Journal of Electric Power Science and Technology

Volume 38 | Issue 5

Article 17

1-15-2024

Fault detection for overhead line power equipment based on improved YOLOv4

Shurong PENG

School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China

Denggang LIU

School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China, 2030738574@qq.com

Jieni HE

School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China

Shuang LU

School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China

Sheng SU School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China Follow this and additional works at: https://jepst.researchcommons.org/journal

See next page for additional authors Recommended Citation

PENG, Shurong; LIU, Denggang; HE, Jieni; LU, Shuang; SU, Sheng; and HE, Ming (2024) "Fault detection for overhead line power equipment based on improved YOLOv4," *Journal of Electric Power Science and Technology*: Vol. 38: Iss. 5, Article 17. DOI: 10.19781/j.issn.1673-9140.2023.05.017 Available at: https://jepst.researchcommons.org/journal/vol38/iss5/17

This Scientific Research is brought to you for free and open access by Journal of Electric Power Science and Technology. It has been accepted for inclusion in Journal of Electric Power Science and Technology by an authorized editor of Journal of Electric Power Science and Technology. For more information, please contact dlxb04@163.com.

Fault detection for overhead line power equipment based on improved YOLOv4

Authors

Shurong PENG, Denggang LIU, Jieni HE, Shuang LU, Sheng SU, and Ming HE

基于改进 YOLOv4的架空线路电力设备故障检测

彭曙蓉1,刘登港1,何洁妮1,陆 双1,苏 盛1,贺 鸣2

(1.长沙理工大学电气与信息工程学院,湖南长沙410114;2.广西电网有限责任公司桂林供电局,广西桂林541000)

摘 要:针对传统目标检测算法检测精度低、速度慢的问题,提出一种改进YOLOv4的目标检测模型,对架空线路中的电杆、变压器、电杆倾斜以及绝缘子跌落4类常见的电力设备及故障进行检测。模型采用针对嵌入式平台设计的MobileNet代替原YOLOv4中的骨干网络,使模型轻量化,为进一步降低模型的运算复杂度,在其颈部网络引入深度可分离卷积,同时为了加强卷积神经网络的学习能力,在颈部网络中使用了跨阶段局部网络(cross stage partial networks,CSPNet)结构。利用改进后的模型对架空线路图像数据集进行实验,实验结果表明,该模型能够在检测精度相当的情况下将检测速度提升为原模型的1.68倍,能够更好地应用到嵌入式设备上,利用无人机实现对架空线路中常见的电力设备及故障进行实时的检测。

关键 词:故障检测;架空线路;MobileNet;YOLOv4;深度可分离卷积

DOI:10.19781/j.issn.1673-9140.2023.05.017 中图分类号:TM50,TP 391.4 文章编号:1673-9140(2023)05-0169-08

Fault detection for overhead line power equipment based on improved YOLOv4

PENG Shurong¹, LIU Denggang¹, HE Jieni¹, LU Shuang¹, SU Sheng¹, HE Ming²

(1.School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China;
 2.Guilin Power Supply Bureau, Guangxi Power Gird Co., Ltd., Guilin 541000, China)

Abstract: Aiming at the problems of low detection accuracy and slow speed of traditional target detection algorithms, an improved YOLOv4 target detection model is proposed to detect four types of common power equipment and faults in overhead lines, such as poles, transformers, pole tilts, and insulators drop. Instead of the backbone network in the original YOLOv4, MobileNet which is designed for the embedded platform is deployed in this model, making this model lightweight. In order to further reduce the computational complexity and strengthen the learning ability of the convolutional neural network, a deep separable convolution and a CSP structure is introduced in the neck network. This improved model is used to conduct experiments on the overhead line image data set, and the experimental results show that this model can increase the detection speed to 1.68 times of the original model with a equivalent detection accuracy. It can be better applied to embedded devices, and thus achieves the real-time detection of common power equipment and faults in overhead lines by drones.

