

基于改进 SOLOv2 和虚拟数据增强的输电线路实例分割模型

吕 磊¹, 霍耀冉¹, 唐震宇¹, 肖钰皓¹, 黄长久², 方 夏³

(1. 国网四川省电力公司信息通信公司, 四川 成都 610041; 2. 国网四川电力映秀湾电厂, 四川 汶川 624000; 3. 四川大学机械工程学院, 四川 成都 610065)

摘 要:针对目前将绝缘子自爆缺陷检测和输电线、杆塔检测视作为两个独立的任务, 存在对缺陷以及场景理解不充分的问题。提出一种改进的 SOLOv2 的实例分割方法, 可以在航拍图像中同时检视正常绝缘子、自爆缺陷绝缘子、杆塔和输电线。由于绝缘子、杆塔、输电线之间的长径比相差巨大, 该方法使用 HRNet 替代原始 SOLOv2 中的 ResNet+RPN 结构, 可以更好地实现多尺度检测, 并且在残差结构中引入了可变形卷积, 可更好地检测形状细长的绝缘子和输电线。此外, 为了提高数据标注工作效率、扩大数据量并节约时间成本, 利用虚幻引擎和 AirSim 自动生成数据集标签的功能, 制作了部分虚拟数据集以增强真实数据集。经过实验测试, 在构建的数据集中, 所提出的方法相较于原始的 SOLOv2 在平均准确率上提升了 8.7%, 在平均交并比上提升了 8.5%, 也优于其他现有实例分割方法。

关键词:输电线和杆塔检测; 绝缘子自爆缺陷检测; SOLOv2; HRNet; 实例分割

中图分类号:TM 755 **文献标志码:**A **文章编号:**1003-6954(2024)06-0092-09

DOI:10.16527/j.issn.1003-6954.20240614

Instance Segmentation Model for Transmission Line Based on Improved SOLOv2 and Virtual Data Enhancement

LYU Lei¹, HUO Yaoran¹, TANG Zhenyu¹, XIAO Yuhao¹, HUANG Changjiu², FANG Xia³

(1. State Grid Sichuan Information & Communication Company, Chengdu 610041, Sichuan, China;
2. State Grid Yingxiuwan Hydroelectric Power Plant, Wenchuan 624000, Sichuan, China;
3. School of Mechanical Engineering, Sichuan University, Chengdu 610065, Sichuan, China)

Abstract: Currently, the detection of insulator self-explosion defects and the inspection of transmission lines and towers are taken as two separate tasks, resulting in insufficient understanding of defects and scenarios. Aiming at these problems, an improved instance segmentation method based on SOLOv2 is proposed, which allows for the simultaneous inspection of normal insulators, self-explosion defect insulators, towers and transmission lines in aerial images. Due to the significant aspect ratio differences among insulators, towers and transmission lines, this method replaces the ResNet+RPN structure in original SOLOv2 with HRNet, which better achieves multi-scale detection. Additionally, deformable convolution is introduced into the residual structure to better detect the elongated shapes of insulators and transmission lines. Furthermore, in order to enhance data annotation efficiency, increase data volume and save time, a portion of the virtual dataset is created using unreal engine and AirSim to augment the real dataset. Experimental tests show that, in the constructed dataset, the proposed method improves the average accuracy by 8.7% and the average intersection over union (IoU) by 8.5% compared to the original SOLOv2, and it also outperforms other existing instance segmentation methods.

Key words: transmission line and tower detection; insulator self-explosion defect detection; SOLOv2; HRNet; instance segmentation

0 引言

随着无人机技术的迅猛发展,无人机拍摄已成为获取输电线路高空视角图像的重要手段。通过航拍图像可以获取输电线和杆塔信息,用于输电线路巡检和绝缘子自爆缺陷检测。通常将绝缘子自爆缺陷检测和输电线、杆塔检测视为两个独立的任务。绝缘子自爆缺陷检测是目前故障诊断和可靠性研究领域的热点话题。

