

基于 YOLOv4 的绝缘子爆裂故障识别研究

高健宸, 张家洪*, 李英娜, 李川

昆明理工大学信息工程与自动化学院, 云南 昆明 650000

摘要 提出了一种基于 YOLOv4 目标检测方法的绝缘子爆裂故障智能识别模型, 以某供电局一年内正常绝缘子及爆裂绝缘子图像为样本, 对故障识别模型进行训练, 得出识别模型的权重。采用该模型对绝缘子及其爆裂故障进行识别测试, 结果表明, 该模型识别绝缘子的平均精度(AP)为 92.6%, 识别绝缘子爆裂故障的平均精度(AP)为 91.78%, 模型每秒处理帧数(FPS)为 46 frame/s, 与 Faster R-CNN、SSD 模型比较可得, 提出的绝缘子爆裂故障识别模型能够准确、快速地对绝缘及其爆裂故障进行识别。

关键词 机器视觉; 深度学习; YOLOv4; 绝缘子爆裂故障; 智能识别

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202259.0210005

Insulator Burst Fault Identification Based on YOLOv4

Gao Jianchen, Zhang Jiahong*, Li Yingna, Li Chuan

Faculty of Information Engineering and Automation, Kunming University of
Science and Technology, Kunming, Yunnan 650000, China

Abstract Based on the YOLOv4 target detection method, in this study, we proposed an intelligent insulator burst fault recognition model. Considering images of normal and burst insulators in a power supply bureau within one year as samples, the proposed model was trained to obtain its weight. The proposed model was further used to identify insulators and their bursting faults. Experimental results showed that the proposed model had an average precision of insulator positioning of 92.6%, an average precision of insulator burst fault location of 91.78%, and the model's resolution was 46 frame/s. Compared with Faster R-CNN and SSD models, the constructed insulator burst fault identification model can accurately and quickly identify insulators and their burst faults.

Key words machine vision; deep learning; YOLOv4; insulator burst failure; intelligent recognition

1 引言

绝缘子作为输配电系统中支撑电线的重要控件, 长期暴露于户外恶劣环境条件下, 面临温湿度、雷电、强电场、污秽以及自然灾害等各种挑战^[1]。只有对输配电线路绝缘子进行定期巡检, 及时对故障绝缘子进行维修或替换, 才能保证输电线路的稳定有效运行。

常用的绝缘子检测方式可分为人工现场检测、传统图像检测、深度学习目标检测三类。人工现场检测通常采用电压隔离、绝缘电阻、电场、超声波检测等方法进行检测^[2], 需要人工爬上杆塔进行检查, 不仅耗时耗力而且存在危险。传统针对绝缘子的图像检测方法基本可分为 3 类: 阈值分割法^[3]、边缘检测法^[4]和纹理特征检测法^[5]。但这 3 类方法通常只能完成单一环境下的识别, 对复杂环境下绝缘子

收稿日期: 2021-01-20; 修回日期: 2021-03-01; 录用日期: 2021-03-09

基金项目: 国家自然科学基金(61962031, 61765009)

通信作者: *zjh_mit@163.com

的分割识别效果不佳,难以达到工程实时检测的要求。随着深度学习在目标检测^[6-7]和故障分类^[8-9]方面的快速发展,传统检测方法的不足得以改善。

现有基于深度学习的绝缘子爆裂故障识别模型包括两类。一类是采用双阶段(Two stage)的目标检测模型,如 Faster R-CNN^[10]、Mask R-CNN^[11]等,将绝缘子检测分为特征提取和特征分类两部分;另一类是采用单阶段(One stage)的目标检测模型,如 YOLO^[12-14]、SSD^[15]等,将绝缘子检测转化为回归问题。2019年程海燕等^[16]使用 Faster R-CNN 模型识别航拍图像绝缘子,其识别平均精度为 90.5%,识别准确率较高,但是每秒处理帧数仅为 10.9 frame/s,检测的实时性有待提升。2019年赖秋频等^[17]提出了一种基于 YOLOv2 网络图像识别的输电线路绝缘子在线识别与缺陷诊断模型,绝缘子的识别平均精度为 90%,每秒处理帧数为 30 frame/s。董召杰^[18]使用 YOLOv3 模型对电力关键部件进行检测,绝缘子识别平均精度为 90.2%,模型每秒处理帧数为 57.6 frame/s。可见 YOLOV2、YOLOV3 模型在识别实时性方面有较大提升,但识别精度较低。