Key words: fault detection; overhead line; MobileNet; YOLOv4; depthwise separable convolution

架空线路是一种必不可少的供电方式,保障其 安全、可靠地运行具有重要的意义。架空线路中常 见的电气设备主要有电杆、变压器和绝缘子等,如果这些设备出现故障,很有可能会影响电能的正常

收稿日期:2021-11-18;修回日期:2022-05-20

供应,因此对架空线路进行巡线检查是十分必要 的。以往,主要通过人工巡线的方式进行线路的故 障排查,由于架空线路很可能经过森林或高原,当 地气候、环境情况复杂,人工进行电力架空线路巡 检的工作难度大、耗时长并且效率低下。无人机的 出现使得电力巡线方式有了新的选择。文献[1]利 用2个视角可见光图像识别输电线路中的常见缺 陷,取得了较好的效果。

使用无人机对架空线路进行巡线,关键技术就 是目标检测,检测方法主要包括传统目标检测^[2]和 基于深度学习的目标检测^[3]。传统目标检测方法主 要分为区域选择、特征提取和分类器3个部分,即首 先在给定的图像上选择一些候选区域,然后对这些 区域提取特征,最后使用训练的分类器进行分类。

传统目标检测算法主要存在2个方面的问题: 一是在进行区域选择时,传统方法没有针对性,导 致大量的窗口冗余;二是人工设计的特征一般较简 单,对背景复杂画面的适应性较差^[4]。近年来,随着 人工智能技术的快速发展和应用,人们对架空线路 图像检测研究有了新的突破。目前,对架空输电线 路的图像检测研究大多以绝缘子的故障识别为主, 文献[5]利用色彩模型和纹理特征对输电线路中的 绝缘子串进行识别,作者首先对目标和背景区域进 行分割,然后对目标区域进行标定,并对目标区域 进行纹理特征识别,找出绝缘子串的位置。文献 [6]采用带反馈机制的卷积神经网络对绝缘子的各 类状态进行检测,包括完好的绝缘子、缺陷的绝缘 子以及自爆的绝缘子3种状态。文献[7]针对Fast R-CNN^[8]在生成候选框的过程中耗时较长的问题, 对其进行改进提出Faster R-CNN算法,该算法使用 区域生成网络(region proposal networks, RPN)结构 生成候选框,即候选框的生成也交给神经网络来 做,使检测速度得到了进一步的提高。文献[9]利 用改进的Faster R-CNN算法对输电线路航拍图像 中的绝缘子进行检测。文献[10]通过改进Faster R-CNN算法实现对输电线路中的脱落防震锤、完好 防震锤、掉串绝缘子和完好绝缘子等6类目标进行 识别。然而Faster R-CNN作为二阶段目标检测算 法,虽然在检测精度上占有优势,但在检测速度上 远不如一阶段目标检测算法,典型的一阶段目标检 测算法主要有文献[11]提出的只看一次(you only look once, YOLO)算法、文献[12]提出的单发多框 检测器(single shot multi box detector, SSD)算法以 及文献[13]提出的CenterNet目标检测算法等。文 献[14]提出了一种结合Inception-Resnet-v2和 YOLOv3^[15]的目标检测算法,并利用该方法对无人 机拍摄的玻璃绝缘子进行检测。针对单阶段目标 检测算法在检测精度上的不足,研究人员对YOLO 算法不断改进,文献[16]在YOLOv3的基础上进行 改进提出YOLOv4算法。由于YOLOv4目标检测 算法能够做到保证检测速度的同时提升精度,因此, 该算法是目前应用较为广泛的一种目标检测算法。

在利用无人机对架空线路进行图像检测时既 要确保检测的实时性,同时又要确保有较高的检测 精度,减少出现错检或漏检的情况,因此本文采用 检测速度和检测精度都比较高的YOLOv4作为基 本的检测框架,在YOLOv4的基础上对网络结构进 行改进,将骨干网络采用轻量型网络MobileNet^[17] 替换,颈部网络采用深度可分离卷积替换原来的常 规卷积,并在颈部网络中引入跨阶段局部网络 (cross stage partial networks, CSPNet)结构。通过 对网络的改进,来达到降低模型的大小,进而提升 模型检测速度的目的,使模型能够更好地应用到无 人机巡线。

