· 130 ·

DOI: 10. 13382/j. jemi. B2205877

基于超分辨率重建与多尺度特征融合的 输电线路缺陷检测方法*

刘兰兰 1,2 万旭东 2,3 汪志刚 1,2 张 建 1,2 彭 昊 1,2 杨嘉妮 1,2

(1. 带电巡检与智能作业技术国网公司实验室 长沙 421000;2. 智能带电作业技术及装备(机器人) 湖南省重点实验室 长沙 421000;3. 三峡大学 电气与新能源学院 宜昌 443002)

摘 要:针对输电线路巡检中可能存在拍摄图像质量不高的问题,以及线路缺陷目标小而分布密集而导致传统方法检测精度不高的问题,提出一种基于超分辨率重建与多尺度特征融合的输电线路缺陷检测方法。首先,使用超分辨率网络对巡检图像进行重建,提升清晰度,丰富图像中包含的特征信息;然后使用改进的 YOLOX 网络检测巡检图像中的缺陷,在主干网络中嵌入卷积块注意力机制,强化模型对重叠小目标的定位能力;为进一步提升小目标的检测能力,在 YOLOX 的特征融合网络中新增浅层检测尺度进行特征融合;最后,通过使用 CIOU 优化边界框损失函数提升模型收敛能力,降低缺陷目标的漏检率。实验结果表明,所提方法能在提升巡检图像质量的基础上对输电线路缺陷准确地检测,精度达到 93. 27%,相比 SSD 等经典模型,对小而密集的缺陷目标有着更强的提取能力和鲁棒性。

关键词:输电线路缺陷检测;超分辨率;卷积块注意力;多尺度特征融合

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 470.40

Transmission line defect detection method based on super-resolution reconstruction and multi-scale feature fusion

Liu Lanlan^{1,2} Wan Xudong^{2,3} Wang Zhigang^{1,2} Zhang Jian^{1,2} Peng Hao^{1,2} Yang Jiani^{1,2}

- (1. Live Inspection and Intelligent Operation Technology State Grid Corporation Laboratory, Changsha 421000, China;
- 2. Hunan Province Key Laboratory of Intelligent Live Working Technology and Equipment (Robot), Changsha 421000, China;
 - 3. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Aiming at the problem that the quality of the captured image may be poor in the inspection of transmission lines, and the problem that the detection accuracy of traditional methods is not high due to the line defect that the targets are small and densely distributed, a transmission line defect detection method based on super-resolution reconstruction and multi-scale feature fusion is proposed. First, the super-resolution network is used to reconstruct the inspection image, improve the clarity and enrich the feature information contained in the image. Then the improved YOLOX network is used to detect defects in the inspection image, and the convolution block attention mechanism is embedded in the backbone network to strengthen the positioning ability of the model for overlapping small targets. In order to further improve the detection ability of small targets, a shallow detection scale is added to YOLOX's feature fusion network for feature fusion. Finally, by using CIOU to optimize the loss function of the bounding box, improve the convergence ability of the model and reduce the missed detection rate of the defect targets. The experimental results show that the proposed method can accurately detect the transmission line defects on the basis of improving the inspection image quality, with an accuracy of 93.27%. Compared with classical models such as SSD, it has stronger extraction ability and robustness for small and dense defect targets.

Keywords: transmission line defect detection; super resolution; convolutional block attention; multiscale feature fusion

收稿日期: 2022-10-04 Received Date: 2022-10-04

^{*}基金项目:智能带电作业技术及装备(机器人)湖南省重点实验室开放基金(2021KZD3001)、湖北省输电线路工程技术研究中心开放课题(2019KXL05)项目资助

0 引 言

输电线路作为电网的基础设施,其安全稳定运行是电能传输的基本保障^[1-3]。随着我国电网规模不断扩大,输电线路巡检范围也在激增,当前,基于智能化、自主化的输电线路缺陷目标检测技术受到广泛关注,利用计算机检测与分析采集到的输电线路图像不仅能够快速而精准地掌握输电线路的运维情况,还能节省大量人力物力^[4]。

对输电线路目标识别最初主要通过对目标纹理和特 征的分析进行检测,宋伟等[5]基于传统图像处理计算机 识别算法检测防震锤的锈蚀缺陷,但检测效果受图像拍 摄时的光线影响较大。陈晓娟等[6]采用 Hough 变换检测 防振锤,主要通过对图像施加形状约束进行检测。金立 军等[7] 先采用图像匹配和形态学运算从提取间隔棒,然 后采用形状度量的方法进行故障分类。上述传统检测方 法均局限于单一类别,且易受环境等因素影响。之后,基 于机器学习的目标检测成为新的热点,金立军等[8]利用 类 Haar 特征与级联 AdaBoost 算法实现了对输电线路中 的防震锤进行识别,一定程度上提高了检测精度,但过程 较为复杂。付晶等[9]利用类 Haar 特征和级联 AdaBoost 分类器结合层次模型检测输电线路中防振锤、螺母-销钉 部件的缺陷,与之前算法相比可靠性有所提高,但精度和 识别速度有待提高。上述方法多为依赖人工特征提取的 单目标检测方法,对图像质量有一定要求,且对小目标检 测鲁棒性较差。

