

基于语义信息分块的高像素导线缺陷目标识别

廖如超¹, 张英¹, 廖建东¹, 袁新星², 康泰钟²

(1. 广东电网有限责任公司机巡作业中心, 广东 广州 510145; 2. 北京数字绿土科技有限公司, 北京 100089)

摘要:输电导线作为架空输电线路重要的部件, 在巡检过程中如果被发现存在缺陷可能导致重大电力事故的发生。对高像素无人机巡检图像进行导线缺陷识别所需计算量大且缺陷目标区域范围小, 若在无人机巡检过程中实现实时较高精度的识别能够大大加快巡检效率。本文提出一种利用无人机搭载板载计算机实时处理高清摄像头采集的高分辨率导线图像识别导线缺陷的方法。该方法首先采用语义信息分块将导线图像降采样处理, 然后利用分割网络获取低像素导线分割区域并对其网格化, 裁剪出多个导线区域, 将导线区域以降采样比例映射回高像素原图像后再裁剪出多个导线高分辨率导线区域, 批次输入 yolov3 网络进行导线缺陷识别, 最后根据输入的高精度关注区域在原图像的相对位置获得缺陷识别目标区域。实验结果表明, 提出的识别方法可以实现对相机采集的高分辨率导线图像进行高帧率的缺陷实时识别, 为无人机智能化巡检提供新的思路。

关键词:高像素; 分块; 降采样; 目标识别; 实时

DOI:10.19781/j.issn.1673-9140.2022.03.025 中图分类号:TM755 文章编号:1673-9140(2022)03-0206-07

Research on defect target identification of high pixel wire image based on semantic information patching

LIAO Ruchao¹, ZHANG Ying¹, LIAO Jiandong¹, YUAN Xinxing², KANG Taizhong²

(1. Patrol Operation Center of Guangdong Power Grid Co., Ltd., Guangzhou 510145, China;

2. Beijing GreenValley Technology Co., Ltd., Beijing 100089, China)

Abstract: As an important component of overhead transmission lines, transmission wires may cause major power accidents if they are found to be defective during the inspection process. The identification of wire defects in high-pixel UAV inspection images requires a large amount of calculation and the target area of defects is small. If real-time high-precision identification is realized in the UAV inspection process, the inspection efficiency can be greatly accelerated. This paper proposes a method to identify wire defects by using the on-board computer of UAV to process high-resolution wire images collected by high-definition cameras in real time. The method firstly uses semantic information patching to sub-sample the wire image, and then uses the segmentation network to obtain the low-pixel wire segmentation areas and mesh them. Multiple wire areas are cropped out and mapped back to the high-pixel original image at a down-sampling ratio. Then a number of high-resolution wire areas are cut out and enter the yolov3 network in batch for wire defect recognition. Finally the defect recognition target area is produced according to the input high-precision

收稿日期:2020-12-17; 修回日期:2021-06-17

基金项目:中国南方电网有限责任公司科技项目(GDKJXM20184731)

通信作者:廖如超(1990-),男,硕士,工程师,主要从事电网智能巡检技术研究;E-mail:525492887@qq.com

attention area in the relative position of the original image. The experimental results show that the identification method proposed in this paper can realize the real-time identification of high frame rate defects in the high-resolution wire images collected by the camera in the process of UAV patrolling, which provides a new idea for the intelligent patrolling of UAV.

Key words: high-pixel image; patching; down-sampling; object identification; real-time

输电导线是输电系统中重要的设备,而输电导线需要跨越复杂的地理环境,如高山深林、沙漠戈壁^[1-4]。在复杂的环境中,输电导线面临着风吹雨打、电闪雷击、冰敷等恶劣天气带来的损害^[5],极易造成雷击、散股、断线等电力故障^[6]。这些电力故障若及时发现和处理,极易引发电力事故。在巡检过程中,运维人员能够对导线进行精细化巡检,发现导线缺陷,并及时汇报反应处理,对电网安全可靠运行有着重要实际意义。

