

DOI:10.19651/j.cnki.emt.2210866

融合迁移学习的绝缘子缺陷分级检测方法^{*}

翟永杰 胡哲东 白云山 孙圆圆
(华北电力大学自动化系 保定 071003)

摘要:针对Faster R-CNN算法对复杂环境下的小样本绝缘子缺陷检测精度不高的问题,本文提出了一种融合迁移学习和主体局部的绝缘子缺陷分级检测方法。整个方法使用融合残差模块和特征金字塔结构的卷积神经网络作为骨干网络进行特征提取,用于适应不同尺度的缺陷目标,保留更多有效信息。首先使用迁移学习的方法改善对缺陷所在绝缘子主体的检测效果;然后对检测出的绝缘子主体进行自动裁剪来改善复杂背景对缺陷区域检测的影响,使得模型能够更有效地挖掘出缺陷特征;最后将裁剪后的缺陷绝缘子局部图像送入第二阶段进行训练,进一步提高模型准确率。通过对无人机航拍采集的绝缘子缺陷图像进行检测实验。结果表明,本文方法相较于Faster R-CNN基线模型平均精度提高了37.5%,达到了89.6%。在对自爆和破损检测上,精度分别提高了34.9%和60.2%。

关键词:迁移学习;主体局部;绝缘子缺陷;小样本;目标检测

中图分类号: TP391;TP389 文献标识码: A 国家标准学科分类代码: 520.2040

Integrating transfer learning for insulator defect grading detection

Zhai Yongjie Hu Zhedong Bai Yunshan Sun Yuanyuan

(North China Electric Power University, Department of automation, Baoding 071003, China)

Abstract: This paper proposes a Main-Partial Transfer Region-CNN method for insulator defect detection to address the problem that the Faster R-CNN algorithm is not accurate in detecting insulator defects with small samples in complex environments. The whole method uses a convolutional neural network with a fused residual module and feature pyramid structure as the backbone network for feature extraction, which is used to adapt to different scales of defect targets and retain more valid information. Then, the detected insulator body is automatically cropped to improve the effectiveness of the complex background in the detection of the defective area, so that the model can be more effective in mining the defective features. The insulator defect images collected by UAV aerial photography are detected. The results show that the average accuracy of the method in this paper is improved by 37.5% compared with the Faster R-CNN baseline model, reaching 89.6%. The accuracy is improved by 34.9% and 60.2% on the detection of missing and damaged, respectively.

Keywords: transfer learning; main-partial; insulator defect; small samples; target detection

0 引言

在输电线路中,绝缘子作为一种重要的电力器件,主要起到了导线的机械支撑和电气绝缘的作用^[1]。长期工作于恶劣的外界环境中,在积污、受潮和电场三者同时作用下,可能产生自爆、破损等缺陷^[2],一旦出现故障,会对输电线路的安全性和可靠性产生很大程度上的威胁。因此,应该将准确、高效地排查绝缘子是否处于完好状态视为重要的问题。对绝缘子缺陷的检测从传统的人工实地

勘察方式、直升机载人巡查方式、再到如今的无人机采集航拍图像。输电线路的架设位置地理环境复杂且气候多变,无人机和人工智能技术的引入^[3],有效降低了绝缘子巡检工作的难度、保障了人员安全、同时极大的提升了效率和完成度。

然而,无人机采集的巡检图像中,绝缘子所在的背景干扰性强、主体大小不一,缺陷位置的特征不明显且缺陷样本数量不足。因此,处理这些图像比较复杂,很容易造成对故障的漏检、误检,提高检测绝缘子状态的精度和效率,成为

收稿日期:2022-07-28

*基金项目:国家自然科学基金项目重点支持项目(U21A20486,61871182)资助

了提高电力巡检效率的关键因素之一。而对绝缘子缺陷检测的关键步骤可以分为:1)定位绝缘子和 2)缺陷识别。即从复杂背景中锁定绝缘子位置,再于局部绝缘子图像中对缺陷进行识别。在诸多类型的缺陷中,本文关注的是户外绝缘子较常见的缺陷:自爆以及破损。

传统的图像检测算法一般是通过人工提取特征,建立对应的数学模型,训练图像特征分类器,实现对绝缘子的检测和定位。Zhao 等^[4]使用 SURF 对巡检图像进行特征提取,然后使用相关系数 IFS 实现特征分类,通过对各类型的形状特征值以及最小限制矩形实现绝缘子的识别。Zhao 等^[5]基于绝缘子形状特征,提出了结合方向角检测以及先验知识的绝缘子定位算法。Zhai 等^[6]针对绝缘子的结构和变形问题融合自适应学习,提出了基于显著性特征和自适应形态学的故障检测算法。Cheng 等^[7]利用边缘检测算子进行提取,然后结合绝缘子空间特征识别绝缘子自爆缺陷。传统的识别方式需要对绝缘子形态有专业知识积累,且只能在特定背景、形态下进行识别,带来了精度低、泛化能力差等一系列缺点。因此,传统的方法无法使用于本文中复杂背景下的绝缘子缺陷图像识别。