为了在保证实时性的前提下,进一步提高模型识别的平均精度,本文基于当前平均精度和每秒处

理帧数最高的 YOLOv4^[19]建立绝缘子及其爆裂故障识别模型。采用某供电局真实的绝缘子图像样本对检测模型进行训练,得到模型权重,并使用该模型对绝缘子及其爆裂故障进行识别实验。

2 基于改进 YOLOv4 的绝缘子爆裂识别模型

2.1 模型理论

YOLOv4 绝缘子爆裂识别模型是一种以 CSPDarknet-53 为基础,采用 PANet 网络进行特征融合的端到端(end-to-end)检测模型,将绝缘子图片划分为若干网格,在每个网格上通过候选框预测,最终输出每个候选框预测的绝缘子类别概率和坐标,得出绝缘子爆裂故障的位置。整体结构如图 1 所示,输入绝缘子图片的尺寸为 608 pixel×608 pixel,绝缘子特征提取网络 CSPDarknet-53 主要由 1×1 和 3×3 的卷积层组成,使用 DarknetConv2D_BN_Mish 卷积块解决了训练时因参数优化引起的输入相同但输出不同的问题,同时加快了网络训练速度。特征金字塔部分对 CSPDarknet-53 中最后一个特征层使用 Leaky_relu 函数进行 DarknetConv2D_BN_Leaky 卷积,并对非线性进行拟合,避免了梯度消失的问题。DarknetConv2D_BN_Mish 的卷积公

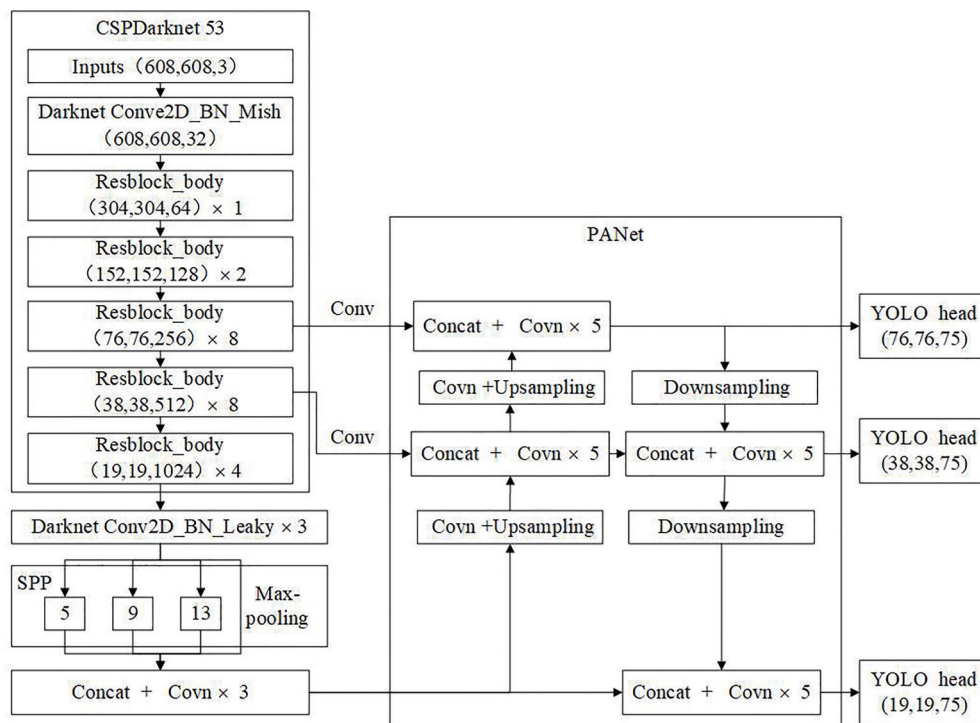


图 1 YOLOv4 网络结构

Fig. 1 YOLOv4 network structure

式为

$$y_{\text{Mish}} = x \times \tanh[\ln(1 + e^x)], \quad (1)$$

式中 y_{Mish} 为下级神经元输入, x 为上级神经元输出。

Leaky_relu 函数可表示为

$$y_i = \begin{cases} x_i, & x_i \geq 0 \\ \frac{x_i}{a_i}, & x_i < 0 \end{cases}, \quad (2)$$

