

DOI:10.19651/j.cnki.emt.2108643

基于改进 Faster RCNN 的电缆外护套破损检测*

薛阳¹ 张舒翔¹ 贾巍² 秦瑶¹

(1.上海电力大学自动化工程学院 上海 200090; 2.上海太阳能工程技术研究中心有限公司 上海 200241)

摘要: 工业现场的电缆外护套破损主要依靠人工巡检的方式,消耗人力,主观性大容易出现检查盲点,实时性差且某些工业现场人工巡检危险性较大。针对人工巡检产生的一系列问题,提出一种基于改进的 Faster RCNN 电缆外护套破损检测方法。为提高模型泛化能力对采集的训练集采用灰度化、翻转、平移、锐化等方法进行数据增强;使用参数量更少且层数更深的特征提取网络 RseNet50 替换原始的 VGG16 作为主干特征提取网络;采用迁移学习的方式将 ImageNET 数据集上训练完成的权重作为模型的初始权重;利用双线性插值法替换感兴趣区域池化操作;通过 K-means 聚类算法对原始数据集进行聚类分析,采用轮廓系数法作为评价标准,由聚类结果定制外护套破损检测的锚框。实验结果表明,改进的 Faster RCNN 对电缆外护套破损检测的平均精度均值(mAP)为 88.33% 比原始的 Faster RCNN 提高了 5.49%,同时优于经典的 SSD 算法和 YOLOv3 算法,改进后检测速度达到 0.36 张/s 满足检测要求。该模型可后续搭载各类移动检测平台,具有较高的工程使用价值。

关键词: 电缆外护套;目标检测;Faster RCNN;K-means;迁移学习

中图分类号: TP394.1 **文献标识码:** A **国家标准学科分类代码:** 520.60

Damage detection of cable outer sheath based on improved Faster RCNN

Xue Yang¹ Zhang Shuxiang¹ Jia Wei² Qin Yao¹

(1. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Shanghai Solar Energy Engineering Technology Research Center, Shanghai 200241, China)

Abstract: The damage of the outer sheath of the cable at the industrial site mainly relies on manual inspection, which consumes manpower, is subject to high subjectivity, and is prone to blind spots. The real-time performance is poor and the manual inspection of some industrial sites is more dangerous. Aiming at a series of problems caused by manual inspection, this paper proposes an improved Faster RCNN cable sheath damage detection method. In order to improve the generalization ability of the model, grayscale, flip, pan, and sharpen the collected training set are used for data enhancement; use the feature extraction network RseNet50 with fewer parameters and deeper layers to replace the original VGG16 as the backbone feature extraction network; use migration learning to use the weights trained on the ImageNET dataset as the initial weights of the model; use bilinear interpolation to replace the ROI Pooling operation; use the K-means clustering algorithm to analyze the original data Cluster analysis was performed on the collection, the Silhouette method was used as the evaluation standard, and the anchor frame of the outer sheath damage detection was customized based on the clustering results. Experimental results show that the improved Faster RCNN has an average accuracy (mAP) of 88.33% for the detection of damage to the outer sheath of the cable, which is 5.49% higher than the original Faster RCNN, and is better than the classic SSD algorithm and YOLOv3 algorithm. The improved detection speed achieve 0.36 frame/s to meet the testing requirements. This model can be subsequently equipped with various mobile detection platforms and has high engineering value.

Keywords: cable sheath; object detection; Faster RCNN; K-means; transfer learning

0 引言

电缆可分为 5 类产品:电力电缆、绕组线、电器装备用

电线电缆、通信电缆和光缆。这些电缆被广泛应用于各行各业,是各个工业现场最基本的东西,被比喻为国民经济的“血管”与“神经”。随着工业技术的快速进步,对于各种工

收稿日期:2021-12-21

* 基金项目:国家自然科学基金(52075316)、上海市 2021 年度“科技创新行动计划”(21DZ1207502)、国网浙江省电力有限公司科技项目(5211HZ17000F)资助