1 算法介绍

1.1 YOLOv4算法原理

目标检测算法的网络框架一般包含输入端 (input)、骨干网络(backbone)、颈部网络(neck)和检 测头(head)4个部分,YOLOv4目标检测算法是在 YOLOv3的基础上改进得到的,其网络结构如图1 所示。

在输入端上,YOLOv4通过运用Mosaic数据增强和自对抗训练(self-adversarial training, SAT)达到扩充数据集的目的。

骨干网络是目标检测算法的核心部分, YOLOv4算法的骨干网络借鉴了CSPNet的思想, 采用的是CSPDarknet53。网络结构图中的CBM表 示经过了卷积、批标准化(batch normalization, BN) 和Mish激活函数,图1中CSPX中的X表示残差单 元(res unit)的个数,残差网络的引入是为了防止随着网络层数的增加而出现的梯度消失或梯度爆炸。

YOLOv4的颈部网络使用了空间金字塔池化 (spatial pyramid pooling, SPP)。经过SPP结构后能 够极大地增加感受野(receptive field),分离出最显著 的上下文特征。此外,其颈部网络还采用了路径聚 合网络(path aggregation network, PANet)结构,它 是在特征金字塔网络(feature pyramid network, FPN) 的基础上增加了一个自低而上的路径增强结构,缩 短了信息传播路径,同时有效利用了低层特征的精 准定位信息,提高网络预测的准确性。

YOLOv4的检测头会输出3条不同尺度的预测 信息,YOLO Head1的形状(shape)为(52,52,256), YOLO Head2的形状为(26,26,512),YOLO Head3 的形状为(13,13,1024),3个检测头可以分别用 来检测小目标、中目标以及大目标。YOLOv4模 型的损失函数采用的是完整并交比(complete intersection over union, CIOU),其计算公式如下:

$$L_{\text{CIOU}} = 1 - I_{\text{IOU}} + \left(\frac{d}{c}\right)^2 + \alpha r \qquad (1)$$

$$I_{\rm IOU} = \frac{A \cap A_{\rm gt}}{A \cup A_{\rm gt}} \tag{2}$$

式(1)、(2)中, I_{IOU} 为预测框面积A与真实框面积A_g 的交并比(intersection over union, IOU);d为预测框 与真实框中心点的距离;c为包括预测框和真实框的 最小矩形框对角线距离; α 为平衡比例参数;r为预测 框和真实框的宽高比例一致性参数,可以使预测框 的宽和高能更快地接近真实框,计算公式如下:

$$r = \frac{4}{\pi^2} \left(\arctan \frac{w_{\text{gt}}}{h_{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \qquad (3)$$

$$\alpha = \frac{r}{(1 - I_{\text{IOU}}) + r} \tag{4}$$

式(3)中, w_{gt} 为真实框的宽; h_{gt} 为真实框的高;w为 预测框的宽;h为预测框的高。



图 1 YOLOv4 网络结构 Figure 1 Network structure of YOLOv4

1.2 深度可分离卷积

深度可分离卷积(depthwise separable convolution)是将常规卷积分解为两步进行,先用深 度卷积(depthwise convolution)进行特征提取,然后 采用逐点卷积(pointwise convolution)调整输出的维 度。常规卷积的计算过程如图2所示,它将卷积核 用在所有的输入通道上,即卷积核维度和输入特征 图维度一样,在对应的维度上进行卷积计算,从而 生成一张新的特征图,再将不同卷积核生成的特征 图进行堆叠,就可以得到常规卷积的输出,输出的 维度和卷积核的个数一致。深度卷积则是对每个 输入通道都采用不同的卷积核,具体过程如图3所 示。逐点卷积也就是采用卷积核大小为1×1的常 规卷积,具体过程如图4所示。采用深度可分离卷 积可降低网络的计算量,对于大小为3×3的卷积 核,若采用常规卷积,则需要的参数量和计算量分 别如下:

$$3 \times 3 \times c_{i} \times c_{o} = 9c_{i}c_{o} \tag{5}$$

$$3 \times 3 \times c_{i} \times c_{o} \times n \times n = 9c_{i}c_{o}n^{2} \qquad (6)$$

式(5)、(6)中,ci为输入特征图的通道数;c。表示输出

特征图的通道数;n×n为输入特征图的尺寸。

若采用深度可分离卷积,则所需要的参数量和 计算量分别如下:

 $3 \times 3 \times c_{i} + c_{i} \times c_{o} = 9c_{i} + c_{i}c_{o} \qquad (7)$ $3 \times 3 \times c_{i} \times n^{2} + c_{i} \times c_{o} \times n^{2} = 9c_{i}n^{2} + c_{i}c_{o}n^{2} \quad (8)$

对比可知,输出通道数越多,使用深度可分离 卷积替换常规卷积的效果越明显,一般情况下,采 用深度可分离卷积代替标准的3×3卷积可以使模 型的参数量和计算量降低到原来的12%左右。



图2 常规卷积

Figure 2 Conventional convolution



图3 深度卷积

Figure 3 Depthwise convolution



图 4 逐点卷积 Figure 4 Pointwise convolution

1.3 MobileNet

MobileNet是由谷歌团队在2017年针对移动端 或嵌入式设备设计的轻量级卷积神经网络,该网络和 其他网络相比,能够在检测精度相当的情况下降低模 型的运算量。目前为止,MobileNet系列网络一共有 3个版本,分别为MobileNetV1、MobileNetV2^[18]和 MobileNetV3^[19],本文采用MobileNetV1作为主干 特征提取网络,其网络结构及参数如表1所示。 MobileNetV1的基本单元是深度可分离卷积,表1 中Conv为常规卷积;Conv dw为深度卷积。

表1	MobileNetV1网络结构和参数
Table 1	Network structure and parameters of
	the MobileNetV1

	the Widdlerverv 1		
类型/步长	滤波器形状	输入尺寸	
Conv/ 2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$	
Conv dw/ 1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$	
Conv/1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$	
Conv dw/2	$3 \times 3 \times 64 \text{ dw}$	$112{\times}112{\times}64$	
Conv/1	$1\!\times\!1\!\times\!64\!\times\!128$	$56\!\times\!56\!\times\!64$	
Conv dw/1	$3 \times 3 \times 128 \text{ dw}$	$56\!\times\!56\!\times\!128$	
Conv/1	$1 \times 1 \times 128 \times 128$	$56\!\times\!56\!\times\!128$	
Conv dw/2	$3 \times 3 \times 128 \text{ dw}$	$56 \times 56 \times 128$	
Conv/1	$1\!\times\!1\!\times\!128\!\times\!256$	$28 \times 28 \times 128$	
Conv dw/1	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$	
Conv/1	$1\!\times\!1\!\times\!256\!\times\!256$	$28 \times 28 \times 256$	
Conv dw/2	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$	
Conv/1	$1\!\times\!1\!\times\!256\!\times\!512$	$14 \times 14 \times 256$	
Conv dw/1	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$	
o× Conv/1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$	
Conv dw/2	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$	
Conv/1	$1\!\times\!1\!\times\!512\!\times\!1024$	$7 \times 7 \times 512$	
Conv dw/2	$3 \times 3 \times 1$ 024 dw	$7 \times 7 \times 1024$	
Conv/1	$1 \times 1 \times 1 \ 024 \times 1 \ 024$	$7 \times 7 \times 1024$	
Avg Pool/1	Pool 7×7	$7 \times 7 \times 1024$	
FC/1	1.024×1.000	$1 \times 1 \times 1$ 024	
Softmax/1	classifier	$1 \times 1 \times 1 000$	

1.4 改进的 YOLOv4 网络

为了在保证检测精度的同时降低模型的大小, 提升模型的检测速度,使模型在应用到无人机巡线 时检测的实时性效果更好,提出改进YOLOv4目标 检测算法,改进后的模型网络结构如图5所示。在 模型骨干网络部分采用MobileNetV1替换原来的 CSPDarknet53,使模型轻量化;在颈部网络上的改 进主要是将模型中标准的卷积使用深度可分离卷 积替换,减少模型的参数量和计算量,进而提升模 型的检测速度,同时在颈部网络引入CSPNet结构, 其核心思想就是将特征图拆成2个部分,一部分进 行卷积操作,另一部分和上一部分卷积操作的结果 进行连接(concat)操作,获取更丰富的梯度融合信 息。通过引入CSPNet结构可以解决网络优化过程 中的梯度信息重复的问题,加强卷积神经网络的学 习能力,这样既保证了推理速度和准确率,又减小

