

基于改进 Cascade R-CNN 的绝缘子故障检测方法研究

居来提·阿不力孜¹, 刘玉龙¹, 曹 留¹, 黄 杰², 张 勇², 朱彦卿²

(1. 国网新疆电力有限公司乌鲁木齐供电公司, 新疆 乌鲁木齐 830000; 2. 湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘 要: 针对航拍图中存在的绝缘子故障位置在图像中占比小、背景环境复杂导致的故障检测准确率低的问题, 提出一种基于改进 Cascade R-CNN 模型的绝缘子故障检测方法。在原有 Cascade R-CNN 模型的基础上, 在骨干网络中引入可变形卷积学习几何变换能力, 在检测器中引入平衡损失函数平衡难易样本。在模型训练阶段, 使用 Copy-Paste 与 Mosica 丰富故障绝缘子样本, 平衡正负样本。使用该模型对航拍绝缘子图片进行故障检测实验, 改进损失函数的模型与传统 Cascade R-CNN 模型相比平均召回率提升 0.38%, 引入可变卷积后的 Cascade R-CNN 模型与 Faster R-CNN 模型, 相比平均召回率, 从原来的 89.78% 变成 93.49%, 结果表明该模型能够有效克服样本遮挡以及样本不平衡的干扰。

关 键 词: 绝缘子; 故障检测; 改进 Cascade R-CNN; 可变形卷积

DOI: 10.19781/j.issn.1673-9140.2023.03.015 中图分类号: TM855 文章编号: 1673-9140(2023)03-0140-09

Study of insulator fault detection algorithm based on improved Cascade R-CNN network

ABULIZI Julaiti¹, LIU Yulong¹, CAO Liu¹, HUANG Jie², ZHANG Yong², ZHU Yanqing²

(1. Urumqi Power Supply Company of State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830000, China;

2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Aiming at the low accuracy problem of insulator fault detection caused by the fault position occupies a small proportion in the image and complex background environment in aerial images, an insulator fault detection method based on optimized Cascade R-CNN model is proposed in this paper. Based on the original Cascade R-CNN model, deformable convolution is inserted into the backbone network to learn geometric transformation capabilities, and balance loss function is introduced in the detector to balance difficult and easy samples. In the model training phase, the faulty insulator samples are enriched by using Copy-Paste and Mosica, and the positive and negative samples are balanced. The proposed model is tested for insulator fault detection. Compared with the traditional Cascade R-CNN model, the average recall of the optimized loss function model improves 0.38%. Comparing with the Faster R-CNN model, the average recall of the Cascade R-CNN model after introducing variable convolution improves from 89.78% to 93.49%. The results indicate that the proposed model can overcome the interference of samples shielding and sample imbalance effectively.

Key words: insulator; fault detection; improved Cascade R-CNN; deformable convolution

收稿日期: 2022-03-29; 修回日期: 2022-05-23

基金项目: 国家电网有限公司科技项目(SGXJWL00SDJS2100845)

通信作者: 朱彦卿(1978—), 男, 博士, 副教授, 主要从事电工程理论与新技术、电网络测试与诊断、人工智能技术应用等研究; E-mail:

zyq@hnu.edu.cn

绝缘子作为输电线路的关键组成部分,发挥着 2 个主要作用:支撑和固定导线载荷,同时确保导线与地之间具备良好的绝缘性能。然而,在实际工程中,受到天气、温度、污染等多种因素的影响,绝缘子可能会遭受自爆、老化、腐蚀等问题^[1-2]。因此,电力部门定期对绝缘子进行巡检和维护具有重要性和必要性。早期,工作人员沿着输电线路和塔杆进行人工巡检,然而大多数输电线路穿越山区和丛林,道路崎岖难行。因此,人工巡检存在诸多困难,不仅耗时费力,还存在安全隐患。

随着无人机技术的发展,目前电力巡检和维护的主要方式是利用无人机搭载高清摄像头,对输电线路中的电力基础设施进行航拍,然后通过人工方式分析航拍图像以判断是否存在故障^[3]。然而,这种方式效率和准确度有限。为了显著提升故障检测的精确性和效率,引入人工智能技术来辅助现有的人工检测变得尤为重要。文献[4]基于绝缘子轮廓特性,采用 Hough 变换提取轮廓信息,并通过匹配方法定位绝缘子;文献[5]提出了一种基于色彩模型和纹理特征的输电线路绝缘子串航拍图像识别方法,但未深入进行故障检测;文献[6]引入归一化互相关函数和傅里叶变换进行模糊匹配,最终通过灰度奇异值进行故障检测;文献[7]则构建了基于梯度的特征描述子,分析窗口特征之间的差异,并采用特定的投票策略实现绝缘子的定位;文献[8]提出了基于感知编组的识别方法,将图像分为 6 个不同方向,通过聚类算法对每个方向上的特征进行分类,然后依据与导线的相似性来定位绝缘子区域,并对区域进行分块、计算纹理特征量以及比较各块之间的差异,以定位故障。然而,传统的图像处理方法在检测效率和准确度方面存在一定的局限性。

