

基于机器视觉的电力塔杆锈蚀程度检测

黄荷, 黄靖, 廖佳祥

(福建理工大学 电子电气与物理学院, 福建 福州 350118)

摘要: 针对电力塔杆在不同环境下运行容易产生表面锈蚀的问题, 利用机器视觉技术引入一种基于 YOLACT 的实例分割方法。将 ResNet 作为主干网络来提取图像特征, 使用多损失函数和 Fast NMS 来提高模型的分割性能; 以 YOLACT 建立基线, 在不同主干网络和分辨率下进行训练, 选择平均精度较好的 ResNet101-700×700 模型; 从采集的图像中推断锈蚀的 RGB 颜色特征并划分锈蚀等级。使用边界框策略对塔杆进行锈蚀程度检测, 提出线性投影的概念以更好地定位出锈蚀区域。在测试集上对该方法进行验证, 其识别平均精确率达到 97.3%、平均召回率为 94.1%。

关键词: 机器视觉; 电力塔杆; YOLACT; 锈蚀检测; 线性投影

中图分类号: TP391.4

文献标志码: A

文章编号: 2097-3853(2024)06-0582-08

Corrosion degree detection of power tower poles based on machine vision

HUANG He, HUANG Jing, LIAO Jiaxiang

(School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China)

Abstract: In response to the problem of surface corrosion of power tower poles in different environments, an instance segmentation method based on YOLACT is introduced by using machine vision technology. ResNet is used as the backbone network to extract image features, and multi-loss functions and Fast NMS are used to improve the segmentation performance of the model. YOLACT is used to establish the baseline, training is conducted at different backbone networks and resolutions, the ResNet101-700×700 model with better average accuracy is selected. The RGB color characteristics of corrosion are deduced from the acquired images and the corrosion degree is divided. A boundary box strategy is employed for corrosion detection on the towers. The concept of linear projection is introduced to better localize the corroded areas. Validation results on the test dataset achieve an average precision of 97.3% and an average recall of 94.1%.

Keywords: machine vision; power tower poles; YOLACT; corrosion detection; linear projection

电力塔杆多为钢铁制成, 因其大多处于复杂多变的室外环境下, 不可避免会出现一些锈蚀问题, 存在安全隐患。因此, 有必要定期对输电塔杆进行巡检和锈蚀维护工作。为减少人力维护输电系统产生的安全隐患并提高工作效率, 许多研究将机器视觉引入输电塔杆的目标检测中。Tian G 等^[1]结合 YOLOv2 和 VGG 算法对 SAR 图像的塔杆目标进行识别; 卢君妥^[2]提出了一种融合了 SLIC 算法、DBSCAN 算法和斜空间距离方法的改

进密度空间聚类分割算法以分离目标和背景; 商俊平等^[3]提出了一种基于机器视觉的绝缘子掉片缺陷检测算法, 使用大津法分割高压输电线路巡检图像中的绝缘子区域; Nash 等^[4]利用 VGG-16 为主干网络的 FCN 模型对输电线路电塔进行锈蚀分割任务; He 等^[5]研究了 Faster R-CNN 目标检测算法, 并提出了实例分割模型 Mask R-CNN, 为图像中的每个目标分配像素级的分割掩码; 张洪才等^[6]运用超红色法、最小二乘拟合和

收稿日期: 2024-04-22

第一作者简介: 黄荷 (2000—), 女, 福建莆田人, 硕士研究生, 研究方向: 机器视觉。

几何特征结合来检测输电线路中的锈蚀缺陷。然而,采用传统的图像处理技术对输电线路进行缺陷检测严重依赖研究人员手动提取的图像特征,在单一背景下的塔杆图像中可能有良好的表现,但对于复杂环境下的图像检测则不具普适性。采用深度学习的图像处理方法在检测精度上比传统的图像处理方法有较大的提升,塔杆的分割效果主要取决于对不同模型和神经网络结构的设计。

由于巡检图像中的塔杆特征尺度较小且容易与输电线路等背景相互交错,容易产生识别精度低、漏检误检等问题。综上,本研究采用 YOLACT (you only look at coefficients) 模型对输电塔杆进行分割,并在区域内融合 RGB 颜色空间统计锈蚀的像素占比,判断其锈蚀等级,从而快速判断各个塔杆的锈蚀等级,可以有效减少巡检人员检修设备的工作量。

