

基于改进 U-Net 的金具图像小样本识别算法研究^{*}

谢智慧¹ 王文爽² 刘雪峰¹

(1. 青岛科技大学自动化与电子工程学院 青岛 266061; 2. 山东省电力公司烟台供电公司互联网部 烟台 264000)

摘要: 电力金具巡检是保证电网安全运行的关键任务。针对因金具样本类别不平衡、金具图像背景复杂而导致的误检、漏检问题,提出了一种改进 U 型网络 (U-shaped network, U-Net) 的检测方法。首先,通过生成对抗网络生成虚拟金具样本扩充数据集,解决数据集中样本类别不平衡的问题;然后,提出一种前景增强方法,在网络输出的特征图中加入背景掩膜,并优化损失函数;最后,将注意力机制嵌入 U-Net,以提高模型在复杂背景下提取金具特征的能力。经实验证明,改进算法对电力金具目标的检测效果良好,其金具检测准确率达到 98.82%,平均交并比达到 83.94%,精确率达到 91.01%,召回率达到 86.18%,平均精度均值达到 89.73%。改进算法不仅可应用于正常金具的检测,还有效适用于生锈金具的检测,为电力金具智能化检测提供了一种新思路。

关键词: 电力金具;U-Net;生成对抗网络;前景增强;ACmix;智能巡检

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.60

Research on few-shot recognition algorithm of fittings image based on improved U-Net

Xie Zhihui¹ Wang Wenshuang² Liu Xuefeng¹

(1. College of Automation and Electric Engineering, Qingdao University of Science and Technology, Qingdao 266061, China;

2. Yantai Power Supply Company of State Grid Shandong Electric Power Company, Yantai 264000, China)

Abstract: Power fittings inspection is a critical task in ensuring the safe operation of the power grid. To address the challenges of imbalanced fittings samples and complex background images leading to false and missed detections, an improved detection method based on the U-Net is presented. Firstly, a generative adversarial network is employed to generate synthetic fittings samples, alleviating the issue of imbalanced sample distribution in the dataset. Secondly, a foreground enhancement method is proposed, which applies a background mask to the feature map generated by the network and optimizes the corresponding loss function. Finally, an attention mechanism is integrated into the U-Net network to enhance the model's ability to extract fittings features in complex backgrounds. Experimental results demonstrate the effectiveness of the proposed algorithm in detecting fittings objects, the fittings detection accuracy reached 98.82%, the mean intersection over union reached 83.94%, the precision reached 91.01%, the recall reached 86.18%, and the mean average precision reached 89.73%. The proposed algorithm is not only applicable to normal fittings, but also effective in detecting rusty fittings. This approach provides a new perspective for the intelligent detection of fittings.

Keywords: fittings; U-Net; generative adversarial network; foreground enhancement; ACmix; intelligent inspection

0 引言

架空输电线路巡检是保证电网安全运行的关键技术手段。在架空输电线路中,电力金具作为悬挂、固定和支

撑的金属附件关系着导线或杆塔的安全^[1]。电力金具识别是判断电力金具是否存在缺陷或故障的前提,对分析电力金具运行状态和评估电力系统是否安全稳定运行具有重要意义。传统的架空输电线路巡检工作强度高、依赖人

收稿日期:2023-08-30

^{*} 基金项目:国家自然科学基金(61971253)、山东省自然科学基金(ZR2020MF011)项目资助

员经验、验收时间周期长,无法满足当前电力系统发展的需求。无人机或带电作业机器人等高清摄像头的出现为处理传统电力巡检问题提供了有效途径,目前电力系统部门利用计算机视觉及无人机作业技术辅助人工巡检的方法已成为国内外输电线路巡检的重要模式^[2]。深度学习在电力金具智能检测领域不断发展^[3],赵振兵等^[4]提出一种基于改进级联区域卷积神经网络的典型金具及其部分缺陷检测的方法,提升了金具检测精度。但该方法没有考虑金具间的关系结构,不能使模型与电力领域知识作有效融合。Wan等^[5]提出了一种基于区域的全卷积网络的目标检测方法,通过在金具间引入细粒度特征和上下文信息提高网络检测性能,但该方法神经网络层数多、结构复杂、模型训练时间长。翟永杰等^[6]提出基于更快速的区域卷积神经网络(faster region convolutional neural network, Faster R-CNN)的融合共现推理网络来对电力金具进行检测,但是该检测方法没有在其他检测模型上应用对比,其适用范围具有不确定性。