业设备的稳定性、可靠性与安全性的要求也不断提高^[1]。多数工业现场的生产运作环境较恶劣,对电缆的安全性、稳定性要求较高。因此工业现场电缆通常外包了外护套用于防止钢带腐蚀、水树枝老化、电缆受潮、特性防护性能降低。对于铠装型电缆,外护套可以保护铠装层免遭水汽侵蚀,防止电化学腐蚀造成钢带断裂、腐蚀、脱落导致纵向抗压作用减弱。若没有及时发现并维护则可能会导致工业事故的发生。通常电缆受潮会使得水在电缆内部过电压下发生电离现象,生成游离的 O^{2-} 与 Cu 作用使得铜芯线氧化导致局部电阻增加,温度上升降低电缆的使用寿命,成本增加,严重时甚至更会引起设备的停运造成不必要的经济损失和人力浪费^[2]。外护套破损的因素多有不同,具体应视不同的工业现场条件来分析。但是通常可以大体分为如下 4 个方面造成:1)施工及转运过程中的机械损伤。2)地面生物如老鼠、白蚁蛀蚀以及乙酸腐蚀。3)工作人员敷设施工不规范。4)工业现场不同时段温差过大导致外护套开裂。以目前的技术不能完全避免电缆外护套的破损,之前的电缆外护套破损检测主要采用电桥法、跨步电压法、声磁同步法等对电缆外护套进行测寻^[3],2014 年大庆油田供电公司开发并安装了电缆外护套接地环流在线监测^[4]外护套破损且对实际传输电缆或信号产生影响情况下用于检测定位,由于成本与复杂度高等原因未能推广。目前大部分工厂仍然主要依靠人工定期巡检,发现破损处之后巡检人员多用防水胶布等材料进行修补处理。恶劣的工业环境下定期人工巡检的方式存在可靠性低、追溯性差、人身安全风险大、人力成本大等问题。在深度学习兴起之前,数字图像处理方法是传统的图像处理方法,常通过用图像的二值化和边缘检测,包括正交归一化小波即 Haar 小波^[5-6]、显著性检测^[7-8]以及图像分割等方法,随着深度学习的蓬勃发展,计算机视觉检测方面也得到了飞跃的发展,深度卷积网络 CNN 在图像处理取得巨大的进步。Faster RCNN 是经典、具有代表性的双阶段目标检测算法,被广泛应用于目标检测领域。Faster RCNN 算法基于端到端的目标检测框架,显著提升了目标检测的精度和速度,同时 Faster RCNN 算法存在特征提取网络参数量大,对多尺度目标的检测偏弱等问题。文献[9]基于 Faster RCNN 成功实现对破片群识别。文献[10]通过对主干网络和锚框尺寸的改进成功提高了对铝材表面缺陷的识别精度。

综上所述,为了使得 Faster RCNN 能够提高对尺度不一电缆破口的检测精度和速度,本文提出以下方式对整体网络进行改进。通过实地拍摄国内某海岛天然气公司工业现场的方式建立数据集,通过旋转、尺度变化等方式增强数据集,使训练模型的泛化能力更强。同时 RseNet50 代替传统的 VGG-16^[11]主干特征提取网络^[12],采用迁移学习提前设置好主干提取网络参数,减少达到期望训练效果的迭代次数,并采用双线性插值法替换感兴趣区域池化部分^[13],解决区域不匹配^[14]特征信息丢失的问题。引入 K-means

聚类算法并以轮廓系数法为评价指标设计新的锚框用于目标检测^[15]。通过与目前主流的目标检测算法 SSD^[16]、YOLOv3^[17]的在相同数据集下的横向对比,验证该方法其有效性。

1 Faster RCNN 检测原理

1.1 Faster RCNN 网络结构

Faster RCNN 算法网络框架按网络功能细分可分为主要 4 个部分:主干特征提取网络、区域建议网络(RPN)、感兴趣区域池化(ROI Pooling)与全连接网络(RCNN)模块。模型检测时,网络输入图像,检测网络中的主干特征提取网络得到特征图,特征图被后续的区域建议网络和检测网络层共享。特征图输入 RPN 层,经 RPN 层输出包含位置信息的建议框再输入到感兴趣区域池化层,该层将输入池化到固定维度,输入到 RCNN 全连接网络完成目标的定位和分类。Faster RCNN 整体结构如图 1 所示。