1 基于 YOLACT 的塔杆分割

1.1 网络模型分析

深度学习算法分为单阶段和双阶段两类。其中,双阶段算法网络精度更高,但是计算成本也比较高、速度较慢。YOLACT^[7] 是单阶段^[8] 目标检测算法,它作为一种用于实例分割任务的深度学习模型,可以直接从图像中预测对象的类别和边界框。YOLACT 模型在网络上增加了掩码分支,并为每个独立目标分配精确的分割掩码,无需等待区域候选网络(region proposal network, RPN)^[9] 生成建议区域后再进行特征映射产生实例掩码,具有速度快、掩码质量高、普适性强等优点。在电网检查等任务中,不同种类的电缆和塔杆等可能相似度很高且易重叠,YOLACT 模型可以较为精确地将它们分离开,并提供可靠的识别与处理能力。

YOLACT 模型的整体结构如图 1(a) 所示。它选用 ResNet 作为主干网络,引入残差学习的概念生成 5 个不同的特征层,分别对应图 1(a) 中 $C_1 \sim C_5$ 。残差块的使用允许网络在训练过程中适当跳层,使训练深度能够达到上百层^[8]。提取主干网络特征后,基于特征金字塔(feature pyramid network, FPN)进行卷积操作融合多尺度特征,然后分为两个并行的子任务。检测器模块中的 Prediction Head 预测分支是在一阶段目标检测器(Retina-Net)^[10] 的基础上改进得到的,使用锚框

(anchor-box) 方法去预测分类的置信度与边框对于每个目标物体输出类别、边框信息(k 个置信度),其结构如图 1(b) 所示。Protonet 原型网络分支为每张图片生成 k 个原型掩码,其结构如图 1(c) 所示。将预测分支和原型网络分支通过线性组合等操作生成最终图像中每个目标对象的掩码,可以更准确地输出实例分割图像。

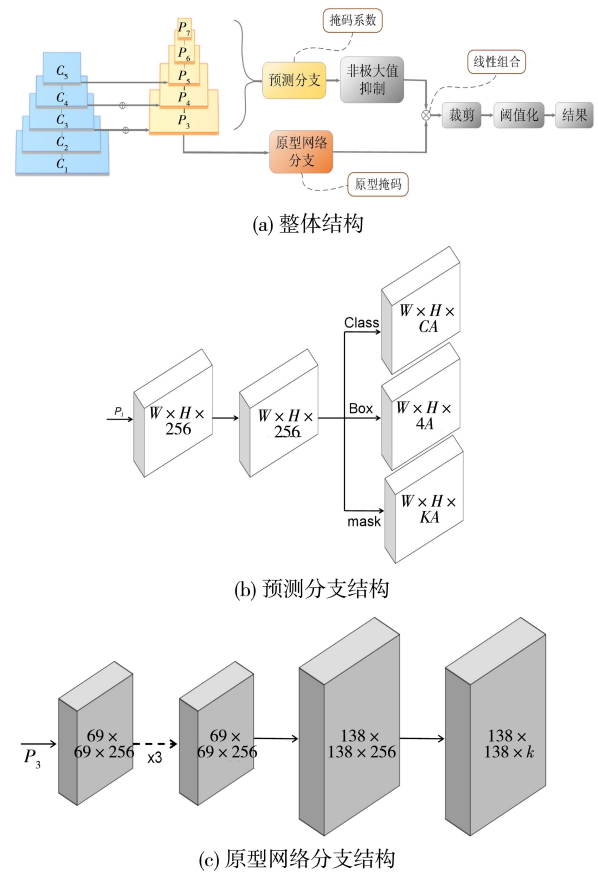


图 1 YOLACT 网络模型
Fig.1 Network model of YOLACT

1.2 非极大值抑制

YOLACT 利用特征金字塔中的特征图对每个像素点生成目标框;为了避免太多冗余目标框,使用非极大值抑制的方法来实现对图像目标候选框的筛选。非极大值抑制(non-maximum suppression, NMS)是按照顺序执行的方式,核心思想是将最高得分的框与其他边界框进行交并比(IoU)计算,保留具有最高置信度的框,并剔除 IoU 值较大的框^[11]。由于塔杆所处环境复杂,单一的 NMS 在数据集上实用性不大, NMS 阈值较低将丢失高度重叠的对象并导致删除更多的真阳性,而 NMS 阈值较高则会导致假阳性增加。

