

引用格式:刘逸康,张铭煊,余倩倩. 基于计算机视觉的钢结构损伤检测综述[J]. 工业建筑, 2026, 56(5): 215-231. LIU Yikang, ZHANG Mingxuan, YU Qianqian. A Review of Computer Vision-Based Damage Detection in Steel Structures [J]. Industrial Construction, 2026, 56(5): 215-231 (in Chinese). DOI: 10. 3724/j. gyjzG26033109

基于计算机视觉的钢结构损伤检测综述^{*}

刘逸康^{1,2} 张铭煊^{1,2} 余倩倩^{1,3}

(1. 同济大学建筑工程系, 上海 200092; 2. 同济大学工程结构性能演化与控制教育部重点实验室, 上海 200092; 3. 同济大学土木工程防灾减灾全国重点实验室, 上海 200092)

摘 要 高效可靠的钢结构健康监测是保证结构安全、延长服役寿命的关键。当前, 计算机视觉 (Computer Vision, CV) 技术因其非接触、效率高和自动化程度高等优势, 正逐渐成为钢结构运维检测的重要技术手段。围绕钢结构表面裂纹与腐蚀损伤, 系统梳理了计算机视觉技术在钢结构损伤检测中的研究进展, 归纳了图像分类、目标检测和图像分割等主要方法, 重点总结了现有研究在微小目标识别、复杂背景抑制、小样本训练及工程现场部署等方面的关键优化策略。现有研究表明, 计算机视觉技术有效提升了钢结构损伤检测的自动化、智能化和精细化水平, 但在数据集规范化、模型抗干扰能力、跨场景泛化能力和轻量化实时推理等方面仍有进一步发展空间。

关键词 钢结构; 损伤检测; 计算机视觉; 深度学习

A Review of Computer Vision-Based Damage Detection in Steel Structures

LIU Yikang^{1,2} ZHANG Mingxuan^{1,2} YU Qianqian^{1,3}

(1. Department of Structural Engineering, Tongji University, Shanghai 200092, China; 2. Key Laboratory of Performance Evolution and Control for Engineering Structures, Tongji University, Shanghai 200092, China; 3. State Key Laboratory of Disaster Reduction in Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract: Efficient and reliable structural health monitoring is essential for ensuring the safety and extending the service life of steel structures. Owing to the advantages of non-contact nature, high efficiency, and a high degree of automation, computer vision (CV) has gradually become an important technology for the inspection and maintenance of steel structures. Focusing on surface cracks and corrosion damage of steel structures, this review systematically summarizes the recent research progress in CV-based damage detection and outlines the major approaches, including image classification, object detection, and image segmentation. Particular attention is paid to key optimization strategies for small object detection, robustness under complex backgrounds, few-shot learning, and on-site deployment. Existing studies indicate that CV has significantly improved the automation, intelligence, and precision of damage detection for steel structures. However, further advances are still required in dataset standardization, model robustness to interference, generalization capability across scenarios, and lightweight real-time inference.

Keywords: steel structure; damage detection; computer vision; deep learning

^{*} 国家自然科学基金项目(52578239, 52222803)。

第一作者: 刘逸康, 硕士研究生, 主要从事钢结构性能检测方向研究, 2430876@tongji.edu.cn。

通信作者: 余倩倩, 博士, 教授, 主要从事结构性能演化与控制方向研究, qianqian.yu@tongji.edu.cn。

收稿日期: 2026-03-31

钢结构因强度高、自重轻、施工便捷等优势,在桥梁、工业建筑及公共建筑等工程领域得到广泛应用^[1]。随着建筑业进入高质量发展阶段,钢结构行业的发展重心正由规模扩张逐步转向绿色化、智能化与工业化并重的发展路径,在城市更新、新型基础设施建设及既有工程运维中的作用日益凸显^[2]。在长期服役过程中,既有钢结构不可避免地受到环境作用与服役荷载的共同影响,进而产生多种形式的性能劣化与局部损伤,如疲劳、腐蚀、螺栓脱落等^[3-4](图1)。传统钢结构损伤检测主要依赖人工目视巡检以及超声、磁粉等常规无损检测技术。这类方法虽然在局部精细检测中具有一定优势,但通常存在作业效率较低、对人员经验依赖较强、检测成本较高以及大范围连续巡检困难等问题,而常规非破坏性检测技术^[5-6],虽具备一定量化能力,但在大尺度结构快速筛查中成本高昂、操作复杂,难以实现常态化监测,难以充分满足现代大型复杂钢结构高频次、全覆盖的智能化运维需求。



图1 钢结构损伤

Fig. 1 Damage images of steel structures

随着人工智能技术和低成本图像采集硬件的快速发展,基于计算机视觉的钢结构损伤检测方法因具有非接触、高效率和自动化程度高等特点,正逐渐成为钢结构工程运维中的重要研究方向和关键技术手段^[7]。该方法早期主要是数字图像处理技术(IPT)^[8],包括形态学处理^[9]、阈值分割^[10]、二值化^[11]、直方图均衡^[12]、边缘检测^[13]等,对于理想光照和纹理下的损伤图像处理具有一定的适用性,但其精度取决于选取特征的质量,在实际工程应用中,裂纹、腐蚀等小目标往往受限于复杂背景干扰、特征选取困难等问题。

经过多年发展,深度学习(Deep Learning, DL)算法能够从输入图像中自动提取适用于该任务的特征,无需依赖经验和人为设计特征,在特征提取方面比图像处理方法更具鲁棒性,现已被广泛应用于土木工程领域中的损伤识别。在Web of Science对“计算机视觉”“钢结构”“损伤”进行近5年文献的

搜索,对96篇论文进行关键词共现图绘制,如图2所示。早期研究多遵循工程实施顺序^[14]或围绕具体损伤类型^[15]展开,之后研究视角转向方法学分类,如依据数据标注范式^[16]或技术原理类别^[17]构建框架,并深入剖析核心网络结构的技术演进脉络与共性挑战^[18]。近期研究进一步体现出细分化与交叉融合趋势,在检测任务维度上细化为分类、定位、分割^[19],并针对纹理干扰等具体特征进行专述^[20],部分将视觉检测的功能从静态缺陷识别拓展至动态参数测量与多模态感知^[21],从而构建起更为系统且面向实际工程约束的知识体系。




图2 钢结构损伤关键词共现图

Fig. 2 Co-occurrence network of keywords for steel structure damage

随着Transformer架构、扩散模型、自监督预训练等新技术的兴起以及边缘计算设备、无人机自主巡航、5G传输等硬件平台的进步,实际钢结构损伤检测中面临的小目标、小样本检测^[22]以及现场实时推理难的问题迎来了新的算法突破与技术革新。

1 钢结构表面裂纹检测

钢结构表面裂纹是其服役期间最常见的损伤形式之一,通常由疲劳问题引起,高发于焊缝、切口、连接细节等应力集中区域。传统的人工目视检测存在检测效率低、主观性强等局限,难以满足重大工程海量巡检与高可靠性要求^[23-24]。近年来,计算机视觉技术与深度学习方法不断发展,已能够针对钢结构疲劳高发区域进行结构表面裂纹的识别、

定位与定量表征^[25-27]。

1.1 基于卷积神经网络(CNN)的裂纹检测模型

基于计算机视觉和深度学习的裂纹检测方法

主要是用大量标注的图像训练深度学习模型进行裂纹检测,主要包括三类任务,即图像分类、目标检测和图像分割,如图3所示。




图3 钢结构损伤分类识别、目标检测、分割检测

Fig. 3 Classification, object detection, and segmentation of damage in steel structures

1) 图像分类算法能够自动对输入图像中的裂纹、腐蚀和螺栓缺失等损伤进行分类,当前主流网络以卷积神经网络(CNN)为核心,如 AlexNet^[28]、VGGNet^[29]、ResNet^[30]、GoogLeNet^[31]和 DenseNet^[32]等,通常模型相对简单,计算速度较快。Vannocci等^[33]在热轧钢带缺陷场景下的对比研究表明,CNN模型对缺陷的分类性能显著优于传统机器学习方法,测试集准确率可达90%;而针对钢桥检测场景,Xu等^[34]提出一种基于图像分块的深度融合分类策略,将消费级相机采集的高分辨率图像切分为多尺度子图并进行判定,有效规避了全局视角的特征丢失。

2) 目标检测算法则通过边界框(Bounding Box)实现了裂纹的空间定位。现有方法主要包括以R-CNN系列为代表的两阶段检测框架^[35-37]和以YOLO系列为代表的一阶段检测框架^[38-40],通常两阶段算法更侧重精度,而一阶段算法则更侧重效率。Cha等^[41]将Faster R-CNN用于五类结构损伤的同步检测,五类损伤的平均精度(mAP)达到87.8%;Suh等^[42]使用的Deep Faster R-CNN模型在多类型损伤自动检测与定位中取得了77.97%的平均精度。

3) 相比前两者,图像分割算法实现了像素级裂纹表征,不仅能精确提取裂纹的边界与细部形态,还能直接服务于裂纹长度、宽度等关键几何参数的计算。当前主流网络多采用编码器-解码器结构,如FCN^[43]、U-Net^[44]和 Deeplabv3+^[45-47]等模型及其

改进模型。Liu等^[48]提出的DeepCrack能够以端到端的方法预测逐像素的裂纹分割,在包含537张裂纹图像的自建数据集上平均交并比(mIoU)达到85.9%;类似地,Dong等^[49]也针对钢结构大幅面图像提出了基于改进U-Net的裂纹分割框架,在测试集上mIoU达到65.06%,优于FCN网络的57.74%。

这三类算法并非完全独立,而是在不同工程需求下各有适用性,如分类、目标检测算法适用于海量巡检图像的快速筛查与标记,而分割算法能提供更高精度的裂纹几何尺寸与细部形态,因此实际钢结构表面裂纹检测往往根据任务需求选择不同的算法。