式中 y_i 为下级神经元输入, x_i 为上级神经元输出, a_i 为 $(1, +\infty)$ 的固定参数。

SPP 模块利用池化核大小为 $13 \times 13, 9 \times 9, 5 \times 5,$




图2 PANet网络结构(a) FPN主干网络;(b)自下而上路径增强

Fig. 2 PANet network structure. (a) FPN backbone; (b) bottom-up path augmentation

2.2 K-means++聚类进行目标框改进

YOLOv4 网络沿用了 Faster R-CNN 中的先验框思想, 将目标检测简化为判断固定框内是否有检测目标、求解预测框和真实框之间的距离等问题。YOLOv4 设置了 9 个先验框, 将这 9 个先验框分别用于 3 个不同尺度 ($76 \times 76, 38 \times 38, 19 \times 19$) 的 YOLO 检测头上, 可得检测目标的预测框。但由于这 9 个先验框是根据 VOC 数据集的标注聚类得到的, 且数据集物体多、大小差别大, 造成先验框差别也大, 故在识别绝缘子爆裂故障时, 因目标较小, 使用原始的先验框会影响模型的识别性能。

为提升模型性能, 采用 K-means++ 聚类方法对绝缘子数据集进行聚类, 从绝缘子数据集中随机选择一个样本 x 的目标框作为初始的聚类中心 c_1 , 计算每个样本框与当前聚类中心的最小距离 $D(x)$, 通常情况下计算距离 $D(x)$ 采用欧氏距离, 但本实验中数据集为人为标注的矩形框, 大小不一致, 采用欧氏距离容易产生误差, 所以改进方法采

1×1 的 4 个不同尺度的最大池化层进行处理, 能极大地增加感受野, 分离出最显著的上下文特征。在 3 个有效特征层使用如图 2 所示的 PANet 网络完成绝缘子的特征提取, 首先完成图 2(a) 中传统特征的提取, 即高层特征进行上采样和低层特征进行自顶向下的连接, 完成自顶向下的特征融合后再进行图 2(b) 所示的从下到上的特征采样融合, 多次特征融合实现了对网络 3 个有效特征层的充分提取, 输出尺度为 $76 \times 76, 38 \times 38, 19 \times 19$ 的绝缘子特征图, 最后使用 YOLO head 得出类别、置信度和预测框参数等结果。

用交并比 (IOU) 距离 η_{IOU} , 随后计算每个绝缘子样本框被选为下一个聚类中心的概率 $a(x)$, 最终使用轮盘法选出下一个聚类中心。其中

$$D_{(N_{\text{box}}, N_{\text{centroid}})} = 1 - \eta_{\text{IOU}(N_{\text{box}}, N_{\text{centroid}})}, \quad (3)$$

$$a(x) = \frac{D(x)^2}{\sum_{x \in X} D(x)^2}, \quad (4)$$

式中: N_{box} 为数据集中边框尺寸样本, N_{centroid} 为类簇中心尺寸。

重复计算 $D(x)$ 和 $a(x)$ 的步骤直至选出 K 个聚类中心, 计算数据集中每个样本 x_i 到 K 个聚类中心的距离并将该样本分到距离最小的聚类中心对应的类中, 重新计算每个类别 c_i 的聚类中心, 即

