

DOI: 10.19783/j.cnki.pspc.210482

基于改进 Mask R-CNN 的输电线路防外破目标检测方法研究

魏贤哲¹, 卢武¹, 赵文彬¹, 王道累²

(1. 上海电力大学电气工程学院, 上海 200090; 2. 上海电力大学能源与机械工程学院, 上海 200090)

摘要: 随着现代电力系统的不断发展, 电网规模越来越大, 外破原因引发的故障已经成为架空输电线路故障的主要原因之一。在架空输电线路视频监控中, 使用传统的边界框式目标检测方法进行外破预警时, 误报或漏报的情况时有发生。掩模实例分割神经网络(Mask-RCNN)训练时使用的像素级掩模标注数据集成本较高, 限制了该算法的大规模应用。针对这些问题, 将改进的 Mask-RCNN 网络应用到输电线路外破目标检测领域, 在数据集标注过程中, 使用边界框标注代替部分掩模标注。训练时, 将检测分支的特征迁移到掩模分支。实验结果表明, 改进后的算法能够在掩模标注样本占比 80% 的条件下, 对常见外破类别的平均识别准确率高于 91%, 为输电线路外破隐患的准确识别与分割提供了一种可行的思路。

关键词: 输电线路; 外力破坏; Mask R-CNN; 迁移学习; 数据增广

Target detection method for external damage of a transmission line based on an improved Mask R-CNN algorithm

WEI Xianzhe¹, LU Wu¹, ZHAO Wenbin¹, WANG Daolei²

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. College of Energy and Mechanical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: With the continuous development of modern power systems and the increasing scale of power grids, faults caused by external damage have become one of the main causes of overhead transmission line failures. In overhead transmission line video surveillance, false or missed alarms occur when using the traditional bounding box target detection method for external damage warning. The high cost of integrating the pixel-level mask annotation data used in the training of the mask instance segmentation neural network (Mask-RCNN) limits the large-scale application of this algorithm. To address these problems, this paper applies an improved Mask-RCNN network to the field of transmission line external breakage target detection by using bounding box annotation instead of partial mask annotation in the process of dataset annotation. During training, the features of the detection branch are migrated to the mask branch. The experimental results show that the improved algorithm can achieve an average recognition accuracy of more than 91% for common external damage categories with 80% of the mask labeled samples, providing a feasible idea for accurate identification and segmentation of external damage hazards on transmission lines.

This work is supported by the National Natural Science Foundation of China (No. 61502297).

Key words: transmission line; external force damage; Mask R-CNN; transfer learning; data augmentation

0 引言

随着我国城镇规模的不断扩大, 输电走廊用地被压缩, 输电走廊保护区内的违规施工作业、违章建筑、树木生长和突发性外破等, 给架空输电线路的安全稳定运行造成威胁^[1]。架空输电线路作为电

力系统的重要组成部分, 其安全与否关系到整个电力系统的稳定运行^[2]。外力破坏故障主要表现为异物悬挂导致的短路、违规施工碰线和山火这三个主要类别, 故障后重合闸装置动作成功概率较低, 输电线路一旦发生停运, 对电网的安全稳定运行危害较大^[3]。据统计, 在各类输电线路故障中, 外力破坏已经逐步成为引起输电线路故障跳闸的主要原因, 严重威胁到电网的安全稳定运行^[4]。

基金项目: 国家自然科学基金项目资助(61502297)

由于外力破坏事故的偶发性和不可预测性，传统的人工巡线以及无人机和直升机巡线受成本的影响，无法全天候对输电走廊进行监控，难以及时发现危险物对输电走廊的入侵^[5]。因此视频图像处理方法由于实时性和经济性逐渐成为架空输电线路外力破坏监控的主要手段。与传统的人工巡线方式相比，在线视频监控可以实时监控输电线路的状态，一定程度上实现了输电线路的全天候保护，提高了监控效率^[6]。但是依靠后台人工筛选出有外力破坏隐患的图片进行预警，一方面隐患预警信息不具有实时性，另一方面大量无预警信息图像浪费了大量人力物力^[7]。因此，对架空输电线路所处的输电走廊区域中的外破隐患目标进行自动化识别预警，是当前视频监控输电线路防外破工作的关键所在。

传统的输电通道危险物检测主要是通过对图像进行边缘、颜色等特征检测，例如视频监控系统基础上应用背景建模以及直线检测算法，跟踪外侵物并自动预警，但该方法判据指标单一，易造成漏报。激光雷达技术通过获取输电线路场景建模，计算线路和物体的空间坐标，判断物体是否威胁到线路，但是该方法成本较高，需要额外的软硬件配合^[8-9]。