1.2 关键优化技术

随着深度学习的发展,更多研究关注到钢结构相比其他结构或建筑的特殊性,相关研究的核心问题逐渐集中于复杂背景下微小裂纹的准确检测、小样本条件下的模型训练以及面向现场巡检的实时部署等方面。

1.2.1 小目标检测与复杂背景抑制

不同于混凝土裂纹,钢结构裂纹尺寸更加微小、形态细长,一般在图像中的像素占比也很小,因此属于典型小目标检测问题^[22]。此外,真实裂纹图像中往往包含焊缝、划痕和阴影等复杂背景干扰,在形态和纹理上容易与真实裂纹混淆,因此在模型判断时容易产生误检[图4(g)、图4(h)]和漏检[图4(h)、图4(i)]^[50-51]。

图4 钢箱梁裂纹检测失败案例^[51]

Fig. 4 Failure cases of crack detection in steel box girders

当前,有许多研究对深度学习模型进行优化以增强其对小目标的感知能力。一种优化思路是在模型中集成金字塔型的采样方法,提取图像在不同尺度下的特征图,将所有特征图同时用于模型后续的检测头,以此增强模型对小目标的检测能力^[52]。需要注意的是,该方法在提升小裂纹检测能力的同时,也可能使模型对噪声更加敏感,在降低漏检率的同时误检率增加,如引入特征金字塔(FPN)^[53]改进后的 Faster R-CNN 模型对细裂纹的平均精度均值(mAP)仅为 50.1%^[54]。除 FPN 外,也有研究通过残差卷积和上下文编码增强细裂纹特征提取能力,提出的 R2CE-Net 裂纹检测准确率达到 98.62%、mIoU 达到 80.93%^[55]。

另一种优化思路则是将高分辨率的裂纹图像划分为多张低分辨率的子图,在局部尺度上提高裂纹显著性,再通过后续融合恢复全图结果^[50,56-57]。Meng 等^[58]将高分辨率钢箱梁图像先划分为子图,再进行裂纹区域定位和边缘细化,测试集召回率(Recall)达到 0.95;Zhang 等^[50]采用集成式框架,将前端判别、像素级分割与后续推理结合起来,以提高复杂背景下钢箱梁裂纹的识别可靠性。

总之,合理引入多尺度采样与图像切分方法,

可以一定程度上缓解微小裂纹像素占比低、背景干扰大等特征问题,实现复杂工程环境中裂纹检测精度的提升。

1.2.2 小样本条件下的模型训练

除裂纹尺寸小及实际背景复杂的特点外,当前钢结构裂纹相关的公开数据集较少,而深度学习模型极大依赖于训练数据,小样本可能无法完全发挥模型的性能,甚至可能产生负面影响,因此许多研究尝试对数据集构建和模型训练过程进行优化,进而增大数据集体量,或使得模型在小数据集上也能训练得到较好的结果,从而增强裂纹检测的精度。

在数据集构建时,除旋转、平移、错切、反转、缩放、添加噪声和颜色变换等基础数据增强方法外,也可以使用虚拟合成数据构建数据集,更加省力高效。如创建具有疲劳裂纹的钢结构表面的随机纹理并映射至三维模型中,通过改变照明条件和相机角度来合成图像以增强真实数据集,研究结果表明,相比于仅使用真实数据,采用包含真实图像和虚拟合成图像的混合数据集训练模型,裂纹检测准确率从 49% 提升到 62%,交并比(IoU)从 35% 提升到 40%^[59]。另外,当数据集中包含更多的复杂背景时,模型对于背景的抗干扰能力也会增强。有研究

表明,在训练集中针对性地引入含有焊缝、划痕等干扰信息的背景切片(Patch),可大幅增强模型对现实场景的鲁棒性并显著降低假阳性率^[51,60-61]。

除采用上述方法扩展真实数据集外,迁移学习也是一种针对小样本学习的有效方法^[47,62]。迁移学习是指在已采用大型数据集预先训练的模型基础上,再针对新问题小样本数据进行二次训练的方法。由于深度学习模型浅层部分主要检测边缘、纹理等特征,而这些特征对于类似场景是通用的,因此通过迁移学习可以直接利用浅层的权重参数,仅对深层部分重新训练,从而节省训练时间,且使得模型对于小样本也能有较好的性能。Dung等^[63]采用了在ImageNet数据集上预训练的VGG16网络进行钢桥裂纹分类检测,结果表明迁移学习相比于从零训练裂纹检测的准确率从90%提升到97%;Yu等^[64]提出的基于视频流特征点跟踪的钢表面裂纹检测方法,其用于特征匹配的改进LoFTR模型也采用了类似的预训练和微调策略,预训练阶段使用ScanNet数据集^[65],并用自建的钢板裂纹数据集进行了微调,使模型有效学习并适应目标领域的特性,有效提升了钢表面图像的匹配性能。

综上所述,针对钢结构表面裂纹检测面临的小样本问题,通过不同数据增强方法扩充原始数据集及基于大型通用数据集预训练模型进行微调与迁移均是增强裂纹检测精度的可行方案。

1.2.3 面向现场的实时部署优化

在实际工程部署中,钢结构表面裂纹检测模型的实时推理能力主要受两方面制约:1)现场图像通常分辨率较高而裂纹占比很小,直接进行整图分割计算代价较高。2)无人机或移动终端的算力、存储和续航能力均较为有限,难以长期运行参数量大、推理链路复杂的深度模型。因此,面向现场的模型设计更强调在有限算力条件下兼顾检测速度、稳定性与量化能力。当前提高检测效率的技术路径主要包括粗到细联动检测和网络轻量化重设计等。

粗到细的联动检测流程是提升现场效率最直接的手段,其核心是充分利用较快的分类器和检测器筛查候选区域,再在局部尺寸上用分割模型进行精细分割与尺寸计算。Han等^[66]先利用YOLOv3粗略提取候选区域后,联合多个Deeplabv3+模型进行像素级精细提取,并辅以全景拼接技术直观重构了裂纹形貌。Meng等^[67]进一步提出基于无人机的实时自动裂纹检测方法,采用轻量分类、轻量分割、高

精度分割和裂纹宽度测量相结合的多阶段流程,本质也是通过分级推理降低整图精细识别的计算负担。该方法既保留了局部细节,又避免了整图高精度推理带来的高时延,较适用于钢结构裂纹的现场检测。

此外,轻量化的模型设计也是提高推理速度的方法之一。早期的轻量化更多体现在以SqueezeNet^[68]、MobileNet^[69]、EfficientNet^[70]和ShuffleNet^[71]等轻量骨干替换传统卷积主干,以降低参数量和内存占用。近年来则进一步扩展到对特征融合路径^[72]和检测头的重设计,Lu等^[73]将DeepLabv3+主干替换为MobileNetv3,并对上下文特征提取模块进行重设计,在兼顾识别精度的同时参数量、浮点运算和训练时间分别减少了91.18%、73.18%和35.55%。类似地,改进的CSCP-YOLO模型将参数量大幅压缩至14.3 MB,同时在高端算力下达到了186.2每秒帧率(FPS)的高频实时检测,但mAP略微下降到79.1%^[74]。因此,在钢结构表面裂纹检测中,通过轻量骨干与关键模块协同优化可以有效提升实时推理效率。

现阶段,粗到细联合检测及网络轻量化重设计已在钢桥裂纹与钢结构表面裂纹研究中展现出较好的工程适用性。此外模型剪枝、知识蒸馏等模型压缩方法也可压缩模型规模^[75]。

1.3 小结

钢结构表面裂纹的计算机视觉检测方法现已形成由分类识别、目标定位到像素级分割与几何量化的基本技术路径,但从工程应用角度看,现有方法仍面临裂纹尺寸微小、实际图像背景复杂、小样本训练和实时部署算力限制等挑战。

需要指出的是,当前计算机视觉方法主要针对结构表面可见裂纹,通常难以检测防腐或防火涂层下的近表面裂纹或缺陷。未来通过引入其他模态的图像或数据,如热成像^[76-78]、激光成像^[79]、结构光^[80]或深度图^[81]等,利用不同模态之间的互补信息提升裂纹分割与量化性能是更具潜力的研究方向。此外,通过纳米涂层传感器与电位差监测来跟踪疲劳裂纹萌生与扩展也是涂层下近表面裂纹检测的方向之一^[82]。

因此,未来钢结构疲劳裂纹检测的发展方向将集中于早期微小裂纹的准确识别、复杂背景下的稳健检测、小样本条件下的有效训练,以及面向现场应用的实时推理与多模态协同感知。

2 钢结构腐蚀检测

随着我国基础设施建设进入存量时代,大量服役中的钢结构设施面临长期环境侵蚀、疲劳累积和材料退化等问题,其中腐蚀作为最普遍的劣化形式之一,严重威胁结构安全性和耐久性^[83]。尤其在沿海、高湿度或工业污染区域,钢材表面氧化反应加速,形成局部点蚀、均匀腐蚀乃至结构性截面削弱,若未能及时识别与干预,可能导致突发性断裂事故。已有综述集中于特定检测场景^[84]、算法模型^[85],Das等^[86]在2024年对钢结构图像腐蚀检测进行了系统评述,通过融合多模态数据构建量化评估体系,致力于检测后的评估与工程整合。基于此,本章将聚焦于腐蚀等级的精细化划分与面向实际应用的算法优化。

2.1 腐蚀分级标准

钢结构构件表面通常有防腐防火涂层保护,因此仅针对涂装前钢材的腐蚀等级分类标准并不适用于钢结构质量检测中的腐蚀等级分类。我国的GB/T 6461—2002《金属基体上金属和无机覆盖层经腐蚀试验后的试样和试件的评级》^[87]中对于基体的腐蚀等级和覆盖层的破坏类型评价如表1和表2所示。

