

基于对抗自学习的跨域绝缘子检测算法

李凡^{1,2}, 高瞻^{1,2}, 王红斌^{1,2}, 李爽^{1,2}, 庞健^{1,2}, 徐开雄^{1,2}, 余正涛^{1,2}

(昆明理工大学 1.信息工程与自动化学院; 2.云南省人工智能重点实验室, 云南 昆明 650500)

摘要:为实现在海量线路巡检图像中对绝缘子的自动识别,提出一种基于对抗自学习的跨域绝缘子识别方法。该方法由对抗学习和自训练学习2个阶段组成。在对抗学习阶段,通过特征提取器和分类器之间的对抗学习,使模型分别获得对玻璃绝缘子和复合绝缘子具有鲁棒性的分类特征。在自训练学习阶段,首先,采用有标签的玻璃绝缘子样本对模型进行预训练;然后,将无标签的复合绝缘子样本输入网络,并选择置信度高的样本赋予软标签对模型进行再次训练,使模型最终获得在不同域上的泛化能力。与现有方法相比,该文方法采用分属不同材质的绝缘子样本对神经网络进行2个阶段的训练,在有效降低模型训练过程中样本标注量的同时,解决了跨域识别不同材质的绝缘子的问题。

关键词:对抗学习; 绝缘子; 线路巡检; 图像; 自训练学习; 特征提取器; 玻璃绝缘子; 复合绝缘子
中图分类号: TP391.1 文章编号: 1005-9830(2020)06-0651-09

DOI: 10.14177/j.cnki.32-1397n.2020.44.06.003

Cross-domain insulator detection algorithm based on adversarial self-learning

Li Fan^{1,2}, Gao Zhan^{1,2}, Wang Hongbin^{1,2}, Li Shuang^{1,2},
Pang Jian^{1,2}, Xu Kaixiong^{1,2}, Yu Zhengtao^{1,2}

(1.Faculty of Information Engineering and Automation; 2.Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: In order to realize the automatic recognition of insulators in inspection images of massive lines, a cross-domain insulator recognition method based on adversarial self-learning is proposed. The method consists of adversarial learning and self-training learning two stages. In the adversarial learn-

收稿日期: 2020-08-17 修回日期: 2020-10-12

基金项目: 国家重点研发计划(2018YFC0830105; 2018YFC0830100); 云南电网公司科技项目(YNKJXM20190729)

作者简介: 李凡(1986-),男,博士,讲师,硕士生导师,主要研究方向: 图像处理及图像识别, E-mail: 478263823@qq.com; 通讯作者: 王红斌(1983-),男,博士,副教授,硕士生导师,主要研究方向: 自然语言处理、机器学习, E-mail: whbin2007@126.com。

引文格式: 李凡,高瞻,王红斌,等. 基于对抗自学习的跨域绝缘子检测算法[J]. 南京理工大学学报, 2020, 44(6): 651-659.

投稿网址: <http://zrxuebao.njust.edu.cn>

ing stage ,through adversarial learning between the feature extractor and the classifier ,the model obtains robust classification features of glass insulators and composite insulators. In the self-training learning stage ,firstly ,the model is pre-trained with labeled glass insulator samples; then ,the unlabeled composite insulator samples are input into the pre-trained model ,and the sample with high confidence is selected to give the soft label to retrain the model ,so that the model obtains generalization ability in different domains. Compared with the existing methods ,the proposed method uses insulator samples of different materials to train the deep neural network in two stages ,which effectively reduces the amount of sample annotations in the model training phase and solves the problem of cross-domain identification of different materials.

Key words: adversarial learning; insulators; lines inspection; images; self-training learning; feature extractor; glass insulators; composite insulators

绝缘子是输电线路中一种用于固定导体的特殊绝缘控件,在架空输电线路中起着非常重要的作用。长期暴露于自然环境中的绝缘子受到冰霜雨雪、污秽、雷击等因素影响,容易发生自爆、掉片、破损、裂纹等故障^[1-3],从而引发输电线路安全隐患、供电中断等危害国民生产、生活的严重问题。因此,在输电线路日常维护工作中,常常需要对巡检采集的大量数字图像进行人工复核,快速发现绝缘子对象及判断存在的故障。这是一项费时费力的工作,而且对工作人员的专业水平和工作效率要求较高。