传统的绝缘子检测方法^[1-3]通常使用图像处理技术,通过手动调整算法参数来检测绝缘子的外轮廓和纹理特征。然而,这些方法复杂繁琐,容易受到背景干扰且鲁棒性较差,只适用于特定目标和场景,难以满足实际需求。近年来,基于卷积神经网络的算法模型在目标检测和图像分割领域取得了蓬勃发展,为绝缘子的分割和自爆缺陷检测提供了更高效的方法和思路。在绝缘子自爆缺陷检测领域,常见的目标检测算法有以 Fast RCNN (fast region-based convolutional neural networks)^[4]为代表的双阶段检测网络和以 YOLO (you only look once)^[5]为代表的单阶段检测网络。这些算法都利用了神经网络模型强大的特征表达能力,相比传统的检测方法具有更强的鲁棒性。它们能够更准确地提取绝缘子的特征并检测出缺陷。常用于绝缘子自爆缺陷检测的图像分割算法有以 Mask RCNN^[6]为代表的实例分割算法,和以 UNet^[7]为代表的语义分割算法。与目标检测相比,图像分割可以更加精细地标记出不同物体、纹理和颜色等信息,并且可以对小物体或者密集的目标进行有效的检测。

也有不少文献提出了各种方法来检测输电线,例如采用特殊的图像处理算法,如文献[8-9]基于 Canny 边缘检测算法进行检测;文献[10]基于 Radon 变换的线段提取算法利用 Hough 变换和 K-mean 聚类跟踪电力线,使用脉冲耦合神经滤波器去除背景噪声并利用改进的 Hough 变换细化检测结果。然而,传统图像处理方法存在速度慢和精度低的问题。因此,越来越多的研究开始使用基于深度学习的图像分割算法在航拍图像中检测电力线和杆塔^[11-13]。通过深度学习模型的训练,可以获得较好的鲁棒性和泛化能力,并且基于深度学习的图像分割可以通过端到端的训练直接从原始图像到目标分

割结果,简化了处理流程,并且可以获得更好的整体性能。

尽管已经涌现出大量绝缘子自爆缺陷检测以及输电线路和杆塔检测的研究,但是现有研究没有考虑将三项检测合并成一个任务,使实际的输电线路巡检过程占用更多的计算资源而不利于应用。

但利用航拍图像共同检测绝缘子、杆塔和输电线以显著提升算法的性能水平,面临以下几个难点:1) 绝缘子、输电线和杆塔三者之间的尺寸、形状相差巨大,使其难以被全部准确检测和识别。2) 为获得准确的检测模型需要大量的训练数据,但是无人机航拍图像本身尺寸巨大,标注所需的专注力和时间成本高,特别是对于输电线路这种需要精细标注轮廓边缘的目标。

为此,下面提出了一种基于改进的 SOLOv2^[14]和虚拟数据增强的输电线路实例分割模型,用于快速检测和区分输电线、输电塔、正常绝缘子及自爆缺陷绝缘子。为实现实例分割,即区分绝缘子、输电线和输电塔之间的语义分割,并解决数据集标注困难的问题,提出了一种基于改进的 SOLOv2 单级实例分割网络的方法,该方法可同时检测输电线、输电塔和绝缘子自爆缺陷。同时,为了降低标注成本并扩大数据集,创新性地使用基于虚幻引擎 5 的虚拟增强数据集来训练和测试模型。该方法的应用将促进无人机在输电线路巡检中的自适应巡检和智能规划路线的发展。这对于提高电力系统安全性和可靠性具有重要意义。

1 SOLOv2 算法

SOLOv2 是一种用于目标检测和实例分割的深度学习方法。这种方法在其前身 SOLO (segmenting objects by locations)^[15-16]的基础上进行了一些关键改进,以提高性能并使其更适用具体的应用场景^[17-22]。

SOLOv2 依旧维持了 SOLO 的核心思想,即目标实例分割可以通过直接预测每个像素的类别并将其定位在特定的目标实例中。其网络结构如图 1 所示。在 SOLOv2 中,输入图像经过一个全卷积网络 (fully convolutional network, FCN) 和特征金字塔 (feature pyramid network, FPN) 之后,得到不同层级的特征图 I , 其形状尺寸为 $H \times W \times E$, H 、 W 、 E 分别是特征

