

基于视觉的输电线路金具锈蚀缺陷 检测方法研究进展^{*}

刘传洋^{1,2}, 吴一全¹, 刘景景²

(1. 南京航空航天大学电子信息工程学院 南京 211106; 2. 池州学院机电工程学院 池州 247000)

摘要: 输电线路金具的表面锈蚀作为常见的缺陷类型, 是危害输电线路安全运行的重要隐患之一, 如何快速、准确地发现锈蚀的金具设备并进行修复是线路巡检运维工作亟待解决的问题。本文综述了近十年来基于视觉的输电线路金具锈蚀缺陷检测方法的研究进展。首先简述了基于传统图像处理的金具锈蚀缺陷检测流程; 然后按照基于传统图像处理、深度学习方法概述了金具设备锈蚀缺陷检测, 重点阐述了基于深度卷积神经网络的目标检测和语义分割算法在输电线路金具锈蚀缺陷检测中的应用; 随后介绍了基于深度学习的金具锈蚀缺陷检测自建数据集以及性能评价指标; 最后指出了基于深度学习的输电线路金具锈蚀缺陷检测方法目前存在的问题, 并对未来研究工作进行了展望。

关键词: 金具; 锈蚀缺陷; 图像处理; 深度学习; 目标检测; 语义分割

中图分类号: TP391. 41 TM930. 1 TH89 文献标识码: A 国家标准学科分类代码: 510. 4050

Research progress of vision-based rust defect detection methods for metal fittings in transmission lines

Liu Chuanyang^{1,2}, Wu Yiquan¹, Liu Jingjing²

(1. College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

2. College of Mechanical and Electrical Engineering, Chizhou University, Chizhou 247000, China)

Abstract: As a common defect type, surface rust of metal fittings in transmission lines is one of the important hidden dangers endangering the safe operation of transmission lines. How to quickly and accurately discover and repair rusted metal fittings is an urgent problem to be solved in the work of transmission line inspection. This article reviews the research progress of vision-based rust defect detection methods for metal fittings in the last ten years. Firstly, the rust defect detection process of metal fittings based on traditional image processing is introduced. Then, the rust defect detection of metal fittings is summarized according to traditional image processing and deep learning methods. The application of object detection and semantic segmentation algorithms in rust defect detection of metal fittings is emphasized. Next, the self-built data sets for metal fittings' rust defect detection and performance evaluation indexes are introduced. Finally, the existing problems of rust defect detection methods based on deep learning are pointed out and future research work is prospected.

Keywords: metal fittings; rust defect; image processing; deep learning; object detection; semantic segmentation

0 引言

随着国家电网公司不断推进“数字新基建”建设, 人工智能、物联网、大数据、云平台等数字技术已广泛用于

发电、输电、变电、配电、用电等环节^[1-2]。近年来电网规模的不断扩大, 输电线路金具的使用量持续增多, 使得输电线路运维工作难度越来越大。与传统人工巡检相比, 无人机巡检不仅可以节约资金和人工成本, 而且还降低了人工巡检作业风险, 国家电网公司纷纷采用无人机搭载摄像装置巡检输电线路。然而, 无人机巡检势必会采

集海量的图像,人工查找金具设备并标注缺陷位置,容易造成视觉疲劳,从而导致缺陷的错检或漏检。因此,智能识别输电线路中的金具设备变得越来越重要^[3-5]。

为进一步提高输电线路巡检运维工作的智能化、自动化程度,众多研究者致力于无人机航拍图像中电力设备识别及表面缺陷检测研究^[6-10]。输电线路金具长期暴露于自然环境中,难免会造成金具设备表面锈蚀,金具锈蚀缺陷是输电环节中比较常见的缺陷类型,如何快速、准确地发现金具设备锈蚀缺陷并进行修复是输电线路运维工作亟待解决的问题。

电力设备表面缺陷检测主要分为基于人工检测、基于涡流检测、基于超声波检测、基于X射线检测和基于视觉检测等。人工检测方法很大程度上依赖于巡检人员的工作经验,该方法主观性强,检测效率低,且容易造成误检和漏检。涡流检测方法检测精度低,超声波检测方法检测效率低,X射线检测方法对检测人员有一定的辐射副作用^[11]。基于视觉的检测方法利用图像处理技术实现电力设备表面缺陷快速检测,可以有效地避免上述检测方法的不足。目前,视觉检测方法已广泛应用于诸多领域的表面锈蚀缺陷检测。文献[12]从图像配准、分割、锈蚀缺陷检测及量化3个方面概述了多光谱图像中钢桥表面锈蚀缺陷的自动检测。文献[13]提出了一种基于传统图像处理方式的防震锤锈蚀状态识别方法。为了实现彩钢表面锈蚀缺陷智能分割,文献[14]提出一种智能图像分析方法。文献[15]提出了基于单阶段目标检测算法的变电站电力设备表面锈蚀缺陷检测方法。文献[16]通过优化深度神经网络结构实现了集装箱锈蚀缺陷的自动检测。文献[17]提出了一种轻量化目标检测算法用于起重机钢结构表面锈蚀智能检测。迄今为止,基于机器视觉的表面锈蚀缺陷检测已经取得了相当大的进展,但由于输电线路中金具设备种类繁多,且锈蚀区域形态各异,还没有一种通用的检测方法能够智能识别航拍图像中金具设备的表面锈蚀缺陷。鉴于目前尚未有输电线路金具设备表面锈蚀缺陷检测方法的综述发表,因此,有必要对各种不同的金具设备表面锈蚀缺陷检测方法进行全面系统的分析和总结,便于研究人员针对特定的金具设备锈蚀缺陷选取合适的视觉检测方法,为从事电力巡检的研究人员提供有价值的参考。

本文梳理和分析了大量的输电线路金具设备表面锈蚀缺陷视觉检测的方法,本文主要内容包括:1)简述了基于传统图像处理的金具设备表面锈蚀缺陷检测流程;2)概述了基于传统图像处理的金具设备锈蚀缺陷检测方法;3)重点阐述了基于深度学习的金具设备锈蚀缺陷目标检测和语义分割方法;4)梳理了用于金具设备锈蚀缺陷检测的自建数据集以及性能评价指标;5)对基于深度学习的金具设备锈蚀缺陷检测的进一步研究方向做了展望。

1 基于传统图像处理的金具设备锈蚀缺陷检测流程

数字图像处理技术已经在金属表面锈蚀检测中得到了广泛应用,传统图像处理方法作为一种无损检测方法可提供客观、快速、准确的检测结果。如图1所示,基于传统图像处理的金具设备表面锈蚀缺陷检测流程包括图像获取、图像预处理、图像分割、特征提取及图像分类与分析^[18]。

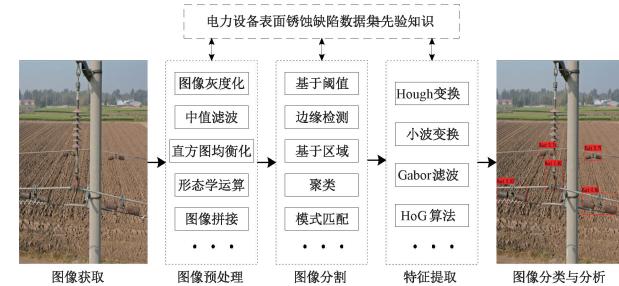


图1 基于传统图像处理的金具锈蚀缺陷检测流程

Fig. 1 Process of rust defect detection of metal fittings based on traditional image processing

1)图像获取:图像处理的第一步是借助相机、激光雷达(light detection and ranging, LiDAR)等装置采集检测目标的图像数据(例如可见光图像、红外图像、激光雷达图像等)。无人机已在输电线路巡检中得到普及,其搭载的监测设备主要有光学相机、红外相机、红外热像仪等。如图2所示,基于无人机巡检输电线路的航拍图像,第1列到第3列分别为图2(a)可见光图像、图2(b)远红外成像和图2(c)近红外图像。与近红外图像、远红外热成像相比,可见光图像具有丰富的颜色、形状、纹理等特征,因此可见光图像已成为输电线路金具设备锈蚀缺陷检测的首选数据源。

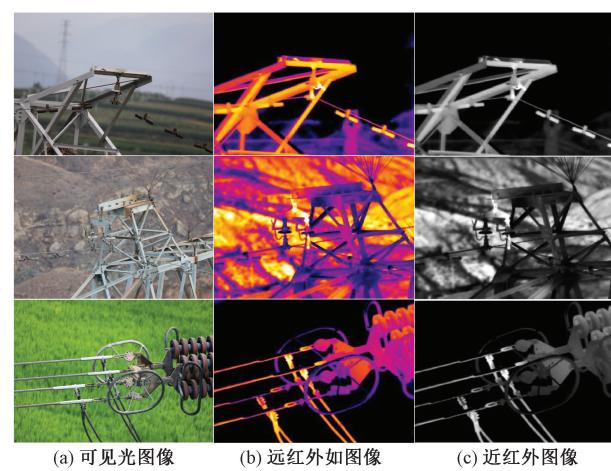


图2 输电线路金具航拍图像

Fig. 2 Aerial images of metal fittings in transmission lines

2) 图像预处理: 无人机航拍采集到的输电线路图像通常存在噪声干扰、模糊不清、畸变等问题。中值滤波、直方图均衡化、图像灰度化、形态学运算、图像拼接等操作用于图像增强处理, 以抑制噪声、提高对比度、避免图像失真, 达到图像质量改善的目的。

3) 图像分割: 航拍图像预处理是金具设备目标准确分割的前提。图像分割是将经过预处理后的图像划分成若干区域并提取感兴趣目标的过程, 通过阈值分割、区域生长、边缘检测、特征聚类以及模式匹配等方法实现。

4) 特征提取: 特征提取的本质是在图像分割后利用颜色、纹理、形状及其组合等特征提取感兴趣目标信息。常用的特征提取算法有 Haar 小波、Hough 变换、方向梯度直方图 (histogram of oriented gradient, HOG)、Gabor 滤波、小波变换等。

5) 图像分类与分析: 图像分类与分析是基于某些已知特征来确定检测目标的所属类别。基于传统图像处理的分类方法有主成分分析 (principal component analysis, PCA)、最近邻 (k-nearest neighbor, kNN)、支持向量机 (support vector machine, SVM) 等。用于锈蚀检测和分析的方法可分为基于小波域、基于 SVM 分类、基于无损评价 (nondestructive evaluation, NDE) 和自组织映射 (self organizing mapping, SOM) 的损伤分析、基于纹理分析等 4 种类型。

2 基于传统图像处理的金具设备锈蚀缺陷检测方法

输电线路安全稳定运行是社会生产和人民生活的必要保障。我国的输电线路总里程较长, 众多金具设备长期暴露于自然环境中, 难免会出现设备表面锈蚀缺陷, 这对电力金具设备的使用寿命和输电线路的安全运行产生不利影响。随着无人机在输电线路巡检中的广泛应用, 利用视觉检测方法自动识别金具设备表面缺陷是电力巡检的一个主要发展方向^[19]。目前基于传统图像处理的金具设备锈蚀缺陷检测方法可划分为基于特征、基于图论分割及其他的方法。

2.1 基于特征的金具设备锈蚀缺陷检测方法

图像特征提取、目标识别和目标定位是机器视觉检测中的 3 个主要步骤, 图像特征提取是目标识别和目标定位的关键。特征反映了目标的本质, 特征选取的好坏直接影响目标识别准确率, 选取合适的特征进行表面锈蚀缺陷检测至关重要。基于特征的方法是根据先验知识或设计规则, 通过聚类或分割的方式将锈蚀区域从图像中分离。颜色、纹理、形状是常用的图像底层视觉特征, 在金具设备表面锈蚀缺陷检测过程中, 按照提取特征的