Fast NMS 通过优化排序的复杂度和减少对 IoU 的计算次数来提升速度,可以解决传统 NMS 的顺序特性,其主要思想是将传统的 NMS 计算方法转换为矩阵运算。如表 1 体现了每类对象在不同阈值下的边界框重叠数目。以木质塔杆为例,其在阈值为 0.50 的情况下,有 3 个重叠的边界框,而阈值为 0.95 时,则没有重叠的边界框。当阈值为 0.50、0.75、0.95 时,可以计算出不同实例之间的边界框重叠占比分别为 36.8%、17.9%、2.5%。本研究通过交叉验证,最终将置信度阈值设定为 0.50,以提高目标对象预测的准确性。

表 1 不同阈值下各类别的边界框重叠数

Tab.1 Number of bounding box overlaps of different categories under different thresholds

类别	重叠数/个		
	阈值为 0.50	阈值为 0.75	阈值为 0.95
电缆	3 224	1 570	224
格栅塔杆	3	0	0
木质塔杆	3	2	0
钢管/混凝土混合塔杆	4	2	0

1.3 多损失函数

训练过程中,通过比较模型的输出与真值来衡量每个模型的预测质量。在基于 YOLACT 的分割模型中,采用分类损失函数 L_{class} 、边框回归损失函数 L_{loc} 和掩码损失函数 L_{mask} 3 部分来进行正向训练,多损失函数 L_{loss} 是 3 个函数的和,即:

$$L_{loss} = \frac{\alpha}{N}L_{class} + \frac{\beta}{N}L_{loc} + \frac{\gamma}{A_{gb}}L_{mask} \tag{1}$$

式中, α 、 β 、 γ 是在反向传播过程中平衡每个损失函数贡献的权重^[7],在模型中分别设置为 1、1.5 和 6.125。 N 是与地面真值框匹配的框数; A_{gb} 是地面真值包围盒的面积,其可以对掩模损失进行归一化处理。通过计算整张图片的损失情况,确保 YOLACT 模型能够在各个任务上联合优化,从而实现高效的分割。

2 塔杆锈蚀的缺陷检测

2.1 锈蚀图像分析

本研究的塔杆图像数据由不同设备采集所

得,在颜色特征和分辨率上有所差异,需要将图像尺寸先归一化处理后,对锈蚀区域的颜色特征进行缺陷检测识别。

2.1.1 RGB 颜色空间

RGB 是一种加法色彩模型,通过组合红、绿、蓝 3 个基本颜色通道的不同强度来创建颜色空间。模型建立在笛卡尔三维直角坐标系里,将 3 个通道的值归一化到 0~1,将颜色空间视为一个边长为 1 的单位立方体,如图 2 所示。通过观察图像的颜色分布情况,可以直观地识别锈蚀区域的颜色特征,不需要复杂的数学模型或转换,更加方便地集成到现有的检测流程中。

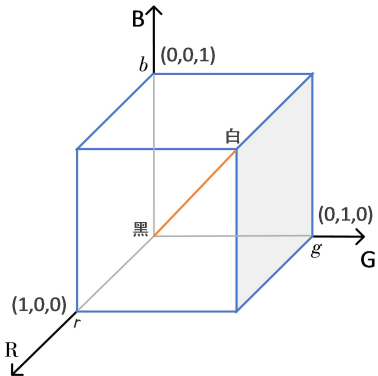


图 2 RGB 颜色空间

Fig.2 RGB color space

2.1.2 锈蚀等级分类

表面形貌是反映塔杆锈蚀等级最直观的手段,也是巡检过程中现场工作人员判断其锈蚀等级的主要观测指标。电力塔杆图像包括塔头、塔身、左侧地线、右侧地线等多个角度。结合塔杆表面的颜色、粗糙度或平整度等信息,以及中国的现行标准 GB/T 8923-2011^[13] 对锈蚀缺陷程度标准,从形貌特征和整体特征角度出发,将锈蚀等级分为 4 大类,如表 2 所示。

2.2 基于 RGB 空间的锈蚀缺陷检测方法

2.2.1 边界框策略

在边界框检测法提出前,一般是通过滑动窗口法^[14]进行目标检测,其计算成本较高。本研究采用边界框策略对塔杆表面进行锈蚀程度的缺陷检测。边界框通常由一个矩形区域表示,可以限定住不同复杂物体的位置,为目标检测、分割和识别等任务提供基本信息,主要流程如图 3 所示。

表 2 锈蚀程度划分

Tab.2 Classification of corrosion degrees

锈蚀等级	形貌特征	整体特征
无锈蚀	表面呈青灰色或银白色,光亮且无锈迹,形貌平整规则	锈蚀面积小于 1%
轻腐蚀	表面呈黑灰色或暗灰色,边角或平面处存在少量锈点和凹坑,形貌较粗糙	锈蚀面积 1%—10%
中腐蚀	表面呈暗灰色或黄褐色,边角或平面处存在成片锈点和凹坑,形貌凹凸不平	锈蚀面积 10%—30%
重腐蚀	表面呈红褐色或黑红色,边角或平面处存在成片锈迹,产生明显穿孔或断裂	锈蚀面积大于 30%