随着神经网络研究的持续发展,深度强化学习结合了深度学习的感知能力与强化学习的决策能力,在多个复杂场景中取得了出色的控制效果,并被应用于配电网的优化和控制问题^[9]。一些学者已经开始利用深度学习算法来进行绝缘子故障检测。在此背景下,文献[10]通过深度学习处理红外图像,实现了对红外图像中瓷绝缘子串铁帽和盘面区域的自动识别,但并未进一步对其劣化状态进行诊断;文献[11]则对 Faster R-CNN 模型进行改进,采用 VGG16 作为骨干网络,并通过改进的损失函数对分类交叉熵与平衡交叉熵进行加权融合;文献[12]

则结合深度学习 EAST 模型和 Hu 不变矩,提出了一种图像检测方法;文献[13-14]在 YOLOv3 算法的基础上进行了改进,用以实现绝缘子故障检测,且取得了较高的准确性。尽管基于卷积神经网络的故障分类模型在上述文献中表现出色,但有些模型仍然依赖于人工选取的特征,或只能识别绝缘子的一种或两种故障,难以满足实际工程需求。为此,文献[15]提出了一个多阶段的目标检测结构,称为 Cascade R-CNN,通过逐渐提高交并比(intersection over union, IoU)阈值的检测器来减少过拟合问题,但仍无法满足绝缘子故障检测的精度要求;文献[16]引入了可变形卷积和可变形 RoI(感兴趣区域)池,以增强卷积神经网络的转换建模能力。

针对以上问题,本文提出一种基于改进 Cascade R-CNN 网络的绝缘子故障检测算法,该方法在经典 Cascade R-CNN 模型上,引入可变形卷积(deformable convolution, DC)丰富模型,训练样本集采用 copy-paste 和 mosica 进行数据增强,回归使用 Balanced L1 损失函数提高训练精度。

1 基于改进 Cascade R-CNN 的绝缘子故障检测方法

本文提出一种基于改进 Cascade R-CNN 网络的绝缘子故障检测算法,实现绝缘子的自爆和异常放电的故障检测,其流程如图 1 所示。

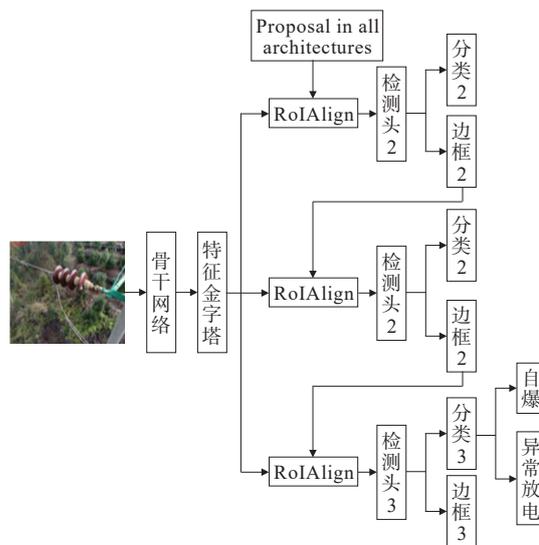


图 1 基于改进 Cascade R-CNN 的绝缘子故障检测流程
Figure 1 Flow chart of insulator fault detection based on improved Cascade R-CNN

绝缘子故障检测的具体流程如下:

1) 航拍绝缘子图片输入骨干网络,通过骨干网络中的可变形卷积加强模型的拟合能力;

2) 将骨干网络提取的特征图通过特征金字塔进行多层融合处理;

3) 经过多层处理的特征图通过3个RoIAlign和3个递增IoU阈值的检测头进行检测,其中第1个检测头使用Balanced L1损失函数,第2、3个使用Smooth L1函数;

4) 最后将第3次检测的分类结果输出,得到绝缘子故障类型。

基于绝缘子故障检测的特点,图1所示的目标检测模型对Cascade R-CNN进行了改进。通过在骨干网络中引入可变形卷积,模型学习目标的几何变换能力,从而增强骨干网络的特征提取多样性。引入特征图金字塔网络结构,以融合底层特征的位置信息和高层特征的语义信息,从而能够识别不同尺度的目标。随后,候选区域网络在多个尺度下提取预测框,然后通过多个检测器进行回归与分类,最后通过非极大值抑制来获取最终的检测结果。在边框回归阶段,使用Balanced L1损失函数以解决样本不均衡问题,从而提升模型的精度。同时,在模型训练阶段,为了丰富数据集中的故障样本,采用了Copy-Paste与Mosaic数据增强方法,以平衡训练样本的分布。