随着深度学习算法在图像识别和检测方面取得的巨大成就,这引起了绝缘子缺陷检测研究人员的广泛关注。Tao 等^[8]提出基于 CNN 的两级级联网络,先于一级定位绝缘子,再由二级检测绝缘子缺陷。Li 等^[9]融合 Faster R-CNN 和 U-Net 网络对无人机采集图像中的绝缘子进行缺陷检测,通过 Faster R-CNN 进行缺陷定位,再根据 U-Net 实现对绝缘子缺陷的边缘分割。潘哲等^[10]提出基于 MFIDN 的检测网络,该算法的特点在于:使用多尺度预测结构,采用具有弱监督细粒度的 MFIFIN 网络检测绝缘子。杜丽群^[11]以基于 VGG-16 的 SSD 网络为基础,利用微调网络模型、生成自适应默认框的方法对绝缘子进行检测。刘业鹏^[12]在 SSD 检测模型的基础上进行改进,实现对绝缘子的检测,在图像底层引入 FPN 结构,增强了对特征信息的提取从而提高了检测精度。

上述研究方法从不同的研究方向实现了绝缘子缺陷检测,较传统检测方法在检测精度、泛化能力上均有大幅提升,但当目标处于复杂背景下,上述算法难以对缺陷目标进行有效的特征提取,适应性较差,且对数据量要求高。为了解决由于在绝缘子缺陷检测过程中样本背景复杂且绝缘子缺陷数据量小使得模型特征提取效果不佳、检测精度低等问题,本文面向输电线路中的绝缘子自爆与破损缺陷,提出了一种融合迁移学习的主体-局部目标检测模型 MPT R-CNN(main-partial transfer region-CNN)。

首先对绝缘子进行定位并裁剪绝缘子局部区域,再对绝缘子缺陷进行定位和检测。该网络使用迁移学习的训练方式,提升模型性能的同时节省了开发时间。本文的主要贡献在于使用 MPT R-CNN 模型对绝缘子缺陷进行检测,使得复杂的绝缘子图像背景对缺陷检测的干扰得到有效的

减少,从而充分挖掘缺陷的细节特征,实现了检测精度上的提升。

1 相关技术和理论

当前基于深度学习的目标检测算法分为两大类,一种是基于回归直接进行分类以及调整候选框的 One-Stage 方法,主要包括 SSD^[11]、YOLO^[13]系列的算法;另一种是通过专门模块去生成候选框,再基于候选框进行进一步分类以及调整边界框的 Two-Stage 方法,主要包括使用 RCNN^[14]、Fast RCNN^[15]、Faster R-CNN^[16]等。其中,One-Stage 方法拥有更高的检测速率,而 Two-Stage 方法则有更高的准确率与精确度。同时,黄文琦等^[17]对比在有限的绝缘子数据集上,两个卷积神经网络的检测效果,实验表明 Faster R-CNN 网络拥有较高的平均精度,而 R-FCN 网络的测试效果不佳。而在样本数量有限的前提下,这两种模型受到的影响比其他网络低得多。

在深度学习的模型训练过程中,数据的收集过程是需要成本的,因此常常会遇到标注数据量少、样本数目无法满足平台的训练要求的问题,导致很难训练出适配度高、泛化能力强的权重,迁移学习可以很好的解决这种问题。迁移问题中涉及到知识的迁移,学习的主体可以分为有经验的源域和无经验的目标域,其中包括了数据和这些数据对应的概率分布。按照学习方法的不同,迁移学习又被分为基于样本、特征、模型和关系的迁移。在本文中使用到的是基于样本的迁移,由于源域和目标域的样本集存在相似性,一些特征数据和信息是存在重合的,因此在一个数据集中习得的知识可以应用在另外一个任务当中。

卷积神经网络通过不断的卷积池化操作进行特征提取,然而在逐层抽取特征的过程中会丢失一些较小的目标信息,导致检测的精度有所下降。为了解决上述问题并获取表达能力更强的特征图,HE^[15]提出了特征金字塔网络(feature pyramid networks,FPN),该网络可以将的高层特征以自上而下的方式与低层特征进行加法合并操作,得到包含丰富语义信息的特征图,使得神经网络可以更好地适应与不同尺寸的目标。

2 融合迁移学习和主体局部的绝缘子缺陷分级检测模型

由于绝缘子的自爆、破损缺陷,具有目标小、特征提取难度大等问题。同时,在检测的过程中,现有的目标检测模型会受到图像背景复杂、样本数据量小的干扰。针对上述问题,本文以 Faster R-CNN 算法作为基础模型,提出了融合迁移学习和主体局部部分级检测模型 MPT R-CNN(main-partial transfer region-CNN),结构如图 1 所示。第一级,在样本数量充足的公开无缺陷绝缘子数据集上训练一个 Faster R-CNN 网络;再将训练完成的网络模型迁移到样本数量较少的绝缘子缺陷图像上,对绝缘子进行定位并裁剪