对架空线路的导线检测,若依靠人工巡检,会存在检测效率低、工作强度大、人力管理成本大、安全性低等问题。近些年,为了提高巡检效率和降低巡检成本,大部分架空线路巡检运维工作都会通过无人机、直升机、机器人等巡检手段采集导线图像,并对其进行缺陷识别。而所采集的图像信息还需人工检验,缺陷自动化识别是进一步提高巡检效率的关键。图像处理、深度学习等技术在自动化巡检流程中得到了广泛的应用^[7-8]。文献[9]通过设计模拟退火微粒群算法实现导线图像分割后,利用改进的Freeman链码表示法对输电导线进行目标提取,复原缺失部分实现导线完整提取,其算法仅实现其导线的提取部分,并没有定位其缺陷位置。在导线缺陷识别方面,文献[10]通过感知定律的共线性和分段灰度的相似度实现检测导线上的断股与异物检测的研究;文献[11]应用小生境遗传算法寻找最优的Gabor滤波器参数,在利用该分割阈值和图像能量二值化得到导线缺陷检测结果;文献[12]提出通过纹理斜率分布的散股判定模型,而算法在复杂背景如树木、道路等效果不佳。在深度学习应用中,文献[13]提出利用径向基概率神经网络实现输电导线缺陷状态识别,而该方法不能全面覆盖导线缺陷情况;在高分辨率图像目标识别的研究中,文献[14]通过改进Yolov3的残差网络模块,实现对高分辨的遥感图像中飞机的目标识别,获得了99.72%的准确率和98.34%的召回率;文献[15]通过改进Faster R-CNN,实现了对高分辨率的遥感图像中房屋等特定

目标的识别。但以上算法未考虑实时识别的需求。

本文基于切片分块的思想^[16]对导线图像分块处理,从而减少目标识别模型的输入大小,以此减少目标识别模型的计算时间,满足实时识别需求。另外,导线图像分块处理需对导线区域进行识别,利用现有主流图像分割模型U-net实现对图像导线区域分割,并探索U-net的输入大小会对模型计算时间的影响。在此基础上,为了方便对导线区域作分块处理,通过网格化图像实现导线区域位置的定位。进一步地,为了提高对导线区域中小目标识别的准确率,通过导线区域位置和降采样比例提取高分辨率原图像的导线区域。最后,将该提取的导线区域图像作为目标识别模型的输入,其中目标识别模型采取骨干网络为Mobilenetv2的Yolov3模型,对导线缺陷如断股、散股、烧蚀等进行目标识别,对分割过程和识别过程的损失函数进行分别优化。为了验证在具体场景中的实时性和识别率是否达到巡检需求,利用由历史巡检数据中的导线缺陷样本进行测试,实际测试效果显示该方法能够满足无人机巡检过程对导线缺陷识别需求。

1 语义分割导线区域

为了获取导线目标区域,需要对巡检图像中的导线区域进行提取。深度学习技术在图像分割任务上有着较好的效果,如U-net模型。图像分类任务在深度学习中一般通过卷积神经网络实现(如VGG和Resnet^[17])。卷积神经网络会完成特征提取后加入全连接层,最后通过Softmax计算获得输入图像的分类概率向量。而概率向量维度为1,即当前分类任务只能实现对整个图像分类,而不能实现对图像像素的分类。图像分割任务区即是对图像像素的分类任务。FCN(fully convolutional networks for semantic segmentation)^[18]是首个语义分割网络,提出通过反卷积或插值放大等上采样方式将卷积层得到的特征图从小尺度的特征图恢复原来图像大小的尺度,最后以连接一个二维的softmax得到图像中

每个像素的分类概率。U-net 与 FCN 基本思想相同,而 FCN 为了实现细节的分割,采用不同尺度下的特征图相加(Add)融合使得分割精度得到上升。另外,U-net 以拼接(Concat)的方式融合特征图^[19],可以通过更小的训练集实现图像较好的分割精度。