目前,大多数金具目标检测网络结构复杂,存储和训练困难,而U型网络(U-shaped network, U-Net)具有简单的拓扑结构和高精度的检测能力,适合应用于电力图像领域的识别和分割。Han等^[7]提出一种结合GhostNet的轻量化U-Net模型,虽然该方法优化了输电线检测结果,但更适用于长度和方向相似的输电线检测。刘军等^[8]提出一种防震锤锈蚀检测方法,该方法通过U-Net网络对复杂背景下的防震锤图像进行分割,并利用椭圆度量学习进行防震锤锈蚀的识别。然而,该方法存在训练样本过少的问题,并且没有考虑样本不平衡的多目标金具检测情况。Choi等^[9]利用嵌入注意力机制的U-Net模型来检测融合的传输线可见光图像和红外图像,尽管最终获得了高精度的分割结果,但该方法的网络结构复杂且参数量较大。

为提高金具目标识别精度,改善金具样本不平衡的问题,本文提出一种基于改进U-Net网络的电力金具检测方法。首先,采用生成对抗网络(generative adversarial network, GAN)生成虚拟样本以平衡金具的样本数量,然后将注意力机制嵌入到U-Net网络中缓解因金具间相互遮挡造成的目标显著度降低的问题,最后,在输出特征图中加入背景掩膜且优化损失函数,以达到前景增强(background enhancement)的目的。该方法在电力金具智能化检测方面有一定的应用前景。

1 相关算法介绍

1.1 U-Net

U-Net网络是用编码器-解码器方法构建的对称U形网络,由编码路径和解码路径构成^[10]。其中,编码路径负责提取上下文特征信息,由卷积块、最大池化和整流线性单元组成。图像输入网络后,对特征图作4次下采样处理,其特征图通道数量会增加1倍,该过程可得到特征图的高维特征,保留图像的全局信息和语义信息。解码路径

和编码路径相对应,由卷积块和上采样组成,使用转置卷积作4次上采样操作来捕获深度信息。同时上采样过程结合跳跃连接结构,将编码路径保存的浅层信息和解码路径保存的深层信息作特征融合,最后通过 2×2 的反卷积块恢复图片的分辨率,输出结果^[11]。

1.2 注意力机制

深度学习中的注意力机制是一种模仿人类视觉认知的方法^[12],允许在处理输入数据时,神经网络可以自动学习并选择性集中关注于重点信息,从而增强模型的性能。Pan等^[13]提出了一种将自注意力和卷积模块优势融合的注意力机制(ACmix),该注意力机制由卷积模块和自注意力模块组成。在卷积模块中,先将卷积核大小为 $k \times k$ 的传统卷积分解为 k^2 个 1×1 的卷积,再作移位运算和求和运算。在自注意力模块中,将query、key和value的映射理解为多个 1×1 的卷积,然后投影特征图根据内核位置移动并聚合。ACmix模块将卷积模块和自注意力模块的一阶段整合,用3个 1×1 卷积来投影输入的特征图,然后将来自两个路径的特征叠加作最终输出。其模型结构如图1所示。

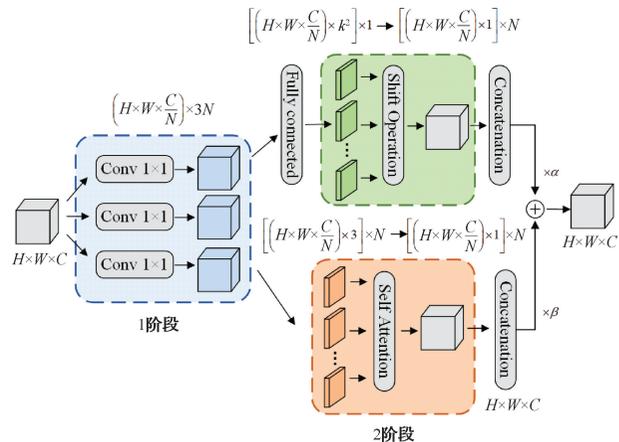


图1 ACmix注意力机制结构

2 FFE-UNet

为提高金具目标检测的准确性,本文提出了一种基于结合快速生成对抗网络(Fast GAN)和前景增强的FFE-UNet电力金具检测方法。首先利用FastGAN生成虚拟样本,平衡金具样本数量,然后在U-Net网络的每个上采样模块之前嵌入ACmix机制模块,提高模型对复杂背景中目标的特征提取能力,最后将模型输出特征加入背景掩膜,并且优化损失函数,以增强前景。FFE-UNet网络框架如图2所示。