出绝缘子区域;第二级,以绝缘子局部图像为输入,使用 Faster R-CNN 模型进行训练,实现了绝缘子缺陷的分类和定位。在本文提出的模型中,通过迁移学习的方式实现了

绝缘子主体的定位,使得缺陷检测的干扰得到有效的减少,从而改善了缺陷区域的提取过程,实现了检测精度上的提升。

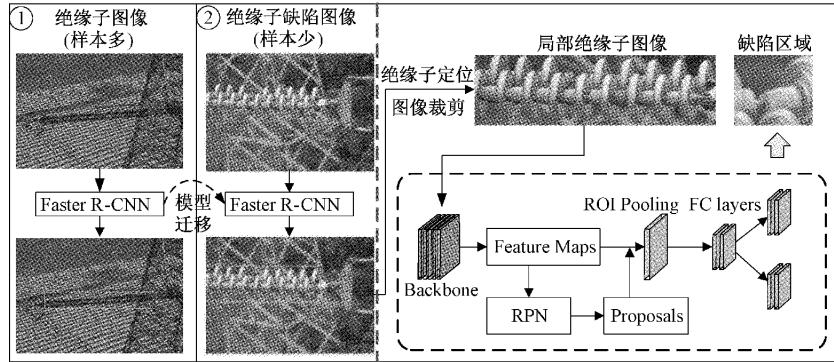


图 1 绝缘子缺陷检测网络

2.1 骨干网络

由于绝缘子缺陷图像背景复杂,且缺陷目标较小,这样使得绝缘子缺陷特征难以被有效的提取出来。如果强行增加网络层数会导致梯度爆炸和梯度消失的问题。因此,本文采用引入融合残差模块和特征金字塔结构的卷积神经网络作为目标检测模型的骨干网络,如图 2 所示。这种骨干网络能够更好的融合不同尺度的特征图,充分利用各个阶段的特征,对于检测比较小的缺陷区域,有更好的检测性能。

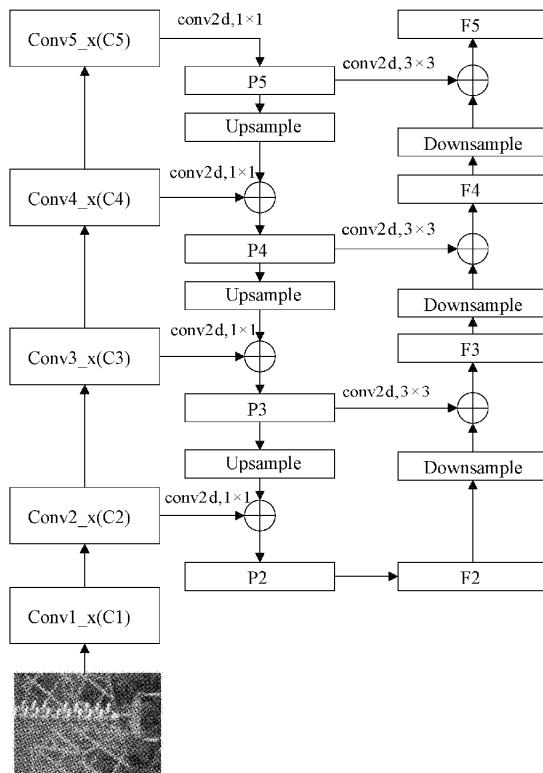


图 2 骨干网络结构

骨干网络结构主要包含以下 3 个步骤:

1)最左侧线性特征提取过程。图片被送入到最左侧的线性特征提取结构中,通过卷积操作得到不同尺度的特征图 $[C_2, C_3, C_4, C_5]$;

2)上采样过程。将所得到的不同尺度的特征图 $[C_2, C_3, C_4, C_5]$ 通过 1×1 的卷积核后,采用一种自上而下的上采样过程,使得这些特征图之间进行了不同尺度的交互,从而获得了更大的感受野,挖掘出更多的细节信息。更新后的新特征图为 $[P_2, P_3, P_4, P_5]$;

3)下采样过程。将得到最大尺度的特征图 P_5 ,通过 3×3 的卷积核后进行下采样操作,然后与上采样过所得到的不同尺度的特征图依次进行融合后下采样操作得到了用于不同尺度预测的特征图 $[F_2, F_3, F_4, F_5]$ 。这样的下采样过程很好的提升了骨干网络的鲁棒性,实现了对浅层细节信息和深层语义信息的挖掘。

2.2 绝缘子主体检测过程

由于绝缘子缺陷样本少,使得以数据驱动的目标检测模型难以发挥较好的性能。为此本文提出一种迁移学习策略。具体而言,采用源域(source domain)无缺绝缘子图像数据集 A 训练模型并迁移至目标域(target domain)有缺绝缘子数据集 B 上,优先实现对含有缺陷绝缘子的定位。其中 $A \cap B = \emptyset$ 。如图 3 所示。这样的一个策略所存在的问题是源域与目标域的数据分布存在偏移状态。但由于绝缘子目标相对于缺陷区域较大,占据了图像的主要部分,且两个数据集 A 和 B 中均为复杂背景下的绝缘子图像,导致这一问题对绝缘子的定位过程影响较小。因此可以直接 A 学习系统迁移到 B 学习系统进行训练。