本文中的 U-net 的网络结构采用 4 层对称结构,如图 1 所示。在实际巡检中,无人机采用相机 Z-Fusions,其拍摄图像像素为 3840×2160。U-net 网络的识别速度和分割精度与网络输入大小降采样比例 768 有关,如图 2 所示。

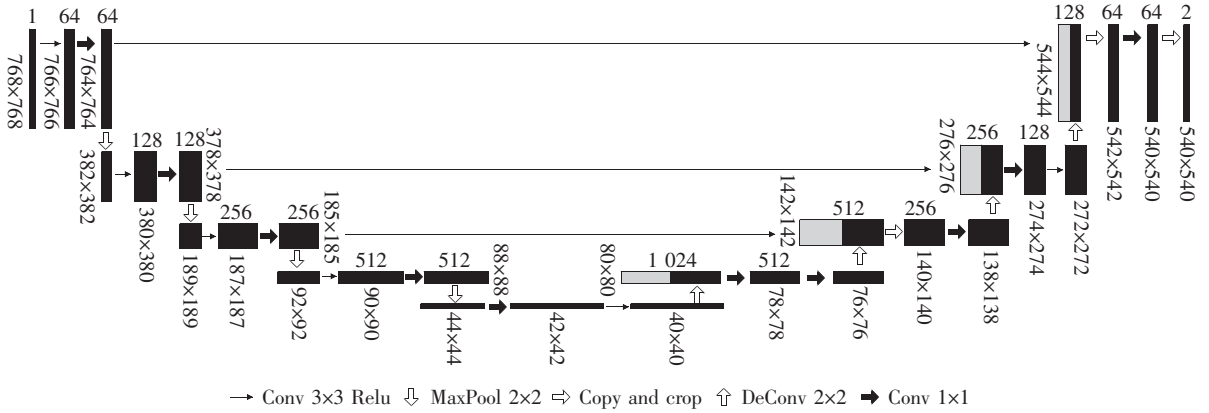


图 1 U-net 网络结构

Figure 1 Structural diagram of U-net network




图 2 输入大小降采样比例与识别精度和识别速度关系

Figure 2 Relationship amongst input size down-sampling ratio and recognition accuracy and recognition speed

在识别速度和分割精度之间权衡,为了方便后续导线区域定位和区域图像输入至目标模型,可对原图像通过线性插值方式调整其像素大小为 3 840 × 3 840,然后降采样 K 倍,得到低像素图像,如图 3 所示。




图 3 高像素图像降采样后的低像素图像

Figure 3 Low-pixel image after high-pixel image down-sampling

低像素图像作为本文的 U-net 网络输入,其损失函数如为

$$E = \sum_{x \in \Omega} \omega(x) \log(p_{l(x)}(x)) \quad (1)$$

式中 x 为二维平面 Ω 上的像素位置; $\alpha_k(x)$ 为网络最后输出层中 x 对应 k 个通道的值; K 为类别总数。 $p_k(x)$ 为像素 x 属于 k 类的概率,其表达式为

$$p_k(x) = \exp(\alpha_k(x)) / (\sum_{k'=1}^K \exp(\alpha_{k'}(x))) \quad (2)$$

式中 $p_l(x)$ 为 x 在真实标签样本所在通道上的输出概率。另外 $\omega(x)$ 为类别权重,根据训练数据集中的各类别出现的频率来进行统计,类别出现的频率越高,给予的权重越低,频率越低则权重越高。加权交叉熵能够缓解前景像素数量远远小于背景像素的数量时导致模型偏向背景的问题。训练过程中采用 Adam 优化函数,其中,学习率 $l_r=0.001$, $\beta_1=0.9$, $\beta_2=0.99$, $\epsilon=10^{-8}$ 。为了网络能在复杂背景下得到好的分割效果,需要在多个角度、不同光照下、不同背景下采集样本数据,而缺陷图像不容易获取,所以采用人工提取导线区域后添加至新背景图的方式扩充数据集,在此基础上进行对样本数据进行数据增强扩充数据集数量,需标记的导线区域和实际模型输出如图 4 所示。