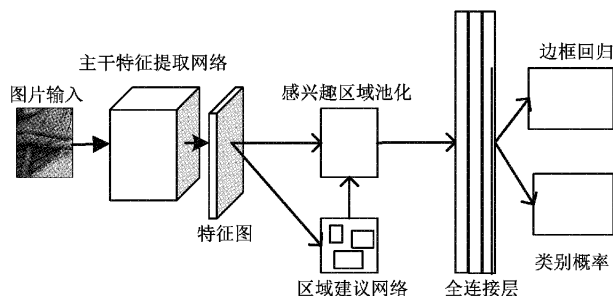


图 1 原始的 Faster RCNN 结构框架图

1.2 RPN 网络

RPN 为全卷积网络结构,作用是生成较好的建议框。在 RPN 结构中,滑动窗口会对特征图进行卷积操作将产生的结果输入到回归层和分类层。具体步骤如下:

1)锚框生成:RPN 对特征图上的每一个点都生成对应的 9 个锚框,对于大小不同的目标,使用 3 个 scale 为 {8, 16, 32} 与 3 种长宽比为 [0.5, 1, 2] 的 9 种锚框对特征图进行框选。RPN 再从中筛选,进一步调整出更好的位置,得到建议框。

2)RPN 卷积网络:与生成的锚框对应,由于特征图上每个点对应了 9 种锚框,因此可以利用 1×1 的卷积在特征图上得到每一个锚框的分类预测值与预测偏移值。

3)生成建议框:将 RPN 卷积网络生成的分类预测值与预测偏移值作用到全部锚框,过滤超出图像尺寸的建议框,根据 RPN 卷积网络中的分类网络输出得分对锚框排名,保留前 12 000 得分最高的锚框,通过非极大值抑制将重叠的框去掉。在剩余的锚框中再次选择得分前 2 000 的锚框,作为最终生成的建议框。

4)筛选建议框生成感兴趣区域:在训练模型时,生成的建议框需要进一步筛选得到默认数量为 256 的感兴趣区域,在测试阶段,不需要此步骤,建议框直接作为感兴趣区

域进行微调。

5) 损失函数计算: 在 RPN 中得到锚框后需要通过分类器判定框选的目标是前景还是背景, 判定为前景的部分作为网络输出的目标候选框, 因此 RPN 层在训练时的损失函数如下:

$$L(\{P_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (1)$$

式中: N_{cls} 代表网络目标分类个数, N_{reg} 代表感兴趣区域个数, $\sum_i L_{\text{cls}}(P_i, P_i^*)$ 为每个锚框的分类损失, P_i 为每个锚框的类别值, P_i^* 为每个锚框的预测类别。 $\sum_i P_i \times L_{\text{reg}}(P_i, P_i^*)$ 代表了回归损失, t_i 表示预测框的边界参数, t_i^* 表示检测目标的真值边界框参数, λ 用于平衡分类损失与回归损失在总损失函数中的占比。分类损失与回归损失的具体损失函数如下:

$$L_{\text{cls}}(p_i, p_i^*) = -\log[p_i p_i^* + (1 - p_i^*)(1 - p_i)] \quad (2)$$

$$L_{\text{reg}}(t_i, t_i^*) = \sum_{i \in \{x, y, w, h\}} \text{smooth}_{l1}(t_i - t_i^*) \quad (3)$$

其中, x, y 为框的中心坐标, w 为框宽, h 为框高, 回归损失使用了 smooth_{l1} 函数具体公式如下:

$$\text{smooth}_{l1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & |x| \geq 1 \end{cases} \quad (4)$$

1.3 感兴趣区域池化与全连接网络

感兴趣区域池化部分将特征图和 RPN 输出的感兴趣区域对应并池化到固定维度, 以满足后续全连接网络的处理要求。通过全连接层和 softmax 进一步对特征被池化到固定维度的感兴趣区域的回归框位置进行微调与检测物体分类, 得到最终的类别与回归的预测。具体步骤为将感兴趣区域部分划分为相等大小的 7×7 个区域的部分, 将每个区域的像素最大值找出, 再将这些值复制保留到 Max pooling 层, 所有的感兴趣区域被转化为固定的维度进行前向传播, 全连接层对统一池化到固定维度后的信息进行分类和回归, 输出最终的检测结果。