表1 基体腐蚀等级评价		
Table 1 Evaluation of substrate corrosion grade		
序号	面积锈蚀率 η	锈蚀等级 L
1	无腐蚀	10
2	$0 < \eta \leq 0.1$	9
3	$0.1 < \eta \leq 0.25$	8
4	$0.25 < \eta \leq 0.5$	7
5	$0.5 < \eta \leq 1.0$	6
6	$1.0 < \eta \leq 2.5$	5
7	$2.5 < \eta \leq 5.0$	4
8	$2.5 < \eta \leq 10$	3
9	$10 < \eta \leq 25$	2
10	$25 < \eta \leq 50$	1
11	$50 < \eta$	0

欧洲、美国及国际标准针对涂层钢结构的腐蚀评价,均以腐蚀面积比例为核心划分依据,但在等级设置上各有不同,如表3所示。欧洲标准将腐蚀程度分为10级;美国ASTM D610标准^[88]将腐蚀类型区分为点蚀、普通腐蚀与针蚀,并进一步按面积比例划分出11个腐蚀等级;ISO 4628-3标准^[89]则将其分为6级。这三种分类体系虽然划分严密,但在

表2 涂层破坏类型		
Table 2 Types of coating damage		
序号	破坏特征	缺陷类型
1	涂层损坏导致斑点和颜色变化	A
2	很难看见,或者看不见的涂层腐蚀导致的发暗	B
3	阳极性覆盖层的腐蚀产物	C
4	阴极性覆盖层的腐蚀产物	D
5	表面出现点蚀	E
6	碎落、起皮、剥落	F
7	鼓泡	G
8	开裂	H
9	龟裂	I
10	鸡爪状或星状缺陷	J

表3 钢结构腐蚀等级分级标准比较			
Table 3 Comparison of corrosion classification standards for steel structures			
腐蚀等级	腐蚀面积比例(%)		
	欧洲腐蚀等级标准	ASTM D610	ISO 4628-3
0	0	≤ 0.01	0
1	0.05	0.01~0.03	0.05
2	0.5	0.03~0.1	0.5
3	1	0.1~0.3	1
4	3	0.3~1.0	8
5	8	1.0~3.0	40~50
6	15~20	3.0~10.0	
7	45~50	10.0~16.0	
8	75~85	16.0~33.0	
9	95	33.0~50.0	
10		> 50	

工程实践的具体应用中仍存在明显不足,尤其是对腐蚀面积比例在0%~10%区间内的过细分级,增加了腐蚀图像自动识别的难度,已超出当前常见深度学习算法能够稳定达到的识别精度。现有算法多基于标准简化调整,设计不同场景下钢结构腐蚀的分级^[90]。

2.2 计算机视觉相关技术发展

2.2.1 基于CNN的腐蚀检测模型

钢结构腐蚀检测的核心目标是获取腐蚀的相关特征参数,包含腐蚀类型、面积、三维信息等。腐蚀面积直观反映钢结构表面的腐蚀区域,是腐蚀等级划分的核心依据;腐蚀三维信息决定构件的结构承载能力,直接关系到钢结构的安全服役性能。下文将结合具体技术路径梳理其发展现状。

对于图像采集设备采集的图像,既需要判断该图像中是否有腐蚀,又需要对图像中存在腐蚀的程度

进行分级,以便采取不同的维修措施。图像分类问题,即判断有无腐蚀,Petricca 等^[91]比较传统图像处理和深度学习在腐蚀分类的性能,结果表明深度学习方法在实际应用中表现更好。Atha 等^[92]比较不同 CNN 模型的腐蚀检测性能,并探究了网络层数、输入图像色彩空间以及滑动窗口大小对分类准确率的影响。对于腐蚀等级评估,即自动识别图像中的腐蚀严重程度,其核心依赖腐蚀面积的量化分析。Holm 等^[93]比较使用了 AlexNet、VGG16、ResNet 和 GoogLeNet 的性能,结果表明,VGG-16 总体表现最佳,在损伤检测类别中,AlexNet 表现最佳,准确率为 99.14%。上述结果表明,将 CNN 运用到腐蚀图像分类任务中,可以得到较理想的性能^[94-95]。Xu 等^[96]为进一步提升模型的性能,将多个 CNN 模型的识别结果进行结合,发现单个 CNN 分类器的精度最高达 90%,通过集成学习可以将腐蚀等级分类精度提高到 93%。

目前研究的 CNN 分类器适用于特定环境下的腐蚀构件,准确率基本可以达到使用要求,是一种快速、准确的腐蚀等级评估方法。但仅对图像进行分类已无法满足腐蚀检测的要求,需要确定腐蚀位置,并对腐蚀区域进行定性或者定量描述。基于深度学习的目标检测方法,大致可以分为两类,即单阶段(One-Stage)检测器和二阶段(Two-Stage)检测器。最具代表性的是 Faster RCNN^[97-98]和 YOLO^[99]系列,它们通过预定义不同尺寸形状的 anchor 来检测不同尺寸形状的目标区域,从而实现目标的定位和分类。Jia 等^[100]开发了用于检测公共设施腐蚀的 Corrosion-YOLOv5s 模型,它使用金属腐蚀图像数据集表现出出色的检测精度。Nabizadeh 等^[101]训练了 YOLOv3、YOLOv5s、YOLOv7 模型,并将其在混凝土腐蚀图像上进行测试,发现 YOLOv5 在混凝土腐蚀检测方面表现最好。Ameli 等^[102]构建了一个带有注释的钢桥腐蚀开源数据集,通过训练,验证了 Mask RCNN 和 YOLOv8 算法在腐蚀分割和分级方面的性能良好。Yu 等^[103]提出的 YOLOv5-GOLD-NWD 模型在涂层金属表面腐蚀检测中实现了 78% 的检测精度,较传统 YOLOv5 模型提升了 4%。

在钢结构腐蚀检测的工程实践中,若腐蚀沿构件对角线方向呈细长形态分布,矩形边界框往往包含大量背景区域,导致腐蚀面积估算误差显著。为从根本上解决边界框冗余引起的误判问题,需采用像素级分割方法,分为语义分割与实例分割两类算

法。语义分割算法可将图像中所有像素按腐蚀、钢材基体、背景等语义属性进行分类,实现腐蚀区域与非腐蚀区域的全局像素级区分,实例分割算法则在此基础上进一步区分不同腐蚀个体^[104]。针对分割算法的工程落地,研究者开展了大量实践。王达磊等^[105]基于 U-Net 架构设计了深度神经网络,对提取到的腐蚀区域进行了定量分析,但模型主要在自建数据集上有效。Pirie 等^[104]对 CNN、YOLO 和 Mask RCNN 的性能进行比较,发现 Mask RCNN 针对水下腐蚀分割图像表现最优。Fondevik 等^[106]基于自建数据集训练 Mask R-CNN 和 PSPNet 网络,结果发现在红色背景下效果较差,数据集规模不够。Duy 等^[85]把具有 DenseNet 和 PSPNet 层的全卷积网络与 U-Net、E-Net 进行比较,发现实际应用中同时包含 U-Net 和 FCN 的性能更好。Katsamenis 等^[107]将 RGB 图像输入经过 FCN、U-Net 和 Mask RCNN 三种语义分割网络,通过形态学运算,得到高置信度和低置信度的区域,运用分水岭算法得到最终的准确边界。整体来看,深度学习腐蚀检测精度受数据集规模和分割数据集标注困难的限制,同时腐蚀的形状不规则、区域不连续,标注主要依赖于标注者的主观性,会导致标注质量不稳定且耗时耗力。

腐蚀的深度检测旨在通过技术手段获取场景中目标的三维空间深度信息,是计算机视觉领域实现从二维感知到三维理解的核心任务之一。传统深度检测方法,如结构光法、立体匹配法,受限于是手工特征设计,在复杂场景下鲁棒性不足,而深度学习凭借其强大的特征自动学习能力,显著突破了传统方法的瓶颈,成为当前腐蚀深度检测研究的主流方向。Akhlaghi 等^[108]针对埋地管道点蚀深度预测的多环境特征耦合问题,提出两类深度学习模型,该模型通过反馈连接记忆土壤氯化物含量与点蚀深度的历史关联,在高盐土壤场景的误差 <5%,证明深度学习在复杂环境特征建模上的优势。Gao 等^[109]针对铁路滑床板的锈蚀深度检测,提出 VGG 和 ResNet50 的融合模型,在 72 h 中性盐雾试验(等效自然环境 3a)样本上,深度预测相对误差平均值仅 4.08%,显著优于超声检测,且在现场粉尘干扰下仍保持较小的误差。Zhang 等^[110]提出基于 CNN 的区域关联模型,突破了传统深度学习孤立区域建模的局限,通过区域交互特征提取,更贴合工程中管道多锈蚀共存的实际场景。

目前对于仅依靠 RGB 可见光图像的深度学习

模型较少。秦荣杰^[111]将跨尺度注意力Transformer用于钢板锈蚀检测,利用单反相机收集钢板不同锈蚀周期的锈蚀形貌照片数据,以及对锈蚀钢板进行形貌扫描确定其锈蚀深度,并对钢板锈蚀产物进行X射线衍射(XRD)成分分析,得出钢板锈蚀深度与表观形貌特征的关联关系。基于实验室数据构建60000张4个深度梯度(0.01~0.65 mm)的均匀锈蚀图像,发现模型锈蚀深度对应4个类型的识别精度达96.86%。但模型未针对深度特征优化,仅沿用通用分类网络结构,同时数据库基于理想盐雾环境,泛化性不足。Altabey等^[112]针对钢管道锈蚀深度检测提出3D阴影建模与CNN结合的方法,利用锈蚀深度低于周围区域产生的阴影特征,通过双向投影构建阴影图,用CNN提取阴影特征反推深度。该方法通过迭代最近点算法(ICP)排除光照干扰,大幅提高精度,但其过于依赖光照条件,且未考虑锈蚀产物对阴影的影响。仅依靠图片信息的核心不足源于二维视觉信息与三维深度物理量的本质矛盾,二者关联性弱且易受干扰,同时数据集稀缺,标注成本较高,即使训练后的模型也因缺乏可解释性难以满足工程信任需求,环境适应性差。