随着人工智能的不断发展,基于深度学习的方法对 输电线路航拍图像目标进行检测逐渐成为了线路巡检的 热点[10]。根据网络训练方式的不同,基于深度学习的目 标检测算法可以分为两类:一类是 two-stage 目标检测算 法,如 Fast R-CNN^[11]、Faster R-CNN^[12]、Mask R-CNN^[13] 等,此类方法先利用区域候选网络根据目标特征生成候 选区域,然后对每个区域提取特征图分类预测结果,精度 较高但检测慢,汤踊等[14] 先对数据集进行扩充,然后使 用调整卷积核大小之后的 Faster R-CNN 识别输电线路的 部件与缺陷,提高了模型的有效性与可靠性,赵振兵 等[15]对 Faster R-CNN 模型改变回归损失函数并加入形 状约束,对于被遮挡目标有较好的应用,通过对典型金具 的检测验证该方法与原模型相比性能显著提高;另一类 为 one-stage 方法,包括 SSD^[16]、YOLO^[17]、YOLOv3^[18]等, 该类方法直接通过输入图片得到预测结果,速度更快,赵 振兵等[19]使用嵌入遮挡关系模块的 SSD 模型检测输电 线路金具,一定程度缓解了重叠、遮挡带来的目标定位不 准确的问题,但小目标的检测精度仍有待提升,缪希仁 等[20] 先对巡检图像进行锐化处理, 然后采用 YOLOv3 和 Resnet152 网络进行防鸟刺故障检测,但锐化对图像质量的改善较为有限。

在输电线路巡检中,实际采集到的图像可能因成像 效果差而导致缺陷检测精度受到影响,同时,输电线路缺 陷目标多为小目标,不同缺陷部件往往密集重叠在一起, 如何克服图像质量问题、实现高精度的输电线路缺陷检 测仍存在挑战。因此,本文提出一种基于超分辨率重建 和多尺度特征融合的输电线路缺陷检测方法,主要贡献 如下:1)为解决部分巡检图像质量不高的问题,采用超分 辨率 Real-ESRGAN (real-enhanced super resolution generative adversarial network) 网络[21] 重建图像,提升清 晰度;2)搭建YOLOX 网络[22],在其骨干网络中嵌入卷积 块注意力 (convolutional block attention module, CBAM)^[23],提升网络对分布密集的小目标的定位关注; 3)在YOLOX 特征融合网络中新增检测超小目标的尺 度,形成多尺度特征融合,增强小目标检测鲁棒性:4)引 入 CIOU^[24]构建损失函数,提高对密集缺陷目标的检测 精度,同时加速模型收敛。

1 算法框架及关键技术

1.1 算法框架

本文提出的基于超分辨率重建与多尺度特征融合的输电线路缺陷检测框架如图 1 所示,算法框架如下:1)使用无人机采集输电线路图像,将获得的图像进行筛选、标注、数据扩充以及划分从而构建数据集;2)搭建改进的多尺度特征融合 YOLOX 网络,使用数据集中的训练集和测试集图像进行训练;3)采用结合 Real-ESRGAN 超分辨率网络和多尺度 YOLOX 网络的输电线路缺陷检测方法对测试集图像进行检测。

1.2 Real-ESRGAN 超分辨率网络

在电力巡检拍摄过程中,由于设备抖动、天气、光线等因素可能产生的部分图像质量不高的情况,导致输电线路缺陷漏检、误检,因此采用 Real-ESRGAN 对检测图像进行超分辨率重建,提升图像质量,丰富特征信息。超分辨率重建是一种通过图像处理从低分辨率图像中得到高分辨率图像的技术,可分为基于插值、重构和学习3种重建方法,基于学习的重建方法在效果上最好。基于学习的重建方法主要有两种,一种是以 SRCNN^[25]、ESPCN^[26]为代表的基于卷积神经网络的方法,另一种是以 SRGAN^[27]、ESRGAN^[28]以及 Real-ESRGAN 为代表的基于生成对抗网络(generative adversarial networks, GAN)的图像超分辨率重建方法。其中,基于 GAN 的重建方法具有博弈对抗的学习方式,在处理复杂特征分布的视觉图像领域更具优势,已经在解决图像超分辨率问题中崭

