image. A multi-task framework for classification, localization, and segmentation, is studied to explore the complementarity between classification and segmentation detection. Finally, the current issues of existing surface defect detection studies are concluded and an outlook on the development trend is given.

Key words: surface defect detection; defect classification; defect localization; defect segmentation

智能制造是《中国制造 2025》及制造强国战略的重要内容, 其核心是以智能信息技术赋能生产制

造。智能赋能制造的关键在于把计算机信息技术引入制造系统, 实现制造的智能化和自动化。作为制

收稿日期: 2023-12-06

基金项目: 国家自然科学基金资助项目 (52205523)

作者简介: 高艺平 (1991—), 男, 山东省人, 博士, 主要研究方向为深度学习、智能检测。

通讯作者: 李新宇 (1985—), 男, 湖北省人, 教授, 博士, 主要研究方向为智能制造系统、车间调度、智能优化与机器学习。

Email: lixinyu@mail.hust.edu.cn

造系统的关键质量保障措施, 高端检测技术能够提升企业的竞争力和风险抵抗能力, 对于企业乃至国家发展至关重要^[1]。表面缺陷检测作为基本的工业质量检测, 普遍存在于机械、电子、汽车等制造领域^[2-5], 对于维护供应关系、避免重大生产事故有着重要意义。

传统的表面缺陷检测受限于生产环境和算法性能, 检测效率低, 检测结果不稳定, 难以大规模部署应用。近年来, 深度智能视觉作为一种新兴人工智能技术, 在人脸识别、医学图像处理、自动驾驶等领域都取得了很好的效果。良好图像识别效果也使得深度智能视觉在表面缺陷检测中受到广泛关注^[6]。

表面缺陷检测的任务流程简单, 但需要专业的检测经验, 使用深度智能视觉技术能够通过数据学习到专业经验并能完成简单的决策任务。同时, 表面缺陷检测作为生产制造过程的关键质量保障措施, 对于制造系统的运行效率、产品质量以及售后问题和安全问题都有很大影响^[7]。利用深度智能视觉技术实现自动化检测可以极大地提高效率, 保证检测质量, 降低生产风险。

本文按照不同的检测粒度对 2019 年以来的基于深度智能视觉的表面缺陷检测方法进行总结。工业视觉检测按照不同检测粒度可以分为缺陷类别检测、缺陷定位检测和缺陷分割检测, 它们分别对缺陷图像样本进行图片级、区域级和像素级的检测。由于检测的精细度和标签的模态不同, 这些任务所使用的方法有一定差异, 主要表现在基准模型选择、特征融合方法、损失函数等方面。本文通过对已有方法的综述, 简要阐明当前基于深度智能视觉表面缺陷检测方法的研究现状, 并对其存在的问题及未来研究方向进行分析。

1 表面缺陷检测问题概述

1.1 表面缺陷检测概述

表面缺陷检测通过使用高效准确的检测模型和算法, 对产品表面的图片所包含的信息进行充分提取和深度学习, 进而对是否带有缺陷以及缺陷的具体位置进行判断和识别, 以保证产品质量符合设计要求, 满足产品需求。一个成熟的表面缺陷检测系统一般应具有但不限于如下功能: 采集产品表面图

像; 识别产品表面是否带有缺陷, 如果带有缺陷则识别缺陷的类别以便于进一步维修或返工, 以矩形框或像素标注缺陷的位置; 计算检测时间和成本; 确定计算资源容量等。其中, 表面图像采集、图像缺陷类别识别、确定检测时间和计算资源等功能是表面缺陷检测的基础性功能, 可以视为一般性的表面缺陷检测内容。

深度智能视觉是赋能工业检测的智能信息方法, 是表面缺陷检测的核心技术。通过人工构建“图像-标注对”数据集, 再合理选择多个线性和非线性变换函数以及它们的结合方式, 构建复杂高维的深度学习模型, 得到逼近理想检测效果的输入-输出模型, 最终实现对表面缺陷的自动检测。一个高性能的深度智能视觉模型需要满足如下功能: 高推理速度、小的模型规模和部署难度、简单的训练方式、满足要求的识别精度等。

通常情况下, 基于深度智能视觉的表面缺陷检测问题被描述如下。对于特定检测类别的工业场景, 通过人工采集或生成方法构建数据集; 在计算资源条件和计算时间条件的限制下, 考虑该工业场景图像的特点, 设计合适的缺陷检测模型; 使用“预训练+微调”的框架先在大规模通用数据集上预训练, 再在工业特定数据集上微调, 得到检测精度能够满足特定需求的自动检测模型。

1.2 表面缺陷检测问题分类

检测过程可描述为通过相机采集工业表面图像, 利用深度学习模型对图像进行特征提取并识别图像的缺陷特征, 最后输出检测结果。由于深度学习模型是黑箱的, 而在工业应用中往往需要明确检测方法的可靠性以减小使用风险, 因此更精细的检测结果可以提供更大的可靠性。检测结果的精度按照不同的工业场景检测细粒度可分为缺陷分类检测、缺陷定位检测和缺陷分割检测, 依次实现图片级—区域级—像素级的检测效果。不同精细度的表面缺陷检测方法如图 1^[8]所示, 具体阐述如下。

1) 表面缺陷分类检测 (surface defect classification)。如图 1 (a) 所示, 是表面缺陷检测问题中最简单和最基础的问题, 是其他精确检测问题的必要组件。其特征为对缺陷的类别进行图片级检测, 即以图片为最小检测精度。