单纯RGB图像更适合面积与等级评定,而要实现定量腐蚀深度的估计,常需引入多光谱、高光谱或X射线等具有更强物理相关性的成像,并结合回归或图像修补框架。典型方法^[113-117]已能在试验条件下达到高精度连续深度预测或厚度损失预测,但向复杂工程现场推广仍需解决环境干扰、标定与真值获取等问题。

目前针对钢结构腐蚀检测的视觉深度研究仍较为匮乏,相关检测技术的精度尚未达到工程应用需求,因此当前基于计算机视觉的钢结构腐蚀检测研究仍以腐蚀分类、面积识别和分级为核心重点。

2.2.2 小样本学习

在腐蚀检测中,为处理数据集图像数量不足的问题,多采用基于数据扩充的方法。小样本学习的根本问题是数据缺乏,若利用已有数据生成一批新数据,可以直接解决这一问题。一般的数据增强方法是对输入图片进行翻转、旋转、平移、添加噪声或者随机裁剪^[96]等操作。然而腐蚀损伤没有方向,也没有任何规定的尺寸、形状或绝对颜色,该方法处理的腐蚀图片,无法生成具有新特征的图片。另一种常用的方法是迁移学习(Transfer Learning),在大数据集上对模型预训练,然后在目标数据集上微

调。Liu等^[118]提出基于VGG19的Faster-RCNN网络,利用迁移学习实现了对海上结构压载舱中不同类型的涂层损坏和腐蚀的分类。许多学者在ImageNet^[119-120]、PASCAL VOC2007和PASCAL VOC2012^[121]等标准数据集上初始化权重,利用迁移学习将大型数据集上预训练学到的低层次特征知识迁移到小样本的腐蚀数据集上,从而解决样本数量不足的问题。然而,使用迁移学习时,大型数据集和任务数据集需要足够相关,使底层特征例如颜色特征、纹理特征、形状特征等可以保留用于任务目标检测^[122]。目前大型的公开数据集与腐蚀相关的图片极少^[123],即使应用了迁移学习,仍然需要数千张输入图片作为目标数据集。

生成对抗网络(GAN)自2014年被提出以来,为应对深度学习中的小样本问题提供了一种创新思路^[124]。其核心思想是通过生成器与判别器的对抗博弈进行学习,使生成器能够合成与真实数据高度相似的图像。然而,经典GAN存在训练不稳定、收敛慢等问题,常导致生成失败或样本质量较低。为此,研究者们相继提出了一系列改进模型。Radford等^[125]提出的深度卷积生成对抗网络(DCGAN)通过引入卷积结构取代全连接层,有效提升了训练的稳定性与收敛速度。针对训练困难与模式崩溃问题,Gulrajani等^[126]进一步提出了沃瑟斯坦生成对抗网络(WGAN)及其改进版本,从损失函数层面增强了训练的稳定性与生成样本的多样性。GAN在土木工程中的应用已有一些研究,Lei等^[127]使用GAN重建了结构健康监测的丢失数据;Gao等^[128]使用GAN进行损伤数据集扩充,并评估了生成图像的质量;Maeda等^[129]使用GAN生成公共道路表面坑洞图像。Xu等^[130]提出基于双CycleGAN的表面缺陷检测方法,核心创新在于构建两阶段框架,CycleGAN1通过无监督图像转换生成无缺陷和有缺陷的配对样本,CycleGAN2输出多轮迭代图像后,通过缺陷像素差异累积与阈值分割生成二值化缺陷图,全程无需人工标注缺陷特征。Wang等^[131]提出DG-GAN双向框架,编码器无需梯度信息即可生成对抗样本,且框架无需修改现有分类器结构,可灵活适配各类损伤检测模型。在Caltech-101等数据集上的验证表明,其平均准确率超88%。

GAN类方法通过无监督样本生成、对抗干扰优化,为腐蚀小样本检测及复杂环境适配提供新思路。而半监督学习^[132]与半自动标注^[133]技术,从样

本利用效率与标注成本控制角度,缓解了腐蚀检测中标注样本少且定位标注成本高的核心矛盾。钱企豪等^[134]针对铜片腐蚀等级识别,提出基于颜色特征的半监督 k-means 算法,通过核主成分分析(KPCA)降维处理颜色直方图特征,以标准比色卡特征作为初始聚类中心,无需大量标注样本即可实现 84% 的识别精度。Feng 等^[135]在复杂海洋场景的半监督目标检测研究中,提出自适应对抗自训练框架,仅用 2% 标注样本结合全量未标注样本的检测性能,即可超越 5% 标注样本的全监督模型。Wang 等^[136]结合 Mean Teacher 模型,在仅有 67% 标注数据的情况下,实现 90.0% 的平均精度和 87.1% 的交并比(IoU),即使在仅 33% 标签可用时,性能也优于全监督模型。这进一步验证了半监督学习在降低腐蚀检测标注成本中的潜力。

2.2.3 关键优化技术

CNN 与 Transformer 架构在图像语义分割、目标检测等任务中展现出卓越性能。但在实际工程部署中,仍面临两大核心挑战,一是如何提升模型对小目标腐蚀、边缘模糊区域及复杂背景干扰下的特征提取能力;二是如何在嵌入式设备或无人机平台等资源受限环境中实现高效推理。为此,研究者们将注意力机制^[137]引入主流网络框架,并探索轻量化策略以降低参数量与计算开销。

许多学者尝试将注意力机制嵌入编码器-解码器结构,以增强关键特征的表达权重。一种典型路径是在 U-Net 基础上集成通道-空间联合注意力模块。Duan 等^[138]提出一种改进型 U-Net Attention 架构,在跳跃连接处引入注意力门控机制,使解码器能够有选择性地融合来自编码器各层级的特征图,抑制无关背景响应,用于复杂背景下钢构件腐蚀等级的智能诊断。试验结果显示,该方法在真实工程现场采集的数据集上实现了 94.1% 的分割准确率,显著优于原始 U-Net。Katsamenis 等^[139]构建 SPLAC U-Net 模型,在最后一层附加残差注意力模块,用于锈迹定位与分级任务,相比仅使用颜色阈值的传统方法,其 F_1 和 IoU 指标均有明显提升。除了 U-Net 变体,Ma 等^[140]展示了如何将 MPCA(MultiPath Coordinate Attention)整合进 YOLOv8n 的颈部结构,从而强化对坐标位置敏感的特征响应。MPCA 的设计理念在于同时建模水平与垂直方向的空间依赖关系,相较于 SE(Squeeze and Excitation Module)或 CBAM(Convolutional Block Attention

Module)等通用注意力模块,更适合处理具有规则几何形态的钢板表面损伤。试验证明,该改进使 mAP 提升了 1.2%,同时能维持较低的计算负载。Fu 等^[141]开发 CBG-YOLOv5s 模型,通过在 C3 模块中嵌入 CBAM,增强通道与空间维度的关注能力。此外,还设计一种轻量化的 C3Ghost 组件,进一步减少参数数量。目前大部分研究均未直接比较不同类型注意力机制的效果,而是默认选用某种特定结构。

轻量化部署的需求促使研究者探索更极致的模型压缩策略。资源约束主要体现在边缘设备的内存与算力限制以及无人机巡检系统对功耗与实时性的要求。单纯增加网络深度或宽度不再可行,目前主流的轻量化手段可分为三类,主干网络替换、结构重参数化与模型剪枝。Ma 等^[140]采用 Ghost-Net 作为 YOLOv8 的主干,借助线性变换生成冗余特征图,大幅削减浮点运算次数。Zhang 等^[142]提出 YOLO-RD 模型以 RexNet 作为主干,引入 GSConv 与 VOV-GSCSP 模块重构特征融合路径,模型在 NEU-DET 和 GC10-DET 两个公开数据集上分别取得 3.7% 和 3.5% 的 mAP 增益,参数量下降达 40%。该方法在极端压缩情况下可能出现特征退化现象,特别是在处理低对比度目标时表现不稳定。Tan 等^[143]关注 DSNet 网络内部结构的优化重组,采用共享主干的双分支架构,分别执行螺栓检测与像素级腐蚀分割任务,二者输出取交集后生成检测结果,避免独立训练两个模型带来的额外开销。模型剪枝属于后训练压缩技术,Yu 等^[144]系统评估了五种分割模型在两种腐蚀图像数据集(NEA、SSCS)上的剪枝效果,涵盖线性衰减、渐进式与运动剪枝三种策略。研究表明,当稀疏度达到 90% 时,多数模型在 SSCS 数据集上的 IoU 下降不超过 10%,而在噪声更少的 NEA 数据集上降幅仅为 5% 左右,表明在合理控制剪枝强度的前提下,可实现模型体积的显著压缩而不致严重损失性能。

目前越来越多的学者强调算法的实际落地能力。Han 等^[145]提出一种两阶段定位法,先利用超像素分割方法中的简单线性迭代聚类方法(SLIC)预处理无人机图像,再结合飞行轨迹信息精确定位腐蚀区域相对位置。Eltouny 等^[146]开发的 Dmg2Former-AR 模型结合视觉 Transformer 与拉普拉斯金字塔缩放网络,专门应对高分辨率检测图像带来的计算压力。Katsamenis 等^[139]的 SPLAC U-Net 服务于自动化维修机器人,要求模型既能精确定界又能

识别腐蚀等级,以便规划打磨或喷涂动作。Duan等^[138]则面向运维阶段的大规模结构评估,提出滑动窗口采样与Inception v3分类结合的流水线流程,便于批量处理航拍影像。尽管已有大量工作聚焦于单一维度优化,强调精度提升或追求模型压缩,但兼顾高精度与低延迟的系统性解决方案尚不成熟。

3 目前损伤检测存在的问题与改进方向

3.1 缺少足量规范的数据集

数据集是深度学习研究的基石,但当前钢结构损伤检测领域常用的数据集普遍存在背景单一、缺陷种类有限的问题,难以真实反映复杂多变的工业现场。实际上,生产中的图像往往来自不同成像条件、拍摄角度,构建贴近真实场景的数据集,不仅有