深度学习特别是卷积神经网络(CNN)方法在图像分类和目标检测领域得到越来越多的应用，并取得了显著的效果，该类方法具有自动化程度高、鲁棒性强以及可以实现多目标检测等优点，目前在输电线路防外力破坏系统中常用的 Faster R-CNN、YOLOv3 等目标检测算法的外破隐患识别准确率高达 80% 以上^[10-11]。在外破识别的实际应用中，不仅需要准确地识别出外破隐患，还需要知道外侵物是否对输电线路构成威胁。虽然目标检测算法能够迅速准确地将目标物体识别出来，但是无法描述被检测物体的形状，从而无法准确判断目标物体是否对输电线路的安全运行构成威胁，需要对“危险点”进行手动提取，不仅容易造成漏判和误判，还给监控人员带来了大量的工作量。实例分割算法虽然可以实现目标物体的精确分割，但是由于其数据集的标注成本较高，限制了它的大规模推广应用。如何在保证识别精度的前提下，最大限度地减少获取训练样本的工作量，是一个具有挑战性的课题。

外力破坏隐患目标与输电线路之间安全距离的确定依赖人工手动选取，本文针对此问题，对传统的目标检测式外破预防体系进行了改进，在 Mask R-CNN 框架的基础上，将实例分割问题分解为边界框检测和掩模预测这两个子任务，使用基于特征映射的迁移学习方法，将边界框参数迁移到掩模参数，最后在实际应用中验证了方法的可行性与准确性。

1 基于迁移学习的掩模实例分割算法

1.1 目标检测方式的比较

根据 DL/T741—2019《架空输电线路运行规程》中的规定，架空输电线路与输电走廊内的物体必须符合安全距离限值的要求。输电线路外力破坏防治中的实际应用中，外破隐患物体与输电线路之间需要保持一定的安全距离^[12]。图 1(a)为使用边界框式目标检测方法对外破隐患目标进行识别时的示意图，从图中可以看到边界框虽然可以轻松地找到目标，但是矩形边界框内包含了大量无效区域。图 1(b)展示了使用掩模的方式对吊车识别的示意图，像素级掩模可以较为准确地从背景图像中将目标物体分割出来，包含的无效像素点较少。



(a) 边界框示意图



(b) 掩模示意图

图 1 目标检测方式的比较

Fig. 1 Comparison of target detection methods

从图 1 中可以看出，以矩形框与导线之间的像素坐标距离作为预警的依据时，误报或漏报的情况时有发生，危险点仍需手动选取，增加了监控人员的工作负担。掩模预警策略能准确地从二维图像中识别并分割出目标物体的区域，然后可以结合立体视觉或三维重建等方法，将分割出的二维像素坐标转换成三维空间坐标，从而实现外破隐患的准确预警，提升了输电通道安全管控的自动化水平^[13-14]。

在实际应用中，边界框式目标检测算法所需的

矩形边界框标注较为简单, 且现有大量的类别标签和边界框数据可供使用。而掩模实例分割算法所需的像素级掩模标注费时费力, 数据集标注时所需的人力成本大大增加。

综上所述, 需要解决的问题有两个: 一是常用的目标检测算法仅能检测出外破隐患的种类和位置, 在没有人工干预的情况下难以自动判断外破隐患目标是否处于安全距离之内; 二是实例分割掩模数据集的标注较为繁琐, 限制了实例掩模分割在外破隐患识别领域的大规模应用。

1.2 基本框架

在本文中使用的算法是在掩模实例分割卷积神经网络(Mask R-CNN)算法基础上, 并根据任务的特征进一步改进的。如图 2 所示, Mask R-CNN 算法的框架由特征提取模块(ResNet50-FPN 特征金字塔

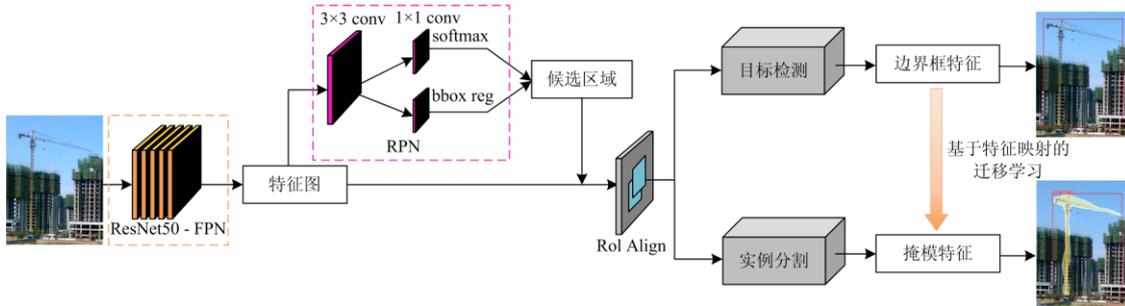


图 2 基于改进 Mask R-CNN 的输电线路外力破坏检测方法框架

Fig. 2 Framework of transmission line external force damage detection method based on improved Mask R-CNN