173

了模型尺寸。在图5中,CBL模块中的卷积为1×1 的常规卷积;DSC为深度可分离卷积模块,包括深 度卷积(DConv)和逐点卷积(PConv)2个模块; CDC代表3次卷积,其中一次为深度可分离卷积。



图 5 改进 YOLOv4 网络结构 Figure 5 Network structure of improved YOLOv4

2 实验结果与分析

2.1 数据集与实验平台

实验数据来源于架空线路的航拍图片,由于架 空线路的故障样本较少,因此对其进行了翻转、色 彩变换以及增加噪声的数据增强方式扩充数据集, 共得到2000张架空线路图像样本,图像中包含的 各类目标数量如表2所示。对图片中的电杆、变压 器、电杆倾斜和绝缘子脱落使用进行标定,标定后 会产生图像对应的XML文件,该文件包含了目标 的类别、尺寸以及位置信息。在模型训练之前,需 用K-means聚类算法对样本进行先验框的计算,选 择合适的先验框尺寸。

表2 目标数量 Table 2 Target number

~	
类别	数量
电杆	1 763
变压器	1 256
电杆倾斜	369
绝缘子脱落	352

本次实验使用的是Windows10操作系统,所用 电脑硬件配置为Nvidia GeForce RTX2080TI显卡、 酷睿 I7-9700K CPU。在Tensorflow2.2 深度学习框 架下使用改进的 YOLOv4 目标检测算法对标定好的架空线路图像数据集进行训练。

2.2 模型评价指标

评价一个目标检测模型的好坏,主要看模型的 检测精度和检测速度。模型的检测精度如何一般 可以用精确率(precision)、召回率(recall)、平均精度 值(average precision, AP)和平均精度均值(mean average precision, mAP)来衡量;评估速度的指标通 常使用的是每秒帧率(frame per second, FPS),即每 秒内可以处理的图片数量。

精确率是指在所有检测出的目标中检测正确的概率,精确率越高模型的误检率就越低,其计算 公式如下:

$$P = \frac{T_{\rm TP}}{T_{\rm TP} + T_{\rm FP}} \tag{9}$$

召回率是指所有的正样本中正确识别的概率, 召回率越高,模型出现漏检的概率也就越低,其计 算公式如下:

$$R = \frac{T_{\rm TP}}{T_{\rm TP} + T_{\rm FN}} \tag{10}$$

式(9)、(10)中,*T*_{TP}为识别正确的正样本数量;*T*_{FP}为 负样本被识别成正样本的数量;*T*_{FN}为正样本被识 别成负样本的数量。

由于在进行图片检测时会设定一个 IOU 阈值, 大于该阈值模型会将其预测为正类样本,否则会将 其预测为负类样本,通常为了更全面地衡量模型的

0/

性能会使用AP值作为模型的评价指标,所谓AP值 是指在不同的IOU阈值下,某一类别的精确率和召 回率所围曲线的面积。对于预测的类别有多个的 情况,可以采用mAP作为评价指标,mAP是指所有 类别AP值的平均值,计算如下:

$$P_{\rm mAP} = \frac{\sum P_{\rm AP}}{T_{\rm num_classes}} \tag{11}$$

式中, P_{mAP} 为平均精度均值; P_{AP} 为平均精度值; $T_{\text{num_classes}}$ 为目标类别数目。

2.3 算法性能对比

将改进后的模型与原模型在同一数据集上进 行性能对比,结果如表3所示。由表3可以看出,改 进后的模型各个类别的精确率、召回率及AP值与 原模型相当,而且对于电杆倾斜和绝缘子脱落检测 效果较差,这是因为对于电杆倾斜和绝缘子脱落这 样的故障类别来说,由于样本量相对较少,尤其是 绝缘子脱落,目标较小,容易受到背景的干扰,导致 检测的平均精度相对较低。