层的高、宽和通道数,其中 H 、 W 均为输入图像的 $1/4$ 。随后的检测头由两个分支组成:类别分支和蒙版分支。

在类别分支中,将图像分为 $S \times S$ 个特征区域,当有需要预测类别的图像中心落入到某一区域时,需要预测其位置,因此输出为 $S \times S \times N$,其中 N 为数据集类别数。在蒙版分支中,SOLOv2 使用了动态卷积的策略,因此又将蒙版分支分为 2 个分支,分别为卷积核分支和特征分支。在卷积核分支中,经过 4 层卷积和 1 层卷积核为 $3 \times 3 \times D$ 的卷积后,由大小为 $H \times W \times E$ 的特征图输出一个大小为 $S \times S \times D$ 的预测蒙版 G 。在特征分支中,大小为 $H \times W \times E$ 的特征图经过卷积、组归一化、线性整流单元 (rectified linear unit, ReLU) 等操作后变成大小为 $H \times W \times E$ 的特征图;之后,再经过 1×1 卷积调整通道数,特征 F 最终得到对应区域蒙版;最后,通过矩阵非极大值抑制,去除冗余的预测结果,最终得到各个实例的分割区域。

2 改进 Solov2 算法

巡检航拍图像分辨率较大,而卷积神经网络是

一个下采样过程。为了在下采样过程中保持高分辨率的特征图信息,并在不同分辨率之间进行信息交互,将 SOLOv2 的骨干网络替换为高分辨率网络 (high resolution network, HRNet),可以提供更好的空间感知能力和特征细节捕捉能力。因此,使用动态卷积对 HRNet 中的传统卷积滤波器进行调整,通过引入一个可学习的滤波器形状参数,根据输入序列的实际长度来动态地调整滤波器的形状。

2.1 骨干网络

由于需要分割的输电塔和输电线的尺度变化较大,将 SOLOv2 骨干残差网络 (residual network, ResNet)^[23] 换成 HRNet^[16]。HRNet 是一种用于图像分类、目标检测和图像分割等计算机视觉任务的基础网络架构,其网络结构如图 2 所示。HRNet 的设计理念是同时保持高分辨率 (原始输入的 $1/4$) 和丰富的语义信息,以克服传统网络在高分辨率图像上的信息损失问题。它通过多分支的方式,在网络中保留了多个分辨率的特征图。

与原始 SOLOv2 使用 ResNet 和 FPN 相比,HRNet




图 1 SOLOv2 结构




图 2 HRNet 网络结构

有更好的多尺度表示能力;相较于 ResNet, HRNet 具有多分支并行结构,能够在不同分支上同时保留低、中、高分辨率的特征信息。这提高了 HRNet 在多尺度物体表示方面的能力,有助于更好地检测不同尺寸的物体。同时,HRNet 有更高的时空一致性,其在构建特征金字塔时,采用了密集的连通性以保持时空一致性。这意味着特征图的每个位置都能够从所有分辨率的特征获益,而不仅仅是从固定的分辨率中获得信息。这种时空一致性有助于提高 SOLOv2 在目标分割任务中的性能。此外,HRNet 拥有更强的特征传递能力,其通过高分辨率的特征保留了图像中的细节信息,这对于物体边界的细微结构和细节非常重要,尤其对于输电线这种细长物体而言。相比之下,ResNet 在较低层级特征中可能会有信息丢失,而 HRNet 的特征传递能力更强,可以更好地捕捉物体的空间和形状信息。

2.2 可变形卷积

常规的卷积操作使用固定、规则的采样位置,例如 3×3 卷积核在图像上滑动时,卷积核中的每个元素对应到输入图像的固定位置,然后根据这些位置的值计算卷积结果。但是这种方法在处理一些具有复杂的空间变化的图像时会存在效率和准确性方面的限制。可变形卷积 (deformable convolution, DCN)^[24]正是为了解决这个问题而提出,它不再使用固定和规则的采样格点,而是允许在卷积过程中,采样的位置进行“位移”或“变形”,这使得模型能够适应更多的空间变换,从而提高了模型的性能与准确性。

在 HRNet 的残差结构 (与 ResNet 的残差结构类似) 中引入 DCN,即在每个残差相加之前加入 DCN,结构如图 3 所示。图中, C 为特征层通道数。使用 DCN 那层的输出特征图计算公式为

$$f(p) = \sum_{p_i \in R} w(p_i) \cdot x(p + p_i + \Delta p_i) \quad (1)$$

式中: $f(p)$ 为中心点 p 处的输出值; p_i 为相对于 p 的第 i 个采样点偏移; $w(p_i)$ 为空间位置 p 处第 i 个采样点的卷积权重; Δp_i 为第 i 个采样点位置的额外偏移量,由网络学习得到; $x()$ 为输入特征图值, $x(p + p_i + \Delta p_i)$ 即为输入特征图在位置 $p + p_i + \Delta p_i$ 的值。