该网络的损失函数由用于分类的损失 L_{cls} 、用于回归的平滑损失 L_{box} 和用于掩模分割的平均二值交叉熵损失 L_{mask} 三部分构成, 该网络的多任务损失函数定义为

$$L = L_{cls} + L_{box} + L_{mask} \quad (1)$$

式中 L_{cls} 、 L_{box} 、 L_{mask} 的定义为式(2)~式(4)。

$$L_{cls}(p, u) = -\log p_u \quad (2)$$

$$L_{box}(t, v) = \sum_i \text{smooth}L_1(t - v) \quad (3)$$

$$L_{mask}(y, \hat{y}) = -\frac{1}{m \cdot m} \sum_{i=1}^m [y(i, j) \log \hat{y}(i, j) + (1 - y(i, j)) \log(1 - \hat{y}(i, j))] \quad (4)$$

对于每个训练的对象 p , 都有其标注的类别标签 u , p_u 表示边界框被预测为含有目标的概率, v 表示边界框回归目标, t 为预测的边界框回归的偏移, y 和 \hat{y} 分别为目标的掩模和预测掩模, (i, j) 为每个像素的坐标, m 为掩模的边长。

Mask R-CNN 在 RoI 上的结构改进使得它在检测小物体时具有更高的精确度, Faster R-CNN 中的

网络)、候选区域生成模块(RPN 区域建议生成网络), 目标检测模块(边界框识别)和实例分割模块(掩模预测)这四部分组成^[15]。首先, 我们采用以 ResNet50 为骨干的特征金字塔网络进行特征提取; 然后, 利用区域建议生成网络为图像生成许多兴趣区域(Region of Interest, RoI); 由感兴趣区域聚集(RoI Align)操作处理后, 每个感兴趣区域生成一个固定大小的特征图; 最后, 基于该特征图实现了边界框识别和掩模预测。由于 Mask R-CNN 算法可以被看作是在 Faster R-CNN 算法上增加了一个掩模分支, 所以算法将实例分割问题分解为边界框预测(第一阶段)和掩模预测(第二阶段)两个子任务, 两个子任务共享了 Mask R-CNN 算法中的特征提取、候选区域生成和 RoI Align 这三个模块^[16]。为了提升模型的性能, 本文采用端到端联合训练的方式, 将边界框分支和掩模分支并行训练。

感兴趣区域池化(RoI Pooling)方法在将 RoI 映射到统一尺寸的特征图时会进行取整分割, 这对于分类影响有限, 但是对于位置回归或者像素级的掩模语义分割会产生很大的负面影响。RoI Align 舍弃取整操作, 使用双线性插值的方法使得算法对小目标的定位更加精确, 其原理如图 3 所示, 虚线网格代表特征图, 实线代表 RoI, RoIAlign 层通过对特征图上与采样点相邻格点进行双线性插值, 来计算采样点 P 的值^[17]。

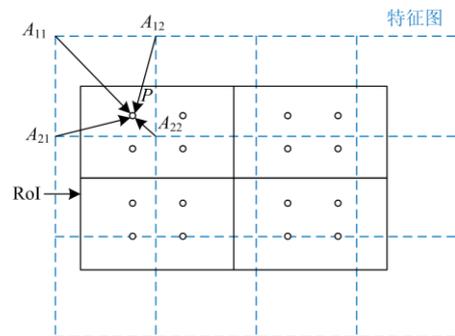


图 3 RoI Align 中的双线性插值算法

Fig. 3 Bilinear interpolation algorithm in RoI Align

双线性插值算法的公式为

$$f(x, y) = \frac{y_2 - y_1}{y_2 - y_1} \left(\frac{x_2 - x}{x_2 - x_1} f(A_{11}) + \frac{x - x_1}{x_2 - x_1} f(A_{12}) \right) + \frac{y - y_1}{y_2 - y_1} \left(\frac{x_2 - x}{x_2 - x_1} f(A_{21}) + \frac{x - x_1}{x_2 - x_1} f(A_{22}) \right) \quad (5)$$

式中： $f(x, y)$ 为待求解点 P 的像素值； A_{11} 、 A_{12} 、 A_{21} 、 A_{22} 这四个点的坐标分别为 (x_1, y_1) 、 (x_2, y_1) 、 (x_1, y_2) 、 (x_2, y_2) 。