2) 表面缺陷定位检测 (surface defect localization)。如图 1 (b) 所示, 对图像中的缺陷区域使用矩

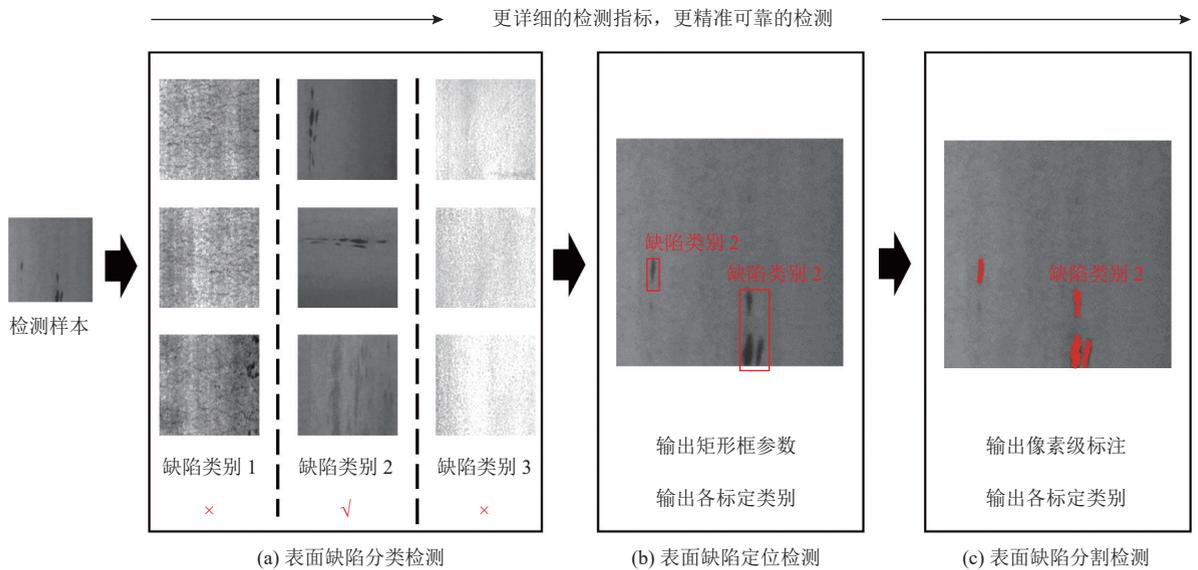


图1 表面缺陷分类、定位、分割检测

Figure 1 Surface defect classification, detection, and segmentation

形框标定, 提供比分类检测更精确、更可靠的检测结果。

3) 表面缺陷分割检测 (surface defect segmentation)。如图1(c)所示, 对图像中的缺陷区域按像素进行精确标定, 得到缺陷区域与非缺陷区域的精确分割, 提供完备的检测结果供各项检测指标计算, 以提供更高的检测可靠性。

缺陷分类作为基本任务, 需要考虑工业图像的典型特点。首先, 对于模型的训练数据需求, 由于工业数据有防止泄露的安全性要求, 这限制了可训练数据集的构建。此外, 由于缺陷数据出现远比正常数据出现频率低, 工业数据的“正常-缺陷”数据分布有极端的不平衡性, 这也为模型在工业数据集上的训练提高了难度。其次, 相较于一般图像, 工业图像有其图形学特点, 工业生产场景相较于生活场景的图像偏差较大, 大部分缺陷特征形状复杂, 尺寸差异大。尤其是部分缺陷特征非常微小, 普通模型难以感知, 同时缺陷与背景的高相似性以及缺陷的类间相似性^[9]和类内差异性^[10]问题都给检测方法带来新的挑战。再次, 工业检测需要满足特定的计算条件, 例如部分场景下检测需要在规定时间段内完成, 模型的规模需要能够部署到特定的检测设备上。最后, 还有一系列工业特殊场景问题亟待解决, 例如对于数据流、视频的常时检测、“边走边测”的检测要求以及图像噪声问题等。

随着检测结果的逐渐细化, 检测的难度也逐渐

增大, 检测方法更加复杂。缺陷分类仅完成了在图片级对缺陷类别的识别, 忽略了缺陷在图片中的定位、单张图片中缺陷是否完整、是否存在多个不同类缺陷等问题; 缺陷定位和分割在分类检测的基础上不仅需要考虑上述被忽略的问题, 还需要考虑许多工业检测场景的特有问题, 以满足工业领域对检测精度和计算效率的需求。这带来的影响是定位与分割检测所使用的模型规模一般比分类检测模型更大, 数据集的标识花费更大, 但研究进展较分类检测缓慢。因而更多研究被投入到定位和分割检测上, 以追求更精细、更可解释的检测结果和更高的检测性能。

2 表面缺陷分类检测研究现状

由于分类检测的基础性和简单性, 各种深度学习模型都能在不同的工业场景下取得较优性能, 因此目前基于深度智能视觉的表面缺陷分类检测的研究方法比较分散。按照模型可以分为卷积神经网络 (convolutional neural networks, CNN)^[10] 系列和 ViT (vision transformer)^[11] 系列。CNN 系列通用图像分类模型有残差深度网络 ResNet^[12]、SqueezeNet^[13] 等; ViT 系列模型有 Swin Transformer^[14] 等。

缺陷检测的数据问题体现在不同类别的缺陷样本数差异大、样本图像少等方面。一些研究从改善网络框架或扩充数据集的角度来解决这个问题。Cheon 等^[15] 考虑了晶圆缺陷的特有问题, 在加工过