2.3 损失函数

所使用的多任务损失函数 L 定义为:




图 3 融合 DCN 的残差结构

$$L = L_{\text{cate}} + L_{\text{mask}} \quad (2)$$

$$L_{\text{cate}} = -y \lg(\hat{p}) - (1 - y) \lg(1 - \hat{p}) \quad (3)$$

$$L_{\text{mask}} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (4)$$

式中: L_{cate} 为语义分类的常规 Focal Loss 函数,用于解决数据不平衡造成的模型性能问题; $\hat{p}$ 为预测概率; y 为真值标签; L_{mask} 为掩码预测的 Dice Loss 函数,用于评估两个样本相似性的度量函数,其值越大意味着这两个样本越相似; X 为真实分割图像的像素标签; Y 为模型预测分割图像的像素类别; $|X \cap Y|$ 近似为预测图像的像素与真实标签图像的像素之间的点乘,并将点乘结果相加; $|X|$ 和 $|Y|$ 分别近似为它们各自对应图像中的像素相加。

3 实验验证与分析

3.1 实验数据准备

所使用的数据由真实数据集和虚拟数据集两部分组成,如图 4 所示。

1) 真实数据集:来自于机载 HDR 摄像机在实际无人机检测过程中拍摄的航拍视频。所有航拍视频的分辨率为 3648×5472 , 30 帧/s。从这些航拍视频中选择 500 个合适的帧,以 8 : 2 的比例分配到训练集和测试集中。通过手工标记获得高质量的标签,该数据集可用于各种任务,如实例分割、目标检

测和语义分割。该数据集包含两种类型的线缆(接地线和四分裂线)、两种类型的铁塔(线性塔和耐张塔)、两种类型的绝缘子(正常绝缘子和自爆缺陷绝缘子)。该数据集包含 4329 个实例,数据样本如图 4(a)所示。背景占据了图像中的大部分空间,背景与待检测目标所占像素之间存在严重的不平衡,并且由于地线细长的特性,地线与其他目标之间的像素占用也存在严重的不平衡。

2) 虚拟数据集:由三维仿真软件虚幻引擎制作,借助微软开源的跨平台模拟器 AirSim 使用 Python 一键自动生成数据集的标签,而所需做的只有搭建场景。由于开源社区已经公布了大量的杆塔模型以及山脉、城镇等大量常见场景,所以搭建场景工作只是简单的复制粘贴,相比于手动标注会节省大量时间。实验搭建了一个大型的山脉景观仿真环境,按照真实场景中铁塔的布局搭建了一条输电线路;制作了包含 5000 张仿真样本的数据集,数据样本如图 4(b)所示。该数据集可用于实例分割、目标检测和语义分割,并且可为真实数据集提供数据增强的样本。


3.2 评价指标

实验图像分割评价指标采用准确率(accuracy, ACC)、交并比(intersection over union, IoU)衡量模型的检测性能,评价算法在每一类目标上的表现能力。其计算公式分别如式(5)、式(6)所示。

$$I_{ACC} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (5)$$



(a) 真实数据集



(b) 虚拟数据集

图 4 数据集典型样本

式中: I_{ACC} 为预测准确率; T_P 为真正例,表示模型正确地预测为正例的样本数; T_N 为真负例,表示模型正确地预测为负例的样本数; F_P 为假正例,表示模型错误地预测为正例的样本数; F_N 为假负例,表示模型错误地预测为负例的样本数。

$$I_{IoU} = \frac{A_{overlap}}{A_{union}} \quad (6)$$

式中: I_{IoU} 为预测区域和真实区域的交并比; $A_{overlap}$ 为预测区域和真实区域相交的像素数; A_{union} 为预测区域和真实区域覆盖的像素数。