2.1 样本平衡策略

在金具巡检任务中,数据集集中的金具样本类别可能存在不平衡情况,不同金具在数据集集中所占比例不同,像U型挂环、悬垂线夹等占比大,延长环、防震锤等占比少,不

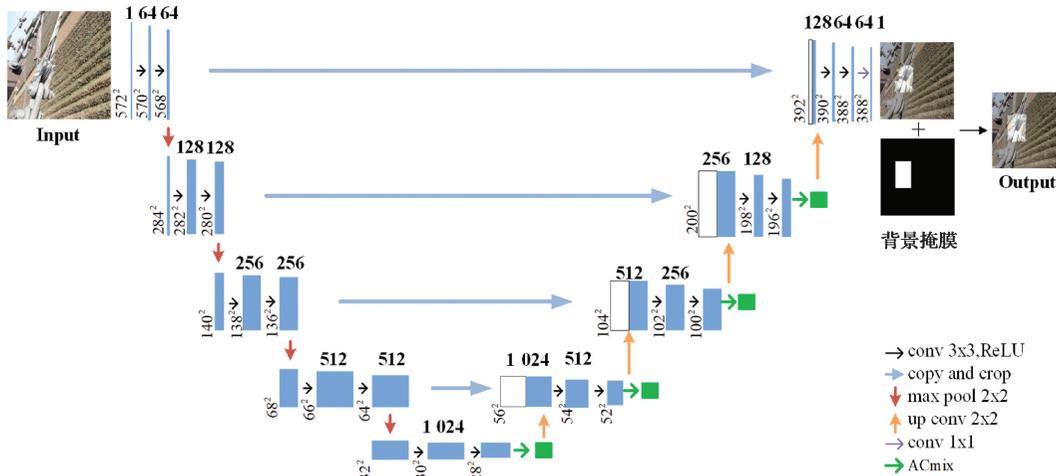


图2 FFE-UNet模型整体网络架构

同金具样本数量差异大会影响卷积神经网络 (convolutional neural networks, CNN) 模型识别的准确性。像旋转、镜像、平移和随机裁剪等传统的数据增强方法,只增加图像的数量,不一定能提高网络模型的泛化能力,而生成式数据增强方法不但可以增加样本多样性,其训练模型泛化能力也较强。FastGAN 是一种深度卷积生成对抗网络^[14],由生成器和判别器组成,生成器以随机样本作为输入,用于生成新数据,判别器可区分真实图像和生成图像,也可作特征提取器去训练和识别图像,但后者由于识别准确性较低不常被使用^[15]。两个模型相互博弈,通过不断的训练迭代,生成器逐渐学习到了真实样本的分布特征,从而能够生成更加逼真的虚拟样本, FastGAN 网络流程如图3所示。

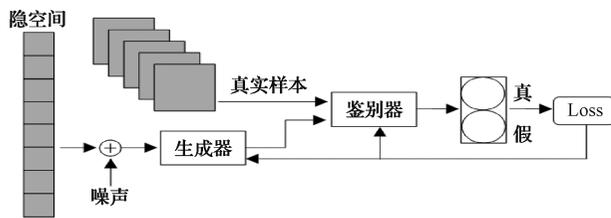


图3 FastGAN网络流程

2.2 前景增强

神经网络模型训练时可能会错误地将背景检测为前景,影响神经网络的特征学习能力。本文针对此问题提出前景增强方法,将 U-Net 网络输出的特征图中加入背景掩膜,且优化网络损失函数以解决图像前景和背景不平衡的问题。加入背景掩膜时,将标签与 U-Net 网络的输出特征图作点乘,使背景区域为 0。在点乘前对金具标签作形态学膨胀操作,使损失函数只关注前景及周围,消除复杂背景的干扰,公式如下:

$$L_r = R(L) \quad (1)$$

$$F_m = L_r \cdot F \quad (2)$$

式中: R 为形态学膨胀算法; L_r 为由 R 算法处理的标签; F_m 表示加入背景掩膜操作的特征图。

目前常见的损失函数,如交叉熵损失 (cross entropy loss, CE Loss), 是对全部像素的预测值进行累加, 函数中对前景和背景的预测分为独立的两项, 通过引入权重项应对样本前景像素和背景像素不平衡的问题^[16], 但不能针对假阳性或者假阴性进行校准。像基于区域的损失函数 Tversky Loss, 通过调整超参数 λ 控制假阳性和假阴性之间的权衡。因此, 本文结合 CE Loss 和 Tversky Loss 的优点, 提出混合损失函数 CET Loss, 通过引入权重参数 λ 来控制假阳性和假阴性间的平衡, 以此来优化损失函数。CET Loss 的计算如下:

$$L_{CE} = -\log_2 \left(\frac{\exp(g_i^c)}{\sum_{c=1}^C \sum_{i=1}^N \exp(p_i^c)} \right) \quad (3)$$