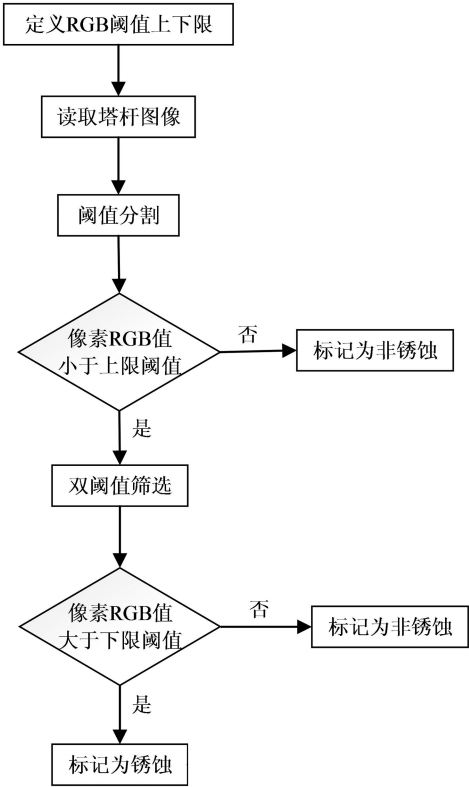


图 3 边界框策略流程图

Fig.3 Bounding box strategy flowchart

边界框策略的主要思想是比较分割后的塔杆图像中每个像素的 RGB 值与设定的颜色阈值。通过双阈值筛选,只保留同在上、下限阈值之间的像素点,确保提取的区域符合锈蚀条件。将结果输出的二值掩码扩展为三维,与原始图像具有相同的维度,以便对锈蚀区域进行进一

步可视化分析。将像素映射到 RGB 颜色空间中,检测原理如图 4 所示。其中,黄色区域为塔杆的像素值小于设定的上限阈值,绿色区域为塔杆的像素值大于设定的下限阈值,取任意一像素点,判断其是否处于蓝色像素值交集区间,即塔杆锈蚀点。

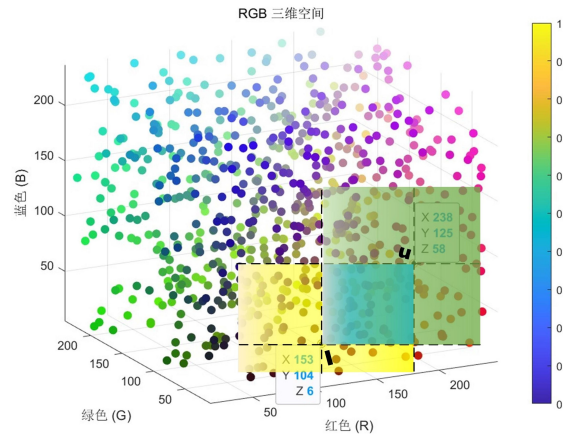


图 4 边界框策略原理图

Fig.4 Bounding box schematic diagram

结合边界框策略的 RGB 阈值分割方法来检测锈蚀区域时,边界框始终保持以一个盒子的形状在变化,检测范围可能过大,导致分割图像中混入其他背景颜色,造成误检或漏检。为了提高锈蚀区域检测的准确性和可靠性,应该尽可能地缩小检测框的大小,使像素值位于 RGB 通道区间内的识别更加精确。

2.2.2 线性投影策略

利用像素投影的线性化几何关系,基于上文的 RGB 阈值上下限定义线段的两个端点,通过计算像素到特定范围的距离,更加精细地检测和标记图像中锈蚀区域。主要流程如图 5 所示。

首先,计算上下限之间的距离,并将其向量归一化;其次,求出任一像素点到上下限的距离以及它们之间的夹角。通过向量内积的运算关系,判断像素点是否投影在 RGB 阈值范围内。与边界框策略不同的是,它并不是通过是否在阈值范围而判定锈蚀与非锈蚀,而是计算其投影长度和垂线距离来判定锈蚀像素点。当任一像素高于上限值或低于下限值的时候,像素到阈值范围的最小距离即为像素到两端点之间的距离;当任一像素处于上下限区间时,通过勾股定理的线性关系(即垂线段最短)来求得两者间距离。假设将圆