Mask R-CNN 实例分割算法虽然可以精确地分割出目标物体，但是其性能很大程度上依赖于人工像素级别的标注，为了改善算法在掩模标注数据集有限的情况下，训练出高质量掩模分割模型的能力，本文在 Mask R-CNN 算法的基础上，使用迁移学习的方法将边界框特征迁移到掩模特征。

1.3 迁移学习

迁移学习是根据已经学习的相关任务，迁移权重参数等知识信息用于新任务的学习。本文使用迁移学习的方法，放宽了传统机器学习中用于学习的训练集与测试集中的样本需满足独立同分布的条件，在边界框和掩模之间搭建起桥梁^[18]。迁移学习的前提是源域和目标域之间的相似性，边界框和掩模在标定区域上具有部分一致性的特征，仅仅是后者比前者更精确。因此使用迁移学习的方法能够充分利用类别标签和边界框标注数据。

基于上述分析，本文提出了一种基于特征映射的迁移学习方法，迁移已有目标检测边界框预测参数，用于实例分割掩模的预测。在 Mask R-CNN 算法中，边界框分支的头部和掩模分支的头部都包含了与类别相关的参数，分别用于对每个类别进行边界框预测和掩模预测。本文使用一个通用的、与类别无关的权重传递函数 $T(\cdot)$ ，来预测掩模参数 w_{seg}^c 。目标检测权重 w_{det}^c 与掩模分割权重 w_{seg}^c 之间的权重迁移函数如式(6)所示。

$$w_{seg}^c = T(w_{det}^c; \theta) \quad (6)$$

式中， θ 是通过学习得到的基于特征映射的迁移参数。当掩模损失反向传播时，冻结检测参数 w_{det}^c 的梯度，即只计算掩模预测权重相对于迁移参数 θ 的梯度，可以实现为 $w_{seg}^c = T(\text{stop_grad}(w_{det}^c); \theta)$ 。

基于特征映射的权重传递函数可以实现为一个小型的全连接神经网络。如图4中虚线框所示，本文使用由全连接层组成的神经网络来实现 $T(\cdot)$ ，首先将边界框头部中提取出的边界框特征权重输入全连接层，全连接层的隐藏层中包含了LeakyReLU

类型的激活函数，然后将传递函数输出的权重进行尺度变换，调整为 $21 \times 256 \times 1 \times 1$ 的卷积核，最后使用该卷积核对从掩模头部提取出的掩模特征进行卷积操作，从而实现了边界框特征到掩模特征的迁移。

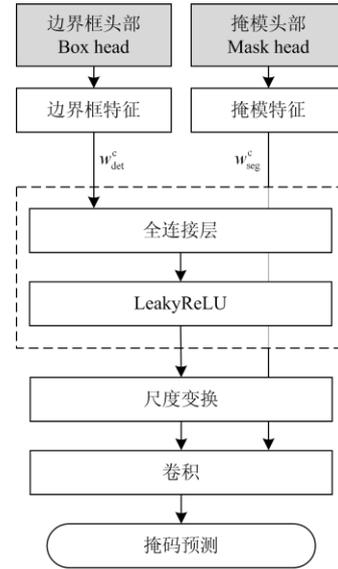


图4 基于特征映射迁移学习的网络结构

Fig. 4 Structure of feature-mapping-based transfer learning framework

2 应用实验与分析

2.1 数据增广与图像标注

本文从安装在输电杆塔上的监控摄像机采集到的现场图像中选择合适的图片，收集了3571张存在外破隐患情况下的样本图像，制作了专门的输电线路外破图片数据集。如图5所示，数据集中包括挖掘机、吊车、塔吊、泵车、山火、异物悬挂这6种常见外力破坏类型的图片，这些外部入侵物对输电线路的安全和稳定运行具有潜在或直接的危害。



(a) 挖掘机

(b) 吊车

(c) 塔吊

(d) 泵车



(e) 山火

(f) 异物悬挂

图 5 外破隐患图片数据集

Fig. 5 External force damage hidden danger picture dataset

为了获得理想的分类效果, 需要使用数据增广的方式降低样本之间的不平衡度。基于输电杆塔监控摄像头拍摄到的图片在色彩、噪点和视角等方面具有多样性的特性, 本文提出了一种适用于输电线路监控图像的数据增广方法^[19-20]。从常用的图像数据增广方法中选取了色彩空间变换、高斯噪声、透视变换和水平镜像这四种策略, 数据增广效果如图 6 所示。在对图像进行色彩空间变换时, 采用随机改变照片色相、饱和度、明度的方法可以模拟由于光照强度和天气的变化对图像的影响, 在一定程度上可以消除光环境的影响^[21]。为减少不同类型样本间的不平衡度, 对数据集中山火和异物悬挂的图片分别扩增 2 倍和 3.5 倍, 使数据集中各类样本数量基本一致, 以解决小样本外破隐患数据集在深度学习过程中容易出现过拟合问题。