不同分为基于颜色特征的阈值分割方法和基于纹理特征的边界提取方法。

1) 基于颜色特征的阈值分割方法

在像素分类任务中, 颜色特征是最明显、最直观的视觉特征, 图像中的锈蚀区域可以通过颜色特征很好地体现出来, 因此很多研究者使用颜色特征区分锈蚀目标与背景。文献[20]通过对比分析 RGB 和 HSI 颜色空间模型发现 RGB 图像中锈蚀区域与非锈蚀区域的 R 分量存在明显区别, 受到超绿色算法 (2.0 G-R-B) 的启发, 提出了有利于提取红色特征的超红色法。实验结果表明, 超红色法能够有效去除复杂背景, 解决了航拍图像中背景无法去除的问题, 为后续的图像分割奠定了基础。受到计算机硬件处理速度和能力的限制, 早期开发的算法在对图像进行分割和识别前, 需要先将 24 位彩色图像转换为 8 位灰度图像, 使得图像分析丢失了更多的信息。为了得到较为适合图像锈蚀目标识别的颜色模型, 文献[21]提出了 19 位颜色空间模型, 解决了灰度图像信息丢失问题。

防震锤固定安装在输电线上用于防止电力线随风舞动, 防震锤表面锈蚀可能会导致锤体脱落, 从而造成不可预测的风险。为了实现防震锤锈蚀缺陷检测, 文献[22]提出了基于传统图像处理技术的防震锤锈蚀缺陷检测方法, 通过将直方图均衡化、形态学处理、RGB 彩色模型相结合, 利用 R 通道阈值比较来判断防震锤是否存在锈蚀缺陷, 但是该方法受背景噪声干扰和图像预处理的影响较大。为了实现实现金具锈蚀区域与背景的有效分割, 文献[23]结合聚类理论提出了 RGB 分量约束的分割算法, 利用 RGB 分量约束条件 ($R \geq 30; B = 0; R > G$) 结合最大类间方差法对锈蚀区域进行分割, 金具锈蚀缺陷检测准确率达到了 92.1%, 但是锈蚀缺陷检测系统的整体运行速度还有待进一步提高。由于无人机航拍图像背景复杂, 加之不同的光照条件, RGB 颜色空间模型和形态学算法对金具锈蚀区域检测鲁棒性较差, 且无法确定金具锈蚀程度, 为此文献[24]提出了一种金具锈蚀缺陷检测及量化方法, 先利用超红色算法粗定位出金具锈蚀区域, 再使用 HSV 分量算法对锈蚀区域进行二次定位, 最后采用锈蚀区域与金具面积比的方式量化金具的锈蚀程度。

除上述分割方法以外, 文献[25]利用杆塔锈蚀在 HSI 颜色空间上的差异性进行杆塔锈蚀区域检测; 文献[14]将 HSI 颜色空间模型和 Retinex 算法相结合, 实现了金具表面锈蚀缺陷自动识别。

2) 基于纹理特征的边界提取方法

在金具设备锈蚀缺陷检测中, 纹理作为一类非常重要的视觉特征为缺陷检测提供了重要信息^[26], 锈蚀缺陷检测任务在一定程度上可以看作是纹理分析问题。缺陷

检测方法通常采用灰度共生矩阵^[27]、Fourier 变换^[28]、Gabor 变换^[29]、小波变换^[30]等方法获取纹理特征,研究者利用纹理特征对金具锈蚀缺陷检测展开了研究。

文献[31]将 Fourier 变换与彩色图像处理相结合提出了基于颜色特征和纹理特征的金具表面锈蚀缺陷识别方法。该方法适用于各种背景颜色,能够克服背景噪声干扰,且具有较快的检测速度。实验结果证明了 Fourier 变换在非均匀光照条件下提取纹理特征具有一定的优势,基于 Fourier 变换的分析方法对具有高规律性或方向性纹理特征呈现出良好的检测结果,但是由于缺乏空间位置信息而使其应用受到限制。为了实现图像中锈蚀区域建模和特征提取,文献[32]提出了一种基于图像模拟、滤波、特征提取以及分类的锈蚀检测方法。首先借助 Perlin 噪声生成锈蚀纹理图像以扩增样本数量,接着将待检测图像的 RGB 颜色空间映射到 HSV 空间,经高斯滤波后,通过特征描述符和分块分割算法提取纹理特征,最后利用贝叶斯分类器实现有锈蚀分类。该方法计算成本低,能够有效识别锈蚀和非锈蚀区域,但是需要进一步优化描述符使其更好地检测锈斑纹理。为了评估金属锈蚀程度,文献[33]提出了一种金具表面锈蚀分析方法,利用小波变换和分形算法进行金具表面形貌分析,实验结果证明了香农熵、能量、分形维数、截距等参数随着锈蚀程度的增加而增大。为了提高低分辨率条件下锈蚀缺陷检测准确率,文献[34]将图像灰度与纹理梯度结合提出了一种表面锈蚀检测方法,先利用区域灰度特征函数获取金具表面特征,再基于信息熵的方法进行灰度分布特征和动态特征量化,从而实现了表面锈蚀缺陷检测,其中锈蚀缺陷检测准确率达到了 98%,但是该方法的通用性及适用性还有待提高。为了自动识别输电线路中的防震锤锈蚀缺陷及隐患,文献[35]提出了先定位再识别的防震锤表面锈蚀检测方法,先通过 HOG 特征和 SVM 分类器检测出图像中的防震锤,再采用基于粗糙度的锈蚀判别器和基于 HSV 颜色信息的判别器级联对防震锤区域进行锈蚀识别,最后利用面积比的方式自动判定锈蚀等级。该方法在输电线路巡检管理系统上实现了防震锤锈蚀缺陷自动识别及缺陷等级量化。但是防震锤的识别准确率还有待进一步提高。为了实现防震锤锈蚀的直观展示和精确量化,文献[36]提出了一种基于超红因子灰度化与 HSV 颜色空间相结合的防震锤锈蚀程度量化分析方法,先利用超红因子灰度化粗略定位出防震锤锈蚀区域,再使用 HSV 分量精细提取锈蚀区域并进行像素级标记,最后通过锈蚀区域与防震锤分割区域占比实现防震锤锈蚀等级量化。实验结果表明,防震锤锈蚀识别准确率达到 98% 以上,其中严重锈蚀防震锤识别准确率高达 100%,但是实验样本有限,不同背景下的航拍图像数据集还有待进一步扩充。

2.2 基于图论的金具设备锈蚀缺陷分割方法

交互式图像分割算法是将图像分割问题与图的最小割问题相关联,用户以某种手段指定前景和背景使得图像分割得到较为精确的结果。如图 3 所示,此类算法首先将图像映射为 S-T 无向图,S 代表前景端点,T 代表背景端点,每个顶点与图像中的像素一一对应,每条边分别与相邻像素连接,所有顶点必须和端点 S、T 相连组成第 2 种边的集合。交互式分割算法的本质是将图像映射为赋权无向图,把像素视作节点,利用最小切割得到图像的最佳分割。

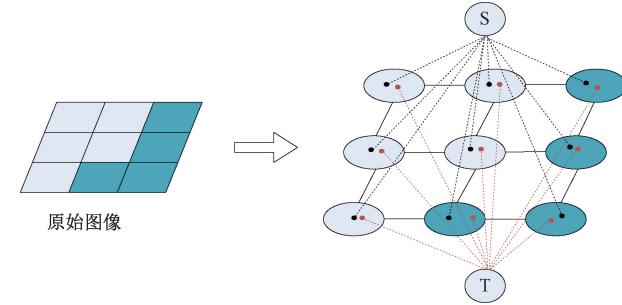


图 3 S-T 无向图

Fig. 3 Undirected graph of S-T

GrabCut 算法是在传统 GraphCut 能量优化算法基础上改进而来的交互式图像分割算法^[37],其在 RGB 通道内采用高斯混合模型(Gaussian mixture model, GMM)计算边界项,对图像进行迭代分割获取 GMM 中一系列最优参数,寻找图的最小割并利用矩形框标注出目标的大致位置,从而实现目标图像分割。如算法 1 所示 GrabCut 算法流程,该算法是以图论为基础的一种组合优化分割方法,在图像分割模型中被广泛应用,研究者提出了基于超像素、显著性检测、修改能量函数等改进算法^[38],同时还有研究者利用 GrabCut 算法进行金具设备锈蚀缺陷检测应用研究。

算法 1 GrabCut 算法流程

- 步骤 1: 输入图像,标记矩形框,矩形框内部是前景,外部是背景;
- 步骤 2: 为前景和背景的每个像素分配标签;
- 步骤 3: 利用 K-means 算法将前景和背景区域分别聚类 K 种像素;
- 步骤 4: 使用 GMM 对前景和背景建模;
- 步骤 5: 将前景区域中的每个像素代入得到 GMM 模型中,计算该像素分别属于前景和背景区域的概率;
- 步骤 6: 计算前景区域中所有两两相邻的像素之间的欧氏距离,得到边界项;
- 步骤 7: 采用最大流最小割算法,得到能量的最小值;
- 步骤 8: 重复步骤 4~7,直到收敛,输出图像。

为了能在海量的输电线路图像中自动识别金具锈蚀缺陷并确定锈蚀等级,文献[39]提出了基于交互式图像分割的金具锈蚀缺陷检测方法,先利用 GrabCut 算法在具有相似场景的航拍图像中分割出目标金具,再将分割后的 RGB 图像转换成 YCrCb 图像,最后通过 Cr 通道阈值比较进行锈蚀区域判定。该方法在金具锈蚀缺陷检测方面取得了较好的分割效果,与传统的图像分割算法相比,交互式图像分割算法在分割速度和准确率上都有了很大的提高。交互式图像分割 GrabCut 算法有利于提高后续金具锈蚀检测准确率并缩短检测时间,与直接利用颜色特征进行锈蚀缺陷检测的方法相比,金具锈蚀缺陷检测准确率提高了 24.4%。但是 GrabCut 分割算法仅适用于颜色、纹理、形状等特征存在极大相似性场景中的目标分割,对于场景多变的航拍图像,易出现误分割、过分割和漏分割现象。输电线路航拍图像背景复杂,针对传统最大类间方差法 Otsu 对金具小目标锈蚀缺陷分割效果差的问题,文献[40]提出了一种基于 GrabCut 与 Lab 颜色空间相结合的图像双分割方法,先利用 GrabCut 算法对电力设备目标进行一次分割,再基于 Lab 颜色空间下的 a 通道进行 Otsu 二次分割,最后通过形态学算法处理获得待检测目标的分割图像。与 Otsu 阈值分割、Regiongrow 分割、Grabcut 分割等算法进行了对比实验及量化分析,该方法在信噪比、交并比、Hausdorff 距离、相似度等评价指标上均具有优势。

2.3 其他方法

除了上述利用颜色空间模型、纹理特征边界提取、图论分割等主要检测方法之外,金具表面锈蚀缺陷检测还有很多其他方法。文献[41]利用 3D 激光雷达点云数据进行设备表面锈蚀检测和分析,先将 RGB 颜色转换成 HSV 空间分离出光照不变的颜色分量,再利用直方图分布或自适应阈值的方法实现锈蚀程度分析与量化。文献[12]利用航拍多光谱图像对设备表面进行自动锈蚀缺陷检测,先通过可见光图像和红外图像融合自动分割出设备轮廓,再基于 YCbCr 颜色空间识别表面锈蚀区域,并计算出锈蚀百分比。文献[13]采用传统图像处理方法进行防震锤锈蚀缺陷检测,先通过基于局部差分处理、基于高斯核方向导数的图像融合对航拍图像进行图像增强处理,再利用阈值分割和形态学优化算法分割出图像中的防震锤,最后根据锈蚀面积比(rusty area ratio, RAR)和色泽指数(color shade index, CSI)等评价指标评估防震锤的锈蚀状态,其锈蚀识别准确率达到 93%。

其他能够实现输电线路金具设备表面锈蚀检测的方法还有一些,如利用分水岭分割^[42]、决策树分类^[43]、度量学习^[44]等,具体可进一步参考相关文献。

基于颜色特征的阈值分割方法在金具锈蚀识别方面应用较为广泛,阈值分割算法检测速度较快,对于灰度对

比差异较大的图像具有较好的分割效果,但是阈值参数的设定至关重要,且阈值分割算法受噪声影响较大,复杂背景下的分割效果不理想。边缘特征是图像分割的重要依据,基于纹理特征的边界提取方法能够准确地定位边缘,单独依靠纹理信息无法准确地获取设备表面锈蚀区域,通常会将纹理特征和颜色特征结合使用。基于特征的方法易受光照、地理环境、图像畸变、噪声干扰等因素影响,同时算法的计算量较大,无法满足实时检测的要求。基于图论的分割方法相比基于特征的方法有很大改进,能够在相对复杂的背景下得到较好的分割结果。GrabCut 算法具有较强的抗干扰能力和较高的鲁棒性,但是该类方法在复杂场景下易出现误分割、过分割和漏分割现象。