3.3 实验环境

实验基于 Ubuntu 18.04 操作系统,实验环境为 Python3.8、CUDA11.3 及 PyTorch1.10.1,使用 NVIDIA GeForce GTX 3060 Ti GPU 加速模型训练。使用 OpenmmLab 的开源项目 mmdetection 来完成实验。实验设置的优化器为随机梯度下降算法(stochastic gradient descent, SGD),初始学习率为 0.01,权重衰减系数为 0.000 5,动量为 0.937,最大迭代轮数为 300,图片大小统一调整为 640×512。

3.4 实验结果对比与分析

3.4.1 消融实验

为了验证所提改进措施对网络模型性能的提升,在 SOLOv2 网络上逐次增加 HRNet 和 DCN 模块,实验结果如表 1 所示。表中使用平均准确率(mean accuracy, mACC)和平均交并比(mean intersection over union, mIoU)来评价算法在所有目标上的表现能力, mACC 和 mIoU 分别为 ACC 和 IoU

表 1 经过不同改进方式后实验结果

单位: %

方法	mACC	mIoU	线性塔		耐张塔		四分裂线		接地线		正常绝缘子		缺陷绝缘子	
			ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU
SOLOv2	43.15	43.37	75.36	70.25	71.95	69.76	50.92	47.52	9.15	14.52	19.84	23.59	31.72	34.58
SOLOv2+HRNet	43.77	44.02	76.58	71.28	72.38	70.72	51.27	48.01	9.60	13.25	20.01	25.35	32.78	35.51
SOLOv2+DCN	44.69	43.72	77.63	72.54	74.41	70.17	53.19	48.15	10.70	15.28	20.56	23.87	31.62	32.35
SOLOv2+HRNet+DCN	46.25	45.86	78.24	73.81	75.66	72.37	55.41	48.75	10.58	15.43	23.22	28.62	34.41	36.27

在所有类别上的均值。

由表 1 可知:所提改进骨干网络对于所有种类而言效果更优,因为输电线、绝缘子和输电塔之间主要面临的问题是图像尺度变化较大,而 HRNet 相较于原始模块 ResNet 在多尺度任务上性能更好;使用 DCN 有效提高了输电线的检测效果,因为输电线对尺度相对不敏感,但形状细长,非常特殊,而 DCN 可以在轴线防线上捕捉更多的特征,从而较大幅度提高模型性能。总的来说,添加 HRNet 和 DCN 模块后形成的新网络比原始 SOLOv2 分别在 mACC 和 mIoU 上提升了 7.2%和 5.7%。

3.4.2 虚拟数据增强实验

使用第 3.1 节展示的性能最好的网络结构 SOLOv2+HRNet+DCN 来对比验证虚拟数据集的数据增强作用。首先,使用原始的真实数据集,即包含 4000 真实图片的训练集对网络进行训练;然后,分别使用 400 张真实数据旋转增强、400 张真实数据平移增强、400 张真实数据错切增强、400 张虚拟数据增强、1000 张虚拟数据增强和 5000 张虚拟数据增强等 6 种方式来进行对比实验。旋转、平移和错切增强是深度学习常用的数据增强方式。

虚拟数据增强实验并没有直接使用大量的虚拟样本来进行增强,而是逐层次地递增虚拟数据样本,以验证虚拟数据量对实验结果的影响。实验结果如

表 2 所示。

从表 2 中可以看出:1)使用旋转、平移和错切等方式进行增强时,提升的效果并不明显,甚至不如直接在原始数据上的训练结果。这是因为巡检航拍图像分辨率高,旋转、平移和错切带来的空白填充势必会影响原始图片的分辨率,导致目标信息丢失。因此在虚拟数据上并没有采用这 3 种增强方式,而是直接扩充样本容量。2)使用虚拟数据增强普遍要比在真实数据机上旋转、平移和错切效果要明显,并且随着虚拟样本容量的递增,增强效果更明显。如图 5 所示为数据增强前后效果对比,未增强前接地线可能漏检,而使用数据增强后就可以检测出更加细小的接地线。

3.4.3 与其他文献的方法对比试验

为了验证所提方法的优越性,选择现有的几种实例分割算法,如 Yolact++^[25]、Mask RCNN^[6]、Mask Scoring RCNN^[26]、SOLOv2^[11]、SparseInst^[27]与所提方法进行对比。

实验结果如表 3 所示,可以看出:无论是在总体指标 mACC 和 mIoU 上,还是在面对具体目标的识别精度上,所提方法都比上述其他文献的实例分割算法展现出了更强的性能,如所提方法在 mACC 和 mIoU 上分别比 SparseInst 方法提高了 11.28%和 11.46%。