$$L_T = 1 - \left(\frac{\sum_{c=1}^C \sum_{i=1}^N g_i^c p_i^c}{\sum_{c=1}^C \sum_{i=1}^N g_i^c p_i^c + \alpha \sum_{c=1}^C \sum_{i=1}^N (1 - g_i^c) p_i^c + \beta \sum_{c=1}^C \sum_{i=1}^N g_i^c (1 - p_i^c)} \right) \quad (4)$$

$$L_{CET} = (1 - \lambda)L_T + \lambda L_{CE} \quad (5)$$

式中: L_{CET} 、 L_T 和 L_{CE} 分别代表损失函数 CET Loss、Tversky Loss 和 CE Loss; λ 为权重参数; i 为像素数; c 为像素类别数; N 为像素点总数; C 为像素点类别; p_i^c 为像素 i 属于类别 c 的概率; g_i^c 为像素 i 属于类别 c 的真实值; α 和 β 代表假阳性和假阴性的权重参数。

2.3 嵌入注意力机制的改进 U-Net 网络

在使用 U-net 网络进行特征提取时, 像防震锤等小目标的特征和轮廓信息不易被检测, 使金具检测难度增大^[17]。ACmix 注意力机制结合卷积模块和自注意力模块的优势, 有利于提高网络在复杂背景下的特征提取能力, 卷积路径中使用卷积的权重对特征映射的局部感受野作聚合^[18], 为图像处理提供了重要的归纳偏置, 使得自注意力模块可以更好地地区分背景和前景, 捕获更多特征, 获得

更大的感受野和上下文信息,以此来提高模型的整体性能。因此,本文将 ACmix 模块嵌入到 U-Net 网络的上采样层前,提高模型的检测准确性。

3 实验结果与分析

3.1 数据集及数据增强处理

本文将架空线路巡检时拍摄的 2 563 张电力金具巡检图像作为检测数据,参考“架空输电线路设备缺陷影像标注规范”制定的标准,使用 LabelImg 标注工具对 U 形挂环、球头挂环、悬垂线夹、平行挂板、延长环、防震锤和心形环 7 类金具图像作标注。在目标检测任务中,为解决部分金具训练样本不足的问题,利用 FastGAN 网络生成延长环、防震锤和平行挂板的虚拟图像,然后将所有金具图像尺寸统一为 512×512,再进行灰度化处理。训练集、验证集和测试集样本按 7:2:1 划分,最终用于训练的电力金具数量如表 1 所示。

表 1 电力金具数量

金具名称	训练集	验证集	测试集
悬垂线夹	2 433	695	248
球头挂环	1 578	450	225
平行挂板	1 233	352	176
U 型挂环	3 356	959	480
防震锤	1 119	320	160
延长环	1 080	308	156
心型环	1 192	340	170

3.2 实验设备与网络训练

本文实验使用 NVIDIA GeForce GTX2080Ti 的 GPU,操作系统为 Ubuntu 16.04.7 LTS,编程语言为 Python3.7,深度学习框架为 Anaconda、CUDA10.1、PyCharm2020 和 PyTorch1.7.0。实验训练批次容量 (batch_size) 设为 4,迭代次数 (epoch) 设为 100。

3.3 实验结果

为验证 FFE-UNet 模型的性能,本文设置多组对比实验,除了将 FFE-UNet 模型与 U-Net 算法进行对比的同时,也与现阶段较先进的目标检测算法进行比较。表 2 为 FFE-UNet 算法与不同目标检测算法的比较结果。由表 2 可以看出,FFE-UNet 相比其他模型具的确检测准确性更高。FFE-UNet 在金具检测中相较于 SSD (single shot multibox detector) 模型^[19]的精确率 (precision)、召回率 (recall) 和平均精度均值 (mean average precision, mAP) 值分别提高了 16.53%、10.02% 和 20.38%。相较于 Faster R-CNN 算法^[20],分别提高了 10.55%、6.66% 和 10.08%。相较于 YOLOX 算法^[21],分别提高了 6.33%、4.47% 和 4.94%。与 R-CNN 系列算法^[22]、YOLO (you only look once) 系列算法^[23-24]、U-Net 系列算法相比,FFE-UNet 表现出更优越的检测准确性。此外,为验证前景增强方法的

有效性,分别将 U-Net 模型^[25]、U-Net3+ 模型^[26] 和 TransUNet 模型^[27] 作前景增强处理,除了 U-Net3+ & 前景增强网络的 Recall 值比 FFE-UNet 算法高 0.06% 之外,整体来看,引入前景增强方法后的金具检测 Precision 和 Recall 值均有一定程度的提升。这表明该前景增强方法具有一定程度的适用性,由此可以推断前景增强方法可以提高神经网络的特征学习能力。因此,FFE-UNet 适用于金具目标检测场景。

表 2 不同算法检测结果 (%)