表3 实验结果 Table 3 Test results of fault detection

	Table 5	I Cot IC.	50113 01 18	unucie	ction	/0	
类别	精確	精确率		召回率		AP	
	改进模型	原模型	改进模型	原模型	改进模型	原模型	
电杆	96.85	96.33	91.11	95.33	97.15	98.13	
变压器	96.06	95.45	98.45	96.32	99.75	97.88	
电杆倾斜	93.09	93.02	89.31	95.65	92.38	93.64	
绝缘子脱落	\$ 81.90	82.82	82.28	83.73	82.27	84.71	

为了检验模型改进对检测性能的影响,将改进 的YOLOv4算法与原模型进行消融实验对比,对比 结果如表4所示,从表4可以看出,当把YOLOv4的 主干网络换成轻量型网络MobileNetV1后,mAP值 较原模型下降了1.03%,但检测速度提升了近 18.00 fps;在替换了主干网络的同时将颈部网络中 3×3的常规卷积替换为深度可分离卷积后,检测精 度较原模型降低了1.84%,而检测速度较原模型提 升了34.23 fps;为了弥补改进后的网络在检测精度 上的下滑,在颈部网络中,与只进行主干网络以及 深度可分离卷积的替换相比,在引入CSP结构后, 模型的检测精度有所提高,虽然仍比原模型的检测 精度低0.7%,但检测速度要远比原模型高,高出近 $35.00 \text{ fps}_{\circ}$

为了进一步验证改进模型的性能,将该模型的 检测精度、检测速度以及参数量与其他模型进行了 对比,对比结果如表5所示。从表5中可以看出经 过模型的对比可见,改进后的YOLOv4模型的参数 量仅为原模型的19.7%,检测速度提升到原模型的 1.68倍,而检测精度仅在原模型的基础上降低了 0.7%。同时将其与同为一阶段目标检测算法SSD 进行对比,可以看出改进后的YOLOv4算法的检测 精度和检测速度均比SSD算法高。经过模型的对 比,可以看出本文提出的改进的YOLOv4模型的性 能更适用于架空线路的无人机在线巡检。

表4 消融实验 Table 4 Ablation experiment

MobileNet	深度可分离卷积	CSP结构	$\mathrm{mAP}/\%$	速度/fps
_	—	—	93.59	50.73
\checkmark	—	—	92.56	68.83
\checkmark	\checkmark	—	91.75	84.96
\checkmark	\checkmark	\checkmark	92.89	85.40

表5 不同模型下的检测性能对比

 Table 5
 Comparison of detection performance in

different models

算法	mAP/%	FPS/fps	参数量/10 ⁷
SSD	92.14	46.25	2.63
YOLOv4	93.59	50.73	6.44
改进 YOLOv4	92.89	85.40	1.17

图 6 展示了模型的检测效果,识别出了架空线 路中的电杆、变压器、电杆倾斜和绝缘子跌落 4类 目标,并与原 YOLOv4算法以及 SSD 目标检测算 法的检测效果进行对比,其中图 6(a)为 SSD 的检 测效果图,6(b)为原 YOLOv4的检测效果图,6(c) 为改进 YOLOv4 的检测效果图,可以看出,3种模 型对电杆和变压器的检测效果较好,主要原因是电 杆和变压器的样本量充足且特征明显,但是对于多 目标重合度较高以及光线较差的情况下,SSD 目 标检测算法容易出现漏检的情况。SSD 目标检测 算法出现了电杆倾斜以及绝缘子脱落的漏检,而改 进 YOLOv4算法和原 YOLOv4算法均能够较好地 识别出各类目标,改进后的算法的检测速度更快。