近年来,随着深度学习技术在目标检测领域的深入应用,利用目标检测技术代替人工筛查,从庞大的巡检图像数据中对绝缘子进行快速自动检测,已成为解决该问题的有效方法之一。目前一些基于深度学习的目标检测算法^[4-9]采用卷积神经网络^[10,11]在检测准确性及效率上都得到了提升。如:Redmon 等^[4]提出的 YOLO 目标检测算法通过将输入图像划分成若干网格,对每个网格分别进行坐标回归和类别回归,有效提升了在数据缺乏情况下模型的泛化能力。2018 年,Redmon 等^[12]对原有的 YOLO 算法进行了改进,提出了 YOLOv3 目标检测算法,通过添加多尺度预测机制将聚类后得到的锚点分配给不同尺度的检测框,有效降低了误检率,提高了对同类且不同尺寸物体检测的泛化能力。然而,常见的绝缘子包括玻璃绝缘子和复合绝缘子 2 类。2 类不同材质的绝缘子在外观上差别较大。若将该类模型应用于跨域绝缘子检测任务,会因为缺乏不同类型的绝缘子标注信息,导致模型无法提取 2 类绝缘子共同的鉴别性特征,从而影响最终的识别准确性。

在减少样本标注的情况下,为使模型能够对属于不同域但同为一类的物体提取到具有一致性的特征,无监督域自适应算法^[13,14]近年来受到了广泛研究。其中,Caron 等^[15]利用神经网络对目标域无标签样本进行聚类并赋予伪标签,然后最小化带有伪标签的目标样本和辅助样本之间数据分布的库尔贝克-莱布勒(KL)散度,建立了目标域无标签样本之间的内在结构和联系。为解决跨域检测时性能低下的问题,一些方法^[16-18]将目标检测框架与无监督域自适应算法联系起来,旨在解决检测来自不同域的同一种物体时识别率低下的问题。其中,Kim 等^[18]设计了一种多通道压缩和激励适配器,在更快速的区域卷积神经网络(Faster region-convolution neural network, Faster R-CNN)模型的基础上加入多个适配器,使得模型能够适应多种域自适应目标检测任务。此外,受到生成对抗网络(Generative adversarial networks, GAN)^[19,20]的启发,Goodfellow 等^[19]将通过 Faster R-CNN 的源域和目标域样本特征输入域鉴别器中进行对抗训练,试图提取域不变特征信息并加入局部特征分类器,来对齐局部特征分布以提高特征的鲁棒性。陈耀等^[20]为解决生成对抗网络(Generative adversarial networks, GAN)的训练难点问题,在 Wasserstein GAN(WGAN)方法基础上提出了迭代化代价函数及超参数可变的生成对抗网络,使生成器的拟合速度有了显著提高。然而,这些方法在由鉴别器主导的对抗训练中,会丢失源域样本和目标域样本的共有特征,且存在计算量较大、运算成本较高的问题。不同类型的绝缘子的主要差别在于颜色、尺寸、材质不同,这些差别会导致这 2 种绝缘子之间的数据分布不一致。同

时,由于输电线路图像背景复杂,类似绝缘子的物体繁多,如果直接在 YOLOv3 上训练,会因绝缘子数据分布差异过大造成误检率过高。因此要统一复合绝缘子和玻璃绝缘子的数据分布,减小其他异物的影响,提取玻璃绝缘子和复合绝缘子一致的特征。而现有域自适应算法适用于物体类别多、数据分布广泛的数据集,如果将其直接应用到不同类型的绝缘子检测上,会产生将类似绝缘子的物体误识别为绝缘子的问题。

为解决绝缘子跨域检测的问题,本文提出了一种基于对抗自学习的跨域绝缘子检测算法,该算法由自监督学习和对抗学习 2 部分组成。在自监督学习中,通过由概率值筛选得到的赋予伪标签的目标样本重新优化特征提取网络,弥补了目标检测算法在无标签条件下具有弱检测能力的缺陷,使得在无监督的条件下对其他类型绝缘子能进行正确识别。在对抗学习中,利用赋予了伪标签的目标样本和源域样本,通过特征提取器和分类器之间的对抗训练,使得模型能够提取对于不同类型绝缘子具有鲁棒性的特征,从而实现在复杂输电线路图像中正确检测不同类型的绝缘子的目的。该方法经实验证明具有以下优点:标注的工作量小,对不同类型绝缘子具有鲁棒性,网络易训练,计算成本低且识别率较高。

1 算法流程

本文中,源域表示为 $\{X_s, Y_s\}$, 其中 $X_s = \{x_i^s\}_{i=1}^{N_s}$, $Y_s = \{y_i^s\}_{i=1}^{N_s}$ 分别表示绝缘子图片及其对应标签,源域共有 N_s 张绝缘子图片,每张图片 x_i^s 对应 1 个标签 y_i^s 。此外还提供了 1 个没有标签的目标域 $\{X_t\}$, 包含 N_t 张绝缘子图片。对于每一张绝缘子图片 x_k , 含有 n 个绝缘子, $n=0$ 时表示这张图上没有绝缘子。常见的绝缘子包括玻璃绝缘子和复合绝缘子 2 类,如图 1 所示。

为实现绝缘子的跨域识别,本文提出了基于对抗自学习的跨域绝缘子识别算法。算法流程如图 2 所示。提出的网络以 YOLOv3 为基础,运用对抗学习和自训练的思想,使其具备一定的域自适应能力。总体框架分为 3 阶段:

- (1) 采用源域数据训练 1 个 YOLOv3 目标检测基础网络;
- (2) 固定训练好的基础网络,直接迁移到目

标域,按照置信度得分对目标域的测试结果挑选自训练样本并赋予软标签;

- (3) 用第 2 阶段的挑选结果和源域一起训练,更新模型参数,特别地,设计了 1 个分类器,使分类器与特征提取器 (Darknet-53) 进行对抗学习,让特征提取器能够提取绝缘子域不变的特征。



(a)复合绝缘子



(b)玻璃绝缘子

图 1 不同材质的绝缘子

1.1 预训练网络阶段

基础网络如图 2 第 1 阶段所示,可总结为 2 个模块:特征提取模块 (Darknet-53) 和检测模块 (YOLO detection)。使用有标签的源域训练基础网络,目标是使特征提取模块 Darknet-53 能很好地提取到玻璃绝缘子的特征,并且检测模块 YOLO detection 能够正确预测出绝缘子类别和位置信息。因为是在有监督的方式下训练的,所以特征提取模块能够提取源域绝缘子的特征,检测模块能够做到正确分类。预训练损失函数如下

$$L_{\text{YOLOv3}} = L_{\text{xy}} + L_{\text{wh}} + L_c + L_{\text{class}} \quad (1)$$

式中: L_{YOLOv3} 为 YOLOv3 的原损失函数; L_{xy} 是通过交叉熵计算的中心损失; L_{wh} 是通过均方差函数计算的检测框的尺寸损失; L_c 是通过交叉熵计算的置信度损失; L_{class} 是通过交叉熵函数计算的类别损失。

如果直接把模型应用到目标域绝缘子的识别任务上,由于源域和目标域差异显著,性能会明显下降。为了解决这个问题,提出了基于对抗自学习的跨域绝缘子识别算法。

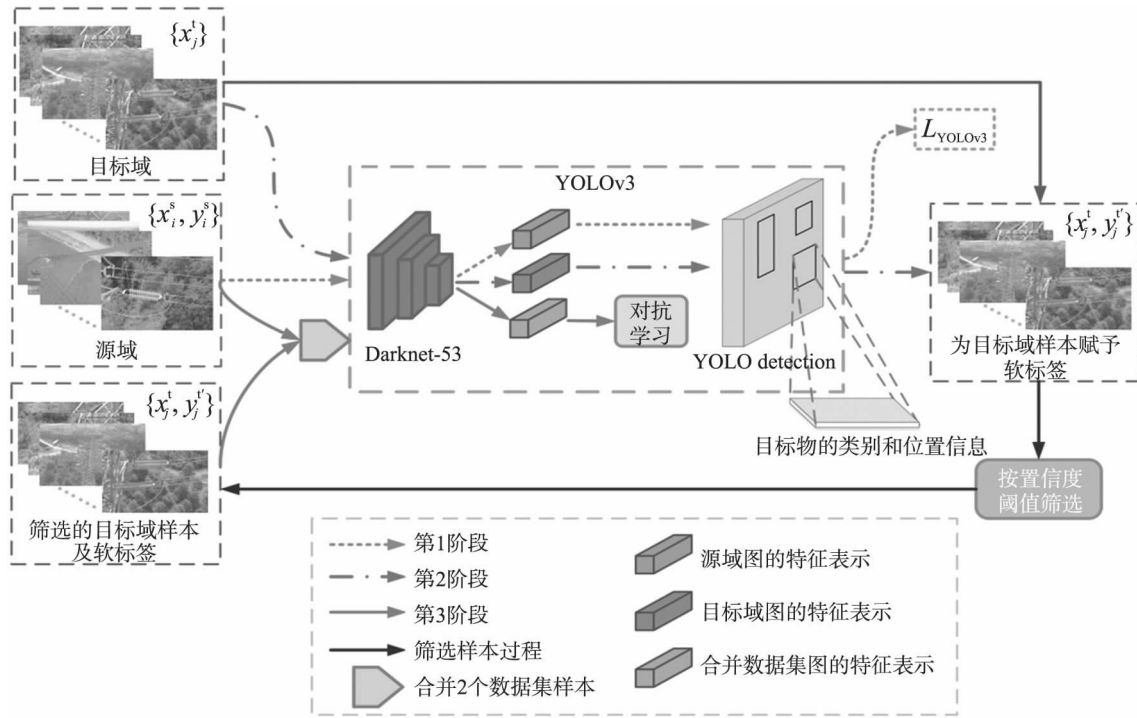


图 2 总体网络框架

1.2 软标签生成阶段

自训练前,将目标域输入训练好的基础网络做测试,测试结果显示预训练模型能够识别部分目标域绝缘子,把预测结果作为目标域绝缘子的软标签,记为 $Y_T = \{y_j^t\}_{j=1}^{N_T}$ 。预测的软标签与真实标签越接近,自训练的性能越好。然而,并不是将所有预测结果都作为自训练的软标签,按照以下 2 个方面对软标签进行挑选:

(1) 预测框面积 S 。由于拍摄距离、视角的影响,图片上绝缘子的大小、形状、位置各不相同,检测时生成的预测框大小也各不相同,如图 3 所示,太小的检测框内的对象可能不是绝缘子。如果挑选了面积过小的预测框,对提升网络性能没有作用。因此,模型设置丢弃预测框面积小于图像面积 1% 的预测结果,不将其作为软标签。




图 3 挑选预测框

(2) 置信度 α 。在检测过程中,分类器会预测每一个预测框分类正确的概率,即置信度。置信

度的范围是 $[0, 1]$,为选择更有效的软标签,将丢弃置信度小于 α 的预测结果,不将其作为软标签。

1.3 自训练网络阶段

图 2 第 3 阶段为自训练阶段。软标签不等同于真实标签,具有不准确性。不准确的软标签会对模型进行错误引导,为了提高模型的泛化能力和准确性,自训练使用软标签的同时,把源域绝缘子及真实标签也加入训练。

自训练 1 轮后,Darknet-53 的权重参数得到更新。之后重复 1.2 节的操作,并继续自训练,直至训练 M 次。第 3 阶段训练分为源域绝缘子的真实标签训练和目标域绝缘子的软标签训练,训练好的 Darknet-53 能够同时检测到源域和目标域绝缘子。模型训练过程如算法 1 所述。

算法 1 基于对抗自学习的跨域绝缘子识别算法训练过程

Input: 有标签的源域和无标签的目标域绝缘子数据;

Output: 1 个训练好的跨域绝缘子检测模型;

Optimizing:

For $i=1$ to $epoch$ do:

源域数据预训练基础网络,执行式(1);

end for

for $j=1$ to M do:

基础网络测试目标域,产生软标签;

按置信度挑选软标签并保存;

For $k=1$ to $4^* epoch$ do:

带真实标签的源域样本同挑选的带软标签的目标域样本进行自训练;

固定 G , 用式 (2)、(3) 更新 D ;

固定 D , 用式 (4)、(5) 更新 G ;

end for

end for

注: $epoch$ 为训练模型的迭代次数, M 为自训练次数。

1.4 对抗训练

受 GAN^[19, 20] 的启发, 设计 1 个域分类器与特征提取器进行对抗训练来提升模型的域自适应能力。不同于传统的 GAN 方法, 不需要额外生成图像和添加其他辅助网络。如图 4 所示, 对抗学习网络由自训练阶段的特征提取器 Darknet-53 (命名为 G) 和 1 个分类器 D 组成。分类器的输出结果是 1 个三维向量, 用于表示输入图像为源域图像、目标域图像和公共域图像的概率。

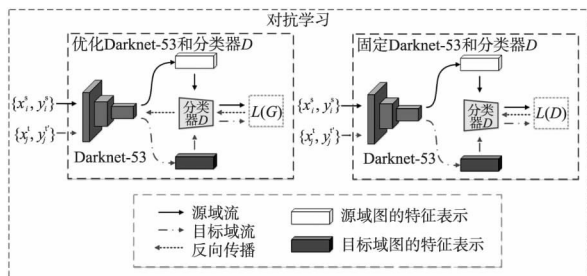


图 4 对抗学习网络

训练时, 将源域图像特征和目标域图像特征输入分类器 D , 训练分类器能够区分源域和目标域的公式如下

$$L_S(D) = E_{(x_i^S \sim X_S)} \sum_{i=1}^{N_S} -q_S \log(\text{softmax}(D(G(x_i^S)))) \quad (2)$$

$$L_T(D) = E_{(x_i^T \sim X_T)} \sum_{i=1}^{N_T} -q_T \log(\text{softmax}(D(G(x_i^T)))) \quad (3)$$

式中: x_i^S 和 x_i^T 分别表示源域样本和目标域样本。 N_S 和 N_T 表示 1 个批次的源域样本和目标域样本的数量。 $q_S = [1 \ 0 \ 0]$, $q_T = [0 \ 1 \ 0]$, 表示 one-hot 向量, 希望把源域样本分类到域鉴别器 D 的第 1 个神经元, 把目标域样本分类到域鉴别器 D 的第 2 个神经元。

根据对抗训练的思想, 训练特征提取器提取到的特征, 迫使分类器不能正确地区分来自源域还是目标域, 目的是提取源域和目标域的共有特征, 并将该特征分到其他类。如下

$$L_S(G) = E_{(x_i^S \sim X_S)} \sum_{i=1}^{N_S} -q_{\text{other}} \log(\text{softmax}(D(G(x_i^S)))) \quad (4)$$

$$L_T(G) = E_{(x_i^T \sim X_T)} \sum_{i=1}^{N_T} -q_{\text{other}} \log(\text{softmax}(D(G(x_i^T)))) \quad (5)$$