2.3 局部缺陷区域检测过程

在完成对绝缘子主体的检测任务后,可以得到具体的绝缘子检测参数 $(x_B, y_B, w_B, h_B, g_B)$ 。其中 (x_B, y_B, w_B, h_B) 为绝缘子结果预测框的坐标信息, g_B 为标签信息。根据预测框的坐标信息对绝缘子数据集 B 中的原始

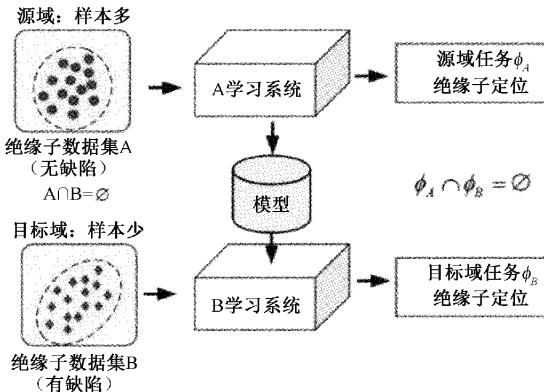


图 3 跨域迁移学习过程

图像进行裁剪,得到绝缘子缺陷局部数据集 B_i 。然后,本文对绝缘子缺陷局部数据集 B_i 进行缺陷标注,并进行数据扩增(旋转、平移等数据扩充手段)。将扩充后的数据送入 Faster R-CNN 网络中进行绝缘子局部缺陷检测任务。本文算法在第二阶段局部检测中能够有效改善由于复杂背景所带来信噪比过大对缺陷区域检测的不良影响,并且有效弥补了由于缺陷样本数据量小所带来的模型性能下降的问题。本文具体算法如下:

本文算法:融合迁移学习和主体局部的目标检测算法

输入:绝缘子图像(无缺陷) $A_i \in A$, 绝缘子缺陷图像 $B_i \in B$

输出:绝缘子缺陷图像 B_i 的缺陷检测结果 (x, y, w, h, g_c)

第一阶段:绝缘子主体检测

1) 将无缺绝缘子图像 A_i 送入 Faster R-CNN 网络中进行训练,获取绝缘子主体检测精度最高时的 Faster R-CNN 模型 Φ_{max} ;

2) 将模型 Φ_{max} 迁移至绝缘子缺陷图像 B_i 的训练过程中,用于获取 B_i 中所包含的绝缘子检测参数 $(x_B, y_B, w_B, h_B, g_B)$;

第二阶段:绝缘子局部缺陷检测

3) 根据绝缘子结果预测框的坐标信息 (x_B, y_B, w_B, h_B) 对绝缘子缺陷图像 B_i 进行自动裁剪得到绝缘子缺陷局部图像 b_i ;

4) 将图像 b_i 进行数据扩充后,送入 Faster R-CNN 网络中进行训练,最终检测到绝缘子缺陷区域 $c_i = (x_c, y_c, w_c, h_c, g_c)$;

5) 根据 c_i 中预测框的坐标信息 (x_c, y_c, w_c, h_c) 以及绝缘子预测框的坐标信息 (x_B, y_B, w_B, h_B) ,计算出最终的绝缘子缺陷图像 B_i 的缺陷区域预测坐标信息 (x, y, w, h) 。

3 实验测试与结果分析

3.1 实验设备及参数设置

本实验 GPU 使用的是 NVIDIA GeForce GTX 1080Ti。模型搭建环境为 Pytorch1.7.1、torchvision0.8.2、CUDA10.1。学习率(lr)设置为 0.005,设置梯度下降过程的单次训练网络处理样本个数(Batch_size)为 2,动量因子(momentum)为 0.9,权重下降系数(weight_decay)为 0.00005。整个实验中,各个环节的网络均为训练 Epoch 为 70。

3.2 数据集介绍

本文所使用的数据集,主要包括来自于公开的绝缘子数据集 Insulator Data Set-Chinese Power Line Insulator Dataset (CPLID)^[18],其中公开数据集 CPLID 包括 600 张正常绝缘子。除此之外,本文收集标注的绝缘子缺陷图像 350 张。两个数据集均为 PASCAL VOC 格式。绝缘子图像的标签类别为 Insulator,绝缘子缺陷图像的标签类别为 damaged、missing。图 4、5 分别为 CPLID 数据集中的部分图像以及绝缘子缺陷数据集中的部分图像。