程中由于环境条件的变化,可能会出现新的缺陷类别,使原有模型检测失效,于是引入 K 最近邻 (K-nearest neighbor, KNN) 方法对已知类别进行聚类,通过类间距离的衡量辨识未知类别的缺陷,达到 96.2% 的分类准确率。Wei 等^[16]进一步在晶圆缺陷的类别不明确问题中引入 Transformer 模型以追求更好的大量类别检测,达到 97.17% 的分类准确率。由于工业正常/缺陷类别极不平衡,且缺陷类别数据收集开销较大,一些方法采用生成对抗网络 (generative adversarial network, GAN)^[17] 扩充数据集。He 等^[18]对于钢铁表面的缺陷检测,提出一种结合 GAN 和残差网络的多重训练算法扩充钢铁缺陷样本,通过对 90 张样本的扩充训练,提升了 20% 的准确率。Hu 等^[19]在深度卷积对抗神经网络 (deep convolutional generative adversarial network, DCGAN)^[20] 中增加一个编码器,使得模型可利用重建的残差图加强对潜在缺陷区域的检测,对 80 个样本的纺织品表面缺陷数据集进行了扩充,准确率超过其他增强方法 10%。Niu 等^[21]进一步研究 GAN 生成的图像质量问题,设计了多个 GAN 的联合作用框架,来解决生成图像多元性和对真实图像数据的不平等依赖问题,在换向器气缸缺陷数据集上的图像生成质量的 Fréchet Inception 距离 (Fréchet inception distance, FID) 优于该文中用于比较的其他方法。但是 GAN 方法训练时长约为一般数据增强方法的 3~7 倍。

除数据问题外,工业图像前后景相似性、缺陷的形状尺寸差异问题也被研究。Yang 等^[22]针对工业图像背景杂乱、缺陷尺寸差异大的问题,提出使用模板匹配首先识别并去除背景区域,再使用多尺寸卷积核提取多尺度特征和获取更大的感受野,达到超过 95% 的准确率。Liu 等^[23]进一步对微小不规则形状的缺陷使用多级连接的特征金字塔以增强对图像细节的感知,在钢铁表面缺陷数据集上达到 97% 的准确率。对于铁轨的缺陷检测,Zhang 等^[24]考虑铁轨的长度远远大于宽度的特点,创新性地 将铁轨的长条状图片视为长度方向的序列,进而使用长短期记忆网络进行检测,该像素线分类模式的 F1 分数超过该文中用于比较的其他最优方法。Li 等^[25]研究微型电枢的微小复杂缺陷,提出使用通道注意力机制增强模型感知能力,达到 98.42% 的准确率。Zhu 等^[26]考虑缺陷特征的检测角度问题,

引入具有旋转不变性的特征提取模块来使网络更好地处理不同方向的缺陷特征,以 0.12 M 的参数量取得 95.1% 的准确率。图像图形问题被广泛研究,但是研究方法缺乏可解释性。

对于实时检测问题和模型部署问题,Yang 等^[22]提出基于 SqueezeNet 的轻量化模型,实现对 USB 数据集的快速检测,平均单次检测时间为 7.2 ms,模型容量减小到 3.4 MB。Wang 等^[27]研究更严格情况下的三维打印的熔融沉积模型所需的实时监控问题,提出一种轻量的 CNN 模型并优化模型参数,单图检测时间为 0.487 s,检测准确率达到 91%。在模型部署问题中,SqueezeNet^[13]、MobileNets^[28-30]、MobileViT^[31]、ShuffleNet^[32] 等模型取得较好的降低模型参数量的效果。一般倾向于通过大数据集预训练后在目标数据集上微调,使用模型蒸馏^[33]等方法压缩模型的规模以便于部署。但是通用检测往往更复杂,现有方法依赖于大规模预训练权重,检测的基准模型一旦被压缩便难以检测复杂目标。

表面缺陷分类检测作为初级的检测任务,各深度学习模型都有其特点,工业领域任务种类繁多,各模型都能满足一定的检测精度需求,因此发展较分散。表面缺陷分类检测方法据此为各种工业检测问题提供自动化的解决方案。但是分类检测未能明确解释模型所预测的特征与图片中相对应的缺陷特征,这会带来一定风险。

3 表面缺陷定位检测研究现状

表面缺陷定位检测在分类检测确定缺陷类别的基础上以矩形框的形式确定缺陷的位置,以表明模型自动检测结果所依赖的区域对应图片中的缺陷区域。由于工业图像缺陷有着多类别、分布密集的特征,同一张图像样本中可能同时存在密集的多类别多目标缺陷区域,因而极大地增加了检测信息敏感度。目前的表面缺陷定位检测方法的框架是首先使用一个分类模型作为关键的特征提取网络,再设计细粒度更高的附加模型,对从特征提取网络抽取的多尺度特征进行融合,设计矩形框的产生和优化机制,根据融合的特征信息进行矩形框的缺陷定位。

按照检测模型的结构可以将现有定位检测研究分为一阶段模型和二阶段模型,区别在于前者直接生成回归的定位目标框,后者使用一个新阶段来生

成定位目标框。通用的定位检测一阶段模型包括 SDD (single shot detector)^[34]、YOLO (you only look once)^[35-37]、DETR (detection transformer)^[38]、RetinaNet^[39]、FCOS (fully convolutional one-stage object detection)^[40]等; 二阶段模型包括 Faster RCNN^[41]等。出于对目标框的定位准确需求, CNN 系列模型在该目标上的表现目前超越 ViT 系列模型, 因而更受研究人员青睐。由于工业检测更注重检测效率, 现有方法多采用一阶段模型作为基本框架。

部分工业检测场景下采集的图像以数据流的形式不断传入检测模型。Liu 等^[42]研究工业实时检测的流数据及其带来的检测不稳定的域波动问题, 采用传统学习方法和深度学习方法相结合的框架, 基于 YOLO 模型的骨干网络设计数据差异分辨器对网络的权重进行监视和控制, 以抵抗域波动现象, 全类平均准确率 (mean average precision, mAP) 达到 95.8%。Block 等^[43]对于冲压金属表面的印记缺陷, 突破性地使用深度学习方法进行视频图像的定位检测, 基于 RetinaNet 引入检测区域的跟踪来研究视频连续帧的时间相干性, 消除时态特征冗余, 减少识别错误的定位候选框, mAP 达到 76.21%, 超过该文中用于比较的其他最优方法。Wu 等^[44]考虑在铁轨自动检测场景下的铁轨组件难以被同时检测的问题, 基于 YOLO 网络进行多任务铁轨组件检测, 在 ConvNeXt^[45]的基础上引入大尺度卷积和层正则化, mAP 达到 95.6%, 每秒传输帧数 (frames per second, FPS) 为 147.1, 实现对铁轨检测视频数据的“边走边测”。