图 4 U-net 分割训练集标记图和 U-net 输出的分割图

Figure 4 U-net segmentation training set and U-net output partitioning graph

2 导线区域切片分块

通过图像分割将导线区域提取后,为了减少目标识别模型输入的大小,可通过网络化分割图进行切片分块,并获取导线更小的分块图像。该研究通过导线分割图进行 $N \times N$ 网格切片处理,得到 $N \times N$ 个切片图像。为了区分导线切片图像和背景切片图像,可计算切片图像导线类别概率总和 S ,当 S 大于阈值 $\beta=0$ 时,可认为该切片图像中存在导线区域。标记每个切片在分割图的相对位置 $P(i, j)$,其中, $0 \leq i \leq N, 0 \leq j \leq N$,切片图像如图 5 所示,切片图像大小为 $540/N \times 540/N$ 。



图 5 低像素分割图像网格化后生成批量切片

Figure 5 An example image of batch slicing generated after low-pixel segmentation image gridding

此时导线区域已被切片分块,其大小要远少于原来图像大小。而导线切片图像已被降采样方式降低像素,其缺陷特征信息将减少,在后续目标识别中会降低对小目标的缺陷识别精度。那么可根据低像素切片图像的位置信息和降采样比例 K 映射至高像素图像上,得到高像素切片图像,如图 6 所示,并作为后续目标识别网络的输入。




图 6 高像素切片

Figure 6 High-pixel slicing map

3 导线缺陷识别

通过语义分割导线区域,定位导线区域切片位置,将原本高像素图像划分为含有导线信息区域的多个切片图像,输入大小大大减少。然后需对这些切片图像进行导线缺陷识别,其在图像任务中属于目标识别任务。而 YOLOv3 是目前落地应用广泛的目标检测网络,其骨干网络为 Darknet-53 网络,其具有网络实现简单、处理速度快的特点。Darknet-53 是基于 Resnet 的残差网络思想,并采用多尺度特征融合计算从中提取 3 个尺度特征图对不同尺度下的特征图进行特征融合,实现对小尺度的目标识别。而 Darknet-53 网络规模大,其对硬件要求很高,在板载计算机有限的计算能力下识别速度无法满足实时需求。在实际巡检场景中对目标检测种类数量不多,可以采用轻量级的网络作为骨干网络。其中,MobileNet 系列是由 Google 提出的移动端轻量级网络,MobileNetv1 通过深度可分离卷积层 (Convolution Depth Wise Layers) 将标准卷积分解为 2 个更小操作分别为 Depthwise Convolution 和 Point-Wise Convolution,以此提高计算效率,而 MobileNetv2 设计了 Linear Bottlenecks 和反转残差 (Inverted Residuals) 模块进一步提高准确率^[20],模块结构,如图 7 所示。

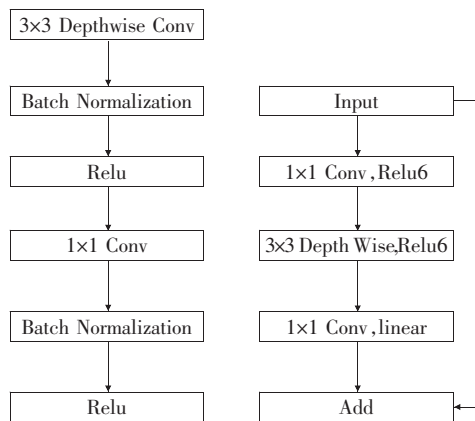


图 7 Depthwise Convolutional Layers 和 Linear Bottlenecks 和 Inverted Residuals 结构

Figure 7 Structural diagram of depthwise convolutional layers and linear bottlenecks and inverted residuals

为了减少目标识别网络的计算量的同时保持其特征提取的能力,可以采取 MobileNetv2 作为该研究中目标识别网络的骨干网络,其改进的 YOLOv3 检测网络结构如图 8 所示。