2 改进的 Faster RCNN

本文针对工业现场对电缆外护套破损检测的要求提出改进的 Faster RCNN 网络。对模型的特征提取网络进行改进将 ResNet50 替换 VGG16, 参数量更少网络结构更深, 对目标的特征提取更加丰富, 能够避免训练过程中可能会出现梯度消失等问题。

对 Faster RCNN 中 RoI Pooling 层进行改进。原始的检测网络中, RoI Pooling 层在特征计算中会进行两次取整操作, 由于取整操作会舍弃像素中的小数点后的值, 这样带来的特征信息损失会影响到模型之后对信息的处理, 导致 Faster RCNN 整体精度的下降。改进的 Faster RCNN

采用了 Mask RCNN 中双线性插值的思想将 RoI Pooling 层替换为 RoI Align 层, 避免了取整操作会丢失部分信息的问题。RoI Align 层算法最大可能的保存了原始区域的特性, 提升模型的精度。

对 Faster RCNN 中的默认 Anchors 生成部分进行改进, 原始的 Faster RCNN 网络默认生成使用 3 个尺寸 scale 为 $\{8, 16, 32\}$ 与 3 种长宽比为 $\{0.5, 1, 2\}$ 的 9 个 Anchors 覆盖检测目标, 虽具有一定的通用性, 但是对于不同的检测目标来说这样缺少针对性的锚框设计会导致在一些特定数据集上的检测任务精度不佳。实际现场待检测目标尺度大小不一且尺度变化较大, 使用默认的 9 种锚框不能很好的回归待检测物体的边框位置和种类, 小尺度破口识别困难, 导致整体检测效果不理想, 难以满足实际需求。文中采用 K-means 聚类算法分析数据, 重新定制符合需求的新锚框。理论改进为如下 3 个方面:

1) 将 Faster RCNN 的主干特征提取网络由原始的 VGG16 替换为 ResNet50, 减少了参数量且能提取更加丰富的特征信息用于之后的处理。

2) 将 Faster RCNN 的 ROI Pooling 替换为 ROI Align, 消除了池化到固定维度时产生的误差损失, 最大程度保留了原始区域特征信息。

3) 使用 K-means 聚类算法分析数据集, 针对电缆外护套的破损信息设计了新的锚框, 使得模型收敛更快, 检测能力更强。

改进后的 Faster RCNN 网络结构如图 2 所示, 电缆外护套破口图像输入 ResNet50 网络经过特征提取得到 feature map, RPN 结合 K-means 聚类算法获得定制的锚框进行修剪超过图像尺寸的 Proposal 和按得分排序筛选、NMS 操作等操作后得到最终的 RoI, RoI 区域输入 RoI Align 进行区域校准池化, 得到准确的 7×7 大小的特征图后送入 RCNN, 特征图通过 RCNN 进行分类和边框回归。下面对改进的 Faster RCNN 网络关键部分进行详细介绍。

2.1 深度残差网络简介

针对电缆外护套破口体积较小、输入的图像分辨率较低的特点, 利用深度神经残差网络 ResNet50 替换 VGG16 网络。VGG16 网络在加深卷积层数时会越来越难训练, 伴随着梯度消失现象, 且越深的网络返回的梯度相关性会越来越差。为了解决以上问题且提取到更深层次的特征信息 ResNet-50 引入了深度残差框架解决了以上问题。ResNet50 深度网络更深, 参数量更少, 可提取更加丰富的特征信息传入之后进行处理。普通网络与 ResNet 残差块结构对比如图 3 所示, 对于神经网络最终目标映射为 $H(x)$, 普通网络需要直接拟合出 $H(x)$, ResNet 提出的子模块, 通过引入一个捷径分支, 将需要拟合的映射变为残差 $F(x) = H(x) - x$ 。这样 ResNet50 就可以在提取更深层次特征信息时避免信息丢失、梯度爆炸或消失等问题。