相较于分类检测任务, 定位检测对缺陷的形状尺寸差异问题更加敏感。Yang 等^[22]研究工业图像缺陷形状尺寸差异大的问题, 以 SqueezeNet 为骨干网络, 通过多尺度卷积使不同尺寸的特征协同作用, 以提高感受野。Liu 等^[23]引入可变形卷积来增强对不同尺寸的缺陷的感知, 设计一种新的多级特征拼接网络来提高目标检测效果, mAP 达到 98.6%。Cheng 等^[46]指出之前方法所使用的人为指定的定位框尺寸与工业缺陷实际尺寸差异过大而导致定位不准的问题, 考虑从改善定位框的设定入手, 在 RetinaNet 中引入差分进化算法, 优化了定位框的尺寸设定, 并提出通道注意力模块和自适应空间特征融合模块增强语义细节信息和空间信息, 在钢铁表面缺陷检测数据集上, mAP 达到 79.1%。

Zeng 等^[47]对于工业小目标缺陷, 基于特征金字塔网络 (feature pyramid networks, FPN)^[48]提出增强的多尺度特征融合模型, 使用更大感受野的空洞卷积金字塔结构融合特征信息, 并设计平衡模块平衡各层获取的特征信息对输出的影响, mAP 达到 98.8%。Yeung 等^[49]对于缺陷尺度形状变化和检测效率的问题, 提出融合注意力网络, 从考虑多尺度特征融合的平衡的角度出发, 提出自适应特征平衡模块根据特征重要性融合多级特征图, 增强了在通道和空间维度上的特征融合, 并提高了检测效率, 在钢铁表面缺陷检测数据集上, mAP 达到 80.5%。Ni 等^[50]考虑铁轨表面场景下的复杂背景和极端的数据不平衡问题, 提出交并比 (intersection over union, IoU) 一致性引导的中心点估计注意力神经网络; 相较于以前方法的简单的逐级特征融合, 以一种沙漏形框架提出新的交叉逐级融合的多级特征融合方法来有效学习多级特征; 并增强对特征中心点的精确估计, 同时使用可变感知域的卷积模块来压缩空间噪声, mAP 达到 92.45%。Luo 等^[51]对于柔性印刷电路板 FPCB 板表面缺陷检测的非显著缺陷和缺陷类间相似性问题, 提出一种解耦的两阶段目标检测网络, 提出多层次聚合模块和局部非局部模块, 分别用于定位效果增强和分类效果增强, mAP 达到 94.15%。

Transformer 在自然语言处理和多模态大模型上都取得了突破性进展, 一些研究^[52]使用 ViT 进行表面缺陷检测。Gao 等^[53]向工业领域引入 ViT 模型, 通过在 Swin Transformer 的基础上, 提出两种新的滑动策略变体: 横向滑动分割和纵向滑动分割, 在 NEU 热轧钢带缺陷数据集上, mAP 达到 80.5%。Zhou 等^[54]对于工业表面的前后景相似性和缺陷尺寸形状差异性问题, 提出一种基于 ViT 的轻量模型, 以修改的轻量 ViT 模型为骨干网络, 设计多级特征融合模块和分类定位输出模块, 将参数量从大于 30 M 降低到 7 M, 在钢铁表面缺陷检测上达到了 50 FPS。Lu 等^[55]针对复杂背景下的缺陷检测问题, 提出通道空间自适应增强特征金字塔网络, 使用 Swin-Tiny 作为特征提取网络, 联合对通道空间增强的特征融合模块和高效自适应交叉尺寸像素引导模块, 提出一种新颖的特征金字塔网络, 在不生成锚框的条件下对纺织品缺陷检测, mAP 达到 89.1%。Zhang 等^[56]对于视觉无法分辨的螺栓缺陷

问题和螺钉螺母丢失问题, 提出基于 DETR 的模型以提取多级特征, 设计传输线图像相对位置编码方法进行螺栓位置知识推理。通过将螺钉和螺母视为检测目标的属性来进行知识推理, 以解决实际的工业检测需求, 分别设计了螺栓属性分类器和螺栓缺陷分类器作为网络的输出头。网络还使用膨胀卷积作为膨胀编码器模块以增大感受野, 并考虑相对位置编码的距离和角度以提供更丰富的位置信息, mAP 达到 81.9%。Wang 等^[57] 同样使用 DETR 模型, 解决工业检测的小缺陷问题, 引入跨度敏感纹理融合模块和数据增强策略, 在铝材表面缺陷数据集上, mAP 达到 88.5%, 在磁砖数据集上达到 98.5%。Yuksel 等^[58] 对于管道的磁漏信号的自动检测, 提出使用 Swin Transformer 和 YOLOv5 模型结合的新框架, 使用二阶段检测方式, 对磁漏信号图像进行尺寸上的更精确检测, mAP 达到 99.5%。

为构建深度智能视觉模型的工业通用评价标准, 很多研究者在解决工业检测问题的同时提供相应的标注数据集作为评价基准, 如 NEU 热轧钢带缺陷数据集^[9]、木制品表面缺陷数据集^[59]; KolektorSDD 数据集^[60]、FPCB 柔性印刷电路板缺陷定位数据集^[51]、实际生产过程中采集的冲压检测数据集^[43]、现实中采集的金属表面缺陷检测数据集^[50] 等。