式中: $q_{\text{other}} = [0 \ 0 \ 1]$ 表示 one-hot 向量, 希望把混淆的源域样本和目标域样本分到鉴别器的第 3 个神经元。

为了使特征提取器能够提取到域不变的特征, 有

$$L_{\text{adaptation}}(G, D) = L_S(D) + L_T(D) + L_S(G) + L_T(G)$$

$$L(D) = L_S(D) + L_T(D)$$

$$L(G) = L_S(G) + L_T(G) \quad (6)$$

式中: $L(G)$ 负责训练特征提取器提取域不变的特征, $L(D)$ 负责训练分类器, 提高分类器的域鉴别能力。 $L(G)$ 和 $L(D)$ 交替训练。总的训练过程如算法 1 所示。

目标函数如下

$$L_{\text{total}} = L_{\text{YOLOv3}} + L_{\text{adaptation}}(G, D) \quad (7)$$

2 实验与结果

2.1 数据准备

本文采用的输电线路图像数据集共有 4 113 张图片, 全都是现实场景下采集的。由无人机或相机拍摄, 包括不同尺度、季节、背景、遮挡程度、光照条件的绝缘子图片, 图片样式丰富。按照绝缘子材质可分为玻璃绝缘子和复合绝缘子, 其中玻璃绝缘子 2 416 张, 复合绝缘子 1 697 张。

使用 LabelImg 对图像数据集进行人工标注, 按照 PASCAL VOC 格式注释, 包含了标注物体的类别和位置信息, 如图 5 所示。



图 5 绝缘子标注

2.2 评估指标

为验证本文方法的有效性,本文采用最常见的评估指标:平均精度均值(Mean average precision, mAP)^[21],它是多个类别平均精度(Average precision, AP)的平均值,mAP值的范围是0~100%,越大越好。目标检测问题需要评估物体的分类和定位的性能,因此不能直接用图片分类的精度(Precision)作为评价指标,所以根据AP评价模型的好坏,其中 m 表示分类的种类数,本文中因为只有绝缘子1个类别,所以 $m=1$ 。

2.3 实验条件

2.3.1 网络设置

使用 Pytorch 实现模型,预训练网络、自训练网络的结构相同,训练参数不同。特征提取器采用全卷积层连接,并引入残差结构,本文采用 YOLOv3 的网络结构^[12],共 53 层,包含 52 个卷积层和 1 个全连接层。如文献[4,12,21]所述,YOLOv3 的输入尺寸为 $416 \times 416 \times 3$,经过特征提取网络输出 3 个级别的特征向量,浅层特征尺寸为 $13 \times 13 \times 18$,中层特征尺寸为 $26 \times 26 \times 18$,深层特征尺寸为 $52 \times 52 \times 18$,更深层的特征部分通过更浅层的特征获得,本文在实验中选择用浅层特征,对抗学习网络中采用 2 个全连接层,将最后 1 个卷积层的特征由 3 024 维转化成 64 维,最后转化为 3 维的特征向量,经过 3 个类别的分类器进行分类。

2.3.2 参数设置

(1) 预训练基础网络。

训练基础网络时,采用 YOLOv3 的预训练权重文件,将训练图片数据按照 7:3 的比例划分为训练集和测试集来预先训练网络。由图 6 所示,训练迭代次数设置为 3 000 代,mAP 在 2 100 代达到最大值(82.4%),并从 2 400 代开始锐减。本文识别的对象仅有绝缘子,因此,设置类别数 $classes=1$,过滤器数 $filters=18$ 。玻璃绝缘子跨复合绝缘子检测时设置学习率 $lr=0.002\ 61$,学习率衰减策略使用多步长衰减策略,到 2 400 代学习率衰减 1 个数量级(10%),到 2 700 代学习率再衰减 1 个数量级(10%)。迭代次数 $epoch=3\ 000$,每个训练批次 $batch_size=32$ 。复合绝缘子跨玻璃绝缘子检测时设置学习率 $lr=0.002\ 61$,迭代次数 $epoch=3\ 000$,每个训练批次 $batch_siz=32$,学习率

衰减策略使用多步长衰减策略,到 2 400 代学习率衰减 1 个数量级,到 2 700 代学习率再衰减 1 个数量级。




图 6 不同迭代次数对预训练模型性能的影响

(2) 跨域对抗训练。

本文方法属于半监督域自适应,训练数据包括 2 部分:源域(提供的图片包括标签的内容,如目标的类别、数量和坐标)和目标域(只提供图片无标签)。首先,以原始的 YOLOv3 框架为基准,使用源域数据进行训练,不考虑域适应。然后直接用目标域图片测试初始网络,挑选识别率较高的目标域图片及其软标签进行对抗学习和自训练。