从表 3 中可以看出,正常绝缘子和自爆缺陷绝缘

表 2 经过不同方式的数据增强后实验结果

单位: %

方法	mIoU	mACC	线性塔		耐张塔		四分裂线		接地线		正常绝缘子		缺陷绝缘子	
			ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU
原始真实训练集	46.25	45.86	78.24	73.81	75.66	72.37	55.41	48.75	10.58	15.43	23.22	28.62	34.41	36.27
400 张真实数据旋转增强	48.83	48.04	79.36	75.25	78.95	76.76	59.92	49.52	12.15	19.52	26.84	30.59	35.72	39.58
400 张真实数据平移增强	49.45	48.13	80.58	77.28	82.38	80.72	57.27	48.01	12.70	19.88	27.01	32.35	36.78	30.51
400 张真实数据错切增强	50.34	49.72	79.63	76.54	81.41	80.17	62.19	54.15	16.60	25.25	30.56	29.87	31.62	32.35
400 张虚拟数据增强	50.91	51.43	80.31	77.79	82.20	81.46	63.07	55.04	17.55	28.05	30.77	33.85	31.53	32.37
1000 张虚拟数据增强	51.64	50.61	83.15	79.85	85.20	83.18	59.46	49.84	17.16	23.87	31.32	32.46	33.57	34.49
5000 张虚拟数据增强	54.91	54.47	83.18	79.77	85.05	83.34	65.04	56.16	20.99	30.05	34.21	35.97	40.99	41.54




图 5 所提方法数据集增强对比试验

表 3 不同方法在每个类别上的实验结果

单位: %

方法	mACC	mIoU	线性塔		耐张塔		四分裂线		接地线		正常绝缘子		缺陷绝缘子	
			ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU
Yolact++	34.72	33.40	59.93	57.12	60.85	58.21	15.10	14.55	6.40	5.70	32.41	33.52	33.63	34.85
Mask RCNN	37.17	37.18	62.12	61.69	65.80	63.51	24.01	22.35	3.12	2.25	31.68	35.84	36.95	37.41
Mask Scoring RCNN	38.72	39.17	69.17	71.07	68.26	67.58	16.57	15.60	6.15	5.99	33.56	34.99	38.63	39.81
SOLOv2	50.49	50.20	79.36	75.25	78.95	76.76	59.92	49.52	12.15	19.52	36.84	40.59	35.72	39.58
SparseInst	49.34	48.87	76.63	73.28	75.93	72.47	55.86	53.27	15.66	19.65	33.44	37.31	38.57	37.21
所提方法	54.91	54.47	83.18	79.77	85.05	83.34	65.04	56.16	20.99	30.05	34.21	35.97	40.99	41.54

子的 ACC 和 IoU 较低。这是因为绝缘子是串行结构,其轮廓曲线较为复杂,分割算法在曲线变化大的地方没有做到精准分割。但是,从图 6 所示的可视化结果可以看出,尽管铁塔、绝缘子和输电线的形状、长径比相差悬殊,所提方法都能大致地分割出目标的整体轮廓。




图 6 所提方法在测试集上的可视化结果

上述对比实验可以证明,所提出的改进策略有效地提升了原始 SOLOv2 的性能,使其能够在高分辨率的航拍图像中,准确地检测并分割输电线路杆塔、输

电线、绝缘子及自爆缺陷绝缘子。

3.4.4 检测目标数量对检测结果的影响

为了说明不同数量的检测目标种类对检测结果的影响,第 1 轮实验中只针对正常绝缘子和自爆缺陷绝缘子进行检测,以后依次增加数据集中检测目标的种类,实验结果如表 4 所示。从表 4 可以看出,当依次增加目标的种类时,算法对不同种类的目标的识别准确性都有提升,特别是针对绝缘子检测这一任务,正常绝缘子的 ACC 提升了 1.56 个百分点,自爆绝缘子的 ACC 提升了 3.40 个百分点。这是因为在高分辨率的航拍图像中,增加分类任务的复杂性,丰富了网络本身对场景的感知能力,使算法更准确地识别和分割每个对象,因此所提采用共同分割杆塔、输电线和绝缘子的策略是有效的。