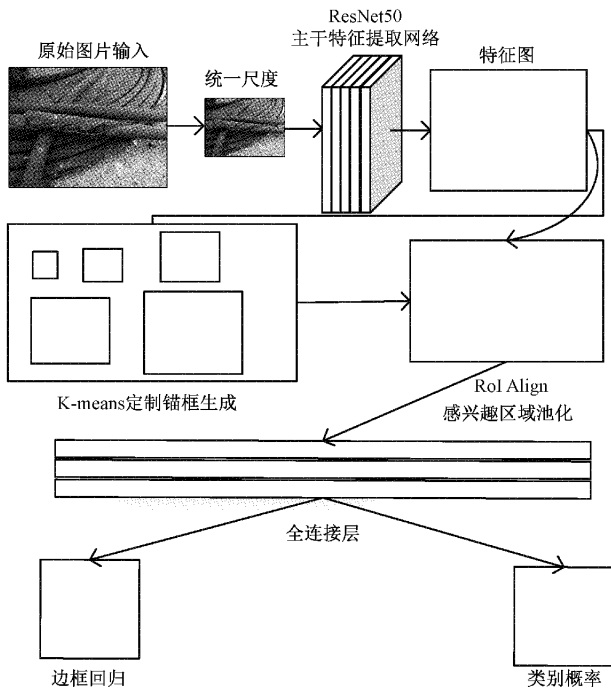


图 2 改进的 Faster RCNN 结构框架

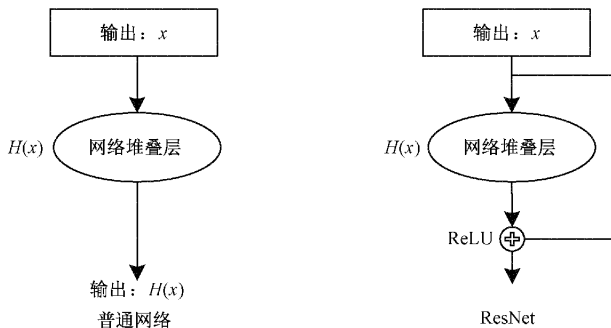


图 3 普通网络与 ResNet 结构对比

2.2 采用 ROI Align 保留完整特征信息

ROI Align 是实例分割中 Mask RCNN 框架中提出的区域特征聚集方式,采用双线性内插法替换 ROI Pooling 层最大程度保留了原始区域的特征。ROI Pooling 的做法是对特征图上的区域进行两次量化取证,这样的做法会影响网络回归物体位置的准确率和对于区域特征较小物体的检测效果。而采用 ROI Align 主要过程如图 4 所示,使用双线性插值获得坐标为浮点数的值,依然将 RoI 对映到特征图上,但坐标与大小都保留着浮点数,保留了原始区域的特征对于小物体的检测性能有明显提升。

2.3 基于 K-means 聚类算法的锚框定制

Faster RCNN 算法中锚框采用的 9 种锚框是通过人工事先设计的先验框,对于本文的数据集所需要检测的目标不能够很好的适应,最终会导致检测效果不佳。经过统计计算原始数据集中待检测目标的方框长和宽,通过 K-means 聚类算法训练出具有针对性的锚框,重新定制锚




图 4 RoI Align 双线性插值与池化示例

框大小和宽高比及数量。使得检测网络更容易学习到准确的破口检测锚框,提高检测准确度。K-means 聚类算法是一种无监督机器学习方法,算法步骤如下:

- 1)从样本集 D 中随机选择 k 个样本作为初始均值向量 $\{\mu_1, \mu_2, \dots, \mu_k\}$,令 $C_i = \emptyset (1 \leq i \leq k)$;
- 2)计算所有的样本 x_j 与各个均值向量 $\mu_i (1 \leq i \leq k)$ 的距离: $d_{ij} = \|x_j - \mu_i\|_2$;
- 3)根据距离最近的均值向量确定 x_j 的簇标记: $\lambda_j = \operatorname{argmin}_{i \in \{1, 2, \dots, k\}} d_{ij}$;
- 4)将样本 x_j 划入相应的簇,计算新均值向量 μ_i^* ,将当前均值向量更新;
- 5)重复步骤 2)~4)直到当前所有的均值向量不再改变;
- 6)输出簇划分 $C = \{C_1, C_2, \dots, C_k\}$ 。