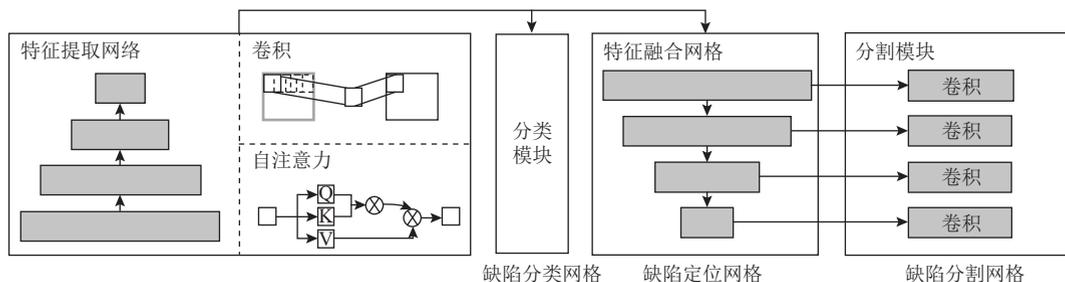


图 2 缺陷分类、定位、分割网络框架

Figure 2 The network framework of defect classification, detection, and segmentation

分割检测任务中的图像图形特点不仅表现在特征提取中, 在特征融合中也需要被考虑。Dong 等^[66] 对于工业缺陷图片的类内复杂性和类间相似性问题, 较早地进行了缺陷分割的研究, 提出金字塔特征融合模块, 并使用全局信息注意力块和边界细化模块, 该方法在 4 个数据集上都达到了 SOTA (state-of-the-art) 的性能。Wu 等^[44] 对于铁轨自动检测使用 U 形显著目标分割作为补充的缺陷分割检测分支, 以此学习到在浅层被丢弃的特征信息, mAP

表面缺陷定位检测的研究目前以单阶段模型为主, 为了达到更精细的识别, 学者们提出许多方法来增强模型的语义信息感知与融合, 在矩形框的生成机制上也有许多工作产生, 基于 ViT 的模型越来越多地被用于检测任务上。但是这些方法没有考虑模型在多个工业领域的实际泛用性, 表面缺陷检测往往要求大量且专业的检测指标, 与通用的矩形框标定检测存在一定应用壁垒, 尚难达到多任务多场景多指标精准检测的通用模型。

4 表面缺陷分割检测研究现状

表面缺陷分割检测是在分类检测和定位检测的基础上, 对表面缺陷区域进行精确的像素级标定, 以此满足更严格和更精细的工业检测需求。常用的模型有全卷积神经网络 (fully convolutional network, FCN)^[61]、DeepLabV1-V3^[62-64]、U-Net^[65] 等。其主要框架是首先使用一个特征提取网络进行多次的下采样, 实现对样本图像的金字塔式压缩和抽象化, 再抽取特征提取网络的多个中间层的多尺度特征图, 从而得到抽象度高的特征信息和丰富的语义信息。在此基础上通过一个特征融合网络融合各级特征, 并输出对图像的像素级标注以及各缺陷类别, 如图 2 所示。

达到 96.2%, FPS 达到 147.1。Luo 等^[67] 针对工业图像的分割完整性和缺陷边界难以被精确分割的问题, 基于 ViT 模型提出交叉注意力 transformer 编码器-解码器网络, 提出残差连接在编码器和解码器中的作用并不等效; 通过动态分配扩大的多尺度网络层的权重来确定显著的特征区域, 并提供充足的浅层细节特征; 再使用交叉注意力细化模块优化缺陷区域的边界分割, 以处理多尺度特征语义之间的隔阂, 对钢铁表面缺陷的分割加权 F 分数达到 93.63%,

并验证噪声鲁棒性。Zhang等^[68]认为工业图像缺陷的局域复杂性需要重点研究, 基于ViT模型设计一种新的两阶段框架: 第1阶段引入哈尔小波进行缺陷的复杂特征的学习和建模, 但是会引入噪声; 第2阶段通过分析噪声在网络训练中的变化特性进行特征压缩, 由此构成促进-压缩的二阶段框架。网络引入通道注意力增强特征融合, 将哈尔小波引导的损失、一阶段辅助损失和二阶段交叉熵损失合成最终的损失函数。该方法在纹理表面缺陷、磁砖表面缺陷、路面裂纹缺陷3个缺陷分割数据集上分别取得89.57%、92.16%、97.29%的准确率。Wang等^[69]对于路面缺陷存在的类别多样性和缺陷极端随机分布特点, 提出一个新颖的相关性感知Transformer块和交叉推理细化模块进行路面缺陷的异常分割, 平均交并比(mean intersection over union, mIoU)达到65.1%, 同时提供一个路面镶嵌块异常分割数据集; 提出一个内容感知的异常蒸馏测量方法, 通过评价语义重建的一致性来自适应地增强显著缺陷区域的感知。这些方法考虑了各种工业检测场景中的缺陷图形特点, 但是检测准确率仍然有较大提升空间。

一些方法将缺陷分类、定位和分割一起研究, 从而得到一些先进的启发。Božič等^[70]针对工业数据的分割标注成本高的问题, 研究分类标注、分割标注这些不同强度的标签对分割精度的影响, 想要找出满足足够工业检测需求的数据标注成本平衡点。通过使用分割和分类分支子网络来研究不同强度的混合标签监督的异常检测模型, 在DAGM纹理数据集、KolektorSDD金属表面数据集、Severstal steel defect dataset钢铁表面数据集上进行端到端的检测, 得到两个有价值的结论: 1) 使用大量的图像分类标签比少量分割标签更重要; 2) 添加5%~10%的全标签监督可以取得精确度的大幅上涨, 近似于100%的全标签监督。Sampath等^[71]进一步提出融合分类、定位、分割3个任务的新框架, 考虑了小样本、缺陷尺寸形状差异等多个问题, 使用自下而上的特征提取网络和自上而下的特征融合网络, 前者提取特征信息缩小特征图, 后者提取语义信息增大特征图; 并加入SE(squeeze and excitation)模块、空间注意力模块来帮助进行工业图像复杂信息的处理; 最后使用分割、定位、分类的三支网络输出构建损失函数, 实现多任务的数据驱动学习