助于开发更具实用性的算法,为算法落地部署提供关键基础,还能为无人机巡检、异常溯源等延伸任务提供必要的评估基准。

数据集的匮乏也直接加剧了小样本问题,这已成为深度学习在钢结构损伤检测等领域推广的瓶颈。深度学习方法依赖大量数据进行训练,但在实际应用中,可用损伤样本数量不足,现有公开数据集中真实多损伤、多工况的钢结构数据仍然有限^[123],如表4所示,钢结构裂纹和腐蚀的公开数据集很少。现有数据集还存在制作不规范、不统一的问题,导致模型在训练过程中容易出现过拟合,难以实际部署应用。当前解决小样本问题的思路主要围绕增加有效样本、降低算法对样本数量依赖两个方面。

表4 钢结构表面缺陷数据集
Table 4 Datasets of surface defects in steel structures

数据集名称	规模	类型	数据集来源网址
Cracks in Steel Bridge (CSB) ^[51]	755张512×512像素级标注	钢箱梁疲劳裂纹	https://data.4tu.nl/datasets/6162a9b6-2a20-4600-8207-e9ded53a264a
Bridge Crack Library (BCL) ^[147]	11000张256×256像素级标注	钢结构/混凝土裂纹	https://doi.org/10.7910/DVN/RURXSH
Corrosion Condition State Classification ^[148]	440张512×512像素级标注	钢框架结构腐蚀4级腐蚀程度	https://github.com/beric7/structural_inspection_main
Illinois-MADNet ^[149]	检测框标注	钢结构/混凝土结构损伤(腐蚀、裂纹、表面剥落、变形等)	https://sites.google.com/view/illinois-madnet/home
GC10-DET ^[53]	检测框标注	金属表面损伤10类	https://github.com/lvxiaoming2019/GC10-DET-Metallic-Surface-Defect-Datasets
NEU Surface Defect Database ^[150]	300张200×200分类/目标检测	热轧带钢缺陷(氧化铁皮、压痕、麻点、裂纹、夹杂、划痕)	http://faculty.neu.edu.cn/yunhyan/NEU_surface_defect_database.html
RSDDs ^[151]	2656张检测框标注	钢轨表面损伤(裂纹、孔洞、磨损等)	http://icn.bjtu.edu.cn/Visint/resources/RSDDs.aspx
Severstal Steel Defect Detection	18074张像素级标注	钢材表面损伤4类	https://www.kaggle.com/c/severstal-steel-defect-detection/data
SLSM ^[152]	1500张检测框标注	钢结构纵横裂纹	http://faculty.neu.edu.cn/yunhyan/SLSM.html
SCACM ^[153]	2200张像素级标注	裂纹(金属1200张,混凝土1000张)	http://faculty.neu.edu.cn/yunhyan/SCACM.html

在增加有效样本方面,传统数据扩充方法通过简单图像变换提升样本数量,但无法解决样本多样性不足的问题;GAN及其改进模型可合成高相似度无监督腐蚀样本,弥补真实样本匮乏短板并降低标注成本,部分改进模型^[125,130]实现无人工标注突破,但生成样本的真实性与适配性仍需优化。在降低样本依赖方面,迁移学习^[119-122]通过通用数据集预训练迁移特征,缓解小样本压力,但受特征差异限制仍需进行目标样本微调;半监督学习与半自动标注技术可挖掘未标注样本信息,降低标注成本并保障性能,但其复杂场景稳定性仍需验证。此外,各类方法落地需依托统一的数据集制作标准,解决数据

集不规范问题,为方法优化与工程化应用提供支撑。

3.2 复杂背景下模型抗干扰能力不足

钢结构服役环境的复杂性导致损伤识别难度显著提升。钢结构表面的裂纹与划痕、锈迹与表面附着物在视觉纹理、灰度特征上存在高度重叠,损伤特征混淆,常规模型难以实现精准区分,易出现误判、漏判现象。同时环境干扰显著,因光照不均、阴影遮挡、雨水附着、海洋盐雾侵蚀等现象严重破坏钢结构损伤区域的特征完整性,模型特征提取易失效。另外,传统损伤标注依赖人工完成,裂纹、腐蚀、螺栓脱落等小目标的标注耗时耗力、效率低下,

易因标注人员的经验差异产生主观误差,影响模型训练的准确性与一致性。

在此背景下,单纯依赖单一数据源或传统模型优化已难以满足实际需求,当前的主要热点在于拓展多源数据融合技术。通过融合视觉图像、振动信号、红外热成像、机电阻抗(EMI)等多维度数据,实现优势互补^[86]。视觉图像可捕捉表面损伤的直观特征,振动信号能反映结构内部力学性能的变化,红外热成像可识别钢结构涂层下腐蚀、裂纹等隐蔽损伤^[76-78],机电阻抗信号可实现腐蚀程度的定量表征。结合环境自适应预处理算法可减少复杂环境对特征提取的干扰,进一步提升模型在实际场景中的识别稳健性,突破单源数据的应用局限。

3.3 模型泛化与迁移能力不足

现有深度学习模型通常在特定结构类型与环境条件下训练,导致其特征提取能力呈现较高的场景依赖性,泛化与迁移能力有限。当应用于不同结构类型或不同服役环境时,因损伤特征分布存在差异,模型识别精度往往下降趋势显著。同时,跨结构、跨环境的特征迁移难度大,缺乏有效缓解特征分布偏移的技术手段,已成为制约该技术规模化应用的关键^[122]。

为提升模型在多样化场景下的适应能力,现有研究采用了多种训练策略:1)采用迁移学习策略,在大规模通用数据集上预训练模型^[119-121],结合目标场景的少量标注数据进行微调,以增强模型对新结构与新环境的适配能力。2)引入领域自适应方法,利用领域对抗训练、风格迁移等方法减小跨场景的特征分布差异,实现不同光照、纹理风格条件下钢结构损伤的跨域识别^[154]。3)结合对比学习^[155]、元学习^[156]等技术,进一步增强模型对损伤特征与场景变化的自适应与泛化能力,从而推动检测技术在多类型钢结构、多服役环境中的规模化应用。

3.4 工业化部署挑战

当前主流的深度学习模型如 CNN、Transformer 及混合架构等,通常结构复杂、参数量庞大,虽有助于提升钢结构损伤的识别精度,但也导致算力消耗显著增加。这使得模型对硬件要求高,难以部署至嵌入式设备或边缘终端等常见工业场景,难以满足现场实时检测与在线监测的需求。同时高昂的算力成本也制约了该技术在中小型工程中的推广应用。针对上述问题,模型加速技术是目前重要的改进方向。在算法层面,可在设计时引入轻量化思

想,采用分组卷积、深度可分离卷积减少计算量,或直接使用轻量级网络^[68-71]进行特征提取。在硬件层面,可借助 GPU、FPGA、DSP 等专用加速芯片进一步提升推理效率,从而在保证精度的前提下满足实时性要求。

同时,现有检测技术与工程运维设备的集成度较低,未实现检测流程的自动化、智能化升级,导致技术落地成本高、实用性不强。可聚焦工业化集成优化,重点推动检测技术与无人机、巡检机器人等自动化设备的深度融合。

4 总结与展望

随着深度学习技术的不断发展,钢结构损伤检测正逐步从依赖人工巡检、单一传感器检测的传统模式,向智能化、自动化与高精度的方向演进。目前,以 CNN、Transformer 及其混合架构为核心的技术路线已在视觉损伤识别等领域取得显著进展,初步实现了损伤的存在性判断、区域定位与程度分级,为钢结构健康监测提供了新的技术路径。然而,面对工程实际需求,现有技术仍面临一系列突出瓶颈,制约其规模化落地。展望未来,为进一步推动计算机视觉在钢结构损伤识别领域落地,以下几个方向值得重点关注。

1)模型架构设计与优化。当前钢结构损伤检测模型多依赖手工设计的网络拓扑结构,超参数选择易受主观经验影响,缺乏针对工程场景的针对性优化,难以实现性能与效率的较优平衡。未来可探索引入神经架构搜索(Neural Architecture Search, NAS)等自动机器学习技术,面向钢结构损伤检测任务自主挖掘最优网络架构,弥补人工设计的不足,为模型轻量化与检测效率提升提供新的技术路径。相关研究已证实,基于自动机器学习构建的模型在性能上优于传统人工设计的网络^[157-158],为该方向的探索提供了可行性支撑。目前 NAS 在无监督与半监督视觉任务中的应用仍有待拓展,这也为后续面向少标注腐蚀检测场景的模型优化提供研究缺口。

2)多模态信息融合。钢结构损伤种类繁多,单一成像方式往往难以全面捕捉复杂背景下的各类特征,利用不同成像条件的差异形成信息互补是提升检测能力的重要思路。通过融合来自振动、图像、红外等多源异构数据的特征,模型能够应对更复杂的真实场景,增强对损伤的表征与区分能力。同时推动多模态系统与边缘计算、实时在线监测平

台结合,是实现技术工程化落地的关键发展方向。

3)模型可解释性。尽管基于深度学习的方法性能卓越,但其决策过程通常缺乏透明性,许多无监督方法仍依赖经验性假设。对模型可解释性的研究不仅有助于理解其工作机制、推动方法创新,在实际落地中对于建立人机互信、辅助人工决策也至关重要。因此,提升模型的可解释性,是推动技术落地不可或缺的一环。

4)工业化部署技术。当前,模型轻量化与边缘计算的融合应用仍存在短板,需针对钢结构损伤识别任务的特殊性,优化知识蒸馏、网络剪枝、量化压缩等轻量化技术,在保障检测精度的前提下,降低模型参数量与计算开销,适配工程现场便携式巡检终端、无人机机载处理器等边缘设备的算力约束。此外,还需解决多设备数据格式统一、通信协议兼容、模型与工程监测平台接口衔接等问题,完善模型与设备的常态化校准、故障排查、版本更新运维机制,推动技术从实验室原型向标准化、可推广的钢结构损伤实地检测部署转型。