2 改进 Cascade R-CNN

2.1 Cascade R-CNN 算法

在目标检测网络的训练中,通常根据IoU阈值的选择来确定正负样本。在Faster R-CNN的第1阶段中,如果锚框与真实框的IoU阈值 $I_{ou} > 0.7$,那么该锚框被视为正样本,代表检测目标;而如果 $I_{ou} < 0.3$,锚框会被归为负样本,即背景。而在第2阶段中, $I_{ou} > 0.5$ 被分类为正样本, $I_{ou} < 0.5$ 被分类为负样本。因此,IoU阈值的选择对训练结果产生重大影响^[17]。如果阈值过高,所得到的正样本会更接近真实框,从而训练的检测器会更准确,但由于正样本数量有限,会导致模型过度拟合。然而,当阈值较低时,模型可以获得更丰富的正样本,有助于模型的训练,但也会产生大量不必要的预测框^[18]。

文献[15]提出了Cascade R-CNN,其结构如图2所示。Cascade R-CNN包含多个检测器,每个检测器由池化层与输出层组成,使用不同的IoU阈值进行训练。前一个检测器的输出被作为后一个检测器的输入,逐步提高IoU阈值,从而使重新采样的预测框能够适应具有更高阈值的后续检测器。通过多个检测器的逐步优化,预测框的检测质量逐渐提高,其定位精度也更加准确。

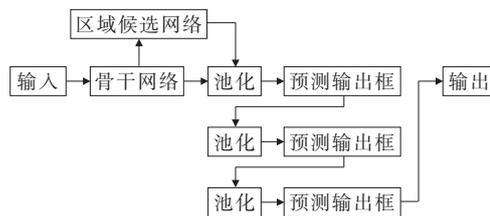


图2 Cascade R-CNN网络结构

Figure 2 Cascade R-CNN network structure

2.2 改进 Cascade R-CNN 算法

Cascade R-CNN算法通过多个检测器提高了预测精度,但在绝缘子故障检测中的效果还不够理想。针对绝缘子缺陷检测问题,对Cascade R-CNN进行改进,以提升模型精准度。

2.2.1 可变形卷积

传统的卷积操作在固定且规则的网格点上数据进行采样,这限制了网络感受野的形状以及对几何形变的适应能力。以 3×3 卷积核为例,普通卷积操作与可变形卷积操作的差异如图3所示^[16]。

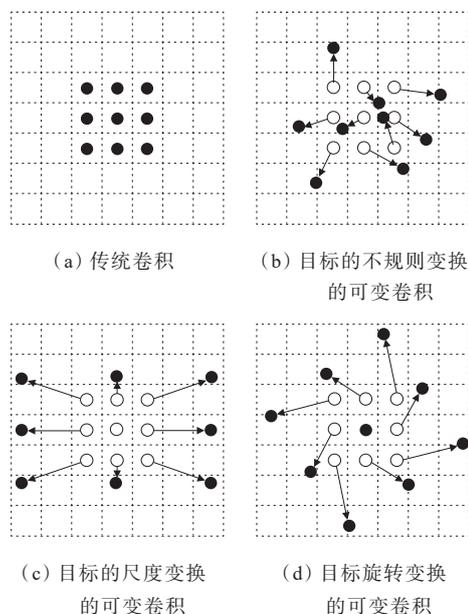


图3 传统卷积与可变形卷积

Figure 3 Traditional convolution and deformable convolution

在图 3 中,空心的采样点坐标被引入一个偏移量,从而得到了实心的采样点^[16]。图 3(b)展示了目标的不规则变换,图 3(c)表示目标的尺度变换,而图 3(d)表示了目标的旋转变换。因此,引入可变形卷积使得网络具备了学习空间几何变换的能力。

可变形卷积网络结构如图 4 所示^[16]。它引入了一组平行的卷积计算单元,通过反向传播进行端对端的学习。在该平行分支中,根据输入的特征图计算出采样点的偏移量,然后在输入特征图上对应的点进行卷积运算。需要注意的是,偏移采样点在实际中并不存在,而是通过周围的 4 个像素点进行双线性差值估计得出的。可变形卷积核的采样点会根据特征图的变化而自适应调整,从而适应不同大小、尺度和形变的目标。

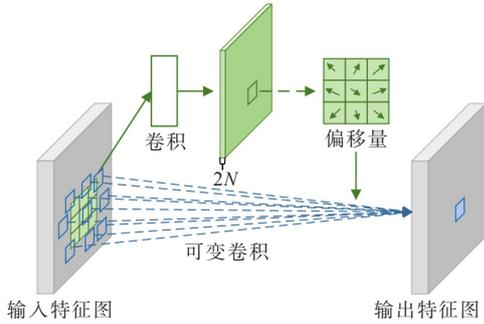


图 4 可变形卷积网络结构

Figure 4 Structure diagram of deformable convolutional network

以二维卷积为例,假设卷积核的尺寸为 3×3 ,传统卷积操作分为 2 步:先在输入的特征图上使用网格 R 进行采样,再对每个点进行加权求和运算。

$$R = \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\} \quad (1)$$

式(1)对应了 9 个采样点,那么传统的卷积可表示为

$$y(\mathbf{p}_0) = \sum_{\mathbf{p}_n \in R} \mathbf{w}(\mathbf{p}_n) \cdot \mathbf{x}(\mathbf{p}_0 + \mathbf{p}_n) \quad (2)$$