$$c_i = \frac{1}{|c_i|} \sum_{x \in c_i} x_o. \quad (5)$$

重复更新分类和聚类中心直到先验框大小不变。

2.3 模型指标

损失值是评判模型训练效果的重要指标,损失函数曲线的收敛情况直接反映训练模型的稳定性。本文的绝缘子爆裂识别模型采用损失值之和的形

式计算模型损失值。模型损失值由坐标位置损失值(l_{CIoU})、置信度损失值($l_{\text{confidence}}$)和类别损失值(l_{class})三部分组成,采用完全交并比(CIoU)作为坐标位置损失值,即

$$L = l_{\text{CIoU}} + l_{\text{confidence}} + l_{\text{class}}, \quad (6)$$

$$l_{\text{CIoU}} = \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} \left[1 - \eta_{\text{IoU}} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \frac{\frac{16}{\pi^4} \left(\arctan \frac{\omega^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{\omega}{h} \right)^4}{1 - \eta_{\text{IoU}} + \frac{4}{\pi^2} \left(\arctan \frac{\omega^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{\omega}{h} \right)^2} \right], \quad (7)$$

$$l_{\text{confidence}} = - \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} \left[\hat{C}_i^{(j)} \log(C_i^{(j)}) + (1 - \hat{C}_i^{(j)}) \log(1 - C_i^{(j)}) \right] - \lambda_{\text{noobj}} \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{noobj}} \left[\hat{C}_i^{(j)} \log(C_i^{(j)}) + (1 - \hat{C}_i^{(j)}) \log(1 - C_i^{(j)}) \right], \quad (8)$$

$$l_{\text{class}} = - \sum_{i=0}^{s^2} I_{i,j}^{\text{obj}} \sum_c \left\{ \hat{p}_i^{(j)}(c) \log[p_i^{(j)}(c)] + [1 - \hat{p}_i^{(j)}(c)] \log[1 - p_i^{(j)}(c)] \right\}, \quad (9)$$

式中: s^2 为输出特征图上的网格数; B 为先验框个数; $I_{i,j}^{\text{obj}}$ 和 $I_{i,j}^{\text{noobj}}$ 为第*i*个网格第*j*个先验框含有目标的概率,有目标取1和0,没有目标取0和1; λ_{noobj} 为置信度误差权重,通常采用较小的 λ_{noobj} 处理包含目标网格与不包含目标网格数量差距过大的问题; C 和 \hat{C} 为预测框和真实框的置信度, p 和 \hat{p} 为预测框和真实框的类别概率; $\rho^2(b, b^{\text{gt}})$ 为预测框和真实框的中心点的欧氏距离; c 为同时包含预测框和真实框的最小闭包区域的对角线距离; b, ω, h 为预测框中心坐标和宽高; $b^{\text{gt}}, \omega^{\text{gt}}, h^{\text{gt}}$ 为真实框中心坐标和宽高。

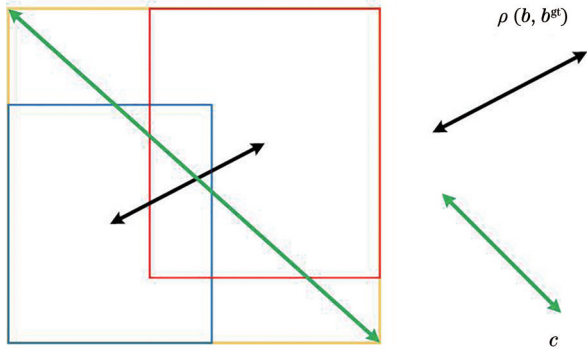


图 3 CIoU 示意图

Fig. 3 CIoU schematic diagram

绝缘子定位和爆裂故障识别可以归为一个二分类问题,采用平均精度(AP, P_A)来衡量模型的性能,采用每秒处理帧数(FPS, N_{FPS})来衡量模型的实时性,定义为