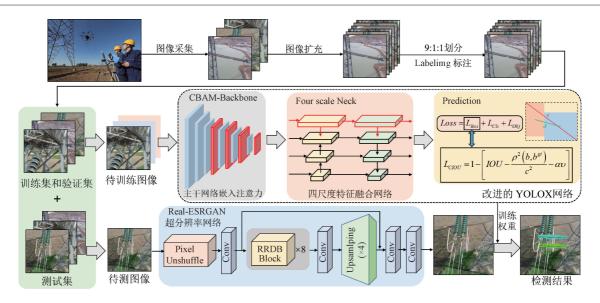


图 1 检测框架

Fig. 1 Detection framework

露头角。本文采用目前在基于 GAN 的方法中性能较好的 Real-ESRGAN 网络进行输电线路图像的超分辨率 重建。

Real-ESRGAN 网络分为生成器和判别器两部分,生 成器用来对低分辨率图像进行超分辨率重建. 判别器用 来判断输入的图像是否为真实图像,通过不断训练增强 网络的重建能力。Real-ESRGAN 在 ESRGAN 的基础上, 通过采用高阶退化模型和 sinc 滤波器构建更优秀的数据 集进行训练,其生成器与 ESRGAN 相同,判别器使用了 带有光谱归一化的 U-Net (U-Net discriminator with spectral normalization) 网络结构。本文直接使用训练成熟 的 Real-ESRGAN 生成器进行巡检图像的重建,其网络如 图 2 所示,该结构采用改进的 SRResNet 作为骨干网络, 当巡检图像输入该网络后,首先通过下采样(pixel unshuffle)压缩图像尺寸,扩充图像通道,然后输入改进 的 SRResNet 网络,将所有的 BN(batch normalization)层 去除,然后将原有的残差模块替换为 RRDB (resdual in resdual in dense block) 模块,改进的 SRResNet 网络通过 8 个包含密集连接的残差块、卷积块以及上采样模块生成 高分辨率图像。本文使用在公共数据集上已经训练成熟 的模型直接通过生成器对输电线路缺陷图像进行重建, 从而提高图像感知质量,改善细节和纹理。以输电线路 的局部图像为例,经过 Real-ESRGAN 超分辨率重建之后 的图像如图 3 所示。

1.3 YOLOX 网络

YOLOX 网络以 YOLOv3 网络为基础进行改进,其结构如图 4 所示。YOLOX 网络结构主要包含 4 个部分,分别为输入端、骨干网络、特征融合网络及预测网络。

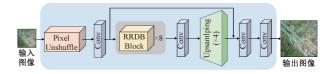


图 2 Real-ESRGAN 生成器网络结构

Fig. 2 Generator network structure of Real-ESRGAN



(a) 重建前 (a) Before reconstruction

(b) After reconstruction

图 3 Real-ESRGAN 网络的重建效果(局部)

Fig. 3 Reconstruction effect of Real-ESRGAN networks (local)

输入端主要对用于图像进行尺寸归一化与数据增强以提升训练效果。骨干网络为 CPSDarkNet53^[29],该网络是在 YOLOv3 的骨干网络 Darknet 的基础上构建的,采用多个跨区域部分连接结构,通过重复残差网络单元不断进行特征提取。经过骨干网络的特征提取后输出尺寸分别为 80×80×256、40×40×512 以及 20×20×1 024 的 3 种特征图,在特征融合网络中,这 3 种特征图通过特征金字塔结构进行进一步特征融合^[30-31],小尺寸特征图包含更多语义信息,大尺寸特征图包含更多位置信息,通过深层与浅层信息的融合从而提高模型的检测精度。特征融合

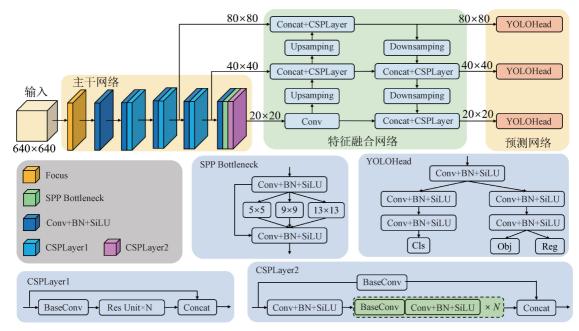


图 4 YOLOX 网络结构

Fig. 4 Network structure of YOLOX

网络同样输出 80×80×256、40×40×512 以及 20×20×1 024 这 3 种尺寸的特征图,这 3 种特征图分别负责预测图像中不同大小的目标,在预测网络中,通过解耦头将得到的 3 种特征图进行分别分类与回归,输出最终检测结果。

检测性能,但在输电线路缺陷目标检测中,如果直接应用仍存在一些问题:航拍巡检图像背景更为复杂,缺陷目标多为小目标且分布密集,因而模型可能出现漏检问题。为了解决上述问题,本文基于 YOLOX 网络提出一种融合 CBAM 注意力机制的多尺度输电线路缺陷检测模型,其结构如图 5 所示。

2 YOLOX 网络改进

现有目标检测方法中,YOLOX 网络拥有更加均衡的

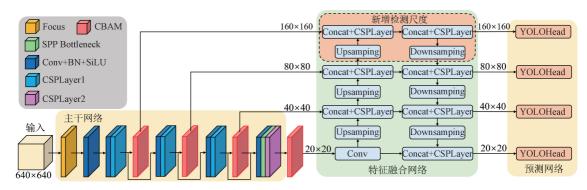


图 5 改进的 YOLOX 网络结构

Fig. 5 Network structure of improved YOLOX

2.1 嵌入通道注意力的骨干网络

为提升复杂背景下输电线路缺陷目标的检测效果, 本文将 CBAM 注意力分别添加骨干网络中每个输出层之 后,在输出特征图层的通道、位置之间建立特征映射关 系,充分利用这些全局信息,将缺陷目标区域的通道与位置特征信息重要程度进行提高,帮助模型加强对小目标区域的关注。