式中, $\mathbf{x}(\cdot)$ 、 $\mathbf{y}(\cdot)$ 分别为卷积层的输入特征图与输出特征图; $\mathbf{w}(\mathbf{p}_n)$ 表示卷积核对应位置的权重; \mathbf{p}_0 为卷积中心; \mathbf{p}_n 为对 R 中的所有位置的枚举。

可变形卷积可以表示为

$$y(\mathbf{p}_0) = \sum_{\mathbf{p}_n \in R} \mathbf{w}(\mathbf{p}_n) \cdot \mathbf{x}(\mathbf{p}_0 + \mathbf{p}_n + \Delta \mathbf{p}_n) \quad (3)$$

式中, $\Delta \mathbf{p}_n$ 为偏移量。一般情况下 $\mathbf{p}_0 + \mathbf{p}_n + \Delta \mathbf{p}_n$ 不为整数,则需采用双线性差值:

$$x(\mathbf{p}) = \sum_q G(\mathbf{q}, \mathbf{p}) \cdot x(\mathbf{q}) \quad (4)$$

$$G(\mathbf{q}, \mathbf{p}) = \max(0, 1 - |q_x - p_x|) * \max(0, 1 - |q_y - p_y|) \quad (5)$$

式中, \mathbf{p} 为经过偏移的任意一点; \mathbf{q} 为 \mathbf{p} 点周围最近的网格整点。

可变形卷积的加入使得网络在无需额外的监督信息和只增加了少量计算量的情况下,最终却对模型带来显著的提升效果。

2.2.2 样本不平衡处理

在绝缘子故障检测样本中,每张图片通常只包含 1~2 个故障点,这可能导致模型训练过程中正样本数量过少,负样本数量过多,从而引发模型过拟合问题。此外,在自爆数据集中,存在背景复杂且故障点被背景遮挡的情况,导致了一些难以训练的样本。为了应对上述问题,本文从以下 3 个方面入手来解决。

1) Copy-Paste 方法。虽然 Faster R-CNN 通过正负样本的采样来缓解不平衡问题,即从正样本中随机抽取 N 个,从负样本中随机抽取 N 个,但这并没有从根本上解决问题。考虑到图像中故障点数量有限,可以尝试创造更多的故障点,如图 5 所示,其展示了通过 Copy-Paste 方法生成的图片^[19]。从数据集中随机选取 2 张图片,将图片中的目标对象复制出来,再经过旋转,尺度变换后粘贴在另一个图像中。通过 Copy-Paste 不仅扩增了数据集,同时也在单张图像中增加了故障目标,缓解了正负样本不均衡的问题,使模型能够更好地进行训练。

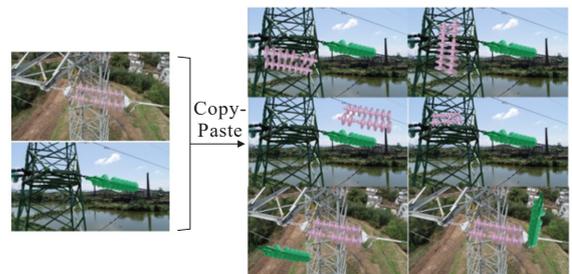


图 5 Copy-Paste 结果

Figure 5 Copy-Paste results

2) Mosica 是一种数据增强方法,它从数据集中随机选择 4 张图片进行随机裁剪,并将它们拼接成一张新的图像作为训练数据^[20]。采用这种方法的好处在于可以增加绝缘子故障图片中的故障个数,

从而解决正样本数量不足的问题。此外,通过Mosica数据增强,还能丰富图像的背景信息,有助于模型从复杂的背景中识别出故障位置。此外,在批量归一化层中,同时对4张图像进行计算,这也间接地提高了模型的批尺寸,从而使得在单个GPU的情况下减少对批尺寸的依赖^[19]。图6展示了Mosica数据增强的示例结果。需要注意的是,如果在随机裁剪时真实框被削减了一部分,那么这个真实框将会被直接移除。

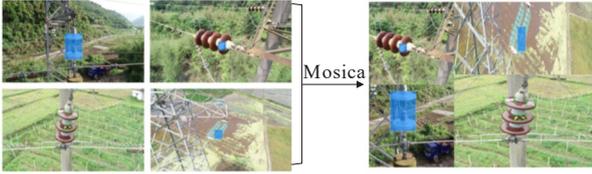


图6 Mosica结果

Figure 6 Mosica results

3) 损失函数。Cascade R-CNN的损失函数与Faster R-CNN没有太大区别。Cascade R-CNN有3个检测器,每个检测器都包含分类损失与回归损失^[20],定义如下:

$$L(\{p_i\}, \{t_i\}, \{k\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (6)$$