并达到SOTA。但是多任务模型损失了简单性和高效性。

图像生成同样作为像素级的工业视觉任务, 为缺陷分割提供辅助性帮助。一些研究^[72-74]考虑了工业检测图像的特点和数据难以收集的问题, 提出了许多生成性方法扩充现有数据集, 在扩充数据集的基础上训练模型可以达到更好的分割精度。Niu等^[20]将对抗损失和D2损失联合起来促进模型生成更高质量和更大多样性的图像。Jain等^[74]条件生成对抗网络将(conditional generative adversarial network, CGAN)^[75]和信息最大化对抗生成网络(information maximizing generative adversarial network, InfoGAN)^[76]联系起来, 提出一种可以控制图像的缺陷类别和光强等属性的生成方法。Niu等^[77]考虑工业上微小缺陷数据难以收集的问题, 基于GAN提出一种对区域和强度可控的图像生成方法丰富工业数据集, 并达到更好的缺陷语义分割效果。

表面缺陷语义分割检测在定位检测上更进了一步, 进行的是最精细的像素级检测, 但是训练难度加大, 数据集标注成本大大提高。一些学者通过将分类、定位、分割检测任务统一研究, 得到一些有价值的见解。但目前语义分割的瓶颈仍然存在, 视觉模型的特征感知能力还需进一步提升。

5 总结与展望

表面缺陷检测已普遍取得较好的检测效果, 研究发展在应用上分散, 在方法上集中表现为寻找更好的方式以追求缺陷图形特点和网络结构的契合。分类检测研究多从图形的抽象化着手, 从不同角度提取缺陷的可检测特征, 目前大多数研究都取得90%及以上的准确率, 研究空间较大。表面缺陷定位检测和分割检测依赖于矩形框标定和像素级重建的检测结构, 对于这种向下抽象-向上退化的模型结构, 现有方法更多地追求抽象和退化的平衡上, 精确的特征提取和高效简约的特征融合对表面缺陷检测是更有研究价值的。定位、分割检测作为精细检测任务, 目前的难点在于如何减小模型体量和提高检测效率, 同时检测指标也需要与实际生产场景进行衔接。

尽管深度智能视觉的表面缺陷检测的研究已经取得较好进展, 但仍然需要进一步完善。当前研究的问题主要表现如下。

1) 可解释性问题。分类、定位、分割逐步精细的检测虽能够为研究人员提供一定的经验保障,但深度学习模型本质为黑箱的问题并未解决。这一方面需要大量的实践对智能视觉检测方法的可靠性进行验证,另一方面也需要风险管控措施的规范。

2) 数据问题。数据作为模型的检验标准,对于表面缺陷检测的深入研究至关重要,较高检测率水平下的模型性能已经难以对比,尤其对于表面缺陷分类检测模型,可行模型基准测试已逐步超过 90% 的准确率。但实际应用效果却难以保障,表面缺陷定位和分割模型在未来也需要标准有效的数据对方法进行验证。

3) 研究分散,难成体系。研究者一方面为追求模型准确率的提升,需要在方法理论上进行大量探索;另一方面工业严苛的生产条件提出了许多制约因素。这导致当前研究能在简单场景下取得良好的泛用效果,但失去了复杂工业场景下的可行性。各表面缺陷检测领域的常用方法和通用视觉方法无明显差异,对工业场景少有研究深入,难成体系,这制约着工业智能化自动化的深入发展。

针对上述问题,深度智能视觉的表面缺陷检测的未来工作可聚焦在以下 3 个方面。

1) 检测规范的统一和可靠性的检验。第三方风险管控与规范制定机构的产生和介入,是深度智能视觉广泛应用的基础。需要探索和开发更可靠的检测基准数据集和检测方法,在缺陷分割检测上更进一步实现对规范指标的预测,以便与标准进行衔接。

2) 研究无监督模型、生成方法以解决工业数据缺乏的问题,同时需加快和实际生产场景的视觉自动化,采集更多的工业表面缺陷图样。这有利于解决目前数据缺乏真实性和可靠性的问题。

3) 考虑更多的实际工业场景,深度视觉检测方法需要与工业的检测硬件协同设计,探索统一灵活的自动检测系统是促进未来分布式制造系统发展的关键。

参考文献:

[1] 周东华,魏慕恒,司小胜.工业过程异常检测、寿命预测与维修决策的研究进展[J].自动化学报,2013,39(6):711-722.
ZHOU Donghua, WEI Muheng, SI Xiaosheng. A survey on anomaly detection, life prediction and maintenance decision for industrial processes[J]. Acta Automatica Sinica, 2013, 39(6): 711-722.

[2] 黄聪,农英雄,张毅.基于高斯受限玻尔兹曼机的工业产品质

量智能异常检测[J].工业工程,2022,25(6):152-159.
HUANG Cong, NONG Yingxiong, ZHANG Yi. Intelligent Anomaly detection for industrial product quality inspection based on Gaussian restricted Boltzmann machine[J]. Industrial Engineering Journal, 2022, 25(6): 152-159.

[3] 姚洵,潘尔顺.基于两视图半监督学习的产品质量问题识别方法[J].工业工程,2023,26(3):86-94.
YAO Chi, PAN Ershun. Identification method of product quality problems based on two-view semi-supervised learning[J]. Industrial Engineering Journal, 2023, 26(3): 86-94.