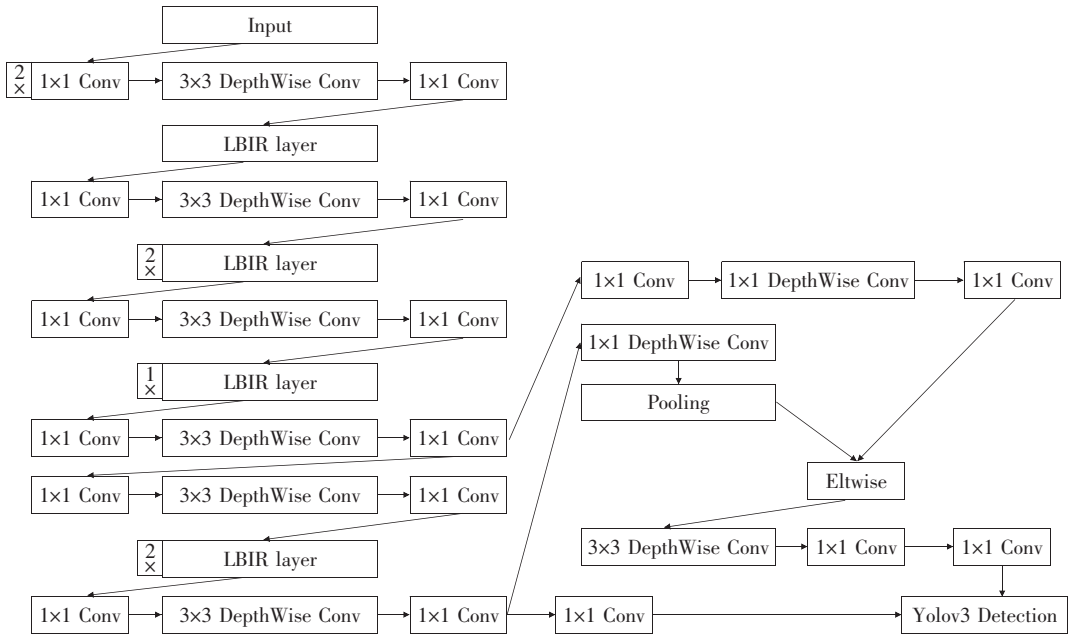


图 8 Mobilenetv2-Yolov3 结构

Figure 8 Structural diagram of Mobilenetv2-Yolov3

4 实验结果与分析

4.1 实验条件

为了验证该研究方法在具体场景中的实时性和识别率是否达到巡检需求,搭建实验平台验证其效果。首先,硬件平台采用 Jetson AGX Xavier (8GB)的板载计算机,软件框架通过 Caffe 编写模型代码和使用量化技术实现模型加速。通过历史采集的导线缺陷图像构成该研究的样本数据集,数据集样本数量为 500,并对该数据集进行数据增强,散股、断股、烧蚀的标注比例为 1 : 1 : 2,训练集与验证集的比例为 7 : 3 划分后进行训练。其中,网格划分大小 N 为 8,降采样大小 K 为 5。采取 VOC (Visual Object Class)数据集评价指标标准,即当分割精度大于或等于 0.5 时,预测框命中。其实验结果以网络的 mAP(mean Average Precision)、召回率(Recall)、识别时间(Inference Time)为评价指标,对比将输入图像直接降采样为网络标准输入为 416×416 的 Darknet53-Yolov3、采取语义分块后的输入大小为 480×480 ,并且使用不同骨干网络网络的 Patched-tiny-yolov3、Patched-darknet53-yolov3、Patched-mobilenetv2-yolov3、Mask-RCNN 效果。

4.2 结果分析

实验算法对比如表 1 所示,实验算法的效果如

图 9 所示。由实验可知,若直接对输入图像进行降采样到低像素图像大小后再输入 Yolov3 网络,会让原本高像素图像小目标特征丢失,如图 10 所示,如烧蚀等细微的目标检测无法实现,导致平均识别率很低,各个类别的识别率如图 11 所示。通过切片分块映射得到高像素图像后,输入网络识别精度得到提升, Mobilenetv2 为骨干网络的 Yolov3 网络比其