3.4.5 与目标检测方法的对比

目前针对绝缘子自爆缺陷检测任务,涌现出了大量目标检测技术,下面通过和现有的目标检测方法对比,来验证所提的实例分割方法的优越性。为此,挑选了最新的 YOLOv8 算法来进行对比。YOLO

表 4 目标数量对检测结果的影响

单位: %

实验顺序	线性塔		耐张塔		四分裂线		接地线		正常绝缘子		缺陷绝缘子	
	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU	ACC	IoU
第 1 轮	—	—	—	—	—	—	—	—	32.65	34.20	37.59	37.88
第 2 轮	—	—	—	—	—	—	18.95	28.34	33.79	34.55	38.24	39.63
第 3 轮	—	—	—	—	63.26	55.19	19.30	29.87	34.01	34.92	39.76	40.68
第 4 轮	—	—	84.53	81.62	63.55	56.13	19.98	30.02	33.90	35.81	39.85	41.53
第 5 轮	83.18	79.77	85.05	83.34	65.04	56.16	20.99	30.05	34.21	35.97	40.99	41.54

系列在目标检测领域展现出了优越的性能,并且常被用于绝缘子自爆缺陷检测的基准^[28-30]。将 YOLOv8 在第 3.1 节所建数据集上进行了训练,最后在测试结果中挑选了两张有代表性的可视化结果进行对比,如图 7 所示。可以看出,虽然 YOLOv8 对未遮挡的绝缘子的检测效果更好,但是在目标小且被遮挡的条件下,YOLOv8 则失效了,而所提实例分割方法依然有良好的性能,这是因为所提方法通过对杆塔、输电线和绝缘子以及自爆缺陷绝缘子进行共同感知,可以使算法学得图片中更多的语义信息,促进对场景的理解,从而提高了对各种目标的检测精度。




图 7 不同领域的两种网络在测试集上的可视化结果

4 结 论

上面提出了一种改良型 SOLOv2 输电线路实例分割模型,该方法可在航拍图像中共同检测正常绝缘子、自爆缺陷绝缘子、杆塔和输电线。所提方法将 SOLOv2 的骨干网络 ResNet 与 FPN 架构替换为 HRNet,从而提高了多尺度特征提取的能力。同时,在残差结构中引入 DCN,进一步提升了输电线检测的准确性。为了扩充和丰富数据集,使用了基于虚幻引擎 5 的虚拟增强数据,有效地减轻了数

据标注的难度,同时因数据量的大幅增加,使模型的检测效果得到显著提升,比在原始数据集的平均准确率提升了 18.7%。在构建的数据集中,实验测试表明所提方法比原始的 SOLOv2 平均准确率和平均交并比分别提高了 8.7%和 8.5%。此外,与其他现有的实例分割方法相比也展现出了优越的性能,为智能化电力巡检的发展创造了新的可能。

参考文献

[1] 方挺,董冲,胡兴柳,等. 航拍图像中绝缘子串的轮廓提取和故障检测[J]. 上海交通大学学报, 2013, 47(12):1818-1822.

[2] TAN P, LI X F, XU J M, et al. Catenary insulator defect detection based on contour features and gray similarity matching [J]. Journal of Zhejiang University-Science A, 2020, 21:64-73.

[3] 赵振兵,李延旭,戚银城,等. 基于动态焦点损失函数和样本平衡方法的绝缘子缺陷检测方法[J].电力自动化设备, 2020, 40(10):205-211.

[4] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-15, 2015, Santiago, Chile. IEEE, 2015:1440-1448.

[5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, USA. IEEE, 2016:779-778.

[6] HE K M, GKIOXARI G,DOLLÀR P, et al.Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2):386-397.

[7] RONNEBERGER O, FISCHER P, BROX T.U-Net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Springer, Cham, 2015:234-241.