式中, i 为预测框编号; k 为检测器编号(当 $k=1$ 时 $N_i=0.5$,当 $k=2$ 时 $N_i=0.6$,当 $k=3$ 时 $N_i=0.7$); p_i 为预测框 i 是否存在目标的概率; p_i^* 为对应的真实框概率(当预测框与真实框的 $I_{\text{ou}} \geq N_i$ 时为正样本,当 $I_{\text{ou}} < N_i$ 时为负样本); t_i 为预测框 i 的坐标信息; t_i^* 为对应的真实框与预测框 i 之间的偏移量; λ 为平衡2个损失的超参数; L_{cls} 为分类损失; L_{reg} 为边框回归损失,计算公式为

$$L_{\text{reg}}(t_i, t_i^*) = \text{Balanced L1}(t_i - t_i^*) \quad (7)$$

损失函数为2个部分损失的总和,当分类正确时,得到的损失较低,从而可能忽略了回归的重要性。在绝缘子缺陷数据集中,自爆等类型的故障周围存在复杂的背景,并可能出现遮挡问题,从而产生难以训练的样本。基于Libra R-CNN的实验数据表明,易于训练的样本会产生困难样本梯度的0.3倍,从而导致模型的梯度下降变得不稳定。因此,在第1个检测器中,通过使用平衡的L1损失函数替代平滑的L1损失函数来平衡难易样本,而在第2和

第3个检测器中,经过2次回归后,预测框很难产生困难样本,因此仍然使用原始的平滑L1损失计算公式^[18]。Balanced L1计算公式如下:

$$\text{Balanced L1}(x) = \begin{cases} \frac{\alpha}{b}(b|x|+1)\ln(b|x|+1) - \alpha|x|, & \text{if } |x| < 1 \\ \gamma|x| + \frac{\gamma}{b} - \alpha, & \text{otherwise} \end{cases} \quad (8)$$

为确保函数的连续性, α, b, γ 需满足 $\alpha \ln(b+1) = \gamma$,其中 α 设置为0.5, γ 设置为1.5。

3 实验结果与分析

3.1 检测方案选择

绝缘子故障检测一般采用2种方案:第1种方案是首先从复杂的背景中定位出绝缘子的位置,然后通过分类模型对绝缘子进行分类。这种方法之所以被采用,是因为在航拍图像中,绝缘子所占比重较小。通过先定位再识别的方法,能够消除大部分冗余信息,从而提高模型在分类阶段的准确率。第2种方案则是直接在航拍图像中识别出故障的类型与位置。这种方案的优势在于处理速度较快,并且能够准确地确定故障出现的位置。在实际工程中,为了能够及时发现绝缘子的异常放电痕迹,无人机在航拍过程中会与绝缘子保持距离在1.5~5.0 m的范围内。在这种距离下,获得的图像非常清晰,同时绝缘子的占比也足够大。因此,在本文中,采取了第2种方案,即直接在图像中识别故障的位置和类别。

3.2 训练参数设置

本文中的所有实验均在Paddle深度学习框架上完成。在训练阶段采用了迁移学习的策略,总共进行了20 000次迭代。其中,前1 000次采用了衰减系数为0.1的Warm-up策略。学习率衰减方案采用了固定的步长衰减,在第14 000次和第18 000次迭代时,将学习率减少为原来的十分之一。优化器选择了Momentum,动量因子设置为0.9。在进行了10 000次迭代后,每500次迭代计算一次模型的mAP值。最终,选择具有最高mAP值的模型进行预测。在测试阶段,没有采用数据增强方法。为了

加速模型的收敛速度,输入图像的尺寸被归一化为 1 333×800 的分辨率。

3.3 数据集标注

本文所使用的绝缘子图像包括玻璃绝缘子,复合绝缘子,瓷质绝缘子;故障类型包含自爆,异常放电 2 种,故障绝缘子航拍图像示例如图 7 所示。



(a) 自爆



(b) 异常放电

图 7 故障绝缘子的航拍图像

Figure 7 Aerial images of faulty insulator

航拍图像共有 932 张,其中训练集与验证集的比例为 8:2。本文使用了开源标注工具 Labelimg 进行故障标注,标注过程如图 8 所示。故障位置被用矩形框标记,并赋予相应的目标标签,如“自爆”(self-destruct)。标注完成后,每张图片会生成对应的 .xml 文件,其中包含矩形框的位置信息、图片的尺寸以及标签的分类信息。