柱缩放到以 0.2 倍的半径大小作为决策边界,这里的决策边界被定义为一个距离阈值,即设定为上下限向量长度的 20%。具体来说,如果一个像素到阈值的距离小于该范围,则判其为锈蚀点;否则判其为非锈蚀点。最后,计算出锈蚀点像素占图像分割区域的面积。

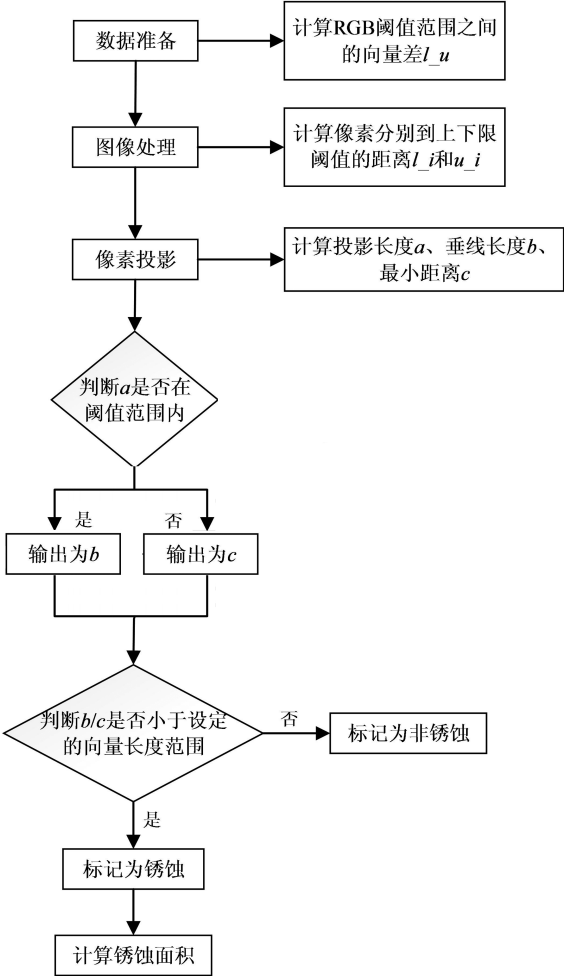


图 5 线性投影策略流程图

Fig.5 Linear projection strategy flowchart

该锈蚀检测方法可以将边界框缩放到仅限于所设定的锈蚀颜色阈值区间的类似圆柱体形状。通过使用向量运算和矩阵计算,不仅可以高效地处理大规模的图像数据,还可以根据实际情况调整上下限、决策边界参数等,以适应不同场景的锈蚀检测需求。将像素映射到 RGB 颜色空间中,主要原理如图 6 所示。其中,黑色线条阴影部分即为定义的决策边界范围,不同大小的决策边界对 RGB 通道的颜色取值范围也有所不同,可以较好地避免锈蚀漏检和误检的问题。

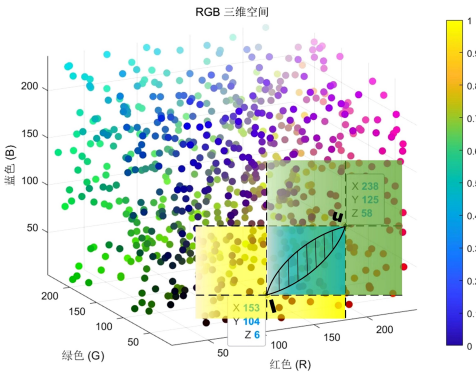


图 6 线性投影策略原理图

Fig.6 Linear projection strategy schematic diagram

3 实验

3.1 实验环境

实验操作系统为 Window10,处理器为 11th Gen intel(R) Core(TM) i5-1135G7 @ 2.40GHZ,开发环境为 Python3.10,编译软件为 Pycharm,深度学习框架采用 PyTorch1.12+CUDA11.3

3.2 数据集

本研究的数据包括不同的角度、地点和天气环境下的在役塔杆图像,主要由福建省国家电网公司提供。对数据集进行整理,按照塔杆所处的地区分为福州市、莆田市、泉州市、漳州市、厦门市、龙岩市、三明市、南平市和宁德市 9 大类。由于图像背景大多存在噪声且分辨率较大,故对图像尺寸均归一化为 700×700 像素比。随机抽取 40 张作为测试样本,使用 LabelMe 图像注释工具对其进行打点标注,标记出 30 个位于塔杆上的正样本点,再标记出 25 个位于塔杆外其他环境背景区域内的负样本点。