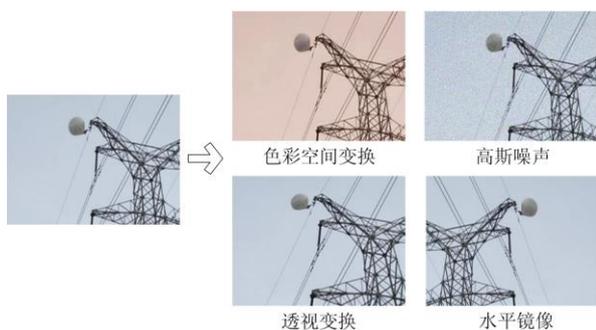


图 6 数据增广效果

Fig. 6 Effect of data augmentation

经数据增广后, 数据集中图片的数量如表 1 所示, 将图片按照 6:2:2 的比例分成训练集、测试集和验证集, 以取得最佳的训练效果^[22]。

表 1 图像数据集的划分

Table 1 Number of images used for training

类别	训练集/张	测试集/张	验证集/张	合计/张
挖掘机	471	157	157	785
吊车	440	147	147	734
塔吊	468	156	156	780
泵车	428	143	143	714
山火	424	141	141	706
异物悬挂	430	143	143	717

在进行模型训练之前, 需要对数据集中的图片进行标注。边界框标注仅需选取目标物体对角线上的两个点, 而掩模标注是通过沿着目标轮廓画多边形的方式进行的。本文在进行标注时, 先从每个类别中随机抽取部分图片, 进行相对复杂的掩模标注, 供神经网络中的掩模分支使用, 再对剩余的图片进行简单的矩形框标注。

2.2 网络模型训练

为了验证迁移学习函数对提升 Mask R-CNN 实例分割算法在输电线路外破目标检测方法中的表现, 本案例中计算环境如表 2 所示。

表 2 网络参数设置和软硬件参数

Table 2 Neural network parameter settings and hardware and software parameters

网络参数		软硬件参数	
名称	参数	名称	参数
批处理大小	2	内存	62 G
训练轮数	50	处理器	Intel Xeon@2.30 GHz
每轮迭代次数	100	显卡	Nvidia RTX 2080 Ti
动量因子	0.9	操作系统	Ubuntu 16.04 LTS

图 7 使用可视化的方法将训练和分割对象的关键步骤进行了展示, 首先, 输入图片表示为多维数组形式, 经过预训练 CNN 特征提取器的处理, 得到特征图; 然后, RPN 对提取的卷积特征图进行处理, 寻找可能包含目标物体的边界框。RoI Align 通过双线性插值的方法, 将原图和特征图的像素对应起来; 其次, 对这些 RoI 区域进行多类别分类和候选框的回归; 最后, 生成掩模, 完成目标的识别与分割任务。

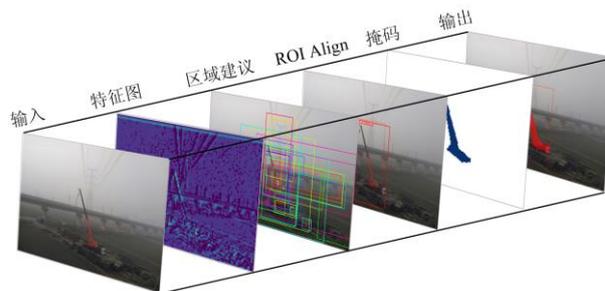


图 7 训练过程可视化效果

Fig. 7 Visualization of training process

2.3 实验评估标准

需要对提出的输电线路外破隐患识别算法性能进行评价, 准确率(Precision, P)和召回率(Recall, R)是衡量一个模型性能的基本指标, 选取了 F-score 来衡量外破隐患检测的准确率, 其计算公式如式(7)一式(9)所示。

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$F-score = \frac{2 \times Precision \cdot Recall}{Precision + Recall} \quad (9)$$

式中： TP 表示实际为外破且被模型预测为外破的个数，即正样本被检测为正样本数； FP 实际为背景却被模型预测为外破的个数，即负样本被错分为正样本数； FN 表示实际为外破却没有被网络识别为外破的个数，即正样本被错分为负样本数^[23]。