参 考 文 献

- [1] 袁宇峰. 我国钢结构产业发展现状及其用钢需求调查[J]. 冶金管理, 2024(8): 10-13.
- [2] 中国建筑金属结构协会建筑钢结构行业可持续发展研究课题组. 中国建筑钢结构行业发展报告(2023—2024年度)[J]. 建筑, 2025(7): 62-68.
- [3] 幸坤涛, 赵晓青, 郭小华, 等. 工业建筑钢结构疲劳损伤检测、评估及加固关键技术研究[C]//第十二届中国钢铁年会论文集. 北京: 2019.
- [4] 何润, 周世康, 张琦超, 等. 桥梁钢结构的腐蚀与防护技术研究进展[J]. 钢铁研究学报, 2025, 37(5): 539-556.
- [5] WU R K, ZHANG H, YANG R Z, et al. Nondestructive testing for corrosion evaluation of metal under coating[J]. Journal of Sensors, 2021, 2021(1): 1-16.
- [6] VASAGAR V, HASSAN M K, ABDULLAH A M, et al. Non-destructive techniques for corrosion detection: a review[J]. Corrosion Engineering, Science and Technology, 2024, 59(1): 56-85.
- [7] 陈飞圻, 薛江, 逯鹏, 等. 基于机器视觉的钢结构工程运维关键技术研究现状[J]. 工业建筑, 2025, 55(7): 131-142.
- [8] 朱洪洲, 谭祺琦, 范世平, 等. 基于图像技术的沥青混合料微观结构研究进展[J]. 重庆交通大学学报(自然科学版), 2021, 40(10): 97-110.
- [9] 宋伟, 左丹, 邓邦飞, 等. 高压输电线防震锤锈蚀缺陷检测[J]. 仪器仪表学报, 2016, 37(增刊1): 113-117.
- [10] XU Y, LI H, LI S, et al. 3-D modelling and statistical properties of surface pits of corroded wire based on image processing technique[J]. Corrosion Science, 2016, 111: 275-287.
- [11] 刘涛, 艾军, 张丽芳, 等. 基于图像处理技术的钢箱梁防腐涂层寿命预测实验研究[J]. 中国腐蚀与防护学报, 2013, 33(5): 407-412.
- [12] 刘森, 薛建军, 王玲, 等. 基于数字图像分析的碳钢腐蚀等级评定方法[J]. 腐蚀与防护, 2013, 34(11): 997-1000.
- [13] SHI T, KONG J Y, WANG X D, et al. Improved Sobel algorithm for defect detection of rail surfaces with enhanced efficiency and accuracy[J]. Journal of Central South University, 2016, 23(11): 2867-2875.
- [14] 姚志东, 卢佳祁, 熊梦雅, 等. 基于计算机视觉的钢结构表面缺陷智能识别研究综述[J]. 建筑结构, 2023, 53(24): 126-135.
- [15] 逯鹏, 赵天淞, 王剑, 等. 基于计算机视觉的钢结构表面损伤识别与健康监测综述[J]. 工业建筑, 2022, 52(10): 22-27.
- [16] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习算法综述[J]. 中国科学:信息科学, 2022, 52(6): 1002-1039.
- [17] 杨泽青, 张明轩, 陈英姝, 等. 基于机器视觉的表面缺陷检测方法研究进展[J]. 现代制造工程, 2023(4): 143-156.
- [18] 程锦锋, 方贵盛, 高惠芳. 表面缺陷检测的机器视觉技术研究进展[J]. 计算机应用研究, 2023, 40(4): 967-977.
- [19] 高艺平, 王浩, 李新宇, 等. 基于深度智能视觉的表面缺陷检测研究进展[J]. 工业工程, 2024, 27(2): 27-36.
- [20] 邓志鹏, 何施茗, 杨根, 等. 基于深度学习的纹理表面缺陷检测方法综述[J]. 计算机集成制造系统, 2025, 31(3): 721-745.
- [21] AZIMI M, ESLAMLOU A D, PEKCAN G. Data-driven structural health monitoring and damage detection through deep learning: state-of-the-art review[J]. Sensors, 2020, 20(10): 2778.
- [22] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述[J]. 电子学报, 2020, 48(3): 590-601.
- [23] ZHANG G, LIU Y, LIU J, et al. Causes and statistical characteristics of bridge failures: a review[J]. Journal of Traffic and Transportation Engineering (English Edition), 2022, 9(3): 388-406.
- [24] IMAM B, CHRYSSANTHOPOULOS M K. A review of metallic bridge failure statistics [C]//Bridge Maintenance, Safety and Management: Proceedings of the Fifth International IABMAS Conference. Boca Raton: 2010: 3275-3282.
- [25] HAMISHEBAHAR Y, GUAN H, SO S, et al. A comprehensive review of deep learning-based crack detection approaches[J]. Applied Sciences, 2022, 12(3): 1374.
- [26] YUAN Q, SHI Y, LI M. A review of computer vision-based crack detection methods in civil infrastructure: progress and challenges[J]. Remote Sensing, 2024, 16(16): 2910.
- [27] CUI C, ZHANG Q, ZHANG D, et al. Monitoring and detection of steel bridge diseases: a review[J]. Journal of Traffic and Transportation Engineering (English Edition), 2024, 11(2): 188-208.
- [28] RIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Proceed-

- ings of the 25th International Conference on Neural Information Processing Systems. New York: 2012: 1097–1105.
- [29] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[PP/OL]. V6. arXiv (2015–04–10) [2026–05–07]. <https://doi.org/10.48550/arXiv.1409.1556>.
- [30] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2015: 1–9.
- [31] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2016: 770–778.
- [32] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2017: 4700–4708.
- [33] VANNOCCI M, RITACCO A, CASTELLANO A, et al. Flatness defect detection and classification in hot rolled steel strips using convolutional neural networks [C]//International Work-Conference on Artificial Neural Networks. Cham: Springer International Publishing, 2019: 220–234.
- [34] XU Y, BAO Y, CHEN J, et al. Surface fatigue crack identification in steel box girder of bridges by a deep fusion convolutional neural network based on consumer-grade camera images [J]. Structural Health Monitoring, 2019, 18(3): 653–674.
- [35] 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.
- [36] 王海云, 王剑平, 罗富华. 融合多层次特征 Faster R-CNN 的金属板带材表面缺陷检测研究 [J]. 机械科学与技术, 2021, 40(2): 262–269.
- [37] 戴学丰, 陈慧, 朱成军. 基于改进 Faster R-CNN 的金属工件表面缺陷检测及实现 [J]. 表面技术, 2020, 49(10): 362–371.
- [38] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2016: 779–788.
- [39] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2017: 7263–7271.
- [40] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: 2023: 7462–7475.
- [41] CHA Y J, CHOI W, SUH G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9): 731–747.
- [42] SUH G, CHA Y J. Deep Faster R-CNN-based automated detection and localization of multiple types of damage [C]//Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2018. Bellingham: 2018, 10598: 197–204.
- [43] LONG J, SHEHMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: 2015: 3431–3440.
- [44] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: 2015: 234–241.
- [45] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European conference on computer vision (ECCV). Cham: 2018: 801–818.
- [46] JIA X, WANG Y, WANG Z. Fatigue crack detection based on semantic segmentation using DeepLabV3+ for steel girder bridges [J]. Applied Sciences, 2024, 14(18): 8132.
- [47] PAN Y, ZHANG L. Dual attention deep learning network for automatic steel surface defect segmentation [J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(11): 1468–1487.
- [48] LIU Y, YAO J, LU X, et al. DeepCrack: a deep hierarchical feature learning architecture for crack segmentation [J]. Neurocomputing, 2019, 338: 139–153.
- [49] DONG C, LI L, YAN J, et al. Pixel-level fatigue crack segmentation in large-scale images of steel structures using an encoder-decoder network [J]. Sensors, 2021, 21(12): 4135.
- [50] ZHANG C, WAN L, WAN R Q, et al. Automated fatigue crack detection in steel box girder of bridges based on ensemble deep neural network [J]. Measurement, 2022, 202: 111805.
- [51] KOMPANETS A, DUTTS R, PAI G, et al. Loss function inversion for improved crack segmentation in steel bridges using a CNN framework [J]. Automation in Construction, 2025, 170: 105896.
- [52] 舒江鹏, 李俊, 马亥波, 等. 基于特征金字塔网络的超大尺寸图像裂纹识别检测方法 [J]. 土木与环境工程学报(中英文), 2022, 44(3): 29–36.
- [53] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2117–2125.
- [54] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning [J]. Computational Intelligence and Neuroscience, 2021, 2021(1): 5592878.
- [55] LI G, LI X, ZHOU J, et al. Pixel-level bridge crack detection using a deep fusion about recurrent residual convolution and context encoder network [J]. Measurement, 2021, 176: 109171.
- [56] QUQA S, MARTAKIS P, MOVSESSIAN A, et al. Two-step approach for fatigue crack detection in steel bridges using convo-