3.3 评价指标

为验证算法的有效性,需要通过一些评价指标来衡量模型的性能。其中,准确率指预测正确的结果占有所有样本的比例,但是本实验正负样本不平衡,用准确率评价指标是有缺陷的。因此,本研究采用误报率(FAR)、召回率(Recall)和精确率(Precision)作为检测不同锈蚀程度模型的评价指标。在计算指标时需要用到混淆矩阵中的一些参数,其中,TP 表示真正类,FP 表示假正类,FN 表示假负类,TN 表示真负类。

3.3.1 误报率

误报率是指实际为正的样本中被预测为负样

本的概率,即非锈蚀区域被标记为锈蚀的占比。高误报率会造成不必要的修复操作,降低工作效率;低误报率可以准确识别锈蚀区域,提高系统可靠性。计算公式为:

$$FAR=\frac{FP}{FP+TN}$$

(2)

3.3.2 召回率

召回率是指实际为正的样本中被预测为正样本的概率,即模型成功预测为锈蚀部分的占比。召回率越高,出现漏检的可能性越低。计算公式为:

$$Recall=\frac{TP}{TP+FN}$$

(3)

3.3.3 精确率

精确率是指在所有被预测为正样本中实际为正的样本的概率,即所有模型预测为锈蚀的样本中实际为锈蚀的占比。精确率越高,误检的可能性越低。计算公式为:

$$Precision=\frac{TP}{TP+FP}$$

(4)

3.4 结果及分析

3.4.1 分割结果对比

当 IoU 大于 50%时,模型分别计算出边界框(表示为 AP_b)和实例掩码(表示为 AP_m)的平均精度值。其中, $AP^{50\%}$ 表示重叠值为 50%的 AP 值, $AP^{75\%}$ 表示重叠值为 75%的 AP 值, AP^{avg} 表示不同 IoU 的阈值(从 50%到 95%,步长为 5%)下的平均精度值。以 YOLACT 模型为基线,结合不同主干网络 and 不同分辨率进行训练,结果对比如表 3 所示。由表 3 可见,模型在 50%IoU 下的边界框和实例掩码平均精度均高于 75%IoU,说明了模型在边界框或实例掩码的预测上存在一些局部化或精细化的问题,更倾向于生成较大的边界框或较大的掩码,以便更好地覆盖目标区域,从而提高平均精度。另一方面,边界框的平均精度值效果最好的是基于 ResNet101 主干网络下 700×700 的模型, AP_b^{avg} 为 22.96%;而掩码的平均精度值效果最好的是基于 ResNet50 主干网络下 700×700 的模型, AP_m^{avg} 为 15.72%。

表 3 不同模型训练结果对比
Tab.3 Comparison of training results of different models

主干网络	图像分辨率/像素	$AP_b^{50\%}/\%$	$AP_m^{50\%}/\%$	$AP_b^{75\%}/\%$	$AP_m^{75\%}/\%$	$AP_b^{avg}/\%$	$AP_m^{avg}/\%$
Resnet-50	640×360	46.72	34.28	4.99	11.20	16.50	14.52
	550×550	43.37	28.36	18.36	12.22	20.76	14.70
	700×700	42.62	30.07	20.36	13.64	21.90	15.72
Resnet-101	640×360	44.99	32.58	10.00	10.06	18.42	14.05
	550×550	45.30	28.85	19.80	12.33	22.61	14.68
	700×700	43.19	28.18	21.27	13.46	22.96	14.88

ResNet101 的网络结构比 ResNet50 更深,具有更多的卷积层和更丰富的特征表达能力,可以捕获更复杂抽象的图像特征,对于塔杆这类较大目标的分割任务具有更好的适应能力,可以提高分割的准确性。因此,本研究选用 ResNet101 网络下 YOLACT- 700×700 的模型对电力塔杆进行分割实验。从测试集中选择不同场所、不同天气和不同航拍角度下的塔杆图像进行模型性能测试,分割识别结果如图 7 所示。

3.4.2 锈蚀程度检测结果对比

本研究在 RGB 颜色空间中使用两种策略分别对塔杆图像进行锈蚀检测。选取一张已知实际锈蚀面积为 4%的塔杆图像,采用两种算法进行检测,结果分别如图 8 和图 9 所示。其中图 8 得到的锈蚀检测面积为 8.12%,图 9 得到的锈蚀检测面积为 3.68%,说明基于线性投影策略的检测方法更接近实际塔杆锈蚀数据。根据锈蚀程度等级划分标准,将该塔杆划为轻腐蚀,建议缩短巡视周期,定期对塔杆进行检查。