表 1 各算法性能对比

Table 1 Performance comparison table of each algorithm

算法	mAP/%	召回率/%	识别时间/s
Darknet53-Yolov3	28.1	37.0	0.157
Patched-Tiny-Yolov3	79.2	81.1	0.136
Patched-Darknet53-Yolov3	90.2	91.1	0.164
Patched-Mobilenetv2-Yolov3	92.1	90.8	0.122
Mask-RCNN	88.3	87.1	0.321



图 9 高像素导线缺陷识别效果

Figure 9 Effect picture of high-pixel wire defect identification




图 10 分块高精度图片和降采样后裁剪的低精度图片对比

Figure 10 Comparison of patched high-precision image and low-precision image after down-sampling

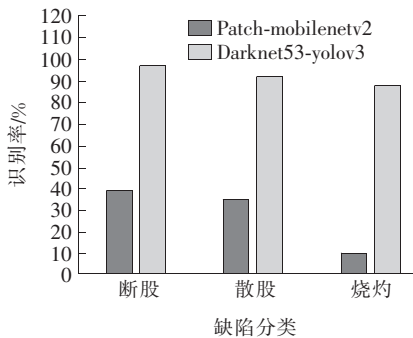


图 11 不同模型下的各个类别识别率对比

Figure 11 Comparison of recognition rate in each category under different models

他网络精度差别不大的情况下速度更快,能够满足实时需求,而 Mask-RCNN 在识别精度和处理速度上都难以满足。

5 结语

在对无人机巡检采集的高像素导线图像进行缺陷实时识别过程中,导线腐蚀等缺陷在高像素图像中属于小目标,若采取直接降采样方法进行目标检测,其缺陷特征信息会丢失,无法实现高召回率的目标检测需求。此外,由于板载计算机算力有限,若直接将原图像作为目标识别网络输入,则小目标识别准确度将降低。本文通过切片重映射方法获取高像素切片图像,大大减少目标检测区域和计算量,并加快了识别速度。实验结果体现出本文提出方法的有效性,该方法为实现高像素图像小目标识别及无人机智能巡检的研究提供了新思路。

参考文献:

[1] 全国输配电技术协作组,输电线路无人机技术组. 无人机电力输电线路巡检应用发展报告[M]. 北京:中国电力出版社,2016:3-5.

[2] 李映国,杨宏,徐郁,等. 基于 Alexnet 网络的绝缘子自爆无人机巡检技术研究[J]. 智慧电力,2021,49(8):104-109.
LI Yingguo, YANG Hong, XU Yu, et al. Insulator Self-explosive inspection technology based on alexnet network in UAV grid inspection[J]. Smart Power,2021,49(8):104-109.

[3] 许保瑜,赵毅林,陈庆宁,等. 输电线路移动式不间断自主智能巡检技术研究[J]. 电测与仪表,2021,58(11):157-163.
XU Baoyu, ZHAO Yili, CHEN Qingning, et al. Research on mobile uninterrupted autonomous intelligent inspection technology for transmission line[J]. Electrical Measurement & Instrumentation, 2021, 58(11):157-163.

[4] 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.

[5] 宋耐超,王瑞琦,李明明,等. 多自然灾害下的架空输电线路运行风险评估[J]. 电力系统保护与控制,2021,49(19):65-71.
SONG Naichao, WANG Ruiqi, LI Mingming, et al. Risk assessment of overhead transmission lines under multiple natural disasters[J]. Power System Protection and Control,2021,49(19):65-71.

[6] 黄郑,王永强,王红星,等. 基于云雾边异构协同的无人机智慧巡检系统[J]. 中国电力,2020,53(4):161-168.
HUANG Zheng, WANG Yongqiang, WANG Hongxing, et al. Design and application of UAV intelligent inspection system for transmission lines based on cloud and fog-edge heterogeneous collaborative computing architecture[J]. Electric Power, 2020, 53(4):161-168.