$$P_A = \int_0^1 P(R) dR, \quad (10)$$

$$N_{\text{FPS}} = 1/t_{\text{avg}}, \quad (11)$$

式中 $P(R)$ 为准确率 P 随召回率 R 的变化曲线, t_{avg} 为识别一张绝缘子图片的时间。

准确率和召回率是一组矛盾的指标,表达式为

$$P = \frac{T_p}{T_p + F_p}, \quad (12)$$

$$R = \frac{T_p}{T_p + F_n}, \quad (13)$$

式中 T_p 为准确识别的绝缘子个数, F_p 为将非绝缘子识别为绝缘子的个数, F_n 为未识别出的绝缘子个数。准确率和召回率其中一个增高时,另一个必然降低,使用单一指标不能完全衡量绝缘子爆裂故障识别模型的性能,所以通常采用AP值作为模型的衡量指标。以召回率 R 为*x*轴,准确率 P 为*y*轴作召回率-准确率(P - R)曲线,AP值的大小等于 P - R 曲线下覆盖的面积大小,AP越大,模型分类效果越好。FPS表示1s内模型能够识别的图片数量,FPS越高,表明模型的实时性能越好。

3 模型训练和测试

3.1 数据集制作

训练集采用某供电局供电线路无人机巡检和人工巡检获取的图片,从大量图片中筛选出绝缘子图片共计2030张,该图片的分辨率为8000 pixel × 6000 pixel,直接用于训练时运算量太大。因此将图

片缩放至 608 pixel×608 pixel 分辨率,以图片的最长边作为基准,在短边填充白边,形成低分辨率的正方形图片。此外,注意到图片集中包含的绝缘子爆裂图片相对较少,为保证模型后续使用的泛化性,采用随机翻转的方法扩充数据集,随机选取图片进行翻转±90°、180°,从而实现原始图片集的扩充,具体如图 4 所示。通过对数据集扩充得到包含玻璃、陶瓷、复合材料三种不同材料绝缘子的图片 5000 张,将数据集按 4:1 比例划分,随机选取 4000 张作为训练集,1000 张作为测试集。

根据模型要求将图片集转化为视觉目标分类(VOC)格式,采用 Labelimg 图片标注工具对图片进行标注,将绝缘子标注为 insulator,将绝缘子爆裂位置标注为 damage,标注过程中遇到大部分被杆塔遮挡且不利于直接判断状态的绝缘子时,放弃对其标




图 4 数据集扩充

Fig. 4 Data augmentation

注,具体如图 5 所示。通过上述工作,完成训练数据集的制作。

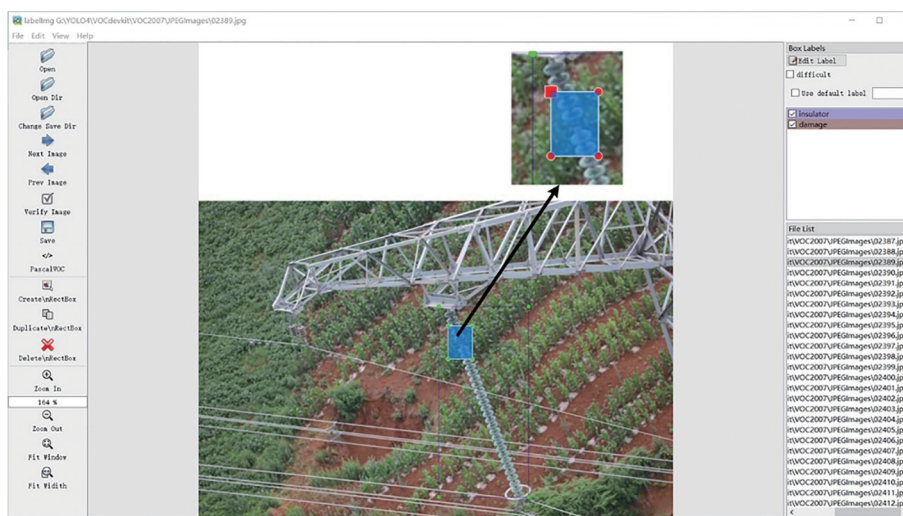


图 5 数据集标注

Fig. 5 Marking of insulator samples

3.2 模型训练

YOLOv4 预设的 9 个先验框为 (12, 16), (19, 36), (40, 28), (36, 75), (76, 55), (72, 146), (142, 110), (192, 243), (459, 401), 通过 K-means++ 聚类后得到针对绝缘子的新先验框为 (21, 56), (30, 33), (35, 83), (52, 51), (50, 133), (75, 180), (100, 64), (123, 133), (246, 351); 将新的先验框写入配置文件进行实验。