如表 1 所示,总结了在输电线路金具锈蚀缺陷检测中应用的传统图像处理方法。

3 基于深度学习的金具设备锈蚀缺陷检测方法

深度卷积神经网络(deep convolutional neural networks, DCNN)凭借其强大的特征学习能力自动提取图像深层特征,在图像分类、目标检测、语义分割、实例分割等方面取得了一系列的突破。随着高性能硬件资源的不断推出和深度学习技术的快速发展,一些主流的深度学习算法在计算机视觉领域得到了广泛应用并取得了较好的实验结果。

自 2012 年 AlexNet 被提出以来,众多研究者通过重构网络结构和设计新模块,提出了很多优秀的 DCNN 分类网络框架,例如网络结构为 16~19 层的 VGGNet^[45],基于 inception 模块的 GoogleNet^[46],网络深度为 53 层的 Darknet-53、跨阶段局部(cross stage partial network, CSP)Darknet-53,引入跨层连接使网络深度可达百层以上的 ResNet^[47]、DenseNet,以及部署于嵌入式设备上的轻量化网络 SqueezeNet^[48]、MobileNet^[49]、ShuffleNet^[50]等。DCNN 具备强大的图像特征提取与处理能力,使得基于深度学习的目标检测算法在图像分类任务中取得了突破性进展。鉴于 DCNN 的优良表现,众多研究者将基于深度学习的视觉检测技术应用到输电线路金具设备锈蚀缺陷检测研究中,如图 4 所示,基于深度学习的金具设备锈蚀缺陷检测流程。根据检测网络结构的不同分为基于 DCNN 的目标检测方法和语义分割方法。

3.1 基于 DCNN 的金具设备锈蚀缺陷目标检测方法

2014 年 R-CNN 算法的提出开创了深度学习在目标检测领域应用的先河。随着计算机视觉、深度学习等新技术的快速发展,基于深度学习的目标检测算法也取得了巨大进步,如图 5 所示,像 Faster R-CNN (regions with convolutional neural networks)、SSD (single shot multi-box

表1 在输电线路金具锈蚀缺陷检测中应用的传统图像处理方法

Table 1 Traditional image processing methods used for rust detection of metal fittings in transmission lines

分类	文献	方法	效果	局限性
	[20]	提出了有利于提取红色特征的超红色法	有效去除复杂背景,解决了航拍图像中背景无法去除的问题	每幅航拍图像中锈蚀缺陷部件的检测时间需要 11.7 s
	[22]	直方图均衡化、形态学处理、RGB 彩色模型相结合	防震锤的锈蚀识别率在 80% 左右	该方法受背景和图像预处理影响较大
基于特征的方法	[23]	利用 RGB 分量约束条件结合最大类间方差法对锈蚀区域进行分割	金具锈蚀缺件检测准确率达到了 92.1%	锈蚀检测系统的每幅图像平均运行时间为 10.5 s
	[24]	超红色和 HSV 分量算法定位锈蚀区域,采用锈蚀区域面积比量化金具的锈蚀程度	锈蚀检测准确率为 84.64%,其中对于严重锈蚀目标的分类准确率可达到 95.3%。	该方法计算量较大,锈蚀缺陷检测的推理时间较长
	[35]	HOG 特征和 SVM 分类器定位防震锤,再通过级联判别器进行锈蚀识别	防震锤的检测率成功率达到 93.2%,平均每幅巡线图像有 0.14 次虚警检测	复杂背景下防震锤的检测准确率不高
	[36]	基于超红因子灰度化与 HSV 颜色空间相结合的防震锤锈蚀程度量化分析方法	防震锤锈蚀识别准确率达到 98% 以上,严重锈蚀防震锤识别准确率达到 100%,	样本有限,不同背景下的航拍图像数据集还有待进一步扩充
	[38]	GrabCut 算法分割金具,再将 RGB 转换成 YCrCb,通过 Cr 阈值比较进行锈蚀检测	金具锈蚀缺陷检测准确率比直接利用颜色特征的方法提高了 24.4%。	算法仅适用特征存在极大相似性特征的场景中的目标分割
	[39]	基于 G-GrabCut 图像分割算法的绝缘子内部发热缺陷检测方法	具有较低的误分割率(1% 以下),能够分割出完整、边缘轮廓清晰的绝缘子	需要对每个像素点进行运算,存在计算复杂度高的缺陷
基于图论的分割方法	[40]	采用 GrabCut 和最大类间方差算法分离电力设备目标,在空间域和小波域进行颜色、形状、纹理特征融合,利用 SVM 分类	识别准确率达到 92.4%,比单独使用 HSV 颜色特征、基于小波变换的纹理特征识别提高了 10.89% 和 10.19%	算法的运算量较大,需要花费更多的时间

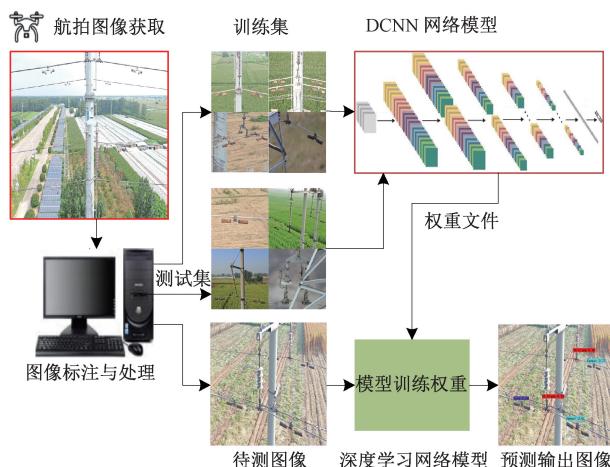


图4 基于深度学习的金具锈蚀缺陷检测流程

Fig.4 Process of rust defect detection based on deep learning

detector)、YOLO(you only look once)等主流的目标检测算法被相继提出。

相比于传统的目标检测算法,基于深度学习的目标检测算法具有更高的检测准确率、更快的检测速度、更强的鲁棒性等优点。目前根据是否有候选区域生成步骤将基于锚点框的目标检测算法分为两类:基于候选区域的

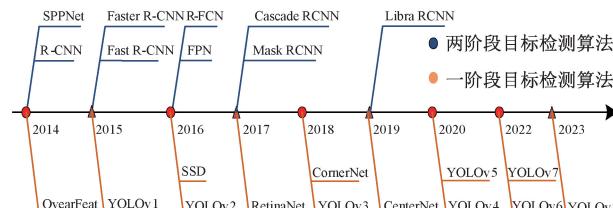


图5 典型的目标检测算法

Fig.5 Typical algorithms of target detection

两阶段(two-stage)目标检测算法和基于回归的一阶段(one-stage)目标检测算法。two-stage 算法具有检测准确率和定位精度高优势,而 one-stage 算法检测速度更快,适用于实时性要求较高的场景。如表 2 所示,两类算法在 COCO 和 VOC2007 数据集上的对比实验结果。

1) 基于 two-stage 算法的金具锈蚀缺陷检测

基于候选区域的目标检测算法采用 two-stage 框架,先提取输入图像的 k 个候选框区域,再基于 DCNN 进行特征提取,最后对候选区域进行感兴趣分类和位置回归从而获得预测结果,其检测流程图如图 6 所示。

典型的 two-stage 算法有: R-CNN^[51]、SPPNet^[52] (spatial pyramid pooling network)、Fast R-CNN^[53]、Faster

表 2 典型的目标检测算法性能对比

Table 2 Performance of typical object detection algorithms

算法	COCO mAP/%	VOC2007 mAP/%	检测速度 /fps
R-CNN		58.5	
SPPNet		59.2	2
Fast R-CNN	19.7	70.0	3
Faster R-CNN	21.9	73.2	5
R-FCN	29.9	79.5	6
Mask RCNN	37.1		5
YOLOv1		64.5	45
SSD	31.2	76.8	19
YOLOv2	21.6	78.6	40
YOLOv3	33.0		45.4
RetinaNet	39.1		5

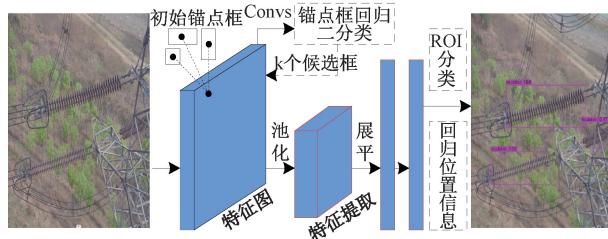


图 6 two-stage 算法检测流程图

Fig. 6 Detection flow chart of two-stage algorithm

R-CNN^[54]、R-FCN^[55] (region-based fully convolutional networks)等。作为主流的目标检测算法, Faster R-CNN 因其具有较高的检测准确率, 在输电线路目标检测领域得到了广泛应用。输电线路中包含有大量的金具设备, 它们起到支撑和固定电力线、架空线路等作用。为实现无人机航拍图像中金具设备锈蚀检测, 文献[56]提出了HSI颜色特征与Faster R-CNN模型相结合的金具锈蚀检测方法, HSI颜色模型用于去除图像中的背景干扰, Faster R-CNN模型实现锈蚀部位检测与定位, 该方法的锈蚀识别准确率和召回率达到了76.34%和71%, 但是HSI模型利用像素阈值进行有锈蚀区域检测会受到背景纹理噪声和光照影响, 易发生错检和漏检。为实现金具表面锈蚀准确识别及锈蚀状态评估, 文献[57]提出了基于视觉的设备表面锈蚀检测及评估方法, 先以ResNet50为骨干网络替代传统的VGG-16构建Faster R-CNN网络模型, 改进的Faster R-CNN模型用于识别设备表面锈蚀缺陷, 其锈蚀检测平均精度(accuracy precision, AP)高达94%, 再利用锈蚀区域与整个设备面积比进行锈蚀程度评估并判定锈蚀等级, 该方法能够实现锈蚀缺

陷准确识别及锈蚀程度有效评估, 但是阈值比较是锈蚀状态评估的主要手段, 阈值参数设定的好坏直接影响锈蚀等级判定。为了进一步提高深度学习网络模型的金具设备锈蚀缺陷识别精度, 文献[58]利用注意力机制改进Faster R-CNN, 提出了一种基于注意力引导的多任务卷积神经网络(attention-guided multitask convolutional neural network, AGMNet), 如图7所示, AGMNet由包含注意力机制模块的特征提取网络、可细化的区域提议网络(regional proposal network, RPN)、多任务检测网络等组成。先构建区域注意力机制模块, 将注意力机制模块嵌入到ResNet50特征提取网络中, 用于增强航拍图像中目标的特征表示;再引入一个可细化的RPN替代原始Faster R-CNN中的RPN和特征融合策略, 从而提高网络在第1阶段生成区域建议的质量;最后通过多任务检测实现金具设备异常状态识别及锈蚀程度评估。AGMNet网络模型实现了航拍图像中不同尺度目标识别及锈蚀状态检测, 金具设备(防震锤、均压环)检测的平均精确均值(mean accuracy precision, mAP)达到95.3%;金具锈蚀程度识别准确率为75.4%, 比Faster R-CNN(69.4%)提高了6%;但是该模型的检测速度仅有7.8 fps(frame per second, FPS), 比FPS为13.9的Faster R-CNN要慢很多。