- lutional neural networks [J]. *Journal of Civil Structural Health Monitoring*, 2022, 12(1): 127-140.
- [57] TONG T, LIN J, HUA J, et al. Crack identification for bridge condition monitoring using deep convolutional networks trained with a feedback-update strategy [J]. *Maintenance, Reliability and Condition Monitoring*, 2021, 1(2): 37-51.
- [58] MENG S Q, GAO Z Y, ZHOU Y, et al. A three-stage deep-learning-based method for crack detection of high-resolution steel box girder image [J]. *Smart Structures and Systems*, 2022, 29(1): 29-39.
- [59] ZHAI G H, NARAZAKI Y, WANG S, et al. Synthetic data augmentation for pixel-wise steel fatigue crack identification using fully convolutional networks [J]. *Smart Structures and Systems*, 2022, 29(1): 237-250.
- [60] TA Q B, DANG N L, KIM Y C, et al. Semantic crack-image identification framework for steel structures using atrous convolution-based Deeplabv3+ Network [J]. *Smart Structures and Systems*, 2022, 30(1): 17-34.
- [61] 邓露, 香超, 王维, 等. 基于改进编解码网络的钢箱梁疲劳裂纹分割 [J]. *华中科技大学学报(自然科学版)*, 2022, 50(8): 66-72.
- [62] 朱劲松, 李欢, 王世芳. 基于卷积神经网络和迁移学习的钢桥病害识别 [J]. *长安大学学报(自然科学版)*, 2021, 41(3): 52-63.
- [63] DUNG C V, SEKIYA H, HIRANO S, et al. A vision-based method for crack detection in gusset plate welded joints of steel bridges using deep convolutional neural networks [J]. *Automation in Construction*, 2019, 102: 217-229.
- [64] YU Q Q, WANG J, GU X L, et al. An attention-based detection method of fatigue cracks on steel [J]. *Structural Control and Health Monitoring*, 2025, 2025(1): 7487687.
- [65] DAI A, CHANG A X, SAVVA M, et al. Scannet: Richly-annotated 3d reconstructions of indoor scenes [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: 2017: 5828-5839.
- [66] HAN Q H, LIU X, XU J. Detection and location of steel structure surface cracks based on unmanned aerial vehicle images [J]. *Journal of Building Engineering*, 2022, 50: 104098.
- [67] MENG S, GAO Z, ZHOU Y, et al. Real-time automatic crack detection method based on drone [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2023, 38(7): 849-872.
- [68] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: alexNet-level accuracy with 50x fewer parameters and <0.5 MB model size [PP/OL]. V4. *arXiv* (2016-11-04) [2026-05-07]. <https://doi.org/10.48550/arXiv.1602.07360>.
- [69] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [PP/OL]. V1. *ArXiv* (2017-04-17) [2026-05-07]. <https://doi.org/10.48550/arXiv.1704.04861>.
- [70] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Long Beach: 2018: 6848-6856.
- [71] TAN M, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks [C]//*Proceedings of the 36th International Conference on Machine Learning*. 2019: 6105-6114.
- [72] WANG Y, WANG H, XIN Z. Efficient detection model of steel strip surface defects based on YOLO-V7 [J]. *IEEE Access*, 2022, 10: 133936-133944.
- [73] LU N, WANG K, WANG H, et al. Real-time fatigue crack detection and prediction in steel structures based on an automated digital twin-driven framework [J]. *Thin-Walled Structures*, 2025, 218: 114099.
- [74] GUO Z, ZHANG Y, ZHU Q. CSCP-YOLO: a lightweight and efficient algorithm for real-time steel surface defect detection [J]. *Advanced Engineering Informatics*, 2022, 54: 101741.
- [75] LIU R, ZENG W. Automatic detection of structural defects in tunnel lining via network pruning and knowledge distillation in YOLO [J]. *Structural Health Monitoring*, 2026, 25(2): 1165-1181.
- [76] HUANG H, CAI Y, ZHANG C, et al. Crack detection of masonry structure based on thermal and visible image fusion and semantic segmentation [J]. *Automation in Construction*, 2024, 158: 105213.
- [77] ALEXANDER Q G, HOSKERE V, NARAZAKI Y, et al. Fusion of thermal and RGB images for automated deep learning based crack detection in civil infrastructure [J]. *AI in Civil Engineering*, 2022, 1(1): 3.
- [78] WANG P, XIAO J, QIANG X, et al. An automatic building facade deterioration detection system using infrared-visible image fusion and deep learning [J]. *Journal of Building Engineering*, 2024, 95: 110122.
- [79] ZHOU S, SONG W. Deep learning-based roadway crack classification with heterogeneous image data fusion [J]. *Structural Health Monitoring*, 2021, 20(3): 1274-1293.
- [80] PARK S E, EEM S H, JEON H. Concrete crack detection and quantification using deep learning and structured light [J]. *Construction and Building Materials*, 2020, 252: 119096.
- [81] WANG S, ZHAO X, GAO L, et al. Pixel-level crack segmentation and quantification enabled by multi-modality cross-fusion of RGB and depth images [J]. *Automation in Construction*, 2024, 160: 105318.
- [82] XU W, CUI C, LUO C, et al. Fatigue crack monitoring of steel bridge with coating sensor based on potential difference method [J]. *Construction and Building Materials*, 2022, 350: 128868.
- [83] MANU K C, MADHUSHREE C, CHANDINI M S, et al. Corrosion in steel structures: a review [J]. *Journal of Mines, Metals and Fuels*, 2025, 73(1): 189-198.
- [84] ANWAR S, LI C. Diving deeper into underwater image enhancement: a survey [J]. *Signal Processing: Image Communication*, 2020, 89: 115978.
- [85] DUY L D, ANH N T, SON N T, et al. Deep learning in seman-

- tic segmentation of rust in images [C]//Proceedings of the 2020 9th International Conference on Software and Computer Applications. Malaysia: 2020: 262–266.
- [86] DAS A, DORAFSHAN S, KAABOUC N. Autonomous image-based corrosion detection in steel structures using deep learning [J]. *Sensors*, 2024, 24(11): 3630.
- [87] 中国国家标准化管理委员会. 金属基体上金属和其他无机覆盖层 经腐蚀试验后的试样和试件的评级: GB/T 6461—2002 [S]. 北京: 中国标准出版社, 2002.
- [88] ASTM International. Standard test method for evaluating degree of rusting on painted steel surfaces: ASTM D610–23 [S]. West Conshohocken, PA: ASTM International, 2023.
- [89] International Organization for Standardization. Paints and varnishes—evaluation of degradation of coatings—part 3: assessment of degree of rusting: ISO 4628–3:2016 [S]. Geneva, Switzerland: ISO, 2016.
- [90] 陆廷杰, 刘东海, 齐志龙. 基于深度学习的水下钢结构锈蚀识别与评价 [J]. *天津大学学报 (自然科学与工程技术版)*, 2023, 56(7): 713–722.
- [91] PETRICCA L, MOSS T, FIGUEROA G, et al. Corrosion detection using AI: a comparison of standard computer vision techniques and deep learning model [C]//Proceedings of the Sixth International Conference on Computer Science, Engineering and Information Technology. Chennai: 2016: 91–99.
- [92] ATHA D J, JAHANSHAH M R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection [J]. *Structural Health Monitoring*, 2018, 17(5): 1110–1128.
- [93] HOLM E, TRANSETH A A, KNUDSEN O Ø, et al. Classification of corrosion and coating damages on bridge constructions from images using convolutional neural networks [C]//Twelfth International Conference on Machine Vision (ICMV 2019). Bellingham: 2020: 549–556.
- [94] BASTIAN B T, JASPREETH N, RANJITH S K, et al. Visual inspection and characterization of external corrosion in pipelines using deep neural network [J]. *NDT & E International*, 2019, 107: 102134.
- [95] FORKAN A R M, KANG Y B, JAYARAMAN P P, et al. CorrDetector: a framework for structural corrosion detection from drone images using ensemble deep learning [J]. *Expert Systems with Applications*, 2022, 193: 116461.
- [96] XU J, GUI C, HAN Q. Recognition of rust grade and rust ratio of steel structures based on ensembled convolutional neural network [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2020, 35(10): 1160–1174.
- [97] JIN LIM H, HWANG S, KIM H, et al. Steel bridge corrosion inspection with combined vision and thermographic images [J]. *Structural Health Monitoring*, 2021, 20(6): 3424–3435.
- [98] ANDERSEN R, NALPANTIDIS L, RAVN O, et al. Investigating deep learning architectures towards autonomous inspection for marine classification [C]//2020 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR). Abu Dhabi: 2020: 197–204.
- [99] ZHOU Q, DING S, FENG Y, et al. Corrosion inspection and evaluation of crane metal structure based on UAV vision [J]. *Signal, Image and Video Processing*, 2022, 16(6): 1701–1709.
- [100] JIA Z, FU M, ZHAO X, et al. Intelligent identification of metal corrosion based on Corrosion-YOLOv5s [J]. *Displays*, 2023, 76: 102367.
- [101] NABIZADEH E, PARGHI A. Automated corrosion detection using deep learning and computer vision [J]. *Asian Journal of Civil Engineering*, 2023, 24(8): 2911–2923.
- [102] AMELI Z, NESHELI S J, LANDIS E N. Deep learning-based steel bridge corrosion segmentation and condition rating using mask RCNN and YOLOv8 [J]. *Infrastructures*, 2023, 9(1): 1–16.
- [103] YU Q F, HAN Y D, LIN W G, et al. Detection and analysis of corrosion on coated metal surfaces using enhanced YOLOv5 algorithm for anti-corrosion performance evaluation [J]. *Journal of Marine Science and Engineering*, 2024, 12(7): 1090.
- [104] PIRIE C, MORENO-GARCIA C F. Image pre-processing and segmentation for real-time subsea corrosion inspection [C]//International Conference on Engineering Applications of Neural Networks. Cham: 2021: 220–231.
- [105] 王达磊, 彭博, 潘玥, 等. 基于深度神经网络的锈蚀图像分割与定量分析 [J]. *华南理工大学学报 (自然科学版)*, 2018, 46(12): 121–127.
- [106] FONDEVIK S K, STAHL A, TRANSETH A A, et al. Image segmentation of corrosion damages in industrial inspections [C]//2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI). Baltimore: 2020: 787–792.
- [107] KATSAMENIS I, PROTOPAPADAKIS E, DOULAMIS A, et al. Pixel-level corrosion detection on metal constructions by fusion of deep learning semantic and contour segmentation [C]//International Symposium on Visual Computing. Cham: 2020: 160–169.
- [108] AKHLAGHI B, MESGHALI H, EHTESHAMI M, et al. Predictive deep learning for pitting corrosion modeling in buried transmission pipelines [J]. *Process Safety and Environmental Protection*, 2023, 174: 320–327.
- [109] GAO R P, SHANG W J, ZHAO Y, et al. Research on fusion model method for corrosion damage detection of switch sliding baseplate [J]. *Coatings*, 2024, 14(12): 1552.
- [110] ZHANG Z W, LI S L, WANG H J, et al. A study of neural network-based evaluation methods for pipelines with multiple corrosive regions [J]. *Reliability Engineering & System Safety*, 2025, 253: 110507.
- [111] 秦荣杰. 基于深度学习 Transformer 网络的钢板锈蚀类别识别方法研究 [D]. 西安: 西安建筑科技大学, 2023.
- [112] ALTABEY W A, NOORI M, WANG T, et al. Deep learning-based crack identification for steel pipelines by extracting features from 3D shadow modeling [J]. *Applied Sciences*, 2021, 11(13): 6063.
- [113] WANG B Q, LIU L A, CHENG X Q, et al. Advanced multi-