实验通过 Python 3.7 语言编程,采用深度学习架构 TensorFlow-2.2.0 在硬件 NVIDIA 1060 Ti GPU 上实现模型的训练。如图 6 所示,使用马赛克数据增强方式加强图像,将 4 张图片缩放翻转后拼接,以丰富检测物体的背景。采用余弦退火衰减更




图 6 马赛克数据增强

Fig. 6 Mosaic data augmentation

新学习率,设置标签平滑为 0.01,以防止过拟合。模型训练 80 个 epoch,前 30 个 epoch 采用冻结训练加快训练速度,以防止训练初期权值被破坏。设置学习率为 10^{-4} ,Batchsize 为 8,一个 epoch 迭代次数为 500。后 50 个 epoch 全网络训练,设置学习率为 10^{-3} ,Batchsize 为 4,一个 epoch 迭代次数为 1000。整个模型迭代 65000 次。

3.3 结果分析

根据(6)式,计算迭代次数和损失值下降关系,结果如图 7 所示。从图中可以看出,迭代 10 次前损耗值大幅下降,迭代 10 次后损耗值下降开始变缓,迭代 70 次后损耗值开始平稳收敛。因本实验只计算正样本损失,所以当迭代 75 次后损耗曲线收敛稳定时即可保存模型权重。

采用训练好的模型进行绝缘子及其爆裂故障识别的测试,设定预测框与真实框的 IOU 大于 0.5 为成功预测到目标位置,部分识别结果如图 8 所示,图 8(a)为无杆塔背景干扰、倾斜角度绝缘子的识别结果;图 8(b)和图 8(c)为有杆塔背景干扰、竖直和




图 7 损失函数收敛曲线

Fig. 7 Convergence curve of loss function

水平角度绝缘子的识别结果;图 8(d)为单绝缘子目标绝缘子爆裂故障的识别结果;图 8(e)为双绝缘子目标绝缘子爆裂故障的识别结果;图 8(f)为多绝缘子目标绝缘子爆裂故障的识别结果。由测试结果可得,提出的基于改进 YOLOv4 的绝缘子爆裂识别模型能够对复杂背景下不同角度的绝缘子及其爆裂故障进行识别。

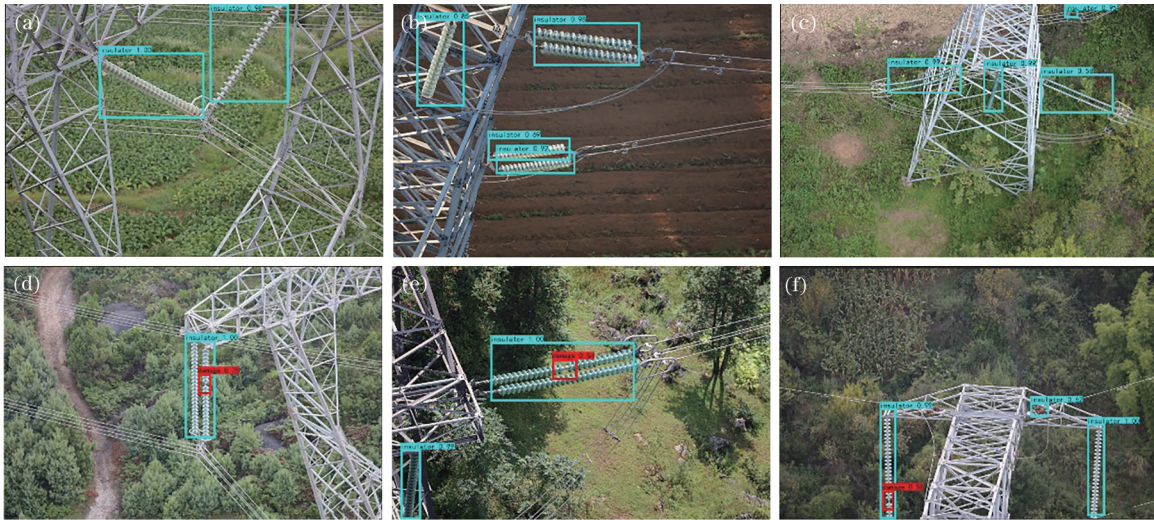


图 8 模拟测试结果。(a)无背景干扰;(b)(c)杆塔背景干扰;(d)单目标;(e)双目标;(f)多目标

Fig. 8 Simulation test results. (a) No background interference; (b)(c) with towers interference; (d) single target; (e) double target; (f) multi-target