CBAM 注意力包含通道注意力和空间注意力两个子

模块,它们分别从通道和空间位置信息上提取模型所需关注的信息。图 6(a) 展示了通道注意力结构,假设输入特征图为 F1,其尺寸为 $H\times W\times C$, F_1 首先通过全局最大池化和全局平均池化聚合空间信息,生成两个尺寸为 $1\times 1\times C$ 的特征图,然后经过一个共享参数的多层感知器(multilayer perceptron, MLP),将 MLP 输出的两个特征图沿通道合并,使用 Sigmoid 特征激活后生成包含通道权重的特征向量,该过程可由式(1)表示:

$$M_{c}(F_{1}) = Sigmoid \begin{pmatrix} MLP(MaxPool(F_{1})) + \\ MLP(AvgPool(F_{1})) \end{pmatrix}$$
 (1)

如图 6(c) 所示,将通道注意力和空间注意力结合即为 CBAM 注意力模块。在输电线路缺陷检测中, CBAM 能够帮助模型过滤复杂背景中的无效信息,避免背景信息干扰,帮助模型增强对如 U 型挂环等分布密集的小目标缺陷位置的关注,提升检测精度。

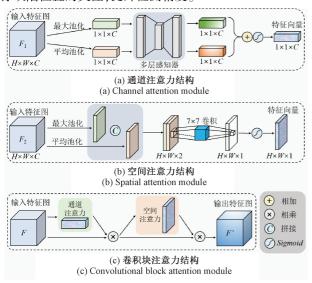


图 6 通道注意力与空间注意力结构

Fig. 6 Channel attention structure and spatial attention structure

2.2 多尺度特征融合网络

YOLOX 原模型使用 3 种尺寸的特征图分别针对图像中不同大小的目标进行检测。由于浅层网络特征图中包含的位置信息更多,而深层网络特征图中包含的语义信息更多,故尺寸为 80×80 的特征图用于检测大目标,40×40 的特征图用于检测中目标,20×20 的特征图用于检测小目标。

在输电线路巡检图像中,缺陷多为整张图像中占比很低的小目标,原网络在对其检测时可能会因丢失浅层网络中包含的位置信息而导致检测小目标的能力受到限制,因此,本文在原网络基础上增加一个检测尺度,具体为:在骨干网络的第2个残差模块后增加一个160×160的特征图输出,将其与原来的3个尺度的特征图同时输

入特征融合网络进行多尺度特征融合。

改进后的多尺度特征融合网络如图 7 所示,新增的 检测尺度由更浅层的网络输出,包含更多的定位信息,改 进后的特征融合网络拥有比原三检测尺度更强的小目标 提取能力,在特征融合网络中,新增尺度特征图与原来的 3 个尺度特征图相同,通过下采样参与特征的进一步整 合,从而实现浅层网络定位特征和深层网络语义特征的 交叉融合,在原网络的基础上增加更多目标细节信息,使 得模型对输电线路缺陷小目标的检测更加精确。

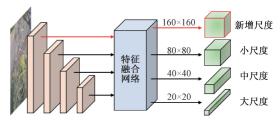


图 7 改进的特征融合网络

Fig. 7 Improved feature fusion network

2.3 优化边界框损失函数

损失函数在目标检测方法中用来评估预测的输出值与实际值之间的差距,以提升模型的运行情况。YOLOX的损失函数由 3 部分组成,分别为真实框与预测框的位置损失 L_{Reg} 、类别损失 L_{Cls} 以及置信度损失 L_{Obj} ,如式(2) 所示:

$$Loss = L_{Reg} + L_{Cls} + L_{Obj}$$
 (2)

其中,真实框和预测框的位置损失 使用交并比 IOU 进行计算。对于真实框 A 和预测框 B,方框 C 为一个能够包住 A 和 B 的最小方框,IOU 损失定义如式(3) 所示:

$$L_{IOU} = 1 - \frac{|A \cap B|}{|A \cup B|} \tag{3}$$

但在实际检测中 IOU 也存在两个较大缺点:1) 当真实框与预测框没有重叠部分时,无法判断两框的相对远近位置,如图 8(a) 所示;2) 当 IOU 相同的情况下,无法反映真实框与预测框的实际重叠方式,如图 8(b) 所示。

输电线路巡检图像中的目标小而密集,模型预测框与真实框的位置情况复杂,IOU 损失函数在不能很好地指导模型训练,限制了模型的检测能力。因此,本文使用CIOU 构建真实框与预测框的位置损失函数,如式(4)~(5)所示:

$$L_{CIOU} = 1 - \left(IOU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha \nu\right) \tag{4}$$

$$\begin{cases}
\alpha = \frac{v}{(1 - IOU) + v} \\
v = \frac{4}{\pi^2 \left(\arctan\frac{\omega^{gt}}{h^{gt}} - \arctan\frac{\omega}{h}\right)^2}
\end{cases}$$
(5)