- image segmentation-based machine learning modeling strategy for corrosion prediction and rust layer performance evaluation of weathering steel[J]. *Corrosion Science*, 2024, 237: 112334.
- [114] LI Y P, LI H G, GUAN Y, et al. Dense metal corrosion depth estimation[J]. *Frontiers in Physics*, 2023, 11: 1277710.
- [115] SON E Y, JEONG D, OH M J. Corrosion area detection and depth prediction using machine learning[J]. *International Journal of Naval Architecture and Ocean Engineering*, 2024, 16: 100617.
- [116] ARIAS F, GUEVARA E, JARAMILLO E, et al. Automated assessment of marine steel corrosion using visible-near-infrared hyperspectral imaging[J]. *Coatings*, 2025, 15(6):645.
- [117] EGODAWELA S, GOSTAR A K, BUDDIKA H A D S, et al. Metal loss defect detection and depth estimation using multi-spectral image analysis of cooling excited steel specimen with corrosion[J]. *Scientific Reports*, 2025, 15(1): 23894.
- [118] LIU L, TAN E, ZHEN Y, et al. AI-facilitated coating corrosion assessment system for productivity enhancement[C]//2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA). Wuhan: 2018: 606-610.
- [119] YAO Y, YANG Y, WANG Y, et al. Artificial intelligence-based hull structural plate corrosion damage detection and recognition using convolutional neural network[J]. *Applied Ocean Research*, 2019, 90: 101823.
- [120] LUO C, YU L, YAN J, et al. Autonomous detection of damage to multiple steel surfaces from 360 panoramas using deep neural networks[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2021, 36(12): 1585-1599.
- [121] YU L J, YANG E F, LUO C, et al. AMCD: an accurate deep learning-based metallic corrosion detector for MAV-based real-time visual inspection[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14:8087-8098.
- [122] HUANG M, ZHANG J, LI J, et al. Damage identification of steel bridge based on data augmentation and adaptive optimization neural network[J]. *Structural Health Monitoring*, 2024, 24: 1674-1699.
- [123] BIANCHI E, HEBDON M. Visual structural inspection datasets[J]. *Automation in Construction*, 2022, 139: 104299.
- [124] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络GAN综述[J]. *计算机科学与探索*, 2020, 14(1): 1-17.
- [125] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [PP/OL]. V2. arXiv (2016-01-07) [2026-05-07]. <https://doi.org/10.48550/arXiv.1511.06434>.
- [126] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]// *Neural Information Processing Systems*. Long Beach: 2017: 5769-5779.
- [127] LEI X, SUN L, XIA Y. Lost data reconstruction for structural health monitoring using deep convolutional generative adversarial networks[J]. *Structural Health Monitoring*, 2022, 20(4): 2069-2087.
- [128] GAO Y, KONG B, MOSALAM K M. Deep leaf-bootstraping generative adversarial network for structural image data augmentation[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2019, 34(9): 755-773.
- [129] MAEDA H, KASHIYAMA T, SEKIMOTO Y, et al. Generative adversarial network for road damage detection[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2021, 36(1): 47-60.
- [130] XU Y Z, WU H, LIU Y L, et al. Automated surface defect detection based on CycleGAN model[C]//*Journal of Physics: Conference Series*. Bristol: 2024, 2890: 012036.
- [131] WANG Y, LIAO X, CUI W, et al. Defending against and generating adversarial examples together with generative adversarial networks[J]. *Scientific Reports*, 2025, 15(1): 12994.
- [132] ZHOU H Y, JIANG F, LU H T, et al. SSDA-YOLO: semi-supervised domain adaptive YOLO for cross-domain object detection[J]. *Computer Vision and Image Understanding*, 2023, 229: 103649.
- [133] 牟宗涵. 基于无人机图像的铁路桥梁钢结构表面缺陷智能识别方法研究[D]. 北京:北京交通大学, 2023.
- [134] 钱企豪, 郑战光, 梁钊, 等. 基于颜色特征的半监督聚类算法在铜片腐蚀等级识别中的应用[J]. *腐蚀与防护*, 2023, 44(5): 34-40.
- [135] FENG J J, TIAN L F, LI X X, et al. Adaptive adversarial self-training for semi-supervised object detection in complex maritime scenes[J]. *Mathematics*, 2024, 12(15): 2348.
- [136] WANG S Y, NGUYEN H D, WILSON R, et al. Deep CNN-based semi-supervised learning approach for identifying and segmenting corrosion in hydraulic steel and water resources infrastructure[J]. *Structural Health Monitoring*, 2025, 24: 2229-2249.
- [137] GUO M H, XU T X, LIU J J, et al. Attention mechanisms in computer vision: a survey[J]. *Computational Visual Media*, 2022, 8(3): 331-368.
- [138] DUAN Z, HUANG X H, HOU J, et al. Research on intelligent diagnosis of corrosion in the operation and maintenance stage of steel structure engineering based on U-Net attention[J]. *Buildings*, 2024, 14(12): 3972.
- [139] KATSAMENIS I, DOULAMIS N, DOULAMIS A, et al. Simultaneous precise localization and classification of metal rust defects for robotic-driven maintenance and prefabrication using residual attention U-Net[J]. *Automation in Construction*, 2022, 137: 104182.
- [140] MA S B, ZHAO X, WAN L, et al. A lightweight algorithm for steel surface defect detection using improved YOLOv8[J]. *Scientific Reports*, 2025, 15: 93469.
- [141] FU M J, JIA Z T, WU L Z, et al. Detection and recognition of metal surface corrosion based on CBG-YOLOv5s[J]. *PloS One*, San Francisco, 2024, 19(4): 1932-6203.
- [142] ZHANG G H, LIU S X, NIE S Q, et al. YOLO-RDP: lightweight steel defect detection through improved YOLOv7-tiny and

- model pruning[J]. *Symmetry*, 2024, 16(4): 1–12.
- [143] TAN L, CHEN X H, YUAN D J, et al. DSNet: a Computer vision-based detection and corrosion segmentation network for corroded bolt detection in tunnel [J]. *Structural Control and Health Monitoring*, 2024, 2024(1): 1–16.
- [144] YU V F, SANTIYUDA G, LIN S W, et al. Neural network pruning for lightweight metal corrosion image segmentation models [J]. *IEEE Access*, 2025, 13: 71673–71687.
- [145] HAN Q H, ZHAO N, XU J. Recognition and location of steel structure surface corrosion based on unmanned aerial vehicle images[J]. *Journal of Civil Structural Health Monitoring*, 2021, 11(5): 1375–1392.
- [146] ELTOUNY K, SAJEDI S, LIANG X. Dmg2Former-AR: vision transformers with adaptive rescaling for high-resolution structural visual inspection[J]. *Sensors*, 2024, 24(18): 6007.
- [147] YE X W, JIN T, LI Z X, et al. Structural crack detection from benchmark data sets using pruned fully convolutional networks [J]. *Journal of Structural Engineering*, 2021, 147 (11) : 04721008.
- [148] BIANCHI E, HEBDON M. Corrosion condition state semantic segmentation dataset [DS]. Blacksburg, VA, USA: Virginia Tech, 2021.
- [149] HOSKERE V, NARAZAKI Y, HOANG T A, et al. MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure[J]. *Journal of Civil Structural Health Monitoring*, 2020, 10 (5) : 757–773.
- [150] DONG H, SONG K, HE J, 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.
- [151] GAN J, LI Q, WANG J, et al. A hierarchical extractor-based visual rail surface inspection system [J]. *IEEE Sensors Journal*, 2017, 17(23): 7935–7944.
- [152] SONG K C, HU S P, YAN Y H, et al. Surface defect detection method using saliency linear scanning morphology for silicon steel strip under oil pollution interference [J]. *ISIJ International*, 2014, 54(11): 2598–2607.
- [153] SONG K, YAN Y H. Micro surface defect detection method for silicon steel strip based on saliency convex active contour model, mathematical problems in engineering [J]. *Mathematical Problems in Engineering*, 2013(1): 429094.
- [154] ZHANG S, ZHANG Q, GU J, et al. Visual inspection of steel surface defects based on domain adaptation and adaptive convolutional neural network [J]. *Mechanical Systems and Signal Processing*, 2021, 153: 107541.
- [155] HU X, YANG J, JIANG F, et al. Steel surface defect detection based on self-supervised contrastive representation learning with matching metric [J]. *Applied Soft Computing*, 2023, 145: 110578.
- [156] YANG X CA1, FAN Y L, BAO Y Q, et al. Task-aware meta-learning paradigm for universal structural damage segmentation using limited images [J]. *Engineering Structures*, 2023, 284: 115917.
- [157] LI Y, CHEN Z, ZHA D, et al. Automated anomaly detection via curiosity-guided search and self-imitation learning [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(6): 2365–2377.
- [158] RIPPEL O, MERTENS P, MERHOF D. Modeling the distribution of normal data in pre-trained deep features for anomaly detection [C]//2020 25th International Conference on Pattern Recognition (ICPR). Milan: 2021: 6726–6733.