[7] 冯敏,罗旺,余磊,等. 适用于无人机巡检图像的输电线路螺栓检测方法[J]. 电力科学与技术学报,2018,33(4):135-140.
FENG Min, LUO Wang, YU Lei, et al. A bolt detection method for pictures captured form an unmanned aerial vehicle in power transmission line inspection[J]. Journal

- of Electric Power Science and Technology, 2018, 33(4): 135-140.
- [8] 唐波,覃乔,黄力. 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[J]. 电力科学与技术学报, 2020, 35(4): 13-19.
TANG Bo, QIN Qiao, HUANG Li. Transmission line aerial image recognition of insulator strings based on color model and texture feature[J]. Journal of Electric Power Science and Technology, 2020, 35(4): 13-19.
- [9] 孙凤杰,杨镇澧,李媛媛,等. 输电导线图像目标识别方法[J]. 中国图象图形学报, 2012, 17(3): 349-356.
SUN Fengjie, YANG Zhenhuan, LI Yuanyuan, et al. Methods of transmission line target recognition [J]. Journal of Image and Graphics, 2012, 17(3): 349-356.
- [10] 王万国,张晶晶,韩军,等. 基于无人机图像的输电线路断股与异物缺陷检测方法[J]. 计算机应用, 2015, 35(8): 2404-2408.
WANG Wanguo, ZHANG Jingjing, HAN Jun, et al. Broken strand and foreign body fault detection method for power transmission line based on unmanned aerial vehicle image[J]. Journal of Computer Applications, 2015, 35(8): 2404-2408.
- [11] 蒋兴良,夏云峰,张志劲,等. 基于优化 Gabor 滤波器的输电导线断股图像检测[J]. 电力系统自动化, 2011, 35(15): 78-83.
JIANG Xingliang, XIA Yunfeng, ZHANG Zhijin, et al. Image detection of broken strand faults of transmission conductor based on optimized Gabor filter[J]. Automation of Electric Power Systems, 2011, 35(15): 78-83.
- [12] 张成,王卫东,杨延滨,等. 新型电缆多参量带电检测装置设计与应用[J]. 中国电力, 2021, 54(10): 144-151.
ZHANG Cheng, WANG Weidong, YANG Yanbin, et al. Design and application of a new-type power cable multi-parameter live detection device [J]. Electric Power, 2021, 54(10): 144-151.
- [13] 黄新波,章小玲,张焯,等. 基于径向基概率神经网络的输电导线缺陷状态识别[J]. 电力系统自动化, 2020, 44(3): 201-214.
HUANG Xinbo, ZHANG Xiaoling, ZHANG Ye, et al. Fault state identification of transmission wires based on radial basis probabilistic neural network[J]. Automation of Electric Power System, 2020, 44(3): 201-214.
- [14] 王井利,阎鑫. 基于 Faster R-CNN 的高分二号遥感影像特定目标识别[J]. 中国科技论文, 2019, 14(9): 985-990.
WANG Jingli, YAN Xin. Faster R-CNN based specific target recognition of GF2 remote sensing images[J]. China Sciencepaper, 2019, 14(9): 985-990.
- [15] 郑志强,刘妍妍,潘长城,等. 改进 YOLO V3 遥感图像飞机识别应用[J]. 电光与控制, 2019, 26(4): 28-32.
ZHENG Zhiqiang, LIU Yanyan, PAN Changcheng, et al. Application of improved YOLO V3 in aircraft recognition of remote sensing images[J]. Electronics Optics & Control, 2019, 26(4): 28-32.
- [16] HOU L, SAMARAS D, KURC T M, et al. Patch-based convolutional neural network for whole slide tissue image classification[C]//Proceedings of the IEEE conference on computer vision and pattern recognition, Las Vegas, USA: IEEE, 2016: 2424-2433.
- [17] 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: IEEE, 2016: 770-778.
- [18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]// Proceedings of the IEEE conference on computer vision and pattern recognition, Boston, USA: IEEE, 2015: 3431-3440.
- [19] 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, Munich, Germany, 2015: 234-241.
- [20] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]// Proceedings of the IEEE conference on computer vision and pattern recognition, Salt Lake City, USA: IEEE, 2018: 4510-4520.