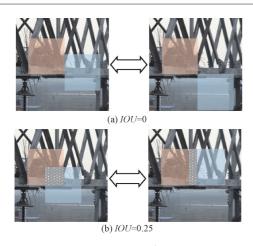


图 8 IOU 示意图 Fig. 8 Schematic diagram of IOU

其中,预测框中心点用 b 表示,真实框中心点用 b_{gt} 表示, $\rho^2(b,b^{gt})$ 表示欧氏距离,c 代表相交的预测框与目标框之间所构成最小外接矩形的对角线距离, α 是一个权重参数,v 为衡量长宽比一致性的参数。

如图 9 所示,c 为真实框和预测框的最小外接矩形对角线距离,d 为两框中心点距离,通过 c 和 d 即可在无重叠或者重叠面积相同的情况下反映两框之间的真实位置关系,克服了 IOU 的不足。

此外,除了考虑重叠面积和中心点距离,CIOU 还引入 α 和v以考虑长宽比因素,从而更加全面地衡量两框的距离,并且当真实框与预测框不重合时,能够为预测框提供移动的方向,在模型训练时加快收敛速度,同时提高缺陷检测中对于密集小目标的检测精度。

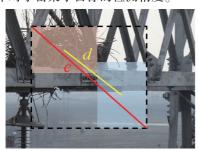


图 9 CIOU 计算示意图 Fig. 9 Schematic diagram of CIOU calculation

3 实验结果与分析

本文实验环境如下:操作系统为 Windows10,深度学习模型基于 Pytorch1.2 搭建,计算机 CPU 为 AMD R7-4800H,GPU 为 NVIDIA GTX 1660Ti,显存 6 GB,使用的 GPU 加速库为 CUDA11.2。

3.1 数据集与预处理

如图 10 所示,本文选取绝缘子缺失、鸟巢等 5 类输电线路常见缺陷进行检测。本文使用的原始图像来源于某输电检修公司的输电线路巡检图像以及网络收集,在构建数据集时参考《架空输电线路设备缺陷影像标注规范(试行)》以及 VOC 数据集格式^[32]筛选得到 698 张包含各类缺陷的图像,然后使用 labelimg 工具进行标注。由于深度学习中,样本图像数量往往影响模型训练效果,图像数量不足可能导致模型未能有效训练使得检测性能受限,因此,本文通过随机对每张图像采用镜像、色彩反转、改变亮度、唯一变换及添加高斯噪声的方式对原始图像进行扩充,从而提高训练模型的泛化能力^[33],考虑到服务器训练模型时的算力因素,将图片扩充为原来的 5 倍,得到 3 490 张图像,按照 9 : 1 : 1 随机划分为训练集、验证集以及测试集,构建数据集之后,将对模型进行训练,然后通过多组实验验证所提方法的效果。



(a) 绝缘子缺失 (a) Insulator missing

(b) 鸟巢 (b) Nest



(c) 螺栓锈蚀 (c) Bolt rusted



(d) U型挂环锈蚀 (d) Ushackle rusted



(e) DB调整板锈蚀 (e) DB plate rusted

图 10 输电线路部件及缺陷目标

Fig. 10 Transmission line components and defect targets

3.2 模型训练

在模型训练时,输入的图像尺寸统一调整为640×640,IOU 阈值设定为0.5,前100轮训练中使用预训练权重初始化主干网络参数并保持其不变,初始学习率设定为1×10⁻³,后200轮允许骨干网络变化,初始学习率设定为1×10⁻³,每个批次训练4张图片,共训练300轮,所有模型均按照此参数设定进行训练。

改进前后 YOLOX 算法的迭代损失曲线如图 11 所示,其中,实线为改进后 YOLOX 模型训练损失变化,虚线表示原始 YOLOX 模型训练损失变化。可以看出,算法训练在前 20 轮迭代中损失下降迅速,随后平稳,说明骨干网络以外的参数已经区域收敛,在 100 轮时骨干网络参数开始进行调整,损失函数继续下降,直到 200 轮后几乎

不再变化,两种模型在 300 轮附近已经收敛。对于不同模型,均取损失值最低的权重载入模型进行实验。

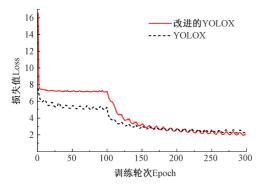


图 11 训练中损失函数下降曲线

Fig. 11 Decline curve of loss function in training

3.3 评价标准

为衡量所提方法检测的有效性,采用准确率(Precision)、召回率(Recall)、平均精度(AP)以及平均精度均值(mAP)对模型进行评价,如式(6)~(9)所示:

$$Precision = \frac{TP}{TP + FP} \tag{6}$$

$$Recall = \frac{TP}{TP + FN} \tag{7}$$

$$AP = \int_0^1 p(r) \, \mathrm{d}r \tag{8}$$

$$mAP = \frac{\sum AP}{N(Class)} \tag{9}$$

式中:TP 表示检测正确的正样本、TN 表示检测正确的负样本(true negatives,)、FP 表示检测错误的正样本、FN 表示检测错误的负样本,N 为目标类别个数。