模型	Precision	Recall	mAP
SSD	74.48	76.16	69.35
Fast R-CNN	76.39	70.74	77.21
Faster R-CNN	80.46	79.52	79.65
YOLOv3	71.2	75.47	76.28
YOLOv4	78.72	81.61	76.31
YOLOX	84.68	81.71	84.79
U-Net	82.48	82.46	84.96
U-Net & 前景增强	84.03	84.95	85.47
U-Net3+	82.08	83.71	82.42
U-Net3+ & 前景增强	85.15	86.24	85.33
TransUNet	81.74	82.49	84.26
TransUNet & 前景增强	86.94	85.28	86.44
FFE-UNet	91.01	86.18	89.73

为体现前景增强方法的有效性,首先将有背景掩膜和无背景掩膜的网络作对比,然后在平行挂板和 U 型挂环数据集上对 CET Loss 进行测试,选择以 BCElogits Loss 为基础的 U-Net 网络进行对比实验。此外,将 CET Loss 的权重参数 λ 由 0.1 逐步增加到 0.9,步长设为 0.1,经实验, $\lambda=0.3$ 时,网络评估指标的结果最佳。表 3 为损失函数改进前后对 U-Net 网络性能的影响。分别对前景增强前后的检测结果作可视化处理,图 4 所示为有、无前景增强热力图,图 4(a) 为有前景增强结果,图 4(b) 为无前景增强结果。

表 3 不同损失函数检测结果 (%)

Loss Function	平行挂板数据集		U 型挂环数据集	
	mIoU	mAP	mIoU	mAP
Loss BCE logits	77.57	82.41	82.18	87.09
Loss CET	79.64	86.01	84.33	88.98

图 4(b) 表明,经前景增强处理后,目标分类器所感兴趣的点更明显,热力图的高响应区域的确集中在平行挂板和 U 型挂环上。表 3 结果表明,CET Loss 在平行挂板和 U 型挂环数据集上确实结合到 CE Loss 和 Tversky Loss 的优点,并且可以通过引入权重项来解决前景和背景不平衡问题。

为验证 ACmix 注意力模块嵌入 UNet 网络的优越

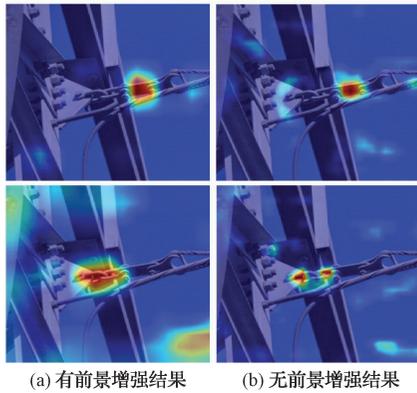


图4 有、无前景增强热力图

性,在 U-Net 网络上采样后分别嵌入压缩和激励网络模块 (squeeze-and-excitation networks, SENet) 模块^[28]、卷积块注意力机制 (convolutional block attention module, CBAM)^[29]、高效通道注意力机制网络 (efficient channel attention networks, ECANet)^[30]、双多尺度注意力网络 (dual multi scale attention network, DMSANet)^[31] 和 AC-mix 注意力机制,并在悬垂线夹数据集上进行 4 次测试,训练结果如图 5 所示,结果表明在网络中嵌入 ACmix 注意力机制后,网络检测精度更高也更稳定。

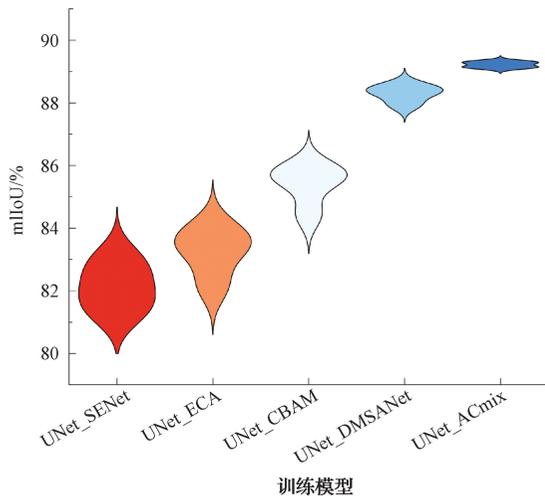


图5 不同注意力机制检测结果

此外,本文将 FFE-UNet 算法应用于金具缺陷数据的检测,以验证其适用性。生锈金具检测结果如图 6 所示。由图 6 可以看出,生锈的球头挂环、防震锤、悬垂线夹和 U 型挂环都可以被良好的识别,检测的目标框平滑且位置准确。这意味着 FFE-UNet 在缺陷金具的检测方面也具有良好的效果,该算法的广泛适用性使其在实际应用中具有很大的潜力。