对原始数据集训练集中的 500 张图像锚框宽度和高度进行统计得到 500 组二维数据,对 500 组二维数据进行均值聚类分析,分别令 $K=4, 5, 6, 7, 8$ 进行聚类分析。聚类效果的评价标准采用平均轮廓系数进行评估,结果如表 1 所示。当簇数 $K=5$ 时的聚类效果最好,聚类结果如图 5 所示。

表 1 不同簇数的平均轮廓系数计算结果

簇数/K	4	5	6	7	8
平均轮廓系数	0.437	0.462	0.455	0.453	0.408




图 5 $K=5$ 时聚类结果

实验结果聚类中心如表 2 所示,聚类结果与 Faster RCNN 的 9 种锚框相比,对于待检测数据集中尺寸较小的目标识别困难,增加新锚框提高训练模型的识别精度和有效性。

表 2 5 个聚类中心点统计结果

中心类	1	2	3	4	5
宽度	76.8	127.7	219.4	176	352.3
高度	63.3	135.3	118.5	300	174.5
长宽比	1.21	0.94	1.85	0.59	2.01

改进的 Faster RCNN 网络默认生成使用 5 个 scale 为 {2,4,8,16,32} 与 3 种长宽比 Ratio 为 {0.5,1,2} 的 15 种 Anchors 可以帮助网络更好的回归与识别目标,定制的锚框训练与测试各类电缆外护套的破口数据集时能够使得模型收敛更快,检测效果更好。

3 数据采集与处理

3.1 实验数据集采集

实验图像数据集采集于国内某海岛天然气公司,该公司的工业现场电缆长期经受风吹、雨淋、日晒等恶劣天气因素影响。现场采集各式电缆外护套破损图 800 张。本文所用图像采用尼康 D3500 单反相机拍摄多角度近距离(3 m 以内)进行拍摄,拍摄图像尺寸为 5 120 pixels×3 840 pixels,原始图像格式为 .JPG。

3.2 数据集样本以及标签制作

本文从拍摄的 800 张原始图片中随机采样 300 张作为测试集,剩下 500 张作为训练集。使用 Photoshop CS6 软件,将 800 张原始图片尺寸统一设为 800 pixels×600 pixels。由于训练集的数量有限,为提高模型的泛化能力和防止样本数量过少导致训练过程过拟合情况的发生,本文使用 Irfan View 对原始训练集进行水平翻转、垂直翻转和灰度化处理,将训练集从 500 张扩充到 3 054 张。增强后的数据集样式如图 6 所示。

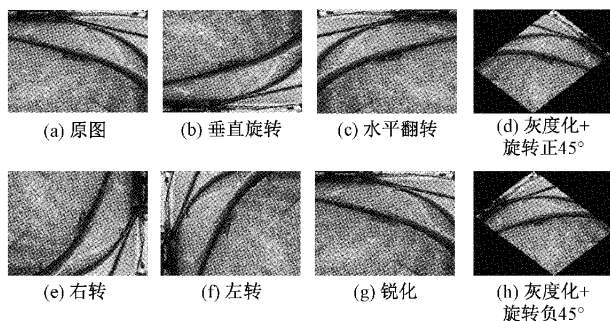


图 6 数据处理增强示例

3.3 电缆破损外护套分类方法

电缆外护套破损的原因与自身所处工业现场的环境因素相关,具体情况应结合实际分析。本文根据工业现场收

集到的电缆外护套的破损状况和外护套断裂形式可分为 3 类,pokou_a 为外护套破损程度较小的破口呈斜向断裂的形式,pokou_b 外护套破口面积较大主要呈竖向断裂形式,pokou_c 为外护套破损程度较小的破口呈横向断裂的形式,如图 7 所示。