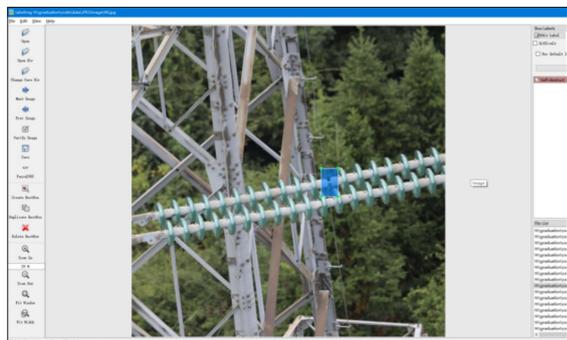


图 8 Labelimg 标注绝缘子故障数据集

Figure 8 Insulator fault dataset with Labelimg annotated

3.4 损失函数对比分析

自爆这一类型的故障因其缺乏明确的目标,并且周围环境复杂,属于难以训练的样本。这些样本在反向传播过程中会得到较大的梯度,被称为难样本;相反,模型中的简单样本会获得较小的梯度,称为易样本。在本实验所使用的数据集中,自爆故障占样本的 70%。在难易样本不平衡的情况下,可能导致模型训练不稳定,最终训练结果不尽如人意。

为验证损失函数改进的有效性,使用了 Cascade R-CNN 模型,骨干网络采用 50 层的残差网络。在边框回归损失函数方面,对比了使用 Smooth L1 loss 和 Balanced L1 loss 2 种方法。实验结果如表 1 所示。

表 1 Cascade R-CNN 改进损失函数前后对比

Table 1 Comparison of Cascade R-CNN before and after improving the loss function

算法模型	骨干网络	边框回归损失函数	AP		mAP	FPS	平均召回率
			自爆	异常放电			
Cascade R-CNN	Resnet50	Smooth L1 loss	0.757	0.727	0.742 3	5.09	0.931 1
		Balanced L1 loss	0.774	0.727	0.750 7	5.14	0.934 9

根据实验结果,改进后的模型表现出 0.84% 的 mAP 提升和 0.38% 的召回率提升。FPS 变化不大,整体性能得到了提升,这意味着在不增加计算负担的情况下改善了模型性能。因此,引入 Balanced L1 loss 能够平衡难易样本,从而使模型训练更加稳定和高效。

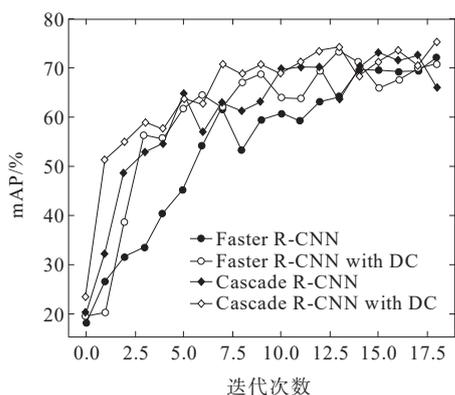
3.5 可变形卷积对比分析

为了提升模型的泛化能力,通常会通过数据增强来增加样本的多样性。这意味着目标会经历多种形变,每个目标都可能具有不同的形状。为了让模型更好地学习这些形变,本文在骨干网络中引入了可变形卷积结构。为了更详细地展现可变形卷积结构对模型的影响,绘制了训练过程中 mAP 随着迭代次数的变化趋势,如图 9 所示。

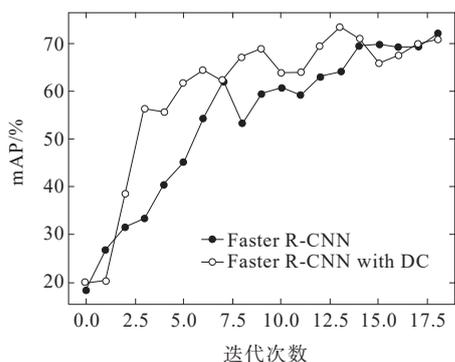
图 9 呈现了可变形卷积结构在不同算法模型中,随迭代次数的增加,mAP 的变化曲线。从

图 9(a)中可以看出加入了可变形卷积的 cascade R-CNN 的 mAP 变化曲线基本上包裹住了其他模型的曲线,这意味着在模型训练的各个阶段它都是优于其他模型的。从 2 个单独的模型来看也是如此,如图 9 所示。表 2 为曲线图中最高点的数值。

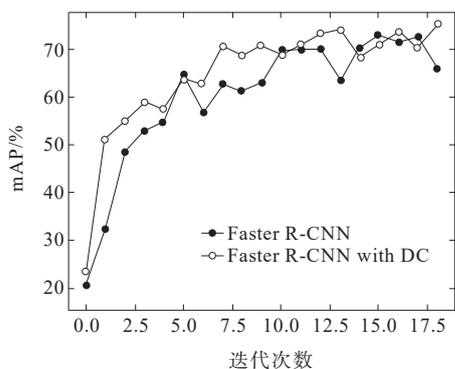
在 Cascade R-CNN 与可变形卷积的组合下, mAP 与平均召回率分别为 0.751 7 和 0.934 9。FPS 之间的差异是因为 Cascade R-CNN 采用了多个检