图6 生锈金具可视化结果

为验证 FFE-UNet 模型的合理性,本文设置了 U-Net、样本平衡策略 (UNet_A)、嵌入注意力机制模块 (UNet_B)、前景增强策略 (UNet_C) 的多组消融实验。表 4 为不同改进方法下的消融实验结果,由表 4 可得,经过样本平衡策略后,模型检测精度值有一定程度的提升,这表明通过使用 FastGAN 生成虚拟的金具样本,可以扩充数据集中样本的数量,使得不同类别的金具样本数量相对平衡。这样,训练模型时就能更好地学习到各个类别的特征和规律,提高金具巡检的准确性和可靠性。在嵌入 AC-mix 注意力模块后,金具目标检测检测精度均有提升,这说明嵌入 ACmix 注意力模块确实能够使模型的特征提取能力增强,使模型检测效果变好。前景增强策略对模型检测的 Precision 和 Recall 值提升较明显,同时采用 3 种策略后,模型检测精度 mIoU、Precision 和 Recall 值分别提升 4.35%、8.54% 和 3.77%,证明了本文改进方法的合理性。

表4 消融实验结果

(%)

U-Net	UNet_A	UNet_B	UNet_C	Accuracy	mIoU	Precision	Recall
✓				98.03	79.59	82.47	82.41
✓	✓			98.43	82.86	84.83	82.65
✓		✓		98.56	81.92	84.61	82.71
✓			✓	98.49	80.78	87.95	84.56
✓		✓	✓	98.75	83.33	88.34	85.07
✓	✓	✓		98.78	83.2	87.35	84.12
✓	✓	✓	✓	98.82	83.94	91.01	86.18

不同金具检测精度结果对比如表 5 所示,对于样本数量较少的金具,如延长环、防震锤和平行挂板等,应用本文方法后金具检测精度值相较 U-Net、U-Net3+和 TransU-Net 提升较为明显,这表明本文利用 FastGAN 网络生成样本数量少的金具虚拟样本能缓解金具数据集的样本数量差异大带来的检测精度不高的问题。同时,FFE-UNet 网络在金具检测中对 Precision 和 Recall 的提升效果显著。特别是对于悬垂线夹的 Precision 和 Recall 值,相较于 U-Net 网络分别提升了 13.65% 和 2.18%,相较于 U-Net3+网络分别提升了 15.25% 和 4.34%,相较于 TransUNet 网络分别提升了 14.91% 和 2.06%。这一结果表明,前景增强方法可以有效解决金具图像中前景和背景不平衡导致的误检和漏检问题,进一步证明了前景增强方法的有效性。此外,FFE-UNet 网络在金具检测中的 mIoU 值也有所提升。与 U-Net 网络相比,对于平行挂板、悬垂线夹、延长环、球头挂环、心形环、U 型挂环和防震

锤的 mIoU 值分别提升了 20.59%、3.24%、12.87%、4.09%、7.44%、5.84% 和 8.61%;与 U-Net3+网络相比,分别提升了 9.37%、5.83%、10.09%、4.97%、10.69%、6.01% 和 8.42%;与 TransUNet 网络相比,分别提升了 19.33%、4.23%、10.07%、4.86%、3.65%、4.6% 和 5.22%。从这些结果可以看出,采用样本平衡策略的 FFE-UNet 网络对于样本数据量较少的延长环、防震锤和平行挂板等金具具有更好的精度提升效果。此外,嵌入 ACmix 注意力机制使模型能够获得更大的感受野和上下文信息,从而提高了模型的特征提取能力,进一步提升了模型的检测精度。整体来看,FFE-UNet 网络在准确率 (accuracy)、mIoU、Precision 以及 Recall 4 项评价指标上均有一定程度的提升,并且从训练平均耗时来看,FFE-UNet 网络训练速度快,算法性能优于 U-Net、U-Net3+和 TransUNet 网络。这充分体现了本文算法在电力金具检测方面的优越性。