在本文进行的目标检测与分割任务中，需要对目标进行分类以及描绘出目标的轮廓。平均精度 (Average Precision, AP) 是衡量分类器性能的指标，在本文中指的是目标检测交并比 (Intersection over Union, IoU) 阈值在 0.5 时目标识别的准确率，其定义如式(10)所示^[24]。

$$AP = \int_0^1 P(R) dR \quad (10)$$

2.4 实验结果与分析

本文在构建的数据集上对改进后的 Mask R-CNN 网络进行训练，初始学习率为 0.001，训练 50 轮，共迭代 20 000 次，损失函数的变化曲线如图 8 所示。

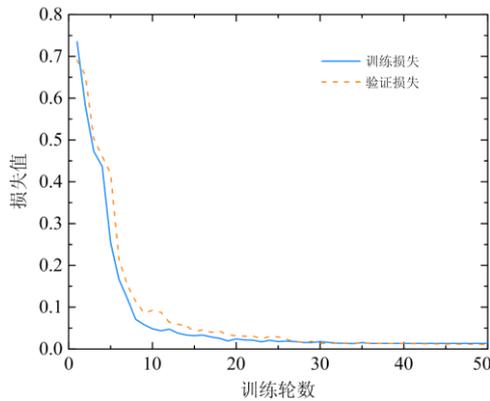


图 8 损失函数变化曲线

Fig. 8 Loss function curve changing diagram

为了进一步验证本文算法的优势，将本文算法与 Faster R-CNN、YOLOv3、Mask R-CNN 这 3 种代表性算法的检测效果进行了对比，所用算法均使用相同的参数和图片样本进行训练。如表 3 所示。

经过测试集的测试，YOLOv3 在检测速度上明显高于其他几种网络，但是其检测准确率较低。Faster R-CNN 算法的检测精度较高，但是其检测速度较慢。本文所提出的改进算法与原 Mask R-CNN

表 3 不同神经网络算法的准确率与识别速度

Table 3 mAP and recognition speed of different neural network algorithms

检测模型	mAP	帧速率/fps
YOLOv3	0.81	33.33
Faster R-CNN	0.89	3.29
Mask R-CNN	0.91	4.95
改进 Mask R-CNN	0.91	5.06

算法相比，在掩模标注与矩形框标注之比为 8:2 的情况下，识别准确率与识别速度与 Mask R-CNN 算法较为接近，且较为准确地提取出目标物体的轮廓，能够满足输电线路外破隐患检测的需要。

从图 9 算法实际检测结果的示意图中可以看出，经过改进的网络与 Mask R-CNN 网络相比在分割准确度上差别不大，均能满足保护输电线路防外破的要求。检测模型能有效地提取外破目标的特征信息，从而进行准确的定位、识别和分割，并能将其与复杂背景的特征信息进行区分。



(a) Mask R-CNN算法



(b) 本文改进算法

图 9 两种算法对吊车的检测效果

Fig. 9 Detection effect of the two algorithms on the crane

经过实验，如果训练集中仅具有标注框标注的图片占比较高时，模型的识别效果不够理想，无法达到有效识别外破隐患的需求，也就是过度依赖标注框分支训练权重的迁移学习时，识别准确率偏低且掩模质量较差。如图 10 所示，随着数据集中具有掩模标注的图片的比例提高，识别准确率有所回升，当具有掩模标注的图片的比例在 80% 时，各类别 AP 的平均值 mAP 为 0.91，能够基本满足保护输电

线路安全运行的要求, 与使用 Mask R-CNN 算法训练时, mAP 值为 0.94 的效果差距不大, 可以兼顾标注成本和识别准确率, 通过对具有掩模标注的图片进行数据增广的方法, 还可以进一步降低数据集的标注成本。

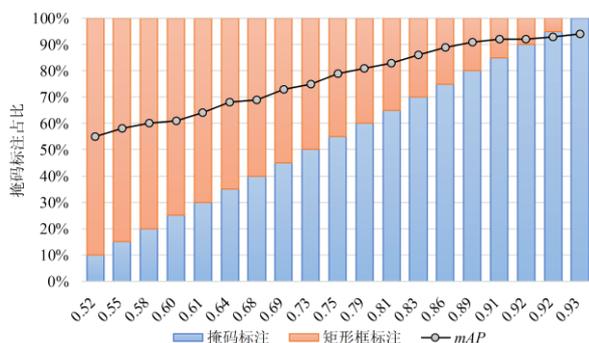


图 10 数据集构成对识别精确度的影响

Fig. 10 Influence of dataset composition on identification accuracy

3 结论

本文分析了在输电线路防外破视频监控领域中传统边界框目标检测方法的不足, 并提出了一种基于 Mask R-CNN 算法的目标检测与实例分割方法, 检测入侵高压架空输电线路监控区域的危险因素。使用特征映射的迁移学习方法, 将样本标签和边界框信息充分利用; 使用数据增广的方法, 解决了不同场景下数据分布的差异。当数据集中具有掩模标注的图片占比为 80% 时, 平均识别误差在 10% 以内。实验结果表明, 本方法能够在使用较少的人力物力的情况下, 实现对外破目标的掩模的准确分割, 可用于架空输电线路防外破监控自动化安全预警。