[4] 刘颀,高文科,张志胜,等.基于多尺度估计理论的晶圆减薄工艺方差变化检测方法[J].工业工程,2018,21(3):75-81.
LIU Yang, GAO Wenke, ZHANG Zhisheng, et al. A study of the standard deviation change in the wafer thinning process based on the multiscale estimation theory[J]. Industrial Engineering Journal, 2018, 21(3): 75-81.

[5] 叶祎旋,李艳婷.基于 CNN-集成学习的多风电机组故障诊断[J].工业工程,2022,25(1):136-143.
YE Yini, LI Yanting. Fault diagnosis of multi wind turbine based on CNN-ensemble learning[J]. Industrial Engineering Journal, 2022, 25(1): 136-143.

[6] GAO Y, GAO L, LI X, et al. A multilevel information fusion-based deep learning method for vision-based defect recognition[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 3980-3991.

[7] GAO Y, LI X, WANG X V, et al. A review on recent advances in vision-based defect recognition towards industrial intelligence[J]. Journal of Manufacturing Systems, 2022, 62: 753-766.

[8] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493-1504.

[9] GAO Y, GAO L, LI X. A hierarchical training-convolutional neural network with feature alignment for steel surface defect recognition[J]. Robotics and Computer-Integrated Manufacturing, 2023, 81: 102507.

[10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[11] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale[DB/OL]. (2020-10-22). <https://doi.org/10.48550/arXiv.2010.119290>.

[12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C/OL]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE (2016-12-12). <https://ieeexplore.ieee.org/document/7780459>.

[13] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size[DB/OL]. (2016-02-24). <https://doi.org/10.48550/arXiv.1602.07360>.

[14] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[DB/OL]. (2021-03-25). <https://doi.org/10.48550/arXiv.2103.14030>.

[15] CHEON S, LEE H, KIM C O, et al. Convolutional neural network for wafer surface defect classification and the detection of unknown defect class[J]. IEEE Transactions on Semiconductor

- Manufacturing*, 2019, 32(2): 163-170.
- [16] WEI Y, WANG H. Mixed-type wafer defect recognition with multi-scale information fusion transformer[J]. *IEEE Transactions on Semiconductor Manufacturing*, 2022, 35(2): 341-352.
- [17] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[DB/OL]. (2014-06-0) . <https://arxiv.org/abs/1406.2661>.
- [18] HE Y, SONG K, DONG H, et al. Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network[J]. *Optics and Lasers in Engineering*, 2019(122): 294-302.
- [19] HU G, HUANG J, HUANG X, et al. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network[J]. *Textile Research Journal*, 2020, 90(3-4): 247-270.
- [20] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[DB/OL]. (2016-01-07). <https://doi.org/10.48550/arXiv.1511.06434>.
- [21] NIU S, LI B, WANG X, et al. Defect image sample generation with GAN for improving defect Recognition[J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 17(3): 1611-1622.
- [22] YANG J, FU G, ZHU W, et al. A Deep learning-based surface defect inspection system using multiscale and channel-compressed features[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(10): 8032-8042.
- [23] LIU Z, YANG B, DUAN G, et al. Visual defect inspection of metal part surface via deformable convolution and concatenate feature pyramid neural networks[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(12): 9681-9694.
- [24] ZHANG D, SONG K, WANG Q, et al. Two deep learning networks for rail surface defect inspection of limited samples with line-level label[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(10): 6731-6741.
- [25] LI Y, YANG M, HUA J, et al. A channel attention-based method for micro-motor armature surface defect detection[J]. *IEEE Sensors Journal*, 2022, 22(9): 8672-8684.
- [26] ZHU Y, XIE L, YIN M, et al. Convolution with rotation invariance for online detection of tiny defects on Magnetic tile surface[J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 5021412 (2023-07-14). <https://ieeexplore.ieee.org/document/10184057>.
- [27] WANG Y, HUANG J, WANG Y, et al. A CNN-based adaptive surface monitoring system for fused deposition modeling[J]. *IEEE/ASME Transactions on Mechatronics*, 2020, 25(5): 2287-2296.
- [28] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [DB/OL]. (2017-04-17). <https://doi.org/10.48550/arXiv.1704.04861>.
- [29] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C/OL]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE (2018-12-16) . <https://ieeexplore.ieee.org/abstract/document/8578572>.
- [30] QIAN S, NING C, HU Y. MobileNetV3 for image classification[C/OL]//2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE) . New York: IEEE (2021-04-02) . <https://ieeexplore.ieee.org/document/9389905>.
- [31] MEHTA S, RASTEGARI M. MobileViT: light-weight, general-purpose, and mobile-friendly vision transformer[DB/OL]. (2021-10-05) . <https://doi.org/10.48550/arXiv.2110.02178>.
- [32] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C/OL]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE (2018-12-16). <https://ieeexplore.ieee.org/abstract/document/8578814>.
- [33] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[DB/OL]. (2015-03-09) . <https://doi.org/10.48550/arXiv.1503.02531>.
- [34] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[DB/OL]. (2015-12-08). https://doi.org/10.1007/978-3-319-46448-0_2.
- [35] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C/OL]//Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE (2016-12-12). <https://ieeexplore.ieee.org/document/7780460>.
- [36] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C/OL]//Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE (2017-11-09) . <https://ieeexplore.ieee.org/document/8100173>.
- [37] REDMON J, FARHADI A. YOLOv3: an incremental improvement[DB/OL]. (2018-04-08). <https://doi.org/10.48550/arXiv.1804.027678>.
- [38] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C/OL]//European Conference on Computer Vision. Cham: Springer International Publishing (2020-11-03). <https://doi.org/10.48550/arXiv.2005.12872>.
- [39] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C/OL]//Proceedings of the IEEE International Conference on Computer Vision. New York: IEEE (2017-11-25). <https://ieeexplore.ieee.org/document/8237586>.
- [40] TIAN Z, SHEN C, CHEN H, et al. FCOS: fully convolutional one-stage object detection[C/OL]//Proceedings of the IEEE/CVF International Conference on Computer Vision. New York: IEEE (2020-02-27). <https://ieeexplore.ieee.org/document/9010746>.
- [41] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [42] LIU Y, GAO H, GUO L, et al. A data-flow oriented deep ensemble learning method for real-time surface defect inspection [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(7): 4681-4691.
- [43] BLOCK S B, DA SILVA R D, DORINI L B, et al. Inspection of imprint defects in stamped metal surfaces using deep learning and tracking[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(5): 4498-4507.
- [44] WU Y, CHEN P, QIN Y, et al. Automatic railroad track components inspection using hybrid deep learning framework[J/OL].