表 5 各类金具检测结果

模型	评价指标	悬垂线夹	球头挂环	平行挂板	U 型挂环	防震锤	延长环	心形环
U-Net	Accuracy/%	97.75	99.11	98.26	99.42	97.76	99.42	98.18
	mIoU/%	86.79	85.62	61.33	78.3	75.14	61.96	70.46
	Precision/%	80.23	81.19	27.31	64.72	53.1	29.63	47.76
	Recall/%	93.43	86.64	71.26	85.84	92.43	69.27	82.55
	训练平均耗时/s	2.87	2.96	2.87	2.97	2.96	2.95	3.00
U-Net3+	Accuracy/%	97.91	98.74	98.18	98.24	99.23	97.9	97.96
	mIoU/%	84.38	84.74	72.55	78.13	75.33	64.69	67.21
	Precision/%	78.63	75.46	30.83	62.98	60.15	33.29	52.27
	Recall/%	91.27	85.52	73.23	86.33	92.46	74.22	83.65
	训练平均耗时/s	3.08	3.12	2.96	2.95	2.96	2.88	3.16
TransUNet	Accuracy/%	97.36	98.99	98.61	98.08	99.34	97.84	98.2
	mIoU/%	85.98	84.85	62.59	79.54	78.53	64.71	74.25
	Precision/%	78.97	80.8	31.11	63.19	56.94	32.84	51.97
	Recall/%	93.55	85.27	70.57	86.41	93.69	72.06	81.23
	训练平均耗时/s	2.62	2.77	2.81	2.89	2.91	2.85	2.91
FFE-UNet	Accuracy/%	98.38	99.45	99.17	98.64	99.63	98.22	98.36
	mIoU/%	90.21	89.71	81.92	84.14	83.75	74.78	77.9
	Precision/%	93.88	82.97	84.52	88.51	88.43	80.62	71.32
	Recall/%	95.61	94.74	94.16	87.3	91.47	83.46	87.18
	训练平均耗时/s	3.39	3.51	3.42	3.33	3.3	3.43	3.5

金具在不同模型下的可视化检测结果如图 7 所示。图 7(a)~(f)分别为延长环、防震锤、球头挂环、平行挂板、悬垂线夹、心形环和 U 型挂环的结果,由图 7(a)、(b)和 (g)可知,FFE-unet 网络可以准确地识别其他网络漏检的金具目标。图 7(c)~(f)中,FFE-UNet 网络不仅可以完

整地检测到金具目标,而且其检测结果的目标框更平滑、更准确。因此,FFE-UNet 网络能够更好地识别金具目标,并且具有更精确、更平滑的检测结果,更适配于金具数据集的检测。这进一步证实了 FFE-UNet 算法在电力金具检测方面的优越性和广泛适用性。

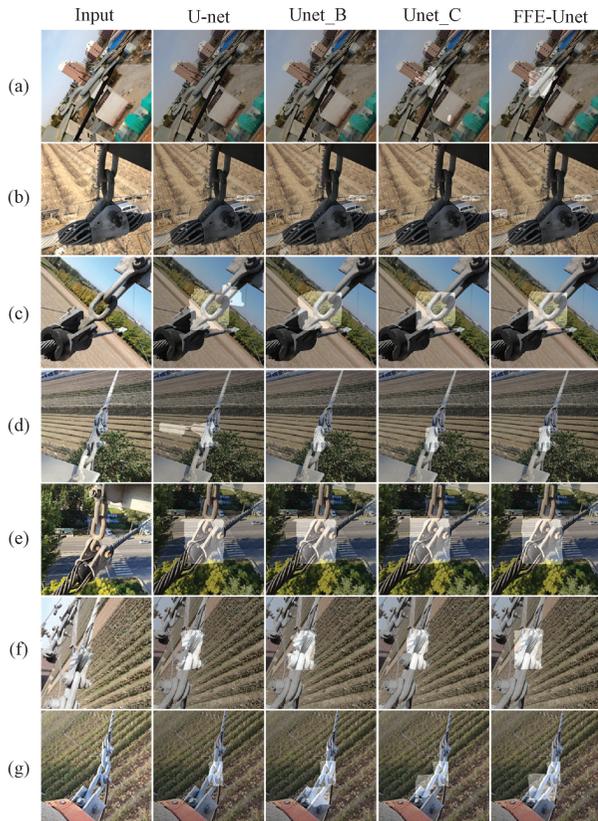


图7 不同模型的可视化结果

4 结 论

为了解决电力金具巡检图像检测任务中金具样本不平衡、金具图像背景复杂和金具间相互遮挡造成的检测识别率低等实际问题,本文提出了基于FFE-UNet的金具检测方法。该方法首先使用FastGAN增强单类金具样本,然后在U-Net网络中嵌入ACmix注意力模块,增强模型在复杂背景下对金具目标对象的特征提取能力。此外,U-Net网络的输出特征图中加入背景掩膜且优化损失函数以增强前景。该算法显著提高了模型检测的准确性,不但可实现金具目标的自动检测,还可以应用于缺陷金具图像的自动检测,这有效减轻了线路巡检后对所拍摄金具图像检验的工作量。尽管目前U型挂环和延长环目标的识别准确性可以满足检测要求,但是U型挂环和延长环相似的结构仍会对识别结果有影响。因此,未来可以继续优化模型,针对这两类金具作细粒度目标识别。

参 考 文 献

[1] 宋立业,王诗翱,刘昕明. 基于改进胶囊网络的电力线巡检异物检测[J]. 电子测量与仪器学报, 2020, 34(12): 49-56.
[2] ZOU Z, CHEN K, SHI Z, et al. Object detection in 20 years: A survey[J]. Proceedings of the IEEE,

2023, 111(3): 257-276.