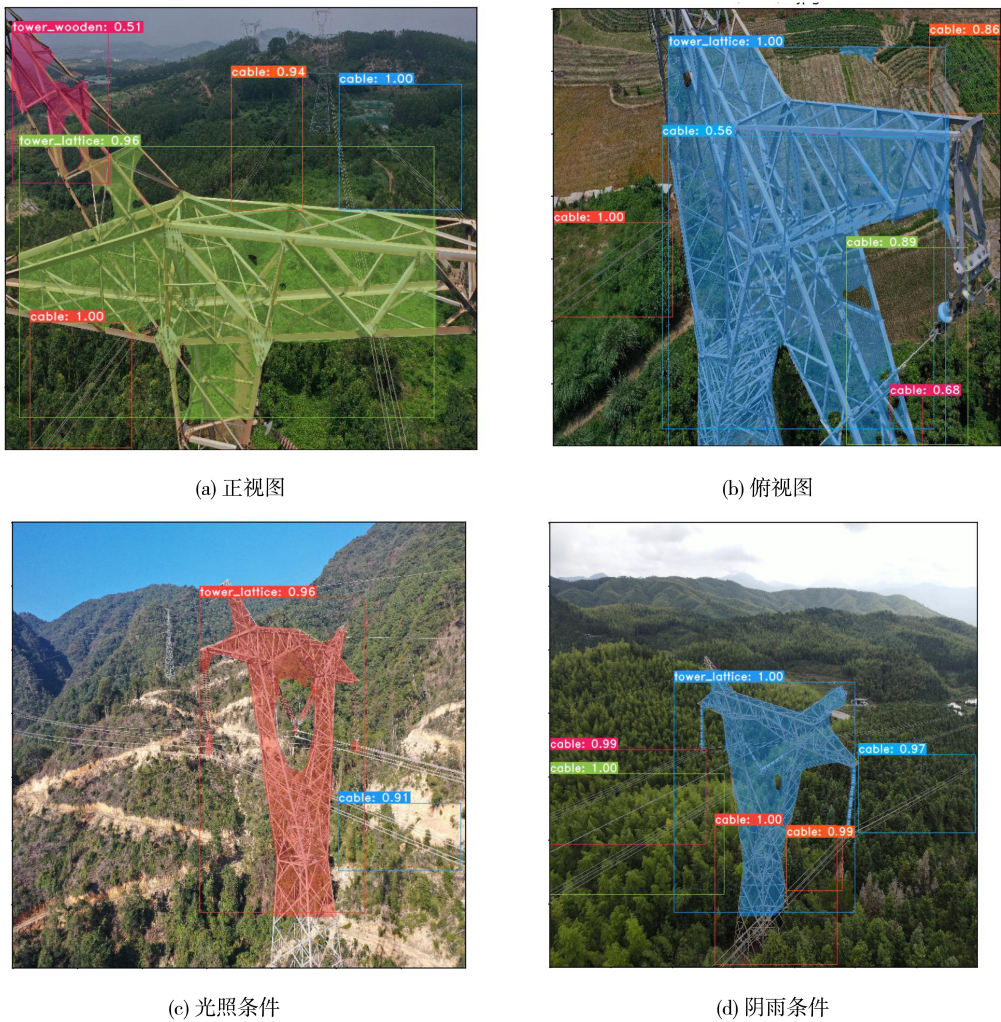


图 7 不同情况的识别结果

Fig.7 Identification results of different cases

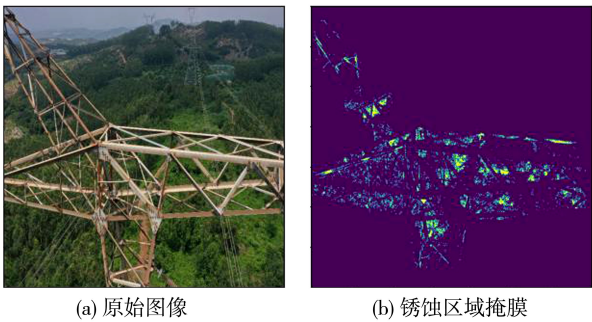


图 8 边界框锈蚀检测结果

Fig.8 Results of bounding box corrosion detection

根据锈蚀检测结果的对比分析,采用线性投影策略的锈蚀缺陷检测识别方法对测试集样本进行算法验证。检测建立在分割后图像后的基础上,列举其中 10 张图片的实验结果,如表 4 所示。