玻璃绝缘子跨复合绝缘子:把玻璃绝缘子数据作为源域,复合绝缘子数据作为目标域,目标检测网络优化器选用随机梯度下降(Stochastic gradient descent,SGD),对抗学习网络学习率 $lr=0.002\ 61$,由表 1 和表 2,把自训练微调设置为 5 次,每次迭代 4 个 $epoch$ 。筛选软标签时设置信度 $\alpha=0.4$ 。

表 1 微调次数对模型性能的影响

微调次数	迭代次数	$x^{S \rightarrow T} / \%$	$x^{T \rightarrow S} / \%$
5	4	60.9	42.5
10	4	60.7	40.7
15	4	59.5	35.1
20	4	46.2	36.8
25	4	43.2	36.0

表 2 迭代次数对模型性能的影响

微调次数	迭代次数	$x^{S \rightarrow T} / \%$	$x^{T \rightarrow S} / \%$
5	4	60.9	42.5
5	8	34.8	50.5
5	16	32.7	53.9
5	32	46.8	54.5
5	64	55.8	55.1

复合绝缘子跨玻璃绝缘子: 把复合绝缘子数据作为源域, 玻璃绝缘子数据作为目标域, 目标检测网络优化器选用 SGD, 对抗学习网络学习率 $lr=0.001$, 由表 1 和表 2, 把自训练微调设置为 5 次, 每次迭代 64 个 *epoch*。筛选软标签时设置置信度 $\alpha=0.5$ 。

自训练前对软标签的筛选至关重要, 筛选方法如 2.2 节所述, 软标签置信度对模型性能的影响, 如图 7 和图 8 所示, 展示了不同的置信度 α 对模型性能的影响, 说明了最佳置信度的选择方法。通过实验发现, 玻璃绝缘子跨复合绝缘子时 $\alpha=0.4$ 最佳, 复合绝缘子跨玻璃绝缘子时 $\alpha=0.5$ 最佳。




图 7 玻璃绝缘子跨复合绝缘子筛选软标签时置信度的取值对性能的影响




图 8 复合绝缘子跨玻璃绝缘子筛选软标签时置信度的取值对性能的影响

2.4 消融及可视化

本文方法的损失项对检测性能的影响如表 3 所示, 第 1 列是各损失项, 第 2 列是玻璃绝缘子数据集跨复合绝缘子数据集的跨域性能 mAP 值, 第 3 列是复合绝缘子数据集跨玻璃绝缘子数据集的跨域性能 mAP 值。

表 3 网络结构及损失项效果对比

损失项	$x^{S \rightarrow T} / \%$	$x^{T \rightarrow S} / \%$
仅预训练	27.1	31.2
仅自训练	45.6	41.2
自训练+对抗学习	48.5	43.4

首先, 就网络结构进行比较: 当训练集为玻璃绝缘子时, 测试集为复合绝缘子, 采用自训练网络结构比直接使用 YOLOv3 模型的 mAP 提升了 18.5%; 当训练集为复合绝缘子时, 测试集为玻璃绝缘子, 采用自训练网络结构比直接使用 YOLOv3 模型的 mAP 提升了 10%。其次, 就损失项进行比较: 当训练集为玻璃绝缘子时, 测试集为复合绝缘子, 同时使用自训练和对抗网络的损失项比只采用自训练的损失项的 mAP 提升了 2.9%; 当训练集为复合绝缘子时, 测试集为玻璃绝缘子, 同时使用自训练和对抗网络的损失项比只采用自训练的损失项的 mAP 提升了 2.2%。根据结果所示, 本文自训练网络和对抗学习损失项使绝缘子的跨域检测性能显著提升。

2.5 比较研究

Chen 等^[22]提出的 Domain adaptive faster R-CNN 是基于 Faster-RCNN 的, 简记为 DAFR, 解决了目标检测域迁移问题, 取得了不错的效果。与本文方法的对比情况如表 4 所示。

表 4 2 种方法实验结果对比

方法	$x^{S \rightarrow T} / \%$	$x^{T \rightarrow S} / \%$
DAFR	35.1	19.2
本文方法	48.5	43.4

当训练集为玻璃绝缘子时, 测试集为复合绝缘子, 本文方法比 DAFR 的 mAP 值提升了 13.4%; 当训练集为复合绝缘子时, 测试集为玻璃绝缘子, 本文方法比 DAFR 的 mAP 值提升了 24.2%。由此可见, 本文方法对于绝缘子的跨域检测性能更加优秀。

图 9 展示了复合绝缘子跨玻璃绝缘子的检测效果, 图 10 展示了玻璃绝缘子跨复合绝缘子的检测效果。可以看出 YOLOv3 和 DAFR 存在的 2 个明显不足:

- (1) 当图上有多个绝缘子时检测有遗漏, 如图 9(a)、图 9(b)、图 10(a)、图 10(c);
- (2) 容易把其他区域错误检测为绝缘子, 如图 9(d)、图 10(d)。另一方面, 对于提出的方法仅采用自训练和同时采用自训练和对抗学习的效果也有不同, 如图 9(e) ~ 图 9(h) 和图 10(e) ~ 图 10(h), 表现在置信度和精度的提高。