图 7 常见 3 类电缆外护套破口类型示例

4 实验与结果分析

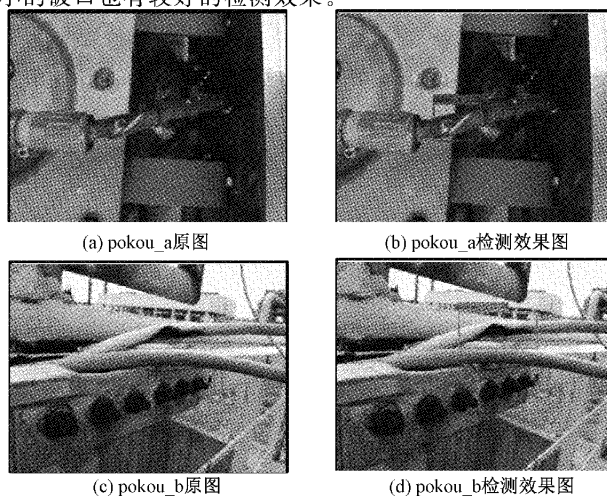
4.1 实验环境配置与参数设置

本文实验环境配置如下:软件环境为 Window10 系统 Python3.6,深度学习环境框架为 Pytorch 计算机配备内存 16 G,处理器为 Intel(R) Core(TM) i7-9750H CPU @ 2.60 GHz 12 核处理器,GPU 为 GeForce GTX 1660 搭配 cuda10.1 与 Cudnn7.4.2。数据集采用 PASCAL VOC 格式,共 3 354 张图片,其中 2 444 张作为训练集,610 张作为验证集,300 张原图作为测试集。

4.2 实验结果与分析

采用迁移学习,模型初始权重设置为 ImageNET 上所提供 coco 数据集训练权重。优化器采用随机梯度下降法进行训练,优化器动量设置为 0.9,初始学习率设置为 0.005,权重衰减设置为 0.000 5,共迭代 18 330 次,在约 10 000 次后损失函数基本收敛,训练时长约 12 h 后结束训练并保存模型。通过划分好的测试集模拟该方法所训练模型对实际工业现场电缆破口的检测效果。

最终训练模型检测不同类别的电缆外护套破口,检测结果对比如图 8 所示。图中左侧为原图,右侧为检测后的图片结果。可以看出改进后的 Faster RCNN 对于尺度较小的破口也有较好的检测效果。






图 8 基于改进的 Faster RCNN 电缆外护套破损检测结果

用相同测试集在原始的 Faster RCNN、YOLOv3、SSD 上进行训练,在各类模型收敛之后保存。设置 IoU 为 0.5, IoU 是测量在特定数据集中检测相应物体准确度的一个标准,该标准用于测量真实和预测之间的相关度,相关度越高,则该值越高。map 是目前目标检测领域的通用评价指标, map 越接近 100% 说明该模型的检测精度越高。通过相同测试集进行测试得到每个模型的 map 对实验结果进行量化评估,同时记录每个模型整体的测试时长计算出平均检测每张图片所需时间,实验结果如表 3 所示。

表 3 改进算法结果与各类经典算法对比

各类检测网络	改进的 Faster RCNN	Faster RCNN	YOLOv3	SSD
pokou_a/%	80.7	84	87	78
pokou_b/%	79.9	80	57	72
pokou_c/%	91.0	70	56	63
Map/%	83.33	77.84	66.75	71
检测速度/(张·s ⁻¹)	0.36	0.43	0.03	0.02

实验结果表明,相比于原始的 Faster RCNN 以及经典的 YOLOv3、SSD 网络,改进的 Faster RCNN 对于 3 种常见的外护套破损破口类型的检测精度都有明显提升,改进后的 Faster RCNN 比改进前平均精度提升了 5.49% (IoU 为 0.5),改进的 Faster RCNN 的检测速度仍然低于单阶段检测网络 SSD 和 YOLOv3 但优于改进前的 Faster RCNN 达到 0.36 张/s。以上结果表明,改进的 Faster RCNN 能够满足对工业现场电缆外护套破损的快速检测且满足准确度的要求,可搭载于其他移动平台如巡检机器人或各类检测设备之中,为解决目前工业现场主要依靠人工巡查而造成的效率较低和人力浪费问题提供了解决思路。