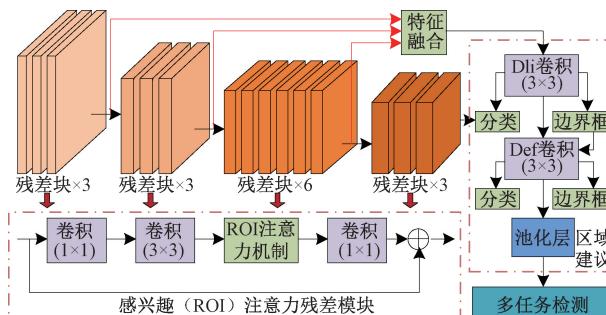


图 7 AGMNet 网络结构图

Fig. 7 Overview of AGMNet

螺栓作为输电线路中数量最多的紧固件之一, 开口销丢失及表面锈蚀缺陷在所难免。如何利用视觉检测方法实现螺栓缺销及其表面锈蚀缺陷智能检测, 是输电线路巡检图像中目标检测的一个难题。为了解决航拍图像中小目标金具 two-dimensional 视觉结构不一致的干扰问题, 文献[59]提出了一种自动视觉形状聚类网络(automatic visual shape clustering network, AVSCNet), AVSCNet 网络模型在现有 Faster R-CNN 的基础上引入了特征增强、特征融合和扩展感兴趣区域特征提取, 其网络结构如图8所示。AVSCNet 实现了销钉丢失缺陷检测, 销钉缺失检测 mAP 值达到 72.4%, 比 Faster R-CNN (63.1%) 提高了 9.3%;但是 AVSCNet 的 FPS 仅有 1.02, 远低于 Faster R-CNN 的 3.09。

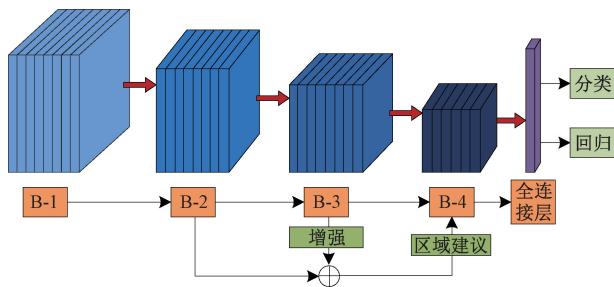


图 8 AVSCNet 网络结构图

Fig. 8 Overview of AVSCNet

输电线路中锈蚀的金具是影响其安全的一大隐患。为了提高锈蚀金具智能检测的可靠性和鲁棒性,文献[60]提出了具有特征增强机制的 Faster R-CNN 模

型,引入残差网络 ResNet-101 作为 Faster R-CNN 模型的骨干网络,在其感兴趣区域池化层之后添加了特征增强机制,有针对性地改进锈蚀金具的特征表示。对比结果证明了该模型在检测精度方面的有效性,其中锈蚀检测 AP 值达到 97.07%,比原始 Faster R-CNN 模型提高了近 11%。为了实现锈蚀螺栓的识别和螺栓松动的监测,文献[61]提出了 R-CNN 与 Hough 变换相结合的检测算法,R-CNN 算法用于锈蚀螺栓与非锈蚀螺栓的识别,Hough 变换算法实现螺栓的旋转角度估计,在不同捕获距离、视角扭曲和光强度条件下验证了该算法的可行性,但是训练样本有限,该算法只能进行螺栓有无锈蚀分类。

在输电线路金具锈蚀缺陷检测中应用的 two-stage 目标检测方法如表 3 所示。

表 3 在输电线路金具锈蚀缺陷检测中应用的 two-stage 目标检测方法

Table 3 Two-stage target detection methods used for rust detection of metal fittings in transmission lines

文献	方法	效果	局限性
[56]	HSI 颜色特征与 Faster R-CNN 相结合	锈蚀识别准确率和召回率达到了 76.34% 和 71%,每幅图像的平均处理时间缩短到了 0.141 s	HSI 模型会受到背景噪声和光照影响,易发生错检或漏检
[58]	基于注意力引导的多任务卷积神经网络(AGMNet),AGMNet 由包含注意力机制模块的特征提取网络、可细化的区域提议网络、多任务检测网络组成	电力设备检测的 mAP 达到 95.3%;电力设备锈蚀程度识别 mAP 为 75.4%,比 Faster R-CNN 提高了 6%;电力设备的状态识别 mAP 达到 93.2%,远高于 Faster R-CNN 的 83.1%	AGMNet 网络的检测速度仅有 7.8 fps,比 fps 为 13.9 的 Faster R-CNN 要慢得多
[60]	以 ResNet-101 为骨干网络,在其感兴趣区域池化层之后添加了特征增强机制	锈蚀检测的平均精度达到 97.07%,比原始 Faster R-CNN 模型提高了近 11%。	训练样本有限,只能进行目标定位,无法进行锈蚀程度评估
[61]	R-CNN 与 Hough 变换相结合的检测算法	在不同捕获距离、视角扭曲和光强度条件下验证了该算法的可行性	

2) 基于 one-stage 算法的金具锈蚀缺陷检测

基于回归的目标检测算法利用 DCNN 进行端到端的检测,不存在中间的区域检出过程,直接对待检测目标进行分类和定位,其检测流程如图 9 所示。典型的 one-stage 算法有:SSD^[62]、YOLO^[63-64]系列、RetinaNet 等。

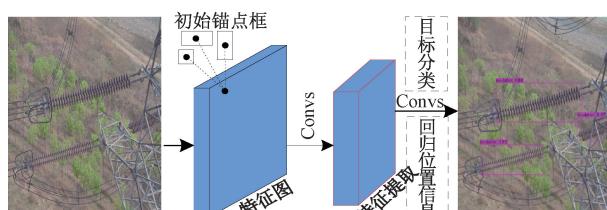


图 9 One-stage 算法检测流程图

Fig. 9 Detection flow chart of one-stage algorithm

YOLO 算法在检测精度和推理速度上具有突出的优势,是目前工程界首选的目标检测算法之一,众多研究者

利用 YOLO 算法进行电力设备识别与故障诊断研究。为了解决电力设备目标检测定位困难的问题,文献[15]利用多尺度特征融合改进 YOLOv4 进行设备锈蚀、裂纹、漏油等缺陷检测,改进的 YOLOv4 网络结构如图 10 所示。改进 YOLOv4 模型与 Faster R-CNN、原始 YOLOv4 进行了对比实验,实验结果表明改进模型在设备锈蚀、裂纹和漏油检测方面具有较好的检测效果,其中锈蚀缺陷检测 mAP 达到了 95.2%,比 Faster R-CNN、YOLOv4 分别提高了 5.7% 和 2%;改进模型实现了对电力设备锈蚀缺陷检测,有望在其他电力设备缺陷检测中推广应用,并为输电线路目标检测提供新的理论依据和技术支持。

文献[65]将 YOLO 与模糊评价算法相结合提出了一种高压断路器操动机构锈蚀状态评估方法,先利用 YOLO 算法进行目标识别与定位,再使用评价算法进行锈蚀状态检测,通过对 YOLOv3、YOLOv4、YOLOv5 进行对比实验,实验结果验证了 YOLOv5 算法在模型训练和

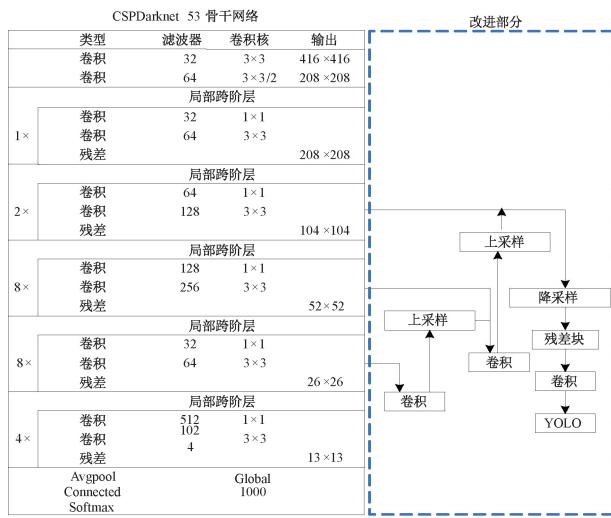


图 10 改进 YOLOv4 网络结构图

Fig. 10 Network structure of the improved YOLOv4

检测速度上具有很大优势。传统的视觉检测方法在进行设备锈蚀等表面缺陷检测时存在灵敏度低、检测效果差的缺点,为了解决上述问题,文献[66]对 YOLOv5 算法进行改进,提出了 YOLO-OurNet 网络模型,如图 11 所示。先将跨阶段局部网络 CSPNet 与 VoVNetV2 相结合构成 CSPVoV 骨干网络,再引入通道注意力机制模块 (efficient channel attention module, ECANet) 到 VoVNetV2 中,最后采用空间金字塔池化 (spatial pyramid pooling, SPP) 网络与 CSPNet 结合形成 CSPSPPNet 模块,并构建双向特征金字塔网络 (bidirectional feature pyramidal network, BiFPN) 加强特征融合,在测试集上进行了对比实验, YOLO-OurNet 的缺陷检测 FPS 达到了 46, 其缺陷检测准确率 (99.2%)、召回率 (98.9%) 和 F1 值 (98.8%) 均在 98% 以上,综合以上评价指标, YOLO-OurNet 在设备锈蚀缺陷检测方面比 YOLOv3、YOLOv4、YOLOv5 更具优势。

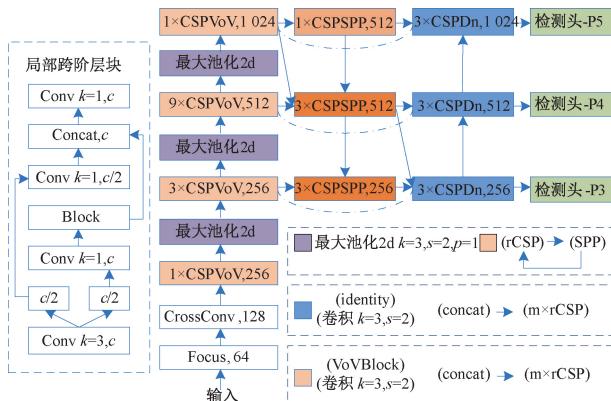


图 11 YOLO-OurNet 结构图

Fig. 11 Overview of YOLO-OurNet

针对传统图像处理技术和卷积神经网络难以有效处理输电线路中存在遮挡干扰的小目标金具密集检测任务,文献[67]提出了一种融合通道空间注意力机制和 Vision Transformer 的双注意力机制 YOLO 模型,其网络结构如图 12 所示。该模型首次将 Vision Transformer 的网络结构集成到 YOLOv5 的骨干网络中,提高了网络模型对输入图像上下文语义信息的理解,增强模型在特征图上的全局感受野;在网络模型的头部引入了注意机制模块 (convolutional block attention module, CBAM),使神经网络更加关注待检测区域的显著细节。与 YOLOv5s 进行了对比实验,实验结果表明,改进模型的金具识别 mAP 到了 94.8%, 比 YOLOv5s (90.2%) 提高了 4.6%, 但是其检测速度只有 YOLOv5s 的 1/4。

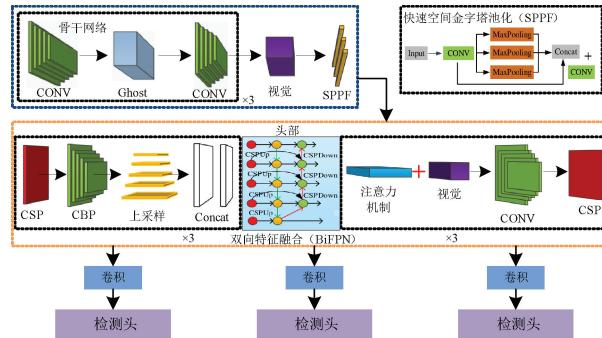


图 12 双注意力 YOLO 网络结构图

Fig. 12 Network structure of double attention YOLO

为了提高电力变压器外部锈蚀和漏油缺陷检测能力,文献[68]提出了 YOLOv3 和改进 LeNet-5 级联的缺陷检测算法, YOLOv3 用于电力变器的准确定位,以消除复杂背景干扰,改进的 LeNet-5 算法在缺陷检测过程中加入局部特征有利于提高电力变压器外部锈蚀和漏油缺陷检测精度。生成对抗网络 (generator adversarial networks, GAN)、变分自编码器 (variational autoEncoder, VAE) 等图像生成算法可以扩充缺陷样本数量,但是生成缺陷图像往往与电力变压器的实际应用场景不一致,为了解决此问题,文献[68]还利用泊松融合方法生成电力变压器锈蚀、漏油缺陷图像,进一步地提高了检测模型的锈蚀缺陷识别能力。