测试集全部测试结果如表 1 所示。

将表 1 中的数据代入(12)式和(13)式可得基于改进 YOLOv4 绝缘子爆裂识别模型的准确率、召回

表 1 测试集测试结果
Table 1 Test results

Target	T_P	F_P	F_N
Insulator	4490	709	228
Insulator damage	265	47	13

率,并绘制 $P-R$ 曲线,结果如图 8 所示,横坐标为召回率,纵坐标为准确率。根据(10)式计算图 9(a)中阴影面积可得模型识别绝缘子的 AP 为 92.6%,计算图 9(b)中阴影面积可得模型识别绝缘子爆裂故障的 AP 为 91.78%,根据(11)式计算 FPS 结果为 46 frame/s。

使用同一数据集训练测试 YOLOv4、Faster R-CNN 和 SSD 模型并计算 AP 和 FPS,结果如图 10 所




图 9 K-means++ YOLOv4 模型 P - R 曲线。(a) 绝缘子识别; (b) 绝缘子爆裂故障识别

Fig. 9 P - R curves of K-means++ YOLOv4 model. (a) Insulator identification; (b) insulator burst fault identification




图 10 不同检测算法性能指标对比

Fig. 10 Comparison of performance indicators of different detection algorithms

示。从图中可得出,改进 YOLOv4 的绝缘子爆裂故障识别模型识别绝缘子的 AP 比 YOLOv4 模型、Faster R-CNN 模型、SSD 模型分别提高 1.5、2.4 和 5.7 个百分点;识别绝缘子爆裂故障的 AP 比 YOLOv4 模型、Faster R-CNN 模型、SSD 模型分别提高 4.2、8.28 和 13.88 个百分点;FPS 比 Faster R-CNN 模型、SSD 模型分别多 2、28、13 frame/s。因此,提出的基于改进 YOLOv4 的绝缘子爆裂故障识别模型在保证实时性的情况下提高了识别绝缘子及其爆裂故障的准确性。

4 结 论

提出了基于改进 YOLOv4 的绝缘子故障识别模型,使用某供电局线路巡检图片制作数据集,训练测试该绝缘子爆裂故障识别模型并进行对比实验。结果表明,基于改进 YOLOv4 的绝缘子爆裂故障识别模型识别绝缘子的平均精度 (AP) 为 92.6%,识别绝缘子爆裂故障的平均精度 (AP) 为 91.78%,每秒处理帧数 (FPS) 为 46 frame/s。本文

所提模型在准确性和实时性上均高于 YOLOv4、Faster R-CNN 和 SSD 模型,可以在复杂背景下完成对不同角度绝缘子及其爆裂故障的识别。本文模型对绝缘子爆裂故障识别符合智能巡检要求,但卷积层数过多导致网络计算复杂,后续研究将以网络小型化为主,在保证识别精度的情况下,精简网络大小。