(a) 4种模型对比



(b) 可变形卷积结构在 Faster R-CNN 中对比



(c) 可变形卷积结构在 Cascade R-CNN 中对比

图 9 训练过程中 mAP 变化曲线

Figure 9 mAP variation curve during training

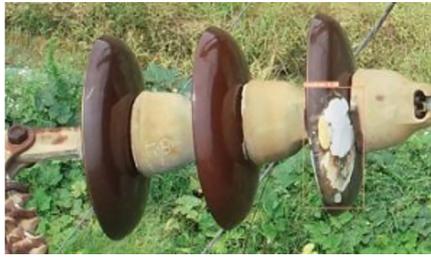
表 2 改进骨干网络对比分析

Table 2 Comparative analysis of improved backbone network

算法模型	骨干网络	AP			FPS	平均召回率
		自爆	异常放电	mAP		
Faster R-CNN	Resnet50	0.715	0.727	0.720 9	9.16	0.897 8
	Resnet50 with DC	0.743	0.727	0.735 2	9.13	0.925 4
Cascade R-CNN	Resnet50	0.736	0.727	0.731 7	5.03	0.907 3
	Resnet50 with DC	0.776	0.727	0.751 7	5.14	0.934 9

测器级联,因而检测速度稍慢。由于拍摄距离和角度的变化,航拍图像中存在目标大小、位置、形状等的变化,以及目标之间的遮挡等问题,进而增加了目标检测的难度。传统目标检测网络结构未能进行多分辨率检测,难以有效地完成小尺寸目标的检测任务。本文引入的特征图金字塔网络则对各个尺度的图像进行了特征提取,无论是高分辨率还是低分辨率、大目标还是小目标,都能够提取到有力的信息,从而保证了检测效果的稳定。同时,由于航拍图像中不同位置可能对应着不同尺度或不同形变的物体,传统的卷积操作可能效果欠佳,特别是在处理形变复杂的目标时。而文中引入的可变形卷积核的大小和位置则能够根据图像内容自适应地进行调整,以适应航拍图像中不同目标的形状、大小,甚至遮挡等几何变化。通过这些方法,虽然能够有效提升绝缘子自爆检测的准确率,但异常放电的准确率却没有得到显著提高。可能的原因在于绝缘子表面的污垢会干扰模型对异常放电特征的提取。因此,需要进一步研究如何避免绝缘子表面污渍对绝缘子异常放电检测准确率的影响。

如图 10 所示为改进后 Cascade R-CNN 算法的检测结果。可以明显观察到该算法在不同类型的绝缘子、不同故障类型、不同目标大小以及不同角度的各种场景下都能够准确定位故障。其定位性能精准且鲁棒性出色。



(a) 水平绝缘子异常放电



(b) 水平绝缘子自爆



(c) 垂直绝缘子自爆

图10 改进 Cascade R-CNN 算法部分检测结果示例

Figure 10 Partial detection results of improved Cascade R-CNN algorithm

4 结语

本文旨在解决绝缘子缺陷检测问题,以提升模型的精准度为目标,提出了一种改进的 Cascade R-CNN 网络绝缘子故障检测方法,该方法引入了可变形卷积结构和 Balanced L1 损失。对 Cascade R-CNN 和 Faster R-CNN 分别进行训练,考虑不同损失函数和是否引入可变形卷积结构,实验结果显示,在引入平衡损失函数后,优化后的 Cascade R-CNN 模型的平均召回率提升了 0.38%。同时,在引入可变形卷积后,Cascade R-CNN 模型的平均召回率从原来的 89.78% 提升至 93.49%。虽然采用了 Copy-Paste 和 Mosica 等方法在一定程度上解决了样本不平衡的问题,但可能导致预测正样本变得

相对简单,因此需要进一步研究更为有效的样本不平衡解决方法。区域候选网络和非极大值抑制等方法能够有效从图像中提取候选框,然而,由于航拍图像的拍摄角度问题,存在一定的遮挡情况。此外,玻璃绝缘子的异常放电痕迹不够明显,且目标较小,难以进行有效的训练。因此,如何在复杂背景中准确识别不清晰的小目标是一个值得深入研究的方向。另外,模型参数庞大,需要较高的计算资源,难以在无人机上实现实时检测。因此,在保持准确性的前提下减小模型参数量也将成为后续研究的关键内容。

参考文献:

- [1] 梁曦东,高岩峰,王家福,等.中国硅橡胶复合绝缘子快速发展历程[J].高电压技术,2016,42(9):2888-2896.
LIANG Xidong, GAO Yanfeng, WANG Jiafu, et al. Rapid development of silicone rubber composite insulator in China[J]. High Voltage Engineering, 2016, 42(9): 2888-2896.
- [2] 黄郑,王红星,周航,等.基于混合算法的电力杆塔巡检实时航迹规划[J].中国电力,2021,54(11):214-220.
HUANG Zheng, WANG Hongxing, ZHOU Hang, et al. Real-time path planning for power tower inspection based on hybrid algorithm[J]. Electric Power, 2021, 54(11): 214-220.
- [3] 唐睿,张铭予,徐宏,等.基于深度学习的输电线路巡检图像绝缘子识别[J].电网与清洁能源,2021,37(4):41-46.
TANG Rui, ZHANG Mingyu, XU Hong, et al. Insulator recognition in transmission line inspection image based on deep learning[J]. Power System and Clean Energy, 2021, 37(4):41-46.
- [4] FANG T, JIN X, HU X L, et al. A fast insulator-contour-detection-algorithm on power transmission lines images[J]. Applied Mechanics & Materials, 2012, 201-202: 337-343.
- [5] 韩谷静,何敏,雷宇航,等.基于改进 U-Net 的输电线路绝缘子图像分割方法研究[J].智慧电力,2022,50(3):93-99.
HANGujing, HE Min, LEI Yuhang, et al. Image segmentation method of transmission line insulator based on improved U-Net[J]. Smart Power, 2022, 50(3):93-99.
- [6] 黄玲,赵锴,李继东,等.基于特征金字塔和多任务学习的绝缘子图像检测[J].电测与仪表,2021,58(4):37-45.

- HUANG Ling,ZHAO Kai,LI Jidong,et al.Insulator image detection based on feature pyramid and multi-task learning[J]. *Electrical Measurement & Instrumentation*, 2021,58(4):37-45.
- [7] OBERWEGER M, WENDEL A, BISCHOF H. Visual recognition and fault detection for power line insulators [C]//19th Computer Vision Winter Workshop, Beijing, China,2014.
- [8] 刘云鹏,董王英,许自强,等.基于卷积神经网络的变压器套管故障红外图像识别方法[J]. *高压电器*, 2021,57(10):134-140.
- LIU Yunpeng,DONG Wangying,XU Ziqiang,et al.Infrared image recognition method on fault of transformer bushing based on convolutional neural networks[J]. *High Voltage Apparatus*,2021,57(10): 134-140.
- [9] 胡维昊,曹迪,黄琦,等.深度强化学习在配电网优化运行中的应用[J]. *电力系统自动化*,2023,47(14):174-191.
- HU Weihao,CAO Di,HUANG Qi,et al.Application of deep reinforcement learning in optimal operation of distribution network[J]. *Power System Automation*, 2023, 47(14): 174-191.
- [10] 蔡智超,孙翼虎,赵振勇,等.基于时频分析和深度学习的表面粗糙度超声模式识别方法[J]. *电工技术学报*, 2022,37(15):3743-3752.
- CAI Zhichao,SUN Yihu,ZHAO Zhenyong,et al. A deep learning-based electromagnetic ultrasonic recognition method for surface roughness of workpeice[J]. *Transactions of China Electrotechnical Society*,2022,37(15):3743-3752.
- [11] 秦瀛.基于深度学习的输电线路复合绝缘子缺陷检测[D].北京:北京交通大学,2020.
- QIN Ying. Defect Detection of composite insulators for transmission lines based on deep learning[D]. Beijing: Beijing Jiaotong University,2020.
- [12] 刘君,邓毅,杨延西,等.基于深度学习的空预器转子红外补光图像积灰状态识别[J]. *发电技术*, 2022,43(3): 510-517.
- LIU Jun,DEND Yi,YANG Yanxi,et al. Ash accumulation state identification for infrared compensation images of air preheater rotor based on deep learning method[J]. *Power Generation Technology*,2022,43(3):510-517.
- [13] 王卓,王玉静,王庆岩,等.基于协同深度学习的二阶段绝缘子故障检测方法[J]. *电工技术学报*, 2021,36(17): 3594-3604.
- WANG Zhuo,WANG Yujing,WANG Qingyan,et al. Two stage insulator fault detection method based on collaborative deep learning[J]. *Transactions of China Electrotechnical Society*,2021,36(17):3594-3604.
- [14] 罗潇,於锋,彭勇.基于深度学习的无人机电网巡检缺陷检测研究[J]. *电力系统保护与控制*, 2022, 50(10): 132-139.
- LUO Xiao, YU Feng, PENG Yong. UAV power grid inspection defect detection based on deep learning[J]. *Power System Protection and Control*, 2022, 50 (10): 132-139.
- [15] CAI Z, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City,USA,2018.
- [16] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]// *Proceedings of the IEEE international conference on computer vision*, Venice, Italy, 2017.
- [17] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017,39(6):1137-1149.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, USA, 2016:770-778.
- [19] GHIASI G ,CUI Y ,SRINIVAS A ,et al.Simple copy-paste is a strong data augmentation method for instance segmentation[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*, Nashville, USA, 2021.
- [20] PANG J, CHEN K, SHI J, et al. Libra R-CNN: towards balanced learning for object detection[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*, Long Beach, USA, 2020.