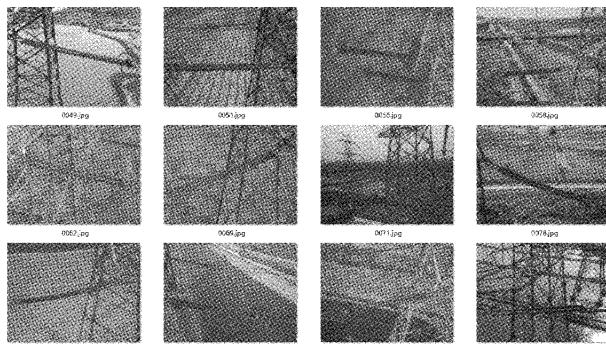


图 4 CPLID 数据集示例

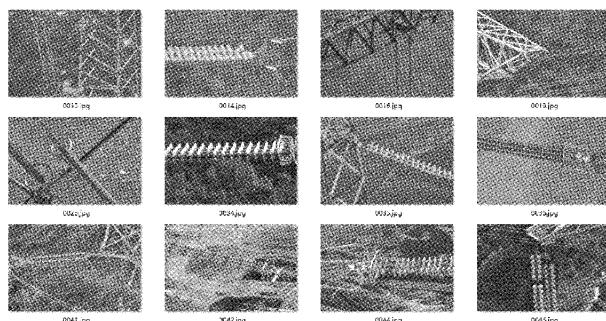


图 5 绝缘子缺陷数据集示例

3.3 评价指标

在目标检测领域对模型的检测性能评价有着特定的指标。为了衡量算法性能,本文采用平均精度(Average Precision, AP)与平均类别精度(mean Average Precision, mAP)作为本文算法评估标准。其中 AP 又细分为 $AP^{50:95}$ 、 AP^{50} 、 AP^{75} , 分别表示 IoU 阈值在 50~95%、50% 以

上、75 以上的 AP 值。具体计算公式如下所示:

平均精度(AP)是衡量模型算法在每个类别上的好坏,计算公式为:

$$AP = \int_0^1 p(r)dr \quad (1)$$

所有类别平均精度(mAP)由平均精度(AP)求和取平均得到,计算公式为:

$$mAP = \frac{\sum_{k=0}^c AP_k}{C} \quad (2)$$

式中: $\sum_{k=0}^c AP_k$ 是每一个类别的平均精度,C 是总类别数。

3.4 实验结果与分析

1) 不同主干网络下检测结果比较

本文以 Faster R-CNN 为基础网络,分别使用 VGG16、ResNet50、EfficientNetB0、ResNet50+FPN 为特征提取骨干网络(Backbone)对绝缘子缺陷数据集进行训练,性能对比如表 1 所示。其中训练集与测试集比例为 3:1。特别的,图 6 展示了不同主干网络下,三类目标的检测结果。从表 1 和图 6 可以看出使用 ResNet50+FPN 的 Faster R-CNN 模型在检测精度上有明显的优势。在其余特征提取网络下,对 3 种目标类型的检测效果均较差,无法达到本文中的精度要求。

表 1 不同骨干网络的检测性能对比 %

主干网络	AP ^{50,95}	AP ⁵⁰	AP ⁷⁵
VGG16	2.8	7.5	1.2
ResNet50	1.0	3.7	0.1
EfficientNetB0	4.0	11.0	2.3
ResNet50+FPN	23.7	52.1	22.0

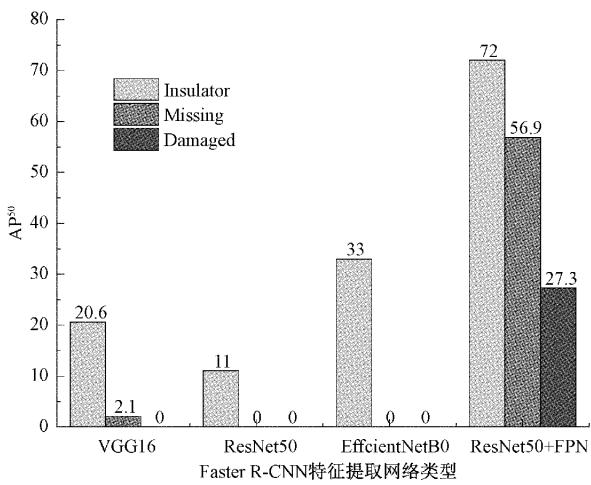


图 6 不同骨干网络下 Faster R-CNN 的缺陷检测结果

为了定性分析不同骨干网络的检测效果,本文选取了同一张测试集的照片进行算法检测效果展示,如图 7 所示。其中图 7(a)、(b) 分别为使用 VGG16、ResNet50 为特征提取网络的检测效果,图片中的绝缘子没有被检测成

功;图 7(c) 对应为使用 EfficientNetB0 的检测效果,对应检测结果为 75% insulator,其生成的目标建议框位置偏差较大;图 7(d) 中为使用 ResNet50+FPN 为特征提取网络的检测效果,可以看出此时绝缘子的位置能够被较为准确的检测出来,检测的结果为: 98% insulator; 精度高于使用其他特征提取网络的模型。