- [8] 陈建, 沈潇军, 姚一杨, 等. 基于航拍图像的输电线检测方法[J]. 计算机工程与设计, 2018, 39(4):1155-1160.
- [9] 陈雪云, 夏瑾, 杜珂. 基于多线型特征增强网络的架空输电线检测[J]. 浙江大学学报(工学版), 2021, 55(12):2382-2389.
- [10] YAN G J, LI C Y, ZHOU G Q, et al. Automatic extraction of power lines from aerial images[J]. IEEE Geoscience and Remote Sensing Letters, 2007, 4(3):387-391.
- [11] ABDELFAHATTAH R, WANG X F, WANG S. PLGAN: Generative adversarial networks for power-line segmentation in aerial images[J]. IEEE Transactions on Image Processing, 2023, 32:6248-6259.
- [12] YANG L, KONG S Y, DENG J H, et al. DRA-Net: A dual-branch residual attention network for pixelwise power line detection[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72:5010813.
- [13] CHEN G K, HAO K, WANG B B, et al. A power line segmentation model in aerial images based on an efficient multibranch concatenation network[J]. Expert Systems with Applications, 2023, 228:120359.
- [14] WANG X L, ZHANG R F, KONG T, et al. Solov2: Dynamic and fast instance segmentation[EB/OL]. [2023-08-10]. <https://arxiv.org/pdf/2003.10152v3>.
- [15] WANG X L, KONG T, SHEN C H, et al. Solo: Segmenting objects by locations[EB/OL]. [2023-08-10]. <https://arxiv.org/abs/1912.04488>.
- [16] WANG J D, SUN K, CHENG T H, et al. Deep high-resolution representation learning for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10):3349-3364.
- [17] 宋亮, 谷玉海, 黄佳伟. 改进 Solov2 的非结构化道路图像实例分割[J]. 激光杂志, 2024, 45(3):133-139.
- [18] 何佳琦, 周思艺, 唐晓萌, 等. 基于改进的轻量版 Solov2 红鳍东方鲀实例分割方法[J]. 华中农业大学学报, 2023, 42(3):71-79.
- [19] 吴忧, 袁雪. 基于改进 Solov2 的复杂场景下智能机器人巡检识别算法[J]. 北京交通大学学报, 2022, 46(5):95-106.
- [20] 庄前伟, 王志明, 吴龙贻, 等. 基于改进 Solov2 的穴盘幼苗图像分割方法[J]. 南京农业大学学报, 2023, 46(1):200-209.
- [21] 吴逢斌, 曹国, 时昊. 基于改进 Solov2 的转炉炼钢钢液检测[J]. 计算机应用, 2022, 42(增刊1):321-326.
- [22] 谢智宇, 唐立新, 肖宇, 等. 基于改进 Solov2 的金丝球焊焊点检测方法[J]. 现代制造工程, 2023(1):110-115.
- [23] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, USA. IEEE, 2016:770-778.
- [24] ZHU X Z, HU H, LIN S, et al. Deformable ConvNets V2: More deformable, better results[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, USA. IEEE, 2019.
- [25] BOLYA D, ZHOU C, XIAO F Y, et al. Yolact++ better real-time instance segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(2):1108-1121.
- [26] HUANG Z J, HUANG L C, GONG Y C, et al. Mask scoring R-CNN[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, USA. IEEE, 2019:2980-2988.
- [27] CHENG T H, WANG X G, CHEN S Y, et al. Sparse instance activation for real-time instance segmentation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, USA. IEEE, 2022:4423-4432.
- [28] 王韵琳, 冯天波, 孙宁, 等. 融合注意力与多尺度特征的电力绝缘子缺陷检测方法[J]. 高电压技术, 2024, 50(5):1933-1942.
- [29] 郭雨, 马美玲, 黎大林. 基于改进 YOLOv5 的轻量化绝缘子表面缺陷检测[J]. 激光与光电子学进展, 2023, 60(24):222-229.
- [30] 杨露露, 马萍, 王聪, 等. 结合特征重用与重建的 YOLO 绝缘子检测方法[J]. 计算机工程, 2024, 50(7):303-313.

作者简介:

吕 磊(1974), 男, 硕士, 教授级高级工程师, 研究方向电力系统信息化;

霍耀冉(1987), 男, 博士, 高级工程师, 研究方向为电力数字化新技术;

唐震宇(1989), 男, 硕士, 高级工程师, 研究方向为电力系统信息化;

肖钰皓(1995), 男, 硕士, 工程师, 研究方向为电力数字化技术;

黄长久(1991), 男, 硕士, 工程师, 研究方向为电力系统;

方 夏(1990), 男, 博士, 副研究员, 研究方向为故障诊断和机器视觉。

(收稿日期:2024-02-22)