- IEEE Transactions on Instrumentation and Measurement, 2023, 72: 5011415 (2023-04-10). <https://ieeexplore.ieee.org/document/10098120>.
- [45] LIU Z, MAO H, WU C Y, et al. A ConvNet for the 2020s[C/OL]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE (2022-12-27). <https://ieeexplore.ieee.org/document/9879745>.
- [46] CHENG X, YU J. RetinaNet with difference channel attention and adaptively spatial feature fusion for steel surface defect detection[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 2503911 (2020-11-25). <https://ieeexplore.ieee.org/document/9270024>.
- [47] ZENG N, WU P, WANG Z, et al. A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3507014 (2022-02-24). <https://ieeexplore.ieee.org/abstract/document/9720996>.
- [48] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C/OL]//Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE (2017-11-09). <https://ieeexplore.ieee.org/document/8099589>.
- [49] YEUNG C C, LAM K M. Efficient fused-attention model for steel surface defect detection[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2510011 (2022-05-18). <https://ieeexplore.ieee.org/document/9777969>.
- [50] NI X, MA Z, LIU J, et al. Attention network for rail surface defect detection via consistency of intersection-over-union (IoU) - guided center-point estimation[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3): 1694-1705.
- [51] LUO J, YANG Z, LI S, et al. FPCB surface defect detection: a decoupled two-stage object detection framework[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5012311 (2021-06-25). <https://ieeexplore.ieee.org/document/9465824>.
- [52] GAO Y, GAO L, LI X. A two-stage focal transformer for human-robot collaboration-based surface defect inspection[J]. ASME Journal of Manufacturing Science and Engineering, 2023: 1-32.
- [53] GAO L, ZHANG J, YANG C, et al. Cas-VSwin transformer: a variant swin transformer for surface-defect detection[J]. Computers in Industry, 2022, 140: 103689 (2022-11).
- [54] ZHOU H, YANG R, HU R, et al. ETDNet: Efficient Transformer-based detection network for surface defect detection [J/OL]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2525014 (2023-08-23). <https://ieeexplore.ieee.org/abstract/document/10227321>.
- [55] LU H, FANG M, QIU Y, et al. An anchor-free defect detector for complex background based on pixelwise adaptive multiscale feature fusion[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 5002312 (2022-12-19). <https://ieeexplore.ieee.org/document/9992183>.
- [56] ZHANG K, LOU W, WANG J, et al. PA-DETR: End-to-end visually indistinguishable bolt defects detection method based on transmission line knowledge reasoning[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 5016914 (2023-06-09). <https://ieeexplore.ieee.org/document/10147381>.
- [57] WANG C, XIE H. MeDERT: a metal surface defect detection model[J]. IEEE Access, 2023, 11: 35469-35478.
- [58] YUKSEL V, TETIK Y E, BASTURK M O, et al. A novel cascaded deep learning model for the detection and quantification of defects in pipelines via magnetic flux leakage signals[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2512709 (2023-05-02). <https://doi.org/10.1109/TIM.2023.3272377>.
- [59] SILVÉN O, NISKANEN M, KAUPPINEN H. Wood inspection with non-supervised clustering[J]. Machine Vision and Applications, 2003, 13(5-6): 275-285.
- [60] TABERNIK D, ŠELA S, SKVARČ J, et al. Segmentation-based deep-learning approach for surface-defect detection[J]. Journal of Intelligent Manufacturing, 2020, 31(3): 759-776.
- [61] LONG J, SHEHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[C/OL]//Proceedings of the IEEE conference on computer vision and pattern recognition. New York: IEEE (2016-05-24). <https://ieeexplore.ieee.org/document/7478072>.
- [62] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [63] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [64] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[DB/OL]. (2017-06-17). <https://doi.org/10.48550/arXiv.1706.05587>.
- [65] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[DB/OL]. (2015-05-18). <https://doi.org/10.48550/arXiv.1505.04597>.
- [66] DONG H, SONG K, HE Y, et al. PGA-Net: pyramid feature fusion and global context attention network for automated surface defect detection[J]. IEEE Transactions on Industrial Informatics, 2020, 16(12): 7448-7458.
- [67] LUO Q, SU J, YANG C, et al. CAT-EDNet: cross-attention transformer-based encoder-decoder network for salient defect detection of strip steel surface[J/OL]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 5009813 (2022-04-14). <https://ieeexplore.ieee.org/abstract/document/9757932>.
- [68] ZHANG Q, LAI J, ZHU J, et al. Wavelet-guided promotion-suppression transformer for surface-defect detection[J]. IEEE Transactions on Image Processing, 2023, 32: 4517-4528.
- [69] WANG Y, NIU M, SONG K, et al. Normal-knowledge-based pavement defect segmentation using relevance-aware and cross-reasoning mechanisms[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 4413-4427.
- [70] BOŽIČ J, TABERNIK D, SKOČAJ D. Mixed supervision for surface-defect detection: from weakly to fully supervised learning[DB/OL]. (2021-04-13). <https://doi.org/10.1016/j.compind.2021.103459>.