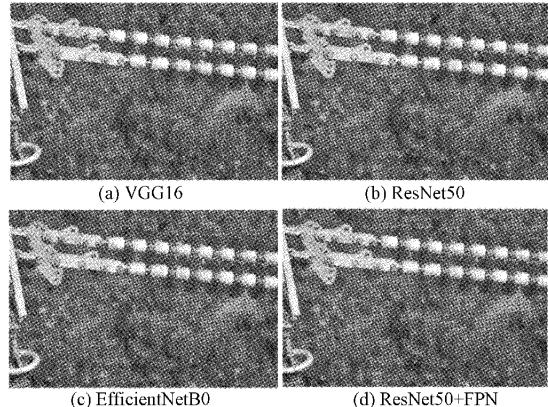


图 7 不同骨干网络的绝缘子检测结果

2) 本文模型训练结果

本文所提出的模型训练包括两个阶段,第一阶段为绝缘子主体检测阶段。为了在这一阶段得到理想的绝缘子检测结果,本文使用 CPLID 无缺陷数据集进行迁移学习训练,设定 epoch=70,训练权重得到的 mAP 图像、损失及学习率图像如图 8 所示。

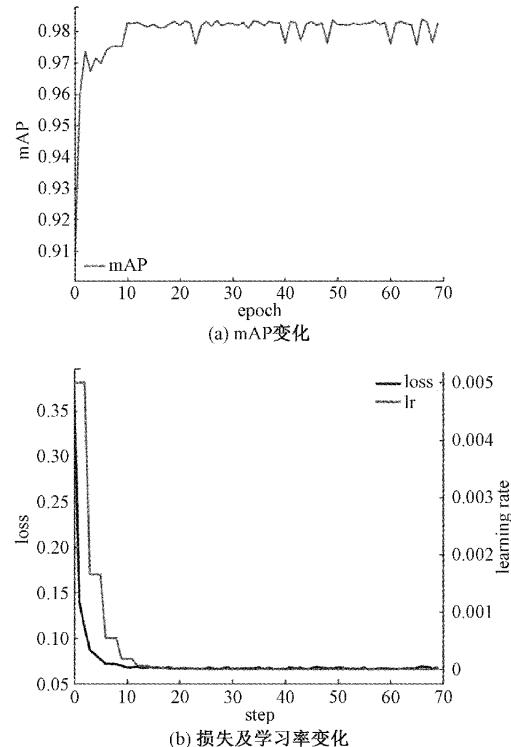


图 8 主体第一阶段训练中的 mAP、损失及学习率变化

第二阶段为绝缘子裁剪过程以及局部绝缘子缺陷检测过程。本文使用第一阶段所得到的最优权重对 300 张含缺陷的绝缘子图像进行测试, 得到绝缘子的检测结果, 并依据该结果进行自动裁剪。将得到裁剪后得到含有缺陷的绝缘子图像进行标注和数据增强, 得到用于第二阶段的训练数据集。这个数据集包括训练集 500 张、测试集 160 张, 如图 9 所示, 训练周期 epoch=70, 训练权重过程中得到的 mAP 图像、损失及学习率图像如图 10 所示。