3.4 不同超分辨率重建方法对输电线路缺陷检测结果 的影响

为验证本文所提检测方法中超分辨率 Real-ESRGAN 网络的有效性,使用改进后的 YOLOX 模型对 3 种典型的超分辨率网络重建输电线路图像后的结果进行对比,结果如图 12 所示。

图 12(b) 所示为使用 SRCNN 方法重建的结果, SRCNN 首次将深度学习应用于超分辨率领域,对比原图可以看出,在绝缘子串以及金具图像的细节部分有一定提升,但效果比较有限,改进后的模型仅检测到了一个绝缘子缺失以及两个锈蚀的 DB 调整版;图 12(c)使用的ESPCN 在超分辨中提出亚像素卷积并将其应用,可以看出相对于 SRCNN,图像质量有了进一步的提升;图 12(d)为 SRGAN模型,其首次将生成对抗网络应用于超分辨率重建,重建后的效果有了较大提升,可以明显看出,绝缘子串的轮廓相比 ESPCN 更加清晰,且右图中模型能

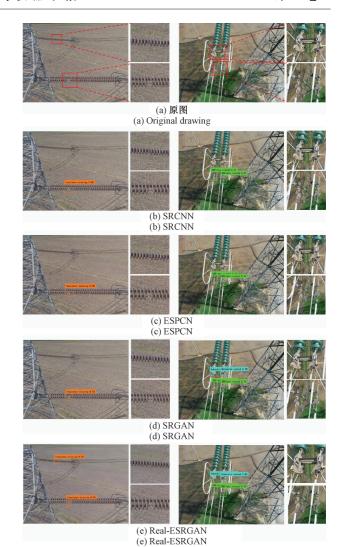


图 12 不同超分辨率网络处理后图像的检测结果 Fig. 12 Image detection results after different super-resolution network processing

够检测到两个之前漏检的 U 型挂环;图 12(e)即为本文 所使用的 Real-ESRGAN 重建结果,虽然图像有轻微失真,但重建的细节已经非常丰富,放大后也很清晰,并且在该重建图像的基础上,改进的 YOLOX 模型检测到了图 12(b)、(c)、(d)方法漏检的绝缘子缺失小目标。综上,前3种方法重建后的图像检测结果都出现了不同程度的漏检且主观上清晰度不够,说明本文使用的 Real-ESRGAN 重建方法的在输电线路缺陷目标检测任务中有着更好的表现。

3.5 YOLOX 网络改进对比实验及消融实验

本文在 YOLOX 主干网络使用 CBAM 注意力改进策略进行特征权重的分配,为探究不同注意力机制对网络检测能力的影响,在主干网络中嵌入不同的注意力模块进行实验,检测结果如表 1 所示。使用经典注意力 SE 模

(%)

块^[34]、ECA 模块^[35]以及 CBAM 注意力在网络中同一位置嵌入然后对比其检测精度,可以看出,主干网络中嵌入注意力机制均能提升模型的检测精度,且本文使用的CBAM 对网络检测性能的提升效果最好。

表 1 不同注意力机制对模型精度的影响

Table 1 Effects of different attention mechanisms on model accuracy

注意力类别	不添加	SE	ECA	CBAM
mAP	88. 37	89. 47	88. 93	89. 93

为进一步分析每个改进点对 YOLOX 模型的效果,设计了采用不同改进策略的 YOLOX 模型对经过 Real-ESRGAN 超分辨率重建后图像检测结果的消融实验,以评估不同改进对输电线路缺陷目标检测模型的影响,结果如表 2 所示。

表 2 YOLOX 网络不同改进的消融实验
Table 2 Ablation Experiment of yolox network
with different improvements

实验组别	1	2	3	4
YOLOX 网络	$\sqrt{}$	$\sqrt{}$	$\sqrt{}$	
CBAM		$\sqrt{}$	$\sqrt{}$	$\sqrt{}$
四尺度检测			$\sqrt{}$	$\sqrt{}$
CIOU				$\sqrt{}$
mAP/%	88. 37	89. 93	92. 58	93. 27

表2中第1组实验为使用未改进的YOLOX模型进行检测,第2、3、4组分别为在前一个模型的基础上使用CBAM改进骨干网络、使用四尺度特征融合网络以及使用CIOU计算损失函数的模型检测实验。从表2中可知,在骨干网络中加入CBAM注意力机制后,模型的特征提取能力有所提高,模型检测精度提高了1.56%,在此基础上,特征融合网络增加新的检测头,针对线路中的绝缘子缺失、鸟巢、U型挂环锈蚀等小目标进行优化,使得检测精度提升了2.65%,实验4进一步优化损失函数,同时考虑预测框与真实框的重叠面积、中心点面积等多方面因素,提升模型对预测框与真实框位置的感知,从而使得模型对密集输电线路缺陷目标检测的鲁棒性增强,模型精度提升0.69%。