目前, 随着深度学习和计算机视觉技术在电力领域的应用, 许多问题将会得到解决。本文为输电线路防外破视频监控中, 实现外破隐患的像素级分割提供了可行的方法, 并且由于标注成本的降低, 使得标注新的外破物体类别更加容易。然而, 深度学习算法运行的效率和安全距离的准确判断等问题, 还需要进一步的研究。

参考文献

[1] 顾晓东, 唐丹宏, 黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别[J]. 电力系统保护与控制, 2021, 49(5): 91-97.
GU Xiaodong, TANG Danhong, HUANG Xiaohua. Deep learning-based defect detection and recognition of a power grid inspection image[J]. Power System Protection and Control, 2021, 49(5): 91-97.

[2] 叶保璇, 王康坚, 余盛达, 等. 计及数据时效性的输电线路状态综合评估方法[J]. 广东电力, 2020, 33(11): 109-116.
YE Baoxuan, WANG Kangjian, YU Shengda, et al. Comprehensive evaluation method of transmission line status considering data timeliness[J]. Guangdong Electric Power, 2020, 33(11): 109-116.

[3] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度神经网络的输电线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37-44.
YANG Jianfeng, QIN Zhong, PANG Xiaolong, et al. Foreign body intrusion monitoring and recognition method based on Dense-YOLOv3 deep learning network[J]. Power System Protection and Control, 2021, 49(4): 37-44.

[4] 孙翠英, 蔡文彪, 贾伯岩, 等. 基于 I-OHEM 的输电线路防外破目标检测方法研究[J]. 电气自动化, 2020, 42(4): 103-106.
SUN Cuiying, CAI Wenbiao, JIA Boyan, et al. Research on a target detection method for external breakage prevention of transmission lines based on I-OHEM[J]. Electrical Automation, 2020, 42(4): 103-106.

[5] 周文武, 江岳, 张小力, 等. 一种求解架空输电线路单端覆冰下不平衡张力的方法[J]. 电网与清洁能源, 2021, 37(1): 49-53, 61.
ZHOU Wenwu, JIANG Yue, ZHANG Xiaoli, et al. A Calculation method of unbalanced tension under single-ended icing on overhead transmission lines[J]. Power System and Clean Energy, 2021, 37(1): 49-53, 61.

[6] 邓红雷, 戴栋, 李述文. 基于层次分析-熵权组合法的架空输电线路综合运行风险评估[J]. 电力系统保护与控制, 2017, 45(1): 28-34.
DENG Honglei, DAI Dong, LI Shuwen. Comprehensive operation risk evaluation of overhead transmission line based on hierarchical analysis-entropy weight method[J]. Power System Protection and Control, 2017, 45(1): 28-34.

[7] ZHUANG Lihu, HE Tong, ZENG Yihui, et al. Fast image recognition of transmission tower based on big data[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 149-158. DOI: 10.1186/s41601-018-0088-y.

[8] 陈嘉琛, 俞曜辰, 陈中, 等. 基于改进 YOLOv3 的输电线路缺陷识别方法[J]. 南方电网技术, 2021, 15(1): 114-120.
CHEN Jiachen, YU Yaochen, CHEN Zhong, et al. An improved method for defect identification of transmission lines based on YOLOv3[J]. Southern Power System Technology, 2021, 15(1): 114-120.

[9] 麻卫峰, 王成, 王金亮, 等. 基于激光点云的高压输电线路覆冰厚度反演[J]. 电力系统保护与控制, 2021, 49(4): 87-95.