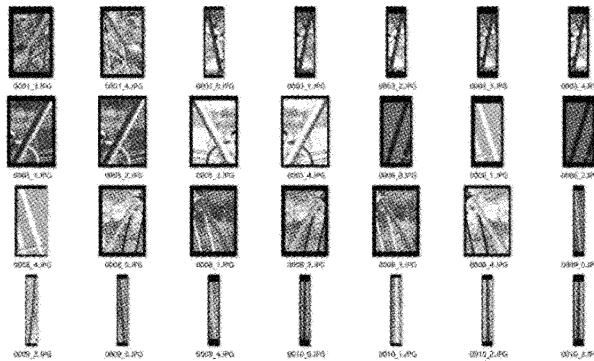


图 9 裁剪后的缺陷绝缘子图像

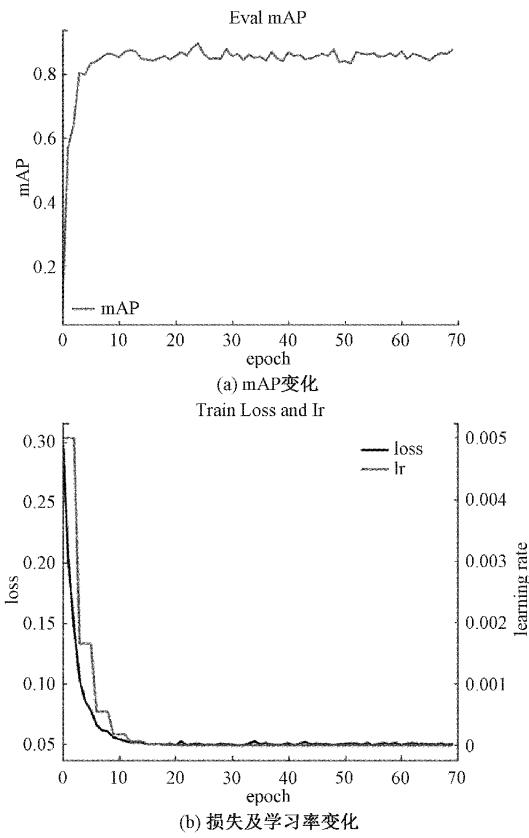


图 10 局部第二阶段训练中的 mAP、损失及学习率变化

3) 不同目标检测算法的检测结果对比

为了验证本文提出的 MPT R-CNN 目标检测模型的检测性能, 本文分别将其与 Faster R-CNN 模型、YOLOv3

模型、SSD、RetinaNet 模型对绝缘子缺陷检测的效果进行对比, 结果见表 2。除此之外, 本文还给出了在不同检测算法下不同目标的检测结果, 见图 11。

表 2 不同目标检测算法的检测结果 %

算法	AP ^{50,95}	AP ⁵⁰	AP ⁷⁵
YOLOv3	8.4	23.3	5.2
SSD	18.0	41.4	13.8
RetinaNet	10.3	23.9	7.0
Faster R-CNN	23.7	52.1	22
本文方法	60.3	89.6	77.7

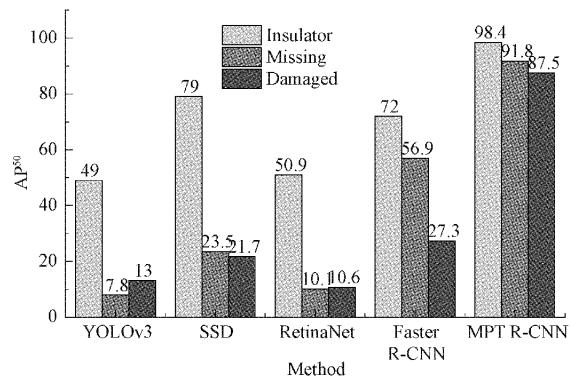


图 11 不同目标检测算法的缺陷检测结果

由表 2 可知, 在所有的基础模型中, Faster R-CNN 模型在检测精度上远远超过其余一阶段算法。在本文主要研究的两种缺陷类型上, Faster R-CNN 的基础模型即使在图像背景复杂、目标特征小的难题下, 相对一阶段的算法有较为理想的检测效果, 故作为本文提出模型 MPT R-CNN 的检测网络的基线模型存在合理之处。对比本文提出的 MPT R-CNN 目标检测模型与基础的 Faster R-CNN 模型检测效果, 由表 2 可以看出, MPT R-CNN 的检测效果均优于直接使用 Faster R-CNN 进行检测, 其中 AP⁵⁰ 提高了 37.5%。本文提出的模型平均准确率较 RetinaNet、SSD、YOLOv3 分别提高 65.7%、48.2%、66.3%。同时从图 11 可以看出, 本文模型对 Damaged 的 AP⁵⁰ 值提升幅度较大, 这是因为本文所提模型可以增强对小目标特征的捕获能力, 展现出较好的鲁棒性。

图 12 是不同算法检测结果的展示。其中图 12(a)为使用 YOLOv3 的检测效果, 绝缘子的检测结果为 11% insulator, 缺陷位置检测存在多个错误重叠框, 将绝缘子的头部结构错检测为自爆缺陷位置, 检测效果不理想; 图 12(b)为使用 SSD 的检测效果, 绝缘子检测效果为 50% insulator, 精度相对较低, 同时其检测出的缺陷位置错误; 图 12(c)对应为使用 RetinaNet 的检测效果, 对应检测结果为 72% insulator, 精度低于使用 Faster R-CNN 的效果, 未检测出缺陷位置。图 12(d)中为使用 Faster R-CNN 算法

的检测效果,绝缘子的位置被准确检测出,检测的结果为 98%insulator,但缺陷位置并未被成功检测出;图 12(e)和(f)中为使用本文所提模型进行检测的检测效果,可以看出第一阶段成功检测出 99%insulator,第二阶段准确定位出 95%missing,对缺陷的检测效果优于直接使用 Faster R-CNN 检测。

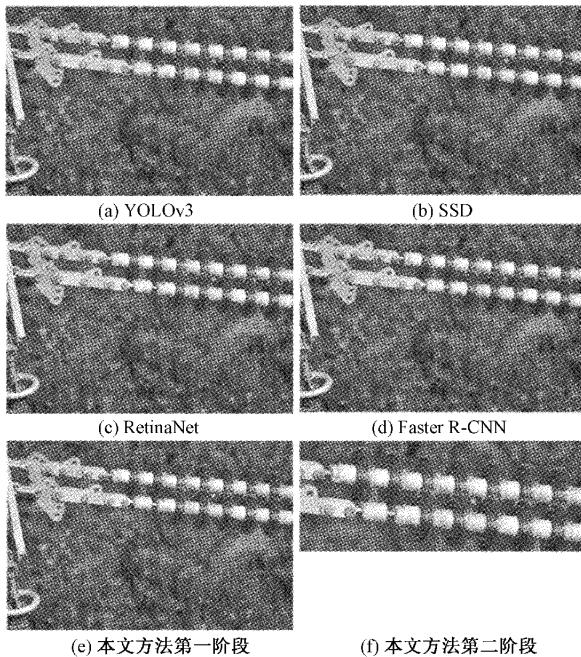


图 12 不同算法的缺陷检测结果展示

4) 消融实验

为了验证本文所提出模型的有效性,本文以基线模型为基础分别引入不同模块进行消融实验。在保持参数量相同的情况下,以 ResNet50+FPN 网络作为主干网络,在绝缘子缺陷数据集上进行缺陷识别消融实验,分析各个模块对实验结果的影响,其结果如表 3 所示。