随着智能物联网技术的快速发展,越来越多的深度学习模型部署于智能边缘设备上。文献[17]采用 YOLOv3 智能识别钢结构表面锈蚀缺陷,为了解决深度学习网络模型难以在有限内存空间和计算力的边缘设备上正常运行的问题, Jiang 等人采用剪枝技术进行轻量化网络调整,在保证检测准确率的前提下,检测模型的内存使用量压缩到 YOLOv3 的 1/5, 其检测速度提高了近 1 倍。为了弥补轻量化网络特征提取带来的精度损失,文献[69]提出了基于 MobileNet-V3 的金具设备锈蚀目

标检测模型,通过级联双注意力机制模块改进目标检测模型,改进模型的金具设备锈蚀区域检测 AP 值达到 91.75%,比 YOLOv3 和 SSD 分别提高了 9.06% 和 20.4%;检测模型的所占内存空间仅需 20 MB,与 237 MB 的 YOLOv3 模型相比要小得多。

除了 YOLO 算法用于金具设备锈蚀缺陷检测以外,还有研究者利用 SSD 算法进行金具设备表面锈蚀缺陷检测。为了解决航拍图像中绝缘子锈蚀缺陷目标难以识别和定位的问题,文献[70]提出了基于特征融合和空间注意力机制改进的 SSD 模型,其改进模型如图 13 所示。改进模型的绝缘子锈蚀检测 mAP 达到 85.40%,比原始 SSD 和 YOLOv3 算法分别提高了 8.65% 和 2.9%,改进模型的 FPS 仅有 4.3,比 FPS 为 5.6 的 YOLOv3 算法要稍慢一些。

为了实现设备表面锈蚀、疤痕等缺陷检测,文献[71]提出了一种级联深度学习模型的表面缺陷自动检测方法,在 SSD 的基础上引入注意力机制挤压和激励网络模块(squeeze-and-excitation networks, SENet)得到前级网络模型 SSDSE600,先利用 SSDSE600 模型识别设备表面可能存在的缺陷,再使用基于 ResNet50 的后级网络模型对缺陷类型分类,实验结果表明,该方法能够在设备表面缺陷检测中取得较高的检测精度。

表 4 在输电线路金具锈蚀缺陷检测中应用的 one-stage 目标检测方法

Table 4 One-stage target detection methods used for rust detection of metal fittings in transmission lines

文献	方法	效果	局限性
[15]	利用多尺度特征融合改进 YOLOv4 进行变电站设备锈蚀、裂纹、漏油缺陷检测	锈蚀缺陷检测 mAP 为 95.2%,比 Faster R-CNN、YOLOv4 分别提高了 5.7% 和 2%	
[65]	YOLO 算法与模糊评价算法相结合	YOLOv5 在训练时间和检测速度上具有很大优势	
[66]	CSPVoV、通道注意力机制模块、CSPSPNet 模块改进 YOLOv5	缺陷检测时间仅需 0.024 s,准确率、召回率和 F1 值分别为 99.2%、98.9% 和 98.8%	
[68]	YOLOv3 和改进 LeNet-5 级联	外部锈蚀和漏油缺陷检测取得了较好的检测结果	
[69]	轻量化网络 MobileNet-V3 的电力设备锈蚀目标检测	电力设备锈蚀区域检测精度达到 91.75%,检测模型的所占内存空间仅需 20 MB	无法用矩形框对图像中电力设备的锈蚀区域进行准确标记,而矩形框内会包含过多干扰信息,从而影响后续的锈蚀状态识别
[70]	基于特征融合和空间注意力机制的改进 SSD 检测模型	绝缘子锈蚀检测 mAP 达到 85.40%,锈蚀检测平均处理时间为 0.23 s	

3.2 基于 DCNN 的金具设备锈蚀缺陷语义分割方法

传统分割算法大多针对图像的表层信息进行分割,无法有效应对需要大量语义信息的分割任务。语义分割本质是传统图像分割与目标识别融合,以各像素点分类的方式把图像分割成具有特定语义类别的区域。随着深度学习技术的快速发展,基于 DCNN 的语义分割方法实现了从像素级数据到抽象语义特征转换。图像语义分割是计算机视觉领域极具挑战性的问题,为实现更加高效且准确的图像分割,一系列基于 DCNN 的语义分割算法

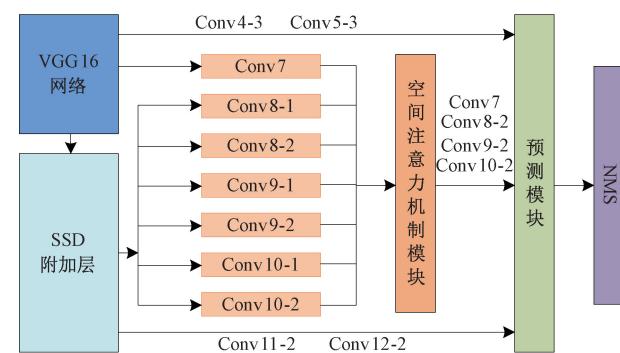


图 13 基于空间注意力机制的 SSD 模型

Fig. 13 SSD model based on spatial attention mechanism

基于深度学习的方法利用 DCNN 自动学习并提取图像深度特征,实现端到端的目标检测,具有学习能力强、可移植性好、适应性强等优点。由于输电线路金具设备的锈蚀区域不规则和不确定性,基于 DCNN 的目标检测方法只能用于电力巡检图像中的设备有无锈蚀缺陷检测,无法使用边界框进行锈蚀区域标记和锈蚀程度评估。

在输电线路金具锈蚀缺陷检测中应用的 one-stage 目标检测方法如表 4 所示。

被提出,如基于编码器-解码器结构的全卷积网络(fully convolutional network, FCN^[72])、U-Net^[73]、SegNet^[74],基于特征融合的金字塔场景解析网络(pyramid scene parsing network, PSPNet^[75]),以及基于空洞卷积层的 DeepLab^[76]系列等。

1) FCN:文献[72]利用 1×1 卷积层替换原始 CNN 中的全连接层,提出了 FCN 全卷积网络。FCN 采用卷积池化操作以提取图像高层语义特征,通过反卷积层和跳跃连接恢复图像分辨率,实现了分类网络向分割网络、图像

级分类向像素级分类双重转换。虽然 FCN 在上采样时容易造成像素位置信息丢失,导致分割结果比较粗糙,但是 FCN 开创了深度学习技术在图像分割中应用的先河。

2) U-Net: 2015 年 Ronneberger 等^[73]采用完全对称的编码器-解码器结构提出了用于生物医学图像分割的 U-Net 网络。编码器阶段,利用 3×3 卷积和 2×2 最大池化层降低图像分辨率提取图像特征;解码器阶段,低分辨率特征图(编码器端)采用跨层连接方式(复制与裁剪)与对应上采样生成的特征图(解码器端)相拼接。U-Net 网络实现了低分辨率的细节信息和高分辨率的高层语义信息融合,进一步提高了图像分割精度。

3) SegNet: 与 U-Net 网络结构类似,也采用对称编码器-解码器结构,不同的是编码器由 5 个卷积池化模块组成(VGG16 去掉全连接层),通过卷积池化操作提取特征图,解码器采用上采样层和最大池化层索引恢复低分辨率的输入特征图。SegNet^[74]训练参数较少,因此图像分割速度较快,为后续实时分割网络设计提供了思路。

4) PSPNet: 针对场景解析和语义分割任务,文献[75]利用金字塔池化模块将局部和全局信息融合,通过对不同尺度的特征聚合提出了 PSPNet 网络。该网络能够充分利用全局上下文信息,具有较好的分割性能,其在多个数据集上的分割精度超越了 FCN、U-Net、SegNet 等网络模型。

5) DeepLab 系列: 为了解决 FCN 网络在下采样时易造成空间信息丢失的问题,文献[76]提出了基于空洞卷积和全连接随机场(fully connected conditional random field, FCCRF)的 DeepLabv1 网络模型,该模型采用空洞卷积取代特征提取网络中的标准卷积,在增大感受野的同时还获得了更多的特征信息;特征提取网络的最后一层添加 FCCRF 能够更好地学习像素相关性。为进一步提高图像的分割性能,Chen 等人对 DeepLab v1 做了以下优化和改进:1)在 DeepLabv1 中引入空间金字塔池化模块(atrous spatial pyramid pooling, ASPP)捕获多尺度上下文信息,提出了 DeepLabv2 网络;2)在 ASPP 模块中添加批次正则化层,同时去除 FCCRF,提出了 DeepLabv3 网络;3)在 DeepLabv3 基础上引入解码模块以提高检测目标边界分割精度,提出了 DeepLabv3+ 等改进网络。

基于 DCNN 的语义分割网络模型通过图像各像素点分类实现检测目标的类别分割,目前很多研究者已经将基于深度学习的语义分割网络用于金具设备表面缺陷检测研究。为解决设备表面锈蚀图像难以分割和定量分析的问题,文献[77]通过 U-Net 网络模型进行表面锈蚀缺陷检测,同时还提出了锈蚀面积、锈蚀率、总体锈蚀率等评价量化指标,U-Net 网络模型在验证集上锈蚀图像分割准确率达到 90.56%。该方法可以拓展到其他目标表面缺陷检测,在更为丰富的数据集支持下,目标分割精度有

望进一步提升。文献[78]提出了网络结构为 8 层的 U-Net 用于设备表面锈蚀检测,该模型的锈蚀检测准确率达到 96.87%,与 5 层 U-Net 网络模型(93%)相比提高了 3.87%,比基于小波变换的传统图像处理方法(83.2%)提高了 13.67%。针对传统方法在进行设备表面锈蚀检测过程中存在锈蚀区域分割不准确的缺陷,文献[79]在 U-Net 网络的基础上引入双注意力机制改进锈蚀图像分割模型,该分割模型如图 14 所示。

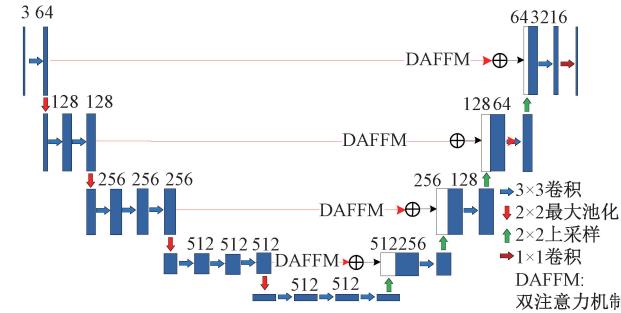


图 14 双注意力机制 U-Net 模型

Fig. 14 U-Net with DAFFM

该模型的编码器采用 4 个相同的编码块,每个编码块由 2 个 3×3 卷积层和 1 个 2×2 最大池化层组成;解码器由 4 个相同的解码块组成,每个解码块包括 2 个 3×3 卷积和 1 个 2×2 反卷积;下采样和上采样的跨层连接融合通道和空间双注意力机制。所构建的分割模型能够有效地从复杂背景中分割出设备的锈蚀区域,其锈蚀区域识别准确率高达 95.5%,高于 FCNs(94.5%)、SegNet(89.2%)、U-Net(92.2%)、DeepLab v3+(92.6%)等语义分割网络模型。

由于图像中的锈蚀形状不规则且大小不一,在进行设备表面锈蚀检测过程中容易受到噪声等因素干扰,为了进一步提高锈蚀图像检测准确率,文献[80]以 DenseNet 作为编码器, PSPNet 中间层、两个跨层连接和上采样层作为解码器改进 FCN 网络模型,改进模型用于通信杆塔表面锈蚀检测,其锈蚀检测结果优于 EfficientNet、U-Net 等对比网络模型。为了实现小样本数据集下的设备表面锈蚀缺陷检测,文献[81]先通过生成对抗网络 GAN 进行样本扩增,再利用 U-Net 和 DeepLabv3+ 网络模型进行样本图像锈蚀缺陷区域检测(DeepLabv3+ 模型结构如图 15 所示),其中 DeepLabv3+ 和 U-Net 在测试集上的锈蚀缺陷分割 AP 值分别为 93.5% 和 73.7%。对比实验结果表明,DeepLabv3+ 模型的分割精度明显高于 U-Net 网络,DeepLabv3+ 网络可以为其他电力设备表面锈蚀缺陷的智能语义分割提供技术支撑。