- MA Weifeng, WANG Cheng, WANG Jinliang, et al. Inversion of ice thickness for high voltage transmission line based on a LiDAR point cloud[J]. Power System Protection and Control, 2021, 49(4): 87-95.
- [10] 罗朝祥, 万华舰, 罗文博, 等. 输电线路导线覆冰图像处理与识别技术[J]. 中国电力, 2014, 47(9): 132-136.
- LUO Chaoxiang, WAN Huajian, LUO Wenbo, et al. Image processing and recognition technology for transmission line icing[J]. Electric Power, 2014, 47(9): 132-136.
- [11] LIU Yunpeng, JI Xinxin, PEI Shaotong, et al. Research on automatic location and recognition of insulators in substation based on YOLO-v3[J]. High Voltage, 2019, 5(1): 62-68.
- [12] XIANG Xuezhi, LÜ Ning, GUO Xinli, et al. Engineering vehicles detection based on modified faster R-CNN for power grid surveillance sensors[J]. Sensors, 2018, 18(7).
- [13] 符杨, 荣帅昂, 刘恩圻, 等. 架空输电通道图像监测中大场景双目测距的方法及校正算法[J]. 高电压技术, 2019, 45(2): 377-385.
- FU Yang, RONG Shuai'ang, LIU Enqi, et al. Calibration method and regulation algorithm of binocular distance measurement in the large scene of image monitoring for overhead transmission lines[J]. High Voltage Engineering, 2019, 45(2): 377-385.
- [14] 王艳如, 刘海峰, 李琳, 等. 基于边缘智能分析的图像识别技术在输电线路在线监测中的应用[J]. 电力信息与通信技术, 2019, 17(7): 35-40.
- WANG Yanru, LIU Haifeng, LI Lin, et al. Application of image recognition technology based on edge intelligence analysis in transmission line online monitoring[J]. Electric Power Information and Communication Technology, 2019, 17(7): 35-40.
- [15] HE Kaiming, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [16] HU Ronghang, PIOTR D, HE Kaiming, et al. Learning to segment every thing[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA: 4233-4241.
- [17] 孔英会, 王维维, 张珂, 等. 基于改进 Mask R-CNN 模型的电力场景目标检测方法[J]. 科学技术与工程, 2020, 20(8): 3134-3142.
- KONG Yinghui, WANG Weiwei, ZHANG Ke, et al. Object detection method of electric power site based on improved Mask R-CNN[J]. Science Technology and Engineering, 2020, 20(8): 3134-3142.
- [18] 林铭瀚, 胡永洪, 薛毓强, 等. 基于 mesh 网络的输电线路山火预警监视系统研制[J]. 电力系统保护与控制, 2016, 44(1): 134-138.
- LIN Minghan, HU Yonghong, XUE Yuqiang, et al. Research and application of forest fire early-warning and monitor system based on wireless mesh network for transmission line[J]. Power System Protection and Control, 2016, 44(1): 134-138.
- [19] SUN Yongqing, LIAO Shisha, GAO Chenqiang, et al. Weakly supervised instance segmentation based on two-stage transfer learning[J]. IEEE Access, 2020, 8: 24135-24144.
- [20] 张小力, 周文武, 李小亭, 等. 架空输电线路初伸长计算方法探讨[J]. 电网与清洁能源, 2020, 36(9): 57-62.
- ZHANG Xiaoli, ZHOU Wenwu, LI Xiaoting, et al. Discussion on the calculation method of the permanent elongation of overhead transmission lines[J]. Power System and Clean Energy, 2020, 36(9): 57-62.
- [21] 许志海, 胡楠, 张峰, 等. 数据增广在电力走廊深度学习分类中的研究[J]. 计算机仿真, 2019, 36(11): 64-68.
- XU Zhihai, HU Nan, ZHANG Feng, et al. The data augmentation in research of segmentation of UAV aerial power tower images based on Segnet[J]. Computer Simulation, 2019, 36(11): 64-68.
- [22] REN Shaoqing, HE Kaiming, 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.
- [23] 彭秋辰, 宋亦旭. 基于 Mask R-CNN 的物体识别和定位[J]. 清华大学学报: 自然科学版, 2019, 59(2): 135-141.
- PENG Qiuchen, SONG Yixu. Object recognition and localization based on Mask R-CNN[J]. Journal of Tsinghua University: Science and Technology, 2019, 59(2): 135-141.
- [24] SEBAI M, WANG Tianjiang, AL-FADHLI S A, et al. PartMitosis: a partially supervised deep learning framework for mitosis detection in breast cancer histopathology images[J]. IEEE Access, 2020, 8: 45133-45147.

收稿日期: 2021-04-24; 修回日期: 2021-07-30

作者简介:

魏贤哲(1996—), 男, 硕士研究生, 研究方向为图像处理、电力设备状态监测;

卢武(1991—), 男, 通信作者, 讲师, 硕士研究生导师, 研究方向为输变电设备状态管理; E-mail: wuluee@shiep.edu.cn

赵文彬(1977—), 男, 教授, 硕士研究生导师, 研究方向为电力系统接地技术、输电线路状态监测。

(编辑 周金梅)