3.6 本文方法与其他目标检测方法检测结果对比

对本文所提结合超分辨率重建和多尺度特征融合的 检测方法与未进行超分辨率重建的现有模型的检测结果 进行对比,为了更加清晰地反映各个类别目标的检测效 果,将每类输电线路缺陷目标的平均精度均值对比如 表3所示。

表 3 不同检测方法的精度对比 Table 3 Accuracy comparison of different detection methods

(%)

缺陷目标	SSD	YOLOv3	Faster	本文
			R-CNN	方法
绝缘子缺失	91. 23	96. 59	98. 51	99. 45
鸟巢	93.72	95. 52	98. 87	99. 81
螺栓锈蚀	49. 56	56. 78	61.21	75. 31
DB 调整版锈蚀	86. 81	90. 12	89. 34	96. 49
U 型挂环锈蚀	81.62	80. 98	85. 49	95. 31
mAP	80. 59	84.00	86.68	93. 27

与表 3 中同为单阶段检测方法的 SSD、YOLOv3 相比,本文方法的 mAP 分别高出 12.68%和 9.27%,与两阶段检测方法 Faster R-CNN 相比,本文方法的 mAP 高出 6.59%,故本文方法在一定程度上优于部分单阶段和两阶段的检测模型。整体而言,本文方法由于采用了超分辨率重建图像,所检测的图像质量更高,因而在各类目标上均有着更高的精度,并且,在 U 型挂环以及螺栓锈蚀两个目标的检测中,本文方法相比现有模型提升较大,说明本文方法在输电线路小目标以及密集目标检测中的鲁棒性较好。

4 结 论

针对输电线路巡检中部分图像清晰度不高且缺陷目标小而密集造成的难以检测的问题,提出一种结合超分辨率重建和多尺度特征融合的输电线路缺陷检测方法。首先使用 Real-ESRGAN 超分辨率网络重建图像以提高图像质量,然后使用改进的多尺度 YOLOX 网络对缺陷目标进行检测。对比多种经典图像重建方法以及经典检测模型后可知,Real-ESRGAN 对线路缺陷图像的重建效果最好,改进的 YOLOX 对 5 种缺陷的检测精度最高,达到93.27%,所提方法鲁棒性好,检测效果优势明显,在输电线路自主巡检研究中具有一定的参考价值。

参考文献

- [1] 胡毅,刘凯,吴田,等. 输电线路运行安全影响因素分析及防治措施[J]. 高电压技术, 2014, 40(11): 3491-3499.
 - HU Y, LIU K, WU T, et al. Analysis of influential factors on operation safety of transmission line and countermeasures [J]. High Voltage Engineering, 2014, 40(11): 3491-3499.
- [2] 赵振兵,张薇,翟永杰,等. 电力视觉技术的概念、研究现状与展望[J]. 电力科学与工程,2020,36(1):1-8.
 - ZHAO ZH B, ZHANG W, ZHAI Y J, et al. Concept,

[15]

- research status and prospect of electric power vision technology[J]. Electric Power Science and Engineering, 2020, 36(1): 1-8.
- [3] 林海雪. 现代电能质量的基本问题[J]. 电网技术, 2001(10): 5-12.

 LIN H X. Main problems of modern power quality[J]. Power System Technology, 2001(10): 5-12.
- [4] 赵振兵,蒋志钢,李延旭,等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报, 2021, 26(11): 2545-2560.

 ZHAO ZH B, JIANG ZH G, LI Y X, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26(11): 2545-2560.
- [5] 宋伟,左丹,邓邦飞,等. 高压输电线防震锤锈蚀缺陷检测[J]. 仪器仪表学报, 2016, 37(S1): 113-117. SONG W, ZUO D, DENG B F, et al. Corrosion defect detection of earthquake hammer for high voltage transmission line [J]. Chinese Journal of Scientific Instrument, 2016, 37(S1): 113-117.
- [6] 陈晓娟,吴英石,赵亮. 基于随机 Hough 变换的 OPGW 防震锤识别[J]. 黑龙江电力, 2010, 32(1): 1-2,5. CHEN X J, WU Y SH, ZHAO L. Identification of OPGW vibration damper based on random Hough transformation[J]. Heilongjiang Electric Power, 2010, 32(1): 1-2,5.
- [7] 金立军,胡娟,闫书佳. 基于图像的高压输电线间隔棒故障诊断方法[J]. 高电压技术, 2013, 39(5): 1040-1045.

 JIN L J, HU J, YAN SH J. Method of spacer fault diagnose on transmission line based on image procession[J]. High

Voltage Engineering, 2013, 39(5): 1040-1045.

- [8] 金立军, 闫书佳, 刘源. 基于类 Haar 特征与级联 AdaBoost 算法的防震锤识别[J]. 系统仿真学报, 2012, 24(9): 1806-1809.

 JIN L J, YAN SH J, LIU Y. Vibration damper recognition based on Haar-like features and cascade AdaBoost classifier [J]. Journal of System Simulation,
- [9] 付晶,邵瑰玮,吴亮,等. 利用层次模型进行训练学习的线路设备缺陷检测方法[J]. 高电压技术, 2017, 43(1): 266-275. FU J, SHAO G W, WU L, et al. Defect detection of line facility using hierarchical model with learning algorithm[J].