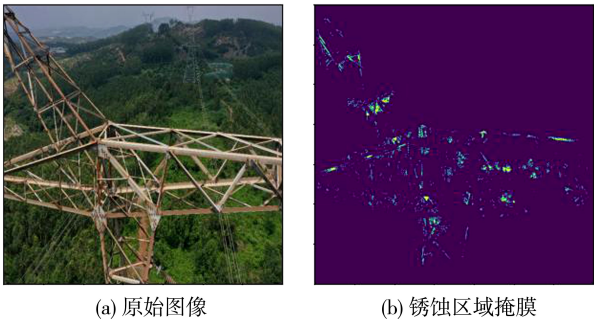


图 9 线性投影锈蚀检测结果

Fig.9 Results of linear projection corrosion detection

通过对所有测试样本进行验证,计算得出模型的识别平均误报率为 3.1%,平均精确率达到 97.3%,平均召回率为 94.1%,证明了算法的有效性。

表 4 测试性能指标

Tab.4 Test performance index

图号	误报率/%	精确率/%	召回率/%	锈蚀等级
1	3.8	96.7	96.7	轻
2	0	100.0	96.7	无
3	4.0	96.6	93.3	中
4	7.4	93.3	93.3	重
5	4.0	96.7	96.7	轻
6	0	100.0	96.7	无
7	4.0	96.5	87.5	中
8	3.8	96.7	96.7	轻
9	0	100.0	96.7	无
10	4.0	96.6	87.5	轻

4 结论

本研究采用 YOLACT 的实例分割模型,提取出复杂环境下塔杆的形态特征,选择 Fast NMS 的阈值实现对目标候选框的筛选,减少各类塔杆以及密集电缆的误检漏检问题。结果表明,基于 YOLACT 的 ResNet101-700×700 分割模型可以满足不同天气情况和不同角度下的塔杆图像分割任务。提取出塔杆的特征后,结合 RGB 颜色空间来分析锈蚀颜色,采用基于线性投影的方法计算出的锈蚀面积更接近人工测量的实际塔杆数据,实现对电力塔杆表面的锈蚀程度进行分类,便于指导防腐处理和修护工作。研究结果表明,该模型可降低人工统计锈蚀面积的成本,减轻设备巡检作业人员的安全隐患,为电力塔杆的维护工作提供了一种有效且可行的解决方案,具有较高的应用价值。

参考文献:

[1] TIAN G S,MENG S,BAI X J,et al. Electric tower target identification based on high-resolution SAR image and deep learning[J]. Journal of Physics:Conference Series,2020,1453(1):012117.

[2] 卢君妥. 飞行机器人巡检图像中关键部件缺陷特征量化[D]. 北京:华北电力大学,2016.

[3] 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.

[4] NASH W,DRUMMOND T,BIRBILIS N. Quantity beats quality for semantic segmentation of corrosion in images[EB/OL]. 2018;1807.03138.<https://arxiv.org/abs/1807.03138v1>.

[5] HE K M,GKIOXARI G,DOLLAR P,et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE,2017:2961-2969.

[6] 张洪才. 直升机巡检输电线路锈蚀缺陷检测识别方法研究[D]. 大连:大连海事大学,2009.

[7] BOLYA D,ZHOU C,XIAO F S, et al. YOLACT: Real-time instance segmentation[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea(South): IEEE,2019:9157-9166.

[8] 李瑾,范佳能,刘屹然. 复杂环境基于 YOLACT 电缆识别与定位[J]. 电子测量技术,2023,46(4):114-120.

[9] 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,2017,39(6):1137-1149.

[10] 张冬明,靳国庆,鲁鼎煜,等. 注意力引导的标志检测与识别[J]. 软件学报, 2024, 35(11): 5116-5132.

[11] 王凤随,王启胜,陈金刚,等. 基于注意力机制和 Soft-NMS 的改进 Faster R-CNN 目标检测算法[J]. 激光与光电子学进展,2021,58(24):405-416.

[12] 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]. 广州:华南理工大学,2020.

[13] 国家质量监督检验检疫总局,中国国家标准化管理委员会. 涂覆涂料前钢材表面处理 表面清洁度的目视评定 第 1 部分:未涂覆过的钢材表面和全面清除原有涂层后的钢材表面的锈蚀等级和处理等级:GB/T 8923.1—2011[S]. 北京:中国标准出版社,2013.

[14] 逯鹏,赵天淞,王剑. 基于计算机视觉的钢结构表面锈蚀程度检测方法[J].工业建筑, 2024, 54(8): 133-139.

(责任编辑:方素华)