为实现输电线路航拍图像中金具锈蚀缺陷快速、准确地分割,文献[82]提出了基于轻量化 DeepLabv3+ 的语

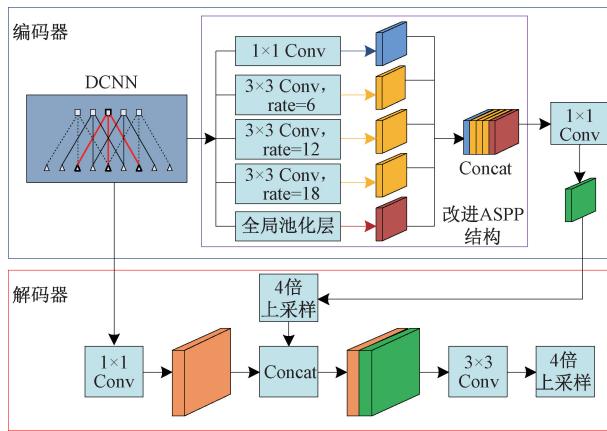


图 15 Deeplabv3+模型结构

Fig. 15 Model structure of Deeplabv3+

义分割网络模型,通过 MobileNetV3 网络和特征融合空洞空间金字塔池化结构 ASPP 改进 Deeplabv3+ 网络模型。通过与 U-net、HRNet、SegNet、PSPNet、原始 Deeplabv3+ 网

络模型进行对比实验可得,改进模型的金具锈蚀分割 AP 值达到了 96.64%,比 U-net (71.78%)、HRNet (81.18%)、SegNet (85.34%)、PSPNet (92.87%)、原始 Deeplabv3+(92.35%) 分别提高了近 25%、15%、11%、4% 和 4%;改进模型的推理时间缩短到了 15.94 ms,仅为原始 Deeplabv3+ 网络模型的一半。在执行输电线路巡检图像中金具设备锈蚀缺陷检测任务时,可以通过上述 FCN、U-Net、PSPNet、Deeplabv3+ 等语义分割网络模型实现锈蚀缺陷区域分割,对于多目标锈蚀检测任务可以通过 Mask R-CNN 等实例分割^[83]算法实现。

基于 DCNN 的语义分割方法通过像素分类的方式实现锈蚀区域检测以及锈蚀状态评估,但是语义分割网络模型设计复杂,且需要性能较高的硬件资源和大量的样本数据支撑。

在输电线路金具锈蚀缺陷检测中应用的语义分割方法如表 5 所示。

表 5 在输电线路金具锈蚀缺陷检测中应用的语义分割方法

Table 5 Semantic segmentation methods used for rust detection of metal fittings in transmission lines

文献	方法	效果	局限性
[78]	网络结构为 8 层的 U-Net	锈蚀检测准确率达到 96.87%,比 5 层 U-Net 提高了 3.87%,比基于小波变换的检测方法提高了 13.67%	
[79]	U-Net 网络与双注意力机制融合的锈蚀图像分割模型	其锈蚀区域识别准确率达到 95.5%,高于 FCNs、SegNet、U-Net、DeepLab v3+	需要庞大的训练样本数据,对硬件资源有较高的要求,各个数据集的标注准则不同和网络模型没有统一的衡量标准
[80]	基于 DenseNet 和 PSPNet 改进的 FCN	锈蚀检测结果优于 ENet、U-Net 等对比网络	
[81]	生成对抗网络 GAN 样本扩增结合 Deeplabv3+ 网络模型	该模型的分割精度明显高于 U-Net 网络,其可以为金属表面锈蚀缺陷的智能语义分割提供技术支撑	
[82]	MobileNetV、FEF-ASPP 改进 Deeplabv3+ 网络模型	分割精度比 U-net、HRNet、SegNet、PSPNet、Deeplabv3+ 分别提高了近 25%、15%、11%、4% 和 4%	

4 数据集及性能评价指标

4.1 数据集

训练卷积神经网络模型需要庞大的样本数据,基于深度学习的目标检测和语义分割网络模型的广泛应用,离不开数据集的支持。

常用的公开数据集有 ImageNet、CIFAR、COCO、PASCAL VOC、Cityscapes、KITTI、Youtube-Objects 等,百度飞桨 PaddlePaddle 开源深度学习平台也提供了大量的数据集供研究者实践。电网作为国家最重要的战略设施之一,其中的绝大部分电力设备图像处于非公开状态,仅有绝缘子和电力线有公开数据集,用于金具设备锈蚀缺陷

检测研究的数据集大多是学者们自建的数据集^[84]。

基于深度学习的输电线路金具设备锈蚀缺陷检测自建数据集如表 6 所示。

4.2 性能评估指标

深度学习网络模型应用于输电线路金具设备目标检测或语义分割中,需要对它们的性能进行评估,明确网络模型的优缺点。目标检测算法常用的性能评价指标如表 7 所示,包括准确率 Accuracy(正确预测样本在所有预测样本中所占的比率)、召回率 Recall 又称为查全率或真阳性率(被正确预测的锈蚀缺陷样本占所有锈蚀缺陷样本的比率)、精确率 Precision 又称为查准率(被正确预测的锈蚀缺陷样本占所有预测为锈蚀缺陷样本的比率)、F1 分数 F1-score(准确率和召回率的调和值)、假阳性

表 6 基于深度学习的输电线路金具设备锈蚀缺陷检测自建数据集

Table 6 Self-built data sets of transmission line metal fittings defect detection based on deep learning

检测对象	文献	数据集规模	图像分辨率	应用场景	深度学习框架	网络模型
金具	[56]	637	600×500	目标检测		Faster R-CNN
金具	[58]	1 209		目标检测	PyTorch	AGMNet
销钉	[59]	1 843	900×720	目标检测	TensorFlow	AVSCNet
金具	[60]	419	227×227	目标检测		Faster R-CNN
螺栓	[61]	350	112×112	目标检测	PyTorch	R-CNN
电力变压器	[15]	1 500	256×256	目标检测	TensorFlow	YOLO-v4
高压断路器	[66]	896	640×640	目标检测	PyTorch	YOLO 系列(v3~v5)
绝缘子、杆塔、金具等	[67]	6 600+7 700	640×640	目标检测	PyTorch	Transformer-YOLOv5
电力变压器	[68]	400	100×100	目标检测		YOLO-v3
绝缘子	[70]	1 159	1 000×800	目标检测	TensorFlow	SSD
电力杆塔	[80]	350	5 300×3 800	语义分割	PyTorch	Densenet + Pspnet
金具	[82]	2 160	256×256	语义分割	PyTorch	FEF-Deeplabv3+
均压环、电力拉环等	[84]	450	1 000×1 200	目标检测	Mxnet	Faster R-CNN

表 7 目标检测评价指标

Table 7 Evaluation indexes of object detection

评价指标	定义
准确率(ACC)	$ACC = \frac{TP + TN}{TP + FP + FN + TN}$
召回率(REC)	$REC = \frac{TP}{TP + FN}$
精确率(PRE)	$PRE = \frac{TP}{TP + FP}$
F1 分数(F1-score)	$F1 = \frac{2 \times PRE \times REC}{PRE + REC}$
假阳性率(FPR)	$FPR = \frac{FP}{TN + FP}$
假阴性率(FNR)	$FNR = \frac{FN}{TN + TP}$
平均精度(AP)	$AP_C = \int_0^1 P_R dR$
平均精度均值(mAP)	$mAP = \frac{\sum AP_C}{N(classes)}$

率(false positive rate, FPR)又称为误检率或虚警率(背景被预测为锈蚀缺陷样本占所有负样本的比率)、假阴性率(false negative rate, FNR)又称为漏检率或漏警率(锈蚀缺陷样本被预测为负样本占所有锈蚀缺陷样本的比率)、交并比(intersection over union, IoU)、平均精度 AP(预测正确的样本数与所有样本数的比率)、平均精度均值 mAP(各类别预测正确的样本数占所有样本数的平均值)。

在二分类任务中,混淆矩阵通过真正例(true positive, TP)、假正例(false positive, FP)、真反例(true

negative, TN)、假反例(false negative, FN)指标描述真实值与预测结果之间的关系。

语义分割算法评价指标如表 8 所示,由像素精度(pixel accuracy, PA)、像素精度均值(mean pixel accuracy, MPA)、交并比(IoU)、平均交并比(MIoU)、频率权重交并比(frequency weighted intersection over union, FWIoU),以及 Dice 系数等。

表 8 语义分割评价指标

Table 8 Evaluation indexes of semantic segmentation

评价指标	定义
像素精度(PA)	$PA = \frac{\sum_{i=0}^k p_{ii}}{\sum_{i=0}^k \sum_{j=0}^k p_{ij}}$
像素精度均值(MPA)	$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{\sum_{j=0}^k p_{ii}}{\sum_{j=0}^k p_{ij}}$
平均交并比(IoU)	$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}$
频率权重交并比(FWIoU)	$FWIoU = \frac{1}{\sum_{i=0}^k \sum_{j=0}^k} \sum_{i=0}^k \frac{\sum_{j=0}^k p_{ij} p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}$
Dice 系数	$Dice = \frac{2 \times TP}{(TP + FN) + (TP + FP)}$

5 主要问题和展望

5.1 主要问题

输电线路金具锈蚀缺陷将危害输电线路的安全稳定运行。日益发展的图像识别技术可以根据航拍图像数据信息来判断电力设备是否存在锈蚀缺陷。但是输电线路通道环境复杂,且金具设备锈蚀形状不规则,以及不同金具的锈蚀形态有较大的差异,传统的图像处理方法基于颜色、纹理等特征进行锈蚀区域识别会受到背景噪声干扰,造成错检或漏检现象,导致金具设备锈蚀缺陷识别准确率不高。随着机器视觉与深度学习有效结合,并借助高性能的边缘计算设备,使得图像识别技术进入了一个新的阶段。基于深度学习的视觉检测技术应用于输电线路智能巡检,推动输电线路巡检向自动化、智能化方向创新和进步。深度学习技术在电力巡检中发挥着重要作用,基于深度学习的视觉检测方法已成功用于输电线路金具设备锈蚀缺陷检测,但也揭示了诸多问题等待挑战。

1) 缺乏锈蚀缺陷检测数据集。基于图像数据驱动的深度学习网络模型,其目标检测精度依赖于数据集的规模和质量。由于锈蚀缺陷数据集较少,且用于输电线路金具设备锈蚀检测的公开样本不多,有限样本训练出的深度学习网络模型易过拟合或无法收敛。

2) 锈蚀缺陷样本标注问题。输电线路金具设备识别及锈蚀缺陷检测数据集的构建依赖人工标注,人工标注训练样本费时费力。在 Nguyen 等^[8]的样本标注工作中,平均 1 小时人工标注 40 幅图像,构建一个中等规模数据集将花费 700 个小时。

3) 先验条件缺失下的锈蚀缺陷检测。深度学习网络模型对数据集里出现的目标具有较好的识别效果,但是对于实际场景中的遮挡、模糊、变形等目标,以及数据集中没有出现的相似目标检测鲁棒性不高。国网 2018 年 EPTC 年会公布在役金具模型超过 1 900 种,国网运维管理规定指出金具缺陷类型达到 111 种,用于金具设备识别及锈蚀缺陷检测的自建数据集难以覆盖所有的金具种类和锈蚀缺陷类型。

4) 锈蚀缺陷小目标检测效果不佳。金具设备种类众多,对于不同尺度的航拍图像,小目标金具设备分辨率低、信息量少、识别准确率低,例如防震锤、均压环、螺栓、间隔棒、销钉等,其锈蚀缺陷特征不明显,难以有效提取金具锈蚀特征。YOLO、SSD、Faster R-CNN 等经典的深度学习网络模型在锈蚀缺陷小目标检测方面效果欠佳。

5) 复杂背景下锈蚀缺陷特征提取。现实场景中电力设备锈蚀区域背景复杂,由于锈蚀形状不规则,且锈蚀区域大小不一,增加了锈蚀缺陷特征提取难度,导致金具设备识别及锈蚀缺陷检测准确率不高。

5.2 未来研究工作展望

随着输电线路智能巡检研究的不断深入,深度学习网络模型对输电线路金具设备锈蚀缺陷检测有着很好的检测结果,但是在数据集规模及样本标注、先验条件缺失下的目标检测、小目标检测、特征提取等方面面临严峻的挑战。基于视觉的金具设备锈蚀缺陷检测技术还需要进一步改进。未来的研究工作将从以下几个方面展开:

1) 构建小样本锈蚀缺陷数据集。收集金具设备锈蚀缺陷航拍图像,通过生成对抗网络、图像融合技术扩充训练样本多样性。如何利用生成对抗网络模型、图像配准、多源图像融合等技术有效扩增出特征多样性锈蚀缺陷样本将是未来研究热点之一。

2) 弱监督或无监督锈蚀缺陷目标检测。借助半自动标注工具,利用交互式图像标注方法降低人工标注成本。深度学习与弱监督、无监督等学习方式结合实现锈蚀缺陷目标检测是未来目标检测的研究方向之一。

3) 锈蚀等级评价标准。输电线路中金具设备种类众多,不同设备的锈蚀程度各不相同,由于不同目标之间的差异性,以及深度学习算法的多样性,金具设备锈蚀缺陷检测及信息量化还没有统一的评价标准,亟需建立用于电力设备锈蚀等级性能评价标准。

4) 提高模型的锈蚀缺陷小目标检测能力。输电线路中小目标金具较多,其中防震锤、均压环、螺栓、销钉等占据了 50% 以上。如何进行小目标锈蚀缺陷检测是当前电力巡检亟需解决的一个问题。多尺度特征融合、特征金字塔网络、注意力机制、可变形卷积、网络模型级联等策略结合训练出性能更好的深度学习网络模型将成为锈蚀缺陷小目标检测研究的重点。

5) 多种网络模型深度融合。金具设备锈蚀区域不规则,目前主流的深度学习网络模型进行锈蚀缺陷检测时容易受到图像噪声干扰,难以有效地提取锈蚀区域特征。如何将目标检测、语义分割等机器视觉任务融合到一个检测模型中,以及在不影响处理速度的前提下提高检测精度是从事智能巡检研究人员面临的重要挑战。

6) 多种检测方法结合。深度学习方法是近年来主流的目标检测方法,但是利用多层卷积神经网络对金具设备锈蚀缺陷特征提取不够理想。基于 DCNN 的目标检测算法能够准确地识别锈蚀金具,但只能判断金具设备有无锈蚀缺陷,无法准确定位锈蚀区域;传统图像处理方法和基于 DCNN 的语义分割算法能够精确定位金具锈蚀区域,但在复杂背景下容易漏检或误检。如何将深度学习方法与传统图像处理方法结合进行锈蚀缺陷特征提取、分类及锈蚀等级评估将会取得良好的效果。

7) 网络模型轻量化。为满足实际场景需求,促进输电线路智能巡检技术落地,将深度学习网络模型部署在嵌入式设备上用于金具设备表面锈蚀缺陷实时检测,网

络模型轻量化尤为重要。保证网络模型的准确性、实时性和鲁棒性,降低模型计算开销是目标检测领域的研究方向之一。

6 结 论

电网安全稳定运行是国计民生的重要保障。输电线路金具设备锈蚀缺陷对输电线路的安全运行有巨大危害,因此对线路中设备识别及锈蚀缺陷检测具有重要意义。本文围绕输电线路中金具设备锈蚀缺陷检测问题,从可见光图像中金具设备目标检测技术流程出发,介绍了基于传统图像处理的金具锈蚀缺陷检测流程,概述了基于特征、图论分割、深度学习的锈蚀缺陷检测方法,并比较和分析了主要锈蚀缺陷检测方法的优缺点,给出了基于深度学习的金具设备锈蚀缺陷检测自建数据集以及性能评价指标,指明了金具设备锈蚀缺陷检测从传统图像处理向深度学习不断演变是智能电网建设的必然趋势。与传统方法相比,深度学习方法能更有效地实现无人机航拍图像中金具设备锈蚀缺陷快速检测。最后阐明了基于深度学习的锈蚀缺陷检测方法在缺乏训练样本、样本标注困难、小目标检测、特征提取等方面面临挑战,同时针对现有的深度学习技术和最近的研究思路,详细分析了基于深度学习的金具设备锈蚀缺陷检测未来的发展趋势。通过以上的论述,期望本文为从事电力巡检的研究人员提供有价值的参考。

参考文献

- [1] 马富齐,王波,董旭柱,等.面向输电线路覆冰厚度辨识的多感受野视觉边缘智能识别方法研究[J].电网技术,2021,45(6):2161-2169.
MA F Q, WANG B, DONG X ZH, et al. Receptive field vision edge intelligent recognition for ice thickness identification of transmission line [J]. Power System Technology, 2021, 45 (6) : 2161-2169.
- [2] 赵振兵,蒋志钢,李延旭,等.输电线路部件视觉缺陷检测综述[J].中国图象图形学报,2021,26(11):2545-2560.
ZHAO ZH B, JIANG ZH G, LI Y X, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26 (11) : 2545-2560.
- [3] 叶飞,骆星智,宋永春,等.基于双特征融合的改进R-CNN电力小金具缺陷检测方法研究[J].电子测量与仪器学报,2023,37(7):213-220.
YE F, LUO X ZH, SONG Y C, et al. Research on defect inspection of power small fittings based on improved R-CNN and double feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (7) : 213-220.
- [4] 刘传洋,吴一全.基于深度学习的输电线路视觉检测方法研究进展[J].中国电机工程学报,2023,43(19):7423-7446.
LIU CH Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission lines [J]. Proceedings of the CSEE, 2023, 43 (19) : 7423-7446.
- [5] 彭继慎,孙礼鑫,王凯,等.基于模型压缩的ED-YOLO电力巡检无人机避障目标检测算法[J].仪器仪表学报,2021,42(10):161-170.
PENG J SH, SUN L X, WANG K, et al. ED-YOLO power inspection UAV obstacle avoidance target detection algorithm based on model compression [J]. Chinese Journal of Scientific Instrument, 2021, 42 (10) : 161-170.
- [6] 刘开培,李博强,秦亮,等.深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述[J].高电压技术,2023,49(9):3584-3595.
LIU K P, LI B Q, QIN L, et al. Review of application research of deep learning object detection algorithms in insulator defect detection of overhead transmission lines [J]. High Voltage Apparatus, 2023, 49 (9) : 3584-3595.
- [7] 商俊平,李储欣,陈亮.基于视觉的绝缘子定位与自爆缺陷检测[J].电子测量与仪器学报,2017,31(6):844-849.
SHANG J P, LI CH X, CHEN L. Location and detection for self-explode insulator based on vision [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31 (6) : 844-849.
- [8] NGUYEN V N, JENSSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning [J]. International Journal of Electrical Power and Energy Systems, 2018, 99: 107-120.
- [9] 贾晓芬,吴雪茹,赵伯亭.绝缘子自爆缺陷的轻量化检测网络DE-YOLO[J].电子测量与仪器学报,2023,37(5):28-35.
JIA X F, WU X R, ZHAO B T. Lightweight detection network for insulator self-detonation defect DE-YOLO [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (5) : 28-35.

- trumentation, 2023, 37(5): 28-35.
- [10] MIAO X R, LIU X Y, CHEN J, et al. Insulator detection in aerial images for transmission line inspection using single shot multibox detector [J]. IEEE Access, 2019, 7: 9945-9956.
- [11] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- LI SH B, YANG J, WANG ZH, et al. Review of development and application of defect detection technology [J]. Acta Automatica Sinica, 2020, 46(11): 2319-2336.
- [12] LI Y D, KONTSOS A, BARTOLI I. Automated rust-defect detection of a steel bridge using aerial multispectral imagery [J]. Journal of Infrastructure System, 2019, 25(2): 04019014.
- [13] HUANG X B, ZHANG X L, ZHANG Y, et al. A method of identifying rust status of dampers based on image processing [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(8): 5407-5417.
- [14] VOROBEL R, IVASENKO I, BEREHULYAK O, et al. Segmentation of rust defects on painted steel surfaces by intelligent image analysis [J]. Automation in Construction, 2021, 123: 103515.
- [15] CHEN X J, AN Z Y, HUANG L S, et al. Surface defect detection of electric power equipment in substation based on improved YOLOV4 algorithm [C]. 2020 10th International Conference on Power and Energy Systems (ICPES 2020), Chengdu, 2020: 256-261.
- [16] BAHRAMI Z, ZHANG R, RAYHANA R, et al. Optimized deep neural network architectures with anchor box optimization for shipping container corrosion inspection [C]. 2020 IEEE Symposium Series on Computational Intelligence (IEEE SSCI), 2020: 1328-1333.
- [17] JIANG W, LIU T L, CHEN Y, et al. Lightweight convolutional neural network-based method for crane safety inspection [C]. 2020 7th International Conference on Dependable Systems and Their Applications (DSA), 2020: 324-329.
- [18] 张瀚丹, 吴一全. 基于视觉的汽车装配件缺陷检测研究进展[J]. 仪器仪表学报, 2023, 44(8): 1-20.
- ZHANG H D, WU Y Q. Research progress of vehicle assembly defect detection methods based on vision [J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 1-20.
- [19] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.
- ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [20] 张洪才. 直升机巡检输电线路锈蚀缺陷识别方法研究[D]. 大连: 大连海事大学, 2009.
- ZHANG H C. The method research on rusty defect identification of inspecting transmission line by helicopter [D]. Dalian: Dalian Maritime University, 2009.
- [21] CHEN P H, SHEN H K, LEI C Y, et al. Fourier-transform-based method for automated steel bridge coating defect recognition [C]. 12th East Asia-Pacific Conference on Structural Engineering and Construction (EASEC), 2011: 470-476.
- [22] 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(S1): 113-117.
- SONG W, ZUO D, DENG B F, et al. Corrosion defect detection of earthquake hammer for high voltage transmission line [J]. Chinese Journal of Scientific Instrument, 2016, 37(S1): 113-117.
- [23] 姜哲. 无人机巡线电力设备故障的视觉检测技术[D]. 成都: 电子科技大学, 2017.
- JIANG ZH. Visual detection for fault diagnosis of power equipment by UAV line patrol [D]. Chengdu: University of Electronic Science and Technology of China, 2017.
- [24] 黎春翔. 无人机电力巡检图像的缺陷检测和信息量化[D]. 广州: 华南理工大学, 2020.
- LI CH X. Defect detection and information quantification of UAV power inspection images [D]. Guangzhou: South China University of Technology, 2020.
- [25] 陈肇隆. 基于无人机图像的输电线路附件识别与缺陷检测[D]. 南京: 南京理工大学, 2020.
- CHEN ZH J. Accessory identification and defect detection of transmission line based on UAV-taken images [D]. Nanjing: South China University of Technology, 2020.
- [26] FERNANDEZ-LSLA C, NAVARRO P J, ALCOVER P M. Automated visual inspection of ship hull surfaces using the wavelet transform [J]. Mathematical Problems in Engineering, 2013: 101837.