[3] LI X, SU H, LIU G. Insulator defect recognition based on global detection and local segmentation[J]. IEEE Access, 2020, 8: 59934-59946.
[4] 赵振兵,熊静,李冰,等. 基于改进 Cascade R-CNN的典型金具及其部分缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1060-1067.
[5] WAN N, TANG X, LIU S, et al. Transmission line image object detection method considering fine-grained contexts [C]. 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2020: 499-502.
[6] 翟永杰,杨旭,赵振兵,等. 融合共现推理的Faster R-CNN输电线路金具检测[J]. 智能系统学报, 2021, 16(2): 237-246.
[7] HAN G, ZHANG M, LI Q, et al. A lightweight aerial power line segmentation algorithm based on attention mechanism[J]. Machines, 2022, 10(10): 881.
[8] 刘军,孙庆,刘玮,等. 基于U-Net网络和椭圆度量学习的防震锤锈蚀识别[J]. 计算机技术与发展, 2020, 30(11): 163-167.
[9] CHOI H, YUN J P, KIM B J, et al. Attention-based multimodal image feature fusion module for transmission line detection[J]. IEEE Transactions on Industrial Informatics, 2022, 18(11): 7686-7695.
[10] 高梓皓,张巧芬,王桂棠,等. 基于Resinv-Unet的图像特征点检测方法[J]. 国外电子测量技术, 2023, 42(4): 1-7.
[11] 赵文慧,杨霄,孟丽洁. 充分利用多尺度特征改进UNet实现皮肤病变分割[J]. 电子测量技术, 2022, 45(2): 110-116.
[12] 陈仁祥,詹赞,胡小林,等. 基于多注意力Faster RCNN的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
[13] PAN X, GE C, LU R, et al. On the integration of self-attention and convolution[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 815-825.
[14] SUN J. Underwater image enhancement method based on multi-scale fusion GAN[J]. Research and Exploration in Laboratory, 2022, 41(11): 62-65.
[15] CAO Z, NIU S, ZHANG J, et al. Fast generative adversarial networks model for masked image restoration[J]. IET Image Processing, 2019, 13(7): 1124-1129.
[16] LI X, CHANG D, TIAN T, et al. Large-margin regularized softmax cross-entropy loss [J]. IEEE Access, 2019, 7: 19572-19578.

- [17] 李航, 朱明. 基于深度卷积神经网络的小目标检测算法[J]. 计算机工程与科学, 2020, 42(4): 649-657.
- [18] HE X. Vehicle target detection algorithm based on yolov5[J]. Frontiers in Computing and Intelligent Systems, 2023, 3(1): 56-59.
- [19] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Computer Vision-ECCV 2016: 14th European Conference, 2016: 21-37.
- [20] 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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [21] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. Computer Science, 2021, DOI:10.48550/arXiv.2107.08430.
- [22] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [23] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. Computer Science, 2018, DOI:10.48550/arXiv.1804.02767.
- [24] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. Computer Science, 2020, DOI: 10.48550/arXiv.2004.10934.
- [25] 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, 2015: 234-241.
- [26] HUANG H, LIN L, TONG R, et al. Unet 3+: A full-scale connected unet for medical image segmentation [C]. ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2020: 1055-1059.
- [27] CHEN J, LU Y, YU Q, et al. TransuNet: Transformers make strong encoders for medical image segmentation[J]. Computer Science, 2021, DOI: 10.48550/arXiv.2102.04306.
- [28] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42(8): 2011-2023.
- [29] 常丽, 张雪, 蒋辉, 等. 融合 YOLOv5s 与 SRGAN 的实时隧道火灾检测[J]. 电子测量与仪器学报, 2022, 36(8): 223-230.
- [30] 卢嫚, 刘秀平, 冯国栋. 基于 YOLOv5 融合注意力机制的轻量级行人检测算法研究[J]. 国外电子测量技术, 2023, 42(8): 96-101.
- [31] SAGAR A. Dmsanet: Dual multi scale attention network [C]. International Conference on Image Analysis and Processing, 2022: 633-645.

作者简介

谢智慧, 硕士研究生, 主要研究方向为图像处理。

王文爽, 硕士, 助理工程师, 主要研究方向为电力通信。

刘雪峰(通信作者), 博士, 教授, 主要研究方向为人工智能、图像处理。

E-mail: nina_xf.liu@hotmail.com