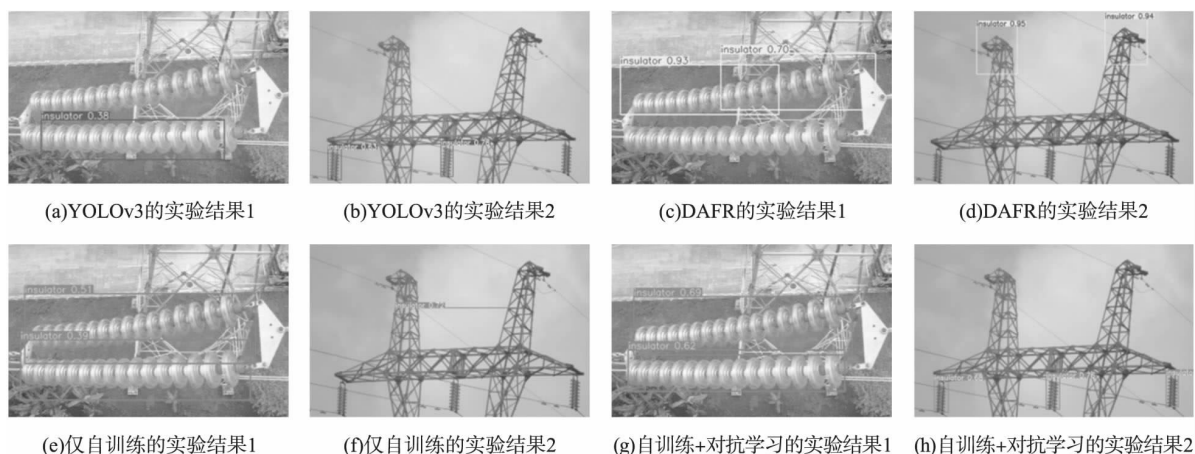


图 9 复合绝缘子跨玻璃绝缘子检测效果

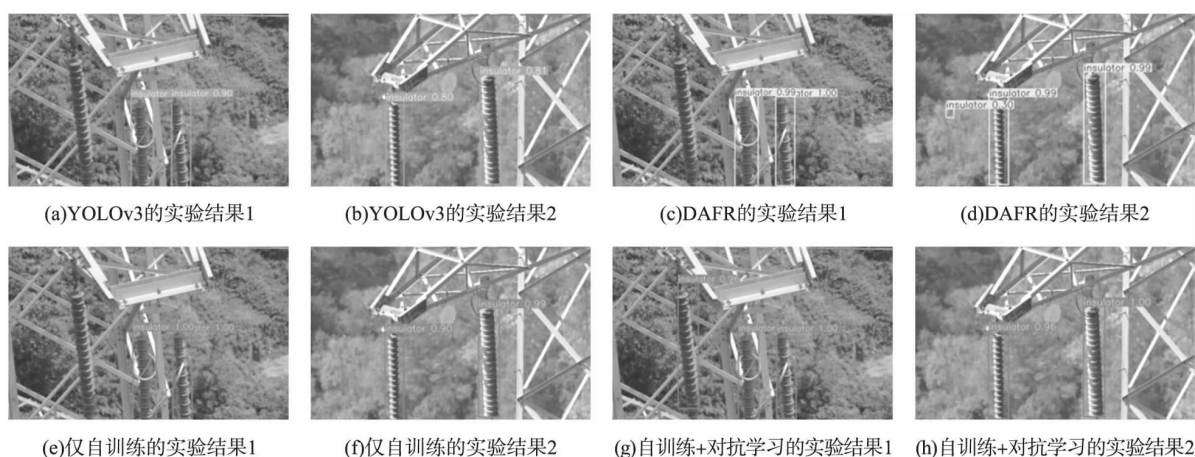


图 10 玻璃绝缘子跨复合绝缘子检测效果

3 结束语

本文采用分属不同材质的绝缘子样本对深度神经网络进行 2 个阶段的训练,在有效降低模型训练过程中样本标注量的同时,解决了跨域识别不同材质的绝缘子的问题,并为进一步实现基于计算机视觉的绝缘子故障自动诊断研究奠定了基础,也对输电线路的实际巡检工作提供了帮助。

自建数据集的大量实验结果表明:本文方法对于处于不同视角、遮挡情况、光照条件及复杂背景下的不同类型绝缘子数字图像都能取得较好的识别效果。此外,与基于 Faster-RCNN 的目标检测算法 DAFR 对比,本文算法具有一定优越性。

参考文献:

[1] Tudevtagva U, Battseren B, Hardt W, et al. Image processing based insulator fault detection method [EB/OL]. <https://www.researchgate.net/publication/>

329508391_Image_Processing_Based_Insulator_Fault_Detection_Method 2020-12-01.