参 考 文 献

- [1] Lü Z N. A survey of common faults analysis and detection methods for transmission line[J]. Automation & Instrumentation, 2020(1): 161-164, 168. 吕志宁. 输电线路常见故障分析与检测方法综述[J]. 自动化与仪器仪表, 2020(1): 161-164, 168.
- [2] Deng K, Tu M, Wan W J, et al. Discussion on the application of live detection methods for UHV insulators[J]. Electrical Manufacturing, 2014, 9(11): 70-75. 邓科, 涂明, 万文杰, 等. 特高压绝缘子带电检测方法应用探讨[J]. 电气制造, 2014, 9(11): 70-75.
- [3] Huang X N, Zhang Z L. A method to extract insulator image from aerial image of helicopter patrol[J]. Power System Technology, 2010, 34(1): 194-197. 黄宵宁, 张真良. 直升机巡检航拍图像中绝缘子图像的提取算法[J]. 电网技术, 2010, 34(1): 194-197.
- [4] Zhao Z B, Jin S X, Liu Y C. Aerial insulator image edge extraction method based on NSCT[J]. Chinese Journal of Scientific Instrument, 2012, 33(9): 2045-2052. 赵振兵, 金思新, 刘亚春. 基于 NSCT 的航拍绝缘子图像边缘提取方法[J]. 仪器仪表学报, 2012, 33(9): 2045-2052.
- [5] Li W G, Ye G S, Huang F, et al. Recognition of insulator based on developed MPEG-7 texture feature

- [J]. High Voltage Apparatus, 2010, 46(10): 65-68.
李卫国, 叶高生, 黄锋, 等. 基于改进 MPEG-7 纹理特征的绝缘子图像识别[J]. 高压电器, 2010, 46(10): 65-68.
- [6] Sun Y C, Pan S G, Zhao T, et al. Traffic light detection based on optimized YOLOv3 algorithm[J]. Acta Optica Sinica, 2020, 40(12): 1215001.
孙迎春, 潘树国, 赵涛, 等. 基于优化 YOLOv3 算法的交通灯检测[J]. 光学学报, 2020, 40(12): 1215001.
- [7] Ju M R, Luo H B, Wang Z B, et al. Improved YOLO V3 algorithm and its application in small target detection[J]. Acta Optica Sinica, 2019, 39(7): 0715004.
鞠默然, 罗海波, 王仲博, 等. 改进的 YOLO V3 算法及其在小目标检测中的应用[J]. 光学学报, 2019, 39(7): 0715004.
- [8] Xue Y, Wu H D, Zhang N, et al. Detection of insulation piercing connectors and bolts on the transmission line using improved Faster R-CNN[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081008.
薛阳, 吴海东, 张宁, 等. 基于改进 Faster R-CNN 输电线穿刺线夹及螺栓的检测[J]. 激光与光电子学进展, 2020, 57(8): 081008.
- [9] Zhang G S, Ge G Y, Zhu R H, et al. Gear defect detection based on the improved YOLOv3 network [J]. Laser & Optoelectronics Progress, 2020, 57(12): 121009.
张广世, 葛广英, 朱荣华, 等. 基于改进 YOLOv3 网络的齿轮缺陷检测[J]. 激光与光电子学进展, 2020, 57(12): 121009.
- [10] 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.
- [11] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [12] 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 Press, 2016: 779-788.
- [13] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [14] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2021-01-15]. <https://arxiv.org/abs/1804.02767>.
- [15] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [16] Cheng H Y, Zhai Y J, Chen R. Faster R-CNN based recognition of insulators in aerial images[J]. Modern Electronics Technique, 2019, 42(2): 98-102.
程海燕, 翟永杰, 陈瑞. 基于 Faster R-CNN 的航拍图像中绝缘子识别[J]. 现代电子技术, 2019, 42(2): 98-102.
- [17] Lai Q P, Yang J, Tan B D, et al. An automatic recognition and defect diagnosis model of transmission line insulator based on YOLOv2 network[J]. Electric Power, 2019, 52(7): 31-39.
赖秋频, 杨军, 谭本东, 等. 基于 YOLOv2 网络的绝缘子自动识别与缺陷诊断模型[J]. 中国电力, 2019, 52(7): 31-39.
- [18] Dong Z J. Real-time detection of power transmission line key components based on YOLOv3[J]. Electronic Measurement Technology, 2019, 42(23): 173-178.
董召杰. 基于 YOLOv3 的电力线关键部件实时检测[J]. 电子测量技术, 2019, 42(23): 173-178.
- [19] Bochkovskiy A, Wang C Y, Liao H Y M, et al. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-24)[2020-09-21]. <https://arxiv.org/abs/2004.10934>.