表 3 消融实验结果

检测算法	AP ⁵⁰			mAP
	Insulator	Missing	Damaged	
基线模型	72.0	56.9	27.3	52.1
基线模型+两级检测	75.0	64.2	45.3	67.9
本文算法	98.4	91.8	87.5	89.6

由表 3 可知,本文算法在绝缘子缺陷数据集上的识别率为 89.6%。在 Faster R-CNN 的基线模型引入主体局部的两级检测的方法可以使平均准确率提高 15.8%,这说明该方法能够有效降低复杂背景对缺陷检测任务的干扰。相较于基线模型绝缘子缺失(Missing) AP⁵⁰ 提高了 7.3%,破损(damaged) AP⁵⁰ 提高了 18.0%。当同时引入迁移学习和两级检测可以使平均准确率提升 37.5%,这说明通过迁移学习能够加强对第一阶段绝缘子主体的检测

效果,绝缘子主体检测效果越好,则对于第二阶段缺陷区域的检测越能有效的提取缺陷区域特征信息。

4 结 论

本文提出了一种融合迁移学习与主体-局部的绝缘子缺陷检测方法。通过使用迁移学习方法,改善了对缺陷所在主体绝缘子的检测精度。通过使用先检测绝缘子后检测缺陷的主体-局部思想,进一步挖掘了缺陷区域的细节特征。经过实验对比,本文所提出的算法模型相较于传统的 Faster R-CNN 算法,在绝缘子缺陷数据集上平均检测精度提高了 37.5%,在自爆和破损缺陷上,检测精度分别提高了 34.9% 和 60.2%。证明了本文算法对自爆和破损缺陷检测的有效性。

参 考 文 献

- [1] ZHAI Y, WANG D, ZHANG M, et al. Fault detection of insulator based on saliency and adaptive morphology[J]. Multimedia Tools and Applications, 2017, 76(9): 12051-12064.
- [2] LI X, SU H, LIU G. Insulator defect recognition based on global detection and local segmentation[J]. IEEE Access, 2020, 8: 59934-59946.
- [3] BRUMRY D. Artificial intelligence: a modern approach [J]. Telecommunication Journal of Australia, 2014, 54(1):63-64.
- [4] ZHAO ZH B, LIU N. The recognition and localization of insulators adopting SURFand IFS based on correlation coefficient [J]. Optik-International Journal for Light and Electron Optics, 2014, 125(20): 6049-6052.
- [5] ZHAO ZH B, LIU N, WANG L. Localization of multiple insulators by orientation angle detection and binary shape prior knowledge[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(6): 3421-3428.
- [6] ZHAI Y J, WANG D, ZHANG M L, et al. Fault detection of insulator based on saliency and adaptive morphology[J]. Multimedia Tools and Applications, 2016, 76(9):1-14.
- [7] CHENG H, ZHAI Y, CHEN R, et al. Self-shattering defect detection of glass insulators based on spatial features[J]. Energies, 2019, 12(3):543.
- [8] TAO X, ZHANG D, WANG Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4):1486-1498.
- [9] LI X, H SU, LIU G. Insulator defect recognition

- based on global detection and local segmentation[J]. IEEE Access, 2020, PP(99):1-1.
- [10] 潘哲,张兴忠,杨罡,等.弱监督细粒度分类在绝缘子故障识别中的应用[J].山西大学学报(自然科学版),2020,43(3):490-498.
- [11] 杜丽群.基于 SSD 的绝缘子图像检测技术研究[D].保定:华北电力大学,2019.
- [12] 刘业鹏.基于深度学习的输电线路目标检测方法研究[D].保定:华北电力大学,2019.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [14] ZHU L, XIE Z, LIU L, et al. IoU-uniform R-CNN: Breaking through the limitations of RPN[J]. Pattern Recognition, 2021, 112: 107816.
- [15] 张琦,胡广地,李雨生,等.改进 Fast-RCNN 的双目视觉车辆检测方法[J].应用光学,2018,39(6):832-838.
- [16] GONG J, HUANG H. Static vehicle detection based on improved faster RCNN [J]. International Core Journal of Engineering, 2021, 7(3): 306-312.
- [17] 黄文琦,张福铮,李鹏,等.基于 Faster R-CNN 的绝缘子识别探索和应用[J].南方电网技术,2018,12(9):22-27.
- [18] TAO X, ZHANG D, WANG Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 50(4): 1486-1498.

作者简介

- 翟永杰,教授,主要研究方向为计算机视觉与模式识别。
E-mail: zhaiyongjie@ncepu.edu.cn
- 胡哲东(通信作者),硕士研究生,主要研究方向为计算机视觉与深度学习。
E-mail: caughyhzd@ncepu.edu.cn