2012, 24(9): 1806-1809.

[10] 廖瑞金,王有元,刘航,等. 输变电设备状态评估方法的研究现状[J]. 高电压技术, 2018, 44(11): 3454-3464.

High Voltage Engineering, 2017, 43(1): 266-275.

- LIAO R J, WANG Y Y, LIU H, et al. Research status of condition assessment method for power equipment[J]. High Voltage Engineering, 2018, 44(11): 3454-3464.
- [11] GIRSHICK R. Fast R-CNN [C]. 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 1440-1448.
- [12] REN S Q, HE K M, GIRSHICK R, et al. Faster RCNN: Towards realtime object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017. Venice, Italy. New York; IEEE, 2017; 2980-2988.
- [14] 汤踊,韩军,魏文力,等. 深度学习在输电线路中部件识别与缺陷检测的研究[J]. 电子测量技术, 2018, 41(6): 60-65.

 TANG Y, HAN J, WEI W L, et al. Research on part recognition and defect detection of transmission line in deep learning[J]. Electronic Measurement Technology, 2018, 41(6): 60-65.
- Faster R-CNN 典型金具检测方法[J]. 高电压技术, 2020, 46(9): 3018-3026.

 ZHAO ZH B, LI Y X, ZHEN ZH, et al. Typical fittings detection method with Faster R-CNN combining KL divergence and shape constraints [J]. High Voltage Engineering, 2020, 46(9): 3018-3026.

赵振兵,李延旭,甄珍,等. 结合 KL 散度和形状约束的

- [16] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [17] 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, NV, USA. New York: IEEE, 2016: 779788.
- [18] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. arXiv preprint arXiv: 1804.02767, 2018.
- [19] 赵振兵,江爱雪,戚银城,等. 嵌入遮挡关系模块的 SSD 模型的输电线路图像金具检测[J]. 智能系统学报, 2020, 15(4): 656-662.
 ZHAO ZH B, JIANG AI X, QI Y CH, et al. Fittings detection in transmission line images with SSD model

embedded occlusion relation module [J]. CAAI Transactions on Intelligent Systems, 2020, 15 (4): 656-662.

- [20] 缪希仁, 林志成, 江灏, 等. 基于深度卷积神经网络的输电线路防鸟刺部件识别与故障检测[J]. 电网技术, 2021, 45(1): 126-133.

 MIAO X R, LIN ZH CH, JIANG H, et al. Fault detection of power tower anti-bird spurs based on deep convolutional neural network [J]. Power System Technology, 2021, 45(1): 126-133.
- [21] WANG X, XIE L, DONG C, et al. Real-ESRGAN: Training real-world blind super-resolution with pure synthetic data [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1905-1914.
- [22] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. arXiv preprint arXiv: 2107.08430, 2021.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer vision (ECCV), 2018: 3-19.
- [24] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [25] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution [C]. European Conference on Computer Vision. Springer, Cham, 2014; 184-199.
- [26] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016; 1874-1883.
- [27] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017; 4681-4690.
- [28] KANG X, LIU L, MA H. ESR-GAN: Environmental signal reconstruction learning with generative adversarial network [J]. IEEE Internet of Things Journal, 2020, 8(1): 636-646.
- [29] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. CVPR 2016: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [30] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature

- pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017; 2117-2125.
- [31] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [32] EVERINGHAM M, WINN J. The PASCAL visual object classes challenge 2012 (VOC2012) development kit[J]. Pattern Anal. Stat. Model. Comput. Learn., Tech. Rep., 2012, 2007; 1-45.
- [33] ENGSTROM L, TRAN B, TSIPRAS D, et al. A rotation and a translation suffice: Fooling cnns with simple transformations [J]. 2018.
- [34] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [35] ZHANG Q L, YANG Y B. Sa-net; Shuffle attention for deep convolutional neural networks [C]. ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2021; 2235-2239.

作者简介



刘兰兰,2009年于中南大学获得学士学位,2014年于中国科学院大学获得博士学位,现为国网湖南省电力有限公司超高压输电公司高级工程师,主要研究方向为智能输电运维。

E-mail: 0603050307@ 163. com

Liu Lanlan received her B. Sc. degree form the Central South University in 2009, Ph. D. degree from the University of Chinese Academy of Sciences in 2014, respectively. Now she is a senior engineer of the ultra-high voltage transmission company of State Grid Hunan Electric Power Co., Ltd. Her main research interests include intelligent transmission operation and maintenance.



万旭东(通信作者),2020 年于湖北工业大学获得学士学位,现为三峡大学硕士生,主要研究方向为输电线路智能检测和电力深度视觉。

E-mail: 416208625@ qq. com

Wan Xudong (Corresponding author)

received his B. Sc. degree from Hubei University of Technology in 2020. He is now a M. Sc. candidate of China Three Gorges University. His main research interests include intelligent detection of transmission lines and power depth vision.