5 结 论

为了解决工业现场对于电缆外护套的破损主要依靠人工巡查而导致的各类问题,本文提出一种改进的 Faster RCNN 目标检测方法。最终实验对比,改进的 Faster RCNN 将原始 Faster RCNN 的整体 Map 从 77.84% 提高到 83.33%,且准确度优于经典的 YOLOv3 和 SSD。检测速度从改进前的 0.41 张/s 提高到了 0.36 张/s,速度和精度的提高明显,与理论相符。比起 3 种主流目标检测网

络更能满足工业现场对于可靠性的要求。为多尺度目标的识别和电缆外护套的破口检测提供了一种有效实用的方法,为深度学习在工业设备故障检测中的应用提供了思路,从精度与实时性考率所提出改进算法训练出的模型搭载工业现场视觉设备进行检测的优势明显。

参考文献

- [1] Harry Orton. 电力电缆技术综述(英文)[J]. 高电压技术, 2015, 41(4): 1057-1067.
- [2] 袁燕岭,李世松,董杰,等. 电力电缆诊断检测技术综述[J]. 电测与仪表, 2016, 53(11): 1-7.
- [3] 董浩,张曦,费泽林,等. 时频分析在真空热试验测试电缆故障检测中的应用[J]. 电子测量技术, 2019, 42(5): 133-138.
- [4] 郭忠. 电缆外护套破损定位技术[J]. 油气田地面工程, 2015, 34(8): 50-51.
- [5] 贾博,冯孝鑫,李军,等. 基于球面 Haar 小波和卷积神经网络的飞行员虹膜识别[J]. 电子与信息学报, 2021, 43(4): 939-947.
- [6] 牟奇春. 基于改进二维 Haar 小波的图像去噪算法[J]. 重庆理工大学学报(自然科学), 2019, 33(6): 177-183.
- [7] 田菲,孙忠民. 关于视觉图像的复合小波变换显著性检测方法[J]. 计算机仿真, 2020, 37(11): 427-430, 469.
- [8] 丰婧,程耀瑜,贺磊. 基于 PHOG 特征的坐姿识别方法研究[J]. 国外电子测量技术, 2021, 40(5): 83-87.
- [9] 雷江波,王泽民,李静. 基于 Faster R-CNN 的破片群图像目标检测研究[J]. 国外电子测量技术, 2021, 40(1): 70-74.
- [10] 向宽,李松松,栾明慧,等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法[J]. 仪器仪表学报, 2021, 42(1): 191-198.
- [11] SONG Z Z, FU L S, WU J Z, et al. Kiwifruit detection in field images using Faster R-CNN with VGG16[J]. IFAC PapersOnLine, 2019, 52(30): 76-81.
- [12] 薛阳,吴海东,张宁,等. 基于改进 Faster R-CNN 输电线穿刺线夹及螺栓的检测[J]. 激光与光电子学进展, 2020, 57(8): 84-91.
- [13] 闫建伟,赵源,张乐伟,等. 改进 Faster-RCNN 自然环境下识别刺梨果实[J]. 农业工程学报, 2019, 35(18): 143-150.
- [14] 音松,陈雪云,贝学宇. 改进 Mask RCNN 算法及其在行人实例分割中的应用[J]. 计算机工程, 2021, 47(6): 271-276, 283.
- [15] 黄小莉,陈静娴,胡思宇. 基于自适应果蝇优化算法的 K-means 聚类[J]. 国外电子测量技术, 2021, 40(6): 14-20.
- [16] 陈为,梁晨红. 基于 SSD 算法的航空发动机内部凸台缺陷检测[J]. 电子测量技术, 2020, 43(9): 29-34.
- [17] 贾振卿,刘雪峰. 基于 YOLO 和图像增强的海洋动物

目标检测[J]. 电子测量技术, 2020, 43(14): 84-88.

作者简介

薛阳, 博士, 副教授, 主要研究方向为智能控制和电力机器人等。

E-mail: xueyang@shiep.edu.cn

张舒翔(通信作者), 硕士, 主要研究方向为人工智能、深

度学习。

E-mail: 13122321105@163.com

贾巍, 博士, 研究员, 主要研究方向为新能源发电。

E-mail: jiawei@solarcell.net.cn

秦瑶, 硕士, 主要研究方向为人工智能, 深度学习。

E-mail: 870539559@qq.com