- [2] 程海燕, 韩璞, 王迪, 等. 一种电网巡检航拍图像中绝缘子定位方法 [J]. 系统仿真学报, 2017, 29(6): 1327-1336.
Cheng Haiyan, Han Pu, Wang Di, et al. Location method of insulators in power grid patrol aerial images [J]. Journal of System Simulation, 2017, 29(6): 1327-1336.
- [3] 姚春羽, 金立军, 闫书佳. 电网巡检图像中绝缘子的识别 [J]. 系统仿真学报, 2012, 24(9): 1818-1822.
Yao Chunyu, Jin Lijun, Yan Shujia. Recognition of insulators in the image of power grid inspection [J]. Journal of System Simulation, 2012, 24(9): 1818-1822.
- [4] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection [EB/OL]. <https://arxiv.org/pdf/1506.02640.pdf> 2020-12-01.
- [5] Ren Shaoqing, He Kaiming, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [EB/OL]. <http://de.arxiv.org/>

- pdf/1506.01497 2020-12-01.
- [6] Cai Zhaowei , Vasconcelos N. Cascade R-CNN: Delving into high quality object detection [EB/OL]. <https://arxiv.org/pdf/1712.00726.pdf> 2020-12-01.
- [7] Gui Zhongcheng , Li Haifeng. Automated defect detection and visualization for the robotic airport runway inspection [J]. *IEEE Access* , 2020 , 8: 76100-76107.
- [8] Aguiar A S , Santos F N D , de Sousa A J M , et al. Visual trunk detection using transfer learning and a deep learning-based coprocessor [J]. *IEEE Access* , 2020 8: 77308-77320.
- [9] He Yihui , Zhu Chenchen , Wang Jianren , et al. Bounding box regression with uncertainty for accurate object detection [EB/OL]. <https://arxiv.org/pdf/1809.08545.pdf> 2020-12-01.
- [10] Krizhevsky A , Sutskever I , Hinton G. ImageNet classification with deep convolutional neural networks [EB/OL]. https://www.researchgate.net/publication/267960550_ImageNet_Classification_with_Deep_Convolutional_Neural_Networks 2020-12-01.
- [11] LeCun Y , Boser B , Denker J S , et al. Backpropagation applied to handwritten zip code recognition [J]. *Neural Computation* , 1989 , 1(4) : 541-551.
- [12] Redmon J , Farhadi A. YOLOv3: An incremental improvement [EB/OL]. <https://arxiv.org/pdf/1804.02767.pdf> 2020-12-01.
- [13] Yang Zhenheng , Mahajan D , Ghadiyaram D , et al. Activity driven weakly supervised object detection [EB/OL]. <https://ieeexplore.ieee.org/document/8953417> 2020-12-01.
- [14] Xie Shaoan , Zheng Zibin , Chen Liang , et al. Learning semantic representations for unsupervised domain adaptation [EB/OL]. <http://proceedings.mlr.press/v80/xie18c/xie18c.pdf> 2020-12-01.
- [15] Caron M , Bojanowski P , Joulin A , et al. Deep clustering for unsupervised learning of visual features [EB/OL]. <https://arxiv.org/pdf/1807.05520.pdf> , 2020-12-01.
- [16] Wang Xudong , Cai Zhaowei , Gao Dashan , et al. Towards universal object detection by domain attention [EB/OL]. <https://arxiv.org/pdf/1904.04402.pdf> , 2020-12-01.
- [17] Ma Xinhong , Zhang Tianzhu , Xu Changsheng. GCAN: Graph convolutional adversarial network for unsupervised domain adaptation [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) . Long Beach , CA , USA: IEEE , 2019: 8266-8276.
- [18] Kim T , Jeong M , Kim S , et al. Diversify and match: A domain adaptive representation learning paradigm for object detection [EB/OL]. <https://arxiv.org/pdf/1905.05396v1.pdf> 2020-12-01.
- [19] Goodfellow Ian J , Pouget-Abadie J , Mirza M , et al. Generative adversarial networks [EB/OL]. <https://arxiv.org/pdf/1406.2661.pdf> 2020-12-01.
- [20] 陈耀 , 宋晓宁 , 於东军. 迭代化代价函数及超参数可变的生成对抗网络 [J]. *南京理工大学学报* , 2019 , 43(1) : 35-40.
Chen Yao , Song Xiaoning , Yu Dongjun. Iterative cost function and variable parameter generative adversarial networks [J]. *Journal of Nanjing University of Science and Technology* , 2019 43(1) : 35-40.
- [21] Redmon J , Farhadi A. YOLO9000: Better , faster , stronger [EB/OL]. <https://arxiv.org/pdf/1612.08242.pdf> 2020-12-01.
- [22] Chen Yuhua , Li Wen , Sakaridis C , et al. Domain adaptive faster R-CNN for object detection in the wild [EB/OL]. <https://arxiv.org/pdf/1803.03243.pdf> , 2020-12-01.