(a) SSD 检测效果



(b) YOLOv4检测效果



(c) 改进 YOLOv4 检测效果

图 6 不同模型检测效果对比 Figure 6 Comparison of detection results of different algorithms

3 结语

针对低压架空线路的巡线问题,提出一种改进 的YOLOv4目标检测算法对架空线路中的电杆、变 压器、电杆倾斜和绝缘子脱落进行检测。模型采用 MobileNetV1代替YOLOv4中的骨干网络,并将网 络中3×3的常规卷积用深度可分离卷积替换,将检 测速度提升为原模型的1.68倍,同时为了使改进后 的模型的检测精度更高,在颈部网络中引入了CSP 网络结构,使模型能够在牺牲较小的精度下大幅度 提升检测速度。实验结果表明经过改进后的模型 参数量大大降低,仅为原模型的19.7%,检测速度从 原来的50.73 fps提升到85.40 fps,并且具有较高的 检测精度。为了更进一步验证该模型的优越性,将 其与同为一阶段目标检测的SSD算法进行对比,结 果表明改进后的YOLOv4算法在精度和速度上均 占有优势,能够应用到嵌入式设备上,利用无人机 实现对架空线路中常见的电力设备及故障进行实 时的检测。此外,本文存在一些不足,如在对正常 电杆和倾斜电杆进行检测时可能会出现由于拍摄 角度的不同,导致图片本身倾斜,使得将原来正常 的电杆检测成故障的倾斜电杆,因此在对图片进行 检测时需要根据拍摄的角度对图片进行校正处理, 然后对校正后的图片进行检测,或采用半监督学习 的方法做进一步的研究。

参考文献:

[1] 殷浩然, 苗世洪, 韩佶, 等. 基于三维卷积神经网络的配电物联网异常辨识方法[J]. 电力系统自动化, 2022, 46 (1):42-50.

YIN Haoran, MIAO Shihong, HAN Ji, et al. Anomaly identification method for distribution Internet of Things based on three-dimensional convolutional neural network [J]. Automation of Electric Power Systems, 2022, 46(1): 42-50.

[2] 郑含博,李金恒,刘洋,等.基于改进 YOLOv3 的电力设备
红外目标检测模型[J].电工技术学报,2021,36(7):
1389-1398.

ZHENG Hanbo,LI Jinheng,LIU Yang,et al.Infrared object detection model for power equipment based on improved YOLOv3[J]. Transactions of China Electrotechnical Society,2021,36(7):1389-1398.

- [3] 黄雪莜,熊俊,张宇,等.基于残差卷积神经网络的开关 柜局部放电模式识别[J].中国电力,2021,54(2):44-51.
 HUANG Xueyou, XIONG Jun, ZHANG Yu, et al. Partial discharge pattern recognition of switchgear based on residual convolutional neural network[J]. Electric Power, 2021,54(2):44-51.
- [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] 黄新宇,张洋,王黎明,等.基于 Mask-RCNN 算法的复合
 绝缘子串红外图像分割与温度读取[J].高压电器,2021, 57(9):87-94.

HUANG Xinyu, ZHANG Yang, WANG Liming, et al. Infrared image segmentation and temperature reading of composite insulator strings based on Mask-RCNN algorithm[J].High Voltage Apparatus,2021,57(9):87-94.

[6] 何宁辉,王世杰,刘军福,等.基于深度学习的航拍图像
 绝缘子缺失检测方法研究[J].电力系统保护与控制,
 2021,49(12):132-140.

HE Ninghui, WANG Shijie, LIU Junfu, et al. Research on infrared image missing insulator detection method based on deep learning[J]. Power System Protection and Control, 2021,49(12):132-140.

 [7] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2016:1440-1448.

- [8] REN S Q, HE K M, 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.
- [9] 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):37-43.
 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):37-43.
- [10] 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.
 HAN Gujing, 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.
- [11] 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),Las Vegas,NV,USA,2016:779-788.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]//European Conference on Computer Vision, Amsterdam, The Hetherlands, 2016:21-37.
- [13] ZHOU X Y, WANG D Q, KRÄHENBÜHL P. Objects as points[EB/OL]. [2021-10-19]. http://arxiv.org/abs/1904.07850. pdf
- [14] 杨焰飞,曹阳.改进YOLOv3的无人机拍摄图玻璃绝缘 子检测[J].计算机工程与应用,2022,58(3):259-265.
 YANG Yanfei,CAO Yang.Detection of glass insulators in images taken by drones based on improved YOLOv3[J]. Computer Engineering and Applications, 2022, 58(3): 259-265.
- [15] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017: 6517-6525.
- BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/ OL]. 2020: arXiv: 2004.10934. http://arxiv. org/abs/2004. 10934.pdf
- [19] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea, 2020:1314-1324.