- [27] 何翔, 李亮玉, 王天琪, 等. 基于磁光成像的低碳钢 WAAM 成形件表面缺陷检测与分类[J]. 仪器仪表学报, 2020, 41(4): 255-262.
HE X, LI L Y, WANG T Q, et al. Surface defects detection and classification of low carbon steel WAAM formed parts based on magneto-optical imaging [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 255-262.
- [28] 李雪琴, 刘培勇, 殷国富, 等. 基于 Fourier 拟合曲面的 X 射线焊缝缺陷检测[J]. 焊接学报, 2014, 35(10): 61-64, 116.
LI X Q, LIU P Y, YIN G F, et al. Weld defect detection by X-ray images method based on Fourier fitting surface [J]. Transactions of the China Welding Institution, 2014, 35(10): 61-64, 116.
- [29] 钟万里, 徐俊, 谢涛, 等. 基于导波频散特征的金属排管缺陷辨识方法[J]. 中南大学学报(自然科学版), 2015, 46(10): 3682-3688.
ZHONG W L, XU J, XIE T, et al. Defect identification of metal pipe based on guided wave dispersion characteristics[J]. Journal of Central South University (Science and Technology), 2015, 46(10): 3682-3688.
- [30] 吴彰良, 孙长库, 刘洁. 基于图像处理的油封缺陷自动检测与分类识别方法[J]. 仪器仪表学报, 2013, 34(5): 1093-1099.
WU ZH L, SUN CH K, LIU J. Oil-seal surface defect automatic detection and recognition method based on image processing [J]. Chinese Journal of Scientific Instrument, 2013, 34(5): 1093-1099.
- [31] SHEN H K, CHEN P H, CHANG L M. Automated steel bridge coating rust defect recognition method based on color and texture feature [J]. Automation in Construction, 2013, 31: 338-356.
- [32] ACOSTA M, DIAZ J, CASTRO N. An innovative image-processing model for rust detection using Perlin Noise to simulate oxide textures [J]. Corrosion Science, 2014, 88: 141-151.
- [33] ALKANHAL T. Image processing techniques applied for pitting corrosion analysis [J]. International Journal of Research in Engineering and Technology, 2014, 3(1): 385-391.
- [34] 黄杰贤, 杨冬涛, 欧阳玉平, 等. 钢丝绳锈蚀、磨损缺陷识别研究[J]. 表面技术, 2016, 45(10): 187-192.
HUANG J X, YANG D T, OUYANG Y P, et al. Corrosion and wear defects recognition of wire rope [J]. Surface Technology, 2016, 45(10): 187-192.
- [35] 蒋泽峰. 无人机巡线图像管理与图像查重系统设计与实现[D]. 成都: 电子科技大学, 2019.
JIANG Z F. Design and implementation of UAV line patrol image management and image duplicate checking system [D]. Chengdu: University of Electronic Science and Technology of China, 2019.
- [36] 张新星. 针对输电线路防震锤锈蚀的缺陷识别与量化分析[D]. 济南: 山东大学, 2022.
ZHANG X X. Defect identification and quantitative analysis of anti-vibration hammer corrosion of transmission lines [D]. Ji'nan: Shandong University, 2022.
- [37] 韩晓微, 岳高峰, 谢英红, 等. 动态视角下自主目标识别与跟踪[J]. 仪器仪表学报, 2019, 40(3): 221-229.
HAN X W, YUE G F, XIE Y H, et al. Autonomous target recognition and tracking under dynamic perspective [J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 221-229.
- [38] 吴润良. GrabCut 彩色图像分割方法研究[D]. 兰州: 兰州大学, 2021.
WU R L. Research on GrabCut color image segmentation method [D]. Lanzhou: Lanzhou University, 2021.
- [39] 张岳魁. 基于视觉的高压输电线路锈蚀检测[D]. 北京: 北京交通大学, 2018.
ZHANG Y K. Vision-based corrosion detection of high voltage transmission line [D]. Beijing: Beijing Jiaotong University, 2018.
- [40] 肖志云, 王海强. 图像双分割与小波域多特征融合的高压输电线路典型小目标故障识别[J]. 电网技术, 2021, 45(11): 4461-4470.
XIAO ZH Y, WANG H Q. Typical small target fault identification of high-voltage transmission lines based on image double segmentation and fusion of multi-features in wavelet domain [J]. Power System Technology, 2021, 45(11): 4461-4470.
- [41] AIJAZI A K, MALATERRE L, TAZIR M L, et al. Detection and analyzing corrosion spots on the hull of large marine vessels using colored 3D LiDAR point clouds [C]. 23rd ISPRS Congress, Czech Republic, 2016, 3(3): 153-160.
- [42] JI G, ZHU Y H, ZHANG Y Z. The corroded defect rating system of coating material based on computer

- vision [C]. 6th International Conference on E-Learning and Games, Edutainment 2011, 2011: 210-220.
- [43] SON H, HWANG H, KIM C, et al. Rapid and automated determination of rusted surface areas of a steel bridge for robotic maintenance systems [J]. Automation in Construction, 2014, 42: 13-24.
- [44] 于重重, 萨良兵, 马先钦, 等. 基于度量学习的小样本零器件表面缺陷检测 [J]. 仪器仪表学报, 2020, 41(7): 214-223.
- YU CH CH, SA L B, MA X Q, et al. Few-shot parts surface defect detection based on the metric learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(7): 214-223.
- [45] CHATFIELD K, SIMONYAN K, VEDALDI A, et al. Return of the devil in the details: delving deep into convolutional neural networks [J]. Computer Science, 2014, 41: 1-41.
- [46] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. European Conference on Computer Vision and Pattern Recognition (CVPR), Boston, 2015.
- [47] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 2016: 770-778.
- [48] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size [J]. ArXiv Preprint, 2016, ArXiv: 1602.07360v1.
- [49] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. ArXiv Preprint, 2017, ArXiv: 1704.04861.
- [50] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, 2018.
- [51] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, USA, 2014: 580-587.
- [52] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolution networks for visual recognition [C]. European Conference on Computer Vision (ECCV), Zürich, Switzerland, 2014: 346-361.
- [53] GIRSHICK R. Fast R-CNN [C]. IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 1440-1448.
- [54] REN S Q, HE K M, 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, 2015, 39(6): 1137-1149.
- [55] DAI J F, LI Y, HE K M. R-FCN: object detection via region-based fully convolutional networks [C]. Proceeding of 30th Conference on Neural Information Processing Systems (NIPS), Barcelona, SPAIN, 2016.
- [56] TIAN Z R, ZHANG G F, LIAO Y L, et al. Corrosion identification of fittings based on computer vision [C]. 2019 International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM), Dublin, Ireland, Oct 16-18, 2019, 592-597.
- [57] XU X B, WANG Y H, WU J, et al. Intelligent corrosion detection and rating based on faster region-based convolutional neural network [C]. 2020 Global Reliability and Prognostics and Health Management, Shanghai, China, Oct 16-18, 2020.
- [58] ZHANG H, WU L C, CHEN Y R, et al. Attention-Guided multitask convolutional neural network for power line parts detection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 5008213.
- [59] ZHAO Z B, QI H Y, QI Y C, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 6080-6091.
- [60] GUO Z M, TIAN Y Y, MAO W D. A Robust Faster R-CNN model with feature enhancement for rust detection of transmission line fitting [J]. Sensors, 2022, 22: 7961.
- [61] TA Q B, KIM J T. Monitoring of corroded and loosened bolts in steel structures via deep learning and Hough transforms [J]. Sensors, 2020, 20(3): 6888.
- [62] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector [C]. European Conference on Computer Vision (ECCV), Amsterdam, 2016.
- [63] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. ArXiv Preprint, 2018, ArXiv:

1804. 02767.
- [64] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint, 2020, ArXiv:2004. 10934.
- [65] 杨鼎革, 丁彬, 高健, 等. 基于图像深度学习的高压断路器操动机构锈蚀状态评估[J]. 电工电能新技术, 2022, 41(5): 71-79.
- YANG D G, DING B, GAO J, et al. Rust status evaluation of high voltage circuit breaker operating mechanism based on image deep learning[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(5): 71-79.
- [66] TAO J M, ZHU Y J, JIANG F, et al. Rolling surface defect inspection for drum-shaped rollers based on deep learning [J]. IEEE Sensors Journal, 2022, 22 (9): 8693-8700.
- [67] SONG Z W, HUANG X B, JI C, et al. Double-attention YOLO: Vision transformer model based on image processing technology in complex environment of transmission line connection fittings and rust detection[J]. Machines, 2022, 10: 1002.
- [68] ZHAO J, YOU Z F, WANG X Y, et al. A hybrid CNN/Poisson fusion based power transformer external defect detecting method [C]. 2020 IEEE/IAS Industrial and Commercial Power System Asia, Weihai, China, July 13-15, 2020.
- [69] 吴之昊. 面向电力设备锈蚀区域检测的目标识别算法研究[D]. 杭州:浙江理工大学, 2019.
- WU ZH H. Research on object recognition algorithm for corrosion area detection of power equipment [D]. Hangzhou: Zhejiang Sci-Tech University, 2019.
- [70] 王婷. 基于 SSD 的航拍图像中绝缘子识别与定位研究[D]. 北京:华北电力大学, 2021.
- WANG T. Research on recognition and location of insulators in aerial images based on SSD [D]. Beijing: North China Electric Power University, 2021.
- [71] LIN C Y, CHEN C H, YANG C Y, et al. Cascading convolutional neural network for steel surface defect detection[C]. 10th Int Conf on Appl Human Factors and Ergon (AHFE)/AHFE Int Conf Human Factors in Artificial Intelligence and Social Comp/AHFE Int Conf on Human Factors, Software, Serv and Syst Engn/AHFE Int Conf of Human Factors in Energy, Washington, DC, July 24-28, 2019, 202-212.
- [72] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [73] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. 18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), Munich, GERMANY, 2015.
- [74] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017: 1-1.
- [75] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network [J]. ArXiv Preprint, 2017, ArXiv: 1612. 01105.
- [76] 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, 2018, 40(4): 834-848.
- [77] 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, 146.
- WANG D L, PENG B, PAN Y, et al. Segmentation and quantitative analysis of corrosion images based on deep neural networks[J]. Journal of South China University of Technology(Natural Science Edition), 2018, 46(12): 121-127, 146.
- [78] SRIVASTAVA A, JI G, SINGH R K. Application of deep-learning architecture for image analysis based corrosion detection [C]. 2021 Smart Technologies, Communication and Robotics (STCR), Sathyamangalam, India, Oct 9-10, 2021.
- [79] 陈法法, 成孟腾, 杨蕴鹏, 等. 融合双注意力机制和 U-Net 网络的锈蚀图像分割[J]. 西安交通大学学报, 2021, 55(12): 119-128.
- CHEN F F, CHENG M T, YANG Y P, et al. A segmentation method based on dual attention mechanism[J]. Journal of Xi'an Jiaotong University, 2021, 55(12): 119-128.
- [80] LE D D, NGO T A, NGO T S, et al. Deep learning in semantic segmentation of rust in images [C]. 2020 9th

International Conference on Software and Computer Applications, Langkawi, Malaysia, Feb 18-21, 2020, 129-132.

- [81] 倪有豪, 陆欢, 季超, 等. 基于语义分割的桥梁锈蚀病害识别对比分析[J]. 东南大学学报(自然科学版), 2023, 53(2):201-209.

NI Y H, LU H, JI CH, et al. Comparative analysis on bridge corrosion damage detection based on semantic segmentation[J]. Journal of Southeast University(Natural Science Edition), 2023, 53(2):201-209.

- [82] 王凌云, 李婷宜, 李阳, 等. 基于FEF-DeepLabV3+的电力金具锈蚀分割方法[J]. 电子测量与仪器学报, 2023, 37(7): 166-176.

WANG L Y, LI T Y, LI Y, et al. Segmentation method of power armor clamp corrosion Based on FEF-DeepLabV3+[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7):166-176.

- [83] 蔡彪, 沈宽, 付金磊, 等. 基于Mask R-CNN的铸件X射线DR图像缺陷检测研究[J]. 仪器仪表学报, 2020, 41(3):61-69.

CAI B, SHEN K, FU J L, et al. Research on defect detection of X-ray DR images of casting based on Mask R-CNN[J]. Chinese Journal of Scientific Instrument, 2020, 41(3):61-69.

- [84] 李辉, 钟平, 戴玉静, 等. 基于深度学习的输电线路锈蚀检测方法的研究[J]. 电子测量技术, 2018, 41(22): 54-59.

LI H, ZHONG P, DAI Y J, et al. Study on detection method of transmission line rusty based on deep learning[J]. Electronic Measurement Technology, 2018, 41(22): 54-59.

作者简介



刘传洋, 2010年于南京航空航天大学获得硕士学位, 现为南京航空航天大学电子信息工程学院信息与通信工程专业博士研究生, 主要研究方向为图像处理与机器视觉。

E-mail: liuchuanyang608@nuaa.edu.cn

Liu Chuanyang received M.Sc. degree from Nanjing University of Aeronautics and Astronautics in 2010. He is currently pursuing his Ph.D. degree in information and communication engineering, College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics. His main research interests include image processing and machine vision.



吴一全(通信作者), 1998年于南京航空航天大学获得博士学位, 现为南京航空航天大学教授、博士生导师, 主要研究方向为遥感图像处理与理解、红外目标检测与识别、视觉检测与图像测量、视频处理与智能分析等。

E-mail: nuaaimage@163.com

Wu Yiquan (Corresponding author) received his Ph.D. degree from Nanjing University of Aeronautics and Astronautics in 1998. He is currently a professor and a Ph.D. advisor at Nanjing University of Aeronautics and Astronautics. His main research interests include remote sensing image processing and understanding, infrared target detection and recognition, visual detection and image measurement, video processing and intelligent analysis, et al.